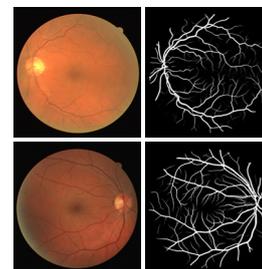




DOI: 10.12086/oe.2021.210291

鬼影卷积自适应视网膜血管分割算法

梁礼明¹, 周珑颂¹, 陈鑫¹, 余洁¹, 冯新刚^{2*}¹江西理工大学电气工程与自动化学院, 江西 赣州 341000;²江西理工大学应用科学学院, 江西 赣州 341000

摘要: 针对视网膜血管分割存在主血管轮廓模糊、微细血管断裂和视盘边界误分割等问题, 提出一种鬼影卷积自适应视网膜血管分割算法。算法一是用鬼影卷积替代神经网络中普通卷积, 鬼影卷积生成丰富的血管特征图, 使目标特征提取充分进行。二是将生成的特征图进行自适应融合并输入至解码层分类, 自适应融合能够多尺度捕获图像信息和高质量保存细节。三是在精确定位血管像素与解决图像纹理损失过程中, 构建双路径注意力引导结构将网络底层特征图与高层特征图有效结合, 提高血管分割准确率。同时引入 Cross-Dice Loss 函数来抑制正负样本不均问题, 减少因血管像素占比少而引起的分割误差, 在 DRIVE 与 STARE 数据集上进行实验, 其准确率分别为 96.56% 和 97.32%, 敏感度分别为 84.52% 和 83.12%, 特异性分别为 98.25% 和 98.96%, 具有较好的分割效果。

关键词: 视网膜血管; 鬼影卷积; 自适应融合模块; 双路径注意力引导结构

中图分类号: TP391

文献标志码: A

梁礼明, 周珑颂, 陈鑫, 等. 鬼影卷积自适应视网膜血管分割算法[J]. 光电工程, 2021, 48(10): 210291

Liang L M, Zhou L S, Chen X, *et al.* Ghost convolution adaptive retinal vessel segmentation algorithm[J]. *Opto-Electron Eng.*, 2021, 48(10): 210291

Ghost convolution adaptive retinal vessel segmentation algorithm

Liang Liming¹, Zhou Longsong¹, Chen Xin¹, Yu Jie¹, Feng Xingang^{2*}¹School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China;²School of Applied Sciences, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

Abstract: In order to solve the problems in retinal vessel segmentation, such as blurred main vessel profile, broken micro-vessels, and missegmented optic disc boundary, a ghost convolution adaptive retinal vessel segmentation algorithm is proposed. The first algorithm uses ghost convolution to replace the common convolution in neural network, and the ghost convolution generates rich vascular feature maps to make the target feature extraction fully carried out. Secondly, the generated feature images are adaptive fusion and input to the decoding layer for classification. Adaptive fusion can capture image information at multiple scales and save details with high quality. Thirdly, in

收稿日期: 2021-09-06; 收到修改稿日期: 2021-10-02

基金项目: 国家自然科学基金资助项目(51365017, 61463018); 江西省自然科学基金面上项目(20192BAB205084); 江西省教育厅科学技术研究重点项目(GJJ170491)

作者简介: 梁礼明(1967-), 男, 硕士, 教授, 主要从事医学影像方面的研究。E-mail: 9119890012@jxust.edu.cn

通信作者: 冯新刚(1980-), 男, 硕士, 讲师, 主要从事医学影像方面的研究。E-mail: gzfxf1980@163.com

版权所有©2021 中国科学院光电技术研究所

the process of accurately locating vascular pixels and solving image texture loss, a dual-pathway attention guiding structure is constructed to effectively combine the feature map at the bottom and the feature map at the top of the network to improve the accuracy of vascular segmentation. At the same time, Cross-Dice Loss function was introduced to suppress the problem of uneven positive and negative samples and reduce the segmentation error caused by the small proportion of vascular pixels. Experiments were conducted on DRIVE and STARE datasets. The accuracy was 96.56% and 97.32%, the sensitivity was 84.52% and 83.12%, and the specificity was 98.25% and 98.96%, respectively, which proves the good segmentation effect.

Keywords: retinal vessels; ghost convolution; adaptive fusion module; dual-pathway attention guided structure

1 引言

视网膜血管形态结构是反映人体健康的重要指标,其图像的处理与分割对青光眼、心血管疾病和静脉阻塞等多种疾病的早期发现和治疗具有非常重要的意义^[1]。然而,现实中视网膜血管分割面临着眼球末端血管呈交织状分布且轮廓模糊等难题。因此,迫切需要能够自动识别和自动分割血管结构的算法,去帮助医疗人员诊断眼底疾病。

目前,视网膜血管分割算法主要分为无监督和有监督学习方法^[2],其中无监督学习方法主要关注眼底血管原始信息。She等^[3]将Franqi滤波器和方向分数相结合来提取视网膜血管,Hessian矩阵组成的Franqi滤波器可以提高线状物体的平滑性,增强眼底血管与背景对比度。同时引入方向分数去扩展平面维度,使二维血管图像映射到多维平面中以捕获多尺度特征信息,改善微细血管末端交叉相连问题,但该算法并没有很好解决视盘对于血管分割的影响。有监督学习需要先验标记信息,利用人工Label图像对分类器进行特征训练。Liang等^[4]集成可变形卷积到传统U型网络中构成ASU-Net,该算法根据血管形状和尺度自适应地调整感受野,以捕捉结构复杂的视网膜血管,并通过低级特征图与高级特征图相聚合的方式,来实现微血管精确定位,但是需要引入大量卷积算子去学习可变形偏移量,使得训练和测试时间大幅度增加;Wang等^[5]提出HA-Net视网膜血管分割网络,该网络包含一层编码器和三层解码器,首先利用主解码器生成粗略血管分割图并自动确定图像中硬区域和软区域,然后将软硬区域分别输入对应的辅助解码器中进行重新分割,算法存在过度分割现象,致使血管轮廓整体过粗和错误生成假血管分支。

虽然上述算法在分割领域有较好研究成果,但分割视网膜血管时仍存在缺陷,文献^[3]利用方向分数扩展维度,将二维图像结构映射到不同平面,会使眼底

视盘区域、硬性渗出物和正常血管融合,进而影响微血管分割。文献^[4]引入可变形卷积复杂化网络结构,带来大量参数和提高训练时长,不利于算法实际应用。文献^[5]多层解码器并联会使网络出现过拟合情况,生成假血管分支。针对上述存在问题,本文提出一种鬼影卷积自适应视网膜分割算法,先对彩色眼底图片进行RGB(Red、Green、Blue)三通道分离和限制对比度直方图均衡化(CLAHE)处理,增强视网膜微血管与视盘区域对比度,降低光照强度和颜色通道对分割效果的影响。然后将眼底图片输入鬼影卷积自适应网络中进行训练以提取血管特征,U型网络编码器和解码器中普通卷积替换成鬼影卷积,鬼影卷积利用较小计算量生成丰富甚至冗余的特征图,可以有效减少网络参数和训练时长,快速提取出视网膜血管信息。为增加卷积层感受野,多尺度提取目标特征,将自适应融合模块置于神经网络底端。同时利用双路径注意力引导结构级联编码部分和解码部分,解决池化层信息损失和实现语义全局传递,能够更好地保留血管像素,分割出边缘细节更加完整的图片。

2 网络结构

2.1 鬼影模块

神经网络通过卷积层扩展输入特征图数量,产生丰富甚至冗余的信息以保证视网膜血管特征充分提取,但冗余特征也带来大量浮点运算(floating point operations, FLOP)和参数(parameters),导致网络训练时间过长和占用内存过大。眼底图像经过普通卷积输出结果如图1所示,图中存在大量类似结构像彼此幽灵一样,利用这种相似特性本文采用鬼影卷积(ghost convolution)^[6]生成冗余特征图,该卷积利用廉价线性运算替代部分卷积操作,可以有效地减少网络参数和优化网络结构。

鬼影卷积层由两部分组成:第一部分普通卷积(convolution),该部分严格控制通道数量,利用有限滤

波器组 f 对通道和空间进行联合映射输出部分特征图, 此特征图称固定特征图。第二部分鬼影卷积(ghost convolution), 利用廉价线性运算生成与固定特征图具有类似特征的图像, 此图像称为鬼影特征图, 结构如图 2 所示。

鬼影卷积层输出 N 个特征图, 步骤如下:

1) 普通卷积操作, 给定输入数据 $X \in \mathfrak{R}^{H \times W \times C}$ (H 、 W 和 C 分别是输入图像的高度、宽度和通道数), 则普通卷积输出 M 个固定特征图的公式和所需运算量如下:

$$Y = f * X + b, \quad (1)$$

$$O_{\text{FLOP1}} = M \times H \times W \times C \times K \times K, \quad (2)$$

其中: $*$ 表示卷积运算, 输出特征图集合 $Y \in \mathfrak{R}^{H \times W \times M}$, 卷积滤波器组 $f \in \mathfrak{R}^{C \times K \times K \times M}$, 滤波器将数据通道数由 C 变成 M , 特征图数量随通道数变化而改变, $K \times K$ 是卷积核大小, O_{FLOP1} 表示普通卷积浮点运算量。

2) 鬼影卷积操作, 对固定特征图进行廉价线性运算 $\Phi(\cdot)$, 输出 S 个鬼影特征图的公式和运算量如下:

$$y_{ij} = \Phi_{ij}(y'_i) \quad \forall i=1, \dots, M; j=1, \dots, S, \quad (3)$$

$$O_{\text{FLOP2}} = M \times (S-1) \times H \times W \times 1 \times D \times D, \quad (4)$$

其中: y'_i 是输出 Y 中第 i 个固定特征图, y_{ii} 表示第 i 个固定特征图原图, $y_{ij(j \neq i)}$ 表示第 i 个固定特征图经过廉价运算生成的第 j 个鬼影特征图, O_{FLOP2} 表示鬼影卷积浮点运算量, 廉价线性函数 $\Phi(\cdot)$ 滤波器组 $f \in \mathfrak{R}^{1 \times D \times D \times (S-1)}$, 表示将一个固定特征图变化为 $S-1$ 个鬼影特征图, $D \times D$ 为滤波器核大小, M 个固定特征图最终输出 $N = M + M \cdot (S-1)$ 个图像。

鬼影卷积层能够与普通卷积层一样生成视网膜特征图, 因此可以轻松地替换普通卷积层嵌入神经网络架构中降低计算成本。普通卷积核大小为 K , 鬼影卷积核大小为 D , 输出 N 个视网膜特征图浮点运算量之比 F 为

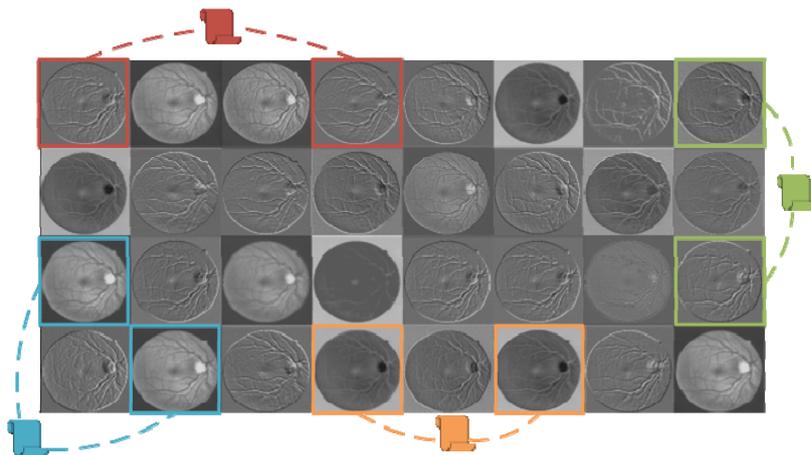


图 1 普通卷积层输出结果

Fig. 1 Common convolution layer output results

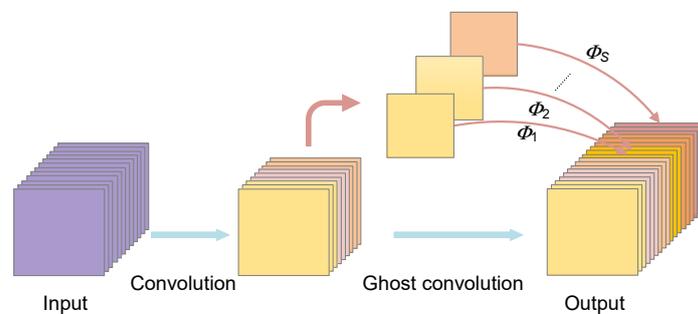


图 2 鬼影卷积层

Fig. 2 Ghost convolution layer

$$F = \frac{N \cdot H \cdot W \cdot C \cdot K \cdot K}{M \cdot H \cdot W \cdot C \cdot K \cdot K + M \cdot (S-1) \cdot H \cdot W \cdot D \cdot D}$$

$$\approx \frac{N \cdot C}{M \cdot C + M \cdot (S-1)} = \frac{S \cdot C}{S + C - 1} \quad (5)$$

在大尺寸高通道图像中, $S \cdot C \gg S + C - 1$ 表明鬼影卷积层具有显著降参能力。鬼影卷积创新, 与普通卷积层利用滤波器组一次性输出所有特征图相比, 鬼影卷积层采用分布式结构逐次输出所需特征图, 首先利用有限滤波器组对视网膜图像进行联合映射输出固定特征图, 在采用廉价线性运算转变固定特征图为鬼影特征图, 此过程降低网络参数和计算量。同时, 普通卷积滤波器核大小是固定不变的, 而鬼影卷积滤波器核大小具有多样性, 使得特征被映射时, 并不是以单一窗口滑动形式进行, 从而带来更为丰富的特征图。

本文利用鬼影卷积层(ghost convolution layer)设计出鬼影模块(ghost module)优化网络结构, 模块结构见图 3。Ghost module 主要由三部分组成: 第一部分扩展鬼影卷积层, 利用鬼影卷积层增加视网膜特征图数量; 第二部分 SE 注意力模块^[7], SE 模块可以动态地抑制与血管任务不相关区域特征, 提高网络分割精度; 第三部分压缩鬼影卷积层, 利用鬼影卷积层减少特征图数量以匹配输出所需。

普通卷积层将输入 $X \in \mathfrak{R}^{H \times W \times C}$ 转化为输出 $Y \in \mathfrak{R}^{H \times W \times N}$, 视网膜特征图数量由 C 变为 N , 完成图像数量扩张和特征提取。在鬼影卷积模块中, 输入 X 经过由 1×1 标准卷积(convolution)、激活函数(ReLU)和批量归一化(batch normalization)处理组成的普通卷积层后, 生成 A 个固定特征图, 再利用扩展鬼影卷积将特征图数量扩充为 $2N$, 相对普通卷积层采用适当计算量实现图像翻倍, 更加充分地提取出眼底信息。提

取出的信息经 SE 模块处理保留与目标任务最紧密特征, 剔除无关因素, 优化输入特征图。SE 模块输出再经过普通卷积层处理生成 B 个固定特征图, 经过廉价线性运算扩充特征图数量为 N 以匹配实际需求。鬼影模块将数量为 N 的特征图扩充为 $2N$, 并利用 SE 模块将无关特征置零和保存目标相关特征, 在由压缩鬼影卷积输出 N 个特征图, 虽然最终输出图像数量没有改变, 但中间过程视网膜图像数量翻倍, 提取出更多有用特征。鬼影模块利用更少计算量实现特征图扩张、优化和压缩, 输出高价值信息。将其放入编码层和解码层可以显著识别血管区域, 扩充相应特征响应并降低网络参数, 充分提取出眼底血管特征。

2.2 自适应特征融合

融合多尺度特征可以增强模型分割性能, 在网络底端引入空洞卷积可以使输入特征图在不连接池化层的情况下扩大感受野, 让卷积后输出拥有更多细节信息。本文基于非对称扩张卷积提出自适应融合模块(adaptive fusion module, AFM), 该模块由一对混合非对称扩张卷积(HADC)^[8]和一个跳跃路径(skip connection)^[9]组成。自适应融合主要思想是通过不同感受野分支捕获不同尺度信息, 从而达到多维特征提取, 整体结构如图 4(a)所示。

混合非对称扩张卷积包含三个三向层(three direction layer, TDL), 各层空洞卷积率(rate)^[10]依次扩大, 分别为 1、2 和 3, 变化的空洞卷积率组合可以保证在扩大感受野同时减少区域像素丢失, 如图 4(b)所示。其中三向层中卷积以并行方式工作, 在 X 和 Y 轴上互补融合血管像素, 如图 4(c)所示。TDL 利用 5×5 空洞卷积探索全局信息, 3×5 空洞卷积补充横向层信息,

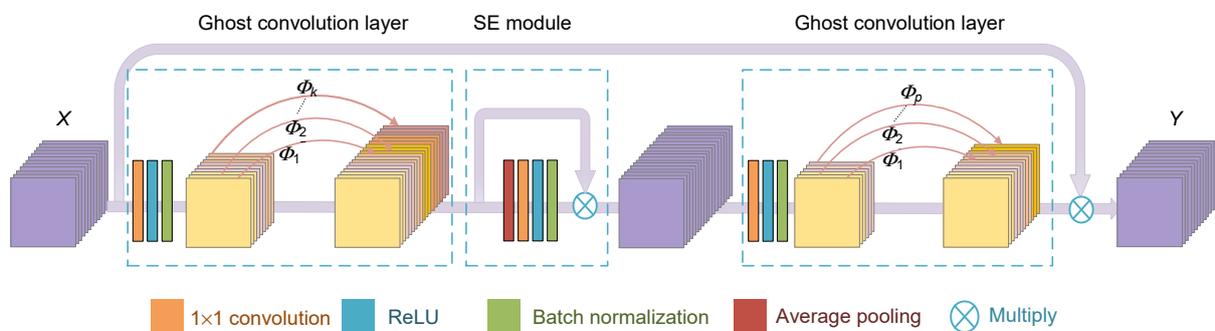


图 3 鬼影模块
Fig. 3 Ghost module

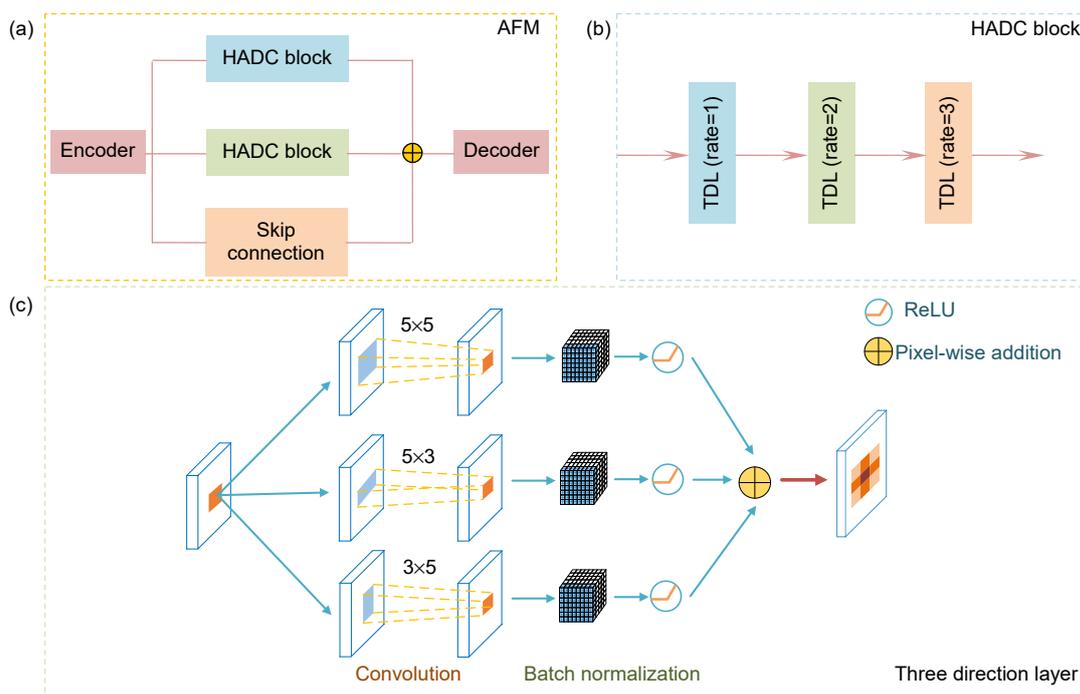


图 4 自适应融合模块
Fig. 4 Adaptive fusion module

5×3 空洞卷积补充纵向层信息，多方向元素交叉融合可以保存高质量细节。支路的跳跃连接由 1×1 卷积构成，用于防止梯度爆炸和梯度消失(导数出现指数上升和下降)。独特的分支结构使得自适应融合模块能够增加卷积层感受野，从而探索多维区域尺度特征和提取全局语义信息。该模块将编码部分信息进行自适应融合后输入解码部分预测分类，可以保留视网膜血管深层像素。

2.3 注意力机制

U-Net^[11]原始上下采样方式容易丢失底层特征,难以高精度预测出视网膜血管轮廓。因此增强眼底血管

像素对于提高分割精度十分重要，注意力引导(AG)结构通过跳跃式连接将低级特征图(编码层特征图)与高级特征图(解码层特征图)级联，增强眼底像素传递，改善血管细节模糊现象，结构如图 5 所示。 x^h 是高级特征图， x^l 是低级特征图，低级和高级特征图先用 1×1 卷积处理并相加，在用 1×1 卷积提取血管特征，ReLU 激活函数防止梯度消失，Sigmoid 函数获取注意力系数 $\epsilon \in [0,1]$ ，注意力系数与高级特征图 x^h 相乘确定其权重，与目标任务关系越紧密的图像被保留的特征越多。

单路径注意力引导结构可能会导致空间图像产生噪声，影响模型分割的鲁棒性，因此本文将单路径引

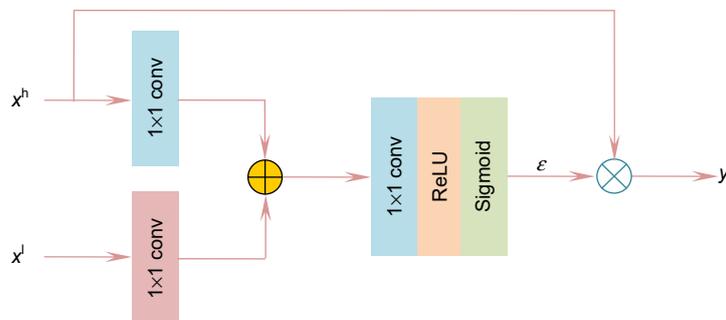


图 5 注意力引导结构
Fig. 5 Attention guided structure

导结构改进成双路径引导(dual-pathway attention guided, DAG)结构, 结构如图 6 所示。双路径引导能够产生二个注意力系数, 输出 y_1 是确定权重的高级特征图 x^h , 输出 y_2 是确定权重的低级特征图 x^l , 二者相加并用 1×1 卷积、批量归一化(BN)和 ReLU 激活函数处理得到最终输出 y , 添加双路径引导结构使得图像边缘更加清晰。

2.4 网络结构

视网膜血管拥有复杂的形态结构和多变的尺度信息, 为确保算法可以融合全局信息, 分割出更多微细血管数目, 本文提出鬼影卷积自适应视网膜血管分割算法, 网络整体结构如图 7 所示。鬼影卷积自适应网络(GANet)主体由图像预处理(image preprocessing)、编码器、解码器和连接部分共同组成。原始眼底图像尺

度为 $565 \times 584 \times 3$, 预处理先将眼底图片裁剪成 $64 \times 64 \times 1$, 再输入到神经网络中进行训练。网络左半部为编码器用于视网膜血管特征提取, 由鬼影模块(ghost module)和最大池化层(maxpooling)组成, 对眼底图像进行空间维度收缩和通道扩张, 将尺度为 $64 \times 64 \times 1$ 的眼底图像变成 $4 \times 4 \times 512$ 。网络右半部为解码器用于类别预测, 由上采样(upsampling)和鬼影模块组成, 将 $4 \times 4 \times 512$ 尺度图像恢复为 $64 \times 64 \times 1$ 。连接部分分为自适应融合模块(AFM)和双路径注意力引导结构(DAG), 其中自适应融合模块置于网络下层, 连接神经网络底端编码器和解码器, 交叉融合血管像素, 减少特征丢失和保存高质量细节。双路径注意力引导结构置于网络上中层, 级联相应解码层和编码层, 结合低级特征图和高级特征图, 降低池化层对信息的损害, 提高血管像素定位精度。网络末端是 Sigmoid 激

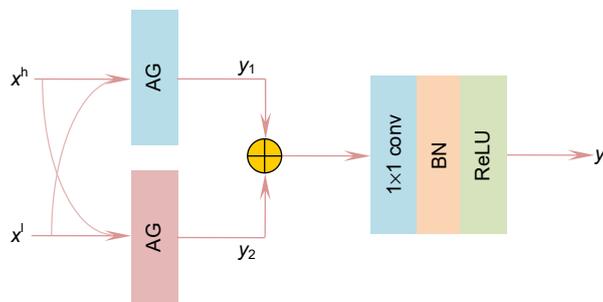


图 6 双路径注意力引导结构
Fig. 6 Dual-pathway attention guided structure

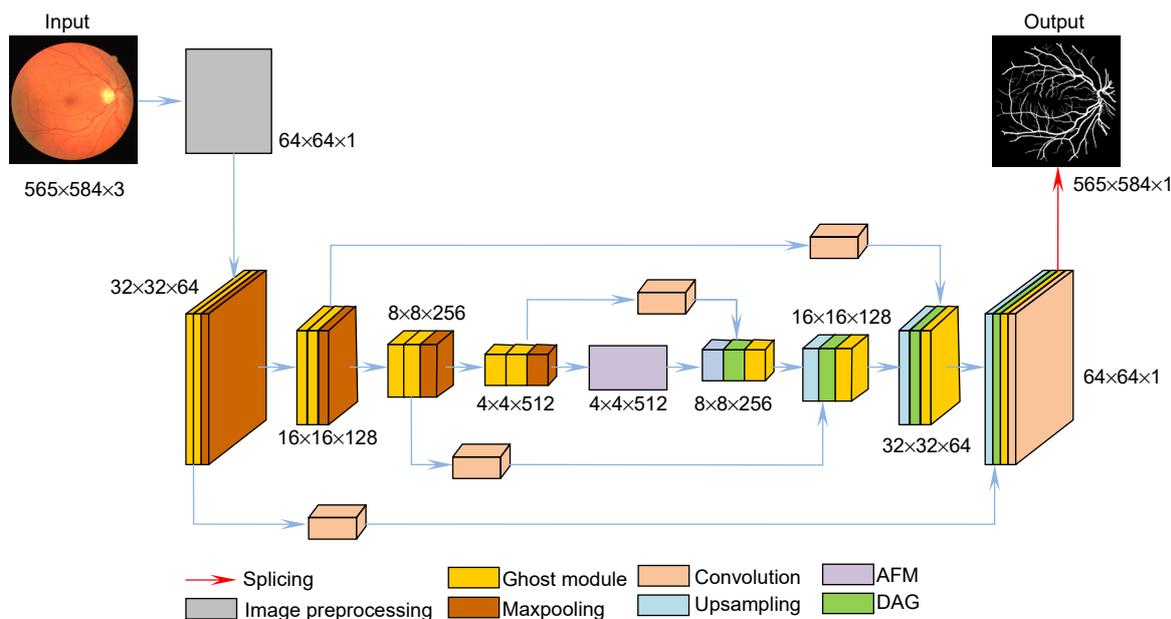


图 7 鬼影卷积自适应网络
Fig. 7 Ghost convolution adaptive network

活函数, 对血管和背景进行分类得到 $64 \times 64 \times 1$ 的分割结果图, 最后拼接(splicing)裁剪结果图得到最终血管分割结果。此外, 本文引入新型混合损失(Cross-Dice Loss)函数来抑制正负样本不均问题, 减少因血管像素占图片整体像素比例较小而引起的分割误差, 从而得到更为优异地分割结果。

2.5 损失函数

视网膜血管分割任务中常用交叉熵损失(Cross-entropy Loss)函数衡量模型预测的好坏, Cross-entropy Loss 基于像素平均值预测, 面对血管像素占眼底图像整体像素比例较小时, 会使预测偏向背景目标。Dice-coefficient Loss 可以引入权重来缓解类别间不平衡的影响, 关注预测与事实之间重叠, 但分割眼底图像边界时效果较差。将 Dice-coefficient Loss 和 Cross-entropy Loss 混合成一种新型损失(Cross-Dice Loss)函数用于本文算法评估, 可以很好地适应前景与背景像素比例不平衡的分割任务, 表现出预测结果与实际结果的区别, 新损失函数定义为

$$L(Y, \hat{Y}) = -\frac{1}{B} \sum_{a=1}^A \sum_{b=1}^B (y_{ab} \log \hat{y}_{ab} + \frac{2y_{ab} \cdot \hat{y}_{ab}}{y_{ab}^2 + \hat{y}_{ab}^2}), \quad (6)$$

其中: $y_{ab} \in Y$ 、 $\hat{y}_{ab} \in \hat{Y}$ 分别为批处理中第 a 类第 b 个像素的真实标签和预测标签, Y 、 \hat{Y} 是视网膜血管真实值和预测值。

3 实验结果与分析

3.1 数据集与图像预处理

本文采用公开数据库中的 DRIVE 和 STARE 数据集作为实验数据集, DRIVE 数据库中包含 40 张彩色眼底图片, 官方已经将数据集进行手工分割且分为训练集和测试集。STARE 数据库中包含 20 张彩色眼底

图片, 将数据集平均分成五份, 采用五折交叉验证方式进行实验。为获取更好实验结果, 需要对原始眼底图像进行预处理再输入到模型中训练, 预处理的步骤如下。

1) 图像扩充: DRIVE 和 STARE 数据集中包含图片数量较少, 采用沿轴 18° 旋转采样, 将数据集扩充 20 倍, 以增加网络训练样本量。

2) RGB(Red、Green、Blue)三通道处理: 将眼底图像分离成 RGB 三通道特征图, 发现绿色通道对比其他通道亮度适中、血管与背景对比度好, 故选用绿色通道图片作为预处理后续图片。

3) 限制对比度直方图均衡化(CLAHE)处理: CLAHE 处理在增强血管与背景对比度的同时不放大噪声, 使处理后的眼底图片更加平滑。均衡化后采用伽马变换对图片较暗部分进行亮度提升, 增强图片可视度, 预处理如图 8 所示。

3.2 实验环境和参数设置

实验电脑仿真平台是 PyCharm, 实验环境是 TensorFlow2.0 开源框架, 电脑配置为 Intel® Core™ i7-6700H CPU, 16 GB 内存, Nvidia GeForce GTX 2070 GPU, 64 位 Win10 操作系统。

采用 Adam 算法优化 Cross-Dice Loss 函数, 加快目标函数收敛速度, 迭代次数设置为 100, 网络初始学习率设置为 0.0005, 训练批量设置为 16, 训练集中 20% 样本作为验证集。

3.3 评价指标

本文用准确度(accuracy, 简称为 Acc, 在式中写为 A_{cc})、敏感度(sensitivity, 简称为 Sen, 在式中写为 S_{en})、特异性(specificity, 简称为 Spe, 在式中写为 S_{pe})

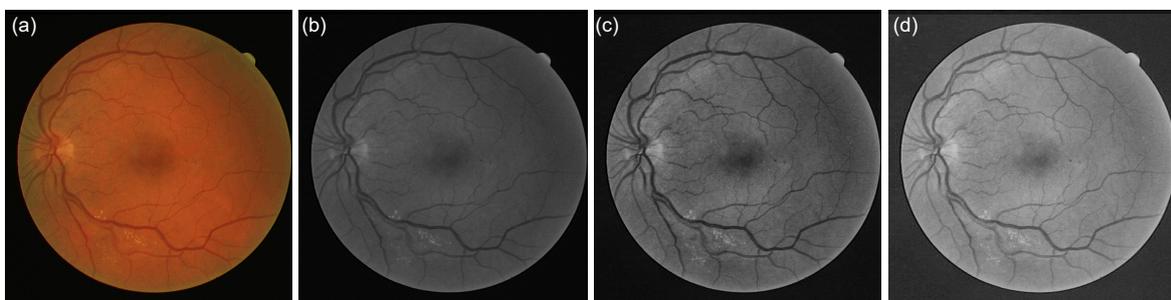


图 8 预处理图像。(a) 原图; (b) 绿色通道图; (c) CLAHE 图; (d) 伽马变换图

Fig. 8 Preprocessed image. (a) Original image; (b) Green channel image; (c) CLAHE image; (d) Gamma transform image

和受试者工作特征曲线(ROC)下方的面积 AUC 这四个指标来评估算法性能。其中, 敏感度表示检测血管像素数量与真实血管像素数量的比率; 特异性表示检测非血管像素的数量与真实非血管像素数量的比率; 准确度表示准确分类像素数量与图像中总像素数量的比率。

$$A_{cc} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N}, \quad (7)$$

$$S_{en} = \frac{T_p}{T_p + F_N}, \quad (8)$$

$$S_{pe} = \frac{T_N}{T_N + F_p}, \quad (9)$$

其中: T_p 为真阳性, 正确分类的血管像素, T_N 为真阴性, 正确分类非血管像素; F_p 为假阳性, 错误分类为血管像素, F_N 为假阴性, 错误分类为非血管像素。

3.4 不同算法主观性对比

为验证鬼影卷积自适应网络(GANet)分割血管的有效性, 选取文献[11]中 U 型网络(U-Net)、文献[12]中密集卷积长短期记忆网络(BCDU-Net)、文献[13]中双层 U 型网络(DoubleU-Net)和文献[14]中蝶形全卷积神经网络(BFCN)与本文算法(GANet)进行主观性对比。编码器和解码器对称连接, 形似英文字母 U 的网络称为 U 型网络(U-Net), 编码器用于压缩图片进行特征提取, 解码器用于恢复图片尺寸进行分类预测。BCDU-Net 是在 U 型网络编码层和解码层中添加密集卷积块, 并用记忆神经元级联而成的网络。DoubleU-Net 由双层 U 型网络并联组成, 前层采用 VGG-19 预训练框架, 后层类似 U-Net 结构, 并联框架可以多层次提取血管像素。BFCN 编码层由多尺度信息提取块构成, 同时利用传输层串联网络整体结构, 可以多尺度提取血管特征。普通卷积自适应网络

(CANet)是将鬼影卷积还原成普通卷积, 其余结构与本文算法一致。将上述六种算法置于同一实验环境下进行测试, 不同算法对比结果见表 1, 其中最优指标加粗表示。

表 1 可以看出, 本文网络 GANet 综合性能比较好, 网络参数(parameters)为 27400454, 低于上述五种算法, 仅为 CANet 的 75.62%, 证明鬼影卷积具有显著降低网络参数功能。同时单轮训练时长分别为 152 s、286 s、294 s、422 s、348 s 和 244 s。GANet 训练时间虽高于 U-Net 少许, 但低于其余四种网络, 仅为 CANet 的 70.11%。U-Net 未添加任何模块以最简单形式组成, 使得训练最短, 但本文算法其他指标均高于 U-Net, 能更好地平衡时间与准确率关系。

在 DRIVE 数据集上除特异性(Spe)指标外, 本文准确度(Acc)、敏感度(Sen)和 AUC 值均为最高, 分别为 0.9656、0.8452 和 0.9869。DoubleU-Net 由双层 U 型网络构成, 训练时可能出现过拟合现象, 进而生成假血管分支, 使特异性值高于本文算法, 但本文算法准确度和敏感度更高, 血管误分割率更低。在 STARE 数据集上除 AUC 值比 CANet 低 0.01%外其余指标均高于上述五种算法, 说明本文算法综合性能优于传统算法。图 9 展示不同算法视网膜血管分割结果, 前三幅是 DRIVE 数据集图片, 后三幅是 STARE 数据集图片, 其中 9(a)代表数据库中原始彩色图, 9(b)代表医学专家手工分割结果称金标准, 9(c)~9(h)分别代表 U-Net、BCDU-Net、DoubleU-Net、BFCN、CANet 和 GANet 分割结果。在第一幅和第三幅图片中, U-Net、BCDU-Net、DoubleU-Net 和 BFCN 分割眼底视盘区域时不能有效地辨别视盘和血管轮廓, 容易将视盘误分割为血管, 导致其周围主血管链结, 而 GANet 能够较好地识别视盘与血管, 避免假血管生成。第二幅眼底

表 1 不同算法对比结果

Table 1 Comparison results of different algorithms

Method	DRIVE				STARE				Parameters	Time/s
	Acc	Sen	Spe	AUC	Acc	Sen	Spe	AUC		
U-Net	0.9637	0.8250	0.9830	0.9856	0.9653	0.7958	0.9857	0.9831	28245825	152
BCDU-Net	0.9638	0.8292	0.9826	0.9857	0.9659	0.8054	0.9791	0.9878	29288325	286
DoubleU-Net	0.9642	0.8201	0.9843	0.9862	0.9667	0.7991	0.9854	0.9851	31837850	294
BFCN	0.9639	0.8313	0.9824	0.9859	0.9687	0.8227	0.9862	0.9893	48224433	422
CANet	0.9645	0.8374	0.9822	0.9867	0.9729	0.8185	0.9873	0.9901	36232127	348
GANet	0.9656	0.8452	0.9825	0.9869	0.9732	0.8312	0.9896	0.9900	27400454	244

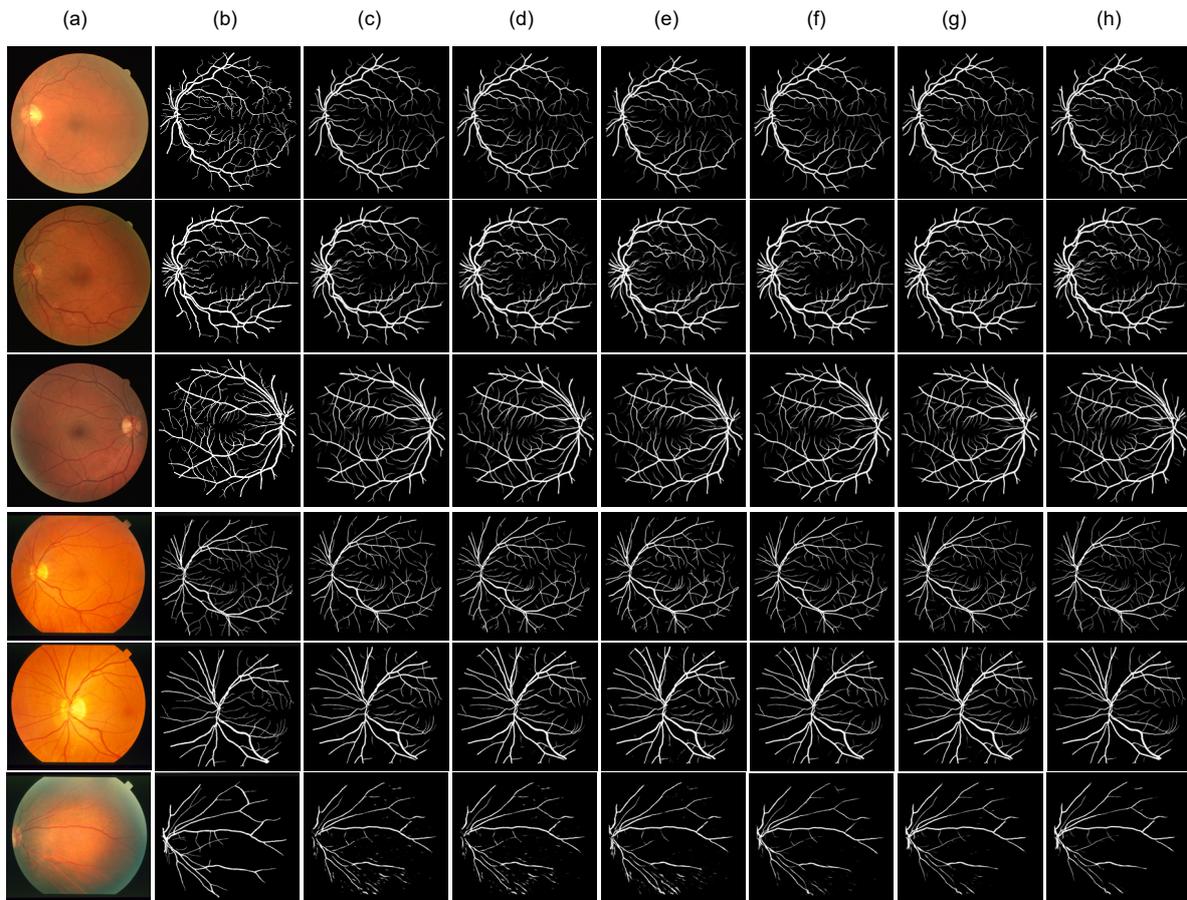


图 9 不同算法分割结果。

(a) 原图; (b) 金标准; (c) U-Net 图; (d) BCDU-Net 图;
(e) DoubleU-Net 图; (f) BFCN 图; (g) CANet 图; (h) GANet 图

Fig. 9 Segmentation results of different algorithms. (a) Original image; (b) Gold standard image; (c) U-Net image; (d) BCDU-Net image; (e) DoubleU-Net image; (f) BFCN image; (g) CANet image; (h) GANet image

图片左下角存在病变现象, DoubleU-Net、BCDU-Net 和 CANet 抑制病理信息能力较差, 病变区域主管模糊和缺失, 而 U-Net、BFCN 和 GANet 在分割病变血管时, 能够剔除病变斑点, 减少血管缺失程度。GANet 可以捕获更多微细血管数目, 使末端细小血管与主干血管平滑连接, 第四幅和第五幅图片可以看出其他分割算法微细血管丢失情况严重, 造成评价时灵敏度较低。第六幅图片血管附近有明显的硬性渗出物, 渗出物容易引起交叉处血管错误连接, 同时掩盖细小血管脉络走势, 使目标区域产生伪影, GANet 和 CANet 丰富的特征提取使得硬性交叉处血管也能平滑融合, 减小无关斑点生成, 而其他算法则有不同程度的伪影, 其渗出物的识别证明本文算法及其变形算法的鲁棒性更强。

进一步清晰展现分割结果, 图 10 和图 11 给出

DRIVE 和 STARE 数据集分割细节, 并用颜色强化血管与背景像素, 其中 10(a) 和 11(a) 代表灰色或彩色原图, 10(b) 和 11(b) 代表金标准细节图, 10(c)~10(h) 和 11(c)~11(h) 分别代表 U-Net、BCDU-Net、DoubleU-Net、BFCN、CANet 和 GANet 分割细节图。图 10 展示的是图 9 中第三幅眼底图像, 由橙色和红色圆圈可以看出本文算法能够分割出更多微细血管, 而其他算法在分割末端血管时效果欠缺。

图 11 展示的是图 9 中第六幅眼底图像, 由橙色和红色圆圈可以看出本文算法能够识别血管硬性渗出物, 避免伪影生成。通过直观细节对比, 体现出本文算法能够平滑地拟合主干血管和微细血管, 保证视网膜血管分割完整性和准确性, 实验对比细节图说明鬼影卷积自适应网络对 DRIVE 和 STARE 中的眼底图片具有较好的分割能力。

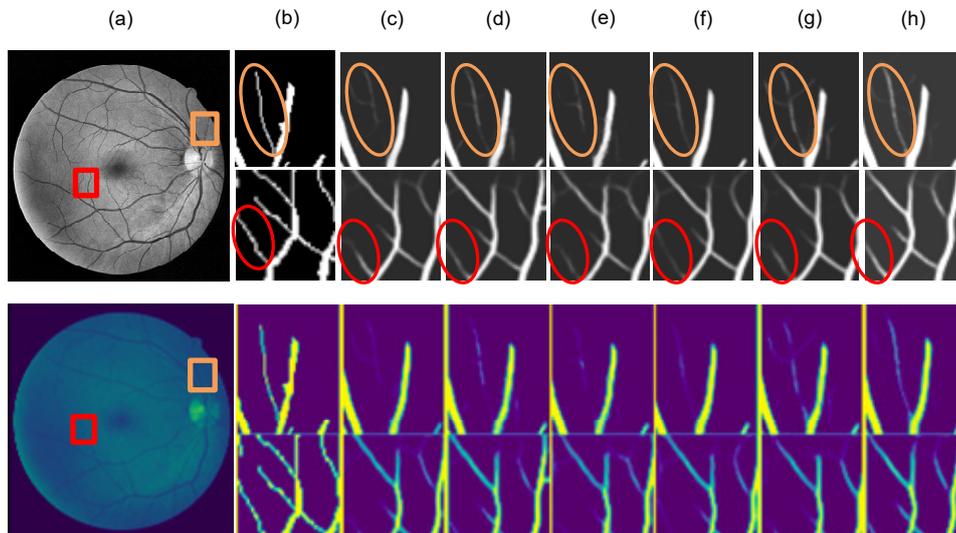


图 10 DRIVE 数据集分割细节。

(a) 原图; (b) 金标准细节图; (c) U-Net 细节图; (d) BCDU-Net 细节图;
 (e) DoubleU-Net 细节图; (f) BFCN 细节图; (g) CANet 细节图; (h) GANet 细节图

Fig. 10 DRIVE dataset segmentation details.

(a) Original image; (b) Gold standard detail image; (c) U-Net detail image;
 (d) BCDU-Net detail image; (e) DoubleU-Net detail image; (f) BFCN detail image;
 (g) CANet detail image; (h) GANet detail image

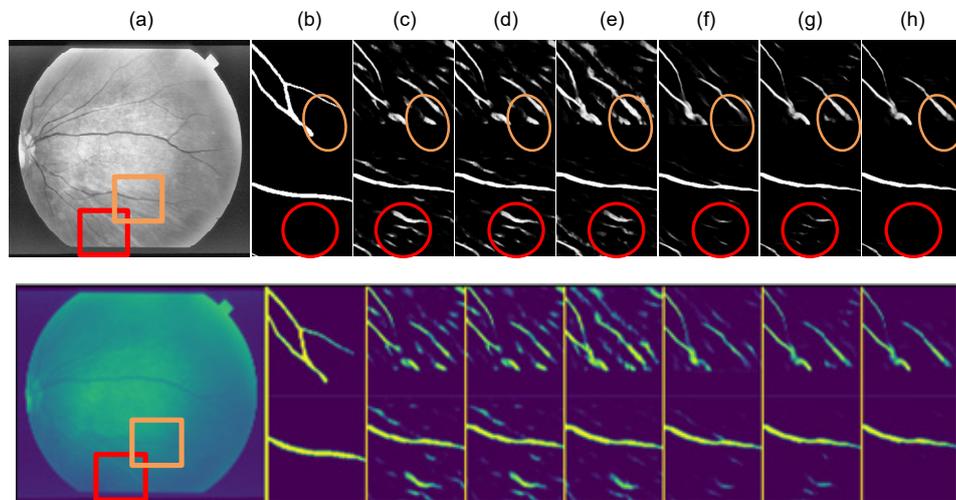


图 11 STARE 数据集分割细节。

(a) 原图; (b) 金标准细节图; (c) U-Net 细节图; (d) BCDU-Net 细节图;
 (e) DoubleU-Net 细节图; (f) BFCN 细节图; (g) CANet 细节图; (h) GANet 细节图

Fig. 11 STARE dataset segmentation details.

(a) Original image; (b) Gold standard detail image; (c) U-Net detail image;
 (d) BCDU-Net detail image; (e) DoubleU-Net detail image; (f) BFCN detail image;
 (g) CANet detail image; (h) GANet detail image

为更加直观地显现 GANet 优越性, 图 12 和图 13 给出 DRIVE 数据集上的受试者工作特征(ROC)曲线图

12(a)和精度召回率(PR)曲线图 13(a)走势。ROC 曲线以真阳性率(TPR)为纵坐标, 假阳性率(FPR)为横坐标,

巧妙地以图示方法揭示灵敏度和特异性关系。ROC 图中曲线越靠近左上角表明实验准确性越高, 假阳性率和假阴性率占比越低, 由图 12 放大图 12(b)看出本文算法 GANet 曲线走势最靠近左上角, 分类视网膜图片像素时错误分类为血管像素概率最低。

PR 曲线中 P 代表精准率(Precision), R 代表召回率(Recall), 图像蕴含精准率与召回率关系, 每条 PR 曲线对应一个阈值。PR 曲线越靠近右上角表明正负样本区分效果越好, 由图 13 放大图 13(b)可以看出本文算法 GANet 曲线走势最靠近右上角, 分类视网膜图片像素时错误分类为非血管像素概率最低。

损失函数可以估量模型预测值与真实值不一致程度, 图 14 给出不同算法在 STARE 数据集上训练损失曲线和测试损失曲线走势图。

3.5 不同算法客观性对比

本文算法与其他文献方法进行客观性对比, 不同算法客观性对比结果见表 2, 其中最优指标加粗表示。本文算法在 DRIVE 和 STARE 数据集上评价指标: 准确率(Acc)为 96.56%和 97.32%, 敏感度(Sen)为 84.52%和 83.12%, 特异性(Spe)为 98.25%和 98.96%, AUC 值为 98.69%和 99.00%。通过数据证明本文算法性能对比

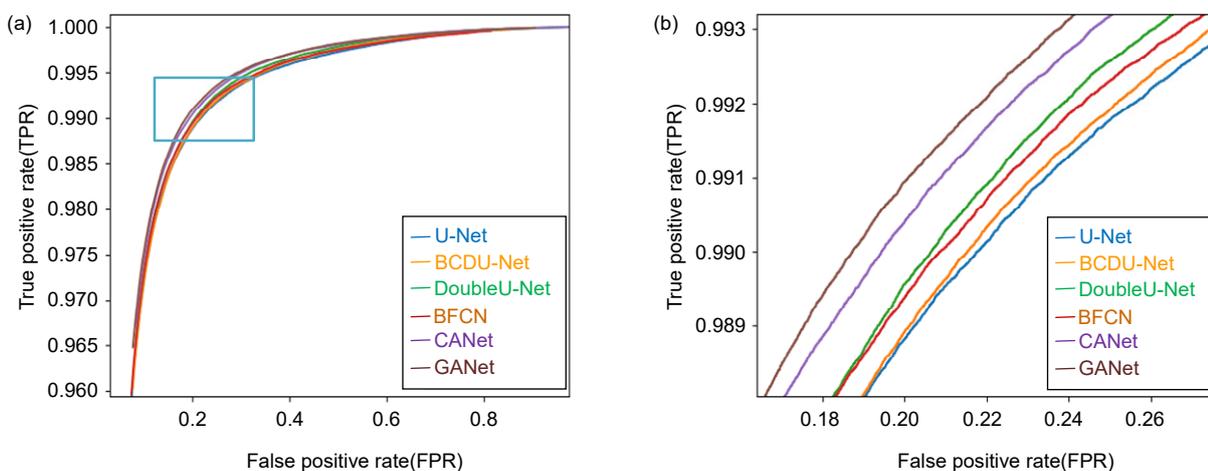


图 12 受试者工作特征曲线
Fig. 12 Receiver operating characteristic curve

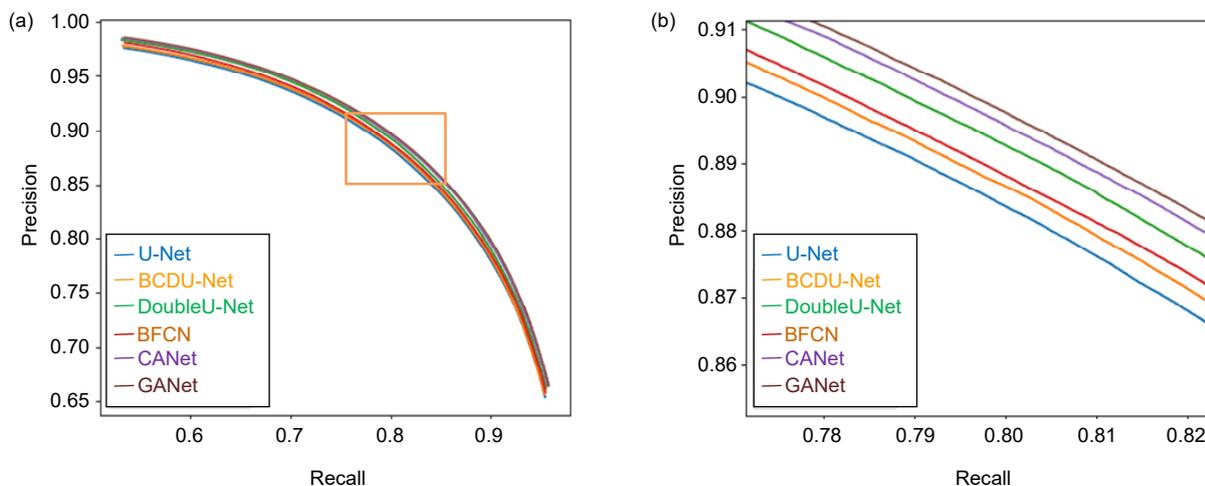


图 13 精度召回率曲线
Fig. 13 Precision recall curve

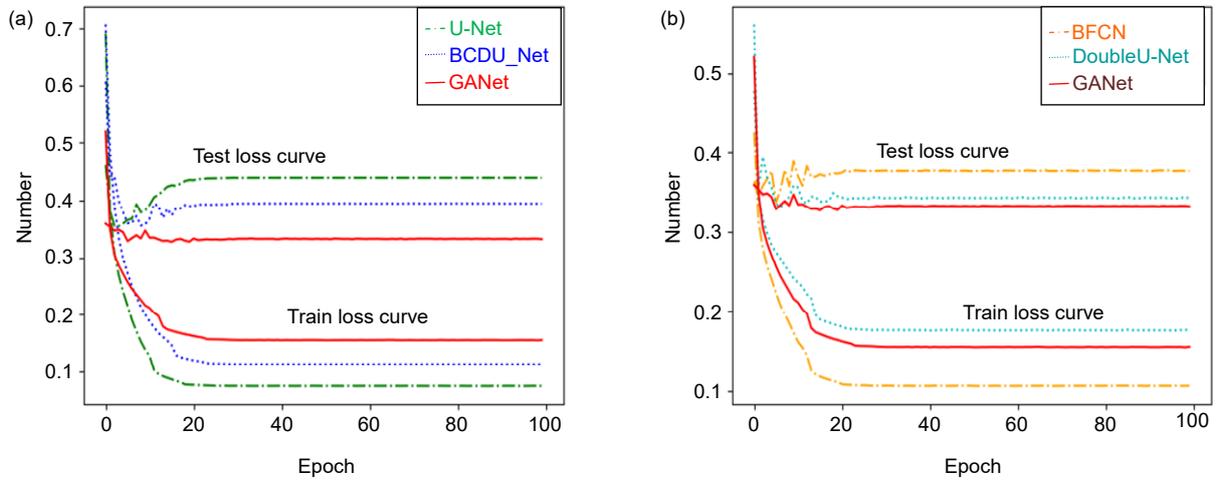


图 14 损失曲线
Fig. 14 Loss curve

表 2 不同算法客观性对比结果

Table 2 Objective comparison results of different algorithms

Method	DRIVE				STARE			
	Acc	Sen	Spe	AUC	Acc	Sen	Spe	AUC
Ref.[15]	0.9542	0.7653	0.9818	0.9752	0.9612	0.7581	0.9846	0.9801
Ref.[16]	0.9557	0.7890	0.9799	0.9774	0.9620	0.7798	0.9822	0.9791
Ref.[17]	0.9566	0.7963	0.9800	0.9802	0.9641	0.7595	0.9878	0.9832
Ref.[18]	0.9568	0.7921	0.9810	0.9806	0.9678	0.8352	0.9823	0.9875
Ref.[19]	0.9574	0.8083	0.9790	0.9822	0.9695	0.8162	0.9869	0.9898
Ref.[20]	0.9576	0.8039	0.9804	0.9821	0.9694	0.8315	0.9858	0.9905
Ref.[21]	0.9582	0.7996	0.9813	0.9830	0.9672	0.7963	0.9863	0.9875
Ref.[22]	0.9667	0.8221	0.9817	0.9853	0.9724	0.8210	0.9859	0.9897
Ref.[23]	0.9554	0.8160	0.9756	0.9799	0.9723	0.7551	0.9903	0.9863
Ref.[24]	0.9609	0.8282	0.9738	0.9786	0.9646	0.8979	0.9701	0.9892
GANet	0.9656	0.8452	0.9825	0.9869	0.9732	0.8312	0.9896	0.9900

其他视网膜分割算法具有明显优势, 实验对比结果说明鬼影卷积自适应网络(GANet)对 DRIVE 和 STARE 库中视网膜图片具有较好地分割能力。文献[16]利用可变形卷积去代替普通卷积, 并采用双路径注意力引导结构级联编码器和解码器, 可变形卷积包含偏移量学习, 可以动态地调整卷积核目标内容进行自适应采样, 但二个数据集四项指标均低于本文算法, 其中精度比本文低 0.99%和 1.12%, 敏感度比本文低 5.62%和 5.14%, 特异性比本文低 0.26%和 0.74%, 鬼影卷积提取视网膜血管能力强于可变形卷积。文献[20]基于尺

度空间逼近卷积神经网络对视网膜血管进行分割, 该网络应用上采样多尺度结构增加交换感受野, 提高微薄结构血管分割和边界轮廓定位, 同时引入剩余块辅助网络感受野变化, 在 STARE 数据集中其精度和特异性均比本文低 0.38%, 敏感度和 AUC 值比本文高 0.03%和 0.05%, 表明自适应融合模块和上采样多尺度结构对血管像素融合各有优劣。文献[22]提出实时模糊形态学视网膜血管分割算法, 无监督学习方法利用模糊集理论和模糊逻辑算子去处理不确定和信息缺失的血管, 并用黑顶帽操作增强微血管区域像素, 提高分割

精度, 在 DRIVE 数据集中该算法准确率最高 96.67%, 比本文高 0.11%, 但是敏感度、特异性和 AUC 值均低于本文, 敏感度低 2.31%, 特异性低 0.08%, AUC 值低 0.16%, 说明有监督学习方法在分割血管轮廓时效果优于无监督学习方法。文献[23]和文献[24]采用交叉熵损失函数评估算法模型, 在面对类别间不平衡时, 很难权衡敏感度和特异性。相比 DRIVE 数据集 STARE 数据集中眼底图像尺寸更大, 血管像素占图片整体像素比例更小。文献[23]利用金字塔思想, 将图像放大不同尺度再输入网络中训练, 使特异性最高 99.03%, 但敏感度为 75.51%。文献[24]采用迁移学习预训练模型, 并将学习的多级别多尺度特征融合以消除错误分割, 使敏感度最高 89.79%, 但特异性为 97.01%。本文采用 Cross-Dice Loss 函数评估算法整体性能, 可以很好地适应前景与背景像素比例不平衡的分割任务, 权衡敏感度和特异性之间关系, 算法敏感度和特异性分别为 83.12%和 98.96%, 综合分析不同算法, 得出鬼影卷积自适应网络性能优异。

3.6 消融研究

鬼影卷积自适应网络(GANet)生成丰富的视网膜特征图, 并自适应融合血管特征, 更好地保留血管像素, 从而分割出边缘细节更加完整的眼底图片。为验证鬼影卷积自适应网络(GANet)各模块有效性, 本文在 DRIVE 和 STARE 数据集上进行消融研究。GANet_1 以普通卷积层为基础加入自适应融合模块(AFM)和双路径引导结构(DAG), GANet_2 将普通卷积层替换成鬼影卷积模块, 并加入双路径引导结构(DAG), GANet_3 将普通卷积层替换成鬼影卷积模块, 并加入自适应融合模块(AFM), 表 3 显示消融实验结果。

消融实验显示本文算法各模块具体作用, 其中 GANet_1 和 GANet 区别在于是否加入鬼影卷积模块, 鬼影卷积模块对比普通卷积层可以产生更丰富的特征图, 充分提取眼底信息, 分割出更多微细血管,

GANet_1 和 GANet 准确度分别为 96.45%和 96.56%, 敏感度分别为 83.74%和 84.52%, 明显提高算法准确度和敏感度。GANet_2 在鬼影卷积模块基础上引入双路径引导结构, 级联编码器和解码器, 解决池化层信息损失和实现语义全局传递, 更好地保留血管像素, 分割出边缘细节更加完整的图片, 使敏感度达到最优 85.06%和 83.36%。GANet_3 在鬼影卷积模块基础上引入自适应融合模块, 增加卷积层感受野, 多尺度提取目标特征, 使特异性达到最优 98.51%和 99.29%。本文算法在鬼影卷积基础上加入了自适应融合模块和双路径引导结构, 在提高算法准确度的同时权衡敏感度和特异性。

4 结 论

本文针对视网膜血管难以高精度分割, 提出鬼影卷积自适应视网膜血管分割算法。算法先对数据库中图片进行预处理, 增强眼底图像可识别度。训练网络编码和解码器中普通卷积被替换为鬼影卷积, 利用鬼影卷积快速生成丰富特征图的优势, 充分提取血管特征。编码层捕获信息经过自适应融合模块后输入解码层中分类, 自适应模块利用非对称卷积核交叉融合血管像素, 高质量保存视网膜血管细节。为弱化池化层噪声干扰, 采用双路径注意力引导结构级联低级特征图与高级特征图, 让视网膜特征能够全局传递。此外, 本文引入新型混合损失(Cross-Dice Loss)函数来抑制正负样本不均问题, 减少因前景占比少而引起的分割误差, 得到优异分割结果。实验结果表明, 本文算法综合性能优于现有算法, 其分割精度数值较高, 对于眼科疾病诊断拥有一定应用价值。虽然鬼影卷积能够生成丰富的特征图, 但不能很好地确定每张图片信息度, 无法辨别出高质量特征图。未来将研究如何巧妙地融合可变形学习量, 通过网络学习自动增加高维信息特征图权重, 提高视网膜血管分割精度。

表 3 各模块消融研究

Table 3 Ablation study of each module

Method	DRIVE				STARE			
	Acc	Sen	Spe	AUC	Acc	Sen	Spe	AUC
GANet_1	0.9645	0.8374	0.9822	0.9867	0.9729	0.8185	0.9873	0.9901
GANet_2	0.9650	0.8506	0.9801	0.9868	0.9730	0.8336	0.9892	0.9906
GANet_3	0.9607	0.7865	0.9851	0.9823	0.9699	0.8171	0.9929	0.9892
GANet	0.9656	0.8452	0.9825	0.9869	0.9732	0.8312	0.9896	0.9900

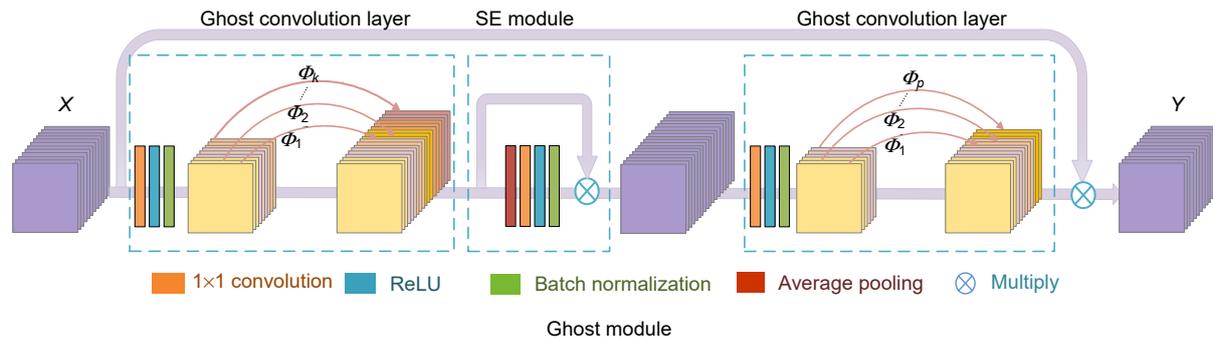
参考文献

- [1] Xu G Z, Wang Y W, Hu S, et al. Retinal vascular segmentation combined with PCNN and morphological matching enhancement[J]. *Opto-Electron Eng*, 2019, **46**(4): 180466.
徐光柱, 王亚文, 胡松, 等. PCNN 与形态匹配增强相结合的视网膜血管分割[J]. *光电工程*, 2019, **46**(4): 180466.
- [2] Liu X M, Cao J, Fu T Y, et al. Semi-supervised automatic segmentation of layer and fluid region in retinal optical coherence tomography images using adversarial learning[J]. *IEEE Access*, 2018, **7**: 3046–3061.
- [3] She L H, Guo Y R, Zhang S. Retinal vessel segmentation algorithm based on orientation scores and Frangi filter[J]. *J North-east Univ (Nat Sci)*, 2020, **41**(2): 182–187.
余黎煌, 郭一蓉, 张石. 基于方向分数和 Frangi 滤波器的视网膜血管分割算法[J]. *东北大学学报(自然科学版)*, 2020, **41**(2): 182–187.
- [4] Liang L M, Sheng X Q, Lan Z M, et al. U-shaped retinal vessel segmentation algorithm based on adaptive scale information[J]. *Acta Optica Sinica*, 2019, **39**(08): 126–140.
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**(08): 126–140.
- [5] Wang D Y, Haytham A, Pottenburgh J, et al. Hard attention net for automatic retinal vessel segmentation[J]. *IEEE J Biomed Health Inform*, 2020, **24**(12): 3384–3396.
- [6] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 1577–1586.
- [7] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2018: 7132–7141.
- [8] Zheng X W, Huan L X, Xia G S, et al. Parsing very high resolution urban scene images by learning deep ConvNets with edge-aware loss[J]. *ISPRS J Photogrammetry Remote Sens*, 2020, **170**: 15–28.
- [9] Zhang S D, He F Z. DRCDN: learning deep residual convolutional dehazing networks[J]. *Vis Comput*, 2020, **36**(9): 1797–1808.
- [10] Wang Y J, Hu S Y, Wang G D, et al. Multi-scale dilated convolution of convolutional neural network for crowd counting[J]. *Multimed Tools Appl*, 2020, **79**(1–2): 1057–1073.
- [11] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//*18th International Conference on Medical Image Computing and Computer Assisted Intervention*. 2015: 234–241.
- [12] Azad R, Asadi-Aghbolaghi M, Fathy M, et al. Bi-directional ConvLSTM U-Net with densely connected convolutions[C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*. 2019: 406–415.
- [13] Jha D, Riegler M A, Johansen D, et al. DoubleU-Net: a deep convolutional neural network for medical image segmentation[C]//*2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*. 2020: 558–564.
- [14] Jiang Y, Wang F L, Gao J, et al. Efficient BFCN for automatic retinal vessel segmentation[J]. *J Ophthalmol*, 2020, **2020**: 6439407.
- [15] Yan Z Q, Yang X, Cheng K T. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation[J]. *IEEE Trans Biomed Eng*, 2018, **65**(9): 1912–1923.
- [16] Li H, Wang Y K, Wan C, et al. MAU-Net: a retinal vessels segmentation method[C]//*2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. 2020: 1958–1961.
- [17] Jin Q G, Meng Z P, Pham T D, et al. DUNet: a deformable network for retinal vessel segmentation[J]. *Knowl Based Syst*, 2019, **178**: 149–162.
- [18] Li X, Jiang Y C, Li M L, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. *IEEE Trans Industr Inform*, 2021, **17**(3): 1958–1967.
- [19] Tang P, Liang Q K, Yan X T, et al. Multi-proportion channel ensemble model for retinal vessel segmentation[J]. *Comput Biol Med*, 2019, **111**: 103352.
- [20] Oliveira A, Pereira S, Silva C A. Retinal vessel segmentation based on fully convolutional neural networks[J]. *Expert Syst Appl*, 2018, **112**: 229–242.
- [21] Wu Y C, Xia Y, Song Y, et al. NFN+: a novel network followed network for retinal vessel segmentation[J]. *Neural Netw*, 2020, **126**: 153–162.
- [22] Guo F, Li W Q, Kuang Z H, et al. MES-Net: a new network for retinal image segmentation[J]. *Multimed Tools Appl*, 2021, **80**(10): 14767–14788.
- [23] Tang Y, Rui Z Y, Yan C F, et al. ResWnet for retinal small vessel segmentation[J]. *IEEE Access*, 2020, **8**: 198265–198274.
- [24] Samuel P M, Veeramalai T. Multilevel and multiscale deep neural network for retinal blood vessel segmentation[J]. *Symmetry*, 2019, **11**(7): 946.

Ghost convolution adaptive retinal vessel segmentation algorithm

Liang Liming¹, Zhou Longsong¹, Chen Xin¹, Yu Jie¹, Feng Xingang^{2*}

¹School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China; ²School of Applied Sciences, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China



Overview: Retinal vascular morphology is an important indicator of human health, and its image processing and segmentation are of great significance for the early detection and treatment of glaucoma, cardiovascular disease, and venous obstruction. At present, retinal vessel segmentation algorithms are mainly divided into unsupervised and supervised learning methods. Unsupervised learning method mainly focuses on the original information of fundus blood vessels and uses matching filtering, mathematical morphology and vascular tracking to segment fundus images. Supervised learning requires prior label information, and the classifier is trained and extracted by manually labeled Label image, and then the retinal vessels are segmented. However, the existing retinal vessel segmentation algorithm has some problems, such as blurred main vessel contour, micro-vessel fracture, and optic disc boundary missegmentation. To solve the above problems, a ghost convolution adaptive retinal vessel segmentation algorithm was proposed. First, color fundus images were separated by RGB (Red, Green, Blue) channels and Contrast Limited Adaptive Histogram Equalization to enhance the contrast between retinal blood vessels and background, and to reduce the influence of light intensity and color channel on the segmentation effect. Then the fundus images were input into the ghoul convolution adaptive network for training to extract the vascular features. The algorithm uses ghoul convolution to replace the common convolution in the neural network, and the ghoul convolution can generate rich vascular feature maps to fully extract the target features. The features are classified and predicted by the adaptive fusion module input into the decoding layer, and the adaptive fusion can capture the image information at multiple scales and preserve the vascular details with high quality. In the process of accurately locating vascular pixels and solving the loss of image texture, a dual-pathway attention guiding structure is constructed to effectively combine the feature maps at the bottom and the high level of the network, which solves the information loss at the pooling layer, achieves global semantic transmission, better retains vascular pixels, and makes the edge details of the segmented image more complete. At the same time, Cross-Dice Loss function is introduced to suppress the problem of uneven positive and negative samples and reduce the segmentation error caused by the small proportion of foreground. The experiment was carried out on DRIVE and STARE datasets. The DRIVE dataset contains 40 color fundus images, which were manually divided into training sets and test sets by the authorities. The STARE database contains 20 color fundus images, which were evenly divided into five parts, and the experiment was carried out in a 50% fold cross validation method. Experimental results: the accuracy rate was 96.56% and 97.32%, sensitivity was 84.52% and 83.12%, specificity was 98.25% and 98.96%, respectively. In the segmentation results, the main vessels were less broken and the microvessels were clear, which has certain medical clinical application value.

Liang L M, Zhou L S, Chen X, *et al.* Ghost convolution adaptive retinal vessel segmentation algorithm[J]. *Opto-Electron Eng*, 2021, 48(10): 210291; DOI: 10.12086/oe.2021.210291

Foundation item: National Natural Science Foundation of China (51365017, 61463018), General Project of Jiangxi Natural Science Foundation (20192BAB205084), and Key Project of Science and Technology Research of Jiangxi Provincial Department of Education (GJJ170491)

* E-mail: gzfxf1980@163.com