

Diagnostic d'un système non stationnaire à partir d'une approche de reconnaissance des formes floue. Application au diagnostic de cliquetis moteur

A non-stationary system diagnosis using fuzzy pattern recognition. Application to engine knock diagnosis

par Jean-Hugh THOMAS

Institut d'Acoustique et de Mécanique (IAM)
Ecole Nationale Supérieure des Ingénieurs du Mans (ENSIM)
Université du Maine
Rue Aristote
72085 Le Mans cedex 9
Tél 02 43 83 39 55, Fax 02 43 83 37 94
e-mail : jean-hugh.thomas@univ-lemans.fr

résumé et mots clés

Le cliquetis dans les moteurs à allumage commandé demeure un problème pour les motoristes. La détection de cliquetis doit en effet permettre de réaliser un compromis entre l'optimisation du rendement du moteur, la consommation de la voiture et le respect des normes en matière de dépollution. Souvent l'allumage est réglé avec une marge de sécurité qui garantit l'absence de cliquetis même en cas de variations de la qualité du carburant. L'enjeu de l'élaboration d'une méthode de détection de cliquetis est de se rapprocher le plus possible des conditions limites de cliquetis tout en évitant son apparition. L'objectif de l'étude présentée consiste à évaluer l'intensité du cliquetis produit dans la chambre de combustion à partir d'un enregistrement fourni par un accéléromètre placé sur le bloc moteur. Son but est de reconnaître trois types de cliquetis : l'absence de cliquetis, le cliquetis naissant et le cliquetis violent. L'approche envisagée pour mener à bien cette détection fait appel aux techniques du diagnostic par reconnaissance des formes floue. L'ensemble des modules mis en œuvre conduisant au diagnostic est décrit ainsi que leurs fonctionnalités. Une expérimentation sur données réelles acquises sur banc moteur est proposée. La méthode, mise au point à l'aide d'un ensemble d'apprentissage, conduit à la réalisation de plusieurs processus de diagnostic qui coopèrent.

Diagnostic en mode supervisé, reconnaissance des formes floue, analyse temps-échelle, détection de cliquetis.

abstract and key words

Knock is a well-known problem for spark-ignition engine manufacturers. Knock detection helps achieve the best compromise between increasing engine efficiency, fuel consumption and present requirements with regard to exhaust emission legislation. The ignition timing is usually controlled so that knock never occurs even with fuel quality changes. The advantage of a knock detection method is to work within close range of knocking conditions but avoid its occurrence. The purpose of our study consists in highlighting several knock intensities from block vibration signals provided by an accelerometer. Our aim is to differentiate three kinds of engine cycles : absence of knock, increasing knock and heavy knock. The developed diagnostic approach deals with fuzzy pattern recognition. After describing the diagnostic architecture line modules and their functions, experimental results from data acquired from an engine test bench are reported. The method, experimented on a learning set, leads to several diagnoses that cooperate.

Supervised diagnosis, Fuzzy pattern recognition, Time-scale analysis, Knock detection.

1. introduction

Le phénomène de cliquetis au cours du fonctionnement d'un moteur à allumage commandé suscite une attention particulière de la part des motoristes depuis le début des années vingt. Cette attention est toujours soutenue aujourd'hui, comme le témoigne l'abondance des écrits sur le sujet dans la littérature récente. Le problème du cliquetis n'est donc pas complètement résolu. L'explication physique de son avènement, sa détection, la tentative de minimiser ses effets sont autant d'axes d'étude pour les chercheurs. Néanmoins, chacun semble s'accorder sur la description du cliquetis en tant que phénomène de combustion indésirable ainsi que sur les méfaits qu'il entraîne sur la durée de vie du moteur.

Le souci permanent d'amélioration du rendement des moteurs couplé aux exigences en matière de dépollution des gaz d'échappement conduisent les motoristes à se rapprocher des conditions de fonctionnement limites de cliquetis. C'est pourquoi il est prépondérant de savoir caractériser ce phénomène afin d'envisager de le détecter.

Chacun s'accorde pour situer l'apparition du cliquetis à l'intérieur de la chambre de combustion. Conséquence de l'avènement incongru de pointes de pression, le cliquetis doit son nom au bruit métallique occasionné par des vibrations de la chambre. Les signaux délivrés par les capteurs de pression et les accéléromètres sont les grandeurs le plus souvent exploitées pour caractériser le cliquetis [Chu89,Puz92,Chu94,Fer96]. Bien souvent ils ne sont pas utilisés à l'état brut mais subissent certaines transformations du domaine du traitement du signal. Il s'agit de déterminer les paramètres d'un signal les plus aptes à témoigner de la présence de cliquetis et à quantifier sa sévérité. Cette étape de caractérisation du phénomène est fondamentale pour envisager de le détecter avec le moins d'incertitude possible. L'information véhiculée par les capteurs peut être traitée de plusieurs façons : certains paramètres extraits sont issus d'une analyse temporelle du signal, d'autres d'une approche fréquentielle [Puz92,Barg95,Fer96] ou encore de méthodes temps-échelle, temps-fréquence [Chi87,Gue94].

Quelques auteurs préconisent l'emploi de méthodes de détection appartenant à la reconnaissance des formes [Bart92,Mol95]. La présente étude s'inscrit dans ce cadre. Son objectif est l'élaboration d'un processus de diagnostic capable de détecter, à partir de signaux vibratoires, trois situations pour un cycle de combustion : l'absence de cliquetis, la présence de cliquetis naissant et celle de cliquetis violent. Les signaux vibratoires sont enregistrés au moyen d'un accéléromètre placé sur le bloc moteur. Le choix de ce type de capteur au détriment du capteur de pression a été motivé par le faible coût de son installation.

Nous proposons un agencement de modules destinés à extraire et sélectionner les caractéristiques pertinentes du signal vibratoire puis à qualifier l'intensité de cliquetis par rapport aux trois catégories prédéfinies. La prise de décision naît d'une coopération originale entre plusieurs diagnostics. Les techniques employées

font appel à la reconnaissance des formes floue. Il s'agit dans un premier temps de construire un vecteur appelé *vecteur forme* dont les composantes sont censées caractériser le cycle de fonctionnement étudié. Les composantes sont déterminées à partir d'une analyse temps-échelle du signal vibratoire. Chaque forme ainsi créée est représentée par un point dans un espace R^d où d désigne le nombre de composantes du vecteur. L'intensité du cliquetis pour une forme x se déduit de la localisation de x dans l'espace de représentation. Si la représentation est bonne, on peut espérer que trois régions différentes de l'espace correspondent aux trois classes de cliquetis. L'appartenance de la forme x à une région de l'espace de représentation permet de déduire l'intensité du cliquetis du cycle étudié.

La notion de flou associée à la reconnaissance des formes permet non pas d'associer une forme à une classe de façon exclusive mais de situer cette forme par rapport à toutes les classes existantes. Un degré d'appartenance compris dans l'intervalle $[0, 1]$ est fourni à la forme étudiée pour chaque classe. Si ce degré est proche de 0, la forme est considérée très différente de la classe. A l'inverse, un degré voisin de 1 indique une forte ressemblance entre la forme et les individus de la classe.

Au cours d'une démarche de diagnostic en mode supervisé, l'intensité du cliquetis est déterminée parmi un nombre fini, en l'occurrence trois, d'états connus, supposés bien documentés. La mise au point d'un tel processus de diagnostic nécessite l'utilisation d'une base de signaux représentatifs des intensités de cliquetis que l'on souhaite reconnaître. C'est la *base d'apprentissage*. Une autre base distincte dite *base de validation* est également nécessaire dans le but d'expérimenter et valider la méthode de diagnostic proposée.

Les jeux de données expérimentales sont présentés dans la deuxième partie. Les diverses fonctionnalités de la méthode de diagnostic ainsi que sa réalisation sont détaillées au cours de la troisième partie. Le quatrième chapitre présente les résultats obtenus sur des données réelles enregistrées sur un banc moteur de PSA Peugeot-Citroën.

2. la base de travail

2.1. acquisition des données

Les données sont enregistrées à une fréquence d'échantillonnage de 200 kHz de façon à appréhender les composantes inaudibles du phénomène de cliquetis même si les motoristes se contentent très souvent de signaux filtrés dans une bande 5-10 kHz ou parfois dans des bandes plus larges : 4-12 kHz [Puz92], 3-20 kHz [Fer96]. La figure 1 illustre six voies d'acquisition : les quatre premières montrent les signaux de pression correspondant à chacun des quatre cylindres, la cinquième, les tops tour vilebrequin et la dernière,




Figure 1. – Séquence d'acquisition représentant un cycle moteur (deux tours vilebrequin) sur chaque cylindre.

le signal capté par l'accéléromètre placé sur le bloc moteur entre les cylindres 2 et 3. Une septième voie délivre les demi-degrés vilebrequin. Le signal vibratoire issu de l'accéléromètre constitue le point de départ de notre étude. Les acquisitions sont synchronisées sur le cylindre 1 ou le cylindre 4 à l'aide des tops tour. Nous travaillons à partir d'une série de mesures effectuées à un régime moteur de 5600 tr/mn avec une avance à l'allumage fixe de 22.5° vilebrequin. A un tel régime, le signal vibratoire est très bruité rendant le cliquetis difficilement décelable.

2.2. segmentation des signaux

Le cliquetis se manifeste à des moments spécifiques du cycle moteur par l'apparition d'oscillations situées après le pic d'amplitude maximale du signal de pression. Il est donc préférable d'observer le signal autour de ce pic à l'intérieur d'une fenêtre temporelle. Il faut également s'assurer que d'autres phénomènes ne viennent pas ajouter leurs signatures dans la plage choisie. Des vibrations occasionnées par les rebonds des soupapes sur leurs sièges lors de leurs fermetures apparaissent immédiatement après le cliquetis.

Lors d'une étude précédente, nous avons décidé de définir la fenêtre d'observation par rapport au pic-même du signal de pression [Tho97]. La fenêtre s'étendait alors sur 35° vilebrequin (15° avant le pic de pression maximal, 20° après). Le choix d'une telle fenêtre présente l'avantage d'être indépendante du régime moteur considéré et de l'avance à l'allumage réglée. Cependant il nécessite de rechercher le maximum du signal de pression, ce qui constitue une contrainte pour une segmentation du signal en temps-réel.

Pour la présente étude, nous avons choisi de privilégier l'aspect temps-réel de la méthode. C'est pourquoi la segmentation est




Figure 2. – La fenêtre d'étude du cliquetis a une durée fixe de 0.88 ms représentant environ 30° vilebrequin.

synchronisée par rapport au point-mort haut (*PMH*), représentant la position haute maximale du piston dans le cylindre et directement déductible des enregistrements fournissant les tops tour et les demi-degrés vilebrequin. La fenêtre d'observation choisie démarre au *PMH* et s'étend sur une durée correspondant à une rotation de 30° environ du vilebrequin (*cf.* figure 2), la précédente étude ayant montré que l'on pouvait diminuer l'étendue de la plage (de 35° à 30°). La longueur relativement étroite de la fenêtre permet d'éviter la prise en compte des oscillations du signal vibratoire dues aux rebonds occasionnés par l'ouverture et la fermeture des soupapes.

L'étape de segmentation va également permettre d'isoler les signaux concernant un seul cylindre. Tous les cylindres n'ont en effet pas la même sensibilité au cliquetis. L'étude est axée sur le cylindre 3 très enclin, d'après les motoristes, au cliquetis.

2.3. base d'apprentissage

Afin de mettre au point le processus de diagnostic, il est nécessaire de se procurer un ensemble de signaux vibratoires présentant de façon assez équitable les trois intensités de cliquetis *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent*. Se pose alors le problème de l'étiquetage des signaux. L'étiquetage est déterminant puisque le processus de diagnostic est construit sous l'hypothèse que tel signal d'apprentissage est bien représentatif de tel type de cliquetis. C'est pourquoi, l'étiquetage des signaux vibratoires est réalisé par un motoriste, expert en cliquetis, qui observe minutieusement l'enregistrement des signaux de pression correspondant. La présence de fortes oscillations ou de faibles fluctuations après le pic de pression maximal lui permet de choisir l'étiquette de chaque cycle (*cf.* figure 3). Les signaux, représentés à la même échelle, ont été préalablement segmentés.




Figure 3. – Signaux de pression cylindre : a) cliquetis absent, b) cliquetis naissant, c) cliquetis violent.

La base d'apprentissage est constituée de 117 cycles de combustion correspondant au cylindre 3, répartis de façon assez homogène :

- 40 cycles sans cliquetis,
- 32 cycles présentant du cliquetis naissant,
- 45 cycles du cliquetis violent.

2.4. base de validation

Un nouveau jeu de données, appelé ensemble de validation, est expérimenté sur le processus de diagnostic mis en œuvre afin de le valider. Cet ensemble de signaux vibratoires doit être acquis dans des conditions opératoires similaires à celles utilisées pour la constitution de l'ensemble d'apprentissage. Or pour ces conditions, nous ne disposons malheureusement pas d'enregistrements de signaux vibratoires correspondant au cylindre 3 hormis les 117 cycles utilisés dans la phase d'apprentissage. Nous nous sommes tournés vers les acquisitions concernant le cylindre 4 voisin du 3 d'autant plus que les signaux concernant le cylindre 2 se sont avérées non exploitables.

L'ensemble de validation est ainsi constitué de 117 cycles dont la répartition, peu homogène, est indiquée ci-dessous :

- 85 cycles sans cliquetis,
- 26 cycles présentant du cliquetis naissant,
- 6 cycles du cliquetis violent.

3. le processus de diagnostic

3.1. présentation

La chaîne de traitement mise en œuvre s'appuie sur six modules (cf. figure 4).

Avant d'explicitier en détail les quatre derniers modules de la chaîne, dégageons leurs principales fonctionnalités :

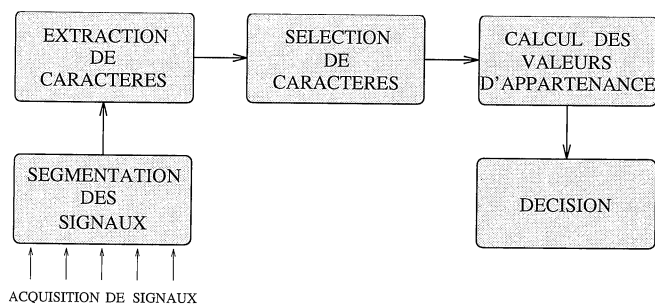


Figure 4. – Architecture de la chaîne de diagnostic.

- *Extraction de caractères* : Cette fonction primordiale va conditionner la mise au point et le succès du processus de diagnostic. Son but est de mettre en évidence l'information contenue dans les signaux vibratoires caractéristique d'un mode de fonctionnement du système. Cette information est susceptible de permettre la reconnaissance de ces modes. A l'issue de cette phase, un vecteur forme contenant toute l'information pertinente extraite est constitué. L'espace de représentation des données, défini par les caractères ou composantes du vecteur forme, est ainsi fixé.
- *Sélection de caractères* : La sélection de caractères se charge de réduire la dimension de l'espace de représentation en choisissant les caractéristiques les plus pertinentes pour la reconnaissance. Cette étape est nécessaire afin d'une part de simplifier le processus de diagnostic, d'autre part de le rendre « optimal » du point de vue de la pertinence du vecteur forme.
- *Calcul des valeurs d'appartenance* : Le propre de ce module est d'associer à chaque classe de fonctionnement une fonction d'appartenance qui permet de définir les frontières entre ces classes. Ainsi chaque observation du système à une date t se voit affecter une valeur d'appartenance aux différents modes de fonctionnement répertoriés. En d'autres termes, chaque état observé est situé par rapport aux états connus. Son degré de ressemblance à ces états est évalué.
- *Système de décision* : A partir des valeurs d'appartenance fournies par le précédent module, il donne son verdict en se référant à une règle de décision déterminée. La règle est définie dans un espace de décision construit à partir des états

du système à reconnaître. Ce module tranche sur l'appartenance de l'état observé aux modes de fonctionnement prédéfinis. Pour ce faire, il entreprend une procédure de fusion de plusieurs diagnostics préalablement établis. Différents processus de diagnostic émanent en effet de différents choix opérés lors de la sélection de caractères. Les formes à classer s'expriment dans des espaces de représentation différents suivant le processus considéré.

La démarche qui consiste à juxtaposer ces différents modules se rapproche des travaux de F. Molinaro et F. Castanié [Mol95] bien que ceux-ci n'utilisent pas de module de calcul des valeurs d'appartenances. Pour ce qui est des autres modules, même s'ils ont la même finalité, les fonctions réalisées sont différentes. Quant à l'approche développée par R. Bartz, G. Schmitz et P. Böhnke [Bart92], elle diffère nettement de l'étude développée ici. En effet, leurs travaux sont basés sur l'utilisation de deux types de méthodes : les méthodes des nuées dynamiques et le calcul direct de frontières afin d'exploiter des classifications en deux classes.

Ajoutons que notre système de décision permet de ne pas systématiquement associer une forme à une classe. En effet, une observation peut traduire un mode de fonctionnement situé entre deux modes prédéfinis ou bien indiquer un mode très différent des modes documentés. Dans ces deux cas de figure, l'affectation de la forme à une classe conduirait à une erreur de diagnostic. Afin de pallier cette erreur, le processus de diagnostic comporte deux options de rejet : le rejet d'ambiguïté et le rejet de distance (cf. figure 5).

La mise en œuvre du rejet d'ambiguïté conduit à prévoir une classe supplémentaire ω_0 dans laquelle se trouvent toutes les formes dont il est difficile de prouver l'appartenance à une classe plutôt qu'à une autre [Cho57].

Quant aux formes très éloignées des classes en présence dans l'espace de représentation des données, elles seront affectées à une classe ω_d , classe regroupant les formes rejetées en distance [Dub90]. B. Dubuisson souligne tout l'intérêt d'une telle possibilité de rejet de distance puisqu'elle permet la mise en évidence de nouveaux modes de fonctionnement du système et ainsi d'élaborer un processus de diagnostic adaptatif.




Figure 5. – Représentation des options de rejet. La forme X_1 est rejetée en ambiguïté et est affectée à la classe ω_0 . La forme X_2 est rejetée en distance et est associée à la classe ω_d .

3.2. extraction de caractères

Les caractères pertinents extraits lors de cette phase doivent permettre la reconnaissance des trois classes *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent*.

La structure non-stationnaire des signaux vibratoires nous a conduit à envisager une analyse par ondelettes. Dans une première approche, nous avons proposé l'utilisation d'un réseau de neurones à l'architecture particulière : le réseau d'ondelettes de Q. Zhang et A. Benveniste [Zha92]. Bien que les résultats obtenus par cette technique soient encourageants [Tho96d], nous avons décidé d'axer l'étude vers une nouvelle voie : l'analyse multirésolution du signal vibratoire. C'est la capacité de traitement en temps réel de cette analyse qui nous a poussé à explorer cette direction.

L'analyse multirésolution va permettre de s'intéresser successivement à diverses caractéristiques du signal vibratoire. Elle se charge d'observer le signal sous des angles différents. Elle fournit une décomposition du signal à différentes échelles sur des bases orthogonales d'ondelettes. Cette décomposition du signal sur ces bases est alors unique. Les coefficients d'ondelettes n'ont aucune corrélation entre deux niveaux d'échelle. L'analyse multirésolution focalise d'abord sur les détails les plus fins du signal puis s'attache progressivement aux éléments de plus en plus grossiers.

L'analyse multirésolution repose sur l'existence d'une décomposition d'un signal $x(t)$, pour un niveau de résolution, en deux signaux, l'un correspondant à une approximation de $x(t)$, l'autre à des détails, qui, ajoutés à l'approximation, reconstruisent le signal initial. La décomposition de l'approximation du signal échantillonné $x(n)$ fournit, à son tour, deux signaux pour le niveau de résolution immédiatement inférieur et ainsi de suite (cf. figure 6). Les coefficients de détail sont d_1 , d_2 et d_3 . Ils sont obtenus par filtrage (au moyen du filtre de fonction de transfert $G(z)$) suivi de décimation (un échantillon sur deux est retenu) des coefficients d'approximation de la résolution immédiatement supérieure. Les coefficients d'approximation a_1 , a_2 et a_3 sont déterminés de façon similaire au moyen du filtre $H(z)$. Le signal $x(n)$ est parfaitement reconstitué à partir des détails d_1 , d_2 et d_3 et du coefficient d'approximation a_3 . Notons que du fait des décimations successives,

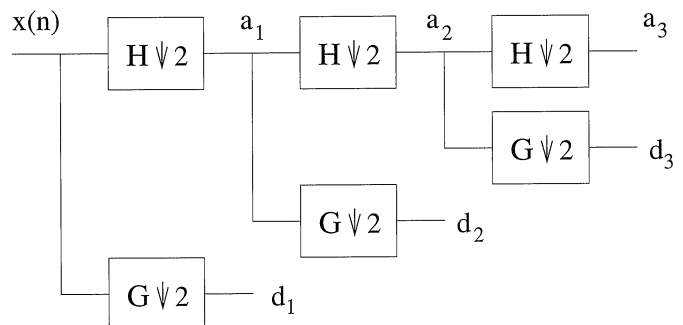


Figure 6. – Analyse sur trois niveaux de résolution d'un signal $x(n)$.

le nombre de coefficients diminue lorsque l'on descend en résolution. L'approximation du signal se fait sur une base de fonctions appelées fonctions d'échelle alors que la décomposition en détails est produite sur une base d'ondelettes. Nous utilisons l'ondelette de Daubechies d'ordre cinq dont les propriétés de régularité semblent adaptées à l'analyse des signaux vibratoires enregistrés.

L'analyse multirésolution est rendue possible par la convolution du signal avec les réponses impulsionnelles de deux filtres en parallèle dont les propriétés sont celles des filtres miroirs en quadrature (QMF) [Est77]. La notion de fréquence est sous-jacente. Le but de l'opérateur H est de lisser le signal $x(t)$, c'est-à-dire d'isoler ses basses fréquences, tandis que l'opérateur G cherche à mettre en valeur les détails du signal représentés par des fréquences plus hautes. Les gabarits idéaux des filtres passe-bas H et passe-bande G sont indiqués sur la figure 7 pour un niveau de résolution j (ν_e désigne la fréquence d'échantillonnage du signal).

En effectuant une analyse multirésolution des 117 signaux vibratoires de la base d'apprentissage sur cinq niveaux de résolution (cf. figure 8), nous cherchons à voir quels sont les niveaux et le type de coefficients, approximation ou détail, qui traduisent le mieux différentes intensités de cliquetis. L'examen visuel des coefficients d'un même niveau pour les trois types de signaux vibratoires nous conduit à privilégier les détails des niveaux 1, 2 et 3. En effet, ceux-ci diffèrent selon le type de cliquetis rencontré (cf. figure 9). Les coefficients sont au nombre de 174 par signal répartis en :

- 93 coefficients de détail de niveau 1,
- 51 coefficients de détail de niveau 2,




Figure 7. – Gabarits des filtres H et G.




Figure 8. – Exemple de décomposition fournie par analyse multirésolution sur 5 niveaux d'un signal vibratoire présentant du cliquetis violent.




Figure 9. – Valeurs des 93 coefficients de détail de niveau 1 pour trois types d'intensité de cliquetis : en haut absence de cliquetis, au milieu cliquetis naissant et en bas cliquetis violent.

- 30 coefficients de détail de niveau 3.

Afin d'évaluer le degré de pertinence des coefficients de détail des trois niveaux de résolution obtenus, nous proposons de construire plusieurs vecteurs forme, en l'occurrence quatre, comportant, soit essentiellement des détails d'un niveau de résolution, soit un mélange de détails de plusieurs niveaux :

- Le premier comporte les détails de niveau 3 (dimension 30),
- le second, ceux de niveau 2 (dimension 51),
- le troisième, ceux de niveau 1 (dimension 93),
- le quatrième, un mélange des détails de tous les niveaux (dimension 174).

Nous obtenons quatre espaces de représentation des données de dimensions différentes. Ces vecteurs forme vont conduire à l'élaboration de cinq processus de diagnostic (un opérant dans chacun des trois premiers espaces de représentation et deux dans le quatrième).

Remarquons que les vecteurs forme proposés diffèrent de ceux des travaux déjà mentionnés précédemment. R. Bartz, G. Schmitz et P. Böhnke [Bart92] utilisent en effet des vecteurs forme à deux dimensions dont les paramètres sont statistiques : moyenne et variance de l'énergie du signal vibratoire. F. Molinaro et F. Castanié calculent d'autres paramètres [Mol95] : un histogramme des amplitudes du signal, l'énergie du signal dans plusieurs bandes de fréquence, ses coefficients de Prony et ses coefficients cepstraux.

3.3. sélection de caractères

3.3.1. principe

L'espace de représentation R^d des signaux $x(t)$, défini lors de la phase d'extraction de caractères, peut être rapidement très grand. Sa dimension est en effet liée au nombre de coefficients de détail fourni par l'analyse multirésolution.

L'objet de la sélection de caractères est de trouver un espace de représentation $R^{d'}$ de dimension inférieure ($d' < d$). Il s'agit de choisir parmi les d caractères, ceux dont les qualités discriminantes sont les meilleures. En effet, ne perdons pas de vue l'objectif de l'étude qui est de reconnaître trois types de cliquetis, d'où l'intérêt de choisir des caractères qui peuvent faciliter la mise en évidence de différences entre ces classes.

A la sortie du module d'extraction de caractères, nous disposons de $n = 117$ formes d'apprentissage réparties respectivement en $n_1 = 40, n_2 = 32$ et $n_3 = 45$ formes représentatives des classes *absence de cliquetis* ω_A , *cliquetis naissant* ω_N et *cliquetis violent* ω_V .

3.3.2. présélection

Avant la sélection proprement dite, nous effectuons lorsque le nombre d de caractères est important, une présélection de d_1 composantes parmi les d initiales ($d' < d_1 < d$). Pour ce faire, nous examinons les composantes en recourant à des histogrammes de chacun des caractères (cf. figure 10). Le but est de détecter les variables qui subissent des fluctuations selon l'intensité du cliquetis du cycle moteur. Celles-ci sont conservées. Il s'agit également de mettre en évidence les variables qui restent relativement inchangées quelle que soit l'intensité du cliquetis, afin de les écarter. L'examen des histogrammes nous a conduit à considérer plutôt les valeurs absolues des coefficients de détail que leurs valeurs réelles. Pour plusieurs caractères, les grandeurs importantes en valeur absolue, correspondent en effet à des cycles de cliquetis violent.




Figure 10. –Présélection de caractères. Le graphe en haut représente les disparités d'un caractère c en fonction des 117 cycles moteur. L'histogramme en bas, permet de rassembler dans des intervalles les cycles dont les composantes c sont voisines.

3.3.3. critère de sélection

La démarche consiste à choisir un vecteur forme de dimension réduite tout en minimisant la perte d'information. Le critère suivant basé sur les matrices de dispersion est retenu :

$$J = \text{trace} (\hat{\Sigma}_W^{-1} \hat{\Sigma}_B) \quad (1)$$

Il tient compte de la géométrie des classes. En effet $\hat{\Sigma}_W$, estimateur de la dispersion des formes à l'intérieur des classes, peut être vu comme un indice de compacité des classes tandis que $\hat{\Sigma}_B$, estimateur de la dispersion entre les classes, exprime un indice de séparabilité. La structuration des formes la plus souhaitable correspondrait à une petite dispersion à l'intérieur des classes et à une grande dispersion entre les classes, c'est-à-dire à des classes compactes éloignées les unes des autres.

L'estimation de la matrice de dispersion intra-groupe $\hat{\Sigma}_W$ est donnée par :

$$\hat{\Sigma}_W = \frac{1}{n} \sum_{i=1}^3 \sum_{j=1}^{n_i} (x_i^j - \hat{m}_i)(x_i^j - \hat{m}_i)^t \quad (2)$$

où :

- x_i^j désigne le $j^{\text{ième}}$ vecteur forme de la $i^{\text{ième}}$ classe,
- \hat{m}_i le centre de gravité de la $i^{\text{ième}}$ classe :

$$\hat{m}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_i^j \quad (3)$$

Quant à l'estimée de la matrice de dispersion inter-groupe, elle s'exprime par :

$$\hat{\Sigma}_B = \frac{1}{n} \sum_{i=1}^3 \sum_{j=1}^{n_i} (\hat{m}_i - \hat{m})(\hat{m}_i - \hat{m})^t \quad (4)$$

où \hat{m} est l'estimateur du centre de gravité général du nuage de points :

$$\hat{m} = \frac{1}{n} \sum_{i=1}^3 n_i \hat{m}_i \quad (5)$$

Nous avons préféré ce critère au détriment de celui de Fisher [Fis6, Mol95] qui étudie chaque caractère séparément sans tenir compte du pouvoir de séparabilité des classes d'une association de caractères.

3.3.4. algorithme de sélection

L'algorithme de sélection de caractères utilisé est celui de Seybesten [Did82, Mas92]. Par une méthode d'analyse discriminante menée pas à pas (*Sequential Forward Selection*), il fournit un sous-ensemble de caractères sous-optimal avec un temps d'exécution très correct : lors de la première étape, le critère J (1) est évalué pour les d caractères dans un espace de dimension 1. Le caractère pour lequel le critère est maximum est retenu. A chaque étape q , un nouveau caractère est sélectionné (le $q^{ième}$) en considérant le critère calculé dans un espace de dimension q avec les $(q - 1)$ caractères déjà choisis.

La difficulté réside dans le choix du nombre d' de caractères finalement sélectionnés. A quelle étape de l'algorithme s'arrêter? Le choix assez arbitraire résulte d'un compromis entre la dimension de l'espace de représentation et la valeur du critère (1). On peut par exemple sélectionner la valeur d' à partir de laquelle le critère n'augmente plus de façon significative. Un autre critère empirique conseille de satisfaire la condition $n_i > 2d' + 1$ lorsque l'on dispose de peu de signaux d'apprentissage [Dud73].

Au cours de notre étude, nous avons respectivement réduit les dimensions des quatre espaces de représentation de R^{30} , R^{51} , R^{93} et R^{174} à R^5 , R^5 , R^{10} et R^{15} .

Pour les trois premiers processus de diagnostic, l'algorithme de sélection est appliqué sur la totalité des composantes de chaque espace de représentation. En ce qui concerne le quatrième vecteur forme, qui est aussi le cinquième, nous avons préféré tenir compte des précédentes sélections. La sélection est ainsi opérée parmi un ensemble de 25 caractères et non pas 174 : les 5 caractères retenus pour le processus 1, les 10 « meilleurs » coefficients de détail de niveau 2 et les 10 « meilleurs » de niveau 3. Le choix tient également compte des performances des trois processus de diagnostic citées par la suite. Ainsi les coefficients de détail de niveau 2 sont les plus représentés. Les 15 caractères sélectionnés se répartissent en 5 coefficients de détail de niveau 1, 6 de niveau 2 et 4 de niveau 3. Rappelons que les caractères désignent les valeurs absolues des coefficients de détail obtenus par analyse multirésolution.

3.4. calcul des valeurs d'appartenance

3.4.1. principe

L'objectif de ce module est d'affecter à chaque vecteur forme de d' caractères des valeurs d'appartenance aux différentes classes de cliquetis. Ces valeurs sont calculées par le biais de fonctions d'appartenance. Chaque cycle moteur est ainsi caractérisé par rapport aux intensités de cliquetis connues.

L'idée de départ consiste à associer une fonction d'appartenance Φ_i continue sur l'intervalle $[0, 1]$ à chaque classe ω_i ($i \in \{A, N, V\}$). Cette fonction d'appartenance doit satisfaire les contraintes d'être maximale et voisine de 1 pour les formes qui appartiennent à la classe de façon certaine et de décroître vers 0 à mesure que les formes s'en éloignent. Dans le cadre de notre étude chaque fonction d'appartenance est exponentielle et repose sur la définition d'un point particulier G_i , d'une distance d et d'une constante b_i (cf. figure 11) :

$$\Phi_i(x, G_i, b_i) = e^{-b_i d^2(x, G_i)} \quad (6)$$

- G_i désigne le centre de gravité des prototypes de la classe ω_i . Un prototype est une forme, issue de l'ensemble d'apprentissage, représentative d'une classe. Il appartient de façon certaine à une classe. Ainsi la fonction d'appartenance Φ_i associée à une classe ω_i est maximale pour ses prototypes. Le problème qui se pose concerne le choix des prototypes, que nous éluciderons au prochain paragraphe.

- b_i permet d'ajuster la rapidité de décroissance de l'exponentielle. Afin de définir b_i , nous utilisons la méthode décrite dans [Mas96] qui consiste à assurer une appartenance supérieure à un seuil pour un certain pourcentage des formes d'apprentissage.

- d^2 est le carré de la distance de Mahalanobis :

$$d^2 = (x - G_i)^t \Sigma_i^{-1} (x - G_i) \quad (7)$$




Figure 11. – Gabarit des fonctions d'appartenance : la valeur d'appartenance de la forme x à la classe ω_i est fonction de la distance $d(x, G_i)$ de la forme x au centre de classe G_i .

où Σ_i est la matrice de variance-covariance estimée des p_i prototypes de la classe ω_i :

$$\Sigma_i = \frac{1}{p_i} \sum_{j=1}^{p_i} (x_i^j - G_i) (x_i^j - G_i)^t \quad (8)$$

avec :

- p_i le nombre de prototypes de la $i^{\text{ème}}$ classe ($p_i \leq n_i$),
- x_i^j la $j^{\text{ème}}$ forme prototype de la $i^{\text{ème}}$ classe,
- G_i le centre de gravité des p_i prototypes :

$$G_i = \frac{1}{p_i} \sum_{j=1}^{p_i} x_i^j \quad (9)$$

L'expérimentation sur la base d'apprentissage du module ainsi conçu, avec trois fonctions d'appartenance, n'a pas donné les résultats escomptés. En effet, certaines formes d'apprentissage, prototypes d'une classe ω_i se sont vues affecter une valeur d'appartenance faible à la classe qu'elles sont pourtant censées représenter. Dans ce cas, ces prototypes sont trop éloignés dans R^d du centre de gravité G_i et sont alors rejetés en distance. Afin de pallier ce problème, nous avons choisi d'associer à chaque classe, non plus une seule fonction d'appartenance mais plusieurs. La fonction d'appartenance f ($f = 1, F_i$) de la classe ω_i s'écrit désormais Φ_{i_f} . Il convient également de remplacer l'indice i des équations 6 à 9 par i_f . Une classe ω_i , qui contient plusieurs groupes de prototypes, possède plusieurs centres G_{i_f} . L'ensemble des p_i prototypes d'une classe ω_i est scindé en sous-ensembles de p_{i_f} prototypes :

$$p_i = \sum_{f=1}^{F_i} p_{i_f} \quad (10)$$

3.4.2. choix des prototypes

Afin de rechercher les prototypes d'une classe d'intensité de cliquetis, nous faisons appel à un algorithme de coalescence. L'objet de ces algorithmes est de structurer l'espace de représentation R^d des vecteurs forme en un nombre M de classes. Ce nombre est imposé à l'algorithme. Il s'agit de présenter à l'entrée de l'algorithme l'ensemble des formes étiquetées de la base d'apprentissage et d'observer la structuration obtenue. Quels sont les individus qui se retrouvent le plus souvent regroupés ensemble? Ont-ils la même étiquette? C'est en cherchant les réponses à ces questions que l'on détermine les individus les plus représentatifs d'une classe.

En procédant à plusieurs itérations d'un processus de coalescence, nous détectons les formes stables, c'est-à-dire celles qui sont le plus souvent regroupées dans la même classe. Ces formes sont nommées *formes fortes* dans [Dub90], dans le sens où elles ne varient pas d'une expérimentation de coalescence à l'autre. Elles vont logiquement constituer les prototypes des classes.

Nous avons utilisé l'algorithme des c-moyennes floues [Bez81, Fre92].

Remarquons que l'étape d'élaboration des fonctions d'appartenance décrite ci-dessus est assez fastidieuse. Toutefois elle a lieu durant la phase d'analyse du processus de diagnostic. Lors de la phase d'exploitation, l'obtention des valeurs d'appartenance d'une forme est rapide puisque les centres G_{i_f} des classes ω_i , ainsi que les matrices de variance-covariance Σ_{i_f} sont déjà déterminés.

3.4.3. application

Les processus de diagnostic mis en œuvre ne conduisent pas, pour une forme présentée, au même nombre de valeurs d'appartenance. Ce nombre dépend évidemment du nombre de fonctions d'appartenance associées à chaque classe d'intensité de cliquetis. Le tableau 1 indique la dispersion des fonctions d'appartenance par processus. Rappelons que les espaces de travail des quatre premiers processus sont différents. L'espace de représentation du cinquième est celui du quatrième. Le cinquième processus ne diffère donc du quatrième que par l'ajout d'une fonction d'appartenance.

Tableau 1. – Répartition des fonctions d'appartenance dans les différentes classes *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent* pour 5 processus de diagnostic.

Processus de diagnostic	Dimension de l'espace de représentation	Nombre de fonctions d'appartenance	Répartition		
			Classe cliquetis		
			absent	naissant	violent
1	5	6	1	1	4
2	5	5	2	2	1
3	10	5	2	1	2
4	15	5	2	1	2
5	15	6	2	2	2

3.5. système de décision

L'objet de ce module est de prendre la décision finale concernant le type de cliquetis du cycle étudié. Or nous venons de voir que plusieurs degrés d'appartenance sont fournis au système de décision pour une forme testée. Nous sommes capables à cet instant de situer le cycle moteur considéré par rapport aux trois classes *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent* mais il est nécessaire de choisir définitivement une classe.

3.5.1. règle du maximum d'appartenance

La règle du maximum d'appartenance [Pal91] permet de classer un vecteur forme dans la classe pour laquelle son degré d'appartenance est le plus grand. La forme x , construite à partir du signal vibratoire observé $x(t)$, est affectée à la classe ω_m si la plus grande valeur d'appartenance de la forme x est obtenue par une fonction d'appartenance r modélisant cette classe ω_m :

$$x \longrightarrow \omega_m \quad \text{si} \quad \Phi_{m_r}(x) = \max_{\substack{i=1,3 \\ f=1, F_i}} \Phi_{i_f}(x) \quad (11)$$

F_1 , F_2 et F_3 désignent le nombre de fonctions d'appartenance modélisant respectivement les classes *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent*.

3.5.2. fusion de diagnostics : règle du rapport d'appartenance

L'utilisation de la règle du maximum d'appartenance peut permettre d'associer, dans un espace de représentation donné, une forme à l'une des trois classes de cliquetis prédéfinies. Chacun des cinq processus de diagnostic conduit ainsi à une décision. Mais quel degré de confiance accorder à ces diagnostics et lequel privilégier?

Nous proposons de faire coopérer les divers diagnostics dans le but d'améliorer la robustesse de l'ultime décision en utilisant la règle du rapport d'appartenance.

Cette règle repose sur la construction d'un rapport tenant compte des deux plus grands degrés d'appartenance associés à une forme. Ce rapport dépend donc de la position de la forme dans l'espace de représentation par rapport aux deux classes les plus proches. Il a été proposé par C. Frélicot [Fre95, Mas96], dans le cadre d'un unique processus de diagnostic, afin de sélectionner la classe d'une forme x parmi M classes possibles en tenant compte du rejet d'ambiguïté. Lorsque le rapport est faible, la forme est affectée à la classe la plus proche. Lorsqu'il est voisin de 1, la forme est rejetée en ambiguïté.

Nous utilisons ce rapport afin d'affecter des degrés de certitude aux diagnostics formulés par les différents processus élaborés. Un rapport d'appartenance est évalué pour chaque processus de diagnostic et associé à chaque proposition faite à l'aide de la règle du maximum d'appartenance. L'ultime diagnostic est celui donné par le processus dont le rapport d'appartenance est minimum et suffisamment faible. Le système de décision ainsi conçu, fait confiance au processus qui a le plus d'assurance, le processus le plus sûr de son diagnostic.

La procédure est illustrée sur la figure 12 dans le cas de deux processus de diagnostic. Dans cet exemple, les trois classes *absence de cliquetis*, *cliquetis naissant* et *cliquetis violent* sont respectivement associées à 1, 1 et 2 fonctions d'appartenance prenant leurs valeurs dans l'intervalle $[0, 1]$. D'après la règle du maximum d'appartenance, les deux processus fournissent des diagnostics différents. La plus grande valeur d'appartenance correspond à une classe cliquetis violent pour le processus 1, à une classe cliquetis naissant pour le 2. Lequel des deux processus va-t-il enlever la décision? Considérons les deux rapports d'appartenance. Pour le processus 2, le rapport est déterminé à partir des valeurs d'appartenance 2 et 4. Celles-ci sont voisines, le rapport est donc proche de 1. Dans le cas du premier processus, le rapport se calcule avec les valeurs d'appartenance 2 et 3. Le rapport est faible. Notons que le rapport fait évidemment intervenir deux fonctions d'appartenance modélisant des classes différentes. C'est bien ici le processus 1 de rapport moindre qui impose son diagnostic. Il est plus sûr de lui.




Figure 12. – Exemple d'un système de décision avec deux processus de diagnostic pour lequel la décision du processus 1 (classe 3, volumes grisés) l'emporte sur celle, plus ambiguë du fait de la similarité des deuxième et quatrième valeurs d'appartenance, du processus 2 (classe 2, volume gris clair).

Formalisons la procédure développée (cf. figure 13) :

Soient x^p le vecteur forme utilisé par le processus de diagnostic p ($p = 1, 5$) et $\Phi_{i_f}^p$ la i_f ème fonction d'appartenance associée à la classe ω_i . Le rapport d'appartenance construit à partir des deux plus grands degrés d'appartenance $\Phi_{m_r}^p(x^p)$ et $\Phi_{s_v}^p(x^p)$ s'exprime :

$$R_p(x^p) = \frac{\Phi_{s_v}^p(x^p)}{\Phi_{m_r}^p(x^p)} \quad (12)$$

où :

$$\Phi_{m_r}^p(x^p) = \max_{\substack{i=1,3 \\ f=1, F_i}} \Phi_{i_f}^p(x^p) \quad (13)$$

$$\Phi_{s_v}^p(x^p) = \max_{\substack{i=1,3 \\ i \neq m \\ f=1, F_i}} \Phi_{i_f}^p(x^p) \quad (14)$$

- Si $R_p(x^p) \simeq 0$ alors $\Phi_{m_r}^p(x^p) \gg \Phi_{s_v}^p(x^p)$, donc $\Phi_{m_r}^p(x^p) \gg \Phi_{i_f}^p(x^p) \quad \forall i = 1, 3 \quad \forall f = 1, F_i$ avec $i \neq m$, il existe une grande différence entre la valeur d'appartenance maximale à la classe ω_m et les valeurs d'appartenance aux autres classes, la forme x^p est affectée avec un degré de certitude important à la classe ω_m .
- Si $R_p(x^p) \simeq 1$ alors $\Phi_{m_r}^p(x^p) \simeq \Phi_{s_v}^p(x^p)$, le vecteur forme x^p ne peut pas être affecté plus sérieusement à la classe ω_m qu'à la classe ω_s . Il y a ambiguïté quant à l'appartenance de x^p à une classe.

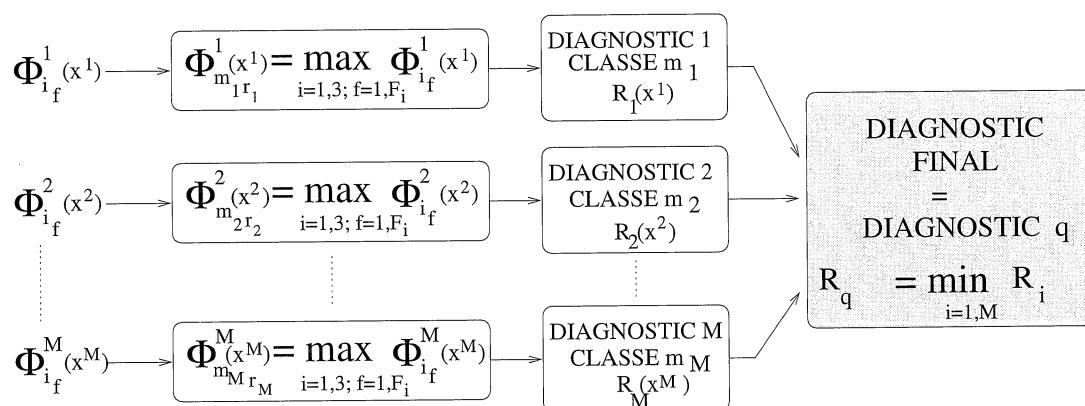


Figure 13. – Système de décision.

3.5.3. rejet d'ambiguïté

Lorsque le plus petit rapport d'appartenance reste relativement élevé, il dépasse une valeur S_a dite seuil de rejet d'ambiguïté, la forme étudiée n'est pas affectée à une seule intensité de cliquetis. Il y a ambiguïté entre deux classes. Ce sont celles dont les fonctions d'appartenances sont impliquées dans la détermination du rapport d'appartenance.

Il pourrait être envisagé de lever l'ambiguïté en privilégiant un des processus de diagnostic mieux adapté à la reconnaissance de telle ou telle classe.

3.5.4. rejet de distance

Lorsque la forme considérée se situe trop loin dans l'espace de représentation R^d des trois classes répertoriées, elle est rejetée en distance. Les caractéristiques du signal vibratoire en matière d'intensité de cliquetis sont alors trop différentes de celles des signaux vibratoires de la base d'apprentissage. En pratique, cette décorrélation est mise en évidence en comparant la valeur maximale d'appartenance d'une forme à une classe à un seuil de rejet S_d . Si la valeur est inférieure à S_d , la forme est rejetée en distance par le processus de diagnostic.

4. résultats

4.1. indicateurs de performance pour le système de décision

La pertinence des diagnostics formulés est évaluée en recourant à des indicateurs de performance. Il s'agit de voir si la décision concernant une forme est conforme à l'étiquette fournie aux données lors de l'expertise.

Soient :

- M_j le nombre d'individus mal classés de la classe ω_j ,
- M le nombre total d'individus mal classés,
- B_j le nombre d'individus bien classés de la classe ω_j ,
- B le nombre total d'individus bien classés,
- R le nombre total d'individus rejetés (en distance ou en ambiguïté).

• ϵ_j avec $j \in \{A, N, V\}$, est un estimateur de la probabilité d'erreur de reconnaissance pour la classe ω_j :

$$\epsilon_j = \frac{M_j}{B_j + M_j} \quad (15)$$

• ϵ est un estimateur de la probabilité d'erreur globale de reconnaissance :

$$\epsilon = \frac{M}{B + M} \quad (16)$$

• δ est un estimateur du taux de reconnaissance :

$$\delta = \frac{B}{B + M + R} \quad (17)$$

Ces indicateurs de performance sont successivement appliqués sur l'ensemble d'apprentissage et sur l'ensemble de validation.

4.2. ensemble d'apprentissage

Les performances des cinq classifieurs sont présentées dans le tableau 2. L'examen des résultats des trois premiers processus, qui mettent en jeu des vecteurs forme bâtis autour d'une seule variété de détails, permet de discerner le niveau de détail le plus apte à la classification des signaux vibratoires. Les détails de résolution 2, correspondant à la bande de fréquences 25-50 kHz, présentent les meilleurs résultats pour les trois classes (cf. processus 2). Toutefois la classe *cliquetis violent* est aussi bien reconnue par le processus 3 qui utilise les détails de niveau 1 (bande 50-100 kHz).

Tableau 2. – Taux de reconnaissance et taux d'erreur de classification pour les 117 cycles moteur de l'ensemble d'apprentissage.

Classifieur	δ	ϵ	ϵ_A	ϵ_N	ϵ_V
Processus 1	77.8%	22.2 %	32.5 %	25 %	11.1 %
Processus 2	89.7%	9.5 %	7.5 %	15.6 %	6.8 %
Processus 3	84.6%	14.7 %	20 %	18.7 %	6.8 %
Processus 4	88.9%	11.1 %	17.5 %	3.1 %	11.1 %
Processus 5	92.3%	6.1 %	12.5 %	3.1 %	2.3 %

Les détails de niveau 3 (bande 12.5-25 kHz) donnent les moins bons résultats bien qu'ils concernent une bande fréquentielle souvent utilisée par les motoristes.

Le fait de mélanger des détails de différents niveaux (cf. processus 4) améliore la perception de la classe *cliquetis naissant*. Néanmoins le taux de reconnaissance n'est pas supérieur à celui fourni par le processus 2. En ajoutant une sixième fonction d'appartenance, le taux de reconnaissance est porté à 92.3%, c'est le meilleur taux obtenu. La classe *cliquetis violent* est alors très bien reconnue.

Remarquons qu'une augmentation du nombre de fonctions d'appartenance dans le processus de diagnostic conduit à un meilleur taux de reconnaissance (figure 14). Néanmoins le taux ne croît pas indéfiniment. Il s'agit de déterminer le nombre adéquat de

Tableau 3. – Taux de reconnaissance et taux d'erreur de classification obtenus par fusion de diagnostics pour les 117 cycles moteur de l'ensemble d'apprentissage

Classifieurs	δ	ϵ	ϵ_A	ϵ_N	ϵ_V
Processus 1, 2, 3	88%	12 %	12.5 %	18.7 %	6.7 %
Processus 1, 2, 3, 4	88%	12 %	15 %	15.6 %	6.7 %
Processus 1, 2, 3, 5	89.7%	10.3 %	12.5 %	15.6 %	4.4 %




Figure 14. – Evolution du taux de reconnaissance δ et du taux d'erreur ϵ en fonction du nombre de fonctions d'appartenance utilisées par le processus de diagnostic 1.

fonctions d'appartenance qui va permettre de doter le processus de diagnostic d'une bonne capacité de généralisation.

La coopération des diagnostics fournis par les différents processus conduit aux performances indiquées dans le tableau 3.

Les performances atteintes suite aux deux premières fusions entreprises ne sont pas meilleures que celles obtenues, sans fusion, par le processus de diagnostic 2. Cependant la fusion permet d'améliorer les performances par rapport à la simple utilisation des processus 1 ou 3. Le fait de fusionner le processus 4 avec les trois précédents ne semble pas d'un grand intérêt. Cette fusion permet de légèrement mieux cerner la classe *cliquetis naissant* au détriment de la classe *absence de cliquetis*. La fusion avec le processus 5 permet d'améliorer la reconnaissance de la classe *cliquetis violent* et atteint globalement les résultats du processus 2 considéré seul.

Les performances obtenues par les différents processus de diagnostic sont satisfaisantes. La fusion n'améliore pas ici les taux d'erreur de classification probablement parce qu'elle est pénalisée par les valeurs d'appartenances produites par le premier processus de diagnostic qui fournit les moins bons résultats (tableau 1).

4.3. ensemble de test

Du fait de la répartition très hétérogène des données, nous avons préféré uniquement indiquer, dans le tableau 4, les résultats concernant les erreurs de classification des classes prises séparément. Les taux de reconnaissance et d'erreur de classification globaux ne sont pas fiables.

Les performances des processus 3, 4 et 5 apparaissent non satisfaisantes bien que le processus 5 présente un bon taux d'erreur de classification pour la classe *cliquetis violent*. L'examen des formes mal classées par les processus 1 et 2 traduisent le plus souvent une confusion entre les classes *absence de cliquetis* et *cliquetis naissant*. Mais il est vrai que l'observation des signaux de pression correspondants peut conduire à des interrogations du type : « est-ce vraiment un cliquetis naissant ou n'est-ce pas plutôt une absence de cliquetis ? » Le classement obtenu semble à cet égard plus pertinent que ce que laissent présager les indicateurs de performance. Cet aspect montre l'importance que revêt l'étiquetage des données.

Dans la configuration actuelle avec un seul accéléromètre, il semble contre-indiquer de tester la méthode sur un cylindre

Tableau 4. – Taux d'erreur de classification de l'ensemble test pour chaque classe.

Classifieur	ϵ_A	ϵ_N	ϵ_V
Processus 1	15.3 %	65.4 %	80 %
Processus 2	21.4 %	69.6 %	50 %
Processus 3	68.2 %	46.1 %	20 %
Processus 4	84.7 %	23.1 %	60 %
Processus 5	85.7 %	34.6 %	0 %

différent de celui qui a conduit à la mise au point du processus de diagnostic, à moins peut être de déterminer un emplacement optimal de cet accéléromètre sur le bloc moteur.

5. conclusion et perspectives

Nous avons proposé une chaîne de diagnostic permettant à partir d'un signal vibratoire de déduire trois catégories d'intensité du cliquetis produit dans la chambre de combustion. La méthode, faisant appel à des techniques de reconnaissance des formes floues, s'organise autour de cinq fonctions : la segmentation des signaux, l'extraction de caractères, la sélection de caractères, le calcul des valeurs d'appartenance et la décision. Cinq processus de diagnostic ont été élaborés à partir de signaux vibratoires enregistrés sur le cylindre 3 à un régime moteur de 5600 tr/mn pour une avance à l'allumage de 22.5°. Ils présentent deux particularités.

La première concerne l'extraction des caractéristiques d'un signal vibratoire non stationnaire réalisée par analyse multirésolution. Outre sa capacité à tenir compte d'événements transitoires, cet outil d'analyse temps-échelle est particulièrement adapté aux applications automobiles puisqu'il offre des possibilités d'implantation temps réel.

La seconde consiste à améliorer la robustesse du diagnostic final en élaborant l'ultime décision à partir de plusieurs propositions émises par plusieurs processus.

Les résultats obtenus ont montré qu'il est pertinent d'étudier les composantes fréquentielles élevées du signal vibratoire lorsque l'on désire différencier plusieurs intensités de cliquetis.

Afin de disposer en phase de test d'un ensemble homogène de signaux, la méthode devrait toutefois être expérimentée sur un jeu de données plus important.

En utilisant plusieurs accéléromètres, il serait intéressant de voir si les processus de diagnostic élaborés sur le cylindre 3 entraînent de bons résultats sur les autres cylindres. Il est également envisageable d'étudier la robustesse de la méthode vis-à-vis de l'avance à l'allumage réglée et du régime moteur considéré.

L'étude présente nous a conduit à faire coopérer des processus de diagnostic de structure similaire. Mais le type de fusion que nous proposons peut être envisagé sur des processus de nature différente.

La chaîne de traitement peut ainsi être utilisée dans de nombreuses applications pour lesquelles il s'agit de déduire le comportement d'un système à partir de données recueillies sur ce système. La structure modulaire du processus de diagnostic permet en outre une grande souplesse d'utilisation.

Enfin, les processus de diagnostic que nous avons élaborés sont d'autant plus efficaces que la phase préalable d'étiquetage des

données a été menée consciencieusement. En effet, la chaîne de traitement est mise au point à partir des données étiquetées. Le calcul des performances de la reconnaissance dépend également de ces données.

6. remerciements

Nous remercions M.A. Dillies-Peltier et F. Neveu, ingénieurs de recherche de PSA Peugeot-Citroën, d'avoir permis la réalisation de cette étude, pour laquelle les mesures ont été effectuées au sein du service Recherche Moteur et Propulsion.

BIBLIOGRAPHIE

- [Barg95] M. Bargende. Critère de point fort et détection automatique du cliquetis. *MTZ*, 56(10) :632-638, 1995.
- [Bart92] R. Bartz, G. Schmitz and P. Bohnke. Nouvelles méthodes pour détecter le cliquetis dans les moteurs à essence. *MTZ*, 53(6) :286-293, 1992.
- [Bez81] J. C. Bezdek. *Pattern Recognition with fuzzy objective function algorithms*. Plenum Press, 1981.
- [Chi87] M. Chiollaz, P. Flandrin and N. Gache. Utilisation de la représentation de Wigner-Ville comme outil de diagnostic des défauts de fonctionnement de moteurs thermiques. *Onzième colloque Gretsi*, pages 579-582, Nice, Juin 1987.
- [Chu89] K.M. Chun and J.B. Heywood. Characterization of knock in a spark-ignition engine. *SAE*, (890156) :1-14, 1989.
- [Chu94] K.M. Chun and K.W. Kim. Measurement and analysis of knock in a SI engine using the cylinder pressure and block vibration signals. *SAE*, (940146) :286-293, 1994.
- [Cho57] C. K. Chow. An optimum recognition error and reject tradeoff. *IEEE Transactions on Information Theory*, 16(5) :41-46, 1957.
- [Did82] E. Diday, J. Lemaire, J. Pouget and F. Testu. *Éléments d'analyse des données*. Dunod, 1982.
- [Dub90] B. Dubuisson. *Diagnostic et reconnaissance des formes*. Traité des Nouvelles Technologies série Diagnostic et Maintenance. Hermès, 1990.
- [Dud73] R.O. Duda and P.E. Hart. *Pattern classification and scene analysis*. Wiley-Interscience Publication, 1973.
- [Est77] D. Esteban and C. Galand. Application of quadrature mirror filters to split band voice coding schemes. In *ICASSP-77*, IEEE Int. Conf. on Acoust., Speech and Signal Proc., pages 191-195, 1977.
- [Fis36] R.A. Fisher. The use of multiple measurements in taxonomic problems. *Annals Eugenics*, II(7) :179-188, 1936.
- [Fre92] C. Frelicot. *Un système adaptatif de diagnostic prédictif par reconnaissance des formes floues*. Thèse de doctorat, Université de Technologie de Compiègne, 1992.
- [Fre95] C. Frelicot, M. H. Masson and B. Dubuisson. Reject options in fuzzy classification rules. In *Proc. EUFIT'95*, volume III, pages 1495-1464, Aachen, Germany, August 1995.
- [Fer96] C.V. Ferraro, F. Millo, C. Fenoglio and F. Imperio. A critical analysis of knock-detection methods based on cylinder pressure analysis. In *1st International Conference on Control and diagnostics in automotive applications*, pages 293-304, Genova (Italy), October 1996.
- [Gue94] O. Guetta and A. Morandat. Détection du cliquetis par analyse temps-fréquence et traitement d'images sur des signaux de pression chambre.

Diagnostic d'un système non stationnaire

Journées thématiques du GDR TdSI et colloque, temps-fréquence, ondelettes et multirésolution : théories, modèles et applications, pages 36.1–36.4, INSA-Lyon, Mars 1994.

[Mas92] M. H. Masson. *Contribution à l'élaboration d'une méthode de décision avec rejet par réseaux de neurones. Application à la surveillance de systèmes*. Thèse de doctorat, Université de Technologie de Compiègne, 1992.

[Mas96] M. H. Masson, B. Dubuisson and C. Frelicot. Conception d'un module de reconnaissance des formes floues pour le diagnostic. *RAIRO-APII-JESA*, pages 319–341, 1996.

[Mol95] F. Molinaro and F. Castanie. Signal processing pattern classification techniques to improve knock detection in spark ignition engines. *Mechanical Systems and Signal Processing*, 9(1) :51–62, 1995.

[Pal91] S.K. Pal. Fuzzy tools for the management of uncertainty in pattern recognition, image analysis, vision and expert systems. *Int. Journal of Systems Science*, 22(3) :511–549, 1991.

[Puz92] P.V. Puzinauskas. Examination of methods used to characterize engine knock. *SAE*, (920808) :1–13, 1992.

[Tho96] J.H. Thomas. *Etude de méthodes de diagnostic par reconnaissance des formes floues. Application à deux situations issues du domaine automobile*. Thèse de doctorat, Université de Technologie de Compiègne, 1996.


[Tho97] J.H. Thomas, B. Dubuisson and M.A. Dillies-Peltier. Engine knock detection from vibration signals using pattern recognition. *Meccanica*, 32(5) :431–439, 1997.

[Zha92] Q. Zhang and A. Benveniste. Wavelet networks. *IEEE Transactions on Neural Networks*, 3(6) :889–898, November 1992.

Manuscrit reçu le 13 mai 1998.

L' AUTEUR

Jean-Hugh THOMAS



Jean-Hugh Thomas, ingénieur U.T.C. (1991), est maître de conférences à l'Ecole Nationale Supérieure d'Ingénieurs du Mans (ENSIM) depuis septembre 1998. Depuis sa thèse (UTC-1996) menée en convention Cifre avec PSA Peugeot Citroën, ses activités de recherche concernent au sein de l'Institut d'Acoustique et de Mécanique du Mans, l'extraction de caractéristiques par des méthodes temps-échelle et le diagnostic vibratoire à partir de méthodes de reconnaissance des formes.