



HAL
open science

Impact de méthodes d'analyse de données pour améliorer le pronostic de défaillance moteur à partir de séries temporelles multivariées

Morgane Suhas, Emmanuelle Abisset-Chavanne, Pierre-André Rey, Frederic Deschamps

► To cite this version:

Morgane Suhas, Emmanuelle Abisset-Chavanne, Pierre-André Rey, Frederic Deschamps. Impact de méthodes d'analyse de données pour améliorer le pronostic de défaillance moteur à partir de séries temporelles multivariées. S-MART 2023 : 18ème Colloque national S.mart, Arts et Métiers Paristech ENSAM Aix-en-Provence, Université de Toulon [UTLN], Apr 2023, Carry-le-Rouet, France. hal-04397904

HAL Id: hal-04397904

<https://hal.science/hal-04397904>

Submitted on 16 Jan 2024

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.

Impact de méthodes d'analyse de données pour améliorer le pronostic de défaillance moteur à partir de séries temporelles multivariées

M. Suhas ^{a,*}, E. Abisset-Chavanne ^b, P.-A. Rey ^b, F. Dèschamps ^c

^a AMValor, Laboratoire I2M, Bordeaux, France

^b Arts et Métiers, Laboratoire I2M, Bordeaux, France

^c LGM, Toulouse, France

* e-mail : morgane.suhas@ensam.eu

1. INTRODUCTION

Contexte : La motivation de ce travail provient d'une problématique industrielle. Pour surveiller l'usure dans un système industriel, des signes précurseurs de défaillance peuvent être identifiés au sein des données relevées sur le système. Elles sont indispensables pour la construction des modèles visant à prédire les défaillances des systèmes puisqu'elles retracent leur historique et garantissent de ce fait un suivi fiable des systèmes. Cependant, lorsque l'on cherche à transposer ces modèles, possédant des performances satisfaisantes, sur d'autres systèmes, on peut constater des écarts de performances. Ces cas-là se présentent la plupart du temps quand les données d'entrée sur lesquelles a appris le modèle sont trop éloignées des données réellement remontées. Le problème provient alors de l'extrapolation des données d'entrée, c'est-à-dire que le modèle n'arrive pas à généraliser ses capacités de prédictions sur de nouveaux jeux de données d'entrée. Il peut ainsi être utile de

développer des méthodes basées sur la réduction des données d'entrée. En effet, les multiples données récoltées sur le système peuvent présenter des redondances ou des informations non essentielles, qui peuvent fausser la phase d'apprentissage. Le passage de bases de données complètes à des bases de données réduites permet de synthétiser l'information essentielle dans le but de réaliser des projections de nouvelles données dans ces bases. Si les bases réduites sont bien définies, la projection des données extrapolées apportera une meilleure prédiction des défaillances des systèmes. La réduction de la dimensionnalité vise à projeter les données d'un espace à haute dimension en représentations à basse dimension par l'extraction, l'élimination ou la sélection de caractéristiques. La réduction de la dimensionnalité doit cependant respecter les similitudes entre les différentes données d'entrée. L'objectif est de mettre en place un modèle capable de prédire le comportement de l'usure d'un moteur électrique en particulier mais qui puisse toutefois

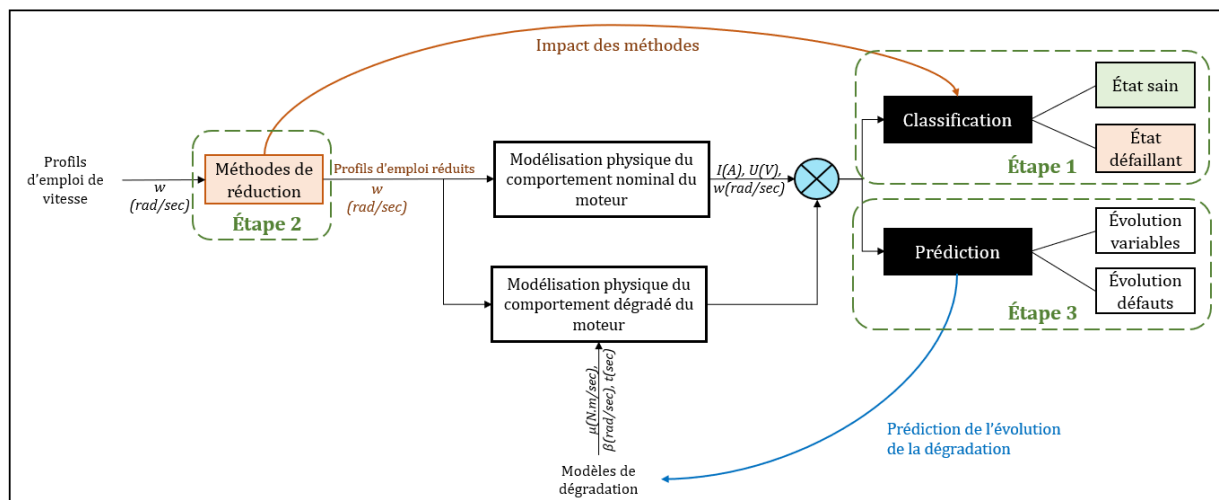


Figure 1 - Schéma de la méthode mise en place

s'adapter sur un autre moteur présentant d'autres conditions d'usage, avec des performances de prédiction équivalentes. L'enjeu sera donc, d'une part, d'entraîner le modèle prédictif sur une base de données d'entrée réduites, pour augmenter les capacités d'extrapolation et de généralisation lorsque le modèle sera face à de nouvelles données d'entrée. De plus, en réduisant la taille de l'espace des données d'entrée, les techniques de réduction de la dimensionnalité permettront d'ajouter de l'interprétabilité entre les données d'entrée et les résultats fournis par les modèles prédictifs [11]. D'autre part, la méthodologie devra intégrer les connaissances physiques du système dans le but de créer tout de même un modèle de pronostic de défaillances spécifique au système.

Démarche : Le développement de la méthode présentée dans ce papier comprend trois phases (voir figure 1). La première phase concerne la mise en place d'un modèle de classification non prédictif (étape 1 de la figure 1). Il a été construit lors d'un travail préliminaire [1] et permet de diagnostiquer les défauts du roulement du moteur. On le qualifie de modèle hybride puisqu'il s'appuie à la fois sur les modèles physiques du moteur et sur les données réelles du système [8,12,13,14]. En effet, le comportement réel du moteur électrique est représenté grâce à une modélisation multi-physique via le logiciel MATLAB avec des simulations de 20 secondes. Afin de comprendre et de maîtriser l'impact des défauts sur le comportement du moteur, des défaillances ont été introduites dans le modèle du moteur via des modèles physiques de comportement. Dans ce travail, ces derniers, utilisés pour modéliser les défaillances du moteur sont des couples résistants évoluant dans le temps. Les données d'entrée pour les modèles physiques du moteur (modèle sain et modèle dégradé) sont des séries temporelles représentant les profils de vitesse du moteur. Elles sont générées en variant les amplitudes et les fréquences des signaux temporels constituant les profils d'entrée. Les données de sortie des modèles physiques du moteur sont l'intensité, la tension et la vitesse de rotation. Le modèle hybride identifie en sortie le comportement du moteur, à savoir un comportement sain ou un comportement défaillant à partir des résidus entre les données de sortie du modèle dégradé et celles du modèle en comportement sain. Le modèle de classification a été construit à l'aide d'un réseau de neurones. Il localise un défaut s'étant déjà produit sur le moteur mais ne permet pas de prédire son évolution. L'étape 2 de la méthode (voir figure 1) concerne la partie réduction des données d'entrée afin de mieux extrapoler de nouveaux profils d'emploi du moteur. L'impact de cette réduction des données d'entrée sera également évalué. La troisième phase (étape 3 de la figure 1) s'attache à la prédiction de l'évolution des liens existants entre les variables relevées en sortie du modèle et les paramètres d'usure injectés artificiellement dans le modèle.

Ainsi, dans ce travail, nous discuterons dans un premier temps de plusieurs méthodes de réduction de la dimensionnalité pour réduire la taille des données d'entrée dans l'algorithme de classification. Nous verrons par la suite l'impact de ces méthodes sur la détection des défauts. La démarche pour prédire l'évolution de l'usure

selon l'évolution des grandeurs physiques de sortie du système sera développée dans une dernière partie.

2. METHODES DE REDUCTION DIMENSIONNELLE SUR DONNEES D'ENTREE

Les méthodes de réduction dimensionnelle sont utiles pour visualiser et traiter les ensembles de données de grande dimension, tout en conservant autant de variance que possible dans l'ensemble de données [9,16]. Ce travail a pour objectif de définir les bases réduites pertinentes pour la prédiction de défaillance (étape 2 de la figure 1). Effectivement, l'objectif est de trouver une base réduite des données qui explique toute la variabilité des données d'entrée. La pertinence de cette base pour la prédiction de la défaillance sera vérifiée a posteriori.

Pour cette première étude, les données utilisées seront des données synthétiques créées à partir d'un modèle physique sain puis dégradé pour se rapprocher des données réelles. Ces données d'entrée représentent les différents profils d'emploi que peut subir le moteur lorsqu'il est en marche. Initialement, la base des données d'entrée est constituée de 270 profils de vitesse.

2.1. Filtrages passe-bas et passe-haut

L'étude va se porter sur l'importance des fréquences des signaux d'entrée, après avoir étudié les spectres qui contribuaient majoritairement à la variabilité des données. La méthode appliquée consiste à filtrer les signaux d'entrée par un filtre passe-bas dans un premier temps. Les hautes fréquences, c'est-à-dire les fréquences supérieures à la fréquence de coupure choisie, sont supprimées pour ne garder que les basses fréquences. Le choix de la fréquence de coupure s'est fait après étude de la répartition des spectres des signaux d'entrée. Elle a été sélectionnée comme la fréquence moyenne des spectres. Les signaux basses fréquences sont reconstruits dans le domaine temporel grâce à la Transformée de Fourier rapide inverse (voir figures 2 et 3) et injectés dans le modèle hybride en tant que données d'entrée. Le signal filtré reconstruit depuis le domaine fréquentiel équivaut au signal filtré dans le domaine temporel. De manière

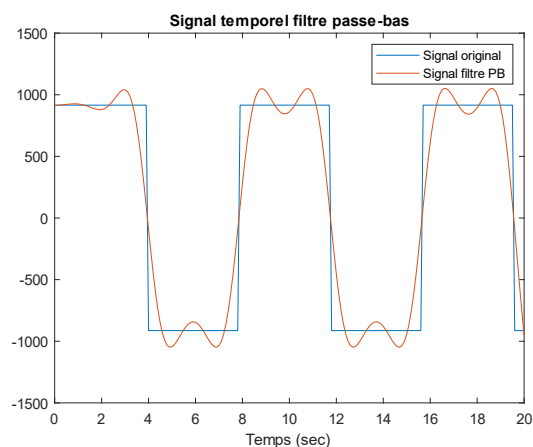


Figure 2 - Exemple de signal d'entrée filtré dans le domaine temporel

analogue, les signaux d'entrée sont filtrés dans un deuxième temps à l'aide d'un filtre passe-haut puis sont également reconstruits dans le domaine temporel [7].

2.2. Transformée de Fourier Discrète

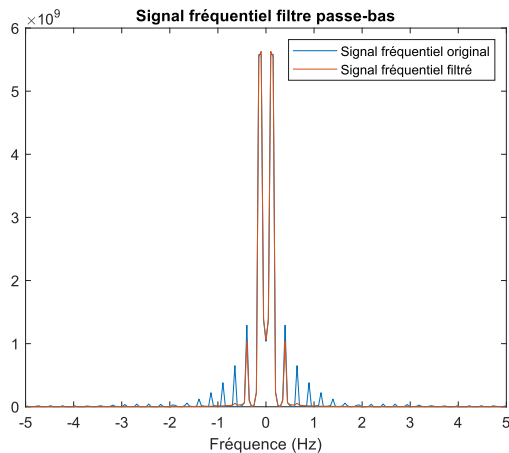


Figure 3 - Exemple de signal d'entrée filtré dans le domaine fréquentiel

Pour réduire la base initiale des signaux d'entrée, on peut procéder à la comparaison du contenu fréquentiel des signaux. Les séries temporelles sont transformées dans le domaine fréquentiel selon leur spectre via la Transformée de Fourier Discrète (TFD), définie telle que ci-dessous [10].

Prenons un signal $x[n]$ contenant N échantillons. Sa TFD est alors définie par :

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi \frac{kn}{N}}, 0 \leq k \leq N-1$$

La TFD est appliquée à l'ensemble des signaux d'entrée. Les pics, correspondants aux harmoniques, sont identifiés sur chaque spectre de chaque signal et leurs fréquences respectives sont récupérées. Pour identifier les pics, un seuil d'amplitude minimale entre le pic mis en évidence et ses voisins est défini. Le seuil a été choisi de manière à ne

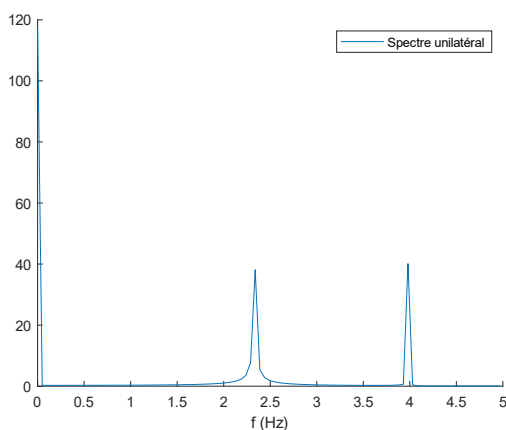


Figure 4 - Exemple de spectre unilatéral correspondant à un profil d'emploi du moteur

garder que les pics les plus importants pour la caractérisation du spectre sans suppression d'information. Une limite des 10 premières harmoniques est fixée pour l'analyse du spectre. Les spectres redondants sont supprimés pour ne garder que ceux présentant un contenu fréquentiel unique. 172 spectres uniques contenant plusieurs pics sont ainsi retenus. Leur indice est récupéré et les signaux uniques sont isolés dans la base des données d'entrée initiale.

2.3. Décomposition en Valeurs Singulières & Analyse en Composantes Principales

Une autre méthode communément employée dans la réduction dimensionnelle est la méthode de décomposition en valeurs singulières (SVD) [4]. C'est une technique non paramétrique qui permet d'exprimer une matrice $A \in \mathbb{R}^{m \times n}$ à l'aide de 2 matrices orthogonales $U = [u_1, u_2, \dots, u_m] \in \mathbb{R}^{m \times m}$ et $V = [v_1, v_2, \dots, v_m] \in \mathbb{R}^{n \times n}$ telles que :

$$A = U \Sigma V^T.$$

Où $\Sigma = [diag(\sigma_1, \sigma_2, \dots, \sigma_q), 0]$, O est une matrice nulle et $q = \min(m, n)$. Les paramètres $\{\sigma_i\}$ ($i=1, 2, \dots, q$) sont les valeurs singulières de A et $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_q > 0$.

La SVD a été appliquée sur la base des données d'entrée initiale mais la méthode de l'Analyse en Composantes Principales (ACP) aurait également pu être employée. Effectivement, les 2 techniques sont intimement liées. L'ACP fonctionne en trouvant les vecteurs propres de la matrice de covariance et en les classant par leurs valeurs propres respectives. Ces dernières sont les carrés des valeurs singulières trouvées par la SVD [3,10].

Pour estimer le nombre de signaux d'entrée à conserver pour entraîner le modèle hybride, on applique la méthode SVD sur l'ensemble des signaux. Les valeurs diagonales de la matrice S obtenues constituent le spectre des valeurs singulières (figure 5). Quant à l'amplitude d'une valeur singulière, elle reflète son importance pour expliquer les données. D'après la figure 5, ce sont les 30 premiers modes des signaux qui ont le plus d'importance pour expliquer les données sans perdre d'informations dans le contenu fréquentiel. Par la suite, on pourra se limiter aux

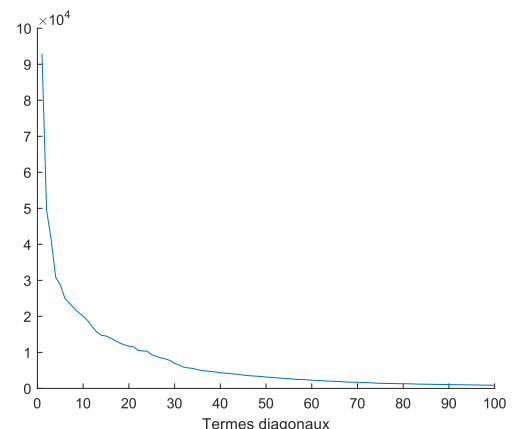


Figure 5 - Energie des modes des signaux d'entrée

10 premiers modes (d'après la figure 5). Les 30 signaux d'entrée qui expliquent le mieux la variabilité des données sont alors reconstruits dans le domaine temporel [5]. Après avoir décrit et testé les méthodes une à une, les méthodes de réduction dimensionnelle sont combinées. Une fois que la TFD a transformé les signaux d'entrée en spectres, on cherche à savoir ceux qui sont les plus influents. Pour cela, la méthode de l'ACP est appliquée sur ces spectres. L'analyse des spectres les plus influents est ensuite réalisée grâce à l'ACP. Elle met en évidence des familles de spectres en explorant les liaisons linéaires sur l'ensemble des spectres. Cela revient à résoudre un problème de maximisation de la variance de projection des données.

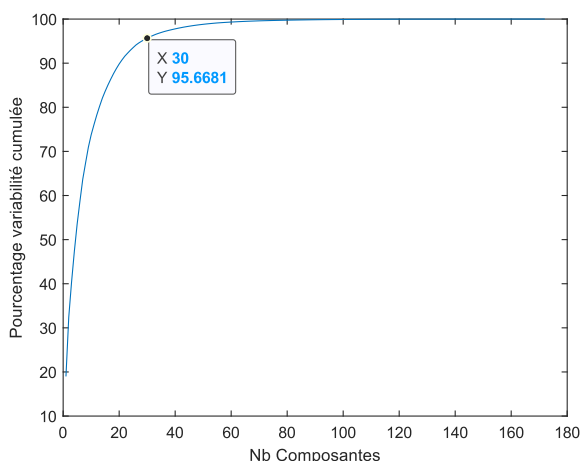


Figure 6 - Variabilité cumulée des spectres après ACP

On remarque sur la figure 6, qu'après application de l'ACP sur les spectres obtenus via TFD, on retrouve les résultats obtenus précédemment avec la SVD, à savoir que les 30 premières composantes suffisent à expliquer plus de 95% de la variabilité des 270 profils d'utilisation. On en conclut qu'en diminuant de 90% le nombre des signaux d'entrée constituant la base d'apprentissage du modèle prédictif, l'information essentielle contenue dans les données initiales est conservée. Par la suite, une analyse des fréquences des premières harmoniques de chaque spectre a permis de confirmer une faible plage de répartition des fréquences. Cela pourrait expliquer que les 30 premières composantes sont suffisantes pour expliquer la variabilité des données.

3. IMPACT DES METHODES DE REDUCTION DES DONNEES SUR LA DETECTION DES DEFAUTS

Après avoir décrit les méthodes de réduction dimensionnelle mises en place, il s'agit de vérifier que le modèle parvient à obtenir les mêmes performances de classification avec les bases réduites des données d'entrée. En premier lieu, on vérifie qu'en exprimant des nouvelles données d'entrée dans les bases de données trouvées dans cette section, le modèle parvient à s'adapter rapidement. Les nouvelles données sont des nouveaux signaux d'entrée pour le modèle, produites en modifiant les fréquences, les amplitudes et les types de

signaux afin d'obtenir des profils d'entrée différents de ceux existants dans la base de données initiale. Pour les exprimer dans les bases de données réduites, on construit une base orthonormée pour l'espace des colonnes de A (matrice des données après réduction via la SVD) en utilisant les 30 colonnes de U qui correspondent aux valeurs singulières non nulles les plus influentes pour le jeu de données initial (des 270 profils d'utilisation du moteur). Les nouvelles données B sont ensuite projetées dans cette base orthonormée et forment la matrice C. C est une représentation de la matrice B dans l'espace des colonnes de U. Pour comprendre ce que signifie C dans l'espace initial, c'est-à-dire dans l'espace temporel, on multiplie les colonnes de C par la base orthonormée [15]. Ces données sont par la suite injectées dans le modèle hybride de classification des défauts du moteur. La classification de ces données projetées produit un RMSE de 7.23. En deuxième lieu, on utilise les données d'entrée réduites pour la phase d'apprentissage du modèle hybride et on teste la classification des défauts sur la base de données complète. On s'assure par conséquent que les performances avec les données réduites sont conformes aux résultats obtenus avec une phase d'apprentissage sur une base de données complète.

Les méthodes sont comparées selon leur précision finale en fin de phase d'apprentissage et selon le critère RMSE (Root-Mean-Square Error) calculé sur les données de test. Le critère RMSE évalue la distance moyenne entre les valeurs prédites par l'algorithme de classification et les valeurs réellement observées sur le système modélisé du moteur. Pour notre cas d'étude, il renvoie la différence de temps en secondes de prédiction entre l'apparition des premiers signes de défaillance classifiés et ceux réellement observés. Pour comparer les résultats de la méthode SVD avec les résultats de l'ACP sur la TFD, les 30 scores des composantes principales qui expliquent le mieux la variabilité dans les données sont reconstruits grâce à la Transformée de Fourier Inverse. Les scores des composantes principales sont les représentations des spectres des données d'entrée dans l'espace des composantes principales. Après reconstruction, les signaux vont servir de données d'entrée pour le modèle hybride.

Tableau 1 - Comparaison des méthodes de réduction de données

Méthode de réduction appliquée	Précision finale (%)	RMSE	Nombre de profils retenus
Aucune	96.27	6.12	270
TFD	94.15	7.60	172
SVD/ACP	93.87	6.98	30
ACP + FFT	85.14	9.1	30
Hautes fréquences	98.76	8.55	243
Basses fréquences	98.89	8.54	243

La réduction dimensionnelle a permis la construction de bases réduites à partir des données d'entrée tout en observant des performances similaires avec le modèle hybride. Plus précisément, le modèle est capable de classer les nouvelles séries temporelles selon le comportement du moteur observé avec un nombre limité de modes de profils d'emploi.

On remarque qu'après élimination des spectres en doublon, ce sont les bases contenant uniquement les hautes fréquences ou les basses fréquences qui obtiennent les meilleures performances de classification. Ce résultat est cohérent puisque les bases finales obtenues avec ces méthodes sont moins réduites qu'avec les autres méthodes appliquées et ont pu donc conserver plus d'informations. En revanche, ces deux méthodes présentent des difficultés de généralisation lorsqu'on utilise le modèle sur d'autres données d'entrée. Cette technique de réduction sera ainsi écartée pour la suite de notre étude. Comme on se trouve dans le cas de signaux périodiques (signaux sinusoïdaux et signaux à impulsions), la TFD apparaît comme le meilleur compromis entre la précision et le taux d'erreur de classification. Pour une réduction plus précise des données, cette méthode peut être combinée avec les performances de l'ACP.

De ce fait, on peut conclure que les bases réduites trouvées, notamment avec la méthode de la SVD, sont pertinentes pour réduire les nouveaux profils d'emploi et prévoir leur défaillance plus précisément. Ces bases permettent en particulier d'alléger le modèle et d'avoir une phase d'apprentissage minimale. Ainsi, on a montré qu'avec d'autres profils d'emploi très différents de ceux rencontrés lors de la phase d'apprentissage, ils peuvent être exprimés dans les bases réduites et produire des performances similaires de classification des défauts. La méthodologie de réduction dimensionnelle est basée sur les résidus calculés à partir du comportement nominal du moteur. Par conséquent, la spécificité de la défaillance sera également détectée lorsque la réduction sera effectuée sur une base d'entrée contenant les profils d'emploi d'un autre moteur. Pour vérifier cela, les modèles physiques doivent être modifiés selon les paramètres du nouveau moteur.

4. PREDICTION DE L'ÉVOLUTION DES DÉFAUTS A PARTIR DES VARIABLES EXPLICATIVES

La classification des données résiduelles effectuée à l'aide du modèle hybride permet de relier les résidus à une loi d'usure. En effet, le travail préliminaire [1] a permis d'associer chaque résidu aux paramètres d'usure appliqués au modèle physique dégradé. Les paramètres d'usure incluent notamment la pente du défaut infligé au moteur et le moment d'apparition du défaut. Quant à la loi d'usure, elle est déterminée selon l'amplitude et la fréquence des données d'entrée. Une caractérisation des résidus selon le type de défaut observé sur le système

peut, dans ce cas, être réalisée pour établir une corrélation entre les paramètres d'usure et les variables d'entrée. A terme, un lien sera établi entre l'évolution des variables suivies et l'évolution des défauts. Avec un suivi de l'évolution des variables, il sera possible de prédire l'évolution du défaut au cours du temps grâce à une régression.

L'objectif est de réaliser la prédiction de séries temporelles sur le long terme (évolution du paramètre d'usure) en utilisant également les valeurs des séries temporelles observées sur le court terme (évolution des quantités d'intérêt de sortie). Après plusieurs tests de performances de prédictions et, en tenant compte de notre durée totale de simulation, on choisit d'observer une fenêtre de 50 échantillons pour prédire le reste de l'allure de la pente du défaut. Une régression comprenant des couches de cellules LSTM (Long short-term memory) (figure 7) a ensuite été mise en place (étape 3 de la figure 1). L'atout de ce type de cellules dans les réseaux neuronaux est qu'il possède des connexions de rétroaction permettant de réguler le flux d'informations qu'il a en mémoire grâce à des systèmes qui peuvent s'apparenter à des « portes ».

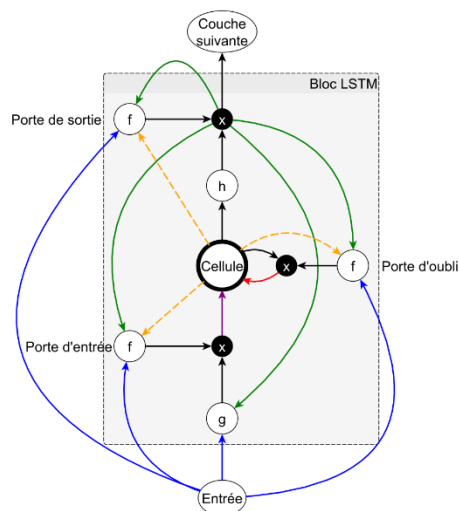


Figure 7 - Schéma d'un neurone LSTM [6]

Les données d'entraînement pour la régression LSTM englobent les données résiduelles obtenues en sortie du modèle mis en place dans le travail précédent ainsi que les paramètres injectés dans les lois d'usures utilisées dans la modélisation de l'usure du moteur, à savoir les instants d'apparition du défaut et la pente du défaut. La limite de ce modèle est qu'il est gourmand en données, même s'il modélise bien les processus non linéaires. Les résultats du modèle de régression sont présentés sur la figure 8.

On s'aperçoit que la régression parvient à retranscrire correctement l'évolution de la pente du défaut mais on vérifiera par la suite que la régression reste aussi performante dans le cas de motifs d'usure cycliques. En effet, il faudra s'assurer que la régression s'adapte lors d'une allure de défaut moins linéaire et évoluant plus lentement dans le temps. Il est prévu pour cela de

complexifier l'étude des profils d'emploi, tout comme l'étude des défauts.

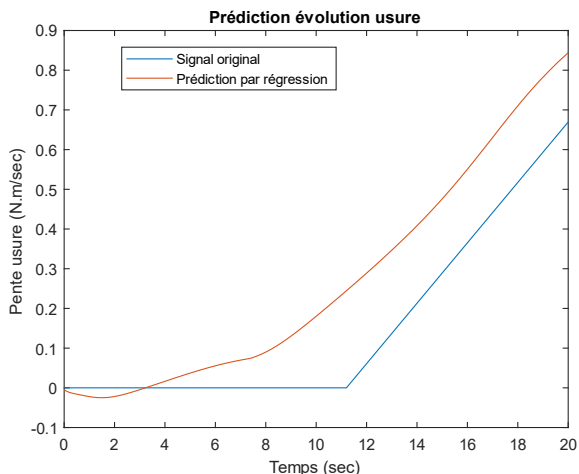


Figure 8 - Prédiction de l'évolution de l'usure

5. DISCUSSION & PERSPECTIVES

L'approche proposée basée sur la réduction dimensionnelle a montré que le modèle mis en place est capable d'obtenir des performances équivalentes en réduisant le nombre de données d'entrée. Cela signifie que lorsqu'un nouveau profil d'utilisation est appliqué sur le moteur, le modèle cherche à le décomposer en plusieurs profils qu'il aura déjà rencontré pendant sa période d'entraînement pour, en premier lieu, identifier et localiser le défaut. Ce travail s'est axé sur le développement des méthodes réalisées sur données synthétiques mais dans le but de l'appliquer sur des données réelles. La démarche a consisté à partir du développement d'une méthode validée numériquement pour progressivement l'appliquer à un banc d'essai moteur à axe linéaire remontant des données réelles.

En deuxième lieu, grâce à la corrélation établie entre l'évolution des grandeurs physiques relevées en sortie de modèle et l'évolution des défauts, il s'agira de montrer dans de futurs travaux que les lois d'usure et les modèles de régression prédisent l'usure sur le long terme. Dans un premier temps, la méthode devra vérifier que les modèles de régression détectent à quel stade du cycle d'usure se trouve le système. Dans un deuxième temps, la méthode sera testée sur les données réelles provenant du banc d'essai du moteur afin d'être validée.

Enfin, une limite de la démarche détaillée dans ce papier est que la répartition des fréquences des données d'entrée, mise en évidence par la TFD de chaque spectre, présente une faible amplitude. On peut alors se demander si les profils d'utilisation simulés ont une assez grande variabilité initialement, avant réduction des données. L'application de la méthode de réduction de dimensionnalité sur le banc d'essai permettra de la valider expérimentalement de manière rigoureuse.

RÉFÉRENCES

- [1] Morgane, S., Emmanuelle, A., Pierre-André, R. & Frédéric, D. (2022) Performance of hybrid modeling on a failure process in industrial systems Performance de la modélisation hybride sur un processus de défaillance dans les systèmes industriels.
- [2] Ibrahim, Kaddouri, Youcef & Serah. (2019) Détection des défauts d'une machine tournante par l'analyse FFT. Thèse de doctorat. Université Mohamed Boudiaf M'Sila.
- [3] Tanwar, S., Ramani, T., & Tyagi, S. (2018) Dimensionality reduction using PCA and SVD in big data: A comparative case study. Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST, 220 LNICST, 116–125.
- [4] Kanth, K. V. F., Agrawal, D., & Singh, A. (1998) Dimensionality Reduction for Similarity Searching in Dynamic Databases.
- [5] Frusque, G., Jung, J., Borgnat, P., & Gonçalves, P. (2019). Réduction de dimension tensorielle parcimonieuse : Application au clustering de connectivité fonctionnelle. <https://hal.inria.fr/hal-02154888>
- [6] Sterner, B., "Theta series attached to level one quadratic forms and Siegel modular forms", Thèse (2018)
- [7] Condat, L. (2006) Méthodes d'approximation pour la reconstruction de signaux et le redimensionnement d'images. Interface homme-machine [cs.HC]. Institut National Polytechnique de Grenoble -INPG
- [8] Patel, N., Nease, J., Aumi, S., Ewaschuk, C., Luo, J., Mhaskar, P. (2020) Integrating Data-Driven Modeling with First-Principles Knowledge. Industrial and Engineering Chemistry Research (11), 5103–5113
- [9] Gupta, T.K., et al.: (2015) Dimensionality reduction techniques and its applications. J.Comput. Sci. Syst. Biol.8(3), 170
- [10] Suri, S., Bailis, P. (2019). DROP: A workload-aware optimizer for dimensionality reduction. Proceedings of the ACM SIGMOD International Conference on Management of Data
- [11] Soleimani-Babakamali, M. H., Soleimani-Babakamali, R., Sarlo, R., Farghally, M. F.; Lourentzou, I. (2023). On the effectiveness of dimensionality reduction for unsupervised structural health monitoring anomaly detection. Mechanical Systems and Signal Processing
- [12] Hanachi, H., Yu, W., Kim, I. Y., Liu, J.; Mechefske, C. K. (2019). Hybrid data-driven physics-based model fusion framework for tool wear prediction. International Journal of Advanced Manufacturing Technology (9–12), 2861–2872.
- [13] De Bézenac, E., Pajot, A.; Gallinari, P. (n.d.). Deep learning for physical processes: incorporating prior scientific knowledge
- [14] Bhutani, N., Rangaiah, G. P.; Ray, A. K. (2006). First-principles, data-based, and hybrid modeling and optimization of an industrial hydrocracking unit. Industrial and Engineering Chemistry Research
- [15] D. Ryckelynck, F. Chinesta, E. Cueto, A. Ammar. (2005) On the a priori Model Reduction: Overview and Recent Developments. Meshfree Methods for Partial Differential Equations II, 43, Lecture Notes in Computational Science and Engineering
- [16] J.-L. Blanchard, F. Abid, G. Chevallier. (2014) A New Approach for the Identification of Reduced Thermal Models, Institute of Electrical and Electronics Engineers, THERMINIC : 20th International Workshop, Thermal Investigations of ICs and Systems : proceedings, Greenwich, London, UK