

DOI:10.13382/j.jemi.B2508299

多层次语义融合与特征耦合 Transformer 的 视网膜血管分割*

梁礼明 王成斌 康婷 钟奕

(江西理工大学电气工程与自动化学院 赣州 341000)

摘要:针对视网膜血管分割中存在微细血管提取困难、成像对比度低及病灶信息干扰等问题,提出一种多层次语义融合与特征耦合 Transformer 的视网膜血管分割算法。首先,采用列非均匀校正模块构建双联合特征提取端,有效保留血管纹理信息,增强模型提取微细血管的能力;然后,在编解码连接处引入特征耦合 Transformer 模块,增强血管特征的表达,使算法能更准确辨别血管语义特征;最后,在编码端加入多层次语义融合模块,有效抑制背景噪声干扰,着重关注血管区域特征。在公共数据集 DRIVE、STARE 和 CHASE_DB1 上进行实验,其灵敏度分别为 80.30%、80.84% 和 82.43%,准确率分别为 97.11%、97.61% 和 97.63%,F1 值分别为 82.96%、83.76% 和 81.48%。实验结果表明,该方法在血管分割精度、微细血管结构完整性保持以及复杂病灶区域处理方面均表现优异,整体性能优于现有大部分先进算法,并在泛化能力和鲁棒性方面展现出良好潜力,为视网膜血管疾病的智能辅助诊断提供更为可靠的技术支持。

关键词: 视网膜血管分割;列非均匀校正模块;特征耦合 Transformer;多层次语义融合

中图分类号: TP391.41;TN06 **文献标识码:** A **国家标准学科分类代码:** 510.40

Multi-level semantic fusion and feature-coupled Transformer for retinal vessel segmentation

Liang Liming Wang Chengbin Kang Ting Zhong Yi

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

Abstract: A retinal vessel segmentation algorithm based on multi-level semantic fusion and feature-coupled Transformer was proposed to address challenges such as the difficulty in extracting fine vessels, low imaging contrast, and interference from lesion information in retinal images. First, a column non-uniformity correction module was used to construct a dual-branch joint feature extraction module, which effectively preserved vessel texture information and enhanced the model's ability to extract fine vessels. Then, a feature-coupled Transformer module was introduced at the encoder-decoder connection to enhance the representation of vessel features, enabling more accurate recognition of vascular semantic information. Finally, a multi-level semantic fusion module was added to the encoder to suppress background noise interference and focus on vessel-related features. Experiments were conducted on public datasets DRIVE, STARE, and CHASE_DB1. The sensitivity achieved was 80.30%, 80.84% and 82.43%, respectively, the accuracy reached 97.11%, 97.61% and 97.63%, respectively, and the F1-scores were 82.96%, 83.76% and 81.48%, respectively. The experimental results indicate that the proposed method achieves superior segmentation accuracy, preserves the integrity of fine vascular structures, and effectively handles complex lesion regions; overall performance surpasses that of most existing advanced methods and exhibits strong generalization and robustness, thereby providing more reliable technical support for intelligent auxiliary diagnosis of retinal vascular diseases.

Keywords: retinal vessel segmentation; column non-uniformity correction module; feature-coupled Transformer; multi-level semantic fusion

收稿日期: 2025-04-09 Received Date: 2025-04-09

* 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资助项目(20192BAB205084)、江西省教育厅科学技术研究青年项目(GJJ2200848)资助

0 引言

眼底图像中包含大量动脉血管,其形态特征的变化可作为许多疾病诊断的重要依据。医学研究表明,视网膜血管的异常与高血压、冠心病和糖尿病等心血管疾病密切相关,但视网膜血管拓扑结构复杂多变,血管和背景之间对比度低,且存在病灶信息干扰等问题,导致血管分割精度不理想。因此,亟待开发一种自动高效的视网膜血管分割算法^[1-2]。

目前,视网膜血管分割方法可分为无监督学习方法和有监督学习方法两大类。无监督学习方法通过图像特征之间的内在关联以识别目标血管,包括匹配滤波法^[3]、血管追踪法^[4]、数学形态学^[5]和 K-means 聚类^[6]等方法,此类方法虽然结构简单,但难以准确分割视网膜中血管末端和低对比度区域血管。相较于无监督学习方法,有监督学习方法具有更好的分割性能,该方法主要依靠图像的真实标签来训练图像的分类模型,包括贝叶斯方法^[7]、k 最近邻^[8]和支持向量机^[9]等方法。近年来,基于有监督学习的深度学习方法因其先进的图像特征捕获能力和更强的数据处理能力,在图像处理领域广受学者青睐^[10]。如 Ronneberger 等^[11]提出 U-Net 分割网络,其通过跳跃连接巧妙融合低分辨率和高分辨率特征,以捕获更多血管语义信息,在视网膜血管分割任务中表现出卓越的性能。多尺度卷积神经网络-注意力机制(MSCNN-AM)^[12]利用注意力机制,使模型能更多关注视网膜血管像素,而非背景像素。Li 等^[13]设计多任务对称网络,采用全局分割和细节增强网络,以提高视网膜血管图像分割的准确性。Wang 等^[14]构建多尺度上下文融合网络,从多个尺度捕获空间语义信息,并自动为不同的通道上下文信息分配不同的权重。BW-Net^[15]采用菱形结构融合的方式进行语义特征聚合,并引入嵌套的密集跳跃连接,从而改善模型的图像分割性能。宋伟伟等^[16]提出一种空间频域融合的视网膜血管分割方法,通过联合提取局部与全局特征,有效提升血管分割精度并保持小血管的连贯性。上述基于改进 U-Net 的视网膜血管分割方法虽取得了较为理想的分割效果,但仍存在血管信息易丢失及噪声像素抑制不足问题。

在自然语言处理领域中,Transformer^[17]模型首次被提出并取得较好的效果。随后 Dosovitskiy 等^[18]将 Transformer 引入图像识别任务,将图像转换为一系列图像块进行识别。Lyu 等^[19]设计选择性密集连接 Swin Transformer 模块,以实现选择性密集连接和多级特征的有效融合。Zhang 等^[20]将 Transformer 模块引入跳跃连接中,其内置自注意力机制建模眼底图像长程关系,有效缓解边缘血管信息丢失问题。Wu 等^[21]设计跨尺度级联分

层 Transformer 网络,促进多尺度特征之间的相互利用,有助于提取更多局部血管信息。CTAUNet (collaborative transformer attention U-Net)^[22]并行采用卷积神经网络与 Transformer 作为编码器,利用协同注意力实现多尺度特征融合,从而将局部细节与全局语义有机整合。Wen 等^[23]提出一种结构感知 Transformer 注意力融合网络,将基于窗口的自注意力与通道注意力并行结合,以捕捉全局空间依赖并强调重要特征通道。上述算法虽有效提升血管分割性能,但仍存在如下局限性:1) 编码端连续卷积和池化操作在一定程度上会导致血管细节信息丢失;2) 基于 Transformer 的方法通常将自注意力操作限制在固定的空间范围内或仅在通道维度内进行,以有效利用内存,这会阻碍 Transformer 全局信息建模能力,降低对细节特征的捕捉能力,且 U-Net 编解码连接层未能充分整合全局上下文信息;3) 解码部分中原始上采样操作易使血管边缘分割较模糊,且难以有效抑制病理噪声干扰。

针对以上问题,本文提出一种多层级语义融合与特征耦合 Transformer 的视网膜血管分割算法(multi-level semantic fusion and feature-coupled Transformer for retinal vessel segmentation, MFCT-Net)。在编码部分构建列非均匀校正双编码结构,捕捉列特征的长程依赖性,以弥补血管语义信息损失;设计一种特征耦合 Transformer,并将其引入 U 型网络连接处,在全局低频语义与局部高频细节间建立交互机制,增强模型的全局上下文建模能力,使算法能更好捕获微细血管信息;在解码端加入多层级语义融合模块,着重突出病灶区域血管信息,有效抑制伪影噪声干扰。

1 本文算法

1.1 算法设计

眼底视网膜图像血管形态结构高度复杂,血管分支末端与背景的对比较低,为确保算法能提取更多血管语义信息及提高血管分割准确性,本文构造 MFCT-Net 模型,其结构如图 1 所示。首先在编码部分构建列非均匀校正双编码结构,通过捕获列之间的长程依赖关系以弥补下采样造成的特征丢失问题。然后在跳跃连接处引入特征耦合 Transformer,增强全局和局部特征聚合,提升算法辨别血管和非血管区域的能力。最后在编码部分加入多层级语义融合模块,有效抑制噪声干扰,改善病灶区域血管分割效果。

1.2 列非均匀校正模块(CNCM)

为了有效建立血管像素长程依赖关系,更好捕获血管纹理细节信息,本文引入 CNCM^[24],其建立灵活的远程依赖关系,聚合上下文信息以微调不同特征层之间的

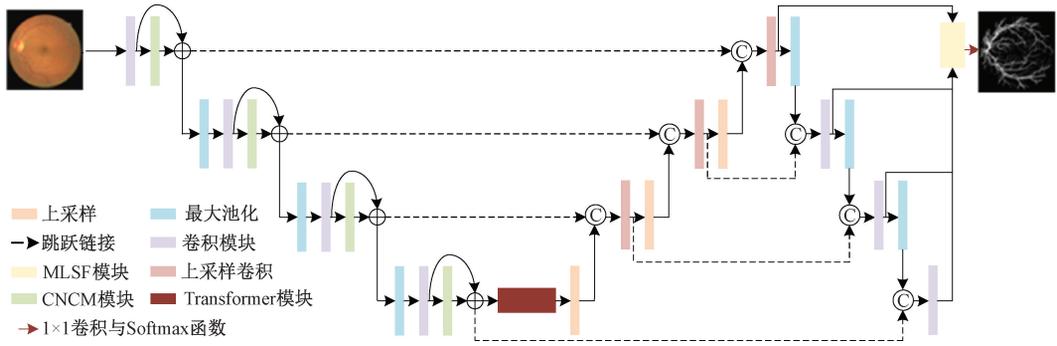


图 1 多层次语义融合与特征耦合 Transformer 的视网膜血管分割算法

Fig. 1 Multi-level semantic fusion and feature-coupled Transformer for retinal vessel segmentation

全局一致性。CNCM 嵌套残差列空间自校正模块(residual column spatial self-correction, RCSSC), 其中 RCSSC 是一种将残差连接整合到列空间自校正模

块(column spatial self-correction, CSSC)的结构, CSSC 由空间注意力分支、列注意力分支及自校准分支构成, 如图 2 所示。

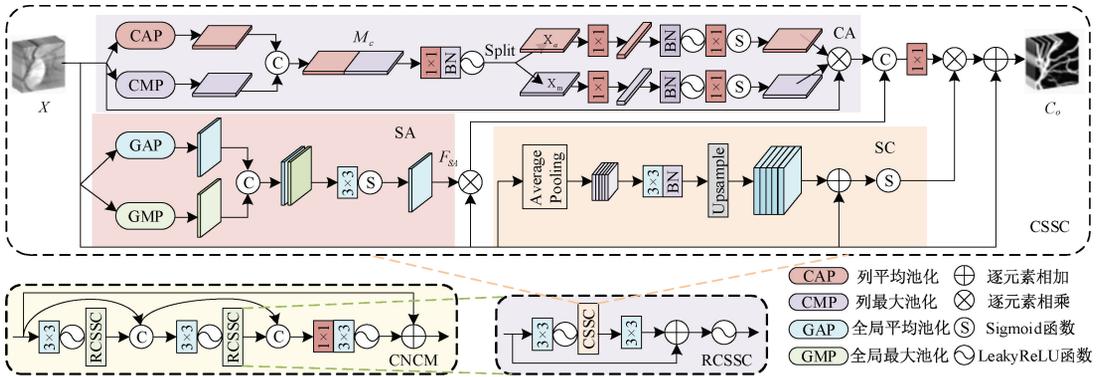


图 2 列非均匀校正模块

Fig. 2 Column non-uniformity correction module

在空间注意力分支部分, 首先将输入特征 $X \in R^{C \times H \times W}$ 沿通道维度进行全局平均池化和全局最大池化操作以捕获不同的语义响应。然后将这些响应拼接以获得空间权重。之后将输入特征 X 与空间权重相乘得到输出特征 F_{SA} 。其过程可表述为:

$$F_{SA} = f_{3 \times 3}^s([f_{spatial}^{Avg}(X), f_{spatial}^{Max}(X)]) \otimes X \quad (1)$$

式中: $f_{3 \times 3}^s$ 表示 3×3 卷积层和 Sigmoid 激活函数运算; $f_{spatial}^{Avg}$ 和 $f_{spatial}^{Max}$ 分别表示平均池化和最大池化; $[\cdot]$ 表示特征融合连接。

在列注意力分支部分, 首先利用列平均池化和列最大池化对输入特征 $X \in R^{C \times H \times W}$ 进行处理, 由于不同池化响应对应于相同列, 将池化处理结果沿通道维度连接, 以捕获共享特征 M_c 。然后为实现信息交互, 将融合特征 M_c 拆分为两个相等的分支 X_a 和 X_m , 之后, 利用注意力模型对特征 X_a 和 X_m 进行处理得到输出特征 F_{CA} , 其数学表达式如下:

$$M_c = [f_{column}^{Avg}(X), f_{column}^{Max}(X)] \quad (2)$$

$$X_a, X_m = \text{Split}(C\beta \tau(M_c)) \quad (3)$$

$$F_{CA} = F_{column}(X_a) \otimes F_{column}(X_m) \otimes X \quad (4)$$

式中: f_{column}^{Avg} 和 f_{column}^{Max} 分别表示列平均池化和列最大池化; Split 表示沿通道维度分割; $C\beta \tau$ 表示 1×1 卷积层、批量归一化和 Sigmoid 激活函数运算; F_{column} 表示通道注意力模型中 1×1 卷积层、批量归一化、LeakyReLU 激活函数和 Sigmoid 激活函数运算。

在自校准分支部分, 首先将输入特征 $X \in R^{C \times H \times W}$ 传输到由平均池化、 3×3 卷积层、批量归一化及上采样构成的单元得到输出特征 F_{SC}^1 。然后将特征 F_{SC}^1 与输入特征 X 相加并应用 Sigmoid 激活函数处理得到输出特征 F_{SC} , 该过程表述如下:

$$F_{SC}^1 = \text{Upsample}(\text{BN}(f_{3 \times 3}(f^{Avg}(X)))) \quad (5)$$

$$F_{SC} = \delta(X \oplus F_{SC}^1) \quad (6)$$

式中: f^{Avg} 表示平均池化; $f_{3 \times 3}$ 表示 3×3 卷积层, BN 表示批量归一化; Upsample 表示上采样操作; δ 表示 Sigmoid 激活函数。

最后,给定输入特征 $\mathbf{X} \in R^{C \times H \times W}$, CSSC 模块总过程可被定义如下:

$$C_o = \text{Conv}([\mathbf{F}_{SA}, \mathbf{F}_{CA}]) \otimes \mathbf{F}_{SC} \oplus \mathbf{X} \quad (7)$$

1.3 特征耦合 Transformer

在视网膜血管分割任务中,传统 Transformer 仅依赖全局注意力,难以充分提取微细血管信息。此外,不同通道对血管与背景的区别作用各异,需有针对性地调整各通道权重。为此,本文设计特征耦合 Transformer (feature-coupled Transformer, FCT),通过特征交互注意力机制建模血管形态的全局语义关联,结合极性感知注意力增强模型对低对比度血管区域的表征能力,同时引入通道注意力模块强化血管特征信息。旨在有效平衡全局与局部信息的提取,使模型在保持对整体血管结构的理解的同时,能更好捕获微细血管语义特征,其结构如图 3 所示。

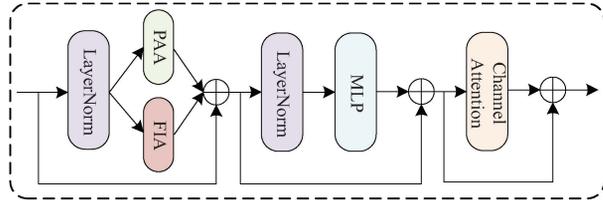


图 3 特征耦合 Transformer

Fig. 3 Feature-coupled Transformer

1) 特征交互注意力模块

传统 Transformer 的自注意力虽能捕捉全局信息,但对局部细节信息关注不足。而基于卷积的架构虽能较好捕捉局部特征,但受限感受野,难以建立长程语义关联。因此,本文提出特征交互注意力模块 (feature interaction attention, FIA),通过结合 1×1 卷积和多尺寸卷积核,在利用自注意力捕捉长距离依赖的同时,采用局部卷积操作提取细粒度血管信息,提高模型对细节血管区域的分割效果,其结构如图 4 所示。

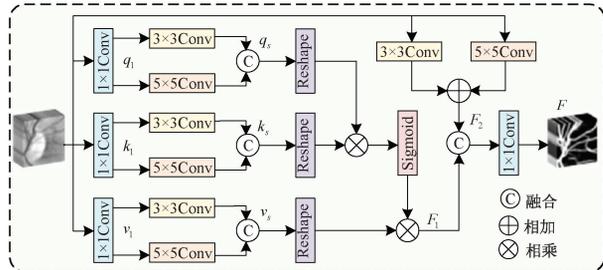


图 4 特征交互注意力模块

Fig. 4 Feature interaction attention module

首先给定输入特征 $\mathbf{x} \in R^d$,分别通过 3 个 1×1 卷积层生成用于查询、键和值的基础特征 $\mathbf{q}_1, \mathbf{k}_1$ 和 \mathbf{v}_1 。然后对每个基础特征分别采用 3×3 和 5×5 分组卷积以提取

局部卷积特征,并将结果在通道上拼接,得到查询、键和值的卷积特征 $\mathbf{q}_s, \mathbf{k}_s$ 和 \mathbf{v}_s 。之后对 \mathbf{q}_s 和 \mathbf{k}_s 进行归一化处理,并将结果对 \mathbf{v}_s 进行加权求和,得到全局注意力输出 \mathbf{F}_1 。其过程可分别表述为:

$$\mathbf{q}_1 = f_{1 \times 1}(\mathbf{x}), \mathbf{k}_1 = f_{1 \times 1}(\mathbf{x}), \mathbf{v}_1 = f_{1 \times 1}(\mathbf{x}) \quad (8)$$

$$\mathbf{q}_s = [f_{3 \times 3}(\mathbf{q}_1); f_{5 \times 5}(\mathbf{q}_1)] \quad (9)$$

$$\mathbf{k}_s = [f_{3 \times 3}(\mathbf{k}_1); f_{5 \times 5}(\mathbf{k}_1)] \quad (10)$$

$$\mathbf{v}_s = [f_{3 \times 3}(\mathbf{v}_1); f_{5 \times 5}(\mathbf{v}_1)] \quad (11)$$

$$\mathbf{F}_1 = \delta(\mathbf{q}_s \otimes \mathbf{k}_s) \otimes \mathbf{v}_s \quad (12)$$

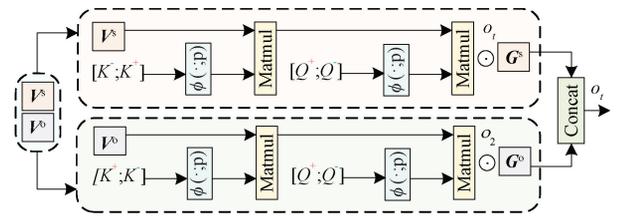
式中: $\int_{k \times k}$ 表示核为 $k \times k$ 的卷积操作; $[\cdot; \cdot]$ 表示拼接操作; δ 表示 Sigmoid 激活函数; \otimes 表示相乘。为了进一步补充局部细节信息,将输入特征 $\mathbf{x} \in R^d$ 分别通过 3×3 和 5×5 分组卷积处理,并通过拼接操作得到 \mathbf{F}_2 。最后将全局注意力输出 \mathbf{F}_1 与特征 \mathbf{F}_2 融合,得到输出特征 \mathbf{F} 。其数学表达式分别为:

$$\mathbf{F}_2 = [f_{3 \times 3}(\mathbf{x}); f_{5 \times 5}(\mathbf{x})] \quad (13)$$

$$\mathbf{F} = f_{1 \times 1}([\mathbf{F}_1; \mathbf{F}_2]) \quad (14)$$

2) 极性感知注意力

传统注意力机制在计算查询与键之间的内积时,通常更关注对比度较强的正值特征信息,而易忽略微细血管区域等负值信息,导致注意力分布过于平滑,难以有效辨别血管与背景。针对这一问题,本文引入极性感知注意力模块^[25] (polarity-aware attention, PAA),通过同时保留正负信息,使模型对血管区域的响应更加敏感,从而提高算法的血管分割精度,其结构如图 5 所示。



⊙ 逐元素相乘 X^+ 正极部分 X^- 负极部分 X^+ 同符号响应 X^- 异符号响应

图 5 极性感知注意力模块

Fig. 5 Polarity-aware attention module

首先给定查询向量 $\mathbf{q} \in R^d$ 和键向量 $\mathbf{k} \in R^d$,将二者分解为正、负两部分 $[\mathbf{q}^+, \mathbf{q}^-]$ 与 $[\mathbf{k}^+, \mathbf{k}^-]$ 。然后将值向量 \mathbf{v} 沿通道维度拆分为两部分 \mathbf{V}_1^+ 和 \mathbf{V}_1^- ,分别对应处理相同和相反符号的响应,从而得到两组输出特征 \mathbf{o}_1 和 \mathbf{o}_2 。最后通过可学习极性系数矩阵 \mathbf{G}^+ 和 \mathbf{G}^- 对两组特征 \mathbf{o}_1 和 \mathbf{o}_2 进行缩放,并将结果拼接融合得到注意力权重 \mathbf{o}_i ,其表达式如下:

$$\mathbf{q}^+ = \max(\mathbf{q}, 0), \mathbf{q}^- = \max(-\mathbf{q}, 0) \quad (15)$$

$$\mathbf{k}^+ = \max(\mathbf{k}, 0), \mathbf{k}^- = \max(-\mathbf{k}, 0) \quad (16)$$

$$\mathbf{o}_1 = \frac{\phi([\mathbf{q}_i^+; \mathbf{q}_i^-]) \sum_{i=1}^N \phi([\mathbf{k}_i^+; \mathbf{k}_i^-])^T \mathbf{V}_i^s}{\phi([\mathbf{q}_i^+; \mathbf{q}_i^-]) \sum_{j=1}^N \phi([\mathbf{k}_j^+; \mathbf{k}_j^-])^T} \quad (17)$$

$$\mathbf{o}_2 = \frac{\phi([\mathbf{q}_i^+; \mathbf{q}_i^-]) \sum_{i=1}^N \phi([\mathbf{k}_i^-; \mathbf{k}_i^+])^T \mathbf{V}_i^o}{\phi([\mathbf{q}_i^+; \mathbf{q}_i^-]) \sum_{j=1}^N \phi([\mathbf{k}_j^-; \mathbf{k}_j^+])^T} \quad (18)$$

$$\mathbf{o}_i = [\mathbf{o}_1 \odot \mathbf{G}^s; \mathbf{o}_2 \odot \mathbf{G}^o] \quad (19)$$

式中: $\phi(\cdot)$ 表示经过非线性映射的特征表示; $[\cdot; \cdot]$ 表示通道维度拼接; \odot 表示逐元素相乘。

1.4 多层次语义融合模块

为了更好地捕获目标对象的多尺度特征,有效结合细粒度和粗粒度信息,本文设计多层次语义融合模块(multi-level semantic fusion module, MLSF),如图6所示。MLSF由特征融合、通道注意力和空间注意力组成,旨在增强模型对血管区域特征的关注能力,提升血管分割性能。

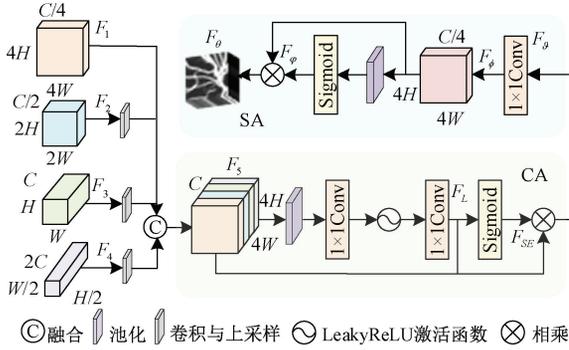


图6 多层次语义融合模块

Fig. 6 Multi-level semantic fusion module

在特征融合部分,首先将输入端的多尺度特征 F_2 、 F_3 和 F_4 分别经邻近上采样和卷积操作以实现空间分辨率对齐,并将上述结果与特征图 F_1 沿通道维度拼接,得到输出特征 F_5 。然后将特征 F_5 经过由池化层、卷积层和非线性运算构成的通道注意力单元,得到输出特征 F_L 。再利用 Sigmoid 激活函数对特征 F_L 进行处理得到输出特征 F_{SE} 。最后将特征 F_5 、 F_L 及 F_{SE} 相乘得到输出特征 F_θ ,其数学表达式分别为:

$$F_5 = \text{Concat}(F_1, \overset{\sqrt{\cdot}}{F_2}, \overset{\sqrt[4]{\cdot}}{F_3}, \overset{\sqrt[8]{\cdot}}{F_4}) \quad (20)$$

$$F_L = \delta(f_{1 \times 1}(\text{LR}(f_{1 \times 1}(\text{Pool}(F_5)))))) \quad (21)$$

$$F_\theta = F_5 \otimes F_L \otimes F_{SE} \quad (22)$$

式中: $\overset{\sqrt{\cdot}}{\cdot}$ 表示邻近上采样和卷积操作; Concat 表示拼接操作; δ 表示 Sigmoid 激活函数; $f_{1 \times 1}$ 表示 1×1 卷积层; Pool 表示池化操作; LR 表示 LeakyReLU 激活函数。

在空间注意力部分,首先对特征 F_θ 进行 1×1 卷积操作,得到输出特征 F_ϕ 。然后将特征 F_ϕ 经过由池化层和 Sigmoid 激活函数构成的空间注意力单元,得到输出特征

F_ϕ 。最后将特征 F_ϕ 与特征 F_θ 相乘得到输出特征 F_θ ,该过程表述如下:

$$F_\phi = f_{1 \times 1}(F_\theta) \quad (23)$$

$$F_\phi = \delta(\text{Pool}(F_\phi)) \quad (24)$$

$$F_\theta = F_\phi \otimes F_\theta \quad (25)$$

2 实验过程及参数设定

2.1 实验环境以及参数设置

MFCT-Net 算法基于 Pytorch 框架实现,利用 Python 语言在 Pycharm 平台完成实验的训练与测试,实验环境基于 64 位 Windows 11 操作系统,硬件配置包括 13th Gen Intel (R) Core (TM) i7-13650HX 2.60 GHz CPU, 16.0 GB 内存及 NVIDIA GeForce RTX 4060 Laptop GPU 显卡。在实验过程中,采用交叉熵损失函数和 Adam 优化器,初始学习率为 0.0005,并应用余弦退火法对其进行衰减,通道数依次设置为 32、64、128、256,批量大小为 6,迭代次数为 20,训练过程采取早停机制,若连续 5 个训练轮次为最佳权重,则停止训练。

2.2 预处理

眼底视网膜图像对比度较低,且在血管分割过程中易受病变区域及背景噪声干扰,因此,在训练之前需对原始图像进行一系列预处理操作,如图7所示。首先对图像进行灰度转化,使模型更加专注于图像的结构特征及亮度变化。然后对灰度图像进行限制对比度自适应直方图均衡化(contrast limited adaptive histogram equalization, CLAHE),使图像的灰度分布更均匀,增强图像的对对比度。最后对均衡化的图像进行伽马校正,以调整图像的亮度并有效减弱噪声干扰。

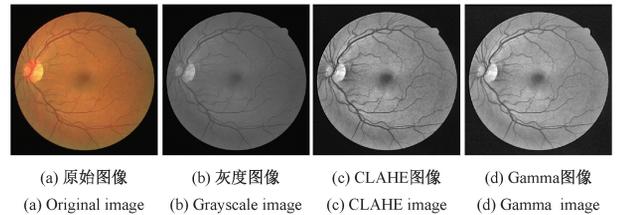


图7 图像预处理流程

Fig. 7 Image preprocessing flow chart

2.3 数据集

实验采用了3个公共数据集 DRIVE^[26]、STARE^[27]和 CHASE_DB1^[28],这些数据集为视网膜血管分割任务提供了丰富的数据支持。DRIVE 数据集包含 40 幅彩色视网膜图像和专家标注的金标准图像,其中,7 幅图像显示存在糖尿病变,33 幅图像为正常视网膜图像,每幅图像的分辨率为 565 pixel \times 584 pixel,官方将其前 20 幅图像用

作训练集,后 20 幅图像用作测试集;STARE 数据集包含 20 幅分辨率为 700 pixel×605 pixel 的彩色视网膜图像,由于 STARE 数据集未区分训练和测试集,故采用五折交叉验证方法进行实验;CHASE_DB1 数据集包含 28 幅分辨率为 999 pixel×960 pixel 的彩色视网膜图像,由 14 名儿童双眼的眼底图像构成,每幅图像的血管结构由两位不同的专家标注,将前 20 幅图像划分为训练集,后 8 幅图像作为测试集。

2.4 评价指标

为了评估 MFCT-Net 模型性能,采用准确率(accuracy, ACC)、灵敏度(sensitivity, SE)特异性(specificity, SP)、F1 分数(F1-score, F1)以及 ROC 曲线与坐标轴围成的面积(area under curve, AUC)作为评估指标,各项指标公式为:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \tag{26}$$

$$SE = \frac{TP}{TP + FN} \tag{27}$$

$$SP = \frac{TN}{TN + FP} \tag{28}$$

$$F1 = \frac{2TP}{2TP + FP + FN} \tag{29}$$

式中:TP 和 TN 分别为真阳性和真阴性;FP 和 FN 分别为假阳性和假阴性。

3 实验结果分析

3.1 不同分割算法对比

为了验证 MFCT-Net 在血管分割任务中的可行性,在 DRIVE、STARE 和 CHASE_DB1 数据集中,将 MFCT-Net 与 U-Net^[11]、Attention U-Net^[29]、FR U-Net^[30] 和 GT-DLA-dsHFF^[31] 4 种不同算法在相同的实验环境下进行对比实验。其中 U-Net 为所提算法的基准模型,Attention U-Net 为在 U-Net 基础上引入注意力机制的变体模型,FR U-Net 为视网膜血管分割任务中的经典模型,GT-DLA-dsHFF 为在 U-Net 基础上引入 Transformer 的变体模型,不同算法的分割可视化结果如图 8 所示。图 8(a)为不同算法在 DRIVE 数据集上的实验结果。图 8(b)为不同算法在 STARE 数据集上的实验结果;图 8(c)为不同算法在 CHASE_DB1 数据集上的实验结果,图像中绿色像

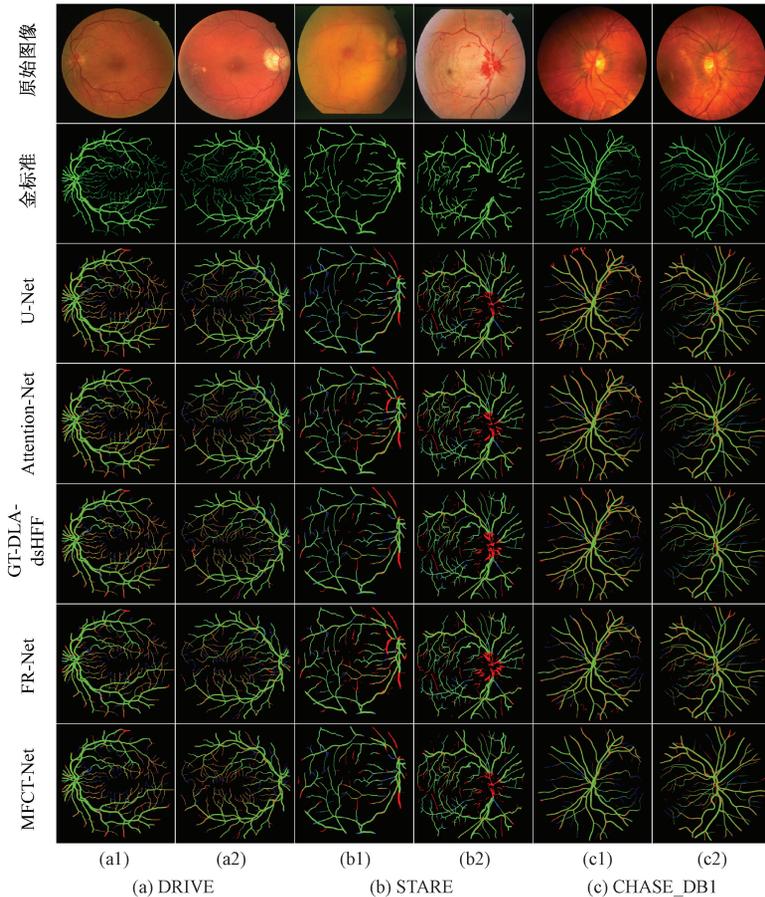


图 8 不同算法视网膜血管分割结果

Fig. 8 Results of retinal blood vessel segmentation by different algorithms

素表示真阳性,红色像素表示假阳性,蓝色像素表示假阴性。

观察图 8 可知,在 DRIVE 数据集中,U-Net、Attention U-Net 和 GT-DLA-dsHFF 受噪声干扰严重,MFCT-Net 和 FR U-Net 能较好抑制伪影干扰,但 MFCT-Net 较 FR U-Net 输出实验结果图中绿色像素更多,表明 MFCT-Net 分割性能更好;在 STARE 数据集中,与其他模型相比,MFCT-Net 输出实验结果图中病变区域的红色像素更少,表明 MFCT-Net 能有效抑制病灶信息干扰,降低误分割率;在 CHASE_DB1 数据集中,相较于其他算法,MFCT-Net 输出实验结果图中交叉连接和微细血管区域的蓝色像素更少,表明 MFCT-Net 能捕获更多血管交汇处和低对比度区域微细血管特征。综上所述,MFCT-Net 在血管交织处及病灶影响严重区域具有较好的分割性能,优于其他算法。

3.2 局部细节图对比

为了进一步突出 MFCT-Net 算法的先进性,图 9 所示

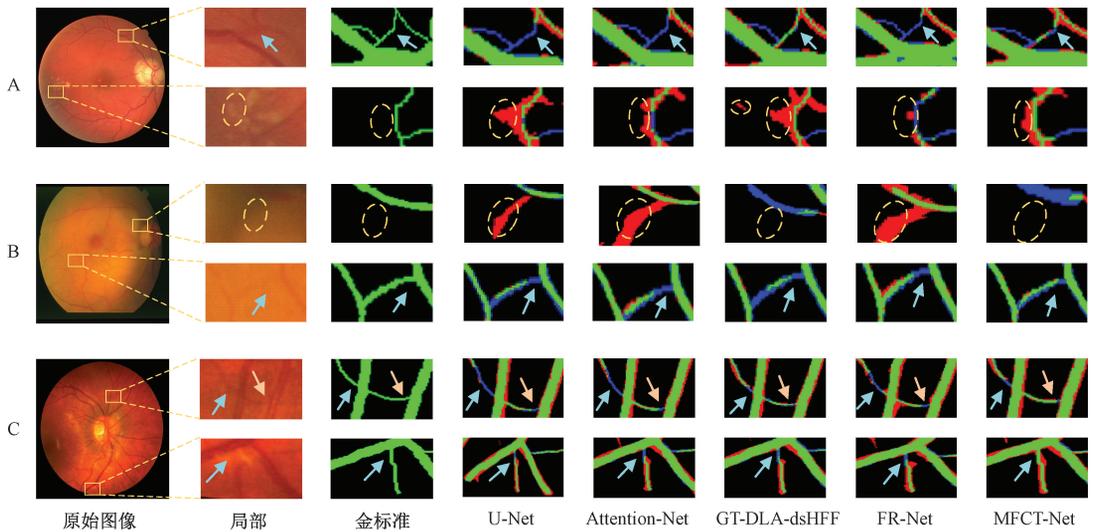


图 9 不同算法视网膜血管局部分割图像

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

管分割任务中的性能差异,表 1 为不同算法在 DRIVE、STARE 和 CHASE_DB1 数据集中,以相同实验条件进行对比实验的性能指标,其中加粗项表示最优值。同时,为了更加直观展示 MFCT-Net 算法的血管分割性能,不同算法在数据集 DRIVE 和 CHASE_DB1 上 ROC 曲线和 PR 曲线的对比如图 10、11 所示。AUC-PR 和 AUC-ROC 分别表示 PR 曲线和 ROC 曲线与坐标轴所围成的面积,AUC 值越接近于 1,表示模型血管分割性能越好,由图 10 和 11 可知,MFCT-Net 中 AUC-PR 和 AUC-ROC 值均优于其他算法,说明 MFCT-Net 能更准确提取微细血管语义信息,具有较强的可靠性。

为不同算法血管分割结果的局部细节放大图,图 9A~C 分别为图 8(a2)、(b1)和(c2)原始图像的局部细节放大图。由图 9A 可知,在 DRIVE 数据集中,除 MFCT-Net 和 GT-DLA-dsHFF 外,其余算法均出现血管未分割现象,但 MFCT-Net 较 GT-DLA-dsHFF 能更好抑制病灶信息干扰,降低误分割率;观察图 9B 可得,在 STARE 数据集中,U-Net、Attention U-Net 及 FR U-Net 未能有效抑制噪声干扰,对非血管像素辨别不明,且除 MFCT-Net 外,其余算法均出现血管分割断裂现象,说明 MFCT-Net 血管分割精确率较高;由图 9C 可以看出,在 CHASE_DB1 数据集中,其余算法在眼底分支血管分割过程中,均出现血管纹理丢失现象,唯 MFCT-Net 血管分割结果较为完整。实验结果表明,MFCT-Net 能提取更多的细节血管信息并抑制病灶信息干扰,表明 MFCT-Net 在视网膜血管分割任务中具有较强稳健性。

3.3 性能指标

为了进一步体现 MFCT-Net 与其他算法在视网膜血

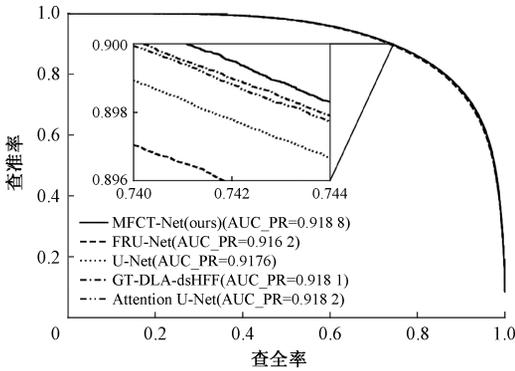
由表 1 可知,在 DRIVE 数据集中,MFCT-Net 除 SP 未取得最优值,其余指标均高于其他算法,且 SE 较 U-Net、Attention U-Net 和 GT-DLA-dsHFF 分别提高 1.73%、0.88%和 0.15%,表明 MFCT-Net 对微细血管具有较强的捕获能力,能分割出更多血管;在 STARE 数据集中,MFCT-Net 除 SP 指标未取得最优值,其余指标均达到最优值,且 SE 和 F1 指标分别达到 80.84%和 83.76%,表明 MFCT-Net 分割性能更稳健;在 CHASE_DB1 数据集中,Attention U-Net 和 GT-DLA-dsHFF 的 SP 指标略高于本文算法,MFCT-Net 其余指标均为最优值,表明 MFCT-Net 分割效果理想。

表 1 不同算法在 3 个数据分割结果性能指标对比

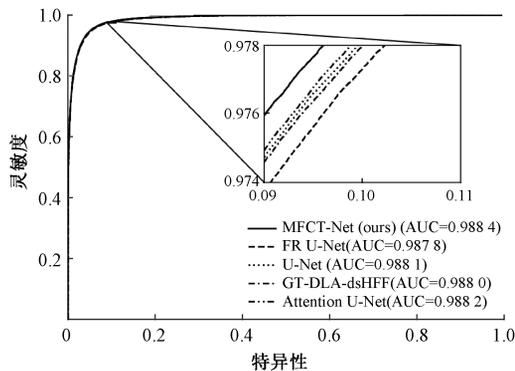
Table 1 Compared with performance indicators of different algorithms in three datasets

(%)

数据集	方法	ACC	SE	SP	AUC	F1
DRIVE	U-Net	97.08	78.57	98.86	98.81	82.53
	Attention U-Net	97.10	79.42	98.80	98.82	82.78
	FR U-Net	97.06	80.10	98.69	98.78	82.69
	GT-DLA-dsHFF	97.10	80.15	98.73	98.80	82.91
	本文	97.11	80.30	98.72	98.84	82.96
STARE	U-Net	97.52	79.26	99.02	99.01	82.98
	Attention U-Net	97.55	78.88	99.01	99.05	83.08
	FR U-Net	97.49	80.36	98.90	99.03	83.01
	GT-DLA-dsHFF	97.56	79.98	99.01	99.09	83.37
	本文	97.61	80.84	98.98	99.12	83.76
CHASE_DB1	U-Net	97.46	80.90	98.57	98.86	80.09
	Attention U-Net	97.60	80.65	98.74	98.97	80.96
	FR U-Net	97.41	81.19	98.50	98.75	79.83
	GT-DLA-dsHFF	97.61	80.72	98.74	99.00	80.97
	本文	97.63	82.43	98.66	99.03	81.48

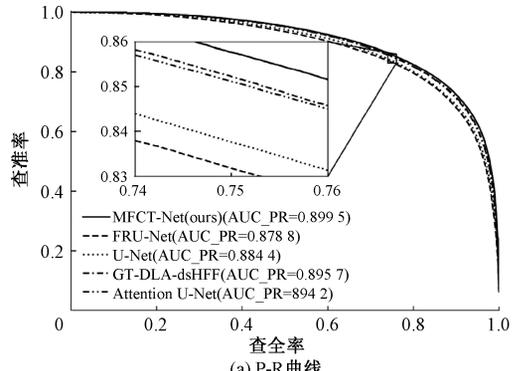


(a) P-R 曲线
(a) P-R curve

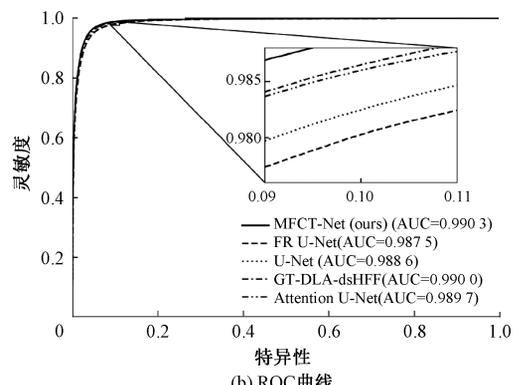


(b) ROC 曲线
(b) ROC curve

图 10 DRIVE 数据集上 ROC 曲线与 P-R 曲线对比
Fig. 10 Comparison of ROC curve and P-R curve on DRIVE dataset



(a) P-R 曲线
(a) P-R curve



(b) ROC 曲线
(b) ROC curve

图 11 CHASE_DB1 数据集上 ROC 曲线与 P-R 曲线对比
Fig. 11 Comparison of ROC curve and P-R curve on CHASE_DB1 dataset

3.4 与近年先进算法对比

为了进一步验证 MFCT-Net 算法的分割性能,将 MFCT-Net 与近年先进不同算法在 DRIVE、STARE 和

CHASE_DB1 数据集上进行对比,其对比指标如表 2~4 所示,其中加粗项为最优值。

由表 2~4 可知,文献 [32] 在其编码端嵌入 Transformer 模块以提取全局拓扑信息,同时利用局部二

表 2 DRIVE 数据集对比结果

Table 2 Comparison results of DRIVE dataset (%)

方法	ACC	SE	SP	AUC	F1
文献[32]	96.50	81.40	98.09	89.75	81.01
文献[33]	96.92	82.21	98.78	98.56	82.71
文献[34]	96.78	81.00	98.79	98.28	81.49
文献[35]	97.04	86.03	98.08	97.06	82.89
文献[36]	96.08	86.90	97.37	98.39	—
文献[37]	96.86	81.92	98.29	—	82.02
文献[38]	96.83	83.63	98.11	97.93	82.11
本文	97.11	80.30	98.72	98.84	82.96

表 3 STARE 数据集对比结果

Table 3 Comparison results of STARE dataset (%)

方法	ACC	SE	SP	AUC	F1
文献[32]	96.81	80.04	98.52	89.28	81.98
文献[33]	97.18	80.04	98.82	98.08	78.75
文献[34]	95.72	73.60	99.47	96.86	78.65
文献[35]	96.69	82.68	97.89	98.45	79.65
文献[36]	97.10	85.02	98.36	98.99	—
文献[37]	97.30	81.70	98.53	—	81.78
文献[38]	97.32	82.72	98.47	98.55	81.96
本文	97.61	80.84	98.98	99.12	83.76

表 4 CHASE_DB1 数据集对比结果

Table 4 Comparison results of CHASE_DB1 dataset (%)

方法	ACC	SE	SP	AUC	F1
文献[32]	97.08	83.54	98.06	90.80	78.96
文献[33]	97.43	83.56	98.56	98.67	80.50
文献[34]	97.14	83.66	98.29	98.18	77.41
文献[35]	97.27	86.27	98.08	98.94	80.47
文献[36]	97.53	84.11	98.43	98.98	—
文献[37]	97.26	82.10	98.38	—	80.48
文献[38]	97.14	85.41	97.94	98.06	79.00
本文	97.63	82.43	98.66	99.03	81.48

值能量函数模块来捕获局部细节信息,使其模型能有效专注和捕获血管语义特征,因而文献[32]在数据集 DRIVE 和 CHASE_DB1 中 SE 指标高于 MFCT-Net,但 MFCT-Net 其余指标在 3 个数据集中均高于文献[32],说明 MFCT-Net 能更准确地对血管进行分割。文献[34]构造基于空洞卷积和多核池化的多模块连接网络,使模型能保留更多详细血管特征并能更好辨别血管前景和非血管背景,文献[34]在 DRIVE 和 CHASE_DB1 数据集中 SP 指标达到最优值,在 DRIVE 和 CHASE_DB1 数据集中 SE 指标高于 MFCT-Net,但文献[34]其余指标均低于 MFCT-Net,说明 MFCT-Net 血管分割整体性能较好。文献[35]将脉冲神经 P 系统与 U-Net 网络相结合,设计具有扩张卷积的双通道编码器,增强了模型对细节血管的感知敏

感性,文献[35]在 3 个数据集中 SE 指标均高于 MFCT-Net,且在 CHASE_DB1 数据集中 SE 指标达到最优值,但 MFCT-Net 其余指标均高于文献[35],说明 MFCT-Net 分割性能更稳健。文献[36]通过结合特征复用与分配模块和注意力特征融合模块,使模型能更好捕获多尺度特征信息,从而文献[36]在 3 个数据集中 SE 指标均高于 MFCT-Net,且在 DRIVE 和 STARE 数据集中 SE 指标达到最优值,但 MFCT-Net 其余指标均高于文献[36],说明 MFCT-Net 在视网膜血管分割中具有较强的可靠性。综合 MFCT-Net 与其他先进算法在 3 个公共数据集上的比较,MFCT-Net 具有较高的 ACC、AUC 和 F1 值,表明 MFCT-Net 具有较强的鲁棒性和泛化性。

3.5 消融实验及模型参数

为了验证 MFCT-Net 算法中提出的列非均匀校正模块、特征耦合 Transformer 模块以及多层次语义融合模块的有效性,在 DRIVE、STARE 和 CHASE_DB1 数据集上进行消融实验,如表 5~7 所示,W1 表示 U-Net 网络;W2 表示在 W1 解码端加入 MLSF 模块;W3 表示在 W2 编码部分引入 CNCM 模块构建双编码结构;W4 表示在 W3 编解码连接处加入 FCT 模块。

表 5 DRIVE 数据集消融实验分析

Table 5 Analysis of ablation experiments on the DRIVE dataset (%)

方法	ACC	SE	SP	AUC	F1
W1	97.08	78.57	98.86	98.80	82.53
W2	97.10	80.09	98.73	98.80	82.89
W3	97.10	80.18	98.72	98.82	82.90
W4	97.11	80.30	98.72	98.84	82.96

表 6 SATRE 数据集消融实验分析

Table 6 Analysis of ablation experiments on the SATRE dataset (%)

方法	ACC	SE	SP	AUC	F1
W1	97.52	79.26	99.02	99.01	82.98
W2	97.58	80.32	99.01	99.11	83.54
W3	97.60	80.35	99.02	99.11	83.62
W4	97.61	80.84	98.98	99.12	83.76

表 7 CHASE_DB1 数据集消融实验分析

Table 7 Analysis of ablation experiments on the CHASE_DB1 dataset (%)

方法	ACC	SE	SP	AUC	F1
W1	97.46	80.90	98.57	98.85	80.09
W2	97.60	81.44	98.68	98.98	81.05
W3	97.63	81.77	98.69	99.02	81.32
W4	97.63	82.43	98.66	99.03	81.48

分析表 5~7 可知,在 3 个数据集中,W1 中 SE 和 F1

指标较低,表明 U-Net 存在血管信息捕获不足及血管误分割率较高的问题;W2 较 W1 的 ACC 指标在 3 个数据集集中均有所上升,表明 MLSF 模块能有效抑制噪声干扰,更精准地实现血管分割;W3 中 SP 指标在 STARE 和 CHASE_DB1 达到最优值,且 SE 和 F1 指标较 W2 均有所上升,表明 CNCM 模块对微细血管具有较强的捕获能力并能更好保留血管细节信息;W4 中 ACC、SE、AUC 及 F1 指标均为各项最优值,表明 FCT 模块有助于增强血管提取能力,改善低对比度血管分割效果。

为了评估模型的复杂度,将本文算法同文献[11,29-31]的参数大小及其在 DRIVE 数据集上运行时间进行对比,如表 8、9 所示。本文在计算复杂度方面取得最优值,其参数量略高于 FR U-Net 以及训练测试时间略高于 U-Net 和 Attention U-Net,但本文算法相较于 U-Net、FR U-Net 和 Attention U-Net 血管整体分割效果较好,表明 MFCT-Net 推理效率较高,计算成本较低,血管分割性能更可靠。

表 8 参数量及浮点运算量对比

Table 8 Comparison of parameter count and floating point operation count

方法	参数量/($\times 10^6$)	计算量/GFLOP
U-Net	34.52	4.09
Attention U-Net	34.87	4.16
FR U-Net	5.72	3.68
GT-DLA-dsHFF	26.09	7.40
本文	6.27	3.16

表 9 训练及测试时间对比

Table 9 Comparison of training and testing time

方法	训练时间/s	测试时间/s
U-Net	70	90
Attention U-Net	80	95
FR U-Net	120	200
GT-DLA-dsHFF	262	3120
本文	106	184

4 结 论

为了提高视网膜血管分割性能,本文提出了一种多层次语义融合与特征耦合 Transformer 的视网膜血管分割算法。利用列非均匀校正模块构建双编码结构,模型能更全面理解和利用全局上下文信息和局部细节信息,有效保留血管纹理信息。通过设计特征耦合 Transformer,算法能更加专注于血管区域特征,减少对非血管信息的关注,从而提高血管分割精度。通过加入多层次语义融合解码,模型能更好捕获多尺度特征信息,突出病灶区域血管特征,有效去除噪声干扰。

实验结果表明,MFCT-Net 展现了较好的分割性能,优于许多现有先进算法,但 MFCT-Net 对低对比度图像进行分割时仍会出现血管分割断裂或血管未分割现象,原因在于利用列非均匀校正模块构建双边特征提取编解码端并不能完全缓解血管特征丢失问题,未来将进一步优化列非均匀校正模块,提高其对微细血管信息的提取和保留能力,同时结合特征耦合 Transformer 和多层级语义融合模块,增强算法区分血管和非血管区域的能力。

参考文献

- [1] 夏平,何志豪,雷帮军,等. 密集级联卷积与自注意力特征聚合的视网膜血管分割模型[J]. 电子测量与仪器学报, 2024, 38(9):36-44.
- XIA P, HE ZH H, LEI B J, et al. Retinal vascular segmentation algorithm based on full scale dense convolutional u-shaped networks [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(9):36-44.
- [2] 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.
- LIANG L M, ZHAN T, LEI K, et al. Multi-level adaptive scale U-shaped retinal blood vessel segmentation algorithm [J]. Electronic Measurement Technology, 2022, 45(13):130-140.
- [3] OLIVEIRA W S, TEIXEIRA J V, REN T I, et al. Unsupervised retinal vessel segmentation using combined filters[J]. PLoS One, 2016, 11(2):e0149943.
- [4] ZHAO J L, YANG J, AI D N, et al. Automatic retinal vessel segmentation using multi-scale superpixel chain tracking [J]. Digital Signal Processing, 2018, 81:26-42.
- [5] HASSAN G, EL-BENDARY N, HASSANIEN A E, et al. Retinal blood vessel segmentation approach based on mathematical morphology [J]. Procedia Computer Science, 2015, 65:612-622.
- [6] ALI A, WAN ZAKI W M D, HUSSAIN A. Blood vessel segmentation from color retinal images using K-means clustering and 2D Gabor wavelet [C]. International Conference on Applied Physics, System Science and Computers. Cham: Springer International Publishing, 2017:221-227.
- [7] USLU F, BHARATH A A. A recursive Bayesian approach to describe retinal vasculature geometry [J]. Pattern Recognition, 2019, 87:157-169.
- [8] RIZKY L M R, SUYANTO S. Adversarial training and deep k-nearest neighbors improves adversarial defense of glaucoma severity detection[J]. Heliyon, 2022, 8(12):

- e12275.
- [9] RELAN D, MACGILLIVRAY T, BALLERINI L, et al. Automatic retinal vessel classification using a least square-support vector machine in VAMPIRE [C]. 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2014: 142-145.
- [10] 姚迎乐, 赵娟. 基于深度学习的红外过采样扫描图像小目标跟踪算法 [J]. 国外电子测量技术, 2023, 42(1):35-40.
- YAO Y L, ZHAO J. Small object tracking algorithm for infrared oversampled scanning images based on deep learning [J]. Foreign Electronic Measurement Technology, 2023, 42(1):35-40.
- [11] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional Networks for Biomedical Image Segmentation [M]. International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer International Publishing, 2015:234-241.
- [12] FU Q L, LI S Q, WANG X. MSCNN-AM: A multi-scale convolutional neural network with attention mechanisms for retinal vessel segmentation [J]. IEEE Access, 2020, 8:163926-163936.
- [13] LI J Y, GAO G, YANG L, et al. GDF-Net: A multi-task symmetrical network for retinal vessel segmentation [J]. Biomedical Signal Processing and Control, 2023, 81:104426.
- [14] WANG X, LI Z S, HUANG Y P, et al. Multimodal medical image segmentation using multi-scale context-aware network [J]. Neurocomputing, 2022, 486: 135-142.
- [15] 黎强, 陈惠贤. BW-Net: 用于视网膜血管图像分割的 W-Net 扩展框架 [J]. 电子测量技术, 2023, 46(21): 23-29.
- LI Q, CHEN H X. BW-Net: A W-Net extension framework for retinal vascular image segmentation [J]. Electronic Measurement Technology, 2023, 46(21): 23-29.
- [16] 宋伟伟, 许茗, 于晓升, 等. 空间频域融合的视网膜血管分割方法 [J]. 仪器仪表学报, 2025, 46(5):195-204.
- SONG W W, XU M, YU X SH, et al. Retinal vessel segmentation method based on fusion of frequency domain and spatial domain [J]. Chinese Journal of Scientific Instrument, 2025, 46(5):195-204.
- [17] VASWANI A, SHAZEER N, PARAMAR N, et al. Attention is all you need [J]. ArXiv preprint arXiv: 1706.03762, 2017.
- [18] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: Transformers for image recognition at scale [J]. ArXiv preprint arXiv. 2010.11929, 2020.
- [19] LYU N, XU L, CHEN Y L, et al. TCDDU-Net: Combining transformer and convolutional dual-path decoding U-Net for retinal vessel segmentation [J]. Scientific Reports, 2024, 14:25978.
- [20] ZHANG H B, ZHONG X, LI Z J, et al. TiM-net: Transformer in M-net for retinal vessel segmentation [J]. Journal of Healthcare Engineering, 2022, 2022(1):9016401.
- [21] WU C W, GUO M, MA M, et al. TLNet: A novel transscale cascade layered transformer network for enhanced retinal blood vessel segmentation [J]. Computers in Biology and Medicine, 2024, 178:108773.
- [22] PUNN N S, KUMAR S. CTAUNet: Improved retinal blood vessel segmentation with collaborative transformer attention U-Net [J]. Neural Computing and Applications, 2025, 37:15705-15718.
- [23] WEN Y, LUO B, SHI W Z, et al. SAT-Net: Structure-Aware transformer-based attention fusion network for low-quality retinal fundus images enhancement [J]. IEEE Transactions on Multimedia, 2025, 14(8):1-14.
- [24] YUAN S, QIN H L, YAN X, et al. ASCNet: Asymmetric sampling correction network for infrared image destriping [J]. ArXiv preprint arXiv. 2401.15578, 2024.
- [25] MENG W K, LUO Y D, JIANG D M, et al. PolaFormer: Polarity-aware linear attention for vision Transformers [J]. ArXiv preprint arXiv. 2501.15061, 2025.
- [26] 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.
- [27] HOOVER A D, KOUZNETSOVA V, GOLDBAUM M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response [J]. IEEE Transactions on Medical Imaging, 2000, 19(3): 203-210.
- [28] OWEN C G, RUDNICKA A R, MULLEN R, et al. Measuring retinal vessel tortuosity in 10-year-old children: Validation of the computer-assisted image analysis of the retina (CAIAR) program [J]. Investigative Ophthalmology & Visual Science, 2009, 50(5): 2004-2010.
- [29] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-net: Learning where to look for the panc-reas [J]. ArXiv preprint arXiv. 1804.03999, 2018.

- [30] 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 Journal of Biomedical and Health Informatics, 2022, 26 (9): 4623-4634.
- [31] LI Y, ZHANG Y, LIU J Y, et al. Global transformer and dual local attention network via deep-shallow hierarchical feature fusion for retinal vessel segmentation [J]. IEEE Transactions on Cybernetics, 2023:5826-5839.
- [32] ZHANG H Y, NI W H, LUO Y, et al. TUNet-LBF: Retinal fundus image fine segmentation model based on transformer Unet network and LBF [J]. Computers in Biology and Medicine, 2023, 159:106937.
- [33] KONG L F, WU Y. RVS-FDSC: A retinal vessel segmentation method with four-directional strip convolution to enhance feature extraction [J]. Biomedical Signal Processing and Control, 2024, 95:106296.
- [34] ZHANG T, LI J, ZHAO Y, et al. MC-UNet: Multi-module concatenation based on U-shape network for retinal blood vessels segmentation [J]. ArXiv preprint arXiv. 2204.03213, 2022.
- [35] 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 Processing, 2023, 136:104002.
- [36] NI J J, SUN H Z, XU J X, et al. A feature aggregation and feature fusion network for retinal vessel segmentation [J]. Biomedical Signal Processing and Control, 2023, 85:104829.
- [37] IQBAL S, NAQVI S S, KHAN H A, et al. G-Net light: A lightweight modified google net for retinal vessel segmentation [J]. Photonics, 2022, 9(12):923.
- [38] DENG X Y, YE J H. A retinal blood vessel segmentation based on improved D-MNet and pulse-coupled neural network [J]. Biomedical Signal Processing and Control, 2022, 73:103467.

作者简介



梁礼明, 1989 年于南方冶金学院获得学士学位, 2005 年于江西理工大学获得硕士学位, 现为江西理工大学教授, 主要研究方向为机器学习、医学影像和系统建模等。

E-mail: 9119890012@jxust.edu.cn

Liang Liming received his B. Sc. degree from Southern Institute of Metallurgy in 1989, and M. Sc. degree from Jiangxi University of Science and Technology in 2005. He is currently a professor at Jiangxi University of Science and Technology. His main research interests include machine learning, medical imaging, and system modeling.



王成斌 (通信作者), 2023 年于三明学院获得学士学位, 现为江西理工大学硕士研究生, 主要研究方向为机器学习、模式识别与图像处理等。

E-mail: 2411425428@qq.com

Wang Chengbin (Corresponding author) received his B. Sc. degree from Sanming University in 2023. He is now a M. Sc. candidate at Jiangxi University of Science and Technology. His main research interests include machine learning, pattern recognition, and image processing.