

## TABLE DES MATIÈRES

	Page
INTRODUCTION .....	1
CHAPITRE 1 REVUE DE LITTÉRATURE .....	7
1.1 Système de pronostic et son rôle dans la gestion des actifs .....	7
1.2 Estimation de la probabilité de défaillance d'un actif ou d'un système d'actifs .....	11
1.3 Les systèmes de pronostic de défaillance .....	14
1.4 Approches et classification des systèmes de pronostic .....	21
1.4.1 Niveau d'étude des systèmes de pronostic .....	21
1.4.2 Approches des systèmes de pronostic .....	23
1.4.3 Approche de pronostic basée sur les modèles de fiabilité .....	26
1.4.4 Approche de pronostic basée sur les données .....	28
1.4.5 Approche de pronostic basée sur la physique de défaillance (PoF) .....	35
1.5 Approche de maintenance prévisionnelle (aide à la décision post-pronostic) .....	42
1.6 Métriques de validation des modèles de pronostic .....	47
1.6.1 Classification fonctionnelle des métriques de performance des systèmes de pronostic .....	47
1.6.2 Les métriques de performances du pronostic <i>Offline</i> .....	50
1.6.2.1 Les métriques basées sur la précision (anglais: <i>accuracy</i> ) et la justesse (anglais: <i>precision</i> ): .....	50
1.6.2.2 Les métriques issues du diagnostic .....	52
1.6.2.3 Les métriques de performance des algorithmes de pronostic ....	54
1.6.3 Les métriques de performances <i>Online</i> : .....	64
CHAPITRE 2 MÉTHODOLOGIE DE RECHERCHE .....	67
2.1 Introduction .....	67
2.2 Structure et contributions scientifiques .....	69
CHAPITRE 3 APPROCHE DE PRONOSTIC MULTIMODES DE DÉFAILLANCE POUR LES ÉQUIPEMENTS COMPLEXES .....	71
3.1 Hypothèses du modèle fondé sur des connaissances d'experts .....	71
3.2 Algorithmes de diagnostic .....	78
3.2.1 Détection des défauts : Algorithmes de détection des états physiques .....	79
3.2.2 Estimation de l'état : Algorithmes de détection et d'identification de l'état d'avancement des mécanismes de défaillance .....	80
3.3 Algorithme de pronostic .....	83
3.3.1 Algorithme de propagation des mécanismes de défaillance .....	84
3.3.2 Algorithme de pronostic des modes de défaillance .....	86
3.4 Cas d'application industrielle: cas d'étude des stators hydro-électriques .....	88
3.4.1 Contexte industriel .....	89
3.4.2 Construction du modèle pour les stators des groupes turbine-alternateurs	90

3.4.2.1	Construction du modèle de dégradation multi-états du stator hydro-électrique .....	90
3.4.2.2	Quantification de l'incertitude des paramètres génériques du modèle: temps de transition <i>TFM<sub>jeu</sub>, ev</i> .....	93
3.4.3	Application du modèle et évaluation de sa performance .....	95
3.5	Discussion .....	105
3.6	Conclusion .....	107

#### CHAPITRE 4 APPROCHE DE MAINTENANCE PRÉDICTIVE POUR ÉQUIPEMENT COMPLEXE BASÉE SUR LES RÉSULTATS DE PRONOSTIC .....109

4.1	Hypothèses du modèle de maintenance prévisionnelle .....	109
4.2	Algorithmes de diagnostic .....	110
4.3	Algorithmes de propagation des mécanismes de défaillance pour la maintenance prévisionnelle.....	110
4.3.1	Propagation des mécanismes de défaillance vers les états ciblés pour la maintenance .....	110
4.3.2	Propagation des mécanismes de défaillance vers les modes de défaillance liés aux états ciblés pour la maintenance prévisionnelle .....	112
4.4	Pronostic de l'occurrence des états ciblés pour la maintenance prévisionnelle et des modes de défaillance qui y sont associés.....	114
4.5	De la propagation du mécanisme de défaillance à la maintenance prévisionnelle ....	115
4.6	Étude de cas : Stator d'alternateur hydro-électrique.....	117
4.6.1	Tâches de maintenances associées aux états ciblés .....	117
4.6.2	Application du modèle de pronostic .....	118
4.6.3	Validation des algorithmes de pronostic pour la maintenance prévisionnelle.....	125
4.7	Discussion.....	128
4.8	Conclusions.....	129

#### CHAPITRE 5 ÉVALUATION DE LA PERFORMANCE DES ALGORITHMES DE PRONOSTIC POUR LES ÉQUIPEMENTS RÉPARABLES DANS UN CONTEXTE INDUSTRIEL .....131

5.1	Hypothèses sous-jacentes pour l'évaluation des performances des algorithmes de pronostic pour les systèmes réparables .....	131
5.2	Performance <i>off-line</i> des algorithmes de pronostic pour les systèmes réparables ....	132
5.2.1	Définition de la fonction <b>TTF</b> pour les systèmes réparables .....	132
5.2.2	Définition de la zone de prédiction acceptable selon le contexte opérationnel.....	134
5.3	Performance <i>on-line</i> des algorithmes de pronostic pour les systèmes réparables ....	139
5.4	Études de cas : pronostic de défaillance des alternateurs hydro-électriques .....	141
5.4.1	Définition du cadre de validation pour le contexte opérationnel des alternateurs hydro-électriques.....	141
5.4.2	Application du cadre de validation sur les résultats de pronostic des défaillances historiques.....	142

5.5	Discussion.....	145
5.6	Conclusions.....	146
CHAPITRE 6 PROCESSUS D'ACTUALISATION DES MODÈLES DE PRONOSTIC POUR UNE APPLICABILITÉ LONG-TERME .....		
		149
6.1	Facteurs d'influence pouvant avoir un impact sur les performances d'un algorithme de pronostic à long terme.....	149
6.1.1	Nouvelles données disponibles.....	149
6.1.2	Nouvelles connaissances disponibles .....	150
6.1.3	Nouvelle technologie disponible.....	151
6.1.4	Évolution des infrastructures informatiques .....	151
6.1.5	Évolution du contexte opérationnel .....	151
6.2	Processus d'actualisation .....	152
6.3	Conclusions.....	154
CONCLUSION.....		
		155
Discussion générale .....		
		155
Contributions scientifiques .....		
		157
RECOMMANDATIONS .....		
		159
Défis futurs et limites de la méthodologie .....		
		159
Recherches futures .....		
		159
ANNEXE I EXTRAITS DES PUBLICATIONS SCIENTIFIQUES AVEC COMITÉ DE LECTURE RELATIVE AUX TRAVAUX DE RECHERCHE.....		
		165
BIBLIOGRAPHIE.....		
		173



## LISTE DES TABLEAUX

	Page
Tableau 2.1	Processus général du pronostic .....19
Tableau 2.2	Résumé des approches de pronostic existantes.....25
Tableau 2.3	Évaluations des besoins et des caractéristiques des approches de pronostic (Javed et al., 2017) .....25
Tableau 2.4	Forces et faiblesses des principaux algorithmes de détection de défauts par apprentissage (Liu et al., 2018) .....31
Tableau 2.5	Performances des principaux algorithmes de détection de défauts par apprentissage (Liu et al., 2018).....31
Tableau 2.6	Principales méthodes des approches basées sur les données utilisées pour le pronostic (Peng et al., 2010).....32
Tableau 2.7	Analyse des méthodes de pronostic basées sur les données (Atamuradov et al., 2017a) .....33
Tableau 2.8	Métriques basées sur la précision (anglais: <i>accuracy</i> ) et la justesse (anglais: <i>precision</i> ) (Drucker).....51
Tableau 2.9	Métriques de performances statistiques des systèmes de diagnostic (Drucker).....53
Tableau 2.10	Métriques de performances statistiques des systèmes diagnostics (Drucker).....58
Tableau 2.11	Métriques de performances utilisées par Baraldi et al. (Baraldi et al., 2013).....59
Tableau 2.12	Métriques utilisées par Son et al. (Son et al., 2013) .....60
Tableau 2.13	Métriques pour un système d'actif utilisé par Son et al. (Son et al., 2013).....61
Tableau 2.14	Illustration de métriques simples proposées par Michael E. Sharp (Sharp, 2013).....62
Tableau 2.15	Bilan des métriques offline et leur utilisation selon les types d'approches utilisées (Saxena et al., 2014) .....64

Tableau 2.16	Métriques de performance online (Saxena et al., 2014) .....	65
Tableau 3.1	Liste des publications scientifiques produites durant la recherche .....	68
Tableau 3.2	Explication détaillé de la structure de la méthodologie de recherche.....	70
Tableau 4.1	Hypothèses sur la propagation des mécanismes de défaillance et leurs interprétations dans la théorie des graphes .....	76
Tableau 5.1	États physiques ciblés pour la maintenance prévisionnelle .....	117
Tableau 5.2	Tâches de maintenance associée aux états ciblés <i>vMnetarget</i> et leur potentiel effet sur le système .....	118
Tableau 5.3	Historique des mesures, inspections et actions de maintenance du stator de l'alternateur A .....	119
Tableau 5.4	États physiques actifs en 2012 sur le stator de l'alternateur A et leurs intervalles d'activation $K_E$ .....	119
Tableau 5.5	Intervalles de confiance des temps nécessaires pour atteindre le TTE ( <i>vTTEetarget2012</i> ) pour chaque état physique ciblé en 2012 .....	122
Tableau 5.6	Prédictions des intervalles de confiance à 50% pour l'occurrence du mode de défaillance <i>vF1</i> pour l'année de prédiction 2012 : <i>vTTFF1(2012)</i> .....	124
Tableau 5.7	Tâches de maintenance prévisionnelle proposées en 2012 suite aux résultats de pronostic et dates d'application correspondantes.....	125
Tableau 5.8	Historique des états de détection des états physiques ciblés <i>vεeik</i> pour le stator de l'alternateur A .....	126
Tableau 5.9	Intervalles de détection observés <i>KE</i> des états ciblés estimés à partir de données historiques.....	127
Tableau 6.1	Processus de planification opérationnelle des groupes turbine-alternateurs .....	141
Tableau 6.2	Liste des défaillances historiques du stator <i>D</i> .....	142

## LISTE DES FIGURES

		Page
Figure 2.1	Modèle conceptuelle de la gestion des actifs par IAM (IAM, 2015).....	9
Figure 2.2	Hierarchie de la gestion des actifs au sein d'un système intégré de gestion des actifs (IAM, 2015).....	9
Figure 2.3	Modèle conceptuelle de l'estimation du risque de défaillance .....	10
Figure 2.4	Sélection du modèle d'estimation de probabilité de défaillance suivant les données disponibles .....	11
Figure 2.5	Type de système réparable et leurs modèles stochastiques associés (Rausand et al., 2004) .....	13
Figure 2.6	Familles d'application de prédiction (Saxena et al., 2010) .....	15
Figure 2.7	Sources d'incertitudes dans les modèles de pronostic (Sankararaman et al., 2015) .....	16
Figure 2.8	Composantes d'un algorithme de pronostic (Shankar Sankararaman et al., 2014) .....	17
Figure 2.9	Liens entre les activités du processus de pronostic (Sankararaman et al., 2015) .....	18
Figure 2.10	Illustration du pronostic et de l'effet des incertitudes de diagnostic (Elattar et al., 2016) .....	20
Figure 2.11	Niveaux d'étude des systèmes de pronostic, du composant au système complexe (Javed et al., 2017) .....	21
Figure 2.12	Choix du niveau d'étude du système de pronostic .....	22
Figure 2.13	Illustrations des approches pronostics selon leurs applicabilités versus leurs niveaux de précisions et coûts de développement (Byington, Roemer, & Galie, 2002).....	24
Figure 2.14	Forces et faiblesses des approches de pronostic (Atamuradov et al., 2017a) .....	26
Figure 2.15	Approches basées sur les modèles fiabilistes (Pecht & Kumar, 2008).....	27

Figure 2.16	Étapes du processus de pronostic et leurs principaux challenges (Atamuradov et al., 2017a) .....	29
Figure 2.17	Processus de prétraitement des données (Atamuradov et al., 2017a).....	30
Figure 2.18.	Méthodologie PHM basée sur les modèles physiques (Kwon et al., 2016) .....	36
Figure 2.19	Illustration d'un réseau de Petri comportant 3 places et une transition (Manuel Chiachío et al., 2017) .....	38
Figure 2.20	Illustration du "Plausible Petri Net" proposé par Chiachio et al. (Manuel Chiachío et al., 2017) .....	39
Figure 2.21	Illustration de résultats de pronostic par une approche de « Plausible Petri Net » (Manuel Chiachío et al., 2017) .....	39
Figure 2.22	Illustration de pronostic d'un système par un réseau bayésien dynamique (Medjaher et al., 2009) .....	40
Figure 2.23	Illustration du graphe d'interactions entre plusieurs mécanismes de défaillance (Zeng et al., 2017) .....	41
Figure 2.24	Processus du diagnostic-pronostic proposé dans la norme ISO13381 et son implication dans le processus décisionnel (Sikorska et al., 2011) .....	44
Figure 2.25	Illustration du modèle de pronostic via un réseau de Pétri. (Ammour et al., 2016).....	46
Figure 2.26	Temps nécessaires à un algorithme de pronostic pour fournir une prédiction (Saxena et al., 2010) .....	47
Figure 2.27	Saxena et al. classification des métriques de performances (Saxena et al., 2010).....	48
Figure 2.28	Zhou et al. Classification des métriques de performances (Zhou et al., 2013) .....	49
Figure 2.29	Illustration d'un diagramme RUL-EOL.....	55
Figure 2.30	Illustration des limites des prédictions en avance et en retard des prédictions pour des algorithmes de pronostic (Saxena et al., 2012).....	56

Figure 2.31	Arbre démontrant l'écoulement des exigences du système de pronostic pour la mission d'un drone afin d'en estimer les paramètres de validation (Saxena et al., 2012).....	57
Figure 2.32	Illustration des métriques utilisées par Son et al. (Son et al., 2013).....	60
Figure 2.33	Illustration de la méthode proposée par Leao et Yoneyama (Leao et al., 2013).....	61
Figure 2.34	Illustration de la validation de différents algorithmes de pronostic à l'échelle d'une population d'équipement (Hu et al., 2012).....	63
Figure 4.1	Modèle multi-états de dégradation représenté sous la forme d'un graphe causal.....	72
Figure 4.2	Illustrations de l'algorithme de diagnostic pour un actif X à des dates de prédiction, 2012 et 2014.....	78
Figure 4.3	Illustration des algorithmes de détection d'états physiques.....	79
Figure 4.4	Illustration de l'algorithme de pronostic.....	83
Figure 4.5	Illustration de mécanismes de défaillance menant à un mode de défaillance.....	87
Figure 4.6	Groupe turbine-alternateur d'une centrale d'Hydro-Québec (Hydro-Québec, 2017).....	89
Figure 4.7	Modèle de dégradation multi-états d'un stator hydro-électrique.....	91
Figure 4.8	Mécanisme de défaillance avec les algorithmes de détection et seuils définissant chaque état physique (Normand Amyot et al., 2013a).....	92
Figure 4.9	Exemples de résultats de processus d'élicitation avec quatre experts sur une partie d'un mécanisme de défaillance.....	94
Figure 4.10	Résultats des algorithmes de détection d'états physiques à l'année de prédiction 2005.....	96
Figure 4.11	Estimation de l'état du Stator A à l'année de prédiction.....	97
Figure 4.12	Résultats de la propagation des mécanismes de défaillance et de la prédiction des occurrences des modes de défaillance pour le stator A à la date de prédiction 2005.....	99

Figure 4.13	Validation de la prédiction du mode de défaillance pour le stator A, avec des dates de prédiction allant de 2002 à 2010. ....	101
Figure 4.14	Validation du pronostic du mode de défaillance pour le stator B, avec des années de prédiction allant de 1992 à 2010.....	102
Figure 4.15	Validation de la prédiction du mode de défaillance pour le stator C, pour des années de prédiction allant de 2006 à 2015.....	103
Figure 4.16	Validation du pronostic du mode de défaillance pour le stator D, avec des années de prédiction allant de 1992 à 2016.....	104
Figure 5.1	Illustration de l'algorithme de propagation des mécanismes de défaillance vers un état cible.....	112
Figure 5.2	Illustration de l'algorithme de propagation du mécanisme de défaillance vers un état cible.....	114
Figure 5.3	Illustration de l'algorithme de propagation des mécanismes de défaillance.....	117
Figure 5.4	Estimation de l'état du stator de l'alternateur A en 2012 .....	120
Figure 5.5	Propagation des mécanismes de défaillance menant aux états physiques ciblés pour la maintenance prévisionnelle en 2012 .....	121
Figure 5.6	Prédiction de l'occurrence des modes de défaillances résultant des états physiques ciblés par la maintenance prévisionnelle en 2012 ...	123
Figure 5.7	Intervalle d'activation observés (Boxplot) par rapport aux intervalles d'activation prévus pour les états cibles. Les lignes en pointillés illustrent la date de détection observée et la zone grise l'intervalle d'activation possible observé. Les pourcentages représentent le rapport entre la masse de probabilité de la prévision qui reste dans la zone acceptable. ....	127
Figure 6.1	Illustration de la fonction de vérité ( <i>Ground Truth</i> ) RUL appliquée à un système réparable comportant 3 défaillances <i>EOF1</i> , <i>EOF2</i> et <i>EOF3</i> . ....	133
Figure 6.2	Illustration de la fonction de vérité ( <i>Ground Truth</i> ) TTF proposée et appliquée à un système réparable comportant 3 défaillances <i>EOF1</i> , <i>EOF2</i> et <i>EOF3</i> . ....	134

Figure 6.3	Illustration de la zone de prédiction acceptable pour un PPO ayant un horizon de planification de 3 ans et une fréquence d'actualisation de 1 an .....	137
Figure 6.5	Illustration des performances <i>on-line</i> d'un algorithme de pronostic par analyse graphique pour un PPO.....	140
Figure 6.6	Évaluation des performances des résultats de pronostic du stator <i>D</i> dans le cadre du plan de retrait aux 6 ans ( $PPO1H = 6 \text{ ans}; PPO1f = 2 \text{ ans}$ ).....	143
Figure 6.7	Évaluation des performances des résultats de pronostic du stator <i>D</i> dans le cadre du plan de production aux 2 ans ( $PPO2H = 2 \text{ ans}; PPO2f = 1/2 \text{ ans}$ ) .....	144
Figure 6.8	Évaluation des performances des résultats de pronostic du stator <i>D</i> dans le cadre du plan de production aux mois ( $PPO3H = 1 \text{ mois}; PPO3f = 10 \text{ jours}$ ).....	144
Figure 7.1	Illustration du processus d'actualisation des algorithmes de pronostic....	153



## LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

AMDEC	Analyse des modes de défaillance et de leur criticité
ASMD	Analyse des symptômes et des mécanismes de défaillance
MTBF	<i>Mean Time Between Failure</i>
PHM	<i>Proportional Hazard Model</i> ou <i>Prognostic and Health Management</i>
ARMA	<i>Auto-regressive Moving Average</i>
FORM	<i>First Order Reliability Moment</i>
EOL	<i>End of Life</i>
EOF	<i>End of Function</i>
TTF	<i>Time to Failure</i>
RUL	<i>Remaining Useful Life</i>
PPO	Processus de planification opérationnelle



## LISTE DES SYMBOLES ET UNITÉS DE MESURE

$G$	Graphe de causalité ou graphe acyclique dirigé (DAG)
$V$	Ensemble fini de sommets ou nœuds distincts
$E$	Ensemble fini d'arêtes ou de liens distincts
$v^{ei}$	État physique $i$ associé au nœud $v$
$v^{RCa}$	Cause physique $a$ associé au nœud $v$
$v^{Fb}$	Mode de défaillance $b$ associé au nœud $v$
$FM^j$	Mécanismes de défaillance $j$
$v^{etarget}$	État physique cible associé au nœud $v$
$T_{FM^j}^{e_u, e_v}$	Temps de transition pour passer de l'état physique $u$ à $v$ d'après la séquence définie par le mécanisme de défaillance $FM^j$
$v_{\varepsilon}^{ei}(k_p)$	Évidence $\varepsilon$ de l'état physique $i$ pour un temps discret de prédiction $k_p$
$v_{\varepsilon k_E}^{ei}(k_p)$	Date discrète $k_E$ à laquelle l'évidence $\varepsilon$ de l'état physique $i$ a été détectée pour un temps discret de prédiction $k_p$
$v_{\varepsilon K_E}^{ei}(k_p)$	Intervalle de détection possible $K_E$ de l'évidence $\varepsilon$ de l'état physique $i$ pour un temps discret de prédiction $k_p$
$FM_{\varepsilon}^j(k_p)$	Évidence $\varepsilon$ du mécanisme de défaillance $j$ pour un temps discret de prédiction $k_p$
$FM_{e_x}^j(k_p)$	État physique actif le plus proche de la défaillance $e_x$ dans le mécanisme de défaillance $j$ pour un temps discret de prédiction $k_p$
$FM_{T_x}^j(k_p)$	État de propagation estimé $T_x$ du mécanisme de défaillance $j$ pour un temps discret de prédiction $k_p$
$FM_{EOF}^j(k_p)$	Fin de la fonction prédite du système d'étude $EOF$ basée sur la propagation du mécanisme de défaillance $j$ pour un temps discret de prédiction $k_p$

$FM_{v^{e_{target}}}^j(k_p)$	Temps prédit pour atteindre l'état physique cible $v^{e_{target}}$ du système d'étude basé sur la propagation du mécanisme de défaillance $j$ pour un temps discret de prédiction $k_p$
$v_{CDF}^{e_{target}}(k_p)$	Fonction cumulative prédite $CDF$ du temps pour atteindre l'état physique cible $v^{e_{target}}$ pour un temps discret de prédiction $k_p$
$v_{EOF}^{F_b}(k_p)$	Fin de la fonction prédite du système d'étude $EOF$ basée sur l'occurrence du mode de défaillance $F_b$ pour un temps discret de prédiction $k_p$
$v_{TTF}^{F_b}(k_p)$	Temps restant avant la défaillance prédite du système d'étude $TTF$ basée sur l'occurrence du mode de défaillance $F_b$ pour un temps discret de prédiction $k_p$
$v_{TTE}^{e_{target}}(k_p)$	Temps restant pour atteindre l'état physique cible $e_{target}$ pour un temps discret de prédiction $k_p$
$v_{M_n}^{e_{target}}$	Maintenance spécifique $M_n$ rattaché à l'état cible $v^{e_{target}}$
$v_{k_E}^{e_{target}}(k_p)$	Date prédite $k_E$ du temps pour atteindre l'état physique cible $v^{e_{target}}$ pour un temps discret de prédiction $k_p$
$v_{M_n[k_E]}^{e_{target}}(k_p)$	Intervalle d'application prédit $K_E$ pour l'action de maintenance spécifique $M_n$ rattachée à l'état physique ciblé $v^{e_{target}}$ pour un temps discret de prédiction $k_p$
$PPO_i^H$	Horizon du processus de planification opérationnel
$PPO_i^f$	Fréquence d'actualisation du processus de planification opérationnel
$\alpha^-(t_p)$	Limite acceptable de prédiction en avance pour un temps de prédiction $t_p$
$\alpha^+(t_p)$	Limite acceptable de prédiction en retard pour un temps de prédiction $t_p$
$\lambda$	Temps nécessaire pour planifier raisonnablement une action de mitigation
$\Lambda$	Taux de défaillance
$\beta$	Niveau de confiance exigé pour chaque temps de prédiction $t_p$ ( $\pi[t_p]_{\alpha^-}^{\alpha^+} \geq \beta$ )
$t_f$	Date de défaillance
$t_p$	Date de prédiction

## INTRODUCTION

### 0.1 Mise en contexte

Les récents développements dans les systèmes de mesure, les nouveaux moyens d'analyse et d'apprentissage, l'accessibilité des données et les capacités de calcul ont fait du pronostic et de la gestion de l'état de santé des équipements (PHM) une discipline émergente en pleine croissance. Cette discipline vise à combler le fossé entre les données spécifiques des actifs et l'estimation actualisée de leur état de santé (Javed, Gouriveau, & Zerhouni, 2017; Sikorska, Hodkiewicz, & Ma, 2011). Le pronostic fait partie intégrante de cette discipline. Il est défini par la norme ISO 13381 comme étant l'analyse des symptômes de défaillance qui permet de prédire les conditions futures et la durée de vie résiduelle d'un actif selon ses paramètres de conception (International Standard, 2015). Les *modèles* de pronostic permettent de prédire l'occurrence de modes de défaillance d'un équipement en tenant compte de son état, de son niveau de charge et de son environnement et en estimant les incertitudes qui y sont intrinsèquement associées (Atamuradov, Medjaher, Dersin, Lamoureux, & Zerhouni, 2017b; K.; Goebel, Daigle, Saxena, Sankararaman, Roychoudhury et al., 2017). Tout comme le domaine de la fiabilité lors de ces dernières décennies (Aven & Zio, 2011), le PHM joue aujourd'hui un rôle important dans la gestion de la maintenance. Contrairement aux approches de maintenance préventive ou de maintenance basée sur la fiabilité, les approches de maintenance prévisionnelle prennent en compte les aspects dynamiques et individuels des données de chaque actif (Aven, 2016; Aven & Zio, 2011; Kwon, Hodkiewicz, Fan, Shibutani, & Pecht, 2016). Par définition, la *maintenance prévisionnelle* est une discipline qui permet de planifier des actions de maintenance basées sur des modèles de pronostic. Du point de vue de l'organisation, elle fait partie intégrante du processus de gestion des actifs qui est défini comme l'ensemble d'activités coordonnées d'une organisation visant à réaliser de la valeur des actifs (ISO, 2014).

Ainsi, les modèles de pronostic sont mis à jour au fur et à mesure que de nouvelles informations sur l'état de santé des actifs deviennent disponibles. Des actions de maintenance sont proposées

à l'avance pour éviter l'occurrence des modes de défaillance. Différents aspects doivent également être pris en compte pour optimiser la planification de la maintenance, afin de garantir la planification stratégique au sein d'une population d'actifs telle que la criticité des équipements, les contraintes de ressources opérationnelles ou encore les objectifs organisationnels, pour ne citer que quelques exemples (IAM, 2015).

Les différentes approches de pronostic peuvent être classées en quatre types, comme proposés par Elattar et al. (Elattar, Elminir, & Riad, 2016):

- Les approches basées sur la fiabilité;
- Les approches basées sur la physique de dégradation;
- Les approches basées sur les données;
- Les approches hybrides (combinant les approches précédentes);

Le choix de l'approche repose principalement sur nos connaissances de la physique des mécanismes de dégradation, de la disponibilité des données (connaissances théoriques, données de défaillance et données d'inspection et mesure), leur qualité et le contexte opérationnel dans lequel les résultats du modèle devront être appliqués (précision des prédictions, temps de réaction, conditions d'utilisation, acceptabilité des incertitudes, etc.).

## **0.2 Problématique de la recherche**

Malgré l'arrivée des nouvelles technologies de capteurs et des dispositifs d'acquisition de données, le manque de données historiques exploitables reste un problème commun pour une proportion importante d'applications industrielles (Compare, Baraldi, Bani, Zio, & Mc Donnell, 2017). Les modèles de pronostic basés sur la physique apparaissent alors comme un choix pertinent. Ces modèles peuvent être appliqués même si les données historiques ne sont pas disponibles en quantité significative. Ils s'appliquent généralement au niveau des composants et supposent que les mécanismes de défaillance (par exemple, la propagation des fissures, la cavitation, vieillissement d'un isolant, etc.) sont indépendants, connus et

modélisables (Javed et al., 2017; Sikorska et al., 2011; Zeng, Chen, Zio, & Kang, 2017). Dans un contexte industriel, ils peuvent être appliqués à des équipements spécifiques avec un nombre relativement limité de composants critiques et de mécanismes de défaillance.

Les équipements complexes disposent généralement de multiples modes et mécanismes de défaillance qui peuvent être interdépendants et évoluant au travers de nombreux composants. Typiquement, les informations de diagnostic proviennent de différentes sources (par exemple, des mesures et des inspections) à des intervalles discrets dans le temps. Par conséquent, les modèles de pronostics au niveau des composants ont une applicabilité limitée face aux équipements complexes, car ils ne gèrent ni la complexité inhérente des mécanismes de défaillance ni les interrelations entre les composants (Compare et al., 2017; Zeng et al., 2017). De plus, ils permettent d'obtenir qu'une représentation partielle, et par conséquent, approximative, de l'équipement dans son ensemble (Fink, Zio, & Weidmann, 2015). Comme remarqué par Sikorska et al. (Sikorska et al., 2011) et Javed et al. (Javed et al., 2017), peu de modèles de pronostic ont été appliqués à des équipements complexes.

L'applicabilité de la maintenance prévisionnelle sur les équipements complexes nécessite donc la prise en compte des multiples mécanismes de défaillance actifs et de leurs progressions. Les actions de maintenance peuvent ne pas avoir le même effet pour arrêter ou ralentir leurs propagations vers les modes de défaillance associés. Il est donc important de comprendre comment les mécanismes se propagent et s'interconnectent lorsque nous souhaitons appliquer des tâches de maintenance spécifiques pour prolonger la durée de vie utile des équipements complexes.

Finalement, la validation des modèles de pronostic est un aspect essentiel pour leur mise en application dans l'industrie. Cette étape nécessite la prise en compte de leur contexte d'utilisation et des incertitudes inhérentes aux modèles, aux mesures et données collectées. Bien que des métriques de validation aient été proposées dans la littérature (Drucker; K.; Goebel et al., 2017; Saxena, Celaya, Saha, Saha, & Goebel, 2010; Saxena, Sankararaman, &

Goebel, 2014; Sharp, 2013), il n'existe pas de règles claires permettant de déterminer les zones de prédictions acceptables des modèles de pronostic pour les systèmes réparables en tenant en compte de leur contexte opérationnel (horizons des plans de maintenance et leurs fréquences d'actualisation).

Toutes ces considérations nous ramènent vers une *opportunité* de recherche et de développement. Nous pensons qu'il est nécessaire de développer une approche de pronostic multimode de défaillance qui prend en compte la complexité des mécanismes de défaillance en tant que système et qui permet l'application de la maintenance prévisionnelle en incluant et intégrant pleinement cette complexité. Ces considérations sont essentielles afin d'assurer une compréhension globale des mécanismes de dégradations pouvant mener à la défaillance du système et ainsi d'assurer l'applicabilité et l'efficacité des actions de maintenance proposée sur le système. Par ailleurs, pour assurer la viabilité à long terme des modèles, il est important de pouvoir évaluer leurs performances et de définir des processus d'actualisation rigoureux.

### **0.3 Questions et objectifs de la recherche**

La problématique et les enjeux de recherche discutés dans la section précédente permettent de définir le but, les questions et objectifs de la thèse. Le but de cette recherche est de développer une approche globale de modèles de pronostic pour les équipements complexes permettant l'application de la maintenance prévisionnelle en tenant en compte de la complexité de leurs mécanismes de défaillance et de leur contexte opérationnel.

Les questions de recherches identifiées dans le cadre de cette thèse sont :

1. Comment développer et valider un modèle de pronostic pour les équipements complexes permettant de prédire l'occurrence de plusieurs modes de défaillance?
2. Comment tenir en compte de la complexité des mécanismes de défaillances et leurs interrelations sur les différents modes de défaillance du système?

3. Comment permettre l'application de la maintenance prévisionnelle en tenant compte de cette complexité et du contexte opérationnel?

Les objectifs de la recherche sont les suivants:

- Identifier les hypothèses et proposer un cadre théorique régissant la propagation des mécanismes de défaillance et leurs interactions avec les modes de défaillance d'un système complexe;
- Développer une approche de modélisation permettant le développement d'un système de pronostic pour les équipements complexes;
- Développer une approche permettant l'application de la maintenance prévisionnelle basée sur les résultats du système de pronostic proposé;
- Élaborer un formalisme mathématique permettant le développement d'algorithmes génériques;
- Valider l'approche par des études de cas réels;



# CHAPITRE 1

## REVUE DE LITTÉRATURE

La recherche proposée touche à plusieurs domaines d'expertises tels que la gestion des actifs, les systèmes de pronostic et plus précisément les approches de pronostic basé sur la physique, les métriques de validation des modèles de pronostic et les modèles de maintenance prévisionnelle. La revue ci-dessous résume les contributions importantes dans ces domaines liés au sujet de recherche, le but est de dresser un résumé de l'état de l'art dans le domaine.

### 1.1 Système de pronostic et son rôle dans la gestion des actifs

La gestion des actifs est un concept relativement récent initié par les industries nucléaire et pétrolière dans les années 1980. Comme définie dans l'Introduction, elle permet la coordination des activités d'une organisation afin de réaliser de la valeur de ses actifs (ISO, 2014). Il s'agit de trouver un équilibre entre les performances opérationnelles, les coûts et les risques lors de la prise de décision. La norme PAS 55, publiée en 2004, a posé les bases du concept de gestion des actifs physiques. Elle a été suivie par la norme ISO 55000 en 2014 (ISO, 2014). La norme ISO 55000 a une portée plus large que PAS 55, elle ne s'applique pas uniquement aux actifs physiques.

La gestion des actifs rassemble différents groupes d'activités d'une organisation telle que présentée par *The Institute of Asset Management* (IAM) dans la Figure 1.1. Les activités du diagnostic et du pronostic interviennent dans les activités suivantes :

- La gestion du cycle de vie des actifs en détectant les défauts via des mesures ou des inspections, en suivant l'évolution des mécanismes de défaillances par la combinaison des informations de diagnostic dans le temps et en prédisant dynamiquement les probabilités d'occurrence des modes de défaillance ou de l'équipement au fur et à mesure que de nouvelles informations sont disponibles. Cela permet de générer des indicateurs spécifiques sur les fiabilités, actuelles et futures, de chaque actif. Par la suite, les résultats

de pronostic permettent l'application de la maintenance prévisionnelle. La maintenance prévisionnelle permet à son tour l'optimisation du cycle de vie des actifs. Les décisions de maintenance doivent être basées sur le risque de défaillance de l'équipement qui inclut à la fois sa probabilité de défaillance et sa criticité vis-à-vis de sa fonction dans le système. Finalement, la maintenance prévisionnelle vise à optimiser les décisions liées à la planification d'actions de maintenance ou d'investissements en pérennité.

- Le contrôle des performances, des coûts et des risques en permettant l'estimation dynamique des probabilités de défaillance spécifiques à chaque actif. Comparativement aux approches fiabilistes, les approches de PHM permettent de prévenir des défaillances rares ou extrêmes qui ne seraient pas bien identifiées par des modélisations de type fréquentiste.
- La prise de décision en proposant une vue d'ensemble de l'état des actifs et en proposant des actions de maintenance futures à prévoir dans le temps et leurs influences sur l'état de l'actif.
- L'organisation et le personnel en donnant accès à la connaissance des experts telle que présente dans le système pour les générations actuelles et futures.

À travers ces différentes activités, la gestion des actifs doit permettre de gérer les actifs d'une organisation selon les différents niveaux décisionnels. Il est nécessaire de gérer le cycle de vie des actifs tout en prenant des décisions optimales au niveau du système d'actifs auquel il appartient, mais aussi de l'organisation dans son ensemble. Cette hiérarchie est présentée dans la Figure 1.2 ci-dessous.

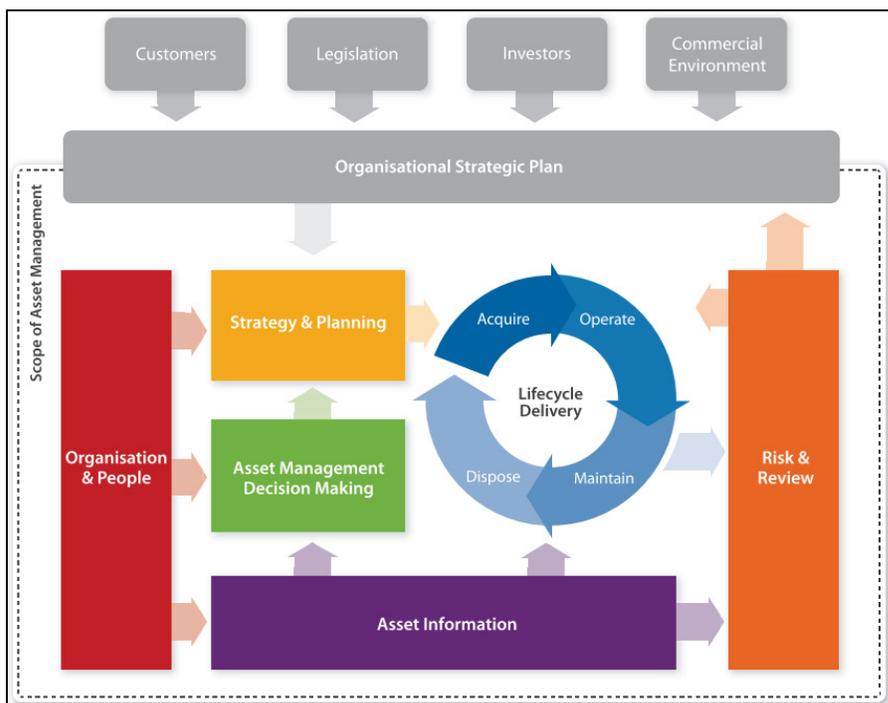


Figure 1.1 Modèle conceptuel de la gestion des actifs par IAM (IAM, 2015)

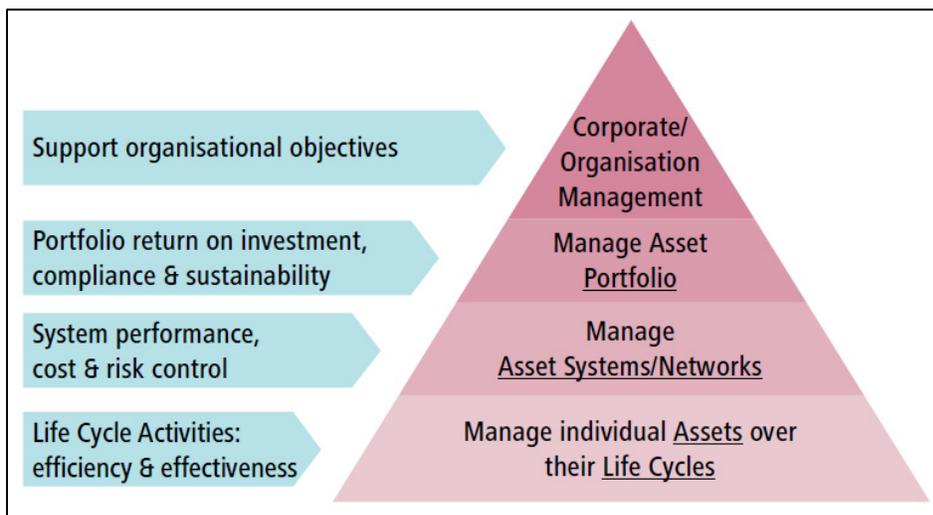


Figure 1.2 Hiérarchie de la gestion des actifs au sein d'un système intégré de gestion des actifs (IAM, 2015)

Afin de mieux identifier le rôle des données sources dans le processus de gestion de l'actif, nos travaux (Olivier Blancke, Komljenovic, Tahan, Amyot, Hudon et al., 2018) ont proposé un concept de décomposition du flux d'informations dans la gestion de l'état de santé des actifs en utilisant la classification DIKW (*Data, Information, Knowledge, Wisdom*). Ce concept est résumé dans la Figure 1.3. Il permet de faire le lien entre les données sources et les différents domaines d'expertises en jeu dans l'estimation du risque de défaillance telle que: les analyses statistiques de fiabilité, les modèles bayésiens, les systèmes de pronostic et les modèles de fiabilité au niveau des systèmes. Ce modèle est basé sur le modèle conceptuel d'IAM présenté dans la Figure 1.1 et un article de T. Aven (Aven, 2013) proposant une décomposition des flux d'information dans l'analyse du risque. La Figure 1.3 décrit plus en détail l'estimation du risque de défaillance selon les sources de données et de connaissances disponibles.

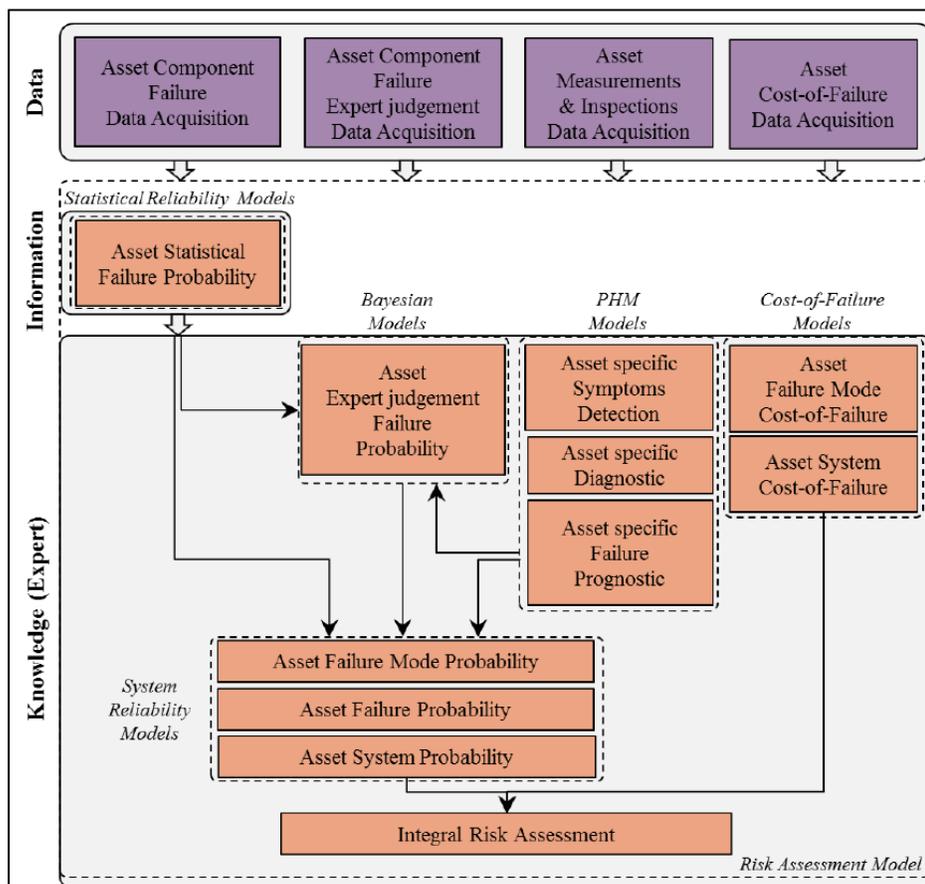


Figure 1.3 Modèle conceptuel de l'estimation du risque de défaillance

## 1.2 Estimation de la probabilité de défaillance d'un actif ou d'un système d'actifs

Au niveau de l'estimation de la probabilité d'occurrence des modes de défaillance, trois principales sources de données peuvent être utilisées : les données de défaillances, les connaissances de l'équipement et les données de mesures et d'inspection. Dépendamment des données disponibles et de la criticité des défaillances, différentes approches peuvent être envisagées. Afin de les synthétiser, un schéma est proposé dans la Figure 1.4 ci-dessous.

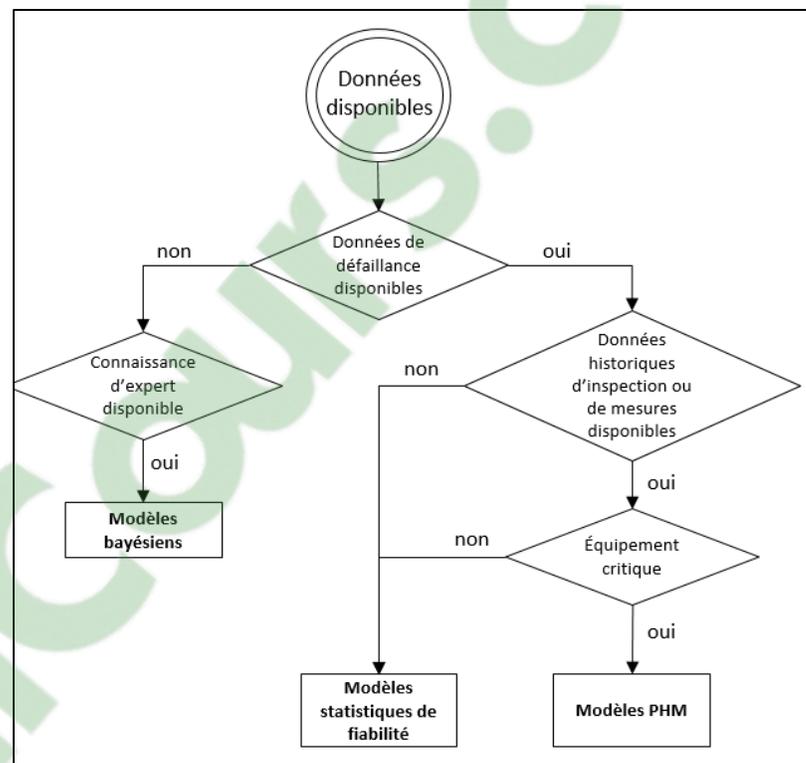


Figure 1.4 Sélection du modèle d'estimation de probabilité de défaillance suivant les données disponibles

Dans le cas où les données de défaillance ne sont pas disponibles, ou leur qualité n'est pas suffisante, il est tout de même possible de se fier à l'avis des experts via des processus d'élicitation d'experts (Simola, Mengolini, & Bolado-Lavin, 2005; Simola, Mengolini, Bolado-Lavin, & Gandossi, 2005). Les processus d'élicitation d'experts ont pour but d'extraire

la connaissance implicite des experts afin d'en déduire des données quantitatives. Ils visent à minimiser les biais cognitifs inhérents au processus d'élicitation. Bien sûr, lorsque les données de défaillance sont disponibles en quantité suffisante et que les données historiques de mesures et d'inspection ne sont pas disponibles, les approches statistiques peuvent alors être appliquées. Les modèles statistiques dans le domaine de la fiabilité visent à modéliser la probabilité de défaillance d'un équipement selon le comportement d'une population d'actifs homogène auquel il appartient (théorie fréquentiste) (Rausand & Høyland, 2004).

Ces modèles peuvent être mis à jour au fur et à mesure que de nouvelles données de défaillance sont disponibles. Ils ne permettent pas de détecter des changements brusques dans le comportement d'un ensemble d'actifs. Ils permettent cependant d'illustrer l'évolution statistique des probabilités de défaillance au cours du temps.

Pour les systèmes non réparables, deux modèles sont largement utilisés : le modèle exponentiel et le modèle de Weibull. Le modèle exponentiel ne comporte qu'un seul paramètre. Il considère le taux de défaillance d'une population d'actif comme constant dans le temps. L'équation (1.1) présente la distribution de probabilité de défaillance selon le modèle exponentiel (pour  $t \geq 0$ ).

$$F(t; \Lambda) = 1 - R(t) = 1 - e^{-\Lambda t} \quad (1.1)$$

Dans le cas où l'âge a un effet sur le taux de défaillance, il est alors recommandé d'utiliser le modèle de Weibull. L'équation (1.2) présente la distribution de probabilité de défaillance selon le modèle de Weibull.

$$F(t; \beta, \theta) = 1 - R(t) = 1 - e^{-\left(\frac{t}{\theta}\right)^\beta} \quad (1.2)$$

La distribution de Weibull a pour avantage principal d'être une distribution dite « caméléon ». Elle possède deux paramètres; paramètre de forme ( $\beta$ ) et paramètre d'échelle ( $\theta$ ), elle s'adapte donc à une grande variété de formes de distribution.

Dans le cas des systèmes réparables, il est préférable d'utiliser des modèles statistiques permettant de tenir en compte le fait que des équipements peuvent vivre plusieurs défaillances dans leur vie utile. Pour ces types d'équipements, on ne parle pas de taux de défaillance, mais plutôt d'intensité de défaillance qui représente la fréquence à laquelle ils vont connaître des défaillances (Rausand et al., 2004; Rigdon & Basu, 2000). La Figure 1.5 illustre les principaux modèles utilisés.

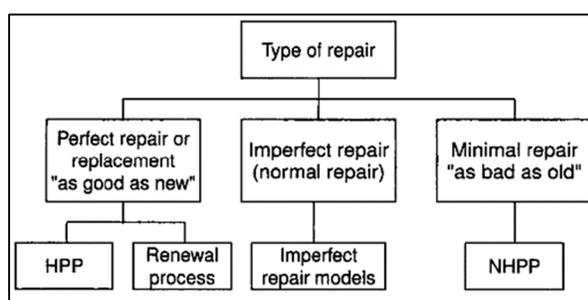


Figure 1.5 Types de systèmes réparables et leurs modèles stochastiques associés (Rausand et al., 2004)

Lorsque l'intensité de défaillance peut être considérée quasi constante dans le temps, les processus de Poisson homogène (HPP) peuvent être utilisés. Dans le cas des processus HPP, l'estimateur qui permet de définir la distribution statistique des défaillances est basé sur le temps moyen entre les défaillances (MTBF). Si l'intensité des défaillances dépend de l'âge de l'équipement, il faut alors utiliser le processus de Poisson non homogène (NHPP). Ces processus permettent d'estimer la probabilité qu'un équipement vive une, deux ou plusieurs défaillances au cours de sa vie utile. Lorsque ces modèles alimentent un simulateur, ils permettent d'estimer de manière plus fiable l'indisponibilité des équipements. Pour plus d'informations sur ces modèles, il est recommandé de se référer au livre de Rigdon et Basu (Rigdon et al., 2000).

Bien que les modèles fiabilistes apportent déjà certaines métriques à cet effet telles que le temps moyen avant défaillance (MTTF), ils sont basés sur l'hypothèse que les temps de

défaillance de composants identiques peuvent être considérés comme des variables aléatoires statistiquement identiques, mais indépendantes. Celles-ci peuvent être décrites par une fonction de densité de probabilité (Sikorska et al., 2011). En d'autres termes, les approches fiabilistes analysent et estiment le temps de défaillance d'une population de mécanismes de défaillances. Cependant, les fonctions de densité de probabilité utilisées (ex. : fonction Weibull) ne sont pas représentatives de la progression d'un seul mécanisme de défaillance, qui généralement (mais pas toujours) suit une courbe exponentielle. Dans les cas où les défaillances sont relativement rares, les estimations fiabilistes peuvent être trop pessimistes (Goode, Goode, & Roylance, 2000; Sikorska et al., 2011).

### **1.3 Les systèmes de pronostic de défaillance**

La discipline du Pronostic a vu le jour il y a environ une vingtaine d'années quand la communauté de fiabilité a commencé à s'intéresser aux principes fondamentaux de la physique de défaillance dans le but de comprendre comment les systèmes électromécaniques complexes vieillissent et défont. Inspiré par les travaux dans le domaine médical, le pronostic a connu son essor dans l'armée et dans l'industrie aérospatiale. Le but est de minimiser les incertitudes entourant l'estimation du temps avant défaillance (TTF) et d'estimer la fin de vie utile d'un système (RUL) (K.; Goebel et al., 2017).

Dans un premier temps, il est important de bien différencier l'objectif principal des systèmes de pronostic comparativement aux autres applications de prédiction (météo, finance...). La Figure 1.6, proposée par Saxena et al. (Saxena et al., 2010), illustre les grandes familles. Le pronostic vise à prédire l'occurrence de la fin de fonctionnement d'un système. Il vise à prédire un événement ou une trajectoire de dégradation.

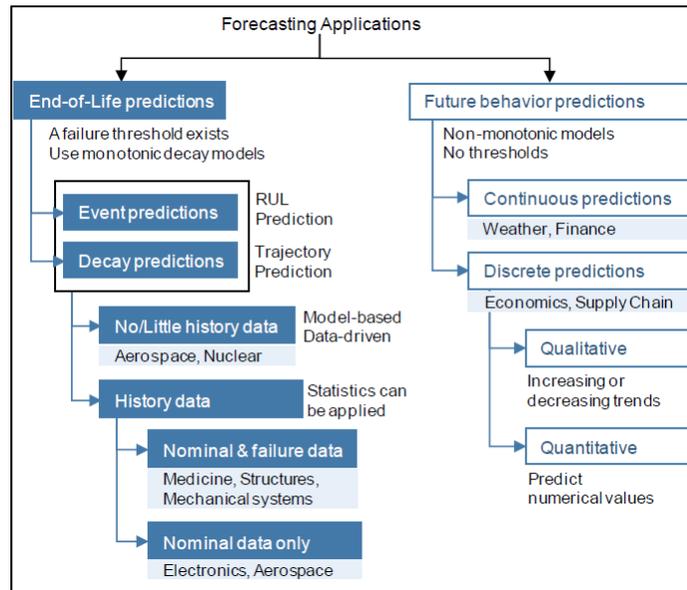


Figure 1.6 Familles d'application de prédiction  
(Saxena et al., 2010)

Comparativement aux approches fiabilistes qui estiment la probabilité de défaillance en se basant sur les données de défaillance d'une population d'équipements homogènes, le pronostic se base sur les données liées aux conditions spécifiques de l'équipement d'étude. Les chercheurs du « *Prognostics Center of Excellence (PCoE)* » au centre de recherche *NASA Ames* précisent qu'en utilisant notre compréhension de la dynamique des composants, des défauts, de la propagation des mécanismes de dégradation et les données spécifiques d'un équipement, il est alors possible de prédire le comportement futur et d'estimer ainsi le temps auquel une défaillance ou un événement spécifique de l'équipement survient (K.; Goebel et al., 2017).

Il existe de nombreux facteurs qui peuvent rendre la prédiction d'un événement incertain. L'analyse d'incertitudes est une des étapes les plus importantes dans l'élaboration des systèmes pronostiques. Différentes contributions importantes ont vu le jour dans le domaine pour proposer des méthodologies permettant d'estimer l'incertitude (Aven & Guikema, 2011; Celaya, Saxena, & Goebel, 2012; Matthew Daigle, Saxena, & Goebel, 2012; Liang,

Kacprzyński, Goebel, & Vachtsevanos, 2009; Sankararaman, 2015; Sankararaman, Daigle, & Goebel, 2014; Sankararaman & Goebel, 2013, 2015). Dans leur plus récente publication, Sankararaman et Goebel proposent une méthodologie en quatre étapes : interprétation et identification, quantification, propagation et gestion des incertitudes (Sankararaman et al., 2015). Les sources d'incertitudes des systèmes de pronostic ont été résumées dans la Figure 1.7.

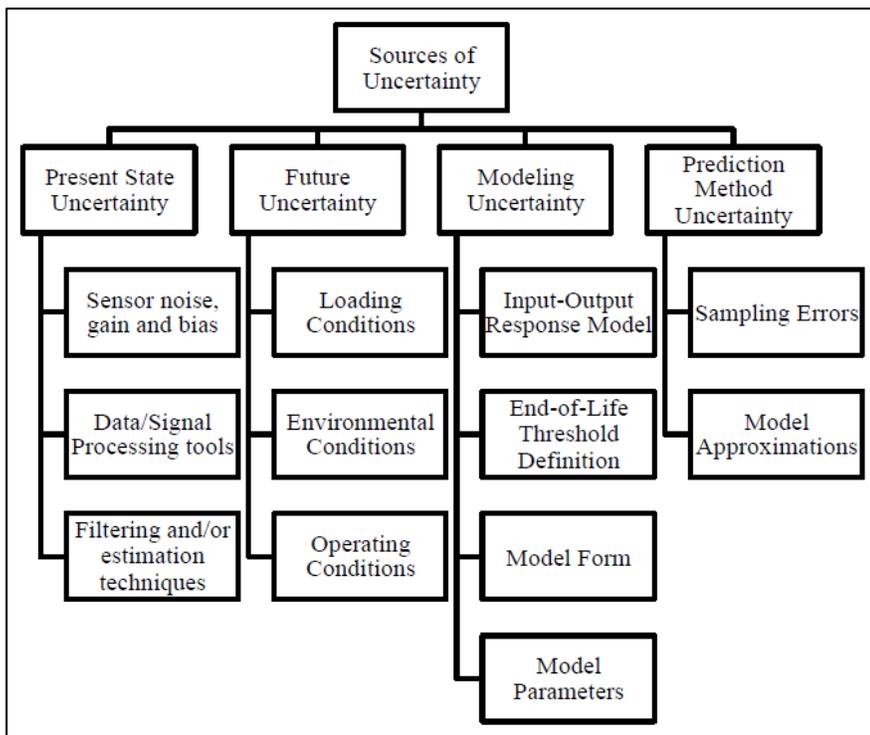


Figure 1.7 Sources d'incertitudes dans les modèles de pronostic (Sankararaman et al., 2015)

Quatre grandes catégories d'incertitudes sont présentées : les incertitudes liées à l'estimation de l'état actuel (diagnostic), les incertitudes liées aux conditions futures, les incertitudes liées aux hypothèses du modèle de pronostic et à ses paramètres et finalement les incertitudes liées à la méthode de prédiction. Afin de faire face à ces différentes sources d'incertitudes, les algorithmes de pronostic doivent comporter différentes composantes qui permettent de les

modéliser et de les quantifier. La Figure 1.8 illustre les composantes d'un algorithme de pronostic tel que défini par Sankararaman et al. (Sankararaman, Saxena, & Goebel, 2014).

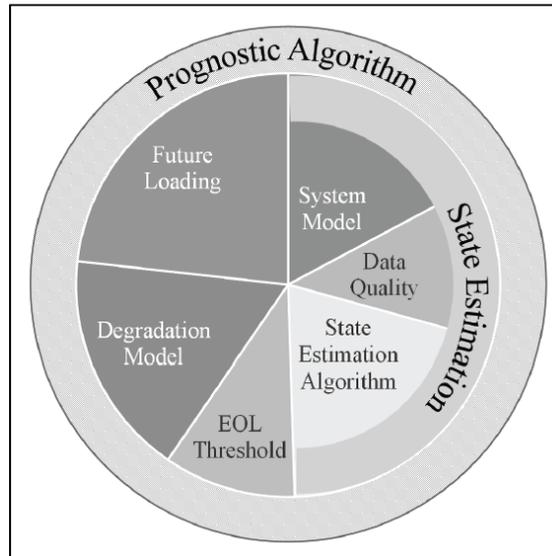


Figure 1.8 Composantes d'un algorithme de pronostic  
(Shankar Sankararaman et al., 2014)

Dans la Figure 1.8, les composantes liées à l'estimation de l'état peuvent être assimilées aux activités de diagnostic. Les algorithmes de pronostic comportent généralement deux composantes principales : l'estimation de l'état actuel (activités de diagnostic) et la propagation des incertitudes (activités de pronostic). Il est important de préciser que la qualité des données est aussi importante dans les activités de diagnostic que de pronostic.

Pour ce qui est de l'estimation des incertitudes, les références proposées précédemment présentent différentes méthodes selon les types de modèles. Au niveau des incertitudes liées à l'utilisation de l'avis d'expert, d'autres références provenant d'autres domaines proposent des méthodes spécifiques (Aven & Guikema, 2011; Gordon, 1994; Hoffman & Kaplan, 1999; Runge, Converse, & Lyons, 2011; Simola, Mengolini, & Bolado-Lavin, 2005; Straub, 2014).

Afin de permettre la gestion des incertitudes dans son ensemble, il est important de définir les possibilités de propagation des sources d'incertitudes tout au long du processus de pronostic et leurs impacts sur les résultats souhaités via une analyse de sensibilité comme proposée par Liang et al. (Liang et al., 2009). La Figure 1.9, proposée par Sankararaman et Goebel (Sankararaman et al., 2015), présente les interactions relatives dans un processus de pronostic au niveau de la propagation d'incertitude.

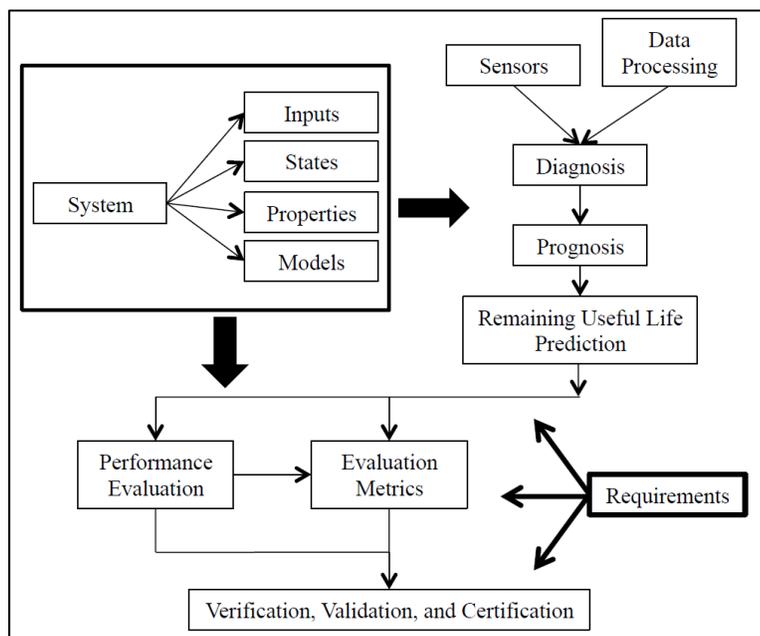


Figure 1.9 Liens entre les activités du processus de pronostic (Sankararaman et al., 2015)

D'une manière générale, le système d'étude est défini par des entrées (mesures ou inspections), des états (défauts, symptômes, modes de défaillance, etc.), des propriétés (modèles, date de mise en service, niveau d'opération, localisation, etc.) et des modèles qui le représentent. Ces différents attributs sont utilisés tout au long du processus de pronostic. D'un point de vue général, le processus du pronostic peut être résumé en quatre étapes successives qui restent nécessaires, quelle que soit l'approche ou le modèle choisi (Tableau 1.1).

Tableau 1.1 Processus général du pronostic

1. Acquisition des données	Acquisitions des données et inspections du système
2. Diagnostic	Identification de l'état de dégradation <u>actuel</u> du système
<b>3. Pronostic</b>	Estimation de l'état de dégradation <u>futur</u> du système
4. Prise de décision (maintenance prévisionnelle)	Identification et planification d'actions intelligentes et appropriées

La frontière entre le diagnostic et le pronostic peut parfois être ambiguë, notamment entre les écoles de pensée nord-américaine et européenne. Il a été constaté par Vachtsevanos et al. que chaque étape du processus défini doit être réalisée sur l'hypothèse que les sorties renvoyées par l'étape précédente sont disponibles (Vachtsevanos, Lewis, Roemer, Hess, & Wu, 2007). Il est alors possible de segmenter la conception d'un système de pronostic et de superposer certaines phases de développements. Cependant, les étapes successives nécessaires à l'élaboration d'un système de pronostic induisent chacune une part d'incertitude et qui doit être quantifiée. La Figure 1.10 illustre une prédiction de défaillance.

Les points rouges représentent les différentes mesures du paramètre d'étude  $a$  représentant ici l'état du système d'étude. L'estimation de l'état actuel du système au temps de prédiction  $t_{now}$  comporte déjà des incertitudes liées aux mesures et au traitement des données représentées par les lignes continues. Les lignes en pointillé représentent la propagation de ces incertitudes pour établir la prédiction de l'événement. Dans ce cas, l'événement est représenté par le franchissement du seuil de défaillance. La prédiction de cet événement peut être représentée par une densité de probabilité représentant la probabilité que les différentes trajectoires de dégradation atteignent la défaillance.

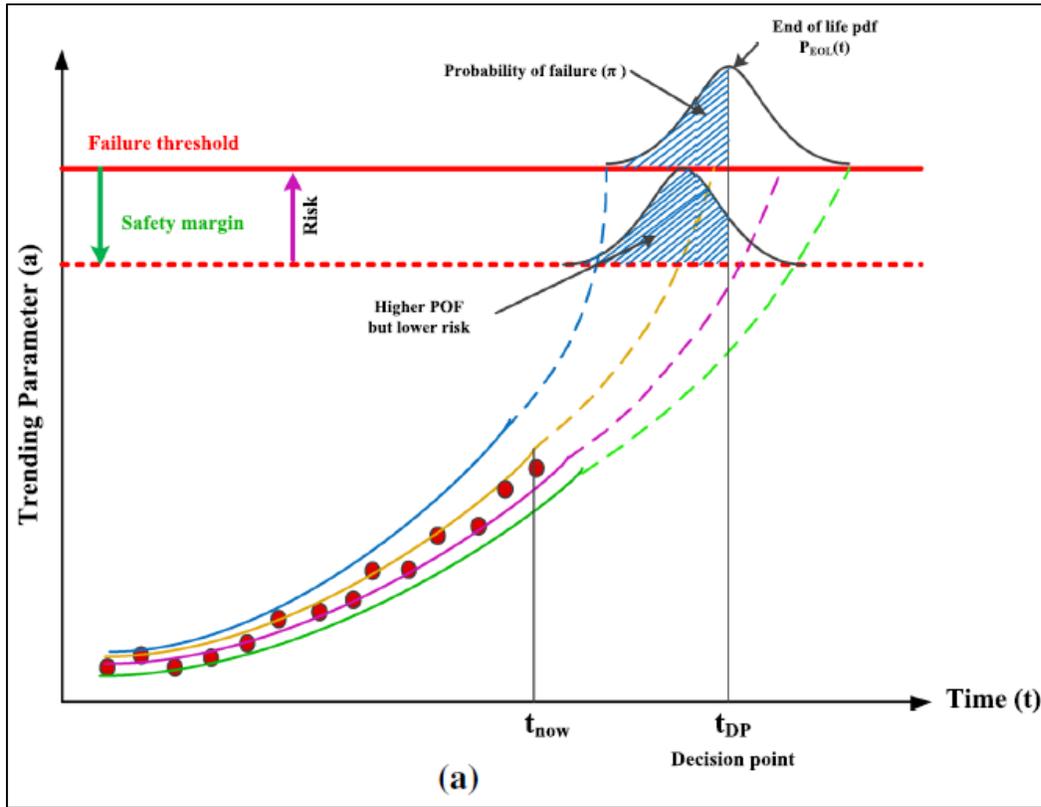


Figure 1.10 Illustration du pronostic et de l'effet des incertitudes de diagnostic (Elattar et al., 2016)

L'objectif direct du pronostic est d'estimer le temps avant défaillance TTF (équation (1.3)) ou la durée de vie résiduelle RUL (équation (1.4)) du système d'étude selon les données d'entrée qui peuvent être des données de diagnostic, l'avis d'expert ou autres.

$$\text{TTF} = t_f - t_p \quad (1.3)$$

$$\text{RUL} = \text{EOL} - t_p \quad (1.4)$$

Comme illustré dans la Figure 1.9, il est nécessaire de définir des métriques de validation afin de s'assurer que le modèle de pronostic répond adéquatement au besoin d'affaires. Ces métriques de validation doivent être définies en se basant sur les besoins.

## 1.4 Approches et classification des systèmes de pronostic

L'élaboration des systèmes pronostique nécessite trois principaux choix : (i) le choix du niveau d'étude (la vision portée sur le système pour l'étudier : composant ou système), (ii) le choix de l'approche (la manière de modéliser le système d'étude) et, (iii) le choix du type de modèle. Ces choix doivent être faits selon les besoins et les ressources disponibles de l'organisation.

### 1.4.1 Niveau d'étude des systèmes de pronostic

Comme défini par Daigle et al. (M. Daigle, Bregon, & Roychoudhury, 2012), il existe principalement deux niveaux d'étude des systèmes de pronostic : les approches centrées sur les composants et les approches systèmes. La Figure 1.11 proposée par Javed et al. (Javed et al., 2017) illustre les différents niveaux d'étude pour les applications de systèmes de pronostic.

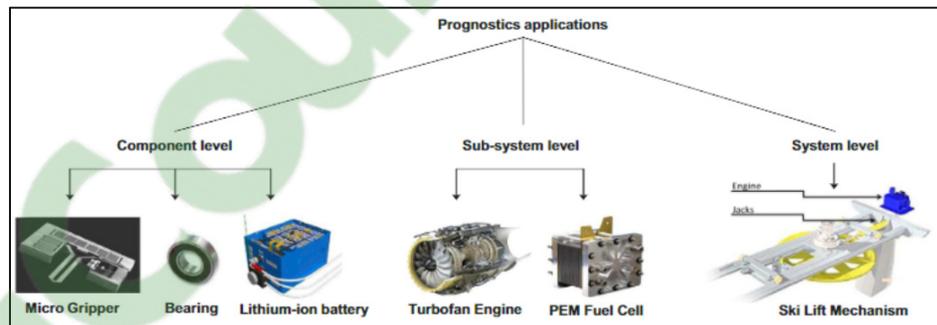


Figure 1.11 Niveaux d'étude des systèmes de pronostic, du composant au système complexe (Javed et al., 2017)

Une grande partie des systèmes de pronostic existants utilise une approche centrée sur la dégradation d'un seul composant du système menant à un maximum de 1, 2 ou 3 modes de défaillance (M. Daigle et al., 2012). Les composants étudiés sont critiques pour le fonctionnement du système et nécessitent une analyse plus poussée de leurs dégradations. Les applications typiques de ce genre d'approche sont la propagation de fissures (Swanson,

Michael Spencer, & Arzoumanian, 2000), les batteries (M. Daigle & Kulkarni, 2014) ou encore la corrosion (Kacprzyński, 2006).

Bien que plus rares, différentes contributions proposent des approches système (Abdelwahed & Karsai, 2009; Normand Amyot, Hudon, Lévesque, Bélec, Brabant et al., 2013b; Manuel Chiachío, Chiachío, Sankararaman, Andrews, & Targett, 2017; Cochetoux, 2010; M. Daigle et al., 2012; M. J. Daigle & Goebel, 2013; Garga, McClintic, Campbell, Chih-Chung, Lebold et al., 2001; Gomes, Rodrigues, Galvão, & Yoneyama, 2013; Medina-Olivier, Iung, Barbera, Viveros, & Ruin, 2012; Mooney, 2015; Ribot, 2009). Les approches système sont principalement utilisées pour caractériser des systèmes plus complexes et dont le niveau de certitude demandée sur les résultats est plus faible. La Figure 1.12 illustre une méthodologie permettant de choisir le niveau d'étude pour un système donné.

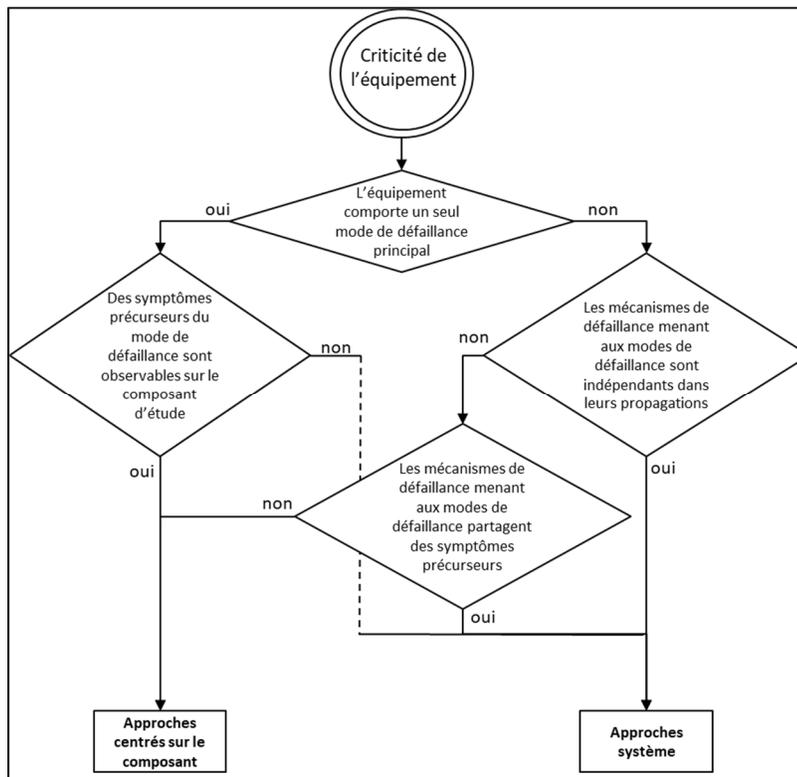


Figure 1.12 Choix du niveau d'étude du système de pronostic

Dans la pratique, comme discuté dans la problématique de recherche, les approches système apportent des possibilités d'utilisation beaucoup plus importantes pour l'organisation. Afin de créer un modèle permettant une vision système, il est nécessaire de définir les interactions existantes entre les dégradations des composants du système. Cet aspect sera couvert plus en détail dans la section 1.4.5 portant sur les approches basées sur la physique.

#### 1.4.2 Approches des systèmes de pronostic

Plusieurs contributions proposant une classification des approches et des modèles de pronostic ont vu le jour ces dernières années et proposent des revues assez exhaustives de l'état de l'art selon les différents secteurs d'activités (Aizpurua & Catterson, 2015; Atamuradov, Medjaher, Dersin, Lamoureux, & Zerhouni, 2017a; BSI, 2004; J. Chiachío, M. Chiachío, S. Sankararaman, A. Saxena, & K. Goebel, 2015; Coble, Ramuhalli, Bond, Hines, & Upadhyaya, 2015; Cochetoux, 2010; Elattar et al., 2016; Heng, Zhang, Tan, & Mathew, 2009; Ribot, 2009; Schwabacher & Goebel, 2007; Si, Wang, Hu, & Zhou, 2011; Sikorska et al., 2011). Les différentes classifications proposées divergent quant à la définition d'une liste exhaustive de catégories comme remarqué par Azura et al. (Aizpurua et al., 2015). La classification des modèles proposée par Elattar et al. (Elattar et al., 2016) représente bien l'ensemble des modèles présents dans la littérature. Les modèles et approches peuvent être classés selon 4 grandes catégories:

- Modèles basés sur les approches de fiabilité;
- Modèles basés sur les données;
- Modèles basés sur la physique;
- Modèle hybride.

En général, la complexité, le coût de développement et la précision des modèles sont inversement proportionnels à leur applicabilité tel que présenté dans la Figure 1.13. Le défi principal lors du développement des algorithmes de pronostic consiste à minimiser les coûts

de développement et la complexité des modèles tout en maximisant leur précision (Elattar et al., 2016).

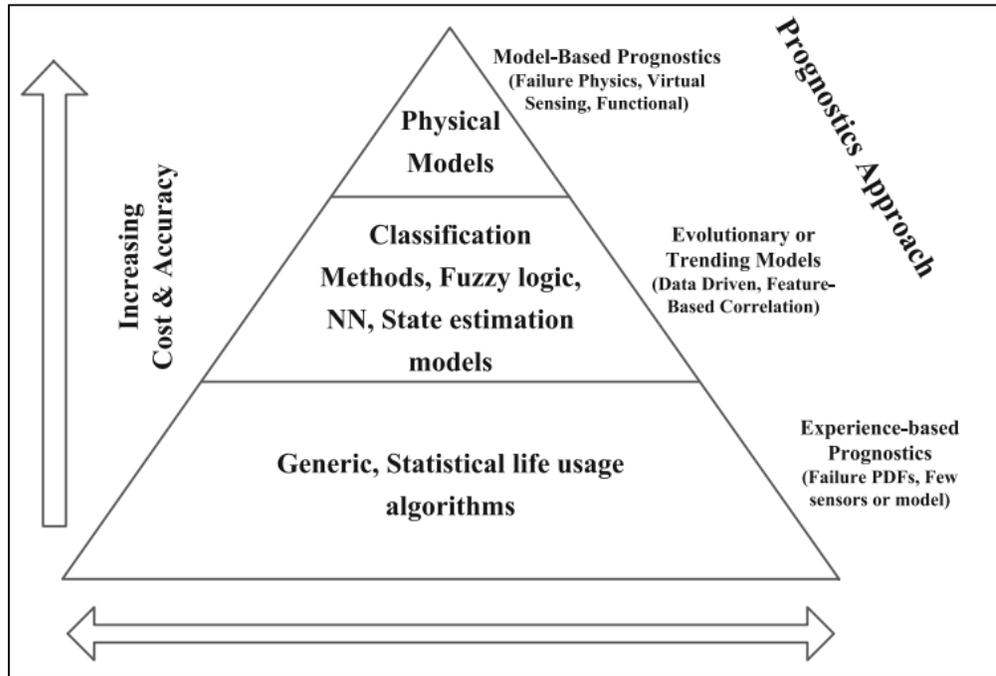


Figure 1.13 Illustration des approches pronostiques selon leur applicabilité versus leur niveau de précision et coûts de développement (Byington, Roemer, & Galie, 2002)

Dans les grandes catégories d'approches proposées ci-dessus, la complexité et les coûts de développement des modèles vont de pair avec l'ordre des approches énoncées. La Tableau 1.2 propose un résumé conceptuel ordonnant les approches de pronostic selon le risque acceptable de défaillance de l'équipement d'étude (relatif à leur niveau de précision), les données et les connaissances disponibles et le coût de développement du système de pronostic.

Tableau 1.2 Résumé des approches de pronostic existantes

Approches de pronostic	Risque de défaillance	Connaissances de l'équipement disponibles	Données disponibles	Coût de développement
Basée sur la fiabilité	Faible	Faible	Moyen	Faible
Basée sur les données	Moyen - Élevé	Faible	Élevé	Faible
Basée sur la physique	Moyen - Élevé	Élevé	Faible	Moyen - Élevé
Hybride	Moyen - Élevé	Élevé	Moyen - Élevé	Élevé

Un tableau plus détaillé portant sur l'évaluation des approches de pronostic a été proposé par Javed et al. (Javed et al., 2017). Il est présenté dans le Tableau 1.3.

Tableau 1.3 Évaluation des besoins et des caractéristiques des approches de pronostic (Javed et al., 2017)

Applicability	Physics based	Data-Driven			Hybrid	
		<i>Univariate</i>	<i>Direct RUL</i>	<i>Multivariate</i>	<i>Series</i>	<i>Parallel</i>
Degradation process model	Required	Not required	Not required	Not required	Required	Required
Failure Threshold	Required	Required	Not required	Not required	Required	Required
Generality & scope	Limited	Broad	Broad	Broad	Limited	Limited
Learning experience	Observations	Observations	Run-to-failure	Run-to-failure	Observations	Observations
Operating conditions	Required	Beneficial	Beneficial	Beneficial	Required	Required
Assumptions (Phys./math.)	Yes	No	No	No	Yes	Yes
Knowledge	Detailed	Few	Few	Few	Detailed	In-depth
Transparency	High	Low	Low	Low	Medium	Medium
Modeling Complexity	High	Low	Low	Low	High	Very high
Computational Time	Low	Low	Medium	Medium	Medium	High

Atamurakov et al. (Atamuradov et al., 2017a) ont proposé une analyse haut niveau des forces et des faiblesses des approches de pronostic. Elles sont présentées dans la Figure 1.14.

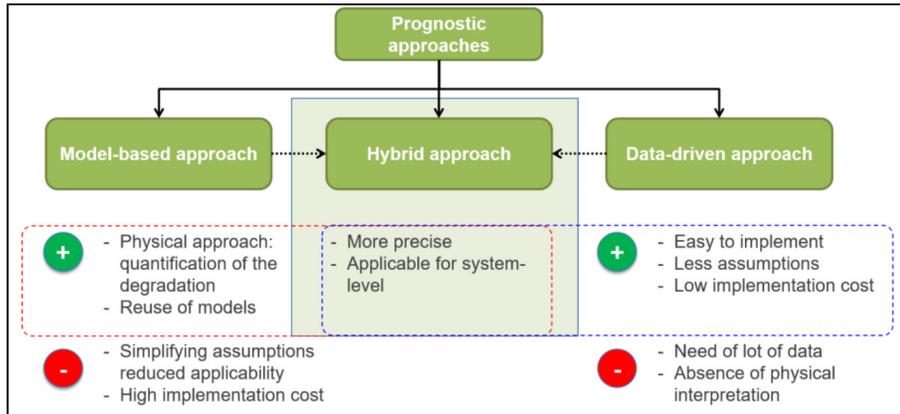


Figure 1.14 Forces et faiblesses des approches de pronostic (Atamuradov et al., 2017a)

### 1.4.3 Approche de pronostic basée sur les modèles de fiabilité

Les approches basées sur les modèles de fiabilité vont être préconisées pour des équipements dont le risque acceptable de défaillance d'un équipement est peu élevé. Elles consistent généralement à mettre à jour l'estimation de la fiabilité d'un équipement en pondérant sa fiabilité statistique par un ou plusieurs facteurs d'influence spécifiques souvent relatifs au niveau de charge, l'environnement ou bien à l'état de santé. Comparativement au modèle classique de fiabilité uniquement basé sur les approches statistiques, les modèles de pronostic basés sur la fiabilité permettent de tenir en compte de certains paramètres spécifiques et de leur évolution au cours du temps. Ils permettent une meilleure réactivité décisionnelle en cas de changement soudain du comportement de l'équipement. La Figure 1.15 illustre le fonctionnement de ce type d'approche. Une distribution du MTBF est mise à jour en utilisant les nouvelles données disponibles sur l'équipement.

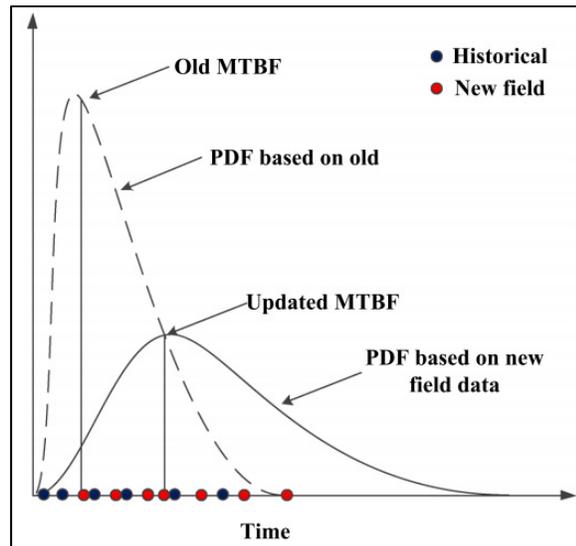


Figure 1.15 Approches basées sur les modèles fiabilistes (Pecht & Kumar, 2008)

Ces modèles nécessitent des données de défaillance historiques pour le développement des modèles statistiques ainsi que des données en ligne et historiques des covariables d'intérêt pour chaque équipement d'étude. Une connaissance détaillée de la physique de dégradation n'est donc pas essentielle pour ce type de modèle (Elattar et al., 2016). Par ailleurs, l'utilisation des experts est peut-être requise pour identifier les covariables d'intérêt permettant la pondération des modèles statistiques.

Il existe différents modèles pouvant être utilisés dans ce type d'approche. Le plus utilisé est le modèle proposé par Cox et intitulé « *Proportional Hazard Model* » (PHM) (Sikorska et al., 2011). Il s'agit d'un modèle proche des modèles de Weibull, mais comprenant des co-variables permettant de pondérer la distribution statistique. L'équation (1.5) présente la formulation du modèle PHM. Pour plus d'informations sur ce modèle, il est conseillé de se référer à l'article de Tran, V. et al. (Tran, Thom Pham, Yang, & Tien Nguyen, 2012) qui illustre un cas de pronostic par la méthode PHM. Le modèle de Cox est présenté dans l'équation (1.5). Le taux de défaillance d'un équipement peut alors s'exprimer sous la forme suivante :

$$\lambda(t) = \lambda_0(t) \times e^{(b_1X_1+b_2X_2+\dots+b_iX_i)} \quad (1.5)$$

Le taux de défaillance en fonction du temps  $\lambda(t)$  s'exprime selon une fonction de hasard de base  $\lambda_0(t)$  (non spécifique à l'équipement d'étude) et des covariables dépendantes du temps  $X_i$  (spécifiques à l'équipement d'étude). Les coefficients  $b_i$  permettent de calibrer l'influence des covariables sur le taux de défaillance. Ils sont généralement estimés via des méthodes de maximum de vraisemblance.

Dans ce type de modèle, le diagnostic est principalement réalisé lors de l'estimation de covariables liées à l'état de santé de l'équipement au temps de prédiction. Le modèle PHM permet alors de réaliser le pronostic en estimant statistiquement la distance entre la défaillance et les différentes covariables au temps de prédiction. Le livre de Goebel et al. (K.; Goebel et al., 2017) et la revue de Sirkoska et al. (Sikorska et al., 2011) propose d'autres modèles pour ce type d'approche.

#### 1.4.4 Approche de pronostic basée sur les données

Les approches basées sur les données sont préconisées pour les équipements dont la connaissance de leur physique de dégradation est limitée et les données historiques sont disponibles en grande quantité. Il peut aussi être recommandé d'utiliser ce type d'approche lorsque la physique de dégradation est complexe comme dans le cas où la propagation des mécanismes de défaillance menant aux modes de défaillances est fortement corrélée. Dans ce type d'approche, les modèles sont souvent considérés comme des modèles de type « boîtes noires » dans le sens où il est souvent difficile de comprendre le lien logique entre les données d'entrée consommées par le modèle et les sorties qu'il renvoie (Javed et al., 2017). C'est d'autant plus le cas lorsqu'il s'agit de modèle d'apprentissage comme les réseaux de neurones.

Les modèles basés sur les données sont les plus représentés dans la littérature due à leur facilité d'application, leurs faibles coûts d'implémentation et le peu de connaissances intrinsèques de l'équipement qu'elles requièrent (Elattar et al., 2016).

Bien qu'il existe une grande variété de modèles par apprentissage utilisés dans les systèmes de pronostic, leur méthodologie de développement est assez similaire. Une méthodologie est proposée par Atamuradov et al. (Atamuradov et al., 2017a) est proposée dans la Figure 1.16.

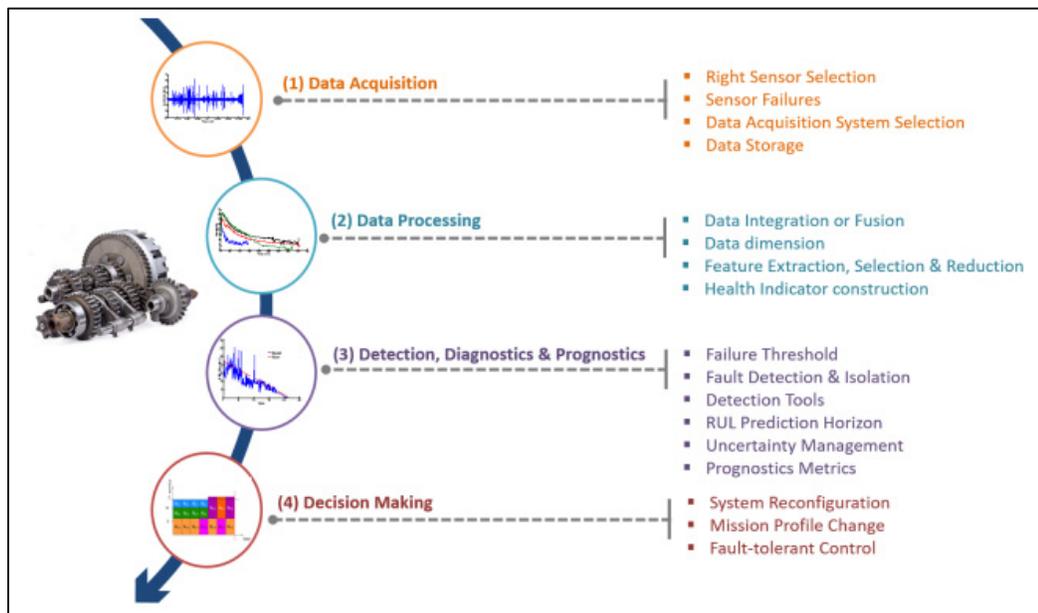


Figure 1.16 Étapes du processus de pronostic et leurs principaux challenges (Atamuradov et al., 2017a)

La première étape consiste à réaliser l'acquisition et le prétraitement des données pertinentes à la prédiction de l'occurrence du ou des modes de défaillances du système d'étude. Il peut s'agir de données relatives à l'état de santé (mesures ou inspection), à certaines caractéristiques spécifiques, au niveau de charge ou à l'environnement du système d'étude. Afin que le système de pronostic puisse les traiter, l'ensemble des données d'entrée doivent être normalisées. Il est aussi recommandé de nettoyer et d'appliquer des tests sur les données pour identifier des données aberrantes ou des incertitudes et biais pouvant venir d'un défaut de capteurs ou autres.

Certaines caractéristiques peuvent être extraites pour réduire la quantité des données acquises en temps réel (ex : niveau RMS pour les capteurs de vibrations). La Figure 1.17 illustre cette étape de prétraitement des données.

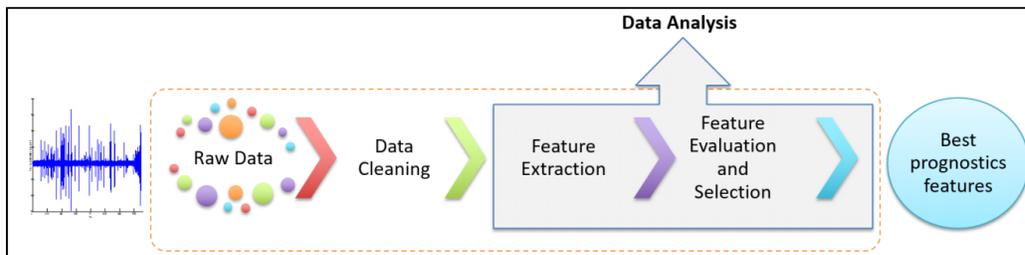


Figure 1.17 Processus de prétraitement des données  
(Atamuradov et al., 2017a)

La deuxième étape consiste à détecter la présence de défauts sur l'équipement d'étude. On parle alors de la partie diagnostic. Il s'agit à la fois de détecter la présence d'une condition anormale, mais aussi d'identifier le ou les défauts à l'origine de ces anomalies. Pour cela, des algorithmes de détection sont appliqués sur les données au cours de la vie de l'équipement. Lorsque des connaissances de l'équipement sont présentes, il est recommandé d'identifier les principales caractéristiques d'état (défauts, anomalies) à l'aide d'experts. Les algorithmes peuvent être de différentes formes : seuils, règles logiques, algorithmes de regroupement par apprentissage (ex : *Principal Component Analysis* (PCA), *Radom Forest* (RF), *k-Nearest neighbour* (kNN), *Artificial Neural networks* (ANN), *Deep Neural networks*, *Support Vector Machines* (SVM), etc.). Liu Ruonan et al. (Liu, Yang, Zio, & Chen, 2018) ont proposé une analyse des forces, faiblesses et performances des algorithmes de classifications par apprentissage tels que présenté dans le Tableau 1.4 et Tableau 1.5 . Pour plus d'information sur ces algorithmes, il est recommandé de se référer à l'article de revue proposé par Liu et al. (Liu et al., 2018).

Tableau 1.4 Forces et faiblesses des principaux algorithmes de détection de défauts par apprentissage (Liu et al., 2018)

Algorithm	Advantages	Limitations
<i>k</i> -NN	<ol style="list-style-type: none"> <li>1. Mature theory and easy to implement</li> <li>2. Can be used for both classification and regression</li> </ol>	<ol style="list-style-type: none"> <li>1. Large computation</li> <li>2. Needs lots of storage space</li> <li>3. The selection of <i>k</i> influence rightarrow too much</li> </ol>
Naive Bayes	<ol style="list-style-type: none"> <li>1. Robust to missing values</li> <li>2. Requires little storage space</li> <li>3. Good physical explanation ability</li> </ol>	<ol style="list-style-type: none"> <li>1. Strong prior assumptions</li> <li>2. Combinatorial explosion and computation problem</li> <li>3. Need of prior probability</li> </ol>
SVM	<ol style="list-style-type: none"> <li>1. High classification accuracy</li> <li>2. Can deal with high-dimensional features</li> </ol>	<ol style="list-style-type: none"> <li>1. Low efficiency for big data</li> <li>2. No physical meaning</li> </ol>
ANN	<ol style="list-style-type: none"> <li>1. High classification accuracy</li> <li>2. Good approximation of complex nonlinear function</li> </ol>	<ol style="list-style-type: none"> <li>1. Many parameters and easy to over-fitting</li> <li>2. No physical meaning</li> <li>3. Training procedure cannot be seen</li> </ol>
Deep learning	<ol style="list-style-type: none"> <li>1. Learning features and recognizing fault automatically</li> <li>2. Learning more complex structure from data due to the deep architecture</li> <li>3. Do not need the feature extractor</li> </ol>	<ol style="list-style-type: none"> <li>1. Needs of large samples</li> <li>2. No physical meaning</li> <li>3. Training for long time</li> </ol>

Tableau 1.5 Performances des principaux algorithmes de détection de défauts par apprentissage (Liu et al., 2018)

	ANN	SVM	<i>k</i> -NN	Naive Bayes	Deep learning
Accuracy in general	***	****	**	*	****
Classification speed	****	****	*	****	**
Robustness to noise	**	**	*	***	****
Dealing with overfitting	*	**	***	***	***
Physical explanation	*	*	***	****	*
Robustness to parameters	*	*	***	****	**

Une fois l'estimation de l'état actuel réalisée, la prochaine étape consiste à estimer le temps entre l'état actuel et l'occurrence d'un mode de défaillance de l'équipement : le pronostic. Au niveau des approches basées sur les données, les modèles de pronostic ont des méthodes d'estimation différentes. Une partie de ces méthodes sont recensées avec leurs avantages et inconvénients dans le Tableau 1.6 ci-dessous proposé par Peng et al.(Peng, Dong, & Zuo, 2010).

Tableau 1.6 Principales méthodes des approches basées sur les données utilisées pour le pronostic (Peng et al., 2010)

Category	Methods	Supportive techniques	Application domains	Advantages	Disadvantages	References
Data-driven model	ANN	BP, DWNN, PNN, SOM	Bearing, gearbox, power plant, aircraft actuator, gear plate	Model analytically difficult system, able to implement accurate and fast on-line pattern recognition	Hard to fit domain knowledge to ANN, model retraining is needed if operating conditions change, black box system	Zhang and Ganesan [37] Yam et al. [38] Byington et al. [39] Khawaja et al. [40] Wang et al. [42] Gebraeel et al. [43] Parker et al. [44] Huang and Xi [47]
		Bayesian network-related method	Bearing, drill-bits	Have a well-constructed theoretical basis, easy to predict further states	A lot of historical state transition and fatal data are needed	Sheppard et al. [49] Przytula and Choi [50] Gebraeel et al. [34] Dong and Yang [51]
	State space model	HMM, HSMM	Pumps, aircraft system, drilling process	Reveal the hidden states change processes, easy to realize in software	The assumptions in HMM are not practical in real world, HSMM relax the assumptions but complicate the model	Baruah and Chinnam [54] Zhang et al. [53] Camci [55] Dong and He [59, 60]
	Hazard rate, proportional hazard rate	Statistical techniques such as maximum likelihood function	Pumps, turbine	A general model without making much specific assumptions	The application is restricted by the assumption of "good-as-new after repair"	Wang [30] Victor et al. [63] Lloyd et al. [65] Liao et al. [66] Li et al. [67]
	Gray model	GM (1, 1)	Production process, electric system	Deal with incomplete information, good at smoothing time series data	A new introduced method in prognostics, more research and demonstration is need	Ku and Huang [70] Gu et al. [71]

Atamuradov et al. propose une analyse similaire dans un article récent datant de 2017 tel que présenté dans le Tableau 1.7.

Tableau 1.7 Analyse des méthodes de pronostic basées sur les données (Atamuradov et al., 2017a)

Prognostics Tools	Advantages	Disadvantages	Application
ARIMA Models	-Applicable to linear systems with stationary behavior -Uses less amount of data	-Short term prediction -Not useful for non-stationary processes	- Rotating machinery
Match Matrix (MM)	-Deals with high dimensional data -Provides long term prediction -Suitable for non-stationary processes	-Needs sufficient historical data -Data should have degradation trend	- Rotating machinery
Gaussian Mixture (GM)	-Many Gaussian functions can be used to approximate an arbitrary distribution and accuracy	-Initialization methods are important in parameter optimization -Determining number of mixtures is difficult	- Bearings, CNC machines
Gaussian Process Regression (GPR)	-Adaptable to environment and can learn from experience	-Needs covariance function determination -Suitable for Gaussian likely hood	- Nuclear power plants, batteries
Artificial Neural Networks (ANN)	-Applicable for complex systems and which have non-linear behavior -Adaptable to the system	-Network structure is not determinable -Needs resources for computation	- Bearings, batteries, turnout point machines
Fuzzy Logic (FL)	-Inputs can be imprecise noisy/incomplete -Appropriate for complex systems	-Needs rule development based on expert knowledge	- Bearings
Bayesian Networks (BN)	-The number of structure parameters are reduced by conditional probability distribution -Visualizes variable pair dependency links	-Has complex and costly learning -Prior knowledge is needed	- Bearings

L'analyse des méthodes proposées ci-dessus montre que le choix de l'algorithme de pronostic doit être basé sur le contexte opérationnel de l'équipement d'étude. Il est important de bien identifier les données disponibles incluant leurs qualités, les connaissances présentes et l'horizon nécessaire du modèle de pronostic pour atteindre les besoins opérationnels. Les algorithmes de type *Artificial Neural Network* nécessitent une quantité importante de données de qualité, mais ne nécessitent pas de connaissance intrinsèque à l'équipement. Ils permettent de prédire des défaillances même pour des équipements extrêmement complexes comportant de nombreux composants et de nombreux mécanismes de dégradation. Par leurs capacités à suivre de nombreuses caractéristiques, ils permettent aussi de prévenir à un certain niveau de conditions nouvelles dans le cas où de nombreuses données sont disponibles. Cependant, ces algorithmes sont généralement plus performants pour des prédictions court-termes. Il est aussi difficile de comprendre le raisonnement de leurs prédictions par leur estimation de type « *black box* ».

Les méthodes utilisant des graphes d'état tels que les réseaux bayésiens ou les chaînes de Markov cachées (HMM ou HSMM) nécessitent elles aussi une quantité importante de données, mais restent performantes avec des échantillons de données plus réduits que ceux que nécessitent les méthodes de type ANN. L'utilisation de graphes d'états nécessite une certaine connaissance intrinsèque de l'équipement. Le principal avantage de ces approches réside dans la transparence de leur processus. Elles permettent une meilleure compréhension des prédictions ce qui permet aux experts d'améliorer les modèles au cours du temps. Elles permettent de réaliser des prédictions relativement longs termes par leur capacité à pouvoir suivre un grand nombre d'états de dégradation dont certains peuvent être assez éloignés des modes de défaillance. Cependant, tel que mentionné par Peng et al. (Peng et al., 2010), il est important de bien comprendre les hypothèses sous-jacentes à ces méthodes. En effet, ces approches ont été initialement développées pour optimiser les chaînes de production. Les hypothèses qui les régissent ne sont souvent pas compatibles avec la propagation de dégradation concurrente et indépendante. La modification de ces hypothèses peut impliquer des résolutions mathématiques complexes.

Les méthodes de pronostic basées sur des statistiques ou des régressions ont déjà été traitées dans la section 1.4.3.

Pour conclure, les approches de pronostics basés sur les données nécessitent en grandes parties une quantité importante de données de qualité. Elles sont les plus utilisées dans la littérature pour leur simplicité d'application et le peu de connaissances intrinsèques aux équipements qu'elles requièrent. Elles permettent d'obtenir des modèles pouvant traiter une quantité importante de données hétérogènes. Cependant, dans le contexte industriel, les données historiques de défaillance et de capteurs sont souvent encore peu disponibles et rarement de bonne qualité.

#### 1.4.5 Approche de pronostic basée sur la physique de défaillance (PoF)

Comment quantifier de manière dynamique la probabilité d'occurrence des modes de défaillance lorsque les données historiques sont rares? Comme indiqué dans la section précédente, les technologies PHM proposent des approches attrayantes. À la différence des approches basées sur les données, les approches PoF peuvent être appliquées même si les données historiques sont rares. Elles se basent sur la compréhension des processus de dégradation et sont conçues pour modéliser les mécanismes de défaillance des équipements basés sur les connaissances de la physique, en appliquant les lois physiques et les modèles mathématiques existants (Gu & Pecht, 2008). Dans de telles approches, les données de diagnostic sont utilisées pour mettre à jour l'estimation de l'état à la date de prédiction, surveiller les conditions de charge ou affiner certains paramètres spécifiques du modèle (approche hybride) (Javed et al., 2017). Plusieurs travaux notables ont été publiés sur les approches PoF dans la littérature, notamment dans le domaine du pronostic des batteries (C. Kulkarni, Ceyla, Biswas, & Goebel, 2012; C. S. Kulkarni, Biswas, Celaya, & Goebel, 2013), des matériaux composites (Juan Chiachío, Manuel Chiachío, Shankar Sankararaman, Abhinav Saxena, & Kai Goebel, 2015; Manuel Chiachío, Chiachío, Sankararaman, Goebel, & Andrews, 2017) et des métaux (Corbetta, Sbarufatti, Manes, & Giglio, 2014, 2015). Gu et Pecht (Gu et al., 2008) ont proposé une méthodologie générique pour les modèles pronostiques PoF basée sur l'analyse des modes, des mécanismes de défaillance et de leurs effets qui ont ensuite été adaptés par Kwon et al. (Kwon et al., 2016) comme présentée dans la Figure 1.18.

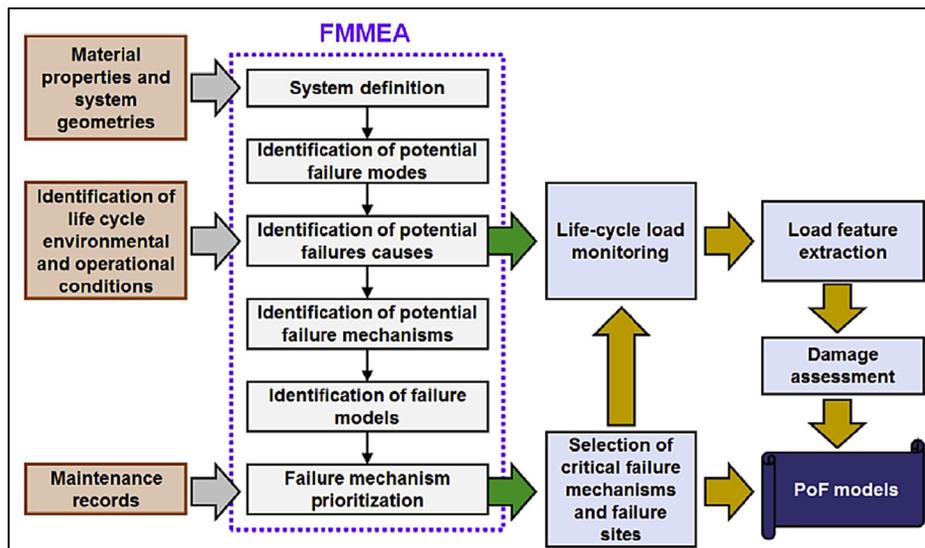


Figure 1.18. Méthodologie PHM basée sur les modèles physiques (Kwon et al., 2016)

L'analyse des modes, de leurs mécanismes de défaillance et de leurs effets (AMMDE) a été définie par Pecht (Pecht, 1999) en 1999 comme une extension à l'analyse des modes de défaillance et d'effets (AMDE). Le but de l'AMMDE est d'identifier et de modéliser les mécanismes de défaillance (processus par lesquels une combinaison de contraintes physiques conduit à un mode de défaillance (Pecht, 1999)) et les hiérarchiser en termes de criticité. Dans cette recherche, nous considérons qu'un mode de défaillance est un effet par lequel une défaillance est observée sur l'équipement (International Standard, 2012). Selon Gu et Pecht (Gu et al., 2008), les modèles de pronostic PoF permettent d'actualiser les prédictions de l'occurrence d'une défaillance en combinant les données relatives au niveau de charges, aux inspections et mesures avec des modèles de mécanisme de défaillance (Gu et al., 2008; Kwon et al., 2016).

Les modèles de PoF sont généralement appliqués au niveau des composants et modélisent les mécanismes de défaillance de manière indépendante. Par conséquent, ces modèles ont une applicabilité limitée aux équipements complexes (Compare et al., 2017; Zeng et al., 2017). Par exemple, des travaux récents ont été proposés sur l'utilisation de méthodes d'arbre de

défaillances pour combiner l'estimation de la durée de vie utile restante (RUL) de chaque équipement. (Gomes et al., 2013) ou la méthode de fiabilité inverse du premier ordre (inverse-FORM) pour propager les incertitudes et calculer les limites de crédibilité lors de la prévision au niveau du système (Khorasgani, Biswas, & Sankararaman, 2016). Cependant, plusieurs contributions ont discuté de la nécessité de développer des modèles de pronostic pour des équipements complexes prenant en compte la complexité de la propagation des mécanismes de défaillance. (Javed et al., 2017; Sikorska et al., 2011). Récemment, de nombreux articles ont été écrits sur des modèles de dégradation multi états (Normand Amyot, Hudon, Lévesque, Bélec, Brabant et al., 2013a; Compare et al., 2017; Fink et al., 2015; Wang, Di Maio, & Zio, 2016; Wang, Maio, & Zio, 2017; Zeng et al., 2017).

Les modèles de dégradation multi états sont conçus pour discrétiser les mécanismes de défaillance en une succession d'états identifiés par des indicateurs de dégradation (symptômes, signes avant-coureurs, etc.). (Compare et al., 2017). Avec de tels modèles, les processus complexes de dégradation des équipements peuvent être représentés (Fink et al., 2015). De nombreux modèles de dégradation multi états ont été proposés en utilisant des degrés de dégradation (par exemple, états neufs, états relativement dégradés, états fortement dégradés et états de défaillance (Compare et al., 2017; Li, Chen, Yuan, Tang, & Kang, 2017)), très peu de contributions sur le pronostic ont été trouvées sur les modèles de dégradation multi états en mettant l'accent sur l'analyse de la propagation du mécanisme de défaillance via l'utilisation d'informations de diagnostic hétérogènes (par exemple, inspections visuelles et capteurs).

Chemweno et al. (Chemweno, Pintelon, Muchiri, & Van Horenbeek, 2018) ont proposé une analyse des méthodes de modélisation de la fiabilité dans le contexte de l'évaluation des risques. Sur la base de cette étude, deux approches principales semblent s'appliquer aux graphes de causalité dans un processus de propagation stochastique : les réseaux dynamiques bayésiens et les réseaux de Petri stochastiques (SPN).

Les réseaux de Petri ont été introduits par Carl Adam Petri en 1966 (Petri, 1966). Les PN sont des graphes directs bipartites principalement utilisés pour modéliser des systèmes dynamiques multi états dans diverses disciplines. Les graphes d'un PN consistent en deux types de nœuds; transitions et lieux liés par des arcs ou des arêtes. Un lieu peut être utilisé pour spécifier l'état actuel d'un système et est visité par des jetons qui se propagent d'un endroit à l'autre, comme défini par le PN. Les transitions permettent de représenter le comportement dynamique du système. Ils comportent des transitions temporelles d'un endroit à un autre (Manuel Chiachío et al., 2017). Une illustration d'un réseau de Petri est présentée dans la Figure 1.19.

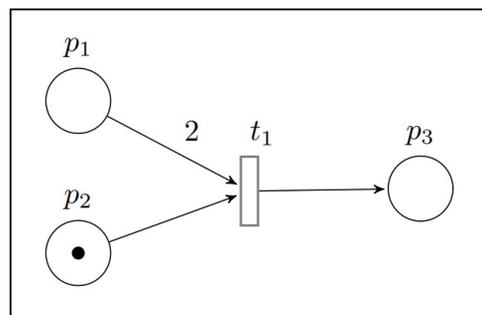


Figure 1.19 Illustration d'un réseau de Petri comportant 3 places et une transition (Manuel Chiachío et al., 2017)

Pour plus d'informations, plusieurs références présentent le formalisme des réseaux de Pétri (Manuel Chiachío et al., 2017; Murata, 1989; Peterson, 1981). Dans la continuité des PN, Chiachío et al. (Manuel Chiachío et al., 2017) ont introduit un cadre mathématique pour la modélisation des pronostics au niveau système basé sur le formalisme plausible du réseau de Petri (PPN). Le modèle intègre des actions de maintenance, diverses informations de pronostics, des connaissances d'experts et la disponibilité des ressources. Pour ce faire, deux formes de sous-réseau en interaction sont introduites: le sous-réseau symbolique (unités mobiles entières) et le sous-réseau numérique (états d'information). La Figure 1.20 en propose une illustration.

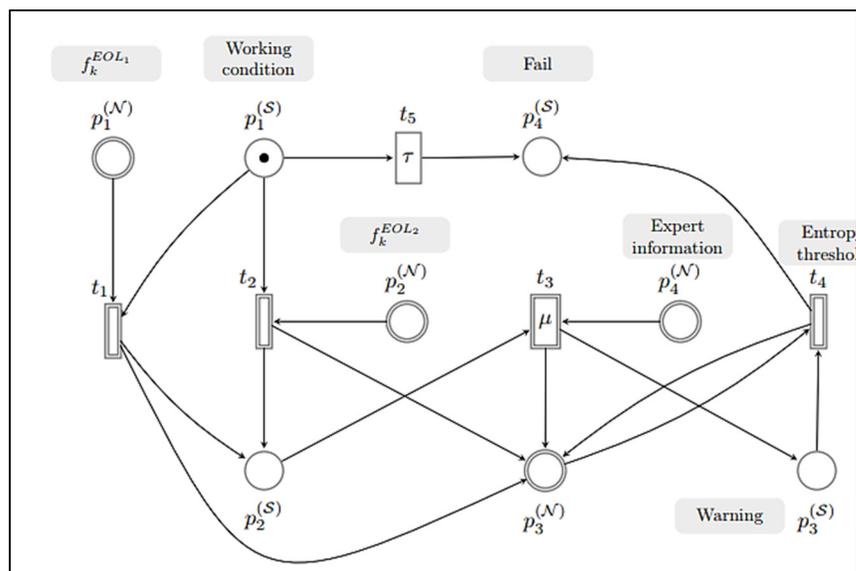


Figure 1.20 Illustration du "Plausible Petri Net" proposé par Chiachio et al. (Manuel Chiachío et al., 2017)

Le modèle prédit la fin de vie de différentes composantes en tenant compte du processus global. Des résultats de cette approche sont présentés dans la Figure 1.21 ci-dessous.

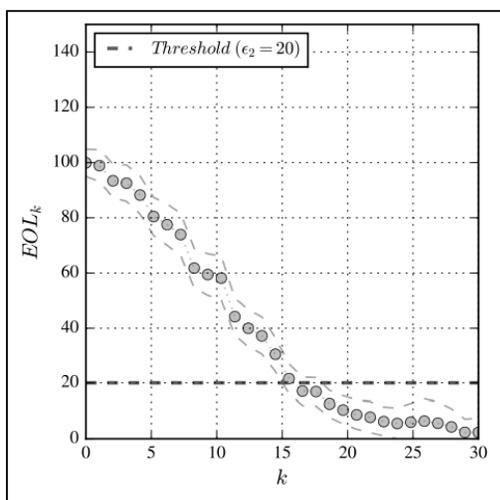


Figure 1.21 Illustration de résultats de pronostic par une approche de « Plausible Petri Net » (Manuel Chiachío et al., 2017)

Il s'appuie sur des connaissances et des données de diagnostic. Des actions de maintenance peuvent être recommandées et une défaillance de composant individuel peut être prédite. Cependant, l'approche ne permet pas d'identifier les mécanismes de défaillance physique qui conduisent au mode de défaillance des composants.

Medjaher et al. (Medjaher, Moya, & Zerhouni, 2009) ont proposé une approche de pronostic de défaillance en utilisant des réseaux bayésiens dynamiques (DBN). La structure DBN est définie par des experts et est composée d'événements de dégradation (issus de différentes composantes du système) liés par des relations causales temporelles conduisant à une défaillance du système. Les tables de probabilités conditionnelles (relations causales temporelles, par exemple) sont quantifiées en fonction de trois types d'informations: des analyses statistiques à partir de données historiques, le jugement d'experts et les lois physiques. Une illustration du réseau bayésien dynamique est proposée dans la Figure 1.22.

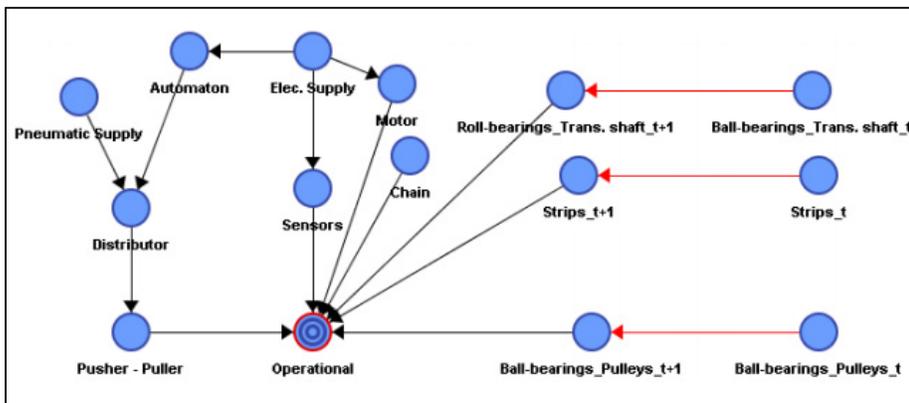


Figure 1.22 Illustration de pronostic d'un système par un réseau bayésien dynamique (Medjaher et al., 2009)

Les simulations du DBN conduisent à une estimation de la fiabilité du système qui prend en compte tous les mécanismes de défaillance. Dans ce projet, les données des capteurs n'ont pas été utilisées pour actualiser l'état estimé de l'équipement pour une date de prédiction donnée,

ce qui, selon les auteurs, constitue un de leurs défis majeurs. De plus, les modes de défaillance du système étaient considérés comme un seul état de défaillance.

Zeng et al. (Zeng et al., 2017) ont proposé une méthode de modélisation de l'interaction entre mécanismes de défaillance basée sur trois relations fondamentales: concurrence, superposition et couplage. Par exemple, la relation de concurrence suppose que deux mécanismes de défaillance sont indépendants et que le délai de défaillance du système correspond au délai minimal de défaillance des différents mécanismes de défaillance actifs. Leur approche est illustrée dans la Figure 1.23.

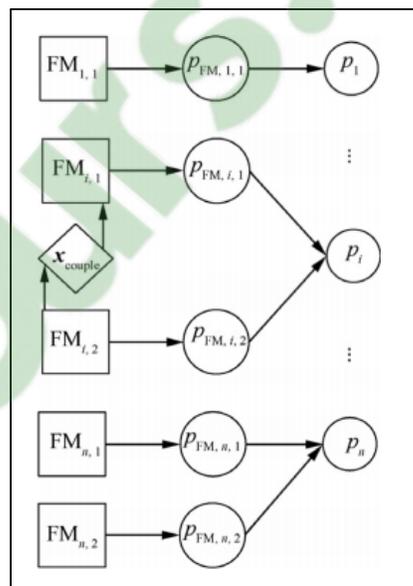


Figure 1.23 Illustration du graphe d'interactions entre plusieurs mécanismes de défaillance (Zeng et al., 2017)

Ces mécanismes de défaillance peuvent contribuer aux mêmes modes de défaillance (superposition) ou à la présence d'un mécanisme de défaillance ayant une incidence sur les autres mécanismes de défaillance (couplage). Sur la base de la littérature recensée à ce jour, peu de modèles de pronostic prenant en compte tous les mécanismes de défaillance possibles

et des informations de diagnostic provenant de différentes sources (mesures et inspections, par exemple) ont été proposés pour modéliser un équipement complexe en tant que système.

Amyot et al. (N Amyot, Hudon, Lévesque, Bélec, Brabant et al., 2014) ont proposé une approche basée sur l'analyse des symptômes et des mécanismes de défaillance (FMSA). Cette approche pourrait être considérée comme une extension de l'approche FMMEA et une partie de l'approche PoF. À l'instar des approches FMMEA et PoF, tous les mécanismes de défaillance conduisant aux divers modes de défaillance d'équipement sont identifiés à l'aide des résultats de la FMEA et de consultations d'experts. L'approche FMSA structure les mécanismes de défaillance au moyen de graphes de causalité partant de causes initiales physiques, passant par une succession d'états physiques discrétisés interdépendants et se terminant par des modes de défaillance d'équipement. Chaque état physique représente un événement discret de dégradation. D'après Amyot et al. (N Amyot et al., 2014), un mécanisme de défaillance est alors défini comme chemin unique qui s'initie d'une cause physique initiale et qui se termine par l'occurrence d'un mode de défaillance. De nombreux mécanismes de défaillance peuvent conduire au même mode de défaillance et un état physique peut être présent dans plusieurs mécanismes de défaillance. Blancke et al. (Olivier Blancke, Amyot, Hudon, Lévesque, & Tahan, 2015) ont proposé une méthodologie efficace pour construire un tel graphe de causalité. Chaque état physique est ensuite identifié par un algorithme de détection unique qui utilise une combinaison de symptômes observables par des outils de diagnostic ou des données d'inspection. Le modèle résultant détecte et suit les mécanismes de défaillance de manière dynamique au niveau du système à mesure que de nouvelles informations deviennent disponibles. Cette approche de diagnostic n'a pas encore été étendue à une approche de pronostic.

### **1.5 Approche de maintenance prévisionnelle (aide à la décision post-pronostic)**

La maintenance prévisionnelle est une discipline qui permet de planifier des actions de maintenance basées sur des modèles de pronostics. Du point de vue de l'organisation, elle fait

partie intégrante du processus de gestion des actifs défini comme un ensemble d'activités coordonnées d'une organisation visant à réaliser la valeur des actifs (ISO, 2014). Contrairement aux approches de maintenance préventive ou de maintenance basée sur la fiabilité, les approches de maintenance prédictive prennent en compte les aspects dynamiques et individuels des données de chaque actif. Des actions de maintenance sont ensuite proposées à l'avance pour éviter que les modes de défaillance ne se produisent. Les algorithmes permettant la maintenance prévisionnelle peuvent être considérés comme partie intégrante du pronostic comme illustré dans la Figure 1.24. La maintenance prévisionnelle fait partie de l'aide à la décision post-pronostic en identifiant les actions à prendre aux vues de la prédiction de mode de défaillance.

Afin de garantir la planification stratégique au sein de la flotte, différents aspects doivent également être pris en compte pour optimiser la planification de la maintenance, telle que la criticité des équipements dans leur système, les contraintes de ressources opérationnelles, les objectifs organisationnels, pour ne citer que quelques exemples (IAM, 2015).

La propagation des mécanismes de défaillance peut également impliquer plusieurs composants et divers outils de diagnostic peuvent être utilisés pour les détecter et les suivre à différents niveaux du système. Une fois que les seuils de dégradation prédéterminés sont atteints, des actions de maintenance spécifiques doivent être entreprises pour éviter une défaillance du système. En fonction des types de mécanismes de défaillance actifs et de leur progression, les actions de maintenance peuvent ne pas avoir le même effet pour arrêter ou ralentir leur propagation vers les modes de défaillance associés. Il est donc important de comprendre comment les mécanismes se propagent lorsque nous souhaitons appliquer des tâches de maintenance spécifiques pour prolonger la durée de vie utile restante d'équipements complexes.

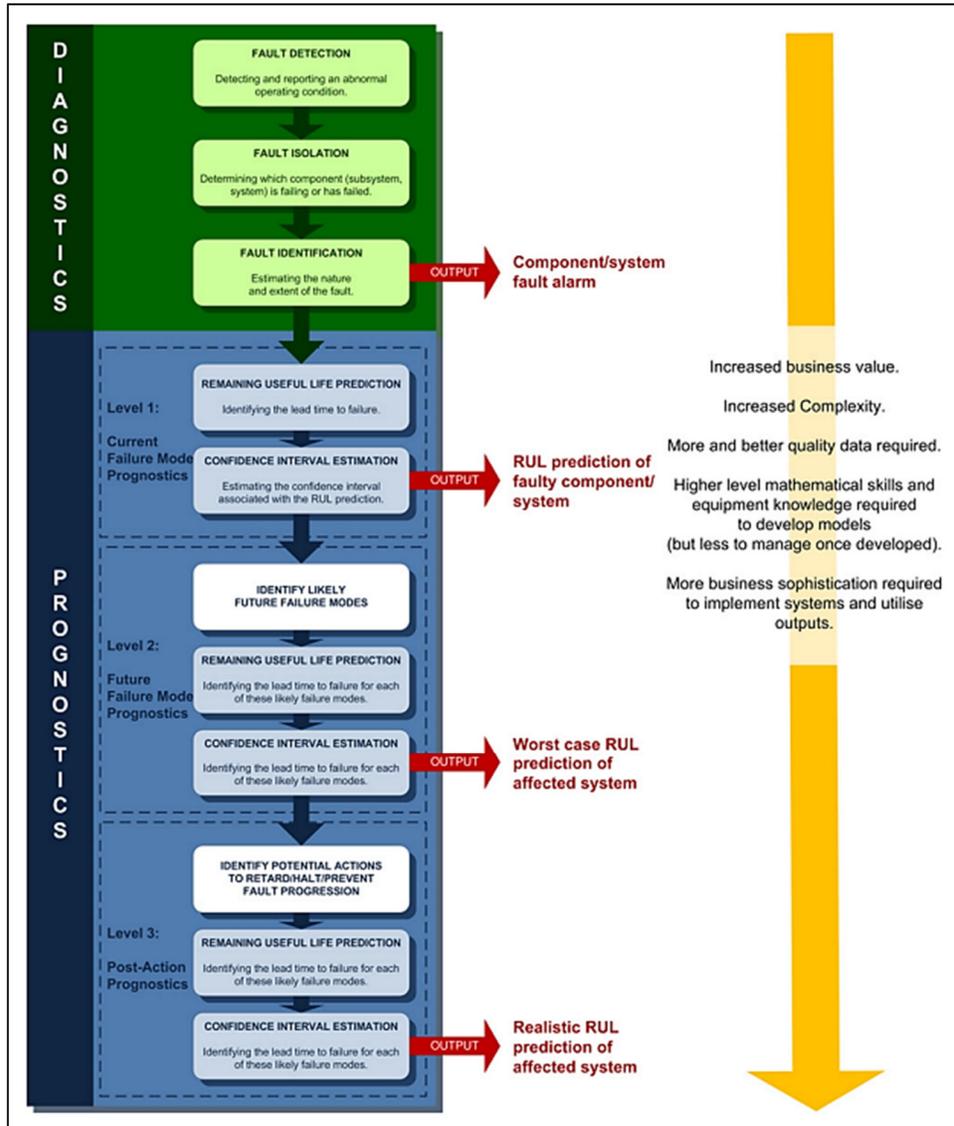


Figure 1.24 Processus du diagnostic-pronostic proposé dans la norme ISO13381 et son implication dans le processus décisionnel (Sikorska et al., 2011)

Dans la littérature, divers auteurs ont utilisé PN dans le contexte de la maintenance prédictive. Zhouhang et al. (Zhouhang, Maen, & H., 2014) ont proposé une application de PN pour modéliser l'analyse de fiabilité et de maintenance de systèmes multi états et multi unités. L'approche prend en compte 3 états de dégradation: sain, dégradé et défaillant. Le modèle PN simule la transition entre ces états dans différentes composantes. Un modèle d'arborescence de

pannes permet d'assembler différents composants dégradés ou défaillants dans le comportement du système. Il prend également en compte la disponibilité de l'opérateur de maintenance et le processus de maintenance. Dans ce travail, le modèle ne suggère pas de tâches de maintenance spécifiques, mais se concentre davantage sur les aspects opérationnels de la maintenance prédictive.

Ammour et al. (Ammour, Leclercq, Sanlaville, & Lefebvre, 2016) ont proposé une approche de pronostic de défaillance basé sur des systèmes stochastiques à événements discrets. Le PN est utilisé pour modéliser le système et ses capteurs. Des mesures ont été attachées à certains endroits du PN et une approche incrémentielle identifie des ensembles de trajectoires cohérentes basées sur des données de mesure historiques. Ensuite, sur la base de ces trajectoires de mesure du temps, le modèle PN estime l'état actuel du système et la probabilité d'occurrence d'états futurs. La Figure 1.25 présente une illustration de leur modèle.

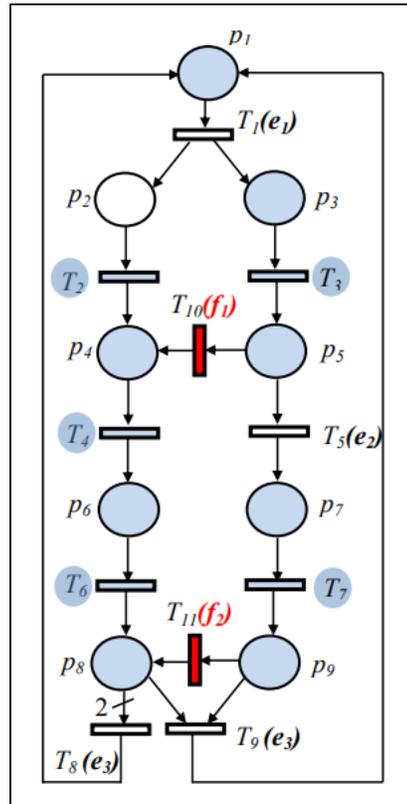


Figure 1.25 Illustration du modèle de pronostic via un réseau de Pétri (Ammour et al., 2016)

Dans cette approche, les données historiques ont été choisies pour identifier les trajectoires des mécanismes de défaillance. Toutefois, les avis d'expert du domaine n'ont pas été pris en compte. L'approche se termine par un pronostic de défaillance et n'identifie aucune action de maintenance spécifique.

Finalement, de la même référence que celle citée précédemment dans les approches de pronostic basé sur la physique, Chiachío et al. (Manuel Chiachío et al., 2017) ont proposé un cadre mathématique pour la modélisation du pronostic au niveau système basé sur le formalisme Plausible Petri Net (PPN). Le modèle intègre des actions de maintenance, diverses informations pronostiques issues de différents composants, des connaissances expertes et la disponibilité des ressources. Le modèle prédit la fin de vie de différents composants en prenant

en compte le processus global. Des tâches de maintenance peuvent être suggérées et une défaillance de composant peut être prédite. Cependant, l'approche ne permet pas d'identifier les mécanismes de défaillance physique qui conduisent à la défaillance prévue des composants.

## 1.6 Métriques de validation des modèles de pronostic

Le développement des systèmes de pronostic implique un processus rigoureux de vérification et de validation des performances des algorithmes développés afin de pouvoir déterminer si l'algorithme permet de rencontrer les spécifications définies par les utilisateurs. Cette partie vise à explorer les métriques de performances existantes dans la littérature permettant l'analyse des performances des algorithmes de pronostic dans un contexte industriel. Ces métriques ont principalement deux objectifs:

- Permettre de s'assurer que les spécifications utilisateurs sont rencontrées;
- Permettre d'orienter et d'améliorer le développement des systèmes de pronostic;

### 1.6.1 Classification fonctionnelle des métriques de performance des systèmes de pronostic

Les métriques de performance des systèmes de pronostic peuvent être classifiées temporellement suivant la partie du système de pronostic qu'elles évaluent. Il existe des métriques pour évaluer les capacités d'un algorithme à détecter un défaut, des métriques permettant d'évaluer le temps de réponse, l'horizon ou encore la précision de la prédiction.

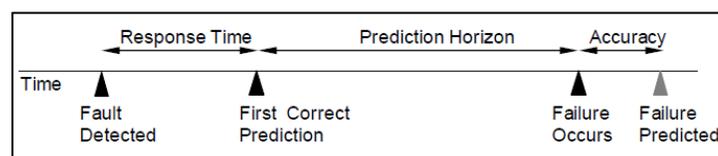


Figure 1.26 Temps nécessaires à un algorithme de pronostic pour fournir une prédiction (Saxena et al., 2010)

Différents auteurs en ont proposé une classification tels que Saxena et al. (Saxena et al., 2010) et Zhou et al. (Zhou, Bo, Jie, & Mingwei, 2013). Elles sont illustrées dans les Figure 1.27 et Figure 1.28.

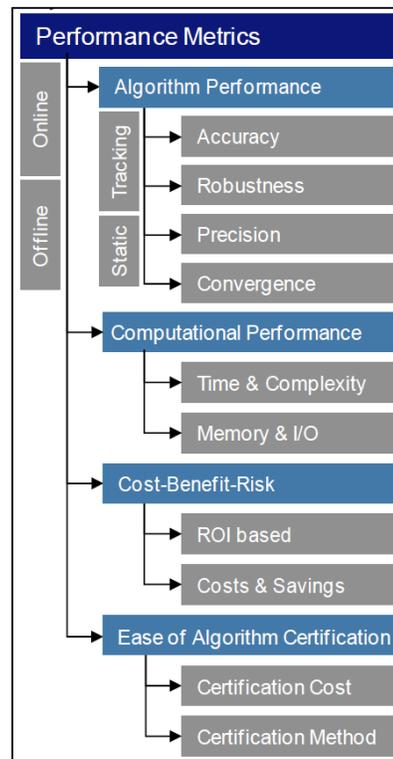


Figure 1.27 Saxena et al.  
classification des métriques  
de performances  
(Saxena et al., 2010)

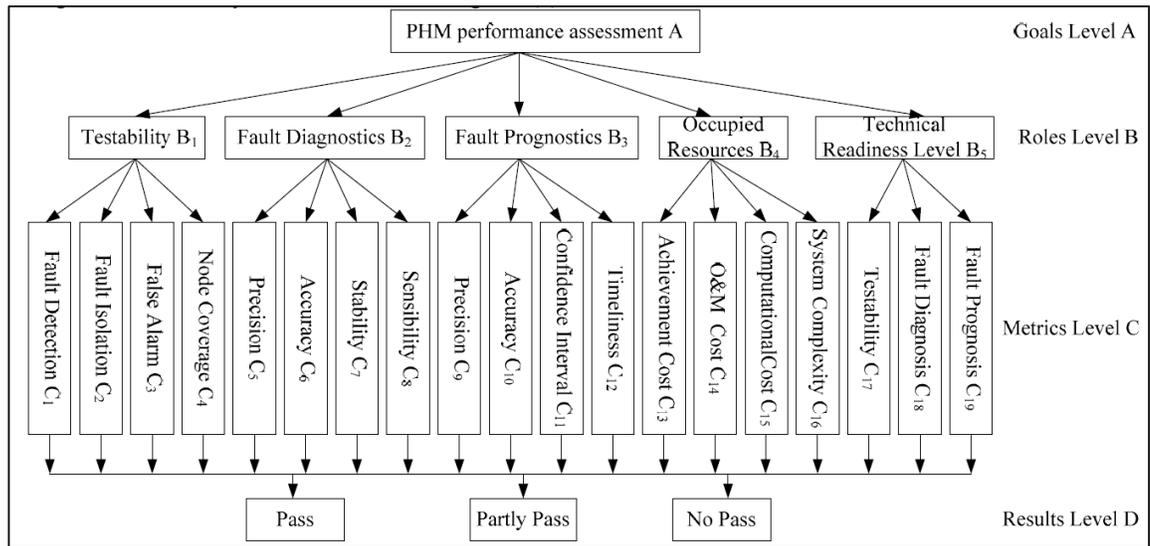


Figure 1.28 Zhou et al. Classification des métriques de performances (Zhou et al., 2013)

Selon les besoins et les spécifications des systèmes de pronostic, ces différentes catégories de métriques peuvent être utilisées. Concernant les performances des algorithmes, les termes suivants ont été définis:

- Précision (anglais: *accuracy*): évaluer le degré de proximité des prévisions par rapport au temps de défaillance réel (Kai Goebel, Saxena, Saha, Saha, & Celaya, 2011);
- Justesse (anglais: *precision*): est définie comme l'étendue des prédictions effectuées au même moment (Kai Goebel et al., 2011);
- Robustness: ce terme est défini par Goebel et al. (Kai Goebel et al., 2011) comme la sensibilité des prédictions avec les changements des variations des paramètres de l'algorithme ou des perturbations externes;
- Convergence: Convergence exprime le taux auquel les métriques (M) – tels que la précision (anglais: *accuracy*) ou justesse (anglais: *precision*) – s'améliorent avec le temps à mesure que de nouvelles informations sont acquises dans le système d'étude.
- Rapidité (anglais : *timeliness*): Disponibilité et convivialité d'un algorithme de pronostic, rapidité avec laquelle un algorithme pronostique pourrait produire ses résultats (Saxena et al., 2014).

## 1.6.2 Les métriques de performances du pronostic *Offline*

Évaluation du pronostic *Offline*: inclus des méthodes qui nécessitent d'acquérir des connaissances sur la date ou l'heure et la nature réelles d'un événement et, par conséquent, se rapportent à l'analyse post mortem (K.; Goebel et al., 2017).

Les métriques *offlines*, permettent d'analyser les performances des algorithmes de pronostic en confrontant leurs résultats à des données historiques de défaillance. Il peut sembler que ces métriques ont une utilité limitée pour le domaine opérationnel. Cependant elles jouent un rôle crucial dans le développement des algorithmes. Elles permettent l'amélioration des algorithmes en procurant un retour d'expérience aux équipes de développement sur les améliorations et divergences des algorithmes au cours de leur développement sur différents cas d'études (K.; Goebel et al., 2017).

### 1.6.2.1 Les métriques basées sur la précision (anglais: *accuracy*) et la justesse (anglais: *precision*):

Les principales applications de prédictions utilisent des métriques basées sur la précision (*accuracy*) et la justesse (*precision*). Elles sont très souvent ajustées et adaptées pour répondre aux besoins spécifiques des applications. En finance, différentes métriques sont utilisées pour exploiter les quantités importantes de données disponibles telles que *Mean Squared Error* (MSE) ou encore *Standard Deviation* (SD) (K.; Goebel et al., 2017). Le chapitre 9 du rapport IVHM de la NASA (Drucker) en donne une bonne synthèse telle que présentée dans la Tableau 1.8.

Tableau 1.8 Métriques basées sur la précision (anglais: *accuracy*) et la justesse (anglais: *precision*) (Drucker)

<b>Accuracy and Precision Measures</b>	
Error	<p>Error defines the basic notion of deviation from desired output. Applications where estimates of fault dimension are computed, such as crack length or bearing spall size, typically use estimation error as a metric of diagnostic performance.</p> <p><math>\Delta = \text{Measured Ground Truth} - \text{Diagnostic Estimate}</math></p> <p>Most accuracy based metrics are derived directly or indirectly from error as defined below.</p>
Error Based Metrics (Hyndman & Koehler, 2006)	<p>Several metrics are defined to aggregate errors (<math>\Delta</math>) into absolute or weighted measures. Aggregates can be computed over multiple systems (<math>l</math>) (e.g. in a fleet scenario) or over multiple test cases (<math>i</math>) for a single system over time. Some representative examples are given here, but many more metrics exist that can be useful in different cases.</p> <p>Mean Squared Error (MSE) <math>MSE(i) = \frac{1}{L} \sum_{l=1}^L \Delta^l(i)^2</math></p> <p>Mean Absolute Error (MAE) <math>MAE(i) = \frac{1}{L} \sum_{l=1}^L  \Delta^l(i) </math></p> <p>Root Mean Squared Percentage Error (RMSPE) <math>RMSPE(i) = \sqrt{\frac{1}{L} \sum_{l=1}^L \left  \frac{100\Delta^l(i)}{r^l(i)} \right ^2}</math></p> <p>Mean Absolute percentage Error (MAPE) <math>MAPE(i) = \frac{1}{L} \sum_{l=1}^L \left  \frac{100\Delta^l(i)}{r^l(i)} \right </math></p>
Precision Based Metrics (Hoaglin et al., 1983)	<p>Precision in estimation is estimated by computing spread of the error around the true value. Once again, there are several variants of dispersion measures, some of which are mentioned here to exemplify. Users pick their favorite ones based on desired robustness and acceptable computational complexity in computing these measures.</p>
Sample Standard Deviation	<p>Sample standard deviation measures the dispersion/spread of the error with respect to the sample mean of the error. Technically this metric is restricted to the assumption of normal distribution of the error, which may not always be a correct assumption.</p> $S(i) = \sqrt{\frac{\sum_{l=1}^n (\Delta^l(i) - M)^2}{n-1}}$ <p>where <math>M</math> is the sample mean of the error</p>
Mean absolute deviation from the sample median (MAD)	<p>A more robust estimator of the dispersion/spread of the estimation error is MAD.</p> $MAD(i) = \frac{1}{n} \sum_{l=1}^n  \Delta^l(i) - M $ <p>where <math>M = \text{median}(\Delta^l(i))</math> and median is the <math>\frac{n+1}{2}</math><sup>th</sup> order statistic</p>

À titre d'exemple, en 2014, un article proposé par Ragab et al (Ragab, Ouali, Yacout, & Osman, 2016) utilise la *Root Mean Squared Error* (RMSE) pour comparer les performances de 3 modèles de pronostic pour un temps de prédiction donné.

Ces métriques ne considèrent pas la nature aléatoire de l'événement étudié ni les incertitudes liées au moment de sa réalisation.

### **1.6.2.2 Les métriques issues du diagnostic**

Les statistiques de performance d'une évaluation de diagnostic au niveau d'un ensemble de systèmes, collectées au cours du temps où de multiples modes de défaillance peuvent être présents sur une variété de systèmes et de composants (Drucker). Elles sont présentées dans le Tableau 1.9.

Tableau 1.9 Métriques de performances statistiques des systèmes de diagnostic (Drucker)

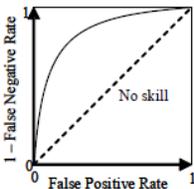
Diagnostic Performance Statistics (Rate) Metrics												
Confusion Matrix	<table border="1"> <thead> <tr> <th rowspan="2">Predicted System State</th> <th colspan="2">Actual System State</th> </tr> <tr> <th>Non-faulty</th> <th>Faulty</th> </tr> </thead> <tbody> <tr> <th>Non-faulty</th> <td><math>a</math></td> <td><math>b</math></td> </tr> <tr> <th>Faulty</th> <td><math>c</math></td> <td><math>d</math></td> </tr> </tbody> </table> <p>A confusion matrix is often constructed to document outcomes (correct or incorrect) and subsequently analyze performance of a diagnostic system. Once populated this matrix is then used to derive a variety of performance indicators commonly used in the industry. Performance is often specified as absolute correct or incorrect outcomes, or weighted to express as rates over a period of time. Some examples are given below.</p>	Predicted System State	Actual System State		Non-faulty	Faulty	Non-faulty	$a$	$b$	Faulty	$c$	$d$
Predicted System State	Actual System State											
	Non-faulty	Faulty										
Non-faulty	$a$	$b$										
Faulty	$c$	$d$										
Detection Accuracy	<p>The ratio of correctly classified cases (i.e., fault detected when the system was actually faulty, and no fault detected when the system was non-faulty) to the total number of scenarios to assess overall accuracy of the system.</p> $DA = \frac{a + d}{a + b + c + d}$											
Fault Detection Rate	<p>The ratio of cases where a fault is detected out of the total number of scenarios when the system was actually faulty.</p> $FDR = \frac{c + d}{b + d}$											
False Negative Rate	<p>The ratio of the number of times a fault is missed (goes undetected) to the number of scenarios when the system was actually faulty. Low false negatives are preferred to avoid downtime due to missed failures.</p> $FNR = \frac{b}{b + d}$											
False Positive Rate	<p>The ratio of the number of times a fault is detected to the number of scenarios when the system was actually non-faulty. Low false positive rates are desired to avoid unnecessary maintenance actions.</p> $FPR = \frac{c}{a + c}$											
False Positive Confidence Metric (M. J. Roemer <i>et al.</i> , 2005)	<p>Measures the frequency and upper confidence limit associated with false anomaly detection by a diagnostic tool. Calculation of the false confidence metric is based on the false positive function that is stated in the following equation:</p> $F(c) = n(c)/N$ <p>where,  <math>n(c)</math> – number of false positive detection events with confidence <math>&gt; c</math>,  <math>N</math> = number of opportunities to detect a normal operating condition</p>											
Receiver Operating Characteristic (ROC)	 <p>ROC gives a comprehensive overview of the tradeoff between false positives (FP) and false negatives (FN). The ideal curve would have zero false positives and zero false negatives. Such a curve cannot realistically be achieved for real-world problems and therefore, a balance must be achieved based on cost and safety priorities in a given application.</p>											

Tableau 1.9 (suite)

Diagnostic Performance Statistics (Rate) Metrics																																
Power of Test	Power of test estimates the overall bias of a diagnoser towards FPs or FNs over the entire range of the ROC curve. It is computed by calculating the area under the ROC curve, which represents the probability that a diagnoser favors false positives over false negatives in general.																															
Isolation Performance Matrix	<p>Similar to confusion matrix above a higher fidelity confusion matrix may be constructed for a system that not only detects faults but also isolates various fault modes. Absolute or rate metrics can be constructed for isolation performance as well. In the matrix shown below all elements are weighted by total number of cases, which can also be seen as probabilities if large number of cases is observed.</p> <table border="1" style="margin-left: auto; margin-right: auto;"> <thead> <tr> <th rowspan="2">Predicted State</th> <th colspan="5">Actual State</th> </tr> <tr> <th>Component</th> <th>Mode<sub>1</sub></th> <th>Mode<sub>2</sub></th> <th>...</th> <th>Mode<sub>n</sub></th> </tr> </thead> <tbody> <tr> <th>Mode<sub>1</sub></th> <td>p<sub>11</sub></td> <td>p<sub>21</sub></td> <td>...</td> <td>p<sub>n1</sub></td> </tr> <tr> <th>Mode<sub>2</sub></th> <td>p<sub>12</sub></td> <td>p<sub>22</sub></td> <td>...</td> <td>p<sub>n2</sub></td> </tr> <tr> <th>...</th> <td>...</td> <td>...</td> <td>...</td> <td>...</td> </tr> <tr> <th>Mode<sub>n</sub></th> <td>p<sub>1n</sub></td> <td>p<sub>2n</sub></td> <td>...</td> <td>p<sub>nn</sub></td> </tr> </tbody> </table>	Predicted State	Actual State					Component	Mode <sub>1</sub>	Mode <sub>2</sub>	...	Mode <sub>n</sub>	Mode <sub>1</sub>	p <sub>11</sub>	p <sub>21</sub>	...	p <sub>n1</sub>	Mode <sub>2</sub>	p <sub>12</sub>	p <sub>22</sub>	...	p <sub>n2</sub>	...	...	...	...	...	Mode <sub>n</sub>	p <sub>1n</sub>	p <sub>2n</sub>	...	p <sub>nn</sub>
Predicted State	Actual State																															
	Component	Mode <sub>1</sub>	Mode <sub>2</sub>	...	Mode <sub>n</sub>																											
Mode <sub>1</sub>	p <sub>11</sub>	p <sub>21</sub>	...	p <sub>n1</sub>																												
Mode <sub>2</sub>	p <sub>12</sub>	p <sub>22</sub>	...	p <sub>n2</sub>																												
...	...	...	...	...																												
Mode <sub>n</sub>	p <sub>1n</sub>	p <sub>2n</sub>	...	p <sub>nn</sub>																												
Isolation Classification Rate	The rate of correct classification. This metric equals to the sum of elements along the diagonal.																															
	$ICR = \sum_{i=1}^n p_{ii}$																															
Isolation Misclassification Rate	The rate of misclassification computed as the sum of all off-diagonal elements. $IMR = \sum p_{ij} \forall i \neq j$																															
Size of Isolation Set	Often times a diagnostic system does not converge on a single isolated fault but a number of possible faults with corresponding probabilities. In such cases the size of isolation set becomes a metric. A smaller size implies less ambiguity and hence preferable.																															

Ces métriques sont majoritairement utilisées pour évaluer les algorithmes de diagnostic. Cependant, pour les systèmes de pronostic, elles peuvent permettre de mettre en évidence pour des temps de prédiction donnée une « *Confusion Matrix* » mettant en valeur la part des « *False negative* » et « *False positive* » prédictions pour le parc d'actif.

### 1.6.2.3 Les métriques de performance des algorithmes de pronostic

- Métriques au niveau d'un actif :

Les métriques de performance des systèmes de pronostic au niveau d'un actif sont principalement définies en se basant sur un diagramme RUL-EOL. Le diagramme RUL-EOL

est basé sur une date de défaillance historique (EOL) et illustre pour chaque année où une prédiction de défaillance est réalisée (RUL), sa distance avec la défaillance réelle observée telle que présentée dans la Figure 1.29 Illustration d'un diagramme RUL-EOL.

RUL : *Remaining Usefull Life* - Durée de vie résiduelle (système non réparable) ou Temps avant défaillance (système réparable)

EOL : *End Of Life* – Fin de vie utile (système non réparable) ou Temps de la défaillance (système réparable)

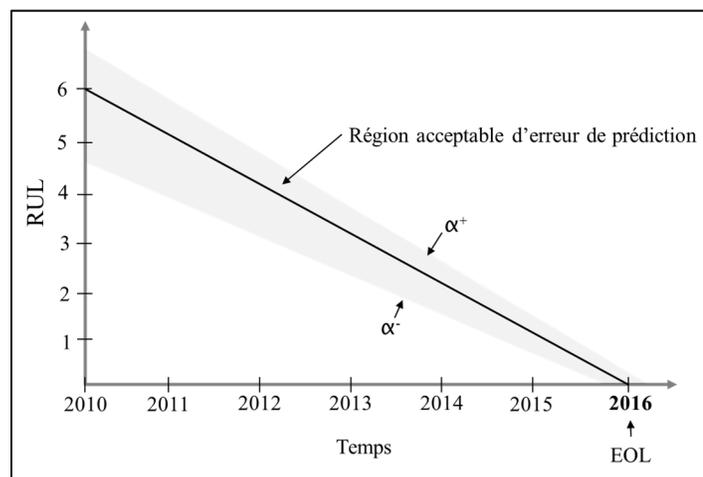


Figure 1.29 Illustration d'un diagramme RUL-EOL

À titre d'exemple théorique, le RUL-EOL diagramme est présenté ci-dessus illustre le cas d'un équipement ayant subi une défaillance en 2016 ( $EOL = 2016$ ). À l'année 2010, la défaillance se situe dans 6 années et donc en 2010. La durée de vie résiduelle de l'équipement est de 6 ans ( $RUL(2010) = 6$ ). La fonction RUL est illustrée par la fonction présentée dans l'équation (1.6).

$$RUL = EOL - t \quad (1.6)$$

Afin de pouvoir prendre des décisions basées sur un pronostic, et tenant compte de l'incertitude inhérente des résultats de pronostic, Saxena et al. (Saxena et al., 2010) ont démontré qu'il est préférable de mesurer la performance des résultats de pronostic en se basant sur une région acceptable plutôt que de mesurer la distance entre RUL et la médiane de la distribution de prédiction par exemple (Saxena, Roychoudhury, Celaya, Saha, Saha et al., 2012). La zone d'erreur acceptable de prédiction est définie par les bornes  $\alpha^-$  (temps acceptable pour une prédiction en avance) et  $\alpha^+$  (temps acceptable pour une prédiction en retard). Une illustration de ces paramètres est proposée par Saxena et al. (Saxena et al., 2012) dans la Figure 1.30.

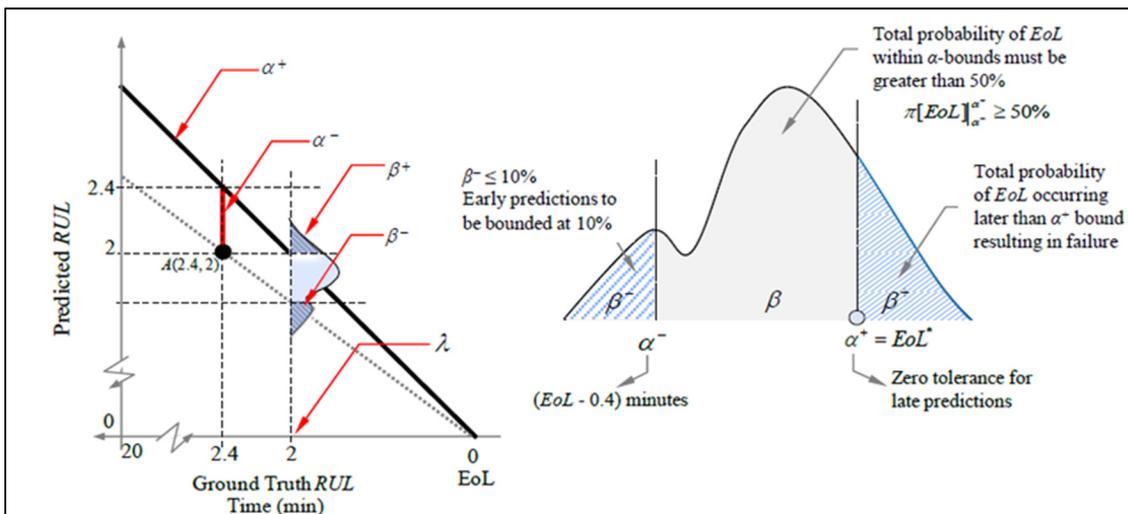


Figure 1.30 Illustration des limites des prédictions en avance et en retard des prédictions pour des algorithmes de pronostic (Saxena et al., 2012)

$\alpha^+$ : temps acceptable pour une prédiction en retard – généralement catastrophique pour un système en opération, car prédit la défaillance après qu'elle ait eu lieu. Elle est souvent définie avec une très infime tolérance voir une tolérance nulle (Saxena et al., 2012).

$\alpha^-$ : temps acceptable pour une prédiction en avance – elle représente le temps acceptable auquel on peut prédire une défaillance en avance sans impliquer de surcoût de maintenance.

Elle est souvent définie avec un niveau de tolérance assez important dépendamment du cas d'application (Saxena et al., 2012). Exemple : « L'alternateur de doit pas être arrêté plus de X jours plus tôt avant sa défaillance »

Ces paramètres doivent découler d'une analyse des besoins du système de pronostic en tenant en compte de son contexte opérationnel (contraintes de fiabilité et analyse coût-bénéfice). La Figure 1.31 propose un cas d'exemple de détermination de ces paramètres proposée par Saxena et al (Saxena et al., 2012) dans le cas d'un drone. Basées sur ces considérations, les métriques suivantes ont été dérivées de ce diagramme et sont synthétisées dans le Tableau 1.10.

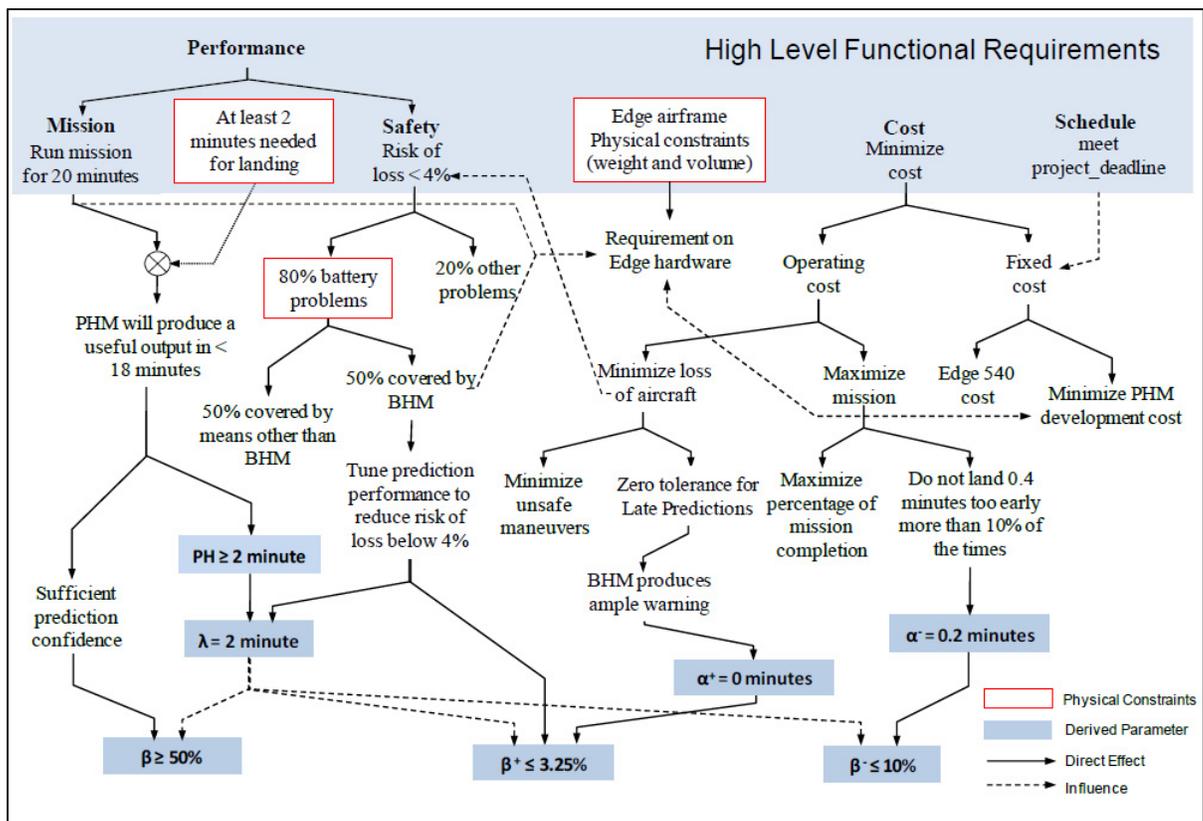
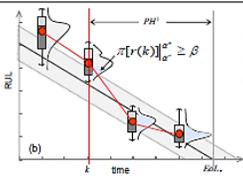
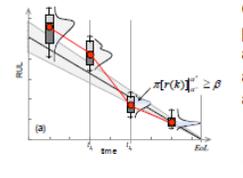
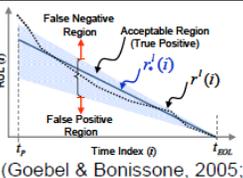
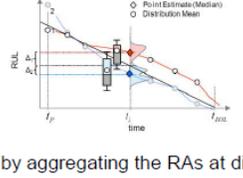
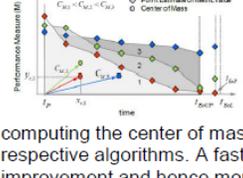


Figure 1.31 Arbre démontrant l'écoulement des exigences du système de pronostic pour la mission d'un drone afin d'en estimer les paramètres de validation (Saxena et al., 2012)

Tableau 1.10 Métriques de performances statistiques des systèmes diagnostics (Drucker)

Offline Prognostic Performance Metrics	
Metric	Description and Usage
Prognostic Horizon	 <p>Determines the maximum advance warning an algorithm can provide with desired confidence. It is defined as the maximum predicted RUL (or the first prediction) that falls within desired accuracy (<math>\alpha</math>) bounds. An algorithm with larger PH is preferred.</p> $PH = t_{EoL} - t_{prediction} \mid \text{first prediction} \in \text{desired accuracy } (\alpha)$
$\alpha$ - $\lambda$ Performance	 <p>Characterizes how well an algorithm's performance (accuracy and precision) improves as EoL approaches. Improvement is measured against desired accuracy level (<math>\alpha</math>) expressed as a percentage of RUL at any specified time (<math>\lambda</math>).</p> $\alpha - \lambda \text{ Accuracy} = \begin{cases} 1 & \text{if a prediction falls inside the } \alpha \text{ accuracy bounds} \\ 0 & \text{otherwise} \end{cases}$
Prognostic False Alarm Rate	 <p>This metric is an extension from classical false positive and false negative metrics used for diagnostics performance where an early prediction is classified as false positive and a late prediction as false negative. Therefore, the <math>\alpha</math> accuracy bounds mentioned above define FP and FN regions on an RUL vs. time graph. (Goebel &amp; Bonissone, 2005; Leao <i>et al.</i>, 2008; Luna, 2009; Saxena <i>et al.</i>, 2008)</p>
Relative Accuracy	 <p>Quantifies how accurate an algorithm is at any given time (<math>\lambda</math>) relative to the EoL. It is computed as RUL error normalized by actual RUL for any given time. It captures the notion that accuracy of prediction becomes more critical as EoL approaches. Further, a cumulative relative accuracy may be computed by aggregating the RAs at different time instants to specify algorithm's accuracy in general.</p>
Convergence Rate	 <p>Quantifies the rate of convergence of prognostic performance improvement as predictions are updated with time. Convergence can be computed for any metric of interest such as accuracy, precision, etc. This metric quantifies the convergence rate by computing the center of mass of the area under the predicted trajectories for respective algorithms. A faster convergence rate indicates faster performance improvement and hence more time available for making actionable decisions for IVHM.</p>
Sensitivity (Vachtsevanos <i>et al.</i> , 2006)	<p>Sensitivity is a measure of how sensitive a prognostic algorithm is to input changes or external disturbances. Can be assessed against any performance metric of interest. <math>\Delta M</math> is the distance measure between two successive outputs for metric <math>M</math>'s value and <math>\Delta_{input}</math> is a distance measure between two successive inputs, e.g. failure threshold, noise level, available sensor set, sampling rate, etc. Sensitivity may be aggregated over similar systems (units under test (<math>l</math>)).</p> $S(l) = \frac{1}{L} \sum_{l=1}^L \left\{ \frac{\Delta M^l(i)}{\Delta_{input}} \right\}$

Il existe dans la littérature des variantes aux métriques proposées ci-dessus. À titre d'exemple, dans un article de 2013, Baraldi et al. (Baraldi, Cadini, Mangili, & Zio, 2013) ont comparé des approches de pronostic en utilisant deux métriques présentées dans le Tableau 1.11.

Tableau 1.11 Métriques de performances utilisées par Baraldi et al. (Baraldi et al., 2013)

Métriques	Signification	Formulation
Mean Relative Absolute Error (rMAE)	<i>Evaluate the precision (anglais: accuracy) of the estimate of the estimated RUL with respect to the true RUL of the system.</i> *Équivalent à MAE dans la figure 7.	$rMAE = \frac{1}{N_{tst}} \sum_{i=1}^{N_{tst}} \left  \frac{rul_i - \hat{r}ul_i}{rul_i} \right $
Coverage (Cov)	<i>Verify whether the estimation of the prediction interval <math>PI(0.32)</math> actually contains with the probability <math>1-0.32=0.68</math> the true RUL of the system.</i> *Équivalent à la métrique $\alpha$ - $\lambda$ dans la figure 10.	$Cov = \frac{1}{N_{tst}} \sum_{i=1}^{N_{tst}} c_i; \quad c_i = \begin{cases} 1 & C_i^{inf}(0.32) < rul_i < C_i^{sup}(0.32) \\ 0 & \text{otherwise} \end{cases}$

- Les métriques pour les parcs d'actifs :

Les métriques de performances des algorithmes de pronostic précédentes permettent d'évaluer les performances d'un algorithme de pronostic au niveau d'un actif. Cependant dans certains cas industriels où il est nécessaire que les algorithmes aient des performances spécifiques pour l'ensemble d'un parc d'actifs, des métriques agrégées de performances sont nécessaires. Dans ce cas-ci, peu de références ont été trouvées dans la littérature. Dans un article publié en 2014, Saxena et al. (Saxena et al., 2014) suggèrent d'utiliser des métriques de classification d'erreurs telles que les False-négatives et False-positives ou bien d'utiliser des métriques d'erreurs agrégées telles que MAPE, MSE, MAD, etc.

Un article publié en 2013 par Son et al. (Son, Zhou, Zhou, Mao, & Salman, 2013), propose une approche pour estimer les performances de plusieurs types d'algorithmes sur des données

de défaillances provenant de multiples équipements, à travers différents temps de prédiction. Pour cela, ils ont défini deux métriques de performances pour un temps de prédiction  $t_k$  et un équipement spécifique  $i$  tels que présentés dans le Tableau 1.12 et la Figure 1.32.

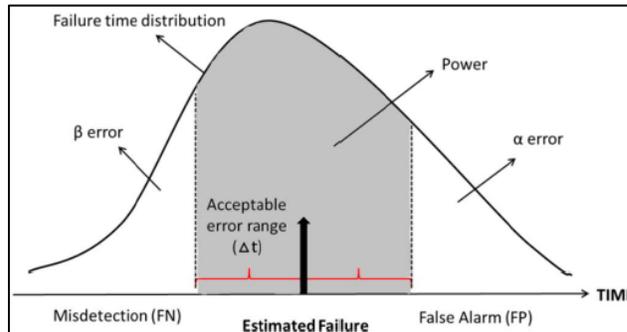


Figure 1.32 Illustration des métriques utilisées par Son et al. (Son et al., 2013)

Tableau 1.12 Métriques utilisées par Son et al. (Son et al., 2013)

Métriques	Signification	Formulation
Approximated Mean Squarred Erroe (AMSE)	*équivalent à MSE dans la figure 7 en enlevant les termes liés au système d'étude dans la métrique.	$ASME(t_k)$ $= E_{\theta} \left[ \hat{T}_i(t_k) - \mu_{T_i} \right]^2$
Power ( $t_k$ )	*Équivalent à la métrique $\alpha$ - $\lambda$ dans la figure 10, mais en gardant la probabilité que la prédiction tombe dans la zone de prédiction acceptable plutôt que de la rendre binaire selon le critère d'acceptation $\beta$ .	$Power(t_k)$ $= E_{\theta} \left[ P \left[ \hat{T}_i(t_k) - \Delta t < T_i < \hat{T}_i(t_k) + \Delta t \right] \right]$

Une fois les métriques estimées pour tous les temps de prédiction  $t_k$  et tous les équipements  $i$ , les résultats sont présentés en illustrant la moyenne et l'écart type de ces deux métriques sur l'ensemble du parc d'équipement pour chaque temps de prédiction  $t_k$ . Cela nécessite d'avoir les mêmes temps de prédiction pour l'ensemble des actifs. Tableau 1.13 illustre les résultats présentés.

Tableau 1.13 Métriques pour un système d'actif utilisé par Son et al. (Son et al., 2013)

$t_k$	Models	Performance metrics				Median residual life (mdrl)			
		Power	std error	AMSE	std error	mdrl	std error	95% C.I.	
								left	right
0	JPM	0.727	0.014	0.010	0.133	50.196	0.958	48.318	52.074
	DSPM	0.727	0.011	0.280	0.382	50.188	1.396	47.452	52.924
10	JPM	0.728	0.013	<0.001	<0.001	41.267	1.035	39.238	43.296
	DSPM	0.727	0.010	0.228	0.326	41.287	1.513	38.322	44.252
20	JPM	0.735	0.013	<0.001	<0.001	31.326	0.985	29.395	33.257
	DSPM	0.734	0.010	0.209	0.311	31.334	1.442	28.508	34.160

Un autre article proposé par Leao et Yoneyama (Leao & Yoneyama, 2013) en 2013 propose une méthode basée sur une transformée appelée Probability Integral Transform (PIT). Cette méthode vise à évaluer si l'algorithme de pronostic a correctement procédé les incertitudes en comparant l'écart des prédictions avec les dates de défaillances réelles de différents équipements. Cela permet de suivre le comportement de l'algorithme sur une population d'équipement. Cependant, cette approche requiert un nombre important de défaillances connues. De plus, cette métrique ne représente pas l'aspect temporel des prédictions et leur convergence au faire et à mesure de l'arrivée de nouvelles données (K.; Goebel et al., 2017). La Figure 1.33 illustre cette métrique.

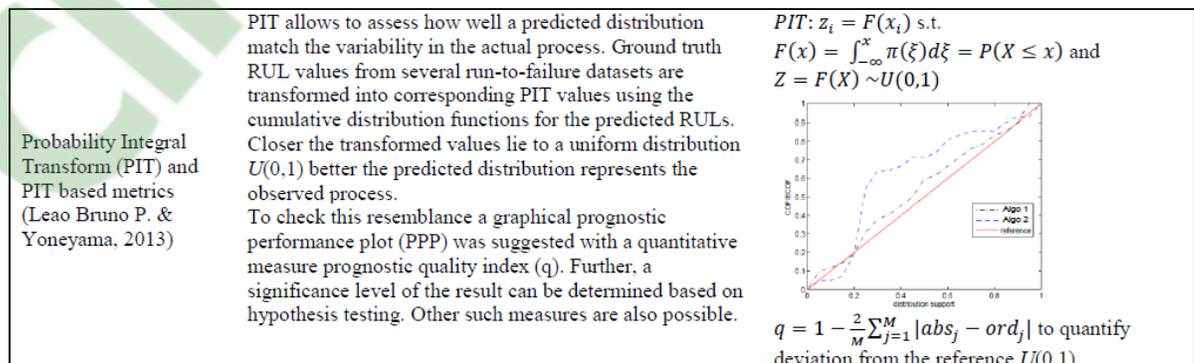


Figure 1.33 Illustration de la méthode proposée par Leao et Yoneyama (Leao et al., 2013)

Michael E. Sharp (Sharp, 2013) a introduit en 2013 un ensemble de métriques simples permettant l'évaluation des algorithmes de pronostic. L'objectif de ces métriques est qu'elles puissent être utilisées et comprises par des utilisateurs provenant de différents domaines d'étude. Ces métriques permettent d'obtenir rapidement un bilan des différentes performances de l'algorithme sur un parc d'actifs. Le Tableau 1.14 en illustre un résumé.

Tableau 1.14 Illustration de métriques simples proposées par Michael E. Sharp (Sharp, 2013)

<u>Metric Name</u>	<u>Quality Aspect Reflected</u>	<u>Units</u>	(CIC)	<i>uncertainty contains the true value</i>	
Mean Absolute Error (MAE)	<u>Precision</u> <i>Average distance from true value</i>	Real Time Units	Confidence Convergence Horizon (CCH)	<u>Timely Accuracy &amp; Precision</u> <i>What part of life can all remaining estimates be trusted to within 10%</i>	Percent of Unit Remaining Useful Life
Weighted Error Bias (WEB)	<u>Timely Precision</u> <i>Scaled expected distance from true value</i>	Percent of Unit Life <i>Weighted by Lifetime Importance</i>	Binned Prediction Value Map	<u>Timely Accuracy &amp; Precision</u> <i>Detailed visualization of the evolution of the prognostic predictions. Used to calculate other metrics</i>	Percent of Unit Life
Weighted Prediction Spread (WPS)	<u>Timely Accuracy</u> <i>Scaled uncertainty estimate associated with each prediction</i>	Percent of Unit Life <i>Weighted by Lifetime Importance</i>			
Confidence Interval Coverage	<u>Accuracy</u> <i>How often the estimated</i>	Percent of Unit Life			

Récemment plusieurs références, telles que Youn Hu et al., (Hu, Youn, Wang, & Taek Yoon, 2012) utilisent un graphique illustrant les prédictions d'un algorithme sur une population d'équipement en affichant les dates de défaillance des équipements dans l'ordre et leurs prédictions de défaillance. Une illustration de ce type de graphique est présentée dans la Figure 1.34.

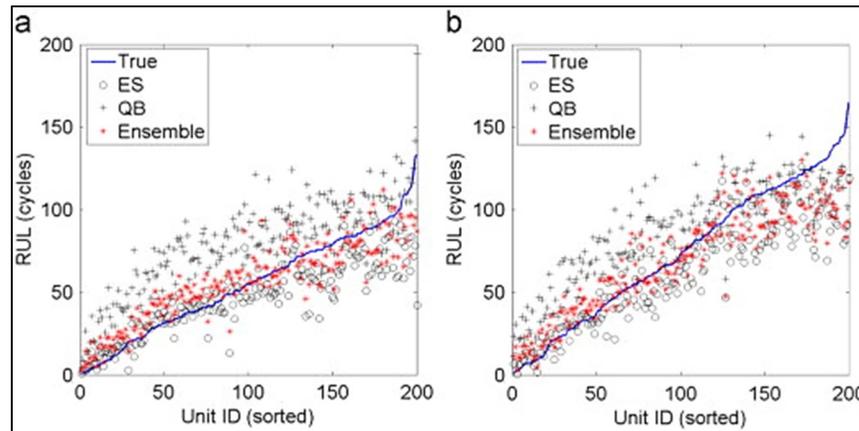


Figure 1.34 Illustration de la validation de différents algorithmes de pronostic à l'échelle d'une population d'équipement (Hu et al., 2012)

Ce type de graphique permet d'analyser la capacité d'un algorithme à satisfaire la diversité statistique d'une population d'équipement. Il peut permettre aussi de visualiser les performances d'un algorithme pour différent temps de prédiction. Cependant il est difficile de visualiser la convergence des prédictions de l'algorithme de pronostic.

Lors de l'utilisation de métriques agrégées pour analyser les performances des algorithmes de pronostic, l'aspect des performances temporelles est souvent omis. À l'aide des métriques utilisées, il est important de pouvoir évaluer la précision (*accuracy*) et le *timeliness*. Par ailleurs, en comparant les performances sur différents équipements, il ne faut pas oublier que ces équipements ont vécu des niveaux de charges et des conditions différentes tout au long de leur vie utile (K.; Goebel et al., 2017). Les métriques de performances devraient idéalement permettre d'identifier les équipements sur lesquels l'algorithme performe moins bien afin de pouvoir ajouter certaines spécificités pour certains cas.

- Bilan des métriques offline et leur utilisation selon les types d'approches utilisées:

Saxena et al. (Saxena et al., 2014) ont proposé un tableau récapitulatif des métriques qui peuvent être utilisées différemment du type d'approche. Il est présenté dans le Tableau 1.15.

Tableau 1.15 Bilan des métriques offline et leur utilisation selon les types d'approches utilisées (Saxena et al., 2014)

Prediction Method	Prediction Model	Applicability	Accuracy	Timeliness	Confidence
<b>Type I</b> Reliability analysis based predictions	Population-based statistics data from (mostly controlled) experiments or usage history data	Predict mean life of a component. Correctness of predictions is meaningful for a fleet in general, and not for an individual unit	Mean-life metrics such as MTBF, MTBR, etc. can be predicted and then compared to observations from actual field data. These, errors in predictions can be used as a metric of accuracy. Otherwise, if maintenance actions based on these metrics are effective, then any observed change in mean-life estimates can be interpreted as a measure of effectiveness (accuracy, timeliness) of such predictions.		Probability of success metrics such as RxCy specifying x% reliability with y% confidence. E.g. R96C90 is a popular metric in automotive industry
<b>Type II</b> Damage accumulation model based predictions	Unit specific load history data + population based Damage accumulation model	Predict remaining life of an individual unit based on population model	Metrics like alpha-lambda accuracy and relative accuracy quantify correctness of prognostic algorithms (Saxena et al., 2010)	Prediction horizon, and lambda, the time window modifier, based metrics assess timeliness aspects of prognostics	$\beta$ -criterion (Saxena, Celaya, Saha, Saha, & Goebel, 2009a) assesses confidence in prediction correctness, Robustness (Guan et al., 2010) and sensitivity metrics (Vachtsevanos, Lewis, Roemer, Hess, & Wu, 2006) assess confidence via offline analysis
<b>Type III</b> Condition based predictions - Prognostics	Unit specific degradation model (data-driven or physics based), load history, and condition monitoring data.	Predictions customized for individual unit by learning specific individual behavior			
<b>Type IV</b> Data Analytics based predictions – Predictive analytics	Rich set of data from multiple units in a variety of operating conditions + analytical data model for pattern matching	Predictions for individual unit based on rich operational history data	Classification error rate metrics (such as false positives, false negatives), aggregate error metrics (such as MAPE, MSE, MAD, etc) to evaluate predictions on multiple units.	Timeliness may be expressed by length of history sequence considered for accurate predictions.	Similarity scores between two high dimensional history vectors establish confidence. Similarity metrics such as precision and recall are often employed

Dans le Tableau 1.15, on peut alors remarquer que différentes métriques peuvent être utilisées dépendamment si on veut évaluer l'algorithme sur des cas d'étude spécifique ou si on veut évaluer son comportement à l'échelle d'un parc d'actif.

### 1.6.3 Les métriques de performances *Online* :

*Évaluation Online* : inclus des méthodes de pronostic qui sont exécutées en temps réel et ne requièrent pas la connaissance du temps où un événement a eu lieu (K.; Goebel et al., 2017).

Les métriques des méthodes de pronostic *online* sont principalement adressées en évaluant les prédictions à court terme de l'état intermédiaire d'un système. La précision (anglais: *accuracy*) et la justesse (anglais: *precision*) des prédictions à court terme permettent d'estimer un niveau de confiance sur la prédiction long terme où la date de l'événement visé n'est pas encore connue. Le Tableau 1.16 en illustre quelque une proposée dans la littérature.

Tableau 1.16 Métriques de performance online (Saxena et al., 2014)

Metric	Description	Formula
<b>Online Performance Evaluation</b>		
RUL Online Precision Index (RUL-OPI) (Orchard, Tang, Goebel, & Vachtsevanos, 2009)	RUL-OPI quantifies and tracks the precision of predicted RUL distributions by quantifying the length of 95% confidence bounds (CI(i)) normalized by the predicted RUL (r(i)) at any given time instant. An algorithm with a high index (close to 1) is preferred, which indicates high precision or narrow confidence bounds.	$I(i) = e^{-\left(\frac{\sup\{CI(i)\} - \inf\{CI(i)\}}{r(i)}\right)}$
Dynamic Standard Deviation (DStd) (Olivares, Muñoz, & Orchard, 2013)	DStd quantifies the stability of predictions within a time window ( $\Delta$ ). Variance between individual predictions made within the time window is computed. The metric is normalized to a range [0,1] using the logistic function $\phi$ for easy comparisons.	$DStd = \phi\left(\text{Var}\left(E\{EOL   Y_{1:j}\}\right)_{j \in \Delta}\right)$
Critical- $\alpha$ Performance Measure (Olivares et al., 2013)	Looking from the perspective of actionable decision making, this measure computes the critical percentile ( $\alpha$ ) of an RUL distribution that would define a Just-In-Time-Point (JITP) for that application. JITP must always occur before actual failure, and hence the value of this metric lies in interval (0,0.5] and should be maximized to avoid unnecessary conservatism in decision making.	$\alpha_{crit} = \arg \max_{\alpha} \{JITP_{\alpha\%}(k_{pred}) \leq EOL\};$ $\forall k_{pred} \in [1, EOL]$
Accuracy and Precision over fixed horizon (Liu & Sun, 2012)	The accuracy metric (Ac) computes the probability mass of the predicted RUL within the acceptable $\alpha$ bounds and compares them to actual states realized at the end of the short horizon window. Similarly the precision (Pr) metric compares the spread (based on confidence intervals (CI)) of the predicted (P) probability density function to the true pdf (T) at the end of one horizon window. It is however not clear how the true pdf is obtained for comparison, where one would expect only a point observation from an actual event.	$Ac = \int_{\alpha^-}^{\alpha^+} \varphi_p(c) dc \quad \text{or} \quad \sum_{\alpha^-}^{\alpha^+} \varphi(c)$ $Pr = \begin{cases} 1 - \frac{CI_T - CI_P}{CI_T} & \text{if } CI_T \geq CI_P \\ 1 - \frac{CI_P - CI_T}{CI_{max} - CI_T} & \text{if } CI_T \leq CI_P \leq CI_{max} \\ 0 & \text{if } CI_P \geq CI_{max} \end{cases}$

Sen Gupta et al. (Gupta, Trinquier, Medjaher, & Zerhouni, 2015) ont proposé en 2015 une approche originale pour analyser les performances des algorithmes de pronostic dans le cas où peu de défaillances sont répertoriées dû à des actions de maintenances préventives déjà appliquées basées sur des modèles de pronostic. Ils proposent de tenir en compte les dates des maintenances réalisées au lieu des dates de défaillance. Cela permet de donner accès à une quantité de données de validation beaucoup plus importante. Afin de pouvoir estimer l'horizon

du pronostic (PH) basé sur les dates de défaillance réelles, ils proposent d'estimer un facteur pondéré qui accorde plus d'importance aux maintenances qui ont eu lieu à un état plus proche de la défaillance selon l'algorithme déjà implémenté.

Pour conclure notre Revue, nous pouvons avancer que certaines opportunités et pistes de recherche ont récemment été identifiées dans la littérature. Bien que des contributions sur le pronostic de systèmes complexes aient déjà été présentées, une approche de pronostic au niveau du système considérant différentes sources d'informations de diagnostic ET la complexité du mécanisme de défaillance de l'équipement dans la prédiction des différents modes de défaillances reste à développer, valider et implémenter.

Au niveau des approches de maintenance prévisionnelle, il semble qu'il n'existe pas d'approche permettant de prédire des actions de maintenance spécifiques en fonction des mécanismes de défaillance détecter actifs et des résultats de pronostic.

Pour finir, les métriques d'évaluation des systèmes de pronostic existants portent principalement sur des systèmes non réparables. Il semblerait intéressant de développer des approches permettant d'évaluer les performances des algorithmes de pronostic pour des équipements réparables. Elles permettraient analyser la capacité des algorithmes de pronostic à prédire l'occurrence des différentes défaillances que peut vivre un système réparable lors de sa vie utile.

## CHAPITRE 2

### MÉTHODOLOGIE DE RECHERCHE

#### 2.1 Introduction

Ce chapitre présente la méthodologie de recherche telle qu'elle a été retenue et définit la structure des chapitres subséquents de la thèse. Son développement se base sur les questions et objectifs de recherche.

Rappelons au lecteur que l'objectif *in fine* de la thèse est de développer une approche permettant d'adresser le pronostic en exploitant les informations issues de la maintenance préventive (incluant les inspections et les maintenances systémiques et prédictives) des équipements complexes et réparables. Pour y arriver, nous avons opté pour des étapes/jalons que nous présentons ci-dessous.

- Élaborer une approche physique permettant le pronostic de différents modes de défaillance d'un équipement complexe. Par approche physique, nous désignons un modèle qui se base sur les lois physiques, la modélisation des phénomènes de dégradation et une sorte de cascade hiérarchisée des phénomènes. Cette succession de mécanismes est définie *a priori* par des experts;
- Élaborer une approche mieux adaptée pour la maintenance prédictive tenant en compte des mécanismes de défaillance et des résultats actualisés de pronostic;
- En capitalisant sur les deux premiers jalons, proposer une nouvelle approche d'évaluation de pronostic pour les équipements réparables en tenant compte de leur contexte opérationnel;
- Identifier une stratégie d'actualisation des modèles de pronostic et de maintenance prédictive à long terme.

La recherche permettra de préparer une base pour la définition des systèmes de pronostic et de maintenance prévisionnelle adaptés aux équipements complexes et réparables en tenant compte de leurs mécanismes inhérents de défaillance.

Le cas d'étude privilégié portera sur les alternateurs hydro-électriques. Les approches proposées dans cette thèse peuvent être appliquées sur n'importe quel type d'équipement complexe et réparable comportant différents mécanismes de défaillance menant à différents modes de défaillance.

La thèse est constituée de sept chapitres. Les quatre chapitres suivants constituant les contributions scientifiques de la thèse. Le CHAPITRE 3 et CHAPITRE 4 présentent deux articles de revues avec comité de lecture déjà publiés. Cette thèse a aussi permis de produire 4 articles de conférences internationales et un poster. Le poster a reçu le *Best Poster Award* lors de la conférence européenne de la PHM Society. Le Tableau 2.1 présente la liste des articles de conférence et de journaux publiés.

Tableau 2.1 Liste des publications scientifiques produites durant la recherche

Type	Titre	Année
Journal	Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). <i>A Predictive Maintenance Approach for Complex Equipment Based on Failure Mechanism Propagation Model</i> . International Journal of the Prognostic and Health management society. url: <a href="http://www.phmsociety.org/node/2675">http://www.phmsociety.org/node/2675</a>	2019
Journal	Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Lévesque, M., & Hudon, C. (2018). <i>A holistic multi-failure mode prognosis approach for complex equipment</i> . Reliability Engineering & System Safety, 180, 136-151. doi: <a href="https://doi.org/10.1016/j.ress.2018.07.006">https://doi.org/10.1016/j.ress.2018.07.006</a>	2018

Tableau 2.1 (suite)

Type	Titre	Année
Article Conférence	Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). <i>A Predictive Maintenance Approach for Complex Equipment Based on Petri Net Failure Mechanism Propagation Model</i> . Paper presented at the PHM Society European Conference. url : <a href="https://phmpapers.org/index.php/phme/article/view/434">https://phmpapers.org/index.php/phme/article/view/434</a>	2018
Article Conférence	Blancke, O., Komljenovic, D., Tahan, A., Amyot, N., Hudon, C., Boudreau, J.-F., & Lévesque, M. (2018). <i>From data to asset health management in the context of hydropower generation: A holistic concept</i> . Paper presented at the World Congress of Engineering Asset Management (WCEAM).	2018
Article Conférence	Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Levesque, M., & Hudon, C. (2016). <i>A Hydrogenerator Model-Based Failure Detection Framework to Support Asset Management</i> . Paper presented at the IEEE International Conference on Prognostics and Health Management, Ottawa, OT, Canada. doi: <a href="https://doi.org/10.1109/ICPHM.2016.7542867">https://doi.org/10.1109/ICPHM.2016.7542867</a>	2016
Article Conférence	Blancke, O., Merkhouf, A., Amyot, N., Pedneault-Desroches, J., Hudon, C., & Haddad, K. (2016). <i>Strategic Fault Diagnosis Approach for Hydrogenerator Shaft Current Discharges</i> . Paper presented at the 2016 International Conference on Electrical Machines, Lausanne, Suisse. doi: <a href="https://doi.org/10.1109/ICELMACH.2016.7732849">https://doi.org/10.1109/ICELMACH.2016.7732849</a>	2016

## 2.2 Structure et contributions scientifiques

Les quatre prochains chapitres détaillent donc les résultats de la recherche. Les chapitres proposés suivent l'ordre logique d'implémentation des algorithmes de pronostic dans un contexte industriel. Les chapitres CHAPITRE 3 et CHAPITRE 4 posent les bases de l'approche de pronostic et de maintenance prévisionnelle. Le CHAPITRE 5 propose une approche de validation des algorithmes de pronostic pour les systèmes réparables et pour finir le CHAPITRE 6 propose une perspective long terme d'actualisation des modèles. Le Tableau 2.2 présente les principales contributions des chapitres.

Tableau 2.2 Explication détaillée de la structure de la méthodologie de recherche

	CHAPITRE 3	CHAPITRE 4	CHAPITRE 5	CHAPITRE 6
Objectif	Approche de pronostic pour les équipements complexes	Approche de maintenance prédictive pour les équipements complexes	Évaluation des modèles de pronostic pour des équipements réparables	Actualisation des modèles pour assurer leur pérennité
Titre	Approche de pronostic multimodes de défaillances pour les équipements complexes	Approche de maintenance prédictive pour équipements complexes basée sur les résultats de pronostic	Évaluation de la performance des méthodes de pronostic pour les équipements réparables dans un contexte industriel	Processus d'actualisation des modèles de pronostic pour une applicabilité long-terme
Contributions	<ul style="list-style-type: none"> <li>-Prendre en compte la complexité des mécanismes de défaillance;</li> <li>-Suivre l'avancement des mécanismes de défaillance dans le temps;</li> <li>-Faire un pronostic dynamique des différents modes de défaillance.</li> </ul>	<ul style="list-style-type: none"> <li>-Suggérer des tâches de maintenance en fonction des mécanismes de défaillance actifs;</li> <li>-Prédire l'intervalle d'application des tâches de maintenance en se basant sur les résultats de pronostic.</li> </ul>	<ul style="list-style-type: none"> <li>-Permettre l'évaluation des méthodes de pronostic pour les systèmes réparables;</li> <li>-Définir un cadre de validation à partir du contexte de maintenance industriel.</li> </ul>	<ul style="list-style-type: none"> <li>-Permettre l'actualisation des systèmes de pronostic dans le temps;</li> <li>-Assurer les performances et la longévité des systèmes de pronostic.</li> </ul>
Journal	Reliability Engineering and System Safety (article publié)	International Journal of the Prognostics and Health Management (article publié)	International Journal of the Prognostics and Health Management (article en rédaction)	

## CHAPITRE 3

### APPROCHE DE PRONOSTIC MULTIMODES DE DÉFAILLANCE POUR LES ÉQUIPEMENTS COMPLEXES

L'objectif de ce chapitre est de proposer un modèle générique de pronostic pour les équipements complexes qui, par essence, possèdent plusieurs et différents modes de défaillance. À cette fin, ce chapitre propose un cadre adaptatif pour le développement des modèles, dans lequel différentes options pourraient être prises en fonction des informations disponibles, du contexte industriel et de la maturité organisationnelle. Toutes les options ne seront pas abordées dans ce chapitre: certaines sont discutées dans les études de cas et d'autres sont identifiées comme étant des travaux ultérieurs. Le formalisme proposé par Goebel et al (K.; Goebel et al., 2017) est utilisé pour décrire les variables de pronostic utilisées dans la méthodologie et les algorithmes proposés.

#### 3.1 Hypothèses du modèle fondé sur des connaissances d'experts

L'approche de diagnostic proposée par Amyot et al. (Normand Amyot et al., 2013a) est utilisée ici comme cadre de référence. Le modèle vise à passer d'un graphe causal dynamique utilisé pour le diagnostic, à un pronostic dynamique des modes de défaillance de l'équipement. Comme présenté par Blancke et al. (O. Blancke, Tahan, Komljenovic, Amyot, Hudon et al., 2016), tous les mécanismes de défaillance et leurs corrélations peuvent être représentés à l'aide d'un graphe de causalité. Le formalisme proposé par Kjaerulff et Madsen (Kjaerulff & Madsen, 2008) est utilisé pour décrire la théorie des graphes. Ce graphe de causalité peut être défini comme un graphe acyclique dirigé (DAG) désigné par  $G$  et identifié par un couple  $(V, E)$ ,  $V$  étant un ensemble fini de sommets distincts et  $E \subseteq V \times V$  étant un ensemble d'arêtes dirigées. Tel que défini par Amyot et al. (Normand Amyot et al., 2013a), un mécanisme de défaillance  $j$  est un chemin unique désigné par  $FM^j = (v^{RCa}, v^{eu}, v^{ev}, \dots, v^{Fb})$ , où  $v^{RCa}$  est la cause initiale physique  $a$ ,  $v^{eu}$  et  $v^{ev}$  sont une séquence d'états physiques de dégradation et  $v^{Fb}$  est un mode de défaillance résultant noté  $b$ . Les vertices ou les arêtes peuvent avoir des attributs

différents. Par exemple, la variable aléatoire temporelle attachée à la transition entre les états  $u$  et  $v$  dans le mécanisme de défaillance  $FM^j$  est notée  $T_{FM^j}^{e_u, e_v}$ .

Comme mentionné dans la section précédente, une méthodologie a été proposée pour construire de tel graphe de causalité. Pour plus d'informations, voir les travaux de Blancke et al. (O. Blancke et al., 2016). La granularité du graphe de causalité peut varier en fonction des connaissances disponibles, des outils de diagnostic disponibles et de la complexité des mécanismes de défaillance de l'équipement. Un équipement complexe peut nécessiter plus de cent états physiques impliquant des centaines de mécanismes de défaillance interdépendants. L'approche pourrait également être appliquée à des équipements comportant un ou deux mécanismes de défaillance discrétisés par peu d'états physiques. À titre d'exemple, la Figure 3.1 présente un graphe causal théorique illustrant plus d'une centaine de mécanismes de défaillance interdépendants.

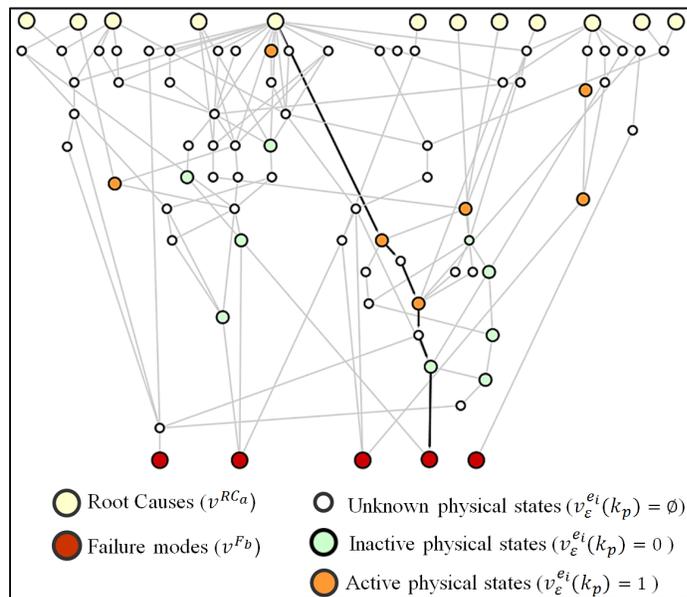


Figure 3.1 Modèle multi-états de dégradation représenté sous la forme d'un graphe causal

Sur la base des commentaires des experts et des réactions des opérateurs, plusieurs hypothèses ont été proposées pour modéliser la propagation du mécanisme de défaillance dans le temps.

Aucune contrainte mathématique n'est initialement imposée; le modèle doit donc être piloté par des experts et les modèles mathématiques doivent être choisis en fonction des hypothèses proposées.

Dans cette étude, un ensemble d'hypothèses est considéré, chacune étant présentée dans le Tableau 3.1 ci-dessous avec son interprétation mathématique (le cas échéant). Pour une application donnée, la liste des hypothèses à considérer peut évoluer avec le temps, à mesure que davantage de connaissances et d'informations deviennent disponibles.

Selon la ASMD, un état physique peut avoir trois états d'activation différents  $v_{\varepsilon}^{e_i}(k_p)$  à un instant discret de la prédiction  $k_p$ . Il peut être détecté comme actif ou inactif par son algorithme de détection lorsque de nouvelles mesures ou inspections sont effectuées. Au fil du temps, l'état d'activation de l'état physique ne changera pas tant que d'autres mesures ne seront pas prises. Si aucune mesure n'a encore été prise pour détecter l'état physique, il sera considéré comme inconnu (H1). Les hypothèses du modèle sont présentées dans le Tableau 19 et sont annotées H1...H14. L'état d'activation de l'état physique peut être illustré dans une visualisation de graphe de causalité, présentée à la Figure 3.1, où les états physiques actifs sont représentés en orange, les inactifs en vert et les inconnus en blanc. Par conséquent, les mécanismes de défaillance peuvent également avoir trois états d'activation  $FM_{\varepsilon}^j(k_p)$  à un instant discret de la prédiction  $k_p$ : actif, inactif et indétectable. Un mécanisme de défaillance est considéré comme actif s'il possède au moins un état physique actif et aucun état physique inactif antécédent dans le mécanisme de défaillance (A4). Un mécanisme de défaillance est considéré indétectable si tous ses états physiques sont inconnus (A4). Les mécanismes de défaillance actifs peuvent également être représentés dans la visualisation du graphe de causalité en mettant en évidence leurs chemins dans le graphe. Sur la Figure 3.1, un mécanisme de défaillance actif a été mis en évidence depuis sa cause initiale physique jusqu'au mode de défaillance résultant. Sur les Figure 3.2 et Figure 3.11, seule la partie des mécanismes de défaillance qui se sont déjà propagés au moment de la prédiction est mise en évidence. Cela

permet d'illustrer l'estimation de l'état de l'équipement étudié au moment précis de la prédiction.

En ce qui concerne les processus de propagation des mécanismes de défaillance, ceux-ci ne sont pas mutuellement exclusifs. On a supposé qu'ils évoluent simultanément pour atteindre un mode de défaillance donné (A5). Cette hypothèse pourrait également changer si les données historiques montrent qu'il existe une interdépendance significative. À ce stade, il a été supposé que la propagation d'un mécanisme de défaillance n'influence pas celui des autres (A6). La propagation d'un mécanisme de défaillance est un processus avec mémoire. Les temps de transition entre deux états physiques peuvent différer en fonction de l'historique de leur mécanisme de défaillance (A7). Par exemple, dans le cas de la dégradation de l'isolant, le temps de transition nécessaire pour se propager de la présence de décharges partielles à une érosion avancée de l'isolation, puis à une défaillance, varie selon que l'érosion est purement électrique ou qu'elle est combinée à une érosion mécanique par vibration. La transition temporelle sera plus courte que pour l'érosion par décharge partielle uniquement. Lorsque les mécanismes de défaillance sont visualisés à l'aide de graphes de causalité, certains chemins peuvent apparaître comme des mécanismes de défaillance possibles bien qu'ils ne soient en réalité pas possibles. C'est pourquoi seuls les mécanismes de défaillance reconnus par les experts sont pris en compte (A8). Seuls certains chemins du graphe ont un sens physique. Ainsi, il a été supposé que la causalité dépend de l'historique du mécanisme de défaillance. Tous les mécanismes de défaillance sont supposés être en concurrence (A9) et le premier mécanisme de défaillance à atteindre le mode de défaillance définit la fin de fonction (EOF)  $v_{EOF}^{F_b}(k_p)$ . Les temps de transition  $T_{FMj}^{e_u, e_v}$  sont considérés comme des variables aléatoires intégrant des incertitudes épistémiques liées au processus de propagation (A10). Bien que la distribution de Weibull soit proposée comme distribution paramétrique appropriée pour représenter ces variables, une autre distribution paramétrique pourrait être choisie, en fonction de l'équipement. Enfin, l'impact du cycle d'utilisation futur et des conditions environnementales futures (A11) est ignoré à ce stade, de même que l'impact des actions de maintenance futures sur la propagation du mécanisme de défaillance (A12).

En ce qui concerne l'identification de l'état d'avancement du mécanisme de défaillance, l'estimation de l'état du mécanisme de défaillance  $FM^j$  à un instant discret de la prédiction  $k_p$  est une variable aléatoire notée  $FM_{T_x}^j(k_p)$ . Elle est définie par l'intervalle de détection  $K_E$  de l'activation de son état physique actif le plus proche du mode de défaillance  $FM_{e_x}^j(k_p)$  (A13). En cas de remplacement, les états physiques liés aux composants ou équipements remplacés sont définis comme inconnus (A14). Le mécanisme de défaillance revient donc à l'état initial et la propagation recommence.

Tableau 3.1 Hypothèses sur la propagation des mécanismes de défaillance et leurs interprétations dans la théorie des graphes

		Model limitations	Assumptions	Graph model interpretation
FMSA	Physical states		A1: A discrete physical degradation state is defined by a unique detection algorithm that uses a combination of symptoms identified from diagnostic data.	$v^{ei}$ (physical state $i$ )
			A2: Specific evidence at discrete time of prediction $k_p$ : active, inactive and unknown.	Algorithms 4.2.1 $v_{\varepsilon}^{ei}(k_p) = 1$ (active at discrete time of prediction $k_p$ ) $v_{\varepsilon}^{ei}(k_p) = 0$ (inactive at discrete time of prediction $k_p$ ) $v_{\varepsilon}^{ei}(k_p) = \emptyset$ (unknown at discrete time of prediction $k_p$ )
	Failure mechanisms		A3: Possible paths are identified by experts as a single sequence of physical states leading from a physical root cause to a mode of failure.	$FM^j = path(v^{RCa}, v^{eu}, v^{ev}, \dots, v^{Fb})$
			A4: Specific evidence at discrete time of prediction $k_p$ : active, inactive and undetectable.	Algorithm 3.2.2.a
Failure mechanism	Not mutually exclusive independent processes		A5: Failure mechanisms can evolve in parallel to reach their corresponding failure modes.	Algorithm 3.3.1
		×	A6: Failure mechanisms progress uninfluenced by one another.	Algorithm 3.3.1
	Processes with memory (non-Markovian)		A7: Transition times can be influenced by the failure mechanism history.	Algorithm 3.3.1
			A8: Only failure mechanisms identified by experts are taken into account.	Algorithm 3.3.1
	Competition processes		A9: Failure mechanisms are considered in competition. The first failure mechanism to reach failure mode defines <i>EOF</i> .	Algorithm 3.3.1

Tableau 3.1 (suite)

		Model limitations	Assumptions	Graph model interpretation
Failure mechanism	Transition times		A10: Transition times between states are random variables and are assumed to be Weibull-distributed.	$T_{FM^j}^{eu, ev} \sim weibull(\beta, \theta, \alpha)$
	Future operation (duty cycle) and environmental conditions	×	A11: Different apparatus under study are considered to have the same future operational duty cycle and environmental conditions.	
	Future maintenance action	×	A12: The impact of future maintenance actions on failure mechanism propagation is ignored.	
State estimation	State estimation		A13: The state of failure mechanism $FM^j$ at discrete time of prediction $k_p$ is equal to random variable $FM_{T_x}^j(k_p)$ bounded between detection interval $K_E$ of its active physical state closest to failure mode $FM_{e_x}^j(k_p)$ .	Algorithm 3.2.2.b
	Replacement		A14: Following the replacement of a piece of equipment or one of its major components, the set of physical states attached to it becomes unknown. Thus, the failure mechanism goes back to the initial state and propagation begins again.	Algorithms 4.2.1

### 3.2 Algorithmes de diagnostic

L'algorithme de diagnostic proposé est une adaptation de l'approche de diagnostic d'Amyot et al. (Normand Amyot et al., 2013a) dans le cadre d'une application de pronostic. Il se compose de trois étapes incrémentielles effectuées pour chaque temps discret de prédiction  $k_p$ : (1) acquisition des données, (2) détection des défauts et (3) estimation de l'état. L'algorithme de diagnostic est illustré à la Figure 3.2 pour deux dates théoriques de prédiction, 2012 et 2014.

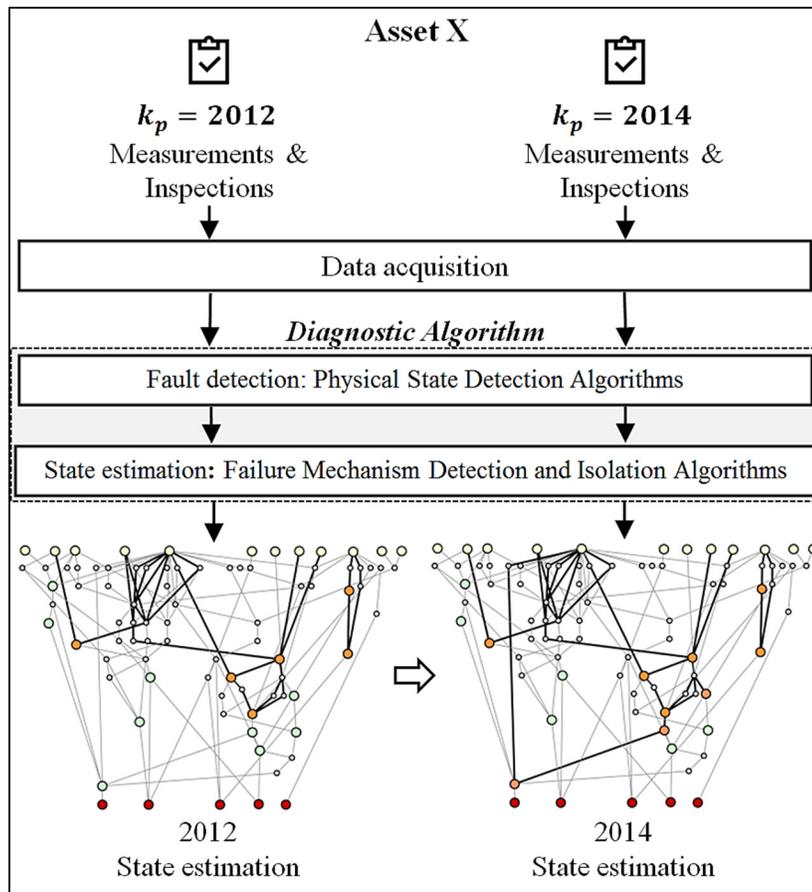


Figure 3.2 Illustration de l'algorithme de diagnostic pour un actif X à des dates de prédiction, 2012 et 2014

L'acquisition de données consiste à stocker dans une base de données les mesures et les données d'inspection ainsi que leurs dates correspondantes. La détection de défaut et

l'estimation d'état sont ensuite effectuées de manière incrémentielle pour chaque instant de prédiction. Les résultats de l'estimation d'état pour 2012 et 2014 ont été tracés à l'aide d'une visualisation graphique, où l'état d'activation de chaque état physique correspond à une couleur de sommet tel que défini à la Figure 3.1, et les chemins des mécanismes de défaillance détectés actifs sont mis en surbrillance jusqu'à leur dernier état physique actif  $FM_{e_x}^j(k_p)$ . Les sections 3.2.1 et 3.2.2 présentent plus en détail les étapes de la détection de défaut et de l'estimation d'état, ainsi que leurs algorithmes sous-jacents.

### 3.2.1 Détection des défauts : Algorithmes de détection des états physiques

La détection de défauts consiste à détecter les évidences d'état physique  $v_{\varepsilon}^{ei}(k_p)$  et à estimer leurs intervalles de détection possibles  $v_{\varepsilon_{KE}}^{ei}(k_p)$  sur la base des résultats de mesure disponibles et des données d'inspection au moment de la prédiction  $k_p$ . Comme introduit par Amyot et al. (Normand Amyot et al., 2013a) et présenté dans les hypothèses du modèle au Tableau 3.1, un état physique est défini par un algorithme de détection unique qui utilise une combinaison de symptômes identifiés à partir de données de diagnostic (A1). La Figure 3.3 illustre un algorithme théorique de détection d'état physique.

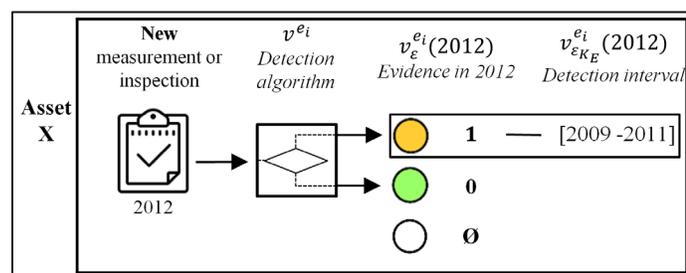


Figure 3.3 Illustration des algorithmes de détection d'états physiques

À chaque instant discret  $k_p$  où les nouveaux résultats de mesure et les données d'inspection sont acquis, tous les algorithmes de détection d'état physique identifiés sont exécutés pour

mettre à jour l'évidence des états physiques  $v_{\varepsilon}^{ei}(k_p)$  (A2). Si un état physique est détecté et que son évidence a changé, sa nouvelle date de détection d'évidence  $v_{\varepsilon k_E}^{ei}(k_p)$  est égale à la date  $k_p$  à laquelle la nouvelle information de diagnostic est acquise. L'intervalle de détection possible de cette nouvelle évidence  $v_{\varepsilon k_E}^{ei}(k_p)$  est alors considéré comme bornée entre la date de détection de la nouvelle évidence  $v_{\varepsilon k_E}^{ei}(k_p)$  et la date où l'état physique a été détecté pour la dernière fois. En cas de mesure en continu, si la plage d'incertitude de l'intervalle de détection d'état physique  $k_E$  est non significative par rapport à la plage d'incertitude de propagation du mécanisme de défaillance,  $v_{\varepsilon k_E}^{ei}(k_p)$  peut être considéré comme une variable déterministe.

Dans l'exemple théorique présenté à la Figure 3.3, de nouvelles données de mesure ou d'inspection ont été acquises en 2012. L'algorithme de détection de l'état physique  $v^{ei}$  a été exécuté et a détecté que son évidence était active ( $v_{\varepsilon}^{ei}(2012) = 1$ ). Étant donné que l'état physique  $v^{ei}$  était déjà actif en 2011 ( $v_{\varepsilon}^{ei}(2011) = 1$ ), la date de détection de son évidence n'avait pas changé ( $v_{\varepsilon k_E}^{ei}(2012) = 2011$ ) et son intervalle de détection d'évidence  $v_{\varepsilon k_E}^{ei}(2012)$  est resté égal à [2009; 2011]. 2009 représente la dernière date à laquelle l'état physique  $v^{ei}$  a été détecté comme étant inactif. En conséquence, l'algorithme de détection de l'état physique  $v^{ei}$  a détecté que  $v^{ei}$  était actif en 2012 et aurait pu être activé entre 2009 et 2011.

### 3.2.2 Estimation de l'état : Algorithmes de détection et d'identification de l'état d'avancement des mécanismes de défaillance

L'estimation de l'état d'avancement consiste à détecter les évidences des mécanismes de défaillance  $FM_{\varepsilon}^j(k_p)$  et à isoler leur état d'avancement  $FM_{T_x}^j(k_p)$  sur la base des informations des évidences d'état physique à un instant discret de la prédiction  $k_p$ . L'algorithme 3.2.2.a est basé sur les hypothèses des experts et permet de détecter l'évidence des mécanismes de défaillance pour un temps discret de prédiction  $k_p$ .

L'algorithme analyse tous les mécanismes de défaillance identifiés par les experts (A8) pendant un temps discret de prédiction  $k_p$ . Si aucun de ses états physiques n'est détectable avec les observations et les mesures prises, le mécanisme de défaillance est considéré comme indétectable ( $FM_\varepsilon^j(k_p) = \emptyset$ ). S'il a au moins un état physique actif et aucun état physique antérieur inactif dans le mécanisme de défaillance, le mécanisme de défaillance est détecté comme actif ( $FM_\varepsilon^j(k_p) = 1$ ). Si au moins un état physique est infirmé et qu'aucun état physique n'est actif, le mécanisme est considéré comme étant inactif ( $FM_\varepsilon^j(k_p) = 0$ ) (A3 et A4).

<b>Algorithm 3.2.2.a</b>	Active failure mechanism detection for a discrete time of prediction $k_p$
<p>1: <b>Input:</b> <math>k_p, [FM^1, \dots, FM^j], [v_\varepsilon^{e1}(k_p), \dots, v_\varepsilon^{ei}(k_p)], [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)]</math></p> <p>2: <b>Output:</b> <math>[FM_\varepsilon^1(k_p), \dots, FM_\varepsilon^j(k_p)]</math></p> <p>3: <b>for</b> <math>a = 1</math> to <math>j</math> <b>do:</b></p> <p>4: <b>if</b> <math>v_\varepsilon^{eu}(k_p) = 1</math> <b>not exist in</b> <math>FM^a</math> <b>and</b> <math>v_\varepsilon^{ev}(k_p) = 0</math> <b>not exist in</b> <math>FM^a</math> <b>then</b></p> <p>5:     <math>FM_\varepsilon^a(k_p) = \emptyset</math></p> <p>6: <b>else if</b> <math>v_\varepsilon^{eu}(k_p) = 1</math> <b>exist in</b> <math>FM^a</math> <b>and</b> <math>v_\varepsilon^{ev}(k_p) = 0</math> <b>with</b> <math>\text{rank}(v) &lt; \text{rank}(u)</math> <b>not in</b> <math>FM^a</math> <b>then</b></p> <p>7:     <math>FM_\varepsilon^a(k_p) = 1</math></p> <p>8: <b>else</b></p> <p>9:     <math>FM_\varepsilon^a(k_p) = 0</math></p> <p>10: <b>end if</b></p> <p>11: <b>end for</b></p>	
<p>*<math>\text{rank}(v) &lt; \text{rank}(u)</math>: an inactive physical state <math>v^{ev}</math> exist before the rank of an active physical state <math>v^{eu}</math> in the failure mechanism sequences <math>FM^a</math>.</p>	

Dans l'exemple de la Figure 3.2, six états physiques de l'actif X ont été détectés comme actifs et huit comme inactifs en 2012. Cela a permis de détecter 25 mécanismes de défaillance actifs possibles. Deux ans plus tard, sur la base des informations de diagnostic nouvellement disponibles, huit états physiques de l'actif X ont été détectés comme actifs et six comme inactifs en 2014. Cela a conduit à la détection de 37 mécanismes de défaillance actifs possibles. De plus, l'algorithme 3.2.2.a a montré que 23 mécanismes de défaillance étaient indétectables en 2012 et seulement 12 le sont resté en 2014. Un pourcentage élevé de mécanismes de défaillance

non détectables diminue la confiance dans les prédictions du modèle et nécessite des mesures ou des inspections supplémentaires.

Une fois que l'évidence du mécanisme de défaillance  $FM_{\varepsilon}^j(k_p)$  est détectée, l'algorithme 3.2.2.b permet d'isoler l'état d'avancement de chaque mécanisme de défaillance actif ( $FM_{\varepsilon}^j(k_p) = 1$ ) au moment de la prédiction  $k_p$ . Sur la base des hypothèses du Tableau 3.1, l'état du mécanisme de défaillance actif  $FM^j$  à un instant discret de la prédiction  $k_p$  est considéré comme censuré par intervalles conformément à la date de mesure et égal à la variable aléatoire  $FM_{T_x}^j(k_p)$  borné entre l'intervalle de détection  $K_E$  de son état physique actif le plus proche du mode de défaillance  $FM_{e_x}^j(k_p)$  (A13).

<b>Algorithm 3.2.2.b</b>	Active failure mechanism state isolation for a discrete time of prediction $k_p$
<p>1: <b>Input:</b> <math>k_p, [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)], [v_{\varepsilon K_E}^{e_1}(k_p), \dots, v_{\varepsilon}^{e_i}(k_p)], [FM_{\varepsilon}^1(k_p), \dots, FM_{\varepsilon}^j(k_p)]</math></p> <p>2: <b>Output:</b> <math>[FM_{T_x}^1(k_p), \dots, FM_{T_x}^j(k_p)]</math></p> <p>3: <b>for</b> <math>a = 1</math> to <math>j</math> <b>do:</b></p> <p>4:   <b>if</b> <math>FM_{\varepsilon}^a(k_p) = 1</math> <b>then</b></p> <p>5:     <math>FM_{T_x}^a(k_p) \text{ distribution}(FM_{e_x}^a(k_p) [v_{\varepsilon K_E}^{e_x}(k_p)])</math></p> <p>6:   <b>end if</b></p> <p>7: <b>end for</b></p>	

Les résultats peuvent également être illustrés à l'aide de la visualisation graphique. Sur la Figure 3.2, les mécanismes de défaillance actifs détectés sont mis en évidence à partir de leurs causes initiales physiques respectives jusqu'à leurs états isolés aux années de prédictions 2012 et 2014. Ainsi, la propagation des mécanismes de défaillance de 2012 à 2014 est capturée.

### 3.3 Algorithme de pronostic

L'algorithme de pronostic comprend deux étapes incrémentielles effectuées pour chaque instant discret de la prédiction  $k_p$ : (1) propagation des mécanismes de défaillance et (2) pronostic des modes de défaillance. L'algorithme de pronostic est illustré à la Figure 3.4 pour les deux mêmes dates théoriques de prédiction, 2012 et 2014.

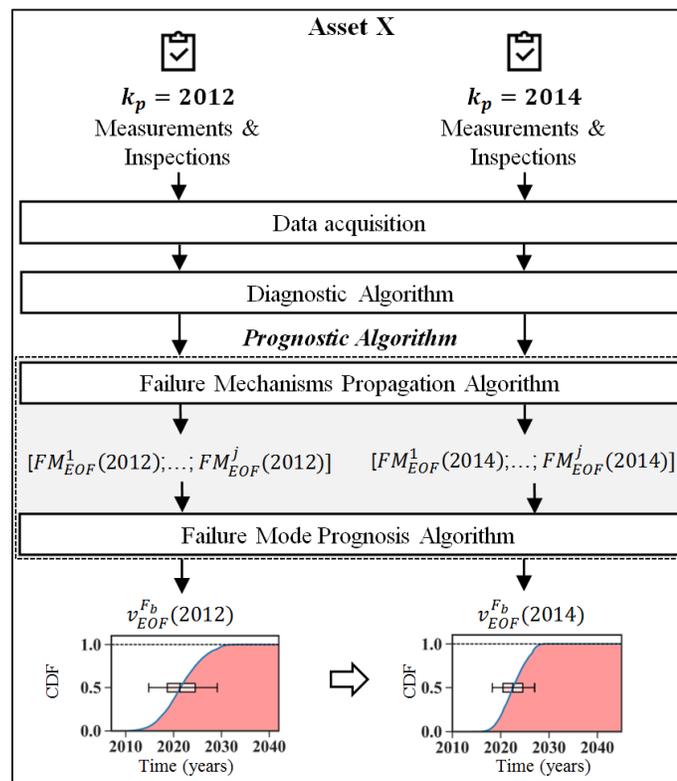


Figure 3.4 Illustration de l'algorithme de pronostic

Sur la base d'hypothèses des experts, même si les mécanismes de défaillance sont interdépendants, car ils partagent des états physiques dans leurs chemins, leurs processus de propagation sont considérés comme indépendants et en concurrence (A5, A6 et A9). La distribution *EOF* des modes de défaillance dépendra des mécanismes de défaillance actifs qui les ont conduits. Ainsi, pour estimer l'événement de fin de fonctionnement via le mode de

défaillance  $v_{EOF}^{Fb}(k_p)$ , la première étape consiste à estimer  $EOF$  pour chaque mécanisme de défaillance actif  $FM_{EOF}^j(k_p)$  au moment de la prédiction  $k_p$ . Le premier mécanisme à atteindre le mode défaillance définit l' $EOF$  (A9). Les sections 3.3.1 et 3.3.2 présentent plus en détail les étapes de la propagation du mécanisme de défaillance et le pronostic du mode de défaillance, ainsi que les algorithmes sous-jacents.

### 3.3.1 Algorithme de propagation des mécanismes de défaillance

Le but de l'algorithme de propagation des mécanismes de défaillance est d'estimer la probabilité qu'un mécanisme de défaillance actif atteigne son mode de défaillance dans le temps  $FM_{EOF}^j(k_p)$  pour un temps de prédiction  $k_p$ . En supposant que les mécanismes de défaillance soient des processus markoviens non homogènes (A5, A7 et A10) et ne s'influencent pas mutuellement (A6), l'idée est donc de considérer chaque mécanisme de défaillance identifié par les experts comme tributaire d'un modèle de pronostic indépendant; chaque mécanisme évoluant donc indépendamment des autres.

L'algorithme 3.3.1 consiste à propager tous les mécanismes de défaillance actifs ( $FM_{\varepsilon}^j(k_p) = 1$ ) à partir de leur état à un temps donné  $FM_{T_x}^j(k_p)$  (intervalle de détection de l'état physique actif du mode de défaillance le plus proche  $FM_{\varepsilon_x}^j(k_p)$ ) à leur mode de défaillance correspondant au moment de la prédiction  $k_p$ .

L' $EOF$  du mécanisme de défaillance  $j$  pour un temps de prédiction  $k_p$ , noté  $FM_{EOF}^j(k_p)$ , suit une distribution spécifique correspondant à la somme de son état d'avancement  $FM_{T_x}^j(k_p)$  (variable aléatoire bornée au moment de la prédiction  $k_p$ ) et toutes les variables aléatoires restantes du temps de transition  $T_{FM^j}^{e_u, e_v}$  appartenant au mécanisme de défaillance  $j$ , à partir de l'état physique actif le plus proche du mode de défaillance  $FM_{\varepsilon_x}^j(k_p)$  jusqu'au mode de défaillance résultant. Pour ce faire, l'algorithme effectue des simulations de Monte-Carlo. Il

calcule la réalisation de sommation  $c$ , notée  $FM_{EOF_c}^j(k_p)$ , pour un nombre d'itérations  $numIter$ . La distribution de probabilité résultante  $FM_{EOF}^j(k_p)$  correspond à la distribution  $EOF$  du mécanisme de défaillance  $j$  pour un temps discret de prédiction  $k_p$ .

<b>Algorithm</b>	Failure mechanism propagation algorithm for a
<b>3.3.1</b>	discrete time of prediction $k_p$
<p>1: <b>Input:</b> <math>k_p, numIter, [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)], [FM_{\varepsilon}^1(k_p), \dots, FM_{\varepsilon}^j(k_p)], [FM_{T_x}^1(k_p), \dots, FM_{T_x}^j(k_p)], [FM^1, \dots, FM^j], [T_{FM^1}^{e_1, e_2}, \dots, T_{FM^j}^{e_u, e_v}]</math></p> <p>2: <b>Output:</b> <math>[FM_{EOF}^1(k_p), \dots, FM_{EOF}^j(k_p)]</math></p> <p>3: <b>for</b> <math>a = 1</math> to <math>j</math> <b>do:</b></p> <p>4:   <b>if</b> <math>FM_{\varepsilon}^a(k_p) = 1</math> <b>then</b></p> <p>5:     <b>for</b> <math>c = 1</math> to <math>numIter</math> <b>do</b></p> <p>6:       <math>X \boxtimes FM_{T_x}^a(k_p)</math></p> <p>7:       <math>rank = rank(FM_{e_x}^a(k_p))</math></p> <p>8:       <math>FM_{EOF_c}^a(k_p) = X_b</math></p> <p>9:       <b>while</b> <math>rank \neq rank(v^{F_b})</math> <b>do</b></p> <p>10:          <math>Y \boxtimes T_{FM^a}^{e_{rank}, e_{rank+1}}</math></p> <p>11:          <math>FM_{EOF_c}^a(k_p) = FM_{EOF_c}^a(k_p) + Y_c</math></p> <p>12:       <b>end while</b></p> <p>13:     <b>end for</b></p> <p>14:   <b>end if</b></p> <p>15: <b>end for</b></p> <p>*<math>FM_{EOF_c}^a(k_p), X_c, Y_c</math> realisation <math>c</math> of distribution <math>FM_{EOF}^1(k_p), X, Y</math>.</p>	

L'  $EOF$  du mécanisme de défaillance  $j$  pour un temps de prédiction  $k_p$ , noté  $FM_{EOF}^j(k_p)$ , suit une distribution spécifique correspondant à la somme de son état d'avancement  $FM_{T_x}^j(k_p)$  (variable aléatoire bornée au moment de la prédiction  $k_p$ ) et toutes les variables aléatoires restantes du temps de transition  $T_{FM^j}^{e_u, e_v}$  appartenant au mécanisme de défaillance  $j$ , à partir de l'état physique actif le plus proche du mode de défaillance  $FM_{e_x}^j(k_p)$  jusqu'au mode de

défaillance résultant. Pour ce faire, l'algorithme effectue des simulations de Monte-Carlo. Il calcule la réalisation de sommation  $c$ , notée  $FM_{EOF_c}^j(k_p)$ , pour un nombre d'itérations  $numIter$ . La distribution de probabilité résultante  $FM_{EOF}^j(k_p)$  correspond à la distribution  $EOF$  du mécanisme de défaillance  $j$  pour un temps discret de prédiction  $k_p$ .

Les temps de transition  $T_{FMj}^{e_u, e_v}$  sont des variables aléatoires et peuvent être supposés distribués selon la loi de Weibull (A9). Ils sont considérés comme des paramètres génériques du modèle. En fonction des connaissances disponibles (par exemple, des commentaires d'experts et des commentaires des opérateurs) et, si les données historiques sont disponibles, il est possible de recourir à une élicitation d'experts structurée. Cette situation est présentée dans l'étude de cas de la section 3.4.2. Si des connaissances spécialisées sont disponibles et que les données historiques sont en outre suffisamment abondantes, des techniques d'estimation statistique pour les algorithmes d'apprentissage peuvent être mises en œuvre pour estimer les distributions des temps de transition. Un processus de mise à jour bayésien pourrait être utilisé pour mettre à jour les distributions. S'il existe des lois physiques spécifiques pour des mécanismes de défaillance, elles peuvent être utilisées pour estimer directement leurs propagations. Les conditions environnementales et les charges opérationnelles ne sont pas prises en compte dans le présent document, mais leur impact sur l'estimation de la distribution selon la période de transition pourrait être pris en compte.

### 3.3.2 Algorithme de pronostic des modes de défaillance

Le pronostic des modes de défaillance consiste à prédire la distribution de probabilité de l' $EOF$  des modes de défaillance  $v_{EOF}^{Fb}(k_p)$  en agrégeant les résultats des propagations de leurs mécanismes de défaillance  $FM_{EOF}^j(k_p)$  pour un temps discret de la prédiction  $k_p$ .

Différents mécanismes de défaillance peuvent conduire au même mode de défaillance, comme le montre la Figure 3.5. Dans les travaux en cours, il est supposé que tous les mécanismes de

défaillance possibles et connus ayant un processus de propagation ont été identifiés. Cependant, certains mécanismes de défaillance peuvent survenir soudainement en raison d'événements initiateurs aléatoires tels qu'une erreur humaine ou une surcharge. Ces mécanismes de défaillance sont définis comme des mécanismes de défaillance soudaine et aléatoire. Par définition, de tels événements ne peuvent être prédits et aucune action de maintenance ne peut les éviter. Ainsi, même si aucun mécanisme de défaillance n'est actif, il existe une probabilité de défaillance non nulle. Cette probabilité doit être prise en compte dans le processus de prise de décision.

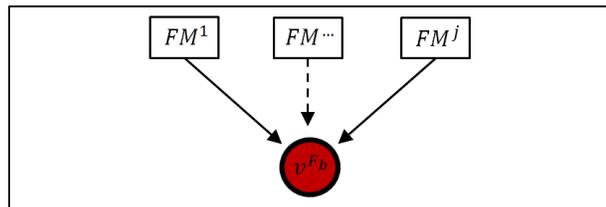


Figure 3.5 Illustration de mécanismes de défaillance menant à un mode de défaillance

Ainsi, l'algorithme 3.3.1 est basé sur l'hypothèse que le premier mécanisme de défaillance pouvant atteindre le mode de défaillance définit l'*EOF* de ce dernier (A5 et A9). Si aucun mécanisme de défaillance actif ne conduit à un mode de défaillance à un instant discret de prédiction  $k_p$ , le mode de défaillance EOF est considéré comme vide ( $v_{EOF}^{F_b}(k_p) = \emptyset$ ). Si aucun état de dégradation n'a été détecté, la défaillance ne peut pas être prédite.

L'algorithme calcule, pour tous les modes de défaillance  $v^{F_b}$ , la fonction d'enveloppe maximale de toutes les fonctions de densité cumulée *EOF* du mécanisme de défaillance y menant. Le temps avant défaillance pour chaque mode de défaillance,  $v_{TF}^{F_b}(k_p)$ , est ensuite déduit du temps de prédiction  $k_p$ .

<b>Algorithm</b>	Failure mode prognosis algorithm for a discrete time of prediction $k_p$
<b>3.3.2</b>	
1: <b>Input:</b> $k_p, [FM_\varepsilon^1(k_p), \dots, FM_\varepsilon^j(k_p)], [FM_{EOF}^1(k_p), \dots, FM_{EOF}^j(k_p)], [FM^1, \dots, FM^j]$ 2: <b>Output:</b> $[v_{EOF}^{F_1}(k_p), \dots, v_{EOF}^{F_b}(k_p)], [v_{TTF}^{F_1}(k_p), \dots, v_{TTF}^{F_b}(k_p)]$ 3: <b>for</b> $c = 1$ to $b$ <b>do</b> : 4: <b>for</b> $a = 1$ to $j$ <b>do</b> : 5: <b>if</b> $FM_\varepsilon^a(k_p) = 1$ and $v^{F_c}$ in $FM^a$ <b>then</b> 6: $CDF(v_{EOF}^{F_c}(k_p)) = Max\_Enveloppe(CDF(FM_{EOF}^a(k_p)))$ 7: $v_{TTF}^{F_c}(k_p) = v_{EOF}^{F_c}(k_p) - k_p$ 8: <b>end if</b> 9: <b>end for</b> 10: <b>end for</b>	

### 3.4 Cas d'application industrielle: cas d'étude des stators hydro-électriques

L'approche proposée a été appliquée en utilisant les données d'alternateurs hydro-électriques provenant du parc de production d'Hydro-Québec. Hydro-Québec est une utilité électrique publique nord-américaine qui produit, transporte et distribue de l'électricité. Les centrales hydro-électriques représentent 99% de son parc de production. Hydro-Québec exploite plus de 350 alternateurs hydro-électriques dans 62 centrales. Les alternateurs sont des pièces d'équipement extrêmement critiques. Une panne inattendue, en particulier en période de pointe, entraîne des pertes de revenus soudaines et des coûts de réparation importants. Les pannes de stator représentent environ 70% des pannes d'alternateurs (CIGRE, 2003). Le pronostic du stator est donc un sujet de recherche important pour assurer la fiabilité et la résilience du parc de production d'Hydro-Québec. Les alternateurs hydrauliques sont des équipements de grande envergure pouvant atteindre plus de 10 mètres de diamètre. Ils ont une durée de vie utile de 50 ans et peuvent parfois être en service jusqu'à 100 ans. Ce sont des équipements complexes comportant de nombreux mécanismes de défaillance impliquant un grand nombre de composants. La Figure 3.6 présente une photo d'un groupe turbine-alternateur d'une centrale hydro-électrique d'Hydro-Québec.



Figure 3.6 Groupe turbine-alternateur d'une centrale d'Hydro-Québec (Hydro-Québec, 2017)

Dans cette étude, les informations disponibles (données sur l'état de santé des stators et connaissances d'experts) sont d'abord analysées. Le modèle de dégradation multi-états du stator et la quantification des paramètres génériques du modèle sont présentés. Ensuite, trois études de cas de défaillance au stator et un cas où aucune défaillance n'a encore été observée sont analysées pour comparer les prédictions du modèle aux résultats réels. Finalement, les performances et les limites du modèle sont discutées en référence aux études de cas.

### 3.4.1 Contexte industriel

À Hydro-Québec, une application Web appelée «MIDA» a été développée et mise en service en 2008 (Levesque, Hudon, Belec, & David, 2009). MIDA recueille les données de diagnostic du stator fournies par les outils de diagnostic disponibles et les utilise pour calculer un indice d'état de santé pour chaque stator. Toutes données de diagnostic colligées depuis le début des années 1990 ont été intégrées à la base de données MIDA. À l'heure actuelle, les données proviennent de sept outils de diagnostic, tels que des analyses des décharges partielles, des mesures en tension C.C. et des inspections visuelles. La plupart des outils de diagnostic sont des mesures hors ligne prises périodiquement conformément au plan de maintenance en vigueur. Une grande partie des inspections ou mesures nécessitent l'intervention des opérateurs et l'arrêt des groupes. En raison du coût des temps d'arrêt et de la lenteur des processus de

dégradation, les intervalles d'inspection et de mesurage sont grands. Par exemple tous les six ans pour une inspection visuelle partielle et tous les 12 ans pour une inspection visuelle complète. Sur la base de ces données de diagnostic périodiques et de leurs analyses, plus de cent symptômes ont été identifiés pour suivre les mécanismes de défaillance du stator. Étant donné qu'Hydro-Québec exploite des centrales hydro-électriques depuis plus de 50 ans, un important volume de connaissances et de retours d'expérience est disponible.

### 3.4.2 Construction du modèle pour les stators des groupes turbine-alternateurs

#### 3.4.2.1 Construction du modèle de dégradation multi-états du stator hydro-électrique

L'équipe d'experts et les ingénieurs de terrain ont travaillé ensemble à travers plusieurs sessions au cours d'une année pour identifier l'ensemble de tous les mécanismes de défaillance possibles. Plus de 150 mécanismes de défaillance conduisant à trois modes de défaillance ( $v^{F_1}$ ,  $v^{F_2}$  and  $v^{F_3}$ ) ont été identifiés. Pour discrétiser ces mécanismes de défaillance, plus de 70 états physiques ont été définis. La moitié de ces états est détectable à l'aide d'outils de diagnostic existants et est identifiable à l'aide de symptômes disponibles à partir de données de diagnostic. Les moyens de diagnostic disponibles ne permettent pas encore de détecter tous les états physiques, même si, dans certains cas, de nouveaux outils de diagnostic pourraient être introduits ou développés pour améliorer la détectabilité. Le modèle de dégradation multi-états résultant d'un stator est présenté à la Figure 3.7 à l'aide d'une visualisation graphique.

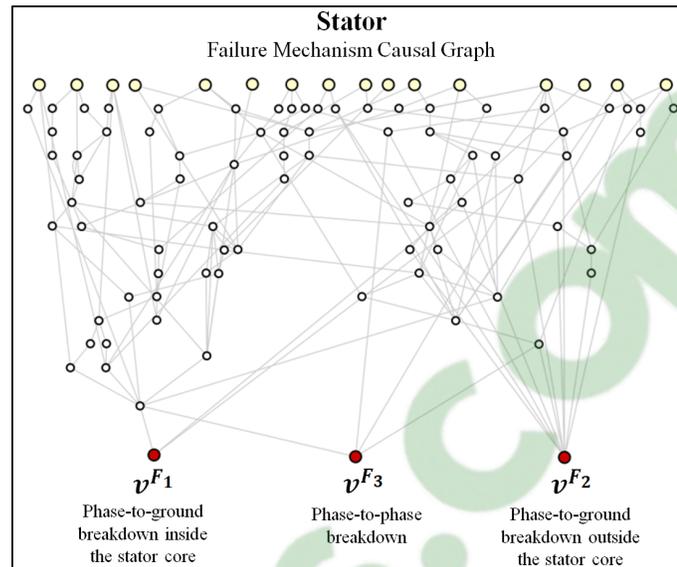


Figure 3.7 Modèle de dégradation multi-états d'un stator hydro-électrique

Dans le graphe de causalité du stator présenté à la Figure 3.7, les causes physiques initiales sont les nœuds du graphe en jaune, les états physiques sont les nœuds blancs et les modes de défaillance, les nœuds rouges. Tous les mécanismes de défaillance identifiés sont présentés comme un chemin allant d'une cause initiale à un mode de défaillance illustré dans le graphique.

L'équipe d'experts et les ingénieurs de terrain ont ensuite défini des algorithmes de détection des états physiques en se basant sur les symptômes pouvant être identifiés par les sept outils de diagnostic de stator disponibles. La Figure 3.8 présente un exemple de mécanisme de défaillance de stator discrétisé avec les algorithmes de détection résultant de ses états physiques.

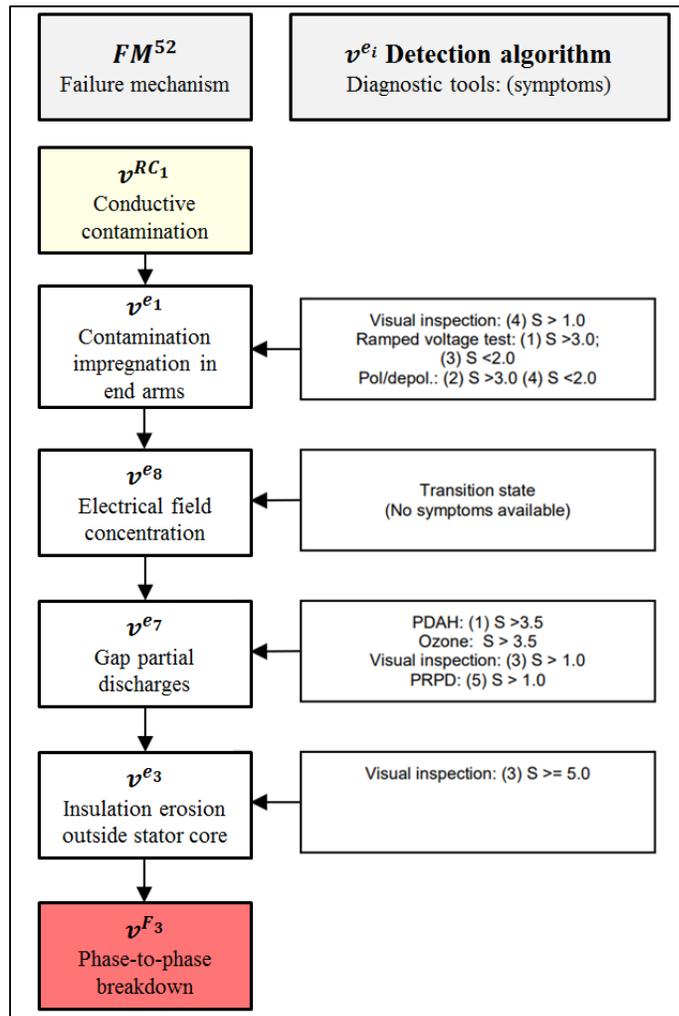


Figure 3.8 Mécanisme de défaillance avec les algorithmes de détection et seuils définissant chaque état physique (Normand Amyot et al., 2013a)

L'état physique  $v^{e_1}$  (imprégnation de contamination dans les extrémités des bras) peut être détecté à l'aide d'outils de diagnostic ou d'inspection (inspection visuelle, test de tension progressive, etc.). Par exemple, si le symptôme (numéro 4) de l'inspection visuelle a une sévérité ( $S$ ) supérieure à 1,0, alors l'état physique  $v^{e_1}$  peut être considéré actif ( $v_{\varepsilon}^{e_i}(k_p) = 1$ ) à un temps de prédiction discret  $k_p$ .

### 3.4.2.2 Quantification de l'incertitude des paramètres génériques du modèle: temps de transition $T_{FMj}^{e_u, e_v}$

Afin de quantifier les temps de transition, les données historiques ont d'abord été explorées pour évaluer la faisabilité de leur utilisation pour une estimation directe. Il a été conclu que les données historiques étaient trop rares pour permettre une estimation directe des temps de transition. Un processus d'élicitation d'experts a donc été lancé, inspiré des approches utilisées par la commission de réglementation nucléaire des États-Unis (NUREG) (U.S. Regulatory Commission (NRC), 1997) et la NASA (NASA, 2004).

Un groupe de quatre experts et un facilitateur/intégrateur technique ont été identifiés pour estimer les temps de transition. Le processus était divisé en quatre étapes principales dans le but de minimiser les biais cognitifs lors de l'élicitation. Lors de la première étape, chaque expert a estimé les temps de transition individuellement sous la forme d'une fonction triangulaire (minimum, valeur attendue, maximum) sans aucune interaction avec les autres experts. Comme la confiance des experts variait en fonction de leur expérience relative avec des mécanismes de défaillance spécifiques, les experts devaient classer leur confiance sur une échelle de cinq points pour chaque mécanisme. Dans un deuxième temps, des réunions ont été organisées au cours desquelles les experts ont dû comparer leurs estimations avec celles des autres. Pour chaque temps de transition, des estimations d'experts (fonctions triangulaires) ont été tracées de manière anonyme sur le même graphique, comme illustré à la Figure 3.9. L'expertise des experts a été utilisée pour définir l'amplitude de chaque fonction triangulaire. Les fonctions triangulaires de la Figure 3.9 ne représentent pas des fonctions de densité réelles; leur but est de représenter le jugement et la confiance des experts en même temps. Afin de vérifier la cohérence du jugement de différents experts, une fonction de densité cumulative (CDF) a été définie. Elle est décrite ci-dessous et illustrée à la Figure 3.9. Les valeurs minimale, maximale et moyenne de la fonction triangulaire cumulative des avis d'experts ont été calculées et tracées pour chaque pas de temps. La zone comprise entre le minimum cumulatif et le maximum représente la cohérence du jugement des experts. Lorsque les estimations des

experts divergeaient de manière significative, une discussion était nécessaire pour parvenir à un consensus.

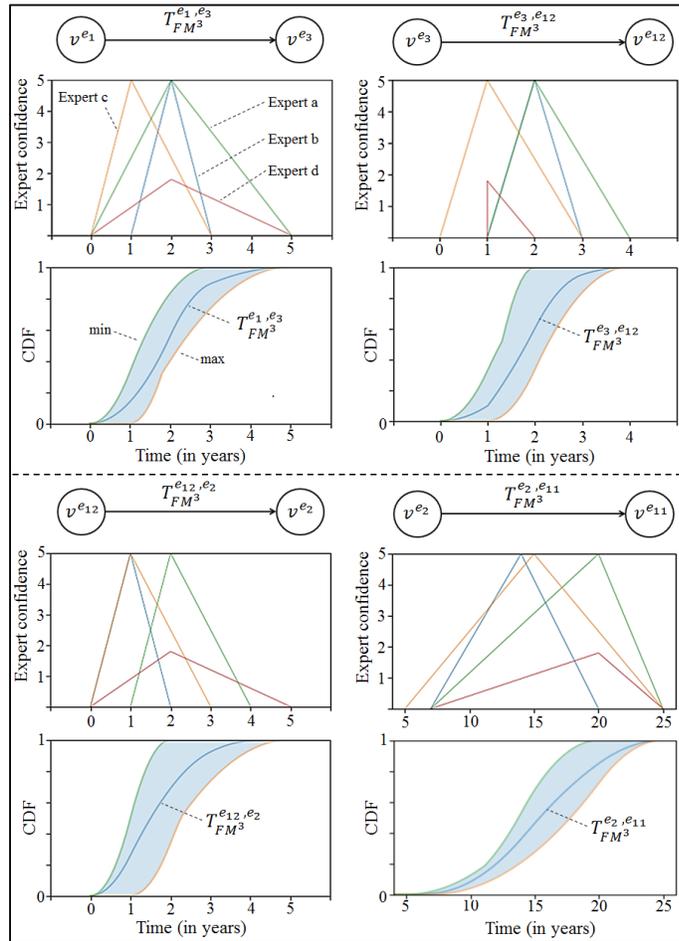


Figure 3.9 Exemples de résultats de processus d'élicitation avec quatre experts sur une partie d'un mécanisme de défaillance

Dans la troisième étape du processus, tous les experts ont réévalué individuellement leurs estimations à la lumière des discussions précédentes. La dernière étape a consisté à agréger le jugement d'expert final en une CDF pour chaque temps de transition entre des états physiques. Dans cette étude, la fonction de densité cumulée moyenne pondérée  $CDF_{aggregation}$  des jugements  $CDF_i$  présentée dans l'équation (3.1) a été choisie. Les pondérations  $p_i$  représentent

les niveaux de confiance des experts. La Figure 3.9 présente quatre résultats des estimations du temps de transition obtenues après des comparaisons d'experts et un consensus.

$$CDF_{aggregation} = \frac{1}{n_{p_i}} \sum p_i CDF_i \quad (3.1)$$

Une fois que la CDF pondérée moyenne a été estimée, un algorithme de vraisemblance a été utilisé pour estimer les paramètres de la distribution de Weibull. Un test de qualité pour évaluer la qualité de l'ajustement (Kolmogorov-Smirnov) a été appliqué pour valider le modèle de Weibull.

### 3.4.3 Application du modèle et évaluation de sa performance

Afin d'appliquer le modèle et d'analyser ses performances et ses limites, trois cas de défaillance et un cas de stator n'ayant pas encore connu de défaillance ont été analysés en utilisant des données de diagnostic historiques disponibles.

La première étude de cas impliquait une panne forcée due à la défaillance du stator A en 2010. Ce stator a été mis en service en 1976 et des réparations majeures ont été effectuées en 1993. En 1993, le stator A était considéré « comme neuf ».

Pour effectuer l'analyse, l'année 2005 a été utilisée comme la date de prédiction pour illustrer les différents résultats de l'algorithme. Les résultats de diagnostic disponibles de 1993 à 2005 ont été acquis. Ensuite, l'algorithme de diagnostic a été exécuté en fonction de cette information. Les algorithmes de détection des états physiques ont permis de détecter sept états physiques actifs et trois états inactifs, ainsi que leurs intervalles de détection possibles associés. Leurs états sont répertoriés à la Figure 3.10. La limite inférieure de ce tableau correspond à la dernière fois où l'état physique a été détecté comme étant inactif, tandis que la limite supérieure correspond au moment où il est devenu actif.

Stator A ( $k_p = 2005$ ) Physical state detection			
ID	Active physical state $\forall e_i   v_{\varepsilon}^{e_i}(2005) = 1$	$v_{\varepsilon_{KE}}^{e_i}(2005)$	
		Min.	Max.
$v^{e_2}$	Slot partial discharges - inside the iron core	2004	2005
$v^{e_{29}}$	Delamination partial discharges	2004	2005
$v^{e_{22}}$	Partial discharges at copper-insulation separation	2005	2005
$v^{e_{19}}$	Discharges with instrumentation lead	2005	2005
$v^{e_4}$	Partial discharges at the semi-conducting and stress grading junction	2005	2005
$v^{e_9}$	Internal partial discharges	2005	2005

Figure 3.10 Résultats des algorithmes de détection d'états physiques à l'année de prédiction 2005

Les intervalles d'activation possibles ont été estimés en se basant sur les données de diagnostic. Notez que l'application de diagnostic MIDA a été mise en œuvre en 2008 et que les données de diagnostic acquises avant 2008 ont été intégrées. L'incertitude des résultats du modèle de pronostic est donc directement proportionnelle à la plage d'incertitude des intervalles de détection des états physiques actifs les plus proches du mode de défaillance  $v_{\varepsilon_{KE}}^{e_i}(k_p)$ . Dans le cas ci-dessus, l'état physique  $v^{e_2}$  présenté dans la Figure 3.10, a été détecté comme actif à la date de prédiction 2005 ( $v_{\varepsilon}^{e_2}(2005) = 1$ ). Il a été détecté actif pour la première fois en 2005 ( $v_{\varepsilon_{KE}}^{e_2}(2005) = 2005$ ). La dernière fois qu'il avait été détecté inactif remonte à 2004. Ainsi, il a été actif entre 2004 et 2005 ( $v_{\varepsilon_{KE}}^{e_2}(2005) = [2004; 2005]$ ).

Les algorithmes d'estimation d'état ont été appliqués sur la base des résultats de détection de défaut au moment de la prévision 2005. L'algorithme de détection des mécanismes de défaillance (algorithme 3.2.2.a) a détecté 104 mécanismes de défaillance potentiellement actifs: 94 menant au mode de défaillance  $v^{F_1}$  ( $v_{FM_{active}}^{F_1}(2005) = 94$ ), 7 menant à  $v^{F_3}$  ( $v_{FM_{active}}^{F_3}(2005) = 7$ ) et 3 menant à  $v^{F_2}$  ( $v_{FM_{active}}^{F_2}(2005) = 3$ ). Ensuite, l'algorithme d'isolation d'état des mécanismes de défaillance (algorithme 3.2.2.b) a été exécuté. La Figure

3.11 présente une représentation graphique de l'estimation de l'état du stator A en 2005. Les nœuds des états physiques actifs sont orange, les nœuds des états physiques inactifs sont en vert et les chemins des mécanismes de défaillance actifs sont en traits gras jusqu'à leur état de propagation isolé.

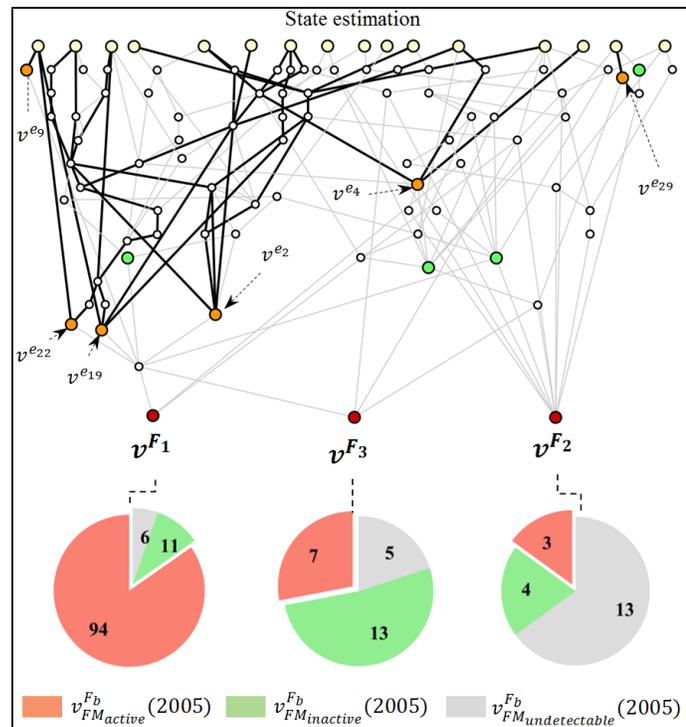


Figure 3.11 Estimation de l'état du Stator A à l'année de prédiction

La proportion de mécanismes de défaillance indétectables peut varier pour chaque mode de défaillance en fonction des outils de diagnostic utilisés (tous les outils ne sont pas toujours utilisés). Pour le stator A, 13 mécanismes de défaillance non détectables ont été identifiés en 2005 pour le mode de défaillance  $v^{F_2}$  sur 20 mécanismes de défaillance potentiels ( $v_{FM_{undetectable}}^{F_2}$  (2005) = 13), comparativement au mode de défaillance  $v^{F_1}$ , qui a seulement 6 mécanismes de défaillance indétectable ( $v_{FM_{undetectable}}^{F_1}$  (2005) = 6) sur 111. Étant donné que peu d'outils ont été utilisés, la plupart des mécanismes n'ont pas été détectés.

L'algorithme de pronostic peut ensuite être appliqué sur les résultats de l'estimation d'état de 2005. L'algorithme de propagation du mécanisme de défaillance (algorithme 3.3.1) a été exécuté. On a choisi d'utiliser une distribution uniforme pour représenter les variables aléatoires de l'état du mécanisme de défaillance  $FM_{T_x}^j(k_p)$ . Dans cette étude de cas, il a été décidé de fixer le nombre d'itérations de réalisation à cinq mille ( $numIter = 5000$ ) pour la simulation Monte-Carlo. La Figure 3.12 présente la propagation de tous les mécanismes de défaillance actifs pour chaque mode de défaillance. Par exemple, pour le mode de défaillance  $v^{F_2}$ , trois mécanismes de défaillance actifs ont été détectés et propagés. Le premier mécanisme de défaillance pouvant atteindre le mode de défaillance est identifié comme le mécanisme de défaillance  $FM^{78}$ . Son état physique actif le plus proche de la défaillance est l'état  $v^{e_{29}}$  ( $FM_{e_x}^{78}(2005) = v^{e_{29}}$ ). Ainsi, l'état d'avancement du mécanisme  $FM_{T_x}^{78}(2005)$  est défini par une distribution uniforme encadrée entre 2004 et 2005 par l'algorithme d'isolation (algorithme 3.2.2.b). L'algorithme de propagation (algorithme 3.3.1) a prédit que le mécanisme de défaillance  $FM^{78}$  peut atteindre sont  $EOF$  ( $FM_{EOF}^{78}(2005)$ ) entre 2014 et 2024, avec un intervalle de confiance de 80% à l'année de prédiction 2005.

Enfin, l'algorithme de pronostic du mode de défaillance (algorithme 3.3.2) a été exécuté en se basant sur les résultats de propagation du mécanisme de défaillance en 2005. Les résultats de pronostic pour l'année de prédiction 2005 sont présentés à la figure 14. Pour le même exemple du mode de défaillance  $v^{F_2}$ , la fonction d'enveloppe des trois mécanismes de défaillance actifs propagés indique que le mode de défaillance  $v^{F_2}$  ( $v_{EOF}^{F_2}(2005)$ ) peut être atteint entre 2014 et 2024, avec un intervalle de confiance de 80% en se basant sur les informations disponibles en 2005. Son  $TTF$  prédit en 2005 ( $v_{TTF}^{F_2}(2005)$ ) est estimé dans 9 à 19 ans.

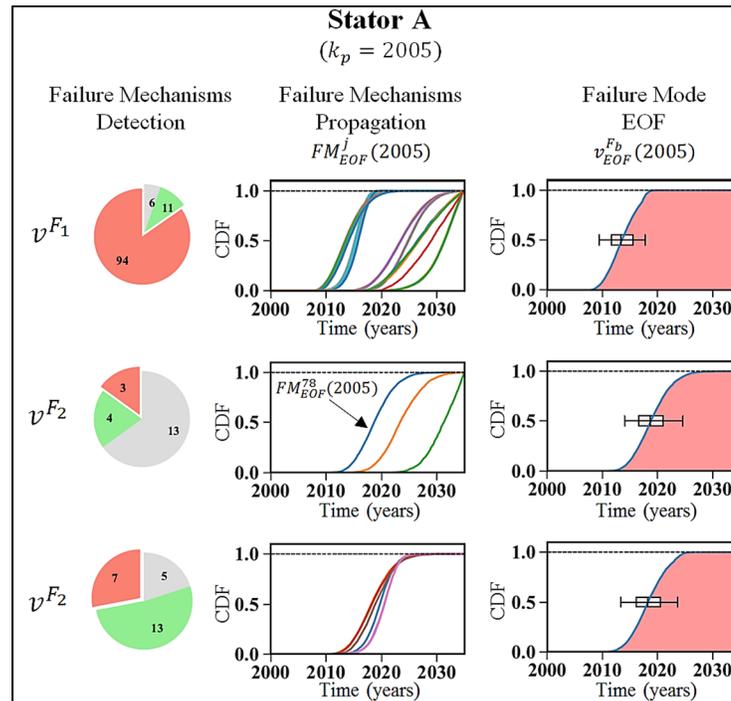


Figure 3.12 Résultats de la propagation des mécanismes de défaillance et de la prédiction des occurrences des modes de défaillance pour le stator A à la date de prédiction 2005

Dans cette étude, chaque fois qu'une nouvelle mesure est acquise, les algorithmes de diagnostic et de pronostic décrits ci-dessus sont exécutés. Cela permet de mettre à jour les prévisions à mesure que de nouvelles informations deviennent disponibles. Pour le stator A, huit résultats de mesure ou données d'inspection ont été acquis à huit moments différents à partir de 2002. La Figure 3.13 présente les résultats de pronostic de 2002 à 2010. Les résultats de pronostic comprennent toujours le résultat de la détection du mécanisme de défaillance et le pronostic du mode de défaillance sur la durée de la prédiction. Comme mentionné précédemment, les décideurs doivent prendre en compte le délai de défaillance estimé de chaque mode de défaillance.  $v_{\text{TF}}^{\text{Fb}}(k_p)$  et le nombre de mécanismes de défaillance indétectables pouvant mener à chacun  $v_{\text{FM}_{\text{undetectable}}}^{\text{Fb}}(k_p)$  à travers les différentes dates de prédiction. Comme mentionné dans la section 3.3.1, si aucun état physique de dégradation n'a été détecté, une défaillance ne

peut pas être prédite. Ainsi, un "X" est alors tracé sur l'abscisse de la date de prédiction pour informer l'utilisateur qu'aucune prédiction n'a été exécutée à cette date.

Sur la base d'enquêtes menées par des ingénieurs de terrain, le mode de défaillance atteint et ayant entraîné la panne en 2011 était le mode de défaillance  $v^{F_1}$ : claquage entre la phase et la terre. Les résultats montrent que le modèle aurait pu prévoir la défaillance huit ans à l'avance, à partir de 2003, avec un intervalle de confiance de 60%. La défaillance est survenue en 2010, 17 ans seulement après le remplacement du stator A. Sans mesures ni pronostic, une telle défaillance aurait été totalement inattendue entre 2007 et 2016. Le nombre de mécanismes de défaillance indétectable pour les modes de défaillance  $v^{F_1}$  and  $v^{F_3}$  était faible de 2002 à 2010, alors que la plupart des mécanismes de défaillance identifiés conduisant au mode de défaillance  $v^{F_2}$  étaient indétectable. En raison des plages de probabilité qui se chevauchent pour les trois modes de défaillance, il est parfois difficile de déterminer à l'avance quel mode de défaillance en particulier se produira. Dans ce cas, cependant, depuis 2003, l'occurrence du mode de défaillance  $v^{F_1}$  ( $v_{TF}^{F_1}(k_p)$ ) a été prédit quelques années plus tôt que pour les modes de défaillance  $v^{F_2}$  et  $v^{F_3}$ .

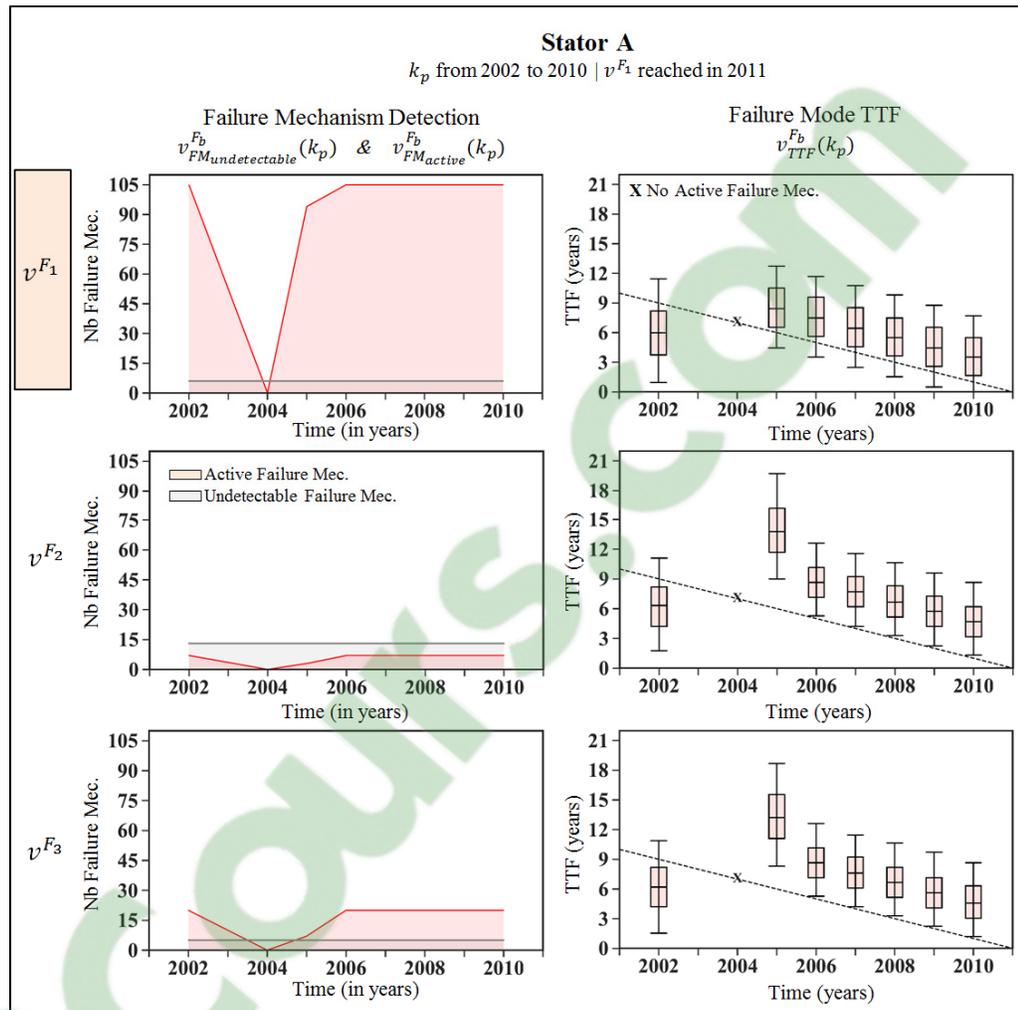


Figure 3.13 Validation de la prédiction du mode de défaillance pour le stator A, avec des dates de prédiction allant de 2002 à 2010.

La deuxième étude de cas portait sur la défaillance du stator B, qui a atteint le mode de défaillance  $v^{F_1}$  en 2011. Ce stator a été mis en service en 1976 et aucune réparation majeure n'a été effectuée avant 2011. L'algorithme de pronostic a été appliqué à onze reprises de 1992 à 2010. Les résultats des pronostics sont présentés à la Figure 3.14.

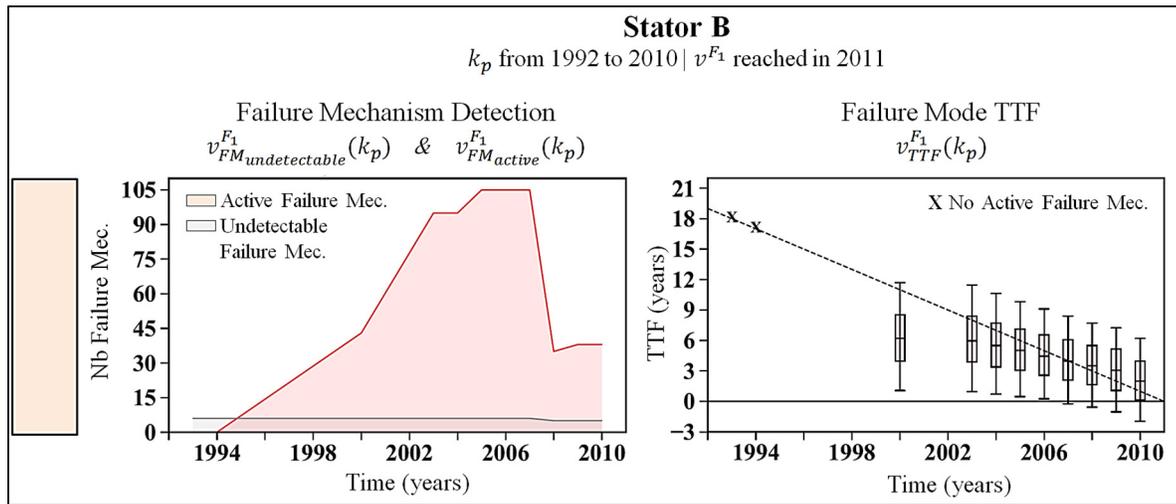


Figure 3.14 Validation du pronostic du mode de défaillance pour le stator B, avec des années de prédiction allant de 1992 à 2010

Les résultats montrent que le modèle de pronostic aurait prédit l'apparition du mode de défaillance  $v^{F_1}$  5 ans à l'avance avec un intervalle de confiance de 80% et 7 ans à l'avance avec un intervalle de confiance de 50%. Le graphique de détection des mécanismes de défaillance indique que peu de mécanismes de défaillance menant au mode de défaillance  $v^{F_1}$  du stator B étaient actifs entre 1992 et 2000. Ensuite, entre 2000 et 2007, le nombre de mécanismes de défaillance actifs détectés a augmenté pour atteindre 104 mécanismes de défaillance actifs ( $v_{FM_{actif}}^{F_1}(2007) = 104$ ) en 2007. En 2008, les résultats de la première inspection visuelle depuis 1992 ont été acquis, entraînant l'inactivation de plus de 60% des mécanismes de défaillance. Les inspections visuelles ont un impact plus important que les autres outils de diagnostic dans les algorithmes de détection d'état physique, ce qui permet de réduire le nombre de mécanismes de défaillance actifs possibles et d'améliorer ainsi les prédictions.

La troisième étude de cas portait sur la défaillance du stator C en raison de l'apparition du mode de défaillance  $v^{F_1}$  en 2016. Cet alternateur a été mis en service en 1951 et aucune réparation majeure n'a été effectuée avant 2016. L'algorithme de pronostic a été appliqué à neuf reprises de 2006 à 2016. Les résultats de pronostic sont présentés à la figure 17.

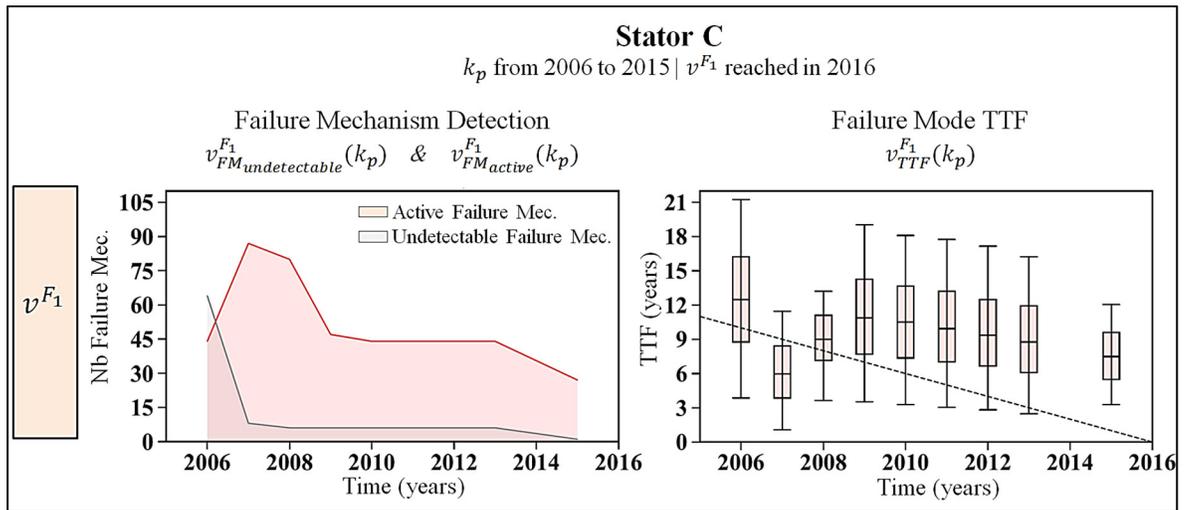


Figure 3.15 Validation de la prédiction du mode de défaillance pour le stator C, pour des années de prédiction allant de 2006 à 2015

Dans ce cas, les résultats montrent que le modèle de pronostic est parvenu à prévoir l'apparition du mode de défaillance  $v^{F_1}$  à partir des années 2006 et jusqu'à 2013 avec un intervalle de confiance de 80%. Cependant, en 2015, un an avant la survenue du mode  $v^{F_1}$ , le modèle de pronostic n'a pas réussi à prédire le mode, car il prévoyait que  $v_{EOF}^{F_1}(2015)$  se produirait entre 2018 et 2027 avec un intervalle de confiance de 80%. De plus, dans ce cas, la plage d'incertitude des prévisions s'est élevée à 17 ans en 2006 et est restée significative pour la plupart des prédictions. Ceci est principalement dû à la grande plage d'incertitude de l'estimation de l'état du mécanisme de défaillance actif  $FM_{T_x}^j(k_p)$ , liée au fait qu'aucune information de diagnostic n'était disponible pour la période de 1951 à 2006.

La dernière étude de cas portait sur un stator pour lequel aucune défaillance n'avait encore été constatée en 2017. Le Stator D avait été mis en service en 1932 et avait fait l'objet de réparations majeures en 1989. L'analyse avait été effectuée sur 13 périodes de prévision allant de 1992 à 2016. Les résultats de pronostic sont présentés à la Figure 3.16.

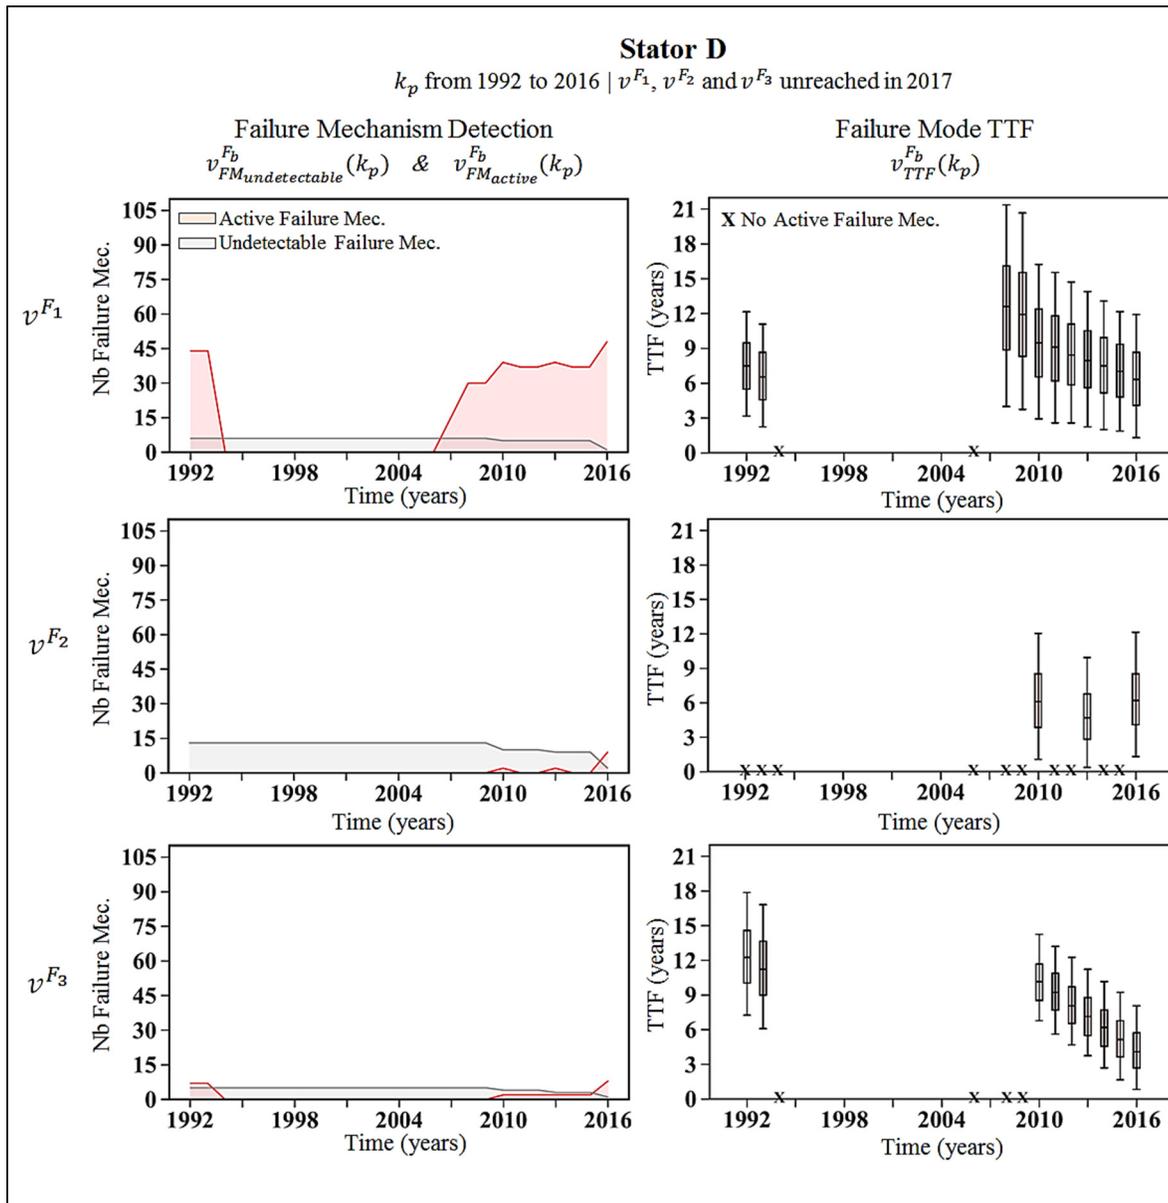


Figure 3.16 Validation du pronostic du mode de défaillance pour le stator D, avec des années de prédiction allant de 1992 à 2016

Les résultats montrent que le modèle a commencé à prédire l'occurrence du mode de défaillance  $v_{TTF}^{F_1}(k_p)$  et  $v_{TTF}^{F_3}(k_p)$  de 1992 à 1993 en raison de la détection de mécanismes de défaillance actifs. Ensuite, entre 1994 et 2008, aucun mécanisme de défaillance actif n'a été détecté pour aucun des modes de défaillance. En 2008, 37 mécanismes de défaillance

conduisant au mode de défaillance  $v^{F_1}$  ( $v_{FM_{actif}}^{F_1}(2008) = 37$ ) ont été détectés comme actifs. Les prédictions sur le temps nécessaire pour atteindre le mode de défaillance  $v^{F_1}$  ( $v_{TTF}^{F_1}(k_p)$ ) convergent de 2008 à 2016 et indiquent une occurrence  $v_{EOF}^{F_1}(k_p)$  entre 2018 et 2028, avec un intervalle de confiance de 80%. Les prédictions sur le temps nécessaire pour atteindre le mode de défaillance  $v^{F_2}$  ( $v_{TTF}^{F_3}(k_p)$ ) convergent également de 2010 à 2016 et montrent une occurrence  $v_{EOF}^{F_3}(k_p)$  entre 2017 et 2025, avec un intervalle de confiance de 80%. Pour le mode de défaillance  $v^{F_2}$ , le rapport entre les mécanismes de défaillance non détectables et les mécanismes de défaillance actifs de 1992 à 2015 n'inspire pas confiance dans les prédictions. En 2016, le modèle prédit l'occurrence du mode de défaillance  $v_{TTF}^{F_2}(2016)$  entre 2018 et 2028 avec un intervalle de confiance de 80%. Selon les dernières informations disponibles sur le stator D, aucune panne ne s'était encore produite en 2017 et des travaux de maintenance mineurs avaient été effectués en octobre 2016.

### 3.5 Discussion

Une méthodologie de pronostic multimodes de défaillance pour les équipements complexes a été proposée et a été appliquée à quatre études de cas sur des stators hydro-électriques du parc de production d'Hydro-Québec. Comme indiqué à la section 3.3, la méthodologie proposée est conçue comme un cadre adaptatif dans lequel différentes options peuvent être sélectionnées en fonction des informations et des ressources disponibles. Dans les études de cas présentées, les données de diagnostic provenaient de différentes sources et les données historiques existaient, mais étaient rares, un problème courant dans l'industrie. D'autre part, d'importantes connaissances spécialisées étaient disponibles et ont été intégrées au modèle. Des efforts considérables ont été investis dans la construction et la quantification des modèles, motivés notamment par la criticité des équipements. Le résultat est un modèle détaillé de dégradation multi-états composé de plus de 150 mécanismes de défaillance discrétisés par plus de 70 états physiques et impliquant un nombre important de temps de transition estimés par des experts. Une granularité plus fine du modèle le rendrait plus dynamique avec des données de diagnostic

actualisées, mais compliquerait en même temps la quantification des temps de transition. Ce processus doit être optimisé pour améliorer les performances tout en garantissant que le modèle est développé de manière rentable et répond aux besoins d'affaires.

Les résultats d'études de cas de stator d'alternateurs hydro-électriques ont montré que le modèle peut utiliser différentes sources de données de diagnostic acquises au fil du temps pour détecter de manière dynamique tous les mécanismes de défaillance actifs possibles et de prédire l'apparition des modes de défaillance. Le modèle permet d'évaluer les performances des résultats de pronostic. Premièrement, le modèle aide à détecter si les sources de diagnostic suffisent à couvrir les mécanismes de défaillance et à empêcher que les modes de défaillance se produisent de manière inattendue. Si seuls quelques outils de diagnostic fournissent des données éparses, le nombre de mécanismes de défaillance non détectables  $v_{FM_{undetectable}}^{Fb}(k_p)$  restera élevé au cours des années de prédiction, conduisant à une confiance faible dans les résultats de pronostic. Le cas du stator D de 1992 à 2015 présenté à la Figure 3.16 illustre ce point. Deuxièmement, l'incertitude des résultats de pronostic est évaluée en fonction de l'incertitude épistémique des connaissances des experts ( $T_{FMj}^{eu, ev}$ ) et de l'estimation de l'état par les algorithmes ( $FM_{T_x}^j(k_p)$ ) à des dates de prédiction. Une analyse d'incertitude des résultats de pronostic permet de déterminer si la plage d'incertitude est principalement due à une incertitude concernant l'estimation de l'état ou à une connaissance insuffisante des temps de transition inter-états.

Les études de cas de défaillance historiques des stators A, B et C ont montré que le modèle peut prédire les occurrences de mode de défaillance plusieurs années à l'avance en utilisant des données historiques. La plage d'incertitude pour l'occurrence du mode de défaillance prédit varie en fonction de l'incertitude de l'estimation d'état au moment de la prédiction et de l'incertitude résultant de la propagation des mécanismes de défaillance. Les occurrences des modes de défaillance sur les stators A et B auraient pu être prédites plus de huit ans à l'avance.

Les résultats présentés et ceux d'autres études sur les stators montrent que le modèle proposé et ses algorithmes sous-jacents constituent un outil attrayant et efficace qui évoluera pour prévoir et prévenir l'apparition de modes de défaillance pour des équipements complexes. Cependant, le modèle actuel peut générer de fausses alarmes dans les cas où les données de diagnostic sont rares. De plus, les conditions environnementales, les charges opérationnelles et la maintenance effectuée ont toutes une incidence significative sur le taux de propagation des mécanismes de défaillance, mais ne sont pas encore incluses dans le modèle. Les pistes identifiées pour améliorer le modèle de pronostic des stators incluent le développement de nouveaux capteurs permettant de détecter de nouveaux états physiques et ainsi d'améliorer la détectabilité des mécanismes, et l'utilisation de modèles statistiques sur des données historiques pour estimer les temps de transition. ( $T_{FMj}^{eu, ev}$ ). Sur la base des études de cas, la méthodologie de pronostic en mode multi-défaillance pourrait être améliorée. Par exemple, en prenant en compte les actions de maintenance, les conditions environnementales et les conditions d'opération pour obtenir des temps de transition dynamiques.

### 3.6 Conclusion

Ce chapitre présente une approche holistique permettant le pronostic simultané de multiples modes de défaillances pour les équipements complexes. Une méthodologie générique est proposée sous la forme d'un cadre adaptatif permettant la construction de modèles de pronostic basés sur les informations disponibles et le contexte industriel. Un ensemble d'hypothèses est proposé pour modéliser la détection des mécanismes de défaillance et leur propagation sur la base des connaissances d'experts et du retour d'expérience des ingénieurs de terrain. La première étape de la méthodologie consiste à créer un modèle de dégradation multi-états pour suivre la progression de tous les mécanismes de défaillance actifs possibles jusqu'au mode de défaillance associé. Pour ce faire, sur la base des hypothèses émises, un algorithme de diagnostic est proposé pour détecter de manière dynamique les mécanismes de défaillance actifs éventuels et isoler leur état de propagation à chaque instant de prédiction, sur la base d'informations de diagnostic hétérogènes. Un algorithme de pronostic est proposé et consiste

à propager tous les mécanismes de défaillance actifs de leur état à un moment de prédiction discret jusqu'aux modes de défaillance associés. En fonction des données historiques et des connaissances spécialisées disponibles, plusieurs options sont proposées pour estimer les temps de transition (paramètres de modèle génériques) et leurs incertitudes relatives. En conséquence, le modèle de pronostic prédit le temps restant avant l'occurrence de chaque mode de défaillance pour tous les temps discrets de prédiction. Il identifie également le nombre de mécanismes de défaillance indétectables sur les durées de prédiction, en fonction des informations de diagnostic disponibles, afin de garantir la résilience du modèle. Des études de cas sont présentées pour de vrais stators hydro-électriques du parc de production d'Hydro-Québec. Le contexte industriel, les informations disponibles et le modèle de dégradation multi-états qui en résulte sont présentés. Les hypothèses permettant aux experts d'estimer l'incertitude des paramètres génériques du modèle sont expliquées. Pour comparer les prédictions du modèle au comportement passé, trois défaillances de stator et un stator qui n'a pas encore connu de défaillance ont été analysés. Les résultats montrent que le modèle est dynamique par rapport aux informations nouvellement disponibles et peut prendre en compte de nombreuses sources différentes d'informations de diagnostic. L'utilisation de l'algorithme de pronostic semble être un moyen efficace de prédire l'occurrence des modes de défaillance d'équipements complexes, mais des efforts supplémentaires sont nécessaires pour réduire les incertitudes liées aux prédictions.

## CHAPITRE 4

### APPROCHE DE MAINTENANCE PRÉDICTIVE POUR ÉQUIPEMENT COMPLEXE BASÉE SUR LES RÉSULTATS DE PRONOSTIC

Ce chapitre vise à faire évoluer les algorithmes de pronostic proposés dans le CHAPITRE 4 pour permettre l'application de la maintenance prévisionnelle en tenant en compte le contexte opérationnel. Dans ce chapitre, le graphe de causalité est vu comme un réseau de Pétri (PN).

#### 4.1 Hypothèses du modèle de maintenance prévisionnelle

Dans ce chapitre, les hypothèses portant sur le modèle de pronostic décrit dans le Tableau 3.1 sont appliquées. Comme mentionné précédemment, le modèle peut être présenté comme un graphe causal ou un réseau de Pétri coloré. Ce modèle peut être considéré comme générique. Il représente l'ensemble des mécanismes de défaillance  $FM^j$  qui partent d'une cause initiale  $v^{RCa}$  à un mode de défaillance  $v^{Fb}$ . Les états physiques ou nœuds du graphe  $v^{ei}$  peuvent alors être ciblés pour être associés à des actions de maintenance  $v_{M_n}^{ei}$ .

- Hypothèse sur les états physiques

Les mécanismes de défaillance sont considérés comme étant en compétition. Le premier mécanisme de défaillance qui atteint un état cible définit la probabilité d'occurrence d'un mode de défaillance (hypothèse pessimiste).

- Hypothèses sur la maintenance prévisionnelle

La maintenance est considérée comme ayant un effet positif sur le système une fois qu'un seuil de dégradation spécifique est atteint. Cette tâche de maintenance  $M_n$  peut être considérée comme spécifique à un état physique  $v^{ei}$  et est notée  $v_{M_n}^{ei}$ . La tâche de maintenance  $v_{M_n}^{ei}$  doit être effectuée avant l'occurrence du mode de défaillance qui est associé aux mécanismes de l'état ciblé  $v^{Fb}$ .

## 4.2 Algorithmes de diagnostic

Les mêmes algorithmes de diagnostic que ceux décrits dans le CHAPITRE 3 sont utilisés. Dans un premier temps, les algorithmes de détection de défaut de chaque état physique de dégradation permettent d'identifier les états actifs. Les algorithmes de détection (Algorithme 3.2.2.a) et d'isolation des mécanismes de défaillance (Algorithme 3.2.2.b) permettent d'estimer l'état du système pour des dates de prédiction spécifique  $k_p$ .

## 4.3 Algorithmes de propagation des mécanismes de défaillance pour la maintenance prévisionnelle

### 4.3.1 Propagation des mécanismes de défaillance vers les états ciblés pour la maintenance

L'idée principale est de propager indépendamment tous mécanismes de défaillance détectés actifs vers les états cibles. Une variable notée  $v^{e_{target}}$  est proposée pour définir les états cibles pour lesquels nous souhaitons prédire l'occurrence sur un temps discret de prédiction  $v_{CDF}^{e_{target}}(k_p)$ . Tel que défini dans les algorithmes de diagnostic, l'état d'un mécanisme de défaillance active  $FM_{T_x}^j(k_p)$  à un temps de prédiction  $k_p$  défini par l'intervalle d'activation du dernier état actif  $FM_{e_x}^j(k_p)$  comme la date initiale de propagation. Ensuite, le PN stochastique se propage à travers les états restants du mécanisme de défaillance vers l'état cible  $v^{e_{target}}$ . Pour sommer les différents temps de transition aléatoires restants, une simulation de Monte Carlo est utilisée pour un nombre spécifique d'itérations noté *numIter* dans l'Algorithme 5.3.1.

<b>Algorithm 5.3.1</b>	Failure mechanism propagation algorithm for a discrete time of prediction $k_p$ to target states contained in $Target$
<p>1: <b>Input:</b> <math>k_p, numIter, [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)], [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)], [FM_{T_x}^1(k_p), \dots, FM_{T_x}^j(k_p)], [FM^1, \dots, FM^j], [T_{FM^1}^{e_1, e_3}, \dots, T_{FM^j}^{e_u, e_v}], v^{e_{target}}</math></p> <p>2: <b>Output:</b> <math>[FM_{v^{e_{target}}}^1(k_p), \dots, FM_{v^{e_{target}}}^j(k_p)]</math></p> <p>3: <b>for</b> <math>a = 1</math> to <math>j</math> <b>do</b></p> <p>4:   <b>if</b> <math>FM_{e_x}^a(k_p) = 1</math> <b>and</b> <math>v^{e_{target}}</math> <b>in</b> <math>FM^a</math> <b>then</b></p> <p>5:     <b>for</b> <math>c = 1</math> to <math>numIter</math> <b>do</b></p> <p>6:       <math>X \boxtimes FM_{T_x}^a(k_p)</math></p> <p>7:       <math>rank = rank(FM_{e_x}^a(k_p))</math></p> <p>8:       <math>FM_{v_c}^a(k_p) = X_c</math></p> <p>9:       <b>while</b> <math>rank \neq rank(v^{e_{target}})</math> <b>do</b></p> <p>10:          <math>Y \boxtimes T_{FM^a}^{e_{rank}, e_{rank+1}}</math></p> <p>11:          <math>FM_{v_c}^a(k_p) = FM_{v_c}^a(k_p) + Y_c</math></p> <p>12:       <b>end while</b></p> <p>13:     <b>end for</b></p> <p>14:   <b>end if</b></p> <p>15: <b>end for</b></p>	
* $FM_{v_c}^a(k_p), X_c, Y_c$ realization $c$ of distribution $FM_{v^{e_{target}}}^a(k_p), X, Y$ .	

La Figure 4.1 illustre la propagation de chaque mécanisme de défaillance actif vers l'état cible  $v^{e_{14}}$ . En 2016, même si neuf mécanismes de défaillance ont été détectés actifs, deux seulement ont conduit à l'état  $v^{e_{14}}$ . Ainsi, seuls deux mécanismes de défaillance ont été propagés:  $FM^1$  and  $FM^2$ . La fonction de densité cumulée (CDF) de ces deux mécanismes est illustrée à la Figure 4.1. Ces CDFs,  $FM_{v^{e_{14}}}^1(2016)$  et  $FM_{v^{e_{14}}}^2(2016)$  illustrent la probabilité prédite en 2016 que chaque mécanisme de défaillance  $FM^1$  and  $FM^2$  atteignent l'état physique ciblé  $v^{e_{14}}$ .

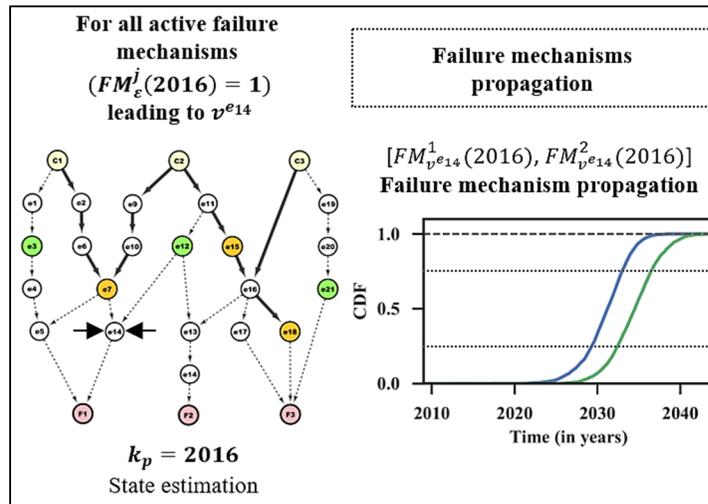


Figure 4.1 Illustration de l'algorithme de propagation des mécanismes de défaillance vers un état cible

#### 4.3.2 Propagation des mécanismes de défaillance vers les modes de défaillance liés aux états ciblés pour la maintenance prévisionnelle

Sur la base des mêmes hypothèses, un deuxième algorithme permet de propager indépendamment tous les mécanismes de défaillance actifs contenant les états cibles  $v^{e_{target}}$  à partir de l'estimation de leur état  $FM_{T_x}^j(k_p)$  à une date de prédiction  $k_p$  vers les modes de défaillance résultants  $v^{F_b}$ . Cet algorithme est légèrement différent de celui proposé dans le CHAPITRE 3 précédent. Il propage seulement les mécanismes de défaillance comprenant l'état ciblé pour la maintenance prévisionnelle en question  $v^{e_{target}}$ . L'algorithme (Algorithme 5.3.2) permet alors de propager l'ensemble des mécanismes de défaillance actifs qui sont relié à l'état ciblé  $v^{e_{target}}$  vers les modes de défaillance résultants.

La Figure 4.2 montre la propagation de chaque mécanisme de défaillance actif vers les modes de défaillance liés à l'état cible  $v^{e_{14}}$ . Dans ce cas, les deux mécanismes de défaillance actifs liés à l'état cible mènent à un seul mode de défaillance:  $v^{F_1}$ . En 2016, ces deux mécanismes de défaillance ont été propagés:  $FM^1$  and  $FM^2$ . Leurs CDFs sont illustrées à la Figure 4.1. Les

CDFs  $FM_{EOF}^1(2016)$  et  $FM_{EOF}^2(2016)$  représentent la probabilité prédite en 2016 que chaque mécanisme de défaillance  $FM^1$  and  $FM^2$  atteigne un mode de défaillance et ainsi la perte de fonction de l'équipement ( $EOF$ ). En d'autres mots,  $FM_{EOF}^2(2016)$  est la probabilité d'occurrence du mode de défaillance résultant de la propagation du mécanisme de défaillance  $FM^2$  à la date de prédiction 2016.

<b>Algorithme</b> <b>5.3.2.</b>	Failure mechanism propagation algorithm for a discrete time of prediction $k_p$ to failure modes $v^{Fb}$ related to the target state $v^{etarget}$
<p>1: <b>Input:</b> <math>k_p, numIter, [FM_{e_x}^1(k_p), \dots, FM_{e_x}^j(k_p)], [FM_{e}^1(k_p), \dots, FM_{e}^j(k_p)], [FM_{T_x}^1(k_p), \dots, FM_{T_x}^j(k_p)], [FM^1, \dots, FM^j], [T_{FM^1}^{e_1, e_3}, \dots, T_{FM^j}^{e_u, e_v}], v^{etarget}</math></p> <p>2: <b>Output:</b> <math>[FM_{EOF}^1(k_p), \dots, FM_{EOF}^j(k_p)]</math></p> <p>3: <b>for</b> <math>a = 1</math> to <math>j</math> <b>do:</b></p> <p>4:   <b>if</b> <math>FM_{e}^a(k_p) = 1</math> <b>and</b> <math>v^{etarget}</math> <b>in</b> <math>FM^a</math> <b>then</b></p> <p>5:     <b>for</b> <math>c = 1</math> to <math>numIter</math> <b>do</b></p> <p>6:       <math>X \boxtimes FM_{T_x}^a(k_p)</math></p> <p>7:       <math>rank = rank(FM_{e_x}^a(k_p))</math></p> <p>8:       <math>FM_{EOF_c}^a(k_p) = X_b</math></p> <p>9:       <b>while</b> <math>rank \neq rank(v^{Fb})</math> <b>do</b></p> <p>10:          <math>Y \boxtimes T_{FM^a}^{e_{rank}, e_{rank+1}}</math></p> <p>11:          <math>FM_{EOF_c}^a(k_p) = FM_{EOF_c}^a(k_p) + Y_c</math></p> <p>12:       <b>end while</b></p> <p>13:     <b>end for</b></p> <p>14:   <b>end if</b></p> <p>15: <b>end for</b></p>	
* $FM_{EOF_c}^a(k_p), X_c, Y_c$ realization $c$ of distribution $FM_{EOF}^1(k_p), X, Y$ .	

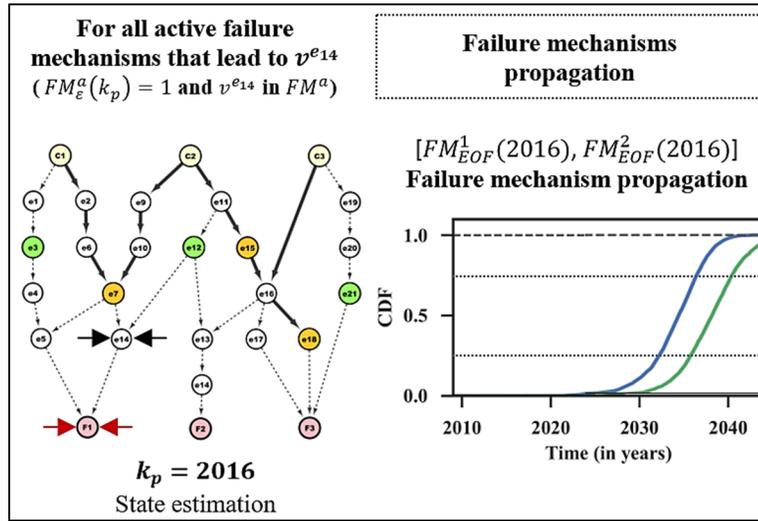


Figure 4.2 Illustration de l'algorithme de propagation du mécanisme de défaillance vers un état cible

#### 4.4 Pronostic de l'occurrence des états ciblés pour la maintenance prévisionnelle et des modes de défaillance qui y sont associés

La dernière étape consiste à agréger la propagation des mécanismes de défaillance actifs afin d'estimer l'occurrence du ou des états physiques cibles  $v^{e_{target}}$  et leurs modes de défaillance résultant  $v^{F_b}$  pour une date de prédiction  $k_p$ . Partant de l'hypothèse que les mécanismes de défaillance sont en concurrence, leur occurrence a été définie comme l'enveloppe de toutes les fonctions CDF. Les équations (4.1) et (4.2) présentent les deux fonctions agrégées.

$$v_{CDF}^{e_{target}}(k_p) = Max\_envelope(FM_{v^{e_{target}}}^j(k_p)) \quad (4.1)$$

$$v_{EOF}^{F_b}(k_p) = Max\_envelope(FM_{EOF}^j(k_p)) \quad (4.2)$$

#### 4.5 De la propagation du mécanisme de défaillance à la maintenance prévisionnelle

L'algorithme est utilisé pour estimer l'état du système pour différents moments discrets de prédiction  $k_p$  et pour propager les mécanismes de défaillance détectés actifs jusqu'à ce qu'aux états physiques ciblés pour la maintenance prévisionnelle  $v^{e_{target}}$  et leurs modes de défaillance résultants  $v^{F_b}$ . La maintenance prévisionnelle a pour objectif de prédire et de suggérer des actions de maintenance basées sur des algorithmes de pronostic. Une action de maintenance est considérée comme ayant un effet positif sur le système. Du point de vue d'un PN, on peut considérer qu'une fois que les états physiques ciblés sont atteints, des actions de maintenance qui leurs sont associées auront un effet positif sur le système. Ainsi, les actions de maintenance peuvent être attribuées aux états physiques ciblés du PN et sont alors notées  $v_{M_n}^{e_{target}}$ . Les experts ont les connaissances nécessaires pour suggérer les effets attendus possibles de ces actions de maintenance. Par exemple, ces actions préventives pourraient permettre de:

- Inhiber la propagation du mécanisme de défaillance associé;
- Réinitialiser la propagation du mécanisme de défaillance associé;
- Ralentir la propagation du mécanisme de défaillance associé.

La prédiction de l'applicabilité des tâches de maintenance prévisionnelle permettra à l'organisation de planifier le travail à venir. Cependant, la planification de la maintenance est généralement confrontée à de nombreux problèmes opérationnels et organisationnels. Pour une organisation, il est plus facile de disposer d'un intervalle d'applicabilité pour chaque tâche de maintenance afin de planifier plus facilement différentes tâches en fonction des contraintes opérationnelles et organisationnelles.

Dans l'industrie nucléaire, le concept d'intervalle d'application de la maintenance (ou tolérance admissible de l'intervalle de maintenance) a déjà été discuté. Un rapport EPRI (EPRI, 2002) a défini une plage de temps en termes d'intervalle d'inspection pour une tâche de maintenance spécifique. Ce délai est défini entre deux limites appliquées à l'intervalle d'inspection ( $T_o$ ):

0.9 To et 1.125 To. Dans cet article, nous avons choisi d'appliquer ces facteurs au temps nécessaire pour atteindre les états cibles  $v_{TTE}^{e_{target}}(k_p)$ . Ce temps est défini dans l'équation (4.3) comme étant la différence entre la date d'occurrence prédite de l'état cible  $v_{k_E}^{e_{target}}(k_p)$  et la date de prédiction  $k_p$ . Pour définir la date d'occurrence  $v_{k_E}^{e_{target}}(k_p)$ , le rang centile  $q_{75\%}$  de la prédiction de l'occurrence de l'état physique ciblé  $v_{CDF}^{e_{target}}(k_p)$  est utilisé.

$$v_{TTE}^{e_{target}}(k_p) = v_{k_E}^{e_{target}}(k_p) - k_p \quad (4.3)$$

L'équation (4.4) présente l'intervalle d'applicabilité  $K_E$  d'une tâche de maintenance spécifique  $M_n$  attribué à un état ciblé  $e_{target}$  pour une date de prédiction  $k_p$ .

$$v_{M_n[K_E]}^{e_{target}}(k_p) = [0.9 v_{TTE}^{e_{target}}(k_p); 1.125 v_{TTE}^{e_{target}}(k_p)] \quad (4.4)$$

Cependant, une action de maintenance doit être effectuée avant qu'un mode de défaillance ne soit atteint. L'algorithme de propagation 5.3.2 est utilisé pour informer les décideurs de l'occurrence de modes de défaillance potentiels. Si le rang de centiles  $q_{25\%}$  d'une occurrence d'un mode de défaillance résultant est inférieur à la limite supérieure de l'intervalle d'applicabilité, l'intervalle d'applicabilité sera remplacé par le rang  $q_{25\%}$  du mode de défaillance associé.

En conséquence, la Figure 4.3 illustre un exemple de maintenance prévisionnelle  $M_n$  associée à l'état ciblé  $v^{e_{14}}$ . Le temps prédit pour atteindre  $v^{e_{14}}$  à la date de prédiction 2016 est de 17 ans. L'intervalle d'applicabilité suggéré pour la tâche de maintenance est compris entre 2031 et 2035. La lubrification du palier d'arbre peut être effectuée à partir 2031 pour obtenir un effet positif de l'action de maintenance. Cependant, elle doit être réalisée avant 2035 afin d'être sûr d'atténuer le risque de défaillance de l'équipement.

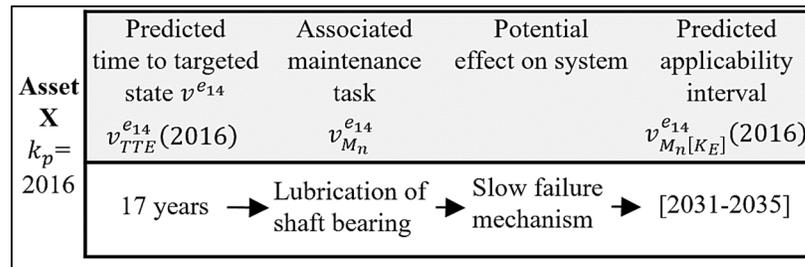


Figure 4.3 Illustration de l'algorithme de propagation des mécanismes de défaillance

## 4.6 Étude de cas : Stator d'alternateur hydro-électrique

### 4.6.1 Tâches de maintenances associées aux états ciblés

Dans cette étude de cas, une brève analyse des données disponibles a été réalisée pour identifier les états physiques ciblés auxquels des actions de maintenance possibles sont associées. Quatre états physiques ont été ciblés et sont présentés dans le Tableau 4.1.

Tableau 4.1 États physiques ciblés pour la maintenance prévisionnelle  $v^{e_{target}}$

ID	États physiques
$v^{t_6}$	Vieillessement thermique de la paroi de l'isolation de mise à la terre
$v^{m_{31}}$	Usure d'isolation stator par stratification
$v^{m_{21}}$	Érosion mécanique de paroi de l'isolant de mise à la terre dans le noyau du stator
$v^{e_{12}}$	Érosion du revêtement semi-conducteur

Basées sur les connaissances des experts, des tâches de maintenance ont été associées aux états physiques cibles et leurs effets potentiels sur le système ont été estimés. Les résultats sont présentés au Tableau 4.2.

Tableau 4.2 Tâches de maintenance associée aux états ciblés  $v_{M_n}^{e_{target}}$  et leur potentiel effet sur le système

ID	Tâches de maintenance associée $v_{M_n}^{e_{target}}$	Effet potentiel sur le système
$v^{t_6}$	Rembobinage du stator (remplacement)	Réinitialiser les mécanismes de défaillance au niveau des enroulements stator
$v^{m_{31}}$	Injection d'époxy dans les laminés du stator	Ralentir les mécanismes de défaillance associés
$v^{m_{21}}$	Remplacement de quelques barres stator	Réinitialiser les mécanismes de défaillance locaux (prolonger la durée de vie moyenne de tout l'enroulement)
	Rembobinage du stator (remplacement)	Réinitialiser les mécanismes de défaillance au niveau des enroulements stator
$v^{e_{12}}$	Peinture de l'isolant semi-conducteur du stator	Arrêter les mécanismes de défaillance associés pour une certaine période

#### 4.6.2 Application du modèle de pronostic

Dans cette étude de cas, un stator d'alternateur (appelé alternateur A) pour lequel plusieurs mesures et données d'inspection étaient disponibles est utilisé pour illustrer la méthodologie. Le Tableau 4.3 présente la liste des données de diagnostic historiques et des actions de maintenance effectuées sur le stator de l'alternateur A.

Cinq dates de prédiction  $k_p$  ont été choisies: une pour chaque année entre 2010 et 2015. La date de prédiction 2012 est décrite en détail dans l'étude de cas. L'occurrence des états physiques cibles ainsi que la période pendant laquelle les tâches de maintenance associées seront applicables sont présentées ci-dessous.

Tableau 4.3 Historique des mesures, inspections et actions de maintenance du stator de l'alternateur A

Date	Diagnostics/Intervention
1932-09	Mise en service
1989-01	Rembobinage avec modernisation & remplacement du noyau stator
1992-01	Analyse de décharges partielles (PDA)
2008-01	Test DC Ramp (DCRT)
2009-06	Analyse de décharges partielles (PDA)
2010-05	Test de Polarisation/Dépolarisation du courant (PDC)
2010-05	Test DC Ramp (DCRT)
2010-05	Évaluation de revêtement semi-conducteur
2010-05	Inspection visuelle
2011-04	Décharges partielles avec résolution de phase (PRPD)
...	
2014-02	Décharges partielles avec résolution de phase (PRPD)
2014-04	Test de détection d'ozone
2015-10	Analyse de décharges partielles (PDA)
2016-03	Test de Polarisation/Dépolarisation du courant (PDC)
2016-06	Évaluation de revêtement semi-conducteur
2016-07	Test DC Ramp (DCRT)

- Estimation d'état en 2012

Sur la base des données de diagnostic existantes en 2012, les états physiques actifs détectés et leurs intervalles d'activation  $K_E$  sont présentés dans la Tableau 4.4 ci-dessous.

Tableau 4.4 États physiques actifs en 2012 sur le stator de l'alternateur A et leurs intervalles d'activation  $K_E$

Alternateur A ( $k_p = 2012$ )		
ID	Appellation des états physiques actifs	Intervalles d'activation $v_{\varepsilon_{K_E}}^{ei}$ (2012)
$v^{a_1}$	Contamination conductrice aux extrémités des bobines	[1996; 2010]
$v^{a_3}$	Présence de poussière	[2002; 2010]
$v^{e_{21}}$	Point chaud dans le noyau lié au courant de Foucault	[2002; 2010]
$v^{t_2}$	Dégradation thermique de l'isolant	[2006; 2010]
$v^{m_{34}}$	Flambage du noyau stator	[2009; 2010]

Pour les intervalles d'activation  $K_E$ , la limite supérieure correspond à la date de détection  $k_E$  et la limite inférieure à la dernière date à laquelle l'état physique a été détecté inactif. Sur la base de ces résultats, l'algorithme de détection du mécanisme de défaillance (Algorithme 4.4.2.a) et l'isolation de l'état du mécanisme de défaillance (Algorithme 4.4.2.b) ont été effectués. Les résultats sont illustrés à l'aide de la visualisation graphique du PN à la Figure 4.4.

En 2012, cinq états physiques ont été détectés comme actifs et 28 comme inactifs. Au total, 30 mécanismes de défaillance ont été détectés comme actifs. Sur la Figure 4.4, les états physiques ciblés  $v^{e_{target}}$  sont identifiés par une croix au milieu de leurs nœuds. Quatorze des mécanismes de défaillance actifs ont conduit à l'état cible  $v^{t_6}$ , six à l'état  $v^{m_{31}}$  et seulement 3 à l'état  $v^{e_{12}}$  en 2012.

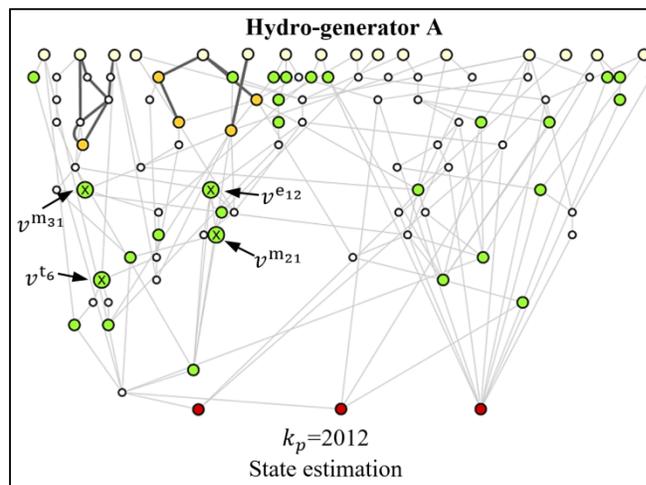


Figure 4.4 Estimation de l'état du stator de l'alternateur A en 2012

- Propagation des mécanismes de défaillance en 2012

Tous les mécanismes de défaillance actifs menant aux états physiques ciblés ont été propagés à l'aide de l'algorithme de propagation des mécanismes de défaillance (algorithme 5.3.1). Les temps de transition ont été estimés sur la base du processus d'élicitation tel que présenté dans

la section 3.4.2.2. La Figure 4.5 présente les résultats des propagations des mécanismes de défaillance et des probabilités d'occurrence pour les états physiques ciblés pour la maintenance prévisionnelle.

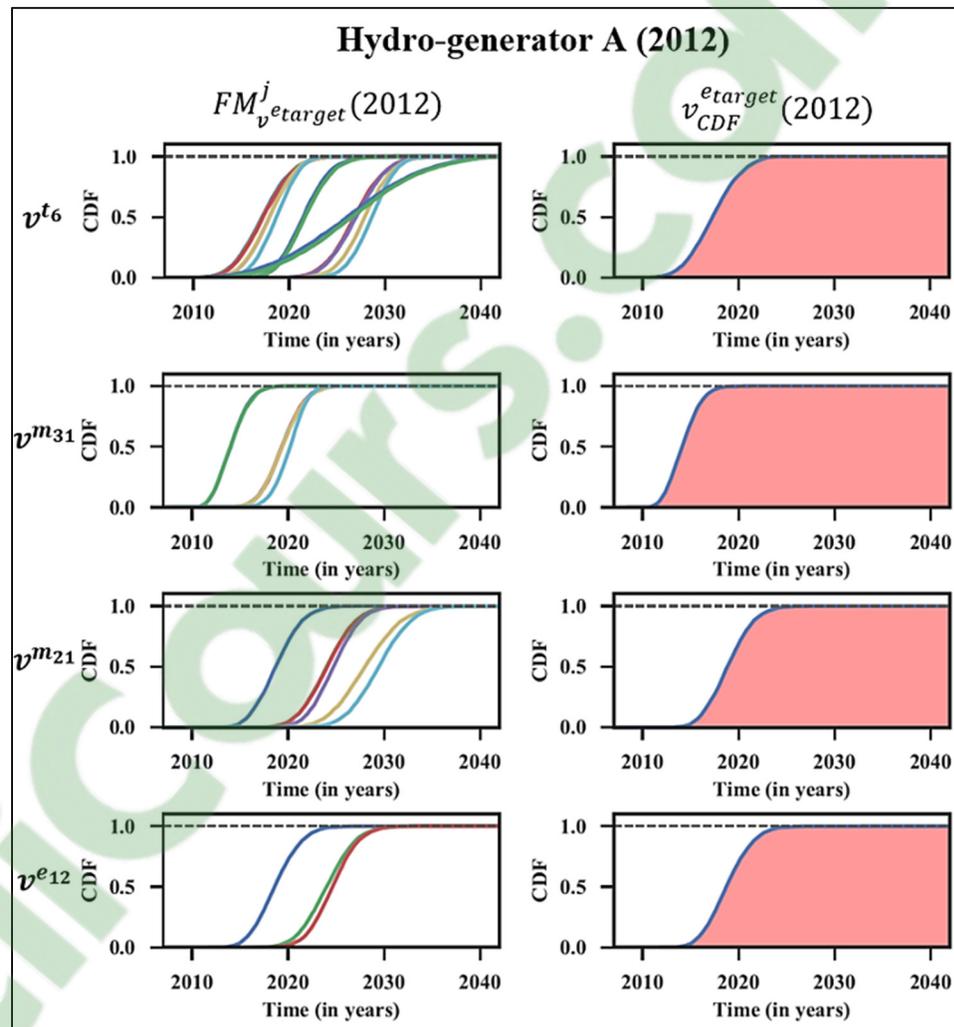


Figure 4.5 Propagation des mécanismes de défaillance menant aux états physiques ciblés pour la maintenance prévisionnelle en 2012

Les intervalles de confiance prédits à 50% pour chaque état physique ciblé sont présentés dans le Tableau 4.5.

Tableau 4.5 Intervalles de confiance des temps nécessaires pour atteindre le TTE ( $v_{TTE}^{e_{target}}(2012)$ ) pour chaque état physique ciblé en 2012

Hydro-generator A ( $k_p = 2012$ )			
ID	État physique	Intervalle d'occurrence prédit $v_{CDF}^{e_{target}}(2012)$	Temps restant prédits pour l'occurrence de l'état physique (années) $v_{TTE}^{e_{target}}(2012)$
$v^{t_6}$	Vieillessement thermique de la paroi de l'isolation de mise à la terre	[2015; 2019]	7
$v^{m_{31}}$	Usure d'isolation stator par stratification	[2012; 2015]	3
$v^{m_{21}}$	Érosion mécanique de paroi de l'isolant de mise à la terre dans le noyau du stator	[2017; 2020]	8
$v^{e_{12}}$	Érosion du revêtement semi-conducteur	[2017; 2020]	8

Le deuxième algorithme de propagation de défaillance (algorithme 5.3.2) a été appliqué pour prédire le temps avant défaillance (*TTF*) pour chaque mode de défaillance lié à chaque état physique ciblé pour la maintenance. Les résultats sont présentés à la Figure 4.6.

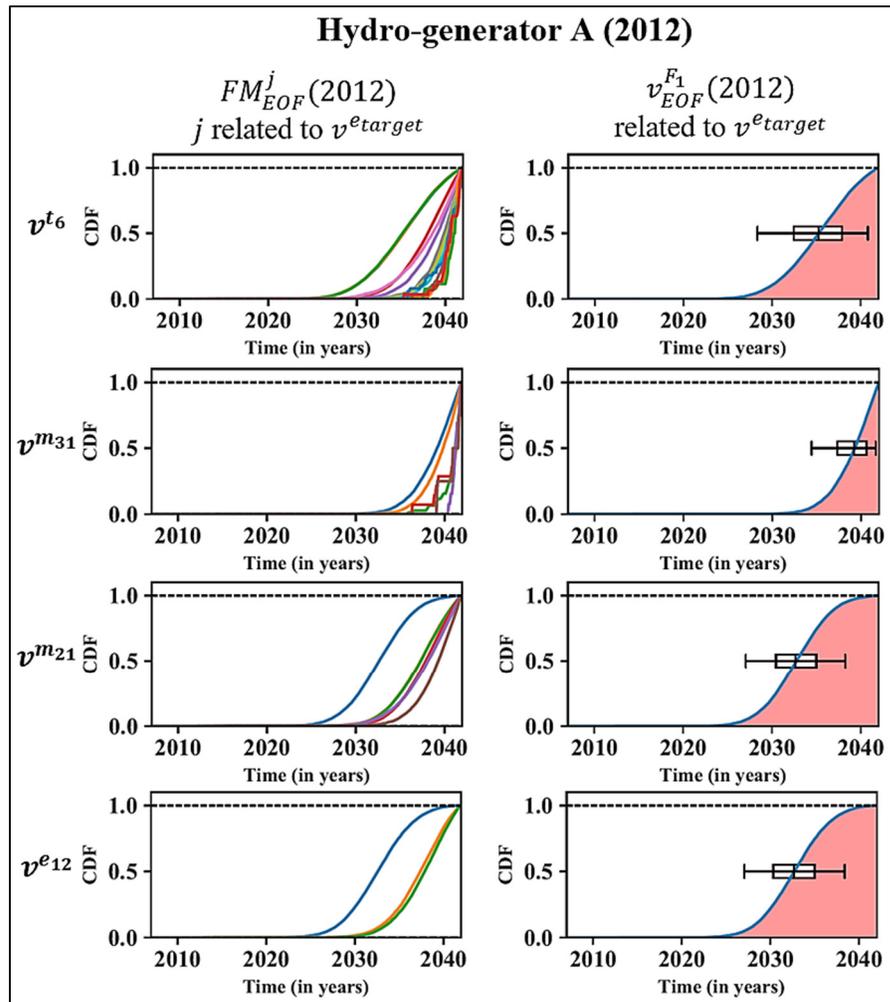


Figure 4.6 Prédiction de l'occurrence des modes de défaillances résultant des états physiques ciblés par la maintenance prévisionnelle en 2012

Dans tous les mécanismes de défaillance actifs, seul le mode de défaillance  $v^{F_1}$  se trouve dans les mécanismes de défaillance où les états physiques ciblés sont présents. Les prédictions des intervalles de confiance à 50% pour le mode de défaillance  $v^{F_1}$  sont présentées dans la Tableau 4.6.

Tableau 4.6 Prédictions des intervalles de confiance à 50% pour l'occurrence du mode de défaillance  $v^{F_1}$  pour l'année de prédiction 2012 :  $v_{TTF}^{F_1}(2012)$

Hydro-generator A ( $k_p = 2012$ )				
ID	État physique	Mode de défaillance résultant	Intervalle prédit pour l'occurrence du mode de défaillance $v_{EOF}^{F_1}(2012)$	Temps restant prédit jusqu'à la défaillance (années) $v_{TTF}^{F_1}(2012)$
$v^{t_6}$	Vieillessement thermique de la paroi de l'isolation de mise à la terre	$v^{F_1}$	[2032; 2037]	[20; 25]
$v^{m_{31}}$	Usure d'isolation stator par stratification	$v^{F_1}$	[2037; 2040]	[25; 28]
$v^{m_{21}}$	Érosion mécanique de paroi de l'isolant de mise à la terre dans le noyau du stator	$v^{F_1}$	[2030; 2035]	[18; 23]
$v^{e_{12}}$	Érosion du revêtement semi-conducteur	$v^{F_1}$	[2030; 2035]	[18; 23]

- Maintenance prévisionnelle suggérée en 2012

En se basant sur les prédictions de l'occurrence des états physiques ciblés pour la maintenance et de l'occurrence des modes de défaillance résultants, des tâches de maintenance  $v_{M_n}^{e_{target}}$  et leurs intervalles d'application  $K_E$  ont été proposés en 2012 (voir Tableau 4.7). Comme aucune défaillance n'est prévue dans l'intervalle de maintenance proposé, l'occurrence de défaillance n'a aucun impact sur les intervalles proposés.

Tableau 4.7 Tâches de maintenance prévisionnelle proposées en 2012 suite aux résultats de pronostic et dates d'application correspondantes

Intervalle d'application de la maintenance $v_{M_n[KE]}^{e_{target}}(2012)$	Intervalle d'occurrence prédit du mode de défaillance associé $v_{EOF}^{F_b}(2012)$	Tâches de maintenance suggérée $v_{M_n}^{e_{target}}$	Effet potentiel sur le système
[2015; 2015]	[2037; 2040]	Injection d'époxy dans les laminés du stator	Ralentir les mécanismes de défaillance associés
[2018; 2020]	[2032; 2037]	Rembobinage du stator (remplacement)	Réinitialiser les mécanismes de défaillance au niveau des enroulements stator
[2019; 2021]	[2030; 2035]	Remplacement de quelques barres stator	Réinitialiser les mécanismes de défaillance locaux (prolonger la durée de vie moyenne de tout l'enroulement)
		Rembobinage du stator (remplacement)	Réinitialiser les mécanismes de défaillance au niveau des enroulements stator
[2019; 2021]	[2030; 2035]	Peinture de l'isolant semi-conducteur du stator	Arrêter les mécanismes de défaillance associés pour une certaine période

#### 4.6.3 Validation des algorithmes de pronostic pour la maintenance prévisionnelle

Afin de valider les algorithmes de pronostic, les dates d'activation des états physiques ciblés pour la maintenance ont été identifiées à partir des données historiques de diagnostic. Les états de détection historiques des états physiques ciblés résultant de l'analyse des symptômes pour chaque date de mesure sont présentés dans le Tableau 4.8. Le symbole 0 signifie que les états ciblés ont été détectés comme étant inactifs à cette date. Le symbole 1 signifie qu'ils ont été

détectés comme actifs et x signifie que les données de mesure ou d'inspection à cette date ne permettent pas de détecter l'état physique, qui peut donc être considéré comme inconnu. Par exemple, en 2016-03, le test du courant de polarisation / dépolarisation (PDC) a détecté  $v^{m_{21}}$  comme actif, mais n'était pas capable de détecter l'état  $v^{t_6}$ ,  $v^{e_{12}}$  et  $v^{m_{21}}$ .

Tableau 4.8 . Historique des états de détection des états physiques ciblés  $v_{\varepsilon}^{e_i}(k_p)$  pour le stator de l'alternateur A

Date des mesures ou inspections ( $k_p$ )	$v_{\varepsilon}^{t_6}(k_p)$	$v_{\varepsilon}^{m_{31}}(k_p)$	$v_{\varepsilon}^{e_{12}}(k_p)$	$v_{\varepsilon}^{m_{21}}(k_p)$
2010-05	0	×	×	×
2010-05	×	0	0	0
2010-05	×	0	0	0
2011-04	×	×	×	×
...	...	...	...	...
2014-02	×	×	×	×
2014-02	×	×	×	×
2014-04	×	×	×	×
2015-10	×	×	×	×
2016-03	×	×	×	×
2016-03	×	1	×	×
2016-06	×	x	1	1
2016-07	1	×	×	×

En se basant sur ces résultats, l'intervalle d'activation observé  $K_E$  de chaque état physique ciblé est présenté dans le Tableau 4.9. Tous les états physiques cibles ont été détectés comme actifs en 2016 et la dernière date à laquelle ils ont tous été détectés comme inactifs était en 2010.

La Figure 4.7 présente la validation de l'algorithme de pronostic pour les dates de prédiction  $k_p$  de 2010 à 2015. Les résultats montrent l'évolution de chaque prédiction temporelle. Lorsque de nouvelles données de diagnostic deviennent disponibles, l'algorithme met à jour les prédictions en calculant à nouveau les algorithmes de diagnostic et de pronostic.

Tableau 4.9 . Intervalles de détection observés  $K_E$  des états ciblés estimés à partir de données historiques

ID	État physique	Intervalle d'activation observé $v_{\varepsilon_{KE}}^{e_i}$ (2018)
$v^{t_6}$	Vieillesse thermique de la paroi de l'isolation de mise à la terre	[2010; 2016]
$v^{m_{31}}$	Usure d'isolation stator par stratification	[2010; 2016]
$v^{m_{21}}$	Érosion mécanique de paroi de l'isolant de mise à la terre dans le noyau du stator	[2010; 2016]
$v^{e_{12}}$	Érosion du revêtement semi-conducteur	[2010; 2016]

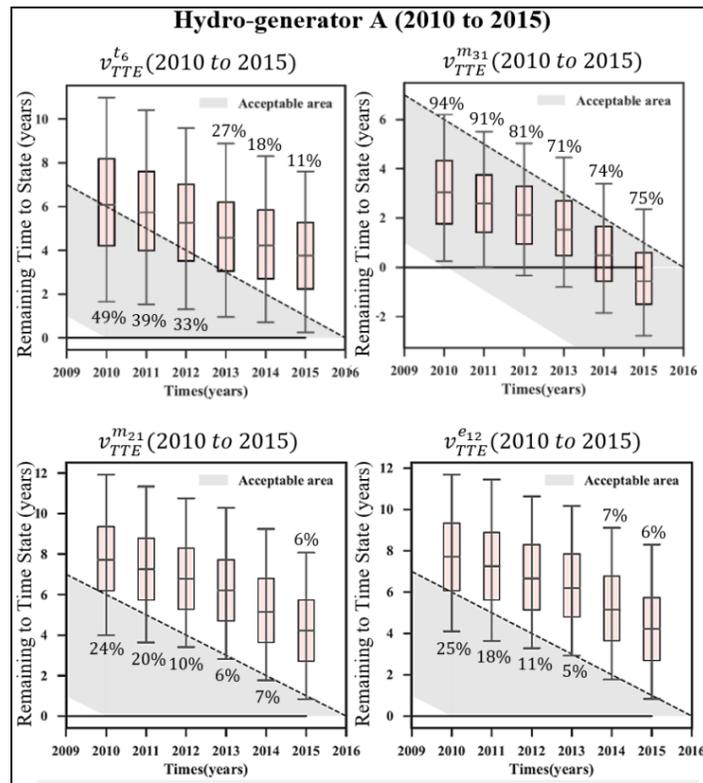


Figure 4.7 Intervalles d'activation observés (Boxplot) par rapport aux intervalles d'activation prévus pour les états ciblés. Les lignes en pointillés illustrent la date de détection observée et la zone grise l'intervalle d'activation possible observé. Les pourcentages représentent le rapport entre la masse de probabilité de la prévision qui reste dans la zone acceptable.

Les résultats montrent que toutes les prédictions restent dans les intervalles d'activation observés pour un intervalle de confiance de 90%. Plus de 70% des réalisations de la distribution des prédictions sont restées dans la zone acceptable de 2010 à 2015 pour l'état physique  $v^{m_{31}}$  et plus de 25% pour l'état  $v^{t_6}$  avant 2013. D'un point de vue général, les prévisions se rapprochent des dates de détection de 2010 à 2012. L'intervalle d'incertitude des prévisions va d'environ 9 ans à 6 ans pour un intervalle de confiance de 80% (2 à 4 ans pour un intervalle de confiance de 50%).

Cette étude a été réalisée en 2018. Le groupe alternatif est toujours en fonctionnement et aucun mode de défaillance n'a été atteint jusqu'à présent. De plus, aucune action de maintenance n'a été effectuée depuis 2010. Jusqu'à présent, le pronostic des modes de défaillance liés aux états physiques ciblés pour la maintenance prévisionnelle correspond aux dernières observations disponibles.

#### 4.7 Discussion

Du point de vue de la maintenance prévisionnelle, les résultats semblent cohérents avec le comportement observé de l'alternateur A de 2017 à 2018. En effet, le modèle suggère en 2012 qu'une opération de maintenance mineure était prévue en 2015 et que des actions de maintenance majeures sont attendues en 2019. À ce jour, le groupe alternatif n'a pas rencontré de panne. De plus, selon l'historique des actions de maintenance, aucun entretien majeur n'a été effectué depuis 2010. Avec le modèle proposé, les décideurs peuvent passer d'un large éventail d'actions de maintenance possibles à une sélection d'actions de maintenance spécifiques pouvant avoir un effet positif sur le système. Par exemple, le modèle aurait pu prolonger la durée de vie de l'équipement en suggérant une injection d'époxy dans les tôles du stator en 2015. Dans ce cas, lorsqu'une action de maintenance suggérée est effectuée, l'état du système en sera affecté et les actions de maintenance suggérées pour la suite pourraient devenir inadéquates. Des études ultérieures pourraient être envisagées pour estimer plus précisément

l'impact des actions de maintenance sur le système, afin de suggérer d'autres scénarios de maintenance.

Le modèle proposé est capable de calculer un intervalle d'applicabilité pour une action de maintenance spécifique en tenant compte des résultats de pronostic des éventuelles défaillances qui pourraient y être associées. Il permet à l'organisation de prioriser et de planifier efficacement les opérations de maintenance tout en prenant conscience du risque de défaillance. La priorisation nécessite plusieurs années pour permettre un ajustement, mais une organisation doit être capable de planifier une action de maintenance prioritaire dans un délai d'un an. Sinon, cela sera considéré comme inefficace.

En ce qui concerne les résultats de l'algorithme de pronostic, l'étendue des plages d'incertitude provient de deux facteurs: l'estimation de l'état du système (intervalles d'activation des états physiques) et la propagation des mécanismes de défaillance (plage d'incertitude des temps de transition). Premièrement, étant donné que les intervalles d'inspection pour les différents outils de diagnostic sont importants et qu'ils sont effectués une fois par an voir quelquefois sur plusieurs années, les intervalles d'activation potentiels pour les états physiques sont assez grands. Cela crée une incertitude considérable concernant l'estimation de l'état du système. Par exemple, dans le Tableau 4.4, basé sur les données de 2012, l'état physique  $v^{e21}$  a un intervalle d'activation potentiel de 8 ans, ce qui est assez important.

Ensuite, comme les temps de transition ont été estimés sur la base d'un processus d'élicitation, divers biais tels que la confiance excessive peuvent avoir induit des temps de transition qui ne représentent pas complètement les réalités du parc de production.

#### **4.8 Conclusions**

Ce chapitre présente une approche de maintenance prévisionnelle pour les équipements complexes. L'approche se base les mêmes algorithmes de diagnostic et les mêmes hypothèses

régissant le développement du modèle de pronostic que ceux présentés dans le CHAPITRE 3. Afin de pouvoir permettre la maintenance prévisionnelle sur la base des résultats de l'algorithme de pronostic, des algorithmes de pronostic personnalisés ont été définis pour propager les mécanismes de défaillance détectés actifs de leurs états initiaux à certains états physiques de dégradation ciblés auxquels des tâches de maintenance sont associées. Une fois que les états physiques cibles sont prédits, un intervalle d'application des tâches de maintenance peut être prédit pour ces états physiques. Un deuxième algorithme de propagation est utilisé pour propager les mécanismes de défaillance jusqu'aux modes de défaillance. Cela permet de prendre en compte le risque de défaillance dans la planification. Les résultats montrent que le modèle permet de prédire des actions de maintenance spécifiques en fonction de mécanismes de défaillance détectés actifs par les outils de diagnostic. Le modèle permet alors de prédire une période pendant laquelle les actions de maintenance peuvent être applicables, dans la mesure où elles commenceront à affecter le système. On constate également que le modèle de pronostic s'adapte rapidement à de nouvelles données de diagnostic. De plus, le modèle prend en compte les incertitudes contenues à la fois dans l'estimation d'état et dans la propagation des mécanismes. Certaines perspectives de recherche ont été identifiées, telles que l'estimation de l'effet de la maintenance sur les résultats de pronostic ou l'évaluation des performances du pronostic d'équipements réparables.

## CHAPITRE 5

### ÉVALUATION DE LA PERFORMANCE DES ALGORITHMES DE PRONOSTIC POUR LES ÉQUIPEMENTS RÉPARABLES DANS UN CONTEXTE INDUSTRIEL

Comme mentionné dans la section 1.6, l'évaluation de la performance des algorithmes de pronostic permet d'orienter le développement et de s'assurer du respect des spécifications exigées par les utilisateurs. Par définition, les systèmes réparables peuvent subir différentes défaillances lors de leur vie utile. Les algorithmes de pronostic doivent être capables de suivre en tout temps l'occurrence de la prochaine défaillance lors de ses périodes de fonctionnement, on parle donc, d'un critère d'adaptabilité ou une capacité à tenir en compte l'évolution de l'information disponible sur l'état de l'équipement. Au niveau d'une population d'équipements réparables, les algorithmes de pronostic doivent permettre une optimisation des stratégies d'opération et de maintenance dans un contexte opérationnel évolutif et prédéfini pour éviter une perte non planifiée de la fonction de l'équipement.

Dans ce chapitre, un cadre d'évaluation original est proposé pour mesurer les performances des algorithmes de pronostic pour les équipements réparables. Dans un premier temps les hypothèses retenues sont énoncées, puis les éléments constitutifs du cadre d'évaluation sont décrits pour un suivi historique des performances en se basant sur les défaillances passées (*off-line*) et sur les performances en temps réel sans connaissance *a priori* des défaillances à venir (*on-line*). Finalement, une étude de cas sur la méthode de pronostic proposée dans le CHAPITRE 3 est déclinée dans le contexte opérationnel des alternateurs hydro-électriques.

#### 5.1 Hypothèses sous-jacentes pour l'évaluation des performances des algorithmes de pronostic pour les systèmes réparables

Pour permettre l'application du cadre d'évaluation proposé, les hypothèses suivantes sont utilisées :

- H1 : Les dates des défaillances historiques sont connues [ $EOF_1, \dots, EOF_n$ ];

- H2 : Les périodes de fonctionnement des équipements sont régies par un ou plusieurs processus de planification opérationnelle (maintenance, retrait, ordonnancement, etc.)  $[PPO_1, \dots, PPO_l]$ ;
- H3 : L'horizon des processus de planification  $PPO_l^H$  et leurs fréquences d'actualisation ou de révisions sont connues  $PPO_l^f$ ;
- H4 : Les algorithmes de pronostic visent à prédire le temps avant l'occurrence de la prochaine défaillance  $TTF$  pour un temps de prédiction  $t_p$ .
- H5 : La planification opérationnelle optimale vise à assurer la disponibilité et la fiabilité des équipements lors de leur période de fonctionnement.

## 5.2 Performance *off-line* des algorithmes de pronostic pour les systèmes réparables

### 5.2.1 Définition de la fonction TTF pour les systèmes réparables

La première étape consiste à définir la fonction de vérité (*Ground Truth*) représentant l'événement, ou les événements d'intérêt, pour l'évaluation des performances des algorithmes de pronostic. Dans le cas d'un système non réparable, l'événement de défaillance ou de perte de fonction  $EOF$  représente aussi la fin de la vie utile de l'équipement aussi notée  $RUL$  (voir section 1.6.2.3). Les algorithmes de pronostic ont alors pour objectifs de prédire cet unique événement tout au long de la vie utile de l'équipement.

Dans le cas des systèmes réparables, la défaillance n'est pas létale pour l'équipement s'il est réparable. Des actions de maintenance sont donc nécessaires pour remettre l'équipement dans un état fonctionnel. La *vie utile* d'un système réparable est par conséquent composée de différentes périodes de fonctionnement qui peuvent connaître différentes défaillances. La fin de vie utile de l'équipement est alors principalement liée à une décision économique ou à l'occurrence d'une défaillance non réparable ou létale.

La Figure 5.1 illustre l'application du cadre d'évaluation défini pour les systèmes non réparables à un équipement réparable pour illustrer les limitations des approches existantes.

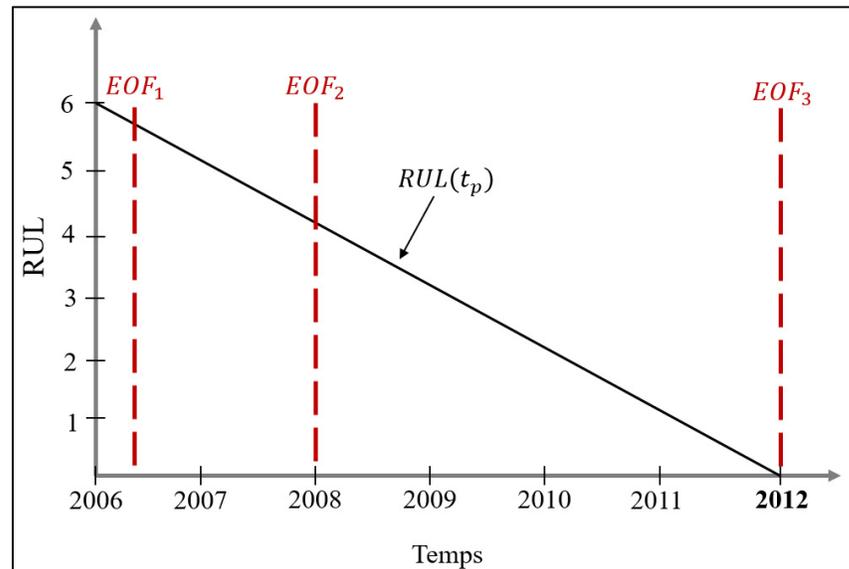


Figure 5.1 Illustration de la fonction de vérité (*Ground Truth*)  $RUL$  appliquée à un système réparable comportant 3 défaillances  $EOF_1$ ,  $EOF_2$  et  $EOF_3$ .

La fonction de vérité (*Ground Truth*)  $RUL$  telle que définie dans la section 1.6.2.3 est continue et strictement monotone. Elle permet de représenter l'occurrence d'un seul événement. Dans le cas d'un système réparable tel que proposé dans la Figure 5.1, le cadre d'évaluation permet d'analyser la capacité des algorithmes de pronostics à prédire une seule défaillance dans la vie utile de l'équipement (dans ce cas présent, la dernière défaillance  $EOF_3$ ).

Pour définir un cadre d'évaluation des systèmes réparables, il est proposé de décomposer la fonction  $RUL(t)$  en représentant les événements d'intérêts à chaque temps de prédiction  $t_p$ . On appelle la fonction  $TTF$ , la fonction qui représente le temps restant avant la prochaine défaillance pour un temps de prédiction  $t_p$ . Cette fonction est composée et non-continue. Elle représente la fonction  $RUL(t)$  des temps avant défaillance pour les différentes périodes de fonctionnement du système. Chaque période de fonctionnement est délimitée par une

défaillance du système  $EOF_n$ . L'équation (5.1) présente la fonction de vérité (*Ground Truth*)  $TTF$  pour les systèmes réparables.

$$TTF(t_p) = \begin{cases} EOF_1 - t_p, & t_p < EOF_1 \\ EOF_{...} - t_p, & EOF_1 \leq t_p < EOF_{...} \\ EOF_n - t_p, & EOF_{...} \leq t_p < EOF_n \end{cases} \quad (5.1)$$

La Figure 5.2 présente la fonction  $TTF(t_p)$  appliquée à un équipement ayant vécu 3 défaillances dans sa vie utile.

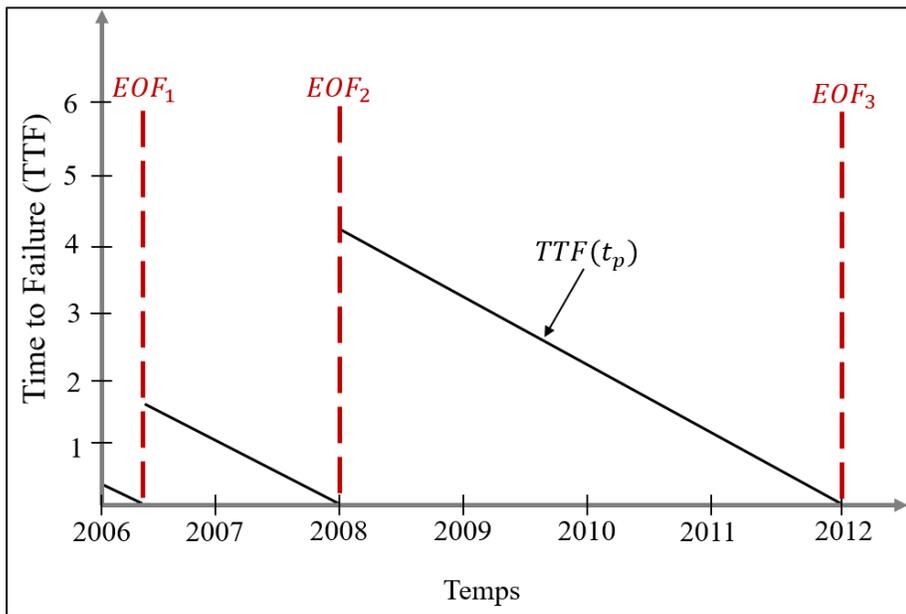


Figure 5.2 Illustration de la fonction de vérité (*Ground Truth*) TTF proposée et appliquée à un système réparable comportant 3 défaillances  $EOF_1$ ,  $EOF_2$  et  $EOF_3$ .

### 5.2.2 Définition de la zone de prédiction acceptable selon le contexte opérationnel

La deuxième étape a pour but de proposer une définition de la zone acceptable de prédiction pour chaque temps de prédiction  $t_p$ . Cette zone doit être étroitement liée aux décisions post-

pronostic permettant de planifier des actions de mitigation possibles pour empêcher l'événement de défaillance prédit d'avoir lieu. Les niveaux de planification peuvent être à différentes échelles de temps selon les processus de planification opérationnelle (PPO) en place (automatisme de reconfiguration de système, plan d'ordonnancement, maintenance préventive ou encore plan de retrait). En se basant sur les travaux présentés dans la section 1.6.2.3, on peut définir plus précisément cette zone acceptable pour qu'elle représente plus fidèlement le contexte opérationnel du système réparable d'étude.

Le temps nécessaire pour planifier raisonnablement une action de mitigation  $\lambda$  permet de définir le temps avant défaillance auquel l'algorithme de pronostic doit être capable de fournir des prédictions fiables jusqu'à la défaillance (horizon de l'algorithme de pronostic  $PH$ ). La limite de prédiction en avance  $\alpha^-$  vise à estimer l'acceptabilité des prédictions en avance. Une prédiction de défaillance en avance représente une perte d'opportunité d'utilisation du système. De même, la limite de prédiction en retard  $\alpha^+$  vise à estimer l'acceptabilité des prédictions en retard. Dans le cas d'équipement de production, cette borne est souvent nulle. On ne souhaite pas qu'un algorithme prédise une défaillance après que celle-ci arrive. Le niveau de confiance exigé  $\beta$  permet de définir le niveau de confiance auquel l'on souhaite que les prédictions restent dans les bornes acceptables  $\alpha^-$  et  $\alpha^+$ . En d'autres termes, l'étendue des réalisations des algorithmes de pronostic doit rester entre chacune des limites de prédiction demandée ( $\alpha^-$  et  $\alpha^+$ ) pour le niveau de confiance exigé  $\beta$  et pour chaque temps de prédiction  $t_p$  ( $\pi[t_p]_{\alpha^-}^{\alpha^+} \geq \beta$ ). Ces métriques sont présentées dans la Figure 5.3. C'est en analysant l'acceptabilité des prédictions des algorithmes de pronostic sur les différentes défaillances de l'équipement que l'on peut définir l'horizon des algorithmes de pronostic  $PH$ .

Au niveau du contexte opérationnel, un système réparable vise à assurer sa fonction tout au long des périodes de fonctionnement qui lui sont imposées (critère de disponibilité). Les périodes de fonctionnement sont définies par des processus de planification opérationnelle (PPO) qui ont pour objectif de s'assurer que l'équipement assure ses fonctions pour les périodes demandées. Les périodes de fonctionnement d'un système réparable peuvent être

régies par différents processus de planification opérationnelle. Par exemple, les processus de planification de production qui assurent l'ordonnement et la planification des périodes d'opérations des équipements afin de s'assurer de répondre à la demande et aux objectifs d'affaires de l'organisation. Les processus de planification des maintenances préventives (systématique, conditionnelle et prévisionnelle) ont pour objectif d'intercepter et d'arrêter la propagation des mécanismes de défaillance en planifiant des actions de mitigation qui permettent qu'aucune perte de fonction non planifiée ne survienne. Il en est de même avec les processus de planification des retraits ou des remplacements. Typiquement, les processus PPO comportent un horizon sur lesquels les planifications sont faites  $PPO_t^H$  et une fréquence de révision à laquelle les planifications sont actualisées  $PPO_t^f$  en tenant en compte des informations disponibles.

Pour qu'un algorithme de pronostic puisse être bénéfique à un processus de planification opérationnelle, il doit être capable d'assurer des prédictions de défaillance fiables dans la période d'horizon de la planification  $PPO_t^H$  avec un niveau de confiance exigé  $\beta$ .  $PPO_t^H$  représente alors le temps nécessaire pour planifier une action de mitigation  $\lambda$ . En d'autres termes, l'horizon de l'algorithme de pronostic  $PH$  doit être supérieur ou égal à l'horizon de planification du PPO ( $PPO_t^H$ ) (équation (5.2)).

$$\lambda = EOF - PPO_t^H \quad (5.2)$$

De plus, pour ne pas altérer la planification et occasionner des pertes d'opportunités de fonctionnement, l'algorithme ne doit pas prédire de défaillances hâtives entre la date de planification et la prochaine date d'actualisation de la planification. Il est alors possible de définir une zone acceptable de prédiction pour chaque PPO en vigueur pour un système réparable en fonction de son horizon de planification  $PPO_t^H$  et de sa fréquence de révision  $PPO_t^f$ . La Figure 5.3 illustre la zone acceptable de prédiction ( $\alpha^-$  et  $\alpha^+$ ) proposée pour un

PPO ayant un horizon de planification de 3 ans ( $PPO_t^H = 3 \text{ ans}$ ) et une fréquence d'actualisation de 1 an ( $PPO_t^f = 1 \text{ an}$ ).

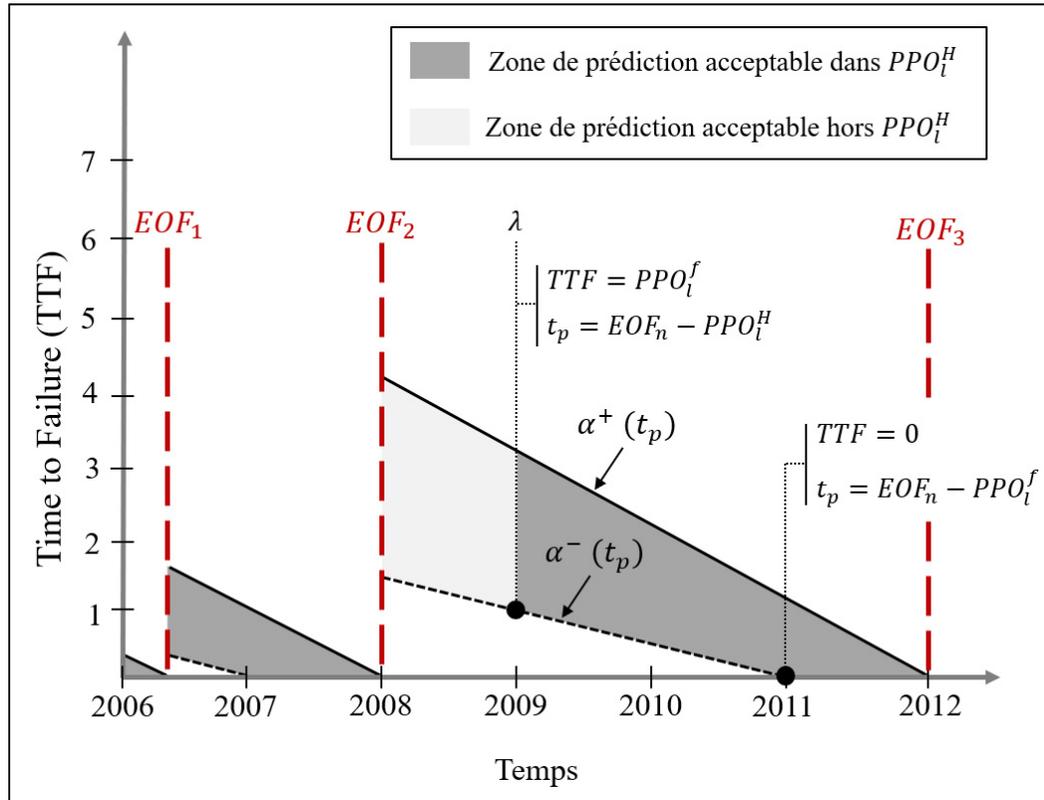


Figure 5.3 Illustration de la zone de prédiction acceptable pour un PPO ayant un horizon de planification de 3 ans et une fréquence d'actualisation de 1 an

La zone acceptable proposée dans la Figure 5.3 définit la limite de prédiction en retard  $\alpha^+$  comme égale à la fonction  $TTF(t_p)$ . On ne souhaite pas qu'un algorithme de pronostic prédise une défaillance en retard. Cela impliquerait une planification erronée et occasionnerait un risque de défaillance. L'équation (5.3) illustre la fonction de la limite de prédiction en retard pour un temps de prédiction  $\alpha^+(t_p)$ .

$$\alpha^+(t_p) = TTF(t_p) \quad (5.3)$$

Pour définir la limite de prédiction en avance  $\alpha^-$ , il est proposé d'utiliser deux points d'intérêt. Dans un premier temps, on se place à un temps de prédiction  $\lambda$  représentant le temps nécessaire pour planifier une action de mitigation. Comme définit dans l'équation (5.2) ce temps de planification représente l'horizon d'un PPO avant défaillance ( $EOF - PPO_l^H$ ). Dans l'exemple proposé à la Figure 5.3, en 2009 on souhaite planifier les actions de mitigation pour les 3 prochaines années afin d'éviter l'occurrence d'une défaillance dans cette période. Or, en 2010, une mise à jour de la planification sur 3 ans pourra être proposée aux vues des nouvelles informations disponibles. On peut alors en déduire qu'à l'année de planification 2009, on ne souhaite pas que l'algorithme de pronostic prédise des défaillances en avance dans l'année courante (2009) car cela induirait une planification d'une action de mitigation pour cette défaillance prédite trop en avance et ainsi une perte d'opportunité. Or, si une défaillance est prédite en avance entre les années 2010 à la date de défaillance réelle en 2012, les mises à jour de la planification permettront d'ajuster les actions requises et ainsi éviter les pertes d'opportunité. De même, pour le deuxième point d'intérêt, à la date de la dernière révision de la planification avant la défaillance réelle ( $EOF - PPO_l^f$ ) en 2011, même si la défaillance est prédite en avance dans cette période, elle n'impactera pas la planification dans le sens où elle ne nécessitera pas d'ajouter de nouvelles actions de mitigation. On peut donc dire qu'en tenant compte de ce cadre de validation pour un PPO, la perte d'opportunité sera, au maximum, égale à sa fréquence d'actualisation. L'équation (5.4) définit la limite de prédiction à l'avance pour chaque temps de prédiction  $\alpha^-(t_p)$  pour les variables  $A$  et  $B$  définies dans les équations (5.5) et (5.6).

$$\alpha^-(t_p) = \begin{cases} A \times TTF(t_p) + B, & t_p < (EOF_n - PPO_l^f) \\ 0, & t_p > (EOF_n - PPO_l^f) \end{cases} \quad (5.4)$$

$$A = \frac{PPO_l^f}{PPO_l^H - PPO_l^f} \quad (5.5)$$

$$B = \frac{EOF_n - PPO_l^f}{PPO_l^H - PPO_l^f} \quad (5.6)$$

### 5.3 Performance *on-line* des algorithmes de pronostic pour les systèmes réparables

Au niveau des performances dites *on-line* (ou en temps réel) des algorithmes de pronostic, le cas des systèmes réparables offre plus de possibilités que celui des systèmes non réparables. En effet, les systèmes réparables peuvent vivre plusieurs défaillances dans leur vie utile. Il est alors possible de connaître les performances des algorithmes spécifiquement pour le système à l'étude en analysant les capacités des algorithmes à prédire les défaillances passées. Dans cette partie, il est proposé d'analyser les performances en temps réel en se basant sur une analyse graphique simple des performances passées. La Figure 5.4 illustre les performances *on-line* d'un algorithme de pronostic par analyse graphique pour le même exemple de processus de planification (PPO) proposé dans la section précédente 5.2.

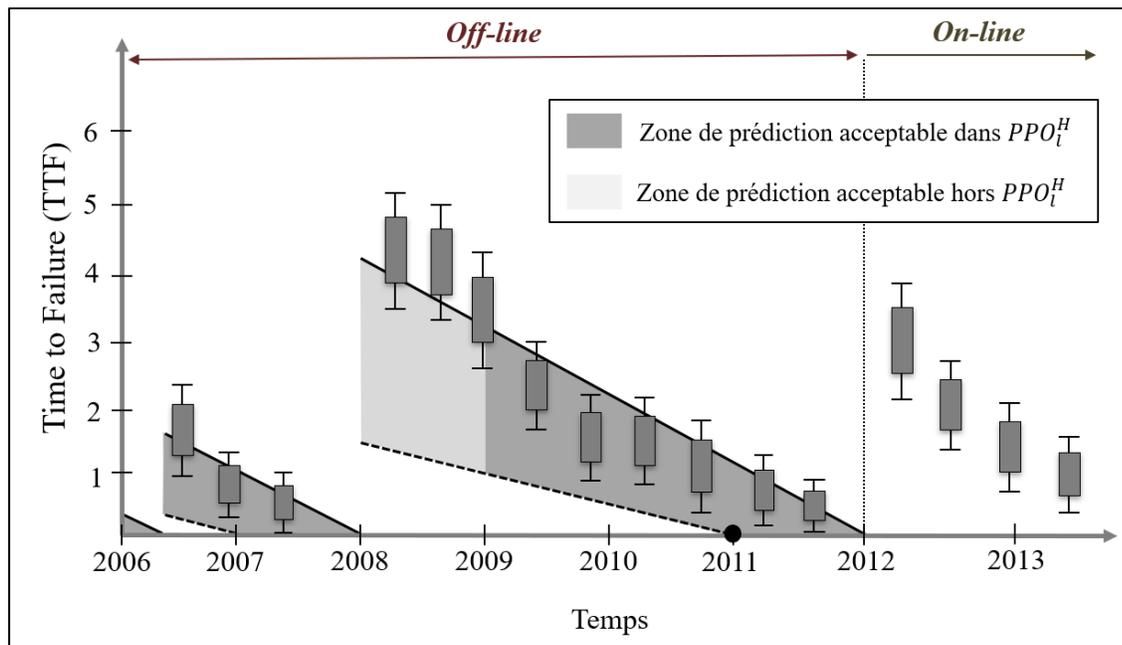


Figure 5.4 Illustration des performances *on-line* d'un algorithme de pronostic par analyse graphique pour un PPO

L'exemple proposé dans la Figure 5.4 permet de présenter visuellement, à la fois les performances des prédictions sur deux défaillances passées ayant eu lieu en 2008 et 2012 et les prédictions en cours pour la prochaine défaillance n'ayant pas encore eu lieu. Cette visualisation permet, par une simple analyse graphique, de définir un niveau de confiance dans les prédictions de défaillance pour le système d'étude. Dans le cas d'exemple proposé, l'analyse du comportement de l'algorithme permet de conforter les décideurs dans les prédictions futures de l'algorithme pour ce processus de planification (PPO). En effet, l'algorithme semble avoir réussi à prédire les défaillances passées dans les 3 ans représentant l'horizon de planification nécessaire avant la défaillance. Au vu des résultats passés, lors la mise à jour de la planification de 3 ans en 2013, les décideurs doivent s'assurer qu'une action de mitigation sera planifiée dans les deux prochaines années pour s'assurer qu'aucune défaillance ne survienne sur ce système.

## 5.4 Études de cas : pronostic de défaillance des alternateurs hydro-électriques

Dans ce chapitre, la même étude de cas des chapitres précédents est proposée : les alternateurs hydro-électriques. Pour cette étude de cas, le contexte opérationnel de l'organisation est utilisé pour définir le cadre de validation de l'algorithme de pronostic.

### 5.4.1 Définition du cadre de validation pour le contexte opérationnel des alternateurs hydro-électriques

Dans l'organisation d'étude, différents niveaux de PPOs sont mis en place pour assurer le bon fonctionnement des alternateurs. Les alternateurs hydrauliques sont des équipements de grande envergure qui comportent des mécanismes de dégradation et de défaillance relativement lents pour la plupart. Les processus de planification des retraits ou des maintenances préventives sont à l'échelle des mois ou des années. Le Tableau 5.1 présente une partie des processus de planification régissant l'utilisation des groupes turbine-alternateur dans l'organisation.

Tableau 5.1 Processus de planification opérationnelle des groupes turbine-alternateurs

Processus de planification opérationnel $PPO_l$	Horizon de planification $PPO_l^H$	Fréquence d'actualisation $PPO_l^f$
Plan de retrait aux 6 ans	6 ans	2 ans
Plan de production aux 2 ans	2 ans	6 mois (1/2 ans)
Plan de production aux mois	1 mois (1/12 ans)	10 jours (10/365 ans)
Plan aux 10 jours	10 jours (10/365 ans)	1 jour (1/365 ans)
Plan du lendemain (36h)	36 h (36/365/24 ans)	24 h (1/365 ans)

À la vue des étendues d'incertitude du modèle pronostic utilisé dans les chapitres précédents (CHAPITRE 3 et CHAPITRE 4), nous avons retenu d'étudier les performances de l'algorithme de pronostic pour des processus PPOs ayant un horizon  $\geq 1$  mois.

#### 5.4.2 Application du cadre de validation sur les résultats de pronostic des défaillances historiques

Considérant le nombre relativement faible de défaillances historiques vécues et les données diagnostics disponibles pour analyser le cadre de validation, un seul cas historique d'étude d'alternateur est proposé. Le stator d'alternateur  $D$  a connu 5 défaillances lors de sa vie utile entre l'année 2000 et 2013. La liste des défaillances est présentée dans le Tableau 5.2 ci-dessous.

Tableau 5.2 Liste des défaillances historiques du stator  $D$

Défaillances historiques	Dates de l'occurrence
$EOF_1$	Juillet 2000
$EOF_2$	Juillet 2001
$EOF_3$	Août 2003
$EOF_4$	Novembre 2010
$EOF_5$	Août 2013

Les cadres de validation pour les 3 processus de planification opérationnelle à long terme ont pu être définis en utilisant les dates de défaillance du stator  $D$  et les horizons  $PPO_t^H$  et les fréquences d'actualisation  $PPO_t^H$  des PPOs (Tableau 5.1). Les zones de prédiction acceptables des algorithmes de pronostic ont été définies pour chaque PPO en se basant sur les équations (5.2), (5.3) et (5.4). La zone de prédiction acceptable est composée de deux parties : les zones dans et hors de l'horizon de planification du processus  $PPO_t^H$ . Pour qu'un algorithme puisse supporter les décisions de planification d'un PPO, les prédictions doivent être fiables dans la période d'horizon de la planification  $PPO_t^H$  avec le niveau de confiance exigé.

L'algorithme de pronostic défini dans le CHAPITRE 3 a été appliqué sur les données de mesures et d'inspections disponibles pour le stator  $D$ . Les prédictions ont été effectuées sur

12 années de prédictions (de l'année 2000 à l'année 2013). L'évaluation des performances du pronostic dans le cadre d'un plan de retrait aux 6 ans est présentée dans la Figure 5.5.

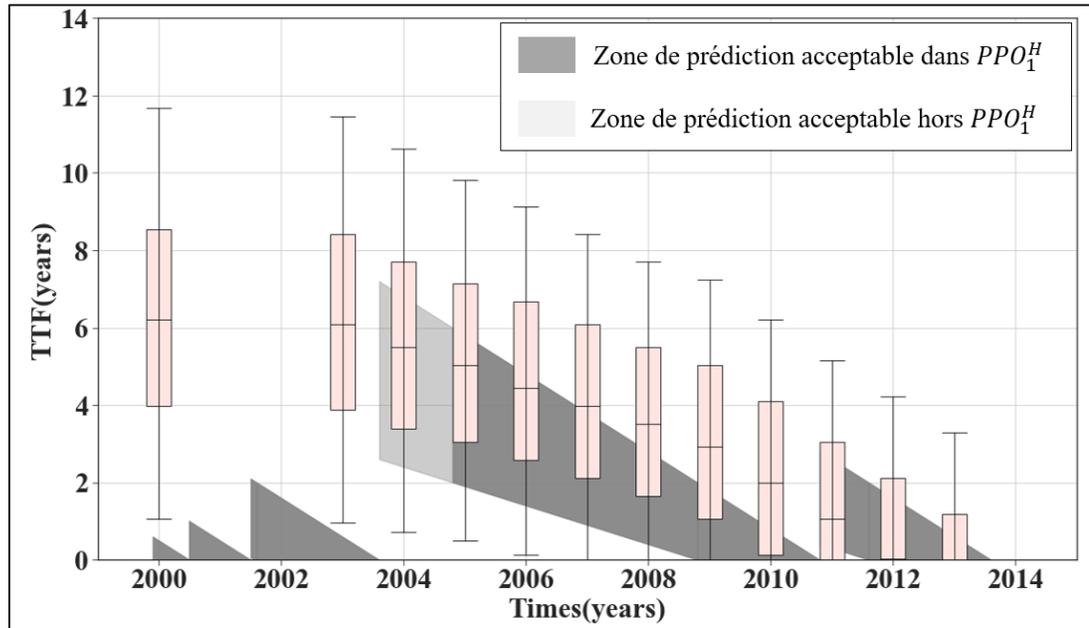


Figure 5.5 Évaluation des performances des résultats de pronostic du stator  $D$  dans le cadre du plan de retrait aux 6 ans ( $PPO_1^H = 6 \text{ ans}$ ;  $PPO_1^f = 2 \text{ ans}$ )

Dans ce cas d'étude, les résultats de l'évaluation montrent que les étendues d'incertitudes des prédictions sont grandes comparativement à la zone acceptable de prédiction pour un plan de retrait avec un horizon de 6 ans. L'algorithme de pronostic a prédit de façon raisonnable la défaillance ayant eu lieu en août 2013 ( $EOF_5$ ) mais n'a pas été capable de prédire les défaillances antérieures avec un niveau de confiance acceptable. En 2008, lors de la mise à jour de la planification des retraits aux 6 ans, une décision aurait pu être prise pour définir un retrait du stator entre les années 2010 et 2013 aux vues des prédictions. Il y a de fortes chances que cette planification n'ait pu éviter la défaillance ayant eu lieu en novembre 2010. La Figure 5.6 et la Figure 5.7 présentent l'évaluation des performances des résultats de pronostic dans le cadre du plan de production aux 2 ans et aux mois.

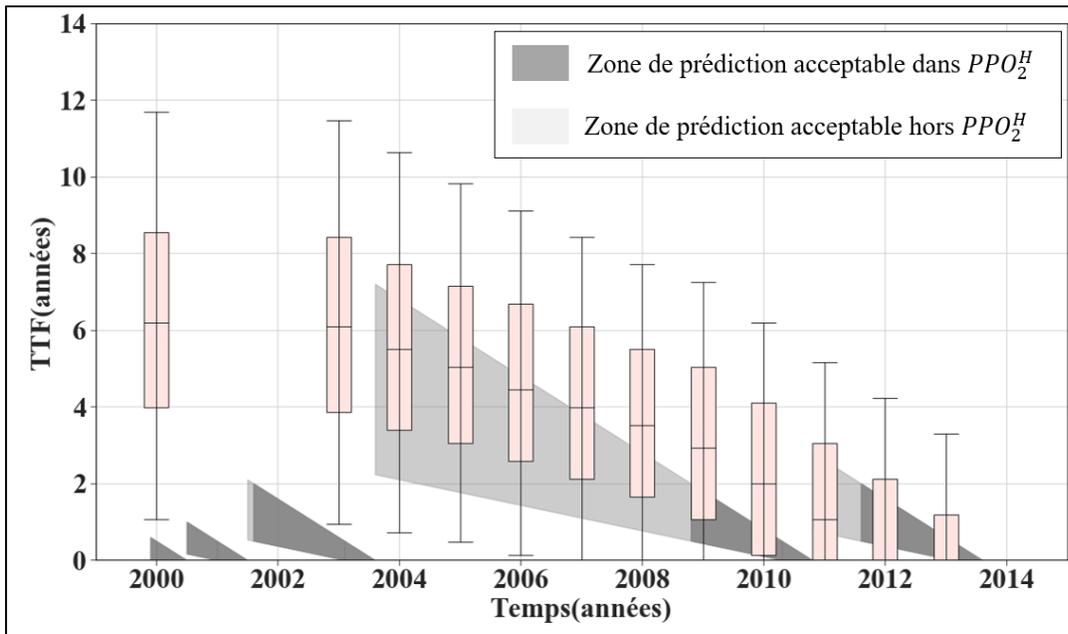


Figure 5.6 Évaluation des performances des résultats de pronostic du stator  $D$  dans le cadre du plan de production aux 2 ans ( $PPO_2^H = 2 \text{ ans}$ ;  $PPO_2^f = 1/2 \text{ ans}$ )

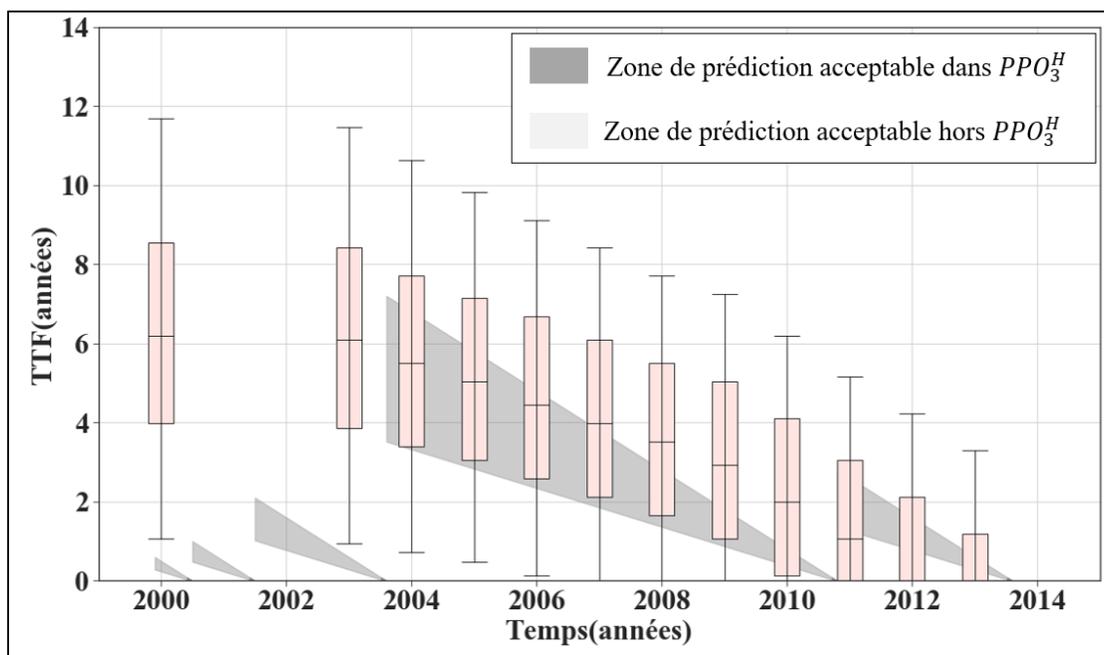


Figure 5.7 Évaluation des performances des résultats de pronostic du stator  $D$  dans le cadre du plan de production aux mois ( $PPO_3^H = 1 \text{ mois}$ ;  $PPO_3^f = 10 \text{ jours}$ )

Sachant que les horizons de planification et leurs fréquences d'actualisation sont encore plus courts, les résultats présentés dans la Figure 5.6 et la Figure 5.7 montrent que les étendues d'incertitudes de l'algorithme de pronostic, dans ce cas précis de l'alternateur D sont trop grandes pour les planifications de production aux 2 ans et aux mois. À l'échelle d'une année, on ne distingue presque pas l'horizon de planification au mois. À la vue des résultats de pronostic proposés par l'algorithme, il aurait été difficile de planifier des actions de mitigation sur les plans de production aux 2 ans et aux mois.

## **5.5 Discussion**

L'arrivée des algorithmes de pronostic offre des capacités de décisions proactives aux organisations. Cependant, la capacité d'évolution des processus de planification déjà en place nécessite un temps d'adaptation pour pouvoir intégrer la force de ces résultats. Il est donc important d'analyser la capacité des algorithmes à supporter les processus décisionnels déjà en place. Pour une organisation, il peut être difficile de définir une zone acceptable de prédiction. Ce chapitre propose une approche simple et efficace permettant de la définir. Les résultats ont montré que la zone acceptable de prédiction proposée s'adapte bien avec les différents contextes opérationnels définis. Le cadre de validation proposé permet rapidement d'estimer les performances de l'algorithme quant à sa capacité à supporter un processus de planification.

À la vue des résultats, on peut remarquer qu'un seul algorithme de pronostic ne peut satisfaire l'ensemble des processus PPOs. Simplement par la nature des données qu'ils utilisent, les algorithmes vont avoir des horizons de planifications et des étendues d'incertitudes différents. Il est donc important d'analyser leurs performances pour des processus de planification opérationnelle pouvant leur correspondre. Dans le cas où les processus de planification actuels ne permettent pas de tirer le plein potentiel d'un algorithme de pronostic, il peut être envisagé de définir des planifications de maintenance prévisionnelle spécifiques selon les performances optimales de l'algorithme en question.

Enfin, un même algorithme de pronostic peut voir ses performances s'améliorer dans le temps si les données qu'il utilise évoluent (augmentation de la fréquence d'acquisition des données, nouveaux capteurs) ou si des mises à jour de certaines parties de l'algorithme sont apportées suite à l'arrivée de nouvelles connaissances. Il est donc important de suivre les performances des algorithmes de pronostic à long terme.

## 5.6 Conclusions

Ce chapitre propose un cadre de validation original offrant la possibilité d'analyser la performance des algorithmes de pronostic pour les systèmes réparables. De plus, il permet d'analyser leurs capacités à supporter les décisions d'opération en considérant les processus de planification déjà en place.

Pour cela, une nouvelle fonction de vérité représentant le temps avant la prochaine défaillance *EOF* est proposée en se basant sur les travaux existants sur les systèmes non réparables. Cette fonction offre la possibilité de pouvoir analyser la capacité des algorithmes de pronostic à prédire la prochaine défaillance de l'équipement tout au long de sa durée de vie. Ensuite, une nouvelle approche est proposée pour définir la zone de prédiction acceptable dans le but d'estimer les performances des algorithmes de pronostic et leur capacité à pouvoir supporter les décisions opérationnelles. L'approche définit la zone acceptable de prédiction en se basant sur l'horizon de planification et la fréquence d'actualisation des processus opérationnels (PPO) existants dans l'organisation. Chaque PPO possède un cadre de validation qui lui est propre et qui représente ses propres besoins en termes de capacité de planification et d'erreur acceptable.

Finalement une étude de cas est proposée dans le contexte opérationnel des alternateurs hydro-électriques. Les résultats de prédiction d'un algorithme de pronostic sont évalués pour 3 processus PPOs. L'étude de cas a démontré que le nouveau cadre de validation proposé permet d'analyser la capacité d'un algorithme à prédire les différentes défaillances tout au long de sa vie utile. Par ailleurs, les résultats ont mis en valeur l'importance d'analyser les performances

des algorithmes selon les besoins spécifiques d'un processus décisionnel. Un algorithme peut être très performant pour supporter certains processus de planification, mais inutilisable pour un autre dépendamment de l'horizon de planification et de sa fréquence d'actualisation.



## CHAPITRE 6

### PROCESSUS D'ACTUALISATION DES MODÈLES DE PRONOSTIC POUR UNE APPLICABILITÉ LONG-TERME

Ce chapitre propose une approche concernant les processus d'actualisation des modèles de pronostic afin d'assurer leur applicabilité à long terme.

Tout au long du développement d'un système de pronostic, différentes hypothèses et décisions de conception sont prises pour assurer les performances optimales de l'algorithme compte tenu des informations de diagnostic disponibles, de notre niveau connaissance, des infrastructures informatiques disponibles et des besoins opérationnels. Un fois l'algorithme de pronostic mis en production, il ne faut pas oublier qu'il représente l'état des connaissances au moment de son développement. Par ailleurs, les paramètres estimés du modèle, qu'ils soient issus des données ou via des connaissances d'experts, doivent aussi pouvoir être actualisés à la vue des nouvelles données ou connaissances disponibles.

Le présent chapitre propose une approche qui permet d'identifier les facteurs d'influence pouvant avoir un impact les performances d'un algorithme de pronostic à long terme. Par la suite, nous proposons un processus d'actualisation pour inclure les évolutions de données ou connaissances.

#### **6.1 Facteurs d'influence pouvant avoir un impact sur les performances d'un algorithme de pronostic à long terme**

##### **6.1.1 Nouvelles données disponibles**

La première partie, la plus évidente dans le contexte des algorithmes de pronostic, est l'arrivée de nouvelles données disponibles jugées comme fiables, donc, exploitables. Ces données peuvent être des données de mesures et d'inspection, mais aussi de nouveaux modèles ou données sur les mécanismes de dégradation. Dans les deux cas, ces données représentent une

nouvelle capacité d'apprentissage pour l'algorithme, mais aussi pour les experts qui participent à son développement. Un processus d'actualisation des paramètres du modèle doit être mis en place.

Du point de vue des algorithmes de pronostic existant, la quantité de nouvelles données disponibles (données d'apprentissage) va avoir un effet sur leurs performances en diminuant l'étendue des incertitudes liées à l'estimation de l'état et, par conséquent, en augmentant leur précision. Ainsi, un algorithme avec des performances historiques faibles pourrait être performant dans le futur au vu de ces nouvelles informations.

Dans le contexte de numérisation actuelle de l'ensemble de nos systèmes, la quantité de données disponible va continuer d'augmenter. La fréquence d'actualisation des modèles devra être basée sur la vitesse de l'arrivée de ces nouvelles données.

### 6.1.2 **Nouvelles connaissances disponibles**

La science est en perpétuelle évolution. Nos connaissances vont continuer de croître dans les prochaines années. Ces connaissances peuvent être de différentes natures : connaissance sur la physique de dégradation, connaissance sur le système technologique, les données opérationnelles ou encore notre connaissance des modèles de pronostic. Elles peuvent permettre de lever certaines hypothèses simplificatrices et ainsi améliorer les performances des modèles de pronostic. Par ailleurs, les connaissances issues du retour d'expérience opérationnel peuvent permettre d'identifier de nouveaux modes de défaillance, de nouveaux moyens de détection de défauts, de nouvelles actions de maintenance ou encore de mieux estimer certains paramètres provenant de processus d'élicitation d'expert.

### 6.1.3 **Nouvelle technologie disponible**

L'arrivée de nouvelles technologies va offrir de nouvelles possibilités pour les algorithmes de pronostic. Par exemple, l'arrivée d'un nouveau capteur peut permettre d'améliorer les performances d'un algorithme de détection et diminuer l'incertitude temporelle de l'activation du défaut. L'arrivée sur le marché des technologies de calcul distribué peut permettre d'améliorer la vitesse d'exécution des algorithmes, mais aussi offre de nouvelles possibilités pour les algorithmes de propagation d'incertitude. L'arrivée de nouveaux algorithmes d'apprentissage peut permettre d'identifier automatiquement de nouvelles caractéristiques de défaut d'un équipement.

### 6.1.4 **Évolution des infrastructures informatiques**

L'évolution des infrastructures informatiques va principalement offrir des capacités de calculs et de stockage de données plus importantes. De plus, cela peut permettre d'avoir plus facilement accès à d'autres types de données pertinentes. Au vu de ces changements, de nouveaux types d'algorithmes de pronostic pourraient être applicables.

### 6.1.5 **Évolution du contexte opérationnel**

Enfin, l'évolution du contexte opérationnel va avoir un très fort impact sur les performances des systèmes de pronostic en place dans le sens où c'est ce contexte qui définit les besoins et spécifications des algorithmes de pronostic. L'évolution des processus de planification opérationnelle (PPO) va directement influencer la capacité des algorithmes à pouvoir supporter les décideurs dans ce nouveau contexte d'opération. Par ailleurs, l'évolution de la population des équipements à l'étude peut aussi avoir un impact important sur les performances des algorithmes à prédire les défaillances en tenant compte de l'hétérogénéité des systèmes.

## 6.2 Processus d'actualisation

Pour assurer la viabilité des algorithmes de pronostic à long terme, les organisations doivent mettre en place un processus d'actualisation et de suivi des performances. Le processus d'actualisation a deux principaux objectifs : (i) actualiser les paramètres du modèle, (ii) analyser l'évolution des performances de l'algorithme de pronostic.

Il est proposé de définir un comité de revue des performances des algorithmes de pronostic. Idéalement, le comité doit être composé d'acteurs ayant des rôles différents liés au développement ou l'utilisation des algorithmes (scientifiques, architectes de solution, développeurs, experts équipements, décideurs, planificateurs de maintenance, etc.). Dépendamment des PPOs que supportent les algorithmes de pronostic, une fréquence de rencontre du comité doit être définie pour assurer le suivi régulier des performances en tenant en compte de l'évolution des facteurs d'influence. La Figure 6.1 présente schématiquement un processus d'actualisation tel que proposé pour les algorithmes de pronostic.

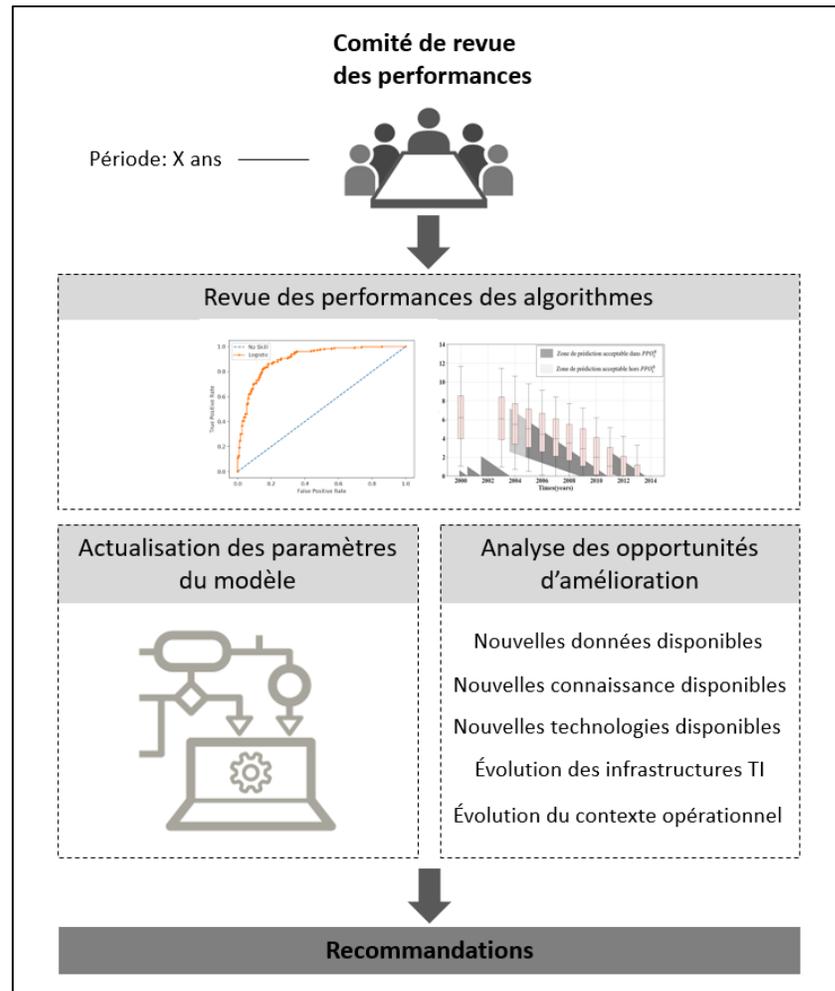


Figure 6.1 Illustration du processus d'actualisation des algorithmes de pronostic

À chaque rencontre du comité, une revue des performances des algorithmes de diagnostic et de pronostic doit être faite sur la période précédente. Au besoin, des études de cas de défaillance peuvent être faites pour analyser les forces et faiblesses des algorithmes. Une fois la revue réalisée, le comité doit faire une analyse des différents facteurs présentés dans la section 6.1. Différentes opportunités ou menaces peuvent alors être identifiées pour faire évoluer l'algorithme de pronostic existant. Ces recommandations doivent être formulées par le comité aux décideurs. Pour finir, les paramètres du modèle doivent être mis à jour au vu des

nouvelles données disponibles. Il est important de mesurer le gain en performance qu'a pu apporter la mise à jour des paramètres du modèle.

### **6.3 Conclusions**

Ce chapitre propose une réflexion et une approche pour assurer la viabilité des algorithmes de pronostic à long terme en tenant compte de l'évolution du contexte d'affaires. Dans un premier temps, une analyse des différents facteurs pouvant avoir un impact sur les performances à long terme des algorithmes de pronostic est proposée. Ensuite, un processus d'actualisation des modèles de pronostic est présenté. Le processus préconise la rencontre périodique d'un comité de revue des performances pour actualiser les paramètres et statuer sur des recommandations d'opportunités d'amélioration.

## CONCLUSION

### Discussion générale

Cette thèse propose une approche globale de développement de modèles de pronostic pour les équipements complexes permettant l'application de la maintenance prévisionnelle. L'approche permet à la fois de prédire plusieurs modes de défaillance en tenant en compte de la complexité intrinsèque de leurs mécanismes de défaillance et de proposer des actions de maintenance prévisionnelle basées sur les résultats de pronostic. L'application de l'approche aux cas des stators d'alternateurs hydro-électriques permet de démontrer sa validité. Les contributions de cette thèse ne s'arrêtent pas seulement au développement d'algorithmes de pronostic, mais visent aussi à assurer l'applicabilité de ces algorithmes dans un contexte opérationnel.

Le CHAPITRE 3 propose une approche de diagnostic et de pronostic pour les équipements complexes. L'approche se base essentiellement sur la compréhension et la modélisation de la physique (mécanismes de dégradation) pour identifier et suivre l'évolution des mécanismes de défaillance à travers une succession d'états physiques de dégradation détectables par des outils de diagnostic. Un formalisme mathématique se basant sur la théorie des graphes est proposé pour assurer la généralité des algorithmes proposés. L'algorithme de diagnostic intègre l'information provenant de divers moyens de diagnostic et permet de suivre l'évolution des mécanismes de défaillances actifs à travers des représentations graphiques sous forme de graphes de causalité dynamiques. Les utilisateurs peuvent alors analyser l'évolution des défauts et du nombre de mécanismes de défaillance actifs sur l'équipement dans le temps. Basé sur les résultats de diagnostic, l'algorithme de pronostic permet de propager les mécanismes de défaillance jusqu'aux modes de défaillance de l'équipement. Il permet alors l'estimation du temps restant avec l'occurrence de chaque mode de défaillance pour chaque date de prédiction. Au fur et à mesure que de nouvelles informations de diagnostic sont disponibles, l'algorithme met à jour ses prédictions.

Le CHAPITRE 4 adapte l'algorithme de pronostic pour permettre l'application de la maintenance prévisionnelle. L'approche de maintenance prévisionnelle se démarque des autres approches proposées dans la littérature, car elle permet d'identifier les actions de maintenance requises en fonction des mécanismes de défaillances actifs et des résultats des algorithmes de pronostic. Les algorithmes de pronostic permettent de définir l'intervalle d'application des actions de maintenance en tenant compte du risque de défaillance et du contexte opérationnel. Les résultats permettent à l'organisation d'identifier automatiquement toutes les actions de mitigations qui sont possibles, pour éviter l'occurrence des modes de défaillance et suggèrent leurs effets potentiels sur le système.

À la lumière de ces résultats, les CHAPITRE 5 et CHAPITRE 6 ont pour objectif d'assurer la viabilité long terme des algorithmes de pronostic dans un contexte opérationnel.

Le CHAPITRE 5 propose une approche originale pour évaluer les performances des algorithmes de pronostic pour les systèmes réparables en tenant en compte des processus opérationnels de l'organisation. L'approche offre la possibilité d'analyser les performances d'algorithmes de défaillance pour prédire les différentes défaillances d'un équipement réparable tout au long de sa vie utile. De plus, elle propose une méthodologie simple pour définir la zone de prédiction acceptable en fonction de l'horizon de planification et de la fréquence d'actualisation des processus de planification opérationnelle en place dans l'organisation.

Finalement, le CHAPITRE 6 offre une vision long terme sur l'utilisation des algorithmes de pronostic permettant l'application de la maintenance prévisionnelle. Il propose un processus d'actualisation et d'évolution des modèles de pronostic en tenant en compte de l'évolution du contexte d'affaires et des nouvelles informations disponibles.

L'approche complète est appliquée et validée avec succès dans le cas des alternateurs hydro-électriques en tenant en compte de leurs contextes opérationnels. Elle démontre un grand potentiel d'applications dans diverses industries lors de recherches futures.

### **Contributions scientifiques**

Dans son ensemble, le travail de recherche apporte plusieurs contributions scientifiques :

- Développement d'une approche de pronostic multimodes de défaillance pour les équipements complexes tenant en compte la complexité de leurs mécanismes de défaillance;
- Définition d'un formalisme mathématique des algorithmes de diagnostic et de pronostic basé sur la théorie des graphes pour assurer la généralité des algorithmes proposés et la visualisation interactive de leurs résultats;
- Développement d'une approche de maintenance prévisionnelle permettant de prédire les intervalles d'application des actions de maintenance qui seront requises en tenant compte des mécanismes de défaillance détectés actifs, des résultats de pronostic et du contexte opérationnel;
- Développement de la première approche permettant l'évaluation des performances des algorithmes de pronostic pour les systèmes réparables et la définition de la zone de prédiction acceptable en se basant sur leur contexte opérationnel;
- Développement d'un processus d'actualisation et d'évolution des algorithmes de pronostic pour assurer leur viabilité à long terme.

Une partie majeure de ces contributions est déjà publiée dans des revues ou conférences avec comité de lecture:

- Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). *A Predictive Maintenance Approach for Complex Equipment Based on Failure Mechanism Propagation Model*. International Journal of the Prognostic and Health management society. <http://www.phmsociety.org/node/2675>

- Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Lévesque, M., & Hudon, C. (2018). *A holistic multi-failure mode prognosis approach for complex equipment*. Reliability Engineering & System Safety, 180, 136-151. doi: <https://doi.org/10.1016/j.ress.2018.07.006>
- Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). *A Predictive Maintenance Approach for Complex Equipment Based on Petri Net Failure Mechanism Propagation Model*. Paper presented at the PHM Society European Conference. <https://phmpapers.org/index.php/phme/article/view/434>
- Blancke, O., Komljenovic, D., Tahan, A., Amyot, N., Hudon, C., Boudreau, J.-F., & Lévesque, M. (2018). *From data to asset health management in the context of hydropower generation: A holistic concept*. Paper presented at the World Congress of Engineering Asset Management (WCEAM).
- Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Levesque, M., & Hudon, C. (2016). *A Hydrogenerator Model-Based Failure Detection Framework to Support Asset Management*. Paper presented at the IEEE International Conference on Prognostics and Health Management, Ottawa, OT, Canada. doi: <https://doi.org/10.1109/ICPHM.2016.7542867>
- Blancke, O., Merkhouf, A., Amyot, N., Pedneault-Desroches, J., Hudon, C., & Haddad, K. (2016). *Strategic Fault Diagnosis Approach for Hydrogenerator Shaft Current Discharges*. Paper presented at the 2016 International Conference on Electrical Machines, Lausanne, Suisse. doi: <https://doi.org/10.1109/ICELMACH.2016.7732849>

Une troisième publication de revue avec comité de lecture est en cours de rédaction :

- Blancke, O., Tahan, A., Komljenovic, D., Amyot, (2020). *Performance Evaluation of Prognostic Algorithms for Repairable Equipment in an Industrial Context*. Reliability Engineering & System Safety.

## RECOMMANDATIONS

### Défis futurs et limites de la méthodologie

Il est indispensable de souligner les défis et limites que le développement et l'application de l'approche proposée peuvent rencontrer. Ils incluent, mais ne sont pas limités à :

- Le niveau de connaissance nécessaire pour développer le modèle physique (mécanismes de dégradation/défaillance, algorithmes de détection, temps de transition);
- L'historique des contraintes d'opération (environnement et niveau de charge) et de l'effet des maintenances ne sont pas pris en compte dans l'algorithme de pronostic;
- La disponibilité des données de diagnostic en quantité et qualité suffisantes;
- La disponibilité des données de défaillance pour valider l'algorithme de pronostic;
- La validité des algorithmes de détection;
- L'effort en temps et financier pour le développement des modèles;
- L'homogénéité des équipements d'étude pour assurer la représentativité du modèle physique;

### Recherches futures

Lors de la réalisation de ce travail de recherche, différentes avenues ont été identifiées pour le développement de futures recherches. Ces recherches visent à s'attaquer dans un premier temps aux lacunes, limites, défis et finalement aux opportunités identifiées dans les travaux proposés.

L'un des principaux défis de l'approche proposée est l'estimation des temps des transitions inter-états de dégradation. Le processus d'élicitation proposé dans l'étude de cas des alternateurs hydro-électriques permet d'obtenir des estimés au meilleur de nos connaissances. Cependant, l'effort nécessaire est considérable et implique des heures de travail pour différents experts. Par ailleurs, l'approche ne permet pas de tenir en compte de l'effet de l'historique des contraintes d'opération et de maintenance. L'étendue des incertitudes estimées est souvent

grande et représente la limite de nos connaissances pour certains processus de dégradation. Il serait pertinent de développer une approche pouvant permettre l'estimation des temps de transition inter-états de dégradation à partir des données de diagnostic, de défaillances et de variables tenant en compte l'historique des contraintes d'opération et de la maintenance. Cette approche devra prendre en compte l'incertitude inhérente des intervalles d'activation des états physiques de dégradation et proposer des distributions pour représenter les incertitudes des temps de transition estimés selon les variables d'étude choisies. Il sera important de vérifier que le processus d'apprentissage respecte les hypothèses de propagation des mécanismes de défaillance tel que l'indépendance des mécanismes de défaillance. Il serait important d'intégrer l'impact de l'environnement et des niveaux de contraintes opérationnels sur les temps de propagation des mécanismes de défaillance. Cela permettrait de faire évoluer le modèle vers un modèle hybride utilisant la robustesse des approches physiques et la puissance des algorithmes d'apprentissage. Dans la littérature, de nombreuses publications récentes montrent un engouement pour le développement d'approches hybrides dans les modèles de pronostic (Kong, Jo, Jung, Ha, Shin et al., 2019; Yucesan & Viana, 2019).

Un autre défi de l'approche proposée est la construction des graphes de causalité. Lorsque les connaissances des experts sont présentes, il est relativement abordable d'identifier les liens de causalité entre les différents états de dégradation identifiés. Cependant, pour des systèmes complexes où les liens de cause à effet sont difficiles à identifier, il serait intéressant de pouvoir les identifier par les données historiques. Ce sujet est d'actualité et différentes publications ont été publiées récemment sur l'identification des liens de causalité par des approches d'apprentissage machine (Bontempi & Flauder, 2019; Leng, Xu, & Ma, 2019). Une recherche future pourrait être envisageable sur l'identification des liens de causalité entre des états de dégradation par des algorithmes d'apprentissage machine.

Pour assurer une meilleure couverture des algorithmes de pronostic et notamment envers les événements de défaillance encore non connus, il serait intéressant de coupler le modèle physique proposé dans ce travail avec un algorithme de pronostic seulement basé sur des

données. Le modèle physique donne des informations riches permettant l'application d'une maintenance prévisionnelle avec un horizon de planification long terme (modèle proposé dans cette thèse). L'algorithme basé sur les données permettrait de contre vérifier qu'aucune caractéristique de défaillance ne survienne par inadvertance à court terme en utilisant l'abstraction des modèles basés sur les données. Des recherches pourraient être envisagées pour développer un modèle de pronostic seulement basé sur des algorithmes d'apprentissage machine utilisant des données de mesures en continu sur l'alternateur pour assurer des prédictions de défaillance à court terme.

Afin d'assurer la validité des algorithmes de détection des états physiques de dégradation, il serait important d'évaluer leurs performances en utilisant la méthode d'analyse de la courbe ROC (*Receiver Operating Characteristic*). Cette approche permettrait de mieux connaître la performance des algorithmes en termes de fausses alarmes positives et négatives. De même, par des études de cas issues du passé, une évaluation des performances de l'algorithme de détection des mécanismes de défaillance actifs pourrait aussi être réalisée. À la vue de ces résultats, il serait alors possible d'améliorer les algorithmes de détection ou d'en proposer d'autres.

Finalement, des opportunités de recherche ont été identifiées suite aux développements scientifiques proposés dans ces travaux de recherches.

Au niveau du **diagnostic**, la définition du formalisme mathématique de l'algorithme basé sur la théorie des graphes a permis d'ouvrir de belles perspectives de recherche. En effet, il semblerait intéressant de développer des algorithmes permettant de définir des stratégies de diagnostic pour assurer une couverture maximale des mécanismes de défaillance et minimiser les incertitudes des résultats de pronostic. Les algorithmes d'analyse utilisés pour les réseaux sociaux comportent des caractéristiques intéressantes qu'il serait intéressant d'appliquer au diagnostic. Il serait alors possible d'identifier les stratégies de diagnostic optimales permettant d'assurer une couverture maximale des mécanismes de défaillance et de réduire les incertitudes

de l'algorithme de pronostic au fur et à mesure que de nouvelles données de diagnostic sont disponibles.

Au niveau du **pronostic**, l'approche au niveau système proposée dans ces travaux offre de nombreuses possibilités quant au développement des algorithmes de propagation des mécanismes de défaillance. Dans un premier temps, il pourrait être intéressant d'analyser d'autres algorithmes permettant la propagation des mécanismes de défaillance. Dans les travaux proposés, les mécanismes de défaillance sont considérés comme indépendants. Il serait intéressant d'intégrer l'effet de l'environnement et des niveaux de charges opérationnels en utilisant des modèles de Cox pour pondérer les distributions statistiques des temps de transition. Il serait aussi pertinent de vérifier cette hypothèse en utilisant les données historiques disponibles sur la propagation de ces mécanismes. Ensuite, au niveau de l'estimation des probabilités d'occurrence des modes de défaillance, d'autres approches pourraient être proposées pour agréger la contribution des mécanismes envers leurs modes de défaillance respectifs. Finalement, d'autres méthodes de propagation d'incertitude que les approches Monte-Carlo classiques pourraient être envisagées pour améliorer les temps de calcul des algorithmes. Pour chaque variante d'algorithme proposé, il sera important d'analyser leurs performances sur différents cas d'étude.

Au niveau de **l'analyse des performances** pour les systèmes réparables, il semble qu'il y ait beaucoup de développements possibles encore à réaliser, tel que mentionné par Goebel et al. (K.; Goebel et al., 2017) dans leur livre publié en 2017. Très peu de littérature existe sur ce sujet et encore beaucoup de questions restent à explorer. L'approche proposée permet de définir un cadre de validation pour les systèmes réparables. Cependant, le cadre permet seulement d'estimer les performances d'un algorithme de pronostic pour un système réparable unique. Un point important serait de pouvoir analyser les performances d'un algorithme de pronostic sur une population d'équipements en intégrant les notions de temporalité et de convergence des prédictions. Il serait alors important de trouver à la fois des métriques et des visualisations pour analyser ces performances à l'échelle d'une population d'actifs.

Pour clôturer ma recherche et ces quelques années de réflexions, je souhaite souligner l'importance de la relation étroite entre l'Homme et les algorithmes qui vont, d'ici quelques années, être au cœur de nos futures décisions. N'oublions pas que ces algorithmes, que nous créons et alimentons, ont pour objectifs d'améliorer nos décisions dans l'espoir de garantir un monde meilleur. Il est important d'être en mesure de comprendre leurs résultats pour être capable de prendre des décisions rationnelles. L'utilisation d'algorithmes ne doit pas créer de dépendance, mais bien au contraire permettre le développement de nos connaissances. Je pense que les algorithmes sont une force qui doit permettre le développement de notre compréhension et de nos capacités cognitives. Le domaine naissant de l'intelligence augmentée à l'instar de l'intelligence artificielle semble apporter des éléments de réponse à ce paradigme. Tel que présenté par Zhend et al. (Zheng, Liu, Ren, Ma, Chen et al., 2017), l'intelligence augmentée vise à combiner les forces de l'intelligence humaine (raisonnement intuitif, capacité d'analyse d'informations non structurées, autonomie) à celle de l'intelligence artificielle (puissance de calcul, répétabilité, logique, abstraction) dans un processus d'amélioration continue et bilatérale. Une attention particulière doit être portée pour le développement de ce type d'approche dans les prochaines années.



## **ANNEXE I**

### **EXTRAITS DES PUBLICATIONS SCIENTIFIQUES AVEC COMITÉ DE LECTURE RELATIVE AUX TRAVAUX DE RECHERCHE**

Début sur la page suivante.

Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). *A Predictive Maintenance Approach for Complex Equipment Based on Failure Mechanism Propagation Model*. International Journal of the Prognostic and Health management society. <http://www.phmsociety.org/node/2675>

## A Predictive Maintenance Approach for Complex Equipment Based on a Failure Mechanism Propagation Model

Olivier Blancke<sup>1</sup>, Amélie Combette<sup>2</sup>, Normand Amyot<sup>3</sup>, Dragan Komljenovic<sup>3</sup>, Mélanie Lévesque<sup>3</sup>, Claude Hudon<sup>3</sup>, Antoine Tahan<sup>1</sup> and Noureddine Zerhouni<sup>2</sup>

<sup>1</sup>École de technologie supérieure (ETS), Montréal, Québec, QC H3C 1K3, Canada  
olivier.blancke.1@ens.etsmtl.ca; antoine.tahan@etsmtl.ca

<sup>2</sup>FEMTO-ST Institute, AS2M Department, University of Franche-Comté/CNRS/ENSMM/UTBM, Besançon, 25000, France  
amelie.combette@ens2m.fr; noureddine.zerhouni@ens2m.fr

<sup>3</sup>Institut de recherche d'Hydro-Québec (IREQ), Varennes, Québec, J3X 1S1, Canada  
komljenovic.dragan@ireq.ca; amyot.normand@ireq.ca; hudon.claude@ireq.ca; levesque.melanie@ireq.ca

### ABSTRACT

The aim of this paper is to propose a comprehensive approach for the predictive maintenance of complex equipment. The approach relies on a physics of failure (PoF) model based on expert knowledge and data. The model can be represented as a multi-state Petri Net where different failure mechanisms have been discretized using physical degradation states. Each physical state can be detected by a unique combination of symptoms that are measurable using diagnostic tools. Based on actual diagnostic information, a diagnostic algorithm is used to identify active failure mechanisms and estimate their propagation using the Petri Net technique. Specific maintenance actions and their potential effects on the system can be associated with target states. A prognostic algorithm using a colored Petri Net propagates active failure mechanisms through the target physical states. A predictive maintenance approach is therefore proposed by allowing specific maintenance actions to be determined in a reasonable timeframe. A case study is presented for an actual hydro-generator. Finally, model limits are discussed and potential areas for further research are identified.

### 1. INTRODUCTION

Predictive maintenance is a discipline that allows the planning of maintenance actions based on prognostic models. From an organization's perspective, it is an integral part of the asset management process defined as a *set of coordinated activities of an organization to realize value from assets* (ISO, 2014). Unlike preventive maintenance or reliability-based maintenance approaches, predictive maintenance approaches take into account the dynamic and individual

Olivier Blancke et al. This is an open-access article distributed under the terms of the Creative Commons Attribution 3.0 United States License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

aspects of each asset's data. Prognostic models predict the occurrence of equipment failure modes taking into account their condition, operation and environment loads and their related uncertainties (Atamuradov, Medjaher, Dersin, Lamoureux, & Zerhouni, 2017; Goebel et al., 2017). The predicted information is updated as new asset health information becomes available. Maintenance actions are then proposed in advance to avoid occurrence of the predicted failure modes. Different aspects also need to be taken into account to optimize maintenance planning so as to ensure strategic planning within the fleet. Those aspects include equipment criticality, operational resource constraints and organizational objectives, to name just a few (IAM, 2015).

For the last decade, the development of prognostic models has been an intensive research topic from both an academic and operational point of view. In the literature, the vast majority of prognostics research to date has been focused on the prediction of the *remaining useful life* (RUL) of individual components (Atamuradov et al., 2017; M. Chiacchio, Chiacchio, Sankararaman, Andrews, & Targett, 2017). Moreover, much of this research focuses on the propagation of a single mechanism leading to a single failure mode.

However, industrial complex equipment can have concurrent multi-failure modes and multi-failure mechanisms leading to them involving various components and sub-components (Atamuradov et al., 2017; Blancke, Amyot, Hudon, Lévesque, & Tahan, 2015; Blancke, Tahan, et al., 2018). The propagation of failure mechanisms may also involve several components, and various diagnostic tools can be used to detect and track them at different system scales. Once predetermined degradation thresholds are reached, specific maintenance actions should be taken to avoid a system failure. Depending on the types of active failure mechanisms

Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Lévesque, M., & Hudon, C. (2018). *A holistic multi-failure mode prognosis approach for complex equipment*. Reliability Engineering & System Safety, 180, 136-151. doi: <https://doi.org/10.1016/j.res.2018.07.006>

Reliability Engineering and System Safety 180 (2018) 136–151

Contents lists available at ScienceDirect

**Reliability Engineering and System Safety**

journal homepage: [www.elsevier.com/locate/res](http://www.elsevier.com/locate/res)




**A holistic multi-failure mode prognosis approach for complex equipment**

Olivier Blancke<sup>a,\*</sup>, Antoine Tahan<sup>a</sup>, Dragan Komljenovic<sup>b</sup>, Normand Amyot<sup>b</sup>, Mélanie Lévesque<sup>b</sup>, Claude Hudon<sup>b</sup>

<sup>a</sup> *École de technologie supérieure, Montréal, QC, H3C 1K3 Canada*  
<sup>b</sup> *Institut de recherche d'Hydro-Québec (IREQ), Varennes, QC, J3X 1S1 Canada*

**ARTICLE INFO**

**Keywords:**  
 System-level prognostics  
 Diagnostics  
 Failure mechanisms  
 Multi-state systems  
 Complex systems  
 Expert elicitation  
 Hydrogenerator

**ABSTRACT**

The aim of this paper is to propose a holistic multi-failure mode prognosis approach that takes into account the complexity of failure mechanisms as a system. Model assumptions are first proposed by experts and then formalized using graph theory and stochastic models. The prognosis approach relies on a diagnostic algorithm that combines diagnostic information from different sources (e.g., measurements and inspections) to detect active failure mechanisms and track their progression, and a prognostic algorithm that predicts failure mode occurrences dynamically as new information becomes available. Furthermore, the approach identifies undetectable failure mechanisms where no symptoms have yet been measured. The relative simplicity of the algorithms and graphical representation of the results helps to build decision-makers' trust. In addition, the approach is a means of capturing acquired knowledge and available data. A case study of a hydroelectric generator stator is proposed. The resulting multi-state degradation model identified more than 150 failure mechanisms discretized in 70 physical states and leading to three failure modes. Three historical failure and one online case studies are presented, based on diagnostic data from Hydro-Québec's generating fleet. In two of the case studies, the failure mode occurrence could have been predicted more than eight years in advance.

**1. Introduction**

Recent developments in measuring device technology, data accessibility, analytics and connectivity have made prognostics and health management (PHM) a leading emerging discipline that can bridge the gap between up-to-date asset-specific health data and asset-specific actionable information [1,2]. Prognostics, which is part of this discipline, is defined by the ISO 13,381 standard as the analysis of fault symptoms that predict future conditions and residual life within design parameters [3]. It predicts the probability of occurrence of equipment failure modes based on up-to-date health information. Like reliability engineering in past decades [4], PHM will play a significant role in providing decision makers with the temporal dynamics and specific aspects of operating data [4–6].

Prognostic approaches can be categorized into four types as proposed by Elattar et al. [7]: reliability-based approach, physics-based approach, data-driven approach and hybrid approach. Despite the recent implementation of new sensors and device technology, as well as data storage, lack of relevant historical data is still a common challenge for a significant proportion of industrial applications [8]. Physics-based prognostic models, also called Physics-of-Failure (PoF) prognostic models, can be applied even if historical data is scarce. They are usually applied at the component level and assume that failure mechanisms (e.g., crack propagation and cavitation) are independent [1,2,9]. In an industrial context, they can be applied to specific equipment with a limited number of components, failure mechanisms and failure modes.

Complex equipment usually has multi-failure modes and inter-related failure mechanisms evolving through many of its components. Diagnostic information comes from different sources (e.g., measurements and inspections) at discrete intervals in time. Component-level prognostic models have limited applicability to complex equipment, as they handle neither the inherent complexity of failure mechanisms nor the interrelations among components [8,9] and provide only a partial representation of the overall equipment [10]. As noted by Sikorska et al. [2] and Javed et al. [1], few prognostic models have been applied to complex equipment in the field.

This study aims to develop a holistic multi-failure-mode prognosis approach that takes into account the complexity of failure mechanisms as a system. To achieve this, model assumptions are first proposed by experts and then formalized using graph theory and stochastic models. The prognosis approach relies on a diagnostic algorithm that combines different sources of diagnostic information (e.g., measurements and

\* Corresponding author.  
 E-mail address: [olivier.blancke.1@ens.etsmtl.ca](mailto:olivier.blancke.1@ens.etsmtl.ca) (O. Blancke).

<https://doi.org/10.1016/j.res.2018.07.006>  
 Received 24 November 2017; Received in revised form 31 May 2018; Accepted 5 July 2018  
 Available online 17 July 2018  
 0951-8320/ © 2018 Elsevier Ltd. All rights reserved.

Blancke, O., Combette, A., Amyot, N., Komljenovic, D., Lévesque, M., Hudon, C., Tahan, A., Zerhouni, N. (2018). *A Predictive Maintenance Approach for Complex Equipment Based on Petri Net Failure Mechanism Propagation Model*. Paper presented at the PHM Society European Conference. <https://phmpapers.org/index.php/phme/article/view/434>

## A Predictive Maintenance Approach for Complex Equipment Based on Petri Net Failure Mechanism Propagation Model

Olivier Blancke<sup>1</sup>, Amélie Combette<sup>2</sup>, Normand Amyot<sup>3</sup>, Dragan Komljenovic<sup>3</sup>, Mélanie Lévesque<sup>3</sup>, Claude Hudon<sup>3</sup>, Antoine Tahan<sup>1</sup> and Noureddine Zerhouni<sup>2</sup>

<sup>1</sup>École de technologie supérieure (ETS), Montréal, Québec, QC H3C 1K3, Canada  
 olivier.blancke.1@ens.etsmtl.ca; antoine.tahan@etsmtl.ca

<sup>2</sup>FEMTO-ST Institute, AS2M Department, University of Franche-Comté/CNRS/ENSMM/UTBM, Besançon, 25000, France  
 amelie.combette@ens2m.fr; noureddine.zerhouni@ens2m.fr

<sup>3</sup>Institut de recherche d'Hydro-Québec (IREQ), Varennes, Québec, J3X 1S1, Canada  
 komljenovic.dragan@ireq.ca; amyot.normand@ireq.ca; hudon.claude@ireq.ca; levesque.melanie@ireq.ca

### ABSTRACT

The aim of this paper is to propose a comprehensive approach for predictive maintenance of complex equipment. The approach relies on a physics of failure model based on expert knowledge. The model can be represented as a multi-state Petri Net where different failure mechanisms have been discretized using physical degradation states. Each state can be detected by a unique combination of symptoms that can be measured from diagnostic tools. Based on actual existing diagnostic information, a diagnostic algorithm enables the identification of active failure mechanisms and estimates their progression in the Petri Net. Specific maintenance actions and their potential effect on the system can be associated with targeted states. Thereafter, a prognostic algorithm using a coloured Petri Net propagation method spreads active failure mechanisms through their related remaining states towards the targeted states. This allows specific maintenance actions to be proposed in a timeframe and thus enables predictive maintenance. Case study is presented for a real hydro generator. Finally, model limits are discussed and potential areas of further research are identified.

### 1. INTRODUCTION

Predictive maintenance is a discipline that allows the planning of maintenance actions based on prognostic models. From an organization's perspective, it is an integral part of the asset management process defined as a *set of coordinated activities of an organization to realize the value of assets* (ISO, 2014). Unlike preventive maintenance or

reliability-based maintenance approaches, predictive maintenance approaches take into account the dynamic and individual aspect of each asset's data. Prognostic models allows predicting the occurrence of equipment failure modes taking into account their condition, operation and environment loads and their related uncertainties (Goebel et al., 2017, Atamuradov et al., 2017). The predicted information is updated as new asset health information becomes available. Maintenance actions are then proposed in advance to avoid the predicted failure modes. In order to ensure strategic planning within the fleet, different aspects also need to be taken into account to optimize maintenance planning such as equipment's criticality, operational resource constraints, organizational objectives to name a few (IAM, 2015).

For the last decade, the development of prognostic models has been intensive research topic from both an academic and an operational point of view. In the literature, the vast majority of prognostics research to date have been focused on the prediction of *remaining useful life* (RUL) of individual components (Atamuradov et al., 2017, Chiachio et al., 2017). Moreover, much of this research focuses on the propagation of a single mechanism leading to a single failure mode.

However, industrial complex equipment can have concurrent multi-failure modes and multi-failure mechanisms leading to them involving various components and sub-components (Blancke et al., 2015, Atamuradov et al., 2017). The propagation of failure mechanisms may also involve several components and various diagnostic tools can be used to detect and track them at different system scales. Once predetermined degradation thresholds are reached, specific maintenance actions should be taken to avoid a system failure. Depending on the types of active failure

Olivier Blancke et al. This is an open-access article distributed under the terms of the Creative Commons Attribution 3.0 United States License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Blancke, O., Komljenovic, D., Tahan, A., Amyot, N., Hudon, C., Boudreau, J.-F., & Lévesque, M. (2018). *From data to asset health management in the context of hydropower generation: A holistic concept*. Paper presented at the World Congress of Engineering Asset Management (WCEAM).

## From Data to Asset Health Management in the Context of Hydropower Generation: a Holistic Concept

Olivier Blancke<sup>1</sup>, Dragan Komljenovic<sup>2</sup>, Antoine Tahan<sup>3</sup>, Normand Amyot<sup>2</sup>, Claude Hudon<sup>2</sup>, Jean-François Boudreau<sup>2</sup>, Mélanie Lévesque<sup>2</sup>

**Abstract** Asset management is an enabling discipline that is defined by the International Standard ISO 55000 as the coordinated activities of an organization to realize value from assets. Prognostic and health management (PHM), component and system reliability, risk assessment, asset management planning and organizational structure are all part of the asset health management process. Those activities are themselves specific disciplines which have their own standards, goals, expert communities and visions. However links between them as a whole process still have to be clearly understood and defined. The aim of this paper is to propose a holistic asset health management model depicting interrelations between activities. The well-known Data-Information-Knowledge-Wisdom (DIKW) hierarchy is applied to the asset management process to shed light on interactions between key activities and their contributions to the asset management value chain. To illustrate the concept, an example is shown in the context of hydropower generation.

### 1 Introduction

Over the last decade, modern companies have attempted to establish holistic system approaches for Asset Management (AsM) to increase their value creation by taking advantage of the latest technological advances. In this context, experience gained and significant progress in the field of Asset Management has led to the establishment of an international standard in AsM, the ISO 55000 standard (ISO, 2014).

Asset management is defined by the ISO Standard as a set of *coordinated activities of an organization to realize the value of assets* (ISO, 2014). These coordinated activities are

---

<sup>1</sup> O. Blancke (✉)  
École de Technologie Supérieure, Montréal, QC, Canada  
e-mail: olivier.blancke.1@etsmtl.ca

<sup>2</sup> D. Komljenovic  
Institut de recherche d'Hydro-Québec (IREQ), Varennes, QC, Canada  
email: komljenovic.dragan@ireq.ca

<sup>3</sup> A. Tahan  
École de Technologie Supérieure, Montréal, QC, Canada  
email: antoine.tahan@etsmtl.ca

Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Levesque, M., & Hudon, C. (2016). *A Hydrogenerator Model-Based Failure Detection Framework to Support Asset Management*. Paper presented at the IEEE International Conference on Prognostics and Health Management, Ottawa, OT, Canada. doi: <https://doi.org/10.1109/ICPHM.2016.7542867>

# A Hydrogenerator Model-Based Failure Detection Framework to Support Asset Management

Olivier Blancke and Antoine Tahan  
 École de Technologie Supérieure  
 Montréal, QC, Canada  
 olivier.blancke.1@ens.etsmtl.ca

Dragan Komljenovic, Normand Amyot, Claude Hudon and Melanie Lévesque  
 Institut de Recherche d'Hydro-Québec  
 Varennes, QC, Canada

**Abstract**— Electrical utilities in North America significantly increased their installed capacities between 1960 and 1990. This ageing fleet is now forcing the producers to begin to use a holistic asset management in a more systematic way by introducing diagnostic and prognostic tools to support them in their decision-making process. For the last few decades, the Hydro-Quebec Research Institute has been working to understand ageing mechanisms and developing a diagnostic and prognostic causal graph model for hydrogenerators based on expert knowledge and diagnostic data. This paper proposes asset and asset system metrics based on graph theory to estimate the probability of detecting a failure using the number of detectable early warning signs. Proposed indicators intend to inform operators and decision makers on the failure detection probability for each individual asset and to identify critical failure detection of assets at an asset system level. An analysis has been carried out on a real hydropower plant for each of its sixteen hydrogenerators. Some results will be presented and critical failure detection rates for hydrogenerators will be identified. A framework will be proposed to improve asset management.

**Keywords**—hydrogenerator; diagnostics; failure mechanisms; failure detection; asset management; knowledge-based models; prognostics

## I. INTRODUCTION

Electrical utilities in North America significantly increased their installed capacities between 1960 and 1990. This ageing fleet is now forcing the producers to prioritize hydrogenerator refurbishments and to implement maintenance strategies. For that purpose, electrical utilities began to use holistic asset management in a more systematic way by introducing diagnostic and prognostic tools to support them in their decision-making process. Asset management is defined by the International Standard ISO 55000 as the coordinated activity of an organization to realize value from assets [1]. Figure 1 shows an overview of the management system from the management of individual assets to the organization level. Diagnostic and prognostic tools are part of the system performance, cost and risk control. These activities allow to monitor, anticipate, reduce and control the probabilities and consequences of unwanted faults or failures over time in order to support predictive maintenance and decision-making on an asset system level [2].

For the last few decades, Hydro-Quebec's Research Institute has been working to understand ageing mechanisms and developing diagnostic and prognostic tools for hydrogenerators. The selected approach is summarized in Figure 2.



Figure 1. Hierarchy of assets within an integrated management system [2]

A web-based application called MIDA (Methodology for Integrated Diagnostic of hydrogenerators) was developed and implemented in 2008. MIDA makes use of data from actual diagnostic tools and inspections to calculate a health index for the entire hydrogenerator fleet [3]. At an asset system level, it allows the ranking of hydrogenerators with respect to their health index and at the same time gathers detailed expert knowledge.

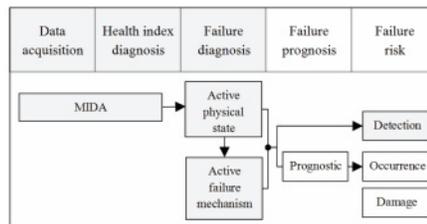


Figure 2. Failure risk prognosis estimation process as defined at Hydro-Québec

Based on significant available diagnostic data combined with expert knowledge, an advanced diagnostic and prognostic model is currently being used for the development of an identification method of active failure mechanisms in hydrogenerators.

As hydrogenerators are multi-failure mode systems evolving through a great number of components and complex failure mechanisms, the diagnostic model under development is based on expert knowledge and diagnostic data. The approach uses a Failure Mechanisms and Symptoms Analysis (FMSA) [4]. The FMSA identifies and structures all possible known failure mechanisms

Blancke, O., Merkhouf, A., Amyot, N., Pedneault-Desroches, J., Hudon, C., & Haddad, K. (2016). *Strategic Fault Diagnosis Approach for Hydrogenerator Shaft Current Discharges*. Paper presented at the 2016 International Conference on Electrical Machines, Lausanne, Suisse. doi: <https://doi.org/10.1109/ICELMACH.2016.7732849>

## Strategic Fault Diagnosis Approach for Hydrogenerator Shaft Current Discharges

O. Blancke, A. Merkhouf, N. Amyot, J. Pedneault-Desroches, C. Hudon and K. Haddad

**Abstract** – Hydroelectric generator shaft current faults, which are mainly due to human error and electromagnetic anomalies in the generator, can cause mechanical bearing failures in several different modes. Because of the silo structure of maintenance departments, such complex failure mechanisms are rarely well diagnosed, and this leads to less-than-optimal maintenance actions because the root causes of the failure are insufficiently understood. This paper proposes a new strategic fault diagnosis approach for shaft current discharges, with the aim of establishing priorities for conducting diagnoses and improving maintenance efficiency. Based on a failure mechanisms review, the authors present a diagnostic strategy for identifying critical shaft currents on hydroelectric generators and also propose a suitable monitoring and decision making methodology to prevent bearing failure using existing sensors and inspections. Some measurement results will be presented.

**Index Terms**– electrical pitting; fault diagnosis; failure mechanisms; shaft current; hydroelectric generator.

### I. INTRODUCTION

HYDROELECTRIC power companies have to maximize their generating assets' availability in order to meet energy demand. As a result, any diagnostics or maintenance needed on critical assets must be performed on a priority basis during low-demand periods. Generator shaft currents faults are mainly due to human error (bypassing of existing insulation) and to electromagnetic anomalies in the generator, specifically design flaws mainly related to the number of stator segments and poles. Shaft currents can lead to mechanical bearing failures in several different modes. Because of the silo structure of maintenance departments, such complex failure mechanisms are rarely well diagnosed, and this leads to less-than-optimal maintenance actions because the root causes of the failure are insufficiently understood. Both mechanical and electrical expertise could help improve the approach to bearing failure prevention and fault diagnosis related to shaft currents.

As defined by various authors [1, 2], the diagnosis or fault diagnosis can be divided into three successive steps: fault detection (determining the presence of a fault on the system), fault isolation (identifying the active failure mechanisms)

and fault identification (actual localization and progression of the active failure mechanisms). These are essentially the basic steps in an efficient diagnosis strategy. The aim of this paper is to identify a suitable monitoring strategy for each of those steps as they apply to shaft current discharges. To this end, the failure mechanisms leading from root causes to shaft current discharges and then to failure modes have to be well identified in order to estimate the potential of existing tools for diagnosing such faults. Several diagnostic methods exist in the literature. Some models are based on failure propagation analysis at a system level, such as Failure Mechanisms and Symptoms Analysis (FMSA), proposed by Amyot et al. in 2007 [3]. This approach identifies all possible failure mechanisms of a system as a discretized causal graph using physical states (nodes of the graph). Figure 1 shows four different failure mechanisms discretized from two root causes to three failure modes using nine physical states.

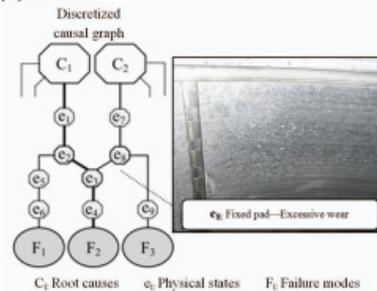


Fig. 1. Four active failure mechanisms leading from root causes to failure modes after discretization by physical states [4].

Each physical state can be activated by a unique combination of symptoms retrieved from a diagnostic database. It is then possible to identify the active failure mechanisms based on the active physical states. This approach is usually used for complex systems and help to efficiently capture expert knowledge and experience feedback in a suitable structure. A recent methodology has been proposed to construct a causal graph based on FMEA and expert knowledge [4]. Other authors have proposed related approaches based on graph theories, such as Fault Tree Analysis [5], the Petri Net model or Bayesian networks [6, 7]. A review on this subject has been done by Ran Cao et al. [8].

Based on existing diagnostic approaches described below, this contribution proposes a way to select a suitable

This work was supported in part by the Institut de Recherche d'Hydro-Québec (IREQ), Hydro-Québec and the Ecole de Technologie Supérieure (ETS).

O. Blancke and K. Al-Haddad are with ETS, 1100 Rue Notre-Dame Ouest, Montréal, Canada (e-mail: olivier.blancke.1@ens.etsmtl.ca, Kamal.Al-Haddad@etsmtl.ca).

A. Merkhouf, C. Hudon and N. Amyot are with IREQ, 1800 Boul. Lionel-Boulet, Varennes, Canada (e-mail: arezki.merkhouf@ireq.ca, hudon.claude@ireq.ca, amyot.normand@ireq.ca).

J. Pedneault-Desroches is with Hydro-Québec, 75 Boul. René-Lévesque Ouest, 11e étage, Montréal, Canada (e-mail: Pedneault-Desroches.Joel@hydro.qc.ca).



## BIBLIOGRAPHIE

- Abdelwahed, S., & Karsai, G. (2009). *Failure Prognosis Using Timed Failure Propagation Graphs*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, San Diego, CA, US.
- Aizpurua, J. I., & Catterson, V. M. (2015). *Towards a Methodology for Design of Prognostic Systems*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, San Diego, CA, US.
- Ammour, R., Leclercq, E., Sanlaville, E., & Lefebvre, D. (2016). *Faults prognosis using partially observed stochastic Petri nets*. Paper presented at the Discrete Event Systems (WODES), 2016 13th International Workshop on.
- Amyot, N., Hudon, C., Lévesque, M., Bélec, M., Brabant, F., & Frenette, F.-X. (2013a). *A new prognostic approach for hydro-generator stator windings*. Paper presented at the Proceedings of the Annual Conference of the Prognostics and Health Management Society, Gaithersburg, MD, USA.
- Amyot, N., Hudon, C., Lévesque, M., Bélec, M., Brabant, F., & Frenette, F.-X. (2013b). *New Prognostic Approach for Hydro-generator Stator Windings*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, New Orleans, USA.
- Amyot, N., Hudon, C., Lévesque, M., Bélec, M., Brabant, F., & St-Louis, C. (2014). *Development of a Hydrogenerator Prognosis Approach*. *CIGRE*.
- Atamuradov, V., Medjaher, K., Dersin, P., Lamoureux, B., & Zerhouni, N. (2017a). *Prognostics and Health Management for Maintenance Practitioners-Review, Implementation and Tools Evaluation* (Vol. 8).
- Atamuradov, V., Medjaher, K., Dersin, P., Lamoureux, B., & Zerhouni, N. (2017b). *Prognostics and health management for maintenance practitioners - review, implementation and tools evaluation*. *International Journal of Prognostics and Health Management*, 8, 31.
- Aven, T. (2013). *A conceptual framework for linking risk and the elements of the data-information-knowledge-wisdom (DIKW) hierarchy*. *Reliability Engineering & System Safety*, 111, 30-36. doi:<https://doi.org/10.1016/j.ress.2012.09.014>
- Aven, T. (2016). *Risk assessment and risk management: Review of recent advances on their foundation*. *European Journal of Operational Research*, 253(1), 1-13.

- Aven, T., & Guikema, S. (2011). Whose uncertainty assessments (probability distributions) does a risk assessment report: the analysts' or the experts'? *Reliability Engineering & System Safety*, 96(10), 1257-1262. doi:<http://dx.doi.org/10.1016/j.ress.2011.05.001>
- Aven, T., & Zio, E. (2011). Some considerations on the treatment of uncertainties in risk assessment for practical decision making. *Reliability Engineering & System Safety*, 96(1), 64-74. doi:<http://dx.doi.org/10.1016/j.ress.2010.06.001>
- Baraldi, P., Cadini, F., Mangili, F., & Zio, E. (2013). Model-based and data-driven prognostics under different available information. *Probabilistic Engineering Mechanics*, 32, 66-79.
- Blancke, O., Amyot, N., Hudon, C., Lévesque, M., & Tahan, A. (2015). A new generic approach to convert FMEA in causal trees for the purpose of hydro-generator rotor failure mechanisms identification.
- Blancke, O., Komljenovic, D., Tahan, A., Amyot, N., Hudon, C., Boudreau, J.-F., & Lévesque, M. (2018). *From data to asset health management in the context of hydropower generation: A holistic concept*. Paper presented at the Engineering assets and Public infrastructures in the Age of Digitalization.
- Blancke, O., Tahan, A., Komljenovic, D., Amyot, N., Hudon, C., & Lévesque, M. (2016, 20-22 June 2016). *A hydrogenerator model-based failure detection framework to support asset management*. Paper presented at the 2016 IEEE International Conference on Prognostics and Health Management (ICPHM).
- Bontempi, G., & Flauder, M. (2019). From Dependency to Causality: A Machine Learning Approach. In *Cause Effect Pairs in Machine Learning* (pp. 301-320): Springer.
- BSI. (2004). BS ISO 13381 Surveillance et diagnostic des machines. In *Pronostic: B S I Standards*.
- Byington, C. S., Roemer, M. J., & Galie, T. (2002, 9-16 March 2002). *Prognostic enhancements to diagnostic systems for improved condition-based maintenance [military aircraft]*. Paper presented at the Proceedings, IEEE Aerospace Conference.
- Celaya, J. R., Saxena, A., & Goebel, K. (2012). *Uncertainty Representation and Interpretation in Model-based Prognostics Algorithms based on Kalman Filter Estimation*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, Minneapolis, Mi, US.
- Chemweno, P., Pintelon, L., Muchiri, P. N., & Van Horenbeek, A. (2018). Risk assessment methodologies in maintenance decision making: A review of dependability modelling approaches. *Reliability Engineering & System Safety*, 173, 64-77.

- Chiachío, J., Chiachío, M., Sankararaman, S., Saxena, A., & Goebel, K. (2015). Condition-based prediction of time-dependent reliability in composites. *Reliability Engineering & System Safety*, *142*, 134-147.
- Chiachío, J., Chiachío, M., Sankararaman, S., Saxena, A., & Goebel, K. (2015). Prognostics Design for Structural Health Management. In B. Diego Alexander Tibaduiza, M. Luis Eduardo, & R. Jose (Eds.), *Emerging Design Solutions in Structural Health Monitoring Systems* (pp. 234-273). Hershey, PA, USA: IGI Global.
- Chiachío, M., Chiachío, J., Sankararaman, S., Andrews, J., & Target:, P. (2017). *Integration of prognostics at a system level: a petri net approach*. Paper presented at the Annual Conference of the Prognostics and Health Management Society.
- Chiachío, M., Chiachío, J., Sankararaman, S., Goebel, K., & Andrews, J. (2017). A new algorithm for prognostics using Subset Simulation. *Reliability Engineering & System Safety*, *168*, 189-199.
- CIGRE. (2003). Hydrogenerator Failures - Results of Survey. *International Council on large Electric Systems (CIGRE)*, 129.
- Coble, J., Ramuhalli, P., Bond, L., Hines, J. W., & Upadhyaya, B. R. (2015). A review of prognostics and health management applications in nuclear power plants. *International Journal of Prognostics and Health Management*, *6*, 1-22.
- Cocheteux, P. (2010). *Contribution to proactive maintenance with the formalization of the prognostic process for industrial system performance*. Université Henri Poincaré - Nancy I, Retrieved from <https://tel.archives-ouvertes.fr/tel-00545249>
- Compare, M., Baraldi, P., Bani, I., Zio, E., & Mc Donnell, D. (2017). Development of a Bayesian multi-state degradation model for up-to-date reliability estimations of working industrial components. *Reliability Engineering & System Safety*, *166*, 25-40. doi:<http://dx.doi.org/10.1016/j.ress.2016.11.020>
- Corbetta, M., Sbarufatti, C., Manes, A., & Giglio, M. (2014). On dynamic state-space models for fatigue-induced structural degradation. *International Journal of Fatigue*, *61*, 202-219.
- Corbetta, M., Sbarufatti, C., Manes, A., & Giglio, M. (2015). Real-time prognosis of crack growth evolution using sequential Monte Carlo methods and statistical model parameters. *IEEE Transactions on Reliability*, *64*(2), 736-753.

- Daigle, M., Bregon, A., & Roychoudhury, I. (2012). *A Distributed Approach to System-Level Prognostics*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, Minneapolis, MI.
- Daigle, M., & Kulkarni, C. S. (2014, 1-8 March 2014). *A battery health monitoring framework for planetary rovers*. Paper presented at the Aerospace Conference, 2014 IEEE.
- Daigle, M., Saxena, A., & Goebel, K. (2012). *An Efficient Deterministic Approach to Model-based Prediction Uncertainty Estimation*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, Minneapolis, MI, US.
- Daigle, M. J., & Goebel, K. (2013). Model-Based Prognostics With Concurrent Damage Progression Processes. *Systems, Man, and Cybernetics: Systems, IEEE Transactions on*, 43(3), 535-546. doi:10.1109/TSMCA.2012.2207109
- Drucker, P. F. IVHM Assessment Metrics.
- Elattar, H. M., Elminir, H. K., & Riad, A. M. (2016). Prognostics: a literature review. *Complex & Intelligent Systems*, 2(2), 125-154. doi:10.1007/s40747-016-0019-3
- EPRI. (2002). *Reliability and Preventive Maintenance: Balancing Risk and Reliability: For Maintenance and Reliability Professionals at Nuclear Power Plants (1002936)*. Retrieved from Palo Alto, CA:
- Fink, O., Zio, E., & Weidmann, U. (2015). A Classification Framework for Predicting Components' Remaining Useful Life Based on Discrete-Event Diagnostic Data. *IEEE Transactions on Reliability*, 64(3), 1049-1056. doi:10.1109/TR.2015.2440531
- Garga, A. K., McClintic, K. T., Campbell, R. L., Chih-Chung, Y., Lebold, M. S., Hay, T. A., & Byington, C. S. (2001, 2001). *Hybrid reasoning for prognostic learning in CBM systems*. Paper presented at the Aerospace Conference, 2001, IEEE Proceedings.
- Goebel, K., Daigle, M., Saxena, A., Sankararaman, S., Roychoudhury, I., & Celaya, J. (2017). *Prognostics: NASA*.
- Goebel, K., Saxena, A., Saha, S., Saha, B., & Celaya, J. (2011). Prognostic Performance Metrics. *Machine Learning and Knowledge Discovery for Engineering Systems Health Management*, 147.
- Gomes, J. P. P., Rodrigues, L. R., Galvão, R. K. H., & Yoneyama, T. (2013). *System level RUL estimation for multiple-component systems*. Paper presented at the Proceedings of the 2013 Annual conference of the prognostics and health management society.

- Goode, K. B., Goode, J., & Roylance, B. J. (2000). *Plant machinery working life prediction method utilizing reliability and condition-monitoring data*. Paper presented at the Proceedings of the IMechE, Part E: Journal of Process Mechanical Engineering.
- Gordon, T. J. (1994). *The DELPHI Method*. Retrieved from
- Gu, J., & Pecht, M. (2008, 28-31 Jan. 2008). *Prognostics and health management using physics-of-failure*. Paper presented at the 2008 Annual Reliability and Maintainability Symposium.
- Gupta, J. S., Trinquier, C., Medjaher, K., & Zerhouni, N. (2015). *Continuous validation of the PHM function in aircraft industry*. Paper presented at the Reliability Systems Engineering (ICRSE), 2015 First International Conference on.
- Heng, A., Zhang, S., Tan, A. C. C., & Mathew, J. (2009). Rotating machinery prognostics: State of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*, 23(3), 724-739. doi:<http://dx.doi.org/10.1016/j.ymsp.2008.06.009>
- Hoffman, O. F., & Kaplan, S. (1999). Beyond the Domain of Direct Observation: How to Specify a Probability Distribution that Represents the “State of Knowledge” About Uncertain Inputs. *Risk Analysis*, 19(1), 131-134. doi:10.1111/j.1539-6924.1999.tb00394.x
- Hu, C., Youn, B. D., Wang, P., & Taek Yoon, J. (2012). Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life. *Reliability Engineering & System Safety*, 103, 120-135. doi:<https://doi.org/10.1016/j.res.2012.03.008>
- Hydro-Québec. (2017). Retrieved from <http://www.hydroquebec.com/about/>
- IAM. (2015). *Asset Management - an anatomy V3*. Retrieved from
- International Standard. (2012). ISO 13372 Condition monitoring and diagnostics of machines -- Vocabulary. In.
- International Standard. (2015). ISO 13381 Condition monitoring and diagnostics of machines -Prognostics. In.
- ISO. (2014). ISO 55000, 55001 and 55002 Asset Management Standards. In: BSI Standards.
- Javed, K., Gouriveau, R., & Zerhouni, N. (2017). State of the art and taxonomy of prognostics approaches, trends of prognostics applications and open issues towards maturity at different technology readiness levels. *Mechanical Systems and Signal Processing*, 94, 214-236. doi:<http://dx.doi.org/10.1016/j.ymsp.2017.01.050>

- Kacprzynski, G. J. (2006). *Sensor/model fusion for adaptive prognosis of structural corrosion damage*. Retrieved from
- Khorasgani, H., Biswas, G., & Sankararaman, S. (2016). Methodologies for system-level remaining useful life prediction. *Reliability Engineering & System Safety*, 154, 8-18. doi:<https://doi.org/10.1016/j.ress.2016.05.006>
- Kjaerulff, U. B., & Madsen, A. L. (2008). Bayesian networks and influence diagrams. *Springer Science+ Business Media*, 200, 114.
- Kong, H. B., Jo, S.-H., Jung, J. H., Ha, J. M., Shin, Y. C., Yoon, H., . . . Jeon, B. C. (2019). *A Hybrid Approach of Data-Driven and Physics-based Methods for Estimation and Prediction of Fatigue Crack Growth*. Paper presented at the Proceedings of the Annual Conference of the PHM Society.
- Kulkarni, C., Ceyla, J. R., Biswas, G., & Goebel, K. (2012). Physics based modeling and prognostics of electrolytic capacitors.
- Kulkarni, C. S., Biswas, G., Celaya, J. R., & Goebel, K. (2013). Physics based degradation models for electrolytic capacitor prognostics under thermal overstress conditions. *International Journal of Prognostics and Health Management*, 825.
- Kwon, D., Hodkiewicz, M. R., Fan, J., Shibutani, T., & Pecht, M. G. (2016). IoT-Based Prognostics and Systems Health Management for Industrial Applications. *IEEE Access*, 4, 3659-3670. doi:10.1109/ACCESS.2016.2587754
- Leao, B. P., & Yoneyama, T. (2013). *Performance Metrics in the Perspective of Prognosis Uncertainty*. Paper presented at the Annual Conference of the Prognostics and Health Management Society (PHM13), New Orleans, LA.
- Leng, S., Xu, Z., & Ma, H. J. C. A. I. J. o. N. S. (2019). Reconstructing directional causal networks with random forest: Causality meeting machine learning. 29(9), 093130.
- Levesque, M., Hudon, C., Belec, M., & David, E. (2009, May 31 2009-June 3 2009). *Measurements of slot partial discharges with an antenna during accelerated aging*. Paper presented at the 2009 IEEE Electrical Insulation Conference.
- Li, Y. Y., Chen, Y., Yuan, Z. H., Tang, N., & Kang, R. (2017). Reliability analysis of multi-state systems subject to failure mechanism dependence based on a combination method. *Reliability Engineering & System Safety*, 166, 109-123. doi:<http://dx.doi.org/10.1016/j.ress.2016.11.007>

- Liang, T., Kacprzyński, G. J., Goebel, K., & Vachtsevanos, G. (2009, 7-14 March 2009). *Methodologies for uncertainty management in prognostics*. Paper presented at the Aerospace conference, 2009 IEEE.
- Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, *108*, 33-47. doi:<https://doi.org/10.1016/j.ymssp.2018.02.016>
- Medina-Olivier, G., Iung, B., Barbera, L., Viveros, P., & Ruin, T. (2012). *Root cause analysis to identify physical causes*. Paper presented at the 11th International Probabilistic Safety Assessment and Management Conference and The Annual European and Safety and Reliability Conference, Helsinki, Finland.
- Medjaher, K., Moya, J. Y., & Zerhouni, N. (2009). Failure prognostic by using Dynamic Bayesian Networks. *IFAC Proceedings Volumes*, *42(5)*, 257-262. doi:<http://dx.doi.org/10.3182/20090610-3-IT-4004.00049>
- Mooney, T. (2015). *A Systems Approach To PHM*. Paper presented at the Annual Conference of the Prognostics and Health Management Society, San Diego, CA, US.
- Murata, T. (1989). Petri nets: Properties, analysis and applications. *Proceedings of the IEEE*, *77(4)*, 541-580.
- NASA. (2004). *Development of an Expert Judgement Elicitation and Calibration Methodology for Risk Analysis in Conceptual Vehicle Design*. Retrieved from Hampton, VA, United States:
- Pecht, M. (1999). *Reliability, maintainability, and availability*: John Wiley and Sons, New York.
- Pecht, M., & Kumar, S. (2008). *Data analysis approach for system reliability, diagnostics and prognostics*. Paper presented at the Pan pacific microelectronics symposium, Kauai, Hawaii, USA.
- Peng, Y., Dong, M., & Zuo, M. J. J. T. I. J. o. A. M. T. (2010). Current status of machine prognostics in condition-based maintenance: a review. *50(1-4)*, 297-313.
- Peterson, J. L. (1981). Petri net theory and the modeling of systems.
- Petri, C. A. (1966). Communication with automata.

- Ragab, A., Ouali, M.-S., Yacout, S., & Osman, H. (2016). Remaining useful life prediction using prognostic methodology based on logical analysis of data and Kaplan–Meier estimation. *Journal of Intelligent Manufacturing*, 27(5), 943-958.
- Rausand, M., & Høyland, A. (2004). *System reliability theory: models, statistical methods, and applications* (Vol. 396): John Wiley & Sons.
- Ribot, P. (2009). *Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes*. Université Paul Sabatier - Toulouse III, Retrieved from <https://tel.archives-ouvertes.fr/tel-00450835>
- Rigdon, S. E., & Basu, A. P. (2000). *Statistical methods for the reliability of repairable systems*: Wiley New York.
- Runge, M. C., Converse, S. J., & Lyons, J. E. (2011). Which uncertainty? Using expert elicitation and expected value of information to design an adaptive program. *Biological Conservation*, 144(4), 1214-1223. doi:<http://dx.doi.org/10.1016/j.biocon.2010.12.020>
- Sankararaman, S. (2015). Significance, interpretation, and quantification of uncertainty in prognostics and remaining useful life prediction. *Mechanical Systems and Signal Processing*, 52–53, 228-247. doi:<http://dx.doi.org/10.1016/j.ymsp.2014.05.029>
- Sankararaman, S., Daigle, M. J., & Goebel, K. (2014). Uncertainty Quantification in Remaining Useful Life Prediction Using First-Order Reliability Methods. *Reliability, IEEE Transactions on*, 63(2), 603-619. doi:10.1109/TR.2014.2313801
- Sankararaman, S., & Goebel, K. (2013). *Why is the Remaining Useful Life Prediction Uncertain?* Paper presented at the Annual Conference of the Prognostics and Health Management Society, New Orleans, US.
- Sankararaman, S., & Goebel, K. (2015). Uncertainty in Prognostics and Systems Health Management. *International Journal of Prognostics and Health Management*, 10.
- Sankararaman, S., Saxena, A., & Goebel, K. (2014). *Are Current Prognostic Performance Evaluation Practices Sufficient and Meaningful?* Paper presented at the Annual Conference of the Prognostics and Health Management Society, San Diego, CA, US.
- Saxena, A., Celaya, J., Saha, B., Saha, S., & Goebel, K. (2010). Metrics for offline evaluation of prognostic performance. *International Journal of Prognostics and Health Management*, 1(1), 4-23.

- Saxena, A., Roychoudhury, I., Celaya, J., Saha, B., Saha, S., & Goebel, K. (2012). Requirements flowdown for prognostics and health management. In *Infotech@ Aerospace 2012* (pp. 2554).
- Saxena, A., Sankararaman, S., & Goebel, K. (2014). *Performance evaluation for fleet-based and unit-based prognostic methods*. Paper presented at the Second European conference of the Prognostics and Health Management society.
- Schwabacher, M., & Goebel, K. (2007). *A survey of artificial intelligence for prognostics*. Paper presented at the Aaai fall symposium.
- Sharp, M. E. (2013). *Simple Metrics for Evaluating and Conveying Prognostic Model Performance To Users With Varied Backgrounds*. Paper presented at the Annual Conference of the Prognostics and Health Management Society (PHM13), New Orleans, LA.
- Si, X.-S., Wang, W., Hu, C.-H., & Zhou, D.-H. (2011). Remaining useful life estimation – A review on the statistical data driven approaches. *European Journal of Operational Research*, 213(1), 1-14. doi:<http://dx.doi.org/10.1016/j.ejor.2010.11.018>
- Sikorska, J. Z., Hodkiewicz, M., & Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25(5), 1803-1836. doi:<http://dx.doi.org/10.1016/j.ymsp.2010.11.018>
- Simola, K., Mengolini, A., & Bolado-Lavin, R. (2005). *Formal Expert Judgement An Overview* (EUR 21772 EN). Retrieved from
- Simola, K., Mengolini, A., Bolado-Lavin, R., & Gandossi, L. (2005). *Traning Material for Formal Expert Judgement*. Retrieved from
- Son, J., Zhou, Q., Zhou, S., Mao, X., & Salman, M. (2013). Evaluation and comparison of mixed effects model based prognosis for hard failure. *IEEE Transactions on Reliability*, 62(2), 379-394.
- Straub, D. (2014). Value of information analysis with structural reliability methods. *Structural Safety*, 49, 75-85. doi:<http://dx.doi.org/10.1016/j.strusafe.2013.08.006>
- Swanson, D. C., Michael Spencer, J., & Arzoumanian, S. H. (2000). PROGNOSTIC MODELLING OF CRACK GROWTH IN A TENSIONED STEEL BAND. *Mechanical Systems and Signal Processing*, 14(5), 789-803. doi:<http://dx.doi.org/10.1006/mssp.2000.1324>

- Tran, V. T., Thom Pham, H., Yang, B.-S., & Tien Nguyen, T. (2012). Machine performance degradation assessment and remaining useful life prediction using proportional hazard model and support vector machine. *Mechanical Systems and Signal Processing*, 32, 320-330. doi:<https://doi.org/10.1016/j.ymssp.2012.02.015>
- U.S. Regulatory Commission (NRC). (1997). *Recomandations for Probabilistic Sceismic Hazard Analysis: Guidance on Uncertainty and Use of Experts (NUREG/CR-6372)*. Retrieved from Livermore, CA
- Vachtsevanos, G., Lewis, F., Roemer, M., Hess, A., & Wu, B. (2007). *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*: John Wiley & Sons, Inc.
- Wang, W., Di Maio, F., & Zio, E. (2016). Component- and system-level degradation modeling of digital Instrumentation and Control systems based on a Multi-State Physics Modeling Approach. *Annals of Nuclear Energy*, 95, 135-147. doi:<http://dx.doi.org/10.1016/j.anucene.2016.05.006>
- Wang, W., Maio, F. D., & Zio, E. (2017). Three-loop Monte Carlo simulation approach to Multi-State Physics Modeling for system reliability assessment. *Reliability Engineering & System Safety*, 167, 276-289. doi:<http://dx.doi.org/10.1016/j.res.2017.06.003>
- Yucesan, Y. A., & Viana, F. A. (2019). *Wind Turbine Main Bearing Fatigue Life Estimation with Physics-informed Neural Networks*. Paper presented at the Proceedings of the Annual Conference of the PHM Society.
- Zeng, Z., Chen, Y., Zio, E., & Kang, R. (2017). A compositional method to model dependent failure behavior based on PoF models. *Chinese Journal of Aeronautics*. doi:<http://dx.doi.org/10.1016/j.cja.2017.05.009>
- Zheng, N.-n., Liu, Z.-y., Ren, P.-j., Ma, Y.-q., Chen, S.-t., Yu, S.-y., . . . Engineering, E. (2017). Hybrid-augmented intelligence: collaboration and cognition. *18*(2), 153-179.
- Zhou, Y., Bo, J., Jie, Z., & Mingwei, G. (2013, 16-17 Jan. 2013). *Performance Metrics Assessment Method on Aircraft Prognostics and Health Management*. Paper presented at the 2013 Fifth International Conference on Measuring Technology and Mechatronics Automation.
- Zhouhang, W., Maen, A., & H., K. A. (2014). Coloured stochastic Petri nets modelling for the reliability and maintenance analysis of multi-state multi-unit systems. *Journal of Manufacturing Technology Management*, 25(4), 476-490. doi:doi:10.1108/JMTM-04-2013-0045