

Comparison of U-Net and DC-UNnet models for an efficient segmentation and visualization of rodent hepatic vascular network from X-Ray phase contrast imaging.

ISBI 2023

M. Alvarez<sup>1</sup>, D.R. Piana<sup>1</sup>, H. Rositi<sup>2\*</sup> and A. Vacavant<sup>2</sup>

<sup>1</sup>Centre of Medical Physics and Radiological Protection - Botucatu Clinical Hospital - UNESP - Brazil

<sup>2</sup>Institut Pascal, F-63000 Clermont-Ferrand, France

Bron, le 15 Juin 2023



# Imagerie du foie à l'échelle microscopique

## Objectifs

- Visualiser le foie à une échelle microscopique.
- Visualiser et caractériser le réseau vasculaire.




Figure – Coupe virtuelle d'un foie de souris en imagerie de contraste de phase.





Figure – Zoom sur vaisseau sanguin.

# Imagerie du foie à l'échelle microscopique

## Objectifs

- Visualiser le foie à une échelle microscopique.
- Visualiser et caractériser le réseau vasculaire.




- Volume important des données 2560x2560x1400 pixels (32 bits).
- Résolution spatiale de l'ordre de  $6.5\mu m$ .

# Approche classique pour la segmentation vasculaire

## Stage de Lucca Merola (Mars 2020)

- Pré-traitements
- Filtre de rehaussement (Frangi)
- Création d'une vérité terrain sur une dizaine de coupes.
- Dice 0.8






# Approche par apprentissage profond

## Comparaison de deux modèles d'apprentissage profond

- U-Net et DC-UNet.
- Dual Channel block encoder/decoder.
- Residual module pour remplacer les skips connections.
- Amélioration entre 1% et 11% (d'après les auteurs de DC-UNet).



Modèle UNet, 2015.




Modèle DC-UNet, 2020.

## Jeu de données

### Détails

- Les dimensions des données sont réduites à 1420x1360x1000 voxels.
- 12 coupes ont été annotées manuellement.
- 80% des coupes sont utilisées pour l'entraînement.
- 20% des coupes sont utilisées pour la validation.
- Les images sont divisées en patches aléatoires de 256x256.



# Pré-traitements

## Quelques optimisations

- Amélioration locale du contraste (CLAHE, égalisation d'histogramme locale).
- Filtrage Sigmoïde :  $I_{new_{i,j}} = \frac{1}{1 + \sqrt{\frac{1 - I_{i,j}}{I_{i,j}}}}$ , pour homogénéiser. Atténue les bas et hauts niveaux et on conserve les niveaux moyens.
- Augmentation des données d'entraînement (inversion horizontale et verticale, rotation)


## Implémentation / paramétrisation

Table: Hyperparameters of our models.


Hyperparameters	UNet1	UNet2	DC-UNet1	DC-UNet2
Batch size	32	32	32	32
Epochs	100	100	50	50
Epochs Drop	20	20	10	20
Loss function	Dice loss	Dice + Cross entropy	Tversky	Tversky
Optimizer	Adam	Adam	Adam	Adam
Dropout Rate	0.1	0.1	0.1	0.1
Init Learning rate	$10^{-2}$	$10^{-4}$	$10^{-2}$	$10^{-3}$
Learning rate	$10^{-5}$	$10^{-4}$	$10^{-2}$	$10^{-2}$
Data augmentation	False	True	True	True

# Résultats de convergence


- 1 epoch correspond au traitement de 10 patches (256x256).




(a)



(b)



(c)



(d)


U-Net 1-2 (a-b), DC-UNet 1-2 (c-d).

# Performance

Modèle	Dice coefficient
U-Net 1	0.83
U-Net 2	0.81
DC-UNet 1	0.84
DC-UNet 2	0.80


Table – Performances des différents modèles.

## Visualisation des résultats patches 2D



U-Net 1


## Visualisation des résultats patches 2D



U-Net 2




## Visualisation des résultats patches 2D




DC-UNet 1

## Visualisation des résultats patches 2D





DC-UNet 2

# Visualisation des résultats Coupes 2D





Coupe 1

## Visualisation des résultats Coupes 2D



Coupe 50

# Visualisation des résultats Coupes 2D



Coupe 90

## Visualisation des résultats 3D




U-Net 1

## Visualisation des résultats 3D



DC-UNet 1

# Visualisation des résultats 3D





## Perspectives et conclusion

### Perspectives

- Plus de données annotées pour une meilleure stabilité des résultats.
- Des fonctions de pertes différentes et une meilleure augmentation des données (artefacts et convergence).
- Intégrer une évaluation de la connectivité des résultats.

### Conclusion

- Preuve de faisabilité des méthodes par apprentissage sur ces données (faible nombre).
- Amélioration des résultats par rapport à notre approche classique.
- Des résultats sensiblement similaires entre les modèles.
- Des approches à affiner (pré-traitements, modèles et paramètres).

Merci pour votre attention.