

# Fusion Génétique de Résultats de Segmentation

Christophe ROSENBERGER

Laboratoire de Vision et Robotique  
ENSI de Bourges, 10 bd lahitolle  
18020 Bourges Cedex - FRANCE  
christophe.rosenberger@ensi-bourges.fr

## Résumé –

Nous proposons dans cette communication une méthode originale de fusion de résultats de segmentation d'images basée sur l'optimisation d'un critère. Le critère d'évaluation que nous proposons permet de prendre en compte la qualité de chaque résultat de segmentation sans connaissances *a priori* telle que la vérité terrain dans le processus de fusion. La méthode d'optimisation est un algorithme génétique permettant de déterminer la meilleure combinaison des résultats de segmentation au sens du critère précédent. Nous montrons l'efficacité de la méthode proposée aux travers de résultats expérimentaux.

## Abstract –

We propose in this communication an original fusion method of segmentation results based upon the optimisation of a criterion. The evaluation criterion we defined allows us to take into account the quality of each segmentation result without any *a priori* knowledge such as the ground truth in the fusion process. The optimisation method is a genetic algorithm providing to determine the best combination of segmentation results in sense of the previous criterion. We show the efficiency of the proposed method through experimental results.

## 1 Introduction

La qualité de l'interprétation d'une image dépend fortement de celle de la segmentation. La fusion de résultats de segmentation est un problème important car peut être appliquée pour combiner la segmentation d'images provenant de différents capteurs, de différentes composantes, etc. Différentes méthodes de fusion ont été proposées parmi lesquelles on peut distinguer deux types d'approche.

La première peut être qualifiée de supervisée dans la mesure où des connaissances *a priori* sur les différents résultats de segmentation sont connues ou extraites par apprentissage [1]. Il est possible dans ce cas, de modéliser la confiance dans l'information apportée par un capteur ou une composante et de l'intégrer dans le processus de fusion en utilisant par exemple la théorie de l'évidence, de Dempster-Schafer, etc [7], [5].

La seconde approche de fusion n'exploite que les informations contenues dans les résultats de segmentation sans *a priori* sur leurs pertinences. Ainsi, les méthodes basées sur des opérations logiques, sur la similarité des résultats [3], [6] sont des exemples de cette approche.

Nous proposons dans cette communication, une méthode de fusion basée sur cette dernière approche. Les méthodes existantes ont le principal inconvénient de ne pas intégrer la qualité des résultats de segmentation mais uniquement leurs corrélations. La méthode que nous proposons permet de prendre en compte la qualité de chaque résultat de segmentation à fusionner en

introduisant un critère d'évaluation. Ce critère quantifie de manière globale la qualité d'un résultat sans connaissance *a priori* d'une vérité terrain [10] en mesurant une disparité intraclasse et interclasse de chaque région. Ces disparités sont calculées en tenant compte du type de région (uniforme ou texturé) et sont combinées afin d'obtenir une valeur normalisée de la qualité globale du résultat de segmentation. Nous appliquons par la suite ce critère d'évaluation en fusion de résultats de segmentation. La fusion est ici considérée comme un problème d'optimisation de la combinaison des résultats de segmentation en prenant en compte leurs qualités. Nous avons utilisé un algorithme génétique [9] qui garantit une grande rapidité de convergence.

Nous présentons la méthode développée et mettons en évidence son efficacité aux travers de différents résultats expérimentaux. Nous concluons et donnons les perspectives de travaux futurs basés sur cette approche.

## 2 Méthode développée

Nous supposons disposer de  $n$  résultats de segmentation  $I^j$  d'une image  $I$ , chacun comportant  $N_{CLASS}^j$  classes. On pose  $NCOL$  et  $NLIG$  le nombre de colonnes et de lignes de l'image  $I$ . Un algorithme génétique est défini à partir de cinq types de données :

- **génotype** : il permet de caractériser un individu. Un résultat de segmentation peut être considéré comme un vecteur à valeurs dans  $\{1, \dots, N_{CLASS}\}$  de taille  $NCOL \times NLIG$ ,

- **population initiale** : elle est composée des résultats de segmentation à fusionner,
- **fonction d'aptitude** : elle correspond au critère d'évaluation d'un résultat de segmentation que nous allons préciser par la suite,
- **opérations sur les génotypes** : nous avons utilisé deux des trois opérateurs sur les génotypes :
  - la sélection : elle consiste à sélectionner les individus qui vont survivre à la prochaine génération. Plusieurs techniques existent parmi lesquelles on peut citer le mode élitiste consistant à ne conserver que les individus ayant les valeurs les plus importantes de la fonction d'aptitude. Le tournoi par contre, consiste à tirer au sort deux individus et de conserver celui des deux ayant la fonction d'aptitude la plus élevée,
  - la reproduction : elle consiste à combiner les gènes des individus parents,
  - la mutation : quelques gènes tiré au sort d'un individu sont modifiés. Nous n'avons pas utilisé l'opérateur de mutation afin que le résultat final ne dépende que de la population initiale. Le résultat final de fusion ne doit refléter que des informations présentes dans la population initiale,
- **critère d'arrêt** : stabilité de l'écart-type des fonctions d'aptitude des résultats de segmentation à une génération donnée.

Nous proposons par la suite une méthode d'évaluation de la qualité d'un résultat de segmentation ne nécessitant aucune connaissance *a priori*, basée sur la définition de la segmentation par Haralick [4]. Le critère défini sera exploité dans la méthode de fusion proposée afin de pondérer chaque résultat de segmentation.

## 2.1 Définition du critère d'évaluation

Dans l'élaboration d'un critère d'évaluation d'un résultat de segmentation, on doit tenir compte des deux propriétés suivantes [4] :

- Une région de l'image segmentée ne doit contenir qu'une seule primitive (une texture ou un niveau de gris constant), ceci pour garantir qu'il n'y ait pas sous-segmentation. Ainsi, une région est caractérisée par une stabilité des statistiques en son sein.
- Deux régions limitrophes doivent contenir deux primitives différentes pour garantir qu'il n'y ait pas sur-segmentation. Ceci correspond à une disparité des statistiques entre ces deux régions [10].

En tenant compte de ces deux points, on peut considérer que le meilleur résultat de segmentation  $I^*$  d'une image donnée  $I$  parmi  $n$  au sens d'un critère  $F$  que nous précisons par la suite est tel que :

$$I^* = \arg \max_{j=1..n} F(\underline{D}(I^j), \overline{D}(I^j))$$

La disparité intraclasse globale  $\underline{D}(I^j)$  quantifie l'homogénéité de chacune des régions de l'image  $I^j$ . De même, la disparité interclasse globale  $\overline{D}(I^j)$  mesure la disparité globale de chacune des régions de l'image  $I^j$ . Ces deux disparités sont des mesures normalisées.

Pour avoir une valeur quantitative d'un résultat de segmentation, nous avons choisi la fonction  $F$  suivante pour le calcul de notre critère :

$$F(\underline{D}(I), \overline{D}(I)) = \frac{\overline{D}(I) + 1 - \underline{D}(I)}{2}$$

Le nombre de régions composant l'image segmentée  $I^j$  peut varier selon la méthode employée. On note  $m_j$  le nombre de régions  $R_i^j$ ,  $i = 1..m_j$  de l'image segmentée  $I^j$ ,  $r_i^j$  le nombre de pixels de la région  $R_i^j$  et  $NT$  le nombre de pixels total de l'image.

La disparité intraclasse globale  $\underline{D}(I^j)$  d'une image segmentée  $I^j$  traduit la stabilité des statistiques de chacune des régions de l'image. Elle est calculée à partir de la disparité intraclasse  $\underline{D}(R_i^j)$ <sup>1</sup> des différentes régions  $R_i^j$ ,  $i = 1..m_j$  de l'image segmentée :

$$\underline{D}(I^j) = \frac{1}{m_j} \sum_{i=1}^{m_j} \frac{r_i^j}{NT} \underline{D}(R_i^j)$$

L'importance de la disparité intraclasse d'une région  $R_i^j$  dans le calcul de la disparité intraclasse globale est proportionnelle au nombre de pixels  $r_i^j$  de cette région. Il est en effet souhaitable qu'une région de petite taille ait une influence moindre dans le calcul de la disparité intraclasse globale. Une région contenant deux primitives différentes doit avoir une disparité intraclasse élevée en rapport avec la même région composée d'une seule primitive.

Le principe est identique pour le calcul de la disparité interclasse globale  $\overline{D}(I^j)$  de l'image segmentée  $I^j$  qui mesure la disparité de chaque région avec ses voisines.

## 2.2 Disparité intraclasse

On essaie ici d'évaluer l'homogénéité d'une région, c'est à dire la variation des statistiques à l'intérieur de celle-ci. Dans le calcul de disparité intraclasse, nous prenons en compte la nature de la région segmentée à savoir uniforme au sens des niveaux de gris ou texturée. Pour différencier ces deux types de régions, nous utilisons le paramètre uniforme définit dans [8].

### 2.2.1 Régions uniformes

Dans le cas uniforme, la disparité intraclasse d'une région est donnée par l'écart-type normalisé de celle-ci. Cette statistique d'ordre 2 sur la dispersion des niveaux de gris d'une région est, dans ce cas, suffisante.

<sup>1</sup>Cette notion de disparité intraclasse n'est pas nouvelle, elle a été notamment utilisée dans les méthodes d'agrégation de régions [2].

### 2.2.2 Régions texturées

Si la région est texturée, l'écart-type seul ne donne pas d'information suffisante sur l'homogénéité de celle-ci. Pour estimer l'homogénéité des statistiques au sein de cette région, nous allons utiliser des attributs de texture (attributs de la matrice de cooccurrence, de longueur de plages,...). Ces paramètres sont calculés sur une fenêtre d'analyse balayant la région considérée. La disparité intraclasse de la région va être caractérisée par la dispersion de ces vecteurs d'attributs caractéristiques.

### 2.3 Disparité interclasse

Le procédé de quantification de la disparité interclasse d'une région est similaire à ce qui a été réalisé précédemment. En effet, au lieu d'estimer l'homogénéité d'une région, on calcule sa disparité avec les régions voisines. La disparité interclasse s'écrit dans ce cas, comme la moyenne de la disparité d'une région avec ses voisines.

Il existe deux types de régions dans une image :

- région uniforme,
- région texturée.

Le problème se pose lors du calcul de la disparité interclasse, de quantifier la disparité entre régions de même type et de type différent. Nous abordons dans un premier temps le cas de figure le plus simple.

#### 2.3.1 Disparité entre régions de type différent

Il est clair que la disparité entre une région uniforme et texturée doit être maximale, elle est donc égale à 1 (cette mesure est normalisée).

#### 2.3.2 Disparité entre régions de même type

Le calcul de la disparité entre deux régions de même type est plus délicat. Une région est décrite par la valeur moyenne des statistiques représentatives de la primitive. Ainsi, une région uniforme est décrite par sa moyenne et une région texturée par le vecteur d'attributs moyen, c'est à dire son barycentre. On estime alors la disparité entre deux primitives en considérant l'écart entre ces valeurs moyennes.

Le calcul de la disparité  $D$  entre deux régions uniformes  $R_i$  et  $R_j$  s'effectue de la façon suivante :

$$D(R_i, R_j) = \frac{|E[R_i] - E[R_j]|}{NG}$$

où  $E[R_i]$  est le niveau de gris moyen de la région  $R_i$  et  $NG$  est le nombre de niveaux de gris dans l'image. Cette disparité donne l'estimée de l'écart normalisé entre les niveaux de gris moyens de deux régions uniformes limitrophes. Cette information est suffisante dans la mesure où une région uniforme a, en général, une moyenne constante.

La disparité entre deux régions texturées  $R_i$  et  $R_j$  se calcule de la façon suivante :

$$D(R_i, R_j) = \frac{d(B_i, B_j)}{\|B_i\| + \|B_j\|}$$

où  $d(.,.)$  est la distance euclidienne et  $B_i$  est le barycentre de la région  $R_i$ .

On note  $\mathcal{V}_i = \{R_1, \dots, R_{q(i)}\}$  l'ensemble des régions voisines de  $R_i$ . La disparité interclasse de cette région s'exprime sous la forme :

$$\bar{D}(R_i) = \frac{1}{q(i)} \sum_{j=1}^{q(i)} D(R_i, R_j)$$


Suivant le type de primitive de chaque région, on adapte le calcul de la dissimilarité en fonction du contexte. La disparité interclasse d'une région exprime la dissimilarité moyenne des statistiques d'une région avec ses voisines.

### 2.4 Validation du critère

Avant d'utiliser ce critère d'évaluation proposé dans l'algorithme génétique, comme fonction d'aptitude, nous avons cherché à le valider. Afin de vérifier sa cohérence, nous le comparons au taux de bonne classification de résultats de segmentation pour des images dont la vérité de terrain est connue.

Nous avons comparé 10 résultats de segmentation de 5 images synthétiques dont les régions sont connues *a priori* (cf. Figure 1). Ces résultats ont été obtenus par classification à partir d'attributs en faisant varier la taille du support d'analyse et le type d'attributs. Ces 5 images comportent des types de régions relativement différents (régions faiblement bruitées, fortement et faiblement texturées).

Figure 1: Images synthétiques utilisées pour la validation du critère d'évaluation



Le tableau Table 1 récapitule la valeur du critère pour chaque résultat de segmentation ainsi que le taux de bonne classification associé. Si l'on analyse les variations du critère d'évaluation et du taux de bonne classification, on remarque qu'elles sont cohérentes les unes par rapport aux autres. En effet, si un résultat de segmentation est meilleur qu'un autre au sens du taux de bonne classification, il l'est aussi en considérant la valeur du critère d'évaluation. Certes, la variation du critère d'évaluation n'est pas proportionnelle à celle du taux de bonne classification.

Table 1: Comparaison entre le critère d'évaluation proposé et le taux de bonne classification des résultats de segmentation d'images de la figure Figure 1.

Résultat	$\underline{D}(I)$	$\overline{D}(I)$	Critère	Taux
résultat 1 de $I_1$	0.26	0.92	0.88	41.6%
résultat 2 de $I_1$	0.04	0.80	0.92	58.2%
résultat 1 de $I_2$	0	0.61	0.87	86.2%
résultat 2 de $I_2$	0.28	0.63	0.78	73%
résultat 1 de $I_3$	0.31	0.81	0.83	78.8%
résultat 2 de $I_3$	0.68	0.8	0.7	54.6%
résultat 1 de $I_4$	0.52	0.67	0.71	20.8%
résultat 2 de $I_4$	0.37	0.59	0.73	44%
résultat 1 de $I_5$	0.58	0.95	0.68	75%
résultat 2 de $I_5$	0.16	0.73	0.85	93.8%

### 3 Résultats expérimentaux

La figure 2 présente le résultat de fusion de plusieurs résultats de segmentation de deux images. Les résultats de segmentation ont été obtenus par classification à partir des attributs moyenne et variance pour différentes tailles d'analyse et différents nombres de classes. Le résultat final combine bien toutes les informations contenues dans les différents résultats de segmentation.

Nous avons comparé l'efficacité des différents opérateurs de reproduction d'un algorithme génétique à savoir le mode élitiste et le tournoi. Les résultats obtenus sont identiques en terme de valeur optimale du critère obtenu mais le mode tournoi permet un accroissement significatif de la vitesse de convergence.

### 4 Conclusion et Perspectives

Nous avons montré dans cette communication, l'intérêt de la fusion de résultats de segmentation basée sur l'optimisation d'un critère de qualité. Nous envisageons de développer une version supervisée de cette méthode afin d'intégrer dans le critère un terme d'attache à des connaissances *a priori* telle qu'une vérité terrain locale.

### References

[1] I. Bloch. Information combination operators for data fusion : a comparative review with classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 1996.

[2] J. P. Cocquerez and S. Philipp. *Analyse d'images : filtrage et segmentation*. Masson, 1995.

[3] R. Kara falah and Ph. Bolon. Une technique d'intégration des résultats en segmentation d'images. In *GRETI*, volume 2, pages 573–576, JUAN-LES-PINS, September 1995.

[4] R.M. Haralick. Statistical and structural approaches to texture. In *proceedings of the IEEE*, volume 69, pages 786–804, May 1979.

[5] S. Houzelle. *Extraction automatique d'objets cartographiques par fusion d'informations extraites d'images satellites*. PhD thesis, Telecom Paris, January 1993.

[6] J. Laferte. *Contribution à l'analyse d'images par modèles markoviens sur des graphes hiérarchiques. Application à la*

*fusion de données multi-résolution*. PhD thesis, université de Rennes 1, October 1996.

[7] V. Lefevre and Y. Pollet. Bbi : Un système multi-agents pour la fusion de données multi-capteurs. In *Avignon*, May 1993.

[8] C. Rosenberger. *Mise en oeuvre d'un système adaptatif de segmentation d'images*. PhD thesis, Université de Rennes I, December 1999.

[9] P. Wall. *A Genetic Algorithm for Resource-Constrained Scheduling*. PhD thesis, MIT, 1996.

[10] Y.J. Zhang. A survey on evaluation methods for image segmentation. In *Computer Vision and Pattern Recognition*, volume 29, pages 1335–1346, 1996.

Figure 2: Fusion de résultats de segmentation d'images

