

Optimisation des performances d'un capteur hybride destiné à l'inspection de produits industriels en vue de la classification des défauts

F. Anstotz, J. Mercklé, J. Gresser

Institut de Recherche Polytechnique (IRP)
 Université de Haute Alsace
 34 rue Marc seguin
 68067 MULHOUSE CEDEX

Résumé : La recherche du "zéro défaut" dans la production industrielle nécessite le développement de systèmes d'inspection et de détection des défauts en temps réel sur les chaînes de production. Notre application concerne la détection et la reconnaissance des défauts dans la production de panneaux alvéolaires translucides. Le travail présenté ici décrit l'optimisation d'un capteur électro-optique en vue de rendre les mesures issues du capteur les plus discriminantes possible et de permettre ainsi un traitement efficace des données.

Abstract : Non destructive testing systems have now to be integrated in industrial processes in order to increase the quality. An opto-electronic method is presented and optimized to characterise surface defects in translucent polycarbonate panels. This application is finalized to in-service defect identification and localization.

1) INTRODUCTION

Le contrôle des produits en ligne de production nécessite le développement de dispositifs de contrôle de plus en plus performant tant au niveau de la vitesse d'inspection qu'au niveau de la fiabilité du contrôle. Afin de réduire les traitements informatiques longs et coûteux (traitement d'images, de signaux...) des systèmes hybrides électro-optiques exploitant le traitement parallèle inhérent à l'optique ont été développés [1].

Notre application consiste à détecter des défauts dans des panneaux alvéolaires translucides constitués de deux faces externes et d'une structure interne. Les caractéristiques optiques (transparence, striures superficielles...) ainsi que la nature des défauts (taches, rayures, sur-épaisseur de matière...) nous ont conduit à adapter et à optimiser un capteur électro-optique mis au point pour la détection de défauts dans les tissus[4]. Il est basé sur l'échantillonnage spatial du spectre de diffraction obtenu au plan focal d'un système optique. Une description du capteur et de son principe est donnée au paragraphe 2. L'optimisation et le choix des différents paramètres inhérent au montage est étudié au paragraphe 3. L'exploitation du capteur avec les résultats obtenus sur échantillons au moyen de différentes méthodes de classifications (mesure de proximité, Foley-Sammon, réseau neuromimétique) est présenté.

2) MONTAGE EXPERIMENTAL

2.1)principe

Le principe de détection des défauts est basé sur l'analyse de l'intensité lumineuse du spectre de diffraction correspondant à la transformée de Fourier de l'échantillon à étudier. Le spectre de diffraction est obtenu au plan focal d'un système optique convergent. Le montage classique de transformé de Fourier optique (TFO) [2] est constitué d'une source de lumière cohérente (Laser) éclairant l'échantillon ; une lentille sphérique convergente (fig 1) permet d'obtenir la TFO au point focal. Ce montage est à la base de nombreux systèmes de contrôle automatique, notamment d'un système de caractérisation d'états de surface [3], et d'un système de

détection de défaut dans les tissus [4]. La résolution spectrale d'un montage à lentilles sphériques est identique dans les directions u et v (fig 1) et proportionnelle à la distance focale de la lentille.

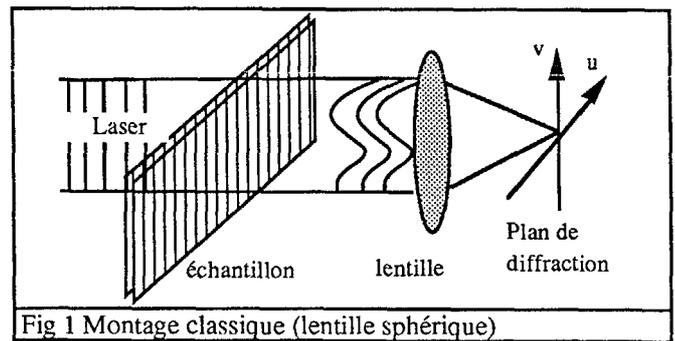


Fig 1 Montage classique (lentille sphérique)

Dans le cas où il est nécessaire d'avoir une résolution spectrale différente selon l'axe u et v on peut utiliser un système optique à base de deux lentilles cylindriques (fig 2) de focales différentes. Dans ce cas on place les lentilles de manière à confondre les deux points focaux au plan (u,v), chaque lentille effectuant la TFO dans une des directions u ou v. Dans ce cas nous obtenons une résolution spectrale :

$$\text{selon l'axe } u \Rightarrow \Delta u = \frac{u}{\lambda \cdot f_1}$$

$$\text{selon l'axe } v \Rightarrow \Delta v = \frac{v}{\lambda \cdot f_2}$$

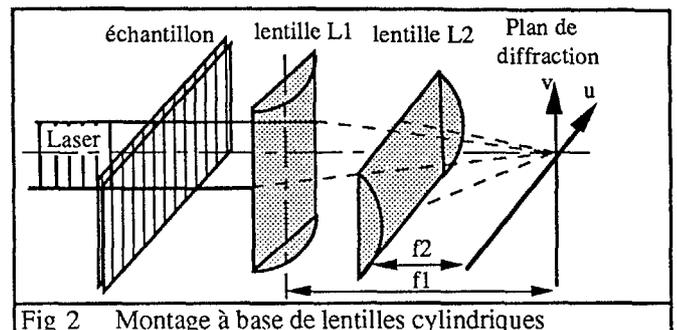
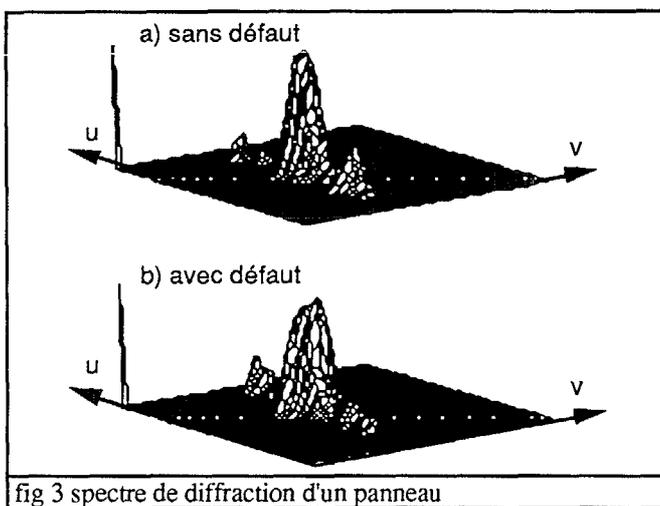


Fig 2 Montage à base de lentilles cylindriques

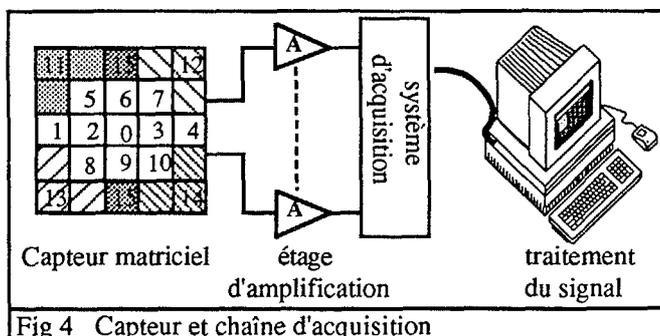


2.2) Le capteur

Une étude qualitative du spectre ainsi que des simulations sur un modèle mathématique du panneau nous ont permis de choisir un capteur adapté aux critères de contrôle qualité du produit inspecté [5]. La forme du spectre pour un échantillon sans défaut ne présente pas de composantes spectrales de fréquence élevée selon l'axe v ; cette caractéristique du spectre est due aux striures naturelles des panneaux (fig3). En présence d'un défaut ce spectre est dégradé (déformation du spectre, atténuation de composantes spectrales, apparition de fréquences selon l'axes v , ...) en fonction du type de défaut. Compte tenu de cette forme du spectre le capteur classique "Wedge Ring Detector" pour échantillonner les spectres de diffraction [6] présente peu d'intérêt d'autant plus que nous ne nécessitons ni l'invariance en rotation ni l'invariance à la taille du spectre.



Nous avons utilisé un capteur matriciel à 25 cellules photovoltaïques en reliant électriquement des cellules voisines afin de réduire à seize le nombre de signaux caractérisant le spectre (fig 4). Ces cellules sont associées à un dispositif électronique et à un système d'acquisition de signaux afin de générer, pour chaque mesure, un vecteur à 16 composantes. Ces vecteurs sont analysés et traités par logiciel.

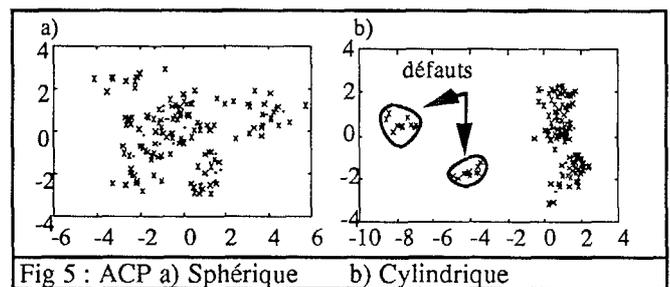


3) CHOIX ET OPTIMISATION DU MONTAGE

Nous avons cherché à déterminer le montage optique le plus performant et à l'optimiser au niveau de son aptitude à dissocier les vecteurs représentant un défaut, des vecteurs représentatifs d'une zone saine. Les paramètres sur lesquels il est possible d'agir pour optimiser le montage sont : le type de lentilles (sphériques ou cylindriques) utilisées pour

réaliser la TFO, le diamètre du faisceau définissant la fenêtre de mesure, la focale des lentilles et leur position par rapport à l'échantillon.

L'analyse en composantes principales (ACP) permet d'évaluer le caractère discriminant des vecteurs de mesures de manière graphique [7]. L'ACP est basée sur l'étude de la matrice de corrélation. La projection des vecteurs dans le plan des deux premiers axes discriminants (représentant un maximum de la variance totale des vecteurs) met en évidence des regroupements (classes) et la ressemblance des vecteurs. Des mesures sur différents échantillons présentant un défaut type et leur analyse en ACP (fig 5) nous ont permis de déterminer le montage le plus apte à dissocier les différents types de défauts. Cette étude a montré l'avantage d'utiliser un montage à lentilles cylindriques afin d'avoir une résolution différente dans les deux directions du spectre. Dans le cas des montages à lentilles sphériques de focales faibles la résolution suivant l'axe " v " s'avérait insuffisante. Dans le cas des focales longues on observait une perte d'informations selon l'axe " u " due à une trop grande dilatation du spectre et à la taille limitée du capteur. L'ACP permet également d'étudier les composantes des vecteurs en mettant en évidence les cellules du capteur responsables de la discrimination ou les cellules délivrant des informations redondantes (signaux corrélés).



4) DETECTION DES DEFAUTS

4.1) Minimum de distance

La méthode utilisée est basée sur l'évaluation de la distance euclidienne séparant le vecteur à tester d'un vecteur de référence caractérisant des échantillons sans défauts. La détection se fait par simple seuillage de la mesure de distance, la valeur du seuil est déterminée de manière empirique. Le vecteur de référence est constitué d'un vecteur moyen (m_i) et d'un vecteur d'écart-type (σ_i) calculé pour un ensemble de vecteurs d'apprentissages (x) sans défaut. La mesure de la distance euclidienne (d) est défini par :

$$d = \left(\frac{\sum [y_i - m_i]^2}{\sigma_i^2} \right)^{1/2} \text{ avec :}$$

$$m_i = \frac{1}{n} \sum (x_i) \text{ et } \sigma_i = \left(\frac{1}{n-1} \sum [x_i - m_i]^2 \right)^{1/2}$$

La normalisation de la distance par l'écart type permet de réduire la contribution des variables à écart-type élevé. La figure 6 montre la moyenne (barres horizontales) et l'écart-type (barres verticales) des 16 composantes du vecteur de référence, la courbe représente un vecteur caractérisant un défaut de type "rayures".

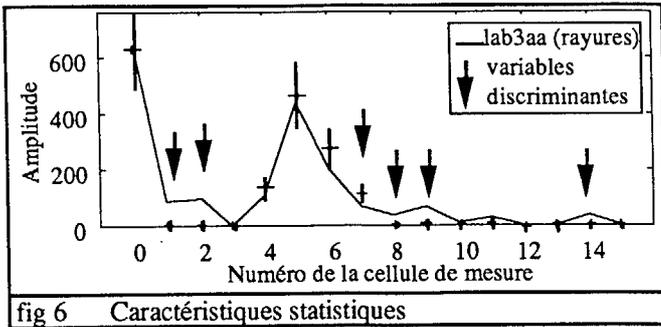


fig 6 Caractéristiques statistiques

Nous avons relevé des courbes de distance par rapport au vecteur de référence (fig 7) pour différents échantillons présentant des défauts types afin de déterminer les performances de cette méthode (tab 1).

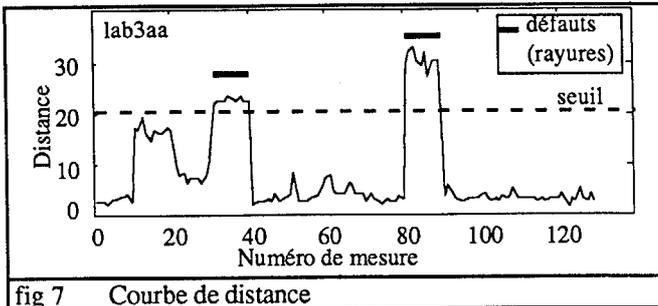


fig 7 Courbe de distance

échantillons	type de défaut	échantillons mal classés	taux (%) de "bien classés"
lab2a	structure	0/130	100%
lab3aa	rayure	16/130	87%
lab3ba	coulure	26/130	80%
lab5ba	coulure	38/200	81%
Global	183/1590	88%

tab 1 Résultats pour différents types de défauts

Cette méthode présente l'avantage d'une mise en oeuvre simple, elle permet une implantation en temps réel sur un ordinateur classique. Pour déterminer le seuil il est souvent nécessaire de faire un compromis entre la non-détection des défauts et les fausses alertes. Elle peut être généralisée au cas multi-classes en déterminant un vecteur de référence pour chaque classe et en cherchant, pour chaque vecteur de mesure, la classe la plus proche au sens de la distance euclidienne.

4.2) Méthode de Foley-Sammon

La méthode de Foley-Sammon [11] est basée sur la projection de vecteurs x_i de dimension n sur une droite (dans le cas de 2 classes) de vecteur directeur w . Le vecteur w doit être dirigé de manière à ce que la projection des vecteurs x_i défini par $y = w^T \cdot x$ maximise la distance inter-classe. Pour satisfaire cette condition il faut que w maximise le ratio de Fisher :

$$F(w) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{s}_1 - \tilde{s}_2} = \frac{w^T \cdot S_w \cdot w}{w^T \cdot S_B \cdot w}$$

\tilde{m}_1, \tilde{m}_2 : valeur moyenne de la projection de chaque classe

\tilde{s}_1, \tilde{s}_2 : variance de la projection de chaque classe
 S_B : matrice de covariance inter-classe
 S_w : matrice de covariance intra-classe (défini par la somme des matrices de covariance de chaque classe)
 La solution maximisant $F(w)$ est donnée par la relation[7] :

$$w = S_w^{-1} \cdot (m_1 - m_2)$$

avec m_1, m_2 : vecteurs moyens de chaque classe

Pour réaliser un tel système, il faut passer par une phase d'apprentissage permettant d'évaluer le vecteur w à partir d'un ensemble de vecteurs représentatifs de chaque classe. En phase d'utilisation on calcul la projection des vecteurs à tester :

$y = w^T \cdot x$ et on seuille cette projection par :

$$S = \frac{(m_1 + m_2)}{2}$$

si $y > S$ alors x appartient à la classe 1
 si $y < S$ alors x appartient à la classe 2

Nous avons réalisé des essais pour la même série d'échantillons que pour la méthode précédente. La figure 8 représente la projection des vecteurs de mesure relevés pour l'échantillon Lab3ba sur le vecteur w (calculé pour un ensemble de mesures de référence). La proximité des mesures 60-69, sans défaut, provoque quelques fausses alertes. Le tableau 2 donne les résultats pour différents échantillons présentant divers types de défauts.

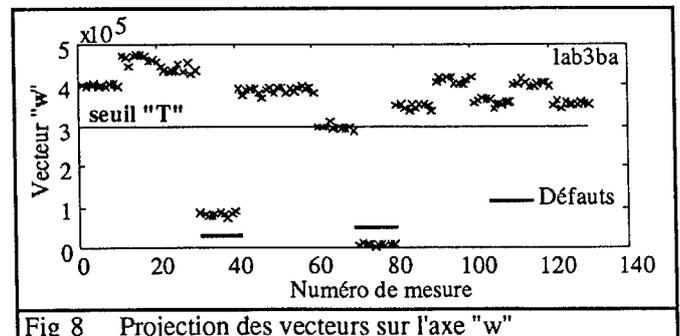


Fig 8 Projection des vecteurs sur l'axe "w"

échantillons	type de défaut	échantillons mal classés	taux (%) de "bien classés"
lab2a	structure	0/130	100%
lab3aa	rayure	10/130	92%
lab3ba	coulure	3/130	97%
lab5ba	coulure	55/200	72%
Global	198/1720	88%

tab 2 Résultats pour différents types de défauts

Cette méthode nécessite, lors de la phase d'apprentissage, un calcul plus important que dans 4.1 (matrice de covariance, inversion...) ainsi qu'un ensemble de vecteurs représentatif de chaque classe. A l'exploitation cette méthode se réduit à un calcul de produit de deux vecteurs ($w^T \cdot x$) et un seuillage du résultat pour détecter les défauts. Le seuil est défini par les moyennes des projections des deux classes de référence de l'ensemble d'apprentissage sur l'axe w .



4.3 Réseaux de neurones

Avec les récents développements des réseaux de neurones artificiels de nombreuses applications ont été développées en reconnaissance de formes, traitement du signal, reconnaissance de la parole.... Les réseaux de neurones sont des systèmes de traitements non algorithmique constitués de processeurs (neurones) partiellement ou totalement interconnectés. Un réseau de neurones est constitué d'une couche de neurones d'entrée, d'une ou plusieurs couches cachées et d'une couche de sortie. La phase d'apprentissage du réseau consiste à présenter un ensemble de couples (entrée, sortie) et d'ajuster le poids des interconnexions entre les neurones de manière à minimiser l'erreur de la couche de sortie.

Dans notre application nous avons utilisé un réseau de type à "retro-propagation" [12] à une seule couche cachée pour réaliser la classification "défaut / pas défaut". Ce réseau présente 16 neurones dans la couche d'entrée et deux neurones dans la couche de sortie (un neurone pour chaque classe). Dans les réseaux à retro-propagation on cherche, lors de l'apprentissage, à minimiser l'erreur quadratique moyenne de la couche de sortie. Pour déterminer le nombre de neurones en couche cachée nous avons tracé la courbe de l'erreur quadratique de la sortie en fonction du nombre de neurones dans la couche cachée pour un nombre constant de présentations de l'ensemble d'apprentissage (fig 9). Le nombre optimal de neurones en couche cachée, pour notre ensemble d'apprentissage et pour un réseau à une couche cachée est de : 8 neurones.

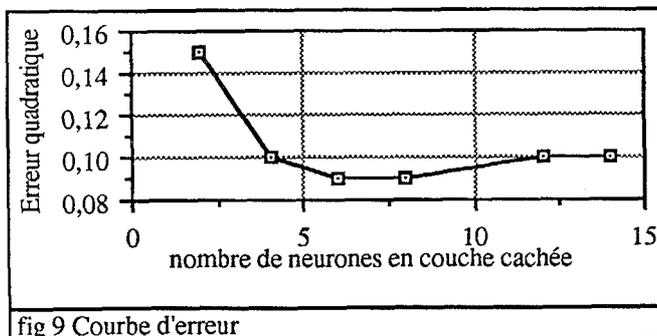


fig 9 Courbe d'erreur

Nous avons réalisé un apprentissage du réseau pour le même ensemble de données que pour la méthode de Foley-Sammon (4.2). La procédure d'apprentissage est arrêtée dès que l'erreur quadratique moyenne sur 50 données pris aléatoirement dans l'ensemble d'apprentissage est inférieure à 0,01. A l'exploitation du réseau nous considérons que l'entrée appartient à la classe dont le neurone de sortie est le plus actif. Pour l'ensemble d'apprentissage nous obtenons 100% de bien classés. Le tableau 3 donne les résultats pour les différents échantillons testés.

échantillons	type de défaut	échantillons mal classés	taux (%) de "bien classés"
lab2a	structure	7/130	94%
lab3aa	rayure	2/130	98%
lab3ba	coulure	3/130	97%
lab5ba	coulure	69/200	65%
Global	322/1720	81%

tab 3 Résultats pour différents types de défauts

Le taux de détection est plus important, par contre le taux de fausse alerte est sensiblement plus élevé. L'inconvénient des réseaux à retro-propagation est le temps d'apprentissage très long (environ 8h sur AT386 SX).

5) CONCLUSION

L'intérêt d'utiliser un système hybride pour la détection des défauts dans les panneaux translucides est de réduire le temps de traitement. L'échantillonnage spatial du spectre de diffraction par un capteur photovoltaïque matriciel permet de réduire la taille des informations à 16 caractéristiques. L'analyse en composantes principales des vecteurs issus du capteur permet de mettre en évidence la nature discriminante des vecteurs et permet ainsi la mise au point du dispositif expérimental. Le taux de fausses alertes important pour les trois méthodes de détection est dû à la grande disparité des vecteurs définissant les alvéoles sans défaut. Les réseaux de neurones à retro-propagation demande un temps d'apprentissage long (> 8 heures) et nécessite plus de calcul à l'exploitation que les 2 méthodes classiques présentées. Néanmoins vu les récents développements de réseaux neuronaux câblés, le temps d'apprentissage et d'exploitation pourrait être considérablement réduit. Les futurs travaux consisteront à éprouver d'autres types de réseaux de neurones tels que les réseaux à contre-propagation en vue d'en évaluer les performances.

Bibliographie

- [1] H. L. Kasdan "Industrial applications of diffraction pattern sampling". Optical Engineering sept 79
- [2] J.W. Goodman "Introduction to Fourier Optics". McGraw-Hil, New York (1968)
- [3] C. Gorecki "Classement des surfaces non polies par échantillonnage de la densité spectrale d'énergie". Journal Optics 1989
- [4] S. Ribolzi, P.E. Exbrayat, J. Gresser, J. Mercklé "On line fault detection on textile material by opto-electronics processing". IFAC-Symposium-AIPAC'89, Nancy 1989
- [5] F. Anstotz, J. Merckle, j. Gresser "Procédé de détection électro-optique de défauts en temps réel dans les tissus et les panneaux translucides". OPTO'90 Paris 1990
- [6] G.G. Lendaris, G.L. Stanley "Diffraction-pattern sampling for automatic pattern recognition". Procc. IEEE (1970)
- [7] R. O. Duda, P. E. Hart "Pattern classification and scene analysis". John Wiley & Sons 1973
- [8] D. Clark "Practical optical Fourier analysis for high speed inspection". Optical engineering 1988
- [9] D. Casasent "Feature extractors for distortion-invariance robot vision". Optical Engineering 1984
- [10] D. E. Glover "An Optical Fourier / Electronic Neurocomputer automated inspection System"
- [11] D. H. Foley, J. W. Sammon "An optimal set of discriminant vectors". IEEE 1975
- [12] D.E. Rumelhart, J.L. McClelland "Parallel distributed Processing".