

## Détection précoce de fuites aux soupapes de moteurs Diesel de forte puissance par analyse des vibrations

O.BARDOU , M.WATREMETZ, T.BOURAS , M.SIDAHMED

CETIM, 52 Avenue Félix Louat, 60300 SENLIS

### Résumé

Nous proposons dans cet article une approche pour la détection des fuites aux soupapes de moteurs Diesel industriels. Actuellement, il n'existe pas d'appareillage capable de détecter précocement ce type de défaut par l'utilisation de capteurs de vibration faciles à installer. C'est pourquoi nous nous sommes intéressés à des techniques de traitement du signal et de reconnaissance des formes pour y parvenir. Le premier domaine a fourni les outils capables d'extraire des paramètres représentatifs des états de fuite (coefficients AR, cepstraux, de réflexions, etc ...). Le deuxième a apporté la possibilité "d'automatiser" la détection d'une fuite par classification grâce à l'utilisation de réseaux de neurones et ainsi déboucher sur le diagnostic.

### I Introduction

Actuellement la présence et l'évolution des fuites aux soupapes est fort préjudiciable pour les utilisateurs de moteurs Diesel puisque ce type d'avarie peut conduire rapidement à la destruction de ces machines. Ainsi les constructeurs se sont mis en quête de moyens pour détecter la présence des fuites et ce le plus précocement possible afin de pouvoir intervenir et changer le cas échéant la soupape défailante. La surveillance vibratoire de systèmes mécaniques est une technique maintenant bien rodée et relativement facile à mettre en oeuvre [1] [2] [3] [4]. Elle fournit de précieux renseignements quant aux sollicitations dynamiques des pièces en mouvement dans la machine à surveiller. De plus, cette solution a démontré son efficacité dans d'autres cas industriels pour la maintenance conditionnelle [5] [6]. La complexité des signaux de moteur nous a conduit à utiliser des techniques de traitement du signal et de reconnaissance des formes pour atteindre le double objectif de détection précoce indépendamment des conditions de charge. Ce dernier point représente d'ailleurs un obstacle à l'utilisation des techniques de l'analyse vibratoire classique.

### Abstract

In this paper a new approach to detect leakage of outlet valves in Diesel engines is proposed. There is no equipment today, enabling early detection of this kind of default by using vibrations transducers which are easy to install. In this purpose we concentrated our works on signal processing and pattern recognition. Signal processing provides tools to extract some efficient parameters to define leakage state (AR, cepstrum, reflexion coefficients, etc ...). Pattern recognition allows "automatic detection" of leakage using neural network. Hence diagnostic is successfully carried out.

### II Diagnostic par reconnaissance de formes

Le problème est donc de mettre en oeuvre un moyen de détection capable de discriminer deux états (ou classes), à savoir dans un premier temps la présence ou non de fuites. Le signal recueilli pour un cycle moteur (deux tours de vilebrequin) est fortement non-stationnaire. De plus pour ce qui concerne les moteurs à explosion comme les Diesel, on ne peut pas tenir compte d'un caractère stationnaire du signal cycle à cycle. D'ailleurs un moyennage temporel de plusieurs réalisations de cycle ne permet plus de différencier les diverses configurations de valeurs de fuite. Afin de prendre en compte cet aspect non-stationnaire, plusieurs cycles moteur ont été recueillis afin de constituer une classe de réalisations (ou individus) représentatifs d'un état de dégradation de la soupape et ce, pour différentes valeurs de fuite (Voir Tableau I)

#### II-a Reconnaissance de formes

Pour effectuer au mieux cette discrimination, il faut d'abord nous assurer qu'il peut y avoir séparation des classes présentes. Pour cela, plusieurs outils statistiques existent dont l'Analyse



en Composantes Principales (ACP) qui permet en premier lieu d'apprécier la dispersion des données constituant les individus d'une classe [7] [8]. On peut alors éventuellement procéder à une réduction de l'ensemble des données pour tous les individus par ce prétraitement. Intervient alors la reconnaissance de forme qui doit permettre d'attribuer à chaque individu l'appartenance à une classe donnée. N'ayant pas de connaissances a priori sur la statistique des individus, nous avons naturellement laissé de côté les discriminations dites paramétriques (Règle de Bayes, ...). De même celles non paramétriques (Parzen, Kplus proches voisins) ainsi que les méthodes de distance n'ont pas retenu notre attention. Par contre, le calcul direct de frontières s'est avéré séduisant par sa facilité de mise en oeuvre en grande partie due à l'existence de produits performants dans ce domaine et en particulier les réseaux de neurones [8].

## II-b Réseaux neuronaux

Les réseaux neuromimétiques connaissent actuellement un essor certain et trouvent des applications dans divers domaines (biologie, physique, traitement du signal, etc ...). Ils réalisent des discriminations, linéaires ou non, de formes par minimisation d'une fonction coût et par le choix d'une fonction de transfert [8]. Le type de réseau choisi ici est un perceptron multi-couches à une couche cachée et l'algorithme d'optimisation du réseau est une méthode classique de rétro-propagation de gradient. Le nombre des cellules dans la couche d'entrée dépend de la dimension des vecteurs d'observation. Pour la discrimination de deux classes, la couche de sortie possède deux cellules. Lors de l'apprentissage elles sont forcées à (1,0) pour la classe "sans-fuite" et à (0,1) pour celle "avec-fuite" (la fonction de transfert est dans ce cas une sigmoïde). Celui-ci s'effectue sur l'ensemble ou base d'apprentissage constitué des deux classes à discriminer. Le nombre d'itérations est fonction de la non-linéarité des frontières. Une fois les poids des connexions stabilisés, il est possible de présenter en entrée du réseau un individu qui sera alors classé dans l'une ou l'autre des deux formes (fuite ou non-fuite)

## III Choix des paramètres caractéristiques

Il est bien sûr impossible de présenter tous les points de numérisation du signal sur un cycle moteur en entrée du réseau de neurones. Cela nécessiterait trop de cellules dans cette couche. Il fallait donc trouver un moyen de réduire la dimension des vecteurs d'entrée tout en caractérisant un état de dégradation de la soupape. Pour l'obtenir, nous avons choisi des paramètres

pertinents représentatifs de cette dégradation. En analyse vibratoire il existe une palette de traitements afin d'extraire l'information recherchée sur la machine instrumentée (calculs de seuils, statistiques, démodulation, cepstre, analyse spectrale, etc ...). L'élaboration des algorithmes rapides de transformée de Fourier ont permis l'adoption de l'analyse spectrale pour la surveillance des machines. Il faut savoir que ces moteurs fonctionnent généralement en palier c'est à dire à charge et à vitesse fixe. En cours de fonctionnement il arrive fréquemment que ces deux derniers paramètres évoluent vers d'autres valeurs de palier. Cela dépend des besoins de l'utilisateur ou d'un système de commande (moteur marin, groupe électrogène, etc ...). Sur ces machines, les conditions de fonctionnement sont donc variables. La méthode développée ici tient compte de cet aspect et en particulier du caractère évolutif de la charge. Cela s'avère plus difficile pour un système classique de surveillance des machines, d'appréhender ces évolutions lors du diagnostic. Ici nous nous sommes limités à deux types d'approches pour l'élaboration des paramètres de caractérisation recherchés.

### III-a Approche non-paramétrique

Après examen des spectres obtenus à partir des signaux recueillis pour différentes valeurs de section de fuite, il nous est apparu que l'énergie présente dans certaines gammes de fréquences évoluait significativement [9] [10]. Le calcul de cette énergie a été ainsi conduit dans six gammes de fréquences (Fig 2) pour obtenir six valeurs énergétiques, les  $\{E_i\}$ .

### III-b Approche paramétrique

En se basant sur la décomposition de Wold, on peut envisager une modélisation AR de notre signal accélérométrique. Ainsi un modèle d'ordre 6 a été choisi et le calcul fournit six coefficients  $\{a_i\}$  pour chaque état de dégradation de la soupape. Ces derniers se calculent par minimisation de l'Erreur de Prédiction Linéaire (EPL) donnée par :

$$e_n = y_n - \sum_i a_i y_{n-i}$$

soit finalement

$$\text{Min} \left\{ \sum_i e_i^2 \right\}$$

Il est apparu aussi que les coefficients de réflexion  $\{k_i\}$  calculés directement sur les échantillons du signal par l'algorithme de Burg, donnent de bons résultats pour la classification [11]. De même les coefficients cepstraux  $\{c_i\}$  calculés à partir des  $\{a_i\}$  sont réputés pour leur capacité à classer des signaux [12].

## IV Applications et résultats

Un accéléromètre a été fixé sur la culasse à proximité d'une soupape d'échappement d'un moteur Diesel de 750kW et les essais ont été menés pour différents états de dégradation correspondant à différentes valeurs de section de fuite. Ainsi les signaux délivrés par ce capteur ont pu être recueillis pour être traité. La portion de signal intéressante sur un cycle moteur concernait la phase fin de compression-début d'injection (Fig. 1). En effet c'est dans cette période du cycle que sont présentes les plus fortes pressions à même de produire des sollicitations dynamiques au niveau de la soupape considérée (échappement). En se basant sur l'examen d'une image Temps-Fréquence calculée pour cette portion, il apparaît que la bande de fréquence utile s'étale jusqu'à 25kHz incluant la résonance du capteur [13] [14]. De plus il fallait tenir compte des conditions de fonctionnement variables évoquées plus haut. C'est pourquoi toutes les acquisitions effectuées pour différentes valeurs de section de fuite ont été reconduites pour diverses valeurs de charge (0 à 100%). Dans cette étude nous nous sommes intéressés aux charges médiane et maximale (50 et 100%). Une vingtaine d'individus ou réalisations ont ainsi été produits pour chaque couple (fuite, charge) (Tableau I). Nous sommes partis du cas le plus favorable (0 - 36 mm<sup>2</sup>) pour une classification au cas le plus défavorable (0 - 0.3 mm<sup>2</sup>) en utilisant à chaque fois les {Ei}, {ki}, {ai} et {ci}. L'apprentissage par le réseau de neurones s'étant effectué avec succès pour les quatre types de paramètres, leurs performances respectives ont pu être évaluées au vu du nombre d'itérations nécessaires pour classer correctement tous les individus des bases d'apprentissage (Tableau II). Il s'avère que nous avons obtenu de façon générale une plus grande robustesse des {ki} pour la convergence du réseau. Viennent ensuite les {ai} et {ci} relativement comparables en efficacité. En dernier les {Ei}, malgré leurs performances modestes par rapport aux autres paramètres, apportent néanmoins une classification correcte de tous les vecteurs d'une base. Et de façon générale, la classification s'opère plus facilement à charge élevée qu'à charge moyenne. Ce résultat d'ailleurs prévisible en utilisant ceux de l'ACP qui montrent une bien meilleure séparation des formes à 100% qu'à 50%. Nous avons confirmé les résultats de l'apprentissage en présentant quelques individus nouveaux en entrée du réseau. Ces derniers avaient été recueillis pour la configuration 0.3 mm<sup>2</sup> et n'appartenaient pas à la base d'apprentissage constituée pour cette fuite. Ils ont été correctement classés après présentation, les uns dans la classe fuite et les autres vers celle non-fuite. Bien sûr nous avons procédé à

l'apprentissage du réseau sur une base qui permettrait la classification d'un individu représentatif d'un état de fuite ou de non-fuite, ce indépendamment de la charge. Une base a donc été constituée à partir des individus des états {0 mm<sup>2</sup>, 50%}, {0 mm<sup>2</sup>, 100%}, {0.3 mm<sup>2</sup>, 50%} et {0.3 mm<sup>2</sup>, 100%}. Nous avons choisi le cas de fuite minimale pour cet apprentissage puisqu'il correspond au but recherché c'est à dire la précocité du diagnostic. La convergence du réseau sur cette base est encore assurée et cela permet le diagnostic d'une fuite faible telle 0.3 mm<sup>2</sup> indépendamment des conditions de fonctionnement.

## V Conclusion

L'approche par cette méthode de traitement des signaux vibratoires apporte il est vrai une dimension nouvelle pour la maintenance conditionnelle dans un sens prédictif. Il ne faut pas néanmoins perdre de vue que l'automatisation par l'utilisation d'un réseau de neurones s'avère délicate à mettre au point. Il est en effet nécessaire de procéder à plusieurs apprentissages avec différentes valeurs d'initialisation des poids de connexions pour tendre vers une convergence satisfaisante sur la base d'apprentissage sous peine d'aboutir à des convergences vers des minima locaux. Les résultats observés sont encourageants puisqu'ils se rapprochent du diagnostic en milieu industriel c'est à dire effectué à charge variable. Il est difficile de relier les performances du réseau de classification avec le nombre de cellules sur les couches d'entrée et cachée ou bien avec le nombre d'individus constituant la base d'apprentissage. La difficulté de la méthode de diagnostic envisagée a donc été surmontée par le calcul des paramètres discriminants et leur classification. Celle-ci, il est clair, apparaît plus performante en utilisant les coefficients des modèles qu'en utilisant les calculs des valeurs énergétiques des bandes de fréquences. Il est tout à fait envisageable d'utiliser d'autres formes d'élaboration de paramètres pertinents qui pourraient décrire d'autres avaries qui surviennent sur les moteurs Diesel (cliqueti, etc ...) voire sur d'autres machines tournantes. D'autre part il est important de signaler que l'expérimentation pour obtenir une banque de signaux sur ce type de machine n'est pas aisée dans un contexte industriel. D'où le nombre d'individus de la base d'apprentissage relativement peu important et qui mériterait d'être augmenté afin d'aboutir à des résultats encore plus probants.



Références

[1] D.CARREAU, "Surveillance des roulements par l'analyse des vibrations" - CETIM Information N° 115

[2] Cours CETIM "Vibrations"

[3] S.BRAUN, "Mechanical Signature Analysis" - Academic Press

[4] M.SIDAHMED, Y.GRENIER, "Le traitement du signal en mécanique" - Recueil de conférences, CETIM

[5] JC.LECOUFLE, "Objectif zéro panne" - CETIM Informations N° 109

[6] A.BOULENGER, "Vers le zéro panne avec la maintenance conditionnelle" - Ed. AFNOR

[7] L.LEBART, A.MORINEAU, JP.FENELON, "Traitement des données statistiques" - Ed. DUNOD

[8] B.DUBUISSON, "Diagnostic et reconnaissance des formes" - Ed. HERMES

[9] P.GRIVELET, "Surveillance des compresseurs alternatifs par les vibrations" - Recueil CETIM

[10] RH.LYON, "Machinery noise and diagnostics" - Ed. Butterworths

[11] M.BASSEVILLE, "Distance en traitement du signal et reconnaissance des formes" - IRISA Publication interne N° 412 Juin 1988

[12] S.McKAY, "Modern spectral estimation theory & application" - Prentice Hall 1987

[13] P.FLANDRIN, "Représentation Temps-Fréquence des signaux non-stationnaires" - TS Vol 2 ,1989

[14] M.CHIOLLAZ, B.FAVRE, "Caractérisation fine de bruits moteur" - Courrier CNRS Juin 1991

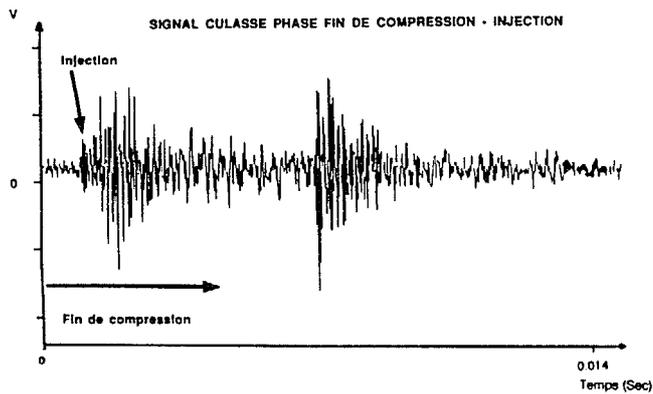


Figure 1

Valeur de fuite	0 mm <sup>2</sup>	0.3 mm <sup>2</sup>	1 mm <sup>2</sup>	36 mm <sup>2</sup>
Charge				
50%	20	20	20	20
100%	19	20	20	19

Tableau I

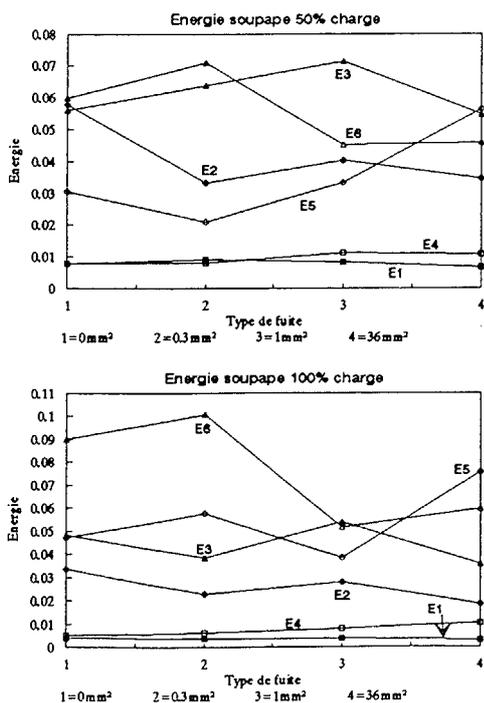


Figure 2

Paramètres	Ei	ai	ki	ci
Configuration				
0 - 36 mm <sup>2</sup>	N # 2400	N # 300	N # 300	N # 300
50%				
0 - 1 mm <sup>2</sup>	N # 60000	N # 30000	N # 28000	N # 30000
50%				
0 - 0.3 mm <sup>2</sup>	N # 5000	N # 25000	N # 8000	N # 25000
50%				
0 - 36 mm <sup>2</sup>	N # 960	N # 220	N # 320	N # 280
100%				
0 - 1 mm <sup>2</sup>	N # 3000	N # 220	N # 340	N # 240
100%				
0 - 0.3 mm <sup>2</sup>	N # 50000	N # 700	N # 1700	N # 500
100%				
0 - 0.3 mm <sup>2</sup>	N # 80000	N # 25000	N # 25000	N # 34000
50 et 100%				

N = Nombre d'itérations du réseau pour assurer une convergence lors de l'apprentissage avec une erreur RMS de sortie inférieure à 0.03%

Tableau II