

文章编号:1007-2780(XXXX)XX-0001-15

基于小波与粗概率先验双分支的眼底微细血管分割网络

常汇谈, 马 瑜*, 黄守彤, 肖 越
(宁夏大学 电子与电气工程学院, 宁夏 银川 750021)

摘要: 视网膜血管的管径、分叉数等形态参数可作为临床诊疗的重要依据, 精准分割微细血管对相关疾病的早期诊断至关重要。现有方法在微细血管检测中易出现血管拓扑断裂的现象, 同时普遍存在粗细血管特征融合不充分的缺陷。本文采用 IterMiUnet 作为粗分割分支提取全局血管特征, Haar 小波先验增强细血管频域表达能力, 强化边缘细节特征。针对粗分割难以精准识别弱边界、伪影干扰等难分割区域, 以粗分割概率不确定性像素作为先验引导, 使细血管分割模型主动聚焦上述难分割区域, 进一步提升分割精度; 构建双尺度概率编码融合机制, 结合温度缩放与背景抑制策略, 借助细血管分割结果优化粗分割输出, 实现两类结果的自适应融合。在 DRIVE、CHASE_DB1、STARE 三个公开数据集上的实验结果表明, 本文算法的分割性能优于当前多种主流方法, F1 指标分别达到了 0.825 7、0.836 0、0.835 7。本文算法整体分割效果稳定可靠, 分割精度优良, 能有效捕捉细血管细节并保持血管拓扑完整性。

关键词: 计算机视觉; 深度学习; 图像分割; 视网膜血管; 小波

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.37188/CJLCD.2026-0107 **CSTR:** 32172.14.CJLCD.2026-0107

Based on wavelet and coarse probability prior dual-branch network for retinal micro vessel segmentation

CHANG Huitan, MA Yu*, HUANG Shoutong, Xiao Yue

(College of Electronics and Electrical Engineering, Ningxia University, Yinchuan 750021, China)

Abstract: Morphological parameters such as the diameter and bifurcation of retinal blood vessels serve as important references for clinical diagnosis, and accurate segmentation of microvessels is essential for the early diagnosis of related diseases. Existing segmentation methods often suffer from blurred edges, fractured topological structures, and inadequate fusion of thick and thin vessel features in microvessel detection. To address these issues, this paper proposes a dual-branch segmentation network. We adopt IterMiUnet as the coarse segmentation branch to extract global vascular features, and introduce Haar wavelet prior to enhance the frequency-domain representation and edge details of microvessels. Since

收稿日期: 2026-06-15; **修订日期:** 2026-07-21.

基金项目: 国家自然科学基金 (No.42361056); 自治区重点研发计划 (No.2023BDE03002); 中央支持地方项目 (No.2023FRD05034)

National Natural Science Foundation of China (No.42361056); Key R&D Program of Ningxia Hui Autonomous Region (No. 2023BDE03002); Central Government Support Program for Local Development (No.2023FRD05034)

*通信联系人, E-mail: mayu95@163.com

coarse segmentation struggles to identify weak boundaries and fractured vessels accurately, we take uncertain pixels from coarse segmentation probability as prior guidance, enabling the fine segmentation model to focus on these challenging regions and boost segmentation precision. A dual-scale probability encoding fusion mechanism combined with temperature scaling and background suppression is also constructed. The outputs of coarse segmentation are optimized using fine segmentation results to realize adaptive fusion and reduce background interference. Experiments on DRIVE, CHASE_DB1 and STARE datasets demonstrate that the proposed algorithm outperforms mainstream methods, with F1 scores of 0.825 7, 0.836 0 and 0.835 7 respectively. It achieves stable and reliable performance, and can effectively capture microvascular details while maintaining the topological integrity of blood vessels.

Key words: computer vision; deep learning; image segmentation; retinal blood vessels

1 引言

视网膜血管的形态变化与多种疾病密切相关,如糖尿病视网膜病变、高血压、心脑血管疾病等^[1]。视网膜血管分割是眼底图像智能化诊断中的一项基础任务,对疾病的早期筛查和诊断具有重要意义^[2-3]。在视网膜血管分割任务中微细血管的准确检测尤为关键。由于微细血管对比度低、边界模糊、拓扑结构复杂,现有分割方法在细血管检测上仍面临较大挑战。传统的匹配滤波、形态学操作^[4]等方法依赖人工设计的特征,难以应对眼底图像复杂性问题。

深度学习方法如是光学神经网络和卷积神经网络在视网膜血管分割中取得了显著进展^[2,5-6]。FCN^[7]的出现成为语义分割的第一个开创性工作,既能保留提取深层语义特征,又能保留浅层细节特征,从而使端到端模型的训练成为可能。Ronneberger等^[8]提出了UNet,编码器-解码器结构和跳跃连接的设计有效地保留细节信息,提升血管图像分割精度;Chen等^[9]提出AAU-Net,在UNet中引入混合自适应注意力模块,聚焦血管区域并抑制背景干扰,进一步增强特征表达能力;郭昊虎等^[10]针对冠脉造影图像提出特征图金字塔分割方法,利用多尺度特征融合提升低对比度下的血管分割鲁棒性。但上述方法通常采用单分支网络结构,在同时捕获全局血管结构和细血管细节方面存在局限性,易导致细血管断裂或漏检。

为提升细血管的分割能力,研究者提出了多种双分支或多阶段网络结构提升眼底血管分割精度。Liu等^[11]提出DS-VPE方法,采用粗细双

分支分别分割主血管与细血管,并基于不确定像素概率修正策略实现分支结果融合,有效改善血管欠分割问题;Qu等^[12]提出TP-Net,采用双路径架构分别提取血管主干与边缘特征,并通过多尺度特征融合提升细血管检测精度;张蓉蓉等^[13]提出双路径编码与跨级解耦网络,通过多向差分残差模块提取血管边缘特征。虽上述方法在细血管检测上取得了一定进展,但在特征融合阶段不能充分考虑不同区域的特征差异,融合效果有待提升。

另外,频域分析方法凭借对图像频率特征的精准捕捉能力,在视网膜血管分割中展现独特优势,将图像转换至频域并分离高低频分量,精准挖掘传统空间域方法难以捕捉的微细血管细节。相关研究中,Wang等^[14]提出WaveRNet,设计小波细化融合架构,依托可学习小波分解与频谱调制模块解耦图像高低频信息,提取眼底血管高频细节特征,增强视网膜血管分割鲁棒性。Li等^[15]构建WDM-UNet,设计空间和小波双域融合结构,结合可变形卷积捕捉自适应感受野,弥补单一空间域建模缺陷,优化多尺度眼底血管分割效果。但现有频域与深度学习结合的方法仍有局限,多数仅将频域特征作为辅助补充,缺少针对微细血管的融合设计,难以充分发挥频域分析在捕捉微细血管特征上的优势。

本文以IterMiUnet^[16]为基础模型,提出一种融合小波^[17-18]空间先验与不确定性引导的双分支视网膜血管分割网络。采用双分支级联结构:粗分割分支以IterMiUnet捕获全局血管结构与整体轮廓;细分割分支为基于密集连接的轻量化小波增强网络(WPUNet),针对现有分割方法易出

现微细血管拓扑断裂问题,引入Haar小波^[18]空间先验模块(WSP)在强化细血管边缘与高频纹理特征的同时具有较低的计算复杂度^[15]。利用空间注意力机制,依托粗分割概率特征的不确定性引导模块(PGSA)使微细血管分割网络聚焦难分割区域。为实现粗细分割结果的精准融合,提出带温度缩放与背景抑制的双尺度概率融合策略(DSPT-BG),完成粗细分支结果的自适应、抗干扰融合。本文粗分割引导细血管分割的双分支设计可移植性良好,可迁移至其他粗分割模型,提升其微细血管分割能力。

2 方 法

2.1 网络框架

微细血管管径细小,现有分割方法常出现血管拓扑断裂问题,还存在粗细血管特征融合效果不佳的问题。为此本文提出由粗概率特征引导的级联双分支视网膜血管分割框架,网络结构如

图1所示。整体框架由粗分割网络(IterMiUnet)与细血管分割分支(WPUNet)级联构成。细血管分割网络WPUNet以密集连接的UNet架构为主干,基础单元与粗分割分支IterMiUnet保持一致,均采用双卷积块(TwoConvBlock)^[16]结构,由两层连续的Conv-BN-ReLU构成,用于完成特征的提取与变换。统一的基础单元设计,保证双分支网络特征表示的一致性。采用IterMiUnet对输入眼底图像进行粗分割输出粗概率特征 P_c 。同时将原始图像输入WSP进行频域增强,强化微细血管的高频边缘与纹理细节。针对粗分割难以精准识别弱边界、伪影干扰等难分割区域,在浅层特征阶段, P_c 通过PGSA实现概率先验引导:由 P_c 计算不确定性提示并生成空间注意力权重,对浅层特征进行自适应加权调制,使网络更聚焦粗分割的不确定区域。最终,将粗分割与细分割输出的两级概率特征,通过DSPT-BG融合策略完成自适应加权融合,进一步提升粗分割网络的精度。




图1 WPUNet网络框架

Fig. 1 Network framework of WPUNet

2.2 IterMiUnet 网络

IterMiUnet 是一种用于视网膜血管分割的轻量化卷积神经网络^[16],模型融合 IterNet^[19]的迭代设计和 MiUnet^[19]的轻量化结构,以基础特征提取结合迭代优化为核心框架,全程保留跳连接保障定位精度。图2为 IterMiUnet 网络

结构示意图,网络以双卷积块为基本特征提取单元,基础模块(Base Module)为 MiUnet 架构, MiUnet 与传统编码器-解码器结构相反,其滤波器数量随网络深度增加而减少或保持不变^[16],多层卷积与池化设计实现多尺度特征提取与初步分割图重建,借助跳连接融合高低层特征;




图2 IterMiUnet网络结构

Fig. 2 Network architecture of IterMiUnet

迭代模块(Iterative Modules),由多个串联的轻量化子网络构成,每个模块输入为前一模块次末层特征图和跨模块跳接复用基础模块的低层特征,迭代修正分割误差,最终经 1×1 卷积输出粗分割概率图 P_c ,为细分割分支提供全局结构先验。

2.3 WPUNet网络

细分割网络WPUNet在编码器前端引入WSP模块对输入图像进行频域增强,突出细血管的高频边缘与纹理特征。在浅层特征编码阶段,通过PGSA模块结合粗分割概率图 P_c 实现先验引导,依据粗分割结果的不确定性生成空间权重,对浅层特征进行自适应调制,使网络更关注弱边界和细血管区域。解码器借助多尺度嵌套跳跃连接实现高低层特征融合,最终输出细血管分割概率图。

2.3.1 WSP模块

为增强特征在频域空间中的上下文关联和强化细血管边缘与纹理特征的表达能力,本研究设计WSP模块。图3为WSP模块的详细设计,模块位于网络输入端,将单通道眼底图像频域特征下的高频信息进行建模与增强。以Haar二维

小波变换为基础,通过离散小波变换(DWT)^[12,15]




图3 WSP模块

Fig. 3 WSP module

将输入图像 X_{in} 分解得到一个低频子带特征 F_{LL} 和三个高频子带特征 F_{LH} 、 F_{HL} 、 F_{HH} 。其中,低频子带特征 F_{LL} 主要保留图像整体结构与背景信息。高频子带 F_{LH} 、 F_{HL} 、 F_{HH} 携带的高频细节信息^[20]在成像与处理中具有普遍重要性。

查看图4单通道眼底图像的小波处理结果可发现,水平、垂直高频子带特征 F_{LH} 、 F_{HL} 包含主要的血管边缘信息,而对角高频子带 F_{HH} 含有的血管信息最少、噪声占比最高。针对不同频带的特性,模块采用差异化的增强策略:对角高频分量 F_{HH} 经可学习缩放因子 γ 调整幅值,为避免噪声被过度放大,本研究将 γ 的上限约束为 0.5;经可学习缩放因子调整幅值后通过两个 3×3 双卷积

块完成特征增强,最后以残差连接融合增强后的特征。水平高频分量 F_{HL} 与垂直高频分量 F_{LH} 分别采用方向敏感的卷积路径; F_{HL} 先通过 3×1 卷积^[21]块提取水平方向边缘信息, F_{LH} 先通过 1×3 卷积^[21]块提取垂直方向边缘信息,两路均经 3×3 卷积块融合后使用 1×1 卷积调整通道,最终利用残差连接融合增强后的特征与原始输入。对低频子带 F_{LL} ,模块引入空间注意力机制生成空间注意力权重后和原特征残差融合,突出血管结构的全局信息。增强后的高低频子带经逆离散小波变换(IDWT)^[15]重构为增强特征图 X_{out} ,并以残差连接与原始输入特征相加,最终输出兼具细节增强与结构保留的强化特征图。




图4 眼底图像的小波分解结果

Fig. 4 Wavelet decomposition results of retinal image

具体设计的公式描述如下:

$$[F_{LL}, F_{LH}, F_{HL}, F_{HH}] = \text{DWT}(X_{in}). \quad (1)$$

$$\begin{cases} F_{LL'} = \text{Conv}(\text{Cat}(\text{AvgPool}(F_{LL}), \text{MaxPool}(F_{LL}))) + F_{LL} \\ F_{LH'} = \text{Conv}(\text{Cat}(\text{CB}_{1 \times 3}(F_{LH}), \text{CB}_{3 \times 3}(F_{LH}))) + F_{LH} \\ F_{HL'} = \text{Conv}(\text{Cat}(\text{CB}_{1 \times 3}(F_{HL}), \text{CB}_{3 \times 3}(F_{HL}))) + F_{HL} \\ F_{HH'} = \gamma \cdot \text{CB}_{3 \times 3}(\text{CB}_{3 \times 3}(F_{HH})) + F_{HH} \end{cases}, \quad (2)$$

$$X_{out} = X_{in} + \text{IDWT}(F_{LL'}, F_{LH'}, F_{HL'}, F_{HH'}), \quad (3)$$

式中: $F_{LL'}$ 、 $F_{LH'}$ 、 $F_{HL'}$ 、 $F_{HH'}$ 分别表示 F_{LL} 、 F_{LH} 、 F_{HL} 和 F_{HH} 经不同增强后的特征;Conv表示 1×1 卷积;Cat表示连接操作;AvgPool表示全局平均池化;MaxPool表示全局最大池化;CB表示卷积块操作。

2.3.2 PGSA 模块

在 WPUNet 的第一层编码器后引入概率图引导空间注意力模块(PGSA),可使细分割网络更聚焦粗分割结果中置信度较低的微细血管、弱

边界及模糊区域,结构见图5。基于粗分割输出的概率特征 P_c 计算像素级不确定性图 P_u ,量化每个像素的分割置信度,计算公式为:

$$P_u = 1 - |2P_c - 1|. \quad (4)$$

再对不确定性图 P_u 生成针对难分割区域的空间注意力权重 F_a 。针对粗分割概率特征分别执行全局平均池化 AvgPool、全局最大池化 MaxPool,将两类池化结果在通道维度拼接后拼接,通过卷积层 Conv 及 Sigmoid 激活操作,生成聚焦难分割区域的空间注意力权重,具体公式为:




图5 PGSA示意图

Fig. 5 Schematic diagram of PGSA module

$$F_a = \text{Sigmoid}\left(\text{Conv}\left(\text{Cat}\left(\text{AvgPool}(P_u), \text{MaxPool}(P_u)\right)\right)\right). \quad (5)$$

将生成的空间注意力权重 F_a 作用于 WPU-Net 第一层编码器输出的浅层特征 F_{e1} , 通过残差增强方式强化难分割区域的特征表达, 同时保留原始特征信息, 增强后特征 F'_{e1} 的计算公式为:

$$F'_{e1} = F_{e1}(1 + F_a). \quad (6)$$

2.4 DSPT-BG 模块

为充分利用粗分割的全局结构先验与细分割的高精度细节信息, 本文提出双尺度概率融合策略 (DSPT-BG), 在推理阶段实现粗、细分割结果的自适应加权融合。该策略以粗分割置信度为引导, 结合尺度对齐、置信度加权、温度缩放、背景抑制^[22]与自适应融合, 在提升细血管区域分割权重的同时, 有效滤除背景伪阳性噪声。与传统方法相比较, 融合结果兼具全局结构的完整性与边缘细节的精准性。整体流程可概括为: 先将粗、细分割概率特征统一尺度, 再对细分割概率图执行温度缩放以调节概率分布锐度。具体操作公式如下:

$$P'_f = \frac{P_f^{1/T}}{P_f^{1/T} + (1 - P_f)^{1/T}}, \quad (7)$$

式中: T 为温度参数, 设定为 0.8; P_f 为细分割概率特征; P'_f 为缩放后的概率特征。

基于粗分割概率图的固定阈值 (0.3~0.7) 识别不确定区域, 在区域内取粗、细概率特征最大值完成基础融合; 相关计算可用公式表示为:

$$P_{fused} = \begin{cases} \max(P_c, P'_f), & 0.3 \leq P_c \leq 0.7 \\ P_c, & \text{otherwise} \end{cases}, \quad (8)$$

式中: P_{fused} , P_c , P'_f 分别代表融合后、粗分割和经温度缩放后第 i 行第 j 列处的细分割概率值。

最后检测粗分割判定为背景但细分割高置信的冲突区域, 对其执行概率衰减的背景抑制操作, 输出最终融合概率图。具体计算过程与公式定义如下:

$$P_{out} = \begin{cases} \text{clip}(P_f \times (1 - \beta), 0, 1), & P_c < 0.2 \wedge P'_f > 0.6 \\ P_f, & \text{otherwise} \end{cases}, \quad (9)$$

式中: P_{out} 为背景抑制后的最终概率特征, β 为背景抑制参数, 默认取值为 0.5, 值越大背景抑制越强但细血管漏检风险越高, $\text{clip}(x, 0, 1)$ 表示数值边界约束操作, 强制输出值落在 $[0, 1]$ 区间内。该公式首先使用 $P_c < 0.2 \wedge P'_f > 0.6$ 来判定冲突区域。

2.5 算法流程

本节给出所提双分支视网膜血管分割网络的完整训练与推理流程, 如算法 1 所示。算法分为粗分割、细血管分割和融合输出三个阶段, 通过迭代训练优化网络参数, 最终在推理阶段输出高精度的血管分割结果。

算法1 所提双分支分割网络的算法流程

Input:

- 预处理后的视网膜眼底图像 I ;
- 血管分割真值图 G ;

Output:

- 最终分割概率图 P_{out} ;

1. Training:
2. 初始化双分支网络参数;
3. 训练粗分割分支 IterMiUnet;
4. For each epoch do:
5. $P_c = \text{IterMiUnet}(I)$; // P_c 为粗分割概率特征
6. End for
7. 训练细血管分割分支 WPUNet;
8. For each epoch do:
9. $P_u = 1 - 2P_c - 1$; // P_u 为基于粗分割结果计算的像素级不确定性图
10. $X_{out} = \text{WSP}(I)$; // X_{out} 为小波增强模块输出的特征
11. $F_a = \text{PGSA}(P_u)$; // F_a 为不确定性引导的特征
12. $F'_{e1} = F_{e1}(1 + F_a)$; // F'_{e1} 为注意力增强后的浅层特征
13. $P_f = \text{WPUNet}(X_{out}, F'_{e1})$; // P_f 为细分割分支输出的细血管概率图
14. End for
15. Inference:
16. $P_c = \text{IterMiUnet}(I)$;
17. $P_f = \text{WPUNet}(I, P_c)$;
18. $P_{out} = \text{DSPT-BG}(P_c, P_f)$;
19. Return P_{out} ;

3 实验结果与分析

3.1 数据集与细血管标签

为验证本文方法的有效性,实验在 DRIVE、CHASE_DB1 和 STARE 三个公开的视网膜血管分割数据集上进行。三个数据集是视网膜血管分割领域广泛使用的基准数据集,具有不同的图像特点。数据集相关信息如表1所示。

DRIVE 数据集^[23]中的图像来自荷兰糖尿病视网膜病变筛查项目,分辨率为 565×584 像素。图像质量较好,血管结构清晰,包含 40 张彩色眼底图像,其中 33 张照片没有显示任何糖尿病视网膜病变迹象,7 张显示轻度早期糖尿病视网膜病变迹象,训练集和测试集各 20 张图像。

CHASE_DB1 数据集^[24]出自儿童心脏与遗传疾病研究,数据集的图像分辨率较高,血管结构较为复杂,微血管细节更加丰富,对分割算法的细节捕捉能力提出了更高要求。共包含 28 张彩色眼底照片,分辨率为 999×960 像素。其中前 20 张用于训练,后 8 张用于测试。

STARE 数据集^[25]常被用来研究眼底视网膜血管特征与糖尿病、高血压、动脉硬化之间的关系。包含 20 张分辨率为 700×605 像素的彩色眼底照片,其中 15 张作为训练集,5 张作为测试集。测试集中包含两张严重病变图像,用于验证算法在病理图像上的分割性能。

表1 不同数据集的相关信息

Tab.1 Details of various datasets

数据集	数量	训练/测试	分辨率
DRIVE	40	20/20	584×565
STARE	20	15/5	605×700
CHASE_DB1	28	20/8	960×999

为训练细血管分割网络,将原始血管金标准分离出粗血管和细血管两套标签。采用基于欧氏距离变换 (EuclideanDistanceTransform, EDT)^[26-27] 的粗细血管分离策略。对血管金标准进行欧氏距离变换,以欧氏距离计算每个血管像素到最近背景的最短距离来表征血管局部直径,据此设定阈值将粗血管像素从原始血管金标准中精准分离,剩余部分即为细血管标签。首先,对血管分割金标准 $G_{(x,y)}$ 进行欧氏距离变换,具体操作的数学表达式为:

$$R(x, y) \equiv \text{EDT}(G_{(x,y)}) = \min_{(x', y') \in \text{background}} \sqrt{(x - x')^2 + (y - y')^2}, \quad (10)$$

式中: $R(x, y)$ 表示像素 (x, y) 到最近背景像素 (x', y') 的距离,即该像素位置的局部半径 R 。血管局部直径 D 定义为 $D = 2R$ 。

同时,采用 Zhang-Suen 细化算法提取血管骨架 S ,骨架为单像素宽的血管中心线,具体表达式为:

$$S = \text{Skeletonize}(G). \quad (11)$$

给定直径阈值 T (本研究设为 3 像素),在骨架上区分粗细血管中心点:直径大于 T 的骨架点

构成粗血管骨架 ThickSkeleton, 其余为细血管骨架。具体操作的数学公式为:

$$\text{ThickSkeleton} = (x, y) \in S \mid D(x, y) > T. \quad (12)$$

为恢复完整的粗血管区域, 以粗血管骨架点为中心, 采用自适应膨胀策略进行区域扩展, 膨胀半径由粗血管骨架点的局部半径确定。具体操作的数学公式为:

$$\text{ThickMask} = \text{Dilate}(\text{ThickSkeleton}, K_{r_{\max}}) \cap G, \quad (13)$$

式中: ThickMask 表示粗血管区域, $K_{r_{\max}}$ 表示膨胀

半径。

粗血管区域确定后, 为避免直接提取细血管可能导致的像素损失或边界变形, 细血管标签通过从原始血管金标准中剔除粗血管像素的方式间接获得。该方法确保细血管区域的像素与原始金标准完全一致, 实现像素级精确的细血管标签生成。为保证细血管标签结果的连通性和完整性, 通过闭运算填补区域内部孔洞, 此外, 去除面积小于 500 像素的粗血管连通域残留以消除噪声干扰。图 6 为本文方法制作的粗血管和细血管标签示意图。




图6 数据集的眼底血管标签示例

Fig. 6 Examples of retinal vessel labels from datasets

3.2 数据预处理

在模型训练之前, 对眼底图像进行必要的预处理, 以增强血管像素的对比度^[28]。具体预处理流程如下: 将 RGB 眼底图像进行灰度转换后进行归一化处理, 确保图像数据尺度一致。CLAHE^[29]对比度增强使用对比度限制自适应直方图均衡化, 以提升眼底图像的局部对比度, 突出图像细节和边缘。Gamma^[29-30]变换提升图像整体对比度, 防止细节丢失。最终将像素值缩放至 $[0, 1]$ 范围。

由于数据集规模较小, 为更好地训练深层

模型并缓解过拟合, 本研究采用了图像裁剪操作^[31], 使模型充分学习局部细节与纹理变化, 更精准地捕捉视网膜细血管结构。具体设置如下: 训练和测试阶段 patch 大小统一为 64×64 像素, 每个 patch 均包含对应局部图像及其真实标签。从所有训练集图像中随机采样 200 000 个 patch, 按照 9:1 的比例随机划分为训练集与验证集。测试阶段在得到预测块后按位置拼接恢复为完整分割图, 仅在视场 (FOV) 区域内计算指标, 以排除无效背景的干扰。图 7 为图像预处理流程图。




图7 数据预处理

Fig. 7 Data preprocessing

3.3 评价指标

为全面评估模型在视网膜血管分割任务中的性能表现,本文采用图像分割领域常用的六项评价指标,分别为准确率(Accuracy, Acc)、灵敏度(Sensitivity, SE)、特异度(Specificity, SP)、F1分数(F1)和交并比(Intersection over Union, IoU)。上述指标均建立在混淆矩阵的四个基本统计量之上:真阳性(True Positive, TP),正确识别为血管的像素数)、真阴性(True Negative, TN),正确识别为背景的像素数)、假阳性(False Positive, FP),误判为血管的背景像素数)以及假阴性(False Negative, FN),误判为背景的血管像素数)。各指标的定义如下:

$$\begin{cases} Acc = \frac{TP + TN}{TP + TN + FP + FN}, \\ SE = \frac{TP}{TP + FN}, \\ SP = \frac{TN}{TN + FP}, \\ F1 = \frac{2 \times TP}{2 \times TP + FP + FN}, \\ IoU = \frac{TP}{TP + FP + FN}. \end{cases} \quad (14)$$

3.4 实验环境

所有实验均在统一的实验平台上完成。实验硬件平台配置为单张 NVIDIA GeForce RTX 4090 (24GB 显) 显卡, 处理器为 16vCPU Intel (R) Xeon (R) Platinum 8358P @ 2.60GHz; 软件环境为 Ubuntu 22.04 操作系统,

Python 3.12, PyTorch 2.8.0 深度学习框架。模型训练采用 Adam 优化器, 初始学习率设为 1×10^{-3} , 权重衰减系数设为 1×10^{-5} , 使用余弦退火算法动态调整学习率。综合考虑模型性能与计算开销, 总训练轮数设为 50, batchsize 设为 64。

3.5 实验结果

为验证所提方法的有效性, 选取六种经典血管分割网络作为对比方法: UNet^[8]、DenseUNet^[31]、AAU-Net^[9]、IterMiUnet^[16]、EDAE-Net^[32]、MK-UNet^[33]。所有对比模型均在相同数据划分与预处理设置下训练, 并在测试集上进行评估。

3.5.1 主观评估

本文在三个数据集上生成粗概率和细血管概率特征热力图, 结果如图 8 所示。可观察到, 粗分割热力图已能完整捕捉大血管与细血管的整体分布与形态轮廓, 为模型提供了全局血管结构的先验信息; 而细血管热力图对微细血管分支的概率响应进行了精细化增强, 有效提升微细血管、分支区域的分割精度。两类热力图能够全面覆盖不同尺度的血管结构, 为最终分割结果提供更准确的概率基础。

为直观验证所提模型在视网膜血管分割任务中的有效性, 在三个数据集上进行了可视化对比实验, 结果如图 4 所示。图中包含原始眼底图像、对应真实标签, 本文方法和其他对比模型的分割结果。为突出关键差异, 红框标记细血管和视盘周围区域。

从可视化结果可观察到, 本文方法在细血管




图8 粗分割和细血管分割概率特征的热力图

Fig. 8 Heatmaps of probability features for coarse segmentation and fine vessel segmentation

分割上表现优于 UNet、DenseUNet 等多个对照模型,较于对照模型易出现的漏检、血管断裂等问题,本文方法能更精准地捕捉细小管轮廓,有效保持血管的空间连续性,减少因血管纤细、对比度低导致的漏检问题。这源于小波空间先验模块对微细血管边缘特征的增强作用,充分挖掘

不同尺度下的血管形态信息。

3.5.2 定量评估

为全面评估模型性能,在三个公开数据集上采用 ACC、SE、SP、F1 和 IOU 进行定量比较,汇总了 UNet、DenseUNet、AAU-Net、IterMiUnet、EDAE-Net、MK-UNet 与本文方法的测试结果,如表 2 所示:在三个公开数据集上,本文方法均展现出显著的性能优势,相较于近期提出的 MK-UNet 等主流算法均实现了有效提升。在 DRIVE 数据集上,本文算法与 MK-UNet 相比,SE 指标提升了 0.034 2,与 IterMiUnet 相比,F1 分数提升 0.003 3;在 CHASEDB1 数据集上,本文方法整体表现突出,与 MK-UNet 相比,F1 分数提升了 0.024 2,与 IterMiUnet 相比,F1 分数提升 0.008 0;在 STARE 数据集上,与 MK-UNet 相比,F1 分数提升 0.003 2、ACC 提升 0.000 9,与 IterMiUnet 相比,F1 分数提升 0.003 5、ACC 提升 0.000 4。

整体来看,本文方法在 DRIVE 和 CHASEDB1 数据集上的 SE 与 F1 指标提升最为显著,在 STARE 数据集上也保持稳定提升,ACC、F1 指标上表现稳健,具备良好的场景适配性与泛化能力,有效缓解细血管漏检问题,满足临床眼底图像自动化分析的需求。




图9 不同模型在 DRIVE、CHASEDB1、STARE 数据集上的实验结果。

Fig. 9 Experimental results of different models on the DRIVE, CHASEDB1, and STARE datasets.

为综合衡量各网络轻量化程度与实时推理性能,统一采用尺寸 64×64 眼底图像块作为模型输入,测算并对比所有模型的参数量、浮点运算量与单图像块推理耗时,量化结果如表 3 所示。本文方法参数量 0.50 M、浮点运算量

0.29 G,模型规模处于轻量区间,但受级联多阶段运算影响,单图像块推理耗时 8.82 ms,推理速度略慢于 DenseUNet、EDAE-Net 两类大参数量模型。综合轻量化与推理速度表现较为均衡。

表 2 不同方法在 DRIVE、STARE 和 CHASE_DB1 数据集上的定量评估结果对比
Tab. 2 Quantitative comparison of different methods on DRIVE, STARE and CHASE_DB1 datasets

Methods	Year	DRIVE				
		ACC	SE	SP	F1	IOU
UNet ^[8]	2015	0.953 2	0.785 6	0.977 6	0.810 4	0.681 2
DenseUNet ^[31]	2019	0.953 5	0.790 5	0.977 3	0.812 3	0.683 9
AAU-Net ^[9]	2023	0.954 6	0.789 5	0.978 7	0.815 7	0.688 8
IterMiUnet ^[16]	2023	0.955 4	0.797 3	0.979 3	0.822 3	0.698 3
EDAE-Net ^[32]	2024	0.954 3	0.801 6	0.976 5	0.817 1	0.690 6
MK-UNet ^[33]	2025	0.955 1	0.781 2	0.980 4	0.815 7	0.688 7
Proposed	—	0.956 1	0.815 4	0.976 6	0.825 7	0.702 2
Methods	Year	STARE				
		ACC	SE	SP	F1	IOU
UNet ^[8]	2015	0.959 8	0.754 5	0.985 9	0.808 9	0.679 1
DenseUNet ^[31]	2019	0.960 5	0.766 6	0.985 1	0.813 8	0.686 1
AAU-Net ^[9]	2023	0.960 8	0.774 5	0.984 5	0.816 8	0.690 4
IterMiUnet ^[16]	2023	0.962 3	0.783 0	0.986 0	0.827 2	0.705 4
EDAE-Net ^[32]	2024	0.947 7	0.850 1	0.960 1	0.785 7	0.647 0
MK-UNet ^[33]	2025	0.959 4	0.775 3	0.982 7	0.811 5	0.682 8
Proposed	—	0.963 6	0.833 1	0.979 5	0.835 7	0.715 0
Methods	Year	CHASE_DB1				
		ACC	SE	SP	F1	IOU
UNet ^[8]	2015	0.964 8	0.756 9	0.990 6	0.826 2	0.703 9
DenseUNet ^[31]	2019	0.965 5	0.760 7	0.990 9	0.829 5	0.708 6
AAU-Net ^[9]	2023	0.962 3	0.775 2	0.985 5	0.819 6	0.694 3
IterMiUnet ^[16]	2023	0.965 9	0.767 7	0.990 5	0.832 6	0.713 2
EDAE-Net ^[32]	2024	0.964 3	0.755 9	0.990 1	0.823 7	0.700 2
MK-UNet ^[33]	2025	0.965 4	0.782 7	0.988 1	0.832 9	0.713 6
Proposed	—	0.966 3	0.779 6	0.989 3	0.836 0	0.717 7

表 3 各方法参数量、浮点运算量与推理耗时
Tab.3 FLOPs, parameters and inference time across methods

Methods	Year	Params/M	FLOPs/G	Time/ms
UNet ^[8]	2015	34.53	4.08	3.53
DenseUNet ^[31]	2019	7.55	8.03	7.40
AAU-Net ^[9]	2023	6.79	1.51	10.35
IterMiUnet ^[16]	2023	0.28	0.78	9.89
EDAE-Net ^[32]	2024	35.54	3.96	7.34
MK-UNet ^[33]	2025	0.45	0.08	8.95
Proposed	—	0.50	0.29	8.82

3.6 消融实验

为验证 PGSA、WSP 模块对视网膜血管分割性能的影响,本文在三个公开数据集的测试集上

开展消融实验,以无 PGSA 和 WSP 的模型为基线,通过逐步添加模块分析各组件对分割性能的贡献,评估指标包括 ACC、SE、SP 和 F1 分数。结果如表 4 所示,在 DRIVE 数据集上,单独加入 SA 模块可使 SE 提升 0.037 3,同时引入 PGSA 和 WSP 后,SE 提升至 0.547 6,F1 分数最高且达到 0.595 2;在 STARE 数据集上,PGSA 和 WSP 都加入的模型相比基准模型,ACC 和 F1 分数分别提升了 0.000 5 和 0.009 6;在 CHASE_DB1 数据集上,完整模型相较于基准模型,SE 和 F1 分数分别提升了 0.077 3 和 0.045 7。
综合消融实验结果表明,本文完整模型在三个公开数据集上的 SE 和 F1 分数显著提升,其他各项指标均得到明显改善,验证了两模块的有效

性与协同增益。

为进一步验证本文方法在细小血管分割上的优势,对关键区域进行局部放大分析结果如图 10 所示。图中展示了三个数据集的原始图像、真实标签、IterMiUnet 分割结果以及本文方法分割结果及其局部放大。红框标记区域聚焦于细小脆弱血管的分割细节。

从局部放大结果可以看出,IterMiUnet 在处理细小血管时虽然通过多尺度迭代提升了分割精度,但在视盘区域和低对比度区域的细小血管

检测上仍有不足,部分血管边缘不够清晰,存在明显的断裂现象。相比本文方法的分割结果在细小血管的连续性和边缘清晰度上表现更优,能够更准确地捕捉血管的分支结构,减少断裂和漏检,与真实标签的吻合度更高。

局部放大的可视化结果进一步验证了消融实验的定量分析结论,表明细小血管分割模型能够显著提升模型对细小血管的分割性能,为视网膜血管分割任务提供了更可靠的解决方案。

表 4 不同数据集的消融实验结果
Tab. 4 Ablation study results on different datasets

Dataset	PGSA	WSP	ACC	SE	SP	F1
DRIVE	×	×	0.955 3	0.503 6	0.984 2	0.575 6
	×	√	0.954 9	0.540 9	0.981 4	0.590 4
	√	√	0.955 2	0.547 6	0.981 2	0.595 2
STARE	×	×	0.966 5	0.580 3	0.987 5	0.641 5
	×	√	0.966 5	0.583 6	0.987 4	0.642 8
	√	√	0.967 0	0.594 6	0.987 3	0.651 1
CHASE_DB1	×	×	0.981 5	0.395 1	0.996 6	0.516 8
	×	√	0.981 3	0.469 2	0.994 4	0.556 2
	√	√	0.981 6	0.472 4	0.994 7	0.562 5




图 10 消融实验结果可视化
Fig. 10 Visualization of ablation experiment results

4 结 论

本文聚焦视网膜微细血管分割难题,构建

融合小波空间先验与不确定性引导的双分支分割网络。粗分割分支负责捕捉全局血管结构轮廓,细血管分支采用密集连接轻量化网络,引入

小波模块强化细血管边缘高频特征。借助粗分割概率不确定性引导模块聚焦难分割区域,通过温度缩放与背景抑制的融合策略,自适应融合双分支分割结果。在 DRIVE、STARE、CHASE_DB1 数据集测试,Acc 分别为 0.956 1、

0.963 6、0.966 3;F1 值分别为 0.825 7、0.836 0、0.835 7。有效改善血管断裂、漏检及伪影干扰问题,血管细节与连续性保留效果良好,整体架构可灵活迁移至其他分割模型,以提升细血管分割质量。

参 考 文 献:

- [1] DAS S, CHAKRABORTY S, MISHRA M, *et al.* Assessment of retinal blood vessel segmentation using U-Net model: A deep learning approach[J/OL]. *Franklin Open*, 2024, 8: 100143. DOI: <https://doi.org/10.1016/j.fraope.2024.100143>.
- [2] SONI T, GUPTA S, KUMAR K S. Exploring Retinal Vessel Segmentation: Deep Learning Models and Their Applications [C/OL]//2025 3rd International Conference on Advancement in Computation & Computer Technologies (InCACCT). 2025: 715-719. DOI:10.1109/InCACCT65424.2025.11011437.
- [3] 张光华, 杨阳, 徐国华. 无源多领域自适应糖尿病视网膜病变分类方法[J/OL]. *液晶与显示*, 2025, 40(7): 1080-1091. DOI:10.37188/CJLCD.2025-0024.
ZHANG G H, YANG Y, XU G. Unsupervised source-free multi-domain adaptive diabetic retinopathy classification [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(7): 1080-1091.
- [4] 范琳琳, 程韵, 田晓冰. 基于匹配滤波和形态学处理的视网膜血管分割[J]. *电脑知识与技术*, 2019, 15(17): 188-190.
FAN Ling-ling, CHENG Yun, TIAN Xiao-bing. Study on retinal vessel segmentation based on matched filtering and morphological processing [J]. *Journal of Computer Knowledge and Technology*, 2019, 15 (17): 188-190. (in Chinese)
- [5] WANG S, PAN J, ZHANG X, *et al.* Towards next-generation diagnostic pathology: AI-empowered label-free multiphoton microscopy[J/OL]. *Light: Science & Applications*, 2024, 13(1): 254-278. DOI: 10.1038/s41377-024-01597-w.
- [6] LUO M, JIANG M, SHASTRI B J, *et al.* Highly scalable machine vision enabled with meta-optics-based ultra-wide neural network[J/OL]. *eLight*, 2026, 6(1): 10-25. DOI:10.1186/s43593-026-00127-y.
- [7] LONG J, SHELHAMER E, DARRELL T. Fully Convolutional Networks for Semantic Segmentation[EB/OL]. *arXiv*, 2015[2026-04-25]. <http://arxiv.org/abs/1411.4038>. DOI:10.48550/arXiv.1411.4038.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation [Z/OL]. 2015. <https://arxiv.org/abs/1505.04597>.
- [9] CHEN G, LI L, DAI Y, *et al.* AAU-Net: An Adaptive Attention U-Net for Breast Lesions Segmentation in Ultrasound Images[J/OL]. *IEEE Transactions on Medical Imaging*, 2023, 42(5): 1289-1300. DOI: 10.1109/TMI.2022.3226268.
- [10] 郭昊虎, 高若谦, 葛明锋, 等. 基于特征图金字塔的冠脉造影图像血管分割方法[J]. *中国光学(中英文)*, 2024, 17(4): 971-981.
GUO Hao-hu, GAO Ruo-qian, GE Ming-feng, DONG Wen-fei, LIU Yan, ZHAO Xu-feng. Coronary artery angiography imagevessel segmentation method based on feature pyramid network[J]. *Chinese Optics*, 2024, 17(4): 971-981.
- [11] LIU Y, SHEN J, ZHAI C, *et al.* A Retinal Vessel Segmentation Network With Dual-Stage Network and Vessel Pixel Emendation [J/OL]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-17. DOI: 10.1109/TIM.2024.3500060.
- [12] QU Z, ZHUO L, CAO J, *et al.* TP-Net: Two-Path Network for Retinal Vessel Segmentation[J/OL]. *IEEE Journal of Biomedical and Health Informatics*, 2023, 27(4): 1979-1990. DOI:10.1109/JBHI.2023.3237704.
- [13] 张蓉蓉, 吕晓琪, 李菁等. 双路径编码和跨级解耦的视网膜血管分割[J/OL]. *光学精密工程*, 2025, 33(14):

- 2242-2261. DOI:10.37188/OPE.20253314.2242.
- ZHANG Rongrong, XiaoqiLÜ, LI Jing, *et al.* Dual-path encoding and cross-level decoupling for retinal vessel segmentation[J]. *Optics and Precision Engineering*, 2025, 33(14): 2242-2261.
- [14] WANG C, WANG Y, XU Q, *et al.* WaveRNet: Wavelet-Guided Frequency Learning for Multi-Source Domain-Generalized Retinal Vessel Segmentation [EB/OL]. *arXiv*, 2026 [2026-04-25]. <http://arxiv.org/abs/2601.05942>. DOI:10.48550/arXiv.2601.05942.
- [15] LI X, ZHOU H. WDM-UNet: A Wavelet-Deformable Gated Fusion Network for Multi-Scale Retinal Vessel Segmentation[J/OL]. *Sensors*, 2025, 25(15): 4840. DOI:10.3390/s25154840.
- [16] KUMAR A, AGRAWAL R K, JOSEPH L. IterMiUnet: a lightweight architecture for automatic blood vessel segmentation[J/OL]. *Multimedia Tools and Applications*, 2023, 82(28): 43207-43231. DOI:10.1007/s11042-023-15433-7.
- [17] DUTTA P, MITRA S, ROY S K. Wavelet-infused convolution-transformer for efficient segmentation in medical images[J/OL]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2025, 55(5): 3326-3337. DOI: 10.1109/TSMC.2025.3539573.
- [18] LIANG M, HAO J, HOU H, *et al.* WMFU-net: multi-scale wavelet mamba network and adaptive fusion for retinal vessel segmentation [J/OL]. *Biomedical Signal Processing and Control*, 2026, 121: 110295. DOI: 10.1016/j.bspc.2026.110295.
- [19] LI L, VERMA M, NAKASHIMA Y, *et al.* IterNet: retinal image segmentation utilizing structural redundancy in vessel networks[C/OL]//2020 IEEE winter conference on applications of computer vision (WACV). 2020: 3645-3654. DOI:10.1109/WACV45572.2020.9093621.
- [20] HU J, LIAO K, DINÇ N U, *et al.* Subwavelength imaging using a solid-immersion diffractive optical processor [J/OL]. *eLight*, 2024, 4(1): 8-27. DOI:10.1186/s43593-024-00067-5.
- [21] SZEGEDY C, VANHOUCKE V, IOFFE S, *et al.* Rethinking the Inception Architecture for Computer Vision [EB/OL]. *arXiv*, 2015[2026-04-25]. <http://arxiv.org/abs/1512.00567>. DOI:10.48550/arXiv.1512.00567.
- [22] GUO C, PLEISS G, SUN Y, *et al.* On Calibration of Modern Neural Networks[EB/OL]. *arXiv*, 2017[2026-04-25]. <http://arxiv.org/abs/1706.04599>. DOI:10.48550/arXiv.1706.04599.
- [23] STAAL J, ABRAMOFF M D, NIEMEIJER M, *et al.* Ridge-based vessel segmentation in color images of the retina [J/OL]. *IEEE Transactions on Medical Imaging*, 2004, 23 (4) : 501-509. DOI: 10.1109/TMI.2004.825627.
- [24] 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/OL]. *Investigative Ophthalmology & Visual Science*, 2009, 50(5): 2004. DOI:10.1167/iovs.08-3018.
- [25] HOOVER A D, KOUZNETSOVA V, GOLDBAUM M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response[J/OL]. *IEEE Transactions on Medical Imaging*, 2000, 19(3): 203-210. DOI:10.1109/42.845178.
- [26] FABBRI R, FONTOURA COSTA LDA, TORELLI J C, *et al.* 2D euclidean distance transform algorithms: a comparative survey[J/OL]. *ACM Computing Surveys*, 2008, 40: 2:1-2:44. DOI:10.1145/1322432.1322434.
- [27] 巫志辉, 王立忠, 梁晋, 等. 面向机械零件三角网格模型自动配准中增强特征的分割方法[J]. *中国光学(中英文)*, 2024, 17(5): 1112-1124.
- WU Zhi-hui, WANG Li-zhong, LIANG Jin, GONG Chun-yuan, ZHU Feng, CHANG Zhi-wen, Jian-ningXÜ. Segmentation method for enhanced features in automatic registration of triangular mesh model of mechanical parts [J]. *Chinese Optics*, 2024, 17(5): 1112-1124.
- [28] 张书赫, 曹良才. 基于数字衍射的单幅眼底图像增强[J/OL]. *光学精密工程*, 2024, 32(15): 2429-2438. DOI: 10.37188/OPE.20243215.2429.
- ZHANG Shuhe, CAO Liangcai. Digital diffraction method for single retinal image enhancement [J]. *Optics and Precision Engineering*, 2024, 32(15): 2429-2438.
- [29] LV N, XU L, CHEN Y, *et al.* TCDDU-Net: combining transformer and convolutional dual-path decoding U-Net

- for retinal vessel segmentation [J/OL]. *Scientific Reports*, 2024, 14 (1) : 25978. DOI: 10.1038/s41598-024-77464-w.
- [30] 盖俊帅, 马玉婷, 张运海, 等. 用于眼底视网膜图像的去雾状杂散光算法[J/OL]. *液晶与显示*, 2024, 39(8): 1070-1078. DOI:10.37188/CJLCD.2023-0289.
- GAI Junshuai, MA Yuting, ZHANG Yunhai, *et al.* Dehazing stray light algorithm for fundus retinal image[J]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 39(8): 1070-1078.
- [31] ZHOU Y, CHANG H, LU X, *et al.* DenseUNet: improved image classification method using standard convolution and dense transposed convolution[J/OL]. *Knowledge-Based Systems*, 2022, 254: 109658. DOI: 10.1016/j.knosys.2022.109658.
- [32] LI J, GAO G, YANG L, *et al.* A retinal vessel segmentation network with multiple-dimension attention and adaptive feature fusion [J/OL]. *Computers in Biology and Medicine*, 2024, 172: 108315. DOI: 10.1016/j.combiomed.2024.108315.
- [33] RAHMAN M M, MARCULESCU R. MK-UNet: Multi-kernel Lightweight CNN for Medical Image Segmentation [EB/OL]. *arXiv*, 2025 [2026-04-25]. <http://arxiv.org/abs/2509.18493>. DOI: 10.48550/arXiv.2509.18493.

作者简介:



常汇谈,男,硕士研究生,2022年于河南大学获得学士学位,主要从事图像处理和深度学习方面的研究。
E-mail: changht_321@163.com



马 瑜,男,博士,教授,2013年于西北工业大学获得博士学位,主要从事计算机视觉和模式识别方面的研究。
E-mail: mayu95@163.com