



HAL
open science

Apprentissage d'un terme de régularisation reconnecteur pour la segmentation de vaisseaux sanguins par approche variationnelle

Sophie Carneiro Esteves, Antoine Vacavant, Odysée Merveille

► To cite this version:

Sophie Carneiro Esteves, Antoine Vacavant, Odysée Merveille. Apprentissage d'un terme de régularisation reconnecteur pour la segmentation de vaisseaux sanguins par approche variationnelle. ORASIS 2021, Centre National de la Recherche Scientifique [CNRS], Sep 2021, Saint Ferréol, France. hal-03339624

HAL Id: hal-03339624

<https://hal.science/hal-03339624v1>

Submitted on 9 Sep 2021

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.

Apprentissage d'un terme de régularisation reconnecteur pour la segmentation de vaisseaux sanguins par approche variationnelle*

S. Carneiro Esteves^{1,2}

A. Vacavant¹

O. Merveille²

¹ Université Clermont Auvergne, CNRS, SIGMA Clermont,
Institut Pascal F-63000, Clermont-Ferrand, France

² Univ Lyon, INSA-Lyon, Université Claude Bernard Lyon 1, UJM-Saint Etienne,
CNRS, Inserm, CREATIS UMR 5220, U1206, F-69100, LYON, France

sophie.carneiro@creatis.insa-lyon.fr, antoine.vacavant@uca.fr, odyssee.merveille@creatis.insa-lyon.fr

Résumé

La segmentation des vaisseaux sanguins est une tâche difficile du fait de leur finesse, tortuosité et connectivité complexe. Des méthodes par apprentissage profond ont été proposées pour répondre à ce problème, mais nécessitent de larges jeux de données (un pour chaque nouvelle application), ce qui est très difficile à obtenir pour les réseaux vasculaires. Dans ce papier, plutôt que d'apprendre à segmenter, nous proposons d'apprendre un terme de régularisation reconnecteur. Ainsi, ce terme peut se généraliser plus facilement que les modèles de segmentation appris par apprentissage profond et peut être facilement injecté dans des schémas d'optimisation variationnelles pour détecter des réseaux vasculaires de différents jeux de données sans nécessiter de nouvelles annotations. Nous montrons que notre approche permet de mieux préserver la connectivité des réseaux vasculaires que certains termes de régularisations classiques. Enfin, nous montrons le pouvoir de généralisation de notre terme de reconnexion en l'appliquant à d'autres types de données.

Mots Clef

vaisseaux sanguins, segmentation, reconnexion, apprentissage profond, approche variationnelle

Abstract

The segmentation of blood vessels is a challenging task as they are thin, connected and tortuous. Deep learning approaches have been developed to tackle this issue, but they require a large annotated dataset for each new application of interest, which is very challenging to build for vascular networks. In this work, rather than learning the segmentation task, we propose to learn a reconnecting regularization term. Therefore, this term generalizes better than deep learning segmentation models, and can be easily plugged

into variational segmentation frameworks to detect vascular networks in different datasets without requiring annotations. We show that our approach better preserves the connectivity of vascular networks than classic regularization terms in the literature. Finally, we illustrate the generalization power of our reconnecting term by applying it to another type of data.

Keywords

blood vessel segmentation, reconnection, deep learning, variational approach

1 Introduction

La détection des vaisseaux sanguins en imagerie médicale est la première tâche fondamentale dans la plupart des outils d'analyse des vaisseaux sanguins qui permettent d'aider les cliniciens à poser un diagnostic et traiter les pathologies cardio-vasculaires. Même si la segmentation automatique des vaisseaux a été étudiée depuis plus de vingt ans, celle-ci est toujours un problème ouvert du fait des particularités de ces structures. En effet, les vaisseaux sont fins, connectés, tortueux, épars dans l'image et faiblement contrastés. Dans ce papier, nous souhaitons proposer une méthode de segmentation de vaisseaux sanguins permettant de préserver la connectivité des structures traitées. Conserver la connectivité des réseaux vasculaires est un enjeu crucial car il s'agit d'une propriété essentielle dans la plupart des applications cliniques comme la modélisation des réseaux vasculaires ou la simulation de flux sanguin.

Des travaux antérieurs se sont intéressés à ce problème, comme les stratégies de *tracking* (voir [12] Section 7), qui préservent intrinsèquement la connectivité des vaisseaux sanguins en ajoutant les pixels voisins de manière récursive. Cependant, cette approche nécessite d'être initialisée avec des informations manuelles. D'autres méthodes évaluent l'orientation locale des vaisseaux sanguins afin de guider la segmentation en fonction de la direction des vaisseaux [11, 16].

*This work was supported by the LABEX PRIMES (ANR-11-LABX-0063) of Université de Lyon, and by the IDEXLYON project within the program "Investissements d'Avenir" (ANR-11-IDEX-0007 and ANR-16-IDEX-0005) operated by the French National Research Agency (ANR).




FIGURE 1 – Pipeline de notre méthode. Un réseau reconnecteur est dans un premier temps entraîné sur un jeu de données séparé en utilisant un U-Net résiduel. Une segmentation par approche variationnelle est ensuite appliquée en utilisant l’attache aux données de Chan *et al.* [2]. Notre terme de régularisation est soit composé de la variation totale seule, soit de la somme de la variation totale et de notre terme reconnecteur appris (cf. Algorithme 1).

Récemment, des méthodes basées sur l’apprentissage profond ont été proposées pour segmenter des structures vasculaires. Certaines ont pour but de renforcer la connectivité des vaisseaux en utilisant une fonction de coût topologique [4] ou en prédisant à la fois la segmentation mais aussi la ligne centrale des vaisseaux à l’aide du même réseau [15]. Ces stratégies montrent des résultats intéressants, mais nécessitent de larges jeux de données annotées pour fournir de bons résultats.

Au contraire, les stratégies de segmentation par approche variationnelle ne nécessitent aucune donnée annotée, mais sont moins flexibles pour représenter des informations complexes telles que la connectivité. Pour combiner les atouts des différentes méthodes, les approches découplées [3] ont été proposées. Elles consistent en l’injection d’un opérateur externe pour agir en tant que terme de régularisation dans un schéma d’optimisation variationnel. Des premiers travaux ont utilisé des algorithmes de débruitages tels que *BM3D* ou *Non Local Means* [5] pour remplacer la Variation Totale (VT) classiquement utilisée comme terme de régularisation. Par la suite, ces termes de régularisation ont été remplacés par un réseau de neurones entraîné [8, 10] pour profiter de la puissance de représentation de l’apprentissage profond.

Dans ce papier, nous proposons d’apprendre un terme de régularisation ayant pour but de préserver la connectivité des structures vasculaires. Une fois appris, ce terme peut être injecté dans un schéma d’optimisation variationnelle pour diverses applications telles que la segmentation ou le débruitage et ne requiert donc aucune donnée annotée. Nous montrons que notre terme de régularisation conserve mieux la connectivité des vaisseaux sanguins que les termes de régularisation classiques tels que la VT, ou encore des termes plus complexes tels que la VT directionnelle.

2 Apprentissage d’un terme reconnecteur

Nous proposons l’apprentissage d’un réseau reconnecteur en entraînant un modèle à reconnecter des vaisseaux san-

guins à partir d’images contenant des déconnexions artificielles. Ce réseau prend en entrée une image binaire des vaisseaux déconnectés et en sortie l’image binaire des vaisseaux reconnectés. Nous avons choisi de travailler avec des images binaires pour deux raisons. Premièrement, les images binaires facilitent la création de déconnexions réalistes. Deuxièmement, étant donné que notre but est d’apprendre un terme reconnecteur indépendant du jeu de données, apprendre un terme à partir d’images binaires permet de ne pas apprendre les variations d’intensités liées à une modalité ou à un organe spécifique, mais seulement de se baser sur des considérations géométriques partagées par toute image contenant des vaisseaux sanguins.

Dans un premier temps, nous avons créé un algorithme afin de simuler des déconnexions réalistes. Ces dernières sont créées aléatoirement dans les vaisseaux avec une probabilité dépendante de leurs épaisseurs : plus le vaisseau est fin, plus il a de chance d’être déconnecté. Pour reproduire l’effet du bruit dans les données, la forme de la déconnexion est aléatoire. Enfin, des artefacts sont ajoutés pour aider le modèle à distinguer les parties de vaisseaux qui doivent être connectées, du bruit qui ne devrait pas faire partie de la structure vasculaire. Un exemple de jeu de données créé est présenté dans la Figure 1.

Pour apprendre le terme reconnecteur, nous avons choisi d’utiliser le U-Net résiduel [7] de la librairie Monai¹ car l’efficacité du U-Net a été prouvée pour les applications médicales. De plus, l’utilisation des boucles résiduelles renforce sa robustesse aux variations dans les données. 20 segmentations manuelles du jeu de données STARE [6] sont utilisées pour créer des paires d’images contenant des structures vasculaires connectées et déconnectées pour apprendre le terme de régularisation reconnecteur. Nous faisons une augmentation de données en appliquant 4 rotations et en créant des déconnexions différentes avec notre algorithme pour chaque image. Nous obtenons ainsi un jeu de données de 80 images. 2 images sont gardées pour la validation et le reste des images est utilisé pour l’entraînement. Pour éviter l’apprentissage de la structure globale de l’arbre vasculaire, le réseau est appris sur des patches de

1. <https://monai.io/start.html>

taille 96×96 . De plus, des rotations et des symétries sont appliquées aléatoirement à chaque patch et à chaque epoch pour augmenter la variabilité et éviter le surapprentissage. Le réseau est entraîné sur 1000 epochs avec une taille de batch de 64, un optimiseur d'Adam, un pas d'apprentissage de 10^{-3} et une fonction de coût Dice.

3 Segmentation des vaisseaux sanguins par approche découplée

3.1 Approche variationnelle

L'application de la segmentation peut être définie comme un problème variationnel consistant en l'optimisation de deux termes d'énergies :

$$\hat{u} = \operatorname{argmin}_{u \in [0,1]^N} E_{\text{data}}(u, f) + \lambda E_{\text{reg}}(u), \quad (1)$$

Avec $f \in \mathbb{R}^N$ l'image initiale, E_{data} le terme d'attache aux données, E_{reg} le terme de régularisation et $\lambda \in \mathbb{R}$ un coefficient de régularisation permettant de pondérer les deux termes d'énergies. La définition de E_{data} dépend de l'application choisie. Pour une segmentation, le terme de Chan *et al.* [2] est souvent utilisé :

$$E_{\text{data}}(u, f) = \langle u, c_f \rangle_F, \quad (2)$$

$$c_f \mapsto (c_1 - f)^2 - (c_2 - f)^2,$$

avec c_1 et c_2 des constantes correspondant aux valeurs moyennes d'intensité du fond et de la forme et $\langle \cdot, \cdot \rangle_F$ le produit de Frobenius.

E_{reg} permet de préciser et sélectionner la solution la plus adéquate parmi l'ensemble des solutions possibles en régularisant et / ou en utilisant des connaissances sur la structure recherchée. Un terme de régularisation bien connu est la Variation Totale (VT) qui permet de réduire le bruit dans l'image étudiée et est définie ainsi :

$$VT(u) = \lambda \|\nabla u\|_{2,1}, \quad (3)$$

Avec $\|\cdot\|_{2,1}$ la norme l_1 de la norme l_2 . Afin de résoudre l'Équation (1) avec l'algorithme *Forward-Backward Primal-Dual* (FBPD) [9], nous reformulons notre problème de segmentation sous la forme :

$$\hat{u} = \operatorname{argmin}_u h(u, f) + g(Lu) + k(u), \quad (4)$$

avec $h(u, f) = \langle u, c_f \rangle_F$, $g(\cdot) = \lambda \|\cdot\|_{2,1}$, $L = \nabla$ l'opérateur gradient et $k(u) = \iota_{u \in [0,1]^N}$ la fonction indicatrice de l'ensemble convexe $[0, 1]^N$. L'algorithme FBPD est ainsi défini par :

$$u_{i+1} = \operatorname{prox}_{\tau k}(u_i - \tau(\nabla h(x_i) + L^T v_i))$$

$$v_{i+1} = \operatorname{prox}_{\sigma g^*}(v_i + \sigma L(2u_{i+1} - u_i)), \quad (5)$$

Avec prox_g l'opérateur *proximal* de g , g^* le conjugué de g , $\tau \in \mathbb{R}^+$ et $\sigma \in \mathbb{R}^+$ des hyperparamètres scalaires.

3.2 Approche découplée

Notre terme reconnecteur permet de traiter des images binaires et retourne des images contenant des structures vasculaires reconnectées. Ainsi, nous proposons d'injecter ce terme comme un opérateur proximal, après un certain nombre d'itérations dans l'algorithme de l'Équation 5, lorsque u est proche d'être une image binaire. Pour cela, nous remplaçons $\operatorname{prox}_{\sigma k}(\cdot)$ par $\Phi(\cdot)$ défini ainsi :

$$\Phi(u) = \begin{cases} \operatorname{prox}_{\sigma k}(u) & \text{si } i < \alpha \\ G_{\text{reco}}(u) & \text{sinon} \end{cases}, \quad (6)$$

avec G_{reco} le terme reconnecteur appris, $\alpha \in \mathbb{N}^{+*}$ le numéro de l'itération à partir duquel G_{reco} est appliqué. L'Algorithme 1 présente notre approche.

Algorithme 1 : Segmentation découplée incluant un terme reconnecteur appris

Data : $\alpha \in \mathbb{N}^{+*}$, $u_0 \in \mathbb{R}^{N^2}$, $v_0 \in \mathbb{R}^{2N^2}$, $(\tau, \sigma) \in]0, +\infty[^2$, $\lambda_n \in]0, +\infty[$

for $n \geq 1$ **do**

$$p_n = (u_n - \tau(\nabla h(u_n) + L^T v_n))$$

if $n < \alpha$ **then**

$$| \quad p_n = \operatorname{prox}_{\iota_{[0,1]}}(p_n)$$

else

$$| \quad p_n = G_{\text{reco}}(p_n)$$

$$q_n = \operatorname{prox}_{\sigma g^*}(v_n + \sigma L(2p_n - u_n))$$

$$| \quad (u_{n+1}, v_{n+1}) = (u_n, v_n) + \lambda_n((p_n, q_n) - (u_n, v_n))$$

4 Résultats expérimentaux

Nous avons appliqué notre approche au jeu de données test de DRIVE [14] composé d'images rétiniennes. Nous avons comparé nos résultats avec le modèle classique de Chan *et al.* [2] et avec un modèle plus récent et complexe : la variation totale directionnelle [11]. Nous avons optimisé les paramètres des différentes méthodes sur le jeu de données d'entraînement de DRIVE et sélectionné les paramètres permettant d'obtenir les meilleurs résultats moyens. Nous avons fixé les paramètres de notre approche expérimentalement à $\alpha = 350$ et $\lambda = 0.005$.

Nous avons évalué quantitativement nos résultats en analysant la sensibilité moyenne (TPR), la spécificité (TNR) ainsi que la précision (ACC) des 20 images du jeu de données test (voir l'Équation 7). Toutes les métriques sont évaluées seulement dans le fond de rétine fourni dans le jeu de données pour avoir une comparaison juste avec la littérature.

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad ; \quad \text{TNR} = \frac{\text{TN}}{\text{TN} + \text{FP}}, \quad (7)$$

$$\text{Acc} = \frac{\text{TN} + \text{TP}}{\text{TP} + \text{TN} + \text{FN} + \text{FP}},$$

avec TP (resp. TN) le nombre de vrais positifs (resp. négatifs), et FP (resp. FN) le nombre de faux positifs (resp.

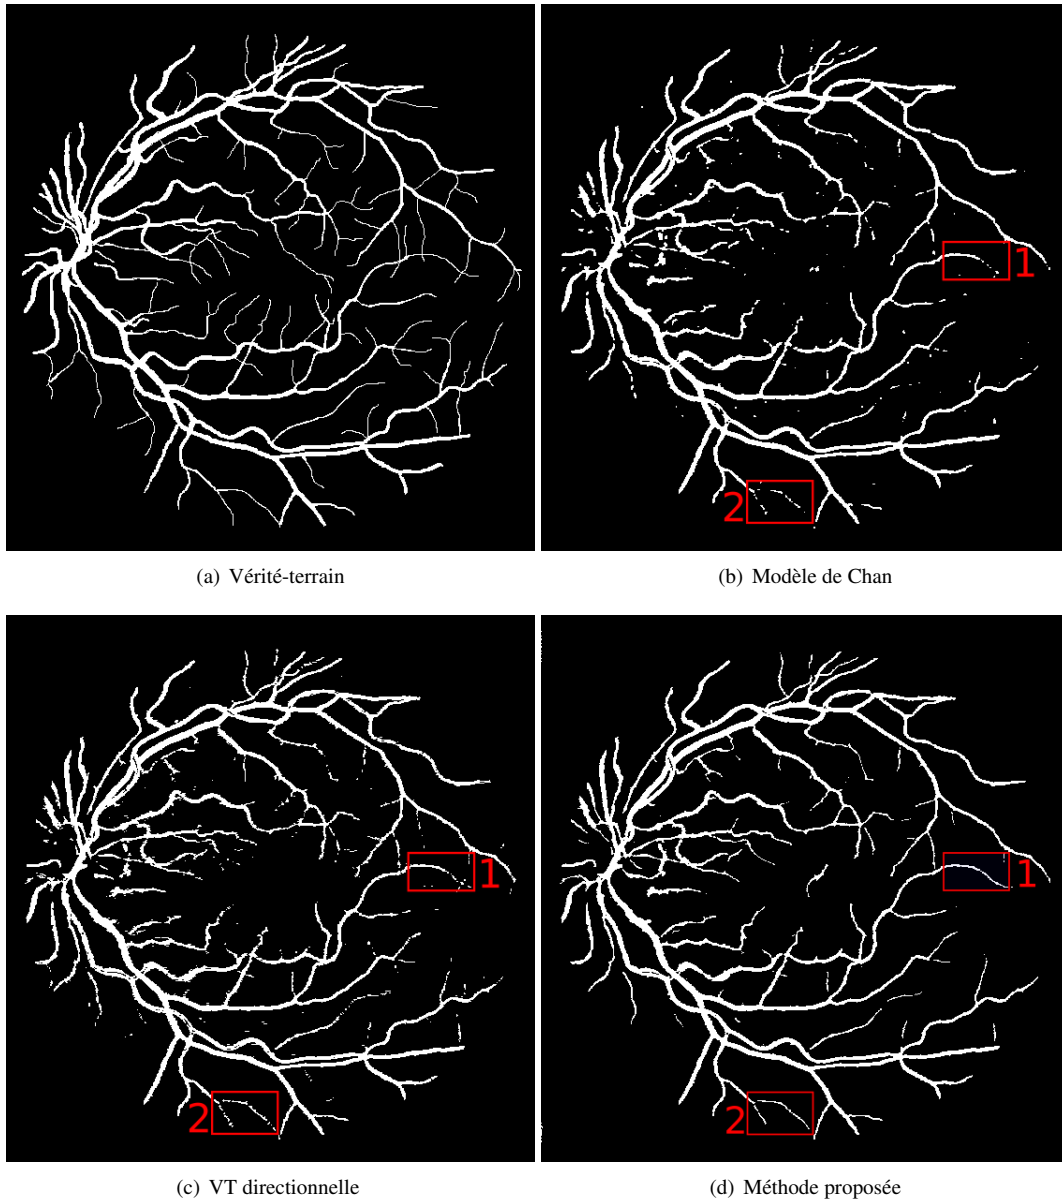



FIGURE 2 – Comparaison des résultats de plusieurs segmentations sur une image du jeu de donnée de DRIVE. Les zooms situés dans les encadrés rouges sont présentés dans la Figure 3



(d) Modèle de Chan (e) VT directionnelle (f) Méthode proposée

FIGURE 3 – Zooms des résultats de la Figure 2. La ligne supérieure correspond à l'encadré 1 et la ligne inférieure à l'encadré 2.

négatifs). Les résultats quantitatifs sont présentés dans le Tableau 4. Nous avons inclus les résultats quantitatifs d'approches récentes basées sur de l'apprentissage profond pour avoir un point de comparaison. Les illustrations des résultats sont présentés dans Fig. 2 et Fig. 3.

Qualitativement, nous observons que notre terme reconecteur augmente la connectivité des structures vasculaires de manière générale. De plus nous obtenons une meilleure connectivité que la variation totale directionnelle. De plus, les vaisseaux sanguins semblent plus lisses que ceux obtenus avec les autres méthodes, ce qui peut être un réel atout pour différentes applications, telles que la modélisation ou les simulations de flux sanguins. Nos résultats présentent aussi moins de bruits, comme il est montré par le TNR. Ce-

pendant, la moyenne du TPR de notre approche est moins élevée que celle de la variation totale directionnelle. Cette dernière approche tend à plus détecter les extrémités du réseau vasculaires, mais de manière très fragmentée. Ces types de détections ne sont cependant pas pertinentes pour les applications nécessitant des réseaux connectés. En revanche, notre approche préserve davantage les vaisseaux connectés : nous avons observé que notre approche détecte en moyenne 230% moins de composantes connexes que la variation totale directionnelle, ce qui veut dire que les bonnes détections sont bien plus connectées que pour celles de la variation totale directionnelle. Ainsi notre approche détecte un nombre moins élevé de vrais positifs, mais présente une meilleure performance quantitative globale et de meilleurs résultats qualitatifs pour des applications nécessitant des structures connectées. En complément, nous fournissons des résultats quantitatifs d'une approche basée sur l'apprentissage profond récente [1] comme base de référence. Ces approches sont entraînées avec des images issues de la même base de données, ce qui permet donc d'obtenir de meilleurs résultats. Cependant, ces méthodes se généralisent difficilement sur des nouvelles données (*i.e.* des vaisseaux sanguins issus d'autres organes ou d'autres modalités). Ces techniques doivent être ré-entraînées pour chaque nouveau jeu de données, avec les annotations correspondantes.

A contrario, notre approche n'a besoin d'annotation que pour l'apprentissage du terme reconnecteur. Pour montrer la puissance de généralisation de notre méthode, nous avons appliqué le même terme reconnecteur que celui utilisé sur le jeu de données DRIVE sur des images contenant d'autres types de structures vasculaires, ou même non vasculaires mais ayant une apparence similaire. La Figure 4 présente les segmentations obtenues sur deux images différentes. Concernant la segmentation des vaisseaux sur une angiographie, nous observons que, malgré le fait que l'image initiale est différente du jeu de données STARE, notre terme reconnecteur se généralise bien et est capable de reconnecter les vaisseaux alors qu'un modèle U-Net entraîné sur STARE a plus de difficultés à traiter cette image différente. Dans ce cas, il semble que le réseau ne soit pas capable de généraliser la segmentation à des vaisseaux avec des diamètres plus importants que dans STARE. De plus, les artefacts liés à la modalité d'image traitée sont considérés comme des vaisseaux par le U-Net et pas par notre approche découplée. Enfin, nous pouvons appliquer notre terme appris sur des images de vaisseaux sanguins. De la même manière le U-Net entraîné sur STARE généralise moins bien que notre approche.

5 Conclusion

Nous avons développé un terme reconnecteur adapté à la segmentation des vaisseaux sanguins. Ce terme apprend à reconnecter des vaisseaux en prenant en compte leur géo-

métrie au lieu d'apprendre les variations de niveaux de gris d'une image. En injectant ce terme dans un schéma d'optimisation variationnelle, nous sommes capables de mieux préserver la connectivité des vaisseaux sanguins que les termes de régularisation classiques.

Notre approche peut être appliquée à des données différentes que celles utilisées en entraînement du terme reconnecteur et montrer de très bons résultats, contrairement aux approches purement basées sur de l'apprentissage profond qui doivent être ré-entraînées pour chaque nouveau type d'image.

Pour les travaux à venir, le terme reconnecteur sera adapté aux données 3D pour pouvoir segmenter divers réseaux vasculaires en 3D, où les annotations sont beaucoup plus complexes à obtenir. Nous allons aussi modifier l'apprentissage de notre terme reconnecteur afin d'apprendre un opérateur étant la résolvante d'un opérateur maximal monotone afin de garantir la convergence de notre algorithme [13].

Références

- [1] M.E.G. ARIAS, I.P. SANTOS D.M. Borrero et M..J.V. VÁZQUEZ. "A new deep learning method for blood vessel segmentation in retinal images based on convolutional kernels and modified U-Net model". In : *Comp. Methods and Programs in Biomed.* (2021), p. 106081.
- [2] T.F. CHAN, S. ESEDOGLU et M. NIKOLOVA. "Algorithms for finding global minimizers of image segmentation and denoising models". In : *SIAM journal on applied mathematics* 66.5 (2006), p. 1632-1648.
- [3] D. GILTON, G. ONGIE et R. WILLET. "Neumann networks for linear inverse problems in imaging". In : *Trans. on Comp. Imaging* 6 (2019), p. 328-343.
- [4] M. HAFT-JAVAHERIAN et al. "A topological encoding convolutional neural network for segmentation of 3D multiphoton images of brain vasculature using persistent homology". In : *Computer Vision and Pattern Recognition Workshops*. 2020, p. 990-991.
- [5] F. HEIDE et al. "Flexisp : A flexible camera image processing framework". In : *ACM Transactions on Graphics* 33.6 (2014), p. 1-13.
- [6] A.D. HOOVER, V. KOUZNETSOVA et M. GOLDBAUM. "Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response". In : *Trans. on Medical imaging* 19.3 (2000), p. 203-210.
- [7] E. KERFOOT et al. "Left-ventricle quantification using residual U-Net". In : *International Workshop on Statistical Atlases and Computational Models of the Heart*. 2018, p. 371-380.




FIGURE 4 – Illustration de la puissance de généralisation de notre terme reconecteur. La ligne supérieure correspond à la segmentation de vaisseaux sanguins dans une angiographie du foie et la ligne inférieure la segmentation d’une image d’arbre vue du dessus.

TABLE 1 – Résultats quantitatifs des segmentations sur le jeu de données de DRIVE.

	TPR	TNR	Acc
Modèle de Chan[2]	0.6615	0.9833	0.9423
VT directionnelle [11]	0.6822	0.9809	0.9427
Notre approche	0.6631	0.9839	0.9429
Apprentissage profond (Arias <i>et al.</i> [1])	0.8597	0.9690	0.9563

- [8] A. KOFLER et al. “Neural networks-based regularization for large-scale medical image reconstruction”. In : *Physics in Medicine & Biology* 65.13 (2020), p. 135003.
- [9] N. KOMODAKIS et J.C. PESQUET. “Playing with duality : An overview of recent primal-dual approaches for solving large-scale optimization problems”. In : *Signal Processing Magazine* 32.6 (2015), p. 31-54.
- [10] T. MEINHARDT et al. “Learning proximal operators : Using denoising networks for regularizing inverse imaging problems”. In : *International Conference on Computer Vision*. 2017, p. 1781-1790.
- [11] O. MERVEILLE et al. “nD variational restoration of curvilinear structures with prior-based directional regularization”. In : *Trans. on Image Processing* (2019), p. 3848-3859.
- [12] S. MOCCIA et al. “Blood vessel segmentation algorithms—review of methods, datasets and evaluation metrics”. In : *Comp. methods and programs in biomed.* 158 (2018), p. 71-91.
- [13] J.C. PESQUET et al. *Learning Maximally Monotone Operators for Image Recovery*. 2021. arXiv : 2012.13247.
- [14] J. STAAL et al. “Ridge-based vessel segmentation in color images of the retina”. In : *Trans. on Medical Imaging* 23.4 (2004), p. 501-509.
- [15] G. TETTEH et al. “Deepvesselnet : Vessel segmentation, centerline prediction, and bifurcation detection in 3-d angiographic volumes”. In : *Frontiers in Neuroscience* 14 (2020).
- [16] A. WU et al. “Deep vessel tracking : A generalized probabilistic approach via deep learning”. In : *International Symposium on Biomedical Imaging*. IEEE. 2016, p. 1363-1367.