
Segmentation d'images couleur par analyse d'histogrammes couleur compacts

Sié Ouattara, Alain Clément, Bertrand Vigouroux, Julio Rojas Varela

*Laboratoire d'Ingénierie de Systèmes automatisés UPRES EA 4094
Institut Universitaire de Technologie, BP 42018, 49016 ANGERS CEDEX, France*

*sie_ouat@yahoo.fr ; alain.clement@univ-angers.fr; bertrand.vigouroux@univ-angers.fr ;
julio.rojasvalera@univ-angers.fr*

Sections de rattachement : 61, 63

Secteur : Secondaire

RÉSUMÉ. Nous présentons une méthode de segmentation non supervisée des images couleur. Elle est basée sur une analyse hiérarchique d'histogrammes couleur compacts. Chaque mode de l'histogramme constitue un noyau de classe, lorsque le nombre de pixels correspondant est supérieur ou égal à un seuil arbitrairement fixé. Généralisé à n dimensions, l'utilisation de l'histogramme nD compact sans pertes de données permet de réduire de façon considérable l'espace mémoire occupé. Par conséquent, la segmentation peut être réalisée sans requantification des couleurs de l'espace colorimétrique considéré dans la phase de classification. On montre que, pour les images couleur l'utilisation de l'histogramme 3D compact conduit à une meilleure segmentation que celles des histogrammes 1D ou 2D.

MOTS-CLÉS : Segmentation, classification, images couleur, histogramme compact.

1. Introduction

La segmentation est une étape importante en traitement des images car elle conditionne leur interprétation. Les méthodes de segmentation basées sur l'analyse d'histogramme couleur sont confrontées à la difficulté de manipuler une grande quantité de données : pour une image de résolution $N \times M$ où chaque composante est codée sur 8 bits, un histogramme couleur classique est représenté par un tableau de 2^{24} cellules. Le nombre occupé par chaque cellule pour stocker le nombre de pixels associés à une couleur réellement présente dans

l'image est codé sur $\log_2(M.N)$ bits. Dans le cas où $M=N=256$, l'histogramme couleur classique occupe 128 Mo.

Il a été proposé il y a quelques années une nouvelle méthode de codage d'un histogramme multidimensionnel appelé histogramme nD compact (Clément et al., 2001), dans lequel seules les cellules occupées dans l'histogramme classique sont prises en compte. Ceci réduit de façon considérable l'espace mémoire occupé : typiquement un volume de 500 Ko pour une image de résolution 256×256 dont chaque composante couleur est codée sur 8 bits, sans perte d'information couleur.

La classification colorimétrique de pixels par analyse d'histogrammes peut être réalisée au moyen de quatre stratégies différentes :

La première stratégie est basée sur une approche marginale. Chaque composante de l'histogramme est examinée séparément. La méthode est facile à mettre en œuvre, mais elle ne prend pas en compte la corrélation entre les composantes colorimétriques (Julie et al. 2007).

Dans la seconde stratégie, chaque composante colorimétrique est requantifiée sur q bits ($q < 8$) afin de réduire la taille de l'histogramme. Cette méthode est efficace mais elle effectue une classification *a priori* (Xuan et al, 2000).

La troisième stratégie effectue soit une projection de l'histogramme sur deux des trois axes colorimétriques, soit une réduction à deux composantes en appliquant une analyse en composantes principales (Kurugollu et al., 2001; Clément et al., 2003). La corrélation entre les composantes est partiellement prise en compte. Les modes détectés peuvent être différents de ceux de l'histogramme couleur.

Nous contribuons ici à une quatrième stratégie totalement vectorielle en utilisant l'histogramme couleur compact. Celui-ci facilite la manipulation des histogrammes couleur dans un espace mémoire réduit. Dans la section 2 nous présentons la structure de l'histogramme compact. La section 3 présente l'étiquetage en composantes connexes de l'histogramme compact. L'analyse hiérarchique de l'histogramme étiqueté permettant la classification des couleurs est détaillée à la section 4. Dans la section 5, la méthode est appliquée à différentes images couleur. Une étude comparative est réalisée, à la section 6, entre la méthode de classification proposée et une méthode de classification par analyse d'histogramme bi-dimensionnels (Clément et al., 2003) en utilisant des méthodes d'évaluation de segmentation.

2. Principe de l'histogramme nD compact

Afin de résoudre le problème de codage et de manipulation des histogrammes multidimensionnels, il a été proposé dans (Clément et al., 2001) un algorithme de calcul d'un histogramme multidimensionnel compact. Sachant que la majorité des cellules de l'histogramme classique sont vides, l'histogramme compact stocke uniquement les C cellules réellement occupées. Il est constitué de deux tableaux (figure 1) : pour une image à

n composantes, un tableau de taille $C \times n$ pour stocker les n -uplets colorimétriques dans l'ordre lexicographique, et un tableau de taille $C \times 1$ correspondant au nombre de pixels associés (effectif). Lorsque C est inférieur à $M \times N$, l'histogramme compact occupe moins d'espace mémoire que l'histogramme classique; dans le cas contraire, il contient toutes les couleurs présentes dans l'image.

R	V	B	effectif
0	0	5	13
0	0	23	5
...
255	10	0	21
255	251	254	3

Figure 1 . Exemple d'histogramme couleur compact d'une image RVB (8 bits par composante).

3. Etiquetage en composantes connexes de l'histogramme nD compact

Nous avons récemment développé dans (Ouattara et al. 2007) un algorithme d'étiquetage en composantes connexes (ECC) de l'histogramme nD compact. Son principe consiste à effectuer un balayage de tous les n -uplets présents dans l'histogramme compact dans le but de réunir, sous la même étiquette, les n -uplets voisins dans l'espace colorimétrique nD .

Comme les n -uplets sont classés dans l'ordre lexicographique dans l'histogramme compact, l'étiquetage d'un n -uplet est obtenu en balayant uniquement les $(3^n - 1)/2$ n -uplets voisins qui le précèdent. La figure 2 montre un exemple de quatre couples à balayer pour étiqueter le couple (r,v) dans le cas d'un histogramme $2D$ compact.

		Axe V		
		$(r-1,v-1)$	$(r-1,v)$	$(r-1,v+1)$
Axe R		$(r,v-1)$	(r,v)	

Figure 2 . Voisins du couple (r,v) à balayer lors de l'ECC dans le cas d'un histogramme $2D$ (axes colorimétriques R et V de l'espace RVB).

4. Classification non supervisée de l'histogramme nD compact

La classification des n -uplets colorimétriques est effectuée en deux phases: la phase d'apprentissage et la phase de décision. La *phase d'apprentissage* consiste en une décomposition hiérarchique de l'histogramme pour un seuil d'effectifs fixé S en parcourant l'axe des effectifs. Pour chaque niveau d'effectifs E_j (j de 1 à effectif max), les modes P_i (i de 1 à m quelconque) sont identifiés au moyen de l'ECC présenté à la section 3. Chaque mode est ensuite décomposé itérativement en d'autres modes tant que son effectif est supérieur ou égal au seuil S (exprimé en pourcentage par rapport à l'effectif total de l'histogramme). Le principe de décomposition hiérarchique est illustré figure 3 (dessiné en une dimension pour des raisons de clarté. Nous noterons K_i les noyaux des modes aux feuilles entourées sur la figure 3b. En d'autres termes, les noyaux sont les modes significatifs (figure 3a) n'ayant pas de descendants dans l'arbre de décomposition hiérarchique. La figure 3 montre cinq modes significatifs P_i ($i = 0$ à 4) et trois noyaux K_i ($i = 2, 3, 4$). Le nombre de classes N_c est égal au nombre de noyaux (une classe correspondant au noyau K_i est noté C_i). Cependant N_c dépend du seuil S , c'est-à-dire de la précision avec laquelle l'analyse de l'image est réalisée. Dans la figure 3, N_c est égal à 3.

Dans la *phase décision*, les centres de gravité $\mu(K_i)$ de chaque noyau K_i sont calculés dans l'espace colorimétrique. Désignons par β un point de coordonnées $(\beta_1, \beta_2, \dots, \beta_n)$ dans l'espace colorimétrique nD . Deux situations peuvent se présenter : si le n -uplet appartient à K_i , la couleur β est attribuée à la classe C_i ; dans le cas contraire, nous désignerons par P_k le mode auquel appartient le n -uplet. La couleur β est attribuée à la classe C_i correspondant au noyau K_i lié au mode P_k minimisant $d(\mu(K_i), (\beta_1, \beta_2, \dots, \beta_n))$. $d(a,b)$ est la distance euclidienne entre a et b .

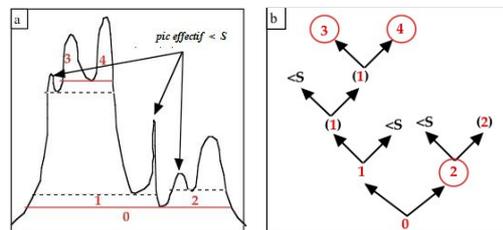
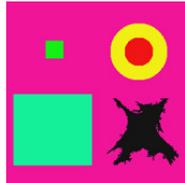


Figure 3 . Exemple de décomposition hiérarchique pour un seuil d'effectif S fixé.

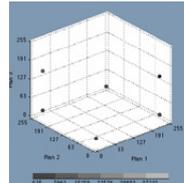
5. Résultats de segmentation

Afin de comparer pour des images couleur, la méthode de segmentation proposée relativement à une approche de segmentation par histogramme 2D (Clément et al., 2003),

dont les résultats d'évaluation sont présentés à la section 6, nous présentons dans cette section les résultats de segmentation des deux approches. Les images à traiter sont une image synthétique (figure 4a) codée sur 24 bits, de résolution 256x256, inspirée de l'image *Savoise* (Lambert et al., 2000) ayant 6 classes de couleurs pures - sa construction et son histogramme 3D sont illustrés figure 4 - et trois images naturelles présentées figure 5.



(a) Image synthétique: Synt_Sie



(b) Histogramme 3D

Description régions	Plans			Effectifs	
	R	V	B	Nombre de Pixels	Pourcentage
Fond (1)	240	20	153	44526	67,9
Petit disk (2)	240	20	20	1245	1,9
Grand disk (3)	240	240	20	3768	5,7
Petit Carré (4)	20	240	20	625	1,0
Grand Carré (5)	20	240	154	11000	16,8
Etoile (6)	20	20	20	4372	6,7

(c) Construction de l'image synthétique

Figure 4 . Image synthétique Synt_Sie dans l'espace RVB et sa construction

Les images sont segmentées au moyen des approches 2D et 3D dont les résultats sont présentés figure 6. Pour chaque image, on précise le nombre de classes recherchées. Pour l'image synthétique l'obtention des six classes n'est pas possible par l'approche marginale. Pour les images naturelles segmentées avec l'approche 2D, les différentes combinaisons de plans engendrent des segmentations différentes. Il reste néanmoins possible de fusionner les trois segmentations 2D mais le nombre de classes final et la nature des classes diffèrent selon la stratégie de fusion utilisée (Kurugollu et al., 2001), (Lezoray et al., 2004).

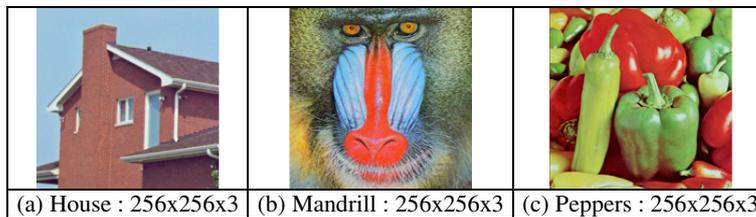


Figure 5. Images naturelles codées sur 24 bits issues de la base de données University of Southern California.

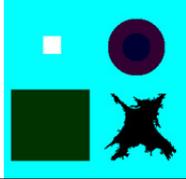
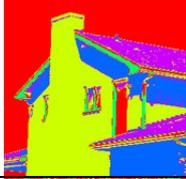
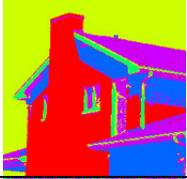
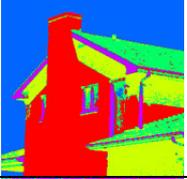
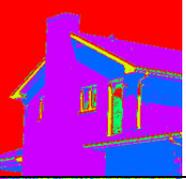
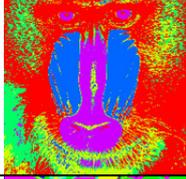
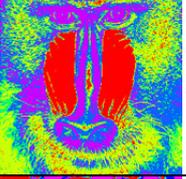
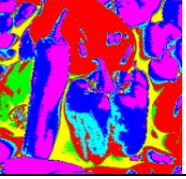
Nombre de classes	Segmentation 3D (RVB)	Segmentation 2D (RV)	Segmentation 2D (RB)	Segmentation 2D (VB)
Synt_Sie (6 classes)		impossible	impossible	impossible
House (5 classes)				
Mandrill (5 classes)				
Peppers (6 classes)				

Figure 6 . Résultats de segmentation en 2D et 3D.

6. Évaluation des résultats

Il existe dans la littérature diverses méthodes d'évaluation de segmentation qui peuvent être regroupées en deux catégories : (i) les méthodes d'évaluation supervisée et (ii) les méthodes d'évaluation non supervisée. La seconde catégorie est utilisée dans ce travail avec les critères de Levine–Nazif (Levine et al., 1985), Zeboudj (Zeboudj, 1988) et de Borsotti (Borsotti et al. 1998) couramment utilisés, leurs expressions mathématiques sont données en annexe. Ces critères se sont avérés performants dans de nombreuses applications (Phillipp-Foliguet et al. 2006).

Les critères de Levine-Nazif et de Borsotti s'appuient sur l'énergie intra-classe et privilégient les segmentations à régions coloriquement homogènes. La différence entre ces deux critères est que le critère de Borsotti accorde un poids important aux classes de grands effectifs et pénalise les segmentations contenant des classes à effectifs égaux. Le critère de Zeboudj prend quant à lui en compte l'énergie intra-classe et l'énergie inter-classes, favorisant les segmentations à classes homogènes et bien séparées. Les critères de Levine-

Nazif et de Zeboudj accordent le plus grand score à la meilleure segmentation, alors que le critère de Borsotti retourne la plus faible valeur.

Conformément à ce qui est pratiqué dans la littérature, les résultats d'évaluation sont donnés avec une précision au 1/10000 dans le tableau ci-dessous. Ces résultats montrent que sur l'ensemble des trois critères d'évaluation, la segmentation vectorielle 3D est en général meilleure que les segmentations marginales. Cependant, pour l'image House et Mandrill, la segmentation sur les plans *VB* et *RB* semblent meilleure selon Zeboudj qu'en 3D. Ceci traduit bien la difficulté qu'il y a à évaluer de manière générale la segmentation et le degré de précision des critères utilisés reste un point discutable. Néanmoins, nos résultats montrent que la prise en compte des corrélations entre les plans colorimétriques (segmentation 3D) aboutit à une meilleure segmentation.

	<i>Nombre de classes</i>	<i>Segmentation 3D (RVB)</i>	<i>Segmentation 2D (RV)</i>	<i>Segmentation 2D (RB)</i>	<i>Segmentation 2D (VB)</i>
Critère de Levine	Synt_Sie (6 classes)	1	impossible	impossible	impossible
	House (5 classes)	0,9680	0,9599	0,9613	0,9650
	Mandrill (5 classes)	0,9144	0,8795	0,9127	0,8207
	Peppers (6 classes)	0,9314	0,8899	0,8954	0,9124
	<i>Nombre de classes</i>	<i>Segmentation 3D (RVB)</i>	<i>Segmentation 2D (RV)</i>	<i>Segmentation 2D (RB)</i>	<i>Segmentation 2D (VB)</i>
Critère de Zeboudj	Synt_Sie (6 classes)	0,5091	impossible	impossible	impossible
	House (5 classes)	0,65006	0,5851	0,5553	0,7092
	Mandrill (5 classes)	0,3680	0,2997	0,3717	0,3177
	Peppers (6 classes)	0,5977	0,5578	0,5264	0,5815
	<i>Nombre de classes</i>	<i>Segmentation 3D (RVB)</i>	<i>Segmentation 2D (RV)</i>	<i>Segmentation 2D (RB)</i>	<i>Segmentation 2D (VB)</i>
Critère de Borsotti	Synt_Sie (6 classes)	$1,25 \cdot 10^{-13}$	impossible	impossible	impossible
	House (5 classes)	0,1211	0,1424	0,1570	0,1445
	Mandrill (5 classes)	0,4043	0,5464	0,4602	0,7241
	Peppers (6 classes)	0,3211	0,3959	0,4215	0,3754

Figure 7 . Résultats d'évaluation de la segmentation. En gras la segmentation la plus pertinente

7. Conclusion

Dans ce travail, nous avons mis en œuvre une méthode de classification vectorielle 3D non supervisée capable de segmenter les images couleur et plus généralement multicomposantes (*nD*). L'évaluation de la segmentation montre que l'approche vectorielle est meilleure que l'approche marginale car elle prend en compte la corrélation entre les composantes colorimétriques.

Bibliographie

Borsotti M., Campadelli P., Schettini R., Quantitative evaluation of color image segmentation results, *Pattern Recognition Letters*, 19:741–747, 1998.

Clément A., Vigouroux B., Un histogramme compact pour l'analyse d'images multicomposante, *Actes du 18e Colloque GRETSI sur le Traitement du Signal et des Images*, Toulouse, France, 1, 305-307, 2001.

Clément A., Vigouroux B., «Unsupervised segmentation of scenes containing vegetation (Forsythia) and soil by hierarchical analysis of bi-dimensional histograms », *Pattern Recognition Letters*, n° 24, 1951-1957, 2003.

Julie D., Agnès D., José-Luis L., Ana B. P., A non-parametric approach for histogram segmentation, *IEEE Transaction on Image Processing*, 16, n°1, 253-261, 2007.

Kurugollu F., Sankur B., Harmanci A. E., Color image segmentation using multithresholding and fusion, *Image and Vision Computing*, 19, 915-928, 2001.

Lambert P., Macaire L., Filtering and segmentation : the specificity of color images, *Proceeding of 1st International Conference on Color in Graphics and Image Processing*, Saint-Etienne, France, 57-71, 2000.

Levine M. D., Ahmed M. Nazif. Dynamic measurement of computer generated image segmentations, *IEEE Transaction on Pattern Analysis and Machine intelligence*, PAMI, 7 n°2, 155-164, march, 1985.

Lezoray O., Charrier C., Segmentation d'images couleur par coalescence non supervisée d'histogrammes 2D et fusion de régions selon la théorie de Dempster-Shafer, *Revue de Traitement du Signal*, vol. 21, n°6, pp.605-621, 2004.

Ouattara S., Clément A. Etiquetage d'histogrammes multidimensionnels compacts pour l'analyse d'images multicomposantes; *Actes du 21^{ème} Colloque GRETSI sur le traitement d'images*, Troyes, France, 11-14 septembre, CD-ROM, 2007.

Philipp-Foliguet S., Guigues L., Evaluation de la segmentation : état de l'article, nouveaux indices et comparaison, *Revue de Traitement du Signal*, 23, n°2, 109-125, 2006.

Xuan G., Fisher P. Maximum likelihood clustering method based on color features, *Proceeding of 1st International Conference on Color in Graphics and Image Processing*, Saint-Etienne, France, 191-194, 2000.

Zeboudj R., Filtrage, Seuillage Automatique, Contraste et Contours: du Pré-traitement à l'Analyse d'image, PhD thesis, Université de Saint Etienne, 1988.

Annexe

$Levine - Nazif = 1 - \sum_i \frac{\sigma_i^2}{c}$, avec σ_i l'écart type de la classe i et C une constante de normalisation

$Borsotti = \frac{1}{10000 \cdot A} \cdot \sqrt{N} \cdot \sum_{i=1}^N \left(\frac{\sigma_i^2}{1 + \log(A_i)} + \left(\frac{f(A_i)}{A_i} \right)^2 \right)$, avec A le nombre de pixel total de l'image, N le nombre de classes, A_i la taille de la classe i et $f(A_i)$ le nombre de classes ayant un effectif égal à A_i

$Zeboudj = \frac{1}{A} \cdot \sum_{i=1}^N A_i \cdot C(R_i)$, avec $C(R_i)$ le contraste global d'une région R_i qui dépend du contraste intérieur et extérieur de la région R_i , voir (Zeboudj 1988)