

基于深度学习的视网膜病变眼底图视盘自动定位与分割研究\*

杨帆<sup>1,2</sup>, 陈睿诗<sup>1</sup>, 莫阳<sup>1</sup>, 缪月红<sup>1,2</sup>, 段平<sup>3</sup>, 谷浩<sup>3</sup>, 王丽会<sup>4\*\*</sup>

(1. 贵州医科大学 生物与医学工程重点实验室, 贵州 贵阳 550004; 2. 贵州医科大学 生物与工程学院 生物医学工程教研室, 贵州 贵阳 550004; 3. 贵州医科大学附院 眼科, 贵州 贵阳 550004; 4. 贵州大学 计算机科学与技术学院 贵州省智能医学影像分析与精准诊断重点实验室, 贵州 贵阳 550025)

[摘 要] 目的: 研究视网膜病变眼底图像中视盘的自动定位与分割。方法: 收集 Messidor 数据库中 1 200 张眼底图, 其中 900 张用于训练, 300 张用于测试; 采用 2 个深度学习网络分别实现视盘在图像上的精确定位与分割, 采用准确率、Dice 系数、Jaccard 系数、敏感性、特异性指标评估结果。结果: 视盘定位准确率为 100%, 视盘分割准确率为 97.38%, 平均 Dice 系数、Jaccard 系数、敏感性、特异性为 0.919 4、0.854 9、0.995 9、0.970 0, 平均处理时间为 0.25 s。结论: 深度学习方法能够实现高精度的视盘定位及视盘分割, 有助于眼底图像的实时自动分析。

[关键词] 视网膜病变眼底图; 视盘定位; 视盘分割; 深度学习, U-Net

[中图分类号] R774.1 [文献标识码] A [文章编号] 1000-2707(2020)04-0432-06

DOI:10.19367/j.cnki.1000-2707.2020.04.011

Automated Localization and Segmentation of Retinopathy Fundus Map Using Deep Learning

YANG Fan<sup>1,2</sup>, CHEN Ruishi<sup>1</sup>, MO Yang<sup>1</sup>, MIAO Yuehong<sup>1,2</sup>, DUAN Ping<sup>3</sup>, GU Hao<sup>3</sup>, WANG Lihui<sup>4</sup>  
(1. Key Laboratory of Biology and Medical Engineering, Guizhou Medical University, Guiyang 550004, Guizhou, China; 2. Department of Biomedical Engineering, School of Biology and Engineering, Guizhou Medical University, Guiyang 550004, Guizhou, China; 3. Department of Ophthalmology, the Affiliated Hospital of Guizhou Medical University, Guiyang 550004, Guizhou, China; 4. Key Laboratory of Intelligent Medical Image Analysis and Precise Diagnosis of Guizhou Province, School of Computer Science and Technology, Guizhou University, Guiyang 550025, Guizhou, China)

[Abstract] Objective: To investigate the automatic positioning and segmentation of the optic disc in the fundus image of retinopathy. Methods: We collected 1,200 fundus images from the Messidor database, of which 900 image were used for training and 300 images were used for testing. Two deep learning networks were used to achieve precise positioning and segmentation of the video disc on the image. Accuracy, Dice coefficient, Jaccard coefficient, sensitivity and specificity index were used to evaluate results. Results: The accuracy rate of optic disc positioning reached 100%, and the accuracy rate of optic disc segmentation was 97.38%. The average Dice coefficient, Jaccard coefficient, sensitivity, and specificity were 0.919 4, 0.854 9, 0.995 9, and 0.970 0, respectively, and the average processing time was 0.25 s. Conclusion: Deep learning can realize high-precision optic disc positioning and optic disc segmentation, which is helpful for real-time automatic analysis of fundus images.

\*[基金项目] 国家自然科学基金(81660298,61661010); 2017 贵州省大学生创新创业训练计划资助项目(201710660033); 贵州省科学技术基金[黔科合 J 字(2015)2044 号]  
\*\* 通信作者 E-mail:wanglihui0404@126.com

[**Key words**] fundus map of retinopathy; optic disc localization; optic disc segmentation; deep learning, U-Net

目前,视网膜眼底图像已经广泛用于视网膜病变、糖尿病性视网膜病变等诊断。青光眼是视神经受损导致视力下降的一种疾病,一旦发病几乎不可能完全治愈,但是及时的早期诊断及治疗可以有效控制青光眼对视力的影响<sup>[1]</sup>。对于青光眼的诊断,可以通过眼底图中视杯和视盘垂直直径的比值作为诊断指标<sup>[2]</sup>,临床上多采用目测方法得到比值,不同医生得到结果存在差异;为了得到精确比值,可以借助计算机图像处理技术自动实现视盘的定位、视盘及视杯分割,而关键步骤是视盘的定位与分割,以往对视盘定位的方法是假设视盘是图像中最亮的区域,通过寻找最大像素的位置确定视盘<sup>[3]</sup>,但该方法不适合对比度较低的图像。对于视盘分割过去采用水平集方法<sup>[4-5]</sup>,但此类方法对于初始曲线放置位置有较高要求,如果视盘中含有大量血管,算法鲁棒性低。最近几年,深度学习方法被广泛用于医学图像的分割<sup>[6-14]</sup>,其中 U-Net 深度学习法对于医学图像分割有较高的精度<sup>[15-16]</sup>。与过往的方法相比,深度学习法不需要对图像做任何假设和预处理,仅需要提供训练图像和标记图,通过网络训练即可得到较好的分割结果,本研究在此基础上,提出两步 U-Net 网络训练深度学习方法,分别实现视盘的定位及分割。

## 1 材料与方法

### 1.1 主要材料

本文视盘定位数据采用了贵州医科大学附院眼科视网膜病变眼底图,共 915 张。视盘分割数据采用 Messidor 数据库<sup>[17]</sup>,该数据库包含 1 200 张彩色视网膜病变图像,以及每张图像对应的视盘边界标记图。数据库中图像有 3 种尺寸,分别为 1 440 × 960、2 240 × 1 488 及 2 304 × 1 536 像素。

### 1.2 方法

**1.2.1 主要算法流程** 本文算法主要基于 U-Net 网络,其中算法分为 2 步,第 1 步将原图输入 U-Net #1 网络,通过网络训练确定视盘在图像中的位置;第 2 步根据视盘位置提取 80 × 80 的视盘区域图像,输入 U-Net #2 网络用于视盘分割训练,将得到的视盘二值图边界标记在原图实现视盘的分割(图 1)。




图 1 视盘定位与分割算法主要流程

Fig. 1 The flow chart of Optic disk positioning and segmentation algorithm

**1.2.2 U-Net 网络结构** 研究中采用的 U-Net 网络模型呈 U 型结构,主要由卷积层、激活层、池化层、反卷积层等结构组成,图 2 显示了算法第 1 步中的 U-Net #1 网络模型。输入图像为 256 × 256 的彩色图像,除了最后一层卷积层滤波器尺寸为 1 × 1 之外,其余所有卷积层滤波器尺寸为 3 × 3,并且步长(stride)为 1,补零(padding)为 1;此外,3 × 3 卷积层之后添加线性整流激活函数(rectified linear unit, ReLU)<sup>[18]</sup>增加网络模型的非线性。网络中下采样阶段使用的池化层为 2 × 2 的最大池化,上采样阶段使用步长为 2,滤波器尺寸为 2 × 2 的反卷积将图像恢复为输入图像尺寸;然后通过归一化指数函数(softmax)得到每一类像素的概率值,并使用带权重的交叉熵函数计算网络的损失函数值(loss)。U-Net #2 网络模型和第 1 步采用网络模型相同,唯一区别是输入图像为 80 × 80 的视盘区域图像,输出为 80 × 80 的视盘二值图。

**1.2.3 数据处理** 由于 U-Net 网络要求输入图像尺寸相同, Messidor 数据库中的图像通过 Matlab 2018a 软件处理重新插值为 256 × 256 像素。Messidor 数据库中 900 幅用于网络模型训练, 300 幅用于网络模型测试。图 3 分别显示了算法第 1 步和第 2 步中用于训练的眼底图及视盘标记图,其

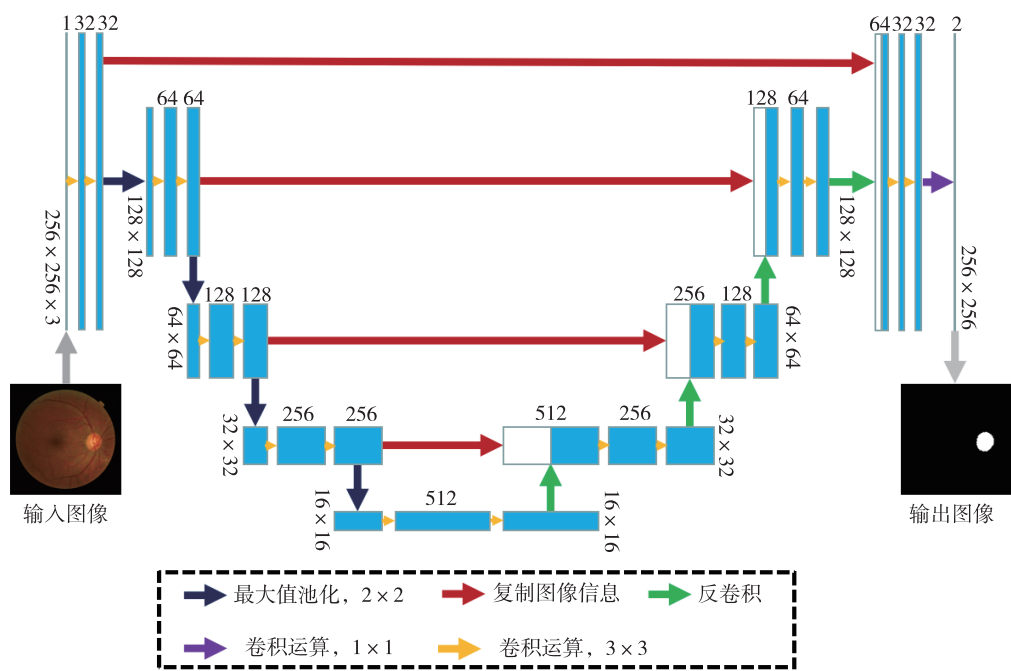



图 2 U-Net #1 网络结构图  
Fig. 2 U-Net #1 network architecture

中第 2 步训练图和标记图是根据第 1 步标记图中视盘中心位置截取 80×80 像素区域而得。标记图中白色区域像素值为 2,黑色背景区域像素值为 1。由于深度学习中需要大量的数据进行网络模型训练,训练集通过水平垂直镜像、旋转、高斯模糊等手段扩增至 14 400 幅图像。因此算法第 1、2 步中实际训练集为 14 400 幅图像。



注:A 为 256×256 像素眼底图,B 为 256×256 像素视盘标记图,C 为 80×80 像素视盘区域图像, D 为 80×80 像素视盘区域标记图。  
图 3 眼底图及视盘标记图

Fig. 3 Fundus image and labeled optic disk image

**1.2.4 实施细节** 第 1 步中 U-Net #1 网络训练每次输入图像为 36 幅,400 次训练完成一个时期(epoch),当 loss 及精度不再增加时停止训练(大约 50 个 epoch);然后使用该训练好的模型检测测试集图像中的视盘位置,截取 80×80 像素视盘区域用于第 2 步中 U-Net #2 网络测试。第 2 步中网络训练同样每次输入 36 幅图像,50 个 epoch 后当 loss 不再降低时停止训练。网络初始学习率为 0.05,每 10 个 epoch 下降为原来 0.2 倍。训练过程中使用深度学习平台为 Matlab 2018a,CPU 为 i7-7700 K,内存 64 g,显卡为 GTX 1080 Ti。

**1.2.5 数据评估方法** 采用了准确率、Dice 系数、Jaccard 系数、敏感性、特异性指标评估实验结果,用真阳性( $TP$ )、真阴性( $TN$ )、假阳性( $FP$ )及假阴性( $FN$ )计算上述指标。计算方法如下:准确率 =  $(TP + TN) / (TP + TN + FP + FN)$ ,Dice 系数 =  $2TP / (2TP + FP + FN)$ ,Jaccard 系数 =  $TP / (TP + FP + FN)$ ,敏感性 =  $TP / (TP + FN)$ ,特异性 =  $TN / (TN + FP)$ 。


## 2 结果

### 2.1 视盘定位及分割

由于本院眼底数据没有提供分割结果,该数据

主要用于视盘定位。915 幅图像全部用于测试,视盘定位准确率为 87.10%。图 4 显示了部分视盘定位准确的图像及其分割结果,图 5 显示了部分未定位视盘图像。此外,对 Messidor 数据库中 300 张


测试图像进行视盘定位,定位准确率为 100%。图 6 显示该数据库部分视盘定位及分割图像,其中绿色十字符号标记了视盘在图像中的位置,蓝色线条为实际分割曲线,绿色线条为真实视盘边界曲线。



注:A 行为视盘定位图像,B 行为对应眼底图视盘分割结果;绿色十字符号标记了视盘在图像中的位置,蓝色线条为实际分割结果。

图 4 医院数据视盘定位及分割结果

Fig. 4 Optic disk localization and segmentation from the hospital's images



注:A 未见视盘,B 低对比度的视盘和眼底背景,C 视盘残缺。

图 5 未定位视盘图像

Fig. 5 Optic disk images without localization

2.2 统计结果

如表 1 所示, Messidor 数据库中 300 幅测试图像视盘分割的平均准确率、Dice 系数、Jaccard 系

数、敏感性、特异性及平均单幅图像处理时间指标,分别为 97.38%、0.919 4、0.854 9、0.995 9、0.970 0 及 0.25 s。


表 1 评估指标统计结果比较

Tab. 1 Comparison of statistic results of evaluation parameters

方法	视盘定位准确率/%	视盘分割准确率/%	Dice 系数	Jaccard 系数	敏感性	特异性	平均处理时间/s
Roychowdhury <sup>[19]</sup>	—	99.56	—	0.837 3	0.904 3	—	—
Kamble <sup>[20]</sup>	99.75	—	—	—	—	—	0.52
Zahoor <sup>[21]</sup>	—	99.18	—	0.844 0	0.889 1	0.997 3	1.30
Sigut <sup>[22]</sup>	99.58	—	0.939 0	0.890 0	—	—	1.28
本文算法	100.00	97.38	0.919 4	0.854 9	0.995 9	0.970 0	0.25

注:“—”表示结果未给出。





注:A 列图像为原图,B 列为 U-Net #1 网络输出结果,C 列为视盘定位图,D 列为 U-Net #2 网络输出结果, E 列为最终分割结果。

图 6 Messidor 数据视盘定位及分割结果

Fig. 6 Optic disk localization and segmentation from Messidor database's images

### 3 讨论

视盘的定位及分割是实现眼底图像自动分析的重要环节,特别是对于青光眼疾病的智能诊断。本文采用深度学习方法对视盘进行定位及分割。对于视盘定位,从医院采集数据定位准确率为 87.10%。部分图像未定位的一个原因是图像中未见视盘、视盘和眼底背景对比度低以及视盘残缺。另外一个原因是研究中采用的训练数据来自 Messidor 数据库,其中数据均含有视盘,且对比度高,没有视盘残缺的情况,因此使用该数据训练的网络模型去测试时,会出现检测不到视盘的情况。进一步改善视盘定位精度,可以通过增加此类数据到训练集中进行网络训练。而 Messidor 数据库中的图像,本文算法视盘定位精度达到 100%,高于其它方法。

对于视盘,在第 1 步视盘精确定位基础上,利用 U-Net #2 网络实现了视盘的分割。从结果可以看出实际分割线条和真实视盘边界曲线相似,分割结果较好。另外从统计结果可以看出,本文算法各项评估指标保持较高水平。虽然视盘分割准确率、Dice 系数、Jaccard 系数略低于文献[22]中的结果,

但敏感性和平均处理时间远高于其它方法。特别是短的处理时间,对于实时处理数据有极大的帮助。此外,研究中只采用了 900 幅图像用于训练,虽然通过图像扩增至 14 400 幅,但对于深度学习方法远远不够,还需要继续增加训练数据。

对于本文算法,主要采用了两个 U-Net 网络。其主要原因是视盘分割属于图像二分类问题(视盘和背景),当样本数据不平衡时,U-Net 网络达不到较高的分割精度。以往可以通过带权重的交叉熵方法解决该问题,但研究中的视盘和背景像素总和差距较大,实验结果精度低。因此通过第 1 步的 U-Net 网络确定一个较小的视盘区域,输入到第 2 个 U-Net 网络中进行测试。通过这种方法可以极大降低背景像素对于视盘分割的影响,从本研究的结果可以看出实际分割曲线和真实曲线几乎重合。

综上所述,本研究采用深度学习方法中的 U-Net 网络分步实现了眼底图中视盘的定位及分割,其视盘定位和视盘分割准确率保存较高的精确度,同时极大缩减了图像处理时间。通过与其它算法比较,证明了本算法的可行性和有效性。课题组将继续扩大训练集,采用新深度学习网络模型提升视盘分割各项评估指标,使其在眼底图像分析,尤其是青光眼智能诊断中发挥其应用价值。

## 4 参考文献

- [1] THAKUR N, JUNEJA M. Survey on segmentation and classification approaches of optic cup and optic disc for diagnosis of glaucoma[J]. Biomedical Signal Processing and Control, 2018, 42:162–189.
- [2] AI-BANDER B, WILLIAMS B M, AI-NUAIMY W, et al. Dense Fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis[J]. Symmetry, 2018, 10(4):1–16.
- [3] WONG D K, LIU J, LIM J H, et al. Level-set based automatic cup-to-disc ratio determination using retinal fundus images in ARGALI[C]. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Vancouver, Canada, 2008, 2008:2266–2269.
- [4] YU H, BARRIGA E S, AGURTO C, et al. Fast localization and segmentation of optic disk in retinal images using directional matched filtering and level sets[J]. IEEE Transactions on Information Technology in Biomedicine, 2012, 16(4):655–657.
- [5] REN F, LI W, YANG J, et al. Automatic optic disc localization and segmentation in retinal images by a line operator and level sets[J]. Technology Health Care, 2016, 24(2):767–776.
- [6] TAN J H, ACHARYA U R, BHANDARY S V, et al. Segmentation of optic disc, fovea and retinal vasculature using a single convolutional neural network[J]. Journal of Computational Science, 2017, 20:70–79.
- [7] SEVASTOPOLSKY A. Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network[J]. Pattern Recognition and Image Analysis, 2017, 27(3):618–624.
- [8] BALAKRISHNAN U. NDC-IVM: An automatic segmentation of optic disc and cup region from medical images for glaucoma detection[J]. Journal of Innovative Optical Health Sciences, 2017, 10(3):1–15.
- [9] FU H, CHENG J, XU Y, et al. Joint optic disc and cup segmentation based on multi-label deep network and polar transformation[J]. IEEE Transactions on Medical Imaging, 2018, 37(7):1597–1605.
- [10] INDRASWARI R, KURITA T, ARIFIN A Z, et al. Multi-projection deep learning network for segmentation of 3D medical images[J]. Pattern Recognition Letters, 2019, 125:791–797.
- [11] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017, 42:60–88.
- [12] LUNDERVOLD A S, LUNDERVOLD A. An overview of deep learning in medical imaging focusing on MRI[J]. Zeitschrift für Medizinische Physik, 2019, 29(2):102–127.
- [13] GIBSON E, LI W, SUDRE C, et al. NiftyNet: a deep-learning platform for medical imaging[J]. Computer Methods and Programs in Biomedicine, 2018, 158:113–122.
- [14] KURATA Y, NISHIO M, KIDO A, et al. Automatic segmentation of the uterus on MRI using a convolutional neural network[J]. Computers in Biology and Medicine, 2019, 114:1–6.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing & Computer Assisted Intervention, 2015, 9351:234–241.
- [16] IBTEHAZ N, RAHMAN M S. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. Neural Networks, 2020, 121:74–87.
- [17] DECENNCIERE E, ZHANG X, CAZUGUEL G, et al. Feedback on a publicly distributed image database: The messidor database[J]. Image Analysis & Stereology, 2014, 33(3):231–234.
- [18] NAIR V, HINTON G E. Rectified linear units improve restricted boltzmann machines[C]. Proceedings of the 27th International Conference on Machine Learning, 2010, 807–814.
- [19] ROYCHOWDHURY S, KOOZEKANANI D D, KUCHINKA S N, et al. Optic disc boundary and vessel origin segmentation of fundus images[J]. IEEE Journal of Biomedical and Health Informatics, 2016, 20:1562–1574.
- [20] KAMBLE R, KOKARE M, DESHMUKH G, et al. Localization of optic disc and fovea in retinal images using intensity based line scanning analysis[J]. Computers in Biology and Medicine, 2017, 87:382–396.
- [21] ZAHOOR M N, FRAZ M M. Fast optic disc segmentation in retina using polar transform[J]. IEEE Access, 2017, 5:12293–12300.
- [22] SIGUT J, NUNEZ O, FUMERO F, et al. Contrast based circular approximation for accurate and robust optic disc-segmentation in retinal images[J]. PeerJ, 2017, 5:e3763.

(2020-01-01 收稿, 2020-03-20 修回)

中文编辑: 吴昌学; 英文编辑: 张启芳