

Exploitation des relations qualitatives topologiques et photométriques a priori pour le seuillage d’images en niveaux de gris par *k-means*

Jean-Baptiste Fasquel, Nicolas Delanoue
Laboratoire d’Ingénierie des Systèmes Automatisés
62 avenue Notre-Dame du Lac, 49000 Angers, France

Jean-Baptiste.Fasquel@univ-angers.fr, Nicolas.Delanoue@univ-angers.fr

Résumé – Cette communication porte sur l’utilisation de relations qualitatives topologiques et photométriques a priori connues entre les régions d’une image pour paramétrer l’algorithme des *k-means*. On considère un processus d’analyse séquentiel où chaque région est segmentée par une chaîne de traitement dédiée incluant une étape de seuillage par *k-means*. Nous proposons de traduire les connaissances a priori et celles des régions déjà segmentées en contraintes sur les paramètres du *k-means* (région d’intérêt, nombre de classes et initialisation des graines) et en illustrons les bénéfices sur deux images réelles. Les résultats présentés montre le fort potentiel de cette approche, bien que son efficacité dépende de la stratégie de segmentation. Par exemple, pour les images traitées, les contraintes d’initialisation des *k-means* permettent d’obtenir des taux de bonne classification de 62.5% et 93.1%, contre seulement 19.6% et 65.5% avec la méthode d’initialisation aléatoire classique. On observe également une réduction significative du nombre d’itérations, et une augmentation de la fiabilité de l’initialisation.

Abstract – This paper concerns the exploitation of a priori known topological and photometric relationships between image regions for the parameterization of *k-means*. We consider a sequential image processing procedure, where each region is segmented using a dedicated processing line including a *k-means*-based thresholding step. We explain how a priori knowledge, together with the one of already segmented regions, can be translated into parameters (region of interest, number of cluster and seeding constraints), and illustrate benefits on two real images. Results show the potential of this approach, although its efficiency depends on the segmentation strategy. For instance, for considered situations, seeding constraints enable to obtain a good classification rate of 62.5% and 93.1%, instead of only 19.6% and 65.5% with classical random seeding. One also observes a significant reduction of the required number of iterations, as well as an improvement of the seeding reliability.

1 Introduction

L’algorithme des *k-means* est largement utilisé pour le partitionnement non supervisé de données [1], et plus particulièrement pour segmenter une image par seuillage de son histogramme [2]. La difficulté concerne la définition du nombre de partitions (classes ou clusters) et l’initialisation de la procédure (placement des graines matérialisant les centres initiaux des partitions). La méthode couramment employée consiste à évaluer le partitionnement obtenu pour différents jeux de paramètres (initialisations aléatoires pour différents nombres de partitions) et à retenir celui optimisant un critère donné. Typiquement, on cherche à minimiser le moment d’inertie, ce qui ne conduit pas toujours au partitionnement souhaité [1]. Pour contourner cette limitation, nous proposons d’exploiter les connaissances qualitatives a priori sur le contenu d’une image en niveaux de gris, en terme de relations d’inclusion et d’intensité moyenne entre les différentes régions d’une image (voir Figures 1-droite et 2). Ce type d’approche est encore peu considéré en traitement d’images [3, 4], et les rares exemples se focalisent sur l’exploitation de relations spatiales [3, 4, 5]. Les connaissances qualitatives sont reconnues comme étant plus simples à construire et plus génériques que les connaissances quantitatives (e.g. modèles statistiques) classiquement considérées en traitement d’images [3, 4]. La contre-partie est la difficulté de lier ces informations (*qualitatives*) disponibles à haut-

niveau aux paramètres (*quantitatifs*) des algorithmes de traitement à bas-niveau. Nous proposons ici d’exploiter ces connaissances qualitatives dans le cadre réaliste d’une procédure de traitement séquentielle (voir Figure 1-gauche) : chaque région est supposée être segmentée par une chaîne de traitement spécifique, en commençant par les régions les plus “simples” à extraire, sur lesquelles on peut ensuite s’appuyer pour segmenter les plus difficiles [3]. La partie 2 décrit l’approche proposée, tandis que la partie 3 illustre les bénéfices.

2 Méthode

On suppose qu’une région $X(u)$ de l’image I est associée à une étiquette $u \in S$ ($S = \{0, 1, 2, 3\}$ dans la Figure 2 et $S = \{0, 1, 2\}$ dans la Figure 1). Les relations topologiques d’inclusion entre les régions sont représentées par un graphe topologique orienté $G_T = (S, A_T)$, tel que :

$$X(i) \subset X(j) \Leftrightarrow i \xrightarrow{T} j \quad (1)$$

Les relations photométriques sont représentées par le graphe photométrique $G_P = (S, A_P)$, tel que :

$$\bar{X}_r(i) < \bar{X}_r(j) \Leftrightarrow i \xrightarrow{P} j \quad (2)$$

où $\bar{X}_r(i)$ désigne l’intensité moyenne du résidu de la région $X(i)$ (i.e. région $X(i)$ privée des régions incluses). Les arêtes

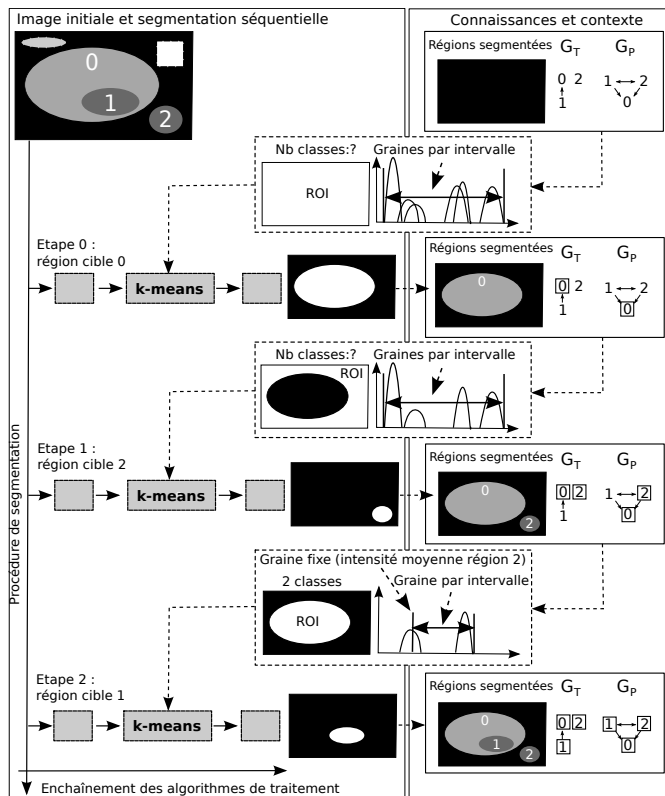


FIGURE 1 – Principe de l’approche proposée. Gauche : les régions sont segmentées séquentiellement (regions 0, 2 et enfin 1). Chaque étape peut comprendre une seuillage par *k-means*, ainsi que des pré et post traitements. Droite : Connaissances *a priori* (partielles) impliquant 3 régions ($S = \{0, 1, 2\}$), dont les relations topologiques et photométriques sont modélisées par G_T et G_P . Par exemple, “la région 1 est incluse dans la région 0” ($1 \rightarrow 0$ in G_T), “les régions 1 et 2 ont des intensités moyennes similaires, et plus sombres que celle de la région 0” ($1 \leftrightarrow 2$, $1 \rightarrow 0$ and $2 \rightarrow 0$ in G_P). Les noeuds entourés indiquent les régions segmentées (S_t). Les paramètres des *k-means* sont détaillés pour l’étape 2.

orientées dans les deux sens indiquent que les résidus des régions associées ont une intensité moyenne similaire.

La notion de processus séquentiel de traitement est associée à l’indice t affecté aux différentes entités S_t et $X_t(u)$. En particulier, $S_t \subset S$ désigne l’ensemble des régions déjà segmentées (si $u \in S_t$, alors $X_t(u) = X(u)$ sinon $X_t(u) = \emptyset$), matérialisé par les noeuds et régions entourés dans la Figure 1-droite.

Supposons qu’à un instant t un utilisateur souhaite segmenter une (ou plusieurs) nouvelle(s) région-cible(s) (e.g. région 1 à l’instant 2 dans la Figure 1).

A partir des connaissances *a priori*, des régions déjà segmentées à l’instant t et de la cible à segmenter, on peut automatiquement déterminer les paramètres des *k-means*, à savoir la région d’intérêt (i.e. ensemble des points concernés par le *clustering*), le nombre de classes et les contraintes d’initialisation des graines. Sans détailler les relations, nous donnons ci-après les règles de détermination de ces paramètres.

La région d’intérêt est la région segmentée (région mère) contenant directement la cible (i.e. la plus proche de la cible $G_{T,t}$), en retirant toutes les régions segmentées (à l’exception de celle contenant la cible).

Le nombre de classes (2 classes dans le cas de la Figure 1-étape 2) correspond au nombre de régions non segmentées de la ROI et d’intensités moyennes distinctes.

Pour l’initialisation, la graine associée à chaque classe correspondra à une valeur fixe s’il existe une région segmentée déclarée comme ayant une intensité similaire, et ne contenant pas directement de régions non segmentées : la valeur sera alors l’intensité moyenne du résidu de cette région (cas de la *graine fixe* dans la Figure 1-étape 2). Dans le cas contraire, la graine sera choisie aléatoirement dans le plus petit intervalle borné par les intensités moyennes des résidus des régions entièrement segmentées, déclarées plus sombres et plus claires (cas de la *graine par intervalle* dans la Figure 1-étape 2).

Notons que ces règles s’appliquent si le contenu de toute région (déclarée) est renseigné. Par ailleurs, la région mère associée à la ROI doit être définie dans le graphe. Dans le cas contraire, la ROI est l’image entière (étape 0 dans la Figure 1), ou l’image entière privée des régions déjà segmentées (étape 1 dans la Figure 1). Par ailleurs, le nombre de classes devient inconnu et l’initialisation non contrainte (méthode classique par défaut).

3 Expériences

Le Tableau 1 et la Figure 3 résument les résultats de segmentation du contenu des régions 2 de la Figure 2 (les cibles sont les régions 3 et 4). Le critère de minimisation du moment d’inertie a été considéré pour évaluer la qualité du *clustering*. On considère la situation où seule la région 2 est préalablement segmentée ($S_t = \{2\}$), ainsi que celle où les régions 0, 1 et 2 sont déjà segmentées ($S_t = \{0, 1, 2\}$). L’image médicale, comprenant 129 coupes de taille 512×512 pixels, a été traitée en 3D (voir les maillages des vaisseaux segmentés - Figure 3),

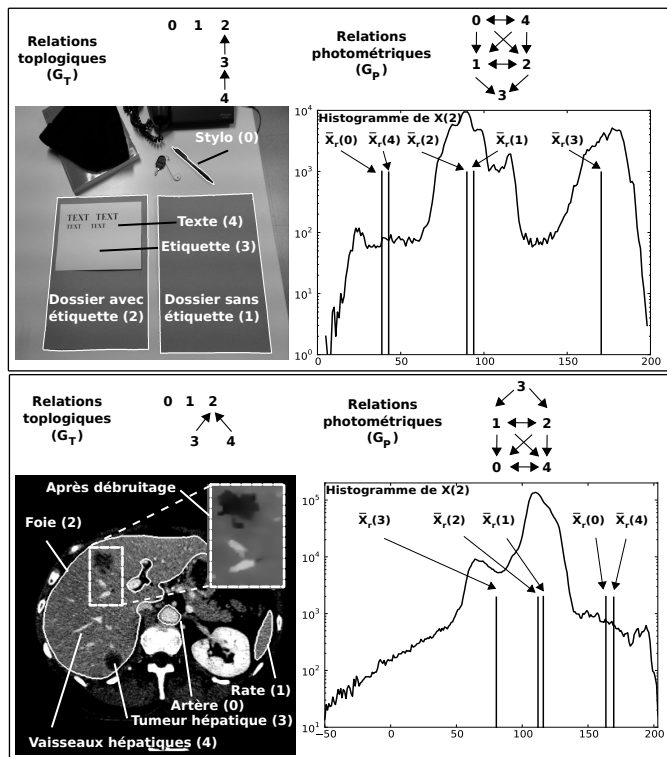


FIGURE 2 – Exemples de connaissances topologiques et photométriques *a priori*. Image naturelle (haut) : la scène comprend en particulier un stylo et deux dossiers, dont un avec un texte écrit sur une étiquette. Les deux dossiers sont composés du même matériau de teinte grise, plus sombres que l'étiquette (blanche), et plus clairs que le stylo et le texte (de teintes similaires noires). Image médicale (bas) : le foie du patient comprend des tumeurs hépatiques hypodenses (plus sombre que le tissu hépatique). Suite à l'injection d'un produit de contraste, le réseau vasculaire (vaisseaux hépatique et artère) apparaît plus clair que les tissus sains constitutifs du foie et de la rate (densité moindre). Les graphes modélisent les relations topologiques d'inclusion (G_T) et photométriques (G_P) entre les régions. Les histogrammes des régions 2 sont donnés, avec les intensités moyennes des résidus des différentes régions ($\bar{X}_r(i)$) : on observe la cohérence entre les connaissances photométriques *a priori* (G_P) et les données numériques.

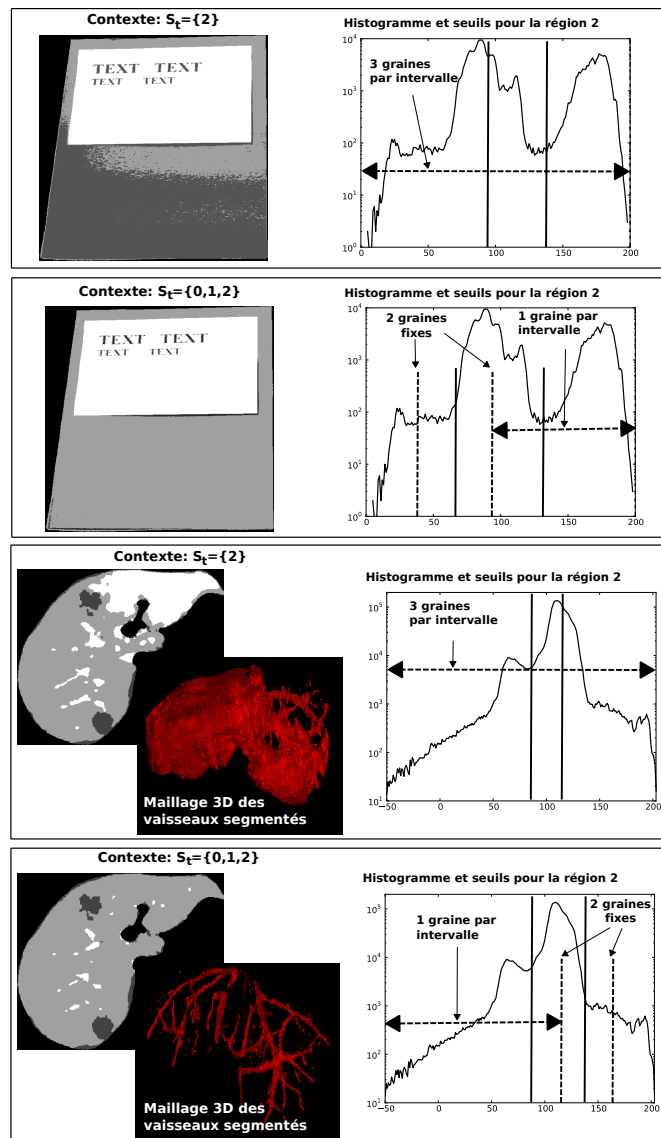


FIGURE 3 – Segmentations des régions 2 obtenues pour différents contextes ($S_t = \{2\}$ et $S_t = \{0,1,2\}$) et donc différentes contraintes d'initialisations. Les histogrammes (réduits à la ROI et en échelle logarithmique) indiquent les seuils et les contraintes (graines fixes ou choisies aléatoirement dans un intervalle).

TABLE 1 – Résultat obtenu (200 initialisations aléatoires). Les valeurs numériques indiquées sont le taux de bonne classification (TBC) avec l’inertie associée, le nombre moyen d’itérations (et écart-type associé), et le taux de bonne initialisation (TBI). La Figure 3 donne les images segmentées pour chaque image pour $S_t = \{2\}$ et $S_t = \{0, 1, 2\}$.

Image naturelle			
S_t	TBC en % (inertie)	Itérations	TBI en %
$\{2\}$	19.6 (24.0×10^6)	8.2 (3.0)	39.5
$\{0, 1, 2\}$	62.5 (30.6×10^6)	4.7 (0.7)	100.0
Image médicale			
S_t	TBC en % (inertie)	Itérations	TBI en %
$\{2\}$	65.5 (22.9×10^7)	22.9 (5.0)	12.5
$\{0, 1, 2\}$	93.1 (27.7×10^7)	15.7 (2.0)	100.0

après préfiltrage par diffusion anisotrope (voir Figure 2). Les TBCs ont été calculés par comparaison avec les segmentations manuelles. Le taux de bonne initialisation (TBI) représente le taux d’initialisation conduisant au résultat retenu (inertie minimale), son complément indiquant le risque ou la probabilité de mal initialiser. Pour $S_t = \{2\}$, nous sommes proche de la méthode classique qui consiste à tester plusieurs initialisations choisies aléatoirement dans la ROI, et à retenir le résultat correspondant au meilleur *clustering*, au sens du critère de qualité choisi. La différence par rapport à l’approche classique est que le nombre de classes est connu, ce qui n’est pas nécessairement le cas en pratique. Les résultats obtenus montrent l’apport significatif des contraintes d’initialisation, en terme de performance et de nombre d’itérations. Notons que ces performances sont obtenues pour une inertie pourtant supérieure. L’information qualitative introduite conduit à réduire l’espace de recherche, permettant ainsi de converger vers les minima (locaux) appropriés en ignorant d’autres minima pourtant inférieurs (globaux), mais violant les contraintes imposées par les graphes. Enfin, les TBI à 100% montrent que les contraintes garantissent, dans ces cas, une initialisation systématiquement pertinente, et donc d’une fiabilité parfaite, et ceci malgré l’aléa correspondant au choix aléatoire, dans intervalle réduit, d’une des 3 graines. Outre l’amélioration de la fiabilité, ceci peut également permettre de réduire le temps de calcul puisque le nombre d’initialisation peut être réduit.

4 Conclusion

D’après les exemples considérés, l’approche proposée semble présenter un fort potentiel.

Il faut néanmoins souligner que les bénéfices dépendent directement de la stratégie de segmentation. Celle-ci doit être choisie de manière à maximiser les contraintes d’initialisation pour les régions les plus "complexes".

Concernant les connaissances *a priori*, celles-ci peuvent être définies soit par observation d’un ensemble d’images de l’ap-

plication considérée, soit par la connaissance des propriétés physiques de la scène (e.g. densité des tissus) et du système d’imagerie.

A notre avis, l’utilisation de relations photométriques, plutôt que de valeurs absolues résultant d’un apprentissage statistique, permet d’être moins sensible à la procédure d’acquisition (e.g. dynamique de l’imageur, ou variations des conditions d’éclairage) et/ou aux variations de caractéristiques physiques (variabilité inter-patient de la densité des tissus). Les similarités photométriques sous entendent une certaine imprécision. Par exemple, les tissus de la rate et du foie sont déclarés similaires bien que les intensités moyennes mesurées soient numériquement distinctes. Les résultats présentés montrent néanmoins que l’algorithme bas-niveau peut compenser cette imprécision faite à haut-niveau, du fait du partitionnement itératif (recalcul des centres des partitions et repartitionnement).

Références

- [1] L. Vendramin and Ricardo Jose Gabrielli Barreto Campello and Eduardo R. Hruschka, *Relative clustering validity criteria : a comparative overview*, Statistical Analysis and Data Mining, 2010
- [2] S.H. Kwon, *Threshold selection based on cluster analysis*, Pattern Recognition Letters, 2004
- [3] C. Hudelot and J. Atif and I. Bloch, *Fuzzy spatial relation ontology for image interpretation*, Fuzzy Sets and Systems, 2008
- [4] A. Deruyver and Y. Hodé, *Qualitative spatial relationships for image interpretation by using a conceptual graph*, Image and Vision Computing, 2009
- [5] J.-B. Fasquel and V. Agnus and J. Moreau and L. Soler and J. Marescaux, *An interactive medical image segmentation system based on the optimal management of regions of interest using topological medical knowledge*, Computer Methods and Programs in Biomedicine, 2006