

Segmentation non supervisée d'images angiographiques de la rétine par le système de Pearson et le rééchantillonnage bootstrap

AHLEM BOUGARRADH, SLIM MHIRI, FAOUZI GHORBEL

Groupe de recherche Images et Formes de Tunisie (GRIFT), Laboratoire CRISTAL
Ecole Nationale des Sciences Informatiques (ENSI) Campus Universitaire de Manouba, 2010 Tunisie

Ahlem.Bougarradh@gmail.com, Slim.Mhiri@ensi.rnu.tn, Faouzi.Ghorbel@ensi.rnu.tn

Résumé - Dans ce papier, nous présentons une méthode de segmentation rapide d'images. Cette méthode combine à la fois la robustesse de la classification bayésienne, l'efficacité des algorithmes d'identification de mélanges particulièrement dans le cadre du système de Pearson et la pertinence de l'échantillonnage bootstrap qui permet de s'affranchir de la complexité en temps de calcul des algorithmes de segmentation bayésienne. Dans ce cadre, nous proposons un critère expérimental de la représentativité de l'échantillon pour l'utilisation de la technique du bootstrap dans l'estimation des mélanges généralisés. Cette méthode est appliquée au problème de la segmentation d'images dans une séquence d'angiographie rétinienne qui présente un bruit non gaussien et là où le temps de calcul est un critère déterminant pour le choix de la méthode de segmentation, attestant de son intérêt dans une situation réelle. Le résultat de segmentation obtenu avec rééchantillonnage bootstrap est comparable à celui obtenu dans le cas classique avec toutefois une réduction significative des temps de calcul.

Abstract - In this paper, we present a method for fast image segmentation. This method combines the robustness of Bayesian classification, the efficiency of the Expectation Maximization algorithms for identifying mixtures particularly under the Pearson system and the bootstrap resampling. In this context, we propose an experimental criterion of representativity of the sample using the technique of bootstrap in the estimation of generalized mixtures. This method is applied to the problem of segmentation of images in a sequence of retinal angiography which is corrupted by a non-Gaussian noise and where the computation time is a criterion for choosing the method of segmentation. The result of segmentation obtained with the bootstrap resampling is quite the same compared to the one obtained in the classical case but with a significant reduction in time computing.

1 Introduction

Nous nous intéressons dans cet article à la segmentation statistique non supervisée d'images avec le modèle de mélange généralisé. Dans un premier temps nous proposons une méthode originale d'estimation des paramètres d'un mélange généralisé en combinant l'algorithme Estimation Maximisation Généralisé EMG [1] avec le principe de rééchantillonnage Bootstrap [3]. Ensuite, nous proposons de déterminer empiriquement la taille optimale de l'échantillon bootstrap qui va nous permettre de réduire considérablement le temps de calcul tout en conservant la qualité de l'estimation. Par une étude de simulations, nous montrons le bon comportement de la méthode proposée même dans des cas d'images fortement bruitées. Cette même méthode est appliquée au problème de la segmentation d'images dans une séquence d'angiographie rétinienne qui présente un bruit non gaussien et là où le temps de calcul est un critère déterminant pour le choix de la méthode de segmentation, attestant de son intérêt dans une situation réelle.

L'approche statistique en segmentation d'images suivie dans ce travail est la suivante : on considère deux processus aléatoires $X = (X_s)_{s \in S}$ et $Y = (Y_s)_{s \in S}$, où S est l'ensemble des pixels. Chaque X_s est à valeurs dans un

ensemble fini de classes $\Omega = \{\omega_1, \dots, \omega_K\}$ et chaque Y_s est une variable aléatoire réelle. L'image que l'on observe est vue comme une réalisation y du champ Y et la segmentation devient un problème d'estimation de la réalisation inobservable x de X à partir des données observables Y . Dans une approche locale, la segmentation se base sur la classification bayésienne qui présente l'avantage de l'optimalité dans le sens de la maximisation des probabilités a posteriori et donc de la minimisation de la probabilité de l'erreur de classification. Dans un cadre concret de classification, ces probabilités ne sont pas connues, et le problème de classification devient un problème d'estimation de paramètres de mélange fini de lois. Les paramètres sont estimés par des méthodes générales de type "Expectation-Maximisation" [2] ou par l'une de ses variantes stochastiques SEM, SAEM [5].

Ces méthodes supposent que la fonction densité de probabilité des données est une combinaison linéaire d'un nombre fini de distributions gaussiennes. Cependant, dans plusieurs cas, cette hypothèse s'avère inadéquate. Plusieurs études ont montré l'intérêt d'une modélisation non gaussienne pour la segmentation de plusieurs types d'images. Dans la littérature, l'algorithme "EM Généralisé" (EMG) [1], peut être une bonne alternative pour surmonter ce problème.

Cette généralisation présente le problème de la lenteur en temps de calcul comme l'algorithme « EM », ce qui la rend inutilisable dans des applications quasi temps réel. L'algorithme EMG qui permet de donner des solutions au maximum de vraisemblance requière aussi une indépendance de l'échantillon issu de l'image.

Pour pallier ces limitations, se basant sur nos anciens travaux [2], l'introduction du rééchantillonnage Bootstrap dans l'algorithme EMG pour la segmentation d'images va présenter deux intérêts. Le premier, va nous permettre une meilleure approximation de la vraisemblance et donc une meilleure estimation des paramètres du mélange en sélectionnant aléatoirement un échantillon indépendant des pixels de l'image. En plus, l'estimation des paramètres du mélange à partir de cet échantillon représentatif de faible taille (au lieu de considérer toute l'image) va nous permettre une réduction considérable des temps de calcul.

La section 2 décrit le modèle généralisé, la section 3 présente l'algorithme EMG bootstrappé, la section 4 montre l'application de l'algorithme pour la segmentation d'images angiographiques. Enfin, la section 5 conclut l'article.

2 Modèle généralisé

La modélisation statistique d'images suppose qu'une image est une réalisation d'un mélange de lois. Ainsi sa densité de probabilité est approchée par :

$$f(y) = \sum_{j=1}^K f(y, \theta_j) \pi_j \quad (1)$$

π_j est la probabilité à priori de la classe j , $f(y, \theta_j)$ est la densité de probabilité conditionnelle de la classe j et K est le nombre de classes. Dans ce travail, nous supposons que la probabilité conditionnelle à la classe j appartient à la famille des distributions du système de Pearson. Ce système [6] permet de décrire huit familles de distributions incluant la gaussienne, la gamma et la distribution beta de première espèce en se limitant au calcul de quelques paramètres qui sont la moyenne ($\mu_1 = E(Y)$) et les moments centrés ($\mu_k = E(Y - E(Y))^k$) avec $k = 2, 3, 4$ et Y est une variable aléatoire réelle. Toute distribution du système de Pearson est identifiée dans le graphe de Pearson [ref] par le couple de coefficients $(\beta_1, \beta_2) = ((\mu_3)^2 / (\mu_2)^3, \mu_4 / (\mu_2)^2)$ connu sous l'appellation de (skewness, kurtosis). Ces paramètres décrivent respectivement l'asymétrie et l'aplatissement d'une distribution. Ce système offre une diversité de formes autre que la forme d'une distribution gaussienne. Chaque type de distribution est localisé d'une manière précise dans ce graphe

Dans ce papier nous proposons d'utiliser l'algorithme EM non gaussien ou généralisé (EMG) pour l'identification des paramètres de mélanges non gaussien. Cet algorithme utilise la famille de distributions du système de Pearson.

La particularité de l'algorithme EMG par rapport au cas Gaussien consiste en l'estimation des moments centrés d'ordre supérieur 3 et 4 en plus de la moyenne ($\mu = \mu_1$) et variance ($\sigma^2 = \mu_2$). Ces moments servent au calcul des paramètres Skewness et Kurtosis afin de sélectionner la distribution adéquate parmi toutes les distributions présentes dans le système de Pearson dans sa phase d'estimation.

3 Estimation de mélanges avec l'algorithme estimation maximisation généralisé Bootstrappé (EMGB)

3.1 La technique du rééchantillonnage bootstrap

L'échantillonnage Bootstrap consiste à faire n tirages aléatoire d'une observation Y_i^* suivant une loi empirique marginale monodimensionnelle définie sur l'ensemble Y des observations de l'image, ce qui correspond à un tirage suivant une loi uniforme (avec remise) d'une observation parmi les N qui constituent l'image initiale. En suivant ce principe nous arrivons à construire un nouvel ensemble d'observations noté $Y^* = (Y_1^*, \dots, Y_n^*)$ qui constitue l'échantillon Bootstrap de l'image. La taille de l'échantillon Bootstrap représentatif de l'image est calculée suivant les critères de représentativité définis dans un cas gaussien [1].

3.2 Description de l'algorithme EMGB

L'algorithme estimation maximisation généralisé bootstrappé EMGB consiste à combiner l'algorithme d'estimation maximisation généralisé EMG avec un rééchantillonnage bootstrap issu de l'image.

L'algorithme Bootstrappé se résume comme suit :

Etant donné un échantillon bootstrap Y^* issu de l'image originale Y . Après l'étape d'initialisation qui est obtenue à partir de l'histogramme de l'image, les deux étapes estimation et maximisation sont itérés jusqu'à la convergence de l'algorithme.

Etape d'estimation: Elle comporte le calcul de la probabilité a posteriori pour que le pixel y_i^* appartient à la classe k à l'itération q . La densité de probabilité conditionnelle f_k adéquate pour cette phase est sélectionnée parmi les distributions du système de Pearson. La probabilité a posteriori est donnée par l'équation suivante :

$$\forall i \in S, \forall k \in \{1..K\} \quad \pi_{ik}^{(q)} = \frac{\pi_k^{(q-1)} f_k(y_i^* | \theta_k^{(q-1)})}{\sum_{l=1}^K \pi_l^{(q-1)} f_l(y_i^* | \theta_l^{(q-1)})} \quad (2)$$

Etape de Maximisation: à l'itération q, les différents paramètres : poids π_k , moyenne μ_1 et moments centrés d'ordre 2, 3 et 4 (μ_2, μ_3, μ_4) sont mis à jour comme suit :

$$\forall k \in \{1..K\} \quad \pi_k^{(q+1)} = \frac{\sum_{i=1}^N \pi_{ik}^{(q)}(y_i^*)}{N} \quad (3)$$

$$\forall k \in \{1..K\} \quad \mu_{1,k}^{(q+1)} = \frac{\sum_{i=1}^N \pi_{ik}^{(q)}(y_i^*) y_i^*}{\sum_{i=1}^N \pi_{ik}^{(q)}(y_i^*)} \quad (4)$$

$$\forall k \in \{1..K\} \quad \mu_{j,k}^{(q+1)} = \frac{\sum_{i=1}^N \pi_{ik}^{(q)}(y_i^*) (y_i^* - \mu_{1,k}^{(q+1)}) (y_i^* - \mu_{1,k}^{(q+1)})^j}{\sum_{i=1}^N \pi_{ik}^{(q)}(y_i^*)} \quad (5)$$

3.3 Simulation

Dans un cadre Gaussien, pour l'utilisation de l'algorithme EM avec la technique de rééchantillonnage Bootstrap, deux critères de représentativité de l'échantillon ont été définis [2,4]. Ces critères déterminent la taille optimale de l'échantillon bootstrap assurant une bonne qualité d'estimation. Une large étude expérimentale nous a montré que l'utilisation de ces critères dans le cadre de l'algorithme EMGB ne permet pas d'avoir une qualité d'estimation acceptable (Figure1). En effet, ceci peut s'expliquer par le fait que dans le cadre généralisé, nous estimons des moments d'ordre supérieurs par rapport au cas Gaussien, ce qui requiert plus d'échantillons. Afin de déterminer un ordre de grandeur de la taille de l'échantillon bootstrap nécessaire pour une bonne estimation des paramètres de mélange, nous avons procédé à une variation linéaire de la taille de l'échantillon en calculant à chaque fois l'erreur quadratique moyenne intégrée EQMI. Une étude empirique est menée à la base de simulations de mélanges non Gaussien (en modifiant à chaque fois le nombre de classes d'une part et la nature des distributions d'autre part) montre que la courbe de l'erreur quadratique moyenne intégrée EQMI (Figure2) en fonction de la taille de l'échantillon bootstrap ($x \cdot K$, x est un entier supérieur à 5) diminue significativement lorsque x augmente et elle devient presque constante à partir d'une certaine valeur de $x = x_0$. L'étude expérimentale menée montre que cette valeur de x_0 est autour de 13. Néanmoins on peut penser à affiner notre recherche pour trouver une taille optimale selon le type d'image étudiée.

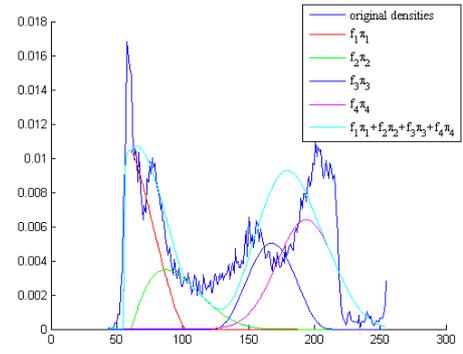


Figure 1: Estimation des densités du mélange avec une taille d'échantillon bootstrap égale à 5K

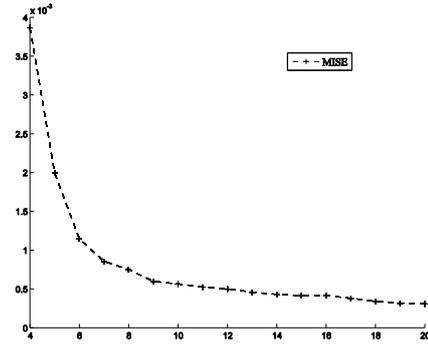


Figure 2: EQMI

4 Segmentation d'images angiographiques

La méthode de segmentation en utilisant l'algorithme EMGB a été validé sur un grand nombre d'images de synthèses (en modifiant à chaque fois le nombre de classes d'une part et la nature des distributions d'autre part). Les résultats obtenus montrent une conservation de la qualité d'estimation des paramètres de mélanges avec une réduction considérable des temps de calculs. Nous avons aussi appliqué cette méthode dans le cadre de la mesure de l'activité de la fuite dans la chorio-rétinopathie séreuse centrale. Cette application passe par la segmentation des images d'une séquence d'angiographie rétinienne. Nous montrons les résultats de la segmentation non supervisée de deux images angiographiques rétiniennes de taille 1280*1024 issues de cette séquence (Figure 3 et 4). En l'absence de la vérité terrain, ces résultats sont comparés à ceux obtenus à partir du modèle classique. En effectuant des zooms sur certaines zones, nous remarquons que beaucoup de détails sont conservés par la nouvelle méthode. Ce fait peut s'expliquer par la définition de la méthode de rééchantillonnage bootstrap. Cette méthode permet de diminuer la dépendance au sein de l'échantillon et par conséquent d'appliquer l'estimateur du maximum de vraisemblance dans les conditions d'indépendance meilleures. Ce qui au niveau de la qualité subjective de la segmentation donne des résultats meilleurs.

Nous avons montré que la taille de l'échantillon bootstrap nécessaire pour l'estimation est supérieure à celle obtenue dans un cadre Gaussien. Toutefois, cette taille permet de réduire considérablement les temps de calculs requis pour la segmentation par l'algorithme EMGB. (92s pour la segmentation avec échantillonnage bootstrap contre 3937s sans échantillonnage bootstrap pour l'image présentée dans la figure 1(a) en utilisant un P4 avec une fréquence de processeur de 2Ghz).

5 Conclusion

Dans ce papier, nous avons proposé l'algorithme d'estimation par maximisation généralisée bootstrappée BGEM en vue d'une segmentation rapide d'images issues d'une séquence angiographique de la rétine. Les résultats obtenus prouvent qu'un échantillon Bootstrap provenant de l'image originale permet d'obtenir une même qualité de segmentation qu'en traitant toute l'image. Ce résultat est accompagné par une réduction considérable des temps de calcul.

6 Références

[1] Delignon Y., Marzouki A., and Pieczynski W.; Estimation of Generalised Mixture and Its Application

in Image Segmentation, IEEE Transactions on Image Processing, Vol. 6, N 10, pp. 1364-1375, 1997.

[2] Dempster A., Laird N. and Rubin D.; Maximum Likelihood from Incomplete Data via the EM Algorithm. Journal of Royal Statistical Society, Series B, Vol. 39, pp. 1-38, 1977.

[3] Ghorbel F. and Banga C. ; Bootstrap sampling applied to image analysis, invited paper, special session, IEEE-ICASSP, Adelaide, South Australia, Vol. 6, pp. VI 81-84, 1994.

[4] Mhiri S, Cammoun L. and Ghorbel F., Speeding up HMRF EM algorithms for fast unsupervised image segmentation by Bootstrap resampling: Application to the brain tissue segmentation. J. Signal Processing 87 (2007), pp 2544-2559.

[5] Zhang Y.J., Evaluation and comparison of different segmentation algorithms, Pattern Recognit. Lett. 18 (1997), pp 963-974.s.

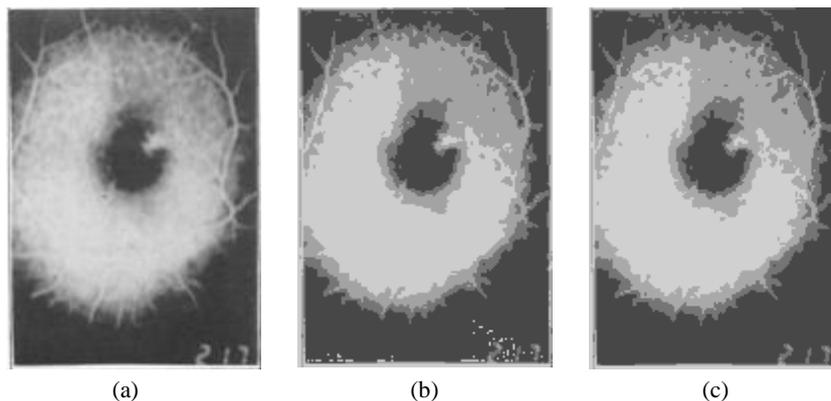


Figure 3: (a) Image originale, (b) segmentation de l'image (a) sans échantillonnage bootstrap, (c) segmentation de l'image (a) avec échantillonnage bootstrap

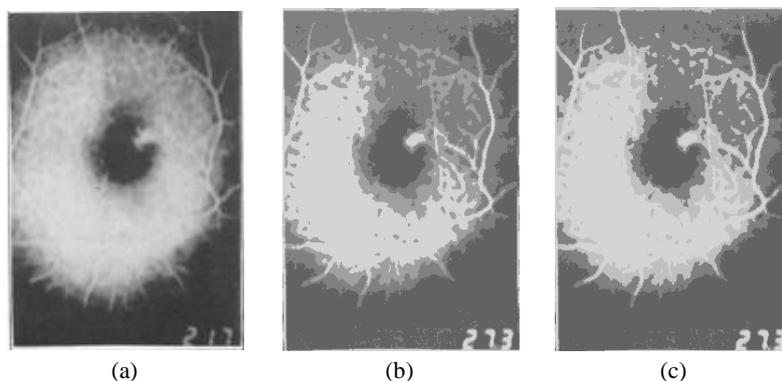


Figure 4: (a) Image originale, (b) segmentation de l'image (a) sans échantillonnage bootstrap, (c) segmentation de l'image (a) avec échantillonnage bootstrap