Une Approche Multi-Modèle pour la classification des textures couleur dans les espaces luminance-chrominance

Ahmed Drissi El Maliani[1], Mohammed El Hassouni[2], Yannick Berthoumieu[3], Driss Aboutajdine[1]

[1]LRIT, Unité Associée au CNRST (URAC 29), Université Mohammed V, Agdal, Maroc.

[2]DESTEC, FLSHR, Université Mohammed V, Agdal, Maroc.

[3]IMS- Groupe Signal- UMR 5218 CNRS, ENSEIRB- Université de Bordeaux, France.

meliani.ahmed@hotmail.fr, mohamed.elhassouni@gmail.com, yannick.berthoumieu@ims-bordeaux.fr, aboutaj@fsr.ac.ma

Résumé – Cet article propose une approche multi-modèle pour la classification des textures couleur. La séparation entre l'information de luminance et celle de chrominance sert à mieux caractériser la texture quand celle-ci est représentée dans un espace couleur approprié. Deux modèles multivariés M_L et M_C basés sur des copules gaussiennes sont utilisés pour modèliser la dépendance spatiale de l'information de luminance, et la dépendance entre les canaux de chrominance respéctivement. L'expérimentation a été réalisée dans deux espaces luminance-chrominance, afin de montrer l'avantage de l'approche multi-modèle en comparaison avec celle utilisant le même modèle pour décrire la luminance et la chrominance.

Abstract – This paper presents multi-model approach for colour texture classification. The separability between the luminance and the chrominance information helps to better characterize the texture when this latter is represented in a luminance-chrominance color space. Two multivariate models M_L and M_C, based on the Gaussian Copula, are used to respectively model the spatial dependence in the luminance channel, and the dependence between the chrominance channels. Experimentation has been carried out in two luminance-chrominance color spaces in order to show the advantage of the multi-model approach over the one using the same model in characterizing luminance and chrominance.

1 Introduction

La classification des textures couleur est l'une des applications les plus importantes dans le domaine de reconnaissance de forme et de vision par ordinateur. Dans une telle application, la caractérisation pertinente de la texture est essentielle, puisque le taux de classification est très influencé par la nature du modèle choisi lors du processus de la caractérisation. De nombreux travaux dans la littérature ont montré que les modèles statistiques sont des modèles pertinents pour représenter les images texturées dans le domaine des ondelettes. Dans le cas des textures couleur, il est possible de reproduire ce qui a été fait dans le cas des textures en niveau de gris en utilisant des modèles univariés tels que la Gaussienne Généralisée (GGD) [1] afin de caractériser chaque composante couleur indépendamment.

Mais, vu le caractère inhomogène et la dépendance qui existe entre les composantes couleur, il peut être pertinent de faire appel à des modèles multivariés qui prennent en considération les dépendances inter et intra bandes. Dans ce sens, Verdoolaeg et al. [2], ainsi que Kwitt et al. [3], ont proposé des modèles multivariés qui regroupent les composantes R,G et B, et qui prennent en considération la forte corrélation qui existe entre ces composantes.

Toutefois, considérer l'image comme étant un signal de luminance et un autre de chrominance, et la traiter dans un espace luminance-chrominance semble approprié puisque cette représentation reste perceptuellement uniforme avec le système visuel humain (SVH). Les espaces luminance-chrominance tels que L*a*b* ou HSV par exemple, donnent une meilleur séparation des composantes de luminance et de celles de chrominance permettant d'avoir une modélisation plus pertinente.

Dans des travaux récents, Quazi et al. [4] ont utilisé des modèles de prédiction linéaire pour estimer les spectres de puissance des canaux de luminance et de chrominance. Pour cela, un modèle bidimensionnel autorégressif quart de plan, et des versions multicanales du modèle demi-plan non symétrique et du modèle de Gauss-Markov ont été utilisés. Ce travail a donné des résultats intéressants en terme de taux de classification, mais tout en considérant le même modèle pour les composantes de luminance et de chrominance qui, elles, peuvent être différentes.

C'est pour cela que nous proposons dans cette contribution une approche multi-modèle qui permet de caractériser

0. Ce travail est supporté par la coopération franco-marocaine CNRS-CNRST projet STIC 05/10

les composantes de luminance et de chrominance séparément par deux modèles différents M_L et M_C. Il s'agit des modèles multivariés construits par des Copules Gaussiennes. Les paramètres de chaque modèle sont estimés pour servir dans l'étape d'apprentissage et de test pour le classifieur choisi (K-Plus Proche Voisin), tout en utilisant la divergence de Kullback-Leibler pondérée comme mesure de similarité.
Cet article est organisé comme suit. Dans la prochaine section nous introduisons l'approche Multi-modèle, en décrivant spécifiquement les modèles de luminance et de chrominance. Dans la section 3, nous présentons le classifieur utilisé, la mesure de similarité et les résultats expérimentaux, avant de terminer avec la conclusion dans la section 4.

2 Modèle de luminance et modèle de chrominance

Considérons une image I représentée dans un espace luminance-chrominance, chaque composante couleur est décomposée selon la transformée en ondelettes complexes en arbres dual DTCWT [5]. Cette transformée présente des avantages en terme d'invariance par rapport à la translation, et aussi en terme de sélectivité directionnelle offrant six sous bandes de fréquences pour chaque niveau de décomposition (échelle), alors que les ondelettes orthogonales classiques n'en offrent que quatre.
Nous appelons l_o, $c_{1,o}$ et $c_{2,o}$ les sous-bandes de fréquence pour la composante de luminance, la première composante de chrominance et la seconde composante de chrominance respectivement, suivant l'orientation o et selon un niveau de décomposition que nous fixons à 2.
Notre but est de construire deux modèles M_L et M_C qui décrivent la luminance et la chrominance à partir des coefficients des ondelettes :

- M_L représente un modèle multivarié qui décrit les dépendances intra bandes (information structurelle) et inter bandes de la luminance.
- M_C représente un modèle bivarié qui considére les dépendances entre les deux canaux de chrominance.

Les deux modèles multivariés reposent sur la théorie des copules. Les copules sont un moyen simple et élégant pour construire des lois multivariées à partir d'un ensemble de lois marginales et une certaine structure de dépendence. Une copule C est une fonction de répartition multivariée définie sur l'hypercube $[0;1]^d$, et dont les marginales sont uniformes sur $[0;1]$. D'aprés le théorème de Sklar [6], étant donné un vecteur aléatoire $X = [X_1, ..., X_d]$ de dimension d, avec une une fonction de répartition F et un ensemble de fonctions de répartition univariées $F_1, ..., F_d$, il existe une copule C telle que :

$$F(x_1, ..., x_d) = C(F_1(x_1), ..., F_d(x_d)) \tag{1}$$

en plus si C est continue et différentiable, la fonction de densité de probabilté de la copule est :

$$c(u_1, ..., u_d) = \frac{\partial^d C(u_1, ..., u_d)}{\partial u_1 ... \partial u_d} \tag{2}$$

et alors, la fonction de densité de probabilité jointe du vecteur X est déduite à partir de la copule et des fonctions de densité de probabilité des marginales

$$f(x_1, ..., x_d) = c(F_1(x_1), ..., F_d(x_d)) \prod_{i=1}^{d} f_i(x_i) \tag{3}$$

Dans cette contribution, nous avons choisi la copule gaussienne pour l'intuitivité et la simplicité de la structure de dépendance qu'elle offre. A partir de là, la densité de la copule est définie comme suit :

$$c(u, \Sigma) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \tag{4}$$

avec $\vartheta_i = \phi^{-1}(F_i(u_i))$, et ϕ représente la fonction de répartition de la distribution normale. Σ définit la matrice de corrélation, et I représente la matrice identité d-dimensionnelle. En se basant sur la famille des copules gaussiennes, la fonction de densité de probabilité jointe du vecteur X est :

$$f(x_1, ..., x_d) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \prod_{i=1}^{d} f_i(x_i) \tag{5}$$

2.1 Le modèle M_L

Comme il a été déja cité, le modèle M_L décrit l'information structurelle pour la luminance. Soit le coefficient $l_k(i, j)$ de la $k^{éme}$ sous-bande de la composante de luminance. En supposant l'homogénéité spatiale des sous bandes de fréquences, nous construisons les vecteurs de voisinage L_k=$[l_k(i-p, i-q),\ ...\ ,l_k(i+p, i+q)]^T$ en faisant glisser une fenêtre de taille $d = (2p+1) \times (2q+1)$. Le vecteur modélisé par M_L est : $L = [L_1, L_2, ..., L_N]$, tel que N représente le nombre des sous-bandes. La fonction de densité de probabilité de M_L est représentée par :

$$f_{M_L}(L; w, \Sigma) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \prod_{i=1}^{N} f_i(l_i, w_i) \tag{6}$$

w=$(w_1, ..., w_N)$ définit l'ensemble des paramètres des marginales, et Σ représente la matrice de corrélation.

2.2 Le modèle M_C

Le modèle M_C décrit la dépendance entre les sous bandes de chrominance $c_{1,k}$ et $c_{2,k}$. Cette dépendence est représentée par le vecteur : C=$[c_{1,k},\ c_{2,k}]$

$$f_{M_C}(C; w, \Sigma) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \prod_{i=1}^{2} f_i(l_i, w_i) \tag{7}$$

tel que w=$(w_1,\ w_2)$ représente les paramètres des marginales des sous-bandes de chrominance.

2.3 Estimation des paramètres

Pour estimer les paramètres de M_L et M_C, nous utilisons la méthode IFM (Inference From Margins) [7]. Elle repose sur le fait que la représentation en copule permet de séparer les paramètres des distributions marginales de ceux de la structure de dépendance. Ainsi, nous estimons, dans un premier temps les paramètres des marginales par la méthode de maximum de vraisemblance :

$$\hat{w_k} = \arg\max_{w_k} \sum_{i=1}^{n} \log(f_k(x_{ik}, w_k)) \quad (8)$$

puis, à partir des estimateurs précédents $\hat{w}$=($\hat{w}_1$, ..., $\hat{w}_d$), nous estimons les paramètres de la structure de dépendance :

$$\hat{\Sigma} = \arg\max_{\Sigma} \sum_{i=1}^{n} \log c(F_1(x_{1i}; \hat{w_1}), ..., F_d(x_{di}; \hat{w_d}); \Sigma) \quad (9)$$

2.4 La mesure de similarité

Afin de mesurer la similarité entre deux images, nous utilisons une divergence de Kullback-leibler (DKL) tenant compte de l'aspect multi-modèle de la caractérisation, en utilisant une combinaison des DKLs entre les modèles de la luminance (KL_L) et ceux de la chrominance (KL_C) à l'aide du coefficient λ :

$$KL = \lambda KL_L + (1 - \lambda) KL_C \quad (10)$$

Le coefficient λ est obtenu expérimentalement, en testant plusieurs valeurs entre 0 et 1.
La mesure de similarité du multi-modèle peut aussi être calculer en utilisant un formalisme de type BIC (Bayesian Inference Criterion),

$$\lambda_i = \frac{exp(BIC(M_i))}{\sum_j exp(BIC(M_j))} \quad (11)$$

tel que $i \in \{L, C\}$. Ainsi,

$$KL = \lambda_L KL_L + \lambda_C KL_C \quad (12)$$

3 Expérimentation et résultats

Afin de valider l'approche proposée, nous utilisons le K-Plus Proche Voisin (K-PPV) comme méthode de classification, en étant une méthode simple et une référence solide dans la littérature. L'idée principale du K-PPV est qu'un objet est classifié selon un vote majoritaire de ses voisins les plus proches en se basant sur une certaine mesure de similarité.
Les tests ont été réalisés sur les textures de la base MIT Vistex [9], en considérant les 24 textures utilisées dans [4] comme le montre la Figure 1, et en utilisant le classifieur du Plus Proche Voisin (PPV). Chaque texture a été divisée en imagettes de taille 32×32. De chaque texture, 96 imagettes sont retenues comme ensemble d'apprentissage et 160 comme ensemble de test.
Comme il a été déja cité, les modèles M_L et M_C sont déduits à partir des équations (6) et (7). Nous avons essayé plusieurs combinaisons de modèles M_L et M_C, et nous avons obtenus les meilleurs résultats en considérant comme modèle de luminance le modèle Gaussienne Généralisée multivariée baseée sur la copule Gaussienne (GGMC), et comme modèle de chrominance, le modèle Weibull multivariée basée sur la copule Gaussienne (WblMC). La pdf du modèle Gaussienne Généralisée multivariée basée sur la Copule Gaussienne est définie par :

$$f_{GGMC}(x, \theta) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \times$$

$$(\frac{\beta}{2\alpha\Gamma(\frac{1}{\beta})})^d \exp - \sum_{i=1}^{d} (\frac{|x_i|^\beta}{\alpha}) \quad (13)$$

avec $\theta = (\alpha, \beta, \Sigma)$, α represente le paramétre de forme, β represente le paramétre d'échelle, et Σ la matrice de corrélation.
Les estimateurs de α et β sont déja calculés en [1], et puisqu'on est dans le cas de la copule gaussienne, l'estimateur de la matrice de corrélation est donné par :

$$\hat{\Sigma} = \frac{1}{d} \sum_{i=1}^{d} \vartheta_i {\vartheta_i}^T \quad (14)$$

La pdf du modèle Weibull multivariée basée sur la copule Gaussienne est définie par :

$$f_{WblMC}(x, \theta) = \frac{1}{|\Sigma|^{1/2}} \exp[-\frac{1}{2}\vartheta^T(\Sigma^{-1} - I)\vartheta] \times$$

$$(\frac{\tau}{\lambda})^d \prod_{i=1}^{2} x_i^{\tau-1} \exp - \sum_{i=1}^{2} (\frac{x_i}{\lambda})^\tau \quad (15)$$

avec $\theta = (\tau, \lambda, \Sigma)$, τ représente le paramétre de forme, λ représente le paramétre d'échelle, et Σ la matrice de corrélation. Les estimateurs de τ et λ sont, cette fois, calculés en [8], et l'estimateur et le même que dans le cas GGMC. Les Tableaux 1 et 2 montrent les taux de classification dans les espaces L*a*b* et HSV respectivement pour différentes valeurs du coefficient de combinaison λ.

TABLE 1 – Taux de classification dans l'espace de couleur L*a*b*

λ	0.15	0.6	0.7	**0.86**	0.95
{GGMC,WblMC}	81.66	88.8	90.65	**96.33**	85
{GGMC,GGMC}	75.32	79.87	84.72	**89.67**	78.77

Nous constatons que les taux sont meilleurs avec l'espace L*a*b*, ce qui est dû au fait que ce dernier permet une meilleure séparation des canaux de luminance et de

FIGURE 1 – 24 classes de textures : De gauche à droite et de haut en bas : 'Bark.0000', 'Bark.0012', 'Fabric.0000', 'Fabric.0004', 'Fabric.0007', 'Fabric.0008', 'Fabric.0011', 'Fabric.0013', 'Fabric.0015', 'Fabric.0017', 'Fabric.0019', 'Flowers.0000', 'Food.0000', 'Leaves.0012', 'Grass.0001', 'Clouds.0000', 'Brick.0000', 'Wood.0002', 'Water.0000', 'Tile.0007', 'Stone.0004', 'Sand.0000', 'Misc.0002', 'Metal.0000'

TABLE 2 – Taux de classification dans l'espace de couleur HSV

λ	0.15	0.6	0.7	**0.86**	0.95
{GGMC,WblMC}	74.45	79.28	87.65	**91.42**	76.88
{GGMC,GGMC}	73.50	77.8	80.45	**85**	74.68

chrominance. Nous observons, aussi, que les valeurs de λ donnant les meilleurs résultats se situent entre 0.6 et 0.86. Il est aussi clair que considérer des modèles différents lors de la caractérisation ({GGMC,WblMC}) améliore celle-ci par rapport à l'approche uni-modèle. Enfin, nous observons que notre approche se montre meilleure que celle présentée dans [4] où le meilleur taux de classification atteint 95.29%, alors que nous obtenons 96.33% comme meilleur taux de classification.

4 Conclusion

Dans cet article, nous avons proposé une approche Multi-modèle pour la caractérisation des textures couleurs dans les espaces luminance-chrominance. En reposant sur la théorie des copules, nous avons developpé des modèles multivariés qui prennent en considération la nature de chacunes des information structure et couleur indépendamment. Les résultats montrent que le fait de considérer ces deux informations dans la modélisation, en utilisant le modèles approprié pour chacune d'elles, améliore considérablement les performances en terme de taux de classification. Ces résultats peuvent être améliorés en choisissant plus pertinemment les modèles M_L et M_C. Par exemple, dans le cas de l'espace HSV, où la composante H est circulaire, nous pouvons opter pour un modèle circulaire comme marginale, et utiliser le fait que les copules permettent de coupler des marginales différentes pour construire le modèle de chrominance M_C.

Références

[1] M. Do and M. Vetterli, "Wavelet-based texture retrieval using generalized Gaussian density and Kullback-Leibler distance,"*IEEE Transactions on Image Processing* , vol. 11, pp. 146–158, 2002.

[2] G. Verdoolaeg, S. De Backer, and P.Scheunders, "Multiscale colour texture retrieval using the geodesic distance between multivariate Generalized Gaussian models," in *Proceedings of the 15th IEEE Interational Conference On Image Processing (ICIP'08)*, San Diego, California, USA, 2008, pp. 169–172.

[3] R. Kwitt and A. Uhl, "A joint model of complex wavelet coefficients for texture retrieval," in *Image Processing, 2009. ICIP 2009. 16th IEEE International Conference*, 2009, pp. 1877-1880.

[4] I.U.H. Qazi, O. Alata, J.C. Burie, and C. Fernandez-Maloigne, "Color spectral analysis for spatial structure characterization of textures in IHLS color space," *Pattern Recognition*, vol. 43,no. 3, pp. 663–675, 2010.

[5] N. Kingsbury, "The Dual-Tree Complex Wavelet Transform : A new Technique for Shift-Invariance and Directional Filters,," in *Proceedings of the 8th IEEE DSP Workshop, Bryce Canyon*, Utah, USA, Aug. 1998, pp. 9–12.

[6] M. Sklar, "Fonctions de répartition à n dimensions et leurs marges,". *Publications de l'institut de Statistique de l'Université de Paris*. vol. 8, pp. 229-231, 1959.

[7] H. Joe, *Multivariate Models and Dependence Concepts*. Monographs on Statistics and Applied Probability. Chapman & Hall, 1997.

[8] K. Krishnamoorthy, *Handbook of Statistical Distributions with Applications*. Chapman & Hall, 2006.

[9] "MIT vision and modeling group," [Online], Available from : http ://vismod.media.mit.edu.