

DOI:10.19651/j.cnki.emt.2312848

BW-Net: 用于视网膜血管图像分割的 W-Net 扩展框架

黎 强 陈惠贤

(兰州理工大学机电工程学院 兰州 730050)

摘要:为了更准确地分割视网膜血管图像中的目标区域,提出了一种基于改进 W-Net 的网络 BW-Net。该网络采用菱形结构融合的方式进行语义特征聚合,通过将含有菱形结构的部分逐层堆叠形成 U 型拓宽框架,并引入嵌套的密集跳跃连接形成最终模型。融合方案提高了特征图组合的灵活性,设计的跳跃连接减少了特征图之间的语义差距,从而减轻了优化器的学习压力,实现了更好的图像分割性能。使用 DRIVE 数据集验证了拟议网络的有效性。BW-Net 在分割任务中获得的 Dice 相似性系数值、敏感性、特异性和准确性分别是 76.86%、73.66%、99.12% 和 94.55%,比目前大部分的先进网络框架的输出表现较好,并且网络参数却得到了减少。结果证明了该扩展结构在视网膜血管图像分割性能上的改进。

关键词:图像分割;视网膜血管;全卷积网络

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 520.60

BW-Net: A W-Net extension framework for retinal vascular image segmentation

Li Qiang Chen Huixian

(School of Mechanical and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: To segment target regions in retinal blood vessel images more accurately, a network based on improved W-Net is proposed. The network uses diamond structure fusion for semantic feature aggregation by stacking the parts containing the diamond structure layer by layer to form a U-shaped widening framework and introducing nested dense jump connections to form the final model. The fusion scheme improves the flexibility of feature map combination, and the designed jump connections reduce the semantic gap between feature maps, thus reducing the learning pressure on the optimizer and achieving better image segmentation performance. The dice similarity coefficient values, sensitivity, specificity, and accuracy obtained by BW-Net in the segmentation task are 76.86%, 73.66%, 99.12%, and 94.55%, respectively, which perform better than the output of most of the current state-of-the-art network frameworks, and the network parameters are reduced. The results demonstrate the improvement of this extended structure in the performance of retinal vascular image segmentation.

Keywords: image segmentation; retinal vessels; fully convolutional network

0 引言

视网膜血管图像是对各种眼疾进行诊断和治疗的重要依据之一,通过将图像中的视网膜血管树结构精准分割出来,从而实现医学图像分析与计算机辅助诊断的目的^[1]。因此,如何准确高效的从视网膜血管图像中分割出目标区域已经成为目前急需解决的问题。

眼科医学中普遍是运用手动分割的方法处理图像,这是一件十分枯燥且低效的工作,且分割准确度易受主观因素的影响,在很大程度上依赖于医生的经验。为了完成图像自动分割的目的,许多的分割方法被研究者所提出,包括传统的根据图像灰度值突变而进行图像分割的方法,或根据预定的规则进行分割的方式。这类分割方法速度快,数据无需标注,属于非监督学习的算法,但

多数会对图像中的噪声较敏感,分割时存在精度低、鲁棒性差等问题^[2]。董恒等^[3]提出的基于 B-COSFIRE 的混合滤波视网膜血管分割方法具有比单一滤波法更加精准的分割,但处理过程较为繁琐,无法实现端到端的快速网络分割。

最近,卷积神经网络(convolutional neural network, CNN)作为深度学习中一种监督型的学习算法被广泛应用于图像的分类任务^[4-6],通过对大量标注样本的学习,以提取出高层次的抽象特征用于图像类别的划分。然而,在许多视觉任务中,特别是医学领域中,所期望的输出应当是分配给每个像素的类标签。全卷积神经网络(fully convolutional network, FCN)^[7]的提出实现了精确到像素级的分类,同时能够输出与原图像相同分辨率大小的语义分割图,跳跃连接的引入有助于恢复图像在下采样过程中丢失的细节,使其具有比传统方法更好的分割效果。但在生物医学领域中大量的图像是难以获得的,因此 Ronneberger 等^[8]在 FCN 的基础上提出了一种用于医学图像分割的网络,即 U-Net。该网络通过使实现精确定位的扩张路径与捕获上下文的收缩路径对称以形成 U 形结构,并将上采样解码特征图与来自编码器子网路的相同比例特征图以叠加的方式级联,使其可以处理训练样本少的数据集,且产生更精确的分割。

随着编码和解码结构的 U-Net 的广泛应用,许多研究者以 U-Net 为主干网络进行大量改进探索从而应用到大部分的生物医学图像的分割任务中,其中也包括了视网膜血管图像。秦俊豪等^[9]通过对 U-Net 的改进提出了 Shuffle-Unet 视网膜血管分割模型,多模块的高效融合实现了快速精准的目标细分。侯向丹等^[10]在结合了注意力机制和多路径 U-Net 后有效的提升了处于病变区域等复杂情况下视网膜血管的分割精度。梁礼明等^[11]提出了融合多层次空间注意的 U 型网络,在性能表现上优于现有模块融合后的视网膜血管分割模型。

在 2017 年由 Xia 等^[12]设计了一种新的无监督架构为 W-Net,而非仅限于在 U-Net 框架中引入新模块。该架构在结合了两个 U-Net 模型的连接后构成一个自动编码器以解决难以获得足够监督数据的问题,后续被引用到多类监督型的图像分割任务中来提高图像边缘信息的捕捉能力^[13],这归因于解码后的特征图跳跃连接到下一个 U 网重新进行编码。但是简单的 U 网连接结构对特征图的处理并不充分且成倍的增加了网络参数。2018 年, Zhou 等^[14]提出了集成的 UNet+十模型,使其可以自动学习下采样的深度,在嵌套的密集跳跃连接的帮助下缩小了编码器和解码器之间的语义差距,减轻了优化器的学习压力以达到更好的分割效果。多深度的 U 网组合架构仍然存在无法探索足够多的信息的问题。Huang 等^[15]在 U-Net 的基础上利用了全尺寸的特征而提出了 UNet3+模型,由于全面的

特征信息聚合实现了更多的细粒度细节和粗粒度语义的捕捉。但过多分辨率尺寸的特征图的同时组合可能会限制网络的性能表现。

本文通过分析多类先进的网络结构进而提出了一种新的视网膜血管分割框架 BW-Net。该深度架构是对 W-Net 的复杂扩展修改,网络的创新点在于:1)通过将包含菱形结构的特征图融合方案多次叠加以获得更多尺度的特征图信息。该融合方案不仅引用了 W-Net 中编码特征图与解码特征图级联后再编码下采样的模式,同时还采用了 UNet3+的全尺寸连接的思想,实现了多分辨率图像信息的重复聚合模式。并且避免了 W-Net 网络参数剧增和 UNet3+全尺寸连接对该网络的结构限制;2)UNet+十的嵌套密集跳跃连接的引入减少了特征图之间的语义差距并促进了训练时的梯度流动,与本文优化框架的结合相较于 UNet+十能够进一步的改善分割性能;3)呈 U 形的主框架本质上仍然是对 U-Net 的局部结构改进,从而介绍了一种新的网络扩展思路。

1 BW-Net 网络分割方法

1.1 W-Net 网络

全卷积神经网络极大的促进了各种分割模型的开发,特别是在 U-Net 的出现后医学图像分割领域得到了快速的发展。在连接了两个 U-Net 网络后形成了无监督模型 W-Net,其首次提出是为了适用于无法获得大量标注数据的视觉任务,然后经过进一步改善的框架应用到耕地和视网膜血管等图像分割中,并且采用标注样本对其进行监督训练。如图 1(k)所示, W-Net 在对特征图进行处理和跳跃连接时,增添了解码后的特征图跳转至下一个 U-Net 进行融合后重新编码的步骤,这样可以提高对目标区域的边缘分割精度。

1.2 BW-Net 网络

虽然 W-Net 可以利用更多的尺度特征,但是低效的特征图融合机制无法捕获足够的特征信息,且过于简易的首尾相连 U-Net 的方式增加了大量的网络参数却达不到预期的分割效果。因此,如图 1 所示了 U-Net 系列中不同深度的结构网络、BW-Net 系列中各类深宽度以及跳跃连接方式的框架网络和 W-Net 网络,对比各种网络的结构特点以进行系统的探索。如图 1(e)中通过将新设计的菱形结构叠加以替换 W-Net 的单路径的中间部分,许多的收缩与扩展路径被交叉连接,这样不仅可以实现 W-Net 的扩展路径的特征图跳转连接到收缩路径进行组合编码,而且在菱形结构的尾部收获了来自三种分辨率尺寸的特征信息(例如图 1(b)中的 X^{2,1} 卷积块)。这不同于 UNet3+的全面的跳过连接,过多尺度的特征图聚合会限制结构复杂的网络的性能。在该改进框架的基础上引入嵌套的密集跳跃连接以淡化特征图之间的语义差距,形成了新的框架结构 BW-Net。

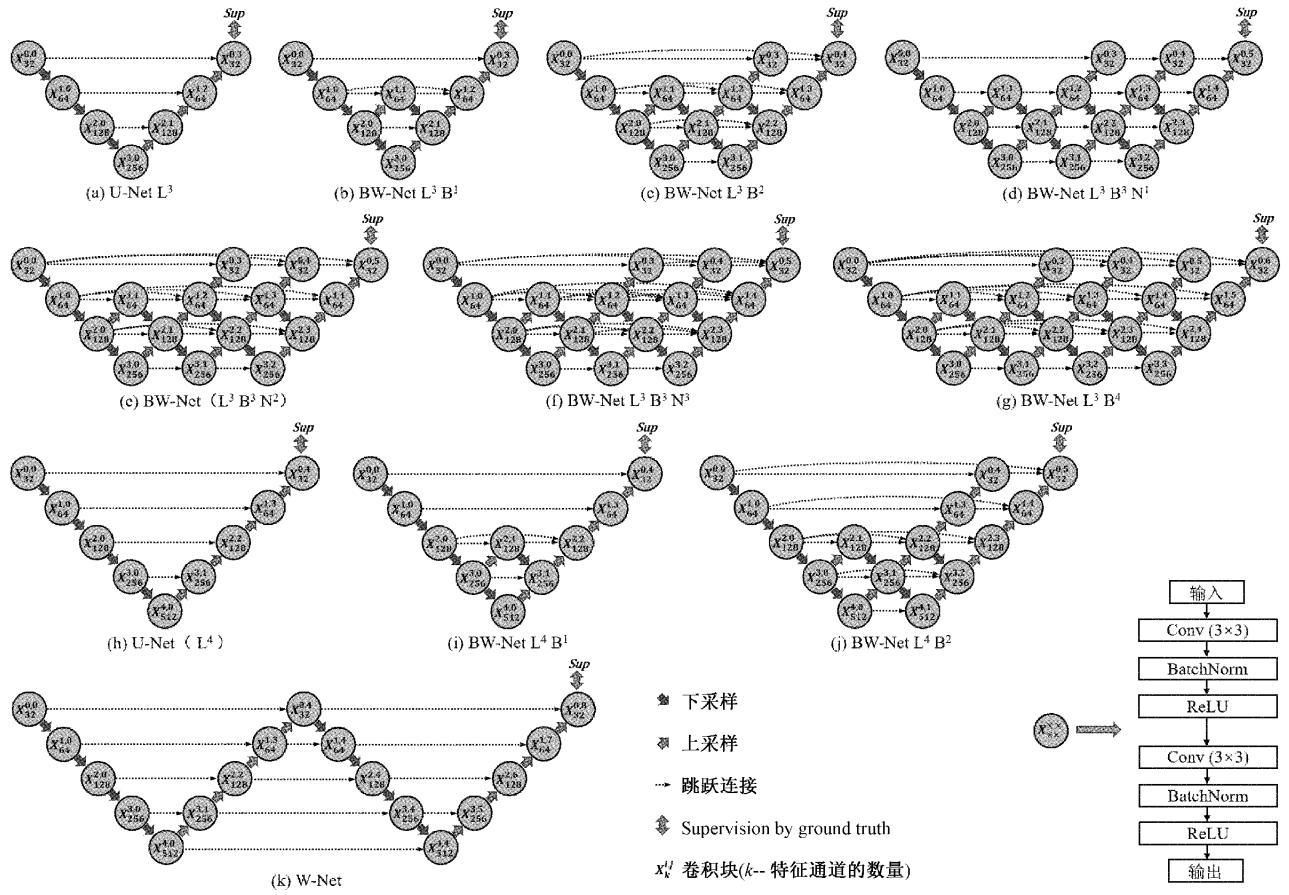


图1 U-Net系列、BW-Net系列和W-Net网络

从函数表达上,本文所设计的BW-Net网络的跳过路径可以表示为: $x^{i,j}$ 表示为卷积块 $X^{i,j}$ 的输出结果,其中*i*表示结构纵向索引,*j*表示结构横向索引; L^a 中的*a*是指网络的深度索引, B^c 中的*c*表示为网络最深卷积块的数量索引, N^d 中的*d*表示为网络跳跃连接的密集程度索引,BW-Net($L^3 B^3 N^2$)中由 $x^{i,j}$ 表示的特征图堆栈计算如下:

$$x^{i,j} = \begin{cases} H(D(x^{i-1,j})), & j=0 \\ H([x^{i,0}, u(x^{i+1,j-1})]), & (i,j)=(1,1), (0,3) \\ H([D(x^{i-1,j}), x^{i,j-1}]), & i=3, j>0 \\ H([D(x^{i-1,j}), x^{i,j-1}, u(x^{i+1,j-1})]), & (i,j)=(2,1) \\ H([D(x^{i-1,j}), x^{i,0}, x^{i,j-1}, u(x^{i-1,j-1})]), & i=2, j>1 \\ H([x^{i,0}, x^{i,j-1}, u(x^{i+1,j-1})]), & (i,j)=(1,2 \sim 4), (0,4 \sim 5) \end{cases} \quad (1)$$

式中:函数 $H(\cdot)$ 为卷积块的所有运算, $u(\cdot)$ 为上采样层,[]表示连接层,函数 $D(\cdot)$ 为下采样层。其中 $j=0$ 级的节点仅从同级的上一层节点接受一个输入, $i=3$ 且 $j>0$ 的节点还需同层的前一级节点的输出作为输入; (i,j) 等于(1,1)和(0,3)的节点接收两个输入,来自于下一层的上采样和同层的第一个节点,而 (i,j) 为(1,2~4)和(0,4~5)的

一系列节点增添了同层的前一级的输出参与融合输入; $i=2$ 且 $j>0$ 的节点具有跨3个连续层的多个输入,分别是上一层的下采样、同层的首节点及前一节点的输出和下一层的上采样, (i,j) 为(2,1)的节点的不同之处在于同层的首节点和同层的前一节点重合,因此只需将两者合为一次输入。

1.3 损失函数

在卷积神经网络训练过程中,选择混合损失函数作为目标函数,可以利用到所有子损失函数提供的优势,如平滑梯度和处理类别失衡等。合理的混合损失函数可以有效地解决网络在反向传播过程中梯度消失的问题,使网络能够处理不同类型的图像分割问题,最终达到更好的训练效果。混合损失函数如下:

$$L = \alpha \left(1 - \frac{2 \sum_{i=1}^N g_i p_i}{\sum_{i=1}^N g_i + \sum_{i=1}^N p_i} \right) - (1-\alpha) \frac{1}{N} \sum_{i=1}^N (g_i \cdot \ln(p_i) + (1-g_i) \cdot \ln(1-p_i)) \quad (2)$$

式中: α 表示权重因子, g_i 表示像素点*i*的真实标签, p_i 表示模型对像素点*i*的预测输出。

2 数据及模型

本研究的实验环境是基于开源深度学习框架 PyTorch, 使用 Python 编程语言进行搭建的。该框架是一款强大的动态计算图的模式的深度学习框架, 提供从原型到生产部署的无缝路径, 是一个基于 Torch 的 Python 工具包, 专门用于 GPU 加速的深度学习编程, 极大的提高了训练速度。计算机配置如下: Windows10 的操作系统; 处理器为 AMD Ryzen 7 4800 H; 显卡为 NVIDIA GeForce RTX 2060, 6 GB 内存; 系统内存为 32 GB。

2.1 数据及预处理

在表 1 中总结了本研究中所涉及的视网膜血管图像分割任务数据集的基本信息, 包括图片的数量、尺寸和图片模式等详细信息。

表 1 本研究中所使用到的 DRIVE 数据集摘要

数据集	图片数	输入尺寸	图片模式	来源
DRIVE	20	96×96	DRI	grand challenge 2019 ^[16]

数字视网膜图像血管提取数据集(digital retinal image vessel extraction, DRIVE)是最广泛使用于视网膜血管分割任务的数据集, 共有 20 张图像(565×584 像素)带有标签。在 10 折交叉验证之后获得训练集和测试集, 并且将原始的 DRIVE 图像从 565×584 像素分辨率缩放成 576×576 像素的尺寸, 然后再裁剪成 96×96 像素大小的图像, 如图 2 所示了原始的 576×576 尺寸的视网膜图像示例和从其中截取 96×96 大小的部分图像作为输入, 并将相对应的金标准作为监督, 另外相邻裁剪图像间存在一半的共享数据。

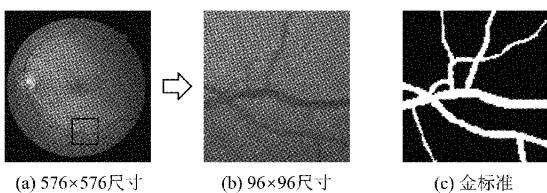


图 2 视网膜图像预处理及其金标准

2.2 模型训练

迭代次数的选择可能会影响实验结果的可靠性。迭代次数过少会导致网络未能较好的拟合于训练数据, 最终处于欠拟合的状态; 而若已经达到最佳拟合状态仍然继续进行训练会造成过拟合的后果, 使得模型表现变糟。因此, 通过采用 Early Stopping 的方法选择合适的训练次数。使用 Adam 作为优化器训练模型参数, 初始学习率设置为 3×10^{-4} , batch size 设定为 1。

2.3 评估指标

本文使用 Dice 相似系数值(dice similarity coefficient,

DSC)、敏感度(sensitivity, SEN)、特异性(specificity, SPE)和准确率(accuracy, ACC)4 个指标对网络进行了全面的评估:

$$DSC = \frac{2 \sum_{i=1}^N g_i p_i}{\sum_{i=1}^N g_i + \sum_{i=1}^N p_i} \quad (3)$$

$$SEN = \frac{TP}{TP + FN} \quad (4)$$

$$SPE = \frac{TN}{TN + FP} \quad (5)$$

$$ACC = \frac{TP + TN}{TP + FN + TN + FP} \quad (6)$$

式中: g_i 表示像素点 i 的真实标签; p_i 表示模型对像素点 i 的预测输出; TP 表示真实阳性, 即被正确预测的前景像素数量; TN 表示真实阴性, 即被正确预测的背景像素数量; FP 表示假阳性, 即被错误预测的前景像素数量; FN 表示假阴性, 即被错误预测的背景像素数量。

3 实验结果与分析

3.1 不同网络的比较

为了探索 BW-Net 的最佳网络结构, 本文进行了有关网络深度(L^d)、宽度(B^w)和嵌套的密集跳跃连接(N^d)的全面消融实验, 从而更好的理解研究结构的改进之处。其中使用医学图像中常用的 DSC 评估指标将图 1 中包含的所有模型在表 1 的数据集上进行相应的实验验证, 得到了如表 2 所示的评估数据, 用于对一系列 U-Net 网络、BW-Net 网络和 W-Net 网络的视网膜血管图像分割性能进行研究和对比。通过表 2 中的数据可以得出 BW-Net($L^3 B^3 N^2$)取得了最高的分割精度分数, 是最佳的结构选择, 并且比 U-Net 提升了 1.44% 的 DSC 分数, 这主要归功于对 W-Net 的扩展改进且图像分割的精度仍然优于它。从表中可以得出网络的深度和宽度过大都可能不利于菱形结构的特征提取, 同样过于密集的跳跃连接会限制模型的表现。在 DRIVE 数据集中 U-Net L^3 的性能优于 U-Net, 因此 U 形网需要面临最佳深度先验未知的问题, 而 BW-Net 避免了这一难题。

3.2 BW-Net 与 U-Net 的比较

各类网络在视网膜血管图像分割任务上取得的预测图被绘制如图 3 所示, 其中显示了 BW-Net、W-Net 与 U-Net 等网络的输出图示例以及原始输入图和真实分割图。通过具体化的实验输出结果示例显示, BW-Net 相对于 U-Net 网络具有更细致化的语义分割能力, 能够更好的处理分割目标的边缘。如图 4 所示了本文模型相对于其它先进的分割网络训练时在测试集上的 Dice 相似系数值, 通过对比可以得出 BW-Net 比较于 U-Net 具有更快的拟合能力和更高的分割准确度。

表2 图1中的网络在DRIVE数据集上进行实验获得的Dice相似系数值

网络	参数/M	DRIVE
U-Net L ³	1.95	75.60±3.52
BW-Net L ³ B ¹	2.21	76.51±3.31
BW-Net L ³ B ²	4.73	76.76±3.30
BW-Net L ³ B ³ N ¹	6.83	76.02±3.56
BW-Net (L ³ B ³ N ²)	7.25	76.86±3.64
BW-Net L ³ B ³ N ³	7.52	76.34±3.72
BW-Net L ³ B ⁴	9.77	76.10±3.32
U-Net (L ⁴) ^[8]	7.86	75.42±3.66
BW-Net L ⁴ B ¹	8.89	75.79±4.22
BW-Net L ⁴ B ²	19.01	75.86±3.55
W-Net ^[13]	18.84	76.40±4.00

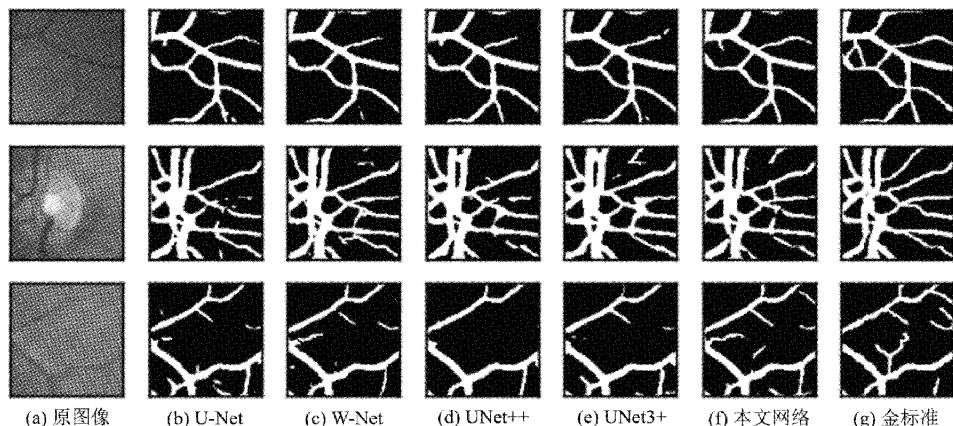


图3 U-Net、W-Net、UNet++、UNet3+和WU-Net的视网膜血管分割结果图

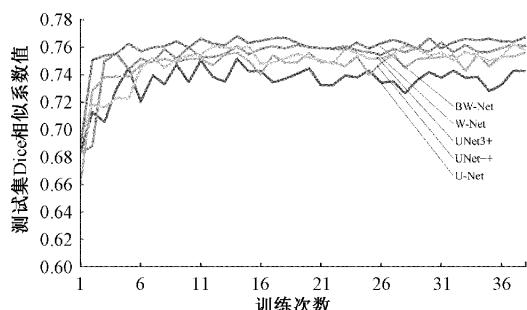


图4 各种网络训练时在测试集上的Dice曲线

敏感。其次,当对每个像素进行分类时,像素和像素之间的关系没有得到充分的利用。通过将两个U-Net网络首尾相连形成的新模型W-Net,实现了两次上下采样路径和多尺度特征图的叠加,更好的选择目标特征和捕捉低级的特征信息,以提高输出的准确性并细化边界信息。但是W-Net过于简单的连接结构和随之大量增加的网络参数显示网络的图像分割性能过于低效,因此本文在此基础上进行了一系列改进后得到了BW-Net网络。该网络是对W-Net的一种复杂扩展优化,并通过实验验证提出模型的

此外,如表3所示给出了BW-Net、W-Net和U-Net等网络在DRIVE数据集上取得的Dice相似系数值、敏感度、特异性和准确率的分数,BW-Net相对于U-Net在数据集上对应于每个指标分别提升了1.44%、2.59%、0.10%和0.29%,使用不同的指标来评估模型以提高实验结论的可信度,从多角度验证本文的框架改进和网络参数的高效使用(比U-Net减少了0.61M)。本文新提出的网络中多次叠加融合不同尺度的特征,允许大量聚合层决定如何处理多尺度特征组合问题,实现了网络中图像特征的横向逐步融合而获得更多的特征信息。

3.3 BW-Net与W-Net的比较

U-Net是适用于难以获得大量数据集的医学图像分割方法,但该网络仍然存在许多不足之处。首先,U-Net输出的分割结果较为粗略,对图像中目标区域的细节不够

改善效果,如表3所示本文网络在多个图像分割性能指标上都要高于W-Net(分别提升了0.46%、0.41%、0.02%和0.07%),在减少大量参数(11.59M)的情况下具有较佳的输出表现。

3.4 BW-Net与UNet++的比较

通过对不同深度的U-Net集成从而形成了性能更加强大的UNet++,嵌套的密集跳跃连接使网络更易于学习数据中信息。因此,本文使用更全面的U形网作为性能基准,以验证BW-Net模型的改进程度,并且都未使用深度监督从而仅仅比较框架层面上的优劣。如表3所示,新提出的网络在多个图像分割评估指标上都更好于UNet++(分别提升了1.12%、1.77%、0.07%和0.20%),网络参数却少了1.92M,这说明了即使充分发挥U形网的特性,结构上的局限依旧难以避免。这证明了更加复杂且合理的网络框架需要被进一步的研究和提出,实现对图像特征更好的处理以提升视网膜血管图像分割的性能。

3.5 BW-Net与UNet3+的比较

UNet3+是在U-Net的基础上进行更加全面的跳跃

表 3 U-Net、W-Net、UNet++、UNet3+和本文网络在 DRIVE 数据集上的 Dice 相似系数值、敏感度、特异性和准确率

网络	参数/M	DRIVE 数据集			
		DSC	SEN	SPN	ACC
U-Net ^[8]	7.86	75.42±3.66	71.07±6.44	99.02±0.24	94.26±0.41
W-Net ^[13]	18.84	76.40±4.00	73.25±6.59	99.10±0.31	94.48±0.36
UNet++ ^[14]	9.17	75.74±4.18	71.89±6.84	99.05±0.23	94.35±0.41
UNet3+ ^[15]	7.68	76.12±4.04	72.93±6.77	99.09±0.29	94.46±0.44
本文网络	7.25	76.86±3.64	73.66±6.69	99.12±0.40	94.55±0.43

连接和深度监督的语义分割模型。全尺寸的跳跃连接结合了来自不同尺度的特征图, 获得具有高级语义的低级特征细节; 深度监督从全尺寸聚合的特征图中学习分层表示。BW-Net 的设计引入了 UNet3+ 的全尺寸跳跃连接思想, 为了适配于 BW-Net 的扩宽结构本文仅采取了三类相邻尺寸特征图的融合方式, 以免过多的跳跃连接影响网络对于图像分割的表征能力。针对 BW-Net 和 UNet3+ 的分割性能, 如表 3 所示, 通过充分的实验对比, 在 Dice 相似系数值等评估指标上取得了更好的表现, 证明了本文网络相对于 UNet3+ 是另外一种更佳的框架结构, 并且网络参数也有所减少。

4 结 论

针对视网膜血管图像需要更准确的语义分割现状, 本文提出基于 W-Net 网络扩展的监督学习分割方法 BW-Net。该方法介绍了一种新的菱形结构的特征融合方案, 通过将其首尾连接而形成了更宽的网络框架, 并引入一定密集程度的跳跃连接, 加强了有效信息的捕捉, 图像边缘细节得到了更好的保留。实验结果表明, BW-Net 具有优于 U-Net、W-Net、UNet++ 和 UNet3+ 的图像分割性能, 其有效的提高了图像分割的效果, 说明了网络设计上的改进可以提升网络分割的精确度, 也验证了本文所提出理论的正确性, 为后续的框架优化提供一定参考依据。在 DRIVE 数据集上的实验数据显示, BW-Net 即使占用更少的内存却可以在多个评估指标上达到更好的水平, 这归因于模型结构上可以从多次的特征融合中学习到不同特征之间的联系, 带来了更好的分割效果。但由于模型结构的复杂化, 在进行网络训练时, 将要花费更多时间。

参 考 文 献

- [1] ZHOU S, CHENG Y, TAMURA S. Automated lung segmentation and smoothing techniques for inclusion of juxtapleural nodules and pulmonary vessels on chest CT images [J]. Biomedical Signal Processing and Control, 2014, 13: 62-70.
- [2] OTSU N. A threshold selection method from gray-level histograms[J]. IEEE transactions on systems, man, and cybernetics, 1979, 9(1): 62-66.
- [3] 董恒, 叶楠, 寇丽杰, 等. 基于 B-COSFIRE 的混合滤波视网膜血管分割算法[J]. 电子测量技术, 2020, 43(16): 156-160.
- [4] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9): 1300-1312.
- [5] 崔雪红, 刘云, 王传旭, 等. 基于卷积神经网络的轮胎缺陷 X 光图像分类[J]. 电子测量技术, 2017, 40(5): 168-173.
- [6] 周明非, 汪西莉, 王磊, 等. 高分辨卫星图像卷积神经网络分类模型[J]. 中国图象图形学报, 2017, 22(7): 996-1007.
- [7] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, 2015: 234-241.
- [9] 秦俊豪, 李忠志, 冯家乐. 基于 Shuffle-Unet 的视网膜血管分割研究[J]. 电子测量技术, 2022, 45(20): 117-124.
- [10] 侯向丹, 李紫宇, 牛敬钰, 等. 结合注意力机制和多路径 U-Net 的视网膜血管分割[J/OL]. 计算机辅助设计与图形学学报: 1-11[2023-02-18].
- [11] 梁礼明, 詹涛, 雷坤, 等. 融合多层空间注意的 U 型视网膜血管分割算法[J/OL]. 小型微型计算机系统: 1-9[2023-02-18].
- [12] XIA X, KULIS B. W-net: A deep model for fully unsupervised image segmentation[J]. ArXiv Preprint, 2017, ArXiv:1711.08506.
- [13] SHI L, HUANG H, SHI Y, et al. W-net: The convolutional network for multi-temporal high-resolution remote sensing image arable land semantic segmentation [C]. Journal of Physics: Conference

- Series. IOP Publishing, 2019, 1237(3): 032067.
- [14] ZHOU Z, RAHMAN SIDDIQUEE M M, TAJBAKHSH N, et al. Unet++: A nested u-net architecture for medical image segmentation[C]. Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, 2018: 3-11.
- [15] HUANG H, LIN L, TONG R, et al. UNet3+: A full-scale connected UNet for medical image segmentation[C]. ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2020: 1055-1059.
- [16] STAAL J, ABRAMOFF M D, NIEMEIJER M, et al. Ridge-based vessel segmentation in color images of the retina [J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501-509.

作者简介

黎强,硕士研究生,主要研究方向为生物医学图像分割。
E-mail:1248093747@qq.com

陈惠贤,研究员,主要研究方向为成套装备及其自动化等。
E-mail:q1570931@163.com