

Sujet de thèse :

Squelettisation d'objets tubulaires par accumulation discrète de normales

Encadrement

- Directeur : Benoît NAEGEL - Équipe IMAGEs - ICube - b.naegel@unistra.fr
- Encadrement : Adrien KRÄHENBÜHL - Équipe IMAGEs - ICube - krahenbuhl@unistra.fr

Financement

Cette thèse est à pourvoir à l'automne 2024.
Durée du financement : 3 ans.

Profil du candidat

Master en Informatique, Imagerie ou Mathématiques appliquées.
Expérience en traitement d'images et apprentissage profond.
Programmation Python, C++.

Candidature

Le candidat devra adresser un dossier comportant impérativement les éléments suivants :

- résultats et classements pour les Master 1 et Master 2 ;
- résultats complets des diplômes obtenus avant le Master ;
- curriculum vitæ ;
- lettre de motivation.

Sujet

La détection de la ligne centrale (ou squelette) d'objets tubulaires est un enjeu important pour nombre de projets aux thématiques variées, de l'imagerie médicale à la modélisation géométrique pour l'animation en passant par l'agronomie forestière, le contrôle qualité industriel, la simulation d'écoulement de fluides. Pour tous ces domaines, la problématique principale réside dans la gestion des zones d'embranchements, qu'il s'agisse de les détecter, de les segmenter ou de les modéliser. Le défi est encore plus grand lorsque l'objet est fin ou que les données sous-jacentes sont incomplètes, bruitées ou non homogènes.

Des travaux précédents ont permis de développer une méthode de détection de ligne centrale [1] à partir d'un nuage de points et de l'estimation des normales à ces points. Les principaux avantages de cette approche résident dans sa robustesse aux données incomplètes et dans sa généralité, permettant théoriquement de s'appliquer à n'importe quel type d'objets pour lesquels on peut estimer un champ de normales. L'idée de base consiste en effet à plonger l'objet continu dans un espace discret pour y calculer une carte de probabilités à partir d'un principe d'accumulation des normales à la surface. Cette méthode a été notamment utilisée pour calculer le squelette de réseaux vasculaires au sein d'images d'angiographie cérébrale IRM 3D (voir Figure 1).

Cependant, quand elle est utilisée sur des données discrètes telles qu'une image, cette méthode possède deux inconvénients. D'une part, elle nécessite une image binaire pour l'estimation des normales. Cette étape de binarisation peut s'appuyer par exemple sur une méthode de filtrage et/ou de segmentation et peut être complexe à mettre en œuvre. D'autre part, la précision du squelette obtenu est liée à la




FIGURE 1 – Détection de la ligne centrale d’une angiographie cérébrale IRM 3D obtenue par une approche basée sur l’accumulation de normales.




FIGURE 2 – Segmentation d’un réseau vasculaire cérébral en imagerie IRM [11]. À gauche : résultat d’une segmentation automatique par réseaux de neurones convolutifs. À droite : vérité terrain. La segmentation automatique souffre encore de certains défauts (déconnexions, parties manquantes, etc.).

résolution de l’image : dans le cas d’objets fins dont l’épaisseur se rapproche de la limite de résolution (petits vaisseaux par exemple), le squelette obtenu peut souffrir de certains défauts.

Le premier objectif de cette thèse est de développer une méthode de détection de ligne centrale d’objets tubulaires qui pallie les deux problèmes précédents. Pour étendre la méthode au calcul de squelette dans les images à niveaux de gris, une méthode d’estimation des normales dédiée à ce type de données pourra être développée. Afin de calculer un squelette ayant une précision plus grande que la résolution de l’image, des méthodes de super-résolution, s’appuyant notamment sur de l’apprentissage profond, pourront être considérées [2]. Ces recherches pourront s’appuyer aussi sur les travaux de Hespén *et al.* [3] qui permettent d’obtenir une précision sous-pixelique pour la mesure d’épaisseur des parois de vaisseaux.

Enfin, ces travaux seront intégrés dans une méthodologie de segmentation des réseaux vasculaires en IRM 3D cérébrale développée dans l’équipe. Dans ce contexte, les structures d’intérêt présentent des propriétés morphologiques (taille, forme), spatiales (positions, orientation), et topologiques (variabilité des embranchements), qui rendent particulièrement délicate une annotation fiable des images, et induisent des variations sensiblement plus importantes que pour d’autres structures. Pour de tels objets, les approches d’apprentissage profond souffrent encore d’un manque de robustesse (voir Figure 2). Dans cette perspective, plusieurs travaux récents proposent des méthodes pour intégrer des contraintes de type topologique dans les réseaux de neurones [4, 5, 6, 7, 8] ou encore modéliser des *a priori* de forme ou des contraintes anatomiques [9, 10].

L’objectif final de ces travaux est d’obtenir, à partir d’une image angiographique IRM 3D, une modélisation des vaisseaux à partir du calcul de leur ligne centrale (ou squelette) et des rayons associés. Les approches d’apprentissage profond pourront permettre d’inférer directement ces informations, sans nécessiter de segmentation préalable.

Références

- [1] B. Kerautret, A. Krähenbühl, I. Debled-Rennesson, and J.-O. Lachaud, “On the Implementation of Centerline Extraction Based on Confidence Vote in Accumulation Map,” in *Reproducible Research in Pattern Recognition* (B. Kerautret, M. Colom, and P. Monasse, eds.), Lecture Notes in Computer Science, (Cham), pp. 116–130, Springer International Publishing, 2017.
- [2] W. Yang, X. Zhang, Y. Tian, W. Wang, and J.-H. Xue, “Deep Learning for Single Image Super-Resolution : A Brief Review,” *IEEE Transactions on Multimedia*, vol. 21, pp. 3106–3121, Dec. 2019. arXiv : 1808.03344.
- [3] K. M. van Hespen, J. J. M. Zwanenburg, J. Hendrikse, and H. J. Kuijf, “Subvoxel vessel wall thickness measurements from vessel wall MR images,” in *Medical Imaging 2019 : Image Processing*, vol. 10949, p. 109491Z, International Society for Optics and Photonics, Mar. 2019.
- [4] A. Mosinska, P. Marquez-Neila, M. Kozinski, and P. Fua, “Beyond the Pixel-Wise Loss for Topology-Aware Delineation,” pp. 3136–3145, IEEE, June 2018.
- [5] R. J. Araújo, J. S. Cardoso, and H. P. Oliveira, “A Deep Learning Design for Improving Topology Coherence in Blood Vessel Segmentation,” in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019* (D. Shen, T. Liu, T. M. Peters, L. H. Staib, C. Essert, S. Zhou, P.-T. Yap, and A. Khan, eds.), Lecture Notes in Computer Science, (Cham), pp. 93–101, Springer International Publishing, 2019.
- [6] J. R. Clough, I. Oksuz, N. Byrne, V. A. Zimmer, J. A. Schnabel, and A. P. King, “A Topological Loss Function for Deep-Learning based Image Segmentation using Persistent Homology,” *arXiv :1910.01877*, Oct. 2019.
- [7] X. Hu, L. Fuxin, D. Samaras, and C. Chen, “Topology-Preserving Deep Image Segmentation,” *arXiv :1906.05404*, June 2019.
- [8] R. Brüel-Gabrielsson, B. J. Nelson, A. Dwaraknath, P. Skraba, L. J. Guibas, and G. Carlsson, “A Topology Layer for Machine Learning,” *arXiv :1905.12200*, May 2019.
- [9] M. R. Adrian V. Dalca, John Guttag, “Anatomical Priors in Convolutional Networks for Unsupervised Biomedical Segmentation,”
- [10] A. J. Larrazabal, C. Martinez, and E. Ferrante, “Anatomical Priors for Image Segmentation via Post-processing with Denoising Autoencoders,” in *Medical Image Computing and Computer Assisted Intervention – MICCAI 2019* (D. Shen, T. Liu, T. M. Peters, L. H. Staib, C. Essert, S. Zhou, P.-T. Yap, and A. Khan, eds.), LNCS, (Cham), pp. 585–593, Springer International Publishing, 2019.
- [11] P. Sanches, C. Meyer, V. Vigon, and B. Naegel, “Cerebrovascular network segmentation of MRA images with deep learning,” in *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, p. 768–771, IEEE, 2019.
- [12] O. Oktay, E. Ferrante, K. Kamnitsas, M. Heinrich, W. Bai, J. Caballero, S. A. Cook, A. de Marvao, T. Dawes, D. P. O’Regan, B. Kainz, B. Glocker, and D. Rueckert, “Anatomically Constrained Neural Networks (ACNNs) : Application to Cardiac Image Enhancement and Segmentation,” *IEEE Transactions on Medical Imaging*, vol. 37, pp. 384–395, Feb. 2018.
- [13] U. Wickramasinghe, G. Knott, and P. Fua, “Probabilistic Atlases to Enforce Topological Constraints,” *arXiv :1909.08330*, Sept. 2019.