



HAL
open science

Une combinaison de filtres de rehaussement des vaisseaux avec des architectures 3D U-Net pour la segmentation des vaisseaux hépatiques

Abir Affane, Antoine Vacavant, Marie-Ange Lebre, Jonas Lamy

► To cite this version:

Abir Affane, Antoine Vacavant, Marie-Ange Lebre, Jonas Lamy. Une combinaison de filtres de rehaussement des vaisseaux avec des architectures 3D U-Net pour la segmentation des vaisseaux hépatiques. ORASIS 2021, Centre National de la Recherche Scientifique [CNRS], Sep 2021, Saint Ferréol, France. hal-03339670

HAL Id: hal-03339670

<https://hal.science/hal-03339670v1>

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.

Combinaison de filtres de rehaussement des vaisseaux avec des architectures 3-D U-Net pour la segmentation des vaisseaux hépatiques

Abir Affane*, Jonas Lamy†, Marie-Ange Lebre*, Antoine Vacavant*

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

† Université Lyon 2, LIRIS (UMR 5205), Lyon, France

Email : abir.affane@uca.fr, jonas.lamy@univ-lyon2.fr, m-ange.lebre@uca.fr, antoine.vacavant@uca.fr

Résumé

La segmentation des vaisseaux hépatiques est une tâche très difficile en raison de la petite taille et de la complexité du réseau vasculaire. Dans cet article, nous proposons une étude comparative originale de plusieurs modèles d'apprentissage profond combinés à des filtres de rehaussement (algorithmes Jerman, Frangi, Sato et RORPO) comme étape de prétraitement. Les modèles 3-D U-Net, 3-D Dense U-Net et 3-D MultiRes U-Net ont été testés sur des images tomodensitométriques pour extraire les réseaux vasculaires avec et sans prétraitement sur des volumes hépatiques complets et sur des slabs (groupes de coupes 2-D). Les modèles ont été testés sur la base de données publique IRCAD et le 3-D Dense U-Net a obtenu le meilleur coefficient Dice sur les données prétraitées (avec le filtre Jerman en particulier), par rapport aux données brutes. En plus de cette analyse numérique, nous proposons une inspection visuelle des résultats de segmentation, qui confirment la précision de ce modèle profond basé sur des filtres de rehaussement vasculaire.

Mots Clef

Segmentation d'images médicales, apprentissage en profondeur, vaisseaux hépatiques, imagerie 3D, U-Net, tomodensitométrie

Abstract

Liver vessel segmentation is a challenging task due to the small size and sparsity of those complex vascular structures. In this paper, we propose an original comparative study of several deep learning models combined with vesselness filters (Jerman, Frangi, Sato and RORPO algorithms) as preprocessing step. 3-D U-Net, 3-D Dense U-Net, and 3-D MultiRes U-Net have been tested on CT-scans to extract the vascular networks with and without preprocessing on full liver volumes and on slabs (stacks of 2-D slices). The models were evaluated on publicly available IRCAD database, and the 3-D Dense U-Net achieved the best Dice score on preprocessed data (with Jerman filter in particular), compared to raw data. In addition to this numerical analysis, we propose a visual inspection of segmentation outcomes, which confirm the accuracy of this deep learning model based on vesselness filters.

Keywords

Medical image segmentation, Deep learning, Liver vessels, 3-D imaging, U-Net, CT-scan

1 Introduction

La segmentation d'image médicale est un processus qui partitionne une image en régions d'intérêt (organes, lésions, etc.). Les troubles des vaisseaux sanguins hépatiques résultent généralement d'un flux sanguin insuffisant venant ou sortant du foie, induit par la cirrhose et d'autres pathologies hépatiques (carcinome hépatocellulaire - CHC par exemple). Pour aider les experts dans leurs diagnostics et la planification des traitements liés à ces maladies, une méthode précise de segmentation des vaisseaux est nécessaire en pratique clinique, quelles que soient les modalités d'images utilisées comme la TDM (Tomodensitométrie) ou l'IRM (Imagerie par Résonance Magnétique) par exemple. Avec l'arrivée du Deep Learning (DL) ces dernières années, des méthodes de segmentation des vaisseaux ont été développées avec des réseaux DL sur différentes modalités d'imagerie. L'article [19] a proposé une méthode DL basée sur une prédiction préliminaire des vaisseaux hépatiques. Les auteurs de [20] ont développé une approche TopNet, qui est une architecture DL multi-tâches pour la reconstruction des vaisseaux en utilisant des paramètres topologiques. [21] ont proposé une approche DL de segmentation automatique des vaisseaux en utilisant une classification binaire basée sur des patches d'entraînement extraits des trois plans : sagittal, coronaire et transversal, issues d'images IRM. Les auteurs de l'article [22] ont utilisé un U-Net avec différentes fonctions de pertes pour une extraction robuste des vaisseaux hépatiques. Dans [7], les auteurs ont introduit une méthode de connectivité pour la segmentation automatique des vaisseaux hépatiques en 3-D dans des images tomodensitométriques. Les auteurs de [25] ont segmenté les vaisseaux à partir d'images IRM abdominales en utilisant une approche adaptative et reconstructive. Les auteurs de l'article [26] ont proposé de combiner un DL avec une analyse anatomique pour la segmentation automatique de la veine porte du foie. Ils ont appliqué un réseau de neurones convolutif (CNN) en utilisant des annotations de référence. Enfin, [27] ont proposé une solution pour la segmentation des vaisseaux hépatiques basée sur

une machine d'apprentissage extrême testée sur des images TDM.

En résumé, les architectures neuronales profondes sont devenues des approches très utiles, avec une précision plus élevée que les techniques conventionnelles, en termes de segmentation d'image basée sur les pixels. En particulier, U-Net [36] et ses extensions, se distinguent comme un modèle de segmentation d'image efficace dans la littérature. L'approche 3-D permet également l'analyse des structures vasculaires, car elle capture les caractéristiques géométriques de ces objets dans les images.

En parallèle, depuis le début du traitement d'images médicales, les algorithmes de rehaussement des vaisseaux sont des techniques largement utilisées pour améliorer les résultats de la segmentation du réseau vasculaire. Récemment, un *benchmark* [9] a comparé sept filtres de rehaussement des vaisseaux publiés ces 20 dernières années dans la littérature sur les images TDM hépatiques pour l'extraction des vaisseaux du foie. Les auteurs ont testé les filtres Sato [1], Frangi [5] et Jerman [6], basés sur des analyses de matrices hessiennes. Ensuite, le filtre de Zhang [7] est une extension de la méthode de Jerman pour les données TDM avec une fonction d'affinité floue améliorée. Un autre filtre nommé RORPO [8] a été proposé (*Ranking the Orientation Responses of Path Operators*), ce dernier est basé sur des opérateurs morphologiques dédiés aux vaisseaux. Ce benchmark a montré que tous ces filtres peuvent être utiles pour améliorer la segmentation des vaisseaux hépatiques et notamment sur les bifurcations.

A notre connaissance, aucune étude comparative basée sur la combinaison de méthodes 3-D DL et des algorithmes de rehaussement des vaisseaux, n'a été proposée dans la littérature pour la segmentation du réseau vasculaire hépatique. Nous proposons donc de combiner différentes architectures U-Net (3-D U-Net, 3-D Dense U-Net et 3-D MultiRes U-Net) avec les quatre meilleurs filtres de rehaussement résultant de l'étude [9], à savoir les algorithmes de Jerman, Sato, Frangi et RORPO. sur des images TDM. Pour une étude complète, nous considérons les volumes 3-D complets ainsi que des *slabs* (groupes de coupes 2-D). Grâce à cette étude comparative, nous montrons que l'utilisation de filtres de rehaussement comme étape de prétraitement améliore significativement la précision des modèles DL pour cette tâche de segmentation.

Notre étude est organisée comme suit. Tout d'abord, nous présentons notre matériel, et nous décrivons l'architecture 3-D U-Net appliquée pour la segmentation des vaisseaux hépatiques dans la section 2. Nous décrivons également deux extensions : les architectures 3-D Dense U-Net et 3-D MultiRes U-Net, qui ont été implémentées sur la base de [4]. Ensuite, dans la section 3, nous comparons les résultats de ces différents modèles, avec ou sans rehaussement de vaisseaux comme étape de prétraitement. Une discussion des résultats s'ensuit. Enfin, nous concluons et donnons des pistes de réflexion pour la suite de ces travaux dans la section 4.

2 Matériel et méthodes

2.1 Prétraitement et analyse des données

Nous utilisons l'ensemble des données publiques IRCAD [37], composées de 20 images CT scans (10 femmes et 10 hommes), au format DICOM avec un nombre variable de coupes ($512 \times 512 \times Z$ voxels) avec des tumeurs hépatiques dans 75 % des cas. Des masques binaires de la vérité terrain du système veineux, réalisés par des radiologues, sont présents pour 19 des 20 patients.

Selon la technique d'imagerie médicale, le GPU disponible joue un rôle important dans la segmentation 3D. Par exemple, avec du matériel informatique standard, il n'est pas possible d'entraîner les modèles CNN ou U-Net sur des images 3D entières d'une taille de $512 \times 512 \times Z$ voxels en raison des énormes besoins en mémoire du GPU ; nous avons donc décidé de redimensionner les données à $256 \times 256 \times Z$. Aussi, les données d'imagerie médicale 3-D peuvent être découpées en petits morceaux d'images, également appelés *slabs*, de $512 \times 512 \times 10$ coupes avec un batch size plus élevé. Il est à noter que nous n'avons utilisé aucun processus d'augmentation des données dans notre étude.

La segmentation des vaisseaux repose souvent sur une étape de rehaussement des vaisseaux, aussi nous décidons dans notre étude de combiner cet étape avec nos modèles DL. Nous avons choisi les quatre meilleurs filtres issus de l'article [9] : Jerman [6], Sato [1], Zhang [23] et RORPO [8].

2.2 Combinaison des filtres de rehaussement avec des architectures DL 3-D

L'architecture 3-D U-Net se compose d'un chemin de contraction pour capturer le contexte et d'un chemin d'extension symétrique qui permet une localisation précise des caractéristiques de l'image. La première partie (encodeur) est similaire à un CNN traditionnel comme nous le ferions pour les tâches de classification, puis les couches de sur-échantillonnage (dans le décodeur) sont utilisées pour générer la sortie sous forme d'image. La concaténation entre les couches codeur et décodeur permet une meilleure précision en ce qui concerne l'alignement du masque de segmentation sur les images originales.

Le réseau 3-D Dense U-Net est basé sur l'implémentation 3-D U-Net originale avec des interconnexions résiduelles supplémentaires entre les couches, basées sur le modèle [4]. Nous avons également testé les interconnexions multi-résiduelles (MultiRes) et denses au réseau U-Net de segmentation. Par conséquent, nous avons utilisé le 3-D MultiRes U-Net, développé par [38]. Dans ce modèle, la séquence de quatre couches convolutives a été remplacée par des blocs 3-D MultiRes. Dans ces blocs, nous commençons par utiliser des filtres convolutifs de $3 \times 3 \times 3$ et $5 \times 5 \times 5$ et en concaténant les *feature maps* générées. Ensuite, nous factorisons des filtres $5 \times 5 \times 5$ et $7 \times 7 \times 7$ plus grands, où nous avons augmenté progressivement le nombre de

filtres dans les quatre couches successives et ajouté une connexion résiduelle. Les modèles ont été implémentés avec les bibliothèques de réseaux neuronaux *open source* Keras et Tensorflow [33, 32]. Nous avons configuré les modèles proposés en suivant les paramètres présentés dans le Tableau 1.

TABLE 1 – Paramètres des modèles sur les slabs et le volume complet

Paramètres	3-D U-Net	3-D MultiRes U-Net	3-D Dense U-Net
Nombre de filtres	128	32	32
Epochs	200	100	200
Dropout	0.2	0.2	–
Batch size (slabs)	8	8	8
Batch size (complet)	1	1	1
profondeur	4	4	4
Normalisation des batchs	vrai	vrai	vrai
Momentum	0.99	0.99	0.99

Les trois architectures proposées ont été testées sur des volumes complets de foie et des slabs, avec et sans application des filtres de rehaussement des vaisseaux. Nous évaluons ainsi les performances de chaque modèle et l’impact de chaque filtre sur les résultats de la segmentation du réseau vasculaire hépatique.

3 Résultats et discussion

3.1 Méthode d’évaluation

Nous avons évalué nos modèles en sélectionnant de façon aléatoire les données (prétraitées ou non) distribuées à partir de la base de données IRCAD en trois ensembles : entraînement, validation et test ; soit 70 % - 20 % - 10 % respectivement. Nous avons utilisé la méthode de validation croisée.

Les performances de chaque modèle ont été évaluées à l’aide de l’ensemble de test (une image 3-D suivant notre distribution). Le coefficient Dice utilisé comme mesure d’évaluation est le suivant :

$$Dice = 2 \frac{|A \cap B|}{|A| + |B|}, \quad (1)$$

où A est l’image segmentée et B est le masque de la vérité terrain de l’image.

3.2 Comparaison des modèles proposés avec rehaussement

Étant donné que le réseau 3-D augmente généralement le déséquilibre entre les voxels correspondants à des vaisseaux et ceux correspondants au fond, nous avons réalisé des modèles avec une fonction perte de Dice pour l’optimisation. Les coefficients Dice obtenus pour chaque donnée et avec chaque réseau potentiellement combiné avec des filtres de vaisseau sont présentés dans les Tableaux 2 et 3. Nous proposons également une inspection visuelle des résultats dans la Figure 1.

TABLE 2 – Résultats du coefficient Dice calculé sur des volumes complets. Les meilleurs scores (supérieurs à 70%) sont en gras.

Prétraitement	3-D U-Net	3-D MultiRes U-Net	3-D Dense U-Net
sans	0.586	0.671	0.694
Filtre Jerman	0.712	0.856	0.835
Filtre RORPO	0.236	0.271	0.334
Filtre Sato	0.512	0.848	0.591
Filtre Zhang	0.201	0.311	0.212

TABLE 3 – Résultats du coefficient dice calculé sur les slabs. Les meilleurs scores (supérieurs à 70%) sont en gras.

Prétraitement	3-D U-Net	3-D MultiRes U-Net	3-D Dense U-Net
sans	0.442	0.498	0.594
Filtre Jerman	0.652	0.701	0.663
Filtre RORPO	0.286	0.242	0.112
Filtre Sato	0.612	0.756	0.597
Filtre Zhang	0.342	0.390	0.223

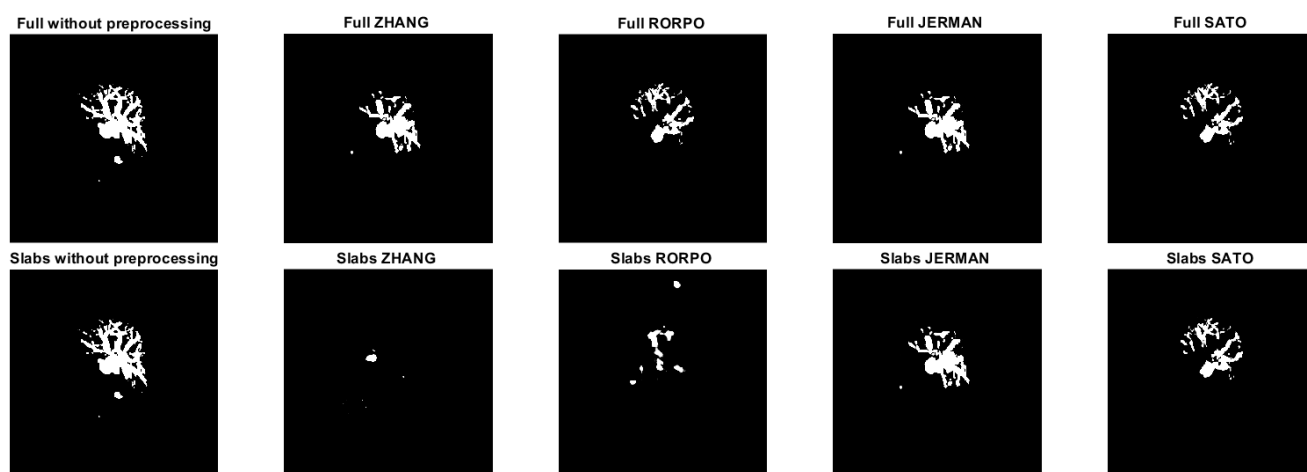
Généralement, la segmentation des vaisseaux est plus précise sur les volumes complets que sur les slabs (voir Figure 1). On remarque également qu’ils sont plus précis après l’utilisation des filtres Sato et Jerman avec une amélioration des coefficients Dice (voir les Tableaux 2 et 3). Avec les données prétraitées à l’aide des filtres Zhang et RORPO, les performances diminuent en particulier sur les slabs et cela peut être dû à la création de bruit lors de l’application de ces filtres.

De plus, on peut remarquer que le 3-D Dense U-Net donne un score Dice sur le volume entier et slabs respectivement de 0,671 et 0,498 sans prétraitement ; 0,856 et 0,701 en utilisant un filtre Jerman ; 0.848 et 0.756 en utilisant le filtre Sato, ce sont les meilleurs scores par rapport à toutes les autres expériences avec 3-D U-Net et 3-D MultiRes U-Net. Nous pouvons en déduire que le 3-D Dense U-Net donne les meilleurs résultats par rapport aux autres modèles avec ou sans filtres de rehaussement des vaisseaux. La Figure 1 confirme ces résultats numériques en montrant que le 3-D Dense U-Net a réussi à segmenter les vaisseaux avec moins de faux négatifs en utilisant les filtres Jerman et Sato.


4 Conclusion

Dans cet article, nous proposons de tester trois architectures 3-D U-Net pour la segmentation des vaisseaux hépatiques en utilisant différents filtres de rehaussement des vaisseaux comme étape de prétraitement. Nous choisissons quatre filtres qui améliorent les contrastes des vaisseaux, évalués dans l’étude [9], à savoir les filtres Zhang, Sato, Jerman et RORPO. Ensuite, nous comparons les résultats obtenus pour trois modèles 3-D U-Net sur les images TDM hépatiques volume entier et sur des slabs d’images.


Nous montrons que le 3-D Dense U-Net avec filtre Jerman



(a) 3-D U-Net



(b) 3-D MultiRes U-Net



(c) 3-D Dense U-Net

FIGURE 1 – Visualisation 2-D des vaisseaux hépatiques par la projection maximale d'intensités pour chaque modèle DL, d'un patient de la base de données IRCAD en utilisant des slabs et un volume hépatique complet

est le plus approprié pour l'extraction des vaisseaux hépatiques sur des images TDM. Il s'agit d'un résultat prometteur pour promouvoir le rehaussement des vaisseaux dans les pipelines DL pour la segmentation du réseau vasculaire hépatique. De plus, sur la base de nos résultats, il est possible d'extraire différents biomarqueurs et de les utiliser pour des expériences cliniques, notamment pour détecter les troubles du foie et des vaisseaux hépatiques. L'architecture proposée peut également être appliquée sur d'autres organes ou vaisseaux.

Dans nos futurs travaux, nous testerons notre méthode sur différentes modalités d'imagerie, comme l'IRM. Nous explorerons d'autres paramètres pour les filtres de rehaussement de contraste des vaisseaux. De plus, nous étudierons la combinaison des modèles DL avec d'autres caractéristiques d'image pour améliorer la réponse pour les bifurcations des vaisseaux et réduire les faux positifs et négatifs. Nous envisagerons également d'explorer des bases de données plus volumineuses pour améliorer les performances de nos modèles.

Références

- [1] Sato, Yoshinobu and Nakajima, Shin and Atsumi, Hideki and Koller, Thomas and Gerig, Guido and Yoshida, Shigeyuki and Kikinis, Ron, *3D multi-scale line filter for segmentation and visualization of curvilinear structures in medical images*, *Journal de Springer*, pp. 213–222, 1997
- [2] Meijering, Erik and Jacob, Mathews and Sarria, J-CF and Steiner, Pascal and Hirling, Harald and Unser, Michael, *Neurite tracing in fluorescence microscopy images using ridge filtering and graph searching : principles and validation*, *IEEE ISBI*, pp. 1219–1222, 2004 IEEE
- [3] Law, Max WK and Chung, Albert CS, *Three dimensional curvilinear structure detection using optimally oriented flux*, *Springer*, pp. 368–382, 2008 ECCV
- [4] Müller, Dominik and Kramer, Frank, *MIScnn : a framework for medical image segmentation with convolutional neural networks and deep learning*, *BMC Medical Imaging*, Vol. 21, pp. 1–11, 2021, BioMed Central
- [5] Frangi, Alejandro F and Niessen, Wiro J and Vinken, Koen L and Viergever, Max A, *Multiscale vessel enhancement filtering*, *Springer*, pp. 130–137, 1998, MICCAI
- [6] Jerman, Tim and Pernus, Franjo and Likar, Bostjan and Spiclin, Ziga, *Enhancement of vascular structures in 3D and 2D angiographic images*, *IEEE T-MI*, pp. 2107–2118, 2016 IEEE
- [7] Zhang, Rui and Zhou, Zhuhuang and Wu, Weiwei and Lin, Chung-Chih and Tsui, Po-Hsiang and Wu, Shuicai, *An improved fuzzy connectedness method for automatic three-dimensional liver vessel segmentation in CT images*, *J Healthc Eng*, vol. 2018, 2018 Hindawi
- [8] Merveille, Odyssee and Talbot, Hugues and Najman, Laurent and Passat, Nicolas, *Curvilinear structure analysis by ranking the orientation responses of path operators*, *IEEE TPAMI*, vol. 40, pp. 304–317, 2017 IEEE
- [9] Lamy, Jonas and Merveille, Odyssee and Kerautret, Bertrand and Passat, Nicolas and Vacavant, Antoine, *Vesselness filters : A survey with benchmarks applied to liver imaging*, *ICPR*, 2020 ICPR
- [10] Zeng, Ye-zhan and Liao, Sheng-hui and Tang, Ping and Zhao, Yu-qian and Liao, Miao and Chen, Yan and Liang, Yi-xiong, *Automatic liver vessel segmentation using 3D region growing and hybrid active contour model*, *Elsevier*, vol. 97, pp. 63–73, 2018 CBM
- [11] Chung, Minyoung and Lee, Jeongjin and Chung, Jin Wook and Shin, Yeong-Gil, *Accurate liver vessel segmentation via active contour model with dense vessel candidates*, *Elsevier*, vol. 166, pp. 61–75, 2018 CMPB
- [12] Lu, Siyu and Huang, Hui and Liang, Ping and Chen, Gang and Xiao, Liang, *Hepatic vessel segmentation using variational level set combined with non-local robust statistics*, *Elsevier*, vol. 36, pp. 180–186, 2017, Magnetic resonance imaging
- [13] Cheng, Yuanzhi and Hu, Xin and Wang, Ji and Wang, Yadong and Tamura, Shinichi, *Accurate vessel segmentation with constrained B-snake*, *IEEE TIP*, vol. 24, pp. 2440–2455, 2015 IEEE
- [14] Shang, Yanfeng and Deklerck, Rudi and Nyssen, Edgard and Markova, Aneta and de Mey, Johan and Yang, Xin and Sun, Kun, *Vascular active contour for vessel tree segmentation*, *IEEE TBME*, vol. 58, pp. 1023–1032, 2010 IEEE
- [15] Guo, Xiaoyu and Xiao, Ruoxiu and Zhang, Tao and Chen, Cheng and Wang, Jiayu and Wang, Zhiliang, *A novel method to model hepatic vascular network using vessel segmentation, thinning, and completion*, *Springer*, pp. 1–16, 2020 MBEC
- [16] Nazir, Anam and Cheema, Muhammad Nadeem and Sheng, Bin and Li, Ping and Kim, Jinman and Lee, Tong-Yee, *Living Donor-Recipient Pair Matching for Liver Transplant via Ternary Tree Representation with Cascade Incremental Learning*, *IEEE Transactions on Biomedical Engineering*, 2021 IEEE
- [17] Yan, Qingsen and Wang, Bo and Zhang, Wei and Luo, Chuan and Xu, Wei and Xu, Zhengqing and Zhang, Yanning and Shi, Qinfeng and Zhang, Liang and You, Zheng, *An Attention-guided Deep Neural Network with Multi-scale Feature Fusion for Liver Vessel Segmentation*, *IEEE JBHI*, 2020 IEEE
- [18] Thomson, Bart R and Nijkamp, Jasper and Ivashchenko, Oleksandra and van der Heijden, Ferdinand and Smit, Jasper N and Kok, Niels FM and Kuhlmann, Koert FD and Ruers, Theo JM and Fusaglia, Matteo, *Hepatic vessel segmentation using a reduced*

- filter 3D U-Net in ultrasound imaging, arXiv preprint arXiv :1907.12109*, 2019
- [19] Xu, Minfeng and Wang, Yu and Chi, Ying and Hua, Xiansheng, *Training liver vessel segmentation deep neural networks on noisy labels from contrast CT imaging, ISBI*, pp. 1552–1555, 2020 IEEE
- [20] Keshwani, Deepak and Kitamura, Yoshiro and Ihara, Satoshi and Iizuka, Satoshi and Simo-Serra, Edgar, *TopNet : Topology Preserving Metric Learning for Vessel Tree Reconstruction and Labelling, Springer*, pp. 14–23, 2020 MICCAI
- [21] Kitrongsakul, Titinunt and Han, Xian-Hua and Iwamoto, Yutaro and Lin, Lanfen and Foruzan, Amir Hossein and Xiong, Wei and Chen, Yen-Wei, *Vessel-Net : A deep convolutional neural network with multi pathways for robust hepatic vessel segmentation, Elsevier*, vol,75, pp. 74–83, 2019 CMIG
- [22] Huang, Qing and Sun, Jinfeng and Ding, Hui and Wang, Xiaodong and Wang, Guangzhi, *Robust liver vessel extraction using 3D U-Net with variant dice loss function, Elsevier*, vol,101, pp. 153–162, 2018 CBM
- [23] Zhang, Rui and Zhou, Zhuhuang and Wu, Weiwei and Lin, Chung-Chih and Tsui, Po-Hsiang and Wu, Shuicai, *An improved fuzzy connectedness method for automatic three-dimensional liver vessel segmentation in CT images, Hindawi*, vol,2018, 2018 J Healthc Eng
- [24] Mishra, Deepak and Chaudhury, Santanu and Sarkar, Mukul and Manohar, Sidharth and Soin, Arvinder Singh, *Segmentation of vascular regions in ultrasound images : A deep learning approach, IEEE TBME*, pp. 1–5, 2018 ISCAS
- [25] Gocer, Evgin and Shah, Zarine K and Gurcan, Metin N, *Vessel segmentation from abdominal magnetic resonance images : adaptive and reconstructive approach, Wiley Online Library*, vol,33, pp. e2811, 2017 ,International journal for numerical methods in biomedical engineering
- [26] Ibragimov, Bulat and Toesca, Diego and Chang, Daniel and Koong, Albert and Xing, Lei, *Combining deep learning with anatomical analysis for segmentation of the portal vein for liver SBRT planning, IOP Publishing*, vol,62, 2017 ,Physics in Medicine & Biology
- [27] Zeng, Ye Zhan and Zhao, Yu Qian and Liao, Miao and Zou, Bei Ji and Wang, Xiao Fang and Wang, Wei, *Liver vessel segmentation based on extreme learning machine, Elsevier*, vol,32, pp. 709–716, 2016 ,Physica Medica
- [28] Wang, Lei and Schnurr, Alena-Kathrin and Zidowitz, Stephan and Georgii, Joachim and Zhao, Yue and Razavi, Mohammad and Schwier, Michael and Hahn, Horst K and Hansen, Christian, *Segmentation of hepatic artery in multi-phase liver CT using directional dilation and connectivity analysis, Wiley Online Library*, vol,9785, pp. 97851P, 2016 ,Medical Imaging 2016 : Computer-Aided Diagnosis
- [29] Oliveira, Dário AB and Feitosa, Raul Q and Correia, Mauro M, *Segmentation of liver, its vessels and lesions from CT images for surgical planning, BioMed Central*, vol,10, pp. 1–23, 2011 ,Biomedical engineering online
- [30] Bruyninckx, Pieter and Loeckx, Dirk and Vandermeulen, Dirk and Suetens, Paul, *Segmentation of liver portal veins by global optimization, International Society for Optics and Photonics*, vol,7624, pp. 76241Z, 2010 ,Medical Imaging 2010 : Computer-Aided Diagnosis
- [31] Chollet, François, *Xception : Deep learning with depthwise separable convolutions, IEEE CVPR*, pp. 1251–1258, 2017 ,IEEE
- [32] Chollet, François, *Deep Learning with Python, Manning*, 2017 ,9781617294433
- [33] Abadi, Martín and Agarwal, Ashish and Barham, Paul and Brevdo, Eugene and Chen, Zhifeng and Citro, Craig and Corrado, Greg S and Davis, Andy and Dean, Jeffrey and Devin, Matthieu and others, *Tensorflow : Large-scale machine learning on heterogeneous distributed systems*, 2016 ,arXiv preprint arXiv :1603.04467
- [34] AFFANE, Abir and LEBRE, Marie-Ange and MITTAL, Utkarsh and VACAVANT, Antoine, *Literature Review of Deep Learning Models for Liver Vessels Reconstruction, IEEE*, pp. 1–6, 2020 ,IEEE ,IPTA
- [35] Long, Jonathan and Shelhamer, Evan and Darrell, Trevor, *Fully convolutional networks for semantic segmentation, IEEE CVPR*, pp. 3431–3440, 2015 ,IEEE
- [36] O. Ronneberger and P. Fischer and T. Brox, *U-Net : Convolutional Networks for biomedical image segmentation, MICCAI*, 2015 ,MICCAI
- [37] IRCAD, *3D Image Reconstruction for Comparison of Algorithm Database, Hôpitaux Universitaires, Strasbourg, France*, vol,10, pp. 1–23, 2011 ,<https://www.ircad.fr/research/3dircadb/>
- [38] Ibtehaz, Nabil and Rahman, M Sohel, *MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation, Elsevier*, vol,121, pp. 74–87, 2020 ,Neural Networks