

Apports des outils fondés sur les corrélations d'ordre trois à l'analyse de textures

Contribution of Third Order Correlation Tools for Textures Analysis

par **Christophe COROYER*** et **Patrick DUVAUT****

* ESIGETEL, 1, rue du Port de Valvins, 77215 AVON-FONTAINEBLEAU Cedex
coroyer@esigetel.fr, tel : 01 60 72 70 51, fax : 01 60 72 11 32

** ETIS/ENSEA, 6, avenue du Ponceau, 95014 CERGY Cedex
duvaut@ensea.fr, tel : 01 30 73 66 10, fax : 01 30 73 66 27

résumé et mots clés

Cette étude apporte une contribution à la classification de textures à l'appui de signatures déduites des corrélations et/ou spectres d'ordre élevé. La première partie montre que les textures ont pour la plupart une statistique non gaussienne, bien représentée à l'ordre trois. Les tests de normalité choisis, les tests d'asymétrie et du Kurtosis, ont été calibrés dans cette étude. Pour limiter la complexité calculatoire et obtenir de faibles variances d'estimation, nous nous sommes orientés vers des attributs fondés sur les corrélations d'ordre trois dans un cadre stationnaire : la bicorrélation, le bispectre et le bicorspectre. Nous avons opté pour une stratégie 2D séparable. Nous proposons dans une seconde partie une caractérisation fondée sur des représentations décrivant les corrélations spatiales d'ordre trois. La dernière partie est consacrée à la classification des textures s'appuyant sur les attributs précédents. Nous donnons des performances de discrimination sur neuf textures de Brodatz, en comparant avec les résultats des paramètres, extraits de matrices de cooccurrences, proposés par Haralick.

Classification de textures, tests de normalité, asymétrie, Kurtosis, bicorrélation, bispectre, bicorspectre.

abstract and key words

This study brings a contribution to non-gaussian textures classification thanks to signatures extracted from high order correlations and/or spectra. The first part exhibits that most of the textures present a non gaussian statistic, well represented for the third order. The chosen normality tests, the Skewness test and the Kurtosis test, have been calibrated for this study. To lower the complexity of algorithms and yet to reach low estimation variances, we choose to focus on third order correlations with the stationary hypothesis: bicorrelation, bispectrum and bicorspectrum. A Row/columns representation of images has been selected. We propose in the second part characterization based on representations describing third order spatial correlations. The last part concerns textures classification using the previous features. Discrimination performances on Mine Brodatz textures are presented and comparison with the results of a coocurrence matrix method are provided.

Textures Classification, Normality tests, Skewness, Kurtosis, Bicorrelation, Bispectrum, Bicospectrum.

1. introduction

Les méthodes utilisées pour la classification visent toutes à définir des paramètres suffisamment pertinents permettant de ranger les textures inconnues dans autant d'ensembles distincts. Par paramètre pertinent, on entend alors une grandeur caractéristique,

scalaire ou vectorielle, qui, lorsqu'elle est estimée sur l'image digitalisée, conduit à une valeur représentative. Le but est donc de pouvoir classifier automatiquement une texture parmi un ensemble fini de textures connues dans le cadre d'une méthode supervisée. Nous introduirons aussi le terme descripteur : par descripteur, nous désignerons la collection des paramètres pertinents ainsi que le modèle, si la méthode de classification utilise un modèle paramétrique.

Apports des outils fondés sur les corrélations

Nous proposons un classement des méthodes selon trois grandes familles. Ces familles sont définies avec une approche traitement du signal pour le vocabulaire. Cette démarche conduit à une vision plus globale qu'un catalogue de méthodes et ce classement permet de mieux déterminer les propriétés par familles de méthodes.

1. les méthodes bayésiennes, où l'on estime la densité de probabilité de la texture.
2. les méthodes paramétriques, où l'on définit un modèle fonction d'un jeu de paramètres visant à représenter au mieux la texture considérée.
3. les méthodes non paramétriques, comprenant les méthodes qui n'appartiennent à aucune des familles précédentes.

Classe	Méthode	Auteurs
bayésiennes	Cooccurrence	[13]
"	Champs Markoviens	[11]
paramétriques	Modélisation AR	[9]
non paramétriques	Spectre de Texture	[22]
"	Fractales	[21]
"	Gabor	[3]
"	Paquets d'ondelettes	[15]
"	Moments	[9]

Nous proposons dans cet article une contribution à la classification de textures non gaussiennes à l'appui de signatures déduites des corrélations et/ou spectres d'ordre élevé. De tels descripteurs corrélatoires et spectraux dépendent, dès l'ordre trois, de deux arguments pour un processus aléatoire stationnaire monodimensionnel. Toujours à l'ordre trois, le nombre de ces arguments passe à quatre dans le cas bidimensionnel, à six si de plus, l'hypothèse de stationnarité est levée. Vu les grandes difficultés à visualiser des différences à partir de fonctions d'au moins quatre variables, la majorité de ce travail opère sur des descripteurs d'ordre élevé « ligne » et/ou « colonne », représentatifs de deux comportements monodimensionnels. Critiquable car bien évidemment susceptible de réduire la nature intrinsèquement bidimensionnelle d'une texture, ce contexte d'étude conduit néanmoins à des résultats de classification intéressants. Ceux-ci justifieraient l'utilisation très coûteuse, dans un prolongement, de descripteurs bidimensionnels, corrélatoires et spectraux d'ordre élevé. Nous pouvons ajouter pour étayer un tel choix que dans le domaine de la compression et du codage des images, la plupart des méthodes travaillent en lignes-colonnes et des études ont montré que la perte d'information à la restitution des images n'était guère différente pour un algorithme 2D séparable par rapport à un algorithme 2D global [19].

La première partie s'intéresse à la séparation des textures en deux grandes classes : les textures gaussiennes et les textures non gaussiennes, afin de rentabiliser au mieux la mise en œuvre d'outils complexes. Pour ceci, nous utilisons les tests statistiques d'asymétrie et du Kurtosis. Nous donnons les performances de rejet de l'hypothèse gaussienne. La dernière étape est l'étude de la normalité des textures sur une base de test des textures de Brodatz [4], présentée figure 1.

Nom	Texture	Numéro dans l'album
Herbe	Grass lawn	D9
Tissage	Herringbone weave	D17
Laine	Woolen cloth	D19
Cuir	Pressed calf leather	D24
Sable	Beach sand	D29
Eau	Water	D38
Bois	Wood grain	D68
Raphia	Raphia	D84
Bulles	Plastic bubbles	D112




Figure 1. – Présentation de la base de test.

Ayant montré que la plupart des textures étaient non gaussiennes et bien représentées à l'ordre trois, nous nous intéressons, dans la seconde partie, plus spécifiquement à la classe des textures non gaussiennes. Nous rappelons la définition d'outils fondés sur les corrélations spatiales d'ordre élevé entre pixels, puis, les utilisons pour caractériser des textures. Nous présentons la version dynamique du cumulatif d'ordre trois. Nous introduisons aussi une nouvelle représentation temps/fréquence : le bicorspectre. Les estimateurs de la bicorrélation, du bispectre et du bicorspectre sont alors testés sur des processus représentatifs, puis sur la base de test des textures.

Puis la troisième partie décrit l'utilisation de ces outils pour la classification des textures. Nous introduisons un vecteur de paramètres à partir des attributs d'ordre trois pour une classification à l'aide d'un classifieur classique : un réseau de neurones. Nous montrons l'apport de l'ordre trois à la classification. Les résultats de classification sont comparés dans les deux paragraphes à la méthode étalon des matrices de cooccurrences.

2. normalité des textures

Remarque 1

Nous présentons dans ce paragraphe, ainsi que dans le suivant, des outils classiques pour la communauté travaillant dans le domaine des statistiques d'ordre élevé (SOS). Cet article touchant aussi des traiteurs d'images, peu familiers avec les outils utilisés, nous avons rendu cette présentation assez didactique. Les définitions utilisées étant classiques pour la communauté SOS, ils seront plus intéressés par les applications sur les textures et peuvent passer directement aux résultats.

Nous présentons un test de normalité dans le but de rejeter des processus non gaussiens. Dans le cas où la loi alternative est connue, ce test de rejet devient un test de deux hypothèses simples [20]. Nous désirons un bon compromis simplicité/performance, ainsi qu'une bonne adaptation pour une utilisation automatique. A cet égard, nous avons retenu les tests d'asymétrie et du Kurtosis.

2.1. estimateurs d'asymétrie et du Kurtosis

2.1.1. formes explicites

Les cumulants d'ordres 3 et 4, ou asymétrie et Kurtosis normalisés, sont définis, pour des processus centrés réduits [18], c'est-à-dire pour une variable aléatoire X telle que $E[X] = 0$ et $Var[X] = 1$:

- asymétrie normalisée

$$S = \frac{E[X^3]}{E[X^2]^{\frac{3}{2}}} = E[X^3] \quad (1)$$

Une valeur du cumulants d'ordre trois non nulle traduit une dissymétrie de la densité de probabilité. La définition de la mesure d'asymétrie, dans la littérature, est le carré du moment d'ordre trois, pour une variable centrée réduite. Nous avons choisi la définition 1 afin de conserver l'information de signe du moment d'ordre 3. En effet, une asymétrie positive entraîne la relation suivante : moyenne > médiane > mode. Inversement, une asymétrie négative entraîne : mode < médiane < moyenne [14]. On a immédiatement pour une densité de probabilité (dp) symétrique mode = médiane = moyenne. Le signe du cumulants d'ordre 3 nous donne une information sur la position d'un maximum (s'il en existe un) de la dp.

Remarque 2

Quelques définitions complémentaires.

La médiane est la valeur x_m pour laquelle :

$$\int_{-\infty}^{x_m} p_X(x).dx = \int_{x_m}^{\infty} p_X(x).dx = \frac{1}{2}$$

Un mode est une valeur telle que la densité de probabilité est maximale.

- Kurtosis normalisé

$$K = \frac{E[X^4]}{E[X^2]^2} - 3 = E[X^4] - 3 \quad (2)$$

Le Kurtosis permet de qualifier la remontée de la « queue » d'une densité de probabilité. Le Kurtosis d'une densité gaussienne centrée réduite vaut 0. On peut attribuer à une dp des propriétés selon qu'elle est pseudo-gaussienne à l'ordre 4 ou « mesokurtic » d'après Kendall [14] ($K = 0$), sur gaussienne ou « leptokurtic » ($K > 0$), sous gaussienne ou « platykurtic » ($K < 0$). Nous dirons qu'un processus est pseudo-gaussien à l'ordre 4 si la mesure du Kurtosis a une valeur très faible (inférieure à un seuil).

En pratique, nous retenons les formes empiriques suivantes d'estimateurs :

- asymétrie

$$\hat{S} = \frac{1}{N} \sum_{i=1}^N x_i^3 \quad (3)$$

- Kurtosis

$$\hat{K} = \frac{1}{N} \sum_{i=1}^N x_i^4 - 3 \quad (4)$$

où x_i représente les échantillons de la variable aléatoire X centrée réduite, et N le nombre d'échantillons de l'estimateur.

Remarque 3

Nous considérons les données centrées réduites. Pour ceci, nous devons en fait estimer la moyenne et la variance sur les données. Nous définissons donc la variable x_i par :

$$x_i = \frac{x'_i - \hat{\mu}}{\hat{\sigma}} \quad (5)$$

où les x'_i représentent les données brutes et $\hat{\mu}$ et $\hat{\sigma}$ sont les moyennes et variances estimés sur les valeurs x_i .

2.1.2. moyennes et variances des estimateurs

Nous supposons dans ce paragraphe que les moyennes et variances des processus sont connues. Dans notre étude, nous prenons donc, la moyenne $\hat{\mu} = \mu$ et la variance $\hat{\sigma} = \sigma$.

Pour des variables x_i indépendamment identiquement distribuées (iid) centrées réduites, les moyennes et variances des estimateurs d'asymétrie et du Kurtosis sont données par :

- moyenne de l'aplatissement

$$E[\hat{S}] = S \quad (6)$$

- variance de l'aplatissement

$$VAR[\hat{S}] = \frac{1}{N} (m_6 - S^2) \quad (7)$$

- moyenne du Kurtosis

$$E[\hat{K}] = K \quad (8)$$

- variance du Kurtosis

$$VAR[\hat{K}] = \frac{1}{N} (m_8 - K^2) \quad (9)$$

où m_6 et m_8 sont respectivement les moments d'ordre 6 et d'ordre 8.

Les variances sur les deux cumulants dépendent fortement de la loi du processus de test. Nous devons donc dans cette étude voir si les lois de probabilités des textures conduisent à une variance suffisamment faible et à partir de quel nombre de points, l'estimation peut être considérée comme sûre, compte tenu des valeurs mesurées.

2.2. performances des tests sous l'hypothèse H_0

Dans cette partie, nous nous proposons de calibrer les tests lorsque l'on ne connaît pas la loi du processus alternatif non-gaussien. Nous ne connaissons donc que la loi « normale » du processus sous l'hypothèse H_0 . Nous n'avons donc accès qu'aux probabilités conditionnellement à H_0 . Si l'on s'intéresse à la probabilité de « rejet erroné », on a :

- pour l'asymétrie :

$$Pr\{|\hat{S}| > \varepsilon/H_0\} \quad (10)$$

- pour le Kurtosis :

$$Pr\{|\hat{K}| > \varepsilon/H_0\} \quad (11)$$

Nous représentons sur les figures 2 et 3 ces probabilités en fonction du seuil pour différents nombres d'échantillons.




Figure 2. – Probabilité de rejet erroné du test d'asymétrie sous H_0 .




Figure 3. – Probabilité de rejet erroné du test du Kurtosis sous H_0 .

Ces courbes nous serviront à connaître la probabilité d'erreur lorsque l'on classera une texture comme non-gaussienne.

Nous savons donc que les estimateurs ont une loi de probabilité gaussienne sur la base de test, pour un nombre d'échantillons limité. Nous souhaitons effectuer une calibration des tests d'asymétrie et du Kurtosis pour pouvoir décider avec une probabilité de rejet erroné si un processus est gaussien ou non. Cette étape est nécessaire dans la stratégie de cette étude, pour valider quantitativement la non normalité des textures.

2.3. normalité des textures

Les tests d'asymétrie et du Kurtosis sont ici appliqués aux textures. Nous avons effectué les calculs de moments sur des images de taille 64×64 . Les estimateurs, pour ces tailles d'images, ont des variances très faibles, la texture étant considérée comme un processus aléatoire 1D.

La chaîne de traitements utilisée pour la prise d'image et la digitalisation font qu'une image ne peut être considérée comme un processus aléatoire indépendant. Pour pallier l'indépendance statistique, nous avons utilisé pour estimer les cumulants sur les textures la technique du bootstrap [12]. Il s'agit dans notre cas de remplacer l'indépendance statistique par une indépendance spatiale. Pour ceci, nous prélevons des échantillons aléatoirement sur un ensemble de sous-images. Dans ce cas, on peut considérer les échantillons comme spatialement indépendants.

Les résultats des moyennes et écarts types de cumulants estimés sur 56 sous-images sont les suivants :

Texture/Ordre	\hat{S}	$ET(\hat{S})$	\hat{K}	$ET(\hat{K})$
Wood grain D68	1.17	0.38	1.04	0.98
Plastic bubbles D112	0.91	0.29	0.79	0.91
Herringbone weave D17	-0.48	0.07	-0.64	0.13
Water D38	-0.18	0.22	-0.16	0.33
Grass lawn D9	0.20	0.16	-0.82	0.18
Woolen cloth D19	0.41	0.24	-0.42	0.31
Pressed calf leather D24	0.65	0.09	-0.81	0.14
Raphia D84	0.04	0.15	-1.07	0.09
Beach sand D29	-0.54	0.13	-0.098	0.40

Nous présentons, figures 4 et 5, un écart à la normalité à l'ordre 3 ou à l'ordre 4 des différentes textures.

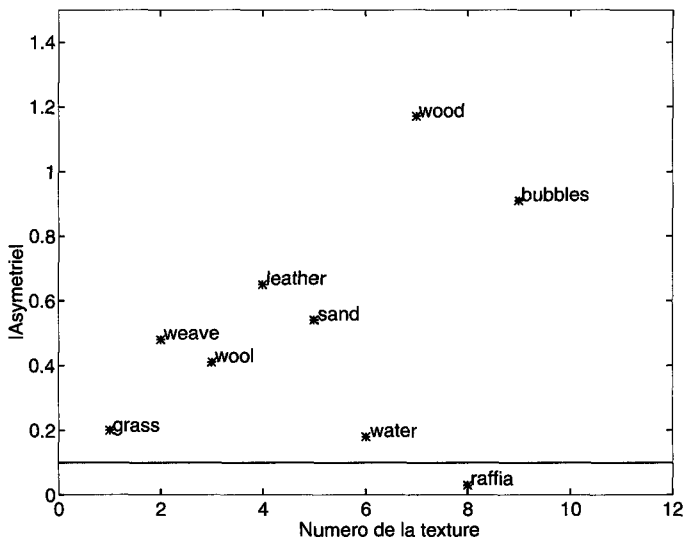


Figure 4. – Test d'asymétrie sur les textures de Brodatz.

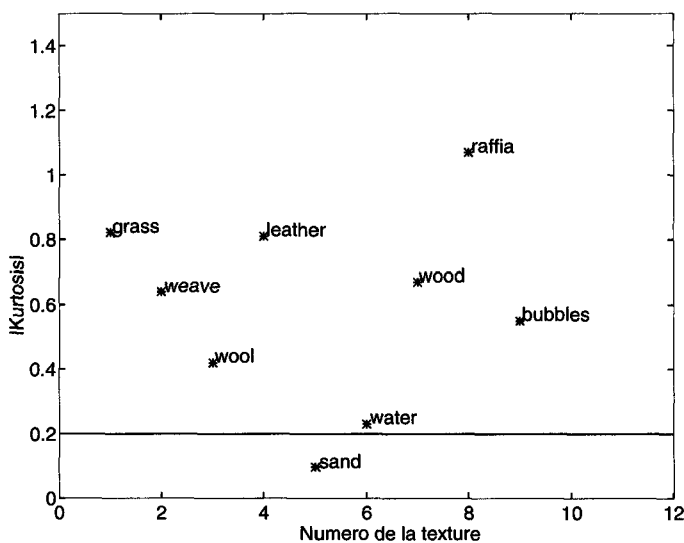


Figure 5. – Test du Kurtosis sur les textures de Brodatz

3. outils fondés sur les corrélations d'ordre trois pour l'analyse de textures

3.1. bicorrélation et bispectre

La bicorrélation d'un processus stationnaire réel est la version dynamique, au sens spatial, du cumulants d'ordre 3 pour une variable centrée.

3.1.1. définition

Si on appelle x_c le signal x stationnaire centré, alors la bicorrélation γ_3 est immédiatement définie par [16] :

$$\gamma_3 [m, n] = E [x_c [t] \cdot x_c [t + m] \cdot x_c [t + n]] \quad (12)$$

La stationnarité supposée du processus x donne à la bicorrélation les propriétés de symétries hexagonales illustrées à la figure 6.




Figure 6. – Propriétés de symétries hexagonales.

3.1.2. estimateur de la bicorrélation

Comme pour l'estimateur de la fonction d'autocorrélation à l'ordre deux, on peut définir deux estimateurs : l'estimateur biaisé et le non biaisé [6]. Pour les deux estimateurs, la propriété de symétrie hexagonale devra être vérifiée. Pour s'assurer de cette symétrie, on limite l'estimation de la bicorrélation à l'espace minimal ($\frac{1}{6}$ de plan). Ensuite, on complète par symétrie comme indiqué sur la figure 6. Cette méthodologie est intéressante pour diminuer le nombre d'opérations lors de l'estimation de la bicorrélation. Nous supposons dans la suite que la moyenne du processus X est connue exactement.

3.1.2.1. estimateur

$$\hat{\gamma}_{3,b}[m, n] = \frac{1}{N} \sum_{t=0}^{N-m-1} x_c[t] \cdot x_c[t+m] \cdot x_c[t+n] \quad (13)$$

avec $m \leq N - 1, n \leq N - 1$ et $m \leq n$.

Le calcul des autres domaines du plan bicorrélateur s'obtient par les symétries de stationnarité données dans [6]. La bicorrélation d'un processus 1D donne une image.

3.1.2.2. méthodologie

Nous souhaitons effectuer une analyse statistique des textures à l'ordre 3. On fait l'hypothèse de séparabilité des processus ligne et colonne. Dans ce cas, l'image est constituée de deux ensembles de processus 1D.

En plus du problème de lisibilité, l'estimation d'attributs d'ordre supérieur nécessite un nombre d'échantillons suffisant si l'on veut garder une variance d'estimation acceptable. En faisant l'hypothèse de séparabilité et celle de stationnarité locale, nécessaires dans notre étude, nous avons choisi de moyenniser les estimations de la bicorrélation sur les lignes et sur les colonnes et vice versa. Une sous-image nous donnera donc deux images bicorrélateures, une pour les lignes et une pour les colonnes.

Cette remarque s'appliquera aussi pour l'utilisation du Bispectre et du Bicospectre.

3.1.2.3. résultats sur textures

Nous présentons (figures 7 et 8) les résultats des bicorrélations moyennées sur les lignes des images pour la base test de textures de Brodatz. Les bicorrélations sont estimées sur 64 points, puis sont moyennées 64 fois sur les images 64×64 . Nous estimons 16 points dans le plan bicorrélateur. Nous utilisons l'estimateur biaisé. Les images sont prises au hasard sur les 56 sous-images de la base de test et le numéro associé au nom de la texture représente le numéro de la sous-image sélectionnée.

3.1.3. estimateur du bispectre

Nous avons choisi un estimateur non-paramétrique du bispectre [16]. L'estimateur du bispectre consiste en une Transformée de Fourier 2D de la bicorrélation. Nous estimons donc le bispectre à partir de l'estimateur de la bicorrélation.

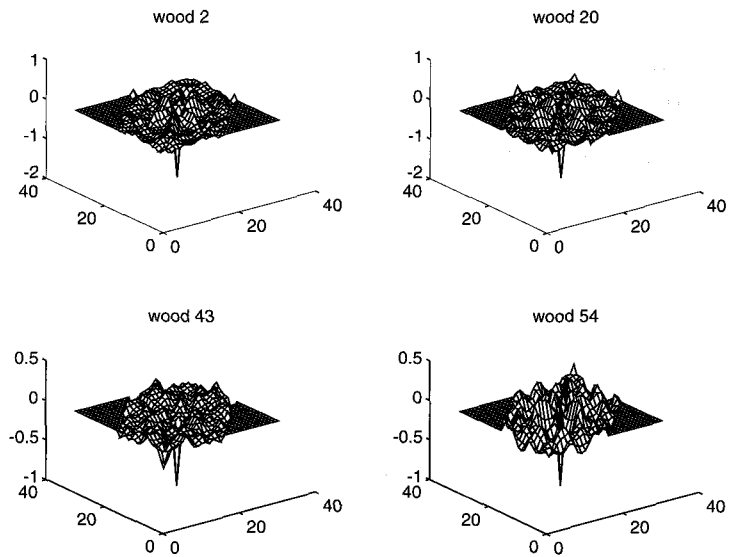


Figure 7. – Estimateur de la bicorrélation sur les lignes de l'image de bois.

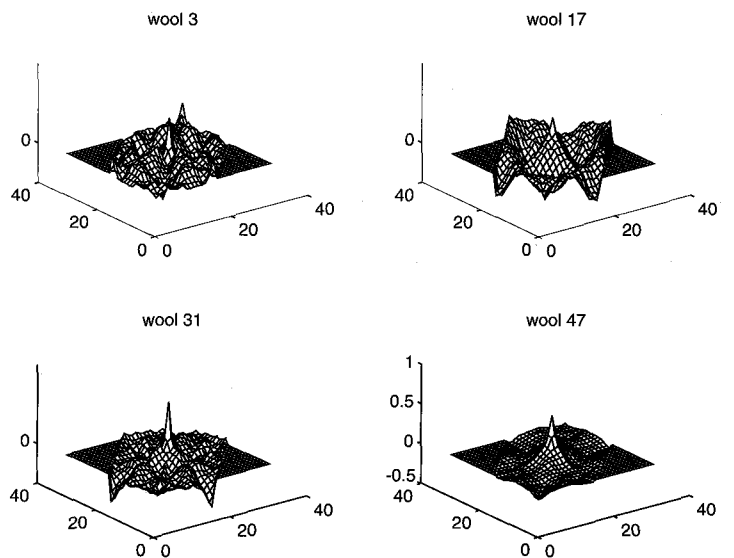


Figure 8. – Estimateur de la bicorrélation sur les lignes de l'image de laine.

3.1.3.1. résultats sur textures

Nous présentons (figures 9 et 10) les résultats des bispectres obtenus à partir des bicorrélations moyennées.

3.2. bicospectre

Le Bicospectre est un outil récemment introduit [16], visant à visualiser les propriétés à l'ordre 3 d'un signal par une représentation temps/fréquence. Cet outil est très efficace pour la détection d'une non-stationnarité du type transition signal gaussien - signal non gaussien. Il paraît donc intéressant de tester cet outil sur les textures, bien représentées à l'ordre 3.

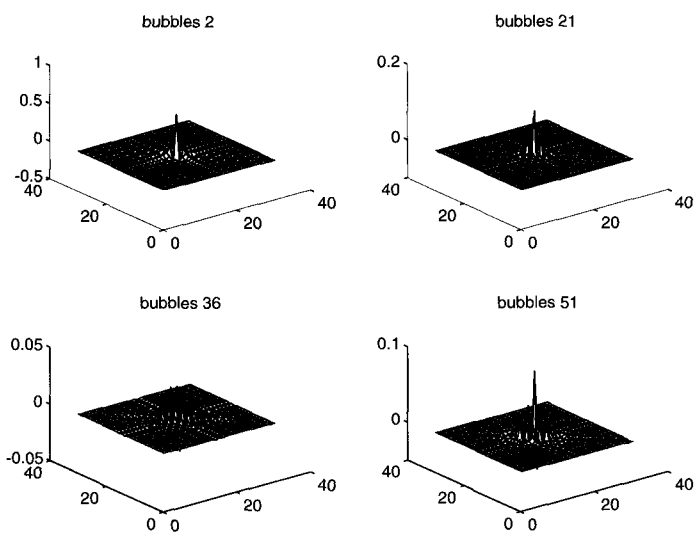


Figure 9. – Estimateur du bispectre sur les lignes de l'image de bulles.

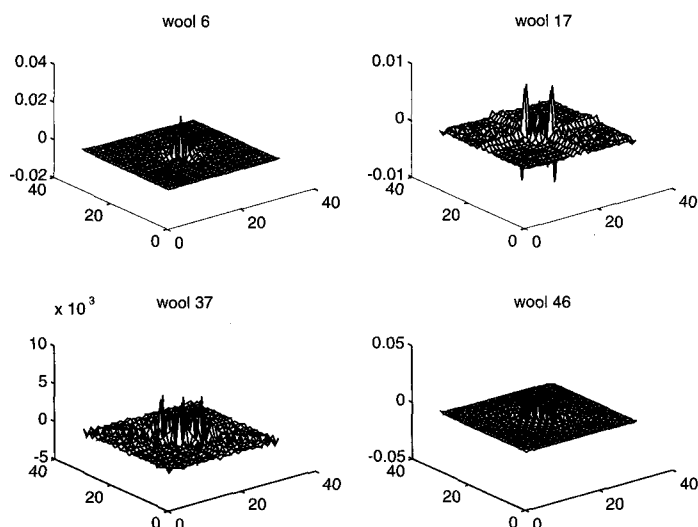


Figure 10. – Estimateur du bispectre sur les lignes de l'image de laine.

3.2.1. définition

Le Bicospectre ou BET est défini par :

$$\beta_{x_g}(t, f) = \frac{1}{2T} \int_{\mathbb{R}^2} x_g(u-t) \cdot x_g(u+\frac{\tau}{2}) \cdot x_g^*(u-\frac{\tau}{2}) \cdot e^{j2\pi f\tau} d\tau du \quad (14)$$

ou x_g représente le signal \times fenêtré par g , de taille $2T$.

On peut voir le BET comme l'intercorrélation déterministe entre le signal lui-même et sa transformée de Wigner-Ville classique. La définition du BET lui confère donc des propriétés intéressantes permettant de le situer par rapport aux autres outils temps/fréquence ou du type corrélation d'ordre élevé déjà existant [1]. Parmi ces propriétés, on peut citer :

- le BET est une représentation temps/fréquence destinée à analyser, pour un processus non gaussien centré, les propriétés statistiques contenues dans les cumulants d'ordre trois

- le BET est relié par un équation asymptotique au bispectre par :

$$\lim_{T \rightarrow +\infty} E \left[\int_{\mathbb{R}} \beta_{x_g}(t, f_1 + \frac{f_2}{2}) \cdot e^{+2\pi j f_2 t} \cdot dt \right] = \gamma_3^{\circ}(f_1, f_2) \quad (15)$$

- si l'on considère la transformation de Wigner-Ville d'un processus fenêtré x_g , soit W_{x_g} , on a alors immédiatement à partir de la définition du BET :

$$\beta_{x_g}(t, f) = \frac{1}{2T} (W_{x_g} @ x_g^-)(t, f) \quad (16)$$

où @ est l'opérateur de convolution et x_g^- représente le signal x_g retourné.

Cette dernière propriété introduit directement l'implantation du BET sous sa forme discrète, donc comme pour la Transformée de Wigner Ville, l'implantation se fera à partir de Transformée de Fourier Discrète [17]. Il est donc possible de trouver un algorithme rapide pour le BET, à partir de la Transformée de Fourier Rapide.

Pour la démonstration des propriétés précédemment citées, on se référera à [7].

3.2.2. estimateur

$$\hat{\beta}_{x_r}[n, \nu] = \frac{2}{2M+1} \sum_{(k,m)} x_r[k-n] \cdot x_r[k+m] \cdot x_r[k-m] e^{-j4\pi\nu m} \quad (17)$$

3.2.3. mise en œuvre - Signal Analytique

Toutes les implémentations des représentations temps/fréquence contiennent des termes d'interférences ayant des origines diverses. L'utilisation du signal analytique $z(t)$ permet de supprimer les interférences entre les fréquences positives et les fréquences négatives.

3.2.4. résultats sur textures

Nous présentons (figures 11 et 12) le résultat du bicorspectre sur les différentes textures de Brodatz. Le bicorspectre est ici utilisé dans un cadre stationnaire. Il s'agit, comme pour la bicorrélation, des images de BET moyennés sur les lignes pour des images 64×64 .

3.3. choix d'une représentation : la bicorrélation

Les résultats montrent que les images obtenues par les différents outils ont des formes répétitives pour différentes sous-images d'une même texture. En revanche, les formes sont très différentes pour des textures distinctes. Nous remarquons aussi qu'il existe une forte redondance entre les différentes représentations, en particulier des relations de passage de l'une à l'autre. Pour ceci, nous n'avons sélectionné qu'une seule représentation pour la classification. En effet, la combinaison des différents outils apporte très peu pour la discrimination [5]. Nous ne conservons

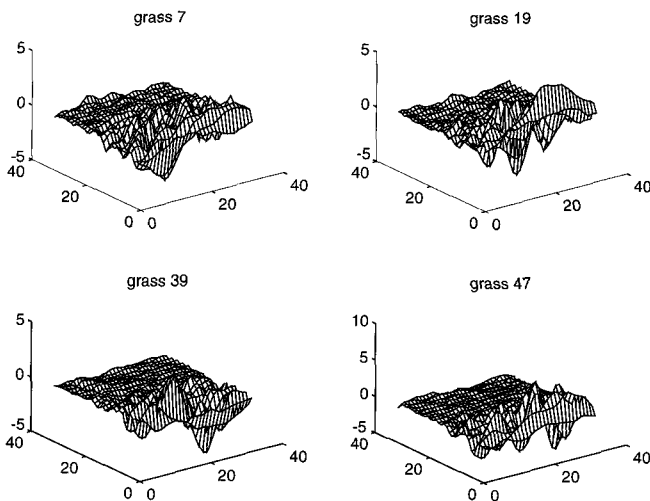


Figure 11. – Estimateur du bicorspectre sur les lignes de l'image d'herbe.

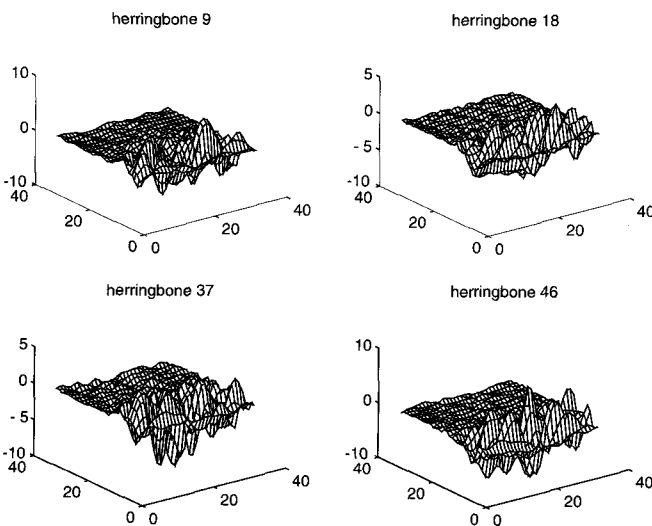


Figure 12. – Estimateur du bicorspectre sur les lignes de l'image de tissage.

donc que la bicorrélation pour la classification, qui se trouve être la plus efficace des trois représentations. Nous pourrions utiliser cet outil, soit directement pour la classification, soit en extrayant des paramètres sur l'image de bicorrélation.

4. classification de textures : apports des corrélations spatiales d'ordre trois

Nous souhaitons de plus trouver un compromis performances-complexité pour la classification. A partir de l'ensemble des at-

tributs permettant de caractériser les textures, l'étape de classification doit permettre de définir un vecteur de paramètres différenciant au mieux une texture dans un ensemble. Nous souhaitons voir en particulier si les outils fondés sur les corrélations d'ordre trois, apportent une information pertinente et améliorent les performances des outils équivalents se limitant à l'ordre deux.

4.1. introduction

La classification des textures entre dans le cadre de la reconnaissance des formes. Le terme classification désigne, pour cette étude, l'action de ranger dans une classe, ici une texture. Nous souhaitons effectuer une classification supervisée. La méthodologie se décompose alors en deux étapes :

1. une étape d'apprentissage avec un ensemble test pour lequel les classes sont connues *a priori*. Cette étape vise à définir, soit des modèles « étalons » pour chaque classe, soit à cerner les limites des classes de décision dans un ensemble de paramètres.
2. une étape de test sur un ensemble inconnu pour évaluer la qualité de la reconnaissance.

La classification se fait à partir d'un vecteur de paramètres extraits des différentes représentations à l'ordre 2 et 3, plus le Kurtosis. Il reste à définir des paramètres à partir des différentes représentations. La définition d'un attribut est difficile et peut sembler arbitraire. Pour réduire l'arbitraire, nous aurions pu appliquer une analyse en composantes principales sur un ensemble exhaustif de ces paramètres. Nous avons sélectionné des ensembles représentatifs de ces attributs pour conserver des vecteurs de codage de taille limitée comprenant des paramètres de complexité limitée.

4.2. choix d'un vecteur de codage

4.2.1. catalogue des paramètres

Les paramètres du vecteur utilisé pour la classification sont :

- premièrement, la moyenne et la variance qui sont deux paramètres fondamentaux pour les textures
- deuxièmement, quelques retards de l'autocorrélation pour compléter les paramètres jusqu'à l'ordre deux

Nous allons ensuite ajouter des paramètres provenant des outils fondés sur les corrélations d'ordre élevé.

- troisièmement, les cumulants d'ordre 3 et 4.
- des paramètres extraits de la bicorrélation sur les textures, par exemple un temps de bicorrélation sur un axe privilégié du plan bicorrélateur. Ces temps sont estimés par un calcul de pente à l'origine.

Nous avons choisi de conserver le temps de bicorrélation sur un axe privilégié du plan bicorrélateur, $m = n$. Il s'agit bien sûr d'un choix arbitraire et l'on pourrait définir un grand nombre de valeurs significatives à partir de la bicorrélation.

4.2.2. choix d'un classifieur

Il existe de nombreux classifieurs ayant chacun leurs avantages et inconvénients.

- arbre de décision binaire : il s'agit d'une méthode de discrimination bayésienne utilisant comme critère la distance de Kolmogorov-Smirnov [10]
- méthode des k plus proches voisins [2]
- réseau de neurones [8]

Nous avons choisi de travailler avec un réseau de neurones. L'avantage est de pouvoir prendre en compte les connaissances *a priori* sur les exemples d'apprentissage. Il sera capable de s'adapter, c'est-à-dire de généraliser aux exemples non appris, dans le cadre de l'étude. Les inconvénients sont que l'ajout d'une nouvelle classe nécessitera le redimensionnement du réseau et que l'apprentissage est long.

4.3. résultats de classification

4.3.1. méthodologie

Nous désirons une classification sûre. Pour cette raison, nous dirons qu'il y a non-classification si aucune des valeurs des neurones de sorties ne dépasse un certain seuil. Nous avons dans ce cas trois résultats possibles :

- classification correcte : le vecteur d'apprentissage a été correctement étiqueté et le neurone de sortie vainqueur a une valeur supérieure au seuil fixé.
- mauvaise classification : le vecteur d'apprentissage a été rangé dans une mauvaise classe et le neurone de sortie vainqueur a une valeur supérieure au seuil fixé.
- non-classification : aucun des neurones de sortie vainqueur n'a une valeur supérieure au seuil fixé.

Nous donnons les résultats pour trois tailles de sous-images : 64×64 , 32×32 et 16×16 . Nous avons fixé un seuil qui donnait une probabilité d'appartenance de 0.7. Puisque le nombre de sous-images tests est faible, nous estimons le taux de reconnaissance par validation croisée. Si l'on dispose d'un nombre suffisant de sous-images, nous en gardons une partie comme ensemble test, classiquement 10%.

Nous avons testé pour différents ensembles de paramètres :

- Cooccurrences : les tests sur les cooccurrences sont réalisés avec les quatre paramètres proposés par Haralick [13], qui sont le contraste, l'entropie, la corrélation et le moment angulaire du deuxième ordre pour deux déplacements unitaires \vec{i} et \vec{j}
- Outils ordre 2 : il s'agit d'un vecteur comprenant la moyenne, la variance et l'autocorrélation ligne et colonne pour trois retards
- Outils ordre 3 : il s'agit du même vecteur que l'ordre deux auquel on ajoute le temps de bicorrélation estimé à l'origine sur l'axe principal ($m = n$). Le temps de bicorrélation est obtenu en mesurant la pente à l'origine par une régression linéaire sur les trois premiers points de l'axe principal dans le plan bicorrélateur. Les tests sur l'ensemble des outils sont réalisés dans les deux directions privilégiées ligne et colonne. Nous comparons les performances pour les mêmes tailles d'images.

4.3.2. résultats sur les sous-images 64×64

Nous possédons dans ce cas 56 sous-images, sans recouvrement, par classe ce qui représente donc une base de 504 sous-images de test pour évaluer les performances de classification. Nous effectuons donc pour obtenir des résultats significatifs une validation croisée ('leave one out') c'est-à-dire que chaque sous image est utilisée une fois pour tester le réseau. L'apprentissage se fait sur 503 sous-images ($9 \times 56 - 1$) et le test est réalisé sur la sous-image restante.

Outils	Ordre 2	Ordre 3	Cooccurrences (paramètres)
Résultat de bonne classification	96,8%	98,4%	95,4%
Résultat de non-classification	3,0%	1,2%	4,2%
Résultat de mauvaise classification	0.2%	0.2%	0.4%

4.3.3. résultats sur les sous-images 32×32

Nous possédons dans ce cas 240 sous-images, sans recouvrement, par classe ce qui représente donc une base de 2160 sous-images pour tester la classification. Nous effectuons donc pour obtenir des résultats significatifs un apprentissage sur 90% des données, les 10% restant étant utilisées pour tester le réseau. L'apprentissage se fait sur 1944 sous-images et le test est réalisé sur les 216 sous-images non-utilisées pour l'apprentissage. Les images tests sont tirées en sélectionnant aléatoirement 24 sous-images par classe. Nous effectuons 10 tirages différents et donnons la moyenne des résultats.

Outils	Ordre 2	Ordre 3	Cooccurrences (paramètres)
Résultat de bonne classification	90,3%	92,5%	90,5%
Résultat de non-classification	6,2%	4,1%	3,5%
Résultat de mauvaise classification	3.5%	3.4%	6%

4.3.4. résultats sur les sous-images 16×16

Nous possédons dans ce cas 992 sous-images, sans recouvrement, par classe ce qui représente donc une base de 8928 sous-images pour tester la classification. La méthodologie est la même que pour les sous-images 32×32 .

Outils	Ordre 2	Ordre 3	Cooccurrences (paramètres)
Résultat de bonne classification	83,8%	81,2%	86,8%
Résultat de non-classification	10,3%	15,4%	5,8%
Résultat de mauvaise classification	5,9%	3,6%	7,4%

5. conclusion

En résumé, les points importants de cet article concernent la normalité des textures, les résultats de classification et le choix de descripteurs pertinents.

Les textures sont, pour la plupart, non gaussiennes et bien représentées à l'ordre trois. Cette affirmation trouve sa justification grâce à l'utilisation des tests de l'asymétrie (Skewness) et du Kurtosis, qui présentent une très faible probabilité de rejet erroné (2% par exemple pour le test d'asymétrie pour 4096 échantillons avec un seuil de 0.1).

Pour des images suffisamment grandes (64×64 ou 32×32), les outils d'ordre élevé (asymétrie, Kurtosis, bicorrélation) sont pertinents et améliorent des résultats de l'ordre deux seul. Ils présentent de plus un bon compromis performances-complexité.

A la lumière des résultats obtenus, les descripteurs les plus discriminants, en fonction de la taille des sous-images sont les suivants :

1. images 64×64 ou 32×32 : moyenne, variance, autocorrélation lignes+colonnes, asymétrie, temps de bicorrélation et Kurtosis
2. images 16×16 : paramètres extraits des matrices de cooccurrences (le contraste, l'entropie, la corrélation et le moment angulaire du deuxième ordre, par exemple) calculés pour un vecteur ligne et un vecteur colonne.

Une suite naturelle de cette étude serait de tester des attributs extraits d'une version 2D « vraie » de la bicorrélation.

BIBLIOGRAPHIE


- [1] all. Special time/frequency. *Signal Processing*, 36 : 733-750, 1992.
- [2] A. Belaid and Y. Belaid, *Reconnaissance de formes - Méthodes et applications*, Paris InterEdition, 1992.
- [3] A. C. Bovik and M. Clark and W. S. Geisler, Multichannel texture analysis using localized spatial filters, *IEEE Trans. Pattern Anal. Machine Intell.* 12 : 55-73, 1990.
- [4] P. Brodatz. *Texture- A photographic album for artists and designers*. New York, Reinhold, 1968
- [5] C. Coroyer, *Apport des corrélations d'ordre élevé à l'analyse de textures non-gaussiennes*, Thèse de doctorat, Université de Cergy, 1996
- [6] P. Duvaut and T. Doligez and D. Garreau, Non Gaussian Qarma processes, bicorrelation and bispectrum, non parametric and parametric approaches. In *IEEE ATHOS Workshop*, pages "...", 1993.
- [7] P. Duvaut and T. Gouraud, BET, the bicospectral transform : Definition, Properties, Implementation and Applications. Technical Report ETIS/GS/3N/9403, Equipe de Traitement de Images et du Signal - Cergy, 1994.
- [8] J. A. Freeman and D. M. Skapura, *Neural Networks - Algorithms, Applications, and Programming Techniques*, Addison Wesley, 1991.
- [9] A. Gagalowicz, *Vers un modèle de texture*, Thèse d'état, Université Paris 6, 1983.
- [10] G. Gaillat, *Méthodes statistiques de reconnaissance de formes*, Paris, ENSTA, 1983.

- [11] S. Geman and D. Geman, Stochastic Relaxation and the Bayesian Restoration of Images, *IEEE Trans. Pattern Anal. Machine Intell.*, 6 : -, 1984.
- [12] P. Hall, *The Bootstrap and Edgeworth Expansion*, New-York Springer Verlag, 1992.
- [13] R. Haralick and K. Shammugam and I. Dinstein, Textural features for image classification, *IEEE Trans Syst.*, man Cyb., 3 : 610-621, 1973. 1973
- [14] M. G. Kendall and A. Stuart and J. Keith Ord, *Kendall's Advanced Theory of Statistics*, London, Griffin, 1987.
- [15] A. Laine and J. Fan, Texture classification by wavelet packet signatures, *IEE Trans. Pattern Anal. Machine Intell.*, 15 : 1186-1190, 1993
- [16] C. Nikias and J. M. Mendel, Signal Processing with Higher Order Spectra, *IEEE Signal Processing Magazine*, pages 10-37, 1993.
- [17] M. A. Poletti, The development of a discrete transform for the Wigner distribution and ambiguity function, *J. Acoust. Soc M.*, 84 : 238-252, 1988.
- [18] V. Pugachev, *Théorie des probabilités et statistique mathématique*, Moscou Editions Mir, 1982.
- [19] O. Rioul, *Ondelettes régulières : application à la compression d'images fixes*, Thèse d'Université, ENST, 1993. 1993
- [20] H. L. Van Trees, *Detection, Estimation, and Modulation Theory (Part I)*, John Wiley and Sons, 1968
- [21] J. Levy Vehel and J. P. Berroir, Description Multifractale de l'Analyse d'Images, Technical Report INRIA, INRIA - Rocquencourt, 1994.
- [22] L. Wang and D. C. Chen, Texture classification using texture spectrum, *Pattern Recognition*, 23 : 905-910, 1990.

Manuscrit reçu le 12 novembre 1996.

LES AUTEURS

Patrick DUVAUT



Patrick DUVAUT est professeur des universités en poste à l'ENSEA (Ecole Nationale Supérieure de l'Electronique et de ses applications). Il co-dirige avec JP Coqueret le DEA TIS de Cergy-Pontoise. Il co-anime avec Dominique Garreau la collection traitement du Signal des éditions Hermès. Patrick Duvaut est directeur scientifique de la société KURTOSIS Ingénierie. Ses activités de recherche s'articule autour de trois thèmes principaux : 1) les approches bayésiennes par simulation stochastique Monte Carlo - Chaînes de Markov, (Algorithmes de Metropolis et Gibbs pour l'essentiel), appliquées à l'analyse spectrale, à la goniométrie et à l'estimation de fréquences instantanées; 2) les modèles de processus non gaussiens et les tests modulaires de normalité utilisant les polynômes d'Hermite; 3) l'égalisation et le décodage conjoints (pour la radio-mobile) et les fonctions de « haut niveau » (modulations multiporteuses par paquets d'ondelettes, égalisation et synchronisation) dans les modems xDSL.

Christophe COROYER



Christophe COROYER a obtenu son DEA Automatique et Traitement du Signal de l'Université d'Orsay en 1992. Il a soutenu en 1996 sa thèse de Doctorat de l'Université de Cergy-Pontoise. Il est actuellement enseignant chercheur dans le département Traitement du Signal et Télécommunications de l'ESIGETEL à Avon-Fontainebleau. Ses activités de recherche portent sur l'analyse et la compression des images.