

Détermination d'un espace couleur pertinent pour la caractérisation de textures couleur

Imtnan-UI-Haque QAZI¹, Jean-Christophe BURIE², Olivier ALATA¹, Christine FERNANDEZ-MALOIGNE¹

¹Lab. XLIM-SIC, UMR CNRS 6172, Université de Poitiers, 86960, Chasseneuil, France.

²Lab. L3I, EA 2118, Université de La Rochelle, 17042, La Rochelle Cedex 1, France.

qazi,alata,fernandez@sic.sp2mi.univ-poitiers.fr , jcburie@univ-lr.fr

Résumé – Cet article propose une comparaison des espaces couleur IHLS et $L^*a^*b^*$ pour la caractérisation de textures. L'information couleur est utilisée pour construire une image constituée de deux canaux : un canal réel pour la "Luminance" et un canal complexe pour la "Chrominance". Des modèles de prédiction linéaire 2D vectorielle sont utilisés pour l'estimation paramétrique de la densité spectrale de puissance de l'image "bi-canal". Dans ce contexte, une expérimentation mettant en oeuvre les spectres de luminance et de chrominance montre que l'espace IHLS présente une interférence plus importante entre les deux canaux que l'espace $L^*a^*b^*$. Les spectres sont ensuite utilisés pour caractériser des textures couleur. La classification a été réalisée, dans chaque espace, en considérant les informations structurelles de luminance et chrominance individuellement, puis en les combinant. Les résultats montrent que l'espace $L^*a^*b^*$ permet d'obtenir des meilleurs taux de classification sur les textures utilisées.

Abstract – This paper presents a comparison of colour spaces including IHLS and $L^*a^*b^*$ for colour texture characterization. Colour information is used to build a two channel image that contains pure luminance values in one channel and complex chrominance values in the other channel. The power spectrum estimation is done using 2D multichannel linear prediction models. A spectral analysis using luminance and chrominance spectra shows that the IHLS colour space presents a more important interference between luminance and chrominance channels than the $L^*a^*b^*$ colour space. The spectra are used to characterize colour textures. Then classification has been carried out in each colour space. Individual as well as combined effect of information from luminance and chrominance structure cues has been used for classification. A better rate classification on the set of colour textures is obtained for $L^*a^*b^*$ colour space.

1 Introduction

Dans une application utilisant des images couleur, le choix d'un espace couleur pertinent permet d'améliorer considérablement les résultats. Une méthode consiste à tester les différents espaces, puis effectuer un choix en fonction des résultats finaux [1]. Une deuxième approche, adoptée ici, consiste à justifier les choix par une inférence théorique et/ou par des preuves expérimentales.

Pour la caractérisation de textures couleur, la structure spatiale de l'information de chrominance n'a pas été étudiée autant que celle de la luminance, alors que G. Paschos [2] a montré l'intérêt de prendre en compte la structure spatiale de la chrominance.

Dans cet article, nous présentons une combinaison probabiliste des informations de structure spatiale de la chrominance avec celle de la luminance, pour la classification des textures dans les espaces couleur IHLS (Improved Hue Luminance Saturation) [3] et $L^*a^*b^*$ [4]. A partir d'une image dans ces espaces, on construit une image constituée de deux canaux : un canal contenant l'information de "luminance" et un canal contenant l'information de "chrominance". Nous proposons l'extension de modèles bidimensionnels de prédiction linéaire aux images constituées de deux canaux. Une comparaison basée sur la

nature et le niveau d'interférence entre le spectre de la luminance et celui de la chrominance est réalisée dans chaque espace couleur. Nous montrons l'importance de prendre en compte simultanément la structure spatiale de la luminance et de la chrominance pour la caractérisation des textures couleur. Les deux informations sont combinées par une approche basée sur la probabilité *a posteriori*. Les taux de classification des textures couleur pour différents modèles de prédiction linéaire sont calculés puis comparés et discutés.

2 Les Espaces Couleur

2.1 Espaces CIE $L^*a^*b^*$ et IHLS

Dans la plupart des applications utilisant des images couleur, les auteurs se contentent de travailler dans l'espace RGB. Cependant, l'emploi d'espaces couleur séparant les composantes chromatiques et achromatiques permet souvent de révéler des éléments difficilement identifiables dans les plans R, G, B. Plusieurs espaces réalisent cette séparation comme l'espace CIE- $L^*a^*b^*$ [4] ou l'espace IHLS proposé dans [3]. Nous avons fait le choix d'utiliser ces deux espaces à cause de leurs bonnes propriétés comme l'indique la littérature.

2.2 L'image couleur "bi-canal"

L'idée consiste à construire une image contenant deux canaux. Le premier canal correspond aux valeurs de Luminance, c'est à dire la composante "L" des espaces IHLS et $L^*a^*b^*$. Le second canal est obtenu à partir des 2 composantes chromatiques. Ces composantes sont regroupées afin d'obtenir une valeur complexe représentative de la chrominance. Pour IHLS, ce deuxième canal est obtenu par l'expression suivante :

$$C = S \times \exp(j \times H) \quad (1)$$

où H et S sont respectivement la teinte et la saturation. Pour l'espace CIE $L^*a^*b^*$, il est calculé ainsi :

$$C = a^* + j \times b^* \quad (2)$$

où a^* et b^* sont les composantes chromatiques de l'espace CIE $L^*a^*b^*$. Une image couleur peut ainsi être représentée par un vecteur défini ainsi :

$$x_n = \begin{bmatrix} l_n \\ c_n \end{bmatrix} \quad (3)$$

où $l_n \in \mathbb{R}$ représentent le canal "luminance" et $c_n \in \mathbb{C}$ le canal "chrominance" avec $n = (n_1, n_2) \in \Lambda \subset \mathbb{Z}^2$, Λ la grille régulière 2D finie, support de l'image.

3 Prédiction linéaire multicanale

3.1 Définition

Un champ aléatoire 2D complexe multicanal peut être décrit par une famille de vecteurs aléatoires $X = \{X_n\}_{n \in \mathbb{Z}^2}$ de dimension P , P représentant le nombre de canaux. On suppose que chaque X_n est de moyenne nulle. Un modèle de prédiction linéaire peut alors être défini par une série de vecteurs de prédiction :

$$\hat{X}_n = - \sum_{m \in D} A_m X_{n-m} \quad (4)$$

permettant d'écrire chaque X_n sous la forme d'une somme :

$$X_n = \hat{X}_n + E_n \quad (5)$$

avec $m = (m_1, m_2) \in D \subset \mathbb{Z}^{*2}$ un site faisant partie d'un voisinage défini par D appelé "support de prédiction". Les matrices $P \times P$, A_m , $m \in D$, contiennent les paramètres du modèle et $E = \{E_n\}_{n \in \mathbb{Z}^2}$ est la famille de vecteurs aléatoires associée aux erreurs de prédiction. Nous supposons ici que E est un processus multicanal stationnaire de matrice de variance-covariance Σ_e et de Densité Spectrale de Puissance (DSP) $S_{e,\nu}$ où $\nu = (\nu_1, \nu_2)$ est la fréquence normalisée 2D. Comme la DSP d'un processus numérique est de période unité pour chacune de deux dimensions, nous étudierons par la suite les DSP pour $\nu \in [-0.5, 0.5]^2$.

D'après les équations 4 et 5, la DSP de X s'obtient de la manière suivante :

$$S_\nu = A_\nu^{-1} S_{e,\nu} (A_\nu^H)^{-1} \quad (6)$$

avec

$$A_\nu = I + \sum_{m \in D} A_m \exp(-j2\pi \langle \nu, m \rangle). \quad (7)$$

I est la matrice identité de dimensions $P \times P$, $\langle \cdot, \cdot \rangle$ le produit scalaire dans \mathbb{R}^2 et A_ν^H la matrice adjointe de A_ν .

Pour les images multicanales (cf. équation 3), $P = 2$ et, pour chaque valeur de ν , la DSP de X est une matrice de la forme :

$$S_\nu = \begin{bmatrix} S_{LL}(\nu) & S_{LC}(\nu) \\ S_{CL}(\nu) & S_{CC}(\nu) \end{bmatrix} \quad (8)$$

avec $S_{LL}(\nu)$ la DSP du canal de valeurs réelles associée à la Luminance, $S_{CC}(\nu)$ la DSP du canal de valeurs complexes associée à la Chrominance et $S_{LC}(\nu) = S_{CL}^*(\nu)$ l'interspectre des deux canaux. L'étape suivante consiste à estimer le spectre de puissance. Nous utilisons pour cela les modèles de prédiction décrits dans la section suivante.

3.2 Modèles de prédiction linéaire

3.2.1 Modèle bidimensionnel autorégressif quart de plan

Le modèle bidimensionnel autorégressif quart de plan (AR 2D QP) est défini à partir des équations 4 et 5. Pour réaliser l'analyse spectrale avec ce modèle, nous utilisons les supports de prédiction D^{QP_1} et D^{QP_2} définis ainsi :

$$\begin{aligned} D_{M_1, M_2}^{QP_1} &= \{(m_1, m_2) / 0 \leq m_1 \leq M_1, \\ &\quad 0 \leq m_2 \leq M_2, (m_1, m_2) \neq (0, 0)\} \\ D_{M_1, M_2}^{QP_2} &= \{(m_1, m_2) / 0 \geq m_1 \geq -M_1, \\ &\quad 0 \leq m_2 \leq M_2, (m_1, m_2) \neq (0, 0)\} \end{aligned} \quad (9)$$

où $(M_1, M_2) \in \mathbb{N}^2$ désigne l'ordre du modèle. Les DSP obtenues à partir des modèles AR QP₁ et AR QP₂ ont la même forme que celle donnée par l'équation 6. Cependant, chacune de ces DSP présente une anisotropie qui peut être corrigée en calculant la moyenne harmonique (Harmonic Mean - HM) des deux DSP :

$$S_{HM}(\nu) = \frac{1}{2} \times \left(S_{QP_1}^{-1}(\nu) + S_{QP_2}^{-1}(\nu) \right)^{-1} \quad (10)$$

avec $S_{QP_1}(\nu)$ et $S_{QP_2}(\nu)$ désignant les DSP respectives associées aux modèles AR QP₁ et AR QP₂. Pour déterminer $S_{HM}(\nu)$, il est nécessaire d'estimer pour chaque modèle : les paramètres $A_m^{QP_1}$ et $A_m^{QP_2}$, $m \in D_{M_1, M_2}$, ainsi que les matrices de variance-covariance $\Sigma_{e,1}$ et $\Sigma_{e,2}$.

3.2.2 Autres modèles utilisés

Afin d'estimer le spectre de puissance de l'image "bi-canal", nous ne nous sommes pas limités au modèle précédent. Des versions "multicanales" du modèle Demi-Plan Non Symétrique (AR 2D DPNS ou NSHP en Anglais) et du modèle de Gauss-Markov (GMRF pour Gauss Markov Random Field) ont également été utilisés. Comme pour le modèle AR 2D QP, la DSP est une matrice identique à celle décrite par l'équation 8. Des détails sur ces modèles sont disponibles dans [5].

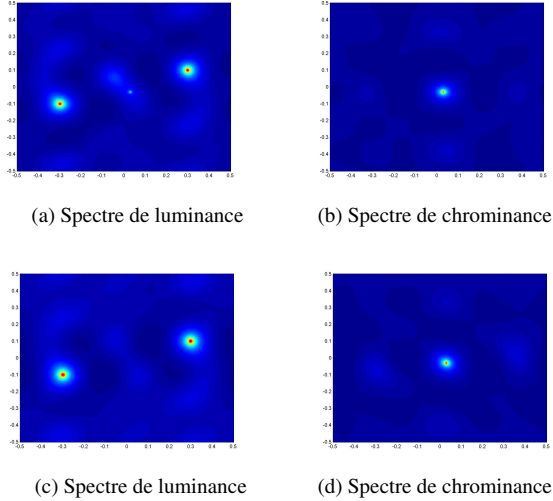


FIG. 1 – DSP estimée de la Luminance et de la Chrominance en IHLS (a,b) et L*a*b* (c,d) avec le modèle AR 2D QP.

4 Analyse Spectrale

Pour comparer objectivement les espaces couleurs, les estimations du spectre ont été réalisées sur des images de synthèse. Des images couleurs “bi-canal” ont été générées afin d’avoir une composante luminance constituée d’une sinusoïde 2D réelle $x_1 = \{x_{1n}\}_{n \in \Lambda}$ définie ainsi :

$$x_{1n} = A_r \cos(2\pi \langle n, \nu_r \rangle + \phi_r) \quad (11)$$

où $A_r, \nu_r = (0.30, 0.10)$ et ϕ_r sont respectivement l’amplitude, la fréquence et la phase de la sinusoïde réelle. La composante chrominance est, quant à elle, constituée d’une sinusoïde 2D complexe $x_2 = \{x_{2n}\}_{n \in \Lambda}$ définie par :

$$x_{2n} = A_c \exp(j\phi_c) \times \exp(j2\pi \langle n, \nu_c \rangle) \quad (12)$$

où $A_c, \nu_c = (0.03, -0.03)$ et ϕ_c sont respectivement l’amplitude, la fréquence et la phase de la sinusoïde complexe. Pour ces images, l’ensemble des paramètres (amplitudes, fréquences, phases) étant connu, une comparaison qualitative des espaces couleurs ILHS et L*a*b* a pu être réalisée. Pour analyser la corrélation entre la luminance et la chrominance dans chacun des espaces couleur cités précédemment, nous avons adopté le protocole suivant. Les sinusoïdes réelles et complexes ont été créées sous la forme d’images de 64×64 pixels. Ces sinusoïdes sont ensuite mises sous la forme d’un vecteur comme le montre l’équation 3 afin d’obtenir des images “bi-canal”. Un bruit blanc multicanal est alors ajouté aux images. En utilisant les formules de passage de IHLS vers RGB et L*a*b* vers RGB, nous obtenons alors des images décrites dans l’espace RGB. Enfin, ces images sont retransformées en IHLS et L*a*b*. La DSP des images obtenues est alors estimées avec un des modèles de prédiction présenté section 3.

L’analyse spectrale a été effectuée sur 10 images sinusoïdales générées avec différentes séquences de bruit blanc gaussien. L’étude des DSP estimées (fig. 1 et table 1) montre que la DSP de la luminance pour l’espace IHLS (fig. 1 (a)) contient

TAB. 1 – Ratio de l’amplitude moyenne des pics de chrominance présents dans les spectres de luminance / amplitude moyenne des pics de luminance pour les espaces IHLS et L*a*b* (modèle AR QP).

	Ratio de <i>C en L</i> sur <i>L</i>	
	IHLS	L*a*b*
AR QP	0.1254	0.0066

une interférence provenant de la chrominance. Par contre, dans le cas de l’espace L*a*b* (fig. 1 (c)), aucune interférence n’est visible. Le rapport entre les valeurs moyennes de l’amplitude des pics de chrominance qui apparaissent dans les spectres de luminance sur les valeurs moyennes de l’amplitude des pics de luminance (table 1) confirme ce résultat. La séparation luminance-chrominance est donc nettement meilleure dans l’espace L*a*b* que dans l’espace IHLS. La section suivante a pour objectif de montrer que la présence d’interférences peut affecter les résultats de classification des textures couleur.

5 Classification de textures couleurs

5.1 Distance spectrale

Pour estimer la similitude entre les spectres de luminance et de chrominance, il est nécessaire de définir une mesure de distance spectrale. Basseville propose dans [6] une extension de la divergence de Kullback-Leibler (KL) pour mesurer la distance spectral entre deux spectres. Nous utilisons la même distance pour mesurer la similitude entre les spectres de luminance ou de chrominance. La mesure de distance spectrale est définie ainsi :

$$K_i(S_{1,i}, S_{2,i}) = \frac{1}{2} \sum_{\nu_1, \nu_2} \left| \sqrt{\frac{S_{1,i}(\nu_1, \nu_2)}{S_{2,i}(\nu_1, \nu_2)}} - \sqrt{\frac{S_{2,i}(\nu_1, \nu_2)}{S_{1,i}(\nu_1, \nu_2)}} \right|^2 \quad (13)$$

où i désigne le canal avec $i \in \{L, C\}$, “L” correspondant à la Luminance et “C” à la Chrominance. Les distances spectrales de la Luminance et de la Chrominance sont ainsi mesurées indépendamment avec la divergence de KL symétrisée [5].

5.2 Fusion “Luminance - Chrominance”

Pour améliorer le taux de classification, les informations sur la structure spatiale de la luminance et de la chrominance sont combinées. Dans un premier temps, les probabilités conditionnelles sont calculées indépendamment pour chaque canal à partir de la mesure de similarité basée sur la divergence de KL (cf. 5.1). Le produit de ces probabilités permet de calculer la probabilité conditionnelle “combinée” des informations de luminance et chrominance. Une texture couleur x est alors affectée à la classe \hat{j} qui maximise le produit des probabilités conditionnelles :

$$\hat{j} = \arg \max_{j \in \{1, \dots, J\}} \left(\prod_{i \in \{L, C\}} P_i(w_j|x) \right) \quad (14)$$

où $i \in \{L, C\}$, w_j , $j \in \{1, \dots, J\}$ est le label de classe et J le nombre de classes de textures couleur. Ces probabilités sont obtenues à partir de la mesure réalisée entre les spectres :

$$P_i(w_j|x) = \frac{\frac{1}{1+d_i(x, x_j)}}{\sum_{l=1}^J \frac{1}{1+d_i(x, x_l)}} \quad (15)$$

où i désigne toujours le canal et $d_i(x, x_j)$ est la divergence de KL symétrisée entre la texture inconnue x et la classe de texture j pour un canal donné (voir partie 5.3).

5.3 Expérimentation et résultats

Les tests ont été réalisés sur les textures de la base MIT Vis-Tex. Afin d'évaluer la pertinence de la méthode proposée nous avons effectué les tests sur les 24 textures utilisées dans [1]. L'estimation des DSP a été réalisée sur des imagerie de taille 32×32 à l'aide des modèles AR 2D QP mais également AR 2D NSHP et GMRF. Pour chaque texture couleur, une base d'apprentissage (96 imagerie) et une base de test (160 imagerie) ont été constituées. Lors de la phase d'apprentissage, la distance $d_i(x, x_j)$ (cf. eq. 15) est calculée ainsi :

$$d_i(x, x_j) = \min_{x_{j,l}} d_l(x, x_{j,l}) \quad (16)$$

où $x_{j,l}$, $l = 1, \dots, 96$ sont les spectres des images de la base d'apprentissage associés à la classe j .

La table 2 présente les pourcentages de classification de textures couleur pour les espaces IHLS et $L^*a^*b^*$ obtenus pour les trois modèles présentés. Sur les tables 2 (a) et (b), la colonne L (resp. C) donne les taux de classification obtenus en utilisant les distances spectrales basées sur la luminance (resp. la chrominance). La troisième colonne LC correspond aux taux de classification obtenus en combinant les informations de luminance et de chrominance. Ces tableaux montrent que le meilleur résultat de classification a été obtenu à l'aide de la méthode QP. Avec $L^*a^*b^*$, les trois méthodes (colonne LC) dépassent le meilleur résultat présenté dans [1] : 91,2% obtenu avec la Transformée en Cosinus Discrète (DCT), en ne considérant que la luminance. On remarque également que les résultats de classification utilisant uniquement l'information spectrale de chrominance (C) sont meilleurs avec $L^*a^*b^*$ qu'avec IHLS. Cela confirme les résultats présentés au 4 à savoir une meilleure séparation des canaux luminance-chrominance avec $L^*a^*b^*$, ce qui permet de mieux caractériser les textures avec cet espace qu'avec l'espace IHLS.

Pour finir, nous avons aussi calculé les taux de classification en utilisant l'espace RGB et la méthode QP. La fusion des trois canaux permet d'obtenir un pourcentage de 85,96% ce qui est un résultat nettement inférieur à ceux obtenus avec IHLS et $L^*a^*b^*$ fournis dans la table 2 (ligne "QP" et colonnes "LC").

TAB. 2 – Pourcentages de classification de 24 textures couleur obtenus par trois méthodes d'analyse spectrale paramétrique pour IHLS (a) et $L^*a^*b^*$ (b).

	(a)			(b)		
	L	C	LC	L	C	LC
GMRF	72.47	66.98	87.27	73.83	78.39	91.95
NSHP	82.11	83.18	93.33	83.62	88.59	94.64
QP	87.37	85.76	95.42	87.66	92.06	97.24

6 Conclusion

Dans cet article nous présentons une comparaison des espaces couleurs Improved HLS et $L^*a^*b^*$ dans un but de caractérisation des textures couleur. La comparaison est réalisée à partir de l'estimation du spectre de puissance des canaux de luminance et de chrominance. Les résultats montrent que la séparation luminance-chrominance est meilleure pour l'espace $L^*a^*b^*$ ce qui permet une meilleure caractérisation des textures. Dans un deuxième temps, la méthode proposée a été comparée, pour les deux espaces couleur étudiés, à d'autres méthodes de la littérature. Les expérimentations ont montré que l'utilisation combinée des informations de luminance et de chrominance associées à la méthode QP améliore nettement le taux de classification des textures couleur dans l'espace $L^*a^*b^*$. D'autre part, la méthode proposée donne de meilleurs résultats de classification que dans la littérature. Les tests présentés dans cet article sont effectués sur des imagerie de taille fixe. Nous travaillons actuellement à étendre la méthode présentée afin de segmenter des images naturelles.

Références

- [1] H. Permuter, J. Francos, and I. Jermyn, "A study of gaussian mixture models of color and texture features for image classification and segmentation," *Pattern Recognition*, vol. 39, no. 4, pp. 695–706, April 2006.
- [2] G. Paschos, "Chromatic Correlation Features for Texture Recognition," *Pattern Recognition Letters*, vol. 19, no. 8, pp. 643–650, June 1998.
- [3] A. Hanbury and J. Serra, "A 3d-polar coordinate colour representation well adapted to image analysis," in *Proceedings of the Scandinavian Conference on Image Analysis (SCIA)*, 2003, pp. 804–811.
- [4] Commission Internationale de l'Eclairage, "Colorimetry," *Technical Report*, 1986, CIE 15.2.
- [5] I. Qazi, O. Alata, J.-C. Burie and C. Fernandez-Maloigne "Spatial structure characterization of textures in IHLS colour space," in *Proc. of the IEEE International Conference on Acoustics, Speech and Signal Processing*, pp. 1069-1072, 2009.
- [6] M. Basseville, "Distance Measures for Signal Processing and Pattern Recognition," *Signal Processing*, vol. 18, no. 4, pp. 349–369, December 1989.