

Caractérisation et Classification de Textures par mesures de Coefficients de Corrélation Multiple

André Smolarz

Laboratoire de Modélisation et Sûreté des Systèmes
 Université de Technologie de Troyes
 12, rue Marie Curie BP 2060
 10010 Troyes Cedex
 andre.smolarz@univ-troyes.fr

RÉSUMÉ

On s'intéresse ici au problème de la caractérisation de la texture dans le but de discriminer différentes classes d'images texturées. L'approche présentée repose sur une nouvelle description et une nouvelle mesure des caractéristiques locales de la texture. Cette description fait appel, plus précisément, à un calcul de coefficient de corrélation multiple entre deux blocs de pixels. De nombreuses études comparatives ont montré que les paramètres de co-occurrence étaient, dans la majorité des cas, les plus performants pour la caractérisation de la texture. Pour cette raison, nous avons comparé nos résultats de classification avec ceux obtenus à l'aide des paramètres de co-occurrence, sur la base des taux de bonne classification sur un ensemble d'apprentissage et de test.

1 Introduction

Comme cela est indiqué dans le résumé ci-dessus, nous nous intéressons ici au problème de la caractérisation de la texture. Depuis les travaux de Haralick & Al. [11] de nombreux auteurs ont abordé cet aspect [1, 4, 6, 7, 8, 9, 10, 12, 16]. La plupart des travaux présentés dans la littérature consistent à étudier les caractéristiques locales de la texture en modélisant et/ou en décrivant les interactions entre un pixel et un ou plusieurs pixels voisins de celui-ci. L'approche que nous proposons consiste à prendre en compte les liens entre un bloc de pixels et un autre bloc, voisin du premier. Les notions de bloc ainsi que celle de bloc voisin seront définies uniquement par des critères structurels et spatiaux.

Dans le cadre de la discrimination de classes de textures, de nombreuses études comparatives de performances ont été effectuées. Ces études ont montré que les meilleurs taux de bonne classification étaient obtenus dans la majorité des cas avec les paramètres de co-occurrence. Pour cette raison, nous avons comparé nos résultats de classification à ceux obtenus avec les paramètres de co-occurrence qui sont présentés dans la littérature comme les plus pertinents [13, 14, 15].

Un point important de notre approche est qu'elle ne nécessite pas de réduction préalable du nombre de niveaux de gris. Cette étape, qui consiste souvent en une égalisation d'histogramme, n'induit pas, en général, une amélioration des performances. C'est précisément ce que nous avons observé avec les résultats qui sont présentés ici.

ABSTRACT

We address the problem of texture characterization in order to classify different classes of textured images. Our approach consists in a new description and measure of the local characteristics of the texture. More precisely, this method is based on the multiple correlation coefficient between two blocks of pixels. Many comparative studies have shown that co-occurrence parameters perform better than others for texture classification. Consequently, we have compared our classification results with those obtained with co-occurrence parameters, on the basis of good classification rates estimated using a cross validation procedure.

Un autre point à souligner est que le critère utilisé ne nécessite aucune hypothèse de modèle probabiliste pour la texture.

2 Approche proposée

2.1 Principe de la méthode

Nous allons considérer une image de texture comme un ensemble S de N sites répartis sur une grille rectangulaire. A chaque site s est attachée une variable aléatoire discrète X_s dont les réalisations seront des valeurs de niveaux de gris allant de 0 à $G-1$. En chaque site s on définit également un vecteur aléatoire $\mathbf{X}_s = [X_s \ X_{s_1} \ X_{s_2} \ \dots \ X_{s_p}]^t$.

La première composante est la variable attachée au site courant s et les p suivantes sont les variables attachées aux sites voisins de s qui auront été choisis. Nous admettrons que chaque texture est homogène à l'ordre 2 :

$$E[X_s] = m, V[X_s] = \sigma^2, Cov[X_s, X_{s+\delta}] = c(\vec{\delta}) \quad \forall s \in S \quad (1)$$

Considérons maintenant la partition du vecteur de voisinage \mathbf{X}_s , en deux blocs de dimensions q_1 et q_2 ,

$$\mathbf{X}_s = \begin{bmatrix} \mathbf{X}_s^{(1)} \\ \mathbf{X}_s^{(2)} \end{bmatrix} \quad (2)$$

Nous pouvons alors définir la matrice \mathbf{B} des coefficients de régression de $\mathbf{X}_s^{(1)}$ sur $\mathbf{X}_s^{(2)}$,

$$\mathbf{B} = \Sigma_{12} \Sigma_{22}^{-1} \quad (3)$$

avec : $\Sigma_{12} = E[(\mathbf{X}_s^{(1)} - \mathbf{m}_{q_1})(\mathbf{X}_s^{(2)} - \mathbf{m}_{q_2})^t]$ et
 $\Sigma_{22} = E[(\mathbf{X}_s^{(2)} - \mathbf{m}_{q_2})(\mathbf{X}_s^{(2)} - \mathbf{m}_{q_2})^t]$

\mathbf{m}_q est le vecteur à q composantes, toutes égales à m .

Soit \mathbf{b}_i^t la i ème ligne de \mathbf{B} , on peut montrer [2] que :

$$\text{corr}(X_{s_i}^{(1)}, \mathbf{b}_i^t \mathbf{X}_s^{(2)}) \geq \text{corr}(X_{s_i}^{(1)}, \mathbf{a}^t \mathbf{X}_s^{(2)}) \quad \forall \mathbf{a} \quad (4)$$

la valeur maximale de $\text{corr}(X_{s_i}^{(1)}, \mathbf{a}^t \mathbf{X}_s^{(2)})$ est appelée coefficient de corrélation multiple (CCM) entre la i ème composante de $\mathbf{X}_s^{(1)}$ et $\mathbf{X}_s^{(2)}$.

Il est important de noter que ce résultat est indépendant de la loi de $\mathbf{X}_s = [X_{s_1} \ X_{s_2} \ \dots \ X_{s_p}]^t$.

Si l'on dispose de K classes de texture représentées chacune par un ensemble d'images, il est possible d'estimer la matrice \mathbf{B} de chaque classe lors d'une phase d'apprentissage. On notera \mathbf{B}_k la matrice de régression estimée sur des échantillons de la classe k . En accord avec la relation (4), il est clair que pour un vecteur \mathbf{X}_s^k extrait d'une texture de la classe k , on doit avoir $\forall i = 1, q_1$ et $l \neq k$:

$$\text{corr}(X_{s_i}^{k(1)}, \mathbf{b}_{k_i}^t \mathbf{X}_s^{k(2)}) \geq \text{corr}(X_{s_i}^{k(1)}, \mathbf{b}_{l_i}^t \mathbf{X}_s^{k(2)}) \quad (5)$$

2.2 Règle de décision

Pour la discrimination entre les différentes classes, nous allons procéder de la manière suivante :

Soit \mathbf{I} une image de texture à classer dans un ensemble comportant K classes de textures.

-pour $k = 1$ à K , on calcule sur \mathbf{I} les q_1 coefficients de corrélation entre chaque composante de $\mathbf{X}_s^{(1)}$ et de $\mathbf{B}_k \mathbf{X}_s^{(2)}$.

-La règle de décision consiste alors à affecter l'image \mathbf{I} à la classe k^* pour laquelle on a obtenu la majorité de coefficients de corrélation maximums (relation (5))

3 Résultats

Nous présentons des essais de discrimination réalisés sur deux ensembles de textures :

Un ensemble composé de 8 textures de Brodatz [3] de la banque d'images du GdR ("bois", "canavas", "eau", "herbe", "laine", "lierre", "sable", et "bulles").

Un autre ensemble composé de 5 textures markoviennes synthétisées selon un modèle auto-binomial [5, 17], (figure 1). Toutes les images sont définies initialement sur 256 niveaux de gris, celles du premier ensemble sont de taille 256x256 pixels et celles du second ensemble de taille 512x512 pixels.

Pour chaque classe, la phase d'apprentissage est effectuée sur un nombre N_{app} de fenêtres, de tailles $W \times W$. Les N_{test} fenêtres restantes constituent l'ensemble test.

Il a été procédé à plusieurs essais, pour différentes valeurs de N_{app} et de W . Pour chaque essai, une matrice de confusion a été établie mais, afin de simplifier la présentation, un seul exemple est présenté sous forme d'une matrice de confusion (figure 2). Pour l'ensemble des autres résultats, seuls les taux moyens de bonne classification de chaque essai sont présentés (tableaux 1 et 2).

3.1 Classification avec le CCM

Nous avons choisi pour $\mathbf{X}_s^{(1)}$ le vecteur correspondant au site s et à ses 8 plus proches voisins tandis que $\mathbf{X}_s^{(2)}$ correspond aux 16 sites entourant le bloc 3x3 correspondant à $\mathbf{X}_s^{(1)}$ ($q_1 = 9$ et $q_2 = 16$).

Pour chaque classe, sur chaque fenêtre j ($j=1, N_{app}$), on estime la matrice \mathbf{B}_j des coefficients de régression. La matrice de référence de la classe est la matrice moyenne sur l'ensemble des N_{app} fenêtres.

Ensuite on applique la procédure d'affectation décrite dans la section 2.2, à l'ensemble des fenêtres définies sur chaque image à classer. Les taux moyens T de bonne classification sont donnés dans les tableaux 1 et 2, en distinguant ceux obtenus sur les ensembles d'apprentissage (T_{app}) de ceux obtenus sur les ensembles tests (T_{test}).

3.2 Classification avec les paramètres de co-occurrence

Pour la classification avec les paramètres de co-occurrence, nous avons choisi les 6 paramètres $f_1, f_2, f_3, f_5, f_9, f_{12}$ définis dans [11] pour une distance de 1 pixel et les images ont au préalable été égalisées sur $G=8$ niveaux de gris.

Ces paramètres forment un vecteur de représentation de dimension 6. La phase d'apprentissage va consister à estimer un prototype pour chaque classe (le vecteur moyenne et la matrice de covariance (6x6) estimés sur N_{app} fenêtres de tailles $W \times W$).

Ensuite, pour l'ensemble des fenêtres définies sur chaque image à classer, on décide d'affecter une fenêtre inconnue à la classe dont elle est la plus proche au sens de la distance de Mahalanobis. Les résultats sont donnés dans les tableaux 1 et 2 afin de les comparer à ceux obtenus avec les CCM.

4 Discussion et conclusion

L'examen des résultats synthétiques présentés dans les tableaux 1 et 2 permet de constater que le coefficient de corrélation multiple permet une meilleure discrimination de la texture que les paramètres de co-occurrence. L'écart est très net pour les textures naturelles alors qu'il est très peu significatif pour les textures markoviennes. Un examen plus détaillé des matrices de confusion permet de remarquer que les textures qui sont le plus souvent mal reconnues avec le CCM, quels que soient les essais, sont les textures "herbe", "sable" et "bulles". Avec les paramètres de co-occurrence, la classe "bulles" est très bien reconnue, tandis que, là aussi, les classes "herbe" et "sable" sont très mal reconnues. On peut remarquer également que les meilleurs résultats sont obtenus sur les images brutes. Des essais identiques à ceux du

tableau 1 avec $G=16$ et $G=32$ ont permis d'observer une amélioration des résultats de classification pour les deux méthodes. Toutefois il semble difficile d'aller au delà de $G=32$ avec les matrices de co-occurrence alors que le problème ne se pose pas pour le calcul des CCM.

Parmi les perspectives envisageables, on peut citer la recherche de structures en blocs $\mathbf{X}_s^{(1)}$ et $\mathbf{X}_s^{(2)}$, adaptées à chaque type de texture et l'utilisation du CCM pour la segmentation d'images texturées.

Dans cette étude, nous avons choisi la même structure pour toutes les classes. Hors, pour des textures présentant des structures géométriques fortement marquées ou des structures périodiques à différentes échelles, on peut penser qu'un choix quelconque des blocs n'offre pas la meilleure représentation.

Concernant la segmentation, deux aspects importants motivent l'utilisation du CCM :

i) Tout d'abord, le fait de ne pas avoir à réduire le nombre de niveaux de gris permet d'éviter un traitement local qui augmente le temps de calcul sans nécessairement améliorer la qualité de la segmentation.

ii) D'autre part, les performances du CCM en classification sur des fenêtres de tailles relativement faibles, permettent d'envisager son utilisation en segmentation, ce que nous étudions actuellement.

En conclusion, nous avons proposé une nouvelle approche reposant sur le calcul du CCM pour l'extraction de caractéristiques pertinentes de texture. Le CCM permet, en termes de régression et indépendamment du modèle, d'évaluer la relation entre deux groupes de pixels. La variance des résidus pourrait également être utilisée, mais nous avons constaté sur nos essais que les meilleurs taux de bonne classification étaient obtenus avec le CCM.

Nos essais, réalisés sur un nombre important de classes, montrent que le CCM présente un pouvoir discriminant très intéressant, comparativement aux paramètres de co-occurrence.

5 Références

- [1] Ade F., "Characterization of textures by eigenfilters", Signal Processing 5, pp 451-457, 1983.
- [2] Anderson T.W., "An Introduction to Multivariate Statistical Analysis", Wiley, second edition, 1971.
- [3] Brodatz, "Textures a photographic album for artists and designers", Dover N.York 1965.
- [4] Chu A., C.M. Sehgal & J.F. Greenleaf, "Use of gray value distribution of run lengths for texture analysis", Pattern recognition letters, 11, pp 415-420, June 1990.
- [5] Cross G.R & A.K Jain, "Markov Random Field Models", IEEE Trans. Pattern Analysis & Machine Intelligence, Vol PAMI-5 N°1, pp 25-39, January 1983.
- [6] Dasarathy B.V. & Holder E.B., "Image characterizations based on joint gray level-run length distributions", Pattern recognition letters, 12, pp 497-502, August 1991.
- [7] Davis L.S, S. A. Johns & J. K. Aggarwal, "Texture Analysis Using Generalized Co-occurrence Matrices", IEEE Trans. Pattern Analysis & Machine Intelligence, Vol PAMI-1, pp 251-259, July 1979.
- [8] Gagalowicz A., "Vers un modèle de textures", Thèse d'état, université Paris VI, mai 1983.
- [9] Galloway M.M, "Texture analysis using Gray Level Run Lengths", Computer graphics and image processing 4, pp 172-179, 1975.
- [10] Gotlieb C.C. & H.E. Kreyszig, "Texture descriptors based on Co-occurrence Matrices", Computer graphics and image processing 51, pp 70-86, 1990.
- [11] Haralick R.M, K. Shanmugam, Its'hak Dinstein, "Textural Features for Image Classification", IEEE Trans. on systems, man & cybernetics, Vol. SMC-3, N° 6, pp 610-621 Nov 1973.
- [12] Laws K.I., "Textured image segmentation", Ph.D. dissertation, Dept. Eng., Univ. of Southern California, Los Angeles, 1980.
- [13] Mignot P., J. Levy Vehel & Y. Le Chevallier, "ARTHUR : Un système d'analyse de texture", Traitement du Signal, Vol 9 N° 6, pp 507-517, 1992.
- [14] Weszka J. S., C. R. Dyer, and A. Rosenfeld, "A comparative study of texture measures for terrain classification", IEEE Trans. SMC. 6(4), April 1976, pp. 269-285.
- [15] Ohanian P.P. & R.C. Dubes, "Performance evaluation for four classes of textural features", Pattern Recognition, 25, pp 819-833 1992.
- [16] Unser, "Description statistique de textures: Application à l'inspection automatique", Thèse n° 534, Ecole Polytechnique Fédérale de Lausanne. 1984.
- [17] Smolarz A., "Étude qualitative du modèle auto-binomial appliqué à la synthèse de texture", XIXèmes Journées de Statistique, Carcassonne, 26-30 Mai 1997.

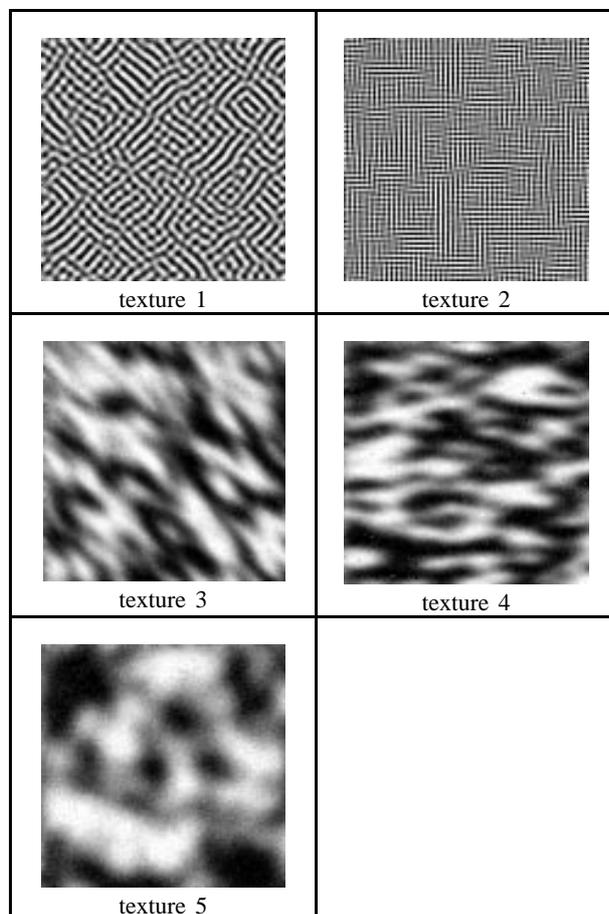


Figure 1 : Textures markoviennes

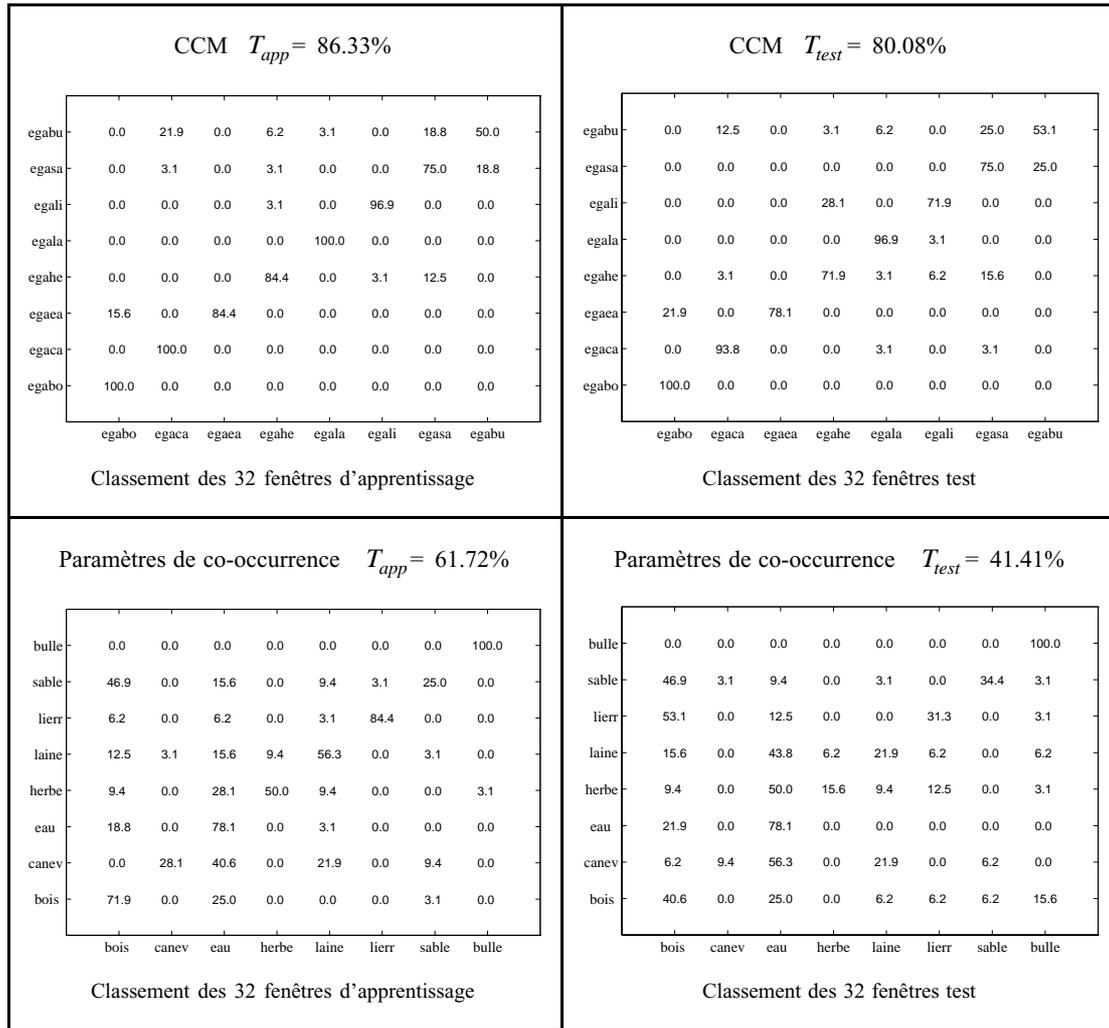


Figure 2 : Matrices de confusion correspondant aux conditions : $G = 8$, $N_{app} = 32$, $W = 31$

W	N_{app} / N_{test}	Co-occurrence ($G = 8$)		CCM ($G = 8$)		CCM ($G = 256$)	
		T_{app} / T_{test}		T_{app} / T_{test}		T_{app} / T_{test}	
21	72 / 72	46.2%	31.1%	75.5%	73.4%	77.1%	72.2%
21	115 / 29	39.9%	35.8%	77.5%	70.3%	77.9%	70.2%
31	32 / 32	61.7%	41.4%	86.3%	80.1%	86.3%	80.9%
31	51 / 13	56.6%	42.3%	85.8%	78.9%	86.8%	80.8%

Tableau 1 : Taux de bonne classification pour les textures de Brodatz

W	N_{app} / N_{test}	Co-occurrence ($G = 8$)		CCM ($G = 8$)		CCM ($G = 256$)	
		T_{app} / T_{test}		T_{app} / T_{test}		T_{app} / T_{test}	
21	25 / 551	100.0%	96.4%	100%	99.9%	100%	98.3%
21	50 / 526	97.6%	96.0%	100%	99.9%	99.6%	98.5%
31	25 / 231	100%	99.3%	100%	100%	100%	99.4%
31	50 / 206	100%	98.9%	100%	100%	99.2%	99.6%

Tableau 2 : Taux de bonne classification pour les textures markoviennes