

وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR – ANNABA UNIVERSITY

UNIVERSITE BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Année: 2019

Faculté des Science de l'Ingéniorat
Département de Génie Mécanique

THÈSE

Présentée en vue de l'obtention du diplôme de DOCTORAT.

**DIAGNOSTIC EMBARQUÉ APPLIQUÉ A UN
SYSTÈME MÉCANIQUE : MOTEUR DIESEL**

Spécialité : Génie Mécanique

Option : Génie Mécanique

Par :

Zine Laabidine BENSAFIA

DEVANT LE JURY

Président :

Pr. BOUCHELAGHEM Abdelaziz Mahmoud Université Annaba

Rapporteur :

Pr. LAKEL Rabah Université Annaba

Examineurs:

Pr. SAAD Salah Université Annaba

Pr. GUERSI Nouredine Université Annaba

Pr. AZZOUZ Salaheddine E.S.T.I Annaba

Pr. BOUCHOUCHA Ali Université Constantine 1

Je dédie ce modeste travail
A mes chers parents
A mes sœurs Asma et Meryem
A mes frères Abd Rahim et Mohamed
A toute ma famille,
A mes amis.

REMERCIEMENTS

L'ensemble des travaux présentés dans ce mémoire a été effectué au Laboratoire de Mécanique Industrielle LMI à l'Université Badji-Mokhtar d'Annaba, Département de Mécanique.

J'exprime ma profonde gratitude et mes vifs remerciements à mon directeur de thèse, Monsieur LAKEL Rabah, Professeur à l'Université d'Annaba, pour sa patience et pour m'avoir guidé vers une meilleure vision professionnelle de la recherche. Mais surtout pour ses conseils judicieux et de m'avoir fait profiter de ses connaissances durant toute le déroulement de la thèse.

Il est de coutume de remercier les membres de comité pour leurs conseils, leur soutien, leur disponibilité et surtout leurs grandes qualités humaines.

Je remercie très vivement Monsieur Bouchelaghem Abdelaziz Mahmoud, Professeur à l'université d'Annaba, pour l'honneur qu'il me fait en président le jury de cette thèse.

Je remercie également

Monsieur Guersi Noureddine, Professeur à l'université d'Annaba ;

Monsieur Saad Salah, Professeur à l'université d'Annaba ;

Monsieur Azzouz Salaheddine, Professeur à E.S.T.I d'Annaba ;

Monsieur Bouchoucha Ali, Professeur à l'université des frères mentouri, Constantine1,

de l'intérêt qu'ils ont montré pour mon travail et d'avoir accepté d'être examinateurs de ma thèse.

Je remercie vivement Monsieur GUERSI Noureddine et Monsieur BENOUARETH pour l'aide précieuse qu'ils ont apporté dans l'élaboration d'une partie de ces travaux.

Je remercie également les jeunes docteurs et futur docteurs du laboratoire qui, durant ces années, ont entretenu une très bonne ambiance et ont fait preuve de solidarité. Je souhaite aux doctorants du succès dans leurs recherches ainsi que dans leurs vies professionnelles.

Je tiens aussi à exprimer ma reconnaissance à mes parents et mes frères pour leur soutien inconditionnel.

Titre DIAGNOSTIC EMBARQUÉ APPLIQUÉ A UN SYSTÈME MÉCANIQUE : MOTEUR DIESEL

Résumé Les moteurs Diesel modernes sont de plus en plus complexes et la sécurité préventive dans de tels systèmes continue à intéresser les constructeurs. Il s'agit d'un enjeu majeur dont l'objectif est l'augmentation de la sécurité et la diminution de la pollution, afin de prévoir la moindre défaillance d'une part et de répondre aux exigences des normes environnementales d'autre part.

L'utilisation d'un système de diagnostic en ligne (temps réel) pour les moteurs diesel est une nécessité incontournable. À partir des modèles décrits dans la littérature, les modèles du moteur diesel dernière génération ainsi que les défauts pouvant l'affecter ont été établis. Deux systèmes de diagnostic ont été développés. Le premier système permet le diagnostic en ligne en utilisant les techniques de reconnaissances des formes floue, le second système de diagnostic basé sur les séparateurs à vastes marges (SVM) permet la classification des différents modes de fonctionnement et dysfonctionnement du moteur diesel.

Mots Clés: *diagnostic en ligne (temps réel) – moteur diesel – modèle de connaissance – reconnaissance de formes floues - diagnostic à base de modèle – classification – Séparateurs à vastes marges.*

Title EMBARKED DIAGNOSIS APPLIED TO A MECHANICAL SYSTEM: DIESEL ENGINE

Abstract The modern diesel engines has become increasingly complex, the preventive safety in such systems continues to interest the manufacturers, it is a major issue with the aim is to increase safety and decrease pollution to predict any failure on one hand and to meet environmental standards on the other.

The use of a system of on-line diagnosis (Real time) for diesel engines has become an unavoidable necessity. From the models described in the literature, the latest generation diesel engine models as well as defects affecting it were established. Two systems of diagnosis were developed; the first system allows the on-line diagnosis by using the fuzzy pattern recognition techniques. The second system of diagnosis based on Support Vector Machines (SVM) allows the classification of different mode of functioning and dysfunction of the diesel engine.

Key words: *diagnostics on-line (real time) - diesel engine - knowledge model - fuzzy Pattern recognition - diagnosis with model – Classification, Support Vector Machines.*

ملخص

أصبحت محركات الديزل الحديثة أكثر تعقيدا, الأمن الوقائي في هذه الأنظمة يستمر في جذب اهتمام المصنعين, إنها قضية كبرى بهدف زيادة السلامة وتقليل التلوث, للتنبؤ بأي عُطل من جهة وتلبية متطلبات المعايير البيئية من جهة أخرى.

استخدام نظام التشخيص للمتابعة الآنية لمحركات الديزل ضرورة لا مفر منها. من خلال النماذج الواردة في الأدب, نماذج من محرك الديزل الجيل الجديد وكذلك نماذج العيوب التي قد تآثر عليه تم إعدادها. نظامين للتشخيص تم إنشاءهما, النظام الأول يسمح بالتشخيص الآني باستخدام تقنيات التعرف غير الجلي على الأشكال. النظام الثاني للتشخيص يعتمد على تقنية (SVM) التي تمكن تصنيف وضعيات العمل العادية و الاختلال الوظيفي في محرك الديزل.

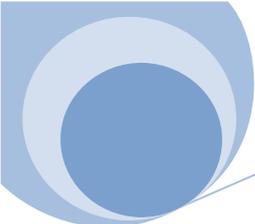
الكلمات المفتاحية : التشخيص الآني - محركات الديزل - نموذج المعرفة - التعرف غير الجلي على الأشكال - التشخيص القائم على نموذج - التصنيف - فاصل كبير هامش.

TABLE DES MATIÈRES

| | |
|------------------------------|-------------|
| TABLE DES MATIÈRES | i |
| INDEX DES FIGURES | v |
| INDEX DES TABLEAUX | viii |
| NOTATIONS | x |
| ABREVIATIONS | xiv |
| INTRODUCTION GENERALE | 1 |

CHAPITRE I : Généralités sur le diagnostic des systèmes

| | |
|--|----|
| 1.1 Introduction..... | 05 |
| 1.2 Diagnostic des défaillances..... | 06 |
| 1.2.1 Introduction..... | 06 |
| 1.2.2 La surveillance..... | 06 |
| 1.2.3 La détection..... | 06 |
| 1.2.4 Le diagnostic..... | 06 |
| 1.2.4.1 Localisation..... | 06 |
| 1.2.4.2 Identification de défauts..... | 06 |
| 1.3 Terminologie de diagnostic..... | 07 |
| 1.4 Classification des méthodes de diagnostic..... | 08 |
| 1.4.1 Méthodes externes..... | 08 |
| 1.4.1.1 Reconnaissance des formes..... | 08 |
| 1.4.1.2 Réseaux de neurones..... | 09 |
| 1.4.1.3 Systèmes expert..... | 10 |
| 1.4.2 Méthodes internes..... | 11 |
| 1.4.2.1 Méthodes de modèle..... | 11 |
| 1.4.2.2 Méthodes d'identification de paramètre..... | 11 |
| 1.4.2.3 Méthodes d'estimation du vecteur d'état..... | 11 |
| 1.4.2.4 Méthode de résidus..... | 12 |
| 1.4.2.4.1 Espace de partie..... | 12 |
| 1.4.2.4.2 Observateur..... | 13 |
| 1.5 Conclusion..... | 13 |



CHAPITRE II : Classification des données

| | |
|--|----|
| 2.1 Introduction..... | 15 |
| 2.2 Reconnaissance des formes..... | 15 |
| 2.2.1 Définition de l'espace de représentation..... | 16 |
| 2.2.1.1 Réduction de l'espace de représentation..... | 17 |
| 2.2.1.1.1 Extraction des variables..... | 17 |
| a) Analyse en composante principale..... | 17 |
| 2.2.1.1.2 Sélection des variables..... | 19 |
| a) Critère d'évaluation..... | 19 |
| b) Procédure de recherche..... | 21 |
| c) Critère d'arrêt..... | 21 |
| 2.2.1.2 Structuration de l'espace de représentation..... | 21 |
| 2.2.1.3 Détermination d'une méthode de décision..... | 22 |
| 2.2.1.4 Evaluation du système de diagnostic..... | 24 |
| 2.3 Reconnaissance des formes floue | 25 |
| 2.3.1 Caractéristique des fonctions d'appartenance..... | 25 |
| 2.3.2 Opérations sur les sous-ensembles flous..... | 27 |
| 2.3.3 Classification floue supervisée..... | 28 |
| 2.3.3.1 K plus proches voisins..... | 28 |
| 2.3.3.2 Algorithme de Bayes..... | 29 |
| 2.3.4 Classification floue non-supervisée..... | 29 |
| 2.3.4.1 Algorithme FCM..... | 29 |
| 2.3.4.1.1 Avantages et inconvénients de l'algorithme FCM..... | 31 |
| 2.3.4.2 Les algorithmes dérivés de l'algorithme FCM..... | 31 |
| 2.3.4.2.1 Algorithme de Gustafson et kassel..... | 32 |
| 2.3.4.2.2 Algorithme C-moyennes possibiliste..... | 33 |
| 2.3.4.2.3 Algorithme C-moyennes possibiliste modifié..... | 34 |
| 2.3.4.3 Problème de classification..... | 35 |
| 2.3.4.3.1 Validation du nombre des classes..... | 35 |
| 2.3.4.3.2 Méthode d'initialisation de la partition..... | 36 |
| 2.3.5 Définition des fonctions d'appartenances..... | 36 |
| 2.3.5.1 Exploitation des résultats de la classification floue..... | 36 |
| 2.3.6 Règle de décision à partir des degrés d'appartenance..... | 37 |
| 2.4 Séparateur à vaste marge (SVM)..... | 39 |
| 2.4.1 Principe de la méthode SVM | 39 |
| 2.4.1.1 Cas des données linéairement séparables | 40 |
| 2.4.1.2 Cas des données non-linéairement séparable | 42 |
| 2.4.1.2.1 Utilisation des fonctions noyaux | 42 |
| 2.4.1.2.2 SVM à marge souple | 45 |
| 2.4.1.2.3 SVM multi-classe | 47 |

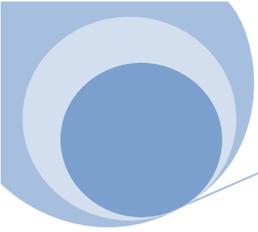


Table des matières

| | |
|-----------------------------|----|
| a) SVM Un Contre Tous | 47 |
| b) SVM Un Contre Un | 48 |
| 2.5 Conclusion..... | 48 |

CHAPITRE III Modélisation du moteur diesel

| | |
|--|----|
| 3.1 Introduction..... | 50 |
| 3.2 Architecture d'un moteur diesel..... | 50 |
| 3.2.1 Bloc moteur (Carter-cylindre)..... | 50 |
| 3.2.2 Cylindres..... | 51 |
| 3.2.3 Le piston..... | 51 |
| 3.2.4 La bielle..... | 51 |
| 3.2.5 Le vilebrequin..... | 51 |
| 3.2.6 L'arbre à cames..... | 52 |
| 3.2.7 Le système d'injection..... | 52 |
| 3.2.8 Différents capteurs d'un moteur diesel..... | 52 |
| 3.2.8.1 Capteur d'arbre à came..... | 53 |
| 3.2.8.2 Capteur de vilebrequin..... | 53 |
| 3.2.8.3 Capteur de température de carburant..... | 53 |
| 3.2.8.4 Capteurs de température d'air d'admission..... | 53 |
| 3.2.8.5 Capteur de vitesse du véhicule..... | 54 |
| 3.2.8.6 Capteur de phase..... | 54 |
| 3.3 Différents types de moteur diesel..... | 54 |
| 3.3.1 Moteurs à injection directs..... | 54 |
| 3.3.2 Moteurs à injection indirects..... | 55 |
| 3.3.3 Moteurs à injection haute pression à rampe commune..... | 56 |
| 3.4 Fonctionnement d'un moteur diesel..... | 57 |
| 3.4.1 Le cycle à 4 temps..... | 57 |
| 3.4.2 Classification..... | 59 |
| 3.4.2.1 Combustion..... | 59 |
| 3.4.2.2 Suralimentation..... | 59 |
| 3.4.3 Les émissions polluantes..... | 60 |
| 3.5 Modélisation d'un moteur diesel..... | 60 |
| 3.5.1 Modèle d'injection..... | 61 |
| 3.5.1.1 Modèle de défaut d'injection..... | 61 |
| 3.5.2 Modèle d'admission..... | 61 |
| 3.5.2.1 Modèle d'admission avec défaut fuite dans le collecteur d'admission..... | 62 |
| 3.5.2.2 Modèle d'admission avec défaut des soupapes d'admission..... | 63 |
| 3.5.2.3 Modèle d'admission avec défaut de compression..... | 63 |
| 3.5.3 Modèle du bloc moteur (Solides en mouvement)..... | 63 |
| 3.5.4 Modèle des émissions polluantes..... | 65 |

| | |
|---|----|
| 3.6 Simulation de modèle sans et avec défaut..... | 65 |
| 3.6.1 Modèle moteur diesel sous l'interface Simulink de Matlab..... | 65 |
| 3.7 Conclusion..... | 68 |

CHAPITRE IV Résultats de classification

| | |
|--|----|
| 4.1 Introduction | 70 |
| 4.2 Classification par reconnaissance des formes floue..... | 70 |
| 4.2.1 Apprentissage hors ligne..... | 71 |
| 4.2.2 Apprentissage en ligne..... | 72 |
| 4.3 Résultats de programme de classification par SVM..... | 78 |
| 4.3.1 Classification des données de vitesse de rotation..... | 79 |
| 4.3.2 Classification des données de pression d'admission..... | 82 |
| 4.3.3 Classification des données des émissions polluantes..... | 84 |
| 4.4 Conclusion..... | 87 |

CHAPITRE V Simulation et Implémentation

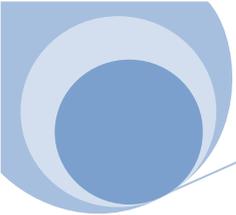
| | |
|--|-----|
| 5.1 Introduction | 90 |
| 5.2 Systèmes embarqués pour le diagnostic | 90 |
| 5.2.1 Introduction aux systèmes embarqués | 90 |
| 5.2.2 Architecture des systèmes embarqués | 91 |
| 5.2.3 Contraintes des systèmes embarqués | 92 |
| 5.2.4 Réseaux logiques programmables (FPGA) | 92 |
| 5.3 Cartographie de l'architecture FPGA | 93 |
| 5.3.1 Algorithme SVM non linéaire | 93 |
| 5.3.2 Modules informatiques pour SVM non-linéaire..... | 95 |
| 5.4 Résultats | 105 |
| 5.5 Conclusion | 110 |

CONCLUSION GÉNÉRALE 111

ANNEXE

| | |
|--|-----|
| A .1 Influence de la chute de pression sur la vitesse de rotation..... | 113 |
| A.1.1 Listes des constantes..... | 113 |
| A.2 Transformation et sélection de l'information..... | 114 |
| A.2.1 ACP Sur les données de pression d'admission..... | 114 |
| A.3 FPGA Cyclone II..... | 120 |

BIBLIOGRAPHIE 123



INDEX DES FIGURES

CHAPITRE I

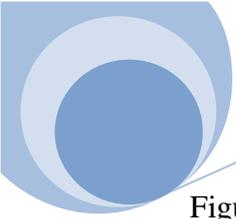
| | | |
|------------|---|----|
| Figure 1.1 | Les phases de diagnostic..... | 07 |
| Figure 1.2 | Schéma général d'un neurone..... | 09 |
| Figure 1.3 | Fonction d'activation les plus utilisées..... | 10 |
| Figure 1.4 | Architecture d'un système expert..... | 10 |
| Figure 1.5 | Principe de génération des résidus..... | 12 |

CHAPITRE II

| | | |
|-------------|---|----|
| Figure 2.1 | Diagnostic d'un système : approche reconnaissance des formes..... | 16 |
| Figure 2.2 | Représentation d'un vecteur forme dans un espace de dimension d | 16 |
| Figure 2.3 | Processus de sélection de variables..... | 19 |
| Figure 2.4 | Méthodes de classification non-supervisée (Méthode de Coalescence) | 22 |
| Figure 2.5 | Rejet d'ambiguïté. Observation située près de la frontière de décision entre deux classes..... | 23 |
| Figure 2.6 | Rejet de distance. Observation ne correspond à aucune des classes connues..... | 23 |
| Figure 2.7 | Représentation d'une fonction d'appartenance au sens classique et au sens flou..... | 25 |
| Figure 2.8 | Exemple de fonction d'appartenance..... | 26 |
| Figure 2.9 | Principaux éléments caractéristiques d'un sous ensemble flou..... | 27 |
| Figure 2.10 | Séparation des deux classes par SVM | 39 |
| Figure 2.11 | Séparation linéaire | 40 |
| Figure 2.12 | (I) Pas de hyperplan séparateur ; (II) Hyperplan dans un autre espace | 42 |
| Figure 2.13 | Séparation non linéaire par méthode de noyau | 44 |
| Figure 2.14 | Séparation non linéaire par marge souple | 46 |
| Figure 2.15 | SVM Un Contre Tous | 47 |

CHAPITRE III

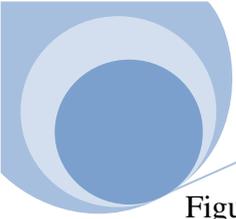
| | | |
|-------------|---|----|
| Figure 3.1 | Moteur Diesel injection directe | 50 |
| Figure 3.2 | Eléments d'un Vilebrequin..... | 51 |
| Figure 3.3 | Schéma descriptif d'un système d'injection directe diesel à rampe commune..... | 52 |
| Figure 3.4 | Capteur d'arbre à came..... | 53 |
| Figure 3.5 | Capteur de vilebrequin..... | 53 |
| Figure 3.6 | Capteur de température de carburant..... | 53 |
| Figure 3.7 | Capteur de température d'air d'admission..... | 54 |
| Figure 3.8 | Capteur de phase..... | 54 |
| Figure 3.9 | Injection directe..... | 55 |
| Figure 3.10 | Injection indirecte..... | 56 |



| | | |
|-------------|--|----|
| Figure 3.11 | Système d'injection haute pression à rampe commune..... | 56 |
| Figure 3.12 | Décomposition du cycle à quatre temps du moteur diesel..... | 58 |
| Figure 3.13 | Cycle d'un moteur Diesel..... | 58 |
| Figure 3.14 | Structure du sous modèle d'injection..... | 61 |
| Figure 3.15 | Structure du sous modèle d'admission..... | 62 |
| Figure 3.16 | Structure du sous modèle du bloc moteur | 63 |
| Figure 3.17 | Courbe du rendement indiqué en fonction de l'excès d'air | 64 |
| Figure 3.18 | Structure de sous modèle d'émissions polluantes..... | 65 |
| Figure 3.19 | Architecture d'un moteur diesel sans défaut dans l'interface Simulink de Matlab | 66 |
| Figure 3.20 | Architecture d'un moteur diesel avec défauts dans l'interface Simulink de Matlab | 66 |
| Figure 3.21 | Influence des défauts sur la vitesse de rotation | 67 |
| Figure 3.22 | Influence des défauts sur la pression d'admission | 67 |
| Figure 3.23 | Influence des défauts sur les émissions Polluantes..... | 67 |

CHAPITRE IV

| | | |
|-------------|---|----|
| Figure 4.1 | Influence de défaut d'injection et défaut de fuite d'admission sur la vitesse de rotation | 71 |
| Figure 4.2 | Classification des données de vitesse de rotation (Apprentissage hors ligne)..... | 71 |
| Figure 4.3 | Rejet en distance d'une nouvelle observation Ob 1 | 72 |
| Figure 4.4 | Classification d'une nouvelle observation Ob2 | 73 |
| Figure 4.5 | Classification des données de Pression d'admission | 74 |
| Figure 4.6 | Modes de fonctionnement du moteur diesel relatif à la classification des données de pression d'admission..... | 74 |
| Figure 4.7 | Classification des données de vitesse de rotation..... | 75 |
| Figure 4.8 | Modes de fonctionnement du moteur relatif à la classification des données de vitesse de rotation..... | 76 |
| Figure 4.9 | Classification des données des emissions polluantes..... | 77 |
| Figure 4.10 | Modes de fonctionnement du moteur relatif à la classification des données d'émissions polluantes..... | 77 |
| Figure 4.11 | Classification des données ω (sans défaut et avec tous les défauts) | 80 |
| Figure 4.12 | Classification des données ω (sans défaut d'injection et avec défaut d'injection)..... | 80 |
| Figure 4.13 | Classification données ω (sans défaut de compression et avec défaut de compression)..... | 81 |
| Figure 4.14 | Classification données ω (sans défaut soupape ad et avec défaut soupape | 81 |
| Figure 4.15 | Classification données ω (Sans défaut fuite ad et avec défaut fuite | 81 |
| Figure 4.16 | Classification données p_a (sans défaut et avec défaut)..... | 82 |
| Figure 4.17 | Classification données p_a (sans défaut d'injection et avec défaut..... | 82 |
| Figure 4.18 | Classification données p_a (sans défaut de compression et avec défaut de compression)..... | 83 |
| Figure 4.19 | Classification données p_a (sans défaut soupape ad et avec défaut de soupape ad)..... | 83 |



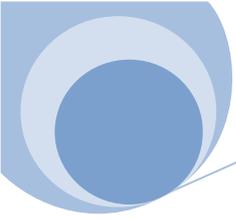
| | | |
|-------------|--|----|
| Figure 4.20 | Classification données p_a (sans défaut fuite ad et avec défaut fuite | 83 |
| Figure 4.21 | Classification données E_p (sans défaut et avec défaut)..... | 85 |
| Figure 4.22 | Classification données E_p (sans défaut d'injection et avec défaut d'injection). | 85 |
| Figure 4.23 | Classification données E_p (sans défaut de compression et avec défaut de compression)..... | 85 |
| Figure 4.24 | Classification données E_p (sans défaut soupape ad et avec défaut de soupape ad)..... | 85 |
| Figure 4.25 | Classification données E_p (sans défaut fuite ad et avec défaut fuite..... | 86 |

CHAPITRE V

| | | |
|-------------|--|-----|
| Figure 5.1 | Architecture en blocs d'un système embarqué..... | 91 |
| Figure 5.2 | Architecture en couches d'un système embarqué | 91 |
| Figure 5.3 | Architecture conceptuelle d'un FPGA | 93 |
| Figure 5.4 | Architecture du classifieur SVM non linéaire..... | 95 |
| Figure 5.5 | Interface de l'additionneur..... | 95 |
| Figure 5.6 | Représentation d'un additionneur 18bits..... | 95 |
| Figure 5.7 | Chronogramme de simulation d'une opération d'addition..... | 97 |
| Figure 5.8 | Interface d'un additionneur à virgule fixe..... | 97 |
| Figure 5.9 | Interface d'un additionneur à point fixe..... | 98 |
| Figure 5.10 | Interface de multiplicateur..... | 99 |
| Figure 5.11 | Chronogramme de simulation d'une opération de multiplication..... | 100 |
| Figure 5.12 | Interface de module de calcul carré..... | 100 |
| Figure 5.13 | Chronogramme de simulation d'une opération carré..... | 101 |
| Figure 5.14 | Chronogramme de simulation d'une opération de calcul d'exponentiel..... | 101 |
| Figure 5.15 | Architecture FPGA du classificateur SVM non linéaire..... | 102 |
| Figure 5.16 | Architecture du Cyclone II | 106 |
| Figure 5.17 | Interface simulateur Modelsim PE Student Edition 10.4a..... | 106 |
| Figure 5.18 | Chronogramme de simulation de testbench SVM non linéaire..... | 107 |
| Figure 5.19 | Résultat et erreur de classification des observations choisies..... | 108 |
| Figure 5.20 | Taux de reconnaissance et erreur de classification des observations de test..... | 108 |
| Figure 5.21 | Résultat de classification des observations en test..... | 109 |
| Figure 5.22 | Taux de reconnaissance et erreur de classification des différentes observations | 110 |

ANNEXE

| | | |
|--------------|---|-----|
| Figure A.2.1 | Valeur Propre en fonction de nombre de composante | 116 |
| Figure A.2.2 | Variabilité et cumulé | 116 |
| Figure A.2.3 | Cercle des Corrélations : Représentation des variables axe 1 et axe 2 | 117 |
| Figure A.2.4 | Représentation des individus axe 1 et axe 2 | 118 |



INDEX DES TABLEAUX

CHAPITRE II

| | | |
|-------------|--------------------------------------|----|
| Tableau 2.1 | Algorithme FCM | 31 |
| Tableau 2.2 | Algorithme Gustafson et Kessel | 33 |
| Tableau 2.3 | Algorithme PCM et MPCM..... | 35 |

CHAPITRE III

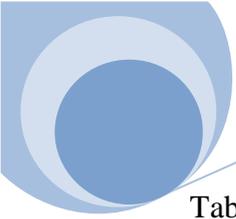
| | | |
|-------------|--------------------------------|----|
| Tableau 3.1 | Norme Euro moteur diesel | 60 |
|-------------|--------------------------------|----|

CHAPITRE IV

| | | |
|--------------|---|----|
| Tableau 4.1 | Description de bases de données..... | 70 |
| Tableau 4.2 | Modes de fonctionnement correspond à l'apprentissage hors ligne | 72 |
| Tableau 4.3 | Degrés d'appartenance de la nouvelle observation Ob1 | 73 |
| Tableau 4.4 | Degrés d'appartenance de la nouvelle observation Ob 2 | 73 |
| Tableau 4.5 | Description des modes de fonctionnement du moteur diesel relatif à la classification des données de pression d'admission | 75 |
| Tableau 4.6 | Description des modes de fonctionnement du moteur diesel relatif à la classification des données de vitesse de rotation | 76 |
| Tableau 4.7 | Description des modes de fonctionnement du moteur diesel relatif à la classification des données des émissions polluantes | 78 |
| Tableau 4.8 | Étapes pour la classification SVM | 79 |
| Tableau 4.9 | Taux de classification obtenu pour différentes valeur de sigma..... | 79 |
| Tableau 4.10 | Taux de classification obtenue pour la classification des données de vitesse de rotation..... | 80 |
| Tableau 4.11 | Taux de classification obtenue pour la classification des données de pression d'admission..... | 82 |
| Tableau 4.12 | Taux de classification obtenue pour la classification des données des émissions polluantes..... | 84 |
| Tableau4.13 | Performances de classification par MPCM et SVM | 87 |

CHAPITRE V

| | | |
|-------------|--|----|
| Tableau 5.1 | Algorithme SVM non linéaire..... | 94 |
| Tableau 5.2 | Code VHDL d'un additionneur complet 18bits..... | 97 |
| Tableau 5.3 | Code VHDL d'un additionneur à virgule fixe18bits..... | 98 |
| Tableau 5.4 | Code VHDL d'un additionneur à point fixe18bits..... | 98 |
| Tableau 5.5 | Code VHDL d'un Multiplicateur à virgule fixe 18bits..... | 99 |



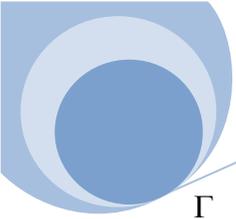
| | | |
|--------------|---|-----|
| Tableau 5.6 | Code de test Multiplicateur..... | 100 |
| Tableau 5.7 | Code VHDL d'un module de calcul carré..... | 100 |
| Tableau 5.8 | Code VHDL d'un module de calcul d'exponentiel..... | 101 |
| Tableau 5.9 | Mappage d'architecture de niveau supérieur de la classification SVM non linéaire..... | 105 |
| Tableau 5.10 | Taux de classification obtenue pour les deux observations de test..... | 107 |
| Tableau 5.11 | Taux de classification obtenue pour les différentes observations en test..... | 109 |

ANNEXE

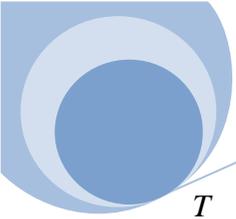
| | | |
|---------------|--|-----|
| Tableau A.1.1 | Listes des constantes | 114 |
| Tableau A.2.1 | Statistiques élémentaires (Données de pression d'admission) | 114 |
| Tableau A.2.2 | Matrice de corrélation Pearson (données de pression d'admission)..... | 114 |
| Tableau A.2.3 | Valeur propre, Variabilité et cumulé des composantes principales (Pad)..... | 115 |
| Tableau A.2.4 | Valeur propre | 115 |
| Tableau A.2.5 | Corrélation entre les variables et les axes principaux | 117 |
| Tableau A.2.6 | Coordonnées des observations | 120 |
| Tableau A.3.1 | Présentation de la famille FPGA Cyclone II..... | 121 |
| Tableau A.3.2 | Packages de périphériques Cyclone II et broches d'E/S utilisateur maximum..... | 121 |
| Tableau A.3.3 | Dispositifs de configuration appropriés pour les FPGA Cyclone II..... | 122 |
| Tableau A.3.4 | Support de température industrielle du dispositif cyclone II..... | 122 |

Notations liées à la classification

| | |
|--------------------|--|
| X_i | Vecteur forme |
| d | Dimension de l'espace de représentation |
| d' | Dimension réduite de l'espace de représentation |
| R^d | Espace de représentation |
| $R^{d'}$ | Sous espace de représentation |
| X_a | Ensemble d'apprentissage |
| N | Nombre des observations de l'ensemble d'apprentissage |
| M | Nombre des classes |
| i, j | Indice relatif aux observations |
| k | Indices relatifs à un numéro de classe k |
| \bar{X} | Centre de gravité de l'ensemble d'apprentissage |
| σ_j^2 | Composante j de la variance des vecteurs |
| X_{ij} | La $j^{\text{ième}}$ composante de X_i |
| \bar{X}_j | La moyenne de la composante j |
| $X_{i\text{norm}}$ | Vecteur forme normalisé |
| Δ | Matrice diagonale des variances σ_j^2 |
| Σ | Matrice de variance-covariance |
| J | Critère |
| $d(.,.)$ | Mesure de distance |
| X_i^p | Projection du vecteur X_i dans la base formée par les vecteurs u_j |
| Γ_i | Pourcentage d'inertie dans le sous espace de dimension d' |



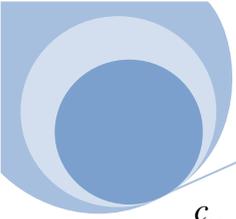
| | |
|----------------------|--|
| Γ | Qualité de la représentation dans le sous espace de dimension d' |
| \sum_w | Matrice de variance intra-classe |
| \sum_B | Matrice de variance inter-classe |
| Ω | Ensemble des classes connues |
| \overline{X}_k | Centre de gravité de la classe Ω_k |
| N_k | Nombre de vecteur dans la classe Ω_k |
| X_{kj} | $j^{ième}$ Vecteur de la classe Ω_k |
| $\sigma_k^2(\alpha)$ | Variance de la composante α des vecteurs de la classe Ω_k |
| n_c | Nombre de combinaisons étudiées de d' parmi d |
| $E_d^{(i)}$ | La $i^{ième}$ combinaison de d' paramètres pour laquelle en calcul J |
| $C_d^{d'}$ | Combinaison de d' parmi d |
| Ω_0 | Classe fictive des vecteurs rejetés en ambiguïté |
| Ω_d | Classe fictive des vecteurs rejetés en distance |
| $f(X/\Omega_j)$ | Densité de probabilité de X dans Ω_j |
| $u_k(X)$ | Degré d'appartenance de X à la classe Ω_k de ses k plus proche voisin |
| $u_{i,k}$ | Fonction d'appartenance à la classe Ω_k du $n^{ième}$ vecteur forme |
| m | Index flou |
| $P_r(\Omega_k/X_i)$ | Probabilité à posteriori pour qu'une observation X_i provienne de Ω_k |
| $P_r(\Omega_k)$ | Probabilité à priori de la classe Ω_k |
| $J_m(U,V)$ | Fonction objective (Distance intra-groupe floue) |
| V | Ensemble des centres des classes |
| U | Matrice de partition floue de dimension $N * M$ |
| V_K | Centroïdes des classes |



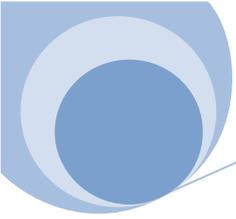
| | | |
|---------------|--|---|
| T | | Nombre maximal des itérations |
| t | | Compteur des itérations |
| w_k | | Carré de distance séparant le centre de la classe k |
| S_k | | Seuil d'appartenance associé à la classe k |
| ε | | Seuil d'arrêt |
| R | | Rapport d'appartenance |
| $D(X)$ | | Règle de décision |
| T_{amb} | | Seuil de réglage du rejet en ambiguïté |

Notations liées à la modélisation du moteur diesel

| | | |
|----------------------|--|---|
| x_p | (%) | Position de l'accélérateur |
| ω | (rad/s) | Vitesse de rotation du moteur |
| Δm_f | -/- | Variation du débit de carburant autour des débits d'injection |
| m_f | (kg/s) | Débit de Carburant |
| i_0 | (kg/s) | Débit minimal d'injection |
| i_1, i_2, i_3, i_4 | (kg/rad) | Débits d'injection |
| m_{fd} | (kg/s) | Débit de carburant avec défaut |
| p_a | (Pa) | Pression d'admission |
| p_{ad} | (Pa) | Pression d'admission en présence de défaut |
| r | (J.kg ⁻¹ .K ⁻¹) | Constante des gaz parfaits |
| T_a | (K) | Température d'admission |
| V_a | (m ³) | Volume d'admission |
| M_a | (kg) | Masse d'air d'admission |
| m_c | (kg/s) | Débit à la sortie de compresseur |
| m_{cyl} | (kg/s) | Débit d'air d'admission |



| | | |
|-----------------------------------|--|---|
| c_m | (kg/rad) | Modèle compresseur à vide |
| m_{fuite} | (kg/s) | Débit de fuite d'admission |
| d | (mm) | Diamètre de la fuite d'admission |
| C_p | (J.kg ⁻¹ .K ⁻¹) | Chaleur massique de l'air |
| P_{atm} | (Pa) | Pression atmosphérique |
| γ | (ø) | Coefficient adiabatique de gaz parfaits |
| m_{cylid} | (kg/s) | Débit d'air d'admission avec défaut |
| m_{cd} | (kg/s) | Débit de la sortie de compresseur avec défaut |
| J | (kg.m ⁻²) | Moment d'inertie de vilebrequin |
| θ | (rad) | Position angulaire du vilebrequin |
| P_i | (W) | Puissance fournie par le moteur |
| P_b | (W) | Puissance résistante |
| C_r | (N.m) | Couple de freinage |
| P_{ci} | (J/kg) | Pouvoir calorifique du carburant |
| η_i | (ø) | Rendement du moteur |
| $a_\lambda, b_\lambda, c_\lambda$ | (ø) | Modèles de rendement du moteur |
| λ | (ø) | Excès d'air |
| α_0 | (ø) | Modèles débit d'air d'admission |
| α_1 | (s.rad ⁻¹) | Modèles débit d'air d'admission |
| α_2 | (s ² .rad ²) | Modèles débit d'air d'admission |
| V_{cy} | (m ³) | Volume des cylindres de moteur |
| O_p | (%) | Taux de fumée noir dans les gaz d'échappement |
| o_1, o_2 | (ø) | Modèles de taux de fumée noir dans les émissions polluantes |



ABBREVIATIONS

| | |
|-----------|--|
| Rdf | Reconnaissance des formes |
| ACP | Analyse en composantes Principales |
| SVM | Séparateurs à vaste marge |
| LDA | Analyse discriminante linéaire |
| PLS | La régression aux moindres carrées |
| FCM | C-moyennes floues |
| PCM | C-moyennes possibilistes |
| MPCM | C-moyennes possibilistes modifiée |
| K-ppv | k plus proches voisins |
| Gk | Algorithme Gustafson et Kessel |
| PMH | Point mort haut |
| PMB | Point mort bas |
| S_{adm} | Soupape d'admission |
| S_{ech} | Soupape d'échappement |
| FPGA | Field Programmable Gate Array (réseaux logiques programmables) |
| RBF | Radial basis function (Fonction de base radiale) |

INTRODUCTION GÉNÉRALE

Suite au développement important et rapide qu'a connu l'industrie automobile, les moteurs Diesel modernes sont de plus en plus complexes et sophistiqués, un défaut dans ces moteurs peut conduire à la baisse de ses performances ainsi qu'une augmentation des émissions des gaz d'échappement. La surveillance et le diagnostic de tels systèmes sont devenus des tâches importantes. Elles imposent des systèmes de diagnostic en ligne et visent le diagnostic en temps réel du moteur afin de prévenir toute défaillance dans le système et éventuellement l'identifier et la localiser [SABEH 06].

De nos jours, tout moteur diesel est commandé par un/ou plusieurs calculateurs traitant les informations collectées par des capteurs (pression, vitesse,...etc.) et commandant les actionneurs (pompe, électrovanne ...etc.). L'analyse des informations collectées depuis les différents capteurs pour la détection rapide et précise des défaillances est un problème réel. Quand elle est mal faite, elle peut causer des pertes humaines, matérielles, économiques,...etc.

En Algérie le diagnostic des moteurs diesel se fait hors ligne, de plus les connaissances des mécaniciens sont très limitées, qui rend le diagnostic difficile à réaliser et prend beaucoup de temps, pour répondre à cette problématique nous présentons un système d'aide au diagnostic en ligne (temps réel) afin de répondre aux exigences des clients en matière de sécurité, de confort et de consommation et ceci même en présence des défauts.

L'exploitation du système de diagnostic en ligne permet en temps réel d'adopter le meilleur comportement en présence des défauts et en temps différé (off line), de développer une stratégie de maintenance préventive.

Les systèmes de diagnostic actuels se basent sur la comparaison des différentes mesures sans exploiter les corrélations entre ces dernières, cela augmente leur tolérance aux défauts, rendent la détection précise des défaillances de plus en plus complexes, c'est pourquoi l'utilisation des techniques de diagnostic tel que les réseaux de neurones, la reconnaissance des formes ..., semblent prometteuses pour améliorer la qualité de détection et de localisation des défauts.

Le moteur diesel est composé par plusieurs sous-systèmes : le système d'injection, le système d'admission, le bloc moteur avec ses solides en mouvements (Cylindres, Bielles, ...etc.), le système de suralimentation et le système d'échappement. Plusieurs modèles décrivant ses différents sous-systèmes, sont abondamment développés dans la littérature.

Du fait qu'il est difficile d'acquérir une base de données ou de la construire en collectant les informations sur tous les modes de fonctionnement du moteur Diesel, on a été contraint de la créer en utilisant les modèles développés dans [NOHRA 09], [PEYSSON 05], [NOURA 06] et [YOUNES 93].

Sous l'hypothèse d'un couple de freinage constant qui ne représente que la résistance exercée par les parties en rotation du moteur à vide, un ensemble de modèles de fonctionnement avec et sans défaut est proposé [NOURA 06]. Les défauts pouvant apparaître sont : défauts d'injection, défaut de fuite d'admission, défaut de soupape d'admission et défaut de compression.

À partir des données générées par l'ensemble de modèles associés à une base de connaissances relatives au moteur, un système de diagnostic complet basé sur les techniques de reconnaissance des formes floue est développé, permettant de détecter et de localiser plus facilement et plus rapidement le composant responsable de défaillance.

Deux méthodes de diagnostic basées sur la classification automatique sont développées dans ce travail. La méthode de reconnaissance floue d'une part, et les séparateurs à vaste marge (SVM) d'autre part, utilisent les mêmes approches d'apprentissage supervisé. Elles partagent la même construction de l'espace de représentation mais différent dans la structuration de cet espace et dans l'élaboration des règles de décision.

Pour la reconnaissance des formes floue, les fonctions de décision sont des règles de décision issues du domaine de l'intelligence artificielle, alors que les règles de décision pour les méthodes SVM sont obtenues par une binarisation de l'espace de représentation avec un hyperplan optimal.

Les deux méthodes sont adaptées aux systèmes complexes et assez robustes pour intégrer les erreurs et les incertitudes.

Les résultats obtenus par ces deux méthodes sont comparés, et analysés avant de choisir la méthode qui sera implémentée sur le système embarqué.

Les travaux menés dans cette thèse sont structurés en quatre chapitres :

Le premier chapitre, est consacré à la présentation des différentes approches nécessaires pour l'établissement d'une démarche de diagnostic.

Le deuxième chapitre, se divise en trois parties, la première présente en détail les différentes étapes de l'approche de diagnostic par reconnaissance des formes. La deuxième partie a été réservée à l'étude de l'approche de reconnaissance floue des formes, dans le cadre de cette approche les différents algorithmes de classification, précisément l'algorithme C-moyennes floue et ses variantes seront largement décrit et détaillé. La comparaison des différents algorithmes nous permet d'adopter une méthodologie de diagnostic basée sur l'un de ses algorithmes. La troisième partie est consacrée à la présentation des différents concepts de base de l'approche des séparateurs à vastes marges. Nous avons choisi d'utiliser un classifieur SVM pour valider les résultats de classification par reconnaissance des formes floue. Nous commençons cette partie par une présentation de principe des SVM, ainsi nous présentons quelques notions de base qui sont : hyperplan, les vecteurs supports et la marge. Nous mettrons en évidence l'utilisation des SVM dans le cas des données linéairement séparables et le cas des données non linéairement séparables. Nous finissons par une présentation des méthodes les plus connues pour le traitement des problèmes de classification multi-classes.

Le troisième chapitre, se divise en trois parties, la première présente une synthèse bibliographique, montrant un état de l'art des moteurs diesel. La partie 2 est dédiée à la présentation de l'ensemble des modèles avec et sans défaut. La troisième partie est réservée à la présentation des résultats provenant de la modélisation sous MATLAB/SIMULINK, accompagnée des commentaires des résultats obtenus.

Le quatrième chapitre est réservé à la présentation des résultats des deux systèmes de diagnostic avec commentaires des résultats obtenus. En premier lieu nous avons présenté les résultats du système de diagnostic par reconnaissance des formes floue. En deuxième lieu nous avons présenté les résultats de classification par la deuxième approche basée sur les séparateurs à vastes marges dont le but de valider les résultats de la première approche.

Le cinquième chapitre est réservé à la simulation et implémentation de système de diagnostic basée sur les séparateurs à vaste marge sur une plateforme FPGA.

Une conclusion termine ce travail, en mettant en évidence que le modèle simplifié présenté dans cette thèse est un modèle non linéaire précis et rapide en temps de calcul, destiné à être utilisé à bord du véhicule dans le but d'établir le diagnostic en temps réel; Il utilise des sous modèles de connaissance pour décrire les évolutions des variables (vitesse, pression, pollution ...etc.).

CHAPITRE I

Généralités sur le diagnostic des systèmes

1.1 Introduction

Ce chapitre est consacré à la présentation des différentes méthodologies de diagnostic des systèmes développés dans les différents travaux de recherche.

Au cours de ces dernières années, la surveillance et le diagnostic des différents systèmes sont d'une grande importance dans l'industrie. Elle impose actuellement des systèmes de diagnostic capable d'identifier, pendant toute la durée de fonctionnement, toute défaillance d'un composant ou d'un système.

En général, il existe pour un système donné un certain nombre de variables dont l'observation permet de déterminer si le comportement obtenu est normal ou non.

Le diagnostic des défauts nous permet de décider s'il existe ou non une anomalie de fonctionnement et de localiser cette dernière au sein du système, à partir des observations et de la connaissance du système. Donc le diagnostic des défauts consiste à déterminer comment représenter la connaissance du comportement normal du système, de définir les variables appropriées du système à observer et de décrire la procédure permettant la prise de décision, à savoir : quel est le défaut présent et où se situe-t-il dans le système **[SABEH 06]**.

Dans le cas de ce travail de thèse, nous nous intéressons au diagnostic en temps réel appliqué à un moteur diesel équipé d'un certain nombre de capteurs et d'actionneurs.

Une méthode de diagnostic est ainsi proposée pour la détection de différents types de défauts du système (défauts d'actionneurs).

1.2 Diagnostic des défaillances

1.2.1 Introduction

L'objectif du diagnostic des défaillances est la détection et l'identification de l'état ou mode opérationnel d'un système dans l'instant actuel. La surveillance d'un système consiste à diagnostiquer ses états et modes défaillants. Le pronostic est la prédiction des possibles états futurs dans lesquels un système peut évoluer. Alors, une fois les états futurs identifiés, le pronostic nous permettrait d'estimer le temps de vie restant d'un système à partir de son état actuel jusqu'à un état défaillant [DIEZ LLEDO 08].

1.2.2 La surveillance

La surveillance est un dispositif passif, informationnel, qui analyse l'état du système et fournit des indicateurs. La surveillance consiste à détecter et classer les défaillances en observant l'évolution du système, puis à les diagnostiquer en localisant les éléments défaillants et en identifiant les causes premières. Donc la surveillance se décompose en deux fonctions qui sont la détection et le diagnostic [RACOCEANU 06].

1.2.3 La détection

Elle permet la détection des dysfonctionnements dans le système. Si l'on dispose d'un modèle nominal, un dysfonctionnement se caractérisera par l'éloignement des paramètres du procédé de ceux du modèle de bon fonctionnement. En présence d'un modèle de dysfonctionnement, la détection identifie clairement le défaut connu a priori [RIPOLL 99].

1.2.4 Le diagnostic

Le diagnostic est l'identification de la cause probable de la (ou des) défaillance(s) à l'aide d'un raisonnement logique fondé sur un ensemble d'informations provenant d'une inspection, d'un contrôle ou d'un test. [AFNOR, CEI], [BOUZIDI 16].

Il s'intègre dans le cadre plus général de la surveillance et de la supervision. Il consiste à localiser les éléments défaillants et à identifier les causes à l'origine du problème ; ceci en établissant un lien causal entre les symptômes et les éléments fautifs à remplacer. La phase qui suit correspond à la décision. Elle a pour rôle de déterminer et d'engager les actions permettant de ramener au mieux le système dans un état normal.

La fonction de diagnostic se décompose en deux fonctions élémentaires, la première c'est la *localisation* et l'autre c'est *l'identification des causes*.

1.2.4.1 Localisation : la localisation suit l'étape de détection ; elle a pour but de remonter à l'origine du défaut détecté.

1.2.4.2 Identification de défauts : la tâche d'identification a pour but de déterminer du type, de l'amplitude, de la localisation et des instants de détection des défauts.

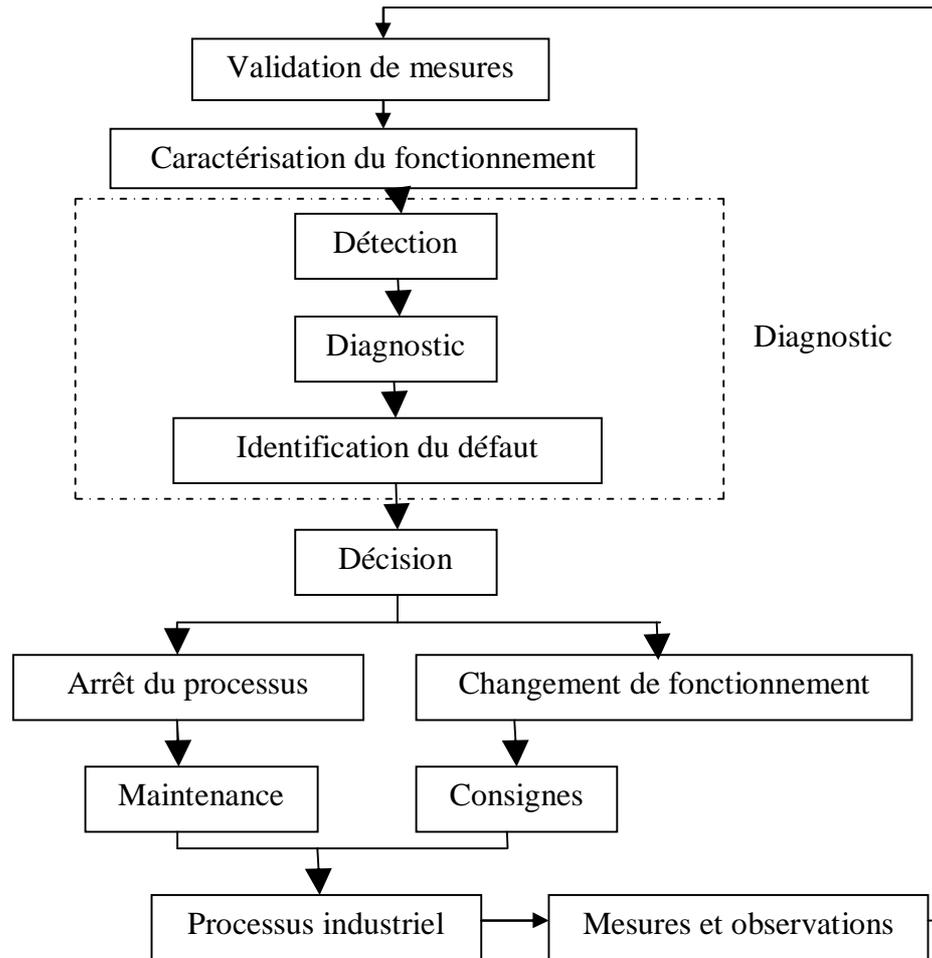


Figure 1.1 : Les phases de diagnostic [BOUZIDI 16].

1.3 Terminologie de diagnostic

Nous présentons dans ce paragraphe la définition des termes principaux utilisée dans le domaine du diagnostic.

Un défaut (fault) est considéré comme un écart du comportement normal. Il s'exprime par une déviation d'une propriété ou d'un paramètre caractéristique du procédé. Un défaut est donc une anomalie de comportement qui peut présager une défaillance à venir.

Selon [ZWINGELSTEIN 95] un défaut est tout écart entre la caractéristique observée sur le dispositif et la caractéristique de référence lorsque celui-ci est en dehors des spécifications.

Une défaillance est la cessation de l'aptitude d'un ensemble à accomplir sa ou ses fonctions requises avec les performances définies dans les spécifications techniques.

Une panne est l'inaptitude d'une entité (composant ou système) à assurer une fonction requise. Elle provoque un arrêt complet du procédé.

- *Les pannes permanentes* peuvent être la conséquence du changement progressif des caractéristiques d'un composant.
- *Les pannes intermittentes* sont très souvent le prélude à une panne permanente et expriment une dégradation progressive des performances du procédé [ALEXANDRE06].
- *La détection des défauts* (fault detection) c'est la détermination des défauts et leurs instants de détection dans un système.
- *L'isolation des défauts* (fault isolation) consiste à déterminer le type de défaut, de la localisation et des instants de détection de ce dernier.
- *L'identification des défauts* est le fait d'estimer l'amplitude et l'évolution temporelle du défaut afin d'expliquer au mieux le comportement du système [GUILLAUME 05].

1.4 Classification des méthodes de diagnostic

Les méthodes de diagnostic utilisées dans l'industrie sont très variées. Leur principe général repose sur la comparaison entre les données observées au cours du fonctionnement du système et les connaissances acquises sur son comportement normal et ses comportements de défaillance [COMBACAU 91].

Les méthodes de diagnostic se distinguent selon la dynamique du procédé (discret, continu ou hybride), l'implémentation du diagnostic en ligne et/ou hors ligne, la nature de l'information (qualitative ou quantitative), ... En général ces méthodes sont divisées en deux catégories :

- Les méthodes externes (model-free methods) qui sont des méthodes soit à base de connaissance, soit des méthodes empiriques et/ou de traitement du signal.
- Les méthodes internes (model-based methods) qui représentent des méthodes à base de modèles quantitatifs et/ou qualitatifs.

1.4.1 Méthodes externes

Les méthodes externes considèrent le système comme une *boîte noire* et elles utilisent uniquement un ensemble de mesures et/ou de connaissances heuristiques sur le système. Elles n'ont besoin d'aucun modèle mathématique pour représenter le fonctionnement du procédé. Ces méthodes comprennent les méthodes à base de reconnaissance des formes, de réseaux de neurones, ou de systèmes experts.

1.4.1.1 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 [DERBEL 09].

- 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.

1.4.1.2 Réseaux de neurones

Un réseau de neurones artificiels est un modèle de calcul dont la conception est très schématiquement inspirée du fonctionnement des neurones biologiques. Ils sont des outils particuliers adaptés pour aider les spécialistes de maintenance dans ces activités de reconnaissance et de classification. Pour ces raisons. De nombreuses études pilotes sont entreprises dans le secteur de maintenance pour évaluer les apports des réseaux de neurones avant leur mise en œuvre de façon opérationnelle.

Les réseaux de neurones sont des réseaux fortement connectés de processeur élémentaire fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit [TOUZET 92].

Un RNA se compose typiquement d'une couche d'entrée, d'une ou de plusieurs couches intermédiaires ou cachées et d'une couche de sortie, chaque neurone est connecté à d'autres neurones d'une couche suivante par des poids synaptiques adaptables. La figure 1.2 illustre le schéma général d'un neurone. Chaque nœud i calcule la somme de ses entrées (X_1, \dots, X_n) , pondérées par les poids synaptiques $(\omega_{i1}, \dots, \omega_{in})$ correspondants ; la valeur obtenue représente l'état interne du neurone μ_i . Ce résultat est transmis à une fonction d'activation F . La sortie y_i est l'activation du neurone [KEMPOWSKY 04].

Le modèle général du neurone est représenté par :

$$\mu_i = \sum_{n=1}^N \omega_{in} X_n \quad (1.1)$$

$$y_i = F(\mu_i) \quad (1.2)$$

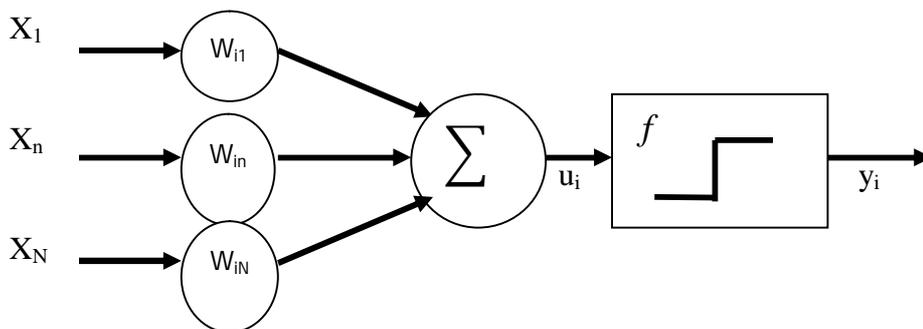


Figure 1.2 : Schéma général d'un neurone.

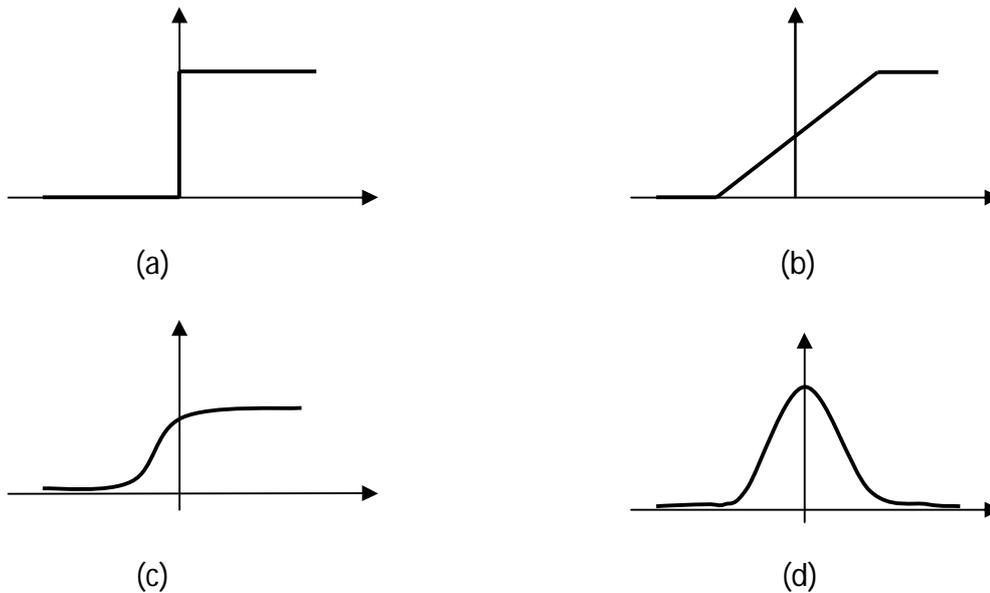


Figure 1.3 : fonction d'activation les plus utilisées : (a) fonction à seuil, (b) fonction linéaire, (c) fonction sigmoïde, (d) fonction gaussienne.

Le choix d'une fonction d'activation influe directement sur le réseau de neurones, c'est bien important de bien choisir pour l'obtention d'un modèle utile en pratique.

La fonction d'activation fait transformer un signal d'entrée dans un neurone à un signal de sortie (réponse). Les fonctions d'activation les plus utilisées sont présentées via la figure 1.3.

1.4.1.3 Systèmes experts

Un système expert utilise la connaissance correspondant à un domaine spécifique afin de fournir une performance comparable à l'expert humain. En général, les concepteurs des systèmes experts effectuent l'*acquisition de connaissances* grâce à un ou plusieurs interviews avec les experts du domaine. Les humains qui enrichissent le système avec leurs connaissances fournissent leur connaissance théorique ou *académique* et aussi des heuristiques qu'ils ont acquises grâce à l'utilisation de leurs connaissances [TOUZET 92].

La qualité première des systèmes experts réside dans leur efficacité au niveau temps de calcul. Le système doit simplement attendre les événements observables des règles pour *sauter* directement aux conclusions.

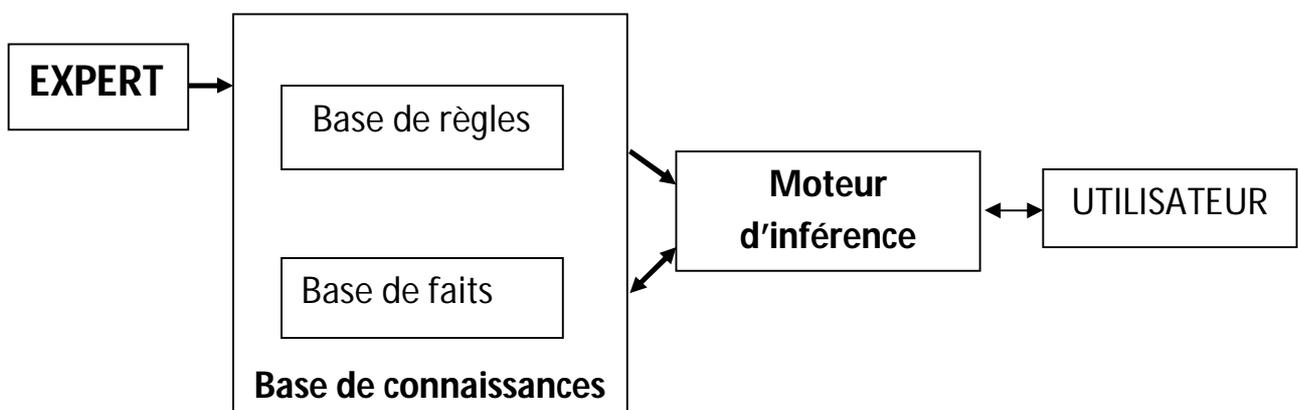


Figure 1.4 : Architecture d'un système expert.

Un système expert est composé de deux parties indépendantes [KEMPOWSKY 04] (voir Figure 1.4) :

- Une base de connaissance elle-même composée d'une base de règles qui modélise la connaissance du domaine considéré et d'une base de faits qui contient les informations concernant le cas traité,
- Un moteur d'inférences capables de raisonner à partir des informations contenues dans la base de connaissances, de faire des déductions,... etc. Au fur et à mesure que les règles sont appliquées des nouveaux faits se déduisent et se rajoutent à la base de faits.

1.4.2 Méthodes internes

Cette famille de méthodes est principalement dérivée de techniques utilisées par les automaticiens. À partir de modèles physiques ou de comportements validés par les techniques d'identification de paramètre, il devient possible de mettre en œuvre la méthode du problème inverse. Le diagnostic de défaillance est possible en suivant en temps réel l'évolution des paramètres physiques ou bien en utilisant de modèle de type **boîte noire**.

Elles impliquent une connaissance approfondie du fonctionnement sous la forme de modèles mathématiques qui devront être obligatoirement validés expérimentalement avant toute utilisation industrielle. Les méthodes de diagnostic internes se regroupent en trois grandes familles : méthodes de modèle, méthodes d'identification de paramètre et les méthodes d'estimation du vecteur d'état.

1.4.2.1 Méthodes de modèle

Cette méthode consiste à comparer les grandeurs déduites d'un modèle représentatif du fonctionnement des différentes entités du processus avec les mesures réelles directement observées sur le processus industriel.

1.4.2.2 Méthodes d'identification de paramètre

Cette méthode s'applique dans les cas particuliers où l'on souhaite suivre l'évolution de certains paramètres physiques critiques pour le fonctionnement et qui ne sont pas mesurables directement [BDIRINA 06].

1.4.2.3 Méthodes d'estimation du vecteur d'état

La généralisation du principe de diagnostic de défaillance par la méthode de l'identification de paramètre a été rendue possible en considérant les modèles physiques d'un processus sous la forme d'équations d'état. Pour les systèmes à plusieurs entrées et à plusieurs sorties.

Le modèle est constitué par un ensemble de n équations différentielles du premier ordre. Les n composantes du vecteur d'état x forment un espace à n dimensions appelées espace d'état.

Grâce à cette représentation d'état il est possible de connaître tous les états internes du processus. L'intérêt de cette représentation réside dans sa généralité.

Elle peut être utilisée aussi bien pour les systèmes monovariables que multivariables. Les méthodes de diagnostic par les techniques du vecteur d'état sont performantes à la condition expresse que la structure du modèle reflète exactement le comportement du système. Dans le cas contraire les résultats des estimations sont à prendre avec beaucoup de précautions. Elles ont fait leurs preuves principalement dans les domaines du spatial et de l'aéronautique où les modèles de la dynamique du vol sont parfaitement connus.

1.4.2.4 Méthodes des résidus

L'objectif du résidu est d'être sensible aux défauts. En cas d'absence de défaillance (fonctionnement normal), les résidus doivent avoir une valeur nulle. En présence d'un défaut, le résidu aura une valeur non nulle [Tatiana 04].

Les résidus représentent des changements (divergences) entre le comportement réel du processus et celui prévu par le modèle estimé. Le principe général pour la génération des résidus est illustré sur la figure ci-dessous.

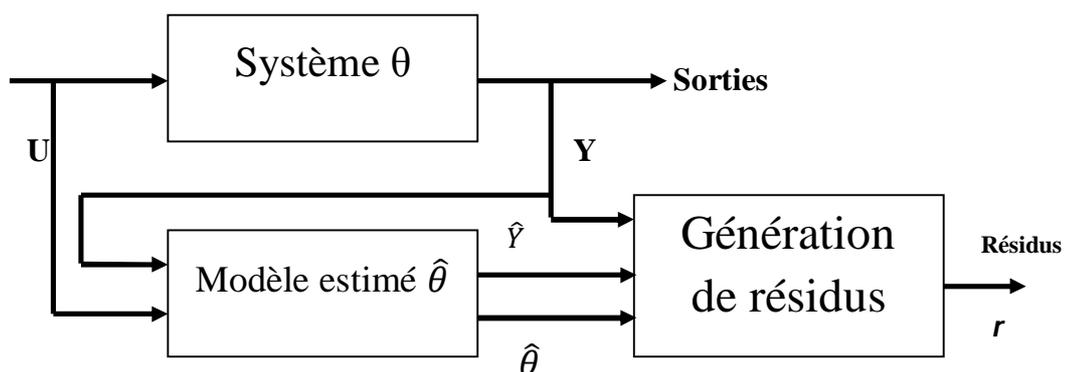


Figure 1.5 : Principe de génération des résidus

Les techniques les plus utilisées pour la génération des résidus sont : les équations de parité, estimation d'état à partir d'observateurs ou filtres de KALMAN, Estimation paramétrique et analyse structurelle.

1.4.2.4.1 Espace de partie

Les méthodes du type d'équations de parité reposent sur la vérification d'une relation statique ou dynamique qui relie les mesures. L'espace de parité peut être vu comme l'espace des résidus possibles. Il est défini comme l'orthogonal de la matrice d'observabilité, ce qui revient à éliminer l'influence de l'état sur le résidu [CHRISTOPHE 00].

1.4.2.4.2 Observateur

Les méthodes de génération de résidus construites à l'aide d'observateurs reposent sur une estimation de l'état. Un observateur d'ordre réduit à ne considérer qu'une partie du système, donc à estimer une partie de l'état et à éliminer l'autre. Par ailleurs, l'estimation d'une partie du système peut être utilisée pour rejeter les perturbations (découplage direct).

1.5 Conclusion

Nous avons décrit toutes les méthodes nécessaires de diagnostic pour l'identification de la cause exacte d'une défaillance, nous avons vu que deux grandes familles de méthode sont disponibles pour l'aide au diagnostic : les méthodes internes qui sont basées sur une connaissance profonde du fonctionnement et les méthodes externes (l'intelligence artificielle, reconnaissance de formes...) à la condition expresse de disposer d'un retour d'expérience riche et parfaitement documenté.

CHAPITRE II

Classification des données

2.1 Introduction

Ce chapitre, sera consacré à la présentation des deux méthodes de classification des données. La première méthode est basée sur l'utilisation des techniques de reconnaissance des formes, la seconde méthode utilise les séparateurs à vaste marge (SVM).

La méthode de reconnaissance des formes est une branche de l'intelligence artificielle, son objectif est le classement et l'identification des formes ou des objets à partir de données brutes afin de prendre une décision dépendant de la catégorie attribuée à cette forme [POISSON 06]. Cette méthode regroupe les techniques informatiques de représentation et de décision qui donnent à la machine la capacité de simuler un comportement sensible.

Les méthodes SVM (Machines à vecteurs de support), est un outil très efficace pour la sélection des paramètres et aussi pour l'optimisation des paramètres d'un classifieur. Nous commençons par une présentation des principes de la méthode SVM où nous mettrons en évidence l'utilisation des SVM dans le cas des données linéairement séparables et le cas des données non linéairement séparables. Ensuite nous présentons des méthodes pour la classification SVM multi-classes.

Nous avons choisi d'utiliser la méthode de reconnaissance des formes floue parmi les autres méthodes, car elle est très performante devant les modèles imprécis (système complexe) et sa robustesse permet de limiter les effets des erreurs et imprécisions associées aux données et aux modèles. Elle nous permet d'identifier l'état actuel du système ainsi que l'évolution vers un mode indésirable. Tandis que La démarche de diagnostic par SVM a été proposée dans le seul but de valider les résultats de classification par reconnaissance des formes floue.

On termine ce chapitre par une conclusion.

2.2 Reconnaissance des formes

La reconnaissance des formes interprète toute nouvelle observation (Forme), les observations sont regroupées en classes, constituant des prototypes auxquels la nouvelle observation est comparée pour être identifiée.

Chaque observation est caractérisée par un ensemble de d paramètres, est représentable par un vecteur X_i dans l'espace R^d .

Les différentes étapes d'une procédure de la reconnaissance des formes sont illustrées par la figure 2.1.

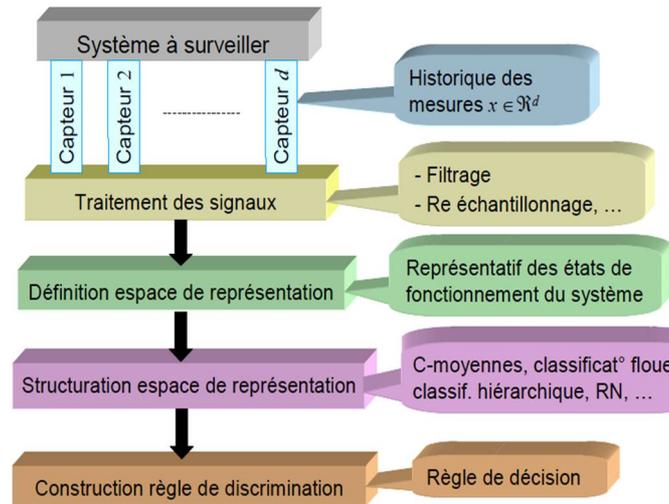


Figure 2.1 : Diagnostic d'un système : approche reconnaissance des formes.

Le diagnostic par reconnaissance des formes est posé comme suite :

Définition de l'espace de représentation, structuration de l'espace de représentation et la construction d'une règle de décision [HANDIS 12].

2.2.1 Définition de l'espace de représentation

Cette première phase de prétraitement consiste à construire le vecteur forme, c.à.d. sélectionner les d paramètres à extraire à partir des signaux recueillis. Le but est de réduire la quantité de données en retenant que les variables les plus importantes et filtrer les informations redondantes. Cela fait réduire le temps de classification pour les nouveaux observateurs.

L'ensemble de d paramètres obtenus après traitement des signaux est représenté par *un vecteur forme* X_i représenté dans l'espace de représentation R^d .

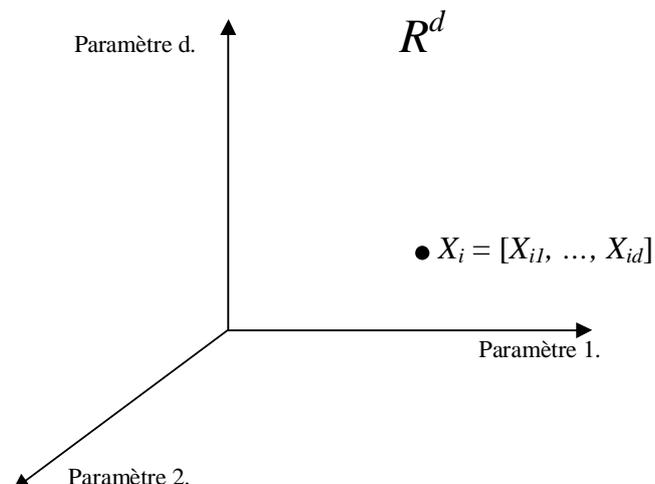


Figure 2.2 : Représentation d'un vecteur forme dans un espace de dimension d .

Il est préférable de disposer des paramètres variant, de manière significative, en fonction des différents modes de fonctionnement du système. Le choix des paramètres pertinents à partir des paramètres recueillis fait diminuer le temps de calcul. Des méthodes de réduction des paramètres doivent être utilisées pour extraire les paramètres les plus représentatifs [GAOUAOUI 12].

2.2.1.1 Réduction de l'espace de représentation

Les données collectées lors d'une observation d'un phénomène sur un système peuvent être peu significatives, corrélées ou redondantes, aberrantes ou simplement inutiles au problème de classification. L'objectif principal de la réduction de l'espace de représentation est de définir un nouvel espace de représentation de dimension réduite, afin de conserver les informations importantes du signal acquis. Les méthodes d'extraction des variables ainsi que les méthodes de sélection des variables peuvent être utilisées pour la réduction de l'espace de représentation.

2.2.1.1.1 Extraction des variables

L'extraction de variables est une étape importante qui consiste à construire un nouveau ensemble de variables ($d' < d$), qui contient la plus grande part d'information, à partir des variables initiaux. Plusieurs méthodes peuvent être appliquées pour l'extraction des variables, les plus connues sont l'ACP (Analyse en Composantes Principales), LDA (Analyse Discriminante linéaire), PLS (la régression aux moindres carrés), ...

a) Analyse en composantes principales

L'analyse en composantes principales (ACP) est une technique statistique d'analyse de données multivariées, capable de comprimer les données pour réduire leur dimensionnalité c.à.d. trouver un sous - espace propre, qui maximise la variance des données après projection de sorte que l'information soit maintenue.

En considère $X_a = (X_{a1}, X_{a2}, \dots, X_{aN})$ l'ensemble d'apprentissage composé de N vecteurs de dimension d (Matrice des données). L'analyse en composantes principales est une méthode permettant d'identifier un sous-espace $R^{d'}$ de dimension $d' < d$ représentant au mieux l'ensemble X_a [HANDIS 12]. Si les composantes de ces vecteurs ne sont pas homogènes les résultats de classification risquent d'être erronés. Pour éviter cette situation les données sont normalisées suivant les étapes qui suivent :

Le centre de gravité \bar{X} de l'ensemble d'apprentissage est défini par :

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (2.1)$$

Et les composantes de la variance sont :

$$\sigma_j^2 = \frac{1}{N} \sum_{i=1}^N (X_{ij} - \bar{X}_j)^2 \quad (2.2)$$

$j=1 \dots d$

À partir des deux relations précédentes on en déduit les vecteurs formes normalisés centré réduits (moyenne nulle et écart-type unité).

$$X_{i\ norm} = \Delta^{-1/2} (X_i - \bar{X}) \quad (2.3)$$

$$\Delta = \begin{bmatrix} 1/\sigma_1^2 & & & 0 \\ & 1/\sigma_2^2 & & \\ & & \ddots & \\ 0 & & & 1/\sigma_d^2 \end{bmatrix} \quad (2.4)$$

Après normalisation des données, les vecteurs propres de la matrice de variance – covariance aide à définir la base du sous-espace :

$$\Sigma = \frac{1}{N} \sum_{i=1}^N (X_i \cdot X_i^t) \quad (2.5)$$

Σ Une matrice d'inertie du nuage de points (matrice carrée, réelle et symétrique). Ses éléments diagonaux sont les variances de l'ensemble d'apprentissage, et les éléments non diagonaux sont les covariances.

Les vecteurs propres de la matrice de variance-covariance Σ sont les vecteurs v_j tels que $x \times v_j = \lambda_j \times v_j$. Les scalaires λ_j repris dans la matrice diagonale (2.7), sont les vecteurs propres.

$$V = [v_1 \ v_2 \ \dots \ v_d \ \dots \ v_d] \quad (2.6)$$

$$\lambda = \begin{bmatrix} \lambda_1 & & & & 0 \\ & \lambda_2 & & & \\ & & \ddots & & \\ & & & \lambda_d & \\ 0 & & & & \ddots & \\ & & & & & \lambda_d \end{bmatrix} \quad (2.7)$$

L'ACP garantit que la déformation du nuage de points est minimale, et conduit à minimiser le critère J [Dubuisson 90]:

$$J = \frac{1}{2} \sum_{i=1}^N d^2(X_i, X_i^p) \quad (2.8)$$

Les résultats de l'ACP peuvent être visualisés en considérant la projection du nuage de points sur les deux ou trois premiers axes factoriels. Autrement dit, en visualisant la matrice des données dans l'espace défini par les deux ou trois premiers vecteurs propres.

Enfin la qualité de la représentation peut être quantifiée par le calcul du pourcentage d'inertie expliquée sur chaque axe factoriel ou sur le sous-espace de dimension d' obtenu. Ce pourcentage d'inertie est défini en fonction des valeurs propres [HAF12], [ROLAND 03]. Le pourcentage d'inertie expliquée par un axe i est donné par :

$$\Gamma_i = \frac{\lambda_i}{\sum_{j=1}^d \lambda_j} \quad (2.9)$$

Et la qualité de la représentation du nuage de points est représentée par :

$$\Gamma = \frac{\sum_{i=1}^{d'} \lambda_i}{\sum_{j=1}^d \lambda_j} \quad (2.10)$$

Plus le rapport Γ est proche de 1, la présentation est plus proche de la réalité.

2.2.1.1.2 Sélection des variables

La sélection des variables consiste à chercher un *sous-ensemble* de d' variables les plus pertinentes parmi les d variables originaux.

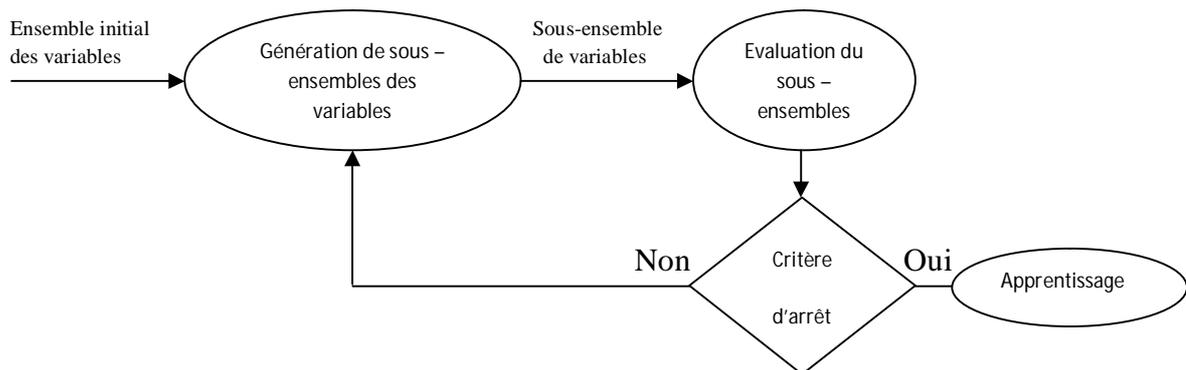


Figure 2.3 : Processus de sélection de variables.

La sélection des variables comporte trois éléments essentiels [HAF12], [PHILIPPE 00] :

- Un critère d'évaluation des variables, pour qualifier la qualité d'un paramètre, et déterminé un sous-ensemble de variables les plus pertinentes.
- Une procédure de recherche pour explorer l'espace des différentes combinaisons de variables,
- Un critère d'arrêt, pour stopper la procédure de recherche.

a) Critère d'évaluation (mesure de pertinence des variables)

La mesure de pertinence associée aux méthodes de sélection de variables est basée sur des heuristiques calculant l'importance individuelle de chaque variable, ce qui correspond intuitivement à :

- La minimisation de la variance intra-classe (regroupement des points de chaque classe).
- La maximisation de la variance inter-classe (éloignement maximal entre les différentes classes).

Ces deux conditions sont traduites par Les matrices de variance intra-classe et inter-classes. La matrice de variance intra-classe fait intervenir les échantillons de chaque classe ainsi que les centres gravités :

$$\sum_w = \frac{1}{N} \sum_{k=1}^M \sum_{j=1}^{N_k} (X_{kj} - \bar{X}_k)(X_{kj} - \bar{X}_k)^t \quad (2.11)$$

Alors que la matrice inter-classes caractérise la dispersion des classes entre elles.

$$\sum_B = \frac{1}{N} \sum_{k=1}^M (\bar{X}_k - \bar{X})(\bar{X}_k - \bar{X})^t \quad (2.12)$$

Le centre de gravité de la classe ω_k est donnée par :

$$\bar{X}_k = \frac{1}{N} \sum_{j=1}^{N_k} X_{kj} \quad (2.13)$$

La matrice variance-covariance qui traduit la dispersion totale de l'ensemble vaut :

$$\sum = \sum_w + \sum_B \quad (2.14)$$

Le critère de Fisher permet de quantifier le pouvoir de discrimination pour chacun des paramètres contenus dans le vecteur forme initial de dimension d .

Dans le cas d'un problème à M classes, le critère s'exprime, pour un paramètre α de la manière suivante :

$$J(\alpha) = \sum_{k=1}^M \sum_{j=1}^{M-1} \frac{(\bar{X}_k(\alpha) - \bar{X}_j(\alpha))}{(N_k \sigma_k^2(\alpha) - N_j \sigma_j^2(\alpha))} \quad (2.15)$$

Avec :

$\bar{X}_k \rightarrow (k = 1, 2)$: Centre de gravité de la classe Ω_k en ne considérant que le paramètre α

$\sigma_k^2(\alpha) \rightarrow (k = 1, 2)$: Variance de la composante α des vecteurs de la classe Ω_k .

$$\bar{X}_k(\alpha) = \frac{1}{N_k} \sum_{i_k}^{N_k} X_{i_k}(\alpha) \quad (2.16)$$

$$\sigma_k^2(\alpha) = \frac{1}{N_k} \sum_{j=1}^{N_k} [X_{kj}(\alpha) - \bar{X}_k(\alpha)]^2 \quad (2.17)$$

b) Procédure de recherche

Le choix d'une procédure de recherche dépend de la taille de l'espace de représentation des observations. Il est possible de rechercher parmi l'ensemble initial E des données (de d paramètres) un sous-ensemble E' (de d' paramètres) de telle sorte que :

$$J(E') = \underset{i=1, \dots, n_c}{\text{Max}} [J(E_{d'}^{(i)})] \quad (2.18)$$

La première solution consiste à calculer le critère J sur toutes les combinaisons de d' paramètres. Le nombre total de combinaisons est égal à $C_d^{d'}$:

$$C_d^{d'} = \frac{d!}{(d-d')! \cdot d'!} \quad (2.19)$$

La solution devient dissuasive est difficile à assurer quand la taille de l'espace de représentation des données est grande. Il existe aussi des méthodes de recherche efficaces comme le Branch & Bound.

En pratique, les méthodes de sélection sous optimales comme les algorithmes de recherche gloutonne (Forward Selection, Backward Elimination) ou les méthodes de recherche aléatoire sont les plus utilisées [HAF A 12].

c) Critère d'arrêt

Pour stopper la procédure de recherche et définir les sous-ensembles des variables les plus pertinents il faut un critère d'arrêt. Le choix de ce dernier reste très difficile à faire, une première solution consiste à arrêter la procédure de recherche lorsqu'un nombre maximum de variables à sélectionner sont atteintes, la fixation de nombre de variables à sélectionner est pratiquement difficile, ce qui rend l'utilisation de ce critère d'arrêt rare. L'idéal est de baser sur le critère d'évaluation en fixant un seuil sur J , dans ce cas la procédure de recherche est arrêtée lorsque ce dernier est atteint.

2.2.1.2 Structuration de l'espace de représentation

L'objectif de la structuration de l'espace de représentation est de regrouper les observations ayant les mêmes paramètres dans la même classe. Cette étape fait appel à des techniques de classification.

La classification se divise en deux familles : classification supervisée, et classification non supervisée. Dans le cas où la classe de chaque observation est connue, l'espace de représentation est parfaitement connu et l'apprentissage est effectué en mode supervisé. Si l'information sur la structuration de l'ensemble d'apprentissage en classe n'est pas disponible, la classification doit être faite en mode non supervisée. La figure suivante représente les différentes méthodes de classification non supervisée, autrement appelée méthode de coalescence.

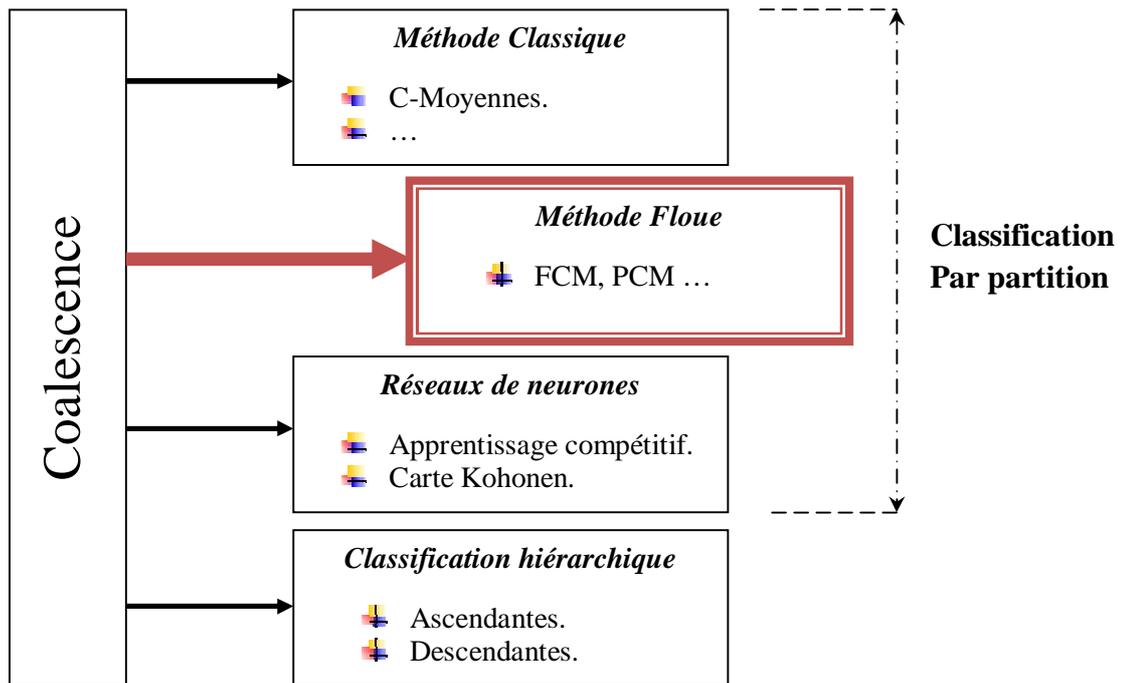


Figure 2.4 : Méthodes de classification non supervisée – Méthode de coalescence –

2.2.1.3 Détermination d'une méthode de décision

À l'issue de la phase d'analyse, l'ensemble d'apprentissage a été structurées en classes distinctes, les données (observations) sont parfaitement connues et étiquetées de telle sorte que chacune des observations appartient à une des M classes connues.

Soit $X_a = (X_{a1}, X_{a2}, \dots, X_{aN})$ l'ensemble d'apprentissage et $\Omega = (\Omega_1, \Omega_2, \dots, \Omega_N)$ l'ensemble des M classes (modes de fonctionnement) connues. La question qui se pose :

À quelle classe affecter une nouvelle observation X recueillie à un instant donné sur le système ?

Pour répondre à cette question, on doit construire une règle de décision en utilisant une approche statistique ou une approche analytique pour la classification des nouvelles observations aux différentes classes de l'ensemble d'apprentissage. L'algorithme de décision doit donc bénéficier des solutions fournies par les options de rejets d'ambiguïté et de distance afin de diminuer le risque de mauvaise classification [ROLAND 03].

Le rejet d'ambiguïté est appliqué aux observations situant aux frontières de décision des classes connues comme montre la figure 2.5.

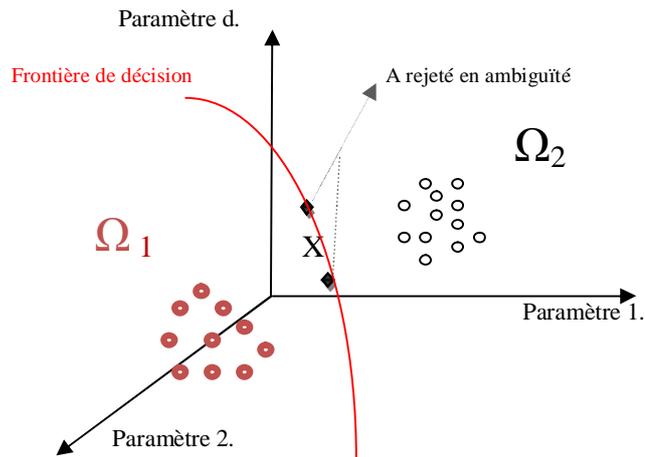


Figure 2.5 : Rejet d’ambiguïté. Observation située près de la frontière de décision entre deux classes.

Les observations se trouvant dans cette situation sont affectés à une nouvelle classe fictive Ω_0 appelée classe de rejet d’ambiguïté.

Si un/ou plusieurs observations sont trop loin des classes connues, on applique un rejet de distance comme montre la figure 2.6.

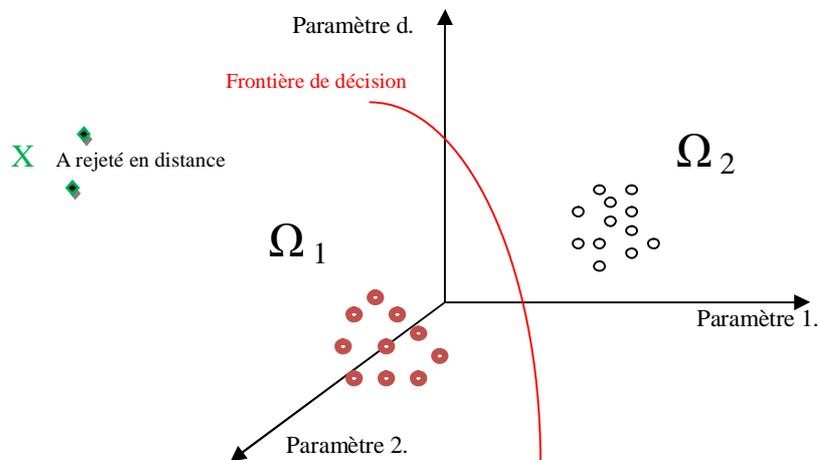


Figure 2.6 : Rejet de distance. Observation ne correspond à aucune des classes connues.

Les observations qui ne correspondent à aucune des classes connues seront affectées à une nouvelle classe fictive Ω_d appelée classe de rejet en distance. Le système se trouve dans un mode de fonctionnement inconnu.

Deux types d’approches peuvent être utilisés pour la mise au point d’une règle de décision. Le premier type consiste à utiliser des méthodes statistiques, paramétriques ou non paramétriques. La deuxième approche, qui est analytique, consiste à privilégier le calcul des frontières de décision entre classes [ROLAND 03], [HAMOU MAMAR 08].

Dans une approche statistique, on associe à chaque vecteur forme X une densité de probabilité conditionnelle $f(X/\Omega_j)$ par rapport à chaque classe de Ω . En fonction de la connaissance, complète ou incomplète sur la distribution de $f(X/\Omega_j)$ on trouve différentes approches.

Si la connaissance est complète, modèle et paramètres de $f(X/\Omega_j)$ étant supposé connus, la règle de décision optimale est basée sur la théorie Bayésienne de la décision.

Dans le cas d'une connaissance incomplète, le modèle $f(X/\Omega_j)$ inconnu, différentes stratégies peuvent être utilisées :

- Si la forme de $f(X/\Omega_j)$ est supposée connue, on estime les paramètres de $f(x/\omega_j)$,
- Si la forme de $f(X/\Omega_j)$ est inconnue, on utilise des méthodes non paramétriques pour l'estimation de $f(X/\Omega_j)$ tels que les noyaux de Perzen. Sinon on estime les probabilités a posteriori en utilisant la méthode des k plus proches voisins, les réseaux neuromimétiques, ... etc.

L'estimation de la densité conditionnelle $f(X/\Omega_j)$ se fait toujours sur un ensemble d'apprentissage.

Dans l'approche analytique, la fonction discriminante est déterminée en estimant les paramètres d'une fonction mathématique de telle sorte à minimiser la probabilité de mauvaise classification pour mieux séparer les classes. La complexité de la frontière de décision impose le choix du modèle de la fonction mathématique. En pratique, on commence par des fonctions linéaires puis si la qualité de classification n'est pas satisfaisante, on passe à des modèles plus complexes, quadratique, réseaux neuromimétiques ...etc.

De plus, il y a d'autres méthodes tel que les réseaux de neurones basés sur la notion de distance, les réseaux perceptron ou bien les réseaux Learning Vector Quantization, tous ses méthodes utilisant des indicateurs pour la division directe de l'espace de représentation en des zones de décision [**HAMOU MAMAR 08**].

2.2.1.4 Evaluation du système de diagnostic

Le système de diagnostic par reconnaissance de formes permet de déterminer à quel mode de fonctionnement correspond chaque nouvelle observation recueillie sur le système. L'algorithme de décision ne pourra que confirmer un mode existant ou rejeter une observation différente des autres. En cas de rejet, seul un travail d'expertise peut fournir une analyse des causes de ce changement d'état [**ROLAND 03**].

Dès que le nombre des observations rejetées devient significatif, la méthode de diagnostic doit permettre de rechercher une nouvelle structure en classe, un nouvel apprentissage est à relancer afin de prendre en compte cette nouvelle classe.

2.3 Reconnaissance des formes floue

Dans la théorie ensembliste classique, l'appartenance d'un élément x à une des classes connues est exprimée par une fonction caractéristique (fonction indicatrice) $u_{E_k}(x)$.

$$x \xrightarrow{u_{E_k}(x) \rightarrow \{0,1\}} u_{E_k}(x) = \begin{cases} 1 & \text{Si } x \in E_k \\ 0 & \text{Sinon} \end{cases} \quad (2.20)$$

Le concept d'appartenance en logique ensembliste classique est binaire (x appartient ou n'appartient pas à un ensemble), qui ne permet pas de représenter les données subjectives à cause des incertitudes liées aux informations et aux connaissances.

La notion floue associée à la reconnaissance des formes permet de situer une forme par rapport à toutes les classes connues. Un degré d'appartenance compris dans l'intervalle $[0, 1]$ est fourni à la forme étudiée pour chaque classe. Si ce degré est proche de 1, cela signifie une forte ressemblance entre la forme et les individus de la classe. À l'inverse, si ce degré est proche de 0, la forme est différente des individus de la classe [JEAN-HUGH 99].

Donc, un ensemble flou F étend la notion d'ensemble classique en généralisant la fonction caractéristique $u_F : E \rightarrow [0,1]$. Cela permet de rendre compte de l'appartenance partielle d'un sous-ensemble flou. Les ensembles flous autorisant des états intermédiaires entre l'appartenance et non appartenance, qui permettent une représentation simple des imprécisions et incertitudes.

La figure 2.7 représente une comparaison entre le concept d'appartenance classique et le concept d'appartenance floue.



Figure 2.7 : Représentation d'une fonction d'appartenance au sens classique et au sens flou.

2.3.1 Caractéristiques des fonctions d'appartenances

Selon [ALOUANE 08], les fonctions d'appartenances possèdent les caractéristiques suivantes :

Le type : les fonctions d'appartenances peuvent avoir différentes formes (triangulaires, trapézoïdales, monotones, gaussiennes).

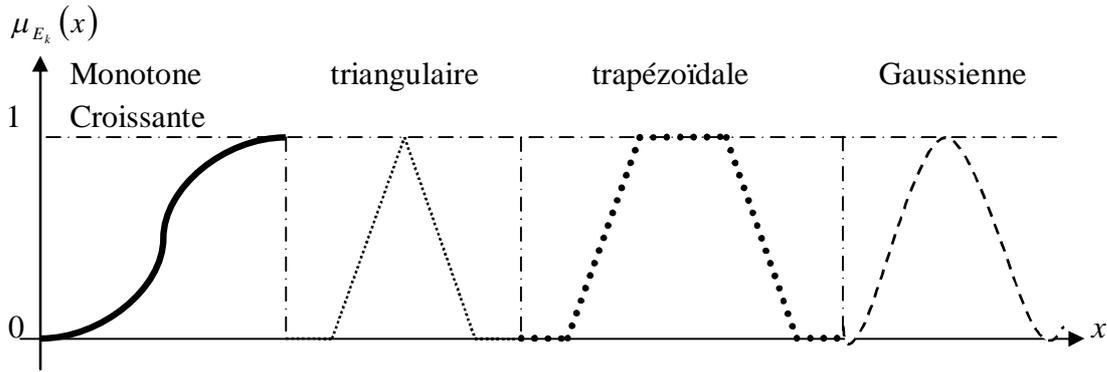


Figure 2.8 : Exemple de fonction d'appartenance

Le noyau ($Noy(F)$): C'est l'ensemble des éléments de E dont le degré d'appartenance à F vaut 1 :

$$Noy(F) = \{x \in E / \mu_F(x) = 1\} \quad (2.21)$$

Le support ($Supp(F)$) : C'est l'ensemble des éléments de E dont le degré d'appartenance à F est non nul.

$$Supp(F) = \{x \in E / \mu_F(x) > 0\} \quad (2.22)$$

La hauteur ($h(F)$): C'est la valeur maximale de la fonction d'appartenance.

$$h(F) = \sup_{x \in E} \mu_F(x) \quad (2.23)$$

Si $h(F)=1 \rightarrow F$ est normalisé.

Les coupes de niveau α (α -coupe) : C'est l'ensemble des éléments de E qui appartiennent à F avec un degré au moins égal à α .

$$F_\alpha = \{x \in E / \mu_F \geq \alpha\} \quad (2.24)$$

L' α -coupe permet à partir de sous-ensembles flous de revenir à la notion d'ensemble classique.

La cardinalité $|F|$: la cardinalité d'un ensemble flou F est la quantité d'éléments de E qui appartiennent à F .

$$|F| = \sum_{x \in E} \mu_F(x) \quad (2.25)$$

Les principaux éléments caractéristiques d'un sous ensemble flou sont illustré dans la figure 2.9

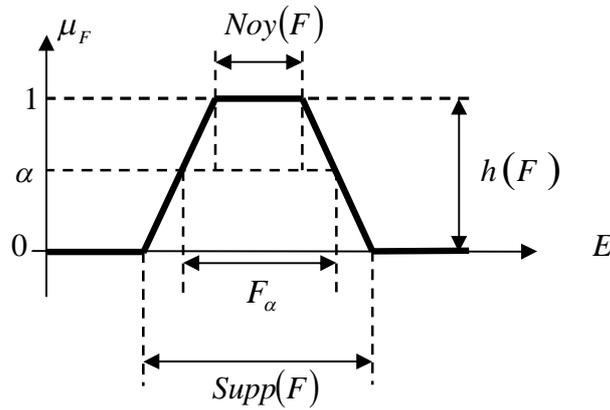


Figure 2.9 : Principaux éléments caractéristiques d'un sous ensemble flou F [ALOUANE08].

2.3.2 Opérations sur les sous-ensembles flous

Le concept de sous-ensemble flou étant une généralisation du concept d'ensemble classique. On présente ici, les opérations couramment utilisées pour la manipulation de deux sous-ensembles flous F et G [AMBAPOUR 09]:

Egalité : Deux sous-ensembles flous F et G sont égaux si leurs fonctions d'appartenance prennent la même valeur pour tous les éléments x de E . Formellement $F=G$ Si seulement si :

$$\forall x \in E, \mu_F(x) = \mu_G(x) \quad (2.26)$$

Complément : le complément d'un sous-ensemble flou F de E noté \bar{F} est défini par :

$$\forall x \in E, \mu_{\bar{F}}(x) = 1 - \mu_F(x) \quad (2.27)$$

Inclusion : Soit F et G deux ensembles flous de E . Si pour n'importe quel élément x de E , x appartient toujours moins à F qu'à G , alors on dit que F est inclus dans G . Formellement :

$$F \subseteq G \Leftrightarrow \forall x \in E, \mu_F(x) \leq \mu_G(x) \quad (2.28)$$

Union : c'est le sous-ensemble flou constitué des éléments de E affectés du plus grand des degrés avec lesquels ils appartiennent à F et G . Formellement :

$$F \cup G \Leftrightarrow \forall x \in E, \mu_{F \cup G}(x) = \max(\mu_F(x), \mu_G(x)) \quad (2.29)$$

Intersection : l'intersection de deux sous-ensembles flous F et G de E est le sous ensemble flou constitué des éléments de E affectés du plus petit des degrés avec lesquels ils appartiennent à F et G , $F \cap G$ est donné par :

$$\forall x \in E, \mu_{F \cap G}(x) = \min(\mu_F(x), \mu_G(x)) \quad (2.30)$$

2.3.3 Classification floue supervisée

La classification par méthodes supervisées, nécessite la connaissance a priori de nombre de classes. Avant d'effectuer une identification des données, il faut passer par les deux phases suivantes [CLAUDIA 07] :

- d) Une phase d'apprentissage pour apprendre les caractéristiques de chaque classe.
- e) Une phase de reconnaissance pour décider l'appartenance des nouvelles données à telle ou telle classe, les données sont classées en fonction du classifieur obtenu lors de la phase d'apprentissage.

Plusieurs algorithmes peuvent être utilisés en mode supervisé tel que les k plus proches voisins, algorithme de Bayes...

2.3.3.1 K plus proches voisins (K-ppv)

L'algorithme de K plus proches voisins *K-ppv* est une méthode non paramétrique et supervisée qui ne nécessite pas une étape d'apprentissage, elle est généralement utilisée en classification et en segmentation d'image en particulier. Le principe de base est d'affecter un individu à la classe qui est majoritaire parmi ses K plus proches voisins. La version floue de cet algorithme apporte deux modifications :

- Introduction de la notion de distance dans le "vote" : un individu (en fait sa classe) aura d'autant plus de poids qu'il sera proche de l'individu à classer.
- Comme pour l'algorithme des C-moyennes, introduction d'une matrice d'appartenance de chaque individu à chaque classe.

L'algorithme se déroule comme suit :

Étape 1 : on fixe une matrice d'appartenance $\mu_k(X)$ initiale.

Étape 2 : pour chaque échantillon X à classifier, on calcule son degré d'appartenance $\mu_k(X)$ dans la classe Ω_k par une somme pondérée des degrés d'appartenance à la classe k de ses *Kppv*.

Plusieurs règles sont proposées dans la littérature pour introduire la notion floue dans la méthode des k plus proche voisin, comme par exemple l'algorithme proposé par Béreau, ou l'algorithme présenté par Keller qui exprime le coefficient d'appartenance d'un nouveau vecteur forme X à la classe Ω_k par [MOCHAWECH 03] :

$$\mu_k(X) = \frac{\sum_{i \in \phi_k(X)} \mu_{i,k} \cdot \left(\frac{1}{\|X - X_i\|^{(2/m-1)}} \right)}{\sum_{i \in \phi_k(X)} \left(\frac{1}{\|X - X_i\|^{(2/m-1)}} \right)} \quad (2.31)$$

La règle floue des K-ppv la plus utilisée est la règle du maximum d'appartenance qui consiste à affecter X à la classe dont la fonction d'appartenance est maximale :

$$X \in \Omega_k \text{ si } \mu_k(X) = \max_{i=1, \dots, M} \mu_i(X) \quad (2.32)$$

L'algorithme flou des k plus proches voisins est simple à implémenter et donne de bons résultats quand le nombre des données n'est pas important.

2.3.3.2 Algorithme de Bayes

L'algorithme de Bayes repose sur la détermination de la valeur de la probabilité a posteriori qu'une observation X provienne de la classe Ω_k :

$$P_r(\Omega_k / X_i) = f(X/\Omega_k) \cdot P_r(\Omega_k) / \sum_{i=1}^M f(X/\Omega_i) \cdot P_r(\Omega_i) \quad (2.33)$$

La règle de Bayes détermine l'affectation du vecteur X à l'une des classes par :

$$X \in \Omega_k \text{ si } P_r(\Omega_k / X) = \max_{i=1, \dots, M} [P_r(\Omega_i / X)] \quad (2.34)$$

Alors l'algorithme cherche à déterminer pour chaque élément X_i la classe Ω_i qui maximise la probabilité de contenir cet élément.

2.3.4 Classification floue non supervisée

2.3.4.1 Algorithme FCM (Fuzzy C-means)

C moyennes floues (FCM) est un algorithme de classification non supervisée floue. Il effectue une optimisation itérative en évaluant de façon approximative les minimums d'une fonction d'erreur.

Les FCM sont un cas particulier d'algorithmes basés sur la minimisation d'un critère ou d'une fonction objectif [ALOUANE 08], [KHODJA 97], [YANG 02], [TREERATTANAPITAK13].

Soit l'ensemble d'apprentissage $X_a = \{X_{a1}, X_{a2}, \dots, X_{aN}\}$ défini dans \mathfrak{R}^d que l'on souhaite partitionner en M classe. Soit $V = \{V_1, V_2, \dots, V_M\}$ qui représente l'ensemble des centres de prototype.

L'objectif de l'algorithme est de minimiser la fonction objective J_m qui représente la distance moyenne intra-groupe floue au sens des moindres carrés, J_m est définie par :

$$J_m(U, V) = \sum_{k=1}^M \sum_{i=1}^N (u_{ik})^m \|X_i - V_k\|_A^2 \quad (2.35)$$

Pour tout $k(1 \leq k \leq M)$, V_k est un vecteur à d composantes qui représente le prototype de la $k^{\text{ème}}$ (Centre classe de la classe k), $m > 1$ est l'indice flou.

Où :

$\|X_i - V_k\|_A^2$ Est la distance entre l'échantillon X_i et le centroïde du cluster V_k définie par :

$$\|X_i - V_k\|_A^2 = (X_i - V_k)^t A (X_i - V_k) \quad (2.36)$$

Si A est la matrice identité, le cluster V_k sera sphérique, sinon il sera ellipsoïdal [GLORENNEC 99]. Dans la version habituelle des FCM, A est la matrice identité quelque soit V_k .

La mise à jour itérative des prototypes et des degrés d'appartenance est donnée par les deux équations suivantes :

La détermination des centroïdes V_k [BERZEK 81] : on calcule les centroïdes des classes.

$$V_k = \frac{\sum_{i=1}^N u_{i,k}^m X_i}{\sum_{i=1}^N u_{i,k}^m} \quad (2.37)$$

Détermination des fonctions d'appartenance :

$$u_{i,k} = \left[\sum_{l=1}^M \left(\frac{\|X_i - V_k\|_A}{\|X_i - V_l\|_A} \right)^{\frac{2}{m-1}} \right]^{-1} \quad (2.38)$$

L'algorithme FCM est décrit de manière détaillée dans le tableau (2.1) :

Algorithme : C-moyennes floues [FCM]

- **Données**
N vecteurs non étiquetés.

- **Paramétrage :**
Nombre de classe M.
nombre maximal d'itérations T
Fixer le degré de flou m.
Norme pour calcul des distances $\|\cdot\|_A$.
Seuil d'arrêt ϵ .

○ **Initialisations :**

Initialiser le compteur de boucle $t \leftarrow 0$.

Tirage au hasard des prototypes $V_0 = (V_1^{(0)}, \dots, V_M^{(0)})$.

○ **Itérations :**

Répéter

$t \leftarrow t + 1$

1. **Calcul de la matrice de partition U_t par :**

$$u_{i,k} = \begin{cases} 1 & \|X_i - V_k\|_A \leq \|X_i - V_l\|_A \quad \forall l \neq k \\ 0 & \text{Sinon} \end{cases} \quad \forall i, k$$

$$\text{Ou par : } u_{i,k} = \left[\sum_{i=1}^M \left(\frac{\|X_i - V_k\|_A}{\|X_i - V_l\|_A} \right)^{\frac{2}{(m-1)}} \right]^{-1}$$

2. **Calcul des prototypes V_t par**

$$V_k = \frac{\sum_{i=1}^N u_{i,k}^m X_i}{\sum_{i=1}^N u_{i,k}^m}$$

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \varepsilon$

Tableau 2.1 : Algorithme FCM.

2.3.4.1.1 Avantages et inconvénients de l'algorithme FCM

L'avantage principal de l'algorithme FCM est le fait d'obtenir des regroupements dans lesquels l'appartenance d'une observation à un regroupement devient une notion graduelle. Les degrés d'appartenance μ_{jk} rendent le processus itératif beaucoup plus robuste qui permet d'obtenir des partitions plus pertinentes, et plus proches de la réalité.

Cependant, l'algorithme FCM n'est pas robuste face aux bruits introduits par l'imprécision des attributs, ce problème de la sensibilité à l'initialisation des centres des classes peut facilement diminuer l'efficacité de l'algorithme et fournir une solution localement optimale.

De plus, il ne permet que la détection des classes de forme sphérique, puisqu'il est basé sur la distance euclidienne pour mesurer la similarité entre une observation et le centre d'une classe. Pour résoudre ces inconvénients, plusieurs modifications ont été apportées à l'algorithme de base et qui sont présentées comme des dérivés de l'algorithme FCM.

2.3.4.2 Les algorithmes dérivés de l'algorithme FCM

Pour pouvoir éviter les problèmes liés à l'algorithme FCM standard, de nombreuses variantes se fondent essentiellement sur une modification de la métrique utilisée ont été proposées.

2.3.4.2.1 Algorithme de Gustafson et Kessel GK

Cette méthode est basée sur l'utilisation de la distance Mahalanobis à la place de la distance euclidienne, cela permet de représenter chaque classe k par son centre de gravité et sa matrice de covariance. On parle alors de distance adaptative qui permet de détecter des classes de forme ellipsoïdale.

Soit l'ensemble $A = \{A_k\}_{k=1}^M$, la fonction objectif donnée par Gustafson et Kessel est:

$$J_m^{GK} = (U, V) = \sum_{k=1}^M \sum_{i=1}^N \mu_{i,k}^m \|X_i - V_k\|_{A_k}^2 \quad (2.39)$$

La distance entre l'échantillon X_i et le centroïde du cluster V_k prend la forme suivante :

$$\|X_i - V_k\|_{A_k}^2 = (X_i - V_k)^t A_k (X_i - V_k) \quad (2.40)$$

Où :

$$A_k = \left[\rho_k \det \left(\sum_k \tilde{\Sigma}_k \right) \right]^{1/n} \sum_k^{-1} \quad \forall k \quad (2.41)$$

$\sum_k \tilde{\Sigma}_k$ Représente la matrice covariance floue associée à la classe k , celle-ci est calculée à chaque itération par l'équation (2.42):

$$\sum_k \tilde{\Sigma}_k = \frac{1}{\sum_{i=1}^N \mu_{ik}^m} \sum_{i=1}^N (X_i - V_k)(X_i - V_k)^t \quad (2.42)$$

L'algorithme Gustafson et Kessel (GK) est décrit de manière détaillée dans le tableau 2.2 :

Algorithme : Gustafson et Kessel (GK)

- **Données** N vecteurs non étiquetés.

- **Paramétrage :**
 - Nombre de classe M.
 - nombre maximal d'itérations T
 - Fixer le degré de flou m.
 - Norme pour calcul des distances $\|\cdot\|_A$.
 - Seuil d'arrêt ε .

○ **Initialisations :**

Initialiser le compteur de boucle $t \leftarrow 0$.

Tirage au hasard des prototypes $V_0 = (V_1^{(0)}, \dots, V_M^{(0)})$.

Initialiser l'ensemble des matrices de covariance $A^{(0)}$ respectant $\det(A_k) = \rho_k > 0$

○ **Itérations :**

Répéter $t \leftarrow t + 1$

1. **Calcul de la matrice de partition U_t par :**

$$u_{i,k} = \left[\sum_{l=1}^M \left(\frac{\|X_i - V_k\|_A}{\|X_i - V_l\|_A} \right)^{\frac{2}{(m-1)}} \right]^{-1}$$

2. **Calcul des prototypes V_t par**

$$V_k = \frac{\sum_{i=1}^N u_{i,k}^m X_i}{\sum_{i=1}^N u_{i,k}^m}$$

$$A_k = \left[\rho_k \det \left(\sum_k \tilde{\mu}_{ik} \right) \right]^{\frac{1}{n}} \sum_k \tilde{\mu}_{ik}^{-1} \quad \forall k$$

$$\text{Où : } \tilde{\mu}_{ik} = \frac{1}{\sum_{i=1}^N \mu_{ik}^m} \sum_{i=1}^N (X_i - V_k)(X_i - V_k)^t$$

Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \varepsilon$

Tableau 2.2 : Algorithme Gustafson et Kessel

2.3.4.2.2 Algorithme C- moyennes possibiliste PCM

L'algorithme c-moyennes possibiliste a été proposé par Krishnapuram et Keller [KRISHNAPURAM 05], dans ce dernier, le degré d'appartenance d'une observation à une classe est considéré comme une possibilité d'appartenir à une classe [SBILI 15].

La fonction objectif modifiée est :

$$J_m^{PCM}(U, V) = \sum_{k=1}^M \sum_{i=1}^N \mu_{i,k}^m \|X_i - V_k\|_A^2 + \sum_{k=1}^M w_k \sum_{i=1}^N (1 - \mu_{i,k})^m \quad (2.43)$$

Dans cette expression, le premier terme correspond au critère, de FCM, le second terme impose des valeurs les plus grandes possibles aux possibilités d'appartenance. La valeur de ω_k fixe la distance à partir de laquelle la possibilité d'appartenance est égale à 0.5 [ASSAS13]. L'algorithme est initialisé avec la matrice de partition obtenue par la méthode FCM.

$$w_k = \frac{\sum_{i=1}^N \mu_{ik}^m \|X_i - V_k\|_A^2}{\sum_i \mu_{ik}^m} \quad (2.44)$$

Les centres de classes sont mis à jour comme dans l'algorithme FCM. Les possibilités d'appartenance sont calculées de manière itérative par les expressions :

$$V_k^{(t)} = \frac{\sum_{i=1}^N \mu_{i,k}^m X_i}{\sum_{i=1}^N \mu_{i,k}^m} \quad (2.45)$$

$$\mu_{i,k} = \left[1 + \left(\frac{\|X_i - V_k\|_A^2}{w_k} \right)^{\frac{1}{(m-1)}} \right]^{-1} \quad \forall i, k \quad (2.46)$$

Le calcul se termine dès que la différence entre chaque possibilité d'appartenance et la possibilité de l'itération précédente est inférieure à un seuil fixé. La confusion des centres est l'inconvénient de cet algorithme.

2.3.4.2.3 Algorithme de C-moyennes possibilistes modifiée MPCM

L'algorithme de c-moyennes possibiliste modifié proposé par KHODJA Lotfi [KHODJA 97], a pour but d'éliminer le problème de confusion des centres, les MPCM limitent la contribution des points les plus éloignés d'un centre donné dans le calcul des coordonnées du centre via la modification de la formule des degrés d'appartenance :

$$\mu_{i,k} = \left[1 + \left(\frac{\|X_i - V_k\|_A^2}{w_k} \right)^{\frac{m}{(m-1)}} \right]^{-1} \quad \forall i, k \quad (2.47)$$

La fonction objectif proposée par KHODJA est :

$$J_m^{MPCM}(U, V) = \sum_{k=1}^M \sum_{i=1}^N \mu_{i,k}^m \|X_i - V_k\|_A^{2m} + \sum_{k=1}^M w_k \sum_{i=1}^N (1 - \mu_{i,k})^m \quad (2.48)$$

Cet algorithme présente l'avantage de sauvegarder les apports espérés de l'approche possibiliste, tout en éliminant l'inconvénient de confusion des centres.

L'algorithme PCM et MPCM sont décrit de manière détaillée dans le tableau (2.3) :

Algorithme : PCM et MPCM

- **Données** N vecteurs non étiquetés.

- **Paramétrage :**
 - Nombre de classe M .
 - nombre maximal d'itérations T
 - Fixer le degré de flou m .
 - Norme pour calcul des distances $\|\cdot\|_A$.
 - Seuil d'arrêt ε .

- **Initialisations :**
 - Initialiser le compteur de boucle $t \leftarrow 0$.
 - Initialiser la partition en utilisant par exemple l'algorithme FCM.
 - Calculer les ω_k par l'équation (2.44)

- **Itérations :**
 - Répéter $t \leftarrow t + 1$
 1. Calcul de la matrice de partition U_t par l'équation (2.46) ou (2.47).
 2. Calcul des prototypes V_t par l'équation (2.45).
 - Tant que $(t \leq T)$ et $\|V_t - V_{t-1}\| \geq \varepsilon$

Tableau 2.3 : Algorithme PCM et MPCM.**2.3.4.3 Problèmes en classification****2.3.4.3.1 Validation du nombre des classes**

Le processus d'évaluation des performances de la classification est appelé indice de validation des classes.

Le processus pour le calcul de l'indice de validation est résumé comme suite :

1. Initialiser les paramètres de l'algorithme excepté le nombre de classe M ,
2. Appliquer l'algorithme pour différentes valeurs de M , avec $M=2,3 \dots M_{max}$ (M_{max} est fixé par l'utilisateur).
3. Calculer l'indice de validation pour chaque partition obtenue à l'étape 2,
4. Choisir le nombre optimal des classes M .

Plusieurs indices de validité de classes sont proposés dans la littérature. Berzek a proposé deux indices: le coefficient de partition et l'entropie de partition. Ils sont sensibles au bruit et à la variation de [MARIA 01]. Ont défini un critère de compacité et de séparabilité, il donne un bon résultat en cas de classes compactes et bien séparées.

2.3.4.3.2 Méthodes d'initialisation de la partition

Le bon choix des paramètres initiaux assure une bonne qualité de classification, l'initialisation de la partition se fait soit par un triage aléatoire des centres des classes parmi l'ensemble d'apprentissage, ou bien par l'utilisation d'un algorithme de classe inférieure dans la famille de c-moyennes ...etc.

2.3.5 Définition des fonctions d'appartenance

2.3.5.1 Exploitation des résultats de la classification floue

L'apprentissage à partir de l'ensemble des données non étiquetées par l'un des algorithmes de classification floue (FCM, PCM, MPCM ...) décrits précédemment, il convient en général d'examiner s'il est possible d'associer à chacune des classes connues, un mode de fonctionnement du système surveillé.

À chaque mode de fonctionnement correspond une seule classe, on pourra déterminer les valeurs de toute nouvelle observation X , des fonctions d'appartenance par l'équation de degré d'appartenance. L'utilisation de l'équation (2.38) entraîne :

$$\forall X \Leftrightarrow \sum_{k=1}^M \mu_k(X) = 1 \quad (2.50)$$

Cela semble une propriété trop forte en diagnostic, notamment lorsque des modes de fonctionnement répertoriés ne sont pas exhaustifs: il se peut alors que le système se trouve, à un instant donné, éloigné de tous les modes connus, ce qui devrait se traduire par une condition du type :

$$\text{Max}_{k=1,M} \mu_k(X) \approx 0 \quad (2.51)$$

Il est recommandé d'utiliser la formule c-moyenne possibiliste modifiée MPCM pour le calcul des degrés d'appartenance :

$$\forall k \Leftrightarrow \mu_k(X) = \left[1 + \left(\frac{\|X - V_k\|_A^2}{w_k} \right)^{\frac{m}{(m-1)}} \right]^{-1} \quad (2.52)$$

Dans le cas où un mode de fonctionnement correspond à plusieurs classes, il paraît naturel de définir le degré d'appartenance au mode Ω_k en fonction des degrés d'appartenance aux classes correspondant à ce mode, en utilisant un opérateur de combinaisons disjonctif.

Soit $[\mu_{k,1}, \mu_{k,2}, \dots, \mu_{k,n_k}]$ les fonctions d'appartenance et les prototypes $[V_{k,1}, V_{k,2}, \dots, V_{k,n_k}]$ caractérisant le mode k . On pourra poser, pour une t -conorme \perp :

$$\mu_k(X) = \mu_{k,1} \perp \cdots \perp \mu_{k,n_k} \quad (2.53)$$

Par exemple, Massons [MASSON 96] a proposé d'utiliser l'opérateur de somme bornée :

$$\mu_k(X) = \min \left[1, \sum_{l=1}^{n_k} \mu_{k,l} \right] \quad (2.54)$$

L'emploi d'autres opérateurs tels que le maximum de ZADEH pourrait se justifier également.

2.3.6 Règle de décision à partir des degrés d'appartenance (Defuzzification)

La règle de décision permet d'établir des frontières entre les classes, et d'affecter ou non une nouvelle observation X à l'une des classes correspondant à un mode de fonctionnement.

Après avoir calculé le vecteur Z qui représente donc les degrés d'appartenance aux différentes classes :

$$Z = (\mu_1(X), \dots, \mu_M(X)) \quad (2.55)$$

Pour affecté X à sa classe, il reste à en déduire le choix d'une action $\Phi_k \in A \rightarrow A = \{\Phi_1, \dots, \Phi_M\}$, le cas le plus simple serait d'avoir chaque action Φ_k qui représente l'affectation du vecteur X à la classe Ω_k . Dans ce cas, on pourrait appliquer le principe de maximum d'appartenance :

$$D(X) = \Omega_k \quad Si \quad \mu_k(X) \gg \mu_l(X) \quad \forall l \neq k \quad (2.56)$$

Si on considère A l'ensemble des actions possibles incluant, l'affectation à un rejet d'ambiguïté Ω_a et l'action de rejet en distance Ω_d , pour chaque vecteur d'entrée X , on obtient un ensemble des résultats des actions obtenues :

$$J(X) = \{k \in \{1, \dots, M\} / \mu_k(X) \gg S_k\} \quad (2.57)$$

Pour chaque classe, S_k présente le seuil d'appartenance. Ce seuil est soit défini a priori, soit déterminé à partir de l'ensemble d'apprentissage.

Cette règle appelée seuillage des appartenances, consiste à rejeter X en ambiguïté si son degré d'appartenance à plusieurs classes est significatif. Et à choisir l'option de rejet de distance quand $J(X)$ est vide :

$$\begin{array}{ll} Si \quad J(X) = \{k\} & alors \quad D(X) = \Omega_k \\ Si \quad J(X) = \emptyset & alors \quad D(X) = \Omega_d \\ Si \quad |J(X)| > 1 & alors \quad D(X) = \Omega_a \end{array} \quad (2.58)$$

L'inconvénient de règle de seuillage des appartenances est le fait qu'elle contrôle les deux options de rejet par le même seuil d'appartenance S_k .

Une autre règle proposée par FRELICOT [FRELICOT 92], [FRELICOT 93], dite règle du rapport d'appartenance, basée sur le seuillage d'appartenance, s'appuie sur le rapport :

$$R = \frac{\mu_m(X)}{\mu_p(X)} \quad (2.59)$$

Avec :

$$\mu_m(X) = \max_{k \in J(X) \setminus \{p\}} \mu_k(X) \quad (2.60)$$

$$\mu_p(X) = \max_{k \in J(X)} \mu_k(X) \quad (2.61)$$

On a $0 \leq R \leq 1$, quand R s'approche de 1 il ya ambiguïté. On pose la règle suivante :

$$\begin{aligned} \text{Si } J(X) \neq \emptyset \text{ et } R \geq T_{amb} \quad \text{alors } D(X) &= \Omega_a \\ \text{Si } J(X) = \emptyset \quad \text{alors } D(X) &= \Omega_d \\ \text{Sinon} \quad D(X) &= \Omega_p \end{aligned} \quad (2.62)$$

T_{amb} est un paramètre fixé par l'utilisateur, permettant le contrôle du rejet en ambiguïté.

Une dernière règle de degrés de confiance, a été proposée par Masson et al [MASSON 92]. Son principe s'appuie sur la définition de degrés de confiance fonctions des M degrés d'appartenance. Plus précisément, on définit le degré de confiance associé à la classe k pour le vecteur forme X comme :

$$C_k(X) = \mu_k(X) \prod_{l \neq k} [1 - \mu_l(X)] \quad (2.63)$$

La quantité $C_k(X)$ est d'autant plus grande que le degré d'appartenance à la classe k est élevé et que les degrés d'appartenance aux autres classes sont faibles. Par ailleurs, soit:

$$C_0(X) = \prod_{l=1}^M [1 - \mu_l(X)] \quad (2.64)$$

Cette quantité est d'autant plus grande que les degrés d'appartenance aux classes sont faibles, et traduits donc le caractère « atypique » du vecteur X . Une règle de décision simple, basée sur les degrés de confiance, est donc la suivante.

Soit q l'indice tel que :

$$q = \arg \max_{k \in \{0, \dots, M\}} C_k(X) \quad (2.65)$$

On pose :

$$\begin{aligned} \text{Si } q = 0 \text{ et } C_0(X) \geq T_{ad} \quad \text{alors } D(X) &= \Omega_d \\ \text{Si } q = k \text{ et } C_k(X) \geq T_{ad} \quad \text{alors } D(X) &= \Omega_k \\ \text{Sinon} \quad D(X) &= \Omega_a \end{aligned} \quad (2.66)$$

T_{ad} Étant un coefficient contrôlant à la fois le rejet d'ambiguïté et le rejet de distance.

2.4 Séparateurs à vaste marge (SVM)

SVM sont basées sur les techniques de classification binaire par apprentissage supervisé, utilisées notamment pour l'analyse des données. L'algorithme SVM a été conçu par Vladimir Vapnik en 1995. Le principe de base de classification par SVM consiste à trouver l'hyper plan idéal qui sépare les données en maximisant la distance entre les deux classes. Grâce à l'usage d'une fonction noyau (*kernel*), elles permettent une classification non linéaire.

2.4.1 Principes de la méthode SVM

Soit X_a l'ensemble d'apprentissage et $\Omega = (\Omega_1, \Omega_2)$ représenter dans l'espace \mathfrak{R}^p :

$$\begin{aligned} X_a &= \{(x_1, z_1), \dots, (x_i, z_i), \dots, (x_N, z_N)\} \quad i = 1 \dots N, x_i \in \mathfrak{R}^p, z_i = \{-1, +1\} \\ \Omega_1 &= \{x_i | z_i = +1\}, \Omega_2 = \{x_i | z_i = -1\} \end{aligned} \quad (2.67)$$

Chaque observation d'entrée $x_i = (x_{i1}, x_{i2}, \dots, x_{ip})^T$ est composée de p variables descriptives.

La sortie z_i définit la classe d'observation d'entrée x_i .

La figure 2.10 illustre l'hyperplan optimal qui sépare les deux ensembles de points.

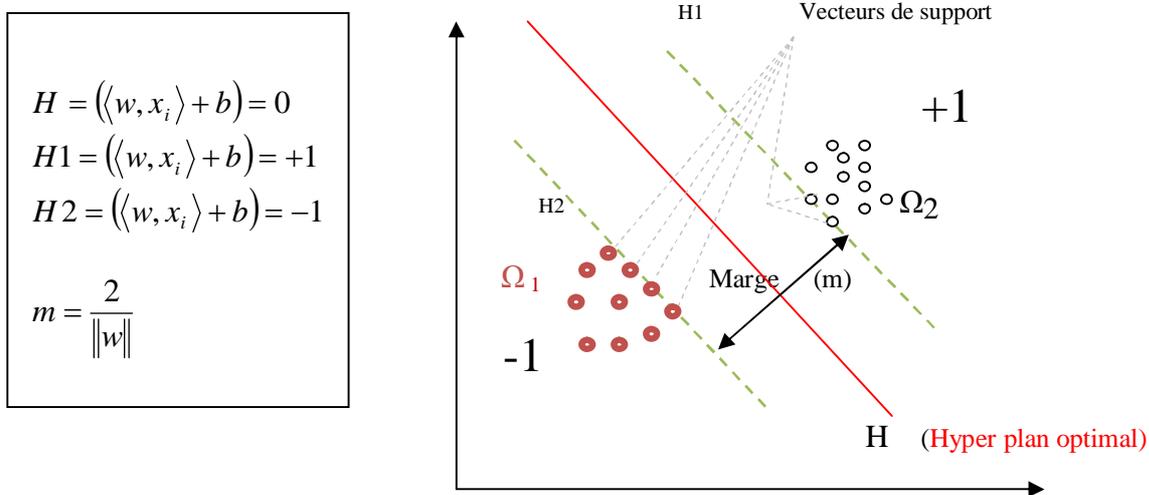


Figure 2.10 Séparation des deux classes par SVM.

La figure 2.10 illustre un cas de séparation des deux classes par SVM, pour commencer nous présentons quelques notions de base qui sont hyperplan, Marge et les vecteurs supports.

- Les hyperplans $H1: (w \cdot x) + b = +1$ et $H2: (w \cdot x) + b = -1$ sont appelés hyperplans coniques. $H1$ et $H2$ sont parallèles, permettant de définir la marge (m), Grâce à l'équation 2.70 il n'existe aucun point entre eux.
- Les vecteurs supports sont les points qui se trouvent sur les hyperplans $H1$ et $H2$.
- La distance (d) qui sépare les deux hyperplans coniques est appelée Marge (m)

$$d(x) = \frac{|w \cdot x + b|}{\|w\|} \quad (2.68)$$

Où : $\|w\|$ est la norme du vecteur w .

- l'hyperplan optimal assure une marge de séparation maximale, c'est-à-dire qui rend la quantité $\|w\|$ minimale.

Le principe de SVM est de séparer les données d'apprentissage en deux, de sorte que toutes les observations d'une classe soient du même côté de l'hyperplan. Deux cas de séparation se présentent, le cas des données linéairement séparables, et le cas des données non linéairement séparables.

2.4.1.1 Cas des données linéairement séparable

Supposons un ensemble de données linéairement séparable, cette situation est considérée comme étant la plus simple de SVM, elle fonctionne seulement quand les données d'apprentissage sont linéairement séparables (système simple). La figure 2.11 illustre un cas de séparation linéaire par SVM.

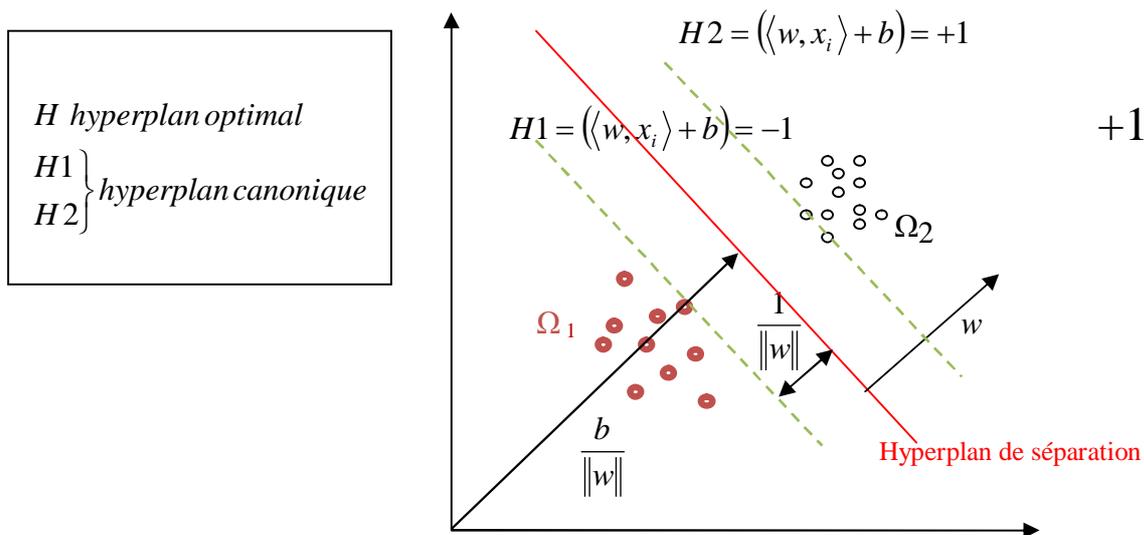


Figure 2.11 : Séparation linéaire.

Dans le cas linéaire, le choix de l'hyperplan optimal parmi les infinis hyperplans séparateurs se fait par une fonction discriminante linéaire décrite par l'équation (2.69) :

$$f(x) = \langle w, x \rangle + b \quad (2.69)$$

Où w est le vecteur poids (la normale au plan), il définit la direction perpendiculaire à l'hyperplan optimal, et b est un scalaire appelé biais, et $\frac{b}{\|w\|}$ la distance entre l'hyperplan et l'origine.

Pour trouver le meilleur classificateur il existe de nombreux choix possibles pour w et b .

La classe de l'observation x est donnée par :

$$f(x) = \begin{cases} +1 & \text{Quand } \langle w, x \rangle + b \geq 0 \\ -1 & \text{Quand } \langle w, x \rangle + b \leq 0 \end{cases} \quad (2.70)$$

Pour le cas des données linéairement séparable. En utilisant une mise à l'échelle appropriée de w et b , il est possible de forcer les observations de chaque classe à satisfaire les conditions suivantes :

$$\begin{cases} \langle w, x_i \rangle + b \geq 1 & \text{si } z_i = 1 \\ \langle w, x_i \rangle + b \leq -1 & \text{si } z_i = -1 \end{cases} \quad (2.71)$$

L'hyperplan obtenu permet de regrouper les observations de chaque classe dans un même coté.

$$z_i (\langle w, x_i \rangle + b) \geq 1 \quad i = 1, \dots, N; w \in \mathfrak{R}^p \text{ et } b \in \mathfrak{R} \quad (2.72)$$

La marge (m) est donnée par :

$$m = \min_{x_i/z_i} \frac{w \cdot x + b}{\|w\|} - \max_{x_i/z_i} \frac{w \cdot x + b}{\|w\|} = \frac{1}{\|w\|} - \frac{-1}{\|w\|} = \frac{2}{\|w\|} \quad (2.73)$$

Maximiser la marge est synonyme à maximiser $\frac{2}{\|w\|}$ ou bien à minimiser $\frac{\|w\|^2}{2}$.

L'hyperplan optimal sépare bien les deux classes quand la Marge est maximisée et la quantité $\|w\|$ soit minimisée.

Sous la contrainte (2.72), on fait face à un problème de minimisation d'une fonction quadratique avec contraintes linéaires. Il faut trouver l'hyperplan optimal qui permet de résoudre le problème dual présenté par l'équation (2.74).

$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ \forall i z_i (\langle w, x_i \rangle + b) \geq 1 \quad i = 1 \dots N \end{cases} \quad (2.74)$$

La résolution de ce problème d'optimisation est réalisable par l'utilisation des multiplicateurs de Lagrange α_i présenté par l'équation suivante :

$$L(w, b, \alpha) = \frac{1}{2} w \cdot w^T - \sum_{i=1}^N \alpha_i [z_i (\langle w, x_i \rangle + b) - 1] \quad (2.75)$$

Pour annuler les dérivées partielles du Lagrangien, ce dernier doit être minimal par rapport au vecteur poids w et le biais b en même temps maximal par rapport à α .

$$\frac{\partial L(w, b, \alpha)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i \cdot z_i \cdot x_i \quad (2.76)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i \cdot z_i = 0 \quad (2.77)$$

On peut écrire le problème dual sous la forme :

$$\begin{cases} \min_{\alpha} \left[\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \cdot \alpha_j \cdot z_i \cdot z_j \langle x_i, x_j \rangle - \sum_{i=1}^N \alpha_i \right] \\ \forall i \alpha_i \geq 0 \quad i = 1 \dots N, \quad \text{et} \quad \sum_{i=1}^N \alpha_i \cdot z_i = 0 \end{cases} \quad (2.78)$$

Ce dual problème, peut-être résolue en utilisons la fonction de décision suivante :

$$\begin{cases} f(x) = \text{sgn}(\langle w, x \rangle + b) \\ w = \sum_{i=1}^N \alpha_i \cdot z_i \cdot x_i \end{cases} \quad (2.79)$$

Dans ce cas si le signe de la fonction $f(x)$ est positive alors la nouvelle observation x appartient à la classe +1, sinon x appartient à la classe -1.

2.4.1.2 Cas des données non linéairement séparable

Dans les cas réels, où la majorité des systèmes sont complexes, il est difficile de trouver un séparateur linéaire qui permet la classification des données (collectés en présence du bruit) en deux classes.

2.4.1.2.1 Utilisation des fonctions noyaux

L'idée de SVM pour le cas non linéaire, est de projeter les données dans un autre espace plus grand qui permet une séparation linéaire des classes [LAOUITI 12].

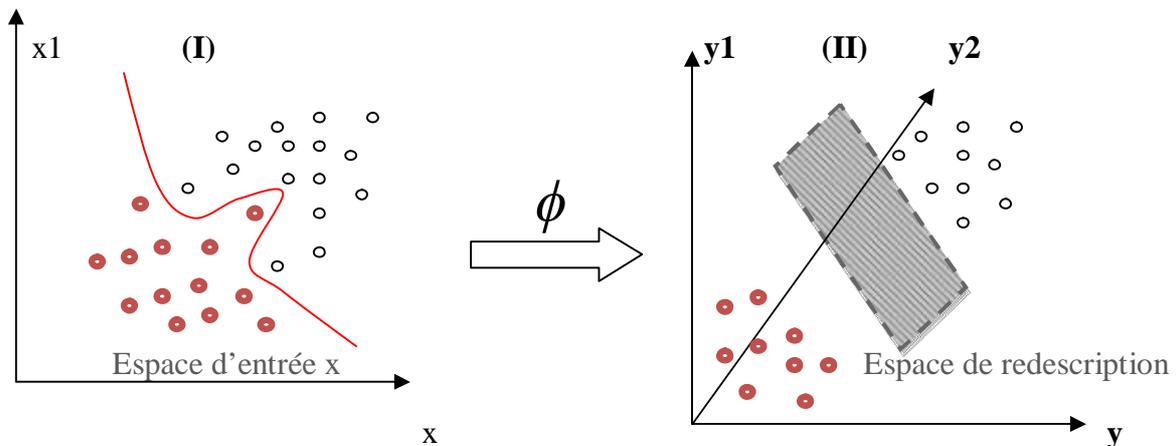


Figure 2.12 : (I) Pas d'hyperplan Séparateur; (II) Hyperplan dans un autre espace.

La figure 2.12 démontre la transformation d'un problème non linéaire à un problème linéaire dans un autre espace de représentation (Espace de redescription). La transformation ϕ du plan (I) vers l'espace (II) est réalisée à l'aide d'une fonction noyau (polynomiale, gaussienne, sigmoïde, ...etc.).

En peut traduire mathématiquement la transformation illustrée dans la figure 2.12, par l'équation suivante :

$$\begin{aligned} \phi : \mathbb{R}^2 &\rightarrow \mathbb{R}^3 \\ x = (x_1, \dots, x_j)^T &\rightarrow \phi(x) = \langle \phi(x_i), \dots, \phi(x_j) \rangle \end{aligned} \quad (2.80)$$

Les observations sont projetées via la fonction $\phi(x)$ telle que :

$$\phi(x_i) \cdot \phi(x_j) = k(x_i, x_j) \quad (2.81)$$

Où k est appelé fonction noyau (Kernel), c'est-à-dire le produit scalaire dans le nouvel espace va être représenté comme un noyau de l'espace d'entrée.

Le produit scalaire dans le nouvel espace est dénoté par \langle , \rangle . Le problème d'optimisation (2.78) devient :

$$\begin{cases} \min_{\alpha} \left[\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \cdot \alpha_j \cdot z_i \cdot z_j \langle \phi(x_i), \phi(x_j) \rangle - \sum_{i=1}^N \alpha_i \right] \\ \forall i \quad 0 \leq \alpha_i \leq C \quad , \quad \text{et} \quad \sum_{i=1}^N \alpha_i \cdot z_i = 0 \quad i = 1 \dots N \end{cases} \quad (2.82)$$

Le paramètre de pénalité C ($C \geq 0$) est positif qui donne moins d'importance aux erreurs de classification, il représente une balance entre La maximisation de la marge et la minimisation de l'erreur de classification [DJEFFAL 11]. Il traduit le niveau de mauvaises classifications que vous souhaitez autoriser durant l'optimisation, une grande valeur de C signifie une forte pénalité pour chaque observation mal classée

La séparation est toujours linéaire, et la fonction de décision dans ce cas est la suivante :

$$f(x) = \sum_{i=1}^N \alpha_i \cdot z_i \langle \phi(x_i), \phi(x) \rangle + b \quad (2.83)$$

Dans le cas des grandes dimensions, le calcul de $\langle \phi(x_i), \phi(x_j) \rangle$ devient impossible, il existe des fonctions bilinéaires symétriques positives $K(x_i, x_j)$, appelées fonction Kernel, qui correspond à un produit scalaire $\langle \phi(x_i), \phi(x_j) \rangle$ dans un espace de grande dimension.

$$K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle \quad (2.84)$$

La figure 2.13 illustre une séparation non linéaire par la méthode de noyau :

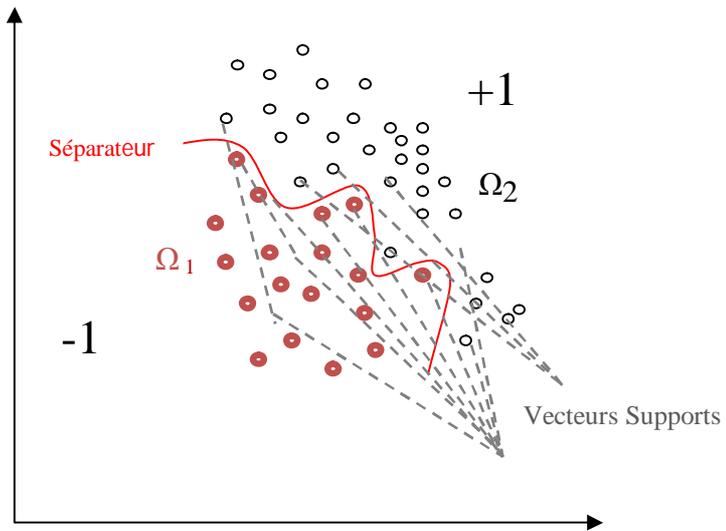


Figure 2.13 : Séparation non linéaire par méthode de noyau.

On peut utiliser la fonction $K(x_i, x_j)$ qui satisfait les conditions de Mercer, sans savoir les informations de transformation non linéaire.

Condition de Mercer : Sachant que la matrice contenant les similarités entre tous les exemples de l'entraînement est appelée la matrice Gram (G) [LAOUITI 12].

La fonction $k(x_i, x_j) : X \times X \rightarrow \mathfrak{R}$ est un noyau si seulement la matrice de Gram $G = (k(x_i, x_j))$, avec $i, j = 1, \dots, N$ (N est le nombre d'exemples d'entraînement) est une matrice définie positive (symétrique et ne contenant pas de valeurs propres négatives).

Notons qu'une fonction k générant une matrice définie positive G possède les propriétés fondamentales du produit scalaires suivantes : $\forall (x_i, x_j) \in X$

- Positivité : $k(x_i, x_j) \geq 0$
- Symétrie : $k(x_i, x_j) = k(x_j, x_i)$
- Inégalité de Cauchy-Schwartz : $|k(x_i, x_j)| \leq \|x_i\| \|x_j\|$

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

La fonction $K(x_i, x_j)$ peut être vue comme une matrice de Gram (G) (équation 2.85) qui représente la distance entre tous les exemples :

$$G = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_n) \\ \vdots & \ddots & \vdots \\ K(x_n, x_n) & \cdots & K(x_n, x_n) \end{bmatrix} \quad (2.85)$$

La matrice de Gram appelé aussi matrice noyau contient toute l'information utilisée par les méthodes à noyaux sur les données.

Une fois le noyau choisi, le problème donné par l'équation (2.82) devient :

$$\begin{cases} \min_{\alpha \in \mathbb{R}^N} \left[\frac{1}{2} \alpha^T \cdot G \cdot \alpha - \alpha^T I \right] \\ \alpha^T z = 0 \\ 0 \leq \alpha_i \leq C \quad i=1, \dots, N \end{cases} \quad (2.86)$$

Où $G = z_i z_j K(x_i, x_j)$ c'est une matrice carrée symétrique définie positive. $\alpha^T = [\alpha_1, \dots, \alpha_N]$. Et I c'est un vecteur unitaire de taille N . Pour décider à quelle classe appartient une donnée x , il suffit de prendre le signe de la fonction de décision suivante :

$$f(x) = \text{sgn} \left(\sum_{i=1}^N z_i \alpha_i K(x_i, x) + b \right) \quad (2.87)$$

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

La valeur du biais b est calculée par l'utilisation de deux supports opposés x_a et x_b tels que $f(x_a)=1$ et $f(x_b)=-1$.

$$b = -\frac{1}{2} \sum_{i=1}^N z_i \alpha_i [k(x_a, x_i) - k(x_b, x_i)] \quad (2.88)$$

Les noyaux SVM les plus utilisés dans le domaine de classification sont :

- Noyau linéaire : $k(x_i, x_j) = \langle x_i, x_j \rangle$ avec $\phi(x_i) = x_i$
- Noyau polynomial : $k(x_i, x_j) = \langle x_i, x_j \rangle^p$ où p est le degré du polynôme. Ce noyau réalise implicitement un produit scalaire dans l'espace du descripteur correspondant à tous les produits à p dimensions.
- Noyau gaussien (RBF) : $k(x_i, x_j) = \exp \left(-\frac{\|x_i - x_j\|^2}{2\sigma^2} \right)$

Où σ est la variance, qui devient un paramètre de régulation. Ce hyper-paramètre permet le réglage de la largeur de la gaussienne. Si σ prend une valeur très grande, la similarité d'une observation par rapport à son entourage sera assez élevée, donc si $\sigma = 0$, l'observation ne sera similaire à aucune autre. En diminuant strictement la gaussienne, un modèle qui utilise ce type de noyau peut arriver à apprendre n'importe quel ensemble d'apprentissage sans erreur [KADRI 13].

- Noyau sigmoïde : $k(x_i, x_j) = \tanh(\langle x_i, x_j \rangle + 1)$.

2.4.1.2.2 SVM à marge souple

Le principe de la marge souple consiste à autoriser quelques erreurs de classification, sous la contrainte de maximiser la distance entre les vecteurs bien classés par rapport à l'hyperplan

optimal, et en même temps minimiser la distance des vecteurs mal classés par rapport à l'hyperplan [ZIANI 15].

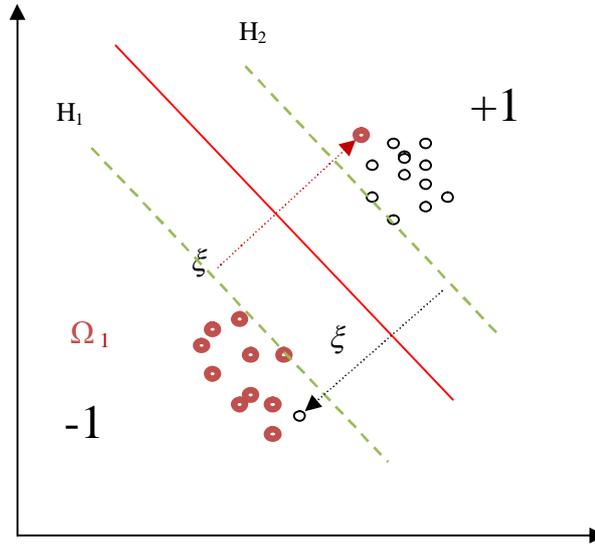


Figure 2.14 : Séparation non linéaire par marge souple.

On introduit des variables d'écart non négatif (Pénalité) ξ_i , le paramètre C (Cf. § 2.4.1.2.1) est un paramètre de régularisation qui régit la tolérance de mauvaise classification.

Après l'introduction d'un terme de pénalité, l'équation (2.74) devient:

$$\begin{cases} \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i & C \geq 0, \quad \xi \geq 0 \\ \forall i \quad z_i (\langle w, x_i \rangle + b) \geq 1 - \xi_i & i = 1, \dots, N \end{cases} \quad (2.89)$$

En introduisant les multiplicateurs de Lagrange α_i et u_i , le Lagrangien associé au nouveau problème d'optimisation devient:

$$L(w, b, \alpha, \xi, u) = \left[\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i (z_i \langle w, x_i \rangle + b) + \xi_i - 1 \right] - \sum_{i=1}^N u_i \xi_i \quad (2.90)$$

Le Lagrangien doit vérifier :

$$\frac{\partial L(w, b, \alpha, \xi, u)}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i z_i x_i \quad (2.91)$$

$$\frac{\partial L(w, b, \alpha, \xi, u)}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i z_i = 0 \quad (2.92)$$

$$\frac{\partial L(w, b, \alpha, \xi, u)}{\partial \xi} = 0 \Rightarrow \forall C - \alpha_i - u_i = 0 \quad (2.93)$$

En remplaçant les équations (2.91), (2.92) et (2.93) dans l'équation (2.90), on obtient le problème dual différent de celui du cas séparable :

$$\left\{ \begin{array}{l} \max_{\alpha} \left[\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j z_i z_j \langle x_i, x_j \rangle \right] \\ 0 \leq \alpha_i \leq C \quad i=1, \dots, N \\ \sum_{i=1}^N \alpha_i z_i = 0 \end{array} \right. \quad (2.94)$$

La seule différence entre SVM à marge souple et SVM linéaire c'est l'introduction d'une borne supérieure pour les paramètres duaux α_i (les α_i ne peuvent pas dépasser C) :

$$\left\{ \begin{array}{l} \alpha_i = 0 \Rightarrow u = C \Rightarrow \xi_i = 0 \quad x_i : \text{bien classé} \\ 0 < \alpha_i < C \Rightarrow u > 0 \Rightarrow \xi_i = 0 \Rightarrow z_i (\langle w \cdot x_i \rangle + b) = 1 \\ \alpha_i = C \Rightarrow u = 0 \Rightarrow \xi_i \geq 0 \Rightarrow z_i (\langle w \cdot x_i \rangle + b) = 1 - \xi_i \end{array} \right. \quad (2.95)$$

Les conditions de Karush-Kuhn-Tucker (KKT) présenté par l'équation (2.95), traduisent le fait que seulement les variables α_i des points situés sur la frontière de la marge $0 < \alpha_i < C$ ou à l'intérieur $\alpha_i = C$ sont les vecteurs supports du classifieur.

2.4.1.2.3 SVM multi classe

Dans cette section, en va présenter une synthèse des différentes techniques utilisées pour la classification multi-classe par SVM [HOOTHUYS 17], [ROCHA 14].

a) SVM Un Contre Tous

Le principe repose sur l'idée de construire plusieurs classificateurs (plusieurs hyperplans séparateurs).

La figure suivante illustre l'architecture d'un SVM un contre tous :

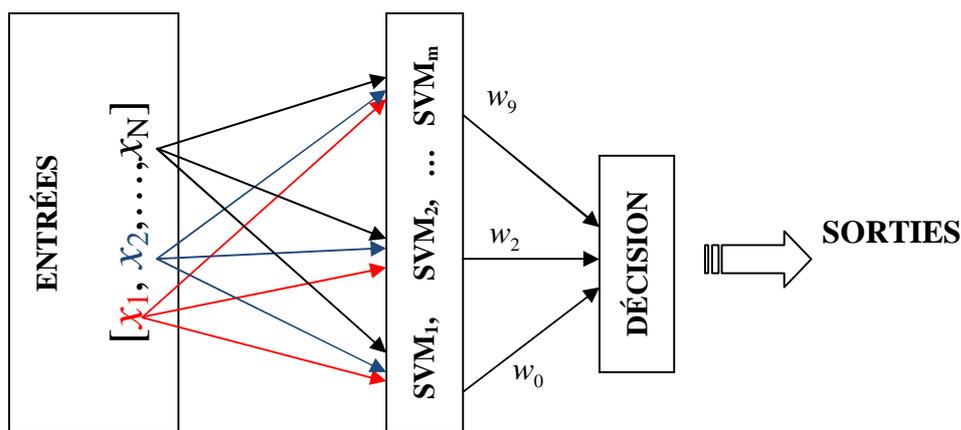


Figure 2.15 : SVM Un Contre Tous [YANG 07].

Durant la phase d'apprentissage, toutes les observations appartenant à la classe sont positives (+1), alors que toutes les autres observations n'appartenant pas à la classe sont considérée négatives (-1) [CHAIBI 14].

Durant la phase de test, les observations situées près des frontières de séparation des classes peuvent avoir plusieurs sorties positives parce que chaque classificateur est entraîné indépendamment d'une part et utilise différents vecteurs de supports d'autre part.

La décision d'affectation d'une observation à une classe donnée se fait à l'issue d'un vote majoritaire basé sur l'utilisation de la règle suivante : $\arg \max(\langle w_i, x \rangle + b_i)$.

La partie décision dans la figure 2.15, désigne le schéma de vote majoritaire utilisé pour désigner la classe d'appartenance.

b) SVM Un Contre Un

Cette méthode est proposée par [DIETTERICH 95], le but de telle approche consiste à résoudre des problèmes liés à la classification multi-classe.

Le principe d'un SVM (un Contre un) repose sur l'utilisation d'un classificateur pour chaque paire de classes, cela est synonyme à la construction de $(K.(K-1)/2)$ SVM binaires, dont les observations de la première classe sont positives (+1), tandis que les observations de la deuxième classe sont négatives (-1).

Cette technique utilise le vote majoritaire comme fonction de décision, où l'observation est affectée à la classe qui obtient le grand nombre de votes [LAOUITI 12].

2.5 Conclusion

Nous avons dans ce chapitre décrit deux approches pour la construction du système de diagnostic. La première approche utilise la reconnaissance de formes floue, Cette méthode repose sur deux étapes ; une étape de classification des données de simulation (apprentissage hors ligne), et une seconde étape de reconnaissance en ligne (temps réel) du mode de fonctionnement du moteur diesel (apprentissage en ligne). Après l'étude des différents algorithmes non supervisés de classification, précisément l'algorithme FCM et ses variantes, nous choisissons l'algorithme *c-moyennes possibiliste modifié* MPCM, au regard des avantages qu'il présente par rapport aux autres algorithmes. La deuxième étape de reconnaissance en ligne consiste à définir à quel mode de fonctionnement affecté une nouvelle observation recueillie sur le système à un instant donné. Pour achever à cette étape il est fondamental de s'appuyer sur les règles de décision ayant pour base les degrés d'appartenance. Notre choix est tombé sur la méthode de décision dite rapport d'appartenance qui présente plus de souplesse comparée aux autres règles. L'utilisation des règles de décision nous donne la possibilité de suivre l'évolution du mode de fonctionnement du système en temps réel.

La deuxième approche utilise les séparateurs à vaste marge (SVM), cette méthode repose sur la classification binaire par apprentissage supervisé, d'autre terme elle cherche à trouver l'hyper plan idéal qui sépare les données en maximisant la distance entre les deux classes. Dans cette section nous avons présenté les concepts de base de l'approche SVM. Nous avons commencé par une explication des différentes étapes utilisées pour la recherche d'un séparateur optimal dans le cas de données linéairement séparables et non linéairement séparables, Nous avons terminé le chapitre par une présentation de différentes approches utilisées pour le traitement des problèmes de classification multi-classe.

CHAPITRE III

Modélisation du Moteur Diesel

3.1 Introduction

Longtemps considérés comme polluants, les moteurs diesel sont aujourd'hui autant vus plus propres que les moteurs essences. Ces moteurs étaient appréciés pour leur robustesse, leur couple important et leur faible coût vis-à-vis de la consommation de carburant (le prix de l'essence était environ 50% plus élevé que celui du gasoil). Dans ces moteurs, le carburant s'auto-enflamme sous l'effet d'une compression très importante [LAURENT 09].

Malgré les avantages présentés par les moteurs diesel, leur forte pollution surtout en présence des défauts, nous oblige à trouver des solutions efficaces pour résoudre à ce grand problème.

Nous choisissons le moteur diesel comme système mécanique pour notre étude, dans le seul but de développer une stratégie de diagnostic qui va aider à prédire tout déséquilibre, afin de respecter les normes d'antipollution.

Dans ce chapitre nous avons essayé de rassembler les connaissances relatives au moteur diesel. Nous commençons par une description de la structure du moteur (§ 3.2). Ensuite une classification des différents types de moteur diesel (§3.3). Nous évoquons aussi le cycle de fonctionnement d'un moteur diesel à quatre temps (§3.4). Finalement dans ce chapitre, nous présentons les différents modèles d'un moteur diesel (§3.5) et les résultats de simulation de modèle (§3.6). On termine ce chapitre par une conclusion (§3.7).

3.2 Architecture d'un moteur diesel

3.2.1 Bloc moteur (Carter-cylindre)

Le bloc moteur est la partie la plus massive, il contient les cylindres et reçoit l'ensemble des organes du moteur (équipement d'injection, vilebrequin, ...). Afin de résister aux pressions élevées pendant la combustion le bloc moteur doit être robuste et étanche.

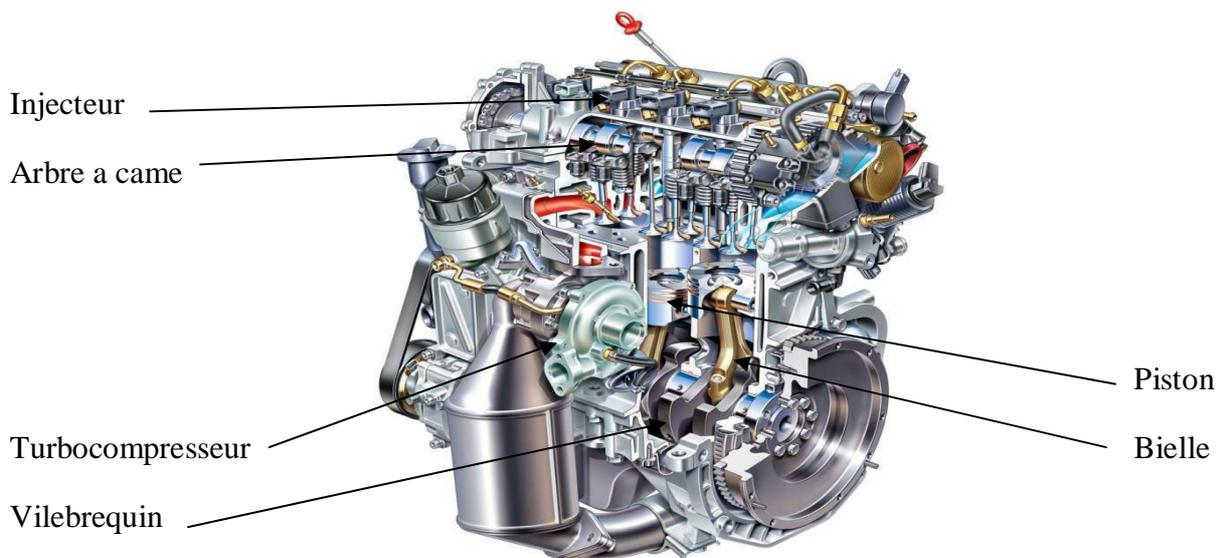


Figure 3.1 : Moteur diesel à injection directe [OLIVIER 04].

3.2.2 Cylindres

Comme son nom l'indique, un cylindre est un tube creux, sa surface a subi un traitement qui le rend résistant aux frottements, ainsi qu'aux températures élevées.

Les cylindres sont, soit alésés directement dans le bloc moteur, soit constitués par une chemise en aluminium insérée dans l'alésage. Les moteurs d'automobiles sont toujours poly-cylindriques (deux à douze cylindres). Les cylindres peuvent être disposés en ligne (voiture de tourisme), à plat ou en V (les gros moteurs).

3.2.3 Le piston

Le piston coulisse dans le cylindre selon un mouvement rectiligne de va-et-vient. C'est un élément essentiel puisque sa fonction consiste à transformer la pression qui s'exerce sur son sommet lors de la combustion en effort sur la bielle. La tête du piston peut être plate ou présenter un relief (généralement concave appelé le bol) [BENCHERIF 18].

3.2.4 La Bielle

La bielle est un élément intermédiaire qui permet la transmission des forces entre deux éléments animés de mouvements différents :

- Le mouvement rectiligne alternatif du piston.
- Le mouvement circulaire continu du vilebrequin.

Par la combinaison des mouvements rapides du piston et du vilebrequin, cet élément est soumis à de multiples contraintes : la **compression**, la **traction**, la **flexion**.

3.2.5 Le vilebrequin

Il est réalisé en acier allié, forgé ou matricé. L'arbre vilebrequin commande la distribution, la pompe d'injection, la pompe d'alimentation, la pompe à eau, le générateur et la pompe à huile.

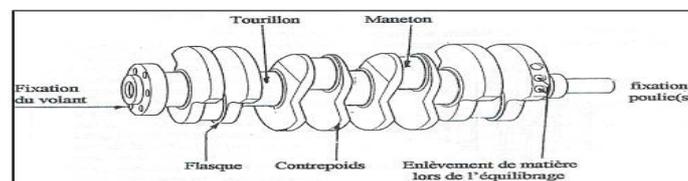


Figure 3.2 : Éléments d'un vilebrequin.

Avec la bielle il termine la transformation du mouvement rectiligne alternatif du piston en mouvement circulaire continu. Les contraintes subies par le vilebrequin sont des **torsions** provenant des efforts opposés du couple moteur et du couple résistant, **flexions**, **compressions**, **tractions**, **cisaillements**, Frottements au niveau des portées et les Vibrations

provenant de la masse du vilebrequin lancé à grande vitesse. Un vilebrequin doit posséder des qualités afin de résister aux efforts qui lui sont soumis :

- Bras de manivelle robuste.
- Géométrie indéformable.
- Équilibrage parfait.

3.2.6 L'arbre à cames

Il est chargé de commander la levée des soupapes et pendant une durée bien déterminée. Le mouvement de l'arbre à cames doit être lié de façon invariable à celui du vilebrequin. La synchronisation de l'arbre à cames et de vilebrequin s'appelle « **le calage de la distribution** ». Ce calage, très important car il assure le respect de l'épure de distribution définie par le constructeur, s'effectue grâce à des repères marqués à l'usinage [CEDRA 90].

3.2.7 Le système d'injection

C'est un organe essentiel car le moteur Diesel nécessite un dosage rigoureux du combustible. La pompe d'injection assure l'alimentation des injecteurs, ces derniers sont chargés de laisser entrer la quantité adéquate de carburant aux instants désirés.

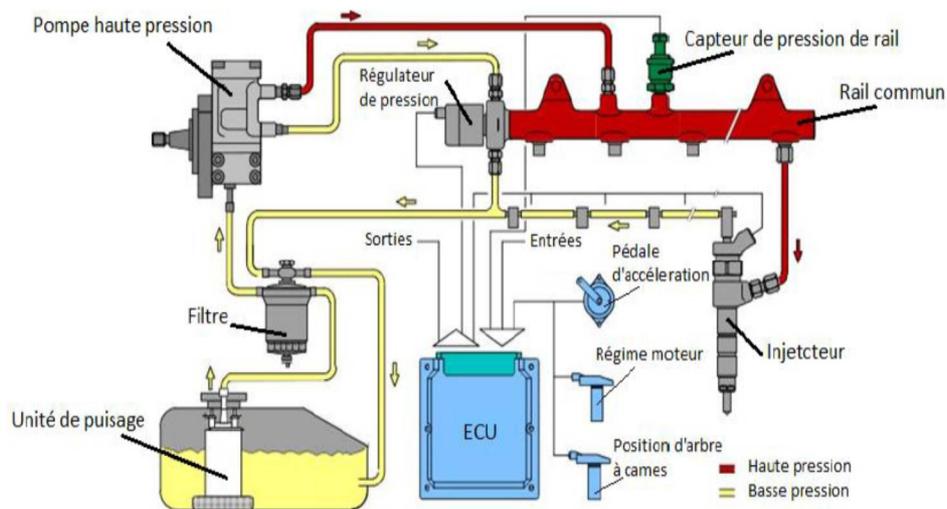


Figure 3.3 : Système d'injection directe diesel à rampe commune [BOSCH 08].

Le système d'injection se divise en trois parties : la basse pression, la haute pression et la gestion électronique.

Un injecteur se compose d'une soupape d'injection ou aiguille et d'un logement appelé corps ou buse.

3.2.8 Différents capteurs d'un moteur diesel

Voilà les différents capteurs que l'on peut trouver sur un véhicule moderne

3.2.8.1 Capteur d'arbre à cames

Il est situé sur la culasse, son rôle c'est la détermination de la position du pignon pour indexer celle de l'arbre à cames.

Les données provenant de ce capteur sont nécessaires pour des fonctions telles que le lancement de l'injection sur des moteurs à injection séquentielle, le signal du régulateur de pression de la valve électromagnétique de la pompe à injection et le contrôle de fin de cours d'un cylindre particulier.



Figure 3.4 : capteur d'arbre à cames.

3.2.8.2 Capteur de vilebrequin

Il est du type inductif, il est situé sur le carter d'embrayage. Ce capteur fournit des informations sur la position du vilebrequin que le calculateur d'injection utilise pour calculer le régime moteur. Ces données permettent de déterminer l'injection de carburant la plus économique et le moment de l'amorçage.



Figure 3.5: capteur de vilebrequin.

3.2.8.3 Capteur de température de carburant

Il est situé sur la pompe haute pression. Il permet au calculateur d'apporter des corrections sur le débit de carburant injecté.



Figure 3.6 : Capteur de température de carburant.

3.2.8.3 Capteurs de température d'air d'admission

Il y a deux capteurs (sonde de température d'air amont et d'air avale) qui mesurent la température de l'air admis dans le moteur. Avec les deux informations de température combinée à la valeur de pression de suralimentation le calculateur détermine la masse d'air admise



Figure 3.7 : Capteur de température d'air d'admission.

3.2.8.5 Capteur de vitesse du véhicule

Le capteur est situé en sortie boîte de vitesses. Il permet au calculateur de connaître différentes configurations d'utilisation du véhicule :

- Arrêt ou roulant ;
- En décélération ou en accélération ;
- Le rapport de boîte de vitesses engagé ;

3.2.8.6 Capteur de phase

Ce capteur est du type à effet Hall (signal carré).

Il est situé dans la culasse, au niveau de l'arbre à cames. Il permet au calculateur de connaître la position du premier cylindre. Certains constructeurs ont prévu un réglage de l'entrefer.



Figure 3.8 : Capteur de phase.

3.3 Différents types de moteur Diesel

Dans le monde actuel il existe trois types de moteurs Diesel

3.3.1 Moteurs à injection directs

- L'injecteur débouche directement dans la chambre principale.
- La pression d'injection est élevée : 200 à 400 bars.
- Le sommet du piston est plat, ou creux lorsque l'on désire donner un mouvement de turbulence.

L'injection directe est apparue en grandes séries tout d'abord sur les moteurs diesel. Elle est aujourd'hui très répandue sur ce type de motorisation.

Les systèmes d'injection directe injectent le carburant aux endroits où la combustion aura une efficacité maximale. Ils utilisent l'électronique pour piloter la quantité de carburant introduite dans la chambre de combustion.

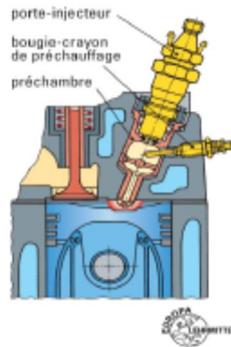


Figure 3.9 : Injection directe.

L'injecteur du type à "téton" est placé sur la culasse et dans une cavité non refroidie appelée préchambre. Elle communique avec le cylindre par un orifice à passage restreint. Le combustible injecté dans la préchambre commence à brûler du fait de l'environnement chaud. De ce fait la précombustion ayant commencé, une montée en pression se produit et expulse le mélange dans le cylindre où la combustion a lieu. Ce système permet un fonctionnement moins bruyant. Par contre, pour le démarrage à froid, l'apport d'une source de chaleur est obligatoire.

3.3.2 Moteurs à injection indirects

Les **moteurs à injection indirecte** sont actuellement largement majoritaires pour les applications aux véhicules de tourisme, du fait d'une puissance massique plus élevée, d'un système d'injection moins coûteux et de bonnes performances sur une large plage de régime. La consommation plus élevée les a progressivement fait disparaître pour les applications industrielles et les poids lourds.

Les systèmes d'injection indirecte injectent le carburant dans une **préchambre** reliée au cylindre par un canal de transfert (chambre de turbulence Ricardo) ou plusieurs orifices de communication (chambre de précombustion Mercedes). Cela crée une aérodynamique puissante qui active le mélange air-carburant sur une large plage de régime, avec un injecteur à un seul trou (injecteur à téton), sans nécessiter de très hautes pressions d'injection (400 à 500 bars).

Mais cette aérodynamique puissante présentait aussi des défauts liés pour beaucoup à l'accroissement du coefficient d'échange thermique aux parois :

- difficultés de démarrage à froid ;
- rendement moins bon ;
- nécessité d'un radiateur de refroidissement plus volumineux ;
- limitation des performances spécifiques, à cause de l'accroissement des contraintes thermomécaniques dans les matériaux des pistons et de la culasse.

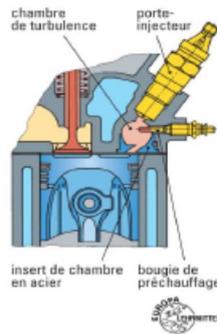


Figure 3.10 : Injection indirecte.

3.3.3 Moteurs à injection haute pression à rampe commune

C'est une version moderne du moteur diesel à injection directe. Contrairement aux systèmes à pompe distributrice, la pression d'injection est indépendante de la vitesse de rotation du moteur et demeure constante pendant la phase d'injection.

Le pilotage de l'injection par un calculateur électronique laisse une grande latitude de programmation aux motoristes.

La quantité de combustible injecté peut être fractionnée pour réaliser un pré injection, ce qui permet de réduire les bruits de combustion et la formation de *Nox*.

Cette faible quantité de carburant (1 à 4 mm³) permet de préparer, par une augmentation de la température et de la pression dans la chambre de combustion, l'inflammation du combustible lors de l'injection principale.

Les véhicules équipés de filtres à particules présentent une phase de nettoyage qui nécessite une post-injection, rendue possible grâce au pilotage des injecteurs par un calculateur électronique. Le pilotage par une électronique numérique de tous les paramètres de l'injection permet d'optimiser le fonctionnement du moteur [LAURENT 09].

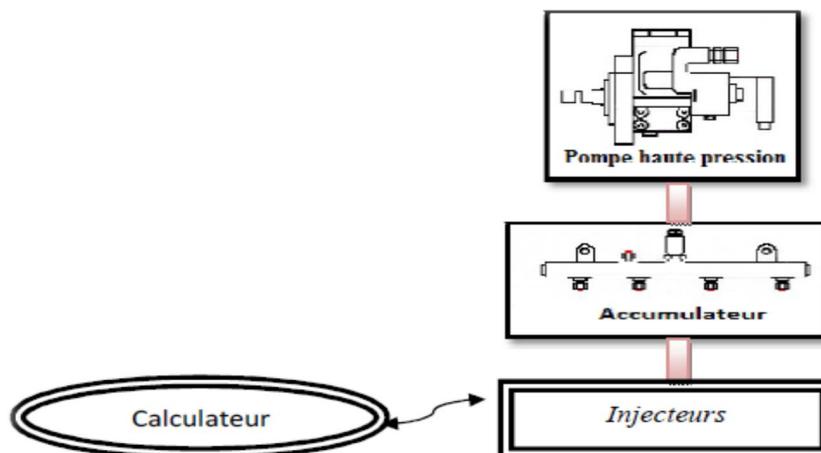


Figure 3.11 : Système d'injection haute pression à rampe commune.

3.4 Fonctionnement d'un moteur Diesel

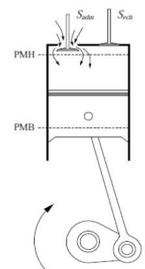
Quel que soit le type de moteur diesel le fonctionnement c'est le même, au début de chaque cycle le cylindre est rempli d'air frais. Cet air est comprimé de façon à obtenir une température supérieure à la température d'auto-inflammation du combustible.

Quand le piston est au PMH (point mort haut), le combustible liquide est injecté avec une pression suffisante pour qu'il soit très finement pulvérisé. Au contact de l'air chaud comprimé et lorsque les conditions de températures et de temps de séjour sont atteintes, le carburant s'enflamme, lors de la phase d'échappement, la soupape d'échappement ($S_{éch}$) s'ouvre pour laisser les gaz brûlés s'évacuer dans le collecteur d'échappement.

3.4.1 Le cycle à 4 temps

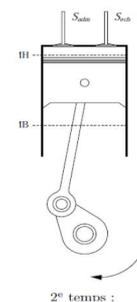
1^{ère} temps : Admission

- Piston au PMH
- Soupape d'admission S_{adm} ouverte,
- Soupape d'échappement $S_{éch}$ est fermée
- Le piston descend du PMH vers PMB.
- Le volume dans le cylindre augmente.
- La pression dans le cylindre diminue.
- La soupape d'admission S_{adm} ferme quand le piston est au PMB.



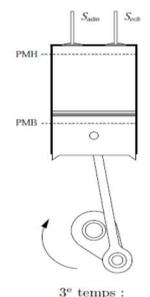
2^{ème} temps : Compression

- Les deux soupapes (S_{adm} et $S_{éch}$) sont fermées
- Le volume de la chambre de combustion diminue à mesure que le piston remonte du PMB vers le PMH
- La pression dans le cylindre augmente
- La température d'air admis augmente



3^{ème} temps : Détente

- Les deux soupapes sont fermées
- Quand le piston est au PMH, le combustible liquide est injecté sous forme fines gouttelettes
- Au contact de l'air chaud comprimé le carburant s'enflamme
- La pression des gaz dans le cylindre augmente
- Le piston est repoussé vers le bas jusqu'au PMB



4^{ème} temps : Echappement

- Le piston est au PMB.
- Le piston remonte du PMB vers le PMH.
- La soupape d'échappement s'ouvre.
- Les gaz brûlés sont évacués.

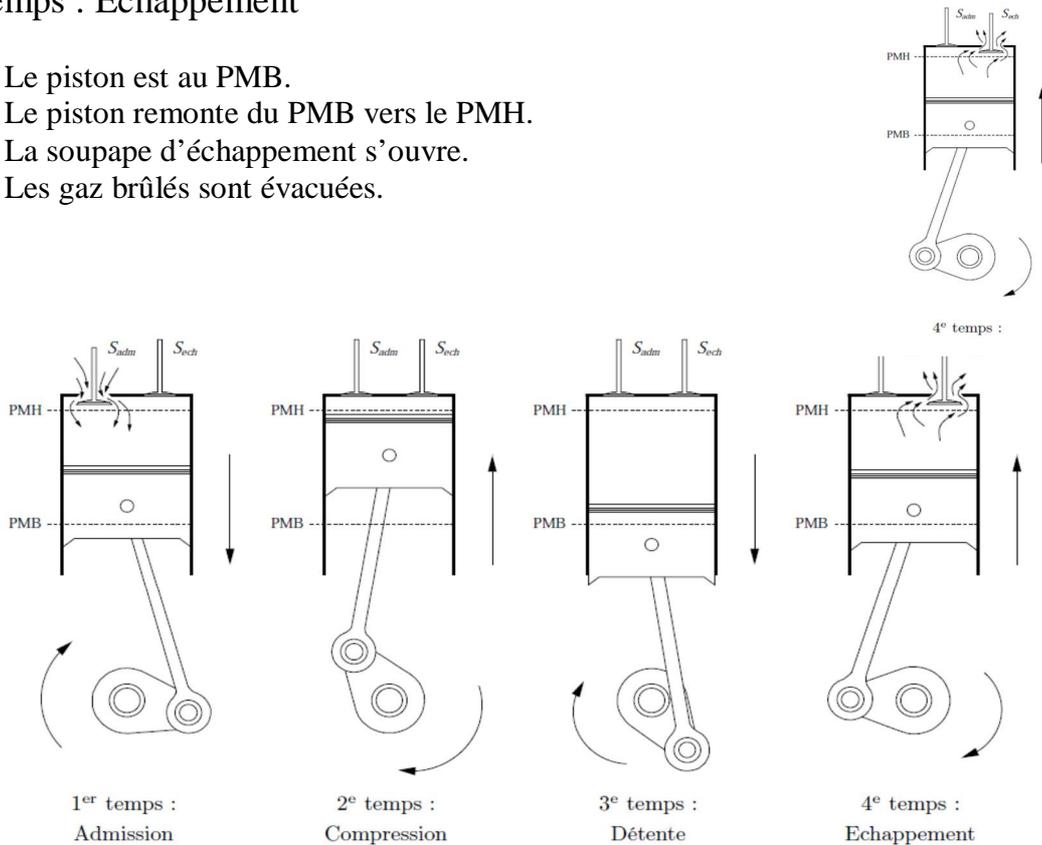


Figure 3.12 : Décomposition du cycle à quatre temps du moteur Diesel.

On représente aussi ce cycle dans le plan « Volume/Pression » (figure 3.13). Ce cycle est la combinaison de deux cycles classiques dans lesquels une partie du combustible brûle à volume constant et l'autre partie à pression constante [PEYSSON 05].

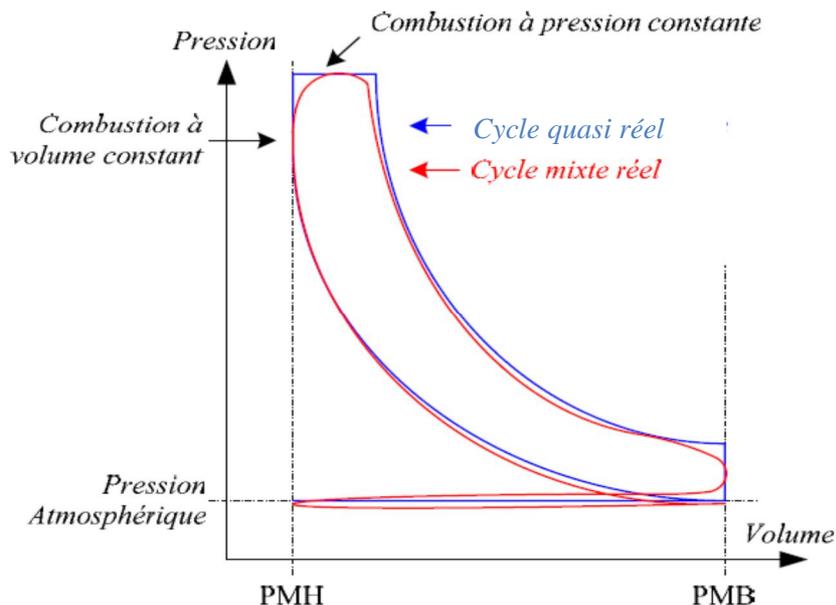


Figure 3.13 : Cycle d'un moteur Diesel.

3.4.2 Classification

3.4.2.1 Combustion

Pour générer un maximum d'énergie, avec un minimum de consommation et de rejets polluants, et un maximum de confort de conduite pour l'utilisateur, la combustion d'un moteur diesel doit être la plus complète possible.

Au fil des années, d'importantes modifications ont été apportées aux formes de chambre de combustion, aux conduits d'admission, aux matériaux employés mais aussi au processus d'injection. La chambre de combustion est d'une importance capitale pour le fonctionnement et le rendement du moteur. Plusieurs technologies sont donc employées. Il existe deux grandes familles de types de combustion [PEYSSON 05] :

- l'injection indirecte : la chambre de combustion est divisée, l'injecteur pulvérise le carburant dans une chambre auxiliaire où a lieu le début de combustion. Les gaz rejoignent ensuite la chambre principale par un canal de liaison.
- l'injection directe : la chambre de combustion n'est pas fractionnée, l'injecteur pulvérise directement le carburant dans la chambre principale du cylindre. La classe des moteurs à injection directe, peut-être divisée en deux sous-classes qui sont l'injection directe basse pression et l'injection directe haute pression aussi appelée « Common Rail ». En effet le carburant s'enflamme d'autant plus vite qu'il est injecté avec violence.

Dans une injection du type Common Rail, la pression en sortie de la pompe est indépendante de la vitesse de rotation du moteur. Des pressions jusqu'à 2000 bars peuvent être obtenues (seulement 250 à 450 bars pour une pompe classique). De plus, tous les injecteurs sont reliés au même accumulateur de pression (Rail) où une régulation de pression est implantée. Ce type d'injection permet une combustion optimisée et donc moins de pollution.

3.4.2.2 Suralimentation

Quelles que soient leurs applications, les moteurs thermiques ont les mêmes impératifs de progrès à savoir une puissance massive élevée avec une consommation minimale, une meilleure fiabilité, une réduction des émissions polluantes et une réduction de l'encombrement. La puissance d'un moteur à combustion interne est pratiquement égale au produit de la pression moyenne effective par la vitesse de rotation du moteur. Cette pression était liée au taux de remplissage en air du moteur. À faible régime, le volume d'air aspiré est pratiquement la cylindrée alors que pour une vitesse correspondant à la puissance maximale, ce volume correspond à environ 60 % de la cylindrée. Rendre un moteur plus puissant à une même vitesse de rotation est donc possible en favorisant le taux en air des cylindres. Plusieurs solutions ont été apportées :

- amélioration du remplissage au temps « aspiration »,
- multiplication du nombre des soupapes,
- modification de la géométrie des conduits d'admission,
- pré-compression de l'air ou « suralimentation » : l'air dans les cylindres est à une pression supérieure à la pression atmosphérique [PEYSSON 05].

3.4.3 Les émissions polluantes

La combustion du gazole dans un moteur Diesel génère un certain nombre de résidus. Le terme d'émissions polluantes désigne les polluants présents dans les gaz d'échappement du moteur. On y recense principalement :

Du monoxyde de carbone (CO) qui est un gaz extrêmement toxique avec une courte durée de vie. Des hydrocarbures imbrûlés, HC, provenant aussi d'une combustion incomplète.

L'oxyde d'azote, NO, dont la concentration dépend de la température de combustion.

Dans l'environnement NO et CO s'oxydent en NO₂ et CO₂ et sont donc susceptibles de réagir avec les HC imbrûlés pour former un brouillard, appelé opacité, sous l'action des ultraviolets.

L'ozone O₃ est un des principaux constituants de l'opacité. Le CO₂ n'est pas nocif et n'a pas d'effet à court terme mais c'est un gaz à effet de serre.

En résumé, les gaz d'échappement sont constitués de molécules de CO-CO₂, NO-NO₂ et HC que l'on note CO_x, NO_x et HC.

Pour limiter les émissions polluantes, l'Europe a mis en place depuis 1993, des normes Euro qui limitent la concentration en g.km⁻¹ des voitures équipées de moteur diesel.

Le tableau ci-dessous montre l'évolution de ses différentes concentrations depuis la norme EURO 1 à la norme actuelle EURO 6.

| | Année | CO | HC+NO _x | NO _x | Particules |
|---------------|-------|------|--------------------|-----------------|------------|
| EURO 1 | 1993 | 2,72 | 0,97 | - | 0,14 |
| EURO 2 | 1996 | 1 | 0,90 | - | 0,10 |
| EURO 3 | 2000 | 0,64 | 0,56 | 0,50 | 0,05 |
| EURO 4 | 2001 | 0,5 | 0,30 | 0,25 | 0,025 |
| EURO 5 | 2011 | 0,5 | 0,23 | 0,18 | 0,005 |
| EURO 6 | 2015 | 0,5 | 0,17 | 0,08 | 0,0045 |

Tableau 3.1 : Norme EURO Moteur Diesel.

Les solutions proposées pour réduire la production de polluants passent par :

- un système d'injection performant ;
- la mise en œuvre d'un catalyseur d'oxydation ;
- un système de recyclage des gaz d'échappement ;
- un filtre à particules.

3.5 Modélisation d'un moteur diesel

Dans cette partie, nous présentons un ensemble de modèles du moteur diesel avec et sans défaut à partir de la synthèse des modèles simplifiés présentés notamment dans les travaux [MOUSSA NAHIM 16], [NOHRA 09], [PEYSSON 05], [NOURA 06] et [YOUNES 93]. Cet ensemble comprend : le modèle de l'injection et de la compression avec et sans défaut, le modèle d'admission avec et sans défaut, le modèle du bloc moteur sans défaut et le modèle des émissions polluantes. Sachant que le système est complexe, les défauts d'admission, de compression et d'injection influent sur le fonctionnement du moteur et sur les émissions polluantes.

L'objectif de la construction de ce modèle est de le rendre le plus simple possible en gardant son aptitude à représenter fidèlement le comportement d'un moteur diesel à vide. Ce modèle n'inclut donc pas les technologies de suralimentation à géométrie variable et de recirculation des gaz.

3.5.1 Modèle d'injection

Le modèle d'injection consiste à prédire le débit de carburant injecté en fonction de la position d'accélération x_p et de la vitesse de rotation ω du moteur.

Il intègre une régulation du rapport $\Delta m_f / \omega$. Lorsque le conducteur accélère, il impose une valeur d'équilibre au rapport $\Delta m_f / \omega$.

Pour une position x_p constante le débit de carburant ainsi que la vitesse augmentent tant que le rapport n'atteint pas sa valeur de consigne (valeur d'accélération).

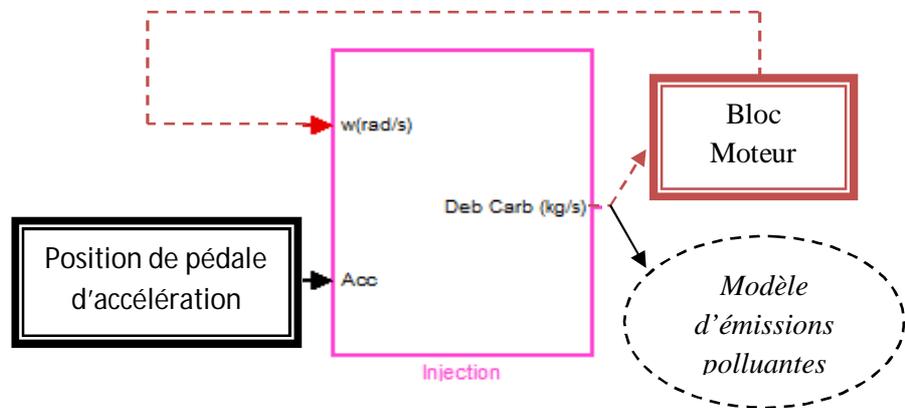


Figure 3.14 : structure du sous modèle d'injection.

Le modèle est représenté par les deux équations suivantes :

$$m_f = i_0 + \Delta m_f \quad (3.1)$$

$$\Delta m_f = \omega (i_1 + i_2 \times x_p + i_3 \times x_p^2 + i_4 \times \omega) \quad (3.2)$$

3.5.1.1 Modèle de défaut d'injection

Ce défaut traduit une diminution de l'efficacité des injecteurs (injecteurs grippés ou encrassés), et provoque une baisse de puissance de ces derniers, le débit du carburant injecté sera donc plus faible que prévu. L'équation de ce modèle est la suivante :

$$m_{fd} = (1 - k) \times m_f \quad (3.3)$$

3.5.2 Modèle d'admission

Le modèle d'admission dépend du débit soufflé par le compresseur et des débits d'air aspiré par le moteur.

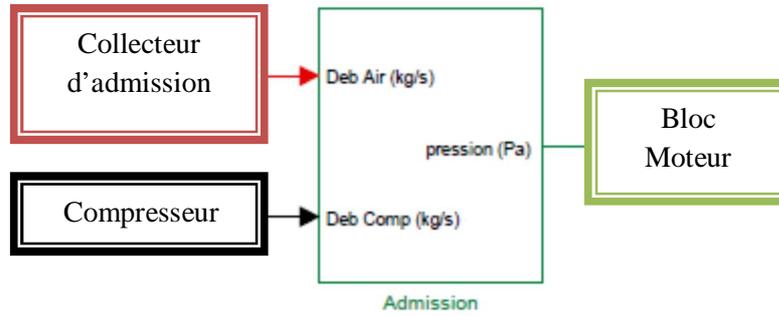


Figure 3.15 : Structure du sous modèle d'admission.

La pression d'admission p_a est calculée par la loi des gaz parfaits :

$$p_a = \frac{rT_a M_a}{V_a} \quad (3.4)$$

Dans notre étude on suppose que la température d'admission T_a est constante.

La variation de la masse d'air entrant dans le collecteur d'admission est donnée par :

$$\frac{dM_a}{dt} = m_c - m_{cyl} \quad (3.5)$$

Donc la variation de la pression d'admission est donnée par :

$$\frac{dp_a}{dt} = \frac{rT_a}{V_a} (m_c - m_{cyl}) \quad (3.6)$$

Le débit de sortie du compresseur m_c , est représenté par une relation proportionnelle au régime moteur.

$$m_c = c_m \times \omega \quad (3.7)$$

3.5.2.1 Modèle d'admission avec défaut de fuite dans le collecteur d'admission

La fuite est modélisée par un trou rond de diamètre d au niveau de l'admission, l'équation (3.6) devient :

$$\frac{dp_{ad}}{dt} = \frac{rT_a}{V_a} (m_c - m_{cyl} - m_{fuite}) \quad (3.8)$$

Le débit de fuite m_{fuite} est donné par la relation d'écoulement de Saint-Venant [PEYSSON05]:

$$m_{fuite} = \left(\pi \frac{d}{2} \right)^2 \frac{p_a}{\sqrt{rT_a}} \sqrt{\frac{2C_p}{r}} \sqrt{1 - \left(\frac{P_{atm}}{p_a} \right)^{\frac{\gamma-1}{\gamma}}} \quad (3.9)$$

3.5.2.1 Modèle d'admission avec défaut des soupapes d'admissions

Ce défaut apparait lorsqu'il y a une diminution de l'efficacité des soupapes d'admission d'ordre $k = 20\%$ (une accumulation d'impureté peut gêner l'ouverture d'une soupape). Le débit d'air sortant de l'admission va être plus faible que le débit entrant. On le modélise par l'équation suivante :

$$m_{cyl} = (1 - k) \times m_{cyl} \quad (3.10)$$

La pression devient :

$$\frac{dp_{ad}}{dt} = \frac{rT_a}{V_a} (m_c - m_{cyl} + km_{cyl}) \quad (3.11)$$

3.5.2.2 Modèle d'admission avec défaut de compression

En fonctionnement, les ailettes du turbo compresseur peuvent s'encrasser jusqu'à casser, le compresseur perd donc de son efficacité. Lors du fonctionnement avec défaut, le débit de sortie du compresseur va donc chuter, l'équation de ce modèle est comme suit [NOURA 06]:

$$m_{cd} = (1 - k) \times m_c \quad (3.12)$$

L'équation (3.6) devient :

$$\frac{dp_{ad}}{dt} = \frac{rT_a}{V_a} ((1 - k) m_c - m_{cyl}) \quad (3.13)$$

3.5.3 Modèle du bloc moteur (solides en mouvement)

Le modèle du bloc moteur doit prendre en considération les solides en mouvement, la puissance fournie par le moteur et les puissances résistantes (frottement des pièces en mouvement, résistance de conditions de conduite) [YOUNES 06], [YOUNES 93].

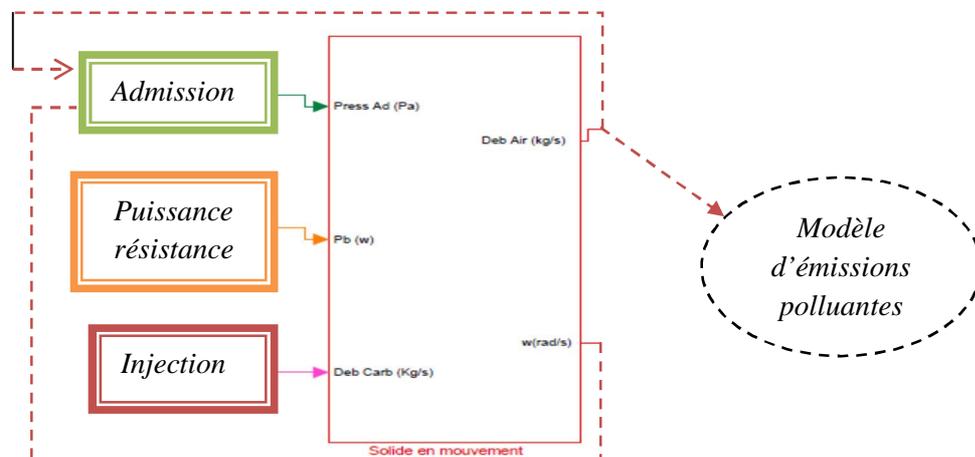


Figure 3.16 : Structure du sous modèle du bloc moteur.

Ce modèle est modélisé par l'équation de conservation d'énergie suivante :

$$\frac{d}{dt} \left[\frac{1}{2} J(\theta) \omega^2 \right] = P_i - P_b \quad (3.14)$$

L'équation de conservation d'énergie nous permet d'exprimer le régime moteur en fonction de la puissance indiquée et la puissance résistante, l'évolution de régime moteur est donc :

$$\frac{d\omega}{dt} = \frac{1}{J\omega} \left(P_i - P_b - \frac{1}{2} \frac{\omega^3}{J} \Delta \right) \quad (3.15)$$

La puissance résistante P_b , et la puissance indiquée P_i fournie par le moteur sont exprimée par les deux équations suivantes :

$$P_b = C_r \times \omega \quad (3.16)$$

Dans notre étude, le couple de freinage C_r ne représente que la résistance des parties en mouvement du moteur.

$$P_i = p_{ci} \times \eta_i \times m_f \quad (3.17)$$

Avec m_f est le débit de carburant, η_i étant le rendement du bloc moteur, modélisé par l'équation (3.18) :

$$\eta_i = a_\lambda + b_\lambda \times \lambda + c_\lambda \times \lambda^2 \quad (3.18)$$

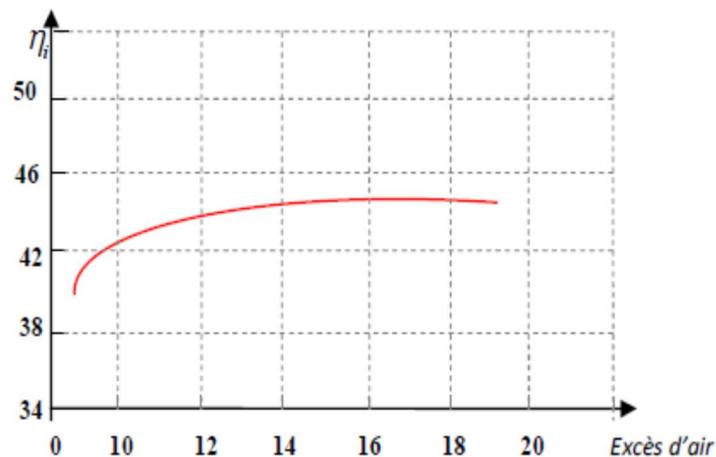


Figure 4.17 : Courbe du rendement indiqué en fonction de l'excès d'air.

L'excès d'air λ présente le rapport entre le débit d'air aspiré par les cylindres m_{cyl} et le débit du carburant m_f .

$$\lambda = \frac{m_{cyl}}{m_f} \quad (3.19)$$

Avec :

$$m_{cyl} = \frac{p_a \times \omega}{T_a} \times \frac{V_{cy} \times (\alpha_0 + \alpha_1 \times \omega + \alpha_2 \times \omega^2)}{4\pi} \quad (3.20)$$

3.5.4 Modèle des émissions polluantes

Le taux de fumée noir dans les gaz d'échappement O_p est exprimé en fonction du régime moteur, du débit de carburant et du débit d'air entrant dans les cylindres.

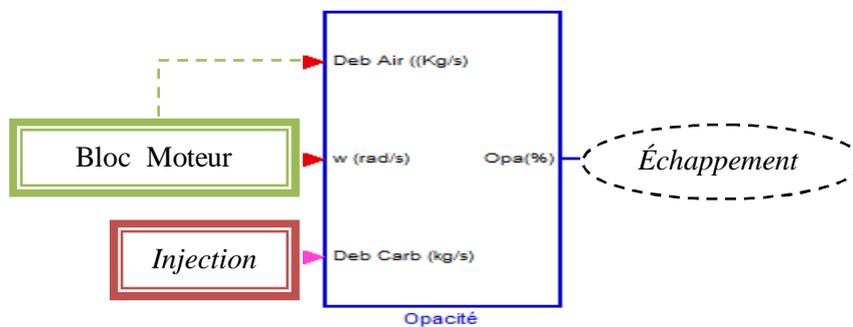


Figure 3.18 : Structure du sous modèle d'émissions polluantes.

L'équation de ce modèle est la suivante :

$$O_p = o_1 \times \omega \left(\frac{m_{cyl}}{m_f} \right)^{-o_2} \quad (3.21)$$

3.6 Simulation de modèle sans et avec défaut

Dans cette partie nous présentons l'architecture du modèle de moteur diesel sans défaut et l'architecture du modèle de moteur diesel avec défauts, ensuite nous présentons les résultats de la simulation qui montre l'évolution des différentes grandeurs.

3.6.1 Modèle moteur diesel sous l'interface Simulink de Matlab

Nous avons utilisé Matlab/simulink pour construire et simuler les différents modèles précédemment présentés.

La figure 3.19 illustre le modèle d'un moteur diesel sans défaut sous l'interface Simulink de Matlab, le modèle est composé de plusieurs sous modèles (modèle d'admission, modèle d'injection, modèle de compresseur, modèle du bloc moteur et modèle des émissions polluantes).

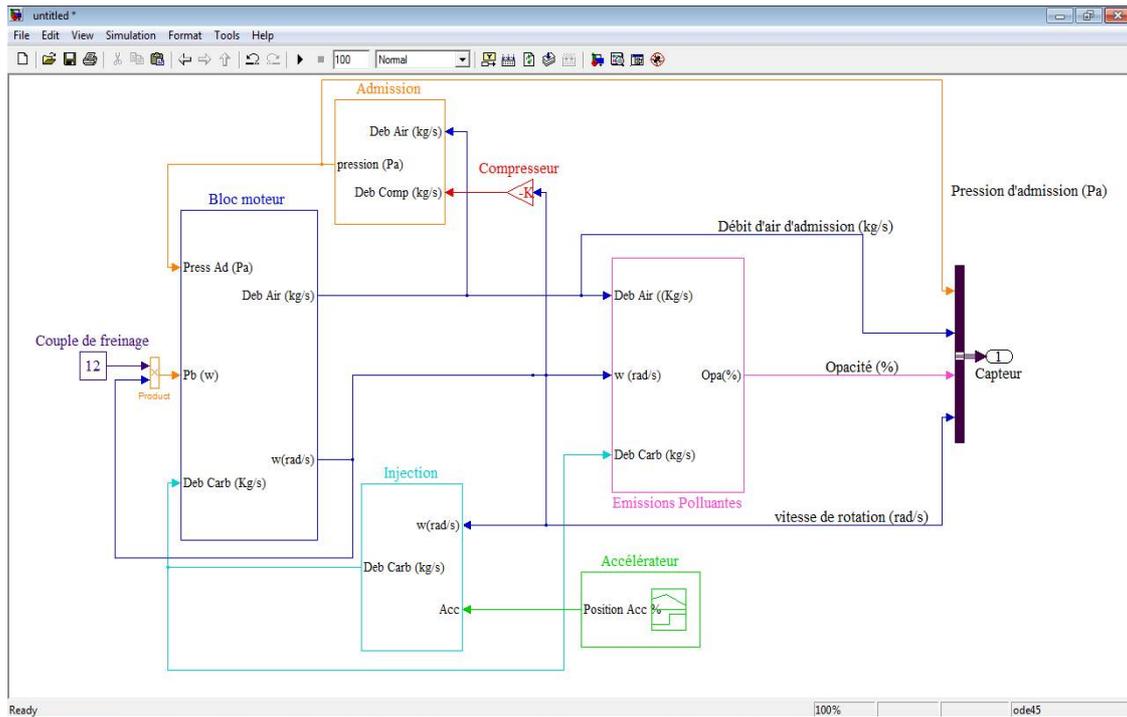


Figure 3.19 : Architecture d'un moteur diesel sans défaut dans l'interface *Simulink* de *Matlab*.

Le modèle de moteur diesel avec les différents défauts cités précédemment est présenté sous *Simulink* via la figure 3.20.

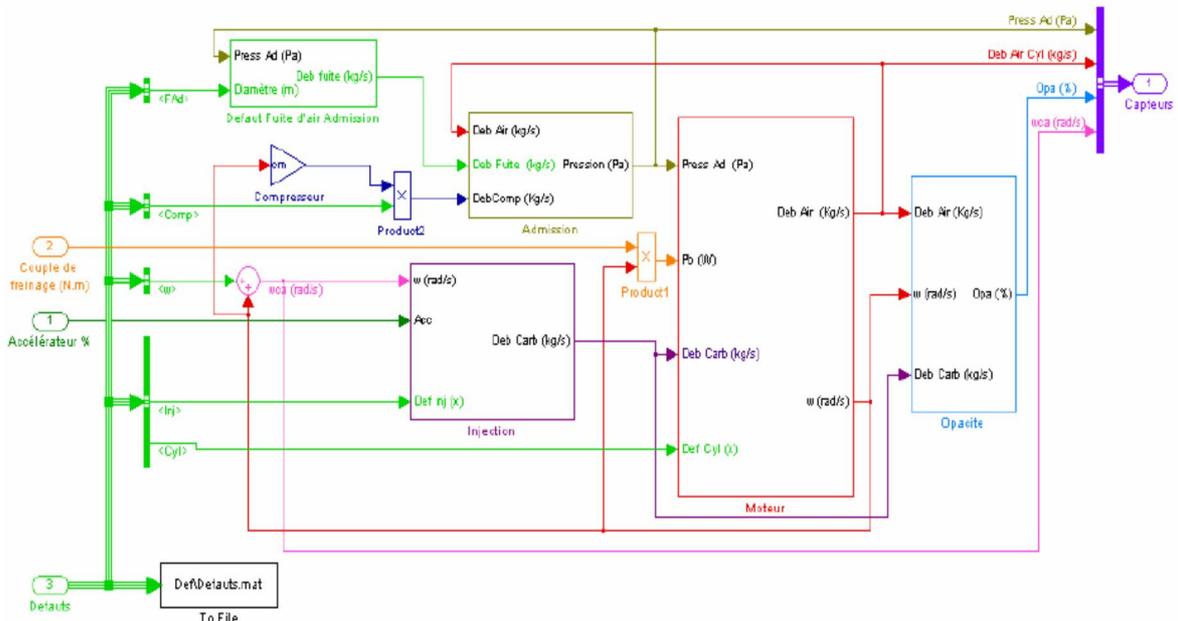


Figure 3.20 : Architecture d'un moteur diesel avec des défauts dans l'interface *Simulink* de *Matlab*.

La simulation dure 100s, les figures 3.21, 3.22 et 3.23 présentent respectivement l'évolution de la vitesse de rotation sans défaut et lors de l'apparition des défauts, l'évolution de la pression d'admission sans défaut et en présence des défauts et l'évolution des émissions polluantes sans défaut et avec défauts.

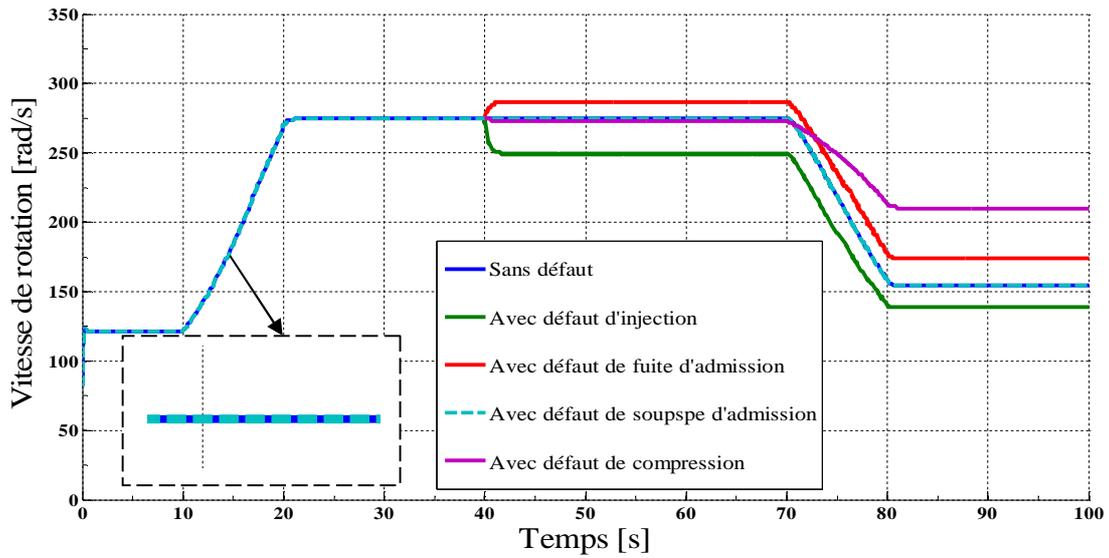


Figure 3.21 Influence des défauts sur la vitesse de rotation

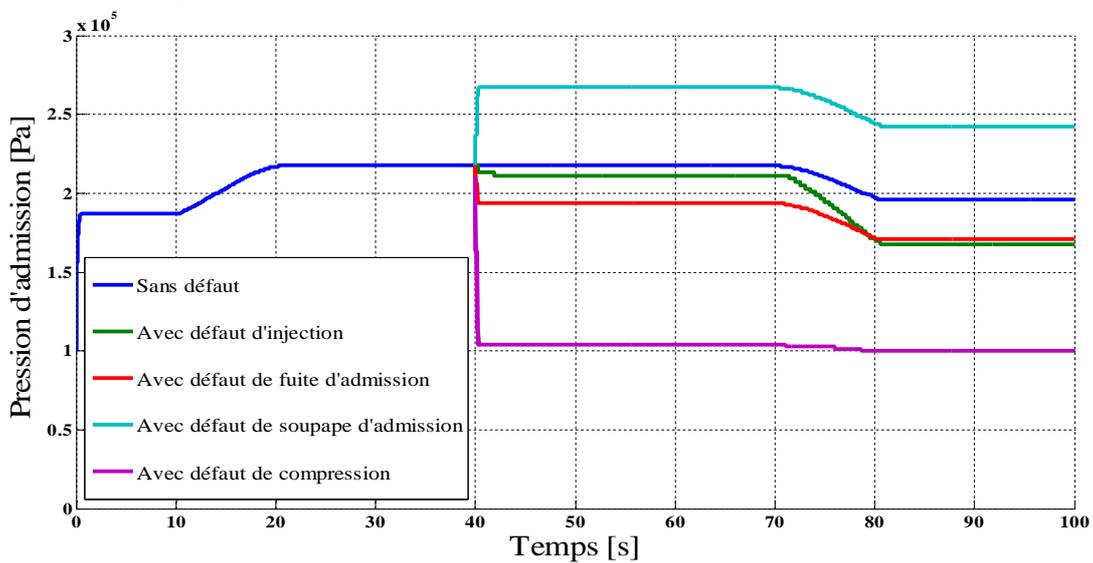


Figure 3.22 : Influence des défauts sur la pression d'admission

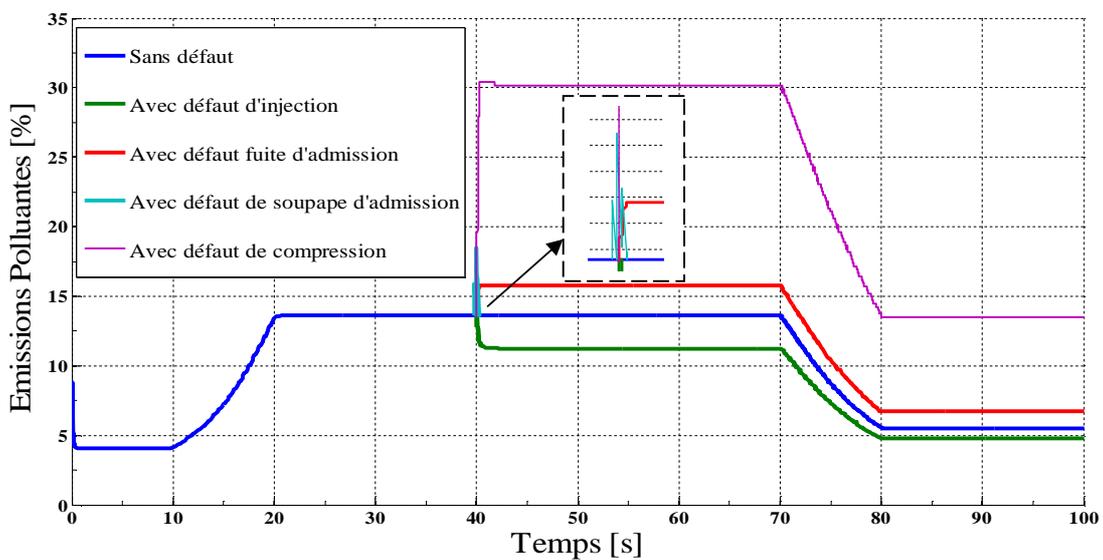


Figure 3.23 Influence des défauts sur les émissions Polluantes

La baisse de puissance et d'efficacité des injecteurs cause une diminution du carburant injecté, par rapport au débit nominal, le débit devient plus faible, cette baisse de quantité du carburant injecté fait que la vitesse de rotation (Fig.3.21) va diminuer ainsi que le débit d'air admis et le débit de compression lors de l'apparition de défaut ($t=40s$). Les émissions polluantes (Fig3.23) sont plus faibles que prévus. La pression d'admission diminue avec une très faible variation (Fig3.22) car les débits d'air aspirés par les cylindres et le débit à la sortie du compresseur restent dans le même ordre de grandeur.

La fuite d'admission agit directement sur les débits d'air aspirés par les cylindres, donc lors de l'apparition de défaut, la pression d'admission va chuter (Fig3.22). Le débit du carburant augmente ce qui entraîne une augmentation de la vitesse de rotation (Cf. Annexe1). Le mélange air carburant est donc déséquilibré, à cet effet les émissions des gaz sortants vont augmenter (Fig3.23) courbe en rouge.

La diminution de l'efficacité des soupapes d'admission d'ordre $k = 20\%$, entraîne une diminution d'air aspiré par les cylindres (équation 3.10). À cet effet, la pression d'admission va augmenter (équation 3.11) et le débit d'air aspiré revient à sa valeur nominale. La vitesse de rotation (Fig3.21) ne varie pas et on observe un pic d'émissions des gaz polluants lorsque le défaut apparaît.

Un défaut de compression entraîne une chute de pression d'admission (équation 3.12), et cette chute de pression (équation 3.13) fait varier la vitesse de rotation (Fig3.21), et la variation de vitesse va causer une augmentation des émissions polluantes (Fig3.23).

3.7 Conclusion

Nous avons présenté dans ce chapitre, une synthèse bibliographique, montrant un état de l'art des moteurs diesel.

Un modèle simplifié d'un moteur diesel a été présenté, ainsi que les modèles des défauts pouvant l'affecter. Par la suite une simulation sous Matlab/Simulink des différents modèles présentés précédemment à permet la bonne étude des multiples influences des défauts sur le fonctionnement de moteur diesel.

CHAPITRE IV

Résultats de classification

4.1 Introduction

Après avoir présenté la méthode de diagnostic par reconnaissance des formes floue et la méthode basée sur les séparateurs à vastes marges, nous essaierons dans le présent chapitre de présenter les résultats obtenus, accompagnés des interprétations.

La base de données obtenue après simulation des précédentes modèles est composée de 15 signaux présentant l'évolution de fonctionnement de moteur diesel d'un mode sain vers des modes défaillants, les données ont subi un prétraitement pour réduire le bruit et supprimer les données aberrantes, la compression des données a été effectuée par méthode de l'analyse en composante principale (ANNEX A.2) dans le but d'améliorer la classification et le temps de calcul.

Après réduction de la dimension de l'espace de présentations des différentes observations de notre base de données, nous avons effectué une séparation des données en base d'apprentissage (deux tiers), base de validation et une base de test (un tiers).

La séparation des données en ensemble d'apprentissage et ensemble de tests correspond à une partie importante de l'évolution de modèles d'explorations des données, la plupart des données sont utilisées pour l'apprentissage et une plus petite partie des données est utilisée pour les tests, l'échantillonnage aléatoire nous aide à s'assurer que les partitions de tests et d'apprentissage sont semblables.

4.2 Classification par reconnaissance des formes floue

Cette partie est consacrée à la présentation des résultats de classification de notre base de données qui comprend l'évolution de la vitesse de rotation, la pression d'admission et les émissions polluantes en mode de fonctionnement normal et en modes de dysfonctionnements, le tableau ci-après résume les différentes caractéristiques de notre base de données.

| Paramètres surveillés | Nombre de classe | Sous-ensemble d'apprentissage | Sous-ensemble de test | Modes de fonctionnements |
|-----------------------|------------------|-------------------------------------|-----------------------------|---|
| Vitesse de rotation | 05 | 2/3 de données pour l'apprentissage | 1/3 de données pour le test | Normal Défaut d'injection Défaut de soupape d'admission Défaut de fuite d'admission Défaut de compression |
| Pression d'admission | 05 | | | Normal Défaut d'injection Défaut de soupape d'admission Défaut de fuite d'admission Défaut de compression |
| Emissions polluantes | 05 | | | Normal Défaut d'injection Défaut de soupape d'admission Défaut de fuite d'admission Défaut de compression |

Tableau 4.1 : Description de bases de données.

La première partie affiche les résultats d'apprentissage hors ligne pour déterminer les modes de fonctionnement du moteur, la seconde démarche consiste à appliquer un apprentissage en ligne pour déterminer les modes de fonctionnement en temps réel.

4.2.1 Apprentissage hors ligne

Dans cette phase nous avons effectué un apprentissage hors ligne sur une base de données qui représente l'évolution de la vitesse de rotation d'un mode sain à des modes avec deux types de défauts (défaut d'injection et défaut de fuite d'admission).

La figure 4.1 illustre les différentes variations de la vitesse de rotation.

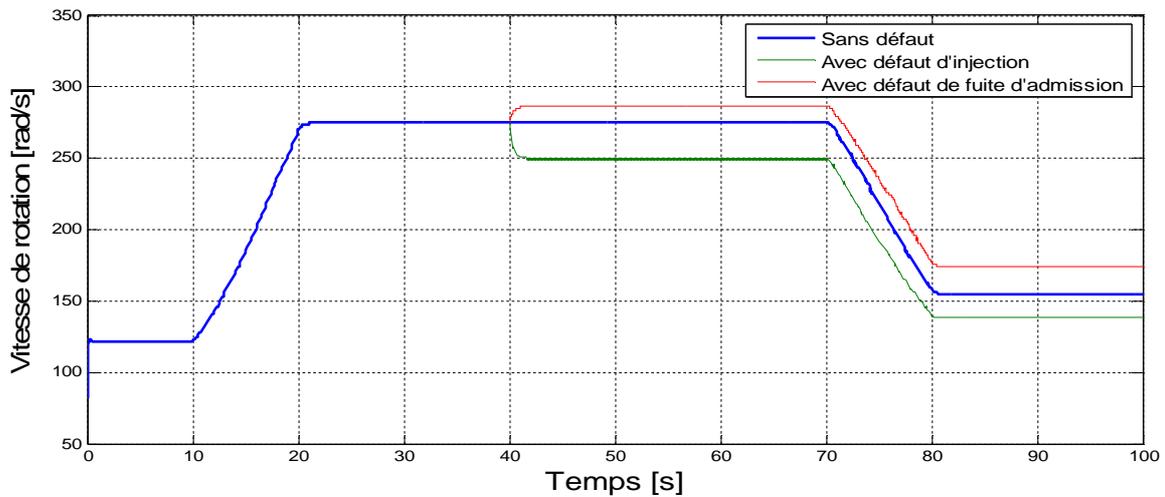


Figure 4.1 : Influence de défaut d'injection et défaut de fuite d'admission sur la vitesse de rotation

Les résultats de classification (apprentissage hors ligne) sont illustrés via la figure 4.2

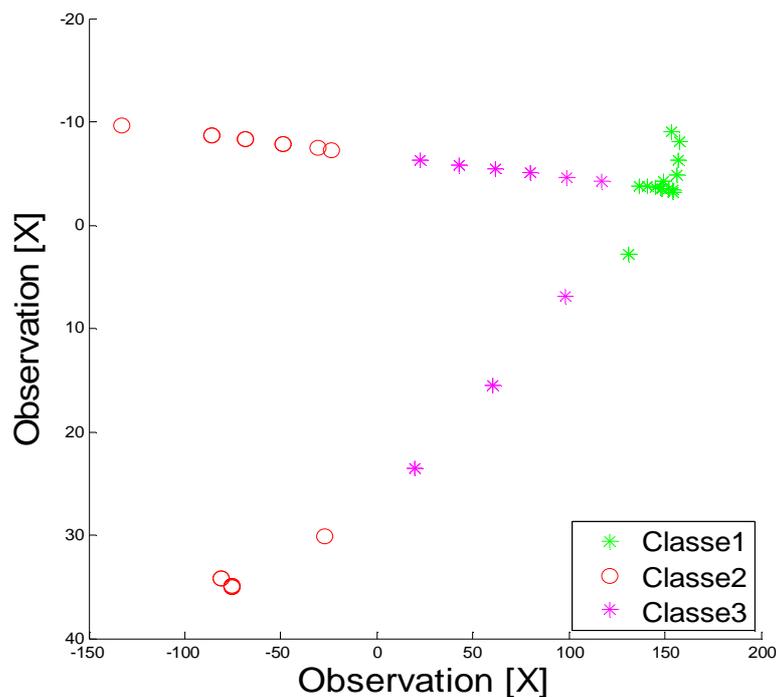


Figure 4.2 : Classification des données de vitesse de rotation (Apprentissage hors ligne)

Les résultats de classification montrant l'existence de trois classes associées aux trois modes de fonctionnement du moteur diesel.

Nous avons essayé d'interpréter les Trois situations ressorties suivant le tableau ci-après.

| Situation | Description | Classe |
|---|---|---------|
| Fonctionnement normal | Les valeurs des variables de vitesse de rotation correspondant aux conditions normales. | Classe1 |
| Fonctionnement en présence d'un défaut d'injection | Vitesse de rotation diminuée | Classe2 |
| Fonctionnement en présence d'un défaut de fuite d'admission | Vitesse moteur augmente | Classe3 |

Tableau 4.2 : Modes de fonctionnement correspond à l'apprentissage hors ligne

L'apprentissage hors ligne nous a permis de déterminer les modes de fonctionnement du moteur correspondant aux trois classes révélées.

4.2.2 Apprentissage en ligne

Dans cette deuxième phase nous avons effectué deux tests pour vérifier notre programme de classification, le premier test consiste à classifier une nouvelle observation (Ob 1) qui n'appartient à aucun mode de fonctionnement.

La figure 4.3 illustre la classification de cette nouvelle observation (Ob 1) :

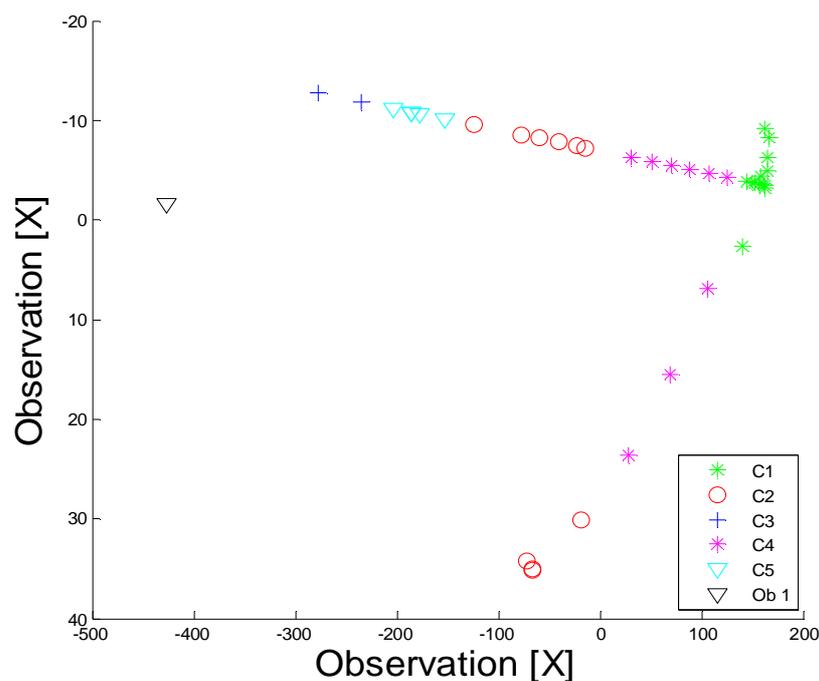


Figure 4.3 : Rejet en distance d'une nouvelle observation Ob 1.

Les résultats de classification, montrent que le cas de classification de la nouvelle observation correspond à un rejet de distance.

Les degrés d'appartenance de nouvelle observation sont présentés par le tableau 4.3 :

| C1 | C2 | C3 | C4 | C5 |
|------------------|------------------|------------------|------------------|------------------|
| $3,8640.10^{-7}$ | $4,0087.10^{-5}$ | $6,7527.10^{-4}$ | $1,6718.10^{-5}$ | $3,0369.10^{-5}$ |

Tableau 4.3 : Degrés d'appartenance de la nouvelle observation Ob 1.

Dans le deuxième test, la nouvelle observation (Ob2) dont les paramètres correspondent à un fonctionnement en présence d'un défaut de compression.

Les degrés d'appartenance de nouvelle observation sont présentés par le tableau 4.4 :

| C1 | C2 | C3 | C4 | C5 |
|------------------|--------|--------|------------------|--------|
| $3.1150.10^{-6}$ | 0,0022 | 0,0221 | $2.3588.10^{-4}$ | 0.8933 |

Tableau 4.4 : Degrés d'appartenance de la nouvelle observation Ob 2.

Les résultats de classification sont présentés via la figure 4.4.

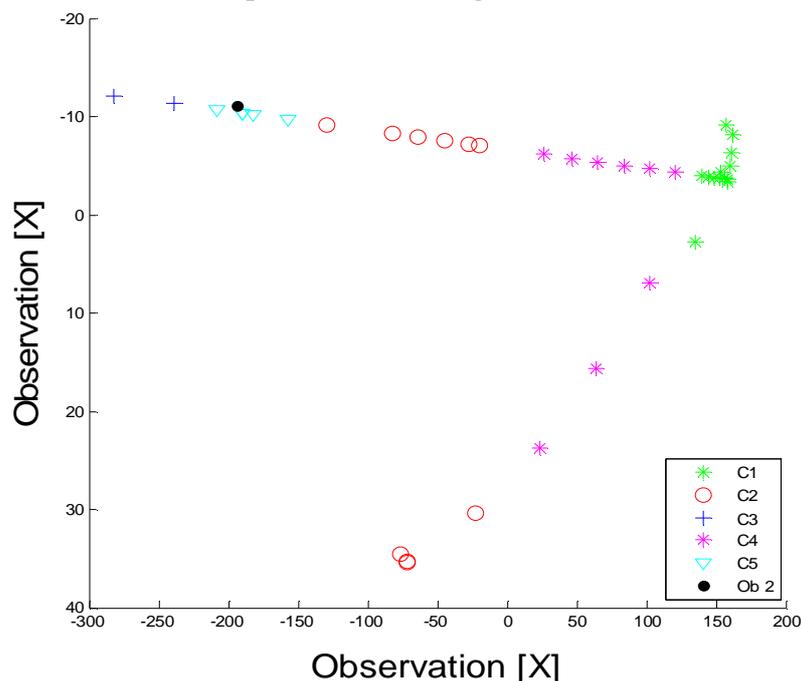


Figure 4.4 : Classification d'une nouvelle observation Ob 2.

Les résultats de classification, montrent que le cas de classification de la nouvelle observation correspond à un mode de fonctionnement avec défaut de compression.

Les résultats du programme de classification en ligne par MPCM appliqué sur notre base de données, illustrés graphiquement via les figures 4.5, 4.7 et 4.9, font ressortir cinq classes représentant l'ensemble des observations.

Les figures 4.6, 4.8 et 4.10 illustrent les modes de fonctionnement du moteur (mode sain et les modes avec défauts). La figure 4.5 illustre la classification des données de pression d'admission.

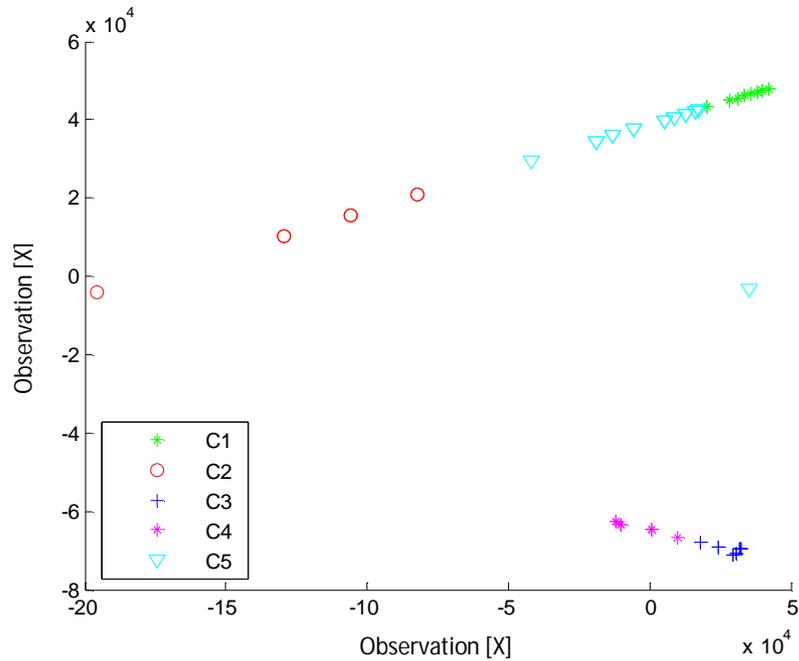


Figure 4.5 : Classification des données de pression d'admission.

Les résultats de classification des données de la pression d'admission font ressortir cinq classes représentant l'ensemble des observations de la pression d'admission. Elles ont été associées aux cinq modes présentés dans le tableau 4.5.

La figure 4.6 représente les modes de fonctionnement correspond à la classification des données de pression d'admission du moteur diesel :

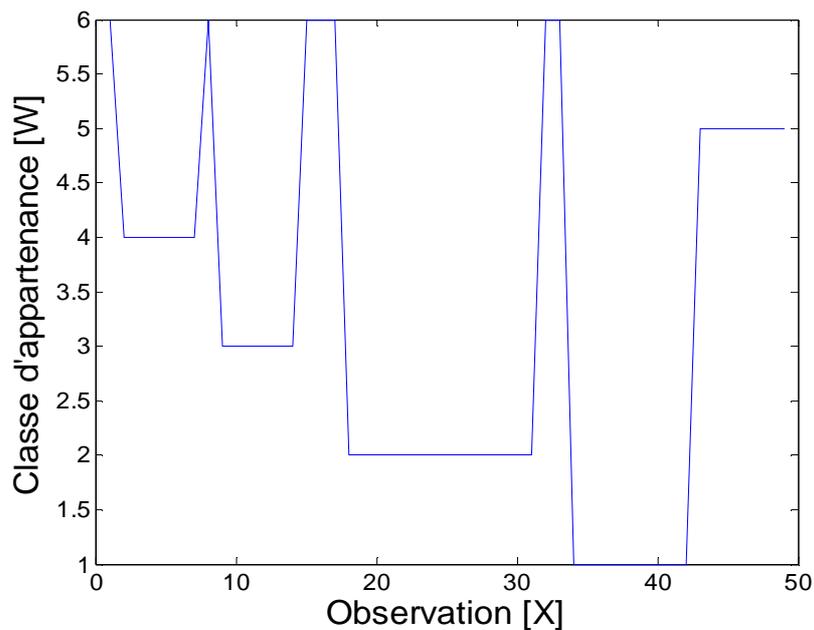


Figure 4.6 Modes de fonctionnement du moteur diesel relatif aux classifications des données de pression d'admission.

Nous avons essayé d'interpréter les cinq situations ressorties suivant le tableau ci-après.

| Situation | Description | Classe |
|---|---|----------|
| Fonctionnement normal | Les valeurs des variables de pression d'admission correspondant aux conditions normales | Classe 1 |
| Fonctionnement en présence d'un défaut d'injection | La pression d'admission se diminue avec une très faible grandeur | Classe2 |
| Fonctionnement en présence d'un défaut de soupape d'admission | augmentation de pression d'admission | Classe3 |
| Fonctionnement en présence d'un défaut de fuite d'admission | la pression d'admission va chuter | Classe4 |
| Fonctionnement en présence d'un défaut de compression | diminution de pression d'admission débit de compression est plus faible | Classe5 |

Tableau 4.5 : Description des modes de fonctionnement de moteur diesel correspond à la classification des données de pression d'admission.

Les résultats de classification des données de la vitesse de rotation font ressortir cinq classes représentant l'ensemble des observations de la vitesse de rotation. Elles ont été associées aux cinq modes présentés dans le tableau 4.6.

La figure 4.7 illustre les résultats de programme de classification des données de la vitesse de rotation du moteur.

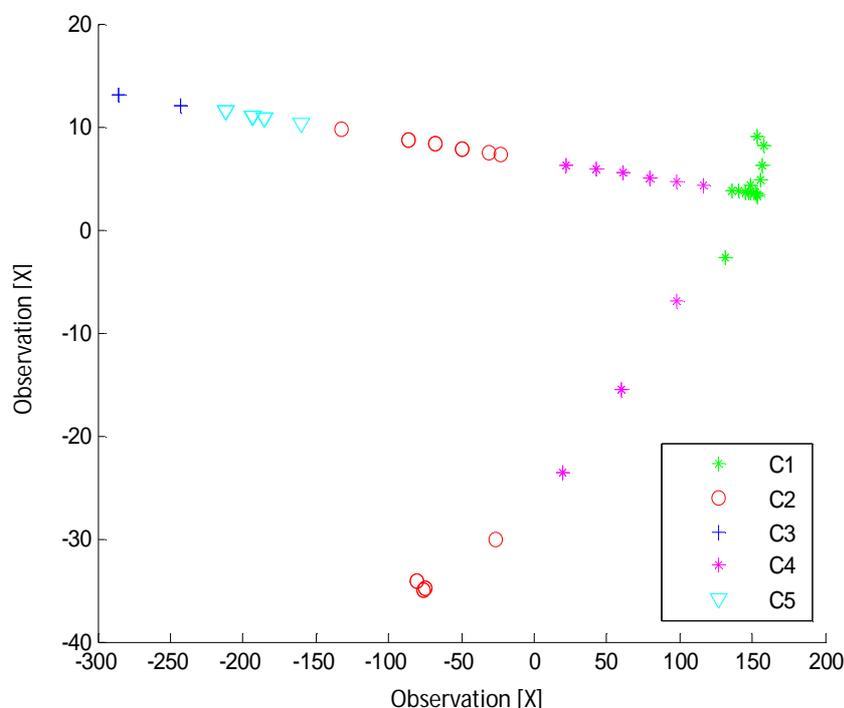


Figure 4.7 : Classification des données de vitesse de rotation.

Les modes de fonctionnement du moteur correspondent à la classification des données de vitesse de rotation sont illustrés par la figure 4.8.

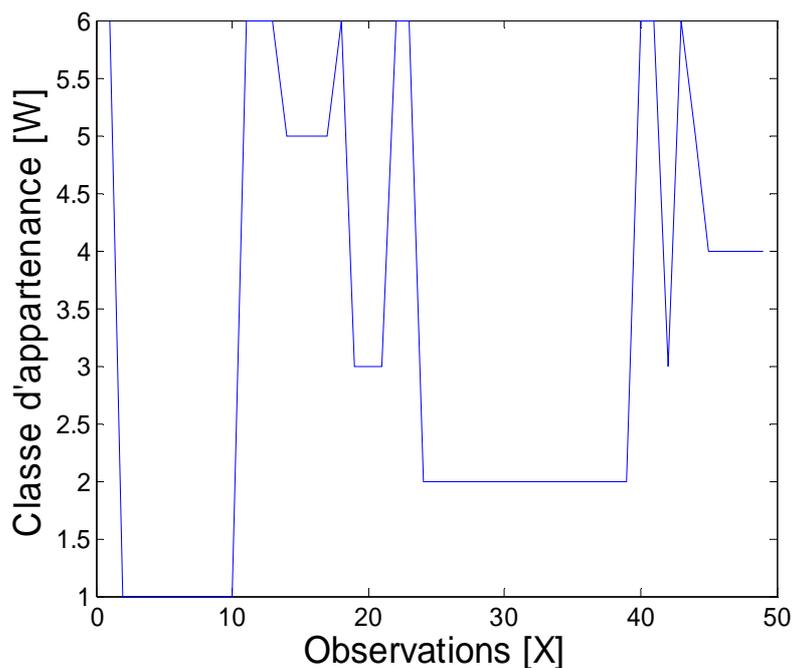


Figure 4.8 Modes de fonctionnement du moteur relatif à la classification des données de vitesse de rotation.

Le tableau ci-dessous représente une interprétation des cinq modes de fonctionnement du moteur diesel relié à la classification des données de vitesse de rotation.

| Situation | Description | Classe |
|---|--|----------|
| Fonctionnement normal | Les valeurs des variables de vitesse de rotation correspondant aux conditions normales | Classe 1 |
| Fonctionnement en présence d'un défaut d'injection | Vitesse de rotation diminuée | Classe2 |
| Fonctionnement en présence d'un défaut de soupape d'admission | Vitesse ne ce change pas | Classe3 |
| Fonctionnement en présence d'un défaut de fuite d'admission | Régime moteur augmente | Classe4 |
| Fonctionnement en présence d'un défaut de compression | Variation de vitesse de rotation | Classe5 |

Tableau 4. 6 : Description des modes de fonctionnement de moteur diesel correspond à la classification des données de vitesse de rotation.

Les résultats de classification des données des émissions polluantes font ressortir cinq classes représentant l'ensemble des observations des émissions polluantes. Elles ont été associées aux cinq modes présentés dans le tableau 4.7.

La figure 4.9 illustre les résultats de programme de classification des données des émissions polluantes du moteur.

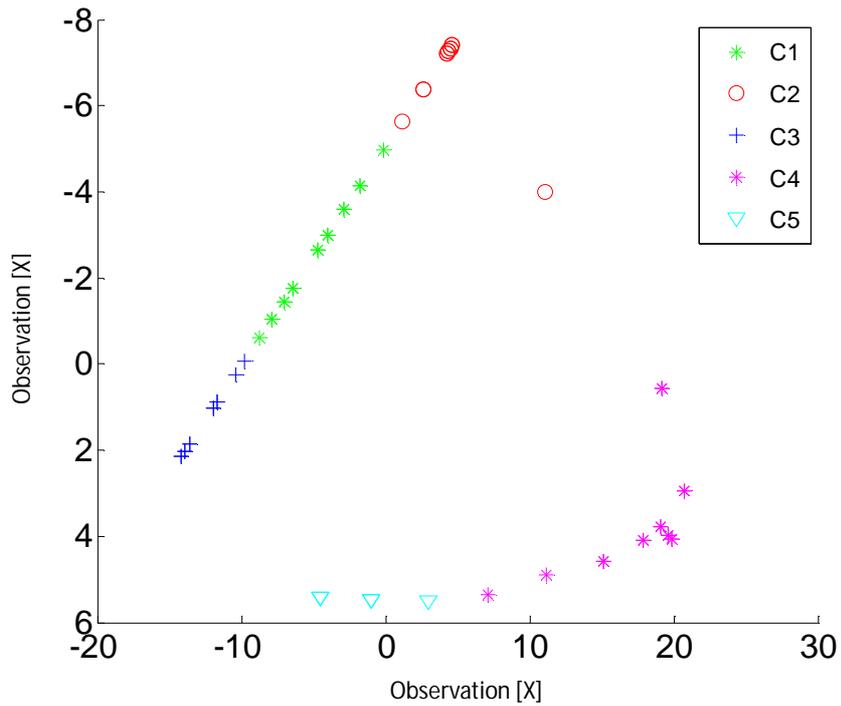


Figure 4.9 : Classification des données des émissions polluantes.

Les modes de fonctionnement du moteur correspondant à la classification des données des émissions polluantes sont illustrés par la figure 4.10 :

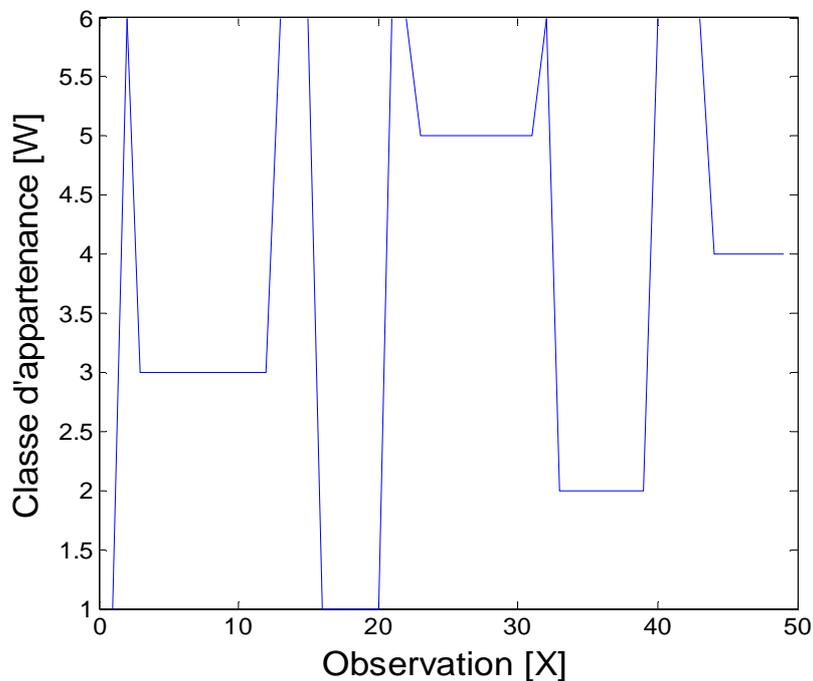


Figure 4.10 : Modes de fonctionnement du moteur relatif à la classification des données des émissions polluantes.

Le tableau 4.7 donne une description détaillée des cinq modes de fonctionnement de moteur diesel.

| Situation | Description | Classe |
|---|--|----------|
| Fonctionnement normal | Les valeurs des variables des émissions polluantes correspondant aux conditions normales | Classe 1 |
| Fonctionnement en présence d'un défaut d'injection | Les émissions polluantes sont moins que d'habitude Vitesse de rotation ↘ | Classe2 |
| Fonctionnement en présence d'un défaut de soupape d'admission | un pic d'émissions polluantes lors de l'apparition de défaut | Classe3 |
| Fonctionnement en présence d'un défaut de fuite d'admission | émissions des gaz sortant vont augmenter. | Classe4 |
| Fonctionnement en présence d'un défaut de compression | augmentations des émissions polluantes | Classe5 |

Tableau 4.7 : Modes de fonctionnement de moteur diesel correspondent à la classification des données des émissions polluantes.

Selon les résultats de classification présentés précédemment, nous constatons l'existence de cinq modes de fonctionnement correspondant aux cinq classes révélées.

La classe C1, appelé mode sain, est décrite par des observations se trouvant dans des intervalles de mesure correspondant aux conditions nominales de fonctionnement.

La classe C2, défaut d'injection, est décrite par une diminution de l'ensemble des mesures des paramètres qui décrivent le système.

La classe C3, défaut de soupape d'admission, est décrite par une conservation des mesures des paramètres de la vitesse de rotation, une augmentation de la pression d'admission accompagnée d'un pic des émissions de gaz polluants.

La classe C4, défaut fuite d'admission, est décrite par une augmentation des mesures des paramètres de la vitesse de rotation et des émissions polluantes avec une diminution des mesures de la pression d'admission.

La classe C5, défaut de compression, est décrite par une diminution de la pression d'admission et une augmentation des émissions polluantes. La vitesse de rotation est variable, elle dépend de la position de l'accélérateur.

Dans le but de valider les différents résultats obtenus par la méthode de reconnaissance des formes floue précédemment présentés, nous avons appliqué une autre méthode de diagnostic par SVM, dont les résultats sont présentés dans la section suivante.

4.3 Résultats de programme de classification par SVM

Dans cette partie de travail, nous présentons les résultats de classification par algorithme SVM de notre base de données relative à la simulation des différents modèles du moteur diesel présenté dans le chapitre IV.

En se basant sur les différentes reconnaissances présentées dans le chapitre III, nous avons développé un algorithme qui utilise à la fois un noyau Linéaire, et un noyau du type Gaussien, l'algorithme SVM utilisé dans cette section est présenté dans le tableau 4.8.

Algorithme : SVM

Ensemble d'apprentissage X_a

$$X_a = \{(x_1, z_1), \dots, (x_i, z_i), \dots, (x_N, z_N)\} \quad i = 1 \dots N, x_i \in \mathfrak{R}^p, z_i = \{-1, +1\}$$

Choisir la fonction noyau (Linéaire, Gaussienne RBF)

- $k(x_i, x_j) = \langle x_i, x_j \rangle$ avec $\phi(x_i) = x_i$

- $k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right)$

Appliquer une procédure d'optimisation (en utilisant la fonction noyau) pour trouver le vecteur de support, les coefficients α_i et les biais b (cf. équation 2.88).

Étant donné une nouvelle instance, x , trouve la classification de x par calcul :

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

Si le signe de la fonction $f(x)$ est positive alors la nouvelle observation x appartient à la classe +1, sinon x appartient à la classe -1.

Tableau 4.8 : Étapes pour la classification SVM.

L'algorithme développé sous MATLAB R2014 a utilisé une fonction noyaux de type gaussien (Rbf_sigma), où sigma c'est un coefficient qui caractérise la fonction noyaux (Cf.2.4.1.2.1). Le tableau suivant résume quelques résultats obtenus en changeant la valeur sigma :

| | Sigma = 0,01 | Sigma=0,1 | Sigma=10 | Sigma=100 |
|-------------------------------|--------------|-----------|----------|-----------|
| Taux de classification | 96% | 100% | 96% | 96% |

Tableau 4.9 : Taux de classification obtenu pour différentes valeurs de sigma.

En changeant le coefficient sigma qui caractérise la fonction noyau, le taux de classification change car sigma sert à réguler la largeur de la gaussienne.

Dans la partie qui suit, nous présentons les résultats de classification de toute la base de données. Pour tester notre algorithme SVM nous avons utilisé comme configuration, la fonction noyaux Gaussien (RBF), et pour l'hyper paramètre (sigma) la valeur 0.15.

4.3.1 Classification de données de vitesse de rotation

Dans cette partie de travail, on va présenter les résultats de classifications des données de vitesse de rotation du moteur, l'algorithme SVM a été entraîné avec deux noyaux : Linéaire et Rbf.

Le tableau 4.10 illustre les performances de classification par SVM un contre tous.

| Cas Étudié (Vitesse de rotation) | Kernel | Taux de classification (%) |
|-------------------------------------|------------|----------------------------|
| | | Un Contre Tous |
| Sans Défaut | Linéaire | 95,83% |
| | Rbf | 100% |
| Défaut d'injection | Linéaire | 87% |
| | Rbf | 95,83% |
| Défaut de soupape d'admission | Linéaire | 83,33% |
| | Rbf | 87,50% |
| Défaut de fuite d'admission | Linéaire | 87,5 % |
| | Rbf | 95,83 % |
| Défaut de compression | Linéaire | 88% |
| | Rbf | 92% |

Tableau 4.10 : Taux de classification obtenue pour la classification des données de vitesse de rotation.

Les résultats de classification on permet de conclure que l'algorithme utilisé à réaliser une bonne classification des différentes observations, ainsi l'utilisation d'un noyau (Rbf) permet d'atteindre 90% à 100% de bonne classification dans la totalité des cas.

Les différents résultats de classification des données de la vitesse de rotation sont illustrés via les figures suivantes :

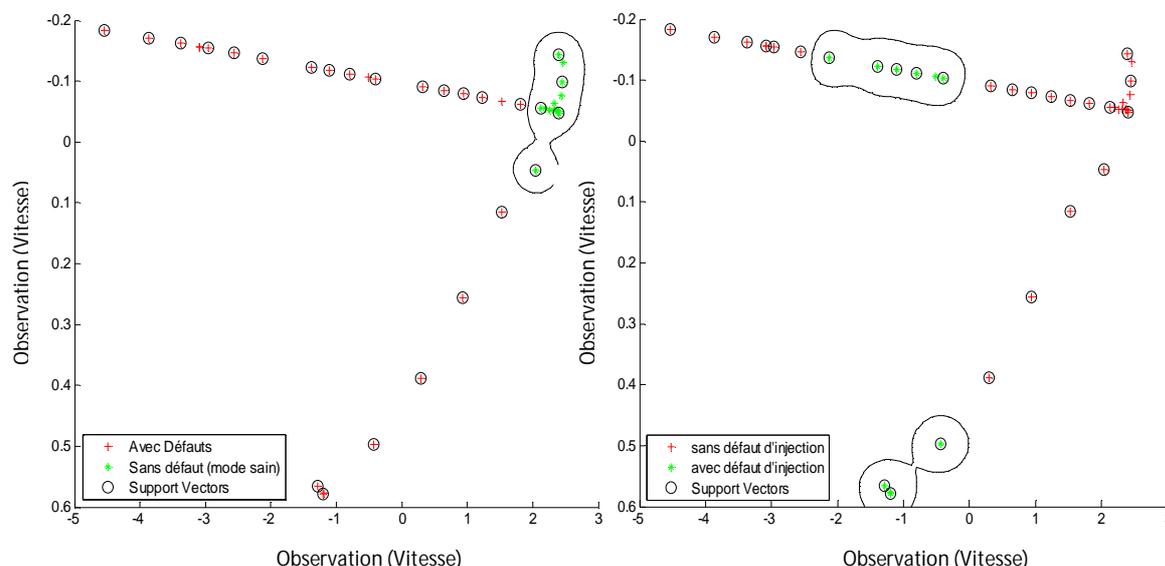


Figure 4.11 : Classification des données ω (sans défaut et avec tous les défauts)

Figure 4.12 : Classification des données ω (sans défaut d'injection et avec défaut d'injection)

La figure 4.11 montre la classification des observations de la vitesse de rotation quand le moteur fonctionne sans défaut (classe 1) et en présence des défauts (classe 2).

La figure 4.12 illustre les résultats de classification des observations de la vitesse dans le cas de fonctionnement en mode sans défaut d'injection contre tous les autres modes de fonctionnement.

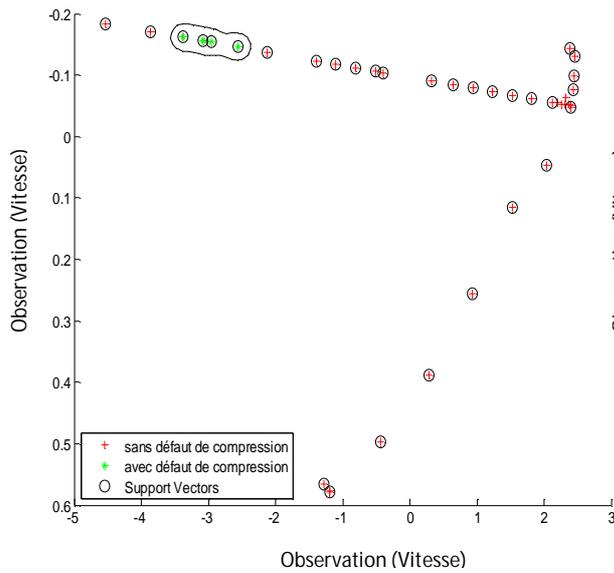


Figure 4.13 : Classification des données ω (sans défaut de compression et avec défaut de compression)

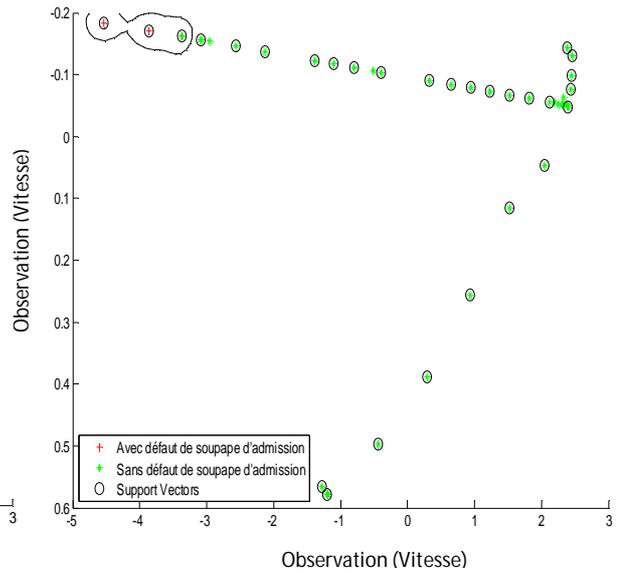


Figure 4.14 : Classification des données ω (sans défaut soupape ad et avec défaut soupape ad)

Sur la figure 4.13 une illustration de la classification des observations de la vitesse de rotation en mode de fonctionnement avec défaut de compression contre tous les autres modes de fonctionnement du moteur diesel.

Pour la figure 4.14 on remarque une séparation des données de vitesse de rotation en présence du défaut de soupape d'admission par rapport aux autres données qui présentent les autres modes de fonctionnement du moteur

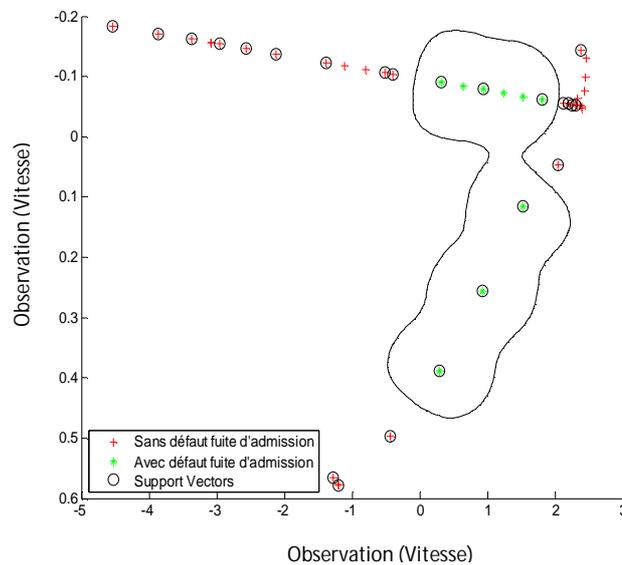


Figure 4.15 : Classification des données ω (Sans défaut de fuite ad et avec défaut de fuite ad)

La dernière figure 4.15 montre la séparation entre les modes de fonctionnement du moteur, la première classe est composée des données de vitesse de rotation sans défaut de fuite d'admission, les autres données (deuxième classe) rassemble les données de vitesse de rotation en présence du défaut de fuite d'admission.

4.3.2 Classification de données de pression d'admission

Les différents résultats de classification de la base de données de la pression d'admission via l'algorithme SVM sont illustrés dans les figures ci-dessous.

Le tableau 4.11 présente les différents taux de classification, afin de montrer les performances de l'approche adoptée.

| Cas Étudié (Pression d'admission) | Kernel | Taux de classification (%) |
|--------------------------------------|------------|----------------------------|
| | | Un Contre Tous |
| Sans Défaut | Linéaire | 76 % |
| | Rbf | 80 % |
| Défaut d'injection | Linéaire | 100 % |
| | Rbf | 100 % |
| Défaut de soupape d'admission | Linéaire | 95,83 % |
| | Rbf | 100 % |
| Défaut de fuite d'admission | Linéaire | 97,98 % |
| | Rbf | 100 % |
| Défaut de compression | Linéaire | 96 % |
| | Rbf | 100 % |

Tableau 4.11 : Taux de classification obtenue pour la classification des données de pression d'admission.

Les différents taux de classification présentés dans le tableau 4.11 permettent de conclure que l'utilisation d'un noyau Rbf donne un taux égal à 100% de bonne classification dans les différents modes de fonctionnement du moteur sauf pour le cas sain où le taux égale à 80% puisqu'il existe une observation mal classée sur la frontière de la classe.

Les résultats de classification des données de pression d'admission sont les suivants :

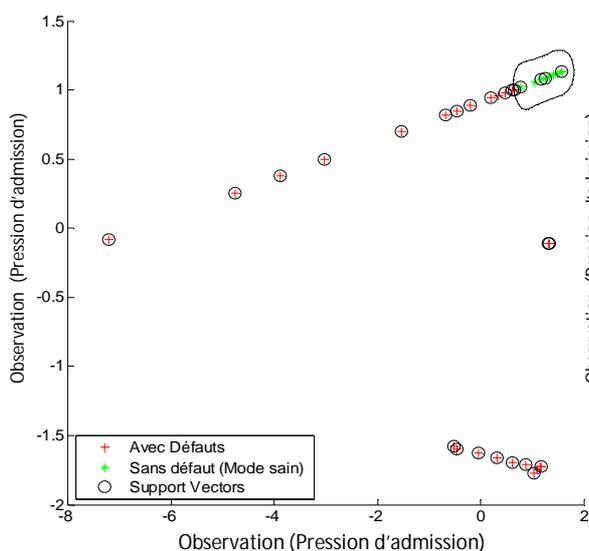


Figure 4.16 : classification des données p_a (sans défaut et avec défaut)

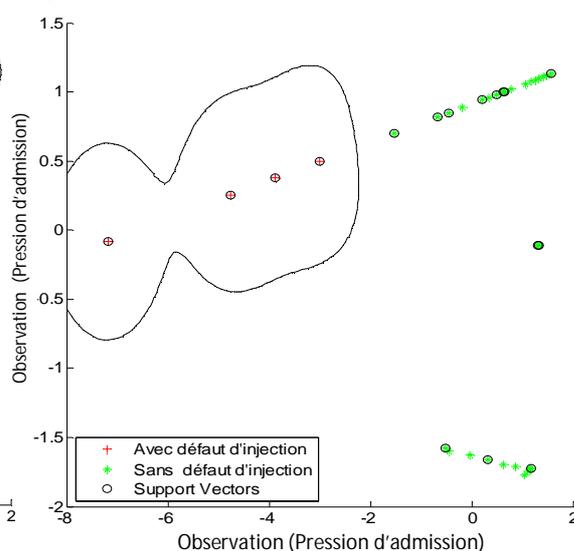


Figure 4.17 : classification des données p_a (sans défaut d'injection et avec défaut d'injection)

Les résultats de classification présentés sur les différentes figures, montrent la séparation des différents modes de fonctionnement du moteur diesel.

La figure 4.16 illustre une classification en deux classes, la première classe traduit le fonctionnement en présence des différents modes défectueux (en présence des défauts), ainsi la deuxième classe présente le fonctionnement en état normal.

Pour la figure 4.17, la première classe englobe les observations en fonctionnement avec défaut d'injection, et la deuxième classe représente les observations de la pression d'admission en présence d'autres modes de fonctionnement du moteur.

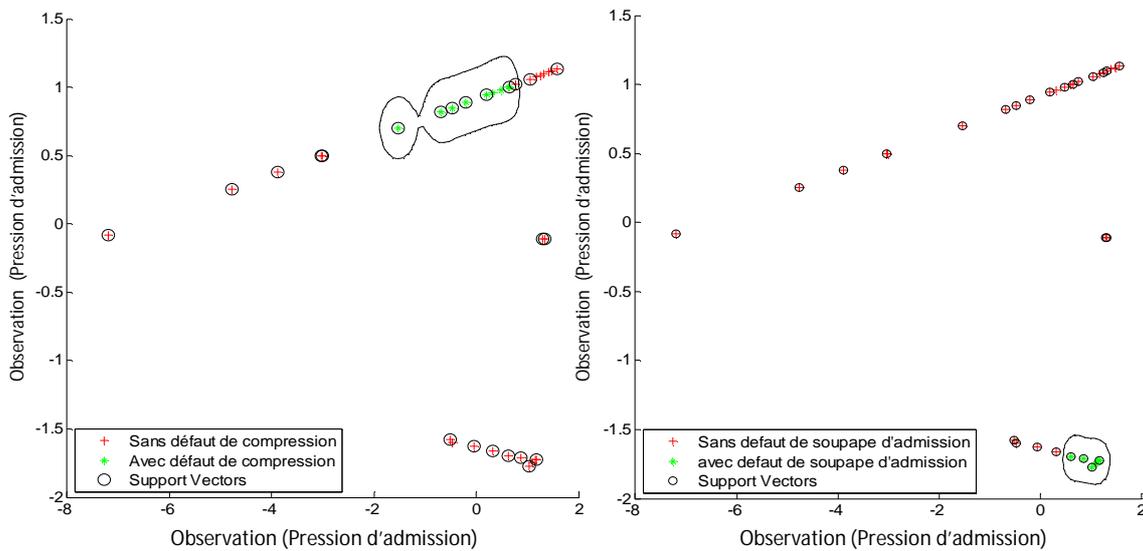


Figure 4.18 : Classification des données p_a (sans défaut de compression et avec défaut de compression)

Figure 4.19 : Classification des données p_a (sans défaut soupape ad et avec défaut de soupape ad)

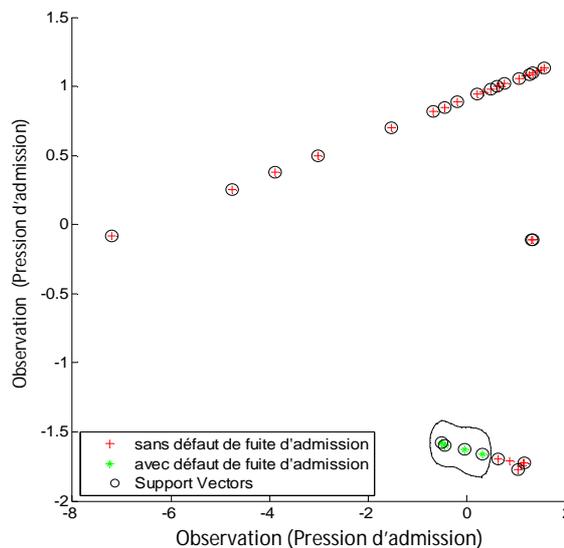


Figure 4.20 : Classification des données p_a (sans défaut de fuite ad et avec défaut de fuite ad)

Sur la figure 4.18 en voix deux classes, les observations de la première classe représentant un fonctionnement sans défaut de compression, tandis que les autres observations traduisant un fonctionnement en présence d'un défaut de compression.

La figure 4.19 illustre les résultats de classification de base de données (Pression d'admission) dans le cas de fonctionnement avec défaut de soupape d'admission contre tous les autres modes de fonctionnement.

La dernière figure 4.20 montre la séparation d'un mode de fonctionnement en présence d'un défaut de fuite d'admission par rapport aux autres modes de fonctionnement du moteur.

Les différents résultats de classifications des modes de fonctionnement et le taux de classification, confirment l'efficacité de l'approche SVM proposé.

4.3.3 Classification de données des émissions polluantes

Après importations de la base de données qui présente l'évolution des émissions polluantes en fonctionnement normal et en présence des défauts dans le code de calcul par SVM développé sur MATLAB 2014a, nous avons effectué une classification dans le seul but de connaître et séparer les différents modes de fonctionnement du moteur diesel pour le bon diagnostic de ce dernier.

Le tableau 4.12 est construit pour la bonne interprétation des résultats de classification, en utilise comme critère de vérification des performances de notre algorithme de calcul, le taux de bonne classification des différentes observations.

L'algorithme SVM a été entraîné avec deux noyaux : noyau de type linéaire et noyau Gaussien (Rbf).

| Cas Étudié (Émissions Polluantes) | Kernel | Taux de classification (%) |
|--------------------------------------|------------|----------------------------|
| | | Un Contre Tous |
| Sans Défaut | Linéaire | 95,83 % |
| | Rbf | 100 % |
| Défaut d'injection | Linéaire | 95,83 % |
| | Rbf | 100 % |
| Défaut de soupape d'admission | Linéaire | 96 % |
| | Rbf | 100 % |
| Défaut de fuite d'admission | Linéaire | 96 % |
| | Rbf | 100 % |
| Défaut de compression | Linéaire | 100 % |
| | Rbf | 100 % |

Tableau 4.12 : Taux de classification obtenue pour la classification des données des émissions polluantes.

Depuis le tableau 4.12 on peut conclure que l'utilisation d'un algorithme SVM avec noyau Rbf permet une bonne classification des différents modes de fonctionnement du moteur, dont le taux de bonne classification atteint 100% pour tous les cas étudiés.

La classification par SVM avec noyau de type linéaire donne un taux entre 95% à 96% sauf pour un seul cas il atteint 100%.

La comparaison des deux approches confirme l'efficacité de l'utilisation d'un algorithme SVM avec noyau Rbf qui donne toujours des bons résultats de classifications comparés à SVM linéaire.

Pour bien visualiser les différents résultats de classifications de base des données des émissions polluantes, nous illustrons les résultats via les figures suivantes :

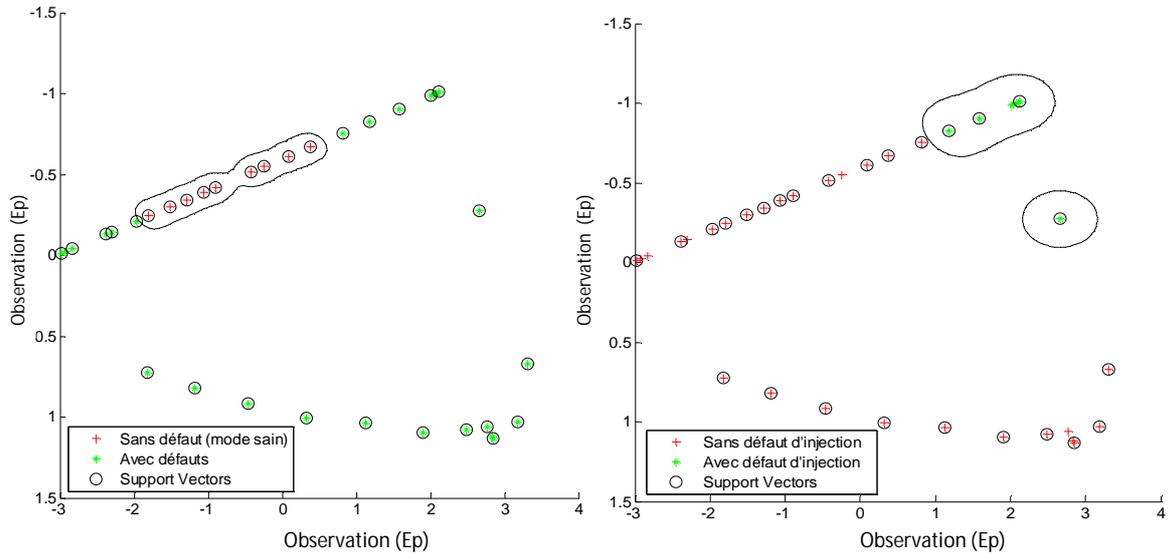


Figure 4.21 : Classification des données E_p (sans défaut et avec défaut)

Figure 4.22 : Classification des données E_p (sans défaut d'injection et avec défaut d'injection)

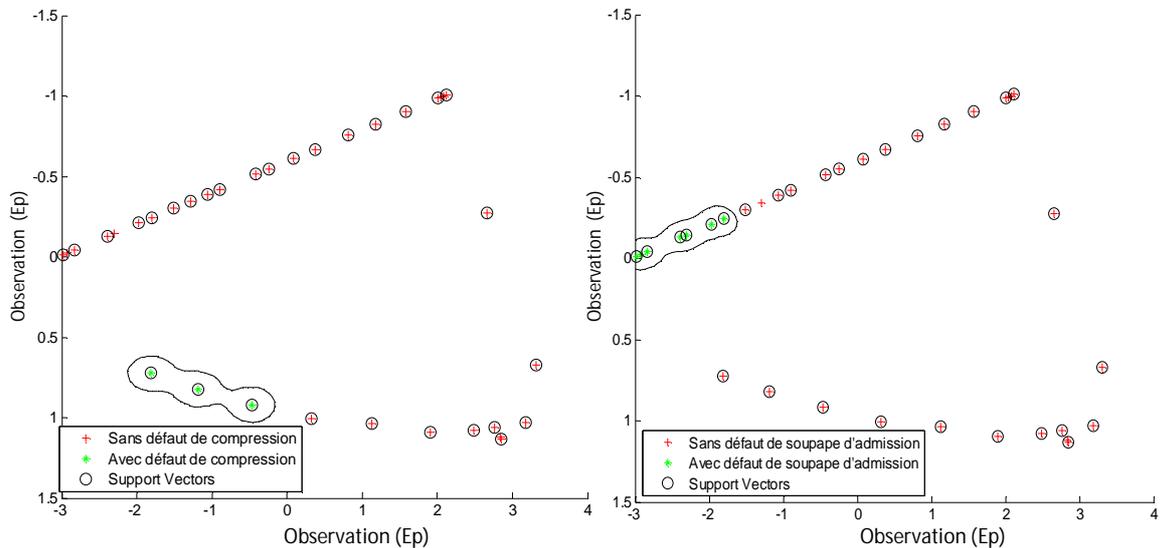


Figure 4.23 : Classification des données E_p (sans défaut de compression et avec défaut de compression)

Figure 4.24 : Classification des données E_p (sans défaut soupape ad et avec défaut de soupape ad)

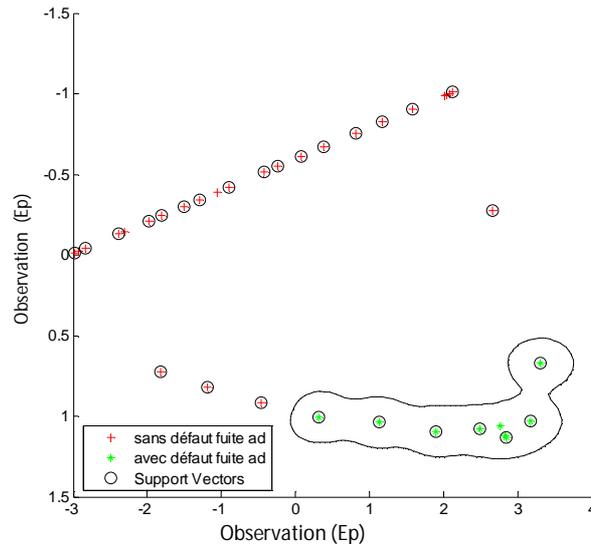


Figure 4.25 : Classification des données E_p (sans défaut de fuite ad et avec défaut de fuite ad)

Les différentes figures illustrant une classification binaire par SVM des différents modes de fonctionnement du moteur diesel.

La figure 4.21 présente une séparation de mode sans défaut par rapport aux autres modes de fonctionnement (émissions polluantes en modes avec différents défauts étudiés).

La figure 4.22 montre une séparation binaire entre la classe 1 (émissions polluantes lors d'un fonctionnement avec défaut d'injection) et la classe 2 qui représente les données des émissions polluantes avec les différents autres modes de fonctionnement du moteur.

Sur la figure 4.23 une classification d'un cas de fonctionnement avec défaut de compression face à tous les différents autres cas de fonctionnement.

Pour la figure 4.24 on constate l'existence des deux classes, les observations de la première classe sont celles d'un fonctionnement sans défaut de soupape d'admission, les autres observations (classe 2) représentent les observations des émissions polluantes en fonctionnement avec défaut de soupape d'admission.

La dernière figure 4.25 illustre la classification des données relatives à un mode de fonctionnement avec défaut de fuite d'admission contre tous les autres modes de fonctionnement du moteur diesel.

Comparaison des résultats de classification

À travers ce chapitre nous avons présenté les résultats obtenus par les deux méthodologies de diagnostic, la première utilise les techniques de reconnaissance des formes floues (algorithme MPCM), la deuxième méthodologie est basée sur les séparateurs à vaste marge (SVM).

La base de données relative à la simulation des différents modèles de moteur diesel a été divisée en deux parties, deux tiers pour l'apprentissage et un tiers pour le test, les mêmes sous-ensembles sont utilisés pour les deux techniques de diagnostic.

Le tableau ci-dessous présente les performances de classifications obtenues par les deux algorithmes de calculs

| Paramètres surveillés | Algorithmes | Taux de bonne classification | Taux de Mauvaise classification |
|-----------------------------|------------------|------------------------------|---------------------------------|
| Vitesse de rotation | <i>MPCM</i> | 72,94 % | 27,06 |
| | <i>SVM (RBF)</i> | 94,23 % | 5,77 % |
| Pression d'admission | <i>MPCM</i> | 96,03 % | 3,97 % |
| | <i>SVM (RBF)</i> | 96 % | 4 % |
| Emissions polluantes | <i>MPCM</i> | 82,80 % | 17,2 % |
| | <i>SVM (RBF)</i> | 100 % | 0 % |

Tableau 4.13 : Performances de classification par MPCM et SVM

Les performances obtenues dans le tableau 4.13 montrant l'efficacité de la méthode des séparateurs à vastes marges (SVM) par rapport à la technique de reconnaissance des formes floue (algorithme MPCM), puisque les taux de bonnes classifications obtenus sont les meilleurs.

Les deux méthodologies de diagnostic, nous permettons de déterminer les mêmes modes de fonctionnement du moteur diesel, sur cette base, les résultats de classification par MPCM sont validés.

4.4 Conclusion

À travers ce cinquième chapitre, nous avons essayé de mettre en évidence l'utilité de la technique de reconnaissance des formes floue pour le diagnostic du fonctionnement d'un moteur diesel et la détection des situations de dysfonctionnements. Dans le but de valider les différents résultats obtenus par reconnaissance des formes floue, nous avons appliqué une deuxième méthode de diagnostic basée sur les séparateurs à vastes marges (SVM) qui permet à son tour la détection des modes de fonctionnement.

En premier lieu, nous avons illustré et interprété les résultats du programme de classification par reconnaissance des formes floue.

Les résultats obtenus ont démontré l'efficacité de la méthode de diagnostic basé sur l'algorithme C-moyenne possibiliste modifié, en termes de bonne classification. Cette démarche nous à permis de déterminer les différents modes de fonctionnement du moteur diesel qui sont au nombre de cinq.

En deuxième lieu, nous avons illustré et interprété les résultats de classification SVM. Notre algorithme de calcul à viser la classification des données en utilisant deux types de noyaux : linéaire et gaussien (Rbf).

Les résultats de classification permettent de conclure l'efficacité de notre approche pour la détection rapide des différents modes de fonctionnement avec un taux élevé de classification et un taux d'erreur minimal. L'efficacité de la technique SVM dans le cadre du diagnostic de

moteur diesel dépend en grande partie, de la qualité de l'information fournie comme vecteur d'entrée au classifieur.

Après comparaison des taux de bonne classification et de mauvaise classification par les deux algorithmes MPCM et SVM appliqué au diagnostic de moteur diesel, En constatent que les deux approches en déterminer d'une façon similaire les différents modes de fonctionnement. D'autres termes, on a pu valider les résultats de classification par MPCM en utilisons la méthode SVM.

CHAPITRE V

Simulation et Implémentation

5.1 Introduction

Dans ce chapitre, nous présentons la simulation de l'algorithme de diagnostic basée sur les techniques des séparateurs à vaste marge (SVM). Nous commençons ce chapitre par une présentation des systèmes embarqués, en particulier les réseaux logiques programmables (FPGA), ensuite nous présentons l'implémentation d'un système de classification par séparateurs à vaste marge sur FPGA (Field Programmable Gate Array), Grâce à la fonction de calcul parallèle fournie par FPGA, une classification rapide des données peut être réalisée par le classificateur binaire SVM basé sur FPGA. Le système de classification proposé fonctionne en mode non linéaire.

5.2 Systèmes embarqués pour le diagnostic

5.2.1 Introduction aux systèmes embarqués

Les systèmes embarqués sont présents partout dans notre vie quotidienne, ils sont discrets, efficaces et dédiés à ce à quoi ils sont destinés.

Un système embarqué est un système électronique, piloté par un logiciel, qui est complètement intégré au système qu'il contrôle [SADOU 07].

Selon [HEATH 97], un système embarqué est un système basé sur microprocesseur construit pour gérer une fonction ou une série de fonctions et qui n'est pas conçu pour être programmé par l'utilisateur final comme c'est le cas dans un PC.

Selon [HS07], les systèmes embarqués sont des composants qui intègrent du logiciel et du matériel. Ils se caractérisent par une interaction continue avec leur environnement physique. Ils trouvent leur application dans de nombreux domaines.

Initialement, les systèmes embarqués ont été utilisés pour des applications temps réel critique, de sûreté et/ou de sécurité, comme le contrôle des fusées, missiles, satellites. Actuellement, ils sont utilisés dans notre vie quotidienne (les moyens de transport, les équipements médicaux, les équipements industriels, les équipements de télécommunication, les équipements du bâtiment, ...etc.).

La complexité croissante des systèmes embarqués nécessite des méthodes de conception globale qui tiennent compte des fonctionnalités et des constituants (capteurs, actionneurs, contrôleurs, réseaux), des perturbations et des fortes contraintes de coût ou environnemental (retards, incertitudes, ...). Ces systèmes sont basés sur des dispositifs intelligents qui peuvent détecter, communiquer, s'adapter et agir sur l'environnement.

Il y a tant de définition, on pourrait dire que les systèmes embarqués sont constitués de puces électroniques sur lesquelles fonctionnent des logiciels dédiés à l'exécution de fonctions spécifiques ; le tout étant destiné à être intégré dans des sous-ensembles, équipements, appareils et produits divers.

5.2.2 Architecture des systèmes embarqués

L'architecture des systèmes embarqués peut être divisée en deux Familles, nous retrouvant l'architecture en blocs ou en couches. L'architecture en bloc est généralement composée d'une unité centrale de traitement (CPU), d'un système d'exploitation (logiciel), d'une interface homme-machine (IHM) pour reconfigurer le système.

L'architecture en couches est une abstraction du système qui ne montre donc pas les détails d'implémentation ou de conception des circuits. Cette représentation met l'accent sur les niveaux de communication et de circulation d'information à la manière des protocoles réseaux [BOUALI 10]. Les deux types d'architecture d'un système embarqué sont illustrés via les deux figures ci-après :

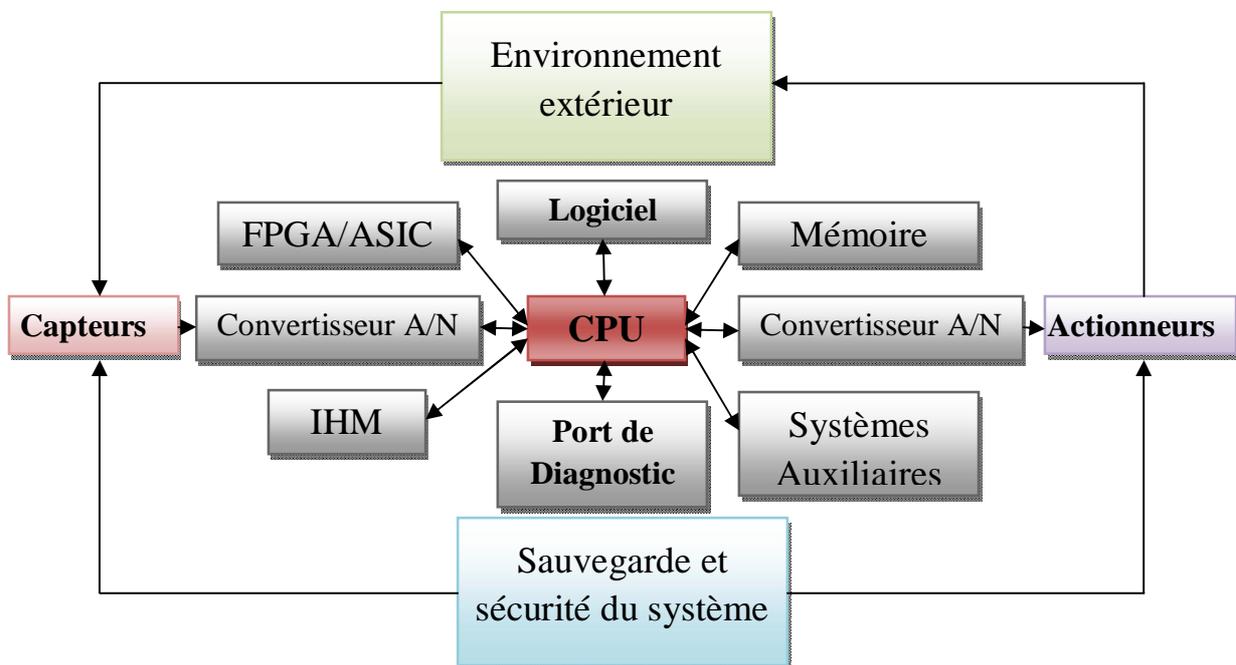


Figure 5.1 : Architecture en blocs d'un système embarqué.

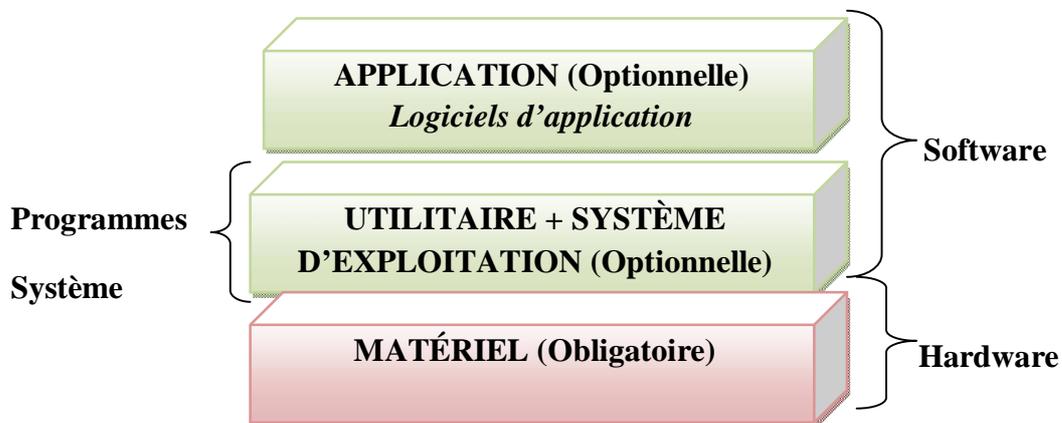


Figure 5.2 : Architecture en couches d'un système embarqué.

5.2.3 Contraintes des systèmes embarqués

Les systèmes embarqués exécutent des tâches prédéfinies et ont des contraintes spécifiques :

- **Cout très bas** : Ce critère est l'un des plus importants. Il désigne la valeur financière allouée qui conditionne le cycle de vie du système embarqué tout entier. Il influe sur les choix de conception (matériel, logiciel, méthodes, outils), de mise en œuvre, de commercialisation, de maintenance, d'amélioration et de fin de vie.
- **Encombrement physique** : Les systèmes embarqués possèdent des caractéristiques physiques (dimensions, poids) qu'on cherche souvent à minimiser pour des raisons fonctionnelles et/ou commerciales. Cet objectif est possible grâce à la miniaturisation des unités de calcul, du développement de matériaux légers (ex. fibres de carbone), d'une meilleure conception et intégration des parties mécaniques.
- **Robustesse aux chocs, à la température et à l'humidité** : L'environnement est souvent hostile pour des raisons physiques (chocs, température, ...) c'est pour quoi la sécurité et la fiabilité sont souvent rattachées à la problématique des systèmes embarqués.
- **Autonomie** : cette caractéristique est essentielle pour les systèmes embarqués, ils doivent être autonomes, c'est-à-dire remplir leur mission pendant de longues périodes sans intervention humaine, particulièrement quand l'intervention humaine est impossible ou trop lente comme dans un environnement radioactif, application spatiale ...etc.

Les composants FPGA (*field-programmable gate array*) intègrent toutes les cellules nécessaires pour embarquer des systèmes autonomes.

5.2.4 Réseaux logiques programmables (FPGA)

Les réseaux logiques programmables sont des composantes électroniques programmables, un FPGA est un ensemble de blocs logiques élémentaires que le concepteur peut interconnecter pour réaliser les fonctions logiques de son choix.

Il est généralement composé d'un réseau de blocs logiques, de blocs mémoires, de blocs dédiés et d'entrées/sorties.

L'ensemble est relié par un réseau d'interconnexions programmable. La programmation FPGA se fait avec un langage de programmation de hardware tel que le VHDL.

La figure 5.3 présente la structure interne d'un FPGA de type matrice symétrique.

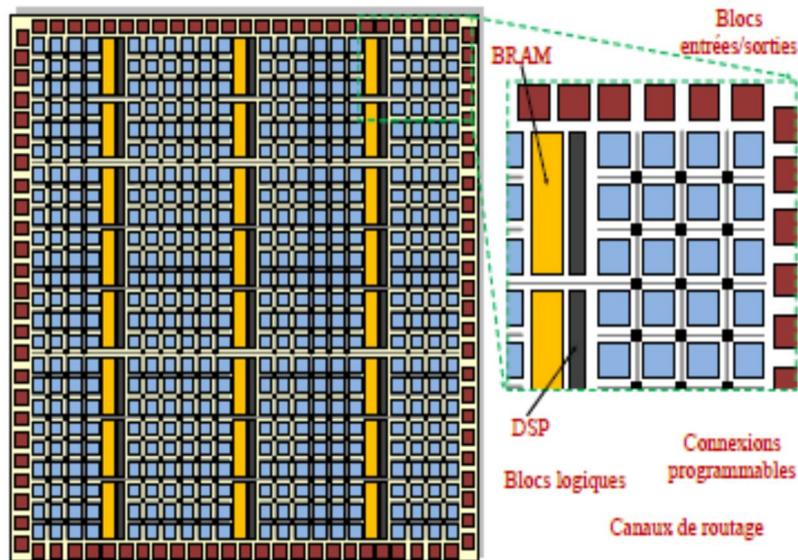


Figure 5.3 : Architecture conceptuelle d'un FPGA

Les FPGA présentent beaucoup de perspectives pour l'implémentation d'algorithmes en temps réel, en plus, les outils de conception assistée par ordinateur servent à passer directement d'une description fonctionnelle (VHDL) à un schéma en porte logique prêt à être implémenté sur FPGA [PHAN 09].

5.3 Cartographie de l'architecture FPGA

Les modules de calcul utilisés pour construire les classificateurs de l'algorithme SVM, détaillé dans le chapitre 2 sont conçus et le mappage de l'architecture FPGA du système est présenté en détail ci-dessous.

5.3.1 Algorithme SVM non linéaire

À partir des résultats de classification par SVM précédemment présenté nous avons choisi d'utiliser un noyau gaussien (RBF).

Étant donné deux classes Ω_1, Ω_2 et $X_a = \{(x_1, z_1), \dots, (x_N, \dots, x_N)\}$ est l'ensemble d'apprentissage où $x_i \in \mathbb{R}^p$, $z_i \in \{1, -1\}$.

La fonction de décision est présentée par l'équation (2.87).

L'algorithme SVM non linéaire est présenté dans le tableau 5.1:

Algorithme : SVM non linéaire○ **Données**

N vecteurs non étiquetés.

DéfinirMatrice x [échantillons de test] ;Matrice X_a [échantillons d'apprentissage] ;Matrice Z [identité de la classe] ;Matrice $C = Z'$;*Pour* $i = 1, \dots, N$; $j = 1, \dots, N$;Calculer les paramètres de la fonction de décision (équation 2.87) en utilisant la matrice d'apprentissage X_a et la fonction noyau gaussienne.

$$K(i, j) = \exp((X_a(i,1) - X_a(j,1))^2 + (X_a(i,2) - X_a(j,2))^2).$$

*Fin.**Fin.**Pour* $k = 1, \dots, 10$; $l = 1, \dots, 10$;Multiplier la matrice $A(k,l)$ par la matrice $Z(l)$ et donner les résultats à la matrice $A(k,l)$;*Fin.**Fin.*Diviser la matrice A par la matrice C et donner le résultat à la matrice B ;*Pour* $q = 1, \dots, 10$;Calculer $B(q) * Z(q) * \exp(((X_a(q,1) - X_a(1,1))^2 + (X_a(q,2) - X_a(1,2))^2) / (2 * (0,15)^2))$ et donner le résultat à $F(q)$.*Fin.*Calculer la somme de tous les éléments de la matrice F et donner les résultats à la matrice H ;Calculer le paramètre $b = Z(1) - H$;*Pour* $p = 1, \dots, 10$;

Calculer la matrice

$$f(p) = B(p) * Z(p) * \exp(-((X_a(p,1) - x(1))^2 + (X_a(p,2) - x(2))^2) / (2 * (0,15)^2));$$

*Fin.*Calculer la somme de la matrice f et donner les résultats à la matrice w ;

$$F = w + b$$

$$\begin{cases} \text{Sgn}\{F\} = +1 & x \in \Omega_1 \\ \text{Sgn}\{F\} = -1 & x \in \Omega_2 \end{cases}$$

Tableau 5.1 : Algorithme SVM non linéaire [XIAOHUI 13].

En remplaçant le produit scalaire par la fonction noyau, nous construisons un algorithme de classification SVM non linéaire. Comme nous pouvons le voir dans le tableau 5.1 - en plus du calcul de la matrice - le calcul de la fonction exponentielle est introduit.

Le paramètre σ dans la fonction de base radiale gaussienne est mis à 0,15 dans notre conception.

5.3.2 Modules informatiques pour SVM non-linéaire

L'architecture du classifieur SVM non linéaire est composée de plusieurs modules de calcul (des additionneurs, des multiplicateurs, module qui calcule les carrés et module qui calcule l'exponentiel [XIAOHUI 13]. La figure 5.4 présente l'architecture générale du classifieur SVM non linéaire.

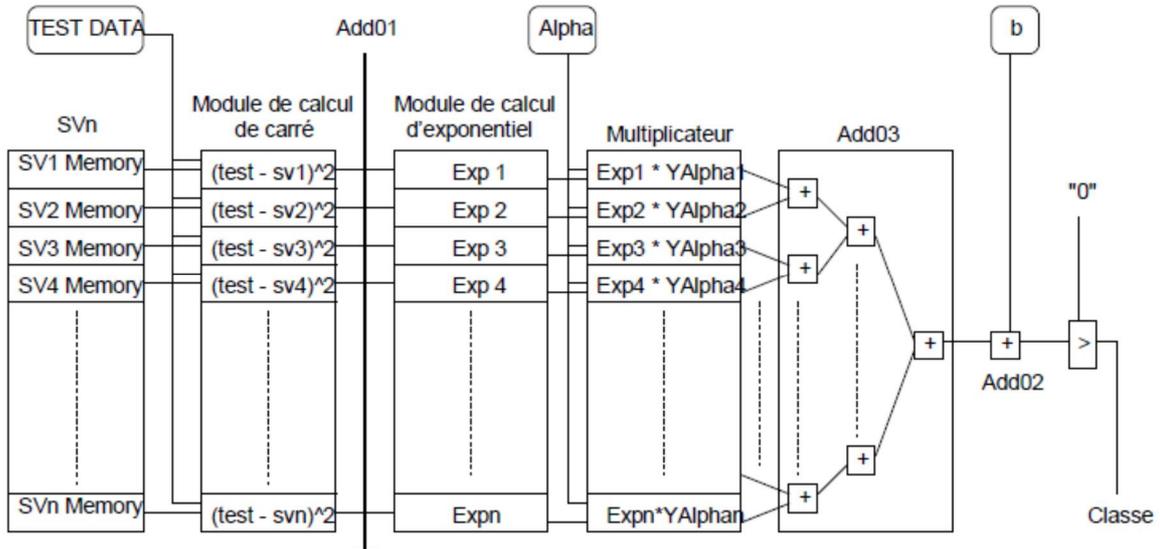


Figure 5.4 : Architecture du classifieur SVM non linéaire.

Add01 : est un additionneur entier de 18 bits pour additionner les résultats des modules de calcul carrés qui montre le carré de la différence entre le vecteur de support et le point de test. La vue externe d'un additionneur complet est la suivante :

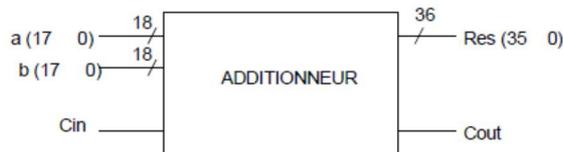


Figure 5.5 : Interface de l'additionneur.

Dans notre cas d'étude en utilise un additionneur de 18 bits dont le schéma correspondant est :

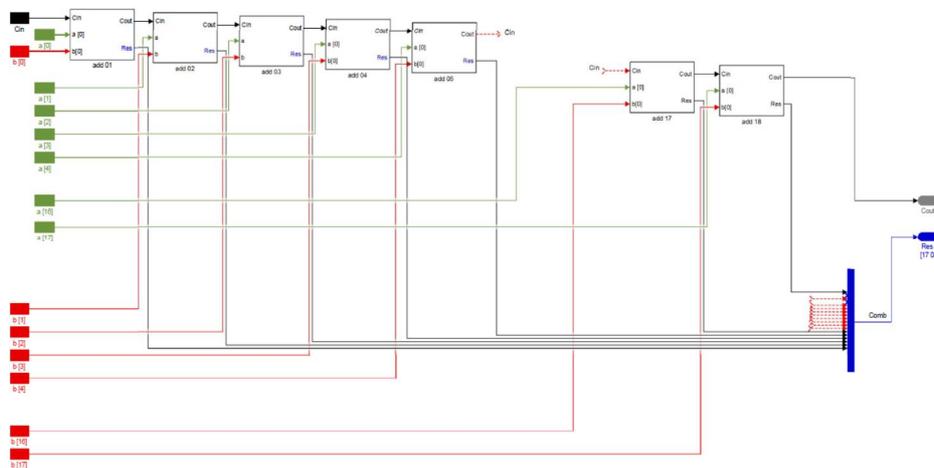


Figure 5.6: Représentation d'un additionneur 18bits.

Le code VHDL correspondant à ce schéma est :

Additionneur

```

LIBRARY IEEE;
USE IEEE.std_logic_1164.ALL;
ENTITY add_18 IS
  pORT ( Cin : in std_logic;
  a, b : in std_logic_vector (17 downto 0);
  Cout: out std_logic;
  Res : inout std_logic_vector (17 downto 0)
  );
END add_18;
ARCHITECTURE arch_add_18 OF add_18 IS
  signal Cout0, Cout1, Cout2, Cout3, Cout4, Cout5, Cout6, Cout7, Cout8, Cout9, Cout10, Cout11, Cout12,
  Cout13, Cout14, Cout15, Cout16, Cout17: std_logic;
  component add_1
  PORT (a,b,Cin:in std_logic;
  Cout,Res:out std_logic);
  end component;
  Begin
  U1:add_1
  port map(a=>a(0), b=>b(0),Res=>Res(0),Cin=>Cin, Cout=>Cout0);
  U2:add_1
  port map(a=>a(1), b=>b(1),Res=>Res(1),Cin=>Cout0, Cout=>Cout1);
  U3:add_1
  port map(a=>a(2), b=>b(2),Res=>Res(2),Cin=>Cout1, Cout=>Cout2);
  U4:add_1
  port map(a=>a(3), b=>b(3),Res=>Res(3),Cin=>Cout2, Cout=>Cout3);
  U5:add_1
  port map(a=>a(4), b=>b(4),Res=>Res(4),Cin=>Cout3, Cout=>Cout4);
  U6:add_1
  port map(a=>a(5), b=>b(5),Res=>Res(5),Cin=>Cout4, Cout=>Cout5);
  U7:add_1
  port map(a=>a(6), b=>b(6),Res=>Res(6),Cin=>Cout5, Cout=>Cout6);
  U8:add_1
  port map(a=>a(7), b=>b(7),Res=>Res(7),Cin=>Cout6, Cout=>Cout7);
  U9:add_1
  port map(a=>a(8), b=>b(8),Res=>Res(8),Cin=>Cout7, Cout=>Cout8);
  U10:add_1
  port map(a=>a(9), b=>b(9),Res=>Res(9),Cin=>Cout8, Cout=>Cout9);

```

```

U11:add_1
port map(a=>a(10), b=>b(10),Res=>Res(10),Cin=>Cout9, Cout=>Cout10);
U12:add_1
port map(a=>a(11), b=>b(11),Res=>Res(11),Cin=>Cout10, Cout=>Cout11);
U13:add_1
port map(a=>a(12), b=>b(12),Res=>Res(12),Cin=>Cout11, Cout=>Cout12);
U14:add_1
port map(a=>a(13), b=>b(13),Res=>Res(13),Cin=>Cout12, Cout=>Cout13);
U15:add_1
port map(a=>a(14), b=>b(14),Res=>Res(14),Cin=>Cout13, Cout=>Cout14);
U16:add_1
port map(a=>a(15), b=>b(15),Res=>Res(15),Cin=>Cout14, Cout=>Cout15);
U17:add_1
port map(a=>a(16), b=>b(16),Res=>Res(16),Cin=>Cout15, Cout=>Cout16);
U18:add_1
port map(a=>a(17), b=>b(17),Res=>Res(17),Cin=>Cout16, Cout=>Cout17);
END arch_add_18;

```

Tableau 5.2 : Code VHDL d'un additionneur complet 18bits.

Les résultats obtenus après simulation sont :

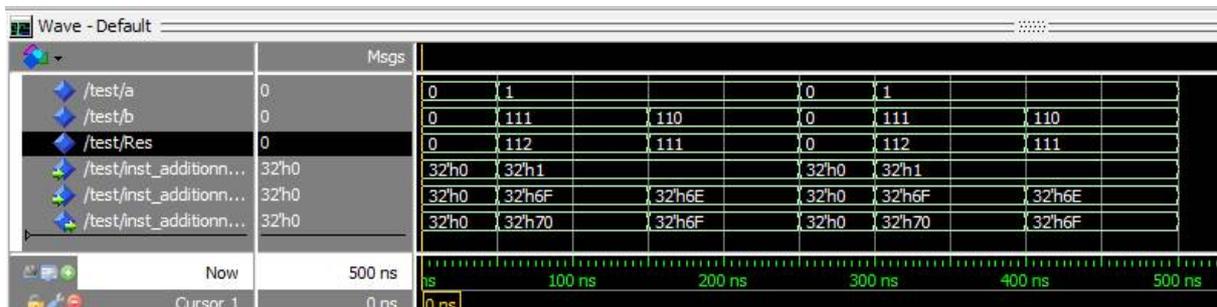


Figure 5.7 : Chronogramme de simulation d'une opération d'addition.

Add02 : est un additionneur à virgule fixe de 18 bits; il additionne b et le total des multiplicateurs, et la précision est de $1/2^{14}$.

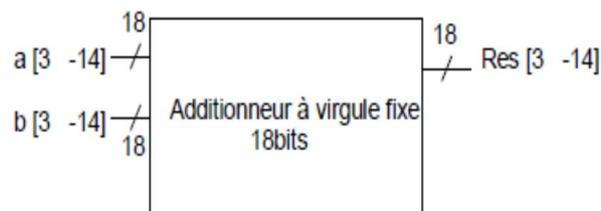


Figure 5.8 : Interface d'un additionneur à virgule fixe.

Le code VHDL correspondant à ce schéma est :

Additionneur à virgule fixe

```
library ieee;
use ieee.std_logic_1164.all;
use ieee.numeric_std.all;
use ieee.fixed_pkg.all;
entity add02 is
port (
  a,b : in sfixed(3 downto -14);
  Res : out sfixed(3 downto -14)
);
end add02;
ARCHITECTURE rtl OF add02 IS
begin
  Res <= a + b;
end architecture rtl;
```

Tableau 5.3 : Code VHDL d'un additionneur à virgule fixe 18bits.

Add03 : est un additionneur de 18bit, il résume les résultats des multiplicateurs, et la précision est de $1/2^{14}$.

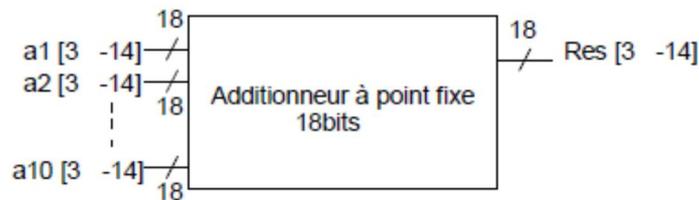


Figure 5.9 : Interface d'un additionneur à point fixe.

Le code VHDL correspondant est :

Additionneur à point fixe

```
library ieee;
use ieee.std_logic_1164.all;
use ieee.numeric_std.all;
use ieee.fixed_pkg.all;
entity add03 is
port (
  a1,a2,a3,a4,a5,a6,a7,a8,a9,a10,a11,a12,a13: in sfixed(3 downto -14);
  Res : out sfixed(3 downto -14)
);
end add03;
ARCHITECTURE rtl OF add03 IS
begin
  Res <= a1+a2+a3+a4+a5+a6+a7+a8+a9+a10+a11+a13;
end architecture rtl;
```

Tableau 5.4 : Code VHDL d'un additionneur à point fixe 18bits.

Multiplicateur : est un multiplicateur à virgule de 18 bits; il multiplie les résultats du calculateur d'exponentiel par le paramètre $\gamma\alpha$.

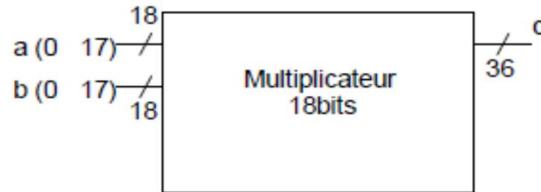


Figure 5.10 : Interface de multiplicateur.

Le code VHDL correspondant est :

```

Multiplicateur
library ieee;
use ieee.std_logic_1164.all;
use ieee.numeric_std.all;
use ieee.fixed_pkg.all;
entity mult_18 is
port (
  yalpha,exp : in sfixed(3 downto -14);
  Res : out sfixed(3 downto -14)
);

end mult_18;
ARCHITECTURE rtl OF mult_18 IS
begin
  Res <= exp * yalpha;
end architecture rtl;

```

Tableau 5.5 : Code VHDL d'un Multiplicateur à virgule fixe 18bits.

Le code de Test de Multiplicateur est le suivant :

```

Testbench Multiplicateur
Library IEEE;
use ieee.std_logic_1164.all;
use ieee.numeric_std.all;
use ieee.fixed_pkg.all;
ENTITY testmult is
end entity;
architecture arch of testmult is
signal yalpha,exp : sfixed(3 downto -14);
Signal Res: sfixed (4 downto -31);
component mult_16 is
Port
(yalpha : in sfixed(3 downto -14);
exp : in sfixed(3 downto -14);
Res: out sfixed(4 downto -31));
end component;
begin
inst_multi_en_test: mult_16 port map ( yalpha, exp , Res);
Process
begin
yalpha <= ("000000000000000000");
exp <= ("000000000000000000");
wait for 50 ns;
yalpha <= ("000000000000000001");
exp <= ("0000000000000000111");
wait for 100 ns;
yalpha <= ("000000000000000001");

```

```

exp <= ("0000000000000000110");
wait for 200 ns;
yalpha <= ("0000000000000000001");
exp <= ("0000000000000000100");
end process;
end arch;

```

Tableau 5.6 : Code de test Multiplicateur.

Après exécution de la simulation, les résultats obtenus sont présentés via le chronogramme de simulation ci-après.

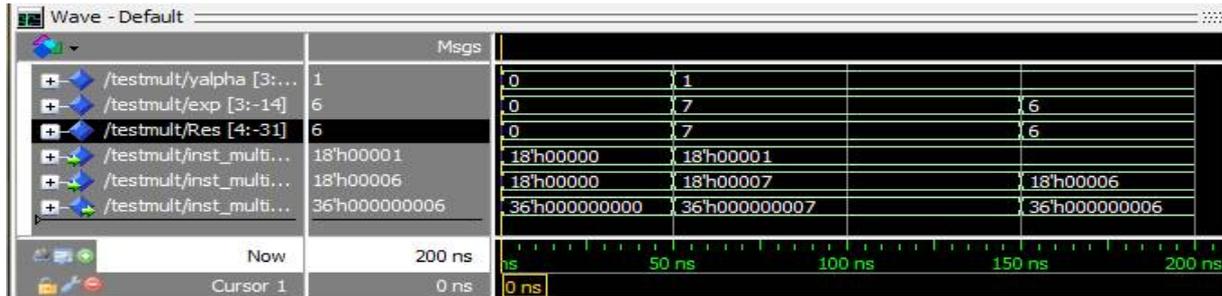


Figure 5.11 : Chronogramme de simulation d'une opération de multiplication.

Carré est un module de calcul carré qui détermine le carré de la différence entre le vecteur de support et le point de test.

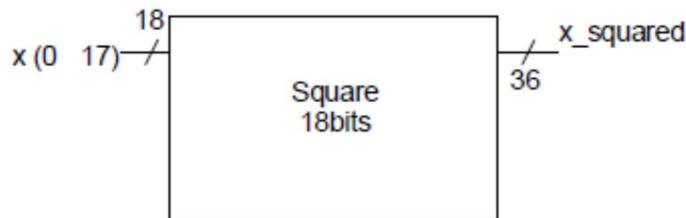


Figure 5.12 : Interface de module de calcul carré.

Le code VHDL correspondant est :

```

Carré
library ieee;
use ieee.std_logic_1164.all;
use ieee.numeric_std.all;
use ieee.std_logic_arith.all;
entity square is
port (
a,b      : in  integer range 0 to 1500;
x_squared : out integer range 0 to 1500
);
end square;
architecture rtl of square is
begin
x_squared <= (a-b)*(a-b);
end architecture rtl;

```

Tableau 5.7 : Code VHDL d'un module de calcul carré.

Le chronogramme de simulation d'une opération carré est illustré via la figure 5.13 :



Figure 5.13 : Chronogramme de simulation d'une opération carré.

Exp est un module de calcul piloté par une table qui montre le résultat du calcul de $\exp(-x/0,15)$ Le code VHDL correspondant est :

```

Exp
library ieee;
use ieee.std_logic_1164.all;
use ieee.std_logic_arith.all;
use ieee.fixed_pkg.all;
entity exp_cal is
port ( a: in integer range 0 to 1500;
      b: out sfixed(3 downto -14));
end exp_cal;
architecture behavior of exp_cal is
begin
with a select
b<= "00000000000000000000" when 0 ,
"000000111111110101" when 1 ,
"00000000111111010" when 2 ,
"00000000001111110" when 3 ,
"000000000000111101" when 4 ,
"000000000000001111" when 5 ,
"000000000000000011" when 6 ,
"000000000000000000" when others;
end behavior;

```

Tableau 5.8 : Code VHDL d'un module de calcul d'exponentiel.

Les résultats de testbench sont affichés via la figure suivante :

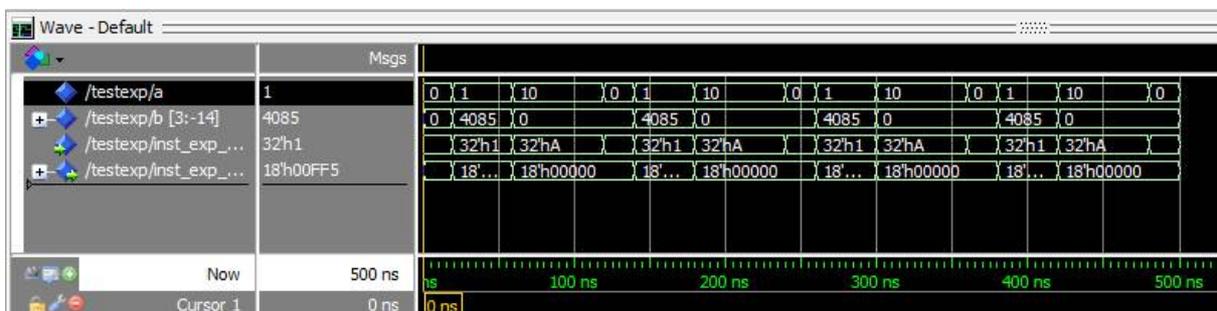


Figure 5.14 : Chronogramme de simulation d'une opération de calcul d'exponentiel.

Le paquet de points fixes (fixed_pkg.all) est utilisé pour construire les unités de calcul. En appliquant un ensemble de points fixes à des unités de calcul conçues, la précision de calcul

peut être satisfaite tandis que la consommation de ressources de calcul est limitée dans une plage acceptable. Après une cartographie appropriée, les unités de calcul assemblées fonctionneront en synergie pour réaliser le système de classification. Chaque unité de calcul de la même hiérarchie travaille en parallèle pour améliorer l'efficacité des performances du système. En remplaçant le produit scalaire par la fonction noyau, nous construisons un algorithme de classification SVM non linéaire. Comme nous pouvons le voir dans le tableau 5.1 le calcul de la fonction exponentielle est introduit [XIAOHUI 13]. L'architecture FPGA de classeur SVM non linéaire est la suivante :

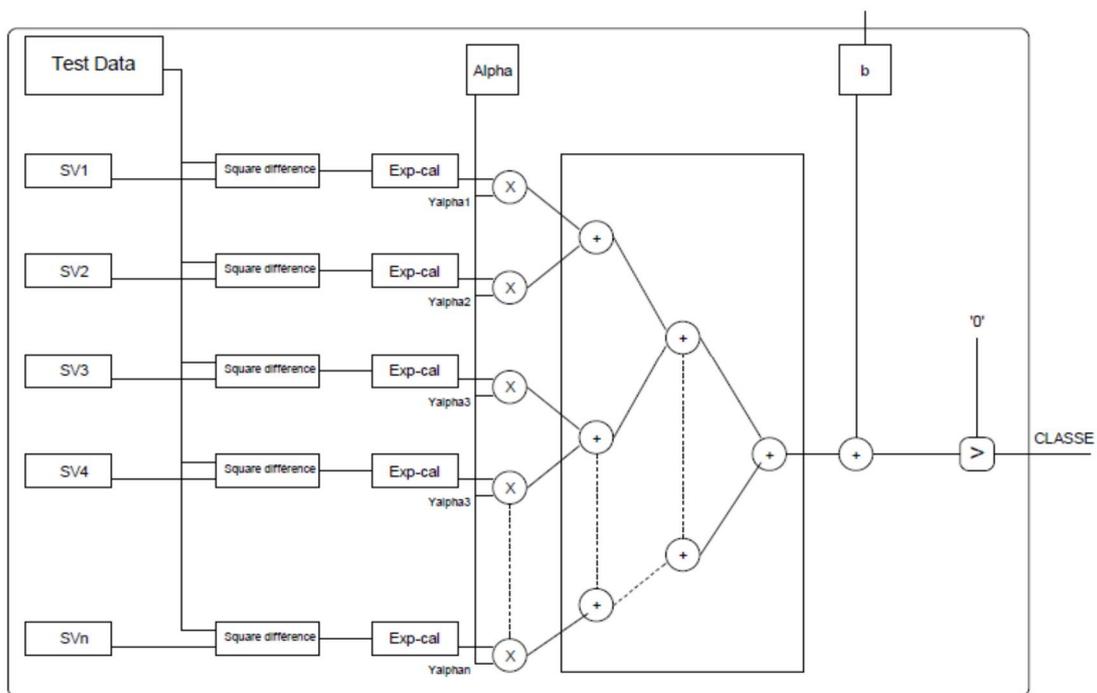


Figure 5.15 : Architecture FPGA du classificateur SVM non linéaire [XIAOHUI 13].

Les données d'apprentissage sont chargées dans les mémoires FPGA internes via SV, puis, avec les données de test, elles sont diffusées en unités de différences carrées. Ces unités calculent la différence de carrés des points de tests et des points d'entraînement. Ensuite, les résultats sont envoyés aux unités exponentielles qui effectuent le calcul de la fonction exponentielle afin d'atteindre la fonction noyau. Ces unités d'exponentielles fonctionnent comme des modules pilotés par table. Non seulement ils remplissent le calcul de la fonction exponentielle mais aussi le reste de la fonction de base radiale gaussienne incluant les paramètres [XIAOHUI 13].

Le code de mappage de niveau supérieur est indiqué dans le tableau 5.9.

Algorithme : SVM non linéaire

```
LIBRARY IEEE;
USE IEEE.STD_LOGIC_1164.ALL;
USE IEEE.STD_LOGIC_ARITH.ALL;
USE IEEE.FIXED_PKG.ALL;
```

```
ENTITY nonlinear_SVM IS
```

```

port(sv1,sv2,sv3,sv4,sv5,sv6,
sv7,sv8,sv9,sv10,sv11,sv12,
sv13,sv14,sv15,sv16,sv17,sv18,
sv19,sv20,sv21,sv22,sv23,sv24,sv25,x1,x2: in integer range 0 to 1500;
yalpha1,yalpha2,yalpha3,yalpha4,yalpha5,yalpha6,yalpha7,
yalpha8,yalpha9,yalpha10,yalpha11,yalpha12,yalpha13,b: in sfixed(3
downto -14));
Res: out sfixed(3 downto -14));
end nonlinear_SVM;

```

architecture structure of nonlinear_SVM is

```

component add01 is
port(a, b: in integer range 0 to 17;
Res: out integer range 0 to 17);
end component;

```

```

component mult_16 is
port(yalpha,exp: in sfixed(3 downto -14));
Res: out sfixed(3 downto -14));
end component;

```

```

component square is
port(a, b: in integer range 0 to 1500;
Res: out integer range 0 to 1500);
end component;

```

```

component exp_cal is
port ( a: in integer range 0 to 1500;
b: out sfixed(3 downto -14));
end component;

```

```

component add02 is
port(a, b: in sfixed(3 downto -14));
Res: out sfixed(3 downto -14));
end component;

```

```

component add03 is
port(a1,a2,a3,a4,a5,a6,a7,
a8,a9,a10,a11,a12,a13: in sfixed(3 downto -14));
Res: out sfixed(3 downto -14));
end component;

```

```

signal s1,s2,s3,s4,s5,s6,s7,s8,s9,s10,
s11,s12,s13,s14,s15,s16,s17,s18,
s19,s20,s21,s22,s23,s24,s25,B1,B2,B3,B4,B5,B6,B7,B8,
B9,B10,B11,B12,B13: integer range 0 to 1500;
signal W1,W2,W3,W4,W5,W6,W7,W8,
W9,W10,W11,W12,W13,Z1,Z2,Z3,Z4,Z5,Z6,Z7,Z8,
Z9,Z10,Z11,Z12,Z13,e1:sfixed(3 downto -14);

```

```
begin
I1:square port map(sv1,x1,s1);
I2:square port map(sv2,x2,s2);
I3:square port map(sv3,x1,s3);
I4:square port map(sv4,x2,s4);
I5:square port map(sv5,x1,s5);
I6:square port map(sv6,x2,s6);
I7:square port map(sv7,x1,s7);
I8:square port map(sv8,x2,s8);
I9:square port map(sv9,x1,s9);
I10:square port map(sv10,x2,s10);
I11:square port map(sv11,x1,s11);
I12:square port map(sv12,x2,s12);
I13:square port map(sv13,x1,s13);
I14:square port map(sv14,x2,s14);
I15:square port map(sv15,x1,s15);
I16:square port map(sv16,x2,s16);
I17:square port map(sv17,x1,s17);
I18:square port map(sv18,x2,s18);
I19:square port map(sv19,x1,s19);
I21:square port map(sv20,x2,s20);
I22:square port map(sv21,x1,s21);
I23:square port map(sv22,x2,s22);
I24:square port map(sv23,x1,s23);
I25:square port map(sv24,x2,s24);
I26:square port map(sv25,x1,s25);
I27:add01 port map(s1,s2,B1);
I28:add01 port map(s3,s4,B2);
I29:add01 port map(s5,s6,B3);
I30:add01 port map(s7,s8,B4);
I31:add01 port map(s9,s10,B5);
I32:add01 port map(s11,s12,B6);
I33:add01 port map(s13,s14,B7);
I34:add01 port map(s15,s16,B8);
I35:add01 port map(s17,s18,B9);
I36:add01 port map(s19,s20,B10);
I37:add01 port map(s20,s21,B11);
I38:add01 port map(s22,s23,B12);
I40:add01 port map(s24,s25,B13);
I41:exp_cal port map(B1,W1);
I42:exp_cal port map(B2,W2);
I43:exp_cal port map(B3,W3);
I44:exp_cal port map(B4,W4);
I45:exp_cal port map(B5,W5);
I46:exp_cal port map(B6,W6);
I47:exp_cal port map(B7,W7);
I48:exp_cal port map(B8,W8);
I49:exp_cal port map(B9,W9);
I50:exp_cal port map(B10,W10);
I51:exp_cal port map(B11,W11);
```

```

I52:exp_cal port map(B12,W12);
I53:exp_cal port map(B13,W13);
I54:mult_16 port map (W1,yalpha1,Z1);
I55:mult_16 port map (W2,yalpha2,Z2);
I56:mult_16 port map (W3,yalpha3,Z3);
I57:mult_16 port map (W4,yalpha4,Z4);
I58:mult_16 port map (W5,yalpha5,Z5);
I59:mult_16 port map (W6,yalpha6,Z6);
I60:mult_16 port map (W7,yalpha7,Z7);
I61:mult_16 port map (W8,yalpha8,Z8);
I62:mult_16 port map (W9,yalpha9,Z9);
I63:mult_16 port map (W10,yalpha10,Z10);
I64:mult_16 port map (W11,yalpha11,Z11);
I65:mult_16 port map (W12,yalpha12,Z12);
I66:mult_16 port map (W13,yalpha13,Z13);
I67:add03 port map (Z1,Z2,Z3,Z4,Z5,Z6,Z7,Z8,Z9,Z10,Z11,Z12,Z13,e1);
I68:add02 port map (e1,b,Res);
end architecture structure ;

```

Tableau 5.9 : Mappage d'architecture de niveau supérieur de la classification SVM non linéaire.

Le module piloté par table a permis d'économiser une grande quantité de ressources informatiques en transférant des calculs flottants massifs dans un mécanisme de recherche de table rapide.

En raison des propriétés mathématiques de la fonction de base radiale gaussienne, le tableau peut être limité à une taille acceptable. L'arbre d'addition et les multiplicateurs construisent les fonctions de classification avec le paramètre b .

Les identités de classe des données de test seront affichées après l'unité de comparaison. Les unités de calcul dans l'architecture utilisent des données binaires entières et des points binaires à 18 points signés pour effectuer le calcul, avec 1 bit de signe, 2 bits avant la virgule décimale et 14 bits après la virgule décimale.

5.4 Résultats

La simulation utilisée est la plate-forme Modelsim.PE Student Edition 10.4a. C'est une version gratuite offerte pour les étudiants. Ce simulateur est très convivial et facile à utiliser au travers de ses menus déroulants, il est recommandé par tous les modules FPGA (Intel, Arria, Cyclone...etc).

Le dispositif ciblé pour implémenter l'architecture SVM non linéaire proposée est le Cyclone d'Altera II, elle est conçue sur un processus SRAM 1,2 V à couche de cuivre. La fiche technique détaillée est présentée en annexe (Cf. Annexe A.3).

La figure 5.16 présente l'architecture du FPGA Cyclone II.

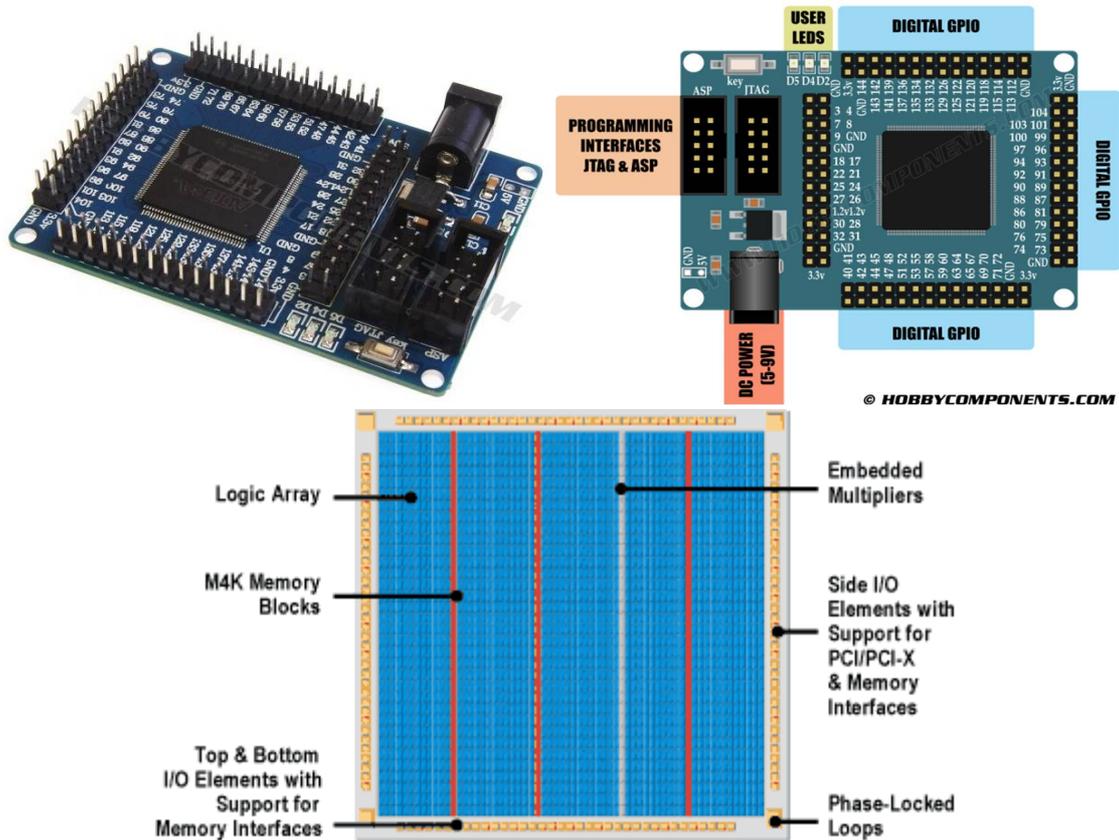


Figure 5.16 : Architecture du cyclone II

La figure 5.17 présente la surface principale de simulateur Modelsim PE Student Edition 10.4.

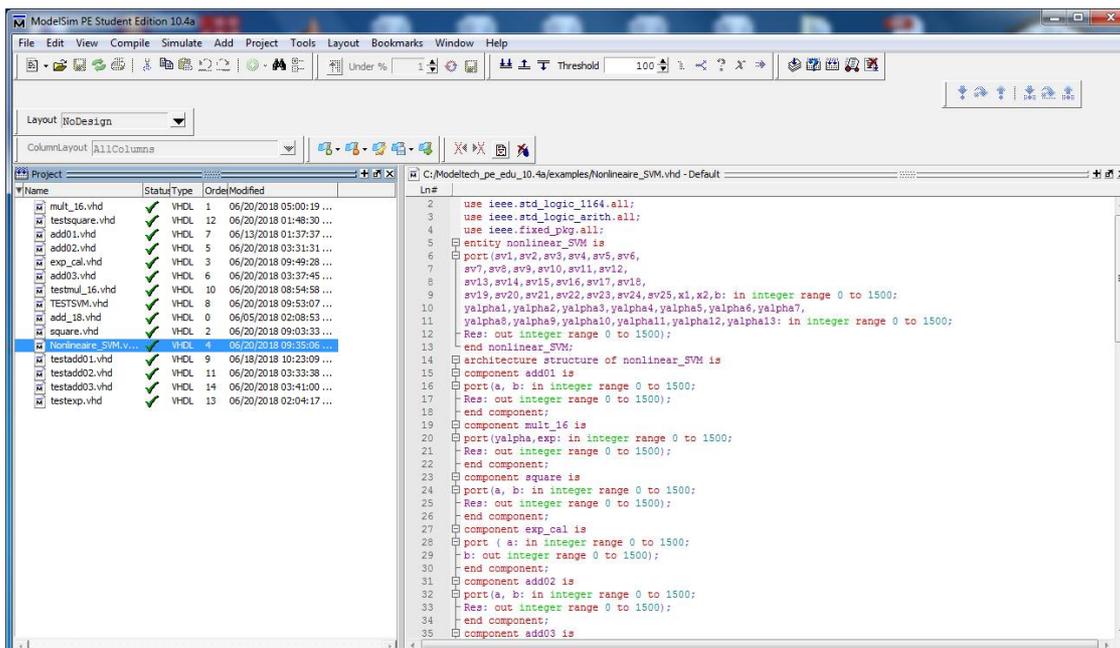


Figure 5.17 : Interface simulateur Modelsim PE Student Edition 10.4a.

Pour tester notre programme SVM non linéaire, nous avons classifié une observation OB1 correspond à un fonctionnement sans défaut, et une observation OB2 dont les paramètres correspondent à un fonctionnement en présence d'un défaut de compression. Après simulation de programme de testbench de l'architecture SVM, nous avons obtenu les résultats suivants :

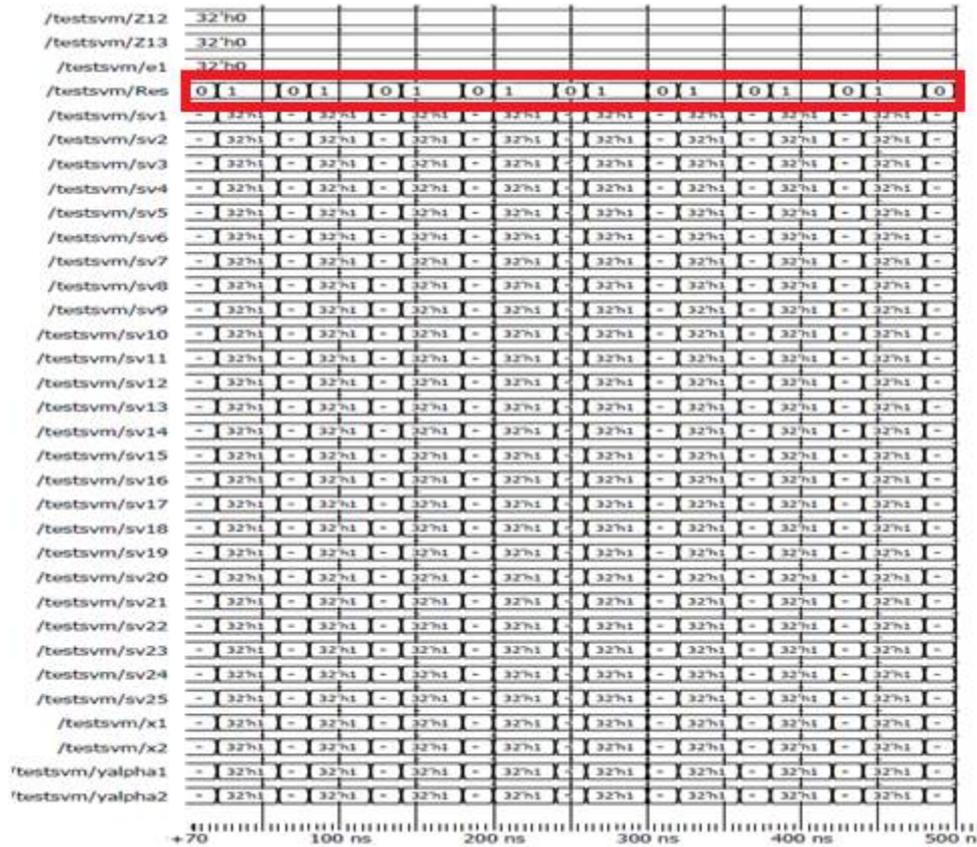


Figure 5.18 : Chronogramme de simulation de testbench SVM non linéaire.

D'après la figure 5.17, nous constatons que les deux observations sont bien classées, ce qui permet de conclure que l'architecture VHDL de l'algorithme SVM non linéaire est en mesure de fournir une classification des différents modes de fonctionnement du moteur.

L'erreur de calcul est d'environ 0,0038 %, le tableau suivant illustre les performances de classificateur SVM non linéaire.

| | Taux de reconnaissance | Erreur de classification |
|------------|------------------------|--------------------------|
| OB1 | 99,99 | 0,0038 |
| OB2 | | |

Tableau 5.10 : Taux de classification obtenue pour les deux observations de test.

D'après les résultats du tableau 5.10, nous obtenons des taux de reconnaissance élevées pour les deux observations de test que nous avons choisis, la figure 5,19 illustre les résultats et l'erreur de classification des deux observations choisis.

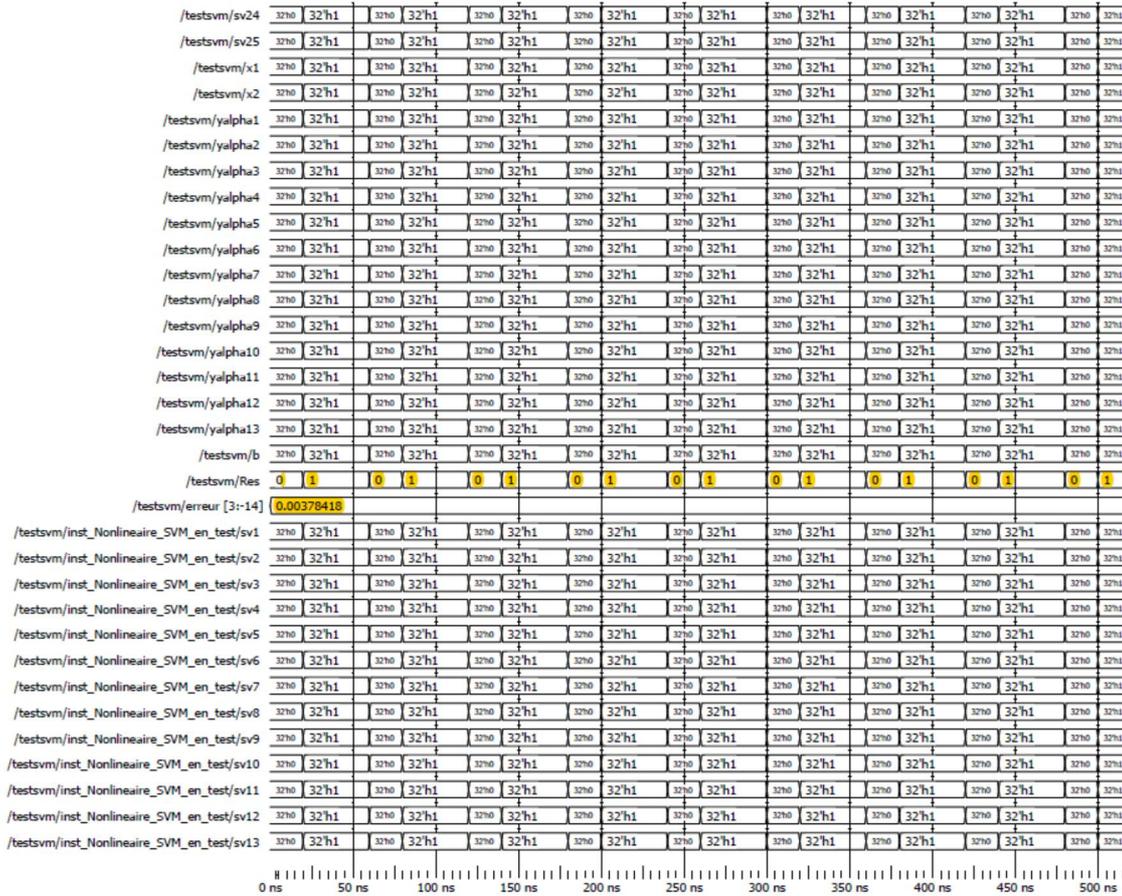


Figure 5.19 : Résultat et erreur de classification des observations choisis.

À partir de la figure 5,19, le taux d'erreur pour les deux observations testé et de 0,0038 %, la performance du classificateur SVM satisfait aux exigences proposées. En peut présenter les résultats sous forme d'histogramme comme montre la figure 5.20.

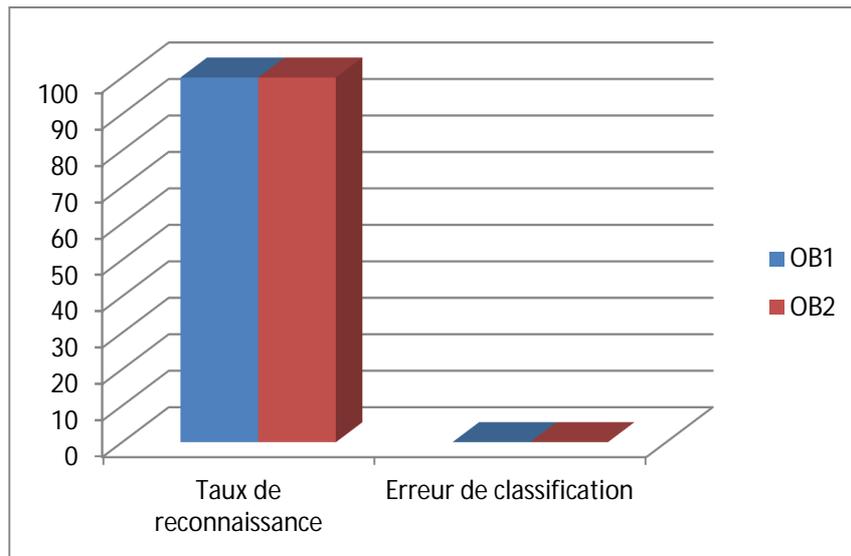


Figure 5.20 : Taux de reconnaissance et erreur de classification des observations de test.

Nous avons testé la classification de plusieurs observations à la fois (05 observations sans défaut et 05 autres observations avec défaut), le délai de test est de 1000ns, chaque observation et testé après 100ns, les résultats de classification sont présenter via la figure suivante :

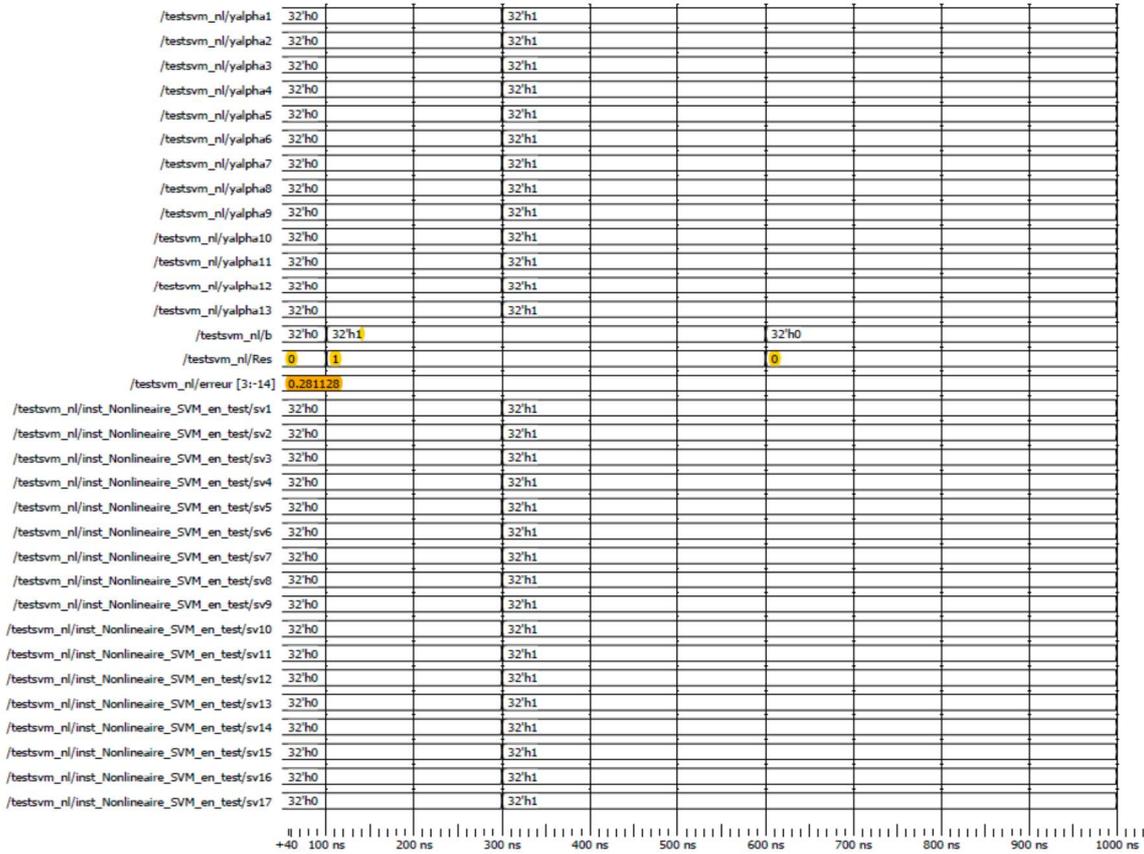


Figure 5.21 : Résultat de classification des observations en test.

Les résultats de classifications des différentes observations, confirment l’efficacité de classificateur SVM_FPGA. Le taux de classification pour le deuxième test et égale à 0,281128 %, le tableau suivant résume les résultats de test des différentes observations :

| | Taux de reconnaissance | Erreur de classification |
|----------------|------------------------|--------------------------|
| Observation 1 | 99,72 | 0,28 |
| Observation 2 | | |
| Observation 3 | | |
| Observation 4 | | |
| Observation 5 | | |
| Observation 6 | | |
| Observation 7 | | |
| Observation 8 | | |
| Observation 9 | | |
| Observation 10 | | |

Tableau 5.11 : Taux de classification obtenue pour les différentes observations en test.

Pour bien présenter le taux de classification et l'erreur de classification, nous présentons les résultats sous forme d'histogramme.

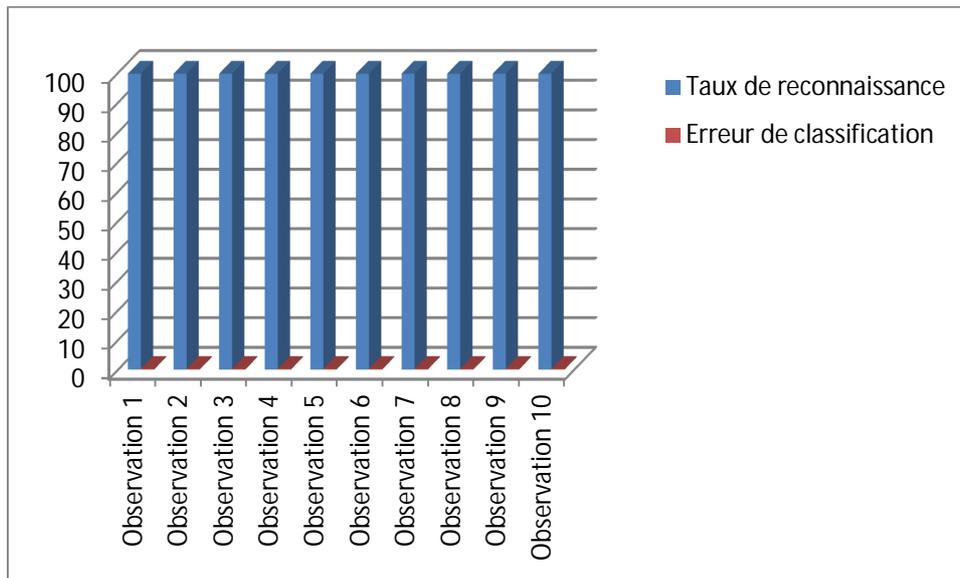


Figure 5.22 : Taux de reconnaissance et erreur de classification des différentes observations

5.5 Conclusion

Ce chapitre présente un système de classification SVM basé FPGA qui peut être utilisé pour la classification rapide des données. La performance du classificateur SVM en tant que système de classification à reconnaissance rapide satisfait aux exigences proposées. Pour le diagnostic du moteur diesel, les classificateurs SVM puissent fournir une détection rapide des modes de fonctionnement afin de protéger l'ensemble du sous-système du moteur diesel en temps réel. Les résultats de tests de l'architecture SVM basé FPGA confirment le fonctionnement correct de classifieur.

CONCLUSION GÉNÉRALE

Dans notre travail, Nous avons présenté deux méthodologies de diagnostic de défaillances dans un moteur diesel (une méthodologie basée sur l'utilisation de reconnaissance des formes floues et l'autre méthodologie utilise la technique SVM).

Pour but d'obtenir une base de données relative au fonctionnement du moteur diesel, nous avons établi une synthèse des modèles décrits dans la littérature afin de construire un modèle d'un moteur diesel dernière génération, qui est un modèle de connaissance. Il est difficile d'obtenir des paramètres depuis la littérature car les travaux sur le moteur diesel sont réalisés sous contrat. La comparaison des résultats de simulation du moteur diesel sous MATLAB/SIMULINK des modèles (avec et sans défaut), nous permettons de détecter le défaut sans nous donner d'information sur sa localisation.

Les résultats issus de la simulation sous MATLAB/SIMULINK sont utilisés pour mettre en œuvre un système de diagnostic basé sur l'utilisation de la reconnaissance des formes floues pour nous permettre de détecter et d'isoler les défauts. Le programme développé sous MATLAB a été appliqué avec succès, il nous a permis de déterminer les différents modes de fonctionnement du moteur qui sont au nombre de cinq (fonctionnement normal, fonctionnement en présence d'un défaut d'injection, fonctionnement en présence d'un défaut de soupape d'admission, fonctionnement en présence d'un défaut de fuite d'admission et fonctionnement en présence d'un défaut de compression).

La reconnaissance en ligne via cette méthode nous permet la surveillance en temps réel des modes de fonctionnement du moteur diesel. Elle nous permet de connaître les situations correspondant aux modes de dysfonctionnement en les comparants à un mode normal de fonctionnement.

Dans le but de valider les résultats obtenus par la reconnaissance des formes floue, nous avons présenté une deuxième approche de diagnostic du moteur diesel basée sur l'utilisation d'une méthode appelée Machine à supports de vecteur. Cette méthode de diagnostic a été appliquée sur l'ensemble des données relatives au fonctionnement du moteur diesel, les résultats obtenus ont démontré l'efficacité de la technique SVM dans la détermination des différents modes de fonctionnement du moteur. Les deux méthodes de diagnostic ont déterminé d'une façon similaire tous les modes de fonctionnement du moteur diesel.

Finalement nous avons présenté l'architecture FPGA du classifieur SVM non linéaire, qui peut être utilisé pour la classification rapide des données. Les résultats de simulation montrent que la mise en œuvre FPGA du système de classification SVM fonctionne correctement.

Pour les travaux ultérieurs, nous implémentant l'architecture SVM non linéaire sur une carte embarquée Cyclone II d' Altera.

ANNEXE

A.1 Influence de la chute de pression sur la vitesse de rotation

Après une chute de la pression l'équation (4.20) devient :

$$m_{cyl} = \frac{(P_a - \Delta) \times \omega_d}{T_a} \times \frac{V_{cy} \times (\alpha_0 + \alpha_1 \times \omega_d + \alpha_2 \times \omega_d^2)}{4\pi} \quad (\text{A.1.1})$$

$$\lambda_d = \frac{m_{cyl}}{m_f} = \lambda - \frac{(P_a - \Delta) \times \omega_d}{T_a} \times \frac{V_{cy} \times (\alpha_0 + \alpha_1 \times \omega_d + \alpha_2 \times \omega_d^2)}{4\pi} \times \frac{1}{m_f} = \lambda - K \quad (\text{A.1.2})$$

$$\eta_{id} = a_\lambda + b_\lambda \times \lambda_d + c_\lambda \times \lambda_d^2 = K(a_\lambda + K - b_\lambda - 2c_\lambda \times K) \quad (\text{A.1.3})$$

$$\frac{d\omega_d}{dt} = \frac{1}{J\omega_d} \left(p_{ci} \times n_{id} \times m_f - P_b - \frac{1}{2} \frac{\omega_d^3}{J} \Delta \right) = \frac{d\omega}{dt} + \frac{(K(a_\lambda + K - b_\lambda - 2c_\lambda \times K))}{J\omega_d} p_{ci} \times m_f \quad (\text{A.1.4})$$

En observant l'équation (A.1.4), on remarque que le défaut peut entraîner une diminution ou une augmentation du régime moteur.

A.1.1 Listes des constantes

| Nom | Constantes | |
|-------------|--|-------------------------------------|
| | Description et valeur | Unité |
| α_0 | $7.73 \cdot 10^{-1}$ | Ø |
| α_1 | $1.54 \cdot 10^{-3}$ | s.rad ⁻¹ |
| α_2 | $2.94 \cdot 10^{-6}$ | S ² .rad ² |
| p_{ci} | Pouvoir calorifique du carburant [$4 \cdot 10^7$] | J.kg ⁻¹ |
| a_λ | $7.2 \cdot 10^{-2}$ | Ø |
| b_λ | $1.8 \cdot 10^{-4}$ | Ø |
| c_λ | $1.7 \cdot 10^{-4}$ | Ø |
| V_{cy} | Cylindre du moteur [$1.588 \cdot 10^{-3}$] | m ³ |
| P_b | Puissance de freinage [12] | W |
| i_0 | $2 \cdot 10^{-4}$ | Kg.s ⁻¹ |
| i_1 | $9.7785 \cdot 10^{-9}$ | Kg.rad ⁻¹ |
| i_2 | $2.1238 \cdot 10^{-6}$ | Kg.rad ⁻¹ |
| i_3 | $4.186 \cdot 10^{-8}$ | Kg.rad ⁻¹ |
| i_4 | $4.9877 \cdot 10^{-12}$ | Kg.rad ⁻² |
| c_m | Modèle du compresseur à vide [$1.5 \cdot 10^{-4}$] | Kg.rad ⁻¹ |
| C_p | Chaleur massique de l'air [10^3] | J.kg ⁻¹ .K ⁻¹ |
| P_{atm} | Pression atmosphérique [10^5] | Pa |
| γ | Coefficient adiabatique des gaz parfaits [1.4] | Ø |
| V_a | Volume d'admission [10^{-3}] | m ³ |
| r | Constante des gaz parfaits [1,4] | J.kg ⁻¹ .K ⁻¹ |

| | | |
|----------|--------------------------------------|-------------------------------------|
| T_a | Température d'admission [328] | K |
| O_1 | Modèle d'opacité [10] | \emptyset |
| O_2 | Modèle d'opacité [-1.258] | \emptyset |
| J | Moment d'inertie [0.12] | Kg.m^2 |
| Δ | Modèle solide en mouvement 10^{-4} | $\text{s.N}^{-1}.\text{m.rad}^{-2}$ |

Tableau A.1.1 : Listes des constantes

A.2 Transformation et sélection de l'information

Pour la réduction de l'espace de représentation nous avons utilisé une analyse en composante principale pour palier le problème de redondance et sélectionner les composantes pertinentes. L'analyse en composante principale a été appliquée sur les données de pression d'admission, la vitesse de rotation et les données d'émission polluantes.

A.2.1 ACP Sur les données de pression d'admission

Nous avons réalisé une A.C.P sur un ensemble de Cinq variables quantitatives représentant l'influence de quatre types de défauts sur la pression d'admission dans un moteur diesel. Après avoir importé les données dans le logiciel XLSTATE2009, nous avons calculé la matrice des données centrées et réduites afin de travailler avec la matrice de corrélations pour calculer les valeurs et les vecteurs propres.

STATISTIQUES ELEMENTAIRES

| VARIABLES | MOYENNES | ECARTS-TYPES |
|------------------------------|------------|--------------|
| Pression admission | 191336,571 | 24212,681 |
| Pad défaut injection | 189935,217 | 23777,991 |
| Pad défaut soupape admission | 208188,008 | 38224,126 |
| Pad défaut fuite admission | 183492,803 | 23448,440 |
| Pad défaut compression | 157688,849 | 44680,240 |

Tableau A.2.1 : Statistiques élémentaires (Données de pression d'admission)

Matrice Corrélation Pearson (n)

| | p_a | p_a injection | p_a soup adm | p_a fuit adm | p_a comp |
|-------------------|-------|-----------------|----------------|----------------|------------|
| p_a | 1 | | | | |
| p_a injection | 0,997 | 1 | | | |
| p_a soup adm | 0,817 | 0,772 | 1 | | |
| p_a fuit adm | 0,901 | 0,931 | 0,487 | 1 | |
| p_a compression | 0,222 | 0,294 | -0,380 | 0,621 | 1 |

Tableau A.2.2 : Matrice de corrélation Pearson (données de pression d'admission)

Valeurs propres, Variabilité et qualité cumulée des composantes principales

| | F1 | F2 | F3 | F4 | F5 |
|----------------|--------|--------|--------|--------|---------|
| Valeur propre | 3,545 | 1,453 | 0,002 | 0,000 | 0,000 |
| Variabilité(%) | 70,894 | 29,068 | 0,032 | 0,004 | 0,001 |
| % cumulé | 70,894 | 99,963 | 99,995 | 99,999 | 100,000 |

Tableau A.2.3 : Valeur propre, Variabilité et cumulé des composantes principales de la pression d'admission.

La valeur propre représente la variance des individus sur l'axe correspondant. Dans notre cas ont une variance de 3,545 sur le 1^{er} axe, 1,453 sur le 2^{ème} axe, 0,002 sur le 3^{ème} axe ... etc.

Cette information n'est pas facilement interprétable, nous allons exprimer chaque variance en valeur relative de la variance totale.

Dans notre exemple avec 5 variables initiales, les pourcentages de variation expliquée par les axes principaux sont donc respectivement :

$$100 \times (3,545 / 5) = 70,9\% ; 100 \times (1,453 / 5) = 29,06\%, \text{ etc. } \dots$$

Les différentes composantes étant non corrélées par construction, la part d'information expliquée par 2 axes données est égale à l'addition des parts expliqués par chaque axe.

$$70,894 + 29,068 = 99,962\% \text{ pour le plan 1-2}$$

$$0,032 + 0,004 = 0,036\% \text{ pour le plan 3-4}$$

... etc.

Vecteur Propre

| | F1 | F2 | F3 | F4 | F5 |
|--------------------------|-------|--------|--------|--------|--------|
| p_a Sans défaut | 0,528 | -0,084 | -0,350 | 0,724 | -0,259 |
| p_a défaut d'injection | 0,531 | -0,022 | 0,081 | -0,050 | 0,842 |
| p_a Soup d'admission | 0,401 | -0,543 | -0,318 | -0,607 | -0,272 |
| p_a fuite d'admission | 0,499 | 0,282 | 0,713 | -0,124 | -0,384 |
| p_a compression | 0,169 | 0,786 | -0,511 | -0,300 | -0,055 |

Tableau A.2.4 : Valeur propre

Les vecteurs propres contiennent les coefficients à affecter aux variables initiales et qui permettant le calcul des composantes principales. Pour notre cas la 1^{ère} composante principale s'obtient en faisant :

$$0,528 + 0,531 + 0,401 + 0,499 + 0,169$$

Pour un axe donné, les variables qui ont les plus forts coefficients en valeur absolue sont celles qui contribuent le plus d'information de cet axe, par exemple, ce sont la Pad Sans défaut, Pad défaut d'injection, Pad soup d'admission, Pad fuite d'admission qui ont contribué le plus à la formation du 1^{er} axe, c'est les deux variables Pad compression et Pad soup d'admission qui ont contribué le plus à la formation du 2^{ème} axe, ... etc.

En pratique, on s'intéresse rarement aux vecteurs propres. Pour interpréter les axes, on regarde surtout les corrélations entre les variables et les axes.

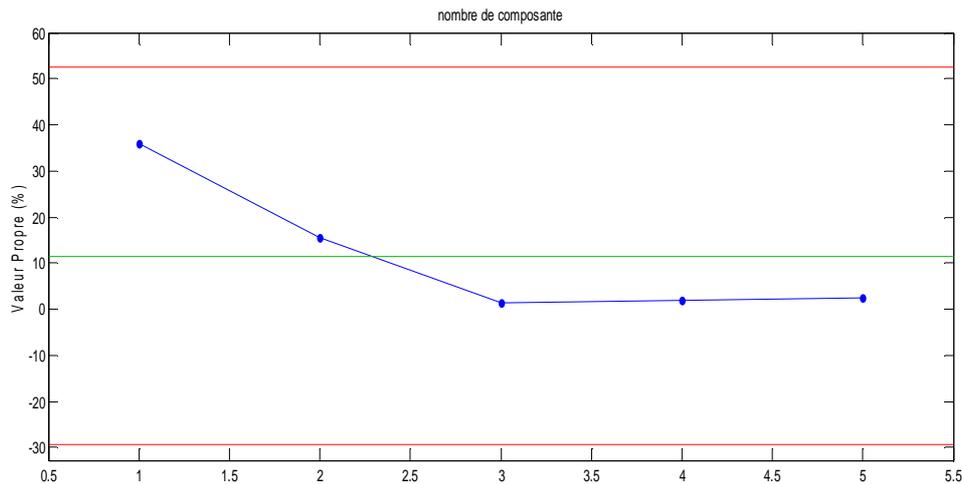


Figure A.2.1 : Valeur Propre en fonction de nombre de composante.

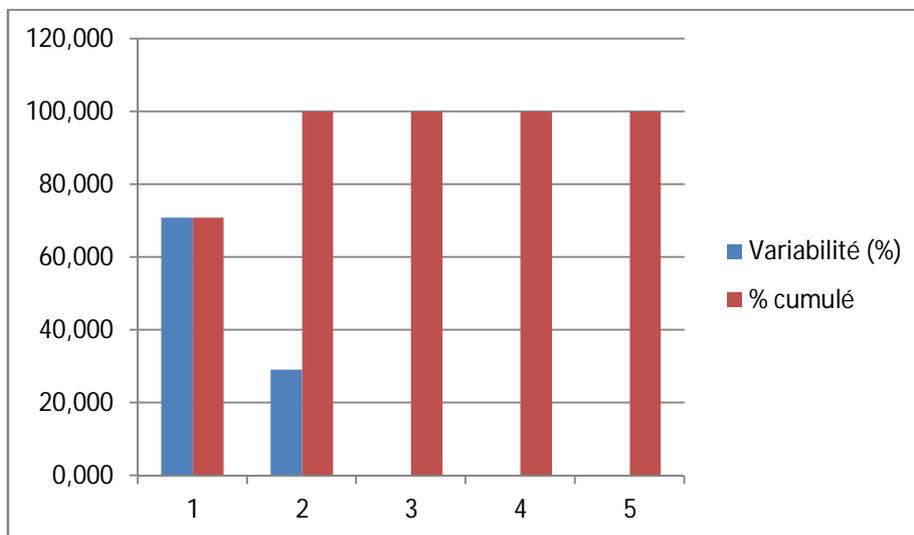


Figure A.2.2 : Variabilité et cumulé p_a .

La figure A.2.2 représente la quantité globale individuelle et cumulée de chaque composante principale. La quantité globale d'une composante principale mesure le pourcentage de l'inertie totale qui est expliquée par l'axe principal correspondant. Celle-ci se mesure par le ratio entre la valeur propre correspondante et le nombre de variables. Elle est considérée comme étant la proximité de la composante principale concernée par rapport à l'ensemble des variables de départ.

Interprétation

Choix du nombre d'axes à retenir

Nous utilisons pour cela le tableau A.2.6, le critère de Kaiser nous conduit à sélectionner deux axes, expliquant 99,96% de l'inertie totale du nuage. Ce qui est très bon. L'axe 1 retient 70,89% et l'axe 2 retient 29,07%, l'axe 3 retient 0,03%, l'axe 4 retient 0%, l'axe 5 retient 0%

Etude des variables :

| | F1 | F2 | F3 | F4 | F5 |
|--------------------------|-------|--------|--------|--------|--------|
| p_a (Sans défaut) | 0,995 | -0,101 | -0,014 | 0,010 | -0,002 |
| p_a défaut d'injection | 1,000 | -0,026 | 0,003 | -0,001 | 0,007 |
| p_a Soup d'admission | 0,755 | -0,655 | -0,013 | -0,008 | -0,002 |
| p_a fuite d'admission | 0,940 | 0,340 | 0,029 | -0,002 | -0,003 |
| p_a compression | 0,319 | 0,948 | -0,021 | -0,004 | 0,000 |

Tableau A.2. 5 : Corrélation entre les variables et les axes principaux

L'examen des corrélations entre les variables initiales et les axes principaux va nous permettre de répondre comment les variables sont-elles structurées ?

Le calcul et l'interprétation de ces corrélations se font de la même façon que pour 2 variables quantitatives quelconques. Par exemple 0,995 est le coefficient de corrélation entre la variable Pad sans défaut et l'axe 1 ; il s'obtient à partir des valeurs des individus pour la variable Pad sans défaut et pour la 1^{ère} composante principale. Pour nous aider à interpréter ces corrélations, le logiciel XLSTAT2009 nous donne le cercle de corrélation ci-dessous :

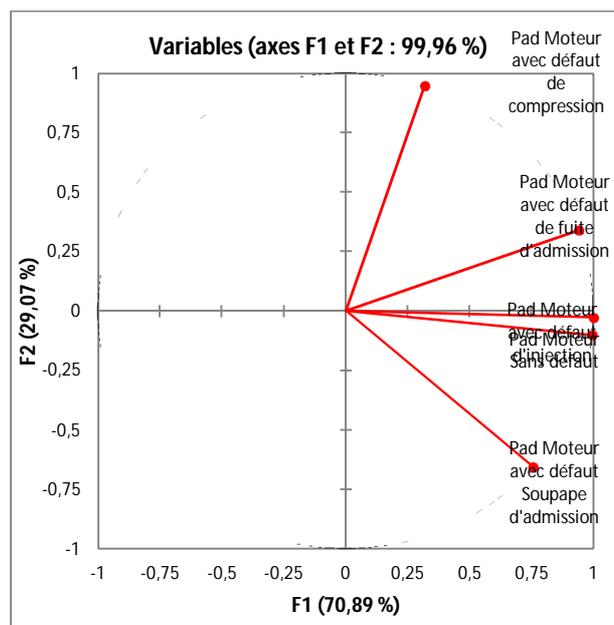


Figure A.2.3 : Cercle des Corrélations : Représentation des variables axe 1 et axe 2

La figure A.2.3 a été réalisée à partir des corrélations entre les 5 Variables initiales et les deux premières composantes principales.

Pour observer les individus, il ne reste qu'à construire les plans à partir des composantes principales les plus intéressantes, le plan principal 1-2 sera examiner en premier, par ce que c'est le plan sur lequel le maximum d'information est visible.

Dans notre cas les individus se répartissent sur l'ensemble du plan.

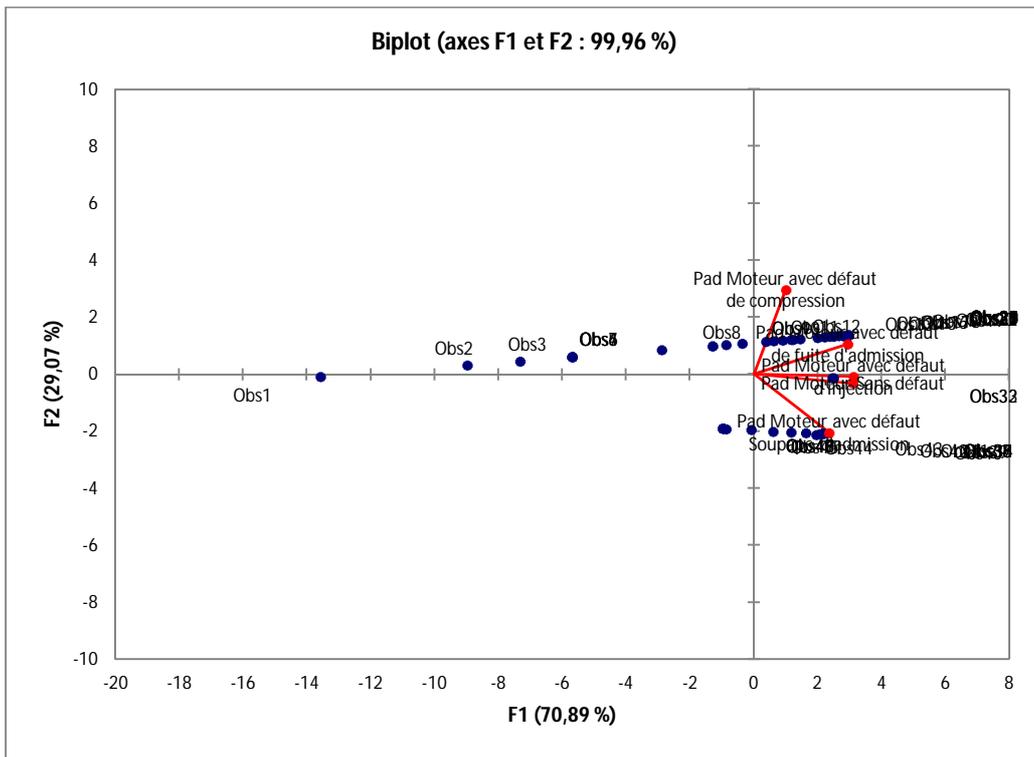


Figure A.2.4 : Représentation des individus axe 1et axe 2

L'interprétation des axes factoriels se fait séquentiellement, pour chaque axe et chaque nuage de points, en regardant les contributions à la formation des axes.

Variables : On sait que les variables contribuant le plus à la formation de l'axe 1 sont celles dont les coordonnées sur cet axe sont proches de 1 en valeur absolue. Pour repérer les contributions significatives, on utilise le tableau 5 : on compare les valeurs de la colonne F1 coordonnées du premier axe factoriel, à la racine de la contribution moyenne $1/\sqrt{8}=35\%$,

Le signe donnant le sens de contribution. On obtient :

| - | + |
|-----------------------------|---|
| p_a défaut de compression | Pad sans défaut Pad défaut d'injection Pad soupape d'admission Pad fuite d'admission |

| Observation | F1 | F2 | F3 | F4 | F5 |
|-------------|--------|--------|--------|--------|--------|
| Obs1 | -7,207 | -0,083 | 0,035 | 0,003 | 0,001 |
| Obs2 | -4,770 | 0,254 | 0,023 | 0,001 | 0,000 |
| Obs3 | -3,885 | 0,376 | 0,019 | 0,001 | 0,000 |
| Obs4 | -3,022 | 0,496 | 0,015 | 0,000 | 0,000 |
| Obs5 | -3,020 | 0,496 | 0,015 | 0,000 | 0,000 |
| Obs6 | -3,020 | 0,496 | 0,015 | 0,000 | 0,000 |
| Obs7 | -3,020 | 0,496 | 0,015 | 0,000 | 0,000 |
| Obs8 | -1,530 | 0,702 | 0,007 | -0,001 | 0,000 |
| Obs9 | -0,687 | 0,818 | 0,003 | -0,002 | 0,000 |
| Obs10 | -0,687 | 0,818 | 0,003 | -0,002 | 0,000 |
| Obs11 | -0,462 | 0,849 | 0,002 | -0,002 | 0,000 |
| Obs12 | -0,196 | 0,886 | 0,001 | -0,002 | 0,000 |
| Obs13 | 0,204 | 0,942 | -0,001 | -0,003 | 0,000 |
| Obs14 | 0,331 | 0,959 | -0,002 | -0,003 | 0,000 |
| Obs15 | 0,486 | 0,980 | -0,003 | -0,003 | 0,000 |
| Obs16 | 0,619 | 0,999 | -0,003 | -0,003 | 0,000 |
| Obs17 | 0,647 | 1,003 | -0,003 | -0,003 | 0,000 |
| Obs18 | 0,767 | 1,019 | -0,004 | -0,003 | 0,000 |
| Obs19 | 1,055 | 1,059 | -0,005 | -0,003 | 0,000 |
| Obs20 | 1,175 | 1,076 | -0,006 | -0,003 | 0,000 |
| Obs21 | 1,259 | 1,087 | -0,006 | -0,003 | 0,000 |
| Obs22 | 1,329 | 1,097 | -0,007 | -0,003 | 0,000 |
| Obs23 | 1,414 | 1,109 | -0,007 | -0,003 | 0,000 |
| Obs24 | 1,491 | 1,119 | -0,008 | -0,004 | 0,000 |
| Obs25 | 1,491 | 1,119 | -0,008 | -0,004 | 0,000 |
| Obs26 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs27 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs28 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs29 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs30 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs31 | 1,575 | 1,131 | -0,008 | -0,004 | 0,000 |
| Obs32 | 1,330 | -0,108 | 0,024 | 0,056 | 0,022 |
| Obs33 | 1,306 | -0,107 | 0,020 | 0,058 | -0,016 |
| Obs34 | 1,171 | -1,726 | 0,058 | 0,003 | 0,025 |
| Obs35 | 1,149 | -1,725 | 0,055 | 0,005 | -0,009 |
| Obs36 | 1,149 | -1,725 | 0,055 | 0,005 | -0,009 |
| Obs37 | 1,149 | -1,725 | 0,055 | 0,005 | -0,009 |
| Obs38 | 1,149 | -1,725 | 0,055 | 0,005 | -0,009 |
| Obs39 | 1,097 | -1,745 | 0,091 | -0,029 | -0,013 |
| Obs40 | 1,036 | -1,770 | 0,031 | -0,033 | 0,026 |
| Obs41 | 0,871 | -1,711 | 0,043 | 0,010 | 0,014 |
| Obs42 | 0,620 | -1,698 | -0,006 | -0,010 | 0,000 |
| Obs43 | 0,317 | -1,664 | 0,006 | -0,015 | -0,012 |
| Obs44 | -0,045 | -1,625 | -0,059 | -0,007 | -0,005 |

| | | | | | |
|-------|--------|--------|--------|--------|--------|
| Obs45 | -0,461 | -1,600 | -0,107 | -0,002 | 0,016 |
| Obs46 | -0,513 | -1,577 | -0,090 | 0,004 | -0,004 |
| Obs47 | -0,513 | -1,577 | -0,090 | 0,004 | -0,004 |
| Obs48 | -0,513 | -1,577 | -0,090 | 0,004 | -0,004 |
| Obs49 | -0,513 | -1,577 | -0,090 | 0,004 | -0,004 |

Tableau A.2.6 : Coordonnées des observations.

L'axe 1 oppose la pression d'admission en présence de défaut de compression, toutes les autres variables sont bien représentées sur l'axe. La première composante principale explique donc correctement tous les variables.

Les Individus : on utilise le tableau suivant :

On compare les valeurs de la colonne F1 à la racine de la première valeur propre $\sqrt{3,545} = 1,43$.

| | |
|---------------|--|
| - | + |
| Les autre Obs | Obs 24, Obs 25, Obs ..., Obs 31 Obs 41, Obs 42, |

Il n'est pas nécessaire de calculer les qualités de représentation des variables. Les variables bien représentées sont celles qui sont proches du bord du cercle des corrélations. L'axe 1 oppose les Obs : Obs24 jusqu'au Obs 31, Obs41 et Obs 42 au autre Obs.

Après avoir réalisé L'ACP normé et interprété ses résultats sur l'exemple des données de la pression d'admission, nous avons effectué L'ACP pour les deux autres bases de données (Vitesse de rotation et émissions polluantes).

A.3 FPGA Cyclone II

Les FPGA Cyclone II à 90 nm, sont conçus à partir de zéro pour un coût modique et pour fournir un ensemble de fonctions personnalisées pour les applications sensibles aux volumes élevés. Les FPGA Cyclone II offrent des performances élevées et une faible consommation d'énergie à un coût qui rivalise avec celui des ASIC.

La famille Cyclone II FPGA d'Altera est conçue sur un processus SRAM 1,2 V à couche de cuivre, à faible coefficient de perméabilité et est optimisée pour la plus petite taille de matrice possible.

Basée sur la technologie de processus 90 nm de TSMC, qui utilise des plaquettes de 300 mm, la gamme Cyclone II FPGA offre des densités plus élevées, plus de fonctionnalités, des performances exceptionnelles et les avantages de la logique programmable aux prix ASIC. La famille FPGA Cyclone II étend la portée des FPGA dans des applications à haut volume et sensibles aux coûts, en continuant le succès de la famille FPGA Cyclone.

Le tableau A.3.1 présente les caractéristiques et la disponibilité de la famille FPGA CycloneII.

| Dispositif | EP2C5 | EP2C8 | EP2C15 | EP2C20 | EP2C35 | EP2C50 |
|---|-------|-------|--------|--------|--------|--------|
| LE | 4,608 | 8 256 | 14 448 | 18 752 | 33 216 | 50 528 |
| M4K RAM Blocs (4 kbits + 512 bits de parité) | 26 | 36 | 52 | 52 | 105 | 129 |
| Mémoire embarquée (Kbits) | 117 | 162 | 234 | 234 | 473 | 581 |
| Multiplicateurs embarqués 18 bits x 18 bits | 13 | 18 | 26 | 26 | 35 | 86 |
| PLLs | 2 | 2 | 4 | 4 | 4 | 4 |
| Nombre maximal d'E / S d'utilisateur | 158 | 182 | 315 | 315 | 475 | 450 |
| Canaux différentiels | 58 | 77 | 132 | 132 | 205 | 193 |

Tableau A.3.1 : Présentation de la famille FPGA Cyclone II.

Le tableau A.3.2 présente une vue d'ensemble de l'emballage des périphériques Cyclone II et des comptages des broches d'E / S de l'utilisateur.

| Taille du paquet (mm x mm) | EP2C5 | EP2C8 | EP2C15 | EP2C20 | EP2C35 | EP2C50 |
|---|-------|-------|--------|--------|--------|--------|
| TQFP à 144 broches (22 x 22) | 89 | 85 | | | | |
| PQFP 208 broches (30,6 x 30,6) | 142 | 138 | | | | |
| PQFP à 240 broches (32 x 32) | | | | 142 | | |
| FineLine BGA à 256 broches (17 x 17) | 158 | 182 | 152 | 152 | | |
| 484-Pin Ultra FineLine BGA (19 x 19) | | | | | 322 | 294 |
| 484 broches FineLine BGA (23 x 23) | | | 315 | 315 | 322 | 294 |
| 672-Pin FineLine BGA (27 x 27) | | | | | 475 | 450 |
| 896-Pin FineLine BGA (31 x 31) | | | | | | |

Tableau A.3.2 : Packages de périphériques Cyclone II et broches d'E/S utilisateur maximum.

Le tableau A.3.3 présente les périphériques de configuration appropriés à utiliser pour les FPGA Cyclone II.

| Dispositif de configuration | Périphériques Cyclone II pris en charge | | | | | |
|-----------------------------|---|-------|--------|--------|--------|--------|
| | EP2C5 | EP2C8 | EP2C15 | EP2C20 | EP2C35 | EP2C50 |
| EPCS1 | X | | | | | |
| EPCS4 | X | X | X | X | | |
| EPCS16 | X | X | X | X | X | X |
| EPCS64 | X | X | X | X | X | X |

Tableau A.3.3 : Dispositifs de configuration appropriés pour les FPGA Cyclone II.

Le tableau A.3.4 montre le support de température industrielle pour les FPGA Cyclone II.

| Dispositif | Paquet | Catégorie de vitesse |
|---------------|---|----------------------|
| EP2C5 | TQFP à 144 broches FBGA à 256 broches PQFP 208 broches | -8 |
| EP2C8 | TQFP à 144 broches FBGA à 256 broches PQFP 208 broches | -8 |
| EP2C20 | FBGA à 256 broches FBGA à 484 broches | -8 |
| EP2C35 | FBGA à 484 broches UFBGA 484 broches FBGA à 672 broches | -8 |
| EP2C50 | FBGA à 484 broches UFBGA 484 broches FBGA à 672 broches | -8 |

Tableau A.3.4 : Support de température industrielle du dispositif cyclone II.

BIBLIOGRAPHIE

[ALEXANDRE 06] Alexandre P., 2006. Contribution au Diagnostic Décentralisé des Systèmes à Evénements Discrets : Application aux Systèmes Manufacturiers, UNIVERSITE DE REIMS CHAMPAGNE ARDENNE, Thèse de doctorat, Génie Informatique, Automatique et Traitement du Signal.

[ALOUANE 08] Alouane B., 2008. Recherche de partitions floues optimales par segmentation floue pour la fouille de données quantitative. Mémoire de magister. Université M'hamedBougara de Boumerdes, Algérie, 47-53.

[AMBAPOUR 09] Ambapour S., 2009. Théorie des ensembles flous : application à la mesure de la pauvreté au Congo. Document de travail. Bureau d'application des methodestatitiques et informatiques. Brazzaville, 7-8.

[ASSAS 13] Assas O., 2013. Classification floue des images. Thèse de doctorat. Université de Batna, algérie, 23-24.

[ASSAS 13] Assas O., 2013. Classification floue des images. Thèse de doctorat. Université de Batna, Algérie, p23-24.

[BDIRINA 06] BDIRINA K., 2006. Diagnostic de Défauts d'Engrenage par Analyse Spectrale, Université de M'SILA, Mémoire de Magister.

[BENCHERIF 18] Bencherif M., 2018. Moteurs à Combustion Interne, Combustion et Eléments deCarburation. Polycopié destiné aux étudiants de licence et master LMD, Université Mohammed Boudiaf, Oran.

[BERZEK 81] Berzek J.C., 1981. Pattern recognition with fuzzy objective function algorithms, New York.

[BOSCH 08] Bosch R., 2008. Évolution technologiques du système d'injection common rail. Conférence CNAM SIA, p09.

[BOUALI 10] Bouali M., 2010. Contributions à l'analyse formelle et au diagnostic à partir de réseaux de Pétri colorés avec l'accessibilité arrière. Thèse de doctorat, Université de technologie de compiègne, 7-10.

[BOUZIDI 16] Bouzidi A., 2016. Diagnostic et contrôle des systèmes de conditionnement de l'énergiephotovoltaïque. Cas d'un système connecté au réseau électrique. Mémoire de magister. Université Hadj Lakhdar Batna, Algérie, p95-102.

[CEDRA 90] Cedra C & Gauthier D., 1990. Les moteurs diesel Technologie et fonctionnement, ouvrage.

[CHAIBI 14] Chaibi S., 2014. Accélération de l'apprentissage des SVMs pour le traitement de bases de données de grandes tailles : Application à la reconnaissance des mots arabes isolés, Thèse de doctorat, Université Badji Mokhtar Annaba, Algérie, p73-77.

[CHRISTOPHE 00] Christophe C., 2000. Méthodes d'Aide à la Décision pour la Détection et la Localisation de Défauts dans les Entraînements Electriques », Institut National Polytechnique de Grenoble, Thèse de doctorat, Electronique, Electrotechnique, Automatique, Télécommunication et Signal.

[CLAUDIA 07] Claudia Victoria Isaza Narvaez., 2007. Diagnostic par techniques d'apprentissage floues : conception d'une methode de validation et d'optimisation des partitions. Thèse de doctorat. Université de Toulouse, France, 15-28.

- [COMBACAU 91] Combacau M., 1991. Commande et surveillance des systèmes à événements discrets complexes : application aux ateliers flexibles. Thèse de doctorat. Université Paul Sabatier, Toulouse, France.
- [DERBEL 09] DERBEL H., 2009. Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de système dynamique hybrides, Université Joseph Fourier-Grenoble I, Thèse de doctorat, Electronique, Electrotechnique, Automatique, Traitement du signal.
- [DJEFFAL 11] DJEFFAL A., 2011. Utilisation des méthodes support vector machine (SVM) dans l'analyse des bases de données, Thèse de doctorat, Université Mohamed Khider Biskra, Algérie, p7-26.
- [DIETTERICH 95] Dietterich T.G, Bakiri G., 1995. Solving multiclass learning problems via error-correcting output codes, Journal of artificial intelligence research, Volume 2, p263-286.
- [DIEZLLEDO 08] DIEZLLEDO E., 2008. Diagnostic et Pronostic de défaillance dans des composants d'un moteur d'avion », Université TOULOUSE III-PAUL SABATIER, Thèse de doctorat, Automatique.
- [Dubuisson 90] Dubuisson B., 1990. Diagnostic et reconnaissance des formes. Traité des nouvelles technologies. Série diagnostic et Maintenance. Hermès, Paris.
- [FRELICOT 92] Frélicot C., 1992. Un système adaptatif de diagnostic prédictif par reconnaissance des formes floues,. Thèse de doctorat, Université de technologie de Compiègne.
- [FRELICOT 93] Frélicot C., Dubuisson B., 1993. A posteriori ambiguity reject solving in fuzzy pattern classification using a multi-step predictor of membership vectors in uncertainty in intelligent systems. Elsevier Science.
- [GAOUAOUI 12] Gaouaoui M., 2012. Diagnostic par reconnaissance des formes : application à la machine asynchrone. Mémoire de magistère. Université Mouloud Mammeri, Tizi-Ouzou, Algérie.
- [GENUER 17] Genuer R., Poggi J.M., Arbres CART et Forêts aléatoires Importance et sélection de variable. <https://hal.archives-ouvertes.fr/hal-01387654v2>.
- [GLORENNEC 99] Glorennec P.Y., 1999. Algorithme d'apprentissage pour systèmes d'inférence floue. Hermès.
- [GUILLAUME 05] Guillaume G., 2005. Diagnostic des systèmes à l'aide d'observateurs à mémoire finie. Application au common Rail, Université d'Orléans, Thèse de doctorat, Automatique et Traitement du signal.
- [HAFA 12] Hafa A., 2012. Sélection de variables biologiques par l'approche FILTER. Mémoire de Master en Informatique. Université Abou BekerBelkaid, Algérie, 21-23.
- [HAMOU MAMAR 08] HamouMamar Z., 2008. Analyse Temps-Echelle et reconnaissance des formes pour le diagnostic du système de guidage d'un tramway sur pneumatiques. Thèse de doctorat en informatique. Université Blaise Pascal Clermont II.
- [HANDIS 12] Handis M., 2012. Modélisation des défaillances et leur diagnostic par les méthodes de reconnaissance des formes floue. Mémoire de magister. Université Badji Mokhtar, Annaba, Algérie, 27-35.
- [HEATH 97] Heath S., 1997. Embedded systems design. Butterworth-Heinemann. Newton, MA, USA, 2p.
- [HOUTHUYS 17] Houthuys L. ,Langone R., Johan A.K., 2017. Multi-view least squares support vectormachines classification. Publication Science Direct. Neurocomputing 282 (2018), p78–88.

- [HS07] Henzinger T.A & Sifakis J., 2007. The discipline of embedded systems design. *Computer*, 32-40.
- [JEAN-HUGH 99] Jean-Hugh T., 1999. Diagnostic d'un système non stationnaire à partir d'une approche de reconnaissance des formes floue. Application au diagnostic de cliquetis moteur. Université du Marine, traitement de signal, volume 16, n°3.
- [KADRI 13] Kadri O, Mouss H, Mouss M D, Abdelhadi A., 2013. Reconnaissance des forms par SVM pour le diagnostic du système de pasteurization d'une usine de lait, Publication revue des sciences et de la technique – RST-, Volume 4 N°1.
- [KEMPOWSKY 04] KEMPOWSKY T., 2004. Surveillance de Procédés a Base de Méthodes de Classification : Conception d'un Outil d'Aide pour la Détection et le Diagnostic des Défaillances, Institut National des Sciences Appliquées de Toulouse, Thèse de Doctorat, Système Industriels.
- [KHODJA 97] Khodja L., 1997. Contribution à la classification floue non supervisée, Thèse de doctorat en physique expérimentale et instrumentation. Université de Savoie Mon Blanc, France, 41-47.
- [KRISHNAPURAM 05] Krishnapuram R & Keller J., 2005. A possibilistic approach to clustering. *IEEE Trans. Fuzzy Syst.* 1(2), 98-110.
- [LAOUTI 12] LOUITI M.N., 2012. Diagnostic de défauts par les machines à vecteurs supports : application à différentes systèmes multi variables non linéaires, Thèse de doctorat, Université Claude Bernard Lyon 1, France, p41-50.
- [LAURENT 09] Laurent P., 2009. Extraction du bruit de combustion d'un moteur Diesel. Développement et application d'un spectrofiltre, Institut National des Science Appliquées de Lyon, thèse de Doctorat, Acoustique.
- [MARIA 01] MARIA H., YANNIS B., MICHALIS V., 2001. On clustering validation techniques. *Journal of intelligent information systems*, 107-145.
- [MASSON 92] Masson M., 1992. Contribution à l'élaboration d'une méthode de décision avec rejet par réseaux de neurones. Application à la surveillance des systèmes. Thèse de doctorat. Université de technologie de Compiègne.
- [MASSON 96] Masson M.H., Dubuisson B & Frélicot C., 1996. Conception d'un module de reconnaissance des formes floues pour le diagnostic. *Journal Européen des Système Automatisés (RAIRO-APII-JESA)*, 319-341.
- [MOCHAWECH 03] Mochawech M.S., 2003. Conception d'un système de diagnostic adaptatif et prédictif base sur la methodfuzzy pattern matching pour la surveillance en ligne des systems évolutifs, Université de Reims, France, 28-29.
- [MOUSSA NAHIM 16] Moussa-Nahim H., 2016. Contribution à la modélisation et à la prédiction de défaillances sur les moteurs diesel marins. Thèse de doctorat. Université Aix Marseille, France.
- [NOHRA09] Chadi N., 2009. Diagnostic de défauts sur un moteur diesel. Thèse de doctorat, Université PAUL CEZANNE, France.
- [NOURA 06] Noura H., Peysson F et Younes R., 2006. Diagnostic de défauts sur un moteur diesel, Conférence international francophone d'automatique CIFA 2006, Bordeaux, France.
- [OLIVIER 04] Olivier G., 2004. Modélisation du moteur à allumage par compression dans la perspective du contrôle er du diagnostic, Université de Rouen, thèse de Doctorat, Energétique.

- [PEYSSON 05] Peysson F., 2005. Diagnostic et Tolérance aux Fautes des moteurs diesel, stage de recherche. Laboratoire des Sciences de l'information et des Systèmes, Universités Paul Cezanne, de Provence, de la Méditerranée, France.
- [PHAN 09] Phan Q. Dzung, Le M. Phuong, Hong H. Lee, Bui N. Thang, Le Dinh Khoa, 'A new FPGA implementation of four- switch three- phase inverter', IEEE International Conference on Power Electronics and Drive Systems, Nov. 2009.
- [PHILIPPE 00] Philippe L., Patrick G., 2000. De l'utilisation d'OBD pour la sélection de variables. Rapport technique PSI.
- [POISSON 06] Poisson D., Mahjoub S., 2006. La reconnaissance de forme comment améliorer les techniques de reconnaissance de forme 3D. Mémoire de recherche, ESGI 5ème Année Spécialisation Animation Numérique Interactive. Paris, France. p4.
- [RACOCEANU 06] RACOCEANU D., 2006. Contribution à la Surveillance des Systèmes de Production et Utilisant les Techniques de L'Intelligence Artificielle, Université de Franche-Comté, Synthèse de l'activité scientifique en vue d'obtention de l'Habilitation à Diriger des Recherches, Automatique.
- [RIPOLL 99] RIPOLL P., 1999. Conception d'un Système de Diagnostic Flou Appliqué au Moteur Automobile, Université de SAVOIE, Thèse de doctorat, Electronique, Electrotechnique et Automatique.
- [ROCHA 14] Rocha., Ryan., Klautau A., 2014. In defense of on-vs-all classification, The Journal of machine learning research, p101-141.
- [ROLAND 03] Roland C., 2003. Diagnostic des défauts des machines asynchrones par reconnaissance des formes. Thèse de doctorat en Electronique. Ecole centrale de Lyon, France.
- [SABEH 06] SABEH Z., 2006. Diagnostic à base de modèle : application à un moteur diesel suralimenté à injection directe, Institut National Polytechnique de Lorraine, Thèse de doctorat, Automatique.
- [SADOU 07] Sadou N., 2007. Aide à la conception des systèmes embarqués sûrs de fonctionnement, Thèse de doctorat, Université Toulouse III – Paul Sabatier, France.
- [SBILI 15] Sbili L., 2015. Segmentation d'image par classification floue. Mémoire de magister en automatique. Université Mouloud Mammeri, Tizi-Ouzou, algerie, p43.
- [TATIANA 04] Tatiana K., 2004. Surveillance de procédés à base de méthodes de classification : conception d'un outil d'aide pour la détection et le diagnostic des défaillances. Thèse de doctorat, Institut National des Sciences Appliquées de Toulouse, France.
- [TOUZET 92] TOUZET C., 1992. Les Réseaux de Neurones Artificiels, Cours, Exercice et TP, 1992.
- [TREERATTANAPITAK 13] Treerattanapitak K., Jaruskulchai C., 2013. Possibilistic Exponential Fuzzy Clustering. Journal of Computer Science and Technology, Volume 28 (2), 311-321.
- [XIAOHUI 13] Xiaohui Song., 2013. FPGA Implementation of a Support Vector Machine based Classification System and its Potential Application in Smart Grid, Thèse de doctorat, Université de Tolido, p30-47.
- [YANG 07] Y. Yang, D. Yu and J. Cheng., 2007. A fault diagnosis approach for roller bearing based on envelop spectrum and SVM, Measurement, Elsevier, Volume 40, p943-950.

[YANG 02] Yang M.S & Wu K.L., 2002. A possibilistic type of alternative fuzzy c-means, Proceedings of the 2002 IEEE International Conference, Honolulu, Hawaiï, 1456-1459.

[YOUNES 06] Younes R., Mustapha Ouladsine., Hassan Noura., 2006. Optimisation du débit d'air dans le diesel suralimenté, Conférence internationale francophone d'automatique 2006, Bordeaux, France, p2.

[YOUNES 93] Younes R., 1993. Elaboration d'un modèle de connaissance du moteur diesel avec turbocompresseur a géométrie variable en vue de l'optimisation des ses émissions, Thèse de doctorat, L'école centrale de Lyon, France, p95.

[ZIANI 15] ZIANI R., 2015. Contribution à l'analyse et à la classification automatique des défauts mécaniques, Thèse de doctorat, Université Ferhat Abbas Sétif 1, Algérie, p25-36.

[ZWINGELSTEIN 95] ZWINGELSTEIN G., 1995. Diagnostic des défaillances : théorie et pratique pour les systèmes industriels. Edition HERMES.