



# U-Net en cascade utilisant le cIDice pour la segmentation de réseaux vasculaires



25/05/2023 ORASIS

Pierre Rougé<sup>12</sup>

**Encadrants :**

Nicolas Passat<sup>1</sup>

Odyssée Merveille<sup>2</sup>

<sup>1</sup>Université de Reims Champagne-Ardenne, CReSTIC, Reims, France

<sup>2</sup>CREATIS; CNRS (UMR 5220); INSERM (U1294); INSA Lyon; Université de Lyon, France

## Contexte clinique : AVC ischémique

- L'accident vasculaire cérébral est une cause majeure de mortalité et de handicap dans le monde
- Deux types de traitements :
  - Dissolution du caillot par perfusion de médicament
  - **Retrait du caillot par un dispositif mécanique : thrombectomie endovasculaire (TEV)**
- Opération complexe → résultats sous-optimaux

### AVC ischémique (France AVC)



## Contexte clinique : AVC ischémique

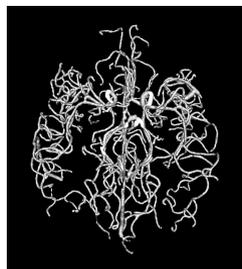
- L'accident vasculaire cérébral est une cause majeure de mortalité et de handicap dans le monde
- Deux types de traitements :
  - Dissolution du caillot par perfusion de médicament
  - **Retrait du caillot par un dispositif mécanique : thrombectomie endovasculaire (TEV)**
- Opération complexe → résultats sous-optimaux
- **Objectif : Mettre au point un simulateur pour la TEV**

### AVC ischémique (France AVC)



## Contexte clinique : AVC ischémique

- L'accident vasculaire cérébral est une cause majeure de mortalité et de handicap dans le monde
- Deux types de traitements :
  - Dissolution du caillot par perfusion de médicament
  - **Retrait du caillot par un dispositif mécanique : thrombectomie endovasculaire (TEV)**
- Opération complexe → résultats sous-optimaux
- **Objectif : Mettre au point un simulateur pour la TEV**
- Pour cela il est nécessaire d'obtenir une segmentation précise du réseau vasculaire cérébral



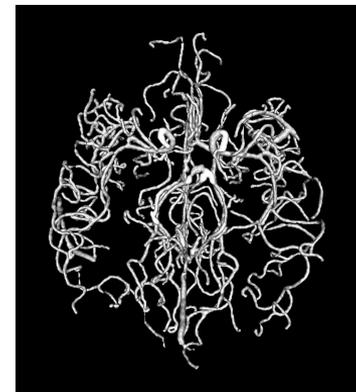
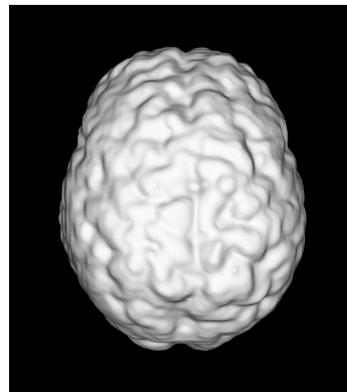
### AVC ischémique (France AVC)



# Problématique

**Objectif : Segmentation du réseau vasculaire cérébral avec une topologie correcte**

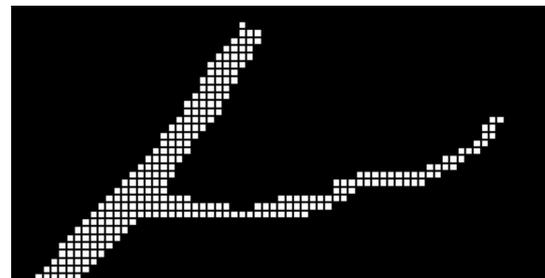
- Spécificités :
  - structure non compacte et tortueuse
  - objets fins à la limite de la résolution
  - différentes échelles de vaisseaux
- Conséquence : les méthodes d'apprentissage profond s'appliquent plus difficilement aux réseaux vasculaires



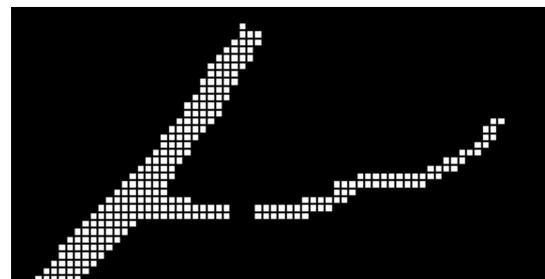
# Problématique

Objectif : Segmentation du réseau vasculaire cérébral avec une topologie correcte

- Spécificités :
  - structure non compacte et tortueuse
  - objets fins à la limite de résolution
  - différentes échelles de vaisseaux
- Conséquence : les méthodes d'apprentissage profond s'appliquent plus difficilement aux réseaux vasculaires
- **Problèmes de connectivité**
- Les métriques et fonctions de coût usuelles ne sont pas adaptées à cette tâche



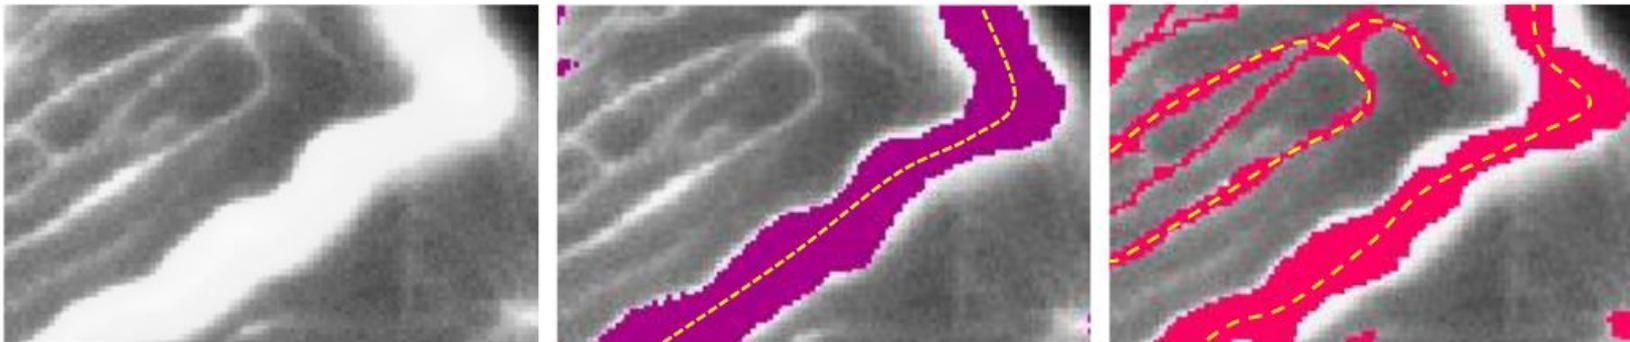
Dice = 0.972



Dice = 0.972

## Qu'est ce que le cIDice (Shit et al., 2020) ?

- Métrique basée sur le squelette de la segmentation
- Évite d'être biaisé par les gros vaisseaux
- Améliore la topologie des segmentations
- **Nécessite de calculer le squelette de manière différentiable**

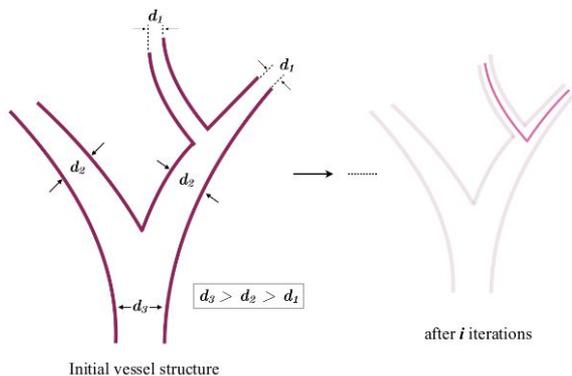


## Algorithme *soft-skeleton*

La plupart des méthodes d'extraction du squelette ne sont pas différentiables

Soft-skeleton :

- On érode progressivement la structure tubulaire
- Si une branche disparaît entre deux érosions, alors c'est qu'elle est squelettisée

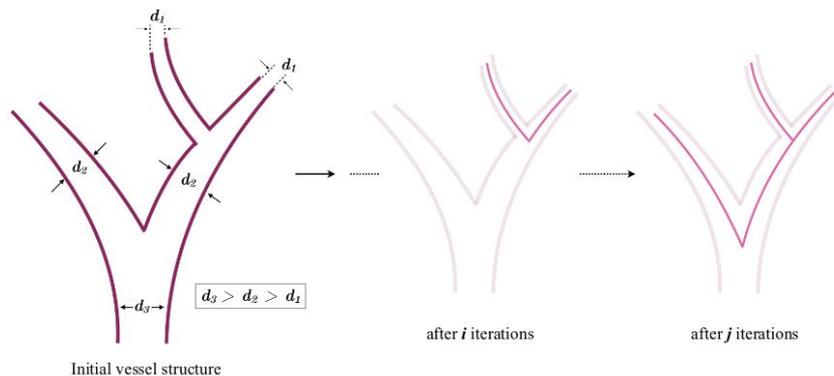


## Algorithme *soft-skeleton*

La plupart des méthodes d'extraction du squelette ne sont pas différentiables

Soft-skeleton :

- On érode progressivement la structure tubulaire
- Si une branche disparaît entre deux érosions, alors c'est qu'elle est squelettisée

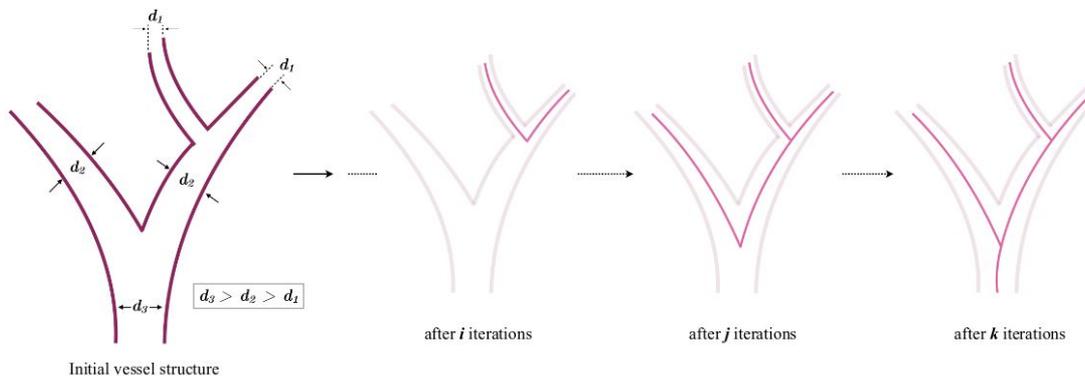


## Algorithme *soft-skeleton*

La plupart des méthodes d'extraction du squelette ne sont pas différentiables

Soft-skeleton :

- On érode progressivement la structure tubulaire
- Si une branche disparaît entre deux érosions, alors c'est qu'elle est squelettisée



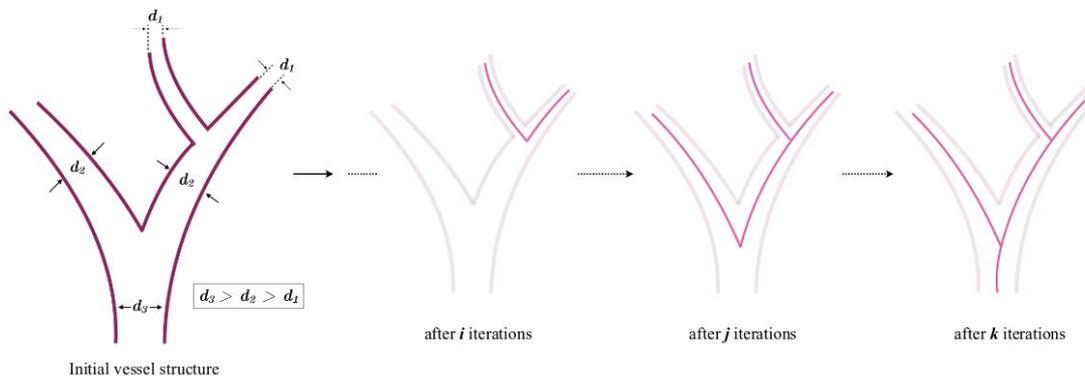
## Algorithme *soft-skeleton*

La plupart des méthodes d'extraction du squelette ne sont pas différentiables

Soft-skeleton :

- On érode progressivement la structure tubulaire
- Si une branche disparaît entre deux érosions, alors c'est qu'elle est squelettisée

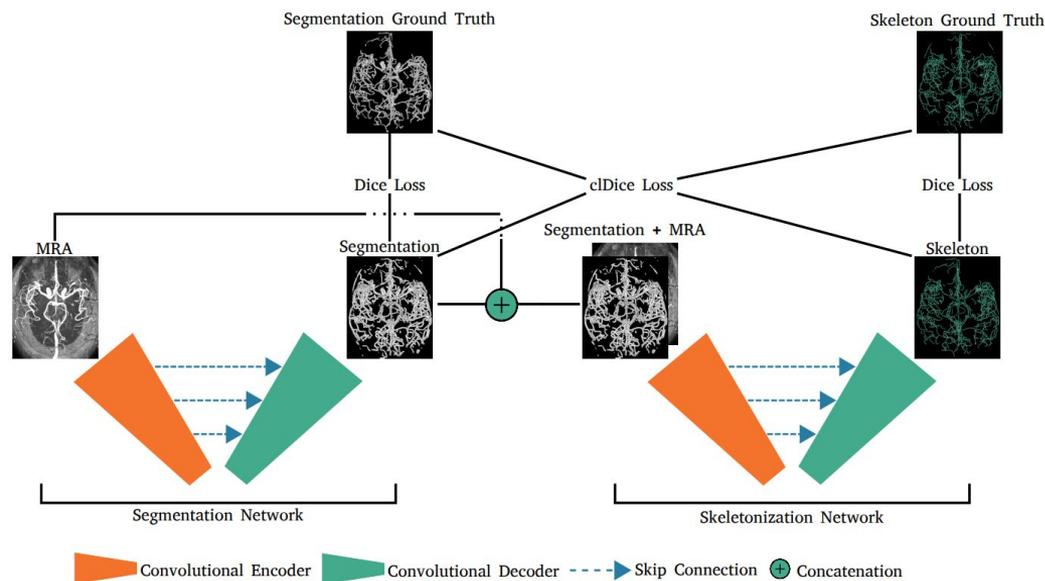
**Problème : Donne de mauvais résultats en 3D**



## Notre approche : U-Net en cascade

Solution : Utiliser un deuxième U-Net (Ronneberger et al. 2015) pour prédire le squelette

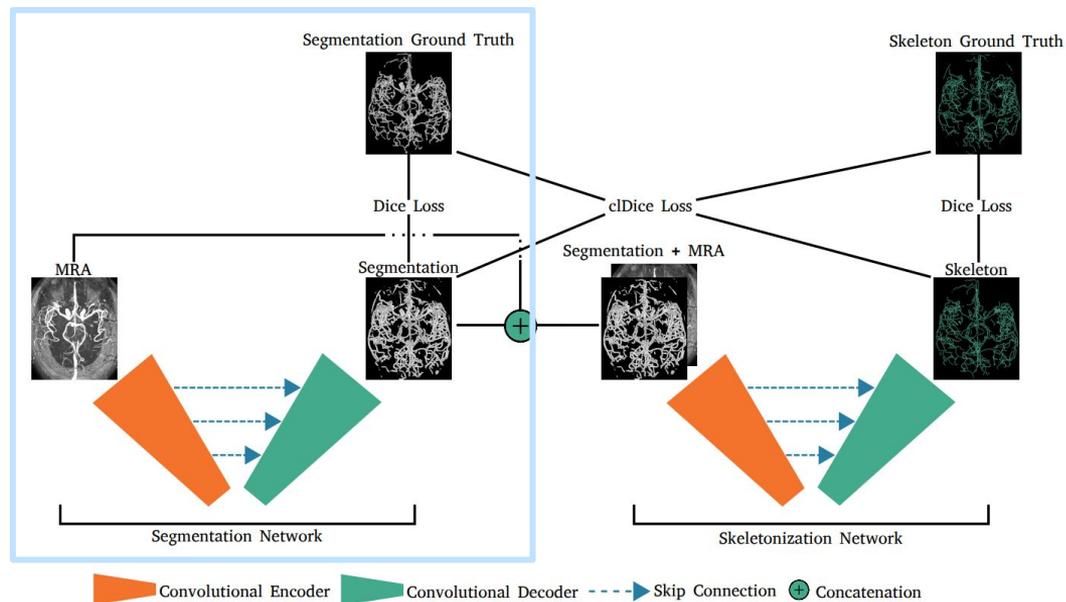
- 1er U-Net : segmentation
- 2e U-Net : squelettisation
- Le réseau de squelettisation prend en entrée l'image ARM et la segmentation



## Notre approche : U-Net en cascade

Solution : Utiliser un deuxième U-Net (Ronneberger et al. 2015) pour prédire le squelette

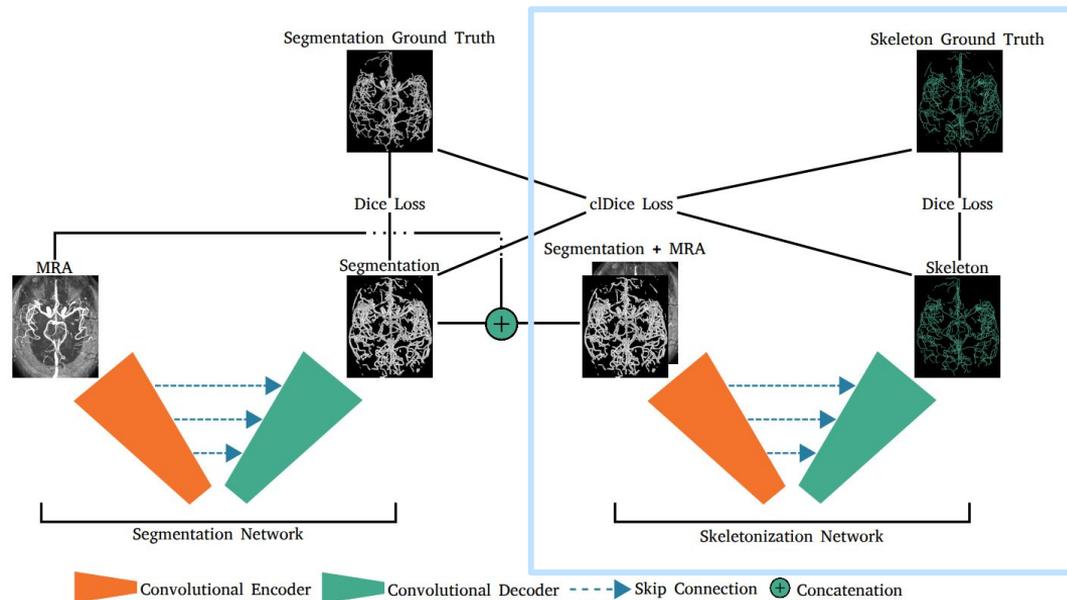
- 1er U-Net : segmentation
- 2e U-Net : squelettisation
- Le réseau de squelettisation prend en entrée l'image ARM et la segmentation



## Notre approche : U-Net en cascade

Solution : Utiliser un deuxième U-Net (Ronneberger et al. 2015) pour prédire le squelette

- 1er U-Net : segmentation
- 2e U-Net : squelettisation
- Le réseau de squelettisation prend en entrée l'image ARM et la segmentation

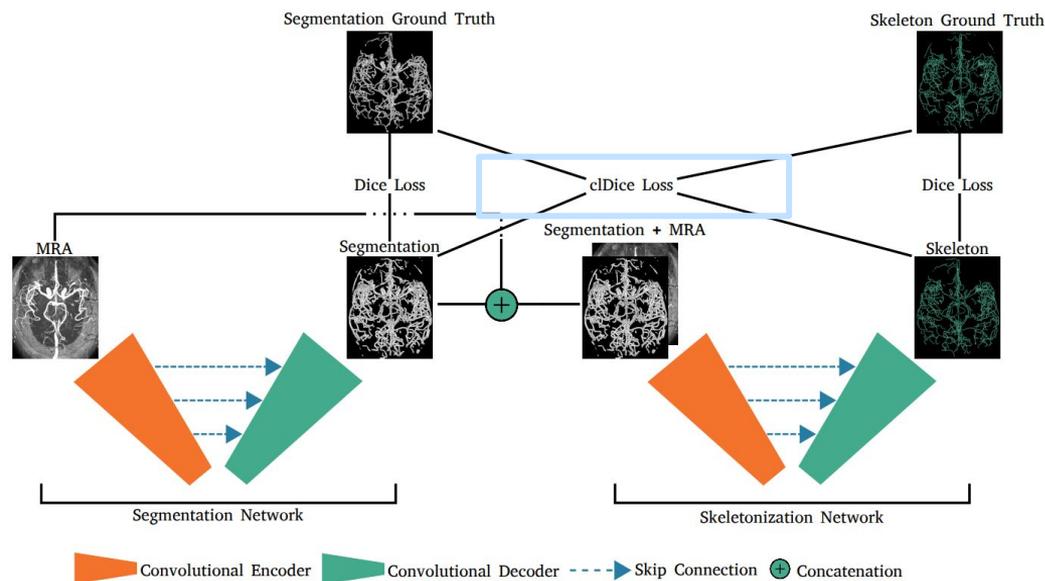


## Notre approche : U-Net en cascade

Solution : Utiliser un deuxième U-Net (Ronneberger et al. 2015) pour prédire le squelette

- 1er U-Net : segmentation
- 2e U-Net : squelettisation
- Le réseau de squelettisation prend en entrée l'image ARM et la segmentation

On peut alors utiliser le cIDice pour induire une contrainte topologique



$$\text{Loss} = \lambda_1 \cdot \text{DiceLoss}(S_p, S_G) + \lambda_2 \cdot \text{DiceLoss}(C_p, C_G) + \lambda_3 \cdot \text{cIDiceLoss}(S_p, C_p, S_G, C_G)$$

- $C_p, C_G$  : Prédiction & vérité terrain ligne centrale
- $S_p, S_G$  : Prédiction & vérité terrain segmentation

## Notre approche : U-Net en cascade

### Données

- Jeu de données public : Bullitt (Aylward et al. 2002)
- Angiographie par résonance magnétique (ARM)
- 34 patients annotés
- Résolution :  $0.513 \times 0.513 \times 0.800 \text{ mm}^3$
- Taille :  $448 \times 448 \times 128$  (taille de patch :  $192 \times 192 \times 128$ )

### Métriques

- Volumétriques : Dice (DSC), cIDice, Précision, Sensibilité
- Topologiques :
  - Nombres de Betti  $\beta_0$  (nombre de composantes connectées)
  - $\beta_1$  (nombre de tunnels)
  - $\beta_2$  (nombre de cavités)
  - caractéristique d'Euler  $\chi = \beta_0 - \beta_1 + \beta_2$

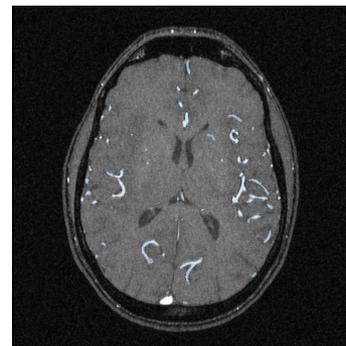
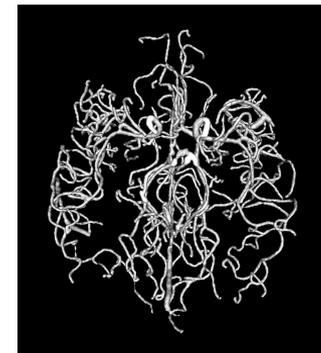


Image ARM (coupe)



Vérité terrain (3D)

## Résultats du réseau de squelettisation

Modèle	Temps (ms)	$\chi$ (erreur) ↓	$\beta_0$ (erreur) ↓	$\beta_1$ (erreur) ↓
<i>Soft-skeleton</i> ( $k=1$ )	<b>2.6</b> ± 0.3	3.507 ± 0.622	11.072 ± 5.336	0.961 ± 0.022
<i>Soft-skeleton</i> ( $k=2$ )	4.0 ± 0.4	3.600 ± 0.647	11.531 ± 5.565	0.959 ± 0.024
<i>Soft-skeleton</i> ( $k=3$ )	5.5 ± 0.5	3.625 ± 0.653	11.661 ± 5.634	0.958 ± 0.023
<i>Soft-skeleton</i> ( $k=4$ )	8.3 ± 1.4	3.631 ± 0.652	11.693 ± 5.647	0.958 ± 0.023
<i>Soft-skeleton</i> ( $k=5$ )	8.9 ± 1.0	3.633 ± 0.653	11.700 ± 5.650	0.958 ± 0.023
Notre réseau	12.4 ± 5.6	<b>1.602</b> ± 0.209	<b>3.197</b> ± 1.565	<b>0.757</b> ± 0.067
p-valeur $p$ (vs. <i>soft-skeleton</i> ( $k=3$ ))		$p < 0.001$	$p < 0.001$	$p < 0.001$

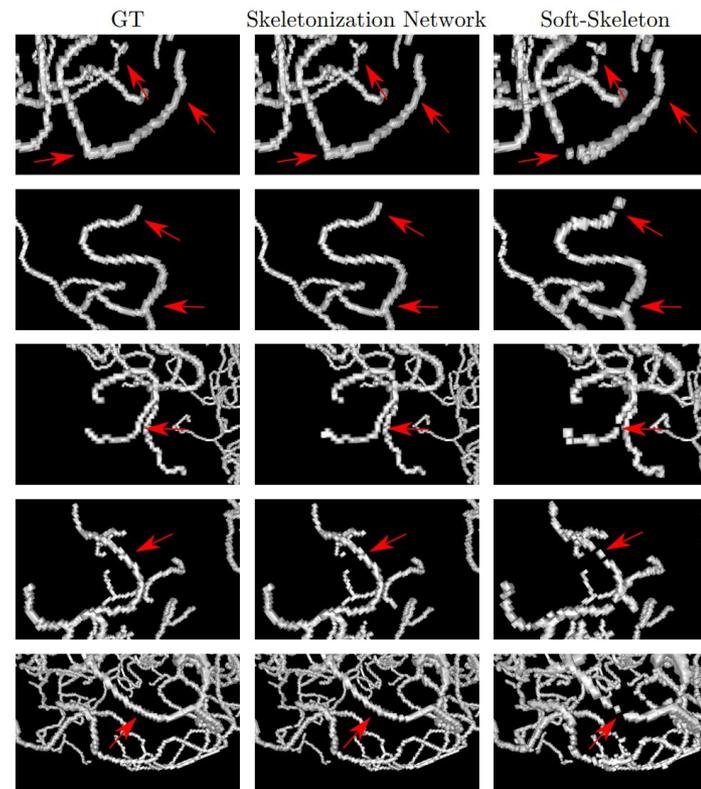
Pour un temps de calcul comparable, notre méthode améliore significativement la qualité des squelettes d'un point de vue topologique

## Résultats du réseau de squelettisation

La méthode soft-skeleton présente deux problèmes :

- les squelettes induisent des déconnexions
- les squelettes ont une largeur supérieure à un voxel

Ces problèmes ne sont plus présents avec notre méthode



## Résultats de notre méthode de segmentation

Modèle	U-Net (Dice)	U-Net (Dice+clDice)	U-Net en cascade
$DSC \uparrow$	$0.751 \pm 0.017$	<b><math>0.752 \pm 0.015</math></b> ( $p = 0.43$ )	$0.750 \pm 0.017$ ( $p = 0.71$ )
$clDice \uparrow$	$0.843 \pm 0.018$	$0.844 \pm 0.016$ ( $p = 0.52$ )	$0.843 \pm 0.017$ ( $p = 0.55$ )
$Prec \uparrow$	<b><math>0.774 \pm 0.030</math></b>	$0.772 \pm 0.029$ ( $p = 0.56$ )	$0.757 \pm 0.030$ ( $p < 0.001$ )
$Sens \uparrow$	$0.732 \pm 0.043$	$0.735 \pm 0.036$ ( $p = 0.37$ )	<b><math>0.746 \pm 0.040</math></b> ( $p < 0.001$ )
$\chi$ (erreur) $\downarrow$	$0.495 \pm 0.187$	$0.518 \pm 0.166$ ( $p = 0.34$ )	<b><math>0.379 \pm 0.186</math></b> ( $p < 0.001$ )
$\beta_0$ (erreur) $\downarrow$	$1.338 \pm 1.103$	$1.424 \pm 1.224$ ( $p = 0.22$ )	<b><math>1.263 \pm 0.874</math></b> ( $p = 0.59$ )
$\beta_1$ (erreur) $\downarrow$	$0.205 \pm 0.138$	$0.212 \pm 0.137$ ( $p = 0.72$ )	<b><math>0.170 \pm 0.104</math></b> ( $p = 0.02$ )

- DSC & clDice : pas de différences significatives

## Résultats de notre méthode de segmentation

Modèle	U-Net (Dice)	U-Net (Dice+cIDice)	U-Net en cascade
$DSC \uparrow$	$0.751 \pm 0.017$	<b>0.752</b> $\pm 0.015$ ( $p = 0.43$ )	$0.750 \pm 0.017$ ( $p = 0.71$ )
$clDice \uparrow$	$0.843 \pm 0.018$	$0.844 \pm 0.016$ ( $p = 0.52$ )	$0.843 \pm 0.017$ ( $p = 0.55$ )
$Prec \uparrow$	<b>0.774</b> $\pm 0.030$	$0.772 \pm 0.029$ ( $p = 0.56$ )	$0.757 \pm 0.030$ ( $p < 0.001$ )
$Sens \uparrow$	$0.732 \pm 0.043$	$0.735 \pm 0.036$ ( $p = 0.37$ )	<b>0.746</b> $\pm 0.040$ ( $p < 0.001$ )
$\chi$ (erreur) $\downarrow$	$0.495 \pm 0.187$	$0.518 \pm 0.166$ ( $p = 0.34$ )	<b>0.379</b> $\pm 0.186$ ( $p < 0.001$ )
$\beta_0$ (erreur) $\downarrow$	$1.338 \pm 1.103$	$1.424 \pm 1.224$ ( $p = 0.22$ )	<b>1.263</b> $\pm 0.874$ ( $p = 0.59$ )
$\beta_1$ (erreur) $\downarrow$	$0.205 \pm 0.138$	$0.212 \pm 0.137$ ( $p = 0.72$ )	<b>0.170</b> $\pm 0.104$ ( $p = 0.02$ )

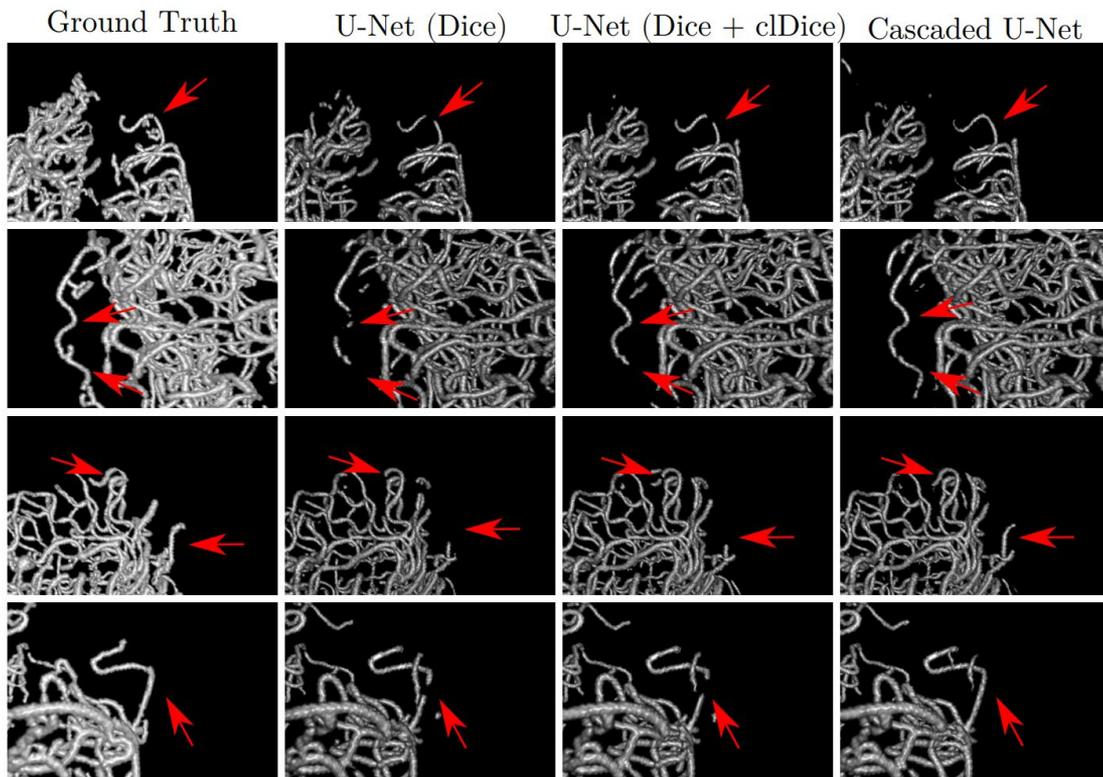
- DSC & cIDice : pas de différences significatives
- Prec & Sens : notre méthode gagne en sensibilité au détriment de la précision

## Résultats de notre méthode de segmentation

Modèle	U-Net (Dice)	U-Net (Dice+clDice)	U-Net en cascade
$DSC \uparrow$	$0.751 \pm 0.017$	<b>0.752</b> $\pm 0.015$ ( $p = 0.43$ )	$0.750 \pm 0.017$ ( $p = 0.71$ )
$clDice \uparrow$	$0.843 \pm 0.018$	$0.844 \pm 0.016$ ( $p = 0.52$ )	$0.843 \pm 0.017$ ( $p = 0.55$ )
$Prec \uparrow$	<b>0.774</b> $\pm 0.030$	$0.772 \pm 0.029$ ( $p = 0.56$ )	$0.757 \pm 0.030$ ( $p < 0.001$ )
$Sens \uparrow$	$0.732 \pm 0.043$	$0.735 \pm 0.036$ ( $p = 0.37$ )	<b>0.746</b> $\pm 0.040$ ( $p < 0.001$ )
$\chi$ (erreur) $\downarrow$	$0.495 \pm 0.187$	$0.518 \pm 0.166$ ( $p = 0.34$ )	<b>0.379</b> $\pm 0.186$ ( $p < 0.001$ )
$\beta_0$ (erreur) $\downarrow$	$1.338 \pm 1.103$	$1.424 \pm 1.224$ ( $p = 0.22$ )	<b>1.263</b> $\pm 0.874$ ( $p = 0.59$ )
$\beta_1$ (erreur) $\downarrow$	$0.205 \pm 0.138$	$0.212 \pm 0.137$ ( $p = 0.72$ )	<b>0.170</b> $\pm 0.104$ ( $p = 0.02$ )

- DSC & clDice : pas de différences significatives
- Prec & Sens : notre méthode gagne en sensibilité au détriment de la précision
- Métriques topologiques : notre méthode améliore la topologie des segmentations

## Résultats de notre méthode de segmentation



Visuellement, on observe que notre méthode permet de mieux connecter les vaisseaux aux extrémités

## Conclusion

- Nous avons proposé d'utiliser un réseau pour effectuer la squelettisation d'une segmentation de manière rapide, précise et différentiable
- Nous avons montré que la méthode fournit des squelettes plus précis sur le plan topologique que la méthode *soft-skeleton*
- **Nous avons ensuite proposé une architecture en cascade permettant d'imposer une contrainte topologique grâce à la fonction de coût cIDice**
- **Cette architecture permet d'améliorer la topologie des segmentations**

## Perspectives

- Validation sur un plus grand jeu de données
- Validation sur des réseaux vasculaires d'autres organes (poumons, foie...)

Merci pour votre attention !

# Segmentation en imagerie médicale

Quelles différences ?

2D

Fort contraste

Bruit faible

Beaucoup de données

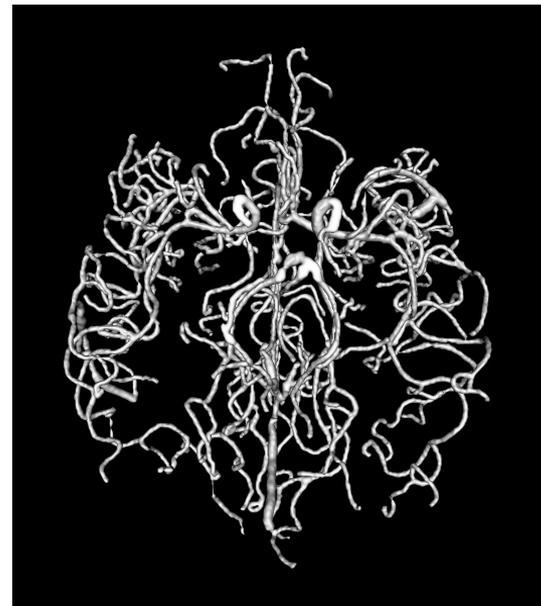


3D

Faible contraste

Bruit fort

Peu de données



## Qu'est ce que le *clDice* [1] ?

$$T_{prec}(C_P, S_G) = \frac{|C_P \cap S_G|}{|C_P|} \quad T_{sens}(C_G, S_P) = \frac{|C_G \cap S_P|}{|C_G|}$$

$$clDice(S_P, S_G, C_P, C_G) = 2 \cdot \frac{T_{prec}(C_P, S_G) \cdot T_{sens}(C_G, S_P)}{T_{prec}(C_P, S_G) + T_{sens}(C_G, S_P)}$$

- $C_p$  : Ligne centrale prédite
- $C_G$  : Vérité terrain ligne centrale
- $S_p$  : Segmentation prédite
- $S_G$  : Vérité terrain de segmentation

## Références

- [1] Shit, Suprosanna et al. (2020). cIDice - a Topology-Preserving Loss Function for Tubular Structure Segmentation.
- [2] S. R. Aylward et al. Initialization, noise, singularities, and scale in height ridge traversal for tubular object centerline extraction. IEEE Transactions on Medical Imaging, 2002
- [3] Ronneberger, O. et al. U-net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015