

# Détection de défauts temps réel sur des objets à géométrie complexe : étude par SVM et hyperrectangles

S. Bouillant, J. Mitéran, F. Yang, M. Paindavoine

Le2i, Aile des Sciences de l'ingénieur - Université de Bourgogne - BP 47870 21087 Dijon

[sbouilla@u-bourgogne.fr](mailto:sbouilla@u-bourgogne.fr)

Résumé : Nous présentons dans cet article une application complète des « Support Vector Machine » au contrôle qualité par vision artificielle de pièces à géométrie complexe. Nous précisons le cadre pratique dans lequel s'effectuent les opérations, la nature des défauts à détecter ainsi que les techniques d'extraction des paramètres discriminants. Puis nous présentons les deux méthodes de classification utilisées. Nous définissons le protocole d'apprentissage, ainsi que la méthode de recherche des paramètres optimum du classifieur. Nous comparons les résultats obtenus sur différents espaces de description définis *a priori* ainsi que ceux issus d'une sélection de paramètres via un algorithme séquentiel.

*Abstract : We present in this paper our works on the classification of industrial parts based on "Support Vector Machine" method. We present the practical frame in which is made the operations, natures of the flaw t be detected as well as features extractions techniques. Then we introduce the two classification techniques we implemented. We explain our learning method and how we obtain optimum classifier parameters. We compare the results obtained on various features spaces, some based on a priori knowledge and on spaces extract from sequential selection algorithm.*

## 1. Introduction

La détection de défauts dimensionnel et d'aspect sur des objets en défilement à cadence élevée demande la mise en place d'un système de contrôle robuste et rapide. Nous proposons ici l'étude d'une machine de vision permettant l'analyse par classification d'une forme relativement complexe (spirale) afin d'améliorer la production, en détectant les défauts d'aspect et de géométrie qui peuvent l'affecter.

Actuellement, l'inspection est réalisée manuellement par des opérateurs, à un coût élevé. L'augmentation de productivité à qualité constante est donc le but initial des travaux présentés ici. Les spécifications industrielles demandent une vitesse de traitement minimale de 10 pièces par seconde. Ce problème peut être résolu en utilisant un système de classification basé sur une machine de vision. De nombreux articles [1], [2], [3] décrivent la détection de défauts à l'aide de méthodes de classification. La méthode retenue consiste à extraire de chaque point de vue un ensemble de mesures modélisant la partie spirale dimensionnelles ou d'aspect [4], [5], puis d'extraire des paramètres internes à chaque spire. Ces mesures alimentent le classifieur qui permet de distinguer une pièce bonne d'une pièce défectueuse. Afin de répondre à ces exigences de qualité tout en respectant les impératifs de traitement en temps réel, deux méthodes de classification ont été


envisagées. La première est basée sur un découpage de l'espace de décision par des hyperrectangles et la seconde sur les Support Vector Machine (SVM). La première méthode est rapide, que ce soit au niveau de l'apprentissage ou au niveau de la décision et a prouvé son efficacité dans plusieurs applications concrètes [6], [7]. Elle présente toutefois des faiblesses au niveau de la généralisation. L'avantage de la seconde méthode est de présenter un fort pouvoir de généralisation et de très bonnes performances de classification [8]. La fonction de décision, relativement coûteuse en temps de calcul, peut être approximée grâce à une combinaison avec la méthode précédente afin d'obtenir une décision temps réel [9]. Dans la première partie de cet article, nous présentons la pièce à contrôler, l'ensemble d'acquisition ainsi que les traitements permettant l'extraction des mesures nécessaires à la caractérisation de l'objet. Dans un deuxième temps, nous expliciterons les algorithmes de classifications retenus. Afin de caractériser les pièces défectueuses, nous avons scindé l'espace total de description en plusieurs sous espaces en se basant sur une connaissance *a priori* des défauts et sur un algorithme de sélection de paramètres. Finalement, nous comparerons les performances des deux méthodes de classification sur ces différents espaces de description, ainsi que deux approches applicables au contrôle qualité : répartition des pièces en deux classes {défaut, correcte}, conduisant à une classification globale, ou en N classes {défaut\_1, défaut\_2, ..., défaut\_N,

correcte} classification généralisée basée sur la classification défaut par défaut (classification particulière).

## 2. Acquisition des images et caractérisation de la pièce

### 2.1 Système d'acquisition et prétraitements

La pièce est composée d'une partie spiralée et d'une partie longiligne appelée « pattes »(Figure 1).



Pattes Corps (partie spiralée)

Figure 1: Partie à contrôler.




Figure 2 : Chaîne d'acquisition.

De précédents travaux nous ont conduit à choisir un système d'éclairage à diodes rouges en régime pulsé, commandé en courant éclairant la partie externe du spiralage [10]. Ce système permet l'acquisition de 10 images 1300x1030 à la seconde. (Figure 2).

### 2.2 Défauts à détecter

Les défauts à détecter sont au nombre de 50, regroupés en deux grandes familles : dimensionnel et d'aspect. Parmi les 20 défauts d'aspect concernés par ce travail, nous ne présenterons les 4 défauts classés comme prioritaires par l'industriel : décoloration locale (Classe D1), spires jointives (D2), bourgeons (D3), badigeons écaillés (D4) (Figure 3). Afin d'effectuer une classification de ces pièces, une base d'apprentissage et de test ont été construites à partir de 1605 pièces bonnes et d'un total de 135 pièces défectueuses réparties en 4 groupes de défauts.




Figure 3 : Défauts d'aspect

### 2.3 Extraction des paramètres de classification

L'extraction des paramètres qui seront utilisés lors de la classification s'effectue en 5 étapes : localisation de la pièce dans l'image, segmentation permettant la différenciation entre le spiralage externe et interne (combinaison des résultats issus de l'algorithme de Wen [11] appliqué d'une part sur l'image de luminance et d'autre part sur l'image résultant d'un gradient de Sobel), accroissement des régions détectées, étiquetage des spires (Figure 4) puis extraction des mesures proprement dites (Figure 5).



Figure 4 : Etiquetage des spires.




Figure 5 : Exemple d'extraction de paramètres géométriques.

Nous extrayons au total 148 paramètres formant l'espace de description total, dont : le nombre de spires détectées, les coordonnées des centres de gravité de chaque spire, les coefficients directeurs de la modélisation linéaire de chaque spire, du centre et des bords (lignes obliques Figure 5), l'aire de chaque spire, moments statistiques des niveaux de gris de chaque spire, etc. Afin d'assurer une densité suffisante dans les espaces de description et de tenir compte des connaissances *a priori* sur les défauts, l'espace total a été scindé en 4 sous espaces.

### 3. Classification et résultats

Afin de répondre au mieux aux contraintes de temps et de performances de détection, nous avons choisis d'étudier deux méthodes de classification, l'une basée sur une méthode de découpage de l'espace par des hyperrectangles [6], l'autre basée sur les Support Vector Machine [8] avec un noyau RBF [13] (Eq. 1).

$$K(\mathbf{x}, \mathbf{y}) = e^{\{-\gamma \|\mathbf{x} - \mathbf{y}\|^2\}} \quad \text{Eq. 1}$$

Afin de minimiser le nombre de paramètres à extraire pour suivre les cadences imposées, nous avons effectué une sélection de paramètres, selon l'algorithme « Sequential Backward Floating Selection » [14][15]. De plus, dans un souci de cohérence, nous avons utilisé comme critère de minimisation les résultats de classification par l'algorithme SVMs RBF [16]. Dans le cas des SVM, pour chacun des défauts et chacun des sous espaces, nous avons déterminé le noyau RBF optimum nous permettant d'atteindre un premier objectif de Taux de Fausse Alarme et Non Détection inférieurs à 1% et 20 % (**Erreur ! Source du renvoi introuvable.**). Le paramètre  $\lambda$  nous permet de suivre les variations des différents taux (Eq. 2).

$$\gamma_{\text{opt}} \in \left[ \frac{1}{d}; 5 \right] / \lambda_{\text{opt}} = \text{Min} \{ \lambda(\gamma) \} \quad \text{Eq. 2}$$

$$\text{avec } \lambda(\gamma) = \text{Max} \left\{ \frac{TFA(\gamma)}{1}; \frac{TND(\gamma)}{20} \right\}$$

Défaut – Dimension du sous-espace	Classification par SVM		
	$\lambda_{\text{opt}}$	TFA	TND
Défaut 1 – 32	0.872	0.872	6.250
Défaut 2 – 112	0.446	0.436	8.929
Défaut 3 – 89	0.436	0.436	8.333
Défaut 4 – 98	0.872	0.872	15.385
Bon contre tous les Défauts – 100	0.748	0.748	14.815
Défaut – Dimension du sous-espace	Classification par polytopes		
	$\lambda_{\text{opt}}$	TFA	TND
Défaut 1 – 32	0.748	0.748	7.250
Défaut 2 – 112	1.308	1.308	16.714
Défaut 3 – 89	2.679	2.679	5.167
Défaut 4 – 98	1.247	0.685	24.949
Bon contre tous les Défauts – 100	1.308	1.308	15.667

Tableau 1 : Performance maximale par défaut après sélection de paramètres

### 4. Optimisation par combinaison

La priorité de ce système de contrôle est de déterminer la nature d'une pièce parmi l'ensemble {défaut, bonne}, puis de donner un avis quant à la nature du défaut afin de corriger une éventuelle dérive de la production. Afin de d'atteindre ce premier but, deux voies ont été envisagées :

une combinaison d'avis de classifieurs décrivant la nature du défaut et une fusion d'avis de classifieur décrivant la nature de la pièce. Comme cela a été montré dans [17], à partir de deux fonctions de combinaisons (basée l'une sur la somme, l'autre sur le produit), il est possible de développer différentes combinaisons. La méthode employée est basée sur la majorité des voix. En l'absence de majorité, un élément est classé dans la classe la plus probable, ici la classe sans défaut. A cela nous avons ajouté une règle de décision exclusive : un élément appartient à une classe si et seulement si tous les avis sont concordants. Ici, nous avons combiné de deux façons différentes les avis des classifieurs les plus performants par défauts, sur l'espace total ainsi qu'un classifieur multi classes, rendant une décision sur la nature du défaut suivit d'une fusion des classes défectueuses

	$\lambda_{\text{opt}}$	TFA	TND
C.G. défaut 1	3.037	0.748	60.741
C.G. défaut 2	3.074	0.125	61.481
C.G. défaut 3	4.259	0.000	85.185
C.G. le défaut 4	3.815	0.623	76.296
Vote Majoritaire combinaison avec vote majoritaire	2.148	0.748	42.963
<b>Classification globale par combinaison avec vote exclusif</b>	<b>1.308</b>	<b>1.308</b>	<b>13.333</b>
<b>Classification globale</b>	<b>0.956</b>	<b>0.174</b>	<b>19.111</b>

Tableau 2 : Optimisation par combinaisons – Après sélection du classifieur généralisée pour chaque défaut.

Les taux de non détections sont ici évalués sur le nombre total d'éléments défectueux (135) et non plus sur le nombre d'éléments appartenant au défaut considéré d'où un taux de non détection élevé pour les 4 premières lignes du tableau. Quelque soit la règle de combinaison utilisée, les performances sont inférieures à celles obtenues avec d'un apprentissage multi classe, définissant un modèle global, suivit d'une fusion des classes défaut (Tableau 2).

### 5. Conclusions et perspectives

Le but de cette étude était de développer un système de détection, dans un premier temps, de pièces défectueuses puis de définir la nature du défaut constaté. Le premier objectif a été atteint via la classification multi classes suivit d'une fusion de tous les défauts. En ce qui concerne les performances de détection par défauts, elles sont encourageantes mais ne permettent pas une décision suffisamment fiable en l'état actuel. Une réflexion quant à une combinaison plus appropriée est en cours ainsi qu'une utilisation approfondie des différents sous espaces de paramètres issus de la méthode de sélection utilisée. De plus une implémentation de l'approximation de la frontière de décision fournit par les SVM est en cours. Elle permettra une prise de décision à une cadence plus importante, délestant le processeurs d'une charge non négligeable de calcul.

## 6. Bibliographie

- [1] M.M. Ratnam, Chee Peng Lim, Egg classification using shadow moiré and neural network, QCAV 2001, Le Creusot, Cépaduès-éditions, Vol.2, pp 355-358, 2001.
- [2] C. M. Bishop, Neural networks for Pattern Recognition, Oxford University Press, 1995, pp 110-230.
- [3] C. Firmin, D. Hamad, J.-G. Postaire, R.D. Zhang, Gaussian neural network for glass bottle production : a learning procedure, International journal on Neural systems, Vol. 8, 1996, pp 77-86.
- [4] B.Dubuisson Diagnostic et reconnaissance des formes, HERMES, Paris, 1990.
- [5] R.O. Duda and P.E. Hart, Pattern classification and scene analysis, Wiley, New-York, 1973, pp. 230-243.
- [6] J. Mitéran, P. Gorria and M. Robert, Classification géométrique par polytopes de contraintes. Performances et intégration, Traitement du Signal, Vol 11, n° 5, 1994, pp. 393-408.
- [7] D. Wettschereck and T. Dietterich, An experimental comparison of the nearest neighbor and nearest hyperrectangle algorithms, Machine Learning, Vol 19n n°1, pp. 5-27, 1995
- [8] V. Vapnik; The nature of statistical learning theory , Springer-Verlag, New York, 1995.
- [9] J.Miteran, S.Bouillant, M. Paindavoine, E. Bourennane, SVM approximation for real-time FPGA based image segmentation, proceeding JFAA 2002, E. Martin, M. Abid, Tunisie, pp.20-23.
- [10] J. Mitéran, P. Geveaux, R. Bailly and P. Gorria, Real-time defect detection using image segmentation (1997) Proceedings of IEEE-ISIE 97, Guimares, Portugal, pp. 713-716
- [11] Wen Hsiang Tsai, Moment preserving thresholding: a new approach, computer vision, graphics and image processing, n°29, pp. 377-393, 1985.
- [12] S.Bouillant, J. Miteran, E. Bourennane, M. Paindavoine, Real flaw detection on complex part : Study of svm and hyperrectangles based methods, Proceeding of IEEE – ICASSP 2002, Orlando.
- [13] V. Vapnik, Statistical learning theory, John Wiley & Son, INS, pp.498-499, 1998.
- [14] J. Kittler, Feature set search algorithms, Pattern recognition and signal processing, Sijthoff and Noordhoff, Alphen aan den Rijn, Netherlands, pp 41-60, 1978.
- [15] P. Somol, P. Pudil, J. Novovocova, P. Paclik, Adaptativ floating search methods in feature selection, Pattern Recognition Letters, Vol. 20, pp. 1157-1163, 1999.
- [16] M. Dash and H. Liu, Feature selection for classification, Intelligent data analysis 1, 1997, pp.131-156.
- [17] J. Kittler, M. Hatef, R.P.W. Duin, J. Matas, On combining classifiers, transactions on pattern analysis and machine intelligence, Vol. 20, n°3, March 1998