

Performances de la classification par les Séparateurs à Vaste Marge (SVM): application au diagnostic vibratoire automatisé

R. Ziani, A. Felkaoui, R. Zegadi

Laboratoire de mécanique de précision appliquée
Département d'optique et mécanique de précision
Université Ferhat Abbes, Sétif Algérie 19000.

ziani_lmpa@yahoo.fr

Résumé- Cette étude est proposée pour comparer les performances de la détection des défauts dans les machines tournantes en utilisant une récente méthode classification : les Séparateurs à Vaste Marge (SVM) ou en anglais *Support Vector Machines*. Les signaux vibratoires ont été traités pour extraire trois types d'indicateurs qui sont utilisés comme entrée au classificateur pour l'identification de deux classes (normale, avec défaut). Les SVM sont entraînés en utilisant un sous-ensemble des données expérimentales. Le sous-ensemble restant est utilisé pour le test. Les performances de la classification sont comparées en utilisant trois noyaux différents (polynomial, RBF, et sigmoïdal).

I. INTRODUCTION

Le premier rôle de la surveillance industrielle est d'augmenter la disponibilité des installations industrielles afin de réduire les coûts directs et indirects de la maintenance des équipements de production.

Une machine en bon état produit un niveau donné de vibrations. L'apparition d'un défaut ou d'une anomalie se traduit par une modification caractéristique de cet état de référence. C'est pourquoi, la plus part des méthodes modernes de maintenance sont basées sur le passage vers une maintenance prédictive (conditionnelle) susceptible de prévoir avec suffisamment de précision, l'évolution de l'état d'une machine.

D'un point de vue théorique, les problèmes du diagnostic des défauts ont un rapport direct avec la reconnaissance des formes (RDF) puisque on souhaite classer les données en classes prédéfinies. L'élaboration de tel système de diagnostic se réalise généralement en trois phases [1] ; La première est la *phase d'analyse* qui comprend l'analyse des données (pré traitement, ...), la définition d'un espace de représentation, la deuxième est la *phase du choix d'une méthode de décision* (discrimination entre classes), qui doit attribuer toute nouvelle donnée (ou mesure) à un mode de fonctionnement. La dernière est la *phase d'exploitation* où l'objectif est d'associer aux nouvelles observations les modes de fonctionnement.

Les séparateurs à vaste marge (SVM) sont des algorithmes de classification récemment développés par Vapnik [2]. L'idée essentielle des SVM est d'utiliser des fonctions noyaux et de projeter les données de l'espace d'entrée (non linéairement séparables) dans un espace de plus grande dimension appelé espace de caractéristiques, de façon à ce que les données

deviennent linéairement séparables. Ces algorithmes tentent de minimiser les erreurs d'apprentissage tout en maximisant la marge séparant les données des classes. Le comportement des SVM est conditionné par le type de noyau utilisé dans la projection et les valeurs accordées à ses paramètres [2] [3].

Dans cet article, nous proposons d'appliquer les SVM pour l'identification de deux classes ; la première est de l'engrenage sain (état normal), la deuxième est de l'engrenage défectueux.

Les signaux vibratoires sont traités pour extraire trois ensembles d'indicateurs; statistique, coefficients du modèle autorégressif (AR), et fréquentiels.

II. LES SEPARATEURS A VASTE MARGE

Pour bien décrire la technique de construction de l'hyperplan optimal séparant des données appartenant à deux classes différentes, Supposons nous avons les données empiriques :

$$(x_i, y_i), \dots, (x_m, y_m) \in \mathbb{R}^n \times \{\pm 1\} \quad (1)$$

Soit $H : w \cdot x + b$ l'hyperplan qui satisfait les conditions suivantes :

$$\begin{cases} w \cdot x_i + b \geq 1 & \text{si } y_i = 1 \\ w \cdot x_i + b \leq -1 & \text{si } y_i = -1 \end{cases} \quad (2)$$

Ce qui est équivalent à :

$$y_i (w \cdot x_i + b) \geq 1 \quad \text{Pour } i=1, \dots, m \quad (3)$$

La fig.1 donne une représentation visuelle de l'hyperplan optimal dans le cas des données linéairement séparables.

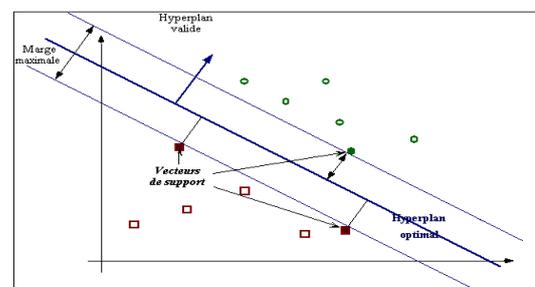


Fig. 1. Un exemple de classification de deux classes par les SVM

L'hyperplan optimal peut être obtenu par la solution du problème d'optimisation quadratique suivant :

$$\begin{cases} \min \frac{1}{2} \|w\|^2 \\ \forall i \ y_i (w \cdot x_i + b) \geq 1 \end{cases} \quad (5)$$

L'introduction des multiplicateurs de Lagrange $\alpha_i > 0, i=1 \dots m$, donne le lagrangien primaire qui s'écrit :

$$L(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^m \alpha_i [y_i (w^T x_i + b) - 1] \quad (6)$$

Le lagrangien doit être minimal par rapport à w et b et maximal par rapport à α , Le point optimal est un point selle qui vérifie :

$$\begin{aligned} \frac{\partial L(w, b, \alpha)}{\partial w} = 0 &\Rightarrow w = \sum_{i=1}^m \alpha_i y_i x_i \\ \frac{\partial L(w, b, \alpha)}{\partial b} = 0 &\Rightarrow \sum_{i=1}^m \alpha_i y_i = 0 \end{aligned} \quad (7)$$

En substituant w par son expression“(7)” dans“(6)” on peut écrire le problème quadratique dual d'optimisation sous la forme :

$$\begin{cases} \max \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \forall i \ \alpha_i \geq 0 \\ \sum_{i=1}^l \alpha_i y_i = 0 \end{cases} \quad (8)$$

Par résolution du problème dual d'optimisation (8) on obtient les coefficients “ α_i ” nécessaire pour l'expression du vecteur “ w ”(7) et on peut, donc, établir la fonction de décision suivante :

$$f(x) = \sum_{i=1}^m \alpha_i^* y_i (x \cdot x_i) + b^* \quad (9)$$

Les points x_i avec $\alpha_i > 0$ sont appelés *vecteurs de supports* (VS).

Dans le cas où l'hyperplan linéaire dans l'espace d'entrée ne sépare pas bien les données des deux classes, il est possible de créer un hyperplan qui offre une séparation linéaire dans un espace de redescription de grande dimension, éventuellement infinie, il devient donc possible d'envisager d'utiliser la méthode des SVM [4].

Notons “ Φ ” une transformation non linéaire de l'espace d'entrée “ X ” en un espace de redescription “ $\Phi(x)$ ” :

$$X = (x_1, \dots, x_d)^T \text{ à } \Phi(x) = (\Phi(x_1), \dots, \Phi(x_d), \dots)^T \quad (10)$$

Généralement, le vecteur image $\Phi(x)$ est de dimension supérieure à d , la dimension de l'espace d'origine. Les données sont projetées via la fonction Φ telle que :

$\Phi(x_i) \cdot \Phi(x) = k(x_i, x)$, où k est appelée fonction noyau ou (*kernel*).

La fig. 2 montre que les données non linéairement séparables dans l'espace d'entrée X sont à présent séparables dans l'espace augmenté $\Phi(x)$.

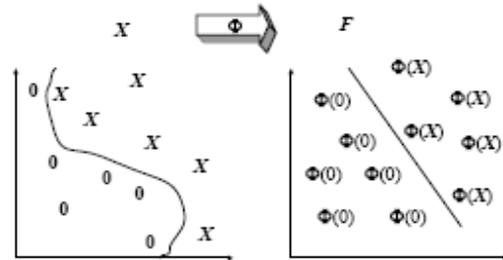


Fig. 2. Illustration de l'effet de changement d'espace par une fonction noyau.

Parmi les noyaux couramment utilisés pour la classification on peut citer [4], [5]:

Polynomial $k(x, x') = (x \cdot x' + 1)^q \quad (11)$

RBF $k(x, x') = \exp(-\frac{\|x - x'\|^2}{2\sigma^2}) \quad (12)$

Sigmoïdal $k(x, x') = \tanh(ax \cdot x' - b) \quad (13)$

Le problème d'optimisation“(8)” se transcrit dans ce cas par :

$$\begin{cases} \max \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \forall i \ 0 \leq \alpha_i \leq C \\ \sum_{i=1}^l \alpha_i y_i = 0 \end{cases} \quad (14)$$

La fonction de décision dans le nouvel espace devient :

$$f(x) = \sum_{i=1}^m \alpha_i^* y_i K(x_i, x) + b^* \quad (15)$$

Où les coefficients α_i^* et b^* sont obtenus comme précédemment par résolution de l'équation (14).

III. SYSTEME ETUDIE

Les vibrations d'engrenages sur lesquelles nous avons fait les tests proviennent d'un réducteur du CETIM (fig.3). (*Centre d'Etudes Techniques des Industries Mécaniques, 52 av. Felix Louat, 60300 Senlis*), fonctionnant 24h/24h. Le dimensionnement des roues d'engrenages cémentés trempés, ainsi que les conditions de fonctionnement (vitesse, couple) sont fixés de façon à obtenir un écaillage sur toute la largeur d'une dent [6]. Tous les jours après l'acquisition des signaux vibratoires, le banc est arrêté, pour expertiser l'état des dentures des roues. Les essais du réducteur s'étalent sur 12 jours avec l'enregistrement d'un signal vibratoire chaque jour.

Le système est composé d'un moteur, d'un réducteur de bouclage de rapport 40/42 et du réducteur testé, de rapport 20/21. Le réducteur testé a pour vitesse de rotation 1000 tr/min, soit donc une fréquence de rotation 16,67 Hz. Or, les deux roues composant ce réducteur ont un nombre de dents quasiment identique. Leurs fréquences de rotation sont donc très proches l'une de l'autre. Nous avons en effet :

- La fréquence d'engrènement des deux roues est $f_{eng} = 333,48 \text{ Hz}$
- La fréquence d'échantillonnage $f_e = 20 \text{ kHz} = 20000 \text{ Hz}$
- La période d'échantillonnage : $\Delta t = 1 / f_e = 5 \cdot 10^{-5} \text{ s}$

Au cours de l'expérimentation, l'engrenage de test passe de l'état de bon fonctionnement à celui d'un engrenage détérioré.

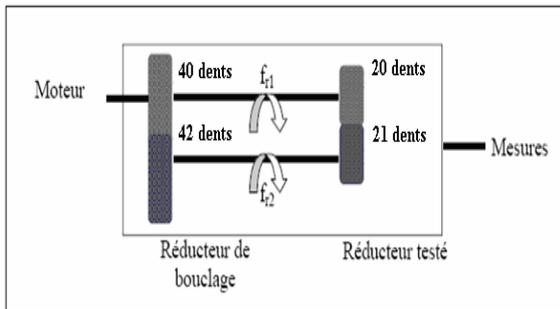


Fig. 3. Schéma de train d'engrenage.

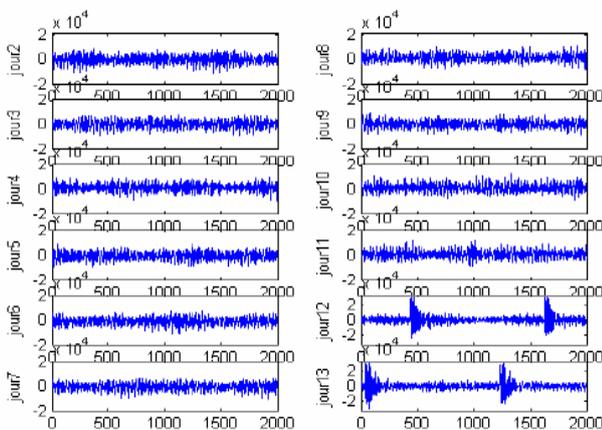


Fig. 4. Signaux temporels du train d'engrenage.

La seule remarque possible sur les signaux temporels de la fig. 4 consiste à souligner l'apparition d'un motif, lié au défaut avec l'apparence d'un choc, de manière périodique. La mesure de cette période nous donne environ 0.0625 s soit une fréquence de 16 Hz . Cette remarque nous permet uniquement de penser qu'un défaut apparaît sur l'une des roues mais sans pouvoir toutefois déterminer laquelle des deux est atteinte. A cet effet nous considérons que les signaux de 2^{ème} au 10^{ème} jour, forment la première classe (sans défaut), et que le 12^{ème} et le 13^{ème} jour appartiennent à la deuxième classe (avec défaut).

IV. PRÉPARATION DES OBSERVATION

Pour avoir suffisamment d'individus dans les deux modes de fonctionnement (sans et avec défaut) et puisque nous disposons d'enregistrements d'une longueur de $N_s = 60160$ points, chaque signal est décomposé en 13 tranches de 8192 points avec, un recouvrement des tranches de 50%.

Pour éviter l'effet de masque qui entache fortement la sensibilité des indicateurs "larges bandes", le signal de chaque tranche, a donc, été centré puis filtré par un filtre passe-bande. Le filtre utilisé est à réponse impulsionnelle finie à phase minimale.

Pour Chaque jour, nous disposons de 13 tranches de signaux, échantillonnées à 20000 Hz. Par le filtrage ci-dessus, nous avons limité notre étude à une fréquence maximale de 1083 Hz. Les tranches des signaux sont, donc, suréchantillonnées. Nous proposons de décimer ces signaux par un facteur 4. Nous obtenons ainsi des signaux de 2048 points échantillonnés à une fréquence $f_e = 20000/4 = 5000 \text{ Hz}$. Nous pouvons remarquer que le théorème de Shannon ($f_e \geq 2 \cdot f_{max}$) est donc bien vérifié. Le vecteur décimé est 4 fois plus court.

V. EXTRACTION DES INDICATEURS

Après les prétraitements précédents, et une analyse préliminaire, nous avons choisi de calculer les indicateurs temporels et fréquentiels dans différentes bandes latérales de largeur 167 Hz autour des fréquences d'engrènement, soit 10 raies latérales (dix fréquences de rotation) autour des 3 principales harmoniques ($1.f_e = 333.33 \text{ Hz}$, $2.f_e = 666.66 \text{ Hz}$, et $3.f_e = 999.99 \text{ Hz}$). Les bandes de calcul sont alors les suivantes: $[250-417 \text{ Hz}]$, $[583-750 \text{ Hz}]$ et $[916-1083 \text{ Hz}]$.

A. Les indicateurs temporels

Dans chaque tranche nous avons choisi de calculer les indicateurs statistiques suivants : la valeur efficace, le facteur de crête, le skewness, le kurtosis, et les moments d'ordre (5 à 9). Ces indicateurs sont calculés dans les trois bandes précitées pour chaque tranche. La matrice des données obtenue est de (156 individus \ 27 indicateurs).

B. Les coefficients du modèle AR

L'idée générale est de représenter le signal temporel par un modèle paramétrique et d'extraire des indicateurs basés sur les

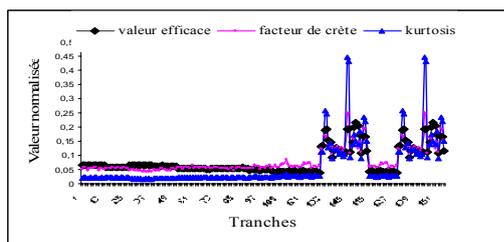
paramètres de ce modèle. Ici nous avons choisi d'utiliser le modèle autorégressif (AR) et d'extraire les coefficients a_i du modèle représentant chaque tranche.

Lors du calcul des coefficients a_i du modèle autorégressif le problème major rencontré est comment déterminer l'ordre p du modèle. Pour résoudre ce problème nous avons utilisé un algorithme basé sur la méthode de décomposition en valeur singulière (SVD), proposée dans [7]. Le résultat obtenu par cet algorithme nous donne pour un modèle AR représentant une tranche l'ordre 19, donc nous avons estimé 19 coefficients en utilisant la fonction IVAR du MATLAB. Ce qui nous donne pour tous les jours, une matrice de (156 individus \ 19 indicateurs).

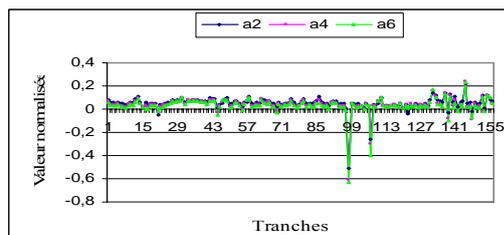
C. Les indicateurs fréquentiels

Pour extraire les indicateurs fréquentiels, nous avons choisi de calculer les énergies autour des fréquences caractéristiques dans les bandes [250-417 Hz], [583-750 Hz], [916-1083 Hz], [1250-1417Hz] et dans la bande totale [250-1417Hz]. La matrice obtenue est composée de (156 individus \ 5 indicateurs).

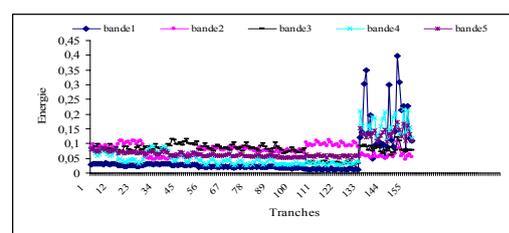
Les trois ensembles de données obtenus, forment, donc, une matrice totale (BDT) de (156individu \ 51 indicateurs). La fig. 5 représente l'évolution de quelques indicateurs de chaque ensemble.



a) les indicateurs temporels



b) les coefficients du modèle AR



c) les indicateurs fréquentiels

Fig. 5. Evolution de quelques indicateurs pour toutes les tranches (12 jours)

Cette figure montre l'évolution des indicateurs pour les douze jours considérés (156 tranches). On peut constater qu'arrivant à l'observation 131, une variation brusque apparaît pour la majorité des indicateurs, car à partir de cette observation on rentre dans l'intervalle des observations appartenant à la deuxième classe (de 131 jusqu'à 156), cette variation, caractérise ainsi une dégradation de l'état de l'engrenage et l'apparition d'un mode de fonctionnement avec défaut.

VI. CONDUITE DES DIFFÉRENTES ÉTAPES DE CLASSIFICATION

L'étape d'extraction des indicateurs nous a permis d'avoir une matrice de données formée par les trois ensembles précédents, et qui est utilisée comme entrée au classificateur (SVM). Chaque ensemble est composé de 156 individus, dont 84 sont utilisés pour l'entraînement, et les 72 restants pour le test. La classification des données a été réalisée en adaptant à notre problème une boîte à outil MATLAB appelée : *Statistical Pattern Recognition Toolbox for Matlab*¹ [7]. L'algorithme principal utilisé pour l'entraînement des SVM est celui de Platt [4]: *Sequential Minimal Optimisation* (SMO), pour plus de détail voir [4],[9].

L'organigramme de la fig. 6 résume ces différentes étapes de classification.

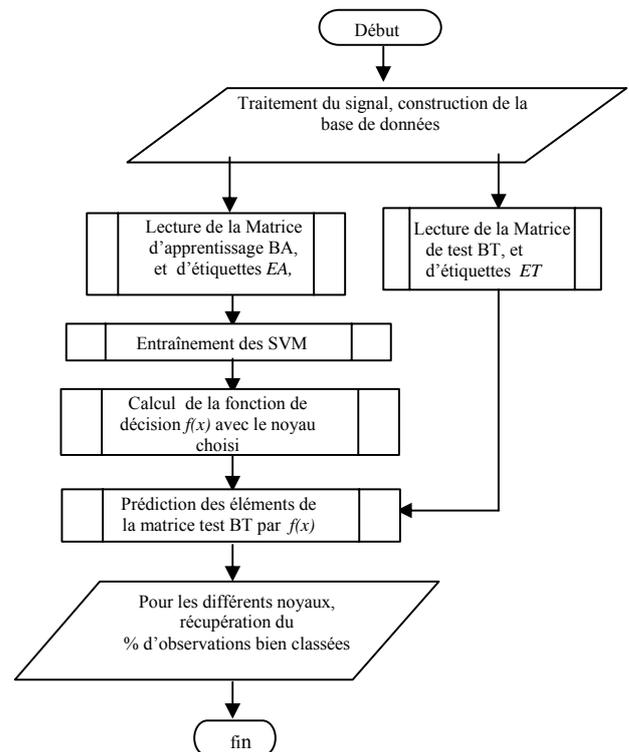


Fig. 6. Organigramme de classification par les SVM

VII. CHOIX DES PARAMETRES

Un des grands problèmes rencontrés lors de la classification par les SVM est le choix des valeurs des paramètres du noyau permettant une bonne classification, un autre problème est lié au choix de la valeur de la constante de régularisation C . Pour résoudre ces deux problèmes nous avons utilisé la méthode de validation croisée (en anglais « cross validation »). Le meilleur modèle obtenu (celui qui donne un faible taux d'erreur), qui est établi avec les meilleures valeurs des paramètres du noyau et de la constante C sera utilisé pour prédire les sorties des observations de la matrice de test BT. La fig.7 illustre la méthode de validation croisée dans le cas de la recherche des meilleurs paramètres du noyau et de la constante de régularisation qui minimisent le taux d'erreurs

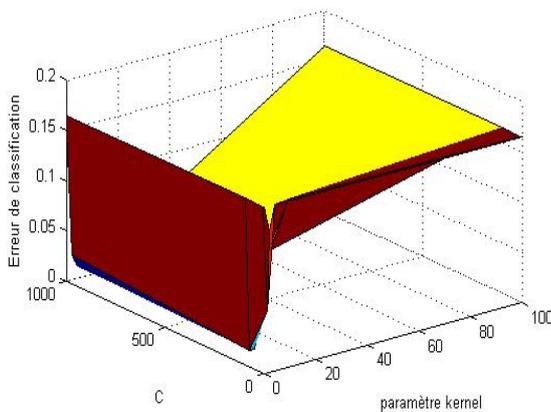


Fig. 7. Illustration de la validation croisée pour les données de CETIM

Cette figure montre l'évolution du taux d'erreur de classification des données de CETIM en fonction de paramètre du noyau, et de la constante de régularisation C . Le noyau utilisé est une fonction à base radiale (RBF), la valeur optimale de la largeur σ est égale à 2, avec une valeur optimale de C égale à 100. Donc le meilleur modèle, que nous avons utilisé pour prédire les sorties des observations de la base de test BT, est celui établi en utilisant les valeurs optimales de ces deux paramètres.

VIII. PERFORMANCES DES SVM

Le tableau 1 représente les performances des SVM pour les trois ensembles d'indicateurs et pour différents noyaux (*kernel*): polynomial, RBF, et sigmoïdal. Notons ici que les paramètres optimaux de chaque noyau ont été choisis par la méthode de validation croisée.

TABLEAU. I
PERFORMANCES DES SVM POUR LES DEFERENTS NOYAUX

Ensembles d'indicateurs	Nbre VS	Noyau	Performance en test (%)
Temporels (27)	11	Polynomial	95.83
	5	RBF	100
	12	Sigmoïdal	100
Coefficients du modèle AR (19)	15	Polynomial	86.11
	11	RBF	97.22
	26	Sigmoïdal	83.33
Fréquentiels (5)	4	Polynomial	100
	6	RBF	100
	9	Sigmoïdal	100
Totale (51)	23	Polynomial	98.61
	10	RBF	100
	30	Sigmoïdal	97.22

Où Nbre VS est le nombre des vecteurs de supports

Les résultats du tableau.1 montrent que le meilleur pourcentage des bien prédits (performance en test) est obtenu avec les indicateurs fréquents (100%) pour les noyaux : RBF, polynomial, et sigmoïdal, tandis que la combinaison des trois ensembles d'indicateurs n'a pas amélioré les performances du classificateur, cela peut être expliqué par l'effet de redondance d'indicateurs.

Les résultats montrent aussi que le noyau RBF donne la meilleure performance pour les trois types d'indicateurs, cela est favorisé par un bon choix du largeur σ par la méthode de validation croisée, car ce paramètre détermine le rayon de l'hypersphère qui enferme les données dans l'espace multidimensionnel ; si la valeur de σ est trop petite, l'espace enfermé est aussi trop petit, donc on risque de perdre une partie significative des données, aussi une grande valeur peut causer un chevauchement entre les classes

L'examen du nombre des vecteurs de supports utilisés dans les différents cas étudiés, peut donner beaucoup d'informations concernant les vecteurs qui sont utilisés réellement, et aussi, il donne une indication sur la complexité des données dans l'espace augmenté par les différents noyaux utilisés. Quand l'hyperplan est difficile à déterminer, beaucoup de vecteurs de support doivent être utilisés, pendant que peu de vecteurs, indique que l'hyperplan est relativement facile à identifier, et par conséquent, la performance sera relativement bonne. Les résultats du tableau.1 montrent pour la matrice totale que le nombre des vecteurs de supports varie en fonction des noyaux choisis. Avec le noyau sigmoïdal, la fonction de décision est établi avec 30 vecteurs de supports, et 10 en utilisant un noyau RBF, ce qui explique les performances obtenues (97.22% pour le noyau sigmoïdal et 100% pour le noyau RBF).

CONCLUSION

Dans cet article nous avons présenté une méthode de détection des défauts d'engrenage par les séparateurs à vaste marge (SVM), trois types d'indicateurs vibratoires sont extrait,

le classificateur entraîné est testé avec trois types de noyaux (polynomial, RBF, et sigmoïdale).

Les SVM ont montré leurs aptitudes de classification des données pour les différents types d'indicateurs, les meilleurs résultats sont obtenus avec les indicateurs fréquentielles.

Les résultats montrent que Les coefficients du modèle AR peuvent être utilisés comme indicateur pour la classification des données avec la nécessité de détermination de l'ordre du modèle avant le calcul des ces coefficients.

Un bon choix de noyau (*kernel*), et de ces paramètres, est un issu major pour avoir une bonne classification des données.

REMERCIEMENTS

Les auteurs remercient Dr. Menad sidahmed de CETIM pour la base des données mise à notre disposition et pour les éclaircissements utiles.

Nous remercions également Dr. F. Vojtěch de l'université Technique de Tchèque pour la disponibilité de la boîte à outil SPRTTool. Et qui est accessible sur le site Internet : <http://cmp.felk.cvut.cz/cmp/software/stprtool/index.html>.

REFERENCES

- [1] G. Zwingelstein., Diagnostic des défaillances. Théorie et pratique pour les systèmes industriels, Traité des Nouvelles Technologies - Série Diagnostic et Maintenance. Editions Hermès, Paris, 1995.
- [2] V Vapnik . *Statistical Learning Theory*, wiley Interscience publication, NewYork, 1998.
- [3] V.Vapnik, *The Nature of Statistical Learning Theory*, 2nd edition. Springer, 2000.
- [4] C. Burge "A Tutorial on Support Vector Machines for Pattern Recognition," Data Mining and Knowledge Discovery, vol 2, pp121-167 . 1998
- [5] J.C. Platt. "*Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*," Technical Report MSR-TR-98-14 April 21, 1998. [4] .
- [6] A. Raad "*Contributions aux statistiques cycliques d'ordre supérieur : applications au diagnostic des défauts d'engrenage*," Thèse de doctorat, Université Technologie de Compiègne, 2003.
- [7] A. Felkaoui, B. Fortas, & A. Apostoliouk. "*Sur la sélection de l'ordre dans l'analyse spectrale moderne des processus linéaires*," ICSS'94 1994.
- [8] F. Vojtěch and V Hlaváček "Statistical Pattern Recognition Toolbox for Matlab," Czech Technical University; juin 2004
- [9] J.C Platt. "Probabilistic outputs for support vector machines and comparisons to Regularized Likelihood Method," Advances in Large Margin classifiers, MITPress, 1999.