



Science Arts & Métiers (SAM)

is an open access repository that collects the work of Arts et Métiers Institute of Technology researchers and makes it freely available over the web where possible.

This is an author-deposited version published in: <https://sam.ensam.eu>
Handle ID: <http://hdl.handle.net/10985/23310>

To cite this version :

Morgane SUHAS, Emmanuelle ABISSET-CHAVANNE, Pierre-André REY, Frédéric DESCHAMPS, Stephane KRECKELBERGH, Nicolas REMY - Performance of hybrid modeling on a failure process in industrial systems - 2022

Any correspondence concerning this service should be sent to the repository

Administrator : scienceouverte@ensam.eu



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

SUHAS Morgane
AMValor, Laboratoire I2M
Bordeaux, France
morgane.suhas@ensam.eu

ABISSET-CHAVANNE Emmanuelle
Arts et Métiers, Laboratoire I2M
Bordeaux, France
emmanuelle.abisset-
chavanne@ensam.eu

REY Pierre-André
Arts et Métiers, Laboratoire I2M
Bordeaux, France
pierre-andre.rey@ensam.eu

DESCHAMPS Frédéric
LGM
Toulouse, FRANCE
frederic.deschamps@lgm.fr

KRECKELBERGH Stéphane
LGM
Tarnos, FRANCE
stephane.kreckelbergh@lgm.fr

REMY Nicolas
LGM
Paris, FRANCE
nicolas.remy@lgm.fr

Résumé — Une approche hybride est proposée pour établir le diagnostic d'un moteur électrique. L'approche se caractérise par un assemblage entre la modélisation physique du système réel et la mise en place d'un algorithme d'apprentissage automatique, en vue d'améliorer les performances de diagnostic.

Mots-clefs — Modèle hybride, apprentissage automatique, modèle basé sur la connaissance, processus de défaillance, calcul haute performance

Abstract— A hybrid approach is proposed to establish the diagnosis of an electric motor. The approach is characterized by a combination of physical modelling of the real system and the implementation of a machine learning algorithm, in order to improve the diagnostic performance.

Keywords — Hybrid Model, Machine Learning, Knowledge-based model, Failure process, High-performance computing

I. CONTEXTE ET PROBLEMATIQUE

Une défaillance non localisée sur un composant peut causer des dégâts irrémediables mais il peut également engendrer l'arrêt complet du système industriel s'il n'est pas décelé dans les temps. En effet, la première étape dans un processus de défaillance réside dans la détection du défaut. La localisation du défaut est la seconde étape du processus pour savoir à quel niveau du système il faut intervenir. De nombreuses méthodes permettant d'établir le diagnostic des

systèmes industriels ont déjà fait leurs preuves. Elles s'appuient principalement sur les lois de comportement basées sur la physique. Cependant, ces modèles de comportement sont génériques et présentent des difficultés d'adaptation lorsqu'ils sont appliqués sur des profils d'emploi particuliers. De plus, face à des systèmes complexes, la mise en place des lois de comportement modélisant le couplage des multiples composants, en interaction les uns avec les autres, est une tâche laborieuse et coûteuse en temps.

L'essor de l'instrumentation des systèmes industriels incite, en outre, à utiliser le potentiel des données récoltées en temps réel sur les systèmes. La problématique dans l'étude des données se trouve dans la transparence des modèles créés uniquement à partir de ces données. Le poids des interactions présentes entre les grandeurs du système n'est pas toujours identifiable. Cela signifie que les modèles développés à partir des données ne seront pas aisément transposables d'un système à un autre, en garantissant la même performance.

Pour améliorer cette adaptabilité, l'idée est de s'appuyer sur les connaissances du système en question et de les intégrer dans la modélisation. Pour cela, les modèles basés sur les lois de la physique et ceux basés sur l'apprentissage des données vont être couplés afin d'étudier la performance globale de ce type de modélisation. Dans la littérature, ce couplage est appelé modélisation hybride.

Pour comprendre le cheminement de construction d'un tel modèle, l'étude propose de se focaliser sur la

modélisation d'un moteur électrique à courant continu. Cette application très étudiée dans la littérature nous permet d'exploiter des modèles physiques du système déjà existant.

L'objectif de ce papier est donc d'étudier les performances de la modélisation hybride pour diagnostiquer les défaillances d'un moteur électrique à courant continu. Pour cela, le papier décrira la construction du modèle basé sur les données et celle du modèle théorique en évoquant les aptitudes et les limites de chacun des modèles. La mise en place d'une approche hybride sera ensuite détaillée. Enfin, les performances des modèles implémentés seront présentées.

II. PRESENTATION DU CAS TEST

A. Fonctionnement théorique

Le cas d'étude est un moteur électrique à courant continu et, plus précisément, un motoréducteur. Le moteur est composé de 2 parties séparées par un entrefer. La partie fixe, nommée le stator, constitue la source du champ magnétique et c'est pourquoi il est aussi nommé l'inducteur. La partie mobile est nommée le rotor ou l'induit. Les balais situés aux extrémités de l'arbre, conduisent l'électricité jusqu'au rotor via le collecteur qui reçoit l'électricité provenant des balais.

B. Principaux modes de défaillance

1) Présentation des éléments les plus critiques du moteur

Dans une machine électrique, la mécanique est la source de défauts la plus fréquente. L'usure des roulements est la principale cause de défaillance, comme présenté par Vaseghi [1]. C'est pour ces raisons que la modélisation des défauts de roulement s'est révélée être cruciale pour l'étude du diagnostic des défauts du moteur électrique. La défaillance au niveau du roulement peut intervenir de façon progressive ou, au contraire, de façon brutale. Lorsque le défaut est progressif, les signaux sont plus difficiles à détecter puisqu'il faut observer une dérive modérée des grandeurs surveillées.

Le bobinage du stator fait également partie des éléments critiques du moteur puisqu'il est sujet aux courts-circuits. Enfin, les engrenages inclus dans les réducteurs de vitesse sont à surveiller en raison de leurs défaillances mécaniques fréquentes. Pour la première phase méthodologique, ce papier prendra en compte seulement les défauts de roulement, progressifs et brutaux.




Figure 1 - Schéma d'un moteur à courant continu [8]

2) Impact sur le système

Un défaut mécanique causé par les roulements provoque une excentricité du roulement qui modifie le comportement du couple. Une instabilité du couple due à la friction plus importante engendre un déséquilibre de la tension et des courants du stator. Cette instabilité augmente les pertes. A terme, un échauffement du moteur se produit compromettant l'efficacité globale du système.

Les défaillances des engrenages résultent en grande partie de l'usure des dents des engrenages qui sont en contact permanent. L'usure peut débiter d'une simple piqûre et conduire à la fissuration de la dent.[5]



Figure 2 - Défaut de la bague intérieure d'un roulement à billes [9]

Un défaut électrique, tel que le court-circuit, peut aggraver l'état du système rapidement en accélérant le vieillissement des composants. Il affecte l'isolation des enroulements du bobinage et perturbe le fonctionnement du moteur.

C. Modélisation multi-physique du système réel

1) Modélisation théorique du moteur sans défaut

Dans l'objectif de diagnostiquer les défaillances par utilisation de modèles hybrides, la première étape est de concevoir un modèle basé sur la physique représentant le système réel.

Le développement et la modélisation d'un modèle physique peuvent être, coûteux en temps selon la finesse de représentation voulue et il est parfois très difficile d'y intégrer l'ensemble des phénomènes du système réel. Cependant, dans le cas du moteur à courant continu, les modèles fondés sur les lois de la physique, et, plus précisément les équations de fonctionnement du moteur, fournissent une haute précision et nécessitent peu de données.

Comme tout moteur, le moteur à courant continu (MCC) est régi par des équations physiques englobant les domaines électrique, mécanique et électromagnétique.

La modélisation physique est basée sur les équations de fonctionnement présentées ci-dessous.

$$u(t) = e(t) + Ri(t) + L \frac{di(t)}{dt} \quad (1)$$

$$e(t) = K_e \omega_m(t) \quad (2)$$

$$J \frac{d\omega_m(t)}{dt} = C_m(t) - C_r(t) - f \omega_m(t) \quad (3)$$

$$C_m(t) = K_m i(t) \quad (4)$$

$u(t)$ = tension appliquée aux bornes du moteur (V)

$e(t)$ = force électromotrice (V)

$i(t)$ = courant (A)

$C_m(t)$ = couple moteur (N.m)

$C_r(t)$ = couple résistant (N.m)

$\omega_m(t)$ = vitesse de rotation du moteur (rad/sec)

R = résistance de l'induit du moteur (Ω)

L = inductance de l'induit du moteur (H)

J = inertie du moteur (kg.m²)

f = coefficient de frottement (N.m.s)

K_m = constante du couple moteur (N.m/A)

K_e = constante de force électromotrice (V.sec/rad)

La modélisation du moteur électrique en mode sain servira de comparaison pour différencier le comportement nominal du système du comportement défaillant (voir partie III sur l'approche hybride). Les données caractéristiques du moteur sans défaut sont produites par le modèle théorique sain.

L'enjeu du modèle est d'obtenir des données de fonctionnement de notre système sain en ayant comme donnée de pilotage la vitesse de rotation. Une boucle d'asservissement de la vitesse de rotation (w_m) a été mise en place dans la modélisation afin de représenter au mieux le système réel. Afin de modéliser le bruit aléatoire et les erreurs de mesure présents dans les systèmes réels, les signaux d'entrée, représentés par des signaux sinusoïdaux, sont bruités.

Les modèles physiques retranscrits au travers des équations de fonctionnement du moteur sont modélisés via le logiciel MATLAB/Simulink (version R2020b).

Les données exportées du modèle sont le couple (Newton-mètre), le courant (Ampère), la vitesse de rotation (Radian par seconde) et la tension du moteur électrique (Volt).

2) Mode défaillant

Dans un premier temps, afin de comprendre et maîtriser l'impact des défauts sur le comportement du moteur, les défaillances vont être prises en compte via des modèles physiques de comportement. A terme, ce comportement défaillant sera pris en compte par des données réelles.

Les défauts de roulement apparaissant sur le moteur peuvent survenir de façon brusque ou, au contraire, de façon progressive. Physiquement, ils se manifestent par une élévation du couple résistant. D'après les équations de fonctionnement du moteur, l'élévation de couple cause une évolution des autres grandeurs temporelles associées au moteur. En particulier, la hausse du couple du moteur se répercute directement sur l'intensité. Pour maintenir la vitesse de rotation de consigne, dans le cas d'une augmentation du couple résistant, le couple moteur cherche à égaliser le couple résistant. Si le couple résistant devient trop important, l'augmentation de l'intensité qui en découle risque d'endommager le moteur, entre autres par effet joule.

Les défauts du roulement sont introduits dans le modèle idéal à l'aide du logiciel MATLAB/Simulink sous la forme d'un échelon pour le défaut brusque et sous la forme d'une rampe pour le défaut progressif. Le modèle idéal devient alors un modèle physique dégradé. Lors de la modélisation d'une perturbation brutale à un instant t , l'évolution des grandeurs temporelles se manifeste par un saut à cet instant. De façon contraire, l'injection modélisant le défaut naissant dans les roulements produit une dérive des grandeurs.

Pour produire une plus grande variabilité des données contenant des défauts, plusieurs paramètres peuvent être maîtrisés. En effet, de multiples défauts brutaux sont introduits dans le moteur en modifiant le temps d'apparition sur le système, la valeur ou encore la fréquence d'apparition. Quant au défaut d'usure, le temps d'apparition et la pente de la dérive peuvent être contrôlés.




Figure 3 - Modèle SIMULINK du moteur électrique

La vitesse de rotation est maintenue à sa consigne grâce à l'asservissement en vitesse de rotation. Ce sont les autres grandeurs qui vont compenser le défaut pour avoir en sortie la même vitesse de rotation qu'en entrée.

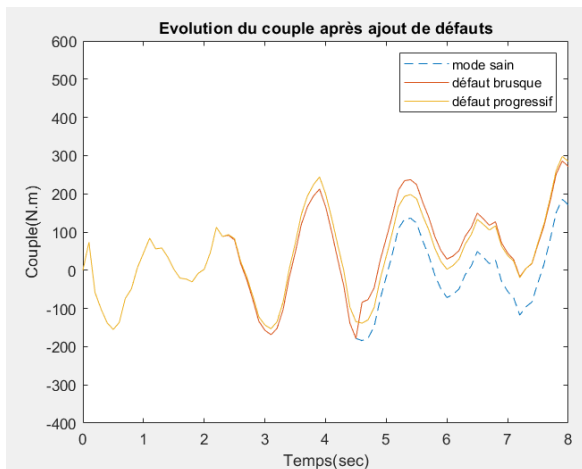


Figure 4 - Couple du moteur en mode sain et défaillant




Figure 5 - Courant du moteur en mode sain et défaillant




Figure 6 - Vitesse du moteur en mode sain et défaillant

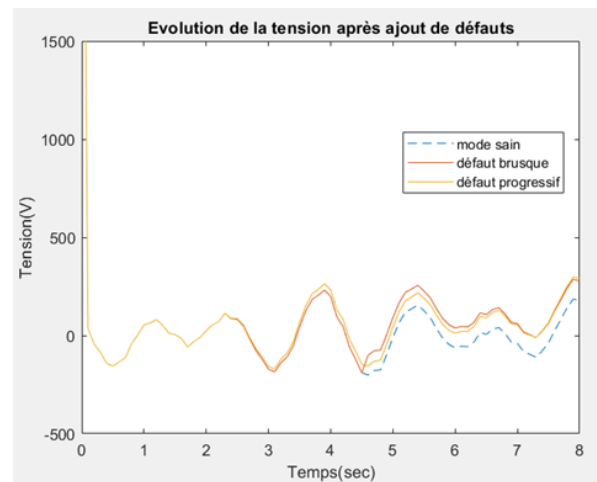


Figure 7 - Tension du moteur en mode sain et défaillant

L'objectif du travail consiste à développer une méthode performante permettant de détecter l'apparition des défauts et d'identifier ses caractéristiques.

III. APPROCHE HYBRIDE POUR LE DIAGNOSTIC DU MOTEUR ELECTRIQUE

A. Principe de la modélisation hybride

La modélisation hybride est la combinaison d'un modèle théorique (boîte blanche), permettant d'expliquer le comportement attendu par le système, à partir de modèles physiques, et d'un modèle d'intelligence artificielle (boîte noire), s'adaptant grâce à des données. Il s'agira de démontrer dans de futurs travaux que l'hybridation permet de modéliser des relations non évidentes et/ou même inconnues au sein du système ou encore d'améliorer l'efficacité du modèle dans sa globalité.

La modélisation hybride regroupe les avantages de la modélisation de la boîte blanche et de ceux de la boîte noire, d'après Estrada Flores et al [3]. Elle est pour cette raison communément dénommée « boîte grise ». Elle réduit les temps de modélisation du système réel tout en augmentant les performances.

Le modèle théorique, appelé « boîte blanche », englobe toutes les connaissances historiques du système en retranscrivant les processus du système. Il comprend notamment les lois de premiers principes, les modèles mécanistiques ou bien les modèles de comportement basés sur le retour d'expérience. Le modèle appelé « boîte noire », construit à partir de données d'entrée et de sortie, ne se base sur aucune loi fondamentale. Par exemple, il peut être sous la forme d'une régression linéaire ou d'un réseau neuronal. Le modèle hybride requiert des données d'entrée pour chacune des deux types de « boîtes ».

Plusieurs architectures de combinaison des deux différents modèles existent dans la littérature d'après Von Stosch et al [4]. Globalement, l'hybridation peut se réaliser soit en faisant interagir les modèles entre eux, soit en fusionnant les sorties des deux types de modèles (architecture

A de la figure 8 ci-dessous) ou bien en utilisant les sorties d'une première boîte pour les injecter dans la deuxième boîte (architectures B et C de la figure 8 ci-dessous).




Figure 8 - Configurations possibles pour le modèle hybride [10]

Lorsque les modèles interagissent entre eux, ils s'enrichissent mutuellement pour produire le résultat attendu. Cela signifie que ce n'est pas la réponse de chaque boîte qui sera prise en compte en sortie soit par une pondération ou un autre type de combinaison. La sortie du modèle hybride trouvera son origine dans la construction bilatérale des deux types de boîtes.

B. Méthode hybride appliquée

La modélisation hybride proposée dans ce papier est la méthode interactive entre les modèles boîte blanche et boîte noire. La boîte blanche est définie par la modélisation du système en comportement sain (décrite par les équations (1), (2), (3) et (4)). Pour construire le modèle d'intelligence artificielle, de type apprentissage profond, on s'intéresse aux résidus des données du système.

Dans notre cas, les résidus résultent de la soustraction des signaux temporels du système modélisé soumis à des défauts (considéré comme le comportement réel, et à terme représenté par des données expérimentales) et des signaux temporels du système en comportement sain. Ils représentent les perturbations du système, conduisant par la suite à des potentielles défaillances. La formation du modèle d'apprentissage profond se fonde alors sur l'étude de la différence entre les données du système sain et les données du système présentant des défauts. L'hybridation se retrouve donc dans l'interaction entre la modélisation du système en comportement nominal et les résidus. Le modèle hybride ainsi obtenu est en mesure d'identifier le défaut présent dans le système (classification) et pourra également être utilisé pour faire de la prédiction de comportement à venir (type maintenance prédictive).

C. Choix du modèle basé sur les données

Dans cette partie, nous allons développer une méthode de diagnostic exclusivement basé sur un modèle d'apprentissage afin de comparer ensuite ses performances avec celle d'un modèle hybride.

1) Performances et limites

Un réseau de neurones récurrents de type 'LSTM' (Long short-term memory) est développé pour l'étude des séries temporelles, afin de garder en mémoire le passé. Son atout est qu'il possède des connexions de rétroaction permettant de réguler le flux d'informations qu'il a en mémoire.

Un réseau de neurones est composé de plusieurs couches [7]. Dans ce cas précis, les données d'entrée arrivent à la couche d'entrée du réseau de neurones sous la forme de séries temporelles. Les données sont par la suite propagées dans la couche LSTM qui conserve uniquement les informations nécessaires qu'elle a déjà en mémoire. Trois couches sont ensuite ajoutées respectivement telle qu'une couche 'Fully connected', une couche 'Softmax' et une de classification. Les trois dernières couches sont ajoutées pour identifier les défauts en récupérant la probabilité la plus élevée pour chaque étiquette.

Avant de mettre en place la modélisation hybride, une première approche de classification des défauts sur le jeu de données complet est effectuée à l'aide du réseau de neurones. Le jeu de données complet contient une séquence pour chaque signal sinusoïdal d'entrée. Chaque séquence est constituée de cinq lignes correspondant aux cinq facteurs pris en compte en sortie du modèle physique. Comme le montre la figure 3, les cinq facteurs de l'algorithme d'apprentissage automatique sont le couple, le courant, la tension, la vitesse de rotation et la consigne de vitesse de rotation. Le nombre de colonnes, quant à lui, coïncide avec le pas de temps choisi, soit de 201 colonnes dans notre cas. Le jeu de données est donc une concaténation de séquences labellisées selon le type de défaut qu'elle présente. Les étiquettes possibles sont « défaut1 » pour le défaut brusque au sein du roulement, « défaut2 » pour le défaut progressif au sein du roulement et « sain » s'il n'y a pas de défaut. Les séquences sont réparties aléatoirement dans le jeu de données. Pour chaque itération, la classification des défauts est effectuée sur l'ensemble de la séquence.

Pour attester d'un développement optimal du réseau de neurones, la précision doit être maximisée, au contraire de la perte qui doit être minimisée. Toutefois, l'adaptation sur de nouvelles données est à prendre en compte également. Le développement passe donc par une optimisation des paramètres du réseau de neurones comme le nombre d'itérations ou le découpage en lots du jeu de données au cours de l'apprentissage. La perte d'un modèle représente l'écart entre les prédictions faites par le réseau de neurones et les sorties réelles des données d'apprentissage.

En phase d'apprentissage, le réseau neuronal développé met environ 3min pour apprendre sur le jeu de données complet. Il se rapproche d'une précision de 90% et d'une

perte de 0.4. Pour augmenter la précision du modèle, des itérations supplémentaires sont à prévoir. Elles entraînent alors une augmentation du temps de formation sans augmenter considérablement la précision du modèle.




Figure 9 - Matrice de confusion avant hybridation

D. Combinaison des deux approches

1) Méthode sélectionnée

La modélisation hybride du moteur électrique s’est principalement articulée autour de la modélisation du modèle théorique sain qui a permis de donner une idée de l’évolution des données en fonctionnement nominal. Ce modèle physique du moteur, après injection des défauts, a provoqué une variation des grandeurs temporelles. Ces écarts de valeurs entre les données du système sain et les données comportant des défauts, autrement dit les résidus, ont servi de données d’apprentissage pour le réseau neuronal LSTM.

On s’appuie sur les données du moteur sain pour créer un masque du fonctionnement normal du moteur électrique. Ce masque constitue la boîte blanche du modèle hybride. Quant aux résidus, ils forment la boîte noire du modèle hybride. En intégrant cette base de connaissances, le modèle hybride est capable de fournir en sortie les défauts présents dans le moteur électrique en fonctionnement. Cela implique de connaître le fonctionnement du moteur en mode sain et les résidus associés à chaque défaut existant au sein du moteur pour que la modélisation hybride s’adapte à tout nouveau défaut recensé.

Le modèle hybride, dans ce cas particulier, met en lumière les corrélations entre les grandeurs temporelles lors de l’apparition d’un défaut. Il permet de détecter comment les grandeurs observées évoluent simultanément en période de défaillance.

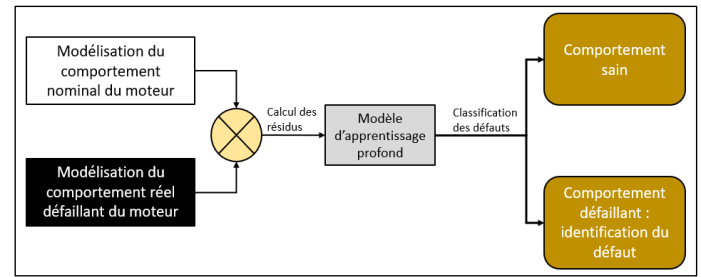


Figure 10 - Méthode d'hybridation mise en place

2) Performances

a) Performances du modèle hybride implémenté

On réitère le processus de formation du réseau neuronal identique en lui fournissant non plus le jeu de données complet mais seulement les résidus. On obtient une précision de 100% avant la fin de l’apprentissage. En effet, le processus est arrêté manuellement au bout de 1min30. On constate que pour une même quantité de données, la modélisation hybride se révèle être plus performante et plus stable sur le long terme qu’un simple réseau neuronal. Cela provient en partie du fait que l’analyse portée sur les résidus ne prend pas en compte les évolutions des grandeurs dues aux bruits aléatoires et aux erreurs de mesure. Le résidu met davantage en lumière l’écart de valeur sur une même variable en comportement sain et défaillant. Cela évite de porter une attention sur l’amplitude de la variable en mode sain.




Figure 11 - Matrice de confusion après hybridation

b) Comparaison des méthodes avec et sans hybridation

Réseau LSTM sans hybridation				Réseau LSTM avec hybridation			
Itération	Temps écoulé (hh:mm:ss)	Perte du mini-lot	Précision du mini-lot	Itération	Temps écoulé (hh:mm:ss)	Perte du mini-lot	Précision du mini-lot
1	00:00:04	1.1528	33.03%	1	00:00:03	1.1245	31.60%
50	00:01:15	0.6385	73.30%	50	00:00:45	0.0180	99.98%
100	00:02:21	0.4204	85.61%	100	00:01:29	0.0002	100.00%
150	00:02:47	0.3516	89.76%	150	00:02:13	6.6060e-05	100.00%

Figure 12 - Performances et temps de formation des 2 approches présentées

Avec la modélisation hybride, le modèle construit atteint rapidement sa précision maximale pendant la période d'apprentissage. Quant à la perte, elle devient minimale. On pourrait croire qu'on se retrouve dans le cas du surajustement mais la figure 11 montre que le modèle hybride parvient à bien généraliser sur de nouvelles données. Les pertes indiquées sont les pertes du mini-lot évalué au moment de l'itération. La fonction de perte employée est celle de l'entropie croisée.

IV. DISCUSSION ET PERSPECTIVES

L'approche proposée est une solution économique et rentable du point de vue de son développement. Le type de modèle proposé nécessite avant tout d'avoir accès aux données réelles du système. Il s'enrichit au cours du temps, au fur et à mesure que les données sont relevées, en raison de son apprentissage basé sur la mémoire à court long terme. Ainsi, l'un des principaux résultats annoncés est la rapidité de construction du modèle hybride, du moment que les connaissances du système soient accessibles et/ou implémentées. Néanmoins, une réflexion se porte sur la technique de l'hybridation des modèles et sur le paramétrage du modèle basé sur les données. L'approche pourrait donc être d'autant plus efficace si elle s'accompagne de critères de performances directement liés au cas d'usage. Le moteur, étant un composant largement répandu dans les systèmes industriels, le modèle hybride ainsi développé trouvera, à terme, une application partielle dans plusieurs domaines industriels.

Une perspective de raffinement du modèle est en cours pour modéliser la dérive de défauts présents sur les autres éléments critiques du moteur ainsi que pour ajouter d'autres grandeurs à surveiller. Effectivement, en se limitant à certains défauts et certaines grandeurs, la localisation du défaut sur les composants du moteur s'avère être moins précise.

Dans ce papier, le travail principal a été de diagnostiquer deux différents types de défauts du roulement du moteur. Autrement dit, le modèle impliquait de localiser un défaut qui s'était déjà produit sur le moteur, en caractérisant le défaut. Par la suite, le modèle devra tendre à prévoir l'apparition d'une défaillance avant qu'elle ne se produise dans le système en détectant des signes précurseurs.

REFERENCES

- [1] B. Vaseghi, « Contribution a l'etude des machines electriques en presence de defaut entre-spires Modélisation – Réduction du courant de défaut », 2014
- [2] S. Yang, P. Navarathna, S. Ghosh, W. Bequette, « Hybrid Modeling in the Era of Smart Manufacturing », in Computers and Chemical Engineering, vol. 140, 2020
- [3] S. Estrada-Flores, I. Merts, B. De Ketelaere, J. Lammertyn, « Development and validation of “grey-box” models for refrigeration applications: a review of key concepts », International Journal of Refrigeration, vol. 29, 2006

- [4] M. von Stosch, R. Oliveira, J. Peres, S. Feye de Azevedo, « Hybrid semi-parametric modeling in process systems engineering: Past, present and future », Computers & Chemical Engineering, 2014, 86-101, 60
- [5] B. Raison, Détection et localisation de défaillances sur un entraînement électrique, 2020
- [6] H. Nahim, Contribution à la modélisation et à la prédiction de défaillances sur les moteurs Diesel marins, 2017, p.140
- [7] M. Msaaf, F. Belmajdoub, “L'application des réseaux de neurones de type « feed forward » dans le diagnostic statique”, 2015
- [8] TIR, Zouheir. « Modélisation et simulation de la machine à courant continu » Mémoire magister en électrotechnique, 2008
- [9] M. Heydarzadeh, M. Nourani, V. Azimi, Amir Kashani-Pour, Vibration-Based Bearing Fault Diagnosis Using Reflection Coefficients of the Autoregressive Model, 2018
- [10] M. von Stosch, R. Oliveira, J. Peresa, S. Feye de Azevedo, « Hybrid semi-parametric modeling in process systems engineering : Past, present and future », Computers and Chemical Engineering 60 (2014) 86–101, 2013