



HAL
open science

Segmentation 3D des organes à risque du tronc masculin à partir d'images anatomiques TDM et IRM à l'aide de méthodes hybrides

Maxime Guinin

► **To cite this version:**

Maxime Guinin. Segmentation 3D des organes à risque du tronc masculin à partir d'images anatomiques TDM et IRM à l'aide de méthodes hybrides. Imagerie médicale. Normandie Université, 2017. Français. NNT : 2017NORMR019 . tel-01578162

HAL Id: tel-01578162

<https://theses.hal.science/tel-01578162>

Submitted on 28 Aug 2017

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.



Normandie Université

THESE

Pour obtenir le diplôme de doctorat

Spécialité Informatique

Préparée au sein de l'Université de Rouen

Segmentation 3D des organes du pelvis masculin par des méthodes superpixel et multi-atlas dans le contexte de la prise en charge des cancers prostatiques par radiothérapie externe

**Présentée et soutenue par
Maxime GUININ**

**Thèse soutenue publiquement le 05/05/2017
devant le jury composé de**

M. Pascal HAIGRON	Professeur des Universités – Université de Rennes 1	Rapporteur
M. Rachid JENNANE	Professeur des Universités – Université d'Orléans	Rapporteur
M. Bernard DUBRAY	PUPH – Université de Rouen Normandie	Examineur
M. David GIBON	Président d'entreprise – AQUILAB	Examineur

**Thèse dirigée par Isabelle GARDIN, Centre Henri Becquerel
et co-dirigée par Su RUAN, Laboratoire d'Informatique et du Traitement de l'Information et des Systèmes (LITIS)**



THÈSE

En vue de l'obtention du grade de

DOCTEUR DE NORMANDIE UNIVERSITÉ

délivré par

L'UNIVERSITÉ DE ROUEN

LABORATOIRE D'INFORMATIQUE DU TRAITEMENT DE L'INFORMATION
ET DES SYSTÈMES

École doctorale : **MATHÉMATIQUES, INFORMATION, INGÉNIERIE DES SYSTÈMES**

Discipline : INFORMATIQUE

Présentée et soutenue publiquement par

Maxime GUININ

Segmentation 3D des organes du pelvis masculin par des méthodes superpixel et multi-atlas dans le contexte de la prise en charge des cancers prostatiques par radiothérapie externe

Directrice de thèse : **Mme Isabelle GARDIN**
Co-directrice de thèse : **Pr Su RUAN**

Jury

M. Pascal HAIGRON,	Professeur, Université de Rennes 1	Rapporteur
M. Rachid JENNANE,	Professeur, Université d'Orléans	Rapporteur
M. Bernard DUBRAY,	Professeur, Université de Rouen	Examineur
M. David GIBON,	Président d'entreprise, AQUILAB	Examineur
Mme Isabelle GARDIN,	HDR, Université de Rouen	Directrice
Mme Su RUAN,	Professeur, Université de Rouen	Co-directrice

Résumé

Le cancer de la prostate est une cause majeure de décès dans le monde. La radiothérapie externe est une des techniques utilisée pour traiter ce cancer. Pour ce faire, la segmentation de la prostate et de ses organes à risque (OAR) associés (le rectum, la vessie et les têtes fémorales) est une étape majeure dans l'application du traitement.

L'objectif de cette thèse est de fournir des outils afin de segmenter la prostate et les OAR de manière automatique ou semi-automatique. Plusieurs approches ont été proposées ces dernières années pour répondre à ces problématiques. Les OAR possédant un contraste relativement bon dans l'image, nous nous sommes orientés vers une approche semi-automatique de leur segmentation, consistant en une sur-segmentation de l'image en petites régions homogènes appelées superpixels. L'utilisateur de la méthode choisit ensuite de labelliser quelques superpixels dans les OAR comme des germes. Enfin, la méthode segmente les OAR grâce à une diffusion sur le graphe (à partir des germes) construit par des superpixels. Quant à la segmentation de la prostate, un sous-volume de l'image appelé VOI (Volume Of Interest), dans lequel se trouve la prostate, est tout d'abord défini. À l'intérieur de ce VOI, la segmentation de la prostate est réalisée. Un dictionnaire composé des caractéristiques de textures extraites sur chaque patch du VOI est d'abord construit. La sélection de caractéristiques du dictionnaire sous contraintes parcimonieuses permet ensuite de trouver celles qui sont le plus informatives. Enfin, basé sur ces caractéristiques sélectionnées, une propagation de label de patch sous contrainte parcimonieuse est appliquée pour segmenter la prostate à deux échelles, superpixels et pixels. Notre méthode a été évaluée sur des images TDM du Centre Henri Becquerel et IRM du challenge ISBI 2013 avec des résultats prometteurs.

Mots clés : Segmentation, Organes à risque, Prostate, Radiothérapie, Superpixels, Multi-atlas, Parcimonie

Abstract

Prostate cancer is a leading cause of death worldwide. External radiotherapy is one of the techniques used to this disease. In order to achieve this, the segmentation of the prostate and its associated organs at risk (OAR) (rectum, bladder and femoral heads) is a major step in the application of the treatment.

The objective of this thesis is to provide tools to segment prostate and OAR automatically or semi-automatically. Several approaches have been proposed in recent years to address these issues. As OAR have a relatively good contrast in the image, we have focused on a semi-automatic approach to segment them, consisting of an over-segmentation of the image into small homogeneous regions called superpixels. Then, the user labels some superpixels in the OAR as germs. Finally, the OAR segmentation is performed by a graph diffusion (from germs) constructed by superpixels. Regarding the prostate segmentation, a sub-volume of the image called VOI (Volume Of Interest), in which the prostate is located, is first defined. The prostate segmentation is performed within this VOI. A dictionary composed of the texture characteristics extracted on each patch of the VOI is first constructed. Then, the selection of characteristics of the dictionary under parsimonious constraints allows to find the most informative ones. Finally, based on these selected characteristics, patch label propagation under parsimonious constraint is applied to segment the prostate at two scales, superpixels and pixels. Our method was evaluated with promising results on TDM images of the Henri Becquerel Center and IRM of the 2013 ISBI challenge.

Keywords : Segmentation, Organ at risk, Prostate, Radiotherapy, Superpixels, Multi-atlas, Sparse

Remerciements

Je tiens tout d'abord à remercier les membres du jury de cette thèse pour l'intérêt porté à mes travaux. Je remercie tout particulièrement Monsieur Pascal Haigron, Professeur à l'Université de Rennes 1, et Monsieur Rachid Jennane, Professeur à l'Université d'Orléans, d'avoir accepté de rapporter ma thèse.

Je souhaite exprimer ma reconnaissance à Madame Isabelle Gardin, HDR au Centre Henri Becquerel de Rouen et directrice de cette thèse, pour m'avoir fait bénéficier de ses nombreuses connaissances et de son expertise. Sa disponibilité et ses précieux conseils ont été d'une grande aide à la réalisation de cette thèse. Je tiens également à adresser toute ma reconnaissance et mes remerciements à Madame Su Ruan, Professeur à l'Université de Rouen et co-encadré cette thèse, pour ses conseils pertinents et très instructifs dans le domaine scientifique et sa disponibilité notable, propice au bon déroulement de ma thèse. Je tiens également à les remercier pour leur aide précieuse m'ayant permis de parfaire la réalisation de ce mémoire.

Ma reconnaissance va également à Monsieur Bernard Dubray, Professeur à l'Université de Rouen et Radiothérapeute au Centre Henri Becquerel de Rouen, pour son expertise médicale en imagerie prostatique, sa gentillesse et sa disponibilité malgré un emploi du temps chargé. Ses conseils et suggestions ont été d'une grande aide à l'appréhension de la problématique de segmentation de la prostate dans la prise en charge de traitement par radiothérapie.

Ma gratitude va ensuite à Monsieur David Gibon, Président de l'entreprise AQUILAB, et à Laurent Massotier, Research and Innovation Manager à AQUILAB, pour leur confiance et leur expertise de l'application de nos recherches au monde de l'entreprise. Je les remercie également pour m'avoir financé et permis de voyager pour présenter mes travaux à travers le monde.

Je remercie également tous les membres de l'équipe QUANTIF, en particulier Paul Desbordes, Damien Grosgoerge, Pierre Buysens et Elyse Colard qui ont rendu ces années de thèse agréables et sympathiques, ainsi que les salariés d'AQUILAB, en particulier Thomas Glachant et François Defrance, pour nos échanges instructifs toujours autour d'un bon repas.

C'est également l'occasion de remercier ma famille et mes amis dont le soutien a été précieux. En particulier, celui de ma femme, Clémence Guinin, a été primordial à l'accomplissement de cette thèse. Les travaux abordés ici n'égaleront jamais sa force, sa compréhension et son soutien sans faille, qui m'ont permis d'en arriver là aujourd'hui.

À ma femme Clémence, et mon fils Paul.

Table des matières

Introduction générale	3
1 Contexte médical et problématique de segmentation	7
1.1 Le cancer de la prostate	8
1.2 La radiothérapie externe	8
1.3 Image médicale numérique	12
1.4 Imagerie par tomodensitométrie – TDM	13
1.5 Imagerie par résonance magnétique nucléaire – IRM	17
1.6 Comparaison d’images TDM et IRM de la prostate	21
1.7 Conclusion	23
2 État de l’art des méthodes de segmentation d’images médicales IRM et TDM dans le cadre du cancer de la prostate	25
2.1 Introduction	26
2.2 Généralité sur la segmentation d’images médicales	27
2.3 Méthodes basées sur les modèles statistiques	28
2.4 Méthodes basées sur les modèles déformables	32
2.5 Méthodes basées sur l’apprentissage automatique	36
2.6 Méthodes basées sur le graphe	39
2.7 Méthodes basées atlas	43
2.8 Conclusion	47
3 Segmentation semi-automatique des OAR par superpixels	49
3.1 Introduction	50
3.2 Méthode de segmentation par superpixels	51
3.3 Évaluation de la méthode	62
3.4 Discussion et conclusion	71
4 Segmentation de la prostate par méthode multi-atlas avec contrainte de parci- monie	73
4.1 Introduction	74
4.2 Principe de traitement d’images par patchs	74
4.3 Méthode proposée	80
4.4 Résultats expérimentaux	93
4.5 Conclusion	99
Conclusion générale et perspectives	101
Liste des publications	105
Bibliographie	106

Introduction générale

Le traitement du cancer est un fort enjeu de santé publique. Chez les hommes, les trois cancers les plus fréquents sont ceux de la prostate, du poumon et du côlon-rectum [INSTITUT NATIONAL DU CANCER (INCA) 2016]. Le cancer de la prostate représente à lui seul près de 54000 nouveaux cas chaque année. C'est le cancer le plus fréquent chez l'homme dans l'ensemble de la population [INSTITUT NATIONAL DU CANCER (INCA) 2016].

Parmi les différentes techniques disponibles pour traiter les tumeurs prostatiques, la radiothérapie externe et la chirurgie sont les principaux modes de traitement. Ils peuvent être complémentaires à une radiothérapie interne (aussi appelée curiethérapie), une chimiothérapie ou hormonothérapie. Dans le cas de la radiothérapie externe, des rayonnements ionisants sont utilisés, afin de détruire les cellules cancéreuses. Elle consiste à diriger précisément ces rayonnements sur la zone à traiter, tout en préservant le mieux possible les tissus sains et les organes avoisinants, dits organes à risque (OAR), notamment la vessie, les têtes fémorales et le rectum. Ces rayonnements sont produits par un accélérateur linéaire de particules et dirigés en faisceaux vers la prostate pour atteindre la tumeur [INSTITUT NATIONAL DU CANCER (INCA) 2017] à travers la peau et les tissus sains. Afin de traiter la tumeur, tout en limitant l'irradiation, la segmentation des OAR est nécessaire. Leur localisation est réalisée lors de la phase de simulation, parfois appelée repérage, sur des imageries anatomiques telles que la tomographie par ordinateur (TDM) ou grâce à une fusion des images obtenues par TDM avec celles provenant d'imagerie par résonance magnétique (IRM). Lors de cette étape, l'oncologue radiothérapeute repère la cible tumorale et les OAR à protéger. De nos jours, cette étape est réalisée de façon manuelle en grande partie.

La délimitation manuelle est une tâche chronophage et est soumise à des variations intra et inter-utilisateurs pouvant mener à des incohérences de segmentations. De plus,

l'imagerie médicale évolue rapidement et fournit des images de grande taille avec des résolutions de plus en plus haute. Le nombre d'images médicales à segmenter croissant ainsi que le nombre de modalités d'imagerie, les praticiens ont plus que jamais besoin d'outils informatiques pour les assister dans leurs tâches. C'est pourquoi une variété de techniques ont été proposées durant cette dernière décennie pour répondre à la problématique de la segmentation de la prostate avec différents types d'imagerie (TDM, IRM, échographie, ...). En particulier, l'imagerie IRM permet de mieux visualiser les structures internes de la prostate. Cependant, l'imagerie TDM reste la référence, car elle permet d'effectuer la planification du traitement.

Dans ce contexte, l'objectif de notre travail a été de proposer des méthodes de segmentation de la prostate et de ses OAR associés qui ont été identifiés comme étant le rectum, la vessie et les têtes fémorales. Comme les OAR ont des intensités assez homogènes dans l'image, nous nous sommes orientés vers une méthode rapide, semi-automatique, utilisant la technique de sur-segmentation de l'image en plusieurs petites régions homogènes appelée superpixels, puis de les regrouper afin de former les OAR à segmenter. De plus, nous utilisons les segmentations des OAR comme *a priori*, afin de déterminer un sous-volume de l'image dans lequel se trouve la prostate. Ce volume d'intérêt (VOI) permet d'éviter une recherche de la prostate dans l'image entière, rendant le processus de segmentation plus rapide et plus automatique. Considérant la variabilité de formes de la prostate et leur contours assez flous dans l'image, nous avons décidé d'utiliser une méthode automatique basée sur des multi-atlas avec contrainte de parcimonie permettant de sélectionner des caractéristiques discriminantes pour décrire les tissus prostatiques. Cette approche multi-atlas permet également de profiter des segmentations déjà réalisées manuellement par des médecins pour rendre la segmentation plus stable et précise.

Dans un premier chapitre, nous présentons le contexte médical, les différents types d'imageries et la problématique de la segmentation sur ces images dans le cadre de traitement du cancer de la prostate par radiothérapie. Nous présentons en particulier le principe d'acquisition des images médicales, leurs avantages et leurs inconvénients propres, mais également leur complémentarité dans le cadre de leur utilisation en radiothérapie.

Au second chapitre, nous présentons un état de l'art des méthodes de segmentation

de la prostate en imagerie TDM et IRM. Dans certaines études, les segmentations des OAR sont associées à celle de prostate. Il est cependant rare que la segmentation des OAR soit abordée seule. Nous présentons donc l'ensemble des travaux dans le cadre de la segmentation de la prostate.

Le troisième chapitre présente le principe des superpixels et leur utilisation en imagerie médicale sur laquelle notre méthode pour la segmentation des OAR est basée. Nous y présentons les différentes étapes permettant de mener à bien cette segmentation semi-automatique des OAR, ainsi que l'étude des paramètres permettant d'optimiser ces segmentations sur des images TDM et IRM, ainsi que la reproductibilité de la méthode.

Le quatrième et dernier chapitre est consacré à l'étude de notre méthode de segmentation multi-atlas avec contrainte de parcimonie. Nous y présentons les différentes étapes menant à la segmentation de la prostate en commençant par l'extraction du volume d'intérêt dans lequel se trouve la prostate. Puis, les notions de patches et de multi-atlas sont ensuite abordés, ainsi que la sélection de caractéristiques sous la contrainte parcimonieuse, à deux échelles : superpixel et pixel. Ainsi, la prostate est automatiquement segmentée à l'aide des caractéristiques textuelles sélectionnées. Enfin, notre méthode a été testée sur la base de données IRM du challenge ISBI 2013, ainsi qu'une base de données TDM de patients du Centre Henri Becquerel, montrant sa bonne performance en comparant avec d'autres méthodes.

Chapitre 1

Contexte médical et problématique de segmentation

Sommaire

1.1	Le cancer de la prostate	8
1.2	La radiothérapie externe	8
1.2.1	Principe	8
1.2.2	La prostate et les organes à risque	10
1.2.3	Prescription médicale	11
1.3	Image médicale numérique	12
1.4	Imagerie par tomодensitométrie – TDM	13
1.4.1	Principe	13
1.4.2	Reconstruction tomographique	14
1.4.3	Origine du contraste	15
1.5	Imagerie par résonance magnétique nucléaire – IRM	17
1.5.1	Principe	17
1.5.2	Origine du contraste	19
1.5.3	Reconstruction	20
1.6	Comparaison d’images TDM et IRM de la prostate	21
1.7	Conclusion	23

1.1 Le cancer de la prostate

En France et en Europe de l'ouest en général, le cancer de la prostate est le cancer masculin le plus fréquent [INSTITUT NATIONAL DU CANCER (INCA) 2016]. Il cumule 56841 nouveaux cas en 2012 en France métropolitaine, loin devant le cancer du poumon (environ 28000 cas) et le cancer du côlon-rectum (environ 23000 cas).

En 2009, 8950 décès par cancer de la prostate en France métropolitaine ont été estimés. En 2012, ce chiffre est descendu à 8876. Cette baisse est le résultat de diagnostics plus précoces et de traitements plus efficaces. Malgré le recul du décès par cancer de la prostate, le risque pour un homme d'avoir ce type de cancer diagnostiqué au cours de sa vie est en augmentation. La prise en charge du cancer de la prostate est donc un très fort enjeu de santé publique.

Les moyens de traitement de ce cancer sont :

- la chirurgie,
- la radiothérapie externe,
- la surveillance active,
- l'hormonothérapie,
- la chimiothérapie plus rarement.

Ces traitements peuvent être utilisés seuls ou combinés. La chirurgie et la radiothérapie sont les deux principaux traitements mis en place. Dans tous les cas, le traitement est personnalisé par l'oncologue en fonction de nombreux critères et selon des arbres de décisions thérapeutiques.

Nos travaux visent à améliorer le traitement du cancer de la prostate par radiothérapie externe.

1.2 La radiothérapie externe

1.2.1 Principe

La radiothérapie externe utilise la capacité d'obtention de la mort cellulaire des rayonnements ionisants. L'objectif de la radiothérapie externe est de détruire les cellules tumo-

rales en conservant aussi intactes que possible les cellules saines avoisinantes. Pour le traitement du cancer de la prostate, les rayonnements ionisants utilisés sont des photons de haute énergie, produits par un accélérateur linéaire de particules (voir Figure 1.1).

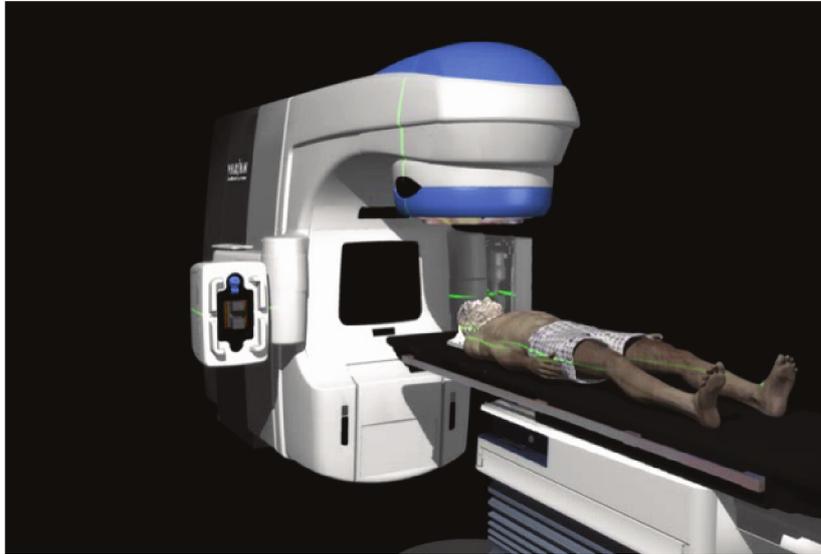


FIGURE 1.1 – Accélérateur linéaire de particule avec un patient positionné sur la table de traitement.

Les rayons ionisants sont dirigés en faisceaux vers la tumeur à travers des tissus. L'un des enjeux majeurs du traitement est de cibler la lésion tumorale tout en préservant les tissus sains avoisinants appelés Organes À Risque (OAR). Pour ce faire, une imagerie initiale est réalisée, afin de segmenter la cible tumorale et les OAR. Cette étape est effectuée lors de la phase de planification du traitement.

Le traitement a lieu en positionnant plusieurs faisceaux de façon à irradier la lésion tumorale de manière uniforme. Un exemple de planification du traitement du cancer de la prostate est donné en Figure 1.2 dans le cas de quatre faisceaux positionnés à 90° les uns des autres. La zone dans laquelle les rayons se croisent est la zone où est localisée la tumeur à traiter. L'intersection des rayons présente une concentration d'énergie maximale. Le traitement est défini par un dépôt d'énergie E dans la matière quantifié par la dose en Gray définie selon l'expression suivante :

$$\text{Dose (Gray)} = \frac{\text{Énergie (Joule)}}{\text{Masse (Kg)}} \quad (1.1)$$

Le traitement est défini par une dose en Gray que doit absorber la zone tumorale.

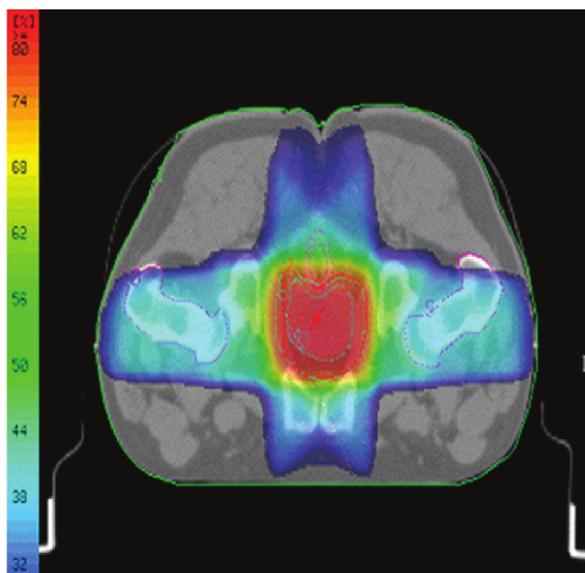


FIGURE 1.2 – Exemple de planification de traitement du cancer de la prostate par radiothérapie à l'aide de 4 faisceaux positionnés à 90° les uns des autres. L'intersection des 4 faisceaux est la zone où l'irradiation est maximum.

L'oncologue détermine ce traitement, planifié dans le temps, en fonction de la localisation, du type de tumeur, de l'historique du patient, etc., afin que le patient absorbe la dose prescrite.

1.2.2 La prostate et les organes à risque

1.2.2.1 La prostate

La prostate est une glande de l'appareil génital masculin dont le rôle est de produire une petite partie des sécrétions qui, avec les spermatozoïdes, constituent le sperme¹. C'est dans cette glande qu'une cellule normale peut se transformer et se multiplier de façon anarchique formant une masse tumorale. Avec le temps, celle-ci peut s'étendre au-delà de la prostate en empruntant les vaisseaux sanguins ou lymphatiques. Les cellules tumorales se propagent dans d'autres parties du corps telles que les ganglions lymphatiques, les os, le foie ou les poumons et forment des métastases (tumeurs malignes envahissant des tissus à distance de la tumeur primaire).

Lors du traitement du cancer de la prostate, l'ensemble de la glande est considérée comme une cible tumorale à irradier. Dans certains cas, il convient d'y associer des aires

1. ©Les traitements du cancer de la prostate, collection Guides patients Cancer info, INCa, novembre 2010.

ganglionnaires (à proximité de la prostate) susceptibles d'être envahies. Dans le cadre de notre travail, nous nous limiterons au traitement exclusif de la prostate.

1.2.2.2 Les organes à risque

Les organes à risque sont susceptibles d'être irradiés au cours du traitement. Ils sont à protéger au contraire de la cible tumorale. Ceux-ci étant sensibles aux rayonnements ionisants, minimiser la dose reçue est nécessaire, afin d'éviter d'y développer une radionécrose à relativement court termes (quelques semaines après le traitement) ou un cancer radio-induit à long terme.

Les volumes contenant ces organes à risque sont à isoler de la zone à traiter lors de la phase de planification. Ces organes sont résumés dans le Tableau 1.1.

Organe	Prostate	Rectum	Vessie	Têtes fémorales
Type	cible	à risque	à risque	à risque

TABLEAU 1.1 – Liste des organes à segmenter dans le cadre du traitement du cancer de la prostate par radiothérapie externe.

1.2.3 Prescription médicale

La prescription du radiothérapeute consiste à définir une dose uniforme à délivrer dans un volume tumoral appelé GTV (Gross Tumor Volume) ainsi que des contraintes de dose à ne pas dépasser pour les OAR. Ces zones sont segmentées par le radiothérapeute.

La dose absorbée dans le GTV est déterminée en trois dimensions (3D) à l'aide de l'imagerie 3D par rayons X, c'est à dire la tomодensitométrie (TDM ou scanner à rayons X). Cette imagerie TDM est utilisée comme modalité de référence. L'imagerie par résonance magnétique (IRM) a également été proposée dans la littérature pour segmenter la prostate à visée de radiothérapie.

À partir de ces informations (imagerie 3D segmentées), les dosimétristes choisissent et adaptent la balistique (les faisceaux d'irradiation), afin de respecter la prescription médicale lors de la phase de simulation. Ensuite, un calcul dosimétrique permet de déterminer la distribution 3D de la dose absorbée. Un exemple de distribution de dose 3D est donné en Figure 1.2.

Le patient reçoit la dose prescrite par fraction de dose, par exemple, cinq jours par semaines pendant plusieurs semaines, suivant la prescription du radiothérapeute. Typiquement, lors d'un traitement par radiothérapie externe exclusive du cancer de la prostate, les doses sont 70 à 80 Gray pendant six à huit semaines à raison de 2 Gray par séance.

1.3 Image médicale numérique

Une image numérique, au sens large, peut être définie comme une matrice avec L lignes et C colonnes. Chaque cellule de la matrice stocke une valeur, encore appelée intensité ou niveau de gris. Dans le cadre d'une image plane, chaque cellule est appelée pixel, abrégé de *picture element*. L'ensemble de ces pixels remplissant une matrice forme alors une image. Cette image est dite 2D puisqu'elle n'a que deux dimensions, à savoir la largeur et la hauteur de l'image, définies par le nombre de lignes et de colonnes.

Il est possible d'ajouter une dimension supplémentaire à cette image en superposant en couches plusieurs images 2D. Elle est donc dite 3D puisqu'elle possède 3 dimensions. Cette troisième dimension permet d'obtenir un volume ou également un ensemble d'images 2D qui sont également appelées coupes du volume 3D. Les éléments d'une matrice 3D sont appelé voxels, abrégé de *volume element*.

L'imagerie médicale est plus spécifique. De manière générale, les volumes sont visualisés selon un plan transverse qui séparent le corps en une partie supérieur et une partie inférieur. Les deux autres plans sont le plan frontale, qui va de l'avant vers l'arrière et le plan sagittal, qui va de gauche à droite. Ces trois plans sont visibles sur la Figure 1.3. Les techniques d'acquisition, de visualisation et de traitement des images médicales privilégient les coupes transverses du volume. Cependant, les outils actuels permettent d'obtenir des coupes dans n'importe quelle direction du volume par reconstruction des images. Ces coupes ne sont pas forcément orthogonales aux plans de la matrice 3D et offrent ainsi de nouvelles interprétations des images.

Les pixels en eux-même ont une taille, permettant de savoir quelle quantité d'information ils contiennent. En général, les coupes transverses restent des matrices carrées, contrairement à la troisième dimension (épaisseur de coupes) qui elle, peut être diffé-

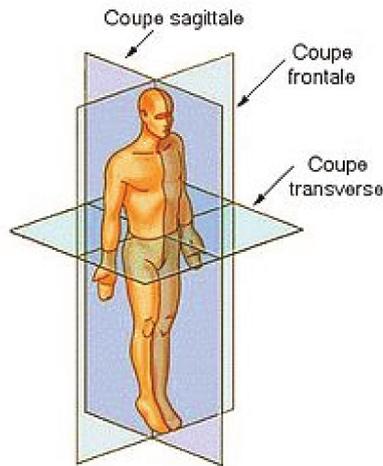


FIGURE 1.3 – Schéma représentant les différents plans de coupes en imagerie médicale.

rente de la tailles des pixels. Par exemple, si une matrice est de taille $128 \times 128 \times 20$ avec une taille de voxels de $2.5 \text{ mm} \times 2.5 \text{ mm} \times 4 \text{ mm}$, cela signifie que la matrice 3D représente physiquement un cube de taille $(128 * 2.5) \text{ mm} \times (128 * 2.5) \text{ mm} \times (20 * 4) \text{ mm}$ soit $25.6 \text{ cm} \times 25.6 \text{ cm} \times 8 \text{ cm}$.

1.4 Imagerie par tomодensitométrie – TDM

1.4.1 Principe

Le scanner ou tomодensitométrie est une technique d'imagerie basée sur la mesure d'atténuation de la projection d'un rayon X après passage dans un tissu. L'appareil scanner ou tomодensitomètre est composé d'un générateur de rayons X pouvant tourner tout autour du patient et d'un système de détection des photons, solidaire du générateur, mais positionné à 180° par rapport au patient (voir Figure 1.4). Dans le cas d'un système d'imagerie par rayons X, le phénomène observé est l'atténuation des photons à la traversée des tissus biologiques selon une imagerie 3D en coupes. Plus la matière traversée par le photon est dense (c'est-à-dire qu'elle possède un numéro atomique élevé), plus le signal perçu par le détecteur est atténué et inversement.

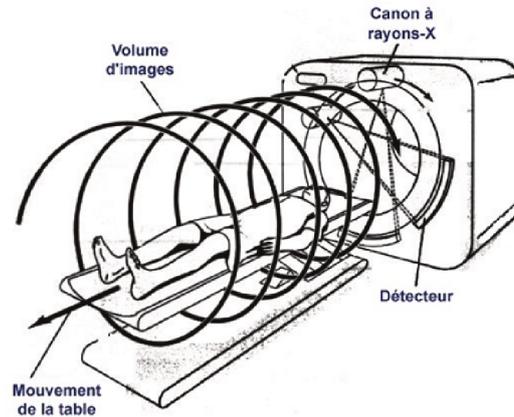


FIGURE 1.4 – Schéma représentant le fonctionnement d'un tomographe.

1.4.2 Reconstruction tomographique

Lors de la rotation du générateur de rayons X, un ensemble de projections d'images du patient selon différents angles sont acquises. Afin d'obtenir un ensemble de coupes formant une image en 3D du patient, le principe de rétro-projection est utilisé. Pour cela, à chaque angle de rotation, un épandage des valeurs d'une projection est fait sur l'image.

Par exemple, une image de test contenant deux solides en Figure 1.5 (a), est projetée selon les angles $\theta = [0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}]$. Au fur et à mesure de l'épandage, les zones contenant de l'information apparaissent de mieux en mieux comme le montre la Figure 1.5 (b). Avec un nombre de projection croissant, le résultat s'améliore comme il est visible sur la Figure 1.5 (c). Cependant, des artefacts en étoile persistent après l'épandage et un flou apparaît. Afin de limiter ces effets, les images finales sont reconstruites sur le principe de la rétro-projection filtrée dans l'espace de Fourier [DUBOIS 1998] donnant un résultat comme visible sur la Figure 1.5 (d).

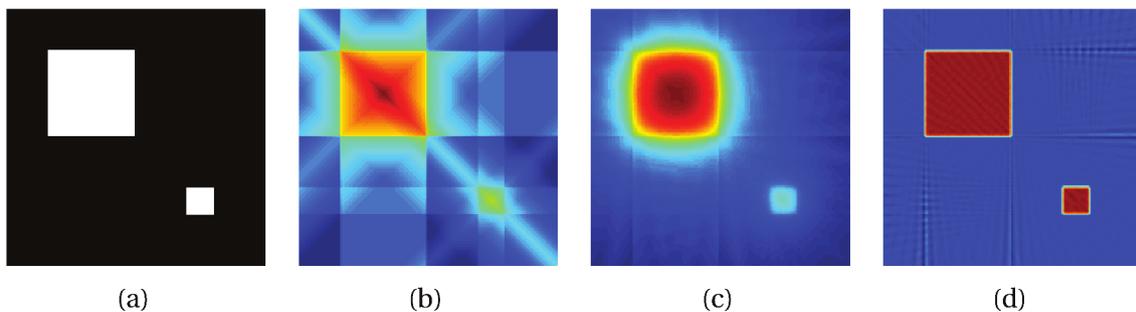


FIGURE 1.5 – Image de test (a) et son épandage pour (b) 4 projections, (c) 20 projections puis (d) filtrée.

1.4.3 Origine du contraste

1.4.3.1 Coefficient d'atténuation linéique

Connaissant l'intensité I_0 des photons émis par l'appareil avant traversée d'une matière d'épaisseur l , il est possible de calculer l'atténuation du faisceau grâce à la loi :

$$I = I_0 e^{(-\mu \cdot l)} \quad (1.2)$$

avec μ le coefficient d'atténuation linéique du milieu et I l'intensité du faisceau après avoir traversé une matière.

Pour un élément simple, il est alors possible, à partir de l'équation (1.2), de calculer son coefficient d'atténuation connaissant l'épaisseur l :

$$\mu = \frac{\ln(I_0/I)}{l} \quad (1.3)$$

Le rayon X peut parcourir plusieurs matières d'épaisseurs différentes. Dans ce cas, l'équation (1.3) devient :

$$\sum_{i=0}^M \mu_i = \frac{\ln(I_0/I)}{L} \quad (1.4)$$

avec M le nombre de matières différentes traversées, μ_i le $i^{\text{ème}}$ coefficient d'atténuation linéique correspondant à la $i^{\text{ème}}$ matière et L la distance totale traversée.

Dans le cas de la Figure 1.6, le signal en sortie sera :

$$I = I_0 e^{-(\mu_1 \cdot l_1 + \mu_2 \cdot l_2 + \mu_3 \cdot l_3 + \mu_4 \cdot l_4 + \mu_5 \cdot l_5 + \mu_6 \cdot l_6)} \quad (1.5)$$

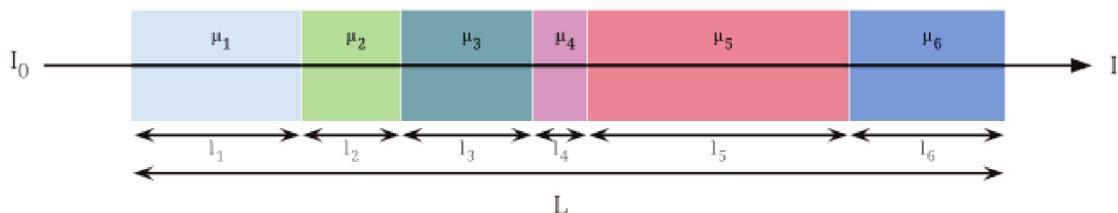


FIGURE 1.6 – Exemple d'atténuation du signal par six matières de différentes largeurs l et ayant chacune leur propre coefficient d'atténuation linéique μ .

1.4.3.2 Nombre d'Unité Hounsfield

Le phénomène quantifié par le détecteur est directement lié aux coefficients linéiques des éléments traversés par les rayons X. Il a alors été décrit une échelle, afin de définir l'intensité associée à chaque pixel de l'image formée de la manière suivante :

$$N = \frac{\mu_{tissus} - \mu_{eau}}{\mu_{eau}} \times 1000 \quad (1.6)$$

avec N le nombre d'Unité Hounsfield (UH), ainsi que μ_{tissus} et μ_{eau} respectivement les coefficients d'atténuation linéique des tissus traversés et de l'eau.

Cette échelle comporte trois valeurs nettement identifiées :

- -1000 pour l'air,
- 0 pour l'eau,
- +1000 (et au delà) pour l'os.

La Figure 1.7 montre la répartition des différents tissus par rapport aux valeurs d'UH.

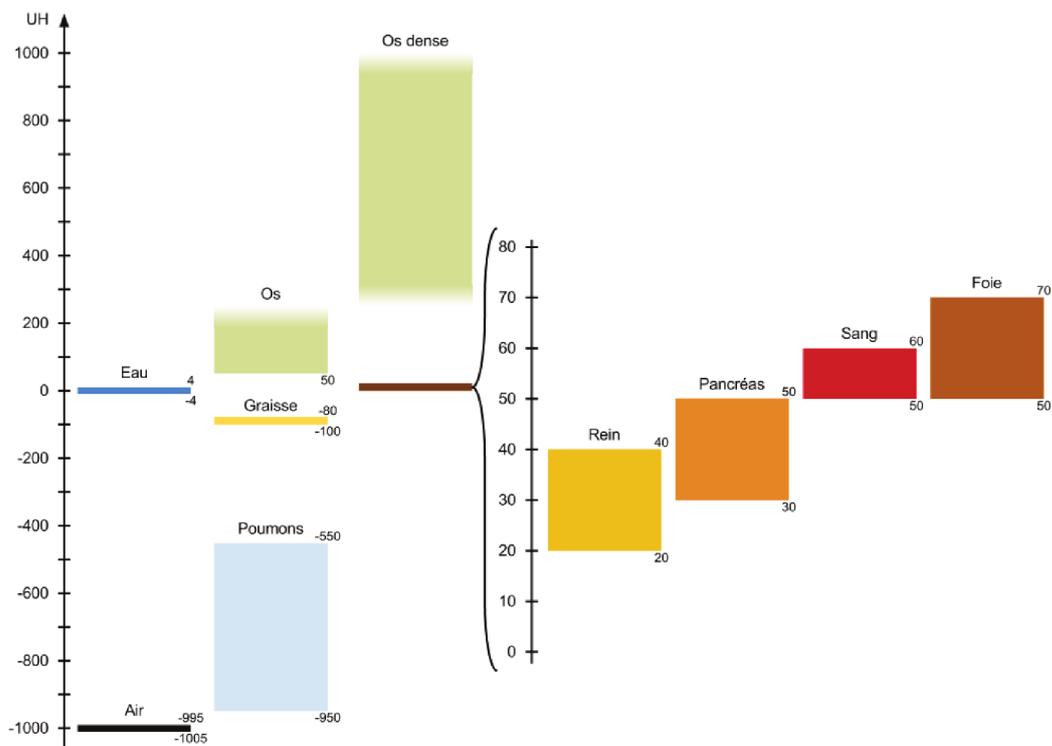


FIGURE 1.7 – Positionnement des tissus biologiques sur l'échelle de représentation en Unité Hounsfield.

1.4.3.3 Contraste dans les tissus biologiques

Le coefficient d'atténuation linéique μ est fonction de deux paramètres :

$$\mu = f(d, E) \quad (1.7)$$

avec d la densité du milieu traversé par les rayons X et E l'énergie des photons.

Comme le montre la Figure 1.7, il est possible de regrouper les valeurs de μ dans quatre grands groupes de tissus en fonction de leur densité :

- $d \approx 0,3$: poumons, et voies aériennes, densité faible, égale ou voisine de l'air,
- $d \approx 0,9$: tissus adipeux (graisses), densité légèrement inférieure à celle de l'eau (valant 1),
- $d \approx 1,04$: tissus mous, muscles, densité légèrement supérieure à celle de l'eau,
- $d \approx 1,8$: tissus osseux, densité élevée.

Un bon contraste est présent entre ces quatre grands groupes de tissus, mais pas au sein d'un même groupe, en particulier au niveau des tissus mous.

L'imagerie par tomodensitométrie est la référence pour effectuer la planification du traitement du cancer de la prostate. Le principal inconvénient de l'imagerie TDM est que le contraste entre les tissus mous est faible puisqu'ils ont des valeurs en UH proches. Afin de les différencier plus facilement, il est possible de s'aider d'une autre technique comme l'imagerie par résonance magnétique nucléaire, détaillée dans la section 1.5 suivante.

1.5 Imagerie par résonance magnétique nucléaire – IRM

1.5.1 Principe

L'IRM est une technique d'imagerie basée sur les propriétés de résonance magnétique des noyaux d'hydrogène. Une description détaillée du principe de l'IRM est donnée dans [DILLENSEGER AND MOERSCHEL 2009]. Bien qu'ils ne représentent que 10% de la masse corporelle, les atomes d'hydrogène participent à 86% de la composition chimique de l'organisme répartie majoritairement dans les molécules d'eau et de graisse.

À l'état naturel, l'aimantation des spins nucléaires des protons d'hydrogène ont tendance à s'annuler en raison de leur distribution aléatoire. En revanche, si ce même échantillon de spins est placé dans un champ magnétique statique intense (\vec{B}_0), les vecteurs d'aimantation microscopique $\vec{\mu}$ associés aux spins des protons ne sont plus distribués de façon aléatoire, mais donnent naissance à deux composantes selon \vec{B}_0 :

- l'une orientée dans le sens inverse de \vec{B}_0 (orientation antiparallèle, spin $-\frac{1}{2}$),
- l'autre, légèrement supérieure en nombre, donne une composante orientée dans le sens de \vec{B}_0 (orientation parallèle, spin $+\frac{1}{2}$).

Les protons en excès selon l'orientation parallèle verront leurs aimantations microscopiques s'additionner pour donner naissance à une aimantation macroscopique notée \vec{M} , orientée dans le sens de \vec{B}_0 , comme visible Figure 1.8.

En IRM, c'est l'étude de cette aimantation macroscopique \vec{M} qui permet d'obtenir des images du corps humain.

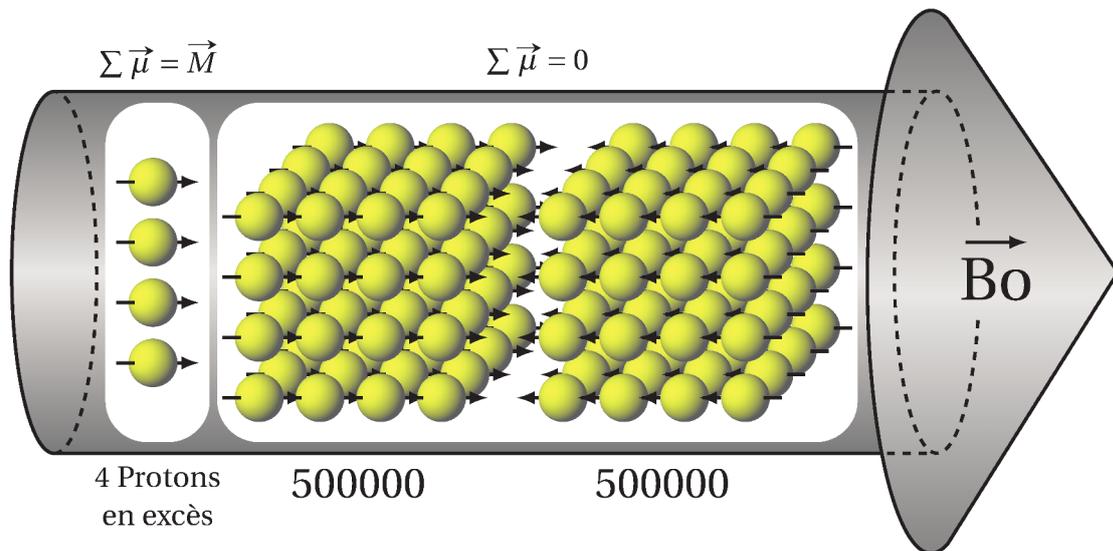


FIGURE 1.8 – Schéma représentant le principe d'aimantation des noyaux d'hydrogène (issue de [DILENSEGER AND MOERSCHER 2009]).

Cependant, cette aimantation est trop faible pour être observée telle quelle. Un moyen technique simple pour observer une aimantation est d'observer ces variations par l'intermédiaire de l'apparition d'un courant électrique dans un circuit fermé. Ce courant est quantifiable en raison de la mise en mouvement d'électrons lorsqu'ils sont placés dans un champ magnétique variable. Ceci s'opère en exploitant le phénomène de réso-

nance qui stipule que pour transmettre de l'énergie à un système en équilibre, il faut le lui apporter avec une fréquence égale à la fréquence propre du système. Dans le cas d'un système de spins nucléaires, le phénomène de résonance se produit grâce à une onde radio-fréquence (RF) ayant la fréquence ν_0 appelée fréquence de Larmor. Cette onde RF est émise par une antenne, directement placée dans l'appareil IRM comme visible sur le schéma de la Figure 1.9. L'antenne surfacique est placée sur le patient, afin d'améliorer le contraste des images acquises.

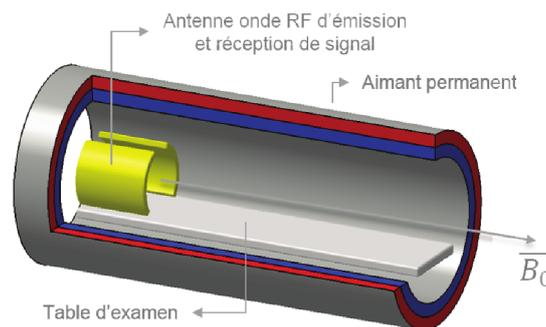


FIGURE 1.9 – Schéma de principe d'un appareil d'IRM.

Cette antenne a une double fonction :

1. provoquer le phénomène de résonance par application d'un courant électrique alternatif de fréquence ν_0 ,
2. enregistrer le signal électrique provoqué par les variations d'aimantation du système de spins.

Dans le cas du cancer de la prostate, une antenne de surface appliquée sur le pelvis du patient est utilisée (Figure 1.10).

1.5.2 Origine du contraste

Lors de l'arrêt de l'onde RF, le système de spins tend à revenir vers sa position d'équilibre selon deux temps de relaxation, T_1 et T_2 , où :

- T_1 est le temps de relaxation longitudinal qui caractérise le retour de M , le long de l'axe de \vec{B}_0 . Ce retour se fait selon l'expression suivante : $M \cdot \left(1 - e^{\left(-\frac{t}{T_1}\right)}\right)$
- T_2 est le temps de relaxation transversal qui caractérise la diminution de l'aimantation dans le plan transverse à \vec{B}_0 . Cette diminution se fait selon l'expression sui-

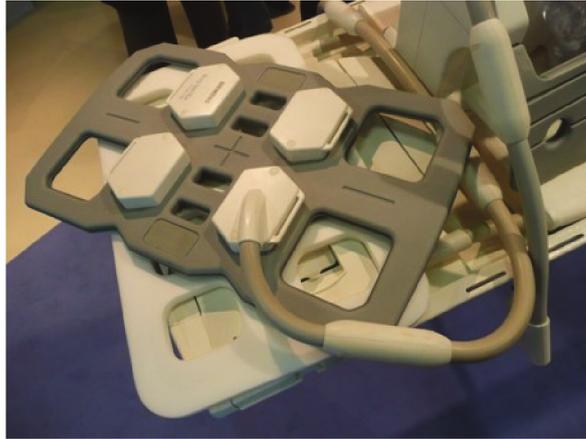


FIGURE 1.10 – Exemple d’antenne surfacique.

$$\text{vante : } M.e\left(-\frac{t}{T_2}\right)$$

Chaque type de tissu est composé d’une densité de proton ρ différente, ainsi que des valeurs de T_1 et T_2 propres.

L’origine du contraste en IRM est plus complexe qu’en imagerie TDM, car il vient des trois caractéristiques tissulaires suivantes : T_1 , T_2 et ρ . Afin de caractériser l’origine du contraste, les acquisitions IRM sont réalisées selon des séquences d’acquisition permettant d’obtenir un contraste venant principalement de T_1 , T_2 ou ρ , appelées séquences pondérées en T_1 , T_2 ou ρ (ou *weighted*). Ces séquences diffèrent dans le nombre et la durée d’application de l’onde radio-fréquence et les délais entre ces applications. En IRM de la prostate à visée de radiothérapie, la séquence généralement utilisée est la séquence *T2-weighted MR axial pulse* [ARCHIVE 2013].

1.5.3 Reconstruction

La méthode de reconstruction des images à partir du signal IRM est basé sur l’application de gradients magnétiques et de la transformée de Fourier [DILLENSEGER AND MOERSCHEL 2009]. Comme la fréquence de Larmor ν_0 est proportionnelle au champs magnétique \vec{B}_0 , le fait d’appliquer des gradients de champs magnétiques modifie spatialement la fréquence de Larmor des spins. Ce principe est utilisé pour localiser spatialement l’origine du signal RMN. Dans la pratique, l’onde radio-fréquence envoyée au système présente une largeur de bande autour de la fréquence de Larmor, afin d’obtenir un phénomène de résonance de l’ensemble des spins, en présence du gradient magnétique.

La transformée de Fourier du signal permet ensuite de localiser son origine spatiale, en accord avec la fréquence de Larmor des spins et du déphasage des signaux. Effectivement, le signal enregistré lors d'une séquence d'IRM est stocké dans l'espace K. L'espace K correspond en fait exactement à un plan de Fourier. Il suffit alors d'appliquer une transformée de Fourier inverse en deux dimensions sur l'espace K pour obtenir une image de la coupe du corps humain.

1.6 Comparaison d'images TDM et IRM de la prostate

Comme nous l'avons décrit dans la section 1.4, l'imagerie TDM est l'imagerie de référence en radiothérapie, car le calcul de la dose absorbée prend en compte la densité des tissus traversés par le rayonnement à partir de la valeur du nombre d'unité Hounsfield. Cette imagerie permet une bonne visualisation des structures osseuses puisqu'elles ont une densité bien plus élevée que les tissus mous avoisinants comme l'illustre la Figure 1.11. La vessie possède également un assez bon contraste. Cependant, ce qui est visualisé est en réalité l'intérieur de la vessie. Or, c'est la paroi vésicale qui doit être segmentée. Lorsque les segmentations sont faites manuellement, des marges sont appliquées par le radiothérapeute, afin d'englober la paroi vésicale. De façon similaire, le rectum possède un faible contraste avec ses tissus avoisinants. Le problème de la paroi rectale est le même que pour celui de la paroi vésicale. Enfin, la prostate est également difficilement visible en imagerie TDM. La résolution spatiale de ce type d'imagerie est de l'ordre du millimètre. Cette méthode est sensible aux artefacts dus à la présence de métaux (prothèses, etc.).

Contrairement à l'imagerie TDM, l'imagerie IRM ne présente pas d'informations exploitables pour les calculs dosimétriques. Actuellement, une segmentation effectuée sur une imagerie IRM nécessite toujours un recalage sur une acquisition TDM du même patient pour pouvoir effectuer la planification de son traitement. Concernant l'imagerie IRM, tout comme en imagerie TDM, les structures osseuses sont bien visibles (voir Figure 1.11). La vessie et plus particulièrement la paroi vésicale possèdent un bon contraste. Concernant le rectum, un bon contraste est également présent. La prostate et même ses différentes structures internes, comme la glande centrale et la zone périphérique sont

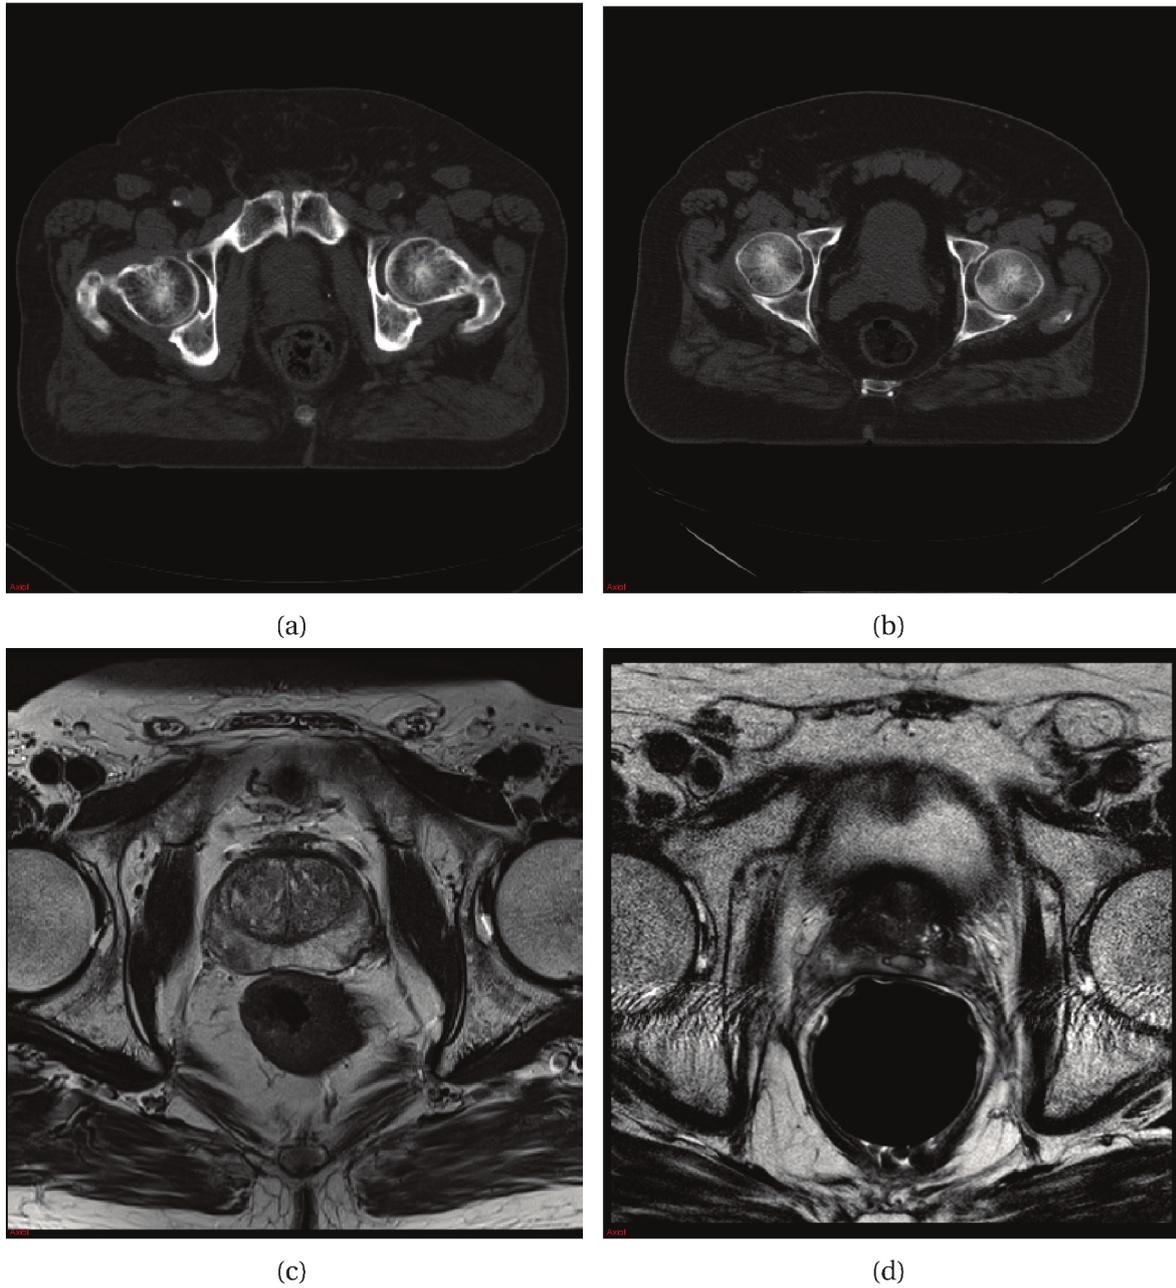


FIGURE 1.11 – Images de coupes de patients différents, en TDM pour (a) et (b), et IRM pour (c) et (d).

visibles sur ce type d'imagerie. Il est donc visuellement possible de différencier la prostate des tissus avoisinants. Par contre, il reste compliqué de la segmenter avec des outils automatiques simples du fait de la présence de textures contrastées, impliquant de forts gradients à l'intérieur même de cette structure. La résolution spatiale est du même ordre de grandeur qu'en imagerie TDM. Par contre, les conditions d'acquisition et de reconstruction étant plus complexes, l'épaisseur des coupes est généralement plus importante en IRM qu'en TDM. La technique est sensible aux artefacts de repliement et est également sensible à des problèmes d'homogénéité de champs magnétique. De ce fait, il peut y avoir des problèmes d'homogénéité de l'image dans une direction de l'espace dû à la technique d'acquisition (application de gradient magnétique). Pour améliorer le recueil du signal, des antennes des surface ou endo-rectales sont utilisées. Elles ont une surface plus ou moins importante avec des problèmes d'homogénéité en bordure du champ observé.

Anatomiquement, le canal anal se trouve dans la continuité du rectum. Cette structure n'est pas considérée comme un organe à risque en radiothérapie. Il n'est donc pas à segmenter. Cependant, il est difficile de connaître la limite entre le rectum et le canal anal aussi bien en TDM qu'en IRM.

1.7 Conclusion

Dans cette première partie, il a été présenté le contexte du développement du cancer de la prostate et des moyens de le traiter, ainsi que le principe du traitement par radiothérapie externe. L'enjeu est de traiter la zone de tissus cancéreux et de limiter l'exposition aux rayonnements des zones saines. La planification du traitement nécessite au préalable une imagerie 3D. L'imagerie de référence en radiothérapie est la TDM. Le fonctionnement de cette modalité a été décrit.

L'imagerie par résonance magnétique nucléaire (IRM) a également été présentée du fait des informations nouvelles qu'elle apporte aux radiothérapeutes. Ensuite, une comparaison entre ces deux techniques d'imagerie présentant les avantages et inconvénients de chacune d'elles a été réalisée.

Une délimitation précise des organes à risque et de la tumeur est cruciale en radiothérapie. L'objectif de notre travail a donc porté sur la segmentation de la prostate et de ses organes à risque sur des images TDM et IRM.

Le chapitre suivant va s'intéresser à l'état de l'art des différentes méthodes proposées dans la littérature pour segmenter les images et plus particulièrement en imagerie TDM et IRM, appliquées au cancer de la prostate.

Chapitre 2

État de l'art des méthodes de segmentation d'images médicales IRM et TDM dans le cadre du cancer de la prostate

Sommaire

2.1	Introduction	26
2.2	Généralité sur la segmentation d'images médicales	27
2.3	Méthodes basées sur les modèles statistiques	28
2.3.1	Construction d'un modèle statistique	29
2.3.2	Segmentation à partir de la modélisation	29
2.3.3	Discussion	31
2.4	Méthodes basées sur les modèles déformables	32
2.4.1	Modèles paramétriques	33
2.4.2	Modèles de contour non paramétriques	33
2.4.3	Discussion	35
2.5	Méthodes basées sur l'apprentissage automatique	36
2.5.1	<i>Artificial Neural Networks</i>	36
2.5.2	<i>Support Vector Machine</i>	38
2.5.3	Discussion	39
2.6	Méthodes basées sur le graphe	39
2.6.1	<i>Graph-cut</i>	40
2.6.2	Superpixels	40
2.6.3	Discussion	41
2.7	Méthodes basées atlas	43
2.7.1	Méthodes utilisant un atlas unique	43
2.7.2	Méthodes utilisant un mutli-atlas	44
2.7.3	Discussion	46
2.8	Conclusion	47

Ce chapitre s'intéresse aux méthodes de segmentation d'images en général, ainsi qu'à celles appliquées spécifiquement au traitement par radiothérapie de la prostate, en imagerie anatomique IRM et TDM.

2.1 Introduction

La segmentation d'images consiste à la partitionner en régions. L'objectif est alors de regrouper les pixels de l'image en régions selon plusieurs critères prédéfinis pouvant être basés sur : l'intensité, la texture, la contiguïté des valeurs, la position, les contours, ainsi que d'autres connaissances demandant des traitements de l'image plus poussés. Cette étape est essentielle dans le processus d'exploitation de l'image comme, par exemple, l'analyse, la visualisation et la planification de traitement. Dans notre cas, nous cherchons à extraire plusieurs régions d'intérêt qui sont des organes sur des images médicales IRM et TDM à savoir la prostate et les OAR associés tels que le rectum, la vessie et les têtes fémorales.

Tout d'abord, des généralités sur la segmentation d'images seront présentées. Dans un second temps nous présenterons les grandes catégories de méthodes de segmentation en indiquant leurs principes, leurs utilisations proposées dans la littérature pour la segmentation de la prostate et des organes à risque, ainsi que leurs avantages et leurs inconvénients. La présentation de ces méthodes a pour but de justifier les grandes orientations prises lors de nos recherches et de nos développements.

Comme nous l'avons vu précédemment au chapitre 1 section 1.6, la segmentation de la prostate est plus complexe que celle des OAR. Par ailleurs, les travaux de la littérature, même à visée de radiothérapie, s'intéressent plus à la segmentation de la prostate, qu'à celle des OAR. De ce fait, l'étude bibliographique, porte généralement sur les méthodes de segmentation de la prostate. La segmentation des OAR est évoquée lorsqu'elle est associée à celle de la prostate.

2.2 Généralité sur la segmentation d'images médicales

Depuis que la segmentation d'image joue un rôle essentiel dans la récupération d'information pertinente, l'extraction efficace de toutes les informations et les caractéristiques contenues dans des images multidimensionnelles est d'une importance croissante dans ce domaine. Comme introduit dans le chapitre 1, les images médicales brutes sont représentées par une matrice contenant des nombres représentant le contraste entre les différents types de tissus du corps humain. La valeur des pixels peut varier en fonction de la modalité d'image, du type de tissus ou encore des paramètres d'acquisition. Traiter et analyser ces images médicales est nécessaire, afin de transformer ces données brutes en données quantifiables. De ce fait, la segmentation a une grande valeur clinique puisqu'elle est souvent la première étape dans l'analyse quantitative d'image. Elle joue donc un rôle important dans de nombreuses applications médicales [PHAM 2000]. Par exemple, en radiothérapie, la segmentation des images médicales permet d'identifier une cible anatomique et définit les contours de la structure d'intérêt pour l'aide à la prise de décision du traitement et de sa planification.

Cependant, la segmentation d'images médicales se distingue d'autres types de segmentation d'images et reste une tâche difficile d'une manière générale. De nombreuses modalités d'imagerie médicale produisent des images bruitées et floues dues à leur processus d'acquisition intrinsèque. Notamment, pour le bien être des patients, les radiologues cherchent à minimiser le temps d'acquisition des images. Cette décision implique une baisse de qualité des images ainsi produites par les imageurs. De plus, les images médicales peuvent être peu échantillonnées. Dans ce cas, des pixels contiennent une valeur de plus d'un seul type de tissu. Cet effet, appelé Effet de Volume Partiel (EVP), rend les contours des objets flous. Plusieurs organes peuvent également avoir la même valeur que celle des tissus proches. Cela empêche d'avoir un contour bien défini autour de l'organe d'intérêt. Dans ces cas, les structures sont difficiles à séparer de leur entourage.

Ces problèmes nécessitent d'avoir des connaissances *a priori* plus élevées, notamment anatomiques, afin de correctement segmenter des images médicales. C'est pourquoi, une expertise est indispensable pour comprendre et interpréter ces images médi-

cales, afin de donner les éléments nécessaires aux outils de segmentation répondants aux besoins des radiothérapeutes.

En segmentation d'images, trois approches sont possibles : les méthodes automatiques, semi-automatiques et manuelles. En imagerie médicale, la méthode manuelle, bien que longue, fastidieuse et non reproductible aussi bien en intra qu'en inter-observateur, est considéré la plupart du temps comme la méthode de référence lorsqu'elle est réalisée par un médecin spécialiste. Du point de vue du traitement de l'image, les méthodes automatiques sont privilégiées, car elles assurent la reproductibilité de la segmentation. D'un point de vue plus pragmatique, les méthodes semi-automatiques sont appréciées dans le domaine médical, ne serait-ce que pour la définition du volume d'intérêt initial qui englobe l'organe à segmenter, mais également lors de la phase de segmentation et/ou la possibilité d'apporter des corrections en fin de segmentation. Par ailleurs, les médecins sont particulièrement sensibles à l'efficacité des méthodes de segmentation proposées, mais également à leur rapidité d'exécution. De ce fait, une approche semi-automatique est souvent proposée dans le domaine médicale.

L'objectif de ce chapitre est de fournir un état de l'art des méthodes de segmentation de la prostate et des OAR associés. Ces méthodes peuvent être divisées en cinq catégories :

1. modèles statistiques,
2. modèles déformables,
3. méthodes basées sur l'apprentissage automatique,
4. méthodes basées graphe et
5. méthodes basées atlas.

2.3 Méthodes basées sur les modèles statistiques

Les méthodes basées sur les modèles statistiques utilisent des informations *a priori* de formes afin d'apprendre les variations d'un ensemble de données annotées. Cela permet de contraindre l'espace de recherche uniquement à des formes définies en fonction des formes modélisées par le modèle. Cette méthode est donc essentiellement décompo-

sée en deux parties : construction d'un modèle statistique et segmentation guidée par le modèle.

2.3.1 Construction d'un modèle statistique

2.3.1.1 Modélisation de la forme

De façon basique, la méthode *statistical shape model* consiste en l'extraction d'une forme moyenne et de la définition des modes de variation de cette forme, issue d'une base d'apprentissage. Dans [COOTES 1993], issue de ces travaux précédent [COOTES 1992], un ensemble de points est distribué de façon régulière le long des contours des objets déjà segmentés.

Par la suite, les formes doivent être recalées. Les points étant situés à des endroits similaires sur le contour de la forme, le recalage est souvent rigide et effectué par minimisation de la somme des distances au carrée entre chaque points correspondants.

Une fois les formes recalées, la formes moyenne et les modes de variation de la forme sont extraits. L'analyse en composante principale (ACP) est une méthode souvent utilisée, qui extrait les modes de variation des points. De cette manière, le modèle de formes est exprimé par la somme du modèle moyen et d'un ensemble de modes de variation.

2.3.1.2 Modélisation de la texture

De façon similaire à la modélisation d'une forme, une modélisation de variations de texture a aussi été proposée par [COOTES 1998]. La variabilité des textures est également définie par sa moyenne et ses modes de variations. Après modélisation de la forme, le modèle statistique des niveaux de gris est construit. L'utilisation des deux modèles (de forme et d'apparence) permet de rendre la segmentation plus robuste.

2.3.2 Segmentation à partir de la modélisation

Une fois le modèle statistique appris, il reste à définir le moyen de l'appliquer dans une nouvelle image à segmenter. Cela revient à trouver les meilleurs paramètres pour exprimer le plus fidèlement possible le modèle dans l'image. Les deux méthodes principa-

lement utilisées pour effectuer la segmentation à partir de ce principe sont l'*Active Shape Model* (ASM) et ASM combiné avec *Active Appearance Model* (AAM).

2.3.2.1 *Active Shape Model*

Afin de correctement effectuer la segmentation, il faut tout d'abord initialiser la position du modèle appris, proche de l'objet ciblé. La méthode originale ASM introduite par [COOTES 1995] est un processus d'optimisation qui consiste à déplacer chaque points du contour vers un meilleur emplacement dans l'image à partir du contour initial. Le déplacement des points du modèle de forme est régi par les informations de l'image (niveaux de gris ou caractéristiques), mais également par ses modes de variation qui contraignent la déformation, afin d'éviter des formes d'objets trop aberrantes.

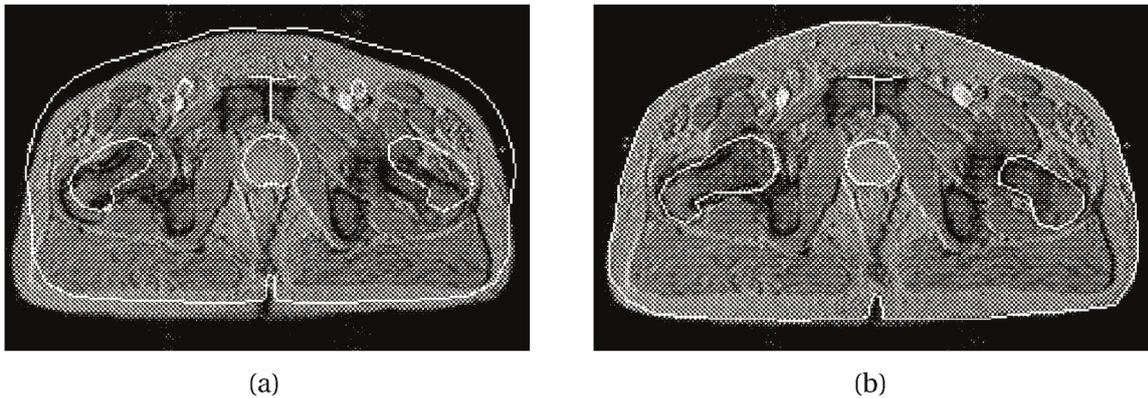


FIGURE 2.1 – Exemple de segmentation par [COOTES 1995] d'une coupe IRM de l'abdomen montrant (a) le placement initial du modèle moyen et (b) le résultat après 100 itérations.

Cette méthode a été appliquée par [COOTES 1993] sur des coupes d'images IRM. Le modèle de forme a été construit, afin de segmenter la prostate, les têtes fémorales et deux artères fémorales, le contour de l'abdomen ainsi que la symphyse pubienne (articulation antérieure du bassin) comme montré sur la Figure 2.1. Cette méthode a été développée pour segmenter une seule coupe. Si l'on souhaite segmenter un volume, le processus d'apprentissage est à effectuer sur toutes les coupes, afin de segmenter entièrement les organes, coupe par coupe. [ZHU 2007] a également appliqué une méthode ASM de manière hybride en prenant des informations en 2D et 3D pour segmenter la prostate sur des images IRM. Cette méthode construit initialement un modèle 3D. L'ASM est calculé sur les coupes en 2D, puis le modèle 3D est mis à jour grâce à l'ensemble de coupes 2D. L'auteur

affirme que cette méthode hybride d'ASM apporte de meilleurs résultats que d'appliquer directement la méthode sur un modèles 3D.

2.3.2.2 *Active Appearance Model*

De façon analogue à la construction du modèle, la méthode de segmentation de l'ASM a été étendue pour prendre en compte les informations de texture. Cette méthode AAM a été introduite par [COOTES 2001].

[TANG 2004] ont utilisé cette méthode sur des images TDM, afin de segmenter la prostate, le rectum et la vessie. En plus du modèle de forme, une fonction de distribution des niveaux de gris à l'intérieur de la forme a été apprise. Cette fonction guide la déformation du modèle des organes. L'application de cette méthode a été montrée en radiothérapie adaptative personnalisée. C'est à dire qu'un même patient bénéficie d'un scanner avant le traitement, puis d'autres scanners pendant le traitement. Ainsi, les segmentations précédentes permettent d'apprendre le modèle et d'adapter le traitement en fonction des nouvelles localisations des organes à certaines instances du traitement. Cependant, cette approche demande un investissement en temps non négligeable. [FENG 2010] a également utilisé la méthode ASM pour segmenter la prostate. L'initialisation du positionnement du modèle est réalisée par le calcul de caractéristiques SIFT [LOWE 1999] (pour *Scale-Invariant Feature Transform*). Les caractéristiques SIFT internes et externes à la prostate sont extraites à partir d'images manuellement segmentées. À partir de ces caractéristiques localisées dans l'image, une concordance est faite avec celles du modèle. Ces concordances permettent d'obtenir une déformation afin de faire correspondre les caractéristiques de l'image avec les caractéristiques du modèle initial. Cette déformation est ensuite appliquée au modèle de la prostate pour effectuer la segmentation finale.

2.3.3 Discussion

Les méthodes basées sur les modèles statistiques demandent d'apprendre un modèle de forme. Les formes moyennes, les textures et leur modes de variation qui définissent un modèle sont appris d'une base d'apprentissage.

L'avantage prépondérant de ces méthodes est leur coût très faible en temps d'exécu-

tion et qu'elles obtiennent des résultats très rapidement, voir même en temps réel comme il l'a été démontré par [YAN 2010] sur des images d'échographie transrectale.

Cependant, si le nombre d'exemples présents dans la base pour construire le modèle n'est pas assez important, il y a un risque de surapprentissage. Le surapprentissage apparaît lorsque le modèle est trop spécifique aux données d'apprentissage et amène à une mauvaise adaptation dudit modèle sur une nouvelle donnée d'entrée. Il perdra alors son pouvoir de prédiction en dehors des exemples utilisés sur lesquels il sera performant.

Lors du processus d'optimisation de l'ASM, le modèle d'intensité et de forme sont alternativement appliqués. Tout d'abord, une fois initialement positionnés sur l'image, les points du modèle sont déplacés dans leur voisinage, afin de correspondre au modèle d'intensité. Ensuite, les contraintes de formes lui sont appliquées. Ces deux étapes sont répétées jusqu'à convergence. Cependant, il arrive que le modèle d'intensité finisse dans un minimum local n'entrant pas en contradiction avec le modèle de forme. Dans ce cas, la position finale du modèle sur l'image est fautive. Par ailleurs, les résultats de l'ASM ou AAM sont très sensibles à l'initialisation du modèle. Cela est dû à la recherche locale effectuée lors du déplacement des points à l'aide du modèle d'intensité. Enfin, les modèles construits dépendent également du recalage des image qui peut poser des problèmes de précision sur l'alignement des contours lors de la construction.

2.4 Méthodes basées sur les modèles déformables

Les modèles déformables, introduits par [TERZOPOULOS 1987], sont décrits par des courbes ou surfaces définies dans le domaine de l'image, déformables sous l'influence de deux forces :

- Interne : influe sur les caractéristiques de la courbes en garantissant un aspect lisse du modèle lors de sa déformation.
- Externe : déforme le modèle, afin de l'attirer vers des caractéristiques de la structure d'intérêt qui sont en relation avec des caractéristiques extraites de l'image calculées dans des régions adjacentes à la courbe.

2.4.1 Modèles paramétriques

Le premier modèle de contour actif a été popularisé sous le nom de *snakes contours* et introduit par [KASS 1988]. La méthode ainsi proposée impose un positionnement manuel du contour initial fermé à proximité des contours de l'objet à segmenter. L'énergie externe appliquée au contour dépend fortement de sa position initiale dans l'image. Cette étape est sensible, car si le contour n'est pas proche de l'objet à segmenter, la segmentation échoue. En initialisant le modèle de contour actif proche du bord de l'objet, il évolue en suivant les directions du gradient en réalisant des déformations successives jusqu'à l'arrêt de l'objet. Également, la présence de bruit dans l'image mène parfois la déformation du contour dans des minima locaux faisant à nouveau échouer la segmentation.

Différentes énergies externes ont été proposées, afin de faire évoluer ce contour comme la force ballon en 3D [COHEN AND COHEN 1993], la force de distance potentielle [ACTON AND RAY 2006] et le flux de gradient de vecteur [XU AND PRINCE 1998]. Ces méthodes ont principalement été appliquées sur des images échographiques transrectales [KNOLL 1999, LADAK 2000, DING 2003, ZAIM AND JANKUN 2007]. Cependant, [BUENO 2004] a exploré cette piste en incorporant une force externe issue d'informations floues. Une image d'intensité floue est extraite de l'image à segmenter, donnant les probabilités d'appartenance à une classe pour chaque pixel en fonction des images d'apprentissage. La prostate est finalement segmentée en ajoutant cette image de probabilité comme force de déformation du contour actif. Cette méthode a été développée sur des images TDM pour la segmentation de la prostate uniquement.

2.4.2 Modèles de contour non paramétriques

Un des problèmes des modèles déformables paramétriques est la difficulté à prendre en compte des changements de topologie tels que la séparation ou la fusion de contours. Par exemple, lorsqu'un objet se scinde en plusieurs parties alors que le modèle n'a été construit que sur des objets uniformes, les objets scindés ne seront compris que dans un seul contour ou un seul sera pris en compte. Afin de combler ce manque de flexibilité de la méthode, les modèles déformables non paramétrique, ou géométrique, ont été implé-

mentés en utilisant un algorithme de *level set*. Cette approche a été initialement développée par [OSHER AND SETHIAN 1988] et ont largement été étudiés dans la littérature depuis. Ces modèles sont décrits comme des surfaces ou contours évolutifs appelés fronts. Ces fronts définissent le *level set* d'une dimension supérieure au domaine de l'image (par exemple trois si la dimension de l'image est de deux).

Les modèles de forme et de la texture de la prostate ont été fusionnés dans les travaux de [TSAI 2003b]. Ces auteurs ont utilisé une forme correspondant sur un ensemble de fonction de *level set* pour segmenter la prostate sur des images IRM. L'un des contours est fixé et utilisé comme emplacement de référence. Les contours des autres patients sont recalés par transformées affines pour minimiser leurs différences. L'analyse en composante principale de la variabilité de la forme est incorporé dans la fonction de *level set*, ainsi que des informations de région tels que la zone, la somme des intensités, intensité moyenne et de l'information de la variance. La minimisation de cette fonction permet la segmentation de la prostate. Les auteurs ont également suggéré un modèle couplé de *level set* de la prostate, du rectum, et les muscles obturateurs internes à partir d'images IRM pour segmenter ces structures simultanément [TSAI 2003a]. L'algorithme accepte que les formes se chevauchent les unes sur les autres. La segmentation finale est obtenue en optimisant l'information mutuelle des trois régions. De même, [LIU 2009b] ont utilisé une ellipse déformable pour segmenter les contours de la prostate en IRM après seuillage selon la méthode proposée par [OTSU 1975]. Une forme contrainte par *level set* initialisée avec la courbe elliptique de la prostate a été utilisée pour affiner les résultats. Enfin, un post-traitement utilisant la carte de gradient d'intensité de la prostate et du rectum permet d'obtenir la segmentation finale.

[ROUSSON 2005] ont utilisé deux contraintes de forme par *level set* pour segmenter simultanément la prostate et la vessie sur des images TDM. Une contrainte de non-chevauchement est imposée pour segmenter la prostate et la vessie à part, en supposant que les deux *level set* évoluent indépendamment les uns des autres. Un terme de pénalité est introduit à chaque fois que deux pixels sont partagés entre deux *level set*, afin de déterminer sa classe d'appartenance. [CHEN 2009] ont utilisé trois *level set* pour segmenter la prostate, la vessie et le rectum en TDM. Ces *level set* se déforment sous l'influence d'une

fonction de distance signée calculée à partir des statistiques de forme, gradients d'intensité, fonction de densité de probabilité de la région et une contrainte de lissage pour segmenter les trois organes. [LU 2011] ont utilisé des *level set* sur la forme et la région pour segmenter la prostate, ainsi qu'un recalage à l'aide de courbes B spline pour minimiser la valeur de corrélation croisée entre l'image d'apprentissage et le stade du traitement pour contraindre les résultats de la segmentation. Les fonctions de segmentation et de recalage sont exécutées de manière itérative pour produire la segmentation finale. Cette méthode étant utilisée dans le cadre de radiothérapie adaptative personnalisée, le recalage est effectué sur les images d'un même patient à des instants différents. Les *level set* sont appris sur les segmentations déjà effectuées des instants précédents, afin de segmenter la prostate, la vessie et le rectum sur des images TDM.

2.4.3 Discussion

Contrairement aux modèles statistiques décrits en section 2.3, les méthodes basées sur les modèles déformables n'ont pas besoin d'apprentissage préalable. Les modèles déformés sont plus flexibles et peuvent évoluer vers la forme souhaitée. Cependant, définir le critère d'arrêt de l'évolution du modèle est une tâche complexe dépendant de l'objet à segmenter.

Par ailleurs, ces méthodes peuvent générer des contours contenant des erreurs de topologie par rapport à l'objet à segmenter lorsque l'image est fortement bruitée et que l'objet possède des écarts importants (par exemple, entre deux têtes fémorales). Dans certains cas, il est nécessaire d'assurer une topologie correcte.

L'utilisation de ce type de méthode est limité à certains types d'images. Les images doivent posséder des contours suffisamment prononcés ou des informations de région pour pouvoir définir un modèle explicite. C'est pourquoi ces méthodes échouent généralement à segmenter des images ayant de fortes inhomogénéités et/ou un faible contraste.

2.5 Méthodes basées sur l'apprentissage automatique

Ces méthodes de segmentation basées sur un apprentissage automatique extraient des caractéristiques sur les images qui offrent plus d'informations que les niveaux de gris. L'objectif global des méthodes basées sur la segmentation supervisée est de définir des règles permettant de classer des objets dans des classes à partir de variables qualitatives ou quantitatives caractérisant ces objets. Il est nécessaire de posséder une base d'apprentissage dont le classement est connu. Cette base est utilisée pour l'apprentissage des règles de classement.

2.5.1 *Artificial Neural Networks*

La méthode *Artificial Neural Networks* (ANN), initiée par [MCCULLOCH AND PITTS 1943], est définie comme un système de traitement d'information constitué d'un grand ensemble de petits composants de traitement d'information inter-connectés appelés neurones. De manière analogue au cerveau humain, les neurones travaillent ensemble de façon distribuée sous forme de réseau pour :

- apprendre des connaissances des données d'entrée,
- traiter l'information,
- produire une réponse pertinente à la sortie.

Chaque neurone n à l'intérieur du réseau traite ses données en entrée en prenant en compte son poids w_n , une valeur de biais b_n , et une fonction de transfert qui somme w_n et b_n . Avec cette structure, différents ANN peuvent être construits en définissant la fonctions de transfert ainsi que la façon de connecter les neurones comme montré Figure 2.2.

Cette méthode est vouée à résoudre des problèmes de classification et est assez peu utilisée en segmentation. [LEE 2003] l'ont cependant utilisé en TDM pour segmenter des organes de l'abdomen : le foie, la rate, les reins, la vessie et le rectum. Dans cette méthode, plusieurs modules sont créés dans le réseau; chacun servant à la segmentation d'un organe. Dans le réseau, un neurone est utilisé pour intégrer et négocier entre les modules pour prendre en considération leurs informations contextuelles. Un pixel est donc évalué

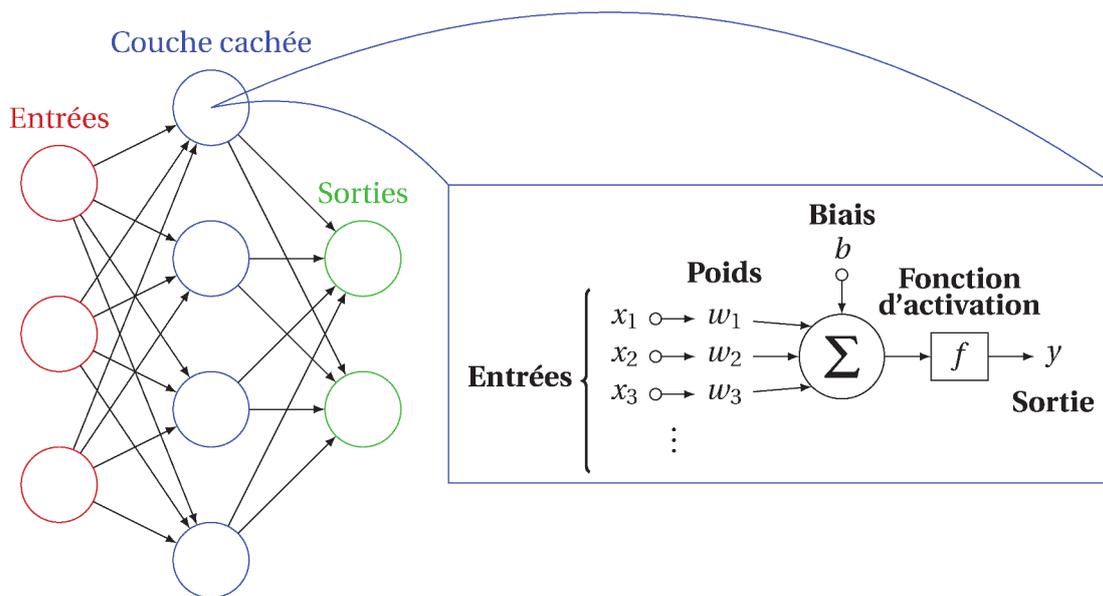


FIGURE 2.2 – Schéma de représentation d'un réseau de neurone (à gauche) avec la représentation de la conception d'un neurone (à droite).

par chaque module, afin de déterminer son appartenance à un organe tout en utilisant le neurone négociant afin d'éviter sa classification dans de multiples organes.

Récemment, une extension aux ANN a été proposée, appelée *Convolutional Neural Networks* (CNN). Les méthodes CNN reprennent le principe des méthodes ANN en prenant comme postula de départ que les informations à traiter en entrée sont forcément des images. Là où une méthode ANN impose de connecter un neurone à tous les neurones de la couche précédente, le CNN n'en connecte qu'une partie. Cela réduit considérablement le nombre de poids d'entrée des neurones et donc des calculs à effectuer par la fonction d'activation de chacun d'eux. De plus, un neurone d'entrée d'un CNN ne va fonctionner que sur une petite partie de l'image qu'il aura extrait au lieu de fonctionner sur toute l'image. Chaque couche du CNN est en fait assimilée à un traitement d'un filtre par convolution sur l'image à traiter. Un classement des pixels est effectué en combinant les résultats des convolutions successives, donc de l'enchaînement des couches du CNN. Cette technique a été récemment utilisé pour la segmentation d'OAR thoraciques en TDM [TRULLO 2017] ainsi que de la prostate en IRM [MILLETARI 2016, SHAH 2016, YU 2017] et démontre des résultats de l'ordre d'autres méthodes de segmentations résumés dans ces travaux.

2.5.2 Support Vector Machine

La méthode la plus employée pour la segmentation est *Support Vector Machine* (SVM) introduite par [CORTES AND VAPNIK 1995] pour effectuer une classification binaire.

Étant donné un ensemble de points d'apprentissage et leur label associé, une méthode SVM permet de faire apprendre un classifieur sur les données d'apprentissage, qui sert à correctement prédire la classe d'un nouveau point. Pour ce faire, il faut définir un hyperplan permettant de séparer l'espace des exemples avec la plus grande marge possible. La marge étant définie par la distance la plus petite entre l'hyperplan et l'exemple d'entraînement le plus proche de cet hyperplan comme visible sur la Figure 2.3.

Cependant, si les données d'exemple ne sont pas linéairement séparable, le classifieur SVM suppose que ces données sont linéairement séparables dans un deuxième espace de plus grande dimension après avoir fait subir une transformation aux données par des noyaux comme visible sur la Figure 2.4.

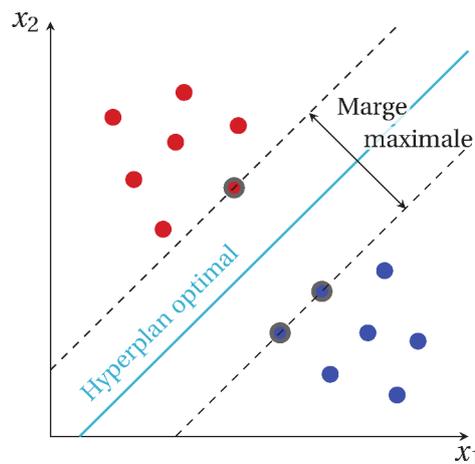


FIGURE 2.3 – Exemple d'un SVM séparant l'espace des exemples avec la plus grande marge possible.

[OZER 2009] et [LITJENS 2011] ont également utilisé la méthode SVM pour segmenter des images IRM multimodales. Des caractéristiques en plus des niveaux de gris ont été ajoutées ainsi que des informations de position anatomique. Une carte de probabilité est obtenue en sortie du SVM. Par la suite, une fonction basée sur un noyau permet d'extraire les maxima locaux de la carte de probabilité. Une sphère est appliquée sur la carte de probabilité au niveau des maxima locaux afin de ne garder que les informations présentes dans ces sphères. Enfin, un SVM est encore appliqué pour classifier ces régions en région

de prostate et de non-prostate. [Li 2011] ont également appliqué la méthode SVM à la segmentation de la prostate en TDM. La méthode, utilisée en radiothérapie adaptative personnalisée, est spécifique à chaque patient. Deux classifieurs sont appris pour localiser la prostate selon deux directions orthogonales de l'espace de l'image (axes axial et sagittal). Chaque classifieur est formé à la fois des caractéristiques d'apparence de l'image, mais également des caractéristiques du contexte de l'image (à différentes échelles et orientations), afin de correctement identifier la région de la prostate. Ces deux résultats sont fusionnés puis une méthode basée *level-set* est utilisée pour obtenir un contour lisse.

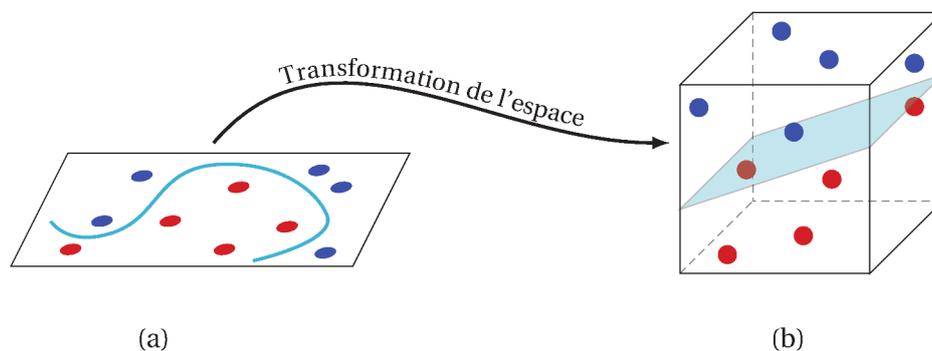


FIGURE 2.4 – Schéma de principe de séparation par SVM en passant (a) d'un espace 2D, non linéairement séparable, (b) à un espace de plus grande dimension, linéairement séparable.

2.5.3 Discussion

Les méthodes basées sur la classification supervisée sont généralement utilisées au niveau du pixel ou voxel. Ces méthodes nécessitent d'effectuer un apprentissage, généralement lourd en terme de temps, et sont de ce fait, dépendantes de l'ensemble de données d'apprentissage. De plus, le temps d'apprentissage augmente d'autant plus que la tâche est complexe.

2.6 Méthodes basées sur le graphe

Les méthodes de segmentation basées graphe considèrent que l'image est un graphe dont les pixels représentent des nœuds et les liens avec les pixels voisins des arrêtes, définies par des coûts. Ce graphe est partitionné en minimisant la fonction de coût et regroupe les pixels dans différentes classes représentant leur similarité. Différents algo-

rithmes de partitionnement de graphes ont été proposés comme *minimum spanning tree*, *minimum cut*, *normalized cuts* [BOYKOV AND VEKSLER 2006].

2.6.1 *Graph-cut*

Cette méthode a été utilisée dans un spectre assez large telle qu'en imagerie médicales comme la segmentation du foie, des poumons, des os ou encore du cœur [GROSGEORGE 2013]. Les différentes applications de la méthode *graph-cut* à l'imagerie médicale ainsi qu'aux images naturelles ont été résumées dans cette étude : [PENG 2013]. De plus, elle montre que très peu de ces méthodes se sont appliquées à la segmentation de la prostate et de ses OAR.

[SONG 2009] a utilisé un graphe pondéré en arc [LI AND JOLLY 2008] pour incorporer des contraintes de forme et des informations de contours pour la segmentation de la vessie et de la prostate sur des images TDM. La connaissance préalable de la forme est introduite en utilisant les poids des nœuds du graphe et des arêtes orientées du graphe ou des arcs. [SONG 2010] ont amélioré la précision de la segmentation en incorporant des informations de distribution d'intensité de la région dans la fonction de minimisation d'énergie optimisée par coupe de graphe. [GHOSE 2012] ont proposé l'utilisation de la méthode *graph-cut* pour obtenir la segmentation final de la prostate à partir d'une image de probabilités calculée à l'aide d'un atlas unique recalé sur l'image. Les méthodes basées sur un atlas sont décrites dans la section 2.7 suivante. Dans le cadre du traitement du cancer de la prostate, [FREEDMAN AND ZHANG 2005] ont utilisé la méthode *graph-cut* en y incorporant un *a priori* de forme afin de segmenter uniquement la vessie sur des images TDM.

2.6.2 Superpixels

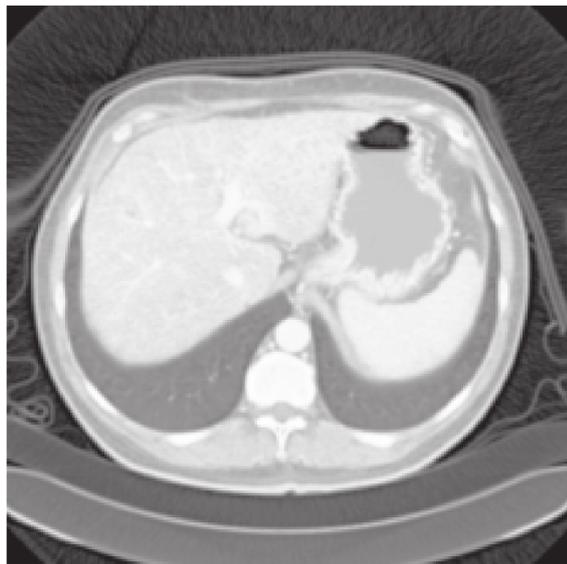
Ces dernières années, des méthodes créant de graphes à vocation de segmentation utilisant une sur-segmentation de l'image sont apparues. La méthode SLIC [ACHANTA 2010] a popularisé cette méthode appuyée sur les superpixels. Le principe d'une méthode basée sur les superpixels est de sur-segmenter une image en beaucoup de petites régions

homogènes.

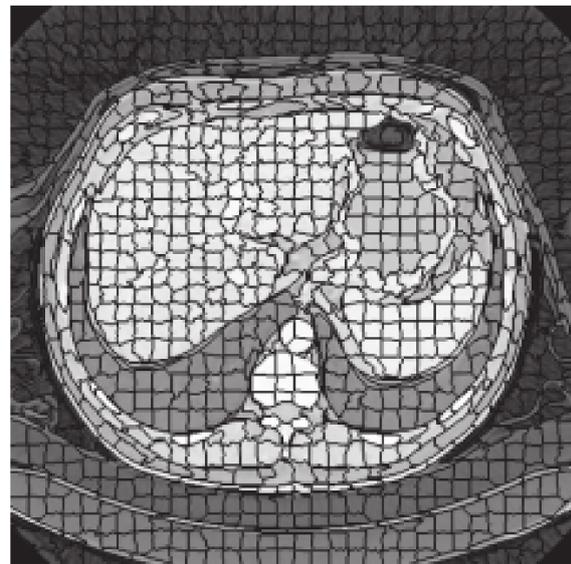
Une fois ces régions créées, un graphe d'adjacence de régions est construit. Chaque nœud du graphe représente une région et chaque arête a un bord en commun avec une région voisine. Les arêtes du graphe sont pondérées par la différence des moyennes des niveaux de gris des deux régions adjacentes. Cette méthode nécessite généralement une labellisation manuelle de certains nœuds du graphe par l'utilisateur par exemple quelques superpixels dans une région prostatique et une région du fond. Enfin, une diffusion sur graphe est calculée afin de diffuser l'information de labellisation sur les nœuds du graphe considérés comme similaires. Cette méthode a été appliquée sur des segmentations de mitochondries sur des images de microscopie par [ACHANTA 2010]. Elle a également été proposée dans le cas de la segmentation du foie (Figure 2.5) sur des images TDM [BUYSSENS 2014]. Plus récemment, [TIAN 2016] a proposé cette technique comme une étape d'initialisation pour segmenter la prostate sur des images IRM. Dans cette méthode, les superpixels sont utilisés pour construire un graphe qui sera binarisé par la méthode de *graph cut* [GREIG 1989]. Le résultat est finalement lissé afin d'obtenir le contour de la segmentation finale.

2.6.3 Discussion

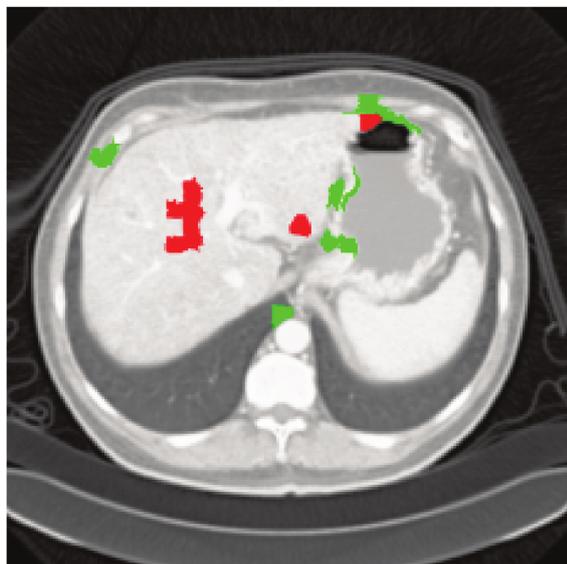
Les méthodes basées sur graphe ont l'avantage de produire rapidement des résultats du fait de leur prise en compte uniquement des informations basiques de l'image comme les valeurs des pixels ou des informations de contours. L'ajout de complexité se trouve au niveau du traitement du graphe construit, comme par exemple la prise en compte d'un *a priori* de forme. Le post-traitement du résultat ajoute également au temps d'obtention des résultats comme un lissage ou un modèle déformable sur la segmentation, afin d'obtenir un contour ou une surface lisse. Malgré la rapide exécution de ce type de méthodes, la segmentation dans des zones faiblement contrastées peut produire des superpixels incluant deux zones anatomiques du fait de l'unique prise en compte des informations de l'image. Comme cette méthode a un faible temps d'exécution, elle est adaptée à la segmentation interactive en temps réel. C'est pour cette raison qu'elle a été étudiée ici pour la segmentation des OAR et présentée dans le chapitre 3.



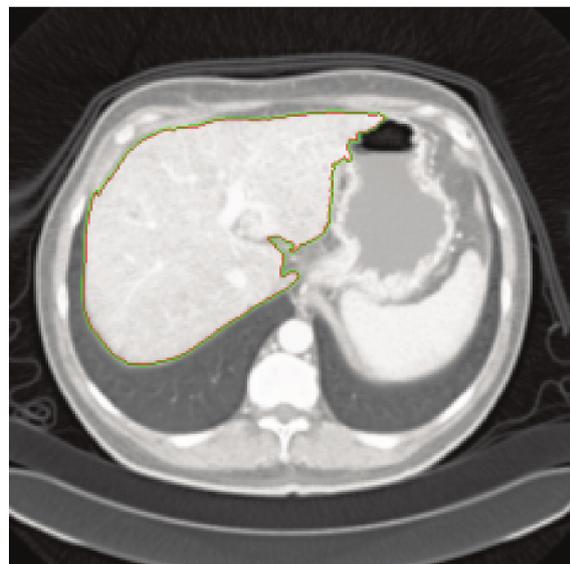
(a) Image initiale



(b) Calcul de superpixels (~1000)



(c) Étape de labellisation manuelle



(d) Résultats de la segmentation

FIGURE 2.5 – Résultats de la segmentation du foie par une méthode de superpixels sur une image TDM par [BUYSSENS 2014].

2.7 Méthodes basées atlas

La segmentation utilisant des méthodes basées atlas peut être décrite par les trois étapes suivantes :

- Construction des atlas,
- Recalage entre les atlas et l'image à segmenter,
- Sélection d'atlas et fusion des labels.

Un atlas contient une image (ou un volume) et la segmentation de l'organe segmenté correspondante. La Figure 2.6 représente ces différentes étapes qui sont décrites dans les sections suivantes.

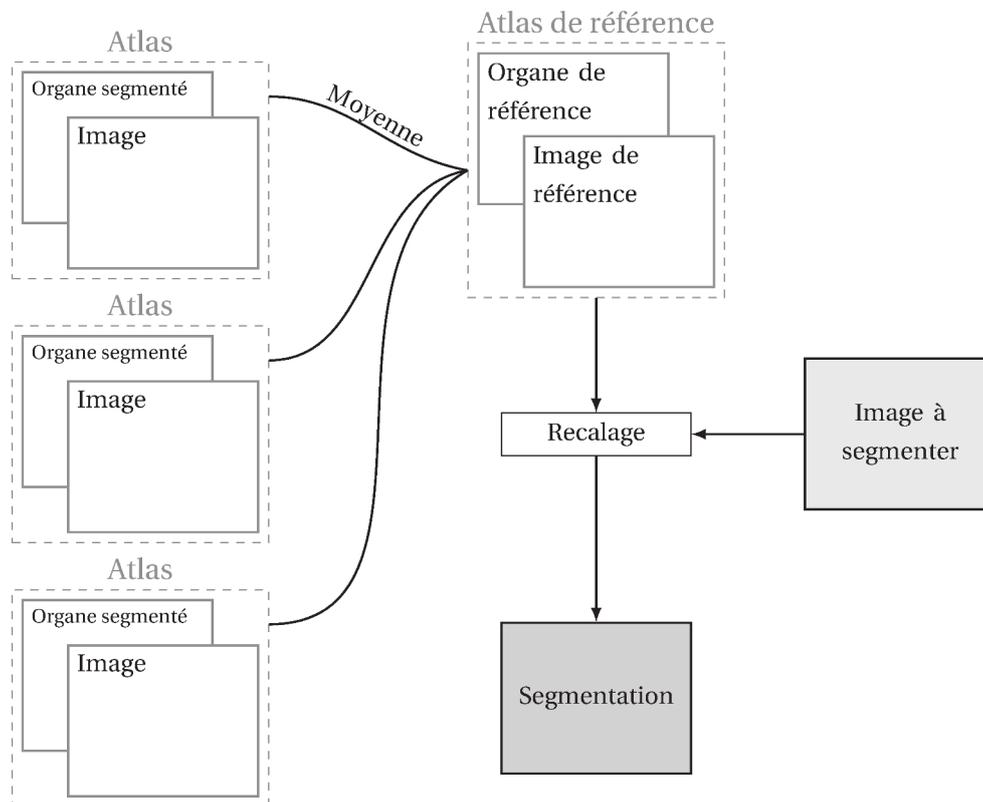


FIGURE 2.6 – Représentation d'une méthode de segmentation basée atlas.

2.7.1 Méthodes utilisant un atlas unique

Un atlas est créé à partir d'un ensemble de segmentations manuelles recalées. Cet atlas est utilisé comme référence pour guider la segmentation d'une nouvelle image. Les techniques de segmentation basées atlas unique consistent à résoudre un problème de

recalage de l'atlas sur la nouvelle image. Ce type de méthodes est pertinent pour la segmentation d'une structure qui est stable sur une large population.

[MARTIN 2008] propose d'utiliser une telle méthode pour segmenter la prostate en IRM. La méthode consiste en une méthode de recalage qui minimise une énergie dépendant des intensités de l'image et des informations de géométrie, afin de recaler l'atlas sur la nouvelle image. La minimisation de l'énergie dépendant des intensités permet de faire correspondre la nouvelle image à l'image de référence alors que l'énergie de géométrie permet de faire correspondre l'atlas de la prostate dans la nouvelle image. Enfin, une méthode basée sur un modèle déformable permet d'obtenir la segmentation finale. [MARTIN 2010] ont récemment proposé d'utiliser un atlas probabiliste, afin d'imposer plus de contraintes spatiales et de segmenter la prostate directement en trois dimensions.

[ACOSTA 2010] proposent de segmenter la prostate, le rectum, la vessie et les os sur des images TDM en utilisant un atlas probabiliste. L'atlas est recalé sur la nouvelle image en utilisant un recalage affine et *demons* (basé sur l'équation du flot optique). Les labels de l'atlas sont transformés avec le même vecteur de transformation de l'image de référence, afin de segmenter la prostate, le rectum, la vessie et les os.

Les méthodes basées sur un atlas unique sont limitées lorsque les variations de l'objet à segmenter sont grandes et peuvent mener à de mauvais résultats de segmentation.

2.7.2 Méthodes utilisant un multi-atlas

Pour palier au problème soulevé par l'utilisation d'un atlas unique, les méthodes utilisant plusieurs atlas (multi-atlas) ont été développées. Cette approche sélectionne plusieurs atlas qui sont les plus ressemblants avec l'image à segmenter dans la base d'apprentissage. Les images correspondantes aux atlas sélectionnés sont recalées sur l'image à segmenter. À cette étape, plusieurs atlas sélectionnés se superposent sur la nouvelle image. Pour pouvoir effectuer la segmentation, une étape de fusion des atlas permet finalement d'identifier l'organe à segmenter. Ces étapes sont résumées sur la Figure 2.7.

[KLEIN 2008] ont utilisé ce principe d'utilisation de multi-atlas afin de segmenter la prostate sur des images IRM. Un recalage affine suivi d'un recalage non-rigide est utilisé afin de recaler les images de la base d'apprentissage sur l'image à segmenter. Ces défor-

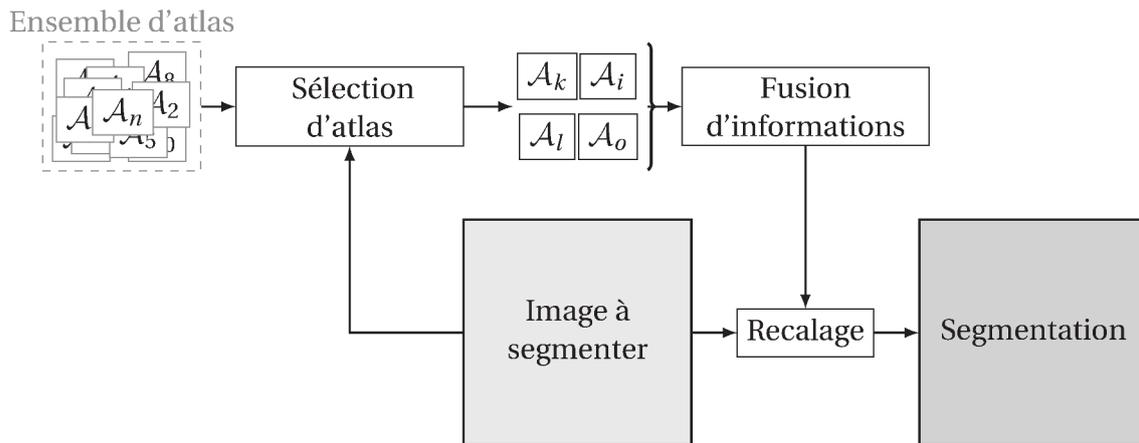


FIGURE 2.7 – Représentation d'une méthode de segmentation basée multi-atlas.

mations sont également appliquées sur les labels des images d'apprentissage. Ensuite, les atlas les plus similaires sont sélectionnés par le calcul de l'information mutuelle. Afin d'obtenir la segmentation finale, un vote majoritaire est effectué entre les atlas sélectionnés. Cette méthode a été améliorée par [DOWLING 2011] en introduisant une étape de pré-traitement en égalisant l'histogramme de l'image ainsi qu'un lissage anisotropique. [LANGERAK 2010] ont proposé une nouvelle approche pour la fusion des labels des multi-atlas qui consiste à fusionner tous les atlas afin de construire un *gold standard*. Chaque image de référence est comparée à l'image à segmenter. Si cette comparaison donne un atlas trop éloigné du *gold standard*, l'image labellisée en question n'est plus prise en compte. Ce processus continue jusqu'à ce qu'il ne reste plus que des atlas proches de l'image à segmenter qui sont ensuite fusionnés pour obtenir la segmentation finale.

[ACOSTA 2011] a également proposé d'utiliser l'approche multi-atlas dans le cadre de la segmentation de la prostate, du rectum et de la vessie sur des images TDM comme extensions de leur méthode utilisant un atlas unique [ACOSTA 2010]. En gardant leur approche d'origine décrite en section 2.7.1, un classement des atlas les plus proches de l'image à segmenter est réalisé. Les plus similaires sont alors fusionnés, afin d'obtenir la segmentation des organes sur la nouvelle image. [LIAO 2012] ont également proposé une nouvelle approche utilisant ce principe de manière originale. La méthode consiste à extraire des caractéristiques sur des patches d'images déjà segmentées. Ces caractéristiques de patches sont extraites pour chaque position de l'image. Le label associé est donc également connu. Un dictionnaire de grande dimension est donc construit avec des ca-

ractéristiques de l'image et leur label associé. Ce dictionnaire étant de très grande taille, une contrainte parcimonieuse est proposée, afin de ne sélectionner uniquement que les caractéristiques qui permettent de bien discriminer les classes de prostate et de non-prostate. Lorsque l'image d'un nouveau patient est à segmenter, les caractéristiques sélectionnées sont extraites. La recherche des atlas similaires et leur fusion permet d'obtenir la segmentation finale.

2.7.3 Discussion

Comme les méthodes basées atlas ont besoin de techniques de recalage, la construction de l'atlas et sa bonne propagation dépend plus ou moins de l'étape initiale de recalage.

L'utilisation d'un atlas unique pour segmenter les organes d'un même patient est généralement suffisant. Cela peut être le cas en radiothérapie adaptative personnalisée où plusieurs images d'un même patient vont être acquises tout au long de son traitement, afin d'adapter le traitement de façon régulière. L'atlas, lui, est donc spécifique puisqu'il n'est construit qu'avec des segmentations de ses propres organes pour ne segmenter à nouveau que ses propres organes. De plus, ces méthodes sont pertinentes pour la segmentation d'une structure dont la forme est stable sur une large population. Comme, le volume et la forme de la prostate varient beaucoup d'un homme à l'autre, cela ne permet pas d'appliquer cette méthode dans notre étude.

L'utilisation d'un atlas unique n'est plus suffisante lorsque l'on souhaite utiliser cette méthode avec plusieurs patients, possédant alors une forte variabilité. De ce fait, les approches multi-atlas se trouvent plus adaptées pour ce genre de problématiques. En augmentant la taille de la base de données disponible, la méthode peut prendre en compte la forte variété de patients ainsi que la variabilité des organes qui les compose. Le point majeur de l'approche multi-atlas est la sélection de l'atlas utilisé pour réaliser la segmentation, qui doit être proche de l'organe cible du nouveau patient à segmenter. Pour ce faire, des mesures de similarité entre les images sont faites après le recalage, afin d'effectuer la meilleure sélection parmi tous les atlas disponibles. De plus, plusieurs atlas peuvent être choisis et combinés, afin de s'approcher encore plus de la segmentation souhaitée. Cela

implique de devoir combiner les atlas à la fin du processus pour obtenir la segmentation.

Un aspect contraignant de ces méthodes est que le besoin de contourages manuels est toujours présent, afin de constituer la base d'apprentissage et prendre en compte au maximum les variations inter-patients. D'après cette étude, il n'existe aucune méthode permettant de décider si un patient doit être inclus ou exclu de la base de données, afin d'améliorer ses performances. Aucun consensus n'a également été établi sur le nombre de patients à inclure dans cette base de données. D'un autre côté, l'un des aspects majeurs de l'utilisation de ce type de méthode est la prise en compte des connaissances des experts puisque leurs segmentations sont directement prises en compte dans le processus de segmentation.

2.8 Conclusion

Actuellement, aucune des méthodes de segmentation de la prostate ne peut donner des résultats utilisable en routine clinique. L'objectif de cette thèse est de développer une méthode permettant de segmenter les OAR et la prostate, qui serait performante et robuste en routine clinique.

Comme nous l'avons vu précédemment (chapitre 1 section 1.6), la segmentation des OAR peut s'avérer compliquée pour certains d'entre eux, comme par exemple le rectum. Par ailleurs, d'un point de vue clinique, le radiothérapeute souhaite que cette segmentation soit rapide, quitte à ce qu'il y ait une forte part d'interactivité avec l'utilisateur. Dans ce contexte, nous avons privilégié le développement d'une méthode semi-automatique qui permet la segmentation très rapide des trois organes à risque et applicable pour les deux modalités d'imagerie (IRM et TDM). Pour ces raisons, la méthode basée graphe avec une initialisation à l'aide de superpixels [BUYSSENS 2014] a retenue notre intérêt. Nous décidons de l'étudier pour la segmentation des OAR. L'algorithme développé et son évaluation fait l'objet du chapitre 3.

Une fois la segmentation des OAR réalisée par la biais de notre méthode par superpixels, nous proposons de les utiliser, afin de restreindre l'espace de recherche de la prostate. Pour ce faire, un volume d'intérêt est automatiquement extrait grâce à la segmen-

tation préalable des OAR. Ainsi, l'appartenance des pixels à la prostate ou non sera faite à l'intérieur de ce volume d'intérêt plutôt que sur l'image entière. Étant donné que la segmentation de la prostate est un problème complexe, les *a priori* des experts sont nécessaires pour obtenir une segmentation performante. De ce fait, nous proposons de développer une méthode basée sur les multi-atlas. Cette méthode et son évaluation font l'objet du chapitre 4.

Chapitre 3

Segmentation semi-automatique des OAR par superpixels

Sommaire

3.1	Introduction	50
3.2	Méthode de segmentation par superpixels	51
3.2.1	Schéma général	51
3.2.2	Création des superpixels	51
3.2.3	Labélisation semi-automatique de superpixels	57
3.2.4	Segmentation par diffusion sur graphe	59
3.3	Évaluation de la méthode	62
3.3.1	Introduction	62
3.3.2	Données de patients	62
3.3.3	Mesures d'évaluation	64
3.3.4	Résultats	65
3.4	Discussion et conclusion	71

Ce chapitre s'intéresse à la première contribution de cette thèse, à savoir : la segmentation d'organes à risque dans le cadre du traitement du cancer de la prostate par radiothérapie. Dans un premier temps, nous présenterons la méthode semi-automatique développée, utilisant une méthode de superpixels. Dans un second temps, nous montrons l'évaluation de la méthode sur un ensemble de patients en IRM et TDM.

3.1 Introduction

La première partie de nos travaux s'est attachée à développer une méthode de segmentation des organes à risque dans le cadre du traitement du cancer de la prostate par radiothérapie. Les organes à segmenter sur les images médicales IRM et TDM sont : la vessie, les têtes fémorales et le rectum.

Comme nous l'avons vu au chapitre 1 section 1.6, la différenciation visuelle des principaux organes à risque avec leur environnement est relativement de bonne qualité aussi bien sur les images TDM qu'IRM. Il est cependant complexe de différencier les parois vésicales et rectales, ainsi que la limite entre le rectum et le canal anal. De ce fait, nous avons développé une méthode pouvant prendre en compte cette problématique. Nous avons privilégié une méthode rapide et interactive avec l'utilisateur, donc semi-automatique, de sur-segmentation, basée sur la notion de superpixels, suivi d'une diffusion sur graphe. Ce processus permet de générer des superpixels puis de les regrouper pour obtenir la segmentation finale des OAR. Cette méthode effectue un découpage de l'image en plusieurs petites régions, homogènes en terme de niveaux de gris, dénommés "superpixels". À la suite de cette étape, un graphe d'adjacence de régions est construit. Ce type de graphe permet une représentation de la structure des superpixels et notamment les relations de voisinage entre eux. La méthode est dite semi-automatique, car l'utilisateur interagit avec l'algorithme. Il doit manuellement définir sur l'image qu'il visualise, un petit nombre de superpixels de chaque OAR, encore appelés germes, afin d'initialiser la phase de regroupement des superpixels. Cette étape permet d'effectuer une labellisation de certains nœuds du graphe. Le regroupement de superpixels s'effectue à l'aide d'une méthode de diffusion sur le graphe. La segmentation des différents organes est obtenue à la suite de

cette diffusion.

3.2 Méthode de segmentation par superpixels

3.2.1 Schéma général

Un schéma d'ensemble de la méthode est donné Figure 3.1. Elle peut être décomposée en trois grandes étapes :

1. la création des superpixels en 2D à partir d'images TDM ou IRM,
2. la définition manuelle par l'utilisateur des germes appartenant à chaque OAR,
3. la segmentation définitive des OAR par agrégation de superpixels selon un processus de diffusion sur graphe en 3D.

Les sections suivantes décrivent ces trois étapes permettant de segmenter les OAR.

3.2.2 Création des superpixels

Cette section décrit la phase automatique de création de superpixels. L'ensemble des superpixels réalise une sur-segmentation en une multitude de petites régions homogènes sur une image médicale d'entrée. Cette phase est constituée de deux étapes :

1. Initialisation des germes : permet de définir la position initiale de l'ensemble des superpixels sur l'image à sur-segmenter.
2. Diffusion locale : permet de regrouper les pixels voisins du germe initial afin de créer l'ensemble des régions homogènes appelées superpixels.

Ces superpixels ainsi construits permettront de créer par la suite le graphe d'adjacence de région.

3.2.2.1 Initialisation des germes

La première étape de cette méthode consiste à définir le nombre K de germes d'initialisation, ainsi que leur position sur l'image d'origine notée I . Nous avons choisi de placer ces germes sur une grille régulière de l'image I tel que $K = L \times C$, comme illustré sur la Figure 3.2, avec L lignes et C colonnes. Ce processus est réalisé coupe par coupe.

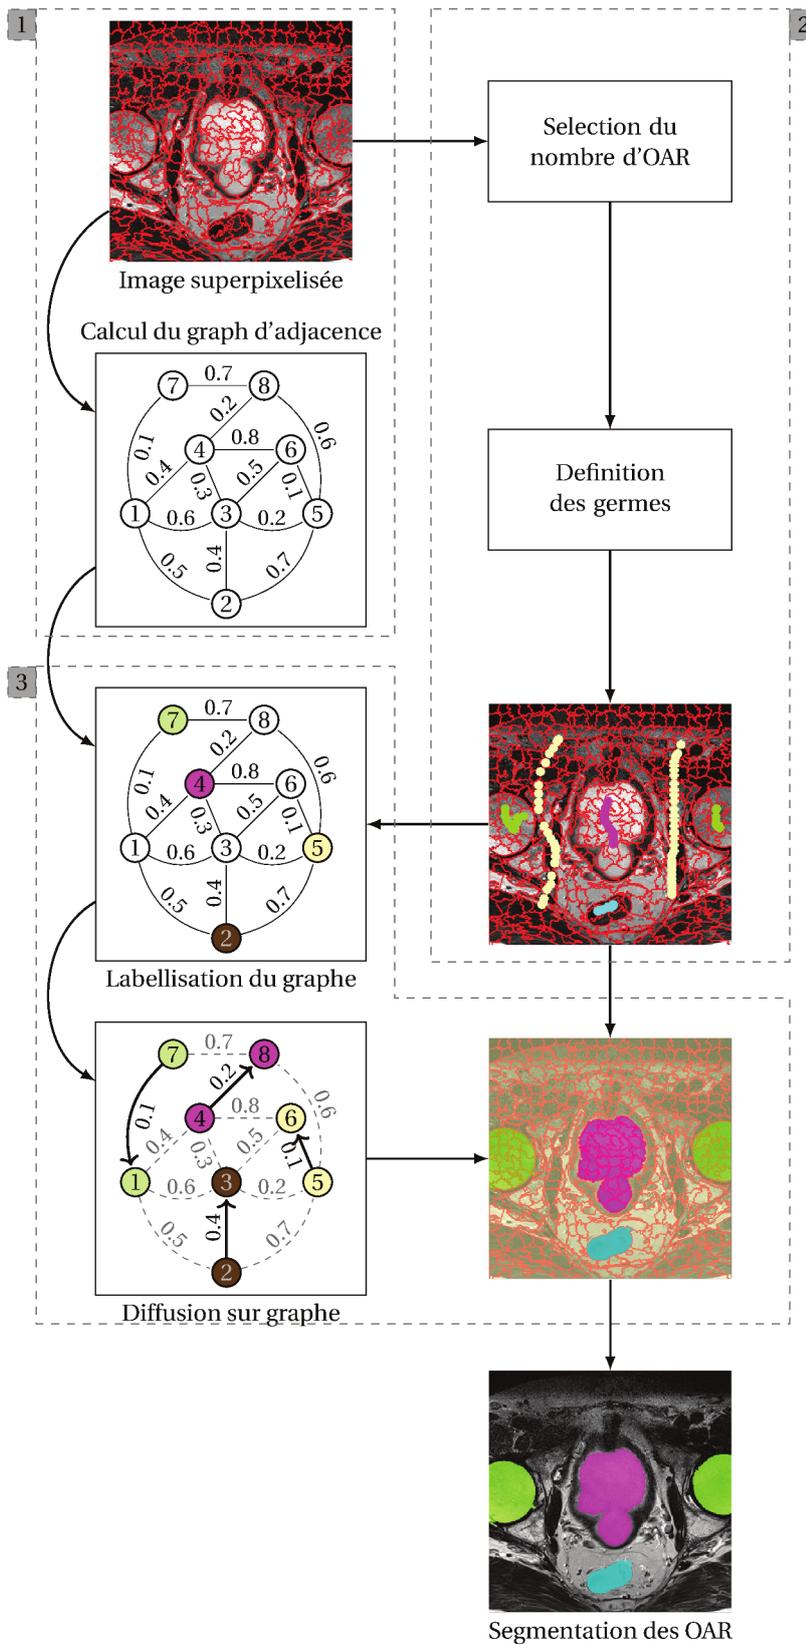


FIGURE 3.1 – Schéma des différentes étapes de la méthode de segmentation des OAR par superpixels. Les boîtes englobantes numérotées correspondent aux trois étapes de la méthode.

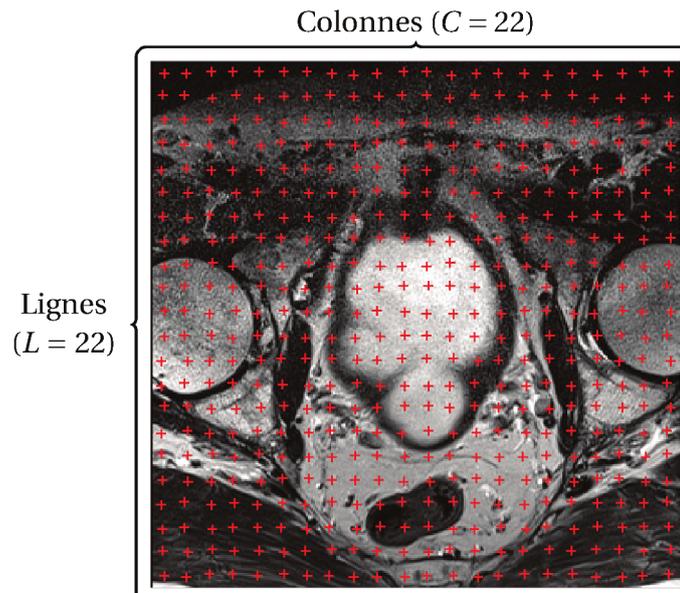


FIGURE 3.2 – Exemple d'initialisation des germes des superpixels sur une image IRM.

Un germe peut être positionné sur le contour d'un objet à segmenter, ce qui fausserait la suite de la méthode en créant une région sur tout le contour de l'objet. Or, ce comportement n'est pas souhaité puisque le but des superpixels est de créer des régions homogènes dont les bords adhèrent aux contours présents dans l'image. Pour ce faire, un voisinage 3×3 autour du germe est isolé. La différence de niveau de gris, par la norme L_2 , entre le pixel germe et chacun de ces huit voisins est calculée. Si ces différences sont nulles, le germe n'est pas déplacé, car il n'est pas positionné sur un contour. Si certaines différences sont importantes, le germe est placé sur le pixel qui donne la différence la plus faible, afin de l'éloigner d'un possible contour.

Les superpixels possèdent trois caractéristiques qui sont :

- La position : qui représente la position du germe initial sur l'image.
- Le nombre de pixels : qui sont compris dans l'ensemble de la région (initialisé à 1, soit le pixel sur lequel est placé le germe).
- La valeur moyenne : qui stocke la valeur moyenne du niveau de gris de l'ensemble des pixels composants le superpixel.

La valeur moyenne initiale du superpixel est alors calculée comme étant la moyenne du pixel de l'image I sur lequel est positionné le germe, ainsi que les pixels voisins en 4-connexité, sur la coupe 2D.

3.2.2.2 Diffusion locale

À partir de la valeur des germes initiaux placés sur la grille $L \times C$, nous mettons en place une diffusion locale. Le but de cette diffusion est d'agréger les voisins similaires les plus proches de chaque germes, suivant la valeur de leur niveau de gris, afin de former les régions homogènes, appelées superpixels.

Afin de gérer cette croissance de région locale, une version modifiée de l'équation Eikonal est utilisée (équation (3.1)). L'équation Eikonal originale régie le trajet de la lumière dans un milieu. Les rayons lumineux cheminent vers le chemin le plus facile, celui qui consomme le moins d'énergie (milieu homogène), qui n'est pas nécessairement une ligne droite. Nous avons établi une analogie du phénomène physique de la diffusion de la lumière dans un milieu avec la croissance de région locale sur une image. Dans notre cas, la lumière correspond au germe qui se répand dans le milieu correspondant à l'image médicale.

L'équation Eikonal modifiée pour notre méthode, régissant la croissance de région, correspond aux relations suivantes [DESQUESNES 2013] :

$$\begin{cases} \|\nabla U(x)\| = F(x) & \forall x \in \mathcal{I} \\ U(x) = 0 & \forall x \in \Gamma \end{cases} \quad (3.1)$$

Dans cette équation, \mathcal{I} est le domaine de l'image, F une fonction positive et Γ l'ensemble des germes initiaux. $U(x)$ est définie comme étant la distance géodésique [PEYRÉ 2010] correspondant au chemin le plus court entre un point x de l'image et le germe Γ le plus proche en terme de niveau de gris, comme illustré sur la Figure 3.3.

La force F de l'équation (3.1) peut être définie selon l'expression F_s suivante :

$$F_s(x, R_i) = \|G_x - G_{R_i}\|_2^2 \quad (3.2)$$

avec G_x et G_{R_i} représentant respectivement la valeur en niveau de gris du pixel x et la valeur moyenne en niveau de gris dans la région R_i .

Dans la littérature, une méthode a été proposée, afin d'obtenir des superpixels compacts [BUYSSENS 2014]. Dans ce cadre, un facteur de compacité imposant une contrainte

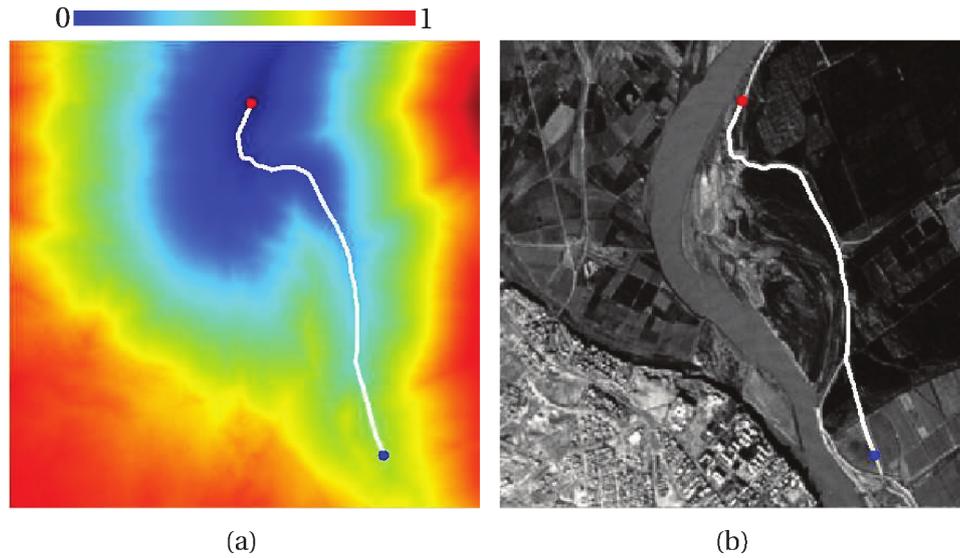


FIGURE 3.3 – Exemple de (a) carte de distance géodésique entre deux points d'une (b) image satellite, d'après [PEYRÉ 2010].

spatiale a été ajouté à l'équation (3.2) de la façon suivante :

$$F(x, R_i) = \sqrt{F_s(x, R_i)^2 + F_c(x, \Gamma_i)^2} \quad (3.3)$$

avec F_s de l'équation (3.2) et la seconde force, F_c , forçant la compacité des superpixels, définie comme suit :

$$F_c(x, \Gamma_i) = \frac{\|x - \Gamma_i\|_2^2}{S} \times m \quad (3.4)$$

avec x la position d'un pixel, Γ_i le germe initial de la région R_i , S l'espace en nombre de pixels entre deux germes initiaux et m le facteur de compacité au choix de l'utilisateur.

Pour chaque germe sur la grille $L \times C$ précédemment créée, l'algorithme de *fast marching* [SETHIAN 1999] est utilisé localement, afin de résoudre l'équation (3.1). L'algorithme de *fast marching* consiste à imiter l'avancée d'un front d'onde se répandant à une certaine vitesse à partir d'une source. Lors du déplacement du front d'onde, chaque point de l'image peut appartenir à l'une des trois classes suivantes : (1) derrière le front, (2) sur le front et (3) devant le front. Les points derrière le front d'onde sont déjà calculés et nous connaissons leur temps de trajet pour aller jusqu'à la source. Les temps pour se rendre de la source jusqu'aux points du front sont calculés. Le point avec la distance la plus courte de la source au front est choisi et passe derrière la ligne de front. Les points voisins de ce point sont ajoutés à la ligne de front et leur distance est à nouveau calculée. Enfin,

tous les points à l'extérieur du front n'ont pas encore de valeur de distance à la source. Ce processus est itératif jusqu'à ce que tous les points soient derrière la ligne de front.

Lorsqu'un pixel est attribué à une région R_i , sa valeur moyenne en niveau de gris G_{R_i} est mise à jour de la façon suivante :

$$G_{R_i} = \frac{(G_{R_i} \times \#R_i + G_x)}{(\#R_i + 1)} \quad (3.5)$$

avec $\#R_i$ la cardinalité, autrement dit, le nombre de pixels compris dans la région R_i .

Afin de savoir quel pixel est ajouté en premier dans une région, une carte de priorité est obtenue en calculant la force F entre les pixels sur le contour de chaque région et la région elle-même. Les pixels sont agrégés par régions suivant cette carte de priorité.

Cette croissance de région locale permet alors de créer K ($K =$ nombre de germes) petites régions homogènes appelées superpixels. Lorsqu'un fort gradient est présent dans l'image, le front de propagation du superpixel ne va pas réussir à le dépasser, tant qu'une autre région de superpixels pourra se diffuser dans un milieu plus homogène. Comme il est visible sur la Figure 3.4, les contours de superpixels ont la propriété d'adhérer aux contours assez marqué de l'image (autour de l'os par exemple). En diffusion dans un milieu homogène, deux superpixels voisins se diffuseront à vitesse égale et leurs front se rejoignent à mi chemin.

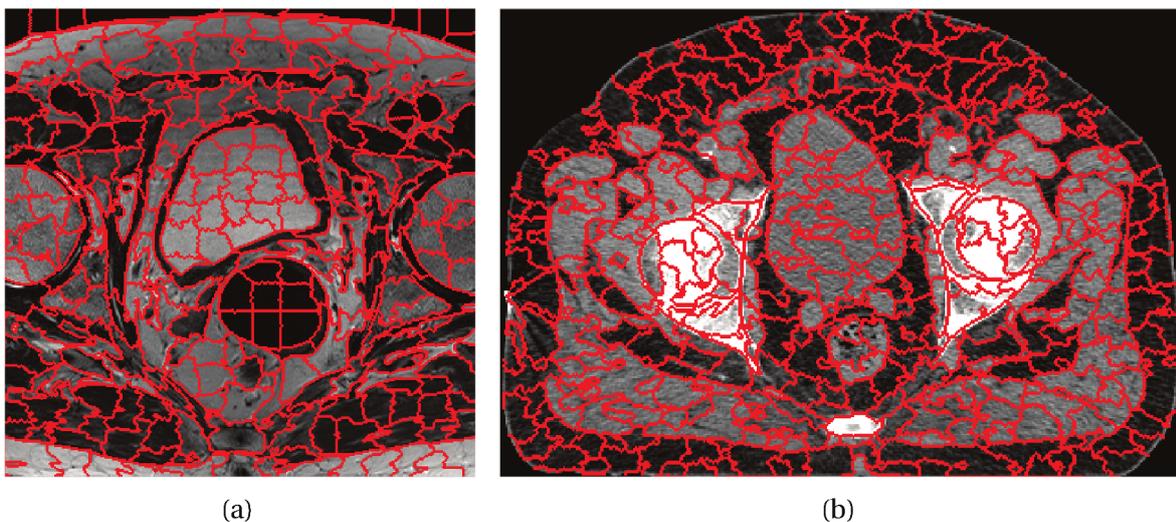


FIGURE 3.4 – Résultats de la sur-segmentation par la création de superpixels : Exemple sur une image (a) IRM et (b) TDM.

3.2.3 Labélisation semi-automatique de superpixels

Nous avons créé un outil basé sur la bibliothèque MITK (*Medical Image Tool Kit*) développée en C++, pour effectuer la labellisation manuelle.

À partir de l'image superpixelisée en K petites régions, l'utilisateur définit manuellement quelques germes dans chaque région à segmenter (la vessie, chacune des têtes fémorales et le rectum). L'idée est de proposer une méthode la plus ergonomique et la plus rapide possible à l'utilisateur. Le principe est un système de va-et-viens d'essais-résultats, avec lequel l'utilisateur définit des germes et vérifie le résultat de la segmentation obtenue. La méthode ainsi proposée est très interactive. La définition de germes s'effectue avec un outil de pinceau permettant de peindre directement de façon grossière sur l'image médicale.

Un exemple de labellisation par l'utilisateur est donné Figure 3.5. Chaque région correspond à une couleur particulière pour les différencier. Dans le cadre de la thèse, il a été développé un logiciel intégrant cette méthode dont l'interface utilisateur est donnée Figure 3.6. Le pinceau peut être utilisé soit sur une ou plusieurs coupes 2D, soit directement en 3D. Les images contenant les OAR segmentés sont visibles dans la partie droite du logiciel. La liste des structures ouvertes dans le logiciel sont visibles dans la partie gauche. À la droite de cette liste se trouve le module de segmentation que nous avons développé. Une fois l'image sur laquelle travailler a été sélectionnée, il est possible de créer les superpixels sur l'image 2D courante, en 2D coupe par coupe ou en 3D en spécifiant les différents paramètres réglables (nombre de superpixels, facteur de compacité et exécution en 2D ou 3D). En dessous de ces réglages, des options permettent d'isoler les volumes qu'il est possible de visualiser une fois les superpixels créés. De plus, l'outil pinceau de la librairie MITK (*Medical Image Tool Kit*) a été intégré et est utilisé pour la définition manuelle des germes. Enfin, les boutons permettant d'exécuter les différentes étapes de la méthode se trouvent en bas du module.

Le disque est l'outil qui a été privilégié pour peindre sur l'image. L'utilisateur peut changer la taille de son rayon pour utiliser un disque de taille souhaitée. En restant sur une position de la souris cliquée et en glissant sur l'image, l'utilisateur peint avec le disque choisi. Cette peinture peut être appliquée sur n'importe quel plan (sagittal, frontal, trans-

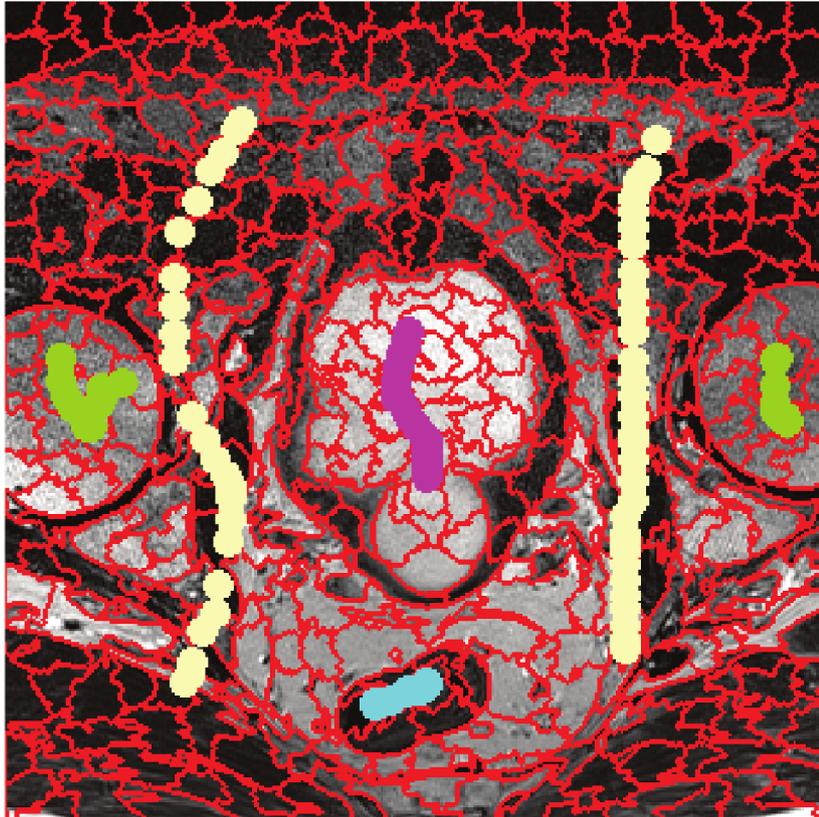


FIGURE 3.5 – Exemple de labellisation par l'utilisateur en peignant directement sur l'image, en vert dans chacune des têtes fémorales, en marron dans le rectum, en beige dans la vessie et en violet dans à l'extérieur des organes.

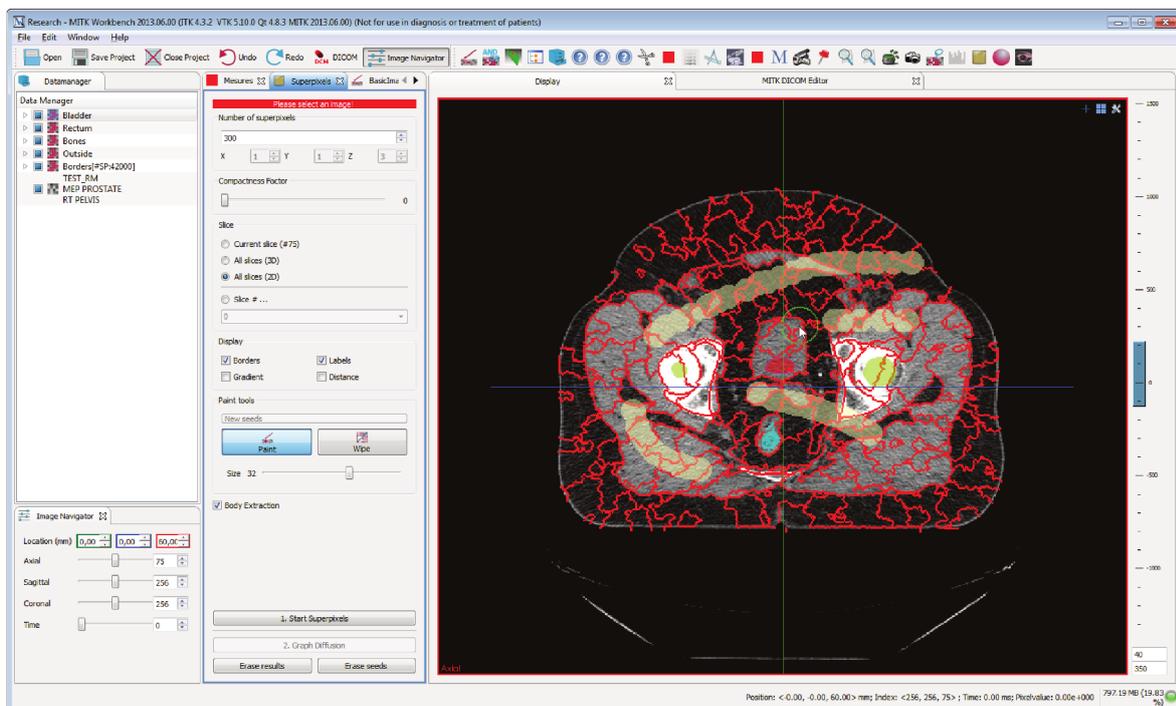


FIGURE 3.6 – Capture d'écran du logiciel développé pour la segmentation d'organes à risque par notre méthode.

verse ou autre). La méthode optimale en terme d’ergonomie, dénommée par la suite ‘Méthode Ergonomique’, est de peindre directement sur les coupes sagittales.

3.2.4 Segmentation par diffusion sur graphe

Une fois l’étape de création de l’image superpixelisée réalisée, un graphe d’adjacence de régions [TRÉMEAU AND COLANTONI 2000], appelé RAG (pour *Region Adjacency Graph*), est construit en 3D à partir des régions de superpixels obtenues sur l’ensemble des coupes 2D.

Ce graphe d’adjacence est construit de la façon suivante :

- Chaque superpixel représente un nœud du graphe. Les nœuds sont caractérisés par le numéro du superpixel (allant de 1 à K), par son nombre de pixels et par sa valeur moyenne en niveau de gris.
- Un lien entre deux nœuds est créé seulement s’ils sont voisins, c’est à dire si les deux superpixels ont une bordure commune. Chaque lien possède un poids défini par la similarité entre les deux nœuds qui les lient, selon l’expression :

$$W(G_{R_i}, G_{R_j}) = \|G_{R_i} - G_{R_j}\|_2 \quad (3.6)$$

avec G_{R_i} et G_{R_j} les niveaux de gris des deux régions R_i et R_j ayant un lien en commun.

De cette manière, nous obtenons une représentation schématique de l’image sur-segmentée par les superpixels comme illustré Figure 3.7.

La labellisation manuelle par l’utilisateur d’un faible nombre de superpixels permet alors d’amorcer la méthode de diffusion sur le graphe. Une diffusion de labels sur le graphe est effectuée selon l’Algorithme 1. Cette diffusion est réalisée en plusieurs étapes comme illustré Figure 3.1. Tout d’abord, le lien de poids le plus faible est recherché parmi tous les liens sortant de l’ensemble de nœud labellisés et dont l’extrémité du lien contient un nœud non labellisé. Ces conditions définissent deux superpixels les plus similaires. Une fois trouvé, le nœud non labellisé est étiqueté avec le même label que le nœud à l’autre extrémité du lien. Ce processus est répété jusqu’à ce qu’il n’y ait plus de nœuds non labellisés. Cette étape permet de classer les nœuds avec les superpixels les plus simi-

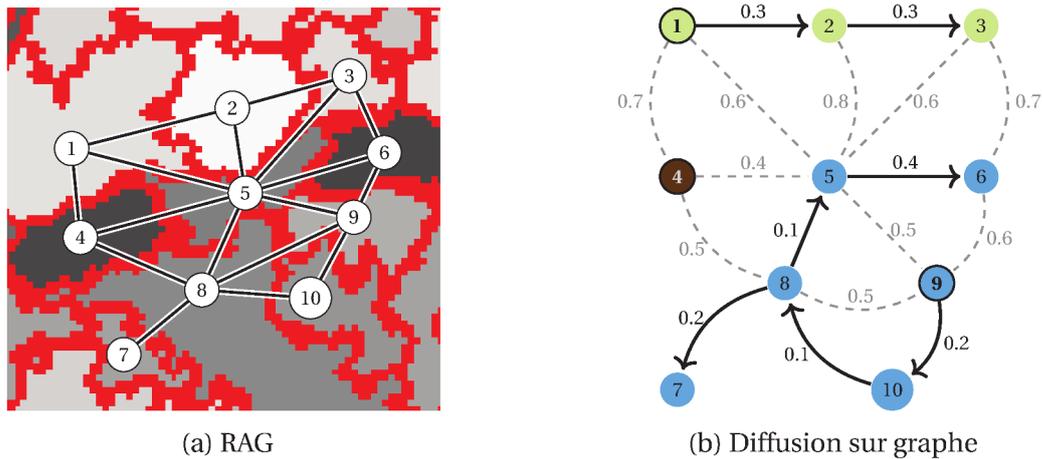


FIGURE 3.7 – Exemple de (a) construction d'un RAG basé sur les superpixels et (b) diffusion sur ce graphe avec les nœuds numéro 1, 4 et 9 comme initialisation. Les couleurs dans (b) représentent 3 régions différentes segmentées. Les flèches noire représentent le sens de la diffusion.

lares en fonction de leurs liaisons définies par le RAG.

Une fois tous les nœuds étiquetés, les régions entières sont labellisées en fonction du résultat pour donner la segmentation finale.

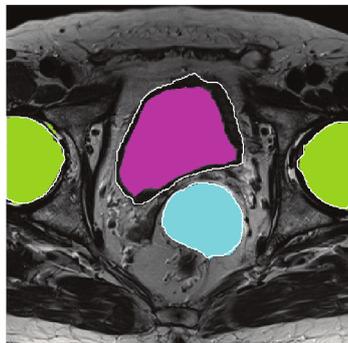
Si le résultat n'est pas concluant, l'utilisateur peut à nouveau utiliser l'outil de peinture sur l'image, afin d'exécuter à nouveau un processus de diffusion sur le graphe avec ces nouveaux germes initiaux. Ce principe itératif permet d'obtenir rapidement des résultats de façon interactive avec l'utilisateur comme visible sur la Figure 3.8.

En tout dernier lieu, l'utilisateur a accès à des outils de segmentation manuelle pour la retouche de certaines zones, appelés outils de correction *a posteriori*. Ce qui permet à l'utilisateur de prendre la main sur le processus et ne le contraint pas à un résultat insatisfaisant.

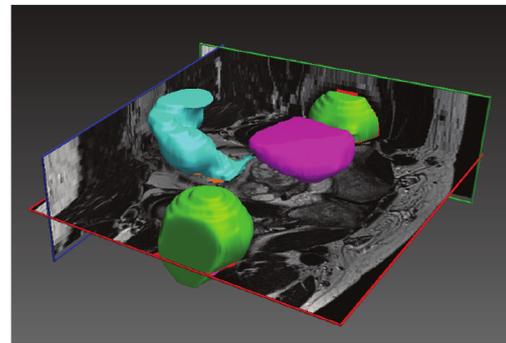
Algorithme 1 : Diffusion sur graphe à partir de nœuds labellisés.

Entrées : Graphe non labellisé g
Output : Graphe labellisé g
Données : Un ensemble d'arêtes L

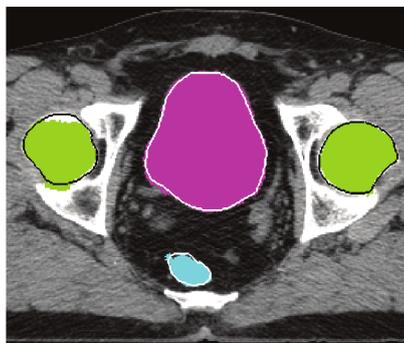
- 1 **pour** chaque nœuds n de g **faire**
- 2 **si** n est labellisé **alors**
- 3 Ajouter toutes les arêtes e de n à L ;
- 4 **fin**
- 5 **fin**
- 6 **tant que** L n'est pas vide **faire**
- 7 Extraire l'arête e de poids minimum de L ;
- 8 Extraire les nœuds n (labellisé) et m connecté grâce à e ;
- 9 Supprimer e de L ;
- 10 **si** m est non labellisé **alors**
- 11 Appliquer le label de n sur m ;
- 12 **fin**
- 13 Ajouter toutes les arêtes v entre m et les nœuds voisins non labellisés à L ;
- 14 **fin**



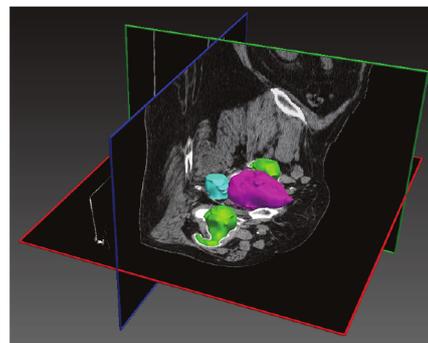
(a)



(b)



(c)



(d)

FIGURE 3.8 – Exemples de résultats de segmentation des OAR sur des images IRM ((a) et (b)) et TDM ((c) et (d)) en 2D (colonne de gauche) et 3D (colonne de droite).

3.3 Évaluation de la méthode

3.3.1 Introduction

Plusieurs possibilités de paramétrage de la méthode ont été étudiés dans l’algorithme proposé pour la segmentation des OAR.

Dans la phase de création des superpixels, nous avons fait le choix d’opérer un traitement en 2D et non pas en 3D. L’option de création de superpixels 3D a été étudiée, mais n’a pas été retenue, car l’épaisseur de coupes en IRM est trop importante. Le principe de la méthode étant de créer des régions homogènes, une épaisseur de coupe trop grande empêche de garder la cohérence d’une telle région. Effectivement, les pixels voisins des germes initiaux pendant la phase de diffusion locale peuvent être proches en niveau de gris d’une coupe à l’autre, mais pourtant appartenir à des structures différentes. Il a également été fait le choix d’un positionnement régulier des germes sur l’image. Dans la littérature, un positionnement irrégulier en privilégiant un nombre limité de superpixels dans les zones très homogènes de l’image a été étudié. Cette approche a été proposée par [MOORE 2008] pour des images photographiques. Cette possibilité n’a pas été étudiée dans le cadre de ce travail en raison de la complexité de l’image médicale.

Par ailleurs, deux paramètres d’ajustement sont possibles. Il s’agit de K , le nombre de germes d’initialisation et de m , le facteur de compacité. L’influence de ces deux paramètres sur les résultats de la segmentation a été étudiée.

La phase de labellisation des superpixels étant semi-automatique, la reproductibilité intra-utilisateur a également été étudiée.

3.3.2 Données de patients

L’évaluation de notre méthode a été réalisée sur une base de données IRM et une base de données TDM.

La base de données d’images IRM est celle du challenge *NCI-ISBI 2013 challenge – Automated Segmentation of Prostate Structures* [ARCHIVE 2013]. Celle-ci contient 70 patients, dont 60 patients pour effectuer de l’apprentissage et 10 patients pour les tests. Ces

60 patients sont répartis en deux groupes de 30 patients chacun, acquis de deux manières différentes. La première moitié a été obtenue sur un appareil d'IRM 3T (Siemens TIM) avec une antenne de surface. Les images sont constituées de 15 (ou plus) coupes axiales adjacentes de 4 millimètre d'épaisseur. La seconde moitié a été acquise sur un appareil d'IRM 1.5T (Philips Achieva) avec une antenne endo-rectale. Ces images sont constituées de 28 (ou plus) coupes axiales adjacentes de 3 millimètres d'épaisseur. La taille des pixels des images IRM 3T et 1.5T est respectivement de $0.625 \times 0.625 \text{ mm}$ et $0.4 \times 0.4 \text{ mm}$. La séquence d'acquisition des images IRM est *T2-weighted MR axial pulse*. Ces informations sont résumées dans le Tableau 3.1. La base d'apprentissage contient l'image IRM ainsi que la segmentation de la prostate, mais pas des organes à risque. La segmentation des OAR a été réalisée par un radiothérapeute sénior du Centre Henri Becquerel, pour les besoins de la thèse.

Challenge ISBI 2013	IRM 3T	IRM 1.5T
Apprentissage (patients)	30	30
Test (patients)	5	5
Antenne	surfacique	endo-rectale
Nombre de coupes	15+	28+
Taille des pixels (millimètres)	0.625×0.625	0.4×0.4
Épaisseur de coupes (millimètres)	4	3

TABLEAU 3.1 – Composition de la base de données IRM du challenge ISBI 2013.

Concernant la base de données TDM, les images proviennent du département de radiothérapie du Centre Henri Becquerel. Elles correspondent à des données TDM de patients traités par radiothérapie dans le cadre du traitement du cancer de la prostate. Elles ont été segmentées par un radiothérapeute sénior lors de l'étape de simulation du traitement. Ces images sont constituées de 147 (ou plus) coupes axiales adjacentes de 2,5 mm d'épaisseur.

Les segmentations médicales manuelles (images TDM et images IRM) ont été considérées comme les segmentations de référence permettant l'évaluation de notre méthode.

3.3.3 Mesures d'évaluation

L'évaluation du résultat de la segmentation a porté sur l'indice de Dice, la distance de Hausdorff à 95%, la sensibilité et la spécificité.

— Indice de Dice

L'indice de Dice est exprimé par :

$$Dice(X, Y) = \frac{2|X \cap Y|}{|X| + |Y|} \quad (3.7)$$

avec X et Y deux ensembles et $|X|$ le nombre d'éléments de X . Cet indice, compris entre 0 et 1, donne une mesure de similarité entre deux ensembles. Si deux segmentations X et Y sont parfaitement superposées, l'indice vaut 1.

— Distance de Hausdorff

La distance de Hausdorff est définie de la façon suivante :

$$Hausdorff(X, Y) = \max \left\{ \sup_{y \in Y} \sigma(X, y), \sup_{x \in X} \sigma(x, Y) \right\} \quad (3.8)$$

avec X et Y deux ensembles fermés bornés non vides, x et y deux points de ces ensembles et σ une métrique. Cette équation permet donc de mesurer la distance la plus grande entre le point x le plus éloigné de l'ensemble Y et le point y le plus éloigné de l'ensemble X . En traitement d'image, la distance de Hausdorff est calculée pour chaque point du contour des objets. Le résultat est alors une distribution de distances. Pour caractériser l'erreur de segmentation, c'est la valeur qui est plus grande que 95% de la distribution qui est utilisée.

— Sensibilité

La sensibilité est définie par l'équation :

$$Sensibilité = \frac{\sum VP}{\sum VP + \sum FN} \quad (3.9)$$

La sensibilité représente la capacité de la méthode à correctement labelliser les pixels

faisant partie de l'organe à segmenter. Une forte sensibilité indique un faible taux de faux négatifs (FN), c'est à dire de pixels d'organes non pris en compte dans la segmentation.

Les significations de VP , VN , FP et FN sont définies dans le Tableau 3.2.

		Volume référence (segmentation manuelle)	
		Organe	Extérieur
Volume segmenté (par superpixels)	Organe	Vrais Positifs (VP)	Faux Positifs (FP)
	Extérieur	Faux Négatifs (FN)	Vrais Négatifs (VN)

TABLEAU 3.2 – Résultats possibles d'un test sur un pixel du volume segmenté par rapport au volume de référence.

— Spécificité

La spécificité est calculée de la manière suivante :

$$Spécificité = \frac{\sum VN}{\sum VN + \sum FP} \quad (3.10)$$

La spécificité représente la capacité de la méthode à ne pas commettre l'erreur de labelliser des pixels comme appartenant à l'organe alors qu'en réalité il n'en fait pas partie. Une forte spécificité indique un faible taux de faux positifs (FP), c'est à dire de pixels n'appartenant pas à l'organe mais ayant été labellisés comme tel.

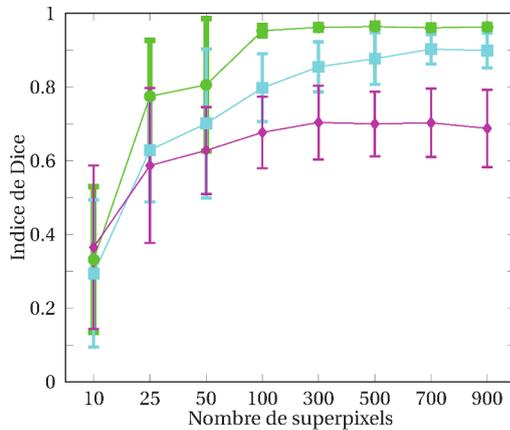
3.3.4 Résultats

3.3.4.1 Étude de l'influence du nombre de superpixels K

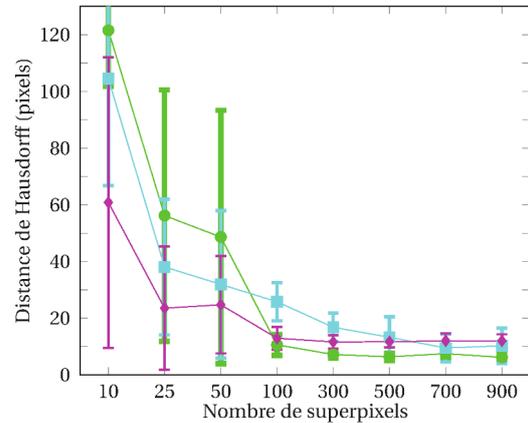
L'influence du nombre de superpixels sur la qualité de la segmentation a été réalisée en faisant varier la valeur de K , de 10 à 900 superpixels selon les valeurs suivantes : 10, 25, 50, 100, 300, 500, 700, 900.

Cette étude a été réalisée sur les 10 premiers patients des bases de données IRM et TDM. Le facteur de compacité a été fixé à 0, c'est à dire que la force F vérifiait l'équation l'équation (3.2) ne prenant pas en compte de contrainte de compacité. Par ailleurs, l'étape de labellisation semi-automatique des superpixels était toujours la même pour un patient donné et un organe donné, c'est à dire que les mêmes germes initiaux ont été utilisés.

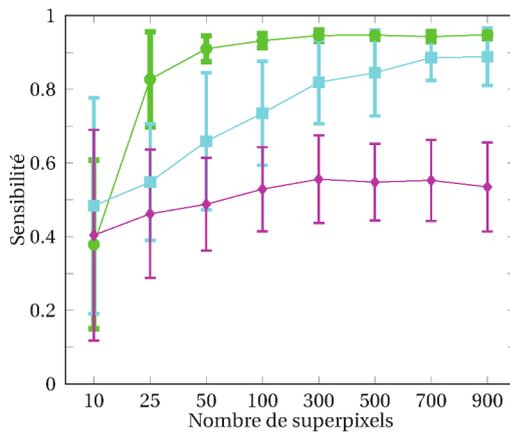
Sur les Figure 3.9 et 3.10 sont reportées les valeurs moyennes et les écarts types des indices de Dice, des distance de Hausdorff à 95%, de la sensibilité et de la spécificité en fonction de la valeur de K obtenues chez les 10 patients pour respectivement des données IRM et TDM.



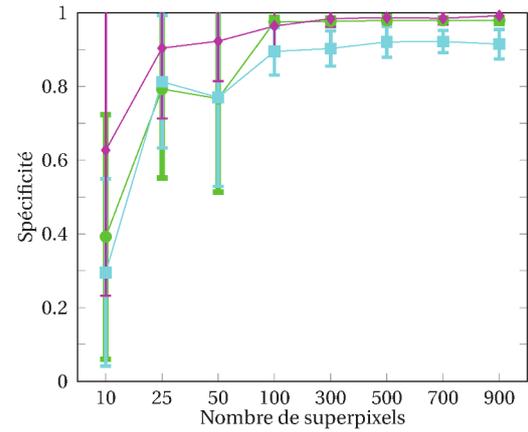
(a) Résultats de l'indice de Dice en IRM



(b) Résultats de la distance de Hausdorff en IRM



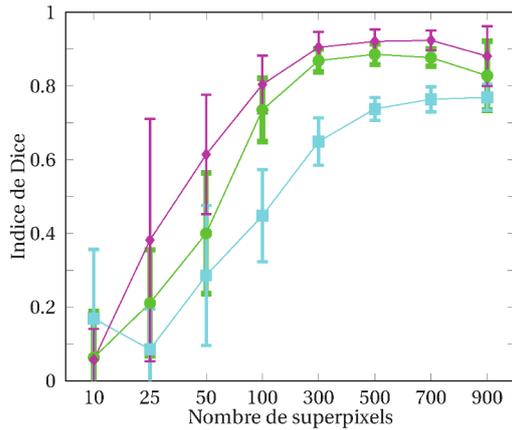
(c) Résultats de sensibilité en IRM



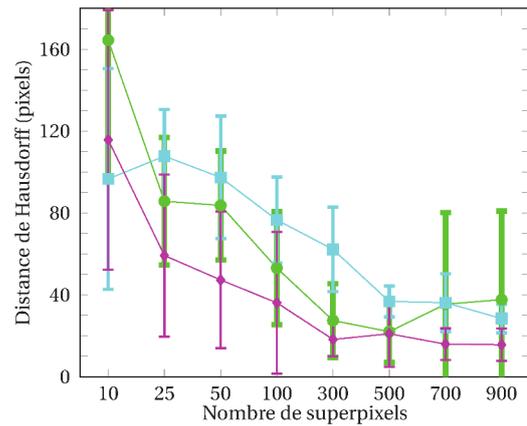
(d) Résultats de spécificité en IRM

FIGURE 3.9 – Résultats de l'indice de Dice, la distance de Hausdorff, la sensibilité et la spécificité moyens de la segmentation sur l'ensemble des patients en IRM pour les têtes fémorales (vert), la vessie (violet) et le rectum (bleu).

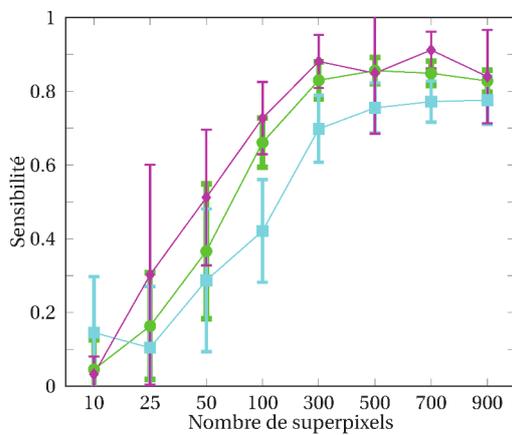
Pour les deux modalités et les trois OAR, l'indice de Dice, la sensibilité et la spécialité sont améliorés lorsque le nombre de superpixels augmente et la distance de Hausdorff diminue. À partir de $K = 300$ pour l'IRM et $K = 500$ pour la TDM, l'indice de Dice et la distance de Hausdorff deviennent stables. Par ailleurs, les écarts types deviennent plus faibles à partir de ces valeurs de K montrant une amélioration des performances de la segmentation chez tous les patients. Ces valeurs de K ont été choisies pour le reste de l'étude car ce sont celles qui permettent le meilleur compromis en terme de nombre de



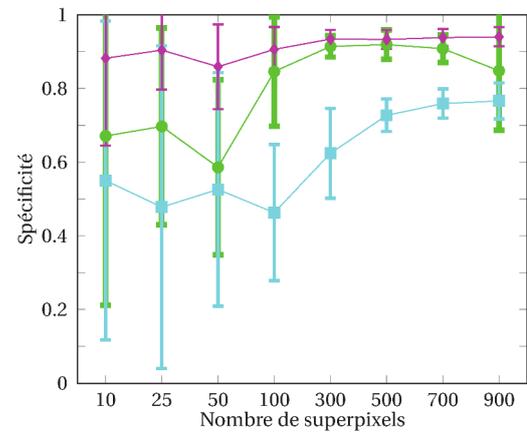
(a) Résultats de l'indice de Dice en TDM



(b) Résultats de la distance de Hausdorff en TDM



(c) Résultats de sensibilité en TDM



(d) Résultats de spécificité en TDM

FIGURE 3.10 – Résultats de l'indice de Dice, la distance de Hausdorff, la sensibilité et la spécificité moyens de la segmentation sur l'ensemble des patients en TDM pour les têtes fémorales (vert), la vessie (violet) et le rectum (bleu).

superpixels et résultats de la segmentation. De plus, le nombre de nœuds du graphe correspondant au nombre de superpixels, il est avantageux d’avoir le moins de nœuds possible, afin que la diffusion sur le graphe reste une étape rapide à exécuter. Les résultats moyens obtenus avec ces valeurs de K sont résumés dans le Tableau 3.3. Nous pouvons observer que les mesures de l’indice de Dice et de sensibilité pour les résultats de segmentation de la vessie en IRM ne sont pas aussi bon que les autres organes. Ceci tient au fait que le radiothérapeute segmente la paroi vésicale facilement identifiable pour lui alors que notre méthode segmente l’intérieur de la vessie. Ce résultat peut être amélioré en utilisant des opérations morphologiques (telles que la dilatation) sur notre résultat par exemple.

Concernant la distance de Hausdorff, la valeur est plus haute en TDM qu’en IRM à cause de la différence d’épaisseur de coupe. La spécificité est plus faible sur la segmentation du rectum en TDM à cause du faible contraste entre le rectum et le canal anal. Cette difficulté explique également certaines valeurs importantes de la distance de Hausdorff.

Organe	IRM			
	Dice(%)	Hausdorff(pixels)	Sensibilité(%)	Spécificité(%)
Têtes Fémorales	96.2 ± 0.8	07.1 ± 1.3	94.6 ± 1.5	97.7 ± 0.8
Vessie	70.4 ± 10	11.6 ± 2.3	55.6 ± 11.9	98.4 ± 2.2
Rectum	85.5 ± 6.6	16.7 ± 5	81.9 ± 11.3	90.3 ± 4.8
Organe	TDM			
	Dice	Hausdorff	Sensibilité	Spécificité
Têtes Fémorales	88.6 ± 2.8	22.0 ± 15.1	85.6 ± 3.6	91.9 ± 4.0
Vessie	92.1 ± 3.3	21.0 ± 16.1	84.9 ± 16.4	93.3 ± 2.6
Rectum	73.8 ± 3.1	36.8 ± 7.5	75.5 ± 6.8	72.7 ± 4.4

TABLEAU 3.3 – Mesures moyennes de l’indice de Dice (%), la distance de Hausdorff (pixels), Sensibilité (%) et Spécificité (%) sur les résultats de segmentations des têtes fémorales, vessie et rectum en IRM (avec $K = 300$) et TDM (avec $K = 500$).

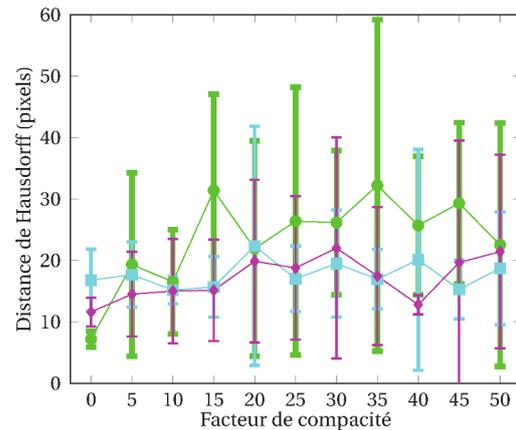
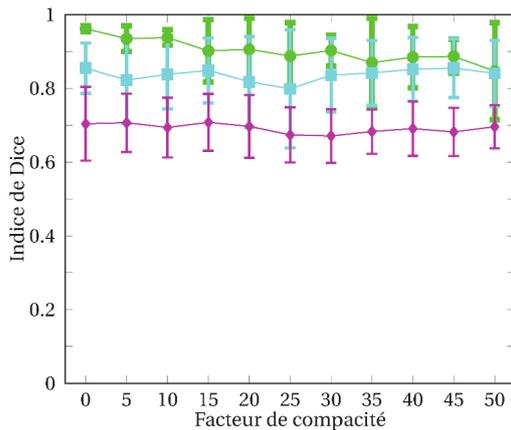
3.3.4.2 Étude de l’influence du facteur de compacité m

Dans un premier temps, le facteur de compacité étant dépendant des niveaux de gris des images, ceux-ci ont été normalisés entre 0 et 255. Puis, l’influence du facteur de compacité sur la qualité de la segmentation a été réalisée en faisant varier la valeur de m , de 0 à 50 avec un pas $\Delta c = 5$.

3.3. ÉVALUATION DE LA MÉTHODE

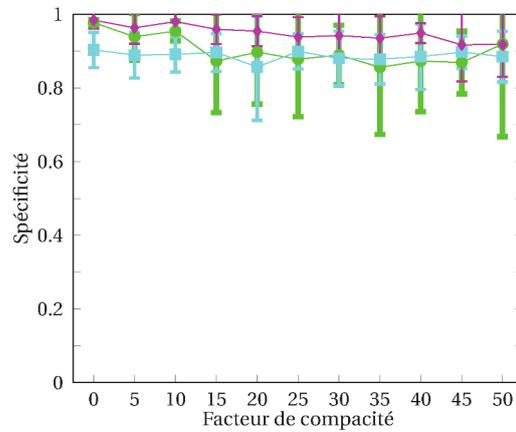
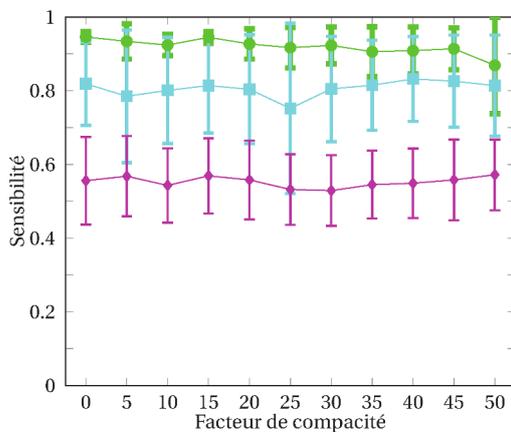
Cette étude a été réalisée sur les 10 premiers patients des bases de données IRM. Le nombre K utilisé correspondait au nombre K optimisé à l'étape précédente. Par ailleurs, l'étape de labélisation semi-automatique des superpixels était toujours la même pour un patient donné et un organe donné.

L'évaluation a porté sur l'indice de Dice, la distance de Hausdorff à 95%, la sensibilité et la spécificité, selon les expressions mathématiques définies précédemment.



(a) Résultats de l'indice de Dice en IRM

(b) Résultats de la distance de Hausdorff en IRM



(c) Résultats de sensibilité en IRM

(d) Résultats de spécificité en IRM

FIGURE 3.11 – Résultats de l'indice de Dice, la distance de Hausdorff, la sensibilité et la spécificité moyens de la segmentation sur l'ensemble des patients pour les têtes fémorales (vert), la vessie (violet) et le rectum (bleu) en fonction du facteur de compacité m avec $K = 300$ sur les images IRM.

L'étude de l'impact du facteur de compacité m sur les résultats de la segmentation sont donnés Figure 3.11. Le nombre de superpixels utilisés est celui présentant les résultats les plus intéressants dans notre application à savoir $K = 300$ pour l'IRM. D'une manière générale, les résultats sont stables, quelque soit la valeur du facteur de compacité, à l'exception de la distance de Hausdorff qui montre une nette augmentation liée à

l'augmentation de m .

Par ailleurs, nous notons que l'écart type est nettement plus faible pour la distance de Hausdorff et la spécificité pour $m = 0$ que pour des valeurs plus élevées de m .

D'un point de vue des différentes mesures, les résultats de segmentation ne sont pas améliorés lorsque le facteur de compacité est augmenté. Ce facteur a peu d'influence sur les résultats. C'est pourquoi, dans la suite de notre étude, le facteur de compacité ne sera pas utilisé (laissé à 0). Cela permet en plus de simplifier le calcul des superpixels de l'équation (3.3) puisqu'il n'y a plus besoin de calculer la force de compacité F_c .

3.3.4.3 Étude de la reproductibilité intra-utilisateur

Cette étude a également été réalisée sur les 10 premiers patients des deux bases de données (IRM et TDM). Les paramètres K et m utilisés correspondaient aux valeurs optimisées lors des deux étapes précédentes. L'étude a porté sur la reproductibilité intra-utilisateur. Celui-ci était expérimenté dans l'utilisation de l'outil logiciel. La "Méthode Ergonomique" a été réalisée à deux reprises à 7 jours d'intervalle sur les mêmes images. Seule l'étape de labellisation manuelle des germes était possible. Les outils de correction *a posteriori* n'ont pas été utilisés.

L'évaluation a porté sur l'indice de Dice, la distance de Hausdorff à 95%, la sensibilité et la spécificité, selon les expressions mathématiques définies précédemment.

Le Tableau 3.4 donne les résultats de l'étude de la reproductibilité intra-utilisateur de la segmentation en IRM et TDM. Les segmentations ayant été réalisées à 7 jours d'intervalle.

Concernant la reproductibilité des résultats en IRM, les indices de Dice, la sensibilité et la spécificité sont pratiquement tous au delà de 90%. L'indice de Dice des segmentations du rectum est plus faible, du fait des niveaux de gris proches des tissus avoisinants le rectum vers sa base.

Pour les résultats en TDM, hormis des résultats de sensibilité plus faibles, les mêmes observations qu'en IRM peuvent être faites. Concernant les résultats de la sensibilité, cela signifie que des régions en plus ont été incluses dans la seconde utilisation de la méthode, comparée à la première utilisation. D'une manière générale, l'utilisateur a donc préféré

Organe	IRM			
	Dice(%)	Hausdorff(pixels)	Sensibilité(%)	Spécificité(%)
Têtes Fémorales	97.2 ± 1.8	11.1 ± 8.3	97.2 ± 2.6	98.3 ± 1.1
Vessie	93.2 ± 5.5	5.4 ± 3.1	94.7 ± 4.8	95.1 ± 6.4
Rectum	86.8 ± 10.2	10.5 ± 4.6	92.8 ± 4.1	90.4 ± 10.1
Organe	TDM			
	Dice	Hausdorff	Sensibilité	Spécificité
Têtes Fémorales	93.1 ± 3.5	18.3 ± 9.2	87.8 ± 7.2	97.2 ± 4.8
Vessie	93.2 ± 4.9	12.2 ± 4.9	88.8 ± 8.7	98.1 ± 2.9
Rectum	88.9 ± 10.2	23.9 ± 11.3	86.4 ± 17.0	93.1 ± 11.8

TABEAU 3.4 – Mesures moyennes de l'indice de Dice (%), la distance de Hausdorff (pixels), Faux Négatifs (FN) (%) et Faux Positifs (FP) (%) moyens sur la reproduction de segmentations des têtes fémorales, vessie et rectum en IRM (avec $K = 300$) et TDM (avec $K = 500$) avec le facteur de compacité $m = 0$.

prendre des contours plus larges lors de la seconde segmentation. Nous constatons également que l'indice de Dice des segmentations du rectum sont plus faibles, toujours en raison des difficultés de délimitation avec le canal anal.

D'une manière générale, les résultats sont donc très voisins entre les deux utilisations de la méthode. De grands écarts, visibles par les résultats de la distance de Hausdorff, s'expliquent par le fait que lorsque l'utilisateur peint sur l'image de façon plus ou moins large que la façon précédente, cela prend ou retire une région entière de superpixels, qui peut être grande.

3.4 Discussion et conclusion

Dans cette partie, nous avons présenté la méthode adoptée pour segmenter les organes à risque dans le cadre du traitement du cancer de la prostate par radiothérapie, les têtes fémorales, la vessie et le rectum. Cette méthode est basée sur les superpixels créant une multitude de petites régions homogènes, puis un graphe d'adjacence de régions à partir de ces superpixels. Ce graphe est initialement labellisé par l'utilisateur en peignant directement sur l'image, puis la segmentation finale est obtenue à partir d'une diffusion sur le graphe. Cette méthode a été appliquée sur 10 patients du challenge ISBI 2013 [ARCHIVE 2013] pour l'IRM et 10 patients du Centre Henri Becquerel pour la TDM, afin d'évaluer sa faisabilité.

Nous avons volontairement fait le choix d'une méthode rapide, interactive et identique quelque soit l'OAR et la méthode d'imagerie. De ce fait, cette méthode est semi-automatique et prend en moyenne 5 minutes pour l'obtention d'un résultat souhaité par un expert. Le choix des germes initiaux est laissée à l'initiative de l'utilisateur. Compte tenu de la méthode utilisée, les écarts de segmentation portent sur des petites régions entières de superpixels. D'une manière générale, pour aucun des patients, l'utilisateur n'a eut recours aux outils de correction *a posteriori*. Par ailleurs, l'étude de la reproductibilité intra-utilisateur a donné des résultats satisfaisants.

Notre méthode comporte deux paramètres d'ajustement : le nombre K de germes d'initialisation et le facteur de compacité m . Nous avons pu constater que la méthode de segmentation nécessitant un nombre minimum de germes d'initialisation et que ce nombre minimum dépendait de la technique d'imagerie. Avec les bases de données utilisées, le nombre K choisi a été de 300 pour l'IRM et de 500 pour la TDM. Par contre, les résultats de la segmentation sont peu sensibles à la valeur du facteur de compacité m dans la gamme étudiée. Il a été choisi une valeur nulle pour m en raison du faible écart type rencontré pour cette valeur en IRM lors de l'étude de la distance de Hausdorff et de la spécificité.

Nous proposons dans le chapitre suivant une approche de segmentation automatique de la prostate. Compte tenu des relations anatomiques entre les OAR et la prostate, nous pouvons nous appuyer sur l'information déjà présente de la segmentation des OAR. Elle nous servira pour pré-localiser la prostate, puis réutiliser les informations de superpixels, afin de la segmenter précisément à l'aide d'une méthode basée multi-atlas.

Chapitre 4

Segmentation de la prostate par méthode multi-atlas avec contrainte de parcimonie

Sommaire

4.1 Introduction	74
4.2 Principe de traitement d'images par patches	74
4.2.1 Patches	74
4.2.2 Débruitage d'images par la méthode des patches	75
4.2.3 Segmentation d'images médicales par patches	77
4.3 Méthode proposée	80
4.3.1 Schéma général	80
4.3.2 Extraction du VOI	82
4.3.3 Extraction de caractéristiques	82
4.3.4 Sélection de caractéristiques discriminantes	88
4.3.5 Segmentation à deux échelles	90
4.4 Résultats expérimentaux	93
4.4.1 Évaluation	94
4.4.2 Résultats et discussion	95
4.5 Conclusion	99

4.1 Introduction

Ce chapitre s'intéresse aux contributions apportées à la segmentation de la prostate dans le cadre de traitement du cancer de cet organe par radiothérapie. Pour ce faire, nous proposons d'utiliser une méthode basée sur le multi-atlas avec deux échelles, superpixel et pixel. La double échelle permet, d'une part, d'accélérer le processus de traitement, d'autre part, d'améliorer les résultats des segmentations. Pour décrire les tissus de prostate et de non-prostate, nous utilisons non seulement les intensités, mais aussi des caractéristiques textuelles. Les méthodes basées patch sont donc étudiées et présentées dans la section suivante.

Compte tenu des difficultés présentes dans l'image, nous souhaitons nous appuyer sur les connaissances *a priori* des radiothérapeutes, Ainsi, nous avons choisi une approche nécessitant un apprentissage. Parmi les méthodes de modélisation d'*a priori*, les méthodes basées multi-atlas sont les plus appropriées du fait de la prise en compte des variations de forme et la disponibilité d'un ensemble d'organes segmentés. C'est pourquoi notre choix s'est porté sur une méthode multi-atlas utilisant des patches dans lesquels les caractéristiques textuelles peuvent être extraites, ce qui permet de prendre en compte des informations supplémentaires aux simples niveaux de gris de l'image.

Dans les sections suivantes, nous verrons tout d'abord le principe d'utilisation des patches en traitement d'image ainsi que celui de la parcimonie, intervenant dans l'étape de sélection de caractéristiques ainsi que de la labellisation. Enfin, nous verrons l'application de cette méthode sur les images IRM du cancer de la prostate.

4.2 Principe de traitement d'images par patches

4.2.1 Patches

4.2.1.1 Définition d'un patch

Un patch est une fenêtre de taille $K \times K$ appliquée sur une image (voir $K \times K \times K$ pour les images en trois dimensions). Cette fenêtre extrait une sous-partie de l'image. Pour définir la position du patch sur l'image, une correspondance est faite entre le pixel x de l'image et

le centre c du patch. De ce fait, il est nécessaire de définir une taille K impaire pour ne pas avoir d'incertitude sur la position centrale du patch par rapport à l'image. Un patch permet d'apporter plus d'informations à un pixel puisque ses pixels voisins sont également présents dans ce patch. L'apport d'information est réalisé par le calcul de plusieurs caractéristiques prenant en compte les relations du pixel concerné avec son voisinage comme par exemple, le gradient ou les textures.

4.2.1.2 Comparaison entre patches

De façon intuitive, deux patches peuvent être comparés en calculant leur différence terme à terme telle que :

$$Sim(P_I(x), P_J(y)) = f \left(\sum_{x' \in P(x), y' \in P(y)} (I(x') - J(y'))^2 \right) \quad (4.1)$$

avec $P_I(x)$ et $P_J(y)$ les patches aux positions x et y dans les images I et J respectivement, x' et y' les position similaires dans les patches $P_I(x)$ et $P_J(y)$ respectivement, $I(x')$ et $J(y')$ les valeurs des pixels aux positions x' et y' respectivement. f peut être une fonction noyau telle que $f(x) = e^{-x/c}$. La fonction noyau permet de donner une valeur de similarité entre 0 (lorsque $x \rightarrow +\infty$) et 1 (pour $x = 0$). Lorsque $x = 0$, la similarité atteint la valeur 1 maximale. La Figure 4.1 présente un exemple de cette comparaison entre deux patches.

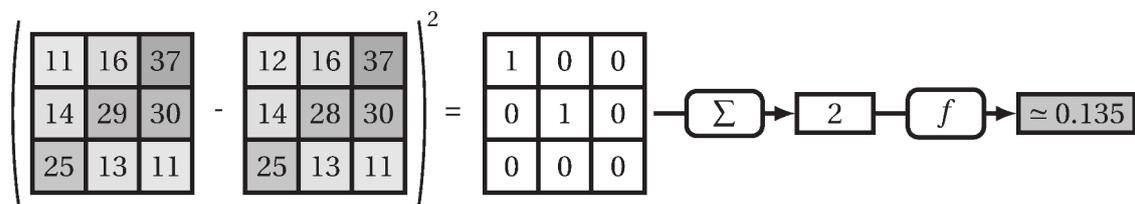


FIGURE 4.1 – Calcul d'une similarité entre deux patches de taille 3×3 par l'équation (4.1) avec la constante $c = 1$ de la fonction noyau f .

4.2.2 Débruitage d'images par la méthode des patches

Les méthodes qui exploitent des patches sont multiples et ont été appliquées à la restauration de séquences d'images vidéo [BOULANGER 2007], la construction de super résolution d'images [WANG 2005] ou bien encore l'inpainting d'images [DAISY 2014]. Ce-

pendant, cette méthode simplifiée décrite jusqu'ici a servi de point de départ pour son utilisation en débruitage d'image par [BUADES 2005]. Pour effectuer le débruitage d'une image I , considérons, sur le domaine de l'image Ω , un graphe pondéré w qui relie l'ensemble des pixels de l'image les uns aux autres avec un poids sur chaque lien $w(x, y)$, avec $(x, y) \in \Omega^2$, comme montré Figure 4.2. Ce graphe pondéré w définit une représentation de similarités non-locales dans l'image d'origine I .

20	18	25	23	28	8	10	12	16	17	22
3	14	29	$P_I(x)$	4	6	29	26	3	13	4
25	25	x	11	18	1	26	6	16	$P_I(y_1)$	23
6	23	2	3	14	26	5	5	y_1	25	29
18	7	5	24	20	14	18	7	2	6	7
11	20	5	2	16	24	10	3	8	26	19
20	16	9	10	27	20	6	3	$P_I(y_2)$	12	3
7	28	19	$P_I(y_n)$	5	3	y_2	20	18	29	
11	29	13	y_n	18	22	15	0	23	3	3
20	5	29	11	19	8	27	15	29	4	2
13	13	13	4	19	15	14	25	13	24	0

FIGURE 4.2 – Représentation d'un patch $P_I(x)$ (centré sur le pixel x de l'image I), relié à n patches $P_I(y_n)$ (centrés sur les pixels y) par des liens pondérés par le poids $w(x, y_n)$. La taille des patches a été fixée dans cet exemple à la taille 3×3 .

Ce graphe non-local utilisé à des fins de débruitage adopte une stratégie de moyenne de voisinage (appelé moyennes non-locales (MNL)) :

$$\forall x \in \Omega, I_{MNL} = \frac{\sum_{y \in \Omega} w(x, y) I(y)}{\sum_{y \in \Omega} w(x, y)} \quad (4.2)$$

avec $w(x, y)$ le poids d'auto-similarité calculé entre les pixels d'un patch aux positions x et y sur l'image bruitée I , $I(y)$ est la valeur du niveau de gris de l'image I à la position y et I_{MNL} la version débruitée de l'image I .

Le poids du graphe reflète la similarité entre les pixels au sein d'une même image. Il est calculé en utilisant une distance entre les patches centrés sur ces pixels, basés sur l'intensité :

$$w(x, y) = f \left(\frac{\sum_{x' \in P_I(x), y' \in P_I(y)} (I(x') - I(y'))^2}{2N\beta\hat{\sigma}^2} \right) \quad (4.3)$$

avec $P_I(x)$ un patch de l'image I centrée sur le pixel x , f est une fonction noyau, N est le nombre de pixels dans le patch, σ est l'écart type du bruit dans l'image I et β est un paramètre de lissage.

Cette méthode permet donc débruiter une image en combinant des patchs présents à de multiples endroits de l'image ressemblant au patch à débruiter localement. Des résultats de ce débruitage d'images à l'aide de cette méthode sont visible dans la Figure 4.3.



FIGURE 4.3 – Exemples d'application au débruitage d'image de la méthode basée patch avec la version bruitée de l'image (colonne de gauche) et sa version débruitée (colonne de droite). Extrait de [BUADES 2005].

4.2.3 Segmentation d'images médicales par patchs

Considérons un atlas (une paire image et segmentation associée) comme défini dans le chapitre 2 section 2.7, il est alors possible d'utiliser le principe de l'équation (4.1), afin de calculer la similarité entre une nouvelle image et l'atlas. La segmentation consiste à obtenir une image binaire dont le label valant 1 correspondant à l'organe à segmenter ou 0 au fond.

Étant donné un patch $P_I(x)$ à la position x dans l'image I , il est possible de connaître sa meilleure similarité avec l'image J de l'atlas en appliquant l'équation (4.1) à chacun de ses pixels. La valeur la plus faible serait donc la meilleure concordance entre les deux patches aux positions x et y_{best} . D'une manière triviale, il suffit d'appliquer à la position x , le label de la segmentation de J à l'emplacement y_{best} . Seulement, il peut exister plusieurs positions y_{best} où une combinaison de plusieurs informations peut être intéressante. C'est ce qui a été proposé par [ROUSSEAU 2011] qui a utilisé cette méthode pour la première fois pour la segmentation de zones cérébrales sur des images IRM en utilisant plusieurs atlas. L'ensemble d'atlas permet d'avoir une grande variabilité de patients. Dans ce cadre, considérons désormais un ensemble E contenant n atlas, formés d'images médicales \mathcal{I} et leur segmentation \mathcal{L} correspondantes : $E = \{(\mathcal{I}_i, \mathcal{L}_i), i = 1, \dots, n\}$.

Les poids $w_i(x, y)$, $(x, y) \in \Omega$ qui lient les pixels x de l'image d'origine I et les pixels y d'une image \mathcal{I}_i sont calculés de la façon suivante :

$$w_i(x, y) = f \left(\frac{\sum_{x' \in P_I(x), y' \in P_{\mathcal{I}_i}(y)} (I(x') - \mathcal{I}_i(y'))^2}{2N\beta\hat{\sigma}^2} \right) \quad (4.4)$$

Les paramètres de cette équation sont similaires à ceux de l'équation (4.3). La principale différence est qu'ici, la comparaison des patches n'est plus effectuée entre des patches d'une même image, mais entre un patch de l'image à segmenter et des patches des images du multi-atlas. Ce poids w_i représente alors les similarités non-locales entre l'image I et l'image \mathcal{I}_i de E .

Cette méthode présume l'hypothèse suivante : si les patches de l'image I sont localement similaires aux patches de l'ensemble E , ils doivent avoir le même label. Cette propagation de labels est effectuée grâce à l'ensemble de graphes w_i qui reflète la similarité entre I et \mathcal{I}_i , $i = 1, \dots, n$.

Dans le cas d'images naturelles, il est normal que la similarité puisse être recherchée sur toute l'image I . Cependant, dans le contexte d'images médicales, la localisation des structures se trouve dans une zone limitée et il n'est donc pas nécessaire de parcourir l'image en entier pour calculer son label par le biais de l'équation (4.4). C'est pourquoi un voisinage limité est utilisé pour calculer le poids tel que : $w = w(x, y), \forall x \in \Omega, y \in \mathcal{N}(x)$,

avec $\mathcal{N}(x)$ le voisinage du pixel x . Ce voisinage peut être défini, par exemple par une zone de $15 \times 15 \times 15$ voxels en 3D.

En reprenant l'équation (4.2), il est alors possible de calculer une carte de probabilité de labels L à chaque pixel selon la similarité $w(x, y)$ de la façon suivante :

$$\forall x \in \Omega, L(x) = \frac{\sum_{y \in \mathcal{N}(x)} w(x, y) \mathcal{L}(y)}{\sum_{y \in \mathcal{N}(x)} w(x, y)} \quad (4.5)$$

avec $\mathcal{L}(y)$ une valeur $\in \{0, 1\}$. La Figure 4.4 représente le schéma de du principe de cette équation (4.5). Pour chaque pixel x de I , l'équation (4.5) mène à une labellisation floue de I puisque $L(x) \in [0, 1]$.

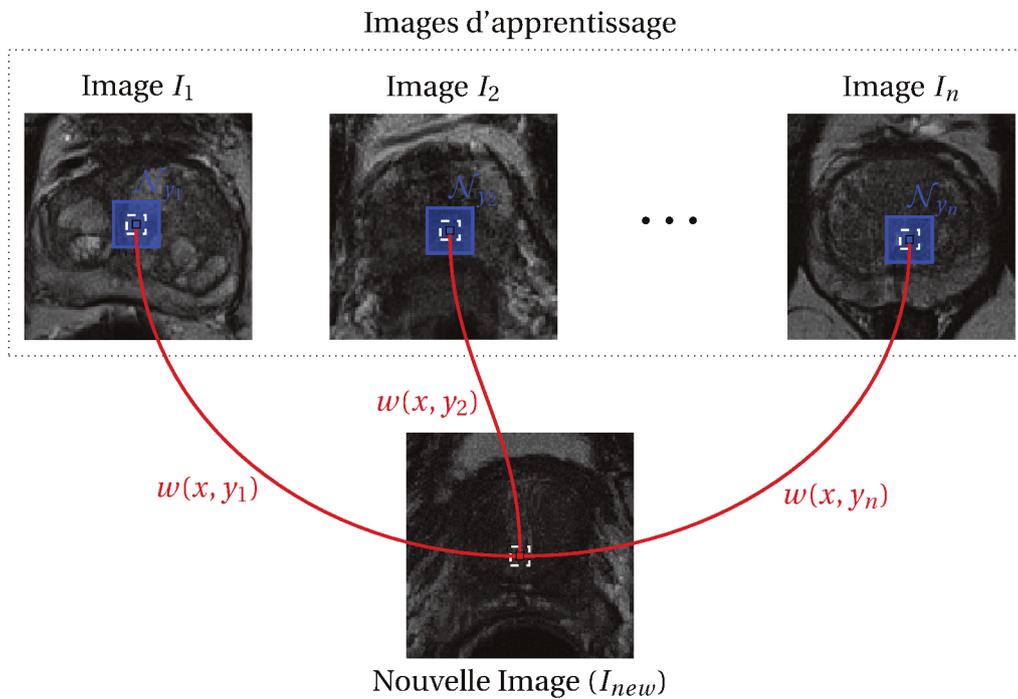


FIGURE 4.4 – Construction de la carte de probabilité, de façon similaire à la Figure 4.2, en utilisant un multi-atlas. Le cadre en bleu représente le voisinage \mathcal{N} des pixel y_n utilisés pour calculer leur poids d'appartenance w avec le pixel x de l'image d'origine I_{new} . Les contours en pointillé blanc représentent les patches autour des pixels considérés.

La carte de probabilité se doit d'être binarisée, afin d'obtenir la segmentation finale. Cette binarisation $\Lambda(x)$ du pixel x de l'image \mathcal{I} peut être obtenue en effectuant diverses opérations. La plus courante d'entre elles est le vote majoritaire (VM) [ROHLFING AND MAURER JR 2007] qui permet, pour un pixel x donné, de comparer la carte de probabilité $L(x)$ avec les labellisations existantes \mathcal{L} du multi-atlas. Pour toutes les valeurs de $L(x)$ valant 0 ou 1, le label est certain. Pour toutes les autres valeurs entre les deux, le label à

associer à x est décidé par la majorité des labels des multi-atlas $\mathcal{L}(x)$ à leur position x propre.

4.3 Méthode proposée

4.3.1 Schéma général

La seconde partie de nos travaux s'est donc attachée à la segmentation de la prostate en prenant en compte la segmentation préalable des OAR par notre méthode de superpixels. La segmentation des OAR obtenue par la méthode décrite au chapitre 3 nous permet de définir un volume d'intérêt (VOI) dans lequel la segmentation de la prostate est effectuée.

Notre méthode est composée de deux parties : apprentissage, afin de sélectionner les caractéristiques discriminantes puis la segmentation qui utilise seulement les caractéristiques sélectionnées afin de segmenter la prostate. La Figure 4.5 montre le schéma global de notre méthode dont les deux parties : apprentissage et segmentation, sont résumées ci-dessous.

4.3.1.1 Apprentissage

La partie d'apprentissage vise à sélectionner des caractéristiques. Puisqu'à ce stade, la segmentation des organes à risque est dors et déjà réalisée, la première étape consiste à extraire le VOI. Ce VOI permet de restreindre l'espace d'apprentissage et de recherche de la prostate. Ensuite, des caractéristiques sont extraites des patches de l'image avec leurs labels associés dans la base d'apprentissage, i.e. le multi-atlas. Enfin, la troisième étape consiste à introduire de la parcimonie dans l'ensemble des caractéristiques, afin de ne sélectionner que les caractéristiques permettant de partitionner les pixels de l'image appartenant à la prostate ou non au regard des labels précédemment extraits.

4.3.1.2 Segmentation

De façon similaire à la phase d'apprentissage, la première étape permet d'extraire un VOI, contenant lui même des superpixels, suite à la segmentation des OAR par la méthode

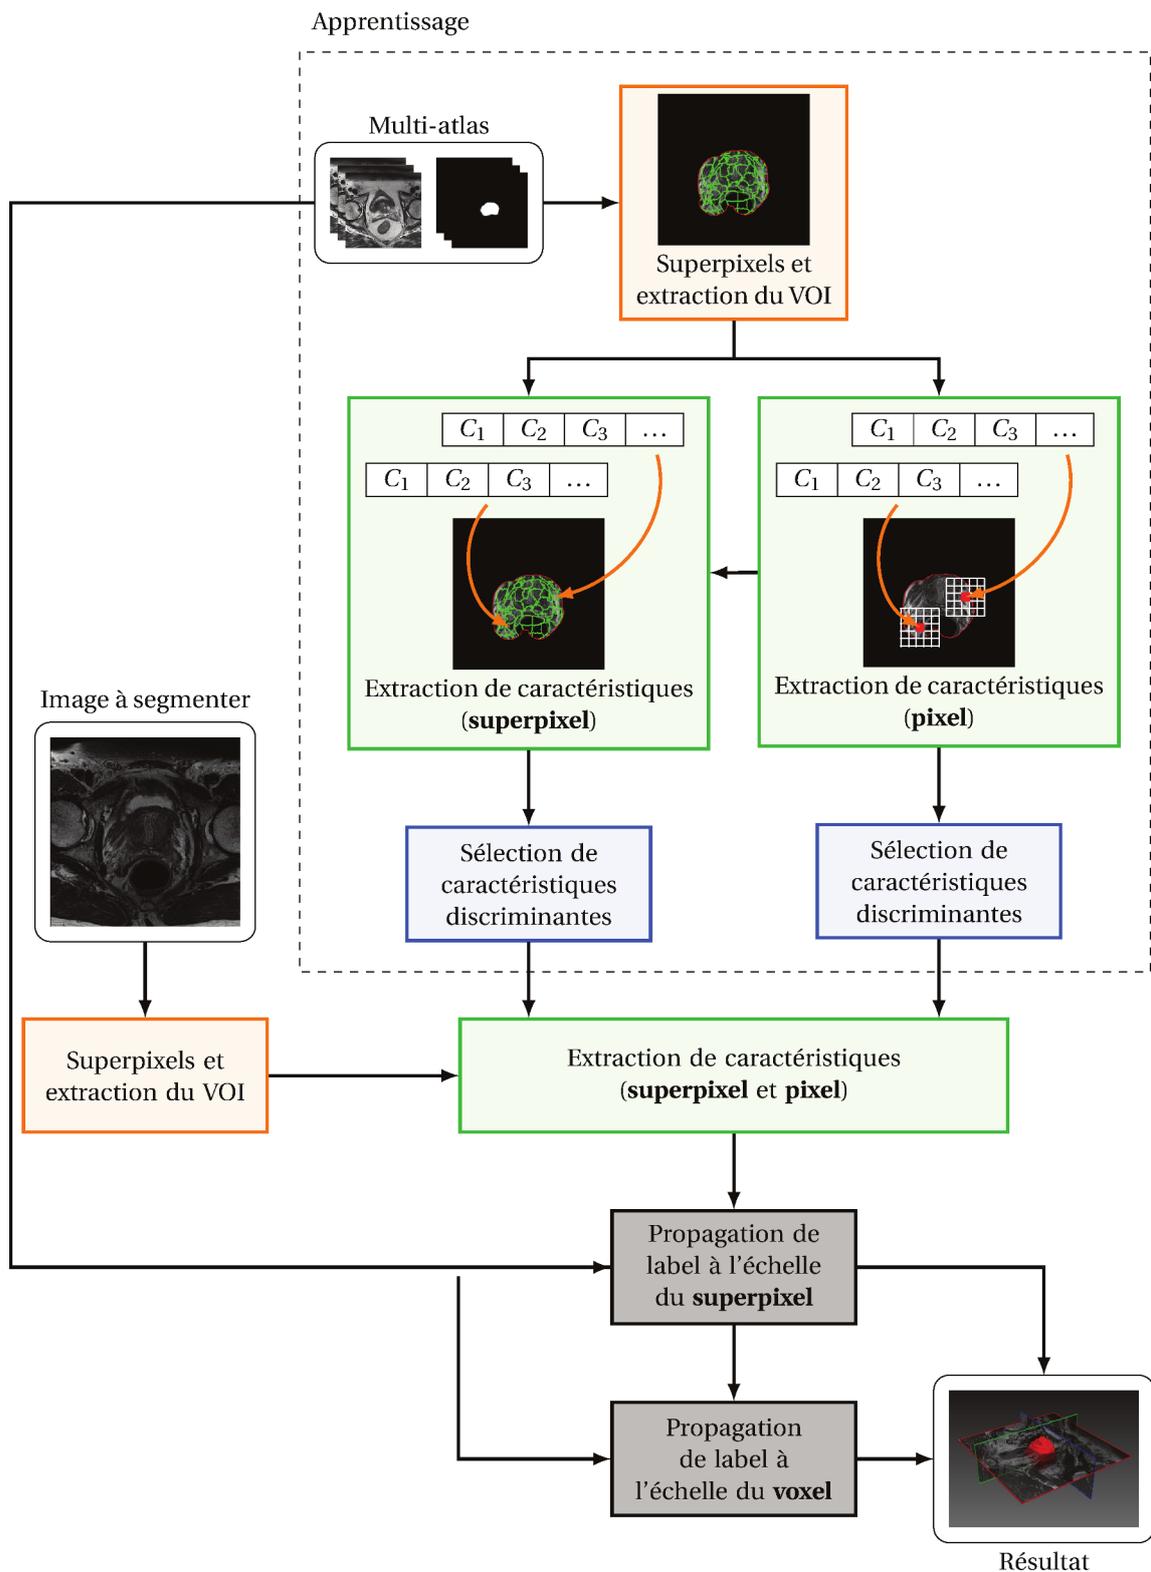


FIGURE 4.5 – Schéma de principe de notre méthode. Les encadrés en orange représentent l'étape de segmentation des OAR par superpixels puis l'extraction des OAR. Les encadrés en vert représentent l'extraction des caractéristiques à l'échelle du pixel et surperpixel. Les encadrés en bleu représentent la sélection de caractéristiques à l'échelle du superpixel puis du pixel. Enfin, les propagations aux deux échelles est réalisée, afin d'obtenir le résultat final.

des superpixels. La seconde étape calcule l'ensemble des caractéristiques préalablement sélectionnées en phase d'apprentissage à l'intérieur de ce VOI, à l'échelle des pixels et des superpixels. Enfin, la labellisation de la prostate de cette nouvelle image est effectuée en comparant ces caractéristiques avec celles du multi-atlas, tout d'abord à l'échelle des superpixels, puis à l'échelle des pixels. Ces étapes sont réalisées en 2D coupe par coupe, permettant de reconstruire un volume 3D de la prostate.

Par la suite, nous présentons en détail chaque étape de notre méthode.

4.3.2 Extraction du VOI

Anatomiquement, la prostate se trouve entre le rectum et la vessie. Une enveloppe convexe incluant ces deux organes est définie dans un premier temps à l'aide de la segmentation des OAR. Par la suite, ces deux OAR sont soustraits du volume de l'enveloppe convexe. Pour prendre en compte la forme de la prostate, une dilatation anisotropique (plus prononcée sur l'axe gauche-droite) et une érosion anisotropique (plus prononcée sur l'axe antéro-postérieur) sont appliquées avec un élément structurant de taille $30 \times 60 \times 1$ et $60 \times 50 \times 30$ voxels, respectivement, expérimentalement définies. La Figure 4.6 résume ces étapes. Les dimensions sont empiriques compte tenu de l'anatomie. Ceci définit un VOI de travail incluant la prostate.

Cette étape permet de réduire la zone de recherche dans laquelle se trouve la prostate. L'extraction du VOI est effectuée une seule fois sur les images multi-atlas ainsi que sur la nouvelle image à segmenter. À l'intérieur du VOI, les superpixels obtenus auparavant (chapitre 3) seront utilisés par la suite pour la segmentation de la prostate comme montré sur la Figure 4.7.

4.3.3 Extraction de caractéristiques

À partir des patchs précédemment décrits, il est possible d'extraire plus d'informations que les niveaux de gris, notamment des caractéristiques de textures. Chacune de ces informations est appelée caractéristique. Les fonctions précédemment vues concernant la segmentation par patchs peuvent également s'appliquer sur ces caractéristiques.

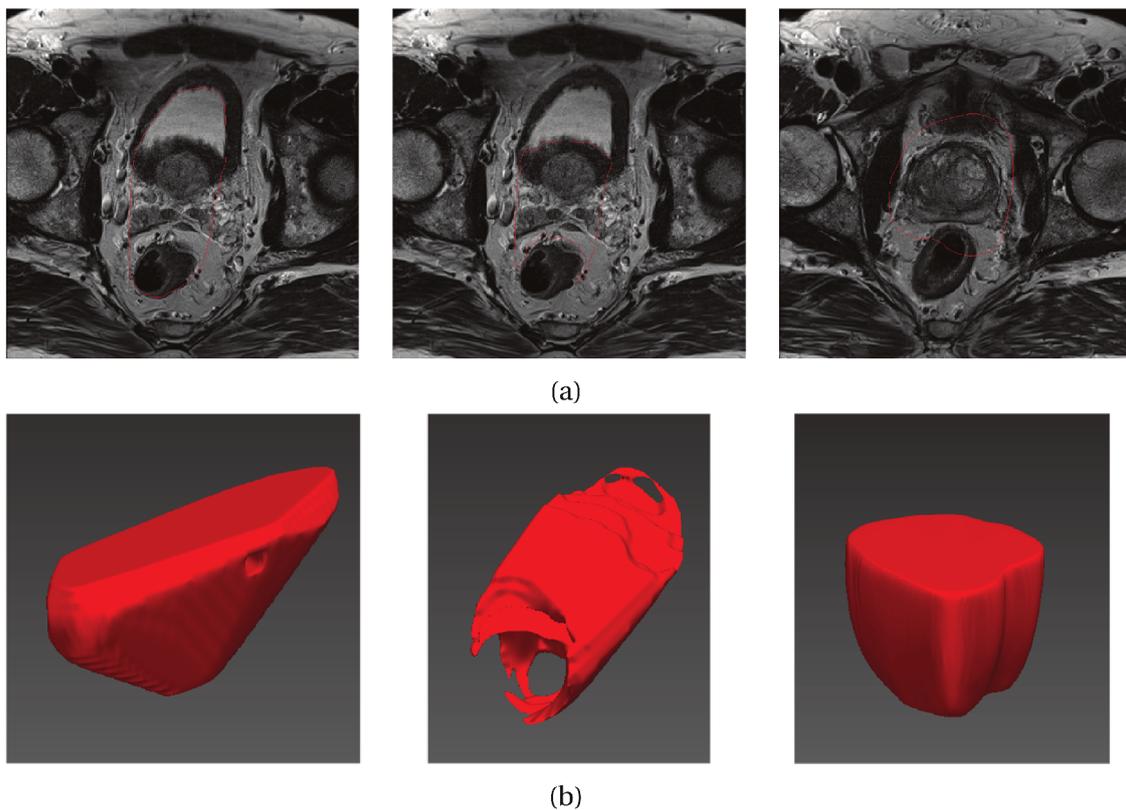


FIGURE 4.6 – Visualisation des étapes d'extraction du VOI en 2D (a) et 3D (b) d'un même patient. La colonne de gauche montre l'étape de calcul de l'enveloppe convexe. La colonne centrale montre la soustraction de deux organes. La dernière colonne représente le résultat final après l'application des opérations morphologiques.

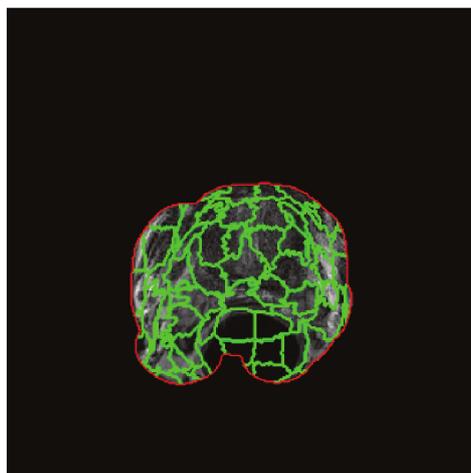


FIGURE 4.7 – Extraction du volume d'intérêt (contours en rouge) contenant des superpixels (contours en vert).

L'intérêt de ces informations supplémentaires est qu'elles permettent de mieux décrire les zones souhaitées du fait qu'elles caractérisent plus de détails et de variations que des intensités. Les caractéristiques que nous avons utilisées dans le cadre de la segmentation par patchs sont les suivantes :

1. moyenne (1 caractéristique)
2. LBP (Local Binary Pattern) [HARWOOD 1995] (1 caractéristique)
3. version étendue de LBP (ELBP) [OJALA 2002] (64 caractéristiques)
4. pseudo-Haar [LIENHART AND MAYDT 2002] (32 caractéristiques)
5. HOG (Histogram of Oriented Gradients) [DALAL AND TRIGGS 2005] (4 caractéristiques)

Chaque caractéristique d'un patch est représentée par un nombre. L'ensemble de ces caractéristiques mises bout à bout forment un vecteur de caractéristiques d'un patch sur un pixel x .

Moyenne : La caractéristique moyenne permet de calculer la valeur moyenne de niveaux de gris des pixels compris dans le patch.

Local Binary Pattern : Cette caractéristique permet de mesurer le contraste local d'une image [HARWOOD 1995]. Le principe général de la méthode *Local Binary Pattern* (LBP) est de comparer le niveau de luminance d'un pixel avec les niveaux de ses pixels voisins. Cette comparaison est définie dans un voisinage de rayon R d'une image sur un voisinage circulaire discrétisé autour d'un pixel x . Ainsi, la texture peut se représenter par les différences de niveau de gris signés entre le pixel central et ces voisins. Une carte de pondération de 2^n donne un poids à chaque pixel, selon sa position n sur le cercle, permettant de leur donner une valeur unique. Enfin, le motif binaire local est calculé en sommant ces valeurs comme montré Figure 4.8. De ce fait, lorsque deux patchs ont une texture similaire sur le contour du patch considéré, ils seront représentés par la même valeur.

Extended Local Binary Pattern : D'origine, le calcul d'un LBP devait se faire sur un cercle discrétisé en prenant les valeurs entières des pixels de l'image. Cependant, lorsque le rayon s'agrandit, il est plus difficile de concevoir une position entière d'un pixel lorsque

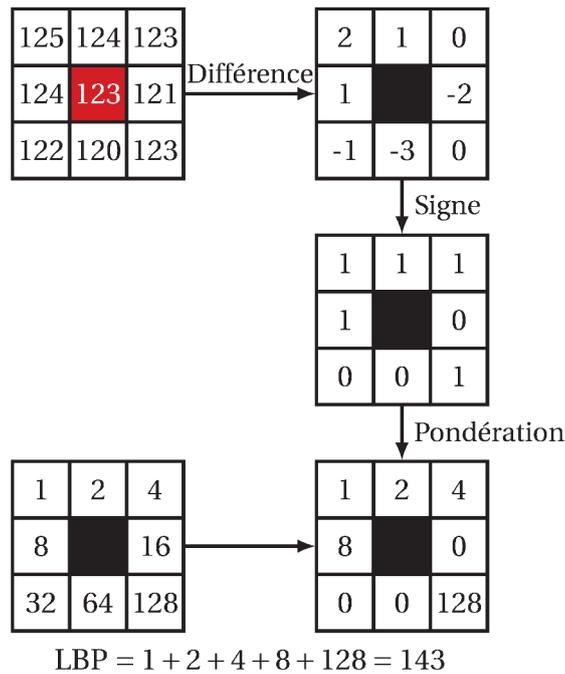


FIGURE 4.8 – Exemple d'extraction de la caractéristique LBP.

le cercle ne passe pas complètement au centre d'un pixel. C'est ainsi qu'une version étendue du LBP (ELBP) a été développée [OJALA 2002]. Cette méthode permet de ne prendre qu'une partie d'un pixel sur le bord du cercle en fonction de son expression mathématique. Un certain nombre de points sont définis le long du cercle comme montré Figure 4.9. En fonction de la position du point sur l'image, une proportion des pixels alentours est utilisée pour calculer la différence avec le pixel central. Le reste du processus reste similaire.

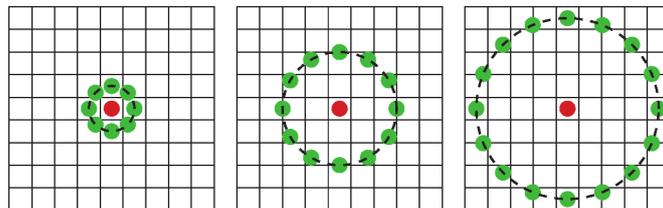


FIGURE 4.9 – Exemple d'extraction des caractéristiques ELBP avec différents rayons et nombre de points discrétisés le long du cercle.

Pseudo-Haar : Les caractéristiques pseudo-Haar tirent leur nom de leur similarité avec la décomposition en ondelettes de Haar [LIENHART AND MAYDT 2002]. Ces caractéristiques considèrent une fenêtre de détection (dans notre cas, le patch) dans laquelle sont présentes des zones rectangulaires adjacentes. Les intensités des pixels présentes dans ces rectangles sont additionnées, formant des sommes dont les différences constituent la

valeur de la caractéristique comme montré Figure 4.10.

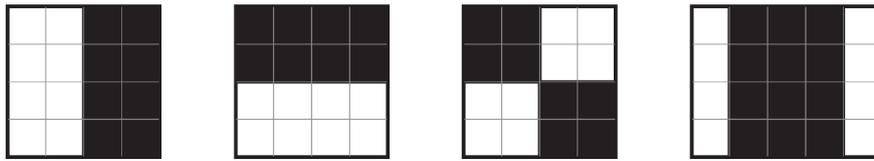


FIGURE 4.10 – Exemples d'extraction de caractéristiques pseudo-Haar.

Histogram of Oriented Gradients : La méthode d'*Histogram of Oriented Gradients* (HOG) calcule des histogrammes locaux de l'orientation du gradient sur une grille dense découpant l'image [DALAL AND TRIGGS 2005]. Dans chaque cellule de la grille, plusieurs axes du gradient sont définis. La méthode décompte ensuite le nombre de gradient apparaissant dans la cellule avec le même axe. Ainsi, un histogramme est constitué reprenant l'ensemble des angles définis dans la cellule comme visible Figure 4.11. Dans notre cas, cet HOG sera calculé par patch et chaque angle sera représenté par une caractéristique.

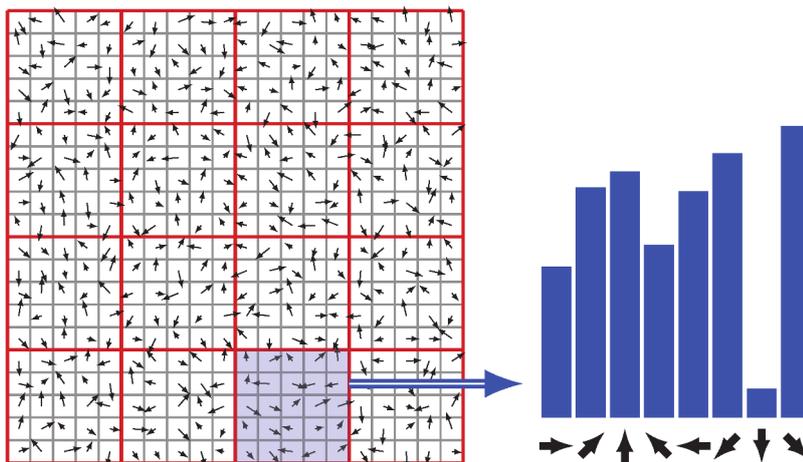


FIGURE 4.11 – Exemple d'extraction de caractéristiques HOG.

4.3.3.1 Paramètres des caractéristiques utilisées

Nous avons fait varier les paramètres des différentes caractéristiques de la manière suivante :

- LBP : 1 caractéristique
 - Utilisation d'une fenêtre 3×3 .
- ELBP : 64 caractéristiques
 - Variation du rayon de 1 à 8 pixels,

- pour chaque variation de rayon, le nombre de points sur le cercle varie de 1 à 8 points.
- Haar : 32 caractéristiques
 - Variations de tailles de filtres horizontaux, verticaux et obliques à l'intérieur du patch.
- HOG : 4 caractéristiques
 - Les 4 principaux axes de variations des gradients sont extraits des patches.

L'ensemble de jeux de paramètres décrits ici, mène à l'extraction de 102 caractéristiques. Cela signifie que, pour un pixel x donné, un vecteur de 102 valeurs lui est associé. Les caractéristiques étant calculées sur des patches, cela signifie que le vecteur de caractéristiques d'un pixel résume l'information des relations du pixel avec ses voisins sous forme d'un seul tableau.

4.3.3.2 Caractéristiques des superpixels

Jusqu'ici, l'ensemble des caractéristiques était calculé à l'échelle du pixel, dans un patch centré sur ce pixel. Étant donné que les images ont été segmentées par la méthode des superpixels (cf. chapitre 3), et que le VOI est composé de superpixels, il est intéressant de calculer les caractéristiques à l'échelle d'un superpixel. Néanmoins, la forme et taille des superpixels sont très variables et la façon d'extraire les caractéristiques, présentée jusqu'alors, ne peut donc pas s'y appliquer directement. Puisqu'une des propriétés des superpixels est que les pixels le composant sont considérés comme similaires, nous proposons de calculer la moyenne des caractéristiques à l'intérieur d'un superpixel pour obtenir ses propres caractéristiques.

4.3.3.3 Problématique d'un grand nombre de caractéristiques

Une fois ces caractéristiques calculées, il faut appliquer le principe de segmentation par patch comme vu en section 4.2.3. Il est possible d'appliquer cette méthode en prenant désormais en compte l'ensemble des caractéristiques en plus du niveau de gris, à l'échelle du superpixel puis du pixel. Cependant, le nombre de caractéristiques utilisées

ici est assez conséquent et rien ne garantit que, pour notre application, toutes ces caractéristiques soient utiles et puissent potentiellement induire des erreurs de segmentation. Effectivement, les caractéristiques ne sont pas toutes pertinentes, dû au bruit et faible contraste dans les images médicales IRM et TDM. C'est pourquoi, une étape de sélection de caractéristiques discriminantes est proposée et est présentée dans la suite de ce chapitre, afin d'extraire les meilleures caractéristiques permettant de séparer correctement en deux classes l'appartenance d'un pixel.

4.3.4 Sélection de caractéristiques discriminantes

Pour répondre à la problématique précédemment posée, la représentation parcimonieuse est adoptée pour la sélection de caractéristiques.

4.3.4.1 Principe de la représentation parcimonieuse

Le principe de la représentation parcimonieuse est de décrire un signal x le plus fidèlement possible à partir d'un dictionnaire D constitué d'un ensemble d'atomes, de la manière suivante :

$$x \approx D\alpha \quad (4.6)$$

avec α permettant de sélectionner les atomes du dictionnaire D qui décrivent au mieux le signal x qui est la somme des atomes pondérés par α .

Dans le cas de la parcimonie, le but est d'utiliser le moins d'atomes possibles, afin de représenter ce signal x , donc chercher le vecteur α qui est parcimonieux.

Afin de résoudre ce problème, l'équation (4.6) peut être écrite sous la forme suivante :

$$\min_{\alpha} \|\alpha\|_0, \quad \text{de sorte que } \|x - D\alpha\|_2 \leq \epsilon \quad (4.7)$$

avec ϵ l'erreur de représentation maximale autorisée. Résoudre cette équation (4.7) revient à résoudre un problème NP-difficile. Cette résolution sera détaillée dans les sections suivantes.

4.3.4.2 Application à la sélection de caractéristiques

Dans notre application, il s'agit de sélectionner des caractéristiques. Pour ce faire, nous construisons donc un dictionnaire D , contenant toutes les caractéristiques calculées sur les patches précédemment décrits. Cela signifie que sur l'ensemble des patches, une centaine de caractéristiques sont calculées qui forment un vecteur de caractéristiques. L'ensemble des vecteurs de caractéristiques forment ensuite le dictionnaire comme montré Figure 4.12.

$$\begin{array}{c} X \end{array} = \begin{array}{c} D \\ \hline M \text{ caractéristiques} \\ \hline M \text{ caractéristiques} \\ \hline \dots \\ \hline M \text{ caractéristiques} \end{array} \times \begin{array}{c} \alpha \end{array}^T$$

FIGURE 4.12 – Multiplication matricielle du principe de représentation d'un ensemble de signaux X dont chaque signal est extrait sur un pixel ou un superpixel.

Par la suite, une étape d'optimisation avec la contrainte parcimonieuse est réalisée. Cela permet d'obtenir uniquement les caractéristiques utiles à la classification des patches en deux classes, appartenant ou non à la prostate. Cette étape est réalisée à deux échelles, celle du superpixel, afin de limiter la zone de recherche de la prostate, puis celle du pixel.

Dans notre cas, les atomes du dictionnaire D correspondent à des vecteurs de caractéristiques de taille $1 \times M$ calculées sur chaque pixel des images de patients du multi-atlas, où M est le nombre de caractéristiques extraites. D'après l'équation (4.6), le signal x est une représentation d'un pixel que l'on souhaite décrire par rapport à ce qui est déjà connu, à savoir, le dictionnaire D . Le vecteur X est l'ensemble des pixels x pour lesquels les caractéristiques doivent être sélectionnées. Enfin, α permet de pondérer chaque élément du dictionnaire, afin de décrire le pixel.

Le vecteur de caractéristiques associé à un pixel i est noté a_i . Par conséquent, il est nécessaire de sélectionner les caractéristiques discriminantes. Pour la sélection des caractéristiques, N vecteurs de caractéristiques $a_j (j = 1, \dots, N)$ sont sélectionnés aléatoirement dans le dictionnaire. Possédant les segmentations manuelles de la prostate pour chaque vecteur de caractéristiques, le label l_j de chaque point y est connu, avec pour valeur +1 lorsque le pixel appartient à la prostate et 0 sinon.

Connaissant le label l_j d'un pixel, la sélection des caractéristiques du vecteur a_j est basée sur la résolution de l'équation (4.6) qui consiste à minimiser le critère suivant basé sur le problème logistique Lasso [TIBSHIRANI 1996] :

$$J(\alpha, c) = \sum_{j=1}^N \log(1 + \exp(-l_j(\alpha^T a_j + c))) + \lambda \|\alpha\|_1 \quad (4.8)$$

avec α le vecteur de coefficients parcimonieux, c l'ordonnée à l'origine, N le nombre de pixels, et λ le paramètre de régularisation de la contrainte parcimonieuse définie par la norme L1, menant à sélectionner le moins de caractéristiques possible.

La méthode de Nesterov [NESTEROV 2004] (disponible dans l'ensemble des fonctions de SLEP pour Matlab [LIU 2009a]) est utilisée pour minimiser l'équation (4.8). Les caractéristiques discriminantes sont définies par $\alpha \neq 0$. Ce sous ensemble de caractéristiques forme une signature parcimonieuse notée b_j . De cette manière, les signatures ne contiennent plus que des caractéristiques discriminantes. Plus les valeurs de λ sont grandes, plus de caractéristiques seront choisies. Les signatures sont regroupées dans un nouveau dictionnaire de plus petite taille noté D' . La constitution d'un tel dictionnaire est effectuée grâce à l'ensemble des atlas du multi-atlas.

Ce calcul peut également être effectué au niveau du superpixel. Pour ce faire, un vecteur de caractéristique moyen $a^{SP}(s)$ est créée en moyennant tous les vecteurs de caractéristiques des pixels dans une même région de superpixel s . De manière similaire à l'échelle du pixel, l'équation (4.8) permet de sélectionner les caractéristiques qui constituent un dictionnaire de petite taille à l'échelle du superpixel noté D'^{SP} et contenant les b_j^{SP} signatures, ($j = 1, \dots, N$).

Pour un nouveau patient à segmenter, seules les caractéristiques constituant les signatures seront extraites.

4.3.5 Segmentation à deux échelles

4.3.5.1 Segmentation de la prostate à l'échelle du superpixel

Nous proposons d'appliquer la segmentation à deux échelles. Dans un premier temps sur les régions de superpixels puis les pixels. Le principe reste le même dans les deux cas.

Pour ce faire, considérons n images recalées et leurs cartes 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 du multi-atlas. Chaque superpixel s de la nouvelle image peut superposer un ensemble de superpixels des images du multi-atlas comme montré en Figure 4.13.

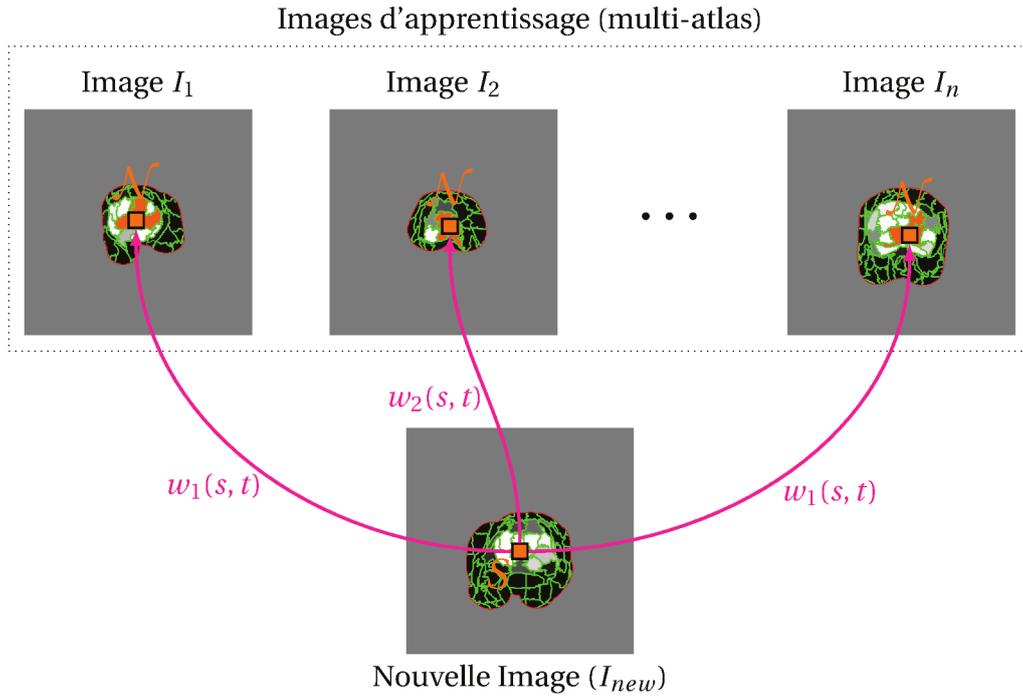


FIGURE 4.13 – Calcul du poids d'un superpixel superposé aux superpixels du multi-atlas.

Basée sur [LIAO 2012], la probabilité qu'un superpixel appartienne à la prostate est déterminé de cette façon :

$$L_{new}^{SP}(s) = \frac{\sum_{u=1}^n \sum_{t \in \mathcal{N}_u(s)} e^{-d(s_c, t_c)} w_u(s, t) L_u^{SP}(t)}{\sum_{u=1}^n \sum_{t \in \mathcal{N}_u(s)} w_u(s, t)} \quad (4.9)$$

avec L_{new}^{SP} la carte de probabilité des superpixels de la prostate de I_{new} , $L_u^{SP}(t)$ le label moyen à l'intérieur d'un superpixel t calculé avec L_u , $\mathcal{N}_u(s)$ les superpixels superposés par s dans I_u et $w_u(s, t)$ le poids du lien entre les superpixels s et t , mesurant la similarité entre leur signature. L'exponentielle négative de la distance Euclidienne d entre les centroïdes s_c et t_c des superpixels s et t permet de donner plus de poids aux superpixels proches du superpixel à labelliser.

Au lieu d'utiliser toutes les images du multi-atlas, nous choisissons celles qui res-

semblent le plus à la nouvelle image. Cette sélection utilise le même principe de contrainte par parcimonie. Pour calculer le poids $w_u(s, t)$, une matrice A est construite. Chaque colonne de A est définie par la signature $b_{I_u}^{SP}(t)$, avec $t \in \mathcal{N}_u(s)$. Le lien entre les superpixels s et t dans u images grâce à la valeur de $w_u(s, t)$ est défini de la même façon que la sélection des signatures précédemment présentées. Ainsi, la sélection des meilleures correspondances de superpixels parmi le multi-atlas consiste en la minimisation de l'équation suivante :

$$J(\theta_s) = \frac{1}{2} \|b_{I_{new}}^{SP}(s) - A\theta_s\|_2^2 + \Lambda \|\theta_s\|_1, \quad \theta_s \geq 0 \quad (4.10)$$

avec $b_{I_{new}}^{SP}(s)$ la signature parcimonieuse du superpixel s de I_{new} , Λ le paramètre de régularisation de la contrainte de parcimonie et θ_s le vecteur des coefficients parcimonieux.

La minimisation de l'équation (4.10) permet de sélectionner de manière parcimonieuse les superpixels du multi-atlas qui ressemblent le plus au nouveau superpixel pour déterminer directement les poids w_u . Cette approche multi-atlas permet, pour chaque superpixel, de combiner les atlas les plus ressemblants. Ainsi, une proportion du label de chaque atlas est prise en compte pour la labellisation des superpixels.

Les superpixels valant +1 et 0 sont directement classés, car nous savons que tous les pixels à l'intérieur du superpixel appartiennent à la prostate (+1) ou non (0). Un exemple de résultat à cette étape est montré Figure 4.14. Concernant les superpixels incertains ayant une valeur comprise dans $]0, +1[$, la même méthode précédemment présentée est appliquée à chaque pixel à l'intérieur des superpixels.

4.3.5.2 Segmentation de la prostate à l'échelle du pixel

Une fois l'étape précédente exécutée, il reste à calculer l'appartenance à la prostate des pixels présents dans les superpixels incertains. Pour ce faire, le même processus d'obtention de probabilité d'appartenance est appliquée, mais cette fois-ci à l'échelle du pixel.

La carte de probabilité finale de la prostate L_{new} de l'image I_{new} est obtenue en utili-

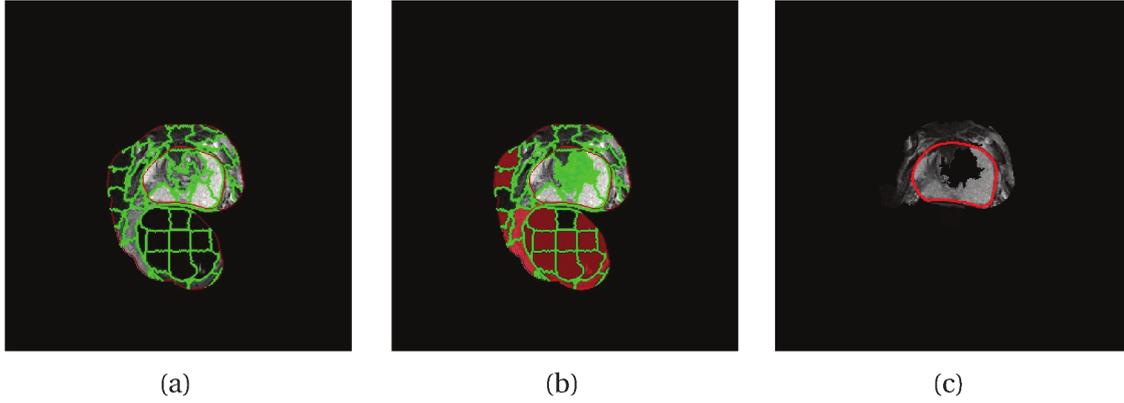


FIGURE 4.14 – (a) Visualisation des superpixels et de la prostate à segmenter à l’intérieur d’un VOI. (b) Visualisation des superpixels sûres, en **rouge** à l’extérieur (label 0) de la prostate, en **vert** à l’intérieur (label 1) de la prostate. (c) Résultat après suppression des superpixels labellisés 0 ou 1. Il ne reste plus que des pixels à traiter qui sont dans des zones de superpixels incertains. Le contour rouge représentant la prostate de référence.

sant l’équation (4.9) qui devient :

$$L_{new}(x) = \frac{\sum_{u=1}^n \sum_{y \in \mathcal{N}_u(x)} w_u(x, y) L_u(y)}{\sum_{u=1}^n \sum_{y \in \mathcal{N}_u(x)} w_u(x, y)} \quad (4.11)$$

$\mathcal{N}_u(x)$ représente désormais une fenêtre de voisinage de taille $W \times W$ centrée en x dans I_u , L_u^{SP} est remplacé par L_u et la distance d de l’équation (4.9) est fixée à 0, à la manière du schéma représenté Figure 4.4.

Puis, la matrice A est construite avec chaque colonne définie par les signatures $b_{I_u}(y)$, avec $y \in \mathcal{N}_u(x)$. Enfin, le poids $w_u(x, y)$ est calculé en utilisant $J(\theta_x)$ avec l’équation (4.10), en remplaçant $b_{I_{new}}^{SP}(s)$ par $b_{I_{new}}(x)$, donnant :

$$J(\theta_x) = \frac{1}{2} \|b_{I_{new}}(x) - A\theta_x\|_2^2 + \Lambda \|\theta_x\|_1, \quad \theta_x \geq 0 \quad (4.12)$$

4.4 Résultats expérimentaux

Cette section va présenter les résultats expérimentaux réalisés sur une base des images IRM fournie par le challenge ISBI 2013 [ARCHIVE 2013] sur la segmentation de la prostate. La méthode précédente a été appliquée sur ces images et les résultats sont évalués grâce à deux indices déjà présentés dans le chapitre 3 qui sont Dice et Vrai Positif. Les résultats des challenger n’étant plus disponibles sur le site l’hébergeant, une com-

paraison sera effectuée avec les trois meilleures méthodes sur la base de ces indices que nous avons pu enregistrer avant leur disparition du site hébergeant les résultats.

4.4.1 Évaluation

Nous avons sélectionné les dix premiers patients du challenge ISIB 2013 [[ARCHIVE 2013](#)], afin de tester notre méthode. Ces images sont de taille $320 \times 320 \times 20$ voxels et sont toutes recalées et segmentées par des experts. Ces segmentations manuelles sont considérées comme la référence absolue à laquelle nous allons comparer nos segmentations.

Le paramètre de régularisation λ pondère la contrainte parcimonieuse des signatures dans le dictionnaire dans l'équation (4.8) et peut influencer les résultats de la segmentation. Nous avons donc évalué son impact. L'influence de λ sur le nombre de caractéristiques sélectionnées dans les signatures parcimonieuses et sur les résultats des segmentations a été évaluée pour six valeurs différentes : 0.1, 0.2, 0.5, 0.7, 0.9, et 0.99. Les autres paramètres ont été fixés à : $K = 5$ (taille des patches), $W = 15$ (taille du voisinage) et $\Lambda = 10^{-4}$ (équation (4.10)). Afin de comparer les résultats des segmentations avec la référence absolue, le l'indice de Dice et taux de vrai positifs (TVP) ont été utilisés. L'indice de Dice représente le taux de superposition entre les deux volumes. Le TVP mesure la fraction des voxels du résultat de la segmentation correctement labellisés à l'intérieur de la référence absolue. Nous avons également évalué l'apport de la segmentation en deux étapes (superpixels et pixels) par rapport à l'utilisation de la méthode à la seule échelle du pixel.

L'évaluation a été accomplie avec une méthode de validation croisée de type *leave-one-out*. Cela signifie que, pour segmenter une image, les neuf autres images ont été utilisées pendant la phase d'apprentissage pour la sélection des caractéristiques. Pour l'étape de segmentation, chaque image est segmentée avec l'ensemble des fonctions de propagation de label basé sur les patches en utilisant les neuf autres images. La segmentation finale de cette image est effectuée par un vote majoritaire entre la carte de probabilité L_{new} et les neuf autres cartes de labels L_u .

Segmentation utilisant seulement les pixels (a)						
λ	0.1	0.2	0.5	0.7	0.9	0.99
#f	18	14	12	7	6	2
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
TVP	81.42 ± 11.99	81.42 ± 11.99	81.42 ± 11.99	75.46 ± 13.03	75.46 ± 13.03	75.46 ± 13.03
Segmentation utilisant les superpixels (b)						
λ	0.1	0.2	0.5	0.7	0.9	0.99
#f	35	27	7	4	2	1
DI	76.62 ± 5.94	76.62 ± 5.94	76.62 ± 5.94	72.77 ± 12.71	72.77 ± 12.71	72.77 ± 12.71
TVP	92.52 ± 8.57	92.52 ± 8.57	92.52 ± 8.57	91.23 ± 9.08	91.23 ± 9.08	91.23 ± 9.08

TABLEAU 4.1 – Nombre de caractéristique sélectionnée (#f) et la moyenne de l'indice de Dice (DI) et taux de vrais positifs (TVP) (tous deux en %) des résultats des segmentations pour différentes valeurs de λ avec et sans l'étape de superpixels.

4.4.2 Résultats et discussion

Sur l'ensemble de la base, les VOI que nous avons extraits contiennent toujours la prostate segmentée par l'expert. Cela démontre bien l'efficacité de l'étape d'extraction du VOI.

Le Tableau 4.1 montre les résultats de notre méthode (Tableau 4.1(b)) comparés à la méthode utilisant uniquement les pixels pour les étapes d'apprentissage et de segmentation (Tableau 4.1(a)). Dans les deux cas, six valeurs différentes de λ ont été testées. Tout d'abord, pour les deux méthodes, nous observons que le nombre de caractéristiques sélectionnées diminue si λ augmente. De plus, les performances de segmentation sont stables pour les trois premières valeurs de λ et commencent à décroître lorsque $\lambda > 0.5$. Une chute de performance est observée à partir de $\lambda = 0.7$. Pour nos données, une valeur de λ à 0.5 permet d'obtenir le meilleur compromis entre le faible nombre de caractéristiques sélectionnées et des bonnes performances de segmentation.

L'indice de Dice et TVP de notre méthode à deux échelles sont tous les deux améliorés de +0.61% et +11.1%, respectivement, pour $\lambda = 0.5$, par rapport à la méthode à l'échelle du pixel. De plus, les résultats sont plus stables, car les écarts-types sont plus faibles avec

notre méthode qu'avec l'utilisation des pixels seuls.

Les caractéristiques sélectionnées pour l'étape de superpixels avec $\lambda = 0.5$ sont LBP et quatre ELBP, une Haar et une HOG. Avec seulement sept caractéristiques sélectionnées sur les 102 initiales, la segmentation de la prostate est obtenue avec un indice de Dice et TVP supérieur à 76% et 81%, respectivement. De plus, avec l'ajout d'une étape de superpixels, l'algorithme de notre méthode permet de réduire le temps d'exécution de 80% en globalité puisqu'il permet de calculer l'étape au niveau du pixel que sur une partie réduite de l'image (dans les régions de superpixels incertaines). Pendant ce processus d'évaluation, les autres paramètres ont été fixés en accord avec les valeurs proposées par Liao et al. [LIAO 2012].

La Figure 4.15 montre plusieurs résultats de segmentation de la prostate par notre méthode sur trois différentes coupes de trois patients, comparés à la référence médicale. Cette figure montre de bons résultats de segmentation, même à la base (Figure 4.15 (a)) et l'apex (Figure 4.15 (c)) de la prostate, des coupes difficiles à segmenter à cause du faible contraste avec les tissus environnants.

La Figure 4.16 montre un résultat complet de la segmentation de la prostate et des organes à risque en 2D sur plusieurs axes ainsi qu'en 3D.

Nos résultats préliminaires ont été évalués sur les dix premiers patients de la base de données IRM du challenge ISBI 2013. Nous avons comparé les résultats de notre méthode par rapport aux trois meilleures méthodes présentées lors du challenge ISBI 2013 qui ont utilisé l'ensemble de la base de données patient. Pour rappel, la base de données du challenge contient 70 patients, dont 60 patients pour effectuer de l'apprentissage et 10 patients pour les tests. Le Tableau 3.1 présenté précédemment au chapitre 3 section 3.3.2 résume plus d'informations au sujet de cette base.

Comme le montre le Tableau 4.2, notre méthode donne des résultats prometteurs même si nous n'avons pas utilisé l'ensemble des données.

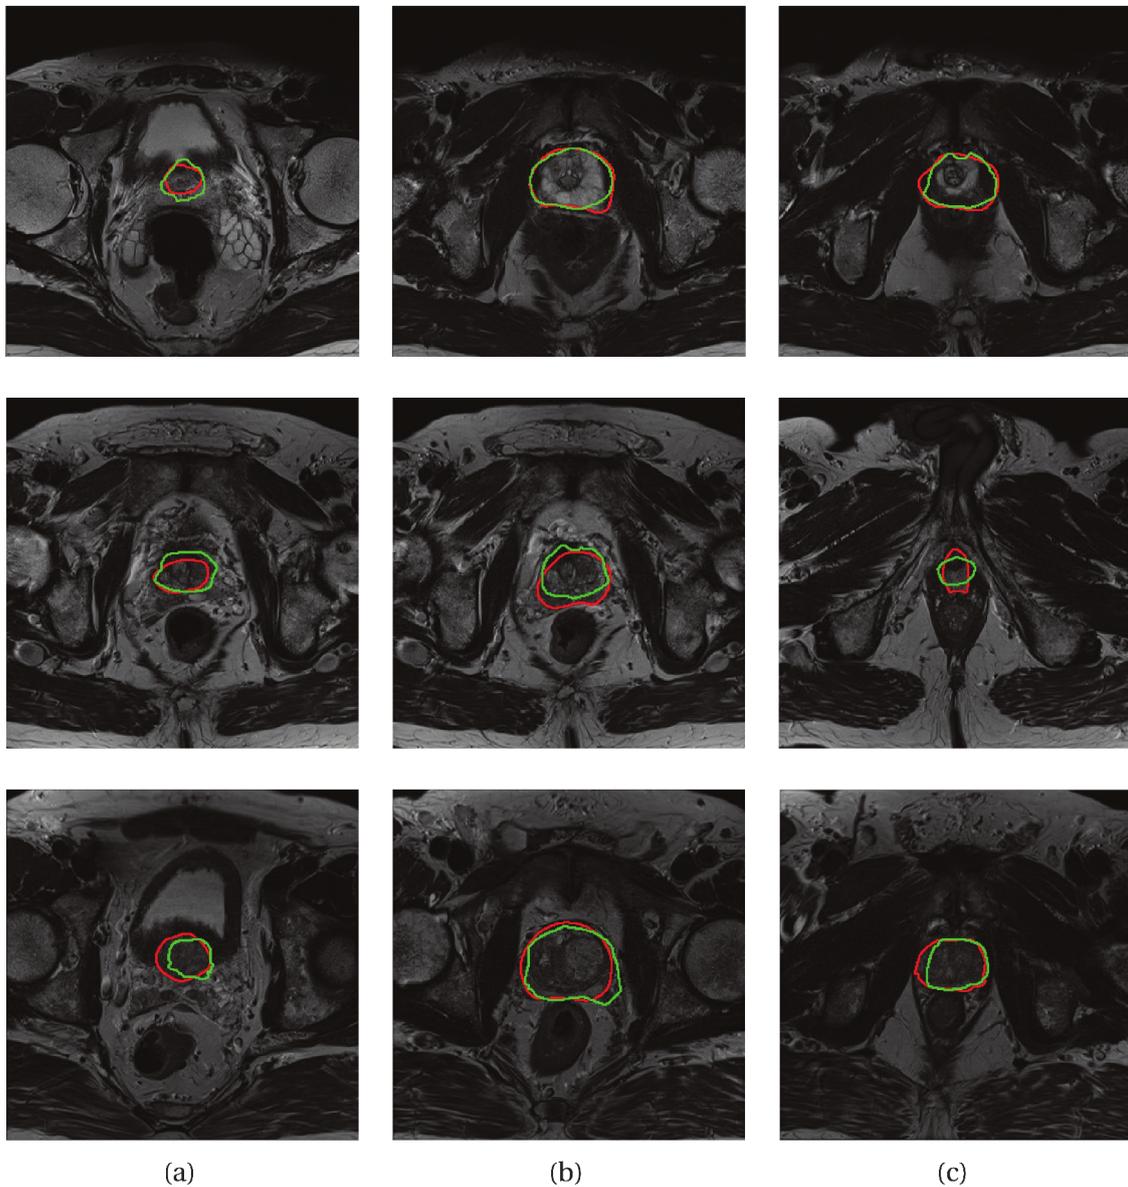


FIGURE 4.15 – Segmentation de la prostate par notre méthode (vert) comparé à la référence absolue (rouge). Chaque ligne représente un patient différent. Les colonnes labellisées (a), (b) et (c) montrent la segmentation de la prostate d’une coupe de la base, médiane et de l’apex respectivement.

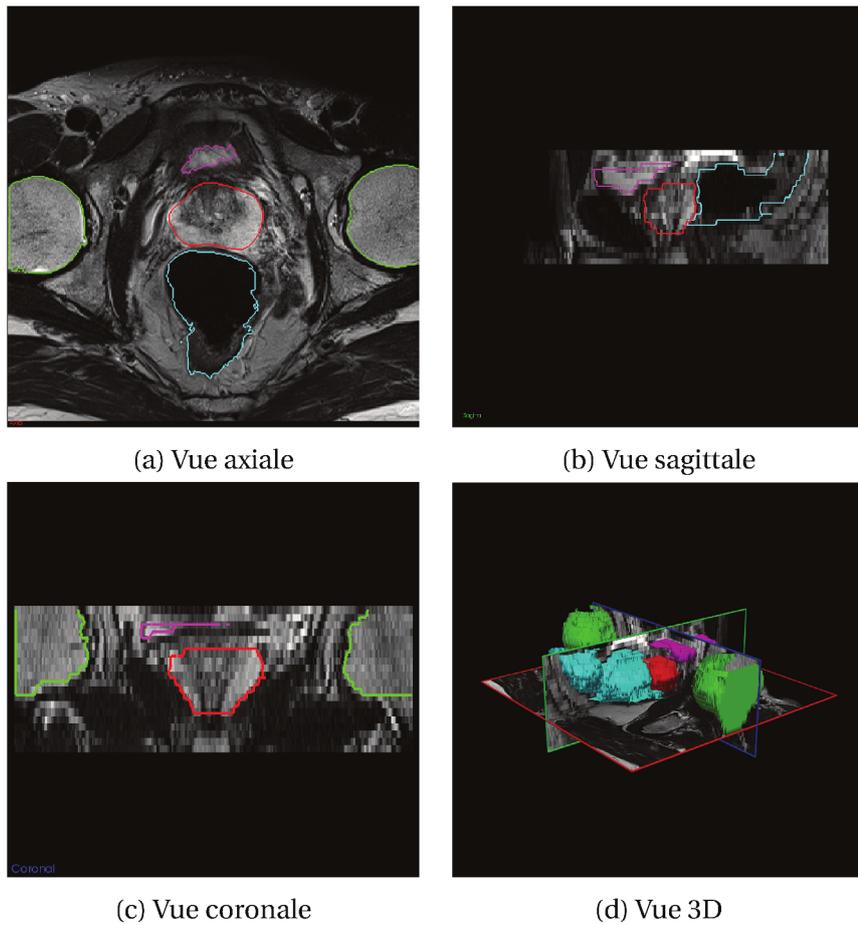


FIGURE 4.16 – Visualisation d'ensemble d'un résultat final de segmentation de l'ensemble des OAR et de la prostate selon plusieurs vues et en 3D.

Méthodes	Dice	Vrai Positif
Notre méthode	76.62	92.52
CCIPD RobToth	76.25	84.55
Geert Litjens	75.05	77.30
MD Anderson Cancer Center	53.20	51.80

TABLEAU 4.2 – Comparaison de l’indice de Dice (en %) and vrai positif (en %) entre les résultats des méthodes du challenge et notre méthode.

4.5 Conclusion

Dans cette partie, nous avons présenté une méthode pour segmenter automatiquement la prostate dans le cadre du traitement du cancer de la prostate par radiothérapie. Cette méthode est basée sur plusieurs étapes : l’extraction de caractéristiques extraits de patches, créant une signature pour chaque pixel, puis la sélection des caractéristiques les plus adaptées pour discriminer l’appartenance des pixels à la prostate, enfin la segmentation à deux échelles, superpixels puis pixels. Cette méthode a été appliquée sur les dix premiers patients IRM du challenge ISBI 2013, afin d’évaluer sa faisabilité.

Nous avons fait le choix d’une méthode automatique basée sur le multi-atlas pour cette étape de segmentation de la prostate, car c’est un problème complexe dû à la variabilité des formes et des faibles contrastes. De ce fait, notre méthode basée sur des connaissances *a priori* permet d’obtenir une segmentation stable et précise.

Notre méthode contient plusieurs paramètres d’ajustement tels que les paramètres de régularisation λ et Λ , le nombre de pixels utilisés pour calculer les caractéristiques discriminantes et la taille des patches. Nous avons fixé les différents paramètres en accord avec des méthodes similaires déjà développées par [LIAO AND SHEN 2011], afin d’évaluer l’impact du paramètre de régularisation λ sur les résultats de segmentation.

De plus, nous avons proposé une étape de labellisation à l’échelle du superpixel, afin de retirer un grand nombre de pixels qui ne seront dès lors plus à traiter à l’échelle du pixel. Cette étape permet d’améliorer les résultats, mais également de réduire le temps d’exécution de la méthode et d’être compétitive par rapport aux autres méthodes de segmentations proposées par le challenge ISBI 2013.

Conclusion générale et perspectives

Conclusion générale

Cette thèse aborde le problème de la segmentation de la prostate et des OAR associés dans le cadre de traitement par radiothérapie. L'objectif était de fournir des outils pour accélérer ou pour déporter la phase de contourage de ces organes sur des images TDM et IRM. L'introduction au sujet et les problématiques soulevées au chapitre 1 ont montré la difficulté de segmenter ces organes du fait du faible contraste avec les tissus voisins dans certains cas, ou d'inhomogénéité, voir d'artefacts dans d'autres cas. Afin de mener à bien notre tâche, nous avons proposé un nouveau système, afin de segmenter les OAR de manière semi-automatique, puis la prostate de manière automatique après une phase d'apprentissage.

L'état de l'art effectué au chapitre 2 nous a permis de connaître les solutions à cette problématique résolu par différentes approches. Tout d'abord, nous avons pu observer qu'une grande variété de méthodes ont été appliquées à la problématique de la segmentation de la prostate. Cependant, aucune d'entre elles se sont attachées à également segmenter l'ensemble des OAR associés. Quelques méthodes ont pris en charge un ou deux OAR tels que le rectum et la vessie, ces derniers servant avant tout comme aide à une meilleure délimitation de la prostate, les résultats de leur segmentation n'a pas été évaluée dans ces travaux. Dans l'ensemble des méthodes présentées, les modèles statistiques et déformables ont grandement été utilisés au début des tentatives de résolution de cette problématique. Ces dernières années, les approches par atlas, voir multi-atlas ont remporté un vif succès, car elles permettent de prendre en compte les *a priori* des experts fournissant les segmentations initiales. Ces méthodes nous ont semblé adaptées pour la

segmentation de la prostate. Étant donné que les OAR ont des régions avec des intensités assez homogènes. De plus, nous souhaitons une méthode plus rapide et plus dynamique pour la segmentation des OAR. Nous avons donc choisi une méthode interactive basée sur les superpixels permettant une implication de l'utilisateur dans le processus de segmentation.

Notre contribution réside dans la proposition d'une méthode adaptée pour la segmentation des OAR suivit d'une seconde méthode prenant en compte les résultats de la première pour segmenter la prostate. La méthode par superpixels présentée au chapitre 3 permet de créer un ensemble de petites régions homogènes voisines par l'intermédiaire de la résolution d'une équation d'Eikonal locale. Une étape interactive permet de labelliser certaines régions de superpixels. Une dernière étape automatique de diffusion permet de labelliser l'ensemble des superpixels. L'utilisateur peut alors corriger les régions sur lesquelles il peint, jusqu'à l'obtention du résultat souhaité.

Fort de cette segmentation des OAR, nous avons proposé, au chapitre 4, d'extraire un sous-volume appelé volume d'intérêt (VOI) de l'image, afin d'éviter une recherche de la prostate dans l'image entière. Une suite d'opérations morphologiques permet l'obtention de ce volume dans lequel, d'après notre étude, la prostate est toujours présente.

À la suite de cette étape, nous avons choisi d'utiliser une méthode multi-atlas afin de segmenter la prostate. Cette approche constituée d'une première phase dite d'apprentissage sur l'ensemble d'atlas (paire image et segmentation associées). La première étape de cette méthode consiste à extraire un grand nombre de caractéristiques extraites de patches du VOI. L'ensemble de ces caractéristiques n'étant pas forcément pertinentes pour la segmentation de la prostate, une étape de parcimonie permet de contraindre l'ensemble de caractéristiques, afin de ne sélectionner que le sous-ensemble pertinent, et constituer ainsi des signatures. La seconde étape est la labellisation d'une nouvelle image d'un patient en extrayant les signatures de cette nouvelle image en les comparant avec les signatures apprises à deux échelles. De plus, une étape de parcimonie est incluse, à ce stade, permettant de choisir, pour chaque pixel de l'image à labelliser, le patient le plus similaire localement et ainsi de prendre en compte une proportion du label à appliquer.

Perspectives

Nous avons proposé un système permettant de segmenter la prostate et ses OAR dans le cadre de traitement de cancer par radiothérapie. La méthode de segmentation des OAR a été évaluée sur deux modalités d'imagerie TDM et IRM et la seconde méthode uniquement en IRM. Les travaux en perspective pourront être envisagés afin d'améliorer notre méthode.

1. Concernant la première méthode basée sur les superpixels, il serait intéressant d'utiliser une méthode de prédiction des germes pour proposer une segmentation à l'utilisateur comme implémenté par [FULKERSON 2009].
2. La comparaison avec d'autres méthodes basées sur un graphe tel que le *graph-cut* serait intéressante.
3. Un autre domaine d'application que le cancer de la prostate comme le poumon ou le foie pourrait également être envisagé.
4. Par rapport à la seconde méthode, l'ajout d'autres caractéristiques pourrait être envisagées comme des filtres de Gabor ou des descripteurs SIFT ou encore DCT (Discret Cosine Transform).
5. Nous pouvons proposer comme perspective directe d'étendre la méthode multi-atlas à l'évaluation de sa faisabilité sur des images TDM bien que le principe de base ait déjà été appliqué sur des images TDM [LIAO 2012], mais sans extraction de VOI, ni utilisation de la notion de superpixels qui est à notre disposition.
6. Également, une évaluation sur l'ensemble de la base de données fourni dans le cadre du challenge ISBI [ARCHIVE 2013] est envisageable, même si les résultats des compétiteurs ne sont plus disponibles; ainsi que l'étude de λ en TDM pour constater les différences des caractéristiques sélectionnées par rapport à celles extraites en IRM.
7. Les méthodes basées sur l'apprentissage de dictionnaire, telle que K-SVD, peuvent être étudiées pour cette application.
8. Du fait de notre approche de description de l'image par un ensemble de caractéristiques, les réseaux de neurones peuvent être envisagés et notamment les réseaux de

neurones profonds (ou *deep learning*).

Liste des publications

- [1] M. GUININ, P. BUYSENS, L. MASSOPTIER, S. RUAN, L. NKHALI, B. DUBRAY et I. GARDIN : Segmentation d'organes à risque du pelvis masculin à l'aide de superpixels. *Cancer/Radiothérapie*, 18(5–6):634 –, Oct. 2014. 25e Congrès national de la Société française de radiothérapie oncologique (SFRO), Deauville, France.
- [2] M. GUININ, S. RUAN, L. NKHALI, B. DUBRAY, L. MASSOPTIER et I. GARDIN : Segmentation of pelvic organs at risk using superpixels and graph diffusion in prostate radiotherapy. *In Proceeding of IEEE 12th International Symposium on Biomedical Imaging (ISBI)*, pages 1564–1567, April 2015. Brooklyn, USA.
- [3] M. GUININ, S. RUAN, L. NKHALI, B. DUBRAY, L. MASSOPTIER et I. GARDIN : Segmentation of organs at risk using superpixels on MRI or CT images in prostate radiotherapy. *Radiotherapy and Oncology*, 115:S515, April 2015. Annual meeting of the European Society for Radiotherapy and Oncology, Barcelona, Spain.
- [4] M. GUININ, S. RUAN, B. DUBRAY, L. MASSOPTIER et I. GARDIN : Feature selection and patch-based segmentation in MRI for prostate radiotherapy. *In 2016 IEEE International Conference on Image Processing (ICIP)*, pages 2663–2667, Oct. 2016. Phoenix, USA.
- [5] M. GUININ, S. RUAN, B. DUBRAY, L. MASSOPTIER et I. GARDIN : Segmentation et sélection de caractéristiques basée sur des patches en irm prostatique. *Conférence nationale sur la Reconnaissance de Formes et Intelligence Artificielle (RFIA)*, Juin 2016. Clermont-Ferrand, France.

Bibliographie

- [ACHANTA 2010] ACHANTA, R., SHAJI, A., SMITH, K., LUCCHI, A., FUA, P., AND SÜSS-TRUNK, S., *Slic superpixels*, Tech. rep. (2010). (pages 40, 41).
- [ACOSTA 2010] ACOSTA, O., DOWLING, J., CAZOULAT, G., SIMON, A., SALVADO, O., DE CREVOISIER, R., AND HAIGRON, P., *Atlas based segmentation and mapping of organs at risk from planning ct for the development of voxel-wise predictive models of toxicity in prostate radiotherapy*, in *International Workshop on Prostate Cancer Imaging*, 42–51, Springer (2010). (pages 44, 45).
- [ACOSTA 2011] ACOSTA, O., SIMON, A., MONGE, F., COMMANDEUR, F., BASSIROU, C., CAZOULAT, G., DE CREVOISIER, R., AND HAIGRON, P., *Evaluation of multi-atlas-based segmentation of CT scans in prostate cancer radiotherapy*, in *Biomedical Imaging : From Nano to Macro, 2011 IEEE International Symposium on*, 1966–1969, IEEE (2011). (page 45).
- [ACTON AND RAY 2006] ACTON, S. T. AND RAY, N., *Biomedical image analysis : tracking*, Synthesis Lectures on Image, Video, and Multimedia Processing, 2(1), 1–152 (2006). (page 33).
- [ARCHIVE 2013] ARCHIVE, T. C. I., *NCI-ISBI 2013 Challenge : Automated Segmentation of Prostate Structures* (2013), available at : <http://goo.gl/jUE64L> [Accessed : October 21, 2015]. (pages 20, 62, 71, 93, 94, 103).
- [BOULANGER 2007] BOULANGER, J., KERVRANN, C., AND BOUTHEMY, P., *Space-time adaptation for patch-based image sequence restoration*, IEEE transactions on pattern analysis and machine intelligence, 29(6) (2007). (page 75).
- [BOYKOV AND VEKSLER 2006] BOYKOV, Y. AND VEKSLER, O., *Graph cuts in vision and graphics : Theories and applications*, in *Handbook of mathematical models in computer vision*, 79–96, Springer (2006). (page 40).
- [BUADES 2005] BUADES, A., COLL, B., AND MOREL, J.-M., *A review of image denoising algorithms, with a new one*, Multiscale Modeling & Simulation, 4(2), 490–530 (2005). (pages 76, 77).
- [BUENO 2004] BUENO, G., MARTÍNEZ-ALBALÁ, A., AND ADÁN, A., *Fuzzy-snake segmentation of anatomical structures applied to ct images*, in *International Conference Image Analysis and Recognition*, 33–42, Springer (2004). (page 33).
- [BUYSENS 2014] BUYSENS, P., GARDIN, I., AND RUAN, S., *Eikonal based region growing for superpixels generation : Application to semi-supervised real time organ segmentation in CT images*, IRBM, 35(1), 20–26 (2014). (pages 41, 42, 47, 54).
- [CHEN 2009] CHEN, T., KIM, S., ZHOU, J., METAXAS, D., RAJAGOPAL, G., AND YUE, N., *3D meshless prostate segmentation and registration in image guided radiotherapy*, in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2009*, 43–50, Springer (2009). (page 34).

- [COHEN AND COHEN 1993] COHEN, L. D. AND COHEN, I., *Finite-element methods for active contour models and balloons for 2-D and 3-D images*, Pattern Analysis and Machine Intelligence, IEEE Transactions on, 15(11), 1131–1147 (1993). (page 33).
- [COOTES 1998] COOTES, T. F., EDWARDS, G. J., AND TAYLOR, C. J., *Active appearance models*, in *European conference on computer vision*, 484–498, Springer (1998). (page 29).
- [COOTES 2001] COOTES, T. F., EDWARDS, G. J., AND TAYLOR, C. J., *Active appearance models*, IEEE Transactions on pattern analysis and machine intelligence, 23(6), 681–685 (2001). (page 31).
- [COOTES 1993] COOTES, T. F., HILL, A., TAYLOR, C. J., AND HASLAM, J., *The use of active shape models for locating structures in medical images*, in *Information Processing in Medical Imaging*, 33–47, Springer (1993). (pages 29, 30).
- [COOTES 1992] COOTES, T. F., TAYLOR, C. J., COOPER, D. H., AND GRAHAM, J., *Training models of shape from sets of examples*, in *BMVC92*, 9–18, Springer (1992). (page 29).
- [COOTES 1995] COOTES, T. F., TAYLOR, C. J., COOPER, D. H., AND GRAHAM, J., *Active shape models-their training and application*, Computer vision and image understanding, 61(1), 38–59 (1995). (page 30, 30).
- [CORTES AND VAPNIK 1995] CORTES, C. AND VAPNIK, V., *Support-vector networks*, Machine learning, 20(3), 273–297 (1995). (page 38).
- [DAISY 2014] DAISY, M., BUYSENS, P., TSCHUMPERLÉ, D., AND LÉZORAY, O., *A smarter exemplar-based inpainting algorithm using local and global heuristics for more geometric coherence*, in *Image Processing (ICIP), 2014 IEEE International Conference on*, 4622–4626, IEEE (2014). (page 75).
- [DALAL AND TRIGGS 2005] DALAL, N. AND TRIGGS, B., *Histograms of oriented gradients for human detection*, in *IEEE Comput. Soc. Conf. Computer Vision and Pattern Recognition*, vol. 1, 886–893 (2005). (pages 84, 86).
- [DESQUESNES 2013] DESQUESNES, X., ELMOATAZ, A., AND LÉZORAY, O., *Eikonal equation adaptation on weighted graphs : fast geometric diffusion process for local and non-local image and data processing*, Journal of Mathematical Imaging and Vision, 46(2), 238–257 (2013). (page 54).
- [DILLENSEGER AND MOERSCHEL 2009] DILLENSEGER, J.-P. AND MOERSCHEL, E., *Guide des technologies de l'imagerie médicale et de la radiothérapie : quand la théorie éclaire la pratique*, Elsevier Masson (2009). (pages 17, 18, 20).
- [DING 2003] DING, M., CHEN, C., WANG, Y., GYACSKOV, I., AND FENSTER, A., *Prostate segmentation in 3D US images using the cardinal-spline-based discrete dynamic contour*, in *Medical Imaging 2003*, 69–76, International Society for Optics and Photonics (2003). (page 33).
- [DOWLING 2011] DOWLING, J. A., FRIPP, J., CHANDRA, S., PLUIM, J. P. W., LAMBERT, J., PARKER, J., DENHAM, J., GREER, P. B., AND SALVADO, O., *Fast automatic multi-atlas segmentation of the prostate from 3D MR images*, in *International Workshop on Prostate Cancer Imaging*, 10–21, Springer (2011). (page 45).
- [DUBOIS 1998] DUBOIS, F., *Reconstruction des images tomographiques par rétroprojection filtrée*, Revue de l'ACOMEN, 4(2), 92–99 (1998). (page 14).
- [FENG 2010] FENG, Q., FOSKEY, M., CHEN, W., AND SHEN, D., *Segmenting CT prostate images using population and patient-specific statistics for radiotherapy*, Medical Physics, 37(8), 4121–4132 (2010). (page 31).

- [FREEDMAN AND ZHANG 2005] FREEDMAN, D. AND ZHANG, T., *Interactive graph cut based segmentation with shape priors*, in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, vol. 1, 755–762, IEEE (2005). (page 40).
- [FULKERSON 2009] FULKERSON, B., VEDALDI, A., AND SOATTO, S., *Class segmentation and object localization with superpixel neighborhoods*, in *Computer Vision, 2009 IEEE 12th International Conference on*, 670–677, IEEE (2009). (page 103).
- [GHOSE 2012] GHOSE, S., MITRA, J., OLIVER, A., MARTI, R., LLADO, X., FREIXENET, J., VILANOVA, J. C., SIDIBÉ, D., AND MÉRIAUDEAU, F., *Graph cut energy minimization in a probabilistic learning framework for 3D prostate segmentation in MRI*, in *Pattern Recognition (ICPR), 2012 21st International Conference on*, 125–128, IEEE (2012). (page 40).
- [GREIG 1989] GREIG, D. M., PORTEOUS, B. T., AND SEHEULT, A. H., *Exact maximum a posteriori estimation for binary images*, *Journal of the Royal Statistical Society. Series B (Methodological)*, 271–279 (1989). (page 41).
- [GROSGEORGE 2013] GROSGEORGE, D., PETITJEAN, C., DACHER, J.-N., AND RUAN, S., *Graph cut segmentation with a statistical shape model in cardiac MRI*, *Computer Vision and Image Understanding*, 117(9), 1027–1035 (2013). (page 40).
- [HARWOOD 1995] HARWOOD, D., OJALA, T., PIETIKÄINEN, M., KELMAN, S., AND DAVIS, L., *Texture classification by center-symmetric auto-correlation, using Kullback discrimination of distributions*, *Pattern Recognition Letters*, 16(1), 1–10 (1995). (page 84, 84).
- [INSTITUT NATIONAL DU CANCER (INCA) 2016] INSTITUT NATIONAL DU CANCER (INCA), *Les Cancers en France en 2016, l'essentiel des faits et chiffres*, <http://www.e-cancer.fr/Expertises-et-publications/Catalogue-des-publications/Les-cancers-en-France-en-2016-L-essentiel-des-faits-et-chiffres> (2016), [En ligne; accès le 07 Mars 2017]. (pages 3, 3, 8).
- [INSTITUT NATIONAL DU CANCER (INCA) 2017] INSTITUT NATIONAL DU CANCER (INCA), *Les traitements des cancers de la prostate*, <http://www.e-cancer.fr/Expertises-et-publications/Catalogue-des-publications/Les-traitements-des-cancers-de-la-prostate> (2017), [En ligne; accès le 07 Mars 2017]. (page 3).
- [KASS 1988] KASS, M., WITKIN, A., AND TERZOPOULOS, D., *Snakes : Active contour models*, *International journal of computer vision*, 1(4), 321–331 (1988). (page 33).
- [KLEIN 2008] KLEIN, S., VAN DER HEIDE, U. A., LIPS, I. M., VAN VULPEN, M., STARING, M., AND PLUIM, J. P., *Automatic segmentation of the prostate in 3D MR images by atlas matching using localized mutual information*, *Medical physics*, 35(4), 1407–1417 (2008). (page 44).
- [KNOLL 1999] KNOLL, C., ALCAÑIZ, M., GRAU, V., MONSERRAT, C., AND JUAN, M. C., *Outlining of the prostate using snakes with shape restrictions based on the wavelet transform (Doctoral Thesis : Dissertation)*, *Pattern Recognition*, 32(10), 1767–1781 (1999). (page 33).
- [LADAK 2000] LADAK, H. M., MAO, F., WANG, Y., DOWNEY, D. B., STEINMAN, D. A., AND FENSTER, A., *Prostate segmentation from 2D ultrasound images*, in *Engineering in Medicine and Biology Society, 2000. Proceedings of the 22nd Annual International Conference of the IEEE*, vol. 4, 3188–3191, IEEE (2000). (page 33).

- [LANGERAK 2010] LANGERAK, T. R., VAN DER HEIDE, U. A., KOTTE, A. N., VIERGEVER, M. A., VAN VULPEN, M., AND PLUIM, J. P., *Label fusion in atlas-based segmentation using a selective and iterative method for performance level estimation (SIMPLE)*, IEEE transactions on medical imaging, 29(12), 2000–2008 (2010). (page 45).
- [LEE 2003] LEE, C.-C., CHUNG, P.-C., AND TSAI, H.-M., *Identifying multiple abdominal organs from CT image series using a multimodule contextual neural network and spatial fuzzy rules*, IEEE Transactions on Information Technology in Biomedicine, 7(3), 208–217 (2003). (page 36).
- [LI AND JOLLY 2008] LI, K. AND JOLLY, M.-P., *Simultaneous detection of multiple elastic surfaces with application to tumor segmentation in CT images*, in *Medical Imaging*, 69143S–69143S, International Society for Optics and Photonics (2008). (page 40).
- [LI 2011] LI, W., LIAO, S., FENG, Q., CHEN, W., AND SHEN, D., *Learning image context for segmentation of prostate in ct-guided radiotherapy*, in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 570–578, Springer (2011). (page 39).
- [LIAO 2012] LIAO, S., GAO, Y., AND SHEN, D., *Sparse patch based prostate segmentation in CT images*, in *Med. Image Comput. Comput. Assist. Interv.*, 385–392, Springer (2012). (pages 45, 91, 96, 103).
- [LIAO AND SHEN 2011] LIAO, S. AND SHEN, D., *A learning based hierarchical framework for automatic prostate localization in CT images*, in *Prostate Cancer Imaging. Image Analysis and Image-Guided Interventions*, 1–9, Springer (2011). (page 99).
- [LIENHART AND MAYDT 2002] LIENHART, R. AND MAYDT, J., *An extended set of haar-like features for rapid object detection*, in *IEEE Int. Conf. Image Proc.*, vol. 1, 1–900 (2002). (pages 84, 85).
- [LITJENS 2011] LITJENS, G., VOS, P., BARENTSZ, J., KARSSEMEIJER, N., AND HUISMAN, H., *Automatic computer aided detection of abnormalities in multi-parametric prostate MRI*, in *SPIE Medical Imaging*, 79630T–79630T, International Society for Optics and Photonics (2011). (page 38).
- [LIU 2009a] LIU, J., JI, S., AND YE, J., *SLEP : Sparse Learning with Efficient Projections*, Arizona State University (2009). (page 90).
- [LIU 2009b] LIU, X., LANGER, D. L., HAIDER, M. A., YANG, Y., WERNICK, M. N., AND YETIK, İ. Ş., *Prostate cancer segmentation with simultaneous estimation of Markov random field parameters and class*, Medical Imaging, IEEE Transactions on, 28(6), 906–915 (2009). (page 34).
- [LOWE 1999] LOWE, D. G., *Object recognition from local scale-invariant features*, in *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*, vol. 2, 1150–1157, Ieee (1999). (page 31).
- [LU 2011] LU, C., CHELIKANI, S., PAPADEMETRIS, X., KNISELY, J. P., MILOSEVIC, M. F., CHEN, Z., JAFFRAY, D. A., STAIB, L. H., AND DUNCAN, J. S., *An integrated approach to segmentation and nonrigid registration for application in image-guided pelvic radiotherapy*, Medical Image Analysis, 15(5), 772–785 (2011). (page 35).
- [MARTIN 2008] MARTIN, S., DAANEN, V., AND TROCCAZ, J., *Atlas-based prostate segmentation using an hybrid registration*, International Journal of Computer Assisted Radiology and Surgery, 3(6), 485–492 (2008). (page 44).
- [MARTIN 2010] MARTIN, S., TROCCAZ, J., AND DAANEN, V., *Automated segmentation of the prostate in 3D MR images using a probabilistic atlas and a spatially constrained deformable model*, Medical physics, 37(4), 1579–1590 (2010). (page 44).

- [MCCULLOCH AND PITTS 1943] MCCULLOCH, W. S. AND PITTS, W., *A logical calculus of the ideas immanent in nervous activity*, The bulletin of mathematical biophysics, 5(4), 115–133 (1943). (page 36).
- [MILLETARI 2016] MILLETARI, F., NAVAB, N., AND AHMADI, S.-A., *V-net: Fully convolutional neural networks for volumetric medical image segmentation*, in *3D Vision (3DV), 2016 Fourth International Conference on*, 565–571, IEEE (2016). (page 37).
- [MOORE 2008] MOORE, A. P., PRINCE, S. J., WARRELL, J., MOHAMMED, U., AND JONES, G., *Superpixel lattices*, in *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*, 1–8, IEEE (2008). (page 62).
- [NESTEROV 2004] NESTEROV, Y., *Introductory lectures on convex optimization*, vol. 87, Springer Science & Business Media (2004). (page 90).
- [OJALA 2002] OJALA, T., PIETIKÄINEN, M., AND MÄENPÄÄ, T., *Multiresolution gray-scale and rotation invariant texture classification with local binary patterns*, IEEE Trans. Pattern Anal. Mach. Intell., 24(7), 971–987 (2002). (pages 84, 85).
- [OSHER AND SETHIAN 1988] OSHER, S. AND SETHIAN, J. A., *Fronts propagating with curvature-dependent speed : algorithms based on Hamilton-Jacobi formulations*, Journal of computational physics, 79(1), 12–49 (1988). (page 34).
- [OTSU 1975] OTSU, N., *A threshold selection method from gray-level histograms*, Automatica, 11(285-296), 23–27 (1975). (page 34).
- [OZER 2009] OZER, S., HAIDER, M. A., LANGER, D. L., VAN DER KWAST, T. H., EVANS, A. J., WERNICK, M. N., TRACHTENBERG, J., AND YETIK, I. S., *Prostate cancer localization with multispectral MRI based on relevance vector machines*, in *Biomedical Imaging : From Nano to Macro, 2009. ISBI'09. IEEE International Symposium on*, 73–76, IEEE (2009). (page 38).
- [PENG 2013] PENG, B., ZHANG, L., AND ZHANG, D., *A survey of graph theoretical approaches to image segmentation*, Pattern Recognition, 46(3), 1020–1038 (2013). (page 40).
- [PEYRÉ 2010] PEYRÉ, G., PÉCHAUD, M., KERIVEN, R., AND COHEN, L. D., *Geodesic methods in computer vision and graphics*, Foundations and Trends in Computer Graphics and Vision, 5(3–4), 197–397 (2010). (pages 54, 55).
- [PHAM 2000] PHAM, D. L., XU, C., AND PRINCE, J. L., *Current methods in medical image segmentation 1*, Annual review of biomedical engineering, 2(1), 315–337 (2000). (page 27).
- [ROHLFING AND MAURER JR 2007] ROHLFING, T. AND MAURER JR, C. R., *Shape-based averaging*, IEEE Trans. Image Process., 16(1), 153–161 (2007). (page 79).
- [ROUSSEAU 2011] ROUSSEAU, F., HABAS, P. A., AND STUDHOLME, C., *A supervised patch-based approach for human brain labeling*, IEEE Trans. Med. Imag., 30(10), 1852–1862 (2011). (page 78).
- [ROUSSON 2005] ROUSSON, M., KHAMENE, A., DIALLO, M., CELI, J. C., AND SAUER, F., *Constrained surface evolutions for prostate and bladder segmentation in CT images*, in *Computer Vision for Biomedical Image Applications*, 251–260, Springer (2005). (page 34).
- [SETHIAN 1999] SETHIAN, J. A., *Level set methods and fast marching methods : evolving interfaces in computational geometry, fluid mechanics, computer vision, and materials science*, vol. 3, Cambridge university press (1999). (page 55).

- [SHAH 2016] SHAH, A., CONJETI, S., NAVAB, N., AND KATOUZIAN, A., *Deeply learnt hashing forests for content based image retrieval in prostate MR images*, in *SPIE Medical Imaging*, 978414–978414, International Society for Optics and Photonics (2016). (page 37).
- [SONG 2010] SONG, Q., LIU, Y., LIU, Y., SAHA, P. K., SONKA, M., AND WU, X., *Graph search with appearance and shape information for 3-D prostate and bladder segmentation*, in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2010*, 172–180, Springer (2010). (page 40).
- [SONG 2009] SONG, Q., WU, X., LIU, Y., SMITH, M., BUATTI, J., AND SONKA, M., *Optimal graph search segmentation using arc-weighted graph for simultaneous surface detection of bladder and prostate*, in *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2009*, 827–835, Springer (2009). (page 40).
- [TANG 2004] TANG, X., JEONG, Y., RADKE, R. J., AND CHEN, G. T., *Geometric-model-based segmentation of the prostate and surrounding structures for image-guided radiotherapy*, in *Electronic Imaging 2004*, 168–176, International Society for Optics and Photonics (2004). (page 31).
- [TERZOPOULOS 1987] TERZOPOULOS, D., PLATT, J., BARR, A., AND FLEISCHER, K., *Elastically deformable models*, in *ACM SIGGRAPH 87, in Computer Graphics*, vol. 21, 205–214, ACM (1987). (page 32).
- [TIAN 2016] TIAN, Z., LIU, L., ZHANG, Z., AND FEI, B., *Superpixel-based segmentation for 3d prostate mr images*, *IEEE transactions on medical imaging*, 35(3), 791–801 (2016). (page 41).
- [TIBSHIRANI 1996] TIBSHIRANI, R., *Regression shrinkage and selection via the lasso*, *Journal of the Royal Statistical Society. Series B (Methodological)*, 267–288 (1996). (page 90).
- [TRÉMEAU AND COLANTONI 2000] TRÉMEAU, A. AND COLANTONI, P., *Regions adjacency graph applied to color image segmentation*, *IEEE Transactions on Image Processing*, 9(4), 735–744 (2000). (page 59).
- [TRULLO 2017] TRULLO, R., PETITJEAN, C., RUAN, S., DUBRAY, B., NIE, D., AND SHEN, D., *Segmentation of Organs at Risk in Thoracic CT images using a SharpMask Architecture and Conditional Random Fields*, in *IEEE International Symposium on Biomedical Imaging (ISBI)* (2017). (page 37).
- [TSAI 2003a] TSAI, A., WELLS, W. M., TEMPANY, C., GRIMSON, E., AND WILLSKY, A. S., *Coupled multi-shape model and mutual information for medical image segmentation*, in *Information Processing in Medical Imaging*, 185–197, Springer (2003). (page 34).
- [TSAI 2003b] TSAI, A., YEZZI JR, A., WELLS, W., TEMPANY, C., TUCKER, D., FAN, A., GRIMSON, W. E., AND WILLSKY, A., *A shape-based approach to the segmentation of medical imagery using level sets*, *Medical Imaging, IEEE Transactions on*, 22(2), 137–154 (2003). (page 34).
- [WANG 2005] WANG, Q., TANG, X., AND SHUM, H., *Patch based blind image super resolution*, in *Computer Vision, 2005. ICCV 2005. Tenth IEEE International Conference on*, vol. 1, 709–716, IEEE (2005). (page 75).
- [XU AND PRINCE 1998] XU, C. AND PRINCE, J. L., *Snakes, shapes, and gradient vector flow*, *Image Processing, IEEE Transactions on*, 7(3), 359–369 (1998). (page 33).

- [YAN 2010] YAN, P., XU, S., TURKBEY, B., AND KRUECKER, J., *Discrete deformable model guided by partial active shape model for TRUS image segmentation*, IEEE Transactions on Biomedical Engineering, 57(5), 1158–1166 (2010). (page 32).
- [YU 2017] YU, L., YANG, X., CHEN, H., QIN, J., AND HENG, P.-A., *Volumetric ConvNets with Mixed Residual Connections for Automated Prostate Segmentation from 3D MR Images* (2017). (page 37).
- [ZAIM AND JANKUN 2007] ZAIM, A. AND JANKUN, J., *An energy-based segmentation of prostate from ultrasound images using dot-pattern select cells*, in *Acoustics, Speech and Signal Processing, 2007. ICASSP 2007. IEEE International Conference on*, vol. 1, I–297, IEEE (2007). (page 33).
- [ZHU 2007] ZHU, Y., WILLIAMS, S., AND ZWIGGELAAR, R., *A hybrid ASM approach for sparse volumetric data segmentation*, Pattern Recognition and Image Analysis, 17(2), 252–258 (2007). (page 30).

Segmentation 3D des organes du pelvis masculin par des méthodes superpixel et multi-atlas dans le contexte de la prise en charge des cancers prostatiques par radiothérapie externe

Résumé :

Le cancer de la prostate est une cause majeure de décès dans le monde. La radiothérapie externe est une des techniques utilisée pour traiter ce cancer. Pour ce faire, la segmentation de la prostate et de ses organes à risque (OAR) associés (le rectum, la vessie et les têtes fémorales) est une étape majeure dans l'application du traitement.

L'objectif de cette thèse est de fournir des outils afin de segmenter la prostate et les OAR de manière automatique ou semi-automatique. Du fait du relatif bon contraste des OAR dans l'image, nous nous sommes orientés vers une approche semi-automatique de leur segmentation, consistant en une sur-segmentation de l'image en petites régions homogènes appelées superpixels. L'utilisateur de la méthode labellise quelques superpixels dans les OAR comme des germes. Enfin, la méthode segmente les OAR grâce à une diffusion sur le graphe (à partir des germes) construit par les superpixels. Quant à la segmentation de la prostate, un sous-volume de l'image appelé VOI (Volume Of Interest), dans lequel se trouve la prostate, est tout d'abord défini. À l'intérieur de ce VOI, la segmentation de la prostate est réalisée. Un dictionnaire composé des caractéristiques de textures extraites sur chaque patch du VOI est d'abord construit. La sélection de caractéristiques du dictionnaire sous contraintes parcimonieuses permet ensuite de trouver celles qui sont le plus informatives. Enfin, une propagation de label de patch sous contrainte parcimonieuse est appliquée pour segmenter la prostate à deux échelles, superpixels et pixels. Notre méthode a été évaluée sur des images TDM du Centre Henri Becquerel et IRM du challenge ISBI 2013 avec des résultats prometteurs.

Mots clés : Segmentation, Organes à risque, Prostate, Radiothérapie, Superpixels, Multi-atlas, Parcimonie

Abstract :

Prostate cancer is a leading cause of death worldwide. External radiotherapy is one of the techniques used to this disease. In order to achieve this, the segmentation of the prostate and its associated organs at risk (OAR) (rectum, bladder and femoral heads) is a major step in the application of the treatment.

The objective of this thesis is to provide tools to segment prostate and OAR automatically or semi-automatically. Several approaches have been proposed in recent years to address these issues. As OAR have a relatively good contrast in the image, we have focused on a semi-automatic approach to segment them, consisting of an over-segmentation of the image into small homogeneous regions called superpixels. Then, the user labels some superpixels in the OAR as germs. Finally, the OAR segmentation is performed by a graph diffusion (from germs) constructed by superpixels. Regarding the prostate segmentation, a sub-volume of the image called VOI (Volume Of Interest), in which the prostate is located, is first defined. The prostate segmentation is performed within this VOI. A dictionary composed of the texture characteristics extracted on each patch of the VOI is first constructed. Then, the selection of characteristics of the dictionary under parsimonious constraints allows to find the most informative ones. Finally, based on these selected characteristics, patch label propagation under parsimonious constraint is applied to segment the prostate at two scales, superpixels and pixels. Our method was evaluated with promising results on TDM images of the Henri Becquerel Center and IRM of the 2013 ISBI challenge.

Keywords : Segmentation, Organ at risk, Prostate, Radiotherapy, Superpixels, Multi-atlas, Sparse
