



HAL
open science

Segmentation par coupes de graphe multi-labels avec a priori de forme

Damien Grosgeorge, Caroline Petitjean, Su Ruan

► **To cite this version:**

Damien Grosgeorge, Caroline Petitjean, Su Ruan. Segmentation par coupes de graphe multi-labels avec a priori de forme. Reconnaissance de Formes et Intelligence Artificielle (RFIA) 2014, Jun 2014, France. hal-00988749

HAL Id: hal-00988749

<https://hal.science/hal-00988749>

Submitted on 9 May 2014

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Segmentation par coupes de graphe multi-labels avec *a priori* de forme

Damien Grosgeorge¹

Caroline Petitjean¹

Su Ruan¹

¹ LITIS EA 4108, Université de Rouen

22 bd Gambetta,
76183 Rouen Cedex, France
damien.grosgeorge@univ-rouen.fr

Résumé

Lorsque l'on cherche à segmenter un ou plusieurs objets de forme connue dans une image, on peut guider la segmentation par l'introduction d'un *a priori* sur la ou les formes. La difficulté de ces approches réside dans le fait que le placement de l'*a priori* dans l'image nécessite, la plupart du temps, un recalage préalable de la forme sur l'image à segmenter. Dans cet article, nous proposons une approche de segmentation automatique en plusieurs classes d'objets, à partir du cadre des coupes de graphe multi-labels. L'*a priori* de forme est une carte probabiliste calculée à partir d'atlas recalés. Dans la fonctionnelle d'énergie du graphe, nous introduisons un terme supplémentaire prenant en compte cet *a priori*. Notre approche a été testée et évaluée sur une application d'imagerie médicale, la segmentation conjointe des ventricules cardiaques en IRM, qui nécessite la segmentation de trois objets différents. Des résultats encourageants ont été obtenus pour cette application connue comme étant difficile, sur une base conséquente de 743 images.

Mots Clef

Segmentation multi-labels, *a priori* de forme, coupes de graphe, recalage, IRM, ventricules cardiaques.

Abstract

When seeking to segment one or more objects of known shape in an image, the segmentation can be guided by the introduction of a prior on one or more shapes. In these approaches, the difficulty relies on the placement of the prior on the unseen image which requires a registration as preliminary step, or an interaction with the user. In this paper, we propose an automatic segmentation into several classes of objects, based on the multi-label graph-cut framework. The shape prior is a probability map computed from registered atlas. We introduce an additional term taking into account this shape prior in the energy functional of the graph. Our approach has been tested and evaluated on a challenging application of medical imaging, the joint segmentation of cardiac ventricles in MRI, which requires the seg-

mentation of three different objects. Encouraging results have been obtained for this challenging application on a database of 743 images.

Keywords

Image segmentation, shape prior, graph cut, registration, MRI, cardiac ventricles.

1 Introduction

En vision par ordinateur, de nombreux problèmes peuvent se mettre sous la forme de la minimisation d'une fonctionnelle d'énergie : la segmentation, la restauration, le recalage, etc. En segmentation d'images, les méthodes variationnelles bien connues sont par exemple les contours actifs [9] et les approches par courbes de niveaux [17]. Ces méthodes reposent sur des fonctionnelles d'énergie intégrant en général un terme d'attache aux données, incorporant des informations sur les contours de l'image, et un terme de régularisation permettant de maîtriser l'aspect du contour. Cependant, l'optimisation peut poser problème lorsque la fonctionnelle d'énergie est non-convexe et présente des minima locaux. La segmentation de plusieurs objets peut également poser problème. D'autre part, notons que dans ces approches, l'image est considérée comme un domaine continu et la nécessaire discrétisation de l'espace et du temps peut poser des problèmes de stabilité.

Offrant des solutions aux problèmes cités précédemment, les méthodes fondées sur les coupes de graphe (GC) ont suscité un fort intérêt depuis l'article de Boykov et Jolly [3]. En s'appuyant sur des algorithmes issus de la communauté combinatoire, elles permettent d'optimiser des fonctions de coût de manière globale, et ainsi d'éviter les minima locaux. D'autre part, en considérant l'image comme un graphe, la stabilité numérique est assurée. La segmentation d'un objet dans une image par GC permet d'obtenir une convergence rapide en 2D. La méthode a également été étendue au problème multi-labels : dans ce cas, il n'est plus possible de déterminer la solution globale exacte comme pour la méthode binaire, le problème étant NP-difficile [4]. Il est cependant possible de déterminer une approximation

de la solution, proche de la solution globale, par l'algorithme α -expansion [4, 11]. La méthode des GC multi-labels a été utilisée en stéréo pour par exemple de la reconstruction [12], du recalage non-rigide [18], du suivi [16], de la restauration d'image [14] ou encore de la segmentation [10, 21].

D'autre part, dans certaines applications où la forme à segmenter est connue a priori (par exemple un organe en imagerie médicale), le processus de segmentation peut être guidé par un modèle de forme ou des contraintes sur celle-ci. Pour des images ayant un contraste faible ou un taux de bruit élevé, une telle contrainte permet d'améliorer la précision de la segmentation. Dans le cadre des modèles déformables par exemple, l'intégration de contraintes de forme a été largement étudiée [6], avec des modèles basés sur une analyse en composantes principales [19] ou sur des atlas [22]. L'avantage de la méthode des GC est sa capacité à donner efficacement une solution optimale pour l'utilisation conjointe de différentes informations sur l'image. A ce jour, les travaux de segmentation par GC multi-labels en prenant en compte des formes a priori sont peu nombreux dans la littérature. Deux problèmes se posent en effet : la modélisation de la forme de l'objet à segmenter et son intégration dans l'algorithme des GC multi-labels. Prenant en compte ces difficultés, un modèle statistique de forme (*Active Shape Model*) a été combiné à la méthode des GC par [5], et des modèles d'apparence multi-échelles ont été intégrés aux GC en alternant des phases d'estimations et de maximisations par [7]. Ces deux méthodes sont cependant itératives et nécessitent des interactions avec l'utilisateur.

Dans cet article, nous proposons une méthode de segmentation automatique et non itérative basée sur les GC multi-labels avec un *a priori* de forme, se déroulant en deux étapes : d'une part la construction d'une carte d'*a priori* de forme, et la segmentation par GC utilisant ce modèle. Plus précisément, nous supposons que nous disposons d'un ensemble d'images labellisées par un expert, ou ensemble d'atlas. Les atlas sont recalés sur l'image à segmenter et combinés pour créer un modèle de forme probabiliste. Un terme d'énergie prenant en compte ce modèle de forme est introduit dans la formulation de l'énergie du graphe.

Dans la suite de cet article, nous présentons notre méthode à la section 2. Elle a été évaluée sur une application d'imagerie médicale, la segmentation conjointe des ventricules cardiaques en IRM, présentée dans la section 3. Enfin, la conclusion et les perspectives sont établies à la section 4.

2 Méthode de segmentation par GC multi-labels avec *a priori* de forme

Notre méthode consiste à créer un *a priori* de forme à partir des atlas afin de guider la segmentation multi-objets par GC. Trois étapes sont nécessaires : (i) le recalage des atlas sur l'image à segmenter, (ii) la fusion des atlas en une carte d'*a priori* de forme, (iii) la segmentation multi-objets par α -expansion intégrant l'*a priori*.

2.1 Recalage non-rigide des atlas par coupes de graphe

Notons I l'image à segmenter, dont le domaine spatial est noté $\Omega \in \mathbf{R}^2$ et dont les objets à segmenter sont représentés par un ensemble de labels \mathcal{L} . Soit N le nombre d'atlas représentatifs, chacun étant composé d'une image d'intensité $A_{[1..N]}$ et d'une carte de labels $L_{[1..N]}$, tel que $\mathcal{A} = \{(A_1; L_1), \dots, (A_N; L_N)\}$. Ces atlas ont été préalablement recalés rigide sur I en utilisant un algorithme en force brute. D'une manière générale, le recalage non-rigide peut se voir comme un problème de minimisation :

$$\mathbf{D}^* = \arg \min_{\mathbf{D}} C(I, A^{\mathbf{D}}) + \lambda_r S(\mathbf{D}) \quad (1)$$

Dans le cas où les déformations peuvent être complexes, la transformation doit être flexible et donc non paramétrique. \mathbf{D} peut alors être un champ de vecteurs de déplacement permettant de déplacer tout point $\mathbf{x} \in \Omega$ de sa position originale à un nouveau point $\mathbf{x} + \mathbf{D}(\mathbf{x}) \in \Omega$ par le vecteur $\mathbf{D}(\mathbf{x}) \in \mathbf{R}^2$. C est une mesure de similarité déterminant le degré de similarité entre I et $A^{\mathbf{D}}$. $A^{\mathbf{D}}$ est l'image flottante après application de \mathbf{D} à A . Enfin, λ_r est une constante positive contrôlant le terme de régularisation S . Dans le cas du recalage monomodal dans lequel nous nous situons, les critères classiques sont l'erreur absolue ou norme L^1 (SAD), l'erreur quadratique ou norme L^2 (SSD), ou encore l'entropie de Shannon de l'image différence. Le meilleur critère sera déterminé empiriquement à la Section 3. Le terme de régularisation S est défini par l'amplitude de la dérivée première [18]. L'équation (1) peut se réécrire sous la forme :

$$\mathbf{D}^* = \arg \min_{\mathbf{D}} \int_{\Omega} C(I(\mathbf{x}), A^{\mathbf{D}}(\mathbf{x})) dx + \lambda_r \int_{\Omega} \|\mathbf{D}(\mathbf{x})\| dx \quad (2)$$

En théorie, cette équation peut être minimisée par n'importe quel outil d'optimisation. Cependant, la transformation étant non paramétrique, le processus d'optimisation peut être très coûteux en temps de calculs. En pratique, cette équation peut être efficacement minimisée par la méthode des coupes de graphe (plus de détails en [18]). Cette méthode permet l'obtention d'un minimum global, ou d'un minimum local fort, en un temps polynomial, sous certaines conditions : la restriction de $\mathbf{D}(\mathbf{x}) \in \mathbf{R}$ à un ensemble fini. Une fenêtre discrète $\mathcal{W} = \{0, \pm s, \pm 2s, \dots, \pm w_s\}^2$ en 2D est ainsi choisie (généralement $w_s = 8$ pixels) telle que $\mathbf{D}(\mathbf{x}) \in \mathcal{W}$. Il est à noter que si $s < 1$, des déplacements avec interpolation seront à considérer. Cette discrétisation permet d'assigner une valeur à tout $\mathbf{D}(\mathbf{x})$. Ainsi, l'équation (2) peut être résolue en utilisant la méthode des coupes de graphe par des séquences d'expansion alpha (α -expansion) [4] et converge vers un minimum local garanti à un facteur près du minimum global.

A la suite de ce recalage non rigide, nous obtenons un ensemble de N champs de vecteurs de déplacement $\mathbf{D}_{1..N}^*$. Ces champs sont appliqués aux images d'intensités et aux

cartes de labels, pour donner les atlas recalés notés $\mathcal{A}^D = \{(A_1^D; L_1^D), \dots, (A_N^D; L_N^D)\}$. Ces atlas sont fusionnés dans une seconde étape afin de créer un *a priori* de forme permettant de guider la segmentation finale.

2.2 Création du modèle de forme

Chaque atlas recalé $(A_i^D(\mathbf{x}); L_i^D(\mathbf{x}))$ a une opinion sur le label de chaque pixel \mathbf{x} . Notre but est de pondérer et de combiner toutes les décisions des atlas afin de créer une carte statistique d'*a priori*, la pondération dépendant de la similarité entre l'intensité du pixel source $I(\mathbf{x})$ et celui de l'atlas $A_i^D(\mathbf{x})$. Dans la littérature, le vote à la majorité est généralement utilisé pour fusionner les atlas, mais d'autres méthodes ont également été proposées [1]. Nous avons choisi de déterminer le poids de fusion pour un label l et un pixel de coordonnées \mathbf{x} par :

$$P(\mathcal{L}(\mathbf{x}) = l | L_i^D(\mathbf{x} + \Delta\mathbf{x}), I(\mathbf{x}), A_i^D(\mathbf{x} + \Delta\mathbf{x})) = \frac{1}{1 + D(\Delta\mathbf{x})} \cdot \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{(I(\mathbf{x}) - A_i^D(\mathbf{x} + \Delta\mathbf{x}))^2}{2\sigma_i^2}\right] \cdot \delta_{l, L_i^D(\mathbf{x} + \Delta\mathbf{x})} \quad (3)$$

avec $\mathbf{x} + \Delta\mathbf{x}$ les coordonnées des pixels voisins au pixel considéré, $D(\Delta\mathbf{x})$ la distance euclidienne du pixel voisin au pixel considéré, σ_i le paramètre pour la distribution gaussienne et δ_{l_1, l_2} la fonction delta Kronecker. $\Delta\mathbf{x}$ est défini par une région de recherche S centrée en \mathbf{x} . Cette fusion permet de compenser d'éventuelles erreurs de régularité dans le recalage en considérant le voisinage de \mathbf{x} .

Notre carte d'*a priori* de forme est alors créée en ajoutant une nécessaire étape de normalisation à l'équation (3) : la somme des scores des labels pour un pixel \mathbf{x} doit être égale à 1. Notre carte d'*a priori* $C_l(\mathbf{x})$ pour chaque label $l \in \mathcal{L}$ est définie par :

$$C_l(\mathbf{x}) = \frac{\sum_{\Delta\mathbf{x} \in S} P(\mathcal{L}(\mathbf{x}) = l | L_i^D(\mathbf{y}), I(\mathbf{x}), A_i^D(\mathbf{y}))}{\sum_{i=1}^{|\mathcal{L}|} \sum_{\Delta\mathbf{x} \in S} P(\mathcal{L}(\mathbf{x}) = l | L_i^D(\mathbf{y}), I(\mathbf{x}), A_i^D(\mathbf{y}))} \quad (4)$$

où $\mathbf{y} = \mathbf{x} + \Delta\mathbf{x}$ les coordonnées des pixels voisins au pixel considéré \mathbf{x} . Cet *a priori* de forme $C_l(\mathbf{x})$ est intégré à la méthode de segmentation dans la section suivante.

2.3 Segmentation multi-labels par coupes de graphe

La segmentation proprement dite est réalisée à l'aide de la méthode des coupes de graphe multi-labels, à laquelle l'*a priori* de forme est intégré. L'image I est considérée comme un graphe, dont l'ensemble des nœuds (pixels) est noté \mathcal{P} et l'ensemble des segments ε . Les nœuds (p, q) dans un voisinage \mathcal{N} sont connectés par un segment appelé *n-link*. Chaque nœud est également connecté à un nœud terminal par un segment appelé *t-link*. Les nœuds terminaux sont les labels $l \in \mathcal{L}$ représentant les objets. Nous notons dans la suite f_p le label du nœud p . Nos contributions portent sur (i) l'intégration d'un terme d'*a priori* de forme

aux *t-links*, (ii) l'ajout d'une contrainte aux *n-links* empêchant un objet inclus dans un autre d'avoir une frontière commune avec tout autre objet.

Nous ajoutons à la formulation de l'énergie de coupe des GC un terme d'*a priori* E_s dépendant de nos cartes C_l pour chaque label l , afin de guider le processus de segmentation. Comme deux valeurs adjacentes de la carte d'*a priori* $C_l(p)$ et $C_l(q)$ (avec $p, q \in \mathcal{N}$) pour un label l donné peuvent être différentes, l'hypothèse de sous-modularité ne peut être vérifiée en cas d'ajout aux *n-links* [11]. Le terme E_s est alors ajouté aux *t-links* :

$$E_f = \sum_{p \in \mathcal{P}} \left(\underbrace{D_p(f_p)}_{\text{Attache aux données}} + \gamma_s \underbrace{E_{s_p}(f_p)}_{\text{Attache à l'a priori}} \right) + \lambda_s \sum_{(p,q) \in \mathcal{N}} \underbrace{V_{p,q}(f_p, f_q)}_{\text{Régularisation}} \quad (5)$$

avec γ_s et λ_s des pondérations. Définissons d'abord les termes associés aux *t-links*. Dans la littérature, le terme d'attache aux données $D_p(f_p)$ est classiquement défini à partir de modèles de niveaux de gris des objets, obtenu à partir d'une interaction avec l'utilisateur, permettant de définir $Pr(I(p)|l)$, la probabilité que l'intensité $I(p)$ du pixel p appartienne au label l . Afin de rendre la méthode totalement automatique, nous proposons la création automatique de germes en utilisant l'ensemble des atlas recalés : si pour un pixel p , tous les atlas $L_i^D(p)$ ont la même opinion de label l , i.e. $C_{f_p=l}(p) = 1$, alors l'intensité $I(p)$ est utilisée pour modéliser l'objet de label l en utilisant une modélisation gaussienne. Si un objet n'a pu être modélisé, les pixels de plus haute opinion selon les atlas sont sélectionnés, à partir d'un seuil s (ainsi, initialement $s = 1$). Le terme d'attache aux données est alors défini par :

$$D_p(f_p) = -\ln Pr(I(p) | C_{f_p}(p) \geq s) \quad (6)$$

Notre terme d'*a priori* de forme $E_{s_p}(f_p)$ pondère également les *t-links*. Il est défini à partir de la carte d'*a priori* $C_{f_p}(p)$ calculée précédemment :

$$E_{s_p}(f_p) = -\ln C_{f_p}(p) \quad (7)$$

$E_{s_p}(f_p)$ peut prendre des valeurs dans \mathbf{R}^+ . Une valeur faible de $E_{s_p}(f_p)$ signifie un coût faible de labellisation du pixel p par le label f_p .

Le terme pondérant les *n-links*, i.e. le terme de régularisation $V_{p,q}(f_p, f_q)$, doit être sous-modulaire afin de permettre la minimisation de l'équation (5) par la méthode des coupes de graphe. Il s'agit de vérifier l'inégalité suivante [11] :

$$V_{p,q}(0, 0) + V_{p,q}(1, 1) \leq V_{p,q}(0, 1) + V_{p,q}(1, 0) \quad (8)$$

Nous souhaitons introduire une contrainte spatiale sur les objets : dans le cas où un objet de label 0 est inclus dans un autre objet de label 1, alors pour tout objet de label l ($l \neq 0$ et $l \neq 1$), il n'existe pas de frontière commune

entre l'objet 0 et l'objet l . Le coût de coupe entre $f_p = 0$ et $f_p = l$ doit alors être maximum. Cette contrainte concernant l'inclusion d'un objet dans un autre peut être introduite grâce au terme de régularisation $V_{p,q}$, et doit donc être sous-modulaire, *i.e.* vérifier l'inégalité (8). Ainsi, nous proposons l'énergie suivante :

$$V_{p,q}(f_p, f_q) = \begin{cases} 0 & \text{si } f_p = f_q \\ \Gamma_{p,q}(f_p, f_q) & \text{si } f_p \neq f_q \end{cases} \quad (9)$$

avec $\Gamma_{p,q}(f_p, f_q)$ l'opérateur de pénalisation frontière. Si les objets de labels f_p et f_q peuvent avoir une frontière commune, alors $\Gamma_{p,q}(f_p, f_q) = 1$, qui est notre valeur minimum possible. Concernant sa valeur maximale, en reprenant l'inégalité de l'équation (8) pour l'expansion d'un nouveau label α sur deux nœuds voisins p et q de labels courants β et γ , les différents coûts possibles de $V_{p,q}$ sont les suivants :

- $V_{p,q}(0, 0) = \Gamma_{p,q}(\beta, \gamma)$ si p et q conservent β et γ .
- $V_{p,q}(1, 1) = 0$ si p et q choisissent le nouveau label α .
- $V_{p,q}(0, 1) = \Gamma_{p,q}(\beta, \alpha)$ si p conserve β et q choisit α .
- $V_{p,q}(1, 0) = \Gamma_{p,q}(\alpha, \gamma)$ si p choisit α et q conserve γ .

On obtient alors la condition suivante :

$$\Gamma_{p,q}(\beta, \gamma) \leq \Gamma_{p,q}(\beta, \alpha) + \Gamma_{p,q}(\alpha, \gamma) \quad (10)$$

Or, sachant que $\min(\Gamma_{p,q}(\beta, \alpha) + \Gamma_{p,q}(\alpha, \gamma)) = 2$, la valeur maximum que peut prendre $\Gamma_{p,q}(f_p, f_q)$ pour respecter l'inégalité de l'équation (10) vaut $\max(\Gamma_{p,q}(\beta, \gamma)) = 2$. On a finalement :

$$\Gamma_{p,q}(f_p, f_q) = \begin{cases} 1 & \text{si } f_p \text{ et } f_q \text{ ont une frontière commune} \\ 2 & \text{sinon} \end{cases} \quad (11)$$

Dans ce cas, l'algorithme α -expansion peut être utilisé pour minimiser la fonctionnelle d'énergie de l'équation (5). L'algorithme converge alors vers un minimum local garanti à un facteur 4 près du minimum global [11], fournissant la segmentation finale.

3 Résultats expérimentaux

Cette méthode a été appliquée à la segmentation du ventricule gauche (VG), droit (VD) et du myocarde sur IRM cardiaques. Cette application est particulièrement difficile du fait du flou aux frontières des ventricules en raison de la circulation sanguine, des artefacts d'acquisition et des effets de volume partiel, de la présence de trabéculations et muscles papillaires (irrégularités) dans les cavités ventriculaires, qui ont le même niveau de gris que la myocarde environnant, et de la forme complexe en croissant du VD. Notre base de données, issue de la routine clinique et collectée au Centre Hospitalier Universitaire de Rouen, comprend 743 Images à Résonance Magnétique, acquise sur 48 patients présentant diverses pathologies. Pour chaque patient, deux volumes d'un total de 16 images (en moyenne) sont disponibles. Sur ces données, l'espacement entre les

coupes est très important, de l'ordre de 8.4 mm, comparé à la résolution spatiale de 0.75 mm/pixel en moyenne. La résolution étant anisotrope, il est possible d'envisager l'utilisation d'une méthode 2D telle que la nôtre. La segmentation manuelle des ventricules droit et gauche a été réalisée par un radiologue.

3.1 Construction du modèle et implémentation

La base d'atlas est formée à partir de l'intégralité de la base d'apprentissage, soit 16 patients (243 images). Pour des raisons évidentes de coûts de calcul, il n'est pas possible de recalculer l'intégralité de la base des atlas sur l'image à segmenter. N atlas sont ainsi sélectionnés selon le niveau de coupe et un critère de similarité (SAD) avec l'image à segmenter (après le recalage rigide).

Notre algorithme automatique débute par la segmentation de la coupe la plus haute du cœur. Le recalage non rigide est réalisé en utilisant comme critère de similarité C une combinaison entre la différence absolue de l'intensité et du gradient entre I et A_I^P (vérifié expérimentalement comme donnant de meilleurs résultats que les critères SAD ou SSD seuls). Les coupes suivantes jusqu'à la pointe du cœur sont alors traitées automatiquement par notre algorithme en utilisant la coupe précédemment segmentée (après recalage sur l'image courante) en tant qu'atlas.

Enfin, les paramètres de notre méthode ont été définis empiriquement à partir de la base d'apprentissage selon une stratégie *leave-one-out*. La majorité des paramètres présente des plages de réglage assez larges n'entraînant que peu de variations dans les résultats. Deux paramètres peuvent être considérés comme critique, et concerne le recalage : la taille de la fenêtre discrète w_s (autrement dit les degrés de liberté du recalage non rigide) et le nombre d'atlas à sélectionner N . Ils influent fortement sur le résultat de fusion et de segmentation finale (en particulier N), mais également sur le temps de calcul (en particulier w_s). La figure 1 illustre les résultats de fusion obtenus en fonction de w_s et de N (indice Dice, voir équation (12)). Comme le montre cette figure, le choix de $N = 3$ et $w_s = \pm 8$ représentent un bon compromis entre rapidité et performances.

3.2 Résultats

Notre algorithme de segmentation a été appliqué aux 32 patients restants (500 images), sans aucune interaction avec l'utilisateur. La Figure 2 présente un exemple de recalage non-rigide sur une image à segmenter. L'étape de recalage permet une meilleure adéquation entre l'image et l'atlas. Afin de comparer les segmentations manuelles et automatiques, le coefficient Dice $DM(A, B)$, une mesure de recouvrement entre deux contours A et B , est calculé par :

$$DM(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (12)$$

Comme le montre le Tableau 1, chaque étape de notre méthode permet d'améliorer les résultats et de réduire l'écart

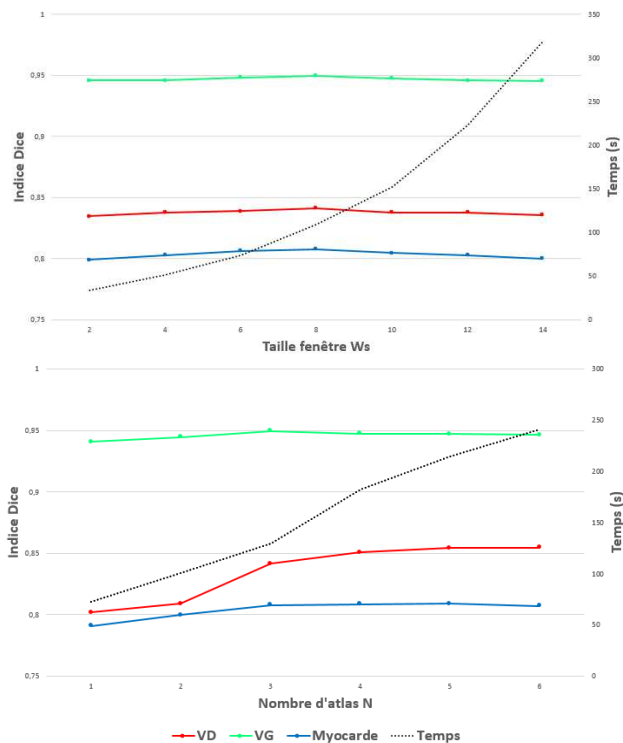


FIGURE 1 – Résultats de fusion (indice Dice) et temps de calcul en fonction de la taille de fenêtre de déplacement w_s (en haut) et du nombre d’atlas N (en bas) pour le recalage non rigide.

type. Le terme d’*a priori* de forme de notre méthode de segmentation conjointe des ventricules permet d’améliorer tous les résultats de segmentation pour le VD, ainsi que de légères améliorations pour le VG et myocarde, comparé à une segmentation classique basée sur un ensemble d’atlas (fusion par vote à la majorité). Des exemples de segmentation pour un patient sont présentés à la Figure 3.

En ne considérant que la segmentation du VD sur cette même base, le tableau 2 compare notre méthode aux 3 méthodes automatiques de segmentation du VD proposées au challenge MICCAI 2012¹, ainsi qu’aux trois méthodes semi-automatiques ayant obtenues les meilleures résultats. Les méthodes automatiques reposent sur du recalage multi-atlas 2D [23] et 3D [15], mais également sur du *clustering* basé sur le mouvement du cœur [20]. Les trois méthodes semi-automatiques reposent sur la méthode des GC binaires avec *a priori* de forme [8], du recalage multi-atlas 3D [2] et un *watershed* 4D [13]. Notre méthode se compare favorablement à ces différentes méthodes et permet des améliorations significatives des résultats.

4 Conclusion et perspectives

Dans cet article, nous avons proposé une méthode automatique de segmentation conjointe des ventricules cardiaques basée sur la méthode des coupes de graphe multi-labels,

1. Plus de détails : <http://www.litislabs.eu/rvsc>




FIGURE 2 – Exemple de recalage non-rigide entre une image I et un atlas A_{I_i} . $A_{I_i}^{D*}$ est le résultat du recalage. Superposition : le vert est utilisé pour I , le rose pour $A_{I_i}^{D*}$.

TABLE 1 – Moyenne (\pm écart type) du coefficient Dice sur 32 patients entre la vérité terrain et (1) les résultats après le recalage non-rigide, (1)+(2) les résultats par vote à la majorité des atlas, (1)+(2)+(3) la segmentation finale par GC multi-labels soit notre méthode complète.

	(1)	(1)+(2)	(1)+(2)+(3)
VD	0.68 ± 0.25	0.75 ± 0.24	0.80 ± 0.19
VG	0.84 ± 0.17	0.87 ± 0.16	0.88 ± 0.14
Myo	0.72 ± 0.17	0.78 ± 0.17	0.79 ± 0.14

utilisant un *a priori* de forme. Le modèle de forme est basé sur le recalage et la fusion d’un ensemble d’atlas. Nous avons proposé et intégré un terme d’*a priori* à la méthode des coupes de graphe multi-labels. Notre méthode de segmentation a été évaluée sur 743 images IRM issues de 48 patients et des résultats encourageants ont été obtenus pour cette application difficile, mais la méthode nécessite le réglage préalable d’un certain nombre de paramètres. Les perspectives de ces travaux sont (i) l’étude des paramètres de la méthode, (ii) l’extension de la validation à d’autres types d’images et (iii) la sélection d’atlas en considérant des caractéristiques patients, tels que l’âge ou le genre.

TABLE 2 – Moyenne (\pm écart type) du coefficient Dice sur 32 patients entre la vérité terrain et différentes méthodes de segmentation proposées au challenge VD MICCAI 2012 (A/SA : Automatique/Semi-Automatique).

Méthodes	A/SA	VD
Notre méthode	A	0.80 ± 0.19
Recalage multi-atlas 2D [23]	A	0.76 ± 0.25
<i>clustering</i> et mouvement [20]	A	0.59 ± 0.33
Recalage multi-atlas 3D [15]	A	0.58 ± 0.30
GC binaire avec <i>a priori</i> [8]	SA	0.78 ± 0.18
<i>Watershed</i> 4D [13]	SA	0.78 ± 0.22
Recalage multi-atlas 3D [2]	SA	0.77 ± 0.21




FIGURE 3 – Segmentation finale pour un patient, soit deux volumes (VD : rouge, VG : vert, myocarde : bleu). De gauche à droite, les niveaux de coupe du haut du cœur jusqu'à sa pointe.

Références

- [1] X. Artaechevarria, A. Munoz-Barrutia, and C. Ortiz de Solorzano. Combination strategies in multi-atlas image segmentation : Application to brain mr data. *Medical Imaging*, 28(8) :1266–1277, 2009.
- [2] W. Bai, W. Shi, D. O'Regan, T. Tong, H. Wang, S. Jamil-Copley, N. Peters, and D. Rueckert. A probabilistic patch-based label fusion model for multi-atlas segmentation with registration refinement : Application to cardiac mr images. *Medical Imaging*, 32(7) :1302–1315, 2013.
- [3] Y. Boykov and M-P Jolly. Interactive graph cuts for optimal boundary & region segmentation of objects in nd images. In *ICCV*, volume 1, pages 105–112, 2001.
- [4] Y. Boykov, O. Veksler, and R. Zabih. Fast approximate energy minimization via graph cuts. *PAMI*, 23(11) :1222–1239, 2001.
- [5] X. Chen and U. Bagci. 3d automatic anatomy segmentation based on iterative graph-cut-asm. *Medical physics*, 38 :4610, 2011.
- [6] D. Cremers, M. Rousson, and R. Deriche. A review of statistical approaches to level set segmentation : integrating color, texture, motion and shape. *IJCV*, 72(2) :195–215, 2007.
- [7] A. Delong, L. Gorelick, F. Schmidt, O. Veksler, and Y. Boykov. Interactive segmentation with super-labels. In *CVPR*, pages 147–162, 2011.
- [8] D. Grosgeorge, C. Petitjean, J-N Dacher, and S. Ruan. Graph cut segmentation with a statistical shape model in cardiac mri. *CVIU*, 117(9) :1027 – 1035, 2013.
- [9] M. Kass, A. Witkin, and D. Terzopoulos. Snakes : Active contour models. *IJCV*, 1 :321–332, 1988.
- [10] R. Kéchichian, S. Valette, M. Desvignes, and R. Prost. Efficient multi-object segmentation of 3d medical images using clustering and graph cuts. In *Image Processing (ICIP)*, pages 2149–2152, 2011.
- [11] V. Kolmogorov and R. Zabih. What energy functions can be minimized via graph cuts ? *PAMI*, 26(2) :147–159, 2004.
- [12] L. Ladický, P. Sturges, K. Alahari, C. Russell, and P. Torr. What, where and how many ? combining object detectors and crfs. In *ECCV*, pages 424–437, 2010.
- [13] O. Maier, D. Jiménez, A. Santos, and M. Ledesma-Carbayo. Segmentation of rv in 4d cardiac mr volumes using region-merging graph cuts. In *Computing in Cardiology*, pages 697–700, 2012.
- [14] D. Miyazaki, Y. Matsushita, and K. Ikeuchi. Interactive shadow removal from a single image using hierarchical graph cut. In *Computer Vision-ACCV*, pages 234–245, 2010.
- [15] Y. Ou, A. Sotiras, N. Paragios, and C. Davatzikos. Dramms : Deformable registration via attribute matching and mutual-saliency weighting. *Medical image analysis*, 15(4) :622–639, 2011.
- [16] N. Papadakis and A. Bugeau. Tracking with occlusions via graph cuts. *PAMI*, 33(1) :144–157, 2011.
- [17] J. A. Sethian. *Level Set Methods and Fast Marching Methods*. Cambridge University Press, 1999.
- [18] T. Tang and A. Chung. Non-rigid image registration using graph-cuts. In *MICCAI*, pages 916–924, 2007.
- [19] A. Tsai, A. Yezzi Jr, W. Wells, C. Tempny, D. Tucker, A. Fan, E. Grimson, and A. Willsky. A shape-based approach to the segmentation of medical imagery using level sets. *Medical Imaging*, 22(2) :137–154, 2003.
- [20] C-W Wang, C-W Peng, and H-C Chen. A simple and fully automatic right ventricle segmentation method for 4-dimensional cardiac mr images. In *Proc. of 3D Cardiovascular Imaging : a MICCAI segmentation challenge.*, 2012.
- [21] G. Zeng and L. Van Gool. Multi-label image segmentation via point-wise repetition. In *CVPR*, pages 1–8, 2008.
- [22] X. Zhuang, DJ Hawkes, WR Crum, R. Boubertakh, S. Uribe, D. Atkinson, P. Batchelor, T. Schaeffter, R. Razavi, and DLG Hill. Robust registration between cardiac mri images and atlas for segmentation propagation. In *Medical Imaging*, 2008.
- [23] M. Zuluaga, M. Cardoso, M. Modat, and S. Ourselin. Multi-atlas propagation whole heart segmentation from mri and cta using a local normalised correlation coefficient criterion. In *Functional Imaging and Modeling of the Heart*, pages 174–181, 2013.