



**HAL**  
open science

# Méthodes de prédiction de durée de vie en vue de modèles de maintenance prévisionnelle : calcul d'intervalles et stratégies en présence de données incertaines

Adrien Delmas, Mohamed Sallak, Walter Schön, Linda Zhao

## ► To cite this version:

Adrien Delmas, Mohamed Sallak, Walter Schön, Linda Zhao. Méthodes de prédiction de durée de vie en vue de modèles de maintenance prévisionnelle : calcul d'intervalles et stratégies en présence de données incertaines. *Lambda Mu 21*, “ Maîtrise des risques et transformation numérique : opportunités et menaces ”, Oct 2018, Reims, France. hal-02066504

**HAL Id: hal-02066504**

**<https://hal.science/hal-02066504>**

Submitted on 13 Mar 2019

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

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

## Méthodes de prédiction de durée de vie en vue de modèles de maintenance prévisionnelle : calcul d'intervalles et stratégies en présence de données incertaines

### Remaining Useful Life prediction method for predictive maintenance: intervals calculation and strategies when dealing with uncertain data

Adrien Delmas, Mohamed Sallak et Walter Schön  
Laboratoire Heudiasyc  
Sorbonne universités,  
Université de Technologie de Compiègne  
CNRS, Heudiasyc UMR 7253  
CS 60319, 60203 Compiègne Cedex France  
{adrien.delmas, sallakmo, wschon}@utc.fr

Linda Zhao  
SECTOR  
12 avenue du Québec  
BP 636 Villebon sur Yvette  
F91965 Courtabœuf cedex  
linda.zhao@sector-group.net

#### Résumé

La maintenance prévisionnelle permet de palier les inconvénients présentés par la maintenance corrective et la maintenance préventive grâce à l'estimation de durées de vie résiduelles.

Les travaux présentés concernent une méthode d'estimation imprécise de RUL grâce aux modèles de Markov cachés. Nous approximations les données pour l'apprentissage du modèle avec un polynôme, puis nous encadrons ce polynôme par 2 autres de même degré. Par conséquent, nous obtenons 3 HMM distincts : le premier est destiné à estimer la RUL et les 2 autres donnent les bornes supérieure et inférieure de l'intervalle. Enfin, nous proposons une stratégie à adopter lorsque les données sont incomplètes ou imprécises. Ces travaux ont été appliqués sur le IEEE PHM challenge de 2008.

#### Summary

Predictive maintenance allows the drawbacks of corrective and preventive maintenance to be overcome by estimating the Remaining Useful Life (RUL) of components.

We propose an imprecise RUL estimation method with the use of Hidden Markov Models (HMM). Here, we fit the training data by a polynomial and then we frame it with 2 other polynomials of the same degree. This results in 3 distinct trained HMMs: the first is used for the RUL estimation and the other 2 provide the lower and higher bounds. Finally, we propose a strategy that can be adopted when dealing with incomplete or imprecise data. This work has been applied to the IEEE 2008 PHM challenge which was a competition aiming at evaluating prognosis methods.

#### Introduction

La maintenance est une étape indispensable dans le cycle de vie d'un système complexe. La norme européenne NF EN 13306 (AFNOR, 2001) définit la maintenance comme : *l'ensemble de toutes les actions techniques, administratives et de management durant le cycle de vie d'un bien, destinées à le maintenir ou à le rétablir dans un état dans lequel il peut accomplir la fonction requise*. En d'autres termes, la maintenance permet d'assurer la disponibilité et un niveau de fonctionnement optimal du système dans des conditions qui garantissent la sécurité de l'utilisateur et de son environnement. Toutefois, cela occasionne généralement des coûts non négligeables et les opérations de maintenance peuvent parfois nécessiter l'immobilisation du système. Ceci d'autant plus que les pratiques actuelles sont rarement optimales :

- La maintenance corrective consiste à attendre l'apparition d'une panne avant de réparer ou remplacer les composants défectueux (AFNOR, 2001).
- La maintenance préventive consiste à remplacer les composants à des intervalles réguliers, selon un planning préétabli (AFNOR, 2001).

La première méthode engendre généralement des surcoûts (Lee, Ni, Djurdjanovic, Qiu, & Liao, 2006) (Lesobre, Bouvard, Barros, Bérenguer, & Cocquemot, 2014) et une indisponibilité du système importants, notamment pendant la recherche de la panne (Palem, 2013) (Jimenez, Feuillebois, Pauly, & Dauzère-Pères, 2010). De plus, une défaillance entraîne l'impossibilité de réaliser une ou plusieurs fonctions pour lesquelles le système a été conçu.

Or certaines de ces fonctions peuvent avoir un but sécuritaire. Leur perte soulève donc des problèmes de sûreté. La maintenance préventive réduit considérablement les risques d'apparition de défaillances de même que les temps d'indisponibilité. En effet, toutes les tâches de maintenance sont planifiées ce qui permet de prévoir à l'avance la disponibilité des pièces de rechange, des outils et du personnel nécessaires. Toutefois, elle peut entraîner des coûts de maintenance élevés car les opérations sont réalisées sans connaître au préalable l'état réel des composants. Ainsi, certains composants sont remplacés alors qu'ils ne sont que très peu dégradés (Lee, Ni, Djurdjanovic, Qiu, & Liao, 2006) (Lesobre, Bouvard, Barros, Bérenguer, & Cocquemot, 2014) (Le, 2016).

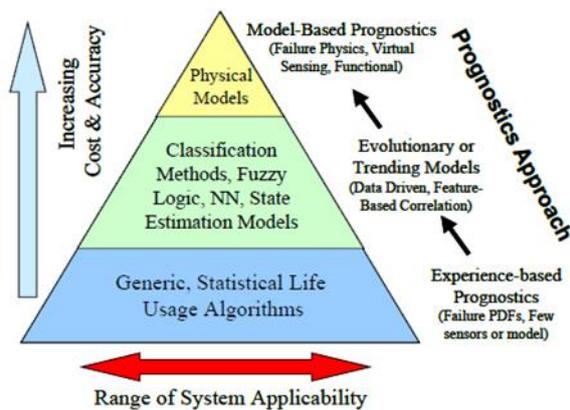
La maintenance prévisionnelle fait l'objet de nombreuses études depuis plusieurs années car elle permet de pallier les inconvénients (Palem, 2013) cités ci-dessus. Elle consiste à surveiller les composants du système (Bartelds, et al., 2004) afin d'évaluer leur état de santé et leur niveau de fonctionnement. Il est alors possible de pronostiquer l'apparition d'une défaillance ou d'une dégradation sévère avant qu'elle ne se produise ou qu'elle n'entraîne des problèmes de sécurité ou de disponibilité (Lee, Ni, Djurdjanovic, Qiu, & Liao, 2006) (Le, 2016) (Jardine, Lin, & Banjevic, 2006). En particulier, les modèles de pronostic ont pour but d'estimer la durée de vie résiduelle (Remaining Useful Life ou RUL en anglais) des composants. Cela permet donc de planifier les tâches de maintenance au moment le plus opportun (Mercier & Pham, 2012).

Le pronostic fait l'objet d'un intérêt croissant depuis plusieurs décennies et plusieurs méthodes ont été développées, testées et améliorées au fil des avancées technologiques. Celles-ci se classent en trois catégories (Le, 2016) (Vachtsevanos, Lewis, Roemer, Hess, & Wu,

2006) (Soualhi, Razik, Clerc, & Doan, 2014) (Roemer, Byington, Kacprzynski, & Vachtsevanos, 2006) :

- *Le pronostic basé sur les modèles physiques* qui s'appuie sur des modèles mathématiques et/ou physiques des phénomènes de dégradation
- *Le pronostic basé sur les données*, qui consiste en des analyses de jeux de données pour la recherche d'indicateurs de l'état de santé du composant.
- *Le pronostic basé sur l'expérience*, qui est basé sur l'exploitation des connaissances acquises sur la défaillance ou la dégradation du composant dans le passé.

La **Figure 1** présente l'étendu des approches de pronostic en fonction de leur applicabilité à différents systèmes, le coût de leur implémentation et leur précision.



**Figure 1.** Approches techniques pour le pronostic (Roemer, Byington, Kacprzynski, & Vachtsevanos, 2006)

Les méthodes basées sur les données permettent de réaliser un pronostic à partir de jeux de données collectées par les moyens de surveillance. En particulier, les modèles stochastiques présentent un grand intérêt pour le calcul de RUL de par leur mise en œuvre relativement simple et compréhensible. Parmi ces derniers, les processus markoviens sont parmi les plus généraux et les plus fidèles pour modéliser une dégradation de par leur aspect dynamique et multi-états. De plus, les modèles de Markov cachés prennent en compte le fait qu'il est impossible de mesurer directement la dégradation d'un système. Enfin, ces modèles ont démontré leur efficacité dans des domaines très variés et ont été employés pour réaliser des stratégies de maintenance prédictive dans plusieurs travaux (Sikorska, Hodkiewicz, & Ma, 2011) (Tobon-Mejia, Medjaher, Zerhouni, & Tripot, 2011) (Geramifard, Xu, Zhou, & Li, 2012) (Roblès, et al., 2014) (Tang, Makis, Jafari, & Yu, 2015).

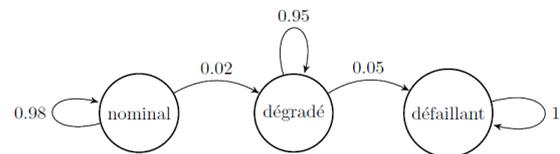
Toutefois, ces travaux s'intéressent à des cas simplifiés et en particulier à des jeux de données parfaits. Or dans un cas réel les données peuvent être altérées. Par exemple, un capteur défaillant peut produire des mesures imprécises voire même manquantes, ou plusieurs capteurs peuvent donner des informations contradictoires (Krüger, Measures of Conflicting Evidence in Bayesian Networks for Classification, 2013) (Krüger, Detection of Failing Sensors by Conflicting Evidence in Bayesian Classification, 2014). Notre travail propose une méthodologie de prédiction de RUL par l'utilisation de HMM en présence de données incertaines. La RUL sera caractérisée par deux RUL inférieure et supérieure. Pour finir, nous proposerons une stratégie adéquate au cas où on dispose de données incomplètes ou imprécises.

Cet article est organisé de la manière suivante : la seconde section présente les HMMs et leur utilisation pour le calcul de durées de vie résiduelles. Dans la troisième section, cette méthode sera appliquée au IEEE PHM challenge de 2008 qui est une compétition dont l'objectif est d'évaluer les modèles de pronostic. La quatrième section présente notre méthode pour déterminer la RUL imprécise. Enfin, la dernière section propose notre stratégie de maintenance en cas de données incertaines.

## Les HMM et le calcul de RUL

Une chaîne de Markov est un processus stochastique décrit par une séquence de variables aléatoires. Chaque variable représente un état du système et le processus subit des transitions aléatoires d'un état à un autre. L'un des principes fondamentaux d'une chaîne de Markov est son absence de mémoire : la probabilité de passer à l'état suivant ne dépend que de l'état présent et pas des états antérieurs (Sikorska, Hodkiewicz, & Ma, 2011).

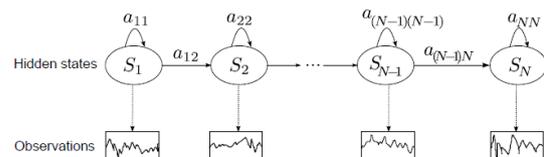
La **Figure 2** présente un exemple de processus de Markov simplifié représentant un composant qui peut être dans un état nominal, dégradé ou défaillant. La probabilité de passer de l'état nominal à l'état dégradé vaut 0.02 et celle de passer de l'état dégradé à l'état défaillant vaut 0.05.



**Figure 2.** Chaîne de Markov représentant la dégradation d'un composant

Dans notre cas, la chaîne de Markov représente les différents états de santé par lesquels peut passer le système, comme montré sur la **Figure 2** (ici le système étudié est un composant). A partir d'un état donné, les méthodes de résolutions permettent de déterminer le temps moyen de séjours dans un état et le temps moyen d'arrivée dans un état en fonction des probabilités de transition. De ce fait, on en déduit la durée de vie résiduelle du composant (Sikorska, Hodkiewicz, & Ma, 2011).

Toutefois, il n'est pas possible d'observer directement l'état de santé d'un composant (on dit alors que les états sont cachés). Il est par contre possible de collecter des informations sur celui-ci (par exemple une température, une pression, des vibrations, etc.) qui peuvent donner des indications sur son état. Il est alors possible de modéliser les états du système à l'aide d'un modèle de Markov caché (Hidden Markov Model ou HMM en anglais). Un tel modèle est constitué d'une chaîne de Markov sous-jacente qui n'est pas observable directement mais qui peut être révélée par des observations d'autres paramètres liés aux variables non observables. La **Figure 3** représente un exemple de modèle de Markov caché.



**Figure 3.** Modèle de Markov caché. Les observations permettent de révéler les états  $S_i$  (Le, 2016)

Formellement, un modèle de Markov caché est caractérisé par les éléments suivants (Rabiner, 1989) (Degirmenci, 2014) :

- La matrice de probabilité de transition  $A = \{a_{ij}\}$ , où  $a_{ij}$  est la probabilité de transition de l'état n°  $i$  vers l'état n°  $j$ . En d'autres termes,  $a_{ij}$  est la probabilité que le système soit dans l'état n°  $j$  à l'instant  $t + 1$  sachant qu'il était dans l'état n°  $i$  à l'instant  $t$ .
- La matrice de probabilité d'émission des observations  $B = \{b_j(k)\}$ , où  $b_j(k)$  est la probabilité d'émettre le symbole n°  $k$  sachant que le système est dans l'état n°  $j$ .
- La distribution initiale  $\pi = \{\pi_i\}$ , où  $\pi_i$  est la probabilité que le système soit dans l'état n°  $i$  à l'instant initial.

Un modèle de Markov caché est défini par les 3 matrices  $A$ ,  $B$  et  $\pi$ . Il est désigné par le symbole  $\lambda = (A, B, \pi)$ .

Il existe 3 problèmes fondamentaux qu'il est possible de résoudre grâce à un modèle de Markov caché (Rabiner, 1989) (Degirmenci, 2014) :

- Problème 1 : connaissant le modèle  $\lambda = (A, B, \pi)$  et disposant d'une séquence d'observations  $O$ , calculer  $P(O|\lambda)$ . Il s'agit de déterminer la probabilité d'observer la séquence  $O$  connaissant le modèle.

En pratique, l'algorithme forward-backward permet de répondre à ce problème.

- Problème 2 : connaissant le modèle  $\lambda = (A, B, \pi)$  et disposant d'une séquence d'observations  $O = (o_1, o_2, \dots, o_t)$ , trouver une séquence d'états optimale  $E = (e_1, e_2, \dots, e_t)$  selon un critère défini. En d'autres termes, il s'agit de trouver la partie cachée du modèle : par quels états est vraisemblablement passé le système pour produire la séquence d'observations  $O$  ? Il existe plusieurs méthodes pour résoudre ce problème. Dans la suite de cette étude nous utiliserons l'algorithme de Viterbi.

- Problème 3 : disposant d'une séquence d'observations  $O$  et connaissant les dimensions du modèle (nombre  $N$  d'états et  $M$  de symboles d'observation différents), trouver le modèle  $\lambda = (A, B, \pi)$  qui maximise la probabilité  $P(O|\lambda)$ . Il s'agit ici de l'apprentissage du modèle afin qu'il corresponde au mieux aux données observées.

L'une des solutions à ce problème est donnée par l'algorithme de Baum-Welch.

La recherche d'une estimation de RUL nécessite d'estimer l'état de santé actuel du composant, ce qui s'apparente au problème 2. En effet, on dispose d'une séquence d'observations et d'un modèle de Markov caché représentatif du système, et on cherche à connaître la séquence d'états par lesquels est passé le système pour produire ces observations. En particulier, le dernier état de cette séquence correspond à l'état de santé actuel. Parmi les méthodes existantes, l'algorithme de Viterbi permet d'identifier la séquence d'états la plus optimale au sens du critère du maximum de vraisemblance, c'est-à-dire celle qui est la plus probable. La séquence réelle d'états reste inconnue, mais nous obtenons la séquence la plus probable grâce à cet algorithme.

Une fois l'état de santé actuel du composant connu, il est possible d'estimer sa RUL. En général, l'état final du HMM est absorbant ce qui signifie qu'une fois cet état atteint, le modèle à une probabilité de 1 de rester dans cet état. Cela se traduit par une matrice de probabilité de transition de la forme suivante (Toufik, 2016) (Berglund, 2014) :  $A = \begin{pmatrix} Q & R \\ 0 & 1 \end{pmatrix}$ , où  $Q$  est une matrice carrée de taille  $(N - 1)$ ,  $R$  est une matrice de taille  $(N - 1) * 1$  et 0 est une matrice nulle de taille  $1 * (N - 1)$ .

Par récurrence on a  $A^n = \begin{pmatrix} Q^n & [I + Q + \dots + Q^n]R \\ 0 & 1 \end{pmatrix}$

Or  $\lim_{n \rightarrow \infty} Q^n = 0$ , donc  $\lim_{n \rightarrow \infty} A^n = \begin{pmatrix} 0 & FR \\ 0 & 1 \end{pmatrix}$ , où  $F = (I - Q)^{-1}$  est appelée matrice fondamentale du modèle. Chaque élément  $f_{ij}$  de  $F$  est l'espérance du nombre de passages en  $j$  partant de  $i$ . Ainsi, la somme des éléments de la ligne n°  $i$  de  $F$  donne l'espérance du temps d'absorption partant de l'état n°  $i$ . Soit  $\tau_i$  le temps moyen avant d'arriver dans l'état défaillant (état n°  $N$ ) à partir de l'état n°  $i$ , alors  $\tau_i = \sum_{j=1}^{N-1} f_{ij}$ . La RUL est calculée de la manière suivante : considérons que le modèle est actuellement dans l'état n°  $i$  ( $i$  ne peut pas valoir  $N$  sinon le composant est défaillant) et appelons  $t_i$  le temps passé dans cet état.

- Si  $i < N - 1$ 
  - o Si  $f_{ij} > t_i$  alors  $RUL = f_{ij} - t_i + \tau_{i+1}$  (on calcule le temps avant de passer dans l'état n°  $i + 1$ , puis on ajoute le temps moyen avant d'atteindre l'état défaillant à partir de l'état n°  $i + 1$ )
  - o Sinon  $RUL = 1 + \tau_{i+1}$  (on considère que l'unité passera dans l'état n°  $i + 1$  dès le prochain pas de temps donc  $RUL = 1 +$  temps moyen avant l'absorption en partant de l'état n°  $i + 1$ )
- Sinon (le composant est dans l'état n°  $N - 1$ )
  - o Si  $\tau_{N-1} > t_i$  alors  $RUL = \tau_{N-1} - t_i$  ( $RUL =$  temps moyen avant l'absorption moins temps de séjour dans l'état actuel)
  - o Sinon  $RUL = 1$  (on considère que l'unité passera dans l'état n°  $i + 1$ , c'est-à-dire l'état défaillant, dès le prochain pas de temps)

Cette méthode permet d'estimer la RUL du composant à chaque instant. Pour chaque nouvelle observation, nous réutilisons l'algorithme de Viterbi pour déterminer l'état de santé actuel du composant (la structure du HMM reste inchangée), puis nous recalculons la RUL comme présenté ci-dessus.

### Application au PHM challenge de 2008

La méthode décrite ici a été appliquée au PHM challenge de 2008 qui est une compétition sponsorisée par IEEE afin d'évaluer les modèles de pronostics (Le, 2016) (Le Son, 2012). Elle consiste en 3 jeux de données : le premier contient les données correspondant à 218 turbines de l'instant initial jusqu'à leur défaillance et permet de faire l'apprentissage du modèle et donc la construction du modèle  $\lambda = (A, B, \pi)$ . Un deuxième jeu de données permet de tester et améliorer le modèle. Il contient les données de 218 turbines mais tronquées à un moment aléatoire avant la défaillance. Le dernier jeu de données permet d'évaluer et comparer les modèles et est construit de la même manière que le deuxième. Les données ont été créées par simulation par le modèle C-MAPSS (Commercial Modular Aero-Propulsion System Simulation) de la NASA. Ce modèle simule un réacteur d'avion. Il a 3 paramètres en entrée et donne les mesures issues de 21 capteurs en sortie (Saxena, Goebel, Simon, & Eklund, 2008). La **Figure 4** et la **Figure 5** présentent une turbine telle que simulée par le modèle.

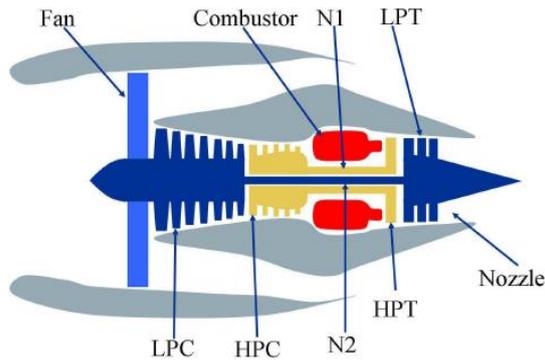


Figure 4. Réacteur d'avion simulé pour le PHM challenge de 2008

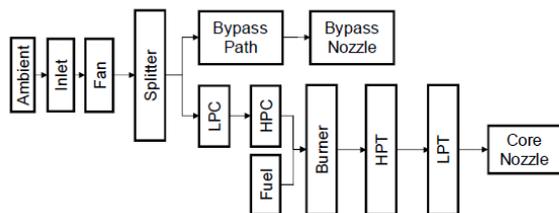


Figure 5. Les différents modules et leurs connections tels que modélisés dans la simulation

Dans le but de créer un HMM décrivant la dégradation du réacteur, il est nécessaire d'avoir un indicateur de cette dégradation. Nous avons utilisé l'indicateur proposé par (Le Son, 2012). Il est construit à partir d'une sélection de 7 des 21 capteurs. La Figure 6 montre cet indicateur pour l'une des 218 unités qui constituent le jeu de données d'apprentissage. Par la suite, les figures présentent les étapes de la méthode appliquées à l'unité n° 2. Ces étapes et les résultats qui en découlent restent valable pour toutes les unités du jeu de données.

Une fois cet indicateur défini, l'étape suivante est de créer le HMM qui modélisera les turbines. Pour cela, il est nécessaire de déterminer l'état de santé et le symbole émis à chaque instant par chaque unité. Appelons  $e_i(t)$  et  $o_i(t)$

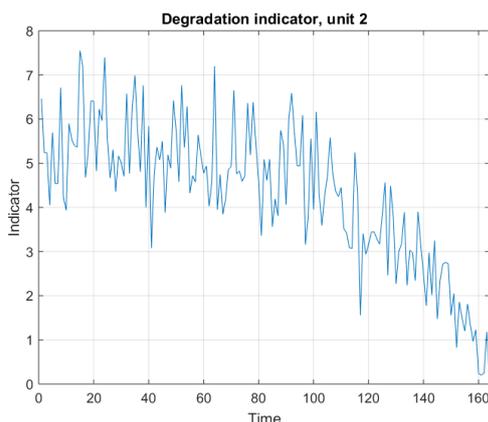


Figure 6. Indicateur de dégradation pour la turbine n° 2

respectivement l'état de l'unité n°  $i$  et le symbole émis par l'unité n°  $i$  à l'instant  $t$ . Pour déterminer  $e_i(t)$  nous procédons de la façon suivante :

- Nous approximations la courbe de l'indicateur en fonction du temps par un polynôme  $P_i$  de degré 3

- Nous définissons  $P_{max} = \max_{1 \leq t \leq T_{défaillance}^i} (P_i(t))$ , où  $T_{défaillance}^i$  est l'instant de défaillance de l'unité n°  $i$ . Notons  $P_{MAX}$  les 95 centiles du vecteur  $P_{max}$  ainsi créé.
- La valeur donnée à  $e_i(t)$  dépend de la valeur de  $P_i(t)$  comparée à des valeurs seuils :
  - o Si  $P_i(t) \geq \frac{N-2}{N-1} P_{MAX}$  alors  $e_i(t) = 1$  (état nominal)
  - o Si  $\frac{N-k}{N-1} P_{MAX} > P_i(t) \geq \frac{N-k-1}{N-1} P_{MAX}$ ,  $2 \leq k \leq N-2$  alors  $e_i(t) = k$
  - o Si  $P_i(t) \geq \frac{1}{N-1} P_{MAX}$  alors  $e_i(t) = N-1$
  - o  $e_i(T_{défaillance}^i) = N$  (l'état final est défaillant pour le jeu de données d'apprentissage)

La Figure 7 montre comment les états sont définis pour un HMM à 6 états. La définition des seuils à cette étape de la méthode est un sujet crucial, mais il n'est pas étudié ici.

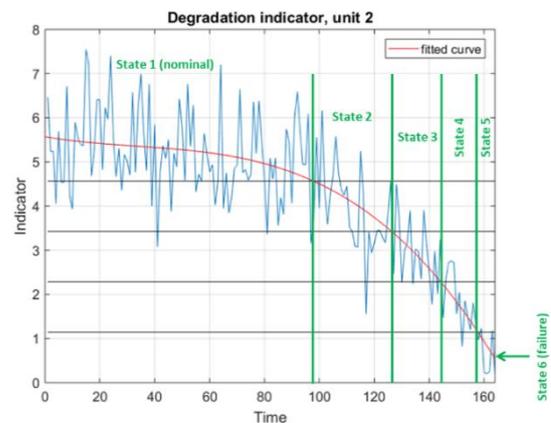


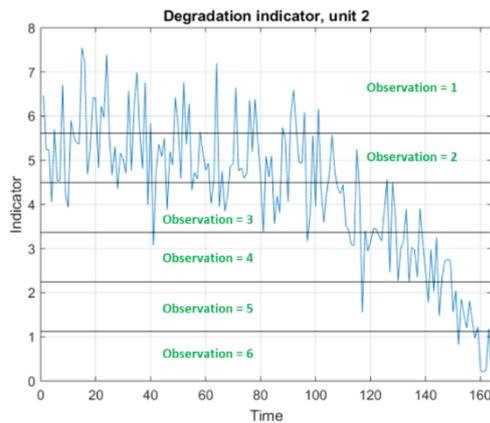
Figure 7. Définition des états pour chaque pas de temps de l'unité n° 2

Pour les symboles d'observation, le processus est similaire :

- Appelons  $D_i(t)$  le symbole émis par l'unité n°  $i$  à l'instant  $t$  et notons  $D_{max}(i) = \max D_i(t)$ .
- Notons  $D_{MAX}$  les 95 centiles de  $D_{max}(i)$ 
  - o Si  $D_i(t) \geq \frac{M-1}{M} D_{MAX}$  alors  $o_i(t) = 1$
  - o Si  $\frac{M-k}{M} D_{MAX} > D_i(t) \geq \frac{M-k-1}{M} D_{MAX}$ ,  $1 \leq k \leq M-1$  alors  $o_i(t) = k+1$

La Figure 8 montre comment les symboles d'observation sont définis pour un HMM à 6 symboles. Encore une fois, la définition des seuils n'est pas étudiée ici.

Ces étapes aboutissent à la création d'un jeu de données que nous pouvons utiliser pour faire l'apprentissage du HMM. Cet apprentissage est réalisé grâce à l'algorithme de Baum-Welch.



**Figure 8.** Définition des symboles d'observation pour chaque pas de temps de l'unité n° 2

Nous disposons donc maintenant d'un HMM qui représente les turbines et pouvons commencer à estimer les RUL avec le second jeu de données. Comme précédemment, nous construisons l'indicateur de dégradation à partir des 7 capteurs sélectionnés. Nous suivons la même procédure que présentée ci-dessus pour définir les séquences d'observation. Puis, nous utilisons l'algorithme de Viterbi pour obtenir la séquence d'états la plus probable et nous prenons le dernier état de cette séquence : il s'agit de l'état de santé actuel de la turbine étudiée. Pour finir, nous calculons la RUL par la méthode décrite plus tôt.

Le but de notre démarche est de valider le modèle de pronostic avec des Modèles de Markov cachés et surtout de traiter le problème de l'incertitude dans l'estimation de RUL. Par contre, notre objectif n'est pas la performance de notre modèle, c'est pourquoi nous ne présentons pas nos résultats bruts ni ne les comparons à ceux des participants au challenge.

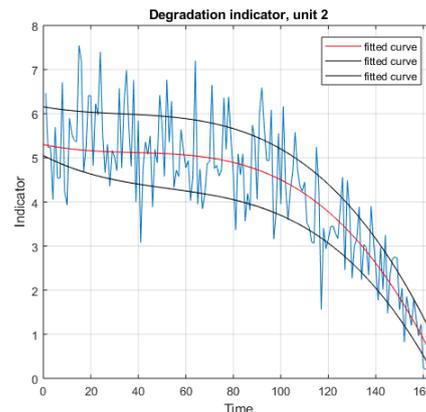
### Définition d'un intervalle pour la RUL

Comme pour chaque estimation, la RUL obtenue dans la section précédente est sujette à des incertitudes et il est important d'évaluer l'ampleur de cette incertitude. Par conséquent, dans cette section nous proposons une méthode pour déterminer un intervalle pour les valeurs de RUL. Le principe est de créer 2 nouveaux HMMs qui donneront une borne supérieure et une borne inférieure. La procédure est la suivante :

- Nous calculons à chaque instant l'erreur entre l'indicateur de dégradation  $D_i(t)$  et le polynôme  $P_i(t)$  qui l'approxime.
- $$err_i(t) = D_i(t) - P_i(t), 1 \leq i \leq n_{turbines}, 1 \leq t \leq T_{défaillance}^i$$
- où  $n_{turbines}$  est le nombre de turbines dans le jeu de données d'apprentissage.
- Cette erreur est divisée en 2 :  $err_{sup}^i$  et  $err_{inf}^i$  qui contiennent respectivement les valeurs positives et négatives de  $err_i$ .
  - Nous calculons les valeurs moyennes de  $err_{sup}^i$  et  $err_{inf}^i$  sur une fenêtre glissante. Appelons les  $\overline{err}_{sup}^i$  et  $\overline{err}_{inf}^i$ .
  - Nous créons 2 nouveaux polynômes :
 
$$\begin{cases} P_{sup}^i = P_i(t) + \overline{err}_{sup}^i(t) \\ P_{inf}^i = P_i(t) + \overline{err}_{inf}^i(t) \end{cases}$$
  - Ces polynômes permettent de construire 2 nouveaux jeux de séquences d'états pour chaque turbine dans le jeu de données pour l'apprentissage. Nous pouvons donc construire et faire l'apprentissage de 2 nouveaux HMMs. L'un

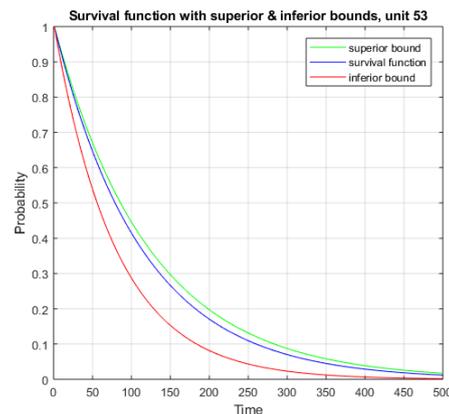
d'eux donnera une borne supérieure et l'autre une borne inférieure pour la RUL estimée.

La **Figure 9** montre le tracé du polynôme  $P_i$  et de ses bornes supérieure et inférieure  $P_{sup}^i$  et  $P_{inf}^i$  pour une turbine issue du jeu de données d'apprentissage.



**Figure 9.** Bornes supérieure et inférieure du polynôme  $P_i$

Disposant de la RUL et de son intervalle, nous pouvons tracer la fonction de survie de la turbine étudiée avec ses bornes supérieure et inférieure. Nous avons choisi de présenter nos résultats sous la forme de fonctions de survie pour rendre leur interprétation plus facile et car cela fournit suffisamment d'informations pour implémenter une politique de maintenance. La **Figure 10** présente la fonction de survie obtenue pour l'une des turbines du jeu de données test ainsi que la borne supérieure et la borne inférieure.



**Figure 10.** Fonction de survie obtenue pour l'unité n° 53 avec les bornes supérieure et inférieure

### Gérer des données incertaines

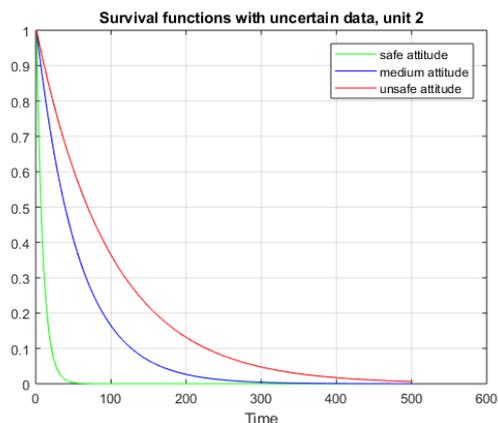
Notre méthode d'estimation de RUL se base sur un jeu de données qui décrit l'état de santé du composant étudié. Par conséquent, le résultat dépend beaucoup de la qualité des données collectées et de la confiance qu'on peut leur accorder. Toutefois, une partie de ces données peut être altérée pour diverses raisons, et cela peut impacter nos résultats. Un HMM étant par définition sans mémoire, si les données incertaines sont au début de la séquence d'observation, cela n'influencera pas l'estimation de la RUL. Par contre, si ces données sont récentes, cela peut changer les résultats. Par conséquent, nous proposons plusieurs stratégies pour traiter ce problème :

- Attitude « safe » : pour chaque donnée incertaine, nous considérons que le symbole émis a la valeur

maximale (6 dans l'exemple présenté plus haut). Il s'agit donc de prendre en compte le pire scénario et de maximiser la sécurité.

- Attitude « unsafe » : pour chaque donnée incertaine, nous considérons que le symbole émis a la valeur 1. Il s'agit de prendre en compte le scénario le plus optimiste.
- Attitude « medium » : pour chaque donnée incertaine, nous considérons que le symbole émis a une valeur intermédiaire (3 ou 4 dans l'exemple présenté plus haut).
- Attitude « aveugle » : nous ne faisons aucune supposition sur les données incertaines. Nous savons uniquement que chaque symbole émis appartient à l'ensemble  $\{1, 2, \dots, M\}$  (dans notre exemple  $M = 6$ ) donc nous considérons tous les cas possibles et nous cherchons les valeurs maximales et minimales des RUL obtenues.

Ces stratégies ont été appliquées sur le PHM challenge de 2008. Nous avons artificiellement altéré des données de certaines turbines du jeu de données de test. Appelons  $T_f^i$  le dernier relevé de données disponible pour l'unité n°  $i$ . On considère que les données collectées entre les instants  $T_f^i - 10$  et  $T_f^i - 5$  inclus sont endommagées et nous appliquons nos stratégies. La **Figure 11** présente les fonctions de survies obtenues par les différentes attitudes. L'attitude « aveugle » prend en compte tous les cas possibles et, en particulier, le pire scénario et le scénario le plus optimiste. Par conséquent, les bornes maximale et minimale résultantes de cette attitude correspondent aux valeurs obtenues par les attitudes « unsafe » et « safe » respectivement.



**Figure 11.** Fonctions de survie obtenues avec nos stratégies en cas de données incertaines

Cette figure souligne les avantages de nos différentes stratégies en termes d'aide à la décision. En effet, elles permettent de choisir le moment adéquat pour effectuer les tâches de maintenance. Par exemple, on peut considérer qu'il faut réaliser la maintenance quand le composant a 50% de chance de défaillir. Alors l'attitude « safe » résultera en une planification de la maintenance dans un futur très proche alors que l'attitude « unsafe » recommandera de ne la réaliser que dans environ 70 pas de temps. En pratique, la sélection d'une stratégie au détriment des autres dépendra de plusieurs paramètres comme, par exemple, de la criticité du composant ou de son coût.

La **Figure 11** met aussi en évidence les limites de cette méthode. En effet, plus le nombre de données incertaines est important plus le résultat de l'attitude « safe » tend vers 0. Par exemple, sur la figure, la fonction de survie de l'attitude « safe » décroît très rapidement vers 0, ce qui rend ce résultat presque inexploitable car il laisse trop peu de

temps pour prévoir les actions de maintenance requises. Il est clair que le nombre de données incertaines influence les incertitudes du résultat.

## Conclusion

Dans cette publication, nous avons présenté une méthode pour calculer la RUL de composants grâce aux HMMs. Puis, nous avons proposé une solution pour donner un intervalle pour cette RUL estimée. Enfin, nous avons proposé une stratégie qui peut être adopter dans le cas où certaines données sont incertaines. Ces méthodes ont été testées sur le PHM challenge de 2008 et les résultats montrent qu'elles peuvent fournir une aide à la décision importante grâce aux informations qu'elles apportent. Toutefois, cette application a aussi souligné certaines limites.

Dans des travaux futurs, nous essaierons d'appliquer ces méthodes sur un cas réel. Nous nous efforcerons aussi de les améliorer et de surmonter les limites dont nous avons discuté dans cette publication. En particulier, nous voudrions utiliser des HMMs imprécis afin de calculer les bornes supérieure et inférieure de la RUL.

## Références

AFNOR. (2001). NF-EN-13306-X-60-319 : Terminologie de la maintenance. Norme, Association Française de Normalisation.

Bartelds, G., Biemans, C., Boller, C., Bredine, M., Claesson, Å., Delebarre, C., . . . Worden, K. (2004). Health Monitoring of Aerospace Structures – Smart Sensor Technologies and Signal Processing. Southern Gate, Chichester, West Sussex PO19 8SQ, England: John Wiley & Sons Ltd.

Berglund, N. (2014). Processus aléatoires et applications. Université d'Orléans, Master 2 Pro de mathématiques.

Degirmenci, A. (2014). Introduction to Hidden Markov Models. Harvard University, 1-5.

Geramifard, O., Xu, J., Zhou, J., & Li, X. (2012). A Physically Segmented Hidden Markov Model Approach for Continuous Tool Condition Monitoring: Diagnostics and Prognostics. IEEE Transactions on Industrial Informatics, 8(4), 964 - 973.

Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. Mechanical Systems and Signal Processing(20), 1483-1510.

Jimenez, C., Feuillebois, C., Pauly, E., & Dauzère-Pères, S. (2010). Intégration des technologies RFID pour la maintenance sur hélicoptère, impacts sur les processus. Lambda Mu 17. La Rochelle, France.

Krüger, M. (2013). Measures of Conflicting Evidence in Bayesian Networks for Classification. 16th International Conference on Information Fusion. Istanbul, Turkey.

Krüger, M. (2014). Detection of Failing Sensors by Conflicting Evidence in Bayesian Classification. 17th International Conference on Information Fusion (FUSION). Salamanca, Spain.

- Le Son, K. (2012). Modélisation probabiliste du pronostic - Application à un cas d'étude et à la prise de décision en maintenance. PhD thesis, Université de Technologie de Troyes.
- Le, T. (2016). Contribution to deterioration modeling and residual life estimation based on condition monitoring data. PhD thesis, Université Grenoble Alpes.
- Le, T., Bérenguer, C., & Chatelain, F. (2015). Prognosis based on Multi-branch Hidden semi-Markov Models: A case study. 9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes SAFEPROCESS. Paris, France.
- Le, T., Chatelain, F., & Bérenguer, C. (2014). Hidden Markov Models for diagnostics and prognostics of systems under multiple deterioration modes. European Safety and Reliability Conference - ESREL. Wroclaw, Poland.
- Lee, J., Ni, J., Djurdjanovic, D., Qiu, H., & Liao, H. (2006). Intelligent prognostics tools and e-maintenance. *Computers in Industry*(57), 476–489.
- Lesobre, R., Bouvard, K., Barros, A., Bérenguer, C., & Cocquempot, V. (2014). Politique de maintenance dynamique pour un système multi-composant intégrant les informations de surveillance. *Lambda Mu 19*. Dijon, France.
- Mercier, S., & Pham, H. (2012). A preventive maintenance policy for a continuously monitored system with correlated wear indicators. *European Journal of Operational Research*(222), 263–272.
- Palem, G. (2013). Condition-based maintenance using sensor arrays and telematics. *International Journal of Mobile Network Communications & Telematics*, 3(3).
- Rabiner, L. (1989). A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition. *Proceedings of the IEEE*, 77(2), 257 - 286.
- Roblès, B., Avila, M., Duculty, F., Vrignat, P., Bégot, S., & Kratz, F. (2014). Modélisation du niveau de dégradation d'un système industriel à l'aide de modèles de Markov cachés. *Lambda Mu 19*. Dijon, France.
- Roemer, M. J., Byington, C. S., Kacprzyński, G. J., & Vachtsevanos, G. (2006). An overview of selected prognostic technologies with application to engine health management. *ASME Turbo Expo 2006: Power for Land, Sea & Air*. Barcelona, Spain.
- Saxena, A., Goebel, K., Simon, D., & Eklund, N. (2008). Damage propagation modeling for aircraft engine run-to-failure simulation. *Proceedings of 2008 international conference on prognostics and health management*.
- Sikorska, J., Hodkiewicz, M., & Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*(25), 1803-1836.
- Soualhi, A., Razik, H., Clerc, G., & Doan, D. (2014). Prognosis of Bearing Failures Using Hidden Markov Models and the Adaptive Neuro-Fuzzy Inference System. *IEEE Transactions on industrial electronics*, 61(6), 2864 - 2874.
- Sprael, J., Sannino, C., & Seguin, C. (2014). Techniques d'aide à la décision appliquées à la maintenance d'un avion de type Business Jet. *Lambda Mu 19*. Dijon, France.
- Tang, D., Makis, V., Jafari, L., & Yu, J. (2015). Optimal maintenance policy and residual life estimation for a slowly degrading system subject to condition monitoring. *Reliability Engineering and System Safety*(134), 198-207.
- Tobon-Mejia, D., Medjaher, K., Zerhouni, N., & Tripot, G. (2011). Hidden Markov models for failure diagnostic and prognostic. *2011 Prognostics and System Health Management Conference*. Shenzhen, China.
- Toufik, A. (2016). Pronostic des systèmes complexes par l'utilisation conjointe de modèle de Markov caché et d'observateur. PhD thesis, Université d'Orléans.
- Vachtsevanos, G., Lewis, F. L., Roemer, M., Hess, A., & Wu, B. (2006). *Intelligent Fault Diagnosis and Prognosis for Engineering Systems*. Hoboken, New Jersey: John Wiley & Sons, Inc.