



**HAL**  
open science

# Surveillance de l'état de santé des actionneurs électromécaniques : application à l'aéronautique

Romain Breuneval

► **To cite this version:**

Romain Breuneval. Surveillance de l'état de santé des actionneurs électromécaniques : application à l'aéronautique. Energie électrique. Université de Lyon, 2017. Français. NNT : 2017LYSE1313 . tel-03934553

**HAL Id: tel-03934553**

**<https://theses.hal.science/tel-03934553>**

Submitted on 11 Jan 2023

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



N°d'ordre NNT : 2017LYSE1313

**THESE de DOCTORAT DE L'UNIVERSITE DE LYON**  
opérée au sein de  
**l'Université Claude Bernard Lyon 1**

**Ecole Doctorale EEA N° 160**  
**(Électronique, Électrotechnique et Automatique de Lyon)**

**Spécialité de doctorat** : Génie Electrique

Soutenue publiquement le 21/12/2017, par :  
**Romain Vincent BREUNEVAL**

---

**Surveillance de l'état de santé des  
actionneurs électromécaniques :  
application à l'aéronautique**

---

Devant le jury composé de :

**PERA, Marie – Cécile**, PU (HDR), FEMTO / IUT Belfort Montbéliard  
**DIALLO, Demba**, PU (HDR), GeePs / Université Paris Sud  
**MARE, Jean – Charles**, PU (HDR), ICA / INSA Toulouse  
**KALLAS, Maya**, MC, CRAN / ENSEM Nancy

**Présidente**  
**Rapporteur**  
**Rapporteur**  
**Examinatrice**

**CLERC, Guy**, PU (HDR), AMPERE / Université Lyon 1  
**NAHIDMOBARAKEH, Babak**, PU (HDR), GREEN / ENSEM  
Nancy  
**MANSOURI, Badr**, Expert en Automatique, Groupe Safran  
**BOILEAU, Thierry**, MC, GREEN / ENSEM Nancy

**Directeur de thèse**  
**Co - directeur de thèse**

**Invité (Encadrant)**  
**Invité**

# UNIVERSITE CLAUDE BERNARD - LYON 1

## **Président de l'Université**

Président du Conseil Académique

Vice-président du Conseil d'Administration

Vice-président du Conseil Formation et Vie Universitaire

Vice-président de la Commission Recherche

Directrice Générale des Services

**M. le Professeur Frédéric FLEURY**

M. le Professeur Hamda BEN HADID

M. le Professeur Didier REVEL

M. le Professeur Philippe CHEVALIER

M. Fabrice VALLÉE

Mme Dominique MARCHAND

## ***COMPOSANTES SANTE***

Faculté de Médecine Lyon Est – Claude Bernard

Faculté de Médecine et de Maïeutique Lyon Sud – Charles Mérieux

Faculté d'Odontologie

Institut des Sciences Pharmaceutiques et Biologiques

Institut des Sciences et Techniques de la Réadaptation

Département de formation et Centre de Recherche en Biologie Humaine

Directeur : M. le Professeur G.RODE

Directeur : Mme la Professeure C. BURILLON

Directeur : M. le Professeur D. BOURGEOIS

Directeur : Mme la Professeure C. VINCIGUERRA

Directeur : M. X. PERROT

Directeur : Mme la Professeure A-M. SCHOTT

## ***COMPOSANTES ET DEPARTEMENTS DE SCIENCES ET TECHNOLOGIE***

Faculté des Sciences et Technologies

Département Biologie

Département Chimie Biochimie

Département GEP

Département Informatique

Département Mathématiques

Département Mécanique

Département Physique

UFR Sciences et Techniques des Activités Physiques et Sportives

Observatoire des Sciences de l'Univers de Lyon

Polytech Lyon

Ecole Supérieure de Chimie Physique Electronique

Institut Universitaire de Technologie de Lyon 1

Ecole Supérieure du Professorat et de l'Education

Institut de Science Financière et d'Assurances

Directeur : M. F. DE MARCHI

Directeur : M. le Professeur F. THEVENARD

Directeur : Mme C. FELIX

Directeur : M. Hassan HAMMOURI

Directeur : M. le Professeur S. AKKOUCHE

Directeur : M. le Professeur G. TOMANOV

Directeur : M. le Professeur H. BEN HADID

Directeur : M. le Professeur J-C PLENET

Directeur : M. Y. VANPOULLE

Directeur : M. B. GUIDERDONI

Directeur : M. le Professeur E.PERRIN

Directeur : M. G. PIGNAULT

Directeur : M. le Professeur C. VITON

Directeur : M. le Professeur A. MOUGNIOTTE

Directeur : M. N. LEBOISNE



*« Tous les modèles sont faux. Certains sont utiles. »*

**Georges Box**

*« La phrase la plus excitante à entendre en science, celle qui annonce de nouvelles découvertes, n'est pas « Eureka ! » (J'ai trouvé !), mais plutôt « Tiens, c'est marrant... »*

**Isaac Asimov**

*« J'ai refait tous les calculs. Ils confirment l'opinion des spécialistes : notre idée est irréalisable... Il ne nous reste qu'une seule chose à faire : la réaliser ! »*

**Pierre-Georges Latécoère**



# Remerciements

Ce mémoire est issu de mes travaux de thèse qui se sont déroulés de 2015 à 2017. Ils ont été financés par *Safran Electronics & Defense* (anciennement Sagem Défense et Sécurité) et par l'Agence Nationale pour la Recherche et la technologie (ANRT) au travers d'une bourse CIFRE. Ces travaux ont été menés conjointement entre Safran Electronics & Defense, le laboratoire Ampère et le laboratoire GREEN.

Ma gratitude va aux rapporteurs de ce mémoire, Demba DIALLO et Jean – Charles MARE, qui ont accepté d'apporter leur expertise pour évaluer et contribuer à améliorer ces travaux. Merci d'avoir relu dans les temps ce long mémoire, malgré le rush de fin d'année que subissent les professeurs d'université. Mes remerciements vont également à Marie – Cécile PERA, qui a accepté de présider ce jury malgré ses nombreuses responsabilités, ainsi qu'à Maya KALLAS et Thierry BOILEAU pour avoir participé activement. Un remerciement particulier à Thierry pour avoir accepté également d'apporter, en plus du reste, son expertise culinaire pour l'évaluation du pot de thèse. En espérant avoir de nouvelles occasions d'échanger avec chacun d'entre vous sur ces sujets de recherche dans le futur. Merci également à Jérôme PIATON et François GUILLOT, experts chez Safran ED, d'avoir fait le déplacement pour assister à ma soutenance.

Une thèse, quoi que l'on en dise, est un travail collectif dont le doctorant est le fer de lance. Ainsi mes plus sincères remerciements vont à ceux qui ont formés le reste de cette lance : Guy CLERC, en tant que directeur, Babak NAHIDMOBARAKEH, en tant que co – directeur et Badr MANSOURI, en tant qu'encadrant industriel. À Guy, pour sa disponibilité et sa gentillesse. À Babak, pour l'accueil toujours chaleureux au GREEN et pour ses conseils. À Badr, pour nos nombreuses discussions, son soutien inconditionnel et sa patience.

Au cours de ces trois années j'ai eu la chance de co – encadrer et d'encadrer trois talentueux stagiaires : Ryan MICHAUD, Kathleen PELE et Dan – Khoa NGUYEN. Merci à chacun d'entre vous pour votre contribution à la réussite de cette thèse. Une pensée pour le « *320 simulations en un week – end* ». Les PC s'en souviendront. Merci également pour votre bonne humeur et le cœur que vous avez mis à l'ouvrage. Je ne doute pas de votre succès dans vos futurs professionnels respectifs.

Je salue également l'ensemble du laboratoire Ampère et, plus en particulier, le personnel du site de l'UCBL. De nombreux rires auront ponctué ces trois ans, tant au labo qu'en dehors. Merci à mes collègues de bureau pour ces trois années (par ordre chronologique) : Seima, Ronan (le Mâle !), Christophe, Nagham, Ryad, Antoine et Mohammed. Merci également à mes autres collègues doctorants, non des moindres : Maxime (Mr Chocolat et avions de chasse ;)), Justine, Nico, Atef (Le beau goss !), Aurélien Chazottes, Albert, Eduardo, Malorie, Pierre, Roberta, Ousseynou, Samuel, Seb et Aurélien Lièvre. Un remerciement spécial et appuyé à Mohammed et Atef qui m'ont aidé à finaliser les courses pour le pot. Merci également à mes collègues permanents, qui de par leur gentillesse et leur bonne humeur, contribue à former les chercheurs de demain (...même Christian !). Mes remerciements s'adressent aussi à Emmanuel BOUTLEUX et Julien HUILLERY, de l'école Centrale, pour notre collaboration sur le calcul de signatures au travers du stage de Ryan. Enfin, que soient ici

remerciés mes camarades de réunions de cohésion. Leur nom ne seront pas donnés ici, mais ils se reconnaîtront. En espérant continuer de partager avec vous ces bons moments dans les années qui arrivent.

Ma reconnaissance va naturellement à mes collègues de Safran E&D. En premier lieu merci à Benjamin DAGUSE, responsable de l'équipe « Asservissement et Puissance », pour ses encouragements constants et la bonne humeur entretenue au sein de l'équipe. Merci aux autres membres de la dream – team « A&P » : Badr, Hicham, Scott, Baptiste, Mehdi, Jérôme et Alberto. Les réunions du jeudi auront été le lieu de nombreux éclats de rire et parfois même, de franches rigolades. Je souhaite bon courage à Scott pour la fin de sa thèse. C'est déjà un succès mais ça le sera encore plus dans quelques mois :) : longue vie à BOA ! Merci à cette deuxième dream – team qu'est l'équipe « métho' » : Isabelle, Charles et Anthony. Les bons moments passés ensemble, au déjeuner, au café ou lors des « sessions gâteau » ne seront pas oubliés. Un merci particulier à Claude pour son aide sur la partie qui décrit les systèmes d'actionnement des commandes de vol et pour sa ponctualité, sans failles, pour venir nous chercher déjeuner. Merci à François – Xavier BENZ pour son expertise en mécanique et pour m'avoir, pendant longtemps, aider afin de chercher une solution au manque de données pour les VAR. Merci à Etienne MERLET pour sa grande expertise technique et les discussions ayant découlé de celle – ci, parfois en allant chercher le RER ! Merci également à Jean – Claude DERRIEN, pour avoir porté le sujet du Health – Monitoring chez Safran E&D pendant toutes ces années, ce qui a permis d'aboutir à ma thèse. Enfin merci à Alexandre GUYAMIER pour avoir lancé cette thèse et pour avoir aidé mon décollage au sein du monde de l'aéronautique.

Quelques mots pour remercier le personnel du GREEN. Lors de mes passages là – bas, j'ai toujours été bien accueilli. Merci aux doctorants et notamment à : Adrien, Thibaud, Marc, Najla, Blaize, Sarah pour m'avoir gentiment avancé les repas au CROUS ainsi que quelques cafés.

Que serait la vie sans des amis ? La liste est ici longue, j'essaierais donc de la rendre à la fois la plus courte et la plus exhaustive possible.

Tout d'abord merci aux sardines pour tous ces bons moments passé ensemble, malgré l'éloignement. J'ai vraiment beaucoup de chance de vous avoir les gars. Merci à Charly pour les bons moments à Nancy, à Paris et à Lyon, pour les coups de fil pour se remonter et pour le reste. Le 13 juillet 2019 est réservé ;). Merci à Tarbou d'avoir été là du début (# meuble) à la fin (# fêter la soutenance) de ce gros morceau de ma vie. Et merci aussi d'être là pour la suite :). Merci à Matthieu, Myriam et Chloé pour le road – trip en Pologne. Merci à JB et Myriam pour les supers quelques jours anglais, post dépôt du mémoire. Merci à Cyrille, Éline et Johan d'être passé nous voir au temps de la grande coloc'. À Cyrille : le meilleur reste à venir ;) (# SardineCity). À Éline : bon courage pour ta propre thèse, quand tu liras ces lignes je ne doute pas que tu sois, toi – même, docteur.

Merci également aux amis de Lyon, qui se reconnaîtront, pour les soirées, restos, bars, cinés (UGC vs Pathé) qui ont ponctués ces trois années. Bon courage à Roro pour la fin de ta thèse (j'ai entendu dire que si elle avait été sur les Mojitos, tu l'aurais déjà achevée ;)). Un merci particulier à Ivanne, pour avoir assisté à ma soutenance, bien qu'elle n'ait pas fait l'avion (que tu sais si bien faire, de par ailleurs).

Merci aux colocs successifs de ces trois années, dans l'ordre chronologique : Pascal, Vincent, Thib', JB, Michel (Michel ! Michel !), Christelle, Loris et Olivier. Un remerciement spécial à JB, pour lequel

on recherche toujours le bouton pause ;), qui est maintenant plus qu'un ex – coloc mais un véritable ami.

Enfin, merci à ma famille, des deux côtés, pour leur soutien inconditionnel. Avec un tel socle, je ne pouvais que réussir. Les nombreuses réunions que nous faisons tous les ans, et ce depuis bien avant que je rentre en thèse, ont vraiment égayé les moments difficiles de ces trois années. Merci à mes parents de m'avoir toujours soutenu dans mes choix. Merci à mon frère, Thomas. Même si nous avons choisi des chemins différents, je suis fière de toi pour ton excellence dans tes domaines et pour ta ténacité. Merci à ma tatie Franc qui est venue assister à ma soutenance et qui aura corrigé une grande partie des (nombreuses) fautes d'orthographe de ce mémoire. Merci à tonton Mick pour les discussions (et les bières qui vont parfois avec ;)). Merci à Clem', pour avoir su me rassurer et m'aider à mettre les choses en perspective au cours des passages sous l'eau. Et merci aussi pour ce fameux week – end lyonnais, où les petit dej' ont été particulièrement savoureux :). Enfin, merci à mon grand-père pour tous les bons moments passés ensemble ,notamment au Crotoy, ce havre de paix au bord de la mer.



## **Titre : Surveillance de l'état de santé des actionneurs électromécaniques : application à l'aéronautique**

L'industrie aéronautique fait face à trois enjeux majeurs : la réduction de son empreinte environnementale, l'absorption de l'augmentation du trafic et le maintien d'un haut niveau de sécurité pour des systèmes de plus en plus complexes, à coûts équivalents. La maintenance prédictive permet de répondre en partie à ces trois enjeux. Les systèmes, dont on peut prédire la durée de vie peuvent être utilisés plus longtemps, ce qui diminue le nombre de composants utilisés sur la vie d'un avion. Prédire les pannes permet également d'augmenter la disponibilité des aéronefs en évitant les arrêts non planifiés. Enfin, le suivi de l'état de vieillissement de l'avion permet d'optimiser la maintenance et ainsi de réduire les coûts. Dans les années 2000, ces méthodologies ont été appliquées sur les moteurs. Elles commencent maintenant à se généraliser aux autres systèmes avioniques. Ainsi cette thèse concerne la mise au point de méthodologies amenant à la maintenance prédictive d'actionneurs électro – mécaniques (EMA) de commande de vol. Les problématiques et les contraintes (temps de calculs, quantités de mémoire...) liées à cette thématique sont détaillées.

Dans un premier temps, le calcul de signatures de défauts est abordé. Une méthode pour les systèmes vis-écrou, basée sur l'identification d'un modèle de frottement, est proposée. Une deuxième méthode, reposant sur l'analyse des courants à partir d'une combinaison de décomposition modale empirique ensembliste complète et d'analyse aveugle de sources, est ensuite introduite. Ces deux méthodes sont testées sur des données issues de profils non opérationnels. Ces données sont issues d'un modèle de simulation représentant finement l'actionneur dans son environnement. L'ensemble des simulations représente des essais virtuels sur une population d'EMA. A partir de ces simulations, les signatures mises au point sont calculées. Puis, afin de valider ces signatures, des métriques de performances sont calculées.

Le diagnostic par reconnaissance de formes est ensuite traité. Un algorithme reposant sur une combinaison de machine à vecteur de supports et de fonctions floues d'appartenances est proposé. Celui-ci peut notamment estimer la sévérité d'un défaut. Il permet également de détecter des points ne correspondant pas à la base d'apprentissage, qui peuvent représenter des défauts inconnus ou des points appartenant à plusieurs classes à la fois, pouvant représenter des cas de défauts combinés. L'architecture d'un système de diagnostic complet, basée sur l'algorithme conçu, est détaillée.

Des validations expérimentales des méthodes de calcul de signatures et de diagnostic sont ensuite menées. Ces validations reposent sur trois bases issues de trois campagnes d'essais. La première repose sur des essais d'un EMA sain sur un banc représentatif. La deuxième concerne un moteur asynchrone en défaut en régime permanent. La dernière porte sur un moteur synchrone à aimants, de type aéronautique, en défaut de court-circuit inter-spires en régime permanent. Le respect des contraintes par l'algorithme est vérifié.

Enfin, des éléments pour aller vers le pronostic sont avancés. Le processus du pronostic est détaillé. Seule une partie de ce processus est traitée, sur des données issues de vieillissement de roulements. Dans un premier temps, le partitionnement de données de vieillissement pour créer des classes de sévérité de défaut est étudié. Cette tâche a amené à proposer une métrique, dite de cohérence temporelle, permettant de vérifier qu'un résultat de partitionnement satisfait aux contraintes pour le pronostic. Puis l'algorithme de classification proposé est validé sur les données partitionnées. Ceci amène à distinguer deux méthodes de validation, une approche dite diagnostic et une dite pronostic. Une méthode de normalisation, pour l'approche pronostic, est proposée. La prédiction des signatures dans le futur est ensuite traitée. Un algorithme de régression par vecteurs de support est utilisé. Enfin l'algorithme de diagnostic est appliqué aux données prédites, ce qui permet d'estimer la durée de vie utile restante. Ces résultats sont évalués selon différentes métriques de performances et selon les contraintes du cadre aéronautique.

**Mots – Clés :** diagnostic, pronostic, actionneur électromécanique, aéronautique, vis à roulements, MSAP, reconnaissance de formes, machine à vecteurs de supports, flou, fonction d'appartenance

## **Title: Health - Monitoring of electromechanical actuators: application to aeronautics**

The aeronautics industry is facing three major challenges: the reduction of its environmental impact, the absorption to the air traffic increase and a high level of safety for increasing complex systems, for equivalent costs. Predictive maintenance allows answering to these issues. Systems, for which the life can be predicted, can be used for a longer time. This reduces the number of components used in the lifetime of an aircraft. To predict failures also allow increasing the availability of aircrafts by avoiding unplanned downtime. Finally, monitoring the ageing of the aircraft allows to optimize maintenance and so to reduce costs. In the 2000s, these methodologies were applied to turbojets. It starts, now, to be generalized to others avionics systems. Therefore, this work deal with predictive maintenance methodologies for electromechanical actuator (EMA) for flight controls systems. Problems and constraints (computation time, memory quantities...) related to this subject are detailed.

In a first part, fault feature computation methodologies are investigated. A first method is proposed for screw/nut systems. This method is based on the identification of a friction model. A second method, based on current analysis, is presented. This method uses a combination of empirical mode decomposition and independent component analysis. The two methods are tested on data from a non-operational profile. This data are from a simulation model which represents the EMA in the aircraft environment. The simulations performed represent virtual trials on a population of EMA. From these simulations, fault features are computed. Then, performances metrics are evaluated.

Diagnosis by pattern recognition is then studied. An algorithm based on support vector machine and fuzzy membership functions is proposed. This algorithm can estimate the severity of a fault. It can also detect unknown observations, which can represent unknown faults or combined faults. The architecture of a global diagnosis system, based on the proposed algorithm, is detailed.

Experimental validation of fault features computation and diagnosis algorithm is performed. These validations are based on three data bases. The first one is based on trials performed on a healthy EMA on a representative bench. The second consists in an induction motor at constant speed for different types of faults. The last one is from trials on a permanent magnet synchronous machine, of aeronautics type, for different kinds of short – circuit fault severities. The respect of the aeronautics constraints is verified.

At last, elements for prognosis process are given. This process is detailed. Only a part of this process is treated, on a roller bearings benchmark database. First, the clustering for prognosis is studied. A metric, which allows verifying that the obtained clusters are coherent regarding time, and thus, checks the constraints for prognosis, is given. Then the proposed diagnosis algorithm is validated on the clustered data. This brought to perform two kinds of validation, a diagnosis oriented one and a prognosis oriented one. A method to normalize data for the prognosis oriented validation, based on sigmoid function, is given. The prediction of the features in the future is studied. A regression algorithm based on support vector regression is used. Finally, the diagnosis algorithm is applied to the predicted data. This allows to estimate the end of life, and so the remaining useful life for a given time. These estimations are evaluated regarding different kinds of performance metrics and regarding the constraints of the aeronautics applicative field.

**Keywords:** diagnosis, prognosis, EMA, aeronautics, roller screw, PMSM, friction, pattern recognition, support vector machine, fuzzy, membership functions

# Acronymes

## Acronymes basés sur des mots français

Acronymes	Signification
ADD	Arbre de Décisions
AFNOR	Association Française de NORmalisation
CC	Court - circuit
CEM	Compatibilité Electromagnétique
CO <sub>2</sub>	Dioxyde de carbone
COVADIS	Commandes de Vol Avec Distribution de l'Intelligence et Intégration de Systèmes
DGAC	Direction Générale de l'Aviation Civile
FA	Fonction d'Appartenance
GIFAS	Groupement des Industries Françaises de l'Aéronautique et Spatial
IH	Interaction des fonctions Health-Monitoring vers le système
IS	Intéraction du système vers les fonctions HM
MSAP	Moteur Synchrone à Aimants Permanents
NO <sub>x</sub>	Oxydes d'azote
RA	Rétroaction au niveau des algorithmes
RB	Réseaux Bayésiens
RC	Rétroaction au niveau de la conception
RDF	Reconnaissance de Formes
R&T	Recherche et Technologie
RNA	Réseaux de Neurones Artificiels
SD	Signature de défaut
UE	Union européenne
VAR	Vis à Rouleaux

## Acronymes basés sur des mots anglais

Acronymes	Signification (Français)	Signification (Anglaise)
AUC	Zone sous la courbe	Area Under Curve
BN	Réseau bayésien Naïf	Naive Bayesian Network
CBM	Maintenance préventive conditionnelle	Condition Based Maintenance
CV	Validation Croisée	Cross Validation
EHA	Actionneur électro – hydraulique	Electro – Hydraulic Actuator
EMA	Actionneur Electro - mécanique	Electro – Mechanical Actuator
HA	Actionneur hydraulique	Hydraulic Actuator
HM	Surveillance de l'état de santé	Health – Monitoring
IC	Composante Indépendante	Independant Component
IMF	Mode de fonction intrinsèque	Intrinsic Mode Function
IATA	Association Internationale du Transport Aérien	International Air Transport Association
KFO	Un Kième dehors	K Fold Out
KNN	K plus proches voisins	K Nearest Neighbours
LOO	Laisse un dehors	Leave One Out
MAPE	Erreur Absolue Relative	Mean Absolute Percentage Error
MIMOSA	Maintenance Information Open System Alliance	
NKPI	Indicateurs Clés de Performance Numériques	Numerical Key Performance Indicators
OTO	Un vers les autres	One To Others
OVA	Un contre tous	One Vs All
OVO	Un contre un	One Vs One
PHM	Pronostic et gestion de l'état de santé	Prognosis and Health Management
ROC	Fonction d'efficacité du récepteur	Receiver Operating Characteristic
RUL	Temps de vie utile restant	Remaining Useful Life

SQP	Programmation Quadratique Successive	Sequential Quadratic Programming
SRM	Minimisation du Risque Structurel	Structural Risk Minimization
SV	Vecteur Support	Support Vector
SVM	Machine à Vecteur de Supports	Support Vector Machine
THS	Plan horizontal réglable	Trim Horizontal Stabilizer
UUT	Unité Sous Test	Unit Under Test

# Notations

## Générales

$i, j, k$	Indices
$\mathcal{L}, \mathcal{H}$	Espaces euclidiens
$\hat{z}$	Valeur estimée de $z$
$r_i$	Variable à valeur dans $[0,1]$

## Modélisation du système (Chapitre II)

$v_{abcf}$	Vecteur des tensions dans le repère quadri – phasé (trois phases, $abc$ , et la phase de défaut, $f$ )
$R_{abcf}$	Matrice des résistances
$i_{abcf}$	Vecteur des courants
$L_{abcf}$	Matrice des inductances
$e_{abcf}$	Vecteur des forces électro - motrices
$E_{abcf}$	Formes d'ondes des forces électro - motrices
$\theta_e$	La position électrique
$C_{ut}$	Couple utile
$C_{em}$	Couple électro - magnétique
$C_{det}$	Couple de détente
$C_{fmot}$	Couple de frottements moteurs
$C_{charge}$	Couple de charge sur le MSAP (modèle de simulation)
$I_q$	Le courant en quadrature
$\Omega$	Vitesse du moteur
$F_{df}$	Effort de déformation de la VAR
$F_{aero}$	Effort de charge aérodynamique (modèle de simulation)
$r_{vis}$	Rapport de réduction de la VAR
$pas$	Pas de la VAR
$J_{rot}$	Inertie équivalente du rotor et des éléments roulants (modèle de simulation)
$m_{rot}$	Masse équivalente du rotor et des éléments roulants
$x_{rot}$	Position équivalente en linéaire du rotor
$x_{int}$	Position linéaire intermédiaire
$x_{vis}$	Position de la vis
$m_{vis}$	Masse de la vis
$x_{ec}$	Ecart entre les positions moteur et vis
$x_{jeu}$	Position du jeu
$x_{df}$	Déformation de la vis
$\alpha_{jeu}$	La moitié de l'amplitude du jeu
$k_{vis}$	Raideur de la vis
$c_{vis}$	Amortissement structurel de la vis
$F_{fr}$	Frottements de la VAR
$F_{fv}$	Coefficient des frottements visqueux de la VAR
$F_{fsec}$	Coefficient des frottements secs de la VAR
$K_{rend}$	Coefficient des frottements dépendants de la charge sur la VAR

## Calcul de signatures (Identification d'un modèle de frottements) (Chapitre II)

$C_f$	Couple de frottements équivalents sur le rotor
$C_v$	Coefficient des frottements visqueux des frottements équivalents
$C_{fsec}$	Coefficient des frottements secs des frottements équivalents
$C_c$	Couple de charge sur le MSAP (modèle d'identification)
$F_c$	Effort de charge (mesuré pour le modèle d'identification)
$C_{i_r}$	Couple inertiel du rotor
$J_m$	Inertie équivalente du rotor et des éléments roulants (modèle d'identification)
$K_{mot}$	Coefficient de couple moteur
$N_{pro}$	Nombre de points du profil de caractérisation
$N_{ind}$	Nombre d'individus de la population
$n_{ind}$	Nombre de gènes d'un individu
$XIND$	Individus de la population
$xind_{ij}$	$j$ ème gène du $i$ ème individu
$XIND_{Max-j}$	Valeur maximale du gène $j$
$XIND_{Min-j}$	Valeur minimale du gène $j$
$XMUT$	Mutant
$XNOU$	Nouveaux individus
$randb$	Fonction rendant un nombre aléatoirement généré dans $[0,1]$
$randnbr$	Index sélectionné aléatoirement dans $\{1, \dots, N_{ind}\}$
$CR$	Le taux de croisement (paramètre utilisateur)
$F$	Facteur (paramètre utilisateur)

## Calcul de signatures (Analyse des courants) (Chapitre II)

$y_s$	Signal échantillonné
$N$	Nombre d'échantillons (de points) de $y_s$
$IMF_j$	$j$ ème $IMF$ extraite du signal
$e_{sup} ; e_{inf}$	Enveloppe supérieure (inférieure) du signal
$w_j(\theta)$	Bruit blanc (aléatoire) de paramètres $\theta$ connus (généré à l'itération $j$ )
$IMF_{j,i}$	$i$ ème $IMF$ obtenu pour l'itération $j$
$N_{iter}$	Nombre d'itérations
$E_j$	Opérateur renvoyant le $j$ ème mode obtenu par EMD
$snr_i$	Rapport signal sur bruit à chaque itération
$SO$	Vecteur des sources
$so_i$	$i$ ème source
$A$	Matrice de l'opérateur de mélange
$Y_s$	Ensemble des observations
$h_{ij}$	La réponse impulsionnelle du filtre qui représente l'effet de la source $j$ sur l'observation $i$
$\langle * \rangle$	Produit de convolution
$n_{filtre}$	Ordre du filtre
$T_{def}$	Temps de réponse lors du signal lors de l'apparition brusque d'un défaut
$T_e$	Période d'échantillonnage
$W$	Matrice inverse de $A$
$\Phi_{sep}$	Critère de séparation statistique
$IC_{def}$	Composantes rassemblés au sein d'un groupe de défaut
$\hat{s}_{def}$	Signal virtuel estimé pour un défaut particulier

$IM$	Information Mutuelle
$pdf$	Fonction de densité de probabilité

## Campagne de simulations (Chapitre II)

$R_s$	La résistance statorique
$L_s$	L'inductance statorique
$G_{mesI}$	Le gain de mesure de courant
$G_{mesC}$	Le gain de mesure de charge
$N_{simu}$	Nombre de simulations à effectuer
$N_{pop\_ema}$	Nombre d'individus dans la population d'EMA
$c_{sev}$	Nombre de classes de sévérité
$VN$	Vrais négatifs
$VP$	Vrais positifs
$FN$	Faux négatifs
$FP$	Faux positifs
$TVP$	Taux de vrais positifs
$TFP$	Taux de faux positifs
$GD_{j,i}^k$	Indice de détectabilité pour une signature $i$ , un défaut $j$ et une sévérité de ce même défaut $k$
$GD_{j,i}$	Indice de détectabilité globale du défaut $j$ permis par la signature $i$
$T_{i,j}^k$	Distribution de la signature $i$ pour le défaut $j$ à la sévérité $k$
$V_k$	Matrice de variation
$V_k^j$	Vecteur de variation du défaut $j$ pour la sévérité $k$
$GI$	Indicateur d'identification globale

## Mathématiques du flou (Chapitres II, IV et V)

$u$	Fonction d'appartenance
$\varphi$	Norme triangulaire (T-norme ou T-conorme)
$T$	T-norme
$\perp$	T-conorme
$\Psi$	Opérateur de fusion d'information basé sur une norme $\varphi$
$\mathcal{C}$	Opérateur de complémentation

## Reconnaissance de formes (Chapitres II, IV et V)

$p$	Nombre de paramètres
$x$	Observation ( $x \in \mathbb{R}^p$ )
$x_j$	$j^{\text{ième}}$ paramètre de $x$
$m$	Nombre d'observations
$X$	Base de données (Matrice de taille $(m, p)$ )
$X_i$	$i^{\text{ième}}$ observation de $X$
$X_{ic}$	$i^{\text{ième}}$ observation du sous ensemble de $X$ représentant la $c^{\text{ième}}$ classe
$XT$	Base de test (Matrice de taille $(m_t, p)$ )
$y$	Classe (label) de l'observation $x$
$Y$	Vecteur des labels correspondant à la base $X$ (Vecteur de taille $(m, 1)$ )

$Y_i$	Label de $X_i$
$c$	Nombre de classes
$d$	Métrique de distance
$\Phi$	Opérateur de projection (transformation non linéaire)
$K$	Fonction noyau
$\sigma$	Paramètre de la fonction noyau à base radiale
$f(x, \alpha)$	Fonction de prédiction de la classe d'une opération
$\alpha$	Paramètres de la fonction de prédiction (SVM : multiplicateurs de Lagrange)
$L[f(x, \alpha), y]$	Fonction perte
$R(\alpha)$	Risque Actuel
$R_{emp}(\alpha)$	Risque Empirique
$h$	Dimension de Vapnik-Chervonenkis
$A$	Confiance de Vapnik-Chervonenkis
$F$	Ensemble de fonctions de prédiction de classe
$\omega$	Vecteur poids (SVM)
$b$	Biais de l'hyperplan
$mg$	Marge de l'hyperplan séparateur
$H_1, H_2$	Hyperplan séparateur
$L_P$	Lagrangien primal
$L_D$	Lagrangien duale
$S$	Vecteur Support
$N_S$	Nombre de vecteurs supports
$x_{new}$	Observation devant être classifié par un modèle RDF
$\hat{y}_{new}$	Classe estimée pour $x_{new}$
$\xi_i$	Variable d'ajustement
$C$	Paramètre de tolérance aux erreurs
$d_x$	Distance de l'observation $x$ à l'hyperplan séparateur
$d_{sv}$	Distance des vecteurs supports à l'hyperplan séparateur
$u_+$	Fonction d'appartenance à la classe +1
$u_-$	Fonction d'appartenance à la classe -1
$\gamma$	Degré d'appartenance des vecteurs supports à l'hyperplan
$pa$	Paramètre des fonctions d'appartenances
$U_{class}$	Matrice des appartenances des observations aux classes
$U_{others}$	Vecteur de l'appartenance des observations à des classes inconnues
$MDLF$	Un ensemble de modèles de SVM-FA binaires
$U_{all}$	Matrice des appartenances des observations aux classes du côté « All » (Méthode OVA)
$U_{class_k}$	Matrice des appartenances des observations à la classe $k$ (Méthode OVO)
$U_{rel}$	Vecteur des appartenances des observations aux classes connues
$U_{c+}$	Matrice des appartenances aux classes successives du côté +1
$U_{rest}$	Matrice des appartenances aux classes successives du côté -1
$g_k$	Centre de gravité de la classe $k$
$ID$	Indicateur de rejet en distance
$IA$	Indicateur d'ambiguïté
$ID_{ref}$	Indicateur de rejet de référence
$IA_{ref}$	Indicateur d'ambiguïté de référence
$\vartheta$	Paramètre de sévérité
$me$	Mesures d'erreur
$crit$	Critères liés aux mesures d'erreurs
$seuil$	Seuil utilisé pour les critères

$MDL^r$	Modèle SVM réglé
$MDLF^r$	Modèle SVM – FA réglé
$\hat{R}$	Risque actuel estimé

## Validation expérimentale (Chapitre IV)

$N_{vit}$	Vitesse du moteur en t/min
$i_q$	Courant de charge
$R_f$	Résistance de défaut
$P$	Précision de la classification
$f_s$	La fréquence des courants statoriques
$f_r$	La fréquence de rotation du rotor
$I_s$	Courant statorique
$I_{s1} ; I_{s2}$	Courant statorique selon l'axe 1 (axe 2) du repère de Concordia
$c_{def}$	Nombre de classe modèle défaut
$c_{sev}$	Nombre de classe modèle sévérité
$MEM_{def}$	Quantité de mémoire prise par un modèle de détection de défaut
$MEM_{sev}$	Quantité de mémoire prise par un modèle de diagnostic de sévérité
$MEM$	Quantité de mémoire prise par un modèle de diagnostic (défaut et sévérité des défauts)
$J$	Critère pour la sélection de signature
$\Sigma_W$	Matrice de dispersion intra – classes
$\Sigma_B$	Matrice de dispersion inter – classes
$p_{opt}$	Nombre de paramètres optimaux

## Pronostic (Chapitre V)

$RUL$	Durée de vie utile restante réelle
$t_{EOL}$	Temps de fin de vie ( <i>End Of Life</i> )
$\mathbf{X}_{t-no \rightarrow t}$	Séquence de $no$ observations des valeurs de signatures allant jusqu'à $t$
$f_P$	Modèle de prédiction
$\hat{\mathbf{X}}_{t+1 \rightarrow t+hp}$	Séquence estimée jusqu'à l'horizon de prédiction $hp$
$PH$	Horizon de pronostic
$\alpha_e$	Intervalle d'exactitude sur l'estimation de la RUL
$t_\lambda$	Temps à partir duquel la prédiction doit être dans l'intervalle d'exactitude
$\lambda_t$	Constante, choisi par l'utilisateur, paramétrant $t_\lambda$
$P_{(\alpha_e - \lambda_t)}$	Précision liée au cône d'exactitude
$RA$	Précision Relative
$CRA$	Précision Relative Cumulée
$MDL$	Modèle de classification par SVM - FA
$MDLRJ$	Modèle de prédiction pour la signature $j$
$CT$	Cohérence Temporelle
$ct$	Cohérence Temporelle entre deux observations successives
$CTN$	Cohérence Temporelle Normalisée
$\Omega_i$	Ensemble des observations de la $i^{ème}$ classe
$E_{par}$	Critère d'énergie
$A_d$	Matrice semi – définie positive définissant la métrique de distance $d$
$\pi_{sig}$	Fonction de normalisation sigmoïdale

$\delta$	Valeur de $\pi_{sig}$ pour la valeur maximale du paramètre
$LR_P$	Lagrangien primal (régression)
$LR_D$	Lagrangien duale (régression)
$\xi_i ; \xi_i^*$	Fonctions de sensibilités
$\varepsilon$	Paramètre des fonctions de sensibilités
$\alpha_i ; \alpha_i^*$	Coefficients de Lagrange primaires et duales
<i>MEMPRED</i>	Quantité de mémoire prise par les modèles de prédiction

# Problématiques

- Problématique 1** : Comment mettre au point des algorithmes de diagnostic et de pronostic robustes aux conditions aéronautiques ? ..... 40
- Problématique 2** : Comment mettre au point des signatures pour les défauts de transmission vis-écrou comme les vis à rouleaux satellites ? ..... 41
- Problématique 3** : Comment mettre à jour les algorithmes à partir de données opérationnelles ? ... 41

# Contraintes

- Contrainte 1** : Manque de données représentatives ..... 41
- Contrainte 2** : Embarcabilité des algorithmes ..... 41

# Hypothèses

<b>Hypothèse 1</b> : Réseau électrique d'alimentation supposé parfait.....	29
<b>Hypothèse 2</b> : Seul un actionneur est en défaut.....	46
<b>Hypothèse 3</b> : Les coefficients de frottements de la VAR sont identiques dans les deux sens de déplacement.....	50
<b>Hypothèse 4</b> : Le moteur synchrone à aimants est supposé linéaire sur la plage de fonctionnement considérée (pas de phénomènes de saturation).....	57
<b>Hypothèse 5</b> : Les signaux provenant de sources physiquement distinctes sont statistiquement indépendants.....	62
<b>Hypothèse 6</b> : Représentativité des bases de données .....	76
<b>Hypothèse 7</b> : Volume des bases de données .....	77
<b>Hypothèse 8</b> : Les classes des observations sont connues .....	78
<b>Hypothèse 9</b> : Pour pouvoir passer d'un modèle de diagnostic RDF à $c$ classes à un modèle à $c' > c$ classes la base de données doit augmenter de $c'c^2$ bits. ....	139
<b>Hypothèse 10</b> : La mémoire nécessaire pour stocker un modèle SVM - FA évolue comme celle de la base nécessaire pour l'entraîner.....	139
<b>Hypothèse 11</b> : Les quantités de mémoire de référence pour le diagnostic et la sévérité sont celles obtenues pour la base MSAP « riche ».....	139
<b>Hypothèse 12</b> : La dégradation du système est monotone .....	145
<b>Hypothèse 13</b> : Le système se dégrade uniquement en fonctionnement.....	145
<b>Hypothèse 14</b> : Une base de données représentative du vieillissement du système/composant est disponible .....	156
<b>Hypothèse 15</b> : Le temps de fin de vie est atteint lorsque le composant / système atteint la dernière classe de sévérité du défaut.....	160
<b>Hypothèse 16</b> : Le diagnostic de sévérité nécessite au plus sept signatures .....	183

# Sommaire

<b>I</b>	<b>INTRODUCTION : VERS LA MAINTENANCE PREDICTIVE DES SYSTEMES AERONAUTIQUES.....</b>	<b>16</b>
	1 - CONTEXTE .....	18
	2 - STRATEGIES DE MAINTENANCE.....	34
	3 - LE CADRE PHM .....	35
	4 - PROBLEMATIQUES.....	40
<b>II</b>	<b>CALCUL DE SIGNATURES DE DEFAUTS.....</b>	<b>44</b>
	1 - MODELE DE L'EMA.....	46
	2 - GENERALITES SUR LES SIGNATURES .....	50
	3 - SIGNATURES POUR EMA DE COMMANDE DE VOL .....	54
	4 - IDENTIFICATION DES FROTTEMENTS.....	56
	5 - ANALYSE DES COURANTS .....	59
	6 - METHODOLOGIE DE VALIDATION .....	66
	7 - VALIDATION PAR SIMULATION.....	69
	8 - CONCLUSION DU CHAPITRE .....	72
<b>III</b>	<b>DIAGNOSTIC PAR RECONNAISSANCE DE FORMES .....</b>	<b>74</b>
	1 - GENERALITES .....	76
	2 - LA RECONNAISSANCE DE FORMES (RDF) .....	76
	3 - MACHINE A VECTEURS DE SUPPORT (SVM).....	83
	4 - SVM ET FONCTIONS D'APPARTENANCE .....	93
	5 - ARCHITECTURE DU SYSTEME DE DIAGNOSTIC.....	113
	6 - CONCLUSION DU CHAPITRE .....	114
<b>IV</b>	<b>VALIDATION EXPERIMENTALE.....</b>	<b>115</b>
	1 - GENERALITES .....	117
	2 - PRESENTATION DES BANCS.....	117
	3 - EXTRACTION DE SIGNATURES .....	120
	4 - DIAGNOSTIC.....	124
	5 - RESPECT DES CONTRAINTES .....	138
	6 - CONCLUSION DU CHAPITRE .....	140
<b>V</b>	<b>VERS LE PRONOSTIC.....</b>	<b>142</b>
	1 - GENERALITES .....	145
	2 - SOURCE DE DONNEES.....	157
	3 - SIGNATURES ISSUES DES DONNEES.....	158
	4 - PARTITIONNEMENT DE SERIES TEMPORELLES.....	160
	5 - REGLAGE ET VALIDATION DU DIAGNOSTIC.....	165
	6 - PREDICTION DES SIGNATURES .....	173
	7 - ESTIMATION DES APPARTENANCES.....	176
	8 - ESTIMATION DE LA RUL .....	178
	9 - CONCLUSION DU CHAPITRE .....	183
<b>VI</b>	<b>CONCLUSION ET PERSPECTIVES.....</b>	<b>185</b>

1 - CONCLUSION GENERALE .....	186
2 - PERSPECTIVES.....	188
<b>VII BIBLIOGRAPHIE.....</b>	<b>192</b>
<b>VIII ANNEXES .....</b>	<b>211</b>
1 - ALGORITHMES EMD .....	213
2 - CRITERE D'INDEPENDANCE STATISTIQUE.....	215
3 - ÉCHANTILLONNAGE PAR HYPERCUBE LATIN .....	215
4 - NKPI.....	216
5 - DETAIL DES NKPI POUR LES SIGNATURES PROPOSEES .....	218
6 - CALCUL DES PARAMETRES DES FA.....	219
7 - EXEMPLES DE TNORMES .....	225
8 - BANC MACHINE ASYNCHRONE.....	229
9 - BANC MACHINE SYNCHRONE A AIMANTS.....	230
10 - SELECTION DE PARAMETRES .....	232
11 - METRIQUES D'ÉVALUATION.....	233
12 - ALGORITHME DES C – MOYENNES.....	235
13 - RESULTATS DE PARTITIONNEMENTS.....	237
14 - COMPARAISONS DES TEMPS DE FIN DE VIE .....	239
15 - NORMALISATION PAR SIGMOÏDE .....	239
16 - PREDICTION DE SIGNATURES.....	240
17 - ESTIMATION DE LA RUL .....	244
<b>LISTE DES FIGURES .....</b>	<b>246</b>
<b>LISTE DES TABLEAUX .....</b>	<b>251</b>

# I

## Introduction :

# Vers la maintenance prédictive des systèmes aéronautiques



<b>I</b>	<b>INTRODUCTION : VERS LA MAINTENANCE PREDICTIVE DES SYSTEMES AERONAUTIQUES.....</b>	<b>16</b>
1	CONTEXTE .....	18
1.1	<i>Défis de l'industrie aéronautique</i> .....	18
1.2	<i>L'avion plus électrique</i> .....	20
1.3	<i>Les commandes de vol</i> .....	21
1.3.a	Commandes de vol primaires .....	22
1.3.a.i	Axe de roulis .....	22
1.3.a.ii	Axe de tangage .....	22
1.3.a.iii	Axe de lacet .....	23
1.3.b	Commandes de vol secondaires .....	23
1.3.b.i	Commandes purement secondaires .....	23
1.3.b.ii	Commandes primaires influant sur la portance.....	24
1.3.c	Actionneurs pour les commandes de vol .....	24
1.3.c.i	Commande et puissance mécanique .....	24
1.3.c.ii	Commande mécanique et puissance hydraulique .....	24
1.3.c.iii	Commande électrique et puissance hydraulique (réseau) .....	25
1.3.c.iv	Commande électrique et puissance hydraulique (groupe).....	26
1.3.c.v	Commande et puissance électrique .....	26
1.4	<i>L'EMA Covadis pour Aileron</i> .....	27
1.4.a	Architecture d'implémentation .....	27
1.4.b	Composants .....	28
1.4.c	Défauts des EMA .....	29
1.4.d	Mécanismes des défaillances.....	30
1.4.d.i	Fatigue des surfaces de contact.....	30
1.4.d.ii	Dégradation des isolants électriques.....	32
2	STRATEGIES DE MAINTENANCE .....	34
2.1	<i>Maintenance Corrective</i> .....	34
2.2	<i>Maintenance Préventive</i> .....	35
3	LE CADRE PHM .....	35
3.1	<i>Généralités</i> .....	35
3.2	<i>Le Health–Monitoring (HM)</i> .....	37
3.2.a	Conception des fonctions HM.....	37
3.2.b	Fonctions HM en opérations .....	38
3.3	<i>Cycles de développement</i> .....	39
4	PROBLEMATIQUES.....	40
4.1	<i>Problématiques et contraintes</i> .....	40
4.2	<i>Structure du manuscrit</i> .....	42

# 1 - Contexte

## 1.1 - Défis de l'industrie aéronautique

L'industrie aéronautique, comme toutes les industries du transport et de l'énergie, est dans une phase de transition technologique, caractérisée par trois défis majeurs :

1. Réduire l'impact environnemental des aéronefs
2. Absorber l'augmentation du trafic
3. Augmenter la rentabilité des compagnies aériennes

L'ensemble de ces défis devront être résolu en maintenant, voire en augmentant la sûreté des vols. Le transport aérien ne représente actuellement que 2 à 3% des émissions de gaz à effet de serre d'origine humaine (**GIFAS 2011**). Dans le même temps, il est prévu que le trafic double tous les 20 ans, porté par l'augmentation des niveaux de vie en Asie, en Europe de l'est et en Amérique du sud (**Airbus 2016; Boeing 2016**). Ainsi, sans actions correctives, il est prévu que les émissions soient de 4 à 6 fois supérieures en 2050 (**DGAC 2014**). Tous les acteurs de l'industrie doivent donc travailler pour stabiliser puis réduire ces émissions.

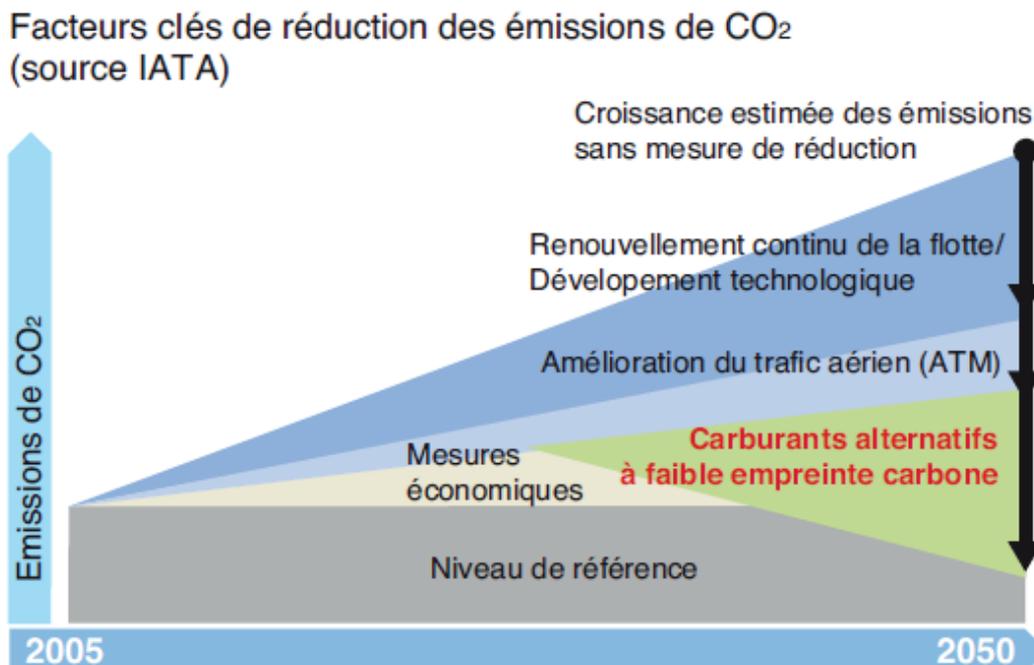


Figure I.1 : Evolutions des émissions de CO<sub>2</sub> et facteurs clés de réduction (DGAC 2014)

Le transport aérien a un impact environnemental au niveau des émissions sonores et au niveau des émissions polluantes. Les principales molécules polluantes émises lors d'un vol sont le dioxyde de carbone (CO<sub>2</sub>), à hauteur de 99%, et les oxydes d'azote (NO<sub>x</sub>), pour moins de 1% (**European Aviation Safety Agency et al. 2016**). Tous les deux sont des gaz à effets de serre ayant un impact sur le réchauffement climatique. Les NO<sub>x</sub> ont également des effets sur la qualité de l'air (**Chossière et al. 2017**). L'union européenne (UE) a fixé des objectifs de réduction des émissions à court (2020) et long (2050) termes. Ces objectifs sont calculés à partir d'une référence année 2000. Les réductions visées

à court terme, par passager/km, sont de 50% pour le CO<sub>2</sub> et de 80% pour les NO<sub>x</sub>. Le bruit perçu devra être réduit de 50% (GIFAS 2011). A long terme, les émissions de CO<sub>2</sub> devront être réduites de 75%, celles de NO<sub>x</sub> de 90% et le bruit perçu de 65%.

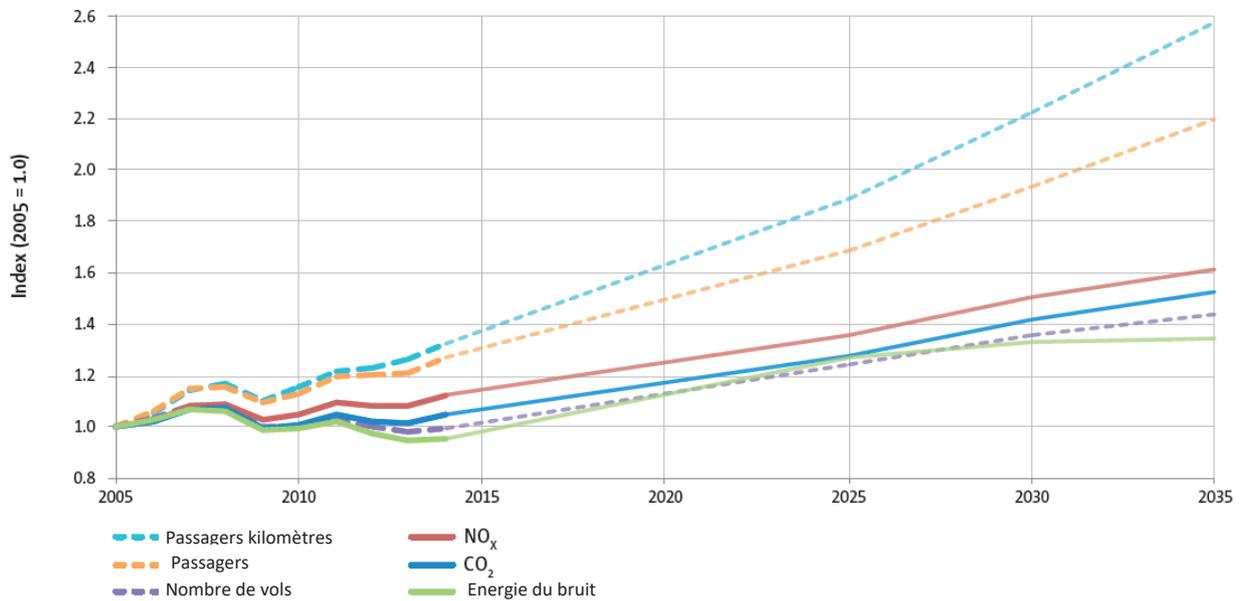


Figure I.2 : Prévisions des émissions et de trafic jusqu'en 2035 (European Aviation Safety Agency et al. 2016)

Tout l'enjeu est donc d'absorber l'augmentation du trafic en respectant les contraintes environnementales et de sûreté. Une réponse à cela est d'augmenter la flotte d'avions en service. En effet, il est prévu que celle-ci double d'ici à 2035 (Airbus 2016; Boeing 2016). Plus des 70% des aéronefs en circulation devraient être des monocouloirs de type A320 / B737.

Type d'avion	Nombre en service (2015)	Nombre en service (2035)	Nombre d'avion neuf (2035)
Gros porteurs (A380 – B747-400)	740	700	530
Long courrier Moyen porteur (A350 ; B777)	1640	3690	3470
Long Courrier Petit Porteur (A330 ; B787)	2660	6060	5100
Monocouloir (A320 ; B737)	<b>14870</b>	<b>32280</b>	<b>28140</b>
Régional (ATR)	2600	2510	2380
<b>TOTAL</b>	<b>22510</b>	<b>45240</b>	<b>39620</b>

Tableau I.1 : Etat et évolution prévue de la flotte mondiale (Boeing 2016)

Néanmoins, sans des changements technologiques importants, l'augmentation de la flotte seule n'est pas une réponse suffisante. C'est pourquoi l'industrie aéronautique, dans son ensemble, se dirige vers des avions plus électriques.

## 1.2 - L'avion plus électrique

La puissance électrique disponible sur les avions « traditionnels » (développés avant l'A380) est généralement sous les 400 kVA. Cette puissance a connu une nette augmentation sur les derniers grands programmes d'importance : l'A380 et le B787 (Roboam et al. 2012; Seabridge et Moir 2013; Setlak 2016).

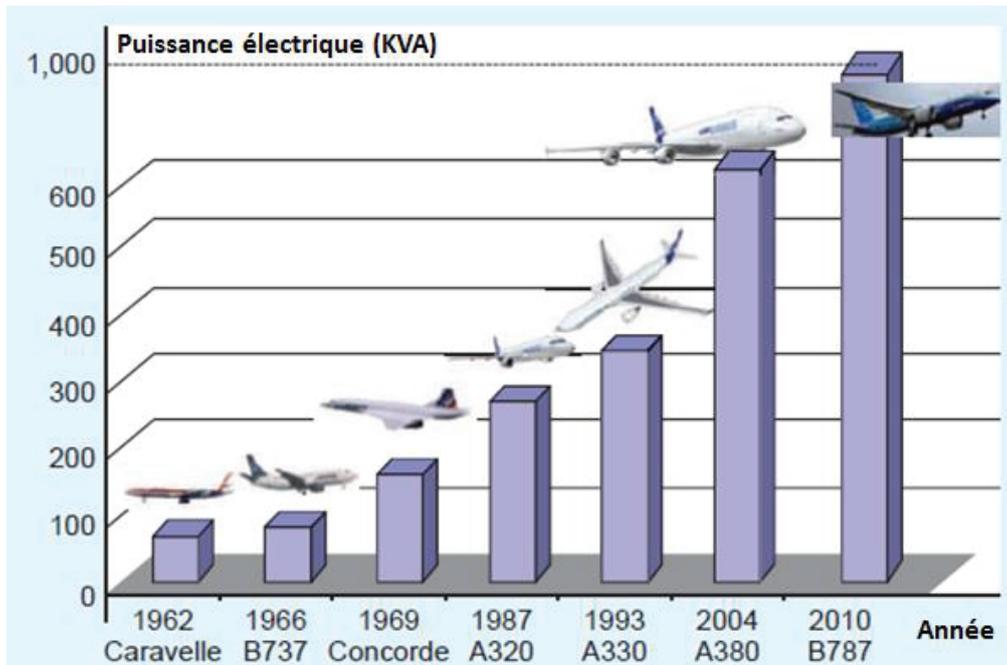


Figure 1.3 : Evolution des besoins en puissance électrique (Roboam et al. 2012)

La différence ne s'explique pas seulement par le fait que ces deux avions soient des gros porteurs. Elle est principalement due au fait que des fonctions, auparavant gérées par des actionneurs alimentés en hydraulique ou pneumatique, ont été converties en électrique. Les fonctions, hors propulsion, nécessaires au bon fonctionnement d'un avion sont précisées dans (Wheeler 2014) et au Tableau I.2.

La majorité des fonctions classiquement non électriques sont, *a minima*, à l'étude pour être converties en électrique. De nouvelles fonctions peuvent également être mises au point par l'utilisation de systèmes électriques. On peut notamment citer le « *electric green taxiing system* » mis au point par Safran et Honeywell (Johnson 2014). Ce système permet à l'avion de se déplacer sur le tarmac sans avoir à allumer ses réacteurs, ce qui permet des gains non négligeables en carburant.

Les objectifs de l'électrification sont nombreux, mais le premier est une réduction de la masse embarquée. En effet, les systèmes hydrauliques, bien qu'offrant des densités de puissance importantes, nécessitent des infrastructures lourdes d'alimentation (Langlois et al. 2005; Rosero et al. 2007). Ainsi, une réduction de près de 1500 kg a été permise par l'utilisation d'actionneurs plus électriques pour les commandes de vol de l'A380 (Adams 2001). De plus, les réseaux hydrauliques peuvent être l'objet de fuites. Les huiles utilisées dans l'aéronautique étant corrosives, cela pose un problème pour la santé des opérateurs et pour l'environnement. Ces systèmes nécessitent donc une maintenance soutenue et régulière (Botten et al. 2000; van den Bossche 2004). Un autre aspect important de l'électrification est de rationaliser les sources et réseaux d'énergie. Cela permettrait un meilleur contrôle des demandes de puissance ainsi que des capacités de reconfiguration en cas de

défaut (**Wheeler 2014**). Parmi les fonctions non propulsives considérées pour l'électrification, le cas des commandes de vol sera traité dans cette thèse.

Fonction	Objectif	Source d'énergie classique
Pompes à carburants	Injecter le carburant dans la chambre de combustion	Mécanique <i>(via réducteur sur le turboréacteur)</i>
Pompes à huile	Assurer la bonne lubrification du turboréacteur	Mécanique
Air conditionné	Assurer la circulation de l'air dans la cabine	Pneumatique <i>(via flux d'air haute pression prélevé sur le turboréacteur)</i>
Pressurisation de la cabine	Assurer le maintien de la pression atmosphérique dans la cabine	Pneumatique
Protection du givrage	Prévenir l'accumulation de glace sur les surfaces de vol	Pneumatique
<b>Commande de vol</b>	<b>Manœuvrer l'avion dans l'espace et assurer sa stabilité</b>	<b>Hydraulique</b> <i>(via réducteur sur le turboréacteur entraînant une pompe)</i>
Train d'atterrissage	Sortir et rentrer les trains	Hydraulique
Frein	Ralentir l'avion lors des phases au sol	Hydraulique
Direction	Assurer la manœuvrabilité de l'avion lors des phases au sol	Hydraulique
Portes	Ouvrir et fermer les portes pour permettre l'accès à l'avion	Hydraulique
Avionique	Aider à la navigation via la mesure (capteurs : gyroscope, accéléromètres...), le calcul (ordinateurs de bord) et la communication (écrans, radar, radio...)	Electrique <i>(via réducteur sur le turboréacteur entraînant un générateur)</i>

Tableau I.2 : Principales fonctions non propulsives dans l'aéronautique civile (Wheeler 2014)

### 1.3 - Les commandes de vol

Les mouvements de l'avion s'articulent selon le référentiel fixé au centre de gravité de l'avion. Celui-ci présente le point fixe de l'avion, qui à son tour présente le repère mobile dans le repère terrestre. Les commandes de vol primaires, qui permettent à l'avion de s'orienter selon les trois axes de l'espace, seront distinguées des commandes de vol secondaires, qui servent à optimiser la portance de l'avion (**Dupin 2009**). Les premières sont donc essentielles au bon déroulement et à la sûreté du vol. Les secondes permettent de faciliter certaines phases.

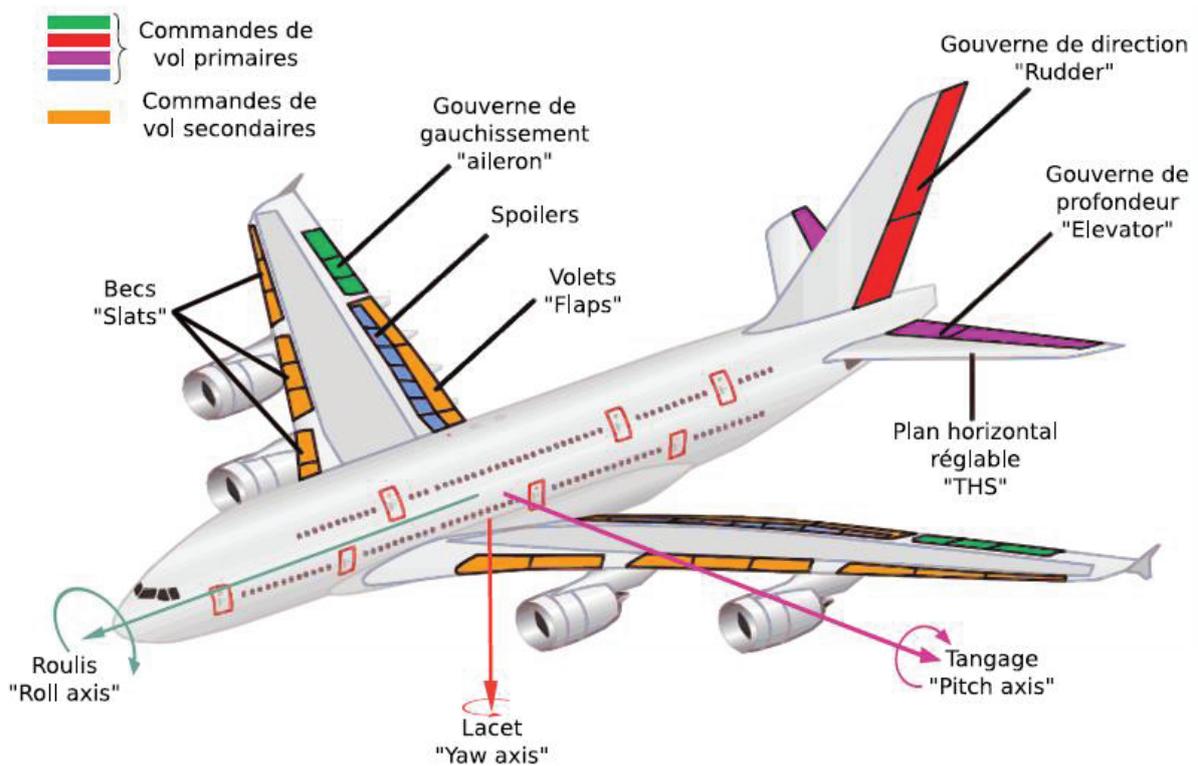


Figure I.4 : Surfaces de commande de vol et axes de l'avion (Delehelle 2008)

### 1.3.a - Commandes de vol primaires

#### 1.3.a.i - Axe de roulis

La commande selon cet axe permet à l'avion de tourner selon l'axe du fuselage passant par le centre de gravité (référentiel avion). L'avion penche ainsi du côté d'une des deux ailes. Les gouvernes contrôlant cet axe sont les gouvernes d'aileron, commandées en opposition gauche – droite, avec un éventuel renfort des gouvernes de spoilers.



Figure I.5 : Manœuvre selon l'axe de roulis (Dupin 2009)

#### 1.3.a.ii - Axe de tangage

La commande selon cet axe permet à l'avion de tourner selon l'axe perpendiculaire au fuselage et

passant par le centre de gravité (référentiel avion). L'avion peut ainsi incliner son nez, ou à l'inverse, le remonter. Les gouvernes contrôlant cet axe sont les gouvernes de profondeurs aidées pour l'équilibrage par le plan fixe horizontal réglable (*Trim Horizontal Stabilizer : THS*).



Figure I.6 : Manœuvre selon l'axe de tangage (Dupin 2009)

### 1.3.a.iii - Axe de lacet

La commande selon cet axe permet à l'avion de tourner selon le dernier axe du repère de l'avion. L'avion peut ainsi orienter son nez sur les côtés. Les gouvernes contrôlant cet axe sont les gouvernes de direction. Les aérofreins peuvent également être utilisés, notamment pour contrer les effets indésirables liés à l'actionnement des ailerons (lacet inverse).



Figure I.7 : Manœuvre selon l'axe de lacet (Dupin 2009)

## 1.3.b - Commandes de vol secondaires

### 1.3.b.i - Commandes purement secondaires

Les becs sont situés sur le bord d'attaque (avant) de l'aile. Les volets sont eux situés sur le bord de fuite (arrière) de l'aile. Ces deux commandes de vol ont la même fonction. Elles permettent en effet de faire varier la portance de l'avion en agissant sur la surface. Cela permet de faciliter les phases de décollages et d'atterrissage.

### 1.3.b.ii - Commandes primaires influant sur la portance

Certaines commandes primaires, les spoilers et les ailerons (commandés en symétrie), ont également une influence sur la portance.

## 1.3.c - Actionneurs pour les commandes de vol

On distingue cinq types de système d'actionnement de commande de vol, en fonction de leur énergie de commande et de celle de puissance. Le premier est le système à commande et puissance mécanique, le plus ancien. Le deuxième est composé de systèmes à commande mécanique et à puissance hydraulique. Le troisième est constitué de systèmes à commande électrique et à puissance hydraulique. Ces deux types sont regroupés sous la dénomination « *Hydraulic Actuator* » (HA). Le quatrième regroupe les actionneurs électrohydrauliques (« *Electro – Hydraulic Actuator* » : EHA). Enfin le dernier concerne les actionneurs électromécaniques (« *Electromechanical Actuator* » : EMA).

### 1.3.c.i - Commande et puissance mécanique

Les systèmes de commande de vol les plus anciens sont purement mécaniques. Le pilote déplace le manche. Le mouvement est transmis, via un ensemble de composants mécaniques (câbles, poulies...) à la gouverne. Celle-ci subit des efforts aérodynamiques résistants qui sont transmis au manche via les composants mécaniques.

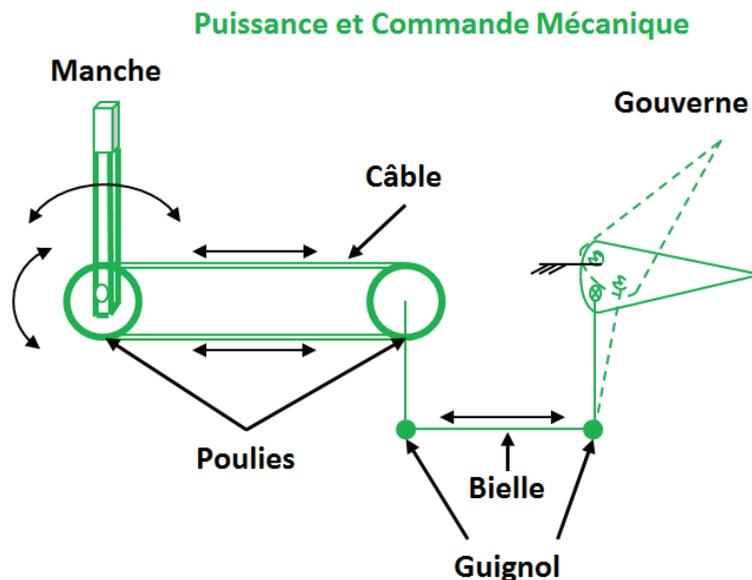


Figure I.8 : Système d'actionnement de commande de vol mécanique

La limitation de ce type de système est liée à la capacité du pilote à combattre les efforts aérodynamiques pour imposer la position voulue. De plus la boucle de rétroaction permettant au pilote de corriger sa commande est relativement limitée. Il s'agit des efforts transmis par le manche qui résultent en sensations pour le pilote. Enfin ce type de système nécessite une maintenance importante. En effet, il faut prévenir tout grippage et rupture, risquant de bloquer les gouvernes.

### 1.3.c.ii - Commande mécanique et puissance hydraulique

Dans ce type de système, une partie du système mécanique de transmission est remplacée par un actionneur hydraulique. Celui-ci est alimenté par un distributeur, commandé mécaniquement par le

pilote. Le distributeur est alimenté en huile par un réseau de bord.

**Commande Mécanique**  
**Puissance Hydraulique et Mécanique**

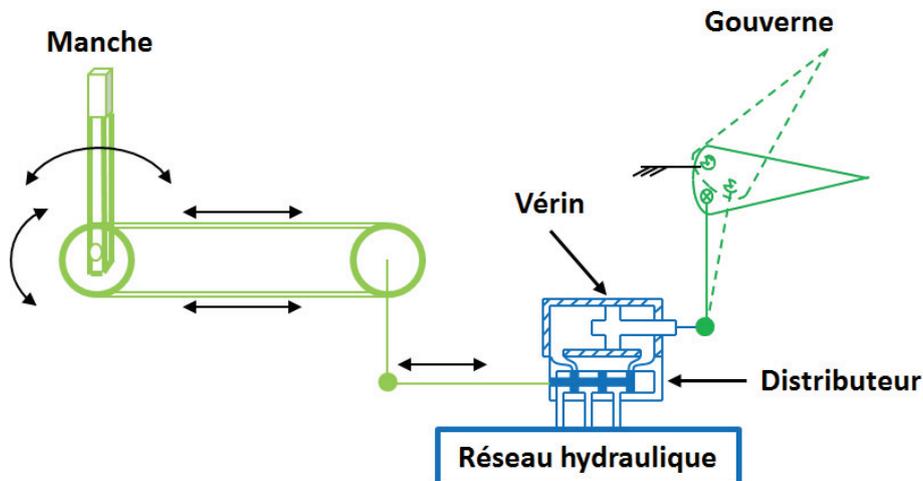


Figure I.9 : Système d'actionnement de commande de vol hydromécanique (HA)

Via ce système, le pilote n'a plus qu'à fournir des efforts minimes. L'inconvénient est qu'il faut créer et entretenir un réseau d'huile sous pression au sein de l'avion. A noter également que pour simuler le retour d'effort de la gouverne vers le manche, des actionneurs supplémentaires de plus faibles puissances, sont placés à proximité de celui-ci.

**1.3.c.iii - Commande électrique et puissance hydraulique (réseau)**

Ce type de système permet de supprimer tous liens mécaniques au niveau du manche. Ceux-ci sont remplacés par la transmission de signaux électriques. On parle de « Vol par fil » (*Fly by Wire*).

**Commande Mécanique et Electrique**  
**Puissance Hydraulique et Mécanique**

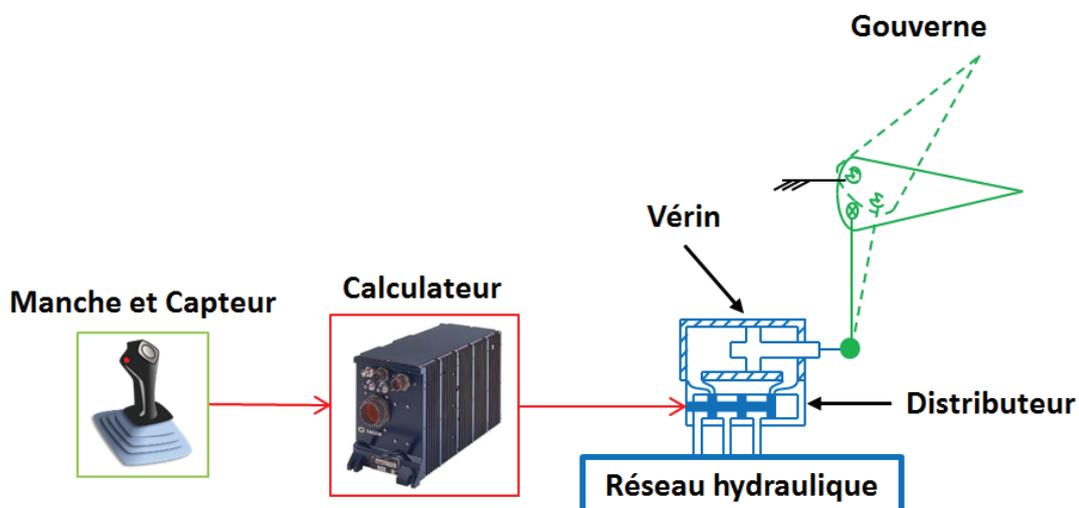


Figure I.10 : Système d'actionnement de commande de vol hydraulique (HA – Fly by Wire)

Le principe reste le même que pour le système précédent à la différence que le distributeur est

commandé électriquement. Cela permet un contrôle plus fin de la position des gouvernes, via des asservissements programmés dans un ordinateur, ainsi que des possibilités de redondance et de reconfiguration plus aisées. Néanmoins, un réseau hydraulique et la maintenance associée sont toujours nécessaires.

### 1.3.c.iv - Commande électrique et puissance hydraulique (groupe)

Ce type de système permet de se passer du réseau hydraulique, en créant la puissance localement.

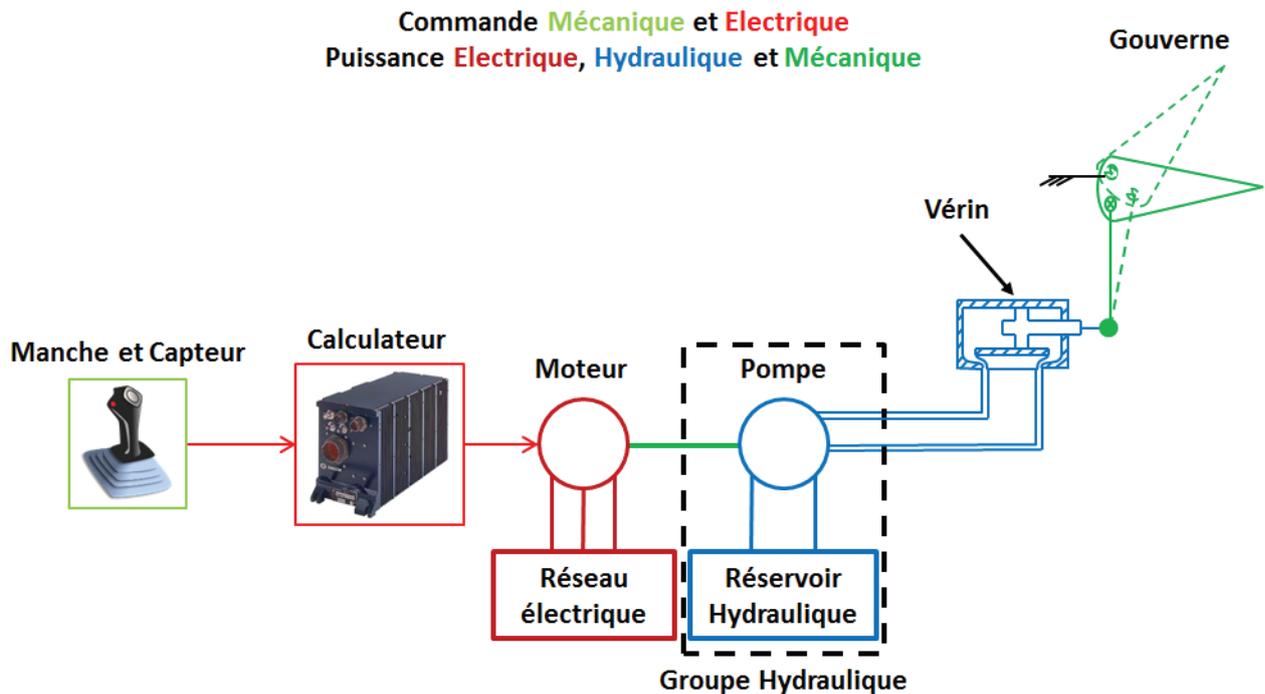


Figure I.11 : Système d'actionnement de commande de vol hydroélectrique (EHA)

Cela nécessite néanmoins la présence d'un réseau électrique de puissance. Le calculateur commande un actionneur électrique qui va entraîner une pompe. Cela va permettre de fournir la puissance nécessaire à un vérin hydraulique, lié à la gouverne. Les coûts de maintenance sont amoindris, tout comme la masse globale nécessaire. Néanmoins, le prix d'un tel système est plus élevé. A noter que certains EHA sont redondés pour pouvoir être alimentés par le réseau hydraulique. On parle alors de « Electrical Back-up Hydraulic Actuators » (EBHA).

### 1.3.c.v - Commande et puissance électrique

L'objectif, à terme, étant de se passer totalement de la puissance hydraulique, de nouveaux types d'actionneurs ont été introduits dans l'avionique civile ces dernières années. Ces systèmes sont composés d'un actionneur électrique couplé à un système de transmission mécanique. Avec ce type de système, l'architecture est simplifiée et les réseaux de puissances sont rationalisés. Néanmoins, on retrouve un problème présent sur les premiers types de commande de vol, à savoir le grippage. En effet, tout blocage du système de transmission peut immobiliser la gouverne. La transmission directe, entre le moteur électrique et la gouverne est donc inenvisageable, de par les limites inhérentes aux technologies actuelles. Il est donc nécessaire d'équiper les EMA de dispositif anti –

coincement (Cronin 1986; Gonzalez-Tablas et al. 2015; de Arriba et Gallego 2016).

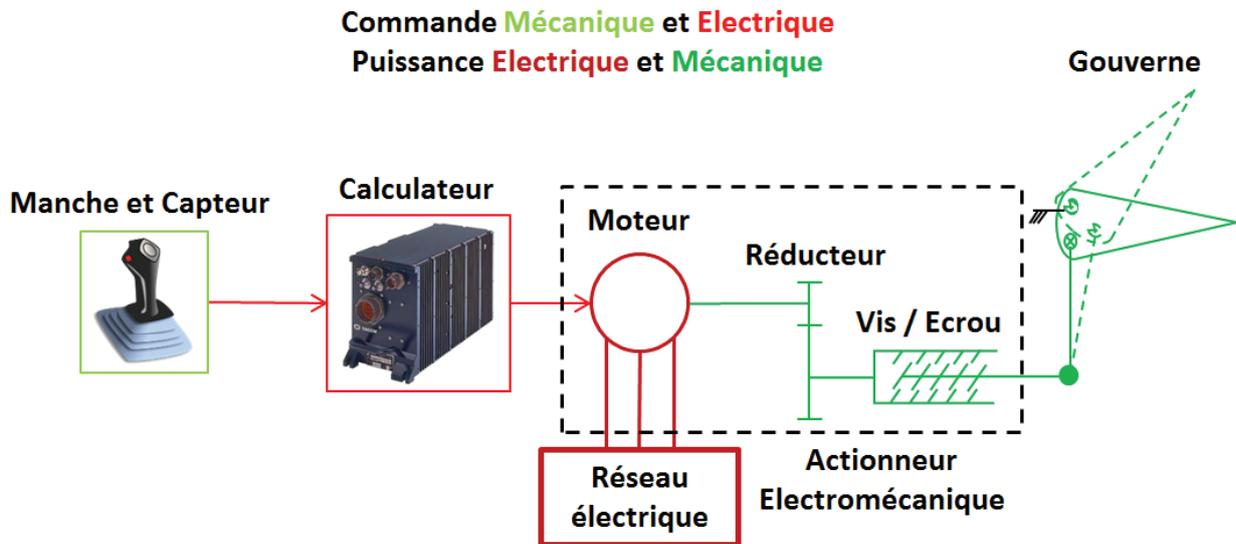


Figure I.12 : Système d'actionnement de commande de vol électromécanique (EMA)

Un autre problème important se situe au niveau de la thermique (Sanchez 2017). En effet, les actionneurs hydrauliques sont naturellement refroidis par la circulation de l'huile, qui assure la convection. Pour les EMA, il n'est pas envisageable de rajouter un système de refroidissement, pour des raisons de masse, de coûts et de complexité. Il faut donc que l'actionneur dégage le moins de chaleur possible (haut rendement) et que celle-ci soit dissipée « naturellement ».

Les EMA ont premièrement été intégrés dans le domaine de l'aviation militaire. Ils n'ont fait que récemment leur apparition dans l'aéronautique civile (Maré 2017). On peut notamment citer les becs de l'A380, les plans horizontaux réglables de l'A350 et du KC390 ou les aérofreins du B787. A noter que ces actionneurs sont souvent redondés avec des actionneurs hydrauliques.

La société Safran Electronics & Defense (anciennement Sagem Défense Sécurité) a orienté sa R&T pour développer des EMA performants et fiables et ce depuis plusieurs années (Derrien 2012). Les efforts fournis ont permis de mettre au point un actionneur électromécanique pour aileron au travers du projet COVADIS (Derrien et al. 2011).

## 1.4 - L'EMA Covadis pour Aileron

Le projet COVADIS (*Commande de Vols Avec Distribution de l'Intelligence et Intégration de Systèmes*), mené avec Airbus, a permis à Safran Electronics & Defense de tester en vol un actionneur électromécanique pour commande de vol primaire (Safran 2011). Celui-ci a volé sur un A320, avion de type monocouloir. Cet actionneur étant à l'origine du développement des EMA pour la commande de vol chez Safran, il constitue le cadre applicatif des travaux de thèse présentés ici.

### 1.4.a - Architecture d'implémentation

L'implémentation de cet actionneur se fait par deux, en parallèle, de manière à augmenter la fiabilité globale du système (Figure I.13). Aucun système d'accouplement n'existe, pour éviter de diminuer la fiabilité globale et d'augmenter la masse embarquée. Un seul actionneur est suffisant pour déplacer l'aileron. Le deuxième est présent en cas de défaillance du premier, il joue également le rôle d'un

amortisseur passif grâce à la structure spécifique du circuit magnétique du moteur (Piaton 2010). Des stratégies de commande sont mises en place pour répartir le plus équitablement possible le vieillissement entre les deux actionneurs (Bonny 2013). Les deux EMA sont alimentés par le réseau de bord (115 VAC à 400 Hz).

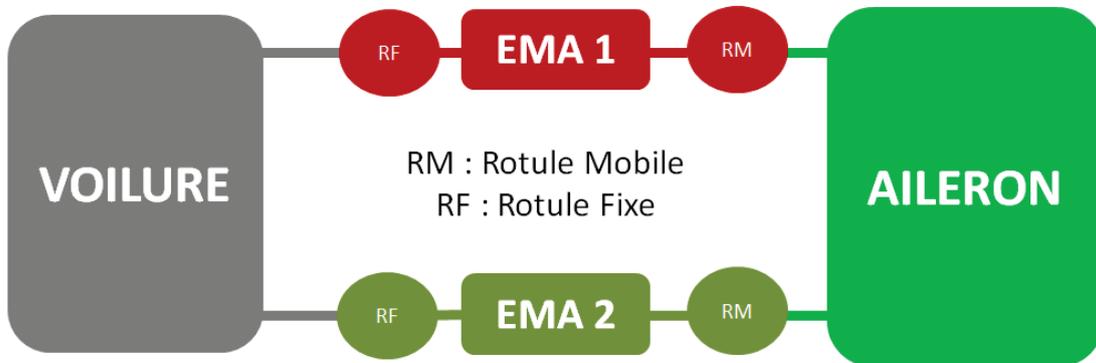


Figure I.13 : Architecture simplifiée d'implémentation de l'EMA Covadis dans l'aile de l'avion

### 1.4.b - Composants

Un EMA Covadis est composé des principaux éléments suivants (voir Figure I.14) :

- ⇒ Un moteur synchrone à aimants (MSAP) à grand nombre de paires de pôles
- ⇒ Un système de vis à rouleaux satellites (VAR) pour faire la transformation rotatif / linéaire
- ⇒ Une électronique de puissance qui redresse le 115 VAC qui alimente un onduleur, lui-même alimentant le moteur
- ⇒ Un calculateur de commande pour assurer : l'asservissement du moteur, la communication avec les réseaux de bord avionique et les surveillances élémentaires
- ⇒ Une rotule de fixation (côté voilure)
- ⇒ Une rotule mobile (côté aileron, liée à la vis)

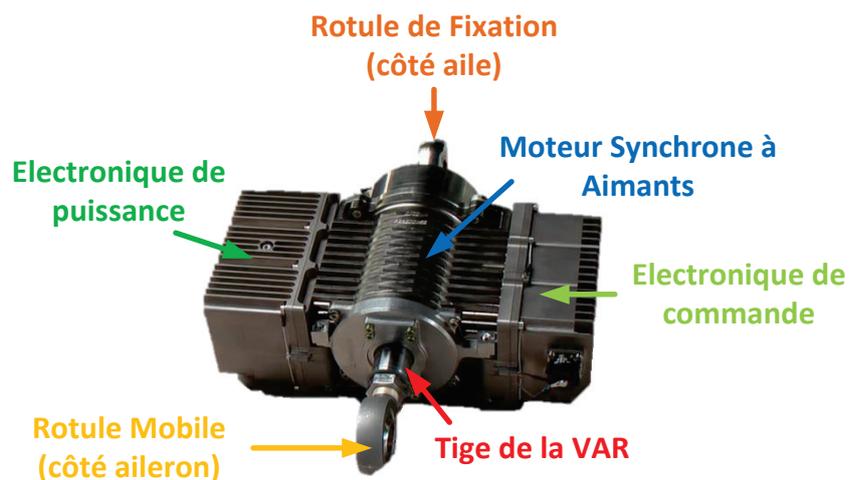


Figure I.14 : EMA Covadis et ses principaux composants

### 1.4.c - Défauts des EMA

Dans le cadre de cette thèse seuls les défauts au niveau de l'EMA seront considérés. On fera donc l'hypothèse suivante :

#### Hypothèse 1 : Réseau électrique d'alimentation supposé parfait

Le réseau électrique de bord alimentant l'actionneur est supposé parfait. Il fournit des formes de tensions parfaites et est capable de fournir suffisamment de courant pour tous les points de fonctionnement de l'actionneur.

Quatre grands types de défauts peuvent être distingués, en fonction du type de composants touchés :

- ⇒ Défauts électroniques
- ⇒ Défauts capteurs
- ⇒ Défauts moteur
- ⇒ Défauts mécaniques

Les défauts électroniques sont séparés entre les défauts au niveau de la partie puissance et ceux au niveau de la partie commande. Pour la puissance, les composants les plus souvent en défaut sont, par ordre de fréquence décroissante, les condensateurs, les modules de puissance (pont redresseur et pont onduleur) et les inductances (**Rome Laboratory et Reliability Analysis Center 1994; Imam et al. 2005; Yang et al. 2010**).

Pour la partie commande, les défauts peuvent être matériels (microprocesseur, PCB, diodes...) ou liés à un bug logiciel (**Brière et Traverse 1993; Seo et al. 2010**). Des redondances sont mises en place pour éviter ce type de défauts.

Les défauts capteurs concernent les capteurs embarqués. Ils entraînent la transmission d'une information partiellement ou totalement fautive à l'électronique de commande.

Les défauts moteurs se distinguent en trois grands types : les défauts stator, les défauts rotor et les défauts de roulements (**Thorsen et Dalva 1995; Bonnett 2000; Chafai et al. 2008**).

Les défauts mécaniques concernent la transmission située entre le moteur et la rotule liée à l'aileron. Dans notre cas, il s'agit des défauts de la vis à rouleaux satellites (**Lemor 1996**).

Les défauts électroniques sont étudiés par une autre équipe au sein de Safran Electronics & Defense. Les défauts capteurs ont déjà été considérés au sein de l'entreprise par le passé. Ainsi, nous nous sommes concentrés sur les défauts moteurs et sur les défauts mécaniques.

Parmi les défauts moteurs les plus prépondérants sont les défauts roulements et les défauts stator (**Chafai et al. 2008**). Il est important de noter que ces derniers ont tendance à augmenter pour les moteurs alimentés par onduleur (**Bellomo et al. 1996; Culbert et al. 2009**). Parmi les défauts stator, le court-circuit inter-spires est le plus fréquent (**Zotos 1993; Thorsen et Dalva 1995**). Enfin, tout défaut de la VAR, notamment le défaut de grippage, de par l'architecture, peut entraîner un blocage de l'aileron. Ce défaut est donc catastrophique vis-à-vis de la commande de vol primaire et doit être anticipé. Ainsi, nous considérerons les défauts suivants (Tableau I.3) :

Nom	Type	Composants	Fréquence	Gravité	Criticité
<b>Roulements à rouleaux</b>	Mécanique (Moteur)	Roulements	Probable	Conséquences matérielles/financières	Marginal à Critique
<b>Court-Circuit inter spires</b>	Electrique	Stator	Probable	Conséquences matérielles/financières	Marginal à Critique
<b>Usure, grippage</b>	Mécanique	VAR	Rare	Conséquences humaines	Catastrophique

Tableau I.3 : Défauts de l'EMA considérés

## 1.4.d - Mécanismes des défaillances

### 1.4.d.i - Fatigue des surfaces de contact

La surface de contact est définie comme la limite externe d'un corps solide (Béranger et Mazille 2005). Etant donné que tout corps est utilisé dans un environnement, la surface est un lieu d'interface avec d'autres corps : gazeux, liquide ou solide. De par ce rôle, c'est au niveau des surfaces que se situent les défauts des composants. Dans le cas des composants qui nous intéressent, l'interface est solide/liquide, lorsque la lubrification se fait correctement, ou solide/solide lorsque celle-ci est déficiente.

Il est important de noter que les surfaces de contact, contrairement à la représentation que l'on s'en fait usuellement, ne sont pas parfaitement planes. Une surface est en effet constituée d'un ensemble d'aspérités, de l'ordre du micromètre (Tran 2015) (voir Figure I.15). L'usure des surfaces de contact est définie de manière générale comme un enlèvement ou un déplacement de matière (Flamand et al. 2013). On peut distinguer différents types d'usure.

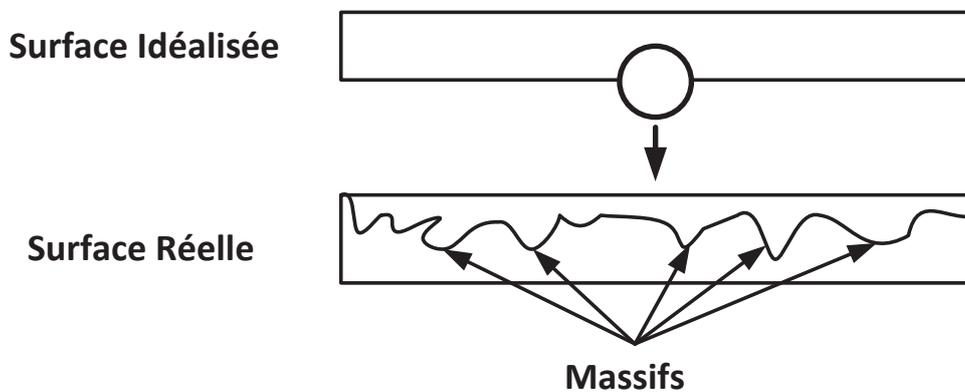


Figure I.15 : Surface d'un solide

Les déformations plastiques sont issues de surcharges sur les massifs des aspérités et peuvent amorcer des fissures ou perturber la lubrification. Elles précèdent l'écaillage ou fatigue superficielle. Ce type d'usure se produit pour des contacts très chargés. Il voit apparaître des cavités aux bords abrupts de l'ordre du dixième de millimètre de profondeur. L'écaillage est précédé de fissures de mêmes profondeurs et souvent de micro-écailles. Celles-ci sont 10 à 20 fois plus petites que les écailles. Elles sont dues à la répétition de cycles qui entraîne l'apparition de contraintes mécaniques dans les massifs.



Figure I.16 : Roulement à rouleaux écaillé (SKF 1994)

En l'absence d'une bonne lubrification, de l'adhérence entre les massifs des surfaces peut apparaître. Cela crée des contraintes à l'origine de fissurations. Si le lubrifiant est contaminé par des particules, des phénomènes de corrosion peuvent apparaître. De plus, associé à des vitesses de glissement entre les deux éléments en contact, ces mécanismes peuvent créer des dégagements d'énergies. Ceux-ci entraînent une montée en température locale qui fait fusionner la matière et entraîne des adhésions, des soudures, entre les deux surfaces de contact. On parle alors de *grippage*. Sous charge, ces microsoudures se cassent entraînant un déplacement brutal de matières et une usure sévère. La répétition de ce phénomène peut entraîner, à terme, un blocage complet du mécanisme.

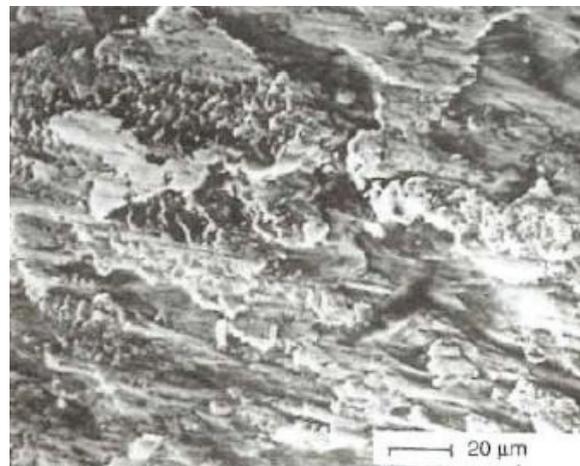


Figure I.17 : Effets du grippage (Flamand et al. 2013)

L'injection d'éléments extérieurs peut favoriser et accélérer l'ensemble des phénomènes cités précédemment. Pour les EMA, on peut également observer de l'usure lié à la mauvaise isolation électrique des composants mécaniques. Celle-ci entraîne la création d'un couplage capacitif entre les enroulements statoriques et le rotor, qui lui-même entraîne la circulation de courants de mode commun entre les deux (Charoy et Dunand 2007; ABB 2011; Bishop 2017). Ceux-ci entraînent des micro-fusions qui créent des stries caractéristiques.



Figure I.18 : Marques caractéristiques dues au passage de courants (Bishop 2017)

Enfin, il est important de noter que l'on observe rarement un seul type d'usure. Dans la pratique, ceux-ci sont souvent combinés.

#### 1.4.d.ii - Dégradation des isolants électriques

Un isolant électrique est défini comme une substance ou un corps dont la conductivité électrique est nulle, ou dans la pratique très faible (Pinel et Duchateau 1999; Aguet et Ianoz 2001). Un isolant a donc très peu de charges libres pouvant permettre la circulation d'un courant électrique. Dans le cadre d'un composant ou d'un système électrique, la fonction d'un isolant est d'empêcher la conduction entre des éléments conducteurs soumis à des tensions différentes. Pour une dimension et une géométrie données, la capacité d'un isolant à soutenir une certaine tension est liée à sa permittivité (Fournié et Coelho 1986; Raju 2016). Celle-ci est représentative de l'amplitude des mécanismes de polarisation du matériau. La polarisation représente le fait que lors de l'application d'un champ au diélectrique, celui-ci voit apparaître un champ interne s'opposant au premier. Ce champ est dû à l'orientation des dipôles électriques internes du matériau, ou polarisation (voir Figure I.19). Avec le vieillissement du matériau isolant, la capacité à se polariser pour contrer le champ externe diminue. Cela augmente les risques que l'isolant ne puisse plus assurer sa fonction et qu'il subisse un claquage. Le claquage consiste en un passage brusque de courant qui entraîne des dommages permanents sur le matériau.

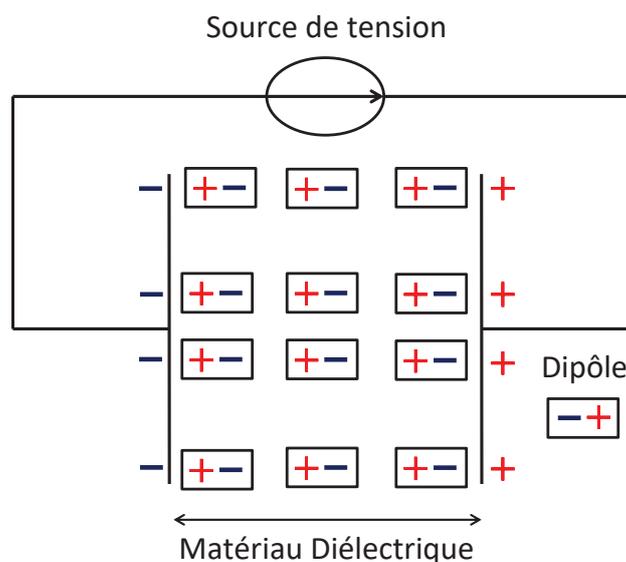


Figure I.19 : Exemple de polarisation d'un isolant sous champ constant (adapté de (Raju 2016))

La famille des isolants électriques est très large tant par leur nature (polymères, céramique, papier, huile, air, ...) que par leur état physique (solide, liquide, gazeux) (Pinel et Duchateau 1999; Anton 2003). Un isolant donné est choisi en fonction d'une application et des contraintes définissant celles-ci (facteurs de stress, possibilités d'industrialisation, ...) (Pinel et Duchateau 1999; Mihaila et al. 2014). Pour une application de moteur électrique, l'isolation des enroulements statoriques se fait à trois niveaux : entre les phases, entre les enroulements et le carter métallique de la machine et entre spires d'une même bobine (Mihaila 2011; Moeneclaey 2015). C'est sur ce dernier niveau que l'épaisseur de l'isolant est la plus faible (voir Figure I.20). Cela entraîne donc un vieillissement et un risque de défaut plus élevé. En général, les fils constituant les enroulements sont d'abord émaillés, c'est-à-dire recouvert d'une couche de matériau assurant l'isolation électrique. Puis, ils sont recouverts d'un vernis d'imprégnation qui permet la tenue mécanique du bobinage. Pour les moteurs de type aéronautique, les matériaux utilisés sont en général basés sur des polymères organiques (polyéther, polyamide-imide, polyamide, ...).

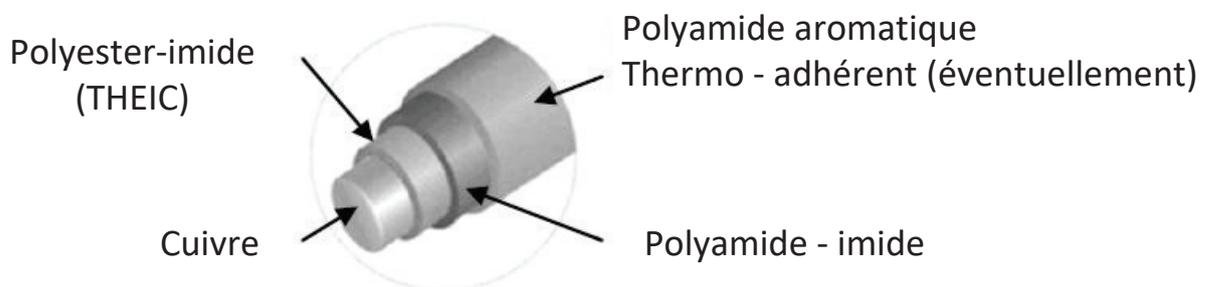


Figure I.20 : Couches possibles d'un fil émaillé (Mihaila 2011)

Les matériaux isolants dans les moteurs électriques sont soumis à quatre types de stress (Mihaila et al. 2014) :

- ⇒ Electrique : surtensions, décharges partielles
- ⇒ Thermique : oxydation, contraintes thermomécaniques
- ⇒ Mécanique : vibrations, frottements
- ⇒ Environnemental : humidité, acidité, radiations

Pour le stress électrique, les surtensions peuvent être dues à des phénomènes de résonance entre le câble d'alimentation et les enroulements pour de fortes variations de tensions lors des commutations de l'onduleur. Les surtensions apparaissent alors aux bornes du moteur. De plus, la distribution de la tension dans un enroulement n'étant ni instantanée, ni homogène, des surtensions locales (au niveau des enroulements) peuvent également apparaître. Ce genre de surtensions survient plutôt dans les premiers enroulements. La combinaison de ces surtensions et de la présence de corps étrangers, d'air notamment, dans l'isolant peut déclencher des phénomènes de décharges partielles. Les effets de ces décharges sur l'isolant sont nombreux : délaminage et érosion, augmentation locale de la température pouvant atteindre le point de fusion, création de substances agressives (acide, ozone...). A terme, si l'isolant est complètement détruit sur une zone cela peut aboutir à une décharge totale (Maussion et al. 2015).

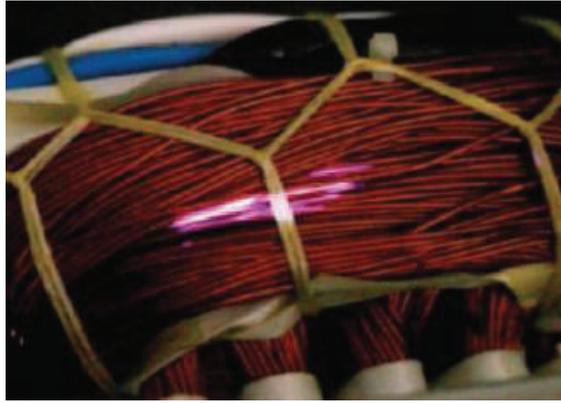


Figure I.21 : Décharge partielle entre enroulements voisins d'un moteur alimenté par onduleur (Billard et al. 2014)

Des températures importantes aggravent et accélèrent l'apparition de ces phénomènes. La température accélère également les phénomènes d'oxydation. Enfin, les variations de températures peuvent créer des contraintes mécaniques dans le matériau isolant, qui peuvent conduire à l'apparition de fissures. Les vibrations, elles, contribuent au déclenchement et à la propagation de fissures. Les facteurs environnementaux contribuent, eux, fortement à l'endommagement de l'isolant. Enfin, il faut noter qu'en pratique, l'ensemble de ces facteurs sont combinés, ce qui aggrave et accélère les effets de chacun.

## 2 - Stratégies de maintenance

La maintenance est définie comme (AFNOR 2002) « l'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destiné à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise ». Différentes stratégies de maintenances existent (Méchin 2005).

### 2.1 - Maintenance Corrective

La maintenance corrective est définie comme une « maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise » (AFNOR 2002). Ce type de maintenance consiste à réagir après une panne, en réparant le système. Cela peut consister à remplacer les composants défectueux ou bien à les réparer. Ce type de stratégie ne s'adresse qu'à des fonctions non critiques. Elles doivent également faire l'objet d'une étude économique pour s'assurer que leur impact financier reste dans la limite acceptable. Une différence est faite entre :

- ⇒ **La maintenance palliative** : remise en état provisoire du système.
- ⇒ **La maintenance curative** : remise en état définitive de l'équipement. Après réparation, le système a retrouvé ses caractéristiques d'avant l'apparition du défaut.
- ⇒ **La maintenance d'amélioration** : consiste à réparer de manière définitive le système et à effectuer des modifications afin de prévenir la réapparition du défaut.

## 2.2 - Maintenance Préventive

La maintenance préventive est définie comme « *la maintenance destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien* » (AFNOR 2002). Ce type de stratégie est utilisé pour les systèmes critiques et pour ceux dont l'augmentation de la disponibilité génère des économies suffisamment importantes. On distingue trois types de maintenance préventive (Méchin 2005) :

- ⇒ **La maintenance préventive systématique** : consiste à effectuer des opérations (inspections, réparations, ...) selon un échéancier d'interventions. Celui-ci est déterminé à partir de la connaissance du système et de ses composants ainsi que du taux de charge de celui-ci. C'est la méthodologie la plus aisée à mettre en œuvre.
- ⇒ **La maintenance préventive conditionnelle (Condition Based Maintenance : CBM)** : consiste à n'effectuer des réparations que si l'état du système le nécessite. Cela implique de disposer de moyens de surveillance précis et robustes de l'état du système.
- ⇒ **La maintenance préventive prévisionnelle** : consiste à effectuer des prévisions sur l'évolution des paramètres de suivi de la dégradation et à utiliser ces prévisions pour anticiper sur les actions de maintenance (CEN 2001). On parle aussi de maintenance prédictive.

Dans l'aéronautique, la maintenance systématique (PIPAME 2010) est très largement utilisée. La maintenance conditionnelle existe également. La maintenance prévisionnelle commence tout juste, elle, à être mise en application (Loukil 2015; Quévrin et Raynal 2015; Renaud 2017). Bien que cette famille de méthodologies n'en soit qu'à ses débuts, les premiers résultats sont impressionnants. Par la mise en place de ces méthodologies sur ses A380, la société Air-France KLM a réduit le temps d'identification et de localisation de la panne de 6 heures à 5 minutes (Loukil 2015). Ainsi, la maintenance prévisionnelle suscite de fortes attentes (Hoyland et al. 2016). La mise en place de ce type de maintenance se fait via un cadre dit cadre PHM « *Prognosis and Health Management* ».

## 3 - Le cadre PHM

### 3.1 - Généralités

Le PHM est issu d'un standard proposé au début des années 2000 par l'association MIMOSA (Lebold et Thurston 2001; Lebold et al. 2002). Ce standard propose un cadre logiciel pour mettre en place de la maintenance industrielle conditionnelle et prévisionnelle. Il a notamment conduit à une normalisation (ISO 2015). Le PHM reprend l'essentiel du standard MIMOSA en rajoutant une fonction d'aide à la décision (Gouriveau et al. 2013). Ainsi le cadre PHM est constitué des fonctions suivantes :

1. **Acquisition des données** : Cette fonction se fait via des capteurs (courants, vibratoires, températures, ...), via des contrôles exceptionnels non-destructifs (rayon X, acoustique, ...) ou via des informations fournies par des opérateurs (fichier de suivi de maintenance, ...).

2. **Traitement des données** : Dans un premier temps, cela consiste à prétraiter (filtrage, diminution du bruit, suppression des doublons, ...) les données. Puis les données prétraitées sont utilisées pour extraire des signatures de défauts. Une signature est une grandeur variant avec l'apparition et le degré de sévérité d'au moins un défaut. Ces signatures peuvent être basées sur des modèles (résidus, évolution de paramètres...) ou sur des données brutes (analyse temporelle, fréquentielle ou temps – fréquence).

3. **Diagnostic** : Sur la base des signatures, ce module évalue l'état de santé du système. S'il détecte un défaut, il peut déterminer sa localisation (quel composant ?) et éventuellement sa sévérité. Certains modules de diagnostic peuvent également mettre en avant les causes probables du défaut.

4. **Pronostic** : Estimation, à partir des résultats de diagnostic et de l'évolution temporelle des signatures, du temps de vie utile restant (*Remaining Useful Life* : RUL). Cette valeur doit être fournie avec ses incertitudes.

5. **Aide à la décision** : A partir des estimations de la RUL, les fonctions d'aide à la décision recommandent les actions de maintenance à effectuer.

6. **Présentation** : Recueille les informations de tous les modules précédents et les synthétise. Puis, communique aux intervenants des différents corps de métier (système PHM, maintenance, logistique, exploitation, ...) les informations qui les concernent.

Une nouvelle version du cadre est ici proposée, tenant compte de rétroactions sur le cycle PHM.

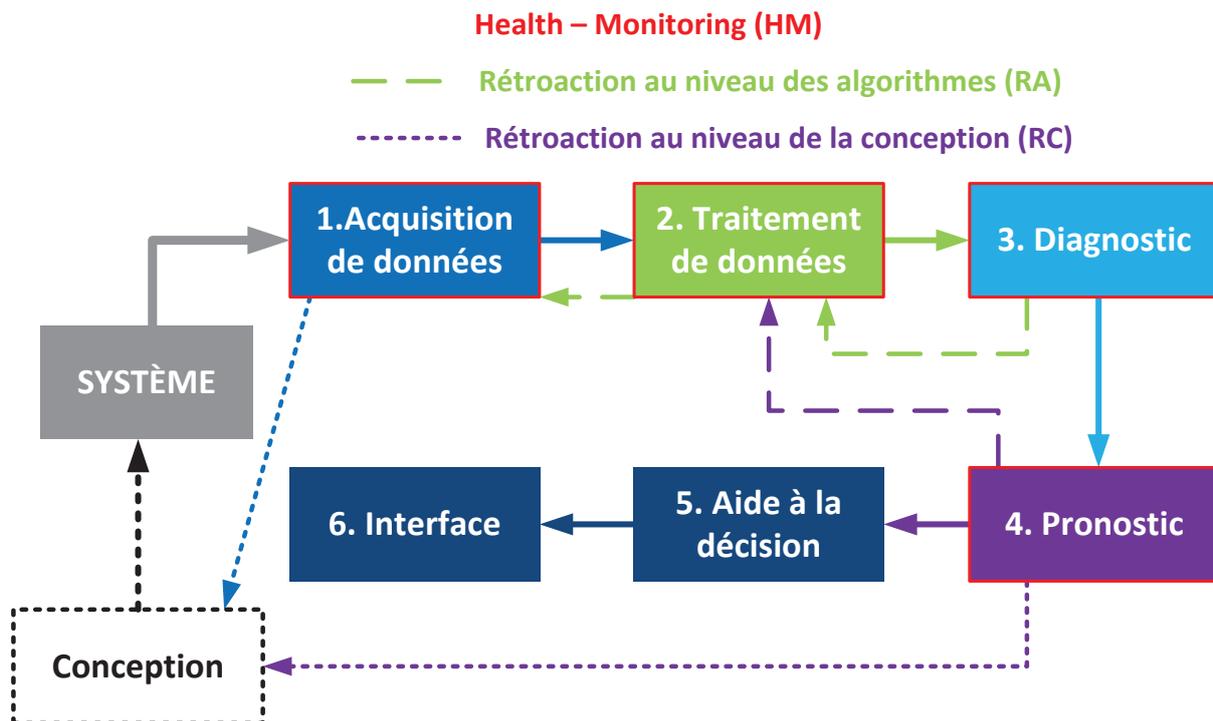


Figure I.22 : Nouvelle version du cycle PHM, avec rétroactions

Ces rétroactions supposent que le système et ses fonctions PHM sont utilisés en opérations. Dans notre cas cela suppose que le système et ses fonctions PHM sont utilisés sur une population d'aéronefs. On distingue deux types de rétroactions : les rétroactions au niveau des algorithmes (notées RA) et celles au niveau de la conception (RC). Les premières permettent d'améliorer les algorithmes via des données opérationnelles et à partir des performances affichées par les

algorithmes en opération. Les deuxièmes permettent de capitaliser pour de futures conceptions d'équipement, notamment en développant des lois de vieillissement en conditions opérationnelles. Elles peuvent également servir à revoir les capteurs embarqués d'un système. Dans le cadre de cette thèse, seule les rétroactions RA seront traitées.

Les fonctions 1 à 4 correspondent à une sous partie du cycle communément appelé « *Health – Monitoring* » ou « *Surveillance de l'état de santé* ». Seule, cette sous partie sera abordée dans cette thèse.

## 3.2 - Le Health–Monitoring (HM)

On distingue deux sous processus pour le health-monitoring. Le premier correspond à la phase de conception et de réglage des algorithmes. Le deuxième correspond à leur utilisation en opérations.

### 3.2.a - Conception des fonctions HM

Lors de la phase de conception des algorithmes, l'acquisition de données se fait au travers d'essais expérimentaux ou via des simulations de modèles représentatifs. Les essais peuvent consister à recréer artificiellement un défaut ou à faire vieillir de manière accélérée le système. Les simulations reposent, elles, sur la connaissance de l'évolution de paramètres caractéristiques avec le vieillissement. Dans les deux cas, des incertitudes liées à la représentativité des générateurs de données existent. Suite à cela, les données sont acquises puis prétraitées.

Le prétraitement correspond à l'ensemble des opérations nécessaires pour rendre les données plus facilement exploitables. Dans un premier temps, les données brutes sont converties en un format compatible avec les logiciels de traitement. Elles sont ensuite partiellement visualisées pour permettre un premier nettoyage : suppression des doublons, des points singuliers, .... Enfin, si cela s'avère nécessaire, la qualité des données peut être améliorée par des techniques de traitement du signal (filtrage, ...).

Les données traitées servent ensuite à mettre au point les signatures. On obtient ainsi une base des signatures, qui sera évaluée selon un ou plusieurs critères. Cette évaluation va permettre de déterminer les signatures les plus sensibles ainsi que celles permettant de séparer au mieux les différents modes de défauts.

Une nouvelle base, constituée des signatures sélectionnées, va permettre de mettre au point les algorithmes de diagnostic puis de pronostic. En fonction des performances affichées par ceux-ci, des retours sur la phase d'extraction des signatures peuvent être faits.

La phase de conception aboutit à un ensemble de fonctions constitué d'un ensemble de signatures optimales, (et des algorithmes pour les calculer), d'un modèle de diagnostic et d'un modèle de pronostic. Dans le cadre aéronautique, l'objectif moyen terme est que l'ensemble de ces fonctions soient embarquées. Des fonctions plus évoluées, pour le pronostic à horizon long notamment, peuvent néanmoins exister dans le cadre d'une exploitation hors-ligne. Ces fonctions pourront coexister avec les fonctions embarquées.

Suite à la phase de conception, les fonctions vont être utilisées pour des systèmes en opérations.

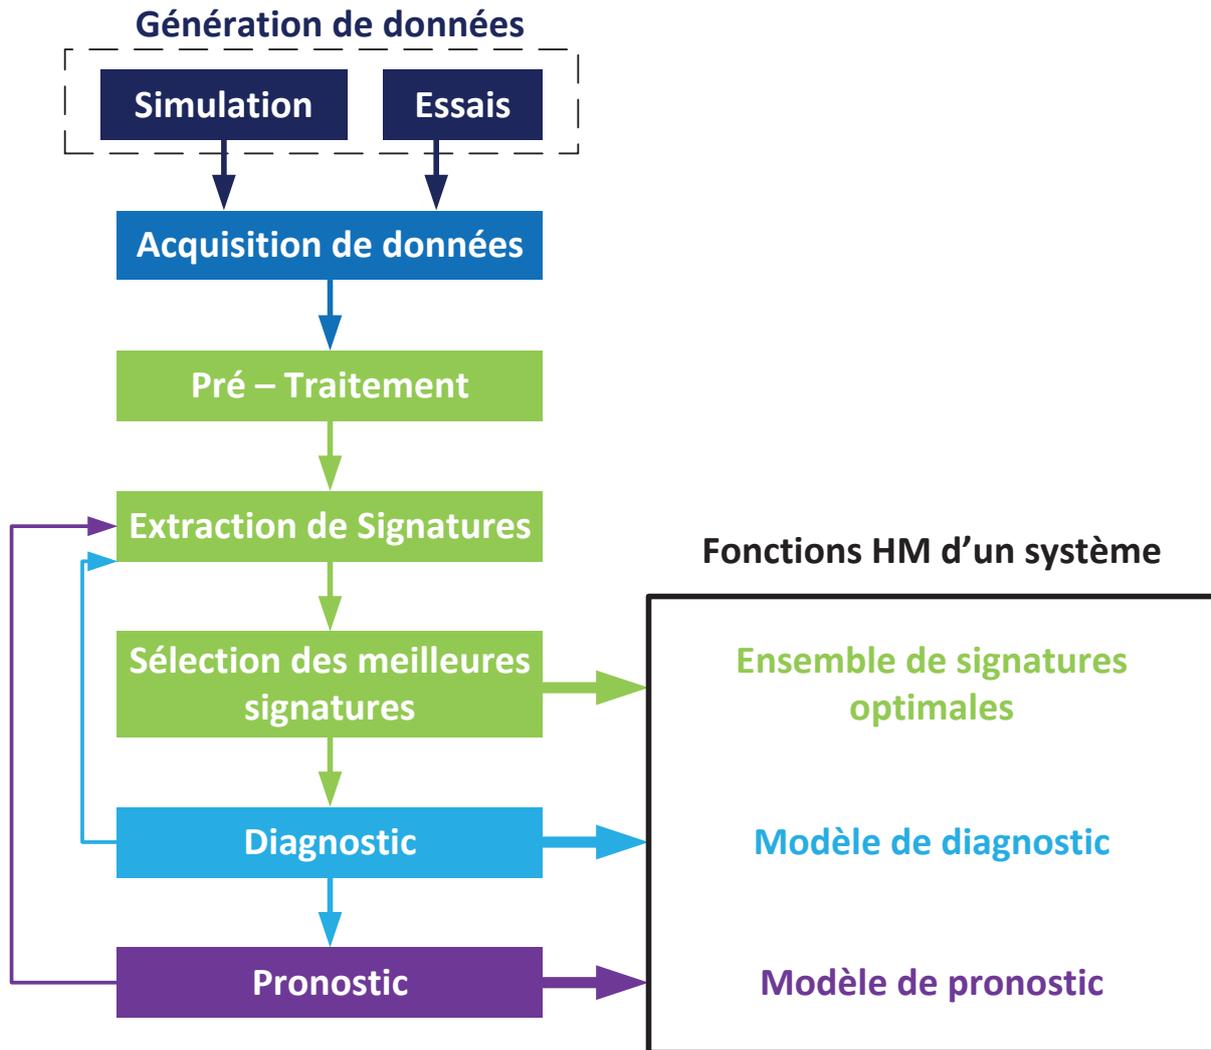


Figure I.23 : Conception de fonctions HM

### 3.2.b - Fonctions HM en opérations

L'utilisation des fonctions HM en opérations reprend globalement les étapes précédentes à deux nuances près. La première est que le prétraitement ne concerne maintenant que l'amélioration de la qualité des données par des techniques de traitement du signal. La deuxième est que le calcul de signatures ne se fait maintenant que sur des signatures pré - sélectionnées lors de la conception. Cet ensemble de signatures peut être modifié en fonction des études de mises à jour effectuées.

L'acquisition de données sur équipements en opération permet de créer des bases de données de profils représentatifs, évoluant dans le temps. L'utilisation des fonctions HM permet également de créer une base d'évolution des signatures dans le temps ainsi que de suivre les performances des algorithmes de diagnostic et de pronostic au cours du temps. L'ensemble de ces bases peut permettre de recalibrer et d'améliorer les algorithmes.

Ces deux derniers paragraphes concernent la méthodologie health-monitoring, sans regard particulier sur le système à l'étude. Nous allons maintenant voir comment le cycle de développement de fonctions HM interagit avec celui du système pour lequel sont conçues lesdites fonctions.

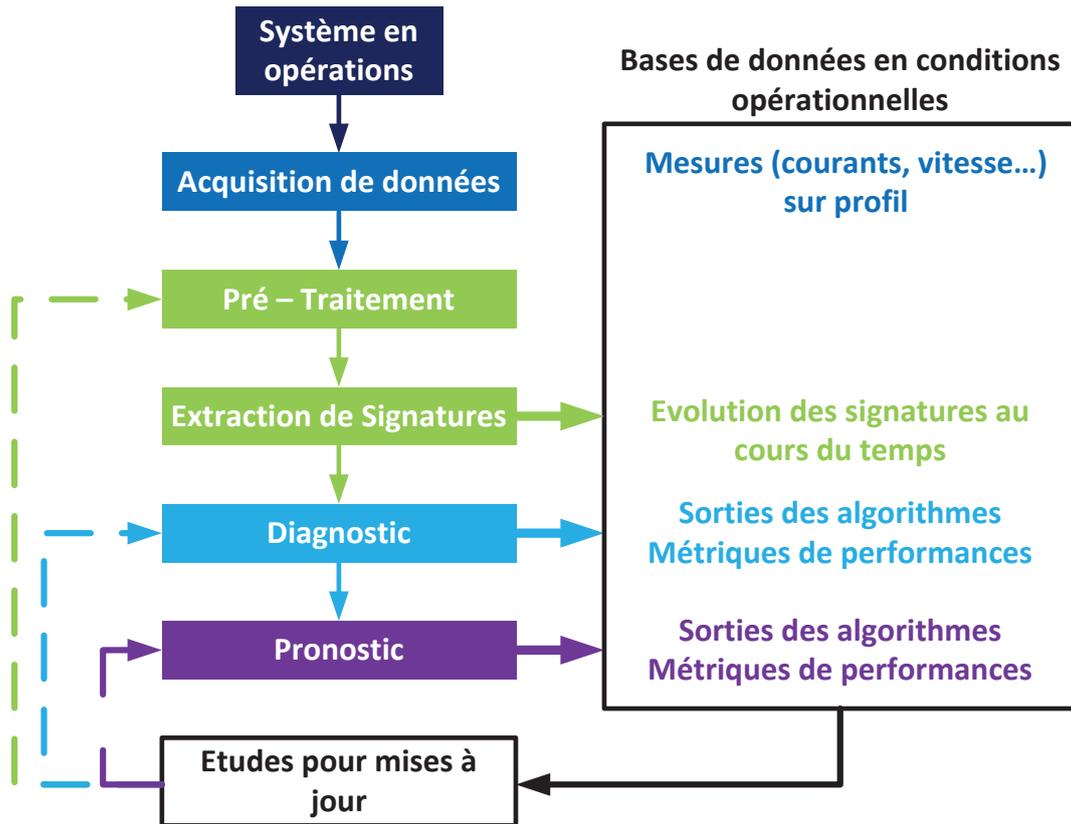


Figure I.24 : Utilisation de fonctions HM en opérations

### 3.3 - Cycles de développement

Lamoureux (Lamoureux 2014) a proposé des cycles de développement imbriqués pour les trois grandes étapes du PHM : la mise au point des signatures, la conception des algorithmes de diagnostic/pronostic et celle de l'aide à la décision. Il a mis en évidence les interactions entre ces différents cycles. En repartant de ces travaux, une version synthétisée est ici proposée (voir Figure I.25). Elle présente les cycles de développement du système à surveiller et des fonctions health – monitoring associées.

On distingue les interactions qui vont du développement du système vers le développement des fonctions HM (notées IS), de celles qui vont du développement des fonctions HM vers le développement du système (notées IH).

La descente du V du développement du système consiste à définir l'ensemble des spécifications des systèmes et de ses composants. Celle-ci doit être achevée avant le démarrage de la phase de production. En parallèle se trouve le début du développement des fonctions HM. Celui-ci consiste à spécifier les fonctions et à mettre au point un ensemble de signatures pour les défauts considérés. La première interaction (IS1) permet, à partir des spécifications du système, de spécifier les fonctions HM (quels défauts considérer ? Quelles performances minimales doivent atteindre les algorithmes ?). Les modèles mis au point lors de la descente du V peuvent servir à établir des algorithmes de signatures de défauts, pour les moins complexes (IS2), ou à valider les signatures, pour les plus complexes (IS3). La phase de validation des signatures peut permettre de revoir la conception du

système (IH1 et IH2), notamment en termes d'acquisition (un capteur supplémentaire est-il nécessaire pour détecter le défaut ? un capteur plus précis ? une fréquence d'acquisition plus élevée ?). Toute modification doit nécessairement se faire avant la mise en production.

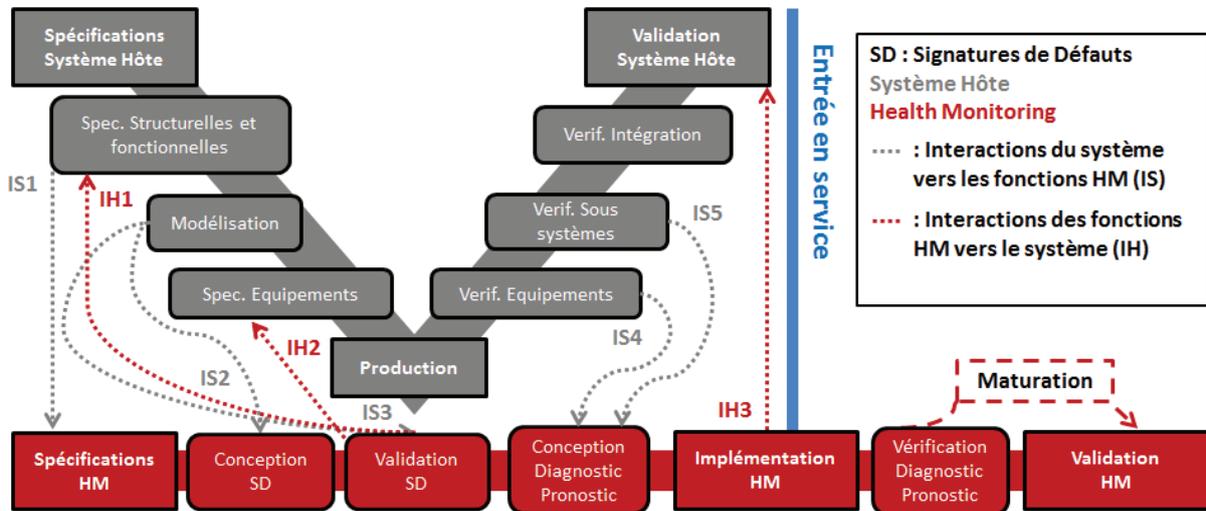


Figure I.25 : Cycles de développement d'un système et cycle de développement d'un ensemble de fonctions HM pour ce même système (inspiré de (Lamoureux 2014) )

La remontée du V du cycle de développement du système fait suite à la production. Elle consiste à vérifier que les systèmes produits correspondent bien aux spécifications. En parallèle, la fin de descente de celui des fonctions HM permet de mettre au point les premières versions des algorithmes de diagnostic et pronostic. La conception de ces algorithmes est alimentée par les essais réalisés lors des phases de vérification (IS4 et IS5). Une fois ces algorithmes conçus, ils vont être implémentés avant la mise en service du système. C'est la fin du cycle de développement du système et le début de la remontée du cycle de développement des fonctions HM. Celle-ci consiste à acquérir des données en opération pour vérifier, et si nécessaire recalibrer, les fonctions HM. Enfin, lorsqu'une quantité de données suffisante a été acquise, les fonctions HM peuvent être validées. Cette phase d'acquisition, appelée aussi phase de maturation, peut prendre de plusieurs mois à plusieurs années, en fonction de la durée de vie du système considéré.

Les problématiques qui peuvent être déduites du cadre et du contexte vont maintenant être présentées. Le positionnement de la thèse vis-à-vis de celles-ci sera également donné. Cela permettra d'introduire les chapitres constituant le corps du mémoire.

## 4 - Problématiques

### 4.1 - Problématiques et contraintes

La mise au point des algorithmes de HM doit répondre à plusieurs problématiques :

**Problématique 1 : Comment mettre au point des algorithmes de diagnostic et de pronostic robustes aux conditions aéronautiques ?**

L'environnement aéronautique, de par le grand nombre de systèmes cohabitant au sein des aéronefs, est très bruyé à tous les niveaux (CEM, vibratoires, ...). De plus, les bruits revêtent des formes parfois très différentes, parfois non gaussiennes, rendant leur modélisation difficile (Zapozhets et al. 2011; Sebbane 2015). Enfin, les conditions environnementales, les températures notamment, sont très étendues (-60°C « froid extrême » sur piste en Sibérie à +70°C sur piste à Dubaï, en plein soleil). Il en va de même pour les domaines de fonctionnement des actionneurs.

### **Problématique 2 : Comment mettre au point des signatures pour les défauts de transmission vis-écrou comme les vis à rouleaux satellites ?**

Nous avons pu voir que ce domaine est très ouvert vis-à-vis de la littérature. C'est un point essentiel dans la conception d'algorithmes de health-monitoring d'EMA de commande de vol. Néanmoins, le fait d'être capable de le diagnostiquer, voir même de le prédire, n'est pas suffisant vis-à-vis de la sûreté de fonctionnement. En effet, le système vis-écrou est connecté directement à l'aileron, sans élément intermédiaire permettant de découpler les deux. Tout défaut de grippage de la VAR peut donc entraîner un blocage de l'ensemble de l'aileron. Ainsi, pour assurer le bon fonctionnement du système des dispositifs d'anti-coincement seront à inclure (Gonzalez-Tablas et al. 2015; de Arriba et Gallego 2016).

### **Problématique 3 : Comment mettre à jour les algorithmes à partir de données opérationnelles ?**

La mise à jour des algorithmes à partir de données opérationnelles peut permettre d'améliorer grandement les performances de ceux-ci. Celle-ci doit être envisagée dès la conception des algorithmes. Toutes ces problématiques sont soumises à deux contraintes majeures, liées directement au cadre applicatif aéronautique :

#### **Contrainte 1 : Manque de données représentatives**

Il n'existe pas d'EMA Safran pour aileron, ni pour n'importe quelle autre commande de vol primaire, actuellement en opération. Ainsi, il n'est pas possible d'obtenir des données opérationnelles pour ces équipements.

#### **Contrainte 2 : Embarcabilité des algorithmes**

Le fait d'utiliser des algorithmes qui tournent en externe, dans des centres de calculs au sol, pose de nombreux problèmes. Cela implique des téléchargements réguliers de données de l'avion vers le centre de calcul. Cela induit des problèmes de sécurité (vol de données) mais également de généralisation, puisque de nombreux aéroports ne sont pas équipés des infrastructures adéquates. L'inverse est également vrai : le centre de calcul doit transmettre ses résultats de manière sécurisée à l'aéronef. Une rupture du canal de communication retour pourrait bloquer l'avion au sol. Un piratage de ce même canal pourrait avoir des conséquences encore plus désastreuses. Enfin, il est nécessaire de garder les signatures représentatives d'un système au plus proche de celui-ci, dans les calculateurs embarqués, avec des copies en externe. Cela limite grandement le risque de perte

d'information. Ainsi, pour envisager d'embarquer les algorithmes à moyen terme, les contraintes de puissance de calcul et de mémoire nécessaire devront être considérées.

Le temps complet disponible pour effectuer l'ensemble de la méthodologie (de l'acquisition à l'estimation de la durée de vie restante) est lié au temps de rotation entre deux vols. Le temps disponible pour la surveillance sera nécessairement inférieur à celui-ci. Il est en effet inenvisageable d'augmenter le temps de rotation, pour des raisons économiques (Mirza 2008). Pour la gamme d'avions considérés celui-ci est de 30 mn à 1 heure (Aeronews 2016). Ainsi on fixera le temps de calculs limite pour toute la méthodologie à 20 mn. En première intention la répartition sera la suivante : 6 minutes pour l'acquisition, 10 minutes pour le calcul de signatures, 1 pour le diagnostic et 3 pour l'estimation de la durée de vie restante.

Les paramètres et modèles liés à la surveillance doivent être enregistrés dans une mémoire long – terme dite non volatile. Pour le cadre aéronautique – commande de vol les composants existants vont jusqu'à 64 Mbits. Afin de rester conservatif la contrainte sur la mémoire est mise à 32 Mbits. En première intention la répartition sera la suivante : 0,5 Mbits pour l'extraction des signatures, 8 Mbits pour l'ensemble du modèle de diagnostic, 23,5 Mbits pour les modèles d'estimation de la durée de vie.

Cette thèse s'efforcera d'apporter des pistes et des solutions aux différentes problématiques sous contraintes énoncées ci-dessus. La structure du manuscrit qui synthétise ces pistes et solutions est donnée au sous-paragraphe suivant.

## 4.2 - Structure du manuscrit

Le sujet de thèse portant sur le health-monitoring, la structure du manuscrit va suivre les grandes étapes de ce processus.

Dans un premier temps (**Chapitre II**) le calcul de signatures de défauts sera abordé. Un état de l'art sera effectué. Puis celui-ci sera prolongé pour le cas des EMA dans le cadre des commandes de vol. Une première méthode de calcul de signatures pour les systèmes vis-écrou, reposant sur l'identification d'un modèle de frottement, sera proposée. Une deuxième méthode, reposant sur l'analyse des courants à partir d'une combinaison de décomposition modale empirique et d'analyse aveugle de sources, sera ensuite introduite. Ces deux méthodes seront testées sur des profils non opérationnels. Les données utilisées sont issues d'un modèle de simulation représentant finement l'actionneur dans son environnement. Enfin, des métriques de performances des signatures seront évaluées.

Le diagnostic par reconnaissance de formes sera ensuite traité (**Chapitre III**). Un état de l'art sur ce type de méthodes sera abordé. Puis, le principe des machines à vecteurs de supports sera développé. Une amélioration de cet algorithme, basée sur une combinaison avec des appartenances floues, sera proposée. Cette amélioration permet notamment d'estimer la sévérité d'un défaut. Elle permet également de détecter des points ne correspondant pas à la base d'apprentissage, qui peuvent représenter des défauts inconnus ou des points appartenant à plusieurs classes à la fois, pouvant représenter des cas de défauts combinés. L'architecture d'un système de diagnostic complet, basée sur l'algorithme conçu, sera détaillée.

Des validations expérimentales (**Chapitre IV**) des méthodes de calcul de signatures et de diagnostic seront ensuite menées. Les méthodes de calculs de signatures seront validées sur des données issues d'un banc représentant l'architecture d'implémentation de l'EMA dans l'avion. La méthode de diagnostic sera validée sur deux bases issues de deux campagnes d'essais. La première porte sur un moteur synchrone à aimants, de type aéronautique, en défaut de court-circuit inter-spires en régime permanent. La seconde concerne un moteur asynchrone en défaut en régime permanent. Trois défauts seront considérés : roulements, barres cassées et défaut du condensateur de l'onduleur alimentant le moteur.

Des éléments pour aller vers le pronostic seront ensuite avancés (**Chapitre V**). Le processus du pronostic sera détaillé. Seule une partie de ce processus sera étudié. Dans un premier temps, le partitionnement de données de vieillissement pour créer des classes de sévérité de défaut sera traité. Puis, une méthode d'extrapolation des états futurs, reposant sur les méthodes de diagnostic proposées au chapitre III sera introduite. Cette méthode constituera un des éléments de notre approche permettant d'estimer la durée de vie restante. L'ensemble des méthodes sera appliqué sur des bases benchmark de vieillissement de roulements. Les résultats seront évalués selon différentes métriques.

Finalement, la conclusion (**Chapitre VI**), reprendra les principaux points développés vis-à-vis des problématiques et des contraintes. Cela permettra de mettre en évidence les contributions de cette thèse ainsi que les limites des travaux réalisés. De ces limites, des perspectives pour de futurs travaux seront proposées.

# II

## Calcul de signatures de défauts

Simulation  
Frottements  
Défaut<sup>CC</sup> Ica  
Signatures NKPI  
Identification  
Statistiques  
Validation  
Courants  
VAR  
CEEMD

<b>II</b>	<b>CALCUL DE SIGNATURES DE DEFAUTS .....</b>	<b>44</b>
1	MODELE DE L'EMA.....	46
1.1	<i>Boucles de Régulation</i> .....	46
1.2	<i>MSAP</i> .....	47
1.3	<i>VAR</i> .....	48
2	GENERALITES SUR LES SIGNATURES .....	50
2.1	<i>Méthodes à base de modèles</i> .....	50
2.2	<i>Méthodes à base de traitement du signal</i> .....	51
2.2.a	Analyse temporelle .....	52
2.2.b	Analyse fréquentielle .....	53
2.2.c	Analyse temps – fréquence .....	54
3	SIGNATURES POUR EMA DE COMMANDE DE VOL .....	54
3.1	<i>Basées sur des modèles</i> .....	54
3.2	<i>Basées sur les signaux</i> .....	55
3.3	<i>Méthodes hybrides</i> .....	55
3.4	<i>Synthèse</i> .....	55
4	IDENTIFICATION DES FROTTEMENTS.....	56
4.1	<i>Modèle de frottements</i> .....	56
4.2	<i>Algorithme d'identification</i> .....	56
4.2.a	Fonction coût .....	56
4.2.b	Algorithme d'optimisation .....	57
4.2.b.i	Fonctionnement .....	57
4.2.b.ii	Réglage de l'algorithme .....	59
5	ANALYSE DES COURANTS .....	59
5.1	<i>Architecture du processus de traitement</i> .....	59
5.2	<i>Détails des étapes</i> .....	60
5.2.a	Décomposition Modale Empirique .....	60
5.2.a.i	Généralités .....	60
5.2.a.ii	Algorithme EMD .....	60
5.2.b	Analyse en Composantes Indépendantes .....	62
5.2.b.i	Généralités .....	62
5.2.b.ii	Estimation des sources .....	62
5.2.c	Sélection automatique des composantes .....	63
5.2.d	Construction des signaux virtuels .....	66
5.2.e	Extraction des signatures .....	66
6	METHODOLOGIE DE VALIDATION .....	66
6.1	<i>Obtention des paramètres influents</i> .....	67
6.2	<i>Calcul des NKPI des signatures</i> .....	68
7	VALIDATION PAR SIMULATION.....	69
7.1	<i>Profil de caractérisation</i> .....	69
7.2	<i>Obtention des paramètres influents</i> .....	69
7.3	<i>Calcul des NKPI des signatures</i> .....	70
7.3.a	Simulations sur profil .....	70
7.3.b	Calcul des signatures .....	70
7.3.c	Calculs des NKPI .....	70
7.3.c.i	Détectabilité .....	71
7.3.c.ii	Identifiabilité .....	71
7.4	<i>Synthèse des résultats</i> .....	72
8	CONCLUSION DU CHAPITRE .....	72

## 1 - Modèle de l'EMA

En première approche un modèle de l'EMA a été utilisé pour simuler des défauts et pré – valider les algorithmes de calculs de signatures. Ainsi l'architecture présentée au chapitre 1 (Figure I.13 page 28) a été modélisée sous Simulink®. Le schéma simplifié du modèle est donné par la figure suivante :

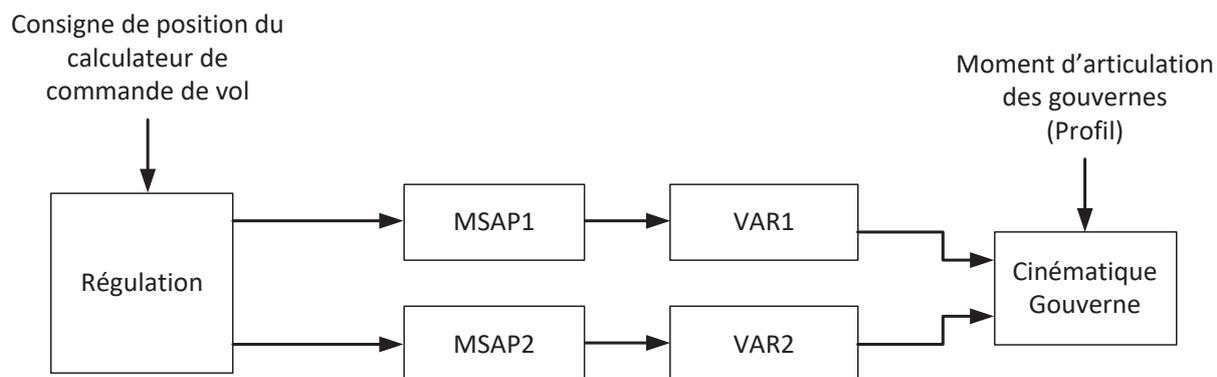


Figure II.1 : Schéma simplifié du modèle utilisé

Le profil de consigne de position linéaire (vis) et le profil de charge sur l'aileron sont les entrées du modèle. En mode opérationnel, la stratégie de commande utilise un MSAP actif et un MSAP inactif, en mode amortisseur. Ici, ce sont des profils non opérationnels, appliqués sur tarmac, qui ont été utilisés, via un MSAP qui joue le rôle de la contre charge.

Afin de simplifier la mise en place de ces profils, il a été choisi de calculer la charge aérodynamique équivalente et de l'appliquer directement à la cinématique de l'avion, sans utiliser l'autre EMA. Cette mise en place repose sur l'hypothèse suivante :

### Hypothèse 2 : Seul un actionneur est en défaut

Le principe de fonctionnement de chacun des principaux blocs du modèle est explicité dans les sous – paragraphes suivants.

## 1.1 - Boucles de Régulation

Les entrées du bloc de régulation sont :

- ⇒ La consigne de position du vérin
- ⇒ La mesure de position du vérin
- ⇒ La mesure de position du moteur
- ⇒ Les mesures des trois courants statoriques
- ⇒ La vitesse angulaire du moteur
- ⇒ La charge mesurée (efforts aérodynamiques + frottements aileron + frottements rotule)
- ⇒ La mesure de la tension du bus continu

Les sorties de ce bloc sont :

⇒ Les tensions commandées dans le repère de Park

Les trois régulations (courant, vitesse, position) sont assurées par des correcteurs PI. La régulation de position est faite sur la position de la vis (linéaire). Celle – ci est ramenée à une vitesse de rotation via le rapport de réduction du système vis/écrou. Etant donné que l'on ne considère pas les défauts de l'onduleur, il est ici modélisé par un gain.

## 1.2 - MSAP

Les entrées de ce bloc sont :

- ⇒ Les tensions appliquées dans le repère de Park
- ⇒ Le couple de charge venant du bloc « VAR » :  $C_{charge}$

Les sorties sont :

- ⇒ La position du rotor (position moteur)
- ⇒ La vitesse du rotor
- ⇒ Les courants dans le repère de Park
- ⇒ Le couple électromagnétique :  $C_{em}$

Le modèle du MSAP permet de tenir compte du défaut relativement fréquent du court-circuit inter-spires au stator (**Leboeuf et al. 2010; Leboeuf 2012**). Pour cela, une maille supplémentaire est considérée au stator. Celle-ci représente le court-circuit inter-spires permettant la circulation d'un courant de défaut  $i_f$  à travers une résistance de défaut  $R_f$  (voir la Figure II.2). Dans ce cas, l'ensemble des trois courants statoriques  $abc$  et le courant de défaut  $i_f$  forment un système d'ordre 4 dont le modèle peut s'écrire comme suit :

$$(II.1) \quad v_{abcf} = R_{abcf} \cdot i_{abcf} + L_{abcf} \frac{di_{abcf}}{dt} + e_{abcf}(\theta_e)$$

Avec  $v_{abcf}$  : le vecteur des tensions,  $R_{abcf}$  : Matrice des résistances,  $i_{abcf}$  : vecteur des courants,  $L_{abcf}$  : matrice des inductances,  $e_{abcf}$  : vecteur des forces électromotrices (fém.),  $\theta_e$  : la position électrique du rotor. Il est rappelé que le modèle ci-dessus ne tient pas compte de la saturation du circuit magnétique alors que les harmoniques de fém. peuvent être pris en compte facilement. Pour un moteur sain, la résistance de défaut  $R_f$  est considérée bien plus grande que la résistance des phases statoriques.

L'évaluation de la matrice des inductances  $L_{abcf}$  et de la forme des fém.  $e_{abcf}$  se fait à l'aide d'un calcul de champs du moteur conçu pour l'EMA d'aileron (voir (**Leboeuf 2012**), page 51). La sévérité du défaut de court-circuit inter-spires est représentée par la valeur de la résistance de défaut  $R_f$  et le nombre de spires en défaut.

Le calcul de champs permet en particulier de déterminer la forme des forces électromotrices du moteur étudié :

$$(II.2) \quad e_{abcf} = E_{abcf}(\theta_e) \cdot \Omega$$

où  $\Omega$  est la vitesse angulaire du moteur et  $E_{abcf}$  : les formes d'ondes des fem. Maintenant, le couple utile peut être calculé par :

$$(II.3) \quad \begin{cases} C_{ut} = C_{em} - C_{det} - C_{f_{mot}} - C_{charge} - C_{iner} \\ C_{em} = E_{abcf}(\theta_e) \cdot i_{abcf} \\ C_{f_{mot}} = C_{f_{sec_{mot}}} + C_{f_{vis_{mot}}}\Omega \end{cases}$$

Avec :  $C_{em}$  : le couple électromagnétique,  $C_{det}$  : le couple de détente,  $C_{f_{mot}}$  : les frottements moteurs,  $C_{charge}$  : couple de charge venant du bloc « VAR »,  $C_{iner}$  : le couple inertiel,  $C_{f_{sec_{mot}}}$  : les frottements secs,  $C_{f_{vis_{mot}}}$  : le coefficient de frottement visqueux.

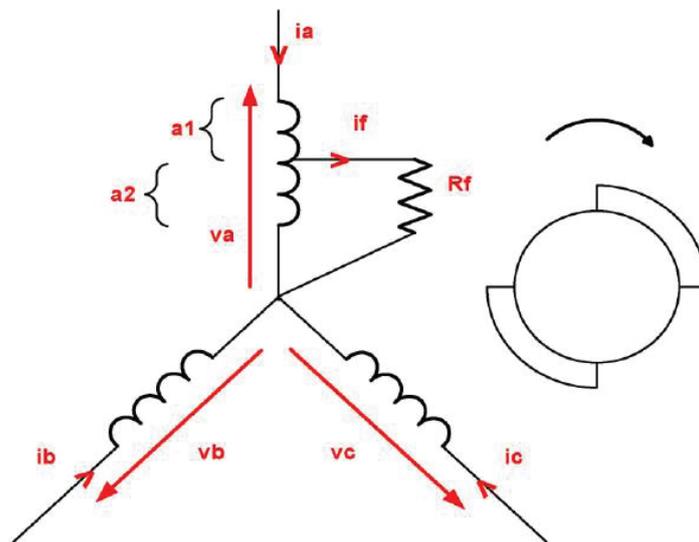


Figure II.2 : Modèle de MSAP avec court – circuit inter - spires sur une phase (Leboeuf et al. 2010)

### 1.3 - VAR

Les entrées de ce bloc sont :

- ⇒ La position du rotor
- ⇒ La charge aérodynamique rapportée sur la VAR, qui vient du bloc « Cinématique avion »

Les sorties de ce bloc sont :

- ⇒ La position de la vis
- ⇒ La vitesse de la vis
- ⇒ Le couple de charge sur le moteur :  $C_{charge}$

La VAR est modélisée comme un système ressort / amortisseur avec un jeu. L'inertie due à la masse de la vis est incluse dans l'effort de déformation  $F_{df}$ .

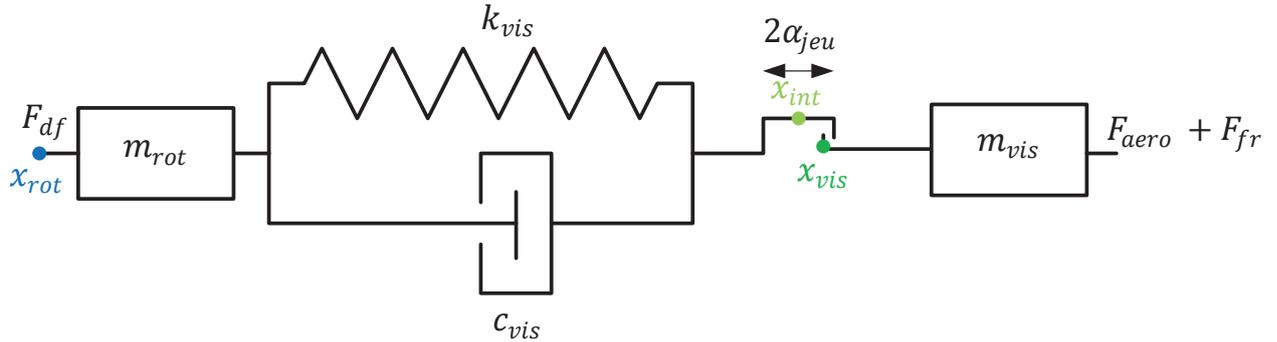


Figure II.3 : Modélisation de la déformation et du jeu de la vis

Les notations suivantes sont définies :

- ⇒  $r_{vis} = \frac{2\pi}{pas}$  : le rapport de réduction de la vis
- ⇒  $x_{rot} = \frac{\theta_{rot}}{r_{vis}}$  : la position équivalente en linéaire du rotor
- ⇒  $m_{rot} = J_{rot} * r_{vis}^2$  : la masse équivalente des éléments roulants
- ⇒  $J_{rot}$  : l'inertie équivalente du rotor et des éléments roulants
- ⇒  $x_{int}$  : la position intermédiaire
- ⇒  $x_{vis}$  : la position de la vis
- ⇒  $m_{vis}$  : la masse de la vis
- ⇒  $x_{ec} = x_{rot} - x_{vis}$  : écart entre les positions du moteur et de la vis
- ⇒  $x_{jeu} = x_{int} - x_{vis}$  : la position du jeu
- ⇒  $x_{df} = x_{rot} - x_{int}$  : la déformation de la vis
- ⇒  $\alpha_{jeu}$  : la moitié de l'amplitude du jeu

L'effort de déformation, qui fait le lien entre la vis et le moteur, est exprimé par:

$$(II.4) \quad F_{df} = F_{raid} + F_{amor} = k_{vis}(x_{df} - x_{df0}) + c_{vis}\dot{x}_{df}$$

Avec  $k_{vis}$  : la raideur de la vis,  $x_{df0}$  : la déformation initiale,  $c_{vis}$  : l'amortissement structurel de la vis. Trois cas sont distingués pour la dynamique de la vis :

Contact droit ( $x_{jeu} = -\alpha_{jeu}$  et  $F_{df} \neq 0$ )

$$(II.5) \quad \dot{x}_{jeu} = \min \left[ 0 ; \dot{x}_{ec} + \frac{k_{vis}}{c_{vis}}(x_{ec} - x_{jeu} - x_{df0}) \right]$$

Contact gauche ( $x_{jeu} = +\alpha_{jeu}$  et  $F_{df} \neq 0$ )

$$(II.6) \quad \dot{x}_{jeu} = \max \left[ 0 ; \dot{x}_{ec} + \frac{k_{vis}}{c_{vis}}(x_{ec} - x_{jeu} - x_{df0}) \right]$$

Pas de contact (dans l'amplitude du jeu) ( $F_{df} = 0$ )

$$(II.7) \quad \dot{x}_{jeu} = \dot{x}_{ec} + \frac{k_{vis}}{c_{vis}}(x_{ec} - x_{jeu} - x_{df0})$$

Le principe fondamental de la dynamique sur la vis donne :

$$(II.8) \quad m_{vis} \frac{d^2 x_{vis}}{dt^2} = F_{df} - F_{fr} - F_{aero}$$

Avec  $m_{vis}$  : la masse équivalente de la vis et des éléments connectés,  $F_{aero}$  : la charge aérodynamique rapportée sur la VAR, tenant compte de la cinématique et des frottements de la gouverne, et  $F_{fr}$  : les efforts de frottement de la VAR défini par :

$$(II.9) \quad F_{fr} = F_{fv} \frac{dx_{vis}}{dt} + \text{signe} \left( \frac{dx_{vis}}{dt} \right) [F_{fsec} + K_{rend} \text{abs}(F_{aero})]$$

Avec  $F_{fv}$  : le coefficient de frottement visqueux de la VAR,  $F_{fsec}$  : le coefficient de frottement sec,  $K_{rend}$  : coefficient des frottement dépendants de la charge.

Ce modèle de frottement est inspiré des travaux de **(Karam 2007)**. Il repose sur l'hypothèse suivante :

**Hypothèse 3 : Les coefficients de frottements de la VAR sont identiques dans les deux sens de déplacement**

Finalement la charge sur le moteur est calculée par :

$$(II.10) \quad C_{charge} = \frac{F_{df}}{r_{vis}}$$

## 2 - Généralités sur les signatures

Pour rappel, une signature de défaut est une grandeur qui varie avec l'apparition et le degré de sévérité d'au moins un défaut. Deux grandes familles de méthodes existent pour mettre au point des signatures : les méthodes à base de modèles et celles reposant sur des techniques de traitement du signal.

### 2.1 - Méthodes à base de modèles

Cette famille de méthodes repose sur l'utilisation de modèles physiques du système à surveiller. Un premier groupe de méthodes consiste à simuler le modèle et à comparer les sorties de celui-ci avec

des mesures effectuées sur le système (Moseler et al. 1999; Liu et al. 2007a, 2007b; Boileau 2010; Leboeuf 2012; Vinson et al. 2012; Liu et Hu 2017). L'écart entre les sorties du modèle et les mesures est appelée les résidus.

$E$  : Entrées ;  $S$  : Sorties (mesurées)

$\hat{S}$  : Sorties (estimées) ;  $R$  : Résidus

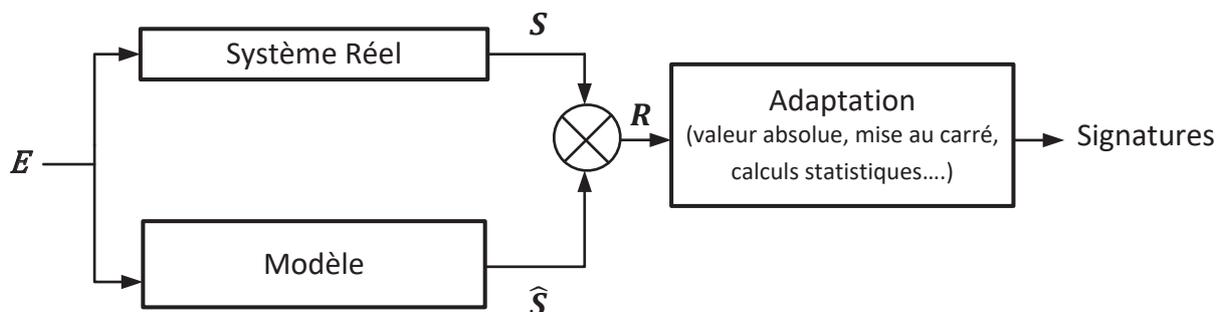


Figure II.4 : Calcul de signatures à base de résidus des modèles

Un deuxième groupe consiste à identifier les paramètres du modèle à partir de mesures sur le système réel (Wu et al. 2004; Izadian et Khayyer 2010; Boileau et al. 2011; Leboeuf et al. 2011; Breuneval et al. 2016; Mansouri et al. 2016). Les paramètres identifiés  $\hat{\theta}$  forment alors les signatures, soit tels quels soit après une adaptation.

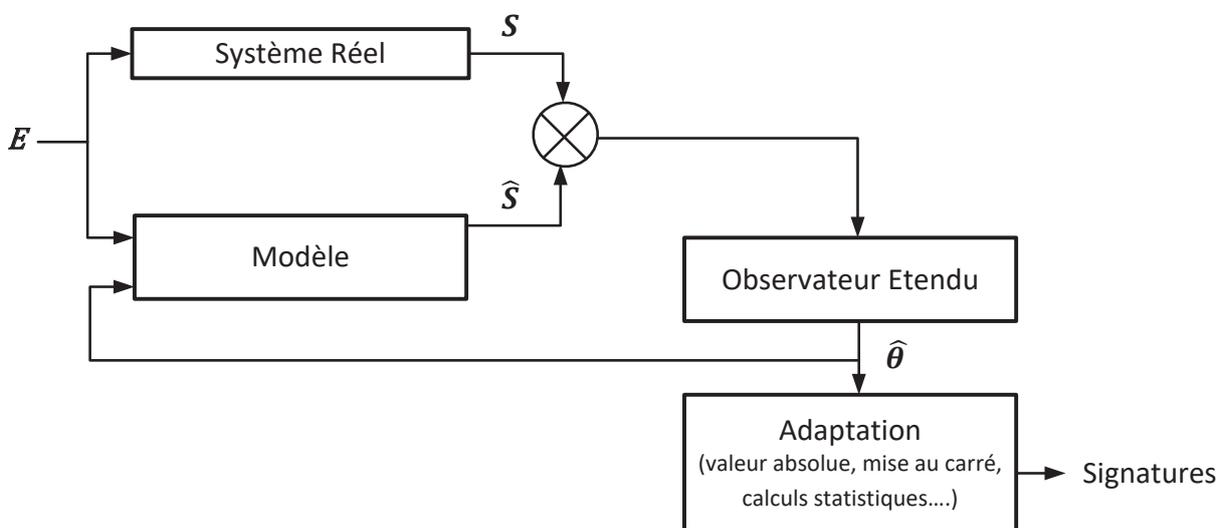


Figure II.5 : Calcul de signatures à base d'identification de paramètres du modèle

## 2.2 - Méthodes à base de traitement du signal

Le traitement du signal est un vaste domaine qui regroupe l'ensemble des méthodes permettant d'analyser des signaux. Trois branches peuvent être distinguées : l'analyse temporelle, l'analyse fréquentielle et l'analyse temps – fréquence (Bellini et al. 2008).

### 2.2.a - Analyse temporelle

Cette famille de méthodes consiste à calculer des indicateurs statistiques à partir du signal. Parmi les indicateurs statistiques les plus connus : le maximum, la valeur moyenne, le minimum. D'autres indicateurs existent. On considérera un signal échantillonné à une fréquence  $f_{ech}$ . Le signal échantillonné sera noté  $y_s$ . On notera  $N$  le nombre d'échantillons du signal. Le  $i^{ème}$  échantillon du signal sera noté  $y_{si}$ .

La valeur efficace (Root Mean Square) :

$$(II.11) \quad RMS(y_s) = \sqrt{\frac{\sum_{i=1}^N (y_{si} - \bar{y}_s)^2}{N}}$$

Avec  $\bar{y}_s$  la valeur moyenne de  $y_s$

La variance

Cette métrique mesure la dispersion du signal. Celle – ci peut augmenter avec l'apparition et l'évolution d'un défaut. Elle est exprimée par :

$$(II.12) \quad \sigma(y_s)^2 = \frac{\sum_{i=1}^N (y_{si} - \bar{y}_s)^2}{N}$$

Le kurtosis

Cette métrique mesure le coefficient d'aplatissement de la distribution d'un signal. Elle est exprimée par :

$$(II.13) \quad Kurt(y_s) = \frac{\frac{1}{N} \sum_{i=1}^N (y_{si} - \bar{y}_s)^4}{(\sigma(y_s)^2)^2}$$

Le kurtosis vaut 3 pour une distribution parfaitement gaussienne. Plus la distribution se resserre autour de la valeur moyenne (forme de « pic ») plus la valeur augmente. A l'inverse plus la distribution se rapproche d'une distribution uniforme (« s'aplatit ») plus le kurtosis diminue.

Le facteur de crête

Cette métrique mesure le ratio entre l'amplitude du pic du signal et sa valeur efficace :

$$(II.14) \quad FC(y_s) = \frac{|y_{s-pic}|}{RMS(y_s)}$$

Cette métrique aura tendance à augmenter avec l'évolution d'un défaut.

*Le coefficient de dissymétrie*

Cette métrique, aussi appelée *skewness*, mesure la dissymétrie de la distribution par rapport à la médiane. Elle s'exprime par :

$$(II.15) \quad SK(y_s) = \frac{\frac{1}{N} \sum_{i=1}^N (y_{si} - \bar{y}_s)^3}{(\sigma(y_s))^3}$$

Une valeur positive signifiera que la distribution est décalée vers la gauche et donc que la queue de distribution s'étend vers la droite. Une valeur négative signifiera l'inverse : décalage vers la droite et queue de distribution qui s'étend vers la gauche.

*L'énergie*

L'énergie d'un signal s'exprime par :

$$(II.16) \quad EN(y_s) = \frac{1}{N} \sum_{i=1}^N |y_{si}|^2$$

## 2.2.b - Analyse fréquentielle

Cette famille de méthodes repose sur l'hypothèse qu'un composant en défaut modifie les spectres dans des bandes de fréquence spécifiques. Dans le cadre des actionneurs électromécaniques, cette analyse est généralement faite en régime permanent. La fréquence d'un signal de défaut est en général liée au composant en défaut. Cela permet donc de faciliter la localisation du défaut, contrairement aux méthodes temporelles. La technique la plus utilisée pour l'analyse fréquentielle est la Transformée de Fourier Rapide (*Fast Fourier Transform*) (Duhamel et Vetterli 1990).

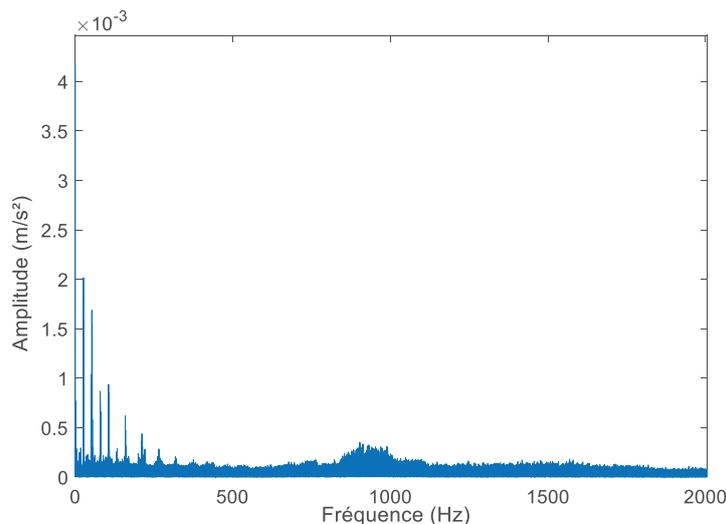


Figure II.6 : Exemple de FFT issue d'un signal vibratoire

### 2.2.c - Analyse temps – fréquence

L'analyse temps – fréquence permet de représenter l'énergie du signal à la fois dans le domaine temporel et dans le fréquentiel. Ce type de techniques est plus adapté aux signaux issus d'actionneurs en régime dynamique. Les méthodes les plus utilisées dans le cadre du calcul de signatures sont les analyses multi – résolution parmi lesquelles : la transformée en ondelettes (**Zanardelli et al. 2002; Peng et Chu 2004; Peter et al. 2004; Yan et al. 2014; Haje Obeid 2016**), la décomposition en mode empirique (**Junsheng et al. 2006; Yu et al. 2006; Lei et al. 2013**) et la transformée de Fourier à court terme (**Safizadeh et al. 2005**).

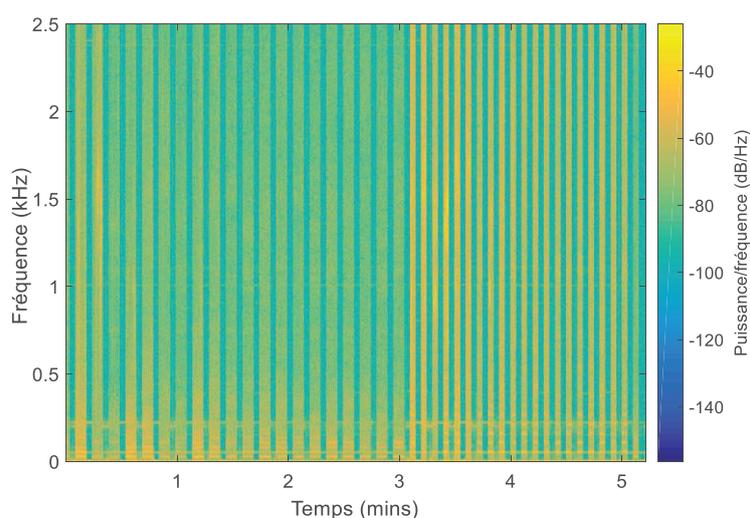


Figure II.7 : Exemple de spectrogramme issue d'une transformée de Fourier à temps court sur un signal vibratoire

De nombreuses méthodes existent donc pour mettre au point des signatures de défauts. Nous allons présenter, dans un premier temps, une synthèse bibliographique des signatures pour le cas des EMA de commande de vol.

## 3 - Signatures pour EMA de commande de vol

### 3.1 - Basées sur des modèles

De nombreux travaux portent sur l'identification de paramètres d'un modèle pour calculer des signatures de défauts mécaniques. Les défauts liés aux frottements sont notamment traités en identifiant un modèle de frottement (**Byington et al. 2004; Maggiore et al. 2014; Dalla Vedova et al. 2015b**). L'identification est faite à partir des mesures de courant, de la charge et de la position sur des profils non – opérationnels (sinus, rampes...). Les signatures mises au point sont des résidus du modèle et les paramètres de frottement identifiés. Les algorithmes d'optimisation utilisés sont, en général, des heuristiques comme les algorithmes génétiques (**Kumar et al. 2010**) ou le recuit simulé (**Czyżak et Jazkiewicz 1998**). Quelques travaux, moins nombreux, portent sur l'identification du jeu mécanique. Dans (**Dalla Vedova et al. 2015a**) les paramètres d'un modèle Simulink® sont

identifiés. Cette identification se fait à partir de données expérimentales d'un EMA sain via l'algorithme du recuit simulé. Ce modèle est ensuite utilisé pour former des résidus, qui constituent des signatures de défauts. Mansouri (**Mansouri et al. 2016**) identifie la largeur du jeu à partir des mesures de position (moteur et vis) et de la mesure de charge. Cette identification se fait sur un profil opérationnel via un filtre de Kalman linéaire. Dans (**Dalla Vedova et al. 2012**) un coefficient de corrélation est calculé à partir des sorties mesurées et estimées par le modèle.

### 3.2 - Basées sur les signaux

Une des techniques de traitement du signal les plus utilisées semble être la FFT. Cette technique est appliquée à des mesures de courants (**Dalla Vedova et al. 2012, 2015c, 2016; Maggiore et al. 2014**) comme à des mesures vibratoires (**Ismail et al. 2016; Van der Linden et al. 2016**). Les courants analysés sont issus de simulations. Les accélérations sont, elles, issues d'expérimentations. Cette méthode s'avère efficace pour détecter le défaut de court – circuit à partir de l'analyse des courants. Lorsqu'elle est utilisée sur des signaux d'accéléromètres, elle permet de détecter des défauts mécaniques. Dans (**Ismail et al. 2016**), la FFT n'est pas appliquée directement sur les signaux vibratoires mais sur l'enveloppe de ceux – ci. Cette enveloppe est estimée par la transformée de Hilbert (**Qin et al. 2008**). Un nombre important de travaux porte sur l'analyse temporelle des courants triphasés, notamment au travers des maxima et des valeurs efficaces (**Belmonte et al. 2015; Dalla Vedova et al. 2015c; De Martin et al. 2016**).

### 3.3 - Méthodes hybrides

Les travaux de (**Narasimhan et al. 2010; Balaban et al. 2015**) portent sur l'utilisation d'une méthode hybride associant modèle et traitement du signal pour le calcul de signatures. La méthode à base de modèle permet de regrouper les défauts sensibles aux mêmes signatures. On parle de groupe d'ambiguïté. Un groupe peut correspondre à l'ensemble des défauts mécaniques (grippage de la vis, écaillage de la vis, roulements...). Puis pour chaque groupe, un jeu de signatures calculées à partir de signaux, est déterminé. L'approche basée sur les modèles utilisée est celle présentée dans (**Manders et al. 1999**). Les modèles utilisés ici sont des modèles Bond – Graph. L'approche consiste à calculer des résidus et à les convertir en valeurs symboliques. Ce sont ces ensembles de valeurs symboliques qui constituent les signatures. Les valeurs symboliques sont : + (valeur estimée au-dessus de la valeur mesurée), 0 (valeur estimée environ égale à la valeur mesurée) et – (valeur estimée en dessous de la valeur mesurée). Deux ensembles de valeurs symboliques sont utilisés : le premier pour l'amplitude et le second pour la variation. Des tables sont ensuite construites en fonction des valeurs symboliques prises pour chaque résidu, tables qui permettent d'identifier les groupes d'ambiguïté. Les signatures calculées à partir de signaux permettent ensuite de différencier les différents défauts au sein du groupe. Ces signatures sont calculées via des statistiques sur les mesures de courants, de températures et accélérométriques.

### 3.4 - Synthèse

Deux éléments sont notables d'après cette revue. Le premier est que la très grande majorité des travaux se basent sur des acquisitions effectuées sur des profils non – opérationnels. L'avantage de

ce type de profil est leur modularité qui leur permet d'être adaptés à l'identification de défauts spécifiques. Le désavantage est lié au fait qu'il faut appliquer ces profils sur le système, et donc aménager des phases de test où le système n'assure pas sa fonction. Dans le cadre aéronautique cela implique des tests sur le tarmac. Il faut également noter que la majorité des travaux se basent sur les capteurs embarqués. Cet aspect est confirmé par des industriels (**Todeschi et Baxerres 2015; de Arriba et Gallego 2016**) qui mettent en avant le surcoût et les problèmes de sûreté liés à l'ajout de capteurs supplémentaires.

La démarche mise en place dans ces travaux de thèse tiendra compte de ces points. La première méthode de calcul de signatures proposée repose sur l'identification d'un modèle de frottements. Ce modèle est différent de ceux présentés dans les travaux de la revue.

La seconde méthode repose sur l'analyse des courants et a pour objectif la mise au point de signatures pour les défauts mécaniques et électriques.

## 4 - Identification des frottements

### 4.1 - Modèle de frottements

Ce modèle se base sur le modèle linéaire présenté à l'équation (II.9) page 50. Il consiste à ramener l'ensemble des frottements sur le rotor du moteur.

$$(II.17) \quad C_f = C_v \Omega + \text{signe}(\Omega) [C_{fsec} + K_{rend} \text{abs}(C_c)]$$

Avec  $C_v$  : coefficient de frottement visqueux en Nm/(rad/s),  $\Omega$  : la vitesse de rotation du rotor (rad/s),  $C_{fsec}$  : coefficient de frottement sec statique en Nm,  $K_{rend}$  : coefficient de frottement dépendants de la charge,  $C_c$  : couple de charge en Nm. Ce dernier s'exprime par :

$$(II.18) \quad C_c = F_c * \frac{pas}{2\pi}$$

Avec  $F_c$  : l'effort de charge aérodynamique ramené sur la vis de l'actionneur (mesuré) et il est rappelé que *pas* correspond au pas de la vis.

### 4.2 - Algorithme d'identification

Pour parvenir à identifier les paramètres du modèle ( $C_v$ ,  $C_{fsec}$  et  $K_{rend}$ ) le principe fondamental de la dynamique est utilisé pour exprimer une fonction coût. Cela permet de formuler le problème d'identification comme un problème d'optimisation.

#### 4.2.a - Fonction coût

Soit l'expression du principe fondamental de la dynamique sur le rotor du MSAP :

$$(II.19) \quad C_{em} - C_c - C_f = C_{i_r} = J_m \frac{d\Omega}{dt}$$

Avec  $C_{em}$  : le couple produit par le moteur en Nm,  $C_{i_r}$  le couple d'accélération et  $J_m$  : l'inertie équivalente des éléments roulants en kg.m<sup>2</sup>. L'accélération est estimée par :

$$(II.20) \quad \frac{d\Omega}{dt} \approx \frac{\Delta\Omega}{\Delta t} = \frac{\Omega(t+1) - \Omega(t)}{\Delta t}$$

L'hypothèse suivante est faite :

**Hypothèse 4 : Le moteur synchrone à aimants est supposé linéaire sur la plage de fonctionnement considérée (pas de phénomènes de saturation)**

Le couple électromagnétique s'exprimera donc :

$$(II.21) \quad C_{em} = \frac{3}{2} K_{mot} I_q$$

Avec  $K_{mot}$  : constante de couple en Nm/A (connue et considérée stationnaire) et  $I_q$  le courant en quadrature en A (mesuré) dans le repère de Park lié au rotor.

Le couple total de charge sur le rotor, équivalent au couple électromagnétique estimé, peut donc être exprimé par :

$$(II.22) \quad \hat{C}_{em} = C_c + C_f + C_{i_r}$$

La fonction coût permettant d'identifier les paramètres du modèle de frottements pourra donc être exprimée sur un profil de  $N_{pro}$  points par :

$$(II.23) \quad f_{cout} = \frac{1}{N_{pro}} \sum_{i=1}^{N_{pro}} (C_{em_i} - \hat{C}_{em_i})^2$$

## 4.2.b - Algorithme d'optimisation

Comme vu précédemment les algorithmes méta – heuristiques sont très utilisés pour l'identification des frottements. L'algorithme d'évolution différentielle (**Storn et Price 1997**) semble être un bon candidat. En effet, les travaux de Feyel (**Feyel et al. 2013; Feyel 2015**) ont mis en évidence les très bonnes performances de cet algorithme pour identifier les frottements de chaînes électromécaniques. C'est donc cet algorithme qui a été sélectionné (**Nguyen 2017**). Il s'inscrit dans la lignée des algorithmes évolutionnaires.

### 4.2.b.i - Fonctionnement

La première étape de l'algorithme est de construire une population initiale  $Pop$  de  $N_{ind}$  individus. Un individu  $XIND$  est défini par  $n_{ge}$  gènes  $xind_{ij}$ :

$$(II.24) \quad XIND_i = [xind_{i1} \ xind_{i2} \ \dots \ xind_{i_{n_{ge}}}]$$

Avec  $i \in [1, \dots, N_{ind}]$ . Soit  $XIND_{Max-j}$  et  $XIND_{Min-j}$ , respectivement les valeurs maximum et minimum du gène  $j$ . La valeur du gène sera prise comme :

$$(II.25) \quad xind_{ij} = XIND_{Min-j} + \rho[XIND_{Max-j} - XIND_{Min-j}]$$

Avec  $\rho$  : nombre généré aléatoirement dans l'intervalle  $[0;1]$ ,  $j$  : indice des gènes,  $i$  : indice des individus.

La  $k^{ième}$  itération comprend trois opérations successives :

#### Etape 1 : Mutation

Deux types de mutations sont possibles. Le schéma aléatoire (« rand ») favorise la diversité au sein de la population :

$$(II.26) \quad XMUT_i^{(k+1)} = XIND_{a_i}^{(k)} + \mathbf{F} [XIND_{b_i}^{(k)} - XIND_{c_i}^{(k)}]$$

Avec  $XIND_{a_i}$ ,  $XIND_{b_i}$  et  $XIND_{c_i}$  trois individus différents et choisis aléatoirement dans la population et  $\mathbf{F} \in [0; 2]$  facteur choisi par l'utilisateur.

Le schéma du meilleur individu (« best ») favorise, lui, le temps de convergence :

$$(II.27) \quad XMUT_i^{(k+1)} = XIND_{best}^{(k)} + \mathbf{F} [XIND_{a_i}^{(k)} - XIND_{b_i}^{(k)}]$$

Avec  $XIND_{best}$  : le meilleur individu, c'est-à-dire celui ayant la fonction cout minimale, obtenu depuis l'initialisation.

Dans le cadre de ces travaux de thèse, le schéma aléatoire sera adopté.

#### Etape 2 : Croisement

L'obtention de nouveaux individus  $XNOU$  se fait en croisant les mutants, notées  $XMUT$ , avec les individus des générations précédentes,  $XIND$ . L'obtention des gènes de ces nouveaux individus se fait comme suit :

$$(II.28) \quad xnou_{ij}^{(k+1)} = \begin{cases} xmut_{ij}^{(k+1)} & \text{si } randb(j) \leq CR \text{ ou si } j = randnbr(i) \\ xind_{ij}^{(k)} & \text{sinon} \end{cases}$$

Avec  $randb(j)$  : nombre généré aléatoirement dans  $[0,1]$ ,  $randnbr(i)$  : index sélectionné aléatoirement dans  $\{1, \dots, N_{ind}\}$  et  $CR \in [0.1, 0.9]$  : le taux de croisement (paramètre utilisateur).

Etape 3 : Sélection

La population est mise à jour telle que :

$$(II.29) \quad \begin{cases} XIND_i^{(k+1)} = XNOU_i^{(k+1)} & \text{si } f_{cout}(XNOU_i^{(k+1)}) \leq f_{cout}(XIND_i^{(k)}) \\ XIND_i^{(k)} & \text{sinon} \end{cases}$$

Tant que le critère d'arrêt n'est pas satisfait, retourner à l'étape 1.

Critère d'arrêt

Etant en phase de conception, le critère utilisé ici est lorsque le nombre maximum d'itération est atteint. Pour mettre en opération l'algorithme, d'autres critères pourront être ajoutés (écart de la fonction cout entre deux itérations...) (Feyel 2015).

4.2.b.ii - Réglage de l'algorithme

Les valeurs conseillées dans (Feyel 2015) sont reprises ici :  $CR = 0,8$  et  $F = 0,75$ . Le nombre d'individus de la population sera pris comme :

$$(II.30) \quad N_{ind} = \text{arrondi}[10 + \sqrt{n_{ind}}]$$

## 5 - Analyse des courants

La méthode proposée ici repose sur une combinaison de l'algorithme de décomposition modale empirique ensembliste complète (« *Complete Ensemblist Empirical Mode Decomposition : CEEMD* ») (Torres et al. 2011) et une analyse en composantes indépendantes (« *Independent Component Analysis : ICA* ») (Hyvärinen et Oja 2000). La combinaison de ces méthodes a été appliquée au diagnostic de maladies neuromusculaires (Mijovic et al. 2010; Naik et al. 2016). Il est ici proposé de l'appliquer au diagnostic de machines électriques (Michaud 2016). Des modifications ont été apportées pour automatiser le processus. L'ensemble de l'analyse se fait à partir du courant  $I_q$ , dans le repère de Park, qui après plusieurs tests s'est révélé être plus porteur d'informations que le courant  $I_d$ .

### 5.1 - Architecture du processus de traitement

L'architecture du processus de traitement donné à la Figure II.8 : Architecture du processus de traitement. La première étape est d'appliquer l'EEMD à la composante en quadrature du courant  $I_q$ . Dans notre application la CEEMD donne une quinzaine de modes de fonctions intrinsèques (« *Intrinsic Modes Functions : IMF* »). Les dix premiers vont constituer les entrées de l'algorithme ICA (l'analyse en composantes indépendantes). Celui – ci va calculer ensuite des composantes indépendantes (« *Independant components : IC* »). Ces composantes vont être regroupées automatiquement en fonction de leur sensibilité aux différents défauts en fonction d'un ou de plusieurs critères. Ici deux défauts seront considérés : le défaut de court – circuit inter-spices

statorique (ici noté par l'indice  $cc$ ) et le défaut de la vis à rouleaux (noté par l'indice  $var$ ). Les composantes de chaque mode de défaut vont ensuite être combinées pour mettre au point un signal caractéristique de chaque défaut, dit signal virtuel du défaut. Ce signal correspond à ce qui serait mesuré sur un système dont tous les composants sont sains, sauf ceux impliqués dans le défaut. L'extraction des signatures se fait finalement sur chaque signal virtuel. Les différentes étapes vont être détaillées dans les sous – paragraphes suivants.

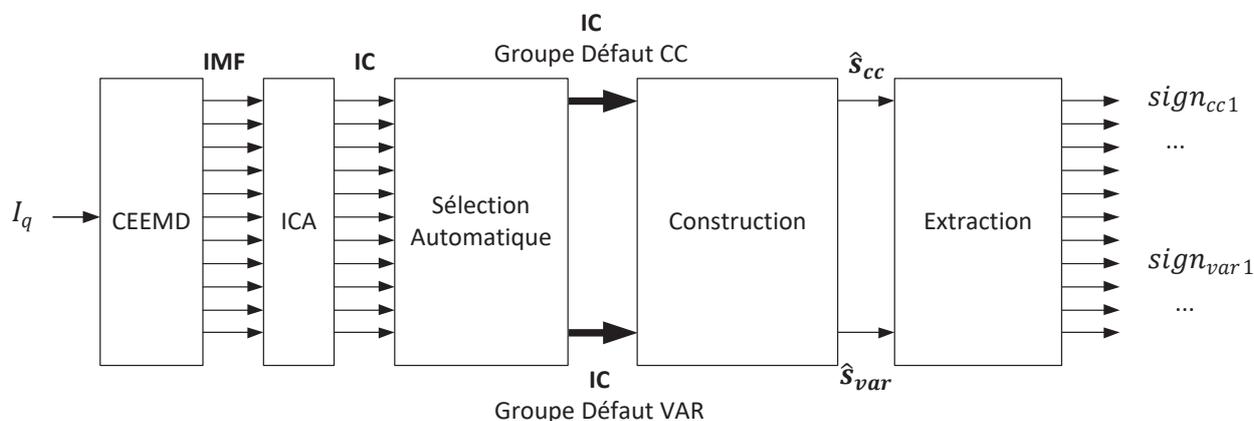


Figure II.8 : Architecture du processus de traitement

## 5.2 - Détails des étapes

### 5.2.a - Décomposition Modale Empirique

#### 5.2.a.i - Généralités

La version originale de l'algorithme par décomposition modale empirique a été proposée par **(Rilling et al. 2003)**. Cet algorithme permet d'analyser des signaux non linéaires (issus de systèmes non – linéaires) et non stationnaires. Il fonctionne directement à partir des données via un traitement local qui sépare le signal en composantes (IMF) sur différentes bandes de fréquences.

De nombreuses versions ont été mises au point depuis l'algorithme original **(Lei et al. 2013)**. Parmi celle – ci, l'EEMD est très populaire de par ses bonnes performances en présence de bruits **(Wu et Huang 2009)**. Cette méthode consiste à ajouter du bruit blanc au signal et à réaliser l'EMD sur le signal obtenu. Les calculs sont effectués pour plusieurs réalisations de bruits. Les IMF sont calculés en faisant la moyenne des IMF obtenus pour chaque réalisation. Cela permet de moyenniser les effets du bruit de mesure et donc de limiter ces effets.

Une version améliorée a été proposée dans **(Torres et al. 2011)** : la décomposition modale empirique complète (CEEMD). Cet algorithme repose sur l'EEMD et consiste à calculer un résidu par mode et non plus un résidu pour tous les modes. Cela permet une meilleure séparation des modes et des temps de calculs réduits. C'est cette version qui a été adoptée dans le cadre de ces travaux de thèse. Les programmes d'implémentations utilisés sont ceux issus de **(Torres et al. 2011)** disponibles au lien suivant : <http://perso.ens-lyon.fr/patrick.flandrin/emd.html>. Afin de ne pas alourdir le mémoire, seul l'EMD est présenté ici. Les algorithmes pour l'EEMD et la CEEMD sont présentés en annexes (Annexe I1 - page 212).

#### 5.2.a.ii - Algorithme EMD

Les notations suivantes sont rappelées :

- ⇒  $y_s$  : signal échantillonné à l'étude
- ⇒  $N$  : nombre de points (échantillons) du signal

L'objectif des méthodes de décompositions modales empiriques est d'exprimer le signal à l'étude sous la forme :

$$(II.31) \quad y_s = \sum_{j=1}^{n_{IMF}} IMF_j + resf$$

Avec  $j$  : l'indice des IMF et  $resf$  : résidu final sur lequel il n'est plus possible d'extraire des IMF.

Pour parvenir à ce résultat, la méthodologie est la suivante :

Algorithme 1 : "Empirical Mode Decomposition" (EMD)	
<b>(1)</b>	<p><b>Initialisation</b></p> <p>Poser <math>res_1 = y_s</math></p>
<b>(2)</b>	<p><b>Détermination des extrémums locaux</b></p> <p>Déterminer les minimums locaux <math>R_{min} = \min_j[res_j]</math> et maximums locaux <math>R_{max} = \max_j[res_j]</math></p>
<b>(3)</b>	<p><b>Création des enveloppes (supérieure <math>e_{sup}</math> et inférieure <math>e_{inf}</math>)</b></p> <p>Relier les minimums (respectivement les maximums) entre eux par une spline cubique pour former l'enveloppe inférieure (respectivement supérieure)</p>
<b>(4)</b>	<p><b>Calcul de l'IMF<sub>j</sub></b></p> <p>Calculer <math>h_j = res_j - moy(e_{sup}; e_{inf})</math>                      Poser <math>IMF_j = h_j</math>                      Calculer <math>res_{j+1} = res_j - IMF_j</math></p>
<b>(5)</b>	<p><b>Répéter les étapes (2) à (4) jusqu'au critère d'arrêt</b></p>
<b>(6)</b>	<p><b>Arrêt</b></p> <p><math>res_j</math> monotone <math>\Leftrightarrow e_{sup}</math> et <math>e_{inf}</math> symétriques <math>\Leftrightarrow moy(e_{sup}; e_{inf}) = 0</math></p>

## 5.2.b - Analyse en Composantes Indépendantes

### 5.2.b.i - Généralités

La famille des méthodes de séparation de sources consiste à identifier à partir de signaux mesurés les sources d'origine de ces défauts (Stone 2002; Choi et al. 2005; Puigt 2011). La séparation est dite « aveugle » lorsqu'elle se fonde sur les mesures et un faible nombre d'hypothèses sur les signaux. Il existe différentes catégories de séparations aveugles qui dépendent des hypothèses utilisées. Parmi ces catégories, celle de l'analyse en composantes indépendantes (ICA) est très populaire, notamment dans le domaine du diagnostic de machines (Li Li et Liangsheng Qu 2002; Lee et al. 2006; Wang et al. 2011; Ali et Mahdi 2014).

L'hypothèse fondatrice de l'ICA est la suivante :

**Hypothèse 5 : Les signaux provenant de sources physiquement distinctes sont statistiquement indépendants**

La condition de l'hypothèse est vérifiée dans le cadre de la surveillance des EMA. En effet les défauts étudiés ici ont chacun pour source un composant différent. Ainsi la méthodologie de l'ICA consistera à déterminer à partir des observations des composantes statistiquement indépendantes. Ces composantes, de par l'Hypothèse 5, seront assimilables aux sources. La version utilisée ici est celle de (Hyvarinen 1999). Elle a été implémentée via un package de fonctions en open – source (voir <http://research.ics.aalto.fi/ica/fastica/>).

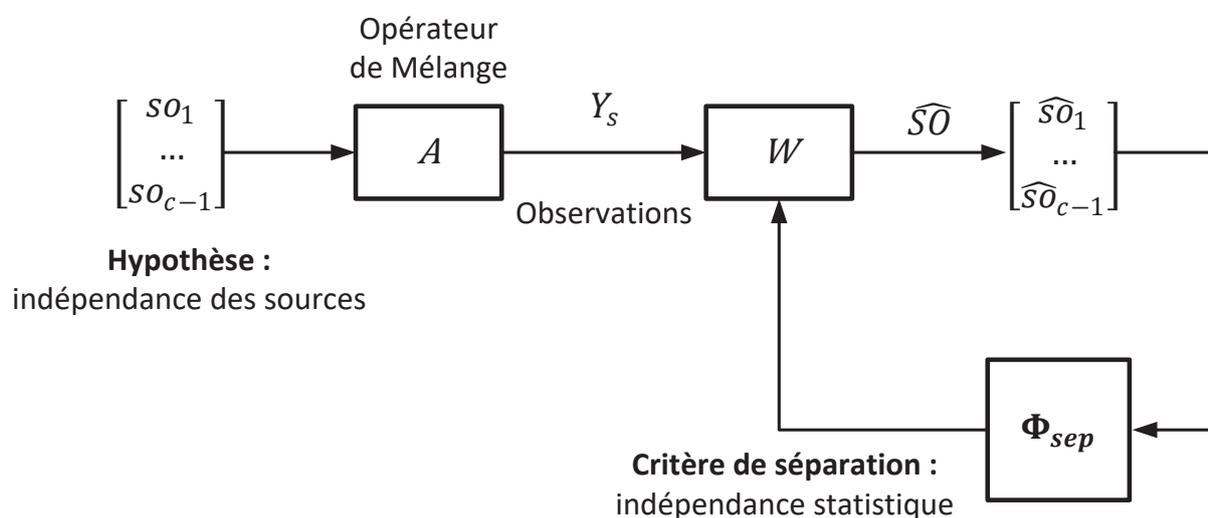


Figure II.9 : Principe de l'ICA (Gelle et al. 2001; Michaud 2016)

### 5.2.b.ii - Estimation des sources

Pour estimer les sources il est nécessaire de supposer la manière dont se mélangent les sources pour former l'ensemble des observations  $Y_s = [y_{s1} \dots y_{sNm}]$ . Dans ces travaux il est supposé que le mélange est convolutif. Ce type de mélange correspond en général aux applications de diagnostic industriel (Antoni 2005). Il suppose que la propagation entre les sources et les capteurs est linéaire et

invariante dans le temps. Chaque observation  $y_{si}$  peut alors s'exprimer comme :

$$(II.32) \quad y_{si} = \sum_{j=1}^{n_{SO}} h_{ij} \langle * \rangle s_{oj}$$

Avec  $\langle * \rangle$  : un produit de convolution et  $h_{ij}$  : la réponse impulsionnelle du filtre qui représente l'effet de la source  $j$  sur l'observation  $i$ . Cela peut s'exprimer sous forme matricielle par :

$$(II.33) \quad Y_s = A * SO$$

Les éléments de la matrice  $A$  sont des fonctions de transfert. Ces fonctions de transfert ont des formes de filtres impulsionnels à réponses finies de la forme :

$$(II.34) \quad A_{ij} = \sum_{k=0}^{n_{filtre}} a_{ij}(k) * z^{-1}$$

Avec  $z^{-1}$  l'opérateur de retard et  $n_{filtre}$  l'ordre du filtre. Ce dernier peut parfois être élevé ce qui entraîne un volume de calcul important. Il peut être estimé par :

$$(II.35) \quad n_{filtre} = \frac{T_{def}}{T_e}$$

Avec  $T_{def}$  : temps de réponse du signal lors de l'apparition brusque d'un défaut et  $T_e$  : période d'échantillonnage. Le temps de réponse des défauts considérés a été estimé par simulation à  $T_{def} = 50 \text{ ms}$ . Dans le cadre de notre application, la période d'échantillonnage est de  $0.5 \text{ ms}$ , ce qui donne  $n_{filtre} = 100$ .

L'estimation des sources se fait par :

$$(II.36) \quad \widehat{SO} = WY_s$$

Où  $W = A^{-1}$  est une inconnue. Le calcul de cette matrice revient à un problème d'optimisation par rapport à un critère  $\Phi_{sep}$  tel que :

$$(II.37) \quad W_{opt} = \operatorname{argmax}[\Phi_{sep}(\widehat{SO})]$$

Le critère choisi ici est la minimisation de l'information mutuelle (**Comon 1994; Hyvärinen et Oja 2000**). Il est détaillé en annexe (Annexe VIII2 - 215).

### 5.2.c - Sélection automatique des composantes

Dans la littérature la sélection des IC se fait de manière manuelle (**Mijovic et al. 2010**). Il est ici proposé de le faire de manière automatique, via un critère (**Michaud 2016**). Cela revient, d'une

certaine manière à classer les IC en fonctions d'indicateurs. Le critère doit être choisi vis-à-vis des signaux pour les cas de défauts considérés.

Pour notre cadre applicatif, le court – circuit est caractérisé par des harmoniques hautes fréquences dans le courant, alors que le défaut d'usure de la VAR crée des pics périodiques de fortes amplitudes. Ceci peut notamment être observé en simulant les deux défauts séparément, ici sur un profil de position sinusoïdale avec une charge constante (voir Figure II.10).

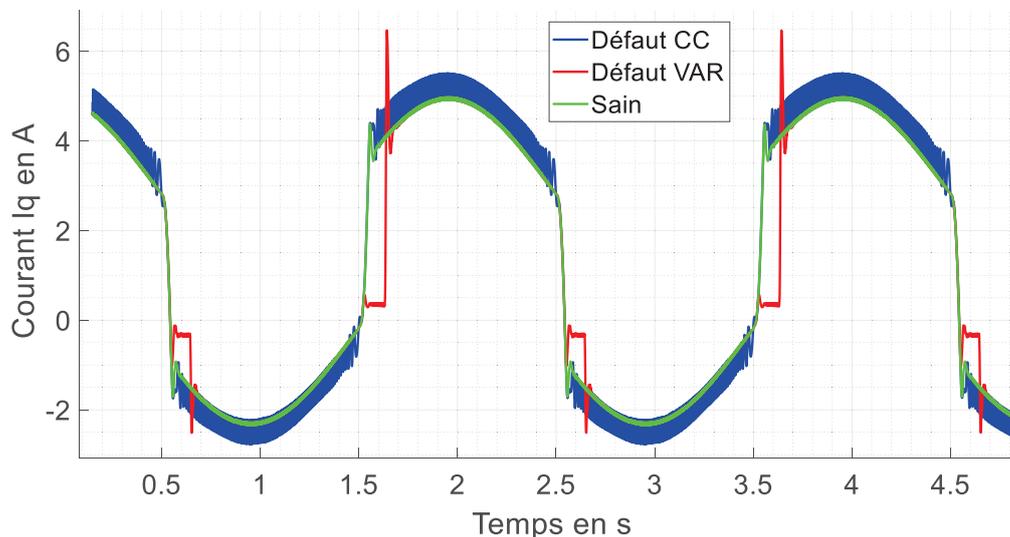


Figure II.10 : Effets des défauts VAR et CC sur le courant  $I_q$  (simulation)

Ces deux phénomènes peuvent s'expliquer physiquement. Le défaut de court – circuit crée une fuite de courant. La régulation de celui – ci essaye de compenser cette fuite, ce qui augmente la quantité de courant nécessaire et injecte du bruit. Lorsque le jeu augmente, le moteur peut se retrouver, pendant un court – instant, découplé de la transmission mécanique. Le MSAP n'est alors chargé que par ses propres frottements et son inertie. Lors de la reprise de contact, la charge augmente brusquement. La régulation injecte alors un fort courant pour éviter une erreur de position trop importante, ce qui engendre un pic. Ainsi les étapes précédentes permettent de séparer les composantes propres à chaque défaut, le bruit additionnel d'une part, et le pic d'autre part.

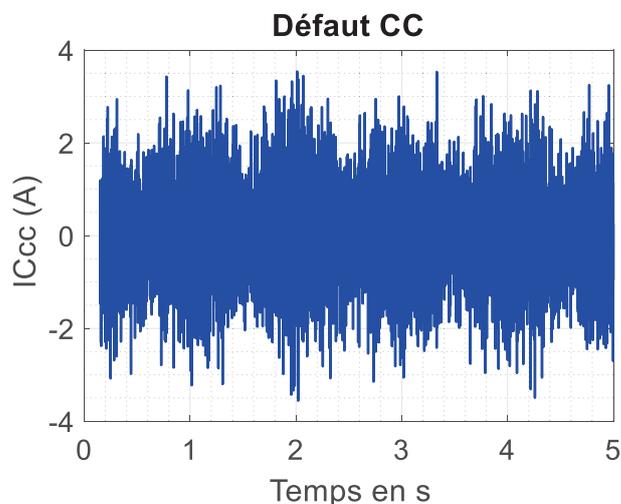


Figure II.11 : Composante représentative du défaut CC pour un défaut CC

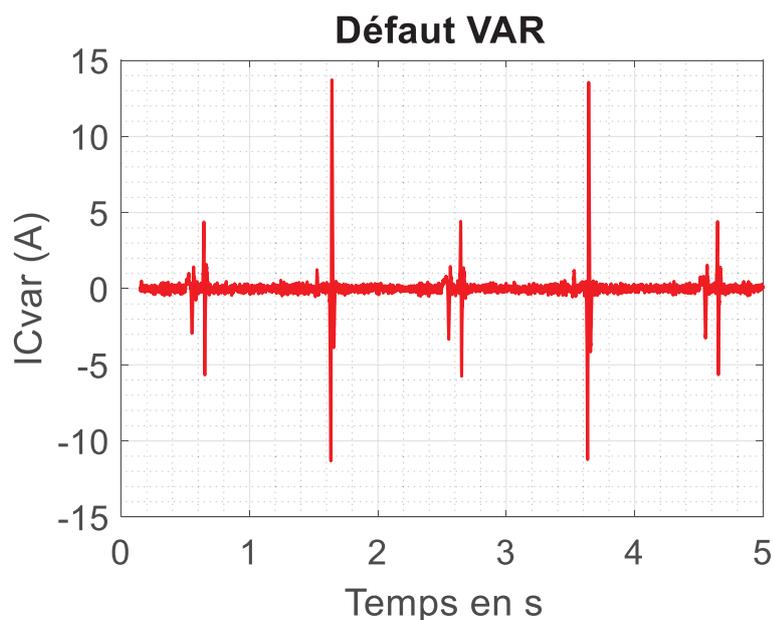


Figure II.12 : Composante représentative du défaut VAR pour un défaut VAR

Ainsi, il est attendu que les distributions de probabilité des composantes créées par le défaut CC seront proches de celle d'un bruit, et donc gaussiennes. A l'inverse, celles des composantes créées par le défaut VAR devraient être plutôt étroites, avec des queues de distribution très courtes. Ainsi un seuil sur la valeur de Kurtosis (voir (II.13)) peut être un bon critère.

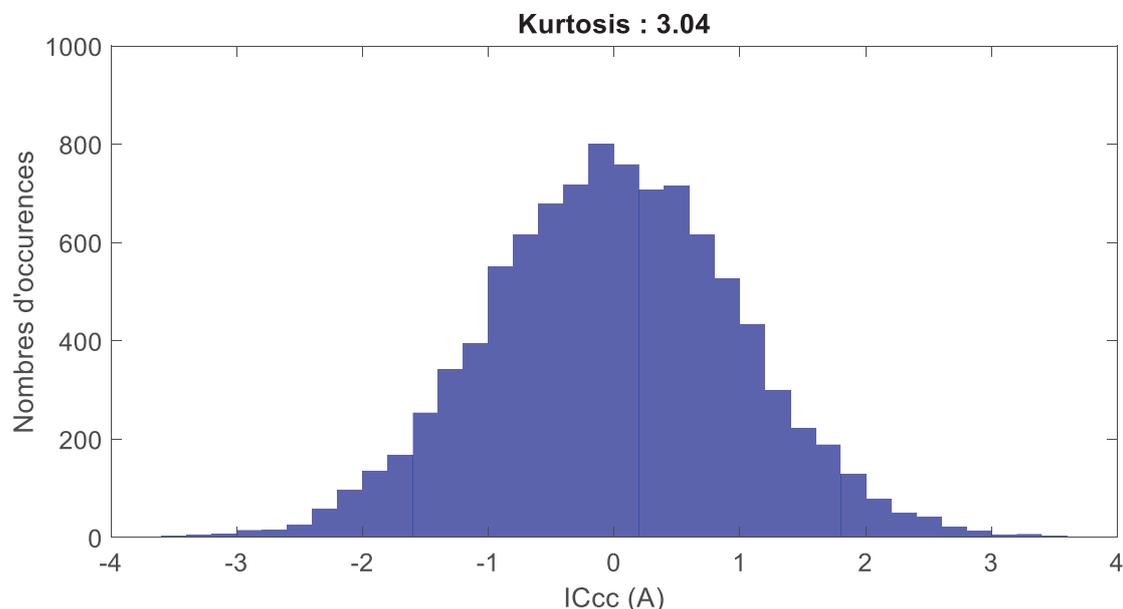


Figure II.13 : Distribution de la composante ICcc

Pour la composante  $IC_{cc}$  la distribution est très proche d'une gaussienne avec un kurtosis de 3.04 (voir Figure II.13). Pour la composante  $IC_{var}$  le kurtosis est de 85.15 (voir Figure II.14). Ainsi il est assez aisé de trouver un seuil adapté pour distinguer les deux types de composantes. Le critère de kurtosis est donc validé et sera adopté pour le reste des présents travaux de thèse.

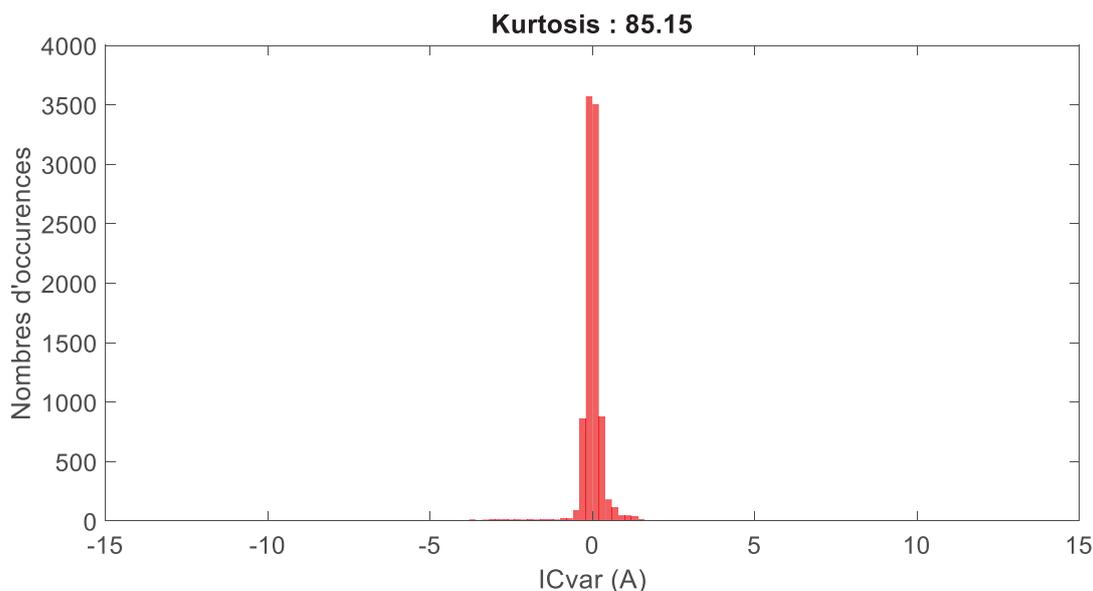


Figure II.14 : Distribution de la composante ICvar

### 5.2.d - Construction des signaux virtuels

La construction des signaux virtuels se fait pour chaque défaut considéré par :

$$(II.38) \quad \hat{s}_{def} = \sum_{i=1}^{n_{IC-def}} W_{opt}^{-1} IC_{def}$$

Avec  $def \in \{cc, var\}$  et  $IC_{def}$  : le vecteur constitué des IC du groupe correspondant au défaut  $def$ .

### 5.2.e - Extraction des signatures

Les signatures calculées à partir des signaux virtuels seront les signatures statistiques évoquées au paragraphe 2.2.a - Analyse temporelle à la page 52. Deux autres signatures seront évaluées :

- ⇒ Le nombre de passages par zéro
- ⇒ Le nombre de pics

L'ensemble des signatures mises au point vont maintenant être validées.

## 6 - Méthodologie de validation

La méthodologie appliquée ici est celle issue des travaux de (Lamoureux 2014). L'idée est d'utiliser le modèle présenté au paragraphe 1 - (page 46) pour effectuer des essais, virtuels, d'une population de moteurs. Chaque individu de la population sera défini par une combinaison spécifique de paramètres de l'EMA. Chaque individu de la population sera testé pour le cas sain et pour les différents cas de défauts, avec différents niveaux de sévérité.

La première étape de la méthodologie consiste en une analyse de sensibilité pour déterminer les paramètres influents sur les signatures. La deuxième est une série de simulations, pour différentes combinaisons de ces paramètres influents, pour l'ensemble des modes de fonctionnements (sain et défauts, avec différents niveaux de sévérité).

## 6.1 - Obtention des paramètres influents

La démarche est décrite par la Figure II.15. Un plan d'expérience est construit à partir de la liste de paramètres à étudier et de leur plage de valeurs. On distinguera deux types de paramètres. Les paramètres épistémiques seront liés aux propriétés intrinsèques du système, par exemple : la résistance statorique, l'inertie ou encore le coefficient de couple. Les paramètres de contexte, eux, seront liés à l'environnement de fonctionnement du système, par exemple : la charge, la température extérieure....

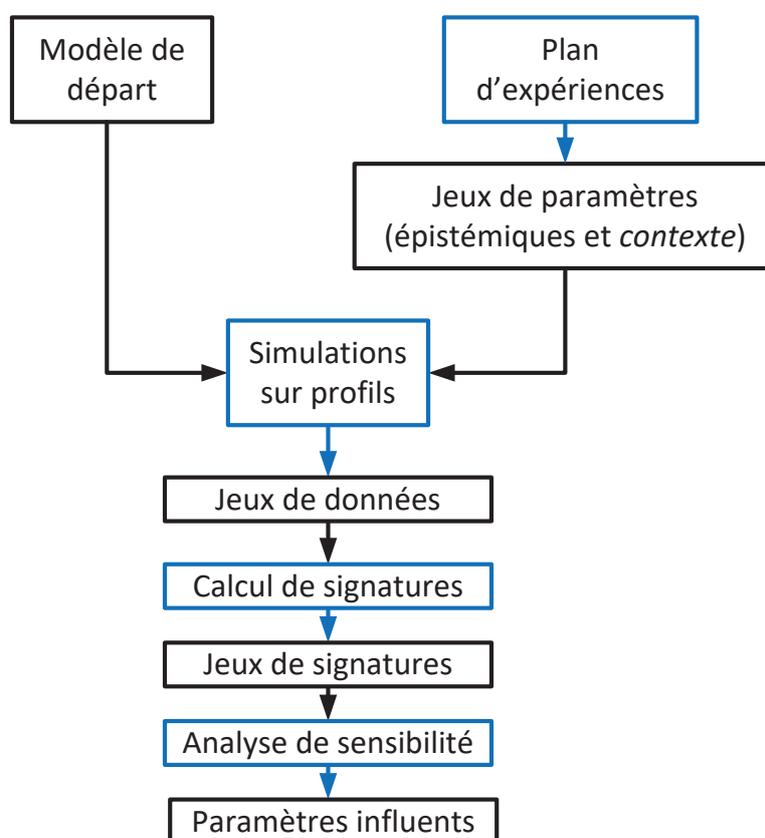


Figure II.15: Méthodologie pour obtenir les paramètres influents

Le plan d'expérience sera ici déterminé par une méthode d'échantillonnage par hypercube latin (Helton et Davis 2003; Iman 2008a, 2008b). Des détails complémentaires sont donnés sur cette méthode en annexe (Annexe VIII3 - page 215). Le modèle de départ est ensuite simulé pour un cas sain, sur un ou plusieurs profils. Cela donne un ensemble de jeux de données, comme des mesures issues d'un ensemble d'essais. Les algorithmes de calculs de signatures sont appliqués à ces jeux de données ce qui donne des jeux de signatures. Finalement, des méthodes d'analyse de sensibilité sont appliquées à ces jeux de signatures, ce qui permet de déterminer les paramètres influents. Seuls ceux – ci sont conservés pour la deuxième étape.

## 6.2 - Calcul des NKPI des signatures

La démarche est décrite par Figure II.16. L'objectif ici est d'utiliser la simulation pour calculer des indicateurs clés de performances (*Numerical Key Performance Indicator : NKPI*) des signatures (**Lamoureux 2014**). Dans un premier temps, tous les paramètres non influents du modèle sont fixés. Puis un nouveau plan d'expériences est établi, celui-ci prend maintenant en compte les paramètres de défauts. Ces paramètres sont représentatifs de la gravité d'au moins un défaut. Pour les EMA, ces paramètres seront : la résistance de défaut  $R_f$ , la demi amplitude du jeu  $\alpha_{jeu}$ , les paramètres de frottements de la VAR  $F_{fv}$  et  $F_{fsec}$ . Le modèle est simulé pour tous les jeux de paramètres, sur un ou plusieurs profils. Comme précédemment les jeux de données sont traités par les algorithmes de calcul de signatures. Les jeux de signatures permettent ensuite de calculer les NKPI.

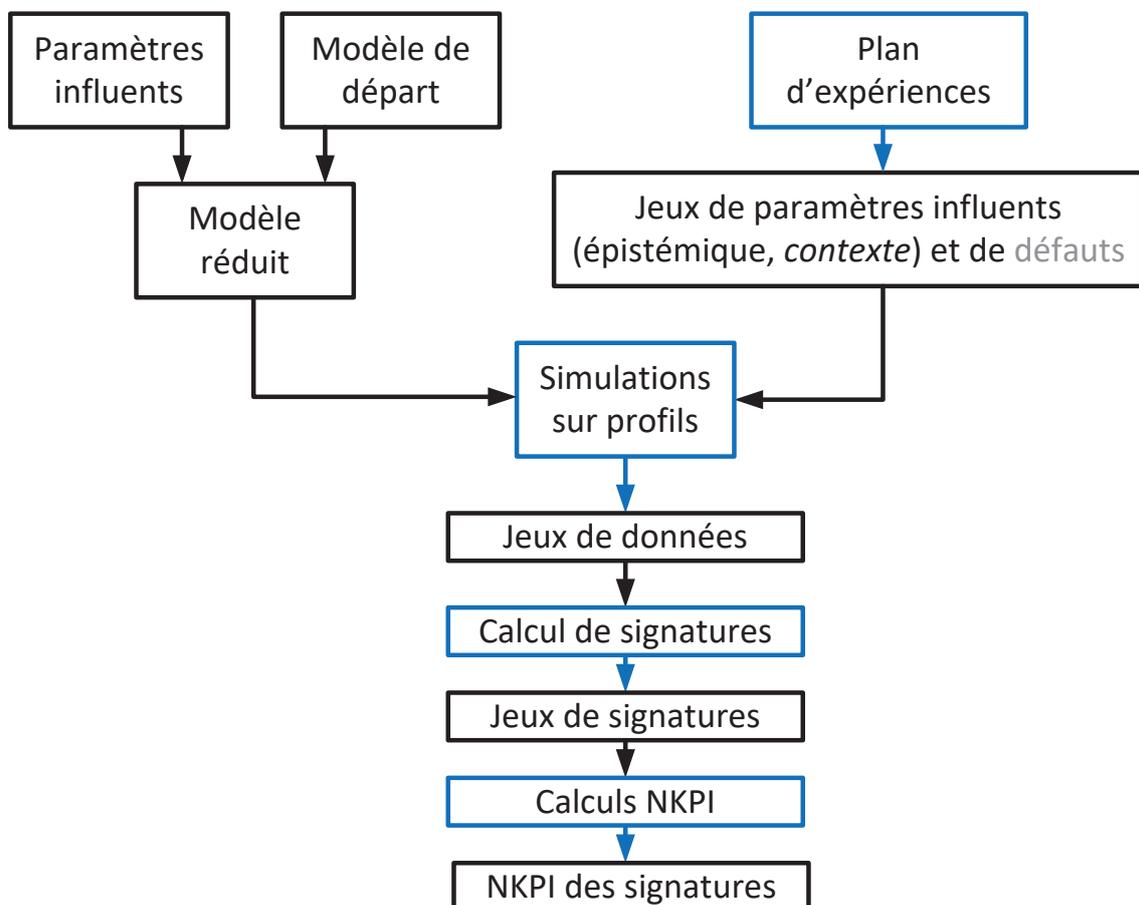


Figure II.16: Méthodologie pour le calcul des NKPI des signatures

Les NKPI peuvent être exprimés de manière binaire (conforme), en caractérisant si les spécifications du client sont respectées. Ils peuvent également être exprimés de manière numérique (globale), en pourcentage. C'est ce deuxième type de formulation qui sera utilisé ici. Deux NKPI sont utilisés ici :

- ⇒ Le NKPI détectabilité permet de mesurer si un défaut est détecté par la signature considérée.
- ⇒ Le NKPI identification permet, lui, de mesurer si la sévérité d'un défaut peut être distinguée des autres sévérités du même défaut, mais aussi de celles des autres défauts.

Les détails sur les NKPI et leurs formules de calculs sont disponibles en annexes (Annexe VIII.4.2 - page 217 et Annexe VIII.4.3 - page 217).

## 7 - Validation par simulation

Cette méthodologie est appliquée au cadre applicatif de l'EMA pour aileron. Le modèle utilisé pour les simulations est celui présenté au paragraphe 1 - 46.

### 7.1 - Profil de caractérisation

Le profil de caractérisation, à appliquer sur le tarmac, consiste en deux phases (voir Figure II.17). La première consiste en un profil trapézoïdal avec un profil de charge, trapézoïdal dont l'amplitude décroît dans le temps. La seconde phase reprend la première mais pour une fréquence plus élevée pour la consigne de position.

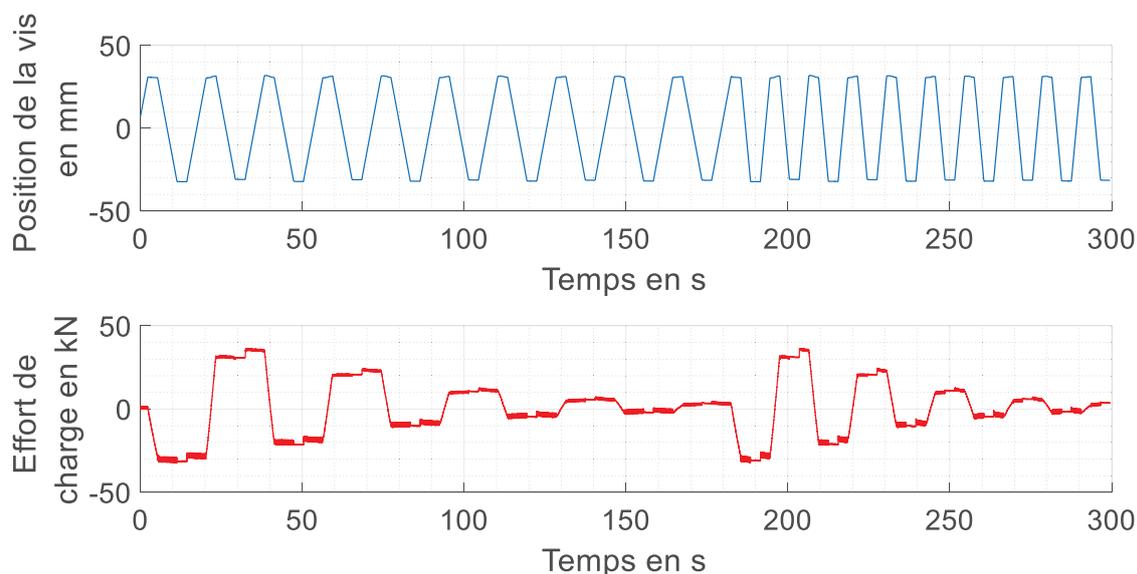


Figure II.17 : Profil de caractérisation

### 7.2 - Obtention des paramètres influents

La liste des paramètres à étudier a été déterminée par concertation avec des experts. Ainsi les paramètres à l'étude sont :

- ⇒ La résistance statorique  $R_s$
- ⇒ L'inductance statorique  $L_s$
- ⇒ Le coefficient de couple  $K_{mot}$
- ⇒ Le gain de mesure de courant  $G_{mesI}$  (représentatif de l'erreur de mesure sur les courants)
- ⇒ Le gain de mesure de charge  $G_{mesC}$  (représentatif de l'erreur de mesure sur la charge)

Les distributions de ces paramètres correspondent à ce qui est attendu en sortie de ligne de

production. Les distributions des paramètres mécaniques sont, elles, beaucoup moins étendues. Ces paramètres sont donc considérés comme constants au sein d'une population. Etant donné que c'est un profil de caractérisation non opérationnel qui est utilisé ici, on ne considérera pas les paramètres de contexte.

La démarche présentée au paragraphe 6.1 - a montré que tous les paramètres à l'étude sont influents. Les détails de l'analyse ne seront donc pas donnés ici. L'ensemble des paramètres sera conservé pour l'étape suivante.

## 7.3 - Calcul des NKPI des signatures

### 7.3.a - Simulations sur profil

Le nombre de simulations à effectuer est un compromis entre les temps de calcul et la précision des résultats. Les distributions des cinq paramètres de l'EMA ont été échantillonnées par hyper cube latin pour produire 20 combinaisons. Chaque combinaison représente un EMA en sortie de production. Les défauts considérés sont : le court – circuit inter-spires et le défaut d'usure de la VAR. Pour chaque défaut, quatre niveaux de sévérité (valeurs de paramètres de défauts) seront étudiés. Le premier niveau de sévérité correspondra à un cas sain. Le cas de défaut combiné sera également étudié. Le défaut de CC sera représenté par la résistance de défaut  $R_f$ . Le défaut de la VAR sera représenté par trois paramètres : l'amplitude du jeu  $\alpha_{jeu}$ , le coefficient de frottement visqueux de la VAR  $F_{fv}$ , le coefficient de frottement sec de la VAR  $F_{fsec}$ . Ces trois paramètres seront modifiés en même temps, mais avec des incréments différents. Ainsi le nombre total de simulations est donné par :

$$(II.39) \quad N_{simu} = N_{pop\_ema} * c * n_{sev}$$

Avec  $N_{pop\_ema}$  : le nombre d'individus dans la population (ici 20),  $c$  : le nombre total de modes de fonctionnement (ici 4 avec 1 : mode sain, 2 : défaut CC, 3 : défaut VAR, 4 : défaut combiné) et  $n_{sev}$  : le nombre de niveaux de sévérité par défaut (ici 4).

Le nombre de simulations à effectuer sera donc de 320.

### 7.3.b - Calcul des signatures

Les algorithmes de calculs de signatures utilisés sont ceux présentés au paragraphe 4 - Identification des frottements et au paragraphe 5 - Analyse des courants. Une analyse statistique (voir 2.2.a - ) sera également effectuée sur le courant  $I_q$ .

Pour l'identification des frottements et l'analyse statistique, l'ensemble du profil sera utilisé. Pour l'analyse des courants seule la portion comprise entre  $t = 200 s$  et  $t = 270 s$  sera utilisée, afin de réduire la quantité de calculs.

### 7.3.c - Calculs des NKPI

Etant donné le grand nombre de signatures évaluées, seuls les cinq meilleurs résultats de chaque

catégorie seront donnés ici. Le reste est disponible en annexe (Annexe VIII5 - page 218).

### 7.3.c.i - Déteçtabilité

Les cinq signatures les plus performantes pour la déteçtion du défaut de court – circuit inter-spires sont :

Nom signature	Nombre de passage par zéro ( $S_{var}$ )	Nombre de pics ( $S_{var}$ )	Facteur crête de $S_{var}$	Energie de $S_{var}$	Nombre de passage par zéro ( $S_{cc}$ )
Déteçtabilité (%)	37	30	29	28	28

Tableau II.1: Cinq meilleurs déteçtabilités pour le défaut CC

Les déteçtabilités sont ici assez faibles. La majorité des signatures sont issues de l'analyse de  $S_{var}$ , il semblerait donc que le signal  $S_{cc}$  soit moins porteur d'informations sur le défaut de CC.

Les cinq signatures les plus performantes pour le défaut de la VAR sont :

Nom signature	Facteur crête de $I_q$	Kurtosis de $I_q$	Coefficient de frottements visqueux $C_v$	Valeur moyenne de $I_q$	Energie de $S_{var}$
Déteçtabilité (%)	100	100	91	81	71

Tableau II.2 : Cinq meilleurs déteçtabilités pour le défaut VAR

La déteçtabilité est ici très bonne. De nombreuses signatures sont au-dessus des 50%.

### 7.3.c.ii - Identifiabilité

Les identifiabilités des niveaux de sévérité de chaque classe de défauts sont données au tableau suivant. Toutes les signatures ont été utilisées pour ces calculs.

	Défaut CC	Défaut VAR
Sévérités 1 et 2	41	58
Sévérités 1 et 3	50	49
Sévérités 2 et 3	41	27

Tableau II.3 : Identifiabilité des sévérités des défauts CC et VAR (en %)

Les identifiabilités sont correctes. A noter que l'identifiabilité, pour le défaut VAR, des sévérités 1 – 2 est supérieure à celle des sévérités 1 – 3. Ceci peut s'expliquer par le fait que l'ensemble des signatures testées, même celles n'ayant pas eu de bons résultats en déteçtabilité, ont été utilisés pour calculer l'identifiabilité. Cela peut également s'expliquer par le fait que la métrique a été estimée à partir d'un nombre trop réduit de points.

Pour le cas de défauts combinés, il faut définir une nouvelle échelle de sévérité. L'objectif est qu'un cas de défaut combiné, de même sévérité, soit plus sévère qu'un cas unique de défaut. On propose donc ici d'additionner les indices sévérité. Ils iront donc de 2 à 6 :

	Défaut combiné CC – VAR
Sévérités 2 et 3	9
Sévérités 2 et 4	27
Sévérités 2 et 5	61
Sévérités 2 et 6	59
Sévérités 3 et 4	27
Sévérités 3 et 5	62
Sévérités 3 et 6	61
Sévérités 4 et 5	58
Sévérités 4 et 6	62
Sévérités 5 et 6	14

Tableau II.4 : Identifiabilité des sévérités du défaut combiné (en %)

Les identifiabilités sont très variables. Cela peut s'expliquer par le fait que l'ensemble des signatures testées, même celles n'ayant pas eu de bons résultats en détectabilité, ont été utilisées. Il y a également le fait qu'un défaut CC de sévérité de niveaux  $k$  ne va pas entraîner la même amplitude de variation dans les signatures qu'un défaut VAR de sévérité  $k$ .

## 7.4 - Synthèse des résultats

La première observation est que les signatures mises au point sont très performantes en détectabilité et assez performante en identification pour le défaut VAR. Ce n'est pas le cas pour le défaut CC, où les performances sont faibles, notamment les signatures issues de l'analyse des courants par combinaison de CEEMD et d'ICA. Cette faible performance pour le défaut CC peut s'expliquer par le réglage des algorithmes. En effet, le réglage a été ici contraint par les temps de calculs. Augmenter les temps de calculs permettrait d'effectuer plus d'itérations, ce qui pourrait permettre de caractériser plus finement les différentes composantes du signal.

## 8 - Conclusion du chapitre

Dans un premier temps, un modèle de l'EMA permettant la simulation de défauts, a été présenté. Puis, les différentes familles de méthodes de calcul de signatures de défauts ont été introduites. Un état de l'art focalisé sur les signatures pour les EMA de commande de vol, a également été effectué. Celui-ci a permis d'orienter les travaux sur les méthodes de calcul de signatures. Ainsi, deux méthodes ont été proposées dans le cadre de ces travaux de thèse. Celles-ci reposent sur l'utilisation d'un profil d'acquisition non opérationnel, bien qu'elles puissent probablement être appliquées à des profils opérationnels (en vol). La première consiste à identifier un modèle de frottement, ramené sur le rotor du MSAP. Les paramètres du modèle de frottement constituent les signatures. La deuxième méthode repose uniquement sur l'analyse du courant en quadrature dans le repère de Park. Une combinaison de décomposition modale empirique ensembliste et d'analyse en composante indépendante est utilisée. Cette combinaison de méthodes permet d'extraire différentes composantes du signal. Ces composantes sont classées automatiquement selon un critère. Le critère défini ici est un critère sur la valeur du kurtosis des composantes. Les composantes sensibles à chaque défaut constituent des signaux virtuels. Chaque signal virtuel correspond à ce qui serait mesuré sur un système dont tous les composants seraient sains, sauf ceux impliqués dans le défaut. L'extraction des signatures se fait finalement sur chaque signal virtuel, par des calculs statistiques.

Une campagne de simulation a été effectuée. Cette campagne vise à reproduire des essais d'une population d'EMA pour des cas sains, de défaut VAR, de défaut CC et de défauts combinés. Les algorithmes de calculs de signatures ont été appliqués aux résultats de ces simulations. Cela a permis de calculer des indicateurs de performance des signatures. Ces indicateurs ont permis d'évaluer la détectabilité des signatures (la capacité d'une signature à détecter un défaut ou non), et l'identifiabilité (la capacité au sein d'un même défaut à distinguer les sévérités). La détectabilité du défaut VAR est très bonne, avec de nombreuses signatures, au-dessus de 50%. Celle du défaut CC est plus faible avec des détectabilités entre 20 et 40%. L'identifiabilité pour les défauts simples est, elle, assez correcte, avec des taux de 40 à 50%. Pour le cas de défauts combinés, elle est très variable avec des taux entre 9 et 62%.

Les signatures ne sont pas le seul axe de travail pour permettre de bons résultats en diagnostic. L'algorithme d'évaluation des signatures peut également être travaillé pour améliorer les performances, en utilisant par exemple des techniques de reconnaissances de formes.

# III

## Diagnostic par reconnaissance de formes

A word cloud of terms related to diagnostic shape recognition. The words are arranged in a roughly circular shape, with 'Diagnostic' being the largest and most central word. Other prominent words include 'RDF', 'Classification Supervisée', 'Appartenances', 'SVM', 'Observations', 'Vecteur de Formes', 'T-norme', 'Ambiguïté', 'Données', 'Flou', 'Sévérité', 'Rejet', 'T-conorme', 'Classes', 'Risques', and 'Défauts'. The words are in various shades of blue and black, with different font sizes and orientations.

T-norme  
Ambiguïté Données  
SVM Observations Flou  
Vecteur de Formes  
Sévérité RDF Rejet  
Diagnostic  
Classification Supervisée  
Appartenances  
T-conorme  
Classes Risques Défauts

<b>III</b>	<b>DIAGNOSTIC PAR RECONNAISSANCE DE FORMES .....</b>	<b>74</b>
1 -	GENERALITES .....	76
2 -	LA RECONNAISSANCE DE FORMES (RDF) .....	76
2.1 -	Principe .....	76
2.2 -	Algorithmes de classification supervisée .....	78
2.2.a -	Basés sur la logique .....	78
2.2.b -	Basés sur des réseaux de neurones artificiels (RNA) .....	79
2.2.c -	Basés sur les probabilités .....	80
2.2.d -	Basés sur l'exemple .....	81
2.2.e -	Basés sur les noyaux .....	81
2.3 -	Choix d'une famille d'algorithmes .....	82
3 -	MACHINE A VECTEURS DE SUPPORT (SVM) .....	83
3.1 -	SVM et risque .....	83
3.2 -	SVM binaire linéaire .....	84
3.2.a -	Cas séparable .....	84
3.2.b -	Cas non séparable .....	87
3.3 -	SVM binaire non linéaire .....	88
3.4 -	SVM multi-classes .....	88
3.4.a -	Un contre tous : « One Vs All » (OVA) .....	88
3.4.b -	Un contre Un : « One Vs One » (OVO) .....	89
3.4.c -	Un pour les Autres : « One To Others » (OTO) .....	92
4 -	SVM ET FONCTIONS D'APPARTENANCE .....	93
4.1 -	Rappels sur la théorie du flou .....	93
4.1.a -	Fondements .....	93
4.1.b -	Opérateurs d'agrégations .....	93
4.1.c -	Fusion d'informations floues .....	94
4.1.d -	Complémentation .....	95
4.1 -	SVM floue binaire .....	95
4.2 -	SVM floue multi-classes .....	97
4.2.a -	Généralités .....	97
4.2.b -	Notations .....	98
4.2.c -	Méthode « One Vs All » .....	98
4.2.c.i -	Principe .....	98
4.2.c.ii -	Exemple .....	99
4.2.d -	Méthode « One Vs One » .....	100
4.2.d.i -	Principe .....	100
4.2.d.ii -	Exemple .....	101
4.2.e -	Méthode « One To Others » .....	103
4.2.e.i -	Principe .....	103
4.2.e.ii -	Exemple .....	105
4.3 -	Règles de décision .....	108
4.3.a -	Indicateur de rejet en distance .....	108
4.3.b -	Indicateur d'ambiguïté .....	109
4.3.c -	Règle de décision reposant sur les indicateurs .....	109
4.4 -	Estimation de la sévérité .....	110
4.5 -	Méthodologie de réglage .....	111
4.5.a -	Notations .....	111
4.5.b -	Réglage d'un modèle SVM .....	111
4.5.c -	Réglage d'un modèle SVM-FA .....	112
4.6 -	Méthodologie de validation .....	112
5 -	ARCHITECTURE DU SYSTEME DE DIAGNOSTIC .....	113
6 -	CONCLUSION DU CHAPITRE .....	114

# 1 - Généralités

Le diagnostic doit permettre, à partir des signatures, d'évaluer l'état de santé du système. Lors de l'apparition d'un défaut, celui-ci doit être localisé, c'est-à-dire que le ou les composants responsables doivent être identifiés. La sévérité du ou des défauts peut également être fournie.

Différentes méthodes existent : comparaison à des seuils prédéfinis (**Choi et al. 2012; Rahman et Uddin 2015**), utilisation d'un système d'experts raisonnant à base de règles (**Zidani et al. 2003; Elsaadawi et al. 2008**), utilisation de méthodes par reconnaissance de formes (RDF).

Ces dernières sont de plus en plus utilisées, de par leurs bonnes performances et de par l'augmentation des quantités de données disponibles. Elles sont également plus facilement mises en œuvre qu'il y a une dizaine d'années. En effet, des applications temps-réel se font maintenant dans le domaine de la vision machine (**Fornaciari et al. 2014**) mais également dans le domaine du diagnostic (**Gajjar et al. 2017**). Ceci s'explique par l'augmentation des performances technologiques en termes de puissance de calcul des processeurs et en termes de mémoire.

Ainsi, cette famille de méthodes est une bonne candidate pour nos applications dans le cadre aéronautique. Nous allons donc maintenant détailler le principe des méthodes par reconnaissance de formes.

## 2 - La reconnaissance de formes (RDF)

### 2.1 - Principe

Ces méthodes reposent sur la notion, centrale, de vecteurs de forme. Un vecteur de forme est un vecteur  $x$  à  $p$  paramètres qui caractérise un objet. Dans le cas du diagnostic, l'objet est le système qui doit être diagnostiqué. Ainsi, le vecteur de forme sera constitué des signatures de défauts calculées pour un système donné, à un instant donné. Dans ce mémoire, toutes les signatures seront à valeurs dans  $\mathbb{R}$ , soit  $x \in \mathbb{R}^p$ . La RDF permet d'apprendre un modèle à partir d'une base de données  $X$ . Cette base est constituée d'un ensemble d'observations, d'exemples de vecteur de forme pour différentes réalisations de l'objet. Dans notre cas, les observations représenteront des exemples de systèmes sains et de différentes réalisations de défauts. La base de données pourra ainsi être représentée par une matrice de taille  $(m, p)$  où  $m$  représente le nombre d'observations et  $p$  le nombre de composantes du vecteur forme. Le modèle appris peut ensuite être évalué sur une base de test, notée  $XT$ , de taille  $(m_t, p)$ . A des fins simplificatrices, les hypothèses suivantes sont faites sur l'ensemble des bases de données qui seront considérées dans cette thèse :

#### **Hypothèse 6 : Représentativité des bases de données**

Chaque base est représentative des défauts considérés. Pour une base expérimentale, cela signifie que les méthodes d'émulation des défauts sont représentatives. Pour une base issue de simulations, cela signifie à la fois que le modèle de simulation est représentatif et que les hypothèses d'évolution des paramètres avec le défaut le sont également.

**Hypothèse 7 : Volume des bases de données**

Chaque base contient suffisamment d'informations pour que des techniques de reconnaissance de formes puissent établir des classes représentatives des modes de fonctionnement du système et les modèles de classification associés à celles-ci.

Les modèles obtenus par RDF permettent d'attribuer une classe, ou label, aux vecteurs de formes. Dans le cas du diagnostic, ces classes représentent les différents états du système (sain, défaut 1, défaut 2, ...). Par convenance, les classes sont, en général, notées sur un ensemble discret d'entiers tel que :  $y \in \{1, 2, \dots, c\}$  où  $y$  est la classe de l'observation  $x$  et  $c$  est le nombre de classes. On notera  $Y$  le vecteur de taille  $(m, 1)$  représentant les classes des observations de  $X$ . Une observation particulière de la base  $X$  sera notée  $X_i \in \mathbb{R}^p$ , avec  $i \in \{1, \dots, m\}$  et sa classe sera notée  $Y_i \in \{1, \dots, c\}$ .

L'attribution d'une classe à une nouvelle observation se fera via le calcul d'une métrique, reposant sur le modèle RDF établi à partir des données. La métrique dépendra du type d'algorithme choisi : il pourra s'agir d'un calcul d'une distance, d'un calcul de probabilité d'appartenance, d'un vote ...

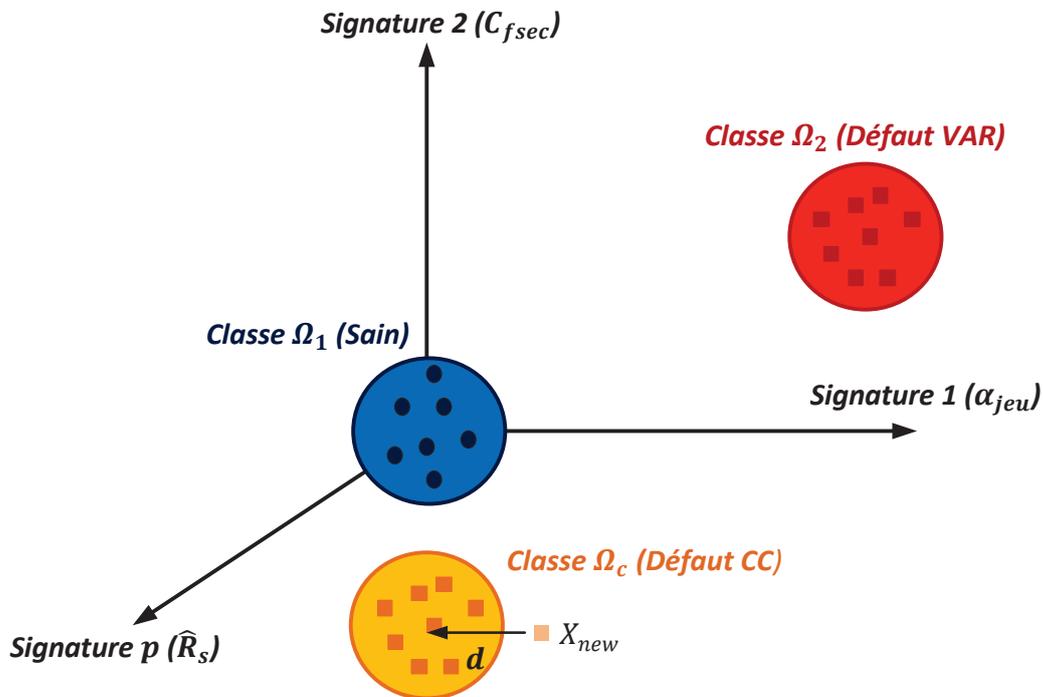


Figure III.1 : Principe de la RDF pour le diagnostic

Le statut de  $Y$  crée trois problématiques différentes, qui engendrent trois sous-familles d'algorithmes :

- ⇒ Lorsque l'ensemble des classes  $Y$  est connu, l'objectif est uniquement de trouver un modèle permettant d'attribuer les classes à des vecteurs inconnus. Il s'agit alors d'algorithmes supervisés permettant de faire de la classification.
- ⇒ Lorsque l'ensemble des classes  $Y$  est inconnu, l'objectif premier est de le déterminer. Il s'agit alors d'algorithmes non supervisés permettant de faire du partitionnement ou classification

*non supervisée*. Le partitionnement permet de déterminer les classes en regroupant les observations similaires selon un certain critère. Une fois les classes établies, l'attribution d'une classe à une nouvelle observation peut se faire soit directement, soit en combinant avec des méthodes supervisées.

⇒ Lorsque  $Y$  est partiellement connu, les algorithmes sont qualifiés de *semi-supervisés*.

Dans le cadre de nos problématiques pour le diagnostic, l'hypothèse suivante est faite :

### **Hypothèse 8 : Les classes des observations sont connues**

Les classes de toutes les observations des bases de données seront supposées connues. Les algorithmes présentés dans ce chapitre seront donc supervisés.

Afin de mieux cibler le type d'algorithme à utiliser vis-à-vis de nos problématiques, les grandes familles de méthodes de classification supervisée sont introduites au paragraphe suivant.

## **2.2 - Algorithmes de classification supervisée**

L'apprentissage automatique, de manière générale, est un domaine très vaste. Même dans le cas de la classification supervisée, une de ses plus anciennes branches, de nouveaux algorithmes sont produits tous les ans. Ainsi s'efforcer de faire une taxonomie exhaustive paraît difficile. Nous ne présenterons donc ici que les principales familles d'algorithmes en se basant sur la revue de **(Kotsiantis 2007)**. Il sera important de noter que ces familles ne représentent que les algorithmes de base, différents algorithmes étant souvent combinés pour aboutir à de meilleures performances.

### **2.2.a - Basés sur la logique**

Ces algorithmes reposent sur la logique. Parmi les plus utilisés, on compte les arbres de décision **(Rakotomalala 2005)**. Ce type d'algorithme consiste à construire un arbre où les nœuds représentent une condition binaire sur une signature, les branches, des intervalles de valeurs pour les signatures et les feuilles, les classes. L'avantage de cette solution est que ce n'est pas un outil type « boîte noire ». Les résultats peuvent être interprétés en suivant le chemin parcouru dans l'arbre, pour une observation donnée. Ce type d'algorithme fonctionne bien en général avec des variables discrètes ou qualitatives. Cependant, le fait d'analyser les variables séquentiellement rend cette solution moins robuste. En effet, pour de légères variations des signatures, par exemple dues à du bruit, les résultats peuvent être très différents. De plus, pour des systèmes très complexes, présentant de nombreux défauts différents, la lisibilité de l'arbre peut être très limitée. Malgré ces inconvénients, des cas d'applications d'arbre de décision pour le diagnostic existent. Dans **(Pomorski et Perche 2001)**, les arbres de décision sont utilisés pour isoler et diagnostiquer des défauts de machine asynchrone. Dans **(Saravanan et Ramachandran 2009)**, ils sont utilisés pour faire du diagnostic d'engrenages droits à pignons coniques.

Une autre forme d'algorithmes, basée sur la logique, repose sur un ensemble de règles du type « Si  $x_1 > 0$  et  $x_2 \leq 0$  Alors  $x$  est en Défaut 1 » **(Fürnkranz et al. 2012)**. Ce type de méthode est fréquemment combiné avec de la logique modale comme de la logique floue, notamment pour le

diagnostic médical (Farahani et al. 2015). Tout comme pour les arbres de décision, le net avantage de ce type de méthode est la traçabilité du cheminement logique conduisant au résultat. Le désavantage est la difficulté de mise en œuvre pour les problèmes de grande dimension.

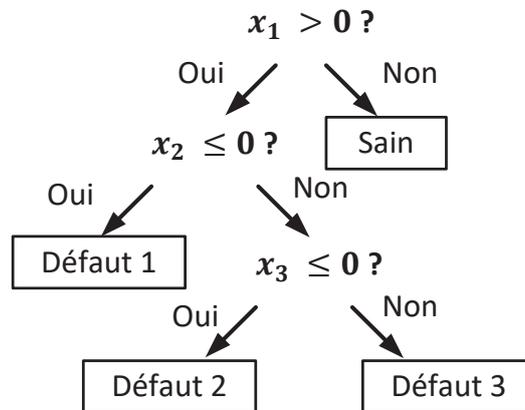


Figure III.2 : Exemple d'arbre de décision pour le diagnostic ( $x_{1..3}$  : signatures)

### 2.2.b - Basés sur des réseaux de neurones artificiels (RNA)

Les réseaux de neurones artificiels (RNA) sont inspirés d'un modèle de fonctionnement des neurones biologiques. L'idée est de combiner des éléments de calcul simples, des neurones, pour atteindre des performances importantes (Lippmann 1987). Un neurone est représenté par une fonction non - linéaire  $s$  à valeurs dans  $[0,1]$ . Cette fonction prend comme variable la somme des entrées  $e_i$ , chacune pondérée par un coefficient de poids  $wp_i$  (voir Figure III.3) ainsi qu'un biais  $\theta_{NN}$ . Différents types de fonctions sont possibles pour  $s$  : linéaire, sigmoïde, gaussienne .... La fonction  $s$  est appelée fonction d'activation ou fonction de seuillage. Dans le cadre du diagnostic, le vecteur d'entrée représentera le vecteur des signatures.

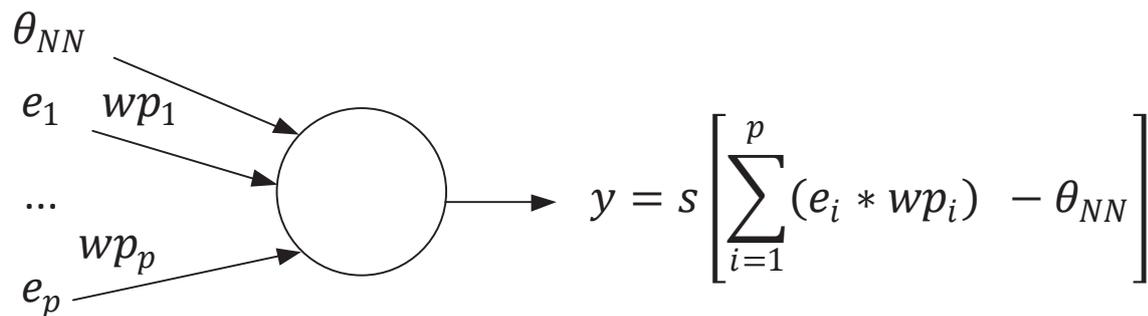


Figure III.3 : Représentation d'un neurone artificiel

La connexion de plusieurs neurones se fait au travers de successions de couches. On parle d'architecture d'un réseau. Une architecture donnée est caractérisée par son nombre de couches de neurones et le type de connexion entre ceux-ci. Les deux grands types de connexion sont par aval supervisé (feedforward), où l'information progresse uniquement du début vers la fin du réseau, et la connexion par rétro propagation (feedback) où des boucles de retour d'erreur sont présentes (Jain et al. 1996). En général, un réseau de neurones comporte : une couche d'entrée, une ou plusieurs

couches intermédiaires, une couche de sortie.

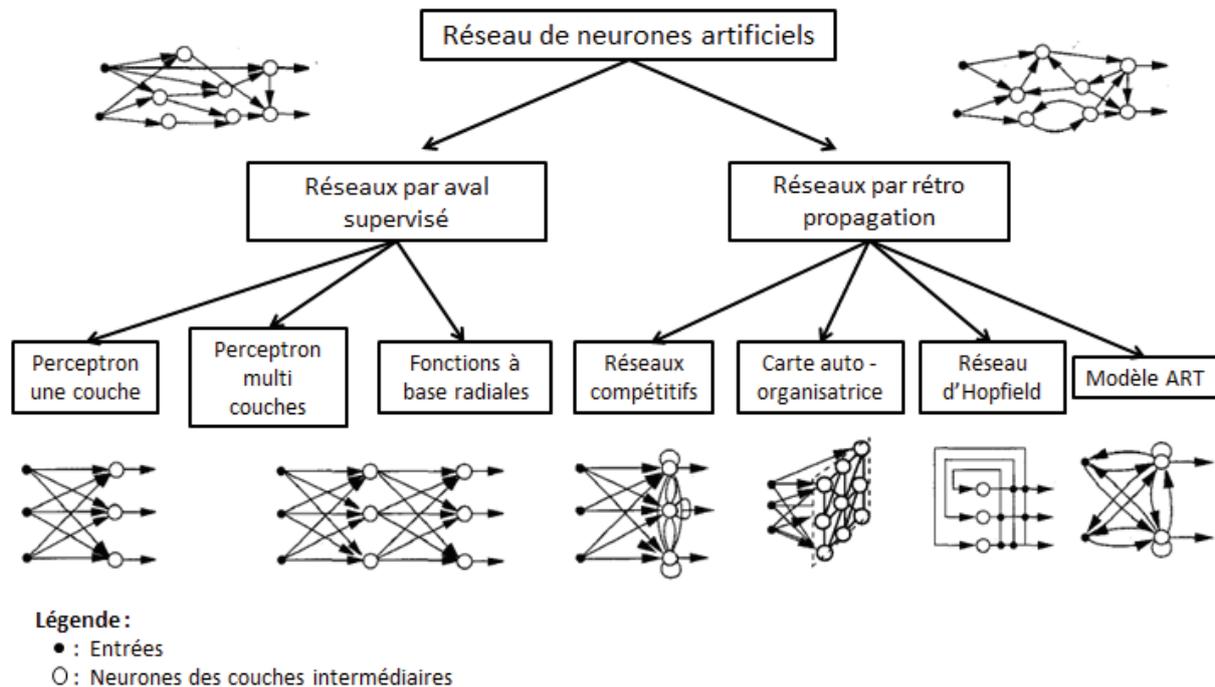


Figure III.4 : Taxonomie non exhaustive des réseaux de neurones (adaptée de (Jain et al. 1996) )

Un troisième grand groupe de réseaux est apparu ces dernières années avec l'augmentation des puissances de calcul et des données disponibles. Il s'agit des réseaux dits « profonds » qui sont constitués de nombreuses couches de neurones (Le 2015). Les premières versions de ce type de réseau comptent trois couches intermédiaires très fortement connectées entre elles (Hinton et al. 2006). Les versions les plus récentes comptent plusieurs centaines à un millier de couches intermédiaires (He et al. 2016).

Les avantages des RNA sont leur capacité à être très performants sur des bases de données présentant des corrélations fortement non linéaires, sans connaissance préalable d'experts. De plus il est possible de paralléliser les calculs. Les inconvénients sont que ce type d'algorithmes nécessite souvent d'importantes bases de données. De plus, il s'agit d'algorithmes « boîte noire ». Ainsi, il est très difficile de comprendre les « choix » effectués par ces RNA.

### 2.2.c - Basés sur les probabilités

Parmi les algorithmes probabilistes, la grande majorité peut se rapporter aux réseaux bayésiens (Barber 2012). Les réseaux bayésiens (RB) consistent à représenter le vecteur de forme comme un graphe acyclique dirigé. Les nœuds du graphe sont des variables aléatoires représentant les composantes du vecteur de forme (signatures de défaut) et les branches représentent les distributions de probabilités conditionnelles entre ces variables (Ben-Gal 2008; Barber 2012). Les RB suivants ressortent dans la littérature pour le diagnostic : les réseaux bayésiens naïfs, le réseau arborescent augmenté naïf, le réseau bayésien général (Cheng et Greiner 1999). Ces types de réseaux ont une structure imposée et nécessitent uniquement de calculer les probabilités conditionnelles à partir des données. Cette famille d'algorithmes peut également permettre de faire de l'extraction de signatures, du diagnostic et du pronostic. A noter également que les chaînes de Markov cachées, très utilisées en diagnostic, sont un cas particulier de réseau bayésien (Tobon-

Mejia et al. 2011; Medjaher et al. 2012).

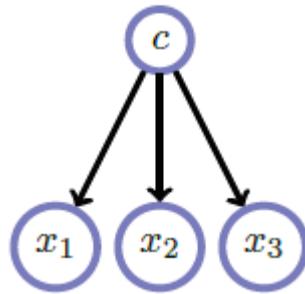


Figure III.5 : Illustration d'un réseau bayésien naïf ( $c$  : classe,  $x_{1,3}$  : signatures) (Barber 2012)

La famille des réseaux bayésiens est très large. Ainsi les avantages et les inconvénients varient d'une sous-famille à une autre. Néanmoins, le fait que ces méthodes soient interprétables, pour des réseaux relativement peu complexes, est un des avantages communs à ces familles. La difficulté de réglage et la quantité de données nécessaires, figurent fréquemment parmi les inconvénients.

### 2.2.d - Basés sur l'exemple

Ce type d'algorithmes est dit « fainéant » car il ne comprend pas d'étape d'apprentissage. La phase de test consiste à comparer directement la nouvelle observation aux exemples contenus dans la base (Aha et al. 1991; Kotsiantis 2007). Parmi cette famille d'algorithmes, le plus connu est celui des  $k$  – plus – proches – voisins (Cover et Hart 1967). Cet algorithme consiste à considérer que la classe d'une observation est celle la plus représentée parmi ses plus proches voisins. La notion de « proche » est représentée par une métrique de distance : les  $k$  points dont la distance à la nouvelle observation est la plus faible sont ces plus proches voisins.

L'avantage de ce type d'algorithme est de supprimer la phase d'apprentissage, ce qui réduit considérablement les coûts de calculs pour cette phase. L'autre avantage est leur relative simplicité. Leur principal inconvénient est de nécessiter une importante mémoire et puissance de calcul pour fonctionner en test.

### 2.2.e - Basés sur les noyaux

Ce type de méthodes repose sur la méthode du noyau (Aizerman et al. 1964). L'idée de cette méthode est de projeter les données depuis l'espace initial  $\mathcal{L}$  dans un espace euclidien  $\mathcal{H}$  de plus grande dimension, appelé espace de redescription, via la transformation non-linéaire :  $\Phi : \mathbb{R}^p \rightarrow \mathcal{H}$  (avec  $\dim(\mathcal{H}) \gg p$ ) (Burgess 1998; Muller et al. 2001). Cette transformation permet de déformer l'espace des paramètres pour rendre les données séparables linéairement comme illustré dans la Figure III.6. Les coûts de calculs peuvent exploser par l'utilisation de la projection. Or, Aizerman établit que tout produit vectoriel des projetés de deux vecteurs  $x$  et  $x'$  est égal à une fonction noyau tel que :

$$(III.1) \quad K(x, x') = \Phi(x) \cdot \Phi(x')$$

Où  $\Phi(x)$  désigne la fonction de projection et  $K$  la fonction noyau.

Cette fonction représente une mesure de similarité des deux observations (Hofmann et al. 2008). Elle permet de travailler sur les projetés des observations plutôt que sur les observations elles – même. Des fonctions noyaux classiquement utilisées sont données au Tableau III.1.

Nom	Expression
Linéaire	$K(x, x') = x \cdot x'$
Polynomiale de degré $dp$	$K(x, x') = (1 + x \cdot x')^{dp}$
Gaussien (fonction à base radiale) ( $\sigma$ : paramètre)	$K(x, x') = e^{-\frac{\ x-x'\ ^2}{2\sigma^2}}$
Sigmoïde ( $a_K, b_K$ : paramètres)	$K(x, x') = \tanh(a_K \cdot x \cdot x' + b_K)$

Tableau III.1: Exemples de fonctions noyaux

Tout l’avantage de la méthode réside dans le fait qu’il n’est pas nécessaire de connaître la fonction de projection  $\Phi$  explicitement. De plus, les fonctions noyaux sont en général relativement simples, avec peu de paramètres à régler. Toute fonction noyau devra être continue, symétrique et définie semi-positive. D’autres manières de formuler ces conditions sont de dire que la fonction doit respecter le théorème de Mercer (Vapnik 1995) ou encore que la matrice noyau, issue de l’application de la fonction sur l’ensemble de la base de données, soit définie semi-positive et symétrique.

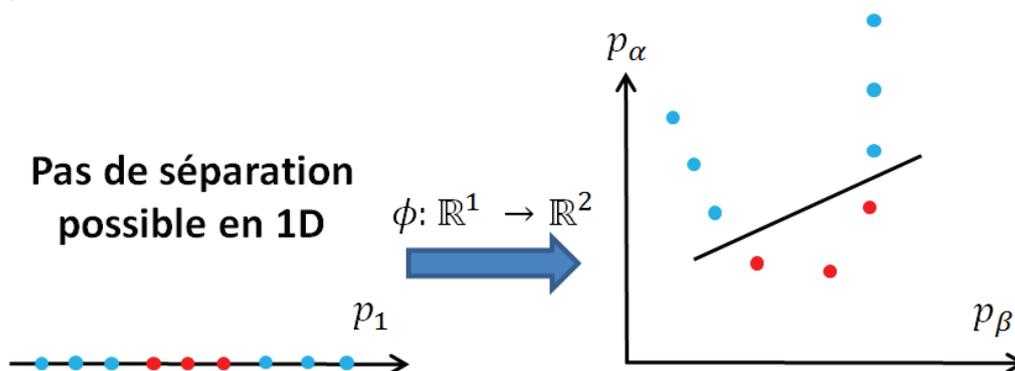


Figure III.6 : Exemple de projection dans un espace de dimension supérieure

L’algorithme à base de noyau le plus connu est les machines à vecteur de supports (*support vector machine* : SVM). Il consiste à calculer un hyperplan optimal entre deux classes d’observations (Vapnik 1995; Burges 1998). L’idée est de maximiser la distance entre les observations et l’hyperplan. Pour le cas de la classification multi-classes, différentes techniques existent. Le principe de base de celles-ci est de se ramener au cas binaire en partitionnant les données de différentes manières. Néanmoins, leur principal inconvénient est d’être un outil de type boîte noire. Ces algorithmes ont la réputation de donner des résultats très robustes.

## 2.3 - Choix d’une famille d’algorithmes

Pour rappel, notre première problématique (voir Problématique 1 page 40) est la robustesse des algorithmes, sous contraintes des temps de calculs et de la mémoire nécessaire. L’interprétabilité sera également prise en compte, dans un second temps.

Les méthodes à base de logique offrent l’avantage de l’interprétabilité. Elles sont cependant trop

limitées vis-à-vis des dimensions nécessaires pour le cas du diagnostic d'un EMA. Les méthodes par réseaux de neurones pourraient être un candidat intéressant, notamment avec les progrès récents en temps-réel. Cependant, ces algorithmes se montrent parfois peu robustes et ne sont pas toujours aisés à paramétrer. De plus, ils peuvent présenter des coûts de calculs importants. Les méthodes par réseaux bayésiens montrent les mêmes inconvénients. Les méthodes basées sur des exemples sont écartées à cause de la mémoire et de la puissance de calcul nécessaire. Ainsi, la famille des machines à vecteurs de support est un candidat naturel pour répondre à nos problématiques. Un couplage avec les méthodes à base de logique, pour gagner en interprétabilité, sera investigué.

## 3 - Machine à vecteurs de support (SVM)

### 3.1 - SVM et risque

Un élément central de tout algorithme d'apprentissage automatique est la fonction perte ou fonction erreur (**Domingos 2012**). Cette fonction mesure l'erreur de l'algorithme sur sa base d'apprentissage. Elle est choisie par l'utilisateur. Elle prend comme variable d'entrée la fonction de prédiction de la classe d'une observation  $f(x, \alpha)$ , avec  $\alpha$  : vecteur de paramètres de la fonction, et le label  $y$  de cette même observation. La fonction perte calculée sur une observation quelconque  $x$  est alors notée  $L[f(x, \alpha), y]$  (**Vapnik 1999**). Parmi les fonctions pertes classiques, peuvent être citées : la valeur absolue de la différence  $|f(x, \alpha) - y|$ , le carré de la différence... Pour le reste du mémoire, la fonction perte pour la classification supervisée sera (**Vapnik 1999**):

$$(III.2) \quad L[f(x, \alpha), y] = \begin{cases} 0 & \text{si } y = f(x, \alpha) \\ 1 & \text{si } y \neq f(x, \alpha) \end{cases}$$

L'erreur d'un algorithme ayant effectué son apprentissage (machine entraînée), nommée également risque attendu ou actuel, est définie comme l'espérance de la fonction perte :

$$(III.3) \quad R(\alpha) = \int L[f(x, \alpha), y] d\mathbb{P}(x, y)$$

Avec  $\mathbb{P}(x, y)$  : distribution de probabilité jointe. Le risque empirique caractérise la perte moyenne sur une base de données  $(X, Y)$  :

$$(III.4) \quad R_{emp}(\alpha) = \frac{1}{2m} \sum_{i=1}^m L[f(X_i, \alpha), Y_i]$$

Avec  $m$  nombre d'observations.

Enfin, soit  $\eta \in [0,1]$  une valeur fixée : la limite supérieure du risque actuel, avec une probabilité de  $1-\eta$  est définie par (**Burges 1998**) :

$$(III.5) \quad R(\alpha) \leq R_{emp}(\alpha) + A, \text{ avec } A = \sqrt{\frac{h(\log(\frac{2m}{h})+1) - \log(\frac{\eta}{4})}{m}}$$

La dimension de Vapnik-Chervonenkis (VC), notée  $h$ , est un entier positif qui représente une propriété d'un ensemble de fonctions  $F = \{f(x, \alpha)\}$ , ensemble correspondant à un modèle de

classification entraînée. Pour le cas d'une classification binaire ( $f(x, \alpha) \in \{-1, 1\} \forall x \in X$ ) : si  $m$  observations, pouvant être classifiées de  $2^m$  manières différentes, sont considérées, et si une fonction  $f(x, \alpha) \in F$ , qui assigne correctement tous les labels, peut être déterminée, alors l'ensemble des points est dit *pulvérisé* par l'ensemble  $F$ . Une autre manière de représenter la dimension VC pour un ensemble  $F$ , est de la définir comme le nombre maximum d'observations pouvant être pulvérisées par  $F$ . Cette grandeur est représentative de la complexité de  $F$  ainsi que de sa capacité à généraliser. De plus, elle permet de montrer que les observations peuvent être pulvérisées (classées) par des hyperplans (**Burges 1998**). Une forte valeur de VC n'implique toutefois pas forcément un grand nombre de paramètres comme le montre (**Burges 1998**) avec une fonction à un paramètre et à VC infini.

La confiance VC, notée  $A$ , est une fonction croissante de  $h$ , quel que soit le nombre d'observations ( $m$ ). Pour un algorithme ayant un risque empirique non nul, il faudra donc s'efforcer de minimiser  $A$  et donc de limiter  $h$  (**Burges 1998**). Cela revient à limiter la complexité du modèle. Ainsi ce compromis entre le risque et la dimension VC s'avère finalement assez semblable au compromis biais/variance évoqué pour les problèmes d'apprentissage automatique (**Geman et al. 1992; Domingos 2000; Valentini et al. 2004; Vijayakumar et al. 2005**). Cependant là où la grande majorité des algorithmes de classification cherche à minimiser le risque empirique, les algorithmes par SVM cherchent eux à minimiser la limite supérieure du risque actuel. C'est cela qui explique la plus grande robustesse de cette famille d'algorithmes. Ce principe de minimisation du risque actuel est parfois nommé « minimisation du risque structurel » (*SRM : Structural Risk Minimization*).

Ainsi les algorithmes par SVM, utilisés dans le cadre de la classification supervisée, apprennent un ensemble de fonctions  $F = \{f(x, \alpha)\}$  avec pour objectif de minimiser la limite du risque. Nous allons maintenant voire comment cela fonctionne pour des données représentant deux classes séparables linéairement.

## 3.2 - SVM binaire linéaire

### 3.2.a - Cas séparable

On suppose l'existence d'un hyperplan qui sépare les exemples positifs ( $y = 1$ ) des négatifs ( $y = -1$ ). Les points reposant sur cet hyperplan vérifient :

$$(III.6) \quad \omega x + b = 0$$

Où  $\omega$  est un vecteur normal à l'hyperplan ( $\in \mathbb{R}^p$ ),  $|b|/\|\omega\|$  la distance perpendiculaire entre l'hyperplan et l'origine,  $b$  le biais ( $\in \mathbb{R}$ ) et  $\|\omega\|$  la norme euclidienne de  $\omega$ . On pose  $d_+$  et  $d_-$  les plus courtes distances entre le plan et l'exemple le plus proche, respectivement positive pour  $d_+$  et négative pour  $d_-$ . La marge est définie par :

$$(III.7) \quad mg = d_+ + d_-$$

L'objectif de l'algorithme par SVM sera de trouver l'hyperplan maximisant cette marge. Toutes les observations sont supposées vérifier  $Y_i(\omega X_i + b) \geq 0$  (Où  $i \in \{1, \dots, m\}$  indice des observations). Les hyperplans parallèles  $H_1$  et  $H_2$  sont définis par :

$$(III.8) \quad \begin{aligned} H_1 &: \forall x \in X \text{ tel que } \omega x + b = 1 \\ H_2 &: \forall x \in X \text{ tel que } \omega x + b = -1 \end{aligned}$$

Les points reposant sur ces deux hyperplans sont appelés **vecteurs supports**. Ce sont eux qui caractérisent l'hyperplan séparateur et donc le modèle SVM entraîné. On peut donc maintenant définir la marge par :

$$(III.9) \quad mg = \frac{1}{\|\omega\|} + \frac{1}{\|\omega\|} = \frac{2}{\|\omega\|}$$

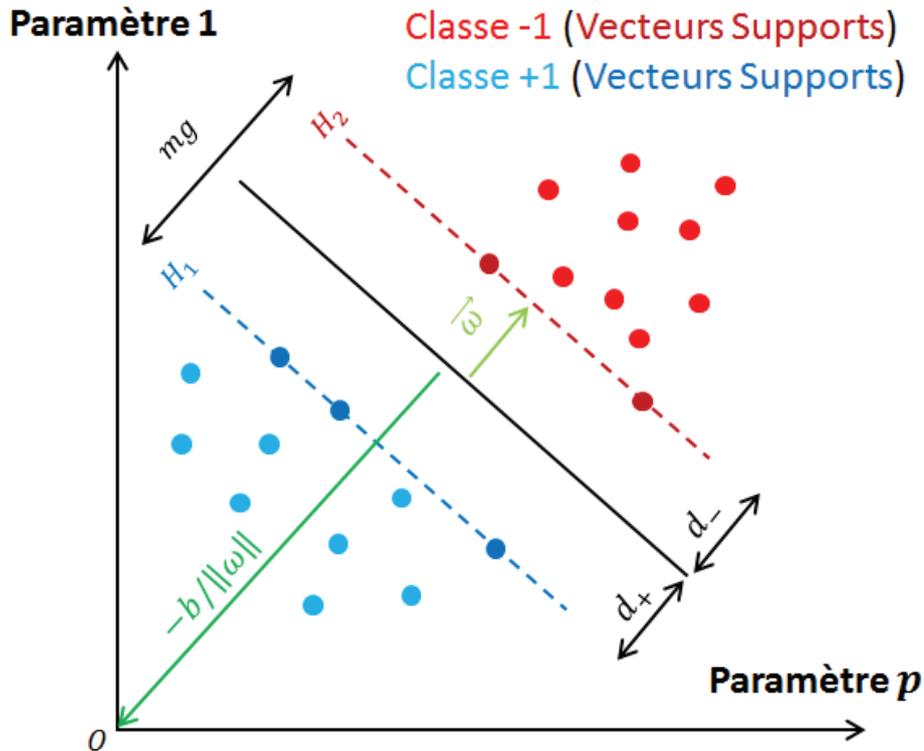


Figure III.7 : Illustration de l'application de la SVM pour un cas binaire linéaire séparable

La maximisation de la marge peut donc se faire en minimisant  $\|\omega\|^2$ . Pour que les données d'apprentissage apparaissent dans la formulation du problème comme des produits de vecteurs, le problème est formulé de manière Lagrangienne (**Burges 1998**). Les multiplicateurs de Lagrange  $\alpha_i$  ( $i \in m$ ) sont ainsi définis. La fonction coût à minimiser est donnée par le Lagrangien primal du problème :

$$(III.10) \quad L_P = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^m \alpha_i Y_i (X_i \omega + b) - \sum_{i=1}^m \alpha_i$$

Cette fonction objective à minimiser par rapport à  $\omega$  et  $b$ , étant convexe et l'ensemble des points vérifiant les contraintes formant un ensemble convexe, il s'agit donc d'un problème d'optimisation convexe. La solution trouvée sera donc un optimum global. Les paramètres à déterminer par résolution du problème d'optimisation sont les  $\alpha_i$  et le biais  $b$ . Le problème peut être exprimé sous forme duale. Cela nécessite l'annulation du gradient de  $L_P$  ce qui donne les conditions suivantes :

$$(III.11) \quad \sum_{i=1}^m \alpha_i Y_i = 0 \quad \forall i \in \{1, \dots, m\}$$

$$\omega = \sum_{i=1}^m \alpha_i Y_i X_i$$

En remplaçant dans l'équation de  $L_p$  cela donne la fonction objective suivante, à maximiser :

$$(III.12) \quad L_D = \sum_{i=1}^m \alpha_i - \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j Y_i Y_j X_i X_j$$

Sous les contraintes :

$$(III.13) \quad \alpha_i \geq 0 \quad \forall i \in \{1, \dots, m\}$$

$$\sum_{i=1}^m \alpha_i Y_i = 0$$

Cette fonction est une fonction quadratique. Ainsi l'ensemble des algorithmes d'optimisation permettant de résoudre ce genre de problèmes est utilisable (Nocedal et Wright 1999; Kruth 2008). C'est l'algorithme par programmation quadratique successive (*Sequential Quadratic Optimization : SQP*), présentant les meilleures performances en termes de temps de convergence, qui a été choisi dans ces travaux de thèse (Boggs et Tolle 1996). L'algorithme d'optimisation donnera donc les  $\alpha_i$  optimum. Ceux – ci seront notés  $\alpha_{opt_i}$ . A noter que les points pour lesquels  $\alpha_{opt_i} > 0$  sont les vecteurs supports (Les points reposant sur ces deux plans  $H_1$  et  $H_2$ ). Pour les autres points  $\alpha_{opt_i} = 0$ . Une fois les multiplicateurs de Lagrange obtenus, le calcul du biais se fait en calculant la fonction de prédiction sur les vecteurs supports. Pour un vecteur support  $S$ , de classe  $y_S$  on aura :

$$(III.14) \quad b = y_S - \sum_{i=1}^{N_S} \alpha_{opt_i} Y_i S_i S$$

En notant  $S_i$ , les vecteurs supports issus de la base d'apprentissage et  $N_S$  : le nombre de vecteurs supports.

La fonction discriminante peut être exprimée par :

$$(III.15) \quad f(x, \alpha_{opt_i}) = \text{signe}\{\omega x + b\}$$

Pour classifier une nouvelle observation  $x_{new}$ , le signe de la fonction discriminante sera analysé. La classe estimée sera notée  $\hat{y}_{new}$ .

$$(III.16) \quad \omega x_{new} + b \geq 0 \Rightarrow \hat{y}_{new} = f(x_{new}, \alpha_{opt_i}) = +1$$

$$\omega x_{new} + b < 0 \Rightarrow \hat{y}_{new} = f(x_{new}, \alpha_{opt_i}) = -1$$

### 3.2.b - Cas non séparable

Il peut arriver que tous les points de la base ne soient pas séparables via un hyperplan linéaire. Il faut donc introduire une tolérance aux erreurs. Cela se fait par l'ajout de variables d'ajustement  $\xi_i$  aux contraintes pour créer des « marges souples », tolérant les mauvais classements (voir Figure III.8). Ces variables prennent différentes valeurs en fonction de la position des observations mal classifiées, comme illustré à la Figure III.8.

$$(III.17) \quad \begin{aligned} (X_i \omega + b) &\geq +1 - \xi_i \text{ pour } Y_i = +1 \\ (X_i \omega + b) &\leq -1 + \xi_i \text{ pour } Y_i = -1 \\ \xi_i &\geq 0 \forall i \in \{1, \dots, m\} \end{aligned}$$

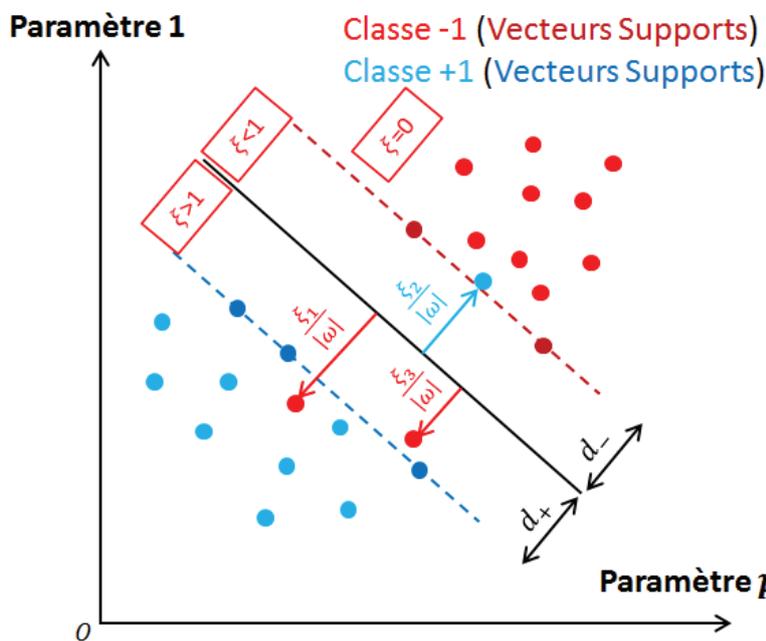


Figure III.8 : Illustration de l'application de la SVM pour un cas binaire linéaire non séparable

Pour inclure cette variable dans le problème d'optimisation, on change la fonction objective par :

$$(III.18) \quad L = \frac{1}{2} \|\omega\|^2 + C (\sum_i \xi_i)^{k_{eps}}$$

Où  $C$  est un paramètre choisi représentant la tolérance aux exemples mal classés. Plus  $C$  est grand plus la pénalité sur les erreurs sera importante. Il s'agit d'un problème d'optimisation convexe pour tout  $k_{eps} \in \mathbb{N}$ . Si on choisit  $k_{eps} = 1$ , la fonction objective s'exprime de manière simplifiée par :

$$(III.19) \quad L_D = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j Y_i Y_j X_i X_j$$

Sous les contraintes :

$$(III.20) \quad \begin{aligned} 0 \leq \alpha_i \leq C \quad \forall i \in \{1, \dots, m\} \\ \sum_{i=1}^m \alpha_i Y_i = 0 \end{aligned}$$

Le calcul des multiplicateurs de Lagrange se fait toujours via l'algorithme SQP. Le calcul du biais se fait toujours via (III.14). Le test d'une nouvelle observation se fait toujours selon (III.16).

### 3.3 - SVM binaire non linéaire

L'application de l'algorithme de SVM à des données non séparables linéairement se fait via l'astuce du noyau (voir 2.2.e - Basés sur les noyaux à la page 81). Une fois choisie, une fonction noyau  $K$  l'expression de la fonction objective duale devient :

$$(III.21) \quad L_D = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j Y_i Y_j K(X_i, X_j)$$

Cette fonction est une fonction quadratique. On peut donc également utiliser l'algorithme SQP. Une fois les multiplicateurs de Lagrange obtenus, le calcul du biais se fait via la même méthodologie que pour les cas linéaires. Pour un vecteur support  $S$ , de classe  $y_S$  on aura :

$$(III.22) \quad b = y_S - \sum_{i=1}^{N_S} \alpha_{opt_i} Y_i K(S_i, S)$$

La classification d'une nouvelle observation  $x_{new}$  se fait maintenant avec

$$(III.23) \quad \hat{y}_{new} = f(x_{new}, \alpha) = \text{signe} \left\{ \sum_{i=1}^{N_S} \alpha_{opt_i} Y_i K(S_i, x_{new}) + b \right\}$$

Les différents types de SVM explicités précédemment ne sont applicables que pour des cas avec deux classes distinctes, pour des cas dits binaires. Nous allons maintenant voir différentes manières d'utiliser ces méthodes pour réaliser une classification multi-classes.

### 3.4 - SVM multi-classes

Le principe général pour étendre les techniques SVM au cas multi-classes reste toujours le même. Il consiste à entraîner plusieurs modèles SVM binaires en partitionnant les données différemment à chaque fois. Lors des phases de test, les différentes fonctions discriminantes obtenues sont combinées. Trois grandes méthodes de combinaisons existent : la « Une classe contre toutes » (*One vs All : OVA*), la « Une classe contre une » (*One vs One : OVO*) et la « Une classe vers les autres » (*One to Others : OTO*).

#### 3.4.a - Un contre tous : « One Vs All » (OVA)

Le principe de cette méthode est de considérer successivement une classe contre toutes les autres. Elle offre un bon compromis performances / temps de calcul. Pour  $c$  classes, l'apprentissage se fera

selon le pseudocode suivant :

Algorithme 2 : "One Vs All" - Apprentissage
<p>Pour <math>j = 1</math> à <math>c</math></p> <p>Classe <math>j</math> versus les autres :</p> <p>Définition d'un nouveau vecteur des labels <math>Y^{(j)}</math></p> $Y_i = j : \begin{cases} \text{Vrai} \Rightarrow Y_i^{(j)} = +1 \\ \text{Faux} \Rightarrow Y_i^{(j)} = -1 \end{cases} \forall i \in \{1, \dots, m\}$ <p>Apprentissage d'un modèle SVM binaire sur le couple <math>(X, Y^{(j)})</math></p> <p>Sauvegarde des paramètres de la fonction discriminante <math>f^{(j)}(x, \alpha^{(j)})</math></p> <p>Fin Pour</p>

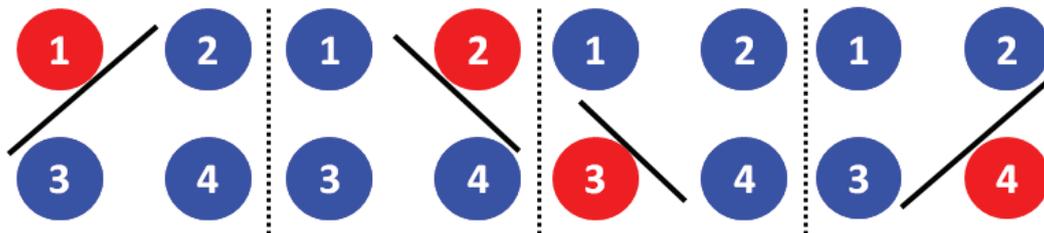


Figure III.9 : Algorithme "One Vs All" pour  $c = 4$

La classification d'une nouvelle observation  $x_{new}$  s'effectue en calculant les fonctions discriminantes de chaque classificateur binaire et en recherchant la fonction discriminante maximale et la classe associée. Le pseudocode suivant explicite cette démarche.

Algorithme 3 : "One Vs All" - Test	
(1)	<p><b>Calcul des fonctions discriminantes</b></p> <p>Pour <math>j = 1</math> à <math>c</math></p> <p style="padding-left: 40px;">Calcul de <math>f^{(j)}(x_{new}, \alpha^{(j)})</math></p> <p>Fin Pour</p>
(2)	<p><b>Trouver la classe maximisant la fonction discriminante</b></p> $\hat{y}_{new} = \underset{j \in \{1, \dots, c\}}{\operatorname{argmax}} \{f^{(j)}(x_{new}, \alpha^{(j)})\}$

### 3.4.b - Un contre Un : « One Vs One » (OVO)

Il s'agit ici de considérer une classe contre une autre. Le nombre d'itérations sera donc de  $c \frac{c-1}{2}$ , ce qui correspondra à l'apprentissage de  $c \frac{c-1}{2}$  classifieurs binaires. Pour un nombre de classes élevé, le coût de calcul sera donc plus élevé que pour la méthode « One Vs All » qui elle ne nécessite d'apprendre que  $c$  classifieurs binaires. Néanmoins les performances de cette méthode, en termes de précision, sont parfois plus élevées. L'apprentissage se fait selon le pseudocode suivant, illustré pour  $c = 4$  à la Figure III.10 :

**Algorithme 4 : "One Vs One" - Apprentissage**

Pour  $j = 1$  à  $c - 1$

Pour  $k = j + 1$  à  $c$

Définition d'un nouveau vecteur des labels  $Y^{(jk)}$

$$Y_i = j \Rightarrow Y_i^{(jk)} = +1$$

$$Y_i = k \Rightarrow Y_i^{(jk)} = -1$$

$$Y_i \neq j \text{ et } Y_i \neq k \Rightarrow Y_i^{(jk)} = 0$$

Apprentissage d'un modèle SVM binaire sur le couple  $(X, Y^{(jk)})$

Sauvegarde des paramètres de la fonction discriminante  $f^{(j)}(x, \alpha^{(jk)})$

Fin Pour

Fin Pour

Pour une nouvelle observation  $x_{new}$ , les fonctions discriminantes de chaque classificateur binaire sont calculées. Puis, pour chaque classe, la somme des fonctions discriminantes, pondérée par +1 quand la classe est du côté +1 et par -1 quand la classe est du côté -1 est évaluée. Le pseudocode suivant formalise ce processus :

**Algorithme 5 : "One Vs One" – Test**

**(1) Calcul des fonctions discriminantes**

Pour  $j = 1$  à  $c - 1$

Pour  $k = j + 1$  à  $c$

Calcul de  $f^{(jk)}(x_{new}, \alpha^{(jk)})$

Fin Pour

Fin Pour

(2) Calcul des sommes pondérées des fonctions discriminantes  $F^{(l)}$

Pour  $l = 1$  à  $c$

$$F^{(l)}(x_{new}) = 0$$

Pour  $j = l$  à  $c - 1$

Pour  $k = j + 1$  à  $c$

Classe  $l$  du coté +1  $\rightarrow \delta_{jk} = +1$

Classe  $l$  du coté -1  $\rightarrow \delta_{jk} = -1$

$$F^{(l)}(x_{new}) = F^{(l)}(x_{new}) + \delta_{jk} f^{(jk)}(x_{new}, \alpha^{(jk)})$$

Fin Pour

Fin Pour

Fin Pour

(3) Trouver la classe maximisant la fonction discriminante

$$\hat{y}_{new} = \operatorname{argmax}_{l \in \{1, \dots, c\}} \{F^{(l)}(x_{new})\}$$

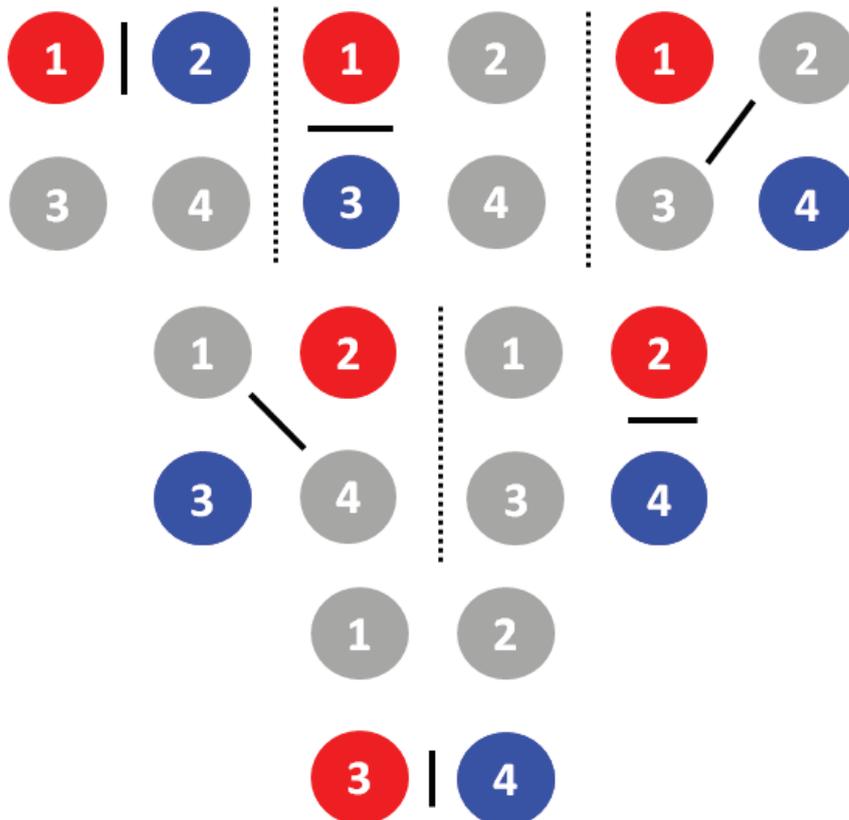


Figure III.10 : Algorithme "One Vs One" pour  $c = 4$

### 3.4.c - Un pour les Autres : « One To Others » (OTO)

Cette méthode consiste en un arbre de décision où chaque nœud est constitué d'une SVM binaire (Cheong et al. 2004). Elle permet de réduire les temps d'apprentissage et de test. De plus, cela permet de hiérarchiser les classes, les premières traitées étant souvent mieux classifiées que les dernières. Dans le cadre du diagnostic, cela peut permettre de hiérarchiser les défauts selon leur criticité. La phase d'apprentissage est décrite par le pseudocode suivant :

**Algorithme 6 : "One To Others" - Apprentissage**

Pour  $j = 1$  à  $c$

Définition d'un nouveau vecteur des labels  $Y^{(j)}$

$$Y_i = j : \begin{cases} \text{Vrai} \Rightarrow Y_i^{(j)} = +1 \\ \text{Faux} \Rightarrow Y_i^{(j)} = -1 \end{cases} \quad \forall i \in \{1, \dots, m\}$$

Apprentissage d'un modèle SVM binaire sur le couple  $(X, Y^{(j)})$

Sauvegarde des paramètres de la fonction discriminante  $f^{(j)}(x, \alpha^{(j)})$

Suppression des points pour lesquels  $Y_i^{(j)} = +1$

Fin Pour

Une illustration est donnée à la Figure III.11

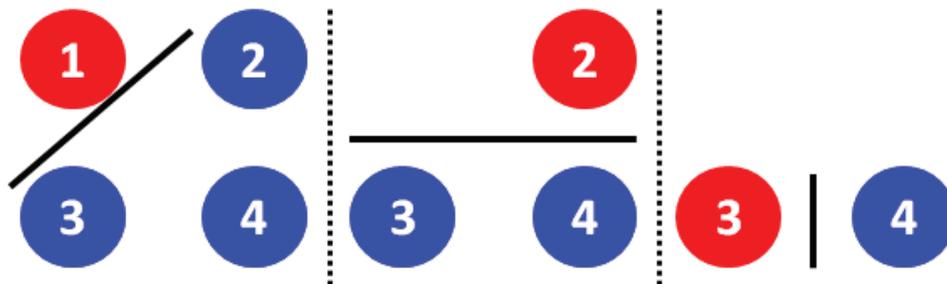


Figure III.11 : Algorithme "One To Others" pour  $c = 4$

Classifier une nouvelle observation  $x_{new}$  se fait de la même manière que pour la méthode « One Vs All », mais en s'arrêtant dès que l'on trouve une fonction discriminante positive. Le pseudocode suivant détaille ceci :

**Algorithme 7 : "One To Others" - Test**

(1) **Initialisation**

$$\hat{y}_{new} = 0$$

$$j = 1$$

**(2) Evaluation des fonctions discriminantes et classification**Tant que  $\hat{y}_{new} = 0$  ouCalcul de  $f^{(j)}(x_{new}, \alpha^{(j)})$ Si  $f^{(j)}(x_{new}, \alpha^{(j)}) > 0$   
 $\hat{y}_{new} = j$ Sinon  
 $j = j + 1$ 

Fin Si

Fin Tant que

## 4 - SVM et fonctions d'appartenance

### 4.1 - Rappels sur la théorie du flou

#### 4.1.a - Fondements

Les fondements de la théorie du flou viennent des travaux de Lotfi Zadeh sur les ensembles flous (**Zadeh 1965**). De ces travaux ont découlé de nombreux autres : la logique floue, la mesure floue, la théorie des possibilités .... Les outils issus du flou sont d'un usage courant dans l'apprentissage automatique et dans la classification (**Kruse et al. 1999; Hüllermeier 2005**). Le fondement de la théorie des ensembles flous porte sur la fonction d'appartenance d'un élément  $x$  à un ensemble  $C$ . En théorie des ensembles classiques, celle-ci est exprimée par :

$$(III.24) \quad u_C(x) : x \rightarrow \{0,1\}$$

Cette fonction prend donc deux valeurs : 0 ou 1. En théorie des ensembles flous, la fonction d'appartenance est exprimée par :

$$(III.25) \quad u_C(x) : x \rightarrow [0,1]$$

Ici, les valeurs possibles sont infinies. Ceci permet de créer une graduation qui peut notamment être interprétée comme un degré de confiance. De nombreux types de fonctions d'appartenances sont possibles : trapézoïdales, polynomiales, sigmoïdales... Dans le cadre de la classification,  $C$  représentera une classe et  $x$  une observation.

#### 4.1.b - Opérateurs d'agrégations

Un des avantages du cadre formel des fonctions d'appartenance flous réside dans le fait qu'elles peuvent être combinées via l'utilisation de normes triangulaires (**Gupta et Qi 1991; Zalila 1993**). On distinguera les T-normes, équivalentes à une intersection pour les ensembles classiques, des T-conormes, équivalentes à une union. Les premières seront notées T et les secondes  $\perp$ . On notera  $\varphi$

une norme quelconque (T-norme ou T-conorme).

(III.26)  $\varphi: [0,1] \times [0,1] \rightarrow [0,1]$

Toute norme devra vérifier les propriétés suivantes,  $\forall r_1, r_2, r_3 \in [0,1]$

- ⇒ Commutativité :  $\varphi(r_1, r_2) = \varphi(r_2, r_1)$
- ⇒ Associativité :  $\varphi(r_1, \varphi(r_2, r_3)) = \varphi(\varphi(r_1, r_2), r_3)$
- ⇒ Non décroissance par rapport à chaque variable :  $r_2 \leq r_3 \Rightarrow \varphi(r_1, r_2) \leq \varphi(r_1, r_3)$
- ⇒ Élément neutre  $e$  :  $\varphi(r_1, e) = r_1$  (T-norme :  $e = 1$ , T-conorme :  $e = 0$ )

Des exemples de normes sont donnés au tableau suivant. Des illustrations sont également données en annexes pour chaque norme (Annexe VIII7 - page 225). A noter que deux normes sur la même ligne sont dites duales :

Nom	T-norme	T-conorme
Max - Min	$\min(r_1, r_2)$	$\max(r_1, r_2)$
Probabiliste	$r_1 * r_2$	$r_1 + r_2 - r_1 * r_2$
Lukasiewicz	$\max(0, (r_1 + r_2 - 1))$	$\min(1, (r_1 + r_2))$
Einstein	$\frac{r_1 * r_2}{1 + (1 - r_1) * (1 - r_2)}$	$\frac{r_1 + r_2}{1 + r_1 * r_2}$

Tableau III.2: Exemples de normes triangulaires

### 4.1.c - Fusion d'informations floues

Un opérateur d'agrégation d'informations est une application permettant de fusionner  $c$  informations en une, via une norme  $\varphi$ . Pour un ensemble d'observations rassemblées au sein d'une matrice, l'opérateur sera noté par :

(III.27)  $\psi: M_{m,c}(\mathbb{R}) \mapsto M_{m,1}(\mathbb{R})$

$$\begin{bmatrix} r_{11} & \dots & r_{1c} \\ \vdots & \ddots & \vdots \\ r_{m1} & \dots & r_{mc} \end{bmatrix} \mapsto \begin{bmatrix} \varphi(r_{11}, \varphi(r_{12}, \varphi(r_{13}, \dots \varphi(r_{1(c-1)}, r_{1c})))) \\ \vdots \\ \varphi(r_{m1}, \varphi(r_{m2}, \varphi(r_{m3}, \dots \varphi(r_{m(c-1)}, r_{mc})))) \end{bmatrix}$$

Où  $m$  désignera le nombre d'observations.

Pour que l'opérateur  $\psi$  fonctionne correctement, il faut que la norme ait les propriétés suivantes :

- ⇒ Commutativité :  $\varphi(r_1, r_2) = \varphi(r_2, r_1)$
- ⇒ Associativité :  $\varphi(r_1, \varphi(r_2, r_3)) = \varphi(\varphi(r_1, r_2), r_3)$

Ces deux propriétés sont vérifiées pour toutes les T-normes et T-conormes. Ces deux types de normes permettront de construire les opérateurs de fusion d'information nécessaires.

### 4.1.d - Complémentation

Le complément  $\mathcal{C}$ , parfois appelé négation floue, est un opérateur vérifiant les axiomes suivants (Zadeh 1965; Ferri et al. 1999) :

- ⇒ Conditions aux frontières :  $\mathcal{C}(0) = 1$  et  $\mathcal{C}(1) = 0$
- ⇒ Monotonie :  $r_1 \leq r_2 \Leftrightarrow \mathcal{C}(r_1) \geq \mathcal{C}(r_2)$
- ⇒ Continuité :  $\mathcal{C}$  est continu
- ⇒ Involution:  $\forall r_1 \in [0,1] : \mathcal{C}(\mathcal{C}(r_1)) = r_1$

Différentes complémentations existent. Dans le cadre de ces travaux de thèse la complémentation utilisée sera la complémentation à 1 :

$$(III.28) \quad \mathcal{C}(r_1) = 1 - r_1$$

Le paragraphe suivant montrera comment utiliser toutes les notions sur le flou pour améliorer la SVM.

## 4.1 - SVM floue binaire

L'introduction des fonctions d'appartenance (FA) doit permettre d'introduire une graduation dans l'appartenance aux classes. Cela doit se faire sans trop augmenter les coûts de calcul et la mémoire nécessaire. De plus, il faut s'efforcer de conserver, à minima, les performances de la SVM en termes de robustesse. Pour ce faire, nous proposons de calculer les FA à partir de la distance à l'hyperplan  $d_x$  d'une observation  $x$ . Ainsi, les conditions suivantes sont imposées aux fonctions d'appartenance :

- ⇒ La fonction d'appartenance de la classe +1,  $u_+$ , est symétrique par rapport à l'hyperplan à celle de la classe -1, notée  $u_-$ . Cela permet d'éviter un déséquilibre d'une classe par rapport à une autre.
- ⇒ Les deux fonctions représentent une partition floue forte de l'ensemble des distances à l'hyperplan possible. On aura donc  $u_+(d_x) + u_-(d_x) = 1, \forall d_x$  et avec  $u_-(d_x) \in [0,1], u_+(d_x) \in [0,1]$  Cela permet d'éviter des déséquilibres sur l'intervalle des distances des observations à l'hyperplan.
- ⇒ Le degré d'appartenance des vecteurs supports est noté  $\gamma \in ]0.5,1]$ . Celui-ci représente la confiance dans la qualité des données d'apprentissage. Plus celle-ci est élevée, plus le degré d'appartenance est élevé.

L'apprentissage de la SVM avec FA se fait de la même manière que la SVM classique en rajoutant une étape de calcul des paramètres des fonctions d'appartenances (voir Figure III.12). Ce calcul se fait en résolvant un système d'équations correspondant aux conditions citées ci-dessus. Pour diminuer les temps de calculs lors des phases de test, il est nécessaire de résoudre ces systèmes hors-ligne. Cela

permet de calculer les paramètres beaucoup plus rapidement. Les calculs des paramètres pour plusieurs fonctions d'appartenance ont été effectués (Annexe VIII6 - page 219). Une illustration de l'application de cet algorithme, pour une FA sigmoïdale, est donnée à la Figure III.14.

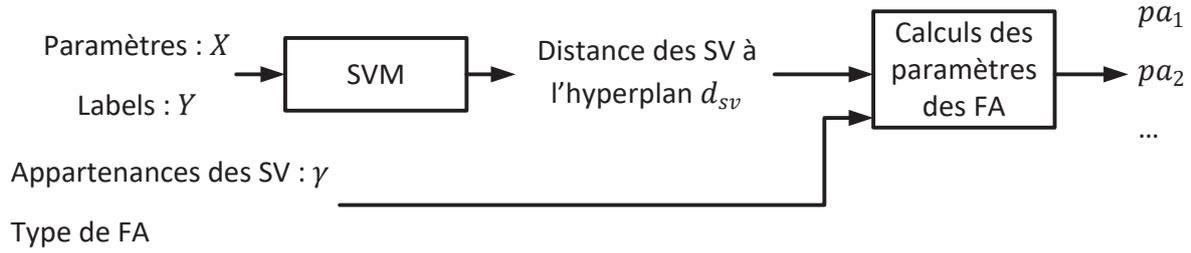


Figure III.12 : Apprentissage pour la SVM avec fonctions d'appartenances

Le calcul des degrés d'appartenance d'une nouvelle observation aux classes est fait en suivant le schéma de principe ci-dessous :

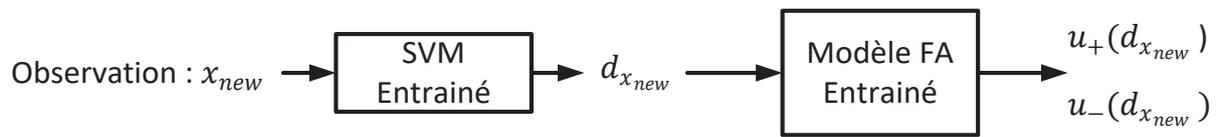


Figure III.13 : Test pour la SVM avec fonctions d'appartenance

Ce principe va maintenant être étendu au cas multi-classes.

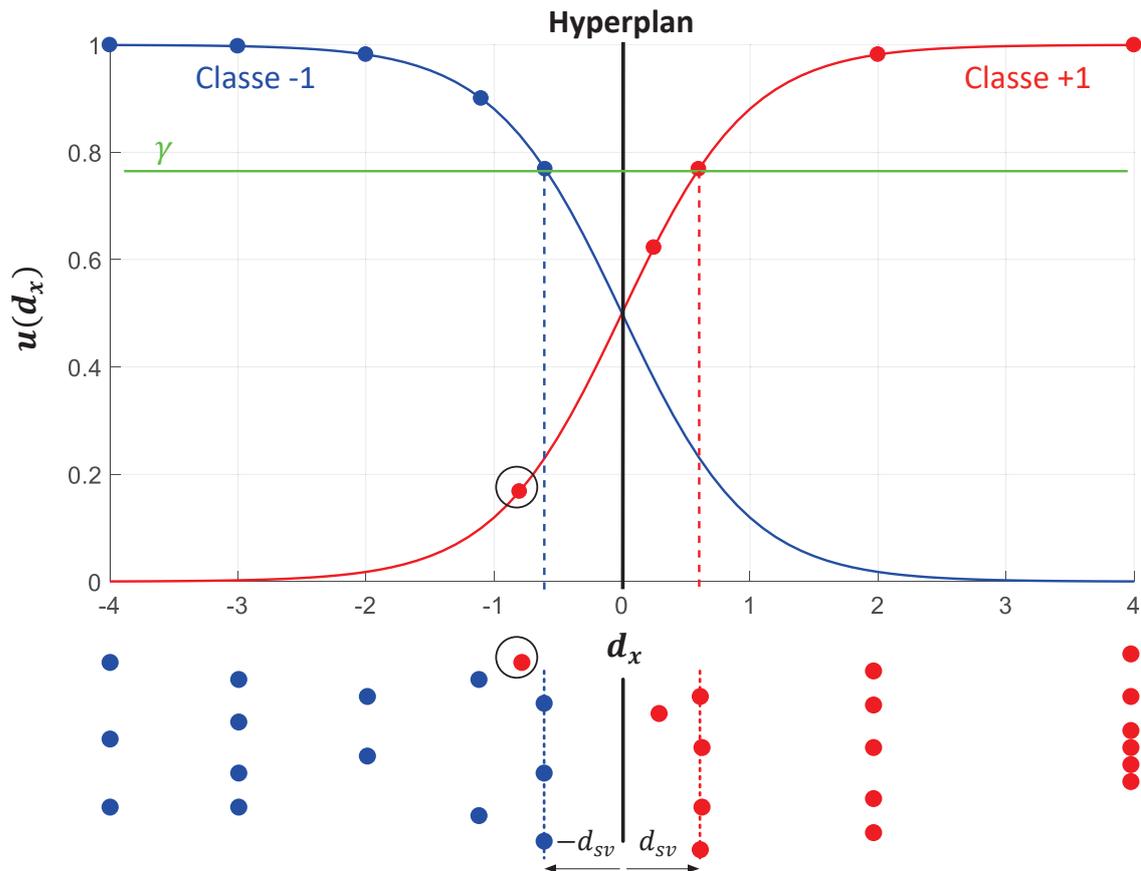


Figure III.14 : FA sigmoïdale liée à une SVM binaire (phase de test)

## 4.2 - SVM floue multi-classes

### 4.2.a - Généralités

L'objectif est d'utiliser la SVM – FA binaire pour mettre au point une matrice  $U_{class}$  où les lignes représentent les observations à classifier et les colonnes les différentes classes. Un vecteur  $U_{others}$  sera également calculé. Ce vecteur représentera le degré d'appartenance des observations à des classes non présentes dans la base d'apprentissage, c'est-à-dire inconnues. La phase d'apprentissage se fera de la même manière que pour la SVM classique, quelle que soit la méthode multi-classes, mais en apprenant les paramètres des FA en plus de l'hyperplan séparateur. Les phases de classification seront modifiées. On notera  $X_t$  la matrice contenant les  $m_t$  observations de test à classifier. A des fins de simplification, et pour tout le reste du mémoire,  $u_c(x)$  désignera le degré d'appartenance d'une observation  $x$  à une classe  $c$ . Le fonctionnement des algorithmes sera illustré sur des bases créées artificiellement. **Ces bases représentent des cas idéaux et sont seulement utilisées à des fins pédagogiques.** La première base, permettant d'illustrer les méthodes OVA et OVO, est composée de 90 observations à 3 paramètres. Les observations sont générées en faisant prendre leur valeur aux paramètres de manière aléatoire dans un intervalle réduit (Tableau III.3). Ces observations sont réparties selon trois classes, de manière équilibrée. Cette base servira à l'apprentissage des modèles SVM. Pour la phase de test, 6 points seront utilisés.

Paramètres / Classe	1	2	3
$p_1$	[0,3]	[3,6]	[7,10]
$p_2$	[7,10]	[0,3]	[3,6]
$p_3$	[3,6]	[7,10]	[0,3]

Tableau III.3 : Intervalles de valeurs des paramètres des classes générées

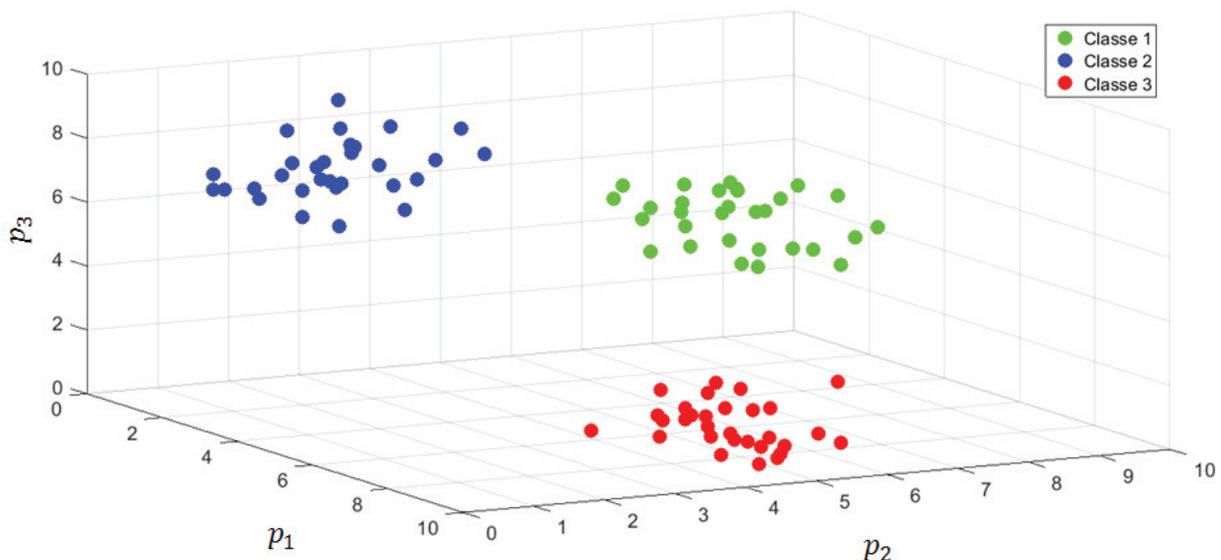


Figure III.15 : Base artificielle pour illustration des méthodes OVA et OVO

La deuxième base contient 120 observations à trois paramètres, réparties équitablement entre 4 classes. Pour la base de test, 8 points seront utilisés.

Paramètres / Classe	1	2	3	4
$p_1$	[0,3]	[3.5,6.5]	[7,10]	[4,6]
$p_2$	[7,10]	[0,3]	[3.5,6.5]	[4,6]
$p_3$	[3.5,6.5]	[7,10]	[0,3]	[4,6]

Tableau III.4 : Intervalles de valeurs des paramètres des classes générées

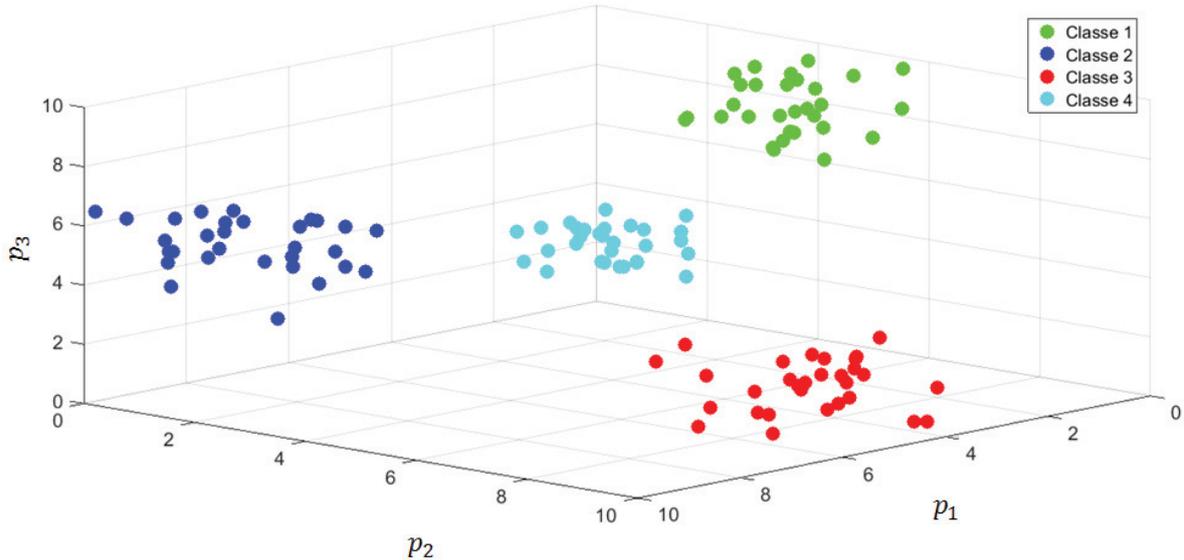


Figure III.16 : Base artificielle pour illustration des méthodes OTO

## 4.2.b - Notations

Pour toutes les méthodes de classification, on notera :

- ⇒  $MDLF$  un ensemble de modèles de SVM-FA binaires notés  $MDLF_i$
- ⇒  $\Psi: M_{m,c}(\mathbb{R}) \mapsto M_{m,1}(\mathbb{R})$  un opérateur de fusion d'information basé sur un opérateur d'agrégation  $\varphi$  (une T-norme ou une T-conorme)
- ⇒ Il est rappelé que  $\mathbb{C}$  est l'opérateur de complémentation. 4.1.d - page 95  $c_{i+}$  : la classe du modèle  $MDLF_i$  pour laquelle le label vaut +1 (correspond à  $u_+$ )
- ⇒  $c_{i-}$  : la classe du modèle  $MDLF_i$  pour laquelle le label vaut -1 (correspond à  $u_-$ )

Il est rappelé que  $m_t$  correspond au nombre d'observations dans la base de test  $XT$ .

## 4.2.c - Méthode « One Vs All »

### 4.2.c.i - Principe

L'opérateur de fusion est ici basé sur une T-norme  $\varphi$ . L'algorithme est présenté par le pseudocode suivant :

Algorithme 8 : SVM – FA “One Vs All”	
<b>(1) Initialisation</b>	$U_{class}(m_t, c)$ , $U_{all}(m_t, c)$ et de $U_{others}(m_t, 1)$ comme matrices nulles
<b>(2) Calculs des appartenances</b>	<p>Pour <math>i</math> allant de 1 à <math>c</math></p> <p>Calculer <math>u_-</math> et <math>u_+</math> pour <math>MDL_i</math></p> <p>Remplacer la <math>i^{ème}</math> colonne de <math>U_{class}</math> par <math>u_+</math></p> <p>Remplacer de la <math>i^{ème}</math> colonne de <math>U_{all}</math> par <math>u_-</math></p> <p>Fin Pour</p>
<b>(3) Calcul de <math>U_{others}</math></b>	$U_{others} = \Psi(U_{all})$

#### 4.2.c.ii - Exemple

Un apprentissage est effectué sur la base artificielle avec les paramètres suivants :

Paramètre	Valeur
C	100
Type Noyau	RBF
Paramètre Noyau	0.3
Type FA	Sigmoïdales
Paramètre FA	0.8
Type Norme	Max / Min

Tableau III.5 : Paramètres pour l'apprentissage de la SVM-FA "One vs All" sur base artificielle

Les modèles binaires entraînés sont :

Modèles / Classes	Classe +1 ( $u_+$ )	Classe -1 ( $u_-$ )
$MDL_1$	1	2, 3
$MDL_2$	2	1, 3
$MDL_3$	3	1, 2

Tableau III.6 : SVM - FA "One vs All" : Exemple de modèles entraînés sur base artificielle

Cet ensemble de modèles est ensuite testé sur une base de 6 points inconnus. Voici la succession des valeurs des matrices  $U_{class}$  et  $U_{all}$  :

$i = 1$						
	$U_{class}$			$U_{all}$		
<b>0.702</b>	0	0	<b>0.297</b>	0	0	
<b>0.868</b>	0	0	<b>0.131</b>	0	0	
<b>0.205</b>	0	0	<b>0.794</b>	0	0	
<b>0.213</b>	0	0	<b>0.787</b>	0	0	
<b>0.183</b>	0	0	<b>0.816</b>	0	0	
<b>0.192</b>	0	0	<b>0.807</b>	0	0	

Tableau III.7 : Valeurs de  $U_{class}$  et  $U_{all}$  pour  $i = 1$

$i = 2$					
$U_{class}$			$U_{all}$		
0.702	<b>0.254</b>	0	0.297	<b>0.7453</b>	0
0.868	<b>0.162</b>	0	0.131	<b>0.8378</b>	0
0.205	<b>0.787</b>	0	0.794	<b>0.2126</b>	0
0.213	<b>0.772</b>	0	0.787	<b>0.2272</b>	0
0.183	<b>0.187</b>	0	0.816	<b>0.8121</b>	0
0.192	<b>0.192</b>	0	0.807	<b>0.8079</b>	0

Tableau III.8 : Valeurs de  $U_{class}$  et  $U_{all}$  pour  $i = 2$

$i = 3$					
$U_{class}$			$U_{all}$		
0.702	0.254	<b>0.248</b>	0.297	0.7453	<b>0.751</b>
0.868	0.162	<b>0.167</b>	0.131	0.8378	<b>0.832</b>
0.205	0.787	<b>0.206</b>	0.794	0.2126	<b>0.793</b>
0.213	0.772	<b>0.213</b>	0.787	0.2272	<b>0.786</b>
0.183	0.187	<b>0.822</b>	0.816	0.8121	<b>0.177</b>
0.192	0.192	<b>0.808</b>	0.807	0.8079	<b>0.191</b>

Tableau III.9 : Valeurs de  $U_{class}$  et  $U_{all}$  pour  $i = 3$

Calcul de  $U_{others}$  :

Le vecteur  $U_{others}$  est ici calculé en prenant, pour chaque observation, la valeur minimum de  $U_{all}$  :

$U_{others}$
<b>0.297</b>
<b>0.131</b>
<b>0.212</b>
<b>0.227</b>
<b>0.177</b>
<b>0.191</b>

Tableau III.10 : Valeur de  $U_{others}$  pour la SVM-FA "One vs All" sur base artificielle

## 4.2.d - Méthode « One Vs One »

### 4.2.d.i - Principe

Cette méthode utilise deux opérateurs de fusion :  $\Psi_1$ , basé sur une T-norme  $\varphi_1$ , et  $\Psi_2$  basé sur sa T-conorme duale  $\varphi_2$ .

Algorithme 9 : SVM – FA “One Vs One”	
<b>(1) Initialisation</b>	$U_{class}(m_t, c)$ , $U_{rel}(m_t, 1)$ et de $U_{others}(m_t, 1)$ comme matrices nulles $U_{class_k}$ comme ensemble vide ( $\forall k \in \{1, \dots, c\}$ )
<b>(2) Calculs des appartenances</b>	Pour $i$ allant de 1 à $\frac{c(c-1)}{2}$ (pour chaque couple de classe)  Calculer $u_-$ et $u_+$ pour $MDL_i$ Mettre $u_+$ dans $U_{class_{c_{i+}}}$ Mettre $u_-$ dans $U_{class_{c_{i-}}}$  Fin Pour
<b>(3) Fusion pour chaque classe :</b>	Pour $j$ allant de 1 à $c$  Remplacer la $j^{ième}$ colonne de $U_{class}$ par $\Psi_1(U_{class_j})$  Fin Pour
<b>(4) Fusion sur toutes les classes :</b>	$U_{rel} = \Psi_2(U_{class})$
<b>(5) Calcul de <math>U_{others}</math></b>	$U_{others} = \mathcal{C}(U_{rel})$

#### 4.2.d.ii - Exemple

Un apprentissage est effectué avec les mêmes paramètres que pour la méthode précédente (voir Tableau III.5). Les modèles binaires entraînés sont :

Modèles / Classes	Classe $c_+$ ( $u_2$ )	Classe $c_-$ ( $u_1$ )
$MDL_1$	1	2
$MDL_2$	1	3
$MDL_3$	2	3

Tableau III.11 : SVM-FA "One vs One" : Exemple de modèles entraînés sur base artificielle

Cet ensemble de modèles est ensuite testé sur une base de 6 points inconnus.

Calculs d'appartenances :

Voici la succession des valeurs des matrices  $U_{class_k}$  :

<b><math>i = 1</math> : Classe 1 (<math>u_+</math>) contre Classe 2 (<math>u_-</math>)</b>					
$U_{class_1}$		$U_{class_2}$		$U_{class_3}$	
0.725		0.275			
0.851		0.148			
0.209		0.790			
0.220		0.779			
0.502		0.497			
0.501		0.498			

Tableau III.12 : Valeurs des  $U_{class_k}$  pour  $i = 1$

<b><math>i = 2</math> : Classe 1 (<math>u_+</math>) contre Classe 3 (<math>u_-</math>)</b>					
$U_{class_1}$		$U_{class_2}$		$U_{class_3}$	
0.725	<b>0.707</b>	0.275		<b>0.292</b>	
0.851	<b>0.824</b>	0.148		<b>0.175</b>	
0.209	<b>0.498</b>	0.790		<b>0.501</b>	
0.220	<b>0.497</b>	0.779		<b>0.502</b>	
0.502	<b>0.180</b>	0.497		<b>0.819</b>	
0.501	<b>0.191</b>	0.498		<b>0.808</b>	

Tableau III.13 : Valeurs des  $U_{class_k}$  pour  $i = 2$

<b><math>i = 3</math> : Classe 2 (<math>u_+</math>) contre Classe 3 (<math>u_-</math>)</b>					
$U_{class_1}$		$U_{class_2}$		$U_{class_3}$	
0.725	0.707	0.275	<b>0.500</b>	0.292	<b>0.499</b>
0.851	0.824	0.148	<b>0.500</b>	0.175	<b>0.499</b>
0.209	0.498	0.790	<b>0.776</b>	0.501	<b>0.223</b>
0.220	0.497	0.779	<b>0.766</b>	0.502	<b>0.233</b>
0.502	0.180	0.497	<b>0.183</b>	0.819	<b>0.816</b>
0.501	0.191	0.498	<b>0.191</b>	0.808	<b>0.808</b>

Tableau III.14 : Valeurs des  $U_{class_k}$  pour  $i = 3$

*Fusion pour chaque classe :*

L'objectif est ici de déterminer plus finement l'appartenance de chaque point à chaque classe. Il faut pour se faire prendre l'intersection de toutes les appartenances d'un point à une classe  $k$ . Ces appartenances sont contenues dans la matrice  $U_{class_k}$ . On prendra une T-norme pour faire l'intersection, ici le minimum :

$U_{class}$		
0.707	0.275	0.292
0.824	0.148	0.175
0.209	0.776	0.223
0.220	0.766	0.233
0.180	0.183	0.816
0.191	0.191	0.808

Tableau III.15 : Valeur de  $U_{class}$  calculée à partir des  $U_{class_k}$

*Fusion sur toutes les classes :*

L'objectif est de calculer un vecteur  $U_{rel}$  qui mesure la pertinence (*relevance*) de chaque observation par rapport aux classes définies. Ce calcul se fait ici en prenant pour chaque observation le maximum de  $U_{class}$ .

$U_{rel}$
0.707
0.824
0.776
0.766
0.816
0.808

Tableau III.16 : Valeur de  $U_{rel}$  calculée à partir de  $U_{class}$

*Calcul de  $U_{others}$  :*

Le vecteur  $U_{others}$  est ici calculé en prenant, pour chaque observation, la complémentation à 1 de  $U_{rel}$  :

$U_{others}$
0.292
0.175
0.223
0.233
0.183
0.191

Tableau III.17 : Valeur de  $U_{others}$  pour la SVM-FA "One vs One" sur base artificielle

## 4.2.e - Méthode « One To Others »

### 4.2.e.i - Principe

Comme pour la méthode OVO, deux opérateurs de fusion seront utilisés,  $\Psi_1$ , basé sur une T-norme, et  $\Psi_2$  basé sur sa T-conorme duale. On ajoute les notations suivantes :

- $ind$  : les indices des points classifiés à la dernière itération
- $indfin_+$  : les indices des points classifiés en +1 à la dernière itération
- $indfin_-$  : les indices des points classifiés en -1 à la dernière itération

Le pseudocode de l'algorithme est le suivant :

**Algorithme 10 : SVM – FA “One To Others”**

**(1) Initialisation**

$U_{class}(m_t, c)$ ,  $U_{c+}(m_t, c)$ ,  $U_{rest}(m_t, c)$ ,  $U_{rel}(m_t, 1)$  et de  $U_{others}(m_t, 1)$  comme matrices nulles

**(2) Calculs des appartenances**

Pour  $i$  allant de 1 à  $c-1$

Calculer  $u_-$  et  $u_+$  pour  $MDLF_i$

Trouver les points considérés comme classifiés :  $ind = \text{trouver}[u_+ \geq 0.5]$  où 0.5 est le seuil d'acceptation

Sauvegarder les valeurs de  $u_+$  pour les points classifiés dans la  $i^{\text{ème}}$  colonne de  $U_{c+}$

Sauvegarder les valeurs de  $u_-$  pour les points classifiés dans la  $i^{\text{ème}}$  colonne de  $U_{rest}$

Retirer les points classifiés de  $XT$

Si  $i = c - 1$

Trouver les points classifiés en +1 :  $indfin_+ = \text{trouver}[u_+ > u_-]$

Sauvegarder les valeurs de  $u_+$  pour ces points dans la  $i^{\text{ème}}$  colonne de  $U_{c+}$

Sauvegarder les valeurs de  $u_-$  pour ces points dans la  $i^{\text{ème}}$  colonne de  $U_{rest}$

Trouver les points classifiés en -1 :  $indfin_- = \text{trouver}[u_+ \leq u_-]$

Sauvegarder les valeurs de  $u_+$  pour ces points dans la dernière colonne de  $U_{c+}$

Sauvegarder les valeurs de  $u_-$  pour ces points dans la dernière colonne de  $U_{rest}$

Fin Si

Fin Pour

**(3) Fusion pour chaque classe :**

Pour  $j$  allant de 2 à  $c$

Mettre dans une même matrice  $U$  la colonne  $j$  de  $U_{c+}$  et les colonnes de  $U_{rest}$  allant de 1 à  $(j - 1)$

Remplacer la  $j^{\text{ème}}$  colonne de  $U_{class}$  par  $\Psi_1(U)$

Fin Pour

Remplacer la 1<sup>e</sup> colonne de  $U_{class}$  par la première de  $U_{c+}$

**(4) Fusion sur toutes les classes :**

$$U_{rel} = \Psi_2(U_{class})$$

**(5) Calcul de  $U_{others}$**

$$U_{others} = \mathcal{C}(U_{rel})$$

4.2.e.ii - Exemple

Un apprentissage est fait sur la deuxième base artificielle avec les paramètres donnés précédemment (voir Tableau III.5) et avec comme priorité des classes (ordre d'apprentissage et de prédiction) un ordre décroissant (de 4 à 1). Les modèles binaires entraînés sont au tableau suivant. Cet ensemble de modèles est ensuite testé sur une base de 8 points inconnus.

Modèles / Classes	Classe $c_+$ ( $u_2$ )	Classe $c_-$ ( $u_1$ )
$MDL_1$	4	3, 2, 1
$MDL_2$	3	2,1
$MDL_3$	2	1

Tableau III.18 : SVM-FA "One to Others" : Exemple de modèles entraînés sur base artificielle

Calculs d'appartenances :

Les valeurs successives de  $U_{c_+}$  et  $U_{rest}$  sont :

Itération 1 : Classe 4 ( $u_+$ ) contre classes 3, 2, 1 ( $u_-$ )							
$U_{c_+}$				$U_{rest}$			
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0.858	0	0	0	0.141
0	0	0	0.862	0	0	0	0.137

Tableau III.19 : Valeurs de  $U_{c_+}$  et de  $U_{rest}$  (itération 1)

Les points pour lesquels  $u_2 \geq 0.5$  sont enregistrés puis supprimés de la base de test. Ils sont considérés comme classifiés. Les autres points restent à 0 pour les deux matrices.

Itération 2 : Classe 3 ( $u_+$ ) contre classes 2, 1 ( $u_-$ )							
$U_{c_+}$				$U_{rest}$			
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0.831	0	0	0	0.168	0
0	0	0.812	0	0	0	0.187	0
0	0	0	0.858	0	0	0	0.141
0	0	0	0.862	0	0	0	0.137

Tableau III.20 : Valeurs de  $U_{c_+}$  et de  $U_{rest}$  (itération 2)

Les points pour lesquels  $u_2 \geq 0.5$  sont enregistrés puis supprimés de la base de test. Ils sont

considérés comme classifiés. Les autres points restent à 0 pour les deux matrices.

Itération 3 : Classe 2 ( $u_+$ ) contre classes 1 ( $u_-$ )							
$U_{c+}$				$U_{rest}$			
<b>0.784</b>	<b>0</b>	0	0	<b>0.215</b>	<b>0</b>	0	0
<b>0.816</b>	<b>0</b>	0	0	<b>0.183</b>	<b>0</b>	0	0
<b>0</b>	<b>0.739</b>	0	0	<b>0</b>	<b>0.260</b>	0	0
<b>0</b>	<b>0.804</b>	0	0	<b>0</b>	<b>0.195</b>	0	0
<b>0</b>	<b>0</b>	0.831	0	<b>0</b>	<b>0</b>	0.168	0
<b>0</b>	<b>0</b>	0.812	0	<b>0</b>	<b>0</b>	0.187	0
<b>0</b>	<b>0</b>	0	0.858	<b>0</b>	<b>0</b>	0	0.141
<b>0</b>	<b>0</b>	0	0.862	<b>0</b>	<b>0</b>	0	0.137

Tableau III.21 : Valeurs de  $U_{c+}$  et de  $U_{rest}$  (itération 3)

Pour la dernière itération, on remplit deux colonnes en même temps. Les points pour lesquels  $u_2 \geq u_1$  remplissent ici la deuxième colonne (avant dernière classe de la priorité). Les autres points remplissent la première colonne (dernière classe de la priorité).

*Fusion pour chaque classe :*

Certains points sont du mauvais côté de l'hyperplan défini par un modèle binaire. Ils constituent des erreurs de classification. Pour corriger une partie de ces erreurs on rassemble toutes les appartenances correspondant à une classe donnée dans une matrice  $U$  et on fusionne cette matrice en un vecteur pour avoir l'appartenance de chaque point à cette classe. Cette fusion se fait par l'utilisation d'une T-conorme pour l'union, ici par un opérateur « Max ».

Itération 1 : Classe 3							
$U$				$U_{class}$			
<b>0</b>	<b>0</b>			0	0	<b>0</b>	0
<b>0</b>	<b>0</b>			0	0	<b>0</b>	0
<b>0</b>	<b>0</b>			0	0	<b>0</b>	0
<b>0</b>	<b>0</b>			0	0	<b>0</b>	0
<b>0.831</b>	<b>0</b>			0	0	<b>0.831</b>	0
<b>0.812</b>	<b>0</b>			0	0	<b>0.812</b>	0
<b>0</b>	<b>0.141</b>			0	0	<b>0.141</b>	0
<b>0</b>	<b>0.137</b>			0	0	<b>0.137</b>	0

Tableau III.22 : Valeurs de  $U$  calculées à partir de  $U_{c+}$  et  $U_{rest}$  et valeurs de  $U_{class}$  (itération 1)

La matrice  $U$  rassemble ici les appartenances des modèles où la classe 3 intervient. Ici cela revient à prendre la troisième colonne de  $U_{c+}$  et la dernière de  $U_{rest}$ . Toutes les appartenances sont ensuite fusionnées pour construire la troisième colonne de  $U_{class}$ .

Itération 2 : Classe 2							
$U$				$U_{class}$			
0	0	0		0	0	0	0
0	0	0		0	0	0	0
0.739	0	0		0	0.739	0	0
0.804	0	0		0	0.804	0	0
0	0	0.168		0	0.168	0.831	0
0	0	0.187		0	0.187	0.812	0
0	0.141	0		0	0.141	0.141	0
0	0.137	0		0	0.137	0.137	0

Tableau III.23 : Valeurs de  $U$  calculées à partir de  $U_{c+}$  et  $U_{rest}$  et valeurs de  $U_{class}$  (itération 2)

La matrice  $U$  rassemble ici les appartenances des modèles où la classe 2 intervient. Ici cela revient à prendre la deuxième colonne de  $U_{c+}$  et les deux dernières de  $U_{rest}$ . Toutes les appartenances sont ensuite fusionnées pour construire la deuxième colonne de  $U_{class}$ .

Itération 3 : Classe 1							
$U$				$U_{class}$			
0.784	0	0	0	0.784	0	0	0
0.816	0	0	0	0.816	0	0	0
0	0	0	0.260	0.260	0.739	0	0
0	0	0	0.195	0.195	0.804	0	0
0	0	0.168	0	0.168	0.168	0.831	0
0	0	0.187	0	0.187	0.187	0.812	0
0	0.141	0	0	0.141	0.141	0.141	0
0	0.137	0	0	0.137	0.137	0.137	0

Tableau III.24 : Valeurs de  $U$  calculées à partir de  $U_{c+}$  et  $U_{rest}$  et valeurs de  $U_{class}$  (itération 3)

Puis, la première colonne traitée (la 4) de  $U_{c+}$  remplace la dernière de  $U_{class}$  (correspondant à la classe 4). En effet, cette classe n'apparaît qu'une fois car elle est tout de suite retirée.

$U_{class}$			
0.784	0	0	0
0.816	0	0	0
0.260	0.739	0	0
0.195	0.804	0	0
0.168	0.168	0.831	0
0.187	0.187	0.812	0
0.141	0.141	0.141	0.858
0.137	0.137	0.137	0.862

Tableau III.25 : Valeurs finales de  $U_{class}$

Fusion sur toutes les classes :

L'objectif est de calculer un vecteur  $U_{rel}$  qui mesure la pertinence (*relevance*) de chaque observation par rapport aux classes définies. Ce calcul se fait ici en prenant pour chaque observation le maximum de  $U_{class}$ .

$U_{rel}$
0.784
0.816
0.739
0.804
0.831
0.812
0.858
0.862

Tableau III.26 : Valeur de  $U_{rel}$  calculée à partir de  $U_{class}$

Calcul de  $U_{others}$  :

Le vecteur  $U_{others}$  est ici calculé en prenant, pour chaque observation, la complémentation à 1 de  $U_{rel}$  :

$U_{others}$
0.215
0.183
0.260
0.195
0.168
0.187
0.141
0.137

Tableau III.27 : Valeur de  $U_{others}$  calculée à partir de  $U_{rel}$

Maintenant que nous avons vu comment calculer la matrice  $U_{class}$  et le vecteur  $U_{others}$ , la méthodologie pour mettre au point une méthode de rejet à partir de ceux-ci va être introduite.

## 4.3 - Règles de décision

### 4.3.a - Indicateur de rejet en distance

Le vecteur  $U_{others}$  présente naturellement une sensibilité aux «*outliers*» (points distants de toutes les classes), points pouvant cacher des classes inconnues. Un indicateur est ici proposé, plus sensible, en reprenant la fonction noyau  $K$  utilisée pour la mise au point du modèle SVM.

$$(III.29) \quad ID(x) = \frac{u_{others}(x)}{\max_{k \in \{1, \dots, c\}} \{K(g_1, x); \dots K(g_j, x); \dots K(g_c, x)\}}$$

Avec :  $x \in \mathbb{R}^d$  : une observation ;  $u_{others}$  : l'appartenance d'une observation à des classes non-définies ;  $K(g_j, x)$  : le noyau (mesure de similarité (**Vapnik 1995**)) entre le centre de gravité  $g_j$  de la classe  $j$  et l'observation.

Moins une observation appartient aux classes définies plus son appartenance aux classes non définies,  $u_{others}$ , sera élevée. De plus, sa distance au centre de gravité des classes définies sera faible. Cela se traduira par une similarité faible et donc une valeur de noyau faible. La classe dont le point est la plus proche (valeur maximum du noyau entre l'observation et le centre de gravité) est prise comme référence.

### 4.3.b - Indicateur d'ambiguïté

Un deuxième indicateur est proposé, reposant lui sur les coefficients de  $U_{class}$ . Cet indicateur permet de détecter les points appartenant fortement à au moins deux classes en même temps. Dans le cadre du diagnostic, cela peut correspondre à des cas de défauts combinés.

$$(III.30) \quad IA(x) = \frac{\max\{K(g_{j_1}, x); K(g_{j_2}, x)\}}{\Delta u_{class_{j_1 j_2}}(x)}$$

Avec :  $j_1$  : classe pour laquelle l'appartenance de  $x$  est maximum ;  $j_2$  : classe pour laquelle l'appartenance de  $x$  atteint sa deuxième plus forte valeur ;  $\Delta u_{class_{j_1 j_2}}(x) = u_{class_{j_1}}(x) - u_{class_{j_2}}(x)$ .

Une observation entre deux classes aura les appartenances à ces deux classes très proches. Leur différence sera donc proche de zéro. La distance et donc la similarité aux deux classes sera assez importante. La valeur de la fonction noyau sera donc élevée. La valeur maximum du noyau entre l'observation et le centre de gravité des deux classes ambiguës est prise. Celle – ci est ensuite divisée par la différence entre les appartenances aux deux classes.

Pour cet indicateur il est important de noter que d'autres formulations ont été testées (noyau entre les deux centres de gravités, produit entre les noyaux observation – centre de gravité...). Cette formulation est celle qui donne les meilleurs résultats.

### 4.3.c - Règle de décision reposant sur les indicateurs

On définit les valeurs de références des indicateurs comme les valeurs maximums de ceux-ci sur la base d'apprentissage.

$$(III.31) \quad ID_{ref} = \max_{x \in X} \{ID(x)\}$$

$$(III.32) \quad IA_{ref} = \max_{x \in X} \{IA(x)\}$$

Lors des phases de tests, les indicateurs seront évalués au travers de leur variation par rapport à la valeur de référence. Quatre seuils seront définis : deux pour le rejet en distance et deux pour l'ambiguïté. Cela nous donne la cartographie de décision suivante (voir Figure III.17).

Les points rejetés en distance (zones rouges) sont transmis à des analystes ou à des experts. Il en sera de même pour les points communs au rejet en distance /ou ambiguïté (zone violette) car

lorsqu'il y a un doute, l'analyse des points par des opérateurs humains est privilégiée. Pour les points en ambiguïté (zones bleues), plusieurs classes sont attribuées, avec les degrés d'appartenances correspondants. Les points sans rejet, dans la zone noire, eux, ne sont pas rejetés. Pour ces deux derniers types de points, les appartenances peuvent également permettre d'estimer la sévérité d'un défaut.

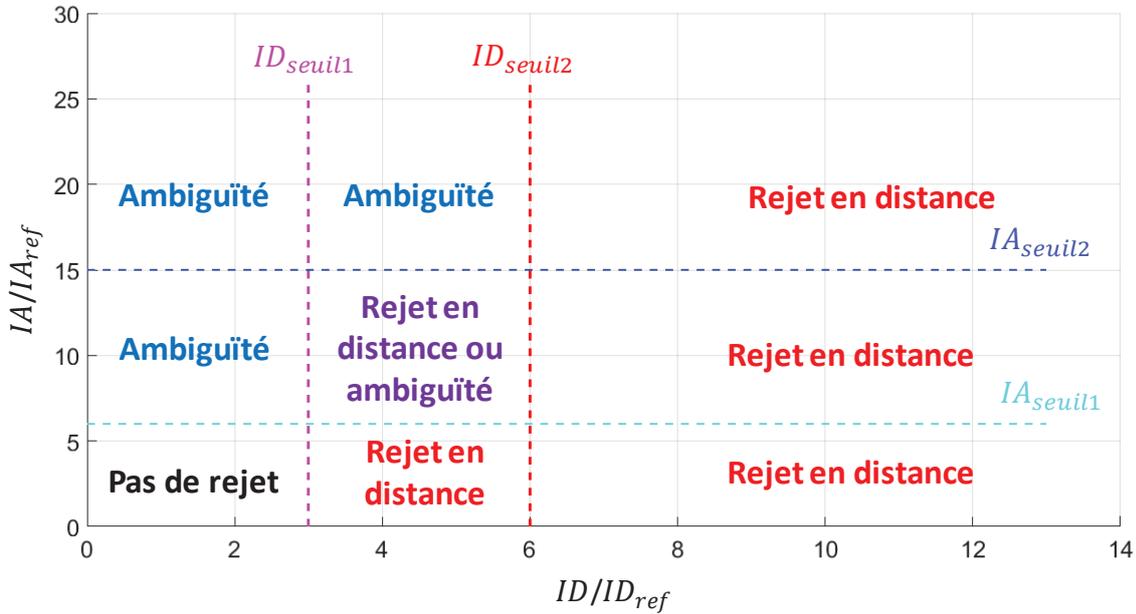


Figure III.17 : Cartographie de décision

## 4.4 - Estimation de la sévérité

L'estimation de la sévérité d'un défaut repose sur l'existence d'une base de données  $X_{sev}$  où les  $n_{sev}$  classes présentent les différentes sévérités du cas de défaut. Les classes peuvent être liées à différentes valeurs d'un paramètre de sévérité  $\vartheta \in \{\vartheta_1, \dots, \vartheta_{n_{sev}}\}$ . Ce paramètre peut avoir une signification physique ou non. Parmi les significations physiques possibles on peut citer, pour les défauts mécaniques : la surface de la zone écaillée, la profondeur des fissures, pour les stators : l'épaisseur de l'isolant ....

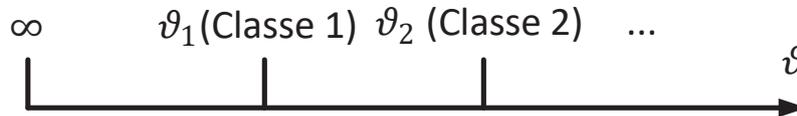


Figure III.18 : Echelle de sévérité

Le test d'une nouvelle observation  $x_{new}$ , selon le modèle SVM appris sur cette base, donne un vecteur des appartenances  $u(x_{new})$ . A partir de celui-ci, la sévérité peut être estimée par :

$$(III.33) \quad \vartheta(x_{new}) = \prod_{j=1}^{n_{sev}} \vartheta_j^{\frac{u_j(x_{new})}{\sum_{j=1}^{n_{sev}} u_j(x_{new})}}$$

Avec  $u_j(x_{new})$  : le degré d'appartenance de  $x_{new}$  à la classe  $j$ .

Les paragraphes précédents ont exposé les différentes composantes du modèle de classification

SVM-FA. La méthodologie de réglage des paramètres de ces modèles est présentée dans le paragraphe suivant.

## 4.5 - Méthodologie de réglage

### 4.5.a - Notations

Pour ce paragraphe et pour le reste du mémoire, on notera :

Notation	Définition
$me$	Mesures d'erreur
$crit$	Critères liés aux mesures d'erreurs
$seuil$	Seuil utilisé pour les critères
$MDL^r$	Modèle SVM réglé
$MDLF^r$	Modèle SVM-FA réglé

Tableau III.28 : Notations pour les méthodologies de réglages

### 4.5.b - Réglage d'un modèle SVM

Le réglage d'un modèle SVM se fait dans l'ordre suivant : choix du type de fonction noyau  $K$ , choix des paramètres de la fonction noyau  $\theta_K$ , choix du paramètre de tolérance aux erreurs  $C$ . Il est préférable de tester les différentes méthodes multi-classes même si celle-ci peut être choisie vis-à-vis des caractéristiques du problème (temps de calculs ...). Dans le cadre de ce mémoire, une seule métrique d'erreur sera utilisée. Il s'agira du risque empirique (voir (III.4) page 83). Une fois celui-ci obtenu, le modèle par fonctions d'appartenance peut à son tour être réglé.

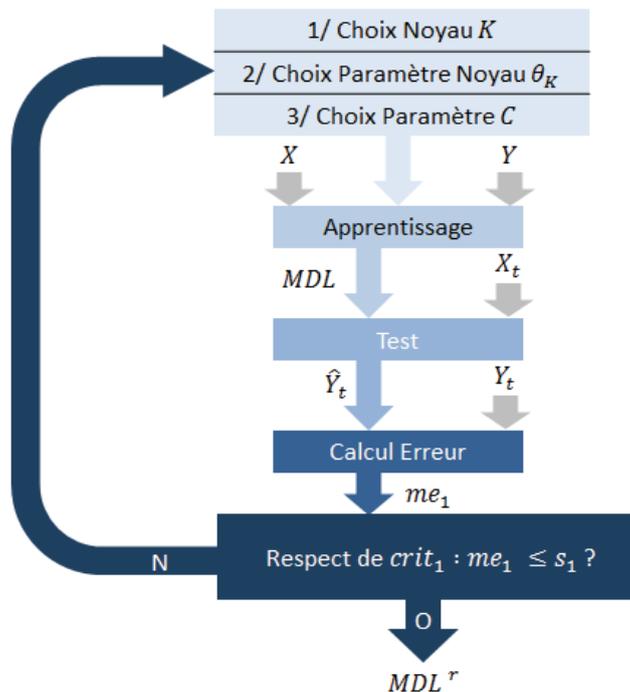


Figure III.19 : Méthodologie de réglage d'un modèle SVM avec un critère d'erreur

### 4.5.c - Réglage d'un modèle SVM-FA

Le réglage se fait dans l'ordre suivant : choix du type de fonctions d'appartenance, choix du degré d'appartenance des vecteurs supports  $\gamma$ , choix de la norme triangulaire, choix des seuils pour les indicateurs de rejet et d'ambiguïté. Les critères seront ici liés aux performances de la règle de décision et à l'estimation de la sévérité.

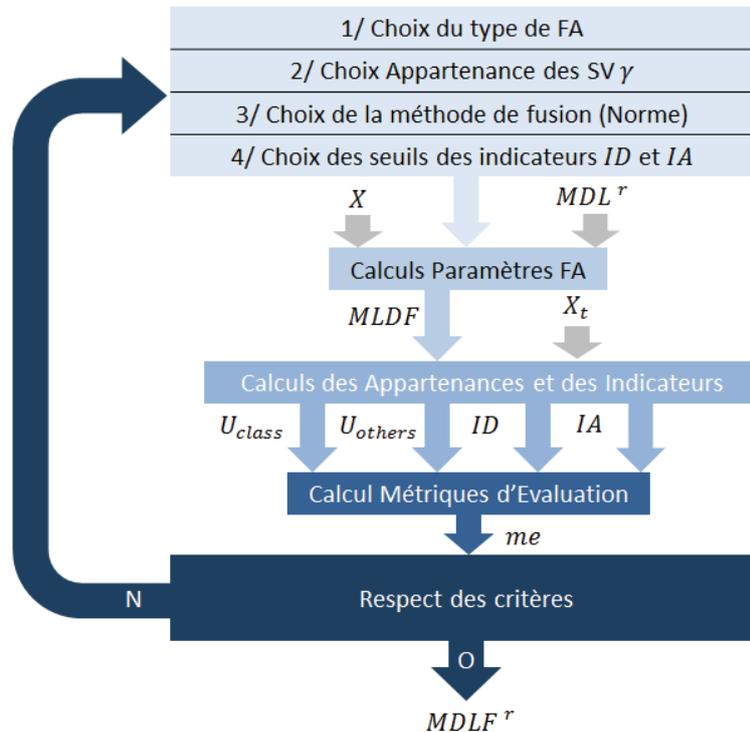


Figure III.20 : Méthodologie de réglage d'un modèle SVM-FA

Une fois le modèle réglé, il doit être validé.

## 4.6 - Méthodologie de validation

La validation, dans le cadre de l'apprentissage automatique, consiste à estimer la robustesse du modèle obtenu et réglé. Cela revient à évaluer le risque  $R$  (voir 3.1 - SVM et risque page 83). La famille de méthodes utilisée est celle des méthodes par validation croisée (Shao 1993; Plutowski 1996; Larsen et Goutte 1999). Ces méthodes consistent à effectuer plusieurs fois l'apprentissage d'un modèle sur une partie de la base et le test sur une autre. La partie de la base liée au test est remplacée d'une itération à une autre, ce qui permet de parcourir toute la base de données. La méthode « *Leave One Out* » consiste à laisser une unique observation dans la base de test. Elle estime très précisément la robustesse, mais au prix de nombreux calculs, notamment si la base est importante. La méthode « *K Fold Out* » consiste à mettre de côté un  $K^{\text{ième}}$  de la base. L'estimation est moins précise mais les calculs sont beaucoup moins importants. A noter que cette méthode sous-estime la robustesse. Ainsi, c'est cette méthode que nous avons choisi comme méthode de validation.

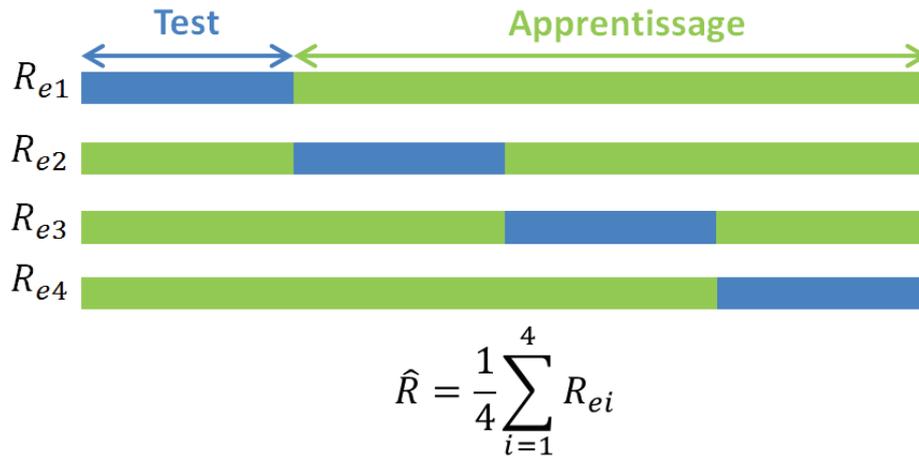


Figure III.21 : Méthode « K Fold Out » pour K = 4

Une fois les modèles validés, ils peuvent être combinés pour mettre au point un système de diagnostic complet.

## 5 - Architecture du système de diagnostic

Le système de diagnostic doit être capable de :

- ⇒ Détecter et diagnostiquer un défaut
- ⇒ Pour un défaut donné, estimer sa sévérité
- ⇒ Détecter les cas ambigus (défauts combinés) et inconnus

Pour répondre à ces problématiques, l'architecture suivante, reposant sur une combinaison de modèle SVM-FA, est proposée :

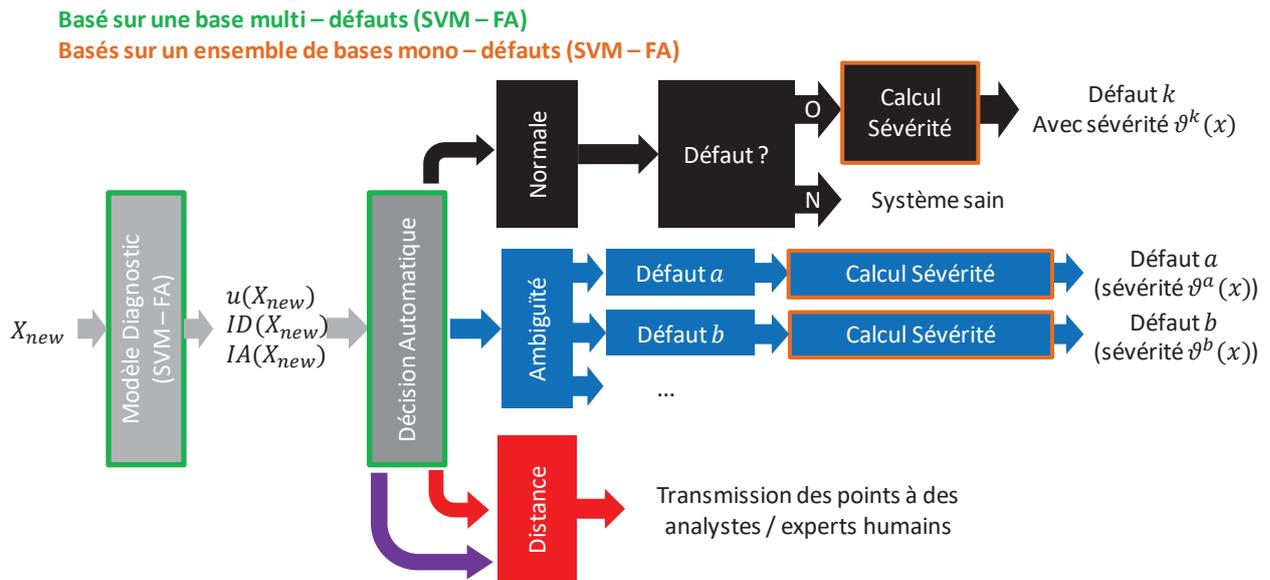


Figure III.22 : Architecture de l'algorithme de diagnostic proposé

Les blocs « Modèle diagnostic » et « Décision automatique » encadrés en vert reposent sur un

modèle SVM-FA entraîné sur une base multi-défauts. Cette base contient des observations du cas sain et des différents cas de défauts. Pour chaque cas de défauts, plusieurs sévérités sont représentées. Chacun des blocs « calcul de sévérité » encadrés en orange reposent sur une base représentative d'un défaut. Chacune de ces bases contient des observations pour différents niveaux de sévérité pour un défaut donné.

## 6 - Conclusion du chapitre

Une revue des méthodes de classification par reconnaissance de formes, permettant de faire du diagnostic, a été effectuée. La famille des méthodes à base de machines à vecteurs de supports a été sélectionnée pour sa grande robustesse. Cette famille de méthode a été présentée en détails. Puis une hybridation avec les appartenances floues a été proposée. Cette nouvelle version de l'algorithme permet de graduer les appartenances à une classe. Elle permet également, pour une observation, d'appartenir à plusieurs classes. Cette méthode permet également d'évaluer l'appartenance d'une observation à des classes inconnues (non présentes dans la base d'apprentissage). De ces notions, des indicateurs en ambiguïté et en distance ont été proposés. Ces indicateurs permettent de mettre au point une règle de décision assez simple qui permet de détecter les points ambigus et les points inconnus. Une méthode pour l'estimation de sévérité d'un défaut a également été proposée. Finalement, l'ensemble des solutions proposées ont été combinées pour proposer une architecture d'algorithme de diagnostic complet.

Après avoir été explicitées sur des bases de données artificielles, les méthodes proposées vont maintenant être appliquées sur des bases expérimentales.

# IV

## Validation Expérimentale

Sévérité Défauts  
Calculs Signatures  
Validation Mémoire  
Expérimentale  
Appartenances Données  
Flou Observations Décision  
Classes Diagnostic SVM  
Rejet Précision

<b>IV</b>	<b>VALIDATION EXPERIMENTALE.....</b>	<b>115</b>
1	GENERALITES .....	117
2	PRESENTATION DES BANCS .....	117
2.1	<i>Le banc ELAM</i> .....	117
2.2	<i>Le banc MSAP</i> .....	118
2.3	<i>Le banc machine asynchrone</i> .....	119
3	EXTRACTION DE SIGNATURES .....	120
3.1	<i>Identification des frottements</i> .....	120
3.1.a	Profil complet.....	121
3.1.b	Points moyennés issus du profil complet .....	122
3.2	<i>A partir des signaux de courants</i> .....	123
4	DIAGNOSTIC.....	124
4.1	<i>Machine asynchrone (multi – défauts)</i> .....	125
4.1.a	Base de données .....	125
4.1.b	Sélection de paramètres.....	126
4.1.c	Validation sur les bases « pauvres ».....	127
4.1.c.i	Critère de précision sur la base de test.....	127
4.1.c.ii	Critère du temps de calcul pour la phase de test .....	129
4.1.c.iii	Critère de la mémoire de stockage.....	130
4.1.d	Validation sur les « bases riches » .....	130
4.1.d.i	Critère de précision sur la base de test.....	130
4.1.d.ii	Critère du temps de calculs en test .....	132
4.1.d.iii	Critère de la mémoire de stockage.....	132
4.2	<i>Machine synchrone (multi – sévérités)</i> .....	132
4.2.a	Base de données .....	132
4.2.b	Sélection de paramètres.....	133
4.2.c	Validation sur la « base pauvre » .....	135
4.2.c.i	Critère de précision sur la base de test.....	135
4.2.c.ii	Critère du temps de calculs en test .....	136
4.2.c.iii	Critère de la mémoire de stockage.....	136
4.2.d	Validation sur la « base riche » .....	136
4.2.d.i	Critère de précision sur la base de test.....	136
4.2.d.ii	Critère du temps de calculs en test .....	137
4.2.d.iii	Critère de la mémoire de stockage.....	138
5	RESPECT DES CONTRAINTES .....	138
5.1	<i>Pour l'extraction de signatures</i> .....	138
5.2	<i>Pour le diagnostic</i> .....	139
6	CONCLUSION DU CHAPITRE .....	140

## 1 - Généralités

Ce chapitre vise à vérifier expérimentalement les méthodes proposées au deux chapitres précédents. Dans un premier temps, les travaux de validation expérimentale ont donc consisté à s'assurer de la validité des méthodes d'extraction de signatures pour un EMA sain sur un banc représentatif. L'obtention de données représentatives de vieillissement dans le temps n'a pas pu être assurée dans le temps limité de cette thèse, sur le banc prévu à cet effet. Ainsi, ces premiers travaux liés au diagnostic n'ont pu être directement validés sur ce banc. Aussi, l'algorithme de diagnostic mis au point a été validé sur des bases de signatures issues de campagnes d'essais précédents. Une base concerne les défauts d'une machine synchrone à aimants de type aéronautique et une autre les défauts d'une machine asynchrone industrielle classique. L'ensemble des calculs au sein de ce chapitre ont été effectués sur un ordinateur équipé d'un processeur Intel Core i5 de 2.7 GHz avec 8 Go de RAM.

## 2 - Présentation des bancs

### 2.1 - Le banc ELAM

Pour tester l'architecture d'implémentation (voir Figure I.13 page 28) et l'EMA, Safran Electronics & Defense a mis au point un banc d'essais spécifique, le banc ELAM (*ELectrical Actuator Monitoring*). Ce banc est capable de tester le système sur des profils opérationnel (OP) issus de mesures en vol et sur des profils non-opérationnel (NOP) correspondant à des profils imposés sur le tarmac. Ces profils sont à la fois en position et en charge. La charge aérodynamique simulée par le banc est assurée par un vérin hydraulique. Le banc est également conçu pour faire vieillir l'EMA via un profil spécifique. L'usure et la caractérisation se font avec l'environnement proche des caractéristiques opérationnelles : l'EMA est maintenu à température constante via un caisson isolant et une génératrice climatique connectée à celui-ci.

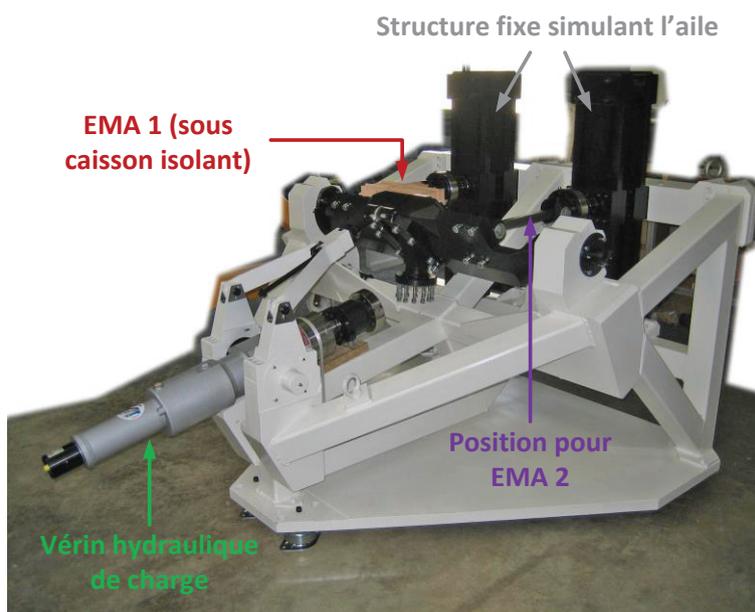


Figure IV.1 : Banc ELAM

Les acquisitions se font avec les capteurs embarqués de l'EMA et avec des capteurs supplémentaires (audio, accéléromètres, thermocouples...). Seules les données issues des capteurs embarqués ont été traitées dans le cadre de cette thèse. Ces données ont été utilisées pour valider les algorithmes d'extraction de signatures.

## 2.2 - Le banc MSAP

Ce banc, situé au laboratoire Green (Nancy), a été mis en place et exploité dans le cadre des travaux de thèse de Nicolas Leboeuf (Leboeuf 2012). Les essais ont consisté à émuler le défaut de court-circuit inter spires en mettant une résistance de défaut  $R_f$  en parallèle d'une des phases de la MSAP. La machine utilisée lors de ces essais est une machine aéronautique mise au point par Safran Electronics & Defense pour ses EMA. Celle – ci est alimentée par un onduleur de tension à IGBT, lui-même alimenté par une source continue stabilisée à 280V. Un moteur à courant continu (MCC) à excitation séparée a été utilisé pour simuler la charge. Celui –ci est alimenté par un hacheur abaisseur de tension. L'acquisition et la commande se sont faites via un PC au travers d'une carte DSpace 1005. Un contrôle vectoriel du couple et du flux a été implanté dans un repère lié au rotor.

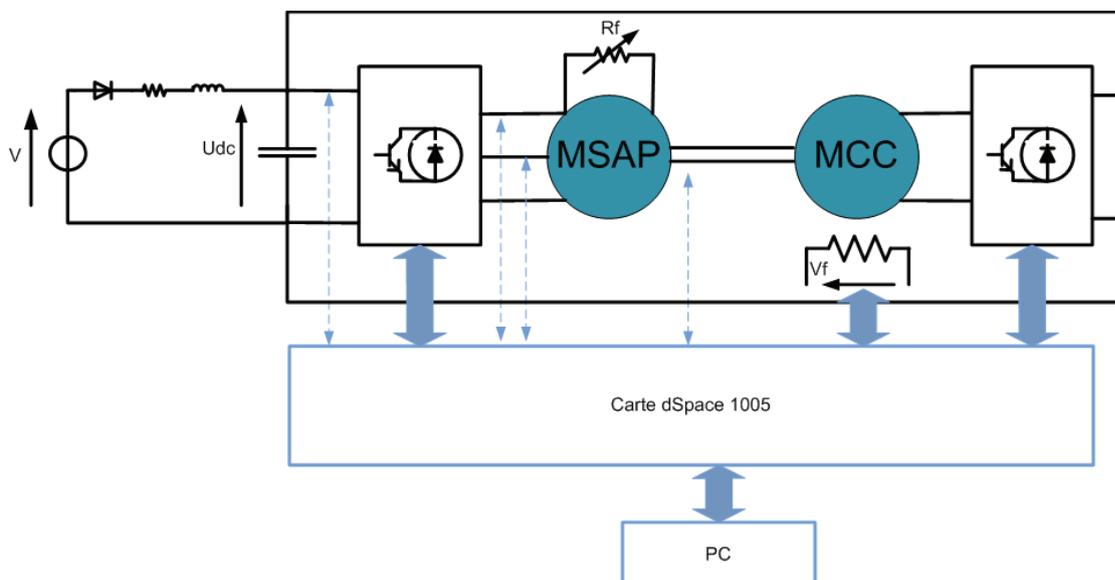


Figure IV.2 : Banc d'essai pour un MSAP en défaut de court – circuit - Schéma (Leboeuf 2012)

Les essais reposent sur 6 valeurs de vitesse  $N$  et 5 valeurs de courant de charge  $i_q$ . Un sixième de phase a été court – circuité pour émuler trois valeurs de la résistance de défaut  $R_f$ . Le cas sain est représenté par une résistance de défaut élevée :  $R_f = 100\text{ k}\Omega$ .

$N_{vit}$ (t/min)	50	100	200	300	400	500
$i_q$ (A)	1	2	4	6	8	
$R_f$ ( $\Omega$ )	0.6	1.2	2.4	100 000		

Tableau IV.1: Valeurs des paramètres variants dans le cadre des essais MSAP

Chaque mesure a été répétée 15 fois pour pallier les effets du bruit. La base finale contient donc  $6 \times 5 \times 4 \times 15 = 1800$  observations. Chaque observation est caractérisée par 11 signatures de défauts (voir Annexe VIII.9.2 - page 230). Ces signatures sont issues des travaux de (Leboeuf 2012) et

(Boileau 2010).

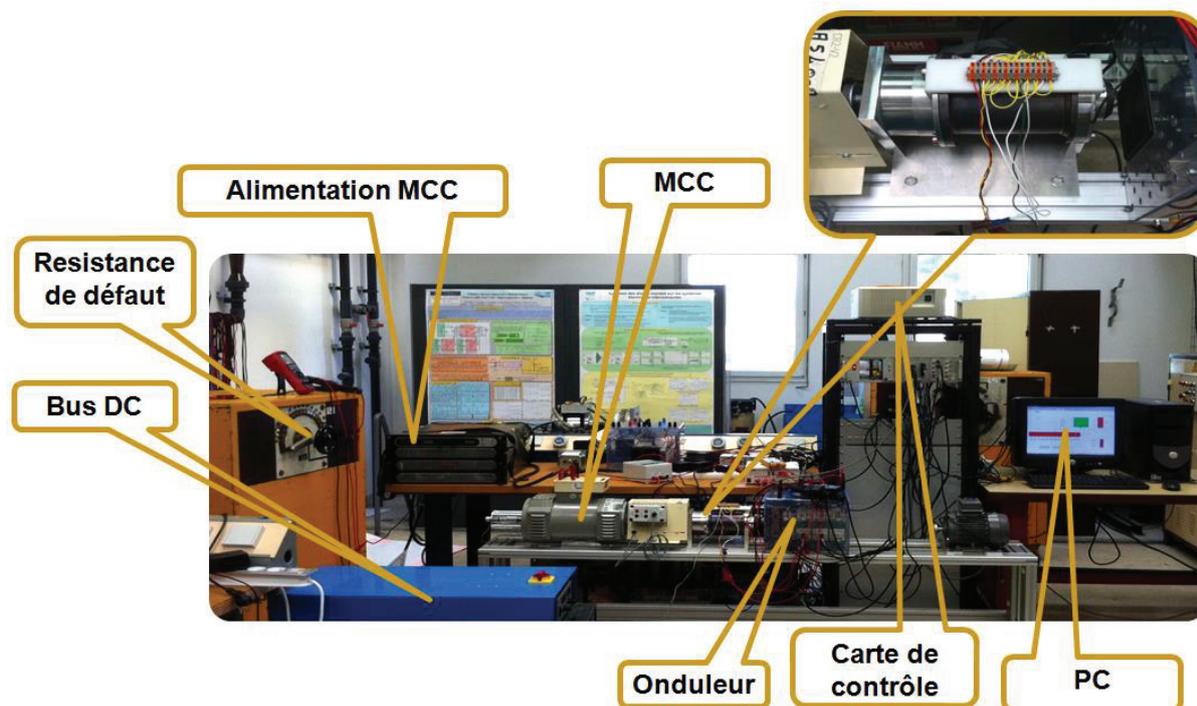


Figure IV.3 : Banc d'essai pour un MSAP en défaut de court – circuit - Photo (Lebœuf 2012)

## 2.3 - Le banc machine asynchrone

Ce banc a été précédemment exploité dans le cadre de deux travaux de thèse (Casimir 2003; Ondel 2006). Il est composé d'un moteur asynchrone à cage d'écurueil, alimenté sur réseau ou par onduleur, et d'un frein à poudre magnétique pour créer une charge passive. Dans le cadre des travaux de la présente thèse, seules les données de la machine alimentée par onduleur ont été traitées, pour rester plus proche du cadre aéronautique. Les caractéristiques du moteur asynchrone sont données en annexe (Annexe VIII8 - 229).

L'acquisition des courants et des tensions se fait sur une période de 5 secondes avec un échantillonnage à 20 kHz. Les modes de fonctionnement étudiés sont les suivants :

Mode de fonctionnement	Type de défauts	Taux de charge (%)
Moteur et onduleur sain		0 et 50
Roulements endommagés et onduleur sain	Roulements	0 et 50
Une barre cassée et onduleur sain	Barres cassées	0 et 50
Trois barres cassées et onduleur sain		0 et 50
Quatre barres cassées et onduleur sain		0 et 50
Moteur sain et condensateur endommagé	Condensateur	0 et 50

Tableau IV.2 : Modes de fonctionnement étudiés via le banc machine asynchrone

Les roulements et le condensateur endommagé ont subi un vieillissement naturel dans des conditions normales d'utilisation (Venet et al. 1999; Bolander et al. 2009). Les barres cassées sont recrées en perçant des trous dans les conducteurs de la cage d'écureuil.

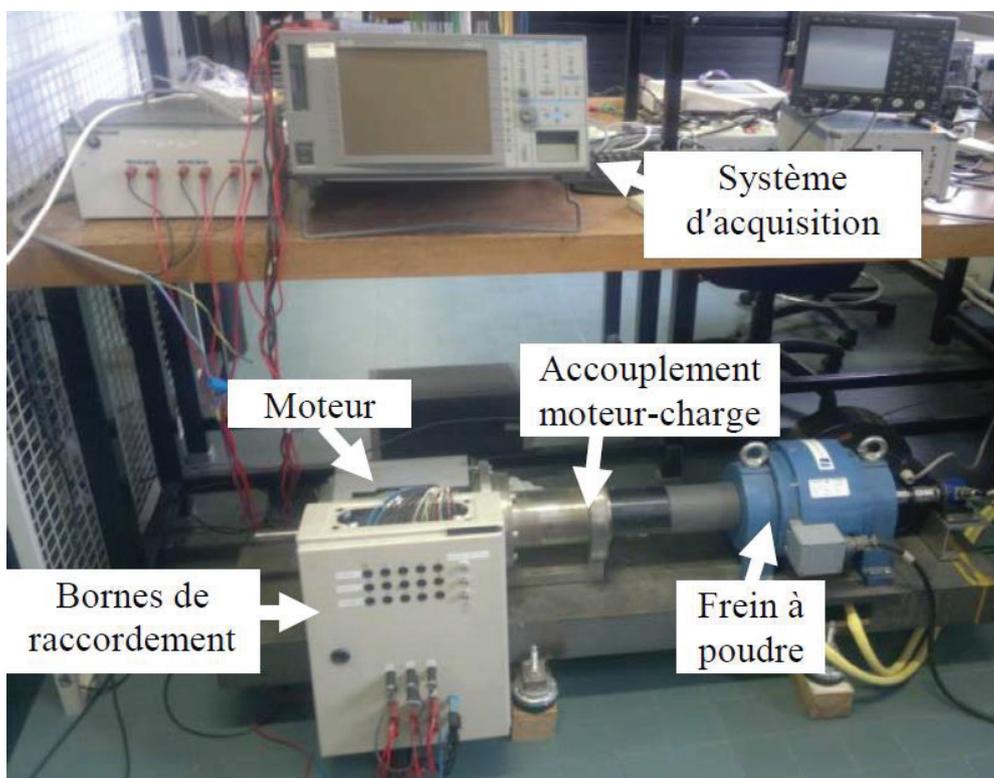


Figure IV.4 : Banc machine asynchrone – Photo (Soualhi 2013)



Figure IV.5 : Emulation des défauts de barres cassées

## 3 - Extraction de signatures

Ayant pris le parti d'évaluer l'état de l'EMA sur la Tarmac, des données adaptées à la détermination des paramètres peuvent être générées avant le vol. Aussi, seuls les profils non opérationnels sont traités ici. De plus des données de vieillissement n'étant également pas disponibles, seule une évaluation qualitative des algorithmes est faite. Toutes les données utilisées pour cette partie sont issues du banc ELAM.

### 3.1 - Identification des frottements

La méthode utilisée ici est celle présentée au paragraphe II4 - page 56. Le profil utilisé est identique et est remis ici pour rappel.

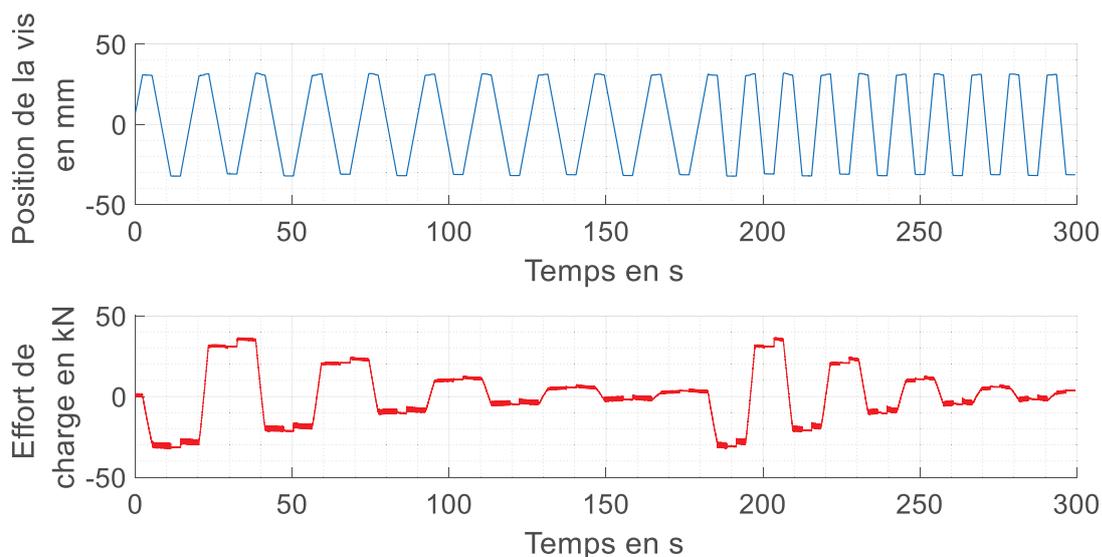


Figure IV.6 : Profil d'acquisition pour le calcul de signatures

Cette méthodologie permet d'identifier les paramètres suivants : le coefficient de frottement visqueux  $C_v$ , le coefficient de frottement sec  $C_{fsec}$ , le coefficient de frottement dépendant de la charge  $K_{rend}$  (voir (II.17)).

### 3.1.a - Profil complet

L'algorithme converge sur un ensemble de paramètres, pour une valeur de fonction coût un peu plus élevée que sur les données issues de simulation.

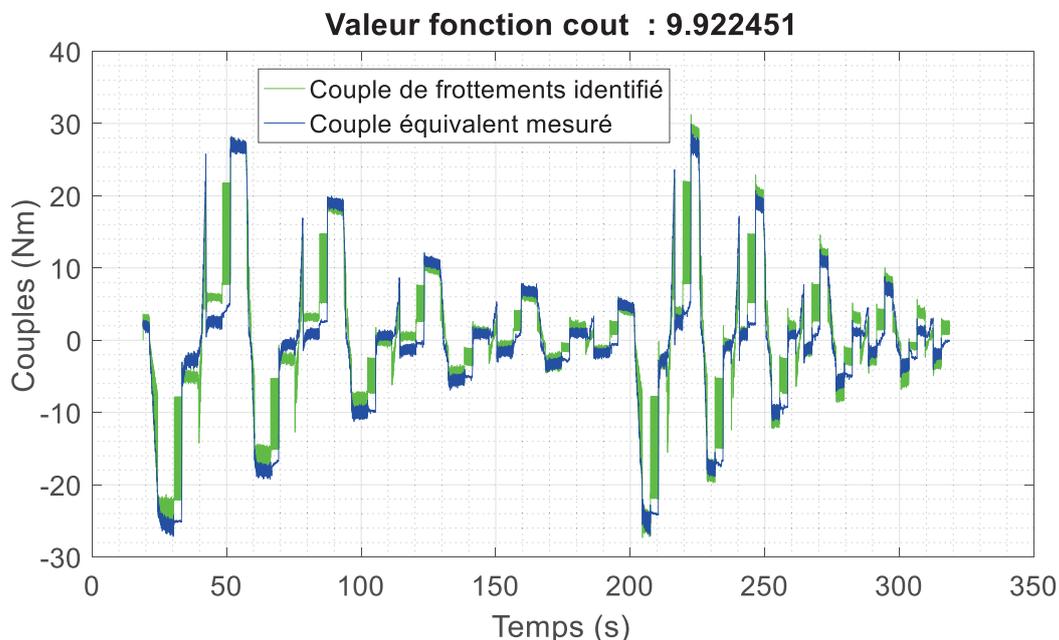


Figure IV.7 : Identification du couple de frottements sur données expérimentales, profil non opérationnel

On observe toujours des oscillations qui correspondent aux phases de changement de vitesse ainsi que des erreurs plus importantes pour les couples faibles. Cela s'explique par le modèle de frottements qui dépend du signe de la vitesse et par la non prise en compte du jeu mécanique et de la raideur. A partir de valeurs initiales, l'algorithme converge assez rapidement vers la solution dans

l'ordre de grandeur des paramètres. Le temps de calcul pour l'identification est de près de 840 secondes, ce qui est un peu élevé vis-à-vis de nos contraintes. Cependant, l'algorithme, converge au voisinage de la valeur à la 14<sup>e</sup> itération ( $f_{cout} = 9.932$ ) et atteint définitivement à partir de la 27<sup>e</sup> (voir Figure IV.8). Le nombre d'itérations peut donc être réduit ce qui amène les temps de calculs entre 118 et 227 secondes.

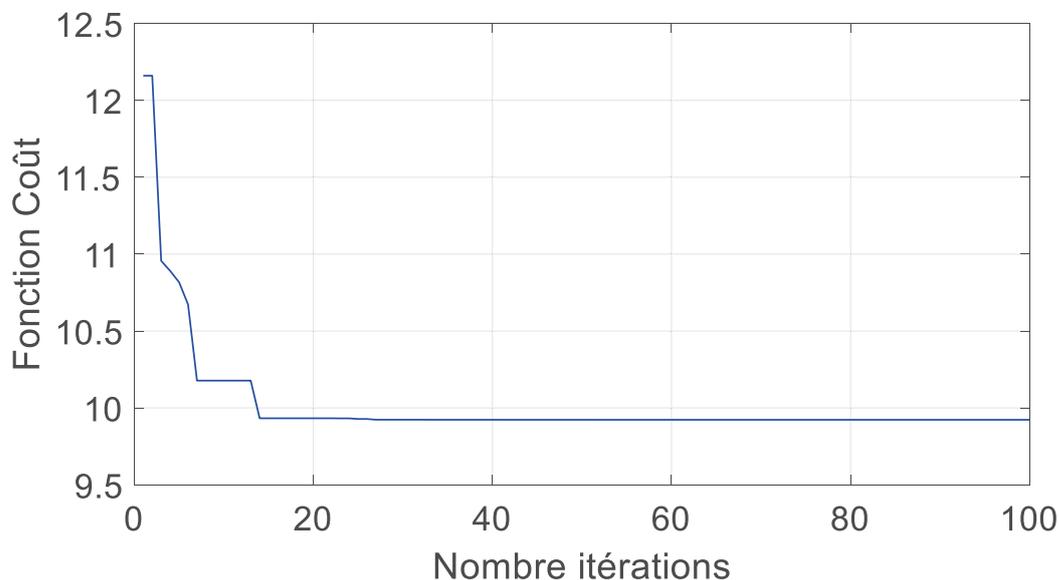


Figure IV.8 : Convergence de l'algorithme d'identification sur profil non opérationnel

La fonction coût représente ici la moyenne du carré de l'erreur sur l'identification du couple. Une autre solution pour accélérer encore les calculs est de travailler à partir des points moyennés sur les paliers de vitesse du profil.

### 3.1.b - Points moyennés issus du profil complet

Les points moyennés sont calculés en prenant le point milieu de chaque palier et tous les points environnants de ce point milieu à  $\pm 0.7 s$ . Les points milieu sont donnés à l'algorithme comme paramètre. L'algorithme converge également pour une fonction coût plus élevée que pour le profil précédent. Cela s'explique par le fait que moins d'information est fourni à l'algorithme. Le temps de calcul est nettement réduit : moins de 8 secondes. L'ensemble des valeurs optimales des paramètres est trouvé à partir de la 33<sup>e</sup> itération. A partir de la 17<sup>e</sup> itération le résultat est très proche de l'optimal.

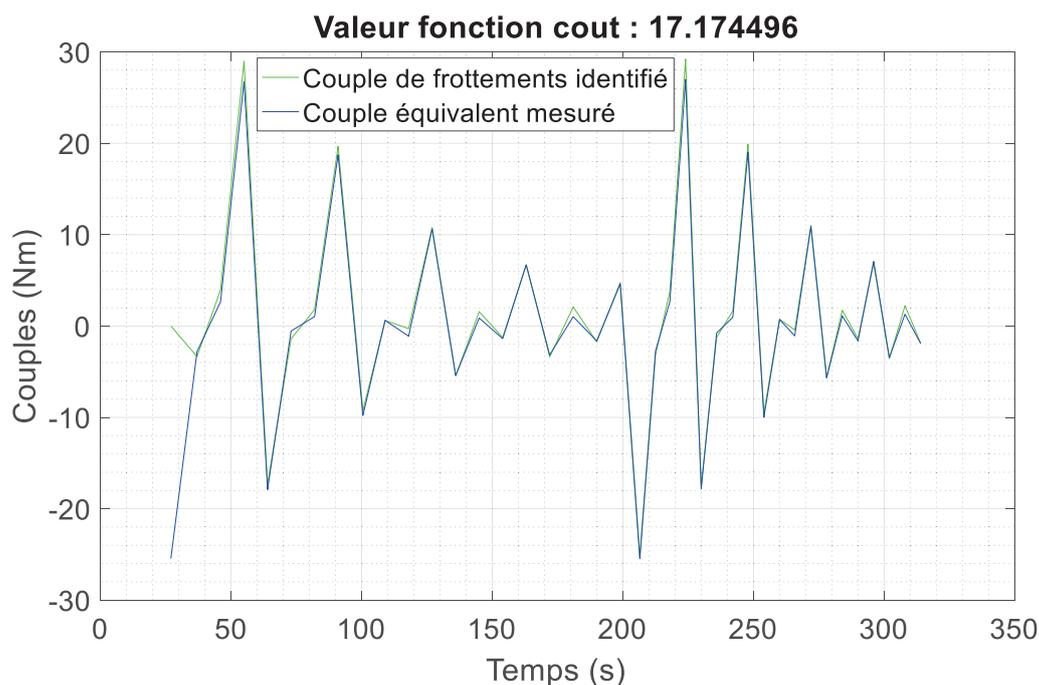


Figure IV.9 : Identification du couple de frottements sur données expérimentales, profil non opérationnel moyenné

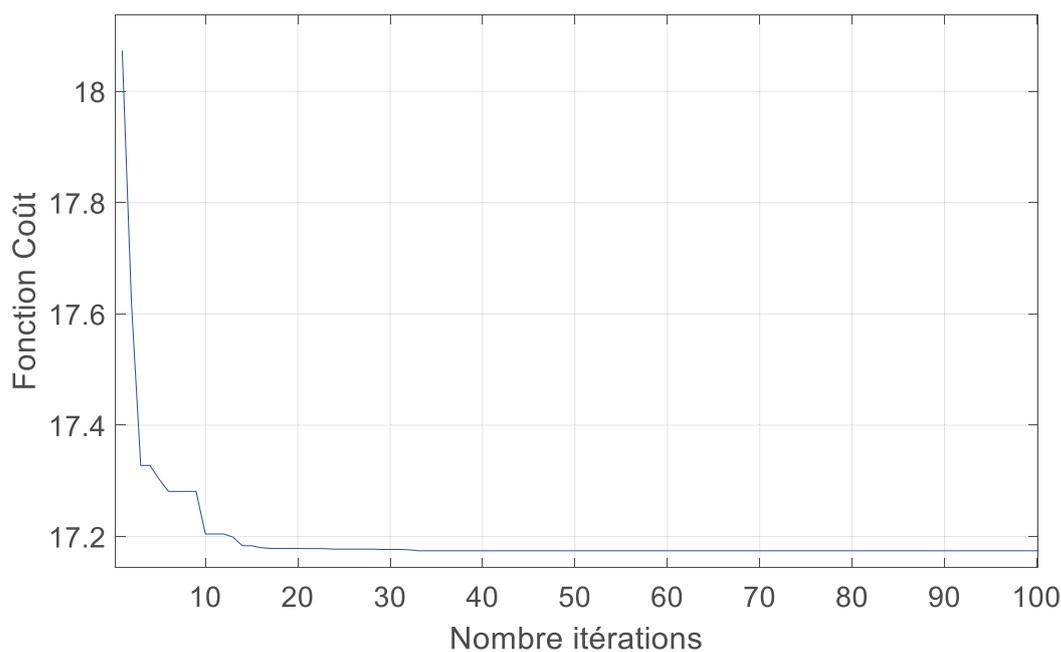


Figure IV.10 : Convergence de l'algorithme d'identification sur profil non opérationnel moyenné

### 3.2 - A partir des signaux de courants

Pour cette méthodologie le profil d'acquisition est le même que précédemment mais réduit à la portion comprise entre  $t = 200$  s et  $t = 270$  s, afin de diminuer les coûts de calculs.

La méthodologie pour l'extraction des signatures est présentée au chapitre II (voir II5 - page 59). Les signaux caractéristiques de chaque défaut correspondent à ce que l'on trouve en simulation (voir

Figure II.13 et Figure II.14).

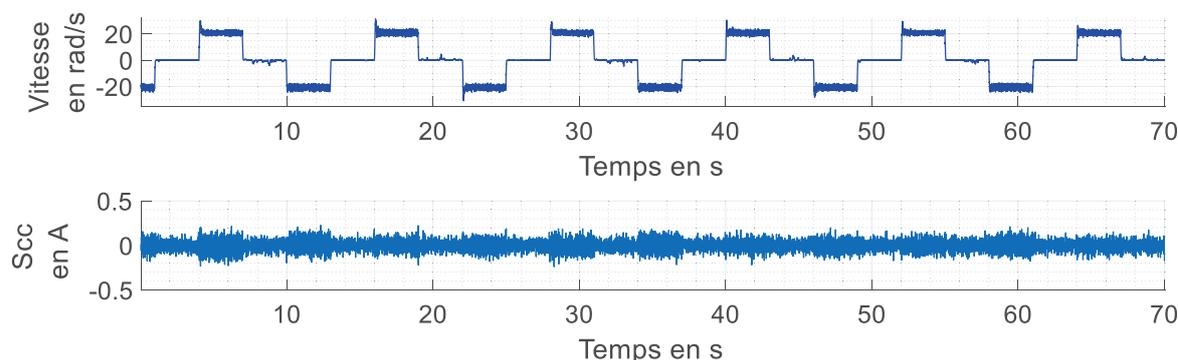


Figure IV.11: Signal "Scc" caractéristique du défaut de court - circuit

Le signal représentatif du défaut de la vis à rouleau présente bien des pics réguliers, représentatifs de la présence de jeu mécanique. Il faut noter que plus la charge est importante, plus les pics ont une forte amplitude.

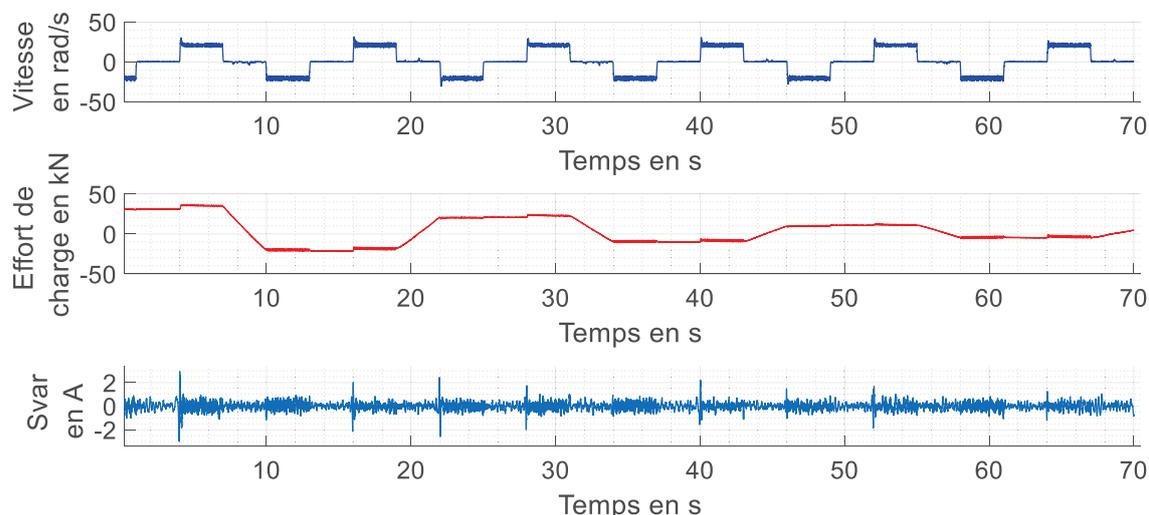


Figure IV.12 : Signal "Svar" caractéristique du défaut d'usure de la vis à rouleaux

Le temps de calcul complet est de près de 240 secondes, ce qui est correct vis-à-vis de nos contraintes.

Il serait intéressant de voir si cette méthode permet de distinguer les défauts VAR et CC d'autres défauts (roulements, électronique...). Le manque de données de cas de défauts ne nous permet pas de statuer sur ce point. Cependant suffisamment de données macroscopiques, où les bases contiennent seulement des signatures de défauts, sont disponibles pour tester notre algorithme de diagnostic.

## 4 - Diagnostic

Pour ce paragraphe, la méthodologie de diagnostic par SVM – FA sera évaluée sur les bases issues du banc MSAP et du banc machine asynchrone. Pour l'ensemble des bases, les paramètres, sont normalisés entre 0 et 1. Une sélection de paramètres est effectuée sur chaque base par « Sélection

Séquentielle Arrière » (*Sequential Backward Selection : SBS*) (Doak 1992; Kudo et Sklansky 2000) (voir Annexe VIII10 - page 232). Trois algorithmes de classification, issus de notre état de l'art, sont également utilisés à des fins comparatives. Les trois méthodes sont : par arbre de décision (ADD), par k plus proches voisins (KNN) et par réseau bayésien naïf (BN) (III2.2 - page 78). Ces trois classifieurs ont été implémentés via la *Statistics and Machine Learning Toolbox™* de Matlab®. A noter que pour les bases machines asynchrones, les performances issues de ces trois algorithmes ne pourront pas dépasser les 75% de précision, étant donné qu'ils sont dépourvus d'option de rejet. Le choix de la méthode multi – classes pour l'algorithme SVM – FA est le « *One Vs All* ». La méthode de validation utilisée est une validation croisée par «5 - Fold Out». Dans un premier temps, une situation défavorable, dit de base « pauvre » en informations, sera considérée. Un cinquième d'une base sera utilisée pour l'apprentissage et quatre cinquièmes pour le test. Puis une validation croisée classique, dite ici de base « riche » en informations, sera effectuée avec quatre cinquièmes de la base utilisée pour l'apprentissage et un cinquième pour le test. Tous les modèles de classification sont évalués selon les critères suivants :

- ⇒ La précision  $P$ , caractérisée par le pourcentage de points correctement classifiés sur la base de test. Cela correspond à un moins le risque empirique sur cette même base de test :

$$(IV.1) \quad P = 1 - R_{emp}(\alpha)$$

Les points inconnus ou ambigus non rejetés seront comptabilisés comme des erreurs. De même un point de classe connu et rejeté sera considéré comme une erreur.

- ⇒ Le temps de classification pour l'ensemble des points de la base de test
- ⇒ La quantité de mémoire nécessaire pour stocker le modèle entraîné. Ce modèle entraîné correspond à l'ensemble : points de la base d'apprentissage sélectionnés lors de l'apprentissage pour faire partie du modèle, coefficients associés à ces points, paramètres de l'algorithme de classification. Pour un algorithme donné, les quantités de mémoires évaluées sont assez stables sur les itérations de la validation croisée. Ainsi, afin de rester conservatif, seule la valeur maximum, arrondi au supérieur, sera donnée.

Une synthèse sur l'adéquation des résultats obtenus vis-à-vis des contraintes sera faite en fin de chapitre (voir paragraphe 5 - page 138).

## 4.1 - Machine asynchrone (multi – défauts)

### 4.1.a - Base de données

Un certains nombres de signatures ont été calculées à partir des données (Soualhi 2013). Cela permet de construire deux bases de données. La première vise à tester l'option de rejet (défaut inconnu). Elle est constituée de quatre classes : machine saine, machine avec roulements endommagés et onduteur sain, machine avec barres cassées et onduteur sain et machine saine avec onduteur endommagé (condensateur). La dernière classe n'est utilisée que pour les tests et elle est dite non définie (ND). Les points non rejetés de cette classe engendreront des erreurs. Les trois autres classes sont utilisées en apprentissage et en test et sont dites définies (D).

N°	Classe	Nombre d'observations
1 (D)	Moteur et onduleur sain	30
2 (D)	Roulements endommagés et onduleur sain	30
3 (D)	Barres cassées (1, 3, 4)	30 (10 de chaque)
4 (ND)	Machine saine et onduleur endommagé (condensateur)	30

Tableau IV.3 : Première base de données issue du banc machine asynchrone

La deuxième base vise elle à tester la détection de cas d'ambiguïté (défauts combinés). Ne possédant pas de données sur des cas de défauts de types différents combinés, le cas de défaut trois barres cassées est considéré comme un cas combiné d'une et de quatre barres cassées. Les points non rejetés de cette classe engendreront des erreurs.

N°	Classe	Nombre d'observations
1 (D)	Moteur sain	30
2 (D)	Une barre cassée	30
3 (ND)	Trois barres cassées	30
4 (D)	Quatre barres cassées	30

Tableau IV.4 : Deuxième base de données issue du banc machine asynchrone

### 4.1.b - Sélection de paramètres

Pour la première base, le tracé de la fonction de coût (voir (VIII.48)) en fonction du nombre de paramètres donne un nombre optimal de paramètres entre 9 et 13. Après quelques tests de l'algorithme SVM – FA, le point optimal se situe pour  $p_{opt} = 11$ .

Soient :  $f_s$  : la fréquence des courants statoriques,  $f_r$  : la fréquence de rotation du rotor,  $I_s$  : courant statorique,  $I_{s1}$  : courant statorique selon l'axe 1 (repère de Concordia),  $I_{s2}$  : courant statorique selon l'axe 2 (repère de Concordia). Les paramètres retenus sont :

- ⇒ Puissance active moyenne
- ⇒ Puissance réactive moyenne
- ⇒ Pertes totales de la machine
- ⇒ Température de l'armature
- ⇒ Amplitude du signal de courant à  $f_s + f_r$
- ⇒ Amplitude du cinquième harmonique de courant
- ⇒ Amplitude du septième harmonique de courant
- ⇒ Variance de  $I_{s1}$
- ⇒ Variance de  $I_{s2}$
- ⇒ Variance de  $\|I_s\|$
- ⇒ Impédance Directe

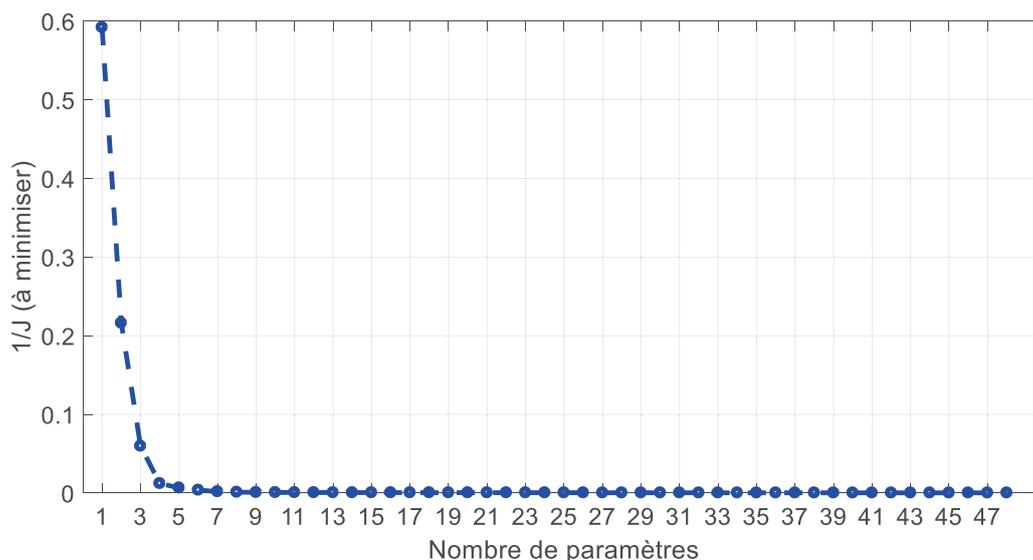


Figure IV.13: Critère de sélection de paramètres - Première base machine asynchrone

Pour la deuxième base le nombre de paramètres optimal est situé entre 4 et 10. Après quelques tests de l’algorithme SVM – FA, le point optimal se situe pour  $p_{opt} = 4$ . Les paramètres à conserver sont :

- ⇒ Puissance active moyenne
- ⇒ Puissance réactive moyenne
- ⇒ Déformation de  $I_{s1}$  par rapport à l’axe 2
- ⇒ Variance de  $I_{s2}$

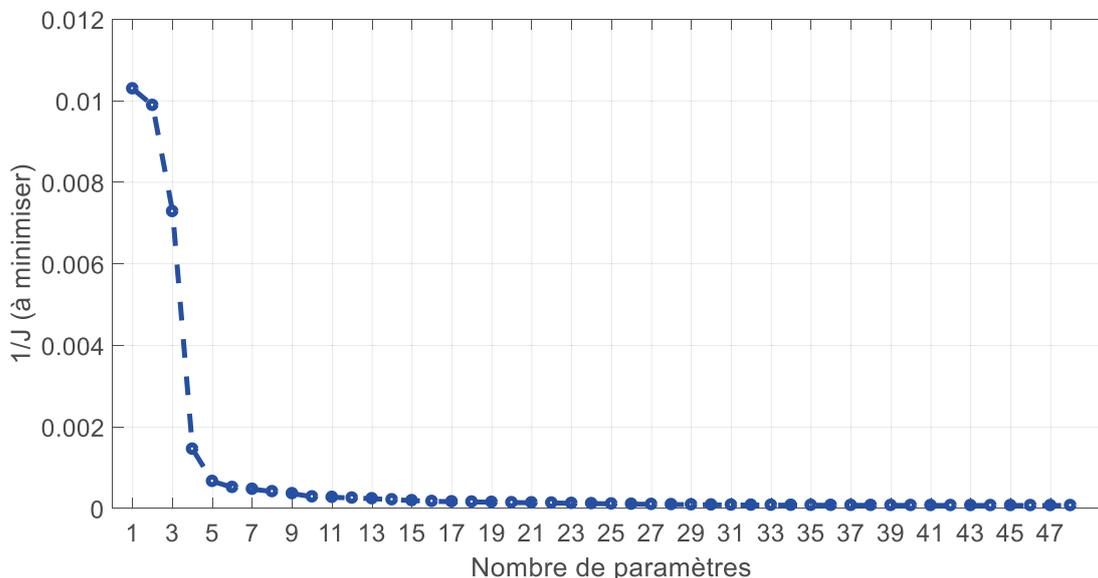


Figure IV.14 : Critère de sélection de paramètres - Deuxième base machine asynchrone

### 4.1.c - Validation sur les bases « pauvres »

#### 4.1.c.i - Critère de précision sur la base de test

Les résultats sur la première base sont les suivants :

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	<b>86.4</b>	73.96	58.34	75
Moyenne	<b>77.5</b>	72.5	50.84	65.42
Minimum	67.7	<b>69.8</b>	40.63	58.34

Tableau IV.5 : Précision sur la première base « pauvre » issue des essais machine asynchrone

L’algorithme par SVM – FA obtient les meilleurs résultats en moyenne, avec toutefois une variabilité de résultats importante. Le détail des résultats est donné sous forme de matrice de confusion. Au sein de cette matrice les colonnes représentent les occurrences des classes estimées, et les lignes les occurrences de classes réelles. La matrice de confusion de l’algorithme SVM - FA donne :

Classes Réel / Prédiction	Sain (D)	Roulements (D)	Barres Cassées (D)	Condensateur (ND)
Sain (D)	<b>100 %</b>	0 %	0 %	0 %
Roulements (D)	0 %	<b>99.17%</b>	0 %	0.83 %
Barres Cassées (D)	9.17 %	0 %	<b>81.67 %</b>	9.17 %
Condensateur (ND)	0 %	0 %	72.5 %	<b>27.5%</b>

Tableau IV.6 : Matrice de confusion pour l’algorithme SVM – FA (première base « pauvre » machine asynchrone)

Les classes saines et de défaut des roulements sont bien caractérisés. La classe des barres cassées est moins bien classifiée. Elle présente une erreur de l’ordre de 9%. Peu de points de la classe condensateur, non définie, sont correctement traités par la règle de décision. Cependant les points non rejetés sont bien classés en défaut, même si ce n’est pas la bonne classe. Les résultats de la règle de décision sont, pour chaque catégorie de points :

Catégorie / Taux de points	Maximum (%)	Moyenne (%)	Minimum (%)
Points rejetés en distance de classes définies	1.04	0.21	0
Points ambigus de classes définies	8.33	2.29	0
Points rejetés en distance de classe non définie	45.83	27.50	4.17
Points ambigus de classes non définies	0	0	0

Tableau IV.7 : Résultats règle de décision (première base « pauvre » machine asynchrone)

Une grande variabilité du taux de réjection est observée pour les points de la classe non – défini. La réjection se fait au prix d’un certain nombre de points de classes définies classés comme ambigus. Les résultats sur la deuxième base, qui se concentre sur le défaut barres cassées pour différentes sévérités, sont les suivants :

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	<b>87.5</b>	75	61.46	75
Moyenne	<b>81.4</b>	74.59	52.71	74.79
Minimum	<b>78.1</b>	73.96	46.88	73.95

Tableau IV.8 : Précision sur la deuxième base « pauvre » issue des essais machine asynchrone

Les résultats de l'algorithme par SVM – FA sont de nouveau et de manières plus nettes, meilleurs. Les résultats sont également moins variables. La matrice de confusion donne :

Classes Réel / Prédiction	Sain (D)	1 barre cassée (D)	4 barres cassées (D)	3 Barres cassées (ND)
Sain (D)	100 %	0 %	0 %	0 %
1 barre cassée (D)	0 %	94.17 %	0 %	5.83 %
4 barres cassées (D)	0 %	0 %	100 %	0 %
3 Barres cassées (ND)	0 %	52.5 %	12.5 %	35 %

Tableau IV.9 : Matrice de confusion pour l'algorithme SVM – FA (deuxième base « pauvre » machine asynchrone)

Les taux de classification sont bons pour toutes les classes définies. La règle de décision fonctionne un peu mieux que précédemment. A noter que les points non rejetés sont tout de même classés en défaut, même si ce n'est pas la bonne classe. Les résultats de la règle de décision de rejet sont, pour chaque catégorie de points :

Catégorie / Taux de points	Maximum (%)	Moyenne (%)	Minimum (%)
Points rejetés en distance de classes définies	7.29	1.46	0
Points ambigus de classes définies	0	0	0
Points rejetés en distance de classe non définie	66.67	14.17	0
Points ambigus de classes non définies	29.17	20.83	0

Tableau IV.10 : Résultats règle de décision (deuxième base « pauvre » machine asynchrone)

#### 4.1.c.ii - Critère du temps de calcul pour la phase de test

Les temps de calculs sur la première et sur la deuxième base correspondent à la classification de 96 points au total. Les temps de calculs sur la première base sont :

Temps Test (ms)	SVM - FA	ADD	KNN	BN
Maximum	48.5	6.26	14.9	9.26
Moyenne	24.4	2.86	5.06	4.44
Minimum	12.4	0.49	1.39	2.54

Tableau IV.11 : Temps de calculs pour la phase de test (première base « pauvre » machine asynchrone)

Les temps de calculs sur la deuxième base sont :

Temps Test (ms)	SVM - FA	ADD	KNN	BN
Maximum	102	6.67	14.5	83.9
Moyenne	47.4	2.84	5.04	38.2
Minimum	24.3	0.40	1.30	17.8

Tableau IV.12 : Temps de calculs pour la phase de test (deuxième base « pauvre » machine asynchrone)

Pour les deux bases, les temps de calculs les plus courts sont obtenus pour l’algorithme par arbre de décision. Néanmoins tous les temps de calculs, quel que soit la méthode, sont acceptables vis-à-vis de nos contraintes, en particulier pour un diagnostic préalable sur tarmac. En effet, le temps par observation est de l’ordre d’une milliseconde.

#### 4.1.c.iii - Critère de la mémoire de stockage

Les quantités de mémoire prises par les modèles entraînés sur la première base sont les suivantes :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Maximum	13.6	6.2	<b>4.5</b>	10.1

Tableau IV.13 : Mémoire de stockage sur la première base « pauvre » machine asynchrone

Sur la deuxième base, les mémoires de stockage sont :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Maximum	8.9	5.1	<b>3.8</b>	5.4

Tableau IV.14 : Mémoire de stockage sur la deuxième base ‘pauvre » machine asynchrone

La mémoire la plus faible est prise par les KNN. Celle la plus élevée est pour l’algorithme SVM – FA. Les deux semblent toutefois acceptables vis-à-vis des contraintes. Ce sera à confirmer lors de l’évaluation globale de la mémoire nécessaire pour l’architecture du système de diagnostic proposé.

### 4.1.d - Validation sur les « bases riches »

#### 4.1.d.i - Critère de précision sur la base de test

Les résultats sur la première base sont les suivants

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	<b>100</b>	75	75	75
Moyenne	<b>97.5</b>	73.34	71.67	74.17
Minimum	<b>91.67</b>	70.84	70.84	70.84

Tableau IV.15 : Précision sur la première base « riche » issue des essais machine asynchrone

L’algorithme par SVM –FA obtient des résultats assez stables, nettement supérieurs aux autres algorithmes. La matrice de confusion donne :

Classes Réel / Prédiction	Sain (D)	Roulements (D)	Barres Cassées (D)	Condensateur (ND)
Sain (D)	<b>100 %</b>	0 %	0 %	0 %
Roulements (D)	0 %	<b>93.33 %</b>	0 %	6.67 %
Barres Cassées (D)	0 %	0 %	<b>96.67 %</b>	3.33 %
Condensateur (ND)	0 %	0 %	0 %	<b>100 %</b>

Tableau IV.16 : Matrice de confusion pour l'algorithme SVM – FA (première base « riche » machine asynchrone)

Toutes les classes sont bien caractérisées. A noter que l'ensemble des points de la classe condensateur, non définie, sont bien rejetés. Les résultats de la règle de décision sont, pour chaque catégorie de points :

Catégorie / Taux de points	Maximum (%)	Moyenne (%)	Minimum (%)
Points rejetés en distance de classes définies	6.67	2.00	0
Points ambigus de classes définies	0	0	0
Points rejetés en distance de classe non définie	100.00	100.00	100.00
Points ambigus de classes non définies	0	0	0

Tableau IV.17 : Résultats règle de décision (première base « riche » machine asynchrone)

Les bons résultats de la règle de décision de rejet sont accompagnés d'un faible taux de rejets de points de classes définies. Les résultats sur la deuxième base sont les suivants :

Précision P (%)	SVM - FA	ADD	KNN	BN
Maximum	100	75	75	75
Moyenne	92.5	75	75	75
Minimum	83.84	75	75	75

Tableau IV.18 : Précision sur la deuxième base « riche » issue des essais machine asynchrone

La SVM – FA est la méthode la plus précise, avec cependant une variabilité importante.

Classes Réel / Prédiction	Sain (D)	1 barre cassée (D)	4 barres cassées (D)	3 Barres cassées (ND)
Sain (D)	93.33 %	0 %	0 %	6.67 %
1 barre cassée (D)	0 %	96.67 %	0 %	3.33 %
4 barres cassées (D)	0 %	0 %	93.33 %	6.67 %
3 Barres cassées (ND)	0 %	13.33 %	0	86.67 %

Tableau IV.19 : Matrice de confusion pour l'algorithme SVM – FA (seconde base « riche » machine asynchrone)

Les classes définies sont bien caractérisées. La classe non définie présente un bon taux de détection en ambiguïté. Les résultats de la règle de décision de rejet sont, pour chaque catégorie de points :

Catégorie / Taux de points	Maximum (%)	Moyenne (%)	Minimum (%)
Points rejetés en distance de classes définies	0	0	0
Points ambigus de classes définies	13.33	3.33	0
Points rejetés en distance de classe non définie	0	0	0
Points ambigus de classes non définies	100.00	86.67	66.67

Tableau IV.20 : Résultats règle de décision (deuxième base « riche » machine asynchrone)

Les résultats de la règle de rejet sont très variables, tout comme le taux de classification de points de classes définies. Cela peut s'expliquer par le fait que le cas « 3 barres cassées » n'est pas vraiment un cas de défaut combiné vis-à-vis d'une et quatre barres cassées.

#### 4.1.d.ii - Critère du temps de calculs en test

Les temps de calculs sur la première et sur la deuxième base correspondent à la classification de 24 points, de classes définies et non définies. Les temps de calculs sur la première base sont :

Temps Test (ms)	SVM - FA	ADD	KNN	BN
Maximum	32.8	<b>7.3</b>	14.8	8.8
Moyenne	14.6	<b>2.9</b>	5.0	4.2
Minimum	5.07	<b>0.38</b>	1.4	2.1

Tableau IV.21 : Temps de calculs pour la phase de test (première base « riche » machine asynchrone)

Les temps de calculs sur la deuxième base sont :

Temps Test (ms)	SVM - FA	ADD	KNN	BN
Maximum	95.1	<b>6.3</b>	15.0	8.2
Moyenne	42.4	<b>2.7</b>	5.0	3.8
Minimum	16.5	<b>0.43</b>	1.1	1.8

Tableau IV.22 : Temps de calculs pour la phase de test (seconde base « riche » machine asynchrone)

Encore une fois, pour les deux bases, les temps de calculs les plus courts sont obtenus pour l'algorithme par arbre de décision. Cependant tous les algorithmes présentent des temps largement acceptables vis-à-vis de nos applications.

#### 4.1.d.iii - Critère de la mémoire de stockage

Les mémoires prises par les modèles entraînés sur la première base sont les suivantes :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Maximum	17.0	11.8	<b>10.5</b>	16.1

Tableau IV.23 : Mémoire de stockage (première base « riche » machine asynchrone)

Sur la deuxième base les mémoires de stockage sont :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Maximum	9.2	7.64	<b>7.60</b>	8.37

Tableau IV.24 : Mémoire de stockage (seconde base « riche » machine asynchrone)

Pour les deux bases les mémoires de stockage sont acceptables vis-à-vis de nos applications.

## 4.2 - Machine synchrone (multi – sévérités)

### 4.2.a - Base de données

Des signatures sont extraites des mesures effectuées sur le banc du Green (Leboeuf 2012). Cela permet de construire deux bases. La première est constituée de deux classes : la première correspond à une MSAP saine ( $R_f = 100 k\Omega$ ) et la deuxième à une MSAP en défaut de court-circuit –

inter spires pour différents niveaux de sévérité ( $R_f = 2.4\Omega$ ,  $R_f = 1.2\Omega$ ,  $R_f = 0.6\Omega$ ). Cette base permet la détection du défaut.

La seconde base est constituée à partir de la seconde classe de la base une. Celle – ci est subdivisée en deux classes, chacune représentant un MSAP en défaut pour un niveau de sévérité ( $R_f = 2.4\Omega$  et  $R_f = 0.6\Omega$ ).

La troisième base ( $R_f = 1.2\Omega$ ) est utilisée pour le test de l'estimation de la sévérité.

Toutes les bases contiennent des mesures faites sur plusieurs points de fonctionnements. Chaque classe contient donc plusieurs points de fonctionnements (voir paragraphe 2.2 - page 118).

Base	Objectif	Nombre d'observations	$R_f (\Omega)$ (classe 1)	$R_f (\Omega)$ (classe 2)
1 (D)	Détection de défaut	1800	$R_f = 100000$	$R_f = 2.4$ $R_f = 0.6$
2 (D)	Classification de sévérité	900	$R_f = 2.4$	$R_f = 0.6$
3 (ND)	Estimation de sévérité	450	$R_f = 1.2$	

Tableau IV.25 : Base de données issue du banc MSAP

L'échelle de sévérité sera donc :

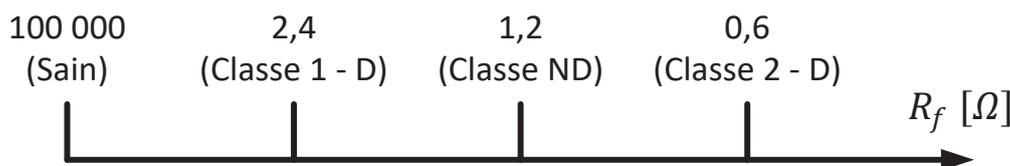


Figure IV.15 : Echelle de sévérité pour le paramètre  $R_f$

#### 4.2.b - Sélection de paramètres

La sélection de paramètres sur la première base donne un nombre de paramètres optimal entre 5 et 9. Après quelques tests de l'algorithme SVM – FA, le point optimal se situe pour  $p_{opt} = 6$ . Les paramètres à conserver sont :

- ⇒ La vitesse du moteur
- ⇒ La valeur efficace du courant  $I_q$
- ⇒ L'inductance statorique estimée par un filtre de Kalman
- ⇒ Résidus basés sur un modèle de machine saine simple
- ⇒ Résidus basés sur un modèle de machine saine simple saturé au premier harmonique d'espace
- ⇒ Résidus basés sur un modèle de référence en saturé avec prise en compte de certains harmoniques d'espace

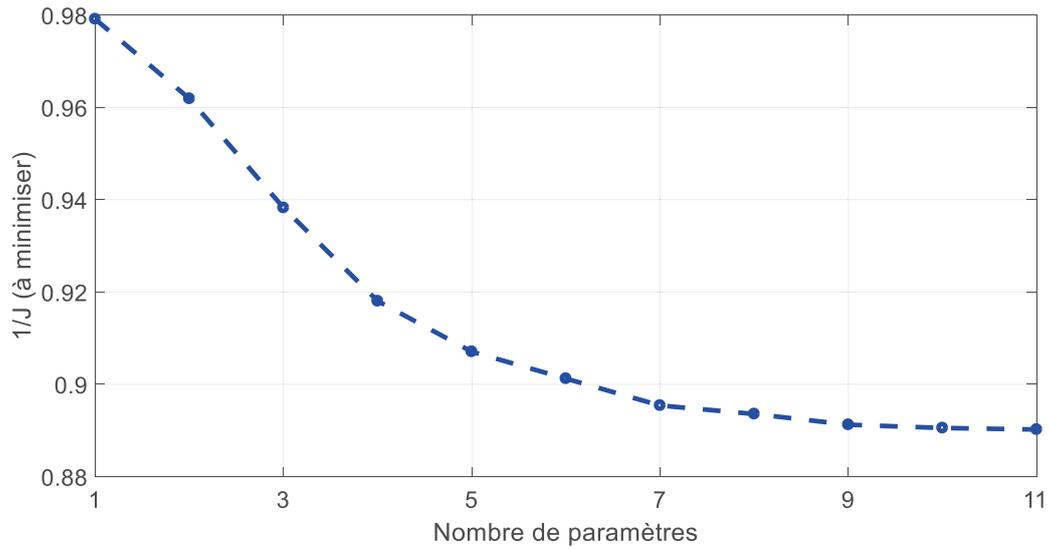


Figure IV.16 : Critère de sélection de paramètres – Première base machine synchrone à aimants

Pour la deuxième base (Breuneval et al. 2017), le nombre optimal de paramètres est compris entre 7 et 11. Après quelques tests de l’algorithme SVM – FA, le point optimal se situe pour  $p_{opt} = 7$ . Les paramètres à conserver sont :

- ⇒ La vitesse du moteur
- ⇒ L’inductance statorique estimée par un filtre de Kalman
- ⇒ La résistance statorique estimée par un filtre de Kalman
- ⇒ Résidus basés sur un modèle de machine saine simple
- ⇒ Résidus basés sur un modèle de machine saine simple saturé au premier harmonique d’espace
- ⇒ Résidus basés sur un modèle de référence en saturé avec prise en compte de certains harmoniques d’espace

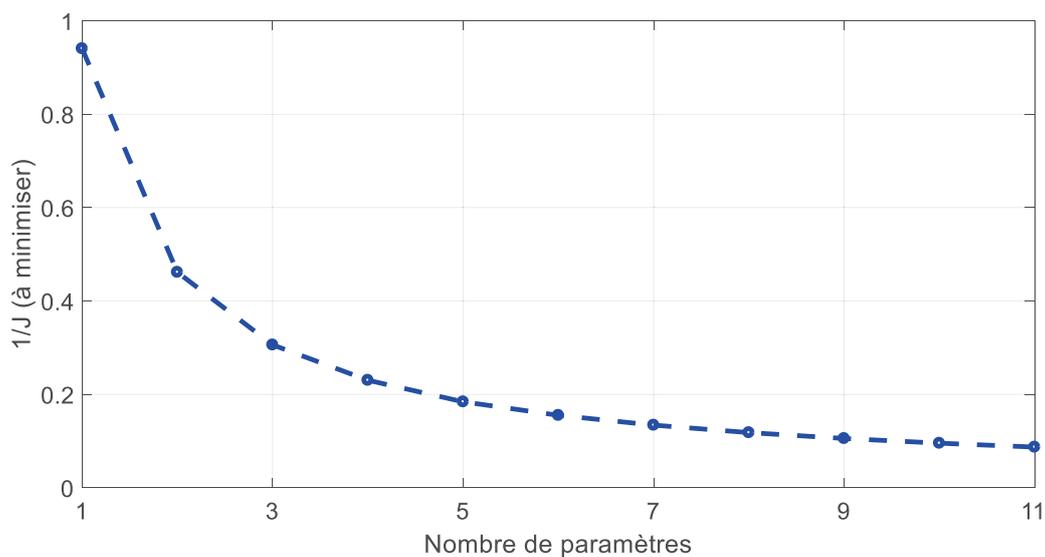


Figure IV.17 : Critère de sélection de paramètres – Deuxième base machine synchrone à aimants

## 4.2.c - Validation sur la « base pauvre »

### 4.2.c.i - Critère de précision sur la base de test

Les résultats sur la première base sont les suivants :

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	<b>93.2</b>	85.56	61.25	57.09
Moyenne	<b>90.45</b>	78.84	58.87	53.98
Minimum	<b>87.92</b>	73.06	55.98	52.23

Tableau IV.26 : Précision sur la première base « pauvre » issue des essais MSAP

La SVM – FA donne de très bons résultats, assez stables sur les itérations de la validation croisée. Ces résultats sont meilleurs que ceux des autres algorithmes. Pour la SVM – FA la matrice de confusion défaut est

Prédiction / Classes réelles	Sain	Défaut CC
Sain	<b>89.17 %</b>	10.83 %
Défaut CC	8.28 %	<b>91.7 %</b>

Tableau IV.27 : Matrice de confusion l’algorithme SVM – FA (première base « pauvre » MSAP)

Les deux classes sont bien caractérisées avec des taux supérieurs à 89%, dans le pire des cas. Les résultats sur la deuxième base, pour la classification de la sévérité, sont les suivants :

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	<b>93.89</b>	89.73	83.06	68.62
Moyenne	<b>88.5</b>	83.89	77.56	63.84
Minimum	<b>81.39</b>	78.89	71.67	56.12

Tableau IV.28 : Précision sur la deuxième base « pauvre » issue des essais MSAP

Les écarts entre la SVM – FA et les autres algorithmes se sont nettement réduits. La SVM – FA est encore meilleure, avec une variabilité qui devient importante. La matrice de confusion sévérité est

Prédiction / Classes réelles	$R_f = 2.4$	$R_f = 0.6$
$R_f = 2.4$	<b>95.44 %</b>	4.66 %
$R_f = 0.6$	81.56 %	<b>18.44 %</b>

Tableau IV.29 : Matrice de confusion l’algorithme SVM – FA (deuxième base « pauvre » MSAP)

La classification de la deuxième classe de sévérité est un peu faible, avec environ 81%. Une évaluation de la classe inconnue est effectuée avec la troisième base ( $R_f = 1.2\Omega$ ) :

Caractéristiques / Critère Evalué	$\hat{R}_f$ sur la base de test ( $\Omega$ )	Erreur (%)
Maximum	1.2756	6.30
Moyenne	1.2233	1.94
Minimum	1.1868	-1.10

Tableau IV.30 : Estimation de la sévérité  $R_f$  pour la base « pauvre »

L'erreur est ici très correcte puisqu'en dessous d'un intervalle de +/- 10% et donc sans confusion avec les autres taux de sévérité.

#### 4.2.c.ii - Critère du temps de calculs en test

Le temps de calcul total, de la détection de défaut à l'estimation de sévérité, est donné dans le Tableau IV.31. A noter que les algorithmes ADD, KNN et BN, n'estimant pas la sévérité, les temps de calculs obtenus seront inférieurs.

Temps (ms)	SVM - FA	ADD	KNN	BN
Maximum	109.53	<b>21.4</b>	35.6	20.67
Moyenne	59.69	<b>6.17</b>	11.93	8.9
Minimum	43.59	<b>0.889</b>	2.83	2.9

Tableau IV.31 : Temps de calculs pour la base « pauvre »

Tous les temps de calculs respectent les contraintes. L'algorithme par arbre de décision est le plus rapide.

#### 4.2.c.iii - Critère de la mémoire de stockage

Les mémoires maximales prises par les modèles entraînés sont les suivantes :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Modèle Défaut	<b>14.5</b>	28.2	18.5	17.6
Modèle Sévérité	<b>16.9</b>	27.5	20.1	19.4

Tableau IV.32 : Mémoire de stockage sur les bases « pauvre » issue des essais MSAP

Contrairement aux tests sur la base machine asynchrone, ici, c'est le classifieur par SVM – FA qui nécessite le moins de mémoire. Les mémoires nécessaires, pour tous les algorithmes, sont cependant dans le même ordre de grandeur.

### 4.2.d - Validation sur la « base riche »

#### 4.2.d.i - Critère de précision sur la base de test

Les résultats sur la première base sont les suivants :

Précision P (%)	SVM - FA	ADD	KNN	BN
Maximum	98.34	97.22	<b>98.89</b>	56.67
Moyenne	<b>97.23</b>	96.22	97.12	53.56
Minimum	<b>96.12</b>	93.89	95	51.67

Tableau IV.33 : Précision sur la première base « riche » issue des essais MSAP

Les meilleurs classifieurs sont les KNN et la SVM – FA. La précision moyenne de la SVM – FA est plus haute et sa variabilité plus réduite. Les KNN présentent eux la valeur maximale la plus élevée. Pour la SVM – FA la matrice de confusion est :

Prédiction / Classes réelles	Sain	Défaut CC
Sain	99.56 %	00.44 %
Défaut CC	5.11 %	94.89 %

Tableau IV.34 : Matrice de confusion l’algorithme SVM – FA (première base « riche » MSAP)

Les deux classes sont très bien discriminées, avec des taux supérieurs à 94%. Les résultats sur la deuxième base sont les suivants :

Précision $P$ (%)	SVM - FA	ADD	KNN	BN
Maximum	97.78	98.89	98.89	75.56
Moyenne	97.56	92.89	97.34	64.23
Minimum	96.67	87.78	95.56	56.67

Tableau IV.35 : Précision sur la deuxième base « riche » issue des essais MSAP

Les résultats peuvent laisser place à interprétation. La SVM – FA présente la précision moyenne la plus élevée avec une variabilité très faible. L’algorithme par ADD et les KNN ont cependant une précision maximale plus élevée. Leur variabilité est néanmoins plus importante, notamment pour l’ADD. Pour la SVM – FA la matrice de confusion de la classification de la sévérité est :

Prédiction / Classes réelles	$R_f = 2.4$	$R_f = 0.6$
$R_f = 2.4$	98.67 %	1.33 %
$R_f = 0.6$	3.66 %	96.44 %

Tableau IV.36 : Matrice de confusion l’algorithme SVM – FA (deuxième base « riche » MSAP)

Les deux classes sont très bien discriminées avec des taux au-dessus de 96%. L’estimation de la résistance de défaut donne :

Caractéristiques / Critère Evalué	$\hat{R}_f$ sur la base de test ( $\Omega$ )	Erreur (%)
Maximum	1,2484	4,03
Moyenne	1,2048	0,40
Minimum	1,1869	-1,09

Tableau IV.37 : Estimation de la sévérité  $R_f$  pour la base « riche »

L’estimation de la sévérité est ici très bonne avec une erreur maximum de 4%.

#### 4.2.d.ii - Critère du temps de calculs en test

Le temps de calcul total, de la détection de défaut à l’estimation de sévérité, est donné sur le Tableau IV.38. Comme pour la base « pauvre », les algorithmes ADD, KNN et BN n’estimant pas la sévérité, cela induit des temps de calculs plus faibles.

Temps (ms)	SVM - FA	ADD	KNN	BN
Maximum	58.8	<b>22.02</b>	35.33	23.24
Moyenne	34.08	<b>6.41</b>	12.71	8.92
Minimum	24.39	<b>0.957</b>	3.48	3

Tableau IV.38 : Temps de calculs pour la base « riche »

Une nouvelle fois, l'arbre de décision est le plus rapide. Tous les algorithmes respectent très largement les contraintes.

#### 4.2.d.iii - Critère de la mémoire de stockage

Les mémoires maximales prises par les modèles entraînés sont les suivantes :

Mémoire (kB)	SVM - FA	ADD	KNN	BN
Modèle Défaut	<b>54.1</b>	73.1	67.5	56.5
Modèle Sévérité	<b>60.1</b>	70.1	73.7	62.6

Tableau IV.39 : Mémoire de stockage sur les bases « riche » issue des essais MSAP

Le classifieur par SVM – FA est celui qui nécessite le moins de mémoire de stockage. Les mémoires nécessaires, pour tous les algorithmes, sont dans le même ordre de grandeur.

## 5 - Respect des contraintes

Les contraintes liées au cadre applicatif sont ici rappelées. Le temps de calcul maximum pour l'extraction de signatures est de 10 mn. Celui pour le diagnostic est d'une minute. La mémoire nécessaire pour le stockage long – terme des modèles de diagnostic est limitée à 8 Mbits (voir Contrainte 2 page 41).

### 5.1 - Pour l'extraction de signatures

La sensibilité des signatures aux défauts est le critère principal. Celle – ci n'a pas pu être évaluée expérimentalement ici à cause du manque de données. Les temps de calculs, eux, ont pu être évalués. Ils vont de 8 à 670 secondes, en fonction des méthodes utilisées. La majorité des méthodes respecte nos contraintes avec des temps de calculs inférieurs à 5 minutes. Les paramètres de réglages étant nombreux sur les deux méthodologies (sous échantillonnage, nombre maximum d'itérations...) des pistes existent pour réduire encore les temps de calculs, à puissance de calcul égale.

Au niveau de la mémoire, les données d'entrées des algorithmes ne nécessitent pas d'être stockées indéfiniment, notamment si l'extraction est lancée à la suite de l'acquisition. Ainsi la quantité de mémoire de stockage nécessaire à nos algorithmes d'extraction est très faible, de l'ordre d'une centaine de bits, comparée à celles des modèles de diagnostic par reconnaissances de formes. Elle est donc considérée comme négligeable.

## 5.2 - Pour le diagnostic

L'algorithme proposé arrive à atteindre des taux de classification corrects, de l'ordre de 80% pour peu de données disponibles (tests sur bases « pauvres »). La règle de décision peut détecter des points de classes inconnus ou ambigus, avec un taux de détection assez variable. Lorsque la quantité de données augmente, la précision passe au-dessus de 90%, ce qui est très correct. La règle de décision de rejet fonctionne beaucoup mieux, avec notamment 100% de points de classes inconnus détectés. L'estimation de la sévérité est correcte, largement à l'intérieur des limites de +/- 10% d'erreur, avec peu et beaucoup de données. L'objectif de robustesse semble donc être rempli partiellement avec peu de données et complètement lorsqu'une base de données suffisamment riche est disponible.

Les temps de calculs sont de l'ordre des millisecondes pour une observation. Ils sont donc très largement en dessous des contraintes. La puissance de calcul, pour le diagnostic, ne devrait donc pas être un problème.

En ce qui concerne la mémoire de stockage, tous les modèles entraînés au cours de nos tests, sur les deux bases, sont très largement en dessous de la limite de 8 Mbits. Qu'en est-il de l'ensemble de l'architecture de diagnostic proposée ? Pour estimer cela, trois hypothèses doivent être posées :

**Hypothèse 9 : Pour pouvoir passer d'un modèle de diagnostic RDF à  $c$  classes à un modèle à  $c' > c$  classes la base de données doit augmenter de  $\left(\frac{c'}{c}\right)^2$  bits.**

Cette hypothèse a deux aspects. Le premier est qu'afin d'ajouter une classe au modèle, le nombre de paramètres doit augmenter du nombre de paramètres moyen par classe. Ceci est conservatif puisqu'une seule signature bien conçue peut suffire pour discriminer une classe. Le deuxième aspect est que pour rajouter une classe, il faut obtenir un nombre d'observations supplémentaires, ici égal au nombre moyen d'observations par classe. Cet aspect est également conservatif puisque pour des signatures bien conçues, rajouter des observations n'améliorera pas significativement les performances. L'hypothèse est donc conservative.

**Hypothèse 10 : La mémoire nécessaire pour stocker un modèle SVM - FA évolue comme celle de la base nécessaire pour l'entraîner.**

C'est l'évolution qui est apparue entre les bases « pauvres » et « riches » pour les tests de la base MSAP. L'évolution pour les bases « machine asynchrone » a été beaucoup plus faible. Pour rester conservatif, l'évolution de la mémoire pour la base « MSAP » a été retenue comme référence.

**Hypothèse 11 : Les quantités de mémoire de référence pour le diagnostic et la sévérité sont celles obtenues pour la base MSAP « riche »**

Ce sont les quantités les plus importantes cela nous permet donc de rester conservatif. Ainsi, pour un seul défaut et deux sévérités, les quantités de mémoire de référence, qui serviront à l'évaluation de la quantité de mémoire maximale pour l'application finale, sont les suivantes :

Nombre de classe modèle défaut ( $c_{def}$ )	Mémoire modèle défaut (kB)	Nombre de classe modèle sévérité ( $c_{sev}$ )	Mémoire modèle sévérité pour un défaut (kB)
2	54,1	2	60,1

Tableau IV.40: Mémoires de références pour l'estimation de la mémoire nécessaire au stockage du modèle de diagnostic proposé

Le nombre de classes pour le défaut est toujours au minimum de deux, puisqu'il y a le cas sain et le cas de défaut. Notre objectif est de diagnostiquer trois cas de défaut : roulements, court – circuit inter –spires et VAR. On a donc  $c'_{def} = 4$ . Pour chaque cas de défaut, nous souhaitons avoir quatre cas de sévérités, d'où  $c'_{sev} = 4$ . Les quantités maximales de mémoire pour les deux unités de bases de notre modèle de diagnostic sont donc définies à partir des tests sur les bases expérimentales :

Nombre de classe modèle défaut ( $c'_{def}$ )	Mémoire modèle défaut (kB)	Nombre de classe modèle sévérité ( $c'_{sev}$ )	Mémoire modèle sévérité pour un défaut (kB)
4	$\left(\frac{c'_{def}}{c_{def}}\right)^2 * 54,1 = 216,4$	4	$\left(\frac{c'_{sev}}{c_{sev}}\right)^2 * 60,1 = 240,4$

Tableau IV.41 : Mémoires nécessaires des blocs élémentaires de l'algorithme de diagnostic proposé

La mémoire de stockage nécessaire pour l'ensemble de la solution proposée est donc :

$$(IV.2) \quad MEM = MEM_{def} + (c'_{def} - 1) * MEM_{sev}$$

Soit dans notre cas :

$$(IV.3) \quad MEM = 216,4 + 3 * 240,4 = 937,6 \text{ kB} \approx 1 \text{ Mbit}$$

La valeur estimée est très en dessous de la limite de 8 Mbits. Cela conforte le fait que la solution proposée peut être implantée dans un calculateur embarqué.

## 6 - Conclusion du chapitre

Dans un premier temps les algorithmes de calculs de signatures ont été testés sur des données issues d'un banc représentatif de l'architecture d'implémentation dans l'avion. L'identification des frottements converge bien, mais pour des temps de calculs un peu élevés. Une deuxième solution, consistant à n'utiliser que des points moyennés sur des paliers de vitesse, a été proposée. Celle – ci permet d'accélérer grandement la convergence, au prix d'une fonction coût plus élevée. L'algorithme d'analyse des courants parvient bien à isoler la composante du signal due au défaut de la VAR.

L'algorithme de diagnostic, proposé au chapitre précédent, a ensuite été testé sur deux bases expérimentales. La première représente des essais conduits sur une machine asynchrone, pour plusieurs cas de défauts. La deuxième représente des essais conduits sur un MSAP aéronautique

pour différentes sévérités d'un défaut de court – circuit. Pour chaque base, deux études sont faites, par validation croisée. La première sur une base « pauvre » (20% des données pour apprentissage, 80% pour test) et la deuxième sur une base « riche » (80% des données pour apprentissage, 20% pour test). Pour chaque étude l'algorithme proposé est comparé à plusieurs algorithmes issus de l'état de l'art. La méthode proposée s'avère être la plus robuste tout en restant en adéquation avec les contraintes de temps de calculs et de quantité de mémoire des modèles.

Maintenant que la validation de la partie diagnostic est effectuée, nous allons voir comment utiliser celle –ci pour aller vers une première estimation de la durée de vie restante des composants.

# V

## Vers le pronostic

Cohérence  
Prédiction Unités  
Normalisation  
Partitionnement SUR  
Pronostic  
Appartenances  
Roulements Horizon  
Séquences  
RUL

<b>V</b>	<b>VERS LE PRONOSTIC.....</b>	<b>142</b>
1	GENERALITES .....	145
1.1	<i>Problématiques du pronostic.....</i>	145
1.2	<i>Interprétation des incertitudes.....</i>	146
1.3	<i>Prise en compte des incertitudes.....</i>	146
1.3.a	Représentation des incertitudes.....	146
1.3.b	Quantification des incertitudes .....	147
1.3.c	Propagation des incertitudes .....	148
1.3.d	Gestion des incertitudes .....	148
1.4	<i>Phase de prédiction .....</i>	148
1.4.a	Taxonomie des méthodes.....	148
1.4.a.i	Basé sur la physique .....	148
1.4.a.ii	Basé sur les données .....	149
1.4.a.iii	Méthodes hybrides.....	149
	Hybride « série » .....	149
	Hybride « parallèle » .....	149
1.4.b	Stratégies multi – pas .....	150
1.4.b.i	Méthode itérative.....	150
1.4.b.ii	Méthode directe .....	151
1.4.b.iii	Méthode parallèle (MIMO).....	151
1.5	<i>Métriques d'évaluation .....</i>	152
1.5.a.i	Métriques de performance des algorithmes .....	153
	L'horizon de pronostic.....	153
	La performance $\alpha$ - $\lambda$ t.....	154
	La précision relative .....	155
1.5.a.ii	Métriques liées à l'implémentation.....	155
1.6	<i>Démarche proposée .....</i>	155
2	SOURCE DE DONNEES.....	157
3	SIGNATURES ISSUES DES DONNEES .....	158
3.1.a	Calcul de signatures statistiques .....	158
3.1.b	Définition de fin de vie par des experts .....	159
4	PARTITIONNEMENT DE SERIES TEMPORELLES.....	160
4.1	<i>Problématique .....</i>	160
4.2	<i>Positionnement .....</i>	160
4.3	<i>Choix d'un algorithme .....</i>	162
4.4	<i>Résultats du partitionnement.....</i>	164
4.4.a	Nombre de classes optimal.....	164
4.4.b	Partitionnement .....	164
4.4.c	Comparaison des temps de fin de vie .....	165
5	REGLAGE ET VALIDATION DU DIAGNOSTIC.....	165
5.1	<i>Problématique .....</i>	165
5.2	<i>Validation du classifieur – approche « Diagnostic ».....</i>	166
5.2.a	« One vs All » .....	166
5.2.b	« One vs One » .....	167
5.2.c	« One to Others » .....	168
5.2.d	Synthèse .....	170
5.3	<i>Validation du classifieur – approche « Pronostic ».....</i>	170
5.3.a	Normalisation par sigmoïde.....	170
5.3.b	Comparaison de méthodes de normalisation.....	171
5.3.c	Evaluation des performances.....	172
5.3.c.i	One Vs All.....	172
5.3.d	One Vs One .....	172

## Chapitre V : Vers le pronostic

6 - PREDICTION DES SIGNATURES .....	173
6.1 - Régression par SVR.....	173
6.1.a - SVR linéaire.....	173
6.1.b - SVR non linéaire.....	174
6.2 - Application aux roulements.....	174
7 - ESTIMATION DES APPARTENANCES.....	176
8 - ESTIMATION DE LA RUL .....	178
8.1 - Mise en place des métriques .....	178
8.1.a - Horizon de pronostic.....	178
8.1.b - La performance $\alpha\epsilon - \lambda t$ .....	178
8.2 - Test sur l'unité 1 .....	178
8.3 - Test sur l'unité 2 .....	179
8.4 - Test sur l'unité 3 .....	180
8.5 - Test sur l'unité 4 .....	180
8.6 - Synthèse .....	181
8.6.a - Métriques de performances .....	181
8.6.b - Estimation de la mémoire nécessaire .....	182
9 - CONCLUSION DU CHAPITRE .....	183

# 1 - Généralités

## 1.1 - Problématiques du pronostic

Le pronostic est défini, dans la norme ISO 13381 (**ISO 2004**), comme « *l'estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillances* ». Cette définition normative peut être interprétée de deux manières, chaque interprétation reposant sur des définitions de fin de vie différentes.

La première est que la fin de vie est atteinte lorsque la fonction n'est plus assurée. Cette vue est centrée sur le composant/système à l'étude et uniquement sur lui. La deuxième interprétation consiste à dire que le composant/système peut également atteindre la fin de vie lorsque son état d'endommagement accélère ou entraîne la dégradation d'autres composants/systèmes. Cette vue, holistique, consiste à voir le composant/système en interaction avec son environnement.

C'est la deuxième interprétation qui sera adoptée dans ce manuscrit, étant celle qui correspond le plus à notre cadre applicatif. Elle offre également l'avantage d'être conservatrice, puisqu'incluant la première.

La durée de fonctionnement avant défaillance, communément nommée RUL (*Remaining Useful Life*), est donc la grandeur qui doit être estimée par le module de pronostic. Pour les travaux présentés ici on fait l'hypothèse suivante

### Hypothèse 12 : La dégradation du système est monotone

Cette hypothèse repose sur le fait que le système ne rajeunit pas et n'est soumis à aucune action de maintenance pouvant le ramener à un état de santé antérieur. Ainsi la RUL réelle est linéairement décroissante avec le temps  $t$  :

$$(V.1) \quad RUL = t_{EOL} - t$$

Avec  $t_{EOL}$  : le temps de fin de vie (*End Of Life*).

Le temps lui-même peut être considéré de différentes manières en fonction des applications. On peut compter le temps écoulé depuis la mise en service. Le temps cumulé de fonctionnement peut également être utilisé. Pour un EMA cela correspond aux phases où l'actionneur est sous tension. Dans le cadre aéronautique, très strict en termes de traçabilité des composants, les deux informations temporelles sont disponibles. Dans le cadre de ces travaux de thèse, le temps cumulé de fonctionnement sera utilisé, ce qui impose l'hypothèse simplificatrice suivante :

### Hypothèse 13 : Le système se dégrade uniquement en fonctionnement

Pour le cadre aéronautique ici considéré, qui est celui des avions monocouloirs, les phases d'attentes, sur tarmac ou en hangar sont faibles comparées aux temps de fonctionnements. Ainsi, cette hypothèse est raisonnable.

Cependant les conditions environnementales en utilisation, en vol notamment, ont une grande importance. Or la prédiction de l'évolution de ces grandeurs dans le futur est entachée d'un certain nombre d'incertitudes. L'estimation de la RUL doit être accompagnée d'incertitudes. Ce dernier aspect n'est pas propre au cadre aéronautique, mais inhérent à l'activité de pronostic elle – même (**Sankararaman et Goebel 2013a**).

Les travaux de l'équipe du *Pronostic Center of Excellence* de la NASA ont fortement contribué à remettre la notion d'incertitudes au centre du pronostic (**Celaya et al. 2012a; Sankararaman et Goebel 2013a, 2015; Goebel et al. 2017**). Ils ont notamment mis en avant comment interpréter les incertitudes dans le cadre du pronostic. Deux interprétations sont possibles, chacune liée à une des deux familles de méthodes de pronostic.

## 1.2 - Interprétation des incertitudes

La première méthode repose sur des tests de fiabilité (**Sankararaman et Goebel 2013a**). Ils consistent à effectuer des essais de vieillissement en environnement très contrôlé. Les conditions de tests doivent être représentatives des conditions dans lesquelles évolueront les équipements en opération. Les méthodes de probabilité classiques (fréquentiste) peuvent alors être utilisées. Les incertitudes calculées représenteront la variabilité inhérente au sein d'une population d'équipements.

La deuxième méthode repose sur la surveillance de l'état du système et sur une projection dans le futur. Le système est alors considéré en lui – même et non plus vis-à-vis d'une population. L'état du système à déterminer est entièrement déterministe. Les incertitudes sont ici épistémiques, liées à un manque d'informations. L'apport de nouvelles données peut aider à réduire ces incertitudes. Les familles de méthodes applicables incluent alors les probabilités subjectives (bayésiennes) (**Ben-Gal 2008; Barber 2012; Mosallam et al. 2013**), les ensembles flous (**Zadeh 1965**), la théorie de l'évidence (**Shafer 1976**) ou encore la théorie des possibilités (**Zadeh 1978; Dubois et Prade 1999, 2011**). La projection dans le futur force le concepteur de l'algorithme à faire un ensemble d'hypothèses à partir des informations disponibles et de son expérience. Cela implique la création d'incertitudes liées à la confiance du concepteur en ses hypothèses et donc subjectives.

Dans le cadre des activités aéronautiques, la création d'une base de données suffisamment représentative et volumineuse est difficile, encore plus à des coûts raisonnables. Ainsi, c'est la deuxième approche qui sera adoptée dans ces travaux. Dans le cadre de cette méthode, nous allons décrire le processus généralement suivi pour prendre en compte des incertitudes.

## 1.3 - Prise en compte des incertitudes

La prise en compte des incertitudes pour le pronostic dans le cadre de la maintenance conditionnelle se fait au travers de quatre étapes : la représentation des incertitudes, leur quantification, leur propagation et enfin leur gestion. Les méthodes utilisables dans les trois dernières étapes dépendent directement du choix sur la méthode de représentation. Ainsi, pour ne pas alourdir le mémoire, les étapes seront présentées de manière générale, sans regard sur le type de méthode de représentation.

### 1.3.a - Représentation des incertitudes

Cette première étape consiste à choisir la méthodologie de représentation des incertitudes. Une

seule et même méthode sera utilisée pour l'ensemble des incertitudes. Comme évoqué précédemment, de nombreuses méthodes sont applicables. Ces méthodes sont plus ou moins adaptées en fonction de la quantité d'informations disponible (Nikolaidis et al. 2010). La Figure V.1 propose une hiérarchie des méthodes en fonction des informations (données et savoir a priori) disponibles.

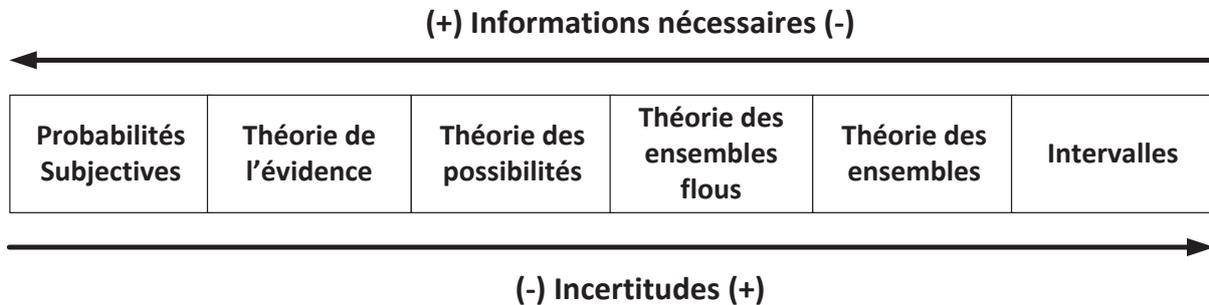


Figure V.1 : Méthode de représentation des incertitudes VS informations disponibles et quantités d'incertitudes (adapté de : (Nikolaidis et al. 2010))

### 1.3.b - Quantification des incertitudes

Une fois la méthode de représentation choisie, il est nécessaire d'identifier et de caractériser les sources d'incertitude. L'objectif est d'étudier chacune des sources d'incertitude séparément et de les quantifier. Celles – ci peuvent être classées en quatre familles : les incertitudes liées à l'état présent, celles liées au futur, celles liées à la modélisation pour estimer la RUL et enfin celles liées à la méthode de prédiction des incertitudes finales (Sankararaman et Goebel 2013a, 2015).

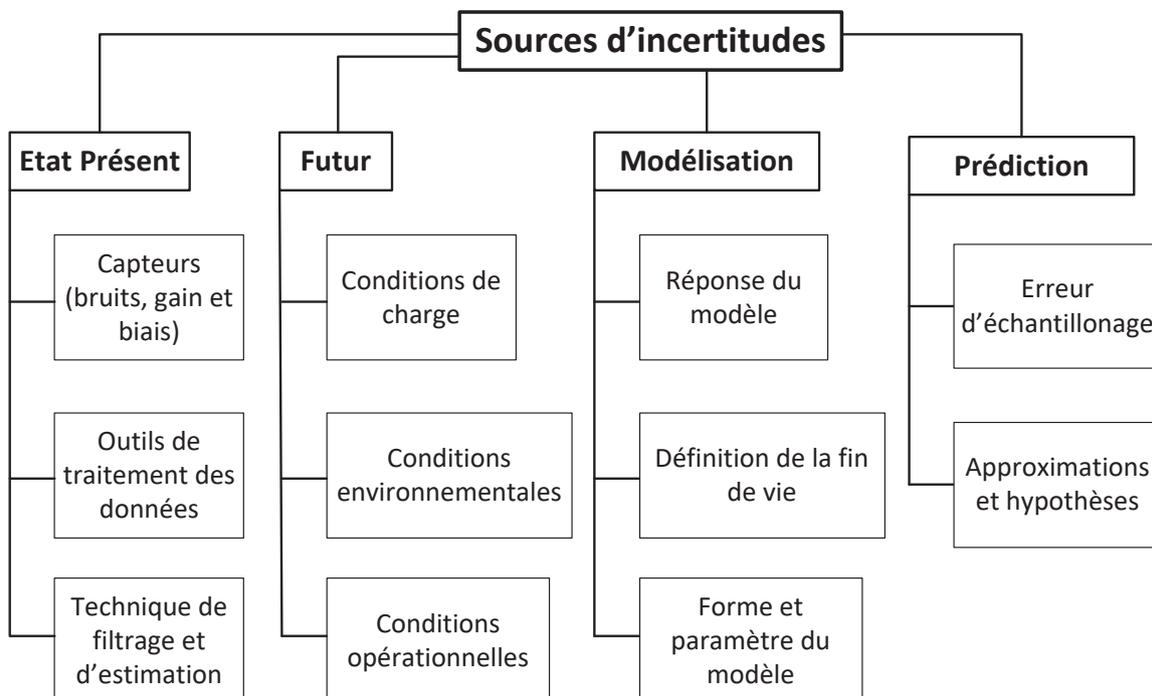


Figure V.2 : Différentes sources d'incertitudes (Sankararaman et Goebel 2015)

La première catégorie porte sur toutes les étapes précédentes au pronostic. Celles – ci permettent d'estimer l'état actuel du système. La qualité de l'acquisition de données est directement liée à celle de l'ensemble du système d'acquisition et entre autres des capteurs. Les méthodes de traitement de

données permettent de faciliter le calcul des signatures, mais ajoutent parfois de la variabilité. Les techniques permettant d'aboutir aux signatures sont, elles – mêmes, entachées de biais qui se combinent aux incertitudes précédentes.

Les incertitudes liées à la projection dans le futur sont les plus importantes, notamment celles sur les conditions de charges et environnementales. Pour être capable d'obtenir des résultats d'estimation de la RUL fiable, il faut donc être capable de les réduire au maximum.

L'estimation de la RUL nécessite un modèle, qui repose notamment sur des définitions de critères de fin de vie, eux – même incertains. Ce modèle lui-même n'est pas parfait et est donc source d'erreur.

Enfin les méthodes permettant de combiner l'ensemble des incertitudes précédentes sont également imparfaites et donc possiblement sources d'erreur. C'est le cas même si les incertitudes précédentes ont été estimées très précisément.

### **1.3.c - Propagation des incertitudes**

La phase de propagation consiste à combiner les incertitudes quantifiées pour estimer celle sur la RUL. Ainsi la forme de la distribution des incertitudes sur la RUL ne doit pas être arbitrairement choisie. Il s'agit d'une conséquence des formes des incertitudes identifiées.

### **1.3.d - Gestion des incertitudes**

Cette dernière étape concerne d'abord l'étude de l'influence des incertitudes sur les processus de décision. Dans un deuxième temps, lorsque suffisamment d'informations ont été récoltées pour pouvoir améliorer les algorithmes, une étude est réalisée en vue de les améliorer. Les plus gros contributeurs d'incertitudes sont identifiés afin de réduire leur influence. L'utilisation de capteurs plus performants peut, par exemple, réduire les incertitudes de certaines sources.

## **1.4 - Phase de prédiction**

Un élément central du pronostic est la phase de prédiction de l'évolution des signatures de défaut, ainsi que de l'état du système, en vue d'estimer le temps de fin de vie. Différentes méthodes existent : à base de modèles physiques, à base de données ou bien des méthodes hybrides (**Gouriveau et al. 2013; Javed 2014**). Dans la pratique les différentes familles sont le plus souvent combinées pour répondre aux contraintes des applications.

### **1.4.a - Taxonomie des méthodes**

#### *1.4.a.i - Basé sur la physique*

Ces méthodes reposent sur une modélisation explicite, sous formes d'équations, des processus de dégradations. Cela implique que ces processus ont des sources physiques connues (mécanique, thermique, chimique, électrique...) En mécanique, il s'agit en général de modèles de fatigue ou d'usure (2005). Un des avantages est que ces méthodes nécessitent peu de données. L'inconvénient est que le système à l'étude doit être très bien connu. Ainsi ce type de méthodes est en général utilisé pour les matériaux ou les composants, et non au niveau de systèmes complets. Les travaux actuels portent principalement sur des composants électroniques (**Kulkarni et al. 2009, 2012; Celaya et al. 2012b**) ou mécaniques (**Li et Lee 2005; Bolander et al. 2009**). Un autre inconvénient

est qu'un modèle est difficilement généralisable à d'autres composants / systèmes.

#### 1.4.a.ii - Basé sur les données

Cette famille de méthodes repose sur la disponibilité de données de surveillance de la dégradation d'un système dans le temps. Ces données permettent d'extraire des signatures de défauts, comme pour le diagnostic reposant sur les données (voir III.2.2 - 78). L'évolution de ces grandeurs dans le temps va permettre l'apprentissage automatique de modèles. Ces modèles vont permettre d'estimer le temps de fin de vie. Les familles de méthodes sont les mêmes que celles évoquées au chapitre III : basée sur la logique (Zhou et al. 2014), réseaux de neurones (Shao et Nezu 2000; Zurita et al. 2014; Cui et al. 2017; Soualhi et al. 2017), réseaux bayésiens et leurs dérivés (Tobon-Mejia et al. 2011; Medjaher et al. 2012; Bartram et Mahadevan 2013, 2017), basée sur des exemples (Khelif et al. 2014), basée sur les méthodes à noyaux et notamment les machines à vecteurs de supports (Soualhi et al. 2015; Satishkumar et Sugumaran 2016; Tao et Zhao 2016). Ces méthodes sont relativement simples à mettre en œuvre. Leurs performances sont néanmoins très liées à la qualité de la base de données utilisée.

#### 1.4.a.iii - Méthodes hybrides

##### Hybride « série »

Ce type de méthodes repose sur un modèle physique dont les paramètres sont estimés par des méthodes basées sur les données (Saxena et al. 2012; Baraldi et al. 2013; Mangili 2013).

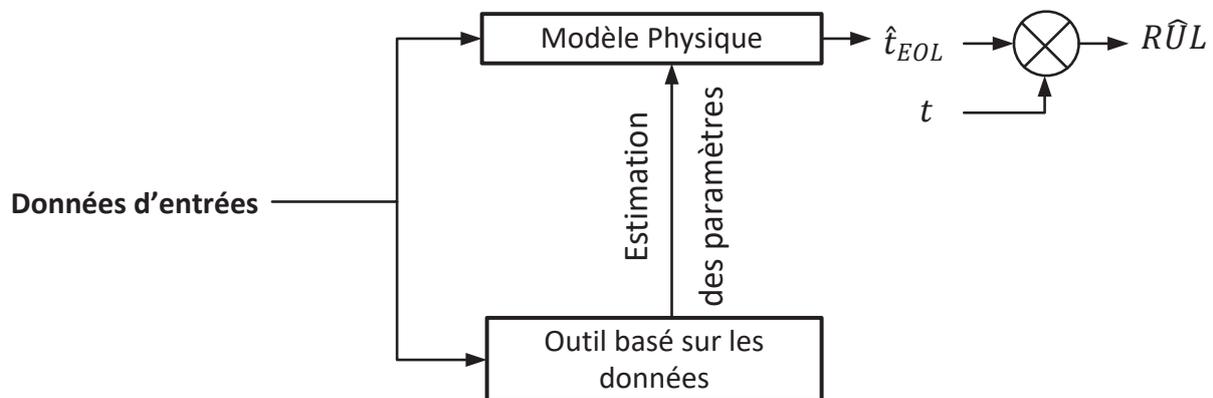


Figure V.3 : Schéma de principe d'un pronostic hybride série

Ces méthodes offrent de bonnes performances mais reposent très fortement sur la possibilité de trouver un modèle physique et sur l'applicabilité de celui – ci. Les coûts de calculs peuvent parfois être importants.

##### Hybride « parallèle »

Les sorties d'un modèle physique et d'une méthode basée sur les données sont combinées en vue d'estimer le temps de vie (Hansen et al. 1994; Kumar et al. 2008; Cheng et Pecht 2009; Jouin

2015).

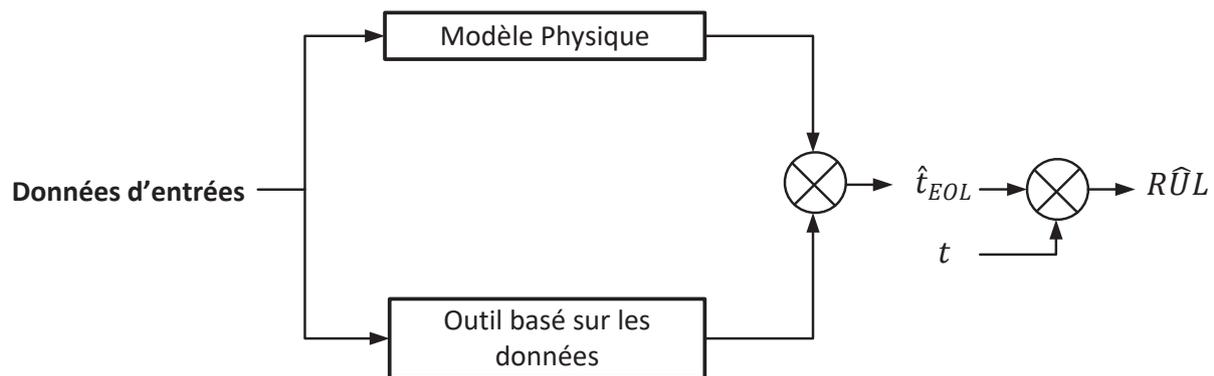


Figure V.4 : Schéma de principe d'un pronostic hybride parallèle

L'importance du modèle physique est un peu moins moindre que pour les méthodes hybrides série. Une modélisation plus fine des incertitudes est également possible. Néanmoins les coûts de calcul, pour la phase d'apprentissage notamment, ont tendance à augmenter.

### 1.4.b - Stratégies multi – pas

Les méthodes présentées précédemment peuvent être combinées de différentes manières pour effectuer des prédictions à plusieurs pas de temps. Ces prédictions se font à partir d'une séquence d'observations d'instantanés passés. Cela s'exprime sous la forme :

$$(V.2) \quad \hat{\mathbf{X}}_{t+1 \rightarrow t+hp} = f_P(\mathbf{X}_{t-no \rightarrow t}, \theta)$$

Avec :

- ⇒  $\mathbf{X}_{t-no \rightarrow t}$  la séquence de  $no$  observations des valeurs de signatures allant jusqu'à  $t$ . Ces observations peuvent concerner une unique signature, les coefficients de  $\mathbf{X}_{t-no \rightarrow t}$  seront à valeurs dans  $\mathbb{R}$ , ou plusieurs signatures, les coefficients seront alors à valeurs dans  $\mathbb{R}^p$ , avec  $p$  le nombre de signatures
- ⇒  $f_P$  : le modèle de prédiction,
- ⇒  $\theta$  les paramètres du modèle de prédiction
- ⇒  $\hat{\mathbf{X}}_{t+1 \rightarrow t+hp}$  : la séquence estimée jusqu'à l'horizon de prédiction  $hp$ .

Le nombre d'observations et l'horizon de prédiction sont le plus souvent fixés par l'utilisateur. Si tous les coefficients de  $\hat{\mathbf{X}}_{t+1 \rightarrow t+hp} \in \mathbb{R}$ , on parlera d'extrapolation univariée. Si les coefficients de  $\hat{\mathbf{X}}_{t+1 \rightarrow t+hp} \in \mathbb{R}^p$ , on parlera d'extrapolation multivariées. Ce second cas permet de tenir compte des corrélations entre signatures. Différentes méthodes existent pour associer des modèles de régression en vue d'effectuer un pronostic à horizon long (Gouriveau et Zerhouni 2012; Taieb et al. 2012; Bontempi et al. 2013).

#### 1.4.b.i - Méthode itérative

Cette méthode consiste à entraîner un modèle pour faire des prédictions à  $t + 1$ . Puis le même modèle est mis en série, de manière itérative, afin de faire une prédiction à  $t + hp$ . L'avantage de

cette méthode est qu'elle est assez aisée à mettre en œuvre. Le désavantage est que l'erreur s'accumule au fur et à mesure des prédictions.

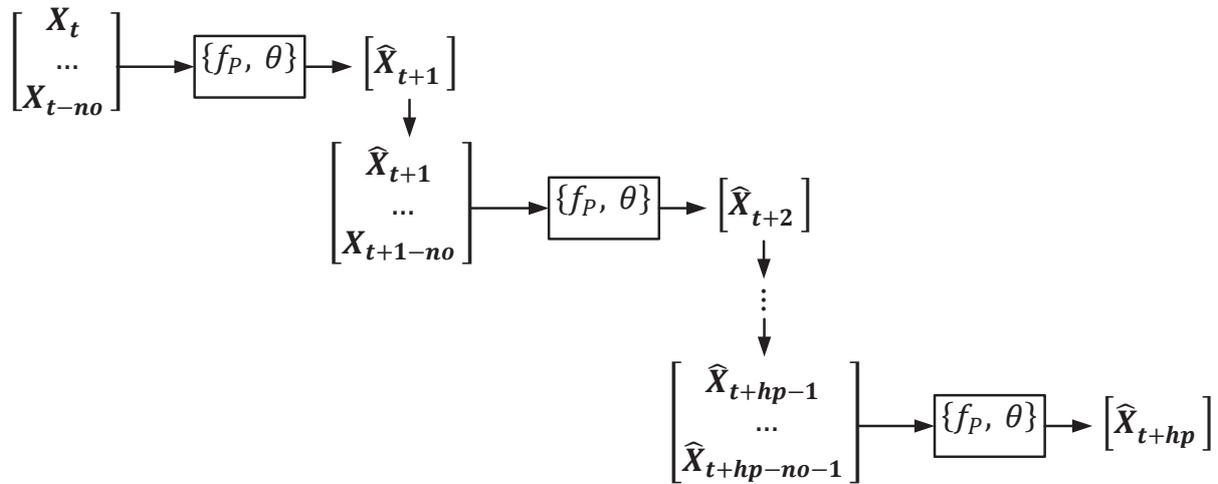


Figure V.5 : Illustration d'une prédiction itérative

#### 1.4.b.ii - Méthode directe

Cette méthode consiste à entraîner un modèle par horizon de prédiction de  $t + 1$  à  $t + hp$ . L'avantage de cette méthode est sa très bonne précision. Ses désavantages sont les coûts de calculs importants en apprentissage et la difficulté d'implémentation liée à l'utilisation de nombreux modèles.

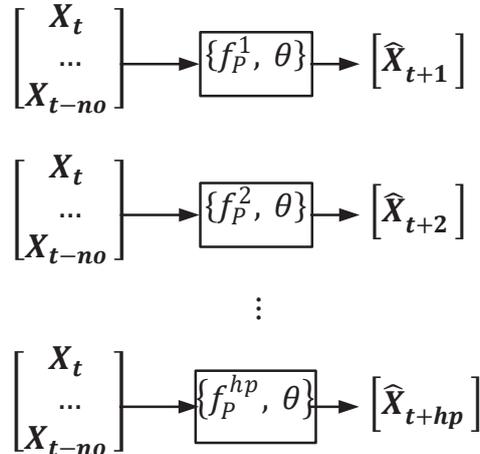


Figure V.6 : Illustration d'un ensemble de prédictions directes, à plusieurs horizons

#### 1.4.b.iii - Méthode parallèle (MIMO)

Cette méthode consiste à utiliser un modèle d'extrapolation à plusieurs entrées et à plusieurs sorties (*multi inputs multi outputs* : MIMO). Cette méthode s'avère plus précise que la méthode itérative. Elle a cependant le désavantage d'avoir, pour un modèle donné, un horizon de prédiction fixe, ce qui peut être pénalisant pour des prédictions à horizon long.

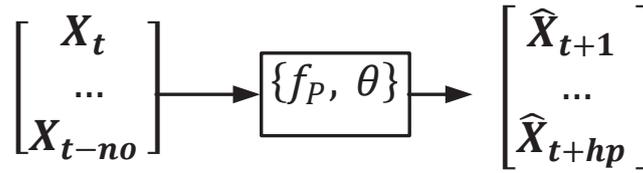


Figure V.7 : Illustration d'une prédiction parallèle

Comme montré dans (Gouriveau et Zerhouni 2012), les méthodes itératives et parallèles sont les plus pertinentes dans le cadre du pronostic de durée de vie. La méthode itérative semble être la seule à pouvoir atteindre des horizons de prédiction élevés. Dans le cadre des contraintes aéronautiques, il est nécessaire de tenir compte d'un facteur qui n'a pas été considéré dans les travaux précédemment cités : la mémoire nécessaire pour stocker les modèles. Vis-à-vis de ces contraintes, la méthode itérative semble être un bon choix en première approche. Le modèle mis au point devra cependant être évalué selon différentes métriques.

## 1.5 - Métriques d'évaluation

Les métriques d'évaluation permettent de spécifier les algorithmes de pronostic mais également de comparer plusieurs algorithmes selon différents critères (Saxena et al. 2008, 2009a, 2010, 2014).

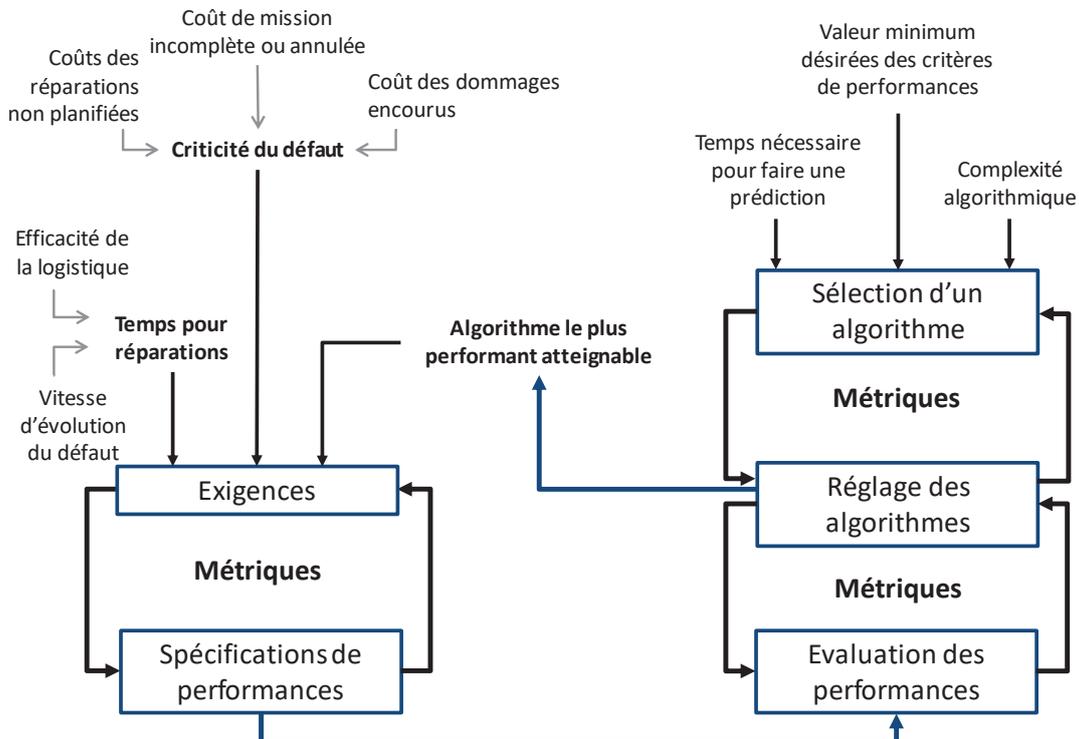


Figure V.8 : Métriques d'évaluation du pronostic pour la définition des exigences et la comparaison des performances (adapté de (Saxena et al. 2010))

Les principaux éléments permettant de définir les exigences sur les métriques sont : le coût d'une mission annulée, le coût de réparations non planifiées, le temps pour les réparations.

Seules les métriques de performances des algorithmes (précision...) et celles liées à l'implémentation

(temps de calculs...) seront considérés ici. Pour plus de détails sur les autres catégories voire l'annexe VIII11 - page 233.

### 1.5.a.i - Métriques de performance des algorithmes

De nombreuses métriques hors lignes existent. Au niveau des performances, parmi toutes celles existantes, nous avons retenu celles proposées dans (Saxena et al. 2009b, 2010). Elles consistent en l'application successive de quatre métriques : l'horizon de pronostic, la performance  $\alpha - \lambda$  (qui sera ici notée  $\alpha_e - \lambda_t$  pour éviter toute confusion de notations), la précision relative et la convergence. Seules les trois premières seront utilisées dans le cadre de ce mémoire, elles sont détaillées dans les sous – paragraphes suivants.

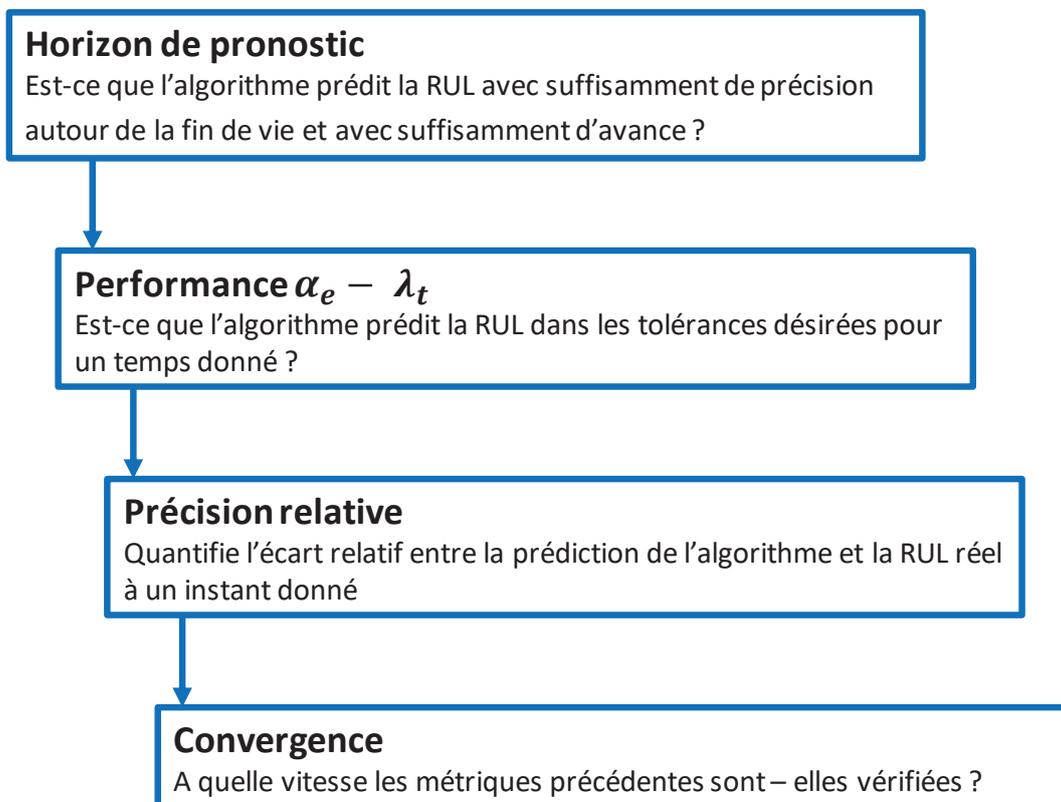


Figure V.9 : Métriques de performance successives pour le pronostic hors - ligne (issu de (Saxena et al. 2010))

#### L'horizon de pronostic

L'horizon de pronostic est l'écart entre le moment  $t_{\alpha_e\beta_e}$  où l'algorithme atteint les performances  $\alpha_e$  (exactitude) et  $\beta_e$  (précision) et le temps de fin de vie  $t_{EOL}$ . Il s'écrit ainsi :

$$(V.3) \quad PH = t_{EOL} - t_{\alpha_e\beta_e}$$

Ce critère peut s'exprimer à partir des moyennes des distributions de la RUL (voir Figure V.10 – (a)) où à partir des distributions elle – mêmes. On notera alors :

$$\Rightarrow RUL(k) : \text{RUL réelle à l'instant } t_k$$

- ⇒  $R\hat{U}L(k)$  : RUL estimée à l'instant  $t_k$
- ⇒  $\pi$  : distribution de la RUL
- ⇒  $\beta_e$  : degré de confiance (probabilité, possibilité...) minimum acceptable sur le centre de gravité de la distribution  $\pi$
- ⇒  $\pi[R\hat{U}L(k)]_{\alpha_e^-}^{\alpha_e^+}$  : distribution à l'instant  $t_k$  à  $\pm \alpha_e$  de la valeur de la RUL réelle

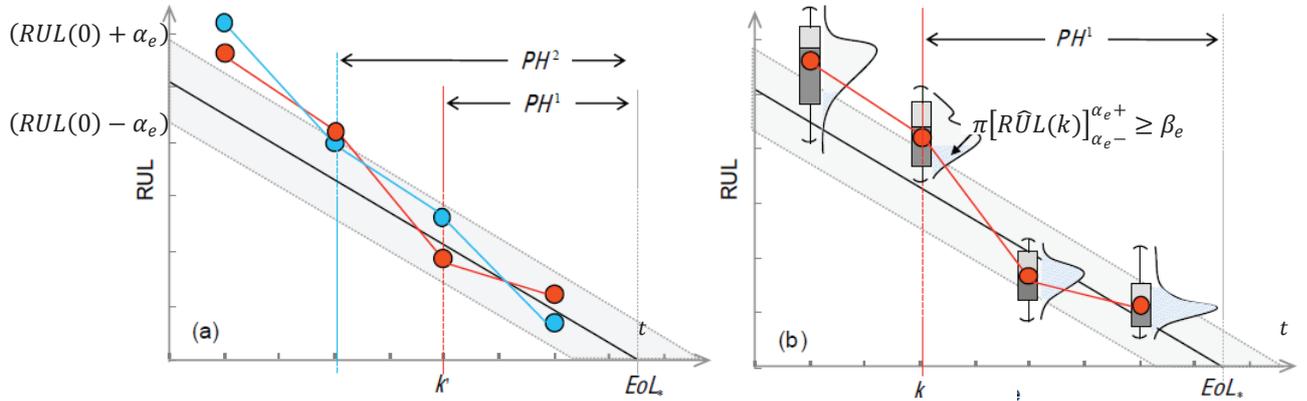


Figure V.10 : Horizon de pronostic : (a) comparaison de deux algorithmes selon le critère  $\alpha_e$  à partir des moyennes des distributions (b) : Evaluation d'un algorithme selon les critères  $\alpha_e$  et  $\beta_e$  à partir des distributions (Saxena et al. 2010)

Le meilleur horizon est obtenu lorsque l'algorithme est toujours dans l'intervalle de performance désiré et le pire lorsqu'il n'y est jamais. Dans ce cas,  $\alpha_e$  est l'intervalle d'incertitude sur la RUL initiale,  $RUL(0)$ .

#### La performance $\alpha_e - \lambda_t$

Cette métrique spécifie si l'estimation de l'algorithme est dans l'intervalle d'exactitude désiré ( $\alpha_e$ ) pour les temps spécifiés ( $\lambda_t$ ). Cela revient à exprimer  $\alpha_e$  comme une fonction décroissante du temps et non plus comme une constante. La constante  $\lambda_t \in [0,1]$ , spécifiée par l'utilisateur, permet de paramétrer le temps  $t_\lambda$  à partir duquel la prédiction doit être dans l'intervalle d'exactitude :

$$(V.4) \quad t_\lambda = t_{pred} + \lambda_t(t_{EOL} - t_{pred}) \forall t_{pred}$$

Avec  $t_{pred}$  : le temps de démarrage de la prédiction. Pour  $\lambda_t = 0$  la prédiction devra être dans l'intervalle dès son démarrage (très forte contrainte). Pour  $\lambda_t = 1$  la prédiction devra être dans l'intervalle qu'au moment de la fin de vie (très faible contrainte). Afin d'être conservatif, dans le cadre de ces travaux, on adoptera  $\lambda_t = 0$ . Le respect de cette métrique sera mesuré pour tous  $t \geq t_\lambda$  par :

$$(V.5) \quad P_{(\alpha_e - \lambda_t)}(k) = \begin{cases} 1 & \text{si } \pi[R\hat{U}L(k)]_{\alpha_e^-}^{\alpha_e^+} \geq \beta \\ 0 & \text{sinon} \end{cases}$$

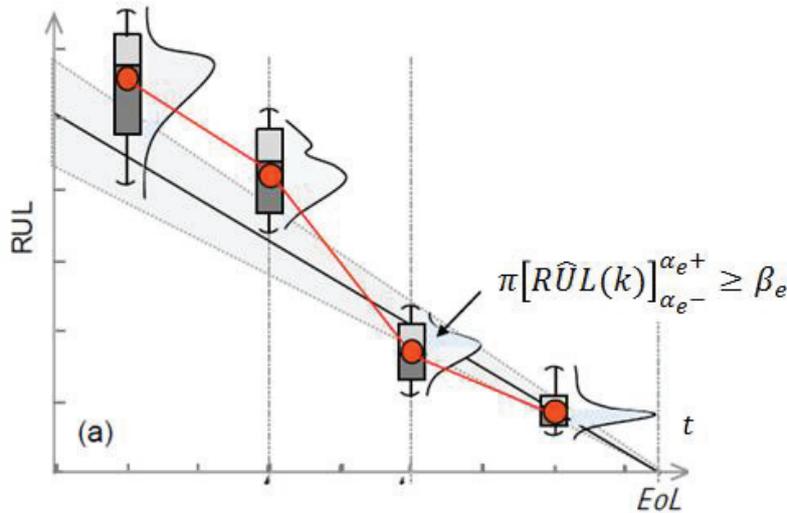


Figure V.11 : RUL vs Temps avec cône d'exactitude (Saxena et al. 2010)

Cette métrique est plus sévère que la précédente. L'idée derrière cette métrique est que la précision doit s'améliorer à mesure que la fin de vie approche.

### La précision relative

Cette métrique correspond à l'erreur sur la RUL normalisée par sa valeur réelle à un instant donné. Elle permet de mesurer l'exactitude quantitativement plutôt que de voir si elle tombe, ou non, dans un intervalle donné. Elle s'exprime à l'instant  $t_k$  par :

$$(V.6) \quad RA(k) = 1 - \frac{|R\hat{U}L(k) - RUL(k)|}{|RUL(k)|}$$

Cette métrique peut également être exprimée sur une période de temps  $T = [t_{start}; t_{stop}]$  au travers de la précision relative cumulée :

$$(V.7) \quad CRA(T) = \frac{1}{n_T} \sum_{k=t_{start}}^{t_{stop}} w(k)RA(k)$$

Avec  $n_T$  : nombre d'échantillons sur la période  $T$  et  $w(k) \in [0,1]$  le poids attribué à la RUL à l'instant  $t_k$ . Dans notre application, les poids seront tous pris égaux à 1.

### 1.5.a.ii - Métriques liées à l'implémentation

Comme pour la partie diagnostic au chapitre précédent, les temps de calculs pour les phases d'estimations de la RUL et la mémoire nécessaire aux modèles de prédiction, seront évalués.

## 1.6 - Démarche proposée

La démarche proposée sera présentée ici dans sa totalité en suivant le schéma de principe de la Figure V.12. La démarche repose sur l'hypothèse suivante :

**Hypothèse 14 : Une base de données représentative du vieillissement du système/composant est disponible**

Ici on considérera le cas d'une base de données représentant un temps discrétisé de façon uniforme. La démarche est constituée des étapes suivantes :

- ⇒ Le calcul de signatures de défauts
- ⇒ Le partitionnement des données pour créer des classes de sévérité successives
- ⇒ L'apprentissage d'un modèle de diagnostic de sévérité du défaut sur les données partitionnées
- ⇒ La validation de ce modèle
- ⇒ L'apprentissage d'un modèle de prédiction, pour chaque signature, et sa validation

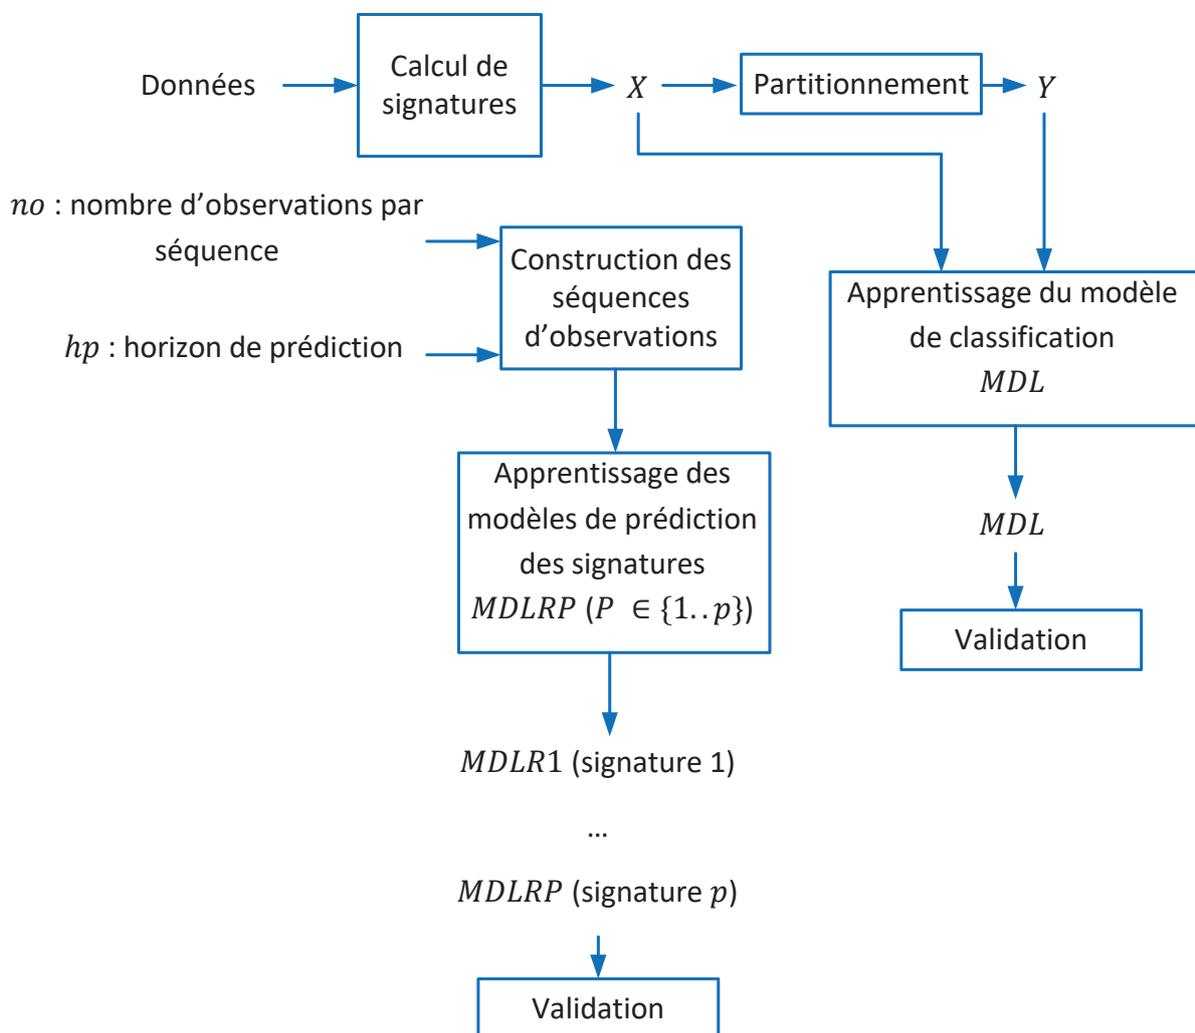


Figure V.12 : Démarche proposée pour la phase de développement (apprentissage) d'une solution permettant d'estimer la RUL

En phase de test, d'exploitation des modèles, les signatures seront calculées et conservées pour créer des séquences d'observation. A partir de ces séquences, l'évolution future des signatures est prédite. Cela permettra de créer des vecteurs de forme prédits de  $t + 1$  à  $t + hp$ . Le modèle de classification calcule alors les appartenances  $u_j$  aux classes de sévérité. Le point  $q$  où l'appartenance

à la dernière classe  $c$  devient la plus élevée est calculé. Il correspond au temps de fin de vie estimé à partir duquel on peut calculer la RUL estimée.

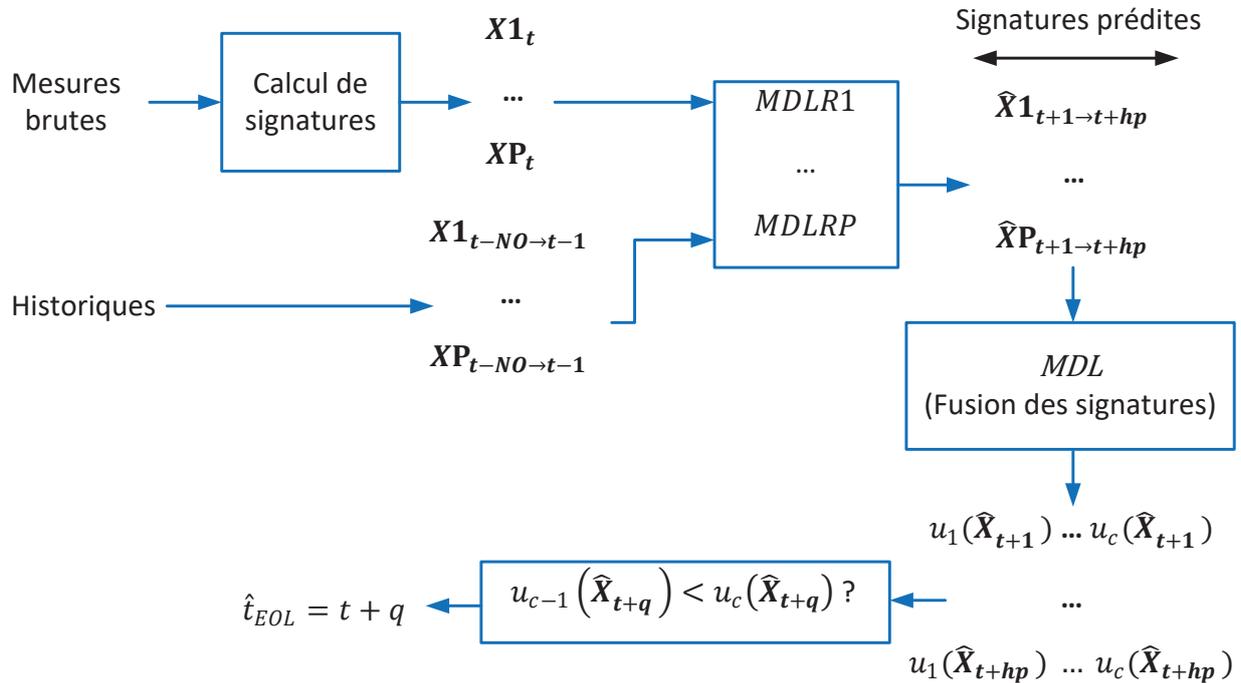


Figure V.13 : Démarche proposée pour l'exploitation (test) des modèles

De nombreuses problématiques ont été rencontrées au cours des travaux sur cette partie. Afin de les mettre en évidence, ainsi que les méthodes proposées pour les résoudre, les aspects théoriques et applicatifs seront présentés successivement, pour chaque partie. La partie applicative a été faite sur une base publique de vieillissement de roulements.

## 2 - Source de données

Les données utilisées proviennent d'une base benchmark de vieillissement de roulements, issue d'essais menés au *Center for Intelligent Maintenance System (IMS)* de l'Université de Cincinnati (**Qiu et al. 2006; Lee et al. 2007**). Quatre roulements à rouleaux sont placés sur un même arbre, tournant à 2000 t/min. Un mécanisme à ressort applique une charge radiale constante de 6000 livres soit 26 698 N. Un système de circulation d'huile assure la bonne lubrification des roulements. Un bouchon magnétique placé dans le circuit de retour d'huile attire les particules métalliques issues de la dégradation des roulements. Lorsqu'un certain nombre de particules a été atteint, un interrupteur bascule, ce qui arrête l'essai. Des accéléromètres et des thermocouples effectuent des mesures sur chaque roulement. Les accéléromètres sont des PCB 353B33 placés sur les axes horizontaux et verticaux. Ils effectuent leurs mesures à 20 kHz, toutes les 20 minutes, par l'utilisation d'une carte d'instrumentation. Les mesures commencent après un jour d'essai.

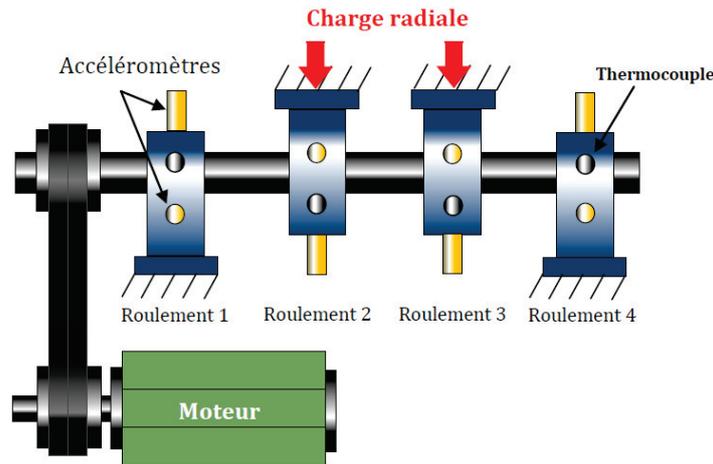


Figure V.14 : Banc de vieillissements des roulements (Soualhi 2013)

## 3 - Signatures issues des données

### 3.1.a - Calcul de signatures statistiques

Diverses techniques de calculs de signatures peuvent être mises en œuvre. Soualhi (Soualhi 2013) a mis en œuvre des calculs statistiques à partir des signaux vibratoires. En se basant sur ces travaux, la valeur efficace et la puissance du signal vibratoire calculée à partir du signal sur l'axe horizontal seront utilisées dans ce manuscrit. Le temps, depuis le démarrage de l'essai, fera également partie du vecteur de forme. Ce dernier peut correspondre, dans le cas aéronautique, au compteur d'heures de vol d'un équipement. Ce type d'informations est classiquement disponible sur les calculateurs d'actionneurs de commande de vol. On observe une augmentation légère des signatures entre 0 et 10 jours, qui correspondent à une phase de rodage. Suit une phase de quasi – constance jusqu'à environ 30 jours. Puis, les paramètres augmentent très rapidement, de manière exponentielle, signe de la dégradation accélérée du roulement, annonciatrice de la fin de vie.

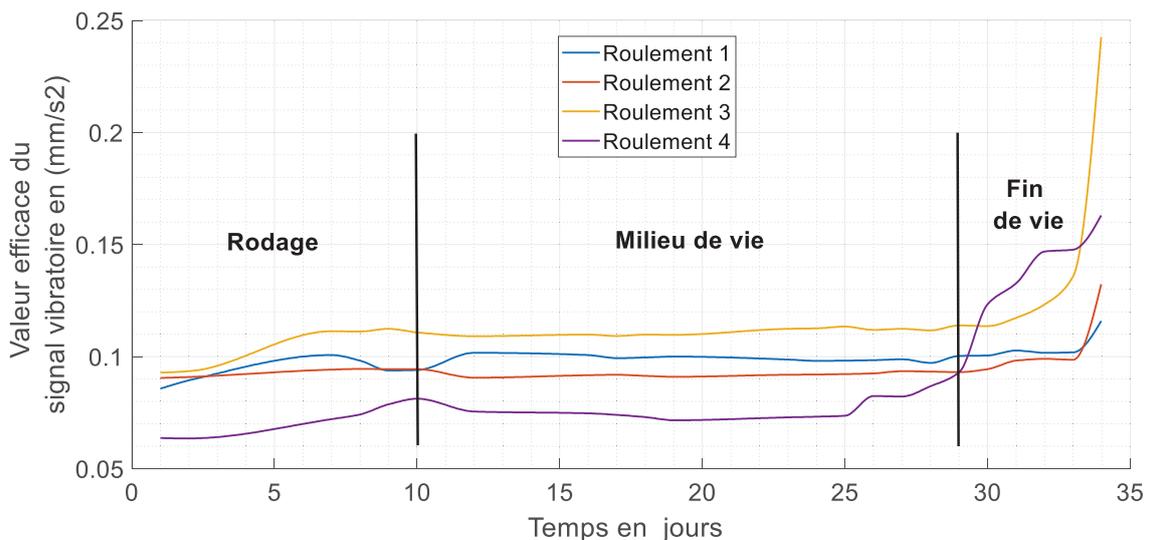


Figure V.15 : Valeur efficace du signal vibratoire en fonction du temps

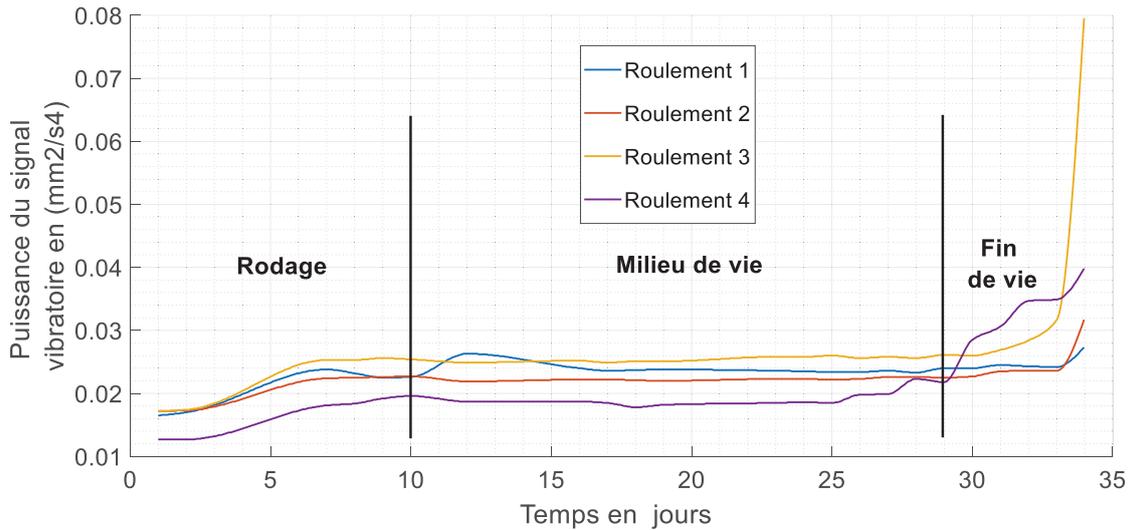


Figure V.16 : Puissance du signal vibratoire en fonction du temps

### 3.1.b - Définition de fin de vie par des experts

La majorité des travaux sur l'estimation de la RUL pour les roulements considère que celle – ci est directement disponible dans la base de données (Jammu et Kankar 2011; Medjaher et al. 2012; Nectoux et al. 2012; Javed 2014; Soualhi et al. 2015). Très peu de travaux donnent une définition reposant sur un critère physique précis (Bolander et al. 2009). Ce type de définition nécessite d'analyser finement les roulements post – essais. Nous ne disposons pas de telles analyses pour la base IMS. Certains travaux considèrent que la fin de vie est atteinte lorsqu'une signature dépasse un certain seuil (Soualhi et al. 2015). Une manière de définir ce seuil, « par expert », est de considérer la zone où la signature forme un coude. Cette zone correspond au moment où la signature commence à varier nettement plus rapidement.

En suivant cette définition, pour les deux signatures sélectionnées et sur les quatre unités sous test considérées, les définitions de fin de vie suivantes peuvent être données :

Unité / Critère	Début du coude (Puissance du signal vibratoire)	Fin du coude (Puissance du signal vibratoire)	Début du coude (Valeur Efficace du signal vibratoire)	Fin du coude (Valeur Efficace du signal vibratoire)
1	33,1	33,1	33	33
2	33	33	33	33
3	30	33,1	30	33
4	25,2	29,1	25,2	27,2

Tableau V.1 : Temps de fin de vie des roulements déterminés par « expert » selon différents critères

Il apparait que cette méthode produit de bons résultats lorsque les signatures montrent un coude très brusque. Reste néanmoins l'incertitude inhérente à toute lecture graphique de valeur. Pour les courbes présentant un coude moins net, la détermination du temps de fin de vie montre plus de variabilité. Celle-ci sera nécessairement liée à l'expert effectuant les lectures graphiques. Pour pallier ces défauts, la définition de fin de vie donnée dans (Soualhi 2013) sera reprise. Cette définition peut

se traduire par l'hypothèse suivante

**Hypothèse 15 : Le temps de fin de vie est atteint lorsque le composant / système atteint la dernière classe de sévérité du défaut**

Cette définition implique un partitionnement en classes de sévérité des observations dans le temps.

## 4 - Partitionnement de séries temporelles

### 4.1 - Problématique

L'objectif est d'identifier, à partir des  $m_u$  observations effectuées sur  $n_u$  unités testées, les différentes sévérités de défauts présentes dans la base de données. Ainsi, il faudra partitionner  $m = m_u * n_u$  observations. Chaque observation correspond à un vecteur de forme de  $p$  paramètres. Une unité est donc représentée par  $p$  séries temporelles (une série par signature du vecteur forme). Les classes obtenues devront être cohérentes temporellement au niveau de l'ensemble des unités. Pour chaque unité testée, chaque classe sera définie par un temps de démarrage  $t_{start}$  et par un temps de fin  $t_{stop}$ . De par les hypothèses prises, les classes de sévérités se succèdent de la moins à la plus sévère. Ainsi,  $t_{stop}$  d'une classe sera  $t_{start}$  de la suivante. Une méthodologie par algorithme de partitionnement sera présentée ici. Elle sera comparée à la méthode « manuelle », par connaissance d'expert.

### 4.2 - Positionnement

Le partitionnement de séries temporelles contient trois grandes catégories de problèmes (**Liao 2005; Fu 2011; Aghabozorgi et al. 2015**) : le partitionnement de séries temporelles entières (« *whole time series clustering* »), le partitionnement de sous – séquences (« *subsequences clustering* ») et le partitionnement de points temporels (« *time point clustering* »). Le partitionnement de séries entières consiste à considérer chaque série comme un objet et à former des groupes de séries entières. Cela est équivalent à du partitionnement classique mais en utilisant des séries temporelles entières plutôt que des vecteurs de formes. Le partitionnement de sous – séquences vise à déterminer des sous – séquences qui se répètent dans une unique série temporelle. Le partitionnement des points de séries temporelles consiste à attribuer des classes sur la base d'une proximité temporelle et de valeurs, au sein d'une unique série.

Aucune de ces catégories ne correspond exactement à notre problématique. Le partitionnement de série entière ne convient pas puisque l'objectif recherché est de trouver des séquences successives. Le partitionnement de sous-séquences ne convient pas non plus puisqu'il travaille à partir d'une seule séquence. Il en va de même pour le partitionnement de points temporels. La problématique est ici de traiter  $n_u * p$  séquences, liées entre elles. Ainsi la question reste ouverte. Autre point important, non traité dans la littérature à notre connaissance, les séquences obtenues devront être cohérentes temporellement. Une proposition de définition de cohérence temporelle du partitionnement est ici donnée. Elle repose sur trois critères :

- ⇒ Le nombre de classes est identique d'une unité à une autre
- ⇒ Chaque classe est continue temporellement, elle ne présente pas de « saut » dans le temps
- ⇒ Les classes se succèdent dans le même ordre d'une unité à une autre

La métrique suivante est proposée pour mesurer cette cohérence sur des observations d'une unité rangées dans l'ordre du temps croissant :

$$(V.8) \quad CT_k = \sum_{i=2}^{m_u} ct(x_k^{(i)}, x_k^{(i-1)})$$

Avec  $x_k^{(i)}$  :  $i^{\text{ème}}$  observation mesurée pour l'unité  $k$  et  $ct$  : la cohérence temporelle entre deux observations successives définie par :

$$(V.9) \quad ct(x_k^{(i)}, x_k^{(i-1)}) = \begin{cases} 1, & \text{si } y_k^{(i)} = y_k^{(i-1)} \\ 0, & \text{si } y_k^{(i)} \neq y_k^{(i-1)} \end{cases}$$

Avec  $y_k^{(i)}$  : classe de l'observation  $x_k^{(i)}$ .

Pour une unité donnée, le partitionnement obtenu est parfaitement cohérent pour  $CT_k = c - 1$ , le nombre de classes moins un. A l'inverse si le partitionnement est totalement incohérent :  $CT = m_u - 1$ . Pour faciliter l'interprétation de la métrique ainsi que son utilisation pour des comparatifs, une version équivalente est définie à valeurs dans  $[0, 1]$  :

$$(V.10) \quad CTN_k = \frac{\sum_{i=2}^{m_u} ct(x_k^{(i)}, x_k^{(i-1)}) - (c - 1)}{m_u - c}$$

Pour un partitionnement parfaitement cohérent temporellement  $CTN = 0$ . Pour un partitionnement totalement incohérent  $CTN = 1$ . Pour un partitionnement où le nombre de classes est différent d'une unité à une autre  $CTN < 0$ . On peut maintenant calculer la cohérence temporelle globale, sur toutes les unités, par :

$$(V.11) \quad CTG = \frac{\sum_{i=1}^{n_u} |CTN_i|}{n_u}$$

Avec  $| \cdot |$  : la valeur absolue.

Cette métrique permet de vérifier les deux premiers critères, le nombre de classes identiques par unité et la continuité temporelle, mais pas le troisième. Celui-ci peut néanmoins être vérifié en traçant l'évolution des signatures dans le temps pour les observations partitionnées.

Pour un nombre de classes donné, si plusieurs algorithmes sont parfaitement cohérents, une deuxième métrique peut être évaluée. Il s'agit de la métrique d'énergie, qui doit être minimisée, pour avoir les classes les plus compactes possibles, calculée par :

$$(V.12) \quad E_{par} = \frac{1}{2} \sum_{i \in \{1, \dots, c\}} \sum_{x^{(j)} \in \Omega_i} \|x^{(j)} - g_i\|_d^2$$

Avec  $\Omega_i$  : l'ensemble des observations de la  $i^{\text{ème}}$  classe,  $x^{(j)} \in \mathbb{R}^p$  : observation,  $g_i$  : centre de gravité de la  $i^{\text{ème}}$  classe,  $d$  : mesure de distance définie par :

$$(V.13) \quad d_{ij}^2 = d(x^{(j)}, g_i)^2 = \|x^{(j)} - g_i\|_d^2 = (x^{(j)} - g_i)^T A_d (x^{(j)} - g_i)$$

Avec :  $A_d$  : Matrice semi – définie positive définissant la métrique de distance  $d$  (choisie par l'utilisateur),  $\| \cdot \|_d$  : Norme correspondante à la distance  $d$ .

Dans ces travaux, la distance euclidienne sera adoptée avec  $A_d = I$ , la matrice identité. Quatre algorithmes, utilisés pour le partitionnement classique, ont été essayés : l'algorithme des k – moyennes (**MacQueen 1967**), celui des k – médianes (**Kaufman et Rousseeuw, 1987**), celui des c – moyennes floues (**Bezdek 1981; Bezdek et al. 1984**) et celui des c – moyennes floues possibilistes (**Pal et al. 2005**).

### 4.3 - Choix d'un algorithme

Les quatre algorithmes traitent la base de données pour un nombre de classes allant de 2 à 10. Pour chaque nombre de classe et pour chaque algorithme la cohérence temporelle normalisée est calculée.

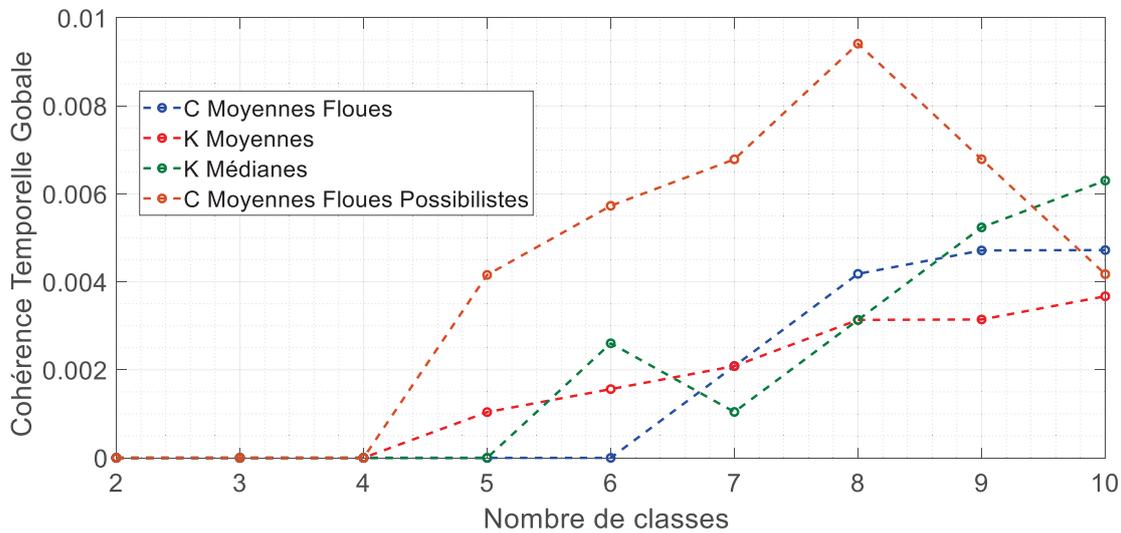


Figure V.17 : Cohérence temporelle globale pour différents algorithmes

Premier point notable : tous les partitionnements sont incohérents, quel que soit l'algorithme choisi, pour  $c > 6$ . Deuxième point notable : seul l'algorithme par c – moyennes floues donne des résultats cohérents entre  $c = 4$  et  $c = 6$ . Pour trancher nettement la question on évalue la métrique d'énergie (V.12) pour  $c$  allant jusqu'à 6.

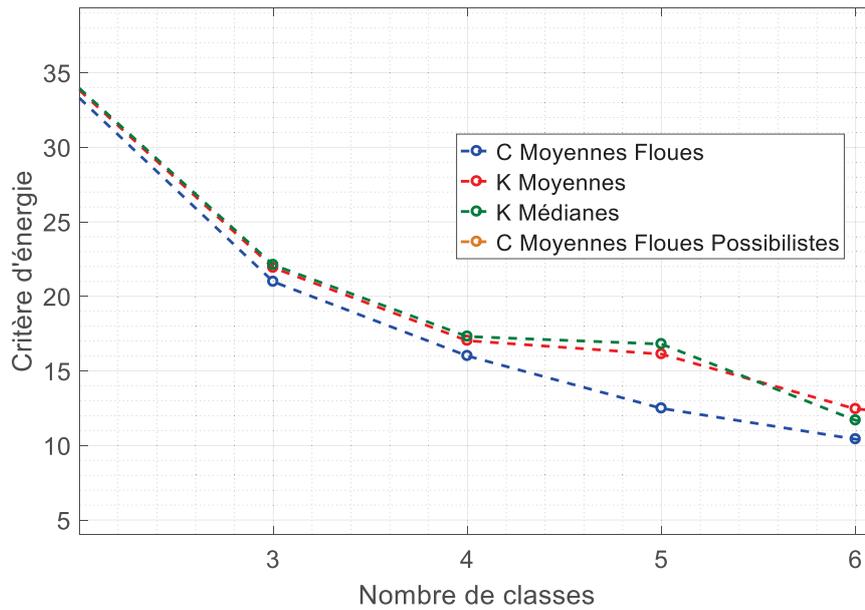


Figure V.18 : Energie en fonction du nombre de classes

L’algorithme des c moyennes floues possibilistes est hors du graphique car il atteint des valeurs trop élevées. Il apparait clairement que l’algorithme par c – moyennes floues obtient l’énergie la plus faible, quel que soit le nombre de classes sur l’intervalle considéré. C’est donc cet algorithme qui sera adopté pour la suite de l’étude.

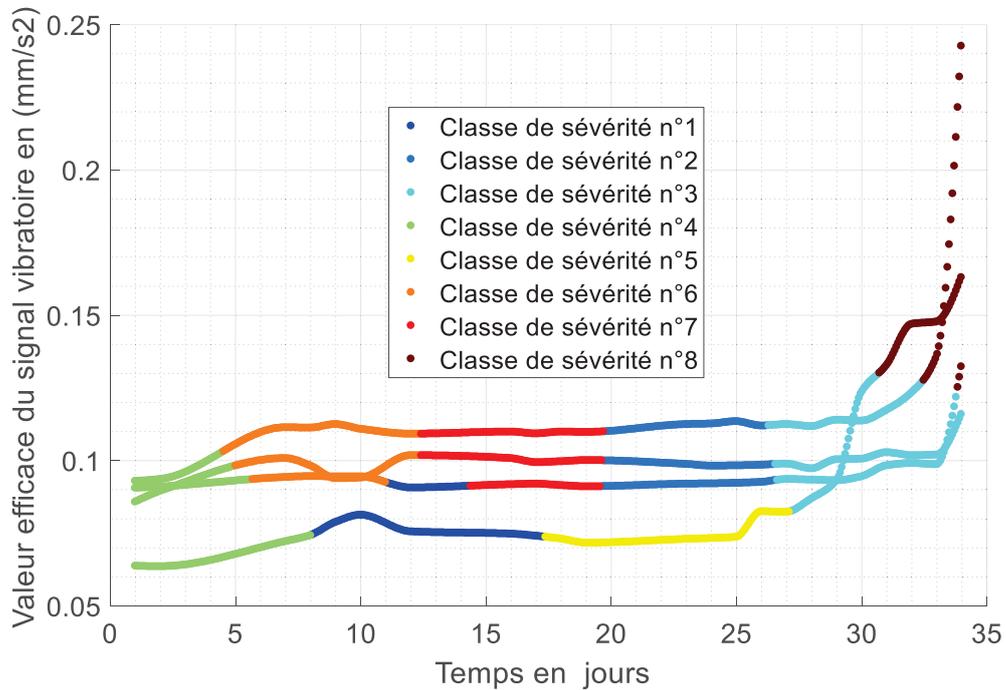


Figure V.19 : Exemple de partitionnement incohérent (k - Moyennes avec  $c = 8$ )

L’algorithme des c – moyennes a été mis au point par James Bezdek (**Bezdek 1981; Bezdek et al. 1984**) comme une amélioration de celui des k – moyennes. L’idée est qu’une observation peut appartenir à plusieurs classes en même temps mais avec différents degrés. A des fins de synthèse, la

description de l'algorithme a été mise en annexe (voir VIII12 - 235).

## 4.4 - Résultats du partitionnement

### 4.4.a - Nombre de classes optimal

Un nombre trop grand de classes ne peut pas être choisi ici, de par l'augmentation des coûts de calculs que cela implique. Ainsi comme pour la sélection de paramètres, le choix du nombre de classes se fera au niveau du « coude » de l'évolution du critère. Ici, on considérera donc les cas avec trois, quatre et cinq classes.

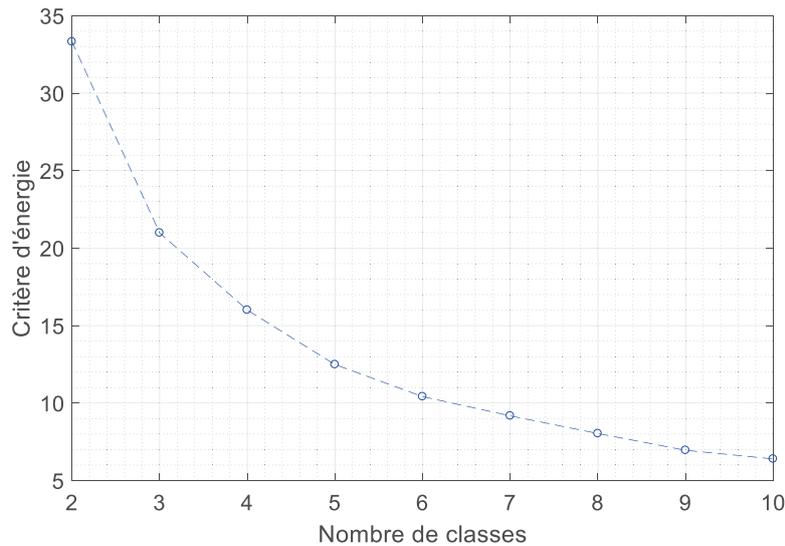


Figure V.20 : Critère d'énergie en fonction du nombre de classes sur la base IMS

### 4.4.b - Partitionnement

Seuls les résultats pour  $c = 4$  seront présentés ici. Les résultats pour  $c = 3$  et  $c = 5$  ont été mis en annexes (voir VIII13 - 237). Les résultats pour quatre classes sont les suivants :

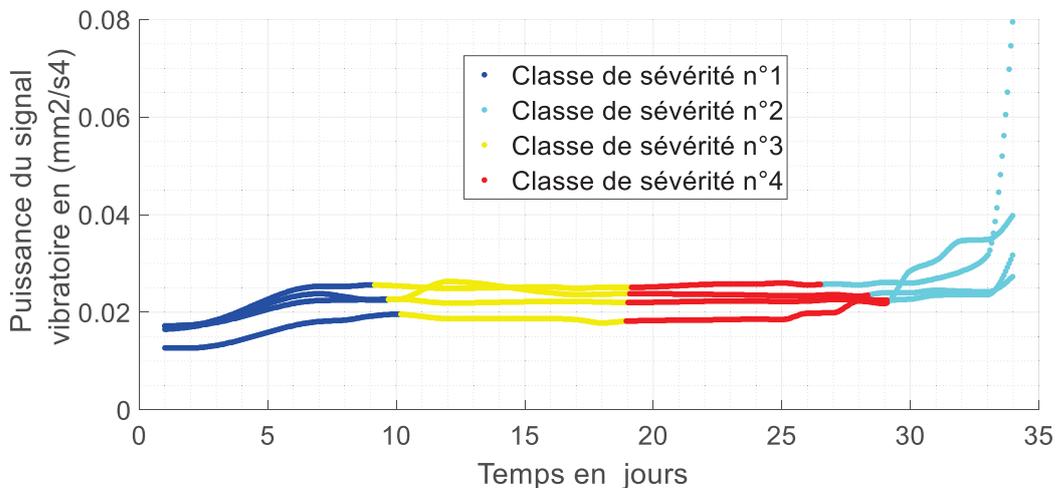


Figure V.21 : Puissance du signal vibratoire en fonction du temps - observations partitionnées ( $c=4$ )

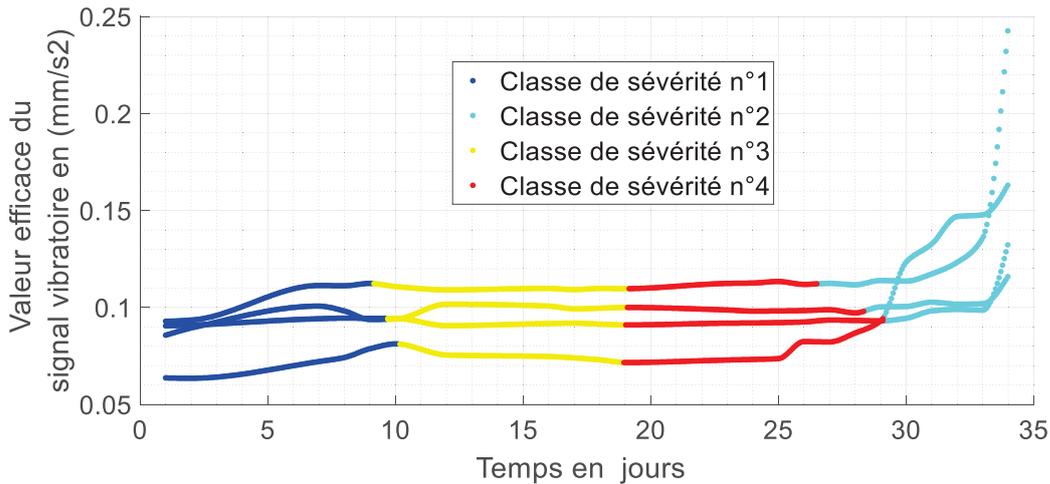


Figure V.22 : Valeur efficace du signal vibratoire en fonction du temps – observations partitionnées (c=4)

La cohérence temporelle est préservée. La première classe correspond à la phase de rodage. La phase de fin de vie est bien isolée. Le milieu de vie est partagé entre deux classes.

### 4.4.c - Comparaison des temps de fin de vie

Une comparaison des temps de fin de vie obtenus par choix d’expert et par méthode de partitionnement est faite. Un écart négatif indique que le partitionnement est conservatif vis-à-vis de la méthode par expert. Seuls les résultats pour  $c = 4$  sont mis en évidence ici. Les autres sont mis en annexe à titre informatif (voir VIII14 - 239).

Ecart sur le temps de fin de vie en % (C = 4)				
Critère / Roulement	Puissance Début Coude	Puissance Fin Coude	RMS Début Coude	RMS Fin Coude
R1	-14,2	-14,2	-13,9	-13,9
R2	-11,7	-11,7	-11,7	-11,7
R3	-11,4	-19,7	-11,4	-19,5
R4	15,7	0,2	15,7	7,2

Tableau V.2 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert (c = 4)

La définition du temps de fin de vie basée sur le partitionnement est conservative dans la majorité des cas vis-à-vis de celle par expert. En effet le temps de fin de vie estimé à cette méthode est inférieur à celui évalué par expert. C’est donc cette méthodologie que l’on adoptera dans les présents travaux.

## 5 - Réglage et validation du diagnostic

### 5.1 - Problématique

Pour les trois cas considérés, les algorithmes de classification par SVM – FA, sans règle de décision, (III4.2 - page 97) ont été réglés par essais – erreur. Les trois méthodes multi – classes ont été testées

et évaluées en termes de précision de classification (voir équation (IV.1)). Une problématique s’est posée sur la phase de validation. En effet, classiquement, en diagnostic, une partie de la base est mise de côté pour la phase de test. Cette partie est obtenue en sous-échantillonnant la base complète. On itère plusieurs fois la procédure pour que chaque point de la base soit testé une fois. Cette méthodologie « validation diagnostic » a été appliquée via une validation croisée 5 – FO et a permis de préciser le nombre de classes de sévérité.

Cette méthodologie ne correspond cependant pas à un cadre applicatif industriel. Pour une application réelle, on dispose de données complètes sur un certain nombre d’unités et on souhaite diagnostiquer de nouvelles unités. La validation croisée ne se fait donc pas sur les données directement mais sur les unités. Le modèle est appris sur les données d’un certain nombre d’unités puis testé sur les données de celles restantes. Cette démarche « validation pronostic » a été appliquée pour le nombre choisi de classes. Les premiers résultats obtenus ont amené à proposer une nouvelle méthode de normalisation des données, plus efficaces, notamment pour des composants/système ayant une dégradation exponentielle en fin de vie.

## 5.2 - Validation du classifieur – approche « Diagnostic »

Les phases de test correspondent ici à la classification de 389 points, sous – échantillonnées de manière égale sur la base de données complète. Ainsi la base de test a la même proportion d’observations dans chaque classe que la base d’apprentissage.

### 5.2.a - « One vs All »

Les résultats pour la méthode « One vs All » sont les suivants :

Méthode OVA		C = 3	C = 4	C = 5
Précision (%)	Max	100	98,46	98,72
	Moy	98,56	97,64	98,31
	Min	97,17	96,66	97,69
Temps Test (389 points) (ms)	Max	89.7	139	180
	Moy	81.8	123	170
	Min	74.0	103	165

Tableau V.3: Résultats de classification de la méthode "OVA"

Les taux de classification sont très corrects, quel que soit le nombre de classes. Les résultats sont très proches, autour des 98%. Les temps de calculs, donnés ici pour 389 points, sont également corrects. Les appartenances aux classes évoluent comme souhaité sur base d’apprentissage, voir la Figure V.23 pour un exemple en apprentissage / test sur les quatre unités :

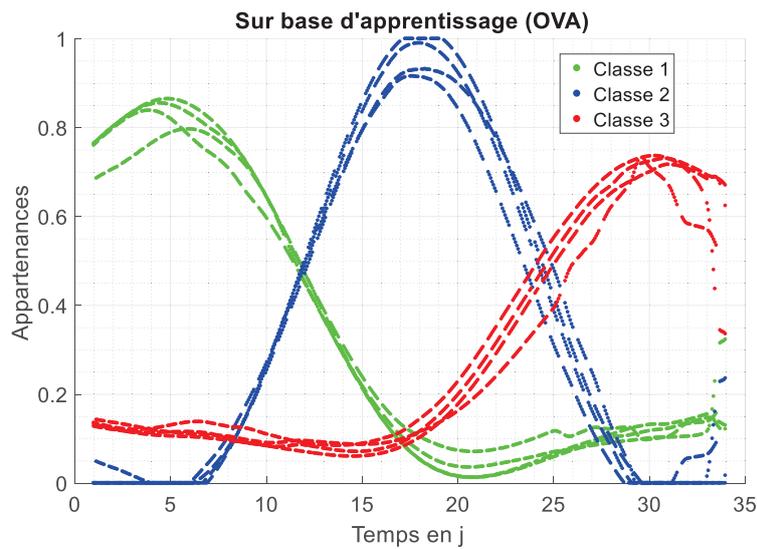


Figure V.23 : Evolution des appartenances en fonction du temps (Apprentissage – OVA –  $c = 3$ )

Cette évolution se conserve lors de la phase de test, avec une dispersion plus importante d'une unité à une autre :

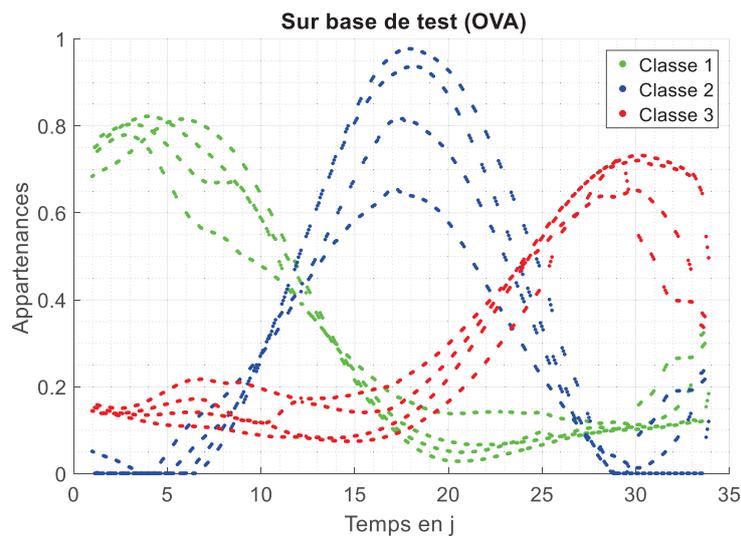


Figure V.24 : Evolution des appartenances en fonction du temps (Test – OVA –  $c = 3$ )

Un point à noter : les appartenances ont la forme de gaussiennes quel que soit le type choisi. Il semblerait que cela vienne de l'utilisation du noyau gaussien pour la SVM, qui impose la forme des fonctions d'appartenances.

## 5.2.b - « One vs One »

Les résultats pour la méthode « One vs One » sont les suivants :

Méthode OVO		C = 3	C = 4	C = 5
Précision (%)	Max	99,49	99,743	98,98
	Moy	99,33	98,98	98,15
	Min	99,49	98,21	97,43
Temps Test (389 points) (ms)	Max	124	259	569
	Moy	121	212	503
	Min	118	187	475

Tableau V.4: Résultats de classification de la méthode "OVO"

Les taux de classification sont très corrects, quel que soit le nombre de classes. Les résultats sont très proches autour des 99%. Les temps de calculs, donnés ici pour 389 points, sont plus longs que pour la méthode précédente, mais restent corrects. Les appartenances prennent pour cette méthode la même forme que pour la méthode « OVA », à savoir celle d'une gaussienne.

### 5.2.c - « One to Others »

Les résultats pour la méthode « One to Others » sont les suivants :

Méthode OTO		C = 3	C = 4	C = 5
Précision (%)	Max	99,75	98,98	97,95
	Moy	98,56	98,26	97,48
	Min	97,69	97,18	96,66
Temps Test (389 points) (ms)	Max	90.5	89.0	93
	Moy	56.7	57.6	59
	Min	44.6	45.4	46

Tableau V.5: Résultats de classification de la méthode "OTO"

Les taux de classifications sont très corrects, quel que soit le nombre de classes. Les résultats sont très proches autour des 98%. Les temps de calculs, donnés ici pour 389 points, sont plus courts que pour les méthodes précédentes. Les appartenances prennent ici leur forme de base, contrairement aux méthodes précédentes :

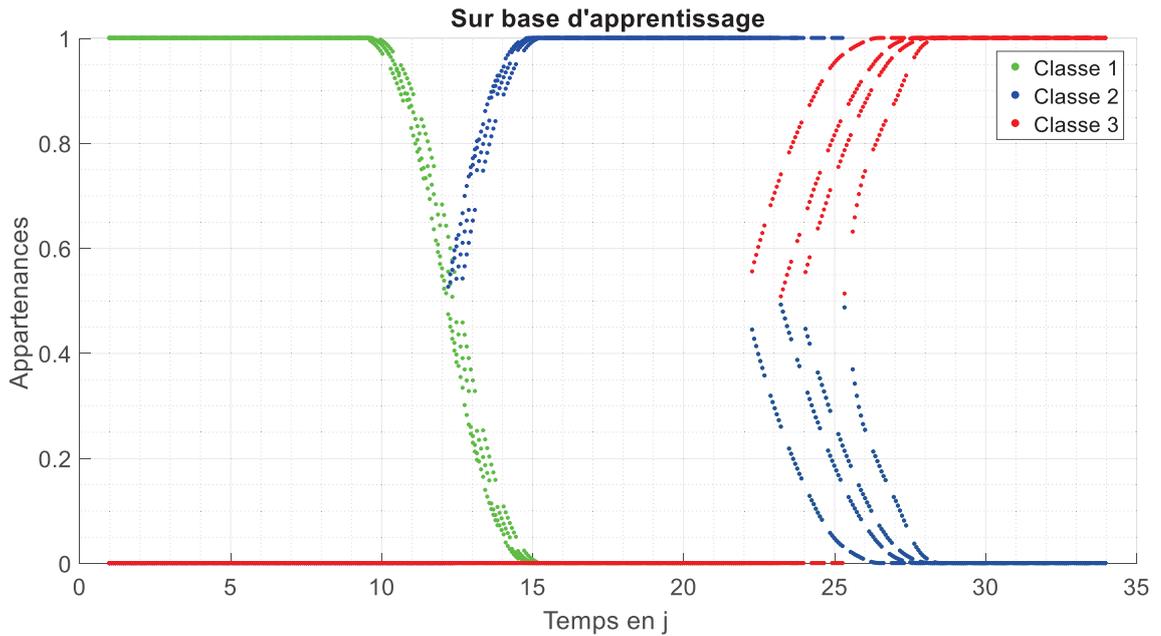


Figure V.25 : Evolution des appartenances en fonction du temps (Apprentissage – OTO – FA sigmoïdale –  $c = 3$ )

L'évolution se conserve lors du passage à la phase de test, avec une dispersion plus importante d'une unité à une autre :

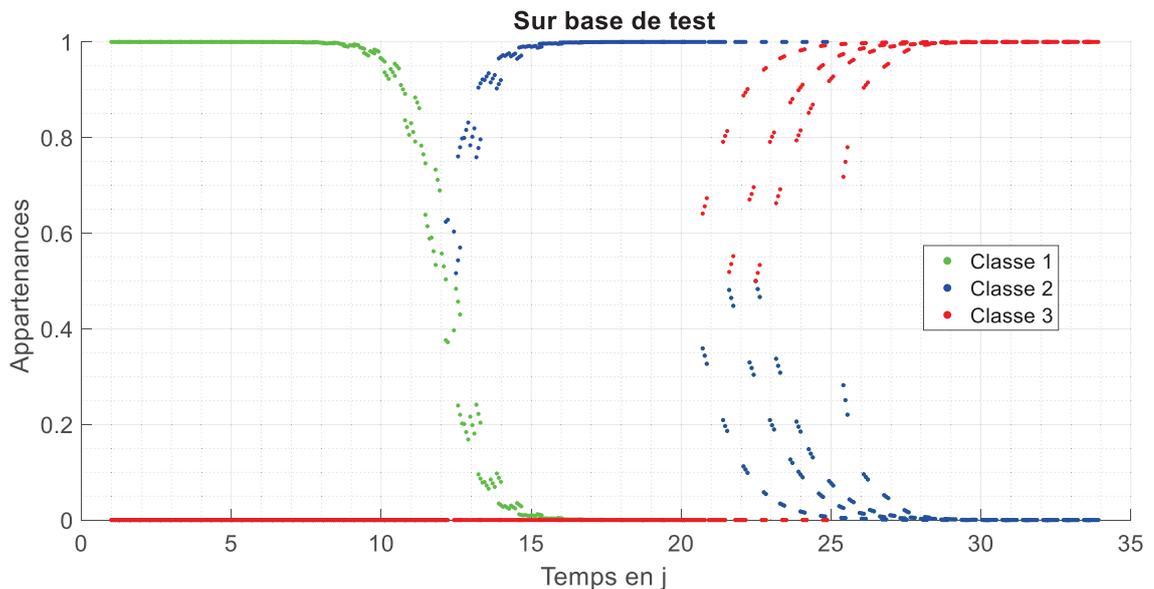


Figure V.26 : Evolution des appartenances en fonction du temps (Test – OTO – FA sigmoïdale –  $c = 3$ )

On observe un saut des appartenances au moment des transitions entre la première et la deuxième classe ( $t \in [12; 13]$  jours) ainsi qu'au moment de la transition entre la deuxième et la troisième ( $t \in [20; 27]$  jours). Elles démarrent directement à des valeurs supérieures à 0.5. Cela est dû à la méthode OTO qui ne calcule pas les appartenances des points lorsque ceux-ci sont considérés comme classés. Cela entraîne l'apparition de beaucoup de valeurs nulles dans la matrice des appartenances. Ces discontinuités peuvent poser problème et créer des discontinuités dans l'estimation de la RUL. Ainsi, les deux premières méthodes seront privilégiées pour le reste de l'étude.

## 5.2.d - Synthèse

Les meilleures méthodes, par nombre de classes sont :

Nombre de classes	C = 3	C = 4	C = 5
Meilleure méthode	OVO	OVO	OVA
Précision moyenne	99,33	98,98	98,31

Tableau V.6 : Meilleure méthode en fonction du nombre de classes

La méthode « One vs One » semble être meilleure pour la majorité des classes. Même pour  $c = 5$ , où la méthode « One vs All » est plus efficace, l'écart entre les deux est très faible, à 0,16%. Les écarts d'une classe à l'autre sont également assez faibles. La précision a toutefois tendance à diminuer lorsque le nombre de classes augmente. Cela est confirmé par le fait que les meilleurs résultats par méthode sont tous pour  $c = 3$  :

Méthode	OVA	OVO	OTO
Nombre de classes qui maximise la précision moyenne	3	3	3
Précision moyenne	98,56	99,33	98,56

Tableau V.7 : Nombre de classe maximisant la précision moyenne par méthode multi – classes

Le meilleur compromis entre le taux de classification (voir Tableau V.6) et l'écart par rapport aux classes définies par un expert (4.4.c - page 165), est atteint pour  $c = 4$ . C'est donc cette valeur qui sera choisie pour le reste de l'étude.

## 5.3 - Validation du classifieur – approche « Pronostic »

Les phases de test correspondent ici à la classification de l'ensemble des observations sur une unité soit 486 points. Étant donné que toutes les unités n'ont pas le même nombre d'observations dans chaque classe cela entraînera des déséquilibres entre les bases d'apprentissage et de test. Ce déséquilibre peut entraîner une variabilité importante des résultats, notamment pour des dégradations évoluant rapidement en fin de vie. Afin de réduire cette variabilité, une nouvelle méthode de normalisation est proposée.

### 5.3.a - Normalisation par sigmoïde

La fonction de normalisation  $\pi$ , correspond à une projection de l'intervalle  $[x_{min}, x_{max}]$  vers un

intervalle commun pour tous les paramètres, généralement  $[-1; 1]$  ou  $[0; 1]$ . Cette projection s'effectue donc pour chaque paramètre. Le type de projection sera le même mais les arguments de la fonction (paramètres fonctionnels), seront différents d'un paramètre à un autre. Les arguments des fonctions de projection seront appris lors de la phase apprentissage puis utilisés lors de la phase de test. L'objectif, ici, est d'obtenir une projection proche de ce qui est obtenu avec la méthode max/min, utilisée depuis le début de cette étude et qui montre de bonnes performances, mais avec un phénomène de saturation aux extrémités de l'intervalle de départ. C'est sur ces extrémités que se retrouveront notamment les points mesurés en fin de vie. Une autre manière de formuler ces contraintes est :

Soit  $x$  un paramètre à valeurs dans  $X \subset \mathbb{R}$ .  $X$  est borné par  $x_{inf}$  et  $x_{sup}$  qui peuvent être fini ou non. Soit  $x_{min}$  sa valeur minimale sur une base de données. Soit  $x_{max}$  sa valeur maximale sur la base de données. On veut établir une projection de  $X$  dans  $[0, 1]$  tel que :

- ⇒ La projection rend une quasi – droite (forte variation) entre  $x_{min}$  et  $x_{max}$
- ⇒ La projection s'aplatit rapidement (faible variation) entre  $x_{inf}$  et  $x_{min}$  et entre  $x_{max}$  et  $x_{sup}$

La fonction sigmoïde apparait comme une candidate naturelle. On posera :

- ⇒  $\pi_{sig}(x_{max}) = \delta$  avec  $\delta \in ]0.5, 1[$
- ⇒  $\pi_{sig}(x_{min}) = 1 - \delta$  (Sigmoïde centrée au point milieu de  $[x_{min}, x_{max}]$ )

Où  $\delta$  est un paramètre utilisateur. Les paramètres de la sigmoïde peuvent être calculés à partir de ces hypothèses (voir annexe VIII15 - 239). La normalisation par sigmoïde s'exprimera donc :

$$(V.14) \quad \pi_{sig}(x) = \frac{1}{1 + e^{-a_{sig}(x - b_{sig})}}$$

### 5.3.b - Comparaison de méthodes de normalisation

Une validation croisée a été effectuée pour la normalisation par sigmoïde, celle par max/min (Patro et Sahu 2015) et celle par Z-score ou standardisation (Patro et Sahu 2015). La méthode multi – classes est l'OVA. Les résultats obtenus sont les suivants :

Unité testée / Méthode	Standardisation	Max/Min	Sigmoïde
1	33,54	<b>99,18</b>	98,56
2	40,33	<b>96,91</b>	96,50
3	28,81	47,33	<b>95,27</b>
4	14,81	52,47	<b>84,16</b>

Tableau V.8 : Résultats en termes de précisions (%) de classification en validation croisée pour différentes techniques de normalisation

La standardisation montre de très mauvais résultats, avec moins de 30% de précision en moyenne. La

normalisation par maximum/minimum obtient la meilleure précision avec 99,18%. Cependant, sa précision moyenne est nettement moins bonne, avec près de 74%. Cela implique une grande variabilité des résultats d'une unité à une autre, ce qui doit être évité au maximum. La normalisation par sigmoïde est, elle, beaucoup plus stable avec une précision maximale à 98,56% et une moyenne à près de 93%. C'est donc cette méthode qui sera adoptée dans le reste de ces travaux.

### 5.3.c - Evaluation des performances

Seuls les modèles entraînés sur la base normalisée par sigmoïde seront traités ici. Etant donné les discontinuités montrées par les modèles OTO (voir Figure V.25 page 169 et la Figure V.26 page 169), on ne traitera que ceux par méthode OVA et OVO ici. Seules les données avec  $c = 4$  ont été traitées.

#### 5.3.c.i - One Vs All

Les résultats pour la méthode « One Vs All » sont les suivants :

Précision $P$ (%)	Précision (%)	Temps de calculs en test pour 486 points (ms)	Mémoire nécessaire (kB)
Maximum	98,56	170	210
Moyenne	93,63	118	137
Minimum	84,16	65	79,6

Tableau V.9 : Performances en validation croisée (SVM - FA "One Vs All")

Comme déjà vu précédemment la précision est bonne malgré les variations d'une unité à une autre. Les temps de calculs sont corrects. La mémoire nécessaire correspond à ce qui a été vu au chapitre précédent.

#### 5.3.d - One Vs One

Les résultats pour la méthode « One Vs One » sont les suivants :

Précision $P$ (%)	Précision (%)	Temps de calculs en test pour 486 points (ms)	Mémoire nécessaire (kB)
Maximum	97,53	273	339
Moyenne	94,70	252	313
Minimum	92,18	228	289

Tableau V.10 : Performances en validation croisée (SVM - FA "One Vs One")

La précision est bonne et montre nettement moins de variabilité que pour la méthode « One Vs All ». Les temps de calculs sont plus importants, mais restent très largement acceptables. La mémoire nécessaire est également plus importante, de l'ordre de 2 à 3 fois plus. Néanmoins, d'après les contraintes (voir Contrainte 2 page 41) et les estimations faites précédemment (voir IV5.2 - 139) cela reste acceptable.

## 6 - Prédiction des signatures

### 6.1 - Régression par SVR

#### 6.1.a - SVR linéaire

La régression a pour objectif de fournir un modèle prédisant une sortie  $y \in \mathbb{R}$  à partir d'un ensemble de  $m$  données labélisées  $\{(x_1, y_1), \dots, (x_m, y_m)\}$  ou  $x_i \in \mathbb{R}^p, p \in \mathbb{N}^*, i \in \{1, \dots, m\}$ . L'algorithme doit donc trouver une fonction  $f_R : \mathbb{R}^p \rightarrow \mathbb{R}$ , de paramètres  $\omega$ , qui minimisent l'erreur sur l'ensemble d'apprentissage tout en ayant une bonne capacité de généralisation. Le problème de régression peut être formulé en utilisant le formalisme des machines à vecteurs de supports. Pour cela, on se base sur la SVM à marges souples. Le problème s'exprime comme la minimisation de la fonction coût suivante (Frag et Mohamed 2004; Smola et Schölkopf 2004) :

$$(V.15) \quad LR_p = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*)$$

Sous les contraintes :

$$(V.16) \quad \begin{aligned} y_i - [\omega x_i + b] &\leq \varepsilon + \xi_i \\ [\omega x_i + b] - y_i &\leq \varepsilon + \xi_i^* \\ \xi_i &\geq 0 \text{ et } \xi_i^* \geq 0 \end{aligned}$$

On note  $\omega$  la normale à l'hyperplan,  $C$  : le paramètre de régularisation et  $b$  l'offset. Les  $\xi_i$  et  $\xi_i^*$  sont appelés fonction de perte de sensibilité  $\varepsilon$  et sont définies telles que :

$$(V.17) \quad |\xi|_\varepsilon = \begin{cases} 0 & \text{si } |\xi| < \varepsilon \\ |\xi| - \varepsilon, & \text{sinon} \end{cases}$$

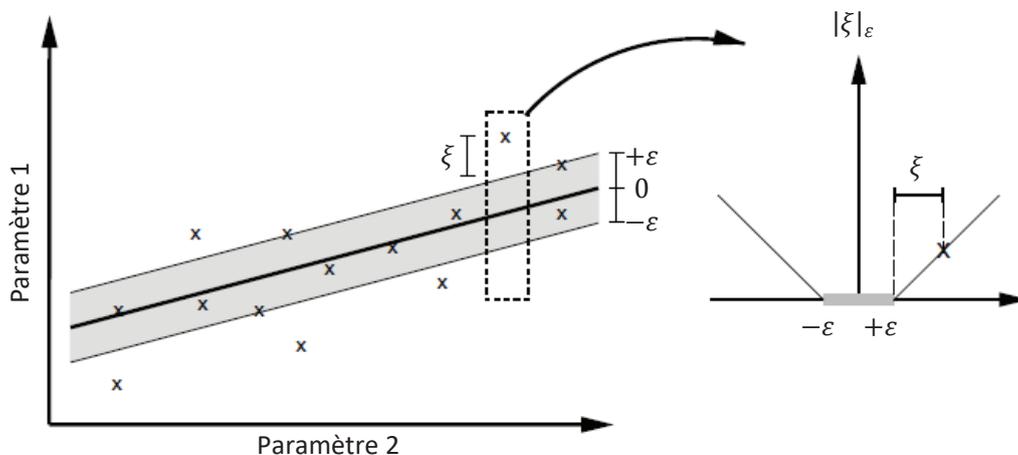


Figure V.27 : Fonction perte pour SVR linéaire à marges souples (Smola et Schölkopf 2004)

## 6.1.b - SVR non linéaire

Pour un cas non-linéaire on utilise l'astuce du noyau pour reformuler le problème. Il s'agit alors de maximiser la fonction suivante :

$$(V.18) \quad LR_D = -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)K(x_i, x_j) - \varepsilon \sum_{i=1}^m (\alpha_i + \alpha_i^*) + \sum_{i=1}^m y_i(\alpha_i - \alpha_i^*)$$

Sous les contraintes :

$$(V.19) \quad \begin{aligned} \sum_{i=1}^m (\alpha_i - \alpha_i^*) &= 0 \\ 0 &\leq \alpha_i \leq C \\ 0 &\leq \alpha_i^* \leq C \end{aligned}$$

Où  $K$  : la fonction noyau (III.3 - 88) et  $(\alpha_i, \alpha_i^*)$  : les coefficients de Lagrange primaires et duals. La fonction de prédiction s'exprime alors par :

$$(V.20) \quad f_R(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) \cdot K(x_i, x) + b$$

## 6.2 - Application aux roulements

La SVR est implémentée via la *Statistics and Machine Learning Toolbox™* de Matlab®. Trois temps de démarrage de prédiction ont été testés : un à  $t = sp1 = 1$  jour (où aucune observation de l'unité en test n'est utilisée pour l'apprentissage), un à  $t = sp2 = 10,45$  jours qui correspond à la fin de phase de rodage et un à  $t = sp3 = 20,65$  jours qui correspond au démarrage de l'avant dernière classe de sévérité.

Les résultats de prédiction sont évalués selon l'erreur absolue relative (*Mean Absolute Percentage Error : MAPE*), qui est le dual de la précision relative cumulée (1.5.a.i - page 153).

$$(V.21) \quad MAPE = \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{|y_i|}$$

A des fins de synthèse, et étant donné que tous les résultats de prédiction sont du même ordre de grandeur, seuls les résultats sur l'unité sous test (*Unit Under Test : UUT*) 1 seront donnés ici. Les résultats des UUT2 à 4 sont en annexes (voir VIII16 - 240). Les résultats pour le test sur l'unité 1 sont donnés à la suite (voir Figure V.28, Figure V.29 et Figure V.30). On observe que l'erreur augmente avec le temps, ce qui est cohérent avec l'utilisation d'une méthode itérative. En général, plus l'on utilise d'observations de l'unité en test, plus l'erreur diminue. L'erreur augmente fortement pour les

dernières prédictions. Cela s'explique par une surestimation de l'accroissement exponentiel de la signature. Celle-ci intervient néanmoins après le temps de fin de vie de cette unité qui est de 28 jours.

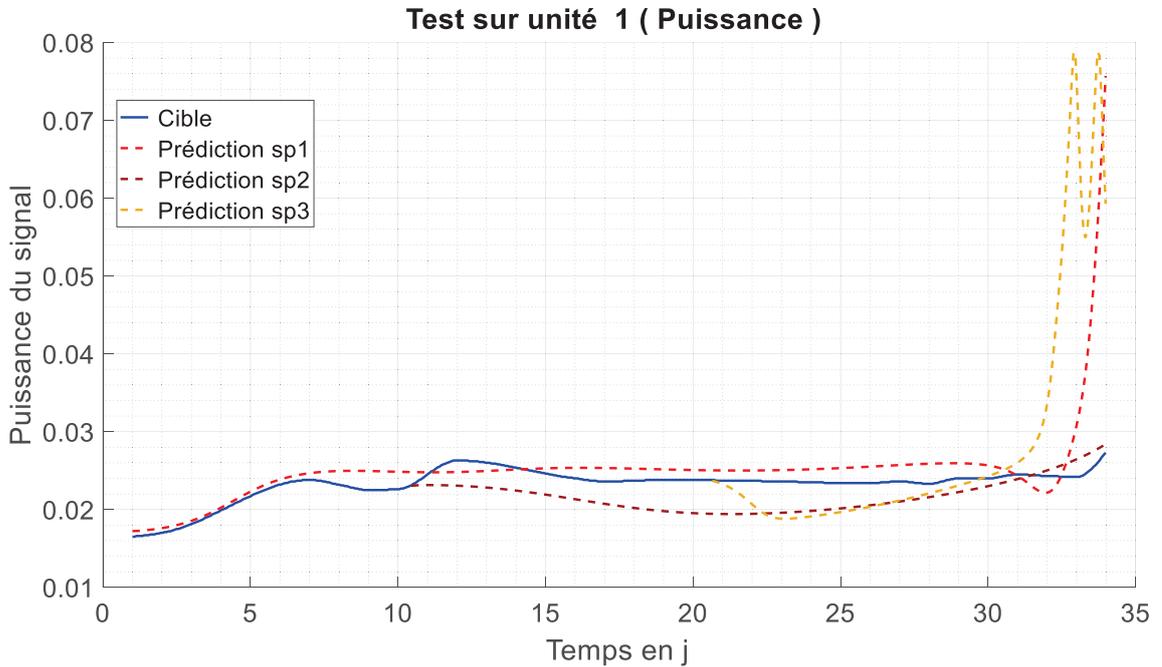


Figure V.28 : Prédiction de la puissance du signal vibratoire (UUT1)

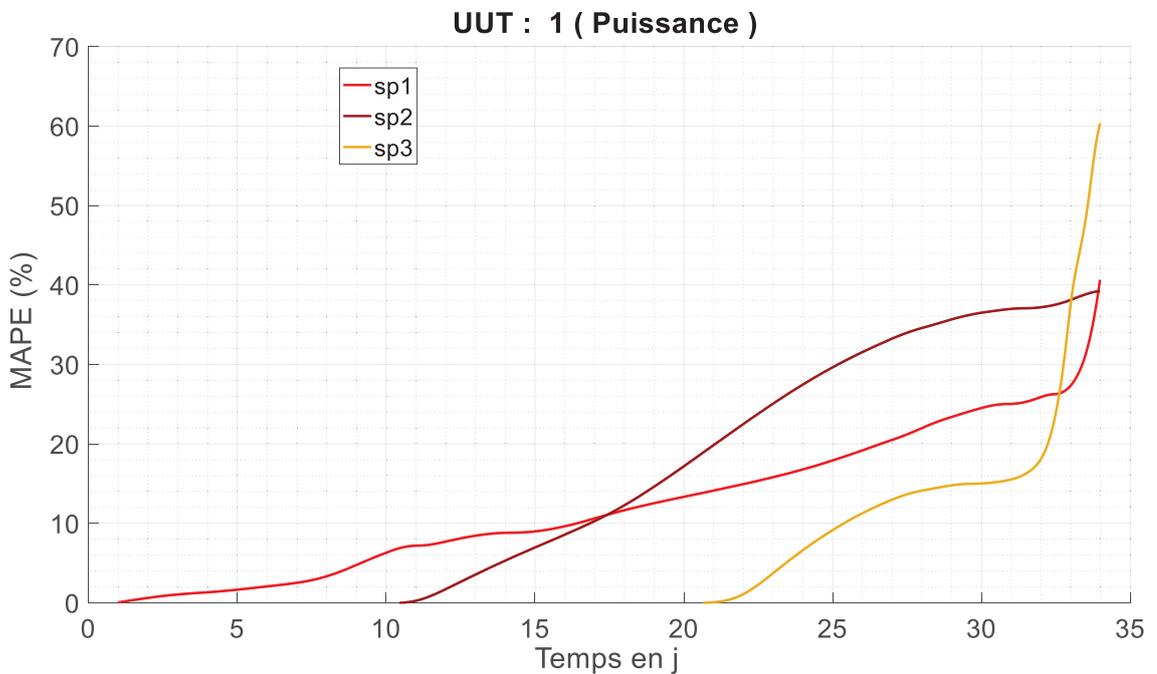


Figure V.29 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT1)

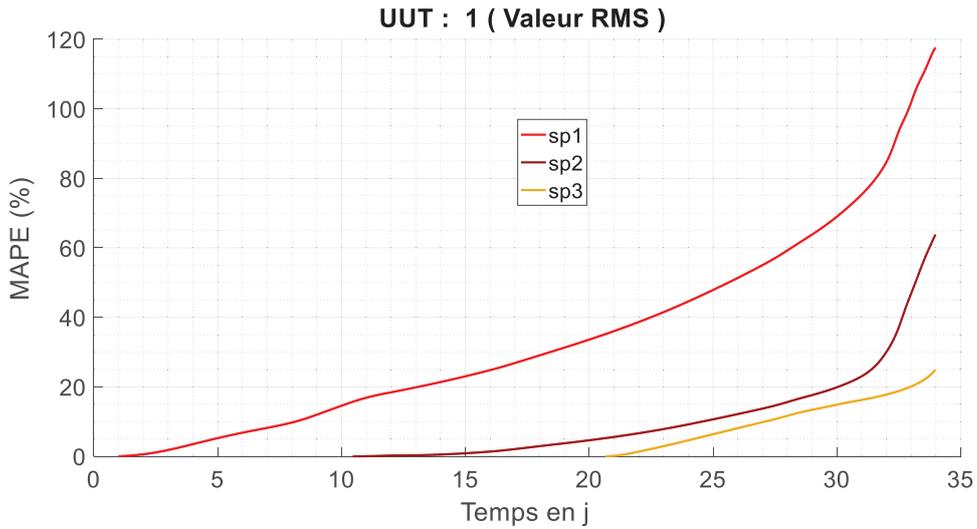


Figure V.30 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT1)

Il est maintenant nécessaire de voir dans quelle mesure l'erreur de prédiction influence l'estimation des appartenances.

## 7 - Estimation des appartenances

L'estimation des appartenances se fait en réutilisant le modèle de diagnostic entraîné au 5.3.d - 172. Bien évidemment, pour chaque test, le modèle de diagnostic a été validé sur toutes les données disponibles sauf celles de l'unité testée. Nous ne présenterons que quelques graphiques représentant les types de comportements observables.

Certaines estimations donnent des appartenances comme ce que l'on peut voir en phase de diagnostic.

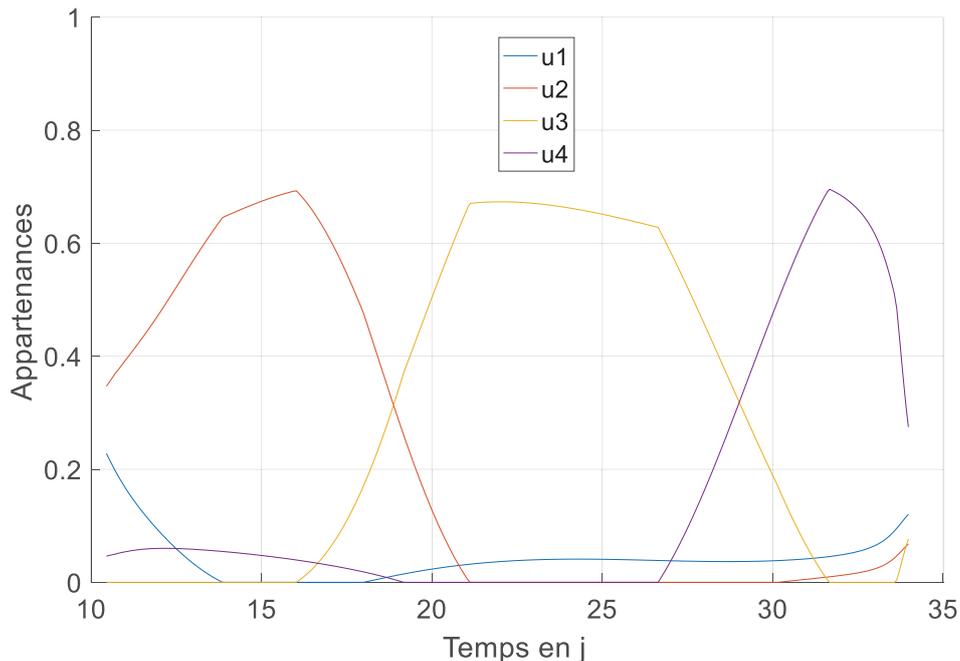


Figure V.31 : Appartenances estimées sur UUT4 à partir des prédictions du modèle *sp2* à  $t = 10, 45$  jour

D'autres présentent des oscillations, dues à des oscillations déjà présentes sur certaines prédictions. L'estimation du temps de fin de vie reste cependant possible en considérant que celle-ci correspond au premier instant où l'appartenance à la dernière classe de sévérité est supérieure à celle de l'avant dernière classe. (Figure V.32).

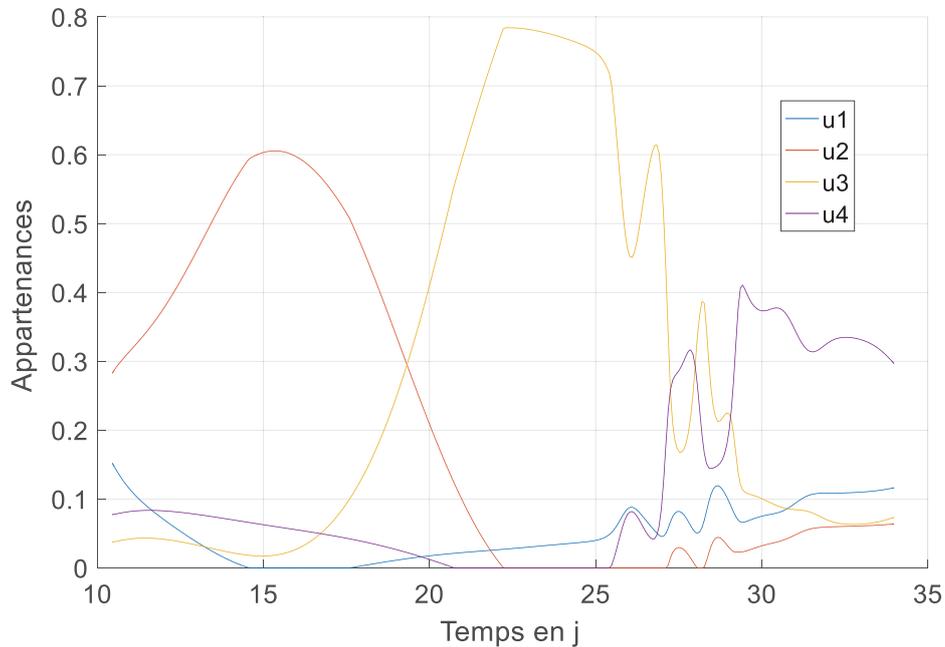


Figure V.32 : Appartenances estimées sur UUT3 à partir des prédictions du modèle *sp2* à  $t = 10, 45$  jour

Enfin pour certaines estimations, certaines appartenances restent constantes sur les derniers temps de prédictions et ne se croisent plus. Ce comportement n'est pas gênant puisqu'il se produit bien après la fin de vie estimée (Figure V.33).

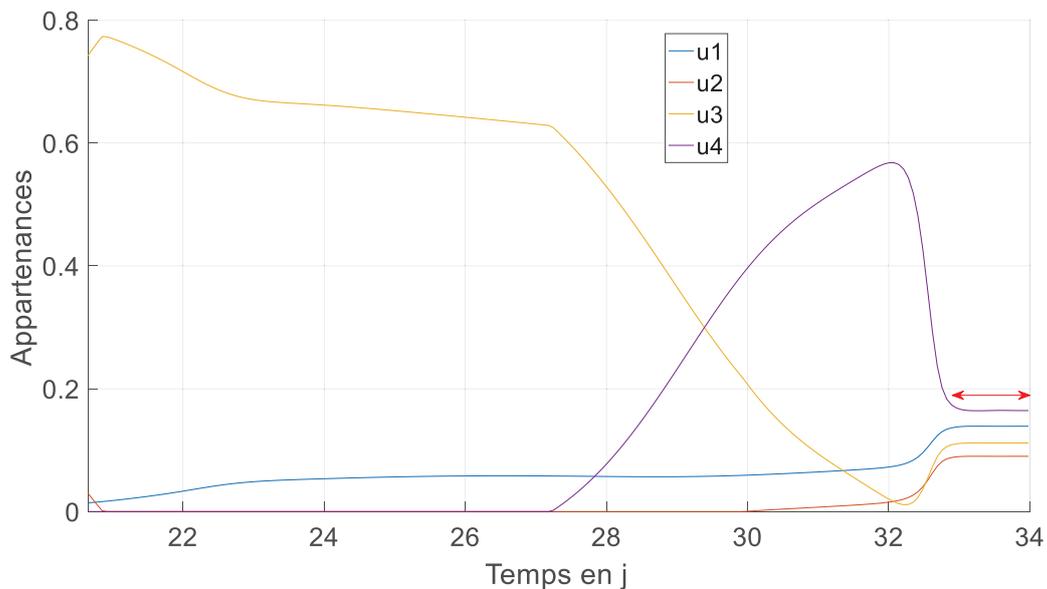


Figure V.33 : Appartenances estimées à partir des prédictions du modèle *sp3* à  $t = 20, 65$  jour (UUT 2)

On peut donc voir que malgré une erreur assez importante sur les prédictions des signatures, il est possible d'obtenir des courbes d'appartenance proches de ce qui est obtenu en diagnostic. Il faut cependant vérifier si ces courbes permettent d'obtenir une estimation performante de la RUL.

## 8 - Estimation de la RUL

A partir des appartenances, le temps de fin de vie et donc la RUL peuvent être estimés. Une comparaison est ici donnée pour chaque unité testée. Une remarque générale, pour le modèle *sp1* : la RUL n'est pas parfois estimable dès le démarrage de la prédiction. Cela entraîne un décalage entre le démarrage de la prédiction et le moment où la RUL estimée devient non nulle.

La courbe avec l'intervalle d'erreur sur la RUL à l'instant initiale et celle avec l'intervalle sur la RUL à l'instant  $t$  seront données pour l'unité 1.

Pour les autres unités seul le deuxième type de courbe sera donné. Les autres sont disponibles en annexes (voir VIII17 - 244). Une synthèse est finalement donnée avec l'évaluation des différentes métriques données au paragraphe 1.5.a.i - page 155.

### 8.1 - Mise en place des métriques

L'objectif ici est seulement de fournir une tendance, longtemps à l'avance, afin de pouvoir anticiper sur les opérations de maintenance. Ainsi la constante  $\alpha_e$  sera prise pour avoir un intervalle de  $\pm 15\%$  autour de la RUL initiale. La mise en place de la précision relative (1.5.a.i - 153) ne nécessite pas de compléments. A l'inverse, celles de l'horizon de pronostic et de la performance nécessitent un complément d'informations.

#### 8.1.a - Horizon de pronostic

Etant donné que la RUL n'est pas donnée ici sous forme de distribution, le degré de confiance  $\beta_e$  n'a pas à être défini. L'horizon de pronostic se calculera donc par :

$$(V.22) \quad PH = t_{EOL} - t_{\alpha_e}$$

Avec  $t_{\alpha_e}$  : l'instant à partir duquel l'estimation de la RUL vérifie, jusqu'à la fin de vie :

$$(V.23) \quad R\hat{U}L \in [(1 - \alpha_e) * RUL(0); (1 + \alpha_e) * RUL(0)]$$

#### 8.1.b - La performance $\alpha_e - \lambda_t$

La métrique  $P_{(\alpha_e - \lambda_t)}$  sera calculée pour tous les instants du démarrage de la prédiction à la fin de vie. Elle sera ensuite exprimée sous forme de valeur moyenne. Etant donné que  $P_{(\alpha_e - \lambda_t)}$  est à valeurs dans  $\{0,1\}$ , la moyenne sera exprimée sous forme de pourcentage.

## 8.2 - Test sur l'unité 1

On observe une légère sous-estimation de la RUL pour les trois modèles. Le modèle *sp1* ne semble pas être capable d'estimer la RUL avant  $t \approx 7,5$  jours. Le modèle *sp2* montre une divergence vers entre  $t = 10,5$  et  $t = 13,5$  jours. Cette oscillation peut s'expliquer par des oscillations sur les prédictions des signatures qui entraînent des oscillations sur les estimations des appartenances. A

noter que tous les modèles convergent bien à l'approche du temps de fin de vie.

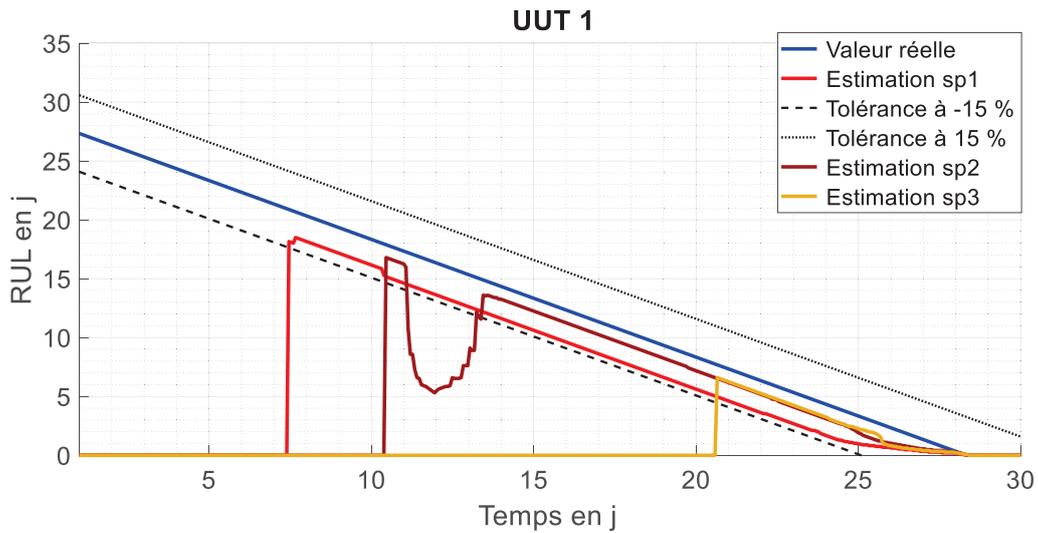


Figure V.34 : Estimation de la RUL pour l'unité 1 – Tolérance à 15% sur la RUL initiale

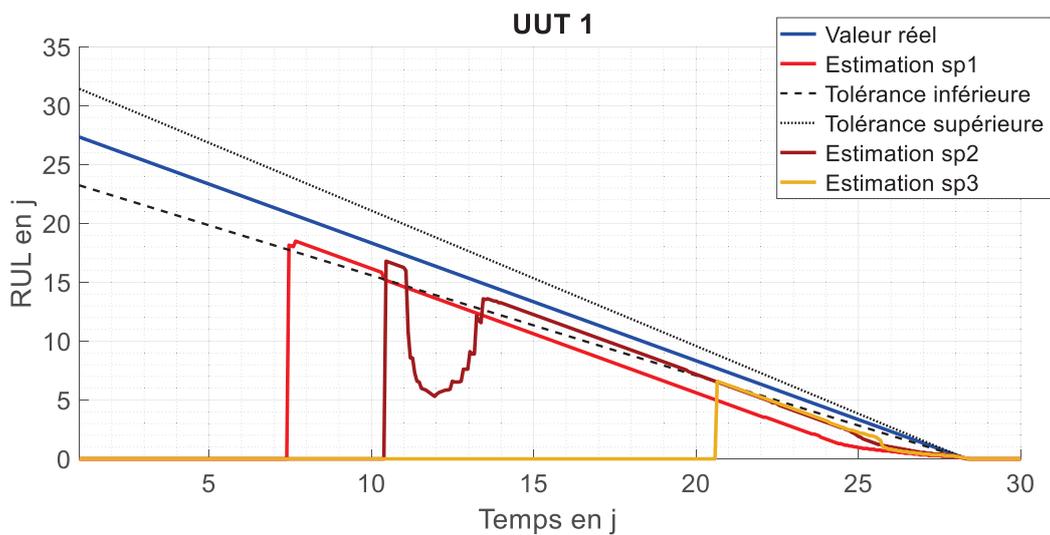


Figure V.35 : Estimation de la RUL pour l'unité 1 – Tolérance à 15% sur la RUL à l'instant  $t$

## 8.3 - Test sur l'unité 2

Les estimations sont ici plus proches de la RUL réelle. Le modèle *sp2* présente encore de fortes oscillations hors tolérance. L'ensemble des modèles converge bien aux environs de la fin de vie mais avec un biais positif (retard) de moins d'un jour.

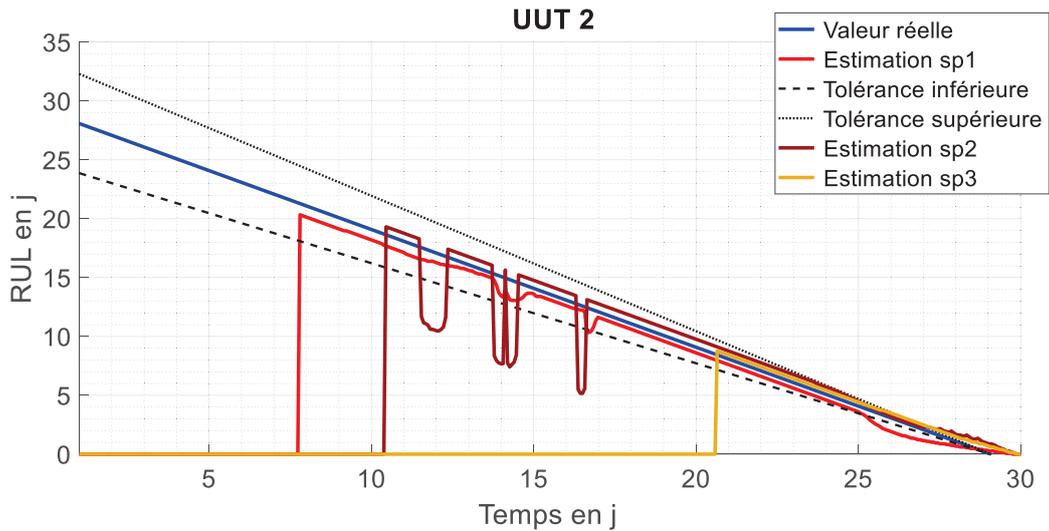


Figure V.36 : Estimation de la RUL pour l'unité 2 – Tolérance à 15% sur la RUL à l'instant  $t$

## 8.4 - Test sur l'unité 3

Les résultats sont les suivants :

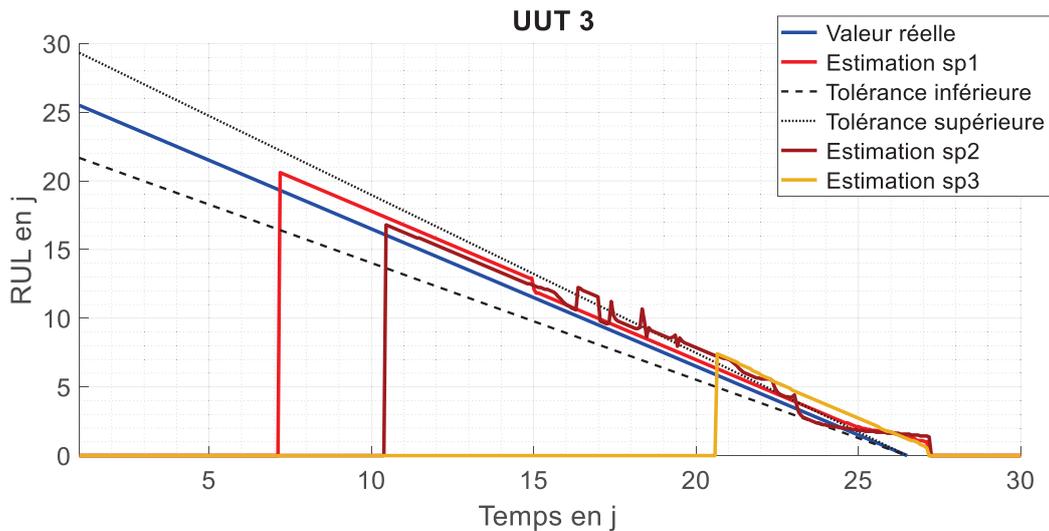


Figure V.37 : Estimation de la RUL pour l'unité 3 – Tolérance à 15% sur RUL à l'instant  $t$

L'ensemble des modèles surestime légèrement la RUL. Ce comportement se conserve même à l'approche de la fin de vie. Le biais est positif et inférieur à 1 jour. Le modèle *sp2* présente encore des oscillations, mais qui ici restent dans la zone de tolérance.

## 8.5 - Test sur l'unité 4

Les résultats sont les suivants :

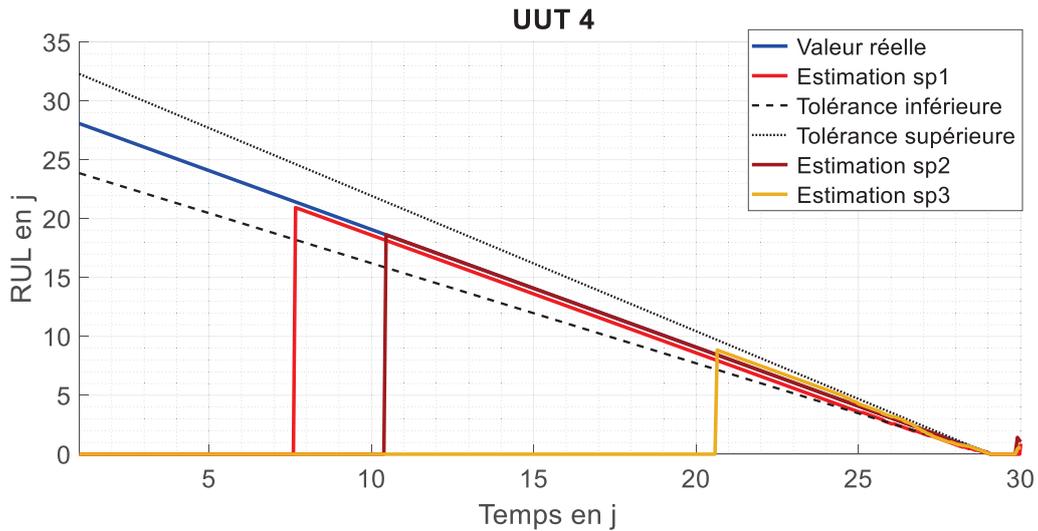


Figure V.38 : Estimation de la RUL pour l'unité 4 – Tolérance à 15% sur RUL à l'instant  $t$

Les trois estimations sont ici très proches de la RUL réelle. Le modèle *sp2* ne présente pas d'oscillations ici. Les trois modèles convergent vers la bonne valeur de fin de vie à l'approche de celle – ci.

## 8.6 - Synthèse

### 8.6.a - Métriques de performances

Les métriques de performances ont été calculées pour les différents modèles et sur chaque unité testée. Les résultats pour le modèle *sp1* sont les suivants :

Métrique / Unitée	1	2	3	4	
PH (j) (Horizon de Pronostic)	11,016	20,604	21,216	20,74	
$\text{moy}[P_{(\alpha_e - \lambda_t)}]$ (%)	6,69	63,7	59,1	68,2	
RA (%)	Max	100	97,4	96,4	97,7
	Moy (CRA)	50,2	67,1	36,1	70,7
	Min	0	0	0	0
Temps de calculs (s)	Max	0,718	0,529	0,573	0,621
	Moy	0,252	0,212	0,224	0,242
	Min	0,007	0,004	0,005	0,005
Mémoire modèle diagnostic (kB)	276	289	324	276	
Mémoire modèles prédiction (kB)	408	389	370	390	

Tableau V.11 : Performances du modèle *sp1*

Les horizons de pronostic sont bons, bien que celui de l'unité 1 soit nettement plus réduit. De même pour la métrique  $\alpha_e - \lambda_t$  qui est correcte pour toutes les unités à l'exception de la une. Cela peut s'expliquer par la forte augmentation de l'erreur de prédiction, un peu avant le temps de fin de vie (voir Figure V.29 et Figure V.30). La précision relative offre des résultats très variables au sein d'une même unité. Cela est dû aux quelques points après le démarrage de la prédiction où la RUL n'est pas estimable. Les temps de calculs sont très corrects. La mémoire bien qu'importante, reste correcte.

Les résultats pour le modèle *sp2* sont les suivants :

Métrique / Unité	1	2	3	4	
PH (j) (Horizon de Pronostic)	14,96	11,764	17,952	17,952	
$\text{moy}[P_{(\alpha_e - \lambda_t)}]$ (%)	0	30,3	51,8	99,7	
RA (%)	Max	100	96,35	100	100
	Moy (CRA)	73,89	86,68	29,72	99,76
	Min	32,37	16,67	0	91,67
Temps de calculs (s)	Max	0,40	0,47	0,43	0,43
	Moy	0,15	0,16	0,16	0,16
	Min	0,004	0,006	0,004	0,005
Mémoire modèle diagnostic (kB)	277	289	324	276	
Mémoire modèles prédiction (kB)	409	441	379	454	

 Tableau V.12 : Performances du modèle *sp2*

Les horizons de pronostic sont ici plus homogènes d'une unité à une autre. La métrique  $\alpha_e - \lambda_t$  est ici nulle pour l'unité 1 et faible pour l'unité 2. Elle est correcte pour les unités 3 et 4. Les précisions relatives sont bonnes sauf pour l'unité 3. Les temps de calculs sont bons pour toutes les unités. La mémoire nécessaire est importante mais reste admissible.

Les résultats pour le modèle *sp3* sont les suivants :

Métrique / Unité	1	2	3	4	
PH (j) (Horizon de Pronostic)	7,752	7,752	7,752	7,752	
$\text{moy}[P_{(\alpha_e - \lambda_t)}]$ (%)	7,8947	73,6842	0	88,5965	
RA (%)	Max	100,00	95,97	73,26	100,00
	Moy (CRA)	65,48	88,10	13,27	92,33
	Min	30,00	41,67	0	78,95
Temps de calculs (s)	Max	0,268	0,267	0,293	0,265
	Moy	0,082	0,085	0,092	0,082
	Min	0,004	0,006	0,007	0,005
Mémoire modèle diagnostic (kB)	277	289	324	276	
Mémoire modèles prédiction (kB)	405	409	407	408	

 Tableau V.13 : Performances du modèle *sp3*

Les horizons de prédiction sont ici tous identiques. Les métriques de précision sont, par contre, très variables d'une unité à une autre. Elles sont mauvaises sur l'unité 3, moyenne sur la 1 et bonnes sur la deux et la quatre. Les temps de prédictions sont bons. Les mémoires nécessaires sont correctes.

Au global, la méthodologie peut offrir de très bonnes performances, notamment en termes d'horizon de pronostic. Les résultats en termes de précisions sont cependant plus variables. Cette variabilité peut s'expliquer en partie par la non prise en compte des incertitudes dans l'estimation de la RUL ainsi que par le manque de précision sur certaines prédictions de signatures.

### 8.6.b - Estimation de la mémoire nécessaire

Les résultats obtenus pour les travaux de ce chapitre permettent d'estimer également la mémoire nécessaire pour la partie estimation de la durée de vie restante. La mémoire nécessaire pour un modèle de diagnostic de sévérité est un peu plus élevée qu'au chapitre précédant (voir IV5.2 - 139).

L'estimation de la mémoire nécessaire pour la partie diagnostic sera donc en partie revue. Les valeurs suivantes servent maintenant de référence :

Nombre de classe modèle défaut ( $c'_{def}$ )	Mémoire modèle défaut (kB)	Nombre de classe modèle sévérité ( $c'_{sev}$ )	Mémoire modèle sévérité pour un défaut (kB)
4	216.4	4	300

Tableau V.14 : Mémoire nécessaire des blocs élémentaires de l'algorithme de diagnostic proposé

A partir de l'équation (IV.2), page 140, la quantité de mémoire nécessaire est réestimée :

$$(V.24) \quad MEM = 216.4 + 3 * 300 = 1164 \text{ kB}$$

L'ordre de grandeur estimé reste donc le même que précédemment. Pour l'estimation de la durée de vie, on fait l'hypothèse suivante :

### Hypothèse 16 : Le diagnostic de sévérité nécessite au plus sept signatures

Cette hypothèse repose sur les tests de la base MSAP sévérité, effectués au chapitre précédent (voir IV4.2.b - 133). On suppose que la mémoire nécessaire pour le modèle de prédiction est égale au pire cas vu lors des tests sur la base roulements, soit 230 kB. Les caractéristiques sont donc les suivantes, en plus des précédentes, pour estimer la mémoire nécessaire pour les modèles de prédictions :

Nombre de signatures pour un modèle de sévérité ( $n_{sign}$ )	Mémoire modèle prédiction d'une signature (kB) ( $MEM_{pred}$ )
7	230

Tableau V.15 : Mémoires nécessaires des blocs élémentaires de l'algorithme d'estimation de la RUL

La mémoire est estimable par :

$$(V.25) \quad MEM_{PRED} = (c'_{def} - 1) * n_{sign} * MEM_{pred}$$

Ce qui donne :

$$(V.26) \quad MEM_{PRED} = 3 * 7 * 230 = 4830 \text{ kB}$$

Cette mémoire est largement inférieure au 24 Mbit disponible pour les algorithmes de prédiction, alors que les calculs effectués ici sont conservatifs. Il reste donc de nombreux degrés de liberté pour pouvoir mettre au point des solutions d'estimation de la durée de vie plus performantes.

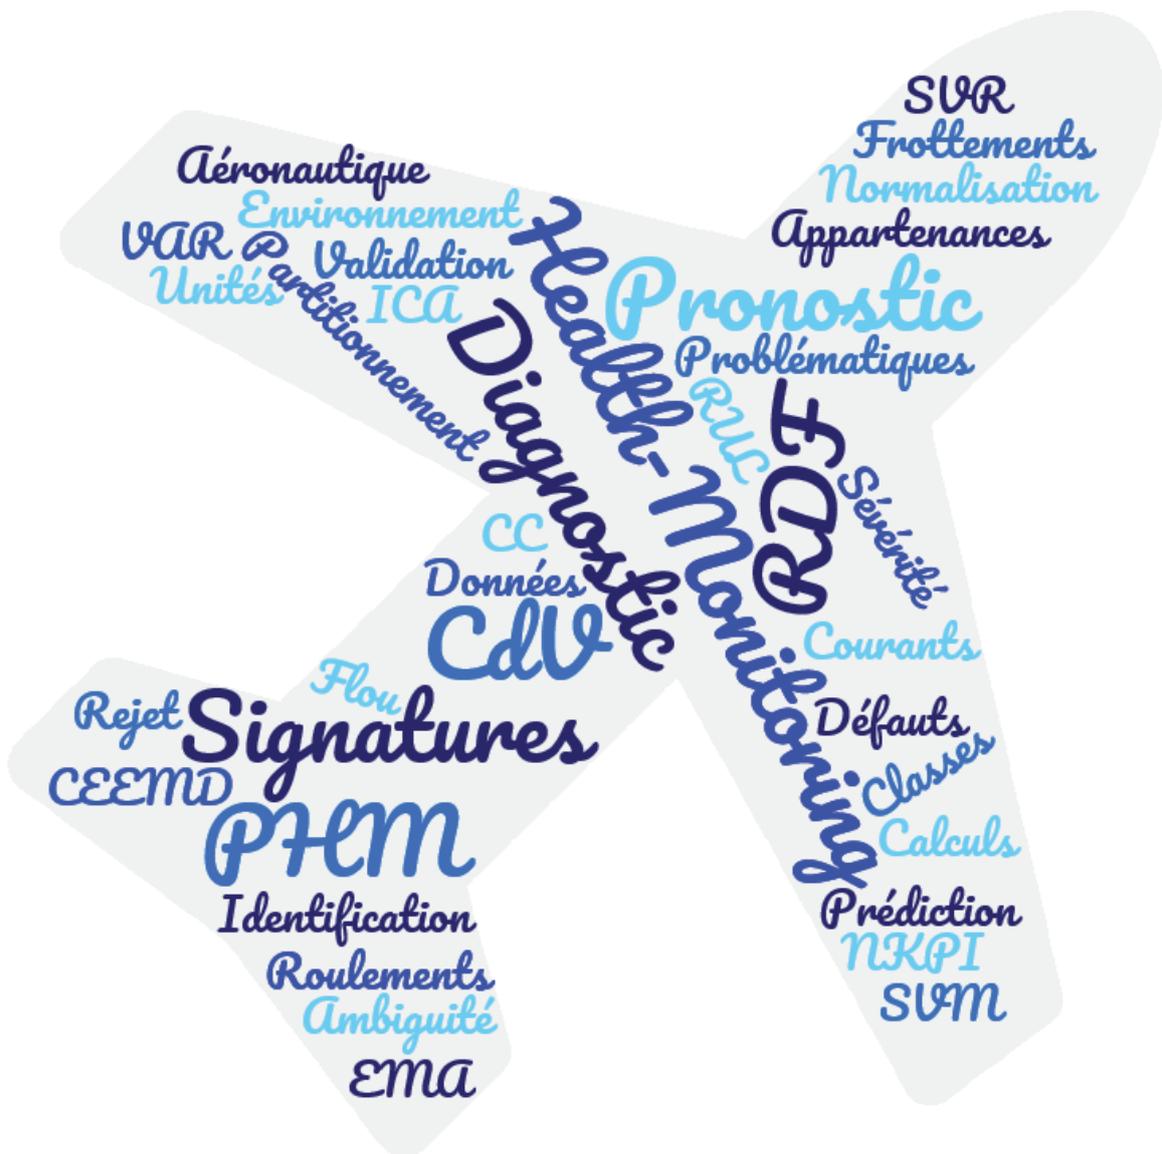
## 9 - Conclusion du chapitre

La première partie de ce chapitre a consisté à définir la notion de pronostic, ainsi que la démarche

pour y parvenir. La notion de fin de vie a notamment été discutée. Elle a été définie comme le démarrage de la dernière classe de sévérité. Une partie la démarche de pronostic a ensuite été traitée sur des données accélérométriques issues d'essais de vieillissement de roulements. La première étape traitée a été de partitionner les données pour établir des classes de sévérité de défauts. Une contrainte était que ces classes doivent être cohérentes temporellement, se succéder dans le même ordre, et ce pour l'ensemble des unités testées. Une métrique d'évaluation de cette contrainte a été proposée. Plusieurs algorithmes de partitionnement ont été comparés selon cette métrique. L'algorithme ayant obtenu les meilleurs résultats est celui des c – moyennes floues. C'est donc celui qui a été sélectionné. L'algorithme par SVM – FA a ensuite été appliqué aux données partitionnées. Une problématique est posée sur la validation. Pour la classification, la base de test est déterminée en sous échantillonnant uniformément la base totale. Or dans le cadre du pronostic, cela a plus de sens d'utiliser toutes les données d'un certain nombre d'unités, et de valider sur les données des unités restantes. Ainsi l'algorithme a été validé selon les deux méthodes. La validation par approche « pronostic » a montré d'importantes variabilités dans les résultats. Cela a amené à proposer une nouvelle méthode de normalisation des données, basée sur une fonction sigmoïde. La prédiction des signatures dans le futur a ensuite été abordée. Celle – ci s'est faite via un algorithme de régression SVR, par approche itérative. Différents temps de démarrage de prédiction ont été testés. Bien que les résultats soient relativement moyens, il a été choisi de continuer jusqu'à l'évaluation des appartenances sur les valeurs de signatures prédites. Les appartenances estimées sont assez proches de celles obtenues sur les données. Elles permettent d'estimer le temps de démarrage de la dernière classe de sévérité, correspondant au temps de fin de vie. Ainsi, la RUL a pu être estimée. Différentes métriques de performance ont été calculées sur ces estimations. Au global, la méthode proposée montre de bons résultats, avec des horizons de prédictions importants. Ces résultats sont cependant assez variables, de par la dispersion des résultats de prédiction. Ainsi, les résultats d'estimation de la RUL pourraient être grandement améliorés en améliorant la partie prédiction des signatures.

# VI

## Conclusion et perspectives



# 1 - Conclusion générale

Le premier chapitre a mis en évidence les nombreux défis qui caractérisent la phase de transition de l'industrie aéronautique. L'avion plus électrique est une des solutions à ces enjeux. Cette électrification touche l'ensemble des systèmes aéronautiques et notamment les commandes de vol. Pour celles-ci, les actionneurs électro – mécaniques sont la piste la plus prometteuse. Cette solution présente encore un inconvénient majeur : le manque de retour d'expériences en termes de durée de vie. Pour répondre à ce verrou, des méthodes de maintenance prédictive sont investiguées. Ces travaux de thèse ont contribué à ces recherches en étudiant des solutions de surveillance pour les EMA de commandes de vol, avec une application sur un actionneur linéaire pour aileron. Les contraintes spécifiques du cadre aéronautique, en termes de temps de calcul et de quantité de mémoire, ont été prises en compte.

La première étape, présentée dans le second chapitre, a été de mettre au point des méthodes de calcul de signatures de défauts. L'ensemble des travaux de ce chapitre répond partiellement aux problématiques des signatures de défauts pour les EMA et notamment celles pour le défaut du système vis – écrou (Problématique 2 page 41). Ainsi le principal défaut traité ici est le défaut de la transmission mécanique. Pour l'actionneur considéré, il s'agit d'une vis à rouleaux satellites. Les deux méthodes proposées reposent sur l'utilisation des seuls capteurs déjà présents dans l'actionneur. La première méthode consiste en l'identification d'un modèle de frottements à partir d'un profil de test. Cette identification se fait par l'algorithme méta – heuristique de l'évolution différentielle. La seconde méthode consiste à analyser le courant dans l'axe de quadrature du repère de Park. Cette analyse s'effectue par combinaison d'un algorithme de décomposition modale empirique avec un algorithme d'analyse en composante indépendante. Un critère a été avancé pour discriminer les composantes liées au défaut de la VAR de celles liées au défaut de court-circuit inter-spires. Les composantes liées à chaque défaut sont ensuite regroupées séparément, afin de créer des signaux virtuels spécifiques à chaque défaut. Un modèle de l'EMA à l'étude a ensuite été utilisé pour faire une série de simulations. L'objectif était de reproduire des essais sur une population d'actionneurs, pour le cas sain et pour les différents cas de défauts. Les algorithmes de calculs de signatures ont été appliqués aux mesures issues de chacune des simulations. Les signatures obtenues ont permis de calculer des indicateurs clés de performances : la détectabilité (la capacité à détecter un défaut ou non). Les signatures mises au point permettent une très bonne détectabilité du défaut de la VAR et une assez modérée du défaut de CC. Au niveau de l'identifiabilité (la capacité à distinguer la sévérité d'un défaut des autres sévérités), les performances sont moyennes. Ces métriques de performances des signatures ne sont pas les seuls indicateurs sur les performances du diagnostic. En effet, la méthode d'évaluation des signatures joue, elle aussi, un rôle très important.

Ainsi un algorithme de diagnostic par reconnaissance de formes a été proposé au chapitre trois. Les travaux de ce chapitre répondent à la problématique de l'algorithme de diagnostic pour le cadre aéronautique (Problématique 1 page 40). Ils répondent également partiellement à celui de sa mise à jour au cours du temps (Problématique 3 page 41). Comme toutes méthodes de RDF, l'algorithme étudie un vecteur de formes, au sein duquel sont rassemblées les signatures de défaut. L'algorithme proposé ici repose sur une combinaison de machines à vecteur de support et de fonction d'appartenances floues. Ces familles d'algorithmes ont été choisies pour leur grande robustesse.

L'algorithme proposé permet de calculer les degrés d'appartenance d'une observation aux différentes classes de défaut. Il fournit également le degré d'appartenance à des classes non définies (inconnues). La construction de ces appartenances a été explicitée par des exemples sur des bases de données artificielles. Ces degrés d'appartenances permettent de calculer des indicateurs d'ambiguïté (appartenance forte à deux classes à la fois) et de rejet (appartenance faible à toutes les classes). Le premier indicateur permet, dans le cas du diagnostic, de détecter d'éventuels cas de défauts combinés. Le deuxième permet de détecter des cas de défauts inconnus, non représentés dans la base d'apprentissage. Ces deux indicateurs combinés ont conduit à la mise en place d'une règle de décision. Celle-ci permet de déterminer, automatiquement, les observations qui nécessitent des investigations par des experts humains.

L'ensemble des algorithmes proposés aux deux chapitres précédents ont ensuite été testés sur des données expérimentales au chapitre quatre. Trois jeux de données, issues de trois bancs différents, ont été utilisés. Le premier jeu est issu d'expérimentations sur un banc Safran, représentatif de l'architecture d'implémentation de l'EMA aileron dans l'avion. Le deuxième jeu est issu d'un banc de test de moteur synchrone à aimants avec la possibilité de tester des cas de court-circuits inter-spires. Le troisième est issu d'un banc de test de machine asynchrone pour différents cas de défauts. Le premier jeu a permis de tester les algorithmes de calcul de signatures. L'algorithme d'identification des frottements converge bien, mais pour des temps de calculs un peu élevés. Une deuxième méthode a donc été proposée, qui consiste à calculer des points moyens sur les phases stationnaires (vitesses constante) et à effectuer l'identification sur ces points moyens. Les temps de calculs sont alors très nettement réduits, au prix d'une erreur un peu plus importante. L'algorithme d'analyse des courants a lui, réussi à extraire les signaux virtuels des défauts. Néanmoins, afin de parvenir à cela en des temps de calcul raisonnables, seule une sous-portion du profil a été traitée. Le nombre d'itérations de l'algorithme a également été réduit. Cela se traduit par l'obtention de signaux virtuels bruités. Les deuxièmes et troisièmes jeux de données ont permis de valider expérimentalement l'algorithme de diagnostic proposé au chapitre 3. Le premier jeu a servi à valider la partie estimation de la sévérité et le troisième la partie détection de défauts avec décision automatique de rejet. Pour les deux jeux, la méthode utilisée a été une validation croisée 5-Fold Out. Celle-ci a d'abord été effectuée sur une base d'apprentissage « pauvre », avec pour chaque itération 1/5 des points pour l'apprentissage et 4/5 pour le test. Puis la validation a été effectuée de manière classique avec 4/5 des points pour l'apprentissage et 1/5 pour le test à chaque itération. Pour les deux méthodes de validation, l'algorithme proposé a été comparé à des méthodes issues de notre état de l'art. L'algorithme proposé s'avère être plus robuste, pour des temps de calculs un peu plus élevés. Finalement le respect des contraintes aéronautiques est évalué. Le calcul des signatures est négligeable en termes de quantité de mémoire de stockage. Les temps de calculs, eux, respectent les contraintes. La partie diagnostic est, elle, très faible en temps de calcul. La quantité de mémoire nécessaire respecte parfaitement les contraintes, avec une marge importante. Ce résultat est d'autant plus notable que la mémoire n'a pas été optimisée. Les bons résultats de la méthode de diagnostic proposée offrant des pistes intéressantes pour aller vers le pronostic, celles-ci ont été investiguées.

Le chapitre cinq a traité de ces aspects. Les travaux proposés au sein de ce chapitre ont permis d'apporter des éléments de réponse à la problématique des algorithmes de pronostic pour

l'aéronautique (Problématique 1 page 40). De nombreux problèmes différents ont été rencontrés au sein de cette partie. Il a ainsi été fait le choix de présenter l'ensemble de la méthodologie pour aller vers le pronostic, du calcul des signatures à l'estimation de la RUL. L'application s'est faite sur une base benchmark de vieillissements de roulements. En premier lieu, la problématique du partitionnement de séries temporelles pour le pronostic a été traitée. Un comparatif par rapport à l'état de l'art du partitionnement de séries temporelles a permis de mettre en avant les caractéristiques de cette problématique. A partir de celles – ci, une métrique de cohérence temporelle a été proposée. Cette métrique permet de s'assurer du respect de ces contraintes. Différents algorithmes issus d'un état de l'art ont été testés. L'algorithme des c – moyennes floues a montré les meilleures performances et a donc été sélectionné. L'algorithme de diagnostic proposé au chapitre trois a ensuite été testé sur les données partitionnées. Ces tests ont mis en évidence une problématique. En diagnostic, la phase de test consiste à appliquer le modèle entraîné sur des points non utilisés pour l'apprentissage. Ces points, qui constituent la base de test, sont issus d'un sous échantillonnage uniforme de la base de départ. Cette méthode ne correspond pas à la réalité opérationnelle. Dans la pratique, on dispose de l'ensemble des données sur un certain nombre d'unités et on souhaite appliquer l'algorithme sur de nouvelles unités. Ainsi, toutes les données concernant un certain nombre d'unités sont utilisées pour l'apprentissage. Puis, l'intégralité des données sur les unités restantes permettent d'effectuer le test. Cette validation est ici dite validation « pronostic ». Les deux méthodes de validation ont montré des résultats très différents. La validation « pronostic » a montré des résultats beaucoup plus variables. Cette variabilité s'explique par le fait que les valeurs extrêmes de signatures sont parfois situées dans l'unité en test. Or les méthodes de normalisation classiques supposent que les valeurs extrêmes sont dans la base d'apprentissage. Ainsi ce phénomène diminue l'efficacité de la normalisation. Une nouvelle méthode de normalisation, basée sur la fonction sigmoïde a donc été proposée. Celle – ci permet d'avoir de bonnes performances. La prédiction des signatures à partir de séquence d'observations a ensuite été traitée. Celle – ci s'est faite par régression à vecteur de supports, de manière itérative. Bien que présentant des résultats moyens, il a été choisi de poursuivre sur l'estimation des appartenances à partir des prédictions. Les appartenances obtenues ont été évaluées qualitativement. Elles se montrent assez semblables aux appartenances obtenues directement à partir des données, même si quelques oscillations sont parfois observables. Ces oscillations sont dues aux oscillations au niveau de la prédiction des signatures. Le temps de fin de vie, défini comme le passage dans la dernière classe de sévérité, a pu être estimé à partir des appartenances prédites. Cela a permis d'estimer la RUL. Cette estimation a été effectuée pour différents temps de démarrage de prédictions. L'ensemble des modèles ont été évalués selon différentes métriques. Les résultats montrent des erreurs d'estimation acceptables, bien que variables d'une unité à une autre. Les horizons de prédiction sont eux très corrects. Une ré – estimation de la quantité de mémoire nécessaire a été effectuée. Les besoins s'avèrent encore largement en dessous des contraintes. Les temps de calculs sont également, très largement en dessous des contraintes.

## 2 - Perspectives

Des contributions ont été apportées à la problématique, très large, de la maintenance prédictive des EMA de commande de vol. De nombreux aspects restent néanmoins à traiter. On distinguera quatre groupes de perspectives. Le premier groupe rassemble les perspectives liées aux hypothèses utilisées

dans ces travaux. Le second présente les pistes générales, liées à la mise en place de tout processus de maintenance prédictive. Le troisième discute les perspectives liées à la maintenance prédictive d'actionneur électro – mécanique. Enfin le dernier mettra en avant les développements envisageables pour la surveillance des EMA dans l'aéronautique et notamment pour les commandes de vol.

## 2.1 - Liées aux hypothèses

Le premier ensemble d'hypothèses posées a porté sur les parties acquisition et modélisation en vue du calcul de signatures. L'*Hypothèse 2 : Seul un actionneur est en défaut* a notamment été posée. Cette hypothèse doit être discutée. Comment les signatures vont évoluer si les deux actionneurs sont endommagés en même temps ? Permettent – elles de distinguer les défauts de chaque actionneur ? Ces questions devront être résolues. L'*Hypothèse 3 : Les coefficients de frottements de la VAR sont identiques dans les deux sens de déplacement* a été prise à des fins de simplification. Il est néanmoins connu que pour ce type de transmissions, les frottements aller sont différents des frottements retours. Ainsi il pourrait être envisagé de distinguer ces deux modes de fonctionnement dans la modélisation. L'objectif serait de voir si cela permet des gains de sensibilité suffisamment importants ou non. L'*Hypothèse 4 : Le moteur synchrone à aimants est supposé linéaire sur la plage de fonctionnement* considérée est raisonnable pour le cadre applicatif d'EMA pour aileron. Pour d'autres cadres applicatifs, avec des profils de fonctionnement très dynamiques comme pour les applications d'inverseurs de poussés électriques, cette hypothèse serait à revoir.

Le deuxième ensemble d'hypothèses porte sur la base de données pour le diagnostic et notamment sa représentativité et son volume (voir Hypothèse 6 et Hypothèse 7 page 77). Ces hypothèses, bien que fortes, sont en partie assurées par la boucle de rétroaction permise par la règle de décision proposée dans les présents travaux. Celle – ci permet en effet de détecter les nouveaux cas de défauts et ainsi d'améliorer la base de données au cours du temps.

Les hypothèses prises pour estimer la quantité de mémoire nécessaire sont sciemment conservatives (voir Hypothèse 9 Hypothèse 10 Hypothèse 11, page 139). La question de savoir si les technologies actuelles permettraient, en termes de quantité de mémoire, d'embarquer les algorithmes a été résolue. Reste maintenant à étudier la réalisation de cette embarcation.

Enfin les dernières hypothèses posées concernent la partie pour aller vers le pronostic et notamment sur la manière dont se dégrade le système au cours du temps. Deux hypothèses fortes ont été prises ici : l'*Hypothèse 12 : La dégradation du système est monotone* et l'*Hypothèse 13 : Le système se dégrade uniquement en fonctionnement*. L'Hypothèse 13 est assez raisonnable. A l'inverse, l'Hypothèse 12 doit être discutée. En effet des effets de « rajeunissement » sont créés par les opérations de maintenance, comme par exemple la lubrification de composants mécaniques. Cette hypothèse pose également la question des systèmes réparés et remis en service. Comment prendre en compte ce type d'opérations dans l'estimation de la RUL ? La question reste ouverte.

## 2.2 - Générales

**La détection automatique de points inconnus** est un vrai enjeu pour le diagnostic basé sur la reconnaissance de formes. La méthode proposée est équivalente à deux classifieurs successifs, avec

les paramètres du second, les indicateurs d'ambiguïté et de rejet, calculés par le premier. Le choix du deuxième classificateur a été ici un système simple de comparaison à des seuils. Des classificateurs plus évolués, avec les mêmes indicateurs d'ambiguïté et de rejet, pourraient permettre d'améliorer les performances de la règle de décision. Cela pourrait également permettre de faciliter le réglage.

**Le calcul de sévérité** a ici été validé sur un cas simple, avec une suite géométrique de valeurs du paramètre de sévérités. La sévérité inconnue a été choisie au centre de l'échelle. La méthode fonctionne – t – elle encore pour des sévérités réparties aléatoirement entre la sévérité minimale et la sévérité maximale ? Et si non, quelles sont les modifications à apporter pour la faire fonctionner ? Comment définir le paramètre de sévérité et l'échelle associée, autrement que par connaissances d'expert ? Toutes ces questions restent ouvertes.

**Le partitionnement de séries temporelles pour le pronostic** est une tâche complexe. La métrique de cohérence temporelle proposée permet d'évaluer les résultats d'un algorithme donné. L'étape suivante est, non plus d'évaluer un algorithme via la cohérence, mais d'inclure celle – ci dans la fonction coût de l'algorithme. Cela permettrait de forcer la cohérence et ainsi d'offrir plus d'options dans le choix des méthodes de partitionnement.

**La prédiction de séries temporelles** reste un sujet très ouvert. La méthode itérative, très largement utilisée en pronostic, ne tient pas compte des corrélations entre signatures. Les méthodes parallèles, bien que plus performantes, ont tendance à avoir des coûts de calculs importants. Des tentatives ont été faites dans le cadre de ces travaux, avec une version parallèle de l'algorithme SVR. L'horizon maximum obtenu était de quelques pas de temps, pour des temps de calculs extrêmement élevés. Les méthodes connexionnistes semblent plus prometteuses pour ces tâches (**Gouriveau et Zerhouni 2012**). Les approches par réseaux de neurones profonds semblent être une piste intéressante comme le montre le nombre de travaux récents sur le sujet (**Kuremoto et al. 2014; Agana et Homaifar 2017; Berriel et al. 2017; Song et Dai 2017; López et al. 2018**). Bien entendu, il peut exister d'autres outils et méthodes pour résoudre cette problématique.

**Les incertitudes** sont au centre de la notion de pronostic (**Sankararaman et Goebel 2013b, 2015; Vandawaker et al. 2015**). Ce point n'a pas été traité dans le cadre de ces travaux de thèse mais reste absolument essentiel. La problématique majeure sur cet axe est le choix de la méthode de représentation et la quantification pour des cas avec peu de données. La validation des méthodologies liées aux incertitudes reste également un sujet ouvert.

## 2.3 - Actionneurs électro – mécaniques

**La modélisation et l'identification des frottements** est un enjeu important pour le diagnostic des transmissions mécaniques. Le modèle utilisé ici, bien qu'efficace, reste assez simple. Des modèles plus complexes existent, notamment le modèle de LuGre, particulièrement adapté aux actionneurs électro – mécaniques (**Canudas de Wit et al. 1995; Altpeter 1999; Astrom et Canudas-de-Wit 2008; Feyel et al. 2013**). Ces autres modèles pourraient permettre de gagner en sensibilité et en robustesse. Les méthodes de compensation de friction, notamment par rapport à la température, pourrait permettre de normaliser les signatures issues des frottements (**Feyel 2015**). Un autre aspect est d'étudier l'identification sur des profils opérationnels (en vol).

**La méthode d'analyse des courants par CEEMD – ICA** peut encore être travaillée. Les temps de calcul s'avèrent longs. Une diminution de ceux – ci constitue donc un axe de recherches. D'autre part, la méthode pourrait être utilisée pour calculer des signatures pour d'autres types de défauts.

L'applicabilité de la méthode sur des profils opérationnels doit être étudiée. A noter que la méthode pourrait également s'avérer performante pour le calcul de signatures de chaînes mécaniques complexes.

**Les signatures pour le défaut de court – circuit inter – spires** restent encore un axe assez ouvert, notamment pour le cas des défauts naissants. Une méthode d'estimation de l'état des isolants statoriques permettrait d'avoir des signatures sur de tels défauts.

## 2.4 - EMA – Commandes de Vol

**L'acquisition de données d'essais représentatives** est une des problématiques majeures de la surveillance des EMA de commandes de vol. Les prototypes de ce type d'actionneurs ont des coûts élevés. Il en est de même pour les bancs permettant de les tester. De plus, leurs durées de vie sont assez longues. Il paraît donc difficile de réaliser des essais de vieillissement sur une population significative, pour des coûts et des délais raisonnables. Ainsi, il paraît plus efficace d'effectuer des essais de vieillissement accéléré sur des populations des principaux composants (transmission, roulements, stator) dans un premier temps. Cela permet de déterminer les lois de vieillissement des composants et de tester certains algorithmes de signatures. Il peut être envisagé, ponctuellement, de remonter les composants vieillis pour former un EMA et caractériser celui – ci sur différents profils. Cela doit se faire en s'assurant que le montage / démontage ne change pas de manière significative les composants. Enfin, le test sur des EMA complets se fait au final, une fois que le vieillissement des composants est bien connu. Ce test peut se faire conjointement avec les essais d'endurance des phases de qualification.

**L'acquisition de données opérationnelles** permettrait d'assurer la représentativité. Cela permettrait notamment de dégager des tendances sur l'évolution des signatures et d'estimer l'influence d'un certain nombre de paramètres de contexte. De telles données, acquises sur une longue période, permettraient également d'obtenir l'évolution de la dégradation des signatures dans le temps.

**L'implémentation des algorithmes en calculateur embarqué** est un axe à part entière. Dans un premier temps, un calculateur pouvant traiter à la fois les fonctions de pilotage des commandes de vol et celles de la surveillance, devra être mis au point. A la suite de cela, les algorithmes mis au point devront être optimisés et codés au sein du calculateur (**Todeschi et Baxerres 2015**).

**Les incertitudes, pour le cadre aéronautique**, vont avoir une influence importante. Cela est dû aux grands nombres de paramètres de contexte (température, conditions météorologiques durant les vols, taux de charge de l'avion...). Ainsi la gestion de ces paramètres et de leurs incertitudes est extrêmement importante pour aboutir à des prédictions de la durée de vie précises et robustes.

La réalisation de l'ensemble de ces tâches permettra d'aboutir à une aéronautique plus respectueuse de l'environnement, plus économique et plus sûre.

# VII

## BIBLIOGRAPHIE

## BIBLIOGRAPHIE

- ABB. Bearing currents in modern AC drive systems. 2011. Report No.: 5.
- Adams C. A380: 'More Electric' Aircraft. Avionics Magazine [Internet]. 10 janv 2001; Disponible sur: <http://www.aviationtoday.com/2001/10/01/a380-more-electric-aircraft/>
- Aeronews. Qu'est-ce- que le temps de rotation d'un avion ? [Internet]. aeronewstv.com. 2016. Disponible sur: <http://www.aeronewstv.com/fr/lifestyle/a-votre-avis/3367-quest-ce-que-le-temps-de-rotation-dun-avion.html>
- AFNOR. Fascicule de Documentation FD X60-000 - Maintenance industrielle. Fonction Maintenance. 2002.
- Agana NA, Homaifar A. A deep learning based approach for long-term drought prediction. In IEEE; 2017 [cité 5 oct 2017]. p. 1-8. Disponible sur: <http://ieeexplore.ieee.org/document/7925314/>
- Aghabozorgi S, Shirkhorshidi AS, Wah TY. Time-series clustering—A decade review. Inf Syst. 2015;53:16-38.
- Aguet M, Ianoz M. Haute tension. Lausanne: Presses polytechniques et universitaires romandes; 2001.
- Aha DW, Kibler D, Albert MK. Instance-based learning algorithms. Mach Learn. 1991;6(1):37-66.
- Airbus. Global Market Forecast - Mapping Demand 2016 / 2035. Airbus; 2016.
- Aizerman MA, Braverman EA, Rozonoer L. Theoretical foundations of the potential function method in pattern recognition learning. In: Automation and Remote Control,. 1964. p. 821-37.
- Ali A, Mahdi D. Independent component analysis approach for fault diagnosis of condenser system in thermal power plant. J Cent South Univ. janv 2014;21(1):242-51.
- Altpeter F. Friction modeling, identification and compensation [Internet]. Ecole Polytechnique Fédérale de Lausanne; 1999 [cité 23 juin 2015]. Disponible sur: <http://dx.doi.org/10.5075/epfl-thesis-1988>
- Anton A. Caractéristiques électriques des matériaux isolants. Tech Ing Propr Électr Electrochim [Internet]. 2003;base documentaire: TIB336DUO.(ref. article: k712). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/sciences-fondamentales-th8/proprietes-electriques-et-electrochimiques-42336210/caracteristiques-electriques-des-materiaux-isolants-k712/>
- Antoni J. Blind separation of vibration components: Principles and demonstrations. Mech Syst Signal Process. 2005;19(6):1166-80.
- de Arriba R, Gallego A. Health and Usage Monitoring System (HUMS) Strategy to enhance the Maintainability & Flight Safety in a Flight Control Electromechanical Actuator (EMA). In 2016.
- Astrom KJ, Canudas-de-Wit C. Revisiting the LuGre friction model. IEEE Control Syst. déc 2008;28(6):101-14.
- Balaban E, Saxena A, Narasimhan S, Roychoudhury I, Koopmans M, Ott C, et al. Prognostic health-management system development for electromechanical actuators. J Aersp Inf Syst. 2015;

## BIBLIOGRAPHIE

- Baraldi P, Mangili F, Zio E. Investigation of uncertainty treatment capability of model-based and data-driven prognostic methods using simulated data. *Reliab Eng Syst Saf*. 2013;112:94-108.
- Barber D. *Bayesian Reasoning and Machine Learning* [Internet]. Cambridge University Press; 2012. Disponible sur: <http://www.cs.ucl.ac.uk/staff/d.barber/brml/>
- Bartram G, Mahadevan S. *Dynamic Bayesian Networks for Prognosis*. In New Orleans , USA; 2013. Disponible sur: <http://www.phmsociety.org/node/1044/>
- Bartram G, Mahadevan S. Probabilistic Prognosis with Dynamic Bayesian Networks. *Int J Progn Health Manag*. 2017;6.
- Bellini A, Filippetti F, Tassoni C, Capolino G-A. Advances in diagnostic techniques for induction machines. *IEEE Trans Ind Electron*. 2008;55(12):4109-26.
- Bellomo JP, Lebey T, Oraison JM, Peltier F. Electrical aging of stator insulation of low voltage rotating machines supplied by inverters. In: *Conference Record of the 1996 IEEE International Symposium on Electrical Insulation*. 1996. p. 210-3 vol.1.
- Belmonte D, Dalla Vedova MDL, Maggiore P. Onboard Electromechanical Actuators Affected by Motor Static Eccentricity: a New Prognostic Method based on Spectral Analysis Techniques. In: *New Developments in Pure and Applied Mathematics* [Internet]. WSEAS Press; 2015. p. 166-72. Disponible sur: <http://porto.polito.it/2604987/>
- Ben-Gal I. Bayesian Networks. In: *Encyclopedia of Statistics in Quality and Reliability* [Internet]. John Wiley & Sons, Ltd; 2008. Disponible sur: <http://dx.doi.org/10.1002/9780470061572.eqr089>
- Béranger G, Mazille H. Approche scientifique des surfaces. Caractérisation et propriétés. *Tech Ing Surf* [Internet]. 2005;base documentaire : TIB463DUO.(ref. article : m1425). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/mecanique-th7/surfaces-42463210/approche-scientifique-des-surfaces-caracterisation-et-proprietes-m1425/>
- Berriel RF, Lopes AT, Rodrigues A, Varejao FM, Oliveira-Santos T. Monthly energy consumption forecast: A deep learning approach. In *IEEE*; 2017 [cité 5 oct 2017]. p. 4283-90. Disponible sur: <http://ieeexplore.ieee.org/document/7966398/>
- Bezdek JC. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Norwell, MA, USA: Kluwer Academic Publishers; 1981.
- Bezdek JC, Ehrlich R, Full W. FCM: The fuzzy c-means clustering algorithm. *Comput Geosci*. 1984;10(2):191-203.
- Billard T, Lebey T, Fresnet F. Partial discharge in electric motor fed by a PWM inverter: off-line and on-line detection. *IEEE Trans Dielectr Electr Insul*. juin 2014;21(3):1235-42.
- Bishop T. *Dealing with shaft and bearing currents*. Electrical Apparatus Service Association; 2017.
- Boeing. *Current Market Outlook - 2016 / 2035* [Internet]. The Boeing Company; 2016. Disponible sur: [http://www.boeing.com/resources/boeingdotcom/commercial/about-our-market/assets/downloads/CMO\\_2015\\_infographic.pdf](http://www.boeing.com/resources/boeingdotcom/commercial/about-our-market/assets/downloads/CMO_2015_infographic.pdf)
- Boggs PT, Tolle JW. Sequential quadratic programming. *Acta Numer*. 1996;4:1-51.

## BIBLIOGRAPHIE

- Boileau T. Contribution à la continuité de service des actionneurs synchrones à aimants permanents. Tolérance au défaut de capteur mécanique. Détection de Défauts Electriques [Internet]. 2010. Disponible sur: <http://www.theses.fr/2010INPL068N/document>
- Boileau T, Leboeuf N, Nahid-Mobarakeh B, Meibody-Tabar F. Online Identification of PMSM Parameters: Parameter Identifiability and Estimator Comparative Study. IEEE Trans Ind Appl. juill 2011;47(4):1944-57.
- Bolander N, Qiu H, Eklund N, Hindle E, Rosenfeld T. Physics-based Remaining Useful Life Prediction for Aircraft Engine Bearing Prognosis. In 2009.
- Bonnett AH. Root cause AC motor failure analysis with a focus on shaft failures. IEEE Trans Ind Appl. 2000;36(5):1435-48.
- Bonny F. Système de déplacement motorisé d'un élément mobile, procédé de pilotage d'un tel système et procédé de test d'un tel système [Internet]. 2013. Disponible sur: <https://www.google.fr/patents/WO2012052438A3?cl=fr>
- Bontempi G, Taieb SB, Le Borgne Y-A. Machine learning strategies for time series forecasting. In: Business Intelligence. Springer; 2013. p. 62-77.
- van den Bossche D. More Electric' Control Surface Actuation - A Standard for the Next Generation of Transport Aircraft. In Royal Aeronautical Society; 2004.
- Botten SL, Whitley CR, King AD. Flight Control Actuation Technology for Next-Generation All-Electric Aircraft. Technology Review Journal. 2000;
- Breuneval R, Clerc G, Nahid-Mobarakeh B, Mansouri B. Hybrid diagnosis of intern-turn short-circuit for aircraft applications using SVM-MBF. In IEEE; 2017 [cité 8 janv 2018]. p. 1-6. Disponible sur: <http://ieeexplore.ieee.org/document/8015588/>
- Breuneval R, Clerc G, Nahidmobarakeh B, Mansouri B, Guyamier A. Identification of a roller screw for diagnosis of flight control actuator. In Ottawa, ON: IEEE International Conference on Prognosis and Health Management; 2016.
- Brière D, Traverse P. AIRBUS A320/A330/A340 electrical flight controls-a family of fault-tolerant systems. In: Fault-Tolerant Computing, 1993 FTCS-23 Digest of Papers, The Twenty-Third International Symposium on. IEEE; 1993. p. 616-23.
- Burges CJC. A Tutorial on Support Vector Machines for Pattern Recognition. Data Min Knowl Discov. juin 1998;2(2):121-67.
- Byington CS, Watson M, Edwards D, Stoelting P. A model-based approach to prognostics and health management for flight control actuators. In: Aerospace Conference, 2004 Proceedings 2004 IEEE. IEEE; 2004. p. 3551-62.
- Canudas de Wit C, Olsson H, Astrom KJ, Lischinsky P. A new model for control of systems with friction. IEEE Trans Autom Control. mars 1995;40(3):419-25.
- Casimir R. Faults diagnosis of induction motors by pattern recognition [Internet] [Theses]. Ecole Centrale de Lyon; 2003. Disponible sur: <https://tel.archives-ouvertes.fr/tel-00139706>
- Celaya JR, Saxena A, Goebel K. Uncertainty representation and interpretation in model-based

## BIBLIOGRAPHIE

- prognostics algorithms based on kalman filter estimation. In 2012a.
- Celaya JR, Saxena A, Kulkarni CS, Saha S, Goebel K. Prognostics approach for power MOSFET under thermal-stress aging. In: 2012 Proceedings Annual Reliability and Maintainability Symposium. 2012b. p. 1-6.
- CEN. Norme Européenne NF EN 13306 - Terminologie de la maintenance. 2001.
- Chafai M, Refoufi L, Bentarzi H. Reliability Assessment and Improvement of Large Power Induction Motor Winding Insulation Protection System Using Predictive Analysis. *WSEAS Trans Cir Sys. avr 2008;7(4):184-93.*
- Charoy A, Dunand P. Bearing current induced by a power drive. 2007;
- Cheng J, Greiner R. Comparing Bayesian Network Classifiers. In: Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence [Internet]. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.; 1999. p. 101-8. Disponible sur: <http://dl.acm.org/citation.cfm?id=2073796.2073808>
- Cheng S, Pecht M. A fusion prognostics method for remaining useful life prediction of electronic products. In: Automation Science and Engineering, 2009 CASE 2009 IEEE International Conference on. IEEE; 2009. p. 102-7.
- Cheong S, Oh SH, Lee S-Y. Support vector machines with binary tree architecture for multi-class classification. *Neural Inf Process-Lett Rev. 2004;2(3):47-51.*
- Choi S, Akin B, Rahimian MM, Toliyat HA. Performance-Oriented Electric Motors Diagnostics in Modern Energy Conversion Systems. *IEEE Trans Ind Electron. févr 2012;59(2):1266-77.*
- Choi S, Cichocki A, Park H-M, Lee S-Y. Blind source separation and independent component analysis: A review. *Neural Inf Process-Lett Rev. 2005;6(1):1-57.*
- Chossière GP, Malina R, Ashok A, Dedoussi IC, t SDE, Speth RL, et al. Public health impacts of excess NO x emissions from Volkswagen diesel passenger vehicles in Germany. *Environ Res Lett. 2017;12(3):034014.*
- Comon P. Independent component analysis, a new concept? *Signal Process. 1994;36(3):287-314.*
- Cover T, Hart P. Nearest neighbor pattern classification. *IEEE Trans Inf Theory. janv 1967;13(1):21-7.*
- Cronin MJ. Electromechanical actuator system with anti-jamming features [Internet]. 1986. Disponible sur: <http://www.google.com/patents/US4575027>
- Cui Q, Li Z, Yang J, Liang B. Rolling bearing fault prognosis using recurrent neural network. In: 2017 29th Chinese Control And Decision Conference (CCDC). 2017. p. 1196-201.
- Culbert I, Lloyd B, Stone G. Stator insulation problems caused by variable speed drives. In: 2009 Conference Record PCIC Europe. 2009. p. 187-92.
- Czyżżak P, Jaskiewicz A. Pareto simulated annealing—a metaheuristic technique for multiple-objective combinatorial optimization. *J Multi-Criteria Decis Anal. janv 1998;7(1):34-47.*
- Dalla Vedova MDL, Lauria D, Maggiore P, Pace L. Linear Electromechanical Actuators Affected by

## BIBLIOGRAPHIE

- Mechanical Backlash: a Fault Identification Method Based on Simulated Annealing Algorithm. WSEAS Trans Syst. 2015a;14:268-77.
- Dalla Vedova MDL, Maggiore P, Pace L. A New Prognostic Method Based on Simulated Annealing Algorithm to Deal with the Effects of Dry Friction on Electromechanical Actuators. Int J Mech. 2015b;9:236-45.
- Dalla Vedova MDL, Maggiore P, Pace L, Romeo S. Model based fault detection neural technique for electromechanical servomechanisms. In: Recent Advances in Computer Engineering Series No 35 - Proceedings of the 6th European Conference of Computer Science (ECCS '15) [Internet]. WSEAS Press; 2015c. p. 66-72. Disponible sur: <http://porto.polito.it/2642532/>
- Dalla Vedova MD, Pace PML, Desando A. Evaluation of the correlation coefficient as a prognostic indicator for electromechanical servomechanism failures. International Journal of Prognostics and Health Management. 2012;
- Dalla Vedova M, Maggiore P, Pace L, Romeo S. Proposal of a model based fault identification neural technique for more-electric aircraft flight control EM actuators. WSEAS Trans Syst. 2016;15.
- Delehelle A. Étude d'un concept innovant d'actionneur électromécanique linéaire à effets magnétique et piézoélectrique en vue d'applications dans le domaine des commandes de vol. Université de Toulouse; 2008.
- De Martin A, Jacazio G, Vachtsevanos G. Anomaly Detection and Prognosis for Primary Flight Control EMAs. In 2016.
- Derrien J-C. Electromechanical actuator (EMA) advanced technologies for flight controls. In 2012.
- Derrien J-C, Tieys P, Senegas D, Todeschi M. EMA Aileron COVADIS Development. SAE Technical Paper; 2011.
- DGAC. Rapport Environnement. Direction Générale de l'Aviation Civile; 2014.
- Doak J. An Evaluation of Feature Selection Methods and Their Application to Computer Security. [Internet]. UC Davis Dept of Computer Science tech reports; 1992. Report No.: CSE-92-18. Disponible sur: <http://escholarship.org/uc/item/2jf918dh>
- Domingos P. A Unified Bias-Variance Decomposition and its Applications. In: In Proc 17th International Conf on Machine Learning. Morgan Kaufmann; 2000. p. 231-8.
- Domingos P. A few useful things to know about machine learning. Commun ACM. 2012;55(10):78-87.
- Dubois D, Prade H. Possibility Theory. In: Webster JG, éditeur. Wiley Encyclopedia of Electrical and Electronics Engineering [Internet]. Hoboken, NJ, USA: John Wiley & Sons, Inc.; 1999 [cité 17 août 2015]. Disponible sur: <http://doi.wiley.com/10.1002/047134608X.W3502>
- Dubois D, Prade H. Possibility Theory and its Applications: Where Do we Stand? 2011; Disponible sur: <http://www.irit.fr/~Didier.Dubois/Papers1208/possibility-EUSFLAT-Mag.pdf>
- Duhamel P, Vetterli M. Fast Fourier transforms: a tutorial review and a state of the art. Signal Process. 1990;19(4):259-99.

## BIBLIOGRAPHIE

- Dupin C. Présentation Architecte système CDV. 2009.
- Elsaadawi AM, Kalas AE, Fawzi M. Development of an expert system to fault diagnosis of three phase induction motor drive system. In IEEE; 2008 [cité 18 déc 2015]. p. 497-502. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4562346>
- European Aviation Safety Agency, European Union, European Environment Agency. European aviation environmental: report 2016. [Internet]. Luxembourg: Publications Office; 2016. Disponible sur: <http://bookshop.europa.eu/uri?target=EUB:NOTICE:TO0115323:EN:HTML>
- Farag A, Mohamed RM. Regression Using Support Vector Machines: Basic Foundations. 2004.
- Farahani FV, Zarandi MF, Ahmadi A. Fuzzy rule based expert system for diagnosis of lung cancer. In: Fuzzy Information Processing Society (NAFIPS) held jointly with 2015 5th World Conference on Soft Computing (WConSC), 2015 Annual Conference of the North American. IEEE; 2015. p. 1-6.
- Ferri E, Kandel A, Langholz G. Fuzzy Negation. In: Zadeh LA, Kacprzyk J, éditeurs. Computing with Words in Information/Intelligent Systems 1: Foundations [Internet]. Heidelberg: Physica-Verlag HD; 1999. p. 297-325. Disponible sur: [https://doi.org/10.1007/978-3-7908-1873-4\\_13](https://doi.org/10.1007/978-3-7908-1873-4_13)
- Feyel P. Controllers optimization with metaheuristics – Application to the ligne of sight stabilization problem. [Internet] [Theses]. Supélec; 2015. Disponible sur: <https://tel.archives-ouvertes.fr/tel-01349315>
- Feyel P, Duc G, Sandou G. LuGre friction model identification and compensator tuning using a Differential Evolution algorithm. In IEEE; 2013 [cité 16 déc 2015]. p. 85-91. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6601446>
- Flamand L, Sainsot P, Lubrecht T. Fatigue des surfaces. Tech Ing Surf [Internet]. 2013;base documentaire : TIB463DUO.(ref. article : bm5055). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/mecanique-th7/surfaces-42463210/fatigue-des-surfaces-bm5055/>
- Fornaciari M, Prati A, Cucchiara R. A fast and effective ellipse detector for embedded vision applications. Pattern Recognit. 2014;47(11):3693-708.
- Fournié R, Coelho R. Diélectriques Bases théoriques. Tech Ing Matér Isolants En Électrotechnique [Internet]. 1986;base documentaire : TIB255DUO.(ref. article : d2300). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/energies-th4/materiaux-isolants-en-electrotechnique-42255210/dielectriques-d2300/>
- Fürnkranz J, Gamberger D, Lavrač N. Foundations of rule learning. Berlin: Springer; 2012. (Cognitive technologies).
- Fu T. A review on time series data mining. Eng Appl Artif Intell. févr 2011;24(1):164-81.
- Gajjar S, Kulahci M, Palazoglu A. Real-time fault detection and diagnosis using sparse principal component analysis. J Process Control. 2017;-.
- Gelle G, Colas M, Serviere C. Blind source separation : a tool for rotating machine monitoring by vibration analysis ? J Sound Vib. 2001;248(5):865-85.

## BIBLIOGRAPHIE

- Geman S, Bienenstock E, Doursat R. Neural Networks and the Bias/Variance Dilemma. *Neural Comput.* janv 1992;4(1):1-58.
- GIFAS. Aéronautique, Espace et Environnement [Internet]. Membres de la Commission R&D, de la Commission Environnement et Développement Durable, de la Commission Espace du GIFAS et du Comité de pilotage du CORAC; 2011. Disponible sur: [https://www.gifas.asso.fr/fichiersPDF/Publications/Publications/BROCHURE\\_ENVIRONNEMENT\\_FR.pdf](https://www.gifas.asso.fr/fichiersPDF/Publications/Publications/BROCHURE_ENVIRONNEMENT_FR.pdf)
- Goebel K, Daigle M, Saxena A, Sankararaman S, Roychoudhury I, Celaya J. *Prognostics: The Science of Making Predictions*. Wrocław: Amazon Fulfillment; 2017.
- Gonzalez-Tablas EC, Lopez FJA, Lopez EM, Olazabal AJ. Linear electromechanical actuator and anti-jamming device [Internet]. 2015. Disponible sur: <https://www.google.com/patents/US20150204427>
- Gouriveau R, Medjaher K, Ramasso E, Zerhouni N. PHM – Prognostics and health management De la surveillance au pronostic de défaillances de systèmes complexes. *Tech Ing Fonct Strat Maint* [Internet]. 2013;base documentaire : TIB137DUO.(ref. article : mt9570). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/genie-industriel-th6/fonction-strategique-de-la-maintenance-42137210/phm-prognostics-and-health-management-mt9570/>
- Gouriveau R, Zerhouni N. Connexionist-systems-based long term prediction approaches for prognostics. *IEEE Trans Reliab.* 2012;61(4):909-20.
- Gupta MM, Qi J. Theory of T-norms and fuzzy inference methods. *Fuzzy Sets Syst.* 1991;40(3):431-50.
- Haje Obeid N. Contribution to stator fault detection of permanent magnet actuators : Application to the detection of intermittent inter-turn fault and health monitoring [Internet] [Theses]. Université de Lorraine; 2016. Disponible sur: <https://tel.archives-ouvertes.fr/tel-01530619>
- Hansen RJ, Hall DL, Kurtz SK. A new approach to the challenge of machinery prognostics. In: *ASME 1994 International Gas Turbine and Aeroengine Congress and Exposition*. American Society of Mechanical Engineers; 1994. p. V005T15A001-V005T15A001.
- He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016. p. 770-8.
- Helton JC, Davis FJ. Latin hypercube sampling and the propagation of uncertainty in analyses of complex systems. *Reliab Eng Syst Saf.* juill 2003;81(1):23-69.
- Hinton GE, Osindero S, Teh Y-W. A fast learning algorithm for deep belief nets. *Neural Comput.* 2006;18(7):1527-54.
- Hofmann T, Schölkopf B, Smola AJ. Kernel methods in machine learning. *Ann Stat.* 2008;1171-220.
- Hoyland T, Spafford C, Medland A. *MRO Big Data - A lion or a lamb ?* Olivier Wyman - Aviation, Aerospace and Defense; 2016.
- Hüllermeier E. Fuzzy methods in machine learning and data mining: Status and prospects. *Fuzzy Sets Syst.* 2005;156(3):387-406.

## BIBLIOGRAPHIE

- Hyvarinen A. Fast and robust fixed-point algorithms for independent component analysis. *IEEE Trans Neural Netw.* 1999;10(3):626-34.
- Hyvärinen A, Oja E. Independent component analysis: algorithms and applications. *Neural Netw.* 2000;13(4):411-30.
- Imam AM, Habetler TG, Harley RG, Divan DM. Condition Monitoring of Electrolytic Capacitor in Power Electronic Circuits using Adaptive Filter Modeling. In: 2005 IEEE 36th Power Electronics Specialists Conference. 2005. p. 601-7.
- Iman RL. Latin Hypercube Sampling. In: Melnick EL, Everitt BS, éditeurs. *Encyclopedia of Quantitative Risk Analysis and Assessment* [Internet]. Chichester, UK: John Wiley & Sons, Ltd; 2008a [cité 2 oct 2017]. Disponible sur: <http://doi.wiley.com/10.1002/9780470061596.risk0299>
- Iman RL. Latin hypercube sampling. *Wiley Online Library*; 2008b.
- Inman DJ, Farrar CR, Lopes V, Steffen V, éditeurs. *Damage prognosis for aerospace, civil and mechanical systems*. Chichester, England ; Hoboken, NJ: Wiley; 2005.
- Ismail M, Balaban E, Spangenberg H. Fault detection and classification for flight control electromechanical actuators. In *Big Sky*, MT, USA; 2016.
- ISO. ISO 13381-1:2004 : Surveillance et diagnostic des machines -- Pronostic -- Partie 1: Lignes directrices générales. 2004.
- ISO. ISO 13374-4:2015 : Condition monitoring and diagnostics of machine systems -- Data processing, communication and presentation -- Part 4: Presentation. 2015.
- Izadian A, Khayyer P. Application of Kalman filters in model-based fault diagnosis of a DC-DC boost converter. In *IEEE*; 2010 [cité 15 déc 2015]. p. 369-72. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5674998>
- Jain AK, Mao J, Mohiuddin KM. Artificial neural networks: A tutorial. *Computer*. 1996;29(3):31-44.
- Jammu N, Kankar P. A review on prognosis of rolling element bearings. *Int J Eng Sci Technol.* 2011;3(10):7497-503.
- Javed K. A robust & reliable Data-driven prognostics approach based on extreme learning machine and fuzzy clustering. *Université de Franche-Comté*; 2014.
- Johnson T. Electric Green Taxiing System (EGTS) for Aircraft [Internet]. *IEEE The Transportation Electrification eNewsletter*. 2014. Disponible sur: <http://tec.ieee.org/newsletter/march-april-2014/electric-green-taxiing-system-egts-for-aircraft>
- Jouin M. Contribution to prognostics of fuel cells of PEMFC type - approach based on particle filtering. [Internet] [Theses]. *Université Bourgogne Franche-Comté*; 2015. Disponible sur: <https://hal.archives-ouvertes.fr/tel-01264824>
- Junsheng C, Dejie Y, Yu Y. A fault diagnosis approach for roller bearings based on EMD method and AR model. *Mech Syst Signal Process.* 2006;20(2):350-62.
- Karam W. Générateurs de forces statiques et dynamiques à haute puissance en technologie électromécanique [Internet]. *Université de Toulouse*; 2007. Disponible sur:

## BIBLIOGRAPHIE

<http://www.theses.fr/2007ISAT0035/document>

- Kaufman L, Rousseeuw, P. Clustering by means of Medoids. In: Statistical Data Analysis Based on the L1 Norm and Related Methods. Yadolah Dodge; 1987. (Statistics for Industry and Technology).
- Khelif R, Malinowski S, Chebel-Morello B, Zerhouni N. RUL prediction based on a new similarity-instance based approach. In: 2014 IEEE 23rd International Symposium on Industrial Electronics (ISIE). 2014. p. 2463-8.
- Kotsiantis S. Supervised Machine Learning: A Review of Classification Techniques. Informatica. 2007;31:249-68.
- Kruse R, Nauck D, Borgelt C. Data mining with fuzzy methods: status and perspectives. In 1999.
- Kruth TR. Interior-Point Algorithms for Quadratic Programming. Technical University of Denmark, DTU, DK-2800 Kgs. Lyngby, Denmark; 2008.
- Kudo M, Sklansky J. Comparison of algorithms that select features for pattern classifiers. Pattern Recognit. 2000;33(1):25-41.
- Kulkarni CS, Biswas G, Koutsoukos X. A prognosis case study for electrolytic capacitor degradation in DC-DC converters. In 2009.
- Kulkarni CS, Celaya JR, Goebel K, Biswas G. Physics Based Electrolytic Capacitor Degradation Models for Prognostic Studies under Thermal Overstress. In 2012.
- Kumar M, Husian M, Upreti N, Gupta D. Genetic algorithm: Review and application. 2010;
- Kumar S, Torres M, Chan Y, Pecht M. A hybrid prognostics methodology for electronic products. In: Neural Networks, 2008 IJCNN 2008 (IEEE World Congress on Computational Intelligence) IEEE International Joint Conference on. IEEE; 2008. p. 3479-85.
- Kuremoto T, Kimura S, Kobayashi K, Obayashi M. Time series forecasting using a deep belief network with restricted Boltzmann machines. Neurocomputing. août 2014;137:47-56.
- Lamoureux B. Development of an Integrated Approach for PHM - Prognostics and Health Management : Application to a Turbofan Fuel System [Internet]. ENSAM; 2014. Disponible sur: <http://www.theses.fr/2014ENAM0018/document>
- Langlois O, Foch E, Roboam X, Piquet H. De l'avion plus électrique à l'avion tout électrique: état de l'art et prospective sur les réseaux de bord. J3eA. 2005;4(HORS SÉRIE 1):001.
- Larsen J, Goutte C. On optimal data split for generalization estimation and model selection. In: Neural Networks for Signal Processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop (Cat No98TH8468). 1999. p. 225-34.
- Leboeuf N. Contribution à l'étude des machines synchrones à aimants permanents en présence de défauts inter-spires : modélisation, détection de défauts inter-spires [Internet]. Université de Lorraine; 2012. Disponible sur: <http://www.theses.fr/2012LORR0364/document>
- Leboeuf N, Boileau T, Nahid-Mobarakeh B, Clerc G, Meibody-Tabar F. Real-Time Detection of Interturn Faults in PM Drives Using Back-EMF Estimation and Residual Analysis. IEEE Trans

## BIBLIOGRAPHIE

- Ind Appl. nov 2011;47(6):2402-12.
- Leboeuf N, Boileau T, Nahid-Mobarakeh B, Meibody-Tabar F. Fault Detection in a Current Controlled PM Drive Using Back-EMF Estimation and Residual Analysis. In: 2010 IEEE Industry Applications Society Annual Meeting. 2010. p. 1-6.
- Lebold M, Reichard K, Hejda P, Bezdicak J. A framework for next generation machinery monitoring and diagnostics. In Citeseer; 2002.
- Lebold M, Thurston M. Open standards for condition-based maintenance and prognostics systems. In Gatlinburg, USA; 2001.
- Lee J-M, Qin SJ, Lee I-B. Fault detection and diagnosis based on modified independent component analysis. *AIChE J.* 2006;52(10):3501-14.
- Lee J, Qiu H, Yu G, Lin J, Rexnord Technical Services. Bearing Data Set [Internet]. IMS, University of Cincinnati, NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA; 2007. Disponible sur: <https://ti.arc.nasa.gov/tech/dash/pcoe/prognostic-data-repository/>
- Lei Y, Lin J, He Z, Zuo MJ. A review on empirical mode decomposition in fault diagnosis of rotating machinery. *Mech Syst Signal Process.* 2013;35(1):108-26.
- Lemor PC. The roller screw, an efficient and reliable mechanical component of electro-mechanical actuators. In IEEE; 1996 [cité 26 févr 2015]. p. 215-20. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=552873>
- Le QV. A Tutorial on Deep Learning Part 1: Nonlinear Classifiers and The Backpropagation Algorithm. 2015;
- Liao TW. Clustering of time series data—a survey. *Pattern Recognit.* 2005;38(11):1857-74.
- Li CJ, Lee H. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. *Mech Syst Signal Process.* 2005;19(4):836-46.
- Li Li, Liangsheng Qu. Machine diagnosis with independent component analysis and envelope analysis. In IEEE; 2002 [cité 27 sept 2017]. p. 1360-4. Disponible sur: <http://ieeexplore.ieee.org/document/1189377/>
- Lippmann R. An introduction to computing with neural nets. *IEEE Assp Mag.* 1987;4(2):4-22.
- Liu W, Schaeffer E, Averty D, Loron L. A new Approach for Form Wound Machine Goundwall Insulation Diagnosis by Means of High Frequency Model Parameter Monitoring. In IEEE; 2007a [cité 23 févr 2015]. p. 1270-5. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4374781>
- Liu W, Schaeffer E, Loron L, Chanemouga P. High Frequency Modelling of Stator Windings Dedicated to Machine Insulation Diagnosis by Parametric Identification. In IEEE; 2007b [cité 23 févr 2015]. p. 480-5. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4393141>
- Liu Z, Hu K. A Model-Based Diagnosis System for Traction Power Supply System. *IEEE Trans Ind*

## BIBLIOGRAPHIE

- Inform. 2017;PP(99):1-1.
- López M, Valero S, Rodriguez A, Veiras I, Senabre C. New online load forecasting system for the Spanish Transport System Operator. *Electr Power Syst Res.* 2018;154(Supplement C):401-12.
- Loukil R. Air France KLM anticipe les pannes de ses avions A380 au big data. [En ligne] [Internet]. *Usine Digitale.* 30 nov 2015; Disponible sur: <http://www.usine-digitale.fr/article/air-france-klm-anticipe-les-pannes-de-ses-avions-a380-au-big-data.N365483>
- MacQueen J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics* [Internet]. Berkeley, Calif.: University of California Press; 1967. p. 281-97. Disponible sur: <http://projecteuclid.org/euclid.bsm/1200512992>
- Maggiore P, Dalla Vedova MD, Pace L, Desando A. Definition of parametric methods for fault analysis applied to an electromechanical servomechanism affected by multiple failures. In 2014.
- Manders E, Mosterman P, Biswas G, Barford L. *TRANSCEND: A System for Robust Monitoring and Diagnosis of Complex Engineering Systems.* 1999;
- Mangili F. *Development of advanced computational methods for Prognostics and Health Management in energy components and systems.* Politecnico di Milano; 2013.
- Mansouri B, Piaton J, Guyamier A. The backlash gap size estimation for electromechanical actuator in an operational behavior. In 2016.
- Maré J-C. *Aerospace actuators 2: signal-by-wire and power-by-wire.* Hoboken, NJ: ISTE Ltd/John Wiley and Sons Inc; 2017.
- Maussion P, Picot A, Chabert M, Malec D. Lifespan and aging modeling methods for insulation systems in electrical machines: A survey. In: *2015 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD).* 2015. p. 279-88.
- Méchin B. Introduction aux méthodes de maintenance. *Tech Ing Fonct Strat Maint* [Internet]. 2005;base documentaire: TIB137DUO.(ref. article: mt9280). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/genie-industriel-th6/fonction-strategique-de-la-maintenance-42137210/introduction-aux-methodes-de-maintenance-mt9280/>
- Medjaher K, Tobon-Mejia DA, Zerhouni N. Remaining Useful Life Estimation of Critical Components With Application to Bearings. *IEEE Trans Reliab.* juin 2012;61(2):292-302.
- Michaud R. Contribution à l'étude de la séparation aveugle de sources pour le diagnostic d'un actionneur électromécanique. *Laboratoire Ampère;* 2016.
- Mihaila V. Nouvelle Conception des bobinages statoriques des machines à courant alternatif pour réduire les effets négatifs des  $dV/dt$ . Artois; 2011.
- Mihaila V, Nguyen MQ, Duchesne S, VELU G, Roger D, Malec D, et al. Solutions d'isolation électrique pour les machines fonctionnant à Hautes Températures. In: *Symposium de Génie Électrique 2014* [Internet]. Cachan, France; 2014. Disponible sur: <https://hal.archives-ouvertes.fr/hal-01065229>

## BIBLIOGRAPHIE

- Mijovic B, Vos MD, Gligorijevic I, Taelman J, Huffel SV. Source Separation From Single-Channel Recordings by Combining Empirical-Mode Decomposition and Independent Component Analysis. *IEEE Trans Biomed Eng.* sept 2010;57(9):2188-96.
- Mirza M. Economic Impact of Airplane turntimes. 2008;
- Moeneclaey J. Méthode de conception des bobinages des actionneurs électriques adaptés aux nouvelles contraintes de l'avionique. Artois; 2015.
- Mosallam A, Medjaher K, Zerhouni N. Bayesian approach for remaining useful life prediction. *Chem Eng Trans.* juill 2013;139-44.
- Moseler O, Juricic D, Rakar A, Muller N. Model-based fault diagnosis of an actuator system driven by the brushless DC motor. In: *Proceedings of the 1999 American Control Conference (Cat No 99CH36251)*. 1999. p. 3779-83 vol.6.
- Muller KR, Mika S, Ratsch G, Tsuda K, Scholkopf B. An introduction to kernel-based learning algorithms. *IEEE Trans Neural Netw.* mars 2001;12(2):181-201.
- Naik GR, Selvan SE, Nguyen HT. Single-Channel EMG Classification With Ensemble-Empirical-Mode-Decomposition-Based ICA for Diagnosing Neuromuscular Disorders. *IEEE Trans Neural Syst Rehabil Eng.* juill 2016;24(7):734-43.
- Narasimhan S, Roychoudhury I, Balaban E, Saxena A. Combining Model-Based and Feature-Driven Diagnosis Approaches – A Case Study on Electromechanical Actuators. In 2010.
- Nectoux P, Gouriveau R, Medjaher K, Ramasso E, Chebel-Morello B, Zerhouni N, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests. In: *IEEE International Conference on Prognostics and Health Management, PHM'12*. IEEE Catalog Number: CPF12PHM-CDR; 2012. p. 1-8.
- Nguyen D-K. IDENTIFICATION ET CARACTERISATION DE DEFAUTS D'UN ACTIONNEUR ELECTROMECHANIQUE DE COMMANDE DE VOL. Safran Electronics & Defense - ENSEM; 2017.
- Nikolaidis E, Mourelatos ZP, Pandey V. Design decisions under uncertainty with limited information [Internet]. Boca Raton: CRC Press; 2010. (Structures and infrastructures series). Disponible sur:  
<https://books.google.fr/books?hl=fr&lr=&id=Xk3LBQAAQBAJ&oi=fnd&pg=PP1&dq=Design+Decisions+under+Uncertainty+with+Limited+Information:+Structures+and+Infrastructures&ots=hnN6xldGFT&sig=MN49dG46VdisG5TML3K0zOPqDsQ#v=onepage&q=Design%20Decisions%20under%20Uncertainty%20with%20Limited%20Information%3A%20Structures%20and%20Infrastructures&f=false>
- Nocedal J, Wright SJ. Numerical optimization. New York: Springer; 1999. (Springer series in operations research).
- Ondel O. Diagnostic par reconnaissance des formes : Application à un ensemble convertisseur-machine asynchrone [Internet]. Thèse de L'Ecole Centrale de Lyon; 2006. Disponible sur: <http://www.theses.fr/2006ECDL0029/document>
- Pal NR, Pal K, Keller JM, Bezdek JC. A possibilistic fuzzy c-means clustering algorithm. *IEEE Trans Fuzzy Syst.* 2005;13(4):517-30.

## BIBLIOGRAPHIE

- Patro S, Sahu KK. Normalization: A preprocessing stage. ArXiv Prepr ArXiv150306462. 2015;
- Pele K. Validation d'indicateurs de défauts en phase amont de développement. Safran Electronics & Defense - UPMC; 2017.
- Peng Z, Chu F. Application of the wavelet transform in machine condition monitoring and fault diagnostics: a review with bibliography. Mech Syst Signal Process. 2004;18(2):199-221.
- Peter WT, Yang W, Tam H. Machine fault diagnosis through an effective exact wavelet analysis. J Sound Vib. 2004;277(4):1005-24.
- Piaton J. Electric motor for roto-linear actuator [Internet]. 2010. Disponible sur: <http://www.google.com.na/patents/WO2010072932A2?cl=en>
- Pinel B, Duchateau F. Fonction isolation dans les matériels électriques. Tech Ing Matér Isolants En Électrotechnique [Internet]. 1999;base documentaire : TIB255DUO.(ref. article : d2302). Disponible sur: <http://www.techniques-ingenieur.fr/base-documentaire/energies-th4/materiaux-isolants-en-electrotechnique-42255210/fonction-isolation-dans-les-materiels-electriques-d2302/>
- PIPAME. Maintenance et réparation aéronautique : base de connaissances et évolutions. Pôle Interministériel de Prospective et d'Anticipation des mutations Economiques; 2010.
- Plutowski ME. Survey : Cross-validation in theory and practise. David Sarnoff Research Center - Princeton; 1996.
- Pomorski D, Perche P-B. Inductive learning of decision trees: application to fault isolation of an induction motor. Eng Appl Artif Intell. 2001;14(2):155-66.
- Puigt M. A Very Short Introduction to Blind Source Separation. 2011.
- Qin Y, Qin S, Mao Y. Research on iterated Hilbert transform and its application in mechanical fault diagnosis. Mech Syst Signal Process. 2008;22(8):1967-80.
- Qiu H, Lee J, Lin J, Yu G. Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics. J Sound Vib. févr 2006;289(4-5):1066-90.
- Quévrin G, Raynal J. Aéronautique : les volumes de données s'envolent. [En ligne] [Internet]. Industrie & Technologies. 11 juin 2015; Disponible sur: <http://www.industrie-techno.com/aeronautique-les-volumes-de-donnees-s-envolent.38548>
- Rahman MM, Uddin MN. Online unbalanced rotor fault detection of an IM drive based on both time and frequency domain analyses. In IEEE; 2015 [cité 22 févr 2016]. p. 1-8. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7356825>
- Raju GG. Dielectrics in electric fields. Second edition. Boca Raton: CRC Press, Taylor & Francis Group; 2016.
- Rakotomalala R. Arbres de décision. Rev Modul. 2005;33:163-87.
- Renaud D. Maintenance prédictive : Magique la Data Science ? [En ligne] [Internet]. Le journal de l'aviation. 4 juin 2017; Disponible sur: <http://www.journal-aviation.com/actualites/36274->

## BIBLIOGRAPHIE

maintenance-predictive-magique-la-data-science

- Rilling G, Flandrin P, Goncalves P, others. On empirical mode decomposition and its algorithms. In: IEEE-EURASIP workshop on nonlinear signal and image processing. IEEE; 2003. p. 8-11.
- Roboam X, Sareni B, Andrade A. More Electricity in the Air: Toward Optimized Electrical Networks Embedded in More-Electrical Aircraft. IEEE Ind Electron Mag. déc 2012;6(4):6-17.
- Rome Laboratory, Reliability Analysis Center. Reliability toolkit : commercial practices edition. Griffiss AFB, N.Y.; [Rome, N.Y.]: [Rome Laboratory] ; [Reliability Analysis Center]; 1994.
- Rosero J, Ortega J, Aldabas E, Romeral L. Moving towards a more electric aircraft. IEEE Aerosp Electron Syst Mag. 2007;22(3):3-9.
- Safizadeh M, Lakis A, Thomas M. Using short-time fourier transform in machinery diagnosis. 2005;
- Safran. Première mondiale : Sagem et Airbus testent en vol avec succès un actionneur électrique d'aile [Internet]. 2011. Disponible sur: [https://www.safran-group.com/fr/media/20110307\\_premiere-mondiale-sagem-et-airbus-testent-en-vol-avec-succes-un-actionneur-electrique-daileron](https://www.safran-group.com/fr/media/20110307_premiere-mondiale-sagem-et-airbus-testent-en-vol-avec-succes-un-actionneur-electrique-daileron)
- Sanchez F. Génération de modèles analytiques pour la conception préliminaire de systèmes multi-physiques : application à la thermique des actionneurs et des systèmes électriques embarqués. Université de Toulouse; 2017.
- Sankararaman S, Goebel K. Why is the Remaining Useful Life Prediction Uncertain? In New Orleans , USA; 2013a. p. 13.
- Sankararaman S, Goebel K. Why is the Remaining Useful Life Prediction Uncertain? In 2013b.
- Sankararaman S, Goebel K. Uncertainty in prognostics and systems health management. Int J Progn Health Manag. 2015;6(010).
- Saravanan N, Ramachandran K. Fault diagnosis of spur bevel gear box using discrete wavelet features and Decision Tree classification. Expert Syst Appl. 2009;36(5):9564-73.
- Satishkumar R, Sugumaran V. Estimation of remaining useful life of bearings based on support vector regression. Indian J Sci Technol. 2016;9(10).
- Saxena A, Celaya J, Balaban E, Goebel K, Saha B, Saha S, et al. Metrics for evaluating performance of prognostic techniques. In: 2008 International Conference on Prognostics and Health Management. 2008. p. 1-17.
- Saxena A, Celaya JR, Roychoudhury I, Saha S, Saha B, Goebel K. Designing data-driven battery prognostic approaches for variable loading profiles: Some lessons learned. In 2012.
- Saxena A, Celaya J, Saha B, Saha S, Goebel K. Evaluating algorithm performance metrics tailored for prognostics. In: Aerospace conference, 2009 IEEE. IEEE; 2009a. p. 1-13.
- Saxena A, Celaya J, Saha B, Saha S, Goebel K. On applying the prognostic performance metrics. In: Annual Conference of the Prognostics and Health Management Society. 2009b.
- Saxena A, Celaya J, Saha B, Saha S, Goebel K. Metrics for offline evaluation of prognostic

## BIBLIOGRAPHIE

- performance. *Int J Progn Health Manag.* 2010;01.
- Saxena A, Sankararaman S, Goebel K. Performance evaluation for fleet-based and unit-based prognostic methods. In 2014.
- Seabridge A, Moir I. Aircraft systems: mechanical, electrical and avionics subsystems integration [Internet]. Hoboken, N.J.: Wiley; 2013 [cité 11 avr 2017]. Disponible sur: <http://public.eblib.com/choice/publicfullrecord.aspx?p=4041347>
- Sebbane YB. Smart Autonomous Aircraft Flight Control and Planning for Uav. CRC Press; 2015.
- Seo SJ, Yeom WS, Jang SR, Hwang BM, Song CI, Min KH, et al. Failure modes effects test for flight control system. In: 29th Digital Avionics Systems Conference. 2010. p. 5.D.5-1 - 5.D.5-10.
- Setlak L. Overview of Aircraft Technology solutions compatible with the concept of MEA. *Czas Tech.* 2016;
- Shafer G. A mathematical theory of evidence. Princeton university press; 1976.
- Shao J. Linear model selection by cross-validation. *J Am Stat Assoc.* 1993;88(422):486-94.
- Shao Y, Nezu K. Prognosis of remaining bearing life using neural networks. *Proc Inst Mech Eng Part J Syst Control Eng.* mai 2000;214(3):217-30.
- SKF. Bearing failures and their causes. 1994. Report No.: 401.
- Smola AJ, Schölkopf B. A Tutorial on Support Vector Regression. *Stat Comput.* août 2004;14(3):199-222.
- Song G, Dai Q. A novel double deep ELMs ensemble system for time series forecasting. *Knowl-Based Syst.* 2017;134(Supplement C):31-49.
- Soualhi A. Du diagnostic au pronostic de pannes des entraînements électriques [Internet]. 2013. Disponible sur: <http://www.theses.fr/2013LYO10146>
- Soualhi A, Makdessi M, German R, Rivas F, Razik H, Sari A, et al. Health Monitoring of Capacitors and Supercapacitors Using Neo Fuzzy Neural Approach. *IEEE Trans Ind Inform.* 2017;1-1.
- Soualhi A, Medjaher K, Zerhouni N. Bearing Health Monitoring Based on Hilbert-Huang Transform, Support Vector Machine, and Regression. *IEEE Trans Instrum Meas.* janv 2015;64(1):52-62.
- Spitzer CR, Ferrell U, Ferrell T, éditeurs. Digital avionics handbook. 3. édition. Bosa Roca: CRC, Taylor & Francis Group; 2015.
- Stone JV. Independent component analysis: an introduction. *Trends Cogn Sci.* 2002;6(2):59-64.
- Storn R, Price K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. *J Glob Optim.* 1997;11(4):341-59.
- Taieb SB, Bontempi G, Atiya AF, Sorjamaa A. A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Syst Appl.* 2012;39(8):7067-83.

## BIBLIOGRAPHIE

- Tao T, Zhao W. A support vector regression-based prognostic method for li-ion batteries working in variable operating states. In: 2016 Prognostics and System Health Management Conference (PHM-Chengdu). 2016. p. 1-5.
- Thorsen OV, Dalva M. A survey of faults on induction motors in offshore oil industry, petrochemical industry, gas terminals, and oil refineries. *IEEE Trans Ind Appl.* 1995;31(5):1186-96.
- Tobon-Mejia DA, Medjaher K, Zerhouni N, Tripot G. Hidden Markov Models for failure diagnostic and prognostic. In *IEEE; 2011* [cité 12 mai 2015]. p. 1-8. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5939488>
- Todeschi M, Baxerres L. Health Monitoring for the Flight Control EMAs. *IFAC-Pap.* 2015;48(21):186-93.
- Torres ME, Colominas MA, Schlotthauer G, Flandrin P. A complete ensemble empirical mode decomposition with adaptive noise. In: 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). *IEEE; 2011.* p. 4144-7.
- Tran IT. Vérification de la validité du concept de surface somme par une approche statistique du contact élastique entre deux surfaces rugueuses [Internet]. 2015. Disponible sur: <http://www.theses.fr/2015ECAP0010/document>
- Valentini G, Dietterich TG, Cristianini N. Bias-variance analysis of support vector machines for the development of svm-based ensemble methods. *J Mach Learn Res.* 2004;5:725-75.
- Vandawaker RM, Jacques DR, Freels JK. Impact of prognostic uncertainty in system health monitoring. *Int J Progn Health Manag.* 2015;
- Van der Linden ...Franciscus L. J., Dreyer N, Dorkel A. EMA Health Monitoring: An overview. In 2016.
- Vapnik VN. *The Nature of Statistical Learning Theory.* New York, NY, USA: Springer-Verlag New York, Inc.; 1995.
- Vapnik VN. An overview of statistical learning theory. *IEEE Trans Neural Netw.* sept 1999;10(5):988-99.
- Venet P, Lahyani A, Grellet G, Ah-Jaco A. Influence of aging on electrolytic capacitors function in static converters: Fault prediction method. *Eur Phys J Appl Phys.* 1999;5(1):71-83.
- Vijayakumar S, D'Souza A, Schaal S. Incremental Online Learning in High Dimensions. *Neural Comput.* 2005;17:2602-34.
- Vinson G, Combacau M, Prado T, Ribot P. Permanent magnets synchronous machines faults detection and identification. In *IEEE; 2012* [cité 30 mars 2015]. p. 3925-30. Disponible sur: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6389265>
- Wang Z, Chen J, Dong G, Zhou Y. Constrained independent component analysis and its application to machine fault diagnosis. *Mech Syst Signal Process.* 2011;25(7):2501-12.
- Wheeler KR, Kurtoglu T, Poll SD. A survey of health management user objectives related to diagnostic and prognostic metrics. In: *ASME 2009 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference.* American Society of

## BIBLIOGRAPHIE

- Mechanical Engineers; 2009. p. 1287-98.
- Wheeler P. The More Electric Aircraft : Why Aerospace Needs Power Electronics. 2014.
- Wu J-D, Huang C-W, Huang R. An application of a recursive Kalman filtering algorithm in rotating machinery fault diagnosis. *NDT E Int.* 2004;37(5):411-9.
- Wu Z, Huang NE. Ensemble empirical mode decomposition: a noise-assisted data analysis method. *Adv Adapt Data Anal.* 2009;1(01):1-41.
- Yang S, Xiang D, Bryant A, Mawby P, Ran L, Tavner P. Condition Monitoring for Device Reliability in Power Electronic Converters: A Review. *IEEE Trans Power Electron.* nov 2010;25(11):2734-52.
- Yan R, Gao RX, Chen X. Wavelets for fault diagnosis of rotary machines: A review with applications. *Signal Process.* 2014;96:1-15.
- Yu Y, Junsheng C, others. A roller bearing fault diagnosis method based on EMD energy entropy and ANN. *J Sound Vib.* 2006;294(1):269-77.
- Zadeh L. Fuzzy sets as a basis for a theory of possibility. *Fuzzy Sets Syst.* 1978;1(1):3-28.
- Zadeh LA. Fuzzy sets. *Inf Control.* 1965;8(3):338-53.
- Zalila Z. Contribution à une théorie des relations floues d'ordre N [Internet]. [Compiègne]: Université de Technologie de Compiègne; 1993. Disponible sur: [http://bibliotheque.utc.fr/EXPLOITATION/doc/IFD/IFD\\_REFDOC\\_0004897](http://bibliotheque.utc.fr/EXPLOITATION/doc/IFD/IFD_REFDOC_0004897)
- Zanardelli WG, Strangas EG, Khalil HK, Miller JM. Comparison of wavelet-based methods for the prognosis of failures in electric motors. In: *Power Electronics in Transportation, 2002.* IEEE; 2002. p. 61-7.
- Zaporozhets O, Tokarev V, Attenborough K. *Aircraft Noise: Assessment, Prediction and Control.* CRC Press; 2011.
- Zhou Z-J, Hu C-H, Han X-X, He H-F, Ling X-D, Zhang B-C. A model for online failure prognosis subject to two failure modes based on belief rule base and semi-quantitative information. *Knowl-Based Syst.* 2014;70:221-30.
- Zidani F, Benbouzid MEH, Diallo D, Naït-Saïd MS. Induction motor stator faults diagnosis by a current Concordia pattern-based fuzzy decision system. *Energy Convers IEEE Trans On.* 2003;18(4):469-75.
- Zotos PA. Motor failures due to steep fronted switching surges-the need for surge protection-users experience. In: *Industry Applications Society 40th Annual Petroleum and Chemical Industry Conference.* 1993. p. 279-91.
- Zurita D, Carino JA, Delgado M, Ortega JA. Distributed neuro-fuzzy feature forecasting approach for condition monitoring. In: *Proceedings of the 2014 IEEE Emerging Technology and Factory Automation (ETFA).* 2014. p. 1-8.

## BIBLIOGRAPHIE

# VIII

## ANNEXES

<b>VIII</b>	<b>ANNEXES</b>	<b>211</b>
1	ALGORITHMES EMD	213
1.1	EEMD	213
1.2	CEEMD	214
2	CRITERE D'INDEPENDANCE STATISTIQUE	215
3	ÉCHANTILLONNAGE PAR HYPERCUBE LATIN	215
4	NKPI	216
4.1	Courbe ROC	216
4.2	NKPI Déteçtabilité	217
4.3	NKPI Identification	217
4.4	NKPI de localisation et de pronostic	218
5	DETAIL DES NKPI POUR LES SIGNATURES PROPOSEES	218
5.1	Déteçtabilité	218
6	CALCUL DES PARAMETRES DES FA	219
6.1	FA trapézoïdale	219
6.2	FA Sigmoidale	221
6.3	FA Polynomiale	222
7	EXEMPLES DE TNORMES	225
7.1	Min/Max	225
7.2	Normes probabilistes	226
7.3	Normes de Lukasiewicz	227
8	BANC MACHINE ASYNCHRONE	229
8.1	Caractéristiques du moteur asynchrone	229
8.2	Signatures liées à la base	229
9	BANC MACHINE SYNCHRONE A AIMANTS	230
9.1	Caractéristiques de la MSAP	230
9.2	Signatures liées à la base	230
9.2.a	Harmoniques deux	230
9.2.b	Paramètres estimés par Filtre de Kalman étendu	230
9.2.c	Résidus issus d'un modèle de machine sain	231
9.2.d	Résidus issus d'un modèle saturé au premier harmonique	231
9.2.e	Résidus issus d'un modèle incluant certains harmoniques d'espaces	231
10	SELECTION DE PARAMETRES	232
11	METRIQUES D'ÉVALUATION	233
11.1	Catégories de métriques	233
11.2	Autres métriques de performances	234
12	ALGORITHME DES C – MOYENNES	235
13	RESULTATS DE PARTITIONNEMENTS	237
14	COMPARAISONS DES TEMPS DE FIN DE VIE	239
15	NORMALISATION PAR SIGMOÏDE	239
16	PREDICTION DE SIGNATURES	240
16.1	Test sur l'unité 2	240
16.2	Test sur unité 3	241
16.3	Test sur unité 4	242
17	ESTIMATION DE LA RUL	244

# 1 - Algorithmes EMD

Les notations suivantes sont rappelées :

- ⇒  $y_s$  : signal échantillonné à l'étude
- ⇒  $N$  : nombre de points (échantillons) du signal

Les notations suivantes sont définies :

- ⇒  $res$  : résidus du signal
- ⇒  $IMF_{j,i}$  :  $i^{\text{ème}}$  IMF obtenu pour l'itération  $j$

## 1.1 - EEMD

Le principe de la méthode EEMD est d'ajouter du bruit blanc au signal étudié et de réaliser une EMD sur le signal obtenu. L'EMD est effectuée pour plusieurs réalisations de bruit blanc. Les IMF finaux sont obtenus en moyennant les IMF obtenus à chaque réalisation. L'algorithme est le suivant :

### Algorithme 11 : "Ensemblist Empirical Mode Decomposition" (EEMD)

**(1) Initialisation**

Poser  $res_0 = y_s$  et fixer le nombre d'itérations  $N_{iter}$  (choix utilisateur)

**(2) Insertion du bruit blanc**

Poser  $res_{1;w_0} = res_0 + w_0(\theta)$  où  $w_0(\theta)$  : bruit blanc (aléatoire) de paramètres  $\theta$  connus

**(3) EMD**

Effectuer une EMD sur  $res_{j;w_{j-1}}$   
Enregistre-les IMF déterminées à cette itération :  $IMF_{j,i}$  avec  $i \in \{1, \dots, n_{IMF}\}$

**(4) Répétitions**

Incrémenter  $j$   
Répéter (2) et (3) jusqu'à  $j = N_{iter}$

**(5) Final : calcul des IMF**

Calculer les IMF du signal en moyennant les IMF pour chaque réalisation de bruits

$$IMF_i = \left(\frac{1}{N_{iter}}\right) \sum_{j=1}^{N_{iter}} IMF_{j,i}$$

## 1.2 - CEEMD

Dans l'EEMD chaque calcul d'IMF se fait indépendamment des autres. Cette version de l'algorithme propose de modifier cela pour parvenir à une meilleure séparation des modes pour des coûts de calculs réduits. Les éléments suivants sont définis :

- ⇒ Un opérateur  $\mathbf{E}_j$  qui pour un signal  $res_j$  renvoie le  $j^{ième}$  mode obtenu par EMD.
- ⇒ Les rapports signal sur bruits à chaque étape (« Signal to Noise Ratio : SNR ») :  $snr_i$ . En général un unique rapport est pris pour toutes les étapes (Torres et al. 2011).

### Algorithme 12 : "Complete Ensemblist Empirical Mode Decomposition" (CEEMD)

#### (1) Initialisation

Poser  $res_0 = y_s + snr_0 w(\theta)$  et fixer le nombre d'itérations  $N_{iter}$  (choix utilisateur)

#### (2) Obtention du premier mode et du premier résidu

Faire une EEMD sur  $res_0$   
Calculer le premier mode

$$IMF_1 = \left( \frac{1}{N_{iter}} \right) \sum_{i=1}^{N_{iter}} IMF_{1,i}$$

Calculer le premier résidu

$$res_1 = y_s - IMF_1$$

#### (3) Obtention du $j^{ième}$ mode et du $j^{ième}$ résidu

Faire une EEMD sur  $res_{j-1} + snr_{j-1} \mathbf{E}_j(w(\theta))$   
Calculer le  $j^{ième}$  mode

$$IMF_j = \left( \frac{1}{N_{iter}} \right) \sum_{i=1}^{N_{iter}} \mathbf{E}_1 \left( res_{j-1} + snr_{j-1} \mathbf{E}_j(w_i(\theta)) \right)$$

Calculer le  $j^{ième}$  résidu

$$res_j = res_{j-1} - IMF_j$$

#### (4) Répéter (3) jusqu'au critère d'arrêt

#### (5) Arrêt

$res_j$  monotone  $\Leftrightarrow e_{sup}$  et  $e_{inf}$  symétriques  $\Leftrightarrow moy(e_{sup}; e_{inf}) = 0$

## 2 - Critère d'indépendance statistique

Le critère présenté ici est celui de la minimisation de l'information mutuelle (**Comon 1994; Hyvärinen et Oja 2000**). L'information mutuelle d'un vecteur aléatoire  $Y_s = (y_{s1} \dots y_{sn_{SO}})$  est donnée par :

$$(VIII.1) \quad IM = \sum_{i=1}^{n_{SO}} \mathbb{H}(y_{si}) - \mathbb{H}(Y_s)$$

Où  $\mathbb{H}$  représente l'entropie différentielle définie par :

$$(VIII.2) \quad \mathbb{H}(Y_s) = - \int pdf(y_s) \log[pdf(y_s)] d(y_s)$$

Avec  $pdf$  : la fonction de densité de probabilité de  $Y_s$

Lorsque les variables aléatoires sont indépendantes, la condition suivante est vérifiée :

$$(VIII.3) \quad \sum_{i=1}^{n_{SO}} \mathbb{H}(y_{si}) = \mathbb{H}(Y_s)$$

Cela implique que l'information mutuelle est nulle.

Différentes méthodes pour calculer l'information mutuelle sont exposées dans (**Comon 1994; Hyvärinen 1999; Hyvärinen et Oja 2000**).

## 3 - Échantillonnage par Hypercube Latin

L'objectif de la méthode d'échantillonnage par latin hypercube est de fournir des points à partir d'une distribution multi – dimensionnelle de paramètres. La première étape est de découper l'espace des paramètres en sous – espaces disjoints (hypercubes). Les sous – espaces obtenus sont équiprobables et uniformes. La seconde étape consiste à échantillonner un point dans chacun des sous – espaces. Prenons l'exemple de deux paramètres  $p_1$  et  $p_2$  à valeurs dans  $[0,5]$ . La représentation du sous – échantillonnage par hyper cube latin peut se faire par la grille suivante :

$p_1 / p_2$	]0,1[	]1,2[	]2,3[	]3,4[	]4,5[
]0,1[	(0.2 ; 0.7)				
]1,2[				(1.2 ; 3.9)	
]2,3[		(2.5 ; 2.7)			
]3,4[					(3.6 ; 4.7)
]4,5[			(4.1 ; 2.3)		

Tableau VIII.1 : Exemple de grille obtenue par échantillonnage par Hyper cube Latin

## 4 - NKPI

Les notions ci – dessous, à l’exception de la ROC, sont issues de (Lamoureux 2014). Elles ont été reprises et détaillées dans (Pele 2017).

### 4.1 - Courbe ROC

Cette courbe de fonction d’efficacité du récepteur (*Receiver Operating Characteristic : ROC*), permet de lier les taux de détection de vrais positifs et ceux de faux positifs, permis par une signature. Le calcul de ces taux repose sur le tableau suivant :

	Système sain	Système en défaut
Signature normal	Vrais Négatifs (VN)	Faux négatifs (FN)
Signature anormale	Faux Positifs (FP)	Vrai Positifs (VP)

Tableau VIII.2 : Tableau de répartitions des points classifiés

Les cases du tableau sont déterminées, pour une signature donnée, en examinant les résultats d’un classifieur binaire n’utilisant que cette signature. Différents réglages sont évalués, ce qui donne plusieurs remplissages du tableau.

Le taux des vrais positifs se calcule alors par :

$$(VIII.4) \quad TVP = \frac{VP}{VP + FN}$$

Et celui de faux positifs par :

$$(VIII.5) \quad TFP = \frac{FP}{FP + VN}$$

Le tracé de l’une par rapport à l’autre de ces quantités, pour plusieurs échantillons, donne la courbe ROC. La surface sous la courbe (*Area Under Curve : AUC*) est un bon indicateur de la détectabilité permise par la signature. Plus l’AUC est proche de 1 plus la détectabilité sera bonne.

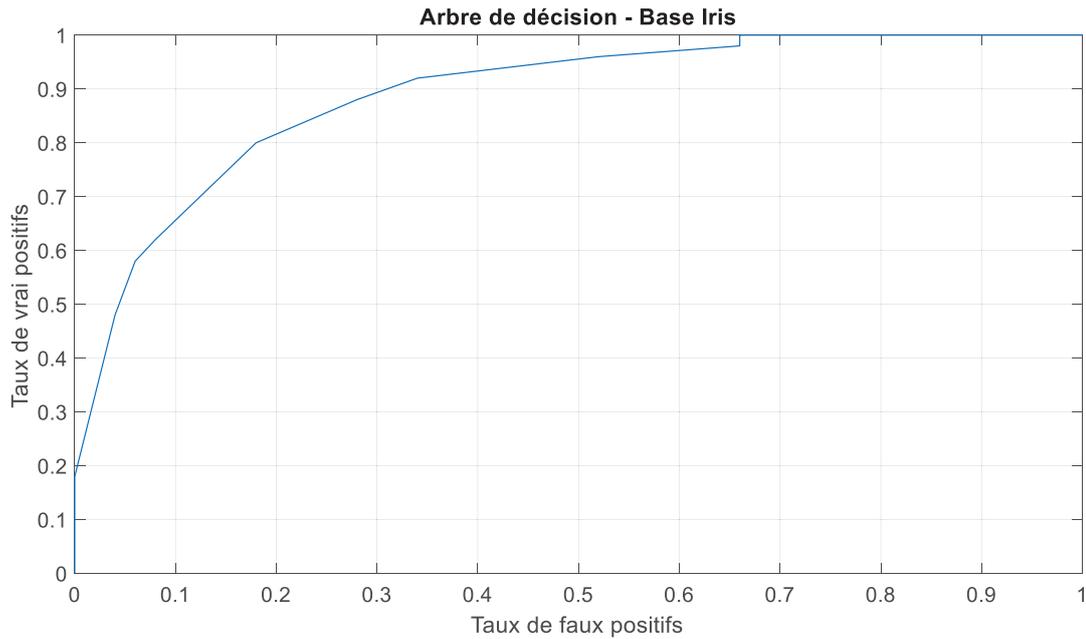


Figure VIII.1 : Exemple de courbe ROC

## 4.2 - NKPI Détectabilité

Cette métrique mesure la capacité d'une signature à percevoir que le système présente un défaut. Considérons un défaut  $j$  de sévérité  $k$ . L'indice de détectabilité permise par une signature  $i$  sera alors donnée par :

$$(VIII.6) \quad GD_{j,i}^k = 2 * AUC_{j,i}^k - 1$$

Plus cette valeur sera proche de 1, plus la détectabilité permise par la signature sera bonne. L'indice de détection de chaque défaut sera donné en prenant la moyenne des indices de détectabilité de tous les modes de sévérité du défaut.

$$(VIII.7) \quad GD_{j,i} = \frac{\sum_{k=1}^{n_{sev}} GD_{j,i}^k}{(n_{sev})}$$

Avec  $n_{sev}$  : le nombre de modes de sévérité

## 4.3 - NKPI Identification

Cette métrique mesure la capacité à distinguer la sévérité d'un défaut. Elle consiste à mesurer la variation de la distribution de la signature entre le cas sain et un cas de défaut  $i$  de sévérité  $k$ . Soit  $T_{i,j}^k$  la distribution de la signature  $i$  pour le défaut  $j$  à la sévérité  $k$ . Par convention le cas  $k = 0$  correspond au cas sain. La matrice de variation  $V_k$  est exprimée par :

$$(VIII.8) \quad V_k = \begin{bmatrix} \text{signe} \left( \text{med}(T_{1,1}^k) - \text{med}(T_1^0) * GD_{1,1}^k \right), \dots, \text{signe} \left( \text{med}(T_{n_{sig}}^k) - \text{med}(T_{n_{sig}}^0) * GD_{1,n_{sig}}^k \right) \\ \vdots \\ \text{signe} \left( \text{med}(T_{1,c}^k) - \text{med}(T_1^0) * GD_{1,c}^k \right), \dots, \text{signe} \left( \text{med}(T_{n_{sig}}^k) - \text{med}(T_{n_{sig}}^0) * GD_{c,n_{sig}}^k \right) \end{bmatrix}$$

Avec med : la fonction médiane, signe : la fonction signe et  $c - 1$  : le nombre de défauts. La  $j^{\text{ième}}$  ligne de la matrice,  $V_k^j$ , représentera le vecteur de variation du défaut  $j$  pour la sévérité  $k$ .

La mesure d'angle entre deux vecteurs de variations  $V_k^j$  et  $V_{k'}^q$  permet de quantifier la capacité à distinguer les cas de sévérité de différents défauts. Dans un cas optimal les deux vecteurs seront de sens opposés et seront donc séparés par un angle de  $\pi$  radians. Le ratio de l'angle formé par ces deux vecteurs et  $\pi$  formera donc l'indicateur d'identification global :

$$(VIII.9) \quad GI(j, q, k, k') = \frac{1}{\pi} \arccos \left\{ \frac{V_k^j \cdot V_{k'}^q}{\|V_k^j\| * \|V_{k'}^q\|} \right\}$$

## 4.4 - NKPI de localisation et de pronostic

Le NKPI de localisation permet de mesurer la capacité à trouver le composant touché par un défaut. Le NKPI de pronostic combine les critères précédents pour former une métrique globale. Pour en savoir plus sur ces NKPI voir (Lamoureux 2014) aux pages 32 à 33 et pages 128 à 133.

# 5 - Détail des NKPI pour les signatures proposées

## 5.1 - Détectabilité

Nom signature	$C_v$	$C_{fsec}$	$K_{rend}$	Kurtosis $S_{var}$	Facteur Crête $S_{var}$	Energie $S_{var}$
Déteçtabilité Défaut CC (%)	3,33	4,00	2,67	25,33	29,33	28,00
Déteçtabilité Défaut VAR (%)	91,33	62,67	8,67	27,33	38,00	70,67

Tableau VIII.3 : Déteçtabilité signatures 1 à 6

Nom signature	Energie $S_{cc}$	Valeur Efficace $S_{var}$	Valeur Efficace $S_{cc}$	Nombre de passages par zéro $S_{var}$	Nombre de passages par zéro $S_{cc}$	Nombre de pics $S_{var}$
Détectabilité Défaut CC (%)	20,00	27,33	20,67	37,33	28,00	30,00
Détectabilité Défaut VAR (%)	67,33	70,00	67,33	53,33	44,67	71,33

Tableau VIII.4 : Détectabilité signatures 7 à 12

Nom signature	Valeur max crête à crête $S_{var}$	Energie $I_q$	Max $I_q$	Min $I_q$	Moyenne $I_q$	Facteur Crête $I_q$
Détectabilité Défaut CC (%)	27,33	0,00	0,00	0,00	0,00	0,00
Détectabilité Défaut VAR (%)	57,33	66,67	63,33	26,67	81,33	100,00

Tableau VIII.5 : Détectabilité signatures 13 à 18

Nom signature	Variance $I_q$	Kurtosis $I_q$	Valeur efficace $I_q$
Détectabilité Défaut CC (%)	0,00	0,00	0,00
Détectabilité Défaut VAR (%)	67,33	100,00	66,67

Tableau VIII.6 : Détectabilité signatures 19 à 21

## 6 - Calcul des paramètres des FA

Pour rappel : on prend la distance entre l'hyperplan et les vecteurs supports dans le sens positif  $d_{sv} \geq 0$ .

### 6.1 - FA trapézoïdale

Les équations définissant une fonction trapézoïdale sont les suivantes :

$$(VIII.10) \quad u(d_x) = \begin{cases} 0 \quad \forall d_x \leq pa_g \\ \frac{d_x - pa_g}{pa_1 - pa_g} \quad \forall d_x \in [pa_g, pa_1] \\ 1 \quad \forall d_x \in [pa_1, pa_2] \\ \frac{pa_d - d_x}{pa_d - pa_2} \quad \forall d_x \in [pa_2, pa_d] \\ 0 \quad \forall d_x \geq pa_d \end{cases}$$

Dans notre cas on ne fait varier les fonctions d'appartenance qu'aux alentours de l'hyperplan séparateur, marqué comme  $d_x = 0$ . Ceci plus la propriété de complémentarité des FA des deux classes font que l'on pose :  $pa_g = -\infty$  et  $pa_d = +\infty$ . La propriété de symétrie donne  $pa_2 = -pa_1$ . On obtient donc les expressions suivantes :

$$(VIII.11) \quad u_+(d_x) = \begin{cases} 0 \quad \forall d_x \leq -pa_2 \\ \frac{d_x}{2pa_2} + \frac{1}{2} \quad \forall d_x \in [-pa_2, pa_2] \\ 1 \quad \forall d_x \geq pa_2 \end{cases}$$

$$(VIII.12) \quad u_-(d_x) = \begin{cases} 1 \quad \forall d_x \leq -pa_2 \\ \frac{-d_x}{2pa_2} + \frac{1}{2} \quad \forall d_x \in [-pa_2, pa_2] \\ 0 \quad \forall d_x \geq pa_2 \end{cases}$$

Une illustration de ces fonctions est donnée à la Figure VIII.2. Le calcul de ces fonctions au niveau des vecteurs supports donne :

$$(VIII.13) \quad \begin{cases} u_+(d_{sv}) = \gamma = \frac{d_{sv}}{2pa_2} + \frac{1}{2} \\ u_-(-d_{sv}) = \gamma = \frac{d_{sv}}{2pa_2} + \frac{1}{2} \end{cases}$$

On obtient deux fois la même équation dont la solution est :

$$(VIII.14) \quad pa_2 = \frac{d_{sv}}{2\gamma - 1}$$

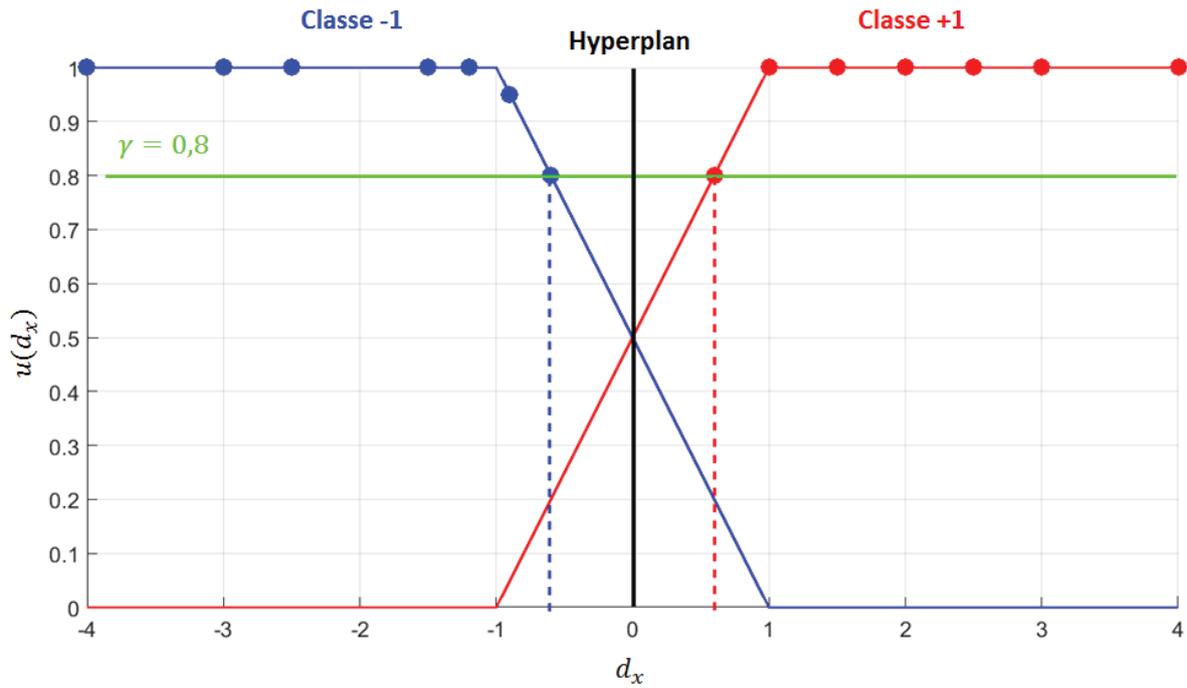


Figure VIII.2 : FA complémentaires trapézoïdales issues d'une SVM binaire

## 6.2 - FA Sigmoïdale

Une fonction d'appartenance sigmoïdale est définie par :

$$(VIII.15) \quad u(d_x) = \frac{1}{1 + e^{-pa_1(d_x - pa_2)}}$$

Pour assurer la condition de symétrie on pose  $pa_2 = 0$ . On obtient donc comme fonctions d'appartenances aux classes

$$(VIII.16) \quad \begin{aligned} u_+(d_x) &= \frac{1}{1 + e^{-pa_1 d_x}} \\ u_-(d_x) &= 1 - \frac{1}{1 + e^{-pa_1 d_x}} \end{aligned}$$

Le calcul au niveau des vecteurs supports donne :

$$(VIII.17) \quad u(d_{sv}) = \gamma = \frac{1}{1 + e^{-pa_1 d_{sv}}}$$

$$(VIII.18) \quad \Leftrightarrow \frac{1-\gamma}{\gamma} = e^{-pa_1 d_{sv}}$$

$$(VIII.19) \quad \Leftrightarrow \ln\left(\frac{1-\gamma}{\gamma}\right) = -pa_1 d_{sv}$$

$$(VIII.20) \quad \Leftrightarrow pa_1 = \ln\left(\frac{1-\gamma}{\gamma}\right) / -d_{sv}$$

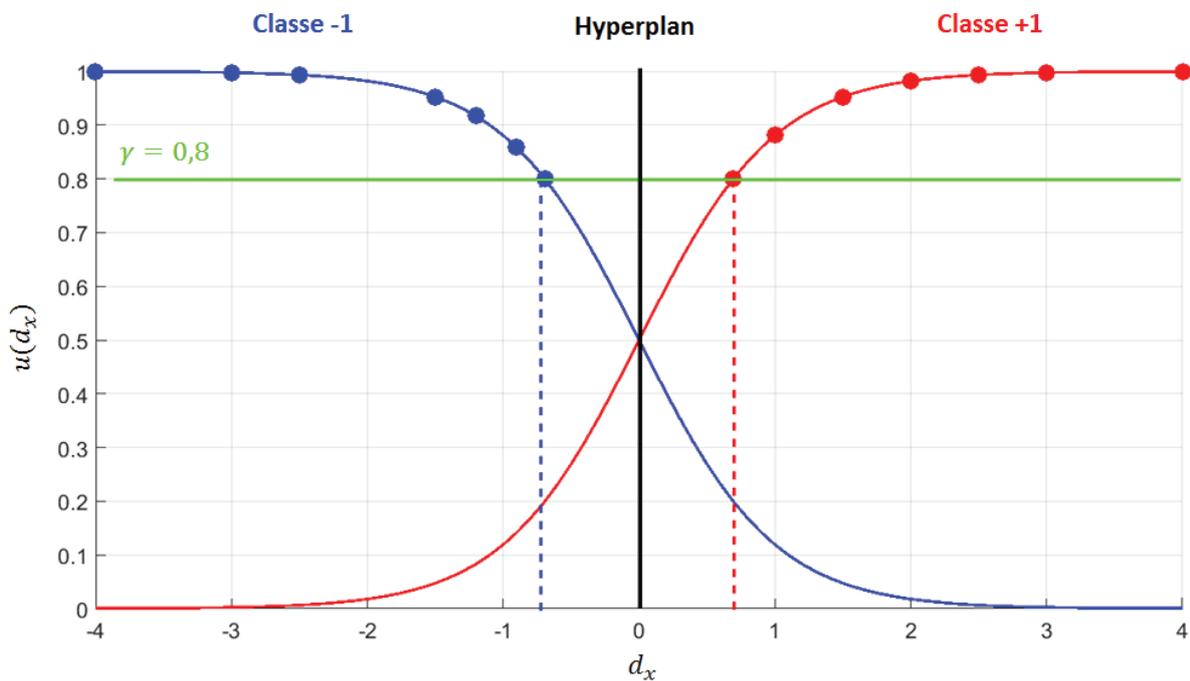


Figure VIII.3 : FA complémentaires sigmoïdales issues d'une SVM binaire

## 6.3 - FA Polynomiale

Une fonction d'appartenance polynomiale en S est définie par :

$$(VIII.21) \quad u(d_x) = \begin{cases} 0 \quad \forall d_x \leq pa_1 \\ 2\left(\frac{d_x - pa_1}{pa_2 - pa_1}\right)^2 \quad \forall d_x \in [pa_1, \frac{pa_1 + pa_2}{2}] \\ 1 - 2\left(\frac{d_x - pa_2}{pa_2 - pa_1}\right)^2 \quad \forall d_x \in [\frac{pa_1 + pa_2}{2}, pa_2] \\ 1 \quad \forall d_x \geq pa_2 \end{cases}$$

Une fonction d'appartenance polynomiale en Z, sa complémentaire, est définie par :

$$(VIII.22) \quad u(d_x) = \begin{cases} 1 \quad \forall d_x \leq pa_1 \\ 1 - 2\left(\frac{d_x - pa_1}{pa_2 - pa_1}\right)^2 \quad \forall d_x \in [pa_1, \frac{pa_1 + pa_2}{2}] \\ 2\left(\frac{d_x - pa_2}{pa_2 - pa_1}\right)^2 \quad \forall d_x \in [\frac{pa_1 + pa_2}{2}, pa_2] \\ 0 \quad \forall d_x \geq pa_2 \end{cases}$$

La condition de symétrie pour notre cas donne  $pa_1 = -pa_2$  avec  $pa_2 \geq 0$ .

En calculant l'une des deux fonctions d'appartenances au niveau des vecteurs supports on obtient :

$$(VIII.23) \quad u(d_{sv}) = \gamma = 1 - 2\left(\frac{d_{sv} - pa_1}{-2pa_1}\right)^2$$

$$(VIII.24) \quad \Leftrightarrow 1 - \gamma = 2\left(\frac{d_{sv} - pa_1}{-2pa_1}\right)^2$$

$$(VIII.25) \quad \Leftrightarrow 4pa_1^2(1 - \gamma) = 2(d_{sv}^2 - 2d_{sv}pa_1 + pa_1^2)$$

$$(VIII.26) \quad \Leftrightarrow 2pa_1^2(1 - \gamma) = (d_{sv}^2 - 2d_{sv}pa_1 + pa_1^2)$$

$$(VIII.27) \quad \Leftrightarrow (1 - 2\gamma)pa_1^2 + 2d_{sv}pa_1 - d_{sv}^2 = 0$$

Il s'agit d'un trinôme du second ordre. Son discriminant est exprimé par :

$$(VIII.28) \quad \Delta = 4d_{sv}^2 + 4d_{sv}^2(1 - 2\gamma)$$

On souhaite avoir une solution réelle. Il faut donc que le discriminant soit positif ou nulle. Cela implique :

$$(VIII.29) \quad 4d_{sv}^2 + 4d_{sv}^2(1 - 2\gamma) \geq 0$$

$$(VIII.30) \quad 1 + (1 - 2\gamma) \geq 0$$

$$(VIII.31) \quad \Leftrightarrow -2\gamma \geq -2$$

$$(VIII.32) \quad \Leftrightarrow \gamma \leq 1$$

Ce qui est déjà le cas puisque par définition  $\gamma \in ]0.5, 1]$ .

Les solutions du trinôme peuvent donc être exprimés par :

$$(VIII.33) \quad \begin{aligned} pa_{1-1} &= \frac{-2d_{sv} - \sqrt{\Delta}}{2(1-2\gamma)} \\ pa_{1-2} &= \frac{-2d_{sv} + \sqrt{\Delta}}{2(1-2\gamma)} \end{aligned}$$

Avec

$$(VIII.34) \quad \sqrt{\Delta} = 2d_{sv}\sqrt{2-2\gamma}$$

D'où :

$$(VIII.35) \quad \begin{aligned} pa_{1-1} &= \frac{-2d_{sv} - 2d_{sv}\sqrt{2-2\gamma}}{2(1-2\gamma)} \\ pa_{1-2} &= \frac{-2d_{sv} + 2d_{sv}\sqrt{2-2\gamma}}{2(1-2\gamma)} \end{aligned}$$

(VIII.36)

$$\Leftrightarrow \begin{aligned} pa_{1-1} &= \frac{-d_{sv} - d_{sv}\sqrt{2-2\gamma}}{(1-2\gamma)} \\ pa_{1-2} &= \frac{-d_{sv} + d_{sv}\sqrt{2-2\gamma}}{(1-2\gamma)} \end{aligned}$$

(VIII.37)

$$\Leftrightarrow \begin{aligned} pa_{1-1} &= \frac{d_{sv}(1+\sqrt{2-2\gamma})}{(2\gamma-1)} \\ pa_{1-2} &= \frac{d_{sv}(1-\sqrt{2-2\gamma})}{(2\gamma-1)} \end{aligned}$$

En sachant que  $d_{sv} \geq 0$  et que  $pa_1 \geq d_{sv}$  l'unique solution est :

$$(VIII.38) \quad pa_1 = \frac{d_{sv}(1 + \sqrt{2-2\gamma})}{(2\gamma-1)}$$

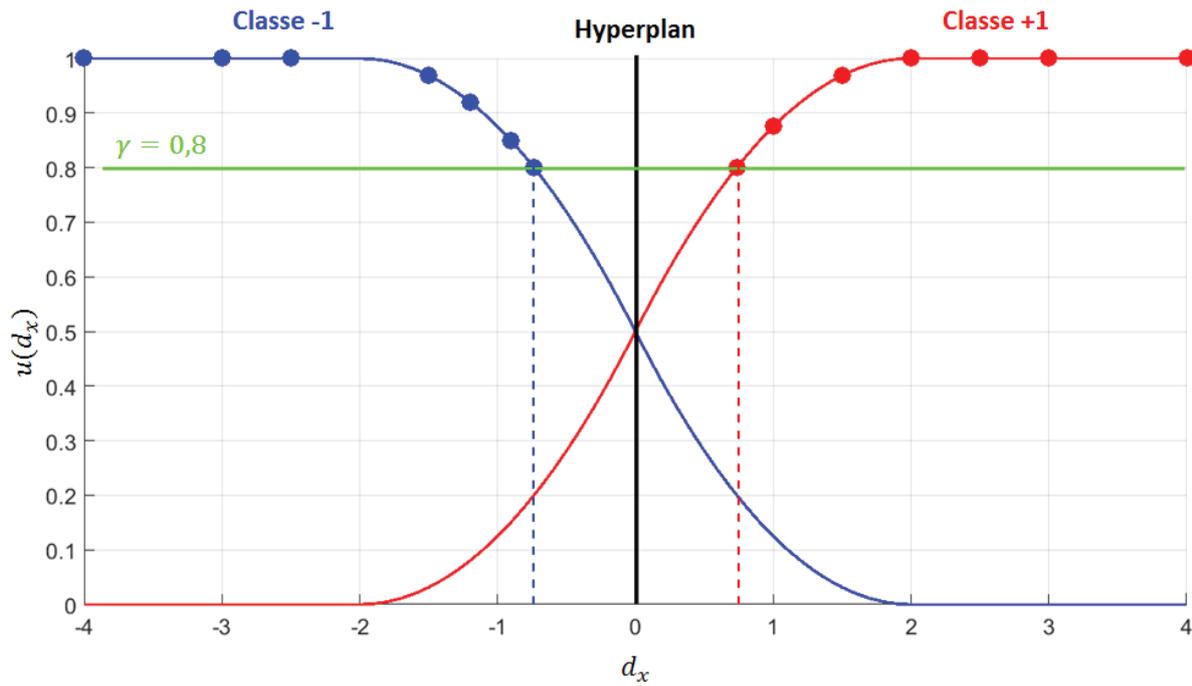


Figure VIII.4 : FA complémentaires polynomiales issues d'une SVM binaire

## 7 - Exemples de Tnormes

### 7.1 - Min/Max

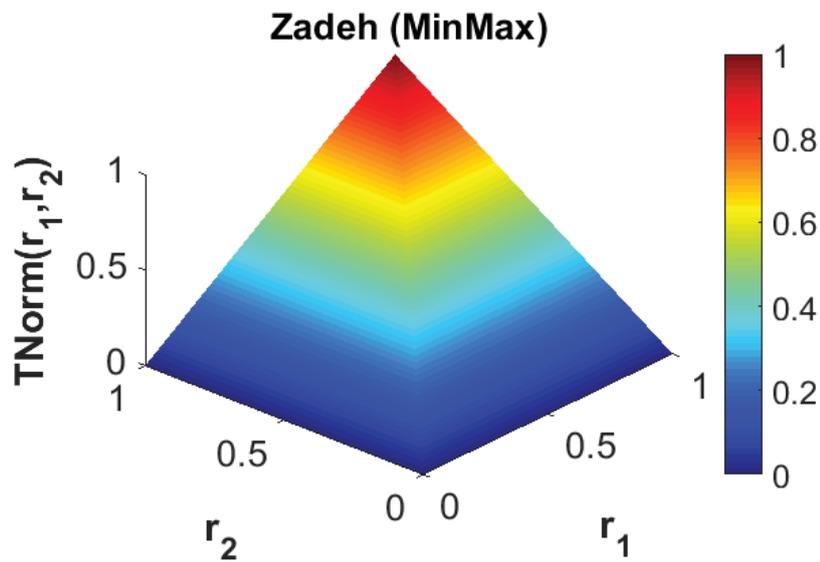
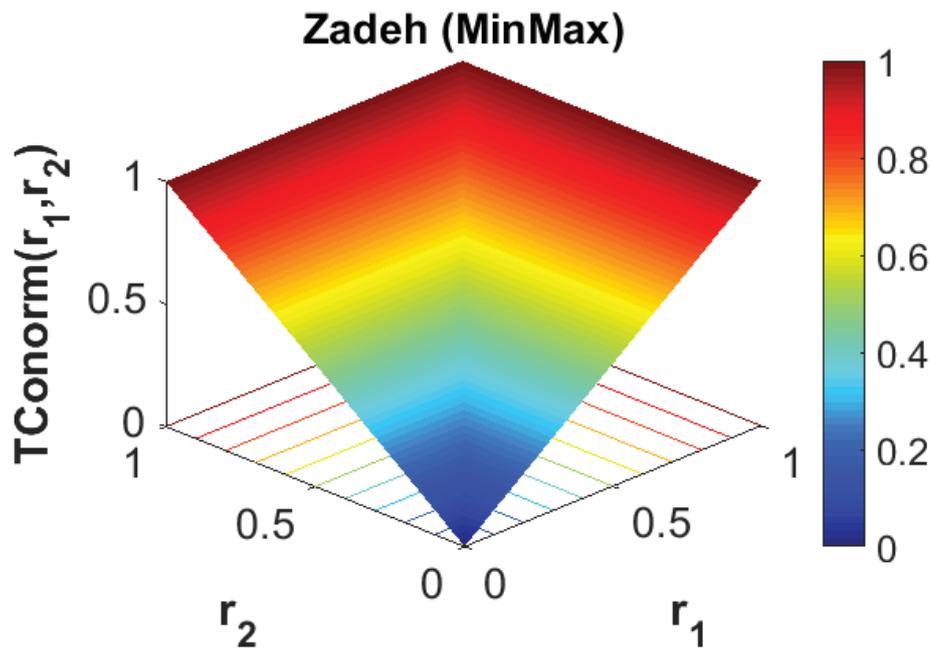
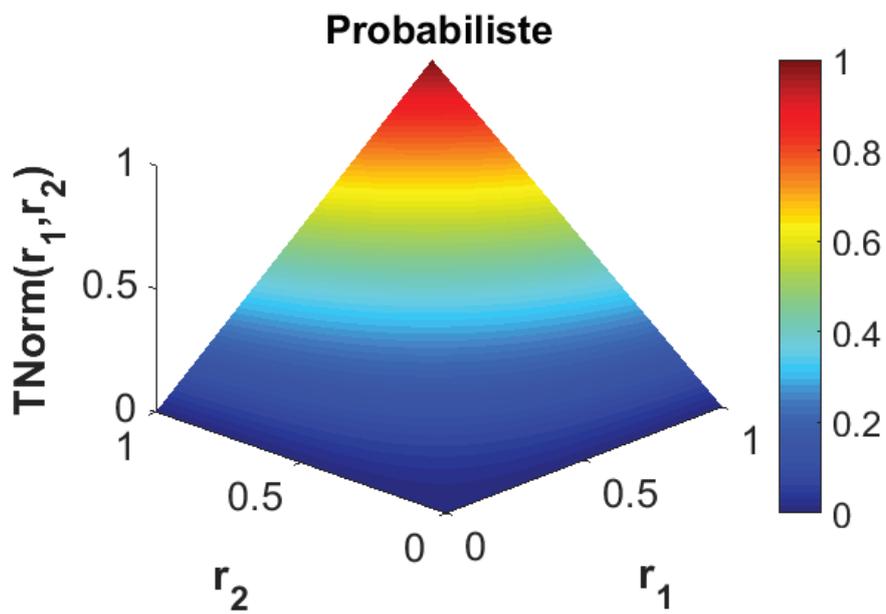


Figure VIII.5 : Cartographie de la T-norme minimum



## 7.2 - Normes probabilistes



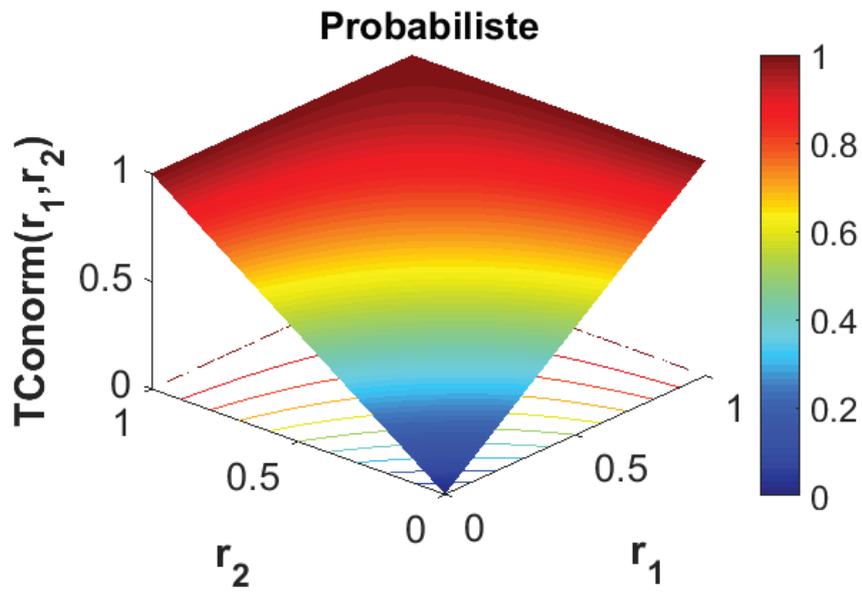


Figure VIII.8 : Cartographie de la T-conorme probabiliste

### 7.3 - Normes de Lukasiewicz

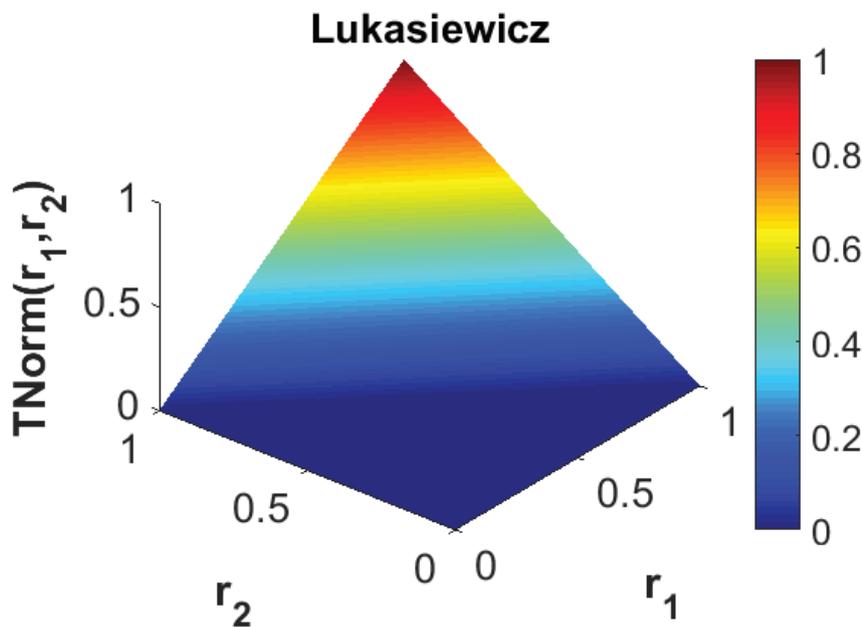


Figure VIII.9 : Cartographie de la T-norme de Lukasiewicz

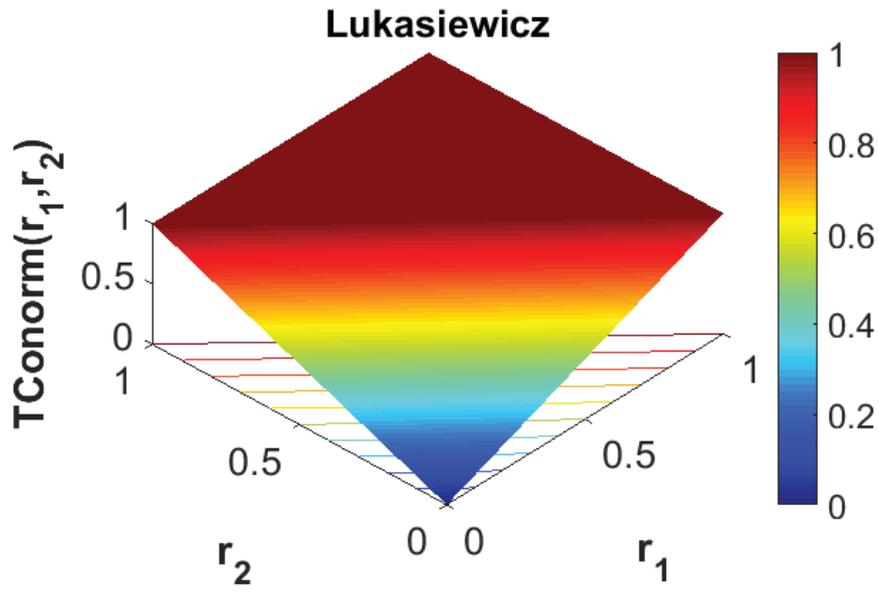


Figure VIII.10 : Cartographie de la T-conorme de Lukasiewicz

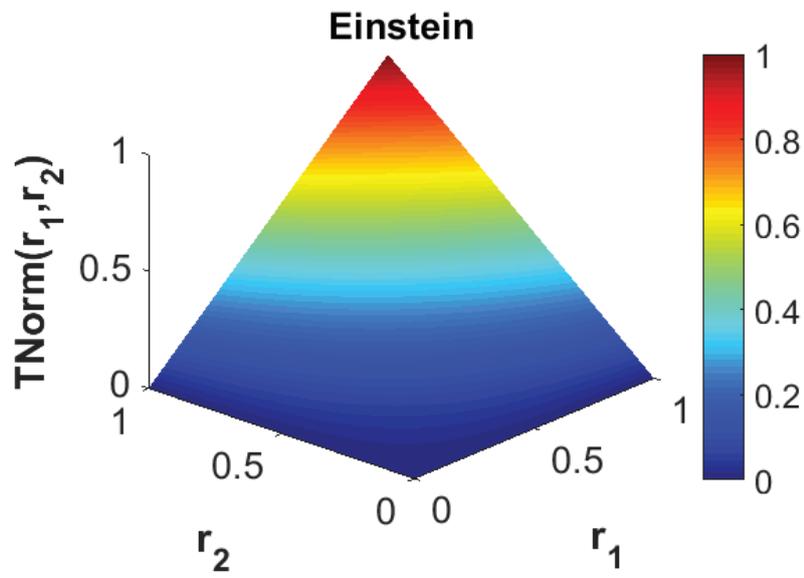


Figure VIII.11 : Cartographie de la T-norme d'Einstein

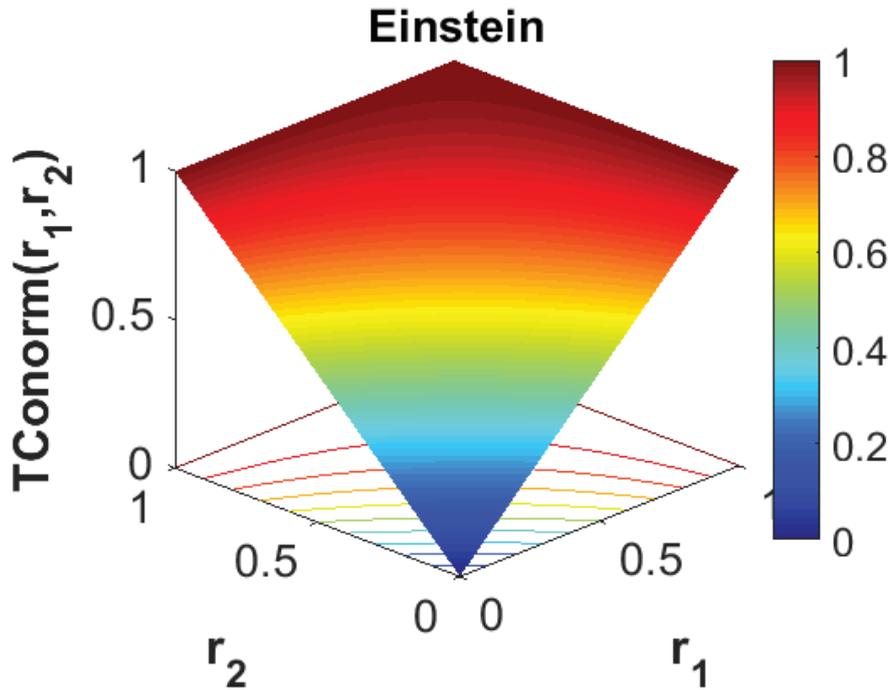


Figure VIII.12 : Cartographie de la T-conorme d'Einstein

## 8 - Banc machine asynchrone

### 8.1 - Caractéristiques du moteur asynchrone

Caractéristique	Valeur
Puissance utile nominale (kw)	5.5
Fréquence d'alimentation (Hz)	50
Vitesse nominale (t/min)	1440
Tension nominale entre phases (V)	400
Courant nominale (A)	11.4
Facteur de puissance	0.84
Nombre de paires de pôles	2
Résistance statorique par phase (Ohm)	1.315
Nombre d'encoches au rotor	28
Nombre d'encoches au stator	48

Tableau VIII.7 : Caractéristiques de la machine asynchrone (Soualhi 2013)

### 8.2 - Signatures liées à la base

L'ensemble des signatures sont disponibles dans (Ondel 2006; Soualhi 2013). Elles sont rassemblées dans (Ondel 2006) aux pages 159 – 160.

## 9 - Banc machine synchrone à aimants

### 9.1 - Caractéristiques de la MSAP

Caractéristique	Valeur
Puissance utile nominale (kw)	1.5
Vitesse nominale (t/min)	375
Tension d'alimentation nominale (V)	270
Nombre de paires de pôle	8

Tableau VIII.8 : Caractéristiques de la MSAP (Leboeuf 2012)

### 9.2 - Signatures liées à la base

Ces signatures sont issues des travaux de (Boileau 2010) et (Leboeuf 2012). La liste complète des signatures est disponible dans (Leboeuf 2012) aux pages 155 – 156.

#### 9.2.a - Harmoniques deux

Soit  $v$  : la tension de commande,  $i$  le courant,  $\dots_d$  : l'indice pour l'axe  $d$  du repère de Park,  $\dots_q$  : l'indice pour l'axe  $q$  du repère de Park,  $\dots_{\dots_0}$  : l'indice pour la composante continue,  $\dots_{\dots_2}$  : l'indice pour l'harmonique de rang 2.

$$(VIII.39) \quad P_{2max} = |v_{d0} * i_{d2}| + |v_{d2} * i_{d0}| + |v_{q0} * i_{q2}| + |v_{q2} * i_{q0}|$$

#### 9.2.b - Paramètres estimés par Filtre de Kalman étendu

Soit le modèle de la machine synchrone à aimants alimenté par onduleur (Boileau 2010) :

$$(VIII.40) \quad G_{ond} \cdot \begin{bmatrix} u_{dref} \\ u_{qref} \end{bmatrix} = \hat{R}_S \begin{bmatrix} i_d \\ i_q \end{bmatrix} + \hat{L}_S \frac{d}{dt} \begin{bmatrix} i_d \\ i_q \end{bmatrix} + \begin{bmatrix} 0 \\ n_p \Omega \Psi_a \end{bmatrix}$$

Avec  $G_{ond}$  : le gain de l'onduleur,  $u_{dqref}$  : les tensions de références,  $\hat{R}_S$  : la résistance statorique estimée,  $\hat{L}_S$  : l'inductance statorique estimée,  $n_p$  : le nombre de paires de pôles,  $\Psi_a$  : le flux magnétique des aimants permanents.

En posant  $pKE_1 = \frac{R_S}{L_S}$  et  $pKE_2 = \frac{1}{L_S}$  on peut réécrire le modèle d'état comme :

$$(VIII.41) \quad \frac{d}{dt} \begin{bmatrix} i_d \\ i_q \\ pKE_1 \\ pKE_2 \end{bmatrix} = \begin{bmatrix} -pKE_1 \cdot i_d + pKE_2 \cdot G_{ond} \cdot u_{dref} \\ -pKE_1 \cdot i_q + pKE_2 \cdot (G_{ond} \cdot u_{qref} - \Psi_a \omega) \\ 0 \\ 0 \end{bmatrix}$$

$$(VIII.42) \quad y = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} i_d \\ i_q \\ pKE_1 \\ pKE_2 \end{bmatrix}$$

### 9.2.c - Résidus issus d'un modèle de machine sain

Le modèle sain s'exprime par (Leboeuf 2012) :

$$(VIII.43) \quad v_{abc} = R_s \cdot i_{abc} + L_s \cdot \frac{di_{abc}}{dt} + e_{abc}$$

$$(VIII.44) \quad e_{abc} = -p \cdot \Psi_m \cdot \Omega \begin{bmatrix} \sin(\theta_e) \\ \sin(\theta_e - \frac{2\pi}{3}) \\ \sin(\theta_e + \frac{2\pi}{3}) \end{bmatrix}$$

Avec  $\dots_{abc}$  : vecteur dans le repère triphasé,  $\Psi_m$  : amplitude du fondamental du flux dans (abc),  $\theta_e$  : position électrique.

### 9.2.d - Résidus issus d'un modèle saturé au premier harmonique

Le modèle s'exprime dans le repère rotorique (Leboeuf 2012) :

$$(VIII.45) \quad v_{dq} = R_s \cdot i_{dq} + L_{dq}(i_d, i_q) \cdot \frac{di_{dq}}{dt} + p \cdot \Omega \cdot \Phi_{dq}(i_d, i_q)$$

Les tables de paramètres sont évaluées par réseaux de perméances.

### 9.2.e - Résidus issus d'un modèle incluant certains harmoniques d'espaces

On considère que les composantes directes et en quadratures dépendent de la position électrique (Leboeuf 2012) :

$$(VIII.46) \quad v_{dq} = R_s \cdot i_{dq} + L_{dq}(i_d, i_q, \theta_e) \cdot \frac{di_{dq}}{dt} + p \cdot \Omega \cdot A(i_d, i_q, \theta_e)$$

$$(VIII.47) \quad A(i_d, i_q, \theta_e) = \begin{bmatrix} A_d(i_d, i_q, \theta_e) \\ A_q(i_d, i_q, \theta_e) \end{bmatrix} = \begin{bmatrix} -\Phi_q(i_d, i_q, \theta_e) + \frac{\delta\Phi_d(i_d, i_q, \theta_e)}{\delta\theta_e} \\ \Phi_d(i_d, i_q, \theta_e) + \frac{\delta\Phi_q(i_d, i_q, \theta_e)}{\delta\theta_e} \end{bmatrix}$$

## 10 - Sélection de paramètres

La méthode de sélection des paramètres utilisé dans ce mémoire est la « Sélection Séquentiel Arrière » (*Sequential Backward Selection : SBS*) (Doak 1992; Kudo et Sklansky 2000). Le principe est le suivant :

Algorithme 13 : SBS	
<b>(1)</b>	<b>Initialisation</b>
	Choisir un critère de sélection : $J$ Choisir le nombre de paramètres à obtenir : $p_{opt}$ avec $p_{opt} < p$ Initialiser : $p' = p - 1$
<b>(2)</b>	<b>Identification du paramètre le moins influant</b>
	Calculer le critère $J$ pour l'ensemble des combinaisons de $p'$ paramètres Trouver le paramètre $p_{min}$ tel que $p_{min} = \operatorname{argmin}_{i \in \{1, \dots, p'\}} [J_i]$ Retirer $p_{min}$ de la base de données $p' = p' - 1$
<b>(3)</b>	<b>Atteinte du critère d'arrêt</b>
	Répéter (2) jusqu'à $p' = p_{opt}$

Le critère de sélection utilisé ici est exprimé par :

$$(VIII.48) \quad J = \frac{\det[\Sigma_W + \Sigma_B]}{\det[\Sigma_W]}$$

Avec  $\Sigma_W$  la matrice de dispersion intra – classes (à minimiser), et  $\Sigma_B$  celle de dispersion inter – classes (à maximiser), exprimées par :

$$(VIII.49) \quad \Sigma_W = \frac{1}{m} \sum_{i=1}^c \sum_{j=1}^{m_c} [(X_{ji} - g_i)(X_{ji} - g_i)']$$

$$(VIII.50) \quad \Sigma_B = \frac{1}{m} \sum_{i=1}^c [(g_i - g)(g_i - g)']$$

Où :  $m$  : nombre d'observations dans la classe,  $c$  : nombre de classes (connu),  $m_c$  : nombre d'observations de la classe  $c$ ,  $X_{ji}$  :  $j^{\text{ème}}$  observation de la  $i^{\text{ème}}$  classe,  $g_i$  : centre de gravité de la  $i^{\text{ème}}$  classe,  $g$  : centre de gravité de l'ensemble des observations.

Dans la pratique la sélection  $p_{opt}$  se fait en traçant l'évolution du critère en fonction du nombre de paramètres. La zone où la courbe forme un coude donne l'intervalle où se trouve le nombre optimal

de paramètres.

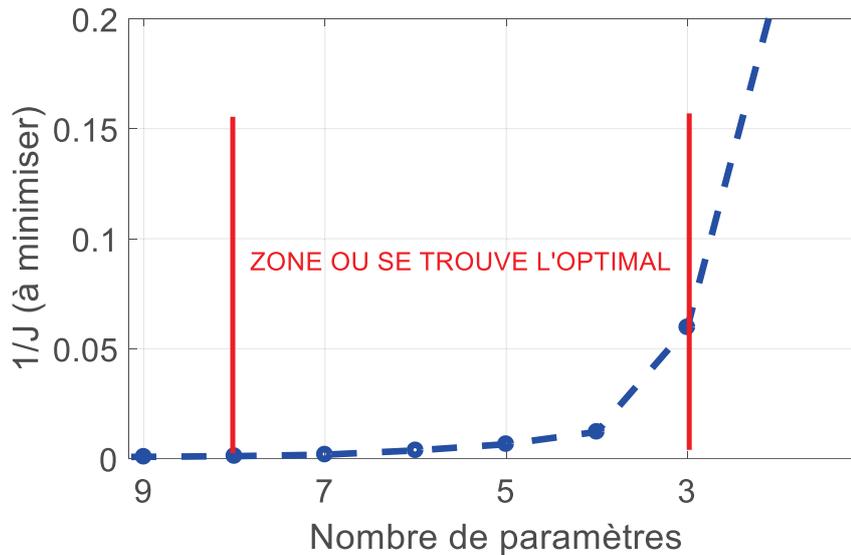


Figure VIII.13 : Exemple d'évolution de critère en fonction du nombre de paramètres

## 11 - Métriques d'évaluation

### 11.1 - Catégories de métriques

Les métriques peuvent être réparties en quatre catégories selon leur domaine d'actions.

Niveau	Objectifs	Type de Métriques
Concepteur d'algorithmes	Développer et implémenter les algorithmes sous les contraintes spécifiées	Algorithmes et Calculs
Maintenance	Planifier pour réduire les immobilisations et maximiser la disponibilité	Algorithmes (Exactitude, précision, horizon de prédiction...)
Logistique	Minimiser le nombre de pièces en stock et le temps de livraison de celles-ci	Algorithmes (horizon de prédiction...)
Gestionnaire de flottes	Maximiser la durée de vie des appareils, minimiser les temps de maintenance imprévus	Coûts / Bénéfices
Réglementaire	Identifier les risques potentiels et minimiser leurs effets	Certification Coûts / Bénéfices

Tableau VIII.9: Classification des métriques par niveau de décision dans le cadre aéronautique (Basé sur : (Saxena et al. 2008, 2010; Wheeler et al. 2009))

Ainsi la première catégorie, la plus importante, représente les métriques de performances des algorithmes (exactitude, précision, robustesse, convergence...). La deuxième catégorie concerne la

partie implémentation des algorithmes (coûts de calculs, complexité...). La troisième porte sur l'impact financier des algorithmes (retour sur investissement, coût du cycle de vie...). Enfin la dernière, plus rarement considérée, porte sur la partie certification (méthodes et coûts associés). On peut lier chaque catégorie de métrique à un ou plusieurs niveaux de décision, ainsi qu'aux acteurs associés. Les deux premières catégories, performances algorithmiques et calculatoires, contiennent des métriques applicables hors – ligne (la fin de vie du système est connu) mais également en ligne (la fin de vie est inconnue). Afin d'évaluer les métriques en ligne, il est nécessaire que les algorithmes soient utilisés sur des systèmes en opération. Ainsi seules les métriques hors – lignes seront utilisées ici. Pour plus d'informations sur les métriques utilisables en ligne voir (Saxena et al. 2014).

## 11.2 - Autres métriques de performances

La convergence repose sur l'hypothèse que l'algorithme à l'étude a déjà atteint les niveaux souhaités vis-à-vis des métriques de performances. Il est également fait l'hypothèse que les performances de l'algorithme s'améliorent au fur et à mesure que des données sur l'équipement sont disponibles. Ainsi la convergence quantifie la manière dont la métrique s'améliore avec l'apport de nouvelles données. La convergence est une méta – métrique puisque qu'elle repose sur le calculs d'autres métriques de performances. La convergence est évaluée jusqu'à un temps de fin de prédiction (*End of Prédiction : EOP*)  $t_{EOP}$ .

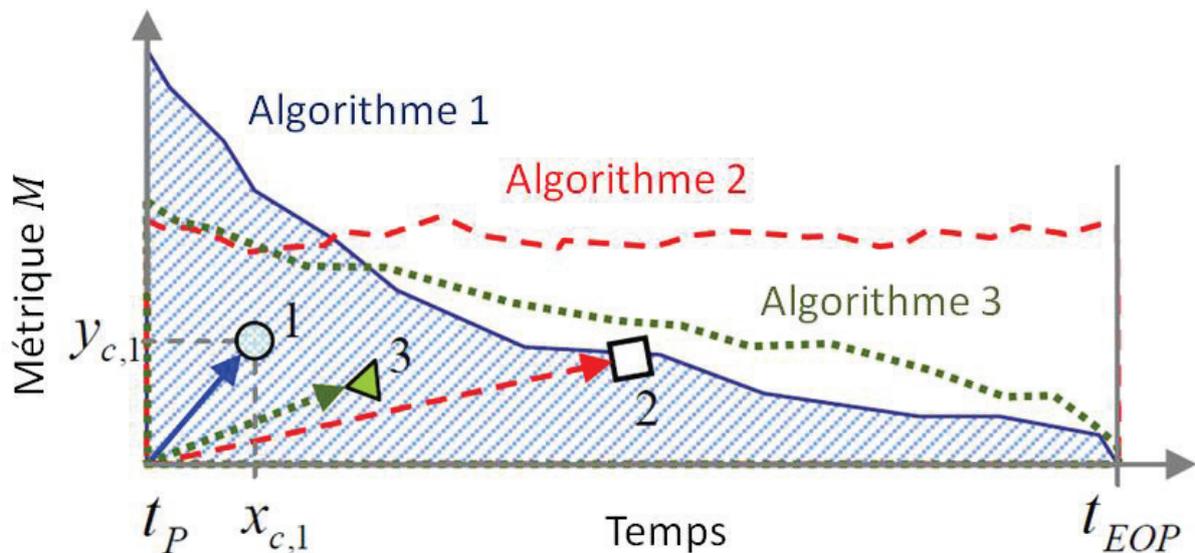


Figure VIII.14 : Comparaison des convergences de trois algorithmes selon une métrique  $M$  (Saxena et al. 2009b)

La distance entre l'origine  $M(t_P)$  et le centre de gravité de la surface correspondant à un algorithme quantifie la convergence (Saxena et al. 2009b, 2010). Ainsi la convergence se calcule par la distance euclidienne entre l'origine et le centre de gravité de la surface de la métrique :

$$(VIII.51) \quad C_M = \sqrt{(x_c - t_P)^2 + y_c^2}$$

Où  $(x_c, y_c)$  : centre de gravité de la surface de la métrique  $M$  pour un algorithme donné.

## 12 - Algorithme des c – moyennes

L'algorithme de partitionnement par c – moyennes (**Bezdek et al. 1984**) est décrit ci – suit. On adopte les notations suivantes :

- ⇒  $U$  : matrice de taille  $(c * m)$  des appartenances des  $m$  observations aux  $c$  classes
- ⇒  $u_{ij} \in [0, 1]$  : appartenance de la  $j^{\text{ème}}$  observation à la  $i^{\text{ème}}$  classe
- ⇒  $m_{fcm} \in [1 ; +\infty[$  : exposant de pondération
- ⇒  $g = [g_1 \dots g_c]$  : vecteur des centres de gravité des classes
- ⇒  $\varepsilon$  : Ecart minimale de la fonction coût entre deux itérations (choisi par l'utilisateur)
- ⇒  $n_{max}$  : nombre maximum d'itérations (choisi par l'utilisateur)

On rappelle :

- ⇒  $X$  : matrice des observations  $x^{(j)} \in \mathbb{R}^p$

La distance  $d$  sera définie par l'équation **(V.13)** avec  $A_d = I$  la matrice identité. Il s'agira donc de la distance euclidienne.

Les appartenances doivent satisfaire aux contraintes suivantes :

$$(VIII.52) \quad \sum_{j=1}^m u_{ij} > 0 \quad \forall i \in \{1, \dots, c\}$$

$$(VIII.53) \quad \sum_{i=1}^c u_{ij} = 1 \quad \forall j \in \{1, \dots, m\}$$

La fonction à optimiser pour calculer les centres de gravités des classes est :

$$(VIII.54) \quad J_{fcm} = \sum_{j=1}^m \sum_{i=1}^c (u_{ij})^{m_{fcm}} \|x^{(j)} - g_i\|_d^2$$

Pour optimiser cette fonction l'algorithme, suivant doit être appliqué

### Algorithme 14 : "Fuzzy C Means" - Apprentissage

<b>(1)</b>	<b>Initialisations</b>  Initialiser aléatoirement la matrice $U$ Calculer la fonction coût initiale $J_{fcm}(0)$
<b>(2)</b>	<b>Incrémenter le compteur d'itérations <math>n</math></b>
<b>(3)</b>	<b>Calcul des centres de gravités</b>  $\hat{g}_i = \frac{\sum_{j=1}^m (\hat{u}_{ij})^{m_{fcm}} x^{(j)}}{\sum_{j=1}^m (\hat{u}_{ij})^{m_{fcm}}}$
<b>(4)</b>	<b>Calcul des distances entre les nouveaux centres de gravités et observations</b>  $d_{ij} = \sqrt{(x^{(j)} - g_i)^T (x^{(j)} - g_i)}$
<b>(5)</b>	<b>Mise à jour des appartenances</b>  $\hat{u}_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d_{ij}}{d_{kj}}\right)^{2/(m_{fcm}-1)}}$
<b>(6)</b>	<b>Critère d'arrêt</b>  Si $(J_{fcm}(n) - J_{fcm}(n-1)) < \varepsilon$ ou $n = n_{max}$ Alors arrêter l'algorithme Sinon répéter depuis l'étape 2

Pour calculer les appartenances d'une nouvelle observation  $x_{new}$  :

### Algorithme 15 : "Fuzzy C Means" - Test

<b>(1)</b>	<b>Calculer les distances de <math>x_{new}</math> aux centres de gravités des classes : <math>d(x_{new}, g_i)</math></b>
<b>(2)</b>	<b>Calculer ses appartenances aux classes</b>  $u_i(x_{new}) = \frac{1}{\sum_{k=1}^c \left(\frac{d(x_{new}, g_i)}{d(x_{new}, g_k)}\right)^{2/(m_{fcm}-1)}}$

L'attribution d'une unique classe à  $x_{new}$  peut se faire par :

(VIII.55)

$$classe(x_{new}) = \underset{i \in \{1, \dots, c\}}{\operatorname{argmax}} u_i(x_{new})$$

## 13 - Résultats de partitionnements

Les résultats ci – dessous ont été obtenus sur les données roulements IMS via l’algorithme des c-moyennes. Les résultats pour trois classes sont les suivants :

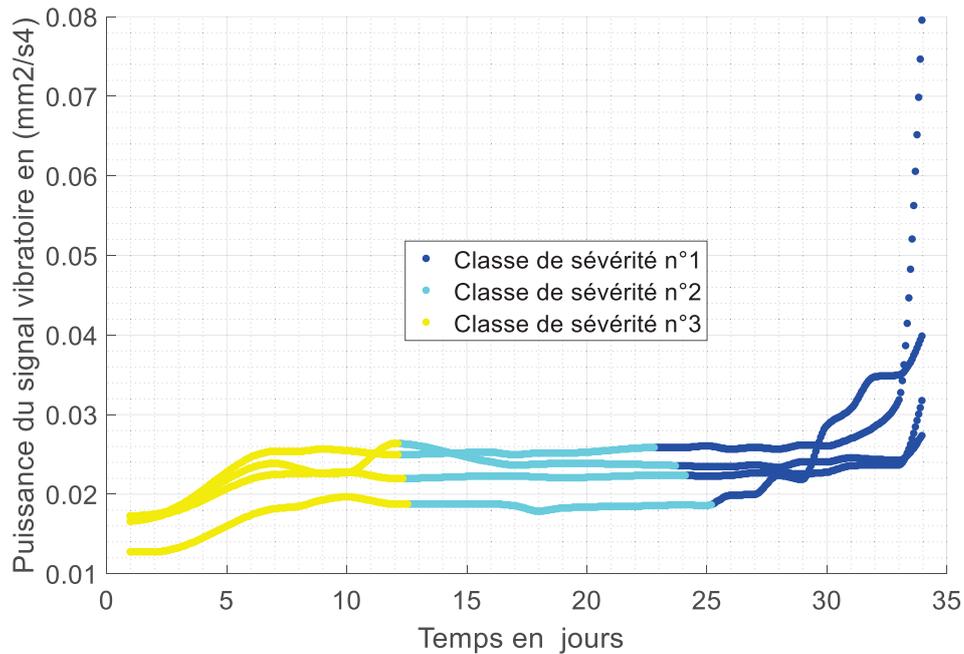


Figure VIII.15 : Puissance du signal vibratoire en fonction du temps - observations partitionnées (c=3)

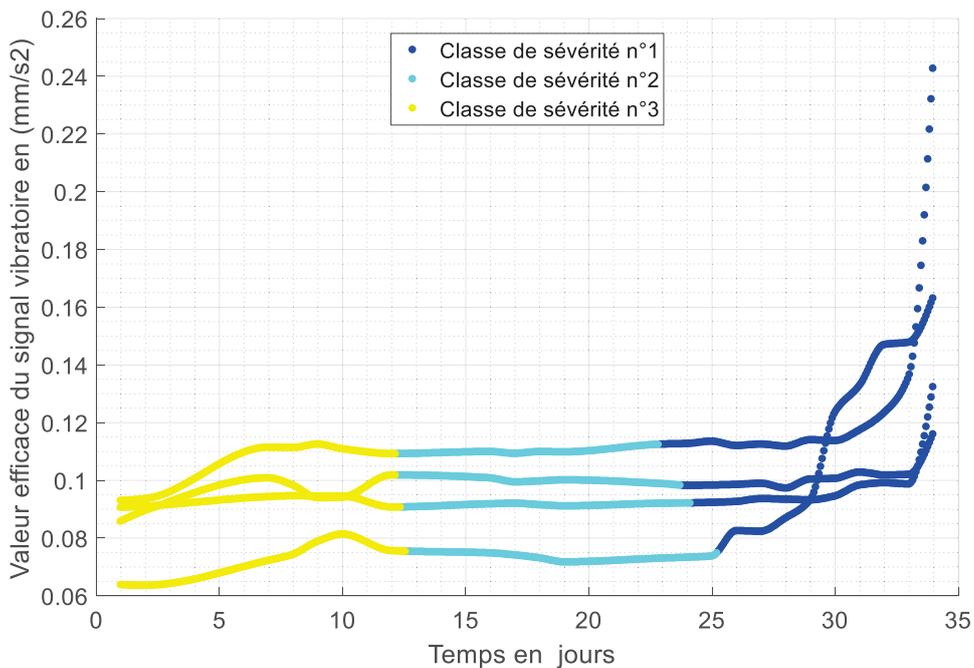


Figure VIII.16 : Valeur efficace du signal vibratoire en fonction du temps – observations partitionnées (c=3)

La cohérence temporelle des classes de sévérité est assurée : les classes se succèdent bien les unes après les autres. La classe de sévérité la plus élevée, la une, démarre entre 23 et 25 jours, en fonction des unités. Elle contient bien le décollage des paramètres qui correspond à la toute fin de vie. Une classe centrale, de sévérité moyenne commence elle vers 12 jours. Elle est précédée par une phase initiale qui correspond au rodage.

Les résultats pour cinq classes sont les suivants :

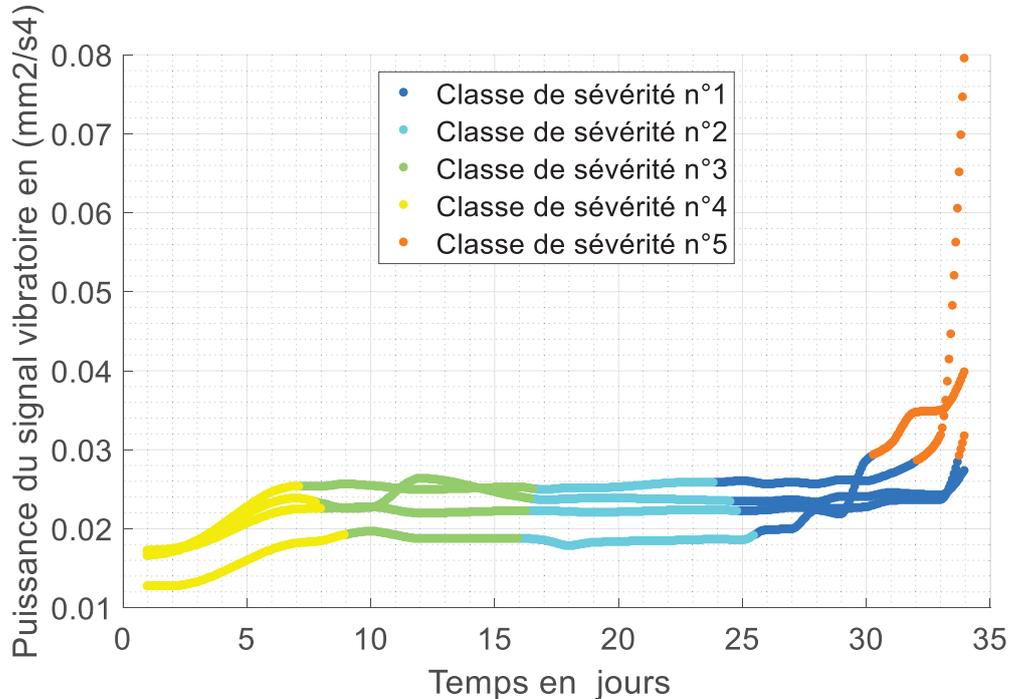


Figure VIII.17 : Puissance du signal vibratoire en fonction du temps - observations partitionnées ( $c=5$ )

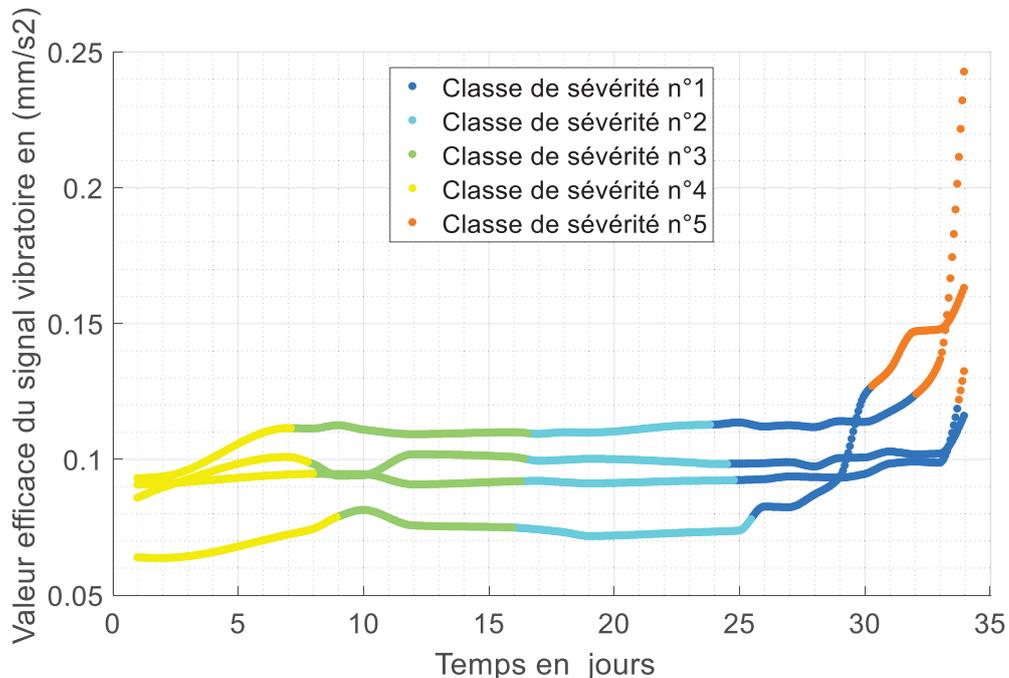


Figure VIII.18 : Valeur efficace du signal vibratoire en fonction du temps - observations partitionnées ( $c=5$ )

La cohérence temporelle est respectée. La fin de vie est séparée en deux classes successives, dont une qui ne contient que très peu d'observations. Une des unités testées n'a d'ailleurs aucune observation dans cette classe de sévérité. Le milieu de vie, comme précédemment, est constitué de deux classes. Enfin la phase initiale de rodage est très bien isolée.

## 14 - Comparaisons des temps de fin de vie

Les écarts relatifs entre les temps de fin de vie donnés par expert et ceux donnés par le partitionnement sont présentés dans le tableau ci-dessous.

Ecart sur le temps de fin de vie en % (C = 3)				
Critère / Roulement	Puissance Début Coude	Puissance Fin Coude	RMS Début Coude	RMS Fin Coude
R1	-28,2	-28,2	-27,9	-27,9
R2	-26,7	-26,7	-26,7	-26,7
R3	-23,7	-30,8	-23,7	-30,6
R4	0,3	-13,1	0,3	-7,1

Tableau VIII.10 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert ( $c = 3$ )

Ecart sur le temps de fin de vie en % (C = 5)				
Critère / Roulement	Puissance Début Coude	Puissance Fin Coude	RMS Début Coude	RMS Fin Coude
R1 (fin de vie non atteinte)	-100,0	-100,0	-100,0	-100,0
R2	2,4	2,4	2,4	2,4
R3	6,9	-3,1	6,9	-2,8
R4	20,3	4,2	20,3	11,4

Tableau VIII.11 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert ( $c = 5$ )

## 15 - Normalisation par sigmoïde

Soit  $x$  un paramètre à valeurs dans  $X \subset \mathbb{R}$ .  $X$  est borné par  $x_{inf}$  et  $x_{sup}$  qui peuvent être fini ou non. Soit  $x_{min}$  sa valeur minimum sur une base de données. Soit  $x_{max}$  sa valeur max sur la base de données. On veut établir une projection de  $X$  dans  $[0, 1]$  tel que :

- ⇒ La projection rend une « quasi – droite » (très variable) entre  $x_{min}$  et  $x_{max}$
- ⇒ La projection « s'aplatit », converge rapidement, entre  $x_{inf}$  et  $x_{min}$  et entre  $x_{max}$  et  $x_{sup}$

La fonction sigmoïde est une candidate naturelle  $\pi_{sig}$ . On aura :

$$\pi_{sig}(x_{max}) = \delta \text{ avec } \delta \in ]0,5, 1[$$

$$\pi_{sig}(x_{min}) = 1 - \delta \text{ (sigmoïde centré au point milieu de } [x_{min}, x_{max}])$$

$\delta$  est un paramètre utilisateur et  $x_{min}$  et  $x_{max}$  sont connus. On cherche à déterminer les paramètres  $a, b$  de la fonction sigmoïde.

$$\begin{aligned}
\forall x \in X \quad \pi_{sig}(x) &= \frac{1}{1 + e^{-a_{sig}(x-b_{sig})}} \\
\Leftrightarrow (1 + e^{-a_{sig}(x-b_{sig})}) \pi_{sig}(x) &= 1 \\
\Leftrightarrow e^{-a_{sig}(x-b_{sig})} &= \frac{1 - \pi_{sig}(x)}{\pi_{sig}(x)} \\
\Leftrightarrow -a_{sig}(x - b_{sig}) &= \ln \left[ \frac{1 - \pi_{sig}(x)}{\pi_{sig}(x)} \right] \\
\Leftrightarrow (x - b_{sig}) &= -\frac{1}{a_{sig}} \ln \left[ \frac{1 - \pi_{sig}(x)}{\pi_{sig}(x)} \right] \\
\Leftrightarrow b_{sig} - x &= \frac{1}{a_{sig}} \ln \left[ \frac{1 - \pi_{sig}(x)}{\pi_{sig}(x)} \right] \\
\Leftrightarrow b_{sig} &= \frac{1}{a_{sig}} \ln \left[ \frac{1 - \pi_{sig}(x)}{\pi_{sig}(x)} \right] + x
\end{aligned}$$

On écrit cette équation en  $x_{min}$  et en  $x_{max}$  ce qui donne le système suivant :

$$\begin{cases}
b_{sig} = \frac{1}{a_{sig}} \ln \left[ \frac{\delta}{1-\delta} \right] + x_{min} \quad (E1) \\
b_{sig} = \frac{1}{a_{sig}} \ln \left[ \frac{1-\delta}{\delta} \right] + x_{max} \quad (E2)
\end{cases}$$

On fait (E2) – (E1) ce qui donne :

$$\begin{aligned}
(x_{max} - x_{min}) + \frac{1}{a_{sig}} \left[ \ln \left[ \frac{1-\delta}{\delta} \right] - \ln \left[ \frac{\delta}{1-\delta} \right] \right] &= 0 \\
\Leftrightarrow (x_{max} - x_{min}) + \frac{1}{a_{sig}} \left[ \ln \left[ \frac{1-\delta}{\delta} \right] + \ln \left[ \frac{1-\delta}{\delta} \right] \right] &= 0 \\
\Leftrightarrow (x_{max} - x_{min}) + \frac{2}{a_{sig}} \ln \left[ \frac{1-\delta}{\delta} \right] &= 0 \\
\Leftrightarrow \frac{2}{a_{sig}} \ln \left[ \frac{1-\delta}{\delta} \right] &= -(x_{max} - x_{min}) \\
\Leftrightarrow \frac{2}{a_{sig}} &= -\frac{(x_{max} - x_{min})}{\ln \left[ \frac{1-\delta}{\delta} \right]} \\
\Leftrightarrow a_{sig} &= -2 \frac{\ln \left[ \frac{1-\delta}{\delta} \right]}{(x_{max} - x_{min})}
\end{aligned}$$

On réinjecte  $a$  dans E1 ou E2 et on obtient  $b_{sig}$ .

$$b_{sig} = \frac{1}{a_{sig}} \ln \left[ \frac{\delta}{1-\delta} \right] + x_{min}$$

## 16 - Prédiction de signatures

### 16.1 - Test sur l'unité 2

Les résultats sont les suivants :

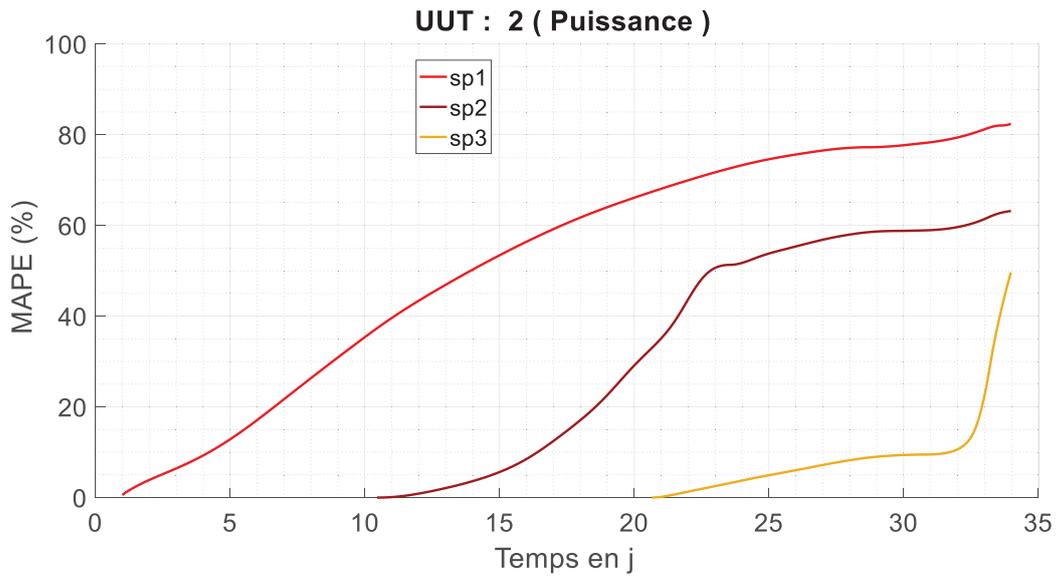


Figure VIII.19 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT2)

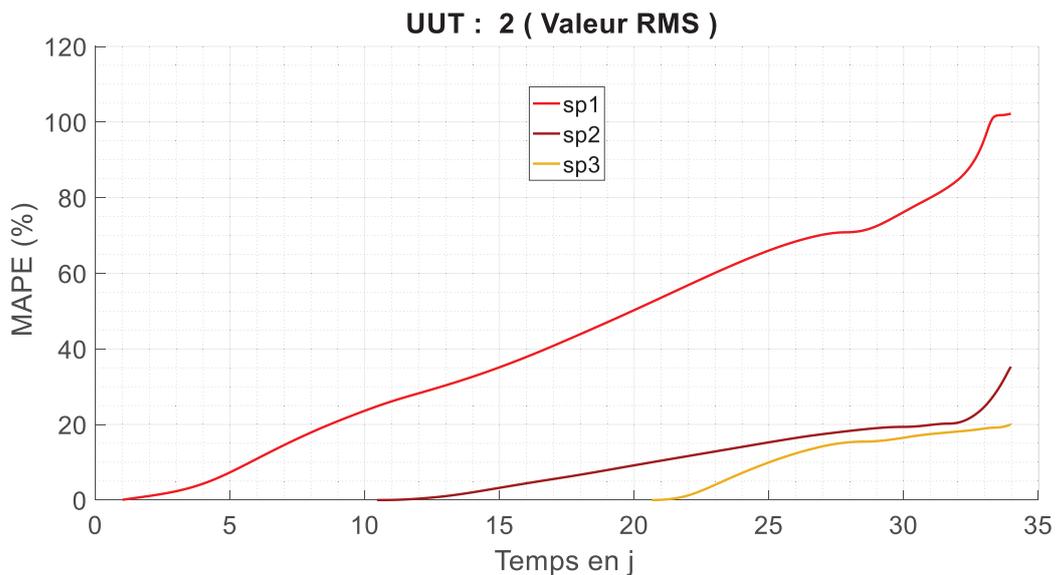


Figure VIII.20 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT2)

Pour cette unité l'erreur diminue très fortement lorsque le nombre d'observations de l'unité en test utilisées augmentent. Les erreurs sont dans les mêmes ordres de grandeurs que pour l'unité précédentes.

## 16.2 - Test sur unité 3

Les résultats sont les suivants :

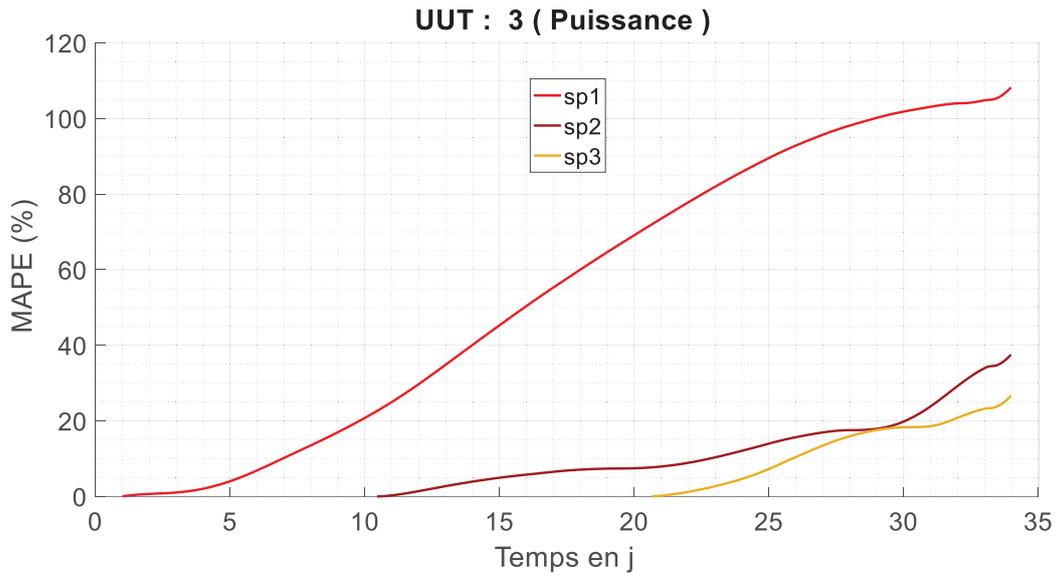


Figure VIII.21 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT3)

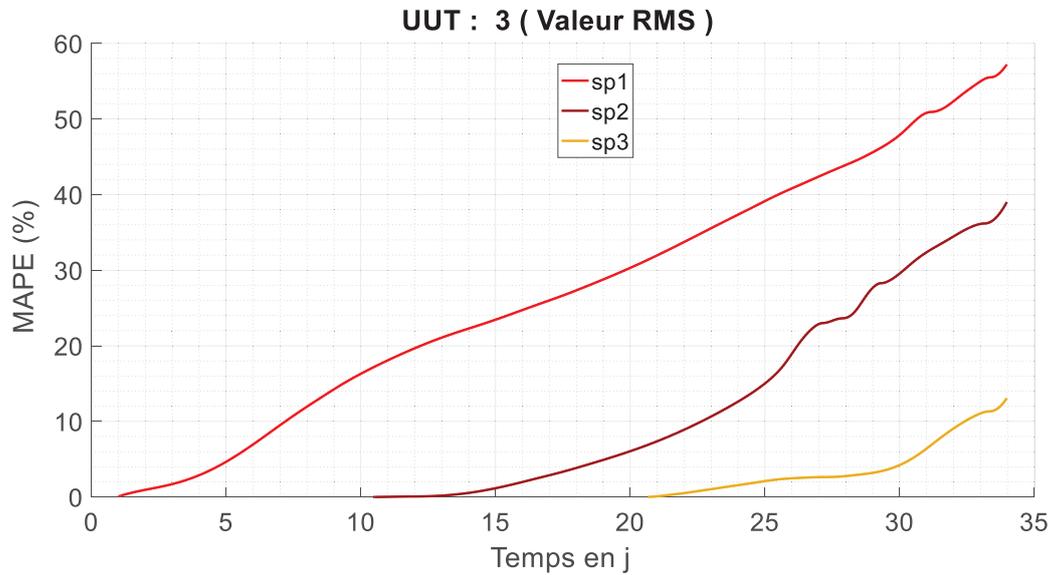


Figure VIII.22 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT3)

On retrouve les mêmes comportements que sur les unités précédentes.

## 16.3 - Test sur unité 4

Les résultats sont les suivants :

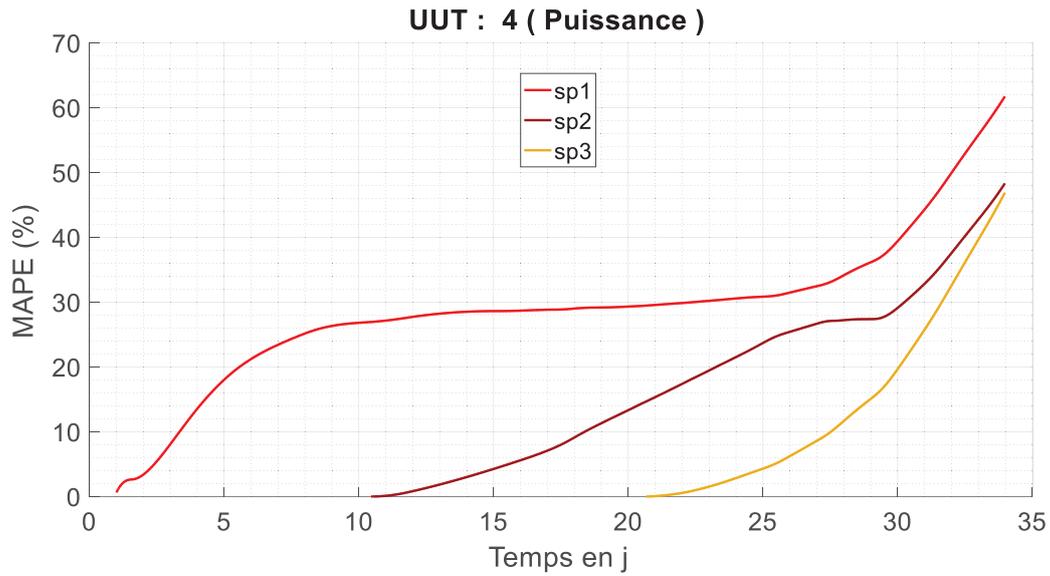


Figure VIII.23 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT4)

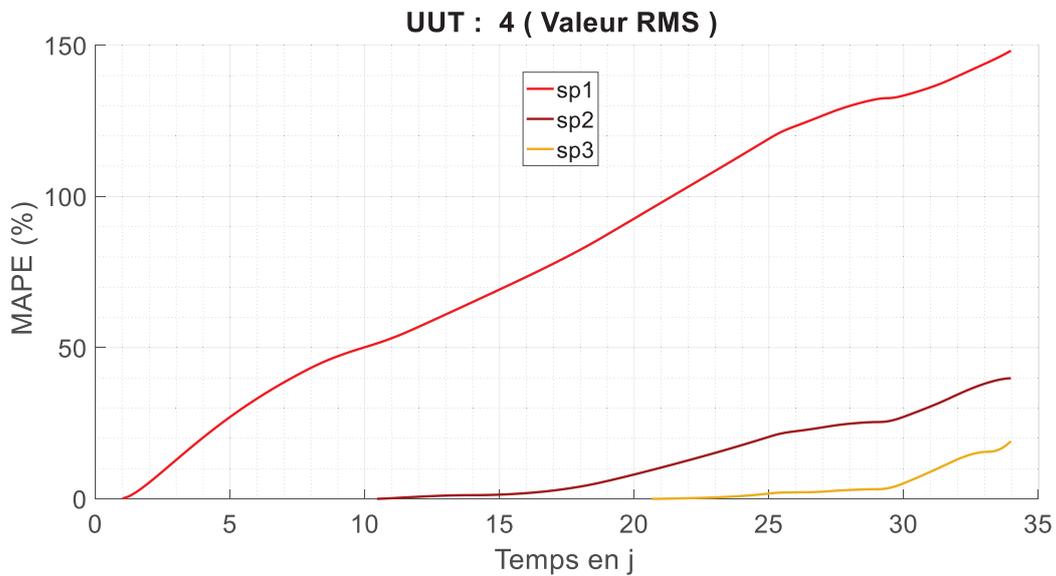


Figure VIII.24 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT4)

On notera l'importante erreur sur la prédiction *sp1* qui atteint les 100% peu après  $t = 20$  jours.

## 17 - Estimation de la RUL

Les courbes Figure VIII.25Figure VIII.27 permettent de déterminer l'horizon de pronostic pour les unités 2 à 4.

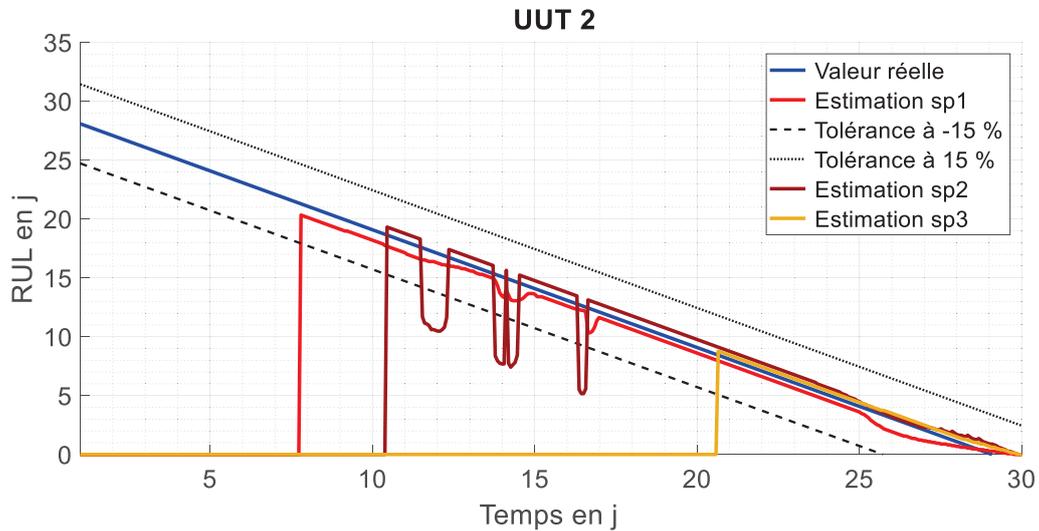


Figure VIII.25 : Estimation de la RUL pour l'unité 2 – Tolérance à 15% sur la RUL initiale

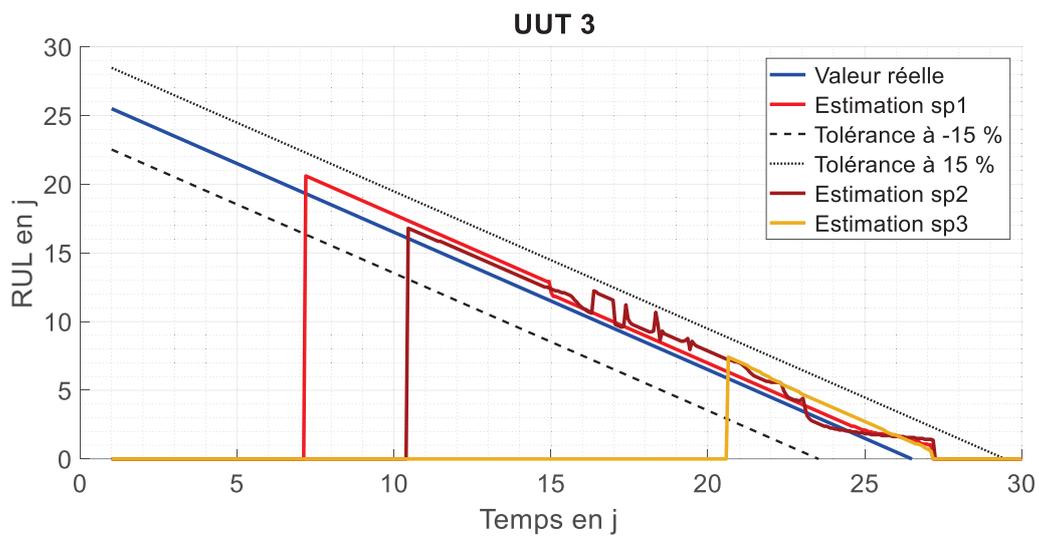


Figure VIII.26 : Estimation de la RUL pour l'unité 3 – Tolérance à 15% sur la RUL initiale

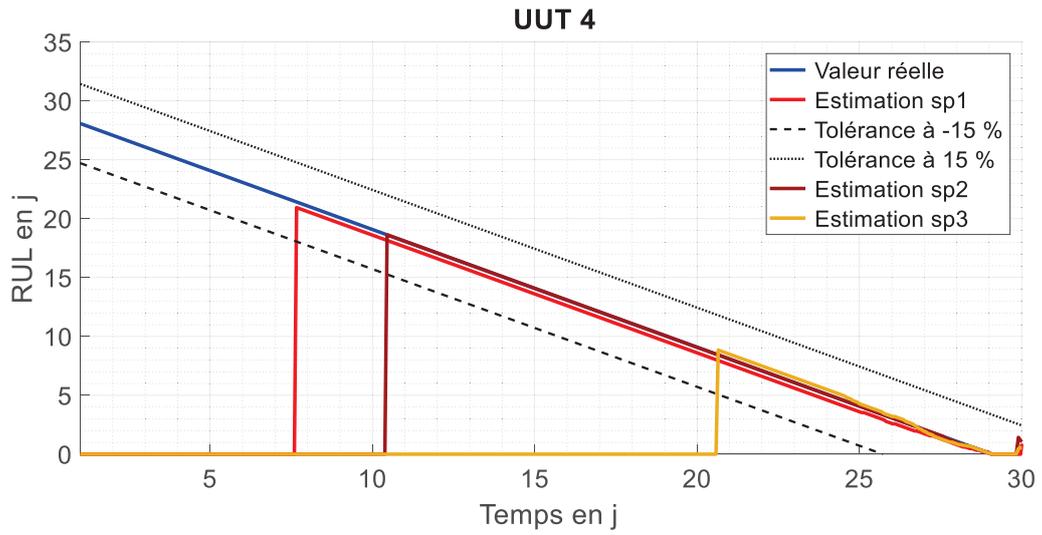


Figure VIII.27 : Estimation de la RUL pour l'unité 4 – Tolérance à 15% sur la RUL initiale

# Liste des Figures

Figure I.1 : Evolutions des émissions de CO <sub>2</sub> et facteurs clés de réduction (DGAC 2014) .....	18
Figure I.2 : Prévisions des émissions et de trafic jusqu'en 2035 (European Aviation Safety Agency et al. 2016).....	19
Figure I.3 : Evolution des besoins en puissance électrique (Roboam et al. 2012) .....	20
Figure I.4 : Surfaces de commande de vol et axes de l'avion (Delehelle 2008) .....	22
Figure I.5 : Manœuvre selon l'axe de roulis (Dupin 2009) .....	22
Figure I.6 : Manœuvre selon l'axe de tangage (Dupin 2009) .....	23
Figure I.7 : Manœuvre selon l'axe de lacet (Dupin 2009) .....	23
Figure I.8 : Système d'actionnement de commande de vol mécanique .....	24
Figure I.9 : Système d'actionnement de commande de vol hydromécanique (HA) .....	25
Figure I.10 : Système d'actionnement de commande de vol hydraulique (HA – Fly by Wire).....	25
Figure I.11 : Système d'actionnement de commande de vol hydroélectrique (EHA) .....	26
Figure I.12 : Système d'actionnement de commande de vol électromécanique (EMA).....	27
Figure I.13 : Architecture simplifiée d'implémentation de l'EMA Covadis dans l'aile de l'avion .....	28
Figure I.14 : EMA Covadis et ses principaux composants .....	28
Figure I.15 : Surface d'un solide .....	30
Figure I.16 : Roulement à rouleaux écaillé (SKF 1994) .....	31
Figure I.17 : Effets du grippage (Flamand et al. 2013) .....	31
Figure I.18 : Marques caractéristiques dues au passage de courants (Bishop 2017) .....	32
Figure I.19 : Exemple de polarisation d'un isolant sous champ constant (adapté de (Raju 2016)) .....	32
Figure I.20 : Couches possibles d'un fil émaillé (Mihaila 2011).....	33
Figure I.21 : Décharge partielle entre enroulements voisins d'un moteur alimenté par onduleur (Billard et al. 2014) .....	34
Figure I.22 : Nouvelle version du cycle PHM, avec rétroactions .....	36
Figure I.23 : Conception de fonctions HM.....	38
Figure I.24 : Utilisation de fonctions HM en opérations .....	39
Figure I.25 : Cycles de développement d'un système et cycle de développement d'un ensemble de fonctions HM pour ce même système (inspiré de (Lamoureux 2014) ).....	40
Figure II.1 : Schéma simplifié du modèle utilisé.....	46
Figure II.2 : Modèle de MSAP avec court – circuit inter - spires sur une phase (Leboeuf et al. 2010) .	48
Figure II.3 : Modélisation de la déformation et du jeu de la vis.....	49
Figure II.4 : Calcul de signatures à base de résidus des modèles.....	51
Figure II.5 : Calcul de signatures à base d'identification de paramètres du modèle .....	51
Figure II.6 : Exemple de FFT issue d'un signal vibratoire.....	53
Figure II.7 : Exemple de spectrogramme issue d'une transformé de Fourier à temps court sur un signal vibratoire.....	54
Figure II.8 : Architecture du processus de traitement .....	60
Figure II.9 : Principe de l'ICA (Gelle et al. 2001; Michaud 2016) .....	62
Figure II.10 : Effets des défauts VAR et CC sur le courant $I_q$ (simulation) .....	64
Figure II.11 : Composante représentative du défaut CC pour un défaut CC.....	64
Figure II.12 : Composante représentative du défaut VAR pour un défaut VAR.....	65
Figure II.13 : Distribution de la composante ICcc.....	65

Figure II.14 : Distribution de la composante ICvar .....	66
Figure II.15: Méthodologie pour obtenir les paramètres influents .....	67
Figure II.16: Méthodologie pour le calcul des NKPI des signatures .....	68
Figure II.17 : Profil de caractérisation .....	69
Figure III.1 : Principe de la RDF pour le diagnostic .....	77
Figure III.2 : Exemple d'arbre de décision pour le diagnostic ( $x_1..3$ : signatures).....	79
Figure III.3 : Représentation d'un neurone artificiel .....	79
Figure III.4 : Taxonomie non exhaustive des réseaux de neurones (adaptée de (Jain et al. 1996) ) ....	80
Figure III.5 : Illustration d'un réseau bayésien naïf ( $c$ : classe, $x_1..3$ : signatures) (Barber 2012).....	81
Figure III.6 : Exemple de projection dans un espace de dimension supérieure.....	82
Figure III.7 : Illustration de l'application de la SVM pour un cas binaire linéaire séparable .....	85
Figure III.8 : Illustration de l'application de la SVM pour un cas binaire linéaire non séparable.....	87
Figure III.9 : Algorithme "One Vs All" pour $c = 4$ .....	89
Figure III.10 : Algorithme "One Vs One" pour $c = 4$ .....	91
Figure III.11 : Algorithme "One To Others" pour $c = 4$ .....	92
Figure III.12 : Apprentissage pour la SVM avec fonctions d'appartenances .....	96
Figure III.13 : Test pour la SVM avec fonctions d'appartenance.....	96
Figure III.14 : FA sigmoïdale liée à une SVM binaire (phase de test) .....	96
Figure III.15 : Base artificielle pour illustration des méthodes OVA et OVO .....	97
Figure III.16 : Base artificielle pour illustration des méthodes OTO.....	98
Figure III.17 : Cartographie de décision.....	110
Figure III.18 : Echelle de sévérité.....	110
Figure III.19 : Méthodologie de réglage d'un modèle SVM avec un critère d'erreur .....	111
Figure III.20 : Méthodologie de réglage d'un modèle SVM-FA .....	112
Figure III.21 : Méthode « K Fold Out » pour $K = 4$ .....	113
Figure III.22 : Architecture de l'algorithme de diagnostic proposé.....	113
Figure IV.1 : Banc ELAM.....	117
Figure IV.2 : Banc d'essai pour un MSAP en défaut de court – circuit - Schéma (Leboeuf 2012) .....	118
Figure IV.3 : Banc d'essai pour un MSAP en défaut de court – circuit - Photo (Leboeuf 2012).....	119
Figure IV.4 : Banc machine asynchrone – Photo (Soualhi 2013).....	120
Figure IV.5 : Emulation des défauts de barres cassées .....	120
Figure IV.6 : Profil d'acquisition pour le calcul de signatures.....	121
Figure IV.7 : Identification du couple de frottements sur données expérimentales, profil non opérationnel.....	121
Figure IV.8 : Convergence de l'algorithme d'identification sur profil non opérationnel .....	122
Figure IV.9 : Identification du couple de frottements sur données expérimentales, profil non opérationnel moyenné.....	123
Figure IV.10 : Convergence de l'algorithme d'identification sur profil non opérationnel moyenné ..	123
Figure IV.11: Signal "Scc" caractéristique du défaut de court - circuit.....	124
Figure IV.12 : Signal "Svar" caractéristique du défaut d'usure de la vis à rouleaux.....	124
Figure IV.13: Critère de sélection de paramètres - Première base machine asynchrone.....	127
Figure IV.14 : Critère de sélection de paramètres - Deuxième base machine asynchrone .....	127
Figure IV.15 : Echelle de sévérité pour le paramètre $Rf$ .....	133
Figure IV.16 : Critère de sélection de paramètres – Première base machine synchrone à aimants ..	134

Figure IV.17 : Critère de sélection de paramètres – Deuxième base machine synchrone à aimants .	134
Figure V.1 : Méthode de représentation des incertitudes VS informations disponibles et quantités d'incertitudes (adapté de : (Nikolaidis et al. 2010))	147
Figure V.2 : Différentes sources d'incertitudes (Sankararaman et Goebel 2015)	147
Figure V.3 : Schéma de principe d'un pronostic hybride série	149
Figure V.4 : Schéma de principe d'un pronostic hybride parallèle	150
Figure V.5 : Illustration d'une prédiction itérative	151
Figure V.6 : Illustration d'un ensemble de prédictions directes, à plusieurs horizons	151
Figure V.7 : Illustration d'une prédiction parallèle	152
Figure V.8 : Métriques d'évaluation du pronostic pour la définition des exigences et la comparaison des performances (adapté de (Saxena et al. 2010))	152
Figure V.9 : Métriques de performance successives pour le pronostic hors - ligne (issu de (Saxena et al. 2010))	153
Figure V.10 : Horizon de pronostic : (a) comparaison de deux algorithmes selon le critère $\alpha e$ à partir des moyennes des distributions (b) : Evaluation d'un algorithme selon les critères $\alpha e$ et $\beta e$ à partir des distributions (Saxena et al. 2010)	154
Figure V.11 : RUL vs Temps avec cône d'exactitude (Saxena et al. 2010)	155
Figure V.12 : Démarche proposée pour la phase de développement (apprentissage) d'une solution permettant d'estimer la RUL	156
Figure V.13 : Démarche proposée pour l'exploitation (test) des modèles	157
Figure V.14 : Banc de vieillissements des roulements (Soualhi 2013)	158
Figure V.15 : Valeur efficace du signal vibratoire en fonction du temps	158
Figure V.16 : Puissance du signal vibratoire en fonction du temps	159
Figure V.17 : Cohérence temporelle globale pour différents algorithmes	162
Figure V.18 : Energie en fonction du nombre de classes	163
Figure V.19 : Exemple de partitionnement incohérent (k - Moyennes avec $c = 8$ )	163
Figure V.20 : Critère d'énergie en fonction du nombre de classes sur la base IMS	164
Figure V.21 : Puissance du signal vibratoire en fonction du temps - observations partitionnées ( $c=4$ )	164
Figure V.22 : Valeur efficace du signal vibratoire en fonction du temps – observations partitionnées ( $c=4$ )	165
Figure V.23 : Evolution des appartenances en fonction du temps (Apprentissage – OVA – $c = 3$ )	167
Figure V.24 : Evolution des appartenances en fonction du temps (Test – OVA – $c = 3$ )	167
Figure V.25 : Evolution des appartenances en fonction du temps (Apprentissage – OTO – FA sigmoïdale – $c = 3$ )	169
Figure V.26 : Evolution des appartenances en fonction du temps (Test – OTO – FA sigmoïdale – $c = 3$ )	169
Figure V.27 : Fonction perte pour SVR linéaire à marges souples (Smola et Schölkopf 2004)	173
Figure V.28 : Prédiction de la puissance du signal vibratoire (UUT1)	175
Figure V.29 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT1)	175
Figure V.30 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT1)	176
Figure V.31 : Appartenances estimées sur UUT4 à partir des prédictions du modèle $sp2$ à $t = 10, 45$	

jour .....	176
Figure V.32 : Appartenances estimées sur UUT3 à partir des prédictions du modèle <i>sp2</i> à $t = 10,45$ jour .....	177
Figure V.33 : Appartenances estimées à partir des prédictions du modèle <i>sp3</i> à $t = 20,65$ jour (UUT 2).....	177
Figure V.34 : Estimation de la RUL pour l'unité 1 – Tolérance à 15% sur la RUL initiale .....	179
Figure V.35 : Estimation de la RUL pour l'unité 1 – Tolérance à 15% sur la RUL à l'instant $t$ .....	179
Figure V.36 : Estimation de la RUL pour l'unité 2 – Tolérance à 15% sur la RUL à l'instant $t$ .....	180
Figure V.37 : Estimation de la RUL pour l'unité 3 – Tolérance à 15% sur RUL à l'instant $t$ .....	180
Figure V.38 : Estimation de la RUL pour l'unité 4 – Tolérance à 15% sur RUL à l'instant $t$ .....	181
Figure VIII.1 : Exemple de courbe ROC.....	217
Figure VIII.2 : FA complémentaires trapézoïdales issues d'une SVM binaire .....	221
Figure VIII.3 : FA complémentaires sigmoïdales issues d'une SVM binaire .....	222
Figure VIII.4 : FA complémentaires polynomiales issues d'une SVM binaire.....	225
Figure VIII.5 : Cartographie de la T-norme minimum.....	225
Figure VIII.6 : Cartographie de la T-conorme maximum .....	226
Figure VIII.7 : Cartographie de la T-norme probabiliste .....	226
Figure VIII.8 : Cartographie de la T-conorme probabiliste .....	227
Figure VIII.9 : Cartographie de la T-norme de Lukasiewicz .....	227
Figure VIII.10 : Cartographie de la T-conorme de Lukasiewicz .....	228
Figure VIII.11 : Cartographie de la T-norme d'Einstein .....	228
Figure VIII.12 : Cartographie de la T- conorme d'Einstein.....	229
Figure VIII.13 : Exemple d'évolution de critère en fonction du nombre de paramètres .....	233
Figure VIII.14 : Comparaison des convergences de trois algorithmes selon une métrique $M$ (Saxena et al. 2009b).....	234
Figure VIII.15 : Puissance du signal vibratoire en fonction du temps - observations partitionnées ( $c=3$ ) .....	237
Figure VIII.16 : Valeur efficace du signal vibratoire en fonction du temps – observations partitionnées ( $c=3$ ) .....	237
Figure VIII.17 : Puissance du signal vibratoire en fonction du temps - observations partitionnées ( $c=5$ ) .....	238
Figure VIII.18 : Valeur efficace du signal vibratoire en fonction du temps – observations partitionnées ( $c=5$ ) .....	238
Figure VIII.19 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT2).....	241
Figure VIII.20 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT2).....	241
Figure VIII.21 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT3).....	242
Figure VIII.22 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal vibratoire (UUT3).....	242
Figure VIII.23 : Erreur absolue moyenne relative pour la prédiction de la puissance du signal vibratoire (UUT4).....	243
Figure VIII.24 : Erreur absolue moyenne relative pour la prédiction de la valeur efficace du signal	

vibratoire (UUT4).....	243
Figure VIII.25 : Estimation de la RUL pour l'unité 2 – Tolérance à 15% sur la RUL initiale .....	244
Figure VIII.26 : Estimation de la RUL pour l'unité 3 – Tolérance à 15% sur la RUL initiale .....	244
Figure VIII.27 : Estimation de la RUL pour l'unité 4 – Tolérance à 15% sur la RUL initiale .....	245

# Liste des Tableaux

Tableau I.1 : Etat et évolution prévue de la flotte mondiale (Boeing 2016) .....	19
Tableau I.2 : Principales fonctions non propulsives dans l'aéronautique civile (Wheeler 2014).....	21
Tableau I.3 : Défauts de l'EMA considérés .....	30
Tableau II.1: Cinq meilleurs détectabilités pour le défaut CC .....	71
Tableau II.2 : Cinq meilleurs détectabilités pour le défaut VAR.....	71
Tableau II.3 : Identifiabilité des sévérités des défauts CC et VAR (en %) .....	71
Tableau II.4 : Identifiabilité des sévérités du défaut combiné (en %).....	72
Tableau III.1: Exemples de fonctions noyaux .....	82
Tableau III.2: Exemples de normes triangulaires .....	94
Tableau III.3 : Intervalles de valeurs des paramètres des classes générées .....	97
Tableau III.4 : Intervalles de valeurs des paramètres des classes générées .....	98
Tableau III.5 : Paramètres pour l'apprentissage de la SVM-FA "One vs All" sur base artificielle.....	99
Tableau III.6 : SVM - FA "One vs All" : Exemple de modèles entraînés sur base artificielle.....	99
Tableau III.7 : Valeurs de <i>Uclass</i> et <i>Uall</i> pour $i = 1$ .....	99
Tableau III.8 : Valeurs de <i>Uclass</i> et <i>Uall</i> pour $i = 2$ .....	100
<b>Tableau III.9 : Valeurs de <i>Uclass</i> et <i>Uall</i> pour <math>i = 3</math> .....</b>	<b>100</b>
<b>Tableau III.10 : Valeur de <i>Uothers</i> pour la SVM-FA "One vs All" sur base artificielle .....</b>	<b>100</b>
Tableau III.11 : SVM-FA "One vs One" : Exemple de modèles entraînés sur base artificielle.....	101
<b>Tableau III.12 : Valeurs des <i>Uclass_k</i> pour <math>i = 1</math> .....</b>	<b>102</b>
<b>Tableau III.13 : Valeurs des <i>Uclass_k</i> pour <math>i = 2</math> .....</b>	<b>102</b>
<b>Tableau III.14 : Valeurs des <i>Uclass_k</i> pour <math>i = 3</math> .....</b>	<b>102</b>
Tableau III.15 : Valeur de <i>Uclass</i> calculée à partir des <i>Uclass_k</i> .....	102
Tableau III.16 : Valeur de <i>Urel</i> calculée à partir de <i>Uclass</i> .....	103
Tableau III.17 : Valeur de <i>Uothers</i> pour la SVM-FA "One vs One" sur base artificielle.....	103
Tableau III.18 : SVM-FA "One to Others" : Exemple de modèles entraînés sur base artificielle .....	105
Tableau III.19 : Valeurs de <i>Uc</i> + et de <i>Urest</i> (itération 1) .....	105
Tableau III.20 : Valeurs de <i>Uc</i> + et de <i>Urest</i> (itération 2) .....	105
Tableau III.21 : Valeurs de <i>Uc</i> + et de <i>Urest</i> (itération 3) .....	106
<b>Tableau III.22 : Valeurs de <i>U</i> calculées à partir de <i>Uc</i> + et <i>Urest</i> et valeurs de <i>Uclass</i> (itération 1)</b> .....	<b>106</b>
<b>Tableau III.23 : Valeurs de <i>U</i> calculées à partir de <i>Uc</i> + et <i>Urest</i> et valeurs de <i>Uclass</i> (itération 2)</b> .....	<b>107</b>
<b>Tableau III.24 : Valeurs de <i>U</i> calculées à partir de <i>Uc</i> + et <i>Urest</i> et valeurs de <i>Uclass</i> (itération 3)</b> .....	<b>107</b>
<b>Tableau III.25 : Valeurs finales de <i>Uclass</i>.....</b>	<b>107</b>
<b>Tableau III.26 : Valeur de <i>Urel</i> calculée à partir de <i>Uclass</i> .....</b>	<b>108</b>
<b>Tableau III.27 : Valeur de <i>Uothers</i> calculée à partir de <i>Urel</i>.....</b>	<b>108</b>
Tableau III.28 : Notations pour les méthodologies de réglages.....	111
Tableau IV.1: Valeurs des paramètres variants dans le cadre des essais MSAP .....	118
Tableau IV.2 : Modes de fonctionnement étudiés via le banc machine asynchrone .....	119
Tableau IV.3 : Première base de données issue du banc machine asynchrone.....	126
Tableau IV.4 : Deuxième base de données issue du banc machine asynchrone .....	126

Tableau IV.5 : Précision sur la première base « pauvre » issue des essais machine asynchrone .....	128
Tableau IV.6 : Matrice de confusion pour l’algorithme SVM – FA (première base « pauvre » machine asynchrone) .....	128
Tableau IV.7 : Résultats règle de décision (première base « pauvre » machine asynchrone).....	128
Tableau IV.8 : Précision sur la deuxième base « pauvre » issue des essais machine asynchrone .....	128
Tableau IV.9 : Matrice de confusion pour l’algorithme SVM – FA (deuxième base « pauvre » machine asynchrone) .....	129
Tableau IV.10 : Résultats règle de décision (deuxième base « pauvre » machine asynchrone).....	129
Tableau IV.11 : Temps de calculs pour la phase de test (première base « pauvre » machine asynchrone) .....	129
Tableau IV.12 : Temps de calculs pour la phase de test (deuxième base « pauvre » machine asynchrone) .....	129
Tableau IV.13 : Mémoire de stockage sur la première base « pauvre » machine asynchrone .....	130
Tableau IV.14 : Mémoire de stockage sur la deuxième base ‘pauvre » machine asynchrone .....	130
Tableau IV.15 : Précision sur la première base « riche » issue des essais machine asynchrone .....	130
Tableau IV.16 : Matrice de confusion pour l’algorithme SVM – FA (première base « riche » machine asynchrone) .....	131
Tableau IV.17 : Résultats règle de décision (première base « riche » machine asynchrone).....	131
Tableau IV.18 : Précision sur la deuxième base « riche » issue des essais machine asynchrone .....	131
Tableau IV.19 : Matrice de confusion pour l’algorithme SVM – FA (seconde base « riche » machine asynchrone) .....	131
Tableau IV.20 : Résultats règle de décision (deuxième base « riche » machine asynchrone).....	131
Tableau IV.21 : Temps de calculs pour la phase de test (première base « riche » machine asynchrone) .....	132
Tableau IV.22 : Temps de calculs pour la phase de test (seconde base « riche » machine asynchrone) .....	132
Tableau IV.23 : Mémoire de stockage (première base « riche » machine asynchrone).....	132
Tableau IV.24 : Mémoire de stockage (seconde base « riche » machine asynchrone) .....	132
Tableau IV.25 : Base de données issue du banc MSAP .....	133
Tableau IV.26 : Précision sur la première base « pauvre » issue des essais MSAP .....	135
Tableau IV.27 : Matrice de confusion l’algorithme SVM – FA (première base « pauvre » MSAP).....	135
Tableau IV.28 : Précision sur la deuxième base « pauvre » issue des essais MSAP .....	135
Tableau IV.29 : Matrice de confusion l’algorithme SVM – FA (deuxième base « pauvre » MSAP) ....	135
Tableau IV.30 : Estimation de la sévérité <b>Rf</b> pour la base « pauvre » .....	135
Tableau IV.31 : Temps de calculs pour la base « pauvre».....	136
Tableau IV.32 : Mémoire de stockage sur les bases « pauvre » issue des essais MSAP .....	136
Tableau IV.33 : Précision sur la première base « riche » issue des essais MSAP .....	136
Tableau IV.34 : Matrice de confusion l’algorithme SVM – FA (première base « riche » MSAP).....	137
Tableau IV.35 : Précision sur la deuxième base « riche » issue des essais MSAP .....	137
Tableau IV.36 : Matrice de confusion l’algorithme SVM – FA (deuxième base « riche » MSAP).....	137
Tableau IV.37 : Estimation de la sévérité <b>Rf</b> pour la base « riche ».....	137
Tableau IV.38 : Temps de calculs pour la base « riche » .....	138
Tableau IV.39 : Mémoire de stockage sur les bases « riche » issue des essais MSAP .....	138
Tableau IV.40: Mémoires de références pour l'estimation de la mémoire nécessaire au stockage du	

modèle de diagnostic proposé.....	140
Tableau IV.41 : Mémoires nécessaires des blocs élémentaires de l’algorithme de diagnostic proposé .....	140
Tableau V.1 : Temps de fin de vie des roulements déterminés par « expert » selon différents critères .....	159
Tableau V.2 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert ( $c = 4$ ) .	165
Tableau V.3: Résultats de classification de la méthode "OVA" .....	166
Tableau V.4: Résultats de classification de la méthode "OVO" .....	168
Tableau V.5: Résultats de classification de la méthode "OTO".....	168
Tableau V.6 : Meilleure méthode en fonction du nombre de classes .....	170
Tableau V.7 : Nombre de classe maximisant la précision moyenne par méthode multi – classes.....	170
Tableau V.8 : Résultats en termes de précisions (%) de classification en validation croisée pour différentes techniques de normalisation .....	171
Tableau V.9 : Performances en validation croisée (SVM - FA "One Vs All") .....	172
Tableau V.10 : Performances en validation croisée (SVM - FA "One Vs One").....	172
Tableau V.11 : Performances du modèle <i>sp1</i> .....	181
Tableau V.12 : Performances du modèle <i>sp2</i> .....	182
Tableau V.13 : Performances du modèle <i>sp3</i> .....	182
Tableau V.14 : Mémoire nécessaire des blocs élémentaires de l’algorithme de diagnostic proposé	183
Tableau V.15 : Mémoires nécessaires des blocs élémentaires de l’algorithme d’estimation de la RUL .....	183
Tableau VIII.1 : Exemple de grille obtenue par échantillonnage par Hyper cube Latin .....	215
Tableau VIII.2 : Tableau de répartitions des points classifiés.....	216
Tableau VIII.3 : Détectabilité signatures 1 à 6.....	218
Tableau VIII.4 : Détectabilité signatures 7 à 12.....	219
Tableau VIII.5 : Détectabilité signatures 13 à 18.....	219
Tableau VIII.6 : Détectabilité signatures 19 à 21.....	219
Tableau VIII.7 : Caractéristiques de la machine asynchrone (Soualhi 2013).....	229
Tableau VIII.8 : Caractéristiques de la MSAP (Leboeuf 2012) .....	230
Tableau VIII.9: Classification des métriques par niveau de décision dans le cadre aéronautique (Basé sur : (Saxena et al. 2008, 2010; Wheeler et al. 2009)) .....	233
Tableau VIII.10 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert ( $c = 3$ ) .....	239
Tableau VIII.11 : Ecart sur les temps de fin de vie estimés par partitionnement et par expert ( $c = 5$ ) .....	239