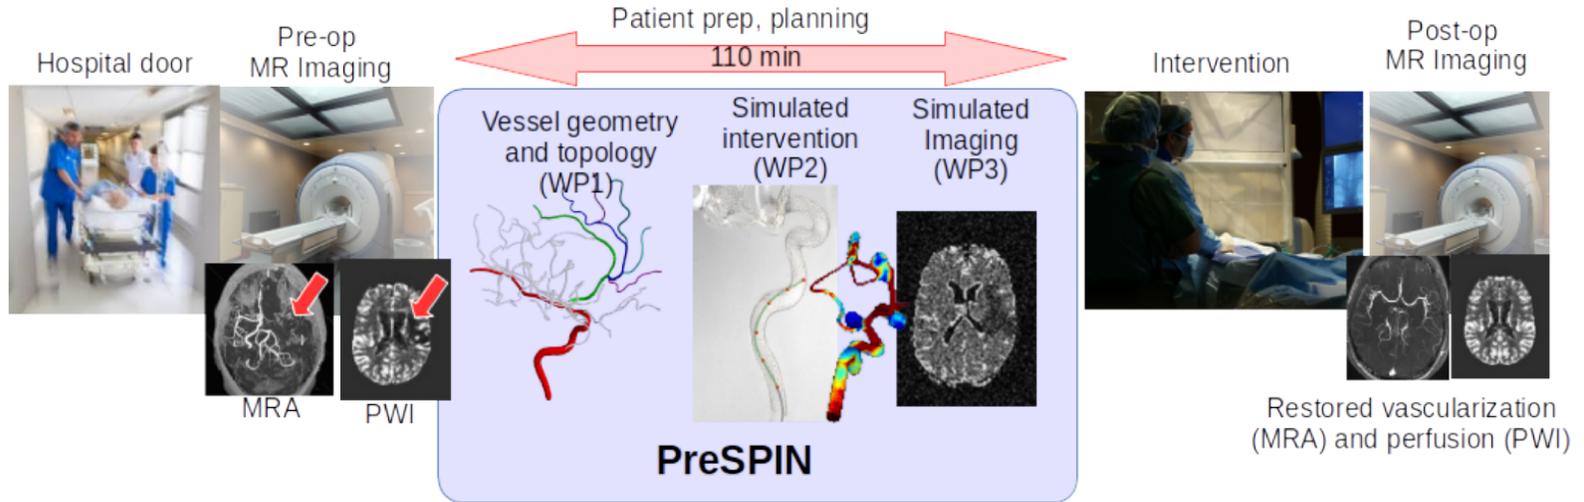


PreSPIN Project



Contexte médicale

- ▶ Le traitement le plus efficace contre l'AVC ischémique est la **Thrombectomie Endovasculaire (TEV)**, une intervention consistant à retirer le caillot à l'aide d'un cathéter
- ▶ Cette opération est complexe et donne souvent des résultats sous-optimaux
- ▶ **Le projet ANR PreSPIN propose de réaliser un simulateur de la TEV pour améliorer la planification de l'intervention et pour estimer le résultat post-opératoire**

Segmentation du réseau vasculaire par apprentissage profond

- ▶ La première étape est d'obtenir une segmentation précise du réseau vasculaire
- ▶ La segmentation manuelle est chronophage et ne peut pas être utilisée pour planifier l'intervention qui doit être effectuée très rapidement
- ▶ On utilise donc des méthodes d'apprentissage profond pour rendre la segmentation automatique
- ▶ **L'objectif est d'adapter l'apprentissage profond pour mieux prendre en compte la géométrie du réseau vasculaire**

Architecture proposée

- ▶ L'architecture utilisée est un UNet [1] modifié avec une branche de décodeur supplémentaire qui prédit seulement l'axe central des vaisseaux
- ▶ Cette architecture permet d'utiliser des fonctions de coût basées sur le squelette de la segmentation

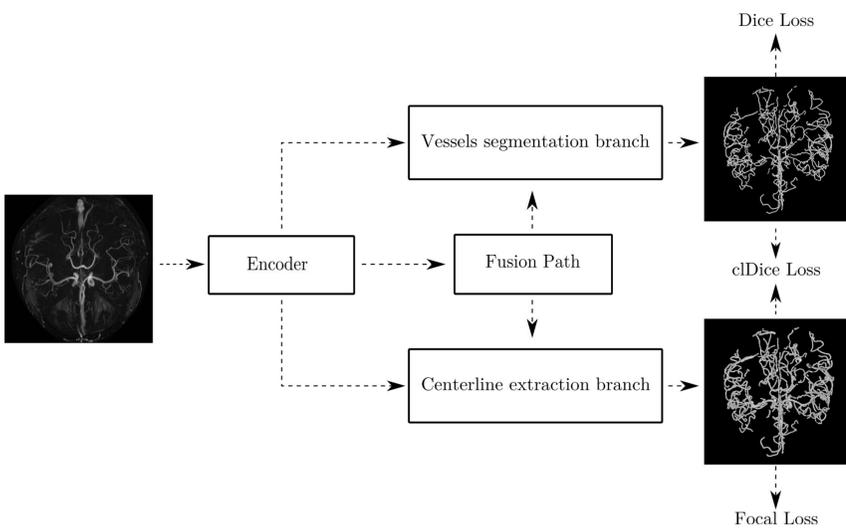


Figure 1: Schéma de l'architecture proposée

cDice Loss

- ▶ Pour améliorer la géométrie des segmentations, le réseau de neurones est entraîné avec la fonction de coût basée sur le squelette cDice Loss [2],
- ▶ Elle est définie par :

$$cDice(S_P, S_{GT}) = 2 * \frac{T_{prec}(C_P, S_{GT}) * T_{sens}(C_{GT}, S_P)}{T_{prec}(C_P, S_{GT}) + T_{sens}(C_{GT}, S_P)} \quad (1)$$

avec :

$$T_{prec}(C_P, S_{GT}) = \frac{|C_P \cap S_{GT}|}{|C_P|}; \quad T_{sens}(C_{GT}, S_P) = \frac{|C_{GT} \cap S_P|}{|C_{GT}|} \quad (2)$$

- ▶ S_P : la segmentation prédite
- ▶ S_{GT} : la vérité terrain de segmentation
- ▶ C_P : les lignes centrales prédites
- ▶ C_{GT} : la vérité terrain des lignes centrales

Résultats

- ▶ Pour évaluer notre méthode, on utilise la base de données publique Bullitt
- ▶ On se compare à plusieurs architectures de l'état de l'art avec une cross-validation 5-fold

Table 1: Résultats sur la base de donnée Bullitt

Modèle	Dice	cDice
DeepVesselNet	0.644 ± 0.008	0.757 ± 0.007
UNet 3D [1]	0.674 ± 0.006	0.788 ± 0.006
Our approach	0.698 ± 0.005	0.810 ± 0.006

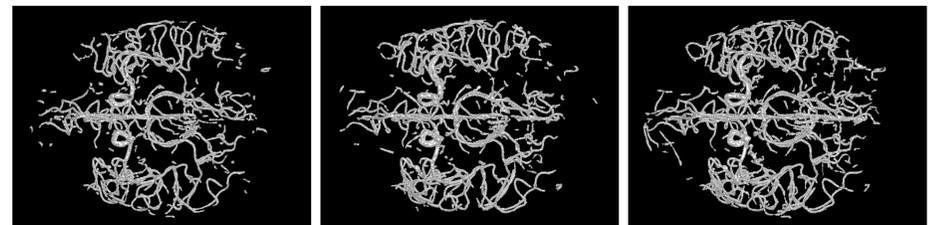


Figure 2: Résultats de segmentation avec les différents modèles pour un même patient

Conclusion et perspectives

- ▶ L'utilisation du cDice semble avoir un impact bénéfique sur la qualité des segmentations
- ▶ Pour une évaluation plus complète, il faut tester la méthode dans un cadre d'apprentissage plus performant (data augmentation, pre-processing...)

References

- [1] Olaf Ronneberger, Philipp Fischer, and Thomas Brox. "U-net: Convolutional networks for biomedical image segmentation". In: *International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2015.
- [2] Suprosanna Shit et al. "cDice - a Novel Topology-Preserving Loss Function for Tubular Structure Segmentation". In: *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021.