

ÉTUDE ET DÉVELOPPEMENT D'UN SYSTÈME EXPERT BASÉ SUR LES RÉSEAUX DE NEURONES POUR LE DIAGNOSTIC DES DÉFAUTS DE ROULEMENTS

*B. Badri*¹; *M. Thomas*¹; *S. Sassi*²

- (1) Department of Mechanical Engineering, École de Technologie Supérieure, Montreal, Qc, Canada
marc.thomas@etsmtl.ca; bechirbadri@yahoo.fr
- (2) Department of Physics and Instrumentation, Institut National des Sciences Appliquées et de Technologie, Tunis, CEDEX, Tunisia
sadok.sassi@insat.rnu.tn

Résumé

En se basant sur l'hypothèse de la présence d'un seul défaut localisé, le but de cette recherche est de décrire un système expert, qui à partir des descripteurs temporels et fréquentiels issues d'un signal vibratoire mesuré sur un roulement endommagé, est capable de remonter à la source du défaut pour prédire son diamètre ainsi que son emplacement (Bague intérieure ou bague extérieure).

Les recherches bibliographiques font savoir que les travaux menés précédemment sur le même sujet ont conduit à des systèmes à sortie binaire, dont le principal résultat est soit : Oui = il y a défaut, soit Non = il n'y a pas de défaut. Par ailleurs, les études localisant l'emplacement du défaut ne lui attribue généralement pas de criticité.

La première originalité de cette recherche est non seulement de signaler la présence d'un défaut, mais aussi de localiser son emplacement et de lui attribuer une criticité en déterminant son diamètre. La deuxième originalité réside dans la manière que l'apprentissage du réseau de neurones a été fait. En effet, un nombre considérable de données provient d'un simulateur de défaut de roulement appelé BEAT (Bearing Toolbox), qui une fois calibré par rapport à des mesures expérimentales réelles, permet de générer une base de données d'apprentissage très grande assurant un apprentissage adéquat et couvrant un large éventail de configuration de défauts. La précision du système expert développé dans les configurations retenues est de l'ordre de 99.8% quand à la détermination du diamètre du défaut, et de 97% quand à sa localisation.

Mots clés : système expert, réseau de neurones, simulation, vibration, Roulements ...

Introduction et Objectifs :

Un système expert a été développé, capable à partir signal vibratoire –plus précisément des descripteurs temporels et fréquentiels issue du signal vibratoire- de remonter au diamètre de défaut ayant causé cette vibration ainsi que son emplacement (Bague intérieure où bague extérieure).

Cet objectif, malgré sa simplicité -apparente-, est assez ambitieux au regard de la bibliographie. En effet, les recherches effectuées dans le domaine fournissent très souvent une sortie binaire, synonyme de présence ou d'absence de défaut seulement. Les études localisant l'emplacement du défaut n'attribue pas nécessairement de criticité au défaut (il peut s'agir de défaut naissant, grave ou très critique). La **première originalité** de ce travail est de, non seulement signaler la présence d'un défaut, mais aussi de **localiser son emplacement**, et de lui **attribuer une criticité** (en déterminant son diamètre). La deuxième originalité dans la démarche réside dans les données d'apprentissage du réseau de neurones. En effet, au lieu de recourir à des signaux expérimentaux issues de mesures vibratoires, nous utiliserons un simulateur BEAT (**B**earing **T**oolbox), qui est lui-même parfaitement calibré par rapport à des mesures expérimentales sur 2 bancs d'essais différents (dont un à l'ÉTS).

En partant du principe qu'un réseau de neurones est de plus en plus performant avec la quantité ET la qualité des données d'apprentissage, l'utilisation de signaux simulés à la place des signaux expérimentaux est d'un apport bénéfique quand à la performance du réseau de neurones. L'utilisation de BEAT, permet de générer très rapidement (15s par configuration), une base de données de vibrations quasi-infinie dans les configurations de défaut et d'opérations choisies. Ce qui représente une source d'apprentissage considérable pour le réseau de neurones.

L'autre avantage que tiré de l'utilisation de BEAT, est la possibilité de simuler des configurations très difficiles à mettre en œuvre en pratique car dangereuse, tel des vitesses de rotation très élevée, des températures extrêmes -hautes ou basse- influent sur la viscosité du lubrifiant, affecte la réponse vibratoire.

Effet de l'emplacement du défaut :

La détermination de l'emplacement du défaut est une information importante à fournir par le système expert. À la question : Pourquoi est-t-il si important de connaître l'emplacement du défaut, à partir du moment où on sait qu'il y a défaut ? La réponse est : la vitesse de propagation d'un défaut diffère selon son emplacement, théoriquement c'est prévisible –vu que les fréquences sont différentes-. Un cas pratique est présenté pour asseoir cette affirmation, et qui détaille la proportion de roulement encore opérationnel en fonction de l'emplacement du défaut.

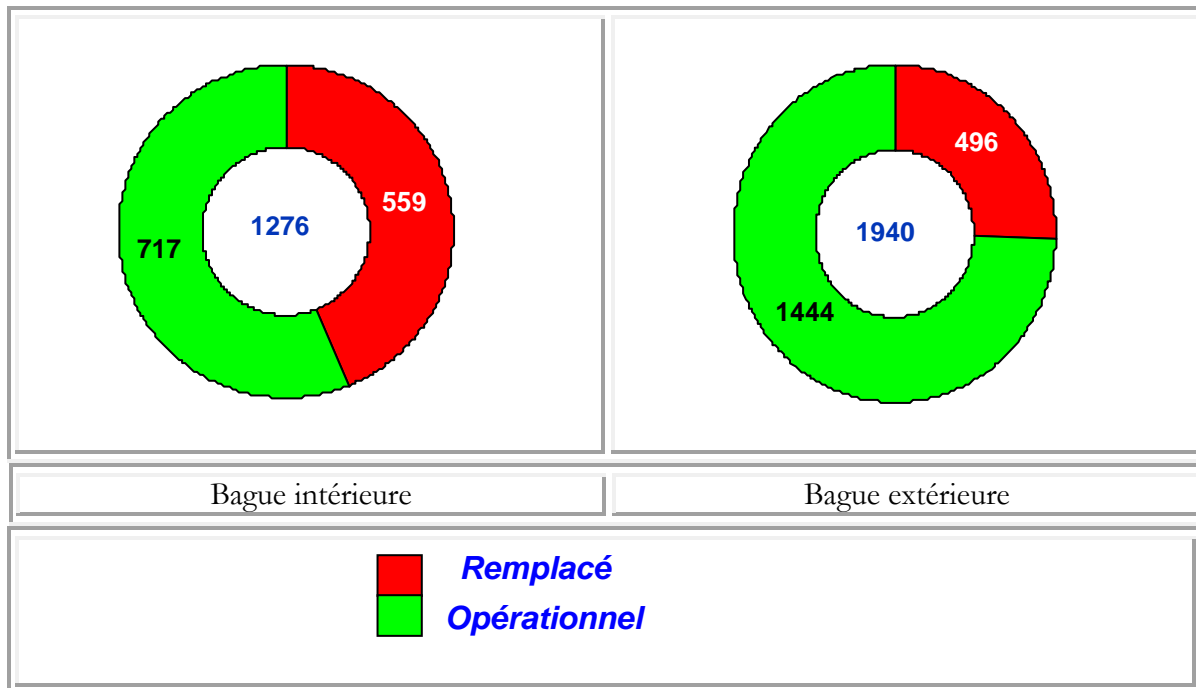


Figure 1 Statistiques de roulement endommagé en fonction de l'emplacement

45% des roulements atteints d'un défaut sur la bague intérieure ont été remplacés, contre 25% pour roulements avec défauts sur la Bague extérieure → la propagation pour un défaut sur la bague intérieure est pratiquement 2 fois plus rapide que pour un défaut sur la bague extérieure, la durée de vie est donc divisée par 2.

Les politiques de maintenances incitent les opérateurs à éviter d'arrêter une machine trop tôt (pour changer un roulement). Tant qu'elle peut encore tourner –sans blesser personne et sans endommager d'autres équipements- il vaut mieux la laisser tourner !!!

Cette politique (Maintenance conditionnelle par opposition à celle systématique), assure le meilleur rendement du parc machine tout en minimisant le coût des pièces de rechange. Cet exemple démontre très clairement l'importance de connaître l'information *Emplacement du Défaut*.

Eléments de théories

En vibration de roulements, l'emplacement du défaut génère une fréquence qui lui est spécifique. À la manière de la parole humaine, chaque défaut possède une signature vibratoire qui lui est propre, analogue à la signature vocale. En effet, un défaut sur la bague extérieure générera un signal contenant des chocs espacés de la période de passage des billes sur la Bague extérieure, la fréquence de ces chocs est appelée dans le jargon BPFO (Ball Passage Frequency Outer). Pour un défaut sur la bague intérieure, cette fréquence est BPFI (Ball Passage Frequency Inner). Ces fréquences se calculent avec les dimensions du roulement et la vitesse de rotation, et sont accessibles dans des bases de données établit par les fabricant. Le spectre -enveloppe- ci-dessous présente un exemple de signal vibratoire d'un roulement atteint de défauts sur les 2 bagues, il montre clairement la présence de la composante spectrale BPFO, (Ball Passage Frequency Outer) témoignant de la présence d'un défaut sur la bague extérieure, ainsi que la composante BPFI (Ball Passage Frequency Inner) témoignant de la présence d'un défaut sur la bague intérieure.




Figure 2 Spectre enveloppe d'un roulement atteint d'un défaut sur BE et BI

À partir de là, la reconnaissance de l'emplacement du défaut passera nécessairement par des descripteurs de types fréquentiels.

1. Reconnaissance du diamètre du défaut et recensement des Variables d'entrées du réseau de neurones:

L'amplitude des chocs appliqués au roulement dépend directement du diamètre du défaut (plus le défaut est grand, plus le choc est grand). Le signal vibratoire (qui est la réponse aux chocs) est aussi directement relié à la dimension du défaut. Pour caractériser un signal -vibratoire ou autre-, plusieurs descripteurs temporels existent, permettant d'avoir une information par une seule valeur, les plus connues sont le PEAK (valeur max), le RMS (Root Mean Square) qui représente la valeur efficace du signal. Il existe aussi des descripteurs (opérateurs mathématiques) spécifique à la vibration, et spécialement pour le diagnostic des roulements, le tableau suivant résume les principaux descripteurs conventionnels:

Peak	$a_{peak} = \sup_{1 \leq k \leq N} a_k $
Root Mean Square	$a_{RMS} = \sqrt{\frac{1}{N} \sum_{k=1}^N a_k^2}$
Crest Factor	$CF = \frac{a_{peak}}{a_{RMS}}$
Kurtosis	$Kurtosis = \frac{\frac{1}{N} \sum_{k=1}^N (a_k - \bar{a})^4}{a_{RMS}^4}$
Shape Factor	$SF = \frac{a_{RMS}}{\frac{1}{N} \sum_{k=1}^N a_k }$
Impulse Factor	$IF = \frac{a_{peak}}{\frac{1}{N} \sum_{k=1}^N a_k }$

Le comportement de ces différents paramètres en fonction du diamètre du défaut sur la bague extérieure est présenté sur le graphique suivant (données générées par BEAT) :

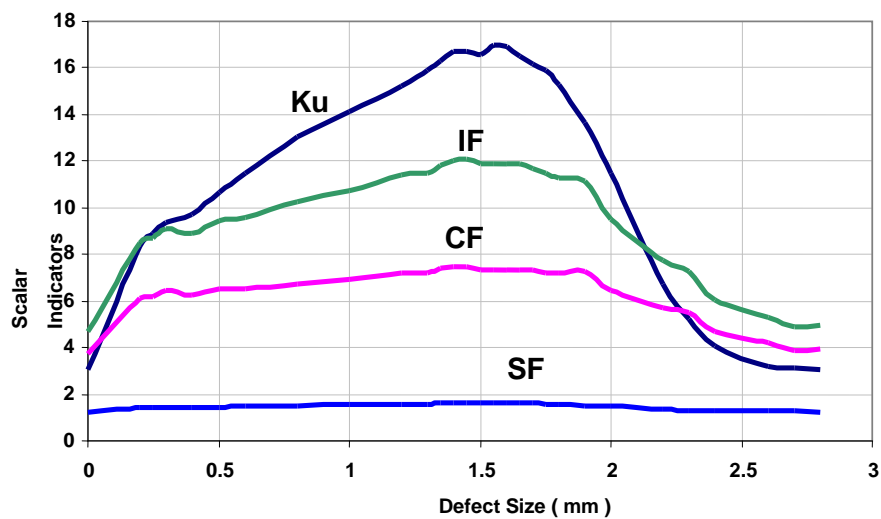


Figure 3 Variation des descripteurs en fonction du diamètre de défauts

Interprétation

Le Kurtosis, le Facteur de crête (CF), et le facteur d'impulsion (IF) d'un roulement neuf (diamètre du défaut =0) et d'un roulement très dégradé (diamètre du défaut =2.75) sont sensiblement les mêmes !!! Ce phénomène a une explication rationnelle (*autre que le roulement s'est auto-réparé* 😊) qui est en partie liée au fait que la limaille de fer –provenant du défaut dans une phase très avancée- se dépose au fond de ce dernier et amorti les chocs. Dans la mesure où ces descripteurs fournissent la même information pour 2 diamètres de défaut différents, il ne seront performant –dans le réseau de neurones- que s'il sont associé au Peak et/ou au RMS, qui reste croissant avec le diamètre du défaut (voir figure plus bas).

Bien que ce constat ne soit pas accompagné de formalisme mathématique (*un point qui sera approfondie dans des travaux ultérieurs*), il a été validé en évaluant les performances du réseau de neurones dans les 2 configurations citées :

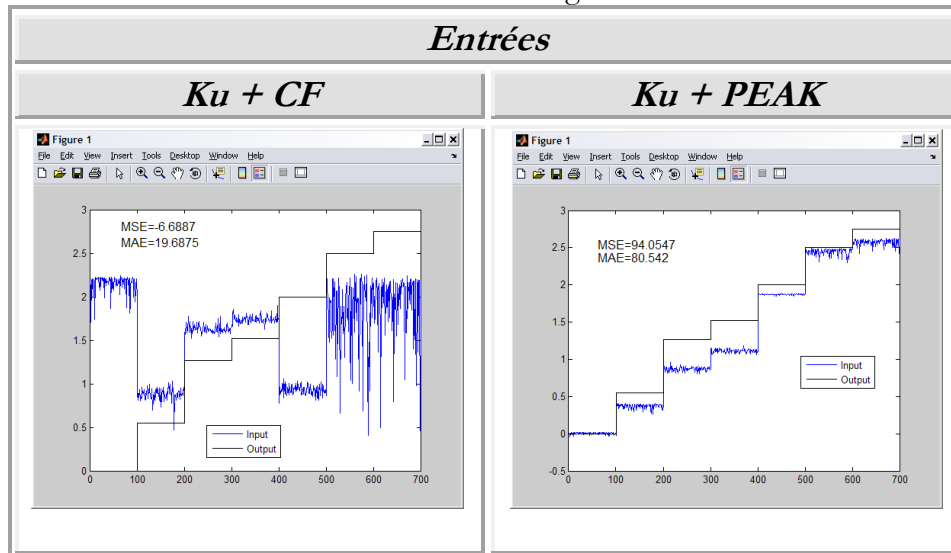
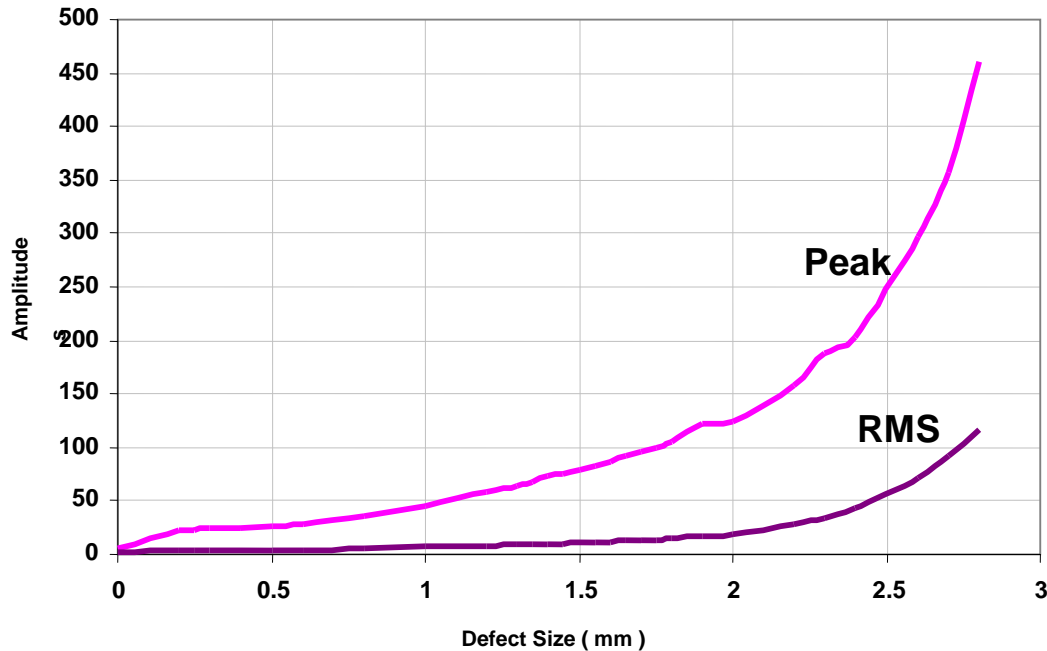


Figure 4 Performance du système pour 2 configurations de variables d'entrées

<i>Entrées</i>	<i>Performance</i>
<i>Ku + CF</i>	6.68 %
<i>Ku + PEAK</i>	94.05 %

Autre constat, le facteur de forme (Shape Factor SF) est pratiquement plat sur la plage d'intérêt, il n'y a donc pas d'informations pertinentes (dans le sens diamètre de défaut) contenu dans ce descripteur, il sera donc inutile de l'inclure dans les variables d'entrées.



Talaf et Thikat : Deux Nouveaux descripteurs :

En plus des descripteurs conventionnels, et dans le cadre d'un travail antérieur (réalisé par la même équipe), deux autres descripteurs ont été développés, permettant une meilleure connaissance de l'état du roulement tout en étant les plus indépendants possibles des conditions de fonctionnement.

Ces descripteurs sont les suivants :

$$TALAF = \log \left[Ku + \frac{RMS}{RMS_0} \right]$$

$$THIKAT = \log \left[(Ku)^{CF} + \left(\frac{RMS}{RMS_0} \right)^{Peak} \right]$$

Où RMS_0 représente la valeur efficace du roulement sans défaut.

THIKAT : descripteurs croissants qui suivent quasi-linéairement la dégradation du roulement, jusqu'à une **valeur critique** du défaut où il s'annule, et où il faut **intervenir d'urgence**.

TALAF : offre l'avantage lors d'un suivi (mesures régulièrement espacées dans le temps), de visualiser les 4 stades de dégradations d'un roulement : 4 **stades de dégradations** signalés par le **changement de pente**.

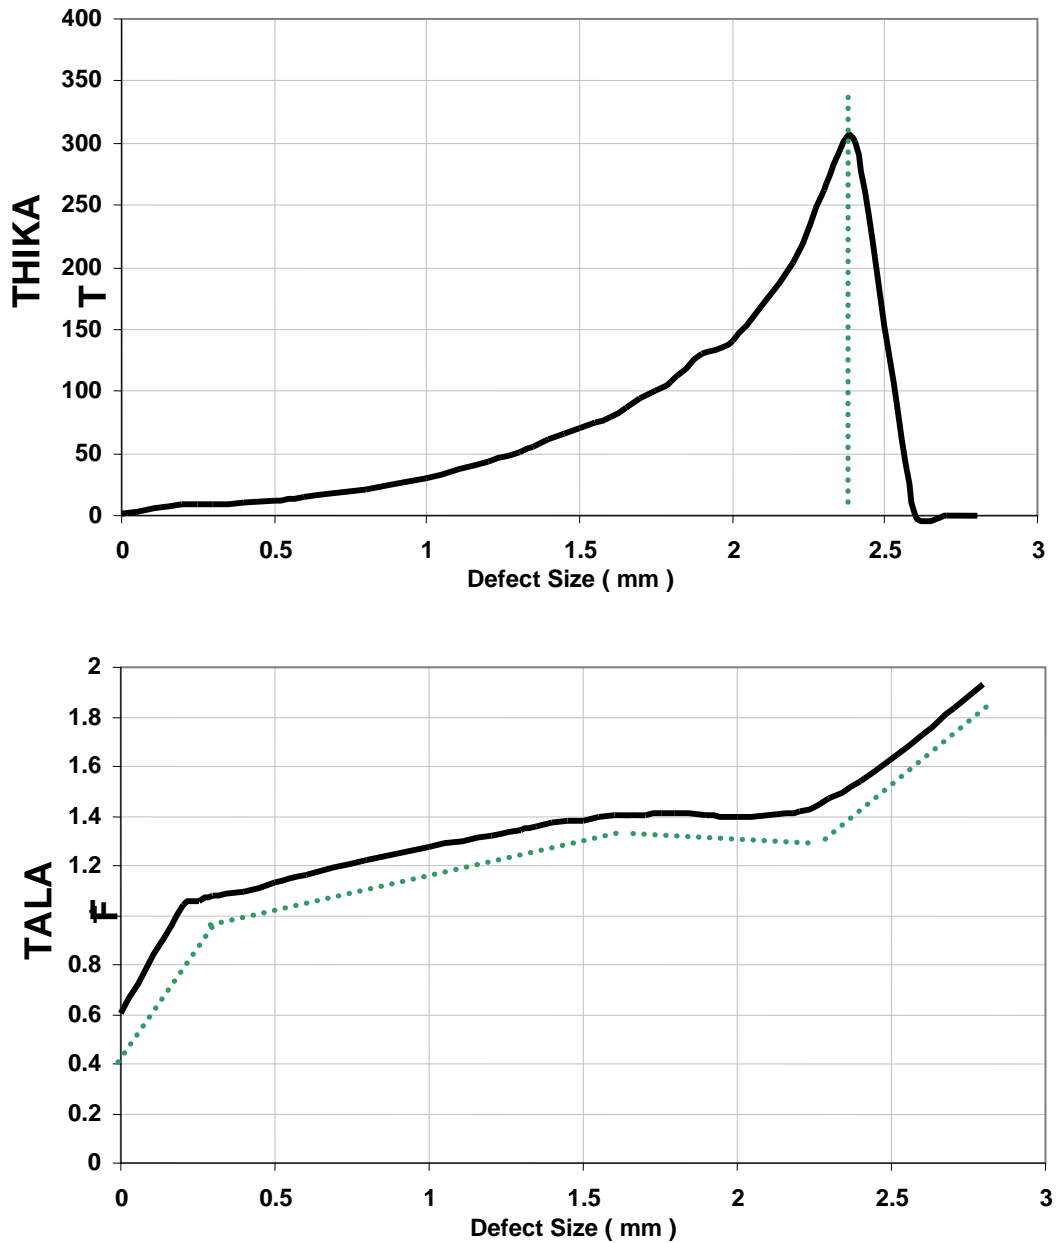


Figure 6 Variation des descripteurs en fonction du diamètre de défauts

2. Organigramme du réseau et optimisation des paramètres:

En simplifiant au maximum , l'objectif peut se résumer sur l'organigramme suivant :



Il s'agit de déterminer, en partant des descripteurs temporels (PEAK, RMS, TALAF...) et fréquentiels (BPFO, BPFI, BPF Moy...), le diamètre d'un défaut localisé et son emplacement.

Configuration du réseau de neurones :

C'est une étape cruciale dans l'élaboration d'un système à base de réseau de neurones. En effet, ce choix doit se faire en fonction des données d'entrées et de sorties, de la dispersion des classes...etc.

La recherche bibliographique sur les études menées dans le même domaine suggérait l'adoption d'un système à base de MLP (Multi-Layer-Perceptron) -réseau multicouche-, dont l'organigramme est le suivant.

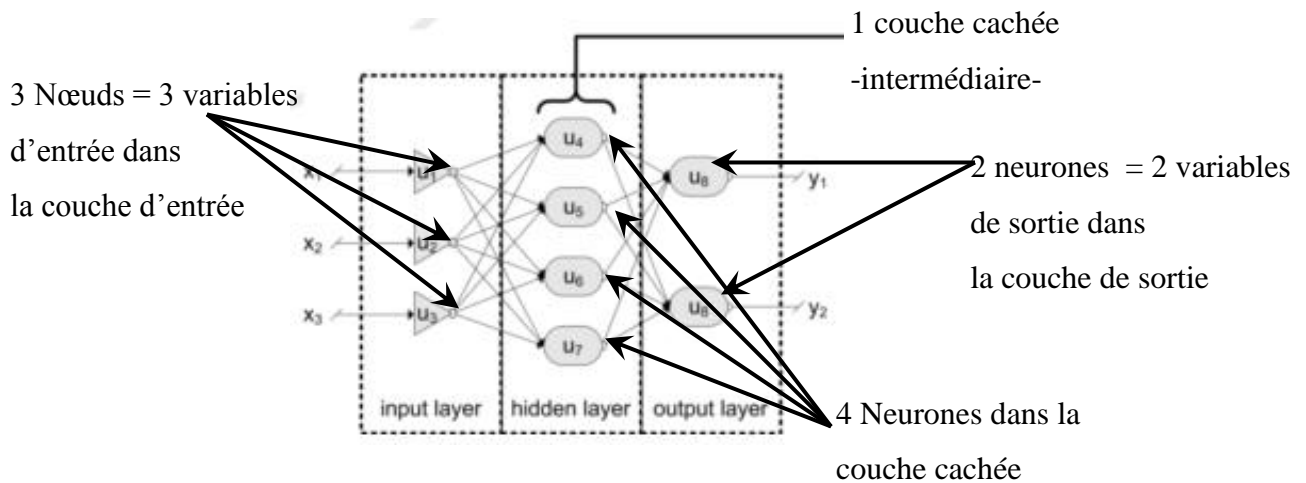


Figure 7 Organigramme d'un réseau de neurones

Source : www.neural-forecasting.com

Pour le présent travail, ce type de réseau (MLP) a été retenue, tout en évaluant la configuration optimale adapté à l'objectif initial, et ce, en terme de nombre de couches (intermédiaire) et de nombre de neurones.

Pour configurer le réseau de neurones, 2 étapes s'imposent :

1. Détermination du nombre de couches intermédiaires optimal.
2. Détermination du nombre de neurones optimal.

Cette étude a été effectuée en simulant plusieurs configurations de réseau –*sous un nombre de variable d'entrée et de neurones constant* - et en comparant leurs performances. Le paragraphe suivant présente les résultats de cette étude.

1. Détermination du nombre de couches intermédiaires optimal.

✚ Pour cette étude Le nombre de variable d'entrées est fixé à 6 :

- Peak
- RMS
- Kurtosis
- Impulse Factor
- Talaf
- Thikat

✚ Le nombre de neurones pour chaque couche cachée a été fixé à 5.

<i>Nombre de couche intermédiaire</i>	<i>Performance (100% - MSE %)</i>
<i>1</i>	<i>99.8</i>
<i>2</i>	99.5
<i>3</i>	99.0
<i>4</i>	97.5
<i>5</i>	91.1




Figure 8 Performances du système en fonction du nombre de couches

Il est clair, au regard de cette étude comparative, qu'un réseau à une seule couche intermédiaire offre les meilleures performances. C'est la valeur (1) qui sera retenue pour ce paramètre.

2. Détermination du nombre de neurones optimal (dans la couche cachée).

Pour cette simulation, le nombre de variable d'entrées est fixé à 6

- Peak
- RMS
- Kurtosis
- Impulse Factor
- Talaf
- Thikat

Le MLP à une seule couche intermédiaire, la tableau suivant présente les performances du réseau en fonction du nombre de neurones de cette couche intermédiaire.

<i>Nombre de neurones</i>	<i>Performance (100% - MSE %)</i>
1	55
2	88
3	92.5
4	97.3
5	99.8
6	99.2
7	99.4
8	99.1
9	99.4
10	99.6




Figure 9 Performances du système en fonction du nombre de neurones


À partir d'un nombre de neurones égal à 5 -pour la couche intermédiaire-, les performances du système restent sensiblement dans le même ordre de grandeur. La valeur 5 sera retenue pour ce paramètre, pour minimiser le temps d'exécution –qui tend à croître avec le nombre de neurones-.

Configuration Retenue :

Ces simulations ont permis la mise au point de la configuration optimale pour le réseau MLP, notons que le choix a été fixé en tenant compte des performances de chaque config. , mais aussi en adoptant un compromis entre performance et temps d'exécution.

La configuration retenue est la suivante:

- ✚ Réseau à 3 couches → 1 seule couche intermédiaire.
- ✚ 5 Neurones dans la couche Intermédiaire.
- ✚ Le nombre de nœud à l'entrée est variable selon les simulations (2 à 10 variables d'entrées)
- ✚ La fonction d'activation utilisée (pour la couche intermédiaire et la sortie) est la log-Sigmoïde, un choix motivé par les variables binaires que nous utilisons pour localiser le défaut (tend rapidement vers 1 s'il y a défaut sur la bague, et vers 0, s'il n'y en a pas).



Les paramètres d'apprentissage sont les suivant :

- ✚ Nombre maximum d'itération (Epochs) = 1000
- ✚ Erreur quadratique moyenne MSE = 10⁻⁶
- ✚ Gradient minimum = 10 e-10

L'apprentissage est arrêté si une de ces conditions est satisfaite. Ci-après un aperçu de l'erreur instantanée au cours de l'apprentissage (400epochs).

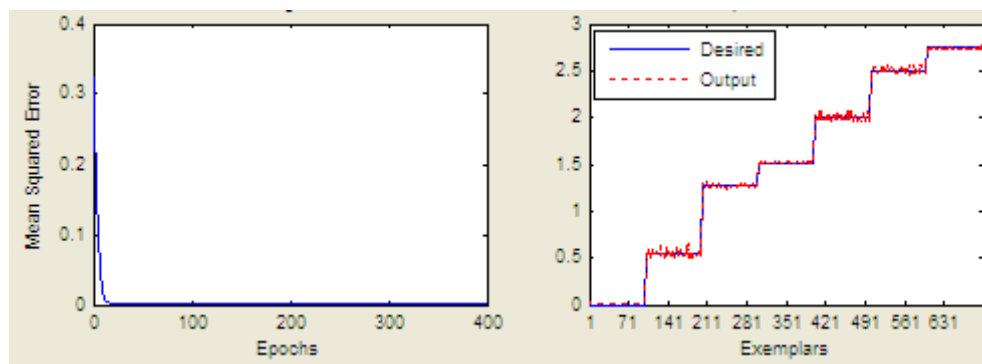


Figure 10 Aperçu de l'apprentissage et erreur quadratique moyenne

Effet des perturbations aléatoires :

Le signal vibratoire est entaché d'une composante aléatoire. Cette composante est principalement due au glissement des billes sur les bagues, au jeu à l'intérieur du roulement, quand ce n'est pas un bruit externe (provenant d'autre machines, équipement, bruit ambiant...etc.).

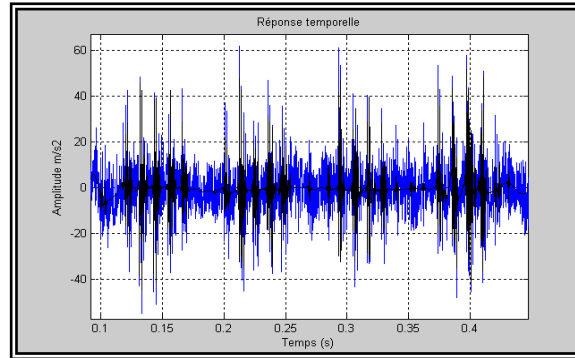


Figure 11 Signal original (bleu) et signal débruité (noir)

La présence de cette composante aléatoire, fait que dans des simulations (ou dans des mesures réelles) ***dans exactement les mêmes conditions***, il y ait une petite dispersion dans les descripteurs.

Ce qui suit représente 100 simulations dans les mêmes conditions (diam. de def., vitesse ...)




Figure 12 Variation des descripteurs pour 100 simulations dans les mêmes conditions

Aussi, pour des valeurs de **diamètres de défauts très proches**, il y un risque de **chevauchement** entre les valeurs d'entrés et de sortie.

Pour clarifier cette notion, l'exemple suivant présente la variation du paramètre PEAK en fonction d'une variation linéaire du diamètre de défaut sur la Bague Extérieure de 0 à 2.75 (avec un pas de 27.5microns).

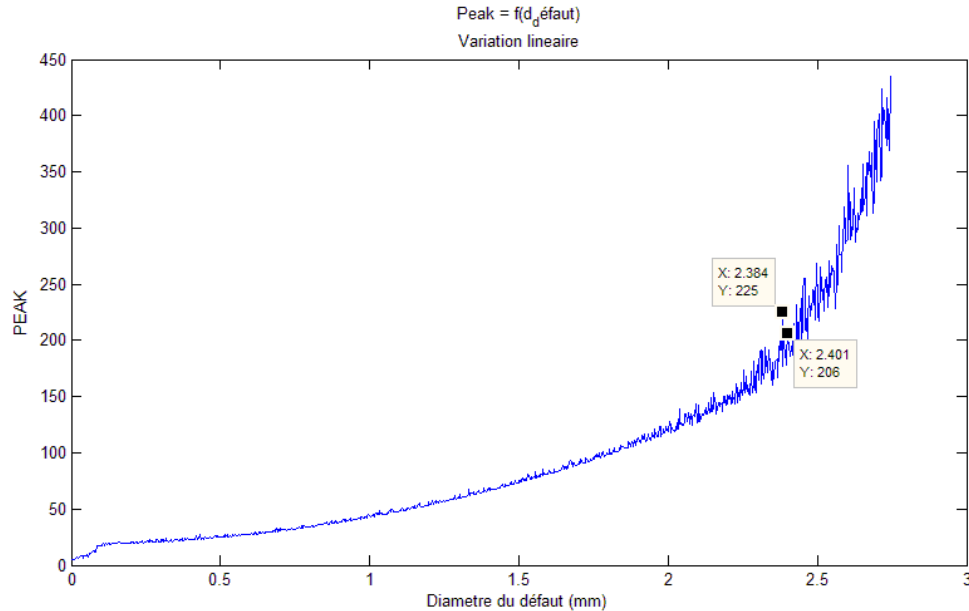


Figure 13 Variation du Peak pour une variation linéaire du défaut

Pour un défaut de 2.38mm le Peak est de 225, et pour un défaut de 2.4mm le Peak est de 206!!!

En conclusion, la composante aléatoire contenue dans le signal, risque d'induire une certaine erreur lors de l'apprentissage : DANS LE CAS D'UN APPRENTISSAGE LINÉAIRE. En effet, si l'apprentissage est effectué par palier (par opposition à l'apprentissage linéaire), le système pourra être *éduqué* à attribuer le même diamètre de défaut à des descripteurs –légèrement- différents. Ce qui est appelé apprentissage par palier, est le fait de fournir à l'entrée une série de données pour le même diamètre de défauts, afin que la composante aléatoire fasse partie de l'apprentissage.

Exemple :

- D=0mm → 100 signaux
- D=0.55mm → 100 signaux
- D=1.27mm → 100 signaux
- D=1.52mm → 100 signaux
- D=2mm → 100 signaux
- D=2.5mm → 100 signaux
- D=2.75mm → 100 signaux

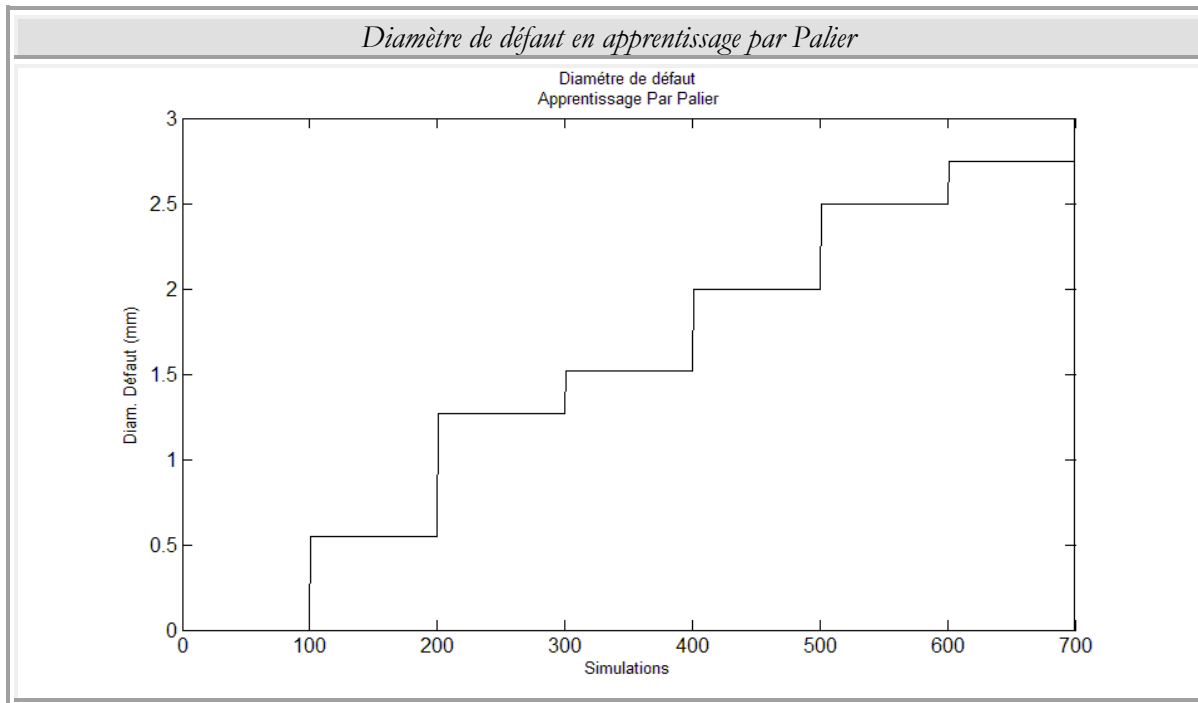


Figure 14 Diamètre de défaut en apprentissage par Palier

Pour valider l'intérêt de l'apprentissage par palier par rapport à celui linéaire, une étude comparative (se basant sur les performances) entre l'apprentissage linéaire (validation par palier) et l'apprentissage par palier (validation linéaire)

NB : L'apprentissage et la validation ne sont pas fait avec la même base de données.

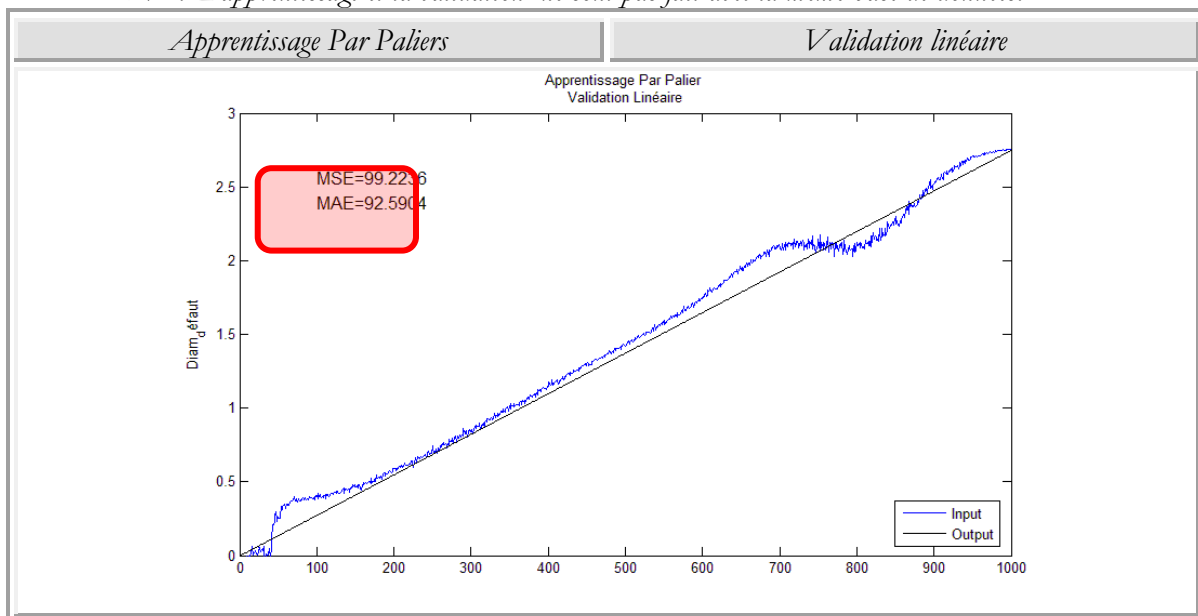


Figure 15 Performance avec Apprentissage Par Paliers et Validation linéaire

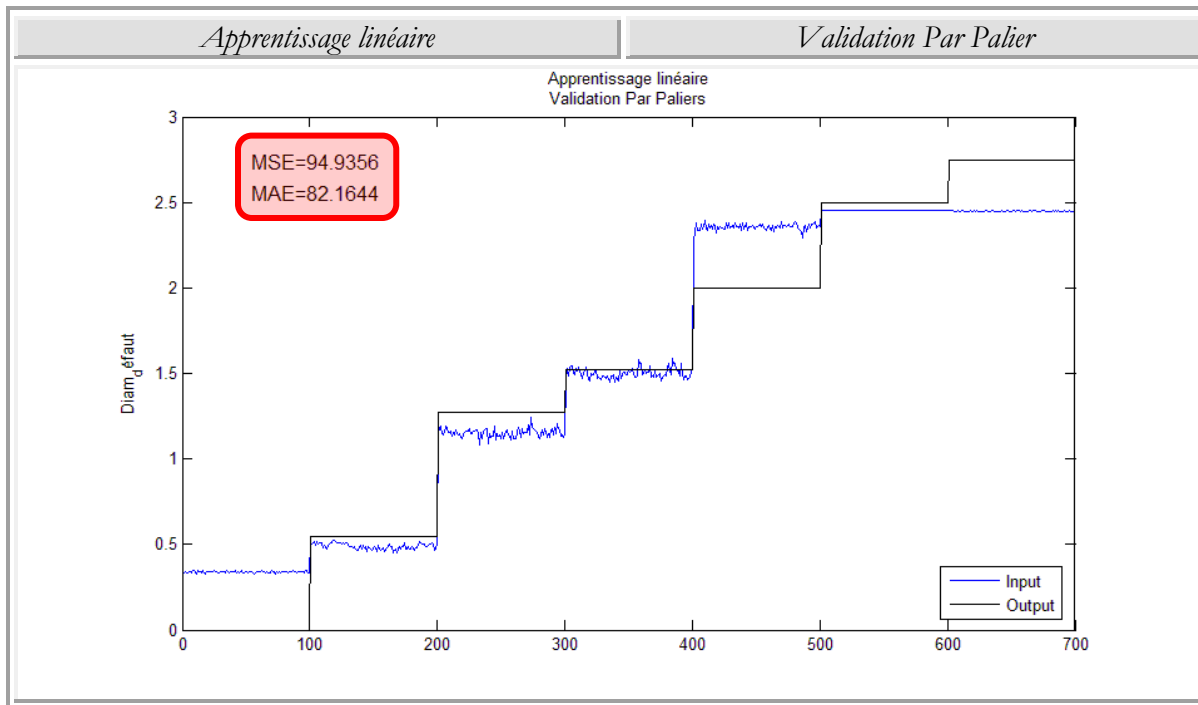


Figure 16 Performance avec Apprentissage linéaire et Validation Par Paliers

Avec les mêmes paramètres de réseau, pour les 2 types d'apprentissage proposés, les résultats sont les suivants :

<i>Apprentissage</i>	<i>Par Paliers</i>	<i>Linéaire</i>
<i>Performance</i>	99.22%	94.93%

Ce qui confirme le fait qu'un apprentissage par palier, intègre dans le processus d'apprentissage l'effet de la perturbation aléatoire.

Notons aussi que ce phénomène est indépendant de la façon avec laquelle les données sont présentées au système. Le phénomène s'observe si la séquence est présentée au réseau dans l'ordre, mais aussi si elle l'est aléatoirement.

4. Descripteurs Fréquentiels et reconnaissance de l'emplacement :

En présence de défauts, les chocs générés par le roulement sont particulièrement synchrones (dans le temps), le risque de dispersion des fréquences de défauts est minime. Il est donc parfaitement raisonnable de supposer que toute opération de reconnaissance d'emplacement doit certainement passer par les fréquences de défauts. L'exemple suivant présente le spectre avec un défaut sur la bague extérieure et un autre sur la bague intérieure, la présence de BPFO et de BPFI est évidente (roulement SKF1210 tournant à 720tr/mn).





Figure 17 Spectre enveloppe d'un roulement atteint d'un défaut sur BE et BI

Une suite logique est donc la proposition d'adopter l'amplitude de BPFO et de BPFI, comme descripteurs fréquentiels servant à localiser l'emplacement du défaut. Un autre point est important à signaler avant d'adopter définitivement cette démarche. La manifestation spectrale du bruit, se traduit par une énergie uniformément répartie sur toute la gamme de fréquence. Sur une mesure de roulement, entaché de bruit, tous les pics (les BPFO, BPFI entre autres) seront soulevés par le bruit de fond du spectre. Dans un cas très général, ce n'est pas *l'amplitude absolue* d'un pic qui est importante, mais c'est son *amplitude relative* par rapport à la base du spectre qui l'est. Une proposition simple sera formulée pour tenir compte de ce point, l'évaluation des pics à BPFO et BPFI sera faite par rapport au niveau moyen du spectre. Plus précisément par rapport à ses voisins immédiats, pour ne pas tenir compte des autres composantes spectrales qui ne proviennent pas du roulement. Sachant que les fabricants de roulements s'arrangent en les concevant (en jouant sur les dimensions) pour que les fréquences de défaut ne soient, ni proches entre elles, ni multiples de la vitesse de rotation (pour ne pas confondre les harmoniques), le risque de chevauchement entre fréquences de défauts de roulements est quasi-nul (surtout vrai pour les harmoniques de premiers ordres).

Illustration :

Spectre Enveloppe du signal :



Zoom sur BPF0 –et ses bandes latérales-

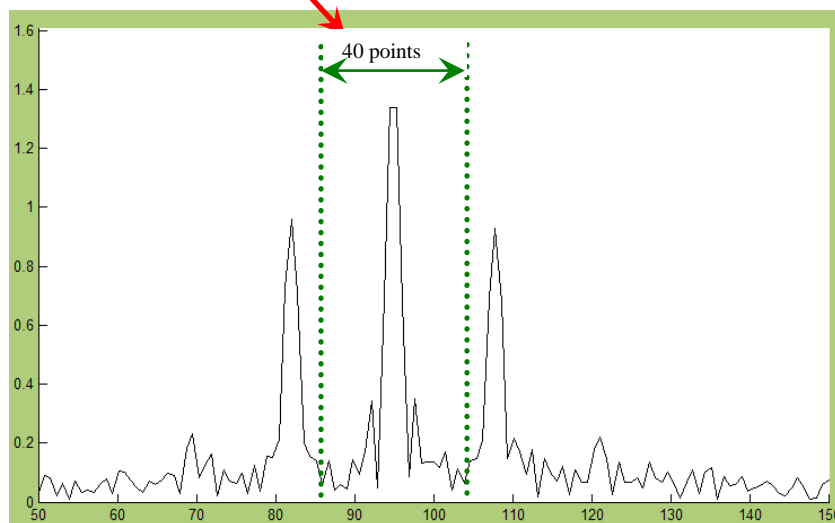


Figure 18 Extraction du paramètre d'entrée fréquentiel

La démarche consiste à calculer le rapport de l'amplitude du pic par la moyenne de ses 40 voisins (20 à gauche et 20 à droite). Les sorties relatives à l'emplacement du défaut sont des sorties binaires (1 défaut présent ; 0 pas de défaut), Le choix d'attribuer une sortie à chaque emplacement de défauts a été motivé par le besoin de tenir compte –là aussi- du cas plus général ou un défaut est présent sur chaque bague.

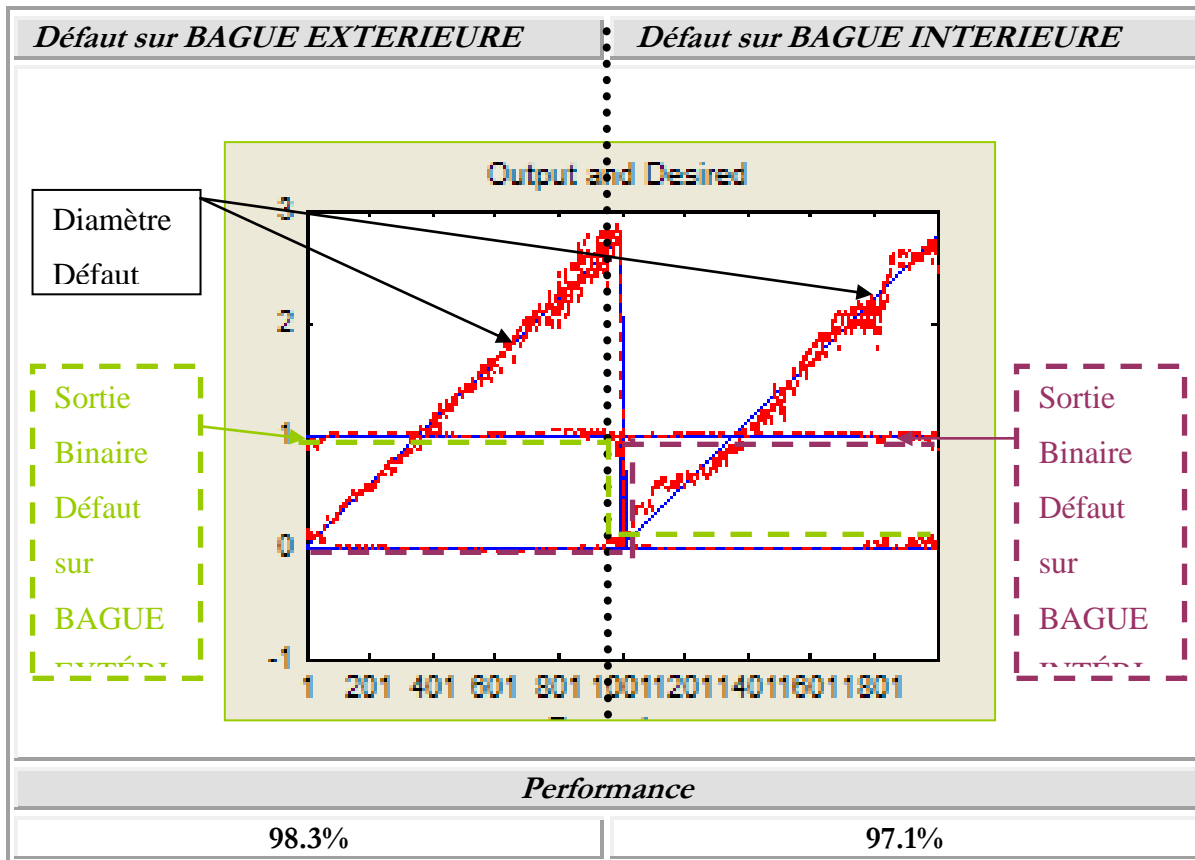


Figure 19 Résultats de reconnaissance pour défauts sur BE et BI (diamètre et emplacement)

Conclusion :

L'objectif initial de ce travail, était de mettre au point un système expert à base de réseau de neurones, capable de diagnostiquer un défaut de roulement, en déterminant son diamètre, et en localisant son emplacement. Cet objectif a été largement atteint avec une précision de l'ordre de 99.8% quand à la détermination du diamètre du défaut, et de 97% quand à la localisation. Ces performances découlent directement de la qualité de l'apprentissage, effectué avec le simulateur BEAT, associé à un choix optimal de la configuration du réseau et des variables d'entrées. Durant tout le processus de développement, toutes les notions traitées ont été validées par des simulations, en accordant beaucoup d'attention (notamment lors du choix des variables d'entrées) à ce que le système tienne compte des configurations les plus générales possibles. Les prochains travaux porteront l'accent sur des possibilités d'améliorations des performances du système, principalement pour tenir compte des configurations de défauts les plus générales (plusieurs défauts sur la même bague, vitesse de rotation excessivement rapide ou lente...). Pour parvenir à un tel objectif, l'intégration d'autres outils de traitement de signal avancés s'imposent.

En effet, le simulateur BEAT dispose d'une large gamme d'outil très adapté à l'aide au diagnostic (voir annexe):

- ✚ Spectrogramme Temps-Fréquences
- ✚ Analyse cepstrale
- ✚ Décomposition par ondelettes (wavelett)
- ✚ Décomposition en bandes d'octave
- ✚ Décomposition en 1/3 d'octave
- ✚ L'Index Julien Modifié (le tout dernier descripteur : Compteurs de chocs).

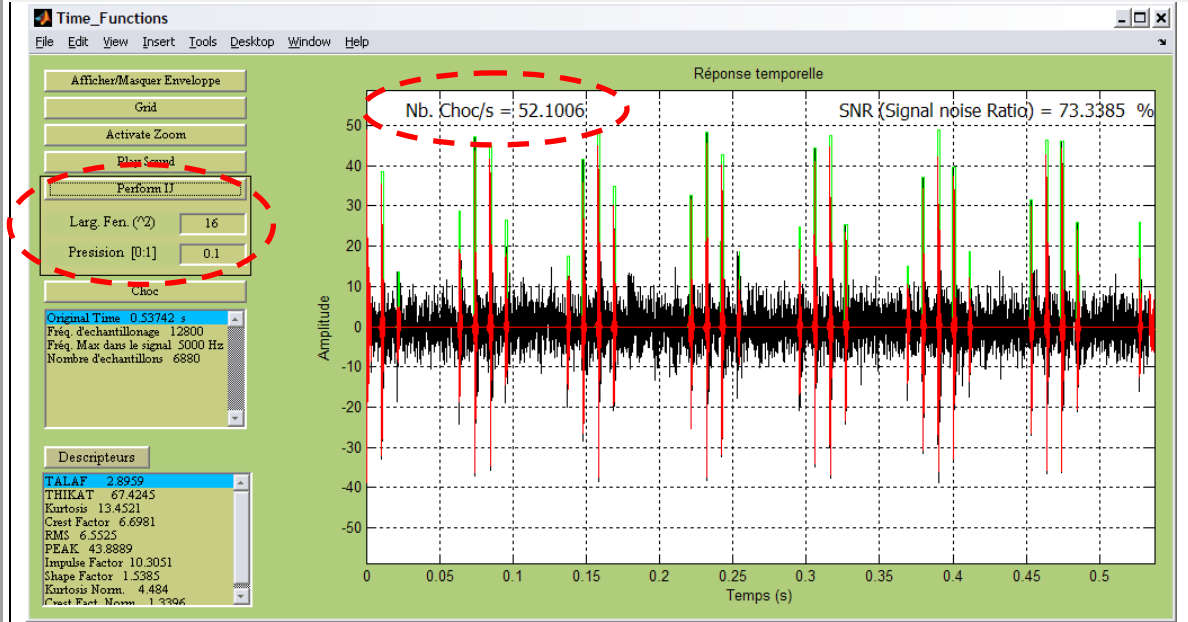
Tous ces descripteurs seront d'une utilité certaine lorsque viendra le temps de traiter des configurations plus compliquées, tel la présence de 2 ou plusieurs défauts simultanément sur la même bague.

Bibliographie

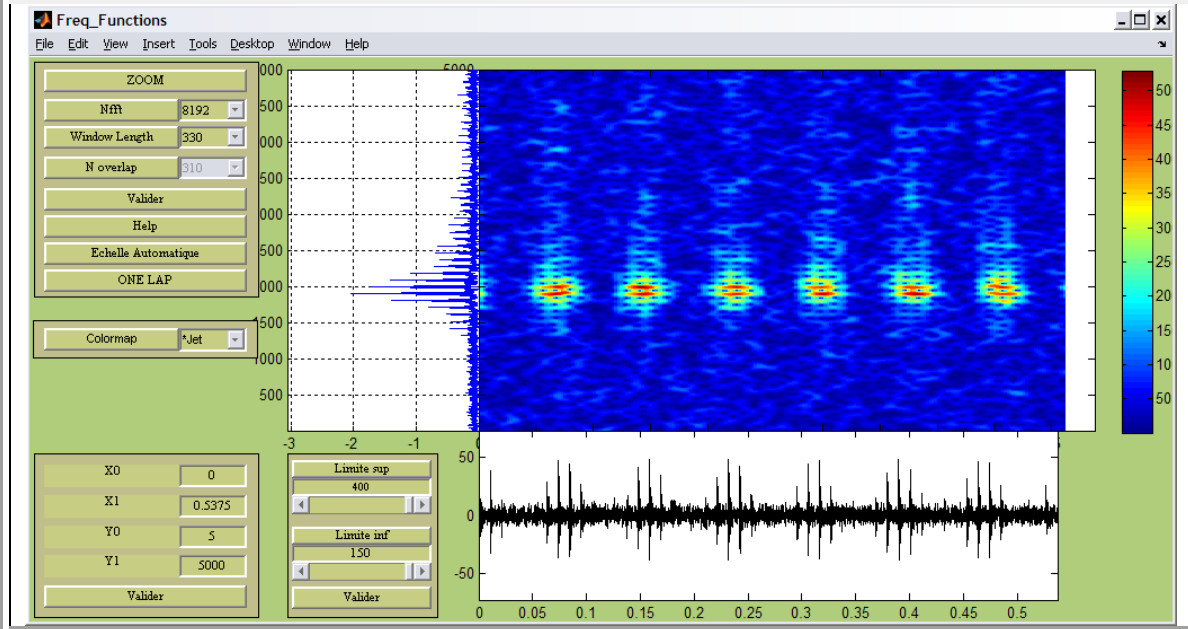
- [1]. **Badri B.**, Thomas M. and Sassi S., October 2004, BEAT, [A numerical simulator for ball bearing affected by localized defects](#), Proceedings of the 22nd Seminar on machinery vibration, Canadian Machinery Vibration Association, Ottawa, ON, 13 p. (Appui financier du CRSNG)
- [2]. **Badri B.**, Thomas M. et Sassi S., Janvier 2004, Caractérisation numérique et expérimentale du comportement vibratoire de roulements endommagés, Conférence ACVM, Montréal. (Appui financier de CRSNG).
- [3]. **Badri B.**, Thomas M., Archambault R. et Sassi S., October 2005, **La transformée de Julien: une nouvelle procédure de traitement de signal pour la détection des chocs.** Proceedings of the 23rd Seminar on machinery vibration, Canadian Machinery Vibration Association, Edmonton, AB, 10 p. (Appui financier du CRSNG)
- [4]. Hong Guo et al. Feature Generation Using Genetic Programming With Application to Fault Classification. IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETICS—PART B: CYBERNETICS, VOL. 35, NO. 1, FEBRUARY 2005
- [5]. B.Samantha and al. Bearing Fault Detection Using Artificial Neural Networks and Genetic Algorithm, Journal on applied signal processing 2004:3,366-377

Annexe

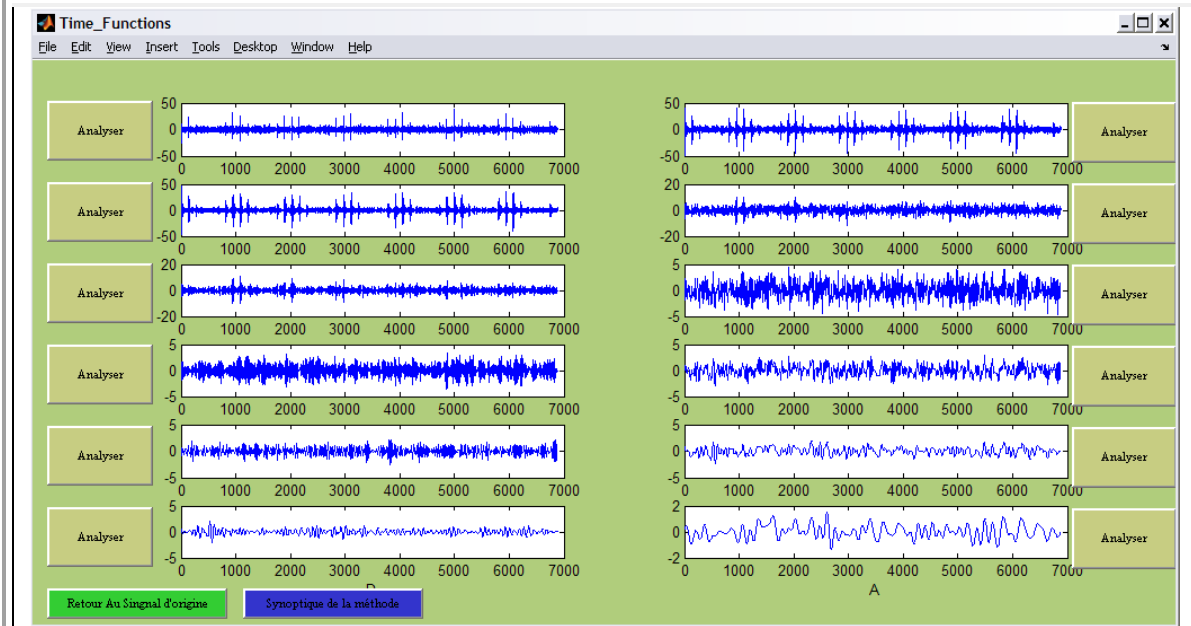
Index Julien (Compteurs de chocs)



Spectrogramme Temps-Fréquences (via STFT)



Décomposition par ondelettes (Wavelett)



Analyse cepstrale

