

光电工程

Opto-Electronic Engineering

中文核心期刊 中国科技核心期刊
Scopus CSCD

自适应特征融合级联Transformer视网膜血管分割算法

梁礼明, 卢宝贺, 龙鹏威, 阳渊

引用本文:

梁礼明, 卢宝贺, 龙鹏威, 等. 自适应特征融合级联Transformer视网膜血管分割算法[J]. 光电工程, 2023, 50(10): 230161.

Liang L M, Lu B H, Long P W, et al. Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm[J]. *Opto-Electron Eng*, 2023, 50(10): 230161.

<https://doi.org/10.12086/oe.2023.230161>

收稿日期: 2023-07-03; 修改日期: 2023-09-28; 录用日期: 2023-10-07

相关论文

基于注意力机制多特征融合的视网膜病变分级算法

梁礼明, 董信, 李仁杰, 何安军

光电工程 2023, 50(1): 220199 doi: 10.12086/oe.2023.220199

鬼影卷积自适应视网膜血管分割算法

梁礼明, 周珑颂, 陈鑫, 余洁, 冯新刚

光电工程 2021, 48(10): 210291 doi: 10.12086/oe.2021.210291

边界注意力辅助的动态图卷积视网膜血管分割

吕佳, 王泽宇, 梁浩城

光电工程 2023, 50(1): 220116 doi: 10.12086/oe.2023.220116

引入双编码器模型的OCT视网膜图像分割

陈明惠, 王腾, 袁媛, 柯舒婷

光电工程 2023, 50(10): 230146 doi: 10.12086/oe.2023.230146

更多相关论文见光电期刊集群网站 

 **光电工程**
Opto-Electronic Engineering

<http://cn.ojournal.org/oe>




OE_Journal



Website

DOI: 10.12086/oe.2023.230161

自适应特征融合级联 Transformer 视网膜血管分割算法



梁礼明, 卢宝贺*, 龙鹏威, 阳 渊

江西理工大学电气工程与自动化学院, 江西 赣州 341000

摘要: 针对眼底视网膜分割存在病理伪影干扰、微小血管分割不完全和血管前景与非血管背景对比度低等问题, 本文提出一种自适应特征融合级联 Transformer 视网膜血管分割算法。该算法首先通过限制对比度直方图均衡化和 Gamma 校正等方法进行图像预处理, 以增强血管纹理特征; 其次在编码部分设计自适应增强注意力模块, 降低计算冗余度同时消除视网膜背景图像噪声; 然后在编解码结构底部加入级联群体 Transformer 模块, 建立血管特征长短距离依赖; 最后在解码部分引入门控特征融合模块, 实现编解码语义融合, 提升视网膜血管分割光滑度。在公共数据集 DRIVE、CHASE_DB1 和 STARE 上进行验证, 准确率达到 97.09%、97.60% 和 97.57%, 灵敏度达到 80.38%、81.05% 和 80.32%, 特异性达到 98.69%、98.71% 和 98.99%。实验结果表明, 本文算法总体性能优于现有大多数先进算法, 对临床眼科疾病的诊断具有一定应用价值。

关键词: 视网膜血管分割; Transformer; 自适应增强注意力; 门控特征融合

中图分类号: TP391

文献标志码: A

梁礼明, 卢宝贺, 龙鹏威, 等. 自适应特征融合级联 Transformer 视网膜血管分割算法 [J]. 光电工程, 2023, 50(10): 230161
Liang L M, Lu B H, Long P W, et al. Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm[J].
Opto-Electron Eng, 2023, 50(10): 230161

Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm

Liang Liming, Lu Baohe*, Long Pengwei, Yang Yuan

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

Abstract: An adaptive feature fusion cascaded Transformer retinal vessel segmentation algorithm is proposed in this paper to address issues such as pathological artifacts interference, incomplete segmentation of small vessels, and low contrast between vascular foreground and non-vascular background. Firstly, image preprocessing is performed through contrast-limited histogram equalization and Gamma correction to enhance vascular texture features. Secondly, an adaptive enhancing attention module is designed in the encoding part to reduce computational redundancy while eliminating noise in retinal background images. Furthermore, a cascaded ensemble Transformer module is introduced at the bottom of the encoding-decoding structure to establish dependencies between long and short-distance vascular features. Lastly, a gate-controlled feature fusion module is introduced in the decoding part to achieve semantic fusion between encoding and decoding, enhancing the smoothness of retinal vessel segmentation. Validation on public datasets DRIVE, CHASE_DB1, and STARE

收稿日期: 2023-07-03; 修回日期: 2023-09-28; 录用日期: 2023-10-07

基金项目: 国家自然科学基金资助项目 (51365017, 6146301); 江西省自然科学基金资助项目 (20192BAB205084)

*通信作者: 卢宝贺, E-mail: 939175848@qq.com.

版权所有©2023 中国科学院光电技术研究所

yielded accuracy rates of 97.09%, 97.60%, and 97.57%, sensitivity rates of 80.38%, 81.05%, and 80.32%, and specificity rates of 98.69%, 98.71%, and 98.99%, respectively. Experimental results indicate that the overall performance of this algorithm surpasses that of most existing state-of-the-art methods and holds potential value in the diagnosis of clinical ophthalmic diseases.

Keywords: retinal vessel segmentation; Transformer; adaptive enhancement of attention; gating feature fusion

1 引言

视网膜血管图像包含丰富的几何结构, 如血管直径、分支角度和长度等, 眼科医生可通过观察视网膜血管结构信息来预防和诊断高血压、糖尿病和动脉粥样硬化等疾病。但眼底血管拓扑结构错综复杂, 在医学提取上较为困难。因此研究一种能高效且自动的视网膜血管分割算法对临床病理诊断具有重要意义^[1-4]。

当下视网膜血管分割方法主要分为传统机器学习和基于深度学习方法。其中传统机器学习方法包括基于形态学处理、基于匹配滤波和小波变换等, 此类方法通常不需先验标记信息, 而是利用数据之间的相似性进行分析。Marios 等^[5]构建一种多尺度线跟踪方法, 利用血管方向属性和形态学重建以实现视网膜血管分割, 该方法减少了背景图像噪声影响, 但无法充分利用血管信息, 导致血管纹理模糊。Azzopardi 等^[6]设计选择性响应滤波器实现视网膜血管的分割, 该方法提高了分割交叉血管的能力, 但分割结果易受图像噪声影响。王晓红等^[7]采用多尺度二维 Gabor 小波变换方法对视网膜图像进行分割, 用不同方法提取粗细血管。此类方法先对视网膜图像进行预处理, 其次对预处理图像进行阈值处理以实现视网膜血管分割。近年来, 基于深度学习的方法被较多学者引入视网膜血管分割任务, 并取得优秀的分割效果。深度学习方法是从端到端的学习方式, 可以自动提取图像底层和高层特征信息, 相较于传统分割方法避免了人工特征提取的过程, 同时减少了分割主观性, 其泛化能力明显优于传统方法。如全卷积网络^[8]通过在编码器路径中应用卷积、激活函数和池化层, 并在解码器中采用卷积层和上采样, 实现像素级语义分割。编解码网络结构 U-Net^[9]性能已在诸多医学语义分割任务中领先, 脑肿瘤分割^[10]和肾肿瘤分割^[11]中 U-Net 均取得较好成效。Li 等^[12]提出动态通道卷积网络 (dynamic-channel graph convolutional network, DCGCN), 将视网膜图像通道映射到拓扑空间, 并在拓扑图上合成每个通道特征, 进而提升视网膜血管的信息利用率。Wang 等^[13]构建多尺度上下文感知网络 (context-aware

network, CA-Net), 为通道分配不同权重, 使网络能够充分捕获血管上下文信息。Yang 等^[14]设计强化神经 P 型双通道扩张卷积网络 (spiking neural P-type dual-channel dilated convolutional network, SDDC-Net) 实现视网膜血管分割, 将强化神经 P 卷积神经元集成到经典编解码结构中, 并在编码部分使用扩张卷积以提升感受野。虽然上述方法在视网膜分割任务中总体上取得了较好的血管分割效果, 但仍存在一定缺陷, 如文献 [9] 边缘检测能力较弱, 易受到病理伪影干扰且网络运行效率较低; 文献 [12] 忽略了全局上下文信息, 会在一定程度上丢失血管轮廓信息; 文献 [13] 血管边界检测能力较弱, 出现微小血管纹理模糊问题; 文献 [14] 采用扩张卷积扩大感受野, 但会造成血管局部特征信息丢失。

针对上述挑战, 本文提出自适应特征融合级联 Transformer 视网膜血管分割算法 (adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm, AFCT-Net), 其主要工作为: ①在编码部分设计自适应增强注意模块, 提升不同通道之间信息交互能力, 同时剔除图像背景噪声信息降低病理伪影干扰, 增强血管图像非线性能力; ②在编解码底端加入级联群体 Transformer 模块, 有效聚合上下文血管特征信息, 充分捕捉微小血管局部特征; ③在解码部分引入门控特征融合模块, 捕获编解码层不同尺寸空间特征信息, 提升特征利用率及算法鲁棒性。

2 本文算法

2.1 算法设计

针对视网膜血管分割任务面临视盘边界误分割、病理伪影干扰和微小血管分割不完全等问题, 本文基于 U 型网络构建一种自适应特征融合级联 Transformer 视网膜血管分割算法, 其结构如图 1 所示。AFCT-Net 由特征增强网络、自适应增强编码、门控特征融合解码及底端级联群体 Transformer 模块四部分组成。首先对视网膜数据集原图像以滑窗裁剪




图 1 自适应特征融合级联 Transformer 视网膜血管分割算法
Fig. 1 Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm

为特征图像块的方式进行数据集扩充, 以保证模型的充分训练与预测; 其次进行图像灰度化、直方图均衡化和 Gamma 校正等操作进行数据集图像增强, 提升血管纹理对比度; 再次自适应增强编码对其编码整合, 提升不同通道之间信息交互能力和降低计算冗余; 此外在网络底端设计级联群体 Transformer 模块将编码信息进行多尺度融合, 促进血管局部信息的有机提取; 最后经门控特征融合部分整合编码信息, 实现对血管特征图像的细粒度还原, 并通过 SoftMax 函数得到血管分割二值图像。

2.2 级联群体 Transformer 模块

Transformer^[15] 模型由 Google 公司在 2017 年提出, 并应用于自然语言处理, 随后 Vision Transformer^[16] 出现并应用于图像分割领域, 其具有较强的全局归纳建模能力, 能够有效聚合上下文信息并摆脱模型对大规模数据的增广依赖。Liu^[17] 等构建级联群体注意模块, 可以为具有不同特征的注意力头提供反馈, 减少计算冗余, 增强抗过拟合能力。为了建立血管特征长短距离依赖, 提升微小血管提取能力, 本文受文献 [17] 和文献 [18] 启发, 融合构建级联群体 Transformer 模块 (cascaded group Transformer module, CGT), 其结构如图 2 所示。

CGT 模块由级联群体注意模块 (cascaded group attention module, CGA)、layer norm 和前馈神经网络 (feed forward network, FFN) 组成。在视网膜血管分割领域中, 图像经过编码后往往很模糊, 需借助上下文信息才能增加分割准确性, 故上下文建模对于视网膜分割任务至关重要, 因此本文算法在编解码底部加入 Transformer 模块, 又因 CGA 模块可以解决因为注

意头之间高度相似性引起的计算冗余问题, 从而提升网络训练及测试效率, 故结合两者优点融合构建为 CGT 模块, 其中 CGA 模块结构如图 3 所示。




图 2 级联群体 Transformer 模块
Fig. 2 Cascade group Transformer module

CGA 首先将视网膜血管特征分解, 将不同的血管语义信息提供给每个注意力, 从而明确分解头部之间注意力计算, 解决计算冗余问题; 其次 QKV 层学习具有丰富信息的血管特征投影来提高模块能力, 在 Q 投影之后应用交互层以捕获视网膜血管局部与全局特征信息; 最后将每个头部的输出添加到后续头部以逐步细化视网膜血管特征, 其数学表达式可表述为

$$X'_{ij} = X_{ij} + \tilde{X}_{i(j-1)}, 1 < j \leq h, \quad (1)$$

其中, X'_{ij} 是第 j 个输入分割 X_{ij} 和第 $(j-1)$ 个头输出 $\tilde{x}_{i(j-1)}$ 之和, 当计算自注意时将取代 X_{ij} 作为第 j 个头的新输入特征。CGA 可以表述为

$$\tilde{X}_{ij} = \text{Attn}(X_{ij}W_{ij}^Q, X_{ij}W_{ij}^K, X_{ij}W_{ij}^V), \quad (2)$$

$$\tilde{X}_{i+1} = \text{Concat}[\tilde{X}_{ij}]_{j=1:h} W_i^P, \quad (3)$$

其中: $X_i = [X_{i1}, X_{i2}, \dots, X_{ih}]$, $1 \leq j \leq h$, h 是头部总数, W_{ij}^Q , W_{ij}^K , W_{ij}^V 是映射输入特征分割到不同子空间的投影层, W_i^P 是将级联输出特征投影变回与输入一致

维度的线性层。

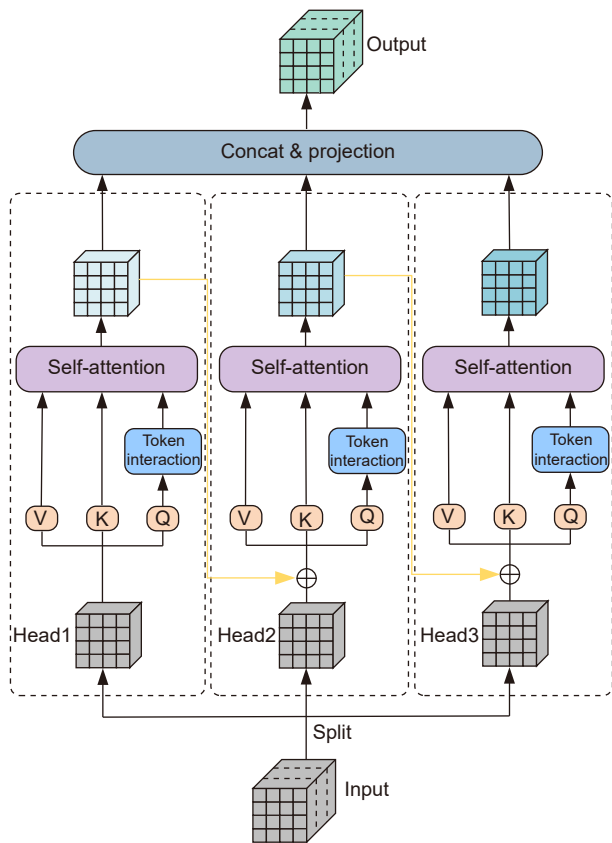


图3 级联群体注意模块

Fig. 3 Cascade group attention module

此类级联设计有两个优点：一是将不同的血管语义提供给每个注意力头，以提高其多样性；二是级联注意力头可以增加网络深度，从而在不引入任何额外参数情况下提高模型容量。编解码底部引入级联群体注意模块，使其在高维空间中有更多通道来学习表示，以此防止血管信息特征丢失，减少冗余参数，加快推理速度，提高模型效率。

2.3 自适应增强注意模块

注意力机制在图像分割领域取得了较大成功，Hu等^[19]设计挤压激励模块(squeeze excitation, SE)模块，加强了高低分辨率特征之间的语义联系，排除了

非血管噪声干扰。针对眼底视网膜血管图像多通道特性及非血管背景噪声干扰问题。本文受文献[19]启发设计自适应增强注意模块(adaptive enhanced attention module, AEA)，其结构如图4所示。

AEA模块首先对输入特征图 F_{in}^i 进行归一化及 1×1 卷积等操作，充分获取视网膜血管特征图 F_{in}^i 的血管语义信息，使用 1×1 卷积可以在不破坏视网膜图像空间结构的同时保留血管局部特征，且能够灵活控制数据通道数；其次进行自适应平均池化操作将特征图尺寸缩减为 $C \times 1 \times 1$ ，降低信息冗余并自由控制输出特征图尺寸；再次将Sigmoid激活后特征 F_L 与输入特征 F_{in}^i 进行特征相乘，使图像尺寸恢复到与输入图像尺寸同一，增强血管图像非线性能力；此外特征 F_L 与原特征 F_{in}^i 特征相加，减小视网膜图像背景噪声影响，降低病理伪影对分割结果的干扰并防止过拟合；最后经过卷积与Leaky ReLU激活函数后得到最终特征图 F_{out} 。其在数学上表示如下：

$$F_L = S(\lambda(\sigma(\text{Con}(\text{BN}(F_{in}^i))))), \quad (4)$$

$$F_{out} = \delta(\text{Con}(F_{in}^i(S(F_L) + 1))), \quad (5)$$

其中： S 表示Sigmoid操作， λ 表示自适应平均池化(adaptive AvgPool)， σ 表示ReLU激活函数， Con 表示卷积操作， BN 表示BatchNorm操作， δ 表示Leaky ReLU操作， F_{in}^i 表示第 i 层输入特征图， F_L 表示第一次Sigmoid之后得到的特征图， F_{out}^i 表示第 i 层输出特征图。

2.4 门控特征融合模块

在视网膜血管分割任务中，血管特征利用率对分割结果至关重要。Ni等^[20]提出特征聚合网络，该网络可以融合不同解码层的高级特征提高特征利用率，以减少血管语义信息损失。为了充分利用编解码部分特征以提升血管分割光滑度，本文引入门控特征融合模块^[21](gated feature fusion module, GFF)，其结构如图5所示。




图4 自适应增强注意模块

Fig. 4 Adaptive enhanced attention module

GFF 模块由复位门和选择门组成, 输入端 x_i 是未解码图像, 需要复位门来抑制视网膜图像非血管背景噪声, 而选择门能够将 e_i 和 d_i 的语义信息融合。该模块首先自适应选择 d_i 的有用特征, 实现 x_i 和 d_i 的语义融合以整合编解码部分血管特征信息; 其次经过卷积和 Sigmoid 激活后分别得到 R_i 和 T_i 值, 其计算公式如下:

$$R_i = S(W_R[d_i, x_i]), \tag{6}$$

$$T_i = S(W_T[d_i, x_i]), \tag{7}$$

其中: W_R 和 W_T 分别表示以 d_i 和 x_i 的串接为输入的卷积过程, S 表示 Sigmoid 函数, R_i 和 T_i 分别表示复位栅极值和选择栅极值。

特征信息经过复位门后与原始图像 x_i 特征相乘再与 d_i 拼接并卷积得到整合特征 e_i ; 通过选择门实现整合特征(e_i)与原始分割特征(d_i)之间自适应互补特征融合。 e_i 表示经过选择门的特征与原始特征融合卷积后的特征, 其数学表达为

$$e_i = W[R_i \times x_i, d_i], \tag{8}$$

$$f_{out} = T_i \times e_i + (1 - T_i) \times d_i, \tag{9}$$

其中: W 表示卷积过程, 可以使重新整合的特征与输入 d_i 具有相同维度, f_{out} 表示输出特征图。

3 实验结果分析

3.1 实验环境与数据集

仿真平台为 PyCharm, 使用 Python3.9.0 程序语言在 Pytorch 框架搭建而成, 计算机配置为 11th Gen

Intel(R) Core(TM) i7-11800H CPU, 16 GB 内存, NVIDIA GeForce RTX 3060 GPU, 采用 64 位 windows11 操作系统, 眼底图像数据集来自公共数据集 DRIVE、CHASE_DB1 和 STARE。DRIVE 数据集中包括图像像素为 565 pixel×584 pixel 的 20 幅训练集图片和 20 幅测试集图片。CHASE_DB1 数据集包括 28 张视网膜样本图像, 前 20 个样本图像用于训练, 其余 8 个样本图像用于测试, 每幅图像的大小为 999 pixel×960 pixel, 二值视野 (FOV) Mask 和分割 Ground truth 通过手工方法获得。STARE 数据集包含 20 幅眼底图像, 图像分辨率为 605 pixel×700 pixel, 由于该数据集没有设置训练集及测试集, 故采用五折交叉验证的方法进行实验。另外, 三个数据集中均包括病变眼底图像与正常眼底图像, 血管结构复杂多变且对比度低, 每张图像包含两位专家手工标注的金标准图像, 表明以上数据集对视网膜血管分割任务具有一定挑战性, 故选用以上三个数据集进行实验并将第一位专家的金标准图作为实验参考标准。

3.2 实验数据预处理

由于数据集在采集时存在血管前景与非血管背景对比度低等问题, 为了充分捕获视网膜血管特征信息及提升分割准确率, 需对数据集图像进行预处理。如图 6 所示, 本文首先对数据集进行图像灰度化处理, 减小内存占用降低计算冗余, 突出目标区域; 其次归一化眼底视网膜灰度图像, 避免视网膜图像像素亮度分布不均匀; 再次对灰度图像进行限制对比度直方图均衡化, 减少光照不均匀对视网膜分割的干扰; 最后将图像进行 Gamma 校正, 提升图像视盘部分和血管

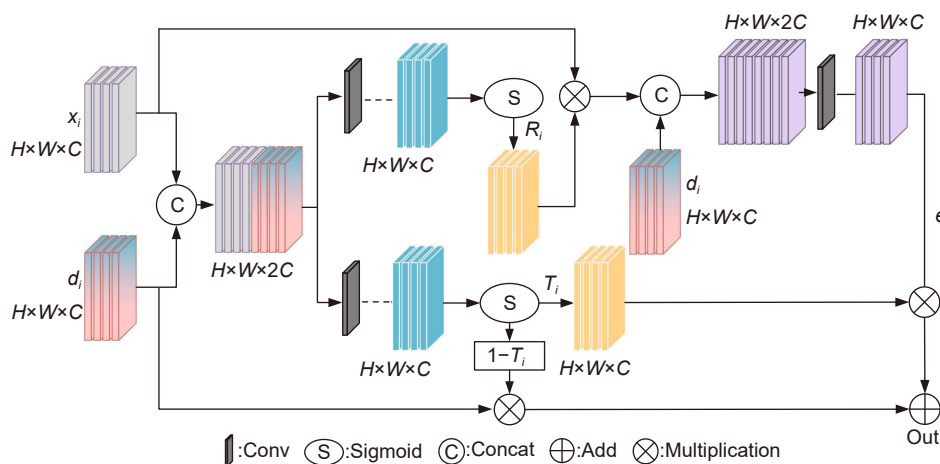


图 5 门控特征融合模块

Fig. 5 Gated feature fusion module




图6 视网膜图像预处理

Fig. 6 Retinal image preprocessing

部分对比度, 增强较暗血管部分可视度。

3.3 图像扩充与参数设置

在网络训练中需要大量数据来拟合模型参数, 而 DRIVE、CHASE_DB1 和 STARE 数据集较小, 较小训练集样本不足以代表整个数据集统计特征, 会导致模型在新数据上表现不如预期, 模型训练会出现过拟合现象且泛化能力不足, 需对数据集进行扩充。本文对图片以滑窗方式进行裁剪, 以 64×64 的滑窗将预处理之后的眼底图像以及金标准图像裁剪为 10000 个特征图像块, 损失函数采用交叉熵函数, 初始学习率设置为 0.0005, batch_size 设置为 6, number of epoches 设置为 20, 训练过程采取早停机制, 若连续 10 轮无最佳权重保存, 则停止训练, 本文算法在 STARE 数据集中训练时间为每轮 1 min 16 s, 测试时间为 52 s; 在 DRIVE 数据集中训练时间为每轮 1 min 17 s, 测试时间为 2 min 48 s; 在 CHASE_DB1 数据集中训练时间为每轮 1 min 17 s, 测试时间为 3 min 53 s。预处理图像局部特征图像块和训练集对应的金标准局部特征图像块, 如图 7 所示。




图7 血管局部特征图像块

Fig. 7 Local feature image blocks of blood vessels

3.4 评价指标

眼底视网膜图像分为两类: 血管前景类和非血管背景类。血管前景类即需要检测分割的目标血管, 称作正类; 非血管背景类即其他剩余部位, 称作负类。为了更清晰地展现出本文算法性能优异性, 将本文算法视网膜分割结果与专家手工分割结果进行对比。对于血管前景像素特征, 本文算法分割结果与专家手工

分割值相同的比例称为真阳率 (TP), 相反则称之为假阳率 (FP); 对于非血管背景像素特征, 本文算法分割结果与专家手工分割值相同的比例为真阴率 (TN), 相反为假阴率 (FN)。

本文计算准确率 (accuracy, Acc)、灵敏度 (sensitivity, Sen)、F1 分数 (F1-score, F1)、特异性 (specificity, Spe) 和受试者工作特性曲线 (area under curve, AUC), 其具体公式分别为

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (10)$$

$$Sen = \frac{TP}{TP + FN}, \quad (11)$$

$$F1 = \frac{2TP}{2TP + FP + FN}, \quad (12)$$

$$Spe = \frac{TN}{TN + FP}. \quad (13)$$

3.5 不同分割算法之间对比

3.5.1 分割结果图客观分析

为了更好地体现本文算法在视网膜血管分割工作中的分割性能, 在公开数据集 DRIVE、CHASE_DB1 和 STARE 上进行验证, 并同文献 [9] 及文献 [22-24] 算法进行比较, 均采用相同环境进行训练以及测试。将本文分割结果与 U-Net 和 Attention U-Net 和 Dense U-Net 和 FR U-Net 进行对比, 其中文献 [9] 为 U-Net 算法、文献 [22] 为 Attention U-Net 算法、文献 [23] 为 Dense U-Net 算法以及文献 [24] 为 FR U-Net 算法。

图 8 第一行、第二行为 DRIVE 数据集中图像, 第三行第四行为 CHASE_DB1 数据集中图像, 第五行、第六行为 STARE 数据集中图像。由第一行健康视网膜图像知, 本文算法和 Dense U-Net 对病理信息有较好抑制效果, U-Net 对主血管分割时出现血管断裂问题, Attention U-Net 和 Dense U-Net 出现微小血管分割不完全问题, FR U-Net 受到病理伪影影响严重,

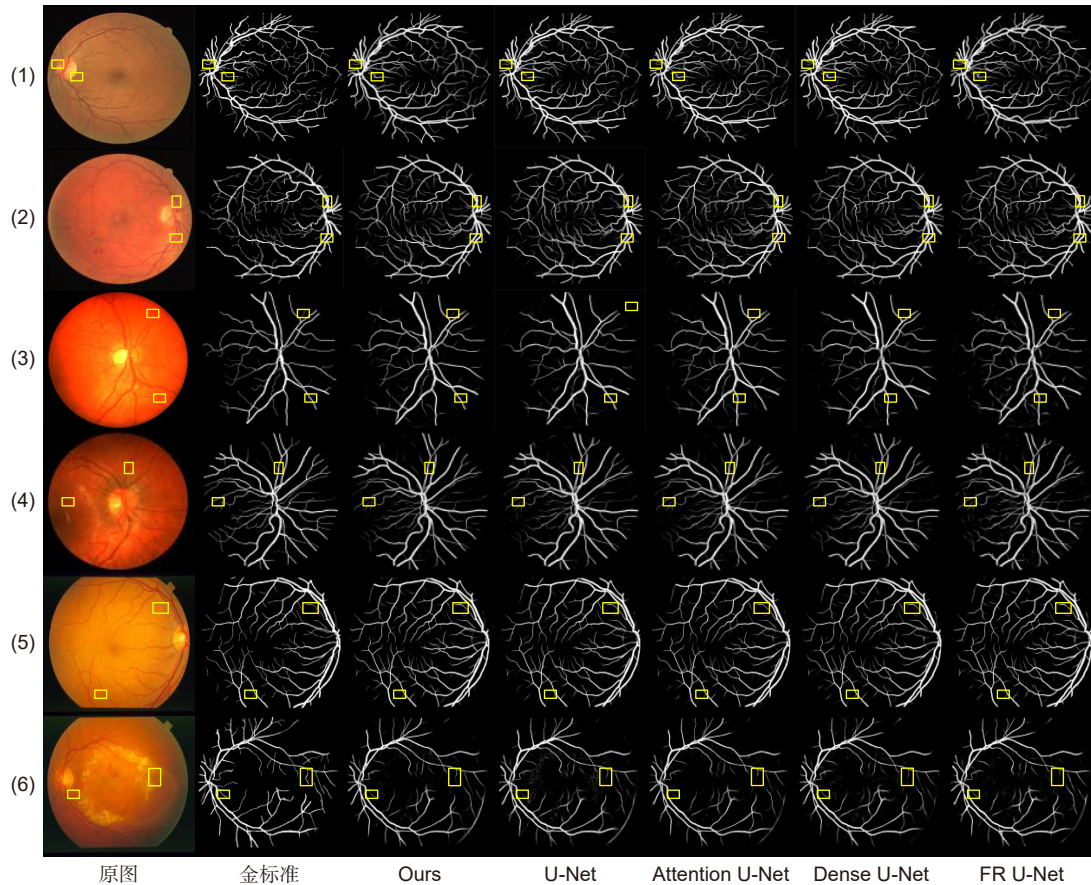


图 8 不同算法视网膜血管分割结果

Fig. 8 Results of retinal vessel segmentation by different algorithms

将病理信息作为血管分割, 假阳性过高; 由第二行病变视网膜图像可知 U-Net、Dense U-Net 及 FR U-Net 出现微小血管分割断裂和血管缺口, U-Net 和 Attention U-Net 出现丢失大量微小血管信息, 因此灵敏度较低; 根据第三行、第四行分割图像可以看出算法对主血管均有较好分割效果, 重点关注微小血管分割情况, 除本文算法外其他算法均出现不同程度误分割和未分割情况; 由第五行 STARE 数据集分割图像中可以看出本文算法较其他算法分割的微小血管数量较多且不易断裂, 并能准确区分背景与目标, 根据第六行 STARE 数据集病理图像分割结果可以看出, U-Net、Dense U-Net 和 FR U-Net 错将病理信息分割为血管信息, 且受病理信息影响血管周围较杂乱, 而本文算法能够剔除病变斑点, 减少血管缺失问题。

实验说明, 本文算法在血管分割方面表现良好, 能系统地捕捉血管形态结构信息, 并且有更少假阳性血管, 使视网膜血管分割图更清晰同时噪声更小, 表明本文算法的有效性以及合理性。

3.5.2 分割局部图客观分析

为了更加直观展示本文算法与文献 [9] 及文献 [22-24] 算法的分割差别, 图 9 详细展示了各算法视网膜局部分割图, 从 DRIVE 数据集、CHASE_DB1 数据集和 STARE 数据集中分别随机取出一幅图进行局部放大进行细节对比。

观察图 9 知, 在第一行 DRIVE 数据集图像分割细节图中, U-Net 出现主血管分割断裂问题。Attention U-Net 主血管分割受到病理伪影影响较大, 非血管背景像素分辨不明。Dense U-Net 出现微小血管未分割及血管分割断裂问题。FR U-Net 和本文算法分割效果较好, 但本文算法相较于 FR U-Net 算法主血管与微细血管能够平滑连接。在第二行 CHASE_DB1 数据集图像分割细节图中, 重点将微小血管进行细节放大对比, 观察对比图发现 U-Net、Attention U-Net、Dense U-Net 和 FR U-Net 均出现血管纹理信息缺失问题, 微小血管分割出现不同程度断裂或未分割问题。在第三行 STARE 数据集图像分割细节图中,

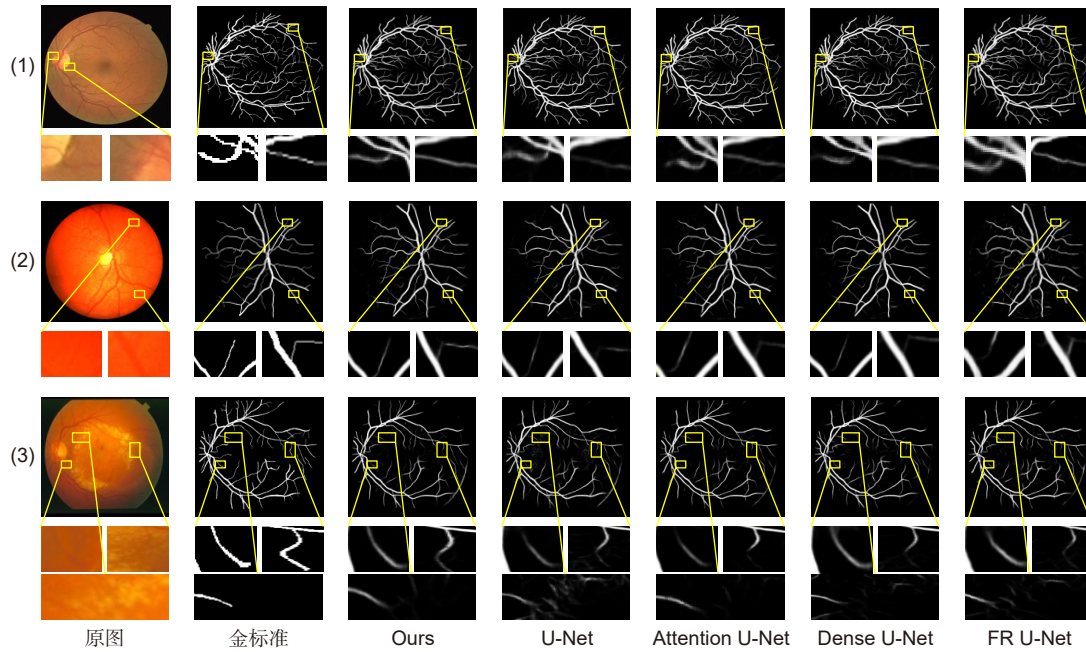


图 9 不同算法视网膜血管局部分割图像

Fig. 9 Image of retinal blood vessel local segmentation by different algorithms

U-Net 和 Attention U-Net 出现血管分割断裂问题, 且除本文算法外其他算法均出现微细血管分割不完全问题。最后放大观察血管周围细节图可以看出 U-Net、Dense U-Net 和 FR U-Net 受病理信息影响较严重, 血管周围较杂乱, 而本文算法和 Attention U-Net 能够剔除病理斑点, 更好地分割血管信息。

综上所述, 本文算法相较于其他算法有较大改进, 能充分捕捉血管语义信息, 从而在病变较严重且对比度较低的眼底图像中分割出更多微小血管, 分割血管情况总体与金标准一致, 说明本文算法在视网膜血管分割任务中的稳健性。

3.5.3 性能指标比较

为了定量分析实验结果, 以此评估本文算法, 从评估指标进行数据分析, 均采用同一实验环境进行对比实验, 其实验结果分别如表 1、表 2 和表 3 所示。表 1 统计了不同算法在 DRIVE 数据集各项指标, 表 2 统计了不同算法在 CHASE_DB1 数据集各项指标, 表 3 统计了不同算法在 STARE 数据集五折交叉验证各项平均指标, 其中标粗为最优指标。图 10 和图 11 分别展示了不同算法在 DRIVE 和 CHASE_DB1 数据集 P-R 曲线及 ROC 曲线对比图。AUC 指标与 ROC 相关, AUC 范围为 0~1, AUC 值越接近 1, 模型预测能力就越好, 而 AUC 值越低, 表示预测模型错误分类率越高。图 12 展示了本文算法在 DRIVE 数据集

表 1 DRIVE 数据集不同算法性能指标/%

Table 1 Performance metrics of different algorithms for the DRIVE dataset /%

数据集	方法	Acc	Sen	Spe	F1	AUC
DRIVE	U-Net	96.97	80.19	98.58	82.26	98.66
	Attention U-Net	97.04	79.19	98.75	82.41	98.72
	Dense U-Net	96.99	79.60	98.66	82.25	98.69
	FR U-Net	97.04	78.96	98.78	82.42	98.74
	Ours	97.09	80.38	98.69	82.87	98.81

表 2 CHASE_DB1 数据集不同算法性能指标/%

Table 2 Performance metrics of different algorithms for the CHASE-DB1 dataset /%

数据集	方法	Acc	Sen	Spe	F1	AUC
CHASE_DB1	U-Net	97.50	80.79	98.62	80.32	98.92
	Attention U-Net	97.57	78.99	98.82	80.43	98.92
	Dense U-Net	97.53	81.51	98.54	80.80	98.95
	FR U-Net	97.44	80.28	98.60	79.85	98.76
	Ours	97.60	81.05	98.71	81.02	98.99

表 3 STARE 数据集不同算法性能指标/%

Table 3 Performance metrics of different algorithms for the STARE dataset /%

数据集	方法	Acc	Sen	Spe	F1	AUC
STARE	U-Net	97.53	79.22	99.06	83.15	99.05
	Attention U-Net	97.55	78.98	99.09	83.17	99.06
	Dense U-Net	97.55	79.68	99.05	83.36	99.09
	FR U-Net	97.51	79.84	98.96	82.99	99.01
	Ours	97.57	80.32	98.99	83.42	99.10

以及 CHASE_DB1 数据集上的训练过程损失趋势。DRIVE 数据集训练损失值维持在 0.095 左右, CHASE_DB1 数据集损失值维持在 0.085 左右, 波动幅度较小, 表明网络已趋于收敛。本文算法在 DRIVE 数据集及 CHASE_DB1 数据集经过三次训练, 但结果相差甚微, 故选用三次测试中指标较高的一次作为实验结果。

在 DRIVE 数据集中, FR U-Net 灵敏度高于本文

0.13%, Attention U-Net 特异性高于本文 0.06%, 但本文算法准确率、F1 指数、ROC 曲线下面积均为最优。在 STARE 数据集中, 除特异性外本文算法其余指标均为最优。在 CHASE_DB1 数据集中 Attention U-Net 特异性高于本文 0.11%, Attention U-Net 和 Dense U-Net 有较好抗过拟合性能, 适合视网膜分割及其他训练数据相对匮乏的任务, 但 Attention U-Net 参数量

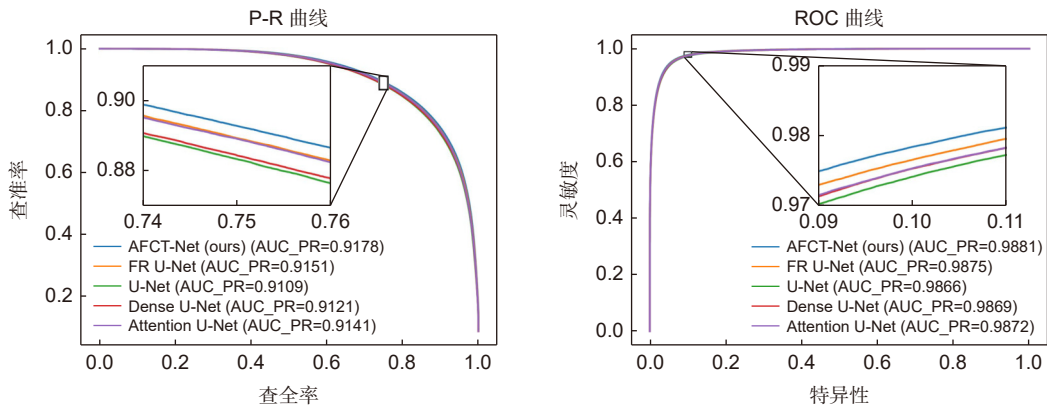


图 10 不同算法在 DRIVE 数据集 P-R 曲线与 ROC 曲线对比图

Fig. 10 Comparison between P-R curve and ROC curve of different algorithms in DRIVE dataset




图 11 不同算法在 CHASE_DB1 数据集 P-R 曲线与 ROC 曲线对比图

Fig. 11 Comparison between P-R curve and ROC curve of different algorithms in CHASE_DB1 dataset

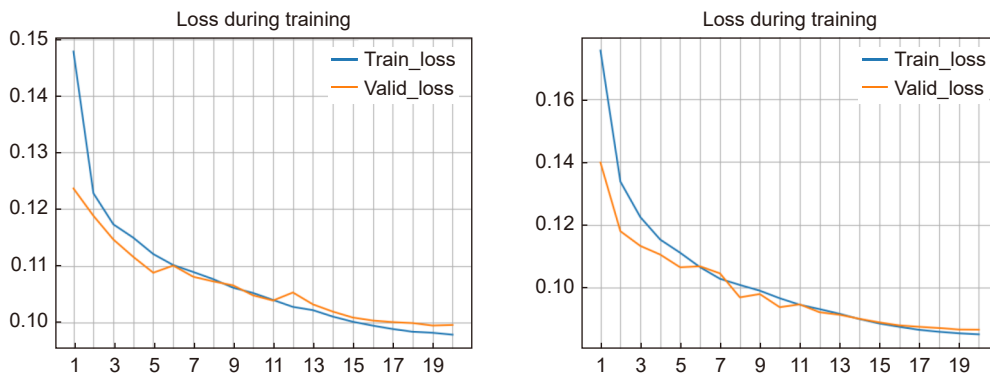


图 12 DRIVE 数据集和 CHASE_DB1 数据集中训练损失曲线图

Fig. 12 Plot of training loss curves in DRIVE dataset and CHASE_DB1 dataset

较大, 网络较为复杂, 需要训练以及测试时间较长。FR U-Net 利用多分辨率卷积交互机制进行水平和垂直扩展, 对特异性有一定提升, 但本文算法其他指标均优于 FR U-Net。说明本文算法性能提升明显、分割效果理想。

3.5.4 与近年先进算法对比

为了进一步说明本文算法在视网膜血管分割中的作用, 将本文所提算法与近年来相关算法进行比较, 如表 4、表 5 和表 6 所示, 其中标粗为最优指标, 其数据均来自原文。

由表 4 可知, 在 DRIVE 数据集中文献 [28] 算法

表 4 DRIVE 数据集对比结果/%

Table 4 Comparison results of DRIVE dataset /%

方法	Acc	Sen	Spe	AUC
文献[23]	96.38	78.05	98.16	96.82
文献[24]	94.80	73.52	97.75	96.78
文献[25]	95.56	78.14	98.10	97.80
文献[26]	96.10	81.25	97.63	
文献[27]	95.76	79.43	98.14	98.23
文献[28]	95.68	79.21	98.10	98.06
文献[29]	95.68	81.15	97.80	98.10
Ours	97.09	80.38	98.69	98.81

表 5 CHASE_DB1 数据集对比结果/%

Table 5 Comparison results of CHASE_DB1 dataset /%

方法	Acc	Sen	Spe	AUC
文献[25]	97.11	76.97	98.65	96.48
文献[26]	94.52	72.79	96.58	96.81
文献[27]	95.90	81.95	97.27	97.84
文献[28]	95.78	80.12	97.30	
文献[29]	95.87	79.47	98.55	98.86
文献[30]	96.35	78.18	98.19	98.10
文献[31]	96.64	80.75	98.41	98.72
Ours	97.60	81.05	98.71	98.99

表 6 STARE 数据集对比结果/%

Table 6 Comparison results of STARE dataset /%

方法	Acc	Sen	Spe	AUC
文献[25]	97.11	78.67	98.80	96.70
文献[26]	95.48	72.65	97.59	96.86
文献[28]	95.86	80.78	97.21	
文献[29]	96.92	82.98	98.55	98.95
文献[30]	96.78	83.52	98.23	98.75
文献[32]	97.47	81.90	98.74	97.06
Ours	97.57	80.32	98.99	99.10

通过定向滤波器捕获微小血管, 灵敏度高于本文算法 0.22%, 但本文算法其他指标均优于文献 [28] 算法, 准确率及特异性均有明显提升, 其余算法分割结果均低于本文算法。说明本文算法能准确分割视网膜血管, 总体稳健性较强。由表 5 可知在 CHASE_DB1 数据集中文献 [26] 灵敏度高于本文算法 0.9%, 文献 [27] 通过非线性连接模式, 使低级特征和高级语义特征集成更加高效, 灵敏度有一定提升, 但本文算法其他指标均优于文献 [27]。文献 [25] 将 Transformer 引入到跳跃连接中, 对特征进行重新编码, 但其指标均低于本文。说明本文算法性能优越鲁棒性强, 在视网膜分割任务中可靠性高。由表 6 可知在 STARE 数据集中文献 [29] 以及文献 [30] 灵敏度高于本文算法, 文献 [29] 开发多尺度多项特征学习模块来有效聚合上下文信息, 提升分割微细血管的能力。文献 [30] 通过注意力模块捕获全局信息, 并通过特征融合过程增强特征, 灵敏度为最优值, 但本文算法其他指标均为最优, 且在 DRIVE 和 CHASE_DB1 数据集中指标均高于文献 [29] 和文献 [30], 表明本文算法泛化能力较强。

3.6 消融实验分析

为了更好地验证本文算法所提各个模块性能, 在 DRIVE、CHASE_DB1 和 STARE 数据集上均进行消融实验, 其中 STARE 数据集采用五折交叉验证的方法进行消融实验, 其结果如表 7、表 8 和表 9 所示。其中 S1 表示 U-Net; S2 表示在 S1 解码部分加入门控特征融合模块; S3 表示在 S2 编码部分加入自适应增

表 7 DRIVE 数据集消融实验分析/%

Table 7 Analysis of ablation experiments on the DRIVE dataset /%

模型	Acc	Sen	Spe	F1	AUC
S1	96.97	80.19	98.58	82.26	98.66
S2	97.06	79.69	98.73	82.62	98.75
S3	97.06	78.18	98.87	82.36	98.87
S4	97.09	80.38	98.69	82.87	98.81

表 8 CHASE_DB1 数据集消融实验分析/%

Table 8 Analysis of ablation experiments on the CHASE-DB1 dataset /%

模型	Acc	Sen	Spe	F1	AUC
S1	97.50	80.79	98.62	80.32	98.66
S2	97.55	79.01	98.80	80.31	98.95
S3	97.59	80.52	98.74	80.85	98.99
S4	97.60	81.05	98.71	81.02	98.99

强注意模块; S4 表示在 S3 编码底端加入级联群体 Transformer 模块, 即本文设计算法。

表 9 SATRE 数据集消融实验分析/
Table 9 Analysis of ablation experiments on the STARE dataset /%

模型	Acc	Sen	Spe	F1	AUC
S1	97.53	79.22	99.06	83.15	99.05
S2	97.55	79.38	99.04	83.16	99.04
S3	97.55	79.90	99.01	83.32	99.08
S4	97.57	80.32	98.99	83.42	99.10

在 DRIVE 数据集消融实验中 S2 各项指标相较于 U-Net 网络均有提升, 在 S3 中 Spe 与 AUC 达到最优, ACC 指标也较好, 但 Sen 较低, 在 S4 中整体指标达到最优, ACC 和 Sen 均达到最优; 在 CHASE_DB1 数据集消融实验中 S2 除 Sen 和 F1 指数外其他指标均有不同程度提升, S3 中除 Spe 外其他指标均有提升, 但 Sen 指标仍低于 U-Net 算法, S4 中整体达到最优; 在 STARE 数据集消融实验中, S4 除 Spe 外指标均达到最优, 但 ACC 及 AUC 提升较小。

综上所述, GFF 能处理好视网膜分割任务中多尺度问题, 提升正确分割微小血管的能力, 但会对 Sen 有一定影响; 加入 AEA 模块后除 DRIVE 数据集中 Sen 指标降低外其他指标均有提升, 说明 AEA 模块能够消除背景噪声并降低病理伪影干扰; 最后加入 CGT 模块, Sen 指标相较于未加入 CGT 模块均有较大提升, 表明 CGT 模块能够增加捕获微小血管局部特征的能力。消融实验表明 AFCT-Net 有效且合理。

4 结束语

眼底视网膜血管分割是医学领域一项重要研究, 是人工分析向自动诊断跨越的重要过程, 本文针对视网膜血管分割中存在末端微小血管缺失、病理伪影干扰及血管前景与非血管背景对比度低等问题, 提出自适应特征融合级联 Transformer 视网膜血管分割算法。首先 AEA 模块可以将不同通道特征信息充分利用, 提高分割结果准确率且降低计算冗余; 其次 GFF 模块将编解码语义信息融合, 提升特征复用率, 增强血管光滑度; 最后 CGT 模块在编解码底层充分聚合上下文血管语义信息, 使主血管与微小血管能够平滑连接。本文在分割对比度较低病理图像时仍出现血管轻微断裂问题, 未来如何精确分割病灶处血管仍是视网膜血管分割需要进一步解决的问题。

参考文献

- [1] 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.
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.
- [2] Liang L M, Yang Y, He A J, et al. Cross-stage deformable transformer encoding and decoding algorithm for retinal image segmentation[J]. *Radio Eng*, 2023, **53**(9): 1990–2001.
梁礼明, 阳渊, 何安军, 等. 跨级可变形Transformer编解码视网膜图像分割算法[J]. *无线电工程*, 2023, **53**(9): 1990–2001.
- [3] Liang L M, Dong X, Li R J, et al. Classification algorithm of retinopathy based on attention mechanism and multi feature fusion[J]. *Opto-Electron Eng*, 2023, **50**(1): 220199.
梁礼明, 董信, 李仁杰, 等. 基于注意力机制多特征融合的视网膜病变分级算法[J]. *光电工程*, 2023, **50**(1): 220199.
- [4] Lv J, Wang Z Y, Liang H C. Boundary attention assisted dynamic graph convolution for retinal vascular segmentation [J]. *Opto-Electron Eng*, 2023, **50**(1): 220116.
吕佳, 王泽宇, 梁浩城. 边界注意力辅助的动态图卷积视网膜血管分割[J]. *光电工程*, 2023, **50**(1): 220116.
- [5] Vlachos M, Dermatas E. Multi-scale retinal vessel segmentation using line tracking[J]. *Comput Med Imaging Graph*, 2010, **34**(3): 213–227.
- [6] Azzopardi G, Strisciuglio N, Vento M, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images[J]. *Med Image Analy*, 2015, **19**(1): 46–57.
- [7] Wang X H, Zhao Y Q, Liao M, et al. Automatic segmentation for retinal vessel based on multi-scale 2D Gabor wavelet[J]. *Acta Autom Sin*, 2015, **41**(5): 970–980.
王晓红, 赵于前, 廖苗, 等. 基于多尺度2D Gabor小波的视网膜血管自动分割[J]. *自动化学报*, 2015, **41**(5): 970–980.
- [8] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//*Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 2015: 3431–3440. <https://doi.org/10.1109/CVPR.2015.7298965>.
- [9] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//*Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention*, Munich, 2015: 234–241. https://doi.org/10.1007/978-3-319-24574-4_28.
- [10] Bakas S, Reyes M, Jakab A, et al. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge[Z]. arXiv: 1811.02629, 2018. <https://doi.org/10.48550/arXiv.1811.02629>.
- [11] Heller N, Sathianathan N, Kalapara A, et al. The kits19 challenge data: 300 kidney tumor cases with clinical context, ct semantic segmentations, and surgical outcomes[Z]. arXiv: 1904.00445, 2019. <https://doi.org/10.48550/arXiv.1904.00445>.
- [12] Li Y, Zhang Y, Cui W G, et al. Dual encoder-based dynamic-channel graph convolutional network with edge enhancement for retinal vessel segmentation[J]. *IEEE Trans Med Imag*, 2022, **41**(8): 1975–1989.
- [13] Wang X, Li Z S, Huang Y P, et al. Multimodal medical image segmentation using multi-scale context-aware network[J]. *Neurocomputing*, 2022, **486**: 135–146.
- [14] Yang B, Qin L, Peng H, et al. SDDC-Net: A U-shaped deep spiking neural P convolutional network for retinal vessel

- segmentation[J]. *Digital Signal Process*, 2023, **136**: 104002.
- [15] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*, Long Beach, 2017: 6000–6010. <https://dl.acm.org/doi/10.5555/3295222.3295349>.
- [16] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[C]//*Proceedings of the 9th International Conference on Learning Representations*, 2021.
- [17] Liu X Y, Peng H W, Zheng N X, et al. EfficientViT: memory efficient vision transformer with cascaded group attention[C]//*Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Vancouver, 2023: 14420–14430. <https://doi.org/10.1109/CVPR52729.2023.01386>.
- [18] Azad R, Jia Y W, Aghdam E K, et al. Enhancing medical image segmentation with TransCeption: a multi-scale feature fusion approach[Z]. arXiv: 2301.10847, 2023. <https://doi.org/10.48550/arXiv.2301.10847>.
- [19] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//*Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018: 7132–7141. <https://doi.org/10.1109/CVPR.2018.00745>.
- [20] Ni J J, Sun H Z, Xu J X, et al. A feature aggregation and feature fusion network for retinal vessel segmentation[J]. *Biomed Signal Process Control*, 2023, **85**: 104829.
- [21] Zhang R F, Liu S S, Yu Y Z, et al. Self-supervised correction learning for semi-supervised biomedical image segmentation[C]//*Proceedings of the 24th International Conference on Medical Image Computing and Computer-Assisted Intervention*, Strasbourg, 2021: 134–144. https://doi.org/10.1007/978-3-030-87196-3_13.
- [22] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-Net: Learning where to look for the pancreas[Z]. arXiv: 1804.03999, 2018. <https://doi.org/10.48550/arXiv.1804.03999>.
- [23] Wang C, Zhao Z Y, Ren Q Q, et al. Dense U-net based on patch-based learning for retinal vessel segmentation[J]. *Entropy*, 2019, **21**(2): 168.
- [24] Liu W T, Yang H H, Tian T, et al. Full-resolution network and dual-threshold iteration for retinal vessel and coronary angiograph segmentation[J]. *IEEE J Biomed Health Inform*, 2022, **26**(9): 4623–4634.
- [25] Zhang H B, Zhong X, Li Z J, et al. TiM-Net: transformer in M-Net for retinal vessel segmentation[J]. *J Healthcare Eng*, 2022, **2022**: 9016401.
- [26] Tchinda B S, Tchiotso D, Noubom M, et al. Retinal blood vessels segmentation using classical edge detection filters and the neural network[J]. *Inf Med Unlocked*, 2021, **23**: 100521.
- [27] Du X F, Wang J S, Sun W Z. UNet retinal blood vessel segmentation algorithm based on improved pyramid pooling method and attention mechanism[J]. *Phys Med Biol*, 2021, **66**(17): 175013.
- [28] Khan T M, Khan M A U, Rehman N U, et al. Width-wise vessel bifurcation for improved retinal vessel segmentation[J]. *Biomed Signal Process Control*, 2022, **71**: 103169.
- [29] Guo S. CSGNet: Cascade semantic guided net for retinal vessel segmentation[J]. *Biomed Signal Process Control*, 2022, **78**: 103930.
- [30] Li X, Jiang Y C, Li M L, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. *IEEE Trans Ind Inf*, 2021, **17**(3): 1958–1967.
- [31] Yang X, Li Z Q, Guo Y Q, et al. DCU-net: A deformable convolutional neural network based on cascade U-net for retinal vessel segmentation[J]. *Multimedia Tools Appl*, 2022, **81**(11): 15593–15607.
- [32] Khan T M, Naqvi S S, Robles-Kelly A, et al. Retinal vessel segmentation via a Multi-resolution Contextual Network and adversarial learning[J]. *Neural Netw*, 2023, **165**: 310–320.

作者简介



梁礼明(1967-), 男, 硕士, 教授, 硕士生导师, 主要研究方向为机器学习、医学影像和系统建模等。公开发表学术论文百余篇, 其中被 SCI、EI、ISTP 收录论文二十余篇。获得中国发明专利六项(排名第一)、出版研究生教材一部。

E-mail: lianglm67@163.com



【通信作者】卢宝贺(2000-), 男, 硕士研究生, 目前就读于江西理工大学, 主要研究方向为医学图像处理。

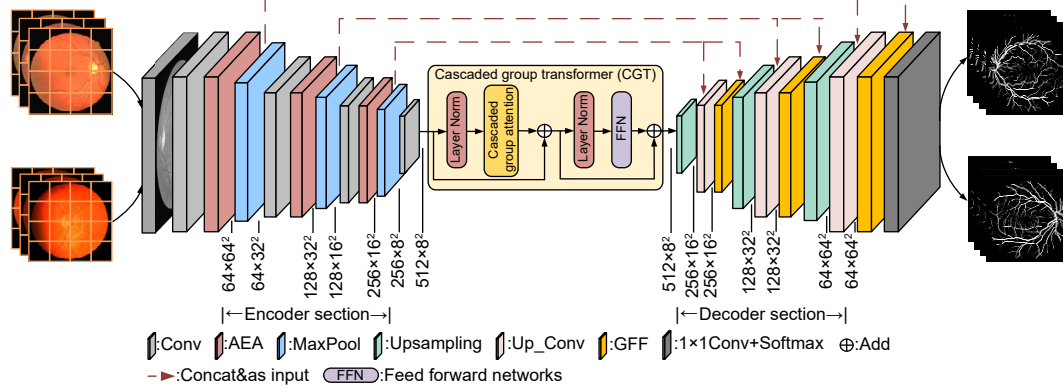
E-mail: 939175848@qq.com



扫描二维码, 获取PDF全文

Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm

Liang Liming, Lu Baohe*, Long Pengwei, Yang Yuan



Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm

Overview: Retinal blood vessel images contain rich geometric structures, such as vessel diameter, branching angle, and length, which allow ophthalmologists to prevent and diagnose diseases such as hypertension, diabetes, and atherosclerosis by observing information about retinal blood vessel structure. However, the topology of the fundus blood vessels is intricate and difficult to extract medically, so it is important to study a retinal vessel segmentation algorithm that can be efficient and automatic for clinicopathologic diagnosis. The contemporary retinal vessel segmentation methods are mainly categorized into traditional machine- and deep-learning-based methods. Traditional machine learning methods include morphology-based processing, matched filter-based, and wavelet transform, etc. Such methods usually do not require a priori labeling information, but rather utilize the similarity between the data for analysis. The deep learning method is an end-to-end learning method, that can automatically extract the bottom and high-level feature information of the image, compared with the traditional segmentation methods to avoid the process of manual feature extraction, and at the same time reduce the subjectivity of segmentation, and its generalization ability is significantly better than that of the traditional methods. However, the fundus retinal segmentation task still suffers from pathologic artifact interference, incomplete segmentation of tiny vessels, and low contrast between the vascular foreground and the nonvascular background. To solve the above problems, an adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm is proposed. The original image of the retina dataset was first subjected to dataset expansion to ensure adequate training and prediction of the model, and operations such as gamma correction were performed to perform dataset image enhancement and to improve the contrast of the blood vessel texture. Secondly, the adaptive enhancement attention module is designed in the encoding part to improve the information interaction ability between different channels, and at the same time, the background noise information of the image is eliminated to reduce the interference of pathological artifacts and enhance the nonlinear ability of the vascular image. Then the cascade group Transformer module is added at the bottom end of the codec to effectively aggregate the contextual vascular feature information and fully capture the local features of tiny blood vessels. Finally, a gated feature fusion module is introduced in the decoding part to capture the spatial feature information of different sizes in the codec layer, which improves the feature utilization and algorithm robustness. Validated on the public datasets DRIVE, CHASE_DB1, and STARE, the accuracy reaches 97.09%, 97.60%, and 97.57%, the sensitivity reaches 80.38%, 81.05%, and 80.32%, and the specificity reaches 98.69%, 98.71%, and 98.99%. The experimental results show that the overall performance of the algorithm in this paper is better than most of the existing state-of-the-art algorithms, and it has a certain application value for the diagnosis of clinical ophthalmic diseases.

Liang L M, Lu B H, Long P W, et al. Adaptive feature fusion cascade Transformer retinal vessel segmentation algorithm[J]. *Opto-Electron Eng*, 2023, 50(10): 230161; DOI: [10.12086/oe.2023.230161](https://doi.org/10.12086/oe.2023.230161)

Foundation item: Project supported by National Natural Science Foundation of China (51365017, 6146301), and Natural Science Foundation of Jiangxi Province (20192BAB205084)

School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000, China

* E-mail: 939175848@qq.com