

文章编号 1004-924X(2026)17-2763-13

超广角 OCT 图像眼底脉络膜层 METransUNet 分割网络模型

赖平红^{1,2}, 江志豪¹, 祝 琴^{1,3*}, 曾明如¹, 韩沈阳¹

(1. 南昌大学 信息工程学院, 江西 南昌 330036;

2. 江西省人民医院, 江西 南昌 330038;

3. 南昌大学 经济管理学院, 江西 南昌 330036)

摘要: 现有眼底脉络膜层分割模型是以传统 OCT 图像为训练对象, 应用于超广角 OCT 图像分割时易产生伪影及边缘振荡, 同时存在边缘特征提取与全局建模能力不足等问题。为了提高超广角 OCT 图像的分割精度, 聚焦超广角 OCT 眼底图像, 基于 TransUNet 构建一种多尺度、边缘增强型 METransUNet 脉络膜层分割模型。该模型在跳跃连接中引入边缘增强模块 EEM, 强化超广角 OCT 特征图的边缘和纹理表达, 并于解码器中融合了注意力融合模块 AIM, 充分利用多尺度特征信息。在自建的 D-choroid 数据集下进行实验, 结果表明, 在该数据集下 METransUNet 模型的 ACC 值为 0.993 0, Dice 值为 0.911 4, IOU 值为 0.837 2, 证明该模型可为超广角 OCT 下脉络膜相关眼病智能辅助诊断提供有效技术支撑。最后, 搭建了一套采集、推理、结果输出一体化的超广角 OCT 影像分析系统, 以完成模型工程化架构设计, 可推动模型临床应用。

关键词: 光学相干断层扫描; 图像分割; 超广角; 脉络膜层分割; TransUNet; 边缘增强; 多尺度特征融合

中图分类号: TP391.41 **文献标识码:** A

doi: 10.3724/OPE.20263417.2763

CSTR: 32169.14.OPE.20263417.2763

METransUNet segmentation network model for ultra-widefield OCT images of ocular fundus choroid layer

LAI Pinghong^{1,2}, JIANG Zhihao¹, ZHU Qin^{1,3*}, ZENG Mingru¹, HAN Shenyang¹

(1. School of Information Engineering, Nanchang University, Nanchang 330036, China;

2. Jiangxi Provincial People's Hospital, Nanchang 330038, China;

3. School of Economics and Management, Nanchang University, Nanchang 330036, China)

* Corresponding author, E-mail: zhuqin@ncu.edu.cn

Abstract: Existing fundus choroidal-layer segmentation models are typically trained on conventional optical coherence tomography (OCT) images and are therefore prone to artifacts and boundary oscillations when applied to ultra-widefield OCT images. Inadequate edge-feature extraction and limited global modeling capability further constrain segmentation accuracy in ultra-widefield OCT imaging. To address these limitations, a multi-scale edge-enhanced METransUNet model for choroidal-layer segmentation in ultra-

收稿日期: 2026-05-25; 修订日期: 2026-07-11.

基金项目: 国家自然科学基金资助项目 (No. 72164027); 江西省红十字基金专项资助项目 (No. 2025L3003)

widefield OCT fundus images is developed based on TransUNet. An Edge Enhancement Module (EEM) is incorporated into the skip connections to strengthen edge and texture representations in ultra-widefield OCT feature maps. In addition, an Attention Integration Module (AIM) is embedded in the decoder to facilitate the effective integration of multi-scale features. Experiments conducted on the self-built D-choroid dataset demonstrate that METransUNet achieves an accuracy of 0.993 0, a Dice coefficient of 0.911 4, and an intersection-over-union value of 0.837 2. These results indicate that the proposed model provides effective technical support for intelligent auxiliary diagnosis of choroidal diseases using ultra-widefield OCT. Furthermore, an integrated ultra-widefield OCT image-analysis system encompassing data acquisition, inference, and result output is established, and an engineering architecture is designed to facilitate clinical deployment.

Key words: optical coherent tomography; image segmentation; ultra-widefield; choroidal layer segmentation; TransUNet; edge enhancement; multi-scale feature fusion

1 引 言

超广角光学相干断层扫描技术^[1](Optical Coherence Tomography, OCT)作为一种眼科医学的精密光学成像设备,其成像具有高分辨率、广视野以及深层成像的特点,能够提供结构更完整、边界更清晰的脉络膜 OCT 图像^[2-4]。脉络膜是为视网膜提供营养物质的重要眼底组织^[5],其形态学改变是老年性黄斑变性(Age-related Macular Degeneration, AMD)、视网膜色素变性(Retinitis Pigmentosa, RP)、青光眼等多种眼底疾病临床诊断的关键依据^[6],OCT 是临床诊断其形态学改变的主要影像学手段^[7]。分割模型是当前智能诊断的一项核心技术,但现有眼底图像分割模型聚焦传统 OCT 图像,对超广角 OCT 图像分割易出现伪影传播和边缘拟合震荡,且边缘信息的提取与全局理解能力均不足等问题,制约超广角 OCT 图像分割精度,进而影响智能诊断的准确度。基于此,本文研究超广角 OCT 图像分割网络模型。

脉络膜层分割模型技术原理可以分为两类,分别为传统脉络膜层分割模型和基于深度学习的脉络膜层分割模型。其中,传统脉络膜层分割模型有基于图论的方法^[8-10]、基于边界的分割模型^[11]和基于纹理的分割模型^[12-13]等。这类脉络膜层分割方法高度依赖先验知识储备,需手动调参,存在分割精度不高的问题。基于深度学习的脉络膜层分割模型凭借对眼底 OCT 数据自主学习、自主挖掘脉络膜层纹理与边界特征,无需大

量人工先验介入和具备较高的模型稳定性等优势,正成为脉络膜层分割任务的主流方案。纪庆革等^[14]提出多尺度与双注意力增强的嵌套 U-Net 结构,提高了网络对 OCT 图像层分割的准确率。Cahyo 等^[15]基于 U-Net 提出一种使用序贯方法分割脉络膜体积的方法。He 等^[16]根据脉络膜层光反射后的生物特性将分割问题转化为分类和拟合问题,提出了一种基于卷积神经网络(CNN)分类器和拟合器的脉络膜层自动分割方法,该方法在准确率和稳定性上表现良好。Khaing 等^[17]以 U-Net 为基准模型,通过集成膨胀卷积的方法实现了脉络膜层的分割。Zhu 等^[18]根据脉络膜层与脉络膜血管的相关特征以及之间的联系提出了 CUnet 网络,成功对脉络膜层进行了分割。Yan 等^[19]基于 CE-Net 引入了高效通道注意力模块并设计了自适应形态细化模块,结合脉络膜凸边界正则化损失函数实现了脉络膜层分割的完整与连续性。Wang 等^[20]根据视网膜先验信息分成两阶段对脉络膜层进行分割,该方法通过突出脉络膜层区域特征来实现边界以及病变区域的影像,从而实现脉络膜层的精准分割。Zhu 等^[21]提出融合注意力机制与多尺度特征融合技术,实现了脉络膜层的自动分割与测量,在分割准确率上有显著提升。黄文博等^[22]针对脉络膜与巩膜对比度低且下边界模糊的问题,在 TransUNet 基础上引入全局与局部注意力模块,解决了脉络膜层边界模糊的问题。Lu 等^[23]通过使用位置敏感的交叉注意力机制与优化特征表示进一步提高了脉络膜层分割准确率。Wen

等^[24]提出了先进行脉络膜层分割的预训练,然后进行脉络膜血管分割的两阶段训练策略,同时引入了多尺度差分连接器以及一个辅助 Trans-former 分支,实现了脉络膜层与脉络膜血管的联合分割。Huang 等^[25]基于 TransUNet 引入了边缘增强模块,使用多分枝结构与空洞卷积提取多尺度特征并结合注意力机制实现边缘特征的增强。

本文基于超广角 OCT 图像提出一种多尺度、边缘增强型 METransUNet 脉络膜层分割模型。通过边缘增强模块(EEM)增强边缘特征信息和全局理解能力;在解码器中嵌入注意力融合模块(AIM)恢复在下采样过程中丢失的高频信息,以提升超广角 OCT 图像脉络膜层的分割效果;构建超广角 OCT 脉络膜数据集 D-choroid 并验证了模型的优越性。

2 原 理

2.1 数据集采集及预处理

本文采用的超广角 OCT 临床影像数据集原

始图像来源于江西省某省级三级甲等医院眼科门诊及住院患者临床采集的检查资料。所有影像均借助如意全眼 OCT 检查设备开展标准化临床检测后收集,包含 75 只眼睛的 115 张超广角 OCT 扫描图像,分辨率可达 $1\,600 \times 750$ 像素,单次扫描范围达到 $26\text{ mm} \times 21\text{ mm}$ 。

选取 750×750 像素作为统一裁剪尺寸,以适配超广角 OCT 有效病灶区域、网络感受野与特征提取稳定性的需求。在实验阶段,将 115 张超广角 OCT 图像进行数据增强,扩充数据集图像数量至 690 张并合理划分为含有 483 张图像的训练集、含有 138 张图像的验证集以及含有 69 张图像的测试集。

本实验采用三阶段的数据预处理策略。第一阶段,对图像进行随机位置裁剪,裁剪出大小 750×750 像素的切片;第二阶段,以随机旋转、翻转等方法对增强原始数据,生成与原始数据相同尺寸的增强图像,即上文所提扩充数据集技术;第三阶段,对每张切片进行 CLAHE 直方图均衡化,增加边界对比度,整个预处理流程如图 1 所示。




图 1 预处理流程

Fig. 1 Preprocessing flow chart

2.2 模型结构

本文基于 TransUnet 网络,结合边缘增强和注意力融合等思想,首先,对输入的原始超广角 OCT 图像进行预处理,以适配模型输入要求;再将预处理后的数据输入编码器,进行特征提取;编码后的特征通过融合 EEM 的跳跃连接,可实现多尺度特征的利用,保留丰富边缘信息;随后,特征依靠嵌入 AIM 模块的解码器,完成特征上

采样;最后,获得理想的超广角 OCT 分割效果,分割流程如图 2 所示。

METransUnet 模型输入尺寸为 $750 \times 750 \times 3$ 的超广角 OCT 图像,通过 CNN 三个不同阶段提取出三个不同大小的图像特征,一方面,这三个特征分别和相应的解码器阶段进行特征融合;另一方面,CNN 网络 Stage1 和 Stage3 分别与边缘增强模块进行连接以实现低阶特征图与高阶

特征图的聚合。最后,解码器输出端与边缘增强模块输出端经过特征注意力融合模块进行特征

融合并输出, METransUnet 网络结构如图 3 所示。




图2 METransUnet脉络膜层分割流程

Fig. 2 Flow chart of choroidal layer segmentation based on METransUnet




图3 METransUnet分割模型网络结构

Fig. 3 Network structure of METransUnet segmentation model

2.3.1 边缘增强模块

在脉络膜层分割任务中,浅层特征包括丰富的边缘细节和非边缘细节,需要利用深层特征信息来促进对边缘特征的探索^[26],关联浅层特征与深层特征信息可以促进模型对边缘特征信息提取。现有的自适应池化^[27](Adaptive Pooling, Adapool)网络可有效捕捉边缘信息,但对空间位置上的长距离依赖的获取能力有限,缺乏对图像特征的全局理解;基于自注意力机制在空间位置上的长距离依赖能力,本文新建以自注意力机制网络模块为基础的边缘增强模块(Edge Enhance-

ment Module, EEM)的结构如图4所示。

EEM 主要包含两个部分:AdaPool 部分和混合注意力部分。其中,浅层特征的提取主要依靠 AdaPool 自适应指数池化操作。AdaPool 是一种动态融合平滑近似平均池化和平滑最大近似池化的混合池化方法,通过可学习的权重参数,自适应调整两种池化操作的贡献比例,从而在保留边缘细节与抑制噪声之间取得平衡。其公式为:

$$\tilde{a}_{ada} = \tilde{a}_{eDSC} \cdot \beta + \tilde{a}_{eM} \cdot (1 - \beta), \quad (1)$$




图 4 边缘增强模块 EEM 结构

Fig. 4 Structure of edge enhancement module (EEM)

其中: $\beta \in \{0, \dots, 1\}$ 是权重掩码, $\tilde{a}$ 表示平滑近似平均池化, $\tilde{a}_{\text{eM}}$ 表示平滑最大近似池化。

平均池化在核区域内对所有输入向量使用相等的权重,合并后的输出会受到区域内异常值的影响。而逆距离加权 (Inverse Distance Weighting, IDW) 是广泛应用于多元插值的加权平均方法,可以限制异常值在正向传递中创建池化图像以及反向传递中的梯度计算影响。其公式为:

$$\tilde{a}_{\text{IDW}} = \begin{cases} \frac{\sum_{i \in R} \frac{w(\bar{a}, a_i) \cdot a_i}{\sum_{j \in R} w(\bar{a}, a_j)}}, & \text{if } d(\bar{a}, a_i) \neq 0, \forall i \in R \\ a_i, & \text{if } d(\bar{a}, a_i) = 0, \exists i \in R \end{cases}, \quad (2)$$

其中: R 表示相对位置索引的集合, a_i 表示每个激活到索引 i 的距离, $\bar{a}$ 表示每个激活到 R 的平均距离, w 表示权重,为每个激活与平均激活之间的距离的倒数,即:

$$w_{\text{IDW}}(\bar{a}, a_i) = \frac{1}{d(\bar{a}, a_i)}. \quad (3)$$

距离函数 d 可以由任何几何距离方法计算,然而距离方法在直接应用于输入区域时可能产生伪影,因此使用相似性度量的方法更适合于池化的区域性质。对于广泛使用的余弦相相似度,当两个向量的相似度为 1 时,即使其中一个向量是无限大也会出现问题。但 Dice-Sørensen 系数 (DSC) 通过考虑向量长度来克服这一限制。基于相似性系数的指数介绍,重新构造公式:

$$\tilde{a}_{\text{eDSC}} = \sum_{i \in R} \frac{e^{w(\bar{a}, a_i)}}{\sum_{j \in R} e^{w(\bar{a}, a_j)}}. \quad (4)$$

平滑最大近似池化基于自然指数,它确保

较大的激活将对最终输出产生更大的影响,同时还确保最低激活被分配到最小的权重值。指数最大池化中的权重用于基于相应激活值的非线性变换,具有较高值的激活将比具有较低值的激活更占主导地位。由于大多数池化操作是在高维特征空间上执行的,因此突出具有更大影响的激活比仅选择最大激活更加平衡。在后一种情况下,丢弃大多数激活存在丢失重要信息的风险。平滑最大近似池化的输出通过对核区域 R 内的所有加权激活进行求和来产生,其公式如下:

$$\tilde{a}_{\text{eM}} = \sum_{i \in R} w_{\text{eM}}(a_i) \cdot a_i, \text{ where } w_{\text{eM}}(a_i) = \frac{e^{a_i}}{\sum_{j \in R} e^{a_j}}. \quad (5)$$

混合注意力部分通过引入通道注意力 (Channel Attention, CA) 和空间注意力 (Spatial Attention, SA) 动态调整特征图在通道和空间上的特征图分布,从而更精准地聚焦脉络膜层边缘和纹理信息,增强模型对边缘特征的提取能力。CA 注意力分支通过提取拼接特征图的通道信息实现通道维度上的加权,其结构如图 5 所示。具体计算公式为:

$$M_c(F) = \sigma \left(W_1 \left(W_0 \left(F_{\text{avg}}^c \right) \right) + W_1 \left(M_0 \left(F_{\text{max}}^c \right) \right) \right), \quad (6)$$

其中: $M_c \in \mathbb{R}^{1 \times 1 \times c}$ 表示通道注意力权重矩阵, σ 表示 ReLU 激活函数, $W_0 \in \mathbb{R}^{c/r \times c}$ 表示降维, $W_1 \in \mathbb{R}^{c \times c/r}$ 表示升维, F_{avg}^c 和 F_{max}^c 分别表示全局平均池化和最大池化特征。

SA 注意力分支通过理解拼接特征图像素之间的位置关系,增强特征图的边缘信息,减少背景信息以及噪声的干扰,其结构如图 6 所示。具




图5 CA注意力结构

Fig. 5 Structure of channel attention (CA)

体计算公式为:

$$M_s(F) = \sigma(f^{7 \times 7}[F_{avg}^s; F_{max}^s]), \quad (7)$$

其中: $M_s(F) \in \mathbb{R}^{H \times W}$ 表示空间注意力权重矩阵, $F_{avg}^s \in \mathbb{R}^{1 \times H \times W}$ 表示全局平均池化产生的特征图, $F_{max}^s \in \mathbb{R}^{1 \times H \times W}$ 表示全局最大池化产生的特征图。通道注意力权重矩阵 M_c 和空间注意力权重矩阵 M_s 将在通道维度拼接, 通过 1×1 卷积压缩通道并生成混合权重。




图6 SA注意力结构

Fig. 6 Structure of spatial attention (SA)

2.3.2 注意力融合模块

针对上采样和跳跃连接不足以完全恢复在下采样过程中, 尤其是在处理复杂或精细的边缘时丢失的高频信息的问题。本文构建以交叉注意力模块为核心的注意力融合模块 AIM, 如图7所示, 该模块通过交叉注意力融合增强后的来自跳跃连接以及编码器的特征, 以解决模型仅通过解码器最后一层上采样生成输出, 忽略中间层特征的细节贡献的问题。

AIM 模块主要包含通道增强和交叉注意力两个部分。在通道增强部分的设计中, 通过通道注意力机制增强边缘增强模块和解码器输出的特征通道信息。在边缘增强模块与解码器中, 特征信息已经被大量编码, 空间注意力机制不足以继续对特征继续加权, 而通道注意力能




图7 空间注意力融合模块 AIM

Fig. 7 Spatial attention integration module (AIM)

够调节包含空间信息的通道, 提高网络对位置空间信息的感知, 进而提升脉络膜层边缘分割准确率。

D_i 是来自编码器的第一个输入张量, 记为 $x_1 \in \mathbb{R}^{H \times W \times C}$ 。 E_i 是来自边缘增强模块的第二个张量, 记为 $x_2 \in \mathbb{R}^{H \times W \times C}$ 。这两个输入特征一方面进行拼接操作输出为 x_{cat} ; 另一方面, x_1 与 x_2 首先经过全局平均池化 GAP 操作, 将每个通道的空间信息压缩为一个值, 保留通道的全局统计特征。然后, 经过通道注意力机制动态调整来自边缘增强模块与解码器的特征信息通道权重, 与输入张量与输出张量相加后输出为 x_{c1} 和 x_{c2} 。具体计算为:

$$x_{cat} = \text{Concat}(x_1, x_2), \quad (8)$$

$$CA(x) = x + \text{MLP}(\text{GAP}(x)), \quad (9)$$

$$x_{c1} = x_1 + CA(x_1), \quad (10)$$

$$x_{c2} = x_2 + CA(x_2), \quad (11)$$

其中: Concat 表示拼接操作, CA 表示通道注意力, MLP 表示多层感知机, GAP 表示全局平均池化。

在交叉注意力部分的设计中, 通过两个不同

序列之间的交互,让一个序列从另一个序列中提取相关信息,实现不同序列之间的融合,具体计算过程如图 8 所示。




图 8 交叉注意力计算过程

Fig. 8 Calculation process of cross attention

来自边缘增强模块的序列会生成一组键向量和值向量,来自解码器部分的序列会生成一个查询向量。查询向量和键向量进行点积操作并通过 softmax 函数生成注意力权重,注意力权重与值向量相乘并求和生成编码器调整的输出。计算公式为:

$$\text{CrossAttention}(x_1, x_2) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (12)$$

其中: x_1, x_2 表示两个输入序列, Softmax 表示激活函数, d_k 表示键值集合的维度。

2.3.3 损失函数

针对分割任务的训练需求,采用交叉熵损失函数构建分割损失项 L_{seg} 。该函数以每个像素为计算单元,通过比较其预测类别概率与真实类别标签的差异来衡量模型预测误差,其公式为:

$$L_{\text{seg}}(X) = -\frac{1}{N} \sum_i \sum_{c=1}^C (l^{(i)} \log(y^{(i)})), \quad (13)$$

其中: $l(i)$ 表示输入图像 $x(i) \in X$ 对应的标签, $y(i)$ 表示输入图像 $x(i) \in X$ 对应的预测图, N 表示超广角 OCT 图像训练的总数, C 表示需要分割出的种类数。

3 实验

3.1 实验环境

实验的软件和硬件环境如表 1 所示。

表 1 实验环境配置

Tab. 1 Experimental environment configuration

Environment	Environment configuration
OS	Ubuntu
GPU	NVIDIA GeForce RTX 2080 Ti
GPU Memory	12 GB
Language	Python3.7
Frameworks	PyTorch1.8.0

3.2 评价指标

本实验选用准确率 (Accuracy, ACC)、Dice 系数及交并比 IOU 来定量评估脉络膜层分割模型的性能。其中, ACC 衡量的是整个超广角 OCT 图像所有像素的分类正确率,体现了模型整体性能。Dice 系数度量的是模型预测区域与超广角 OCT 图像脉络膜层真实标签的重叠程度,体现了模型在目标分割区域的分割性能。交并比 IOU 将超广角 OCT 图像每个像素视为二值图像,通过计算重叠区域的比例衡量相似度,体现的是模型在超广角 OCT 图像目标区域边界分割的性能。其表达式分别为:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (14)$$

$$Dice = \frac{2 \times TP}{TP + FN + TP + FP}, \quad (15)$$

$$IOU = \frac{TP}{TP + FN + FP}, \quad (16)$$

其中: TP 表示模型预测结果与超广角 OCT 图像脉络膜层真实标签均判定为正类的样本集合, TN 表示模型预测结果与超广角 OCT 图像脉络膜层真实标签均判定为负类的样本集合, FP 表示模型结果预测为正类但超广角 OCT 图像脉络膜层真实标签为负类的样本集合, FN 表示模型预测为负类但超广角 OCT 图像脉络膜层真实标签为正类的样本集合。

3.3 消融实验

这里设计了 4 组不同的消融实验,以验证 EEM 模块和 AIM 模块的性能,如表 2 所示。消融实验以 TransUnet 为基准模型,模型 A 为仅新增 EEM 边缘增强模块的 TransUnet,模型 B 为仅增加 AIM 注意力融合模块的 TransUnet,模型 C 为同时新增 EEM 边缘增强模块和 AIM 注意力融合模块的 TransUnet。仅在 TransUNet 中使用

EEM 边缘增强模块的模型 A 与 TransUNet 相比,在 ACC 上增加了 0.007 2,在 Dice 上增加了 0.068 2,在 IOU 上增加了 0.106 8;仅在 TransUNet 中使用 AIM 注意力融合模块的模型 B 在 ACC 上增加了 0.010 9,在 Dice 上增加了 0.061 6,在 IOU 上增加了 0.096 0;同时使用 EEM 边缘增强模块和 AIM 注意力融合模块的模型 C 即 METransUNet,在 ACC 上增加了 0.014 8,在 Dice 上增加了 0.076 0,在 IOU 上增加了 0.119 9。

对比可知,EEM 边缘增强模块可以充分关联浅层特征与深层特征信息,增强脉络膜层的边缘特征信息,有助于提升分割模型的准确率;而 AIM 注意力融合模块通过融合跳跃连接的特征

表 2 消融实验结果

Tab. 2 Results of ablation experiment

Method	EEM	AIM	ACC	Dice	IOU
TransUNet			0.978 2	0.835 4	0.717 3
A	✓		0.985 4	0.903 6	0.824 1
B		✓	0.989 1	0.897 0	0.813 3
C	✓	✓	0.993 0	0.911 4	0.837 2

和编码器的特征,进一步提高分割准确率。

3.4 对比实验

为了验证现有脉络膜层分割模型与超广角 OCT 数据集适配度,将该领域分割模型在 GOALS-2022 数据集与 D-choroid 数据集上分别进行实验对比,结果如表 3 所示。

表 3 不同分割模型在不同数据集上的对比实验结果

Tab. 3 Comparative experimental results of different segmentation methods on different datasets

Method	Dataset	ACC	Dice	IOU
UNet	GOALS-2022	0.984 6	0.905 2	0.826 9
	D-choroid	0.962 4	0.785 7	0.647 1
Attention U-Net	GOALS-2022	0.986 3	0.912 8	0.839 6
	D-choroid	0.964 2	0.793 9	0.658 2
UNet++	GOALS-2022	0.987 2	0.921 0	0.853 5
	D-choroid	0.967 3	0.804 8	0.673 3
Swin-UNet	GOALS-2022	0.992 0	0.926 5	0.863 0
	D-choroid	0.972 1	0.831 8	0.712 1
TransUNet	GOALS-2022	0.994 0	0.929 3	0.868 0
	D-choroid	0.978 2	0.835 4	0.717 3

由表 3 可知,UNet, Attention U-Net, Swin-UNet, UNet++, TransUNet 模型在 GOALS-2022 数据集实验的 ACC, Dice, IOU 值均高于模型在 D-choroid 数据集上的对应实验值。对比结果表明,UNet, Attention U-Net, Swin-UNet, UNet++, TransUNet 分割模型在超广角 OCT 数据集中会出现模型适配度不高、分割效果表现不佳的情况。

为了验证 METransUNet 脉络膜层分割模型的性能,将这些优秀模型在 D-choroid 数据集上进行实验对比,结果如表 4 所示。由表 4 可知,在 D-choroid 数据集上, METransUNet 模型的 ACC 值为 0.993 0, Dice 值为 0.911 4, IOU 值为 0.837 2,均高于其他模型。实验结果表明, METransUNet 脉络膜层分割模型的 Dice, IOU

表 4 不同分割模型在 D-choroid 数据集上的对比实验结果

Tab. 4 Comparison experiment results of different segmentation models on D-choroid dataset

Method	ACC	Dice	IOU
UNet	0.962 4	0.785 7	0.647 1
Attention U-Net	0.964 2	0.793 9	0.658 2
UNet++	0.967 3	0.804 8	0.673 3
Swin-UNet	0.972 1	0.831 8	0.712 1
TransUNet	0.978 2	0.835 4	0.717 3
METransUNet	0.993 0	0.911 4	0.837 2

值较 TransUNet 模型分别提高了 0.076 0, 0.119 9, 能够提高超广角 OCT 图像场景下的脉络膜层分割准确度。

3.5 泛化实验

为了验证 METransUNet 脉络膜层分割模型的泛化性,将 D-choroid 数据集测试集中的 138 张图像替换为未使用的超广角 OCT 图像,训练过程保持一致,实验结果如表 5 所示。

由表 5 可知,替换测试集之后的训练结果在

ACC 上下降了 0.001 3,在 Dice 值上下降了 0.019 2,在 IOU 值上下降了 0.031 8,脉络膜层分割准确率略有下降,但相比于 TransUNet 模型,替换测试集之后的 ACC,Dice,IOU 值均有提升。因此,METransUNet 脉络膜层分割模型具有较好的泛化性。

表 5 泛化实验结果

Tab. 5 Results of generalization comparison experiment

Dataset	Methods	ACC	Dice	IOU
D-choroid	TransUNet	0.978 2	0.835 4	0.717 3
D-choroid	METransUNet	0.993 0	0.911 4	0.837 2
Replaced D-choroid	METransUNet	0.991 7	0.892 2	0.805 4

3.6 可视化实验

为了直观展示新建的脉络膜层分割模型 METransUNet 的分割性能,将 UNet, Attention

U-Net, UNet++ , Swin-Unet, TransUNet 和 METransUNet 模型分别在超广角 OCT 图像中进行可视化,结果如图 9 所示。




图 9 可视化结果

Fig. 9 Visualization results

对 Image1 脉络膜层进行分割时,UNet 出现了不连续的情况;Attention U-Net 相较于 UNet 更加连续但在边界细节处还存在分割错误;UNet++ 模型在边界细节分割上更加优秀,但依然存在不连续的问题;Swin-Unet 相较于 UNet++ 边界更加平滑且无不连续情况,但在对比度较低区域依然存在分割细节不够的问题;TransUNet 在边界分割细节上表现更好,但相对于 Lable 仍有一定差距;METransUNet 在边缘细节上相较于以上模型更好,与 Lable 更为接近。

对 Image2 脉络膜层进行分割时,UNet 将背景噪声误分割为脉络膜层;Attention U-Net 通过引入注意力机制,将背景噪声区域与脉络膜层区

分开,但边界细节不足;UNet++ 将背景信息噪声识别出的同时,在边界分割上更加平滑,但存在过度分割问题;Swin-Unet 在分割时更加平滑,但分割细节不足;TransUNet 相较于 Swin-Unet 在边界分割细节上表现更好,但与 Lable 仍存在一定差距;METransUNet 相较于 TransUNet 在保留边界分割细节的同时更加平滑,与 Lable 更为接近。

由表 4 和图 9 可知,METransUNet 脉络膜层分割模型在 D-choroid 数据集上的实验数据与可视化效果均有所提升,所构建的 EEM 以及 AIM 可以达到预期效果。

4 模型工程化

本系统模型工程化部署采用浏览器-服务器(B/S)架构完成整体系统设计,该模型作为针对超广角OCT图像智慧诊疗的重要技术支撑,已完成工程化部署。

4.1 图像采集端

超广角OCT图像采集选用Intalight赛伟公司如意全眼超广角OCT设备,该设备能够快速采集标准化超广角OCT原始影像,并支持医疗DICOM标准影像输出。

4.2 服务器/算法处理

服务器端以Dell PowerEdge XE9680 GPU为算力核心、Dell PowerScale F910为高速存储

核心构建算力-存储解耦架构,通过万兆以太网进行高速数据交互,完成数据交互、GPU并行推理、临床指标量化计算与结构化临床数据储存等工作。

4.3 用户终端

通过浏览器实现访问,根据用户区分医生端与患者端权限与功能界面。医生可通过PC端在线查看超广角OCT分割结果、分析量化指标、编辑电子诊断报告;患者可通过移动智能设备查询个人检查记录、浏览诊断结果并下载电子报告,同时系统可对接专业医用影像自助打印终端设备巨鼎柯尔尔SDP-10A实现超广角OCT图像和诊断报告的自助打印,满足不同临床用户的使用需求。模型工程化方案如图10所示。

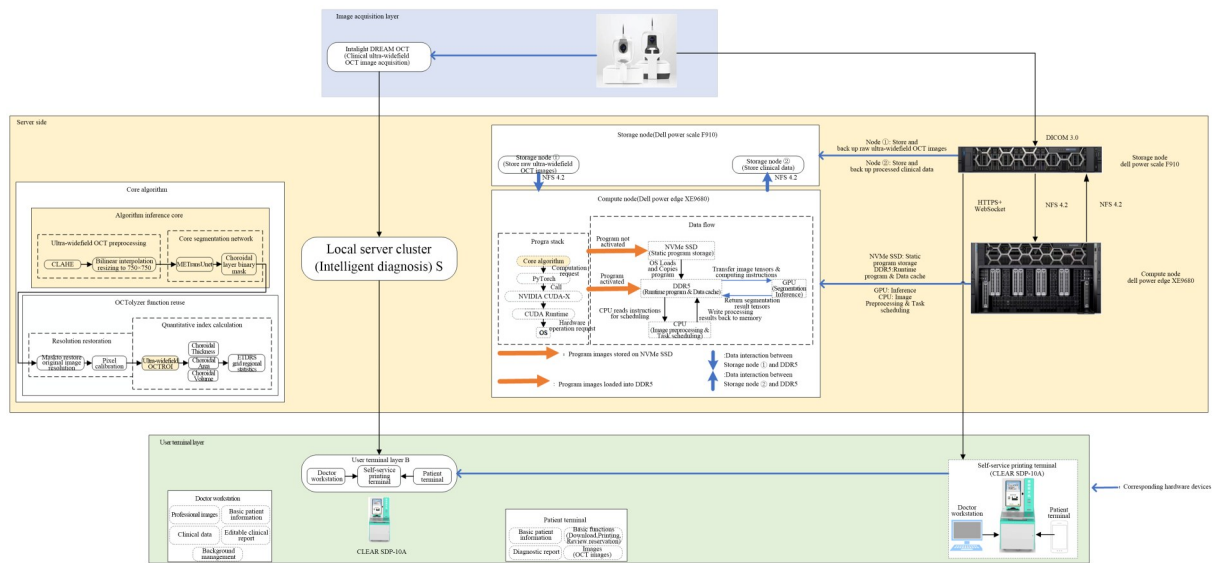


图10 METransUNet模型的工程化布局

Fig. 10 Engineering layout of METransUNet model

在核心算法上选用开源工具OCTolyzer^[28]作为算法部署载体,该工具推理逻辑与影像读取、量化分析、可视化等模块流程完全解耦,仅通过独立函数接口完成分割模型调用,无需改动底层数据处理代码,具备替换为METransUNet分割网络的能力。然而,其内置Choroidalzyer分割模型基于传统OCT图像构建数据集,该工具要进行部分处理以适配超广角OCT图像数据集,最后通过结合患者主诉信息,进行语义分析处理,具体改造方案如下:

(1) 替换本文训练完成的METransUNet分割网络与最优模型权重;

(2) 修改该工具在超广角图像分辨率、视野、图像增强和预处理的逻辑以适配超广角OCT图像数据集;

(3) 新增适配超广角OCT的图像尺度换算、ROI(Region of Interest, ROI)等专属处理模块,匹配超广角OCT成像特征。

该改造方案复用OCTolyzer成熟的批量文件读取、运行日志记录及分割结果可视化存储框

架,能够大幅降低超广角 OCT 脉络膜层临床自动化分析的成本。本文的核心工作聚焦超广角 OCT 图像预处理以及核心分割算法,通过自建 METransUNet 模型实现脉络膜高精度分割,并计划完成 OCTolyzer 工具适配改造,搭建完整临床量化分析与诊断系统。

5 结 论

为实现眼底脉络膜层超广角 OCT 图像的智能分割,本文提出一种基于 TransUNet 网络的多尺度,边缘增强型图像分割模型 METransUNet。通过引入基于池化操作和注意力机制的 EEM,以提取并强化超广角 OCT 图像的边缘和纹理特征的能力。同时,引入 AIM,用于融合来自边缘特征模块和解码器的特征信息,达到充分利用中

间层高分辨率纹理信息的目的。在新构建的超广角 OCT 数据集上进行实验,同时为了避免噪声过度放大的问题,采用 CLAHE 直方图均衡化进行数据增强。最后,在该数据集上评估 METransUNet 模型的分割效果,得到的 ACC 值为 0.993 0, Dice 值为 0.911 4, IOU 值为 0.837 2,达到了理想的分割效果。在此基础上,设计了一套浏览器-服务器(B/S)系统架构,完成模型工程化应用。

作者贡献声明:

赖平红:写作指导,数据集资源提供;
江志豪:论文构思与撰写;
祝 琴:系统设计与论文审核;
曾明如:实验指导;
韩沈阳:实验与数据分析。

参考文献:

- [1] 高阳,李中梁,张建华,等. 基于扫频 OCT 的全眼成像系统[C]. 中国光学学会光学测试专业委员会,第十七届全国光学测试学术交流会摘要集, 2018:258.
GAO Y, LI ZH L, ZHANG J H, *et al.* Full-eye imaging system based on swept-source OCT [C]. *Optical Testing Professional Committee of the Chinese Optical Society, Abstract Collection of the 17th National Optical Testing Academic Exchange Conference*, 2018:258.
- [2] DASTIRIDOU A I, BOUSQUET E, KUEHLEWEIN L, *et al.* Choroidal imaging with swept-source optical coherence tomography in patients with birdshot chorioretinopathy choroidal reflectivity and thickness [J]. *Ophthalmology*, 2017, 124 (8) : 1186-1195.
- [3] MIGACZ J V, GORCZYNSKA I, AZIMIPOUR M, *et al.* Megahertz-rate optical coherence tomography angiography improves the contrast of the choriocapillaris and choroid in human retinal imaging [J]. *Biomedical Optics Express*, 2019, 10(1): 50.
- [4] LIU G J, YANG J L, WANG J, *et al.* Extended axial imaging range, widefield swept source optical coherence tomography angiography [J]. *Journal of Biophotonics*, 2017, 10(11): 1464-1472.
- [5] 何桂琴,文峰. 正常眼的脉络膜血管系统研究进展 [J]. 眼科学报, 2024, 39(7): 365-373.
HE G Q, WEN F. Research progress on choroidal vascular system in healthy eyes [J]. *Eye Science*, 2024, 39(7): 365-373. (in Chinese)
- [6] 周愉,张敏,朱瑜洁,等. 深度学习在脉络膜分割中的应用研究进展[J]. 国际眼科杂志, 2023, 23 (6): 1007-1011.
ZHOU Y, ZHANG M, ZHU Y J, *et al.* Research progress on the application of deep learning in choroidal segmentation [J]. *International Eye Science*, 2023, 23(6): 1007-1011. (in Chinese)
- [7] 杨泽华. 基于深度学习的 OCT 图像脉络膜分割算法研究[D]. 杭州:杭州电子科技大学, 2023.
YANG Z H. *Research on Choroidal Segmentation Algorithm of OCT Images Based on Deep Learning* [D]. Hangzhou: Hangzhou Dianzi University, 2023. (in Chinese)
- [8] ZHANG L, LEE K, NIEMEIJER M, *et al.* Automated segmentation of the choroid from clinical SD-OCT [J]. *Investigative Ophthalmology & Visual Science*, 2012, 53(12): 7510-7519.
- [9] MASOOD S, SHENG B, LI P, *et al.* Automatic choroid layer segmentation using normalized graph cut [J]. *IET Image Processing*, 2018, 12(1): 53-59.
- [10] MISHRA Z, GANEGODA A, SELICHA J, *et*

- al.* Automated retinal layer segmentation using graph-based algorithm incorporating deep-learning-derived information[J]. *Scientific Reports*, 2020, 10: 9541.
- [11] MAZZAFERRI J, BEATON L, HOUNYE G, *et al.* Open-source algorithm for automatic choroid segmentation of OCT volume reconstructions[J]. *Scientific Reports*, 2017, 7: 42112.
- [12] GONZÁLEZ-LÓPEZ A, REMESEIRO B, ORTEGA M, *et al.* A Texture-Based Method for Choroid Segmentation in Retinal EDI-OCT Images[M]. Computer Aided Systems Theory-EUROCAST 2015. Cham: Springer International Publishing, 2015: 487-493.
- [13] 蔡怀宇, 张玮茜, 陈晓冬, 等. 眼科光学相干层析成像的图像处理方法[J]. 中国光学, 2019, 12(4): 731-740.
- CAI H Y, ZHANG W Q, CHEN X D, *et al.* Image processing method for ophthalmic optical coherence tomography[J]. *Chinese Journal of Optics*, 2019, 12(4): 731-740. (in Chinese)
- [14] LIU W, SUN Y K, JI Q G. MDAN-UNet: multi-scale and dual attention enhanced nested U-Net architecture for segmentation of optical coherence tomography images[J]. *Algorithms*, 2020, 13(3): 60.
- [15] CAHYO D A Y, WONG D W K, YOW A P, *et al.* Volumetric choroidal segmentation using sequential deep learning approach in high myopia subjects[C]. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). July 20-24, 2020, Montreal, QC, Canada. IEEE, 2020: 1286-1289.
- [16] HE F, CHUN R K M, QIU Z C, *et al.* Choroid segmentation of retinal OCT images based on CNN classifier and I_2 - I_q fitter[J]. *Computational and Mathematical Methods in Medicine*, 2021, 2021: 8882801.
- [17] KHAING T T, OKAMOTO T, YE C, *et al.* ChoroidNET: a dense dilated U-Net model for choroid layer and vessel segmentation in optical coherence tomography images[J]. *IEEE Access*, 2021, 9: 150951-150965.
- [18] ZHU L, LI J M, ZHU R L, *et al.* Synergistically segmenting choroidal layer and vessel using deep learning for choroid structure analysis[J]. *Physics in Medicine & Biology*, 2022, 67(8): 085001.
- [19] YAN Q F, GU Y Y, ZHAO J Y, *et al.* Automatic choroid layer segmentation in OCT images via context efficient adaptive network[J]. *Applied Intelligence*, 2023, 53(5): 5554-5566.
- [20] WANG Y Q, YANG Z H, LIU X D, *et al.* PG-KD-net: prior-guided and knowledge diffusive network for choroid segmentation[J]. *Artificial Intelligence in Medicine*, 2024, 150: 102837.
- [21] ZHU X Y, LI S Y, BI H L, *et al.* Automatic choroid segmentation and thickness measurement based on mixed attention-guided multiscale feature fusion network[J]. *IEEE Transactions on Medical Imaging*, 2026, 45(1): 350-363.
- [22] 黄文博, 屈超凡, 燕杨. 融合注意力机制的 TransGLnet 脉络膜自动分割[J]. 光学精密工程, 2023, 31(23): 3482-3489.
- HUANG W B, QU CH F, YAN Y. Automatic segmentation of choroid by TransGLnet integrating attention mechanism[J]. *Optics and Precision Engineering*, 2023, 31(23): 3482-3489. (in Chinese)
- [23] LU Z L, LIU T, NI Y W, *et al.* ChoroidSeg-ViT: a transformer model for choroid layer segmentation based on a mixed attention feature enhancement mechanism[J]. *Translational Vision Science & Technology*, 2024, 13(9): 7.
- [24] WEN Y, WU Y L, BI L, *et al.* A transformer-assisted cascade learning network for choroidal vessel segmentation[J]. *Journal of Computer Science and Technology*, 2024, 39(2): 286-304.
- [25] HUANG W B, QU C F, YAN Y. A novel network for choroidal segmentation based on enhanced boundary information[J]. *IEEE Access*, 2025, 13: 7027-7039.
- [26] SUN Y J, WANG S, CHEN C, *et al.* Boundary-guided camouflaged object detection[C]. *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence*. July 23-29, 2022. Vienna, Austria. International Joint Conferences on Artificial Intelligence Organization, 2022: 1335-1341.
- [27] STERGIOU A, POPPE R. AdaPool: exponential adaptive pooling for information-retaining downsampling[J]. *IEEE Transactions on Image Processing*, 2023, 32: 251-266.

- [28] BURKE J, ENGELMANN J, GIBBON S, *et al.* OCTolyzer: Fully automatic toolkit for segmentation and feature extracting in optical coherence tomography and scanning laser ophthalmoscopy data [EB/OL]. 2024: *arXiv*: 2407.14128. <https://arxiv.org/abs/2407.14128>.

作者简介:



赖平红(1974—),男,江西吉安人,博士,2006年于中山大学获得博士学位,主要研究方向为眼科学科研与临床。E-mail:laipinghong@ncmc.edu.cn

通讯作者:



祝琴(1978—),女,江西临川人,博士,教授,2011年于北京科技大学获得博士学位,主要研究方向为计算机视觉技术与系统工程。E-mail:zhuqin@ncu.edu.cn