
Optimisation avec représentation des structures

De nombreux travaux utilisent des modélisations par graphes pour guider la reconnaissance, comme par exemple dans [Colliot et al. \(2006\)](#); [Mangin et al. \(1996\)](#); [Deruyver et al. \(2009\)](#). Certains de ces travaux utilisent un processus de segmentation séquentielle. Ce type de processus permet de diviser un problème de segmentation globale en sous-problèmes, et d'ordonner la résolution de ces sous-problèmes, le principe étant de commencer par les problèmes les plus « simples », pour aller vers les plus « difficiles ». Pour la segmentation des structures cérébrales, la difficulté de segmentation d'une structure particulière est liée aux caractéristiques de la structure elle-même, comme sa forme, ou à la quantité d'information disponible sur son entourage immédiat : la structure sera plus simple à segmenter si toutes les structures avoisinantes sont déjà segmentées.

Nous avons décrit au chapitre 3 comment nous pouvons créer un modèle à partir des connaissances anatomiques sur un graphe spatial. Le processus de segmentation séquentielle nécessite d'avoir plusieurs objets à segmenter évidemment, mais également de pouvoir utiliser de l'information issue des objets segmentés pour permettre ou faciliter la segmentation des autres structures. Le modèle décrit dans le chapitre 3 est donc bien adapté à un processus de segmentation séquentielle. Le domaine d'application, la segmentation des structures cérébrales, est également bien adapté à ce type de processus car il y a de nombreuses structures à segmenter et les relations entre les structures sont décrites dans des ouvrages neuro-anatomiques comme celui de [Waxman \(2000\)](#).

Parmi les travaux cités, nous nous intéresserons particulièrement aux travaux décrits par [Colliot et al. \(2006\)](#) qui proposent d'utiliser les relations spatiales pour segmenter et reconnaître les structures cérébrales de manière progressive, en utilisant un modèle similaire au modèle décrit au chapitre 3. À chaque itération, une structure est segmentée, et sa segmentation est guidée par les relations spatiales existant entre cette structure et les structures précédemment segmentées. Toute la connaissance générique est représentée en utilisant un graphe. Une structure particulière (les ventricules latéraux) est utilisée comme structure de référence, c'est-à-dire comme point de départ de la segmentation. Enfin, une séquence ad-hoc de segmentation des structures, à partir de la structure de référence, permet de ne segmenter les structures les plus compliquées qu'une fois que suffisamment d'information est disponible. La figure 4.1 présente des résultats de segmentation obtenus grâce à ce cadre de segmentation, et avec une séquence définie de manière ad-hoc et empirique. L'objet de ce chapitre est de proposer des raisonnements permettant de remplacer la séquence de segmentation ad-hoc par une séquence de segmentation optimale par rapport à la connaissance disponible, au modèle et aux données utilisées. Une séquence de segmentation correspond ici à un chemin dans un graphe et répond donc au problème suivant : à partir d'une structure de référence,

quelles sont les segmentations successives à effectuer pour segmenter au mieux une structure objectif ?

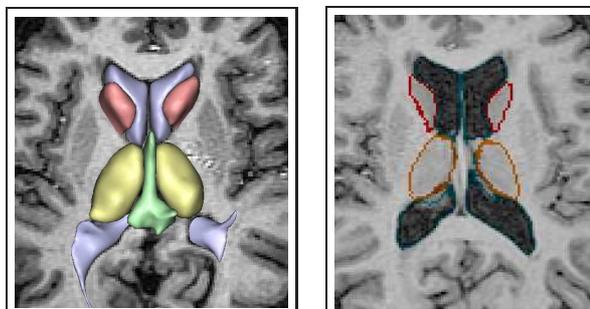


FIG. 4.1 – Les résultats de segmentation présentés par [Colliot et al. \(2006\)](#).

L'imprécision intrinsèque des relations spatiales leur confère une grande stabilité qui permet de prendre en compte la variabilité anatomique existant dans les structures cérébrales. Mais lorsqu'un cas comportant une pathologie se présente, alors la variabilité peut devenir trop importante pour pouvoir être prise en compte de cette manière. En effet, des structures peuvent être déformées, déplacées et même éventuellement disparaître. Dans ce dernier cas, la structure même de l'image est altérée. Dans ce chapitre et le suivant, nous proposons différentes méthodes permettant de déterminer une séquence de segmentation qui ne soit plus ad-hoc, mais qui soit adaptée en fonction des connaissances qui sont disponibles et des pathologies éventuelles.

Dans une première partie, nous allons présenter une approche utilisant une représentation de la forme de chaque structure, pour inférer le chemin de segmentation optimal en fonction du modèle fourni et de la connaissance a priori sur les structures utilisées. L'utilisation d'une connaissance a priori nous permet de définir un chemin complet avant de commencer à effectuer des segmentations. En revanche l'approche est dépendante de la connaissance a priori pour les formes de chaque structure, et est donc moins susceptible de s'adapter aux cas pathologiques (qui entraînent des modifications morphologiques).

Dans une deuxième partie, nous présentons donc une manière de modifier la méthode qui permet de prendre en compte les cas pathologiques. Nous considérons dans ce cas que la pathologie est connue, c'est-à-dire dans notre cas que le type de tumeur cérébrale (sa classe et ses caractéristiques) est connu.

Tous les raisonnements présentés dans les deux premières parties de ce chapitre effectuent une optimisation qui peut être qualifiée de locale, dans le sens où ils attribuent à chaque arc une mesure de manière indépendante, utilisée ensuite pour inférer le chemin. Dans une troisième partie, nous présentons une méthode permettant d'effectuer une estimation globale de la pertinence d'un chemin, c'est-à-dire permettant de faire la sélection du chemin complet à partir d'un unique critère évaluant sa pertinence.

4.1 Raisonnement avec représentation de la forme des structures

Dans cette première partie, nous proposons une méthode permettant de déterminer une séquence optimale de segmentation entre une structure de référence et une structure cible. Cette méthode utilise, pour chaque structure contenue dans le modèle, une représentation de la forme de cette structure. Nous distinguons deux cas différents. Pour commencer, le cas normal, dans le cas de la segmentation des structures cérébrales, correspond à une image sans pathologie, le cas dit

« sain ». Dans un deuxième temps, nous présentons une adaptation de cette méthode pour les cas qui présentent une pathologie.

4.1.1 Raisonnement dans le cas « sain »

Notre objectif est donc de proposer un raisonnement qui permette la sélection du « meilleur » chemin entre une structure de référence, qui sera segmentée au préalable, et une structure que nous souhaitons segmenter et reconnaître, dans une image donnée. Nous utilisons le modèle présenté dans le chapitre 3, à savoir un graphe spatial où les nœuds correspondent aux structures cérébrales et les arcs portent les relations spatiales existant entre des structures. Un chemin correspond donc à une séquence de structures à segmenter, et doit permettre de conduire à la meilleure segmentation possible de la structure objectif, en fonction de nos connaissances de la scène.

La notion de « meilleur » chemin est relative aux contraintes du processus de segmentation. Dans cette première approche, notre raisonnement doit être apte, dans le cadre du processus de segmentation séquentielle présenté par [Colliot *et al.* \(2006\)](#), d'être à même de remplacer le chemin de segmentation ad-hoc utilisé, le processus lui-même restant inchangé. Les contraintes du processus portent donc sur la possibilité de segmenter une structure en utilisant les relations spatiales issues des structures segmentées pour guider la segmentation des structures restantes. Notons que nous ne définissons pas, pour une structure donnée, un minimum de relations spatiales qui seraient nécessaires à sa segmentation. Cette information, plutôt empirique, pourrait être incorporée sur chaque nœud du graphe. Dans cette approche, nous ne tenons pas non plus compte de la difficulté intrinsèque de la segmentation de chacune des structures.

Dans ce cas, nous considérons des chemins simples et sans boucle et donc le nombre de chemins est borné. Ce nombre peut néanmoins être très élevé, et le problème de l'extraction d'un chemin peut rapidement devenir trop complexe pour être calculé. Mais dans notre cas, nous nous limitons à un petit nombre de nœuds, et nous évitons donc ces problèmes. Néanmoins, l'utilisation de cette méthode avec un graphe plus grand nécessiterait de résoudre cette problématique.

Nous avons donc un modèle qui porte une connaissance générique composée d'objets (des structures cérébrales) et de relations spatiales décrites de manière textuelle. Pour déterminer la meilleure séquence de segmentation, nous proposons de munir chaque relation spatiale présente dans le modèle d'une mesure de sa pertinence. Cette mesure évalue l'adéquation avec laquelle cette relation spatiale décrit l'agencement spatial entre les deux structures : la référence et la cible de la relation. Cette évaluation n'est possible qu'à partir du moment où nous avons choisi un formalisme de représentation des relations spatiales, car la comparaison va porter sur la représentation de la relation spatiale et non pas sur la relation elle-même. Nous avons décrit dans la partie 3.3 le formalisme flou utilisé pour représenter les relations spatiales. La méthode utilisée pour représenter une relation spatiale répond à la question suivante : pour une structure de référence, quels sont les lieux de l'espace où cette relation est satisfaite. Cette méthode nous permet d'obtenir une représentation dans l'espace de l'image d'une relation spatiale où chaque point de la représentation correspond à la mesure de satisfaction de la relation en ce point. Notre critère d'évaluation va donc comparer pour chaque relation un ensemble flou et une structure « cible ». Cette mesure, qui sera décrite dans la partie suivante, sera ensuite utilisée pour définir un poids sur les arcs du graphe, et également comme critère pour l'optimisation du chemin en utilisant des algorithmes dérivés de notions classiques de la théorie des graphes présentés dans la partie 4.1.3.

La structure de référence dans le cadre des images IRM du cerveau humain est le ventricule, qui présente en général un fort contraste avec les structures environnantes, et qui se situe approximativement au centre (dans une coupe axiale) du cerveau. La figure 4.1.a présente une coupe axiale d'une image IRM 3D du cerveau, et quelques structures, dont le ventricule, sont marquées.

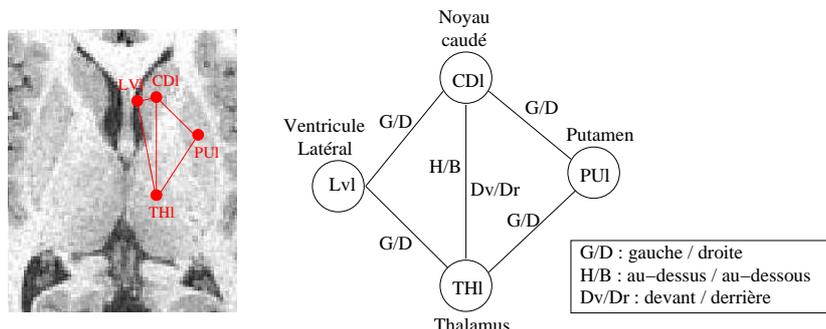


FIG. 4.2 – La connaissance et le modèle utilisés dans cette étude. L’image à gauche est une coupe d’un volume cérébral en vue axiale et montre les structures anatomiques suivantes : LVI ventricule latéral, CDI noyau caudé, THI le thalamus et PUI le putamen. À droite, les mêmes structures apparaissent dans le graphe modélisant la connaissance. Les relations spatiales entre ces structures sont portées par les arcs du graphe.

4.1.2 Évaluation de la pertinence d’un arc

Nous proposons ici deux critères permettant d’évaluer la pertinence d’un arc comme une mesure de l’adéquation entre un ensemble flou représentant la relation spatiale portée par cet arc, et de la structure cible de l’arc. Les représentations des relations spatiales sont effectuées dans l’espace de l’image.

Les notations que nous utilisons pour les graphes et pour désigner les ensembles flous ont été introduites dans le chapitre 3 dans la première partie. Nous nous contenterons ici de rappeler les notations les plus utilisées. Par la suite, nous utilisons la notation $G = (V, E)$ pour désigner un graphe relationnel attribué, avec V désignant l’ensemble des nœuds et E l’ensemble des arcs. Un interpréteur d’arc associe à chaque arc e un ensemble flou μ_{Rel} , défini dans le domaine spatial, et représentant l’ensemble (éventuellement singleton) des relations spatiales portées par cet arc, et calculé par rapport à une structure de référence qui est le nœud source de l’arc, tel que défini par Bloch (1999). De la même manière, un ensemble flou μ_{Obj} est porté par chaque nœud et correspond à la représentation de la structure cérébrale portée par le nœud.

L’ensemble flou μ_{Obj} représente la structure cible. Cette représentation peut être une simple segmentation issue de la base d’apprentissage, sous forme de carte binaire de la structure, éventuellement rendue floue à l’aide d’une dilatation floue par exemple pour accroître la prise en compte de la variabilité. Cette représentation peut également provenir d’un atlas. Il est important que les données utilisées pour calculer les représentations des relations spatiales et les représentations des structures proviennent de la même source afin que leur comparaison soit effective. Dans tous les cas, l’information provient d’une image déjà segmentée et non pas de l’image qui doit être segmentée.

Critère de pertinence

La pertinence d’une relation spatiale doit donc représenter l’adéquation entre μ_{Rel} et μ_{Obj} , c’est-à-dire le degré avec lequel les ensembles flous représentant des relations spatiales ayant une même structure pour cible donnent une localisation précise de cette structure. Si la structure cible est représentée sous forme d’un ensemble flou, alors nous avons deux ensembles flous, définis dans l’espace de l’image, et donc aisément comparables. La pertinence des relations spatiales, dans le cadre du formalisme flou de représentation choisi, nous permet de déduire deux critères de pertinence :

- la localisation de la relation,
- la précision de la relation.

Une relation spatiale fournit une indication sur la position de la structure cible par rapport à la structure de référence, la position exacte étant donnée par la connaissance a priori. Si la relation spatiale fournit une bonne localisation, alors en chaque point de la structure cible, la relation spatiale doit avoir un degré de satisfaction maximal. Plus spécifiquement, si nous comparons des ensembles flous, il est nécessaire que l'ensemble des points de la structure cible soient situés dans le noyau de la relation spatiale (c'est-à-dire un degré de satisfaction de 1).

Une bonne localisation, telle qu'elle vient d'être définie, permet de s'assurer que la relation est pleinement satisfaite à l'emplacement de l'objet. Mais ce critère n'est pas suffisant, car la taille du support de la relation spatiale n'est pas prise en compte. Le support de la relation spatiale, représentée dans l'espace de l'image, correspond à l'ensemble des points pour lesquels le degré de satisfaction de la relation n'est pas nul. Par exemple, dans un cas extrême, tous les points de l'ensemble flou peuvent satisfaire entièrement la relation. Dans ce cas, la localisation sera toujours correcte. Il est donc nécessaire de tenir compte d'un autre critère qui estime la précision de la relation. Nous la définissons comme le rapport entre la taille de l'objet et la taille du support de la relation étudiée.

Nous pouvons trouver un cadre formel approprié pour comparer des ensembles flous dans (Bouchon-Meunier *et al.* (1996)), où les auteurs proposent des mesures de comparaison ainsi qu'une classification de ces mesures. Deux mesures permettant d'estimer les critères de pertinence décrits ont été étudiées :

Mesure de satisfaction :

Le premier critère est une mesure de satisfaction (« M-measure of satisfiability (Bouchon-Meunier *et al.* (1996)) ») définie ainsi :

$$f_s(Rel, Obj) = \frac{\sum_{x \in \mathcal{S}} \min(\mu_{Rel}(x), \mu_{Obj}(x))}{\sum_{x \in \mathcal{S}} \mu_{Obj}(x)} , \quad (4.1)$$

où \mathcal{S} désigne l'espace de l'image. Ce critère mesure la précision de la position de la structure dans la région où la relation est satisfaite, et sera maximale si la structure est entièrement située dans le noyau de μ_{Rel} . Cependant la taille de la région où la relation est satisfaite n'est pas prise en compte. Dans le cas extrême (mais improbable) où le support de la relation correspondrait au domaine de l'image, la relation serait alors maximale avec n'importe quel objet. Si la représentation de la structure n'est pas floue, alors cette mesure est réduite à :

$$f_{s_{crisp}}(Rel, Obj) = \frac{\sum_{x \in Obj} \mu_{Rel}(x)}{|Obj|} . \quad (4.2)$$

Mesure de ressemblance :

Le deuxième critère est une mesure de ressemblance (« M-measure of resemblance (Bouchon-Meunier *et al.* (1996)) ») définie comme :

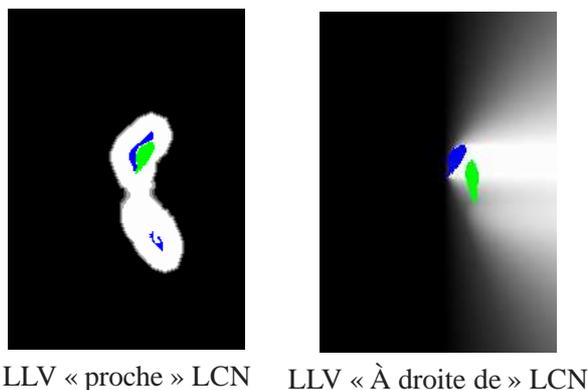
$$f_r(Rel, Obj) = \frac{\sum_{x \in \mathcal{S}} \min(\mu_{Rel}(x), \mu_{Obj}(x))}{\sum_{x \in \mathcal{S}} \max(\mu_{Rel}(x), \mu_{Obj}(x))} . \quad (4.3)$$

Ce critère mesure l'adéquation entre la structure dans la région de l'espace où la relation est satisfaite, le maximum étant atteint si l'objet et la relation sont identiques. Cette mesure permet d'évaluer en même temps le positionnement mais aussi la précision de la relation. Il s'agit donc d'un taux de recouvrement entre μ_{Rel} et μ_{Obj} .

Comparaison des critères :

La mesure de satisfaction est maximale lorsque la localisation de la relation est correcte, mais elle ne prend pas en compte la taille du support ; la normalisation étant effectuée par la taille de l'objet cible. La mesure de ressemblance est maximale lorsque les deux ensembles flous sont identiques, permettant donc de répondre aux deux critères de localisation et de précision. Toutefois, la mesure de la précision pourrait être plus fine. En effet, les cas où l'ensemble flou correspondant à la relation spatiale est identique à l'ensemble flou représentant l'objet ($\mu_{Rel} = \mu_{Obj}$) est improbable, et pas forcément souhaitable, car une telle relation ne pourrait gérer la variabilité.

Le critère de précision pourrait être raffiné en fonction de chaque relation spatiale. Par exemple, pour une relation d'orientation, la précision concerne moins la taille du noyau que la précision des angles utilisés pour calculer la relation. D'un autre côté, le cas extrême où le support d'une relation correspond à tout l'espace de l'image ne se présente pas en pratique. Les deux critères proposés sont donc satisfaisants pour notre application. La mesure de satisfiabilité est en revanche plus simple à calculer car elle est limitée à l'ensemble flou correspondant à l'objet. La figure 4.3 illustre cela.



Comparaison	Satisfaction	ressemblance
LLV « proche » LCN	1,000	0,037
LLV « À droite de » LCN	0,874	0,003

FIG. 4.3 – Comparaison des critères. La mesure de satisfaction reflète que les deux structures cibles (en vert) sont proches du noyau de la relation spatiale représentée à partir de la structure de référence (en bleu) : entièrement dans le noyau dans le premier cas (à gauche) et partiellement dans le deuxième cas. Les mesures de ressemblance ont des valeurs beaucoup plus faibles, car la normalisation est effectuée par rapport à la taille du support de la relation. Dans le premier cas, la relation « proche de » est plus précise que dans le deuxième cas où nous avons une relation d'orientation. Les valeurs reflètent principalement cette différence, plus que la position dans le noyau.

4.1.3 Sélection du « meilleur » chemin

Nous avons présenté deux mesures pouvant être utilisées pour mesurer la pertinence d'une relation (ou des relations) portée(s) par un arc du graphe. L'une ou l'autre mesure peut alors être insérée dans le graphe comme un poids. Il faut noter que chaque poids a une valeur positive et que donc il ne peut y avoir de boucle avec un poids négatif. Nous nous retrouvons donc dans une situation proche de problèmes classiques de la théorie des graphes et nous nous intéressons

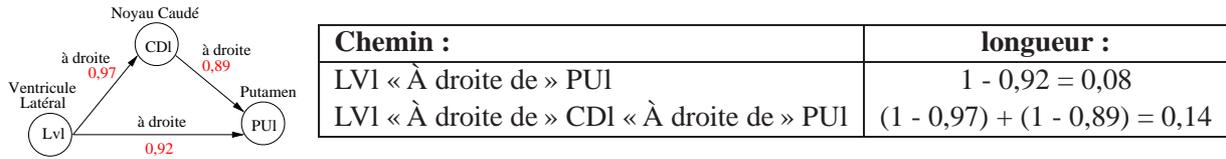


FIG. 4.4 – Un petit exemple pour illustrer le comportement du plus court chemin avec un critère de satisfaction. Nous ne considérons que des relations d’orientation dans ce cas. Nous considérons un arc qui relierait directement le ventricule au putamen, ce qui n’est pas souhaitable en pratique vu l’éloignement des structures. Le chemin direct a une longueur de 0,08 contre 0,14 pour le chemin comportant deux arcs. Pour qu’un chemin comportant deux arcs soit choisi contre un chemin comportant un unique arc même moyen, il est nécessaire que les deux arcs du chemin aient des valeurs deux fois meilleures que l’arc du chemin unique. Ce cas ne se présente pas dans nos expériences. En prenant la moyenne de satisfaction sur le chemin, le chemin plus long sera préféré.

donc aux algorithmes classiques d’optimisation pour trouver le meilleur chemin. Toutefois, nous expliquons également pourquoi les chemins qui pourraient être obtenus par ces algorithmes n’ont pas forcément les caractéristiques souhaitées pour notre problème de segmentation, nous allons donc présenter comment adapter des notions issues de ces algorithmes à notre problème.

Meilleur chemin moyen :

L’algorithme du plus court chemin effectue une optimisation globale sur le graphe. Cette optimisation peut donc accepter pour un chemin donné des valeurs assez différentes, même si le chemin est optimal. Un chemin globalement correct peut alors inclure un arc avec une faible valeur de satisfaction (ou un fort poids). De plus, cet algorithme favorise (évidemment) des chemins courts, et pas seulement des chemins avec des arcs avec un poids faible : un chemin comportant un unique arc avec un poids élevé sera préféré à un chemin comportant deux arcs avec des valeurs meilleures. Le processus de segmentation utilisant les relations spatiales pour guider la segmentation, il est important de noter que plus le chemin comporte de relations utilisables, et plus la segmentation sera encadrée. Potentiellement, un chemin plus informatif est donc plus intéressant.

Pour illustrer cela, nous pourrions envisager un chemin direct entre le ventricule et le putamen, au lieu de segmenter en premier lieu le thalamus et le noyau caudé, puis le putamen. Ce chemin serait sans doute privilégié par l’algorithme du plus court chemin, mais ne permettrait pas une meilleure segmentation à cause de l’imprécision et de l’éloignement des deux structures concernées (nous ne considérons pas une relation de distance ici, mais uniquement l’éloignement entre les deux structures qui induit une plus grande imprécision). La figure 4.4 illustre ce comportement. L’arc « direct » entre le ventricule et le putamen, grâce à sa faible longueur, est préféré à tous les autres.

Nous proposons donc une adaptation de cet algorithme en normalisant le coût de chaque chemin par sa longueur. Cette adaptation conduit à sélectionner non plus le chemin le plus court, mais plutôt le chemin qui a le plus faible poids moyen. Cette modification permet de ne pas favoriser des chemins courts par rapport aux chemins plus informatifs.

Soit \mathcal{F} l’ensemble des ensembles flous sur le domaine spatial. Soit $f : \mathcal{F} \times \mathcal{F} \rightarrow \mathbb{R}$ une fonction à valeurs réelles, ici une mesure de comparaison (parmi les mesures précédemment décrites). La sélection du meilleur chemin moyen \hat{p} entre deux nœuds v et v' sera le résultat de :

$$\min_{p \in \mathcal{P}} \frac{\sum_{e \in p} (1 - f(\mu_{Rel}, \mu_{Obj}))}{card(p)}, \quad (4.4)$$

où e est un arc dans le chemin p , \mathcal{P} représente l'ensemble des chemins de v à v' , μ_{Obj} est l'ensemble flou représentant la structure cible de l'arc e , μ_{Rel} est l'ensemble flou représentant la relation spatiale portée par l'arc e , et $card(p)$ représente le nombre de nœuds présents dans le chemin p . Par exemple dans la figure 4.2, si v est le ventricule latéral (Lvl) et v' le putamen (PUI), un des chemins entre ces deux structures est : $Lvl - L/R - CDl - L/R - PUI$.

Plus grand flot minimal :

Le problème de l'arc « déficient », c'est-à-dire la possibilité pour un arc ne satisfaisant que peu les critères de sélection de se retrouver dans un chemin globalement bon, peut être contourné en caractérisant un chemin par son arc de flot minimal, ce qui correspond à l'arc de plus faible capacité (le poids ici) parmi les arcs du chemin. Nous proposons donc d'effectuer la sélection parmi ces arcs de plus faible capacité, en choisissant celui qui présente la plus forte valeur.

Il faut donc chercher le maximum parmi les capacités minimales de chaque chemin, et nous proposons d'optimiser le critère suivant :

$$\max_{p \in \mathcal{P}} (\min_{e \in p} (f(\mu_{Rel}, \mu_{Obj}))) \quad (4.5)$$

avec les mêmes notations que dans la méthode précédente. Nous considérons dans nos exemples des graphes avec peu de structures et de chemins possibles, nous pouvons donc effectuer l'optimisation avec une recherche exhaustive parmi tous les chemins à partir de la structure de référence vers la structure cible. Pour chaque chemin, la capacité minimale est calculée et le chemin possédant le maximum parmi ces valeurs est sélectionné.

Cette formulation permet d'éviter les chemins qui ont un arc trop faible, et donc de résoudre le problème de cet arc. De plus, n'étant pas dépendante du nombre d'arcs du chemin, elle ne favorise pas les chemins d'une longueur donnée, ce qui évite le deuxième problème souligné avec l'algorithme du plus court chemin.

4.1.4 Expériences

La figure 4.2 présente le graphe qui est utilisé dans nos expériences. Ce graphe contient 4 structures cérébrales : le ventricule latéral gauche, qui est également la structure de référence, le noyau caudé, le thalamus et enfin le putamen, qui est la structure cible dans nos expériences. Nous reprenons ici les structures et les relations spatiales utilisés par [Colliot et al. \(2006\)](#), le but étant de remplacer le chemin ad-hoc par un chemin déterminé par une optimisation du graphe. Il s'agit donc de trouver le meilleur chemin entre le ventricule et le putamen. Chacune de ces structures est présente dans les deux hémisphères du cerveau de manière symétrique par rapport au plan inter-hémisphérique. Nous ne considérons que les structures du côté gauche ici. Les expériences considèrent en outre que l'extraction de chacune des structures présente le même niveau de difficulté.

Comme source pour la représentation des structures, nous avons choisi d'utiliser un unique cas, pour lequel nous possédons une segmentation. Cependant, chacune des structures est rendue floue afin de représenter une certaine imprécision. La figure 4.5 illustre le mécanisme de « fuzzification » d'une structure anatomique. Cette « fuzzification » est effectuée en effectuant une dilatation floue de la représentation d'une structure par un élément structurant parabololoïde défini ainsi :

$$se(x, y, z) = 1 - \frac{(x - x_c)^2 + (y - y_c)^2 + (z - z_c)^2}{\sigma^2},$$

où (x_c, y_c, z_c) représente le centre de l'élément structurant et σ est un paramètre fixé à 5 dans nos expériences.

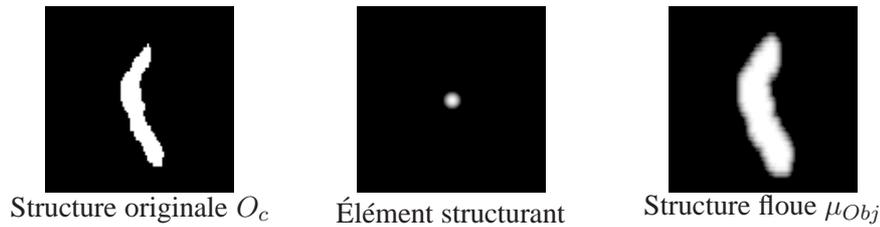


FIG. 4.5 – « Fuzzification » d'une représentation d'une structure. La structure (à gauche) provient d'une segmentation du cerveau. Une dilatation floue par un élément structurant parabolique (au centre) permet de rendre la structure floue (à droite).

Nous pouvons alors définir μ_{obj} ainsi :

$$\mu_{obj} = \delta_{se}(O_c)$$

où O_c représente une structure anatomique.

Les relations spatiales comprises dans le graphe pour nos expériences sont des relations directionnelles. Toutefois, l'extension à d'autres types de relations spatiales binaires peut être effectuée simplement. Il faut toutefois que la fusion de deux relations spatiales conserve une valeur sémantique. Les relations spatiales sont calculées à partir des représentations binaires des structures, les représentations floues sont utilisées pour calculer les critères entre la représentation de la relation et la structure cible de cette relation.

La représentation des relations spatiales est effectuée selon le formalisme flou présenté dans la partie 3.3. La figure 4.3 présente un exemple de relation spatiale d'orientation.

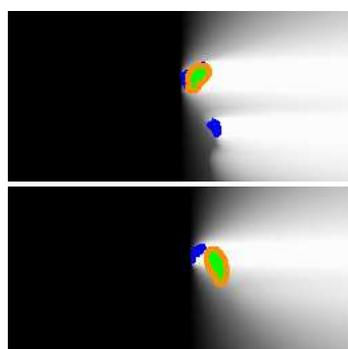
Arc			Satisf.
Ventricule latéral	« Au-dessus »	Thalamus	0,97
Ventricule latéral	« À droite de »	Noyau caudé	0,97
Noyau caudé	« En avant »	Thalamus	0,97
Thalamus	« En arrière »	Noyau caudé	0,96
Thalamus	« À droite de »	Putamen	0,92
Noyau caudé	« À droite de »	Putamen	0,89
Noyau caudé	« Au-dessus »	Thalamus	0,82
Thalamus	« Au-dessous »	Noyau caudé	0,64

TAB. 4.1 – Le classement des arcs en fonction de la mesure de satisfaction.

TAB. 4.2 – Le classement des arcs en fonction de la mesure de ressemblance.

Arc			Ressem. (x100)
Noyau caudé	« En avant »	Thalamus	0,73
Ventricule latéral	« Au-dessus »	Thalamus	0,46
Noyau caudé	« À droite de »	Putamen	0,44
Thalamus	« À droite de »	Putamen	0,42
Noyau caudé	« Au-dessus »	Thalamus	0,41
Thalamus	« En arrière »	Noyau caudé	0,40
Ventricule latéral	« À droite de »	Noyau caudé	0,32
Thalamus	« Au-dessous »	Noyau caudé	0,20

Évaluation des arcs :



Noyau caudé « À droite du » Ventricule
satisfaction : **0,97**
ressemblance : **0,32**

Putamen « À droite du » Noyau caudé
satisfaction : **0,89**
ressemblance : **0,44**

Graphe valué :

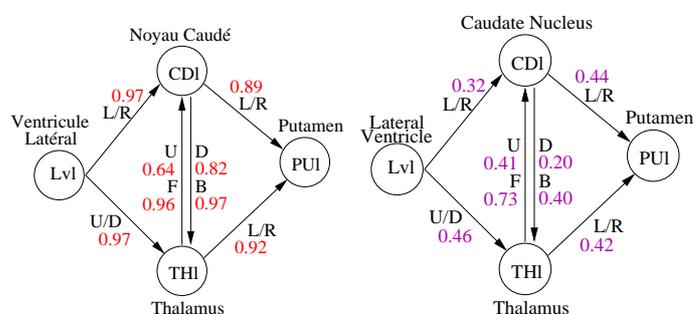


FIG. 4.6 – Les valeurs de satisfaction (en bas à gauche) et de ressemblance (en bas à droite) mesurées pour chaque arc. En haut deux exemples avec un ensemble flou μ_{rel} représentant une relation d'orientation et l'ensemble flou μ_{obj} correspondant à la cible. Les mesures de satisfaction et de ressemblance sont calculées en comparant ces ensembles flous. La structure de référence de la relation est représentée en bleu. Le support de μ_{obj} est représenté en vert orange et le noyau de μ_{obj} en vert clair.

TAB. 4.3 – Les valeurs de satisfaction moyenne et minimale pour chacun des chemins. Les valeurs en gras dans le tableau indiquent les chemins retenus.

Chemin			1 - Moyenne	Minimum
LVI « Au-dessus »	THI « En arrière »	CDI « À droite de » PUI	0,06	0,89
LVI « Au-dessus »	THI « Au-dessous »	CDI « À droite de » PUI	0,17	0,64
LVI « À droite de »	CDI « À droite de »	PUI	0,07	0,89
LVI « À droite de »	CDI « En-avant »	THI « À droite de » PUI	0,05	0,92
LVI « À droite de »	CDI « Au-dessus »	THI « À droite de » PUI	0,10	0,82
LVI « Au-dessus »	THI « À droite de »	PUI	0,06	0,92

La figure 4.6 et le tableau 4.1 présentent des mesures du critère de satisfaction obtenues pour chaque arc du graphe. Nous cherchons dans cette expérience un chemin entre le ventricule latéral et le putamen, certains arcs sont donc inutiles (les arcs qui reviennent vers le ventricule ou les arcs issus du putamen) et ne sont pas présents. Le tableau 4.3 présente les scores obtenus pour chacun des chemins selon le critère de satisfaction. Avec ce dernier, les deux méthodes proposées de sélection du chemin, le meilleur chemin en moyenne ou le chemin avec le « plus grand flot minimal », sélectionnent le même meilleur chemin qui est :

TAB. 4.4 – Les valeurs de ressemblance moyenne et minimale pour chacun des chemins. Les valeurs en gras dans le tableau indiquent les chemins retenus.

Chemin	1 - Moyenne	Minimum
LVI « Au-dessus » THl « En arrière » CDI « À droite de » PUI	0,57	0,40
LVI « Au-dessus » THl « Au-dessous » CDI « À droite de » PUI	0,63	0,20
LVI « À droite de » CDI « À droite de » PUI	0,62	0,32
LVI « À droite de » CDI « En-avant » THl « À droite de » PUI	0,51	0,32
LVI « À droite de » CDI « Au-dessus » THl « À droite de » PUI	0,62	0,32
LVI « Au-dessus » THl « À droite de » PUI	0,56	0,42

LVI « À droite de » CDI « En-avant » THl « À droite de » PUI.

Si le meilleur chemin est sélectionné en utilisant l'arc de capacité minimale, alors un autre chemin possède le même score que le premier chemin :

LVI « Au-dessus » THl « À droite de » PUI.

Ce chemin est moins intuitif que le précédent, car il implique moins de structures. En pratique, si deux chemins possèdent le même score, alors le chemin le plus long en termes de nœuds visités, qui sera donc le plus informatif, sera préféré.

La figure 4.6 (à droite) et le tableau 4.2 présentent les valeurs obtenues en utilisant le critère de ressemblance plutôt que le critère de satisfaction. Le tableau 4.4 présente les scores obtenus avec ce critère. Dans ce cas, le meilleur chemin obtenu au sens du meilleur chemin moyen est le même que le chemin obtenu avec le critère de satisfaction :

LVI « À droite de » CDI « En-avant » THl « À droite de » PUI.

En revanche, en utilisant le critère de l'arc de capacité minimale, la valeur de ressemblance portée par l'arc entre le ventricule et le noyau caudé est rédhibitoire, et le meilleur chemin est :

LVI « Au-dessus » THl « À droite de » PUI.

qui avait déjà une valeur identique en utilisant cette optimisation avec le critère de satisfaction.

Les deux critères évaluent les arcs de manières différentes et l'effet de la prise en compte de la précision par le critère de ressemblance est très visible car toutes les relations visant le noyau caudé, qui est la structure la plus petite en volume, ont les valeurs de ressemblance les plus faibles. À un arc près, les arcs sont d'ailleurs ordonnés par ordre de taille des structures cibles (hormis le ventricule qui n'est visé par aucune relation, le thalamus est le plus important, suivi du putamen et enfin du noyau caudé). La relation entre le ventricule et le noyau caudé a une valeur particulièrement faible par rapport à la robustesse de la relation, mais c'est entre ces deux structures que le rapport de taille est le plus important. Ces résultats montrent que le critère de ressemblance accorde une place trop importante à la taille des structures, et le critère de satisfiabilité sera alors préféré.

Néanmoins, les deux critères donnent des résultats relativement similaires. Ce chemin est le chemin qui avait été défini de manière empirique par Colliot *et al.* (2006), ce qui montre le potentiel de l'approche qui a permis de retrouver automatiquement un chemin qui avait été déterminé de manière ad-hoc.

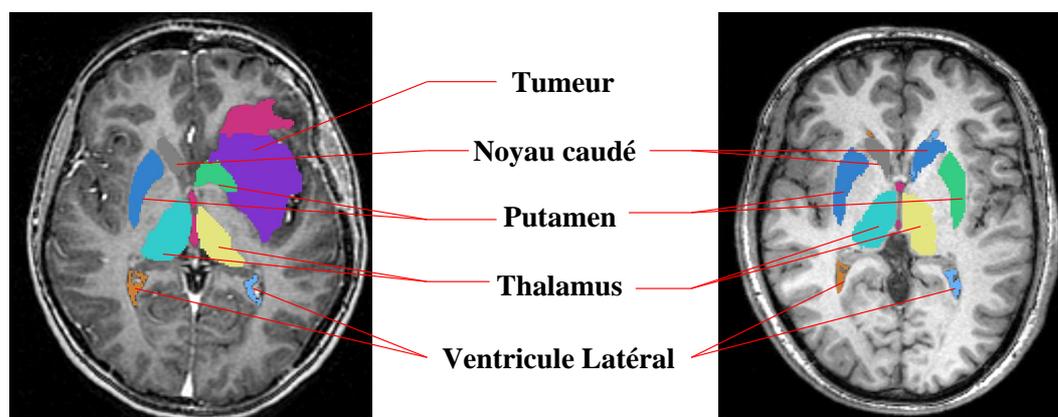


FIG. 4.7 – Deux coupes en vue axiale d’images IRM du cerveau. L’image de gauche présente une pathologie proche du ventricule latéral et des noyaux centraux. L’image de droite est un cas sain. Dans le cas pathologique, les structures ont été déplacées à cause de la tumeur. Le thalamus est écrasé, le putamen est déplacé et déformé. Le noyau caudé a également été déplacé et n’apparaît pas sur cette coupe, alors que le noyau caudé présent dans l’autre hémisphère apparaît.

4.2 Raisonnement dans le cas pathologique

L’approche que nous avons présentée dans la partie 4.1.2 n’est pas directement applicable dans le cas de la présence d’une tumeur, et nécessite une adaptation pour prendre en compte cette situation. En particulier, la présence d’une tumeur peut provoquer une importante altération de l’apparence et des caractéristiques morphométriques d’une structure. La stabilité des relations spatiales permet de prendre en compte la variabilité anatomique des structures cérébrales, mais des modifications plus profondes peuvent apparaître dans les cas pathologiques. La figure 4.7 présente un exemple de cas pathologique dans une image IRM et de l’impact de la tumeur sur les structures proches. Dans cet exemple, toutes les structures marquées ont été déplacées et éventuellement déformées comme le thalamus qui apparaît comprimé. Le putamen a également subi une grande déformation.

Nous proposons une modification de la méthode initiale qui conserve le modèle utilisé à l’identique, mais qui intègre la gestion des pathologies au niveau des poids qui sont utilisés pour optimiser le chemin de segmentation. De cette façon, il est possible de prendre en compte les modifications causées par la pathologie, mais la structure du graphe ne peut pas être modifiée, même si une structure est détruite. Il est toutefois possible avec cette nouvelle approche d’empêcher l’utilisation d’un arc si le poids prend une valeur nulle. Pour prendre en compte les effets d’un type de pathologie sur le modèle, nous exploitons une notion de degré de stabilité des relations spatiales.

4.2.1 Degré de stabilité des relations spatiales

En présence de pathologie, il a été montré par *Atif et al. (2006a)* que certaines relations spatiales sont plus stables que d’autres. Un raisonnement dépendant des pathologies a été introduit pour adapter un processus générique de raisonnement à un cas spécifique, en répondant à la question suivante : étant donné une pathologie, quelles relations spatiales demeurent stables et à quel degré ? À cette fin, un cadre pour l’apprentissage de la stabilité des relations spatiales a été mis en place par *Atif et al. (2007a)* avec une base d’images IRM composées de cas sains et de cas pathologiques manuellement segmentées représentant différentes classes de tumeurs.

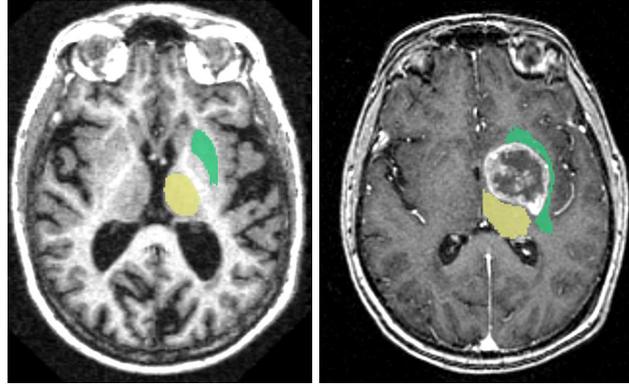


FIG. 4.8 – Étude du degré de stabilité pour la relation : thalamus « distance » putamen. L'image de gauche correspond à un cas sain, l'image de droite à un cas pathologique qui a une influence directe sur les structures, en particulier le putamen qui est déplacé et déformé.

Classification de la base d'apprentissage :

Le degré de stabilité est inféré de la comparaison (en utilisant une mesure de ressemblance) entre les relations spatiales apprises pour les cas sains et les relations apprises pour les cas pathologiques. L'apprentissage est effectué selon le protocole présenté dans la partie 3.5, mais l'apprentissage est effectué de manière distincte pour les cas sains et les cas pathologiques. Pour cela, la base de cas pathologiques est au préalable catégorisée en fonction du type de tumeur et de son impact sur les structures. La structuration de la base est effectuée à l'aide d'une classification de tumeurs cérébrales. Nous avons donc une base de cas :

$$K' = (K^N, K^{P_1}, \dots, K^{P_n}) ,$$

où K^N représente les cas sains et K^{P_i} représente les cas correspondant à une classe de pathologie P_i .

Apprentissage dans le cas sain et dans le cas pathologique :

Nous utilisons une procédure similaire à la procédure présentée dans la partie 3.5 : nous cherchons à apprendre les paramètres des fonctions f , g , et h qui modélisent respectivement les relations spatiales de distance, d'orientation ou d'adjacence respectivement pour un couple de structures (A, B) . Pour une classe de pathologie donnée, correspondant à un sous-ensemble K^{P_i} de la base d'apprentissage, nous allons effectuer pour chaque relation spatiale un apprentissage sur l'ensemble des cas sains K^N et sur le sous-ensemble K^{P_i} .

Nous pouvons considérer une relation particulière pour illustrer comment dériver le degré de stabilité d'une relation. Nous considérons ici la relation « distance » entre le thalamus et le putamen. La figure 4.8 présente ces deux structures dans un cas sain et un cas pathologique.

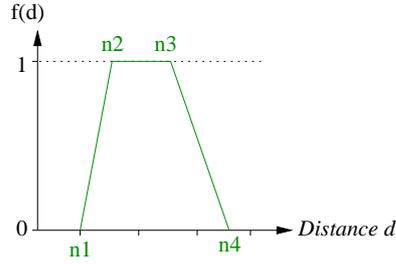
Cette relation est représentée ainsi :

$$\forall x \in \mathcal{S}, \mu_p(x) = f(d_A(x)) ,$$

où A représente le thalamus dans ce cas précis et d_A une carte de distance au thalamus définie ainsi :

$$d_A(x) = \inf_{y \in A} d(x, y) .$$

La fonction f est un intervalle flou de cette forme :



L'apprentissage consiste à apprendre les valeurs des paramètres n_1, n_2, n_3 et n_4 .

Dans le cas sain, ces paramètres sont appris sur tous les cas de l'ensemble K^N . Pour chaque cas $c^N \in K^N$, nous déterminons les valeurs suivantes :

$$\min = \min_{c^N} \min_{x \in B_{c^N}} d_{A_{c^N}}(x) ,$$

$$\max = \max_{c^N} \max_{x \in B_{c^N}} d_{A_{c^N}}(x) ,$$

où A_c représente le thalamus du cas $c \in K^N$, $d_{A_{c^N}}$ la carte de distance à A_c et B_{c^N} le putamen du cas $c \in K^N$ dans cet exemple. Ces valeurs représentent les degrés minimum et maximum de satisfaction de la relation de distance du thalamus sur tous les points du putamen.

Nous pouvons calculer la moyenne (resp. \hat{min}^N, \hat{max}^N) et l'écart-type (resp. $\sigma_{min}^N, \sigma_{max}^N$) des valeurs min et max calculées et ainsi dériver l'intervalle flou suivant :

- n1 : $\hat{min}^N - \sigma_{min}^N$
- n2 : \hat{min}^N
- n3 : \hat{max}^N
- n4 : $\hat{max}^N + \sigma_{max}^N$

Cet intervalle est défini de manière large afin de pouvoir prendre en compte tous les cas de la base d'apprentissage.

Nous considérons la classe de tumeur illustrée dans la figure 4.8, et correspondant à l'ensemble K^{P_i} . Nous effectuons une procédure d'apprentissage similaire avec cet ensemble de données. Nous obtenons ainsi les paramètres correspondant aux cas pathologiques.

Les intervalles flous de notre exemple sont illustrés par la figure 4.9. Nous avons obtenu des valeurs similaires pour le minimum de distance, et les paramètres n_1 et n_2 seront les mêmes dans le cas sain et dans le cas pathologique. En revanche, la moyenne des maximum dans le cas sain est de 31,63 et son écart-type de 4,46. Dans le cas pathologique, la moyenne est de 38.

Degré de stabilité :

La stabilité d'une relation spatiale, pour un cas de pathologie donné, est estimée en comparant les ensembles flous représentant une même relation mais avec les paramètres appris dans le cas sain d'une part, et les paramètres appris dans le cas pathologique d'autre part.

Si nous considérons dans notre exemple une image provenant de la base de cas sains $c \in K^N$, nous pouvons représenter d'une part $\mu_p^N(O_c)$ la représentation de la relation « proche de » avec les paramètres appris sur l'ensemble K^N . D'autre part nous pouvons représenter $\mu_p^{P_i}(O_c)$ la représentation de la relation « proche de » avec les paramètres appris dans sur l'ensemble de cas pathologiques K^{P_i} .

Nous pouvons à présent en déduire le degré de stabilité de la relation en comparant les deux ensembles flous ainsi obtenus. La comparaison est effectuée en utilisant une M-mesure de ressemblance (Bouchon-Meunier *et al.* (1996)), déjà utilisée dans l'approche initiale, qui permet de

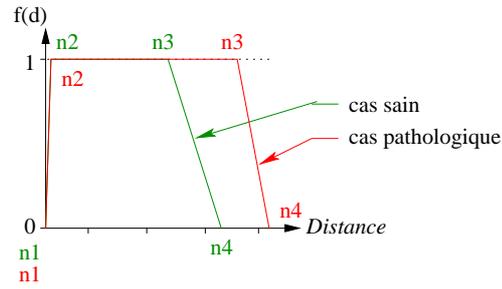


FIG. 4.9 – Intervalles flous dans le cas sain et dans le cas pathologique. Les paramètres de l'intervalle flou pour le cas sain sont les suivants : $n_1 = 0$, $n_2 = 1$, $n_3 = 32$, $n_4 = 36$. Les paramètres de l'intervalle flou dans le cas pathologique sont les suivants : $n_1 = 0$, $n_2 = 1$, $n_3 = 38$, $n_4 = 41$. Ce type de tumeur repousse le putamen, et donc la fonction est plus large.

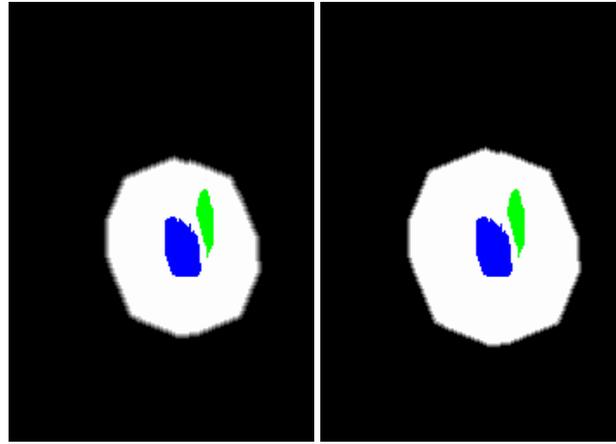


FIG. 4.10 – Les deux paysages flous représentant la relation de distance entre le thalamus (en bleu) et le putamen (en vert). À gauche, les paramètres de la fonction f ont été appris dans le cas sain. À droite, les paramètres ont été appris pour une classe de pathologie illustrée dans la figure 4.8. Le paysage flou appris dans le cas pathologique est moins précis que dans le cas sain, reflétant que le type de tumeur considéré déplace les structures considérées. La ressemblance entre ces deux paysages flous est de 0,72.

calculer la cardinalité de l'intersection de deux ensembles flous, normalisée par la cardinalité de leur réunion :

$$\mathcal{R}(\mu, \mu') = \frac{\sum_{d \in \mathcal{D}} \min(\mu(d), \mu'(d))}{\sum_{d \in \mathcal{D}} \max(\mu(d), \mu'(d))} ,$$

où \mathcal{D} représente le domaine de définition des ensembles flous, par exemple l'espace des distances dans l'exemple décrit plus haut.

Nous obtenons ainsi, pour chaque relation (A, R, B) où A et B sont deux structures et R une relation spatiale, un degré de stabilité pour chaque classe de pathologie. La valeur obtenue pour notre exemple est de 0,72.

4.2.2 Adaptation de l'approche aux cas pathologiques

Nous avons estimé un degré de stabilité, qui est valable pour une classe de pathologie. Il est donc nécessaire de connaître au préalable pour quel type de pathologie l'adaptation doit être

effectuée. Pour cela, nous pouvons utiliser la classification de tumeurs cérébrales proposée par [Atif *et al.* \(2007a\)](#) et [Khotanlou \(2008\)](#). Une fois le type de pathologie connu et les degrés de stabilité correspondant estimés, il est nécessaire de les intégrer dans notre approche initiale. Il y a différentes manières d'intégrer cette information, nous allons en détailler deux : un élagage du graphe par le degré de stabilité, puis la pondération des poids par le degré de stabilité.

Élagage du graphe :

Le graphe original peut être filtré de telle sorte que les relations spatiales présentant un trop faible degré de stabilité soient supprimées. Ensuite, l'approche développée pour les cas sains peut être directement appliquée sur le graphe filtré. Cette approche est plutôt sévère et ne permet pas d'être souple, ce qui est primordial afin de pouvoir effectuer des raisonnements. De plus, il est nécessaire de fixer un seuil pour le filtrage du graphe. La figure 4.11 montre un exemple de filtrage de graphe, avec un seuil déterminé de manière empirique à une valeur de $T = 0,8$. Le résultat ne laisse que deux chemins possibles. Le filtrage a permis d'éliminer les arcs dont le degré de stabilité est faible, mais ne modifie pas les poids pour la suite de la méthode.

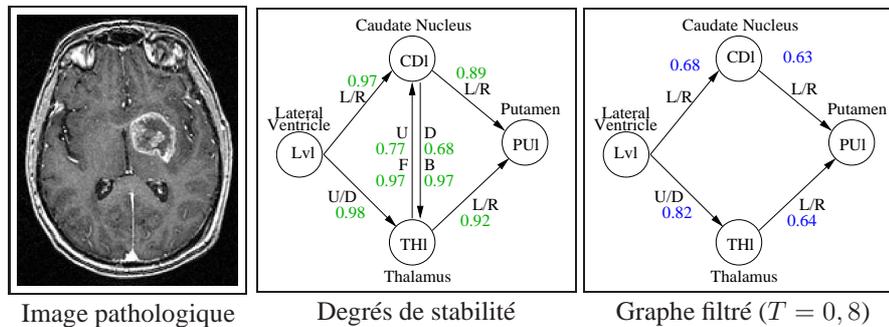


FIG. 4.11 – Élagage du graphe en fonction du degré de stabilité. Le graphe au centre montre les degrés de stabilité obtenus pour le cas de pathologie présenté sur la gauche. Le graphe de droite montre le résultat du filtrage si le seuil de stabilité est $T = 0,8$. Les valeurs de satisfiabilité des arcs restants sont notés en bleu sur ce graphe.

Pondération par le degré de stabilité :

Une autre manière de prendre en compte le degré de stabilité d'une relation spatiale, plus souple que la première approche, est de prendre en compte le degré de stabilité comme un attribut de l'arc qui porte la relation spatiale. De cette manière, le degré de stabilité peut être intégré dans le calcul du coût de l'approche initiale. De plus, cette manière d'intégrer l'information pathologique est relativement simple, si l'on considère le type de pathologie connu.

L'intégration du degré de stabilité doit être effectuée de telle manière que les chemins qui comportent des structures pathologiques ou altérées par une pathologie soient pénalisés. Pour cela, nous pouvons utiliser une t-norme (un produit par exemple) et l'intégrer directement :

$$e_w = \top(d_e, f(\mu_{Rel}, \mu_{Obj})) ,$$

où e_w représente le poids attribué à l'arc, d_e le degré de stabilité porté par cet arc et f la mesure calculée par l'approche initiale, une satisfiabilité ou une ressemblance entre la relation portée par l'arc et la structure cible. La figure 4.12.b présente les degrés de stabilité (en bleu) qui ont été appris pour chaque arc pour la classe de tumeur correspondant au cas pathologique illustré par la figure 4.12.a et les mesures de satisfaction (en rouge) qui ont été pondérées. Dans ce cas, le meilleur chemin devient le suivant :

Ventricule « Au-dessus » Thalamus « À droite de » Putamen.

La figure 4.12.c présente une segmentation du putamen qui a été effectuée en suivant cette séquence de segmentation.

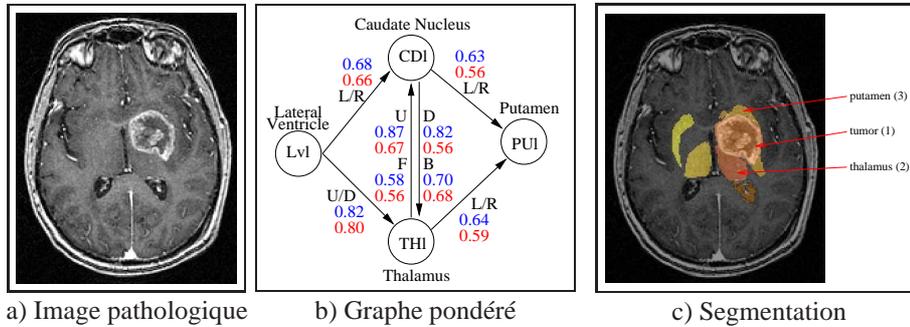


FIG. 4.12 – (a) Vue axiale d’une image IRM avec une tumeur proche du ventricule latéral et des noyaux centraux. (b) Degrés de stabilité appris avec une classe de tumeur similaire (en bleu). Les mesures de satisfaction pondérées sont en rouge. Sélection du meilleur chemin avec le critère du meilleur chemin moyen. Le meilleur chemin est dans ce cas : ventricule « Au-dessus » thalamus « À droite de » putamen. (c) Segmentation du putamen. La tumeur est extraite d’abord. Ensuite, le thalamus et finalement le putamen.

Intégration dans l’apprentissage des relations :

Nous avons vu comment réaliser l’apprentissage des relations spatiales dans le chapitre 3, dont le principe a été rappelé dans la partie précédente. Les représentations des relations spatiales sont plutôt souples dans la manière dont elles sont construites, et cette construction peut être directement adaptée en fonction du degré de stabilité. L’apprentissage proposé dans le chapitre 3 est effectué sur une base d’images saines et d’images pathologiques. Le principe est d’effectuer une extension de l’intervalle flou permettant de prendre en compte les cas pathologiques. Moins la relation sera stable et plus la relation est étendue donc floue. Si on considère un lien entre une faible ressemblance et un plus haut niveau de flou, alors la pertinence des chemins sera diminuée.

Si nous reprenons le cas de tumeur présentée dans la figure 4.12, la relation d’orientation présente entre le noyau caudé et le putamen « À droite de » peut être étendue pour gérer ce cas pathologique, en utilisant des valeurs plus larges pour les angles α_1 et α_2 utilisés pour construire la relation. Ce type d’apprentissage a été illustré dans le chapitre précédent, dans la partie 3.5.

4.3 Optimisation globale de la pertinence d’un chemin

Un chemin peut être qualifié d’une manière globale, par exemple en comptant le nombre de changements de direction, c’est-à-dire à chaque fois que deux relations d’orientation consécutives ne sont pas similaires. D’une manière plus générale, nous sommes intéressés par qualifier non seulement les différentes relations qui composent un chemin, mais aussi la fusion de toute l’information spatiale. L’approche précédente propose une optimisation locale où chaque arc est évalué de manière séparée et il n’est donc pas possible d’effectuer ce type d’évaluation. Nous proposons à présent une méthode permettant d’évaluer la pertinence d’un chemin non plus en évaluant chaque arc de manière séparée, mais en évaluant une représentation du chemin sous forme d’un unique ensemble flou. Nous allons tout d’abord voir sous quelle forme les chemins seront représentés afin de pouvoir être évalués ensuite.

4.3.1 Fusion des connaissances spatiales

Afin de pouvoir effectuer une estimation globale d'un chemin, nous allons déterminer comment représenter un chemin. Nous utilisons comme modèle un graphe dont chaque arc comporte des relations spatiales, et nous avons vu de quelle manière ces relations spatiales étaient représentées dans l'espace de l'image. Nous proposons de représenter un chemin en fusionnant l'information spatiale composant un chemin, c'est-à-dire en fusionnant les représentations des relations spatiales portées par chaque arc composant ce chemin. Chaque ensemble flou porté par un arc étant calculé dans l'espace de l'image, la fusion de ces ensembles flous est aisée et naturelle. Comme précédemment, les représentations des relations spatiales seront calculées en utilisant le formalisme flou. Nous allons donc combiner une information a priori et l'information spatiale contenue par un chemin pour représenter ce chemin.

Nous devons tout d'abord calculer les représentations des relations spatiales portées par les arcs du chemin étudié, en suivant le formalisme flou décrit dans le chapitre 3 ainsi que dans la partie précédente. Nous avons le choix entre une fusion conjonctive ou une fusion disjonctive. La figure 4.13 permet une comparaison entre une fusion conjonctive (un minimum) et une fonction disjonctive (un maximum) pour représenter le même chemin. Dans cet exemple, le chemin représenté est le suivant : LVL « à gauche » CDI « devant » THI « à gauche ». Pour chaque type de fusion, deux cas sont étudiés : dans le premier cas, uniquement des fonctions d'orientation sont utilisées et aucun apprentissage n'est effectué sur ces fonctions. Dans le deuxième cas, un apprentissage est effectué, tel qu'il est décrit dans le chapitre 3. Dans ce cas, nous pouvons ajouter sur chaque arc une relation de distance, qui sera fusionnée avec la relation d'orientation avec un minimum.

La fusion disjonctive nous permet de conserver toutes l'information apportée par les relations spatiales du chemin. Cependant, la zone représentant le chemin va vite être grande par rapport aux structures du chemin. L'information n'est donc pas pertinente. Avec un apprentissage et des relations de distance, la représentation du chemin est plus limitée, mais reste grande par rapport aux structures. Nous utilisons plutôt une mesure conjonctive, qui permet de restreindre l'information. Mais la conjonction fait disparaître beaucoup d'information. Dans le cas avec un apprentissage et des relations de distance, il reste peu d'information sur le chemin, et certains arcs n'apportent plus d'information, comme entre le ventricule et le noyau caudé dans la représentation en bas à droite de la figure. Sans apprentissage, nous avons encore une information sur l'ensemble du chemin. Nous utiliserons ce dernier cas dans nos expériences. Parmi les t-normes et t-conormes, nous avons choisi d'utiliser le minimum et le maximum dans nos expériences.

Les conjonctions de relations spatiales représentent plus la localisation de la structure visée par les arcs d'un chemin, que le chemin lui-même entre ces deux structures, ce qui explique que plus ces localisations sont précises, et moins la représentation du chemin semble correcte, car les interstices entre les structures sont moins représentés que dans le cas sans apprentissage, où les localisations sont moins précises.

La représentation du chemin est donc générée en fusionnant tous les ensembles flous obtenus en utilisant un opérateur de fusion conjonctif (une t-norme), ainsi :

$$\mu_p = \top [\mu_{Rel_i^p}, i = 1 \dots N^p] \quad (4.6)$$

où \top est une t-norme et p un chemin composé de N^p relations. Dans nos expériences, nous utilisons une norme minimum. Le processus permettant la génération de la représentation d'un chemin est illustré dans la figure 4.14.

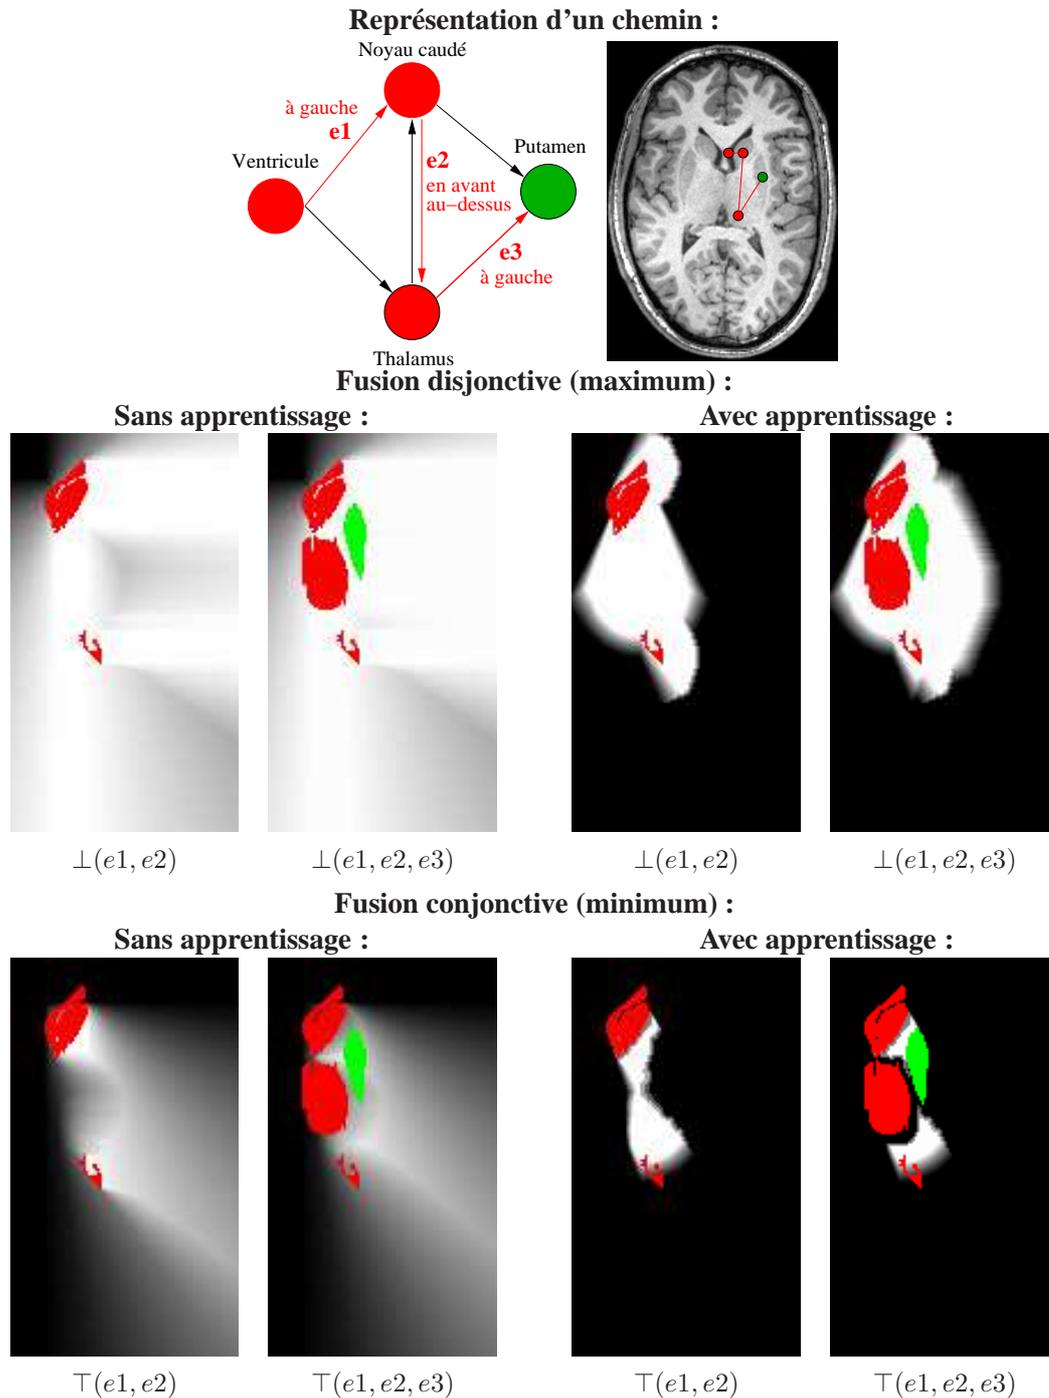


FIG. 4.13 – Comparaison entre une fusion disjonctive (au centre) ou conjonctive (en bas) pour calculer la représentation d'un chemin. La fusion disjonctive conserve toute l'information, et dans le cas de relations non bornées telles que les relations d'orientation, une large partie de l'espace est intégrée dans la représentation du chemin. Avec un apprentissage et l'ajout de relations de distances fusionnées avec les relations d'orientation, moins d'information est prise en compte, mais toujours beaucoup relativement à la taille des structures et du cerveau. En revanche, la fusion conjonctive conserve beaucoup moins d'information. La conjonction des relations spatiales visant une structure d'un chemin a plutôt représenté la localisation de cette structure, et non pas le chemin entre deux structures. Plus ces localisations sont précises, et moins la représentation d'un chemin apparaît correcte, c'est-à-dire moins les espaces entre les structures sont représentés dans la représentation du chemin. Il est important que la structure recherchée soit comprise dans la représentation, et que celle-ci ne soit pas trop étendue, ce qui est le cas de la fusion conjonctive sans apprentissage dans cet exemple.

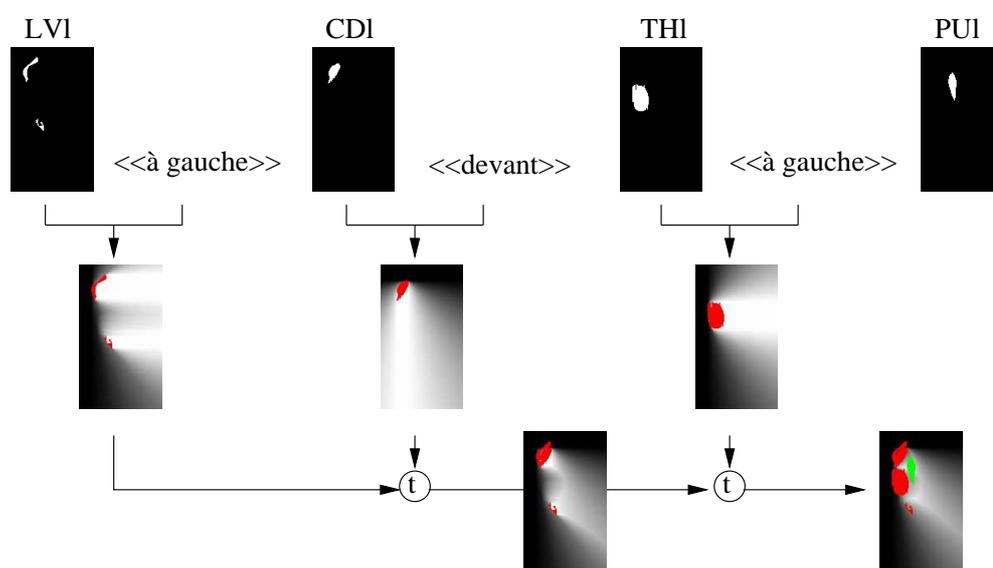


FIG. 4.14 – Génération d’une représentation pour le chemin suivant : ventricule (LVI) « À droite de » noyau caudé (CDI) « En-avant » thalamus (THI) « À droite de » putamen (PUI). Une coupe des représentations de chaque structure est présentée dans la ligne supérieure. Pour chaque relation portée par un arc d’un chemin, nous la représentons dans l’espace de l’image, en utilisant la représentation de la structure de référence de chaque relation. Ces représentations sont présentées dans la ligne du milieu, avec les structures de référence en rouge. Les représentations de chaque relation sont ensuite fusionnées en utilisant une t-norme (ici le minimum). La ligne du bas présente à gauche la fusion des deux premières relations (avec les structures de référence des deux relations en rouge), puis après fusion de la troisième relation, la représentation du chemin à droite, avec la structure cible du chemin (le putamen) en vert.

4.3.2 Évaluation du chemin par mesure de son entropie

À l'aide du processus de fusion qui vient d'être décrit, nous obtenons donc un ensemble flou décrivant chaque chemin que nous étudions. La taille du graphe étant petite, nous pouvons effectuer une exploration exhaustive des chemins du graphe. Si le graphe considéré était plus important, alors il serait nécessaire de prendre en compte la complexité de cette tâche.

Nous souhaitons sélectionner le chemin qui répond le mieux à nos attentes, c'est-à-dire qui répondra le mieux aux contraintes du processus de segmentation des structures. Pour cela, nous proposons de sélectionner le chemin qui est le plus précis possible, c'est-à-dire le chemin qui laisse le moins de doute possible sur l'emplacement de chaque structure à segmenter le long du chemin. Pour cela, nous allons donc sélectionner le chemin le « moins flou ». Comme mesure de flou, toujours dans cette optique, nous utilisons une mesure d'entropie floue [Luca et Termini \(1972\)](#) définie ainsi :

$$H(\mu_p) = -K \left(\sum_{x_i \in \mathcal{S}} \mu_p(x_i) \log \mu_p(x_i) + \sum_{x_i \in \mathcal{S}} (1 - \mu_p(x_i)) \log(1 - \mu_p(x_i)) \right), \quad (4.7)$$

où μ_p est l'ensemble flou correspondant à la fusion de toutes les relations spatiales contenue dans le chemin p et K est une constante de normalisation.

Le meilleur chemin \hat{p} sera donc le chemin le « moins flou », donc avec le minimum d'entropie floue :

$$\hat{p} = \arg \min_{p \in \mathcal{P}} (H(\mu_p)). \quad (4.8)$$

Il faut remarquer que cette mesure est utilisable lorsque, comme dans notre cas, les relations sont plus floues lorsqu'elles sont moins précises. Il serait inutile de mesurer ce critère sur des régions qui ne sont pas floues, qui donneraient une valeur d'entropie nulle même si les régions sont très larges et n'apportent pas d'aide au processus de segmentation.

4.3.3 Expériences

Les mesures de l'entropie floue pour chacun des chemins sont présentées dans le tableau [4.5](#). Le chemin qui possède l'entropie floue la plus basse est le suivant :

LVI « down of » THI « up of » CDI « left of » PUI

Cette représentation est illustrée par la figure [4.15](#). Ce chemin contient plusieurs changements de direction, ce qui explique que la conjonction des représentations des relations spatiales soit très concentrée sur une petite zone uniquement, et donc présente une entropie faible. D'une manière plus générale, l'entropie floue calculée sera dépendante des changements de direction du chemin, plus que de la précision des relations elles-mêmes.

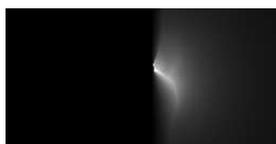


FIG. 4.15 – Une coupe d'une représentation 3D du chemin LVI « down of » THI « up of » CDI « left of » PUI après fusion des connaissances spatiales contenues dans le chemin.

TAB. 4.5 – L'entropie floue obtenue pour chacune des représentations des chemins entre le ventricule et le putamen dans notre graphe. Les structures sont les suivantes : ventricule latéral (LVI), thalamus (THI), noyau caudé (CDI), putamen (PUI).

Chemin :				Entropie floue :
LVI « Au-dessus »	THI en dessous	CDI « À droite de »	PUI	0,08
LVI « Au-dessus »	THI en dessous	CDI « À droite de »	PUI	0,17
LVI « À droite de »	CDI « À droite de »		PUI	0,26
LVI « À droite de »	CDI en avant	THI « À droite de »	PUI	0,16
LVI « À droite de »	CDI « Au-dessus »	THI « À droite de »	PUI	0,16
LVI « Au-dessus »	THI « À droite de »		PUI	0,16

4.3.4 Adaptation aux cas pathologiques

Cette approche reposant sur les représentations des relations spatiales, son adaptation aux cas pathologiques doit porter sur les paramètres de ces relations : l'influence d'une relation est diminuée en étendant sa représentation spatiale, par une dilatation floue de l'ensemble correspondant par exemple. L'extension de sa représentation spatiale correspond à rendre la relation spatiale plus permissive, et donc augmenter le degré de flou et l'entropie du chemin. Les chemins qui possèdent des structures altérées seront ainsi pénalisés.

4.3.5 Conclusion sur l'approche globale

Cette approche permet de prendre en compte un critère global sur le chemin, sa précision selon le critère d'entropie floue. Toutefois, la représentation globale n'est pas satisfaisante. Les représentations utilisant une disjonction sont trop larges et les représentations des chemins se recouvrent trop pour être discriminantes. D'un autre côté, les fusions avec un opérateur de conjonction réduisent suffisamment l'information, mais des parties du chemin ne sont pas représentées et les chemins sont dépendants des changements de direction.

4.4 Conclusion

Nous avons montré dans cette première approche que l'ordre de segmentation des structures d'un processus de segmentation séquentiel peut être déduit de manière automatique, et les résultats, limités à un petit graphe, montrent que le chemin déduit automatiquement est le même que le chemin qui avait été construit de manière ad-hoc. L'extension proposée pour les cas pathologiques nous a permis, en prenant en compte la notion de degré de stabilité d'une relation spatiale, d'adapter le processus à un type de pathologie donné pour déterminer un meilleur chemin dans ce cas.

Cette approche comporte certaines hypothèses. La pertinence des relations est estimée, mais la difficulté intrinsèque de segmentation de chaque structure n'est pas prise en compte. Les critères que nous utilisons ne permettent pas non plus de considérer la précision intrinsèque des relations. Par exemple, une relation d'adjacence sera naturellement plus précise qu'une relation d'orientation (en termes de taille de support). Même si les critères sont normalisés par la taille du support, le rapport à la taille de l'objet cible n'est pas identique.

L'approche utilisant des représentations des chemins serait prometteuse si une bonne représentation d'un chemin pouvait être déduite du chemin. En effet, cette représentation, liée par exemple à une information visuelle telle que celle étudiée dans le chapitre 2, peut permettre de détecter des

événements d'une manière plus globale qu'en raisonnant avec une relation à chaque fois. Nous verrons dans le chapitre suivant comment faire une estimation globale des chemins, mais a posteriori.

L'utilisation d'une connaissance a priori permet de réaliser une optimisation globale sur le chemin complet avant de segmenter. Cependant, l'optimisation est ici locale au sens où la pertinence de chaque arc est évaluée de manière indépendante des autres arcs. Une autre critique est que cette approche n'utilise pas d'information provenant de l'image à segmenter, mais est effectuée uniquement à partir de la connaissance a priori, à part l'adaptation aux cas pathologiques qui prend en compte le type de pathologie présente sur l'image. Une variation de cette approche serait d'effectuer l'optimisation globalement de la même manière mais de réviser le modèle à la suite de chaque segmentation de structure pour prendre en compte cette image. Nous aurions ainsi une instanciation progressive du modèle, mais dans ce cas, même si une optimisation du chemin complet est effectuée, elle est utilisée comme une manière de choisir la prochaine structure à segmenter uniquement. L'approche présentée dans la partie suivante fonctionne de cette manière.

L'objectif du prochain chapitre est de combler l'absence d'information provenant de l'image à segmenter. Nous avons présenté au chapitre 2 comment les modèles du système visuel pouvaient apporter de l'information extraite directement d'une image, via les mécanismes pré-attentionnels, et en particulier les cartes de saillance. Nous allons à présent voir comment intégrer cette information visuelle dans un processus de segmentation séquentielle.
