

# 基于改进 U-Net 视网膜血管图像分割算法

李大湘<sup>1,2</sup>, 张振<sup>1\*</sup>

<sup>1</sup>西安邮电大学通信与信息工程学院, 陕西 西安 710121;

<sup>2</sup>电子信息现场勘验应用技术公安部重点实验室, 陕西 西安 710121

**摘要** 针对视网膜图像中血管细小而导致其分割精度低等问题, 通过在 U-Net 网络中引入 Inception、空洞卷积与注意力机制等模块, 提出一种改进 U-Net 视网膜血管图像的分割算法。首先, 在编码阶段增加 Inception 模块, 采用不同尺度的卷积核对图像进行特征提取, 以获得其多尺度信息; 然后, 在 U-Net 网络的底部增加级联空洞卷积模块, 以在不增加网络参数的情况下扩大卷积操作的感受野; 最后, 在解码阶段为反卷积操作设计了注意力机制, 将注意力机制与跳跃连接方式相结合, 聚焦目标特征, 以解决权重分散等问题。基于标准图像集 DRIVE 的实验结果表明, 所提算法的平均准确率、灵敏度与特异性较之 U-Net 算法分别提高 1.15%, 6.15% 与 0.67%, 也优于其他传统分割算法。

**关键词** 图像处理; 空洞卷积; 注意力机制; 视网膜血管; 图像分割

中图分类号 TP391

文献标志码 A

doi: 10.3788/AOS202040.1010001

## Improved U-Net Segmentation Algorithm for the Retinal Blood Vessel Images

Li Daxiang<sup>1,2</sup>, Zhang Zhen<sup>1\*</sup>

<sup>1</sup>College of Communication and Information Technology, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710121, China;

<sup>2</sup>Key Laboratory of Ministry of Public Security, Electronic Information Field Inspection and Application Technology, Xi'an, Shaanxi 710121, China

**Abstract** In this study, we propose an improved U-Net retinal vascular image segmentation algorithm by introducing some modules, such as inception, hole convolution, and attention mechanism, into the U-Net network to solve the problem of low segmentation accuracy caused by the small blood vessels in the retinal image. Initially, the inception module was added during the encoding stage, and convolution kernels of different scales were used to extract the image features to obtain multiscale information from the image. Subsequently, a cascaded hole convolution module was added to the bottom of the U-Net network for expanding the receptive field of the convolution operation without increasing the network parameters. Finally, an attention mechanism was designed for the deconvolution operation during the decoding phase. The problem of weight dispersion can be solved by focusing on the target features under the combination of the attention mechanism and jump connection mode. The experimental results obtained using the standard image set DRIVE denote that the average accuracy, sensitivity, and specificity of the proposed algorithm are 1.15%, 6.15%, and 0.67% higher than those of the traditional U-Net algorithm, respectively, and that the proposed algorithm outperforms other traditional segmentation algorithms.

**Key words** image processing; hole convolution; attention mechanism; retinal vessels; image segmentation

**OCIS codes** 100.3008; 100.5010; 110.2970

## 1 引言

彩色眼底视网膜血管分割是计算机辅助诊断视网膜疾病的重要组成部分, 例如静脉阻塞、动脉硬化

和糖尿病性视网膜病等疾病。定期对血管的宽度、曲折度和增生进行准确的测量即可对这些疾病进行可靠的评估<sup>[1-2]</sup>, 如果发现血管异常, 可以对患者进行及时的治疗, 防止疾病的恶化。由于视网膜血管

收稿日期: 2020-01-08; 修回日期: 2020-01-13; 录用日期: 2020-02-26

基金项目: 国家自然科学基金(61571361, 61102095)、陕西省国际合作交流项目(2017KW-013, 2019JM-604)

\* E-mail: zhang408356262@163.com

的特殊性,如血管较细,导致人工分割视网膜血管会非常繁琐,也很轻易出错,这就需要经验非常丰富眼科专家手工注释大量的视网膜图像,这对大规模的研究和临床应用是不可行的。所以研究一种准确的、快捷的视网膜血管分割算法是尤为重要的。

目前国内外已经有很多学者研究自动视网膜分割算法,这些算法可以被分为两大类:无监督方法和有监督方法。无监督方法主要关注的是视网膜血管的固有特性,无需关注来自人工注释训练数据的原先信息。常见的无监督视网膜血管分割方法包括血管追踪法<sup>[3-4]</sup>、基于形态学处理法<sup>[5-6]</sup>、基于活动轮廓法<sup>[7-9]</sup>和基于图的方法<sup>[10-11]</sup>。文献[12]中提出了用形态学处理的方法对视网膜血管进行分割。文献[13]中提出一种基于完全连接的条件随机场并使用结构化输出支持向量机(SVM)自动学习参数的方法对视网膜血管进行分割。文献[14]中提出了一种级联分类网络,该网络包含了一组计算效率高的马氏距离分类器,以形成用于视网膜血管分类的高度非线性决策边界。

因深度学习在图像处理方面有很出色的表现,学者们将其应用到视网膜血管分割中。文献[15]中提出用卷积神经网络(CNN)分割视网膜血管。文献[16]中采用稳态小波变换和多尺度全卷积神经网络相结合的方法进行血管分割。文献[17]中提出使用具有改进的交叉熵损失功能的多尺度卷积神经网络对彩色眼底图像进行视网膜血管分割。文献[18]中将血管分割任务分为三个子任务,每个子任务均由深度学习模型使用唯一的像素损失进行训练。文献[19]中提出了一种将残差网络和密集连接网络结合的网络分割视网膜血管。文献[20]中基于一种新的损失函数,即将血管段级损失和像素损失联合,对血管分割,其可以在不增加整体模型复杂性的情况下更有效地学习血管特征。文献[21]中提出了一种多尺度特征融合的全卷积神经网络的方法来分割视网膜血管。文献[22]中提出了一种交叉连接的卷积神经网络(CcNet)用于视网膜血管的自动分割。

目前彩色眼底视网膜因为图像中的血管细小导致分割结果的准确率和灵敏度有待提高,提出了基于改进的 U-Net 视网膜血管图像分割。首先对数据进行 G 通道提取、灰度变换、对比度受限的自适应直方图均衡化(CLAHE)以及伽马变换等预处理;然后在编码阶段用 Inception 模块代替传统卷积,采用不同尺度的卷积核进行图像特征提取;其次在 U-Net 网络的底部采用级联空洞卷积模块,在不增加参数的情况

下扩大视网膜图像特征映射的感受野,提取局部区域的多尺度特征;最后在解码阶段采用带有注意力(Attention)机制的反卷积网络将底层与高层特征信息有效结合,解决了视网膜血管权重分散等问题,将网络目标聚焦到血管分割,保留了更多细小血管。将 U-Net 网络与空洞卷积和注意力机制等模块有效结合起来,提高了分割的准确率和灵敏度。

## 2 本文算法

### 2.1 改进的 U-Net 框架

针对眼底视网膜图像因光照、病变等因素的干扰,图像中细小血管出现分割精度低等问题,提出了一种基于改进的 U-Net 网络算法。引入 Inception 模块改善深层网络优化困难的问题,进一步提升网络的泛化能力和网络结构的表达能力;结合级联空洞卷积模块保留多尺度的血管特征,在不增加额外参数的情况下扩大视网膜图像特征映射的感受野,使网络保留更多图像细节以分割出眼底视网膜中较小的血管,有效地防止眼底视网膜血管图像在训练时产生过拟合;在解码阶段引入注意力机制,充分结合 U-Net 网络跳跃结构,将眼底视网膜图像的底层特征与高层特征相结合,抑制噪声的影响,将目标聚焦在血管特征中,降低在编码阶段因为下采样所导致的视网膜血管信息丢失率,恢复眼底视网膜血管结构,提升视网膜血管分割准确率。基于改进 U-Net 视网膜血管分割算法模型如图 1 所示。

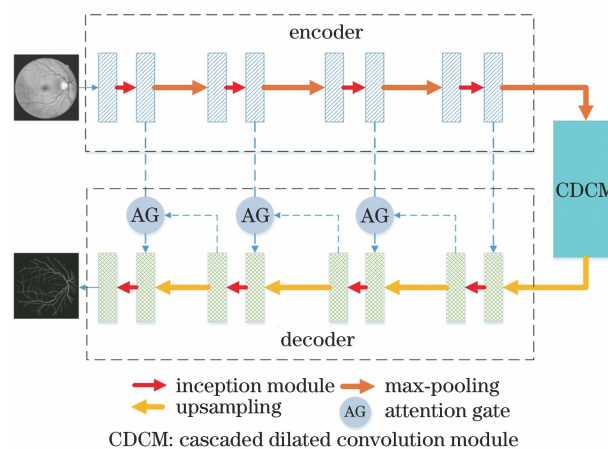


图 1 改进 U-Net 视网膜血管分割算法模型

Fig. 1 Improved U-Net retinal vessel segmentation algorithm model

本文所提算法一共由三个阶段构成,分别是编码阶段、级联空洞卷积、解码阶段。对视网膜数据集进行预处理后输入网络编码部分先经过一个大小为  $3 \times 3$  的卷积核,紧接着是 4 个 Inception 模块,每一

个 Inception 模块都是由  $1 \times 1$ 、 $3 \times 3$  和 2 个级联的  $3 \times 3$  卷积核并联组成,通过提取不同尺度的视网膜血管特征进行融合,之后,接入一个大小为  $1 \times 1$  的卷积核,以减少输入信息的映射数目;在每一个 Inception 模块后都接入一个大小为  $2 \times 2$ ,步长为 2 的最大池化层,目的是将视网膜血管特征图缩小到上一层特征图尺寸的一半;在经过第 4 个最大池化层后接入一个空洞率分别为 1、2、4、8 的级联空洞卷积模块,有效融合血管多尺度信息,使网络能够提取出更多细小血管的特征。解码部分是由上采样层、Inception 模块和带有跳跃连接的注意力机制组成。上采样层是一个大小为  $3 \times 3$ ,步长为 2 的反卷积层,输出的特征图大小和跳跃连接所对应的特征图的尺寸是一样的,但是上采样会造成一部分视网膜血管信息损失,所以接入带有 Attention 模块的跳跃连接,通过门控信息不仅可以恢复目标信息即将注意力聚焦到血管上降低编码部分的信息损失,还可以解决权重分散等问题。最后通过 SoftMax 激活函数对眼底视网膜血管与背景图像进行分类,输出血管分割结果。

### 2.2 Inception 模块

在 Inception 模块被提出之前,很多学者基本上都是通过改进网络的宽度和深度来提升卷积神经网络的性能。随着网络深度和宽度的改进,参数也越来越多,很容易导致过拟合,并且计算量也会大幅度提升。针对这一问题,有一部分研究者提出将传统网络中的全连接层转化为稀疏连接,但是计算机对非平均的疏散数据计算性能很差,因此需要找到同时满足保持网络结构稀疏性并改善网络计算性能的方法。在 ILSVRC 2014 比赛中 Szegedy 等<sup>[23]</sup>提出了 Inception 网络来解决这些问题,将 Inception 模块应用到 GoogLeNet 网络模型中,并且在比赛中取得了最好的分类和检测性能。

在传统卷积层的基础上改进了 Inception 模块。使用多个不同尺度的卷积核可增强网络的泛化和结构表达能力,并为网络模型增加了更多的非线性,极大地提高了卷积神经网络的学习特征能力。图 2 显示了经典 Inception 结构。该模块使用了  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  三种不同的卷积核,并且引入  $3 \times 3$  最大池化结构进行不同尺度的信息融合。为了提取更多眼底视网膜血管的有效特征,增强网络的泛化和表达能力,本文采用的 Inception 模块如图 3 所示,首先对输入的特征图分别采用  $1 \times 1$ 、 $3 \times 3$  和级联的 2 个  $3 \times 3$  卷积核进行特征提取,其次将不同卷积核所获

取的视网膜血管特征图进行融合,最后将融合的特征图输入  $1 \times 1$  卷积核进行降维,提高网络的泛化能力。相比较单个的  $5 \times 5$  卷积核而言,级联的 2 个  $3 \times 3$  卷积核具有相同的感受野,并且能够增加更多的非线性变换,因此用级联的 2 个  $3 \times 3$  卷积核代替单独的  $5 \times 5$  卷积核。




图 2 经典 Inception 结构

Fig. 2 Classic Inception structure

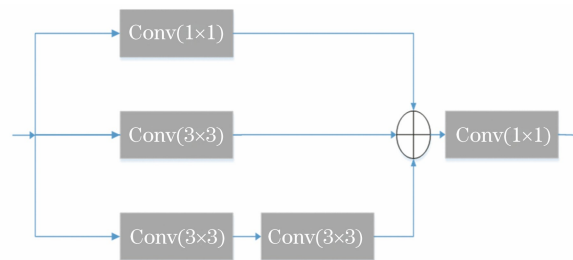


图 3 Inception 模块

Fig. 3 Inception module

### 2.3 级联空洞卷积

在卷积神经网络中,卷积核尺寸越大,相应的感受野也越来越大,但同时也会使学习参数增加,导致训练容易造成数据过拟合。针对这些问题,Chen 等<sup>[24]</sup>提出了一种空洞卷积的方式,扩大了感受野但不增加参数,保留了多尺度特征和更多图像细节信息。空洞卷积也被称作扩张卷积,其基本原理可以看作是在普通卷积核像素之间插入像素为零的值,从而增加网络的空洞率  $r$ 。如图 4 所示:图 4 (a)中  $r=1$ ,相当于  $3 \times 3$  普通卷积核;图 4 (b)中的  $r=2$  相当于  $7 \times 7$  普通卷积核;图 4 (c)中的  $r=4$  相当于  $15 \times 15$  普通卷积核。对于二维图像,输出特征层上  $y$  的每个像素点  $i$ ,其空洞卷积操作的过程可表示为

$$y(i) = \sum_k x(i + rk)w(k), \quad (1)$$

式中: $w$  代表卷积核; $k$  代表卷积核尺寸; $x$  代表卷积输入量; $r$  对应输入信号采样的步长,等效于在输入特征层上添加  $r-1$  个小孔(即  $r-1$  个零像素),通过调整  $r$  的大小可以自适应地调节感受野大小。为了简化网络模型,保留多尺度血管特征,提取细小血管的细节特征,提出用空洞卷积构成的级联空洞

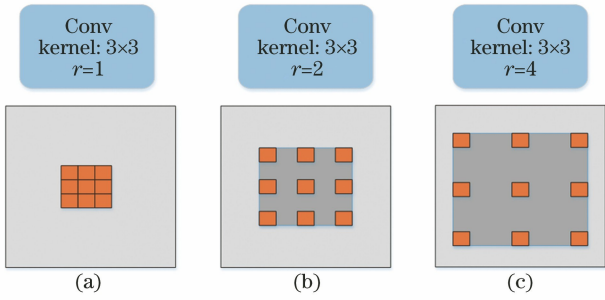


图 4 不同空洞率  $r$  下的空洞卷积示意图。(a)  $r=1$ ;  
(b)  $r=2$ ;(c)  $r=4$

Fig. 4 Schematic diagram of hole convolution under different expansion rates  $r$ . (a)  $r=1$ ;(b)  $r=2$ ;(c)  $r=4$

卷积模块(CDCM),如图 5 所示。

在该模块中,将空洞率  $r$  分别设置为 1、2、4、8,卷积核的大小均为  $3 \times 3$ 。首先通过  $r=1$  的卷积核对输入的视网膜血管特征图进行特征提取,然后将获得的结果作为最终特征图的一部分,同时也作为




图 5 级联空洞卷积模块示意图

Fig. 5 Schematic diagram of cascaded dilated convolution module




图 6 注意力机制内部结构图

Fig. 6 Internal structure of attention mechanism

AG 模型的门注意系数为  $0 \leq \theta_i \leq 1$ ,该系数可以捕获血管特征的显著性区域,仅仅保留与血管特征任务相关的特征信息。AG 的输出特征  $\hat{x}_{i,c}^l$  是输入特征图  $x_{i,c}^l$  和注意系数的逐元素相乘,即  $\hat{x}_{i,c}^l = \theta_i^l \cdot x_{i,c}^l$ ,其中  $c$  为通道尺寸, $l$  为网络来计算层数, $i$  为像素空间大小。注意力机制  $q_{att}$  和注意系数  $\theta_i$  的表达式为

$$q_{att}^l = \psi^T [\sigma_1 (\mathbf{W}_x^T \mathbf{x}_i^l + \mathbf{W}_g^T \mathbf{g}_i + \mathbf{b}_g)] + b_\psi, \quad (2)$$

$$\theta_i^l = \sigma_2 [q_{att}^l (\mathbf{x}_i^l; \mathbf{g}_i; \Theta_{att})], \quad (3)$$

式中: $\sigma_1$  为 ReLu 的激活函数, $\sigma_1(\mathbf{x}_{i,c}^l) = \max(0,$

下一级  $r=2$  的卷积核运算的输入,以此类推,最终得到的特征图是由 5 个部分组合得到的特征图。最后将组合得到的视网膜血管特征图通过  $1 \times 1$  卷积操作,作为解码器的输入。利用空洞卷积和  $1 \times 1$  卷积操作在很大程度上减小了学习的参数,避免了网络过拟合,而且由于空洞率的不同,CDCM 可以学习不同感受野的多尺度特征,提取更多眼底视网膜的细小血管特征。

## 2.4 注意力机制

虽然在特征提取部分引入了 Inception 模块和级联空洞卷积模块,可以有效地提取更多的尺度特征以及细小血管的细节特征,但是在上采样的过程中也会带入一些噪声等多余的信息。为了剔除不相干的图像特征对目标特征的影响,提高眼底血管分割精度,在以上优化的基础上在编码部分引入注意力机制(AG)<sup>[25]</sup>,AG 内部结构如图 6 所示。

$\mathbf{x}_{i,c}^l$ );选择  $\sigma_2$  为 Sigmoid 的激活函数, $\sigma_2(\mathbf{x}_{i,c}^l) = \frac{1}{1 + \exp(-\mathbf{x}_{i,c}^l)}$  是为了防止特征过于稀疏;

$\psi \in \mathbb{R}^{F_{int} \times 1}$  是  $1 \times 1$  卷积的权值参数向量, $F_{int}$  为像素特征向量的长度;AG 特征是由一组包含线性变换的参数  $\Theta_{att}$  得到,该参数包括线性转换系数矩阵  $\mathbf{W}_x \in \mathbb{R}^{F_l \times F_{int}}$  和  $\mathbf{W}_g \in \mathbb{R}^{F_g \times F_{int}}$ ,他们分别是眼底视网膜的输入图像和门信号的权重参数矩阵; $b_\psi \in \mathbb{R}$  和  $\mathbf{b}_g \in \mathbb{R}^{F_{int}}$  为偏置项; $F_l$  为输入  $\mathbf{x}_i^l$  的特征向量长度; $F_g$  为选通信号  $\mathbf{g}$  的特征向量长度; $\mathbf{x}_i \in \mathbb{R}^{F_l \times 1}$  和  $\mathbf{g}_i \in \mathbb{R}^{F_g \times 1}$  分别是输入特征图和选通信

号。AG 通过分析输入特征图和门信号来获得对应的门相关系数,从而使 AG 可以专注于视网膜血管图像的主要目标结构特征,并且消除其他干扰目标的异常特征信息。在解码结构中,AG 通过跳过上池化层直接级联到下一个反卷积层以融合互补目标的特征信息,同时采用  $1 \times 1$  卷积层进行线性变换,将特征解耦并映射到低维空间进行选通操作<sup>[26]</sup>,而 U-Net 网络本身就具有将高层信息与底层信息相结合的优势,更加有利于恢复和提取眼底视网膜图像细小血管的细节特征,以提高分割精度。

### 3 实验结果与分析

#### 3.1 DRIVE 数据集和评价指标

DRIVE<sup>[27]</sup>数据集包含 40 张彩色眼底图像和对应




图 7 DRIVE 数据集(从左到右分别为原始彩色眼底图像、两位专家手动分割图像、二值掩码图像)

Fig. 7 DRIVE dataset (from left to right are the original color fundus image, two expert manual segmentation images, and binary mask image)

真实值(Ground Truth, GT)比较可以得到真阳性  $N_{TP}$ 、假阳性  $N_{FP}$ 、假阴性  $N_{TN}$ 、真阴性  $N_{FN}$ ,其中  $N_{TP}$ 是将目标类分类为目标类的像素点数, $N_{FP}$ 是将背景类错分为目标类的像素点数, $N_{TN}$ 是将目标类错分为背景类的像素点数, $N_{FN}$ 是将背景类分类为背景类的像素点数。视网膜血管的分割任务是为了得到图像中每个像素点的分割结果,并判断该像素点是血管类还是背景类。为了评价视网膜血管分割算法的好坏,选用准确率  $\alpha_{Acc}$ 、灵敏度  $\alpha_{Sen}$ 、特异性  $\alpha_{Spe}$  评价指标,其中  $\alpha_{Acc}$ 表示将目标类和背景类分类正确的概率, $\alpha_{Sen}$ 表示将目标类分类正确的概率, $\alpha_{Spe}$ 表示将背景类分类正确的概率。三者的表达式为

$$\alpha_{Acc} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}}, \quad (4)$$

$$\alpha_{Sen} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (5)$$

$$\alpha_{Spe} = \frac{N_{TN}}{N_{TN} + N_{FP}}. \quad (6)$$

另外,AUC(Area Under Curve)也是视网膜血管分割的一个评价指标,指的是受试者工作特性

的标注图像。该数据集发布于 2004 年,是 Niemeijer 等在荷兰的糖尿病视网膜病变筛查工作中建立的。每张彩色眼底图像的尺寸为  $565 \text{ pixel} \times 584 \text{ pixel}$ 。该数据库的原始图像来自于 453 名年龄不同的个体,其中有 7 幅图像是有早期糖尿病视网膜病变的。40 张眼底图像分为两组:训练组和测试组,每组包含 20 张彩色眼底图像,这些眼底图像彼此之间没有重叠,并且每个图像都包含由两个专家组手动分割的标记结果。如图 7 所示,显示了 DRIVE 数据集的原始图像、手工标注图像和二值掩码图像。

在 DRIVE 数据集中,眼底视网膜图像仅包含两类:血管类和背景类。血管类即需要检测分割的目标血管,也称作正类;背景类即其他剩余的部位,也称作负类。分割算法的结果(Prediction, Pred)与

(ROC)曲线下方的面积。AUC 的值能够直观地表示网络模型的预测能力,范围通常在  $0.5 \sim 1.0$  之间。AUC 值越接近 1.0,表示网络模型预测能力越强;相反,表示网络模型预测错误分类概率越高。

#### 3.2 图像预处理

由于眼底图像照明不均匀以及血管与背景之间的对比度较低等因素,为了捕获小血管的更多特征并提高血管分割的准确性,需要将输入网络的眼底图像进行预处理。首先提取 RGB 图像的三个通道,发现血管与 G 通道的背景之间的对比度最高,所以使用 RGB 图像的 G 通道完成图像的灰度变换获得单通道灰度图像,然后归一化眼底视网膜灰度图像;其次采用对比度受限的自适应直方图均衡化(CLAHE)<sup>[28]</sup>在不放大眼底视网膜图像噪声的情况下增强视网膜血管与背景之间的对比度,以使眼底图像中血管的结构和特征更容易受到关注;最后用伽马变换算法能够增强眼底视网膜图像中亮度较暗的血管部分,同时又不影响亮度较强部分的质量。图 8 分别表示原图像和预处理后的图像。




图 8 视网膜图像预处理。(a) DRIVE 数据集原图像;(b)预处理后的图像

Fig. 8 Retina image preprocessing. (a) Original image of the DRIVE dataset; (b) pre-processed image

### 3.3 图像扩充与参数设置

在网络训练中一般需要大量的数据来拟合模型参数。DRIVE 数据集本身很小,如果直接对图片进行训练,可能会导致过拟合现象,所以需要采取随机切片的方式对图像进行扩充。采用滑窗方式对图片进行裁剪,在每张眼底图像上随机裁剪 9500 个尺寸为  $48 \text{ pixel} \times 48 \text{ pixel}$  的重叠图像块,获得一组重叠图像块,取前 90% 用于网络训练,后 10% 用于验证。图 9 分别给出随机提取的图像块组合图和相对应的标准块分割图。网络参数的权重初始化采用 He 正态分布方法<sup>[29]</sup>,训练过程采用随机梯度下降法进行优化。损失函数采用交叉熵函数,初始学习率设置为 0.001。训练的 batch\_size 设置为 32,epoch 设置为 100。




图 9 视网膜血管局部块状信息图。(a) DRIVE 数据集块状信息;(b)标准块状信息

Fig. 9 Local blocky information map of retinal blood vessels. (a) Block information of the DRIVE dataset; (b) standard block information

### 3.4 实验结果

在 DRIVE 数据集上采用本文算法进行测试,视网膜血管分割结果如图 10 所示,第 1 列为原始图像预处理图,第 2 列为手工标注分割结果图,第 3 列为本实验分割结果。从分割图的效果来看,本文所提算法得到的分割结果基本上和专家分割的标准图是一致的,特别是在细小血管的分割上有很好的效果。




图 10 实验结果分割图。(a)原始图像预处理图;(b)图像分割标准图;(c)实验结果分割图

Fig. 10 Segmentation of experimental results. (a) Original image preprocessing map; (b) image segmentation standard map; (c) experimental result segmentation map

众所周知,视网膜图像的特征较为复杂且因人而异,容易受到外界条件和病变本身的影响。图 11 展示了一些局部区域血管分割对比图,其中包含交叉点上的血管、低对比度下的细小血管及病变区域

的血管。从分割结果可见,本文所提算法通过引入 Inception、空洞卷积模块与注意力机制,能有效克服低对比度、血管形状和视网膜病变等因素的影响,具有较好的分割性能,体现了本文所提算法能够在保




图 11 局部血管区域分割图。(a)原彩色眼底视网膜图;(b)局部眼底视网膜图;(c)局部标准视网膜分割图;(d)局部视网膜分割结果图

Fig. 11 Partial blood vessel region segmentation diagram. (a) Original color fundus retinal images; (b) locally fundus retinal images; (c) local standard retinal segmentation images; (d) local retinal segmentation result images

留细节信息的同时有效识别不同特征的血管信息。

将本文的测试结果与第 2 观察者手动分割的结果进行比较,同时与其他学者所提出的方法进行比较,如表 1 所示,可以看出本文算法在评价指标准确性、灵敏度、特异性与 AUC 上的结果分别是 96.43%,82.74%,98.71%,98.69%,与传统的 U-Net 算法相比在准确性、灵敏度、特异性上分别提高了 1.15%,6.15%,0.67%,整体性能较优。虽然本文算法在准确率上不如文献[31]的高,但是在特异性、灵敏度、AUC 上本文算法明显优于其他算法,从图 12 中也可以看出,整体上来说本文的算法在视网膜血管分割性能方面有很大的提升。

表 1 不同算法在 DRIVE 数据集上测试结果比较

Table 1 Comparison of test results of different algorithms on the DRIVE dataset

Algorithm	$\alpha_{Sen}$	$\alpha_{Spe}$	$\alpha_{Acc}$	AUC
Manual segmentation method by 2th observer	0.7796	0.9717	0.9464	0.9466
Method in Ref. [8]	0.742	0.982	0.954	0.862
Method in Ref. [14]	0.7648	0.9817	0.9541	—
Method in Ref. [15]	0.7763	0.9768	0.9495	0.972
Method in Ref. [20]	0.7631	0.982	0.9538	0.975
Method in Ref. [21]	0.8053	0.9767	0.9546	0.9771
Method in Ref. [30]	0.7655	0.9704	0.9442	0.9614
Method in Ref. [31]	0.8173	0.9733	0.9767	0.9475
Our algorithm	0.8274	0.9871	0.9643	0.9869

对本文提出的网络结构进行调整,分别从 1)基




图 12 不同算法的评价指标对比图

Fig. 12 Comparison of evaluation indexes of different algorithms

本的 U-Net 网络进行测试,此方法用 a 表示;2) U-Net 网络与 Attention 机制相结合进行测试,此方法用 b 表示;3) U-Net 网络与空洞卷积相结合进行测试,此方法用 c 表示。与本文算法结果进行比较,如表 2 所示,通过比较发现本文提出的网络结构在 DRIVE 数据集上测试的性能要优于其他网络性能。

表 2 不同网络结构在 DRIVE 数据集上测试结果比较

Table 2 Comparison of test results of different network structures on the DRIVE dataset

Algorithm	$\alpha_{Sen}$	$\alpha_{Spe}$	$\alpha_{Acc}$	AUC
a	0.7659	0.9804	0.9528	0.9765
b	0.8014	0.9853	0.9562	0.9812
c	0.7856	0.9832	0.9546	0.9784
Our algorithm	0.8274	0.9871	0.9643	0.9869

## 4 结 论

针对视网膜图像中血管细小而导致其分割精度低等问题,将 Inception 模块、级联空洞卷积模块和注意力机制模块与传统 U-Net 网络相结合,提出了基于改进 U-Net 视网膜血管图像分割算法。在特征提取部分加入 Inception 模块和级联空洞卷积模块,一方面可以扩大视网膜图像特征映射感受野而不会增加网络参数,另一方面通过多尺度提取血管图像保留了视网膜小血管的更多特征;解码阶段引入注意力机制可以有效地恢复细小血管的特征信息。通过在公开数据集 DRIVE 上进行测试,本文算法有着很高的准确率,与传统的 U-Net 网络相比较整体性能较优,分割结果可观。

## 参 考 文 献

- [1] Nguyen U T V, Bhuiyan A, Park L A F, et al. An effective retinal blood vessel segmentation method using multi-scale line detection [J]. *Pattern Recognition*, 2013, 46(3): 703-715.
- [2] Roychowdhury S, Koozekanani D D, Parhi K K. Iterative vessel segmentation of fundus images [J]. *IEEE Transactions on Biomedical Engineering*, 2015, 62(7): 1738-1749.
- [3] Bekkers E, Duits R, Berendschot T, et al. A multi-orientation analysis approach to retinal vessel tracking [J]. *Journal of Mathematical Imaging and Vision*, 2014, 49(3): 583-610.
- [4] Yin Y, Adel M, Bourennane S. Retinal vessel segmentation using a probabilistic tracking method [J]. *Pattern Recognition*, 2012, 45(4): 1235-1244.
- [5] Mendonca A M, Campilho A. Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction [J]. *IEEE Transactions on Medical Imaging*, 2006, 25(9): 1200-1213.
- [6] Miri M S, Mahloojifar A. Retinal image analysis using curvelet transform and multistructure elements morphology by reconstruction [J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(5): 1183-1192.
- [7] 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.
- [8] Zhao Y T, Rada L, Chen K, et al. Automated vessel segmentation using infinite perimeter active contour model with hybrid region information with application to retinal images [J]. *IEEE Transactions on Medical Imaging*, 2015, 34(9): 1797-1807.
- [9] Gooya A, Liao H, Matsumiya K, et al. A variational method for geometric regularization of vascular segmentation in medical images [J]. *IEEE Transactions on Image Processing*, 2008, 17(8): 1295-1312.
- [10] Xu X Y, Niemeijer M, Song Q, et al. Vessel boundary delineation on fundus images using graph-based approach [J]. *IEEE Transactions on Medical Imaging*, 2011, 30(6): 1184-1191.
- [11] De J, Cheng L, Zhang X W, et al. A graph-theoretical approach for tracing filamentary structures in neuronal and retinal images [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(1): 257-272.
- [12] Câmara Neto L, Ramalho G L B, Rocha Neto J F S, et al. An unsupervised coarse-to-fine algorithm for blood vessel segmentation in fundus images [J]. *Expert Systems with Applications*, 2017, 78: 182-192.
- [13] Orlando J I, Prokofyeva E, Blaschko M B. Adiscriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images [J]. *IEEE Transactions on Biomedical Engineering*, 2017, 64(1): 16-27.
- [14] Wang X H, Jiang X D, Ren J F. Blood vessel segmentation from fundus image by a cascade classification framework [J]. *Pattern Recognition*, 2019, 88: 331-341.
- [15] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(11): 2369-2380.
- [16] Oliveira A, Pereira S, Silva C A. Retinal vessel segmentation based on fully convolutional neural networks [J]. *Expert Systems with Applications*, 2018, 112: 229-242.
- [17] Hu K, Zhang Z Z, Niu X R, et al. Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function [J]. *Neurocomputing*, 2018, 309: 179-191.
- [18] Yan Z Q, Yang X, Cheng K T. A three-stage deep learning model for accurate retinal vessel segmentation [J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(4): 1427-1436.
- [19] Wu C Y, Yi B S, Zhang Y G, et al. Retinal vessel image segmentation based on improved convolutional neural network [J]. *Acta Optica Sinica*, 2018, 38(11): 1111004.

吴晨玥, 易本顺, 章云港, 等. 基于改进卷积神经网络



- 络的视网膜血管图像分割[J]. 光学学报, 2018, 38(11): 1111004.
- [20] Yan Z Q, Yang X, Cheng K T. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation [J]. IEEE Transactions on Biomedical Engineering, 2018, 65(9): 1912-1923.
- [21] Zheng T Y, Tang C, Lei Z K. Multi-scale retinal vessel segmentation based on fully convolutional neural network [J]. Acta Optica Sinica, 2019, 39(2): 0211002.  
郑婷月, 唐晨, 雷振坤. 基于全卷积神经网络的多尺度视网膜血管分割[J]. 光学学报, 2019, 39(2): 0211002.
- [22] Feng S T, Zhuo Z S, Pan D, et al. CcNet: a cross-connected convolutional network for segmenting retinal vessels using multi-scale features [J/OL]. (2019-04-23) [2020-01-02]. <https://doi.org/10.1016/j.neucom.2018.10.098>.
- [23] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 15523970.
- [24] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [25] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-Net: learning where to look for the pancreas [J/OL]. (2018-08-20) [2020-01-02]. <http://arxiv.org/abs/1804.03999>.
- [26] 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(8): 0810004.  
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): 0810004.
- [27] 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.
- [28] Chen M M, Xiong X L, Zhang Y, et al. A new method for retinal fundus image enhancement [J]. Journal of Chongqing Medical University, 2014, 39(8): 1087-1090.  
陈萌梦, 熊兴良, 张琰, 等. 1 种视网膜眼底图像增强的新方法 [J]. 重庆医科大学学报, 2014, 39(8): 1087-1090.
- [29] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 15802053.
- [30] Azzopardi G, Strisciuglio N, Vento M, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images [J]. Medical Image Analysis, 2015, 19(1): 46-57.
- [31] Wang S L, Yin Y L, Cao G B, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning [J]. Neurocomputing, 2015, 149: 708-717.