

Segmentation automatique des images couleur à base d'indicateurs de performance

N. Bouloudani, P. Lambert, D. Coquin

LISTIC (Laboratoire d'Informatique des Systèmes et du Traitement
de l'Information et de la Connaissance)

ESIA, Université de Savoie, BP 806
5 chemin de Bellevue, 74016 - Annecy, France

{nadia.bouloudani, patrick.lambert, didier.coquin}@univ-savoie.fr

Résumé

Dans cet article nous abordons le problème de la segmentation automatique d'images couleur. La méthode de segmentation utilisée est basée sur un algorithme de classification hiérarchique itérative basé sur des estimateurs flous de compacité et de séparation de classes. Le résultat est une segmentation simplifiée ayant un nombre restreint de grandes régions. L'intérêt de la méthode proposée est qu'elle n'exige qu'un seul paramètre, noté α . Nous utilisons alors deux indicateurs de performance afin de qualifier le résultat de la segmentation. Dans une analyse "hors-ligne" élaborée sur un vaste échantillon d'images de toute nature, nous construisons le lien entre une segmentation "optimale" (du point de vue visuel) et l'évolution des indicateurs en fonction du paramètre de segmentation α . Pour une image quelconque, la connaissance de ce lien est alors exploitée pour choisir automatiquement la valeur de α aboutissant à une "bonne" segmentation.

Mots clefs

Classification Floue, Segmentation Automatique, Indicateurs de Performance.

1 Introduction

La segmentation est une tâche très importante et difficile, car elle dépend de la nature de l'image et de l'objectif de l'analyse. La littérature propose de nombreuses techniques de segmentation [1, 2, 3, 4], mais la plupart d'entre elles ont besoin de plusieurs paramètres dont le réglage exige souvent l'expertise humaine. Dans ce qui suit, nous présentons d'abord une technique robuste de segmentation basée sur une classification floue (§2). Cette méthode exige l'ajustement d'un seul paramètre d'action, noté α dans la suite. Dans une deuxième étape, nous définissons deux indicateurs de performance (§3) qualifiant la segmentation. Puis, en liant ces indicateurs au réglage du paramètre

α , il est possible de définir une segmentation automatique (§4). Le mécanisme ainsi défini sélectionne la valeur du paramètre α en fonction des variations des indicateurs calculés à partir des résultats de plusieurs segmentations de l'image traitée. Enfin nous présentons (§5) quelques résultats utilisant cette approche.

2 Procédé de segmentation

2.1 Principe de la méthode

La méthode de segmentation que nous avons utilisée est basée sur une technique de classification. Cependant, la plupart des algorithmes de classification ont deux inconvénients principaux. D'abord, le nombre de classes est souvent prédéfini, ce qui n'aide pas le traitement automatique. Ensuite, les classes obtenues ont généralement des formes sphériques, du fait des critères quadratiques souvent utilisés. Ce dernier point est particulièrement gênant, en particulier dans le cas des images couleur où les classes ont souvent des formes arbitraires.

Pour éviter ces deux inconvénients, nous employons une technique spécifique de segmentation que nous avons proposée dans [5]. Cette méthode appartient à la classe des algorithmes agglomératifs hiérarchiques et est basée sur les estimateurs flous d'isolation et de compacité des classes. En partant du résultat fourni par une technique de classification traditionnelle, la technique, appliquée de manière itérative, consiste à essayer de fusionner les classes initiales. La fusion entre deux classes n'est effectuée que si l'isolement entre ces deux classes est comparable à leur compacité. La signification quantitative du terme "comparable" est donnée par le paramètre α , unique paramètre de l'algorithme. Ce paramètre fixe le niveau de fusion désiré, et par conséquent le niveau de simplification de la segmentation.

2.2 Technique de segmentation

La technique se décompose en deux étapes:

- *Classification initiale:*

La première étape consiste à faire une première classification en appliquant l'algorithme "Fuzzy C-Mean" - FCM [4, 6]. Ceci exige le choix du nombre de classes, noté C .

Soit $X = \{x_1, x_2, \dots, x_N\}$ l'ensemble des vecteurs couleur initiaux. L'idée fondamentale de l'approche FCM est d'assigner à chaque vecteur x_n un degré d'appartenance flou à chacune des différentes classes c_i , de centre de gravité v_i . Ce degré d'appartenance, noté u_{in} , est défini par:

$$u_{in} = \left(\sum_{j=1}^c \left(\frac{\|x_n - v_i\|}{\|x_n - v_j\|} \right)^{2/(m-1)} \right)^{-1} \quad (\text{Eq. 1})$$

Le paramètre m permet de contrôler le degré flou de la méthode. Dans la suite, nous avons fixé $m = 2$.

L'algorithme est basé sur la minimisation itérative des erreurs d'intra-classe. Le résultat de cette étape est une sur-classification où les classes ont des formes généralement sphériques. La sur-classification est obtenue en choisissant volontairement un nombre de classes important.

- *Le processus d'agglomération:*

La deuxième étape consiste à tenter d'agglomérer les différentes classes sphériques obtenues par le FCM. Cela est obtenu en définissant et en comparant l'**isolation** et la **compacité** des différentes classes. L'isolation I_{ij} entre deux classes c_i et c_j est donnée par :

$$I_{ij} = \left(\sum_{n=1, N} \min(u_{in}, u_{jn}) \right) / \left(\sum_{n=1, N} \max(u_{in}, u_{jn}) \right) \quad (\text{Eq. 2})$$

Lorsque I_{ij} est proche de 0, les classes c_i et c_j sont bien isolées. Dans le cas contraire, I_{ij} est proche de 1.

Si une classe c_k est composée de l'union de P classes sphériques, c.à.d $c_k = \bigcup_{p=1, P} c_p$, sa compacité CP_k est définie en terme d'isolation entre les différentes classes par :

$$CP_k = \frac{1}{P} \cdot \sum_{i=1}^P \min_{\substack{j=1, P \\ j \neq i}} (I_{ij}) \quad (\text{Eq. 3})$$

Quand les différentes classes c_p composant la classe c_k sont isolées, leurs paramètres d'isolation mutuelles tendent vers 0, et donc la compacité de la classe c_k tend vers 0. Au contraire, quand les classes c_p ne sont pas isolées, leurs isolations tendent vers 1 et la compacité de la classe c_k est proche de 1.

Le processus d'agglomération est basé sur la décision

de fusion binaire pour chaque paire de classes. Le mécanisme est exécuté itérativement pour toutes les paires de classes. Pour deux classes c_i et c_j , à chaque itération, nous comparons l'isolation I_{ij} à la compacité moyenne des deux classes notée CP_{ij} . Cette compacité moyenne CP_{ij} est une moyenne pondérée entre CP_i et CP_j . Les poids sont la cardinalité floue des classes c_i et c_j . La décision de fusion est prise seulement si l'isolation est comparable à la compacité moyenne, décision traduite par la règle suivante:

si $I_{ij} \leq \alpha \cdot CP_{ij}$ **alors**
 c_i et c_j ne sont pas agglomérées
sinon
 c_i et c_j sont fusionnées

Où α est un paramètre qui commande le processus d'agglomération. Si α est petit, la condition ci-dessus ne sera pas souvent vérifiée, et le processus de fusion sera souvent appliqué, conduisant à une segmentation avec un nombre restreint de grandes régions. Au contraire, si α est grand (c'est à dire α proche de 1, car l'isolation est plus petite que la compacité moyenne), le processus d'agglomération sera peu fréquent, et la segmentation résultante restera proche de la segmentation initiale.

2.3 Illustration

La figure suivante donne le résultat obtenu sur une image réelle (image de la base de données de la société GoodShoot). La classification est exécutée dans l'espace RVB avec une initialisation à 16 classes.



Image originale

Image segmentée
($\alpha = 0.9$)

Image segmentée
($\alpha = 0.2$)

Figure 1 - Illustration de la méthode de segmentation

La difficulté est de déterminer la valeur du paramètre α fournissant une segmentation "optimale". Pour ce faire, nous proposons une méthode qui utilise des indicateurs de performance.

3 Indicateurs de performance

Le problème est de trouver des indicateurs pouvant être calculés sur une image segmentée et fournissant des mesures en accord avec l'impression humaine. Nous présentons deux critères mesurant la qualité de la segmentation. Le premier, proposé par Levine et Nazif [7], est basé sur l'uniformité de région. Le second est la fonction d'évaluation de Borsotti [8] basée sur les tailles des régions, leurs formes et leur homogénéité.

La mesure d'uniformité d'une image segmentée est définie par la formule suivante:

$$U = 1 - \frac{1}{W} \sum_{R_j \in SI} A_j \sigma_j^2 \quad (\text{Eq. 4})$$

où A_j et σ_j sont respectivement la taille et la variance des intensités couleurs de la région R_j . La somme est réalisée sur toutes les régions de l'image segmentée. W est un facteur de normalisation assurant $0 \leq U \leq 1$. Cette mesure est une mesure globale puisqu'elle prend en compte toutes les régions de l'image segmentée. Plus l'uniformité U est proche de 1, meilleur est le résultat de la segmentation.

Pour une image segmentée de taille $X \times Y$, la fonction d'évaluation de Borsotti est définie comme:

$$Q = \frac{1}{10000 \times X \times Y} \sqrt{p} \sum_{i=1}^p \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right] \quad (\text{Eq. 5})$$

où p est le nombre de régions de l'image segmentée, A_i est la taille de la région R_j , $R(A_i)$ est le nombre de régions ayant une taille égale à A_i , e_i est l'erreur moyenne de couleur de la $i^{\text{ème}}$ région: e_i est calculée par la somme des distances euclidiennes, dans l'espace RVB, entre les vecteurs couleur des pixels de la région i et le vecteur couleur attribué à la région i dans l'image segmentée.

La somme est composée de deux termes: le premier est d'autant plus grand que les régions sont inhomogènes (avec une pondération en fonction de la taille des régions), alors que le deuxième terme, par l'intermédiaire de $R(A_i)$ vient pénaliser les segmentations comportant un nombre important de régions de même taille, ce qui, dans la pratique, revient à pénaliser les segmentations comportant beaucoup de petites régions. En résumé, plus la valeur de Q est petite, meilleur est le résultat de la segmentation.

Ces deux critères U , et Q sont employés pour évaluer les résultats de la segmentation.

4 Segmentation automatique

4.1 Principe

Cette méthode consiste à faire plusieurs segmentations avec différentes valeurs du paramètre α . Chaque segmentation est évaluée avec les indicateurs de performance définis dans le §3. A partir de cette évaluation, et en s'appuyant sur une connaissance *a priori* sur les liens entre les indicateurs, le paramètre α et la notion de "bonne segmentation", il est alors possible de sélectionner la valeur optimale du paramètre α , et choisir ainsi la meilleure segmentation.

La connaissance experte, nécessaire au développement de la méthodologie, est obtenue en réalisant un grand nombre de segmentations. Cette étape est détaillée ci-dessous.

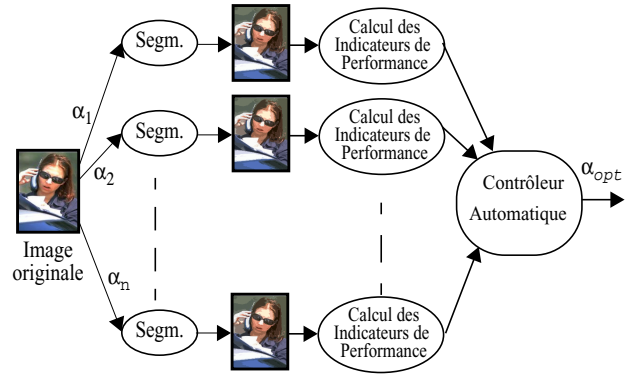


Figure 2 - Réglage automatique de la segmentation

4.2 Acquisition de l'expertise

Le but de cette partie est d'établir notre propre expertise liant les indicateurs de performance au paramètre de contrôle α . Nous avons effectué de nombreuses expériences sur un large éventail d'images, ce qui nous a permis de mettre en évidence trois types de comportements, le troisième étant le plus fréquent. Ceux-ci sont récapitulés dans les diagrammes suivants.




Figure 3 - Evolution des indicateurs de performance U et Q

Dans ces diagrammes, α_{opt} correspond à la meilleure segmentation selon l'appréciation subjective de l'utilisateur. Dans le premier diagramme (Fig. 3-a), la meilleure segmentation correspond à la plus grande valeur de U , ou à la plus petite valeur de Q . Dans le second (Fig. 3-b), α_{opt} est la plus grande valeur de α correspondant à une grande valeur de U ou à une petite valeur de Q . Dans le dernier cas (Fig. 3-c), α_{opt} est la plus petite valeur de α correspondant à une grande valeur de U ou à une petite valeur de Q . Ces résultats sont cohérents avec l'analyse du comportement des indicateurs présentée dans (§3).

4.3 Calcul de α

Notre étude nous a permis d'établir des règles utilisées dans le contrôle et définies comme suit :

si les évolutions de U et Q correspondent à Fig. 3-a alors

α_{opt}^U correspond au maximum de U et

α_{opt}^Q correspond au minimum de Q

si les évolutions de U et Q correspondent à Fig. 3-b alors

α_{opt}^U est la plus grande valeur correspondant à une grande valeur de U

α_{opt}^Q est la plus grande valeur correspondant à une petite valeur de Q

si les évolutions de U et Q correspondent à Fig. 3-c alors

α_{opt}^U est la plus petite valeur correspondant à une grande valeur de U

α_{opt}^Q est la plus petite valeur correspondant à une petite valeur de Q

La valeur optimale finale de α est calculée comme suit:

$$\alpha_{opt} = \frac{1}{2}(\alpha_{opt}^U + \alpha_{opt}^Q) \quad (\text{Eq. 6})$$

5 Résultats

Notre approche a été appliquée sur quatre classe différentes des images extraites de la base de données GoodShoot (Fig. 4).




Figure 4 - Les résultats de la segmentation de l'approche proposée

Les tests effectués ont montré que cette méthode donne des segmentations finales satisfaisantes pour la majorité des images. Nous présentons (Fig. 4) quelques résultats obtenues sur des images de nature différentes, en donnant l'image initiale à droite et le résultat de la segmentation automatique à gauche. Nous avons cependant noté que, dans certains de nos essais, la segmentation finale ne correspond pas à la segmentation optimale du point de vue de l'utilisateur. Dans ces situations, les indicateurs de performance ne semblent pas assez appropriés ou ne correspondent pas à l'un des trois comportements proposés dans notre étude.

6 Conclusion

Nous avons proposé une nouvelle méthodologie permettant une segmentation automatique. Les résultats obtenus sont satisfaisants pour une large variété d'images. Pour que cette méthode puisse être généralisée à tout type d'image, deux pistes sont envisageables :

- d'abord améliorer les indicateurs de performance afin de fournir plus d'information sur les résultats de segmentation,

- ensuite acquérir une meilleure expertise sur le comportement de ces indicateurs en fonction du paramètre de réglage de la segmentation.

Références

- [1] A. N. Zahid. O. Abouelala, M. Limouri, "Unsupervised fuzzy clustering", Pattern Recognition Letters, 20 (1999), pp. 123-129.
- [2] T. Uchiyama & M.A. Arbib, "Color Image Segmentation using competitive learning", IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. PAMI-16, n° 12, 1994, pp. 1197-1206.
- [3] P. Scheunders, "A genetic c-means clustering algorithm applied to color image quantization", Pattern Recognition, vol. 30, no. 6, pp. 859-866, 1997.
- [4] Y.W. Lim & S.U. Lee, "On the color image segmentation algorithm based on the thresholding and the fuzzy c-Means techniques", Pattern Recognition, vol. 23, no 9, 1990, pp. 935-952.
- [5] Grecu H., Lambert P., "Image Retrieval by Partial Queries", Proc. of the 8th IEEE International Conference on Image Processing (ICIP'01), Thessaloniki, Greece, Oct. 2001, pp. 26-29.
- [6] J. Bezdeck, "Pattern recognition with fuzzy objective functions algorithms", Plenum Press, New York, 1982.
- [7] M. D. Levine, A. M. Nazif, "Dynamic Measurement of Computer Generated Image Segmentations", IEEE PAMI, vol. 7, number 2, March, pp. 155-164, 1985.
- [8] M. Borsotti, P. Campadelli, R. Schettini, "Quantitative Evaluation of Color Image Segmentation Results", Pattern Recognition Letters 19, pp. 741-747, 1998.
- [9] P. Lambert, G. Mauris and A. Elbou, "Image Processing Makeup Using Fuzzy Performance Indicators", IEEE Workshop on Emerging Technologies, Intelligent Measurement and Virtual Systems for Instrumentation and Measurement - ETIMVIS'98 ST Paul, MN, USA May, pp. 85-93, 1998.