

Segmentation Basée sur des Patchs et la Représentation Parcimonieuse pour l'IRM en Radiothérapie de la Prostate

Maxime GUININ^{1,2}, Su RUAN¹, Laurent MASSOPTIER², Isabelle GARDIN^{1,3}

¹LITIS – QUANTIF – EA4108, Université de Rouen
Avenue de l'Université, 76800 Saint Étienne du Rouvray, France

²AQUILAB, Parc Eurasanté – Biocentre A. Fleming
250 rue Salvador Allende, 59120 Loos les Lille, France

³Centre Henri BECQUEREL

Rue d'Amiens, 76038 Rouen Cedex 1, France

maxime.guinin@aquilab.com, su.ruan@univ-rouen.fr

laurent.massoptier@aquilab.com, isabelle.gardin@chb.unicancer.fr

Résumé – La segmentation de la prostate est une étape critique pour la planification en radiothérapie. Nous proposons une segmentation supervisée basée sur l'apprentissage d'un dictionnaire composé de caractéristiques de patchs. La première étape consiste en une définition automatique du VOI (Volume Of Interest) en utilisant une méthode de sur-segmentation (superpixels) des OAR (Organs At Risk) et d'opérations morphologiques. Ensuite, l'étape d'apprentissage consiste à construire un dictionnaire avec des signatures de patchs définies par un ensemble de caractéristiques d'image. Basée sur la sélection de caractéristiques du dictionnaire sous contraintes parcimonieuses, les voxels du VOI sont identifiés comme appartenant à la prostate ou non. Enfin, la segmentation de la prostate est effectuée par un ensemble de fonctions de propagation de label. Cette méthode a été évaluée avec une validation croisée sur un ensemble de données IRM de la prostate proposé lors du challenge ISBI 2013. L'influence du paramètre de régularisation à l'intérieur de la fonction de sélection de caractéristiques a été étudiée. Les résultats montrent une bonne performance de notre méthode comparée avec d'autres méthodes existantes.

Abstract – Prostate segmentation is critical for treatment planning in radiotherapy. We propose a supervised segmentation based on dictionary learning. As Organs At Risk (OAR: bladder, rectum) need also to be segmented, our first step leads to an automatic Volume Of Interest (VOI) definition using an over-segmentation method (superpixels) of OAR and morphological operations. Then, the learning step consists of constructing a dictionary with patch signatures defined by a set of image features. Based on the selection of features from the dictionary under sparse constraint, voxels in VOI are identified as belonging to the prostate or not. Finally, a sparse patch label propagation framework segments the prostate. This method has been evaluated on the prostate MRI dataset proposed in ISIB 2013 with a leave-one-out cross-validation. The influence of the regularization parameter inside the feature selection has been studied. The results show a good performance of our method compared with other existing methods.

1 Introduction

Le cancer de la prostate est le plus répandu et le troisième cas de cancers masculins mortels en Europe de l'ouest [1]. Parmi les traitements du cancer de la prostate, la radiothérapie a pour but de traiter le cancer en utilisant des radiations ionisantes. L'efficacité du traitement dépend de la maximisation de l'irradiation à l'intérieur de la tumeur tout en minimisant cette irradiation au sein des OAR (Organs At Risk) environnants. C'est pourquoi, la segmentation de la prostate et des OAR est une étape cruciale dans la phase de planification du traitement.

La segmentation automatique et précise de la prostate en IRM est une tâche difficile puisque la taille et la forme de cet organe varient d'un patient à l'autre avec un faible contraste entre la prostate et les tissus environnants. Plusieurs méthodes ont été développées afin de répondre à cette problématique.

Vincent et al. [2] ont développé un système générique de modèle statistique afin de construire un AAM (Active Appearance Model), permettant une segmentation automatique de la prostate. Liao et al. [3] utilisent une représentation basée sur patchs pour distinguer les voxels appartenant à la région prostatique ou non, intégré au sein d'un ensemble de fonctions de propagation de label basé sur des patchs parcimonieux pour segmenter automatiquement la prostate. Concernant les méthodes semi-automatiques, Yuan et al. [4] proposent un contour déformable 3D de la prostate sous contraintes convexe incorporant une correspondance d'histogramme et un *a priori* de forme générique (en étoile). Maan et al. [5] utilisent un recalage non rigide de surface couplé à un AAM manuellement initialisé en sélectionnant le centre de l'organe.

Notre but est de fournir un outil de segmentation automatique dans le contexte de radiothérapie de la prostate. Notre mé-

thode est composée de trois étapes : (1) extraction du VOI (Volume Of Interest), (2) apprentissage de dictionnaire et (3) segmentation de la prostate. Les OAR sont préalablement segmentés en utilisant une technique de sur-segmentation permettant d’extraire un VOI contenant la prostate sur les images d’apprentissage ainsi que sur la nouvelle image à segmenter. Ensuite, un apprentissage de dictionnaire basé sur une contrainte parcimonieuse est créé sur un ensemble d’images d’apprentissage afin d’obtenir les signatures sur les patches de voxels décrivant les textures de la prostate. Les voxels d’une nouvelle image sont alors labellisés par comparaison entre leur signature de patch et celles du dictionnaire. Cette méthode a été appliquée et évaluée sur un ensemble de données IRM du challenge ISBI 2013 [6] composée de 10 patients préalablement recalés.

Dans la section 2, nous décrivons la méthode proposée pour segmenter la prostate. Dans la section 3, nous étudierons l’influence de la contrainte parcimonieuse sur les résultats de la segmentation. Puis, une comparaison des résultats de notre méthode avec d’autres méthodes du challenge ISBI 2013 sera exposée. Enfin, nous présenterons nos conclusions et futurs travaux dans la section 4.

2 Méthode

Le schéma général de notre méthode est visible en Figure 1. Chaque étape est détaillée dans les sections suivantes.

2.1 Extraction du VOI de la prostate

La segmentation des organes à risque (têtes fémorales, rectum et vessie) est effectuée en utilisant une méthode basée sur les superpixels et une diffusion sur graph, développée dans nos précédents travaux [7]. Puisque, physiologiquement, la prostate se trouve forcément entre le rectum et la vessie, une enveloppe convexe incluant ces deux organes est définie. Par la suite, ces deux OAR sont soustraits au volume de l’enveloppe convexe. Pour prendre en compte la forme de la prostate, une dilatation (plus prononcée sur l’axe gauche-droite) et érosion (plus prononcée sur l’axe antéro-postérieur) anisotropique est appliquée avec un élément structurant de taille $30 \times 60 \times 1$ et $60 \times 50 \times 30$

voxels, respectivement. Ceci définit un VOI incluant la prostate permettant de réduire la région à segmenter. L’extraction du VOI est effectuée sur les images d’apprentissage ainsi que la nouvelle image à segmenter.

2.2 Construction du dictionnaire et sélection de caractéristiques

Le principe de notre méthode est le suivant. La méthode est basée sur des patches définis par une sous-image, appelée patch, de taille $K \times K$ centrée sur un voxel x . Ensuite, cinq familles de caractéristiques de texture sont extraites du patch : moyenne (1 caractéristique), LBP (Local Binary Pattern) (1 caractéristique) et sa version étendue (ELBP) [8] (64 caractéristiques), Haar [9] (32 caractéristiques) et HOG (Histogram of Oriented Gradients) [10] (4 caractéristiques), aboutissant à l’extraction de $M = 102$ caractéristiques.

Le vecteur signature d’un voxel i , noté \mathbf{a}_i , inclut l’ensemble des M caractéristiques. Le dictionnaire est composé de toutes les signatures extraites. Cependant, toutes les caractéristiques ne sont pas nécessairement informatives et nous ne savons pas lesquelles le sont *a priori*. Par conséquent, il est nécessaire de sélectionner les caractéristiques discriminantes. Pour ce faire, N signatures $\mathbf{a}_i (i = 1, \dots, N)$ sont sélectionnées du dictionnaire. Pour chaque signature, son label l_i y est associé, avec pour valeur $+1$ lorsque le voxel appartient à la prostate et -1 sinon. Les caractéristiques peuvent être discriminées en minimisant le problème logistique Lasso suivant [11] :

$$J(\beta, c) = \sum_{i=1}^N \log(1 + \exp(-l_i(\beta^T \mathbf{a}_i + c))) + \lambda \|\beta\|_1 \quad (1)$$

avec β le vecteur de coefficients parcimonieux, c l’ordonnée à l’origine et λ le paramètre de régularisation de la contrainte parcimonieuse définie par la norme L1, menant à sélectionner le moins de caractéristiques possible. Afin de minimiser l’équation (1) par la méthode de Nesterov, l’ensemble de fonctions SLEP pour Matlab [12] est utilisé. Les caractéristiques discriminantes sont définies par $\beta \neq 0$. Ce sous ensemble de caractéristiques forme une signature parcimonieuse notée \mathbf{b}_i .

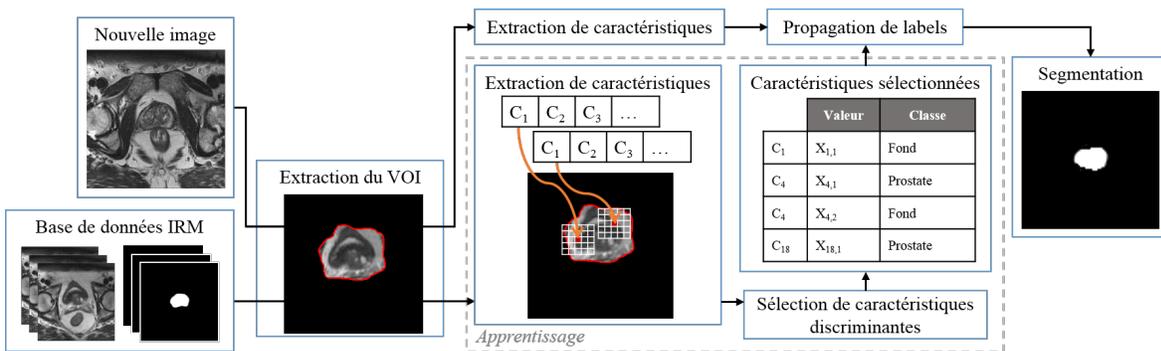


FIGURE 1 – Schéma général de notre méthode.

2.3 Propagation de label par patches parcimonieux et segmentation de la prostate

Considérons n images recalées et leur carte de labels associées $\{(I_u, L_u), u = 1, \dots, n\}$, ainsi qu'une nouvelle image I_{new} devant être segmentée et préalablement recalée sur les images d'entraînement. Une carte de labels L_u contient la valeur $l = 1$ si le voxel y de l'image I_u associé appartient à la prostate, $l = -1$ sinon. Chaque voxel x de I_{new} est relié au voxel y de chaque image d'entraînement I_u . La probabilité du voxel x d'appartenir à la prostate est déterminé par [3] :

$$L_{new}(x) = \frac{\sum_{u=1}^n \sum_{y \in \mathcal{N}_u(x)} w_u(x, y) L_u(y)}{\sum_{u=1}^n \sum_{y \in \mathcal{N}_u(x)} w_u(x, y)} \quad (2)$$

avec L_{new} la carte de probabilité de la prostate de I_{new} , $\mathcal{N}_u(x)$ le voisinage de taille $W \times W$ du voxel x dans I_u et $w_u(x, y)$ le poids du lien entre le voxel x et y , mesurant la similarité entre les signatures en x et y .

Afin de déterminer le poids d'appartenance $w_u(x, y)$ du voxel x le reliant à chaque voxel x des n images d'entraînement, une approche parcimonieuse a également été choisie. Pour calculer $w_u(x, y)$, une matrice A est construite. Chaque colonne de A est définie par la signature $\mathbf{b}_y^{I_u}$, $y \in \mathcal{N}_u(x)$. Ainsi, la sélection des meilleures correspondances de patches consiste à la minimisation de l'équation suivante :

$$J(\theta_x) = \frac{1}{2} \|\mathbf{b}_x^{I_{new}} - A\theta_x\|_2^2 + \Lambda \|\theta_x\|_1, \quad \theta_x \geq 0 \quad (3)$$

avec $\mathbf{b}_x^{I_{new}}$ la signature parcimonieuse en x de l'image I_{new} , Λ le paramètre de régularisation de la contrainte de parcimonie et θ_x le vecteur de coefficient parcimonieux. Le poids, $w_u(x, y)$, correspond directement à chaque éléments de la solution θ_x .

Puisque les images sont préalablement alignées dans la base de données, la segmentation finale L_{new} est effectuée par vote majoritaire.

3 Évaluation, résultats et discussion

3.1 Évaluation

Dix images de taille $320 \times 320 \times 20$ voxels venant du challenge ISBI 2013 [6] ont été utilisées. Elles sont toutes recalées et segmentées par des experts. Les segmentations de la prostate sont considérées comme la référence absolue.

Puisque le paramètre de régularisation, λ , pondère la contrainte parcimonieuse des signatures dans le dictionnaire dans l'équation (1), son impact sur les résultats de segmentations a été évalué. L'influence de λ sur le nombre de caractéristiques sélectionnées dans les signatures parcimonieuses et sur les résultats de segmentations a été évaluée pour 6 différentes valeurs : 0.1, 0.2, 0.5, 0.7, 0.9, et 0.99. Les autres paramètres ont été fixés sur : $K = 5$ (taille des patches), $W = 15$ (taille du voisinage) et $\Lambda = 10^{-4}$ (équation (3)). Afin de comparer les résultats de segmentations avec la référence absolue, le DI

(Dice Index) et TPR (True Positive Rate) ont été utilisés. Le DI représente le taux de superposition entre les deux volumes. Le TPR mesure la fraction de voxels du résultat de la segmentation correctement labellisés à l'intérieur de la référence absolue.

L'évaluation a été accomplie avec une méthode de validation croisée de type *Leave One Out*. Pour segmenter une image, les 9 autres images ont été utilisées pendant la phase d'apprentissage. Pour l'étape de segmentation, chaque image est segmentée avec l'ensemble de fonctions de propagation de label basé sur les patches en utilisant les 9 autres images. La segmentation finale de cette image est effectuée par un vote majoritaire entre la carte de probabilité L_{new} et les 9 autres cartes de labels L_u .

3.2 Résultats et discussion

Sur l'ensemble de la base, le VOI contient toujours la prostate segmentée par l'expert. Les opérations morphologiques permettent d'extraire automatiquement un volume plus petit, limitant l'extraction de patches et le nombre de voxels à traiter.

La Table 1 donne le nombre de caractéristiques sélectionnées et les performances de résultats de segmentations avec notre méthode. Le nombre de caractéristiques sélectionnées diminue lorsque le paramètre de régularisation λ augmente. Il est également montré qu'avec une valeur de λ de 0.5, seules 7 caractéristiques sur 102 sont sélectionnées. Après cette valeur, la diminution du nombre de caractéristiques sélectionnées est moins prononcée, alors que la performance de segmentation diminue entre $\lambda = 0.5$ et 0.7. De plus, ce tableau montre que pour nos données, une valeur de λ de 0.5 est le meilleur compromis entre le faible nombre de caractéristiques sélectionnées et les performances de segmentation. Les caractéristiques sélectionnées pour $\lambda = 0.5$ sont LBP et 4 ELBP, une Haar et une HOG. Avec seulement 7 caractéristiques calculées comme très discriminantes, l'ensemble de fonctions de propagation de labels permet de segmenter la prostate avec un DI et TPR supérieur à 76% et 81%, respectivement. Concernant les autres paramètres de notre méthode, ils ont été fixés comme dans [3] pour seulement évaluer l'influence du paramètre de régularisation sur la segmentation de la prostate en IRM. La Figure 2 montre des résultats de la segmentation par notre méthode comparé à la référence absolue sur la première ligne et la carte de probabilité associée sur la seconde ligne, pour $\lambda = 0.5$. De bons résultats sont visibles sur n'importe quelle coupe même sur celles difficiles sur le haut et le bas de la prostate. De plus, malgré une décision difficile à prendre sur les bords des cartes de probabi-

TABLE 1 – Nombre de caractéristiques sélectionnées (#f) et résultats de DI et de TPR moyens et écart type (en %) de segmentations pour différentes valeurs de λ .

λ	0.1	0.2	0.5	0.7	0.9	0.99
#f	35	27	7	4	2	1
DI	76.01 ±7.41	76.01 ±7.41	76.01 ±7.41	72.16 ±6.15	72.16 ±6.15	72.16 ±6.15
TPR	81.42 ±11.99	81.42 ±11.99	81.42 ±11.99	75.46 ±13.03	75.46 ±13.03	75.46 ±13.03

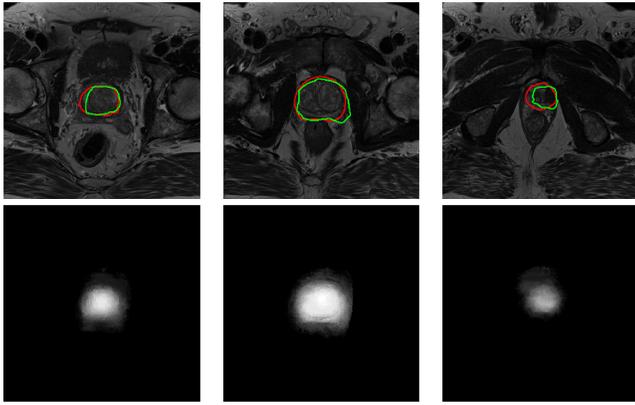


FIGURE 2 – Première ligne : segmentation de la prostate de notre méthode (vert) comparé à la référence absolue (rouge). Seconde ligne : cartes de probabilité associées.

lité (seconde ligne de la Figure 2), le vote majoritaire permet de correctement segmenter.

Afin de comparer les résultats de notre méthode, les 3 meilleures méthodes du challenge ISBI 2013 ont été reportées dans la Table 2. Basée sur les résultats moyens du DI et du TPR, la méthode CCIPD RobThth segmente le mieux la prostate. La seconde méthode ayant été soumise ses résultats au challenge, appelée Geert Litjend perd 1.2% de DI mais plus de 7% de TPR comparé à la première méthode. La dernière méthode nommée MD Anderson Cancer Center obtient des résultats aux alentours de 50% pour le DI et le TPR, loin derrière les autres méthodes. Nos résultats préliminaires sur un sous ensemble constitué des 10 premières images du challenge ISBI 2013 montre que notre méthode obtient des résultats prometteurs comparé aux 3 meilleures méthodes entraînées sur 60 images et testées sur 10 images.

4 Conclusion

Dans cet article, nous proposons une méthode de segmentation de la prostate basée sur une technique de patches parcimonieux en utilisant un apprentissage de dictionnaire. Les caractéristiques les plus informatives sont sélectionnées par une fonction logistique Lasso. Cette méthode permet de discriminer les voxels appartenant à la prostate ou non dans la base d'apprentissage. Un ensemble de fonctions de propagation de label parcimonieux est utilisé pour déterminer la carte de probabilité de la prostate et la segmentation finale est réalisée par

TABLE 2 – Résultats comparatifs du DI et TPR (en %) entre les résultats sur site des méthodes du challenge et Dilem.

Nom de méthode	DI	TPR
CCIPD RobToth	76.25	84.55
Geert Litjens	75.05	77.30
MD Anderson Cancer Center	53.20	51.80
Notre méthode	76.01	81.42

vote majoritaire.

En étudiant des variations du paramètre de régularisation, nous avons montré que seuls quelques caractéristiques sont suffisantes pour obtenir une bonne segmentation. Ce processus a été évalué sur 10 images IRM de la prostate en effectuant une validation croisée de type *Leave One Out*.

Comparée aux 3 meilleures méthodes proposées lors du challenge ISBI 2013, notre méthode obtient des résultats prometteurs sur notre ensemble de données.

Dans nos travaux futurs, nous testerons notre méthode sur la base entière du challenge ISBI 2013 pour la valider, puis nous l'étendrons afin de pouvoir traiter des images tomodynamométriques.

Références

- [1] French National Cancer Institute (INCa) : [The cancer situation in France in 2012](#).
- [2] Vincent, G., Guillard, G., Bowes, M. : Fully automatic segmentation of the prostate using active appearance models. MICCAI Grand Challenge : Prostate MR Image Segmentation (2012)
- [3] Liao, S., Gao, Y., Shen, D. : Sparse patch based prostate segmentation in CT images. MICCAI 2012, 385–392. Springer Berlin Heidelberg (2012)
- [4] Yuan, J., Qiu, W., Ukwatta, E., et al. : An efficient convex optimization approach to 3D prostate MRI segmentation with generic star shape prior. MICCAI Grand Challenge : Prostate MR Image Segmentation (2012)
- [5] Maan, B., van der Heijden, F. : Prostate MR image segmentation using 3D active appearance models. MICCAI Grand Challenge : Prostate MR Image Segmentation (2012)
- [6] The Cancer Imaging Archive. NCI-ISBI 2013 Challenge : [Automated Segmentation of Prostate Structures](#). (2013)
- [7] Guinin, M., Ruan, S., Nkhali, L., et al. : Segmentation of Pelvic Organs at Risk Using Superpixels and Graph Diffusion in Prostate Radiotherapy. To appear in ISBI, (2015)
- [8] Ojala, T., Pietikainen, M., Maenpaa, T. : Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE PAMI, 24(7), 971–987 (2002)
- [9] Lienhart, R., Maydt, J. : An extended set of haar-like features for rapid object detection. IEEE ICIP, 1, 900–903 (2002)
- [10] Dalal, N., Triggs, B. : Histograms of oriented gradients for human detection. IEEE CVPR, 1, 886–893 (2005)
- [11] Tibshirani, R. : Regression shrinkage and selection via the lasso. Journal of the Royal Statistical Society. Series B (Methodological), 267–288 (1996)
- [12] Liu, J., Ji, S., Ye, J. : [SLEP: Sparse Learning with Efficient Projections](#). Arizona State University, 2009.