

Evaluation et optimisation des performances de fonctions pour la surveillance de turboréacteurs Ouadie Hmad

▶ To cite this version:

Ouadie Hmad. Evaluation et optimisation des performances de fonctions pour la surveillance de turboréacteurs. Mécanique des structures [physics.class-ph]. Université de Technologie de Troyes, 2013. Français. NNT: 2013TROY0029. tel-03355280

HAL Id: tel-03355280 https://theses.hal.science/tel-03355280

Submitted on 27 Sep 2021

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.

Thèse de doctorat de l'UTT

Ouadie HMAD

Evaluation et optimisation des performances de fonctions pour la surveillance de turboréacteurs

Spécialité : Optimisation et Sûreté des Systèmes

2013TROY0029

Année 2013



THESE

pour l'obtention du grade de

DOCTEUR de l'UNIVERSITE DE TECHNOLOGIE DE TROYES Spécialité : OPTIMISATION ET SURETE DES SYSTEMES

présentée et soutenue par

Ouadie HMAD

le 6 décembre 2013

Evaluation et optimisation des performances de fonctions pour la surveillance de turboréacteurs

JURY

M. R. TOSCANO	PROFESSEUR DES UNIVERSITES	Président
M. P. BEAUSEROY	PROFESSEUR DES UNIVERSITES	Directeur de thèse
Mme É. GRALL	MAITRE DE CONFERENCES	Directrice de thèse
Mme A. MATHEVET	DOCTEUR EXPERT	Examinateur
Mme D. NUZILLARD	PROFESSEUR DES UNIVERSITES	Rapporteur
M. N. ZERHOUNI	PROFESSEUR DES UNIVERSITES	Rapporteur

Personnalité invitée

M. J.-R. MASSE DOCTEUR EXPERT

A ma famille, A tous ceux qui m'ont soutenu, me soutiennent et me soutiendront.

REMERCIEMENTS

Les remerciements présentent l'aboutissement d'un long parcours et le franchissement d'une nouvelle étape vers de nouvelles aventures. C'est donc avec grand plaisir que je remercie tous ceux qui m'ont permis d'arriver là où je suis aujourd'hui. J'adresse plus particulièrement mes remerciements à :

Agnès MATHEVET, Expert sûreté de fonctionnement et chef du département Qualité Programme et Sûreté de fonctionnement chez Safran Engineering Services, pour m'avoir accueilli dans son département, avoir cru en cette thèse et pour ses qualités humaines qui ont permis le bon déroulement de la thèse au cours de ces trois dernières années.

Edith GRALL-MAËS, maître de conférences à l'Université de Technologie de Troyes, pour son expertise fine et son sens du détail qu'elle a su me transmettre en tant que directrice de thèse.

Jean-Rémi MASSE, Systems Reliability - Prognostics and Health Monitoring senior Expert chez Safran Snecma, pour m'avoir fait confiance dans cette aventure, pour son professionnalisme, son savoir faire et son savoir vivre.

Pierre BEAUSEROY, professeur des universités à l'Université de Technologie de Troyes, pour ses conseils, son expertise et l'esprit d'analyse dont il a fait preuve en tant que directeur de thèse.

Agnès, Edith, Jean-Rémi et Pierre ont su former l'équipe parfaite pour le bon déroulement de cette thèse sur le plan professionnel et personnel. Ces remerciements ne représentent qu'une expression concentrée de la reconnaissance que j'ai envers eux.

Je tiens également à remercier Danielle NUZILLARD, professeur des universités à l'université de Reims, et Noureddine ZERHOUNI, professeur des universités à l'Ecole Nationale Supérieure de Mécanique et des Microtechniques de Besançon, pour avoir accepté d'être rapporteurs de ma thèse et pour leur travail d'analyse.

Merci à Rosario TOSCANO, professeur des universités à l'École Nationale d'Ingénieurs de Saint-Etienne, pour son expertise et la présidence de mon jury de thèse.

Je souhaite également remercier Aurore HUMEAU, statisticienne chez Safran Engineering Service, pour son aide et son soutien tout au long de la rédaction de ce manuscrit.

SOMMAIRE

T/	TABLE DES FIGURES		
ТÆ	BLE DI	ES TABLEAUX	11
IN	TRODU	UCTION GENERALE	13
I	FOI	NCTIONS DE SURVEILLANCE CONSIDEREES	15
	I.1 I	INTRODUCTION	15
	1.2 L	LES TURBOREACTEURS	15
	1.3 F	PRONOSTIC ET SURVEILLANCE DE L'ETAT DE SANTE DE SYSTEMES	16
	I.4 S	Systemes de Surveillance developpes par Snecma	18
	1.5 F	Perimetre de l'etude	19
	1.6 5	Surveillance de la sequence de demarrage	20
	1.6.2	1 Description	20
	1.6.2	2 Causes de non démarrage	23
	1.6.	3 Données disponibles	
	1.7 5	SURVEILLANCE DE LA CONSOMMATION D'HUILE	25
	1.7.	1 Description	
	1.7.2	2 Causes de consommations anormales	
	1.7.	3 Données disponibles	29
	1.8 0	Conclusion	30
II	PER	RFORMANCES DE DETECTION ET DE PRONOSTIC	31
	II.1	INTRODUCTION	31
	II.2	Exigences de performance	31
	II.3	DETECTION	33
	11.3.	.1 Indicateurs de performances	33
	11.3.	.2 Méthodes d'estimation	35
	11.3.	.3 Distribution de la statistique de décision	
	11.3.	.4 Simulation des dégradations prémices de non démarrage	62
	11.3.	.5 Conclusion	68
	11.4	Pronostic	69
	11.4.	.1 Introduction	69
	11.4.	.2 Indicateurs de performances	69
	11.4.	.3 Modèles de dégradation	73
	11.4.	.4 Méthode d'estimation	77
	II.5		81
ш	EST	TIMATION ET AMELIORATION DES PERFORMANCES	82
	III.1	INTRODUCTION	82
	111.2	DETECTION DE PREMICES DE NON DEMARRAGE	82

III.2.1	Introduction	82
III.2.2	Approche moyenne mobile	82
III.2.3	Approche k parmi n	93
111.2.4	Comparaison des deux approches	. 102
III.2.5	Conclusion	. 103
III.3 Prom	NOSTIC DE CONSOMMATIONS ANORMALES	. 104
III.3.1	Introduction	. 104
III.3.2	Principe	. 104
III.3.3	Données	. 105
III.3.4	Estimation des performances	. 106
III.3.5	Analyse et amélioration des performances	. 108
III.3.6	Conclusion	. 110
III.4 CON	CLUSION	. 111
BILAN & PERSP	ECTIVES	. 112
REFERENCES		. 114
PRODUITS DE I	A THESE	. 121
ANNEXES		. 122
ANNEXE - 1	LE TURBOREACTEUR CFM56-7B	. 123
1. LE SYSTE	ME DE REGULATION	. 124
2. LE CIRCU	JIT CARBURANT	. 125
3. LE CIRCU	JIT D'HUILE	. 127
4. LE SYSTE	ME DE DEMARRAGE ET D'ALLUMAGE	. 128
ANNEXE - 2	DESCRIPTION DE L'ECHELLE TRL	. 130
ANNEXE - 3	PROCEDURE DE MATURATION	. 132
ANNEXE - 4	METHODES DE DIAGNOSTIC ET DE PRONOSTIC	. 135
1. INTRODU	JCTION	. 135
2. TERMIN	OLOGIE	. 135
3. Metho	DES DE DIAGNOSTIC	. 136
3.1. CLAS	SIFICATION DES METHODES, POINT DE VUE N° 1	. 136
3.1.1. N	IETHODES INTERNES	. 136
3.1.2. N	IETHODES EXTERNES	. 137
3.1.3. N	1ethodes inductives	. 137
3.1.4. N	IETHODES DEDUCTIVES	. 138
3.2. CLAS	SIFICATION DES METHODES, POINT DE VUE N° 2	. 138
3.2.1. N	IETHODES BASEES SUR DES MODELES QUANTITATIFS	. 138
3.2.2. N	IETHODES BASEES SUR DES MODELES QUALITATIFS	. 138
3.2.3. N	IETHODES BASEES SUR DES DONNEES HISTORIQUES	. 139
4. Metho	DES DE PRONOSTIC	. 141

4.1.	CLASSIFICATION DES METHODES	141
4.2.	APPROCHES BASEES SUR L'EXPERIENCE	143
4.3.	Approches basees sur les donnees	143
4.4.	APPROCHES BASEES SUR LES MODELES	144
ANNEX L'ENSE (AVEC I	KE - 5 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION SUR MBLE DES MOTEURS, DISTRIBUTION DES SCORES D'ANORMALITE MOYENNE SUR N = 5 DEMARRAG ET SANS DEGRADATION)	ES 145
1.	DEGRADATIONS DU COMPRESSEUR D'AIR	145
2.	DEGRADATIONS DU BLOC HYDROMECANIQUE	145
ANNEX MEME (AVEC	KE - 6 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION SUR L TYPE DE MOTEUR, DISTRIBUTION DES SCORES D'ANORMALITE MOYENNE SUR N = 5 DEMARRAGES ET SANS DEGRADATION)	JN 147
1.	Degradations du compresseur d'Air	147
2.	DEGRADATIONS DU BLOC HYDROMECANIQUE	147
ANNEX MOTEL	XE - 7 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION PAR JR, RESULTATS POUR N = 5 2	149
1.	Moteur 1	149
2.	Moteur 2	149
3.	Moteur 3	150
4.	Moteur 4	150
5.	Moteur 5	151
6.	Moteur 6	151
7.	Moteur 7	152
8.	Moteur 8	152
9.	Moteur 9	153
10.	Moteur 10	153
	E - 8 APPROCHE K PARMI N, APPRENTISSAGE DES MODELES DE NORMALISATION PAR MOTEUR	., 1 г л
1	MOTEUR 1	1 54
1. 2		154
2. 2		155
3. 4	MOTEUR 4	155
5.	MOTEUR 5	156
6.	Мотеия 6	156
7.	Мотеur 7	157
8.	Мотеик 8	157
9.	Moteur 9	158
10.	Moteur 10	158
ANNEX	E - 9 PRONOSTIC DE CONSOMMATIONS ANORMALES, DONNEES ET RESULTATS	159
1.	Moteur 1 avion 1	159

CONFIDENTIEL INDUSTRIE

2.	MOTEUR 2 AVION 1	159
3.	Moteur 1 avion 2	160
4.	Moteur 2 avion 2	160
5.	Moteur 1 avion 3	161
6.	Moteur 2 avion 3	161
7.	Moteur 2 avion 4	162
8.	Moteur 2 avion 5	162

TABLE DES FIGURES

Figure 1 : Schéma de principe d'un turboréacteur 15
Figure 2 : Principe des turboréacteurs à double flux 16
Figure 3 : Blocs fonctionnels de l'architecture OSA- CBM [MIMOSA] – Implémentation de la norme ISO 13374 (couches considérées encadrées en gras) 17
Figure 4 : Principe de surveillance de la séquence de démarrage 21
Figure 5 : Signaux acquis sur turboréacteur et extractions associées 21
Figure 6 : Principe d'estimation des résidus 22
Figure 7 : Principe de surveillance de la consommation d'huile
Figure 8 : Extrait de niveaux d'huile après atterrissage et avant décollage avec identification de deux remplissages
Figure 9 : Exemple de quantification de remplissage 27
Figure 10 : Niveau d'huile corrigé des remplissages 28
Figure 11: Approche VOC - VOB
Figure 12: Courbe COR- Caractéristiques Opérationnelles de Réception
Figure 13: Exemple de probabilité de fausse alarme et non détection
Figure 14 : Détermination de α à partir de l'équation (2) et d'une courbe COR
Figure 15 : Exemple d'une densité de probabilité estimée par fenêtres de Parzen avec noyau gaussien 42
Figure 16 : Densité de probabilité de la GEV pour $\xi > 0$, $\xi < 0$ et $\xi = 0$
Figure 17 : Exemple de QQplot dans les domaines d'attraction de Frechet (à gauche), de Weibull (au milieu) et de Gumbel (à droite)
Figure 18 : Exemple de graphe des excès moyens 47
Figure 19 : Exemple de sélection de seuil selon l'estimateur de Hill 47
Figure 20 : Histogramme du score d'anormalité sans dégradation48
Figure 21 : Test d'adéquation de l'ajustement Gamma 50
Figure 22 : Boites à moustaches
Figure 23 : Distributions de référence Γ (5;0,5) et Rayleigh(2)
Figure 24 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson, G : Gamma et P : Parzen) pour différentes tailles d'échantillons issus de la distribution $\Gamma(5; 0,5)$ (a) et de la distribution Rayleigh(2) (b)
Figure 25 : influence de la taille des échantillons d'apprentissage sur les transformations décidées non conformes pour les distributions de référence Gamma et Rayleigh
Figure 26 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson, G : Gamma et P : Parzen) pour différentes valeurs de $\alpha_{recherchée}$ dans le cas d'échantillons issus de la distribution $\Gamma(5; 0.5)$ (a) et de la distribution Rayleigh(2) (b)
Figure 27 : Distributions de référence Gamma pour les différentes valeurs de paramètres considérées 55
Figure 28 : Distributions de référence Rayleigh pour les différentes valeurs de paramètres considérées 55
Figure 29 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson, G : Gamma et P : Parzen) dans le cas d'échantillons issus de distributions Gamma (a) et de distributions de Rayleigh (b) pour différentes valeurs des paramètres

Figure 30 : Distributions de référence Γ(5;2) et Rayleigh(5)58
Figure 31 : Seuil théorique et seuils estimés selon l'approche POT pour $\alpha_{recherchée}=10^{-4}$ et différentes tailles d'échantillon issu de la distribution de référence Gamma (à gauche) et Rayleigh (à droite)
Figure 32 : Seuil théorique et seuils estimés selon l'approche POT pour $\alpha_{recherchée}=10^{-9}$ et différentes tailles d'échantillon issu de la distribution de référence Gamma (à gauche) et Rayleigh (à droite)
Figure 33 : Seuil théorique (T) et seuils estimés après ajustement par fenêtres de Parzen pour $\alpha_{recherchée}=10^{-9}$ et différentes tailles d'échantillons issus de la distribution de référence Gamma (à gauche) et Rayleigh (à droite). 61
Figure 34: Score d'anormalité sans dégradation et ajustements Gamma et Parzen
Figure 35 : Fonction de répartition empirique du score d'anormalité sans dégradation, ajustements Gamma et Parzen, zoom sur les queues de distribution
Figure 36 : Distributions des scores d'anormalité avec et sans dégradation pour une baisse de pression APU64
Figure 37 : Distributions des scores d'anormalité avec et sans dégradation pour une hausse de débit carburant.
Figure 38 : Distributions des scores d'anormalité avec et sans dégradation pour une baisse de débit carburant. 66
Figure 39 : Distributions des scores d'anormalité avec et sans dégradation pour une ouverture lente de la vanne SAV
Figure 40 : Timeliness de la prédiction de RUL 71
Figure 41 : Exemple de diagramme de fiabilité72
Figure 42 : Evolution de la dégradation selon des processus Gamma pour $b=1$; $b=2$ et $b=0,5$ dans la relation $vt = ctb$
Figure 43: Illustration de la méthode de génération des accroissements d'un processus Gamma
Figure 44 : 500 trajectoires théoriques de surconsommation générées par simulation pour une évolution moyenne de 0,1 l/h/mois et un écart type de 0,01 l/h au bout d'un mois
Figure 45 : Illustration du déclenchement de la fonction de pronostic
Figure 46 : Exemple de consommation estimée pour le moteur 1 de l'avion 1 78
Figure 47 : Exemple de 500 trajectoires de surconsommation générées par simulation
Figure 48: Trajectoires « pseudo observées » : consommation estimée pour le moteur 1 de l'avion 1 ajoutée aux surconsommations simulées
Figure 49: Trajectoires « théoriques » : moyenne des consommations pour le moteur 1 de l'avion 1 ajoutées aux surconsommations simulées
Figure 50 : Histogramme du score d'anormalité sans dégradation avant et après moyenne mobile sur n.= 5 démarrages
Figure 51 : Score d'anormalité sans dégradation moyenné sur $n = 5$ démarrages et ajustement par fenêtre de Parzen. 84
Figure 52 : Distributions des scores d'anormalité moyennés sur $n = 5$ démarrages avec et sans dégradation pour une ouverture lente de la vanne SAV
Figure 53 : Représentation graphique du test d'égalité des variances sur le score d'anormalité par moteur 88
Figure 54 : Distribution du score d'anormalité sans dégradation moyenné sur cinq démarrages successifs après apprentissage des modèles de normalisation sur le type de moteur <i>X26</i>
Figure 55 : Distributions des scores d'anormalité moyennés sur $n = 5$ démarrages avec et sans dégradation pour une ouverture lente de la vanne SAV, modèles appris sur le type de moteur X26

Figure 56 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne déte par intensité de dégradation pour chacun des différents modèles particularisés par moteur	ection 92
Figure 57 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne déte par intensité de dégradation pour les différents modèles	ection 93
Figure 58 : Exemple de franchissement de seuil par une observation.	94
Figure 59 : Exemple de confirmation pour une détection de 4 franchissements parmi 5 démarrages	94
Figure 60 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne déte par intensité de dégradation pour chaque moteur avec une règle de détection à $k = 4$ parmi $n = 5$ paramétrage des seuils de base	ection et un 95
Figure 61 : Seuil de détection	96
Figure 62 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne déte par intensité de dégradation pour chaque moteur avec une règle de détection à k = 4 parmi n .= 5	ection 97
Figure 63 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne déte par intensité de dégradation pour chaque moteur avec une règle de détection à $k = 8$ parmi $n = 10$	ection 98
Figure 64 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par intensité de dégrad sur l'ensemble des moteurs lorsque la taille de la fenêtre des démarrages est <i>n</i> = 5	lation 100
Figure 65 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par intensité de dégrad sur l'ensemble des moteurs lorsque la taille de la fenêtre des démarrages est <i>n</i> = 10	lation 101
Figure 66 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par moteur, app moyenne mobile : $n = 5$, approche $k = 5$ parmi $n = 5$	roche 102
Figure 67 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par moteur, app moyenne mobile : $n = 10$, approche $k = 8$ parmi $n = 10$	roche 103
Figure 68 : Principe de fonctionnement de la fonction de pronostic	104
Figure 69 : Consommations estimées pour le moteur 1 de l'avion 4	105
Figure 70 : Consommations estimées pour le moteur 1 de l'avion 5	105
Figure 71 : Moteur 1 avion 4, trajectoires pseudo observées et performance de pronostic	107
Figure 72 : Moteur 1 avion 5, trajectoires pseudo observées et performance de pronostic	107
Figure 73: Moteur 1 avion 4, consommations estimées avant et après comptabilisation des remplis manquants.	sages 108
Figure 74: Moteur 1 avion 5, consommations estimées avant et après comptabilisation des remplis manquants.	sages 108
Figure 75 : Moteur 1 avion 4, trajectoires pseudo observées et performance de pronostic	109
Figure 76 : Moteur 1 avion 5, trajectoires pseudo observées et performance de pronostic	110
Figure 77 : Principe des turboréacteurs à double flux	123
Figure 78 : Le turboréacteur CFM56-7B	124
Figure 79 : Schéma de principe du circuit carburant	126
Figure 80 : Caractéristique d'une boucle de recirculation	127
Figure 81: Schéma de principe du circuit d'huile	127
Figure 82: Echelle des niveaux de maturité technologique – TRL	130
Figure 83 : Principe DMAIC	132
Figure 84: Enchainement des phases de la procédure de maturation.	133
Figure 85 : Classification des méthodes de diagnostic selon [Venkatasubramanian, 2003a]	140

Figure 86 : Classification des méthodes de pronostic selon [Vasile, 2008]142
Figure 87 : Classification des méthodes de pronostic selon [Lebold, 2001] 143
Figure 88 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une baisse de pression APU
Figure 89 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une hausse de débit carburant
Figure 90 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une baisse de débit carburant
Figure 91 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une baisse de pression APU, modèles appris par type de moteur
Figure 92 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une hausse de débit carburant, modèles appris par type de moteur
Figure 93 : Distributions des scores d'anormalité moyennés sur <i>n</i> = 5 démarrages avec et sans dégradation pour une baisse de débit carburant, modèles appris par type de moteur
Figure 94 : Moteur 1 avion 1, trajectoires pseudo observées et performance de pronostic 159
Figure 95 : Moteur 2 avion 1, trajectoires pseudo observées et performance de pronostic
Figure 96 : Moteur 1 avion 2, trajectoires pseudo observées et performance de pronostic 160
Figure 97 : Moteur 2 avion 2, trajectoires pseudo observées et performance de pronostic
Figure 98 : Moteur 1 avion 3, trajectoires pseudo observées et performance de pronostic
Figure 99 : Moteur 2 avion 3, trajectoires pseudo observées et performance de pronostic
Figure 100 : Moteur 2 avion 4, trajectoires pseudo observées et performance de pronostic
Figure 101 : Moteur 2 avion 5, trajectoires pseudo observées et performance de pronostic

TABLE DES TABLEAUX

Tableau 1 : Architecture OSA-CBM des systèmes de surveillance et périmètre de la thèse	19
Tableau 2 : Matrice de signature de l'algorithme ESC.	23
Tableau 3 : Causes de non démarrage et dégradations prémices prises en compte par l'algorithme ESC	24
Tableau 4 : Répartition du nombre de démarrages par moteur et par avion	25
Tableau 5 : Causes de consommations anormales et prémices prises en charge par EOC.	29
Tableau 6 : Répartition du nombre de cycles par avion et par moteur	29
Tableau 7: Formules associées aux trois types de transformation de Johnson	40
Tableau 8 : Impact sur les mesures pour une baisse de pression APU	64
Tableau 9 : Impact sur les mesures pour une hausse de débit carburant.	65
Tableau 10 : Impact sur les mesures pour une baisse de débit carburant	66
Tableau 11 : Impact sur les mesures pour une ouverture lente de la SAV	67
Tableau 12 : Intensités et dégradations étudiées	67
Tableau 13 : Seuils disponibles dans la version de base de la fonction détection	83
Tableau 14 : PSain Détection et PoD à partir des scores d'anormalité moyennés sur n = 5 démarrages pou paramétrage de base.	r le 84
Tableau 15 : Probabilité de dégradation par URL et seuil de détection	85
Tableau 16 : <i>PSain</i> Détection et PoD à partir des scores d'anormalité moyennés sur n = 5 démarrages per P(Sain/Détection) _{exigée} = 1% et PoD _{exigée} > 99%	our 86
Tableau 17 : Poussées respectives par type de CFM56-7B	88
Tableau 18 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> à partir des scores d'anormalité moyennés sur n = 5 démarrag modèles appris sur un même type de moteur (<i>X26</i>), <i>P(Sain</i> <i>Détection</i>) _{exigée} = 1% et <i>PoD_{exigée}</i> > 99%	;es, 89
Tableau 19 : Comparaison des seuils pour une règle de détection à $k = 4$ parmi $n = 5$ avec une règle détection $k = 8$ parmi $n = 10$, pour le moteur 1.	de 99
Tableau 20 : Rapport (P(Sain Détection)/PoD) moyenné par intensité sur l'ensemble des moteurs po différents taux de confirmation lorsque la fenêtre des démarrages est n = 10.	our L01
Tableau 21 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 1, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 149
Tableau 22 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 2, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 149
Tableau 23 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 3, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 150
Tableau 24 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 4, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 150
Tableau 25 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 5, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 151
Tableau 26 : <i>PSain</i> <i>Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur <i>n</i> = 5 démarrages, modèles app sur 50% des démarrages du moteur 6, P(Sain Détection) _{exigée} = 1% et PoD _{exigée} > 99%	oris 151
Tableau 27 : <i>PSain Détection</i> et <i>PoD</i> , scores d'anormalité moyennés sur n = 5 démarrages, modèles app sur 50% des démarrages du moteur 7, <i>P(Sain Détection)_{exigée}</i> = 1% et <i>PoD_{exigée}</i> > 99%1	oris 152

Tableau 28 : $PSain Détection$ et PoD , scores d'anormalité moyennés sur $n = 5$ démarrages, modèles apprissur 50% des démarrages du moteur 8, $P(Sain Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.152
Tableau 29 : $PSain Détection$ et PoD , scores d'anormalité moyennés sur $n = 5$ démarrages, modèles apprissur 50% des démarrages du moteur 9, $P(Sain Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.153
Tableau 30 : $PSain Détection$ et PoD , scores d'anormalité moyennés sur $n = 5$ démarrages, modèles apprissur 50% des démarrages du moteur 10, $P(Sain Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.153
Tableau 31 : PSain Détection et PoD, modèles appris sur 50% des démarrages du moteur 1,P(Sain Détection)_exigée = 1% et PoD_exigée > 99%.154
Tableau 32 : $PSain Détection$ et PoD , modèles appris sur 50% des démarrages du moteur 2, $P(Sain Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.154
Tableau 33 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 3,P(Sain Détection)_exigée = 1% et PoD_exigée > 99%.155
Tableau 34 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 4,P(Sain Détection)exigée = 1% et PoD20%155
Tableau 35 : PSain Détection et PoD, modèles appris sur 50% des démarrages du moteur 5,P(Sain Détection)exigée = 1% et PoD20%156
Tableau 36 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 6,P(Sain Détection)exigée = 1% et PoD20%156
Tableau 37 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 7,P(Sain Détection)exigée = 1% et PoD20%157
Tableau 38 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 8,P(Sain Détection)_exigée = 1% et PoD_exigée > 99%.157
Tableau 39 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 9,P(Sain Détection)exigée = 1% et PoD20%158
Tableau 40 : PSain Détection et PoD , modèles appris sur 50% des démarrages du moteur 10,P(Sain Détection)exigée = 1% et PoD20%158

Introduction générale

Dans le domaine aéronautique, l'une des préoccupations majeures des compagnies aériennes est la disponibilité de leurs équipements. Les indisponibilités non programmées pouvant conduire à, par exemple, des retards ou des annulations de vols entraînent des coûts élevés pour les compagnies.

Pour éviter cela, plusieurs stratégies et dispositifs de maintenance corrective ont été mis en place. Il s'avère que, malgré les approches et actions de maintenance existantes, certaines pannes ayant un impact conséquent sur les temps d'indisponibilités subsistent. Ces pannes n'étant pas décelées par les dispositifs existants, la tendance est de recourir à une maintenance dite « prédictive ».

L'objectif de la maintenance prédictive est de suivre l'état de santé d'un système de manière à détecter et identifier ses dysfonctionnements (diagnostic) et prédire de façon précise son temps de vie résiduel (pronostic). Lorsque cette approche est maitrisée, les coûts de maintenance ainsi que les indisponibilités se réduisent considérablement [Vrignat, 2011]. Les conditions de maitrise de cette approche résident dans la connaissance du système à maintenir et la manière de le modéliser pour mettre en place des méthodes de diagnostic et de pronostic les plus représentatives possibles du système réel. L'objectif est alors d'identifier les prémices des défaillances avant qu'elles ne deviennent critiques pour permettre une planification plus précise des interventions de maintenance. Le point de vue qui associe le diagnostic, le pronostic et la surveillance de l'état de santé des systèmes est regroupé sous les termes Prognostics and Health Management (PHM).

On compte à ce jour plusieurs développements de dispositifs de PHM des systèmes de régulation des turboréacteurs. Le PHM nécessite le développement de systèmes de surveillance, sous forme d'algorithmes, dont l'objectif est de détecter et localiser des dégradations prémices de défauts et d'éviter les défaillances.

Les systèmes de surveillance étant développés, il faut s'assurer de leurs performances pour les introduire en exploitation. C'est le sujet de cette thèse dont l'objectif est l'évaluation et l'optimisation des performances des systèmes de surveillance développés par Safran Snecma. La thèse a été réalisée au sein de l'entreprise Safran Engineering Services en collaboration avec l'Université de Technologie de Troyes dans le cadre d'une convention CIFRE.

L'étape d'évaluation et optimisation des performances est appelée « maturation ». La maturation des algorithmes de surveillance est différente de la validation de codes informatiques. Dans le domaine du génie logiciel, la validation de code est réalisée à l'aide de tests dits unitaires. Ces tests permettent de vérifier le fonctionnement et l'agencement des différentes fonctions codées. En revanche, la maturation intervient après l'étape de validation de code expérimental des systèmes de surveillance et avant le développement du code d'exploitation en opération. Elle consiste à évaluer puis améliorer les performances des algorithmes en vue de leur implémentation en exploitation.

Deux systèmes de surveillance sont considérés :

- le système de surveillance de la séquence de démarrage. Son objectif est double, en cas de panne, il est utilisé pour localiser le ou les éléments incriminés. En l'absence de panne, il est utilisé pour détecter des dégradations prémices de non démarrages et déterminer la probabilité de panne dans un horizon opérationnel donné.
- le système de surveillance de la consommation d'huile. Son objectif est d'estimer la consommation d'huile dans le réservoir afin de détecter des consommations anormales et d'estimer la probabilité de franchir un seuil de défaillance dans un horizon opérationnel fixé.

Le fait qu'un algorithme de surveillance soit parfaitement implémenté en exploitation et ait réussi tous les tests unitaires est une condition nécessaire pour son introduction en exploitation. Toutefois, cela ne garantit pas le fait que les performances de ce dernier soient satisfaisantes.

Les performances dont il est question dans cette thèse concernent les fonctions de détection et de pronostic :

- détection de dégradations prémices de pannes
- pronostic de panne après détection de prémices

Ces fonctions sont des données de la thèse et non l'objet de la thèse. L'objet de la thèse est la définition des performances de ces fonctions, leur estimation et leur amélioration.

Ce document se décompose en trois parties :

- la première partie, « Fonctions de surveillance considérées », situe la thèse dans son contexte industriel. Elle décrit brièvement les turboréacteurs puis les fonctions de surveillance considérées.
- la seconde partie, « Performances de détection et de pronostic », s'intéresse aux indicateurs de performance de la détection et du pronostic rencontrés dans la littérature et ceux pertinents pour les compagnies aériennes. Les méthodes d'estimation des indicateurs de performances issus du domaine aéronautique sont décrites :
 - pour la fonction de détection, dans le cadre de la surveillance de la séquence de démarrage,
 - pour la fonction de pronostic, dans le cadre de la surveillance de la consommation d'huile.
- la troisième partie, « Estimation et amélioration des performances », présente les résultats de l'application des méthodes d'estimation établies précédemment et l'optimisation des performances de chaque fonction pour répondre aux exigences des compagnies aériennes.

Ce travail a permis de proposer des indicateurs pour quantifier les performances des fonctions considérées et d'apporter des solutions pour améliorer les performances et ainsi mieux répondre aux exigences. D'autres améliorations possibles sont proposées comme perspectives pour conclure ce mémoire.

I Fonctions de surveillance considérées

I.1 INTRODUCTION

Ce chapitre présente le contexte industriel de la thèse afin de mesurer les enjeux des travaux réalisés ainsi que leurs orientations. Pour ce faire, le principe de fonctionnement des turboréacteurs est présenté en section I.2. Une description plus détaillée est donnée en ANNEXE - 1 pour situer les différents modules et systèmes composant les turboréacteurs. Par la suite, les notions de pronostic et de surveillance de l'état de santé d'un système sont introduites en section I.3. Cette section décrit, dans les grandes lignes, la stratégie de surveillance adoptée par Safran. Les systèmes de surveillance développés dans ce contexte sont listés (de manière non exhaustive) en section I.4. Au terme de la conception des systèmes de surveillance, un processus de maturation est mis en œuvre. Il permet de quantifier puis d'améliorer les performances des algorithmes. La surveillance des turboréacteurs étant un sujet vaste et complexe, la section I.5 établit le périmètre de la thèse. Enfin, les deux systèmes de surveillance considérés, à titre d'exemple, sont décrits en section I.6 et I.7.

I.2 LES TURBOREACTEURS

Les turboréacteurs (Figure 1) sont des moteurs à réaction tirant leurs propriétés propulsives de la différence entre la vitesse de l'air absorbé (V0) et la vitesse de l'air rejeté (V) [Sif, 2005]. Ils sont basés sur le principe d'action – réaction. Ils absorbent de l'air et le rejettent après l'avoir accéléré. Pour accroître la vitesse de l'air aspiré, celui-ci subit une compression, une combustion et une détente. Pour une tranche d'air entrant dans la turbine, ces trois transformations ont lieu séquentiellement lors du passage dans les différents organes du moteur.



Figure 1 : Schéma de principe d'un turboréacteur.

Pour améliorer la propulsion des turboréacteurs, une solution consiste à traiter une plus grande quantité d'air à l'aide d'une « soufflante » placée à l'entrée du moteur (Figure 2). Un turboréacteur équipé d'une soufflante est dit double flux. Une partie de l'air admis (le flux primaire) s'oriente vers le compresseur basse pression et subit les transformations décrites précédemment alors que l'autre partie (le flux secondaire) est comprimée par la soufflante, entraînée par la turbine basse pression. Le flux secondaire est ensuite détendu dans la partie extérieure du moteur et produit 80% de la poussée. Cette solution permet de faire des économies de carburant et est particulièrement adaptée aux avions de transport civil. Le turboréacteur CFM56, décrit en ANNEXE - 1, exploite cette technologie.



Figure 2 : Principe des turboréacteurs à double flux.

La gestion et l'optimisation des performances des turboréacteurs nécessitent la mise en place et l'interaction de plusieurs systèmes. Ces derniers sont composés d'un système de régulation permettant la gestion de l'orientation des aubes afin de contrôler le flux d'air (cf. ANNEXE - 1) et la gestion de la régulation de l'injection de carburant. Le système de régulation permet également le pilotage des systèmes d'allumage et de démarrage. Un circuit de lubrification permet d'assurer les conditions de fonctionnement des turboréacteurs en diffusant l'huile qui réduit les frottements et permet de refroidir le moteur.

Comme tout système, les systèmes aéronautiques sont sujets à des pannes. La disponibilité des turboréacteurs représente un enjeu crucial pour les compagnies aériennes et est devenue une priorité avec la progression du trafic aérien.

Dans le secteur aéronautique, la maintenance corrective est majoritairement adoptée et les temps d'intervention sont optimisés. Il arrive cependant, dans de rares cas, que les temps d'intervention spécifiés par les avionneurs ne soient pas respectés (15 minutes d'intervention). Ce sont ces cas qui induisent des indisponibilités non programmées et ne permettent pas le décollage des appareils en vertu de la règlementation. Ces pannes sont dites « no-go ».

Pour éviter ces situations, les systèmes pouvant conduire à des « no-go » font l'objet de surveillance afin d'estimer au mieux leur état de santé et de localiser les éléments incriminés (en cas de panne) afin de réduire les temps d'intervention. De plus, une évolution précise de l'état du système permet d'identifier le niveau de dégradation limite qui fait courir un risque de panne trop grand et permet de planifier des opérations de maintenance préventive. Ces notions de pronostic et surveillance de l'état de santé de systèmes sont développées dans le paragraphe suivant.

I.3 PRONOSTIC ET SURVEILLANCE DE L'ETAT DE SANTE DE SYSTEMES

Le PHM est une approche de prise en charge du cycle de vie des systèmes qui vise à réduire ou éliminer les inspections et actions de maintenance en se basant sur des évaluations, en temps réel et continu (Condition Monitoring), de l'état de santé des systèmes. Ce suivi est réalisé à l'aide des systèmes de surveillance s'appuyant sur des fonctions de diagnostic et de pronostic. Le PHM intègre les principes de maintenance adaptative (Condition based Maintenance - CBM) ainsi que les principes de l'optimisation de la maintenance par la fiabilité (OMF). Il étend la vision du CBM et de l'OMF centrée sur la maintenance d'un composant ou d'un équipement à une vision plus large basée sur la connaissance de l'état de santé (état et performance) d'un système. Il offre ainsi un environnement

pour améliorer la disponibilité des systèmes en améliorant potentiellement leur fiabilité et leur longévité [Kalgren, 2006]. L'objectif du PHM est donc d'optimiser le compromis entre la disponibilité d'un système et la sécurité des biens et des personnes par une utilisation appropriée de la maintenance industrielle.

L'une des architectures utilisée dans le cadre du PHM, et qui est la plus répandue, est appelée OSA/CBM (Open System Architecture / Condition Based Maintenance) [Lebold, 2001], [Vachtsevanos, 2006] [Rasovska, 2007]. Elle fournit une architecture pour le transfert d'informations dans un système de maintenance et fournit également les outils de mise en œuvre de cette architecture. Cette dernière est basée sur la norme ISO 13374 [ISO, 2003] et comprend six couches (Figure 3) : acquisition de données, manipulation de données, détection de l'état, évaluation de l'état (de santé), évaluation de pronostic et génération de conseils.

La première couche concerne l'acquisition de mesures sensibles à l'évolution de l'état de santé ou des dégradations du système surveillé. A partir de ces mesures, la couche suivante extrait des indicateurs de dégradation, prémices de défaillances. Ces indicateurs peuvent être traités séparément (pour la localisation par exemple) ou encore être fusionnés entre eux, afin de concevoir un indicateur (global) de l'état de santé qui synthétise l'information sur le niveau de dégradation du système. Par la suite, deux cas de figures se présentent quant à l'exploitation de cet indicateur :

- en cas de présence de défaillance, le diagnostic est déclenché afin de localiser le ou les composants défaillants (ou dégradés). C'est un outil d'aide à la maintenance.
- en cas d'absence de défaillance (mais présence potentielle d'une dégradation), le pronostic est mis en place en vue d'estimer le temps de vie résiduel du système ou de prédire l'état de santé pour un horizon temporel donné.

Enfin, la dernière étape concerne l'aide à la décision en fusionnant les éventuelles informations provenant d'autres algorithmes de surveillance associés à d'autres composants du système.

Les trois premières couches impliquent uniquement les dispositifs qui collectent et traitent les données pour détecter les anomalies (dysfonctionnements). Le reste repose sur la combinaison des systèmes et des agents humains pour définir l'état de santé de l'équipement, prédire son évolution et les défaillances ou dégradations pouvant survenir.



Figure 3 : Blocs fonctionnels de l'architecture OSA- CBM [MIMOSA] – Implémentation de la norme ISO 13374 (couches considérées encadrées en gras).

L'architecture OSA-CBM apporte une flexibilité et une extensibilité au système de maintenance. Elle s'est avérée efficace dans la collecte, le traitement et l'affichage des données de capteurs et permet d'assurer la continuité de l'information et des connaissances [Byington, 2004].

Cette architecture convient parfaitement à la surveillance de systèmes complexes tels que les turboréacteurs où il est nécessaire de combiner plusieurs algorithmes de surveillance pour avoir une vision globale de leur état de santé. Le paragraphe suivant illustre ce propos en listant quelques systèmes de surveillance développés par Safran Snecma.

I.4 SYSTEMES DE SURVEILLANCE DEVELOPPES PAR SNECMA

Les turboréacteurs représentant des systèmes complexes, le développement d'un seul système dédié à leur surveillance totale n'est pas envisageable. L'idée est donc de développer des algorithmes de surveillance propre à chaque système ou module constituant les turboréacteurs. La surveillance du système dans sa globalité se fait alors en fusionnant les informations issues de chaque algorithme de surveillance. Cette règle est vraie pour la majorité des systèmes. Seul le système de surveillance de la séquence de démarrage y échappe. Cela est dû à la spécificité de la séquence de démarrage qui fait intervenir les différents systèmes du turboréacteur.

L'architecture OSA-CBM se prêtant bien à ce contexte, plusieurs systèmes de surveillance ont été développés dans le cadre du PHM des turboréacteurs. Leur objectif est de :

- détecter des dysfonctionnements,
- localiser l'origine de ces dysfonctionnements,
- établir un pronostic en fonction de l'évolution d'indicateur(s) de dégradation représentatif(s) de l'état de santé des composants, modules ou systèmes sous surveillance.

Le panel des systèmes de surveillance développés par Safran Snecma est aussi large que les systèmes et modules constituant un turboréacteur. Quelques uns de ces systèmes sont listés ci-dessous :

- surveillance de la séquence de démarrage (Engine Start Capability, ESC) [Flandrois, 2010],
- surveillance de la consommation d'huile (Engine Oil Consumption, EOC) [Demaison, 2010],
- surveillance des boucles de géométries variables (Variable Stator Valve) [Massé, 2010],
- surveillance des chaînes d'acquisition de mesures de température T25 (T25 : Température en sortie du compresseur basse pression et à l'entrée du compresseur haute pression) [Ecoutin, 2010],
- surveillance des chaines d'acquisition de mesures de pression d'air par Bloc Pression [Massé, 2011a],
- surveillance des boucles de dosage carburant par FMV (Fuel Metering Valve) [Massé, 2011b],
- surveillance des chaines de mesure par comptage de SST (Selection STatus) [Foiret, 2013].

La conception de ces systèmes de surveillance représente la première étape vers leur implémentation en exploitation. L'étape suivante est indispensable. C'est leur maturation. L'expérience a montré que pour les systèmes de surveillance introduits en exploitation sans l'étape de maturation la première alarme émise était fausse. Cela est dû à l'utilisation de l'échelle TRL - Technology Readiness Level (cf. ANNEXE - 2), largement utilisée dans l'aéronautique, qui s'intéresse à la maturité d'un système pour son implémentation en exploitation et non pas à sa maturité par rapport à ses performances intrinsèques.

Cette thèse s'intéresse aux performances des algorithmes de surveillance en vue de leur implémentation en exploitation. Les systèmes de surveillance ne peuvent pas être introduits en exploitation tant qu'ils n'ont pas atteint un certain niveau de maturité. L'atteinte du niveau de maturité exigé est réalisée par un processus de mise au point dont le suivi est assuré selon un schéma de maturation. Ce processus permet de quantifier le niveau de maturité des systèmes de surveillance en vue de l'améliorer pour répondre à des exigences de performance. Le point clé de ce processus réside en une analyse critique des performances permettant d'identifier des axes d'amélioration. Le contrôle des performances à l'aide de la maturation permet de s'affranchir d'incidents causés par un souci de mise au point.

La procédure de maturation [Hmad, 2012a], décrite en ANNEXE - 3, a été appliquée aux fonctions de détection et pronostic des algorithmes considérés. Le périmètre de l'étude est décrit au paragraphe suivant.

I.5 PERIMETRE DE L'ETUDE

Les systèmes de surveillance, tels que construits, peuvent être divisés en trois parties. La première partie consiste à acquérir des mesures à partir de capteurs pour extraire un ou des indicateurs de dégradations. Ces indicateurs de dégradations peuvent être exploités individuellement ou utilisés pour calculer un indicateur global représentatif de l'état de santé du système sous surveillance. Cette première partie est spécifique à chaque système de surveillance.

La seconde partie concerne l'exploitation de l'indicateur de l'état de santé du système au sein des fonctions de détection et de pronostic.

Enfin la troisième partie représente la phase de décision finale en fonction des sorties de la seconde partie. Elle repose sur des règles de décision qu'il faut adapter en fonction des objectifs de surveillance.

Le Tableau 1 représente une décomposition plus précise des systèmes de surveillance selon l'architecture OSA-CBM. Les blocs encadrés en gras représentent les principales fonctions considérées au cours de la thèse.

ACQUISITION DES DONNEES DATA ACQUISITION	Acquérir les données de capteurs et systèmes
MANIPULATION DES DONNEES	Extraire les mesures endogènes
DATA MANIPULATION	Acquérir les mesures exogènes (paramètres de contexte)
	Construire des modèles des mesures endogènes*
	Estimer les mesures endogènes attendues*
DETECTION DE L'ETAT	Analyser les résidus en z-scores*
DETECTION STATE	Calculer un score d'anormalité
	Régler les seuils de détection
	Décision de détection d'anomalie
EVALUATION DE L'ETAT	Apprendre les dégradations prémices ou les modes de défaillance en signatures (ou syndromes) de référence
HEALTH ASSESSMENT	Classifier selon les signatures de référence
	Localiser l'URL ou module dégradé
EVALUATION DE PRONOSTIC PROGNOSTIC ASSESSMENT	Prédire la probabilité d'une dégradation d'intensité maximum avant défaillance en considérant un horizon opérationnel donné
GENERATION DE CONSEIL ADVISORY GENERATION	Consolider en diagnostic et pronostic globaux par fusion avec les autres systèmes de surveillance

Tableau 1 : Architecture OSA-CBM des systèmes de surveillance et périmètre de la thèse.

Les étapes suivi du symbole «* » dans le Tableau 1 ne sont réalisées que pour des systèmes de surveillance pour lesquels il existe une phase d'apprentissage pour la construction des modèles de

normalisation. Cela est le cas du système de surveillance de la séquence de démarrage. Le système de surveillance de la consommation d'huile n'est pas concerné.

La maturation de la fonction de détection a été réalisée dans le cadre de la surveillance de la séquence de démarrage et la maturation de la fonction de pronostic a été réalisée dans le cadre de la surveillance de la consommation d'huile. Ces deux systèmes de surveillance sont décrits dans les paragraphes qui suivent.

I.6 SURVEILLANCE DE LA SEQUENCE DE DEMARRAGE

Le démarrage d'un turboréacteur est une opération qui demande la participation de nombreuses parties du moteur et de ses équipements [Ausloos, 2010]. Il existe deux types de démarrage : le mode automatique et le mode manuel. La séquence de démarrage est cependant la même dans les deux cas :

- Alimenter les canalisations en air,
- Ouvrir la vanne de démarrage,
- Observer l'enroulement (entrainement) du compresseur haute pression par le démarreur,
- Alimenter et claquer les bougies,
- Ouvrir la vanne de carburant et injecter le carburant,
- Constater l'allumage en surveillant la température des gaz d'échappement,
- Fermer la vanne de démarrage au régime d'auto-entraînement du moteur dit « Cut Out »,
- Confirmer le ralenti en vérifiant que le régime du compresseur, le débit carburant, la pression dans la chambre de combustion et la température des gaz d'échappement sont stabilisés,
- Arrêter de claquer les bougies.

La description de la séquence de démarrage permet d'identifier les différents systèmes sollicités. L'algorithme de surveillance de la séquence de démarrage (Engine Start Capability – ESC) a été développé afin de surveiller la capacité à démarrer des turboréacteurs en tenant compte de ces différents systèmes. Cette surveillance représente un enjeu important puisque lors du démarrage les passagers se trouvent à bord de l'avion. Un non démarrage dû à une défaillance peut entrainer des retards ou des annulations de vols dont les coûts sont importants. De plus, cela a un impact négatif sur l'image des compagnies aériennes. L'algorithme ESC s'inscrit donc dans ce cadre. A partir de mesures issues du turboréacteur [Ausloos, 2009], il consiste à générer des indicateurs de dégradation caractéristiques de l'état de santé du turboréacteur puis à suivre leur évolution au fil des démarrages. Cet algorithme se fonde sur plusieurs approches et outils mathématiques permettant la construction d'indicateurs pour diagnostiquer et pronostiquer d'éventuelles anomalies.

La section I.6.1 décrit le principe de fonctionnement de l'algorithme ESC. Les causes de non démarrage prises en charge par l'algorithme sont décrites en section I.6.2. Enfin la section I.6.3 présente les données disponibles et celles utilisées.

I.6.1 DESCRIPTION

Le principe de surveillance de la séquence de démarrage est présenté par la Figure 4. Il repose sur le calcul d'un score d'anormalité, représentatif de l'état de santé du système, auquel un seuil de détection est appliqué pour détecter des anomalies. Après détection la fonction de pronostic est déclenchée afin d'estimer la probabilité que le score d'anormalité franchisse un seuil de panne dans un délai opérationnel donné. Les étapes permettant d'atteindre les blocs « détection » et « pronostic » de la Figure 4 sont décrites dans les paragraphes qui suivent.



Figure 4 : Principe de surveillance de la séquence de démarrage.

Description des blocs « capteurs », « acquisition des signaux » et « extraction des mesures endogènes et exogènes » :

L'algorithme ESC est composé d'une étape d'acquisition de plusieurs signaux relatifs au moteur [Nya Djiki, 2010a], comme le représente la Figure 5. Huit mesures sont extraites à partir de ces signaux :

- **x_accel_max** : temps écoulé depuis le début du démarrage pour atteindre l'accélération maximale du régime moteur.
- **y_accel_max** : valeur de l'accélération maximale du régime moteur.
- **T1** : temps écoulé entre l'instant où le régime moteur est supérieur à 20 tr/min jusqu'à ce qu'il dépasse 20% du régime maximum.
- **T_allum** : temps d'allumage, il correspond à la durée entre l'instant où la position du doseur carburant est supérieure à zéro et l'instant où se produit un changement brutal de l'accélération du régime moteur.
- **T2** : temps écoulé entre l'instant où le régime moteur est supérieur à 30% de sa valeur maximale jusque la « Cut Out » soit 55,3% du régime maximum.
- **T3** : temps écoulé entre l'instant de « Cut Out » jusqu'à atteindre le régime de ralenti soit 8400 tr/min.
- **grad(EGT)max** : valeur maximale du gradient de température des gaz d'échappement (EGT) entre l'injection de carburant et la « Cut Out ».
- **grad(EGT)moy** : valeur moyenne du gradient de température des gaz d'échappement (EGT) entre l'injection de carburant et la « Cut Out ».



Figure 5 : Signaux acquis sur turboréacteur et extractions associées.

Les conditions opératoires ayant un impact sur les mesures précédentes, il est nécessaire d'en tenir compte. Les paramètres de contexte (aussi appelés mesures exogènes) sont les suivants :

- PAStar : pression relative (pression absolue pression atmosphérique) d'alimentation au démarrage
- Pamb : pression ambiante
- Temp_Tamb: température ambiante
- Temp_Toil: température d'huile
- Reg_injec : Régime à l'injection de carburant (régime à l'instant de l'allumage).

Description des blocs « apprentissage des modèles de normalisation des mesures endogènes » et « calcul des z-scores » :

Afin de limiter l'effet des conditions opératoires sur les mesures, un processus de normalisation est mis en œuvre. Il repose sur des modèles de régression, appris à partir d'exemples, qui estiment chaque mesure sans dégradation à l'aide de mesures endogènes (les huit mesures moins celle à modéliser) et de mesures exogènes qui caractérisent les conditions opératoires.

L'algorithme ESC possède deux modes d'exécution :

- un mode apprentissage : ce mode d'exécution n'est pas systématique. Il est lancé une première fois et permet la sélection des modèles de régression. L'algorithme teste plusieurs types de régression pour chaque mesure et choisit celui dont les résidus sont les moins importants [Lacaille, 2009]. L'apprentissage des modèles de normalisation des mesures peut être mis à jour en cas de reconfiguration du système ou pour un changement de contexte d'exploitation (sur demande de l'utilisateur).
- un mode d'exécution standard : une fois les modèles appris, le mode d'exécution standard permet d'estimer la mesure normalisée et d'exécuter les autres fonctions de l'algorithme.

Par la suite, huit indicateurs de dégradation, appelés z-scores (résidus normalisés), sont obtenus en calculant la différence entre les mesures endogènes extraites (observations) et celles prédites par les modèles de régression (Figure 6). Ils ont deux usages, l'un pour la localisation et l'autre pour le calcul du score d'anormalité.



Figure 6 : Principe d'estimation des résidus.

Description des blocs « localisation » et « calcul du score d'anormalité » :

Le premier usage des z-scores consiste à localiser les défaillances (éventuelles) à l'aide d'une matrice de signatures des défaillances de chaque composant ou module suivi par ESC. Le Tableau 2 représente cette matrice pour l'algorithme ESC. Elle comporte des indications (« + », « - », « 0 ») renseignées par les experts sur la tendance d'évolution des z-scores pour chaque type de défaut. Chaque combinaison de ces indications représente la signature d'une cause de non démarrage. Par exemple, il apparait qu'une pression d'air faible se manifeste de la façon suivante :

- augmentation des z-scores de x_accel_max, T1 et T2 : « + ».
- diminution des z-scores de y_accel_max, grad(EGT)max et grad(EGT)moy : « ».
- pas d'impact sur T_allum et T3 : « 0 ».

	Cause de non démarrage			
z-scores	Pression d'air faible	Pas assez de débit carburant	Trop de débit carburant	Non ouverture de la vanne à air
x_accel_max	+	0	0	+
y_accel_max	-	0	0	-
T1	+	0	0	+
T_allum	0	0	0	0
T2	+	-	+	0
Т3	0	-	+	0
grad(EGT)max	-	+	-	0
grad(EGT)moy	-	+	-	0

Tableau 2 : Matrice de signature de l'algorithme ESC.

Le second usage des z-scores consiste à construire un score d'anormalité (monovarié) représentant l'indicateur de l'état de santé du système de démarrage. Ce score est obtenu en calculant la norme de Mahalanobis sur les huit z-scores [Lacaille, 2009]. En théorie, sous l'hypothèse H₀ (absence de dégradation), chaque z-score est une variable aléatoire gaussienne et le score d'anormalité est distribué selon un χ^2 de paramètre γ où γ est le rang de la matrice de corrélation des z-scores. Le score d'anormalité étant l'indicateur de santé de la séquence de démarrage, il constitue la principale donnée d'entrée des fonctions de détection et de pronostic.

Il est important de noter que l'algorithme de surveillance de la séquence de démarrage est atypique dans le sens où la phase de localisation précède la phase de détection. Cela s'explique par le fait que la fonction de détection utilise un seuil spécifique pour chaque cause de non démarrage. Le fait d'exécuter la phase de localisation avant la détection permet d'identifier la cause la plus probable pour utiliser le seuil associé lors de la détection. Les causes de non démarrages considérées sont présentées dans le paragraphe suivant.

I.6.2 CAUSES DE NON DEMARRAGE

Plusieurs causes peuvent être à l'origine d'un non démarrage. Celles couvertes par ESC sont supposées être précédées par des dégradations prémices d'intensité croissante. Ces dernières sont détectables par analyse des indicateurs de dégradations produits par l'algorithme ESC pendant la phase de démarrage.

Le Tableau 3 répertorie les modules ainsi que la nature des pannes associées pris en charge par l'algorithme ESC [Hmad, 2009]. Leurs probabilités d'occurrence (par démarrage) ont été déterminées à l'aide d'arbre de panne et de retours d'expériences. Ces causes représentent environ 80 % des occurrences de non démarrage. Les autres étant prises en charge par d'autres dispositifs, elles ne font pas partie du périmètre de surveillance de l'algorithme ESC.

Module	Cause de non démarrage	Prémices	P(Dégradation)
Compresseur d'air (APU)	Pression faible	Baisse de pression	1,56E-05
Hydro-Mechanical Unit (HMU)	Pas assez de débit carburant	Baisse de débit	2,07E-06
	Trop de débit carburant	Augmentation de débit	1,01E-06
Vanne à air (SAV)	Non Ouverture	Ouverture lente	8,66E-07

Tableau 3 : Causes de non démarrage et dégradations prémices prises en compte par l'algorithme ESC.

I.6.3 DONNEES DISPONIBLES

Plusieurs types de données ont été utilisés au fil de la thèse. Dans un premier temps, un jeu de données de 305 démarrages provenant de tests au banc d'essai a été utilisé [Ausloos, 2010]. Ce jeu de données représentait les seuls démarrages disponibles pour les signaux et mesures considérés. La conception de l'algorithme a été réalisée à l'aide de ce jeu de données et d'expertises métier.

Par la suite un nombre important de données représentant des démarrages en exploitation ont été disponibles. Ces séquences de démarrage ont été acquises sur dix moteurs issus de cinq avions en exploitation [Hmad, 2010a] [Hmad, 2010b]. Elles ont permis d'ajuster les lois d'extraction des huit mesures pour respecter le contexte d'exploitation.

L'ensemble des données d'exploitation regroupe 3594 démarrages. Les huit mesures ont été extraites sur la totalité de la base. Parmi tous ces démarrages, 57 ont présenté des problèmes d'acquisition. Ces démarrages n'étant pas exploitables, ils ont été supprimés de la base.

Le statut de l'ensemble des démarrages est considéré comme sain puisqu'il n'y a pas eu de non démarrage lors de la campagne d'exploitation. Cependant, il est possible que des démarrages plus lents ou plus rapides que d'autres aient eu lieu. Ces démarrages ne sont donc pas considérés comme « parfaitement » sains. Il a donc fallu constituer une base de données saine pour l'apprentissage des modèles des huit mesures sans dégradation. Celle-ci a été constituée en conservant les démarrages dont les mesures sont comprises entre leurs moyennes +/-3 * leur écart-type.

Après application de ce filtre, la base de données des démarrages sains est constituée de 3270 démarrages. Le détail du nombre de démarrages par moteur et par avion est donné dans le Tableau 4 :

Avion n°	Moteur n°	Nombre de démarrages
1	1	352
	2	401
2	1	442
2	2	476
3	1	348
5	2	411
4	1	178
-	2	183
5	1	241
	2	238
-	TOTAL	3270

Tableau 4 : Répartition du nombre de démarrages par moteur et par avion.

La base de données des démarrages sains étant établie, les modèles de régressions de chaque mesure ont été construits. Pour ce faire, une base de données d'apprentissage a été établie. Cette dernière est constituée de 80 démarrages choisis aléatoirement pour chaque moteur. La totalité de la base d'apprentissage est donc de 800 démarrages. Cette base de données n'a été utilisée que pour l'apprentissage des modèles. Les données apprises ne participent donc pas au test des modèles.

La base de test est composée des 2470 démarrages restants. Le score d'anormalité a donc été calculé pour ces démarrages et représente les données de référence de l'étude.

Au vu des probabilités d'occurrence des dégradations (Tableau 3), il n'est pas étonnant que la totalité des données disponibles ne représente que des démarrages sans dégradation. Le fait de disposer d'autant de données dans le cas sans dégradation a permis de caractériser correctement le comportement sain des turboréacteurs. Les détails concernant cette caractérisation sont présentés au paragraphe II.3.3.4.

I.7 SURVEILLANCE DE LA CONSOMMATION D'HUILE

Le suivi de la consommation d'huile est aujourd'hui réalisé lors de l'entretien des turboréacteurs [Nya Djiki, 2010b]. Les compagnies aériennes notent le nombre de cannettes d'huile utilisées à chaque visite pour faire l'appoint (remplissage d'huile). Une cannette contenant 1 litre d'huile, ceci leur permet, d'une part, de déterminer la consommation moyenne des vols effectués depuis le dernier appoint, et d'autre part, d'identifier une dérive de consommation.

La détection opérationnelle d'une fuite majeure du circuit de lubrification est basée simplement sur un seuil qui correspond à un niveau bas du réservoir (capacité de 22 litres). Ce niveau, lorsqu'il est atteint, donne lieu à une alerte.

Le système de surveillance de la consommation d'huile (Engine Oil consumption - EOC) permet d'améliorer le suivi de la consommation d'huile de manière automatique afin de détecter au plus tôt d'éventuelles consommations anormales. Cela représente un enjeu majeur dans le sens où une dégradation de l'état de santé du système de lubrification a une conséquence non négligeable sur le fonctionnement du turboréacteur.

La surveillance de la consommation d'huile se base sur le suivi du niveau d'huile dans le réservoir. La situation idéale consiste en une diminution régulière du niveau d'huile dans le réservoir au cours des

vols indiquant directement la consommation en huile du turboréacteur. Cette situation n'est malheureusement pas représentative de la réalité car intervient un phénomène dit de « gulping ».

Le « gulping » désigne la masse d'huile présente dans le turboréacteur mais non contenue dans le réservoir. C'est la quantité d'huile contenue dans les trois circuits constituant le réseau de distribution d'huile ainsi que dans les enceintes, les échangeurs et les filtres (cf. ANNEXE - 1). Le terme « gulping » traduit le fait qu'une proportion de l'huile initialement contenue dans le réservoir se retrouve dans le circuit de lubrification. La mesure du niveau d'huile (dans le réservoir) seule, n'est donc pas fiable car elle ne tient pas compte de la rétention d'huile dont l'importance est variable. Au cours d'un même vol le « gulping » varie principalement en fonction [Hmad, 2010c] :

- du régime moteur : plus le régime augmente, plus le débit d'alimentation en huile augmente. Il s'ensuit une augmentation de la quantité d'huile dans les enceintes et donc une baisse du niveau d'huile dans le réservoir.
- de la température d'huile : une hausse de la température fluidifie l'huile ce qui favorise son écoulement le long des enceintes et canalisations et diminue donc la rétention d'huile.

Ces effets se combinent et conduisent par exemple à une augmentation du niveau d'huile dans le réservoir lorsque la température augmente. Il est donc nécessaire de prendre en considération le « gulping » pour une estimation correcte de la consommation d'huile.

La prise en compte du « gulping » dans l'estimation de la consommation d'huile peut être réalisée de deux manières. La première consiste à estimer le « gulping ». Au vu des considérations ci-dessus, cela est difficile. La seconde, choisie par les concepteurs, consiste à s'affranchir de la modélisation du « gulping » en estimant la consommation d'huile à partir de niveaux d'huile dans des conditions standardisées : iso température, iso régime et iso contexte d'exploitation.

Le principe de surveillance de la consommation d'huile est présenté en section I.7.1. Les causes de consommations anormales prises en charge par l'algorithme sont décrites en section I.7.2. La section I.7.3 présente les données disponibles.

I.7.1 DESCRIPTION

Le principe de surveillance de la consommation d'huile, présenté Figure 7, se base sur le suivi de l'évolution du niveau d'huile, à iso régime et iso température, sur plusieurs vols, pour un contexte d'exploitation commun [Hmad, 2010c]. Ce principe permet de s'affranchir de l'estimation du « gulping » et permet une meilleure estimation de la consommation d'huile par rapport à une estimation moyenne à chaque entretien des turboréacteurs.



Figure 7 : Principe de surveillance de la consommation d'huile.

L'évolution, sur plusieurs vols, du niveau d'huile mesuré est déterminée au sol. Les niveaux d'huile au sol sont extraits :

- pour une valeur du régime moteur égale à 60% du régime maximum,
- pour une température d'huile de 100°C. Il arrive toutefois que la température d'huile n'ait pas atteint les 100°C. Le niveau d'huile est, dans ce cas, recalé en fonction de la température à l'aide d'un modèle tabulé [Hmad, 2010c].

Des mesures après atterrissage d'un vol et avant décollage du vol suivant sont réalisées. A priori, une mesure à chaque ralenti sol (iso régime) après atterrissage à une température de référence donnée (iso température) serait suffisante au suivi de la consommation d'huile. Cependant, une autre mesure à chaque ralenti sol avant décollage du vol suivant est nécessaire afin de détecter tout remplissage d'huile effectué par le service de maintenance entre deux vols successifs.

La plupart des compagnies aériennes utilisent des cannettes de lubrifiant mais d'autres utilisent des pompes à huile. Le moment et la quantité du remplissage du réservoir sont des données non disponibles. L'une des fonctions de l'algorithme consiste donc à détecter des remplissages. La détection d'un remplissage est faite par comparaison des niveaux d'huile après atterrissage et avant le décollage suivant (Figure 8). Tout écart supérieur à 0,5 l est suffisant pour détecter un remplissage.



Figure 8 : Extrait de niveaux d'huile après atterrissage et avant décollage avec identification de deux remplissages.

La quantification du volume d'huile rajouté lors du remplissage est faite a posteriori, après la détection des remplissages. Elle est estimée par calcul de la différence d'ordonnées entre les droites de régression des niveaux d'huile inter-remplissages (Figure 9).



Figure 9 : Exemple de quantification de remplissage

Une fois les remplissages détectés et quantifiés, ils sont utilisés pour corriger les niveaux d'huile. La correction des niveaux d'huile consiste à retrancher la quantité d'huile estimée pour chaque remplissage aux niveaux d'huile mesurés (Figure 10). Après correction des niveaux d'huile, l'estimation de la consommation consiste à déterminer la pente de la droite de régression des niveaux d'huile échantillonnés sur plusieurs vols.



Figure 10 : Niveau d'huile corrigé des remplissages

La consommation d'huile nominale est de l'ordre de 0,2 l/h. Selon le moteur, cette valeur peut être légèrement différente. Deux niveaux de consommation sont considérés dans le manuel de maintenance [Nya Djiki, 2010b]:

- consommation anormale : 0,38 l/h
- consommation fortement dérivante : 0,76 l/h

La consommation d'huile estimée sert d'indicateur pour l'état de santé du système de lubrification. Cet indicateur est utilisé par les fonctions de détection et de pronostic afin de déceler et prévenir des consommations anormales.

L'algorithme de surveillance de la consommation d'huile permet ainsi de garantir l'état de santé du système de lubrification en surveillant les différentes causes possibles de consommation anormale. Ces causes sont présentées dans le paragraphe suivant.

1.7.2 CAUSES DE CONSOMMATIONS ANORMALES

Lors du fonctionnement normal du moteur, le système consomme de l'huile. Cette consommation normale est due principalement aux déshuileurs qui rejettent de l'huile dans l'atmosphère. Une autre cause de consommation d'huile normale, dans une moindre mesure, est la perte d'huile à travers les joints d'étanchéité des enceintes du moteur. Lorsque cette consommation est régulière, elle traduit le bon état de santé du système de lubrification. En revanche, une surconsommation d'huile peut être symptomatique d'un fonctionnement dégradé du système.

Le Tableau 5 présente les principales causes de consommations anormales ainsi que leurs prémices (lorsqu'elles existent) [Hmad, 2010d].

L'algorithme de surveillance de la consommation d'huile permet de suivre près de 90% des causes de consommations anormales. D'après l'expérience des experts, ces consommations anormales peuvent évoluer de façon soudaine ou graduelle jusqu'à franchir les seuils de consommations anormale (0,381/h) et fortement dérivante (0,761/h).

Selon les experts, l'évolution graduelle de consommation se traduit par une hausse de la consommation de l'ordre de 0,1 l/h/mois. Cela n'a pas encore été observé sur les données recueillies malgré leur volume important. Cette information est importante car elle permet de modéliser le processus d'évolution de la consommation en cas de dégradation dans 90% des cas. Elle a donc été utilisée par la suite pour modéliser l'évolution de consommations anormales en vue de l'estimation des performances de la fonction de pronostic.

Cause de consommation anormale	Effets opérationnels	Prémices	Occurrence (%)
Fuite enceinte	Carburant dans l'huile	Hausse du niveau et de la température d'huile dans le réservoir	10%
Usure labyrinthe Crique des tubes de récupération	Hausse de consommation graduelle	Haussa da la	80%
Rupture paliers moteurs ou pompes de récupération ou tubes de récupération	Hausse de consommation soudaine	consommation d'huile	5%
Rupture paliers moteurs	Consommation supérieure à 0,76 l/h		4%
Rupture de la pompe d'alimentation	Alarme basse pression	Pas de prémices	0,90%
Rupture gicleur huile			0,10%

Tableau 5 : Causes de consommations anormales et prémices prises en charge par EOC.

I.7.3 DONNEES DISPONIBLES

Les données disponibles pour l'algorithme de surveillance de la consommation d'huile sont issues des mêmes moteurs et avions que pour l'algorithme de surveillance de la séquence de démarrage. Elles sont constituées de cycles de vols (décollage, croisière, atterrissage) sur dix moteurs issus de cinq avions.

Le volume de données est synthétisé par moteur et par avion dans le Tableau 6 [Hmad, 2011b].

Avion n°	Moteur n°	Nombre de cycles
1	1	426
1	2	426
2	1	512
	2	512
3	1	236
5	2	236
4	1	224
	2	224
5	1	287
	2	287
	Total	3370

Tableau 6 : Répartition du nombre de cycles par avion et par moteur.

Au cours de l'exploitation aucune consommation anormale n'a été observée. L'ensemble des consommations d'huile estimées, à partir des données disponibles, ne représente que des consommations normales.

I.8 CONCLUSION

Avec le contexte de hausse du trafic aérien, la disponibilité des appareils constitue un enjeu majeur pour les compagnies aériennes. Pour réduire au maximum les indisponibilités non programmées, les pannes de type « no go », impactant la décision de décollage des appareils, font l'objet de surveillances.

Des systèmes de surveillance ont été développés par Safran Snecma dans le cadre du PHM. L'introduction de ces systèmes de surveillance en exploitation ne peut être réalisée qu'après avoir atteint un certain niveau de maturité. Le niveau de maturité requis avant mise en exploitation repose sur des exigences de performance. Pour atteindre ce niveau et ainsi répondre aux exigences de performances, une procédure de maturation est appliquée aux systèmes de surveillance.

Les systèmes de surveillance sont structurés selon l'architecture OSA-CBM. L'acquisition et la manipulation des données (couches 1 et 2 de l'architecture OSA-CBM) sont spécifiques à chaque système de surveillance. En revanche, la détection et le pronostic (couches 3 et 5 de l'architecture OSA-CBM) sont génériques. La maturation s'intéresse à ces fonctions génériques constituant les systèmes de surveillance.

La maturation a été réalisée à partir des fonctions génériques considérées telles que conçues et de données principalement sans dégradation. Les données disponibles ne sont pas faciles d'accès et nécessitent une analyse rigoureuse avant leur utilisation.

Le point clé de la maturation des systèmes de surveillance étant l'évaluation de leurs performances, cette thèse a consisté à formaliser le problème d'estimation, d'analyse et d'amélioration des performances de ces systèmes. Il est important de noter que la thèse ne consiste pas à mettre en place des systèmes de surveillance ou de nouvelles fonctions de détection et de pronostic. L'objectif est d'estimer, analyser puis améliorer les performances des systèmes de surveillance existants pour répondre aux exigences des compagnies aériennes.

L'évaluation des performances étant étroitement liée aux fonctions à maturer, le chapitre II s'intéresse aux indicateurs de performances utilisés dans le cadre de la détection et du pronostic et établit leurs méthodes d'estimation.

II Performances de détection et de pronostic

II.1 INTRODUCTION

L'objectif de ce chapitre est dans un premier temps d'identifier les exigences de performance des compagnies aériennes concernant la détection et le pronostic. Cette première étape permet ensuite d'identifier les indicateurs de performance à utiliser puis d'établir leurs méthodes d'estimation.

La section II.2 présente en deux parties les exigences des compagnies aériennes concernant d'une part la détection et d'autre part le pronostic.

Pour la détection (section II.3), les indicateurs de performance issus de la littérature et du domaine aéronautique sont présentés section II.3.1. Après la sélection des indicateurs de performances « pertinents », la façon de les estimer est présentée en section II.3.2. La méthode d'estimation nécessitant la connaissance de la statistique de décision et la présence de dégradations, ces étapes sont détaillées respectivement en sections II.3.3 et II.3.4.

Concernant le pronostic (section II.4), les indicateurs de performances issus de la littérature et du domaine aéronautique sont présentés en section II.4.2. En l'absence de données évoluant jusqu'à la défaillance, des trajectoires d'évolution sont simulées pour estimer les performances de la fonction de pronostic. La section II.4.3 présente des modèles de dégradation nécessaires pour générer ces trajectoires. La section II.4.4 présente, quant à elle, la méthode d'estimation des performances de pronostic.

II.2 EXIGENCES DE PERFORMANCE

Dans la perspective de maturation des fonctions de détection et de pronostic, la première phase est l'identification des caractéristiques attendues pour ces fonctions en se référant aux exigences des compagnies aériennes.

Pour déterminer ces exigences, les représentants du client (Voice Of Customer - VOC) [Lecerf, 2009] et les représentants du commerce (Voice Of Business - VOB) [Hussenet, 2009] ont été interviewés. Ces interviews ont été retranscrites sous forme de graphiques afin d'identifier les exigences communes aux représentants VOC et VOB [Hmad, 2012a]. La Figure 11 représente cette retranscription.

Ces interviews ont permis d'expliciter les exigences attendues [Hmad, 2009] :

- pour la fonction de détection, elles s'expriment en termes de proportion de bonne détection et de proportion d'alarmes fausses. Il est souhaité que la proportion de bonne détection soit maximale tout en ayant au plus 1% d'alarmes fausses (respectivement, 50%) lorsqu'il s'agit de dégradations de fortes intensités (respectivement, de faibles intensités).
- pour la fonction de pronostic, de façon analogue à la fonction de détection, il est souhaité que le nombre de prédictions donnant lieu à des déposes justifiées soit maximum tout en évitant un trop grand nombre de prédictions donnant lieu à des déposes non justifiées. L'objectif est d'être le plus précis possible en respectant un horizon temporel correspondant à un délai opérationnel permettant de planifier des actions de maintenance « juste à temps ».



Figure 11: Approche VOC - VOB

II.3 DETECTION

II.3.1 INDICATEURS DE PERFORMANCES

II.3.1.1 Dans la littérature

Il existe un nombre important de méthodes de détection associées à différents problèmes. Les indicateurs de performances utilisés ne sont pas conditionnés par la méthode de détection mais par le nombre d'hypothèses considérées pour chaque problème [Zwingelstein, 1995].

Dans le cadre d'un problème à deux hypothèses : H0 (absence de dégradation) et H1 (présence de dégradation), deux décisions sont possibles : D0 (décider l'absence de dégradation) et D1 (décider la présence de dégradation). Au final, quatre cas de figure sont envisageables [Vachtsevanos, 2006] :

- décider H0 alors que H0 est vraie (D0/H0),
- décider H1 alors que H0 est vraie (D1/H0),
- décider H0 alors que H1 est vraie (D0/H1),
- décider H1 alors que H1 est vraie (D1/H1).

Au vu de ces différents cas de figure, les caractéristiques statistiques d'une fonction de détection les plus souvent utilisées sont les suivantes [Basseville, 1993] [Zwingelstein, 1995] [Vachtsevanos, 2006]:

- probabilité de fausse alarme (α) ou erreur de première espèce, P(D1/H0),
- probabilité de non détection ou erreur de seconde espèce, P(D0/H1),
- précision, P(D1∩H1) + P(D0∩H0) : elle permet de quantifier la capacité d'un détecteur de ne pas se tromper. Il est important de noter que si P(H1) est très petite, on peut aboutir à décider H0 tout le temps,
- retard moyen à la détection : temps entre l'apparition d'une anomalie et sa détection.

Les exigences relatives aux fonctions de détection se formulent souvent en valeur maximum de probabilité de fausse alarme et probabilité de non détection. Cependant, les deux probabilités ne peuvent pas être arbitrairement faibles, il est nécessaire de trouver un compromis entre ces deux types d'erreur.

Un bon détecteur est celui qui présente la meilleure validité intrinsèque. La validité intrinsèque d'un détecteur est représentée par le couple probabilité de fausse alarme et probabilité de bonne détection (PoD=P(D1/H1)). Ces deux grandeurs sont souvent synthétisées sur un même graphique appelé courbe COR - Caractéristiques Opérationnelles de Réception (Figure 12).



Figure 12: Courbe COR- Caractéristiques Opérationnelles de Réception

Dans le cadre d'un problème à plus de deux hypothèses, une matrice dite de confusion est généralement utilisée afin d'évaluer les performances. Les lignes correspondent aux décisions (Di), les
colonnes correspondent aux hypothèses (Hj) et dans chaque case on trouve la valeur P(Di/Hj). Elle permet d'analyser les performances du classifieur et d'estimer la proportion de bonne ou de mauvaise classification.

II.3.1.2 Dans le domaine aéronautique

Les indicateurs de performances utilisés dans le domaine aéronautique répondent à des exigences opérationnelles énoncées par les compagnies aériennes.

De façon classique, la **probabilité de bonne détection** – (*PoD*) est utilisée. Elle représente la probabilité de détecter une anomalie sachant qu'il existe une dégradation - P(Détection|Dégradation). L'exigence de bonne détection est établie pour différentes intensités de dégradation :

- une dégradation de faible intensité liée à un délai potentiel long avant une panne permet d'ajuster le stock des pièces de rechange. La détection d'une telle intensité est importante pour les services opération des compagnies aériennes.
- une dégradation de forte intensité liée à un délai potentiel court avant une panne permet d'ajuster la planification de la maintenance. Cela est crucial pour la maintenance en ligne.

Quelle que soit l'intensité de la dégradation, il est souhaité que la proportion de bonne détection soit maximale, idéalement proche de 100%.

De façon moins classique, un autre indicateur est utilisé. Il s'agit de la **probabilité d'alarmes fausses** qui représente la probabilité d'avoir un système sain sachant qu'une dégradation a été détectée - P(Sain/Détection). Elle porte sur la proportion de décisions erronées lors des détections d'anomalie et non sur l'erreur de première espèce. Avec ce critère, on fixe le seuil en fonction de la probabilité dédetection erronée. Il en résulte que le fait d'exiger 1% d'alarmes fausses consiste à ne pas tolérer plus d'une alarme fausse toutes les 100 décisions d'alarmes. Cela est différent du fait de ne pas tolérer plus d'une alarme fausse tous les 100 observations (erreur de première espèce). L'erreur de première espèce (α) représente la probabilité de détecter une anomalie sachant que le système est sain – P(Détection/Sain).

A partir de cette formalisation statistique, le théorème de Bayes a été utilisé pour déterminer P(Sain|Détection).

D'après le théorème de Bayes,

$$P(Sain|Détection) = \frac{P(Détection|Sain)P(Sain)}{P(Détection)}$$

D'après le théorème des probabilités totales,

$$P(Détection) = P(Détection|Sain)P(Sain) + P(Détection|Dégradation)P(Dégradation)$$

A partir de ces éléments,

$$P(Sain|Détection) = \frac{P(Détection|Sain)P(Sain)}{P(Détection|Sain)P(Sain) + P(Détection|Dégradation)P(Dégradation)}$$

En posant :

$$\alpha = P(D\acute{e}tection|Sain)$$

et

$$PoD = P(Détection | Dégradation)$$

On obtient :

$$P(Sain|Détection) = \frac{\alpha.P(Sain)}{\alpha.P(Sain) + PoD.P(Dégradation)} = \frac{\alpha.(1 - P(Dégradation))}{\alpha.(1 - P(Dégradation)) + PoD.P(Dégradation)}$$
(1)

La définition de P(Sain/Détection) repose sur P(Dégradation), α et PoD. Il est à noter que α et PoD ne sont pas indépendants et dépendent du détecteur. La valeur de P(Dégradation) est estimée à partir des AMDEC (Analyse des Modes de Défaillance de leurs Effets et de leur Criticié) réalisées pour la conception des algorithmes de surveillance. Le Tableau 3 donne les valeurs des probabilités de dégradations pour le système de surveillance de la séquence de démarrage. Dans le cadre de la thèse, α et PoD représente un couple dont les valeurs dépendent d'un seuil. Lorsque le seuil est connu, l'estimation des performances est aisée. Dans le cas contraire, une méthode doit être mise en place pour le déterminer et estimer les performances. La section II.3.2 décrit la procédure à suivre permettant l'estimation des performances quand le seuil est connu et quand il ne l'est pas.

II.3.2 METHODES D'ESTIMATION

II.3.2.1 Introduction

Quelle que soit l'approche de détection utilisée, un indicateur de l'état de santé du système sous surveillance (score ou indicateur d'anormalité) est produit par le système de surveillance considéré. Les performances de détection reposent sur une règle de décision à appliquer à la statistique de décision (indicateur de l'état de santé) afin de décider de la présence ou non d'un dysfonctionnement ou d'une anomalie.

Dans le cadre de la thèse, nous nous intéressons à l'estimation des performances d'un détecteur binaire dans \mathbb{R} . Cela implique le fait de décider entre deux hypothèses *H0* (absence de dégradation) et *H1* (présence de dégradation) à l'aide d'un seuil (Figure 13).



Figure 13: Exemple de probabilité de fausse alarme et non détection

Pour une configuration donnée de H0 et de H1, il est possible de tracer la courbe COR correspondante.

Comme P(Sain/Détection) est exprimé en fonction de α , il est donc possible d'exprimer α en fonction de P(Sain/Détection). En considérant que P(Sain) = 1 - P(Dégradation), l'expression de α en fonction de P(Sain/Détection) est :

$$\alpha = \frac{P(Sain|Détection)}{1 - P(Sain|Détection)} PoD \frac{P(Dégradation)}{1 - P(Dégradation)}$$
(2)

A partir de cette relation, il est possible de tracer α , sous forme d'une droite, pour *PoD* variant de 0 à 1, *P*(*Sain*/*Détection*) fixée par VOC et *P*(*Dégradation*) estimée à partir de données métier. Cela a été représenté sur la Figure 14 pour deux cas de figure, cas 1 (PoD=K1. α) et cas 2 (PoD=K2. α),

CONFIDENTIEL INDUSTRIE

dépendants des valeurs de P(Sain/Détection) et P(Dégradation). En admettant qu'on souhaite au minimum 99% de bonne détection, la Figure 14 permet d'observer s'il existe au moins une solution réalisable. Pour une configuration de P(Sain/Détection) et P(Dégradation) donnée, le cas 1 admet plusieurs solutions. La solution retenue (intersection marquée d'un rond) permet de déterminer la valeur de α qui maximise PoD sans être inférieure à 0,99. En revanche, pour une autre configuration de P(Sain/Détection) et P(Dégradation), le cas 2 n'admet pas de solutions permettant de respecter PoD > 0,99. Dans ce cas, quelle que soit la solution retenue, les performances obtenues sont loin de celles escomptées. Une procédure d'estimation des performances a été proposée et est présentée dans la sous-section suivante.



Probabilité de fausse alarme (α)

Figure 14 : Détermination de α à partir de l'équation (2) et d'une courbe COR.

II.3.2.2 Procédure d'estimation

L'estimation des performances de détection peut être réalisée selon deux cas de figure : soit la valeur du seuil est connue, soit la valeur du seuil n'est pas connue.

Quand la valeur du seuil est connue, il suffit d'appliquer le seuil à la distribution de la statistique de décision sans dégradation pour en déduire une estimation de α ($\hat{\alpha}$). L'estimation de PoD (PoD) est obtenue en appliquant le seuil à la distribution de la statistique de décision avec dégradation.

Il apparait que $\hat{\alpha}$ et \widehat{PoD} nécessitent de connaitre la distribution de la statistique de décision sous H0 et sous H1. Toutefois, l'estimation de la distribution de la statistique de décision sous H1 n'est pas indispensable. Comme PoD est en général souhaité assez grande, son estimation empirique par comptage ne pose pas de problèmes majeurs. L'estimation empirique de PoD est réalisée par comptage, dans un environnement supervisé, à l'aide de l'équation (3). Cela implique donc la présence de dégradations. Dans les applications considérées, il n'y avait pas de dégradation. Elles ont donc été simulées, ce qui a permis de se placer dans un environnement supervisé.

$$\widehat{PoD} = \frac{card(dégradation \ tel \ que \ score \ d' \ anormalité \ > \ seuil \ de \ détection)}{card(dégradation)}$$
(3)

Lorsque *PoD* est estimée, il est possible d'estimer $\hat{P}(Sain/Détection)$ à partir d'une estimation de la relation (1) :

$$\hat{P}(Sain|D\acute{e}tection) = \frac{\hat{\alpha}(1 - P(degradation))}{\hat{\alpha}(1 - P(degradation)) + (\widehat{PoD})P(degradation)}$$
(4)

En revanche pour estimer α , lorsque α est petit et le nombre d'exemples limité, l'estimation empirique a une grande variance relative.

Quand la valeur du seuil est inconnue, il est nécessaire de la déterminer.

Si la priorité accordée à α et à *PoD* est identique, le seuil peut être déterminé à l'aide d'une courbe COR. Il suffit de déterminer la valeur du seuil qui optimise le compromis entre les deux exigences. Pour cela, il faut définir une fonction risque au sens de Bayes pour le choix du compromis [Basseville, 1993] [Zwingelstein, 1995]. Une fois le seuil déterminé, l'estimation des performances est réalisée comme expliqué précédemment à l'aide des équations (3) et (4).

Si l'exigence sur α est prioritaire à celle sur *PoD*, le seuil est déterminé à partir de la distribution de la statistique de décision sous *H0* pour respecter l'exigence sur α . Dans le cas contraire, le seuil est déterminé à partir de la distribution de la statistique de décision sous *H1* pour respecter l'exigence sur *PoD*. Dans ces cas de figure, la théorie du test de Neyman Pearson peut être utilisée [Basseville, 1993] [Zwingelstein, 1995]. Une fois le seuil déterminé, l'estimation des performances est réalisée comme expliqué précédemment à l'aide des équations (3) et (4).

Dans le cadre de la thèse, le seuil est inconnu et l'exigence porte sur les alarmes fausses. L'objectif a alors été de déterminer le seuil de détection à partir de la valeur de α obtenue à partir de la relation (2). La procédure a consisté à faire l'hypothèse qu'on est capable de respecter les exigences et fixer *PoD* à $PoD_{exigée} = 0,99$, P(Sain/Détection) à $P(Sain/Détection)_{exigée} = 0,01$ et P(Dégradation) en fonction des valeur issues des AMDEC. A partir de ces valeurs et de l'équation (2), $\alpha_{exigée}$ est calculée. Cela permet de déterminer le seuil de détection en recherchant le quantile correspondant à $\alpha_{exigée}$ sur la distribution de la statistique de décision sous H0. \widehat{PoD} est déterminer P(Sain/Détection) à partir de l'équation (3). Enfin les estimations réalisées permettent de déterminer P(Sain/Détection) à partir de l'équation (4).

Présentée ainsi, l'estimation des performances du détecteur peut paraitre simple. Cela est vrai lorsque tous les éléments nécessaires à l'estimation sont disponibles comme le fait de connaitre la distribution de la statistique de décision sous H0 et de disposer d'observations avec dégradation. Or ce n'est généralement pas le cas. Dans le domaine aéronautique, les données disponibles sous H0 peuvent être nombreuses. En revanche, il est rare de disposer de données sous H1. Dans ce cas, des dégradations sont simulées.

Au vu de ces éléments, la procédure d'estimation devient :

- estimer la distribution de la statistique de décision à partir d'observations sans dégradation issues des données disponibles.
- fixer $PoD \ge PoD_{exigée} = 0,99$, $P(Sain/Détection) \ge P(Sain/Détection)_{exigée} = 0,01$ et P(Dégradation) en fonction des valeur issues des AMDEC.
- calculer $\alpha_{\text{exigée}}$ à partir de l'équation (2).
- déterminer le seuil de détection en recherchant le quantile correspondant à $\alpha_{exigée}$ sur la distribution de la statistique de décision sous *H0*.
- générer des dégradations à partir des données disponibles sous *H0* et des connaissances d'experts sur les dégradations.
- déterminer \widehat{PoD} à partir du seuil de détection et de l'équation (3).
- déterminer $\hat{P}(Sain|Détection)$ à partir de l'équation (4).

Il apparait clairement qu'il est impossible d'estimer les performances du détecteur sans connaitre la distribution de la statistique de décision sous *H0*. Cette dernière étant inconnue, la section II.3.3 présente différentes méthodes pour l'estimer. Une application à la séquence de démarrage est présentée en section II.3.3.4.

II.3.3 DISTRIBUTION DE LA STATISTIQUE DE DECISION

II.3.3.1 Introduction

Pour estimer les performances du détecteur, il est nécessaire de déterminer un seuil de détection. Pour ce faire, il est possible de procéder de deux façons. La première consiste à estimer la densité de probabilité de la statistique de décision de manière globale et de travailler avec cette estimation. Dans ce cas, des méthodes paramétrique et non paramétrique d'estimation de densités sont utilisées. Une description est réalisée en section II.3.3.2. La seconde consiste à n'estimer que la queue de distribution de la statistique de décision. Dans ce cas, la théorie des valeurs extrêmes est utilisée. Elle permet d'estimer des queues de distributions pour déterminer des seuils correspondant à des quantiles extrêmes (probabilité d'événements rares...). Elle est présentée en section II.3.3.3.

Ces deux méthodes sont appliquées en section II.3.3.4 dans le cadre de la surveillance de la séquence de démarrage pour déterminer la distribution du score d'anormalité.

II.3.3.2 Estimation de densité de probabilité

Deux types d'approche d'estimations de densité de probabilité sont rencontrés classiquement dans la littérature : l'approche paramétrique et l'approche non-paramétrique.

L'approche paramétrique suppose que les données disponibles sont issues d'une loi de probabilité de forme connue dont seuls les paramètres sont inconnus [Silverman, 1986]. Dans ce cas, l'estimation de densité se résume à l'estimation des paramètres de la distribution.

En pratique, il n'est pas aisé de connaitre la distribution de la statistique de décision en raison de la complexité des systèmes surveillés. C'est pourquoi l'approche non paramétrique qui cherche plutôt à estimer la distribution globale sans a priori est souvent utilisée.

L'absence d'a priori sur la distribution, ne conditionne pas pour autant l'utilisation de l'approche non paramétrique. Une pratique courante dans le domaine de la Maitrise Statistique des Processus (MSP) consiste à convertir un échantillon d'observations dont la distribution est inconnue en une distribution gaussienne à l'aide d'une fonction de transformation de type lognormale, Box-Cox ou Johnson [Pillet, 2005]. Cela permet de se retrouver dans le cas de l'approche paramétrique.

Ces différentes approches sont présentées dans les paragraphes suivants.

II.3.3.2.1 Approche paramétrique

L'approche paramétrique a l'avantage d'être simple puisqu'il s'agit d'estimer les paramètres d'une distribution connue. En revanche, elle a comme principal inconvénient le fait de nécessiter une forte connaissance a priori sur la loi de probabilité de la statistique de décision considérée. Cette connaissance n'est malheureusement pas aisée surtout lorsqu'il s'agit de systèmes complexes comme les turboréacteurs d'un avion.

Une fois la distribution a priori choisie, l'estimation des paramètres peut être réalisée selon différentes méthodes. Les deux méthodes les plus usuelles sont la méthode des moments et la méthode du maximum de vraisemblance. Quelle que soit la méthode utilisée, l'estimation est d'autant meilleure que la taille de l'échantillon considéré est grande et que cet échantillon est représentatif.

II.3.3.2.1.1 Méthode des moments

La méthode des moments est la méthode formalisée la plus naturelle [Lagrange, 1776]. Elle consiste à estimer les paramètres recherchés en égalisant certains moments théoriques (qui dépendent de ces paramètres) avec leurs contreparties empiriques. On est donc amené à résoudre un système d'équations. Cela revient donc à estimer l'espérance de la distribution à l'aide d'une moyenne

empirique, de même pour la variance de la distribution par une variance empirique grâce à un échantillon d'observations.

II.3.3.2.1.2 Méthode du maximum de vraisemblance

La méthode du maximum de vraisemblance a été développée par Ronald Aylmer Fisher en 1912 [Fisher, 1912] sous le nom de « critère absolu ». Ce n'est qu'à partir de 1922 qu'elle fut appelée maximum de vraisemblance [Fisher, 1922] [Aldrich, 1997] [Stigler, 2007]. Elle consiste, étant donné un échantillon, à prendre comme estimation des paramètres de la distribution les valeurs qui rendent maximale la vraisemblance. Cela est réalisé en annulant les dérivées partielles de la vraisemblance pour identifier les paramètres. La vraisemblance étant un produit (sous l'hypothèse d'indépendance), il est fréquent de maximiser le logarithme de la fonction de vraisemblance (log-vraisemblance) [Saporta, 2011].

Dans certains cas, comme celui de la loi Gamma ou de la loi de Weibull..., les racines des dérivées partielles de la vraisemblance ne peuvent être obtenues que numériquement par approximations successives. Dans ce cas, des méthodes d'approximation numérique de types Newton-Raphson [Lagrange, 1826] sont utilisées. Ces méthodes nécessitant une initialisation, la méthode des moments peut être utilisée comme point de départ pour maximiser la (log-) vraisemblance.

L'estimateur du maximum de vraisemblance est convergent, asymptotiquement efficace, asymptotiquement distribué selon une loi normale et asymptotiquement sans biais. Pour toutes ces raisons il est très utilisé.

II.3.3.2.1.3 Méthode de transformation de données

Lorsque la distribution d'une variable aléatoire X est inconnue, une transformation de la forme Y=f(X) peut être utilisée afin d'obtenir une distribution normale. Après la transformation, l'estimation des paramètres de la loi normale de Y est effectuée comme expliqué précédemment.

Il existe plusieurs transformations pour passer d'un échantillon de distribution inconnue à un échantillon de distribution normale telle que la transformation lognormale, la transformation Box-Cox et la transformation de Johnson [Pillet, 2005] [Johnson, 1949] [Slifker, 1980] [Chou, 1998] [Li, 2009].

La **transformation lognormale** est simple à utiliser car elle ne nécessite pas le recours à de nombreuses tables. L'hypothèse est qu'en prenant le logarithme de chaque observation d'un échantillon, on obtient une variable aléatoire gaussienne. La formule de transformation est la suivante : Y = log(X).

La **transformation Box-Cox** consiste à rechercher une transformation du type $Y = X^{\lambda}$ permettant de se ramener à une loi normale. La valeur de λ la plus appropriée est celle qui permet de minimiser les écarts entre les observations transformées et la droite de Henry. La droite de Henry est une méthode graphique pour ajuster une distribution gaussienne à celle d'une série d'observations. Elle est utilisée, dans notre cas, afin de tester si les observations transformées suivent une loi normale.

La **transformation de Johnson** est une fonction paramétrable permettant de convertir une large classe de variable aléatoire X en variable aléatoire normale. Cette transformation regroupe en fait trois transformations s'appliquant à différentes classes de variables aléatoires X. Les transformations de base sont appelées SB, SL et SU. Elles s'appliquent à des variables aléatoires X qui sont respectivement : bornée, distribuée selon une loi log-normale, ou non bornée.

Le Tableau 7 présente les expressions analytiques des trois familles et les conditions sur leurs paramètres.

Famille de transformation	Formule de transformation	Conditions sur les paramètres
SL (LogNormal)	$V = v \pm n \ln(Y - c)$	$\eta, \gamma > 0$
SL (Logivormal)	$1 = \gamma + \eta \cdot in(\chi - \varepsilon)$	$\varepsilon < x$
SB (Bounded)	$V = v + n \ln \left(\frac{X - \varepsilon}{2} \right)$	$\eta, \gamma > 0$
	$1 = \gamma + \eta . \ln\left(\frac{1}{\lambda + \varepsilon - X}\right)$	$\varepsilon < x < \lambda + \varepsilon$
SU (Unbounded)	$Y = \gamma + \eta. ArcSinH\left(\frac{X-\varepsilon}{\lambda}\right)$	$\eta, \gamma > 0$

Tableau 7: Formules associées aux trois types de transformation de Johnson.

Pour une variable aléatoire X, il n'y a aucun moyen direct de choisir, parmi les transformations, laquelle s'applique. [Slifker, 1980] a défini une règle heuristique se basant sur le ratio de quantiles (QR) permettant de choisir entre SB, SL et SU mais sans préciser comment choisir les quantiles x_1 , x_2 , x_3 et x_4 de la distribution de X.

$$QR = \frac{(x_4 - x_3)(x_2 - x_1)}{(x_2 - x_4)^2}$$
(5)

Toutefois, les quatre quantiles doivent être choisis symétriquement de façon à respecter les contraintes suivantes :

 $x_1 = -3\rho$, $x_2 = -\rho$, $x_3 = \rho$ et $x_4 = 3\rho$.

Plusieurs transformations sont effectuées pour chaque valeur de ρ appartenant à [0,25; 1,25]. Pour sélectionner la meilleure valeur de ρ , dans [Slifker, 1980], les auteurs proposent d'utiliser le test de normalité de Shapiro et Wilk [Shapiro, 1965]. La valeur ρ^* qui donne le meilleur ajustement est alors choisie comme valeur optimale de ρ . En se basant sur la valeur obtenue de QR, le choix de transformation est le suivant :

- si QR < 1 choix de la transformation SB
- si QR = 1 choix de la transformation SL
- si QR > 1 choix de la transformation SU

Une fois que la meilleure transformation de Johnson a été déterminée, elle est utilisée pour transformer la variable aléatoire *X* afin d'obtenir une nouvelle variable *Y* distribuée selon une loi normale.

II.3.3.2.2 Approche non paramétrique

Contrairement à l'approche paramétrique, aucune hypothèse de loi n'est faite. L'approche nonparamétrique estime la densité de probabilité directement à partir de l'information disponible sur un ensemble d'observations. Il est dit que, dans cette approche, les données parlent d'elles-mêmes [Silverman, 1986].

II.3.3.2.2.1 Estimation de densité par histogramme

L'une des premières méthodes d'estimation de densité à être utilisée est l'histogramme. L'origine de l'histogramme est attribuée à John Graunt au XVIIe siècle répondant à l'objectif d'une représentation de la distribution de valeurs [Lejeune, 2010].

Une densité de probabilité peut être vue comme la limite d'un histogramme lorsque le nombre d'observations (*n*) tend vers l'infini et que le pas de l'histogramme (*h*) tend vers zéro. La fonction de densité de probabilité s'écrit alors de la façon suivante [Silverman, 1986] [Alpaydin, 2010] :

$$\hat{f}(x) = \frac{nombre \ de \ valeurs \ dans \ la \ même \ classe \ que \ x}{n.h}$$
(6)

avec n la taille de l'échantillon et h la largeur des classes (pas de l'histogramme).

L'estimation de densité par histogramme possède deux grands inconvénients :

- il faut choisir une origine x_0 pour chaque classe,
- l'estimation de densité est discontinue.

[Silverman, 1986] montre que deux choix d'origine x_0 conduisent à des résultats relativement différents. Pour pallier ce problème, la notion d'histogrammes mobiles (ou estimateur naïf) a été développée.

II.3.3.2.2.2 Estimation de densité par histogramme mobile

L'estimateur de densité par histogramme mobile a été introduit par [Fix, 1951]. Il consiste à considérer chaque point x où l'on souhaite estimer la densité de probabilité, comme le centre d'une classe de largeur h, et comptabiliser le nombre d'observations dans cette classe. Il n'est donc plus nécessaire de choisir une origine x_0 pour la construction de l'histogramme. La densité de probabilité est alors estimée comme suit :

$$\hat{f}(x) = \frac{nombre \ de \ valeurs \ dans \ l'intervalle\left[x - \frac{h}{2}; \ x + \frac{h}{2}\right]}{n.h}$$
(7)

Cet estimateur peut être réécrit de la manière suivante :

$$\hat{f}(x) = \frac{1}{n \cdot h} \sum_{i=1}^{n} w\left(\frac{x - x_i}{h}\right)$$
(8)

Avec *w*(.) une fonction poids définie comme suit :

$$w(u) = \begin{cases} 1 & si |u| < \frac{1}{2} \\ 0 & sinon \end{cases}$$
(9)

L'estimateur de la densité par histogramme mobile dépend de la largeur de classe h. Une valeur trop faible de h entraîne une représentation des données avec trop de détails alors qu'une valeur trop élevée peut engendrer une perte d'informations. Cet estimateur est plus « régulier » que l'histogramme mais w(.) étant discontinue il aboutit toujours à une estimation discontinue.

Pour obtenir une distribution continue, il suffit de remplacer la fonction poids w(.) par une fonction noyau qui attribue un poids d'autant plus important que les observations sont proches de x et possède les propriétés recherchées (continuité, dérivabilité ...). Ce principe est celui de l'estimation de densité selon la méthode des fenêtres de Parzen.

[Silverman, 1986] note que, malgré les inconvénients de l'histogramme, il peut être très utile pour la présentation d'un échantillon de données monodimensionnelles.

II.3.3.2.2.3 Estimation par noyau - fenêtre de Parzen

Le concept de noyau a d'abord été introduit par [Rosenblatt, 1956], mais c'est [Cacoullos, 1966] qui a été le premier à utiliser ce terme pour désigner la fonction de poids utilisé dans l'estimateur naïf.

Bien qu'introduite par Rosenblatt, l'estimation par noyau a été développée par Parzen [Parzen, 1962].

L'estimateur de densité par fenêtre de Parzen est l'estimateur le plus populaire parmi les multiples estimateurs non-paramétriques de la densité. Il consiste à remplacer la fonction poids utilisée dans l'estimateur naïf par une fonction que l'on pourra choisir continue ou dérivable partout, propriété qui se transfère à l'estimateur par noyau. L'estimateur devient alors :

$$\hat{f}(x) = \frac{1}{n.h} \sum_{i=1}^{n} K\left(\frac{x - xi}{h}\right)$$
 (10)

avec, respectivement, K et h la fonction noyau et la largeur de fenêtre.

La fonction noyau est soumise aux conditions suivantes :

•
$$K \ge 0$$

- *K* est paire (le plus souvent)
- $\int_{-\infty}^{+\infty} K(u)d(u) = 1$

Le succès de l'estimateur par fenêtre de Parzen s'explique par sa simplicité et ses propriétés de convergence vers la vraie densité quand *h* tend vers zéro et *n* tend vers l'infini.

Il existe une multitude de noyaux dans la littérature. Certains sont à support fini ([-h, h]) et d'autres à support infini (\mathbb{R}) . Les noyaux suivants sont parmi les plus usuels :

Le noyau de Rosenblatt ou noyau naïf :

$$K(u) = \frac{1}{2h} \qquad si |u| \le h \tag{11}$$

Le noyau triangulaire :

$$K(u) = 1 - \frac{|u|}{h} \qquad si |u| \le h \tag{12}$$

Le noyau d'Epanechnikov :

$$K(u) = \frac{3}{4h} \left(1 - \frac{u^2}{h^2} \right) \qquad si |u| \le h$$
(13)

Le noyau de Tukey ou biweight :

$$K(u) = \frac{15}{16h} \left(1 - \frac{u^2}{h^2} \right)^2 \qquad si |u| \le h$$
(14)

Le noyau gaussien :

$$K(u) = \frac{1}{\sqrt{2\pi}h} exp^{\left(-\frac{u^2}{2h^2}\right)} \qquad u \in \mathbb{R}$$
(15)

La Figure 15 présente un exemple d'estimation de densité par fenêtre de Parzen avec un noyau gaussien.



Figure 15 : Exemple d'une densité de probabilité estimée par fenêtres de Parzen avec noyau gaussien.

CONFIDENTIEL INDUSTRIE

Il est généralement admis que la largeur de fenêtre h a une plus grande influence sur la performance de l'estimateur que le choix du noyau. Le fait d'utiliser une valeur de h trop petite, revient à représenter l'estimation de densité par un Dirac en chaque observation. Une valeur de h trop grande résulte en une estimation qui montre peu de détails. Lorsque h décroit, le biais de l'estimateur décroit mais entraine une hausse de la variance. L'optimisation de h réside dans le compromis à réaliser entre le biais et la variance.

Le réglage de la largeur de fenêtre a donné lieu à plusieurs travaux. Un choix possible est de déterminer h qui minimise l'erreur quadratique moyenne intégrée, *MISE*, (ou son approximation, *AMISE*) entre la densité recherchée (f) et son estimée (\hat{f}).

$$MISE(\hat{f}) = E \int \{\hat{f}(x) - f(x)\}^2 dx$$
(16)

L'estimation de ce critère nécessite de connaitre les dérivées première et seconde de la densité que l'on cherche à estimer. Cette information étant inconnue, plusieurs méthodes ont été utilisées pour y pallier :

• une première méthode repose sur l'utilisation d'une distribution de référence (distribution gaussienne par exemple). Dans ce cas, la dérivée seconde est connue et la largeur de fenêtre optimale peut être déterminée en fonction du noyau utilisé. [Silverman, 1986] montre qu'en considérant une distribution gaussienne et un noyau gaussien, en cherchant à minimiser l'erreur quadratique moyenne intégrée (MISE) et après plusieurs améliorations, la largeur de fenêtre optimale est :

$$h = 0.9.\min\left\{\text{\acute{e}cart_type}, \frac{\text{\acute{e}cart_interquartile}}{1.34}\right\}.n^{\frac{-1}{5}}$$
(17)

ce réglage de *h* a été appelé « règle du pouce » (rule of thumb) ou règle de Silverman.

- une seconde méthode repose sur la détermination de *h* après minimisation des moindres carrés par leave one out.
- une troisième méthode repose sur la détermination de *h* maximisant la vraisemblance par leave one out.

D'après [Bowman, 1985] utiliser la minimisation des moindres carrés donne des résultats convenables pour les distributions à courtes queues. En revanche, les résultats sont moins bons pour les distributions à longues queues (ou queues épaisses). Une règle du pouce, analogue à la règle de Silverman, donne de meilleurs résultats que la seconde méthode pour des densités monomodales. En revanche, les résultats sont moins bons pour des distributions bimodales. La détermination de h par maximisation de la vraisemblance après leave one out présente une sensibilité particulière à la présence de données atypiques (outliers). Par conséquent, la « règle du pouce » (règle de Silverman) a été retenue pour la détermination de h dans le cadre de la thèse.

La méthode d'estimation de densité par noyau ne représente pas la seule méthode non paramétrique d'estimation. D'autres approches ont été proposées comme, par exemple, les séries orthogonales, la méthode « splines », le maximum de vraisemblance pénalisée, les k plus proches voisins... Globalement, elles ne donnent pas de résultats significativement meilleurs que la méthode des noyaux. De plus, aucune ne peut se soustraire à l'incontournable problème du choix d'un paramètre de lissage, explicite ou non [Lejeune, 2010].

II.3.3.3 Estimation de queues de distributions

La théorie des valeurs extrêmes est souvent appliquée lorsqu'il est nécessaire d'estimer des événements rares malgré le fait que la distribution de l'échantillon étudiée est inconnue. Elle s'intéresse non pas à la modélisation globale d'une distribution mais seulement aux queues de cette distribution.

L'intérêt est porté sur le comportement asymptotique des valeurs extrêmes d'un échantillon. Ainsi en identifiant la famille de loi vers laquelle les valeurs extrêmes vont converger (domaine d'attraction du maximum - DAM), il est possible d'utiliser sa fonction de répartition. Il s'agit donc de déterminer quelles sont les valeurs les plus extrêmes de l'échantillon considéré.

Pour caractériser cette loi de distribution des extrêmes, deux théorèmes sont essentiels : celui de Fisher-Tippet [Fisher, 1928] et celui de Balkema-de Haan-Pickands [Balkema, 1974] [Pickands, 1975]. Ces deux théorèmes ont donné lieu à deux méthodes d'estimation de queues de distribution :

- la méthode des maxima par blocs (Block Maxima BM) qui modélise la distribution de maxima normalisés par la distribution généralisée des valeurs extrêmes,
- la méthode des excès (Peaks Over Threshold POT) qui modélise la distribution des excès audelà d'un seuil élevé par la distribution de Pareto généralisée.

II.3.3.3.1 Méthode des maxima par blocs

Cette méthode de modélisation de queues de distribution s'appuie sur le théorème de Fisher-Tippet [Fisher, 1928]. Elle consiste, à partir d'un échantillon d'observations indépendantes et identiquement distribuées selon une distribution inconnue de fonction de répartition F, à :

- partitionner cet échantillon en k blocs disjoints de longueurs identiques,
- sélectionner les maxima de chaque bloc,
- normaliser ces maxima.

Le théorème de Fisher-Tippet énonce le fait que les trois distributions limites possibles pour les maxima normalisés sont les distributions de Fréchet, de Weibull et de Gumbel. Ces distributions peuvent être caractérisées par une distribution unique : la distribution des valeurs extrêmes généralisée (GEV).

Ce théorème présente un intérêt important, car si l'ensemble des distributions est « grand », l'ensemble des distributions de valeurs extrêmes est, quant à lui, très petit. [Coles, 2001] fait le parallèle entre le théorème central limite et celui de Fisher-Tippet. Il énonce le fait que ce théorème fournit un analogue du théorème central limite pour les valeurs extrêmes puisque, quelle que soit la fonction F, il n'y a que trois types de distributions possibles pour la distribution des maxima normalisés.

La distribution des valeurs extrêmes généralisée est définie par la fonction de répartition suivante :

$$H_{\xi}(x) = \begin{cases} exp\left(-\left(1+\xi\frac{x}{\beta}\right)^{\frac{-1}{\xi}}\right) & si \ \xi \neq 0\\ exp\left(-e^{-\frac{x}{\beta}}\right) & si \ \xi = 0 \end{cases}$$
(18)

avec x tel que $1 + \xi x > 0$ où ξ est le paramètre de forme de la queue et β le paramètre de dispersion.

Cette distribution rassemble les trois types de distributions limites en fonction de la valeur de ξ (Figure 16) :

- si $\xi > 0$, domaine d'attraction de Fréchet,
- si $\xi < 0$, domaine d'attraction de Weibull,
- si $\xi = 0$, domaine d'attraction de Gumbel.



Figure 16 : Densité de probabilité de la GEV pour $\xi > 0$, $\xi < 0$ et $\xi = 0$.

Le paramètre ξ est lié au caractère leptokurtique (distribution dont le coefficient d'aplatissement est supérieur à zéro) de la fonction de répartition *F*, c'est pourquoi on lui donne généralement le nom d'indice de queue ou d'indice de valeur extrême. Plus cet indice est élevé en valeur absolue, plus le poids des extrêmes dans la distribution initiale est important. On parle alors de distribution à «queues épaisses». Au contraire, plus cet indice est petit en valeur absolue, moins le poids des extrêmes dans la distribution initiale est important. On parle alors de distribution à «queue courte ».

Le domaine d'attraction de Gumbel regroupe la majorité des distributions à queue fine. Le domaine d'attraction de Fréchet regroupe la majorité des distributions à queue épaisse. Enfin, le domaine d'attraction de Weibull regroupe la majorité des distributions bornées à droite.

A partir de l'échantillon des maxima normalisés, il est possible d'estimer les paramètres de la distribution généralisée des valeurs extrêmes. Plusieurs méthodes d'estimation sont envisageables, cependant, la plus utilisée est l'estimation par maximum de vraisemblance [Hosking, 1985]. Il n'existe pas de solution explicite pour l'estimation des paramètres. Des procédures numériques sont donc utilisées pour estimer ξ et β en maximisant la vraisemblance.

II.3.3.3.2 Méthode des excès

La méthode des excès, aussi appelée Peaks Over Threshold (POT), s'intéresse à la distribution des excès au-delà d'un seuil élevé. Cette modélisation de queues de distribution s'appuie sur le théorème de Balkema-de Haan-Pickands [Balkema, 1974] [Pickands, 1975] qui est l'équivalent du théorème central limite pour la théorie des valeurs extrêmes (au même titre que le théorème de Fisher-Tippet).

Le théorème énonce que si F appartient à l'un des trois domaines d'attraction de la loi limite des extrêmes (Fréchet, Gumbel ou Weibull), alors il existe une fonction de répartition des excès au-delà d'un seuil u, notée F_u qui peut être approchée par une loi de Pareto généralisée.

La distribution de Pareto généralisée (GPD) de paramètres ξ et β est définie par la fonction de répartition suivante :

$$G_{\xi,\beta}(x) = \begin{cases} 1 - \left(1 + \frac{\xi x}{\beta}\right)^{\frac{-1}{\xi}} si \xi \neq 0\\ 1 - exp\left(\frac{-x}{\beta}\right) si \xi = 0 \end{cases}$$
(19)

avec $\beta > 0$. Pour $\xi \ge 0$, le support de cette distribution est $[0; +\infty[$. Quand $\xi < 0$, le support est $[0; -\beta/\xi]$.

La distribution de Pareto généralisée regroupe trois types de distributions limites selon les valeurs du paramètre de forme ξ :

- si $\xi > 0$, distribution de Pareto usuelle,
- si $\xi < 0$, distribution de Pareto de type II,
- si $\xi = 0$, distribution exponentielle.

Avant de pouvoir estimer le modèle, il faut construire un échantillon adéquat. Il est donc nécessaire de trouver un seuil u de sélection des données extrêmes suffisamment élevé et au-dessus duquel assez de données sont conservées pour des estimations précises. Si le seuil est trop bas, les estimations sont biaisées et si le seuil est trop élevé, la variance des estimateurs est très importante. Des travaux ont été réalisés pour choisir le seuil u par optimisation du compromis entre le biais et la variance [Benlagha, 2009]. Il existe des techniques efficaces pour évaluer le seuil u, par exemple : la représentation Quantile-Quantile (QQ plot), le graphe des excès moyen et l'estimateur de Hill.

Représentation Quantile-Quantile (QQ plot).

La représentation Quantile-Quantile est un outil visuel permettant de tester si un échantillon provient d'une distribution spécifique. Les quantiles d'une distribution empirique sont représentés en fonction des quantiles d'une distribution théorique. Si l'échantillon provient de la distribution théorique ou une transformation linéaire de cette dernière, la représentation du QQplot est linéaire. Dans la théorie des valeurs extrêmes, le QQplot est typiquement représenté en fonction des quantiles de la distribution exponentielle (distribution avec une queue de taille moyenne) pour mesurer l'épaisseur d'une queue de distribution. Si les données proviennent d'une loi exponentielle, les points sur le graphique sont répartis autour d'une droite. S'il y a la présence d'une convexité, cela est représentatif d'une distribution à queue épaisse correspondant au domaine d'attraction de Fréchet, en revanche la présence d'une concavité est représentative d'une distribution bornée à droite correspondant au domaine d'attraction de Weibull (Figure 17).



Figure 17 : Exemple de QQplot dans les domaines d'attraction de Frechet (à gauche), de Weibull (au milieu) et de Gumbel (à droite).

Le graphe des excès moyens.

Ce graphe consiste à tracer la moyenne des excès, $e_n(u)$, pour différentes valeurs de seuil u et n le nombre total d'échantillons.

$$e_n(u) = \frac{\sum_{i=1}^n (X_i - u)}{\sum_{i=1}^n I_{\{X_i > u\}}}$$
(20)

avec X_i la variable aléatoire considérée et $I_{\{X_i > u\}} = \begin{cases} 1 & si \ X_i > u \\ 0 & sinon \end{cases}$

Le graphe des excès moyens a un comportement linéaire au-delà d'une certaine valeur de u, ce qui signifie que les excès au-dessus de ce seuil suivent une distribution de Pareto généralisée. Il s'agit donc de repérer la valeur de u à partir de laquelle la moyenne des excès est approximativement linéaire. Graphiquement, cela se traduit par un changement de pente de la courbe qui ensuite reste stable. Cela est visible sur l'exemple donné à la Figure 18. Au-delà de la valeur du seuil u = 3 le comportement devient linéaire.



Figure 18 : Exemple de graphe des excès moyens.

Estimateur de Hill.

L'estimateur consiste à estimer l'indice de queue ξ pour différentes valeurs des seuils selon l'expression suivante :

$$\hat{\xi} = \frac{1}{N_u} \sum_{i=1}^{N_u} ln\left(\frac{X_i}{X_{N_u+1}}\right)$$
(21)

avec N_u le nombre d'excès.

Ensuite, le seuil est sélectionné graphiquement et correspond à la valeur au-delà de laquelle le paramètres ξ devient stable.

Cette méthode est particulièrement bien adaptée aux distributions d'excès convergeant vers une distribution de Pareto généralisée en assurant un bon équilibre entre biais et variance. Cependant, l'estimateur de Hill n'est valable que pour les distributions de Fréchet représentative de queues épaisses.



Figure 19 : Exemple de sélection de seuil selon l'estimateur de Hill.

Une fois le seuil *u* défini, l'estimation des paramètres ξ et β est réalisée par maximum de vraisemblance sur l'échantillon des excès [Hosking, 1987]. Comme pour la méthode des maximas par blocs, il n'existe pas de solution explicite. Des procédures numériques sont donc utilisées pour estimer ξ et β .

Remarque :

La modélisation des queues de distribution est généralement privilégiée par la méthode Peaks Over Threshold avec l'estimation par maximum de vraisemblance. En effet, cette méthode est assez flexible et réaliste par rapport à la méthode des maxima par bloc, qui ne prend pas en compte toutes les valeurs susceptibles d'être extrêmes. La méthode des maxima par blocs extrait le maximum de chaque bloc défini au préalable. Elle peut donc perdre certaines valeurs extrêmes qui pourraient survenir autour du maximum d'un des blocs alors que pour le bloc suivant, le maximum pourrait être relativement faible. Au contraire, la méthode POT évite ce problème puisqu'elle extrait les excès au-dessus d'un seuil fixé à l'avance.

Le principal inconvénient de ces deux méthodes est le fait de nécessiter un échantillon de taille importante à partir duquel les maxima ou les excès vont être déterminés.

II.3.3.4 Application à la séquence de démarrage

II.3.3.4.1 Introduction

Dans le cadre de la surveillance de la séquence de démarrage, le score d'anormalité pour des démarrages sains représente la référence de fonctionnement du système. Il est obtenu par calcul de la norme de Mahalanobis sur les z-scores des huit mesures endogènes. Il a été calculé à partir des démarrages issus de la base de test composée de 2470 démarrages sains (cf. section I.6.3). L'histogramme des observations du score d'anormalité est représenté Figure 20 [Hmad, 2010a].



Figure 20 : Histogramme du score d'anormalité sans dégradation.

Cette distribution sert de référence sous l'hypothèse H0 (fonctionnement sain). Un seuil de détection de dégradations prémices d'incapacité à démarrer peut être estimé dans le cadre d'une approche de détection classique (détection d'une anomalie lorsqu'une observation du score d'anormalité franchit ce seuil). Sa valeur est déterminée par recherche du quantile d'ordre α sur la distribution du score d'anormalité dans le cas sain.

D'après la voix des clients et la voix du business, P(Sain/Détection) ne doit pas excéder 1% et PoD doit être maximale, c'est-à-dire voisine de 100%. Le Tableau 3 (section I.6.2) indique que les probabilités de dégradation provoquant un non démarrage vont de 8,66.10⁻⁷ pour une ouverture lente de la vanne SAV à 1,56.10⁻⁵ pour une baisse de pression APU. Au vu des valeurs de

P(Sain/Détection), PoD et P(Dégradation), les valeurs de α vont de 8,75.10⁻⁹ à 1,5.10⁻⁷. Il est donc nécessaire de déterminer des quantiles extrêmes pouvant atteindre 10⁻⁹. Cela est bien au-delà de ce qui se fait habituellement. Pour ce faire, il est nécessaire de très bien estimer la distribution du score d'anormalité dans le cas sain.

En théorie, la distribution d'une somme quadratique de variables aléatoires gaussiennes indépendantes (norme de Mahalanobis) est un χ^2 à γ degrés de liberté où γ est le rang de la matrice de corrélation entre ces variables. Le score d'anormalité sans dégradation devrait donc être distribué selon un χ^2 à γ degrés de liberté. La distribution du χ^2 à γ degrés de liberté peut se généraliser en une distribution Gamma dont le paramètre de forme est égal à $\gamma/2$ et dont le paramètre d'échelle est égal à 1/2.

Dans le but de vérifier si la distribution du score d'anormalité sans dégradation est en accord avec la théorie, une distribution Gamma a été ajustée sur ce dernier. Le test d'ajustement d'Anderson-Darling [Anderson, 1952] a été utilisé afin de juger de l'adéquation de l'ajustement Gamma aux valeurs du score d'anormalité. Ce test a été considéré puisqu'il représente une variante du test de Kolmogorov-Smirnov qui accorde un poids plus élevé aux extrémités de la distribution. Cela est particulièrement intéressant dans notre cas.

La statistique produite par le test est notée « A^2 » et son estimation est réalisée comme suit. Soit Z = F(X), où F représente une fonction de répartition. Supposons qu'un échantillon $x_1, ..., x_n$ donne des valeurs $z_{(i)} = F(x_i)$ pour i = 1, ..., n. Après avoir réorganisé $z_{(i)}$ dans l'ordre croissant, $z_{(1)} < z_{(2)} < ... < z_{(n)}$, la statistique d'Anderson-Darling (A^2) est calculée à l'aide de la distance quadratique pondérée entre la droite d'ajustement du diagramme de probabilité, Figure 21, basée sur la distribution choisie (Gamma dans ce cas) et la fonction en escalier non paramétrique (déterminée à partir des données). Son expression est la suivante :

$$A^{2} = -n - (1/n) \sum_{i}^{n} [(2i - 1) \log z(i) + (2n + 1 - 2i) \log (1 - z(i))]$$
(22)

Une faible valeur de la statistique d'Anderson-Darling indique que la loi de distribution s'ajuste correctement aux données. [D'Agostino, 1986] donne une table des p-valeurs du test. Une p-valeur correspond à la probabilité $P(A^2 > valeur limite/H0)$. Si la p-valeur du test d'Anderson-Darling est inférieure au niveau de signification choisi (ici 0,05), alors on décide que les données ne suivent pas la distribution testée.

La Figure 21 représente le diagramme de probabilité utilisé pour visualiser le score d'anormalité ajusté par une distribution Gamma. La statistique du test d'Anderson-Darling ainsi que la p-valeur correspondante y sont renseignées. Les droites représentent les percentiles de la distribution Gamma et son intervalle de confiance après avoir estimé les paramètres par maximum de vraisemblance sur les observations du score d'anormalité. Les points (rond) représentent les percentiles estimés empiriquement à partir du score d'anormalité.

Il apparait que les percentiles estimés pour le score d'anormalité ne sont pas compris dans l'intervalle de confiance de la distribution Gamma. Cela est attesté par la p-valeur inférieure à 5%. Il en résulte que la distribution Gamma ne s'ajuste pas au score d'anormalité sans dégradation.



Figure 21 : Test d'adéquation de l'ajustement Gamma

L'hypothèse d'ajustement Gamma étant rejetée, il ne semble donc pas souhaitable de l'utiliser pour déterminer la valeur du seuil correspondant à α .

Par conséquent, une étude a été réalisée afin de sélectionner l'approche la plus adéquate pour l'ajustement de cet échantillon afin de déterminer des quantiles extrêmes (seuils de détection) [Hmad, 2011a].

L'objectif de cette étude est d'observer l'impact, d'une part, de l'erreur de modèle sur la détermination de seuils de détection et, d'autre part, des méthodes d'estimation de queue de distribution.

Ces diverses façons de procéder sont étudiées dans les paragraphes suivants.

II.3.3.4.2 Estimation de densité

L'estimation de densité de probabilité est possible selon trois approches :

- l'approche paramétrique,
- l'approche paramétrique après transformation,
- l'approche non paramétrique

Cette partie de l'étude a été réalisée afin de déterminer laquelle de ces trois approches est la plus adaptée à notre problème de détermination de quantiles extrêmes. L'analyse a été menée par simulation en choisissant deux distributions de référence, dont les paramètres sont connus, à partir desquelles des échantillons dits d'apprentissage sont générées.

Les deux distributions de référence considérées sont la distribution Gamma et la distribution Rayleigh. La distribution Gamma a été choisie car on s'attendait à ce que le score d'anormalité soit distribué selon cette loi. La distribution de Rayleigh a été choisie car comme la distribution Gamma elle est continue et définie sur un support à valeurs positives. Toutefois, elle diffère de la distribution Gamma et permet donc d'analyser le comportement des trois approches sur une classe plus large de distributions.

Des seuils de détection dits « théoriques » ont été déterminés à partir des paramètres de ces distributions pour différentes valeurs d'erreur de première espèce notées $\alpha_{recherchée}$. La distribution de ces échantillons a été estimée selon les trois approches :

- pour l'approche paramétrique, on fait l'hypothèse d'une distribution Gamma dont les paramètres sont estimés par maximum de vraisemblance.
- pour l'approche paramétrique après transformation des données, la transformation de Johnson est considérée et une distribution normale est utilisée. Après transformation des observations de chacune des distributions de référence, la méthode du maximum de vraisemblance est utilisée pour déterminer les paramètres de la distribution normale.
- pour l'approche non paramétrique, une estimation par fenêtre de Parzen est utilisée. Des noyaux gaussiens sont considérés. La valeur du paramètre de lissage est obtenue grâce à la règle de Silverman (section II.3.3.2.2.3).

Par la suite, des seuils de détection ont été déterminés (seuils estimés), en recherchant les quantiles correspondant aux erreurs de première espèce recherchées ($\alpha_{recherchée}$), pour chacune des distributions estimées selon les trois approches.

Enfin, les « seuils estimés » ont été comparés aux « seuils théoriques » pour chacune des distributions de référence afin d'identifier l'influence de :

- la taille des échantillons d'apprentissage,
- la valeur des erreurs de premières espèces recherchées,
- la forme de la distribution de référence.

Les résultats de cette étude comparative ont été représentés à l'aide de boites à moustaches [Le Guen, 2001]. Ces diagrammes permettent de représenter la distribution des « seuils estimés » comme expliqué sur la Figure 22.



Figure 22 : Boites à moustaches

L'influence de la taille de l'échantillon d'apprentissage, des valeurs des erreurs de première espèce recherchées et de la nature de la distribution de référence a été étudiée dans les paragraphes suivants.

II.3.3.4.2.1 Influence de la taille des échantillons d'apprentissage

L'influence de la taille des échantillons d'apprentissage sur la détermination des seuils de détection a été évaluée en générant des échantillons d'apprentissage de différentes tailles à partir des distributions de référence.

Pour chaque distribution de référence, 1000 échantillons de taille 250, 500, 750, et 1000 ont été générés. La valeur de l'erreur de première espèce recherchée a été fixé à $\alpha_{recherchée} = 10^{-9}$.

Les paramètres des distributions de références sont respectivement : $\Gamma(5;0,5)$ pour la distribution Gamma et Rayleigh(2) pour la distribution Rayleigh (Figure 23).



Figure 23 : Distributions de référence $\Gamma(5;0,5)$ et Rayleigh(2).

La Figure 24 représente le « seuil théorique » ainsi que les distributions des seuils estimés selon les trois approches lorsque les échantillons d'apprentissage sont issus respectivement de la distribution de référence $\Gamma(5; 0,5)$ et de la distribution de référence Rayleigh(2).



Figure 24 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson, G : Gamma et P : Parzen) pour différentes tailles d'échantillons issus de la distribution $\Gamma(5; 0,5)$ (a) et de la distribution Rayleigh(2) (b).

Il apparait sur la Figure 24 que pour l'estimation de densité par fenêtre de Parzen, les seuils de détection sont légèrement sous-estimés en moyenne, lorsque les échantillons d'apprentissage sont issus de la distribution de référence Gamma. En revanche, ces derniers sont légèrement surestimés lorsque les échantillons d'apprentissage sont issus de la distribution de référence Rayleigh. Cette surestimation diminue lorsque la taille de l'échantillon d'apprentissage augmente. Quelle que soit la distribution de référence, la variance des seuils estimés diminue avec l'augmentation de la taille des échantillons d'apprentissage. L'estimation par fenêtres de Parzen présente des résultats acceptables pour les deux distributions de référence.

L'utilisation d'un ajustement Gamma donne de meilleurs résultats lorsque les données sont issues d'une distribution de référence Gamma. Ce qui est normal puisque les données sont ajustées par la distribution qui a été utilisée pour les générer. Les résultats ne sont pas aussi bons lorsque les échantillons d'apprentissage sont issus d'une distribution de Rayleigh. En effet l'ajustement Gamma est celui qui présente la plus grande surestimation des seuils de détection pour la variance la plus faible.

Malgré l'augmentation de la taille des échantillons d'apprentissage, les seuils de détection estimés après transformation de Johnson sont surestimés en moyenne et présentent une variance importante. Cette variance est encore plus importante lorsque les échantillons d'apprentissage sont issus de la distribution de Rayleigh. Quelle que soit la distribution de référence et la taille des échantillons d'apprentissage, la transformation de Johnson n'est pas appropriée. Après analyse des échantillons transformés, il s'est avéré que la transformation de Johnson ne fonctionne pas correctement lorsque :

- la taille des échantillons d'apprentissage est importante. La « normalisation » de la distribution est de moins en moins possible à mesure que la distribution est mieux connue. Lorsque la taille des échantillons augmente, il est difficile d'approximer la fonction de transfert entre les deux distributions à l'aide de la transformation de Johnson.
- les échantillons d'apprentissage ne sont pas issus des distributions comprises dans le système des transformations de Johnson.

La Figure 25 représente les proportions de transformations non conformes à une loi normale au sens du test d'Anderson Darling après transformation de Johnson.



Figure 25 : influence de la taille des échantillons d'apprentissage sur les transformations décidées non conformes pour les distributions de référence Gamma et Rayleigh.

Il apparait que les proportions de transformations qui échouent à produire une distribution normale au sens du test d'Anderson-Darling sont importantes et augmentent avec la taille d'échantillon d'apprentissage. Il est à noter que la puissance du test augmente avec la taille d'échantillon

d'apprentissage. Quelle que soit la taille de l'échantillon, les proportions de transformations non conformes sont plus importantes pour les échantillons d'apprentissage issus d'une distribution de Rayleigh que pour ceux issus d'une distribution Gamma. Ceci est probablement dû au fait que la distribution Gamma appartient aux distributions comprises dans le système des transformations de Johnson, ce qui n'est pas le cas de la distribution de Rayleigh. Pourtant, quand bien même la distribution Gamma appartient au système des transformations de Johnson, plus de 20 % des transformations d'échantillons générés à partir de cette distribution sont non conformes pour 1000 échantillons.

II.3.3.4.2.2 Influence des erreurs de première espèce recherchées

L'influence des erreurs de première espèce recherchées ($\alpha_{recherchée}$) sur la détermination des seuils de détection a été étudiée pour des échantillons d'apprentissage de taille 500.

Différentes valeurs de $\alpha_{recherchée}$ ont été testées : 10^{-5} , 10^{-6} , 10^{-7} , 10^{-8} et 10^{-9} .

Les paramètres des distributions de référence restent inchangés et sont respectivement : $\Gamma(5; 0,5)$ pour la distribution Gamma et Rayleigh(2) pour la distribution de Rayleigh.

La Figure 26 représente les « seuils théoriques » correspondant à chaque valeur de $\alpha_{recherchée}$ ainsi que les distributions des seuils estimés selon les trois approches, à partir de 1000 simulations, lorsque les échantillons d'apprentissage sont issus respectivement de la distribution $\Gamma(5; 0,5)$ et de la distribution Rayleigh(2).



Figure 26 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson, G : Gamma et P : Parzen) pour différentes valeurs de $\alpha_{\text{recherchée}}$ dans le cas d'échantillons issus de la distribution $\Gamma(5; 0.5)$ (a) et de la distribution Rayleigh(2) (b).

La Figure 26 montre que lorsque $\alpha_{recherchée}$ diminue, la différence entre les trois approches est plus nette. Quelle que soit la distribution de référence, la transformation de Johnson présente des variances importantes et une surestimation en moyenne du seuil de détection. L'ajustement Gamma donne de bons résultats lorsque les échantillons d'apprentissage sont issus d'une distribution Gamma. Pour les échantillons d'apprentissage issus de la distribution de Rayleigh, l'ajustement Gamma présente la surestimation la plus élevée quelle que soit la valeur de $\alpha_{recherchée}$. L'ajustement par fenêtre de Parzen donne un meilleur compromis (une meilleure robustesse) tant pour les échantillons d'apprentissage issus d'une distribution de Rayleigh que ceux issus d'une distribution Gamma. Ces remarques sont identiques au cas précédent.

II.3.3.4.2.3 Influence de la forme des distributions de référence

L'influence de la forme des distributions de référence sur la détermination des seuils de détection a été étudiée pour des échantillons d'apprentissage de taille 500.

La valeur de $\alpha_{recherchée}$ a été fixée à 10⁻⁹ car c'est pour des petites valeurs de α que les tendances sont les plus marquées. Différentes valeurs des paramètres de chaque distribution de référence ont été testées.

Les valeurs des paramètres testées sont respectivement : $\Gamma(5; 0,5)$, $\Gamma(2; 0,5)$ et $\Gamma(5; 6)$ pour la distribution Gamma (Figure 27), Rayleigh(0,5), Rayleigh(2) et Rayleigh(4) pour la distribution Rayleigh (Figure 28).



Figure 27 : Distributions de référence Gamma pour les différentes valeurs de paramètres considérées.



Figure 28 : Distributions de référence Rayleigh pour les différentes valeurs de paramètres considérées.

La Figure 29 représente les « seuils théoriques » correspondant à $\alpha_{recherchée}$ pour les différentes valeurs des paramètres ainsi que les distributions des seuils estimés selon les trois approches, à partir de 1000 simulations, lorsque les échantillons d'apprentissage sont issus respectivement des distributions Gamma et des distributions de Rayleigh.



Figure 29 : Seuil théorique (T) et seuils estimés pour les trois approches (J : transformation de Johnson,G : Gamma et P : Parzen) dans le cas d'échantillons issus de distributions Gamma (a) et de distributions de Rayleigh (b) pour différentes valeurs des paramètres.

Il apparait sur la Figure 29 que les seuils de détection estimés après transformation de Johnson présentent une variance plus grande pour les échantillons d'apprentissage issus de $\Gamma(2;0,5)$ que ceux issus de $\Gamma(5;0,5)$ et $\Gamma(5;6)$. Il semble que la transformation de Johnson ne fonctionne pas correctement lorsque les échantillons d'apprentissage présentent une variance faible. En effet, la variance de la distribution $\Gamma(2;0,5)$ est plus faible que celles des distributions $\Gamma(5;0,5)$ et $\Gamma(5;6)$. Quelles que soient les valeurs des paramètres de la distribution Gamma, il apparait une surestimation, en moyenne, des seuils de détection suite à une transformation de Johnson. En ce qui concerne les échantillons d'apprentissage issus des distributions de Rayleigh, il apparait que la variance introduite par la transformation de Johnson augmente lorsque la variance des échantillons d'apprentissage diminue. Cet effet a déjà été constaté pour des échantillons issus de la distribution Gamma. Quels que soient les paramètres de la distribution Rayleigh, la transformation de Johnson conserve son comportement pessimiste en moyenne. L'ajustement Gamma est plus pessimiste que la transformation de Johnson mais présente la plus faible variance. L'ajustement par fenêtre de Parzen reste le meilleur compromis.

II.3.3.4.2.4 Conclusion

Trois approches ont été comparées à partir d'échantillons d'apprentissage simulés. Deux cas de figure ont été étudiés. Le premier lorsque les échantillons d'apprentissage suivent une distribution Gamma et l'autre lorsqu'ils suivent une distribution de Rayleigh.

Les résultats montrent qu'en moyenne les seuils estimés après transformation de Johnson sont trop pessimistes et présentent une variance importante quel que soit le cas de figure. Il est important de noter que la transformation de Johnson ne parvient pas toujours à produire une distribution normale alors qu'elle est conçue pour cela. Le fait d'ajuster une distribution Gamma lorsque les données suivent une distribution Rayleigh (sous-entendu, le modèle ne correspond pas à la distribution des données) donne des résultats plus pessimistes qu'après transformation de Johnson, mais avec une variance beaucoup plus faible. Enfin, il apparait que l'estimateur non-paramétrique par fenêtre de Parzen représente le meilleur compromis (meilleure robustesse) parmi ces trois approches et quel que soit le cas de figure étudié.

Après avoir comparé ces trois approches d'estimation de densité de probabilité, le paragraphe suivant consiste à tester la détermination de seuils de détection en estimant des queues de distribution à partir d'échantillons d'apprentissage simulés.

II.3.3.4.3 Estimation de queues de distributions

Dans cette deuxième partie de l'étude, la théorie des valeurs extrêmes est utilisée afin d'estimer les queues de distributions des échantillons d'apprentissage. Une fois les queues de distributions estimées, des seuils de détection sont déterminés pour être comparés aux seuils théoriques. La modélisation des queues de distribution a été réalisée par la méthode des excès (Peaks Over Threshold – POT). Cette méthode décrite en section II.3.3.3.2 consiste à définir un seuil u (seuil d'apprentissage) assez grand à appliquer à chaque échantillon d'apprentissage afin de définir un échantillon d'excès (pour chaque échantillon d'apprentissage). Lorsque le seuil est suffisamment grand, la distribution des excès au-delà du seuil « u » suit une distribution de Pareto généralisée (GPD). Les paramètres de cette dernière sont estimés par maximum de vraisemblance à partir de l'échantillon d'excès.

Ce qui nous intéresse particulièrement dans cette étude concerne l'estimation de quantiles extrêmes à partir des paramètres estimés de la GPD. Pour ce faire, il est possible d'utiliser un estimateur semiparamétrique des quantiles par la méthode POT qui a été obtenu en inversant la fonction de répartition de la GPD [Charpentier, 2008]. Ce dernier permet de déterminer la valeur d'un quantile (seuil de détection) correspondant à une probabilité ($\alpha_{recherchée}$). Cet estimateur s'exprime comme suit :

$$\hat{S}_{\alpha_{rec\,herc\,h\acute{e}e}} = u + \frac{\hat{\beta}}{\hat{\xi}} \left(\left(\frac{N}{N_u} (1 - \alpha_{rec\,herc\,h\acute{e}e}) \right)^{-\hat{\xi}} - 1 \right)$$
(23)

avec N_u le nombre d'excès au-delà du seuil d'apprentissage u, N la taille de l'échantillon, $\hat{\beta}$ et $\hat{\xi}$ les valeurs estimées (par maximum de vraisemblance) des paramètres de la distribution de Pareto généralisée.

Cet estimateur a été utilisé pour déterminer les seuils de détection correspondant à $\alpha_{recherchée}$. L'expérience a été réalisée 500 fois sur des échantillons d'apprentissage issus de distribution de référence Gamma de paramètres $\Gamma(5;2)$ (pour obtenir des seuils dans la même plage que pour Rayleigh) et Rayleigh de paramètre Rayleigh(5) (Figure 30).



Figure 30 : Distributions de référence $\Gamma(5;2)$ et Rayleigh(5).

Différentes tailles d'échantillons d'apprentissage ont été testées : $N = \{250; 500; 750; 2500; 5000\}$. Le seuil d'apprentissage « u » étant inconnu a priori, différentes valeurs pour lesquelles la taille des échantillons d'excès allant de 1% à 10% de la taille totale des échantillons d'apprentissage ont été testées pour déterminer les paramètres de la distribution de Pareto généralisée. Par la suite, les seuils de détection ont été estimés.

La Figure 31 (respectivement, la Figure 32) représente le « seuil théorique » ainsi que les distributions des seuils estimés, pour $\alpha_{recherchée} = 10^{-4}$ (respectivement, pour $\alpha_{recherchée} = 10^{-9}$), à partir de 500 simulations, lorsque les échantillons d'apprentissage sont issus de la distribution $\Gamma(5; 2)$ (partie gauche de la figure) et de la distribution Rayleigh(5) (partie droite de la figure).

Les axes des abscisses représentent les tailles des échantillons d'excès, en % de *N*, utilisés pour l'estimation des paramètres de la distribution de Pareto généralisée. La taille de l'échantillon est arrondie à l'entier inférieur de la taille théorique réelle.

La Figure 31 montre que, quelle que soit la taille de l'échantillon complet et la distribution de référence, plus l'échantillon des excès est petit, plus grande est la variance des seuils estimés et viceversa. Le compromis biais variance est visible avec l'augmentation de la taille totale des échantillons. Il est plus net sur la Figure 32 pour $\alpha_{recherchée}=10^{-9}$. Cette dernière montre que, quelle que soit la distribution de référence, il existe en général un biais entre le seuil théorique et les seuils estimés. Ce biais diminue légèrement lorsque la taille de l'échantillon d'excès diminue. En revanche, plus la taille de l'échantillon d'excès est petite, plus la variance des seuils estimés est grande. Cette variance diminue lorsque la taille *N* des échantillons d'apprentissage augmente.

Il apparait donc nécessaire de trouver un compromis entre le biais et la variance des estimations. Néanmoins, pour que ce compromis soit acceptable, il est nécessaire de disposer d'échantillon de très grande taille. Plus la valeur de $\alpha_{recherchée}$ est petite, plus la taille de l'échantillon nécessaire doit être grande. Cela est visible en comparant la Figure 31 à la Figure 32. Il apparait plus aisé de trouver le meilleur compromis entre biais et variance pour $\alpha_{recherchée}=10^{-9}$.



Figure 31 : Seuil théorique et seuils estimés selon l'approche POT pour $\alpha_{recherchée} = 10^4$ et différentes tailles d'échantillon issu de la distribution de référence Gamma (à gauche) et Rayleigh (à droite).



Figure 32 : Seuil théorique et seuils estimés selon l'approche POT pour $\alpha_{recherchée} = 10^{-9}$ et différentes tailles d'échantillon issu de la distribution de référence Gamma (à gauche) et Rayleigh (à droite).

Afin de comparer les résultats issus des estimations de queues de distribution et ceux issus des estimations de densités de probabilité réalisées au paragraphe précédent, l'estimation non paramétrique par fenêtre de Parzen a été appliquée aux mêmes échantillons d'apprentissage.

La Figure 33 représente les « seuils théoriques » ainsi que les distributions des seuils estimés après ajustement par fenêtre de Parzen à partir de 500 simulations lorsque les échantillons d'apprentissage sont issus de la distribution $\Gamma(5; 2)$ (à gauche) et de la distribution Rayleigh(5) (à droite). La valeur de $\alpha_{\text{recherchée}}$ a été fixée à 10⁻⁹ afin de mieux faire apparaitre les contrastes entre les deux approches.

Les conclusions sont identiques à celles du paragraphe précédent. L'ajustement par fenêtre de Parzen permet une estimation des seuils de détection proches en moyenne des seuils Gamma et Rayleigh. Quelle que soit la distribution de référence, la variance des seuils estimés diminue lorsque la taille des échantillons d'apprentissage augmente. Les seuils sont légèrement sous-estimés en moyenne lorsque les échantillons d'apprentissage sont issus de la distribution Gamma. En revanche, ils sont légèrement surestimés en moyenne pour la distribution de référence Rayleigh. Dans l'ensemble, le compromis obtenu est plus pertinent qu'avec la méthode POT.



Figure 33 : Seuil théorique (T) et seuils estimés après ajustement par fenêtres de Parzen pour $\alpha_{recherchée}=10^{-9}$ et différentes tailles d'échantillons issus de la distribution de référence Gamma (à gauche) et Rayleigh (à droite).

II.3.3.4.4 Conclusion

La distribution du score d'anormalité obtenu à partir des 2470 démarrages sans dégradation étant inconnue, une étude de méthodes pour la détermination de quantiles extrêmes (seuils de détection) a été réalisée à partir de simulations.

Dans un premier temps, elle a consisté à comparer les seuils théoriques aux seuils estimés après ajustement des échantillons par trois approches d'estimation de densité.

L'approche non paramétrique par ajustement de fenêtre de Parzen donne le meilleur compromis et présente la meilleure robustesse comparé aux deux autres approches : l'approche paramétrique et l'approche paramétrique après transformation.

Par la suite, la détermination de seuils de détection par estimation des queues de distributions d'échantillons simulés a été testée et comparée à l'estimation par fenêtre de Parzen. L'estimation par fenêtre de Parzen présente encore les meilleurs résultats.

Cette étude a permis de sélectionner l'ajustement par fenêtre de Parzen pour estimer la distribution du score d'anormalité et ainsi de déterminer les seuils de détection en fonction des exigences sur l'erreur de première espèce.

A titre illustratif, un ajustement par fenêtre de Parzen ainsi qu'un ajustement Gamma ont été appliqués aux 2470 observations du score d'anormalité sans dégradation (Figure 34 et Figure 35). Il apparait que l'ajustement par fenêtre de Parzen est plus proche de la distribution empirique qu'un ajustement Gamma.



Figure 34: Score d'anormalité sans dégradation et ajustements Gamma et Parzen.



Figure 35 : Fonction de répartition empirique du score d'anormalité sans dégradation, ajustements Gamma et Parzen, zoom sur les queues de distribution

L'approche retenue consiste donc à estimer la distribution à l'aide de l'estimateur de Parzen et estimer le seuil correspondant à l'erreur de première espèce souhaitée. Pour qualifier le test il faut ensuite estimer sa puissance. Pour ce faire, il est nécessaire de disposer de données avec dégradations, ce sujet est abordé dans la section suivante.

II.3.4 SIMULATION DES DEGRADATIONS PREMICES DE NON DEMARRAGE

Malgré le nombre important de démarrages disponibles, aucune dégradation des modules ou URL causes de non démarrage n'a été observée. Dans ce cas de figure, il est impossible de déterminer les règles à utiliser pour simuler des dégradations. Selon [Ausloos, 2010], deux solutions sont envisageables.

La première solution consiste à provoquer les dégradations lors de campagnes d'essai afin d'identifier leurs impacts sur les huit mesures endogènes extraites par l'algorithme de surveillance de la séquence de démarrage. Le principal inconvénient de cette solution réside dans son coût très élevé. Dans notre cas, nous ne disposons pas de démarrages réalisés dans le cadre d'essais en mode dégradé sur le turboréacteur considéré. En revanche, il existe des démarrages réalisés pour différents débits de carburant sur un autre turboréacteur.

La seconde solution consiste à utiliser des modèles numériques de démarrage lorsqu'ils existent. Le principal inconvénient de cette solution est que ces modèles ne synthétisent pas toujours les mesures qui nous intéressent. Ce qui est le cas dans le cadre de cette étude. En effet, les modèles de démarrage disponibles ne permettent pas l'extraction de toutes les mesures utilisées par l'algorithme de surveillance de la séquence de démarrage et quand ces synthèses sont disponibles, elles ne sont pas assez précises pour être exploitées directement pour cette analyse. Seule la simulation d'une ouverture lente de la vanne de démarrage a pu être réalisée.

Comme aucune de ces deux solutions ne convient, on est conduit à se satisfaire d'une troisième. Un outil de simulation spécifique a donc été développé à partir d'analyses de données provenant de banc d'essais et des modèles empiriques de démarrage. Les impacts des dégradations sur les huit mesures endogènes extraites par l'algorithme de surveillance de la séquence de démarrage ont été identifiés, quantifiés et modélisés. Les modèles sont ensuite utilisés pour injecter des dégradations sur les huit mesures obtenues en fonctionnement normal. Chaque dégradation considérée a été simulée pour trois intensités différentes : faible, moyenne et forte. Une dégradation de faible intensité traduit des valeurs du score d'anormalité sensiblement différentes de celles obtenues dans le cas sain sans que cet écart ne soit trop important. Une dégradation de forte intensité traduit le niveau de dégradation maximum avant défaillance. Enfin une dégradation de moyenne intensité traduit un niveau de dégradation intermédiaire. Chaque intensité de dégradation a été définie avec les experts pour chacune des causes de non démarrage. Les dégradations étudiées sont les suivantes [El amry, 2010] :

- baisse de pression du compresseur d'air APU,
- hausse du débit carburant,
- baisse du débit carburant,
- ouverture lente de la vanne SAV.

Elles sont détaillées dans les trois paragraphes suivants.

II.3.4.1 Dégradations du compresseur d'air

En fonctionnement nominal, la pression d'alimentation en air est d'environ 2,2 bars relatifs (pression envoyée au démarreur - pression extérieure). Des essais ont mis en évidence le fait que le turboréacteur ne démarre pas lorsque cette pression est inférieure à 1,4 bar relatif. Cette valeur a donc été définie comme l'intensité forte d'une dégradation du compresseur APU. Elle correspond à une valeur de pression 35% inférieure à la pression d'alimentation nominale.

Parmi les 305 démarrages réalisés au banc d'essais (cf. § I.6.3), 5 démarrages ont été effectués pour des pressions d'alimentation élevées. Ils ont donc été utilisés pour l'étude de dégradation du compresseur APU [Hmad, 2009]. L'impact, en pourcentage, d'une hausse de pression sur les huit mesures a dans un premier temps été déterminé. Il s'est avéré que seules les mesures x_accel_max, y_accel_max, T1, T2, grad(EGT)max et grad(EGT)moy sont impactées par cette modification. Les mesures T_allum et T3 ne sont pas impactées.

En parallèle, une étude des tendances d'évolution de ces mesures lors d'une baisse de pression a été effectuée sur un autre turboréacteur. Cette étude a permis de vérifier qu'une diminution de pression d'alimentation a bien un effet symétrique à celui d'une augmentation de pression.

A l'issue de cette confirmation, les impacts déterminés sur chaque mesure pour une hausse de pression ont été appliqués en inversant leurs signes pour simuler une baisse de pression. Le Tableau 8 répertorie les impacts, en pourcentage, d'une baisse de pression sur les mesures impactées.

	Impact en % sur les mesures						
Intensité de dégradation	x_accel_max	y_accel_max	T1	T2	grad(EGT)max	grad(EGT)moy	
Faible : Pression nominale - 11,7%	1,24	-7,82	7,1	2,46	-2,09	-4,75	
Moyenne : Pression nominale - 23,4%	2,48	-15,64	14,2	4,1	-4,17	-9,5	
Forte : Pression nominale - 35%	3,71	-23,39	21,27	7,35	-6,24	-14,2	

Tableau 8 : Impact sur les mesures pour une baisse de pression APU

La Figure 36 représente les distributions du score d'anormalité successivement sans dégradation et avec les trois degrés d'intensité pour une baisse de pression APU.



Figure 36 : Distributions des scores d'anormalité avec et sans dégradation pour une baisse de pression APU.

II.3.4.2 Dégradations du bloc hydromécanique

Des essais de tolérance au phénomène appelé « pompage » ont été réalisés au banc sur un autre turboréacteur [Berthault, 2009a]. Différentes valeurs de débit carburant ont été testées : débit nominal, débit nominal +10%, débit nominal +13% et débit nominal +16%.

Le « pompage » se traduit par une pression excessive et anormale en sortie du compresseur haute pression provoquant une inversion du sens de l'écoulement de l'air à l'intérieur du réacteur. Ce retour des gaz chauds vers l'entrée d'air entraine des fluctuations de puissance et des dommages irréversibles à la turbine. Les pièces des premières sections du turboréacteur sont alors fortement endommagées.

Il a été indiqué par les experts motoriste que +13% de débit carburant était un maximum avant « pompage » sur le moteur considéré [El amry, 2010]. L'intensité de dégradation maximum considérée est donc +13% de débit carburant et non +16%. La limite basse pour considérer un surdosage est de +7% de débit carburant, ce qui correspond à environ deux fois la précision de dosage. Une intensité intermédiaire de +10% a été utilisée pour une hausse de débit carburant.

D'après les experts, lors d'une augmentation ou d'une diminution de débit carburant, les mesures impactées sont T2, T3, grad(EGT)max et grad(EGT)moy. Les autres mesures (x_accel_max, y_accel_max, T1 et T_allum) ne sont pas impactées. L'impact de cette augmentation de débit

carburant a été quantifié pour chaque mesure pour +10% et +13% de débit carburant. Une extrapolation a été réalisée pour déterminer l'impact sur les mesures pour +7% de débit carburant. Les impacts déterminés pour les mesures considérées sont répertoriés dans le Tableau 9.

	Impact en % sur les mesures				
Intensité de dégradation	T2	T3	grad(EGT)max	grad(EGT)moy	
Faible :	-10	-11	3	8	
Débit carburant + 7%					
Moyenne :	-14 39	-157	43	11.5	
Débit carburant + 10%	1,05	10,7	.,.	,-	
Forte :	-20.89	-23 14	5.6	15	
Débit carburant + 13%	20,09	23,14	2,0	10	

Tableau 9 : Impact sur les mesures pour une hausse de débit carburant.

La Figure 37 représente les distributions du score d'anormalité pour une hausse de débit carburant.



Figure 37 : Distributions des scores d'anormalité avec et sans dégradation pour une hausse de débit carburant.

Pour évaluer l'impact d'une baisse de débit carburant sur T2 et T3, une symétrie a été appliquée par rapport au cas d'une suralimentation.

En ce qui concerne grad(EGT)max et grad(EGT)moy, la symétrie ne peut s'appliquer directement. La raison est que la diminution de la vitesse d'enroulement du moteur risque de conduire à une augmentation de l'EGT mesurée à régime donné alors que le volume de carburant injecté diminue. Pour éviter cet effet qui pourrait mener à des interprétations faussées, il a été décidé de modifier les modalités de calcul de ces gradients afin de les rendre invariants par rapport à ces aspects.

Les impacts d'une baisse de débit carburant de -7%, -10% et -13% sur les mesures sont présentés dans le Tableau 10.

	Impact en % sur les mesures				
Intensité de dégradation	T2	T3	grad(EGT)max	grad(EGT)moy	
Faible :	12.5	14 10	-2.6	-7	
Débit carburant - 7%	12,5	17,10	2,0	,	
Moyenne :	20.20	22.89	-3.43	-9	
Débit carburant - 10%	20,20	22,09	5,15	,	
Forte :	35.88	43.08	-3.6	-9.6	
Débit carburant - 13%	22,00	12,00	2,0	2,0	

Tableau 10 : Impact sur les mesures pour une baisse de débit carburant.

La Figure 38 représente les distributions du score d'anormalité pour une baisse de débit carburant.



Figure 38 : Distributions des scores d'anormalité avec et sans dégradation pour une baisse de débit carburant.

II.3.4.3 Dégradations de la vanne à air

Le département hydromécanique de la division « Systèmes » de Snecma dispose d'un modèle de démarrage pour un autre turboréacteur que celui considéré [Berthault, 2009b]. Ce modèle s'appuie sur des équations simples liées au bilan des couples moteurs et équipements. Il ne prend en compte que les modèles mécaniques de chaque équipement sans tenir compte des paramètres de performance moteur ni de la régulation.

Une demande de simulation d'augmentation du temps d'ouverture de la vanne a été effectuée pour différents cas. En fonctionnement nominal, le temps d'ouverture de la vanne est de 7 secondes. Le temps d'ouverture le plus long observé en exploitation est de 15 secondes, soit 8 secondes de plus que le temps d'ouverture nominal. La simulation a été effectuée pour un temps d'ouverture nominal de 7s puis pour des temps d'ouverture dégradés de 9s (nominal +2s), 11s (nominal +4s), et 15s (nominal +8s). Ce dernier est considéré comme l'intensité forte d'une dégradation de la vanne.

Une fois les résultats de la simulation disponibles, il s'est avéré qu'une ouverture lente de la vanne impacte les mesures x_accel_max, y_accel_max et T1. Le Tableau 11 répertorie l'impact en pourcentage sur ces mesures.

	Impact en % sur les mesures			
Intensité de dégradation	x_accel_max	y_accel_max	T1	
Faible :	24.49	-5.27	8.76	
temps d'ouverture nominal + 2s	7 -	- 7 -	- ,	
Moyenne :	51.02	-9 77	18	
temps d'ouverture nominal + 4s	51,02	,,,,	10	
Forte :	101.02	-17.22	35.94	
temps d'ouverture nominal + 8s	101,02		,	

Tableau 11 : Impact sur les mesures pour une ouverture lente de la SAV

La Figure 39 représente les distributions du score d'anormalité pour une ouverture lente de la vanne de démarrage (SAV).



Figure 39 : Distributions des scores d'anormalité avec et sans dégradation pour une ouverture lente de la vanne SAV.

II.3.4.4 Module de génération des dégradations

Les impacts des dégradations sur les mesures ont été intégrés à l'algorithme de surveillance de la séquence de démarrage sous forme d'un module de génération de dégradations. Ce module a permis de simuler des dégradations à partir de démarrages sains grâce aux impacts déterminés pour des dégradations d'intensités faible, moyenne et forte, synthétisées dans le Tableau 12.

Dégradation	Intensités de dégradation				
	Faible	Moyenne	Forte		
APU - Baisse de pression	-11.7%	-23.4%	-35%		
HMU - Baisse de débit carburant	-7%	-10%	-13%		
HMU - Augmentation débit carburant	7%	10%	13%		
SAV - Ouverture lente de la vanne	+2 s	+4 s	+8 s		

Ce module permet de pallier au manque de données sans dégradation. Il a alors été possible, pour chaque démarrage, de simuler des dégradations pour quantifier les performances de détection dans un environnement supervisé.

Il est important de noter que ce module est basé sur des extrapolations et que par conséquent les résultats attendus ont un caractère qualitatif. Seule l'acquisition de données sur des périodes plus longues permettra d'affiner ces résultats.

II.3.5 CONCLUSION

Après avoir identifié les indicateurs pertinents, permettant de caractériser les performances de la fonction de détection, leurs méthodes d'estimation ont été établies. Celles-ci ont révélé la nécessité d'estimer la distribution de la statistique de décision considérée et de simuler des dégradations. Cela a été réalisé et présenté dans les sections précédentes.

A présent tous les éléments nécessaires pour l'estimation des performances de détection sont disponibles. La section III.2 illustre l'application de cette démarche d'estimation dans le cadre de la détection de prémices de non démarrage.

II.4 PRONOSTIC

II.4.1 INTRODUCTION

Le besoin de connaître le futur est une problématique en lien avec un nombre important de disciplines scientifiques. Les applications sont diverses et variées et différentes méthodes sont utilisées pour les différentes applications (cf. ANNEXE - 4 § 4). D'après [Jardine, 2006], quel que soit le domaine d'application, il existe principalement deux mesures ou indicateurs de pronostic. La première mesure consiste à prédire le temps restant avant la défaillance d'un composant ou d'un système connaissant les conditions de fonctionnement passées et actuelles. Cette mesure est communément appelée Remaining Useful Life (RUL). La seconde mesure consiste à prédire la probabilité qu'un composant ou un système fonctionne sans défaillance pendant un horizon donné connaissant les conditions de fonctionnement passées et actuelles. C'est cette seconde mesure qui a été considérée dans la thèse.

L'objectif de la fonction de pronostic considérée est de prédire la probabilité que le score d'anormalité considéré franchisse un seuil de défaillance au bout d'un horizon opérationnel donné. Cette prédiction est ensuite comparée à une limite de probabilité. Si la prédiction est supérieure à cette limite, une alarme est déclenchée et donne lieu à une dépose.

Les indicateurs de performance associés à ces deux mesures sont présentés en section II.4.2. Ceux rencontrés dans la littérature et ceux utilisés dans le domaine aéronautique y sont présentés. Leur estimation nécessite la disponibilité d'évolutions de dégradation afin de réaliser des prédictions et comparer les résultats obtenus à ceux observés. Ces données n'étant pas disponibles, la section II.4.3 décrit des modèles de dégradation permettant de les simuler. Enfin la section II.4.4 présente la méthode d'estimation des indicateurs de performance considérés dans le cadre du pronostic de consommations anormales.

II.4.2 INDICATEURS DE PERFORMANCES

II.4.2.1 Dans la littérature

Quelle que soit l'approche de pronostic utilisée, la caractérisation de cette dernière ne dépend que de la nature du pronostic réalisé, c'est-à-dire de la mesure ou de l'indicateur de pronostic à considérer.

Principalement deux mesures de pronostic sont rencontrées dans la littérature (cf. ANNEXE - 4) : le temps de vie résiduel (RUL) pour une approche de pronostic dite « déterministe » et la probabilité de franchissement d'un niveau de dégradation critique au bout d'un horizon fixé pour une approche de pronostic dite « probabiliste ». Ces mesures de pronostic définissent la nature du pronostic réalisé.

Les performances d'une fonction de pronostic dépendent de la nature du pronostic réalisé. C'est pour cela que deux classes de mesures de performances du pronostic sont rencontrées dans la littérature. La première classe est liée aux mesures de pronostic « déterministe » (RUL). Cette classe est très représentée dans la littérature. La seconde classe est liée aux mesures de pronostic « probabiliste » (probabilité de franchissement). Cette classe est peu représentée dans la littérature.

Dans [Dragomir, 2008], l'auteur précise qu'il est important de différencier les mesures ou indicateurs de pronostic et les mesures ou indicateurs de performance du pronostic.

Les mesures de performance du pronostic associées aux mesures du pronostic « déterministe » et « probabiliste » sont présentées dans les paragraphes suivants.
II.4.2.1.1 Mesures de performance du pronostic « déterministe »

Les mesures de performance du pronostic basées sur le temps de vie résiduel (RUL) sont nombreuses. [Saxena, 2008] a dressé un état de l'art de ces métriques d'évaluation de performance en s'appuyant sur différents domaines (météorologie, médecine, finance, automobile, aéronautique...). Plusieurs métriques ont été discutées dans [Vachtsevanos, 2006], [Saxena, 2008] et [Saxena, 2009]. Des métriques classiques telles que le biais, l'écart-type, l'erreur quadratique moyenne... peuvent être utilisées. Dans ce mémoire, il a été choisi de présenter les indicateurs exactitude (accuracy), précision (precision) et ponctualité (timeliness) puisque ce sont les plus utilisés.

Exactitude (Accuracy) : cette métrique mesure la proximité entre la valeur de RUL prédite (Predicted RUL : p_{RUL}) et la valeur de RUL réelle (Actual RUL : a_{RUL}). Le calcul de cette métrique s'appuie sur l'existence de données historiques sur plusieurs expérimentations sur un intervalle [t_0 ; t_p]. La formule de cette métrique au temps de prédiction t_p est :

$$Accuracy(t_p) = \frac{1}{N} \sum_{i=1}^{N} e^{\frac{-|D_i(t_p)|}{D_0}}$$
(24)

avec :

 $D_i(t_p) = p_{RUL(i)}(t_p) - a_{RUL(i)}(t_p)$: différence entre la RUL prédite à l'instant t_p et la RUL réelle pour l'expérience *i*.

 D_0 : facteur de normalisation (constante) dont la valeur est basée sur l'importance de la valeur réelle dans l'application.

N : Nombre d'expériences.

Accuracy appartient à l'intervalle [0;1]. Plus sa valeur est proche de 1, meilleures sont les performances.

<u>Précision</u> (precision) : cette métrique est une mesure de l'étroitesse de l'intervalle de confiance des prédictions, elle est basée sur la variance des valeurs prédites à partir de plusieurs expériences sur un intervalle $[t_0; t_p]$. La formule de cette métrique au temps de prédiction t_p est :

$$Precision(t_p) = \left(\frac{1}{N} \sum_{i=1}^{N} e^{-\frac{R_i}{R_0}}\right) e^{-\hat{\sigma}^2/\sigma_0}$$
(25)

avec :

 R_i : intervalle de confiance de la prédiction pour l'expérience i.

 $\hat{\sigma}^2$: l'estimateur de variance des $D_i(t_p)$.

 σ_0 et R_0 : facteurs de normalisation.

La précision est d'autant plus faible que les valeurs estimées sont dispersées.

Ponctualité (Timeliness) : Cette métrique représente la position relative de la fonction de densité de probabilité de la fonction de pronostic par rapport à l'apparition de la défaillance. Cette mesure évolue en fonction de la disponibilité des données et permet de juger du moment adéquat pour effectuer des actions préventives. Trois scénarii sont possibles, ils sont illustrés sur la Figure 40 :

- la défaillance a lieu plus tard que prévu. La conséquence de ce scénario n'est pas catastrophique mais déclenche des opérations de maintenance en avance.
- la défaillance a lieu dans l'horizon de prédiction. Ce scénario représente le cas de figure parfait. Les opérations de maintenance sont déclenchées au bon moment.
- la défaillance a lieu plus tôt que prévu. La conséquence de ce scénario peut être catastrophique s'il n'y a aucune opération après la détection de défaillance. Les opérations de maintenance sont déclenchées trop tard, la défaillance a déjà eu lieu.



Figure 40 : Timeliness de la prédiction de RUL

II.4.2.1.2 Mesures de performance du pronostic « probabiliste »

Les métriques associées au pronostic « probabiliste » sont largement issues du domaine météorologique où cette nature de pronostic est régulièrement utilisée. La première idée pour évaluer les performances d'une fonction de pronostic est d'estimer son erreur de prédiction. L'estimation de l'erreur est en règle générale réalisée en estimant l'erreur quadratique moyenne de l'écart entre les prédictions et les observations. Une métrique similaire existe dans le cadre du pronostic probabiliste. Cette métrique est appelée score de Brier (BS) [Brier, 1950].

Le score de Brier représente l'erreur quadratique moyenne du pronostic probabiliste :

$$BS = \frac{1}{N} \sum_{i=1}^{N} (p_i - o_i)^2$$
(26)

avec :

N: le nombre de prédictions,

 p_i : la probabilité de franchissement du seuil S, estimée à un instant t_p et pour un horizon donné H. $p_i=P(X(t_p+H)>S/t=t_p)$

 o_i : la probabilité observée qui est égale à 1 si il y a franchissement de seuil et 0 sinon.

Le score de Brier est compris entre 0 et 1, le score parfait étant 0.

D'après [Candille, 2005] les fonctions de pronostic probabilistes doivent répondre à deux critères :

- la fiabilité indique dans quelle mesure les probabilités prédites concordent avec les observations (franchissements de seuil). Si la fréquence des observations est supérieure ou inférieure à celle des prédictions, les prédictions sont, respectivement, sous-estimées ou surestimées,
- la résolution permet d'évaluer la capacité de la fonction de pronostic à dissocier plusieurs événements à prédire. La résolution d'une fonction de pronostic est forte lorsque la distribution des prédictions correspond à la distribution des observations. Elle est faible dans le cas contraire.

L'estimation de la fiabilité et de la résolution d'une fonction de pronostic est possible grâce à la décomposition du score de Brier [Murphy, 1973]. Ce dernier peut être décomposé en trois composantes (BS = fiabilité – résolution + incertitude) :

$$BS = \frac{1}{N} \sum_{k=1}^{T} n_k (p_k - \bar{o}_k)^2 - \frac{1}{N} \sum_{k=1}^{T} n_k (\bar{o}_k - \bar{o})^2 + \bar{o} (1 - \bar{o})$$
(27)

où un échantillon de N prédictions est séparé en T classes selon les probabilités prédites p_k (par exemple p_i appartient à : 0% - 5% ; 5% - 10% ;...; 95% - 100%). Chaque classe contient n_k

probabilités prédites (p_k) . \bar{o}_k correspond à la fréquence observée lorsque la classe k est considérée et \bar{o} correspond à la fréquence moyenne observée sur la totalité de l'échantillon.

Les deux premières composantes ont été définies précédemment. Quant à la troisième, elle est appelée incertitude. L'incertitude permet de quantifier la variabilité des observations. Elle n'est pas utilisée en tant que métrique des performances du pronostic. Cependant, connaître l'incertitude sur les observations donne une information utile pour interpréter les résultats en termes de performances.

Une dérivée du score de Brier est le score d'habileté (mesure d'exactitude) de Brier (Brier Skill Score) [Ebert, 2013] qui compare le score de Brier d'une prédiction à une valeur de référence. Habituellement, l'incertitude est utilisée comme référence.

$$BSS = \frac{BS - BS_{référence}}{BS_{référence}} = 1 - \frac{BS}{BS_{référence}}$$
(28)

avec :

BS : le score de Brier de la fonction de prévision,

BS_{référence}: l'incertitude correspondant à la troisième composante du score de Brier.

Le score d'habileté de Brier varie de $-\infty$ à 1, 0 indiquant que le système de prévision n'a pas d'habileté par rapport à la probabilité de référence et 1 est le score parfait.

Il est possible d'avoir une idée de la fiabilité de façon graphique à l'aide d'un diagramme de fiabilité, Figure 41, utilisé pour évaluer la fiabilité d'une fonction de pronostic [Bröcker, 2007]. Ce diagramme consiste à tracer les fréquences observées (\bar{o}_k) des événements (franchissement de seuil par exemple) en fonction des probabilités prédites p_k pour ces événements. La courbe ainsi obtenue est comparée à la diagonale du diagramme. La diagonale correspond au cas où les prédictions sont en accord parfait avec les observations de franchissement. Les points en-dessous (respectivement au-dessus) de la diagonale indiquent que les prédictions ont été surestimées (respectivement sous-estimées).



Figure 41 : Exemple de diagramme de fiabilité

Il est possible d'avoir une idée de la résolution de la fonction de pronostic à l'aide d'une courbe COR. Pour cela il faut se ramener à un problème de décision basé sur les probabilités de franchissement estimées. Cela implique qu'il existe une règle de décision qui permet de classer les probabilités estimées selon deux états (franchissement ou non franchissement). La courbe COR permet alors de caractériser la capacité d'une fonction de pronostic à différencier deux catégories d'événements ce qui est également l'objectif de la résolution. Meilleures sont les performances de la courbes COR, meilleure est la résolution de la fonction de pronostic.

II.4.2.2 Dans le domaine aéronautique

De même que pour la fonction de détection, les indicateurs de performance du pronostic retenus répondent à des exigences opérationnelles énoncées par les compagnies aériennes.

Ils sont différents de ceux envisagés dans la littérature :

- la proportion de franchissements non justifiés, *P(Non franchissement/Alarme)* : cet indicateur est l'équivalent de la proportion d'alarmes fausses dans le cadre du pronostic. Il s'intéresse au nombre de fois où la fonction de pronostic échoue lorsqu'elle annonce un franchissement de seuil.
- la proportion de franchissements justifiés, *P*(*Alarme*/*Franchissement*) : cet indicateur est l'équivalent de la proportion de bonne détection dans le cadre du pronostic. Il s'intéresse au nombre de bonnes prédictions réalisées par la fonction de pronostic.

Ces indicateurs de performance reposent sur :

- le déclenchement d'une alarme. Dans le cadre de cette étude, une alarme est déclenchée lorsque la probabilité de franchissement estimée est supérieure à 0,8 ce qui donne lieu à une dépose.
- la disponibilité de trajectoires du score d'anormalité évoluant jusqu'à franchissement d'un seuil de défaillance.

Une fois ces éléments disponibles, il est possible de comparer les prédictions de franchissement réalisées par la fonction de pronostic avec les franchissements observés.

II.4.2.3 Conclusion

Au vu des mesures de performance du pronostic présentées, il apparait que l'évaluation des performances du pronostic repose sur la disponibilité d'observations allant jusqu'à défaillance ou dépassement d'un seuil critique.

De telles données ne sont pas (ou rarement) disponibles dans le domaine aéronautique. Les seules données disponibles ne représentent que le cas sans dégradation. L'application des métriques présentées n'est donc pas possible.

Comme précédemment, pour compenser le manque de données, il est possible de faire des simulations jusqu'à défaillance ou dépassement d'un seuil représentatif d'un niveau de dégradation critique. La simulation s'appuie sur des modèles de dégradation qui permettent de traduire le mécanisme de détérioration ou dégradation d'un composant ou d'un système.

II.4.3 MODELES DE DEGRADATION

L'objectif des modèles de dégradation est de caractériser l'évolution de l'état de santé d'un système ou d'un composant en modélisant l'évolution de sa dégradation jusqu'à la défaillance ou le dépassement d'un seuil critique affectant les performances de fonctionnement.

Le terme « dégradation » décrit l'évolution irréversible d'une ou plusieurs caractéristiques d'un bien liée au temps, à la durée d'utilisation ou à une cause externe. Cette évolution peut être soudaine ou graduelle et son issue est la défaillance (si la dégradation ne s'est pas stabilisée au cours du temps).

La modélisation des dégradations à évolution soudaine considère deux états possibles du système ou du composant étudié : l'état de marche et l'état de panne. Dans ce cas de figure, la modélisation de la dégradation consiste à déterminer la loi de l'instant de panne. La modélisation de la dégradation peut être réalisée de différentes manières (paramétrique, non paramétrique, semi paramétrique). Des modèles dits de durée de vie [Deloux, 2008] sont utilisés. L'un des modèles les plus usuels est la loi de Weibull [Nikulin, 2007] [Letot, 2009]. Ces modèles permettent d'estimer la date de la défaillance

après avoir modélisé la dégradation en se basant sur un historique de durées de fonctionnement avec défaillance.

La modélisation des dégradations à évolution graduelle considère plus de deux états possibles du système ou du composant étudié. Différents états sont considérés, allant de l'état neuf (ou fonctionnement nominal) à l'état de panne en passant par des états intermédiaires n'affectant pas les performances du système de manière critique. Le système se dégrade donc graduellement au cours de son fonctionnement de manière discrète ou continue. La modélisation de ce type de dégradation a fait l'objet de nombreuses publications sur les dernières décennies [Nikulin, 2010]. Il apparait que les analyses fiabilistes basées sur des modèles de dégradation donnent de meilleurs résultats que celles basées sur des modèles de durée de vie [Letot, 2009]. Deux classes de modèles, associées à la nature discrète ou continue de la dégradation, sont rencontrées dans la littérature [Salami, 2011]:

- pour les modèles à dégradation discrète (ou à espace d'états fini ou modèles multi-états), l'ensemble possible des états du système est fini et chaque état représente un niveau de dégradation du système. Ces modèles sont souvent utilisés dans le cadre de défaillances traumatiques (liées à des chocs). Le système évolue d'un état de dégradation vers un autre à chaque choc modélisé par un incrément discret appelé saut. Des processus markoviens tel que les chaines de Markov sont utilisés. Le principal inconvénient de ces modèles réside dans le fait que le nombre d'état est fini. Ils ne permettent donc pas de modéliser des systèmes dont le nombre d'état est inconnu.
- pour les modèles à dégradation continue, deux modèles sont fréquemment utilisés : le processus de Wiener à tendance positive et le processus Gamma. Ces modèles permettent de modéliser l'évolution d'une dégradation croissante (ou croissante en moyenne). Ils appartiennent à la classe des processus de Lévy qui sont des processus stochastiques à accroissements indépendants. La dégradation à un instant donné ne dépend donc que du niveau de dégradation à l'instant précédent et de l'intervalle de temps entre ces deux instants. Le processus de Wiener avec tendance croissante décrit des trajectoires de dégradation croissantes en moyenne. Par contre, la probabilité de voir la dégradation décroître sur un intervalle est non nulle, ce qui peut être un inconvénient pour certains systèmes modélisés. En revanche, le processus Gamma est monotone croissant et permet de modéliser des mécanismes de dégradation qui sont par nature lents, continus et croissants avec indépendance des accroissements.

Dans le cadre de cette thèse, les dégradations à caractériser ont une évolution graduelle croissante et monotone. Ce type d'évolution traduit le fait que l'état de santé du système ne s'améliore pas au cours du temps [Salami, 2011]. Le processus Gamma a donc été choisi pour caractériser cette évolution. Il est détaillé dans le paragraphe suivant. Des détails sur les différentes applications du processus Gamma sont donnés dans [Van Noortwijk, 2009].

II.4.3.1 Processus Gamma

Le processus Gamma est un processus à espace d'états continu et à accroissements positifs et indépendants. Il présente d'autres caractéristiques très intéressantes :

- il est possible de formuler une hypothèse sur sa tendance moyenne (à l'aide d'avis d'experts par exemple),
- les accroissements peuvent être stationnaires ou non. Dans le cas d'accroissements stationnaires, il s'agit d'un processus Gamma homogène.

Ce second point est très intéressant par le fait que l'évolution d'une dégradation peut ne pas être linéaire. Cette qualité du processus Gamma est un avantage qui justifie son usage fréquent [Van Noortwijk, 2009].

Les processus Gamma en général et les cas particuliers homogènes et non homogènes à 3 paramètres, sont décrits dans les paragraphes suivants [Roussignol, 2009] [Van Noortwijk, 2009].

II.4.3.1.1 Processus Gamma

Le processus Gamma est composé d'un paramètre de forme (v(t)) et d'un paramètre d'échelle (u). $(X_t)_{t\geq 0}$ est un processus Gamma si :

- $X_0 = 0$
- $(X_t)_{t\geq 0}$ est un processus stochastique à accroissements indépendants
- Soit $0 \le h \le t$, la loi de l'accroissement $(X_t X_h)$ suit une loi Gamma : $\Gamma(v(t) v(h); u)$

La densité de la loi Gamma $\Gamma(v(t), u)$ est définie par :

$$f_{X_t}(x) = \frac{u^{\nu(t)}}{\Gamma(\nu(t))} x^{\nu(t)-1} e^{-ux} I_{(0,\infty)}(x)$$
(29)

avec :

 $I_{A}(x) = \begin{cases} 1 \text{ si } x \in A \\ 0 \text{ si non} \end{cases}$ $\Gamma(a) = \int_{0}^{\infty} z^{a-1} e^{-z} dz \text{ (fonction Gamma)}$

On montre que :

$$E(X_t) = \frac{v(t)}{u}$$
(30)

$$Var(X_t) = \frac{v(t)}{u^2}$$
(31)

- $(X_t)_{t\geq 0}$ est un processus dont les trajectoires sont presque sûrement croissantes,
- $(X_t)_{t \ge 0}$ est un processus Markovien,
- Les trajectoires de X admettent une infinité dénombrable de sauts dans tout intervalle de temps,
- Si S est le seuil de défaillance et $T = inf(t > 0 : X_t \ge S)$ on a :

$$P(T > t) = P(X_t < S) = \int_0^S \frac{u^{\nu(t)}}{\Gamma(\nu(t))} x^{\nu(t)-1} e^{-ux} dx$$
(32)

II.4.3.1.2 Processus Gamma homogène

Le processus Gamma homogène est un cas particulier du processus Gamma lorsque le paramètre de forme v(t) = ct avec c > 0.

II.4.3.1.3 Processus Gamma non homogène à 3 paramètres

Le processus Gamma non homogène à trois paramètres est un cas particulier du processus Gamma avec un exposant sur le temps [Van Noortwijk, 2009]. Le paramètre de forme du processus Gamma est considéré de la forme suivante $v(t) = ct^b$ (avec b et c réels strictement positifs).

Il est possible d'obtenir différentes formes d'évolution de dégradation en fonction de la valeur de *b* (Figure 42) :

- si *b* = 1, le processus Gamma est un processus homogène. Les accroissements de ce processus sont stationnaires. L'évolution de la dégradation est donc linéaire.
- si b < 1, le processus Gamma est un processus non homogène et l'évolution de la dégradation a une forme logarithmique.
- si *b* > *1*, le processus Gamma est un processus non homogène et l'évolution de la dégradation a une forme parabolique.



Figure 42 : Evolution de la dégradation selon des processus Gamma pour b=1; b=2 et b=0,5 dans la relation $v(t) = ct^b$.

Que le processus Gamma soit homogène ou non, l'estimation de ses paramètres peut être réalisée à l'aide de la méthode des moments ou de la méthode du maximum de vraisemblance [Roussignol, 2009].

Pour des paramètres du processus Gamma donnés, il est possible de générer des trajectoires d'évolution. La méthode de synthèse de trajectoires est présentée dans le paragraphe suivant.

II.4.3.1.4 Génération de trajectoires

Lorsque les paramètres du processus Gamma sont connus, la méthode permettant de générer une trajectoire du processus Gamma de paramètres $v(t) = ct^b$ et u constituée de n observations est le suivant [Nguyen, 2012] :

- générer *n* instants d'observations *t_i*.
- simuler des réalisations de *n* accroissements avec

$$\Delta X_i = X_{t_i} - X_{t_{i-1}} \sim \Gamma(v(t_i) - v(t_{i-1}); u) \quad i = 1...n$$

• construire la trajectoire $x_0 = 0$ et $x_n = \sum_{i=1}^n \Delta x_i$. Un exemple est donné à la Figure 43.



Figure 43: Illustration de la méthode de génération des accroissements d'un processus Gamma.

Lorsque les paramètres du processus Gamma sont inconnus, cette procédure de génération de trajectoires d'évolution peut être adaptée grâce à de l'expertise. Il est possible de fixer a priori l'évolution en moyenne des trajectoires ainsi que leur écart-type à un instant t et également une valeur

de b qui correspond à la forme de tendance moyenne. Les paramètres c et u s'obtiennent alors à l'aide de l'espérance, de la variance et de b en utilisant les relations (30) et (31).

Pour illustrer cette démarche, le cas du système de surveillance de la consommation d'huile est considéré. L'objectif est de générer des consommations anormales à partir des consommations nominales. Pour ce faire, les avis d'experts concernant l'impact d'une fuite d'huile sur les consommations ont été considérés. D'après les experts, une fuite d'huile induit, dans 90% des cas, une hausse de la consommation nominale de 0,1 l/h/mois avec un écart-type de 0,01 l/h au bout d'un mois.

La Figure 44 représente des trajectoires du processus Gamma généré à partir des informations communiquées par les experts. 500 trajectoires ont été générées pour une évolution linéaire (b=1) en moyenne de 0,1 l/h tous les 100 vols (1 mois d'exploitation) et un écart-type de 0,01 l/h au vol n°100.



Figure 44 : 500 trajectoires théoriques de surconsommation générées par simulation pour une évolution moyenne de 0,1 l/h/mois et un écart type de 0,01 l/h au bout d'un mois.

II.4.4 METHODE D'ESTIMATION

II.4.4.1 Introduction

La fonction de pronostic considérée dans cette thèse consiste, à partir d'un indicateur d'anormalité représentatif de l'état de santé du système considéré, à prédire la probabilité de franchir un seuil à un horizon opérationnel donné. La signification du seuil dépend du but dans lequel il a été déterminé. Son franchissement peut représenter l'atteinte d'un niveau critique concernant les performances du système sous surveillance ou tout simplement la panne. Dans notre cas, il s'agit d'un seuil de défaillance.

En opération, la fonction de pronostic n'est déclenchée qu'après détection d'une dégradation prémice d'anomalie. La détection a lieu lorsque l'indicateur d'anormalité franchit un seuil de détection (Figure 45). A partir de cet instant noté « x_d », le pronostic est déclenché. La fonction de pronostic permet d'estimer, en se basant sur un historique de taille *T*, la probabilité que l'indicateur franchisse le seuil de défaillance sur un horizon temporel de taille *H*. Lorsque la probabilité de franchissement estimée par la fonction de pronostic dépasse une limite de probabilité fixée à 0,8, une alarme est émise et elle donne lieu à une dépose.



Figure 45 : Illustration du déclenchement de la fonction de pronostic.

Au vu des mesures de performance du pronostic probabiliste présentées, l'évaluation des fonctions de pronostic repose sur la disponibilité d'observations de dégradation allant jusqu'à franchissement de seuil. Comme les seules données disponibles sont des observations d'un indicateur sans dégradation, il est a priori impossible d'évaluer les performances d'une fonction de pronostic.

Pour contourner ce manque de données, le processus Gamma a été utilisé pour générer des trajectoires d'évolution allant jusqu'au franchissement de seuil. Ces trajectoires ajoutées aux observations de l'indicateur sans dégradation ont été utilisées afin de quantifier les performances de la fonction de pronostic utilisée par les systèmes de surveillance.

La fonction de pronostic considérée est appliquée à ces données. La procédure d'estimation est décrite dans le paragraphe suivant.

II.4.4.2 Procédure d'estimation

Ce paragraphe décrit la méthode d'estimation des indicateurs de performance du pronostic. Cette dernière a été établie dans [Hmad, 2012b] dans le cadre de la surveillance de la consommation d'huile. Tout d'abord, il est nécessaire de recenser les données disponibles pour leur estimation. Les données considérées sont les suivantes :

• les valeurs des consommations d'huile estimées, notées $C_i(t)$, selon l'algorithme EOC (cf. section I.7.1) qui représentent l'indicateur produit par cet algorithme. Un exemple de consommation est représenté Figure 46.



Figure 46 : Exemple de consommation estimée pour le moteur 1 de l'avion 1.

 les surconsommations, notées SC_i(t), simulées à l'aide de processus Gamma choisi d'après les avis d'experts. Un exemple correspondant à 500 réalisations d'un tel processus est donné Figure 47,



Figure 47 : Exemple de 500 trajectoires de surconsommation générées par simulation.

• des trajectoires dites « pseudo observées », notées $PO_i(t)$, ont été construites en ajoutant les surconsommations simulées aux consommations d'huile estimées pour obtenir une évolution de dégradation avec les propriétés souhaitées, $PO_i(t) = C_i(t) + SC_i(t)$. La Figure 48 représente ces trajectoires pour les données issues des deux figures précédentes,



Figure 48: Trajectoires « pseudo observées » : consommation estimée pour le moteur 1 de l'avion 1 ajoutée aux surconsommations simulées.

 des trajectoires dites « théoriques », *CTHi(t)*, décrivent le phénomène théorique considéré. Celui-ci se traduit par une évolution linéaire de la consommation d'huile qui est considérée constante en fonctionnement normal (≈0,2 l/h). Ces trajectoires correspondent aux surconsommations simulées ajoutées à la consommation moyenne (*CM*), *CTHi(t)= CM + SC_i(t)*. Un exemple est donné sur la Figure 49.



Figure 49: Trajectoires « théoriques » : moyenne des consommations pour le moteur 1 de l'avion 1 ajoutées aux surconsommations simulées.

A partir de ces différents types de données, la procédure d'estimation de chaque indicateur de performance du pronostic est décrite dans les deux paragraphes suivants.

II.4.4.2.1 P(Non franchissement|Alarme)

L'estimation de P(Non franchissement|Alarme) consiste, à partir de plusieurs trajectoires, à déterminer la proportion d'alarmes émises par la fonction de pronostic sans qu'il y ait franchissement du seuil de défaillance dans l'intervalle de temps considéré (*H*). Pour ce faire, la procédure a été la suivante :

Pour chacune des trajectoires « pseudo observée » :

- déterminer l'instant (*x*_d) de déclenchement du pronostic,
- appliquer la fonction de pronostic en utilisant les données passées de l'intervalle $[x_d-T, x_d]$,
- estimer la probabilité de franchir le seuil de pronostic au bout de l'horizon temporel H (à x_d + H),
- si la probabilité estimée est supérieure à une limite fixée à 0,8, déclencher une alarme,
- en cas d'alarme, identifier la trajectoire « théorique » correspondant à la trajectoire « pseudo observée » considérée,
- vérifier si la trajectoire théorique a franchi le seuil de défaillance à l'instant $x_d + H$. Incrémenter le compteur de franchissement non justifié si ce n'est pas le cas.

Cette procédure a été appliquée à partir de l'instant x_d sur l'ensemble d'une trajectoire. Ceci a été fait pour toutes les trajectoires. Une fois toutes les trajectoires considérées, la proportion de franchissements non justifiés qui représente une estimation empirique de P(Non franchissement/Alarme) a été déterminée. Cela a permis d'observer l'évolution de cet indicateur au fil des vols.

II.4.4.2.2 P(Alarme|Franchissement)

Les considérations à prendre en compte pour cet indicateur sont identiques à celles de l'indicateur précédent. La procédure d'estimation a été la suivante :

Pour chaque trajectoire théorique :

- déterminer l'instant (*x_p*) de franchissement du seuil de défaillance pour la trajectoire théorique considérée.
- identifier la trajectoire « pseudo observée » correspondante.

- appliquer la fonction de pronostic aux observations de la trajectoire « pseudo observée » comprises dans l'intervalle de temps $[x_p-H-T, x_p-H]$ afin d'estimer la probabilité que la trajectoire franchisse le seuil de pronostic à l'instant x_p .
- si la probabilité estimée est supérieure à une limite de probabilité fixée à 0,8, déclencher une alarme et incrémenter le compteur de franchissement justifié.

Cette procédure a été appliquée à partir de l'instant x_p sur l'ensemble d'une trajectoire. Ceci a été fait pour toutes les trajectoires. Une fois toutes les trajectoires considérées, la proportion de franchissements justifiés qui représente une estimation empirique de *P*(*Alarme*/*Franchissement*) a été déterminée. Cela a permis d'observer l'évolution de cet indicateur au fil des vols.

II.5 CONCLUSION

Il est important de noter que l'objectif de la thèse n'est pas de discuter du choix des méthodes de détection et de pronostic (ce choix a été fait par les concepteurs des systèmes de surveillance) mais d'en évaluer les performances.

Ce chapitre a permis d'identifier les exigences des compagnies aériennes concernant la détection et le pronostic. Dans le domaine aéronautique, la formalisation du problème de surveillance et les exigences de performance de ces systèmes sont réalisés d'un point de vue opérationnel. Il en résulte souvent que les indicateurs de performances utilisés et ceux qui sont issus de la littérature sont différents. L'évaluation des performances consiste donc à adapter des indicateurs issus de la littérature au contexte industriel ou bien à en définir de nouveaux.

L'adaptation de ces indicateurs consiste à s'assurer de leur pertinence vis-à-vis des exigences de performances attendues. La question posée a alors été la suivante : les indicateurs de performances choisis reflètent-ils les exigences attendues ou bien doit-on en définir de nouveaux avant de les utiliser ?

Les exigences de performance des systèmes de surveillance énoncées par les exploitants sont :

- **pour la détection**, en plus de la probabilité de bonne détection (*P(Détection/Dégradation)*), les compagnies aériennes ont formulé une exigence concernant la proportion d'alarmes fausses (*P(Sain/Détection)*). Une méthode d'estimation de ces indicateurs de performance a été établie. Elle nécessite la connaissance de la distribution de la statistique de décision dans le cas sain afin de déterminer les quantiles extrêmes correspondant aux seuils de détection. L'étude de la statistique de décision dans le cadre du démarrage (score d'anormalité) a révélé qu'une estimation de sa densité par fenêtre de Parzen présente le meilleur compromis en termes de performance. L'estimation de la probabilité de bonne détection nécessitant la présence de dégradations, une méthode de simulation de dégradations a été développée dans le cadre du démarrage.
- **pour le pronostic**, de façon analogue à la détection, les exigences portent sur la probabilité de franchissements non justifiés, *P(Non franchissement/Alarme)*, et la probabilité de franchissements justifiés, *P(Alarme/Franchissement)*. La procédure d'estimation de chacune de ces probabilités a été menée dans le cadre du pronostic de consommations d'huile anormales. Les données nécessaires à leur estimation sont les suivantes : des consommations estimées, des surconsommations simulées à l'aide de processus Gamma à trois paramètres, des trajectoires dites « pseudo observées » et des trajectoires « théoriques ». Cela a permis d'établir une méthode d'estimation des performances de la fonction de pronostic.

La thèse a nécessité de concilier le point de vue opérationnel et les informations issues de la littérature afin de quantifier les performances des algorithmes de surveillance. Dans le chapitre suivant, l'estimation des indicateurs de performance et l'analyse des résultats obtenus ont été illustrées par la maturation de :

- la fonction de détection dans le cadre de la surveillance de la séquence de démarrage,
- la fonction de pronostic dans le cadre de la surveillance de la consommation d'huile.

III.1 INTRODUCTION

L'objectif de ce chapitre est d'estimer les performances des fonctions de détection et de pronostic afin de les comparer aux exigences des compagnies aériennes et de les améliorer lorsqu'elles n'y répondent pas. Ce chapitre est composé de deux parties.

La première partie (section III.2) présente les résultats de maturation de la fonction de détection dans le cadre de la surveillance de la séquence de démarrage. Deux méthodes de détection sont considérées. Pour chacune, la méthode initiale avec les paramétrages de base (paramétrage « usine ») a été analysée puis deux variantes ont été considérées. Après estimation des performances pour le paramétrage initial existant, des améliorations sont proposées et les résultats sont comparés aux exigences attendues. Enfin, une comparaison des deux approches est réalisée.

La seconde partie (section III.3) présente la maturation de la fonction de pronostic dans le cadre de la surveillance de la consommation d'huile.

III.2 DETECTION DE PREMICES DE NON DEMARRAGE

III.2.1 INTRODUCTION

Au vu des distributions des scores d'anormalité avec et sans dégradation (cf. section II.3.4), il apparait que la discrimination entre l'état sain et les différentes intensités de dégradation n'est pas aisé.

Dans le cadre de la maturation de la fonction de détection, deux approches ont été considérées. La première dite « approche moyenne mobile » consiste à détecter une anomalie lorsque la moyenne mobile du score d'anormalité sur un nombre n de démarrages dépasse un seuil. La seconde dite « approche k parmi n » consiste à détecter une anomalie lorsqu'un nombre k d'observations du score d'anormalité parmi n franchissent un seuil. L'étude de leurs performances fait l'objet des paragraphes III.2.2 et III.2.3 afin de déterminer l'approche qui respecte au mieux les exigences attendues.

III.2.2 APPROCHE MOYENNE MOBILE

III.2.2.1 Principe

L'approche moyenne mobile consiste à détecter le franchissement d'un seuil par la moyenne du score d'anormalité sur une fenêtre glissante de n démarrages consécutifs.

Sous l'hypothèse que les scores d'anormalité sont indépendants, le fait de moyenner le score d'anormalité réduit la variance d'un facteur $\frac{1}{\sqrt{n}}$ ce qui permet une meilleure discrimination entre l'état sain et les différentes intensités de dégradations [Hmad, 2009]. Le nombre *n* de démarrages dans la configuration de base est égal à 5. Il a été choisi par les concepteurs car il correspond à un jour d'exploitation. La Figure 50 représente un histogramme du score d'anormalité sans dégradation avant et après moyenne mobile sur n = 5 démarrages.



Figure 50 : Histogramme du score d'anormalité sans dégradation avant et après moyenne mobile sur n = 5 démarrages.

Ce type d'approche de détection permet de limiter les erreurs de détection dues à des anomalies ponctuelles ou à du bruit. En revanche, son principal inconvénient est de nécessiter n démarrages avant de prendre une décision.

Le paragraphe suivant s'intéresse aux performances de cette approche.

III.2.2.2 Performance pour le paramétrage existant

La fonction de détection repose sur deux éléments :

- le score d'anormalité,
- le seuil de détection.

L'estimation des performances consiste à appliquer le seuil de détection :

- à la distribution du score d'anormalité sans dégradation afin de déterminer la valeur de l'erreur de première espèce correspondante,
- au score d'anormalité avec dégradation pour déterminer la proportion de bonne détection.

Ces deux estimations sont ensuite utilisées pour calculer la proportion d'alarmes fausses, P(Sain/Détection), pour ce seuil.

Dans la version de base de la fonction de détection, quelle que soit l'approche, un seuil par type de défaut a été renseigné par les concepteurs. Au final, quatre seuils ont été renseignés, ils sont répertoriés dans le Tableau 13.

URL - Dégradation	Seuil de détection
APU - Baisse de pression	3
HMU - Baisse de débit carburant	6
HMU - Augmentation débit carburant	6
SAV - Ouverture lente de la vanne	6

Tableau 13 : Seuils disponibles dans la version de base de la fonction détection.

Concernant la distribution du score d'anormalité moyenné sans dégradation, il a été décidé d'utiliser l'ajustement par fenêtre de Parzen pour l'estimation de sa densité (Figure 51).



Figure 51 : Score d'anormalité sans dégradation moyenné sur n = 5 démarrages et ajustement par fenêtre de Parzen.

Après application des seuils de détection, les résultats obtenus pour le paramétrage de base sont reportés dans le Tableau 14. Il apparait que les performances sont très loin de ce qui est exigé. Ces résultats sont typiques de ce qui arrive lorsque les seuils de détection sont réglés « visuellement » ou en fonction d'une exigence arbitraire sur l'erreur de première espèce. Or, ce qui importe, c'est la proportion d'alarmes fausses et non l'erreur de première espèce, beaucoup moins contraignante.

Par exemple, pour une baisse de pression APU, l'erreur de première espèce correspondant au seuil, de valeur 3, est de l'ordre de 1%, la proportion d'alarmes fausses est alors de l'ordre de 99 %. Il n'est pas acceptable d'un point de vue « opérations » ou « maintenance en ligne » que 99% des alarmes soient fausses surtout pour des réparations coûteuses.

Dégradation	P (Sain Détection) (%)	\widehat{PoD} (%)
APU : pression nominale -11,7%	99,99	51,66
APU : pression nominale -23,4%	99,98	100
APU : pression nominale -35%	99,98	100
HMU : Débit carburant +7%	42,76	19,63

29.62

15,35

19,10

8,76

6,68

97.91

19,89

14,60

34.83

80,86

30,29

74,53

100

0.37

68,86

100

Pour améliorer ces résultats, des améliorations sont proposées et discutées au paragraphe suivant.

Tableau 14 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} à partir des scores d'anormalité moyennés sur n = 5 démarrages pour le paramétrage de base.

HMU : Débit carburant +10%

HMU : Débit carburant +13%

HMU : Débit carburant -7%

HMU : Débit carburant -10%

HMU : Débit carburant -13%

SAV : Ouverture de la vanne +2s

SAV : Ouverture de la vanne +4s

SAV : Ouverture de la vanne +8s

III.2.2.3 Analyse et amélioration des performances

L'objectif de cette section est de proposer des améliorations et d'analyser leurs impacts sur les performances du détecteur afin de les intégrer ou non à l'algorithme de surveillance de la séquence de démarrage. Pour ce faire, plusieurs évolutions ont été proposées :

- dans un premier temps, l'approche moyenne mobile a été conservée. C'est le sujet de cette section. Dans ce cadre, une première amélioration a porté sur le réglage du seuil de détection dans le but de répondre aux exigences. Une seconde amélioration a porté sur la méthode d'apprentissage des modèles de normalisation consistant à ne plus effectuer un apprentissage global sur l'ensemble des moteurs mais plutôt des apprentissages particularisés aux types de moteurs, ou aux moteurs eux-mêmes.
- dans un second temps, une autre approche de détection a été considérée. C'est l'objet de la section III.2.3.

III.2.2.3.1 Réglage du seuil de détection

Considérant les donnés exigées $P(Sain/Détection)_{exigée} = 1\%$, $PoD_{exigée} > 99\%$ et P(Dégradation)dépendant de la dégradation (APU, HMU ou SAV), la valeur de $\hat{\alpha}_{exigée}$ a été déterminée en utilisant la relation (2) du § II.3.1.2. P(Dégradation) étant spécifique à chaque URL (cf. Tableau 3 section I.6.2), la valeur de $\hat{\alpha}_{exigée}$ est différente pour chacune d'entre elles. Il en résulte qu'un seuil de détection spécifique à chaque URL a été déterminé et est répertorié dans le Tableau 15.

URL - Dégradation	$\widehat{P}(Dégradation)$	$\widehat{\alpha}_{exig\acute{e}e}$	Seuil de détection
APU - Baisse de pression	1,56 ⁻⁵	1,58-7	5,99
HMU - Baisse de débit carburant	2,07 ⁻⁶	2,09-8	6,13
HMU - Augmentation débit carburant	1,01-6	1,02 ⁻⁸	6,18
SAV - Ouverture lente de la vanne	8,66 ⁻⁷	8,75-9	6,19

Tableau 15 : Probabilité de dégradation par URL et seuil de détection.

Ces seuils de détection ont été appliqués aux scores d'anormalité avec et sans dégradation pour estimer les performances de l'approche moyenne mobile pour les différentes intensités considérées. Le Tableau 16 répertorie les estimations de P(Sain/Détection) et PoD pour l'ensemble des dégradations considérées.

Pour rappel, la phase de localisation a lieu systématiquement avant la phase de détection. Il est donc possible de choisir le seuil à appliquer conditionnellement à l'origine de défaillance la plus probable.

Dégradation	$\widehat{P}(Sain Détection)(\%)$	<i>PoD</i> (%)
APU : pression nominale -11,7%	78	0,3
APU : pression nominale -23,4%	24,7	3,1
APU : pression nominale -35%	1,4	68,9
HMU : Débit carburant +7%	5,7	16,6
HMU : Débit carburant +10%	3,2	30,3
HMU : Débit carburant +13%	1,3	74,1
HMU : Débit carburant -7%	3,6	27,4
HMU : Débit carburant -10%	1,4	70,5
HMU : Débit carburant -13%	1	100
SAV : Ouverture de la vanne +2s	78	0,3
SAV : Ouverture de la vanne +4s	1,8	53,9
SAV : Ouverture de la vanne +8s	1	100

Tableau 16 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} à partir des scores d'anormalité moyennés sur n = 5démarrages pour $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Malgré le fait que le score d'anormalité soit moyenné, la discrimination entre l'état sain et les différentes intensités de dégradation n'est pas aisée :

- pour une baisse de pression APU, l'intensité faible est quasiment confondue avec l'état sain (cf. Figure 88, ANNEXE 5) ce qui induit une proportion de bonne détection de 0,3%. Ce résultat impacte directement la proportion d'alarmes fausses qui s'élève à 78%, ce qui est totalement inacceptable. Plus l'intensité de la dégradation est importante plus les performances du détecteur s'améliorent. En effet, *PoD* passe de 0,3% pour l'intensité de dégradation la plus faible à 68,9% pour l'intensité de dégradation la plus forte. Cela permet de passer de *P*(*Sain*|*D*étection) = 78% à *P*(*Sain*|*D*étection) = 1,4% proche de 1% souhaité.
- **pour une hausse de débit carburant**, les exigences de performances du détecteur ne sont toujours pas atteintes quelle que soit l'intensité de la dégradation. Toutefois les performances du détecteur sont meilleures que pour une baisse de pression APU. Cela est dû aux lois d'impact des dégradations qui sont différentes en fonction de la dégradation considérée. Le mode de détermination du seuil a permis de se rapprocher de l'exigence concernant P(Sain/Détection).
- **pour une baisse de débit carburant**, la valeur de \widehat{PoD} est de 100% et $\widehat{P}(Sain|Détection)$ de 1% pour l'intensité forte. Les exigences de performance du détecteur ne sont atteintes que pour cette intensité. Les performances estimées pour les intensités faible et moyenne sont également meilleures que dans les cas précédents. L'intensité moyenne de dégradation étant détectée à 70,5%, la proportion d'alarmes fausses correspondante est de 1,4%.
- pour une ouverture lente de la vanne SAV, l'intensité faible n'est quasiment pas détectée, *poD* = 0,3%, et la proportion d'alarmes fausses est importante, *P*(*Sain*|*Détection*) = 78%. L'intensité moyenne est détectée à 53,9% pour une proportion d'alarmes fausses à 1,8%. Enfin, l'intensité forte est détectée à 100%, la proportion d'alarmes fausses correspondante est de 1%. Les exigences de performances sont donc atteintes pour l'intensité de dégradation la plus forte.

A titre illustratif, la Figure 52 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages successivement sans dégradation et avec les trois degrés d'intensité pour une ouverture lente de la vanne SAV. Des figures analogues sont présentées en ANNEXE - 5 dans le cadre de l'APU et du HMU.



Figure 52 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une ouverture lente de la vanne SAV.

L'estimation des performances de l'approche moyenne mobile a été réalisée pour les différentes dégradations considérées et pour trois intensités différentes. Quel que soit le type de défaut, le mode de détermination du seuil a permis de se rapprocher des exigences de performances. Les résultats montrent que les exigences de performances $P(Sain/Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$ ne sont atteintes que pour les intensités fortes d'une baisse de débit carburant et d'une ouverture lente de la vanne SAV. C'est pourquoi d'autres améliorations ont été proposées pour :

- atteindre les exigences de performance pour les intensités fortes d'une baisse de pression APU et d'une hausse de débit carburant,
- améliorer les performances dans le cas des intensités faibles et moyennes.

Les améliorations proposées sont présentées dans la section suivante et leurs impacts sur les performances du détecteur sont analysés.

III.2.2.3.2 Apprentissage des modèles de normalisation

L'idée est d'agir sur le score d'anormalité afin d'obtenir une meilleure discrimination entre les états sain et dégradé. Le score d'anormalité correspond au calcul de la somme quadratique (norme de Mahalanobis) des huit z-scores. Chaque z-score est obtenu en calculant la différence entre un modèle de la mesure dépendant des conditions opératoires et la mesure réalisée. Le z-score correspond à une estimation de bruit de mesure sous l'hypothèse de fonctionnement normal.

Le modèle de chaque mesure est une fonction de régression déterminée par apprentissage à partir d'une base de 800 démarrages sans dégradation (cf. section I.6.3). La construction des modèles d'apprentissage peut donc représenter un des facteurs potentiellement influant sur les performances de l'approche moyenne mobile. En effet, la base de données des 800 démarrages est constituée de 80 démarrages de chacun des 10 moteurs considérés. Le mélange des 10 moteurs conduit à apprendre un modèle moyen qui gomme un éventuel effet moteur. Ce mode d'apprentissage peut expliquer les performances obtenues. Il a donc été proposé de construire un modèle particularisé par moteur.

Pour tester l'hypothèse d'un effet moteur, une analyse de la variance (ANalyse Of Variance – ANOVA) a permis d'étudier les variations par moteur du score d'anormalité calculé sur les 2470 démarrages sains.

La première étape de l'ANOVA consiste à tester l'égalité des variances du score d'anormalité pour les différents moteurs.

La Figure 53 est une représentation graphique des écarts-types du score d'anormalité pour chaque moteur ainsi que les intervalles de confiance, à 95%, correspondants [Hmad, 2010a].



Figure 53 : Représentation graphique du test d'égalité des variances sur le score d'anormalité par moteur.

Les tests de Bartlett et de Levene permettent de déterminer si les populations ont la même variance. Dans chacun des tests, l'hypothèse nulle (H0) est que les variances des populations considérées sont égales et l'hypothèse alternative (H1) qu'au moins une des variances diffère des autres. Le choix du test dépend des propriétés de la loi de distribution :

- le test de Bartlett est utilisé lorsque les données suivent une loi normale,
- le test de Levene est utilisé lorsque les données sont issues de lois de distribution continues, mais pas nécessairement normales.

La p-valeur pour chacun des tests est inférieure au niveau de significativité ($\alpha = 5\%$), ce qui montre qu'il existe une inégalité entre les variances et que donc un modèle global, sur les 10 moteurs, n'est pas approprié.

Après une analyse plus approfondie, il s'est avéré que l'avion 1 (moteurs 1 et 2) est un Boeing 737-700 équipé d'un CFM56-7B-24 alors que les avions 2, 3, 4 et 5 (les autres moteurs) sont des Boeing 737-800 équipés de CFM56-7B-26 (noté *X26* dans la suite). La poussée de ces derniers est plus importante que pour l'avion 1 comme le montre le Tableau 17.

Type de CFM56-7B	Poussée (kN)
CFM56-7B19	86,7
CFM56-7B20	91,6
CFM56-7B22	101
CFM56-7B24	108
CFM56-7B26	117
CFM56-7B27	121

Tableau 17 : Poussées respectives par type de CFM56-7B

L'étude des performances de l'approche moyenne mobile pour un apprentissage spécifique à un même type de moteur, ou à un même moteur font l'objet respectivement des sections III.2.2.3.2.1 et III.2.2.3.2.2.

III.2.2.3.2.1 Modèle de normalisation particularisé par type de moteur

L'objectif de ce paragraphe est de quantifier l'impact d'une particularisation de l'apprentissage des modèles de chaque mesure sur un même type de moteur [Hmad, 2010b]. La base de données d'apprentissage a été limitée à 50% des démarrages des avions 2, 3, 4 et 5 issus du même type de moteur, soit CFM56-7B-26. Les 50% restant constituent la base de test. Les moteurs de l'avion 1 n'ont pas été considérés.

Le score d'anormalité obtenu, et qui a été utilisé pour la détermination des seuils de détection est représenté sur la Figure 54.



Figure 54 : Distribution du score d'anormalité sans dégradation moyenné sur cinq démarrages successifs après apprentissage des modèles de normalisation sur le type de moteur *X26*.

Comme précédemment, le score d'anormalité a été ajusté par fenêtre de Parzen afin de déterminer les seuils de détection correspondant à chaque dégradation considérée. La même procédure d'estimation des performances a été utilisée. Les dégradations ont été injectées par simulation sur les mesures sans dégradation pour des intensités de dégradation faible, moyenne et forte. Le Tableau 18 répertorie les résultats.

Dégradation	P (Sain Détection) (%)	<i>PoD</i> (%)	Seuil de détection
APU : pression nominale -11,7%	#	0	
APU : pression nominale -23,4%	35,5	1,8	6,35
APU : pression nominale -35%	2	49	
HMU : Débit carburant +7%	3,1	31,2	
HMU : Débit carburant +10%	2,7	37,1	6,57
HMU : Débit carburant +13%	1,4	73,1	
HMU : Débit carburant -7%	2,7	36	
HMU : Débit carburant -10%	1,9	52,5	6,51
HMU : Débit carburant -13%	1,1	93,4	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,9	52,5	6,58
SAV : Ouverture de la vanne +8s	1	100	

Tableau 18 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} à partir des scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur un même type de moteur (X26), $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Le Tableau 18 montre les résultats suivants.

- pour une baisse de pression APU, bien que l'étendue du score d'anormalité sans dégradation soit inférieure au cas où les modèles sont appris sur l'ensemble de tous les moteurs, la valeur du seuil de détection déterminée est supérieure au cas précédent (6,35 contre 5,99). Cela a un impact direct sur les performances du détecteur. Les performances diminuent par rapport au cas où les modèles sont appris sur l'ensemble des moteurs, tous types confondus. L'intensité faible n'est pas détectée et il est, par conséquent, impossible de calculer *P*(Sain|Détection) correspondante. C'est pour cette raison que le symbole «#» est renseigné dans la case correspondante.
- **pour une hausse de débit carburant**, les performances sont améliorées. Cela est visible sur la dégradation d'intensité faible pour laquelle \widehat{PoD} passe de 16,6% à 31,23% après un apprentissage particularisé par type de moteur. Cela a un impact direct sur $\widehat{P}(Sain|Détection)$ sans pour autant atteindre les exigences.
- **pour une baisse de débit carburant**, il apparait une amélioration pour la détection de l'intensité faible. En revanche, une légère régression des performances est observée pour les intensités moyenne et forte. Avec l'apprentissage global, l'intensité forte était détectée à 100% contre 93,37% avec un apprentissage particularisé par type de moteur.
- **pour une ouverture lente de la vanne SAV**, l'apprentissage des modèles de normalisation sur un même type de moteur ne change quasiment rien aux performances obtenues. L'intensité faible n'est pas détectée contre une détection de 0,3% avant apprentissage particularisé par type de moteur. La discrimination entre l'état sain et la dégradation forte est identique au cas d'un apprentissage tout type de moteur.

A titre illustratif, la Figure 55 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages, avec un apprentissage des modèles sur un même type de moteur (*X26*), successivement sans dégradation et avec les trois degrés d'intensité pour une ouverture lente de la vanne SAV. L'ANNEXE - 6 présente des figures analogues pour l'APU et le HMU.



Figure 55 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une ouverture lente de la vanne SAV, modèles appris sur le type de moteur *X26*.

En résumé, les dégradations de fortes intensités présentent des proportions de bonne détection satisfaisantes hormis pour la baisse de pression APU. Le seuil de détection étant déterminé sous hypothèse que PoD = 1, les probabilités d'alarmes fausses s'approchent d'autant plus de 1% que PoD augmente.

Comparées aux performances avec un modèle tous types de moteur, les performances de détection sont légèrement moins bonnes sans être significativement différentes. Cela s'explique par la différence de contexte entre les moteurs de l'avion 1 et les autres moteurs. En effet, les bonnes détections du modèle global tous types de moteur correspondent en majorité aux démarrages des moteurs de l'avion

1 car leurs scores présentent une moyenne plus importante que celle des scores obtenus pour le moteur de type X26. Les scores des moteurs de l'avion 1 n'étant pas compris dans le présent modèle, le taux de bonne détection a tendance à décroître.

Bien que les moteurs des avions 2, 3, 4 et 5 soient du même type, les contextes d'exploitation ne sont pas forcément identiques. C'est pourquoi l'apprentissage d'un modèle par moteur a été étudié.

III.2.2.3.2.2 Modèle de normalisation particularisé par moteur

L'impact d'un apprentissage par moteur sur les performances de l'approche moyenne mobile a été étudié. La base de données de chaque moteur a été divisée en deux parties égales, une pour l'apprentissage et une pour les tests.

Les proportions d'alarmes fausses et de bonne détection ont été estimées pour chaque moteur pour chaque type de défaillance (APU, HMU augmentation, HMU diminution, SAV) et pour chaque intensité de dégradation de chacune de ces défaillances. Les résultats détaillés des 10 moteurs sont présentés en ANNEXE - 7.

Comme en règle générale, pour une intensité de dégradation donnée, les performances (proportions d'alarmes fausses et de bonne détection) sur les différents types de défaillances sont homogènes, une moyenne de ces valeurs a été effectuée. Par la suite, on parlera de « moyenne des proportions d'alarmes fausses et de bonne détection par intensité de dégradation ». La Figure 56 donne ces valeurs.

La totalité des proportions d'alarmes fausses pour des dégradations d'intensités fortes atteignent l'exigence de 1%. Il en est de même pour les dégradations d'intensité moyenne sauf pour le moteur 2 dont la valeur est supérieure à 2% (cf. ANNEXE - 7). Cette valeur est due à la dégradation d'intensité moyenne d'ouverture lente de la vanne SAV qui n'a été détectée qu'à hauteur de 12,5% contre 100% pour les autres dégradations de même intensité (cf. Tableau 22, en annexe). Les proportions d'alarmes fausses pour les dégradations d'intensité faible sont toutes, en moyenne, inférieures à 20%. La détection de dégradation d'intensité faible est encourageante et permet de disposer d'un délai avant défaillance plus important que pour les intensités moyenne et forte.

Pour les proportions de bonne détection, la totalité des dégradations de forte intensité présentent des valeurs en moyenne supérieures à 95%. Les valeurs des proportions d'alarmes fausses sont proches des 1%, correspondant à ce qui est recherché. Les dégradations d'intensité moyenne (respectivement faible) présentent des proportions de bonne détection en moyenne supérieures à 75% (respectivement 25%).



Figure 56 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne détection par intensité de dégradation pour chacun des différents modèles particularisés par moteur.

III.2.2.3.2.3 Bilan des améliorations

Les performances de l'approche moyenne mobile ont été estimées en réalisant l'apprentissage sur la base des données selon trois modalités différentes :

- les 10 moteurs ensemble
- les moteurs correspondant à un seul même type (type *X26*)
- chaque moteur individuellement.

Les performances en termes de proportions d'alarmes fausses sont résumées sur la Figure 57.

Cette figure met en évidence que le passage d'un modèle global à un modèle particularisé par moteur réduit les proportions d'alarmes fausses de façon drastique. Ces dernières atteignent ainsi l'exigence de 1% fixée au départ. Cela est vrai pour les dégradations d'intensité moyenne et forte. Certaines valeurs de proportions d'alarmes fausses sont plus importantes que d'autres pour les dégradations d'intensité faible mais restent inférieures à l'exigence de 50% fixée au départ sur les dégradations de faible intensité.

La visualisation des proportions de bonne détection (Figure 57) selon les mêmes modalités que la figure précédente montre clairement que les proportions de bonne détection sont en moyenne meilleures lorsque l'apprentissage des modèles de normalisation est particularisé par moteur comparée aux deux autres modalités d'apprentissage.

Au vu de ces résultats, l'apprentissage particularisé par moteur a été choisi puisque les exigences de 1% de proportion d'alarmes fausses et d'environ 100% de bonnes détections sont atteintes pour les dégradations d'intensité forte. Cela a été possible en considérant le score d'anormalité calculé après un apprentissage des modèles de normalisation particularisé à chaque moteur et sans modifier l'approche de détection.





III.2.3 APPROCHE K PARMI N

Pour l'approche k parmi n, la détection consiste à analyser une séquence de n = 5 démarrages et de décider en faveur d'une anomalie si k démarrages ont un score d'anormalité supérieur à un seuil.

Le principe de l'approche est décrit dans la section III.2.3.1. La section III.2.3.2 présente les résultats de cette approche pour le paramétrage existant. Une analyse des améliorations considérées et de leurs effets sur les performances est présentée en section III.2.3.3.

III.2.3.1 Principe

Disposant d'une séquence d'observations du score d'anormalité, le franchissement d'un seuil de détection par une observation isolée peut être représentatif d'un fonctionnement anormal mais peut aussi résulter de la dispersion naturelle des observations (Figure 58).



Figure 58 : Exemple de franchissement de seuil par une observation.

Le principe de l'approche k parmi n consiste à observer, sur une fenêtre glissante de n démarrages consécutifs, la proportion d'observations dont le score d'anormalité dépasse un seuil de détection. Si cette proportion est supérieure à un taux Tx, appelé taux de confirmation, la persistance du franchissement de seuil est attestée et une décision de prémices d'anomalie est prise. Cette approche de détection repose sur trois paramètres :

- la taille *n* de la fenêtre des observations considérées,
- le nombre k de dépassements ou, de façon équivalente, le taux de confirmation Tx = k/n,
- le seuil de détection.

Pour des raisons opérationnelles, la taille de la fenêtre des démarrages est n = 5 et k a été fixé à 4, soit un taux de confirmation de 80%.

A titre illustratif, la Figure 59 présente un exemple d'application de la détection 4 parmi 5 au score d'anormalité. La détection intervient dans ce cas à l'indice de démarrage 9. Comme pour la méthode à moyenne mobile, cette approche présente un retard à la détection.



Figure 59 : Exemple de confirmation pour une détection de 4 franchissements parmi 5 démarrages.

III.2.3.2 Performance pour le paramétrage existant

Pour k et n fixés, les performances de cette approche dépendent du seuil de détection à appliquer au score d'anormalité. Ce paragraphe présente les performances de cette approche pour k = 4 et n = 5 après application des seuils issus du Tableau 13 de la section III.2.2.2.

Suite aux résultats obtenus pour l'approche moyenne mobile, les performances ont été estimées par moteur. L'ensemble des résultats obtenus pour les dix moteurs est présenté sur la Figure 60.

Ces résultats montrent que les proportions de bonne détection sont satisfaisantes mais complètement discrédités par les proportions d'alarmes fausses correspondantes. Comme pour l'approche moyenne mobile, ces résultats s'expliquent par la valeur des seuils de détection. Une première amélioration consiste donc à régler ces seuils en fonction des exigences de performance et de la règle de détection considérée. Par la suite d'autres améliorations ont été testées pour répondre aux exigences. Le paragraphe suivant s'intéresse à cette problématique.



Figure 60 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne détection par intensité de dégradation pour chaque moteur avec une règle de détection à k = 4 parmi n = 5 et un paramétrage des seuils de base.

III.2.3.3 Analyse et amélioration des performances

Les performances de l'approche k parmi n dépendent directement du réglage du seuil de détection. Il est donc possible d'améliorer les performances en agissant sur le réglage du seuil. La méthode de réglage ainsi que les performances obtenues sont présentées dans le paragraphe suivant. D'autres améliorations ayant un impact sur le seuil de détection sont présentées par la suite. Elles consistent à modifier la taille de la fenêtre des démarrages d'une part et le taux de confirmation d'autre part.

III.2.3.3.1 Réglage du seuil de détection

Pour déterminer le seuil de franchissement, nous avons considéré que le franchissement de seuil obéit à une loi de Bernoulli de paramètre *p* correspondant à la probabilité de franchissement du seuil. Avec l'hypothèse d'indépendance des franchissements, la loi de la variable décisionnelle est une loi Binomiale(*n*,*p*) [Nahed, 2011] [Nahed, 2012]. Etant donné la probabilité $\alpha_{exigée}$ déterminée dans les mêmes conditions que précédemment, l'objectif est de déterminer *p* puis la valeur du seuil de détection correspondant au quantile de probabilité *1-p* sur la distribution du score d'anormalité sous l'hypothèse *H0* (absence d'anomalie). Il convient donc de déterminer la distribution de cette règle de détection avant de régler le seuil.

$$P(Binomiale(n,p) \ge k) \le \alpha_{exig\,\acute{e}e}$$
(33)

Toutefois, comme d'après [Nikuline, 2006]

$$P(Binomiale(n,p) \ge k) = Beta_{(k,n-k+1)}(p)$$
(34)

La valeur p peut être déterminée grâce à l'équation suivante :

$$Beta_{(k,n-k+1)}(p) = (\alpha_{exig\,\acute{e}e})$$
(35)

Après avoir déterminé la valeur de p, il suffit de déterminer la valeur du seuil correspondant au quantile d'ordre 1-p sur l'estimation par fenêtre de Parzen de la distribution du score d'anormalité sans dégradation (Figure 61).



Figure 61 : Seuil de détection.

Les performances sont ensuite obtenues en appliquant les seuils de détection déterminés pour chaque type de défaillance (APU, HMU augmentation, HMU diminution et SAV) aux scores d'anormalité avec et sans dégradation.

Dans un souci de concision, comme au paragraphe III.2.2.3.2.2, les proportions d'alarmes fausses et de bonne détection estimées pour les dix moteurs ont été moyennés sur les différents types de défaillance et sont représentées sur la Figure 62.

Pour les dégradations de forte intensité, les proportions d'alarmes fausses sont en moyenne inférieures à 3% sauf pour le moteur 3 avec la valeur de 6,5%. Cela est associé à une proportion de bonne détection plus faible que pour les autres moteurs.

Le moteur 3 représente un cas particulier car il apparait qu'aucune dégradation d'intensité faible n'est détectée. Il est donc impossible d'estimer une proportion d'alarmes fausses. Ainsi la proportion d'alarmes fausses correspondante n'apparait pas sur la Figure 62. Pour comprendre ces résultats, il faut observer les valeurs des seuils de détection (cf. ANNEXE - 8). Ces valeurs sont grandes et par conséquent la probabilité qu'au moins 4 observations du score d'anormalité parmi 5 franchissent le seuil est faible. Les distributions des scores d'anormalité pour des dégradations d'intensité faible étant très proches de la distribution sans dégradation, il est donc logique que les proportions de bonne détection soient médiocres pour ces intensités.



Figure 62 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne détection par intensité de dégradation pour chaque moteur avec une règle de détection à k = 4 parmi n = 5.

Les exigences de performance n'ont pas été atteintes pour ce paramétrage (k = 4 parmi n = 5).

Puisque l'approche dépend de deux autres paramètres, les améliorations suivantes ont été considérées :

- la modification de *n*, la taille de la fenêtre des démarrages,
- la modification de *k*.

Ces deux améliorations sont analysées dans les paragraphes suivants.

III.2.3.3.2 Modification de la taille de la fenêtre des démarrages

La taille n de la fenêtre des démarrages fixée à 5 démarrages représente un jour d'exploitation. L'apport en termes de proportions d'alarmes fausses et de bonne détection lorsque cette valeur est modifiée, fait l'objet de ce paragraphe.

La taille de la fenêtre des démarrages modifiée a été fixée à deux jours d'exploitation soit n = 10 démarrages, ce qui reste un délai acceptable. Le taux de confirmation reste fixé à 80%. La règle de détection devient 8 parmi 10.

La même méthode de réglage de seuil a été appliquée pour ce paramétrage. Les proportions d'alarmes fausses et de bonne détection ont été moyennées par type de défaillance et sont présentées Figure 63.



Figure 63 : (a) moyenne des proportions d'alarmes fausses et (b) moyenne des proportions de bonne détection par intensité de dégradation pour chaque moteur avec une règle de détection à k = 8 parmi n = 10.

L'augmentation de la taille de la fenêtre améliore très nettement les performances quels que soient le moteur et l'intensité des dégradations. Les exigences d'alarmes fausses et de bonne détection sont atteintes pour la totalité des moteurs lorsqu'il s'agit de dégradations d'intensité forte. Quel que soit le moteur, les proportions de bonne détection sont supérieures à 80% pour les dégradations d'intensité moyenne. Les proportions d'alarmes fausses résultantes sont inférieures à 2%. Concernant les dégradations d'intensité faible, elles sont toutes détectées contrairement à la règle de détection précédente où les dégradations d'intensité faible pour le moteur 3 ne l'étaient pas.

L'augmentation de la taille de la fenêtre des démarrages conduit à une diminution de la valeur des seuils de détection (Tableau 19) ce qui augmente la probabilité qu'une observation du score d'anormalité franchisse un de ces seuils. Les seuils de détection étant plus faibles, même les dégradations de faible et moyenne intensité sont détectées. Cependant, il est important de noter que même si le quantile d'ordre 1-p diminue, la règle de détection est plus stricte puisqu'elle requiert 8 positifs parmi 10. Cela permet donc de garder les proportions d'alarmes fausses à un niveau respectant les exigences.

Dégradation	Seuil de détection	Seuil de détection
Degradation	<i>k</i> = 4 parmi <i>n</i> = 5	<i>k</i> = 8 parmi <i>n</i> = 10
APU - Baisse de pression	8,22	5,07
HMU - Baisse de débit	12,86	5,39
HMU - Hausse de débit	12,75	5,51
SAV - Ouverture lente	12,18	5,52

Tableau 19 : Comparaison des seuils pour une règle de détection à k = 4 parmi n = 5 avec une règle de détection k = 8 parmi n = 10, pour le moteur 1.

Il est néanmoins important de noter que l'augmentation de la taille de la fenêtre des démarrages implique un retard accru à la détection.

III.2.3.3.3 Modification du taux de confirmation

Ce paragraphe porte sur l'impact d'une modification de k sur les proportions d'alarmes fausses et de bonne détection. L'effet de la modification a été testé pour les deux tailles de fenêtre des démarrages précédentes, n = 5 et n = 10. Pour une taille de fenêtre fixée à n = 5, les trois cas suivants ont été testés : k = 3; 4 et 5. Et pour n = 10, k = 5; 6; 7; 8; 9 et 10.

Dans ce paragraphe, les seuils de détection ont été réglés pour chaque moteur. Pour comparaison, les performances ont été moyennées sur l'ensemble des types de défaillance et des moteurs. Les résultats obtenus sont présentés Figure 64.

La règle de détection qui donne les meilleurs résultats en général, pour les démarrages dont on dispose est la règle 5 parmi 5. En effet, le taux de confirmation à 100% fournit les meilleures performances mis à part dans le cas des dégradations de faible intensité : les proportions de bonne détection augmentent bien que les proportions d'alarmes fausses augmentent également. Or c'est l'effet inverse qui devrait se produire. Il s'avère que, tout comme l'augmentation de la taille de la fenêtre d'observation, l'augmentation du taux de confirmation engendre une diminution de la valeur des seuils de détection ce qui augmente les proportions de détection mais aussi les proportions d'alarmes fausses. Les dégradations sont donc mieux détectées et il arrive même que des dégradations de faible intensité non détectées lorsque k = 3 soient détectées lorsque k = 4 (il en est de même pour le passage de k = 4 à k = 5).



Figure 64 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par intensité de dégradation sur l'ensemble des moteurs lorsque la taille de la fenêtre des démarrages est n = 5.

Pour une fenêtre d'observation fixée à n = 10 démarrages, les résultats obtenus sont présentés Figure 65.

Comme dans le paragraphe précédent, le passage d'une fenêtre de taille n = 5 à une fenêtre de taille n = 10 améliore considérablement les performances du détecteur. En ne considérant que les dégradations de faibles et fortes intensités, l'évolution des performances estimées en fonction du taux de confirmation n'est pas monotone. Les meilleures performances sont obtenues pour k = 8 ou k = 9. Afin de sélectionner une valeur, le critère définit par le rapport entre la proportion d'alarmes fausses et la proportion de bonne détection a été utilisé. Les valeurs obtenues sont données dans le Tableau 20. Ces rapports révèlent que la règle de détection avec k = 8 fournit légèrement de meilleures performances que celle avec k = 9.

Il a été observé que l'augmentation du taux de confirmation diminue la valeur du seuil de détection. Dans ce sens, la règle de détection k = 10 parmi n = 10 devrait donner les meilleures performances. Or cela n'est pas le cas. Il semblerait que cette règle soit trop stricte et que malgré un seuil faible, il n'est pas fréquent que 10 observations du score d'anormalité soient supérieures au seuil de détection sur une même fenêtre.



Figure 65 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par intensité de dégradation sur l'ensemble des moteurs lorsque la taille de la fenêtre des démarrages est n = 10.

	Rapport (<i>P(Sain/Détection)/PoD</i>) moyennés par intensité sur l'ensemble des moteurs		
Taux de confirmation	Dégradation faible	Dégradation moyenne	Dégradation forte
k=5 parmi n=10	0,215	0,0652	0,01182
k=6 parmi n=10	0,226	0,0192	0,01033
k=7 parmi n=10	0,129	0,0136	0,00994
k=8 parmi n=10	0,068	0,0126	0,00990
k=9 parmi n=10	0,083	0,0127	0,00990
k=10 parmi n=10	0,117	0,0163	0,01025

Tableau 20 : Rapport (P(Sain|Détection)/PoD) moyenné par intensité sur l'ensemble des moteurs pour différents taux de confirmation lorsque la fenêtre des démarrages est n = 10.

III.2.3.3.4 Bilan des améliorations

L'estimation des performances de l'approche k parmi n a permis de comprendre les variations de cette dernière. Comme pour l'approche moyenne mobile, il s'est avéré que le réglage des seuils de détection représente l'élément central.

De manière générale, une modification de la règle de détection pour une amélioration des performances n'est pas sans compromis. L'augmentation de la taille de la fenêtre des démarrages se fait au détriment de la réactivité du détecteur. Une détection sur 5 démarrages nécessite un jour d'exploitation avant de prendre une décision. Une détection sur 10 démarrages nécessite deux jours d'exploitation. Ces ordres de grandeur paraissent raisonnables mais cela dépend du délai nécessaire pour mettre en place une action de maintenance et de la vitesse de dégradation des composants du système. Le fait de retarder la maintenance, ne serait-ce que d'un jour, peut avoir des conséquences non négligeables quand les composants ne sont pas disponibles en stock. Par exemple, le changement d'un groupe de lubrification nécessite huit heures de main d'œuvre lorsqu'il est disponible en stock. Son absence des stocks peut entrainer des retards conséquents.

III.2.4 COMPARAISON DES DEUX APPROCHES

Les performances des deux approches ont été comparées. Ces comparaisons ont été réalisées entre l'approche moyenne mobile pour n = 5 et n = 10 et les règles de détection les plus performantes de l'approche k parmi n (5 parmi 5 et 8 parmi 10). La Figure 66 et la Figure 67 donnent respectivement les résultats pour n = 5 et n = 10.

Pour n = 5 comme pour n = 10, l'approche k parmi n est moins performante que l'approche moyenne mobile. Cela s'explique par le fait que moyenner permet de réduire l'effet des observations extrêmes du score d'anormalité lors du réglage des seuils de détection.







Figure 67 : (a) proportion d'alarmes fausses et (b) de bonne détection moyennées par moteur, approche moyenne mobile : n = 10, approche k = 8 parmi n = 10.

III.2.5 CONCLUSION

La procédure de maturation a commencé par une analyse des performances. Deux approches de détection ont été analysées et leurs performances ont été comparées. Il a été montré expérimentalement que l'approche moyenne mobile est plus performante que l'approche k parmi n.

La maturation du détecteur de l'algorithme de surveillance de la séquence de démarrage a aussi permis d'établir une méthode de réglage des seuils. Cette dernière est maintenant implémentée et utilisée de manière automatique dans cet algorithme.

III.3 PRONOSTIC DE CONSOMMATIONS ANORMALES

III.3.1 INTRODUCTION

Ce chapitre présente la maturation de la fonction de pronostic dans le cadre de son application à la surveillance de la consommation d'huile. Le principe de la fonction de pronostic est présenté section III.3.2. Les données disponibles sont présentées section III.3.3, pour être utilisées lors de l'estimation des performances section III.3.4. Des améliorations sont proposées et leur impact sur les performances est présenté section III.3.5.

III.3.2 PRINCIPE

L'objectif de la fonction de pronostic est d'estimer la probabilité de franchir un seuil S au bout d'un horizon temporel H compte tenu d'un historique de taille T. L'estimation de la probabilité de franchissement du seuil à un instant t est réalisée en comparant la pente du score d'anormalité à la pente nécessaire pour franchir le seuil à t + H.

La pente d'évolution du score d'anormalité est estimée à l'aide d'une régression linéaire sur une fenêtre d'apprentissage de taille *T*. Ensuite, la pente critique pour franchir le seuil à t + H est déterminée à partir du point à l'instant *t*, d'ordonnée la valeur de la régression à cet instant, et du point à l'instant t + H, d'ordonnée le seuil *S*. La Figure 68 illustre cette description.

Les concepteurs de cette fonction de pronostic ont choisi de comparer ces deux pentes à l'aide d'un test de Student. Le résultat du test de Student permet d'estimer la probabilité que la pente du score d'anormalité soit inférieure ou supérieure à la pente critique. Cela équivaut à la probabilité que le score d'anormalité franchisse le seuil de défaillance au bout de l'horizon temporel H.



Figure 68 : Principe de fonctionnement de la fonction de pronostic.

L'entrée de la fonction est composée d'observations du score d'anormalité et sa sortie est la probabilité de franchissement du seuil au bout de l'horizon H. Les paramètres de la fonction de pronostic sont :

- la taille de l'historique des observations : *T*,
- la taille de l'horizon de pronostic : *H*,
- un seuil : *S*.

Dans le cadre du pronostic de consommations anormales, le score d'anormalité correspond aux consommations d'huile estimées par le système de surveillance de la consommation d'huile au fil des vols. Comme le pronostic n'est déclenché qu'après avoir franchi le seuil de détection, la taille de l'historique des observations, *T*, est de 1 mois d'exploitation au maximum, soit 100 vols (compte tenu du nombre de jours d'exploitation sur un mois calendaire). Lorsqu'une détection a lieu avant, la taille de l'historique des observations est alors égale au nombre de vols disponibles jusqu'à détection.

L'horizon, H, de pronostic est fixé à 20 vols soit 4 jours d'exploitation. Le seuil, S, seuil de défaillance, est fixé à 0,38 l/h ce qui correspond au seuil de consommation anormale du manuel de maintenance.

III.3.3 DONNEES

Les procédures d'estimation des indicateurs de performance du pronostic (cf. § II.4.4.2) ont été appliquées aux consommations d'huile estimées sur les moteurs des 5 avions considérés. Il s'agit de consommations nominales distribuées autour d'une valeur moyenne de consommation entre 0,18 l/h et 0,2 l/h en fonction des moteurs. Il n'y a donc pas présence de dégradations.

Les tailles des enregistrements variant pour chacun des moteurs, il arrive, dans la majorité des cas, que la procédure d'estimation des indicateurs de performance du pronostic ne soit pas applicable par manque de données. Pour pallier cela, il a été décidé de répéter l'enregistrement des consommations estimées pour chaque moteur au bout de l'enregistrement initial. Cela permet de disposer d'enregistrements plus longs et ainsi d'estimer les performances de la fonction de pronostic.

Dans la suite de ce chapitre, seuls les données et résultats des moteurs 1 des avions 4 et 5 sont présentés car les améliorations présentées par la suite n'ont été appliquées qu'à ces deux moteurs. Les données et résultats pour les autres moteurs sont placés en ANNEXE - 9. La Figure 69 (respectivement la Figure 70) représente les consommations estimées mises bout à bout pour le moteur 1 de l'avion 4 (respectivement, de l'avion 5). La taille initiale des enregistrements représente donc la moitié de la taille observée.



Figure 69 : Consommations estimées pour le moteur 1 de l'avion 4.



Figure 70 : Consommations estimées pour le moteur 1 de l'avion 5.
III.3.4 ESTIMATION DES PERFORMANCES

La méthodologie d'évaluation de la fonction de pronostic établie en section II.4.4 a été appliquée à l'algorithme de surveillance de la consommation d'huile (Engine Oil Consumption - EOC) à titre d'étude de cas. La procédure d'estimation des performances de pronostic a été appliquée à chaque moteur indépendamment des autres. Les résultats sont présentés sur la Figure 71 et la Figure 72.

Chaque figure est composée de trois sous-parties :

- la première représente les trajectoires « pseudo observées » du moteur considéré, le seuil de défaillance (ligne continue), le seuil de détection d'anormalité (ligne discontinue) à partir duquel le pronostic est déclenché, un seuil indiquant le fait que 10% des trajectoires « théoriques » ont franchit le seuil de défaillance (ligne verticale discontinue) et un seuil indiquant le fait que 90% des trajectoires « théoriques » ont franchi le seuil de défaillance (ligne verticale discontinue) et un seuil indiquant le fait que 90% des trajectoires « théoriques » ont franchi le seuil de défaillance (ligne verticale en pointillé).
- la seconde représente la proportion de franchissements non justifiés, $P(Non \ Franchissement | Alarme)$, au cours des vols ainsi que les seuils à 10% et 90%. La procédure d'estimation est décrite à la section II.4.4.2.1.
- la troisième représente la proportion de franchissements justifiés, *P*(*Alarme*/*Franchissement*), au cours des vols ainsi que les seuils à 10% et 90%. La procédure d'estimation est décrite à la section II.4.4.2.2.

Quel que soit le moteur, les proportions de franchissements non justifiés ne sont pas nulles. Elles vont de 6% au maximum pour le moteur 1 de l'avion 5 (Figure 72), ce qui est acceptable, à 85 % au maximum pour le moteur 2 de l'avion 4 (cf. Figure 100 en ANNEXE - 9), ce qui n'est pas acceptable.

Pour la majorité des moteurs, les proportions de franchissements non justifiés ne sont pas acceptables. Ces valeurs s'expliquent par la nature bruitée des consommations estimées. En fonction de la zone d'apprentissage de la pente des trajectoires pseudo observées, cette dernière peut être plus ou moins prononcée ce qui a un impact direct sur la probabilité de franchissement. Il arrive donc que la pente d'une trajectoire soit importante et induise une probabilité de franchissement supérieure à 80%. Cependant, comme la consommation estimée chute brutalement, la trajectoire en question ne franchit pas le seuil de défaillance et donne donc lieu à un franchissement non justifié.

Ces performances non acceptables en termes de P(Non franchissement/Alarme) méritent toutefois d'être nuancées. Il est moins préjudiciable d'observer une alarme non justifiée lorsque la probabilité théorique de franchissement de seuil de défaillance est voisine de 90 % que lorsque la probabilité théorique de franchissement de seuil de défaillance est voisine de 10%. Pour ce faire, il convient de repérer sur l'axe des abscisses le vol à partir duquel 10% (respectivement 90%) des trajectoires théoriques sont supérieures au seuil de défaillance. Si le pic de la courbe P(Non franchissement/Alarme) est voisin du vol à 90 % cela est moins préjudiciable que si le pic est voisin du vol à 10 %. Ce dernier cas apparaît pour la majorité des moteurs.

Concernant les proportions de franchissements justifiés, elles augmentent au fil des vols pour atteindre 100% une fois toutes les trajectoires supérieures au seuil de pronostic. La nature bruitée des consommations estimées a là aussi un impact non négligeable. En effet, il arrive dans certains cas que la proportion de franchissements justifiés diminue avant de se remettre à croitre. C'est le cas pour le moteur 2 de l'avion 1 (cf. Figure 95 en ANNEXE - 9). Cela s'explique par le fait que certaines trajectoires passent en dessous du seuil de défaillance pendant un court délai avant de le franchir à nouveau. Cela est bien illustré par la proportion de franchissements justifiés estimée pour le moteur 2 de l'avion 3 (cf. Figure 99 en ANNEXE - 9).

Ces performances, en termes de proportions de franchissements justifiés, P(Alarme| Franchissement), méritent toutefois d'être affinées. Il est moins préjudiciable que P(Alarme| Franchissement) soit faible lorsque la probabilité théorique de franchissement de seuil de défaillance est voisine de 10 % que lorsque la probabilité théorique de franchissement de seuil de défaillance est voisine de 90%. Pour ce faire, il convient de repérer sur l'axe des abscisses le vol à partir duquel 10% (respectivement 90%) des trajectoires théoriques sont supérieures au seuil de défaillance. Si une grande valeur de la courbe

P(Alarme | Franchissement) apparaît entre les vols à 10% et 90 % cela est moins préjudiciable que si cette valeur n'apparait qu'après le vol à 90 %. Ces deux cas sont rencontrés pour les données disponibles.





Figure 71 : Moteur 1 avion 4, trajectoires pseudo observées et performance de pronostic

Moteur 1 avion 5 : Trajectoires pseudo observées



Figure 72 : Moteur 1 avion 5, trajectoires pseudo observées et performance de pronostic

La précision des consommations estimées a un impact direct sur les performances de la fonction de pronostic. Il est donc nécessaire d'améliorer la précision des consommations estimées afin de réévaluer les performances. Cela est discuté dans la section suivante.

III.3.5 ANALYSE ET AMELIORATION DES PERFORMANCES

Plusieurs propositions ont été faites pour améliorer les performances de la fonction de pronostic :

- en premier lieu, comme indiqué ci-dessus, la stabilisation de la précision de l'estimation des consommations. Il apparait clairement que la fluctuation des courbes d'estimation provoque soit des prévisions de franchissement non justifiées, soit au contraire des non-prévisions de franchissements justifiés,
- si cela n'est pas suffisant, la limite de probabilité, arbitrairement fixée à 80 %, qui donne lieu à une alarme et à une dépose peut être modifiée. L'augmentation de cette limite de probabilité est de nature à diminuer le nombre de prévisions de franchissement non justifiées, mais également, en contre partie, celui des prévisions de franchissements justifiés,
- l'optimisation de la taille de la fenêtre d'apprentissage, *T*, ou de l'horizon de pronostic, *H*.

Cependant, l'impact de ces améliorations ne peut être évalué tant que la précision des consommations estimées n'est pas améliorée.

Dans cette perspective, des corrections des consommations du moteur 1 des avions 4 et 5 ont été réalisées. Ces améliorations consistent à agir sur l'extraction des niveaux d'huile pour améliorer l'estimation finale des consommations. La Figure 73, respectivement la Figure 74, montrent les consommations estimées pour le moteur 1 de l'avion 4, respectivement le moteur 1 de l'avion 5, après amélioration de l'extraction. Des imprécisions subsistent toutefois. Elles s'expliquent par l'omission d'un ou plusieurs remplissages lorsque certains vols sont manquants. Les estimations considérées pour l'étude tiennent compte du ou des remplissages manquants. Comme précédemment, les consommations estimées sur un même moteur ont été mises bout à bout afin de pallier la taille des enregistrements.



Figure 73: Moteur 1 avion 4, consommations estimées avant et après comptabilisation des remplissages manquants.



Figure 74: Moteur 1 avion 5, consommations estimées avant et après comptabilisation des remplissages manquants.

Ces estimations de consommation ont été utilisées pour estimer à nouveau les performances de la fonction de pronostic. La procédure d'estimation reste inchangée. Les résultats sont présentés de manière analogue sur la Figure 75 et la Figure 76.

Pour le moteur 1 de l'avion 4 (Figure 75), les résultats après modifications apparaissent moins bons qu'avant. Cela s'explique encore par les consommations estimées. Il semblerait que d'autres remplissages que ceux déjà identifiés aient été omis. Ceci explique les hausses de consommation suivies par des baisses qui sont probablement dues à une détection a postériori du ou des remplissages manquants.

Les conclusions sont identiques dans le cas du moteur 1 de l'avion 5 (Figure 76) avec des proportions de franchissements non justifiés de l'ordre de 98% juste avant franchissement du seuil de défaillance. Cela s'explique par le fait que les trajectoires diminuent juste avant de franchir le seuil. Il en résulte que la majorité des probabilités de franchissement estimées sur la fenêtre d'apprentissage précédant ce phénomène sont supérieures à 80% ce qui a induit une proportion élevée de franchissements non justifiés.



Moteur 1 avion 4 : Trajectoires pseudo observées

Figure 75 : Moteur 1 avion 4, trajectoires pseudo observées et performance de pronostic



Figure 76 : Moteur 1 avion 5, trajectoires pseudo observées et performance de pronostic

III.3.6 CONCLUSION

La proportion de franchissement non justifié P(Non franchissement/Alarme) et la proportion de franchissement justifié P(Alarme/Franchissement) ont été estimées pour les moteurs issus des 5 avions considérés. La procédure d'estimation de chacune des proportions a été établie dans le cadre du pronostic de consommations anormales.

Les résultats montrent que les performances dépendent directement de la précision des consommations estimées. Cela permet de tirer principalement deux leçons :

- la précision des consommations estimées a un impact direct et non négligeable sur les performances de la fonction de pronostic,
- la fonction de pronostic est très sensible à la nature du signal qu'elle utilise pour réaliser le pronostic.

Une première amélioration de l'extraction des niveaux d'huile a stabilisé de façon partielle l'estimation des consommations. Cela n'est pas suffisant pour l'utilisation de la fonction de pronostic. Il convient de poursuivre dans ce sens afin de corriger au maximum les remplissages manquants. Une fois cela réalisé, d'autres optimisations pourront être étudiées :

- la limite de probabilité, arbitrairement fixé à 80 %, qui donne lieu à une alarme et à une dépose,
- la taille de la fenêtre d'apprentissage, *T*, ou de l'horizon de pronostic, *H*.

Une autre amélioration possible serait de changer de méthode de pronostic. Cette perspective est en cours d'étude. Une seconde fonction de pronostic utilisant la méthode des filtres à particules a été développée. Après maturation de cette dernière, les performances des deux méthodes de pronostic (régression linéaire et filtres à particules) pourront être comparées.

III.4 CONCLUSION

Ce chapitre a permis de présenter les résultats de maturation de la fonction de détection appliquée au démarrage et de la fonction de pronostic appliquée à la consommation d'huile.

Concernant la détection, deux approches ont été testées. Une méthode de réglage de seuil a été établie quelle que soit l'approche considérée. Elle a permis de déterminer les seuils de détection permettant de respecter les exigences des compagnies aériennes pour les deux approches.

- pour l'approche moyenne mobile, les performances ont été estimées selon trois modalités de la base d'apprentissage. La modalité d'apprentissage particularisé par moteur a été retenue car elle présente les meilleures performances quelle que soit l'intensité de dégradation.
- pour l'approche *k* parmi *n*, les performances ont été estimées pour la modalité d'apprentissage par moteur et différentes configurations de *k* et *n*. La meilleure configuration a été identifiée.
- ces deux approches ont été comparées pour leurs meilleures configurations respectives. Il s'est avéré que l'approche moyenne mobile est la plus performante.

Concernant le pronostic, les performances ont été estimées sur l'ensemble des moteurs considérés. La maturation de la fonction de pronostic a révélé :

- une sensibilité de la fonction de pronostic à la précision des consommations estimées,
- la nécessité de stabiliser la précision des consommations estimées.

Le bilan des travaux réalisés tout au long de cette thèse ainsi que les perspectives sont présentées dans la section suivante.

Bilan & Perspectives

L'objet de la thèse est de caractériser et optimiser les performances des fonctions de détection et de pronostic. Les innovations développées ont donc porté sur ces deux points.

La thèse a permis en premier lieu d'identifier et d'estimer les performances pertinentes de la fonction de détection. Dans le domaine de la maintenance aéronautique l'indicateur de performance utilisé est P(Sain/Détection) plutôt que l'erreur de première espèce $\alpha = P(Détection/Sain)$.

La distribution du score d'anormalité sans dégradation étant inconnue, il a fallu l'estimer à partir des données. Des méthodes non paramétriques d'une part et des méthodes basées sur les propriétés des valeurs extrêmes ont été investiguées. Il a été établi que l'estimation non paramétrique par fenêtre de Parzen présente le meilleur compromis biais-variance concernant l'estimation des seuils de détection.

Des méthodes d'optimisation des seuils de détection sous contrainte de P(Sain/Détection) de l'ordre de 1% ont été établies. Deux approches de confirmation d'anomalies ont été comparées : l'approche moyenne mobile et l'approche k parmi n. Il semble que la première conduise aux meilleures performances en termes de P(Sain/Détection) faible et P(Détection/Dégradation) élevée. Toutefois, la confirmation k parmi n offre l'avantage de réduire l'exigence sur P(Détection/Sain) jusqu'à ne plus être en valeurs extrêmes. Cette optimisation de seuil a été l'objet de brevet [Hmad, 2012c] et est à présent utilisée en exploitation.

La thèse de Tsirizo RABENORO (thèse en cours chez Safran Snecma) considère ces seuils optimisés comme élément de fusion des systèmes de surveillance. La mise en œuvre de ces techniques d'estimation a conduit à utiliser des modèles d'impact des dégradations et de leur intensité sur les indicateurs. Cela constitue une originalité méthodologique qui est développée dans la thèse de Benjamin LAMOUREUX (thèse en cours chez Safran Snecma) sur le système de surveillance des boucles locales d'asservissement.

Plus généralement, ces indicateurs de performance permettent d'appréhender l'impact des modifications des fonctions et de les optimiser. Par exemple, il s'est avéré bénéfique de particulariser par individu moteur les modèles de normalisation avant détection.

La nature « probabiliste » du pronostic a conduit au développement d'un travail original sur la définition des indicateurs de performance ainsi que leur méthode d'estimation. Les indicateurs de performance ont été définis en fonction d'exigences opérationnelles à savoir la pertinence des déposes induites par les prédictions réalisées par la fonction de pronostic. Pour les estimer, nous avons simulé l'évolution des dégradations jusqu'à panne à l'aide de modèles de nature différentes de ceux sousjacents à la fonction de pronostic. Les processus Gamma ont répondu à cette exigence tout en permettant de prendre en compte les avis d'expert sur les caractéristiques d'évolution lente.

De manière générale, cette thèse a permis une réflexion sur les performances intrinsèques des fonctions utilisées pour la surveillance des systèmes de régulation des turboréacteurs. Cette réflexion a poussé l'effort sur la caractérisation des dégradations et de leurs évolutions. Cela a permis de mettre en évidence les données nécessaires à la qualification des algorithmes de surveillance. L'enregistrement de ces données permettra, à terme, de connaitre la vitesse des dégradations (passage d'une intensité faible à une intensité moyenne puis forte jusqu'à rupture) et de la prendre en compte dans les modèles de dégradation. Ces enregistrements permettront également d'affirmer ou d'infirmer les hypothèses retenues tout au long de la thèse et affiner les modèles de dégradation utilisés. Par exemple, dans le cadre du pronostic de consommations anormales, s'il s'avère que l'évolution de la consommation d'huile est un processus Gamma, la fonction de pronostic pourra être remplacée par une autre fonction utilisant les processus Gamma comme méthode de pronostic. Dans le cas contraire, d'autres méthodes devront être utilisées (filtres a particules, filtres de Kalman...).

La procédure d'estimation et d'optimisation des performances est d'ores et déjà appliquée en exploitation. Elle a été étendue à d'autres algorithmes de surveillance et va faire l'objet d'autres

extensions. La méthode de réglage de seuil étant établie dans le cadre de scores d'anormalité à distribution continue, il est prévu une extension aux cas discrets.

L'apprentissage des modèles de normalisation a posé la question de la prise en compte du vieillissement et de la reconfiguration. Il est donc prévu de prendre en compte le vieillissement lors de l'apprentissage des modèles de normalisation et par la suite pour le réglage des seuils de détection. Il est également prévu de s'intéresser à la stratégie d'apprentissage des modèles de normalisation avec un nombre limité de données par apprentissage sur toute la flotte avec une variable de recalage spécifique à chaque moteur.

Références

[Afnor, 2010] Norme AFNOR NF EN 13306. (2010). Terminologie de la maintenance. Editions AFNOR, Paris.

[Aldrich, 1997]. Aldrich J. (1997). R.A. Fisher and the Making of Maximum Likelihood 1912-1922. Statistical Science, Vol. 12, n°3, pp 162-176.

[Alpaydin, 2010] Alpaydin E. (2010). Introduction to Machine Learning. Second Edition. The Massachusetts Institute of Technology Press Cambridge, Massachusetts London, England.

[Anderson, 1952] Anderson T. W. et Darling D. A. (1952). Asymptotic theory of certain "goodness-of-fit" criteria based on stochastic processes. Annals of Mathematical Statistics, 23, pp 193–212.

[Atger, 2000] Atger F. (2000). La prévision du temps à moyenne échéance en France. La Météorologie, 8e série, n°30.

[Ausloos, 2009] Ausloos A., Grall-Maes E, Beauseroy P., Grall A. et Massé J.R. (2009). Estimation of monitoring indicators using regression methods - application to turbofan starting phase. Conférence ESREL09, 7-10 Septembre, Prague, République Tchèque.

[Balkema, 1974] Balkema A. et de Haan L. (1974). Residual life time at great age. Annals of probability, 2, pp 792-804.

[Basque, 2006] Basque R. (2006). Un itinéraire fléché vers le Capability Maturity Model Intégration. Editions DUNOD, Version 1.2.

[Basseville, 1993] Basseville M. et Nikiforov I.V. (1993). Detection of abrupt changes - theory and applications. Prentice Hall, Information and System Sciences Series.

[Benlagha, 2009] Benlagha N., Grun-Réhomme M. et Vasechko O. (2009). Les sinistres graves en assurance automobile : une nouvelle approche par la théorie des valeurs extrêmes. MODULAD.

[Berenji, 2006] Berenji H. et Wang Y. (2006). Case-Based Reasoning for Fault Diagnosis and Prognosis. Proceedings of the IEEE International Conference on Fuzzy Systems, pp 1316-1321.

[Berthault, 2009a] Berthault C., Massé J.R. et Hmad O. (2009). Chantier Lean - Sigma N° 44 – Imprécisions de dosage carburant CFM56-7B et SaM146 compte rendu de la réunion du 07/04/09.

[Berthault, 2009b] Berthault C., Massé J.R. et Hmad O. (2009) Chantier Lean - Sigma N° 44 - Surveillance de la capacité à démarrer CFM56-7B - Utilisation du modèle performance Sam 146 pour simuler des dégradations du démarrage. Compte rendu de réunion du 10/02/09.

[Besse, 2007] Besse P., Milhem H., Mestre O., Dufour A. et Peuch V.H. (2007). Comparaison de techniques de data mining pour l'adaptation statistique des prévisions d'ozone du modèle de chimie-transport MOCAGE. Pollution Atmosphérique, 195, pp 285-292.

[Brier, 1950] Brier G.W. (1950). Verification of forecasts expressed in terms of probability. Mon. Wea. Rev., 78, pp 1-3.

[Bröcker, 2007] Bröcker J. et Smith L.A. (2007). Increasing the reliability of reliability diagrams. Wea. Forecasting, 22, pp 651-661.

[Brockwell, 1996] Brockwell P.J. et Davis R.A. (1996). Introduction to time series and forecasting. Springer, New York.

[Byington, 2002] Byington C., Roemer M., Kacprzynski G. et Galie T. (2002). Prognostic enhancements to diagnostic systems for improved condition-based maintenance. Proceedings of the IEEE Aerospace Conference, Big Sky, USA.

[Byington, 2004] Byington C.S., Kalgren P.W., Dunkin B.K. et Donovan B.P. (2004). Advanced diagnostic/prognostic reasoning and evidence transformation techniques for improved avionics

maintenance. Proceedings of the IEEE Aerospace Conference, 13 March, Big Sky, Montana, USA, volume 5, pp 3424-3434.

[Cacoullos, 1966] Cacoullos T. (1966). Estimation of a multivariate density. Annals of the Institute of Statistical Mathematics, 18, pp 178-189

[Candille, 2005] Candille G. et Talagrand O. (2005). Evaluation of probabilistic prediction systems for a scalar variable. Royal Meteorological Society, pp 1-20.

[Charpentier, 2008] Charpentier A. (2008). Mesurer les grands risques. Université Rennes 1.

[Chou, 1998] Chou Y., Polansky A.M., et Mason R.L. (1998). Transforming nonnormal data to normality in Statistical Process Control. Journal of Quality Technology, 30, 133-141.

[Coles, 2001] Coles S. (2001). An Introduction to Statistical Modeling of Extremes Values. Springer.

[D'Agostino, 1986] D'Agostino R.B. et Stephens M.A. (1986). Goodness-of-Fit Techniques. Marcel Dekker.

[Darkhovski, 2003] Darkhovski B. et Staroswiecki M. (2003). A Game - Theoretic Approach to Decision in FDI. IEEE Transactions On Automatic Control, Vol. 48, n°5.

[De Haan, 1993] de Haan L. et Rootzen H. (1993). On the estimation of high quantiles. J. Statist. Plann. Inference, 35, 1-13.

[Deloux, 2008] Deloux E. (2008). Politiques de maintenance conditionnelle pour un système à dégradation continue soumis à un environnement stressant. Thèse de l'université de Nantes.

[Demaison, 2010] Demaison F., Flandrois X., Massé J.R., Massot G., Hmad O. et Ricordeau J. (2010). Méthode de suivi de la consommation d'huile dans un système de lubrification de turbomachine. Brevet # 1H105790 1093FR.

[Deming, 1966] Deming W.E. (1966). Some Theory of Sampling. Dover Publications.

[Devaine, 2010] Devaine M., Goude Y. et Stoltz G. (2010). Forecasting of the electrical consumption by aggregation of sleeping experts; application to Slovakian and French country-wide hourly predictions.

[DGA, 2009] Direction Générale des Armements. (2009). Quelques explications sur l'échelle des TRL (Technology readiness level) d'après le plan stratégique de recherche & technologie de défense et de sécurité.

[Dragomir, 2008] Dragomir O.E., Gouriveau R. et Zerhouni, N. (2008). Adaptive neuro-fuzzy inference system for midterm prognostic error stabilization. International Journal of Computers, Communications and Control, pp 271-276.

[Duda, 2001] Duda R.O., Hart P.E. et Stork D.G. (2001). Pattern classification. Second Edition, Wiley, New York.

[Ebert, 2013] Ebert B. Forecast Verification - Issues, Methods and FAQ. Dernier accès 2013, url: http://www.bom.gov.au/bmrc/wefor/staff/eee/verif/verif_web_page.html.

[Ecoutin, 2010] Ecoutin S., Flandrois X. et Massé, J.R. (2010). Surveillance d'une chaine de mesure redondée d'un turboréacteur. Brevet # FR – NP ETR7235.

[El amry, 2010] El amry A. (2010). Maturation d'algorithmes de surveillance aéronautique par Lean-Sigma. Rapport de stage de fin d'études de l'UTT.

[Embrechts, 1997] Embrechts P., Klüppelberg C. et Mikosch T. (1997). Modelling Extremal Events for Insurance and Finance. Springer, Berlin.

[Embrechts, 2000] Embrechts P. (2000). Extremes and Integrated Risk Management. Risk Books and UBS Warburg, London.

[Fisher, 1912] Fisher R.A. (1912). On an absolute criterion for fitting frequency curves. Messenger of Mathematics, 41, pp 155-160.

[Fisher, 1921] Fisher R.A. (1921). On the "probable error" of a coefficient of correlation deduced from a small sample. Metron, 1, pp 3-32.

[Fisher, 1922] Fisher R.A. (1922). On the mathematical foundations of theoretical statistics. Transactions of the Royal Society, pp 309-368.

[Fisher, 1928] Fisher R. et Tippett L. (1928). Limiting forms of the frequency distribution of the largest or smallest member of a sample. Proceedings of the Cambridge Philosophical Society, 24, pp 180-190.

[Fix, 1951] Fix E. et Hodges J. (1951). Discriminatory analysis, nonparametric discrimination : consistency properties. Report n° 4, Project n° 21-49-004, USAF School of Aviation Medicine.

[Flandrois, 2010] Flandrois X., Massé J.R., Ausloos A., Mouton P. et Aurousseau C. (2010). Method for monitoring the health status of devices that affect the starting capability of a jet engine. Brevet W02010092080 A1.

[Foiret, 2013] Foiret, G. (2013). Système de surveillance d'une chaîne de mesure d'un turboréacteur. Brevet # WO 2013/038091 Al.

[Forrest, 2008] Forrest W.B. (2008). Implementing Six Sigma Smarter Solutions Using Statistical Methods. Wiley – Interscience Publications.

[Gumbel, 1958] Gumbel E. (1958). Statistics of Extremes. Columbia University Press, New York.

[Hill, 1975] Hill B. (1975). A simple general approach to inference about the tail of a distribution. Annals of Statistics, 3, pp 1163-1174.

[Hmad, 2009] Hmad O. et Massé J.R. (2009). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC) Maturation : itération 1. V2.0B.

[Hmad, 2010a] Hmad O. (2010). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC), première itération de maturation sur les données d'exploitation. V1.0.

[Hmad, 2010b] Hmad O. (2010). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC V1.2), itération de maturation sur les données d'exploitation. V1.0.

[Hmad, 2010c] Hmad O. (2010). Consommation d'huile, analyse de données SESAM : Etude de faisabilité pour suivi de la consommation d'huile. V1.1.

[Hmad, 2010d] Hmad O., Demaison F. et Massot G. (2010). CFM56-7B : Approfondissement des modes de surconsommation. Compte rendu de réunion du 14/09/10.

[Hmad, 2011a] Hmad O., Grall-Maes E., Beauseroy P., Massé J.R. et Mathevet A. (2011). A comparison of distribution estimators used to determine a degradation decision threshold for very low first order error. Conférence ESREL11, Troyes, France.

[Hmad, 2011b] Hmad O. (2011). Dossier d'études et de Conception, CFM56-7B - Surveillance du système de lubrification (EOC), première itération de maturation sur les données SESAM.

[Hmad, 2012a] Hmad O., Grall-Maes E., Beauseroy P., Masse J.R. et Mathevet A. (2012). A Maturation Procedure for Prognosis and Health Monitoring Algorithms. PSAM11 & ESREL12 conference, June 25-29, Helsinki, Finland.

[Hmad, 2012b] Hmad O. (2012). Méthode de développement et de validation des méthodes de pronostic système. V1.0.

[Hmad, 2012c] Hmad O., Massé J.R., Grall-Maes E., Beauseroy P. et Boulet X. (2012). « Procédé de réglage de seuil de décision ». FR8324.

[Hosking, 1985] Hosking J. (1985). Maximum-likelihood estimation of the parameters of the generalized extreme-value distribution. Applied Statistics, 34, pp 301-310.

[Hosking, 1987] Hosking J. et Wallis J. (1987). Parameter and quantile estimation for the generalized Pareto distribution. Technometrics, 29, pp 339-349.

[Hussenet, 2009] Hussenet F.X., Massé J.R. et Hmad O. (2009). Chantier Lean - Sigma N° 44 – Surveillance de la capacité à démarrer CFM56-7B - Voice of Business - compte rendu de réunion du 03/03/09.

[Iserman, 1997] Isermann R. et Ballé P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. Control Engineering Practice, vol 5, pp 709 -719.

[ISO, 2003] Norme NF ISO 13374-1. (2003). Surveillance et diagnostic d'état des machines – Traitement, échange et présentation des données - Partie 1: Lignes directrices générales.

[ISO, 2005] Norme NF ISO 13381-1. (2005). Surveillance et diagnostic des machines - Pronostic - Partie 1: Lignes directrices générales.

[Jardine, 2006] Jardine A.K.S., Lin D. et Banjevic D. (2006). A review on machinery diagnostics and prognostics implementing condition based maintenance. Mechanical Systems and Signal Processing, 20, pp 1483-1510.

[Johnson, 1949] Johnson N.L. (1949). Systems of frequency curves generated by methods of translation. Biometrika, 36, pp 149-176.

[Kalgren, 2006] Kalgren P.W., Byington C.S. et Roemer M.J. (2006). Defining PHM, A Lexical Evolution of Maintenance and Logistics. Autotestcon, IEEE, pp 353-358.

[Kramer, 1993] Kramer M.A. et Mah R.S.H. (1993). Model-based monitoring. Proceedings of the second international conference on foundations of computer-aided process operations, pp 45 - 68.

[Krzysztofowicz, 2001] Krzysztofowicz R. (2001). The case for probabilistic forecasting in hydrology. Journal of Hydrology, vol. 249, pp 2-9.

[Lacaille, 2009] Lacaille J. (2009). Standardized failure signature for a turbofan engine. IEEE Aerospace Conference, Big Sky, Montana, USA.

[Lagrange, 1776] Lagrange J.L. (1776). Mémoire sur l'utilité de la méthode de prendre le milieu entre les résultats de plusieurs observations dans lequel on examine les avantages de cette méthode par le calcul des probabilités, et où l'on résout différents problèmes relatifs à cette matière. Miscellanea Taurinensia, 5, pp 167–232.

[Lagrange, 1826] Lagrange L.J. (1826). Traité de la résolution des équations numériques de tous les degrés. Bachelier 3ème édition, Paris.

[Le Guen, 2001] Le Guen M. (2001). La boîte à moustaches de TUKEY, un outil pour initier à la statistique.

[Lebold, 2001] Lebold M. et Thurston M. (2001). Open standards for Condition-Based Maintenance and Prognostic Systems. Proceeding of 5th Annual Maintenance and Reliability Conference, Gatlinburg, USA.

[Lecerf, 2009] Lecerf N., Massé J.R. et Hmad O. (2009). Chantier Lean - Sigma N $^{\circ}$ 44 – Surveillance de la capacité à démarrer CFM56-7B - Voice of customer - Définition des CTQ – compte rendu de réunion du 17/02/09.

[Lejeune, 2010] Lejeune M. (2010). Statistique : La théorie et ses applications. Springer, second édition, Paris.

[Letot, 2009] Letot C. et Dehombreux P. (2009). Modèles de dégradation pour l'estimation de la fiabilité et de la durée de vie résiduelle : applications à la fissuration. Actes du 4ème congrès PENTOM, Autrans, France.

[Li, 2009] Li X.H., Yuan F., Bai X.Y. et Li X.Y. (2009). Johnson transformation method in geostatistic analysis - A case study in Tongling area, China. Goldschmidt Conference.

[Lucas, 1999] Lucas P.J.F. et Abu-Hanna A. (1999). Prognostic methods in medicine. Artificial Intelligence in Medicine, 15, pp 105-119.

[Massé, 2010] Massé J.R., Lamoureux B., Aurousseau C., Deldalle R., Flandrois X. et Sif A. (2010). Procédé et dispositif de surveillance d'une boucle d'asservissement d'un système d'actionnement de géométries variables d'un turboréacteur. Brevet # FR1058681 - ETR6511.

[Massé, 2011a] Massé J.R., Boulet X. et Godard T. (2011). Méthode de surveillance d'une chaine de mesure d'un turboréacteur. Brevet # FR8272/1161170.

[Massé, 2011b] Massé J.R., Lamoureux B., Janati idrissi H., Marquisseau F. et Sif A. (2011). Méthode de surveillance d'un dispositif de commande d'un doseur de carburant d'un turboréacteur. Brevet # FR8289/1161175.

[Mayorquim, 2004] Mayorquim J.L. et Tafat S. (2004). Marchés financiers : Prévision du hazard et non stationnaire. Saint Ouen l'aumône, France.

[McNeil] McNeil A.J. et Saladin T. (1997). The peaks over thresholds method for estimating high quantiles of loss distributions.

[MIMOSA] Machinery Information Management Open System Alliance - MIMOSA. Open Systems Architecture for Condition-Based Maintenance, OSA-CBM v3.1 standard.

[Murphy, 1973] Murphy A.H. (1973). A new vector partition of the probability score. J. Appl. Meteor., 12, pp 595-600.

[Nahed, 2011] Nahed C. et Hmad O. (2011). Dossier d'études et de Conception, CFM56-7B - Surveillance de la capacité à démarrer (ESC V1.2), itération de maturation de la fonction de confirmation à partir de données SESAM.

[Nahed, 2012] Nahed C. (2012). Maturation d'un algorithme de surveillance aéronautique. Déploiement d'une démarche Six-Sigma. Rapport de stage de fin d'études de l'UTC.

[Nguyen, 2012] Nguyen D.H. (2012). Maturation d'un algorithme de surveillance d'équipements aéronautiques par modélisation markovienne de l'évolution des dégradations. Déploiement d'une démarche Six-Sigma. Rapport de stage de master de l'UTT.

[Nikulin, 2006] Nikulin M., Bagdonavicius V., Huber C. et Nikouline V. (2006). Cours de Statistique Mathématique, Université Victor Segalen, Bordeaux 2, pp 416-417.

[Nikulin, 2007] Nikulin M., Gerville-Réache L. et Couallier V. (2007). Statistique des essais accélérés. Hermes Science Publications.

[Nikulin, 2010] Nikulin M.S., Limnios N., Balakrishnan N., Kahle W. et Huber-Carol C. (2010). Advances in Degradation Modeling Applications to Reliability, Survival Analysis, and Finance. Birkhauser, Boston.

[Nodet, 2010] Nodet M. (2010). La pluie et le beau temps outils mathématiques de la prévision météo. Journées Nationales de l'association des professeurs de mathématiques de l'enseignement public.

[Nya Djiki, 2010a] Nya Djiki R. (2010). Start Capability, dossier d'études et de conception : Surveillance de la capacité à démarrer. V1.4.

[Nya Djiki, 2010b] Nya Djiki R. (2010). Huile Moteur, dossier d'études et de conception : Surveillance de la consommation d'huile. V3.1.

[Pickands, 1975] Pickands J. (1975). Statistical inference using extreme order statistics. Annals of statistics, 3, pp 119-131.

[Pillet, 2005] Pillet M. (2005). Appliquer la maîtrise statistique des processus (MSP/SPC). Editions d'Organisation, Paris.

[Rasovska, 2007] Rasovska I., Chebel-Morello B. et Zerhouni N. (2007). Classification des différentes architectures en maintenance. 7e Congrès international de génie industriel, Trois-Rivières, Québec, CANADA.

[Roquelaure, 2007] Roquelaure S., et Bergot T. (2007). A Local Ensemble Prediction System (L-EPS) for fog and low clouds : construction, Bayesian Model Averaging calibration and validation. Journal of Applied Meteorology and Climatology.

[Roussignol, 2009] Roussignol M. (2009). Gamma stochastic process and application to maintenance. Cours de l'université Paris Est – Marne la vallée.

[Salami, 2011] Salami A. (2011). Inférence statistique pour un modèle de dégradation en présence de variables explicatives. Thèse de l'université de Pau et des pays de l'Adour.

[Saporta, 2011] Saporta G. (2011). Probabilités, Analyse des données et Statistique. TECHNIP, 3ème édition.

[Saxena, 2008] Saxena A., Celaya J., Balaban E., Goebel K., Saha B., Saha S. et Schwabacher M. (2008). Metrics for Evaluating Performance of Prognostics Techniques. 1st International Conference on Prognostics and Health Management, Denver, USA.

[Saxena, 2009] Saxena A., Celaya J., Goebel K., Saha B. et Saha S. (2009). Evaluating Algorithm Performance Metrics Tailored for Prognostics. IEEE Aerospace Conference, Big Sky Montana, pp 1-13.

[Shapiro, 1965] Shapiro S.S. et Wilk M.B. (1965). An analysis of variance test for normality. Technometrics, 14, pp 355-370.

[Sif, 2005] Sif A. (2005). Préparation de la mise en œuvre de nouvelles méthodologies de surveillance aéronautique. Rapport de stage de fin d'études.

[Slifker, 1980] Slifker J.F. et Shapiro S.S. (1980). The Johnson System : Selection and Parameter Estimation. Technometrics, 22(2), pp 239-246.

[Stigler, 2007] Stigler S.M. (2007). The Epic Story of Maximum Likelihood. Statistical Science, vol. 22, n° 4, pp 598–620. DOI: 10.1214/07-STS249.

[Stoltz, 2010] Stoltz G. (2010). Agrégation séquentielle de prédicteurs : méthodologie générale et applications à la prévision de la qualité de l'air et à celle de la consommation électrique. Journal de la Société Française de Statistique, vol. 151, n° 2, pp 66-106.

[Vachtsevanos, 2006] Vachtsevanos G., Lewis F.L., Roemer M., Hess A. et Wu B. (2006). Intelligent Fault Diagnosis and Prognosis for Engineering Systems. First edition, John Wiley & Sons, Hoboken, New Jersey.

[Van Noortwijk, 2009] Van Noortwijk J.M. (2009). A survey of the application of gamma processes in maintenance. Reliability Engineering and System Safety, 94(1), pp 2–21.

[Vasile, 2008] Vasile O.E. (2008). Contribution au pronostic de défaillances par réseau neuro-flou : maîtrise de l'erreur de prédiction. Thèse de doctorat de l'Université de Franche Comté.

[Venkatasubramanian, 2003a] Venkatasubramanian V., Rengaswamy R., Yin K. et Kavuri S.N. (2003a). A review of process fault detection and diagnosis Part I : Quantitative model-based methods. Computers and Chemical Engineering, vol. 27, pp 293 - 311.

[Venkatasubramanian, 2003b] Venkatasubramanian V., Rengaswamy R., Yin K. et Kavuri S.N. (2003b). A review of process fault detection and diagnosis Part II : Qualitative models and search strategies. Computers and Chemical Engineering, vol. 27, pp 313 - 326.

[Venkatasubramanian, 2003c] Venkatasubramanian V., Rengaswamy R., Yin K. et Kavuri S.N. (2003c). A review of process fault detection and diagnosis Part III : Process history based methods. Computers and Chemical Engineering, vol. 27, pp 327 - 346.

[Vrignat, 2011] Vrignat P., Avila M., Duculty F., Aupetit S., Slimane M. et Kratz F. (2011). Génération d'indicateurs de maintenance par une approche semi paramétrique et par une approche markovienne. 12ème forum international de la maintenance, Paris.

[Zwingelstein, 1995] Zwingelstein G. (1995). Diagnostic des défaillances, théorie et pratique pour les systèmes industriels. Editions HERMES.

Produits de la thèse

Publications dans des congrès internationaux avec articles étendus

[1] Hmad O., Grall E., Beauseroy P., Masse J.R. & Mathevet A. (2011). "A comparison of distribution estimators used to determine a degradation decision threshold for very low first order error". ESREL conference, September 18-22, Troyes, France.

[2] Hmad O., Grall E., Beauseroy P., Masse J.R. & Mathevet A. (2012). "A Maturation Procedure For Prognosis and Health Monitoring Algorithms ". PSAM11 & ESREL12 conference, June 25-29, Helsinki, Finland.

[3] Hmad O., Grall E., Beauseroy P., Masse J.R. & Mathevet A. (2013). "Maturation of Detection Functions by Performances Benchmark. Application to a PHM Algorithm". Prognostics and System Health Management Conference (PHM-2013), September 8-11, 2013, Milan, Italy.

[4] Massé J.R., Hmad O., Grall E., Beauseroy P., Masse J.R. & Mathevet A. (2013). "System PHM Algorithm Maturation". Prognostics and System Health Management Conference (PHM-2013), September 8-11, 2013, Milan, Italy.

Publications dans des congrès nationaux avec articles étendus

[5] Hmad O., Grall E., Beauseroy P., Masse J.R. & Mathevet A. (2012). "Procédure de Maturation d'Algorithmes de Pronostic et Health Monitoring". Conférence Lambda Mu 18, 15-19 Octobre, Tours, France.

Brevets

Hmad O., Massé J -R., Grall-Maes E., Beauseroy P., Boulet X. (16/05/2012). "Procédé de surveillance d'une dégradation d'un dispositif embarqué d'un aéronef avec détermination automatique d'un seuil de décision". FR1254506. (Réglage de seuil après moyenne mobile).

Hmad O., Massé J -R., Grall-Maes E., Beauseroy P. (06/09/2013). "Procédé de surveillance d'une dégradation d'un dispositif embarqué d'un aéronef avec détermination automatique d'un seuil de décision ". FR1358593. (Réglage de seuil pour l'approche K parmi N).

Rapports internes

Hmad O. et Massé J.R. (2009). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC) Maturation : itération 1. V2.0B.

Hmad O. (2010). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC), première itération de maturation sur les données d'exploitation. V1.0.

Hmad O. (2010). Dossier d'études et de Conception : CFM56-7B - Surveillance de la capacité à démarrer (ESC V1.2), itération de maturation sur les données d'exploitation. V1.0.

Hmad O. (2010). Consommation d'huile, analyse de données SESAM : Etude de faisabilité pour suivi de la consommation d'huile. V1.1.

Hmad O., Demaison F. et Massot G. (2010). CFM56-7B : Approfondissement des modes de surconsommation. Compte rendu de réunion du 14/09/10.

Hmad O. (2011). Dossier d'études et de Conception, CFM56-7B - Surveillance du système de lubrification (EOC), première itération de maturation sur les données SESAM.

Hmad O. (2012). Méthode de développement et de validation des méthodes de pronostic système. V1.0.

Nahed C. et Hmad O. (2011). Dossier d'études et de Conception, CFM56-7B - Surveillance de la capacité à démarrer (ESC V1.2), itération de maturation de la fonction de confirmation à partir de données SESAM.

ANNEXES

ANNEXE - 1 LE TURBOREACTEUR CFM56-7B

Le turboréacteur est un moteur à réaction. Il est basé sur le principe d'action – réaction. Il absorbe de l'air et le rejette après l'avoir accéléré. Pour accroître la vitesse de l'air aspiré, celui-ci subit une compression, une combustion et une détente. Ces trois transformations ont lieu simultanément et de façon continue dans chaque organe du moteur.

- La compression permet d'optimiser les processus de combustion et d'extraction de puissance puisque la combustion du mélange combustible/comburant se fait dans la chambre de combustion qui représente un petit volume.
- La combustion est le phénomène par lequel l'énergie chimique d'un combustible est transformée en énergie calorifique. L'air comprimé sortant du compresseur entre dans la chambre de combustion, qui est en général de type annulaire. Là, il est partiellement mélangé au carburant pulvérisé, puis enflammé. Sa température et son énergie disponible sous forme calorifique, augmentent considérablement.
- La détente (dans la turbine et la tuyère) : En sortie de chambre de combustion, les gaz comprimés et très chauds vont se détendre dans la turbine qui va prélever une partie de leur énergie interne et la transformer en énergie mécanique pour entraîner le compresseur et les accessoires. Ensuite ces gaz vont se détendre dans la tuyère où ils vont acquérir une vitesse d'échappement maximale et produire, de ce fait, une poussée.

Différentes configuration de compression, de combustion et de détente permettent d'obtenir différentes performances des turboréacteurs. Pour améliorer ces performances, deux solutions sont possibles :

- accélérer les gaz à la sortie du turboréacteur en les chauffant une seconde fois dans le canal d'éjection : c'est la post-combustion. Elle permet les hautes performances des moteurs militaires comme le M88 ou l'Olympus sur Concorde.
- traiter une plus grande quantité d'air avec une « soufflante » placée à l'entrée du moteur (Figure 77). La « soufflante » aspire et accélère plus d'air qu'il n'en faut pour la combustion. Ce surplus d'air est simplement éjecté à l'arrière plus vite qu'il n'est entré dans la « soufflante ». Cette solution, qui permet de faire des économies de carburant, est particulièrement adaptée aux avions de transport civil. C'est le turboréacteur CFM56 qui illustre le mieux cette technologie.

Un turboréacteur équipé d'une soufflante est dit double flux (Figure 77). Une partie de l'air admis (le flux primaire) s'oriente vers le compresseur basse pression et subit les transformations décrites précédemment alors que l'autre partie (le flux secondaire) est comprimée par la soufflante, entraînée par la turbine basse pression. Le flux secondaire est ensuite détendu dans la partie extérieure du moteur et produit 80% de la poussée.



Figure 77 : Principe des turboréacteurs à double flux.

Le turboréacteur CFM56-7B (Figure 78) est un turboréacteur double flux double corps. Un turboréacteur est dit mono corps s'il se compose d'un seul compresseur associé à une seule turbine. Il est dit double corps s'il est doté d'un compresseur basse pression associé à une turbine basse pression et d'un compresseur haute pression associé à une turbine haute pression. Le turboréacteur CFM56-7B est constitué d'un orifice d'admission d'air, d'une soufflante en titane de 1550 mm de diamètre, de compresseurs basse et haute pression, d'une chambre de combustion annulaire, d'une turbine haute pression dotées d'aubes capables de résister à des températures extrêmes, d'une turbine basse pression et d'une tuyère. Il intègre également une régulation électronique pleine autorité redondante (FADEC : Full Authority Digital Engine Control). Et pour répondre aux exigences des compagnies les plus soucieuses de l'environnement, ce moteur peut être équipé d'une chambre de combustion à double tête, ce qui permet de réduire jusqu'à 40 % les émissions d'oxydes d'azote, par rapport aux chambres classiques, par optimisation de la combustion en fonction du régime moteur.



Figure 78 : Le turboréacteur CFM56-7B

Certifié en 1996 par la Federal Aviation Administration (FAA) et la Direction Générale de l'Aviation Civile (DGAC) et choisit par Boeing pour motoriser sa gamme B737 nouvelle génération, le CFM56-7B assure une poussée maximale au décollage comprise entre 87kN et 121 kN. Le B737 nouvelle génération est, par ailleurs, capable de voler avec un seul moteur pendant 180 minutes.

1. Le système de régulation

La régulation a pour rôle de maintenir le point de fonctionnement du turboréacteur de façon à obtenir la poussée demandée par le pilote. Pour cela, elle doit tenir compte des conditions de vol (altitude, vitesse...) et des limites de fonctionnement imposées par la technologie du turboréacteur. Elle doit aussi assurer :

- l'optimisation des performances sur toute la durée du vol : La régulation numérique et l'intégration avion ont permis l'amélioration des performances avion par un pilotage de la poussée à 1% près, de la gestion des prélèvements d'air et de l'adaptation des régimes. L'intégration numérique permet, quant à elle, l'amélioration des performances moteurs par l'optimisation de la géométrie moteur (servovalves VSV et VBV) et par le pilotage des jeux (servovalves HPTC, LPTC).
- la garantie la sécurité via une accommodation aux pannes. La régulation a également été conçue de façon à garantir la sécurité du système. Elle est dotée d'une architecture redondante qui permet la détection des pannes de capteurs et d'actionneurs et sa reconfiguration (choix des capteurs, utilisation de modèles...). Elle permet également de détecter les extinctions moteur.
- l'indication au cockpit des paramètres pour le pilotage, la surveillance et la maintenance. La régulation indique au cockpit des paramètres de pilotage en temps réel, des paramètres de surveillance moteur et des messages de seuil et de panne associés. Elle permet également l'élaboration de rapport de maintenance avec hiérarchie des pannes possibles.

La régulation est entièrement gérée par le système électronique de régulation pleine autorité (FADEC) qui comprend :

- le calculateur ou l'ECU (Engine Control Unit),
- l'unité hydromécanique ou le HMU (Hydro Mechanical Unit),
- le connecteur d'identification,
- les capteurs,
- les câblages inter-composants (harnais électriques),
- les actionneurs,
- les composants d'allumage moteur,
- les entrées et sorties du système inverseur.

Les capteurs donnent une indication de l'état dans lequel se trouve le moteur à l'ECU. Ils fournissent des indications de température, de pression, de débit, de vitesse de rotation et de position.

L'ECU assure la gestion du système de régulation suivant les informations en entrée (commande provenant de la manette des gaz du cockpit, indications des capteurs, signaux de détection de pannes) et effectue ensuite les opérations appropriées : envoi de consignes à un actionneur ou au système inverseur, envoi de messages de maintenance, envoi de commandes de démarrage du moteur.

Le HMU commande et régule les équipements. Cette interface est pilotée par l'ECU et contrôle le positionnement des actionneurs et le dosage du carburant.

Les actionneurs exécutent les ordres. Parmi ces éléments de puissance, on trouve des pompes, des doseurs de carburant, des injecteurs et des vérins. Chargés du pilotage de la configuration du moteur, les vérins sont au nombre de six :

- FMV (Fuel Metering Valve) qui règle la quantité de carburant injectée dans la chambre de combustion et qui joue donc un rôle fondamental,
- VSV (Variable stator Valve) qui ajuste l'incidence des redresseurs du stator du compresseur pour obtenir son efficacité optimale,
- VBV (Variable Bleed Valve) qui dévie une partie du flux primaire (flux le plus chaud) vers le secondaire pour éviter un retour de pression (pompage),
- TBV (Transient Bleed Valve) qui dévie une partie du flux d'air du 9^{ème} étage du compresseur haute pression vers le 1^{er} étage de la turbine basse pression, pour une efficacité optimale,
- HPTCCV (High Pressure Turbine Clearance Control Valve) qui contrôle le jeu entre les aubes et le carter de la turbine haute pression,
- LPTCCV (Low Pressure Turbine Clearance Control Valve) qui contrôle le jeu entre les aubes et le carter de la turbine basse pression.

2. Le circuit carburant

Le premier rôle du circuit carburant (Figure 79) est d'assurer l'alimentation du turboréacteur en carburant propre en l'amenant du réservoir de l'avion aux injecteurs de la chambre de combustion et doser avec précision. De plus, il doit assurer différentes fonctions commandées par le système de régulation. Il joue un rôle important dans les configurations de vol suivantes : démarrage et rallumage en vol et fonctionnement en secours carburant en cas de panne du circuit de carburant principal. Enfin le carburant est aussi utilisé comme source froide par des échangeurs thermiques (huiles, air). Il est composé d'un circuit basse pression et d'un circuit haute pression.

Les principaux équipements du circuit basse pression sont :

• une pompe basse pression centrifuge qui récupère le carburant fourni par la pompe de gavage du réservoir avion et assure une première élévation de pression pour éviter le phénomène de cavitation de la pompe haute pression. Ce phénomène, qui se manifeste par la formation de poches gazeuses autour des pièces mobiles (pignons, paliers), est responsable de la dégradation du rendement de la pompe haute pression.

- des échangeurs huile/carburant, qui servent, selon leur positionnement dans le circuit, à refroidir l'huile provenant de l'IDG (alternateur) ou du moteur et à réchauffer le carburant destiné aux servovalves.
- un filtre principal qui retient les particules présentes dans le carburant afin de protéger la pompe haute pression et les organes de dosage. On trouve également un filtre auto-lavable qui purifie le carburant destiné aux géométries variables.

Les principaux équipements du circuit haute pression sont :

- une pompe haute pression volumétrique à engrenages qui assure un deuxième étage de pression et alimente le dispositif de dosage dans les conditions déterminées de pression et débit carburant.
- un régulateur hydromécanique ou HMU qui comprend :
 - o un doseur carburant appelé aussi FMV (Fuel Metering Valve),
 - un clapet de pressurisation (HPSOV) qui garantit une pression minimale, même à faible débit, pour faire fonctionner les géométries variables et les servovalves,
 - des servovalves, qui pilotent la puissance hydraulique pour la commande des géométries variables au cours du vol ou du débit de carburant délivré,
 - une vanne de dérivation (By-Pass), qui renvoie dans le circuit l'excès de carburant fourni par la pompe haute pression par rapport à la consigne délivrée par le calculateur.
- un débitmètre massique, qui permet au pilote de détecter les anomalies, et des injecteurs, qui sont protégés par un filtre de toute pollution intempestive et qui assurent une pulvérisation fine du carburant dans la chambre de combustion.



Figure 79 : Schéma de principe du circuit carburant

Ce schéma de principe permet de repérer les principaux composants d'un circuit carburant. Il n'est pas exhaustif, et l'ordre des composants (filtres, échangeurs) peut être différent. Le schéma de principe du circuit carburant comprend :

• La ligne directe. Elle assure la fonction principale du circuit carburant, c'est-à-dire l'alimentation en carburant. Le carburant issu du réservoir avion est mis sous pression par la pompe basse pression puis filtré afin d'éviter l'altération des composants du circuit. Ensuite, la pompe haute pression fournit la pression nécessaire pour permettre l'injection du carburant dans la chambre de combustion.

- La boucle des géométries variables. Elle assure le fonctionnement des vérins qui actionnent les différentes géométries variables du moteur. Elle est en dérivation de la ligne directe. Le carburant est finement filtré et réchauffé car les servovalves qui pilotent les vérins sont très sensibles aux impuretés et à la présence de glace. Le carburant en retour des vérins est ensuite réinjecté dans la boucle de recirculation.
- La boucle de recirculation. Le débit délivré par la pompe haute pression est sensiblement proportionnel à la vitesse de rotation du moteur. Cependant, la Figure 80 montre que la demande réelle au niveau des injecteurs n'est pas linéaire, ce qui se traduit par un excédent de carburant à évacuer via cette boucle grâce à la vanne de dérivation. La pompe haute pression est dimensionnée pour délivrer un débit suffisant compris entre 10% (rallumage) et 100% (plein gaz) du régime maximal.



Figure 80 : Caractéristique d'une boucle de recirculation

3. Le circuit d'huile

Le but principal du circuit d'huile est de fournir la lubrification et le refroidissement des engrenages et des paliers situés dans les enceintes avant et arrière du moteur. L'échauffement provoqué par ces pièces mécaniques est évacué par l'huile qu'il est donc nécessaire de refroidir à son tour. Le circuit d'huile est autonome et peut être divisé en trois circuits différents (Figure 81):

- le circuit d'alimentation d'huile (supply circuit),
- le circuit de récupération d'huile (scavenge circuit),
- le circuit de ventilation d'huile (circuit venting).



Figure 81: Schéma de principe du circuit d'huile

Le circuit d'huile comprend les principaux éléments suivants :

- le réservoir d'huile. Il permet de stocker jusqu'à 22 litres d'huile.
- la vanne anti-fuite. Elle empêche les fuites d'huile lorsque le tube du groupe de lubrification est retiré et après l'arrêt du moteur. Au cours du fonctionnement du moteur, la pression de l'huile maintient la vanne anti-fuite ouverte. Lorsque le moteur est coupé, la vanne se ferme.
- le groupe de lubrification. Il a deux finalités:
 - o pressuriser et filtrer l'huile destinée à lubrifier les roulements et les engrenages,
 - o pomper l'huile dans le circuit de récupération pour la retourner dans le réservoir. Le groupe de lubrification est composé de quatre pompes, un filtre à huile et un indicateur de colmatage. Une pompe est dédiée au circuit d'alimentation et les trois autres au circuit de récupération. Au cours de l'alimentation, l'huile du réservoir est sous pression et se dirige ensuite vers le filtre à huile. En cas de colmatage du filtre, une indication de colmatage est déclenchée. L'indicateur de colmatage est un capteur installé entre les pressions en amont et en aval du filtre. Il détecte toute montée en pression différentielle en raison de l'obstruction du filtre. Cette indication signale la nécessité d'une action de maintenance pour changer le filtre. Lorsque l'indication de colmatage est déclenchée, la vanne de dérivation (by-pass) s'ouvre pour assurer la lubrification.
- l'échangeur principal huile-carburant. L'alternateur IDG (Integrated Drive Generator) fournit l'énergie électrique de l'avion. Il est refroidi à l'huile. Pour empêcher une surchauffe de cette huile, on la fait circuler dans l'échangeur huile-carburant. Cet échangeur est placé en aval de la pompe basse pression où le carburant est le plus froid. Celui-ci ne suffit généralement pas à assurer cette fonction, on complète donc parfois le circuit par un refroidisseur huile-air, placé à l'arrière de la soufflante.
- l'ensemble des filtres de récupération. Dans le circuit de récupération, le mélange huile-air est pompé et passe à travers des détecteurs de particules magnétiques, installés sur les bougies. Ces détecteur appelé MCD (Magnetic Chip Detector) servent à détecter si un filtre ou une partie du circuit est bouché en surveillant la différence de pressions. En plus, un capteur de niveau bas d'huile est en charge de fournir un signal d'alarme au cas où il détecte un niveau d'huile trop faible pour garantir le bon fonctionnement des parties mécaniques. Bien entendu, ce niveau d'alarme est défini de façon à ce qu'il ne soit pas critique pour assurer au moins le vol en cours.

4. Le système de démarrage et d'allumage

Le système de démarrage utilise de la puissance pneumatique pour faire tourner le compresseur haute pression pendant la procédure de démarrage. Il peut être sollicité au sol et en vol. Il est principalement composé d'une vanne d'admission d'air (ou vanne de démarrage, Starter Air Valve - SAV) et d'un démarreur. En plus de ces deux composants, il fait intervenir un compresseur d'air (Auxiliary Power Unit - APU), un système d'allumage et les systèmes décrits précédemment (système de régulation, circuit carburant et circuit d'huile).

- Le compresseur d'air (APU) permet de produire l'énergie pneumatique nécessaire au démarrage lorsque le moteur est à l'arrêt. Il ne représente pas la seule source d'air possible. En l'absence de compresseur APU ou en cas de panne, l'air nécessaire au démarrage du turboréacteur peut être obtenu grâce à un groupe de parc (source d'air au sol, indépendante de l'avion). Une autre solution consiste à utiliser l'air provenant du moteur opposé lorsqu'il est démarré (procédure dite « cross bleed »).
- La vanne de démarrage contrôle le fonctionnement du démarreur. Elle permet le passage de l'air issu du compresseur d'air (ou de l'une des autres sources d'air). Lorsque la vanne de démarrage est ouverte, la pression d'air est distribuée dans le démarreur qui fournit le couple nécessaire pour entraîner le compresseur haute pression. La fermeture de la vanne interrompt l'arrivé d'air dans le démarreur. Celui-ci n'entraine donc plus le compresseur haute pression.

- Le démarreur sert à mettre le moteur en rotation jusqu'à son régime d'auto entrainement. Il entraîne le compresseur haute pression jusqu'à 55,3% de son régime maximal. La pression d'air, provenant de la vanne SAV, met en rotation la turbine à l'intérieur du démarreur enclenchant ainsi l'embrayage et faisant tourner l'arbre de sortie du démarreur. Une fois le moteur démarré, la vanne SAV se ferme et l'embrayage est désengagé. Le moteur est ainsi entrainé par lui même.
- Le système d'allumage permet d'enflammer le mélange carburant-air dans la chambre de combustion. Il est composé de deux voies identiques et indépendantes comprenant chacune un boitier envoyant l'énergie à la bougie. L'allumage du moteur ne nécessite qu'une bougie. Une batterie branchée à une bougie en état de marche est également disponible.

ANNEXE - 2 DESCRIPTION DE L'ECHELLE TRL

Dans le domaine aéronautique, le niveau de maturité d'un processus ou d'une technologie est mesuré à l'aide de l'échelle TRL, Technology Readiness Level (Niveau de Maturité Technologique) [TRL, 2005].

En général, quand une nouvelle technologie est conçue, elle n'est pas immédiatement industrialisable. Elle est généralement soumise à l'expérimentation et à des tests de plus en plus réalistes. Une fois la technologie suffisamment éprouvée, elle peut être industrialisée. C'est dans cette perspective que l'échelle TRL a été élaborée. Elle a été imaginée par l'administration nationale de l'aéronautique et de l'espace – NASA en vue de gérer le risque technologique de ses programmes. Initialement constituée de sept niveaux, elle en comporte neuf depuis 1995 [DGA, 2009].

Ce système de mesure est maintenant employé dans de nombreux domaine afin d'évaluer le niveau de maturité d'une technologie avant de l'intégrer dans un système ou un sous-système. Il existe plusieurs définitions des neuf niveaux de maturité. Les définitions les plus employées sont celles proposées par le département de la défense des États-Unis et la NASA. Elles sont répertoriées sur la Figure 82.



Figure 82: Echelle des niveaux de maturité technologique - TRL

Le niveau TRL 1 représente le plus bas niveau de maturité technologique. A ce niveau, la recherche scientifique commence à être traduite en une recherche et développement (R&D) appliquée. Les exemples peuvent inclure des études papier portant sur les propriétés de base d'une technologie.

L'invention commence à partir du niveau TRL 2. Les principes de base ayant été observés, des applications peuvent être envisagées. Elles sont spéculatives et il n'existe pas de preuve ou d'analyse détaillée pour étayer les hypothèses. Les exemples sont limités à des études analytiques.

A partir du niveau TRL 3, une R&D active est initiée. Elle comprend des études analytiques, et des études en laboratoire destinées à valider physiquement les prédictions analytiques faites pour les différents éléments de la technologie. Les exemples impliquent des composants non encore intégrés ou représentatifs.

Des composants technologiques de base sont intégrés de façon à vérifier leur aptitude à fonctionner ensemble au niveau TRL 4. La représentativité est relativement faible si l'on se réfère au système final. Les exemples incluent l'intégration en laboratoire d'éléments ad hoc.

Au niveau TRL 5, la représentativité de la maquette technologique augmente significativement. Les composants technologiques de base sont intégrés à des éléments supports raisonnablement réalistes de

façon à être testés en environnement simulé. Les exemples incluent l'intégration hautement représentative de composants en laboratoire.

Pour atteindre le niveau TRL 6, un modèle représentatif ou un système prototype, allant bien au-delà de celui du TRL 5, est testé dans un environnement représentatif. Cela représente une étape majeure dans la démonstration de la maturité d'une technologie. Les exemples incluent les essais d'un prototype dans un environnement de laboratoire reproduisant fidèlement les conditions réelles ou les essais dans un environnement opérationnel simulé.

Le niveau TRL 7 représente un saut important par rapport au niveau TRL 6, exigeant la démonstration d'un prototype du système réel dans son environnement opérationnel (exemple : test d'un prototype dans un avion banc d'essai).

Au niveau TRL 8 le fait que la technologie fonctionne dans sa forme finale, et dans les conditions d'emploi prévues est démontré. Dans la plupart des cas, ce niveau de TRL marque la fin du développement du système réel.

Enfin, le niveau TRL 9 représente l'application réelle de la technologie sous sa forme finale et dans des conditions de missions opérationnelle telles que celles rencontrées lors des tests et évaluations opérationnels.

ANNEXE - 3 PROCEDURE DE MATURATION

L'évaluation et l'amélioration du niveau de maturité des algorithmes de surveillance sont réalisées à l'aide d'une procédure de maturation établie lors de cette thèse [Hmad, 2012a]. Elle consiste à dérouler une adaptation de la méthodologie Six-Sigma [Forrest, 2008] pour l'évaluation des performances de processus.

Le Six-Sigma est une marque déposée de Motorola désignant une méthodologie structurée de management visant à une amélioration de la qualité et de l'efficacité des processus. La méthode Six-Sigma a d'abord été appliquée à des procédés industriels avant d'être élargie à tous types de processus.

Cette méthode se base sur une démarche fondée à la fois sur la voix du client (enquêtes, etc.) et sur des données mesurables (par indicateurs) et fiables. Le Six Sigma repose sur les notions de client, processus et mesure, il s'appuie en particulier sur :

- les attentes mesurables du client (CTQ Critical To Quality),
- des mesures fiables mesurant les performances des processus,
- des outils statistiques pour analyser les causes sources influant les performances,
- des solutions attaquant ces causes sources,
- des outils pour contrôler que les solutions ont bien l'impact escompté sur les performances.

Le six sigma consiste à estimer les performances d'un processus tel qu'il existe sans y apporter de modification au préalable. Une fois les performances estimées, des modifications peuvent être apportées au processus si les performances ne répondent pas aux exigences issues de la voix du client. La méthode se base sur cinq étapes qui se contractent dans l'acronyme DMAIC pour « Définir, Mesurer, Analyser, Innover (améliorer) et Contrôler ».



Figure 83 : Principe DMAIC

Le Six-Sigma permet de réduire les coûts et les pertes pour tendre vers des résultats optimums en termes de profit et de qualité. Les objectifs pour l'entreprise sont de se doter d'actions mesurables et efficaces, de satisfaire ses clients, d'impliquer les équipes et bien souvent d'améliorer son image. Le déploiement d'une telle méthode permet d'estimer les performances d'un processus dans le but de l'améliorer continuellement. C'est donc cette amélioration continue qui permet d'acquérir des niveaux de maturité de plus en plus importants.

Cette démarche étant plus généralement appliquée à des processus industriels, elle a donc été adaptée afin d'être appliquée à la maturation d'algorithme. La procédure de maturation adaptée se compose des cinq phases suivantes (Figure 84) : Définir, Mesurer, Analyser, Optimiser et Contrôler.



Figure 84: Enchainement des phases de la procédure de maturation.

La **phase** « **Définir** » consiste à identifier tous les éléments nécessaires pour dérouler une itération de maturation. Cette phase doit établir les éléments suivants :

- sélectionner les versions des systèmes de surveillance à considérer,
- sélectionner les fonctions algorithmiques à maturer (par exemple : fonctions de détection et de pronostic),
- recueillir les besoins des clients « Voice Of Customer », du secteur opérations des compagnies aériennes (en termes de prévisions pour la planification des vols, de maintenance...) et des clients de la maintenance en ligne (en termes de productivité et de gestion des rechanges...),
- en déduire des exigences critiques « Critical Customer Requirements » par exemple en termes d'horizon temporel de prévision et de précision de localisation,
- de façon symétrique, recueillir la « Voice Of Business », par exemple en termes d'arguments de vente de moteurs ou d'arguments de vente de management de flottes,
- en déduire des exigences critiques « Critical Business Requirements » par exemple en termes de coûts de surveillance, de complément à l'excellente fiabilité ou d'amélioration de la gestion des rechanges,
- traduire ces exigences critiques en caractéristiques critiques « Critical To Quality » (CTQ) de type proportions d'alarmes fausses et proportions de détections associées, proportions de localisations conformes en fonction du nombre de modules ou URL ...
- établir des méthodes d'estimation et réglage de ces caractéristiques critiques en fonction des données et modèles de dégradations disponibles.

La **phase** « **Mesurer** » consiste à estimer les CTQ de la version courante de l'algorithme de surveillance considéré selon les méthodes d'estimation établies en phase « Définir ». Cette phase est structurée selon les points suivants :

- estimation des CTQ de la version courante de l'algorithme de surveillance,
- proposition et priorisation de potentiels axes d'amélioration à considérer en phase « Analyser ».

En fin de phase « Mesurer » les performances de l'algorithme de surveillance sont connues. En fonction de celles-ci, des axes d'amélioration sont proposés sous forme de paramètres potentiellement influents sur les CTQ. L'impact de ces axes d'amélioration sur les CTQ est ensuite étudié en phase « Analyser ».

La **phase** « **Analyser** » consiste à quantifier l'impact des améliorations proposées sur les CTQ. Il s'agit d'estimer les CTQ de l'algorithme de surveillance en changeant la configuration de ce dernier. A l'issue de la phase « Analyser », des propositions d'optimisation de l'algorithme sont préparées puis

soumises lors d'une revue inter-modules (réunion avec les experts concernés et les concepteurs du système maturé).

La **phase** « **Optimiser** » répertorie les améliorations à intégrer à l'algorithme pour améliorer ses performances afin de répondre aux exigences. Elle consiste à établir des spécifications de codage associées à chaque amélioration retenue pour permettre l'estimation automatique des CTQ. Les améliorations retenues sont ensuite implémentées sous forme de modules génériques afin de dérouler la phase « Contrôler ».

La **phase** « **Contrôler** » consiste à utiliser les modules génériques pour s'assurer en premier lieu que les performances de l'algorithme incluant les modules génériques sont identiques à celles obtenues en phase analyser. Les modules génériques mis en place permettent :

- l'estimation des CTQ,
- l'acquisition de paramètres sur de nouveaux essais,
- la détermination des seuils de décision en regard des exigences,
- la simulation des dégradations.

Ces modules génériques permettent de réaliser des itérations de maturation de manière automatique. Cela est utile pour un suivi continu des performances des algorithmes mis en exploitation.

Enfin, la phase « Contrôler » spécifie les points à considérer lors de la prochaine itération de maturation pour les prochaines versions de l'algorithme.

ANNEXE - 4 METHODES DE DIAGNOSTIC ET DE PRONOSTIC

1. Introduction

Dans le cadre de la maturation des fonctions de détection et de pronostic des systèmes de surveillance développé par Safran, la première étape de la thèse consiste à identifier les indicateurs permettant de caractériser les performances de ces fonctions et la manière de les évaluer. Cette annexe présente des généralités issues de la littérature concernant des méthodes de diagnostic et de pronostic.

2. Terminologie

Dans un souci d'homogénéité de la terminologie utilisée dans ce mémoire, les différents termes relatifs au diagnostic, pronostic et à la surveillance en règle générale sont définis dans cette section.

Ces définitions sont majoritairement issues de [Afnor, 2010].

Le terme « panne » représente l'état d'un bien inapte à accomplir une fonction requise, excluant l'inaptitude due à la maintenance préventive ou à d'autres actions programmées ou à un manque de ressources extérieures. Il existe plusieurs types de pannes :

- une panne masquée représente une situation dans laquelle une panne existe dans une partie d'un bien, mais ne peut être détectée en raison d'une panne du bien lui-même ou à cause d'une autre panne de cette même partie ou d'une panne d'une autre partie.
- une panne latente représente une panne existante qui n'a pas encore été détectée.
- une panne partielle représente une panne caractérisée par le fait que le bien ne peut accomplir que quelques unes mais pas toutes les fonctions requises. Dans quelques cas il peut être possible d'utiliser le bien avec des performances limitées.

Le terme « défaillance » représente la cessation de l'aptitude d'un bien à accomplir une fonction requise. Après une défaillance, le bien est en panne totale ou partielle. Une défaillance est un événement à distinguer d'une panne qui est un état.

Malgré ces deux premières définitions, il est rare de faire la distinction entre les termes panne et défaillance. Bien souvent, ces termes sont confondus par abus de langage. Cela est peut-être dû au fait qu'à l'issue d'une défaillance il y a une panne et que par conséquent la défaillance et la panne apparaissent de manière presque simultanée.

La discrimination entre les termes « panne » et « défaillance » n'étant pas toujours aisée, ces derniers seront confondus dans le cadre de ce mémoire.

Le terme « dégradation » décrit l'évolution irréversible d'une ou plusieurs caractéristiques d'un bien liée au temps, à la durée d'utilisation ou à une cause externe. Une dégradation peut conduire à la défaillance. L'évolution temporelle d'une dégradation peut être brusque (soudaine) ou progressive (graduelle).

Plusieurs définitions du terme pronostic sont rencontrées dans la littérature. Certaines définitions sont différentes de par leur domaine d'application mais il arrive que pour un même domaine, plusieurs définitions soient utilisées. Le terme pronostic est étroitement lié aux termes prévision et prédiction. En règle générale, les termes prédiction et prévision sont utilisés par les disciplines que sont la météorologie et la finance. La médecine utilise plutôt le terme pronostic. Dans le domaine de la maintenance, le terme prévision est très utilisé par les fiabilistes (prévision du nombre de pannes, prévision des pièces de rechanges...), en revanche, la maintenance basée sur la surveillance (CBM-PHM) des systèmes utilise plutôt le terme pronostic.

Le terme « pronostic » provient du grec progignôskein qui signifie « connaître à l'avance ». Il existe plusieurs définitions de ce terme dans le cadre du PHM. Dans un souci de standardisation le terme pronostic est défini par la norme ISO 13381-1 comme l'estimation de la durée de fonctionnement

avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou plusieurs modes de défaillance [ISO, 2005].

Cette définition associe le pronostic à la notion de durée de vie résiduelle (RUL – Remaining Useful Life) qui représente un enjeu particulier dans le cadre du pronostic industriel. Bien que l'objectif de cette norme soit de partager une définition unique du pronostic, il existe d'autres notions que la durée de vie résiduelle.

Le terme « diagnostic » provient du grec diágnosi : dia - par, à travers, séparation, distinction et gnósi - la connaissance, le discernement. Il signifie donc le fait d'acquérir la connaissance à travers les signes observables. Dans [Afnor, 2010], il est abordé sous le groupe de mots « Diagnostic de panne » et représente les actions menées pour la détection de la panne, sa localisation et l'identification de la cause.

- La « détection » permet de mettre en évidence un dysfonctionnement dans le système et signale la présence d'une dégradation. Une alarme est déclenchée lorsque la valeur du critère d'anormalité (ou indicateur de dégradation) dépasse un seuil.
- La localisation de dégradation, a pour but de classer les dégradations en fonction de leur type et de leur emplacement dans le système. Elle sert à localiser le ou les équipements ou composants incriminés.
- Enfin, l'identification de dégradation vise à caractériser l'amplitude et l'évolution temporelle des dégradations.

Le fait de grouper la détection, la localisation et l'identification par le terme « diagnostic » a été proposé initialement par le comité technique de l'IFAC (International Federation of Automatic Control) SAFEPROCESS [Iserman, 1997] [Darkhovski, 2003] et est englobée par l'appellation FDI (Fault Detection and Isolation).

3. Méthodes de diagnostic

Le diagnostic représente une phase cruciale dans le cadre de la maintenance. C'est à partir des informations fournies par les fonctions de diagnostic que des actions de maintenance sont lancées. Les coûts de maintenance n'étant pas négligeables, le diagnostic se doit d'être le plus performant possible. De nombreux travaux ont été réalisés dans cette perspective. Les premiers travaux ont été initiés par les automaticiens. Cela a donné lieu à plusieurs méthodes de diagnostic de défaillance et de dégradation. Toutes ces méthodes ont pour base les connaissances du système considéré et tiennent compte de sa spécificité et de sa complexité. L'objectif de cette section n'est pas de détailler les différentes méthodes de diagnostic mais de présenter leur classification dans la littérature. Pour ce faire, deux points de vue sont présentés dans la sous-section suivante.

3.1. Classification des méthodes, point de vue n° 1

Le premier point de vue est celui introduit par [Zwingelstein, 1995] qui classifie les méthodes de diagnostic selon deux groupes :

- les méthodes internes et les méthodes externes,
- les méthodes inductives et les méthodes déductives.

3.1.1. Méthodes internes

Les méthodes internes sont dérivées des techniques utilisées par les automaticiens. Elles sont basées sur des modèles physiques ou de comportements validés expérimentalement par les techniques d'identification de paramètres. Le diagnostic est réalisé en suivant en temps réel l'évolution des paramètres ou en utilisant l'inversion de modèles de type « boite noire ». Ces méthodes se regroupent en trois grandes familles :

- **méthodes du modèle** : ces méthodes consistent à comparer les grandeurs déduites d'un modèle représentatif du fonctionnement des différentes entités du processus avec les mesures directement observées sur le processus industriel. La présence d'un écart fournit l'indication qu'en amont du module modélisé une anomalie est en cours d'apparition.
- méthodes d'identification de paramètres : ces méthodes s'appliquent au cas très particulier où l'on souhaite suivre l'évolution de certains paramètres physiques critiques pour le fonctionnement d'un processus et qui ne sont pas mesurables directement (par exemple, mesurer le coefficient d'échange thermique suite à l'encrassement des tubes dans un échangeur de chaleur). Le principe de ces méthodes est d'estimer les paramètres internes physiques à partir de la connaissance des signaux d'entrées et de sorties mesurés sur le processus. Le diagnostic est réalisé par le suivi de l'évolution au cours du temps des paramètres physiques en les comparants à un seuil prédéterminé
- **méthodes d'estimation du vecteur d'état** : ces méthodes sont une généralisation du principe des méthodes d'identification des paramètres en considérant les modèles physiques sous forme d'équations d'état. Le modèle considéré est constitué d'un ensemble de *n* équations différentielles du premier ordre. Les *n* composantes du vecteur d'état forment un espace à *n* dimensions appelé espace d'état. Grâce à cette représentation il est possible de connaitre tous les états internes du processus. Le diagnostic consiste à estimer le vecteur d'état à partir d'un vecteur de mesures. L'analyse des estimations des différentes composantes du vecteur d'état qui ont un sens physique permet la réalisation du diagnostic.

3.1.2. Méthodes externes

Les méthodes externes sont des méthodes soit à base de connaissances, soit des méthodes empiriques et/ou de traitement du signal. Elles supposent qu'aucun modèle n'est disponible pour décrire les relations de cause à effet. La seule connaissance repose sur l'expertise humaine confortée par un solide retour d'expérience. Dans cette catégorie, on retrouve toutes les méthodes basées sur l'intelligence artificielle telles que :

- la reconnaissance des formes : ces techniques sont utilisées après l'interprétation de la part de spécialistes des signatures associées aux défaillances afin de les classer de manière automatique. La reconnaissance des formes se regroupe en deux grandes familles : la reconnaissance statistique (prise en compte de formes définies par des valeurs numériques) et la reconnaissance structurelle (utilisation de grammaire pour la représentation des formes).
- les systèmes experts : un système expert est un outil capable de reproduire les mécanismes cognitifs d'un expert, dans un domaine particulier. Il se compose de trois parties : une base de faits, une base de règles et un moteur d'inférence qui utilise les faits et les règles pour produire de nouveaux faits, jusqu'à parvenir à la réponse à la question experte posée.
- les réseaux de neurones artificiels : un réseau de neurones artificiels est un modèle dont la conception est inspirée du fonctionnement des neurones biologiques. L'objectif des réseaux de neurones est d'opérer rapidement des classifications et d'apprendre à les améliorer. Les paramètres importants de ce modèle sont les coefficients synaptiques, le seuil de chaque neurone ainsi que la façon de les ajuster. Ce sont eux qui déterminent l'évolution du réseau en fonction de ses entrées. Il est nécessaire de choisir un mécanisme permettant de les calculer et de les faire converger vers une valeur assurant une classification aussi proche que possible de l'optimale. Cela est réalisé grâce aux phases d'apprentissage du réseau.

3.1.3. Méthodes inductives

Les méthodes inductives correspondent à une approche montante où l'on identifie toutes les combinaisons d'événements élémentaires possibles qui entraînent la réalisation d'un événement unique indésirable. La méthode de l'arbre de défaillance est une méthode à démarche dite inductive. La méthode de l'arbre de défaillance consiste en la construction d'une structure logique arborescente qui synthétise des séquences de défaillances de composants qui aboutissent à la perte de fonction(s)

principale(s) (ou événement non souhaité). Elle peut être qualitative (identification de scénarii critiques) et/ou quantitative (calcul de la disponibilité et éventuellement de la fiabilité dans le cas de systèmes non réparables).

3.1.4. Méthodes déductives

Les méthodes déductives correspondent à une approche descendante. On part de l'événement indésirable et on recherche ensuite toutes les causes possibles. L'analyse AMDE (Analyse des Modes de Défaillance et de leurs Effets) est une technique déductive qualitative. Elle peut également être quantitative en intégrant une phase d'évaluation de la criticité des défaillances. Cela représente l'analyse AMDEC (Analyse des Modes de Défaillance de leurs Effets et de leurs Criticités). Elle consiste à identifier, au niveau d'un système, les modes potentiels de défaillance de ses équipements, leurs causes et leurs effets. Les étapes de la réalisation de l'AMDEC sont les suivantes :

- réalisation de l'arborescence fonctionnelle de chaque équipement,
- définition des phases de fonctionnement de chaque équipement,
- recherche de tous les modes de défaillance possibles (analyse qualitative),
- recherche des causes et des effets de ces défaillances,
- évaluation de la criticité de ces défaillances (analyse quantitative),
- recherche de mesures correctrices.

3.2. Classification des méthodes, point de vue n° 2

Le second point de vue correspond à celui de [Venkatasubramanian, 2003a, 2003b, 2003c] qui classifie les méthodes de diagnostic selon trois groupes :

- les méthodes basées sur des modèles quantitatifs,
- les méthodes basées sur des modèles qualitatifs,
- les méthodes basées sur des données historiques.

Cette classification s'appuie sur le type de connaissance a priori du système. La connaissance a priori nécessaire pour le diagnostic est l'ensemble des dégradations ainsi que leurs relations avec les observations. Une fonction de diagnostic peut avoir les relations entre dégradations et observations explicitement (comme dans un tableau), ou indirectement. Cette connaissance a priori basée sur un modèle peut être de natures quantitative ou qualitative.

3.2.1. Méthodes basées sur des modèles quantitatifs

Les méthodes basées sur des modèles quantitatifs comparent les valeurs des variables observées avec les valeurs calculées en utilisant un modèle qui met en rapport les variables du système. La comparaison des valeurs réelles à celles calculées génère des résidus. Si les résidus dépassent un seuil, la présence d'une dégradation est alors détectée.

3.2.2. Méthodes basées sur des modèles qualitatifs

Les méthodes basées sur des modèles qualitatifs fonctionnent sur le même principe que celles basées sur des modèles quantitatifs, mais la relation entre les descripteurs est exprimée par des fonctions qualitatives. Ces méthodes ne sont pas basées sur l'écriture de lois physiques, par conséquent leurs performances dépendent fortement de la connaissance de l'expert qui formalise la relation entre les variables du système.

3.2.3. Méthodes basées sur des données historiques

Les industries disposent de plus en plus d'un vaste historique de comportements de systèmes incluant les comportements des variables dans différents modes (nominal, dégradé, démarrage, ralenti sol, croisière...). L'objectif de ces méthodes est d'extraire les informations pertinentes pour le diagnostic et ainsi les caractériser à partir de ces bases de données. Il ne s'agit donc pas de méthodes à base de modèle dans le sens où la théorie ne s'appuie pas sur une modélisation physique du système.

La Figure 85 représente une classification des méthodes de diagnostic selon le point de vue de [Venkatasubramanian, 2003a]. Une liste non exhaustive de techniques y est évoquée.



Méthodes de diagnostic

Figure 85 : Classification des méthodes de diagnostic selon [Venkatasubramanian, 2003a]

CONFIDENTIEL INDUSTRIE

4. Méthodes de pronostic

Le besoin de connaître le futur est une problématique en lien avec un nombre important de disciplines scientifiques. Les applications sont diverses et variées :

- en océanographie (prévision des courants, suivi et prévision des marées noires...) [Nodet, 2010],
- en agronomie (prévision des irrigations d'appoint...) [Nodet, 2010],
- en hydrologie (prévision des crues, niveau des nappes souterraines) [Krzysztofowicz, 2001],
- en météorologie (prévision des températures, prévision des précipitations, prévision de la vitesse des vents... [Atger, 2000], prévision de la qualité de l'air [Stoltz, 2010], prévision des pics d'ozone [Besse, 2007]),
- en finance (prévision du chiffre d'affaire, prévision des ventes, prévision des cours des valeurs de la bourse...) [Mayorquim, 2004],
- dans le domaine de la production d'énergie (prévision de la consommation électrique) [Devaine, 2010].

Différentes méthodes sont utilisées pour ces différentes applications : modèles paramétriques, lissage exponentiel, régression constante, régression stochastique, modèles autorégressifs, modèles non paramétriques, filtrage de Kalman, méthodes Bayésiennes, méthodes à noyaux...

Les différents domaines évoqués jusqu'à présent utilisent majoritairement le terme prévision. Le terme pronostic a longuement été utilisé dans le domaine médical avant d'être utilisé dans le domaine industriel.

Le pronostic médical consiste à évaluer l'évolution de la maladie d'un patient en se basant sur l'évolution observée, pour la même maladie, chez d'autres patients. Des modèles de pronostic tels que les arbres de décision, les processus de Markov, les réseaux de neurones, les algorithmes génétiques sont utilisés [Lucas, 1999]. La principale difficulté réside dans la capacité à caractériser l'évolution de la maladie en tenant compte de l'hétérogénéité des patients. Une fois l'évolution caractérisée, le résultat du pronostic est souvent formulé sous la forme d'une probabilité définie comme la probabilité qu'un patient atteigne un état maladif avancé à une date future.

La transition du domaine médical vers le domaine industriel est aisée dans le sens où l'objectif du pronostic industriel est de statuer sur le devenir d'un système en se basant sur l'évolution de son état de santé. Il existe plusieurs déclinaisons du pronostic industriel dans le cadre de la maintenance des systèmes pour des applications aéronautique, aérospatiale, électronique ou automobile [Saxena, 2008]. D'après [Jardine, 2006], quel que soit le domaine d'application, il existe principalement deux mesures ou indicateurs de pronostic. La première mesure consiste à prédire le temps restant avant la défaillance d'un composant ou d'un système connaissant les conditions de fonctionnement passées et actuelles. Cette mesure est communément appelée Remaining Useful Life (RUL). La seconde mesure consiste à prédire la probabilité qu'un composant ou un système fonctionne sans défaillance pendant un horizon donné connaissant les conditions de fonctionnement passées et actuelles. Dans la littérature, la prédiction du temps de vie résiduel est considérée dans la majorité des cas. Le pronostic probabiliste n'est que très peu représenté.

Quelle que soit la nature du pronostic réalisé (déterministe ou probabiliste), le choix de la méthode de pronostic adéquate à un problème est conditionné par différents critères. Plusieurs classifications des méthodes de pronostic ont été proposées dans la littérature afin de mettre en avant les critères permettant leur choix. Certaines classifications sont présentées en sous-section suivante.

4.1. Classification des méthodes

Comme pour les méthodes de diagnostic, les méthodes de pronostic peuvent être classifiées en fonction de différents critères. [Vasile, 2008] a proposé de classifier les méthodes de pronostic en fonction de leurs entrées. Cette classification (Figure 86) donne lieu à trois catégories de méthodes de
pronostic selon leur orientation : données, connaissances et informations. Les termes utilisés sont décrits par [Vasile, 2008] comme suit :

- les données sont des éléments ayant une signification qu'après avoir été interprétées,
- une information est un ensemble structuré de données ayant une signification,
- une connaissance est une information ou un ensemble d'informations dépendant d'un contexte et permettant la capacité d'action.

L'objectif de cette classification est de proposer un cadre permettant le choix de la méthode de pronostic adéquate en fonction des spécifications dans un contexte industriel.



Méthodes de pronostic

Figure 86 : Classification des méthodes de pronostic selon [Vasile, 2008]

[Jardine, 2006] a proposé une classification des méthodes de pronostic en fonction de la nature du pronostic réalisé (sortie déterministe ou sortie probabiliste). Le pronostic probabiliste étant peu présent dans la littérature, la classification proposée a porté sur le pronostic déterministe et se fait selon trois approches : les approches statistiques, les approches basées sur l'intelligence artificielle et les approches basées sur des modèles.

Cette classification correspond à celle de [Lebold, 2001] sous la terminologie suivante : les approches basées sur l'expérience, les approches basées sur les données et les approches basées sur les modèles. [Byington, 2002] utilise la même classification. La Figure 87 représente la classification de ces approches en fonction de leur domaine d'applicabilité, de leur complexité, de leur précision et de leur coût.



Figure 87 : Classification des méthodes de pronostic selon [Lebold, 2001]

Les principes des approches relatives à cette classification sont décrits dans les paragraphes suivants [Lebold, 2001] [Byington, 2002] [Vachtsevanos, 2006].

4.2. Approches basées sur l'expérience

Les approches de pronostic basées sur l'expérience sont basées sur la formalisation de mécanismes physiques de dégradation (détérioration) de composants ou modules. Des modèles fiabilistes (loi normale, loi log-normale, loi exponentielle ou loi de Weibull...) ou stochastiques (processus de Markov, processus de Poisson, processus Gamma, processus de Wiener...) qui permettent de caractériser l'évolution de l'état de santé du composant ou module sont utilisés en s'appuyant sur le retour d'expérience et ou sur l'avis d'expert.

Dans ces approches, la détérioration ou dégradation est souvent modélisée sous forme probabiliste. Le pronostic fourni est exprimé sous forme de MTBF (Mean Time Between Failure), de MTTF (Mean Time To Failure) ou d'une probabilité de franchissement d'un seuil de défaillance au bout d'un horizon (temporel) donné.

Un autre exemple, moins répandu, de pronostic basé sur l'expérience est le raisonnement à base de cas [BER 06]. Le but de cette méthode est de comparer la situation dans laquelle on se trouve à une situation similaire résolu dans le passé pour réaliser le pronostic.

Les approches de pronostic basées sur l'expérience ont comme principaux avantages d'être simples et peu couteuses. En revanche, elles sont moins précises que les deux approches suivantes.

4.3. Approches basées sur les données

Dans la littérature, les approches de pronostic basées sur les données sont également appelées « guidées par les données ». Ces approches sont utilisées lorsque des données avec et sans dégradation sont disponibles mais sans connaissance physique de la dégradation (détérioration). Elles s'appuient sur des données mesurées directement sur le système ou sur des indicateurs de dégradation établis à partir de ces mesures. L'objectif de ces approches est de caractériser l'évolution d'une dégradation (détérioration) en se basant uniquement sur les données disponibles. Des méthodes par analyse de tendance, par apprentissage (intelligence artificielle) et par estimation d'état sont généralement

utilisées. Ces méthodes ont été décrites dans le cadre du diagnostic. Elles sont utilisées cette fois-ci dans le cadre du pronostic.

Les approches de pronostic basées (guidées) sur les données sont en général plus précises que les précédentes mais plus coûteuse et plus complexes.

4.4. Approches basées sur les modèles

Le terme « modèle » utilisé pour nommer la dernière catégorie d'approches sous-entend modèle physique. Il arrive souvent, dans la littérature, de rencontrer cette catégorie d'approches sous la dénomination « approches basées sur les modèles physiques ».

Comme l'indique la dénomination ci-dessus, ces approches s'appuient sur des modèles physiques des composants ou des systèmes permettant de caractériser l'évolution d'une dégradation de manière analytique.

L'évolution de la dégradation est décrite selon un modèle établi en s'appuyant sur les mécanismes physique du composant ou du système. Pour réaliser des prédictions, il suffit d'agir sur les paramètres du modèle.

Ce type d'approches est très utilisé pour la modélisation du mécanisme de dégradation de composant. La modélisation d'un système de manière globale représente une tâche beaucoup plus ardue.

Les approches de pronostic basées sur les modèles représentent les approches les plus précises car elles modélisent le composant ou le système de manière très fine. En revanche, ces approches sont très couteuses.

ANNEXE - 5 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION SUR L'ENSEMBLE DES MOTEURS, DISTRIBUTION DES SCORES D'ANORMALITE MOYENNE SUR N = 5 DEMARRAGES (AVEC ET SANS DEGRADATION)

1. Dégradations du compresseur d'air

La Figure 88 représente les distributions du score d'anormalité moyenné sur n=5 démarrages successivement sans dégradation et avec les trois degrés d'intensité pour une baisse de pression APU. Il apparait que, malgré le fait que le score d'anormalité soit moyenné, la discrimination entre l'état sain et les différentes intensités de dégradation n'est pas aisée. L'intensité faible de la dégradation APU est quasiment confondue avec l'état sain.



Figure 88 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une baisse de pression APU.

2. Dégradations du bloc hydromécanique

La Figure 89 représente les distributions du score d'anormalité moyenné sur n=5 démarrages successivement sans dégradation et avec les trois degrés d'intensité pour une hausse de débit carburant. Contrairement à la dégradation de l'APU, la discrimination entre l'état sain et les différentes intensités de dégradation semble à première vue plus aisée.



Figure 89 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une hausse de débit carburant.

La Figure 90 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages successivement sans dégradation et avec les trois degrés d'intensité pour une baisse de débit carburant. Contrairement aux deux figures précédentes, il apparait une nette discrimination entre l'état sain et l'intensité la plus forte pour une baisse de débit carburant.



Figure 90 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une baisse de débit carburant.

ANNEXE - 6 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION SUR UN MEME TYPE DE MOTEUR, DISTRIBUTION DES SCORES D'ANORMALITE MOYENNE SUR N = 5 DEMARRAGES (AVEC ET SANS DEGRADATION)

1. Dégradations du compresseur d'air

La Figure 91 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages, après apprentissage des modèles sur un même type de moteur, successivement sans dégradation et avec les trois degrés d'intensité pour une baisse de pression APU.



Figure 91 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une baisse de pression APU, modèles appris par type de moteur.

2. Dégradations du bloc hydromécanique

La Figure 92 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages, après apprentissage des modèles sur un même type de moteur, successivement sans dégradation et avec les trois degrés d'intensité pour une hausse de débit carburant.



Figure 92 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une hausse de débit carburant, modèles appris par type de moteur.

La Figure 93 représente les distributions du score d'anormalité moyenné sur n = 5 démarrages, après apprentissage des modèles sur un même type de moteur, successivement sans dégradation et avec les trois degrés d'intensité pour une baisse de débit carburant.



Figure 93 : Distributions des scores d'anormalité moyennés sur n = 5 démarrages avec et sans dégradation pour une baisse de débit carburant, modèles appris par type de moteur.

ANNEXE - 7 APPROCHE MOYENNE MOBILE, APPRENTISSAGE DES MODELES DE NORMALISATION PAR MOTEUR, RESULTATS POUR N = 5

1. Moteur 1

Dégradation	P (Sain Détection)(%)	$\widehat{\text{PoD}}(\%)$	Seuil de détection
APU : pression nominale -11,7%	1,18	85	
APU : pression nominale -23,4%	1	100	8,2
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,3	76,5	
HMU : Débit carburant +10%	1,12	89	8,57
HMU : Débit carburant +13%	1,13	88,5	
HMU : Débit carburant -7%	1,35	74	
HMU : Débit carburant -10%	1,22	89	8,47
HMU : Débit carburant -13%	1,13	88,5	
SAV : Ouverture de la vanne +2s	48	1	
SAV : Ouverture de la vanne +4s	1,06	94,5	8,59
SAV : Ouverture de la vanne +8s	1	100	

Tableau 21 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 1, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

2. Moteur 2

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	6,86
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,03	97	
HMU : Débit carburant +10%	1	100	7,12
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	1,1	90,9	
HMU : Débit carburant -10%	1	100	7,06
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	7,5	12,5	7,13
SAV : Ouverture de la vanne +8s	1	100	

Tableau 22 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 2, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	$\widehat{\text{PoD}}(\%)$	Seuil de détection
APU : pression nominale -11,7%	9	10,2	
APU : pression nominale -23,4%	1,02	98	7,31
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,7	57	
HMU : Débit carburant +10%	1,2	83,8	7,68
HMU : Débit carburant +13%	1,01	98,6	
HMU : Débit carburant -7%	1,4	70,8	
HMU : Débit carburant -10%	1,2	84	7,6
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	5	19	
SAV : Ouverture de la vanne +4s	1	100	7,69
SAV : Ouverture de la vanne +8s	1	100	

Tableau 23 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 3, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

4. Moteur 4

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	6,6
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,7	58,5	
HMU : Débit carburant +10%	1,05	95,2	6,84
HMU : Débit carburant +13%	1	99,6	
HMU : Débit carburant -7%	1,9	49,8	
HMU : Débit carburant -10%	1,2	85	6,78
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	43,5	1,3	
SAV : Ouverture de la vanne +4s	1	100	6,85
SAV : Ouverture de la vanne +8s	1	100	

Tableau 24 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 4, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	2,4	40	
APU : pression nominale -23,4%	1	100	7,69
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,56	63	
HMU : Débit carburant +10%	1,12	89	8,05
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	1,7	57	
HMU : Débit carburant -10%	1,3	77	7,96
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	1,6	5,3	
SAV : Ouverture de la vanne +4s	1,4	73	8,07
SAV : Ouverture de la vanne +8s	1	100	

Tableau 25 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 5, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

6. Moteur 6

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	#	0	
APU : pression nominale -23,4%	1	100	8,16
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	2,13	46,3	
HMU : Débit carburant +10%	1,47	67,3	8,5
HMU : Débit carburant +13%	1,08	92,2	
HMU : Débit carburant -7%	1,63	60,9	
HMU : Débit carburant -10%	1,59	62,4	8,42
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	50,9	0,97	
SAV : Ouverture de la vanne +4s	1	100	8,52
SAV : Ouverture de la vanne +8s	1	100	

Tableau 26 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 6, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	$\widehat{\text{PoD}}(\%)$	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	15,34
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	2,2	44	
HMU : Débit carburant +10%	1,07	93	16,43
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	4	24	
HMU : Débit carburant -10%	1,47	67	16,18
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,08	91	16,48
SAV : Ouverture de la vanne +8s	1	100	1

Tableau 27 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 7, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

8. Moteur 8

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	2,24	44	
APU : pression nominale -23,4%	1	100	13,66
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,12	89	
HMU : Débit carburant +10%	1	100	14,51
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	1,2	82,8	
HMU : Débit carburant -10%	1	100	14,32
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	1,7	59	
SAV : Ouverture de la vanne +4s	1	100	14,55
SAV : Ouverture de la vanne +8s	1	100	

Tableau 28 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 8, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P(Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	7,8
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,35	73,6	
HMU : Débit carburant +10%	1,04	86	8,23
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	1,7	57	
HMU : Débit carburant -10%	1,12	89	8,13
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	6,5	14,5	
SAV : Ouverture de la vanne +4s	1	100	8,25
SAV : Ouverture de la vanne +8s	1	100	

Tableau 29 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 9, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

10. Moteur 10

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	7,26
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	1,08	92,9	
HMU : Débit carburant +10%	1	100	7,56
HMU : Débit carburant +13%	1	100	
HMU : Débit carburant -7%	1,3	77	
HMU : Débit carburant -10%	1	100	7,49
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	36	1,8	
SAV : Ouverture de la vanne +4s	1,2	84	7,57
SAV : Ouverture de la vanne +8s	1	100	

Tableau 30 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , scores d'anormalité moyennés sur n = 5 démarrages, modèles appris sur 50% des démarrages du moteur 10, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

ANNEXE - 8 APPROCHE K PARMI N, APPRENTISSAGE DES MODELES DE NORMALISATION PAR MOTEUR, RESULTATS POUR K = 4 ET N = 5

1. Moteur 1

Dégradation	P (Sain Détection)(%)	$\widehat{\text{PoD}}(\%)$	Seuil de détection
APU : pression nominale -11,7%	1,95	50,27	
APU : pression nominale -23,4%	1	100	8,22
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	18,62	4,37	
HMU : Débit carburant +10%	13,23	6,56	12,75
HMU : Débit carburant +13%	4,59	20,76	
HMU : Débit carburant -7%	47,78	1,09	
HMU : Débit carburant -10%	26,79	2,73	12,18
HMU : Débit carburant -13%	4,37	21,86	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	#	0	12,86
SAV : Ouverture de la vanne +8s	1	100	

Tableau 31 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 1, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

2. Moteur 2

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1,33	74,04	
APU : pression nominale -23,4%	1	100	7,51
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	5,06	18,75	
HMU : Débit carburant +10%	1,29	76,44	9,29
HMU : Débit carburant +13%	1	98,56	
HMU : Débit carburant -7%	9,01	10,1	
HMU : Débit carburant -10%	1,16	85,58	8,81
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	#	0	9,39
SAV : Ouverture de la vanne +8s	1,06	93,27	

Tableau 32 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 2, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	#	0	
APU : pression nominale -23,4%	5,25	18,06	10,6
APU : pression nominale -35%	1,25	79,17	
HMU : Débit carburant +7%	#	0	
HMU : Débit carburant +10%	#	0	12,49
HMU : Débit carburant +13%	19,35	4,17	
HMU : Débit carburant -7%	#	0	
HMU : Débit carburant -10%	21,26	3,7	12
HMU : Débit carburant -13%	4,58	20,83	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,83	53,7	12,59
SAV : Ouverture de la vanne +8s	1	100	

Tableau 33 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 3, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

4. Moteur 4

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1,017	97,38	
APU : pression nominale -23,4%	1	100	6,33
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	11,29	7,86	
HMU : Débit carburant +10%	2,56	37,99	7,6
HMU : Débit carburant +13%	1,42	69,43	
HMU : Débit carburant -7%	10,27	8,73	
HMU : Débit carburant -10%	3,74	25,76	7,23
HMU : Débit carburant -13%	1,01	98,25	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,32	74,67	7,69
SAV : Ouverture de la vanne +8s	1	100	

Tableau 34 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 4, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	$\widehat{\text{PoD}}(\%)$	Seuil de détection
APU : pression nominale -11,7%	7,53	12,28	
APU : pression nominale -23,4%	1	100	8,09
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	25,48	2,92	
HMU : Débit carburant +10%	14,6	5,85	13,56
HMU : Débit carburant +13%	1,43	69,01	
HMU : Débit carburant -7%	#	0	
HMU : Débit carburant -10%	46,09	1,17	12,75
HMU : Débit carburant -13%	1,84	53,22	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	#	0	13,72
SAV : Ouverture de la vanne +8s	1,63	60,23	

Tableau 35 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 5, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

6. Moteur 6

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	#	0	
APU : pression nominale -23,4%	1	100	8,44
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	29,08	2,44	
HMU : Débit carburant +10%	20,4	3,9	9,72
HMU : Débit carburant +13%	5,12	18,53	
HMU : Débit carburant -7%	15,71	5,37	
HMU : Débit carburant -10%	7,31	12,68	9,41
HMU : Débit carburant -13%	1,4	70,24	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,08	91,22	9,79
SAV : Ouverture de la vanne +8s	1	100	

Tableau 36 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 6, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	15,1
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	22,28	3,49	
HMU : Débit carburant +10%	1,88	52,33	16,5
HMU : Débit carburant +13%	1	98,84	
HMU : Débit carburant -7%	#	0	
HMU : Débit carburant -10%	4,33	22,09	16,16
HMU : Débit carburant -13%	1,03	96,51	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,69	58,14	16,57
SAV : Ouverture de la vanne +8s	1	100	

Tableau 37 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 7, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

8. Moteur 8

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	#	0	
APU : pression nominale -23,4%	1	100	18,07
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	31,74	2,15	
HMU : Débit carburant +10%	4,67	20,43	20,4
HMU : Débit carburant +13%	1,05	94,62	
HMU : Débit carburant -7%	48,19	1,08	
HMU : Débit carburant -10%	11,73	7,53	19,85
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1,19	82,8	20,51
SAV : Ouverture de la vanne +8s	1	100	

Tableau 38 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 8, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1,18	83,64	
APU : pression nominale -23,4%	1	100	9,3
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	8,4	10,91	
HMU : Débit carburant +10%	5,21	18,18	10,19
HMU : Débit carburant +13%	1,21	81,82	
HMU : Débit carburant -7%	18,03	4,55	
HMU : Débit carburant -10%	15,49	5,45	9,96
HMU : Débit carburant -13%	1,1	90	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	1	100	10,24
SAV : Ouverture de la vanne +8s	1	100	

Tableau 39 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 9, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

10. Moteur 10

Dégradation	P (Sain Détection)(%)	PoD (%)	Seuil de détection
APU : pression nominale -11,7%	1	100	
APU : pression nominale -23,4%	1	100	9,6
APU : pression nominale -35%	1	100	
HMU : Débit carburant +7%	#	0	
HMU : Débit carburant +10%	2,56	38,05	11,17
HMU : Débit carburant +13%	1,02	97,35	
HMU : Débit carburant -7%	15,85	5,31	
HMU : Débit carburant -10%	8	11,5	10,81
HMU : Débit carburant -13%	1	100	
SAV : Ouverture de la vanne +2s	#	0	
SAV : Ouverture de la vanne +4s	#	0	11,24
SAV : Ouverture de la vanne +8s	2,35	41,59	

Tableau 40 : $\hat{P}(Sain|Détection)$ et \widehat{PoD} , modèles appris sur 50% des démarrages du moteur 10, $P(Sain|Détection)_{exigée} = 1\%$ et $PoD_{exigée} > 99\%$.

ANNEXE - 9 PRONOSTIC DE CONSOMMATIONS ANORMALES, DONNEES ET RESULTATS

1. Moteur 1 avion 1



Figure 94 : Moteur 1 avion 1, trajectoires pseudo observées et performance de pronostic.



Figure 95 : Moteur 2 avion 1, trajectoires pseudo observées et performance de pronostic.

3. Moteur 1 avion 2



Moteur 1 avion 2 : Trajectoire pseudo observées





Figure 97 : Moteur 2 avion 2, trajectoires pseudo observées et performance de pronostic.

5. Moteur 1 avion 3



Moteur 1 avion 3 : Trajectoire pseudo observées

Figure 98 : Moteur 1 avion 3, trajectoires pseudo observées et performance de pronostic.



Figure 99 : Moteur 2 avion 3, trajectoires pseudo observées et performance de pronostic.

7. Moteur 2 avion 4



Moteur 2 avion 4 : Trajectoire pseudo observées





Figure 101 : Moteur 2 avion 5, trajectoires pseudo observées et performance de pronostic.

Ouadie HMAD Doctorat : Optimisation et Sûreté des Systèmes

Année 2013

Evaluation et optimisation des performances de fonctions pour la surveillance de turboréacteurs

Cette thèse concerne les systèmes de surveillance des turboréacteurs. Le développement de tels systèmes nécessite une phase d'évaluation et d'optimisation des performances, préalablement à la mise en exploitation. Le travail a porté sur cette phase, et plus précisément sur les performances des fonctions de détection et de pronostic de deux systèmes. Des indicateurs de performances associés à chacune de ces fonctions ainsi que leur estimation ont été définis. Les systèmes surveillés sont d'une part la séquence de démarrage pour la fonction de détection et d'autre part la consommation d'huile pour la fonction de pronostic. Les données utilisées venant de vols en exploitation sans dégradations, des simulations ont été nécessaires pour l'évaluation des performances. L'optimisation des performances de détection a été obtenue par réglage du seuil sur la statistique de décision en tenant compte des exigences des compagnies aériennes exprimées en termes de taux de bonne détection et de taux d'alarme fausse. Deux approches ont été considérées et leurs performances ont été comparées pour leurs meilleures configurations. Les performances de pronostic de surconsommations d'huile, simulées à l'aide de processus Gamma, ont été évaluées en fonction de la pertinence de la décision de maintenance induite par le pronostic. Cette thèse a permis de quantifier et d'améliorer les performances des fonctions considérées pour répondre aux exigences. D'autres améliorations possibles sont proposées comme perspectives pour conclure ce mémoire.

Mots clés : systèmes d'aide à la décision - avions, turboréacteurs - prise de décision (statistique) valeurs extrêmes, théorie des - fiabilité, méthodes statistiques.

Evaluation and Optimization of Function Performances for the Monitoring of Turbojet Engines

This thesis deals with monitoring systems of turbojet engines. The development of such systems requires a performance evaluation and optimization phase prior to their introduction in operation. The work has been focused on this phase, and more specifically on the performance of the detection and the prognostic functions of two systems. Performances metrics related to each of these functions as well as their estimate have been defined. The monitored systems are, on the one hand, the start sequence for the detection function and on the other hand, the oil consumption for the prognostic function. The used data come from flights in operation without degradation, simulations of degradation were necessary for the performance assessment. Optimization of detection performance was obtained by tuning a threshold on the decision statistics taking into account the airlines requirements in terms of good detection rate and false alarm rate. Two approaches have been considered and their performances have been compared for their best configurations. Prognostic performances of over oil consumption, simulated using Gamma processes, have been assessed on the basis of the relevance of maintenance decision induced by the prognostic. This thesis has allowed quantifying and improving the performance of the two considered functions to meet the airlines requirements. Other possible improvements are proposed as prospects to conclude this thesis.

Keywords: decision support systems - airplanes, turbojet engines - statistical decision - extreme value theory – reliability (engineering), statistical methods.

Thèse réalisée en partenariat entre :





Ecole Doctorale "Sciences et Technologies"