

Application de la méthode des réseaux de neurones pour la prédiction des vibrations induites par des défauts combinés (désalignement et balourd)

Younes DEBBAH, Abdelhakim CHERFIA, Abdelhafid SAADI.

Laboratoire de Mécanique, Département de Génie mécanique, Faculté des Sciences de la Technologie. Université Frères Mentouri – Constantine 1. Campus Chaab Ersas, 25000 Constantine, Algérie younes_debbah@yahoo.fr, cherfia_abdelhakim@yahoo.fr, mahfoud54@gmail.com.

Résumé - Cet article présente l'application de la méthode des réseaux de neurones pour la prédiction du comportement vibratoire d'un système mécanique. Nous excitons le système expérimental par un défaut combiné (désalignement - balourd) et nous recueillons le RMS comme valeur caractéristique pertinente pour l'état du système. le sous-ensemble de caractéristiques obtenu est ainsi injecté dans le réseau de neurone. ce dernier peut être fondé sur un processus de détection permettant une modélisation pour déterminer l'état courant du système. nous utilisons ces données mesurées pour l'apprentissage et la vérification de la performance du réseau de neurone. la procédure sera faite en trois étapes, la phase de mesure, ensuite la phase d'apprentissage et enfin la phase de prédiction

La prédiction par le réseau de neurone est comparée avec une mesure expérimentale. Les résultats sont satisfaisants et encourageants.

Mots Clés : Maintenance prédictive, Pronostic, Réseaux de neurones, Intelligence artificielle.

Nomenclature

<i>rms</i>	écart quadratique par rapport à une moyenne, <i>g</i>	<i>adp</i>	anomalies, diagnostic et pronostic
<i>rmse</i>	<i>erreur quadratique moyenne, g</i>	<i>rul</i>	temps de vie restant d'un système
<i>rmsd</i>	<i>écart quadratique moyen, g</i>	<i>x1,x2,xn</i>	<i>signal d'entrée : balourd, désalignement...,g,mm,...</i>
<i>X_{obs}</i>	<i>valeur rms observée, g</i>	<i>w1,w2,wn</i>	pois synaptiques
<i>X_{model}</i>	<i>valeur rms modélisée, g</i>	<i>y</i>	valeur de la réponse à la sort
<i>pdm</i>	maintenance prédictive		

1. Introduction

Les méthodes de maintenance ont souvent recours à une information basée sur l'expérience pour prédire les performances futures. Elles sont formalisées en une discipline systématique qui se base sur une évaluation technique complète des événements survenus pendant les phases expérimentales ou d'exploitation. Les méthodes de maintenance apportent, à la conception de produit, des méthodes et des informations qui permettent de faire mieux qu'avant et surtout, de prévoir le comportement futur d'un matériel nouveau. Les résultats de ces études peuvent être qualitatifs, pour connaître les composants critiques et les pannes indésirables ou quantitatifs, pour estimer les probabilités de défaillance et les durées d'indisponibilité associées. La maintenance des

matériels, qu'elle soit définie par le constructeur, l'exploitant ou les deux, est un facteur prépondérant dans la qualité des matériels et la détermination des coûts d'exploitation [1].

Le développement des nouvelles techniques et méthodologies expérimentales donne la possibilité d'aller toujours plus loin dans l'étude de l'architecture neuronale. Ainsi, des modèles toujours plus élaborés sont proposés pour comprendre les mécanismes fondamentaux de la dynamique neuronale d'une part, et pour proposer de nouvelles expériences ou applications d'autre part. En parallèle avec cette évolution il y a un besoin de développer des méthodes mathématiques d'analyse ou d'améliorer les méthodes existantes [2].

L'objectif du diagnostic est la détection et l'identification de l'état ou mode opérationnel d'un système dans l'instant actuel. La surveillance d'un système consiste à diagnostiquer ses états et modes défaillants. Pourtant, dans de situations critiques on pourrait raisonner que la prédiction des défaillances est même plus souhaitable que le diagnostic des défaillances. Le pronostic, est la prédiction des possibles états futurs dans lesquels un système peut évoluer.

Alors, une fois les états futurs identifiés, le pronostic nous permettrait aussi d'estimer le temps de vie restant d'un système à partir de son état actuel jusqu'à un état défaillant. Dans le domaine de la fiabilité, le temps de vie restant d'un système est appelé RUL, d'après l'anglais Remaining Useful Life. Cette approche permet d'aborder le problème de la maintenance adaptative ou prédictive de systèmes et composants dans le but de réduire les couts directs de maintenance ainsi que d'augmenter la sécurité de systèmes dans le cas de pannes subites ou brusques.

Certains auteurs ont groupé les approches basées sur cette coopération entre méthodes de diagnostic et de pronostic sous le nom technologies de ADP (anomalies, diagnostic et pronostic). Ainsi, le but du diagnostic ne devient pas seulement la détection de défaillances mais aussi fournir information sur l'état actuel et l'historique du système pour le pronostic, qui à son tour a comme but la maintenance prédictive (PdM) [3].

Le pronostic est généralement efficace pour les modes de défaillance résultant d'un processus de dégradation progressive, le plus simple étant linéaire. Une défaillance doit donc être définie en termes de paramètres ou de descripteurs surveillés. Cela suppose évidemment que la situation courante peut être saisie. Par ailleurs, le concept même de défaillance implique que le pronostic doit être associé à un degré d'acceptabilité (un système doit exécuter une fonction exigée). Le pronostic devrait donc être fondé sur les critères d'évaluation, dont les limites dépendent du système lui-même et d'objectifs de performance. Tout cela nous conduit à retenir la définition proposée par la norme ISO 13381 (2004) : « Le pronostic est l'estimation de la durée de fonctionnement avant défaillance et du risque d'existence ou d'apparition ultérieure d'un ou de plusieurs modes de défaillance ».

La classification des approches de pronostic n'est pas une fin en soi, nous distinguons alors:–

- Les approches fondées sur un modèle physique ;
- Les approches guidées par les données de surveillance ;
- Les approches fondées sur l'expérience, c'est-à-dire les approches fiabilistes [4].

Pour les approches basées sur le traitement de données, les seules informations disponibles sont les signaux issus des capteurs positionnés sur le système. Les capteurs sont supposés fiables et leurs valeurs correctes. L'objectif de ces méthodes est d'associer un ensemble de mesures à des états de fonctionnement connus du système. Ces approches à base de données font appel à des méthodes de reconnaissance de formes qui utilisent des techniques d'apprentissage numérique et de classification

afin d'établir un modèle de référence du système fondé sur l'expérience (exploitation des données, des mesures sous la forme d'historique).

Les principales techniques de classification utilisées pour construire un tel modèle sont les réseaux de neurones.

Les réseaux de neurones artificiels constituent l'une des approches d'intelligence artificielle dont le développement se fait à travers les méthodes par lesquelles l'homme essaye toujours d'imiter la nature et de reproduire des modes de raisonnement et de comportement qui lui sont propres [5].

I.2 Neurone et le réseau de neurones

La figure 1 montre un schéma comportant la structure générale d'un neurone artificiel.




Fig. 1 .Neurone artificiel

Un neurone artificiel est considéré comme un élément élémentaire de traitement de l'information, Il reçoit les entrées et produit un résultat à la sortie.

2. Procédure expérimentale

2.1. Dispositif expérimental

Le banc d'essai "DADP" (Détection, Analyse, Diagnostic et Prédiction), que nous avons réalisé au niveau de notre laboratoire de mécanique, est composé d'un bâti sur lequel sont montés les supports de paliers et les dispositifs expérimentaux qui sont l'objet de cette étude (Figure 2).

L'acquisition des signaux vibratoires est effectuée à l'aide d'un appareil de mesure vibratoire Movilog2 à un seul canal et par l'utilisation d'un accéléromètre piézoélectrique aimanté fixé sur un palier (figure 3). Le système d'acquisition utilisé (Figure 4) comprend : Un PC, un Module d'acquisition Divadiag et un appareil de mesure vibratoire Movilog2.




Figure. 2. Le banc d'essai « DADP »



Figure. 3. Position de l'accéléromètre




Figure. 4. Le système d'acquisition

piézoélectrique sur le palier vibratoire

2.2. Méthode expérimentale

La procédure expérimentale est réalisée en créant deux défauts combinés, et nous allons suivre l'évolution du facteur RMS (g) du système pour pouvoir prédire le comportement vibratoire futur de notre système.

Le balourd est créé en montant une masse excentrée par rapport à l'axe de rotation du système. Ce balourd est disposé au niveau du disque (Figure4).


Le désalignement du groupe moteur- paliers- disque est créé en intercallant au niveau des paliers une cale de dimensions égale à 0,2mm (Figure5).



Figure.4. Position du balourd



Figure.5. Position des cales pour le mauvais alignement



Le comportement du dispositif est analysé pour une vitesse de rotation 2200 tr/min, obtenues à l'aide d'un variateur de vitesse contrôlant le moteur. Nous prenons comme mesure la valeur efficace de l'accélération RMS.

3. Resultats

À partir des signaux issus des capteurs, une batterie d'algorithmes de traitement du signal permet d'obtenir un nouvel ensemble de signaux appelés « caractéristiques pertinentes de la dégradation du système ». En particulier, la transformée de Fourier est appliquée sur le signal vibratoire fourni par l'accéléromètre afin d'identifier les caractéristiques vibratoires, telles que le RMS (écart quadratique par rapport à une moyenne).

La valeur efficace ou valeur RMS (Root Mean Square) est un indicateur scalaire, très caractéristique du signal, vu qu'il a une relation directe avec l'énergie contenue dans celui-ci. Bien qu'il présente des inconvénients, car il ne détecte pas tous les défauts, son efficacité dépend de son bon paramétrage en terme de bandes de fréquences d'analyse liées à la structure même des machines.

$$V_{efficace} = V_{RMS} = \sqrt{\frac{\sum_{n=1}^{Ne} (x(n))^2}{Ne}} \quad (1)$$

L'extraction de caractéristiques pertinentes permet de réduire la taille des signaux issus des capteurs et réduire la dimension des données.




Figure 6: evolution de la valeur rms mesurée en fonction du temps

Le sous-ensemble de caractéristiques obtenu est ainsi injecté dans le réseau de neurone. Ce dernier peut être fondé sur un processus de détection permettant une modélisation pour déterminer l'état courant du système. Nous utilisons ces données mesurées pour l'apprentissage et la vérification de la performance du réseau de neurone.

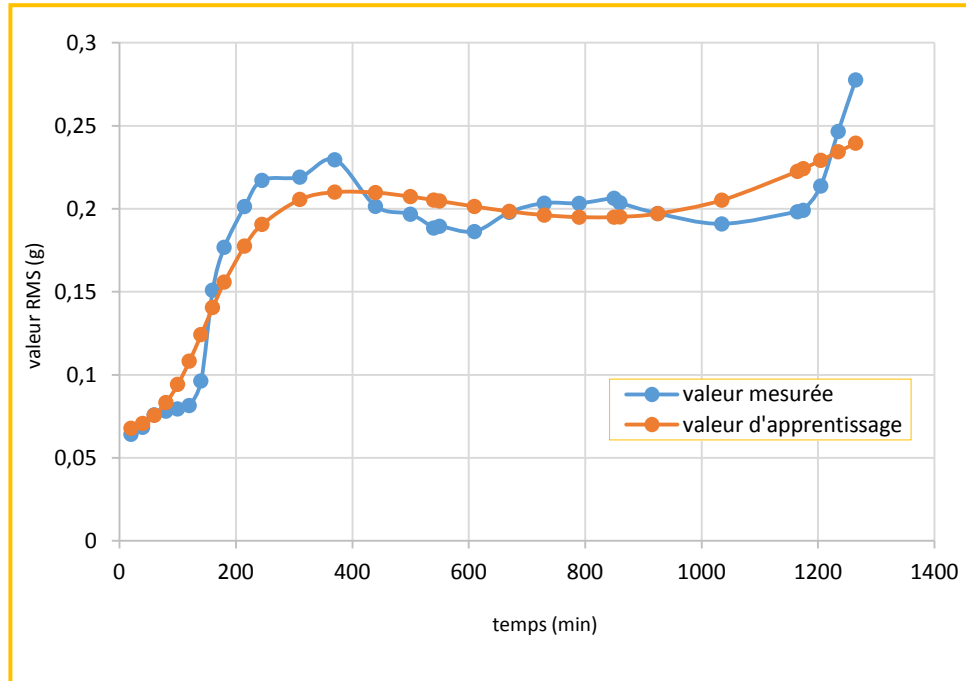


Figure 7 : comparaison entre la courbe de la valeur rms mesurée et la courbe d'apprentissage du réseau de neurone

Après l'étape d'apprentissage, nous avons simulé une prédiction de 10 pas en avant sur le même système et pour les mêmes défauts, nous avons obtenu la courbe suivante :

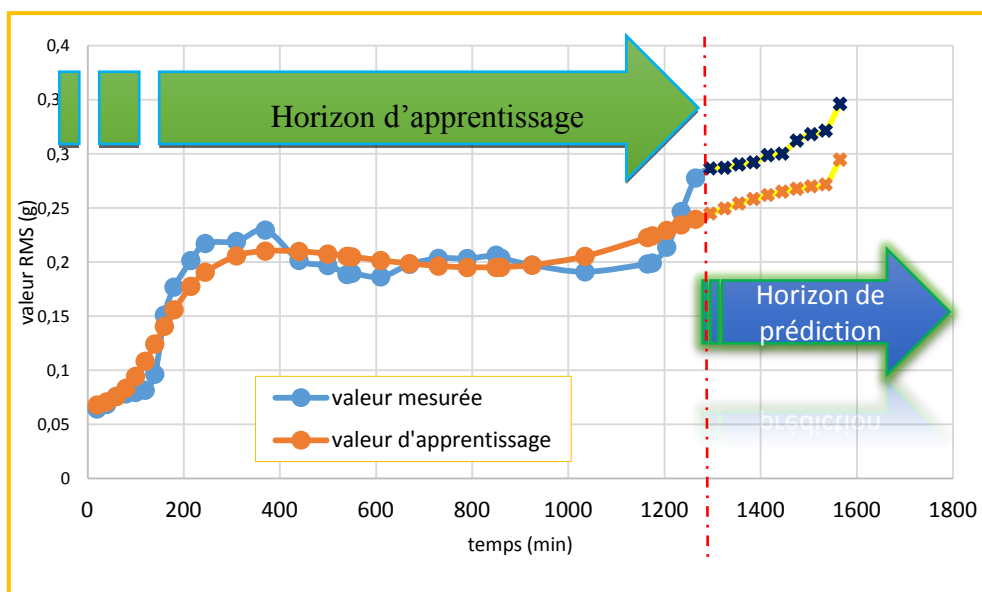


Figure 8 : Prédiction 10 pas en avant sur le même système

4. Discussion

Dans la figure 6, nous remarquons que la valeur rms augmente en fonction du temps ce qui confirme la pertinence de la valeur rms pour estimer la dégradation du système.

La figure 7 représente deux courbes pour le même système mécanique. La première est celle de la valeur rms mesurée (en bleu) et la deuxième est celle de la valeur rms d'apprentissage (en orange). Pour bien estimer la performance d'apprentissage du réseau de neurone nous calculons la valeur rmse qui est l'erreur quadratique moyenne (également appelée écart quadratique moyen, rmsd), qui est la différence entre les valeurs prédites par le modèle et les valeurs réellement observées dans l'environnement qui est en cours de modélisation. Ces différences individuelles sont aussi appelées résidus, et l'erreur quadratique moyenne sert à les agréger en une seule mesure de la puissance prédictive.

L'erreur quadratique moyenne d'une prédiction du modèle par rapport à la x_{model} variable estimée est définie comme la racine carrée de l'erreur quadratique moyenne:

X_{obs} ou on observe des valeurs et x_{model} est modélisé valeurs au moment / lieu i .

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{\text{obs},i} - X_{\text{model},i})^2}{n}} \quad (2)$$

La figure 8 illustre la prédiction du RMS à 10 pas en avant à partir du dernier instant d'apprentissage. Les variations dans les prédictions proviennent de l'adaptation du système au fil des acquisitions.

Nous remarquons que la variation entre les deux courbes est faible dans l'horizon d'apprentissage, par contre, les plus fortes variations apparaissent dans la zone de prédiction.

La prédiction est lissée contrastant avec celles mesurées après 10 unités de temps correspondant à une dégradation marquée du système. La défaillance devient imminente lorsque la prédiction atteint le dixième pas en avant.

En calculant la valeur RMSE qui est égale à **(0,01696)** pour l'horizon d'apprentissage et celle de l'horizon de prédiction qui est égale à **(0,042006)**, nous constatons que le réseau de neurone est très fort pour l'apprentissage avec un certain nombre de données et un certain nombre de neurones, tandis que pour la phase de prédiction, la valeur de RMSE nous a permis d'estimer que la prédiction est faible avec les données utilisées.

5. Conclusion

Les réseaux de neurones artificiels possèdent une propriété fondamentale qui justifie l'intérêt croissant qui leur est accordé et qui sont capables d'intervenir dans des domaines très divers, et qui les distinguent des techniques classiques de traitement des données.

Compte tenu de la complexité de la relation entre les entrées et les sorties, les résultats obtenus sont très encourageants et satisfaisants et nous conduisent à comprendre qu'une bonne prédiction nécessite l'utilisation d'un nombre optimal de neurones dans la couche cachée ainsi qu'un nombre suffisant de données.

Le réseau neuronal peut apprendre de nouveaux modèles qui ne sont pas disponibles auparavant sur les ensembles de données de formation, et comme il peut mettre à jour les connaissances au fil du temps, il aboutit à un plus grand degré de tolérance de précision, que d'autres techniques d'analyse. Par conséquent, la technique se révèle être plus facile et économique par rapport à des travaux expérimentaux coûteux et peut être utilisée avec succès en tant que substitut pour cela. Ainsi, le système peut être interrogé sur les valeurs futures prises à un horizon donné.

Références

1. Marc THOMAS, Fiabilité, maintenance prédictive et vibrations des machines, presses de l'université du Québec (2012).
2. R. Keith Mobley, ANINTRODUCTION TO PREDICTIVEMAINTENANCE, Second Edition, Butterworth-Heinemann, imprint of Elsevier Science (USA).2002.
3. Younes Debbah « Techniques de pronostic en maintenance prédictive » mémoire de fin d'étude. Juillet 2010.
4. Rafael GOURIVEA, Kamal MEDJAHHER, Emmanuel RAMASSO, PHM - Prognostics and health management - De la surveillance au pronostic de défaillances de systèmes complexes, Techniques de l'ingénieur (2013).
5. MERZOUKA NOURESSADAT Etude des performances des réseaux de neurones dynamiques à représenter des systèmes réels : une approche dans l'espace d'état. thèse de doctorat.2009.