



UNIVERSITÉ PARIS-SACLAY
ÉCOLE CENTRALESUPÉLEC
UNIVERSITÉ LIBANAISE FACULTÉ DE GÉNIE

Estimation de la durée de vie résiduelle d'une chambre de combustion LRE

Mme Soha KANSO

Master 2 Automatique, Traitement du Signal et des Images

Superviseurs

Dr. Mayank Shekhar JHA (CRAN - Université de Lorraine)

Prof. Didier THEILLIOL (CRAN - Université de Lorraine)

et M. Marco GALEOTTA (CNES)

Tutrice universitaire

Prof Cristina Maniu (École CentraleSupélec)

Version de 31 août 2021

Remerciements

Tout d'abord, je tiens à remercier vivement mes encadrants de stage Prof. Didier Theilliol, Dr. Mayank Shekhar Jha et M. Marco Galeotta pour leur accueil, le temps passé ensemble et le partage de leur expertise au quotidien. Grâce aussi à leur confiance j'ai pu m'accomplir totalement dans mes missions. Ils furent d'une aide précieuse dans les moments les plus délicats.

Je remercie également mes directeurs de programme à Ecole CentraleSupélec Prof. Didier Dumur et Prof. Guillaume Sandou et mes responsables du Master 2 à l'Université Paris-Saclay Prof. Antoine Girard et Prof. Aurelia Fraysse. Je désire aussi remercier mes professeurs à École CentraleSupélec, à l'université Paris-Saclay et à l'Université Libanaise, qui m'ont fourni les outils nécessaires au bon déroulement de mon stage. Je tiens particulièrement à remercier Prof. Cristina Maniu pour ses conseils et ses recommandations en tant que tutrice universitaire.

Enfin, je tiens à remercier le Centre National d'Etudes Spatiales (CNES) pour l'assistance technique et la disponibilité des données de dégradation simulées.

Résumé

La réutilisation de fusées dans leur cycle de vie nominale est considérée comme un moyen de réduire les coûts des vols spatiaux. Par conséquent, au cours des dernières années, des recherches ont été menées pour estimer l'état de santé et la vie utile restante afin de prolonger la durée de vie de ces dispositifs. Cependant, les méthodes développées sont difficilement exploitables pour effectuer des pronostics avec une quantification en ligne de l'incertitude. Ce travail de recherche vise à résoudre ce problème en proposant un algorithme de pronostic basé sur un estimateur et déclenché par une détection d'occurrence d'un défaut. Un filtre de Kalman étendu estime l'état de santé réel et la dynamique de la dégradation avec l'incertitude associée. Une méthode de fiabilité inverse du premier ordre est utilisée pour extrapoler l'état de santé jusqu'à un seuil limite, pour lequel la durée de vie résiduelle est donnée avec un intervalle de confiance. La méthode globale est validée à l'aide des données de dégradation de simulation fournies par le CNES.

Table des matières

1	Introduction	1
2	État de l’art	3
2.1	Définition du pronostic	3
2.1.1	La relation entre le diagnostic et le pronostic	3
2.1.2	Limites de confiance	3
2.2	Classification des approches	4
2.3	Classification des modèles	4
2.4	Modèles basés sur la connaissance	5
2.4.1	Systèmes experts	5
2.4.2	Systèmes basés sur la logique floue	6
2.5	Modèles d’espérance de vie	6
2.5.1	Modèles stochastiques	6
2.5.1.1	Fonctions de fiabilité agrégées	6
2.5.1.2	Modèles de probabilité conditionnelle	7
2.5.2	Modèles statistiques	10
2.5.2.1	Évaluation des tendances	10
2.5.2.2	Modèles autorégressifs	10
2.5.2.3	Modélisation des risques proportionnels	11
2.6	Réseaux neuronaux artificiels (ANN)	11
2.6.1	Prévision de la valeur RUL	12
2.6.2	RUL via l’estimation des paramètres	12
2.7	Modèles physiques	12
2.8	Conclusion	13
3	Moteur à ergol liquide	14
3.1	Description du moteur	14
3.2	Modélisation et description de la dégradation	15
3.3	Conclusion	17

4	Estimation de l'état de santé (SoH)	18
4.1	Filtre de Kalman Etendu	18
4.2	Initialisation et réglage du filtre de Kalman étendu	20
4.3	Application de EKF aux données du CNES	21
4.4	Résultats et discussion	23
4.5	Conclusion	25
5	Estimation de la durée de vie résiduelle (RUL)	26
5.1	Prédiction de la RUL par projection	26
5.2	Prédiction analytique de RUL	28
5.3	Résultats et discussion	28
6	Quantification de l'incertitude de RUL	30
6.1	Incertitude de RUL	30
6.2	Avantages de l'approche IFORM	31
6.3	Méthode de fiabilité de premier ordre	32
6.4	Méthode inverse de fiabilité de premier ordre (IFORM)	35
6.5	Exemple de mise en œuvre de l'approche IFORM	36
6.6	Application de l'approche IFORM sur les données de CNES	38
6.7	Conclusion	39
7	Fonctionnement en boucle fermée	40
8	Conclusions et Perspectives	42

Table des figures

1.1	Étapes pour l'estimation de l'état de santé	2
2.1	Principales catégories de modèles pour la prédiction de la durée de vie résiduelle utile	5
3.1	Synoptique moteur	15
3.2	Dégradation du rendement de la vitesse caractéristique.	16
3.3	Dégradation de l'indicateur de santé SoH	17
4.1	Estimation de l'état de santé	23
4.2	Estimation du taux d'évolution de la dégradation	23
4.3	Innovation et son intervalle de confiance	24
4.4	Test de blancheur	24
4.5	Estimation de l'état de santé d'un moteur de quantification	25
4.6	Estimation du taux d'évolution de la dégradation d'un moteur de quantification	25
5.1	Illustration de la Durée de Vie Résiduelle	26
5.2	Algorithme de prédiction de RUL.	27
5.3	Résultats de l'estimation de la RUL du moteur de vol	29
5.4	La difference entre RUL_{proj} et RUL_{cal}	29
6.1	Estimation du MPP	33
6.2	Estimation de l'état de santé	36
6.3	Estimation de α	36
6.4	Estimation et Quantification de l'incertitude de RUL	37
6.5	Estimation et Quantification de l'incertitude de RUL pour un moteur de vol	38
6.6	Temps de simulation de la méthode IFORM	39
7.1	Diagramme du fonctionnement en boucle fermée	40
7.2	Estimation de l'état de santé en BO et en BF	41
7.3	Estimation de la durée de vie résiduelle en BO et BF	41

Chapitre 1

Introduction

La nécessité d'un système de gestion de l'état de santé précis et efficace est devenue extrêmement importante dans les systèmes d'ingénierie critiques pour la sécurité et la mission. L'objectif de la gestion de l'état de santé est de surveiller en permanence les performances de ces systèmes, d'effectuer un diagnostic (détection, isolation et estimation des défauts), d'établir un pronostic (prédire les défaillances possibles dans le futur et estimer la durée de vie résiduelle) et d'aider à la prise de décision en ligne (atténuation des défauts, récupération des défauts, replanification de la mission, etc.)[1].

En utilisant les données pertinentes du système à surveiller, des indicateurs de l'état de santé ainsi que leurs tendances peuvent être construits. D'habitude, le diagnostic est effectué au niveau du système ou du sous-système, et le pronostic est effectué au niveau des composants. L'évaluation et la gestion des incertitudes sont des aspects importants de la gestion de la santé, en raison de la présence de plusieurs facteurs inconnus qui affectent le fonctionnement du système concerné. Par conséquent, il est non seulement important de développer des algorithmes robustes pour le diagnostic et le pronostic, c'est-à-dire d'effectuer avec précision le diagnostic et le pronostic en présence d'incertitudes, mais aussi de quantifier le degré de confiance dans les résultats du diagnostic et du pronostic.

Les méthodes de pronostic basées sur les informations de mesure de l'état sont divisées en grandes catégories [2] : techniques basées sur un modèle, techniques basées sur les données et approches hybrides. Les méthodes basées sur des modèles nécessitent une connaissance précise de la dynamique de la progression de la dégradation. En particulier dans le contexte des LPRE, la dynamique comportementale du système et les modèles de progression de la dégradation sont pour la plupart non linéaires et, généralement, non connus de manière précise. Cela rend l'utilité des méthodes purement basées sur des modèles très limitée. D'autre part, les méthodes purement basées sur les données restent difficiles à développer en raison du manque de données sur les défaillances pendant le fonctionnement réel. Les approches hybrides combinent les avantages des approches basées sur les modèles et celles basées sur

les données, dans la mesure où un modèle de dégradation approximativement correct est fusionné avec les informations fournies par les mesures des capteurs réels de manière appropriée.

Ce rapport présente une approche pronostique hybride pour l'évaluation de l'état de santé et la prédiction du RUL d'une chambre de combustion LPRE déclenchée à l'issue d'une détection du défaut. Le système d'étude est un moteur de fusée à propulsion liquide (LPRE) flexible et adapté à un grand nombre de missions. Le LPRE fonctionne avec un mélange LOX-LH2, ce qui apporte une meilleure efficacité et une grande facilité dans la manipulation du carburant. La réutilisation de fusée dans son cycle de vie nominale est considérée comme un moyen de réduire les coûts des vols spatiaux. Ce nouveau besoin ainsi que l'amélioration continue de la performance et la réduction de la masse imposent une réflexion de plus en plus poussée sur la possibilité d'employer des systèmes de surveillance de l'état de dégradation du moteur capables de reconfigurer la performance en cas de détection d'un défaut et/ou d'une panne. Ces systèmes devraient aussi prendre en considération l'état de dégradation du moteur ainsi que la prédiction de sa durée de vie résiduelle (RUL - Remaining Useful Life en anglais).



FIGURE 1.1 – Étapes pour l'estimation de l'état de santé

Dans ce contexte, ce rapport présente une brève description du moteur à ergol liquide et sa dégradation. Il traite l'estimation de l'état de santé (SoH - State Of Health en anglais) et son évolution dans le futur en utilisant un modèle de dégradation approprié et un filtre stochastique. La prédiction du RUL est générée à chaque pas de temps d'observation, ce qui conduit à des prédictions du RUL en ligne pour finalement quantifier l'incertitude de RUL. La Figure 1.1 présente le synoptique des composants de ce rapport

Ce rapport se compose de huit chapitres. Dans le chapitre 2, quelques généralités et un état de l'art du pronostic sont présentés. Le chapitre 3 décrit le système d'étude et ses performances ainsi que sa dégradation. Dans le chapitre 4, un algorithme d'estimation d'état de santé est proposé en se basant sur un filtre de Kalman étendu pour prédire la RUL. Dans le chapitre 5, l'estimation de la durée de vie résiduelle est calculé par projection et par expression explicite. Le chapitre 6 décrit l'algorithme IFORM, qui est ensuite utilisé pour l'estimation de l'incertitude. Une comparaison est établie entre le fonctionnement en boucle ouverte et en boucle fermée dans le chapitre 7. Enfin, le chapitre 8 présente une conclusion et les perspectives.

Chapitre 2

État de l'art

L'essentiel de l'état de l'art qui va être présenté dans ce chapitre est fondé principalement sur l'article [1]. Ce dernier a un grand avantage de présenter un ensemble global sur les modèles de pronostic. Donc, nous nous focalisons dans ce chapitre sur les méthodes de pronostic, les méthodes de diagnostic sont supposées connues et classiques. L'article [1] explore les forces et les faiblesses des principales classes de modèles de pronostic afin d'établir ce qui les rend plus adaptés à certaines applications qu'à d'autres.

2.1 Définition du pronostic

Le pronostic est "une estimation du temps jusqu'à la défaillance et du risque pour un ou plusieurs modes de défaillance existants et futurs" [3]. Cela implique que le domaine de la pronostique ne s'intéresse pas seulement à la prédiction des effets des modes de défaillance connus sur la durée de vie des actifs, mais aussi à la manière dont ceux-ci peuvent déclencher d'autres modes de défaillance. Ainsi, un plus grand nombre de types de modèles sont englobés par le terme "modèles de pronostic".

2.1.1 La relation entre le diagnostic et le pronostic

Le diagnostic implique l'identification et la quantification des détériorations qui se sont produites tandis que le pronostic s'efforce de prédire les détériorations qui doivent encore se produire. Bien que le diagnostic puisse fournir des résultats commerciaux utiles en soi, le pronostic compte sur les résultats du diagnostic (par exemple, les indicateurs de défaillance, les taux de dégradation, l'occurrence de l'apparition du défaut, ...).

2.1.2 Limites de confiance

Une sortie pronostique a deux composantes : (i) un temps estimé jusqu'à la défaillance, qui est également appelé durée de vie résiduelle ou durée de vie utile restante (RUL), et (ii) une limite de confiance associée. Cette valeur de confiance est nécessaire en raison de l'incertitude associée au processus de détérioration, de l'ambiguïté concernant le fonctionnement futur de la machine et enfin des

erreurs associées aux méthodes de diagnostic et de pronostic appliquées. Les limites de confiance sont encore plus importantes dans la modélisation pronostique que dans la prédiction diagnostique. Les décisions commerciales basées sur des informations pronostiques doivent donc être basées sur les limites de l'intervalle de confiance RUL plutôt que sur une valeur spécifique de la durée de vie attendue.

2.2 Classification des approches

Le pronostic peut être abordé en trois approches [2] :

- Basée sur un modèle : un modèle empirique ou physique de la dégradation est utilisé. Cette méthode ne nécessite pas un grand nombre de données. Cependant, la construction d'un tel modèle n'est pas une tâche facile. En effet, les phénomènes de dégradation peuvent ne pas être totalement compris et nécessitent des investigations.
- Basée sur les données : cette méthode ne nécessite pas une connaissance préalable du système mais une grande quantité de données telle que modèles autorégressifs, réseaux neuronaux artificiels, modèles de Markov et semi-Markov, modèles de Markov cachés (HMM) et semi- cachés (HSMM), etc.
- Hybride : c'est une combinaison des deux méthodes précédentes. Un modèle de dégradation approximativement correct est fusionné avec les informations apportées par les mesures des capteurs réels de manière appropriée telle que Filtre de Kalman, Filtres particulières, etc.

2.3 Classification des modèles

Une approche de classification, spécifiquement conçue pour la prédiction de la durée de vie restante, est proposée. Présentée dans la Figure 2.1, les modèles sont classés en 4 groupes principaux et un nombre variable de sous-groupes :

1. Modèles basés sur la connaissance ;
2. Modèles d'espérance de vie ;
3. Réseaux neuronaux artificiels ;
4. Modèles physiques .

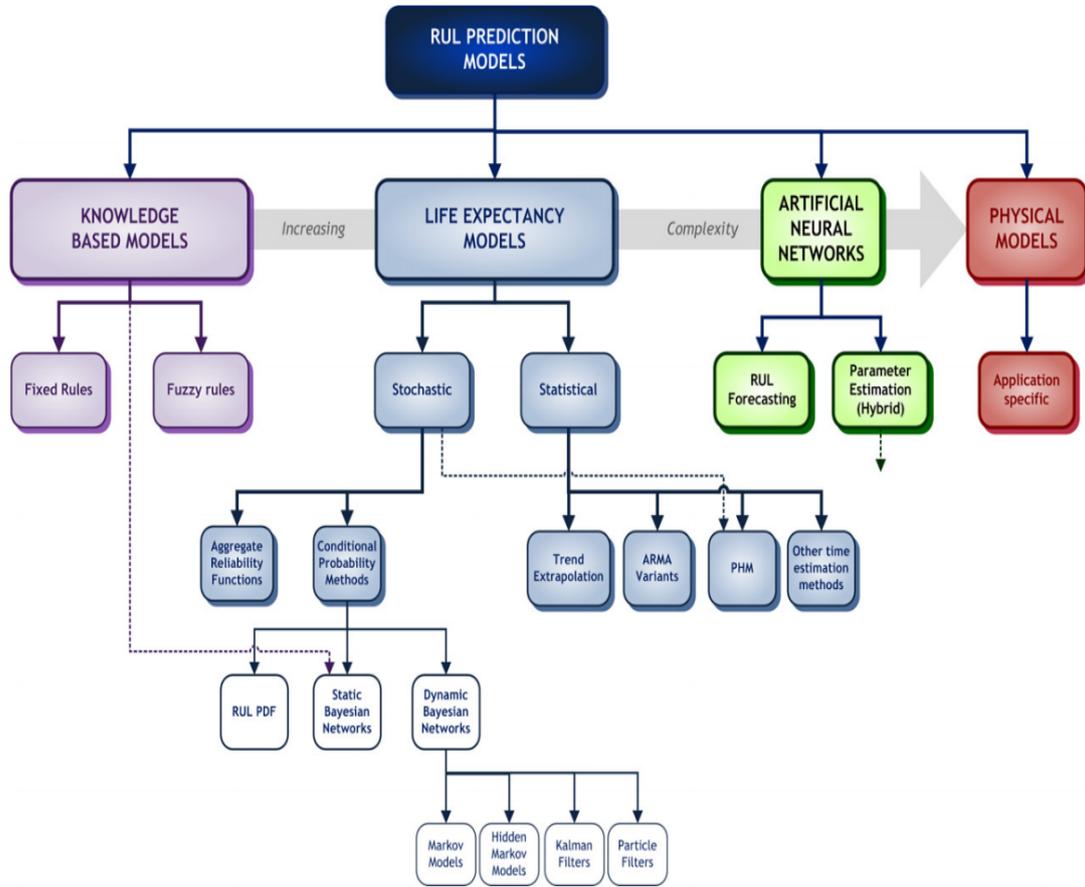


FIGURE 2.1 – Principales catégories de modèles pour la prédiction de la durée de vie résiduelle utile

2.4 Modèles basés sur la connaissance

Les modèles basés sur la connaissance évaluent la similarité entre une situation observée et une banque de données de défaillances définies précédemment et déduisent l'espérance de vie à partir d'événements antérieurs.

2.4.1 Systèmes experts

Un système expert est un programme logiciel (ou un ensemble de programmes) qui simule les performances d'experts humains dans un domaine particulier. Il se compose généralement d'une base de connaissances contenant l'expérience accumulée par les experts du sujet et d'une base de règles permettant d'appliquer ces connaissances à des problèmes particuliers connus du système logiciel. Pour être utile, une base de connaissances doit être aussi complète et exacte que possible [4]. La base de connaissances devra également être mise à jour et entretenue au fur et à mesure de l'acquisition de nouvelles connaissances ou de l'évolution des configurations de l'usine et du processus. Les systèmes experts sont utilisés pour résoudre des problèmes normalement résolus par des spécialistes humains. Leur avantage est que les sorties sont compréhensibles et que le raisonnement pour un résultat particulier peut être établi. Malheureusement, la qualité des systèmes experts dépend de celle des experts

qui élaborent la base de règles. En outre, il leur est impossible de fournir une prédiction de variable continue, cela limite leur utilité pour estimer directement la RUL.

2.4.2 Systèmes basés sur la logique floue

Un système flou est composé d'une base de connaissances, d'une base de règles floues et des algorithmes d'application de la logique. Les modèles de logique floue sont les plus efficaces lorsqu'une ou plusieurs des variables d'entrée sont continues, un modèle mathématique n'est pas disponible ou ne peut être mis en œuvre et les données contiennent des niveaux élevés de bruit. Ils sont également capables de fournir des résultats avec des données incomplètes ou inexactes, comme cela se produit fréquemment dans la pratique. En outre, ils peuvent expliquer leur raisonnement et, du fait qu'ils ont moins de règles, ils sont plus simples à adapter que les systèmes experts. Malheureusement, ils dépendent aussi de la disponibilité d'un expert approprié pour spécifier les règles qui sous-tendent le comportement du système et pour développer les ensembles flous représentant les caractéristiques de chaque variable.

2.5 Modèles d'espérance de vie

Les modèles d'espérance de vie déterminent la durée de vie résiduelle utile des composants individuels de la machine par rapport au risque de détérioration attendu dans des conditions de fonctionnement connues.

2.5.1 Modèles stochastiques

Les modèles stochastiques fournissent des informations relatives à la fiabilité, telles que le temps moyen de défaillance sous forme de probabilités de défaillance par rapport au temps. Ils se basent sur l'hypothèse que les temps de défaillance de composants identiques peuvent être considérés comme des variables aléatoires statistiquement identiques et indépendantes et donc peuvent être décrits par une fonction de densité de probabilité.

2.5.1.1 Fonctions de fiabilité agrégées

L'analyse de fiabilité des données de défaillance agrégées est l'un des outils les plus couramment utilisés par l'industrie pour analyser la performance des actifs et évaluer leur comportement futur probable. Cette approche consiste à analyser les temps de défaillance d'une population d'équipements/modes de défaillance et à déterminer une fonction de densité de probabilité et une fonction de risque correspondante pour la population. Cette fonction de densité de probabilité n'est pas représentative de la progression d'un défaut unique, de l'amorce à la défaillance finale. Elle fournit plutôt des informations sur le moment où les défaillances sont typiquement censées se produire. L'avantage de toutes les

approches de modélisation basées sur la fiabilité est que les distributions sont généralement dérivées de données statistiques observées pour l'équipement/composant concerné. Elles fournissent également des limites de confiance sur les résultats, ce qui est obligatoire pour la prise de décision. L'analyse est également relativement simple et peut être effectuée par des ingénieurs en fiabilité ; des experts ne sont donc pas nécessaires.

2.5.1.2 Modèles de probabilité conditionnelle

Un certain nombre de modèles stochastiques utilisent des approches qui décrivent un état actuel sous la forme d'une fonction de fiabilité conditionnelle, puis utilisent le théorème de Bayes, directement ou implicitement, pour mettre à jour les estimations probabilistes du comportement futur. Une fois qu'une fonction de fiabilité conditionnelle est déterminée, la fonction de durée de vie utile restante est définie comme le temps conditionnel attendu jusqu'à la défaillance, étant donné l'état actuel, qui peut ou non dépendre du temps.

2.5.1.2.1. Fonction de densité de probabilité RUL

Il s'agit d'une extension de l'analyse de fiabilité agrégée traditionnelle car elle nécessite la fonction de densité de probabilité du mode de défaillance/équipement concerné. Des informations sont ensuite obtenues pour localiser un élément spécifique sur cette distribution générale. La distribution est modifiée pour prendre en compte cette information en utilisant le théorème de Bayes [5] le processus est répété chaque fois qu'une nouvelle observation est faite ; ce processus est appelé "mise à jour" bayésienne. La distribution résultante est connue sous le nom de fonction de densité prédictive, également appelée fonction de densité de probabilité de défaillance de la durée de vie résiduelle utile (RUL). Un intervalle de confiance peut également être dérivé. Il convient de noter que des paramètres d'observation (c'est-à-dire des variables de surveillance de l'état/du processus) différents de ceux utilisés pour la détection et le diagnostic peuvent être nécessaires pour surveiller la progression d'une défaillance. Cela ne peut être déterminé qu'en comprenant comment le système physique et les paramètres d'observation interagissent. Elle est également relativement simple à calculer et utilise des techniques et des logiciels accessibles aux ingénieurs en fiabilité.

2.5.1.2.2. Réseaux bayésiens statiques

Les réseaux bayésiens (BN - Bayesian Networks) sont des modèles graphiques acycliques probabilistes qui représentent un ensemble de variables aléatoires et leurs interdépendances probabilistes. Ils sont alternativement appelés réseaux bayésiens de croyance, réseaux de croyance ou réseaux probabilistes causaux. Un réseau bayésien se compose de nœuds, qui représentent des variables aléatoires pouvant prendre des états ou des niveaux distincts. Ceux-ci sont reliés par des arcs directionnels qui représentent une influence causale directe entre les nœuds dans un modèle acyclique. Chaque nœud possède une table de probabilité conditionnelle qui définit les probabilités pour chaque état du nœud étant donné les états de ses parents. Les modèles sont également simples à construire (même s'ils nécessitent

souvent l'intervention d'un expert), facilement réutilisables et faciles à modifier mais le recalcul peut prendre du temps et nécessite des calculs intensifs car les probabilités de toutes les branches du réseau doivent être réapprises. Comme pour toutes les techniques basées sur le modèle bayésien, les prédictions de RUL sont sous la forme de distributions de probabilité, de sorte que les prédictions ont des limites de confiance calculables. En fin de compte, un réseau bayésien n'est utile que dans la mesure où les connaissances préalables sont disponibles et fiables. La qualité des résultats de prédiction du réseau sera également affectée par la sélection d'une distribution préalable. Il est donc utile d'avoir une certaine compréhension du système physique.

2.5.1.2.3. Réseaux bayésiens dynamiques

Les réseaux bayésiens dynamiques sont ceux dans lesquels les arcs dirigés des BN se déplacent dans le temps et sont donc utiles pour modéliser les données de séries temporelles. Les variantes les plus courantes utilisées dans le pronostic technique sont les modèles de Markov, les filtres de Kalman et les filtres particuliers.

a. Modèles de Markov et semi-Markov

Les modèles de Markov supposent qu'un système ou un composant ne peut, à tout moment, se trouver que dans un seul état parmi un nombre fini d'états. En définissant les probabilités associées à chaque état, ainsi que les probabilités associées à la transition d'un état à un autre, les probabilités de défaillance future peuvent être estimées. Une propriété fondamentale de tous les modèles de Markov est que les états futurs sont indépendants de tous les états passés, sauf les plus récents. L'analyse de Markov suppose que chaque état ne peut avoir que l'une des deux options suivantes : défaillant ou disponible (non défaillant). Elle pose également d'autres hypothèses :

- (i) Les probabilités de passer d'un état à un autre ne changent pas avec le temps (c'est-à-dire que le composant/système a un taux de défaillance constant).
- (ii) Le temps de séjour dans un état particulier est distribué exponentiellement, avec un taux constant.
- (iii) La somme de toutes les probabilités de transition de chaque état vers un autre état différent doit être égale à un.

Les modèles semi-markoviens diffèrent des chaînes de Markov de base en ce qu'ils n'exigent pas que le temps passé dans un état particulier soit distribué de manière exponentielle, mais qu'on peut lui attribuer n'importe quelle distribution. Le principal inconvénient des modèles de Markov et de Semi-Markov est l'hypothèse que le taux de défaillance est constant, qui est rarement valide. Cet inconvénient est surmonté en utilisant les variantes de Markov cachées et semi- cachées qui seront décrites dans la section suivante.

b. Modèles de Markov cachés (HMM) et semi- cachés (HSMM)

Ils constituent une extension des chaînes de Markov dans lesquelles tous les états ne sont pas directement observables et, par conséquent, les probabilités de transition respectives ne sont pas directement assignables. Les modèles de Markov semi-cachés diffèrent des HMM en ce qu'ils ne sont pas liés par

l'hypothèse d'un taux de défaillance constant (ce sont donc simplement des variantes des chaînes de Semi-Markov avec l'inclusion d'états cachés). Ils permettent également de modéliser la durée des états avec une distribution explicite qui ne doit pas nécessairement être exponentielle. Les modèles de Markov semi-cachés sont donc plus appropriés pour le pronostic que les modèles de Markov cachés. Le principal avantage des HMM sous leurs différentes formes est qu'ils permettent de modéliser les phénomènes spatiaux et temporels, et qu'ils peuvent donc classer les données de séries temporelles sans connaissance spécifique du problème, à condition que des données suffisantes soient disponibles pour l'apprentissage. L'un des inconvénients de toutes les formes de modélisation de Markov est qu'elle est très gourmande en ressources informatiques, même pour les modèles les plus simples comportant peu d'états. De plus, l'inconvénient des HMM et des HSMM est qu'ils ne peuvent être utilisés de manière fiable que pour la prévision de défaillances connues pour lesquelles suffisamment de données sont disponibles pour entraîner les modèles.

c. Estimation bayésienne avec des filtres de Kalman

Le filtre de Kalman est une technique de traitement numérique récursive efficace sur le plan informatique, utilisée pour estimer l'état d'un système dynamique à partir d'une série de mesures incomplètes et bruyantes, de manière à minimiser l'erreur quadratique moyenne. À tout moment, le filtre de Kalman est défini par son estimation de l'état et la covariance des erreurs. Il estime des états inconnus à partir des seules observations courantes et de l'état le plus récent ces états ne doivent pas nécessairement être directement mesurables. Le filtrage de Kalman suppose que le bruit du processus et le bruit de mesure sont gaussiens, blancs, indépendants l'un de l'autre et additifs. La covariance du bruit de mesure est généralement quantifiée avant la mise en œuvre du filtre ; ceci est relativement facile lorsque les observations sont stationnaires. La détermination de la covariance du bruit du processus est cependant plus difficile car il n'est souvent pas possible d'observer directement le processus à modéliser. Lorsque les deux covariances du bruit sont constantes entre les itérations (c'est-à-dire que le processus et les données observées sont stationnaires), le filtre atteindra très rapidement l'état stationnaire. Les filtres de Kalman étendus (EKF) sont une modification du filtre de Kalman de base qui ne suppose pas la linéarité du processus ou de la relation entre le processus et les mesures. Au lieu de cela, les dérivées partielles des fonctions du processus et des mesures sont calculées pour linéariser l'estimation autour de la prédiction de l'état actuel. Traditionnellement, l'EKF est la variante de Kalman la plus populaire pour l'estimation d'état des processus non linéaires [6] [7].

d. Estimation bayésienne avec filtres particuliers.

Les filtres particuliers constituent une alternative aux filtres de Kalman pour l'estimation de la distribution a posteriori dans les modèles de réseaux bayésiens, sans être liés par les hypothèses de linéarité ou de bruit gaussien. Ils sont également connus sous le nom de méthodes de simulation de Monte Carlo et sont particulièrement utiles dans les situations où la distribution postérieure est multivariée ou non standard. Pour ce faire, ils tirent un ensemble d'échantillons aléatoires, appelés particules, d'une fonc-

tion de densité théorique, puis ajustent l'ensemble associé de poids de particules à chaque itération. Des échantillons de bruit dynamique sont également générés à chaque cycle. Avec des échantillons suffisants, les filtres particuliers sont plus précis que l'EKF. Ils nécessitent également moins d'échantillons pour approximer correctement la distribution que l'intégration Monte-Carlo classique.

2.5.2 Modèles statistiques

Les modèles statistiques estiment l'initiation et la progression des dégradations sur la base des résultats d'inspections précédentes sur des machines similaires. La prévision de la détérioration future est souvent entreprise en comparant ces résultats avec des modèles représentant un "bon" comportement.

2.5.2.1 Évaluation des tendances

La forme la plus simple de prédiction pronostique de la durée de vie restante est basée sur une simple analyse de tendance d'un paramètre monotone unique corrélé à la durée de vie restante. Ce paramètre peut provenir d'un seul capteur ou d'un certain nombre de capteurs regroupés en une seule variable. Ce paramètre unique est ensuite tracé en fonction du temps. Un niveau d'alarme est préétabli et la fin de vie est considérée comme équivalente à l'atteinte de ce niveau. Une tendance est ensuite calculée sur la base de ces données, en utilisant des méthodes de régression standard. Si les données n'ont pas été reçues pour tous les niveaux de paramètres jusqu'à et (si possible) au-delà des limites d'alarme, la tendance résultante devra être extrapolée en conséquence. L'interpolation est toujours préférable à l'extrapolation, en particulier dans le cadre du pronostic technique, car les mécanismes de défaillance changent souvent au fur et à mesure que la défaillance progresse, ce qui peut modifier radicalement les tendances des paramètres. Les limites d'alarme doivent également être choisies avec soin. La RUL est simplement déterminée comme le moment où la tendance est censée dépasser la ou les limites d'alarme. Bien que ce type d'évaluation de tendance soit simple et facile à mettre en œuvre, les indications de défaillance imminente sont généralement bruyantes et souvent non monotones.

2.5.2.2 Modèles autorégressifs

Les modèles autorégressifs sont largement utilisés pour modéliser et prévoir les données de séries temporelles. Les modèles autorégressifs sont développés en trois étapes récursives : Identification du modèle, Estimation des paramètres, Validation du modèle .

Ces trois étapes sont répétées jusqu'à l'obtention d'un modèle satisfaisant, qui peut ensuite être utilisé pour prévoir les valeurs futures. Les modèles autorégressifs sont efficaces pour les prédictions à court terme, mais moins fiables lorsqu'ils sont utilisés pour les prédictions à long terme en raison du bruit dynamique, de leur sensibilité aux conditions initiales du système et d'une accumulation d'erreurs systématiques dans le prédicteur.

2.5.2.3 Modélisation des risques proportionnels

C'est l'un des modèles les plus utilisés pour le pronostic. Le PHM (Proportional Hazards Modelling) modélise la détérioration du système comme le produit d'un taux de risque de base et d'une fonction positive. La durée de vie utile restante peut être déduite de la fonction de survie associée. Le PHM est soumis à un certain nombre d'hypothèses :

- (a) Les temps jusqu'à la défaillance sont indépendants et identiquement distribués (c'est-à-dire une réparation parfaite).
- (b) Les covariables ont un effet multiplicatif sur le taux de risque de base.
- (c) Les covariables individuelles sont indépendantes (c'est-à-dire que la valeur de la fonction covariable pour un élément n'influence pas le temps de défaillance des autres éléments).
- (d) L'effet des covariables est supposé être indépendant du temps.
- (e) Toutes les covariables influentes sont incluses dans le modèle.
- (f) Le rapport de deux taux de risque est constant par rapport au temps (les courbes de survie respectives ne se croisent donc pas).

L'application du PHM nécessite l'estimation des paramètres de la fonction de risque de base et du vecteur de processus de covariation. Ainsi, la capacité du PHM à estimer la RUL pour le pronostic de défaillances variées dans des systèmes complexes est incertaine et constitue probablement un défi permanent. Lors de l'analyse de systèmes complexes réparables avec un certain nombre de sous-systèmes, de composants et de modes de défaillance associés, l'hypothèse selon laquelle les défaillances sont indépendantes et distribuées de manière identique est rarement justifiée. De plus, le PHM nécessite des données de défaillance pour déterminer les pondérations des covariables donc il ne peut pas être utilisé pour estimer la durée de vie utile résiduelle de modes de défaillance qui ne se sont pas produits auparavant.

2.6 Réseaux neuronaux artificiels (ANN)

Les réseaux neuronaux artificiels calculent une sortie estimée pour la durée de vie résiduelle d'un composant/machine, directement ou indirectement, à partir d'une représentation mathématique du composant/système dérivée de données d'observation plutôt que d'une compréhension physique des processus de défaillance. Ils sont efficaces et efficaces pour modéliser des systèmes non linéaires complexes et peuvent généraliser et adapter des solutions à partir d'un ensemble limité de données. Différents types de données peuvent être utilisés comme entrées du réseau, notamment les variables de processus, les indicateurs de surveillance de l'état, les caractéristiques des actifs et les caractéristiques de l'historique de maintenance. Les réseaux sont constitués d'éléments de traitement simples, également appelés nœuds, neurones ou unités, connectés en couches. Un réseau neuronal typique se compose d'une couche d'entrée unique, d'une ou plusieurs couches cachées et d'une couche de sortie, chacune

comprenant un ou plusieurs nœuds. Les connexions entre les nœuds des couches adjacentes sont pondérées. Une fonction d'activation est associée à chaque nœud et elle définit comment les informations sont transmises aux nœuds suivants. Les valeurs calculées de la fonction d'activation de chaque nœud sont ensuite utilisées comme entrées pour tous les nœuds suivants. La même fonction d'activation est généralement utilisée pour tous les nœuds d'une couche ; toutefois, d'autres couches du même réseau peuvent utiliser des fonctions différentes. Comme le traitement (calcul de la fonction d'activation) peut être effectué par les nœuds en parallèle, les réseaux neuronaux sont très efficaces sur le plan informatique.

2.6.1 Prédiction de la valeur RUL

La prédiction directe d'une valeur RUL est la méthode de pronostic la plus populaire utilisant les ANN. Elle consiste à utiliser un réseau neuronal pour prédire les points suivants d'une série de données temporelles. Cette série de données correspond à une certaine mesure de la durée de vie résiduelle utile. Les données sont extrapolées jusqu'à ce qu'elles atteignent une valeur de "défaillance finale". Le RUL est alors simplement le temps jusqu'à ce que ce point soit atteint. Cela suppose que l'on puisse définir ce qui constitue une défaillance finale. La précision diminue à mesure que le nombre de points extrapolés augmente.

2.6.2 RUL via l'estimation des paramètres

La deuxième utilisation des réseaux neuronaux dans la prédiction de la durée de vie utile implique l'estimation des paramètres d'une fonction connue qui a généralement été dérivée à l'aide de techniques de physique des défaillances. Cette application n'est pas aussi courante que l'estimation directe de la durée de vie utile.

2.7 Modèles physiques

Les modèles physiques caractérisent quantitativement le comportement d'un mode de défaillance en utilisant des lois physiques (c'est-à-dire à partir des premiers principes). Cela implique une compréhension approfondie du comportement du système en réponse aux contraintes. En outre, cela suppose que ce comportement peut être décrit de manière précise et analytique. Les modèles physiques estiment une sortie pour la durée de vie utile restante d'un composant/machine en résolvant une équation déterministe ou un ensemble d'équations dérivées de nombreuses données empiriques. Une fois qu'un modèle physique est disponible, les mesures des capteurs du processus réel sont comparées aux sorties du modèle. Les différences entre la réalité et le modèle sont appelées résidus ; les résidus importants sont supposés indiquer un défaut, tandis que les petits résidus se produisent dans des conditions normales, avec du bruit et des erreurs de modélisation [8]. Les estimations de la durée de vie résiduelle

sont basées sur la projection des comportements de dégradation pour les conditions de fonctionnement futures prévues.

L'inconvénient évident de ces modèles est que le comportement du système doit être dérivé des premiers principes, ce qui n'est pas toujours possible en raison d'une compréhension imparfaite du comportement des mécanismes de défaillance dans la gamme des conditions de fonctionnement pertinentes. Par conséquent, les modèles de physique des défaillances ont tendance à être utilisés dans des cas isolés, pour des défaillances bien comprises dans des systèmes simples [9].

2.8 Conclusion

Le pronostic est une activité nécessaire dans les industries pour prévoir la durée de vie restante et optimiser l'utilisation des machines. Une défaillance imprévue dans ces industries peut être catastrophique et entraîner des temps d'arrêt prolongés, qui peuvent à leur tour entraîner des pertes économiques. Un pronostic efficace peut pallier ce problème en prévoyant l'apparition de pannes à l'avance, de sorte que des actions de maintenance peuvent être entreprises avant que les composants ne tombent en panne et éviter ainsi les pannes catastrophiques. La sélection d'un modèle de pronostic approprié pour une application particulière est indispensable pour le succès final d'un programme de pronostic. Les modèles sont soumis à des hypothèses et des approximations spécifiques, dont certaines sont mathématiques, tandis que d'autres se rapportent à des problèmes pratiques de mise en œuvre tels que la quantité de données nécessaires pour valider et vérifier un modèle proposé. Par conséquent, une sélection de modèle appropriée pour une mise en œuvre nécessite non seulement une compréhension mathématique de chaque type de modèle, mais aussi une connaissance de l'objectif de l'utilisation.

Chapitre 3

Moteur à ergol liquide

Les lanceurs spatiaux sont constitués d'au moins deux ou trois étages qui sont composés de moteurs, réservoirs, systèmes de contrôle et d'une coiffe contenant la charge utile pour se placer en orbite. Les moteurs de fusée sont des systèmes complexes produisant des forces de poussée très élevées [10].

3.1 Description du moteur

Les moteurs, à réaction, sont classifiés selon le type d'ergol : solide, liquide ou hybride. Actuellement, les systèmes propulsifs de type solide et liquide sont les plus adaptés pour le transport spatial. Bien que les systèmes solides soient très répandus et permettent une application très simple, les systèmes à ergols liquides mènent à de meilleures performances et rapportent une réponse plus satisfaisante à certains besoins de mission comme le contrôle ou même la réutilisation. En effet, le moteur à ergol liquide est réallumable, donc il peut être testé avant l'intégration au lanceur ce qui permet de réaliser une expertise complète en termes de pressions, de températures et de poussée. Cela signifie également que si un incident survient dans l'étage, il peut être éteint en vol et qu'il peut être utilisé pour plusieurs manœuvres séparées dans le temps, ce qui lui accorde un grand versatilité par rapport aux moteurs solides.

Comme les moteurs-fusées à propergol solide ou hybride, ce type de propulsion exploite l'énergie chimique contenue dans les ergols. Cette énergie est dégagée soit par réaction exothermique d'un comburant et d'un combustible, soit par décomposition. Les principaux organes d'un moteur à ergol liquide sont le système d'alimentation qui est responsable d'amener les ergols à la pression attendue et d'une chambre de combustion dans laquelle les ergols brûlent et produisent des gaz très énergétiques (Figure 3.1).

Un moteur fictif en LOX-LH2 de 10 kN de Poussée avec une alimentation des ergols en chambre via deux électropompes est choisi comme cas d'application pratique des méthodes d'estimation de la

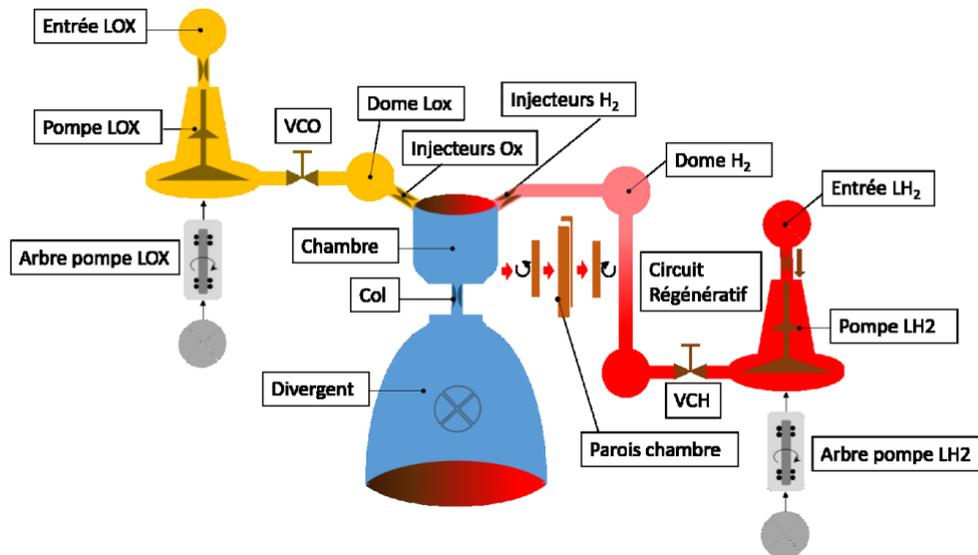


FIGURE 3.1 – Synoptique moteur

RUL de la chambre de combustion. La chambre dispose un circuit régénératif (CR) en hydrogène et un divergent permettant de délivrer la poussée requise de 10 kN. Deux vannes d'isolement VCO et VCH se trouvent dans les lignes d'alimentation des ergols, ils permettent d'admettre les ergols en chambre (vannes tout ou rien). Le moteur a une plage de fonctionnement de poussée entre 50 et 110 % de la poussée nominale et une boucle d'asservissement en pression et en rapport de mélange chambre (RM), et il a comme commandes d'entrée les puissances délivrées aux moteurs électriques des électropompes.

Afin de générer des données qui peuvent être utilisées dans les algorithmes de prévision de RUL à l'étude, des profils de vie type du moteur ont été imaginés :

- Les moteurs de qualification (ou de soutien à la production) ;
- Les moteurs de vol.

Les moteurs de qualification auront un profil d'utilisation plus intense avec une exploration de plusieurs points de fonctionnement. Les moteurs de vol ont seulement deux points de fonctionnement (800 s sur le point A et 50 s sur le point L). Toutes les données ont été générées à partir du simulateur dynamique système réalisés sous l'outil CARINS par le CNES.

3.2 Modélisation et description de la dégradation

La forte sollicitation thermomécanique sur la paroi interne de la chambre commence à provoquer l'ouverture de plusieurs microfissures qui à leur tour sont responsables d'une fuite directe de H2 froid dans la chambre en créant un film cooling sur la paroi interne. Cette présence de film cooling amène à la fois une baisse du flux thermique extrait par le CR et une inhomogénéité de RM en chambre, observable macroscopiquement avec une perte sur le rendement de combustion ce qui conduit à une dégradation globale des performances du moteur [11].

Le simulateur CARINS permet de modéliser l'apparition et l'évolution des fissures par l'ajout d'une branche secondaire sur le CR qui débouche dans la chambre de combustion à travers un orifice (Figure 3.1). L'orifice est initialement fermé et il s'ouvre à partir d'une certaine valeur de l'intégrale de flux thermique extrait à la chambre. L'évolution de la section hydraulique S_{fuite} est proportionnelle au delta d'intégrale de flux thermique ($Flux(t)$) à la puissance 0,6. En plus, la perte de rendement de combustion est modélisée en soutirant de la chambre un flux thermique additionnel ($Flux_{fuite}$) directement proportionnel au débit de fuite calculé. Comme les équations ci-dessous le montrent :

$$N_c = \begin{cases} 0 & \text{si } \int_0^t Flux(t)dt < K_{lim} \\ K_n(\int_0^t Flux(t)dt - K_{lim})^{K_{exp}} & \text{si } \int_0^t Flux(t)dt > K_{lim} \end{cases}$$

$$S_{fuite} = N_c \cdot S_{fissure} \quad \text{et} \quad Flux_{fuite} = K_{flux} \cdot Q_{fuite}$$

Paramètres	Valeur
K_n	$1,8 \cdot 10^{-4} J^{-1}$
K_{lim}	$3,0 \cdot 10^9 J$
K_{exp}	0,6
$S_{fissure}$	0,05 mm ²
K_{flux}	$120 \cdot 10^6 W/(kg/s)$

TABLE 3.1 – Paramètres réglant la modélisation de la fuite CR/chambre

Dans une étude précédente [6], il a été identifié que parmi les données mesurées sur le processus, le rendement de la vitesse caractéristique ηC^* serait le candidat le plus approprié pour jouer le rôle d'un indicateur de santé (SoH). Une fois la fissuration apparaît, ηC^* commence à diminuer comme le montre la Figure 3.2 .

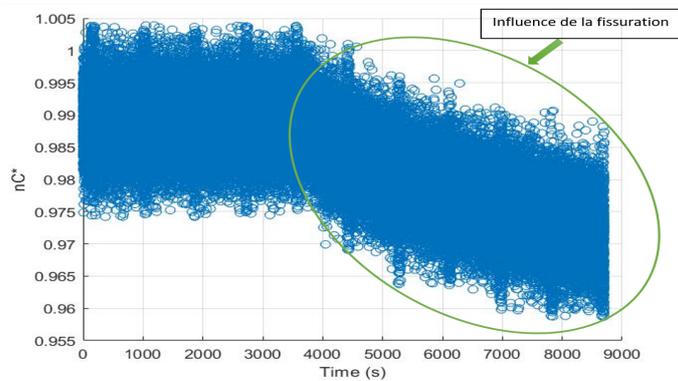


FIGURE 3.2 – Dégradation du rendement de la vitesse caractéristique.

Il peut être calculé à partir des données mesurées selon les équations suivantes :

$$C^*(t) = \frac{p_{cc}(t)S_{col}}{q_{tot}(t)} \text{ et } \eta C^*(t) = \frac{C^*(t)}{C^*_{thorique}(t)}$$

avec S_{col} la section au col, p_{cc} la pression de la chambre de combustion, et q_{tot} le débit total (le débit d'hydrogène et le débit d'oxygène) issues directement des capteurs de la simulation. $C^*_{thorique}$ est définie au cœur du simulateur.

Pour la suite, un changement d'échelle a été effectué pour avoir une évolution de la dégradation cohérente avec les attentes des méthodes classiques, soit :

$$f(t) = \frac{\eta C^*_{max} - \eta C^*(t)}{\eta C^*_{max} - \eta C^*_{min}} \quad (3.1)$$

avec ηC^*_{max} et ηC^*_{min} sont respectivement la valeur maximale et la valeur minimale de ηC^* . La variable f représente l'indicateur de santé donc elle est notée SoH (State of Health en anglais) (Figure 3.3).

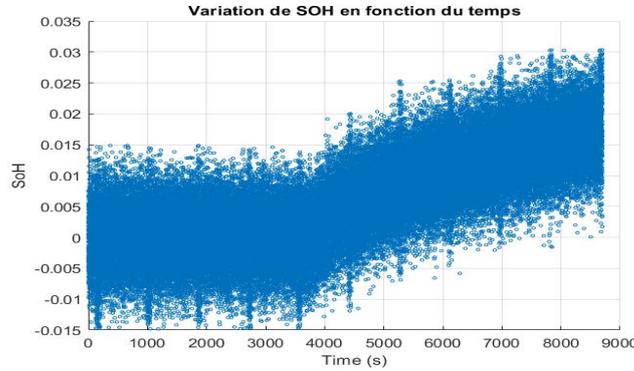


FIGURE 3.3 – Dégradation de l'indicateur de santé SoH

Puisque l'évolution dynamique de la dégradation n'est pas exactement connue, nous avons supposé que la dégradation de l'indicateur de santé soit modélisée selon la formalisation mathématique exponentielle suivante :

$$f(t) = e^{\alpha t} + f_0 \quad (3.2)$$

où f_0 est la dégradation à l'instant $t = 0$ et α est le taux d'évolution de la dégradation (paramètre inconnu). Afin d'estimer l'état de santé $f(t)$ et l'évolution de la dégradation α , une approche hybride qui est le filtre de Kalman étendu est appliquée dans le chapitre suivant.

3.3 Conclusion

Un moteur fictif en LOX-LH2 de 10 kN de Poussée avec une alimentation des ergols en chambre via deux électropompes est choisi comme cas d'application pratique des méthodes d'estimation de la RUL de la chambre de combustion. Des profils de vie type du moteur ont été imaginés : les moteurs de qualification (ou de soutien à la production) et les moteurs de vol. Due à des fortes sollicitations thermomécaniques sur la parois interne de la chambre, le rendement de la vitesse caractéristique se dégrade. Cet indicateur de santé est supposé s'évoluer selon une formalisation mathématique exponentielle.

Chapitre 4

Estimation de l'état de santé (SoH)

Sous les conditions de linéarité et les conditions Gaussien, le filtre de Kalman peut être employé pour évaluer l'estimation d'état qui minimise l'erreur quadratique moyenne. La dynamique du filtre de Kalman résulte des cycles consécutifs de prédiction et de filtrage. La dynamique de ces cycles est dérivée et interprétée dans le cadre des fonctions de densité de probabilité gaussienne. Le processus d'innovation associé au filtre, qui représente la nouvelle information transmise à l'estimation d'état par la dernière mesure du système, est introduit. Cependant, lorsque la dynamique de l'état du système ou la dynamique d'observation n'est pas linéaire, les fonctions de densité de probabilité conditionnelle qui fournissent l'estimation quadratique moyenne minimale ne sont plus gaussiennes. Dans ce cas, une approche non optimale, dans le cadre des filtres linéaires, est exploitée. Cette approche est le filtre de Kalman étendu (EKF) qui est conceptuellement très simple et sa dérivation découle d'arguments simples de linéarisation, de plus il a la même forme de base que le filtre de Kalman linéaire [12]. Cet estimateur va être mis en place dans l'équation de dégradation (3.2).

4.1 Filtre de Kalman Etendu

Dans ce contexte d'estimation d'état et de paramètres, le système est décrit par le système non-linéaire :

$$x(k) = g(x(k-1), u(k), k) + v(k) \quad x \in \mathbb{R}^m, u \in \mathbb{R}^l \quad (4.1)$$

où $x(k)$ est un vecteur d'état à l'instant k de dimension m , $u(k)$ est un vecteur d'entrée connue de dimension l , $v(k)$ est un bruit de processus additif, et $g(., ., k)$ est une fonction non linéaire de transition d'état permettant d'obtenir l'état actuel à travers l'état précédent et l'entrée de la commande actuelle.

Nous supposons que les observations de l'état de ce système sont faites selon une équation d'observation non linéaire sous la forme :

$$z(k) = h(x(k)) + w(k) \quad (4.2)$$

où $z(k)$ est l'observation faite à l'instant k , $x(k)$ est l'état à l'instant k , $w(k)$ est un bruit d'observation additif, et $h(x(k))$ est une fonction d'observation non linéaire.

On suppose que les bruits $v(k)$ et $w(k)$ sont gaussiens de moyenne nulle et de variances respectivement Q et R .

$$\forall k \quad E[v(k)] = E[w(k)] = 0 \quad (4.3)$$

Nous assumons également que les bruits d'état et d'observation ne sont pas corrélés.

$$\forall i, j \quad E[v(i)w^T(j)] = 0 \quad (4.4)$$

L'algorithme du filtre de Kalman étendu discret est composé de trois étapes :

1. **Initialisation :**

$$\hat{x}(0|0) = E[x(t_0)]$$

$$P(0|0) = Var[x(t_0)]$$

2. **Prédiction :** de l'état et de la variance à l'instant k

$$\hat{x}(k|k-1) = g(\hat{x}(k-1|k-1), u(k))$$

$$P(k|k-1) = \nabla g_x(k)P(k-1|k-1)\nabla g_x^T(k) + Q$$

où P est la matrice de la covariance d'erreur d'estimation. ∇g_x est le jacobien de la fonction g par rapport à x .

3. **Mise à jour (ou Correction) :** la mise à jour de l'état et de la variance à l'instant k se base sur l'état et la variance prédites et la nouvelle observation $z(k)$ selon les équations suivantes :

$$\hat{x}(k|k) = \hat{x}(k|k-1) + W(k)[z(k) - h(\hat{x}(k|k-1))]$$

$$P(k|k) = P(k|k-1) - W(k)S(k)W^T(k)$$

avec

$$W(k) = P(k|k-1)\nabla h_x^T(k)S^{-1}(k)$$

et

$$S(k) = \nabla h_x(k)P(k|k-1)\nabla h_x^T(k) + R$$

où ∇h_x est le Jacobien de la fonction non-linéaire $h(\cdot)$ par rapport à x , S est la covariance de l'innovation et W est la matrice du gain de Kalman.

4.2 Initialisation et réglage du filtre de Kalman étendu

Une partie des exigences du filtre de Kalman est la spécification des conditions initiales. Par conséquent, lorsque l'on envisage la mise en œuvre d'un filtre de Kalman, il est important de savoir comment définir les conditions initiales. Il existe de nombreuses méthodes pour faire fonctionner le filtre de manière satisfaisante [12].

Comme certains des états sont généralement mesurés, la première ou la moyenne des premières mesures peut être considérée comme la valeur initiale $\hat{x}(0|0)$ de l'état. Ce résultat peut être amélioré en utilisant un simple ajustement par la méthode des moindres carrés si nécessaire.

La méthode la plus simple pour initialiser la covariance d'état consiste à choisir une constante b et à fixer $P(0|0) = b^2Q$ (typiquement $b = 10$ est une estimation raisonnable de départ). On peut se demander quel est l'intérêt de régler $P(0|0)$, alors qu'en principe il peut être arbitraire. La réponse à cette question est la suivante. Par exemple, si $P(0|0)$ est égal à zéro (on a confiance des estimations initiales), le filtre ignore et n'apprend rien des mesures. Si $P(0|0)$ est extrêmement grande (un choix pessimiste des valeurs initiales), le filtre croit beaucoup en mesures et ignore les valeurs du modèle d'état, ce qui entraîne à une grande incertitude. Ainsi, il faut choisir une initialisation appropriée de $P(0|0)$ qui n'est ni zéro, ni infini pour fournir des estimations et une incertitude correctes.

La performance du filtre en régime permanent est déterminée uniquement par les valeurs des covariances des bruits d'état et d'observation, Q et R respectivement, qui sont choisies comme entrées du filtre. Il existe quelques principes généraux à respecter lors du réglage. En particulier, il n'est souvent pas difficile de commencer avec des valeurs raisonnables ou du moins des plages de valeurs raisonnables pour les différents paramètres du filtre. Ces valeurs peuvent être déduites de l'observation du système, d'expériences simples ou de simulations. Le gain W est calculé en fonction de la confiance dans le modèle (exprimée par Q) et la confiance dans les mesures (exprimée par R). Si le modèle est très bon (Q très petit) et la mesure très bruitée (R très grande) alors le gain W devient très petit. En effet, lorsque Q diminue, cela veut dire que le modèle est fiable et le bruit au niveau de l'équation d'état est très faible. De plus, les valeurs estimées deviennent très lisses et suivent les valeurs prédites sans être corrigées. Alors que quand Q augmente, les estimées suivent les mesures et non pas les prédictions. Cependant, lorsque R diminue, les mesures sont peu bruitées et on a plus de confiance en mesure donc le modèle est déclaré non fiable et le gain de Kalman augmente.

4.3 Application de EKF aux données du CNES

Afin d'appliquer le filtre de Kalman étendu, il faut tout d'abord discrétiser la fonction de dégradation (3.2) pour qu'elle soit de la même forme que l'équation (4.1).

Dérivant (3.2) par rapport à t :

$$\dot{f} = \frac{df}{dt} = \alpha e^{\alpha t} = \alpha(f(t) - f_0)$$

Selon Euler à l'ordre 1 :

$$\frac{f(k) - f(k-1)}{T_s} = \alpha(k-1)(f(k-1) - f_0) \implies f(k) = \alpha(k-1)(f(k-1) - f_0)T_s + f(k-1)$$

donc

$$f(k) = (1 + \alpha(k-1)T_s)f(k-1) - f_0T_s\alpha(k-1) \quad (4.5)$$

avec $T_s = 0.1s$ le temps d'échantillonnage. Sous l'hypothèse selon laquelle le taux de progression de la dégradation est généralement très lent par rapport à la dynamique globale du système, soit :

$$\alpha(k) = \alpha(k-1)$$

L'équation discrète peut être écrite sous la forme d'état avec w_f et w_α représentant les bruits blanc additifs d'état associés respectivement à f et α :

$$\begin{bmatrix} f(k) \\ \alpha(k) \end{bmatrix} = \begin{bmatrix} 1 + \alpha(k-1)T_s & -f_0T_s \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} f(k-1) \\ \alpha(k-1) \end{bmatrix} + \begin{bmatrix} w_f \\ w_\alpha \end{bmatrix} \quad (4.6)$$

avec $x(k) = \begin{bmatrix} f(k) & \alpha(k) \end{bmatrix}^T$ le vecteur d'état.

1) Initialisation et réglage :

La première étape de l'algorithme EKF est l'initialisation des états et le réglage des matrices de covariance pour faire fonctionner le filtre de manière satisfaisante. Donc, comme évoqué dans la section précédente, on suppose que :

$$f(0|0) = f_0 = \frac{1}{500} \sum_{i=1}^{500} z(i) \approx 0$$

et comme la dégradation vaut zéro au départ, alors $\alpha(0|0) = 0$.

En pratique, les bruits de processus et de mesure Q et R sont difficiles à obtenir. Par conséquent, ils sont souvent utilisés comme paramètres de réglage. Par ajustement manuel, les matrices de covariance

de bruit d'état et d'observations sont construites de la manière suivante :

$$R = \sigma_w^2$$

$$Q = \begin{bmatrix} \sigma_f^2 & 0 \\ 0 & \sigma_\alpha^2 \end{bmatrix}$$

tel que $v_f \sim N(0, \sigma_f)$, $v_\alpha \sim N(0, \sigma_\alpha)$ et $w \sim N(0, \sigma_w)$

avec, dans le cadre de notre étude :

$$\begin{cases} \sigma_f = 3.10^{-5} \\ \sigma_\alpha = 10^{-6} \\ \sigma_w = 8.10^{-3} \end{cases}$$

En général, la valeur de $P(0|0)$ doit être réglée en fonction de la performance obtenue. Typiquement $b = 10$ est une estimation raisonnable, soit $P(0|0) = 10Q$.

2) Prédiction :

Les états prédits à l'instant k sous forme matricielle :

$$\begin{cases} \hat{f}(k|k-1) = (1 + \hat{\alpha}(k-1|k-1).T_s)\hat{f}(k-1|k-1) - f_0.T_s.\hat{\alpha}(k-1|k-1) \\ \hat{\alpha}(k|k-1) = \hat{\alpha}(k-1|k-1) \end{cases}$$

La matrice prédite de la covariance d'erreur d'estimation :

$$P(k|k-1) = \nabla g_x(k)P(k-1|k-1)\nabla g_x^T(k) + Q$$

avec

$$\nabla g_x(k) = \begin{bmatrix} 1 + \hat{\alpha}(k-1|k-1).T_s & (\hat{f}(k-1|k-1) - f_0).T_s \\ 0 & 1 \end{bmatrix}$$

3) Correction :

Les états estimés à l'instant k :

$$\begin{cases} \hat{f}(k|k) = \hat{f}(k|k-1) + W(1, k)\epsilon(k) \\ \hat{\alpha}(k|k) = \hat{\alpha}(k|k-1) + W(2, k)\epsilon(k) \end{cases}$$

avec l'innovation $\epsilon(k) = z(k) - \hat{x}(k|k-1)$ et $z(k) = f_{measured}(k)$ (les valeurs mesurées de l'indicateur de santé sont calculées selon l'équation (3.1)).

La matrice estimée de la covariance d'erreur d'estimation :

$$P(k|k) = P(k|k-1) - W(k)S(k)W^T(k)$$

avec

$$W(k) = P(k|k-1)C^T S(k)^{-1}$$

$$S(k) = CP(k|k-1)C^T + R$$

et

$$C = \begin{bmatrix} 1 & 0 \end{bmatrix}$$

4.4 Résultats et discussion

Les figures ci-dessous présentent les résultats des estimations des variables d'état d'un moteur de vol en boucle ouverte pour un temps d'échantillonnage de 0.1s, on suppose diagnostiquer l'apparition des fissures à l'instant 3867 s :

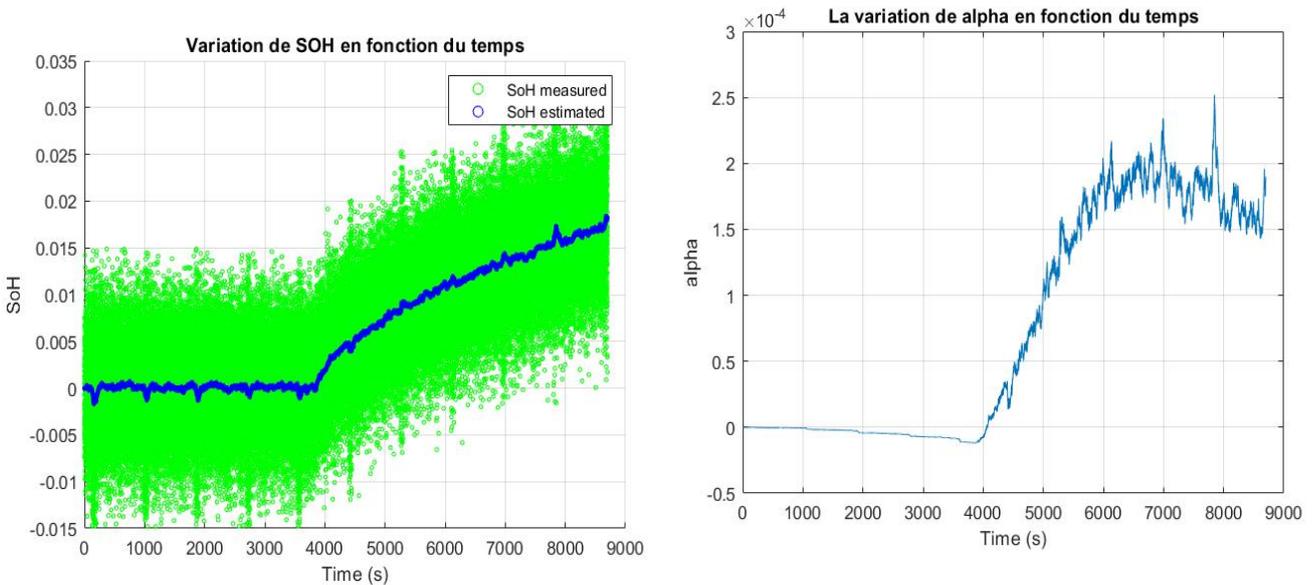


FIGURE 4.1 – Estimation de l'état de santé

FIGURE 4.2 – Estimation du taux d'évolution de la dégradation

L'état de santé mesuré et l'état de santé estimé sont présentés dans la Figure 4.1. Un bon accord est observé entre les deux courbes cela implique que le filtre Kalman arrive à estimer la dégradation de l'indicateur de santé puisque les valeurs estimées convergent vers les valeurs mesurées. La Figure 4.2 montre l'estimation du taux d'évolution de la dégradation. Une évolution rapide de la tendance survient après l'apparition de la fissuration pour tendre vers un maximum. L'importance des estimations de α est de fournir une information sur la vitesse de la dégradation. Comme illustré dans la Figure 4.2, l'évolution de α reflétée dans son profil comportemental pourrait être explicitée pour diagnostiquer un

problème qui se produit dans le moteur. Par exemple, une analyse de tendance appliquée sur l'estimation de α peut être développée pour détecter l'apparition de défauts. Dans la suite de ce rapport, nous supposons que cette méthode existe fournissant cette information d'occurrence du défaut.

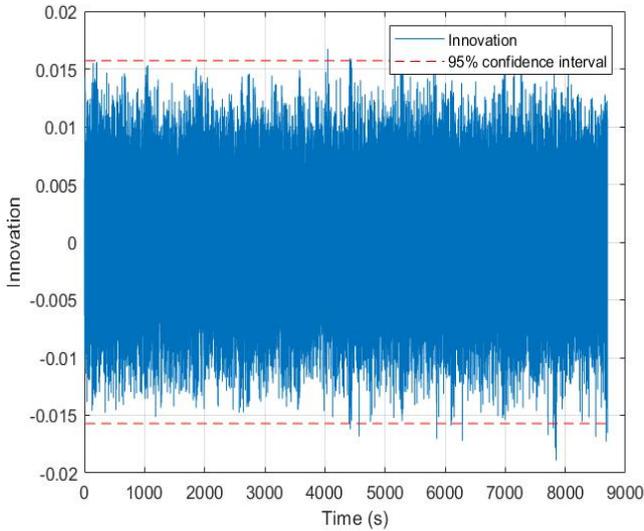


FIGURE 4.3 – Innovation et son intervalle de confiance

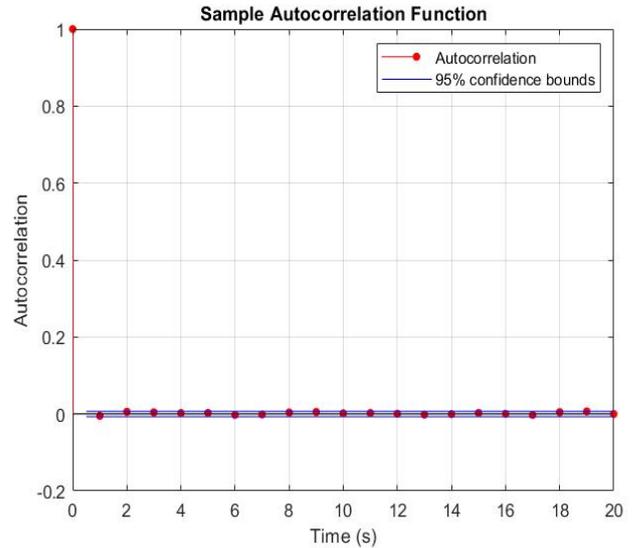


FIGURE 4.4 – Test de blancheur

L'indication la plus simple de la validité du filtre consiste à examiner directement la séquence d'innovations pour s'assurer qu'environ 95 % des innovations se situent dans une limite de $\pm 2\sigma$. Si trop d'innovations se situent en dehors de cette limite, cela indique que les niveaux de bruit fixés dans le filtre sont généralement inférieurs aux bruit réels. Inversement, si les innovations appartiennent à la limite de $\pm 2\sigma$, cela indique que les niveaux de bruit ont été fixés trop haut. D'après la Figure 4.3, l'évolution de l'innovation permet d'affirmer la bonne qualité des estimations avec une innovation centrée autour de 0 et dans l'intervalle des limites. De plus, le test de blancheur dans la Figure 4.4 confirme la validité du filtre et du réglage. En fait, si l'autocorrélation dépasse les limites de variance (loin du zéro), le test de blancheur aura échoué. L'autocorrélation n'est pas validée en cas où le rapport entre le bruit d'observation et le bruit du processus est trop élevé.

Pour le moteur de quantification, les résultats sont présentés dans les figures ci-dessous. Ce cas d'essai est introduit pour tester l'efficacité de l'algorithme par rapport à des changements fonctionnels/opérationnels variables dans le moteur. Ainsi, les données de dégradation montrent les conséquences sur les performances du moteur autour de plusieurs points de fonctionnement et ne présentent pas une tendance unique. D'après la Figure 4.5, nous remarquons que la dégradation de l'état de santé est instable ainsi que ses estimations. Le profil de dégradation est sensible à plusieurs conditions de fonctionnement très changeantes, ces oscillations viennent du fait que la dégradation des moteurs de quantification est dépendante des entrées, car leurs essais dépendent de l'ensemble de points de fonctionnement contrairement aux moteurs de vol. La même variation est observée dans la courbe des

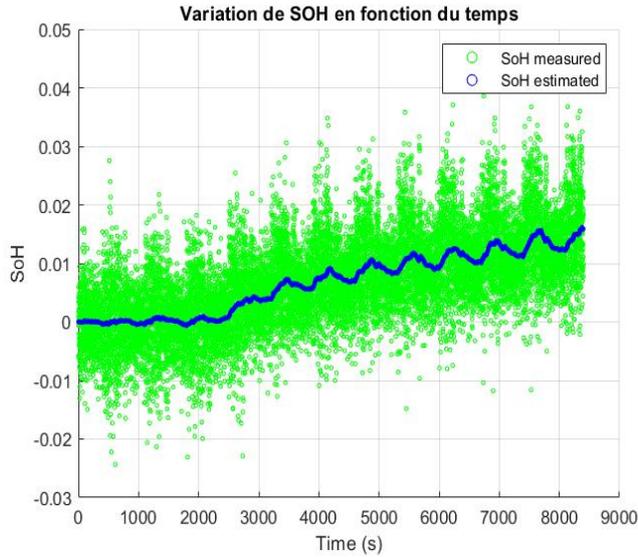


FIGURE 4.5 – Estimation de l'état de santé d'un moteur de quantification

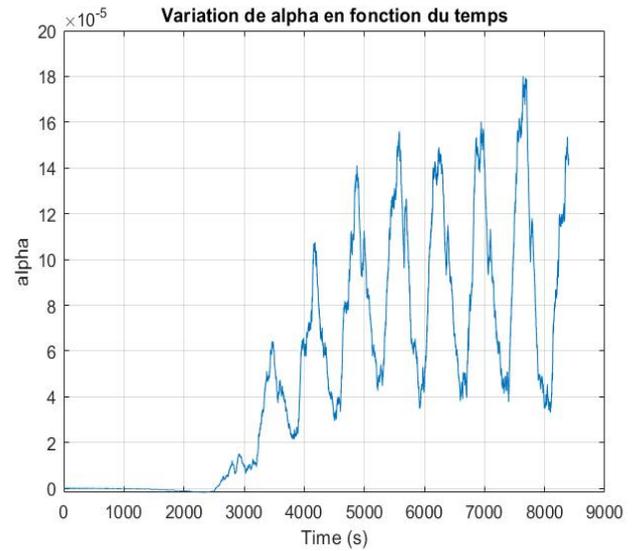


FIGURE 4.6 – Estimation du taux d'évolution de la dégradation d'un moteur de quantification

estimés de α (Figure 4.6) . Contrairement au cas précédent, le fonctionnement du système dans de multiples conditions opérationnelles conduit à la production de multiples taux de dégradation. Ainsi, la présence d'une seule valeur vraie de α ne peut pas être assurée pour toute la mission. En effet, pour chaque domaine de fonctionnement, un unique paramètre α n'est pas suffisant pour ce type de système.

4.5 Conclusion

Le filtre de Kalman étendu peut être employé pour évaluer l'estimation d'état. Après l'initialisation et le réglage du filtre, l'EKF fournit des bons résultats d'estimation de l'indicateur de santé et sa tendance surtout pour les moteurs de vol. Au regard des résultats obtenus pour le moteur de quantification, la prise en compte des entrées dans le modèle et par conséquent l'intégration des entrées dans les estimations du Filtre de Kalman Étendu, semblent nécessaire. Ces entrées vont permettre de tenir en compte les conditions opérationnelles de chaque moteur et de fournir des prédictions en fonction de l'usage du système et son environnement.

Chapitre 5

Estimation de la durée de vie résiduelle (RUL)

La durée de vie résiduelle (RUL) est une estimation du nombre d'unités de temps restantes pendant lesquelles un élément, un composant ou un système est estimé être capable de fonctionner conformément à son objectif avant de justifier son remplacement.

5.1 Prédiction de la RUL par projection

La RUL est définie comme la différence de temps entre un instant de prédiction t_P et l'instant de défaillance t_{fail} associé un seuil à partir duquel le système est considéré en panne et ne peut plus réussir à accomplir ses missions (Figure 5.1).

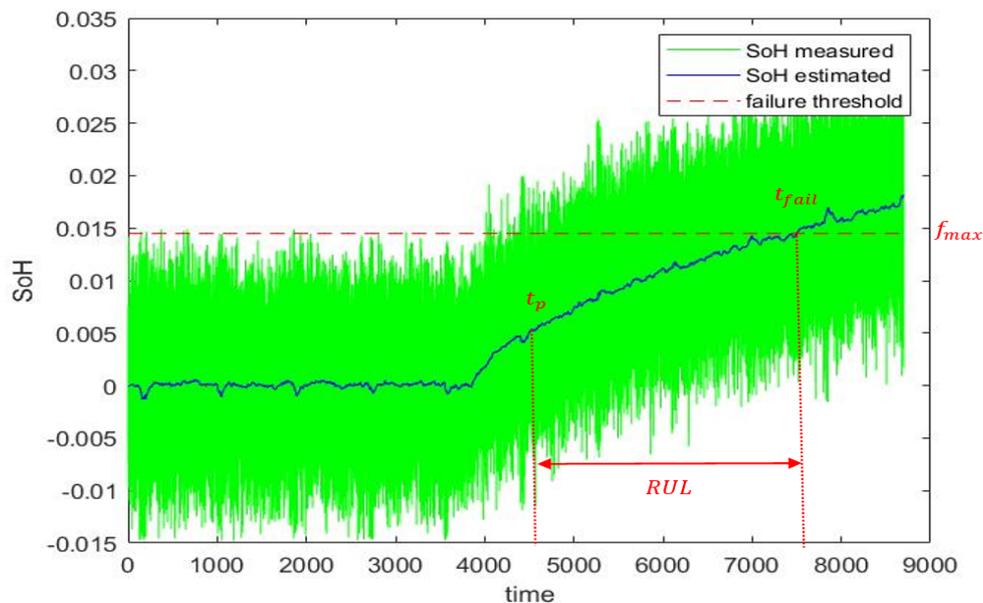


FIGURE 5.1 – Illustration de la Durée de Vie Résiduelle

L'algorithme précédent estime à chaque pas d'échantillonnage l'état de santé $\hat{f}(k|k)$ et l'évolution de

la dégradation $\hat{\alpha}(k|k)$, notés par la suite $\hat{f}(k)$ et $\hat{\alpha}(k)$. Cette information est fournie à un algorithme de prédiction [7] comme détaillé dans la Figure 5.2.

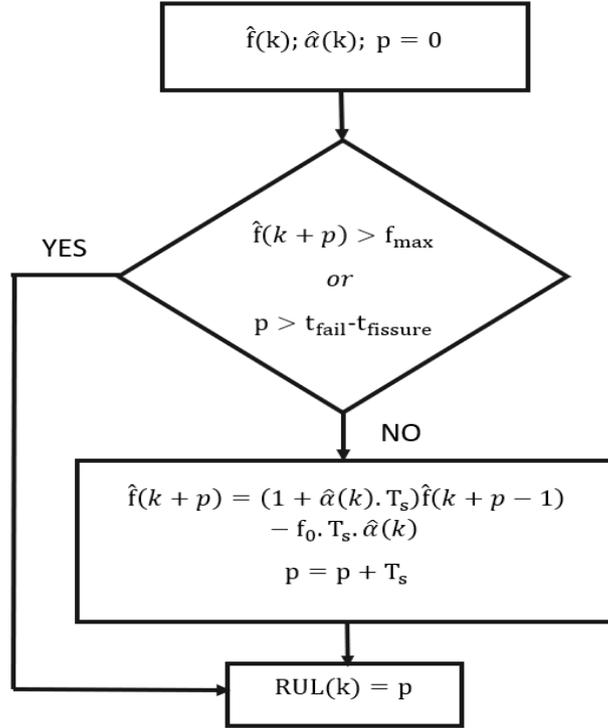


FIGURE 5.2 – Algorithme de prédiction de RUL.

Tant que l'estimation de SoH est inférieure à un seuil prédéterminé, nous nous projetons vers les échantillons futurs sous une condition que RUL ne dépasse pas la différence entre l'instant de franchissement du seuil et l'instant de l'apparition du défaut :

$$p < t_{fail} - t_{fissure}$$

La projection dans le futur se fait selon la récurrence suivante :

$$\hat{f}(k+p) = (1 + \hat{\alpha}(k).T_s)\hat{f}(k+p-1) - f_0.T_s.\hat{\alpha}(k) \quad (5.1)$$

À chaque instant d'échantillonnage k , une prédiction future du SoH $\hat{f}(k+p)$ est calculée jusqu'à ce qu'elle dépasse un seuil défini comme f_{max} (failure threshold). Ce processus est répété chaque fois qu'une nouvelle estimation du SoH est disponible. La RUL obtenue par cette méthode est notée pour la suite RUL_{proj} .

5.2 Prédiction analytique de RUL

La prédiction de la durée de vie résiduelle peut être réalisée analytiquement en explicitant l'expression de RUL.

$$\hat{f}(k+1) = (1 + \hat{\alpha}(k).T_s)\hat{f}(k) - f_0.T_s.\hat{\alpha}(k)$$

Par récurrence successive jusqu'à l'échantillon n et pour $f_0 = 0$:

$$\begin{aligned} \hat{f}(k+n) &= (1 + \hat{\alpha}(k).T_s)^n \hat{f}(k) \\ \implies n &= \frac{\ln(\hat{f}(k+n)) - \ln(\hat{f}(k))}{\ln(1 + \hat{\alpha}(k).T_s)} \end{aligned}$$

A noter qu'à n , $\hat{f}(k+n) = f_{max}$, soit $RUL_{cal}(k)$ équivalente à :

$$RUL_{cal}(k) = n.T_s = \frac{\ln(f_{max}) - \ln(\hat{f}(k))}{\ln(1 + \hat{\alpha}(k).T_s)}.T_s \quad (5.2)$$

La fonction de RUL_{cal} prend comme entrée les valeurs estimées de \hat{f} et $\hat{\alpha}$ à l'instant k . Cette expression est très importante pour la partie quantification de l'incertitude dans le chapitre suivant .

5.3 Résultats et discussion

En supposant que la dégradation n'est influencée que par un seul mode de dégradation (condition de fonctionnement), la RUL_{real} permet de valider les prédictions de RUL et elle est calculée en soustrayant l'instant de prédiction de l'instant de défaillance. Les RULs générées par projection (RUL_{proj}) et par expression explicite (RUL_{cal}) sont tracées et comparées avec des RULs théoriques (RUL_{real}) et ses bornes $\pm 10\%$ afin de vérifier la robustesse des prédictions sous l'hypothèse que la dégradation est linéaire au cours du temps.

A noter que la procédure de prédiction RUL est lancée à l'instant d'apparition de la fissuration pour éviter les complexités de calcul au début de la dégradation.

Le seuil prédéterminé, t_{fail} et $t_{fissure}$ sont représentés ci-dessous :

$$\begin{cases} t_{fissure} = 3867s \\ t_{fail} = 7474s \\ f_{max} = 0.0145 \end{cases}$$

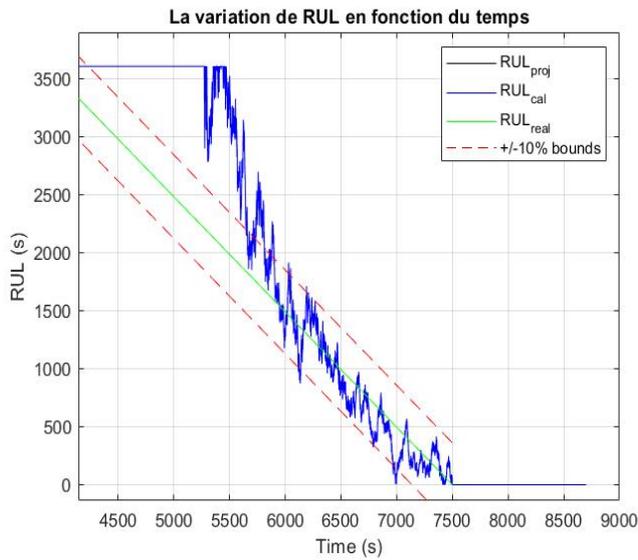


FIGURE 5.3 – Résultats de l'estimation de la RUL du moteur de vol

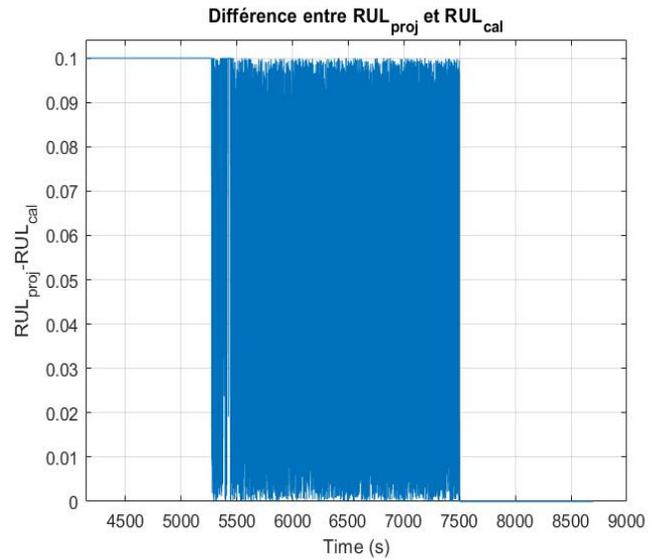


FIGURE 5.4 – La différence entre RUL_{proj} et RUL_{cal}

Nous remarquons de la Figure 5.3 que la RUL_{proj} est confondue avec la RUL_{cal} et la différence entre les RULs est presque négligeable comme le montre la Figure 5.4. De plus, les RULs sont surestimées pour les premiers 1000 s, cela est expliqué par le temps que l'algorithme prend pour converger vers la courbe RUL_{real} . Une fois la RUL estimée converge vers la RUL_{real} , elle reste dans l'intervalle +/- 10%. Pour $t \approx 7500s$, l'état de santé dépasse le seuil prédéterminé et la RUL s'annule.

Chapitre 6

Quantification de l'incertitude de RUL

Il est non seulement important de développer des algorithmes robustes pour le diagnostic et le pronostic, c'est-à-dire d'effectuer avec précision le diagnostic et le pronostic en présence d'incertitudes, mais il est également important de quantifier l'intervalle de confiance dans les résultats du diagnostic et du pronostic. Il est également nécessaire d'effectuer une telle quantification d'incertitude en ligne pour activer les capacités de prise de décision en vol.

6.1 Incertitude de RUL

La RUL prédite à l'instant k notée $R(k)$ dépend de plusieurs facteurs [13] :

1. Estimation de l'état actuel $x(k)$ à travers du filtre de Kalman étendu ;
2. États futurs en utilisant l'estimation de l'état actuel et l'espace d'état (4.1), les états futurs $(x(k), x(k+1), x(k+2), \dots, x(k+p))$ peut être calculé, avec $k+p$ désigne l'indice-temps t_{fail} qui correspond à la fin de vie ;
3. Entrée futur $(u(k), u(k+1), u(k+2), \dots, u(k+p))$ - ces valeurs sont nécessaires pour calculer les valeurs d'état futur ;
4. Bruit d'état - ces valeurs sont $v(k), v(k+1), v(k+2), \dots, v(k+p)$.

Soit $X = [X_1, X_2, \dots, X_i, \dots, X_n]$ le vecteur de tous les facteurs ci-dessus, où n est la longueur du vecteur X , et donc le nombre de quantités incertaines qui influencent la prédiction de RUL. La RUL peut être exprimée en termes de fonction, comme :

$$R = G(X) \tag{6.1}$$

Les quantités contenues dans X sont considérées comme incertaines, et l'objectif est de calculer leur effet combiné sur la prédiction de RUL. Cette tâche peut être accomplie en calculant la densité de probabilité de RUL.

Les diverses sources d'incertitude dans les pronostics peuvent être classifiées selon les catégories suivantes :

- **Incertitude actuelle** : avant le pronostic, il est important de pouvoir estimer avec précision l'état du système à l'instant k , puisqu'il est utilisé pour la prédiction de RUL. Ce problème est lié à l'estimation d'état, et généralement résolu en utilisant le filtrage. Les données de sortie (généralement collectées par des capteurs) sont utilisées pour estimer l'état, et de nombreuses approches de filtrage sont capables de fournir une estimation de l'incertitude dans l'état actuel, c'est-à-dire $X(k)$. Pratiquement, il est possible d'améliorer l'estimation des états, et ainsi de réduire l'incertitude, en utilisant de meilleurs capteurs et des approches de filtrage avancées.
- **Incertitude future** : La source des incertitudes la plus importante dans le contexte des pronostics est due au fait que l'avenir est inconnu, c'est-à-dire que les conditions de fonctionnement ne sont pas connues avec précision.
- **Incertitude de modélisation** : La RUL doit être estimée à l'aide d'un modèle qui prédit l'évolution future du système ; l'utilisation d'un modèle confère une incertitude supplémentaire.

Même si toutes les sources d'incertitude ci-dessus peuvent être quantifiées avec précision, il est nécessaire de quantifier leur effet combiné sur la prédiction RUL, et ainsi de quantifier l'incertitude globale dans la prédiction de RUL. Ce processus équivaut à propager l'incertitude de X à G , et l'incertitude résultante de RUL est exprimée à l'aide de la fonction de densité de probabilité (PDF - Probability Density Function en anglais) ou de la fonction de distribution cumulative (CDF - Cumulative Distribution Function en anglais) [9] [13].

6.2 Avantages de l'approche IFORM

Il existe deux grandes catégories de méthodes pour quantifier l'incertitude : Les méthodes basées sur l'échantillonnage et les méthodes analytiques.

Dans les méthodes basées sur l'échantillonnage telles que la simulation Monte-Carlo, un grand nombre de réalisations aléatoires de X est généré et les réalisations de R sont calculées. L'échantillonnage de Monte Carlo (MCS) tente à calculer approximativement la distribution de probabilité entière (PDF ou CDF). Si un plus grand nombre d'échantillons est utilisé dans le MCS, la distribution de probabilité entière peut être approchée avec une précision accrue. Donc cette méthode demande beaucoup du temps pour l'implémenter. De plus, elle utilise des échantillons aléatoires pour la quantification de l'incertitude, et produisent donc des résultats différents (bien que similaires) lors de la répétition de l'algorithme, car chaque répétition tire un ensemble différent d'échantillons aléatoires.

Afin de surmonter ces problèmes, la méthode analytique IFORM (Inverse First Order Reliability Method) est utilisée. Cette méthode nous permet de quantifier l'incertitude en générant un intervalle de

confiance puisqu'elle calcule la RUL pour une probabilité de défaillance déterminée et surtout pour les systèmes linéaires ou linéarisés. Ce qui rend cette approche applicable dans le cadre du filtre de Kalman et filtre de Kalman étendu. De plus, cette méthode demande peu de calcul complexe donc elle ne prend pas beaucoup du temps et peuvent être implémentée en temps réel. Autre avantage de cette approche est qu'elle peut produire des résultats déterministes c'est-à-dire la même PDF peut être produite. Ce critère est important pour les protocoles de vérification et de validation dans le domaine aérospatial.

6.3 Méthode de fiabilité de premier ordre

Supposons que toutes les variables incertaines suivent des distributions gaussiennes, c'est-à-dire $X_i \sim N(\mu_{X_i}, \sigma_{X_i})$ pour tout i . Lorsque des approches basées sur le filtrage de Kalman (telles que le filtrage de Kalman étendu) sont utilisées pour l'estimation d'état, $x(k)$ est normalement distribué. Afin d'estimer les incertitudes, nous débutons par considérer l'approche FORM (First Order Reliability Method). Le but de cette approche est de calculer la valeur CDF, c'est-à-dire $F_R(r) = P(R \leq r)$, étant donné r , une réalisation de la variable aléatoire R . FORM atteint cet objectif en linéarisant l'équation $R = G(X)$ pour calculer facilement le CDF de R . L'équation linéaire est construite en utilisant une approximation de Taylor autour du point de linéarisation. L'identification du point de linéarisation est un élément essentiel à déterminer dans la méthode FORM.

Considérons les contours de la fonction $R - r = G(X) - r$, en particulier, considérons la courbe décrite par $G(x) - r = 0$, où x est une réalisation de X . Cette courbe divise l'espace multidimensionnel en deux régions : une région 1 où $R < r$, et une région 2 où $R > r$, comme le montre la Figure 6.1 : U_1 et U_2 correspondents aux variables d'état aléatoire X_1 et X_2 exprimées dans l'espace normal standard, et u_1 et u_2 sont les réalisations de U_1 et U_2 .

Cette courbe est communément appelée fonction d'état limite, elle coupe l'espace en deux zones : une zone de défaillance et une zone de sûreté. Puisque cette courbe sert de démarcation entre les deux zones données par $R > r$ et $R < r$, il est intéressant de calculer la probabilité $P(R \leq r)$. Donc, il est important d'identifier une fonction linéaire qui ressemble au contour $G(x) - r = 0$. Par conséquent, le point de linéarisation doit se trouver sur cette courbe de démarcation ; en d'autres termes, le point de linéarisation doit satisfaire $G(x) - r = 0$. Cependant, il existe une infinité de points qui respecte ce critère. Chacun de ces points infinis a une probabilité d'occurrence, et intuitivement le point ayant une probabilité d'occurrence maximale est choisi comme un point de linéarisation. Cette probabilité peut être calculée en utilisant la fonction de densité de probabilité des variables aléatoires. Pour une

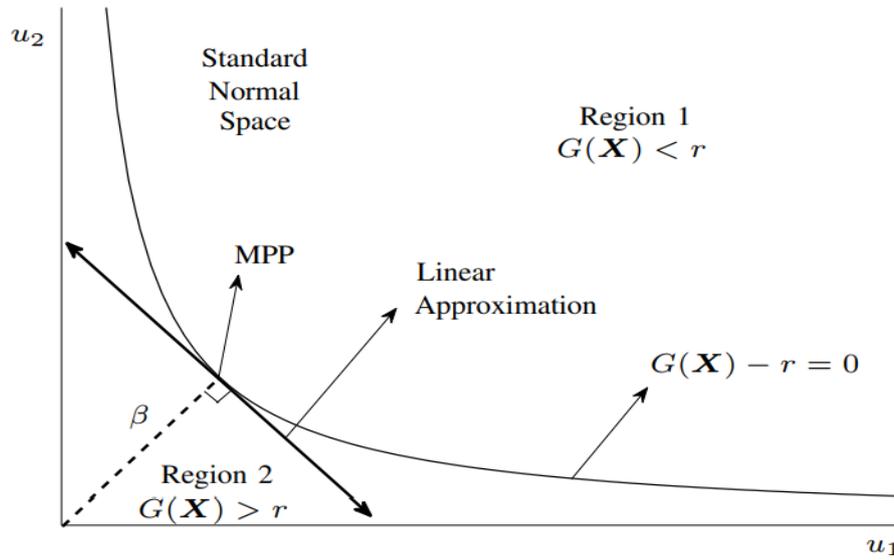


FIGURE 6.1 – Estimation du MPP

seule variable aléatoire normale X de moyenne μ et d'écart type σ , le PDF est donné par :

$$f_X(x|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right] \quad (6.2)$$

La valeur maximale de la fonction d'occurrence est obtenue pour $x = \mu$; par conséquent, plus x s'éloigne de la moyenne μ , plus la probabilité d'occurrence de x diminue. Mais, la moyenne ne peut pas être choisie comme point de linéarisation car $G(\mu) - r \neq 0$. Par conséquent, s'il y a une seule variable d'entrée, le point de linéarisation est choisi de telle manière qu'il satisfasse l'équation $G(x) - r = 0$, et la valeur de $\|x - \mu\|$ est minimale. Dans un problème général de propagation d'incertitude, l'entrée de G est un vecteur, $X = [X_1, X_2, \dots, X_i, \dots, X_n]$, et chaque X_i a sa propre moyenne μ_{X_i} et son propre écart type σ_{X_i} . L'objectif est d'identifier le point d'occurrence maximale, qui peut être calculé en maximisant la fonction de densité de probabilité conjointe de toutes les variables aléatoires d'entrée. Si les variables sont indépendantes, alors la fonction de densité conjointe de X est exprimée par :

$$f_X(x) = \prod_{i=1}^{i=n} \frac{1}{\sigma_i\sqrt{2\pi}} \exp\left[-\frac{(x_i - \mu_i)^2}{2\sigma_i^2}\right] \quad (6.3)$$

Afin de maximiser cette fonction, il faut minimiser la fonction ci-dessus :

$$\beta = \sqrt{\sum_{i=1}^{i=n} u_i^2} \quad (6.4)$$

avec

$$u_i = \frac{x_i - \mu_i}{\sigma_i} \quad (6.5)$$

u_i correspond aux réalisations de la variable normale standard U_i , $U_i \sim N(0, 1)$ et (6.5) est la trans-

formation normale standard. Dans l'espace des variables normales standard, maximiser la probabilité d'occurrence équivaut à minimiser (6.4), ce qui implique que le point de linéarisation est le point qui appartient à la courbe de démarcation et qui est le plus proche de l'origine. Étant donné que le point de linéarisation a la probabilité d'occurrence maximale, donc il est appelé le point le plus probable (Most Probable Point - MPP), comme indiqué dans la Figure 6.2. À partir des équation (6.4) et (6.5), la distance entre MPP et l'origine est exactement égale à β (index de fiabilité) [9] [13] [14]. Et comme :

$$P(R \leq r) \approx \Phi(-\beta) \quad (6.6)$$

où $\Phi(\cdot)$ représente la fonction de distribution cumulative normale standard, le problème de calcul de CDF se réduit à l'identification du MPP sur la courbe d'état limite. Ce problème peut être posé comme un problème d'optimisation sous contraintes :

$$\begin{aligned} & \text{Minimiser } u^T u \\ & \text{t.q. } G(x) = r \\ & u = (u_1, u_2, \dots, u_i, \dots, u_n) \\ & u_i = (x_i - \mu_i) / \sigma_i \\ & (i = 1 \text{ à } n) \end{aligned}$$

Le problème d'optimisation ci-dessus peut être résolu en utilisant l'algorithme de Rackwitz-Fiessler selon une procédure itérative décrite ci-après :

1. Initialiser $j = 0$ et commencer par une estimation initiale pour le MPP

$$x^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]$$

2. Transformer en espace normal standard et calculer $u^j = [u_1^j, u_2^j, \dots, u_i^j, \dots, u_n^j]$ en utilisant la moyenne et la variance de l'EKF ;

$$u_i = (x_i - \mu_i) / \sigma_i$$

3. Calculer le vecteur gradient dans l'espace normal standard, $a = [a_1, a_2, \dots, a_n]$, où :

$$a_i = \frac{\partial G}{\partial u_i} = \frac{\partial G}{\partial x_i} \frac{\partial x_i}{\partial u_i} = \frac{\partial G}{\partial x_i} \sigma_i$$

4. Dans la procédure itérative, le point suivant u^{j+1} est calculé à l'aide d'une équation de type Newton-Raphson :

$$u^{j+1} = \frac{1}{\|a\|} [a^T u^j - G(x^j)] \frac{a}{\|a\|}$$

5. Retransformer à l'espace d'origine, c'est-à-dire calculer x^{j+1} , et répéter de l'étape 3 jusqu'à ce que la procédure itérative converge. En utilisant les limites de tolérance δ_1 et δ_2 , la convergence

peut être vérifiée si ces deux critères sont satisfaits :

- le point se trouve sur la courbe $G(x) - r = 0$, c'est-à-dire $|G(x^j) - r| \leq \delta_1$.
- la solution ne change pas entre deux itérations, c'est-à-dire $|x^{j+1} - x^j| \leq \delta_2$.

La procédure itérative décrite ci-dessus converge généralement après 4 ou 5 itérations.

6.4 Méthode inverse de fiabilité de premier ordre (IFORM)

La section 6.2 permet de calculer la valeur CDF pour une réalisation donnée de R, la section 6.3 considère le problème inverse, c'est-à-dire le calcul de la réalisation de R qui correspond à une valeur CDF donnée ($\lambda = \Phi(-\beta)$). Cette méthode, connue sous le nom de l'approche inverse-FORM (IFORM), peut être utilisée pour calculer les limites de probabilité de la prédiction de la durée de vie résiduelle. La théorie liée à IFORM est similaire à celle de FORM, et l'algorithme discuté dans la section 6.2 est modifié de sorte que la valeur CDF puisse être spécifiée et les réalisations puissent être calculées. Les différentes étapes impliquées dans la procédure itérative de IFORM sont décrites ci-dessous :

1. Initialiser $j = 0$ et commencer par une estimation initiale pour le MPP

$$x^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]$$

2. Transformer en espace normal standard et calculer $u^j = [u_1^j, u_2^j, \dots, u_i^j, \dots, u_n^j]$ en utilisant la moyenne et la variance de l'EKF ;

$$u_i = (x_i - \mu_i) / \sigma_i$$

3. Calculer le vecteur gradient dans l'espace normal standard, $a = [a_1, a_2, \dots, a_n]$, où :

$$a_i = \frac{\partial G}{\partial u_i} = \frac{\partial G}{\partial x_i} \frac{\partial x_i}{\partial u_i} = \frac{\partial G}{\partial x_i} \sigma_i$$

4. Dans la procédure itérative, le point suivant u^{j+1} est calculé comme

$$u^{j+1} = \frac{a}{|a|} \beta$$

5. Retransformer à l'espace d'origine, c'est-à-dire calculer x^{j+1} , et répéter de l'étape 3 jusqu'à ce que la procédure itérative converge. En utilisant les limites de tolérance δ_1 et δ_2 , la convergence peut être vérifiée si ces deux critères sont satisfaits :

- le point se trouve sur la courbe $G(x) - r = 0$, c'est-à-dire $|G(x^j) - r| \leq \delta_1$.
- la solution ne change pas entre deux itérations, c'est-à-dire $|x^{j+1} - x^j| \leq \delta_2$.

Pareil à l'algorithme de Rackwitz-Fiessler, la procédure itérative ci-dessus converge également après 4 ou 5 itérations et convient donc aux calculs rapides dans le contexte de surveillance de la santé en

ligne. La procédure IFORM est utile pour calculer les limites de probabilité. Par exemple, en répétant l'algorithme ci-dessus pour $\lambda = 0.05$ et $\lambda = 0.95$, il est possible d'estimer les limites de probabilité de 90 % de la durée de vie résiduelle.

6.5 Exemple de mise en œuvre de l'approche IFORM

Cette section présente une application académique de la méthode IFORM. L'exemple commence par une génération des données d'un modèle exponentiel pour un taux d'évolution connu. Ces données représentent les valeurs mesurées de l'indicateur de santé (SoH). Par la suite, le taux d'évolution de la dégradation est supposé inconnu, donc le filtre de Kalman étendu est utilisé pour estimer les variables d'états important pour prédire la durée de vie résiduelle par projection et par expression explicite. Finalement, afin de quantifier l'incertitude de l'estimation, l'approche IFORM est appliquée.

Tout d'abord, la formulation exponentielle suivante est supposée décrire la dégradation :

$$f_m(k+1) = (1 + T_s \cdot \alpha) f_m(k) + w(k)$$

avec $\alpha = 0.01$, $f_m(1) = 1$, $T_s = 0.1s$ et w est un bruit d'observation additif tel que $w \sim N(0, \sigma_w)$ pour $\sigma_w = 0.5$.

Pour la suite, α est supposé inconnu, donc le filtre de Kalman étendu est appliqué pour estimer l'état de santé actuelle. Après le réglage des matrices de covariance, Q et R sont choisis tels que :

$$R = \sigma_w^2; Q = \begin{pmatrix} \sigma_{w_f}^2 & 0 \\ 0 & \sigma_{w_\alpha}^2 \end{pmatrix} \text{ avec } \sigma_{w_f} = 5 \cdot 10^{-2} \text{ et } \sigma_{w_\alpha} = 10^{-4}$$

Les états et la matrice P sont initialisés :

$$\hat{f}(0|0) = 1; \hat{\alpha}(0|0) = 0; P(0|0) = 10Q$$

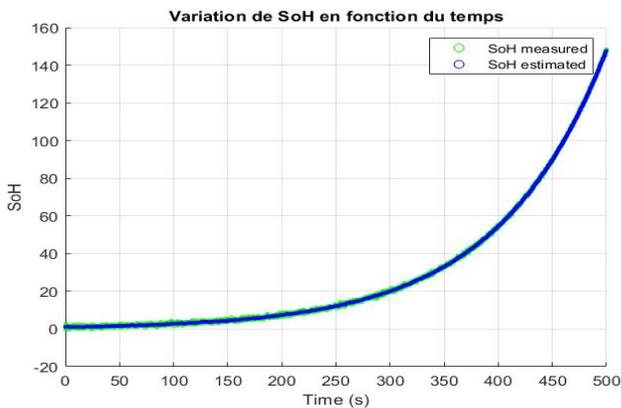


FIGURE 6.2 – Estimation de l'état de santé

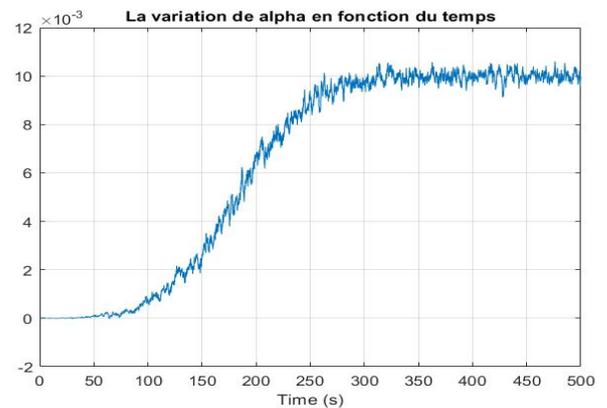


FIGURE 6.3 – Estimation de α

L'état de santé mesuré et l'état de santé estimé sont présentés dans la Figure 6.2. On peut observer un bon accord entre les deux courbes et on peut conclure que le filtre Kalman arrive à estimer la dégradation de l'indicateur de santé puisque les valeurs estimées convergent vers les valeurs mesurées. La Figure 6.3 montre l'estimation du taux d'évolution de la dégradation qui converge vers la bonne valeur qui est 0.01.

Après avoir estimé l'état de santé actuel, la prédiction de RUL se fait par l'algorithme de la section 5.1 et l'expression (5.2). Afin de calculer l'intervalle de confiance, l'approche IFORM, est appliquée en utilisant la fonction (5.2)

$$G(X(k)) - r = RUL(k) - r$$

avec $X(k) = [\hat{f}(k), \hat{\alpha}(k)]$ et $r = 0$.

et le gradient de $G(X)$ par rapport à U :

$$a = \frac{\partial G}{\partial X} \sigma_X = \left(\frac{-1}{\hat{f}(k) * \ln(1+T_s \cdot \alpha(k))} \quad \frac{-T_s}{(1+T_s \cdot \alpha(k))} \frac{\ln(f_{max}) - \ln(f(k))}{(\ln(1+T_s \alpha))^2} \right) \cdot \sigma_X$$

On suppose que :

$$\begin{cases} t_{fissure} = 200s \\ t_{fail} = 450s \\ f_{max} = 109 \end{cases}$$

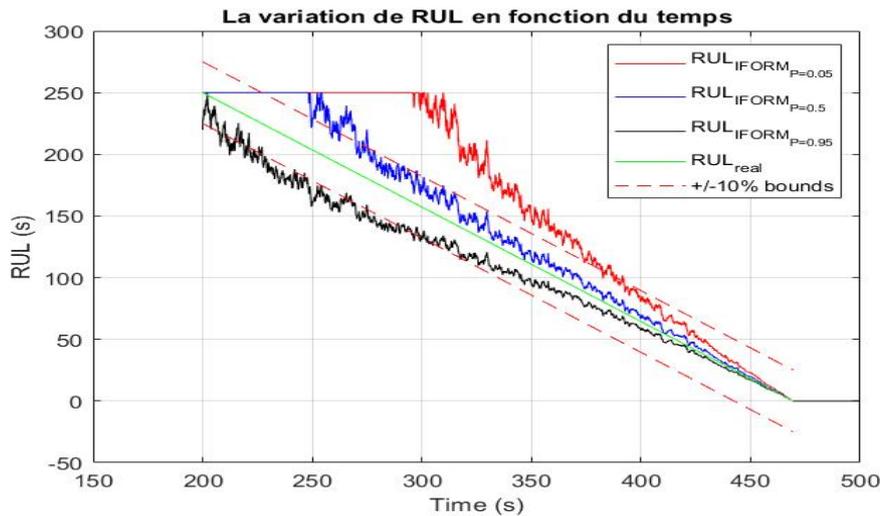


FIGURE 6.4 – Estimation et Quantification de l'incertitude de RUL

La méthode IFORM est directement utilisée pour calculer la valeur de RUL correspondant à $F_R = [0.05, 0.5, 0.95]$ (Figure 6.4). $RUL_{IFORM_{P=0.05}}$ et $RUL_{IFORM_{P=0.95}}$ correspondent aux bornes de probabilité de 90% de la RUL, $RUL_{IFORM_{P=0.5}}$ correspond à la médiane de la RUL. Les limites et la moyenne sont calculées en continu jusqu'à $t_{fail} = 450s$, lorsque la défaillance semble imminente. Il est

évident d'après les résultats obtenus que l'incertitude de la RUL est élevée au départ, puis diminue progressivement jusqu'à ce que la défaillance soit atteinte. Initialement, l'incertitude de la RUL est élevée parce qu'il est nécessaire de prédire à un instant plus éloigné ; les états futurs, et l'incertitude associée, doivent être pris en compte pendant une période plus longue. Cependant, à un instant ultérieur, les états futurs doivent être pris en compte pour une période de temps réduite, et donc l'incertitude de la RUL diminue. En fait, tout bon algorithme de pronostic devrait décrire ce comportement, c'est-à-dire que la prédiction du RUL à un instant ultérieur doit avoir une incertitude plus faible que la prédiction à un instant antérieur. De même, une plus grande incertitude dans l'estimation de l'état implique que l'incertitude correspondante de la prédiction du RUL sera également élevée.

6.6 Application de l'approche IFORM sur les données de CNES

Comme dans l'exemple académique, la méthode IFORM est appliquée pour quantifier l'incertitude de RUL. Mais pour les données de CNES, il est difficile de générer la RUL pour une probabilité de défaillance de 5% pour des problèmes numériques donc les résultats obtenus sont pour $F_R = [0.3, 0.5, 0.95]$.

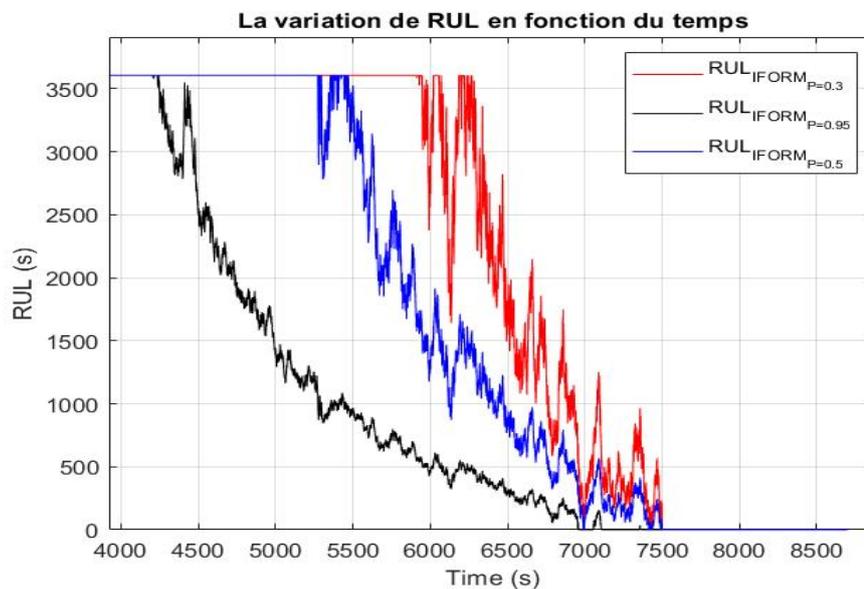


FIGURE 6.5 – Estimation et Quantification de l'incertitude de RUL pour un moteur de vol

D'après la Figure 6.5, l'incertitude au départ est plus élevée que celle dans l'exemple académique ce qui est évident puisque dans notre cas d'étude, le modèle de dégradation est supposé exponentiel et cela impose une incertitude supplémentaire à la prédiction de la RUL.

Afin de mesurer et enregistrer le temps nécessaire pour quantifier l'incertitude par IFORM, la commande tic toc est utilisée (tic démarre un chronomètre, toc imprime le temps passé depuis l'utilisation de tic). Elle permet de mesurer le temps de simulation de l'approche IFORM à chaque itération.

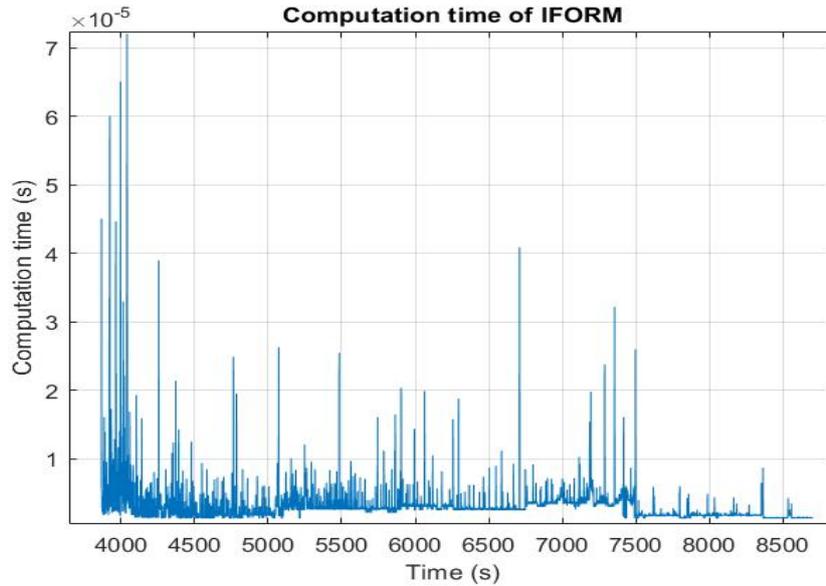


FIGURE 6.6 – Temps de simulation de la méthode IFORM

Donc, d'après la Figure 6.6, l'approche IFORM ne demande pas de calcul long et elle converge après un temps d'ordre 10^{-5} s d'où la possibilité d'implémenter cette approche en ligne et en boucle fermée.

6.7 Conclusion

Il est nécessaire d'effectuer une quantification d'incertitude en ligne pour activer les capacités de prise de décision en vol. La présence d'incertitude a un impact significatif sur le pronostic et la prédiction de la durée de vie résiduelle. Lorsque les estimations d'état, les conditions de fonctionnement, etc. sont incertaines, les états futurs et la durée de vie résiduelle deviennent également incertains. La méthode analytique IFORM est la plus convenable pour quantifier l'incertitude de RUL avec un faible coût de calcul par rapport aux autres méthodes de quantification de l'incertitude. Cette méthode est utile pour calculer les limites de probabilité surtout pour les systèmes linéaires ou linéarisés. Ce qui rend cette approche applicable dans le cadre du filtre de Kalman et filtre de Kalman étendu.

Chapitre 7

Fonctionnement en boucle fermée

Tous les résultats étudiés dans les chapitres précédentes étaient uniquement pour les données générées en boucle ouverte. Dans le but d'investiguer la réaction du moteur à l'apparition du défaut dans le contexte d'un fonctionnement en boucle fermée, la commande est réalisée via un simple PID multi variable.

Les variables contrôlées choisies sont la pression chambre et le rapport de mélange en entrée moteur. Les variables de contrôle sont les puissances électriques fournies aux électropompes. La Figure 7.1 montre la logique de contrôle du moteur :

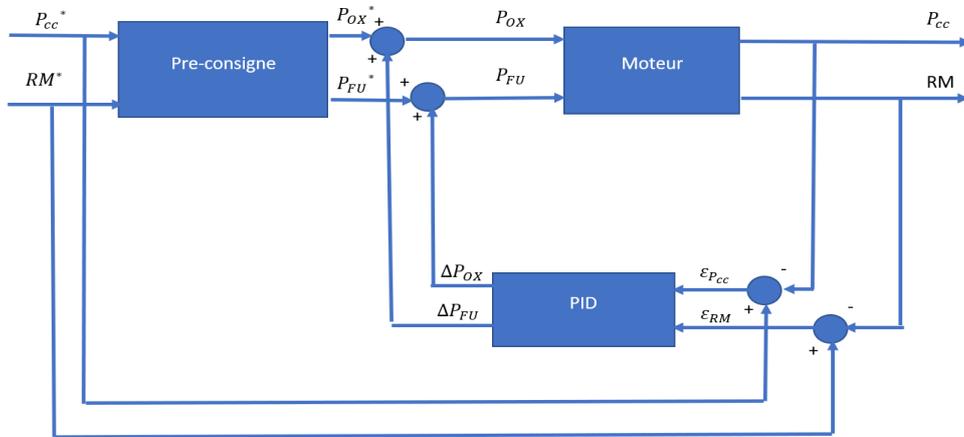


FIGURE 7.1 – Diagramme du fonctionnement en boucle fermée

A noter que le contrôleur est composé d'un bloc de pré-conditionnement de la consigne qui fournit des valeurs nominales des puissances auxquelles sont ajoutés des écarts calculés par un PID multi-variables qui utilise en entrée les résidus sur pression chambre et RM (consigne moins valeur mesurée).

En équations :

$$\begin{bmatrix} \epsilon_{Pcc} \\ \epsilon_{RM} \end{bmatrix} = \begin{bmatrix} P_{cc}^* \\ RM^* \end{bmatrix} - \begin{bmatrix} P_{cc} \\ RM \end{bmatrix}$$

$$\begin{bmatrix} P_{OX} \\ P_{FU} \end{bmatrix} = \begin{bmatrix} P_{OX}^* \\ P_{FU}^* \end{bmatrix} + \begin{bmatrix} \Delta P_{OX} \\ \Delta P_{FU} \end{bmatrix}$$

$$\begin{bmatrix} \Delta P_{OX} \\ \Delta P_{FU} \end{bmatrix} = K_p \begin{bmatrix} \epsilon_{pcc} \\ \epsilon_{RM} \end{bmatrix} + K_I \int_0^t \begin{bmatrix} \epsilon_{pcc} \\ \epsilon_{RM} \end{bmatrix} dt + K_D \frac{d}{dt} \begin{bmatrix} \epsilon_{pcc} \\ \epsilon_{RM} \end{bmatrix}$$

Les gains du PID utilisé sont reportés ci-dessous de la part de CNES. Il est important de noter que ces gains n'ont pas été optimisés, le but a été ici seulement d'avoir une idée qualitative du comportement du moteur en BF en présence du défaut. La synthèse d'une loi de contrôle optimal pourra faire l'objet d'une prochaine activité quand le problème de reconfiguration en fonction de l'état de santé sera abordé.

$$K_p = \begin{bmatrix} 0.1 & 1 \\ 0.275 & 2.75 \end{bmatrix}, K_I = \begin{bmatrix} 5 & 50 \\ 5 & 27.5 \end{bmatrix}, K_D = \begin{bmatrix} 0.001 & 0.01 \\ 0.05 & 0.05 \end{bmatrix}$$

Le fonctionnement en boucle fermée du moteur révèle une amplification des pertes de performance moteur. L'état de santé en boucle fermée se dégrade plus rapidement qu'en boucle ouverte comme illustrée à la Figure 7.2. Par conséquent, la durée de vie résiduelle en BF diminue davantage (Figure 7.3). Les figures ci-dessous montrent les résultats obtenus pour un moteur de vol en BO et BF pour une fréquence de 10 Hz.

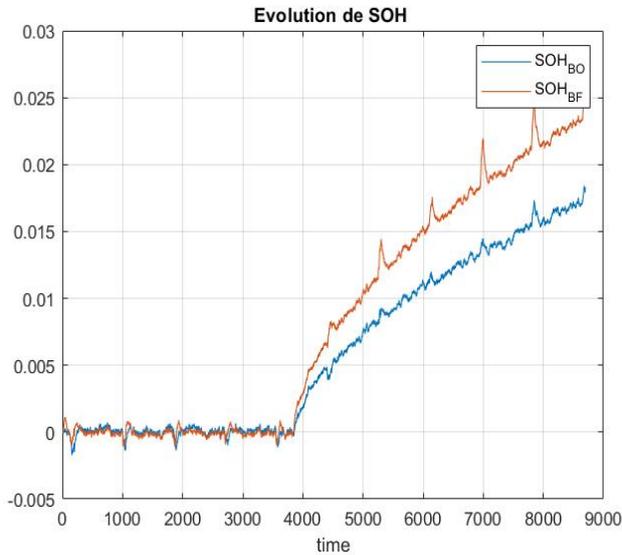


FIGURE 7.2 – Estimation de l'état de santé en BO et en BF

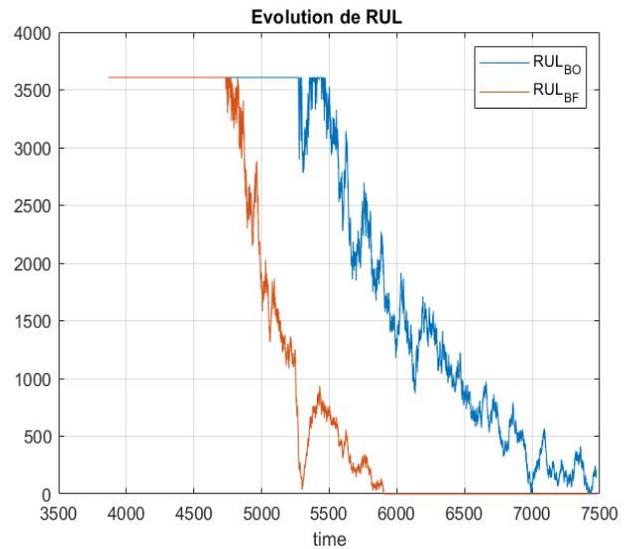


FIGURE 7.3 – Estimation de la durée de vie résiduelle en BO et BF

En BF, le régulateur réagit en délivrant plus de puissance aux pompes pour maintenir la pression sur le niveau de consigne et par conséquent les débits consommés augmentent ultérieurement. La vitesse caractéristique baisse donc davantage.

Chapitre 8

Conclusions et Perspectives

A partir d'un modèle hybride basé sur des données et sur l'hypothèse que les dégradations évoluent selon une fonction exponentielle, l'état de santé du système est estimé ainsi qu'une prédiction de la durée de vie résiduelle (RUL). La méthodologie utilisée est basée sur le Filtre de Kalman Etendu permettant d'estimer l'état de santé actuel et son taux d'évolution. L'EKF fournit des bons résultats d'estimation de l'indicateur de santé et sa tendance pour le moteur de vol ce qui conduit à une estimation rapide et précise de la RUL. Les résultats obtenus démontrent la limitation et la bonne capacité de l'algorithme à prédire le RUL de la chambre pour des moteurs fonctionnant dans des conditions nominales. Puis, afin de calculer l'intervalle de confiance, l'approche IFORM est employée, permettant de calculer les valeurs de RUL qui correspondent à des niveaux de probabilité spécifiés, ce qui peut être utile pour la prise de décision en ligne.

Cependant, le modèle de dégradation n'intègre pas les entrées futures ou le profil des entrées pour l'estimation du SOH ainsi que les prédictions de la RUL, ce qui reste une perspective de travail à considérer. Les travaux futurs envisageront l'intégration des variations des entrées du système pour les générations des RULs futurs. De plus, le développement d'un cadre de contrôle conscient de la santé est une autre perspective ainsi que la prise en compte de la variance de la distribution des SOH pour la génération de la distribution de prédiction des RUL en boucle fermée .

Bibliographie

- [1] J.Sikorska, M. Hodkiewicz, and L. Ma, “Prognostic modelling options for remaining useful life estimation by industry,” *Mechanical Systems and Signal Processing*, vol. 25, pp. 1803–1836, 2011.
- [2] M. S. Jha, G. Dauphin-Tanguy, and B. Dauphin-Tanguy, “Particle filter based hybrid prognostics for health monitoring of uncertain systems in bond graph framework,” *Mechanical Systems and Signal Processing*, vol. 75, p. 301–329, 2016.
- [3] ISO 13381-1, “Condition monitoring and diagnostics of machines – prognostics – part 1 : General guidelines : International standards organization,” 2004.
- [4] T.Biagetti, “Automatic diagnostics and prognostics of energy conversion processes via knowledge-based systems,” *Energy*, vol. 29, 2004.
- [5] S.Dey and J.Stori, “A bayesian network approach to root cause diagnosis of process variations,” *International Journal of Machine Tools and Manufacture*, vol. 45, 2005.
- [6] M.Chelouati, M. S. Jha, M. Galeotta, and D. Theilliol, “Remaining useful life prediction for liquid propulsion rocket engine combustion chamber,” *accepted for publication at 5th International Conference on Control and Fault-Tolerant Systems (SysTol)*, 2021.
- [7] M. Bressel, M. H. D. Hissel, B. Ould Bouamama, and T. Padir, “Extended kalman filter for prognostic of proton exchange membrane fuel cell,” *Applied Energy*, vol. 164, pp. 220–227, 2016.
- [8] J.Luo, M. Namburu, K. Pattipati, L. Qiao, M. Kawamoto, and S. Chigusa, “Model-based prognostic techniques,” *IEEE Systems Readiness Technology Conference.*, p. 330–340, 2003.
- [9] M. Bressel, M. H. D. Hissel, B. Ould Bouamama, and T. Padir, “Remaining useful life prediction and uncertainty quantification of proton exchange membrane fuel cell under variable load,” *IEEE Transactions on Industrial Electronics*, vol. 63, pp. 2569–2577, 2016.
- [10] A.Iannetti, “Méthodes de diagnostic pour les moteurs de fusée à ergols liquides,” PhD Thesis, UNIVERSITE PARIS-SACLAY, September 2016.
- [11] F. Hötte, C. V. Sethe, T. Fiedler, M. C. Hauptand O. J. Haidn, and M. Rohdenburg, “Experimental lifetime study of regeneratively cooled rocket chamber walls,” *International Journal of Fatigue*, vol. 138, p. 105649, 2020.
- [12] H.Durrant-Whyte, “Introduction to estimation and the kalman filter,” *Semantic Scholar*, 2006.

- [13] S.Sankararaman, M. J. Daigle, and K. Goebel, “Uncertainty quantification in remaining useful life prediction using first-order reliability methods,” *IEEE Transactions on Reliability*, vol. 63, pp. 603–619, 2014.
- [14] E.I.Robinson, J. Marzat, and T. Raïssi, “Model-based prognosis using an explicit degradation model and inverse form for uncertainty propagation,” *IFAC-PapersOnLine*, vol. 50, p. 14242–14247, 2017.