

**ÉCOLE DOCTORALE MATHÉMATIQUES, INFORMATIQUE,
PHYSIQUE THÉORIQUE ET INGÉNIERIE DES SYSTÈMES**

LABORATOIRE PRISME

THÈSE présentée par :

Toufik AGGAB

soutenue le : **12 Décembre 2016**

pour obtenir le grade de : **Docteur de l'université d'Orléans**

Discipline/ : **SCIENCES ET TECHNOLOGIES INDUSTRIELLES**

Pronostic des systèmes complexes par l'utilisation conjointe de
modèle de Markov caché et d'observateur

THÈSE dirigé par :

Frédéric KRATZ

Professeur des Universités, INSA Centre Val de Loire

RAPPORTEURS :

Zohra CHERFI-BOULANGER

Professeur des Universités, Université de Technologie de
Compiègne

Eric LEVRAT

Professeur des Universités, Université de Lorraine

JURY :

Jean-Marc THIRIET

Professeur des Universités, Université Joseph Fourier

Zohra CHERFI-BOULANGER

Professeur des Universités, Université de Technologie de
Compiègne

Eric LEVRAT

Professeur des Universités, Université de Lorraine

Olaf MALASSE

Maître de Conférences, Arts et Métiers ParisTech

Gérard POISSON

Professeur des Universités, Université d'Orléans

Frédéric KRATZ

Professeur des Universités, INSA Centre Val de Loire

Manuel AVILA

Maître de Conférences, Université d'Orléans

Pascal VRIGNAT

Maître de Conférences, Université d'Orléans

Remerciements

Je tiens à adresser mes sincères remerciements à tous ceux qui m'ont aidé et contribué à l'aboutissement de cette thèse, et tout particulièrement :

Monsieur Jean-Marc THIRIET, Professeur des Universités à l'Université Joseph Fourier pour l'honneur qu'il m'a fait en acceptant de présider le jury de soutenance.

Madame Zohra CHERFI-BOULANGER, Professeur des Universités à l'Université de Technologie de Compiègne, Monsieur Eric LEVRAT, Professeur des Universités à l'Université de Lorraine d'avoir accepté de rapporter ce travail. Vos remarques pertinentes et vos conseils précieux m'ont beaucoup aidé à améliorer la qualité de ce travail.

Je remercie Monsieur Gérard POISSON, Professeur des Universités à l'Université d'Orléans et Monsieur Olaf MALASSE, Maître de conférences à Arts et Métiers ParisTech d'avoir accepté de faire partie de mon jury.

J'adresse ma gratitude à mon directeur de thèse Monsieur Frédéric KRATZ, Professeur des Universités à l'INSA Centre Val de Loire, pour ses nombreux conseils au cours de ses trois années de thèse, sa rigueur scientifique, sa gentillesse et son contact humain exceptionnel. Je remercie vivement Monsieur Manuel AVILA et Monsieur Pascal VRIGNAT mes Coencadrants de thèse, Maîtres de conférences à l'IUT de l'Indre, pour leur soutien et leur disponibilité. Je souhaite également les remercier pour la confiance dont ils ont fait preuve à mon égard.

Un grand merci à Christophe BARDET, Florent DUCULTY, Stéphane BEGOT, Jean-François MILLET, Bernard ROBLES et David DELOUCHE pour l'excellente ambiance.

Un grand merci à mes amis Djihad, Amine, Andong, Hakim, Bassem, Julien, Seddik, Nassim, Nabil.

Enfin, une pensée particulière pour mes parents, mes deux frères et mon neveu Yanis et mes nièces Rym et Lina.

Table des matières

Introduction générale	15
Terminologie	19
1 Étude bibliographique sur le diagnostic et le pronostic pour la maintenance	21
1.1 Introduction	23
1.2 Mécanismes de défaillance	23
1.2.1 Indicateur de dégradation	23
1.2.2 Niveau de dégradation	24
1.2.3 Modèles de durée de vie	24
1.2.4 Modèles à dégradation	25
1.3 Évolutions des stratégies de maintenance	29
1.3.1 Stratégie de maintenance	29
1.3.2 Différents types de maintenance	30
1.4 Concepts de diagnostic et de pronostic pour la maintenance	33
1.4.1 Méthodes de diagnostic	34
1.4.2 Méthodes de pronostic	38
1.5 Cadre de travail	45
1.5.1 Orientations de travail	45
1.5.2 Discussion	46
2 Estimation de l'état de santé	49
2.1 Introduction	51
2.2 Génération d'indicateur de dégradation	51
2.2.1 Motivation	51
2.2.2 Espace de parité	51
2.2.3 Estimation paramétrique	52
2.2.4 Observateurs	52
2.2.5 Evaluation des résidus	55
2.3 Modélisation par Modèle de Markov Caché	55
2.3.1 Motivation	55
2.3.2 Discrétisation	56
2.3.3 Modèle de Markov Caché	57
2.3.4 Extensions des MMCs	63
2.4 Approche d'estimation de l'état de santé	64
2.5 Illustration de l'approche	65
2.5.1 Description du système considéré	65
2.5.2 Comportement du système	68

2.5.3	Application de notre approche	70
2.6	Discussion	76
3	Pronostic de durée de vie	77
3.1	Introduction	79
3.2	Approches de pronostic	79
3.2.1	Approche de pronostic markovienne	79
3.2.2	Approche à base de modèles	82
3.3	Étapes de l'approche à base de modèles	83
3.3.1	Phase d'estimation	83
3.3.2	Phase de pronostic	83
3.4	Illustration des approches	89
3.4.1	Application de l'approche markovienne	89
3.4.2	Application de l'approche à base de modèles	94
3.5	Discussion	104
4	Application des approches de pronostic à une machine asynchrone et une batterie	105
4.1	Introduction	107
4.2	Pronostic de la durée de vie d'une machine asynchrone	107
4.2.1	Modèle général de défauts de la machine asynchrone	107
4.2.2	Modélisation de l'observateur	111
4.2.3	Application de l'approche markovienne pour le pronostic	114
4.3	Pronostic de la durée de vie d'une batterie Li-ion	119
4.3.1	Modélisation de la batterie	119
4.3.2	Application de l'approche à base de modèles	123
4.4	Conclusion	130
	Conclusion et perspectives	133
A	Algorithmes	139
A.1	Algorithmes de quantification	141
A.1.1	K-means	141
A.1.2	Algorithme LBG	141
A.2	Algorithmes de MMC	142
A.2.1	Algorithme de Baum-Welch	142
A.2.2	Algorithme de Viterbi	142
A.3	Algorithmes Metropolis-Hastings et Gibbs	143
A.3.1	Algorithme de Metropolis-Hastings	143
A.3.2	Algorithme de Gibbs	143

Table des figures

1	Usine 4.0 [Blanchet and Bergerried, 2014].	17
1.1	Modèle de durée de vie.	24
1.2	Modèle de dommage cumulé.	26
1.3	Trajectoires simulées par le processus de poisson d'intensité $\lambda = 1$	26
1.4	Modèle de dommage indépendant.	27
1.5	Modèle à dégradation continue.	27
1.6	Trajectoires simulées par le processus Gamma.	28
1.7	Trajectoires simulées par le processus Wiener.	29
1.8	Exemple de simulation d'un modèle de Markov à 4 états.	30
1.9	Classification des types de maintenance.	30
1.10	Architecture <i>OSA-CBM</i>	32
1.11	Cadre général de diagnostic-pronostic.	33
1.12	Diagnostic vs Pronostic.	34
1.13	Méthode fondée sur la connaissance.	34
1.14	Un système d'inférence floue.	35
1.15	Exemple d'une fonction floue définie par des règles Si-Alors entre deux entrées et une sortie.	35
1.16	Méthode orientée données.	36
1.17	Démarche à suivre pour la conception d'un processus de diagnostic par classification.	36
1.18	Méthode à base de modèle.	36
1.19	Différentes méthodes de pronostic.	38
1.20	Durées de vie des systèmes.	39
1.21	Loi de Weibull ajustée.	40
1.22	Durée de vie résiduelle.	40
1.23	Démarche de pronostic guidée par les données.	40
1.24	Exemple de pronostic basé sur la régression.	41
1.25	Exemple de pronostic basé sur un processus stochastique.	41
1.26	Exemple de pronostic à base d'apprentissage.	41
1.27	Longueur de la fissure vs indicateur de dégradation.	42
1.28	Raideur du ressort vs indicateur de dégradation.	42
1.29	Illustration de l'horizon de pronostic : (a) Horizon de pronostic basé sur des estimations ponctuelles (b) Mesure PH en fonction des densités de probabilité selon le critère β [Saxena et al., 2008].	43
1.30	Mesures de performance du pronostic : exactitude.	43
1.31	Mesures de performance du pronostic : précision et exactitude.	44
1.32	Schéma illustrant la mesure de l'exactitude relative.	44
1.33	Illustration de l'opportunité.	44

1.34	Comparaison de convergence pour trois méthodes de pronostic.	45
2.1	Schéma de principe de génération de résidus à base d'observateurs.	52
2.2	Diagramme structurel d'un observateur d'ordre plein.	54
2.3	Relations de dépendance entre les états cachés et les observations.	57
2.4	MMC avec 3 états et 5 observations discrètes.	58
2.5	Exemple d'un MMC ergodique.	59
2.6	Schéma d'un MMC gauche-droite.	60
2.7	Schéma d'un MMC de Bakis gauche-droite.	60
2.8	Différentes topologies d'un MMC multi-flux [Ling et al., 2009].	63
2.9	Phases de la démarche de modélisation.	65
2.10	Schéma-bloc général d'un système de contrôle-commande en boucle fermée. . . .	66
2.11	Système de régulation du niveau d'eau [Nguyen, 2015].	67
2.12	Une trajectoire du système de contrôle du niveau d'eau du réservoir jusqu'à la défaillance de la pompe : (a) la consigne, (b) le niveau d'eau du réservoir 2, (c) le niveau d'eau du réservoir 1, (d) la capacité de l'actionneur, (e) la valeur de commande appliquée sur l'actionneur et (f) le débit d'écoulement d'entrée correspondant	69
2.13	Erreurs d'estimation des niveaux d'eau sans bruit de mesure.	71
2.14	Erreurs d'estimation des niveaux d'eau avec présence de bruit de mesure.	71
2.15	Ensemble des (a) trajectoires des capacités simulées (b) les instants de défaillance et les valeurs de la moyenne de résidu correspondantes.	72
2.16	Evolution de la log-vraisemblance lors de l'apprentissage.	72
2.17	Evolution jusqu'à la défaillance (a) de la capacité de la pompe, (b) de la moyenne de résidu.	73
2.18	Evolution de (a) la séquence d'observations, (b) la probabilité (δ) et (c) la sé- quence d'états associée pour l'exemple avec K=3 (cas du MMC).	74
2.19	Evolution de (a) la probabilité (δ) et (b) la séquence d'états associée pour l'exemple avec K=7 (cas du MMC flou).	74
2.20	Evolution du niveau de dégradation pour l'exemple (a) MMC, (b) MMC flou. . .	75
2.21	Evolution de (a) la capacité de la pompe simulée et (b) la séquence d'états associée à la dégradation.	75
2.22	Evolution de (a) la capacité de la pompe simulée et (b) la séquence d'états associée à la dégradation.	76
3.1	Les différentes étapes adoptées pour le pronostic.	81
3.2	Architecture de pronostic à base de modèles.	82
3.3	Les variables considérées dans la phase de pronostic.	84
3.4	Principe de prédiction de la dynamique de paramètre.	84
3.5	Principe de la régression par SVM.	86
3.6	Architecture de ANFIS [Jang et al., 1997].	88
3.7	Les différentes étapes adoptées pour le pronostic.	90
3.8	L'ensemble des (a) trajectoires des capacités simulées et (b) instants versus résidu correspondant.	90
3.9	L'évolution (a) de la capacité de la pompe et (b) de la moyenne du résidu. . . .	91
3.10	Évolution de (a) la séquence d'états et (b) l'estimation de la durée de vie rési- duelle (MMC).	91

3.11	Évolution de (a) la séquence d'états et (b) l'estimation de la durée de vie résiduelle (MMC flou).	93
3.12	Contraintes sur la performance du système.	94
3.13	Erreur d'estimation sans bruit de mesure de (a) niveau d'eau du réservoir 2, (b) la capacité de la pompe.	95
3.14	Erreur d'estimation avec présence de bruit de mesure de (a) niveau d'eau du réservoir 2, (b) la capacité de la pompe.	96
3.15	Trajectoire de : (a) la consigne, (b) la capacité de la pompe, (c) le niveau d'eau du réservoir 2, (d) l'erreur d'estimation de niveau d'eau du réservoir 2 et (e) l'erreur d'estimation entre la capacité réelle et estimée après lissage.	97
3.16	Estimation des paramètres (MV).	98
3.17	Estimation de la RUL (MV).	98
3.18	Estimation des paramètres (non informative).	99
3.19	Estimation de la RUL (non informative).	99
3.20	Estimation des paramètres (informative).	100
3.21	Estimation de la RUL (informative).	100
3.22	Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (régression par SVM).	101
3.23	Estimation de la RUL (régression par SVM).	101
3.24	Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (ANFIS).	102
3.25	Estimation de la RUL (ANFIS).	103
4.1	Modèle de défauts stator/rotor de la machine asynchrone [Bachir et al., 2006].	108
4.2	L'évolution (a) de la vitesse, (b) du couple électromagnétique et (c) des courants dans les phases sans défauts.	110
4.3	L'évolution (a) de la vitesse, (b) de couple électromagnétique, (c) du courant de phase I_a et (d) de spectre de phase (a) pour un défaut statorique.	111
4.4	L'évolution (a) de la vitesse, (b) de couple électromagnétique, (c) du courant de phase I_a et (d) de spectre de la phase (a) pour un défaut rotorique.	112
4.5	Blocs de la structure utilisée.	113
4.6	Les évolutions réelles, estimées et l'erreur d'observation en absence de bruit de mesure pour (a) i_{α_s} et (b) la vitesse.	114
4.7	Les évolutions réelles, estimées et l'erreur d'observation avec un bruit de mesure pour (a) i_{α_s} et (b) la vitesse.	114
4.8	(a) Les dégradations de la première phase de l'ensemble de tests et (b) la répartition des défauts causant la défaillance de système	115
4.9	Les instants de défaillance et les valeurs de variance des résidus (a) i_α et (b) i_β correspondantes.	116
4.10	L'évolution (a) des différentes dégradations jusqu'à défaillance, (b) de la variance du résidu i_{α_s} et (c) de la variance du résidu i_{β_s} .	116
4.11	Evolutions (a) de la log vraisemblance et (b) des niveaux de dégradation pour l'exemple.	117
4.12	L'estimation du niveau de dégradation (a) MMC multi-flux et (b) MMC à flux unique pour l'exemple.	117
4.13	L'estimation de la RUL pour l'exemple.	118
4.14	Circuit électrique équivalent d'une batterie Li-ion.	120
4.15	(a) Courant, (b) tension de la batterie et (c) évolution de l'état de charge.	122

4.16	Tension en fonction (a) du temps et (b) de la capacité.	122
4.17	Evolution de (a) la durée de décharge sans et avec dégradation et (b) de la résistance R_s	124
4.18	(a) Évolution réelle et estimée de V_p , (b) erreur d'estimation de V_p , (c) Évolution réelle et estimée de R_s et (d) erreur d'estimation de R_s	125
4.19	Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (régression par SVM).	126
4.20	(a) Estimation de la RUL et (b) sa densité de probabilité (régression par SVM).	126
4.21	Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (prédiction par ANFIS).	127
4.22	(a) Estimation de la RUL et (b) sa densité de probabilité (prédiction par ANFIS).	127
4.23	Les étapes de l'approche hybride.	128
4.24	(a) Trajectoires de dégradation et (b) les durées dans les cycles.	129
4.25	Le résidu (a) sans dégradation et (b) avec dégradation.	129
4.26	Résultats de diagnostic et de pronostic en durée d'usage en utilisant (a) la ré- gression par SVM et (b) la prédiction par ANFIS.	130
4.27	Résultats de diagnostic et de pronostic en cycle de décharge/recharge en utilisant (a) la régression par SVM et (b) la prédiction par ANFIS	130

Liste des tableaux

1.1	Exemple de matrice de signatures.	37
2.1	Valeurs numériques des paramètres du modèle	68
2.2	Mesures de performance pour l'exemple.	73
2.3	Mesures de performance de l'approche.	73
3.1	Mesures de performance de pronostic pour l'exemple (MMC).	92
3.2	Mesures de performance de pronostic (MMC).	92
3.3	Robustesse de l'approche MMC	93
3.4	Mesures de performance pour l'exemple (MMC flou).	93
3.5	Mesures de performance (MMC flou).	93
3.6	Mesures de performance de pronostic (MV).	98
3.7	Mesures de performance de pronostic (non informative).	99
3.8	Mesures de performance de pronostic (non informative actualisée).	99
3.9	Mesures de performance de pronostic (informative).	100
3.10	Mesures de performance de pronostic (informative actualisée).	100
3.11	Mesures de performance de pronostic (régression par SVM).	102
3.12	Mesures de performance (ANFIS).	103
4.1	Valeurs numériques des paramètres.	110
4.2	Mesures de performance pour l'exemple.	117
4.3	Mesures de performance pour 100 partitionnements aléatoires	118
4.4	Mesures de performance pour l'exemple (MMC multi-flux).	118
4.5	Mesures de performance pour 100 partitionnements aléatoires.	119
4.6	Valeurs numériques des paramètres du modèle	121
4.7	Mesures de performance de pronostic (régression par SVM).	126
4.8	Mesures de performance de pronostic (prédiction par ANFIS).	128

Introduction générale

Nous sommes à l'aube d'une révolution majeure, porteuse de nombreuses innovations et créatrice d'une nouvelle dynamique de marché. Les changements concernent en premier lieu le paysage industriel, dans lequel l'usine devient autant une plate-forme du digital qu'un lieu de production (usine 4.0 ou usine de futur) (figure 1). En effet, dans un environnement d'une concurrence mondiale, pour rester compétitif, les industriels misent sur le développement et l'intégration rapide de nouvelles fonctionnalités offertes par les évolutions technologiques de l'information et de la communication. Cette mutation s'accompagne nécessairement de nouveaux enjeux liés à la maîtrise des systèmes industriels. La maintenance prévisionnelle joue un rôle majeur dans cette mutation des usines vers l'industrie du futur. Ce type de maintenance fournit une connaissance sur l'état de fonctionnement du système tout en prévoyant, une estimation de son état futur. L'arrêt de production non planifié est ainsi évité, permettant aux industriels d'augmenter la disponibilité de leurs outils de production et donc leur productivité.




FIGURE 1 – Usine 4.0 [Blanchet and Bergerried, 2014].

Cet état de fait a conduit les industriels à adopter de nouvelles stratégies de surveillance et de maintenance sur leurs processus en s'appuyant notamment sur des concepts développés par la communauté PHM « Prognostics and Health Management ». C'est dans ce contexte que les travaux présentés dans cette thèse portent sur le développement de nouvelles approches de diagnostic et de pronostic de défaillance des systèmes complexes. Les systèmes visés par nos travaux présentent la particularité d'une insuffisance d'instruments de mesures capables d'apporter des indications sur une dégradation potentielle.

Compte tenu de cette contrainte forte, la stratégie adoptée est basée sur l'utilisation d'observateurs de manière à fournir des indications sur la dégradation à travers la génération des résidus ou des informations relatives aux variables internes du système. Le formalisme de Modèle de Markov Caché a été également utilisé en raison de sa capacité à identifier, caractériser et prédire les modes de fonctionnement du système. À cela s'ajoutent des méthodes d'inférences

statistiques et des méthodes de prédiction de séries temporelles à base d'apprentissage.

Le manuscrit de thèse est structuré en quatre chapitres.

Le premier chapitre traite des problèmes associés au diagnostic et au pronostic pour la maintenance. Les différentes stratégies de maintenance utilisées dans le milieu industriel et l'intérêt de mettre en œuvre une stratégie de maintenance prévisionnelle sont décrits. Les concepts relatifs aux problèmes de diagnostic et de pronostic proposés dans la littérature sont également présentés. Le chapitre se termine par une présentation du cadre de travail et l'ensemble des hypothèses considérées.

Le deuxième chapitre est consacré au processus de diagnostic, en particulier à l'estimation de l'état de santé. Ce chapitre propose un cadre de modélisation de la dégradation en vue d'estimer l'état de santé d'un système. Le chapitre décrit les différentes étapes de l'approche adoptée. Cette approche s'appuie sur la construction d'indicateurs de dégradation à l'aide d'un observateur et la modélisation du comportement de la dégradation par l'utilisation des Modèles de Markov Cachés. La mise en œuvre de l'approche sur un système de régulation de niveau d'eau est exposée pour un Modèle de Markov Caché et son extension floue.

Le troisième chapitre concerne le processus de pronostic de défaillance. Dans sa première partie, l'extension de l'approche de diagnostic au pronostic est présentée. L'approche est dite « approche markovienne », elle exploite le résultat du diagnostic et les propriétés d'un Modèle de Markov afin d'estimer la durée de vie résiduelle du système. La seconde partie présente une approche qui exploite le modèle du comportement dite « approche à base de modèles ». Elle utilise un observateur associé à une technique de prédiction. En fonction de la structure du modèle de dégradation, des techniques d'inférences statistiques (la méthode de maximum de vraisemblance et l'estimation bayésienne) et des méthodes de prédiction de séries temporelles à base d'apprentissage (les machines à vecteurs de support et les réseaux de neurones adaptatifs) ont été illustrés. Les deux approches de pronostic sont illustrées sur des exemples de dégradations d'un système de régulation de niveau d'eau présenté au chapitre précédent.

Le quatrième chapitre est consacré à l'application des approches établies sur deux autres systèmes : une machine asynchrone et une batterie Li-ion. Nous montrons que notre travail peut s'étendre à des systèmes différents. La première partie est consacrée au diagnostic/pronostic de dégradation sur la machine asynchrone par l'approche markovienne. Pour cette application, l'approche utilise l'extension multi-flux du modèle de Markov car deux indicateurs de dégradation sont générés. La seconde partie concerne l'estimation de la durée de vie d'une batterie Li-Ion à l'aide de l'approche à base de modèles. Ce travail fait appel aux méthodes de prédiction de séries temporelles à base d'apprentissage pour lesquelles, aucune hypothèse sur la structure du modèle de dégradation n'est nécessaire. Cette seconde partie se termine par l'illustration d'un couplage de l'approche de diagnostic utilisant un observateur et un modèle de Markov avec l'approche de pronostic à base de modèles.

Terminologie

Dans cette partie, les termes liés au diagnostic/pronostic que nous sommes amenés à utiliser dans cette thèse sont définis. Les définitions ci-après sont extraites des références suivantes [Villemeur, 1988; Combacau, 1991; Toguyeni, 1992; Zemouri, 2003; Philippot, 2006; Derbel, 2009].

- Fonctionnement en mode normal : c’est l’état de fonctionnement lorsque les variables caractéristiques du système demeurent au voisinage de leurs valeurs nominales. Dans le cas contraire, le système est considéré en mode défaillant.
- Fonctionnement dégradé : le système remplit partiellement les exigences requises. Malgré l’absence de défaillances, les performances du système sont inférieures à celles attendues par l’exploitant. Cette dégradation progressive des performances du système est généralement due au vieillissement d’un ou plusieurs composants du système.
- Anomalie : c’est une déviation par rapport à ce qui est attendu. Une anomalie justifie une investigation qui peut déboucher sur la constatation d’une non conformité ou d’un défaut.
- Défaut : c’est une déviation du système par rapport à son comportement normal, qui ne l’empêche pas de remplir sa fonction. Un défaut est une anomalie qui concerne une ou plusieurs propriétés du système, pouvant aboutir à une défaillance et parfois même à une panne.
- Dégradation : c’est l’évolution du système vers des états moins performants au cours de sa vie. La dégradation peut être liée au temps, à la durée d’utilisation ou à une cause externe. La dégradation peut aboutir à une défaillance, quand les performances du système sont en dessous d’un seuil d’arrêt défini par les spécifications fonctionnelles.
- Défaillance : c’est une anomalie altérant ou empêchant l’aptitude d’un système à accomplir la fonction souhaitée. Une défaillance correspond à un passage d’un état à un autre, par opposition à une panne qui est un état. Elle peut se manifester par plusieurs symptômes appelés modes de défaillance.
- Panne : état d’un système inapte à accomplir une fonction requise, c’est la conséquence d’une défaillance affectant le système, aboutissant à une interruption permanente de sa capacité à remplir une fonction requise et pouvant provoquer son arrêt complet.
- Symptôme : c’est l’événement ou l’ensemble de données à travers lequel le système de supervision détecte et identifie le passage d’un mode de fonctionnement normal à un mode défaillant.

-
- Mode de défaillance : le système passe à ce mode suite à l'occurrence d'une ou plusieurs défaillances. Les conséquences de ces défaillances sur le système caractérisent le mode de défaillance. En effet, un système peut avoir plusieurs modes de défaillances, par contre, il admet un seul mode de bon fonctionnement.

Chapitre 1

Étude bibliographique sur le diagnostic et le pronostic pour la maintenance

1.1	Introduction	23
1.2	Mécanismes de défaillance	23
1.2.1	Indicateur de dégradation	23
1.2.2	Niveau de dégradation	24
1.2.3	Modèles de durée de vie	24
1.2.4	Modèles à dégradation	25
1.3	Évolutions des stratégies de maintenance	29
1.3.1	Stratégie de maintenance	29
1.3.2	Différents types de maintenance	30
1.4	Concepts de diagnostic et de pronostic pour la maintenance	33
1.4.1	Méthodes de diagnostic	34
1.4.2	Méthodes de pronostic	38
1.5	Cadre de travail	45
1.5.1	Orientations de travail	45
1.5.2	Discussion	46

1.1 Introduction

En raison de la complexité croissante des systèmes industriels et de la recherche récurrente d'une meilleure compétitivité, l'exigence vis-à-vis de l'activité de maintenance dans les entreprises tend à augmenter de manière significative. En effet, les pannes des systèmes, les pertes de production qui s'en suivent et la maintenance des installations ont de nos jours, un impact économique majeur dans les entreprises. Dans ces conditions, une amélioration particulière porte sur la manière d'appréhender les phénomènes de défaillance.

Ce chapitre présente les modèles de comportements possibles pouvant mener à la défaillance. Il identifie l'émergence de la stratégie de maintenance prévisionnelle et traite des concepts de diagnostic et de pronostic pour la maintenance. Les principales approches de diagnostic et de pronostic et leurs critères de performance sont également abordés. Ce chapitre se termine par la définition du cadre de travail de cette thèse.

1.2 Mécanismes de défaillance

Un système peut être affecté par différents mécanismes de défaillance engendrant l'altération ou la cessation de sa fonction. Ces mécanismes progressent en fonction du temps. Leurs lois de comportement peuvent être difficiles à identifier ou bien tellement complexes, qu'elles ne permettent pas le développement d'expressions analytiques. Dans la littérature, plusieurs auteurs ont présenté des classifications de ces mécanismes de défaillance [Rausand and Høyland, 2004; Deloux, 2008]. Ils les ont classifiés selon la cause (défaillance primaire, secondaire, ou due à une mauvaise commande), selon l'impact sur les performances du système (défaillance partielle ou complète), selon la détectabilité (défaillance apparente ou cachée) et selon l'évolution (défaillance graduelle (progressive) ou soudaine). Une présentation détaillée de toutes ces classifications peut être consultée dans les références citées. Nous nous limiterons dans cette thèse, à la description de la classification selon l'évolution de la défaillance : les modèles de durée de vie et les modèles de dégradation. Avant de procéder à la description des classes citées, nous proposons d'introduire les notions d'indicateur et de niveau de dégradation.

1.2.1 Indicateur de dégradation

Les indicateurs de dégradation sont des variables porteuses de la dynamique d'un ou plusieurs modes de dégradation/défaillance. Ils s'appuient sur des observations quantifiables pouvant être évaluées. Ces indicateurs peuvent être associés à des caractéristiques physiques de la dégradation, observées de façon directe (e.g. allongement de la courroie, longueur d'une fissure...) ou être des phénomènes induits par des modes de dégradation (symptômes) observés indirectement (e.g. vibrations, échauffement d'un moteur...). Toutefois, dans certains cas, les observations disponibles ne sont pas forcément pertinentes pour la surveillance de l'état de dégradation du système. Pour y remédier, des méthodes de diagnostic/pronostic (décrites dans la section 1.4) sont utilisées. Des stratégies d'ajout de capteurs et/ou amélioration d'une ou plusieurs partie(s) du système peuvent être également mises en œuvre [Cocheteux, 2010].

1.2.2 Niveau de dégradation

Le mécanisme de défaillance peut être représentée comme la succession de passages par différents niveaux de dégradation. Ces niveaux représentent l'état de santé du système. La transition entre deux niveaux successifs traduit l'aggravation de la dégradation. Par conséquent, à chaque transition de niveau, il existe un risque plus élevé d'apparition de la défaillance.

Suivant le mécanisme considéré et les données disponibles, la distinction peut être étendue à un nombre de niveaux plus important, ou réduite à un nombre plus faible. Cette caractéristique permet de ne pas exclure du champ d'études les dégradations continues (décrites dans la section 1.2.4) [Zille, 2009]. Les auteurs de [Welte, 2008; Vrignat et al., 2015] suggèrent dans leurs travaux que le nombre de quatre niveaux offre une bonne interprétation pour l'aide à la décision de maintenance. L'évolution des mécanismes de défaillance est soumise à plusieurs facteurs tels que, l'environnement opérationnel, les modes de fonctionnement... Dans les problèmes de modélisation, ils sont souvent considérés sous la forme de covariables [Singpurwalla, 1995; Bagdonavičius and Nikulin, 2000].

1.2.3 Modèles de durée de vie

Le modèle de durée de vie représente le cas d'une dégradation la plus simple. Le modèle est caractérisé par deux états : marche et défaillant (panne) (figure 1.1, page 24). Ces modèles sont largement utilisés dans la littérature [Proschan, 1996; Barlow and Proschan, 1975] et particulièrement appropriés pour modéliser des défaillances soudaines, pour lesquelles le passage de l'état de marche à l'état de panne est immédiat. Pour ces modèles, il est nécessaire de déterminer une loi de l'instant de défaillance qui peut être directement fonction de la durée de fonctionnement du système, nombre de sollicitation... On trouve dans le cadre des modèles de durée de vie des approches statistiques de type paramétrique, non-paramétrique et semi-paramétrique [Deloux, 2008]. La modélisation probabiliste associée au formalisme statistique permet de disposer d'un ensemble d'outils adaptés à ces types de problèmes d'estimation [Wolsztynski, 2006].




FIGURE 1.1 – Modèle de durée de vie.

- *L'approche paramétrique* implique la connaissance de la loi de probabilité réelle des observations, qui dépend d'un nombre fini de paramètres. L'avantage de cette approche est la simplicité attendue de la phase d'estimation ainsi que de l'obtention d'intervalles de confiance et de la construction de tests. Si la distribution énoncée est correcte alors les estimateurs obtenus sont plus efficaces que les estimateurs non paramétriques.
- *L'approche non-paramétrique* par opposition à l'approche paramétrique suppose que le modèle n'est pas décrit par un nombre fini de paramètres. Cette approche ne nécessite

aucune hypothèse quant à la loi de probabilité réelle des observations (toutes les distributions possibles sont autorisées). C'est son principal avantage. L'inconvénient d'une telle approche est dans certains cas, la nécessité de disposer d'un nombre important d'observations. Le problème de l'estimation d'un paramètre fonctionnel étant délicat puisqu'il appartient à un espace de dimension infinie.

- *L'approche semi-paramétrique* peut être vue comme un compromis entre les deux approches précédentes. La loi de probabilité réelle des observations est supposée appartenir à une classe de lois pour partie dépendante de paramètres et pour partie sous forme de fonction(s) non-paramétrique(s). De nombreux modèles semi-paramétriques sont appliqués dans différents domaines. L'un des plus utilisés en particulier pour des applications biomédicales est le modèle à risque proportionnel introduit par Cox en 1972 [Cox, 1992]. Ce modèle ne suppose aucune forme pour la distribution de la durée de vie.

1.2.4 Modèles à dégradation

Les modèles à dégradation sont les modèles pour lesquels sont rajoutés des états intermédiaires appelés “*états dégradés*” entre l'état optimal et l'état de panne [Huynh, 2011]. Les états dégradés permettent de transiter successivement entre ces deux états. La difficulté majeure réside dans la manière de représenter ces passages et ainsi, estimer à la fois les dates d'entrée et les durées passées dans ses différents états. Selon la nature du système, on distingue deux classes de dégradation : les modèles à dégradation discrète et les modèles à dégradation continue [Castanier, 2001]. Des modèles faisant intervenir les deux classes existent également.

Les modèles à dégradation discrète

Les modèles à dégradation discrète permettent de modéliser des dégradations de type choc. Le principe de la modélisation s'articule autour de la notion de dommage cumulé où le système passe d'un état à un autre par un incrément de type saut.

Les modèles de dommages peuvent être classés selon deux familles. D'une part, on recense les modèles de dommages cumulés standards. Dans ces modèles, le système est considéré défaillant lorsque la contribution des chocs atteint un seuil fixé. D'autre part, les modèles de dommages indépendants. Dans ces modèles, les chocs ne sont plus additifs. C'est-à-dire, les chocs ne génèrent aucun dommage à moins que leur intensité ne dépasse le seuil de défaillance [Nakagawa, 2007; Nachlas, 2005].

- *Modèle de dommage cumulé* : ce modèle porte aussi le nom de double processus stochastique ou processus de saut [Nakagawa, 2007]. Il décrit un phénomène qui se produit à des instants aléatoires t_j , $j = (1 : N)$, auxquels sont associées des amplitudes de choc X_j (figure 1.2, page 26), avec les hypothèses que $X_0 = 0$ et que les amplitudes X_j sont non négatives, indépendantes et identiquement distribuées. Le dommage total (Z) au temps t s'obtient par :

$$Z(t) = \sum_{j=0}^{N(t)} X_j \quad (1.1)$$

où $N(t)$ correspond au nombre d'événements de choc survenus avant l'instant t .

L'hypothèse la plus courante pour ce genre de modèle consiste à considérer que les chocs





FIGURE 1.2 – Modèle de dommage cumulé.

surviennent selon un processus de Poisson d'intensité λ [Chien and Sheu, 2006; Klutke and Yang, 2002] (figure 1.3, page 26). Lorsque cette intensité est définie comme une fonction du temps $\lambda(t)$, $t \geq 0$, on parle alors de processus de Poisson non homogène. Pour ce processus, les instants d'inter-occurrences ne sont généralement ni indépendants ni identiquement distribués.

FIGURE 1.3 – Trajectoires simulées par le processus de poisson d'intensité $\lambda = 1$.

- *Modèle de dommage indépendant* : la date de défaillance du système liée à ce modèle de dégradation correspond à la première occurrence d'un choc dont l'intensité dépasse un seuil fixé (figure 1.4, page 27). Un exemple d'application de ce type de modèle concerne les matériaux « fragiles » comme le verre qui se brise suite à un choc trop important ou les matériaux électriques qui deviennent défaillants suite à une surcharge [Letot, 2013]. Ce modèle de dommage est décrit par :

$$Z(t) = \min_j(t_j | X_j \geq \text{Seuil}) \quad (1.2)$$

Les modèles à dégradation continue

Les modèles à dégradation continue supposent la connaissance des lois des incréments de dégradation entre deux instants consécutifs. Ces modèles permettent de prédire le niveau de dégradation du système à tous les instants (figure 1.5, page 27). Pour une dégradation continue, le processus Gamma, le processus de Wiener et les modèles de Markov sont les plus utilisés.




FIGURE 1.4 – Modèle de dommage indépendant.




FIGURE 1.5 – Modèle à dégradation continue.

- *Processus Gamma* : ce modèle s'applique lorsque la dégradation est aléatoire et strictement monotone. Il est particulièrement adapté pour représenter l'évolution graduelle de la dégradation suite à une utilisation du système. Il peut être *stationnaire* ou *non-stationnaire*. Les propriétés fondamentales du processus Gamma dans le cas *stationnaire* sont les suivantes :

1. $G(0) = 0$ et $G(t) \in [0, +\infty[$, où $G(t)$ représente l'amplitude de dégradation ;
2. $G(t), t \geq 0$, est un processus continu à accroissements indépendants ;
3. Pour tout $t > 0$, $G(t)$ suit une distribution Gamma de paramètres de forme $\alpha > 0$ et d'échelle $\beta > 0$, c'est-à-dire que l'incrément de dégradation entre deux instants t et $(t + \Delta t)$ suit une loi Gamma $(\alpha \Delta t)$ dont la fonction de densité est :

$$f(x) = \frac{\beta^{(\alpha \Delta t)}}{\Gamma(\alpha \Delta t)} x^{(\alpha \Delta t)} e^{(-\frac{x}{\beta})} \quad (1.3)$$

avec $\Gamma(\alpha \Delta t) = \int_0^\infty x^{\alpha \Delta t - 1} e^{(-x)} dx$.

La figure 1.6, page 28 montre la réalisation de dix trajectoires d'un processus Gamma de paramètres $\alpha = 1$, $\beta = 1$ et $\Delta t = 1$.

Dans le cas *non stationnaire*, le processus permet de représenter une évolution plus complexe des dégradations. A la différence du cas *stationnaire* qui traite des dégradations




FIGURE 1.6 – Trajectoires simulées par le processus Gamma.

linéaires en moyenne, une fonction croissante continue $m(t)$ est utilisée comme paramètre de forme au lieu de α . La fonction de densité pour ce processus est la suivante :

$$f(x) = \frac{\beta^{m(t+\Delta t)-m(t)}}{\Gamma(m(t+\Delta t)-m(t))} x^{m(t+\Delta t)-m(t)-1} e^{-\frac{x}{\beta}}, \quad x \geq 0 \quad (1.4)$$

— *Processus Wiener* : ce processus décrit une trajectoire de dégradations à accroissements indépendants avec une tendance croissante (la probabilité de voir la dégradation décroître sur un intervalle est non nulle) [Whitmore, 1995]. On distingue les processus de Wiener de tendance *linéaire* et *non-linéaire*. Les propriétés qui caractérisent le processus de tendance *linéaire* sont les suivantes :

1. $W(0) = 0$ et $W(t) \in (0, +\infty)$, où $w(t)$ l'amplitude de dégradation ;
2. $W(t), t \geq 0$, est un processus continu à accroissements indépendants ;
3. Pour tout $t > 0$, $W(t)$ suit une distribution normale de moyenne $(m \Delta t)$ et d'écart type $\sigma\sqrt{\Delta t} > 0$, c'est-à-dire que l'incrément de dégradation entre deux instants t et $(t + \Delta t)$ suit une loi Normale $N(0, \sigma^2 \Delta t)$ de densité :

$$f(x) = \frac{1}{\sigma\sqrt{2\pi\Delta t}} e^{-\frac{(x-m\Delta t)^2}{2\sigma^2\Delta t}} \quad (1.5)$$

Un exemple de réalisation de dix trajectoires d'un processus Wiener de paramètres $m = 1$, $\sigma = 1$ et $\Delta t = 1$ est montré sur la figure 1.7, page 29.

De même que pour le processus Gamma *stationnaire*, ce processus traduit des dégradations linéaires en moyenne. Pour rendre ce processus *non-linéaire*, il est à nouveau nécessaire d'utiliser une fonction $m(t)$ croissante et d'opérer le remplacement de $m\Delta t$ par $(m(t+\Delta t) - m(t))$. La loi d'accroissement est alors une loi Normale $N(m(t+\Delta t) - m(t), \sigma^2 \Delta t)$ de densité :

$$f(x) = \frac{1}{\sigma\sqrt{2\pi\Delta t}} e^{-\frac{(x-(m(t+\Delta t)-m(t)))^2}{2\sigma^2\Delta t}} \quad (1.6)$$




FIGURE 1.7 – Trajectoires simulées par le processus Wiener.

- *Modèle de Markov* : c'est un système probabiliste à espace d'états fini qui respecte la propriété de Markov. En probabilité, un processus stochastique vérifie la propriété de Markov si et seulement si, la distribution conditionnelle de probabilité des états futurs, étant donnés les états passés et l'état présent, ne dépend en fait que de l'état présent et non pas des états passés (absence de mémoire). Lorsque les valeurs temporelles sont continues, on parle de processus de Markov. Dans le cas discret, on parle de chaîne de Markov. Dans ce processus, le système peut comporter n états distincts du niveau de dégradation (e.g. l'état 1 correspond à un équipement neuf ; l'état 2 correspond à un état légèrement dégradé ; ...) [Pijnenburg, 1991]. Le temps de séjour dans un état i donné suit une loi exponentielle de paramètre d'échelle λ_i . Les transitions d'un état vers un autre état sont représentées par une matrice dite de transition dont l'élément ij représente le passage de l'état i vers l'état j . Des variantes de ce modèle ont été développées pour mieux répondre aux besoins des analyses de fiabilité. Les processus de Markov cachés et les processus semi-Markov ont ainsi vu le jour.

La figure 1.8, page 30 peut être vue comme le comportement d'un modèle de Markov représentant un système à 4 niveaux sujet à des réparations (possibilité de transition vers des niveaux inférieurs).

1.3 Évolutions des stratégies de maintenance

1.3.1 Stratégie de maintenance

La norme NF EN 13306 (2001) [NFEN2001] définit la stratégie de maintenance comme étant « une méthode de management utilisée en vue d'atteindre les objectifs de maintenance ». Son rôle est d'assurer la pérennité des équipements, de diminuer les pannes et de réduire les coûts de révision et de remise en état, tout en intégrant les contraintes et les impacts des autres processus de l'entreprise (e.g. la production) ou des événements provenant de cas non envisagés ou non attendus.




FIGURE 1.8 – Exemple de simulation d'un modèle de Markov à 4 états.

1.3.2 Différents types de maintenance

Dans les entreprises, deux types de maintenance sont mis en œuvre généralement : la maintenance corrective et la maintenance préventive. La maintenance corrective est celle effectuée lorsque la panne est déjà présente et qu'il faut la réparer. La maintenance préventive est celle que l'on planifie pour prévenir les défaillances. Les deux types en fonction de l'état du système sont illustrés sur la figure 1.9, page 30. Chaque type et son mode d'application sont détaillés par la suite.




FIGURE 1.9 – Classification des types de maintenance.

Maintenance corrective

Selon la norme [NFEN2001], la maintenance corrective est : « *une maintenance exécutée après détection d'une panne et destinée à remettre un bien dans un état dans lequel il peut accomplir une fonction requise* ». On distingue la maintenance corrective palliative lorsque l'intervention a un caractère provisoire et la maintenance curative lorsque les travaux sont définitifs.

Maintenance préventive

La définition donnée par la norme est : « *maintenance exécutée à des intervalles prédéterminés ou selon des critères prescrits et destinée à réduire la probabilité de défaillance ou la dégradation du fonctionnement d'un bien* ». On la retrouve sous quatre formes particulières qui sont :

- *La maintenance programmée*, définie par la norme comme étant « *la maintenance préventive exécutée selon un calendrier préétabli ou selon un nombre défini d'unités d'usage* ».
- *La maintenance systématique*, définie par la norme comme étant « *la maintenance préventive exécutée à des intervalles de temps préétablis ou selon un nombre défini d'unités d'usage mais sans contrôle préalable de l'état du bien* ».
- *La maintenance conditionnelle* est subordonnée à l'apparition d'indices révélateurs de l'état du système. La norme la qualifie comme étant « *la maintenance préventive basée sur une surveillance du fonctionnement du bien et/ou des paramètres significatifs de ce fonctionnement intégrant les actions qui en découlent* ».
- *La maintenance prévisionnelle* qui, en se basant sur la surveillance de l'état du système et de la conduite d'analyses périodiques, permet de prédire l'évolution de la dégradation du système et ainsi la période d'intervention optimale. Elle est qualifiée par la norme comme étant « *la maintenance conditionnelle exécutée en suivant les prévisions extrapolées de l'analyse et de l'évaluation de paramètres significatifs de la dégradation du bien* ».

A ce stade, notre travail s'intégrera dans les stratégies de maintenance prévisionnelle. En effet, de nombreux auteurs ont mis en évidence que la maintenance prévisionnelle est la plus adaptée pour optimiser l'utilisation d'un système jusqu'au terme de sa vie utile [Leger, 1999]. L'ensemble des méthodes, des techniques et des procédures à mettre en œuvre pour réaliser une maintenance prévisionnelle efficace, prend en anglais le terme de *Health Management*. On rencontre également les acronymes *ISHM* pour *Integrated System Health Management* et *PHM* pour *Prognostic Health Management* [Patterson-Hine et al., 2005; Sandborn and Wilkinson, 2007; Scanff et al., 2007].

Dans le but de mettre en œuvre cette stratégie, plusieurs architectures ont été proposées, *OSA-CBM* (*Open System Architecture for Condition Based Maintenance*) [Lebold and Thurston, 2001], *PEDS* (*Prognostic Enhancements to Diagnostic Systems*) [Byington et al., 2002] et *ISPM* (*Integrated System of Proactive Maintenance*) [Muller, 2005]. Elles sont généralement constituées de plusieurs couches : de l'acquisition de données jusqu'à l'aide à la décision. Une correspondance entre les activités supportées par les couches des différentes architectures est dressée dans [Cocheteux, 2010]. Ces architectures sont différentes essentiellement du point de vue de la forme (locale, distribuée, nombre de couches). Dans l'ensemble, l'architecture propo-

sée par [Lebold and Thurston, 2001] et diffusée par le groupe *MIMOSA* s'avère fédératrice. Il s'agit de la *OSA-CBM*. Cette architecture est constituée de 7 couches fonctionnelles détaillées ci-après (figure 1.10, page 32) .




FIGURE 1.10 – Architecture *OSA-CBM*.

- *Acquisition de données (Data Acquisition layer)* : cette couche d'acquisition permet de convertir un signal délivré par un capteur ou un transducteur en un paramètre numérique représentant une quantité physique, auquel sont associées différentes informations (e.g. datation, données de calibration, configuration du capteur utilisé...).
- *Manipulation de données (Data Manipulation layer)* : cette couche analyse les signaux, effectue un calcul de descripteurs significatifs et réalise des traitements et transformations de signaux à partir de mesures brutes.
- *Surveillance de l'évolution des données (Condition Monitoring layer)* : cette couche extrait les données des couches d'acquisition de données et de manipulation de données afin de les comparer à des valeurs limites prédéfinies. Cette couche génère des alarmes ou des alertes lorsque les limites sont franchies.
- *Diagnostic (Health Assessment layer)* : cette couche d'évaluation de la santé réalise le diagnostic des fautes détectées, détermine l'état de santé courant du système surveillé et suggère les défaillances probables, en considérant l'ensemble des informations d'états.
- *Pronostic (Prognostic layer)* : cette couche détermine les états de santé et les modes de défaillances futurs à partir de l'évaluation de l'état de santé courant et de la projection de l'utilisation du système. Elle prédit la durée de vie résiduelle (RUL pour « Remaining Useful Life ») du système.
- *Aide à la décision (Decision Support layer)* : cette couche de génération de conseils fournit des informations sur des actions de maintenance nécessaires ou concernant des modifications opérationnelles à apporter afin d'optimiser la durée de vie du système. Elle exploite pour cela les données des couches de diagnostic et de pronostic.

- *Présentation (Presentation layer)* : cette couche est une interface permettant de présenter des données pertinentes issues des différentes couches. Elle doit fournir aux analystes les données nécessaires pour identifier, confirmer ou comprendre un état anormal. Par ailleurs, cette couche assure une transformation des données en une forme représentant clairement les informations nécessaires pour prendre des décisions sur les actions de maintenance à réaliser.

La mise en œuvre efficace d'une stratégie de maintenance prévisionnelle ne peut se faire que si les phénomènes de dégradation sont correctement appréhendés dans les différentes étapes. Dans cette thèse, on s'intéressera particulièrement aux processus de diagnostic et de pronostic de dégradation (*health assessment and prognostics layers*). Les deux processus sont primordiaux dans l'aide aux choix des décisions de maintenance [Byington et al., 2004; Camci et al., 2007], dans la mesure où ils permettent de déterminer dans quel état de fonctionnement le système évolue et de prévoir son état futur comme l'illustre la figure 1.11, page 33. Ces processus sont décrits et examinés dans la section suivante.




FIGURE 1.11 – Cadre général de diagnostic-pronostic.

1.4 Concepts de diagnostic et de pronostic pour la maintenance

Tout au long de sa mission, un système est sujet à dégradation dont l'évolution peut aboutir à l'apparition d'un mode de défaillance. Le processus de diagnostic intervient au moment de l'apparition d'un défaut ou d'une défaillance et dans l'intervalle de temps entre la défaillance du système et la défaillance des systèmes secondaires [Soualhi, 2013]. Il consiste à fournir de l'information sur l'état de santé du système. Le processus de pronostic pour sa part intervient dans l'intervalle entre l'apparition du défaut et la défaillance. Il consiste à prédire la durée de vie résiduelle du système en considérant les informations passées (historiques) et/ou présentes (état courant), voire futures (missions futures du système).

D'une manière générale, comme l'illustre la figure 1.12, page 34, le diagnostic est postérieur à l'apparition d'un défaut ou d'une défaillance sur le système alors que, le pronostic est antérieur à la survenue de la défaillance [Gucik-Derigny, 2011]. Une description des méthodes et outils de diagnostic et de pronostic est présentée ci-dessous.




FIGURE 1.12 – Diagnostic vs Pronostic.

1.4.1 Méthodes de diagnostic

Les méthodes développées pour traiter les problèmes de diagnostic peuvent être classées en trois grandes catégories [Ribot, 2009] : les méthodes basées sur la connaissance, les méthodes orientées données et les méthodes à base de modèle.

Méthodes basées sur la connaissance : ces méthodes exploitent la connaissance des experts sur le système, une connaissance acquise durant la phase de conception ou/et d'un historique des dysfonctionnements du système. Ces méthodes dites « systèmes experts » font principalement appel à l'intelligence artificielle [Verron, 2007; DePold and Gass, 1998]. La propriété principale d'un système expert est de pouvoir représenter et restituer les connaissances acquises par les experts. Il comporte deux parties indépendantes (figure 1.13, page 34) : une base de connaissances composée d'une base de règles qui modélise la connaissance sur le système et d'une base de faits qui contient les informations concernant le système traité. La seconde partie est un moteur d'inférence capable de raisonner à partir des informations contenues dans la base de connaissances, de faire des déductions...

Pour avoir un modèle mathématique robuste permettant de prendre en compte les imperfections et les incertitudes, la logique floue est très utilisée [Lolas et al., 2007; Sazonov et al., 2002]. Combinée avec des méthodes de simulation, elle offre un compromis raisonnable entre les modèles analytiques rigoureux et les simulations purement qualitatives.




FIGURE 1.13 – Méthode fondée sur la connaissance.

Un exemple de système expert basé sur un système d'inférence floue (SIF) est illustré par la figure 1.14, page 35. Le SIF comporte trois blocs. Un bloc de fuzzification qui transforme les valeurs numériques en degrés d'appartenance (μ). Un bloc moteur d'inférence constitué de l'ensemble des règles. Une règle est de la forme :

Si X_1 est A et X_2 est B et . . . **Alors** Y est C

Enfin, un bloc de défuzzification qui permet d'inférer une valeur nette à partir du résultat de l'agrégation des règles. L'expert intervient dans la construction des ensembles flous et des règles dans les zones pour lesquelles les données ne sont pas disponibles.




FIGURE 1.14 – Un système d'inférence floue.

La figure 1.15, page 35 montre un exemple de la surface de la variable de sortie définie par des règles floues entre deux entrées et une sortie.




FIGURE 1.15 – Exemple d'une fonction floue définie par des règles Si-Alors entre deux entrées et une sortie.

Méthodes orientées données : ces méthodes reposent uniquement sur l'analyse de données, généralement dénommées « observations ». Ces observations sont issues du système (historique de mesures ou mesures temps réel). La démarche consiste à associer un ensemble de mesures extraites du système à des états : modes de fonctionnements connus du système (figure 1.16, page 36). Le diagnostic orienté données fait appel à des méthodes statistiques [Kresta et al., 1991; Wise and Gallagher, 1996], des méthodes de classification [Soualhi et al., 2011; Ondel et al., 2006] et des méthodes basées sur l'intelligence artificielle [Yang, 2004; Hoskins et al., 1991].

Un exemple tridimensionnel pour 4 classes est proposé sur la figure 1.17, page 36. Ces classes contiennent l'information qui caractérise les états et les défaillances du système. Ainsi, le diagnostic peut se voir comme la tâche de classification d'une nouvelle observation dans l'une des classes du système.

Méthodes à base de modèle : ces méthodes exploitent les modèles physiques ou les modèles boîtes noires (modèles entrées/sorties). Le diagnostic à l'aide de ces méthodes consiste à gé-




FIGURE 1.16 – Méthode orientée données.




FIGURE 1.17 – Démarche à suivre pour la conception d'un processus de diagnostic par classification.

néraliser des indicateurs de présence de défauts dans le système que l'on appelle « résidus ». Ces derniers sont obtenus par la comparaison entre le comportement réel du système et celui estimé par le modèle (figure 1.18, page 36). Une valeur non nulle d'un résidu est interprétée comme une modification anormale (ou une déviation inacceptable) d'une propriété ou d'un paramètre caractéristique du système modélisé. Parmi les méthodes les plus utilisées, nous trouvons les méthodes à base d'observateurs [Hammouri et al., 1999; Frank, 1987], les méthodes à base d'espace de parité [Ding, 2008; Schwarte et al., 2004], et les méthodes basées sur l'estimation paramétrique [Baskiotis et al., 1979; Isermann, 1984].




FIGURE 1.18 – Méthode à base de modèle.

Pour localiser les défauts, deux approches de génération de résidus peuvent être utilisées : les résidus structurés et les résidus directionnels (propriétés géométriques) [Patton and Chen, 1997]. Les résidus structurés sont conçus pour que chaque résidu soit sensible à un sous ensemble de défauts connus et insensible aux autres défauts. Ainsi, certains résidus sont différents de zéro pour un défaut donné, alors que les autres résidus ont une valeur nulle. Le type de défaut peut alors être discriminé par une table nommée matrice de signatures (table 1.1, page 37),

traduisant l'impact des défauts sur les résidus.

TABLE 1.1 – Exemple de matrice de signatures.

	f_1	f_2	...	f_n
r_1	1	0	...	0
r_2	1	1	...	0
$\vdots$				
r_m	0	0	...	1

Pour cette matrice, le défaut f_1 impacte le résidu r_1 . Le résidu r_2 est quant à lui affecté par les deux défauts f_1 et f_2 .

Les résidus directionnels sont représentés sous la forme d'un vecteur de résidus orienté selon une direction particulière de l'espace des résidus. La direction prise par le vecteur de résidus permet de discriminer le type de défauts.

Le choix d'une méthode de diagnostic de défauts dépend de la nature de la connaissance disponible, de la présence de capteurs ou de modèles qui permettent de suivre l'état réel du système. Lorsque les modèles existant reflètent de façon précise le comportement du système, les méthodes à base de modèle sont privilégiées. En revanche, si le modèle du système est indisponible ou si la complexité du système le rend inexploitable, les méthodes orientées données offrent une alternative intéressante. Dans ce dernier cas, seule la disponibilité des données de mesure est nécessaire. Les méthodes basées sur la connaissance, quant à elles, ne nécessitent que les connaissances des experts. L'expérience dont dépendent ces méthodes est cependant difficile à acquérir. Si le système évolue, une nouvelle expertise est alors nécessaire. Les principaux critères permettant d'évaluer les performances d'un système de diagnostic selon [Dash and Venkatasubramanian, 2000; Venkatasubramanian et al., 2003] sont :

- *Détection et diagnostic rapide* : un diagnostic rapide et précis est un attribut important et hautement souhaité. Cependant, le défi réside dans le fait que la réponse rapide au diagnostic et la performance tolérable pendant le fonctionnement normal sont deux objectifs contradictoires (il faudra en effet se fixer un compromis entre le taux de fausses alarmes et celui de non-détection).
- *Isolabilité* : elle caractérise la capacité du diagnostic à remonter directement à l'origine du défaut. Une défaillance engendre souvent une cascade d'alarmes. Dans ces conditions, il peut être difficile de remonter à l'organe défaillant.
- *Robustesse* : elle peut être définie comme étant le rapport entre une sensibilité maximale vis-à-vis du défaut recherché et une sensibilité minimale vis-à-vis des autres perturbations (bruits de mesures, variations paramétriques, incertitudes de modélisation...).
- *Identification de nouveaux défauts* : elle consiste en la capacité à identifier et à caractériser les modes de fonctionnement du système et d'avertir l'utilisateur d'une éventuelle apparition d'un nouveau mode de fonctionnement.
- *Identification de défauts multiples* : la capacité d'identifier des défauts multiples est une exigence importante et difficile en raison du caractère interactif de la plupart des défauts.

- *Facilité d'exploitation* : l'origine du défaut doit être localisée. Le diagnostic doit également fournir des explications sur l'apparition et la propagation du défaut. Cela nécessite la capacité de raisonner sur les relations de type causes/effets.
- *Adaptabilité* : les conditions opérationnelles d'un système changent en raison des modifications des entrées (recettes de fabrication...) ou des modifications des conditions environnementales (changement de la qualité des matières premières). Le diagnostic doit être adaptable à ces changements.

D'autres critères sont à prendre en considération : les aspects temps réel sont par exemple prépondérants pour un système de diagnostic embarqué. De même, les coûts économiques vont conditionner la stratégie de diagnostic : le système nécessite-t-il des composants trop onéreux pour sa conception ? Le temps de développement est-il trop important ?

1.4.2 Méthodes de pronostic

Dans la littérature, de nombreuses classifications des méthodes et outils de pronostic de défaillance ont été proposées. Elles se différencient en matière du résultat attendu et de la nature des informations utilisées. Un résumé des différentes classifications est présenté dans [Sikorska et al., 2011]. Ceci étant, la distinction entre les classes n'est pas si évidente, par conséquent, les classifications doivent être associées aux explications des auteurs.

La classification des méthodes pour le pronostic selon la connaissance que l'on a sur le système est identique à celle des méthodes pour le diagnostic. La figure 1.19, page 38 illustre les trois classes de méthodes de pronostic qui reposent sur différents niveaux de connaissance disponible. Cette figure présente également l'étendue de leur domaine d'applications, leur complexité, précision et coût [Lebold and Thurston, 2001].




FIGURE 1.19 – Différentes méthodes de pronostic.

Méthodes basées sur l'expérience : ce sont des méthodes qui s'appuient sur la modélisation stochastique de la dégradation ou sur des modèles fiabilistes. Cette forme de modèle est la plus simple et ne nécessite que le retour d'expérience sur le comportement des systèmes dans des conditions opérationnelles similaires afin de déterminer la probabilité de défaillance sur un

horizon temporel. Les techniques utilisées sont principalement basées sur l'approche fiabiliste, sur les processus stochastiques et sur les systèmes experts [Clarotti et al., 2004; Jardine and Banjevic, 2005; DePold and Gass, 1998].

Un exemple de pronostic par une approche fiabiliste suivant la distribution de Weibull (adapté de [Letot, 2013]) est décrit ci-dessous. Pour cette distribution, la loi de fiabilité $R(t)$, la fonction de densité de défaillance $f(t)$ et le taux de défaillance $\lambda(t)$ sont :

$$R(t) = e^{-(\frac{t-\gamma}{\eta})^\beta} \quad (1.7)$$

$$f(t) = \frac{\beta}{\eta} \left(\frac{t-\gamma}{\eta}\right)^{\beta-1} e^{-(\frac{t-\gamma}{\eta})^\beta} \quad (1.8)$$

$$\lambda(t) = \frac{\beta}{\eta} \left(\frac{t-\gamma}{\eta}\right)^{\beta-1} \quad (1.9)$$

où β est un paramètre de forme, η est un paramètre d'échelle et γ un paramètre de décalage.

Supposons que l'on dispose des temps de défaillance de systèmes identiques ayant travaillé dans les mêmes conditions (figure 1.20, page 39).




FIGURE 1.20 – Durées de vie des systèmes.

L'ajustement de la loi de Weibull sur les durées de vie est représenté en rouge sur la figure 1.21, page 40. En vert sont représentées les courbes correspondant aux intervalles de confiance à 95%. La figure 1.22, page 40 représente l'évolution de la durée de vie résiduelle moyenne calculée par l'intégrale suivante :

$$MRL(t) = \frac{\int_t^\infty R(y)dy}{R(t)} \quad (1.10)$$

Il est à souligner que la durée de vie résiduelle obtenue est une durée générique (e.g. obtenue à partir d'un modèle). Pour le calcul de la durée de vie spécifique à un système, une méthode d'actualisation avec l'apport de nouvelles données au modèle a été présentée dans [Letot, 2013].

Méthodes guidées par les données : ces méthodes sont en pleines expansions. Elles exploitent des données directement mesurées sur le système ou calculées à partir de celles-ci [Si et al., 2011]. Ces données peuvent représenter l'état actuel et/ou l'état passé (historiques de




FIGURE 1.21 – Loi de Weibull ajustée.




FIGURE 1.22 – Durée de vie résiduelle.

mesures) du système. Leur force réside dans l'aptitude à apprendre (par les exemples) et à capturer les relations subtiles entre les données même si, ces relations sont inconnues ou difficiles à décrire (figure 1.23, page 40). Le pronostic est obtenu en utilisant des techniques d'apprentissage ou des techniques d'analyse de tendance [Greitzer and Pawlowski, 2002; Kacprzyński et al., 2002; Zemouri et al., 2003].




FIGURE 1.23 – Démarche de pronostic guidée par les données.

Certains principes des méthodes de pronostic guidées par les données sont maintenant illustrés. L'objectif de ces méthodes consiste à construire un modèle adapté aux données pour ensuite l'extrapoler afin de produire son évolution future. Les mesures (observations) sont représentées par des points et les modèles obtenus par les courbes.

La figure 1.24, page 41 présente le principe de pronostic par un modèle basé sur une régression et la figure 1.25, page 41 expose le principe par un processus stochastique (e.g. processus de Wiener). Pour les méthodes à base d'apprentissage, un exemple d'utilisation d'un modèle ANFIS (système d'inférence floue à base de réseaux de neurones adaptatif) est illustré dans la figure 1.26, page 41.

Méthodes basées sur un modèle : ces méthodes s'appuient sur des modèles issus des lois physiques ou des modèles de simulation (représentations mathématiques d'un mécanisme de dégradation construit par expérimentations). Leurs utilisations impliquent des connaissances spécifiques liées à la défaillance et au mode de fonctionnement du système analysé. Les modèles obtenus sont exploités pour représenter et suivre au cours du temps le comportement du système et de sa dégradation. Cette dernière est représentée par un ou plusieurs paramètres




FIGURE 1.24 – Exemple de pronostic basé sur la régression.




FIGURE 1.25 – Exemple de pronostic basé sur un processus stochastique.




FIGURE 1.26 – Exemple de pronostic à base d'apprentissage.

dont la variation influe sur la dynamique et le comportement global du système [Medjaher, 2014]. Chaque discipline scientifique possède ses propres mécanismes de dégradation et donc ses propres modèles.

A titre d'exemple d'application de ce type de techniques, on peut citer le pronostic basé sur un modèle physique appliqué pour la suspension d'un demi-véhicule pour différents profils de route [Luo et al., 2008]. L'approche repose sur la connaissance complète du modèle. La dégradation représentant la longueur de la fissure se propageant sur le ressort de la suspension n'était pas mesurable. Elle a été estimée au travers un indicateur de son effet (figures 1.27, 1.28, page 42). Dans l'objectif de prédire l'état de dégradation et sa variance selon le profil de route, un filtre de modèles multiples en interaction a été utilisé.

Comme pour le cas du diagnostic, il apparaît que le choix d'une méthode de pronostic adéquate dépend de contraintes classiques liées à la disponibilité des données et/ou connaissances, à la dynamique et à la complexité des systèmes réels, à la possibilité de mesures... Afin d'évaluer ces méthodes, des métriques de performances ont été exposées dans la littérature [Saxena et al., 2008, 2009; George et al., 2006; Dragomir et al., 2009; Laggoune et al., 2009; Nguyen, 2015]. Dans le cadre de notre travail, nous privilégions les mesures de performances liées à la procédure de caractérisation de la RUL. Pour un ensemble de N systèmes identiques dont les instants de défaillance sont connus, les métriques les plus utilisées se déclinent comme suit :





FIGURE 1.27 – Longueur de la fissure vs indicateur de dégradation. FIGURE 1.28 – Raideur du ressort vs indicateur de dégradation.

- *Horizon de pronostic (PH pour Prognostic Horizon)* : il se définit comme la durée écoulée depuis la date d'apparition d'un défaut jusqu'à ce que l'estimation de la RUL satisfasse pour la première fois un critère de performance donné. Le critère de performance peut être l'appartenance d'une estimation de la RUL (ponctuelle) à un intervalle déterminé autour de la RUL réelle par deux bornes α^- et α^+ qui sont définies par la constante α , ou encore l'aire de la densité de probabilité $\pi[r(i_\lambda)]_{\alpha^-}^{\alpha^+}$ de la RUL estimée recouvrant l'intervalle dépassant un seuil β . Le calcul et l'illustration (figure 1.29, page 43) de cette métrique pour les deux critères sont précisés ci-dessous.

$$PH = T_{failure} - T_i \quad (1.11)$$

Avec T_i le premier indice de temps pour lequel la RUL obtenue satisfait le critère choisi. Pour p l'ensemble des indices de temps pour lesquels l'estimation de la RUL est réalisée. Pour le premier critère, $T_i = T_{i_\alpha} = \min \{i | (i \in p) \wedge r(i) \in [RUL(i)]_{\alpha^-}^{\alpha^+}\}$ avec $[RUL(i)]_{\alpha^-}^{\alpha^+}$ l'intervalle α^- et α^+ autour de la RUL réelle. Dans le second critère, $T_i = T_{i_{\alpha\beta}} =$

$\min \{i | (i \in p) \wedge \pi[r(i)]_{\alpha^-}^{\alpha^+} \geq \beta\}$ avec β la densité de probabilité minimale acceptable et $\pi[r(i)]_{\alpha^-}^{\alpha^+}$ l'aire de la densité de probabilité à l'intérieur de l'intervalle α^- et α^+ .

Le critère utilisé dans cette thèse est le suivant [Medjaher et al., 2012] :

$$T_{i_\alpha} = \min \{i | (i \in p) \wedge r(i) \in [RUL(i)(1 - \alpha), RUL(i)(1 + \alpha)]\} \quad (1.12)$$

- *Exactitude $\alpha - \lambda$* : elle est définie comme une mesure de performance binaire qui évalue si à un instant donné (exprimé par le coefficient λ) un critère de performance (caractérisé par le paramètre α) est satisfait. L'idée est la même que précédemment à l'exception du critère de performance qui dépend de la date de pronostic. Elle est représentée par la figure 1.30, page 43.

$$Exactitude \alpha - \lambda = \begin{cases} 1 & \text{si } \pi[r(i_\lambda)]_{\alpha^-}^{\alpha^+} \geq \beta \\ 0 & \text{sinon} \end{cases} \quad (1.13)$$




FIGURE 1.29 – Illustration de l'horizon de pronostic : (a) Horizon de pronostic basé sur des estimations ponctuelles (b) Mesure PH en fonction des densités de probabilité selon le critère β [Saxena et al., 2008].




FIGURE 1.30 – Mesures de performance du pronostic : exactitude.

- *Précision* : c'est une mesure de dispersion des résultats de pronostic, elle permet d'évaluer la variabilité de l'écart entre l'estimation de la date de défaillance et la date réelle. Elle est calculée par l'équation (1.14).

$$Précision = \left(\frac{1}{N} \sum_{i=1}^N e^{\frac{R_i}{R_0}} \right) e^{\frac{\sigma_0^2}{\sigma^2}} \quad (1.14)$$

Avec : σ_0^2 et R_0 des facteurs de normalisation, R_i l'intervalle de confiance de l'estimation pour l' i ème système, et $\sigma^2 = \frac{1}{N} \sum_{i=1}^N (D_i - \bar{D})^2$ où $\bar{D} = \frac{1}{N} \sum_{i=1}^N (D_i)$ et $D_i = \left| \widehat{RUL}(i) - RUL(i) \right|$

- *Accuracy (exactitude)* : elle mesure l'écart entre la date de défaillance et la date réelle. Le calcul de cette métrique représente un point critique dans le processus de pronostic. Une valeur proche de zéro signifie que le pronostic est mauvais. Une valeur égale à 1 signifie que le pronostic est correct. La complémentarité de l'exactitude et de la précision est illustrée dans la figure 1.31, page 44.

$$Accuracy = \frac{1}{N} \sum_{i=1}^N e^{\frac{D_i}{D_0}} \quad (1.15)$$

avec $D_i = \left| \widehat{RUL}(i) - RUL(i) \right|$ et D_0 une constante de normalisation dont la valeur dé-

pend spécifiquement de l'application considérée.




FIGURE 1.31 – Mesures de performance du pronostic : précision et exactitude.

- *Exactitude relative* : elle se définit à chaque instant par la différence entre l'estimation réalisée et sa valeur réelle comme l'illustre la figure 1.32, page 44. Elle est donnée par la formule suivante :

$$RA_{(t)} = 1 - \frac{|\widehat{RUL}_{(t)} - RUL_{(t)}|}{RUL_{(t)}} \quad (1.16)$$




FIGURE 1.32 – Schéma illustrant la mesure de l'exactitude relative.

- *Opportunité (timeliness)* : elle représente la position relative de la fonction de densité de probabilité du modèle de pronostic par rapport à la date réelle de défaillance (figure 1.33, page 44). Les auteurs dans [Goebel and Bonissone, 2005] préconisent de définir des limites au plus tôt et au plus tard au-delà desquelles la valeur estimée doit être considérée comme inacceptable d'un point de vue performance. Ces deux limites sont la conséquence du non centrage systématique de l'erreur d'estimation par rapport à zéro.




FIGURE 1.33 – Illustration de l'opportunité.

- *Convergence* : c'est une métrique destinée à quantifier la vitesse de convergence d'une mesure M de pronostic (comme l'exactitude et la précision) au cours de l'estimation de la RUL. Elle est définie comme étant la distance entre l'origine et le centre de gravité de l'aire sous la courbe de la métrique mesurée. Elle est calculée par l'équation 1.17, page 45.

$$C_M = \sqrt{(x_c - t_p)^2 + y_c^2} \quad (1.17)$$

Avec C_M la distance euclidienne entre le centre de masse (x_c, y_c) et $(t_p, 0)$, $M(i)$ la mesure de pronostic jusqu'à l'indice de temps i et (x_c, y_c) le centre de masse de l'air sous la courbe C_{M_i} entre t_p et t_{EoUP} , défini comme suit :

$$x_c = \frac{\frac{1}{2} \sum_{i=p}^{EoUP} (t_{i+1}^2 - t_i^2) M(i)}{\sum_{i=p}^{EoUP} (t_{i+1} - t_i) M(i)} \quad \text{et} \quad y_c = \frac{\frac{1}{2} \sum_{i=p}^{EoUP} (t_{i+1} - t_i) M(i)}{\sum_{i=p}^{EoUP} (t_{i+1} - t_i) M(i)} \quad (1.18)$$

t_{EoUP} : l'indice de temps au-delà duquel, il n'est pas utile d'estimer une nouvelle fois la RUL car aucune action est possible avant l'instant de défaillance.




FIGURE 1.34 – Comparaison de convergence pour trois méthodes de pronostic.

1.5 Cadre de travail

1.5.1 Orientations de travail

Dans le cadre de la maintenance prévisionnelle, l'information sur l'état de santé courant du système et sa projection dans le futur est le support principal pour orienter le service de maintenance sur les interventions à effectuer. Cette mise à disposition de l'information est rendue possible par les processus de diagnostic et de pronostic. Par conséquent, nous avons choisi d'orienter nos travaux sur la conception d'une approche qui caractérise un couplage diagnostic-pronostic des dégradations. Cette approche doit permettre d'estimer l'état de santé courant et futur du système surveillé en cours de son fonctionnement. Les hypothèses majeures considérées dans nos travaux sont :

- La défaillance est progressive. Elle contraint le système à opérer en mode dégradé impliquant une baisse de performance. Nous considérerons une dégradation au niveau global, c'est-à-dire au niveau de la performance de la fonction du système et non au niveau des fonctions locales de ses composants. Cette considération limitera le processus de diagnostic qu'à l'estimation de l'état de santé.
- L'instrumentation disponible (mesures) sur le système est insuffisante pour déterminer un indicateur de dégradation et elle serait trop coûteuse à compléter.
- Les symptômes observés ne permettent pas l'évaluation de l'état de santé courant et passé du système.
- Les interventions de maintenance ne sont pas considérées pendant le pronostic. La dégradation est supposée aller jusqu'à son terme qui correspond à la défaillance du système.
- La formalisation du modèle de comportement du système est possible.

Bien que les travaux visent un grand éventail de systèmes, le type de système support considéré pour la mise en œuvre des approches développées est un système de contrôle en boucle fermée. Cette classe de systèmes joue un rôle important dans l'essor des systèmes technologiques de plus en plus complexes [Golnaraghi and Kuo, 2009]. L'application des approches pour deux autres systèmes qui sont une machine asynchrone et une batterie sera présentée dans le dernier chapitre.

1.5.2 Discussion

Une politique de maintenance prévisionnelle efficace doit conduire à une réduction des pertes engendrées par des indisponibilités de production. Son efficacité est fortement liée à sa faculté de caractériser l'état de santé courant (diagnostic) et futur (pronostic) du système. Pour cela, l'approche proposée doit être capable de :

1. Générer des données permettant de rendre compte de la dynamique de la dégradation. A partir des hypothèses formulées dans la section (1.5.1), nous avons privilégié de manière naturelle le recours à une méthode à base de modèles. En l'absence de dégradation sur le système, les résidus générés ont une valeur statistiquement nulle (hypothèses d'une modélisation parfaite et absence de bruits de mesure) et non nulle en présence de dégradations.
2. Modéliser les modes de dégradation du système et les représenter sous forme d'états, en utilisant les données disponibles. La stratégie adoptée est d'utiliser les vecteurs de résidus construits en vue de modéliser le mécanisme de dégradation. Ce point est capital car une mauvaise modélisation conduit à de mauvais résultats de diagnostic et de pronostic. L'outil de modélisation retenu dans cette thèse est un outil probabiliste/stochastique en l'occurrence, un Modèle de Markov Caché (MMC).
3. Estimer l'état de santé du système. C'est une étape primordiale car à ce stade, une décision sur l'action à mener peut-être prise. Le modèle obtenu dans l'étape de modélisation est utilisé dans cette partie pour suivre le comportement du système et détecter au plus tôt sa dégradation. Cette estimation est réalisée par des algorithmes adaptés.
4. Prédire la durée de vie résiduelle. Pour son estimation, nous avons fait appel à deux stratégies. Le choix de la stratégie est conditionné par la nature du modèle de comportement

du système disponible et la connaissance de la mission (conditions opérationnelles futures).

- La première stratégie dite « markovienne » exploite le MMC obtenu et les propriétés des Modèles de Markov.
- La deuxième stratégie fait appel à un estimateur et à des outils permettant la prédiction de l'évolution des paramètres affectés par la dégradation.

Le chapitre suivant se focalise sur la phase de diagnostic (Health assessment/estimation de l'état de santé). Cette phase englobe les objectifs de l'approche présentée au niveau des points (1-3). Elle est basée sur l'utilisation conjointe d'un observateur et d'un MMC.

Chapitre 2

Estimation de l'état de santé

2.1	Introduction	51
2.2	Génération d'indicateur de dégradation	51
2.2.1	Motivation	51
2.2.2	Espace de parité	51
2.2.3	Estimation paramétrique	52
2.2.4	Observateurs	52
2.2.5	Evaluation des résidus	55
2.3	Modélisation par Modèle de Markov Caché	55
2.3.1	Motivation	55
2.3.2	Discrétisation	56
2.3.3	Modèle de Markov Caché	57
2.3.4	Extensions des MMCs	63
2.4	Approche d'estimation de l'état de santé	64
2.5	Illustration de l'approche	65
2.5.1	Description du système considéré	65
2.5.2	Comportement du système	68
2.5.3	Application de notre approche	70
2.6	Discussion	76

2.1 Introduction

Ce chapitre est consacré à l'estimation de l'état de santé d'un système. La première partie expose les outils capables de générer des données permettant de rendre compte de la dynamique de la dégradation, en l'occurrence les outils permettant la génération de résidus. La seconde partie présente les Modèles de Markov Cachés (MMCs) et certaines de leurs extensions. La troisième partie présente l'approche adoptée pour l'évaluation continue de l'état de santé du système durant son utilisation. La dernière partie de ce chapitre se concentre sur la mise en œuvre de l'approche proposée sur un système de régulation du niveau d'eau.

2.2 Génération d'indicateur de dégradation

2.2.1 Motivation

Cette étape trouve son intérêt lorsque les grandeurs porteuses de la dynamique sont insuffisantes ou inexistantes (hypothèses formulées dans la section 1.5.1) pour des raisons d'encombrement, de non-accessibilité à la mesure... Son objectif est la génération d'un signal qui reflète l'effet des défauts dans le système. Le moyen d'obtention de ce signal tout en respectant les hypothèses formulées sur l'instrumentation est le recours aux méthodes à base de modèles [Isermann and Ballé, 1997; Cassar et al., 1994]. Le signal est le résidu généré à l'aide de ces méthodes. Nous allons décrire les méthodes les plus usuelles, en l'occurrence la méthode d'espace de parité, la méthode de l'estimation paramétrique et la méthode des observateurs avec un intérêt particulier pour cette dernière.

2.2.2 Espace de parité

L'approche par espace de parité exploite le modèle du système afin d'établir des Relations de Redondances Analytiques (RRA). Ces relations expriment les entrées et les sorties du système en éliminant les variables d'états inconnues (non observables) du modèle [Maquin et al., 1997]. De ce fait, les RRA permettent de vérifier directement la cohérence des entrées-sorties du système à partir de variables mesurables. Initialement, la méthode a été développée pour le cas des systèmes statiques [Potter and Sunman, 1977], puis généralisée aux systèmes dynamiques [Chow, 1980; Chow and Willsky, 1984]. Cette généralisation utilise la redondance temporelle, c'est-à-dire des relations faisant intervenir les valeurs des sorties des capteurs et des entrées des actionneurs à différents instants. La redondance fréquentielle est également utilisée [Ding and Frank, 1990]. La forme générique du vecteur de résidus $r(t)$ est donnée par l'équation (2.1). Le vecteur de résidus est fonction des signaux d'entrée $u(t)$ (vecteurs de commandes) et de sortie $y(t)$ (vecteur de mesures).

$$r(t) = \phi(u(t), y(t)) \quad (2.1)$$

Ces méthodes deviennent intéressantes dans le cas des systèmes complexes qui demandent une structure de modélisation fondée sur des modèles locaux qui décrivent les relations d'entrées-sorties des variables. Pour les défauts issus de dérives importantes sur les paramètres du système, cette méthode n'est pas appropriée. Pour plus de détails sur les travaux utilisant l'espace de parité, nous conseillons les lectures suivantes : [Chow and Willsky, 1984; Gertler and Kunwer, 1995; Patton, 1994; Frank, 1990; Desai and Ray, 1981].

2.2.3 Estimation paramétrique

Cette méthode repose sur le principe selon lequel les effets de l'apparition d'un défaut sur le système se répercutent sur ses l'estimation de ses paramètres physiques. Elle consiste à estimer en permanence un vecteur de paramètres fondé sur les signaux d'entrées-sorties du système lors de son fonctionnement. Le vecteur de résidus $r(t)$ est obtenu en faisant la différence entre les paramètres nominaux θ et les paramètres estimés $\hat{\theta}(t)$ (équation 2.2). Tout écart est considéré comme le symptôme de l'apparition d'un défaut [Balle and Isermann, 1998].

$$r(t) = \theta - \hat{\theta}(t) \quad (2.2)$$

Ces méthodes sont plutôt appliquées à des systèmes à faible nombre de variables pour lesquels des modèles relativement précis peuvent être définis. Pour des systèmes plus complexes, comportant un très grand nombre de variables et devant opérer avec différents modes de fonctionnement, leur utilisation est alors très difficile [Montmain, 1997]. Pour améliorer la qualité de l'estimation, notamment en présence de bruit de mesures, les méthodes de filtrage peuvent être exploitées. Les détails sur ces méthodes et leurs applications peuvent être consultés dans [Isermann, 1984; Bonavita et al., 1994; Le Letty, 1995].

2.2.4 Observateurs

L'approche par observateurs fait partie des approches les plus utilisées et étudiées parmi les méthodes de génération de résidus à base de modèle. La première approche a été proposée par Beard [Beard, 1971]. Le principe consiste à estimer une partie ou l'ensemble des grandeurs mesurables du système à surveiller. Les sorties réelles sont ensuite comparées aux sorties estimées. Le vecteur de résidus $r(t)$ correspond alors à la différence entre les valeurs des sorties observées sur le système $y(t)$ et les valeurs des sorties estimées par l'observateur $\hat{y}(t)$ (équation 2.3).

$$r(t) = y(t) - \hat{y}(t) \quad (2.3)$$

L'observateur revient alors à un modèle parallèle au système avec une contre-réaction qui pondère l'écart de sortie. Ce principe est illustré sur la figure 2.1, page 52.




FIGURE 2.1 – Schéma de principe de génération de résidus à base d'observateurs.

La mise en œuvre d'un observateur doit répondre à différentes contraintes.

Observabilité : *l'observabilité d'un système est la propriété qui permet de dire si l'état peut être déterminé uniquement à partir de la connaissance des signaux d'entrée et de sortie.* Cette notion est due à Kalman et est à la base avec la notion de commandabilité du développement de

la théorie moderne de contrôle [Kalman, 1959]. Dans le cas des systèmes linéaires, l'observabilité dépend exclusivement de la formulation du système. Elle est suffisante pour garantir l'existence d'un observateur à vitesse de convergence exponentielle et arbitrairement rapide [Luenberger, 1971]. Dans le cas des systèmes non linéaires, la notion d'observabilité est liée aux entrées (via la notion d'entrée uniforme) et aux conditions initiales (via la notion d'indiscernabilité). Les résultats classiques que l'on peut trouver dans la littérature sont rappelés ci-dessous [O'Reilly, 1983; Borne and Richard, 1992].

Observabilité des systèmes linéaires : considérons le système d'ordre n gouverné par la représentation d'état suivante :

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) \end{cases} \quad (2.4)$$

Avec $x(t) \in \mathbb{R}^n$, $u(t) \in \mathbb{R}^m$ et $y(t) \in \mathbb{R}^p$ représentant respectivement l'état, l'entrée et la sortie du système. Les matrices A , B et C ont des dimensions appropriées.

La matrice d'observabilité du système (2.4) est définie par :

$$O = \begin{pmatrix} C \\ CA \\ CA^2 \\ \vdots \\ CA^{n-1} \end{pmatrix} \quad (2.5)$$

Le système est observable, si le rang de la matrice d'observabilité O est égal à la dimension n de ce système (équation 2.6). Dans le cas où le rang de la matrice O est inférieur à n on parle alors, d'observabilité partielle.

$$\text{rang}(O) = n \quad (2.6)$$

Observabilité des systèmes non-linéaires : contrairement aux systèmes linéaires, le problème d'observation est compliqué car l'observabilité dépend de l'entrée appliquée. La notion d'observabilité est définie à partir de la notion d'indiscernabilité (d'indistinguabilité). On distingue l'observabilité globale de l'observabilité locale. Pour plus de détails, consulter [Bornard et al., 1993].

Considérons le système non-linéaire suivant :

$$\begin{cases} \dot{x}(t) = f(x, u) \\ y(t) = h(x) \end{cases} \quad (2.7)$$

- *Discernabilité* : deux états initiaux $x(t_0) = x_{01}$ et $x(t_0) = x_{02}$ tel que $x_{01} = x_{02}$ sont dits discernables pour le système (2.7), si $\forall t \geq t_0$, les sorties correspondantes $y_1(t)$ et $y_2(t)$ vérifient $y_1(t) \neq y_2(t)$.
- *Indiscernabilité* : deux états initiaux $x(t_0) = x_{01}$ et $x(t_0) = x_{02}$ tel que $x_{01} = x_{02}$ sont dits indiscernables pour le système (2.7), si $\forall t \geq t_0$, les sorties correspondantes $y_1(t)$ et $y_2(t)$ sont identiques.
- *Observabilité* : le système (2.7) est dit observable s'il n'admet aucune paire indiscernable.

Pour les systèmes non-linéaires, la notion d'observabilité locale faible a été introduite. Cette notion est assurée en faisant localiser l'indiscernabilité, ce qui garantit la distinguabilité de tout point par rapport à son voisinage. Cette caractérisation formelle de l'observabilité s'obtient à partir d'une condition de rang, analogue au cas des systèmes linéaires. On dit que la paire (f, h) est observable au sens du rang si :

$$\text{rang}(H(x)) = n \quad (2.8)$$

où $H(x)$ est appelée matrice d'observabilité locale pour le système (2.7).

$$H(x) = \begin{pmatrix} dh \\ dL_f h(x) \\ dL_f^2 h(x) \\ \vdots \\ dL_f^{n-1} h(x) \end{pmatrix} \quad (2.9)$$

$L_f h(x)$ est la dérivée de Lie de la fonction vectorielle h le long du champ vectoriel f et $dL_f h(x)$ représente le gradient $\frac{\partial L_f h(x)}{\partial x}$.

Synthèse d'observateurs : afin d'expliquer la procédure générale de la conception d'un observateur, nous allons détailler la construction d'un observateur d'ordre plein. Un observateur d'ordre plein permet de reconstruire entièrement le vecteur d'état $x(t)$ donné par $\hat{x}(t)$. Pour un système d'ordre n gouverné par la représentation d'état (2.4), la structure de l'observateur peut être représentée par la figure 2.2, page 54 et exprimée sous la forme suivante :

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + L(y(t) - \hat{y}(t)) \\ \hat{y}(t) = C\hat{x}(t) \end{cases} \quad (2.10)$$

Avec $x(t) \in \mathbb{R}^n$, $u(t) \in \mathbb{R}^m$ et $y(t) \in \mathbb{R}^n$ représentant respectivement l'état, l'entrée et la sortie du système. $\hat{x}(t) \in \mathbb{R}^n$ est l'estimation de $x(t)$.




FIGURE 2.2 – Diagramme structurel d'un observateur d'ordre plein.

Le terme correctif $L(y(t) - \hat{y}(t))$ fait apparaître le gain de correction L , également appelé gain de l'observateur, relatif à l'erreur de la reconstruction de la sortie.

Le système dynamique constituant l'observateur doit s'assurer que l'erreur de reconstruction tend asymptotiquement vers 0, c'est-à-dire :

$$\lim_{t \rightarrow \infty} (y(t) - \hat{y}(t)) = 0, \forall u(t), \forall x(0) \quad (2.11)$$

Le choix de la méthode de génération de résidus va dépendre du type de modèle disponible pour représenter le système mais aussi des types de défauts que l'on veut détecter (défauts additifs ou multiplicatifs, défauts multiples ou non). Une analyse comparative des avantages et des conditions d'application des différentes méthodes est présentée dans [Isermann, 2000].

2.2.5 Evaluation des résidus

Généralement, l'évaluation des résidus consiste en une prise de décision logique quant à l'instant d'apparition du défaut et de sa localisation. Un seul résidu suffit pour connaître l'existence d'un défaut dans le système. En revanche, plusieurs résidus sont nécessaires afin de trouver la cause du défaut [Gertler and Kunwer, 1995]. Ces résidus sont généralement à moyenne nulle et ont une variance déterminée en l'absence de défauts. En présence de défauts, le résidu ainsi formé s'écartera notablement de la valeur zéro.

Le système surveillé étant un système physique soumis à des perturbations inconnues et souvent aléatoires, les résidus sont considérés comme étant eux-mêmes des processus aléatoires soumis à des fluctuations non forcément associées à des défauts, ce qui influe sur les procédures de décision [Guernez Jean, 1998]. Par conséquent, la frontière entre ce qui peut être considéré comme un comportement normal et un comportement dégradé ou défaillant est assez souvent délicate à évaluer.

2.3 Modélisation par Modèle de Markov Caché

2.3.1 Motivation

Dans l'objectif d'estimer l'état de santé du système au travers des résidus, notre choix, comme nous l'avons précisé précédemment, s'est porté sur l'usage des MMCs. Le pouvoir de représentation de ce type de modèles permet en effet de discriminer les différents modes de fonctionnement à partir d'observations directement collectées sur le système (mesures physiques, recette de fabrication, consignation d'interventions de maintenance...). Les approches à base de MMC ont été développées et utilisées dans des champs disciplinaires variés. Dans les domaines de la surveillance et du diagnostic, nous citons : l'identification des types d'accidents dans une centrale nucléaire [Kwon and Kim, 1999], la surveillance de la boîte de vitesses d'hélicoptère [Bunks et al., 2000], la surveillance de l'usure d'un outil d'usinage [Ertunc et al., 2001], le diagnostic des défauts sur un rotor [Lee et al., 2004] et la détection et la reconnaissance de défauts dans les machines tournantes [Li et al., 2005].

Dans cette thèse, nous allons nous intéresser au MMC discret (les observations sont discrètes). Par conséquent, avant d'aborder la modélisation par les MMCs et les outils associés, nous décrirons brièvement les principales techniques appropriées pour le passage de l'espace d'observations de nature continue à l'espace d'observations discrètes. L'étape de discrétisation peut

s'effectuer de différentes manières [Dougherty et al., 1995; Kotsiantis and Kanellopoulos, 2006; Fayyad and Irani, 1993].

2.3.2 Discrétisation

Les techniques les plus simples sont celles de la quantification vectorielle (clustering en anglais). Construire un système de quantification vectorielle consiste à opérer une partition des données d'apprentissage en regroupant ces éléments de nature quantitative en un nombre de classes (groupes) possédant les propriétés suivantes :

- Homogénéité dans les classes : les données appartenant à la même classe doivent être les plus similaires possibles.
- Hétérogénéité entre classes : les données appartenant à la même classe doivent être différentes des données appartenant à d'autres classes.

Ces techniques font référence à la notion de mesure de similarité entre un vecteur de données et le centre du groupe. Les mesures de similarité les plus utilisées sont les mesures de distances. Une multitude de mesures sont présentées dans la littérature [Rifqi, 2010]. Nous exposons les mesures qui peuvent être utilisées dans les techniques qui seront présentées par la suite.

Mesures de similarité : soit $d(x, v_k)$ la mesure de distance entre le vecteur x et le centre v_k au sens d'une métrique.

La distance la plus connue est la distance Euclidienne. Elle est définie par :

$$d(x, v_k) = \sqrt{(x - v_k)^T(x - v_k)} = \|x - v_k\| \quad (2.12)$$

Le carré de cette distance est également souvent utilisé. La distance Euclidienne n'est qu'un cas particulier pour $p = 2$ de la distance de Minkowski. La distance de Minkowski est donnée comme suit :

$$d(x, v_k) = \sqrt[p]{|x - v_k|^p} \quad (2.13)$$

Pour $p = 1$, on obtient la distance de Manhattan (aussi appelée distance « city-block » ou métrique absolue) exprimée par :

$$d(x, v_k) = |x - v_k| \quad (2.14)$$

On trouve aussi la distance de Mahalanobis. Elle prend les covariances Σ en compte dans le calcul. Cette condition permet de prendre en compte la forme elliptique d'une distribution d'observations. Elle est exprimée par :

$$d(x, v_k) = \sqrt{(x - v_k)^T \Sigma^{-1} (x - v_k)} \quad (2.15)$$

Algorithmes : le premier algorithme pour la quantification est connue sous le nom de Lloyd [Lloyd, 1982]. Il fut utilisé pour la quantification scalaire. Cet algorithme a ensuite été généralisé pour la classification automatique et la reconnaissance des formes sous le nom d'algorithme de « K-means » ou méthode des « nuées dynamiques » [Diday and Simon, 1976]. Une variante très utilisée de l'algorithme de Lloyd est l'algorithme « LBG » [Linde et al., 1980]. Il procède hiérarchiquement et réalise une initialisation itérative au cours de sa construction. Il

existe d'autres extensions de l'algorithme « K-means », tel que l'algorithme « FCM » (Fuzzy C-means) [Bezdek, 2013] dans lequel, la notion d'ensemble flou est introduite dans la définition des classes. L'algorithme de « GK-means » (Gustafson-Kessel algorithm) [Gustafson and Kessel, 1978] quant à lui propose une mesure de distance adaptative sur la norme de Mahalanobis afin de détecter des classes avec des formes géométriques différentes. Une autre version est l'algorithme « PAM » (Partitioning Around Medoids) qui au lieu de calculer le centre suggère de calculer la médiane [Kaufman and Rousseeuw, 2009]. Les étapes des algorithmes « K-means » et « LBG » sont présentées respectivement dans les annexes (A.1.1, A.1.2).

À ce stade, le choix de la classe à laquelle appartient une observation est considéré selon la règle de la distance minimale (similarité maximale) représentée par la règle suivante :

$$r \in Cv_i \text{ si } d(r, v_i) = \min \{d(r, v_k), 1 \leq k \leq K\} \quad (2.16)$$

où Cv_i est la classe ayant pour centre v_i .

2.3.3 Modèle de Markov Caché

Un MMC correspond à la modélisation de deux processus stochastiques S et V [L. E. Baum, 1966] : le processus caché S parfaitement modélisé par un modèle de Markov et un processus observé V dépendant des états du processus caché.

Définition : Soit $\mathcal{S} = s_1, \dots, s_N$, l'ensemble des N états cachés du système. Soit $S = (S_1, \dots, S_T)$ un T -uple de v.a définies sur $\mathcal{S}$. Soit $\mathcal{V} = v_1, \dots, v_M$, l'ensemble des M observations discrètes. Soit $V = (V_1, \dots, V_T)$ un T -uple de v.a définies sur $\mathcal{V}$.

Un MMC est alors défini par les probabilités suivantes :

- Les probabilités d'initialisation des états : $P(S_1 = s_i)$,
- Les probabilités de transition entre états : $P(S_t = s_j | S_{t-1} = s_i)$,
- Les probabilités d'émission des observations par chaque état : $P(V_t = v_j | S_t = s_i)$.

On résume généralement ces propriétés par le graphe d'indépendance conditionnelle orienté comme ci-dessous :




FIGURE 2.3 – Relations de dépendance entre les états cachés et les observations.

D'une manière générale, un MMC est désigné par sa notation compacte λ paramétrée par :

- La matrice de probabilité de transition entre états $A = a_{i,j}$ telle que :

$$a_{i,j} = P(S_t = s_j | S_{t-1} = s_i) \text{ avec } a_{i,j} \geq 0, \sum_{j=1}^N a_{i,j} = 1, \forall i \in [1, N], \quad (2.17)$$

- La matrice de probabilité d'émission d'observations $B = b_i(j)$ qui exprime la distribution de probabilité des observations v_j à l'état s_i , avec :

$$b_{i,j} = P(V_t = v_j | S_t = s_i) \text{ avec } b_{i,j} \geq 0, \sum_{j=1}^M b_{i,j} = 1, \forall i \in [1, N], \quad (2.18)$$

- La loi initiale $\pi = (\pi_1, \dots, \pi_N)$ exprimée par :

$$\pi_i = P(S_1 = s_i) \text{ avec } \pi_i \geq 0, \sum_{i=1}^N \pi_i = 1, \forall i \in [1, N] \quad (2.19)$$

La figure 2.4, page 58 présente un exemple de MMC à 3 états avec 5 observations discrètes.




FIGURE 2.4 – MMC avec 3 états et 5 observations discrètes.

Compte tenu des paramètres du MMC, la probabilité jointe de réalisation de la séquence d'observations $O = (o_1, \dots, o_T)$ et celle de la séquence d'états $Q = (q_1, \dots, q_T)$, en utilisant les dépendances des probabilités conditionnelles, peut être décrite par :

$$P(V = O, S = Q | \lambda) = P(V = O | S = Q, \lambda) P(S = Q | \lambda) \quad (2.20)$$

avec

$$P(V = O | S = Q, \lambda) = \prod_{t=1}^T P(V_t = o_t | S_t = q_t, \lambda)$$

$$P(S = Q | \lambda) = P(S_1 = q_1 | \lambda) \prod_{t=1}^{T-1} P(S_{t+1} = q_{t+1} | S_t = q_t, \lambda)$$

Topologie de modèle : la topologie décrit les liens (transitions possibles) entre les états cachés du modèle. Il existe plusieurs topologies, chacune ayant des propriétés particulières [Bideault, 2015]. Le choix de la topologie du MMC se construit en fonction du problème à traiter. La topologie d'un MMC est structurée par les contraintes des valeurs des transitions entre les états et les probabilités initiales [Rabiner, 1989]. Nous pouvons retenir la topologie ergodique, gauche-droite et de Bakis. Ces types de modèles sont illustrés ci-après.

Modèle ergodique : c'est un modèle sans contrainte où toutes les transitions d'un état vers les autres sont possibles (équation 2.21). Dans ces conditions, tous les états communiquent entre eux. Selon une représentation graphique, tous les états sont reliés entre eux par des flèches indiquant le sens de transition et la probabilité qui lui correspond (figure 2.5, page 59) :

$$a_{i,j} > 0 \quad \forall i \in [1, N], \quad \forall j \in [1, M] \quad (2.21)$$




FIGURE 2.5 – Exemple d'un MMC ergodique.

Modèle gauche-droite : c'est un modèle où il existe des contraintes sur certaines transitions. La transition d'un état ayant un indice bas vers un état ayant un indice haut est la seule autorisée. Ce modèle peut être utilisé pour modéliser des processus possédant des propriétés variantes dans le temps : les signaux issus de la voix [Rabiner, 1989; Fink, 2014], l'usure de roulements [Bunks et al., 2000; Nelwamondo et al., 2006], le diagnostic et le pronostic de défauts [Miao and Makis, 2007]... Il possède les propriétés suivantes :

Pour la matrice initiale :

$$\begin{cases} \pi_i = 1 & i = 1 \\ \pi_i = 0 & i \neq 1 \end{cases} \quad (2.22)$$

Pour la matrice de transition :

$$\begin{cases} a_{i,j} = 0 & \forall j < i \\ a_{i,j} \neq 0 & \forall j > i + \delta \text{ avec } \delta = 1, 2, \dots \end{cases} \quad (2.23)$$

Modèle de Bakis : c'est un modèle qui peut être gauche-droite ou inverse (droite-gauche). Il est caractérisé par le fait que $\delta = 2$. Un exemple de modèle de Bakis gauche-droite est illustré dans la figure 2.7, page 60.




FIGURE 2.6 – Schéma d'un MMC gauche-droite.




FIGURE 2.7 – Schéma d'un MMC de Bakis gauche-droite.

Apprentissage du MMC : l'opération d'apprentissage permet d'estimer les valeurs des paramètres du MMC. Elle consiste à ajuster les paramètres du modèle de manière à maximiser un critère. Les critères les plus utilisés dans l'apprentissage des MMCs sont : le critère du Maximum de vraisemblance (MV) et le critère du Maximum a posteriori (MAP) [Binsztok, 2007]. Une présentation des autres critères peut être consultée dans [Aupetit, 2005].

Apprentissage avec le critère MV : cet apprentissage est réalisé par l'algorithme de Baum-Welch [Baum et al., 1970]. Cet algorithme est une instance de l'algorithme Expectation-Maximization (EM). L'algorithme de Baum-Welch part d'un modèle initial λ' , puis il optimise le critère de vraisemblance jusqu'à convergence. L'apprentissage permet de trouver le modèle λ qui maximise $P(V = O|\lambda)$.

Pour estimer ces paramètres, l'algorithme de Baum-Welch utilise deux nouvelles matrices : Ξ et Γ . Le calcul de leurs coefficients s'appuie sur les séquences de probabilités $\alpha_t(i)$ dites « probabilités *Forward* » et les séquences de probabilités $\beta_t(i)$ dites « probabilités *Backward* » [Bilmes, 1998]. Ces probabilités sont définies de la manière suivante :

$$\begin{cases} \alpha_1(i) = P(V_1 = o_1, S_1 = s_i | \lambda) & t = 1 \\ \alpha_t(i) = P(V_1 = o_1, \dots, V_t = o_t, S_1 = s_i | \lambda) & t > 1 \end{cases} \quad (2.24)$$

$$\begin{cases} \beta_T(i) = 1 & t = T \\ \beta_t(i) = P(V_{t+1} = o_{t+1}, \dots, V_T = o_T | S_t = s_i | \lambda) & t < T \end{cases} \quad (2.25)$$

Elles sont calculées de manière récursive par les équations suivantes :

$$\alpha_t(i) = \sum_{j=1}^N \alpha_t(j) P(q_t = s_i | q_{t-1} = s_j) P(V_t = o_t | q_t = s_i) \quad (2.26)$$

$$\beta_t(i) = \sum_{j=1}^N P(q_{t+1} = s_j | q_t = s_i) P(V_{t+1} = o_{t+1} | q_{t+1} = s_j) \beta_{t+1}(j) \quad (2.27)$$

Les coefficients de Ξ , $\zeta_t(i, j)$ représentent la probabilité d'être dans l'état s_i à l'instant t et de passer dans l'état s_j à l'instant $t + 1$ sachant le modèle λ et une séquence O . Ils sont calculés comme suit :

$$\zeta_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{ij} b_j(o_{t+1}) \beta_{t+1}(j)} \quad (2.28)$$

Les coefficients de Γ , $\gamma_t(i, j)$ représentent la probabilité d'être dans l'état s_i à l'instant t sachant le modèle λ et une séquence O . Ces coefficients sont calculés comme suit :

$$\gamma_t(i) = \sum_{j=1}^N \zeta_t(i, j) = \frac{\alpha_t(i) \beta_t(i)}{P(V = O | \lambda)} \quad (2.29)$$

Par conséquent, les expressions qui permettent d'estimer les paramètres du modèle sont définies de la manière suivante :

$$\pi_i = P(S_1 = s_i | O, \lambda') \quad (2.30)$$

$$a_{i,j} = \frac{\sum_{t=1}^{T-1} P(S_t = s_i, S_{t+1} = s_j | V = O, \lambda')}{\sum_{t=1}^{T-1} P(S_t = s_i | V = O, \lambda')} \quad (2.31)$$

$$b_{i,j} = \frac{\sum_{t=1}^T P(S_t = s_i | V = O, \lambda') \delta(o_t = j)}{\sum_{t=1}^T P(S_t = s_i | V = O, \lambda')} \quad (2.32)$$

Les formules de ré-estimation obtenues ci-dessous peuvent s'interpréter de la façon suivante :

$$\pi_i = \text{probabilité d'être dans l'état } s_i \text{ à } t = 1 \quad (2.33)$$

$$a_{i,j} = \frac{\text{nombre de transitions de l'état } s_i \text{ vers l'état } s_j}{\text{nombre de passages provenant de l'état } s_i} \quad (2.34)$$

$$b_{i,j} = \frac{\text{nombre de fois où l'on est dans l'état } s_i \text{ en observant } v_j}{\text{nombre de fois où l'on est dans l'état } s_i} \quad (2.35)$$

L'algorithme de Baum-Welch est donné en (A.2.1).

Apprentissage avec le critère MAP : ce critère trouve son intérêt dans la théorie de décision bayésienne. A l'instar du critère MV, c'est la probabilité *a posteriori* qui est utilisée. La probabilité *a posteriori* est calculée par la formule de Bayes :

$$P(\lambda | V = O) = \frac{P(V = O | \lambda) P(\lambda)}{P(V = O)} \quad (2.36)$$

Avec $P(\lambda|V = O)$, la probabilité *a posteriori* du modèle λ connaissant la séquence d'observations O . $P(\lambda)$ est la probabilité *a priori* d'apparition du modèle λ et $P(V = O)$ est la probabilité *a priori* d'apparition de la séquence d'observations O . Après simplification de $P(V = O)$, l'objectif est alors de maximiser $P(V = O|\lambda)P(\lambda)$. Ainsi, l'estimateur *a posteriori* $\hat{\lambda}_{MAP}$ est donné par l'équation (2.37).

$$\hat{\lambda}_{MAP} = \arg \max_{\lambda} P(\lambda|V = O) = \arg \max_{\lambda} P(V = O|\lambda)P(\lambda) \quad (2.37)$$

Exploitation du MMC : des solutions algorithmiques existent afin de pouvoir exploiter un MMC. Ces algorithmes sont en réponse aux problèmes suivants :

- *Problème d'évaluation* : étant donné une séquence d'observations O et un modèle λ , comment évaluer efficacement $P(V = O|\lambda)$, la probabilité d'observation de O étant donné λ ?
- *Problème de décodage* : étant donné une séquence d'observations O et un modèle λ , comment choisir une séquence d'états S optimale (c'est-à-dire expliquant au mieux O) ?

Le problème d'évaluation : la probabilité de générer la séquence d'observations O étant donné λ peut s'effectuer directement à l'aide de l'équation :

$$P(V = O|\lambda) = \sum_{q_1 \dots q_T} P(S_1 = q_1)P(V_1 = o_1|S_1 = q_1)P(S_2 = q_2|S_1 = q_1)P(V_2 = o_2|S_2 = q_2) \dots P(S_T = q_T|S_{T-1} = q_{T-1})P(V_T = o_T|S_T = q_T) \quad (2.38)$$

Le calcul de cette équation est de complexité $o(TN^T)$. Une méthode plus efficace est l'utilisation des variables *Forward* (équation 2.26). Par conséquent, la probabilité $P(V = O|\lambda)$ peut être calculée en utilisant l'équation (2.39) :

$$P(V = O|\lambda) = \sum_{i=1}^N P(V = O, q_T = s_i|\lambda) = \sum_{i=1}^N \alpha_T(i) \quad (2.39)$$

Les probabilités *Backward* obtenues par l'équation (2.27) peuvent également être utilisées. A l'opposé des probabilités *Forward*, les probabilités *Backward* sont calculées à partir de la dernière observation. La probabilité $P(V = O|\lambda)$ est donnée par l'expression suivante :

$$P(V = O|\lambda) = \sum_{i=1}^N \pi_i b_i(o_1) \beta_1(i) \quad (2.40)$$

Le problème de décodage : le problème consiste à trouver la séquence d'états cachés $Q^* = (q_1^*, \dots, q_T^*)$ qui a le plus probablement engendré la séquence d'observations O . En d'autres termes, étant donné une séquence d'observations et un modèle λ , on cherche à trouver la séquence d'états cachés correspondante. Il consiste à résoudre :

$$Q^* = \arg \max_{Q \in \mathbb{S}} P(V = O, S = Q|\lambda) \quad (2.41)$$

L'algorithme permettant de résoudre ce problème est l'algorithme de Viterbi (A.2.2). Ce dernier utilise une mesure de probabilité $\delta_t(i)$ qui représente le meilleur chemin partiel amenant à l'état

caché s_i , défini par l'expression suivante :

$$\delta_t(i) = \max_{q_1 \dots q_{t-1} \in \mathbb{S}^{t-1}} P(S_1 = q_1, \dots, S_{t-1} = q_{t-1}, S_t = s_i, V_1 = o_1, \dots, V_t = o_t | \lambda) \quad (2.42)$$

2.3.4 Extensions des MMCs

Une évolution possible du MMC est le MMC multi-flux. Ce dernier présente la particularité de pouvoir représenter plusieurs séquences d'observations émanant de sources de mesures différentes (flux d'observations). Une autre évolution est le MMC flou. Dans ce modèle, une observation continue appartient à chaque classe avec une valeur spécifique de similarité.

MMC multi-flux : comme le montre la figure 2.8, page 63, ce modèle peut être représenté sous forme de nombreuses topologies [Ling et al., 2009]. Ces topologies offrent des possibilités en terme de synchronie entre les états et de dépendance des observations. En matière de synchronie entre états, les séquences d'observations sont supposées être produites par les différentes séquences d'états dans le modèle asynchrone (figure 2.8 (a, b)). Une seule séquence d'états est considérée dans le modèle synchrone (figure 2.8 (c, d)). En matière de dépendance, la génération des séquences d'observations est supposée seulement dépendre de l'état dans le modèle indépendant (figure 2.8 (a, d)). Pour un modèle dépendant, il y a une dépendance supplémentaire entre observations (figure 2.8 (b, c)). Dans notre approche, nous retenons seulement le modèle synchrone et indépendant. C'est un modèle qui permet de décrire la défaillance graduelle globale du système avec une interprétation aisée concernant la signification des états [Aggab et al., 2015a].




FIGURE 2.8 – Différentes topologies d'un MMC multi-flux [Ling et al., 2009].

Un MMC multi-flux synchrone indépendant avec K flux d'observations est désigné par la notation compacte $\lambda_{str} = \{A, B, \pi\}$ bien que les paramètres $\{A, \pi\}$ ont la même définition que dans le cas du MMC à flux unique. Les probabilités d'émissions sont placées séparément

pour chaque flux k dans $B = [B_1, B_2, \dots, B_k, \dots, B_K]$. L'observation à l'instant t est alors définie par $O_t = [o_t(1), \dots, o_t(k), \dots, o_t(K)]$ où $o_t(k)$ est l'observation de flux k . Pour la figure 2.8, page 63, $O_t = [Vx_t, Vy_t]$, en effet deux flux d'observations (Vx et Vy) sont présents. Dans ces conditions, la probabilité jointe de la séquence d'observations O et celle de la séquence d'états Q pour deux flux s'écrit :

$$P(V = O, S = Q, \lambda_{str}) = P(S_1 = q_1 | \lambda_{str}) \prod_{t=1}^{T-1} P(S_{t+1} = q_{t+1} | S_t = q_t, \lambda_{str}) b_j(x_t, y_t) \quad (2.43)$$

avec $b_j(x_t, y_t) = b_j(x_t) b_j(y_t)$

MMC flou : une stratégie d'amélioration d'un MMC classique concerne son hybridation avec la logique floue [Li et al., 2009]. Dans ce modèle, une forme de fuzzification est utilisée. L'observation continue n'est pas attribuée à une seule classe mais à plusieurs (M classes) avec des degrés d'appartenance $u = dist^{-1}$. Par rapport à un MMC classique, la modification consiste à remplacer $b_j(o_t)$ par $\sum_{m=1}^M u(m, t) b_i(m)$. Les expressions qui en découlent sont :

$$\alpha_t(i) = \sum_{j=1}^N \alpha_t(j) P(q_t = s_i | q_{t-1} = s_j) \sum_{m=1}^M u(m, t) b_i(m) \quad (2.44)$$

$$\beta_t(i) = \sum_{j=1}^N P(q_{t+1} = s_j | q_t = s_i) \beta_{t+1}(j) \sum_{m=1}^M u(m, t) b_i(m) \quad (2.45)$$

$$\zeta_t(i, j) = \frac{\alpha_t(i) a_{i,j} \beta_{t+1}(j) \sum_{m=1}^M u(m, t) b_i(m)}{\sum_{i=1}^N \sum_{j=1}^N \alpha_t(i) a_{i,j} \beta_{t+1}(j) \sum_{m=1}^M u(m, t) b_i(m)} \quad (2.46)$$

2.4 Approche d'estimation de l'état de santé

L'approche d'estimation de l'état de santé repose sur deux phases :

- *Phase d'apprentissage* : elle consiste à déterminer les centres des classes et à former un modèle capable de caractériser le cycle de vie du système à partir des résidus obtenus sur des cycles complets de dégradation.
- *Phase d'exploitation* : elle utilise les centres des classes et le modèle obtenu dans la phase d'apprentissage. Le résidu calculé en temps réel à l'aide d'un observateur est continuellement assigné à une classe (ou à plusieurs classes dans le cas du recours à un MMC flou). L'estimation est ensuite directement réalisée par la recherche de la séquence d'états à l'aide de l'algorithme de Viterbi. Le niveau de dégradation retenu est le dernier estimé ou le plus persistant à partir des dernières observations [Tobon-Mejia et al., 2012].

Le schéma de la figure 2.9, page 65 résume les étapes de la modélisation choisie permettant l'estimation de l'état de santé d'un système.




FIGURE 2.9 – Phases de la démarche de modélisation.

- *Évaluation de l'approche* : les critères utilisés afin d'évaluer le résultat de l'approche sont le taux de fausses alarmes (TFA) et le taux de non détection (TND). Ces taux sont formulés comme suit :

$$TFA\% = \frac{\text{la durée des fausses détections de la défaillance}}{\text{durée de vie du système}} \cdot 100 \quad (2.47)$$

$$TND\% = \frac{\text{la durée des non-détections de la défaillance}}{\text{durée de vie du système}} \cdot 100 \quad (2.48)$$

2.5 Illustration de l'approche

Dans cette section, nous illustrons l'approche de modélisation et d'évaluation de l'état de santé présentée sur un système de contrôle en boucle fermée, en l'occurrence un système de régulation du niveau d'eau.

2.5.1 Description du système considéré

Un système contrôlé en boucle fermée est un ensemble de composants physiques en interaction (figure 2.10, page 66). Il est constitué d'une chaîne directe et d'une chaîne (boucle) de retour. La chaîne directe est formée par le procédé, l'actionneur et le régulateur. Elle assure les fonctions de commande et de puissance. La chaîne de retour est constituée par un ou plusieurs capteurs. Elle assure la fonction de mesure. La dégradation du système peut être vue

par la détérioration de son actionneur. En effet, la perte de capacité partielle ou totale d'un actionneur peut engendrer une perte de performance du système dans le sens où elle modifie son comportement par rapport au comportement désiré.




FIGURE 2.10 – Schéma-bloc général d'un système de contrôle-commande en boucle fermée.

La commande en boucle fermée est calculée de façon à avoir un comportement entre l'entrée (consigne) et la sortie (mesure) satisfaisant la contrainte de l'équation (2.49). Par conséquent, le contrôle-commande peut masquer les effets de dégradation d'un actionneur et des perturbations. Le système est défaillant lorsque la capacité de l'actionneur ne permet plus de satisfaire la performance désirée.

$$\lim_{t \rightarrow \infty} (y^{ref}(t) - y(t)) = 0 \quad \forall d(t), f(t) \quad (2.49)$$

où $y^{ref}(t)$ est l'entrée de référence, $y(t)$ la sortie contrôlée, $d(t)$ le bruit et $f(t)$ les défauts.

L'application choisie est un système de régulation du niveau d'eau représenté par la figure 2.11, page 67. Elle est présentée dans les travaux de Nguyen [Nguyen, 2015]. L'intérêt de considérer ce système est double. D'une part, son modèle d'évolution, même s'il est non linéaire, reste relativement simple. D'autre part, la variable de dégradation est facilement modélisable et simulable. L'eau est injectée par une pompe dans un premier réservoir de section notée S_1 . Son écoulement par l'intermédiaire de la vanne V_1 alimente le second réservoir de section notée S_2 . La régulation est réalisée sur le niveau d'eau h_2 du réservoir 2. Sa valeur est mesurée par un capteur et contrôlée par ajustement de l'entrée de commande de la pompe u . La commande est calculée à partir d'un régulateur de type PID.

Afin de considérer la réponse réelle de la pompe, la relation entre le débit d'écoulement q_{in} en sortie de pompe et l'entrée de la commande de la pompe u est représentée par un système du premier ordre.

$$\frac{dq_{in}}{dt} = -\frac{1}{\tau_a} q_{in} + \frac{K_a}{\tau_a} u \quad (2.50)$$

où τ_a est la constante de temps de la pompe et K_a sa capacité. La pompe sature lorsque la commande $u(t)$ atteint une valeur maximale u_{max} . Par conséquent, quel que soit l'instant t




FIGURE 2.11 – Système de régulation du niveau d'eau [Nguyen, 2015].

considéré $u(t) \in [0, u_{max}]$. L'eau peut s'écouler par les vannes (V_1 et V_2) de sortie de chaque réservoir selon un débit $q_{j,out}$, $j = 1, 2$ vérifiant la formule de Torricelli :

$$q_{j,out} = K_{v_j} \sqrt{2gh_j} \quad j = 1, 2 \quad (2.51)$$

où h_j est le niveau d'eau du réservoir j , $j = 1, 2$; g est l'accélération de la pesanteur et K_{v_j} est le paramètre spécifique de la vanne j , $j = 1, 2$.

En se basant sur le principe d'équilibre dynamique, le système peut être décrit par les équations suivantes :

$$\begin{cases} \frac{dh_1(t)}{dt} = \frac{1}{S_1} q_{in}(t) - \frac{K_{v_1}}{S_1} \sqrt{2gh_1(t)} \\ \frac{dh_2(t)}{dt} = \frac{K_{v_1}}{S_2} \sqrt{2gh_1(t)} - \frac{K_{v_2}}{S_2} \sqrt{2gh_2(t)} \end{cases} \quad (2.52)$$

L'objectif du contrôle est de maintenir le niveau h_2 à la valeur de la consigne demandée notée y^{ref} . Sa mesure éventuellement bruitée h_2^m est exprimée sous la forme :

$$h_2^m = h_2 + d(t) \quad (2.53)$$

Comme énoncé auparavant, la perte de capacité partielle ou totale d'un actionneur peut engendrer une perte de performance du système dans le sens où elle modifie son comportement par rapport au comportement désiré. Par conséquent, la capacité de la pompe au temps t peut être exprimée comme suit :

$$K_a(t) = K_{a\,init} - D(t) \quad (2.54)$$

où $K_{a\,init}$ est la capacité initiale de la pompe et $D(t)$ décrit la dégradation de la pompe accumulée au temps t .

Les paramètres du régulateur PID sont réglés en phase de conception et ne sont pas modifiés au cours du fonctionnement du système.

Les notations et les valeurs numériques associées nécessaires à la simulation du comportement du système sont résumées dans la table 2.1, page 68.

TABLE 2.1 – Valeurs numériques des paramètres du modèle

<i>Variable</i>	<i>Définition</i>	<i>Valeur numérique</i>
S_1	<i>Section du réservoir 1</i>	25 m ²
S_2	<i>Section du réservoir 2</i>	20 m ²
K_{v_1}	<i>Paramètre de la valve 1</i>	8
K_{v_2}	<i>Paramètre de la valve 2</i>	6
g	<i>Constante de gravité</i>	9.82 m.s ⁻²
τ_a	<i>Constante de temps de la pompe</i>	1 s
K_a^{init}	<i>Valeur initiale du gain d'amplificateur de la pompe</i>	5
u_{max}	<i>Tension maximale de commande de la pompe</i>	100 V

2.5.2 Comportement du système

Dans cette sous-section, nous présentons un exemple d'évolution du système en présence de dégradation pour une consigne variable modélisée par un modèle de Markov. Le système est considéré défaillant lorsque les objectifs au regard des performances ne sont plus satisfaits. Dans cette partie, la capacité réelle de la pompe doit être supérieure à une valeur critique fixée lors de la conception du système de commande, notée $Ka_{critique}$. Selon les équations 2.50 et 2.51 décrivant le comportement du système, les états stables sont obtenus à l'instant (t_{ss}) si

$$u(t_{ss}) = \frac{S_1 K_{v_2}}{S_2 K_a(t_{ss})} \sqrt{2gh_2(t_{ss})} \quad (2.55)$$

Etant donné que $u(t_{ss}) \leq u_{max}$, la capacité minimale $Ka_{critique}$ est donc calculée par :

$$Ka_{critique} = \frac{S_1 K_{v_2}}{S_2 u_{max}} \sqrt{2gh_{max}} \quad (2.56)$$

où h_{max} est la valeur maximale de la consigne.

Remarque : dans le cas de l'application étudiée, l'échelle de temps du modèle de comportement du système de contrôle et celle du modèle de dégradation ont un écart important. Ceci pose le problème du temps de simulation. Dans les tests réalisés, nous avons accéléré la vitesse de la dégradation par rapport à ce qui nous semble réaliste.

Pour cet exemple, la capacité de la pompe K_a diminue à partir de sa capacité nominale suivant un processus de chocs. Le processus d'arrivée des chocs est un processus de Poisson de paramètre $\lambda = 10^{-3}$ arrivée.s⁻¹. Les tailles de choc (z_n) sont des variables aléatoires entre 0 et $\Delta = 0.5$. La valeur de la capacité K_a reste constante entre deux chocs.

L'évolution de la consigne est illustrée sur la figure 2.12 (a), page 69. Les niveaux d'eau des deux réservoirs sont représentés sur les figures 2.12 (b, c), page 69. La figure 2.12 (d), page 69 décrit la trajectoire simulée de la capacité de la pompe. Le débit d'écoulement et l'entrée de commande appliquée sur la pompe sont illustrés sur les figures 2.12 (e, f), page 69.

2.5. ILLUSTRATION DE L'APPROCHE




FIGURE 2.12 – Une trajectoire du système de contrôle du niveau d'eau du réservoir jusqu'à la défaillance de la pompe : (a) la consigne, (b) le niveau d'eau du réservoir 2, (c) le niveau d'eau du réservoir 1, (d) la capacité de l'actionneur, (e) la valeur de commande appliquée sur l'actionneur et (f) le débit d'écoulement d'entrée correspondant

Les trajectoires contenues dans la figure 2.12, page 69 montrent l'évolution des différents paramètres du système lors de son fonctionnement avec une dégradation de la pompe jusqu'à sa

défaillance totale. Le système assure sa fonction de régulation de niveau d'eau du réservoir 2 sur la consigne malgré cette dégradation, et cela jusqu'à ce que la capacité atteigne la valeur critique. Ceci signifie que la dégradation du système n'est pas perceptible sur la mesure avant défaillance. Cette non perception est liée à la commande qui compense l'effet de la dégradation de la pompe et des perturbations associées au système de régulation.

2.5.3 Application de notre approche

Le système étant décrit, nous pouvons entamer la mise en œuvre des deux phases de l'approche proposée. Ces deux phases utilisent le résidu obtenu par un observateur. Ce dernier est synthétisé de manière à exploiter les mesures accessibles au niveau du système, en l'occurrence le niveau d'eau h_2 du réservoir 2 et la valeur de la commande u appliquée sur la pompe.

L'observateur est de la forme :

$$\begin{cases} \frac{d\hat{q}_{in}(t)}{dt} = -\frac{1}{\tau_a}\hat{q}_{in}(t) + \frac{K_{a\text{init}}}{\tau_a}u \\ \frac{d\hat{h}_1(t)}{dt} = \frac{1}{S_1}\hat{q}_{in}(t) - \frac{K_{v_1}}{S_1}\sqrt{2g\hat{h}_1(t)} + L_1\tilde{h}_2(t) \\ \frac{d\hat{h}_2(t)}{dt} = \frac{K_{v_1}}{S_1}\sqrt{2g\hat{h}_1(t)} - \frac{K_{v_2}}{S_2}\sqrt{2g\hat{h}_2(t)} + L_2\tilde{h}_2(t) \end{cases} \quad (2.57)$$

Avec $\tilde{h}_2(t) = h_2^m(t) - \hat{h}_2(t)$ est l'erreur d'estimation du niveau d'eau dans le réservoir 2. L_1 et L_2 sont les gains de l'observateur.

L'évaluation de la performance de l'observateur synthétisé est fondée sur l'erreur d'estimation $\tilde{h}_2$ calculée par la différence entre la sortie mesurée h_2^m et celle estimée $\hat{h}_2$. A des fins d'illustration, l'erreur d'estimation du niveau d'eau du réservoir 1 qui est en réalité non accessible à la mesure est également présentée. En cas d'absence de bruit sur la sortie et pour des conditions initiales différentes, les grandeurs estimées sont présentées dans la figure 2.13, page 71. Les valeurs des gains sont fixés de sorte à obtenir la convergence de l'état rapidement. Nous constatons que pour les valeurs choisies, les estimations sont de bonne qualité. Dans le cas de la présence de bruit de mesure caractérisé par $N(0, 1/16)$, les grandeurs estimées sont présentées dans la figure 2.14, page 71.

Phase d'apprentissage : elle consiste à la récupération des centres des classes et à la synthèse du MMC. Sa réalisation nécessite la connaissance du nombre de classes. Ce nombre est fixé de façon à ce que l'apprentissage du modèle soit possible en un temps de calcul raisonnable. Les centres sont déterminés par l'algorithme « LBG ». Une topologie à quatre états a été choisie. Nous avons repris la stratégie proposée dans [Welte, 2008; Vignat et al., 2015]. L'ensemble des données est constitué de 60 essais de dégradations jusqu'à défaillance de la pompe pour des missions à deux consignes avec une évolution aléatoire. Les consignes sont de 10 – 15, de 10 – 20 et de 10 – 25. La dégradation est modélisée par un processus de Poisson de paramètre $\lambda = 10^{-3}$ arrivée.s⁻¹ et $\Delta = 0.5$ (figure 2.15 (a), page 72). Les instants de défaillance du système et les valeurs de résidu correspondantes pour les différents essais sont présentés dans la figure 2.15 (b), page 72.

A partir de la figure 2.15 (b), page 72, nous observons une variabilité importante des valeurs de résidu aux instants de défaillance. Cette variabilité est principalement due à la présence de




FIGURE 2.13 – Erreurs d'estimation des niveaux d'eau sans bruit de mesure.




FIGURE 2.14 – Erreurs d'estimation des niveaux d'eau avec présence de bruit de mesure.

bruits de mesure sur la valeur de niveau h_2 mesurée, aux valeurs de consignes (capacité critique) ainsi que leurs évolutions. Par conséquent, il apparaît clairement que connaître la valeur de résidu ne reflète pas le niveau de dégradation atteint par le système.

La répartition aléatoire des données pour les tests a été réalisée comme suit : 2/3 pour la base d'apprentissage et 1/3 pour la base de test. Pour la synthèse d'un MMC, la figure 2.16 (a), page 72 présente l'évolution de la log-vraisemblance pour un nombre de classes compris entre 3 et 7 lors de l'apprentissage des paramètres du MMC par l'algorithme de Baum-Welch. La figure 2.16 (b), page 72 présente l'évolution de la log-vraisemblance lors de l'apprentissage d'un MMC flou pour des mesures de similarité différentes (une distance euclidienne et son carré).

L'évolution de la log-vraisemblance lors de l'apprentissage du modèle dépend fortement du nombre de classes choisies. Pour le MMC flou, nous remarquons que pour des matrices initiales identiques, la mesure de similarité utilisée impacte sur la vraisemblance. Le nombre fixé de classes peut correspondre au modèle possédant le maximum de vraisemblance : dans l'exemple,




FIGURE 2.15 – Ensemble des (a) trajectoires des capacités simulées (b) les instants de défaillance et les valeurs de la moyenne de résidu correspondantes.




FIGURE 2.16 – Evolution de la log-vraisemblance lors de l'apprentissage.

respectivement $K = 3$ et $K = 7$ pour le MMC et le MMC flou. Le nombre de classes peut également être celui aboutissant au plus faible TFA et/ou TND selon le risque considéré sur un ensemble de séquences d'évaluation. Toutefois, dans tous les cas, le nombre de classes ne doit pas être élevé pour avoir des temps d'apprentissage et d'inférence raisonnables.

Phase de test : à titre d'illustration, nous présentons un exemple de dégradation issu de la base de test. L'évolution de la capacité de la pompe jusqu'à sa défaillance est présentée dans la figure 2.17 (a), page 73. La moyenne du résidu généré par l'observateur est présentée dans la figure 2.17 (b), page 73.

La séquence d'observations obtenue pour le MMC appris avec $K = 3$ en utilisant les centres des classes est présentée dans la figure 2.18 (a), page 74. L'estimation du niveau de dégradation à partir de cette séquence est effectuée à l'aide de l'algorithme de Viterbi. La probabilité δ et la séquence d'états obtenues sont présentées dans les figures 2.18 (b, c), page 74. La probabilité δ




FIGURE 2.17 – Evolution jusqu'à la défaillance (a) de la capacité de la pompe, (b) de la moyenne de résidu.

et la séquence d'états obtenus pour le cas du MMC flou avec $K = 7$ sont présentées dans la figure 2.19, page 74.

Les estimations des niveaux obtenues par un MMC et un MMC flou pour les différents nombres de classes sont présentées dans la figure 2.20, page 75. Les mesures de performance ainsi obtenues en matière de TFA et TND sont présentées dans la table 2.2, page 73.

TABLE 2.2 – Mesures de performance pour l'exemple.

K	MMC					MMC FLOU				
	3	4	5	6	7	3	4	5	6	7
$TFA\%$	1.25	0	3.41	2.02	20.71	0	0	0	0	0
$TND\%$	0	0.13	0	0	0	3.14	8.67	3.08	8.67	8.7

A partir des taux calculés (table 2.2, page 73) et pour un choix de modèle possédant le maximum de vraisemblance ($K = 3$ pour le MMC et $K = 7$ pour le MMC flou), nous observons que le MMC génère 1.25% de fausses alarmes et le MMC flou 8.7% de non détection. Un compromis devra donc être choisi entre : détection de fausses alarmes et non détection. La non détection peut normalement sembler être plus importante pour le mainteneur.

Pour évaluer la capacité de généralisation, le résultat pour 100 partitionnements aléatoires sur l'ensemble des données, est présenté dans la table 2.3, page 73.

TABLE 2.3 – Mesures de performance de l'approche.

K	MMC					MMC FLOU				
	3	4	5	6	7	3	4	5	6	7
$TFA\%$	11.94	5.38	16.92	19.05	17.42	1.11	0.16	0.91	0.21	0.11
$TND\%$	0.01	0.44	0.001	0	0.17	1.88	5.24	2.32	4.21	4.66

A partir de ces résultats, nous observons que la synthèse d'un MMC et d'un MMC flou offre des résultats satisfaisants en matière de TFA et TND . Les meilleurs résultats ont été obtenus lors de la synthèse du MMC flou. Ces performances sont liées au fait, qu'il prend en considération

2.5. ILLUSTRATION DE L'APPROCHE




FIGURE 2.18 – Evolution de (a) la séquence d'observations, (b) la probabilité (δ) et (c) la séquence d'états associée pour l'exemple avec $K=3$ (cas du MMC).




FIGURE 2.19 – Evolution de (a) la probabilité (δ) et (b) la séquence d'états associée pour l'exemple avec $K=7$ (cas du MMC flu).)




FIGURE 2.20 – Evolution du niveau de dégradation pour l'exemple (a) MMC, (b) MMC fluu.

les degrés d'appartenances à l'inverse du MMC. Pour le MMC, la discrétisation en nombre de 4 offre le meilleur compromis TFD/TND. Pour le MMC fluu, le meilleur compromis est obtenue pour $K = 3$.

Cette approche peut être aussi utilisée pour estimer l'efficacité d'opérations de maintenance [Aggab et al., 2015b]. En effet, lors d'une action de maintenance et selon son efficacité, l'état du système peut revenir à un niveau de dégradation inférieur. A l'inverse de la partie précédente, lors de l'apprentissage du modèle, nous autorisons les transitions des niveaux supérieurs aux niveaux inférieurs.

Deux interventions de maintenance sont alors simulées. Elles consistent en la suppression (totale ou partielle) de la dégradation présente sur le système. Les résultats sont présentés dans les figures 2.21, page 75 et 2.22, page 76.




FIGURE 2.21 – Evolution de (a) la capacité de la pompe simulée et (b) la séquence d'états associée à la dégradation.




FIGURE 2.22 – Evolution de (a) la capacité de la pompe simulée et (b) la séquence d'états associée à la dégradation.

A partir de ces figures, nous pouvons noter que l'action de maintenance effectuée dans le cadre de la première intervention rétablit le système dans un niveau de dégradation mineur (figure 2.21, page 75). Dans ces conditions, l'action de maintenance peut être considérée comme parfaite. Dans le deuxième cas (figure 2.22, page 76). Le retour n'est que partiel, par conséquent l'action de maintenance est imparfaite.

2.6 Discussion

Dans ce chapitre, nous avons présenté une approche de diagnostic de l'état de dégradation d'un système. Nous avons abordé la problématique de construction d'indicateurs permettant de suivre l'état de santé d'un système à partir des signaux disponibles. Nous avons proposé d'utiliser les méthodes de génération de résidus. La variation des caractéristiques de résidus est corrélée à la progression de l'état de santé du système, mais cela ne permet cependant pas de la quantifier. Le résidu ainsi généré a été utilisé pour modéliser la dégradation du système. Notre choix s'est porté sur un MMC. Sa facilité d'utilisation nous a permis de prendre en compte les spécificités d'incertitudes, non-linéarités, non-stationnarités...

L'approche de la modélisation proposée repose sur deux phases : une phase d'apprentissage d'un seul modèle à partir des séquences discrétisées de résidus. Le modèle obtenu tient compte de la nature du résidu et des conditions de fonctionnement. Le modèle est ensuite utilisé pour estimer l'état courant du système. Avec les exemples traités, il a été possible d'illustrer l'intérêt de l'approche dans le cadre de la démarche d'évaluation de l'état de santé d'un système et afin de déterminer l'efficacité des activités de maintenance.

Le chapitre III est consacré à la phase de pronostic. Cette phase est également critique pour l'aide à la décision de la maintenance. Deux stratégies sont proposées. L'objectif est de compléter la connaissance de l'état de santé du système en offrant une connaissance sur la durée de vie résiduelle. Le choix de la stratégie de pronostic est conditionné par la nature du modèle de comportement du système disponible et la connaissance de sa mission (conditions opérationnelles futures).

Chapitre 3

Pronostic de durée de vie

3.1	Introduction	79
3.2	Approches de pronostic	79
3.2.1	Approche de pronostic markovienne	79
3.2.2	Approche à base de modèles	82
3.3	Étapes de l'approche à base de modèles	83
3.3.1	Phase d'estimation	83
3.3.2	Phase de pronostic	83
3.4	Illustration des approches	89
3.4.1	Application de l'approche markovienne	89
3.4.2	Application de l'approche à base de modèles	94
3.5	Discussion	104

3.1 Introduction

Ce chapitre est consacré à la phase de pronostic. On y présente deux approches permettant de calculer la durée de vie résiduelle d'un système sous l'hypothèse que les indicateurs associés à la dégradation ne sont pas directement mesurables. La première approche fait appel au Modèle de Markov Caché utilisé pour le diagnostic et à ses propriétés, notamment son comportement asymptotique. La deuxième approche repose sur l'utilisation de modèles de comportement. Elle utilise un observateur d'état associé à une technique de prédiction. Ces deux approches sont illustrées sur des exemples de dégradations du système de régulation de niveau d'eau. La dernière partie du chapitre est consacrée à la discussion des résultats obtenus.

3.2 Approches de pronostic

L'objectif des deux approches adoptées est d'estimer la durée de vie résiduelle d'un système sous les hypothèses formulées dans la section 1.5.1, page 45. La première est dite « markovienne ». Elle utilise les étapes de la démarche du diagnostic présentée dans le chapitre II et également les propriétés des modèles de Markov. Elle ne nécessite pas la connaissance de la sollicitation future, mais elle suppose que cette dernière en matière de probabilité d'évolution n'est pas très différente des conditions de fonctionnement utilisées lors de l'apprentissage du modèle. La seconde consiste à simuler le modèle de comportement du système et est nommée « approche à base de modèles ». Pour caractériser la dynamique des paramètres reflétant la dégradation, elle utilise un observateur d'état et des techniques de prédiction pour caractériser leurs évolutions futures.

Les étapes des deux approches sont résumées dans les sous-sections suivantes.

3.2.1 Approche de pronostic markovienne

Les premiers travaux de pronostic fondés sur les MMCs sont de Chinnam et Baruah [Chinnam and Baruah, 2003; Baruah and Chinnam, 2005]. L'objectif était d'estimer en temps réel, la durée de vie résiduelle sur un outil d'usinage. Par la suite, les MMCs ont été utilisés pour estimer la durée de vie résiduelle sur des roulements mécaniques [Zhang et al., 2005]. Depuis ces travaux, les MMCs ont été utilisés dans des approches différentes [Peng and Dong, 2011; Giantomassi et al., 2011; Tobon-Mejia et al., 2011, 2012]. Ces différents travaux se différencient selon les architectures des modèles considérés. Par exemple, les auteurs dans [Tobon-Mejia et al., 2012] s'appuient sur la topologie du MMC pour définir le chemin le plus court et le chemin le plus long en considérant seulement une visite par état. La durée de vie résiduelle a été estimée par l'addition des durées de séjour dans les états. L'originalité de ce travail réside dans le fait, que les durées de séjour dans les différents états du modèle sont apprises à partir des séquences d'états issues des données d'apprentissage et cela pour chaque séquence de données. Dans [Camci and Chinnam, 2010], les auteurs ont eu recours à la simulation de Monté Carlo. Cette approche a été également utilisée dans les travaux de [Giantomassi et al., 2011]. L'originalité est qu'aucune hypothèse concernant le modèle n'est considérée. Les auteurs dans [Peng and Dong, 2011] ont intégré un facteur de vieillissement supposé connu dans le modèle, lequel est associé au système Grey Model.

Nous savons que la probabilité de retrouver le MMC dans l'état défaillant tend vers 1 lorsque le nombre de transitions tend vers l'infini. Dans la littérature, un tel état est dit : état absorbant. Dans ce qui suit, nous allons introduire quelques définitions et le comportement asymptotique qui permet de calculer le nombre moyen de transitions que met le modèle pour être dans l'état correspondant à la défaillance du système.

Définitions et comportement asymptotique [Hêche et al., 2003; Prum, 2012; Bouleau, 1988]

Définition 1 : on dit qu'un état $j \in S$ est accessible depuis un autre état $i \in S$, s'il existe un temps $n \in \mathbb{N}$ tel que $a_{ij}^n \geq 0$; c'est à dire que partant de i , j est atteint en un nombre n fini de pas.

Définition 2 : un état $i \in S$ est dit absorbant si $a_{ii} = 1$ et donc nécessairement $a_{ij} = 0$ pour tout $j \neq i$. Un modèle de Markov est dit absorbant, s'il existe un état absorbant accessible.

Pour l'estimation *du nombre moyen avant absorption*, nous conviendrons de numérotter les états de manière à placer d'abord les $q = N - r$ états non absorbants puis les r états absorbants. La matrice de transition A prend alors la forme canonique suivante :

$$A = \begin{pmatrix} Q & R \\ 0 & I \end{pmatrix} \quad (3.1)$$

où Q est une matrice de taille $q \times q$, R est une matrice de taille $q \times r$, 0 désigne la matrice nulle de taille $r \times q$, et I la matrice identité de taille r . Il est facile de montrer par récurrence que :

$$A^n = \begin{pmatrix} Q^n & [I + Q + \dots + Q^{n-1}]R \\ 0 & I \end{pmatrix} \quad (3.2)$$

$a_{ij}^n = 1$ est la probabilité d'arriver à l'état j en partant de l'état i , après n transitions.

Sachant, que la probabilité d'atteindre après un certain nombre de transitions un état absorbant est de 1. Nous obtenons alors :

$$\lim_{n \rightarrow \infty} Q^n = 0 \quad (3.3)$$

La matrice carrée $I - Q$ est inversible, et son inverse vaut :

$$[I - Q]^{-1} = \sum_{k=0}^{\infty} Q^k \quad (3.4)$$

La matrice $N = [I - Q]^{-1}$, est la matrice fondamentale du modèle. Nous obtenons pour la $\lim_{n \rightarrow \infty}$ de l'équation 3.2 :

$$\lim_{n \rightarrow \infty} A^n = \begin{pmatrix} 0 & NR \\ 0 & I \end{pmatrix} \quad (3.5)$$

En conséquence, l'élément de matrice n_{ij} de N représente le nombre moyen de périodes séjour-nées dans l'état transitoire j pour une chaîne débutant son évolution dans l'état transitoire i .

Partant de l'état transitoire i , le nombre moyen de transitions avant d'atteindre un état absorbant (persistant) est égale à la somme des termes de la i ème ligne de N .

Estimation de la durée de vie résiduelle : les différentes étapes pour l'établissement du pronostic peuvent être résumées sur la figure 3.1, page 81.




FIGURE 3.1 – Les différentes étapes adoptées pour le pronostic.

Cette approche est une extension de l'approche de diagnostic. Elle repose sur les deux phases suivantes :

- *Phase d'apprentissage (hors-ligne)* : dans cette phase, nous calculons les durées moyennes de séjour dans les différents états constituant le modèle avant défaillance, en plus de la détermination des centres des classes et l'apprentissage du MMC nécessaire à la phase de diagnostic.
- *Phase d'exploitation (en-ligne)* : à partir de la séquence d'états estimée dans la phase de diagnostic (à l'aide de l'algorithme de Viterbi) et les durées moyennes de séjour, les valeurs des RUL sont calculées de la manière suivante :

$$RUL_{t_p} = E_{il} - t_i \quad (3.6)$$

E_{il} le temps moyen de transitions en partant de l'état i vers l'état défaillant l .
 i , t_i respectivement l'état courant et la durée passée dans cet état.

L'intervalle de confiance associée à la RUL est calculé en utilisant les équations suivantes :

$$RUL_{t_pmax} = E_{il}(1 + n) - t_i \quad (3.7)$$

$$RUL_{t_pmin} = E_{il}(1 - n) - t_i \quad (3.8)$$

avec n le coefficient de confiance. La valeur encadrant la moyenne avec une probabilité de 0.1 est considérée dans la suite.

3.2.2 Approche à base de modèles

Diverses approches à base de modèles, permettant le pronostic sous l'hypothèse que l'état de dégradation n'est pas mesuré, ont été présentées dans la littérature [Chelidze et al., 2002; Cusumano et al., 2002; Chatterjee et al., 2002; Daigle and Goebel, 2011; Sankararaman et al., 2014]. A titre d'exemple, dans [Chelidze et al., 2002], le système est modélisé de façon hiérarchique, avec un sous-système observable à dynamique rapide « fast-time » couplé à un sous-système à dynamique lente « slow-time » caractérisant la dégradation. Le suivi de la dégradation et l'obtention de sa dynamique sont réalisés par un filtre de Kalman. Dans [Gucik-Derigny, 2011; Guzik-Derigny et al., 2016], l'estimation de la dynamique est vue comme un problème de reconstruction d'entrées inconnues en temps fini et de dérivation numérique. Une étude comparative de trois observateurs à entrée inconnue a été réalisée. Ces méthodologies ont été illustrées sur un système électromécanique. Dans [Daigle and Goebel, 2011], la méthodologie adoptée est fondée sur un filtre particulaire. Elle a été appliquée sur un modèle d'une vanne pneumatique présentant différents mécanismes de dégradation.

Dans cette approche, nous considérons la classe de systèmes non linéaires sous la forme suivante :

$$\begin{cases} \dot{x} = g(x, \theta, u) \\ y = h(x, u) \end{cases} \quad (3.9)$$

avec x est le vecteur d'états, θ le vecteur des paramètres nominaux, u le vecteur d'entrée du modèle et y le vecteur de sortie. g et h sont des fonctions supposées connues.

L'approche proposée s'appuie sur l'architecture de pronostic présentée dans [Daigle and Goebel, 2011; Sankararaman et al., 2014].




FIGURE 3.2 – Architecture de pronostic à base de modèles.

Cette approche se décline en deux phases :

- Une phase d'estimation qui consiste à estimer les états et les paramètres du modèle. Une solution classique est de concevoir un observateur d'état étendu [Auger et al., 2013]. Une telle estimation d'états peut être réalisée également par les méthodes de filtrage [Daigle et al., 2012a].

- La seconde phase consiste à déterminer l'instant où la performance souhaitée ne sera plus satisfaite pour un temps de mission défini. La prédiction de la performance du système commence par la détermination des modèles décrivant la dynamique des paramètres. Par la suite, l'estimation de la durée de vie résiduelle est réalisée par la comparaison de la performance obtenue par la simulation et celle désirée.

Dans ce travail, la dynamique des paramètres est déterminée par des méthodes d'inférences statistiques (si la structure de la loi de variation est connue) et par l'utilisation de méthodes de prédiction de séries temporelles à base d'apprentissage lorsque la structure est inconnue. En effet, en général on ne dispose pas de lois de comportement des différents paramètres.

La section suivante présente plus en détails les deux phases et les outils pouvant être utilisés.

3.3 Étapes de l'approche à base de modèles

3.3.1 Phase d'estimation

Cette phase consiste à exploiter les différentes mesures collectées sur le système afin d'estimer les états et les paramètres pertinents non mesurés et capables de caractériser la performance du système. En effet, une dégradation sur un système a pour effet de perturber et d'affecter ses paramètres caractéristiques. Cette situation se traduit par la variation d'un ou plusieurs d'entre eux. Pour réaliser cette phase, nous avons utilisé un observateur d'état augmenté par le vecteur de paramètres.

$$\begin{cases} \dot{\hat{X}} = \hat{g}(\hat{X}, u) \\ \hat{y} = \hat{h}(\hat{X}, u) \end{cases} \quad (3.10)$$

$\hat{X} = [\hat{x}; \theta_{obs}]$ est le vecteur d'état estimé augmenté avec θ_{obs} le vecteur de paramètres estimé, u le vecteur d'entrée du modèle et $\hat{y}$ le vecteur de sortie estimé.

3.3.2 Phase de pronostic

Le système est considéré défaillant lorsqu'il n'est plus capable de satisfaire la performance souhaitée (figure 3.3, page 84). La performance peut être exprimée à travers un ensemble de contraintes C_i liées aux valeurs des états, aux paramètres et aux conditions opérationnelles $(\hat{x}, \hat{\theta}, u)$, avec $C_i = 1$ si la contrainte est satisfaite et 0 sinon. Ces contraintes combinées peuvent être exprimées comme suit :

$$Perf(t) = \begin{cases} 1 & \forall i \ C_i(\hat{x}, \hat{\theta}, u, t) = 1 \\ 0 & \text{sinon} \end{cases} \quad (3.11)$$

En conséquence, la durée de la vie résiduelle à un instant t_p est définie par :

$$RUL_{t_p} = \inf(t \in R : t \geq t_p \wedge Perf(t) = 0) - t_p \quad (3.12)$$

Cette estimation nécessite la connaissance d'un modèle de variation des paramètres. Pour l'identifier, nous proposons d'exploiter en ligne l'historique des estimés obtenus dans la première phase [Aggab et al., 2016].




FIGURE 3.3 – Les variables considérées dans la phase de pronostic.

Principe : soit une série temporelle de paramètres $\theta_{obs\ 1}, \theta_{obs\ 2}, \dots, \theta_{obs\ t-i}, \dots, \theta_{obs\ t_p}$, nous avons besoin de connaître la prédiction aux instants $t > t_p$ ($\hat{\theta}_{t_p+1}, \hat{\theta}_{t_p+2}, \dots, \hat{\theta}_{t_p+i}, \dots, \hat{\theta}_t$). Pour leurs obtentions, nous faisons recours aux méthodes d'estimation paramétrique d'inférence statistique et aux méthodes de prédiction de séries temporelles. Les premières méthodes supposent la connaissance de la loi d'évolution alors que les méthodes de prédiction de séries temporelles ne considèrent aucune information. Le principe est illustré sur la figure 3.4, page 84.




FIGURE 3.4 – Principe de prédiction de la dynamique de paramètre.

Estimation par inférence statistique : supposons que l'incrément entre deux instants t_i et t_{i+1} est une variable aléatoire suivant une distribution de probabilité. Le problème à résoudre consiste à déterminer une fonction de densité $f(\theta|\phi)$ où seul le vecteur de paramètres $\phi = \phi_1 \dots \phi_n$ est inconnu. Une fois le modèle paramétrique construit, l'objectif est d'effectuer une inférence sur le paramètre inconnu ϕ . Dans la littérature, plusieurs méthodes d'inférences statistiques sont possibles [Greenland, 2011]. Nous avons examiné les plus connues : la méthode de maximum de vraisemblance et l'estimation bayésienne.

Méthode d'estimation par le maximum de vraisemblance : l'information provenant des données d'observation est l'unique source utilisée pour estimer les paramètres de la loi d'évolution. Elles sont des réalisations de la variable aléatoire. Elles servent à faire porter l'inférence sur les

paramètres ϕ . Dans cette méthode, une fonction de vraisemblance (en anglais : likelihood) est utilisée. Elle s'écrit comme suit :

$$l(\phi|\theta) = f(\theta|\phi) \quad (3.13)$$

Le principe de la méthode consiste à estimer les paramètres en cherchant les valeurs de ϕ maximisant la vraisemblance. L'estimateur qui maximise cette fonction, appelé maximum de la vraisemblance (MV) est donné par :

$$\hat{\phi}_{MV} = \arg_{\phi} \max \{l(\phi|\theta)\} \quad (3.14)$$

Méthodes d'estimation bayésienne : par opposition à l'estimation paramétrique basée sur le maximum de vraisemblance, l'estimation bayésienne suppose que les paramètres d'intérêts ϕ sont considérés comme des variables aléatoires caractérisées par des densités de probabilité $\pi(\phi)$. Ces densités s'appellent les densités *a priori*. La formule de Bayes (équation 2.36) est utilisée afin d'estimer les paramètres *a posteriori*. Elle donne le résultat suivant :

$$\pi(\phi|\theta) = \frac{f(\theta|\phi)\pi(\phi)}{\int_{\phi}^{\infty} \pi(\phi)d(\phi)} \quad (3.15)$$

Les paramètres de la distribution a priori (nommés les hyperparamètres) sont déterminés par inférence bayésienne dite « hiérarchique ». L'idée consiste à considérer les hyperparamètres de la densité a priori comme des variables aléatoires qui dépendent d'autres hyperparamètres [Robinson, 2001]. En général, il est très difficile d'appliquer une inférence bayésienne analytiquement dans le cas où les distributions de probabilité sont non conjuguées (la distribution a priori et la distribution a posteriori n'ont pas la même forme). Par conséquent, plusieurs algorithmes sont proposés dans la littérature. Les algorithmes Metropolis, Hastings et Gibbs sont parmi les plus utilisés [Beichl and Sullivan, 2000]. Ces algorithmes offrent des méthodes d'échantillonnage à partir de distributions de probabilité complexes. Ils sont présentés en annexe A.3.

Méthodes de prédiction de séries temporelles : dans la littérature, les méthodes de prédiction de séries temporelles sont nombreuses. Les méthodes de l'Intelligence Artificielle (IA) ont montré de meilleures performances que les méthodes conventionnelles [Yam et al., 2001; Wang and Coit, 2004]. Dans l'ensemble, les réseaux de neurones adaptatifs (ANFIS) et les machines à vecteurs de support (SVM) sont des approches efficaces pour la prévision de séries temporelles. L'intérêt de ces méthodes réside dans leurs aptitudes à apprendre et à capturer les relations potentielles entre les données même si le comportement est complexe. Ces modèles sont appris par un ensemble d'échantillons (entrées/sorties) directement extrait de la séquence d'observations $\theta = (\theta_{obs\ 1}, \theta_{obs\ 2}, \theta_{obs\ 3}, \dots, \theta_{obs\ tp})$. Chaque entrée/sortie, représente un vecteur temporel de taille $r + 1$, avec r la taille du vecteur d'entrée.

La prédiction des valeurs futures d'une séquence d'observations à l'horizon $tp + l$ est donnée comme suit :

La première valeur à $tp + 1$ est donnée par :

$$\hat{\theta}_{tp+1} = f(\theta_{obs\ tp-r}, \dots, \theta_{obs\ tp-1}, \theta_{obs\ tp}) \quad (3.16)$$

Ensuite et de manière récursive, le processus est répété jusqu'à $tp + l$.

$$\hat{\theta}_{tp+l} = f(\hat{\theta}_{tp+l-r}, \dots, \hat{\theta}_{tp+l-2}, \hat{\theta}_{tp+l-1}) \quad (3.17)$$

Avant de procéder à la régression par un SVM ou la prédiction par ANFIS, nous transformons l'ensemble des estimations $\theta = (\theta_{obs\ 1}, \theta_{obs\ 2}, \theta_{obs\ 3}, \dots, \theta_{obs\ tp})$ en une matrice composée de $r + 1$ colonnes et N lignes.

La régression par SVM : cette régression découle directement des travaux de Vapnik [Vapnik, 2013] en théorie de l'apprentissage. La procédure principale de construction de ce modèle comprend le choix des échantillons représentant les vecteurs de support et la définition de leurs poids. Elle consiste à trouver la fonction f écrite comme suit :

$$f(\theta) = w \cdot \Phi(\theta) + b \quad (3.18)$$

avec θ le vecteur d'entrée, w le vecteur des poids, b le biais et Φ une fonction de projection qui permet le passage à un espace de dimension supérieure dans lequel le problème devient linéaire.

Le problème d'optimisation présenté par Vapnik [Vapnik, 2013] est le suivant :

$$\text{minimisation } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \zeta'_i) \quad (3.19)$$

$$\text{contraintes } \begin{cases} y_i - w^t \Phi(\theta_i) - b \leq \varepsilon + \zeta_i \\ w^t \Phi(\theta_i) + b - y_i \leq \varepsilon + \zeta'_i \\ \zeta_i, \zeta'_i \geq 0 \end{cases} \quad (3.20)$$

où ζ_i et ζ'_i représentent les variables de relâchement sur la fonction de précision ε afin de gérer les contraintes irréalisables du problème d'optimisation. C est un paramètre de contrôle entre la complexité et l'erreur tolérée au-delà de la précision ε (figure 3.5, page 86). C'est ce compromis qui permet de contrôler un éventuel bruit présent dans les réalisations. Cet ajustement apporte une souplesse à la méthode par rapport à la forme de la fonction à approcher par régression.




FIGURE 3.5 – Principe de la régression par SVM.

Pour la résolution de ce problème d'optimisation, la fonction est réécrite en utilisant les multiplieurs de Lagrange (a, a') , comme suit :

$$\text{maximisation } L = - \sum_{i,j=1}^N (a'_i - a_i)(a'_j - a_j) \mathbb{K}(\theta_j, \theta_i) - \varepsilon \sum_{i=1}^N (a'_i + a_i) + \sum_{i=1}^N y_i(a'_i + a_i) \quad (3.21)$$

$$\text{contraintes } \begin{cases} \sum_{i=1}^N y_i(a'_i + a_i) \\ a'_i, a_i \in [0, C] \end{cases} \quad (3.22)$$

D'où la solution qui prend la forme suivante :

$$f(\theta) = \sum_{i=1}^n (a'_i - a_i) \mathbb{K}(\theta, \theta_i) + b \quad (3.23)$$

Avec $\mathbb{K}$, une fonction noyau et n le nombre de vecteurs supports.

Les détails et les applications de la régression par SVM pour la prédiction peuvent être consultés dans [Benkedjough et al., 2015, 2013; Soualhi et al., 2015].

La prédiction par une modélisation adaptative neuro-floue : le réseau adaptatif à base de système d'inférence floue, connu sous le nom de modèle ANFIS est un approximateur universel [Jang et al., 1997]. Il a été utilisé dans différentes applications de prédictions. Le modèle ANFIS est la combinaison d'un système d'inférence floue (SIF) et de réseaux de neurones (RN). Il applique le mécanisme d'apprentissage des RN sur des techniques d'inférences floues. En d'autres termes, ANFIS est un SIF dont les paramètres des fonctions d'appartenances sont ajustés en utilisant l'algorithme d'apprentissage de rétropropagation.

Considérons la figure 3.6, page 88 pour décrire la structure du prédicteur ANFIS. La structure contient cinq couches, chacune comportant plusieurs nœuds . Les nœuds carrés (adaptatifs) contiennent des paramètres, alors que les nœuds circulaires (constants) n'ont pas de paramètres.

Couche 1 (fuzzification) : chaque nœud se comporte comme une fonction d'appartenance. La fonction d'appartenance peut être une fonction (triangle, trapèze, sigmoïde, gaussienne...). Par exemple, pour une fonction gaussienne, nous avons :

$$\mu_{A_i}(X) = \exp \left(- \left[\frac{X - m_i}{b_i} \right]^2 \right) \quad (3.24)$$

avec m_i, b_i , l'ensemble des paramètres des gaussiennes et X est l'entrée du nœud A_i .

Couche 2 (pondération des règles floues) : dans cette couche, chaque nœud est associée à une règle floue et réalise une T – norme qui lui permet de définir le poids de la règle. La T – norme la plus utilisée est généralement l'opérateur produit (il existe d'autres normes : max, min...).

$$w_k = \mu_{A_i}(X) \cdot \mu_{B_i}(Y), k = 1, 2 \quad (3.25)$$

Couche 3 (normalisation) : c'est la couche dans laquelle chaque nœud calcule le degré d'appartenance normalisé à une règle floue donnée. Le résultat obtenu représente la participation de




FIGURE 3.6 – Architecture de ANFIS [Jang et al., 1997].

chaque règle floue au résultat final. Cette couche renvoie des sorties normalisées de défuzzification.

$$\bar{w}_k = \frac{w_k}{w_1 + w_2} \quad (3.26)$$

Couche 4 (défuzzification) : chaque nœud k de cette couche est un nœud adaptatif qui correspond à l'entrée initiale pondérée par le degré d'appartenance normalisé de la règle floue (approche de Takagi-Sugeno).

$$\overline{w_k f_k} = \bar{w}_k (p_k X + q_k Y + r_k) \quad (3.27)$$

où w_k est la sortie normalisée de la couche 3, et p_k, q_k, r_k sont l'ensemble des paramètres de sortie de la règle k .

Couche 5 (somme) : elle est composée d'un seul nœud fixe circulaire appelé (Σ) recevant la somme des sorties de tous les nœuds de défuzzification. Elle fournit la sortie du modèle ANFIS.

$$f = \bar{w}_1 f_1 + \bar{w}_2 f_2 \quad (3.28)$$

Comme il n'y a pas de règle pour définir le nombre des fonctions d'appartenances utilisées avec les modèles ANFIS et qu'un nombre important de fonctions d'appartenances et de paramètres augmente le temps de calcul [Keskin et al., 2006], la méthode d'essai-erreur pour le choix peut être utilisée [Shirmohammadi et al., 2013]. Une explication plus détaillée sur la procédure d'apprentissage peut être trouvée dans [Jang et al., 1997; Jang, 1993]. Leurs utilisations pour la prédiction peuvent être consultées dans [Silva et al., 2014; Soualhi et al., 2014; Dragomir et al., 2010].

Mesure de la performance des méthodes de prédiction : la performance d'une méthode de prédiction peut être évaluée par l'utilisation de différents critères. Les principaux sont :

- Erreur quadratique moyenne RMSE (Root Mean Square Error) :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\theta_{t_p+i} - \hat{\theta}_{t_p+i})^2} \quad (3.29)$$

- Erreur moyenne absolue en pourcentage MAPE (Mean Absolute Pourcentage Error) :

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{\theta_{t_p+i} - \hat{\theta}_{t_p+i}}{\theta_{t_p+i}} \right| \quad (3.30)$$

- Le coefficient de corrélation R :

$$R = \frac{\sum_{i=1}^N (\theta_{t_p+i} - \bar{\theta})(\hat{\theta}_{t_p+i} - \bar{\hat{\theta}})}{\sqrt{\sum_{i=1}^N (\theta_{t_p+i} - \bar{\theta})^2 \sum_{i=1}^N (\hat{\theta}_{t_p+i} - \bar{\hat{\theta}})^2}} \quad (3.31)$$

où $(\theta_{t_i}, \bar{\theta})$ et $(\hat{\theta}_{t_i}, \bar{\hat{\theta}})$ représentent respectivement la valeur et la moyenne des valeurs réelles et prédites. N est le nombre total d'échantillons.

L'intérêt des différentes mesures d'erreurs à été discuté dans la littérature [De Gooijer and Hyndman, 2006]. Il en ressort qu'il n'existe pas de mesure satisfaisant à la fois des critères de pertinence, de facilité de calcul et de limite d'utilisation.

La mesure retenue pour évaluer la qualité de la prédiction est l'erreur moyenne absolue en pourcentage. Elle offre l'avantage de tenir compte de l'ordre de grandeur de l'erreur de prédiction [De Gooijer and Hyndman, 2006; Soualhi, 2013; Dragomir, 2008].

3.4 Illustration des approches

Dans cette section, nous illustrons les deux approches de pronostic sur le système de régulation de niveau d'eau détaillé dans le chapitre précédent.

3.4.1 Application de l'approche markovienne

L'approche décrite dans la sous-section 3.2.1 a été appliquée sur des données obtenues par la simulation de dégradation du système de régulation de niveau d'eau. Cette approche nécessite la synthèse d'un observateur, l'apprentissage du MMC et le calcul des durées moyennes de séjour. La RUL est ensuite estimée en utilisant l'équation 3.6 et la séquence d'états obtenue par l'algorithme de Viterbi. Les différentes étapes et les algorithmes nécessaires à leurs réalisations sont rappelés dans la figure 3.7, page 90.

À titre d'illustration, nous présentons le résultat sur un exemple de dégradation issue de la




FIGURE 3.7 – Les différentes étapes adoptées pour le pronostic.

base de test. L'ensemble des données d'apprentissage est constitué de 40 essais de dégradations (figure 3.8 (a), page 90) jusqu'à défaillance de la pompe pour des missions à deux consignes avec une évolution aléatoire. Les consignes sont de 10 – 15, de 10 – 20 et de 10 – 25. Les instants de défaillance du système et les valeurs de résidu correspondantes pour les différents essais sont présentés dans la figure 3.8 (b), page 90. Nous observons que les évolutions de dégradation simulées sont différentes et que la valeur de résidu ne reflète pas le niveau de dégradation atteint par le système.




FIGURE 3.8 – L'ensemble des (a) trajectoires des capacités simulées et (b) instants versus résidu correspondant.

3.4. ILLUSTRATION DES APPROCHES

L'évolution de la capacité de la pompe jusqu'à sa défaillance et la moyenne du résidu généré par l'observateur de l'exemple d'illustration sont présentées dans la figure 3.9, page 91.




FIGURE 3.9 – L'évolution (a) de la capacité de la pompe et (b) de la moyenne du résidu.

Nous remarquons que le suivi de l'évolution de résidu ne reflète pas le niveau de dégradation atteint par le système. Il est autour du zéro en absence de dégradations et il augmente en présence de dégradations avec une certaine fluctuation. Cela est dû au changement de consigne et au bruit de mesure.

La séquence d'états et l'estimation de la RUL ainsi obtenues sont présentées dans les figures 3.10 (a, b), page 91. Le nombre de classes est fixé à 4. Ce choix se justifie par le fait que nous exploitons le résultat obtenu dans le chapitre II. Les RUL estimées sont affichées en rouge, l'évolution de la vraie RUL en bleu et les évolutions qui caractérisent l'intervalle de confiance pour un $\alpha = 0.3$ (écart de 30% par rapport à la vraie RUL) en vert.




FIGURE 3.10 – Évolution de (a) la séquence d'états et (b) l'estimation de la durée de vie résiduelle (MMC).

Les résultats obtenus par la mise en œuvre des mesures de performance de pronostic sont présentés dans la table 3.1, page 92.

TABLE 3.1 – Mesures de performance de pronostic pour l'exemple (MMC).

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.70	0.82	0.62
<i>Precision</i>	186.66	316	556.10
<i>HP</i> ($\alpha=0.3$)	2811	2811	1813
$RA[T/4, T/2, 3T/4]$	[0.85 , 0.58, 0.18]	[0.73, 0.88 , 0.77]	[0.33, 0.81, 0.62]

Nous observons que les mesures de performance sont globalement correctes : l'exactitude et l'exactitude relative (RA) évaluées pour trois valeurs correspondant à $[T/4, T/2, 3T/4]$ sont relativement précises dans le cas de la RUL_{moy} . D'autre part, la valeur de la mesure de *HP* est élevée pour l'estimation de la RUL_{moy} et la RUL_{min} . Elle est égale à 2811s, cela signifie que dès le début, les RUL estimées sont dans l'intervalle de confiance. Cependant, les résultats sur la précision sont globalement faibles.

Pour évaluer la capacité de généralisation de l'approche, le résultat pour 100 partitionnements aléatoires sur l'ensemble des données (60 essais) décomposé comme suit : 2/3 pour l'apprentissage et 1/3 pour les tests, est présenté dans la table 3.2, page 92.

TABLE 3.2 – Mesures de performance de pronostic (MMC).

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.65	0.64	0.53
<i>Precision</i>	377.02	319	431.12
<i>HP</i> ($\alpha=0.3$)	2073.1	2304.6	1901
$RA[T/4, T/2, 3T/4]$	[0.66 , 0.56, 0.50]	[0.64, 0.56 , 0.42]	[0.37, 0.31, 0.1]

À partir de ces mesures de performance, nous pouvons conclure que l'utilisation de l'approche pour l'estimation de la RUL offre des résultats satisfaisants, comme le confirment les valeurs de l'exactitude et de *HP* indiquant que la RUL estimée s'insère dans l'intervalle de confiance rapidement. Cependant, les résultats sur la précision sont globalement faibles. Cela peut être expliqué par la grande variabilité sur les durées de vie des essais.

Il est important de regarder la robustesse de nos approches. En effet entre chaque produit d'une même série, il existe une variabilité intrinsèque. De manière à évaluer cette robustesse, nous avons généré des données avec des constantes de temps différentes. Dans la table 3.3, page 93 sont présentés les résultats obtenus pour trois valeurs différentes de la constante de temps de la pompe.

Pour un nombre de classes égal à 4, des essais parfaitement identiques en matière de sollicitation et de bruit de mesure, les résultats montrent que l'approche est robuste au changement du paramètre (τ_a).

L'approche peut également être utilisée lors de la synthèse d'un MMC flou. Pour un nombre de classes fixé à 3 (résultat chapitre II), la séquence d'états et l'estimation de la RUL obtenues pour l'exemple d'illustration sont présentées dans les figures 3.11 (a, b), page 93. Les résultats des mesures de performance de pronostic sont indiqués dans la table 3.4, page 93.

3.4. ILLUSTRATION DES APPROCHES

TABLE 3.3 – Robustesse de l’approche MMC

Performance	$\tau_a = 1$	$\tau_a = 1.5$	$\tau_a = 2.5$
<i>TFA</i>	0.064	0.0615	0.06
<i>TND</i>	3.85	3.87	3.92
<i>Accuracy</i>	0.67	0.67	0.67
<i>Precision</i>	263.26	263.23	263.15
<i>HP</i> ($\alpha=0.3$)	2661.7	2661.1	2660.7
$RA[T/4, T/2, 3T/4]$	[0.69, 0.59, 0.43]	[0.69, 0.59, 0.43]	[0.69, 0.59, 0.43]




FIGURE 3.11 – Évolution de (a) la séquence d’états et (b) l’estimation de la durée de vie résiduelle (MMC flou).

TABLE 3.4 – Mesures de performance pour l’exemple (MMC flou).

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.68	0.77	0.64
<i>Precision</i>	122.2	316.31	607.8
<i>HP</i> ($\alpha=0.3$)	2811	2811	1381
$RA[T/4, T/2, 3T/4]$	[0.82 , 0.73 , 0.56]	[0.78, 0.68, 0.87]	[0.39, 0.09, 0.82]

Les valeurs de l’exactitude et de *HP* indiquent que le résultat de pronostic est relativement de bonne qualité. De la même manière que le MMC, la capacité de généralisation est évaluée à partir des résultats de 100 partitionnements aléatoires sur l’ensemble des données. Les résultats obtenus sont présentés dans la table 3.5, page 93.

TABLE 3.5 – Mesures de performance (MMC flou).

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.62	0.65	0.54
<i>Precision</i>	366.2	300.36	432.12
<i>HP</i> ($\alpha=0.3$)	1904.9	2268.7	2025.1
$RA[T/4, T/2, 3T/4]$	[0.64, 0.46, 0.43]	[0.66 , 0.51 , 0.41]	[0.37, 0.29, 0.09]

Les résultats sont globalement satisfaisants. Ils sont sensiblement similaires à ceux obtenus par l’utilisation d’un MMC.

Dans cette sous section, nous avons mis en œuvre l’extension de l’approche de diagnostic au

pronostic en exploitant les propriétés des modèles de Markov. Cette approche repose sur la synthèse d'un observateur pour la génération d'un signal indicateur de dégradation. L'apprentissage de modèle en utilisant les algorithmes appropriés et l'exploitation de modèle appris pour l'estimation en ligne de l'état et de la RUL nous ont permis d'obtenir des résultats significatifs. Nous avons ainsi montré son applicabilité malgré une mauvaise précision. Cela pourrait être dû à la variabilité élevée des durées de vie des données d'apprentissage. Cette approche est une démarche intuitive, ce qui la rend intéressante pour des industriels.

3.4.2 Application de l'approche à base de modèles

Pour l'application et afin d'illustrer l'approche exposée dans la section 3.3, nous considérons cette fois-ci, que la capacité de la pompe diminue à partir de sa capacité nominale suivant un processus stochastique du type Gamma. Le choix d'une loi de dégradation usuelle est dans le but de pouvoir appliquer aisément l'approche, notamment l'estimation par inférence statistique. Le vecteur de paramètres est constitué seulement de la capacité de la pompe. La démarche reste utilisable pour un vecteur de taille supérieure, avec comme contrainte supplémentaire la caractérisation de la dépendance entre les différents comportements.

La perte de capacité est modélisée par un processus $\text{Gamma}(m(t), \beta)$ de tendance non linéaire avec $m(t)$ de la forme pt^q . Les valeurs de p , q et β sont respectivement égales à 0.01, 1.5 et 0.002. Ces valeurs seront utilisées pour les différents tests.

Pour évaluer la performance du système, nous considérons sa réponse temporelle. Le système est considéré défaillant au regard de la performance, si l'une des deux contraintes suivantes n'est plus satisfaite (figure 3.24, page 102).

- C_1 : contrainte liée au régime transitoire. Le système n'est plus capable lors d'un changement de consigne de satisfaire la condition : le temps nécessaire pour atteindre la zone $\pm 5\%$ de la taille de changement est inférieur à d_1 (dans nos exemples, égale à $1.5 \times$ temps de réponse obtenu dans les conditions nominales).
- C_2 : contrainte liée au régime permanent. Le système n'est plus capable de satisfaire la condition suivante : retrouver la zone $\pm 5\%$ dans un temps inférieur à d_2 (dans nos exemples, égale à la moitié du temps de réponse).




FIGURE 3.12 – Contraintes sur la performance du système.

Le processus de dégradation et les performances souhaitées étant formalisés, nous pouvons alors entamer la mise en œuvre des deux phases préalablement exprimées dans la sous-section 3.2.1.

Phase d'estimation : pour sa réalisation, nous avons utilisé un observateur augmenté par le paramètre K_a . Cet observateur est conçu de manière à exploiter la mesure du niveau d'eau du réservoir 2 et la valeur de la commande appliquée sur la pompe. L'objectif est de pouvoir estimer les états du système et le paramètre K_a . L'observateur étendu synthétisé s'écrit comme suit :

$$\begin{cases} \frac{d\hat{q}_{in}}{dt} = -\frac{1}{\tau_a}\hat{q}_{in} + \frac{\hat{K}_a}{\tau_a}u \\ \frac{d\hat{h}_1(t)}{dt} = \frac{1}{S_1}\hat{q}_{in}(t) - \frac{K_{v1}}{S_1}\sqrt{2g\hat{h}_1(t)} + L_1\tilde{h}_2 \\ \frac{d\hat{h}_2(t)}{dt} = \frac{K_{v1}}{S_1}\sqrt{2g\hat{h}_1(t)} - \frac{K_{v2}}{S_2}\sqrt{2g\hat{h}_2(t)} + L_2\tilde{h}_2 \\ \frac{d\hat{K}_a(t)}{dt} = L_3\tilde{h}_2 \end{cases} \quad (3.32)$$

avec $\tilde{h}_2 = h_2^m - \hat{h}_2$ est l'erreur d'estimation du niveau d'eau dans le réservoir 2. L_1 , L_2 et L_3 sont les gains de l'observateur.

L'erreur d'estimation $\tilde{h}_2$ et l'erreur d'estimation de la capacité de la pompe qui est en réalité non accessible à la mesure sont présentées (figure 3.14, page 96, figure 3.13, page 96). En cas d'absence de bruit sur la sortie et pour des conditions initiales différentes, les estimés sont présentés dans la figure 3.13. Dans le cas de présence de bruit de mesure, les estimés sont présentés dans la figure 3.14. Nous constatons que pour les valeurs des gains choisies, les estimations sont de bonne qualité.




FIGURE 3.13 – Erreur d'estimation sans bruit de mesure de (a) niveau d'eau du réservoir 2, (b) la capacité de la pompe.

Phase de pronostic : dans cette phase, nous estimons la durée avant que l'exigence de performance du système ne soit plus satisfaite. Cette estimation est réalisée sur la base de la




FIGURE 3.14 – Erreur d’estimation avec présence de bruit de mesure de (a) niveau d’eau du réservoir 2, (b) la capacité de la pompe.

connaissance a priori des conditions opérationnelles jusqu’à t_s . L’horizon de prédiction va ainsi de t_p à t_s où t_s est la durée de connaissance de la sollicitation (4000s dans notre cas). Le bruit est supposé suivre une loi normale $N(0, 2.5 \times 10^{-3})$. Les résultats obtenus par la mise en œuvre de l’approche de pronostic avec les différentes méthodes sont illustrés sur l’exemple de la figure 3.15, page 97.

Les trajectoires contenues dans la figure 3.15 montrent que le système satisfait les contraintes de performance souhaitées malgré la dégradation de la capacité de la pompe, et cela jusqu’à l’instant 3023. La figure 3.15 (e) illustre également la faible erreur d’estimation entre la capacité réelle et estimée après lissage. Le lissage est réalisée par la méthode Loess [Cleveland and Devlin, 1988], l’intérêt est d’obtenir une série de données qui suit une tendance et ainsi estimer ses paramètres à l’aide des méthodes d’inférences statistiques.

Estimation par le maximum de vraisemblance : l’estimation des paramètres par la méthode du maximum de vraisemblance pour le modèle étudié à partir d’accroissements s’écrit de la manière suivante :

$$\ln L(p, q, \beta) = \sum_i \frac{\beta^{(-p(t_i^q - t_{i-1}^q))}}{\Gamma(p(t_i^q - t_{i-1}^q))} \Delta x_i^{-1} e^{-\frac{\Delta x_i}{\beta}} \quad (3.33)$$

Pour l’exemple traité et après un lissage de la capacité estimée, nous obtenons les figures 3.16 et 3.17, page 98. La figure 3.16 représente l’évolution de l’estimation des différents paramètres (p , q et β) au cours de la dégradation. Les valeurs obtenues permettent d’estimer la valeur moyenne de K_a aux instants ($t > t_p$). La figure 3.17 représente la RUL estimée en rouge, l’évolution de la vraie RUL en bleu et les évolutions qui caractérisent l’intervalle de confiance pour un $\alpha = 0,3$ en vert.

Nous remarquons à partir de ces figures que nous estimons bien les paramètres (p , q et β), lesquels de manière générale sont proches des valeurs utilisées dans la simulation de la dégra-

3.4. ILLUSTRATION DES APPROCHES




FIGURE 3.15 – Trajectoire de : (a) la consigne, (b) la capacité de la pompe, (c) le niveau d'eau du réservoir 2, (d) l'erreur d'estimation de niveau d'eau du réservoir 2 et (e) l'erreur d'estimation entre la capacité réelle et estimée après lissage.

dation. Les estimations de la RUL réalisées avec ces paramètres offrent des résultats de bonne qualité. Les résultats obtenus par la mise en œuvre des mesures de performance de pronostic sont présentés dans la table 3.6. Le cas où le modèle utilisé pour la simulation dans la phase de prédiction possède une constante de temps de la pompe différente est également présenté.

3.4. ILLUSTRATION DES APPROCHES




FIGURE 3.16 – Estimation des paramètres (MV).




FIGURE 3.17 – Estimation de la RUL (MV).

Pour une bonne estimation de modèle du système $\tau_a = 1$, les valeurs de 0.85 pour l'exac-

TABLE 3.6 – Mesures de performance de pronostic (MV).

Performance	Valeur ($\tau_a = 1$)	Valeur ($\tau_a = 1.5$)	Valeur ($\tau_a = 2.5$)
<i>Accuracy</i>	0.85	0.81	0.65
<i>HP</i> ($\alpha=0.3$)	2930	2860	2560
<i>RA</i> [$T/4, T/2, 3T/4$]	[0.90, 0.99, 0.99]	[0.90, 0.99, 0.99]	[0.09, 0.04, 0.99]

titude et de 2930s pour l'horizon de pronostic, nous permettent de conclure que les résultats de l'approche sont satisfaisants. La précision n'est pas calculée, en raison de l'absence de certaines valeurs de la RUL (hypothèse sur la connaissance de la sollicitation sur 4000s). Pour des valeurs de $\tau_a \neq 1$, les résultats obtenus montrent qu'avec l'éloignement de comportement de modèle, les résultats ont tendance à être de moins au moins bons.

Méthodes d'estimation bayésienne : pour cette estimation, les distributions a priori des paramètres inconnus p , q et β jouent un rôle primordial. Elles peuvent être obtenues par la mise à contribution des expériences du passé, les intuitions ou l'expérience de l'expert. Les informations sont incertaines, donc il est naturel de les modéliser au travers des lois $\pi(\phi)$. En pratique, $\pi(\phi)$ peut-être une loi normale, Beta, Gamma,... Pour formaliser la connaissance a priori, nous avons supposé que les distributions des paramètres p , q et β suivent une loi normale. L'estimation de leurs hyperparamètres a été réalisée par la méthode de maximum de vraisemblance sur 50 essais simulés. Dans un premier temps, pour la connaissance a priori, aucune valeur des paramètres inconnus n'a été privilégiée (loi a priori non informative). Le même poids est ainsi attribué aux valeurs possibles des paramètres (le nombre d'échantillons est de 1000). Dans un second temps, les probabilités a priori des paramètres inconnus ont été prises en considération. Dans la démarche, deux stratégies portant sur la non-actualisation ou l'actualisation des moyennes des paramètres inconnus ont été testées. Soit les paramètres obtenus a priori ne changent pas d'un instant à l'autre (la vraisemblance reste la même), soit les paramètres obtenus a posteriori sont utilisés pour simuler les données de vraisemblance pour l'instant subséquent. L'écart type des paramètres peut aussi être sujet à actualisation.

Pour la loi a priori non informative, l'évolution de l'estimation des paramètres p , q et β et les estimations de la durée de vie résiduelle sans et avec actualisation sont présentées dans les

figures 3.18 et 3.19, page 99. Les résultats pour le cas sans actualisation sont affichés en points rouges. Le cas avec actualisation sont affichés en points bleus. Les mesures de performance sont présentées dans la table 3.7, page 99. La table 3.8, page 99 présente quant à elle, les résultats obtenus lors de la simulation avec différentes valeurs de τ_a pour le cas avec actualisation.




FIGURE 3.18 – Estimation des paramètres (non informative). FIGURE 3.19 – Estimation de la RUL (non informative).

TABLE 3.7 – Mesures de performance de pronostic (non informative).

Performance	Non actualisée	Actualisée
<i>Accuracy</i>	0.86	0.92
<i>Precision</i>	263.61	356.14
<i>HP</i> ($\alpha=0.3$)	2960	2920
<i>RA</i> [$T/4, T/2, 3T/4$]	[0.92, 0.88, 0.85]	[0.95, 0.92, 0.99]

TABLE 3.8 – Mesures de performance de pronostic (non informative actualisée).

Performance	Valeur ($\tau_a = 1$)	Valeur ($\tau_a = 1.5$)	Valeur ($\tau_a = 2.5$)
<i>Accuracy</i>	0.92	0.87	0.68
<i>Precision</i>	356.14	916.90	991.18
<i>HP</i> ($\alpha=0.3$)	2920	2910	2380
<i>RA</i> [$T/4, T/2, 3T/4$]	[0.95, 0.92, 0.99]	[0.92, 0.92, 0.99]	[0.44, 0.16, 0.99]

Nous constatons que lorsque la moyenne de la connaissance a priori de la dégradation est mise à jour, les résultats sont meilleurs que ceux obtenus sans l'actualisation 3.7, page 99. En effet, les moyennes des paramètres actualisés permettent de tirer des échantillons qui se rapprochent le plus des valeurs réelles. Nous constatons également qu'une bonne estimation de modèle de comportement impacte sur les résultats des pronostics réalisés.

Dans le cas où les probabilités sont prises en compte, l'évolution des paramètres et les résultats de l'estimation de la RUL sont présentés dans les figures 3.20 et 3.21, page 100. Les mesures de performance sont présentées dans les tables 3.9, page 100 et 3.10, page 100. Nous avons le même constat que dans le cas de la loi a priori non informative. La mise à jour des paramètres influe sur la qualité d'ajustement du modèle et de surcroît, sur l'estimation de la RUL. Les pronostics réalisés sont de meilleure qualité lorsque le modèle estimé représente

3.4. ILLUSTRATION DES APPROCHES





FIGURE 3.20 – Estimation des paramètres (informative). FIGURE 3.21 – Estimation de la RUL (informative).

TABLE 3.9 – Mesures de performance de pronostic (informative).

Performance	Non actualisée	Actualisée
<i>Accuracy</i>	0.86	0.92
<i>precision</i>	143.68	206.65
<i>HP</i> ($\alpha=0.3$)	3010	3010
<i>RA</i> [$T/4, T/2, 3T/4$]	[0.83, 0.83, 0.42]	[0.96 , 0.87 , 0.99]

TABLE 3.10 – Mesures de performance de pronostic (informative actualisée).

Performance	Valeur ($\tau_a = 1$)	Valeur ($\tau_a = 1.5$)	Valeur ($\tau_a = 2.5$)
<i>Accuracy</i>	0.92	0.88	0.67
<i>precision</i>	206.65	869.82	994.37
<i>HP</i> ($\alpha=0.3$)	3010	2870	2560
<i>RA</i> [$T/4, T/2, 3T/4$]	[0.96 , 0.87, 0.99]	[0.93, 0.99 , 0.88]	[0.09, 0.16, 0.99]

fidèlement le système ($\tau_a = 1$).

A partir des différents résultats présentés (tables 3.6-3.9), nous remarquons que l'apport d'une connaissance sur les paramètres du modèle (perte de capacité de la pompe) a un effet sur les résultats de l'approche de pronostic. Cette constatation est tout à fait logique. Pour les différentes stratégies considérées, les meilleurs résultats ont été obtenus lors de la prise en compte de la probabilité dans l'information a priori avec actualisation des moyennes des paramètres (table 3.9). Cette prise en compte améliore sensiblement les résultats obtenus (avec actualisation) mais sans la prise en considération de probabilité des valeurs possibles (table 3.7). Cela traduit le fait que la stratégie d'actualisation du modèle augmente l'influence de la vraisemblance et rend la distribution a priori moins informative.

La régression par SVM : comme il a été mentionné dans la section 3.5, la régression par SVM nécessite la construction de la matrice d'apprentissage à partir des estimations ($\theta_{obs\ 1}, \theta_{obs\ 2}, \dots, \theta_{obs\ t-i}, \dots, \theta_{obs\ tp}$) obtenue dans la phase d'estimation. Cette phase commence à partir de t_p initial = 100s. Cela permet de pouvoir disposer d'un volume suffisant d'observations pour alimenter l'outil de prédiction. Par conséquent, nous avons choisi $r = 5$, le pas égale à 1 et une fonction de noyau polynomiale. Nous avons commencé par étudier la qualité des prédictions. La figure 3.22, page 101 représente les évolutions de l'erreur MAPE et de sa distribution pour des horizons de temps différents.

3.4. ILLUSTRATION DES APPROCHES




FIGURE 3.22 – Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (régression par SVM).

Nous remarquons que l'augmentation de l'étendue de l'historique augmente la qualité de la prédiction. D'autre part, les modèles donnent des résultats satisfaisants à court et à moyen terme et faible à long terme ($Pred = t + 500$).

Les résultats obtenus par la mise en œuvre de l'approche sont représentés dans la figure 3.23, page 101.




FIGURE 3.23 – Estimation de la RUL (régression par SVM).

Les mesures de performance associées sont indiquées dans la table 3.11, page 102.

Les résultats montrent que les pronostics réalisés sont de bonne qualité pour des horizons de temps d'analyse plus élevée. En effet, ces performances sont liées au fait, que l'estimation de

TABLE 3.11 – Mesures de performance de pronostic (régression par SVM).

Performance	Valeur ($\tau_a = 1$)	Valeur ($\tau_a = 1.5$)	Valeur ($\tau_a = 2.5$)
<i>Accuracy</i>	0.68	0.72	0.67
<i>HP</i> ($\alpha=0.3$)	2140	2650	2480
<i>RA</i> [$T/4, T/2, 3T/4$]	[-Inf, 0.88 , 0.99]	[-Inf, 0.88 , 0.99]	[0.16, 0.16, 0.99]

la progression de la capacité est de meilleure qualité avec un historique plus élevé et pour un horizon de prédiction plus faible. Pour les valeurs de $\tau_a \neq 1$, les résultats peuvent être considérés meilleurs au vu de l'exactitude et la mesure HP, mais au regard des exactitudes relatives, il apparaît que pour des horizons de temps d'analyse élevée, plus le modèle estimé est proche de modèle du système, mieux est le pronostic.

Prédiction par ANFIS : les paramètres de réglage pour ANFIS sont similaires à ceux définis pour la régression par SVM ($r = 5$, pas = 1 et t_p initial = 100s). Les fonctions d'appartenance choisies sont du type gaussien, au nombre de 3 pour une inférence linéaire (Sugeno). Comme pour la régression par SVM, nous commençons par présenter l'évolution de l'erreur MAPE et sa densité de probabilité (figure 3.24, page 102). Le constat est similaire à celui de la régression par SVM, la qualité de la prédiction est impactée par l'étendue de l'historique et l'horizon de prédiction.




FIGURE 3.24 – Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (ANFIS).

L'estimation de la RUL et les mesures de performance de pronostic sont présentées dans la

figure 3.25, page 103 et la table 3.12, page 103. Pour notre exemple, les résultats obtenus par ANFIS sont de meilleure qualité que ceux obtenus par la régression par SVM en matière de performance de pronostic. Cependant, ANFIS offre un pronostic avec une dispersion élevée au début, ce qui dans le contexte d'aide à la prise de décision de maintenance peut poser problème. Par conséquent, les résultats obtenus par les SVM pour la régression sont plutôt préférables.




FIGURE 3.25 – Estimation de la RUL (ANFIS).

TABLE 3.12 – Mesures de performance (ANFIS).

Performance	Valeur ($\tau_a = 1$)	Valeur ($\tau_a = 1.5$)	Valeur ($\tau_a = 2.5$)
<i>Accuracy</i>	0.72	0.73	0.65
<i>HP</i> ($\alpha=0.3$)	2380	2390	2310
<i>RA</i> [$T/4, T/2, 3T/4$]	[-Inf, 0.80, 0.99]	[-inf, 0.67, 0.99]	[0.09, 0.16, 0.99]

À partir des résultats d'utilisation des méthodes de prédiction de séries temporelles à base d'apprentissage, nous remarquons que le recours à ces méthodes est intéressant surtout pour des horizons de temps d'analyse élevé et pour des horizons de prédiction moyennement faible. Un des principaux avantage est l'absence d'hypothèse sur la structure.

L'approche proposée dans cette sous-section est particulièrement adaptée aux modèles de comportements avec les paramètres caractérisant la dégradation bien identifiés, non mesurables et parfaitement observables. Elle a été appliquée sur le modèle de régulation de niveau d'eau présentant un seul paramètre reflétant la dégradation (la capacité de la pompe), mais peut-être généralisée aux modèles présentant plusieurs paramètres. Dans ce cas, la méthode qui sera choisie doit être à même de s'accommoder aux spécificités de comportement des paramètres (nombre de paramètres, non-linéarité...). Deux stratégies ont été présentées : l'estimation des paramètres par inférence statistique et par des outils de prédiction basés sur l'apprentissage. Les résultats obtenus montrent que les pronostics réalisés par l'estimation à l'aide de l'inférence statistique sont plus performants que ceux fournis par les pronostics obtenus par les outils de prédiction à base d'apprentissage. Ces résultats étaient attendus car la structure de la progression était supposée connue. Pour les outils basés sur l'apprentissage, les meilleurs pronostics ont été obtenus pour des horizons de temps d'analyse plutôt élevé et pour des temps de prédiction à court et à moyen terme.

3.5 Discussion

L'objectif de ce chapitre a été d'estimer la durée de vie résiduelle d'un système. C'est dans ce contexte que nous avons proposé les deux approches de pronostic. La première basée sur l'utilisation d'un observateur et un modèle de Markov caché prédit la dégradation d'un système en utilisant les propriétés markoviennes sur les durées de séjour dans les différents états. Cette approche a été utilisée avec un seul flux de résidu. Dans le prochain chapitre nous montrerons que nous pouvons l'utiliser dans un cadre multi-flux. Il est à souligner que l'estimation de la RUL dépend fortement de la représentativité des durées moyennes de séjour dans les états obtenus à partir de modèle générique formé.

La deuxième approche utilise également un observateur pour la surveillance et une méthode de prédiction. Quatre méthodes de prédiction ont été illustrées, deux basées sur l'inférence statistique et deux basées sur l'apprentissage. Les meilleurs pronostics ont été obtenus pour des horizons de temps d'analyse plus élevé. Cette approche à l'inverse de la première est spécifique au test (la prédiction réalisée est non générique).

Nous avons également montré à travers les différents exemples de simulation, les bonnes propriétés de robustesse des différentes approches.

Dans l'objectif global d'une démarche de diagnostic/pronostic, l'approche de diagnostic présentée dans le chapitre précédent permet d'identifier le niveau de dégradation du système. Ensuite, dans la phase de pronostic et selon les connaissances disponibles, l'une des deux approches va servir à estimer la durée de vie résiduelle. Cependant, dans le cas où il est possible de mettre en œuvre l'approche à base de modèle et comme nous l'avons montré, il est difficile de garantir des pronostics d'erreur et de dispersion faible avec des temps d'analyse courts.

Nous proposons alors que l'approche soit mise en œuvre qu'après que le diagnostic estime l'état 2 (niveau dégradé). En d'autres termes, le pronostic n'est réalisé qu'après une certaine évolution dans le temps de la dégradation et le passage à un niveau de fonctionnement dégradé. Cela nous permettra d'assurer des horizons de temps d'analyse qui seront suffisants au bon déploiement des méthodes de prédiction.

Chapitre 4

Application des approches de pronostic à une machine asynchrone et une batterie

4.1	Introduction	107
4.2	Pronostic de la durée de vie d'une machine asynchrone	107
4.2.1	Modèle général de défauts de la machine asynchrone	107
4.2.2	Modélisation de l'observateur	111
4.2.3	Application de l'approche markovienne pour le pronostic	114
4.3	Pronostic de la durée de vie d'une batterie Li-ion	119
4.3.1	Modélisation de la batterie	119
4.3.2	Application de l'approche à base de modèles	123
4.4	Conclusion	130

4.1 Introduction

Ce chapitre met en évidence l'efficacité des méthodes de diagnostic et de pronostic proposées dans les deux chapitres précédents. Il présente l'application de l'approche markovienne pour le pronostic de défaillance de la machine asynchrone et de l'approche à base de modèles pour une batterie Li-ion. La première partie est consacrée au pronostic du défaillance de la machine asynchrone en utilisant l'extension multi-flux du Modèle de Markov Caché. La seconde partie traite du pronostic d'une batterie Li-ion. Elle présente les résultats obtenus par l'utilisation des outils de prédiction à base d'apprentissage pour l'approche à base de modèles. La dernière partie de ce chapitre est consacrée à la discussion des résultats ainsi obtenus.

4.2 Pronostic de la durée de vie d'une machine asynchrone

La machine asynchrone compte parmi les actionneurs les plus robustes et les plus utilisés. Par conséquent, la connaissance de son état de santé est d'une grande importance. La mesure directe du couple, du flux, de la pulsation rotorique, de la vitesse de rotation, de la position ou de l'accélération par des capteurs mécaniques ou optoélectroniques est souvent inadéquate et représente un inconvénient majeur pour des raisons techniques (flux, couple) ou pour des problèmes de coût, de maintenance, de sécurité et de fiabilité (vitesse, accélération et position). Il est donc pertinent de n'utiliser que des informations facilement mesurables telles que tensions et courants statoriques. Dans cette optique, nous aborderons la modélisation de la machine asynchrone en présence de défauts avec comme entrée et sortie respectivement les tensions et les courants statoriques, plus précisément le modèle de défauts stator/rotor pour une alimentation en tension dans le référentiel de Concordia d'axe α et β [Duesterhoeft et al., 1951; Chattopadhyay et al., 2008].

4.2.1 Modèle général de défauts de la machine asynchrone

Le modèle de la machine asynchrone considéré est présenté dans [Bachir et al., 2006]. Il prend en considération les défauts majeurs de la machine, en l'occurrence, les courts-circuits de spires (défaut statorique) et les ruptures de barres (défaut rotorique). Le modèle suppose que la machine est équilibrée à entrefer uniforme, que la distribution du champ est sinusoïdale et que les effets de la saturation magnétique ainsi que les pertes par courants de Foucault et par hystérésis sont négligeables. Les fuites magnétiques quant à elles, sont totalisées au stator. La figure 4.1, page 108 donne le schéma électrique équivalent de la machine asynchrone en tenant compte de la présence des défauts.

Le modèle de la machine asynchrone sous forme d'état avec comme entrée et sortie respectivement les tensions ($U_{\alpha_s}, U_{\beta_s}$) et les courants statoriques ($i_{\alpha_s}, i_{\beta_s}$) est donné ci-après. D'autres formulations de modèles dans d'autres repères et avec d'autres vecteurs d'état existent (voir [Ghouili, 2006]).

$$\begin{cases} \dot{x}(t) = A(w_r)x(t) + Bu(t) \\ y(t) = Cx(t) + Du(t) \end{cases} \quad (4.1)$$




FIGURE 4.1 – Modèle de défauts stator/rotor de la machine asynchrone [Bachir et al., 2006].

avec

$x = [i'_{\alpha_s} \ i'_{\beta_s} \ \phi_{\alpha_r} \ \phi_{\beta_r}]^T$: vecteur d'état

$u = \begin{bmatrix} U_{\alpha_s} \\ U_{\beta_s} \end{bmatrix}$, $y = \begin{bmatrix} i_{\alpha_s} \\ i_{\beta_s} \end{bmatrix}$: entrée et sortie de la machine.

$$A(w) = \begin{bmatrix} -\frac{R_s + R_{eq}}{L_f} & 0 & \frac{R_{eq}}{L_r \cdot L_f} & \frac{w_r}{L_f} \\ 0 & -\frac{R_s + R_{eq}}{L_f} & -\frac{w_r}{L_f} & \frac{R_{eq}}{L_r \cdot L_f} \\ R_r & 0 & -\frac{R_r}{L_r} & -w_r \\ 0 & R_r & w_r & -\frac{R_r}{L_r} \end{bmatrix} : \text{matrice d'état.}$$

$$B = \begin{bmatrix} -\frac{1}{L_f} & 0 & 0 & 0 \\ 0 & -\frac{1}{L_f} & 0 & 0 \end{bmatrix}^T : \text{matrice de commande.}$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} : \text{matrice d'observation.}$$

$$D = \frac{2}{3R_s} \sum_{k=1}^3 \eta_{cck} P(-\theta) Q_{cck} P(\theta) : \text{matrice d'action directe.}$$

Avec $x(t) \in \mathbb{R}^n$, $u(t) \in \mathbb{R}^m$ et $y(t) \in \mathbb{R}^n$ représentant respectivement l'état, l'entrée et la sortie du système. Les matrices A , B , C et D ont des dimensions appropriées.

$P(\theta)$: matrice de rotation d'angle θ .

$$P(\theta) = \begin{pmatrix} \cos(\theta) & \cos(\theta + \frac{\pi}{2}) \\ \sin(\theta) & \sin(\theta + \frac{\pi}{2}) \end{pmatrix} \quad (4.2)$$

$Q(\theta_{cck})$: matrice situant l'angle du bobinage en court-circuit.

$$Q(\theta_{cck}) = \begin{pmatrix} \cos(\theta_{cck})^2 & \cos(\theta_{cck})\sin(\theta_{cck}) \\ \cos(\theta_{cck})\sin(\theta_{cck}) & \sin(\theta_{cck})^2 \end{pmatrix} \quad (4.3)$$

Le modèle considère les défauts des courts-circuits des spires au niveau de la matrice D . Le courant de court-circuit de la k^{eme} phase s'exprime par l'expression suivante :

$$i_{\alpha\beta_{cck}} = \frac{2\eta_{cck}}{3R_s} Q(\theta_{cck}) U_{\alpha\beta_s} \quad (4.4)$$

avec

$$\eta_{cck} = \frac{n_{cck}}{n_s} = \frac{\text{Nombre de spires en court-circuit sur la } k^{eme} \text{ phase}}{\text{Nombre de spires sur une phase saine}}$$

La résistance équivalente au rotor est la mise en série de la résistance saine R_r et d'une résistance de défaut $R_{\text{défaut}}$:

$$R_{eq} = R_r \cdot I + R_{\text{défaut}} = R_r \cdot I + \frac{\alpha}{1 - \alpha} Q(\theta_0) R_r \quad (4.5)$$

avec

$$\alpha = \frac{2}{3} \eta_0$$

$$\eta_0 = \frac{3n_{bc}}{nb} = \frac{\text{Nombre de spires fictives en défaut}}{\text{Nombre de spires fictives sur une phase}}$$

η_0 permet de quantifier le déséquilibre et d'obtenir le nombre de barres cassées. Pour un rotor de nb barres, le nombre de spires fictives sur une phase est de $\frac{nb}{3}$ [Abed et al., 1999; Bachir, 2002].

θ_0 l'angle repérant le défaut et n_{bc} le nombre de barres cassées.

$w = p \cdot w_r$: pulsation électrique avec p le nombre de paires de pôles et w_r la vitesse mécanique.

R_r , L_r : résistance et inductance d'une phase rotorique.

R_s , L_f : résistance d'une phase et inductance de fuite statorique.

A ces équations électriques, nous devons associer l'équation mécanique pour obtenir le modèle complet. Elle est définie par la relation suivante :

$$\frac{dw}{dt} = \frac{p}{J} (C_{em} - C_r - k_f w) \quad (4.6)$$

C_r le couple de charge, L_m l'inductance mutuelle, J le moment d'inertie, k_f le coefficient de frottement visqueux et C_{em} le couple électromagnétique donné par l'expression suivante :

$$C_{em} = \frac{3pL_m}{2L_r} (\phi_{\alpha_r} i_{\beta_s} - \phi_{\beta_r} i_{\alpha_s}) \quad (4.7)$$

Les figures 4.2, page 110, 4.3, page 111 et 4.4, page 112 présentent respectivement les résultats de simulation sans défaut, avec défaut statorique et avec défaut rotorique obtenus à partir du modèle présenté.

Les courbes de vitesse de rotation, du couple électromagnétique, des courants et des spectres des courants y sont présentées. Pour les défauts statoriques, nous introduisons un court-circuit de 12.5% sur la phase (a) à l'instant $t = 2s$. Le défaut rotorique consiste quant à lui, à introduire un défaut de $\eta_0 = 0.1$ sur la phase repérée par $\theta_0 = 0$.

Les notations et les valeurs numériques associées nécessaires à la simulation du comportement de la machine asynchrone sont résumées dans la table 4.1, page 110.

TABLE 4.1 – Valeurs numériques des paramètres.

Variable	Valeur numérique
R_s	4.85 Ω
R_r	3.81 Ω
L_r	0.274 H
L_f	0.0311 H
L_m	0.258 H
J	0.031 Kgm ²
k_f	0.001136 Nm/rd/s
p	2




FIGURE 4.2 – L'évolution (a) de la vitesse, (b) du couple électromagnétique et (c) des courants dans les phases sans défauts.

Nous constatons qu'en absence du défaut, les courants statoriques atteignent de fortes valeurs pendant le démarrage, puis ils décroissent pour atteindre le régime forcé permanent. L'application d'une charge introduit une chute de vitesse et une augmentation de couple électromagnétique et des différents courants. Pour un défaut statorique, nous remarquons qu'un court-circuit

sur une phase affecte l'ensemble des grandeurs. Le défaut statorique provoque un changement au niveau des courants. Il induit des ondulations sur la vitesse et sur le couple. Pour le spectre du courant de la phase (a), nous remarquons la présence de la composante fréquentielle à 150Hz , le même résultat a été trouvé dans [Emara et al., 2003; Arkan et al., 2001]. Cette fréquence peut apparaître également dans le spectre du courant pour un moteur sain en raison de la saturation du circuit magnétique ou encore d'un déséquilibre d'alimentation. Nous constatons, qu'à la suite d'un défaut rotorique, des ondulations plus ou moins importantes apparaissent sur les différentes grandeurs. Le spectre de densité de puissance de la phase (a) retrouve bien les fréquences caractéristiques de rupture de barres qui est de l'ordre du $f = (1 + 2g)f_s$, g représente le glissement de la machine et f_s la fréquence fondamentale des courants statoriques.




FIGURE 4.3 – L'évolution (a) de la vitesse, (b) de couple électromagnétique, (c) du courant de phase I_a et (d) de spectre de phase (a) pour un défaut statorique.

4.2.2 Modélisation de l'observateur

Le modèle étant établi, nous proposons d'utiliser un observateur d'état adaptatif déterministe étudié dans [Bose, 2002; Ghouli, 2006; Rajashekar et al., 1996]. Cet observateur utilise les grandeurs statoriques et considère la vitesse de rotation de la machine asynchrone comme un paramètre inconnu (non mesuré). Il permet d'estimer les composantes $\alpha\beta$ du courant statorique




FIGURE 4.4 – L'évolution (a) de la vitesse, (b) de couple électromagnétique, (c) du courant de phase I_a et (d) de spectre de la phase (a) pour un défaut rotorique.

et du flux rotorique. Son équation d'état est la suivante :

$$\begin{cases} \hat{\dot{x}}(t) = \hat{A}(\hat{w}_r)x(t) + Bu(t) + G(y - \hat{y}) \\ \hat{y}(t) = Cx(t) \end{cases} \quad (4.8)$$

avec $\hat{y} = \begin{bmatrix} \hat{i}_{\alpha_s} \\ \hat{i}_{\beta_s} \end{bmatrix}$, $y = \begin{bmatrix} i_{\alpha_s} \\ i_{\beta_s} \end{bmatrix}$ et G est la matrice du gain qui sera déterminée pour assurer la stabilité asymptotique de l'observateur.

La paire (A, C) est uniformément et localement observable [Ghouili, 2006]. Nous pouvons noter également que le problème de l'observation à vitesse nulle a été soulevé dans les références [Bose, 2002; Rajashekara et al., 1996]. Nous obtenons en procédant par placement de pôles la matrice de gain suivante :

$$G = \begin{bmatrix} -g_1 & -g_2 & -g_3 & -g_4 \\ g_2 & -g_1 & g_4 & -g_3 \end{bmatrix}^T \quad (4.9)$$

En fonction des paramètres de la machine, les éléments de la matrice de gain sont donnés par :

$$\begin{cases} g_1 = -(k-1)(\frac{1}{a_1} + \frac{1}{a_2}) \\ g_2 = -(k-1)\widehat{w}_r \\ g_3 = -(k^2-1)\left\{\left[\frac{1}{a_1} + \frac{1}{a_2}\right]\frac{a_1L_sM}{L_r} - \frac{R_rM}{L_r}\right\} + \frac{a_1L_sM}{L_r}g_1 \\ g_4 = -(k-1)\widehat{w}_r\frac{a_1L_sM}{L_r} \end{cases} \quad (4.10)$$

où M l'inductance mutuelle, L_s l'inductance d'une phase statorique, $a_1 = 1 - \frac{R_r M^2}{L_s L_r^2}$,
 $a_2 = 1 - \frac{R_s M^2}{L_r L_s^2}$ et k est une constante choisie pour accélérer la convergence de l'observateur
(elle est usuellement de valeur faible).

Un mécanisme d'adaptation est inclus pour estimer la vitesse de rotation $\hat{w}_r$ de la matrice $\hat{A}$. Pour déterminer le mécanisme d'adaptation et assurer la stabilité de l'observateur, [Ghouili, 2006] a utilisé le théorème de stabilité de Lyapunov pour une vitesse constante. Par la suite, afin d'améliorer la réponse de l'algorithme d'adaptation pour une vitesse variable, la vitesse est estimée par la relation suivante (structure d'un régulateur PI) :

$$\hat{w}_r = K_p \left((i_{\alpha_s} - \hat{i}_{\alpha_s}) \phi_{\beta_r} - (i_{\beta_s} - \hat{i}_{\beta_s}) \phi_{\alpha_r} \right) + K_i \int \left((i_{\alpha_s} - \hat{i}_{\alpha_s}) \phi_{\beta_r} - (i_{\beta_s} - \hat{i}_{\beta_s}) \phi_{\alpha_r} \right) dt \quad (4.11)$$

La figure 4.5, page 113 montre le schéma en bloc d'un observateur de vitesse adaptatif.




FIGURE 4.5 – Blocs de la structure utilisée.

Pour faire l'étude de cet observateur, nous avons effectué des simulations de comportement sans et avec bruit de mesures. Les figures 4.6, page 114, 4.7, page 114 montrent les courbes simulées et estimées ainsi que l'erreur d'observation pour les courants et la vitesse. Nous constatons que les erreurs sont importantes au démarrage mais faibles en régime permanent même en pré-

sence de bruits et avec application de la charge. L'erreur statique est très faible et l'observateur converge assez bien.




FIGURE 4.6 – Les évolutions réelles, estimées et l'erreur d'observation en absence de bruit de mesure pour (a) i_{α_s} et (b) la vitesse.




FIGURE 4.7 – Les évolutions réelles, estimées et l'erreur d'observation avec un bruit de mesure pour (a) i_{α_s} et (b) la vitesse.

4.2.3 Application de l'approche markovienne pour le pronostic

La machine asynchrone et l'observateur étant présentés, nous pouvons entamer la mise en œuvre de l'approche markovienne. Nous considérons que la machine asynchrone est dans un état défaillant si au moins, le pourcentage de court-circuit d'une seule phase ou η_0 atteint 25%. Ce choix est purement arbitraire. Nous pouvons néanmoins considérer que cette valeur aura un impact important sur la machine.

L'ensemble des données est constitué de 50 essais de dégradation jusqu'à la défaillance de la machine asynchrone. L'augmentation des différents défauts est modélisée par des trajectoires avec des instants d'arrivée suivant un processus de poisson. Les trajectoires de dégradation au

niveau de la première phase statorique sont présentées dans la figure 4.8 (a), page 115. Nous remarquons que certaines trajectoires s'arrêtent avant la valeur de 0.25. En effet, pour celles-ci au moins, une des dégradations a atteint 0.25. La quantité de défaillances versus le défaut incriminé pour l'ensemble des tests est également présenté sur la figure 4.8 (b), page 115.




FIGURE 4.8 – (a) Les dégradations de la première phase de l'ensemble de tests et (b) la répartition des défauts causant la défaillance de système

Les instants de défaillance du système et les valeurs de variance des résidus correspondants pour les différents essais sont présentés dans les figures 4.9 (a, b), page 116. Les résultats montrent que la connaissance des valeurs des résidus n'est pas un indicateur de niveau de dégradation du système. Cela est dû principalement aux perturbations et aux bruits de mesure, d'où l'intérêt d'utiliser le Modèle de Markov Caché. De plus, la prise en compte des deux résidus pour modéliser le comportement de la dégradation nous semble nécessaire car, l'effet de la dégradation peut se manifester sur un résidu et pas sur l'autre. Ce résultat n'est possible qu'en combinant les mesures. Une solution possible consiste à utiliser l'extension du formalisme des MMCs : le MMC multi-flux.

Nous commençons par illustrer l'approche markovienne sur un exemple de dégradation issue de la base d'essais. Les évolutions des différentes dégradations jusqu'à la défaillance de la machine asynchrone et les variances des résidus générés par l'observateur sont présentées dans la figure 4.10, page 116.

L'évolution de la log vraisemblance lors de l'apprentissage à l'aide de l'algorithme de Baum-Welch et l'estimation des niveaux de dégradation à l'aide de l'algorithme de Viterbi ainsi obtenue pour l'exemple, sont données sur la figure 4.11, page 117. Les résultats en terme de TFA et TND sont présentés en fonction du nombre de classes K retenu dans la table 4.2, page 117.

Nous remarquons que les résultats obtenus pour les différents K sont globalement satisfaisants. Les meilleurs résultats sont obtenus pour un nombre de classes égale à 3 et 5.

Pour $K = 3$, les niveaux obtenus par le MMC multi-flux et les niveaux obtenus par une utilisation d'un seul résidu sont représentés sur la figure 4.12, page 117.

4.2. PRONOSTIC DE LA DURÉE DE VIE D'UNE MACHINE ASYNCHRONE




FIGURE 4.9 – Les instants de défaillance et les valeurs de variance des résidus (a) i_α et (b) i_β correspondantes.




FIGURE 4.10 – L'évolution (a) des différentes dégradations jusqu'à défaillance, (b) de la variance du résidu i_{α_s} et (c) de la variance du résidu i_{β_s} .




FIGURE 4.11 – Evolutions (a) de la log vraisemblance et (b) des niveaux de dégradation pour l'exemple.

TABLE 4.2 – Mesures de performance pour l'exemple.

	MMC				
K	3	4	5	6	7
TFA%	0.84	3.67	0.84	2.07	9.51
TND%	0	0	0	0	0




FIGURE 4.12 – L'estimation du niveau de dégradation (a) MMC multi-flux et (b) MMC à flux unique pour l'exemple.

À partir des résultats obtenus, il apparaît clairement que l'utilisation de résidus de façon indépendante n'est pas réaliste. Par exemple, pour la plage temporelle $[0-670s]$, nous constatons que le niveau de dégradation estimé est identique pour le MMC associé au résidu i_α alors que l'estimation associée au résidu i_β passe au niveau 2 à $t = 590s$. Pour la plage temporelle $[590s-910s]$, l'estimation donnée par le MMC associé au résidu i_β est identique, l'estimation du niveau de dégradation par le MMC associé au résidu i_α passe au niveau 2 à $t = 650s$ puis, au niveau 3 à $t = 690s$.

Le résultat obtenu pour 100 partitionnements aléatoires sur l'ensemble des données est présenté dans le tableau 4.3, page 118.

TABLE 4.3 – Mesures de performance pour 100 partitionnements aléatoires

	MMC				
K	3	4	5	6	7
<i>TFA%</i>	10.2	11.71	8.03	9.94	11.8
<i>TND%</i>	3.88	4.7	5.91	5.04	4.50

A partir de ces résultats, nous observons que la synthèse d'un MMC multi-flux offre des résultats corrects en matière de *TFA* et *TND*. Les meilleurs résultats ainsi obtenus concernent une discrétisation pour $K = 5$ classes.

L'estimation de la RUL pour l'exemple est présentée dans la figure 4.13, page 118. Les RUL estimées sont affichées en rouge, l'évolution de la RUL réelle en bleu et les évolutions qui caractérisent l'intervalle de confiance pour un $\alpha = 0.3$ en vert.




FIGURE 4.13 – L'estimation de la RUL pour l'exemple.

Les résultats obtenus par la mise en œuvre des mesures de performance de pronostic sont présentés dans la table 4.4, page 118.

TABLE 4.4 – Mesures de performance pour l'exemple (MMC multi-flux).

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.61	0.81	0.78
<i>precision</i>	169.42	109.17	53.94
<i>HP</i> ($\alpha=0.3$)	536	1060	1060
$RA[T/4, T/2, 3T/4]$	[0.46, 0.72, 0.77]	[0.73, 0.97 , 0.92]	[0.99 , 0.77, 0.62]

Nous observons que les mesures de performance sont relativement correctes : la valeur de la mesure de *HP* est égale à 1060s pour la RUL_{moy} et la RUL_{max} (dès le début les RUL estimées

sont dans l'intervalle de confiance). Pour la RUL_{min} , elle s'insère dans l'intervalle de confiance à la moitié de la durée de vie. L'exactitude et l'exactitude relative (RA) sont également assez précises.

Les résultats obtenus pour 100 partitionnements aléatoires sont présentés dans la table 4.5, page 119.

TABLE 4.5 – Mesures de performance pour 100 partitionnements aléatoires.

Performance	RUL_{min}	RUL_{moy}	RUL_{max}
<i>Accuracy</i>	0.63	0.72	0.65
<i>precision</i>	81.97	46.34	74.71
<i>HP</i> ($\alpha=0.3$)	523.21	849.24	687.18
$RA[T/4, T/2, 3T/4]$	[0.64, 0.62, 0.46]	[0.83 , 0.76 , 0.54]	[0.66, 0.63, 0.41]

À partir de ces mesures de performance, nous pouvons conclure que l'utilisation de l'approche avec un MMC multi-flux pour l'estimation de la RUL offre des résultats satisfaisants. Ce constat est confirmé par les valeurs de l'exactitude et de HP indiquant que la RUL estimée s'insère dans l'intervalle de confiance rapidement.

Les résultats ainsi obtenus peuvent apporter des informations très utiles avant l'arrivée de la défaillance. Nous pouvons également noter, qu'un des intérêts de l'utilisation de MMC multi-flux est sa capacité à intégrer d'autres flots d'informations pertinents a priori (e.g. mesure physique, bruit, environnement, recette de fabrication...). La prise en compte des différentes sources d'information est très importante, car l'effet d'une dégradation peut se manifester à partir d'une mesure particulière.

4.3 Pronostic de la durée de vie d'une batterie Li-ion

Dans cette section, la démarche de pronostic à base de modèles est appliquée sur une batterie du type Li-ion. Le désir de respecter l'environnement, la rareté et le coût des ressources pétrolières ont amené au développement de technologies plus durables et écologiques. Concernant les techniques de stockage d'énergie, les batteries jouent un rôle primordial. Leur durée de vie, leur sécurité et leur coût sont considérés comme des facteurs déterminants pour certaines applications, notamment, dans les transports. La prédiction de la durée de vie de la batterie est donc essentielle. Dans la suite de ce chapitre, nous aborderons sa modélisation dynamique pour ensuite appliquer notre approche de pronostic à base de modèles.

4.3.1 Modélisation de la batterie

La batterie peut s'apparenter à un système complexe, basé sur des interactions entre les domaines de la physique, de l'électrochimie et de la thermique. Ces modèles peuvent être à base de modèles électrochimiques, boîte noire, numériques ou à base de circuits électriques. Dans la suite de notre travail, nous considérons un modèle à base de circuits électriques. Notre choix s'est porté sur la modélisation par des circuits électriques car, ils offrent une bonne compréhension du comportement de la batterie. De plus, la prise en compte du vieillissement peut se faire en changeant les paramètres du modèle en fonction de l'état de santé de la batterie. Dans la littérature, plusieurs modèles décrivant le comportement des batteries Li-ion ont été discutés [Rezvanizani et al., 2014; Al Jed, 2014; He et al., 2011]. En effet, selon la spécificité

de l'application et en particulier selon la précision souhaitée, les modèles peuvent favoriser la simplicité en tenant compte de plusieurs hypothèses. Il est également possible d'exiger plus de performance en intégrant la quasi-totalité des caractéristiques physico-chimiques de la batterie. Le modèle utilisé est décrit par la figure 4.14, page 120. Ce modèle est présenté dans [Chen and Rincon-Mora, 2006; Sankararaman et al., 2014; Daigle et al., 2012b]. La capacité C_b est la tension du circuit ouvert de la batterie. Les deux circuits RC permettent de modéliser la relaxation de la batterie pour deux échelles de temps (temps court et temps long). Les valeurs des résistances et des capacités du circuit dépendent de l'état de charge.




FIGURE 4.14 – Circuit électrique équivalent d'une batterie Li-ion.

La modélisation est donnée par :

$$\begin{cases} \dot{x}(t) = Ax(t) + i(t) \\ y(t) = Cx(t) \end{cases} \quad (4.12)$$

$$\dot{x} = [q_b \quad q_{sp} \quad q_s]^T \quad (4.13)$$

$$A = \begin{bmatrix} -\frac{1}{C_b R_p} & \frac{1}{C_{sp} R_p} & \frac{1}{C_s R_p} \\ \frac{1}{C_b R_p} & -\frac{R_{sp} + R_p}{C_{sp} R_{sp} R_p} & \frac{1}{C_s R_p} \\ \frac{1}{C_b R_p} & \frac{1}{C_{sp} R_p} & -\frac{R_s + R_p}{C_s R_s R_p} \end{bmatrix}, \quad C = \begin{bmatrix} \frac{1}{C_b} & \frac{1}{C_{sp}} & \frac{1}{C_s} \end{bmatrix} \quad (4.14)$$

L'état de charge (SOC) est calculé par l'expression suivante :

$$SOC = 1 - \frac{q_{max} - q_b}{C_{max}} \quad (4.15)$$

avec q_b représentant la charge disponible dans la batterie, q_{max} la charge maximale possible et C_{max} est la capacité maximale possible.

L'expression de R_{sp} en fonction de SOC est la suivante :

$$R_{sp} = R_{sp0} + R_{sp1} \exp(R_{sp2}(1 - SOC)) \quad (4.16)$$

avec R_{sp0} , R_{sp1} et R_{sp2} des paramètres déterminés de manière empirique. La résistance et par

conséquent la chute de tension augmente de façon exponentielle lorsque SOC diminue.

L'expression de C_b en fonction de SOC est un polynôme d'ordre 3.

$$C_b = C_{b_0} + C_{b_1}SOC + C_{b_2}SOC^2 + C_{b_3}SOC^3. \quad (4.17)$$

Il est à noter que les C_{b_1} , C_{b_2} et C_{b_3} n'ont pas de signification physique.

Les valeurs numériques associées et nécessaires à la simulation du comportement de la batterie sont résumées dans le tableau 4.6, page 121. Ces valeurs sont celles d'une batterie qui alimente un véhicule aérien sans pilote. Cette application est utilisée par la NASA comme un moyen d'essai pour ses études sur le pronostic de dégradation [Sankararaman et al., 2014].

TABLE 4.6 – Valeurs numériques des paramètres du modèle

Variable	Valeur numérique	Variable	Valeur numérique
C_{b_0}	19.8 F	C_{s_p}	316.69 F
C_{b_1}	1745 F	$R_{s_{p0}}$	0.0272 Ω
C_{b_2}	-1.50 H	$R_{s_{p1}}$	1.087*10 ⁻¹⁶ Ω
C_{b_3}	-200.20 H	$R_{s_{p2}}$	34.64 sans unité
R_s	0.0067 Ω	q_{max}	3.11*10 ⁴ C
C_s	115.28 F	C_{max}	30807 C
R_p	10 ⁴ Ω	V_{EOD}	16 V

La figure 4.15, page 122 représente les courbes associées au courant, à la tension et à l'état de charge pour une décharge de la batterie sur un cycle.

L'état de charge diminue depuis 100% jusqu'à atteindre 0%. La charge est complète lorsque la quantité de charge disponible correspond à la capacité maximale pouvant être fournie par la batterie. Lors de son utilisation, une quantité de charge est débitée pour faire passer la batterie de pleine charge à un état de charge de 0%. Ce dernier correspond à la tension de seuil définie par le fabricant.

Les évolutions de la tension délivrée par la batterie en fonction du temps et en fonction de la valeur de la capacité de la batterie pour des courants constants sont également représentées dans la figure 4.16, page 122.

Nous constatons que l'allure de la chute de tension est identique pour les différents courants, la différence est dans la durée de vieillissement. Ceci est expliqué par la résistance interne qui est fonction de l'état de charge. Il est aussi possible de remarquer que la tension diminue très fortement aux faibles états de charge dégradant de façon importante la batterie.

Le vieillissement des batteries Li-ion se manifeste soit par une augmentation de l'impédance conduisant à une perte de puissance, soit une perte de capacité de stockage, ou les deux en même temps mais pas forcément de manière proportionnelle [Vinh, 2010]. Les mécanismes de vieillissement se produisent lors de l'utilisation de la batterie (vieillissement en cyclage) mais également pendant, les phases de repos (vieillissement calendaire). Une synthèse des principaux mécanismes de vieillissement recensés dans la littérature et les facteurs pouvant les influencer peuvent être consultés dans [Vinh, 2010; Eddahech, 2013; Al Jed, 2014]. La diminution au cours des cycles charge/décharge de la capacité de stockage est modélisée dans [Al Jed, 2014; Liu et al., 2014a; Saha et al., 2009] par l'expression suivante :

4.3. PRONOSTIC DE LA DURÉE DE VIE D'UNE BATTERIE LI-ION




FIGURE 4.15 – (a) Courant, (b) tension de la batterie et (c) évolution de l'état de charge.




FIGURE 4.16 – Tension en fonction (a) du temps et (b) de la capacité.

$$C_{k+1} = \eta_c C_k + \beta_1 \exp(-\beta_2 / \Delta t_k) \quad (4.18)$$

où k représente le nombre de cycles. η_c , β_2 et β_1 des paramètres à identifier.

En pratique, la tension peut être mesurée simplement. Cependant, ce type de batterie peut vieillir prématurément ou devenir instable dans certaines conditions. En plus du vieillissement propre dû au degré d'utilisation (cyclage, courants, ...) [Broussely et al., 2005], les batteries peuvent subir des altérations qui affectent leurs performances [Han et al., 2014; Rashid and Gupta, 2014] (vieillessement lié à l'environnement de fonctionnement). Ce vieillissement prématuré se manifeste entre autre, par une altération de la capacité et/ou une augmentation de la résistance interne.

Une mauvaise prédiction de la durée de vie de la batterie peut avoir un impact néfaste et peut conduire à des conséquences désastreuses pour la fonctionnalité du système. Il est donc important de réactualiser et de quantifier l'espace temporel dans lequel la batterie répond aux exigences souhaitées. Dans ces conditions, il faut particulièrement s'attacher à estimer :

- L'horizon de décharge (autonomie du système alimenté),
- Le nombre de cycles de charge/décharge (indication sur la durée de vie de la batterie).

4.3.2 Application de l'approche à base de modèles

Pour cette application et afin d'illustrer l'approche à base de modèles, nous considérons que la résistance R_s varie à partir de la valeur nominale $R_{s_{ini}}$ suivant un processus stochastique de type Wiener.

$$R_s = R_{s_{ini}} + R_{deg} \quad (4.19)$$


R_{deg} Résistance représentant l'effet de l'environnement (e.g. le phénomène d'emballement thermique [Liu et al., 2014b]).

La fin de vie d'une batterie est couramment fixée lorsque sa capacité atteint 80% de sa valeur à l'état neuf et/ou lorsque sa valeur de résistance s'accroît de 200% [Lièvre, 2015; Markel et al., 2009]. Dans notre cas, nous considérons une contrainte liée à la durée de vie dans un cycle pour un profil de mission de $i = N(35, 5)$ avec $i_{max} = 80 \text{ A}$ et $i_{min} = 20 \text{ A}$ (profil considéré dans les travaux de [Sankararaman et al., 2014]). La batterie est inutilisable dès que son autonomie pour le profil de mission est inférieure à 100 secondes. D'autres contraintes peuvent également être utilisées, par exemple, la capacité en Ah. Dans cette condition, nous avons une connaissance sur la capacité minimale pour mettre un dispositif en sécurité (e.g. la capacité minimale qu'il faut à un drone pour se poser s'il est en vol). Une autre contrainte peut être liée au nombre du cycle charge/décharge. L'effet et la durée de la phase de décharge ne sont pas considérés.

Des exemples d'évolutions de la durée d'utilisation en fonction du nombre de cycles de charge/décharge sans et avec dégradation pour un courant constant sont représentés sur la figure 4.17, page 124.

Le vieillissement de la batterie en présence de dégradations est accéléré. Par conséquent, le nombre de cycles de charge/décharge et les durées d'utilisation diminuent.

La modélisation de la batterie associée aux performances souhaitées caractérisées, nous pouvons alors entamer la mise en œuvre de l'approche de pronostic à base de modèles.


 FIGURE 4.17 – Evolution de (a) la durée de décharge sans et avec dégradation et (b) de la résistance R_s .

Phase d'estimation : pour sa réalisation, nous avons utilisé un observateur augmenté par le paramètre R_s . L'observateur synthétisé s'écrit comme suit :

$$\begin{cases} \frac{d\hat{i}_b}{dt} = \hat{q}_b = -\frac{1}{C_b R_p} \hat{i}_b + \frac{1}{C_{sp} R_p} \hat{i}_{sp} + \frac{1}{C_s R_p} \hat{i}_s + L_1 \tilde{V}_p \\ \frac{d\hat{i}_{sp}}{dt} = \hat{q}_{sp} = -\frac{1}{C_b R_p} \hat{i}_b + \frac{R_p + R_{sp}}{C_{sp} R_{sp} R_p} \hat{i}_{sp} + \frac{1}{C_s R_p} \hat{i}_s + L_2 \tilde{V}_p \\ \frac{d\hat{i}_s}{dt} = \hat{q}_s = -\frac{1}{C_b R_p} \hat{i}_b + \frac{1}{C_{sp} R_p} \hat{i}_{sp} + \frac{R_p + R_s}{C_s R_p R_{sp}} \hat{i}_s + L_3 \tilde{V}_p \\ \dot{\hat{R}}_s = \hat{R}_s + L_4 \tilde{V}_p \end{cases} \quad (4.20)$$

avec $\tilde{V}_p = V_p - \hat{V}_p$ est l'erreur d'estimation de la tension au niveau de R_p . L_1 , L_2 , L_3 et L_4 sont les gains de l'observateur.

La figure 4.18, page 125 présente l'erreur d'estimation $\tilde{V}_p$ sur un cycle et l'erreur d'estimation de R_s sur la totalité de la durée de vie avec un bruit de mesure sur la tension. Nous constatons que pour les valeurs choisies des gains, les estimations sont de bonne qualité.

Phase de pronostic : dans cette phase, nous estimons le nombre de cycles de charge/décharge avant que la performance attendue ne soit plus satisfaite. Cette estimation est réalisée sur la base de la connaissance *a priori* des conditions opérationnelles associée à l'hypothèse que la recharge n'influe pas sur la déviation de R_s . Les résultats obtenus par la mise en œuvre de l'approche de pronostic avec la régression par SVM et la prédiction par ANFIS sont illustrés ci-après.

La régression par SVM : comme énoncé dans le chapitre 3, il est nécessaire de disposer d'un volume suffisant d'observations pour alimenter l'outil de prédiction. Par conséquent, nous débuterons à partir de la 3^{ème} décharge. Le nombre d'entrées est de $r = 5$. La fonction de noyau est polynomiale. Les valeurs considérées sont prises chaque minute. Une interpolation est ensuite




FIGURE 4.18 – (a) Évolution réelle et estimée de V_p , (b) erreur d'estimation de V_p , (c) Évolution réelle et estimée de R_s et (d) erreur d'estimation de R_s .

réalisée. L'étude de la qualité de prédiction à travers l'évolution et la distribution de la MAPE (figure 4.19, page 126) montre que les résultats de prédiction sont de bonne qualité pour les différents horizons de prédiction avec une prédiction optimale lorsque le temps d'analyse est élevé.

Les résultats de l'estimation de la RUL (en terme de cycle de charge/décharge et de durée de fonctionnement sur le même profil de mission) obtenus par la mise en œuvre de l'approche sont représentés dans la figure 4.20, page 126.

Les mesures de performance associées sont indiquées dans la table 4.7, page 126. Ces résultats indiquent que les pronostics réalisés sont de bonne qualité pour des horizons de temps d'analyse plus élevés. Les valeurs de 0.81 pour l'exactitude et de 58 cycles pour l'horizon de pronostic, nous permettent de conclure que les résultats sont satisfaisants.

Prédiction par ANFIS : Les paramètres de réglages sont identiques à ceux de la régression par SVM, avec des fonctions d'appartenance du type gaussien au nombre de 3 et une inférence linéaire. L'évolution de l'erreur MAPE et sa densité sont représentées dans la figure 4.21, page

4.3. PRONOSTIC DE LA DURÉE DE VIE D'UNE BATTERIE LI-ION




FIGURE 4.19 – Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (régression par SVM).




FIGURE 4.20 – (a) Estimation de la RUL et (b) sa densité de probabilité (régression par SVM).

TABLE 4.7 – Mesures de performance de pronostic (régression par SVM).

Performance	Valeur
<i>Accuracy</i>	0.81
<i>Precision</i>	9.25
<i>HP</i> ($\alpha=0.3$)	58
$RA[T/4, T/2, 3T/4]$	[0.87, 0.81, 0.76]

127. Nous remarquons que les bons résultats de prédiction ne sont obtenus qu'avec des temps d'analyse relativement élevés. Par rapport à la régression par SVM, l'horizon de prédiction pour cet exemple a un effet plus élevé sur les résultats de prédiction.




FIGURE 4.21 – Évolution de la MAPE et de la densité de probabilité pour des horizons de temps différents (prédiction par ANFIS).

L'estimation de la RUL et les mesures de performance de pronostic sont présentées dans la figure 4.22, page 127 et la table 4.8, page 128.




FIGURE 4.22 – (a) Estimation de la RUL et (b) sa densité de probabilité (prédiction par ANFIS).

Pour cet exemple, nous constatons que les résultats obtenus par ANFIS sont également de bonne

TABLE 4.8 – Mesures de performance de pronostic (prédiction par ANFIS).

Performance	Valeur
<i>Accuracy</i>	0.80
<i>Precision</i>	12.81
<i>HP</i> ($\alpha=0.3$)	54
$RA[T/4, T/2, 3T/4]$	[0.91, 0.93, 0.82]

qualité. Le résultat de pronostic montre une dispersion plus élevée par rapport aux résultats obtenus par l'utilisation de la régression par SVM. Cela est dû principalement aux mauvaises prédictions de comportement futur de la résistance R_s au début.

A ce stade, comme nous l'avons énoncé dans le chapitre précédent, la qualité de pronostic à partir de l'approche markovienne est fortement conditionnée par la représentativité des durées moyennes de séjour dans les états de modèle générique. Ainsi, il est très intéressant de combiner le diagnostic par l'approche markovienne avec le pronostic à base de modèles. Cela permettrait une estimation d'une durée de vie spécifique à la sollicitation future souhaitée.

Le pronostic ne serait activé qu'après détection d'un niveau dégradé afin d'éviter le problème de prise en considération. Cette contrainte est tout à fait logique : si le système est en bon état de fonctionnement, il n'y a aucune raison de lancer le processus de pronostic. Cependant, si la batterie est juste soumise à son vieillissement propre et si la valeur de R_s ne varie pas, la procédure de pronostic seule peut être utilisée pour estimer la durée de vie. L'approche combinée est résumée par la figure 4.23, page 128.




FIGURE 4.23 – Les étapes de l'approche hybride.

Dans ce qui suit, nous allons illustrer notre approche sur un exemple. L'ensemble des données est constitué de 50 essais de dégradation jusqu'à défaillance. La dégradation est modélisée par un processus stochastique de type Wiener. Les trajectoires de dégradation et les durées dans chaque cycle de décharge sont présentées dans la figure 4.26, page 130.

La mise en œuvre nécessite la génération de résidus à l'aide d'un observateur. La figure 4.25, page 129 illustre les résidus obtenus en absence et avec dégradation dans le cas de la présence d'un bruit de mesure sur la tension.

Nous constatons que pour un comportement normal de la batterie, le résidu est de faible amplitude malgré le vieillissement et le bruit de mesure sur la tension. Nous remarquons également qu'en présence de dégradation, l'observation directe de la valeur de résidu ne permet pas d'identifier le niveau de dégradation de la batterie.

À ce stade de l'approche, nous allons réaliser les deux étapes de discrétisation et d'apprentissage




FIGURE 4.24 – (a) Trajectoires de dégradation et (b) les durées dans les cycles.




FIGURE 4.25 – Le résidu (a) sans dégradation et (b) avec dégradation.

de MMC. Ensuite, à l'aide de l'algorithme Viterbi, nous estimons le niveau de dégradation. Tant que le niveau est dans 1, il y'a aucune raison d'entamer l'étape de pronostic. Dès que le niveau transite vers 2, nous exécutons l'approche à base de modèles, cela permettra aux utilisateurs et à la maintenance de connaître la capacité du système à répondre aux objectifs de performance selon le profil d'utilisation désirée et par conséquent d'anticiper sur les actions à mener. Les figures 4.26, page 130 et 4.27, page 130 montrent respectivement le résultat de l'approche pour un exemple en durée d'utilisation et en cycle de décharge/recharge.

Le résultat de cette approche présente un avantage certain par rapport aux deux précédentes approches. D'une part, l'état du système est perceptible à travers l'évolution du Modèle de Markov Caché. D'autre part, les problèmes dus à la genericité du modèle pour le pronostic markovien et aux faibles temps d'analyse pour l'approche à base de modèles sont évités. Il est également très facile de procéder de la même manière en imaginant différents scénarii de fonctionnement, de comparer les résultats et enfin de choisir le profil d'utilisation le plus optimal.




FIGURE 4.26 – Résultats de diagnostic et de pronostic en durée d’usage en utilisant (a) la régression par SVM et (b) la prédiction par ANFIS.




FIGURE 4.27 – Résultats de diagnostic et de pronostic en cycle de décharge/recharge en utilisant (a) la régression par SVM et (b) la prédiction par ANFIS

4.4 Conclusion

Les résultats exposés ont mis en évidence les performances des approches proposées pour le diagnostic/pronostic de la machine asynchrone et de la batterie. En effet, l’approche d’estimation de l’état de santé utilisant un observateur et un Modèle de Markov Caché (sous forme d’extension multi-flux) a été appliquée à la machine asynchrone. Cette approche qui peut être étendue au pronostic a été également appliquée à la machine asynchrone. Dans les deux cas, les résultats obtenus présentent une bonne précision. Pour l’approche de pronostic à base de modèles, elle a été appliquée à la batterie et s’est montrée efficace malgré l’absence de connaissance sur le mécanisme de dégradation. Cela a été possible par l’utilisation d’outils à base d’apprentissage, dans notre cas : la régression par SVM et la prédiction par ANFIS. À partir de ces résultats, une nouvelle approche basée sur le couplage des deux a été proposée. Cette approche s’appuie sur l’approche d’estimation de l’état de santé et le pronostic à base de modèles. L’approche a été illustrée sur un exemple de dégradation de batterie. Elle s’est avérée intéressante par le fait que les modèles de prédiction par apprentissage nécessitent des temps d’analyse éle-

vés. Ce qui limite la prise de décision sur une action de maintenance alors que le système est toujours en bon état de fonctionnement. Les différents outils peuvent donc permettre à l'expert une optimisation de sa politique de maintenance.

Conclusion et perspectives

Les travaux présentés dans cette thèse, s'insèrent dans le cadre plus général de l'aide à la décision en matière de planification d'actions de maintenance. Différents indicateurs concernant le niveau de dégradation d'un système complexe sont proposés afin d'aider l'expert dans sa prise de décision pour d'éventuelles actions de maintenance à programmer ou reprogrammer. Cette thèse traite essentiellement du diagnostic et du pronostic de défaillance. Ces deux processus sont primordiaux pour apporter de l'aide au choix de décision de maintenance optimale (réduction de coût, risque...). En effet, ils permettent de déterminer dans quel état de fonctionnement le système évolue et anticipent son comportement futur.

Les principales notions relatives au diagnostic et au pronostic pour la maintenance ont été introduites au début de ce manuscrit. Le premier chapitre a notamment permis d'identifier les modèles de comportements possibles pouvant mener à la défaillance. Il identifie également l'émergence de la stratégie de maintenance prévisionnelle et traite des concepts de diagnostic et de pronostic. Le cadre de travail et les hypothèses sur le type du système considéré dans nos travaux ont par la suite été définis.

Le second chapitre fut consacré à notre approche d'estimation de l'état de santé d'un système. Les différentes étapes de l'approche proposée ont été décrites. Cette approche est fondée sur l'utilisation d'un observateur pour la construction d'indicateurs de dégradation et l'utilisation des Modèles de Markov Cachés pour la modélisation du comportement de la dégradation. La mise en œuvre de l'approche sur un système de régulation de niveau d'eau pour un Modèle de Markov Caché et son extension floue est exposée.

Le troisième chapitre a présenté deux approches de pronostic de défaillance. La première approche dite « markovienne » fait appel au Modèle de Markov Caché utilisé pour la modélisation du comportement de la dégradation et à ses propriétés, notamment son comportement asymptotique. La deuxième approche repose sur l'utilisation de modèle de comportement de système. Elle utilise un observateur associé à une technique de prédiction. Ces deux approches ont été illustrées sur des exemples de dégradations du système de régulation de niveau d'eau.

Dans le dernier chapitre, les deux approches de pronostic proposées ont été appliquées sur une machine asynchrone et une batterie. L'approche markovienne a été mise en œuvre sur une machine asynchrone. Pour cette application, l'extension multi-flux du modèle de Markov a été utilisée car deux indicateurs de dégradation ont été générés. L'approche à base de modèles traite du pronostic d'une batterie Li-Ion. Un couplage des deux approches a également été illustré.

La contribution de notre travail a consisté à proposer deux approches de diagnostic/pronostic, chacune reposant sur un ou plusieurs outils de modélisation. Nous nous sommes focalisés sur les systèmes complexes pour lesquels les observations disponibles ne sont pas suffisantes voire pertinentes pour la surveillance directe de l'état de dégradation du système. Autrement dit, les mesures présentes sur le système ne permettent pas de donner une indication sur la présence de dégradations et/ou son stade d'évolution.

L'approche markovienne pour le pronostic repose sur l'utilisation conjointe d'un observateur et d'un Modèle de Markov Caché ou l'une de ses extensions. Le but de l'observateur est de générer un signal indicateur de la dégradation et le Modèle de Markov Caché de modéliser les niveaux de dégradation et de les représenter sous forme d'états. Cette approche repose sur

deux phases : une première phase d'apprentissage réalisée hors ligne et une seconde phase d'exploitation (ou de test) réalisée en ligne. L'objectif de la première phase consiste à identifier le modèle de dégradation. La seconde phase permet d'évaluer l'état de santé et de prédire la durée de vie résiduelle sur le système surveillé.

L'approche à base de modèles quant à elle, s'appuie sur la mise en œuvre d'un observateur associé à des outils et techniques de prédiction. L'observateur cette fois-ci est utilisé dans le but de suivre le comportement des états et paramètres du système. Les estimés ainsi obtenus par l'observateur sont ensuite utilisés pour alimenter les outils de prédiction et ainsi déterminer l'évolution future de la dégradation. Les pronostics sont réalisés en comparant les résultats obtenus par la simulation de modèle du système et les performances souhaitées. Des techniques d'identification, d'analyse de série temporelle et d'analyse de tendance peuvent être utilisées en fonction du mécanisme de dégradation. Dans cette thèse, nous avons illustré les méthodes d'inférences statistiques et celles à base d'apprentissage.

Les deux approches ont été appliquées sur différents systèmes (le système de régulation de niveau d'eau, la machine asynchrone et la batterie) pour montrer leur efficacité et leur applicabilité. De part leur aspect générique, elles peuvent être généralisées à d'autres types de systèmes que ceux abordés dans ce manuscrit.

Le travail accompli pourra être conforté à l'avenir suivant plusieurs pistes :

- développer l'aspect robustesse des approches en particulier pour le pronostic des systèmes incertains. Une piste envisagée est l'utilisation d'observateur intervalle dans le cadre du suivi des états et des paramètres intéressants à surveiller.
- prendre en compte l'interaction du système avec d'autres systèmes et l'effet des facteurs environnementaux. Une des possibilités envisagées serait, d'utiliser la stratégie développée dans [Zhou et al., 2010]. Les auteurs ont associé au Modèle de Markov des fonctions de croyance pour les représenter en tant que connaissances expertes. Regarder dans ce cadre, le développement d'outils de calcul de fiabilité prévisionnelle et les prévisions de MTBF pour les systèmes maintenus [Couallier et al., 2016].
- prendre en compte les interventions de maintenance durant la phase de pronostic et donc prévoir une réduction du niveau de dégradation.
- développer des approches qui peuvent s'affranchir des difficultés liées à la disponibilité et la représentativité des données d'apprentissage. Autrement dit : améliorer l'apprentissage des modèles en présence des données sous représentées.
- formaliser le passage d'un modèle formé par une base de données obtenue par des essais accélérés à un modèle répondant à des conditions réelles d'utilisation. Cette stratégie apporterait un gain de temps et permettrait de s'affranchir des longues durées d'acquisition pour l'apprentissage du modèle.
- utiliser des critères d'information pour le choix du nombre de classes pertinent. En effet, travailler sur la pertinence des classes est primordiale. Des travaux sur la pertinence des

symboles présentés dans [Robles, 2013] pourraient être une base de réflexion.

- maîtriser l'erreur de prédiction obtenue par SVM et ANFIS. Il serait donc intéressant d'améliorer les algorithmes d'apprentissage des paramètres. La majorité des travaux portent sur la construction de modèles capables de minimiser l'erreur de prédiction. Cependant, peu de travaux traitent de la maîtrise de cette erreur de prédiction [Dragomir, 2008]. Cette maîtrise de l'erreur de prédiction nous semble essentielle car cela permettrait d'associer une confiance.
- valider nos travaux sur un système réel et aborder la contrainte d'implantation temps réel.

Annexe A

Algorithmes

A.1 Algorithmes de quantification

A.1.1 K-means

Algorithm 1 Algorithme K-moyenne

EntréeEnsemble de N données d'apprentissage $(r_n), 0 \leq n \leq N$ Nombre de classes K **Sortie**Un dictionnaire (le centre des K classes) $V = \{v_1, \dots, v_K\}$ **Initialisation** $Dis_0 = \infty, t = 0$ Soit un dictionnaire $V_0 = \{v_1^0, \dots, v_K^0\}$ de taille K **Répéter** $t \leftarrow t + 1$

Construction de la partition en assignant chaque observation à la classe dont le centre est le plus proche.

Calculer les centres associés à la nouvelle partition :

$$v_i^t = \{r_n | d(r_n, v_i^{t-1}) \leq d(r_n, v_j^{t-1}), j \neq i\}$$

Calculer la distorsion :

$$Dis_t = \frac{1}{N} \sum_{n=1}^N \min_{i=1}^K [d(r_n, v_i^t)]$$

Tant que $\left| \frac{Dis_{t-1} - Dis_t}{Dis_t} \right| > \epsilon$

A.1.2 Algorithme LBG

Algorithm 2 Algorithme LBG

EntréeEnsemble de N données d'apprentissage $(r_n), 0 \leq n \leq N$ Nombre de classe K ou $K = 2^p$ **Sortie**Un dictionnaire (le centre des K classes) $V = \{v_1, \dots, v_K\}$ **Initialisation** $t = 0$ Initialisation du centre $V_0 = \{v_0^0\}$, $|V_0| = 2^p$ avec v_0^0 le centre de gravité de l'ensemble d'apprentissage**Pour** $k = 0 : p - 1$ **faire****Eclatement « Splitting »** : la taille du dictionnaire est doublé en éclatant chaque centre v_k en deux nouveaux centres : $v_{2k}^t = v_k^t + \epsilon$, et $v_{2k+1}^t = v_k^t - \epsilon$ **Convergences** : l'algorithme de « K-means » est appliqué sur le dictionnaire des $2k + 1$ éléments ainsi constitué. Après convergence un dictionnaire « optimal » de $2k + 1$ éléments est obtenu.**Fin**

Le test d'arrêt peut se faire aussi par rapport à un seuil minimal sur la distorsion des données d'apprentissage par rapport au dictionnaire, comme dans le cas de l'algorithme de « K-means ».

A.2 Algorithmes de MMC

A.2.1 Algorithme de Baum-Welch

Algorithm 3 Algorithme de Baum-Welch

Choisir un modèle initial

 $t = 0$ **Répéter**| $t \leftarrow t + 1$ | Calculer les variables *Forward* et *Backward* pour le modèle λ_{t-1} | Calculer π de λ_t | Calculer A de λ_t | Calculer B de λ_t **Tant que** $(P(V = O, \lambda_t) > P(V = O, \lambda_{t-1}))$ et $(t > t_{max})$

A.2.2 Algorithme de Viterbi

Algorithm 4 Algorithme de Viterbi

Pour $i = 1$ à N **Faire**| $\delta_t(1) = \pi_i b_i(o_1)$ **Fin Pour****Pour** $t = 2$ à T **Faire**| **Pour** $j = 1$ à N **Faire**| | $\psi_t = \arg \max_{1 \leq i \leq N} \{\delta_{t-1}(i) a_{i,j}\}$ | | $\delta_t(j) = \max_{1 \leq i \leq N} \delta_{t-1}(\psi_t(j)) a_{\psi_t(j),j} b_j(o_t)$ | **Fin Pour****Fin Pour** $q_T^* = \arg \max_{1 \leq i \leq N} \{\delta_t(i)\}$ $P(V = O, S = Q^*) = \max_{1 \leq i \leq N} \{\delta_t(i)\}$ **Pour** $t = T - 1$ à 1 **Faire**| $q_T^* = \psi_{t+1} q_{t+1}^*$ **Fin Pour**

A.3 Algorithmes Metropolis-Hastings et Gibbs

A.3.1 Algorithme de Metropolis-Hastings

Algorithm 5 Algorithme de Metropolis-Hastings

Entrées

La graine de l'algorithme θ_0

Le nombre d'itération T
 $t = 1$
Pour $t \leq T$ **faire**

| Générer le candidat θ_t selon la loi $g(\tilde{\theta}_t|\theta_{t-1})$

| Générer le critère d'acceptation α selon la loi $\min = \left\{ \frac{\pi(\tilde{\theta}_t)g(\tilde{\theta}_{t-1}|\tilde{\theta}_t)}{\pi(\tilde{\theta}_{t-1})g(\tilde{\theta}_{t-1}|\theta_t)}, 1 \right\}$

| Générer $\mu \approx U_{[0,1]}$

| **Si** $\mu \leq \alpha$ **alors**

| $\theta_i = \tilde{\theta}_i$

| **Sinon**

| $\theta_i = \theta_{i-1}$

| **Fin**
Fin

A.3.2 Algorithme de Gibbs

Algorithm 6 Algorithme de Gibbs

Entrées

La graine de l'algorithme θ_0

Le nombre d'itération T
 $t = 1$
Pour $t \leq T$ **faire**

| Générer θ_2^{t+1} en simulant la loi conditionnelle $P(\theta_1|\theta_2^t)$

| Générer θ_1^{t+1} en simulant la loi conditionnelle $P(\theta_2|\theta_1^{t+1})$

| Poser $\theta^{t+1} = [\theta_1^{t+1} \ \theta_2^{t+1}]$
Fin

Bibliographie

- Abed, A., Baghli, L., Razik, H., and Rezzoug, A. (1999). Modelling induction motors for diagnostic purposes. In *EPE*, volume 99, pages 1–9.
- Aggab, T., Vrignat, P., Avila, M., and Kratz, F. (2015a). Estimation du niveau de dégradation d'un système dans un contexte de maintenance dynamique. In *JN MACS'2015, Bourges, 2015*.
- Aggab, T., Vrignat, P., Avila, M., and Kratz, F. (2015b). Estimation du niveau de dégradation par un modèle de Markov caché multi-flux. In *QUALITA' 2015*, Nancy, France.
- Aggab, T., Vrignat, P., Avila, M., and Kratz, F. (2016). Établissement d'un pronostic de dégradation sur un système asservi. In *20 ème Congrès de Maîtrise des Risques et de Sécurité de Fonctionnement*.
- Al Jed, H. (2014). *Influence de la recharge rapide sur les performances des accumulateurs lithium des véhicules électriques dans le cadre de l'utilisation postale*. PhD thesis, Université de Bordeaux.
- Arkan, M., Perovic, D. K., and Unsworth, P. (2001). Online stator fault diagnosis in induction motors. *IEE Proceedings - Electric Power Applications*, 148(6) :537–547.
- Auger, F., Hilaiet, M., Guerrero, J. M., Monmasson, E., Orlowska-Kowalska, T., and Katsura, S. (2013). Industrial Applications of the Kalman Filter : A Review. *IEEE Transactions on Industrial Electronics*, 60(12) :5458–5471.
- Aupetit, S. (2005). *Contributions aux modèles de Markov cachés : Métaheuristiques d'apprentissage, nouveaux modèles et visualisation de dissimilarité*. PhD thesis, Université François Rabelais-Tours.
- Bachir, S. (2002). *Contribution au diagnostic de la machine asynchrone par estimation paramétrique*. PhD thesis, Université de Poitiers. UFR des sciences fondamentales et appliquées.
- Bachir, S., Tnani, S., Trigeassou, J. C., and Champenois, G. (2006). Diagnosis by parameter estimation of stator and rotor faults occurring in induction machines. *IEEE Transactions on Industrial Electronics*, 53(3) :963–973.
- Bagdonavičius, V. and Nikulin, M. (2000). *Semiparametric Estimation in Accelerated Life Testing*, pages 405–418. Birkhäuser Boston, Boston, MA.
- Balle, P. and Isermann, R. (1998). Fault detection and isolation for nonlinear processes based on local linear fuzzy models and parameter estimation. In *American Control Conference, 1998.*, volume 3.
- Barlow, R. E. and Proschan, F. (1975). Statistical theory of reliability and life testing : probability models. Technical report, DTIC Document.
- Baruah, P. and Chinnam, R. B. (2005). HMMs for diagnostics and prognostics in machining processes. *International Journal of Production Research*, 43(6) :1275–1293.
- Baskiotis, C., Raymond, J., and Rault, A. (1979). Parameter identification and discriminant analysis for jet engine mechanical state diagnosis. *1979 18th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes*, 18 :648–650.
- Baum, L. E., Petrie, T., Soules, G., and Weiss, N. (1970). A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains. *The Annals of Mathematical Statistics*, 41(1) :164–171.

-
- Beard, R. V. (1971). *Failure accomodation in linear systems through self-reorganization*. PhD thesis, Massachusetts Institute of Technology.
- Beichl, I. and Sullivan, F. (2000). The Metropolis Algorithm. *Computing in Science & Engineering*, 2(1) :65–69.
- Benkedjouh, T., Medjaher, K., Zerhouni, N., and Rechak, S. (2013). Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence*, 26(7) :1751–1760.
- Benkedjouh, T., Medjaher, K., Zerhouni, N., and Rechak, S. (2015). Health assessment and life prediction of cutting tools based on support vector regression. *Journal of Intelligent Manufacturing*, 26(2) :213–223.
- Bezdek, J. C. (2013). *Pattern recognition with fuzzy objective function algorithms*. Springer Science & Business Media.
- Bideault, G. (2015). *Détection de mots clés et d’expressions régulières en vue de la reconnaissance d’entités nommées dans des documents manuscrits*. PhD thesis, Université de Rouen.
- Bilmes, J. A. (1998). A gentle tutorial of the EM algorithm and its application to parameter estimation for Gaussian mixture and hidden Markov models. *International Computer Science Institute*, 4(510) :126.
- Binsztok, H. (2007). *Apprentissage de modèles Markoviens pour l’analyse de séquences*. PhD thesis, Paris 6.
- Blanchet, M. and Bergerried, R. (2014). *Industrie 4.0- Les leviers de la transformation*. Gimélec.
- Bonavita, N., Fazio, M., and Mainini, M. T. (1994). Mode-based fault detection and isolation techniques : the parameter identification approach within the framework of the TOPMUSS CAE-system. In *Control Applications, 1994., Proceedings of the Third IEEE Conference on*, volume 2, pages 1369–1378.
- Bornard, G., Celle-Couenne, F., and Gilles, G. (1993). *Systèmes non linéaires. 1, Modélisation-Estimation*. Masson.
- Borne, P. and Richard, J. P. (1992). *Modélisation et identification des processus*, volume 1. Editions Technip.
- Bose, B. K. (2002). *Modern Power Electronics and AC Drives*.
- Bouleau, N. (1988). *Processus stochastiques et applications*. Hermann Paris.
- Broussely, M., Biensan, P., Bonhomme, F., Blanchard, P., Herreyre, S., Nechev, K., and Staniewicz, R. (2005). Main aging mechanisms in Li ion batteries. *Journal of Power Sources*, 146(1–2) :90–96.
- Bunks, C., Mccarthy, D., and Al-Ani, T. (2000). Condition-based maintenance of machines using hidden markov models. *Mechanical Systems and Signal Processing*, 14(4) :597–612.
- Byington, C. S., Kalgren, P. W., Dunkin, B. K., and Donovan, B. P. (2004). Advanced diagnostic/prognostic reasoning and evidence transformation techniques for improved avionics maintenance. In *Aerospace Conference*, volume 5.
- Byington, C. S., Roemer, M. J., and Galie, T. (2002). Prognostic enhancements to diagnostic systems for improved condition-based maintenance [military aircraft]. In *Aerospace Conference Proceedings*, volume 6, pages 2815–2824.
- Camci, F. and Chinnam, R. B. (2010). Health-State Estimation and Prognostics in Machining Processes. *IEEE Transactions on Automation Science and Engineering*, 7(3) :581–597.
- Camci, F., Valentine, G. S., and Navarra, K. (2007). Methodologies for integration of phm systems with maintenance data. Technical report, DTIC Document.
- Cassar, J. P., Litwak, R., Cocquempot, V., and Staroswiecki, M. (1994). Approche structurelle de la conception de systèmes de surveillance pour des procédés industriels complexes. *Diagnostic et sûreté de fonctionnement*, 4(2) :179–202.
- Castanier, B. (2001). *Modélisation stochastique et optimisation de la maintenance conditionnelle des systèmes à dégradation graduelle*. PhD thesis, Université de Technologie de Troyes.

-
- Chattopadhyay, S., Mitra, M., and Sengupta, S. (2008). Area based approach for three phase power quality assessment in Clarke plane. *Journal of Electrical Systems*, 4(3).
- Chelidze, D., Cusumano, J., and Chatterjee, A. (2002). A dynamical systems approach to damage evolution tracking, part 1 : description and experimental application. *Journal of Vibration and Acoustics*, 124(2) :250–257.
- Chen, M. and Rincon-Mora, G. A. (2006). Accurate electrical battery model capable of predicting runtime and I-V performance. *IEEE Transactions on Energy Conversion*, 21(2) :504–511.
- Chien, Y. H. and Sheu, S. (2006). Extended optimal age-replacement policy with minimal repair of a system subject to shocks. *European Journal of Operational Research*, 174(1) :169–181.
- Chinnam, R. B. and Baruah, P. (2003). Autonomous diagnostics and prognostics through competitive learning driven HMM-based clustering. In *Neural Networks, 2003. Proceedings of the International Joint Conference on*, volume 4, pages 2466–2471.
- Chow, E. and Willsky, A. (1984). Analytical redundancy and the design of robust failure detection systems. *IEEE Transactions on Automatic Control*, 29(7) :603–614.
- Chow, E. Y. (1980). *A failure detection system design methodology*. PhD thesis, Massachusetts Institute of Technology.
- Chatterjee, A., Cusumano, J. P., and Chelidze, D. (2002). Optimal tracking of parameter drift in a chaotic system : experiment and theory. *Journal of Sound and Vibration*, 250(5) :877–901.
- Clarotti, C., Lannoy, A., Odin, S., and Procaccia, H. (2004). Detection of equipment aging and determination of the efficiency of a corrective measure. *Reliability Engineering & System Safety*, 84(1) :57–64.
- Cleveland, W. S. and Devlin, S. J. (1988). Locally weighted regression : an approach to regression analysis by local fitting. *Journal of the American Statistical Association*, 83(403) :596–610.
- Cocheteux, P. (2010). *Contribution à la maintenance proactive par la formalisation du processus de pronostic des performances de systèmes industriels*. PhD thesis, Université Henri Poincaré-Nancy I.
- Combacau, M. (1991). *Commande et surveillance des systèmes à événements discrets complexes : application aux ateliers flexibles*. PhD thesis, Université de Toulouse 3.
- Couallier, V., Denis, L., and Bayle, F. (2016). Calcul de MTBF des systs anautiques inspectodiquement soumis pture aloire de systs de rlation. In *20 ème Congrès de Maîtrise des Risques et de Sûreté de Fonctionnement*.
- Cox, D. R. (1992). *Regression Models and Life-Tables*, pages 527–541. Springer New York.
- Cusumano, J. P., Chelidze, D., and Chatterjee, A. (2002). A dynamical systems approach to damage evolution tracking, part 2 : Model-based validation and physical interpretation. *Journal of Vibration and Acoustics*, 124(2) :258–264.
- Daigle, M. and Goebel, K. (2011). A model-based prognostics approach applied to pneumatic valves. *International Journal of Prognostics and Health Management*, 2(2) :84–99.
- Daigle, M., Saha, B., and Goebel, K. (2012a). A comparison of filter-based approaches for model-based prognostics. In *Aerospace Conference, 2012 IEEE*, pages 1–10.
- Daigle, M., Saxena, A., and Goebel, K. (2012b). An efficient deterministic approach to model-based prediction uncertainty estimation. Technical report, DTIC Document.
- Dash, S. and Venkatasubramanian, V. (2000). Challenges in the industrial applications of fault diagnostic systems. *Computers & Chemical Engineering*, 24(2) :785–791.
- De Gooijer, J. G. and Hyndman, R. J. (2006). 25 years of time series forecasting. *International journal of forecasting*, 22(3) :443–473.

-
- Deloux, E. (2008). *Politiques de maintenance conditionnelle pour un système à dégradation continue soumis à un environnement stressant*. PhD thesis, Université de Nantes.
- DePold, H. R. and Gass, F. D. (1998). The application of expert systems and neural networks to gas turbine prognostics and diagnostics. In *ASME 1998 International Gas Turbine and Aeroengine Congress and Exhibition*. American Society of Mechanical Engineers.
- Derbel, H. (2009). *Diagnostic à base de modèles des systèmes temporisés et d'une sous-classe de systèmes dynamiques hybrides*. PhD thesis, Université Joseph-Fourier-Grenoble I.
- Desai, M. and Ray, A. (1981). A fault detection and isolation methodology. In *Decision and Control including the Symposium on Adaptive Processes, 1981 20th IEEE Conference on*, pages 1363–1369.
- Diday, E. and Simon, J. C. (1976). *Digital Pattern Recognition*, chapter Clustering Analysis, pages 47–94. Springer Berlin Heidelberg.
- Ding, S. (2008). *Model-based fault diagnosis techniques : design schemes, algorithms, and tools*. Springer Science & Business Media.
- Ding, X. and Frank, P. M. (1990). Fault detection via factorization approach. *Systems & Control Letters*, 14(5) :431–436.
- Dougherty, J., Kohavi, R., and Sahami, M. (1995). Supervised and unsupervised discretization of continuous features. In *Machine learning : proceedings of the twelfth international conference*, volume 12, pages 194–202.
- Dragomir, O. E. (2008). *Contribution au pronostic de défaillances par réseau neuro-flou : maîtrise de l'erreur de prédiction*. PhD thesis, Université de Franche-Comté.
- Dragomir, O. E., Dragomir, F., Gouriveau, R., and Minca, E. (2010). Medium term load forecasting using ANFIS predictor. In *Control Automation (MED), 2010 18th Mediterranean Conference on*, pages 551–556.
- Dragomir, O. E., Gouriveau, R., Dragomir, F., Minca, E., and Zerhouni, N. (2009). Review of prognostic problem in condition-based maintenance. In *Control Conference (ECC), 2009 European*, pages 1587–1592.
- Duesterhoeft, W., Schulz, M. W., and Clarke, E. (1951). Determination of instantaneous currents and voltages by means of alpha, beta, and zero components. *Transactions of the American Institute of Electrical Engineers*, 70(2) :1248–1255.
- Eddahech, A. (2013). *Modélisation du vieillissement et détermination de l'état de santé de batteries lithium-ion pour application véhicule électrique et hybride*. PhD thesis, Université Sciences et Technologies-Bordeaux I.
- Emara, H. M., Ammar, M. E., Bahgat, A., and Dorrah, H. T. (2003). Stator fault estimation in induction motors using particle swarm optimization. In *Electric Machines and Drives Conference, 2003. IEMDC'03. IEEE International*, volume 3, pages 1469–1475.
- Ertunc, H. M., Loparo, K. A., and Ocak, H. (2001). Tool wear condition monitoring in drilling operations using hidden Markov models (HMMs). *International Journal of Machine Tools and Manufacture*, 41(9) :1363–1384.
- Fayyad, U. M. and Irani, K. B. (1993). Multi-interval discretization of continuous-valued attributes for classification learning. In *Proceedings of the 13th International Joint Conference on Artificial Intelligence*. Springer Science & Business Media.
- Fink, G. A. (2014). *Markov models for pattern recognition : from theory to applications*. Springer Science & Business Media.
- Frank, P. M. (1987). Advance fault detection and isolation schemes using non-linear and robust observers. In *Proc. of 10th IFAC World Congress*, pages 63–68, Munich.
- Frank, P. M. (1990). Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy. *Automatica*, 26(3) :459–474.
- George, V., Frank, L., Michael, R., Andrew, H., and Biqing, W. (2006). Intelligent fault diagnosis and prognosis for engineering systems.

-
- Gertler, J. J. and Kunwer, M. M. (1995). Optimal residual decoupling for robust fault diagnosis. *International Journal of Control*, 61(2) :395–421.
- Ghouili, J. (2006). *Commande sans capteur d'une machine asynchrone avec estimation de la vitesse par réseaux de neurones*. PhD thesis, Université du Québec à Trois-Rivières.
- Giantomassi, A., Ferracuti, F., Benini, A., Ippoliti, G., Longhi, S., and Petrucci, A. (2011). Hidden Markov model for health estimation and prognosis of turbofan engines. In *ASME 2011 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, pages 681–689. American Society of Mechanical Engineers.
- Goebel, K. and Bonissone, P. (2005). Prognostic information fusion for constant load systems. In *2005 7th International Conference on Information Fusion*, volume 2.
- Golnaraghi, F. and Kuo, B. C. (2009). Automatic control systems. *Complex Variables*, 2.
- Greenland, S. (2011). The Logic and Philosophy of Causal Inference : A Statistical Perspective. In Bandyopadhyay, P. S. and Forster, M. R., editors, *Philosophy of Statistics*, volume 7 of *Handbook of the Philosophy of Science*, pages 813–830. North-Holland, Amsterdam.
- Greitzer, F. L. and Pawlowski, R. A. (2002). Embedded prognostics health monitoring. In *48th Annual instrumentation, systems, and automation society international instrumentation symposium, San Diego, CA*.
- Gucik-Derigny, D. (2011). *Contribution au pronostic des systèmes à base de modèles : théorie et application*. PhD thesis, Université Aix-Marseille III Paul Cézanne.
- Gucik-Derigny, D., Outbib, R., and Ouladsine, M. (2016). A comparative Study of Unknown-Input Observers for Prognosis Applied to an Electromechanical System. *IEEE Transactions on Reliability*, 65(2) :704–717.
- Guernez Jean, C. (1998). *Surveillance de systemes a modeles polynomiaux : generation de residus et etude de sensibilité*. PhD thesis, Université des Sciences et Technologies de Lille.
- Gustafson, D. E. and Kessel, W. C. (1978). Fuzzy clustering with a fuzzy covariance matrix. In *Decision and Control including the 17th Symposium on Adaptive Processes, 1978 IEEE Conference on*, pages 761–766.
- Hammouri, H., Kinnaert, M., and Yaagoubi, E. H. E. (1999). Observer-based approach to fault detection and isolation for nonlinear systems. *IEEE Transactions on Automatic Control*, 44(10) :1879–1884.
- Han, X., Ouyang, M., Lu, L., Li, J., Zheng, Y., and Li, Z. (2014). A comparative study of commercial lithium ion battery cycle life in electrical vehicle : Aging mechanism identification. *Journal of Power Sources*, 251 :38–54.
- He, H., Xiong, R., and Fan, J. (2011). Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach. *Energies*, 4(4) :582–598.
- Hêche, J. F., Liebling, T. M., and De Werra, D. (2003). *Recherche opérationnelle pour ingénieurs*, volume 2. PPUR presses polytechniques.
- Hoskins, J. C., Kaliyur, K. M., and Himmelblau, D. M. (1991). Fault diagnosis in complex chemical plants using artificial neural networks. *AIChE Journal*, 37(1) :137–141.
- Huynh, K. T. (2011). *Quantification de l'apport de l'information de surveillance dans la prise de décision en maintenance*. PhD thesis, Université de Technologie de Troyes.
- Isermann, R. (1984). Process fault detection based on modeling and estimation methods -a survey. *Automatica*, 20(4) :387–404.
- Isermann, R. (2000). *Integration of Fault Detection and Diagnosis Methods*, pages 15–49. Springer London, London.
- Isermann, R. and Ballé, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*, 5(5) :709–719.

-
- Jang, J. S. R. (1993). ANFIS : adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3) :665–685.
- Jang, J. S. R., Sun, C. T., and Mizutani, E. (1997). Neuro-fuzzy and soft computing ; a computational approach to learning and machine intelligence. *Prentice-Hall, Inc.*
- Jardine, A. K. S. and Banjevic, D. (2005). FROM EQUIPMENT CONDITION MONITORING TOOLS : METHOD AND SOFTWARE. *Modern Statistical and Mathematical Methods in Reliability*, 10 :263.
- Kacprzyński, G. J., Roemer, M. J., Modgil, G., Palladino, A., and Maynard, K. (2002). Enhancement of physics-of-failure prognostic models with system level features. In *Aerospace Conference Proceedings, 2002. IEEE*, volume 6, pages 2919–2925.
- Kalman, R. (1959). On the general theory of control systems. *IRE Transactions on Automatic Control*, 4(3) :110–110.
- Kaufman, L. and Rousseeuw, P. J. (2009). *Finding groups in data : an introduction to cluster analysis*, volume 344. John Wiley & Sons.
- Keskin, M. E., Taylan, D., and Terzi, . (2006). Adaptive neural-based fuzzy inference system (ANFIS) approach for modelling hydrological time series. *Hydrological Sciences Journal*, 51(4) :588–598.
- Klutke, G. A. and Yang, Y. (2002). The availability of inspected systems subject to shocks and graceful degradation. *IEEE Transactions on Reliability*, 51(3) :371–374.
- Kotsiantis, S. and Kanellopoulos, D. (2006). Discretization techniques : A recent survey. *GESTS International Transactions on Computer Science and Engineering*, 32(1) :47–58.
- Kresta, J. V., Macgregor, J. F., and Marlin, T. E. (1991). Multivariate statistical monitoring of process operating performance. *The Canadian Journal of Chemical Engineering*, 69(1) :35–47.
- Kwon, K. C. and Kim, J. H. (1999). Accident identification in nuclear power plants using hidden Markov models. *Engineering Applications of Artificial Intelligence*, 12(4) :491–501.
- L. E. Baum, T. P. (1966). Statistical Inference for Probabilistic Functions of Finite State Markov Chains. *The Annals of Mathematical Statistics*, 37(6) :1554–1563.
- Lagoune, R., Chateauneuf, A., and Aissani, D. (2009). Opportunistic policy for optimal preventive maintenance of a multi-component system in continuous operating units. *Computers & Chemical Engineering*, 33(9) :1499–1510.
- Le Letty, L. (1995). Parameter estimation in analytical models of automotive vehicles and fault diagnosis. In *American Control Conference, Proceedings of the 1995*, volume 2, pages 1050–1054. IEEE.
- Lebold, M. and Thurston, M. (2001). Open standards for condition-based maintenance and prognostic systems. In *5th Annual Maintenance and Reliability Conference*.
- Lee, J. M., Kim, S. J., Hwang, Y., and Song, C. S. (2004). Diagnosis of mechanical fault signals using continuous hidden Markov model. *Journal of Sound and Vibration*, 276(3–5) :1065–1080.
- Leger, J. B. (1999). *Contribution méthodologique à la maintenance prévisionnelle des systèmes industriels de production : proposition d’un cadre formel de modélisation*. PhD thesis, Université Nancy I.
- Letot, C. (2013). *Maintenance prévisionnelle d’équipements industriels basée sur la modélisation, l’estimation et la simulation de lois de dégradation*. PhD thesis, Faculté Polytechnique de Mons.
- Li, Y., Wang, R., Xu, J., Yang, G., and Zhao, B. (2009). Intrusion Detection Method Based on Fuzzy Hidden Markov Model. In *Fuzzy Systems and Knowledge Discovery, 2009. FSKD ’09. Sixth International Conference on*, volume 3, pages 470–474.
- Li, Z., Wu, Z., He, Y., and Fulei, C. (2005). Hidden Markov model-based fault diagnostics method in speed-up and speed-down process for rotating machinery. *Mechanical Systems and Signal Processing*, 19(2) :329–339.

-
- Lièvre, A. (2015). *Développement d'un système de gestion de batterie lithium-ion à destination de véhicules "mild hybrid" : détermination des indicateurs d'état (SoC, SoH et SoF)*. PhD thesis, Université Claude Bernard-Lyon I.
- Linde, Y., Buzo, A., and Gray, R. (1980). An Algorithm for Vector Quantizer Design. *IEEE Transactions on Communications*, 28(1) :84–95.
- Ling, Z. H., Richmond, K., Yamagishi, J., and Wang, R. H. (2009). Integrating Articulatory Features Into HMM-Based Parametric Speech Synthesis. *IEEE Transactions on Audio, Speech, and Language Processing*, 17(6) :1171–1185.
- Liu, D., Luo, Y., Liu, J., Peng, Y., Guo, L., and Pecht, M. (2014a). Lithium-ion battery remaining useful life estimation based on fusion nonlinear degradation AR model and RPF algorithm. *Neural Computing and Applications*, 25(3) :557–572.
- Liu, Z., Ahmed, Q., Rizzoni, G., and He, H. (2014b). Fault detection and isolation for lithium-ion battery system using structural analysis and sequential residual generation. In *ASME 2014 Dynamic Systems and Control Conference*. American Society of Mechanical Engineers.
- Lloyd, S. (1982). Least squares quantization in PCM. *IEEE Transactions on Information Theory*, 28(2) :129–137.
- Lolas, S., Olatunbosun, O., Steward, D., and Buckingham, J. (2007). Fuzzy Logic Knowledge Base Construction for a Reliability Improvement Expert System. In *World Congress on Engineering*, pages 132–137.
- Luenberger, D. G. (1971). An introduction to observers. *Automatic Control, IEEE Transactions on*, 16(6) :596–602.
- Luo, J., Pattipati, K. R., Qiao, L., and Chigusa, S. (2008). Model-Based Prognostic Techniques Applied to a Suspension System. *IEEE Transactions on Systems, Man, and Cybernetics - Part A : Systems and Humans*, 38(5) :1156–1168.
- Maquin, D., Cocquempot, V., Cassar, J. P., Staroswiecki, M., and Ragot, J. (1997). Generation of Analytical Redundancy Relations for FDI purposes. In *IFAC Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives, SDEMPED'97*, pages 86–93, Carry-le Rouet, France.
- Markel, T., Smith, K., and Pesaran, A. A. (2009). Improving petroleum displacement potential of PHEVs using enhanced charging scenarios. *Electr. Hybrid Veh. Power Sources Models Sustain. Infrastruct. Mark.*
- Medjaher, K. (2014). Contribution au pronostic de défaillances guidé par des données. *Habilitation à Diriger des Recherches, Université de Franche-Comté*.
- Medjaher, K., Tobon-Mejia, D. A., and Zerhouni, N. (2012). Remaining Useful Life Estimation of Critical Components With Application to Bearings. *IEEE Transactions on Reliability*, 61(2) :292–302.
- Miao, Q. and Makis, V. (2007). Condition monitoring and classification of rotating machinery using wavelets and hidden Markov models . *Mechanical Systems and Signal Processing*, 21(2) :840 – 855.
- Montmain, J. (1997). From diapason research program to its industrial application in nuclear fuel reprocessing. In *IFAC Symposium on Fault Detection, Supervision and Safety for Technical Process-SAFEPROCESS'97*, pages 209–216.
- Muller, A. (2005). *Contribution à la maintenance prévisionnelle des systèmes de production par la formalisation d'un processus de pronostic*. PhD thesis, Université de Nancy 1.
- Nachlas, J. A. (2005). *Reliability engineering : probabilistic models and maintenance methods*. CRC Press.
- Nakagawa, T. (2007). *Shock and damage models in reliability theory*. Springer Science & Business Media.
- Nelwamondo, F. V., Marwala, T., and Mahola, U. (2006). Early classifications of bearing faults using hidden Markov models, Gaussian mixture models, Mel frequency cepstral coefficients and fractals. *International Journal of Innovative Computing, Information and Control*, 2(6) :1281–1299.

-
- NFEN2001. 13306–x60-319 (2001). *Terminologie de la maintenance*.
- Nguyen, D. N. (2015). *Contribution aux approches probabilistes pour le pronostic et la maintenance des systèmes contrôlés*. PhD thesis, Université de Technologie de Troyes.
- Ondel, O., Boutleux, E., and Clerc, G. (2006). A method to detect broken bars in induction machine using pattern recognition techniques. *IEEE Transactions on Industry Applications*, 42(4) :916–923.
- O'Reilly, J. (1983). *Observers for linear systems*, volume 170. Academic Press.
- Patterson-Hine, A., Biswas, G., Aaseng, G., Narasimhan, S., and Pattipati, K. (2005). A review of diagnostic techniques for ISHM applications. In *Proceedings of the First International Forum on Integrated System Health Engineering and Management in Aerospace*.
- Patton, R. J. (1994). Robust model-base fault diagnosis : The state of the art. In *Preprints of the IFAC Sympo. on Fault Detection, Supervision and Safetyfor Technical Processes : SAFEPROCESS'94*, volume 1, pages 1–27, Espoo, Finland.
- Patton, R. J. and Chen, J. (1997). Observer-based fault detection and isolation : Robustness and applications. *Control Engineering Practice*, 5(5) :671 – 682.
- Peng, Y. and Dong, M. (2011). A hybrid approach of {HMM} and grey model for age-dependent health prediction of engineering assets . *Expert Systems with Applications*, 38(10) :12946–12953.
- Philippot, A. (2006). *Contribution au diagnostic décentralisé des systèmes à événements discrets : Application aux systèmes manufacturiers*. PhD thesis, Université de Reims-Champagne Ardenne.
- Pijnenburg, M. (1991). Additive hazards models in repairable systems reliability. *Reliability Engineering & System Safety*, 31(3) :369–390.
- Potter, I. E. and Sunman, M. C. (1977). Threshold-less redundancy management with arrays of skewed instruments. Technical report, AGARD.
- Proschan, F. (1996). *Mathematical Theory of Reliability*.
- Prum, B. (2012). Chaînes de Markov et absorption. Application à l'algorithme de Fu en génomique. *Journal de la Société Française de Statistique*, 153(2) :37–51.
- Rabiner, L. R. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2) :257–286.
- Rajashekara, K., Kawamura, A., and Matsuse, K. (1996). *Sensorless control of AC motor drives : speed and position sensorless operation*. IEEE press New York.
- Rashid, M. and Gupta, A. (2014). Mathematical model for combined effect of SEI formation and gas evolution in li-ion batteries. *ECS Electrochemistry Letters*, 3(10) :A95–A98.
- Rausand, M. and Høyland, A. (2004). *System reliability theory : models, statistical methods, and applications*, volume 396. John Wiley & Sons.
- Rezvanizani, S. M., Liu, Z., Chen, Y., and Lee, J. (2014). Review and recent advances in battery health monitoring and prognostics technologies for electric vehicle (EV) safety and mobility . *Journal of Power Sources*, 256 :110 –124.
- Ribot, P. (2009). *Vers l'intégration diagnostic/pronostic pour la maintenance des systèmes complexes*. PhD thesis, Université Paul Sabatier-Toulouse III.
- Rifqi, M. (2010). *Mesures de similarité, raisonnement et modélisation de l'utilisateur*. PhD thesis, Habilitation a Diriger des Recherches, Universitierre et Marie Curie.
- Robinson, D. G. (2001). A hierarchical Bayes approach to system reliability analysis. *Sandia Report Sand 2001*, 3513.

-
- Robles, B. (2013). *Etude de la pertinence des parametres stochastiques sur des modeles de Markov caches*. PhD thesis, Université d'Orléans.
- Saha, B., Goebel, K., Poll, S., and Christophersen, J. (2009). Prognostics Methods for Battery Health Monitoring Using a Bayesian Framework. *IEEE Transactions on Instrumentation and Measurement*, 58(2) :291–296.
- Sandborn, P. A. and Wilkinson, C. (2007). A maintenance planning and business case development model for the application of prognostics and health management (PHM) to electronic systems . *Microelectronics Reliability*, 47(12) :1889–1901. Electronic system prognostics and health management Thermal, mechanical and multi-physics simulation and experiments in micro-electronics and micro-systems (EuroSimE 2006).
- Sankararaman, S., Daigle, M. J., and Goebel, K. (2014). Uncertainty Quantification in Remaining Useful Life Prediction Using First-Order Reliability Methods. *IEEE Transactions on Reliability*, 63(2) :603–619.
- Saxena, A., Celaya, J., Balaban, E., Goebel, K., Saha, B., Saha, S., and Schwabacher, M. (2008). Metrics for evaluating performance of prognostic techniques. In *Prognostics and Health Management, 2008. PHM 2008. International Conference on*, pages 1–17.
- Saxena, A., Celaya, J., Saha, B., Saha, S., and Goebel, K. (2009). On applying the prognostic performance metrics. In *Annual Conference of the Prognostics and Health Management Society*.
- Sazonov, E. S., Klinkhachorn, P., Gangarao, H. V. S., and Halabe, U. B. (2002). Fuzzy logic expert system for automated damage detection from changes in strain energy mode shapes. *Nondestructive Testing and Evaluation*, 18(1) :1–20.
- Scanff, E., Feldman, K., Ghelam, S., Sandborn, P., Glade, M., and Foucher, B. (2007). Life cycle cost impact of using prognostic health management (PHM) for helicopter avionics . *Microelectronics Reliability*, 47(12) :1857–1864. Electronic system prognostics and health management Thermal, mechanical and multi-physics simulation and experiments in micro-electronics and micro-systems (EuroSimE 2006).
- Schwarte, A., Kimmidi, F., and Isermann, R. (2004). Model-based fault detection of a diesel engine with turbo charger-a case study. In *Fault Detection, Supervision and Safety of Technical Processes 2003 (SAFEPROCESS 2003) : A Proceedings Volume from the 5th IFAC Symposium, Washington, DC, USA, 9-11 June 2003*, volume 1, page 293. Elsevier.
- Shirmohammadi, B., Vafakhah, M., Moosavi, V., and Moghaddamnia, A. (2013). Application of Several Data-Driven Techniques for Predicting Groundwater Level. *Water Resources Management*, 27(2) :419–432.
- Si, X. S., Wang, W., Hu, C. H., and 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.
- Sikorska, J., Hodkiewicz, M., and Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry . *Mechanical Systems and Signal Processing*, 25(5) :1803–1836.
- Silva, R. E., Gouriveau, R., Jemeï, S., Hissel, D., Boulon, L., Agbossou, K., and Steiner, N. Y. (2014). Proton exchange membrane fuel cell degradation prediction based on Adaptive Neuro-Fuzzy Inference Systems . *International Journal of Hydrogen Energy*, 39(21) :11128–11144.
- Singpurwalla, N. D. (1995). Survival in Dynamic Environments. *Statistical Science*, 10(1) :86–103.
- Soualhi, A. (2013). *Du diagnostic au pronostic de pannes des entraînements électriques*. PhD thesis, Université Claude Bernard-Lyon I.
- Soualhi, A., Clerc, G., Razik, H., and Ondel, O. (2011). Detection of induction motor faults by an improved artificial ant clustering. In *IECON 2011 - 37th Annual Conference on IEEE Industrial Electronics Society*, pages 3446–3451.
- Soualhi, A., Medjaher, K., and Zerhouni, N. (2015). Bearing Health Monitoring Based on Hilbert x2013;Huang Transform, Support Vector Machine, and Regression. *IEEE Transactions on Instrumentation and Measurement*, 64(1) :52–62.

-
- Soualhi, A., Razik, H., Clerc, G., and Doan, D. D. (2014). Prognosis of Bearing Failures Using Hidden Markov Models and the Adaptive Neuro-Fuzzy Inference System. *IEEE Transactions on Industrial Electronics*, 61(6) :2864–2874.
- Tobon-Mejia, D. A., Medjaher, K., Zerhouni, N., and Tripot, G. (2011). Hidden Markov Models for failure diagnostic and prognostic. In *2011 Prognostics and System Health Management Conference*, pages 1–8.
- Tobon-Mejia, D. A., Medjaher, K., Zerhouni, N., and Tripot, G. (2012). A Data-Driven Failure Prognostics Method Based on Mixture of Gaussians Hidden Markov Models. *IEEE Transactions on Reliability*, 61(2) :491–503.
- Toguyeni, A. (1992). *Surveillance et diagnostic en ligne dans les ateliers flexibles de l'industrie manufacturière*. PhD thesis, Université des Sciences et Technologies de Lille.
- Vapnik, V. (2013). *The nature of statistical learning theory*. Springer Science & Business Media.
- Venkatasubramanian, V., Rengaswamy, R., and Kavuri, S. N. (2003). A review of process fault detection and diagnosis : Part I : Quantitative model-based methods . *Computers & Chemical Engineering*, 27(3) :293–311.
- Verron, S. (2007). *Diagnostic et surveillance des processus complexes par réseaux bayésiens*. PhD thesis, Université d'Angers.
- Villemeur, A. (1988). *Sûreté de fonctionnement des systèmes industriels*.
- Vinh, D. (2010). *Diagnostic de batteries Lithium ion dans des applications embarquées*. PhD thesis, Université de Technologie de Compiègne.
- Vrignat, P., Avila, M., Duculty, F., and Kratz, F. (2015). Failure Event Prediction Using Hidden Markov Model Approaches. *IEEE Transactions on Reliability*, 64(3) :1038–1048.
- Wang, P. and Coit, D. W. (2004). Reliability prediction based on degradation modeling for systems with multiple degradation measures. In *Reliability and Maintainability, 2004 Annual Symposium - RAMS*, pages 302–307.
- Welte, T. (2008). *Deterioration and maintenance models for components in hydropower plants*. PhD thesis, Department of Production and Quality Engineering, Norwegian University of Science and Technology, Trondheim.
- Whitmore, G. A. (1995). Estimating degradation by a wiener diffusion process subject to measurement error. *Lifetime Data Analysis*, 1(3) :307–319.
- Wise, B. M. and Gallagher, N. B. (1996). The process chemometrics approach to process monitoring and fault detection. *Journal of Process Control*, 6(6) :329–348.
- Wolsztynski, É. (2006). *Critère d'entropie pour l'estimation semi-paramétrique*. PhD thesis, Université de Nice-Sophia Antipolis.
- Yam, M. R. C., Tse, P., Li, L., and Tu, P. (2001). Intelligent Predictive Decision Support System for Condition-Based Maintenance. *The International Journal of Advanced Manufacturing Technology*, 17(5) :383–391.
- Yang, Q. (2004). *Model-based and data driven fault diagnosis methods with applications to process monitoring*. PhD thesis, Case Western Reserve University.
- Zemouri, R. (2003). *Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamiques : Application à la e-maintenance*. PhD thesis, Université de Franche-Comté.
- Zemouri, R., Racocanu, D., and Zerhouni, N. (2003). Recurrent radial basis function network for time-series prediction . *Engineering Applications of Artificial Intelligence*, 16(5–6) :453–463.
- Zhang, X., Xu, R., Kwan, C., Liang, S. Y., Xie, Q., and Haynes, L. (2005). An integrated approach to bearing fault diagnostics and prognostics. In *Proceedings of the 2005, American Control Conference, 2005.*, pages 2750–2755 vol. 4.

Zhou, Z. J., Hu, C. H., Xu, D. L., Chen, M. Y., and Zhou, D. H. (2010). A model for real-time failure prognosis based on hidden Markov model and belief rule base . *European Journal of Operational Research*, 207(1) :269–283.

Zille, V. (2009). *Modélisation et évaluation des stratégies de maintenance complexes sur des systèmes multi-composants*. PhD thesis, Université de Technologie de Troyes.

Toufik AGGAB

Pronostic des systèmes complexes par l'utilisation conjointe de modèle de Markov caché et d'observateur.

Résumé :

Cette thèse porte sur le diagnostic et le pronostic pour l'aide à la maintenance de systèmes complexes. Elle présente deux approches de diagnostic/pronostic qui permettent de générer les indicateurs utiles pour l'optimisation de la stratégie de maintenance. Plus précisément, ces approches permettent d'évaluer l'état de santé et de prédire la durée de vie résiduelle du système. Les approches présentées visent en particulier à pallier le problème d'absence d'indicateurs de dégradation. Les développements sont fondés sur l'utilisation d'observateurs, de formalisme de Modèle de Markov Caché, des méthodes d'inférences statistiques et des méthodes de prédiction de séries temporelles à base d'apprentissage afin de caractériser et prédire les modes de fonctionnement du système. Les deux approches sont illustrées sur des exemples de dégradation d'un système de régulation de niveau d'eau, d'une machine asynchrone et d'une batterie Li-Ion.

Mots clés : Pronostic, diagnostic, observateur, résidu, Modèle de Markov Caché, niveau de dégradation, durée de vie résiduelle, SVR, ANFIS.

Prognosis of complex systems based on the joint use of an observer and a hidden Markov model.

Abstract :

The research presented in this thesis deals of diagnosis and prognosis of complex systems. It presents two approaches that generate useful indicators for optimizing maintenance strategies. Specifically, these approaches are used to assess the level of degradation and estimate the Remaining Useful Life of the system. The aim of these approaches is to overcome for the lack of degradation indicators. The developments are based on observers, Hidden Markov Model formalism, statistical inference methods and learning-based methods in order to characterize and predict the system operating modes. To illustrate the proposed failure diagnosis/prognosis approaches, a simulated tank level control system, an induction motor and a Li-Ion battery were used.

Keywords : Prognosis, diagnosis, observer, residue, hidden Markov model, level of degradation, Remaining Useful Life, SVR, ANFIS.



Laboratoire PRISME

INSA INSTITUT NATIONAL
DES SCIENCES
APPLIQUÉES
CENTRE VAL DE LOIRE