

Stage Master 2

Segmentation vasculaire par arbre des formes profond

1 Contexte scientifique

La segmentation du réseau vasculaire 3D est un problème très étudié depuis plus de 20 ans [5]. Depuis l'essor de l'apprentissage profond, de telles approches ont été développées et ont montré des performances bien supérieures aux approches classiques [11, 8]. Bien que la qualité globale des segmentations soit généralement bonne, ces approches ne fournissent aucune garantie sur la préservation de la connectivité du réseau vasculaire étudié. Ainsi, il est courant d'observer des vaisseaux déconnectés, ce qui n'est pas acceptable pour de nombreuses applications telles que les simulations de flux sanguin. Récemment, des approches essayant de préserver la connectivité de la segmentation ont été proposées [10, 9, 3]. Néanmoins, ces approches reposent sur des a priori indirects qui ne permettent pas un contrôle direct et précis de la connectivité du résultat.

Les représentations hiérarchiques consistent à représenter une image sous la forme d'un arbre construit selon un critère donné [4]. Trois types d'arbres sont couramment utilisés en se basant sur un critère d'intensité : le max-tree, le min-tree et l'arbre des formes. Un "max-tree" (respectivement "min-tree") peut être construit en seuillant itérativement l'image par des niveaux de gris croissants (respectivement décroissants). Chaque nœud de cet arbre est une composante connexe de l'image résultat pour un seuil donné (voir Figure 1).

L'arbre des formes [6] est une combinaison de max-tree et du min-tree. Contrairement aux deux représentations précédentes, il encode la relation d'inclusion de composantes connexes. En effet, dans cette représentation, un nœud fils (c.-à-d. une composante connexe) est inclus dans son nœud parent, quelle que soit son intensité.

Dans ce contexte, l'objectif de ce stage est de proposer une approche de segmentation vasculaire basée sur l'arbre des formes afin de pouvoir formuler une contrainte directement sur le nombre de composantes connexes du résultat, et ainsi favoriser les segmentations connectées. Ce type de contrainte n'est actuellement pas possible avec l'utilisation des réseaux de neurones convolutionnels classiques, car il repose sur des critères non dérivables.

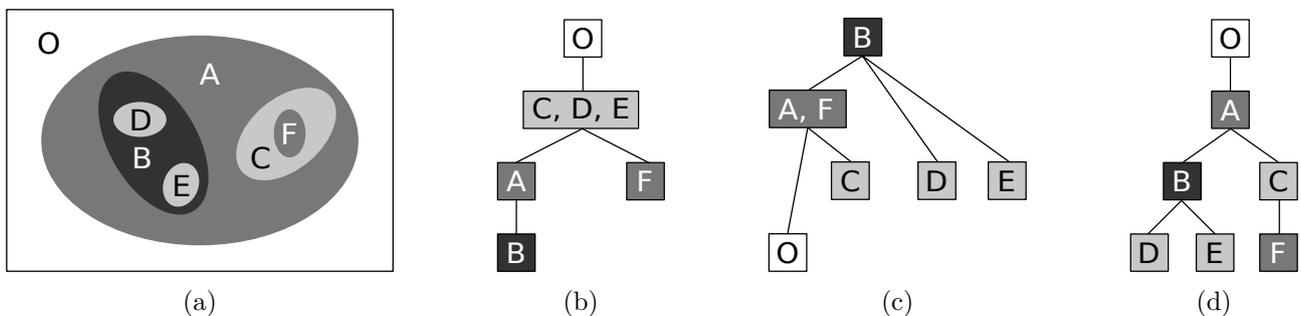


Figure 1: Représentations hiérarchiques. (a) image, (b) min-tree, (c) max-tree, (d) arbre des formes

2 Sujet du stage

Ce stage est découpé en 2 objectifs qui seront traités l'un après l'autre en fonction de l'avancée du/de la stagiaire : l'apprentissage de l'arbre des formes enrichi et la segmentation vasculaire à partir de cet arbre.

Apprentissage de l'arbre des formes enrichi

L'objectif est de créer un arbre des formes à partir d'une image angiographique 3D, enrichi de descripteurs appris par réseau convolutif. Pour cela, nous utiliserons la bibliothèque [Pylene](#), développée au LRE, afin de calculer l'arbre des formes d'une image.

Une fois l'arbre créé, le ou la stagiaire devra entraîner un autoencodeur de type UNet [2] à partir de cette représentation afin d'obtenir un ensemble de descripteurs pour chaque noeud. L'apprentissage de cet autoencoder sera réalisé sur un ensemble de bases de données publiques d'images angiographiques issues de différents organes : cerveau ([Bullitt](#), [BRAVA](#), [OASIS](#)), poumons ([PARSE](#)), foie ([IRCAD](#)).

Nous obtiendrons ainsi un arbre des formes enrichi de descripteurs appris.

Segmentation vasculaire à partir de l'arbre des formes enrichi

L'objectif est de segmenter une image à partir son arbre des formes appris, qui est un graphe (et non plus une image). Ceci se fera par apprentissage profond géométrique (geometric deep learning) [1] et plus particulièrement via un réseau de neurones convolutif géométrique (GCN) [7] supervisé. Le problème de segmentation se formule alors comme un problème de classification binaire de chaque noeud. La segmentation finale sera obtenue par reconstruction d'une image à partir du sous-ensemble de noeuds sélectionnés par le GCN.

3 Profil recherché

Le ou la stagiaire devra avoir de bonnes connaissances en traitement d'images et en apprentissage profond. Il ou elle devra maîtriser le langage Python. Une expérience en imagerie médicale et avec la bibliothèque Pytorch est un plus.

4 Informations sur le stage

- Stage de 6 mois avec date de début entre janvier et avril 2024
- Localisation: [Laboratoire CREATIS](#) à l'INSA Lyon.
- Encadrantes: Odysée Merveille et Élodie Puybareau
- Les candidatures doivent être envoyées à odyssee.merveille@creatis.insa-lyon.fr et elodie.puybareau@lrde.epita.fr et comprendre un **CV détaillé**, les **notes de la dernière formation académique**, et éventuellement une lettre de motivation.

References

- [1] Michael M Bronstein et al. "Geometric deep learning: going beyond euclidean data". *IEEE Signal Processing Magazine* 34.4 (2017), pp. 18–42.
- [2] Özgün Çiçek et al. "3D U-Net: learning dense volumetric segmentation from sparse annotation". *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2016: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II 19*. Springer. 2016, pp. 424–432.

- [3] Sophie Carneiro Esteves, Antoine Vacavant, and Odysée Merveille. “Learning a reconnecting regularization term for blood vessel variational segmentation”. *2021 IEEE EMBS International Conference on Biomedical and Health Informatics (BHI)*. IEEE. 2021, pp. 1–4.
- [4] Ronald Jones. “Connected filtering and segmentation using component trees”. *Computer Vision and Image Understanding* 75.3 (1999), pp. 215–228.
- [5] Sara Moccia et al. “Blood vessel segmentation algorithms—review of methods, datasets and evaluation metrics”. *Computer methods and programs in biomedicine* 158 (2018), pp. 71–91.
- [6] Pascal Monasse and Frederic Guichard. “Fast computation of a contrast-invariant image representation”. *IEEE Transactions on Image Processing* 9.5 (2000), pp. 860–872.
- [7] Federico Monti et al. “Geometric Deep Learning on Graphs and Manifolds Using Mixture Model CNNs”. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017.
- [8] Lei Mou et al. “CS2-Net: Deep learning segmentation of curvilinear structures in medical imaging”. *Medical image analysis* 67 (2021), p. 101874.
- [9] Pierre Rougé, Nicolas Passat, and Odysée Merveille. “Réseau de neurones multitâche et fonction de perte topologique pour la segmentation du réseau vasculaire cérébral à partir d’images IRM”. *Colloque Français d’Intelligence Artificielle en Imagerie Biomédicale (IABM)*. 2023.
- [10] Suprosanna Shit et al. “cIDice—a novel topology-preserving loss function for tubular structure segmentation”. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021, pp. 16560–16569.
- [11] Giles Tetteh et al. “Deepvesselnet: Vessel segmentation, centerline prediction, and bifurcation detection in 3-d angiographic volumes”. *Frontiers in Neuroscience* (2020), p. 1285.