

# Segmentation de stents dans des données médicales à rayons-X corrompues par les artéfacts

Hugo GANGLOFF<sup>1, 2</sup>, Emmanuel MONFRINI<sup>3</sup>, Christophe COLLET<sup>1</sup>, Nabil CHAKFÉ<sup>2, 4</sup>

<sup>1</sup>Université de Strasbourg - CNRS UMR 7357  
300 bd Sébastien Brant, 67400 Illkirch-Graffenstaden, France

<sup>2</sup>Groupe Européen de Recherche sur les Prothèses Appliquées à la Chirurgie Vasculaire  
4 rue Kirschleger, 67000 Strasbourg, France

<sup>3</sup>SAMOVAR - CNRS UMR 5157  
9 rue Charles Fourier, 91000 Évry, France

<sup>4</sup>CHRU Strasbourg  
5 avenue Molière, 67000 Strasbourg, France  
hugogangloff@unistra.fr, emmanuel.monfrini@telecom-sudparis.eu,  
c.collet@unistra.fr, nabil.chakfe@chru-strasbourg.fr

**Résumé** – Nous proposons une nouvelle méthodologie pour la segmentation de stent dans des images scanners 3D à rayons-X. La robustesse de la méthode est mise à l'épreuve par les artéfacts causés par le dispositif métallique et la nécessité d'obtenir des résultats précis liés à l'application médicale. Nous proposons une approche "*coarse-to-fine*", en deux étapes qui conduit à des résultats satisfaisants.

**Abstract** – We propose a new methodology for the segmentation of stents in 3D X-rays acquisitions. Such data are often corrupted by the stent beam hardening, requiring the development of a robust algorithm. Because of the medical application, we need to produce an accurate segmentation. We propose a two-step, coarse-to-fine approach, which leads to satisfying results.

## 1 Introduction

### 1.1 Contexte médical

L'implantation de stent est devenue un traitement standard dans le cas des maladies cardiovasculaires. Cependant, le comportement *in-vivo* du dispositif est encore très mal compris [11]. L'étude des interactions entre les mailles du stent et les calcifications, fondée sur de l'imagerie microtomographique à rayons-X de stents explantés, est un nouvel angle de vue sur le problème. Les cas les plus complexes correspondent souvent à des stents cassés situés dans un environnement calcifié comme on peut le voir sur la Figure 1.

Peu de travaux dans la littérature s'intéressent à la segmentation de stent dans des images médicales. [9] et [10] ne développent pas de modèles adaptés aux environnements calcifiés. L'approche [5] est trop dépendante du modèle de stent. En effet nous devons maîtriser la grande hétérogénéité des données, tant au niveau des modèles de stents à traiter, de leur état de détérioration que du microscanner utilisé pour l'acquisition des images.

Nous cherchons à segmenter les images en 4 classes, à savoir, le *stent*, les *calcifications*, les *autres tissus* et le




FIG. 1: Exemple de données à traiter

*fond*. Nous développons alors un algorithme de segmentation multi-classes suivi d'une étape de raffinement de la classe *stent*.

## 2 Segmentation multi-classe

Nous proposons une généralisation du filtre de [7] pour la segmentation multi-classes. Ce nouveau filtre va produire une première segmentation non-supervisée d'acquisitions à rayons-X qui s'adapte à toutes les dynamiques d'image. Ceci permet un traitement indépendant de l'acquisition et d'éventuels post-traitements.

Soit  $v_k$  le nombre de voxels dont l'intensité est supérieure




FIG. 2: Segmentation brute à 5 classes. *Gauche*: courbe  $v'_k$ . *Droite*: une slice résultat.

ou égale à une intensité  $k$ , nous déduisons le taux de variation:

$$v'_k = \frac{v_k - v_{k+1}}{v_k}, \forall k \in \{i_{max} - 1, \dots, i_{min}\}. \quad (1)$$

Dans nos données, la classe *stent* correspond aux plus hautes intensités puisqu'il s'agit d'un biomatériau métallique hyperdense au milieu de matière organique. Ainsi, un seuil  $\alpha$  est fixé, et quand  $v'_k > \alpha$ , la classe *stent* est considérée segmentée.

L'intuition de ce nouveau filtre est que les autres pics dans la courbe décrite par la quantité  $v'_k$  représentent d'autres classes. Une nouvelle classe est détectée lorsque  $v'_k$  augmente à nouveau, ce qui est fait par l'étude des variations de  $v'_k$ . Ce principe de fonctionnement est justifié dans notre cas car les plages d'intensités des classes à segmenter ne se chevauchent pas.

Afin de limiter les modes dûs au bruit et le problème de sur-segmentation, il est possible de lisser les courbes avec un filtre moyenneur (expérimentalement, nous fixons la largeur de la fenêtre à 15). L'utilisateur peut également fixer en amont le nombre de classes recherchées. Les classes en trop sont alors fusionnées sur un critère de variance intra-classe [14]. La Figure 2 illustre une réponse de notre filtre avec 5 classes demandées.

La segmentation multi-classe obtenue peut alors toujours être corrompue par les artéfacts du stent. C'est pourquoi, nous proposons un modèle statistique pour affiner la segmentation du stent.

### 3 Segmentation fine du stent

La segmentation de la classe *stent* obtenue à la section précédente est dorénavant désignée comme la segmentation *brute*.

Notre modèle doit retrouver la structure lisse et régulière du stent. Les Chaînes de Markov Cachées (CMC) sont un moyen naturel d'introduire de la dépendance entre des voxels voisins afin d'obtenir le traitement désiré sur le stent [1]. La nouveauté de notre approche réside dans le choix du parcours de la CMC et dans le choix du mod-

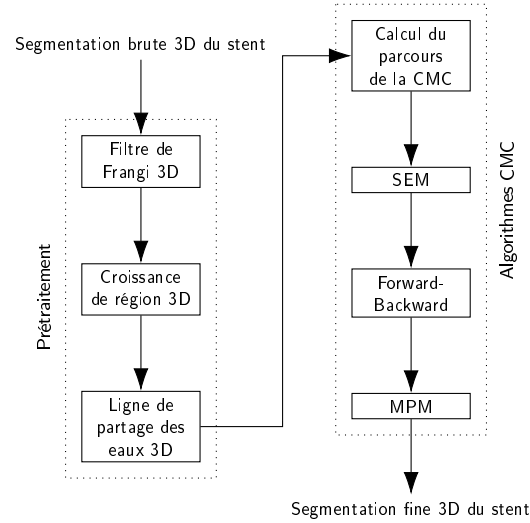


FIG. 3: Schéma de la segmentation fine du stent




FIG. 4: Principe du parcours CMC illustré sur 3 slices.

èle de bruit associé aux observations. La Figure 3 illustre le processus de segmentation *fine* du stent.

#### 3.1 Le parcours de la CMC

Nous devons transformer l'image en une séquence 1D de chaîne, tout en conservant une continuité physique. Une méthode classique consiste à effectuer un parcours 3D de Hilbert-Peano dans tout le cube de données. Nous recherchons un parcours optimal modélisant au mieux la dépendance entre les voxels. Ainsi, nous choisissons que, de manière similaire à [4], chaque composante connexe (du stent issu de la segmentation *brute*) de chaque slice soit visitée par un parcours escargot dont le sens de rotation alterne [15]. Le parcours de CMC est illustré dans la Figure 4.

Afin de faciliter la construction du parcours de la chaîne, des algorithmes de prétraitement sont utilisés *sur la segmentation brute*, ils sont décrits dans la Figure 3. Le filtre de Frangi vise à repérer les structures les plus tubulaires, issues de la segmentation brute, qui formeront le parcours. La croissance de région doit éliminer des arté-




FIG. 5: Segmentation des classes *stent* et *calcifications*

faits n'appartenant pas au stent et la ligne de partage des eaux doit permettre la séparation de composantes du stent qui seraient reliées par des artéfacts.

### 3.2 Le modèle statistique de la CMC

La CMC est caractérisée par des variables à réalisations cachées,  $(X_n)_{n=1}^N$ , et à réalisation observables  $(Y_n)_{n=1}^N$ . Les  $(Y_n)_{n=1}^N$  sont choisies conditionnellement indépendantes sachant les réalisations des  $(X_n)_{n=1}^N$ . La segmentation se fait selon le critère des modes des marginales *a posteriori* (MPM) [12] et la distribution *a posteriori* est calculée avec l'algorithme normalisé *forward-backward* [6]. L'estimation non-supervisée des paramètres est faite avec l'algorithme Stochastic Expectation Maximization (SEM) [2]. L'ensemble de la méthode est résumé dans la Figure 3.

### 3.3 Amélioration du modèle de bruit pour la gestion des artéfacts

Le modèle de bruit pour une CMC est souvent choisi comme un mélange de lois gaussiennes (MdG). Comme proposé dans [13], nous choisissons d'utiliser également le mélange de lois exponentielles (MdE) afin d'améliorer les résultats. En effet, le comportement "tout-ou-rien" permis par cet autre modèle semble particulièrement adéquat à la gestion des artéfacts. La loi exponentielle est donnée par:

$$f(x; \lambda, \delta) = \begin{cases} \lambda \exp(-\lambda(x - \delta)) & x > \delta \\ 0 & x \leq \delta, \end{cases} \quad (2)$$

où  $(\lambda, \delta) \in (\mathbb{R}^{+*}, \mathbb{R})$  sont les nouveaux paramètres à estimer pour chaque classe par la méthode SEM.

## 4 Résultats

La Figure 5 illustre les résultats du nouvel algorithme de segmentation multi-classes de la Section 2.

L'apport de l'utilisation de lois exponentielles dans la segmentation fine du stent a également été constaté en pratique. Pour quantifier les résultats nous avons utilisé la Distance de Hausdorff (DH) [3] implémentée dans MeshLab<sup>1</sup>. Nous avons calculé la DH à partir de la segmentation brute, de la segmentation CMC + MdG et de la segmentation CMC + MdE à la vérité terrain (segmentation manuelle effectuée par les cliniciens). Le Tableau 1 donne les sorties de l'algorithme du calcul de la DH.

	Moy. des DH	Max. des DH
Brute à VT	559.8	4952.1
CMC/MdG à VT	448.3	2344
CMC/MdE à VT	<b>286.9</b>	<b>1444.1</b>

TAB. 1: Données en sortie de l'algorithme de calcul de la DH ( $\times 10^5$ ). VT signifie Vérité Terrain. Les 5 cas utilisés pour ce tableau sont ceux de la Figure 6

Les résultats sont très prometteurs puisque les segmentations utilisant CMC + MdE sont les plus proches de la vérité terrain. Ce choix de modèle entraîne une réduction importante des artéfacts sur l'image finale. Notre nouveau modèle est le plus efficace dans tous les cas. Notons toutefois que lorsque l'image contient relativement peu d'artéfacts, les performances des CMC sont similaires.

La Figure 6 illustre, en 3D, le raffinement obtenu dans la segmentation du stent.

Dans la Figure 7, nous montrons, sur une coupe 2D, la méthode de raffinement à l'oeuvre dans le cas compliqué d'un stent emboîté dans un autre. Cet exemple démontre également la robustesse de notre méthode qui n'utilise pas d'information *a priori* sur la nature du stent, et ne nécessite, en particulier, aucun apprentissage préalable.

## 5 Conclusion

Nous avons présenté un modèle répondant à la problématique de segmentation automatique et précise de stents dans des images médicales très bruitées. Ce modèle est indépendant du stent, de l'évolution de la pathologie et de l'appareil d'acquisition.

Les résultats ouvrent la voie à des études cliniques plus approfondies comme la détection automatique de fractures de stent, ou l'identification du modèle de stent. Nous envisageons également la complexification du modèle statistique avec la modélisation du bruit corrélé [8].

## References

- [1] B. Benmiloud et al. "Estimation des paramètres dans les chaînes de Markov cachées et segmentation d'images". In: *Traitement du Signal* 12 (Jan. 1995), pp. 433–454.
- [2] G. Celeux et al. "L'algorithme SEM: un algorithme d'apprentissage probabiliste pour la reconnaissance de mélange de densités". In: *Revue de statistique appliquée* 34.2 (1986), pp. 35–52.
- [3] P. Cignoni et al. "Metro: measuring error on simplified surfaces". In: *Computer Graphics Forum*. Vol. 17. 2. Wiley Online Library, 1998, pp. 167–174.
- [4] J.-B. Courbot et al. "Vertebra segmentation based on two-step refinement". In: *Journal of computational surgery* 4.1 (2016), p. 1.

<sup>1</sup><http://www.meshlab.net>




FIG. 6: *De gauche à droite* : Vérité Terrain (VT), segmentation brute, segmentation MdG, segmentation MdE. La carte des couleurs représente la distance de Hausdorff du mesh segmenté à la vérité terrain, entre 0 et 10. Plus le mesh est rouge, plus il est proche de la vérité terrain.




FIG. 7: Segmentation brute (*gauche*) et fine (*droite*).

- [5] S. Demirci et al. “3d stent recovery from one x-ray projection”. In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer. 2011, pp. 178–185.
- [6] P. A. Devijver. “Baum’s forward-backward algorithm revisited”. In: *Pattern Recognition Letters* 3.6 (1985), pp. 369–373.
- [7] D. Gao et al. “MGRG-morphological gradient based 3D region growing algorithm for airway tree segmentation in image guided intervention therapy”. In: *Bioelectronics and Bioinformatics (ISBB), 2011 International Symposium on*. IEEE. 2011, pp. 76–79.
- [8] I. Gorynin et al. “Assessing the segmentation performance of pairwise and triplet Markov models”. In: *Signal Processing* 145 (2018), pp. 183–192.
- [9] A. Klein et al. “Automatic segmentation of the wire frame of stent grafts from CT data”. In: *Medical image analysis* 16.1 (2012), pp. 127–139.
- [10] G. Langs et al. “Learning deformation and structure simultaneously: In situ endograft deformation analysis”. In: *Medical image analysis* 15.1 (2011), pp. 12–21.
- [11] A. Lejay et al. “Explanted vascular and endovascular graft analysis: where do we stand and what should we do?”. In: *European Journal of Vascular and Endovascular Surgery* (2018).
- [12] J. Marroquin et al. “Probabilistic solution of ill-posed problems in computational vision”. In: *Journal of the american statistical association* 82.397 (1987), pp. 76–89.
- [13] E. Monfrini et al. “5-Estimation de mélanges généralisés dans les arbres de Markov cachés, application à la segmentation des images de cartons d’orgue de barbarie”. In: (2005).
- [14] N. Otsu. “A threshold selection method from gray-level histograms”. In: *IEEE transactions on systems, man, and cybernetics* 9.1 (1979), pp. 62–66.
- [15] M. Yahiaoui et al. “Implementation of unsupervised statistical methods for low-quality iris segmentation”. In: *2014 Tenth International Conference on Signal-Image Technology and Internet-Based Systems*. IEEE. 2014, pp. 566–573.