

基于 N-Unet 视网膜血管分割

田红^{1,2} 陈姚节^{1,2,3}

¹(武汉科技大学计算机科学与技术学院 湖北 武汉 430065)

²(智能信息处理与实时工业系统湖北省重点实验室 湖北 武汉 430065)

³(冶金工业过程国家级虚拟仿真实验教学中心 湖北 武汉 430065)

摘要 针对在现阶段视网膜血管分割过程中存在的分支断裂问题,提出一种非局部 Unet 的模型 Non-local Unet(N-Unet)。N-Unet 模型保留了编码器-解码器的对称结构,在编码器阶段引入非局部块,使模型在提取特征的过程中关注非局部信息,能更好地捕捉图像中非相邻像素之间的关系。该模型在公开的 DRIVE 数据集上进行评估,得到的准确性、敏感性、特异性、曲线下面积分别为 0.952 3、0.802 1、0.974 3、0.894 9。实验结果表明,该方法在解决血管分割过程中的分支断裂问题表现良好,具有研究意义。

关键词 Unet 网络 Non-local 血管分割 医学图像

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.04.033

RETINAL VESSEL SEGMENTATION BASED ON N-UNET

Tian Hong^{1,2} Chen Yaojie^{1,2,3}

¹(College of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, Hubei, China)

²(Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial System, Wuhan 430065, Hubei, China)

³(Metallurgical Industry Process National Virtual Simulation Experimental Teaching Center, Wuhan 430065, Hubei, China)

Abstract In order to address the problem of vascular branch breakage existing in the process of retinal vessel segmentation at present, a non-local Unet model (N-Unet) is proposed. The model retained the encoder-decoder symmetric structure, and introduced non-local blocks at the encoder stage, which made the model pay attention to non-local information in the process of feature extraction and better capture the relationship between non-adjacent pixels in the image. This model was evaluated on the public dataset DRIVE, and gained 0.952 3 accuracy, 0.802 1 sensitivity, 0.974 3 specificity, and 0.894 9 AUC, respectively. Experimental results show that this method performs well in solving the problem of branch breakage in the process of blood vessel segmentation, and has research significance.

Keywords Unet network Non-local Blood vessel segmentation Medical image

0 引言

在日常生活中,一些常见的疾病如高血压、糖尿病等都会改变视网膜血管的形态结构^[1],并呈现不同的特征。对视网膜血管图像进行分割,有助于医生诊断患者病情^[2],进行快速准确的治疗。手工分割耗时长,且依赖技术人员的经验^[3],难以保证视网膜血管的分割速度和精度。因此,对视网膜血管进行自动分

割成为研究热点。现有的自动分割技术主要分为两种,分别是无监督分割技术和有监督分割技术。

无监督分割技术不需要标注训练样本,自动学习图像特征。Lahiri 等^[4]提出了一种采用无监督的分层特征来学习两层稀疏训练去噪叠加编码器的集合。Hakim 等^[5]提出在 Unet 网络中使用正则化器,将图像视为血管区域和背景区域两幅图,该方法提取背景像素点的准确率高,但提取血管像素的准确率低。Waly 等^[6]通过结合 Gabor 滤波和设置阈值来分割血管,该

方法的分割结果容易受图像噪声干扰,且受滤波器和阈值参数设置的影响。无监督分割虽然不需要对数据进行标注,便于训练,但是其分割的精度要小于有监督分割的方法,所以现有的工作主要致力于有监督分割方法的研究。

有监督分割技术需要事先标注训练样本,从标注样本中学习模型参数。Li 等^[7]构建了一种新的模型,把血管和背景的分类任务转换成视网膜图像和血管图像的跨模态数据转换任务。Liskowski 等^[8]提出深度神经网络模型,该模型要求在训练之前先对图像进行全局对比度归一化、零相位白化、伽马矫正增强等预处理,从而提取更精确的血管结构。Zhang 等^[9]在 Unet 网络中加入了基于边缘的机制,该机制通过在边界区域上添加其他标签,使网络更关注血管的边界。Zhuang 等^[10]提出了由多个 Unet 网络构成的 Ladder-Net 网络,该网络通过在多个 Unet 间增加信息流路径实现分割精度的提升。Jin 等^[11]提出了一种可变形的 Unet 模型,该模型将可变卷积集成到 Unet 网络中,根据血管的形态自动调节感受野,来捕获不同形态大小的血管。梁礼明等^[12]提出在 Unet 模型中加入空洞卷积核和密集可变卷积的分割方法,该方法可以捕获多尺度信息且在不增加参数的情况下扩大感受野。在血管分割任务中,有监督学习的精确度高于无监督学习的方法^[13]。但上述有监督分割方法需要对图像进行预处理,且扩大感受野的方法都采用局部操作,容易损失图像的特征信息。部分方法的分割效果见表 1。

表 1 不同方法的分割性能对比

方法	Se	Sp	Acc	AUC
Lahiri 等 ^[4]			0.953 0	
Hakim 等 ^[5]	0.706 4	0.989 7	0.953 6	
Li 等 ^[7]	0.756 9	0.981 6	0.952 7	0.973 8
Liskowski 等 ^[8]	0.741 7	0.979 2	0.947 9	0.968 3
Zhang 等 ^[9]	0.753 7	0.982 0	0.953 1	0.975 5
梁礼明等 ^[12]		0.988 3		0.974 8
本文方法	0.813 0	0.974 9	0.954 3	0.976 7

现阶段血管分割任务的缺点在于分割出的血管不够连通,这是因为微小血管容易被忽略以及分支血管容易出现断裂。针对这些问题和上述方法存在的缺陷,本文在传统的 Unet 模型基础上,加入了非局部块,通过增加非局部感受野,使模型关注图像中的非局部特征。本文模型能有效分割出细小的血管和连通的分支血管,且不需要对图像进行预处理。

1 模型构建

为了解决视网膜血管分割容易断裂且细小血管容易被忽视的问题,本文以 Unet 模型为基础网络,加入非局部块,构建了一种非局部 Unet 模型(Non-Local Unet, N-Unet)。

1.1 基础网络结构

本文模型以 Unet 网络为基础。Unet 结构如图 1 所示。Unet 网络结构左右对称,分为编码器和解码器两部分。编码器用于捕获丰富的特征,解码器用于定位精准的像素。编码器的每一层都可以拼接到对应层次的解码器,实现深层特征和浅层特征的信息融合。正是由于这种特有的拼接结构,使得 Unet 网络在医学图像中的分割效果优于其他网络^[14]。且 Unet 的训练不需要大量的数据集,适用于数据集较少的视网膜血管分割任务^[15]。




图 1 Unet 网络

1.2 非局部块

非局部操作的优势在于带来了非局部的特征信息,从而减少局部操作造成的损失。对特征图进行非局部信息提取,这一操作的输出加上特征图本身构成一个非局部块^[16],定义如式(1)所示。非局部块被设计成残差块的形式,可以作为一个组件插入到网络中的任何位置。式中 x 表示输入的图像信息, y 表示对 x 进行非局部操作提取出的特征信息, W 是一个使 y 的通道数与 x 的通道数保持一致的卷积核, Z 由输入的图像信息 x 和经过非局部操作学习到的非局部特征 y 构成,是非局部块的输出。

$$z = Wy + x \quad (1)$$

非局部特征 y 的计算如式(2)所示,函数 f 如式(3)所示,表示某个输入 x_i 和与输入信息有依赖的 x_j 之间的关系,函数 g 将 x_i 从点转换成一个向量, $C(x)$

是归一化参数,计算方法如式(4)所示。

$$y_i = \frac{1}{C(x)} \sum_{\forall_j} f(x_i, x_j) g(x_j) \quad (2)$$

$$f(x_i, x_j) = e^{\theta(x_i) \top \phi(x_j)} \quad (3)$$

$$C(x) = \sum_{\forall_j} f(x_i, x_j) \quad (4)$$

图 2 展示了非局部块的具体实现。特征图输入后,为了减少计算量,先减少一半的通道数。将通道减半后的特征图矩阵转化为向量,用 1×1 $\phi(x)$ 的卷积操作分别进行 $\theta(x)$ 和 $g(x)$ 的线性映射,得到的结果分别为 F_1 、 F_2 、 F_3 ,然后将 F_1 转置后与 F_2 矩阵乘得到相似度矩阵 F_4 ,接着 F_3 与经过 softmax 操作的 F_4 矩阵乘得到 F_5 , F_5 经过变换后再和 1×1 的卷积核进行卷积,然后与原输入特征图进行像素点的加和。

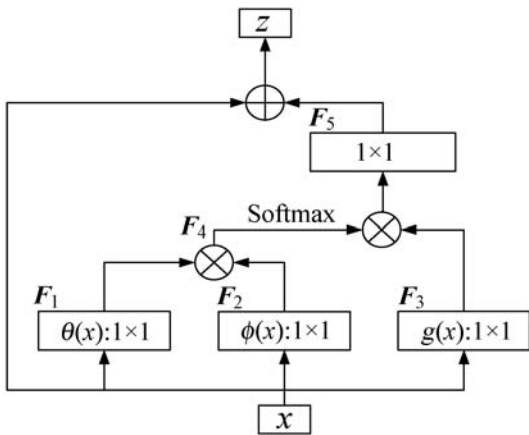


图 2 非局部块的实现

非局部块是受非局部均值操作^[17]的启发而提出的,相对于局部操作,非局部块最大的特点就是其某一个输出结果与所有像素点有关,即不只计算相邻像素之间的关系,还能够捕获非相邻像素之间的关系。

1.3 N-Unet 模型

本文提出的 N-Unet 模型结构如图 3 所示,分为编码器和解码器两部分,在编码阶段插入了非局部块。




图 3 N-Unet 网络结构

其中,编码器结构由若干卷积块、非局部块和池化

层构成。非局部块插入卷积层与池化层之间,可以加入非局部的感受野。卷积块详细结构如图 4 所示,特征图在输入后需要进行两次卷积计算,且每次卷积计算之后都要进行一次批量归一化处理 (Batch Normalization, BN) 和一次修正线性单元 (Rectified Linear Units, ReLU) 激活。卷积核大小为 3×3 , 尺寸为奇数的卷积核可以使输出的特征图尺寸和输入尺寸一致。批量归一化和 ReLU 激活可以缓解网络过拟合,改善梯度消失的问题,提高网络训练速度和泛化能力。ReLU 激活如式 (4) 所示,其原理是当输入值小于 0 时输出为 0,输入值大于等于 0 时输出不变。

$$output = \max(0, input) \quad (5)$$




图 4 卷积块

解码器结构与 Unet 网络的解码器一致,由上采样层和卷积块组成。网络对来自底层的特征图进行上采样操作后,将采样结果与在编码块对应层的特征图进行拼接,最后将拼接后的特征图作为卷积块的输入。解码阶段的卷积块与编码阶段的卷积块操作一样,上采样提高图片分辨率,对特征图进行拼接使网络在解码阶段补充了上下文信息和细节特征。

N-Unet 网络通过插入非局部块扩大感受野,从而提取到更丰富的图像信息。相对于传统的 Unet 通过堆叠卷积层扩大感受野的方法^[18],N-Unet 通过在每一卷积层运算之后插入非局部块增加感受野的方式能够引入更丰富的图像细节信息,解决因局部操作而造成的细节损失问题。

2 实验

2.1 数据集

本文使用的数据集是公开数据集 DRIVE (Digital Retinal Images for Vessel Extraction)^[19],DRIVE 包含 40 幅图片,其中训练集和测试集各占二分之一。

DRIVE 数据集的视网膜血管图片是 RGB 图片,其中绿色通道图片中血管与背景的对比如另外两个通道明显要高^[20],因此本文选择图片的绿色通道进行实验。

2.2 评价指标

本文实验结果的性能评价采用敏感性 (Sensitivity, Se)、特异性 (Specificity, Sp)、准确度 (Accuracy, Acc) 3 个评价指标。式(5) - 式(7) 分别表示这 3 个评价指标的计算方式, 式中的 T_P 、 F_N 、 T_N 、 F_P 是混淆矩阵中的四个元素。图 5 为混淆矩阵, T_P 和 F_P 分别代表被正确分割和错误分割的血管像素点, T_N 和 F_N 分别代表被正确分割和错误分割的背景像素点。

混淆矩阵		真实性	
		Positive	Negative
预测值	Positive	T_P	F_P
	Negative	F_N	T_N

图 5 混淆矩阵

$$S_e = \frac{T_P}{T_P + F_N} \quad (6)$$

$$S_p = \frac{T_N}{T_N + F_P} \quad (7)$$

$$A_{cc} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (8)$$

本文模型还用了曲线下面积 AUC 和 F_1 [21] 指标进行性能评估。

2.3 实验结果

本实验运行批次设置为 100 次, 批处理大小设置为 32 幅, 损失函数用二分类交叉熵, 选择 Adam 优化器进行训练, 初始学习率设置为 0.001。采用多种性能指标进行评定, 最终本文模型在 DRIVE 数据集上的 Se、Sp、Acc、AUC 分别为 0.813 0、0.974 9、0.954 3、0.976 7。本文模型与其他模型的性能对比如表 1 所示, 分割结果如图 6 所示, 不同方法在本文实验环境下运行时间对比如表 2 所示。




图 6 分割结果

表 2 不同方法在同一环境下的训练一次时间对比

方法	Hakim 等 ^[5]	Liskowski 等 ^[8]	Zhuang 等 ^[9]	本文方法
一次训练时间/ms	728	740	861	783

2.4 实验分析

从图 6 中看出, 本文实验分割结果与金标准相比, 分支血管没有出现断裂, 与主血管紧密连接。这说明本文引入非局部块能有效解决血管分割断裂现象。

前文中提到的通过局部操作增加感受野的方法容易造成血管分割断裂的现象是因为受到视网膜血管图像对比度较低, 分支血管本身大小等因素的影响。本文通过观察视网膜血管结构发现血管从一个特定的位置开始, 遵循特定的过程, 这个过程可以几何模拟为一条抛物线。本文通过在 Unet 网络中引入非局部块的方法, 除了关注图像的局部信息还关注图像的非局部信息, 捕获远距离像素点之间的依赖关系, 从而提取出更完整且连通的血管结构。图 7 所示为不同方法的分割出的视网膜血管图像的细节。可以看出, Hakim 方法和 Liskowski 方法的分割效果较差, 容易忽视细小血管, Zhuang 方法和本文方法都能分割出较为完整的血管, 但 Zhuang 方法在分叉处出现断裂, 而本文方法不仅能够分割出细小血管, 在分叉处也与主血管紧密连接。




图 7 不同方法的分割图像细节

根据评价指标的标准, 将本文模型的实验结果与其他模型做对比, 可以发现本文模型的 Se、Acc 和 AUC 要明显高于其他方法。其中, Se 高于其他模型说明本文提取出的血管像素点更精确, Sp 虽然低于其他模型, 但 Sp 表示的是背景像素点分割的准确率, 且 Acc 和 AUC 要高于其他模型说明本文的分割准确度和模型性能都要优于其他方法。

3 结 语

本文提出了一种非局部 Unet 的视网膜血管分割模型 N-Unet。N-Unet 保持了 Unet 网络编码器-解码器的对称结构, 通过在编码阶段的卷积块和下采样之间加入非局部块, 用于捕获非局部的特征信息, 且本文模型不需要对图像进行任何的预处理。本文模型在 DRIVE 数据集上进行实验, 实验结果表明, 本文方法优于其他对视网膜血管进行有监督分割的方法。

本文贡献主要包括以下: (1) 将非局部块应用于视网膜的血管分割领域。(2) 本文方法能有效解决分支血管断裂的问题, 提高血管分割的连通性。(3) 不

需要对图片进行预处理,且模型结构简单明了。

参 考 文 献

- [1] Seeböck P, Orlando J I, Schlegl T, et al. Exploiting epistemic uncertainty of anatomy segmentation for anomaly detection in retinal OCT[J]. IEEE Transactions on Medical Imaging,2020,39(1):87-98.
- [2] 朱承璋,崔锦恺,邹北骥,等. 基于多特征融合和随机森林的视网膜血管分割[J]. 计算机辅助设计与图形学学报,2017,29(4):584-592.
- [3] 游齐靖,万程. 基于深度学习的医学图像分割方法[J]. 中国临床新医学,2020,13(2):115-118.
- [4] Lahiri A, Roy A G, Sheet D, et al. Deep neural ensemble for retinal vessel segmentation in fundus images towards achieving label-free angiography[C]//38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society,2016:1340-1343.
- [5] Hakim L, Yudistira N, Kavitha M, et al. U-Net with graph based smoothing regularizer for small vessel segmentation on fundus image[C]//International Conference on Neural Information Processing,2019:515-522.
- [6] Waly M I, El-Hossiny A. Detection of retinal blood vessels by using Gabor filter with entropic threshold[J]. Majmaah Journal of Health Sciences,2016,4(2):36-55.
- [7] Li Q L, Feng B W, Xie L P, et al. A cross-modality learning approach for vessel segmentation in retinal images[J]. IEEE Transactions on Medical Imaging,2015,35(1):109-118.
- [8] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks[J]. IEEE Transactions on Medical Imaging,2016,35(11):2369-2380.
- [9] Zhang Y S, Chung A C. Deep supervision with additional labels for retinal vessel segmentation task[EB]. arXiv:1806.02132v1,2018.
- [10] Zhuang J T. LadderNet: Multi-path networks based on U-Net for medical image segmentation[EB]. arXiv:1810.07810v1,2018.
- [11] Jin Q G, Meng Z P, Pham T D, et al. DUNet: A deformable network for retinal vessel segmentation[J]. Knowledge-Based Systems,2019,178:149-162.
- [12] 梁礼明,盛校棋,蓝智敏,等. 自适应尺度信息的 U 型视网膜血管分割算法[J]. 光学学报,2019,39(8):126-140.
- [13] Chen Y L. A labeling-free approach to supervising deep neural networks for retinal blood vessel segmentation[EB]. arXiv:1704.07502,2017.
- [14] 王海鸥,刘慧,郭强,等. 面向医学图像分割的超像素 U-Net 网络设计[J]. 计算机辅助设计与图形学学报,2019,31(6):1007-1017.
- [15] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention,2015:234-241.
- [16] Wang X L, Girshick R, Gupta A, et al. Non-local neural networks[EB]. arXiv:1711.07971,2017.
- [17] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C]//IEEE Computer Society Conference on Computer Vision & Pattern Recognition,2005:60-65.
- [18] 徐光柱,胡松,陈莎,等. U-net 与 Dense-net 相结合的视网膜血管提取[J]. 中国图象图形学报,2019,24(9):1569-1580.
- [19] Gkantsidis C, Mihail M, Saberi A. Random walks in peer-to-peer networks: Algorithms and evaluation[J]. Performance Evaluation,2006,63(3):241-263.
- [20] Zhao Y Q, Wang X H, Wang X F, et al. Retinal vessels segmentation based on level set and region growing[J]. Pattern Recognition,2014,47(7):2437-2446.
- [21] 李瑞瑞,彭晓婷,肖革新,等. 基于血管连通性的视网膜血管分割技术研究[J]. 中国数字医学,2020,15(7):125-129.
- ~~~~~
- (上接第 191 页)
- [22] Watcharawipha A, Theera-Umporn N, Auephanwiriyakul S. Space independent image registration using curve-based method with combination of multiple deformable vector fields[J]. Symmetry,2019,11(10):1210.
- [23] 柏连发,韩静,张毅,等. 采用改进梯度互信息和粒子群优化算法的红外与可见光图像配准算法[J]. 红外与激光工程,2012,41(1):248-254.
- [24] 朱浩然,刘云清,张文颖. 基于迭代导向滤波与多视觉权重信息的红外与可见光图像融合[J]. 光子学报,2019,48(3):184-194.
- [25] Seo J H, Kang M S, Kim H J, et al. Image stitching using normalized cross-correlation and the thresholding method in a fluorescence microscopy image of brain tumor cells[J]. Journal of Korea Multimedia Society,2017,20(7):979-985.
- [26] Liu D H, Mansour H, Boufounos P T. Robust mutual information-based multi-image registration[C]//IEEE International Geoscience and Remote Sensing Symposium,2019:915-918.
- [27] Gong M G, Zhao S M, Jiao L C, et al. A novel coarse-to-fine scheme for automatic image registration based on sift and mutual information[J]. IEEE Transactions on Geoscience and Remote Sensing,2014,52(7):4328-4338.