

Utilisation des statistiques d'ordre supérieur pour l'analyse d'images texturées

Carlos Avilés-Cruz, Anne Guérin-Dugué

Laboratoire de Traitement d'Images et de Reconnaissance des Formes
LTIRF, INPG, 46 Av. Félix-Viallet, 38031 Grenoble Cedex 1 / guerin@tirf.inpg.fr

RÉSUMÉ

L'utilisation des statistiques d'ordre supérieur (S.O.S) est de plus en plus répandue en traitement du signal. En traitement d'image, l'analyse de textures est un domaine où l'application de telles techniques peut avoir un intérêt. L'objectif de cet article est de mettre en évidence les points forts et les points faibles d'une caractérisation par S.O.S. en la comparant avec une description par des extracteurs classiques avec les matrices de cooccurrences.

ABSTRACT

In signal processing, High Order Statistics (H.O.S) are more and more used for complex applications such as blind sources separation. In image processing, textures analysis is an application domain where it would be interesting to use H.O.S. The objective of this article is to point out the main advantages and drawbacks of a texture characterisation by H.O.S. comparing to a classical characterisation by cooccurrence matrices.

I. Introduction

L'analyse d'images multitexturées est un problème très courant en analyse automatique des images. Les applications recouvrent de très nombreux domaines (images médicales, satellitaires, sismiques, contrôle de qualité, ...). Ce thème de recherche est très ouvert, tant les approches pour décrire les textures peuvent être très diverses. Ici le point de vue que l'on présentera, est de caractériser les textures par attributs statistiques d'ordre supérieur. L'utilisation de ces statistiques est de plus en plus fréquentes en traitement du signal. Leur emploi en traitement d'images ouvre des potentialités intéressantes [6] dont il faut maîtriser le compromis entre l'accroissement de la complexité avec celui des performances [8]. On montrera leurs avantages et leurs inconvénients en les confrontant à une description via des paramètres issus de matrices de cooccurrence [7] réputés pour leur facilité d'emploi. Les expérimentations présentées ici permettent d'appréhender de manière quantitative l'apport d'une description par des moments d'ordre 3 et 4 en précisant les conditions d'utilisation et les performances attendues en reconnaissance automatique. Cette étude est réalisée sur des micro-textures naturelles issues de [3]. On présente dans ce résumé une partie des expérimentations menées dans [1].

Plus précisément, on abordera cette présentation suivant trois aspects (mise en oeuvre, performance en apprentissage supervisé et en apprentissage non-supervisé).

II. Attributs d'ordre 3 et 4 utilisés : Présentation, Configuration, Discrimination

Pour décrire une région texturée, les attributs d'ordre supérieur choisis sont les moments d'ordre 3 et 4. Cette approche s'applique très bien aux microtextures vues comme une distribution aléatoire de niveaux de gris spatialement corrélés. Ces moments également appelés bi-corrélations et tri-corrélations, donnent des caractéristiques plus riches (plus discriminantes ?) que les moments d'ordre 2, car elles estiment des corrélations entre 3 ou 4 pixels dans un voisinage donné autour du pixel courant. Corroyer a montré [5] sur un échantillon de micro-textures issues de [3] que les distributions sont plutôt non-gaussiennes et déjà bien représentées à l'ordre de trois. Cette question est en fait ouverte et les conclusions sont assez dépendantes du pré-traitement d'images utilisé. Pour notre part, nous avons constaté que les bi-corrélations sont moins pertinentes que les tri-corrélations car elles fournissent un ensemble d'attributs situés dans une gamme de valeurs faibles, proches de zéro. Cela est dû à la symétrie observée

des histogrammes de niveau de gris après centrage. Pour une distribution X quelconque centrée, on a :

$$M_3(i, j) = E[X_n X_{n+i} X_{n+j}]$$

$$M_4(i, j, k) = E[X_n X_{n+i} X_{n+j} X_{n+k}]$$

Ces équations générales sont à particulariser pour des textures de granulosité donnée au même titre que l'on adapte le vecteur déplacement ($\vec{\delta} = [\Delta_x, \Delta_y]$) dans la paramétrisation de la matrice de cooccurrence ("COOC $_{\Delta_x, \Delta_y}$ "). Ici, il faudra fixer la plage de variations des pas de décalage (i,j) suivant la granulosité des textures étudiées. A une granulosité fine correspondra une étendue limitée des pas de voisinage. Pour notre étude, nous avons restreint le calcul des corrélations entre le pixel courant, le premier voisin et le deuxième voisin ($0 \leq i$ ou $j \leq 2$). En ayant ici choisi de manière heuristique cette plage de variation en accord avec les 11 micro-textures de la base d'images, le nombre de moments à estimer reste important et croît de manière exponentielle avec l'ordre du moment en considérant une distribution bidimensionnelle (μC^r , avec C le nombre de possibilités de prendre i ou j - $C=24$, pour un voisinage limité aux deux premières couronnes de pixels autour du pixel courant - et $r=3$ ou 4). De par ces considérations pratiques, on restreint l'image à un processus ligne unidimensionnel [1, 2, 5, 8]. Néanmoins, il est fondamental de prendre en compte l'orientation privilégiée de la texture. Cela est réalisé en considérant plusieurs processus lignes d'orientation différente. Classiquement, on prend les orientations $0^\circ, 45^\circ, 90^\circ, 135^\circ$ et avec ces restrictions on obtient 21 moments M_3 et 37 moments M_4 [1].

Une autre difficulté à mesurer est le nombre N de échantillons à prendre en compte pour l'estimation des moments. Ces estimations se faisant à partir d'une fenêtre d'estimation carrée de taille finie ($N=L \times L$), la convergence de l'estimation est liée à cette taille N . Avec une taille de fenêtre de plus en plus importante, l'hypothèse d'homogénéité des textures dans la fenêtre (stationnarité de la distribution) est moins valide. Nous avons analysé sur les micro-textures, l'évolution de la convergence de l'estimation $\tilde{M}_3(i, j)$, $\tilde{M}_4(i, j, k)$ en fonction de L en la comparant à l'évolution du paramètre de contraste issue de la matrice de cooccurrence ("COOC $_{1,0}$ ") réputée plus robuste à l'estimation sur des fenêtres de petite taille. La figure 1 illustre cette évolution de $M_4(0,1,2)$ et du paramètre de contraste de COOC $_{1,0}$ à partir la texture (D24, cuir) de [2]. Cette évolution vers la stabilité de la valeur estimée est comparable entre les deux paramètres. Néanmoins, pour les paramètres M_4 , une taille de 32×32 est conseillée : elle garantit en moyenne, une convergence à au plus 15% d'erreur par rapport à la valeur finale. Pour faire la discrimination entre plusieurs textures, les gammes de valeur étant assez proches, il faut assurer une bonne convergence de l'estimation. Au niveau des matrices

de cooccurrence, cela est moins critique car il est bien connu que la plage des valeurs des paramètres issues de plusieurs textures peut être beaucoup plus large.




Figure 1 . Estimation de $M_4(0,1,2)$ (a) et du paramètre de contraste de COOC $_{1,0}$ (b) en fonction de la taille de la fenêtre d'estimation ($N= L \times L$).

Le tableau suivant illustre les performances en reconnaissance par analyse discriminante quadratique (classifieur gaussien, CG), en fonction de la taille L de la fenêtre d'estimation de N pixels ($N= L \times L$). Le taux d'erreur est évalué par la méthode d'échantillon-test moyennée sur 20 partitions. Les attributs M_4 et M_3 sont beaucoup plus sensibles à la diminution de la taille de la fenêtre. Cela confirme, du point de vue de la classificabilité de la base de données, l'importance d'estimer ces attributs M_3, M_4 sur des fenêtres de taille plus grande (supérieure à 24×24). On remarque la moins bonne efficacité des attributs M_3 (valeurs moins discriminantes entre les textures).

Erreur % Attributs	8	12	16	20	22	24	28	32
COOC	13,9	8,3	6,9	4,8	3,0	2,6	1,9	1,42
M ₃	54,5	45,5	32,7	12,4	10,3	8,4	7,2	3,8
M ₄	48,0	32,1	22,7	11,3	4,1	2,7	0,7	0,2

Table 1. Taux d'erreur (%) sur une base de 11 textures. COOC est la base d'attributs à 16 dimensions, des paramètres de cooccurrence ($\|\vec{\delta}\|=1$ et 2, 4 orientations). M₄ est la base d'attributs des tri-corrélations à 37 composantes, M₃ est celle des bi-corrélations à 21 composantes.

II. Expérimentation en apprentissage supervisé et non supervisé

Les tests réalisés sur les bases de données M₄ et M₃ ont mis en évidence l'importance de la redondance d'information entre les différents moments à une orientation donnée et également entre les orientations si les textures sont isotropes. Une analyse plus fine des bases de données a montré que cette redondance s'explique principalement par des relations de liaisons linéaires entre les attributs [1]. Ainsi, très simplement par Analyses en Composantes Principales, on peut réduire fortement la dimensionnalité des bases tout en maintenant un score de reconnaissance élevé. Les scores présentés à la figure 2 résument les performances en reconnaissance sous trois conditions d'expérimentation.




Figure 2. Performance comparée de M₃, M₄ et COOC sur une base de 4 textures en apprentissage supervisé (CG) et non-supervisé (SEM) sous trois conditions d'expérimentation (R/R, R/R+F, R+F/R+F)

La première notée ("Région/Région") consiste à faire les apprentissages et les tests sur des textures isolées. La seconde condition ("R/R+Frontière") consiste à faire les apprentissages sur les textures isolées et les tests à partir d'échantillons provenant d'une image

multitexturée incluant des zones de frontière. La troisième condition ("R+F/R+F") est plus difficile avec les apprentissages et les tests à partir de l'image multitexturée. Deux algorithmes de classement ont été utilisés, le classifieur gaussien (apprentissage supervisé) et l'algorithme SEM (version stochastique de "Expectation Maximisation") [4] sous l'hypothèse d'un mélange de fonctions gaussiennes (apprentissage non-supervisé). Quatre textures différentes ont été utilisées pour ces expérimentations. L'image multitexturée est présentée à la figure 3.




Figure 3. Image multitexturée utilisée pour les expérimentations

Sous la condition "R/R", on retrouve l'avantage à la discrimination avec M₄. Sous la condition "R/R+F", quelque soit le protocole d'apprentissage (CG / SEM), les performances entre les trois types de descripteur s'équilibrent : les attributs COOC rattrapent leur retard en performance en limitant les erreurs sur les zones frontière entre 2 textures. De plus, en apprentissage uniquement sur les régions, les bases de données ont une structuration en classes très forte : il n'y a pas de problème de convergence pour l'algorithme SEM : les 4 modes de la distribution sont parfaitement détectés. Dans la troisième condition, on voit très clairement les limitations des descripteurs statistiques M₃, M₄. Les

résultats en apprentissage supervisé sont tout à fait catastrophiques : cela est dû au positionnement complètement imprévisible des échantillons provenant de fenêtres d'estimation situées entre deux textures qui, après étiquetage supervisé à la majorité des pixels de la fenêtre, crée des classes non connexes. En apprentissage non-supervisé, sous cette condition, la convergence de SEM est plus difficile, les modes principaux de la distribution sont moins marqués et les performances moyennes obtenues par M_4 sont donc légèrement moins bonnes que celles obtenues par les cooccurrences tout en restant comparables. Ici, le point caractéristique est l'importante variation des performances obtenues sur 20 réalisations (les barres du schéma représentent le taux maximal et minimal), cela est dû à la moins bonne structuration en classes des bases de données.

III. Conclusions

Les expériences relatées montrent l'apport discriminatoire important d'une caractérisation des textures par statistiques d'ordre supérieur dont un avantage est le lien physique fort entre la paramétrisation des moments (choix du voisinage, des orientations) et le type de texture à décrire. Les attributs sont génériques ; ils se spécialisent suivant les aspects des textures (granulosité, orientation, ...). Les bases de données ainsi réalisées ont une excellente classificabilité qui s'exploite avec les mêmes performances en apprentissage supervisé ou non supervisé, sous des modèles a priori gaussiens des distributions. En contre partie, il faut respecter les conditions d'application sur la taille de la fenêtre d'estimation qui est à l'extrême limite de l'acceptable dans les applications de segmentation automatique quand il n'est pas possible de modéliser à priori la distribution sur un échantillon d'observables ne comportant que des descripteurs sur des régions sans ambiguïté de frontières. Dans [2], nous avons montré

comment par une architecture de fusion de données en apprentissage supervisé, il est possible de tirer partie d'une bonne complémentarité entre les descripteurs M_4 et COOC pour obtenir un taux de reconnaissance en stratégie "R/R+F" bien supérieur (+ 12 %) au taux de chaque descripteur pris isolément. Il reste maintenant à poursuivre cette approche en utilisant au mieux la complémentarité des descripteurs dans des applications de segmentation automatique en apprentissage non-supervisé.

Références

- [1] Aviles-Cruz C., "Analyse de textures par statistiques d'ordre supérieur : caractérisation et performances", Thèse de doctorat INPG, Option Signal, Image, Parole, Grenoble, janvier 1997.
- [2] Aviles-Cruz C., Guérin-Dugué A., "Texture discrimination enhancement by fusion with second and fourth order statistics", Eusipco'96, Trieste, Italy, septembre 1996
- [3] Brodatz P., "Textures : A photographic Album for Artists and Designers", Dove Publications, june 1966.
- [4] Celeux G., Diebolt J., "L'algorithme SEM : Un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités", Revue de Statistiques Appliquées, vol 34, n° 2, pp 35-52, 1986
- [5] Coroyer C., "Apport des corrélations d'ordre élevé à l'analyse de textures non-gaussiennes", Thèse de doctorat, Université de Cergy Pontoise, 1996.
- [6] Gagalowicz A., "Vers un modèle de textures", Thèse d'Etat, Université de Pierre et Marie Curie, Paris VI, 1983.
- [7] Haralick R. M. et al, "Textures features for image classification", IEEE Trans on SMC, vol 3, n° 1, pp.610-621, 1973.
- [8] Ramponi G., Carrato S., "Modified fourth-order moments in texture recognition, workshop on HOS, pp. 139-142, Chamrousse, France, juillet 1991.