



HAL
open science

U-Net en cascade utilisant une fonction de perte topologique pour la segmentation du réseau vasculaire cérébral

Pierre Rougé, Nicolas Passat, Odysée Merveille

► To cite this version:

Pierre Rougé, Nicolas Passat, Odysée Merveille. U-Net en cascade utilisant une fonction de perte topologique pour la segmentation du réseau vasculaire cérébral. Journée Scientifique autour de l'IA (JSIA), Feb 2023, Nancy, France. . hal-04057315

HAL Id: hal-04057315

<https://hal.science/hal-04057315>

Submitted on 4 Apr 2023

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.



Distributed under a Creative Commons Attribution 4.0 International License

Contexte médical

- ▶ Les maladies vasculaires, notamment l'accident vasculaire cérébral, sont une importante cause de mort et de handicap dans le monde.
- ▶ La segmentation précise du réseau vasculaire cérébral à partir d'images angiographiques est la première étape de nombreux traitements médicaux assistés par ordinateur.
- ▶ **Cependant, un réseau vasculaire est une structure difficile à segmenter parce qu'il possède une géométrie et une topologie très complexes (structures très fines, connectées, organisées en réseaux, structure éparse ...).**
- ▶ Pour ces raisons, les méthodes d'apprentissage profond ont encore du mal à obtenir des segmentations satisfaisantes.

cIDice Loss

- ▶ Récemment, [2] ont proposé une nouvelle fonction de coût, appelée cIDice, basée sur le squelette et prenant mieux en compte l'information topologique.

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

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
- ▶ Elle nécessite le calcul du squelette de la segmentation pendant l'entraînement par un algorithme *soft-skeleton* différentiable. Cependant, cet algorithme donne des résultats sous-optimaux.
- ▶ **Nous proposons d'utiliser un réseau U-Net [1] pour apprendre l'opération de squelettisation afin d'obtenir de meilleurs squelettes.**

Architecture proposée

- ▶ Architecture en cascade composée d'un premier réseau U-Net effectuant la segmentation suivis du second U-Net effectuant la squelettisation.
- ▶ Pour entraîner cette architecture, nous avons d'abord pré-entraîné les deux U-Nets séparément puis fixé les poids du réseau de squelettisation avant d'entraîner l'architecture conjointement.

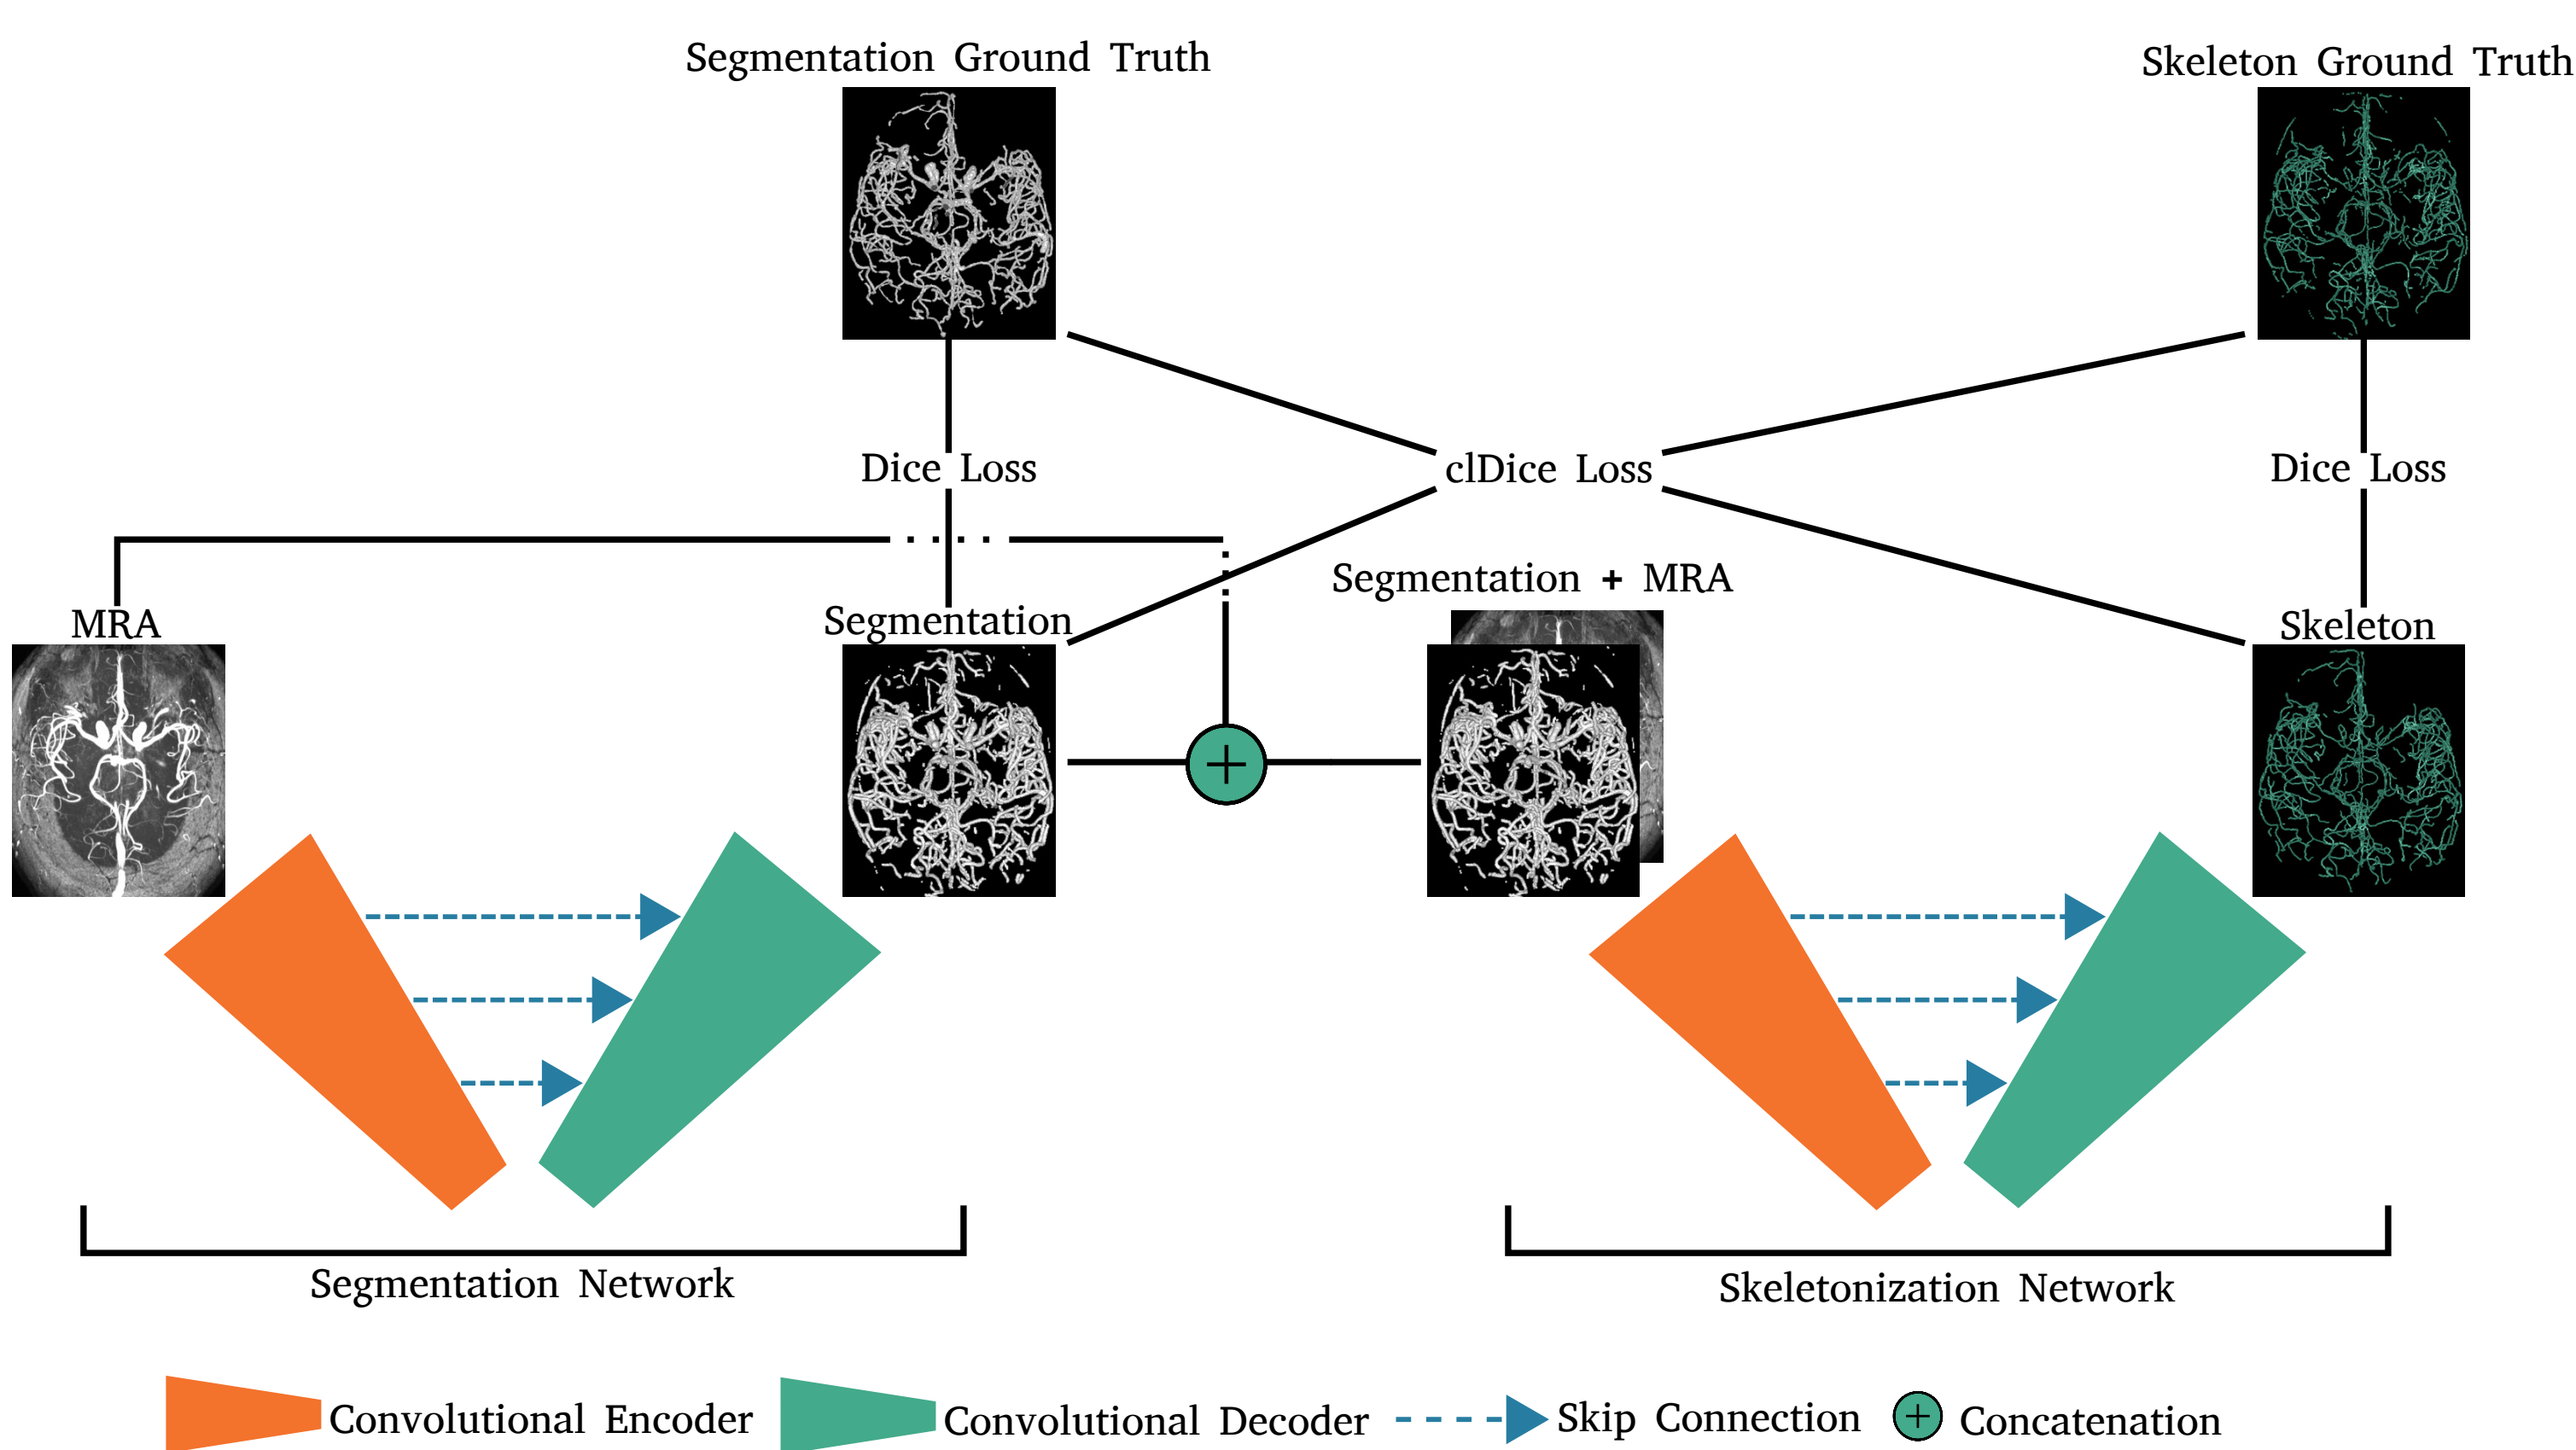


Figure 1: Architecture du U-Net en cascade

Squelettisation

- ▶ Évaluation de la segmentation et de la squelettisation avec la BDD publique Bullitt d'ARM TOF.
- ▶ Comparaison des méthodes de squelettisation.

Table 1: Résultats de notre réseau de squelettisation (6e ligne) vs. l'algorithme *soft-skeleton* pour différentes valeurs de k (1st to 5th row).

Model	Time (ms)	χ error ↓	β_0 error ↓	β_1 error ↓
soft-skel. alg. $k=1$	2.6 ± 0.3	3.507 ± 0.622	11.072 ± 5.336	0.961 ± 0.022
soft-skel. alg. $k=2$	4.0 ± 0.4	3.600 ± 0.647	11.531 ± 5.565	0.959 ± 0.024
soft-skel. alg. $k=3$	5.5 ± 0.5	3.625 ± 0.653	11.661 ± 5.634	0.958 ± 0.023
soft-skel. alg. $k=4$	8.3 ± 1.4	3.631 ± 0.652	11.693 ± 5.647	0.958 ± 0.023
soft-skel. alg. $k=5$	8.9 ± 1.0	3.633 ± 0.653	11.700 ± 5.650	0.958 ± 0.023
Skel. network	12.4 ± 5.6	1.602 ± 0.209	3.197 ± 1.565	0.757 ± 0.067
p-valeur		$p < 0.001$	$p < 0.001$	$p < 0.001$

Segmentation - U-Net en cascade

- ▶ On compare notre approche avec un U-Net utilisant seulement la fonction de perte Dice et un U-Net utilisant une combinaison du Dice et du cIDice mais utilisant l'algorithme *soft-skeleton* pour la squelettisation.

Table 2: Résultats du U-Net en cascade : moyenne ± écart-type (p-valeur). Les p-valeurs sont calculées par rapport aux résultats du U-Net (Dice).

Model	U-Net (Dice)	U-Net (Dice+cIDice)	Cascaded U-Net
DSC ↑	0.751 ± 0.017	0.752 ± 0.015	0.750 ± 0.017 ($p = 0.71$)
cIDice ↑	0.843 ± 0.018	0.844 ± 0.016	0.843 ± 0.017 ($p = 0.55$)
Prec ↑	0.774 ± 0.030	0.772 ± 0.029	0.757 ± 0.030 ($p < 0.001$)
Sens ↑	0.732 ± 0.043	0.735 ± 0.036	0.746 ± 0.040 ($p < 0.001$)
χ error ↓	0.495 ± 0.187	0.518 ± 0.166	0.379 ± 0.186 ($p < 0.001$)
β_0 error ↓	1.338 ± 1.103	1.424 ± 1.224	1.263 ± 0.874 ($p = 0.59$)
β_1 error ↓	0.205 ± 0.138	0.212 ± 0.137	0.170 ± 0.104 ($p = 0.02$)




Figure 2: Résultats de segmentation obtenu avec les 3 approches comparées. Les flèches rouges indiquent les endroits où notre méthode permet une meilleure détection des vaisseaux et crée des reconnexions.

Conclusion

- ▶ On constate que les deux baselines donnent des résultats similaires. D'un autre côté, notre méthode présente une sensibilité plus élevée qui indique une meilleure détection des vaisseaux, mais cela se fait au détriment de la précision.
- ▶ **Cette meilleure détection permet des segmentations mieux connectées (voir Figure 2) et une meilleure conservation de la topologie (Table 2).**

Références

- [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. "cIDice - a Novel Topology-Preserving Loss Function for Tubular Structure Segmentation". In: *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021.