

Discrimination des défauts de roulements par une analyse spectrale globale

Jinane HARMOUCHE^(1,2), Demba DIALLO⁽¹⁾, Claude DELPHA⁽²⁾

¹Laboratoire de Génie Electrique de Paris (LGEP), CNRS – Supélec – Univ. P. et M. Curie – Univ. Paris-Sud

²Laboratoire des Signaux et Systèmes (L2S), CNRS – Supélec – Univ. Paris-Sud

RÉSUMÉ – Ce papier traite de la détection et du diagnostic de défauts mécaniques et plus particulièrement ceux que l'on retrouve dans les roulements à billes pouvant équiper une machine électrique. Généralement les défauts dans les roulements sont diagnostiqués grâce à la recherche des fréquences caractéristiques associées aux éléments constitutifs du roulement. Ces fréquences sont supposées connues a priori ou estimées. Ce papier propose de faire la discrimination entre les défauts de roulements en fonction de la localisation et la sévérité du défaut, tout en s'affranchissant de la connaissance a priori des fréquences caractéristiques. La méthode repose sur l'extraction des paramètres fréquentiels représentatifs de la signature fréquentielle globale des défauts afin de faire la classification. Pour notre approche, l'analyse des résultats expérimentaux montre que l'Analyse en Composantes Principales appliquée sur ces paramètres permet de discriminer avec précision les différents types de défauts. L'Analyse Discriminante Linéaire est ensuite proposée afin d'améliorer la qualité de la discrimination entre des défauts de billes de sévérité différente.

Mots-clés – Diagnostic, Détection, Défauts de roulements, Traitement du signal, Analyse en Composantes Principales, Analyse Discriminante Linéaire

1. INTRODUCTION

Les défauts dans les roulements à billes sont l'une des raisons principales des défaillances des entraînements électriques et la réduction de leur durée de vie. L'analyse et le traitement des grandeurs mesurables dans le système électrique, notamment des vibrations et des courants statoriques, a pris une place prépondérante dans les approches de détection et diagnostic de défauts des roulements [1-4]. L'analyse des signaux vibratoires temporels permet de détecter la présence du défaut à partir des indicateurs scalaires. L'analyse fréquentielle permet d'identifier l'élément défaillant du roulement à partir des fréquences caractéristiques générées par le défaut [5, 6]. En effet, quatre fréquences caractéristiques sont générées par le roulement défaillant en fonction de la localisation du défaut, à savoir sur l'une des bagues, sur les billes ou la cage [7]. Ces fréquences peuvent être fournies par le constructeur ou estimées analytiquement à partir des considérations cinématiques. Cependant, elles ne sont connues que pour un roulement neuf géométriquement parfait et pour une vitesse de rotation donnée de la machine. Du à certains facteurs comme le vieillissement des roulements et les fluctuations de la vitesse de rotation de la machine, les fréquences caractéristiques actuelles peuvent dévier de celles théoriquement estimées [8]. De plus, la présence des fréquences caractéristiques dépend de plusieurs facteurs autres que le défaut lui-même telle que la répartition de la charge. Parfois, le défaut peut aussi persister sans générer la fréquence caractéristique associée. Pour cela, il s'avère raisonnable d'opter pour une approche de diagnostic qui ne nécessite pas la connaissance ou l'estimation a priori des fréquences caractéristiques.

Beaucoup de travaux ont été consacrés à l'exploitation des approches de diagnostic basées sur l'apprentissage automatique des symptômes associés aux défaillances et aboutissant à la classification des défauts de roulements [9, 10]. Pour ces approches, le choix et la sélection de grandeurs caractéristiques ayant une capacité discriminatoire importante facilitant l'analyse sont exigés et leur obtention n'est jamais triviale : Bien souvent, ils font appel aux techniques sophistiquées [11-14] (temps-échelle, temps-fréquence, ...) de traitement du signal qui parfois impliquent une complexité et des coûts calculatoires élevés.

Dans ce papier nous proposons une approche de discrimination entre les défauts de roulements, en fonction de la localisation et du niveau de sévérité du défaut, qui s'affranchit de la connaissance des fréquences caractéristiques et permet de faire la classification sans recours à des classificateurs complexes, tels que les réseaux de neurones et les Séparateurs Vastes Marges. L'approche s'appuie sur l'extraction des grandeurs caractéristiques fréquentielles à partir du spectre de l'enveloppe des signaux vibratoires de façon à effectuer la classification des défauts. Ces grandeurs caractéristiques représentent l'ensemble de la signature fréquentielle globale associée aux défauts, incluant les fréquences caractéristiques, leurs harmoniques multiples et leurs modulations par d'autres fréquences telles que la fréquence de rotation et celle de la cage.

2. DESCRIPTION DE LA MÉTHODE

La méthode combine l'analyse d'enveloppe basée sur la Transformation d'Hilbert [15, 16], la Transformée de Fourier Rapide (FFT) appliquée sur une fenêtre glissante le long du signal d'enveloppe et l'Analyse en Composantes Principales (ACP) utilisée pour la réduction de dimension de l'espace des caractéristiques choisies. Le vecteur des grandeurs caractéristiques est constitué des amplitudes des raies spectrales dominantes, qui sont extraites des spectres des signaux d'enveloppe des vibrations. Ce vecteur est obtenu grâce à la méthodologie suivante, illustrée par le schéma de la Figure 1 :

1. Création de l'espace de mesures (historique de données) : il comprend des signaux de vibrations correspondants aux données pour des roulements sains, des roulements défaillants, pour tous les cas de défauts considérés dans la classification. L'espace peut inclure un ou plusieurs points de fonctionnement de la machine.
2. L'analyse d'enveloppe : consiste à démoduler les signaux de vibrations autour des fréquences de résonance (modes propres) de la structure mécanique, et appliquer la FFT sur le signal temporel obtenu. Un filtrage passe-bande appliqué dans la région des fréquences de résonance et suivi de la Transformation d'Hilbert permet d'obtenir le signal d'enveloppe démodulé [17].

- La sélection des fréquences spécifiques dominantes : consiste à retenir des spectres des signaux d'enveloppe toutes les fréquences dominantes par rapport à chaque spectre, et ensuite exclure les fréquences communes parmi les fréquences retenues. Cela permet de ne garder que les fréquences dominantes spécifiques pour chaque spectre.
- Le Fenêtrage et FFT : une fenêtre temporelle est appliquée sur les signaux d'enveloppe et la FFT est recalculée sur cette fenêtre pour en retenir l'amplitude des raies spectrales déjà sélectionnées. Le vecteur de paramètres est ainsi formé par ces amplitudes.

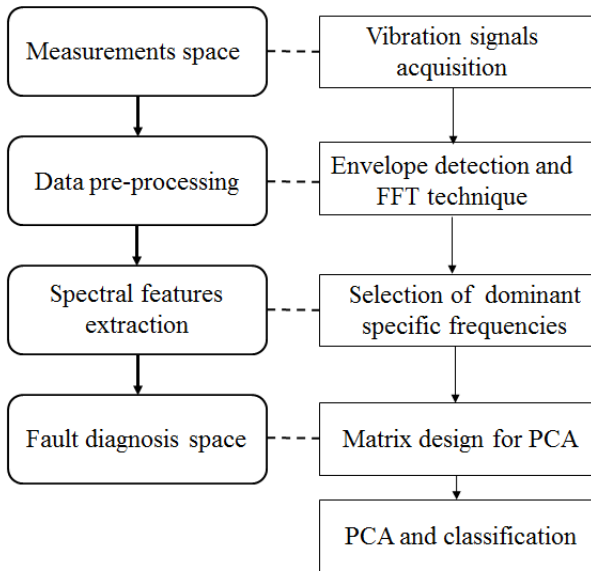


Fig. 1. Description de la méthodologie

La matrice d'information spectrale est formée par les fréquences spécifiques dominantes considérées comme variables descriptives. Chaque vecteur ligne de la matrice correspond à un échantillon/vecteur de paramètres, calculé pour une position de la fenêtre temporelle. La fenêtre glisse le long des signaux d'enveloppe afin d'enrichir la matrice avec un nombre important d'échantillons représentatifs de la localisation et la taille de chaque défaut.

L'analyse en Composantes Principales (ACP) est ensuite appliquée sur cette matrice d'information spectrale afin de réduire la dimension de l'espace des variables. L'espace de classification correspond ainsi au sous-espace principal. Les composantes principales (CPs) définissant le sous-espace principal sont les nouvelles grandeurs caractéristiques discriminatoires. Il s'agit enfin de projeter la matrice dans le sous-espace principal et reconnaître la classe associée à chaque cas de défaut (localisation et taille). On s'attend à ce que la classification obtenue soit indépendante du point de fonctionnement de la machine.

3. ANALYSE DISCRIMINANTE LINÉAIRE ET ACP

L'ACP et l'Analyse Discriminante Linéaire (ADL) sont des méthodes grâce auxquelles on peut obtenir une réduction de dimension de l'espace des grandeurs caractéristiques à l'aide de transformations linéaires [18, 19]. L'ACP effectue la réduction de dimension en essayant de garder dans le sous-espace principal la même variance que dans l'espace initial. L'ADL effectue la réduction de dimension tout en préservant toute l'information discriminatoire dans des classes qui sont préalablement

définies. En d'autres termes, en projetant les données dans un espace de dimension plus petite, l'ACP cherche à minimiser les distances dans l'ensemble des données ; tandis que l'ADL cherche à discriminer le mieux possible les données réparties dans des classes prédéfinies. Au sens de Fisher, l'objectif de l'ADL revient à maximiser la distance entre les classes (distance inter-classes) et minimiser les distances entre les données d'une même classe (distance intra-classe).

Dans ce travail, nous nous proposons d'utiliser l'ADL pour améliorer le résultat de la discrimination obtenu avec l'ACP entre différentes tailles de défauts de billes. L'ensemble de données traité par l'ADL est formé par les échantillons/vecteurs de paramètres calculés suivant la démarche décrite dans la section 2, mais ne correspondant qu'aux roulements sains et aux roulements présentant des défauts de billes avec plusieurs sévérités. La matrice de données concernée par l'application de l'ADL est ainsi formée comme le montre le schéma de la Figure 2.

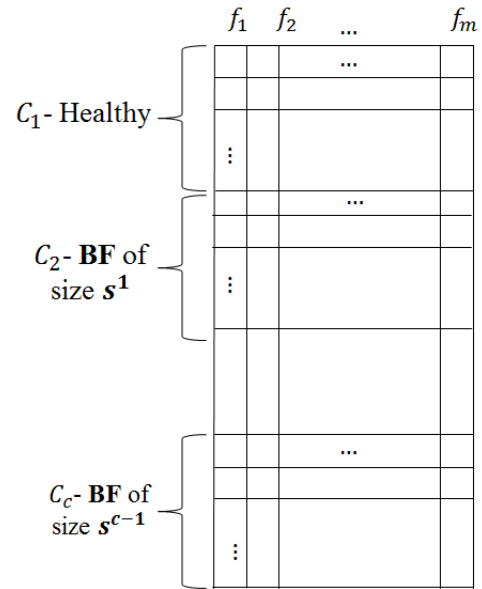


Fig. 2. Matrice de données pour application de l'ADL

Notons que le cas des défauts de billes de roulements est le moins traité dans la littérature en comparaison avec les défauts de bague externe et bague interne. En effet, la signature fréquentielle des défauts de billes est souvent très faible et noyée dans le bruit, ce qui complexifie leur identification. Pour cela, l'extraction de la fréquence caractéristique associée aux défauts de billes fait souvent appel à des techniques de traitement du signal relativement complexes et sophistiquées.

4. RÉSULTATS EXPÉRIMENTAUX

Des signaux de vibrations (accélération) sont obtenus en exploitant les données mises à disposition sur le site du Case Western Reserve University (CWRU, Bearing Data Center) [20]. Les signaux sont mesurés, à une fréquence d'échantillonnage $F_e = 12$ kHz durant 10 sec, sur un moteur électrique de 1.5 kW couplé à une charge qui détermine sa vitesse. Les mesures sont répétées pour trois points de fonctionnement de la machine : à vide, à 50% et à 100% de sa charge nominale. Des défauts de bague interne, bague externe et défauts de billes sont introduits dans les roulements par électro-érosion (Electrical Discharge Machining). Le défaut correspond alors à un trou circulaire, sa taille est ainsi définie par son diamètre. On cherche alors à discriminer les défauts

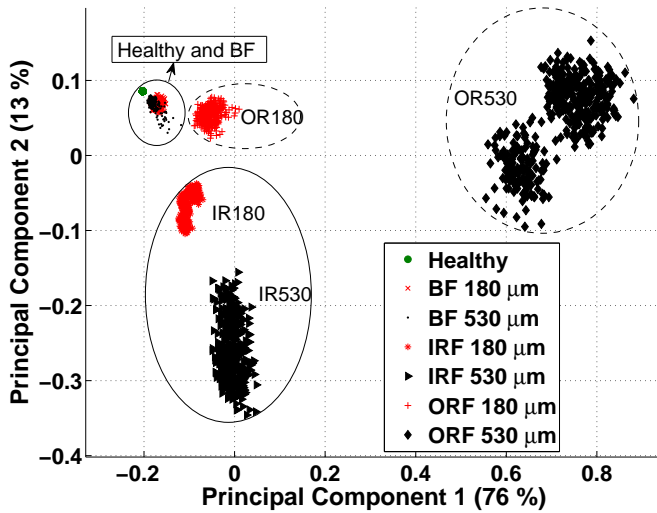


Fig. 3. Classification des défauts de roulements dans le sous-espace principal

en fonction de leur localisation (bille BF, bague interne IRF ou bague externe ORF) et leur sévérité (180 μm et 530 μm) avec un roulement non défaillant (Sain).

Suite à la procédure décrite dans la section 2, 45 fréquences spécifiques sont obtenues à partir d'un espace de mesures comprenant 21 signaux de vibrations (7 signaux par point de fonctionnement). 140 échantillons/vecteurs de paramètres sont générés à partir de chaque signal vibratoire.

4.1. Résultats de la classification utilisant l'ACP

L'ACP est appliquée sur une matrice d'information formée de $21 \times 140 = 2940$ lignes (échantillons) et 45 colonnes (variables descriptives). L'espace de dimension 45 est réduit à un sous-espace de dimension 2 préservant 89% de variances initiales. La matrice spectrale est projetée dans ce sous-espace, dit sous-espace principal, afin de faire la classification. La Figure 3 montre le résultat de la projection obtenue. D'après cette figure, on remarque que :

- Les données projetées sont séparées en 7 classes distinctes correspondantes aux 7 cas de défauts.
- La classification est indépendante du point de fonctionnement de la machine.
- Les deux classes correspondantes aux défauts de billes sont très proches de la classe saine et en plus les deux sévérités sont dans ce cas-là peu discriminées l'une par rapport à l'autre (chevauchements).

La Figure 4 montre particulièrement les classes des défauts de billes dans le sous-espace principal, et les contours des niveaux de densité de probabilité estimés pour chaque classe. Le Tableau 1 montre les taux d'erreur de classification des défauts de billes obtenus par la validation croisée (leave-one-out) en s'appuyant sur une fonction discriminante linéaire entre les classes.

Tableau 1. Matrice de confusion (sous-espace principal)

	C1-Healthy	C2-BF180	C3-BF530
C1-Healthy	420 (100%)	0	0
C2-BF180	0	326 (77.6%)	94 (22.4%)
C3-BF530	0	58 (13.8 %)	362 (86.2%)

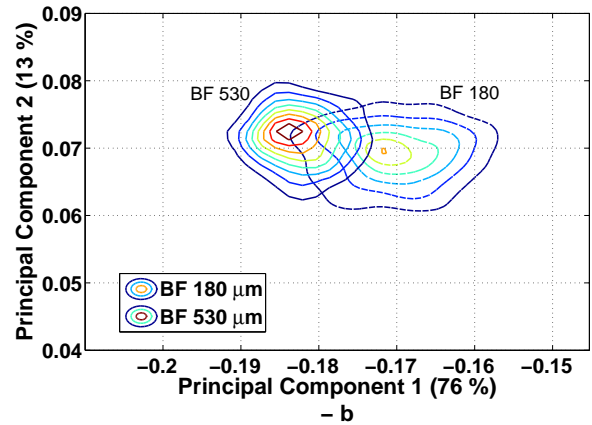
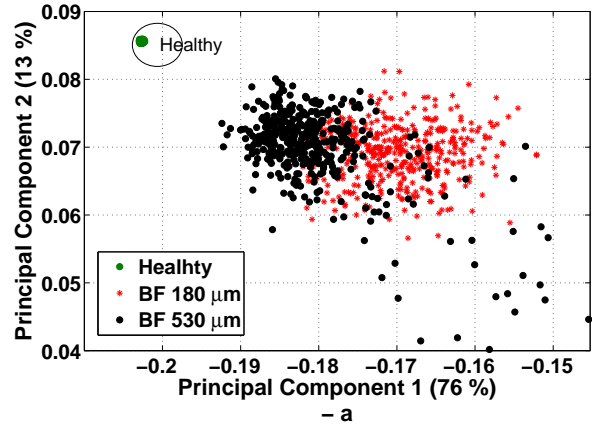


Fig. 4. Discrimination des défauts de billes dans le sous-espace principal - a : classes correspondantes - b : contours des niveaux de densité de probabilité estimée pour chaque classe

4.2. Résultats de la classification utilisant l'ADL

L'ensemble de données traitées par l'ADL contient $140 \times 9 = 1260$ échantillons de 45 variables descriptives. En effet, les échantillons provenant de 9 signaux de vibrations correspondants aux cas de roulements sains et de défauts de billes de diamètre 180 μm et 530 μm sont considérés. L'ADL réduit l'espace de n (3 ici) classes en un espace de dimension $n-1$ (2 ici). Deux axes discriminants sont ainsi obtenus et la projection des données dans l'espace de ces deux axes est illustrée sur la Figure 5.

Les deux densités de probabilités correspondant aux classes des défauts de billes sont mieux séparées dans l'espace de l'ADL que dans celui de l'ACP (Figure 2). La région d'intersection des densités est plus étroite dans la Figure 3. La qualité de la séparation des deux classes peut-être mesurée avec la distance de Bhattacharya. Celle-ci une fois calculée dans les 2 espaces de classification, donne une valeur trois fois plus grande dans l'espace de l'ADL, indiquant une meilleure séparabilité des classes. Le tableau 2 montre les taux de la validation croisée obtenus dans l'espace de l'ADL. Les taux d'erreur diminuent par rapport à ceux obtenus dans le sous-espace principal de 22.4% à 9% et de 13.8% à 5.5%. Ces résultats confirment la contribution de l'ADL à la classification des défauts de billes.

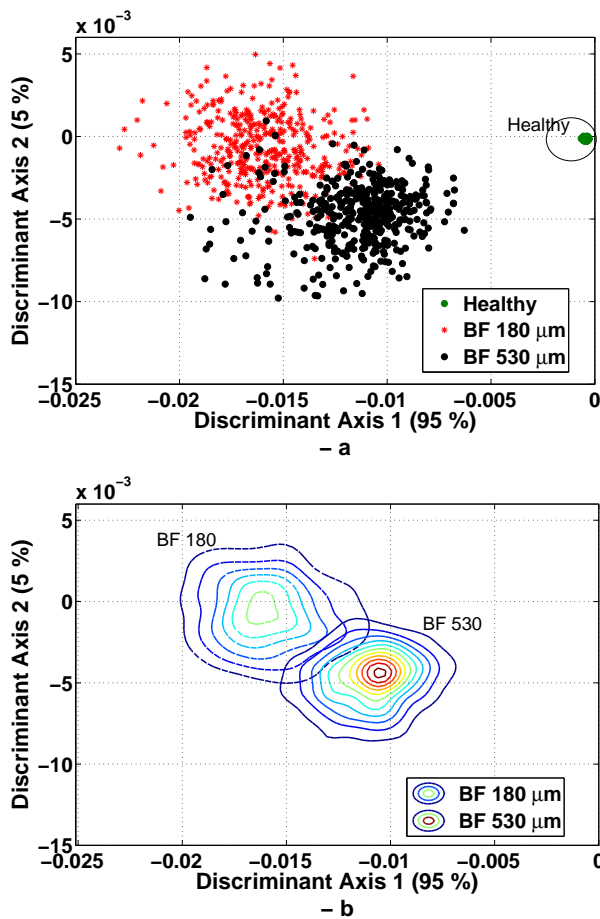


Fig. 5. Discrimination des défauts de billes dans l'espace de l'ADL - a : classes correspondantes - b : contours des niveaux de densité de probabilité estimée pour chaque classe

Tableau 2. Matrice de confusion (espace de l'ADL)

	C1-Healthy	C2-BF180	C3-BF530
C1-Healthy	420 (100%)	0	0
C2-BF180	0	382 (91%)	38 (9%)
C3-BF530	0	23 (5.5%)	397 (94.5%)

5. CONCLUSION

On a montré qu'une analyse spectrale globale permet de faire la classification et le diagnostic des défauts mécaniques dans un roulement, tout en s'affranchissant de la connaissance a priori et l'estimation des fréquences caractéristiques théoriques du roulement considéré. Des paramètres spectraux ayant une capacité discriminatoire élevée, extraits de la signature fréquentielle globale des défauts de roulements, ont permis la discrimination entre les défauts en fonction de la localisation et de la sévérité du défaut.

6. RÉFÉRENCES

[1] B. Trajin, J. Regnier, J. Faucher, « Comparison between vibration and stator current analysis for the detection of bearing faults in asynchronous drives », IET Electric Power Applications, 4 (2), pp. 90–100, 2010.
 [2] S. Ahmed, G. K. Singh, « Experimental investigations on induction machine condition monitoring and fault diagnosis using digital signal processing tech-

niques », Electric Power System Research, 65 (3), pp. 197–221, 2003.
 [3] F. Immovilli, A. Bellini, R. Rubini, C. Tassoni, « Diagnosis of bearing faults in induction machines by vibration or current signals : A critical comparison », IEEE Transactions on Industry Applications, 46 (4), pp. 1350–1359, 2010.
 [4] I. Bediaga, X. Mendizabal, A. Arnaiz, J. Munoa, « Ball bearing damage detection using traditional signal processing algorithms », IEEE Instrumentation and Measurement Magazine, 16 (2), pp. 20–25, 2013.
 [5] J. R. Stack, T. G. Habetler, R. G. Harley, « Fault classification and fault signature production for rolling element bearings in electric machines », IEEE Trans. on Industry Applications, 40 (3), pp. 735–739, 2004.
 [6] D. S. Vilchis-Rodriguez, S. Djurovic, A. C. Smith, « Wound rotor induction generator bearing fault modelling and detection using stator current analysis », IET Renewable Power Generation, 7 (4), pp.330–340, 2013.
 [7] R. A. Collacott, *Vibration Monitoring and Diagnosis : techniques for cost-effective plant maintenance*, New York : John Wiley & Sons, 1979.
 [8] J. I. Taylor, *The Vibration Analysis Handbook*, Vibration Consultants, 2nd edition, 2003.
 [9] K. Worden, W. J. Staszewski, J. J. Hensman, « Natural computing for mechanical systems research : A tutorial overview », Mechanical Systems and Signal Processing, 25 (6), pp. 4–111, 2011.
 [10] A. Raj, N. Murali, « Early classification of bearing faults using morphological operators and fuzzy inference », IEEE Transactions on Industrial Electronics, 60 (2), pp. 567–574, 2013.
 [11] D. Siegel, C. Ly, J. Lee, « Methodology and framework for predicting helicopter rolling element bearing failure », IEEE Transactions on Reliability, 61 (4), pp. 846–857, 2012.
 [12] V. K. Rai, A. R. Mohanty, « Bearing fault diagnosis using fft of intrinsic mode functions in hilbert huang transform », Mechanical Systems and Signal Processing, 21 (6), pp. 2607–2615, 2007.
 [13] Y. Amirat, V. Choqueuse, M. Benbouzid, « EEMD-based wind turbine bearing failure detection using the generator stator current homopolar component », Mechanical Systems and Signal Processing, 41 (1-2), pp. 667–678, 2013.
 [14] H. Bouchikhi, V. Choqueuse, M. Benbouzid, « Current Frequency Spectral Subtraction and Its Contribution to Induction Machines' Bearings Condition Monitoring », IEEE Transactions on Energy Conversion, 28 (1), pp. 135–144, 2012.
 [15] P. D. McFadden, J. D. Smith, « Vibration monitoring of rolling element bearings by the high frequency resonance technique - a review » Tribology International, vol. 17, pp. 1–18, 1984.
 [16] R. B. Randall, J. Antoni, S. Chhobsaard, « A comparison of cyclostationary and envelope analysis in the diagnostics of rolling element bearings », IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP), vol. 6, pp. 3882–3885, 2000.
 [17] Y. Amirat, V. Choqueuse, S. Turri, « Hilbert transform-based bearing failure detection in dfig-based wind turbines », International Review of Electrical Engineering, 6 (3), pp. 1249–1256, 2011.
 [18] J. Xi, Y. Han, R. Su, « New fault diagnosis method for rolling bearing based on pca », 25th Chinese Control and Decision Conference (CCDC), pp. 4123–4127, 2013.
 [19] J. Xiaohang, M. Zhao, T. W. S. Chow, M. G. Pecht, « Motor bearing fault diagnosis using trace ratio linear discriminant analysis », IEEE Transactions on Industrial Electronics, 61 (5), pp. 244–2451, 2014.
 [20] A. Case Western Reserve University, Bearing data centre, "Url :http ://www.eecs.cwru.edu/laboratory/bearing.