

DOI:10.19651/j.cnki.emt.2314726

基于改进 U-Net 的轻量级眼底病变分割算法设计

刘拥民^{1,2} 张毅^{1,2} 欧阳凌轩^{1,2} 石婷婷^{1,2}

(1. 中南林业科技大学计算机与信息工程学院 长沙 410004; 2. 中南林业科技大学智慧林业云研究中心 长沙 410004)

摘要: 精准的糖尿病视网膜病变的分割是实现视网膜病变自动诊断的前提条件和关键步骤,然而现有大部分的分割模型存在着参数量大、模型训练效果不理想、甚至是无法正常处理数据集等局限性。为此,在原 U-Net 网络中加入改进的 Ghost 卷积模块与多尺度特征融合模块,提出一种改进 U-Net 眼底病变分割图像的算法。该模型能以少量的参数量、较低的计算复杂度获得良好的分割结果。利用 Ghost Model 替换原始卷积,设计出 Ghost 卷积与 Ghost 下采样卷积模块,在保证准确度的同时降低参数量;设计出一种轻量级的 Half-U-Net 多尺度特征融合模块来获取多尺度信息,针对不同尺度病变目标,引入 CBAM 注意力机制以改善其适应性,从而更好的提取细小的病变信息。改进后的模型在 e_optha 与 IDRiD 两个公开数据集上的 mIoU 分别为 61.42%、61.84%,F1-Score 分别为 70.59%、69.41%。模型参数量、FLOPs 分别仅为 5.48 M、35.46 GMac,较 U-Net、Att-UNet 等模型更加精简,分割精度更高。

关键词: 糖尿病视网膜病变;图像分割;Ghost 卷积;U-Net

中图分类号: TP2 文献标识码: A 国家标准学科分类代码: 520.20

Design of lightweight fundus lesion segmentation algorithm based on improved U-Net

Liu Yongmin^{1,2} Zhang Yi^{1,2} Ouyang Lingxuan^{1,2} Shi Tingting^{1,2}

(1. Central South University of Forestry and Technology, College of Computer and Information Engineering, Changsha 410004, China;

2. Smart Forestry Cloud Research Center of Central South University of Forestry and Technology, Changsha 410004, China)

Abstract: Accurate segmentation of diabetes retinopathy is the prerequisite and key step to achieve automatic diagnosis of retinopathy. However, most of the existing segmentation models have limitations such as large parameters, unsatisfactory model training effect, and even inability to process data sets normally. To this end, an improved Ghost convolution module and multi-scale feature fusion module are added to the original U-Net network, and an improved U-Net algorithm for fundus lesion segmentation images is proposed. This model can achieve good segmentation results with a small number of parameters and low computational complexity. Using the Ghost Model to replace the original convolution, design Ghost convolution and Ghost down sampling convolution modules to ensure accuracy while reducing the number of parameters; Design a lightweight Half U-Net multi-scale feature fusion module to obtain multi-scale information, and introduce CBAM attention mechanism to improve its adaptability for different scale lesion targets, thereby better extracting small lesion information. The improved model is implemented in the mIoU on the two publicly available datasets, e_optha and IDRiD, were 61.42% and 61.84% respectively, while the F1 Score was 70.59% and 69.41%, respectively. The model parameters and FLOPs are only 5.48 M and 35.46 GMac, respectively, which are more streamlined and have higher segmentation accuracy compared to U-Net, Att-UNet and other models.

Keywords: diabetic retinopathy; image segmentation; Ghost convolution; U-Net

0 引言

糖尿病的患病率在全球范围内正呈现持续上升趋势,而患病带来的后果一直在不断恶化,其中最为典型的便是

糖尿病视网膜病变(diabetes retinopathy, DR),它是发达国家劳动年龄人口失明的主要原因,据估计^[1],它影响了近 93 万多人。如果能够及时发现,可以有效减缓甚至能够有效避免视力障碍的加剧。

目前,DR 的检查基本是一项手动且费时的工程,要求训练有素的临床医师进行和分析视网膜的数字彩色眼底图像,往往为此而错失了治疗时间。因此,利用计算机辅助医生诊断来提高效率,进而降低患者风险已经成为计算机视觉领域关注的一个焦点。

近年来,国内外基于深度学习的 DR 检测系统在疾病检测中取得了显著成果,特别是卷积神经网络对疾病的分级。DR 在眼底图像中,通常表现为微动脉瘤(microaneurysm, MA)、软渗出物(soft exudate, SE)、硬渗出物(hard exudates, EX)和出血(hemorrhage, HE)等^[2]。传统的分级通常是对图像进行特征进行提取,然后运用提取出来的特征对疾病的等级进行分类^[3-5],但这种分级系统缺少对 DR 诊断的可解释性。因此,对病变图像分割的精准程度成为了影响疾病检测结果的关键步骤。

目前,传统算法中常用的眼底病变图像分割算法有阈值分割^[6]、区域生长、水平线分割^[7]等。

如今,基于深度学习医学图像分割的常见网络有 U-Net^[8]、U-Net++^[9]、注意力 U-Net(attention U-Net, Att-UNet)^[10]等。U-Net++ 通过抓取不同层次的特征,将它们通过特征叠加的方式整合,加入更浅的 U-Net 结构,使得融合时的特征图尺度差异更小;Att-UNet 设计了一种注意力门机制,用其优化跳跃连接,以达到抑制输入图像中的不相关区域,同时突出特定局部区域显著特征的目的。Kou 等^[11]使用改进的 UNet 进行视网膜微动脉瘤分割,以 98.7% 的 ACC 取得了不错的分割效果。Yu 等^[12]采用预训练 Inception-V3^[13]、ResNet-50^[14] 和 VGG-19^[15] 网络检测 HE,将模型提取的特征相融合,取得了 91.92% 的分割效果。艾星芳等^[16]采用多分辨率提取模块提升网络性能。虽然多数模型在准确度方面效果不错,但同时也引进了很多参数,占用内存也变得更大。由于嵌入式设备的计算资源有限,使用上述改进的 U-Net 难以部署在临床眼底病变筛查系统所使用的嵌入式设备上。常用的轻量级网络有 MobileNet、Xception 等,通过替换 U-Net 的特征提取模块,减少模型参数量。但这些轻量级网络在准确度方面仍有极大的提升空间。分割模型选择固然重要,而对图像的预处理也不可忽视,Albahli 等^[17]采用 3 种技术进行图像增强,并利用 U-Net 来检测 DR 病变以进行病变分割,从实验结果表明,在经过自适应直方图均衡化(CLAHE)处理后,SE 和 HE 准确率最高,分别达到了 89.69% 和 59.35%。Krishnamoorthy 等^[18]运用回归模型的特征滤波来提高 DR 中出血的检测精度。虽然这些预处理步骤可以提高准确率,但在大数据集中,这些步骤可能会变得繁琐且不利于快速分割病变区域。

基于以上研究,本文提出一种基于改进 U-Net 的多尺度轻量化糖尿病视网膜病变分割算法,主要的工作包括两部分:1)为了减少分割模型的参数量,在 GhostNet^[19] 的基础上设计 Ghost 卷积模块以及 Ghost 下采样模块,剔除了

大量的冗余特征图,在保证分割准确率的同时实现轻量化。2)采用多尺度特征融合的方式设计了 Half-UNet 模块,增强病变的纹理、形状等特征,提供更准确的位置和边界信息,提高对细小、密集病变的分割准确率。

消融实验结果表明,Ghost 模块能大量的减少模型参数量及计算量,并提升模型的分割效果;对比实验结果表明,该方法有效提升了 DR 病变图像的分割精度。本文设计的算法,为眼底病变图像分割工作提供了一种全新的研究思路,具备一定的可行性和先进性,为今后的糖尿病视网膜病变临床诊断和治疗提供了可靠的技术手段。

1 相关工作

1.1 Ghost Model

卷积层是卷积神经网络中的核心模块,目的是为了提取输入图片的特征信息从而得到特征图,但现在主流的卷积神经网络(如 U-Net)从卷积层获取的特征图中,往往存在着大量的冗余图像,并且其中的冗余图往往都是彼此相似的图像。

在实验中,给定输入为 $\mathbf{X} \in R^{c \times h \times w}$,其中 c 为输入数据通道数, h 为输入数据高度, w 为输入数据宽度;卷积滤波器即卷积核 $f \in R^{c \times k \times k \times n}$,其中 k 为卷积核大小, n 为输出通道数; X 与 f 用于生成 n 张特征图,用公式表达为式(1):

$$\mathbf{Y} = \mathbf{X} \times f + b \quad (1)$$

其中, \times 为卷积操作, b 为偏置项,最后的输出特征图为 $\mathbf{Y} \in R^{h' \times w' \times n}$,其中 h' 与 w' 分别为卷积后特征图的高和宽。

根据 Ghost Net 中的 Ghost Model 模块,可以通过减少卷积核个数来减少 FLOPs 与参数计算。使用普通卷积先生成 m 个固有特征图 $\mathbf{Y}' \in R^{h' \times w' \times m}$ 。具体计算如式(2):

$$\mathbf{Y}' = \mathbf{X} \times f' \quad (2)$$

其中, $f' \in R^{c \times k \times k \times m}$ 是所使用到的滤波器, $m \leq n$ 并且为了使其更简易省略了偏置项 b 。为了进一步获得所需的特征图,对 \mathbf{Y}' 中的每个固有特征图进行一系列简易的线性运算,具体如式(3)所示。

$$\mathbf{y}_{ij} = \Phi_{i,j}(\mathbf{y}'_i), \quad \forall i = 1, \dots, m, \quad j = 1, \dots, s \quad (3)$$

其中, \mathbf{y}_{ij} 为 \mathbf{Y}' 中第 i 个固有特征图, $\Phi_{i,j}$ 在函数用于生成 i 中的第 j 个特征图(除了最后一个),所以一个 \mathbf{y}_i 能够具有一个或多个特征图。其中最后一个 $\Phi_{i,j}$ 用于保留 \mathbf{Y}' 中固有的特征图。将 $n = m \times s$ 个特征图 $\mathbf{Y} = [\mathbf{y}_{11}, \mathbf{y}_{12}, \dots, \mathbf{y}_{ms}]$ 作为 Ghost Model 的输出。其中线性运算 $\Phi_{i,j}$ 的本质为分组卷积,由于卷积核数量的大大减少,其计算成本远低于普通卷积。Ghost 模块示意图如图 1 所示。

由此可见,Ghost Model 模块能够大大的减少模型参数,达到模型轻量化的目标。本文采用 Ghost bottle conv 与 Ghost down sample 分别替代 U-Net 中的普通卷积和下采样(如图 2 所示)。

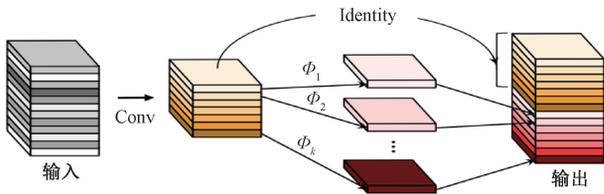


图 1 Ghost 卷积模块

算。而 RestNet 使用了另一种特征融合的加法运算,在小计算量的情况下更简单的进行特征映射,并将输出添加到堆叠层的输出中,并且相加运算并不会增加特征图的维度,只是增加了每张特征图下的信息量,这样更加有利于在运用极小的参数量和计算量的同时加强眼底病变图像分割的效果。

1) 多尺度特征融合

在多数 U-Net 网络优化中,为了获取到更多浅层的细节信息(如器官的边界、形状、纹理、轮廓等),一般采用不同尺寸的卷积核对语义信息进行挖掘的方式优化跳跃连接^[20-22],或者在训练开始前、上采样前采用特征金字塔等方式提取特征图的多尺度特征,再运用提取到的信息进行训练以及上采样^[23-24]但这些方法在提取细小、密集特征的任务中表现依旧不理想。为此,本文采用多尺度特征融合的方式提取更多浅层的特征和细节信息。

现存采用多尺度融合方法的网络,例如 MSLF-Net^[25]、MULTISCALE GUIDED FILTER MODULE^[26]等,由于深层特征图通道数过大,会产生大量的计算量,为了解决这一问题,本文设计了一种 Half-UNet 多尺度特征融合模型,该模型不仅融合了所有尺度的特征图,并且可以在多尺度上获取强语义信息和几何细节信息,模块结构如图 3 所示。将所有尺度的通道数设为主干网络第一次卷积之后输出的通道数,并且沿用 Ghost 模块,在具备计算量少的特点同时,提取到多尺度特征信息。然后对每一层的特征图进行采样以获得原始图像大小,之后通过 Add 进行特征融合。多尺度特征的重要性往往需要动态调整,因此,在此处加入注意力模块是最合适的。

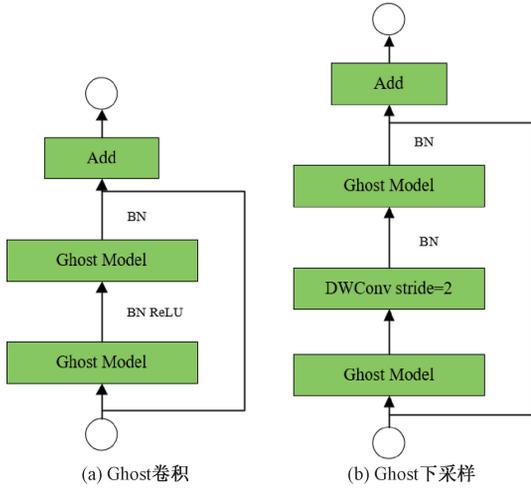


图 2 Ghost 改进模块

1.2 Half-UNet 多尺度特征融合模块

由于眼底病变图像具有病变面积小、分散较大的特点,在训练时便会导致网络专注于细小特征,而部分大面积病变图像分割效果极差。通常解决这一问题都是使用级联运算进行直观的特征融合,但它们需要更多的内存开销和计

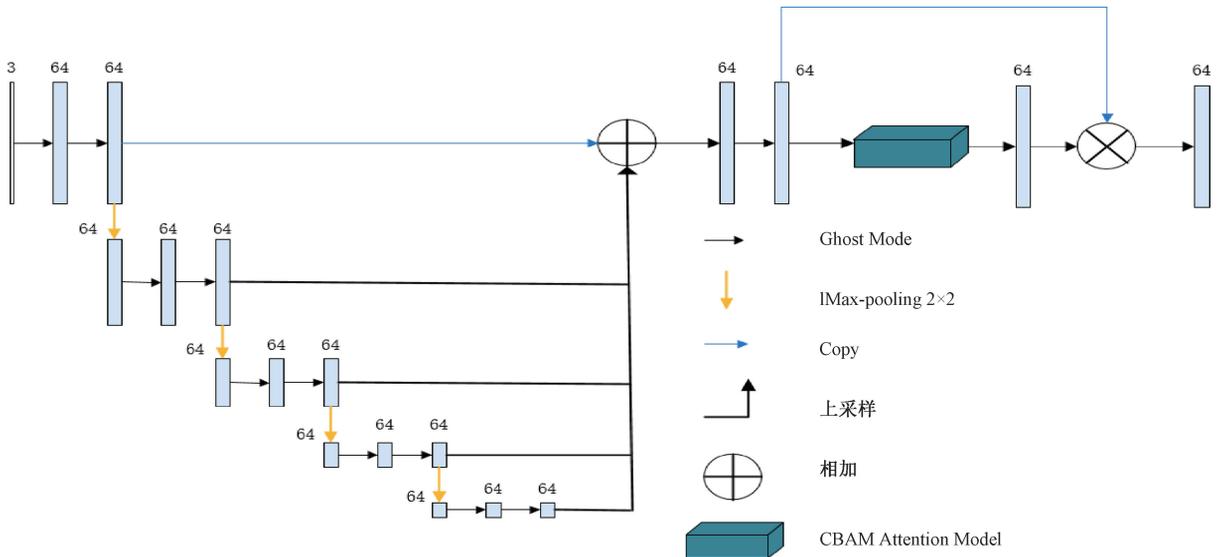


图 3 Half-UNet 多尺度特征融合模块

2) CBAM 注意力模块

本文采用最适合 Half-UNet 的卷积块注意力模块(convolutional block attention model, CBAM)^[27],如图 4

所示,从空间和通道双维度上加强有用信息,抑制无用信息,从而提高小目标和密集目标的分割能力。

为了更加有效的利用通道注意力的计算能力,如图 5

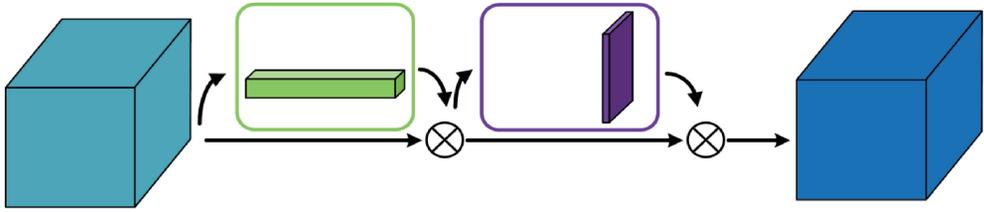


图 4 CBAM 注意力模块

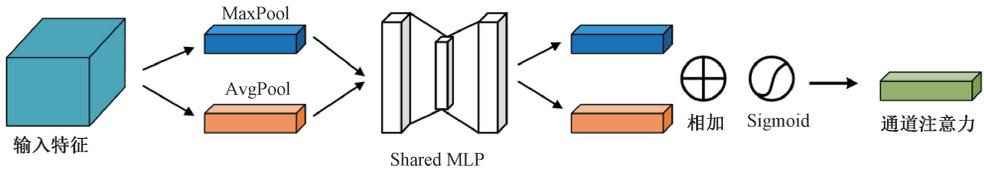


图 5 通道注意力模块

所示,在原网络的卷积层中通过通道注意力模块,采用了最大池化(MaxPool)和平均池化(AvgPool)的方法,对输入特征映射的维度进行压缩;再通过一个多层感知机,将输出特征进行加权之后输入到 Sigmoid 激活函数中,得到归一化的通道注意力权重。工作过程如式(4)所示。

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}})) + W_1(W_0(F_{\text{max}}))) \quad (4)$$

其中, σ 为 Sigmoid 函数, $W_0 \in R^{C/r \times C}$, $W_1 \in R^{C \times C/r}$, 多层感知机的权重 W_0 与 W_1 共享, F_{avg} 与 F_{max} 分别代表对

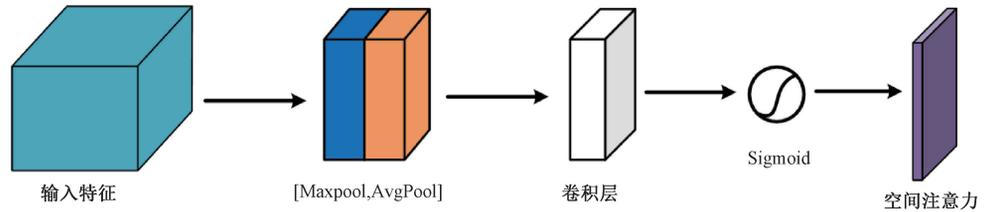


图 6 空间注意力模块

特征图 F 的平均池化和最大池化。

随后,如图 6 所示,将通过通道注意力模块处理之后的特征图作为空间注意力模块的输入,在通道上进行平均池化和最大池化操作,将两者的结果进行 concat 操作,随后将通道数降为 1,以便之后与任意通道数特征图相乘,再经过 Sigmoid 函数生成归一化的空间注意力权重。具体工作过程如式(5)所示,其中 σ 为 Sigmoid 函数, $f^{7 \times 7}$ 代表 7×7 大小的卷积核。

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{avg}}; F_{\text{max}}])) \quad (5)$$

1.3 改进的 U-Net 模型

本文通过改进 U-Net,设计了如图 7 所示的整体网络体系结构。该网络基于编码器-解码器的 U 形结构,在解码时采用跳跃连接来保持浅层特征;并利用 Ghost 模块代替原始的卷积模块,使用一半的标准卷积来生成剩余特征图,在保证准确率的同时大大降低计算成本;运用 Half U-Net 多尺度特征融合模块代替原始的特征融合模块,在不增加额外计算量的同时,可获取到全尺度特征,在保留细节特征的同时,增强前后层之间的联系,有效提升检测细小病变的能力,大大提升了网络的综合性能。

2 实验过程及参数设定

2.1 数据集与实验配置

1) 图像数据集

本数据集分别来自 IDRiD^[28] 和 e_ophtha^[29], 其中

IDRiD 病变分割中由 81 张图像组成,分别包含了 MA、HE、SE 和 EX 4 种病变类型,e_ophtha 数据集由 47 张 EX 和 148 张 MA 组成。部分样本图像、病变注释如图 8 所示。

2) 图片预处理

通过观察数据集图像可以发现,眼底图像存在着许多与黑色无关的背景,这些黑色背景不包含任何病变信息,为了去除黑色背景对分割的影响,这里采用阈值分割的 Otsu 算法^[30]将图像分为感兴趣区域和无关区域。具体效果如图 9 所示,黑色部分为背景,白色部分为感兴趣区域。将原始图像与阈值处理图像相乘,从而去除黑色部分对训练的影响。由于医学图像往往像素较大,为了方便训练,将输入网络图像大小调整为 512×512 。

3) 实验配置

在项目的研究工作中,使用 Adam 优化器作为优化方

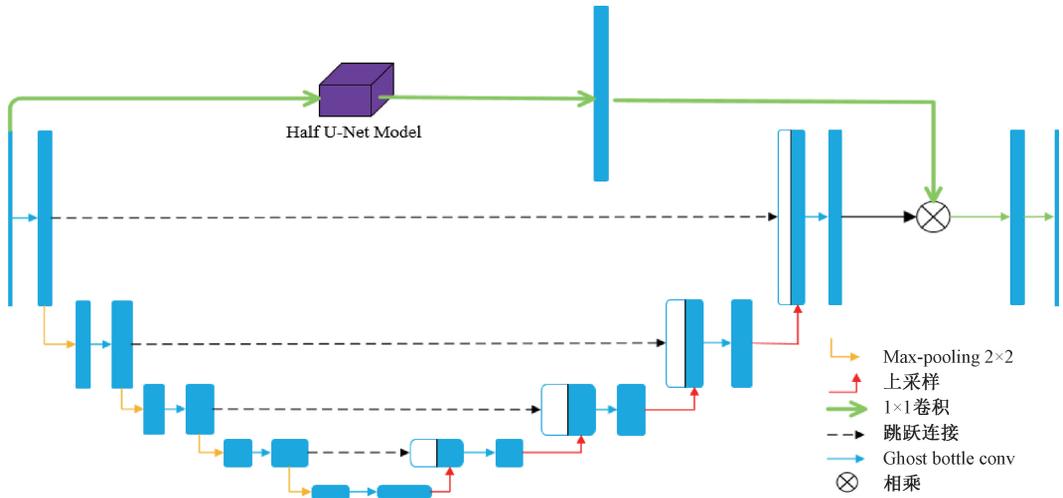


图 7 改进后的 U-Net 模型框架图

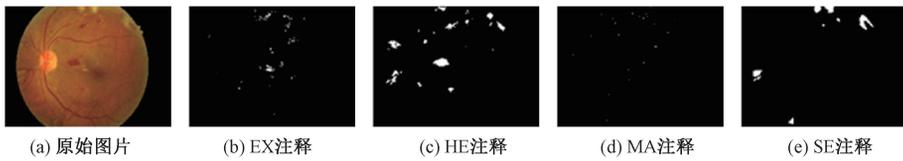


图 8 DR 病变样本图片

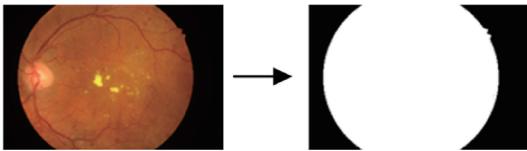


图 9 Otsu 阈值算法预处理图片

$$F1-Score = \frac{2TP}{2TP + FP + FN} \times 100\% \quad (7)$$

3 实验结果与分析

本节用于展示改进的 U-Net 方法在 IDRiD 和 E-ophta 两个数据集分割过程中的实验结果,并且展示不同模型的参数量以及 FLOPs。

3.1 分割结果

本文选取注意力 U 型网络 (Attention UNet)、多模态生物医学图像分割 U-Net 框架 (MultiResUnet)^[31]、Att-UNet、U-Net++ 4 种当前常用经典模型、MSM+INI^[16] 眼底病变分割网络以及 MobileNetV2、Xception 两个轻量级网络与本文所改进的网络进行比较,并用 U-Net 网络作为基线进行对比。

实验结果显示,新方法的平均 IoU 与 F1-Score 值在两个数据集上分别达到了 61.84%、61.42% 和 70.59%、69.41%。表 1、2 分别展示了不同分割模型在 IDRiD 和 E-ophta 上的 IoU 值与 F1-Score 分数。结果表明,在 IoU 与 F1-Score 指标方面,本文的分割网络在所有眼底病变类型分割效果上均优于其他网络的工作性能。

图 10 展示了不同模型的分割效果。第一行到第 6 行分别为 E-ophta 数据集中的 EX、MA 和 IDRiD 中的 EX、HE、MA、SE。结果表明,U-Net、U-Net++ 和 Attention-UNet 对大目标能够进行简单的分割,但对于细小、密集的目标无法得到有效的分割结果。Xception 和 MobileNetV2 两个轻量级分割模型虽然消耗资源较少,但准确率并不理

法,采用批量大小为 1 的小批量进行模型训练,由于本文训练是对每个类别进行单独的分割,仅涉及到单目标和背景两类,故可使用 BCELoss(二分类交叉熵损失)作为损失函数。初始学习率设为 0.001,权重衰减为 0.001,进行 100 次迭代训练,并在每 10 轮训练之后学习率减少 10 倍。所有的模型均使用 Pytorch 软件包实现,所有实验都在配备 15 GB 内存 NVIDIA GeForce RTX 3060 Laptop GPU 上进行。

2.2 性能评估指标

图像分割本质上是对像素进行分类。分类结果可以基于混淆矩阵,由其中的真正类(true position, TP)、假正类(false negatives, FN)、真负类(true negatives, TN)、假正类(false position, FP)进行不同的公式运算,从而得到最后的分割效果。本项目的评价指标选取交并比(intersection over union, IoU)和 F1-Score 来评估每个模型对不同病变类别的分割精度,值越大就代表分割越精准,如式(6)、(7)所示。

$$IOU = \frac{TP}{TP + FN + FP} \times 100\% \quad (6)$$

表 1 不同网络在 IDRiD 数据集上的 IoU 值

方法	IDRiD					E-ophttha		
	HE	MA	EX	SE	mean	MA	EX	mean
U-Net	49.68	54.00	61.29	53.02	54.50	49.95	53.02	51.49
MultiResUnet	49.36	51.69	57.05	44.32	50.61	49.99	47.75	48.87
Att-UNet	49.65	54.35	63.64	53.13	55.19	49.99	51.58	50.79
U-Net++	49.46	50.09	61.12	52.88	52.17	49.95	51.14	50.55
文献[16]	—	49.94	58.42	56.35	54.90	49.99	52.66	51.32
MobileNetV2	50.01	49.94	58.42	56.35	53.68	49.99	52.41	51.20
Xception	51.08	54.01	63.42	60.04	57.14	49.99	59.08	54.54
本文方法	60.65	58.95	67.80	59.98	61.84	60.74	62.10	61.42

表 2 不同网络在数据集上的 F1-score 值

方法	IDRiD					E-ophttha		
	HE	MA	EX	SE	mean	MA	EX	mean
U-Net	50.18	59.37	71.13	57.73	59.60	49.95	58.90	54.43
MultiResUnet	56.65	53.96	66.50	54.28	57.85	49.99	48.23	49.11
Att-UNet	50.60	57.08	71.64	57.19	59.13	49.99	61.71	55.85
U-Net++	50.17	57.57	69.89	56.72	58.59	49.95	58.47	54.21
文献[16]	58.32	49.97	67.57	61.41	59.31	49.99	57.23	53.61
MobileNetV2	55.51	49.97	73.06	59.45	59.50	49.99	58.93	54.46
Xception	59.37	64.39	72.74	66.67	65.79	49.99	67.90	58.95
本文方法	69.30	66.47	77.77	68.81	70.59	69.74	69.07	69.41

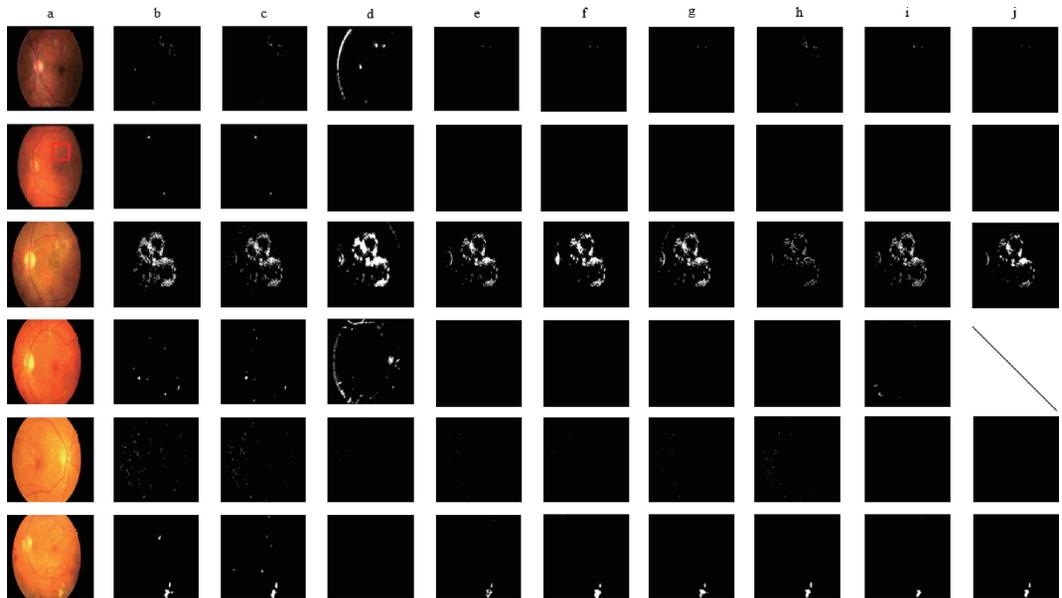


图 10 不同模型分割效果图

想。MultiResUNet 利用深度残差模块将图像局部和全局特征信息进行联系,能够简单的分割出细小、密集目标的位置信息,但仍无法准确的进行分割。而本文改进的分割网络能有效地提取眼底病变图像的特征信息,特别是针对细小、密集的眼底病变特征,表现出了更加优异的分割性

能;甚至是经典网络无法进行有效分割的部分病变图像类型,也能展现出其优质的分割效果,可获得与真实眼底病变图像标签结果相近的分割结果。

表 3 展示了各个模型的参数量与 FLOPs 值,值越小,表示模型越轻量。本项目所改进的模型大小及参数量仅

为 5.48 Mb 和 35.46 GMac,较多数分割网络更加轻量,可极大的节省计算资源。综上所述,本文改进模型在整体的病变分割效果以及模型的大小方面表现更加优异。

表 3 不同模型的参数量及 FLOPs

模型	模型大小/Mb	FLOPs/GMac
Xception	0.303	20.02
MobileNetV2	5.96	6.23
MultiResUNet	7.25	74.44
U-Net++	9.16	138.6
U-Net	32.08	202.91
Att-UNet	34.88	266.54
文献[16]	72.9	332.1
本文方法	5.48	35.46

3.2 消融实验

为了验证本项目所使用的 Ghost Model 和 Half-UNet 多尺度特征模块的有效性,通过调整不同模块的同时在 IDRiD 和 E-ophtha 数据集上进行实验。以 U-Net 为基线设计了如表 4、5 所示的 3 组消融实验。通过消融实验结果可以看出,利用 Ghost 模块与多尺度特征融合模块对 U-Net 网络性能的提升均有影响,证明了各个模块的有效性。但 Half-UNet 模块在模型加入 Ghost 模块之后提升更为明显。

表 4 不同结构下的 IoU 对比

a	b	IDRiD				E_ophtha	
		HE	MA	EX	SE	MA	EX
		49.68	54.00	61.29	53.02	49.95	53.02
✓		55.37	58.94	67.39	59.18	59.79	62.26
	✓	49.47	54.71	63.89	51.71	49.99	55.43
✓	✓	60.61	58.95	67.80	59.98	60.74	62.10

注:(a)Ghost 卷积;(b)Half-UNet 多尺度特征融合

表 5 不同结构下的 F1-Score 对比

a	b	IDRiD				E_ophtha	
		HE	MA	EX	SE	MA	EX
		50.18	59.37	71.13	57.73	49.95	58.9
✓		65.44	66.22	77.56	64.56	69.12	71.06
	✓	49.88	66.25	72.62	57.25	50.00	62.63
✓	✓	69.30	66.47	77.77	68.81	69.74	69.07

注:(a)Ghost 卷积;(b)Half-UNet 多尺度特征融合

4 结 论

本文针对糖尿病视网膜病变图像分割网络参数量多、计算量大以及病变特征分割精度低等问题,在 U-Net 的基

础上,使用 Ghost 卷积模块替换了原始卷积,并设计了一种 Half-UNet 多尺度特征融合模块来提高对细小、密集病变的分割性能,进而改进 U-Net 分割网络。该模型与经典分割网络对比,表现出了更加优异的分割性能;甚至是经典网络无法进行有效分割的部分病变图像类型,该模型也能展现出其优质的分割效果,可获得与真实眼底病变图像标签结果相近的分割结果。目前,所改进模型的分割性能仍不完美,在一定程度上存在着小概率错误分割情况,这也是本项目研究后续工作中需要解决的一个重要难题。

实验结果表明,改进的 U-Net 分割网络在 IDRiD 和 E-ophtha 糖尿病视网膜病变图像上只需要利用少量的参数,较少计算成本就可以达到优质的分割性能,为今后临床检测和诊断治疗提供了可靠的辅助手段,也为图像分割模型轻量化的研究发展提供了新的思维方式和参考方法。

参考文献

- [1] HENDRICK A M, GIBSON M V, KULSHRESHTHA A. Diabetic retinopathy [J]. Primary Care, 2015, 42(3): 451.
- [2] WONG T Y, CHEUNG C M G, LARSEN M, et al. Diabetic retinopathy [J]. Nature Reviews Disease Primers, 2016, 2(1): 16012.
- [3] BHUVANESWARI R, VAIDYANATHAN S G. Classification and grading of diabetic retinopathy images using mixture of ensemble classifiers [J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(6): 7407-7419.
- [4] 程小辉,李贺军,邓响,等.基于 ME-ANet 模型的糖尿病视网膜病变分级[J].广西科学,2022,29(2): 249-259.
- [5] 朱俊东,卓广平,吴诗雨,等.基于迁移学习的糖尿病视网膜病变的分类检测[J/OL].中北大学学报(自然科学版),2023(4):478-486[2023-06-29].
- [6] LI L. Image thresholding based on two-dimensional tsallis gray entropy using fast iterative algorithm[J]. Icvisp 2019: Proceedings of the 3rd International Conference on Vision, Image and Signal Processing, 2019: 11:1-11:5.
- [7] SANKAR M, BATRI D R K, PARVATHI R. Automatic classification of retinal vessels into artery and veins using supervised graph approach [J]. Semantic Scholar, 2016.
- [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] ZHOU Z, RAHMAN SIDDIQUEE M M,

- TAJBAKHS 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.
- [10] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas [J]. ArXiv Preprint, 2018, ArXiv: 1804.03999.
- [11] CAIXIA K, WEI L, WEI L, et al. Microaneurysms segmentation with a U-Net based on recurrent residual convolutional neural network[J]. Journal of Medical Imaging, 2019, 6(2): 025008.
- [12] SHUANG Y, DI X, YOGESAN K. Exudate detection for diabetic retinopathy with convolutional neural networks [C]. The IEEE Engineering in Medicine and Biology Society, 2017: 1744-1747.
- [13] CHRISTIAN S, VINCENT V, SERGEY I, et al. Rethinking the inception architecture for computer vision [J]. Proceedings-IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016, DOI: abs/1512.00567 (1): 2818-2826.
- [14] KAIMING H, XIANGYU Z, SHAOQING R, et al. Deep residual learning for image recognition [C]. Computer Vision and Pattern Recognition, 2016, abs/1512.03385(1): 770-778.
- [15] KAREN S, ANDREW Z. Very deep convolutional networks for large-scale image recognition [C]. International Conference on Learning Representations, 2014.
- [16] 艾星芳, 谢鑫鹏. 基于多分辨率融合深度学习网络的视网膜病变分割[J]. 现代计算机, 2021(5): 52-56.
- [17] ALBAHLI S, YAR G. Detection of diabetic retinopathy using custom cnn to segment the lesions[J]. Intelligent Automation and Soft Computing, 2022, 33(2): 837-853.
- [18] KRISHNAMOORTHY S, SHANTHINI A, MANOGARAN G, et al. Regression model-based feature filtering for improving hemorrhage detection accuracy in diabetic retinopathy treatment [J]. International Journal of Uncertainty Fuzziness and Knowledge-Based Systems, 2021, 29: 51-71.
- [19] HAN K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 1580-1589.
- [20] 邓仕俊, 汤红忠, 曾黎, 等. 基于多尺度特征感知的胸腔图像危及器官分割[J]. 中国生物医学工程学报, 2021, 40(6): 701-711.
- [21] 梁礼明, 詹涛, 雷坤, 等. 多级自适应尺度的 U 型视网膜血管分割算法[J]. 电子测量技术, 2022, 45(13): 130-140.
- [22] 闫祎巧, 王宏生, 赵怀慈, 等. 融合多尺度卷积和注意力机制的场景提取方法 [J]. 电子测量技术, 2023, 46(16): 172-178.
- [23] 杨昆, 杨月婷, 路宇飞, 等. 多光谱视网膜成像动静脉自动分割方法[J]. 电子测量技术, 2023, 46(10): 84-91.
- [24] 徐晓龙, 俞晓春, 何晓佳, 等. 基于改进 U-Net 的街景图像语义分割方法[J]. 电子测量技术, 2023, 46(9): 117-123.
- [25] YAN H, XIE J, ZHU D, et al. MSLF-Net: A multi-scale and multi-level feature fusion net for diabetic retinopathy segmentation [J]. Diagnostics (Basel), 2022, 12(12): 2918.
- [26] YIN P, YUAN R, CHENG Y, et al. Deep guidance network for biomedical image segmentation[J]. IEEE Access, 2020, 8: 116106-116116.
- [27] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Computer Vision-ECCV 2018: 15th European Conference, 2018: 3-19.
- [28] PORWAL P, PACHADE S, KOKARE M, et al. IDRid: Diabetic retinopathy-segmentation and grading challenge[J]. Med Image Anal, 2020, 59: 101561.
- [29] DECENCIÈRE E, CAZUGUEL G, ZHANG X, et al. TeleOphta: Machine learning and image processing methods for teleophthalmology [J]. IRBM, 2013, 34(2): 196-203.
- [30] 汪维华, 张景中, 吴文渊. 改进的形态学与 Otsu 相结合的视网膜血管分割[J]. 计算机应用研究, 2019, 36(7): 2228-2231.
- [31] IBTEHAZ N, RAHMAN M S. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. Neural Networks, 2020, 121: 74-87.

作者简介

刘拥民, 教授, 硕士生导师, 主要研究方向为人工智能理论及其应用、网络拥堵控制等。

E-mail: T20040550@csuft.edu.cn

张毅, 硕士研究生, 主要研究方向为医学图像处理。

E-mail: 20221200516@csuft.edu.cn

欧阳凌轩, 硕士研究生, 主要研究方向为图像处理。

E-mail: 1244073529@qq.com

石婷婷, 硕士研究生, 主要研究方向为图像分割、图像识别。

E-mail: 2711002412@qq.com