

· 实验研究 ·

眼底图像视杯和视盘自动分割与杯盘比计算系统的构建及其在青光眼筛查中的应用

吕晓轩¹ 杨阳¹ 赵佳妮¹ 俞秋丽² 万程³¹南京航空航天大学, 南京 211106; ²南京医科大学第二附属医院眼科, 南京 210003; ³南京航空航天大学深圳研究院, 深圳 518057

通信作者: 万程, Email: wanch@nuaa.edu.cn

【摘要】 目的 构建基于深度学习的自动化分析系统, 实现眼底图像中视杯与视盘的精确分割及垂直杯盘比 (CDR) 自动测量, 用于慢性青光眼早期风险评估与筛查。 **方法** 构建的自动化分析系统包括双重编码注意力 U 型网络 (DCoAtUNet) 视杯与视盘分割模型、条件随机场 (CRF) 后处理模块以及基于分割结果的 CDR 测量与青光眼筛查模块, 以提升视杯与视盘边界检测精度和测量稳定性。采用 Drishti-GS 数据集评估该系统性能, 将数据集按 1:1 分为训练集和测试集。采用 Dice 系数与交并比 (IoU) 等指标量化分割精度与区域一致性, 同时以准确率、精确度、召回率和 F1 值评价青光眼筛查的诊断效能。 **结果** DCoAtUNet 结合 CRF 后处理的模型在视盘和视杯分割的 Dice 系数分别达到 0.976 0 和 0.908 1, 对应的 IoU 值分别为 0.953 4 和 0.837 9, 表明模型在边界识别与区域重叠方面均具备较高精度与稳定性。在青光眼筛查任务中, 该系统的准确率、精确度、召回率和 F1 值分别为 0.843 1、0.840 9、0.973 7 和 0.902 4, 显示出良好的诊断敏感性与准确性。 **结论** DCoAtUNet+CRF 模型通过融合高精度分割与自动测量策略, 显著提升了 CDR 评估的准确性与稳定性, 可在青光眼早期筛查中有效辅助发现高危个体, 在临床辅助诊断流程中具有应用潜力。

【关键词】 青光眼; 计算机辅助诊断; 图像分割; 深度学习; 杯盘比**基金项目:** 深圳市自然科学基金基础研究面上项目 (JCYJ20240813152705008)

DOI: 10.3760/cma.j.cn115989-20250609-00191

Construction of an automatic optic disc and cup segmentation and cup-to-disc ratio calculation system for ocular fundus image and its application in glaucoma screening

Lyu Xiaoxuan¹, Yang Yang¹, Zhao Jiani¹, Yu Qiuli², Wan Cheng³¹Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China; ²Department of Ophthalmology, The Second Affiliated Hospital of Nanjing Medical University, Nanjing 210003, China; ³Nanjing University of Aeronautics and Astronautics Shenzhen Research Institute, Shenzhen 518057, China

Corresponding author: Wan Cheng, Email: wanch@nuaa.edu.cn

[Abstract] Objective To develop a deep learning-based automated analysis system for precise segmentation of the optic cup and disc in fundus images and automatic measurement of the vertical cup-to-disc ratio (CDR) for early risk assessment and screening of chronic glaucoma. **Methods** The proposed automated system comprised three modules: a dual coding-attention U-net (DCoAtUNet) segmentation network for optic cup and disc segmentation, a conditional random field (CRF) post-processing module, and a CDR measurement and glaucoma screening module based on the segmentation results. The system was designed to enhance boundary detection accuracy and measurement stability and its performance was evaluated on the publicly available Drishti-GS dataset. The dataset was divided into a training set and a test set in a 1:1 ratio. Dice coefficient and intersection over union (IoU) were used to quantify segmentation accuracy and regional consistency, while accuracy, precision, recall, and F1-score were employed to assess glaucoma screening performance. **Results** The DCoAtUNet combined with CRF post-processing achieved Dice coefficients of 0.976 0 for the optic disc and 0.908 1 for the optic cup, with corresponding IoU values of 0.953 4 and 0.837 9, demonstrating high segmentation precision and stability in boundary identification and region overlap. In glaucoma screening, the system achieved an accuracy of 0.843 1, precision of 0.840 9, recall of 0.973 7, and F1-score of

0.902 4, indicating good diagnostic sensitivity and accuracy. **Conclusions** By integrating high-precision segmentation and automated measurement strategies, the DCoAtUNet+CRF model significantly improves the accuracy and stability of CDR evaluation. It effectively assists in identifying high-risk individuals during early glaucoma screening and shows strong potential for clinical application in computer-aided diagnosis workflows.

[Key words] Glaucoma; Computer-aided diagnosis; Image segmentation; Deep learning; Cup-to-disc ratio

Fund program: Shenzhen Natural Science Foundation Basic Research General Project (JCYJ20240813152705008)

DOI:10.3760/cma.j.cn115989-20250609-00191

青光眼是全球第二大致盲眼病,预计到 2040 年患病人数将增至 1.18 亿^[1-2]。青光眼典型表现为视神经出现进行性损伤,引起视野缺损和视力持续降低^[3-4]。慢性青光眼早期症状不易察觉,常被称为视力隐形杀手,所以不少患者易错过最佳治疗时机^[5]。研究表明,早期精准诊断与干预可显著降低致盲风险^[6]。因此,开展有效的早期筛查对防止不可逆视力损伤意义重大。临床上,眼压升高是青光眼的重要预警信号^[7],但仅凭眼压难以准确评估病情。视神经头部结构参数,尤其是杯盘比(cup-to-disc ratio, CDR),是评估青光眼风险的重要量化指标^[8-9]。在流行病学研究和临床早期筛查工作中,CDR 超过 0.6 常被视为提示青光眼高风险的参考阈值。传统基于人工分割的 CDR 测量受操作者经验影响较大,易引入主观误差^[10],亟需采用智能化方法实现视杯与视盘精确分割,提高 CDR 测量的稳定性和准确性,提升青光眼高危人群的筛查效率。

近年来,基于深度学习的分割方法取得了显著进展,如融合全局与局部特征的多流网络^[11]、引入注意力机制的 U-Net 改进模型^[12-13]、多任务共享参数结构^[14]以及结合 Transformer 的特征融合框架^[15-18]。尽管近年来基于深度学习的视杯与视盘分割方法在性能上取得了显著提升,但在处理边界模糊、形态复杂以及受病理变化影响较大的眼底图像时,现有模型在鲁棒性与泛化能力方面仍存在不足。这些局限在临床青光眼早期筛查中可能影响诊断稳定性和可信度。为应对上述挑战,本研究提出了一种基于深度学习的自动化青光眼诊断系统,融合双重编码解码结构的分割模型、条件随机场(conditional random field, CRF)后处理方法,以及基于分割结果的自动 CDR 测量模块,通过增强特征提取能力与细化分割处理,提升模型对视杯与视盘区域的识别与分割精度,为青光眼的诊断提供有力的量化指标。

1 方法

1.1 数据集

本研究基于 Drishti-GS 数据集进行训练和验证。Drishti-GS 数据集是一个专门为视神经头分割任务设计的视网膜图像数据集,主要用于青光眼的自动评估研究。本研究使用的 Drishti-GS 数据集共包含 101 幅眼底图像,其中包括 31 幅正常眼图像和 70 幅青光眼患者眼图像。按照 1:1 的比例将其划分为训练集(50 幅图像)和测试集(51 幅图像),并在每个子集中保持正常与青光眼图像的比例一致,其中训练集包含 15 幅正常图像和 35 幅青光眼图像,测试集包含 16 幅正常图像和 35 幅青光眼图像。样本划分采用分层随机抽样方式,以确保训练集与测试集在病理特征分布上的一致性。训练集用于模型训练与参数优化,测试集用于性能评估与结果验证。

1.2 青光眼诊断系统构建

本研究构建了一个基于深度学习的青光眼诊断系统,其架构见图 1。该系统由视杯和视盘分割模块、后处理模块和测量模块 3 个部分组成,旨在实现从眼底图像处理到病理参数计算的全流程自动化分析。首先,视杯和视盘分割模块负责从眼底图像中精准提取视杯和视盘区域,生成高质量的分割结果。随后,后处理模块对分割结果进行优化,增强分割边界的连续性




图 1 青光眼诊断系统架构 DCoAtUNet; 双重编码注意力 U 型网络; CDR: 杯盘比

Figure 1 Glaucoma diagnosis system architecture DCoAtUNet; dual coding-attention U-net; CDR: cup-to-disc ratio

与一致性,从而消除分割过程中可能产生的噪声和误差。在此基础上,测量模块利用优化后的分割结果,精确计算 CDR。

1.2.1 CoAtUNet 模型结构 卷积神经网络(convolutional neural network, CNN)在捕捉空间信息方面表现出色;但它对全局依赖特征的学习能力有限,从而在处理复杂目标重建任务时表现不足。Transformer 通过自注意力机制能够建立长距离依赖关系,有效捕获图像的全局特征;然而,其在细节特征提取方面相对较弱,导致其在处理局部细节时存在一定局限性。卷积注意力网络(convolutional attention network, CoAtUNet)是一种融合 CNN 和 Transformer 优势的混合架构模型^[19]。该模型采用分阶段特征建模设计,通过整合 CNN 的局部特征提取特性和自注意力机制的局部依赖建模特性,逐步实现从局部特征到全局特征的建模,从而在复杂任务中展现出良好的适应性和鲁棒性。基于这一设计,本研究构建了名为 CoAtUNet 的分割模型(图 2)。CoAtUNet 采用 U 型网络架构,编码器部分通过逐步降采样,在使用步长为 2 的 3×3 卷积完成初次下采样,通过移动倒残差卷积块结构首层步长为 2 的卷积完成降采样,通过步长为 2 的卷积和线性投影压缩与聚合更深层次的特征,实现对输入图像的特征提取,捕获多层次的语义信息。解码器则通过逐级上采样方法恢复图像分辨率,并通过跳跃连接将编码器提取的特征融合进解码过程。该 U 型架构不仅有效恢复了图像空间分辨率,还在分割过程中保留了视杯与视盘边界的细节信息,从而提升模型在分割任务中的准确性。

在卷积模块的设计中,本研究采用了移动倒残差卷积块结构以实现高效的特征提取,并对其在上采样和下采样阶段进行优化设计。在上采样阶段,本研究首先通过 1×1 卷积调整特征通道数,以匹配目标特征空间的维度要求。随后,利用步长为 2 的深度可分离卷积对输入特征图进行空间分辨率的缩减,从而实现上采样操作。为确保残差路径中的特征能够与经过缩放的主分支特征实现有效融合,本研究在残差路径中先通过 1×1 卷积匹配通道数,确保与主分支输出特征维度的一致性,随后引入最大池化操作以调整特征图的分辨率(图 3A)。在下采样阶段,为实现空间分辨率的翻倍处理,本研究主路径与残差路径均采用 3×3 卷积核、步长为 2 的转置卷积实现空间分辨率的翻倍处理(图 3B)。转置卷积不仅有效恢复了特征图的空间分辨率,还在参数学习中增强了下采样阶段的特征表达能力。




图 2 CoAtUNet 模型架构
Figure 2 CoAtUNet model architecture

在 Transformer 模块中,上采样通过线性扩展、多头自注意力和前馈网络的组合实现特征分辨率的翻倍。输入特征通过 3×3 卷积调整通道数,将它按照空间维度展平,通过线性层将展平后的特征扩展至原始分辨率的 4 倍实现特征图的上采样,将扩展后的特征图输入到 Transformer 模块中,模块中的相对位置注意力能够捕捉长距离的特征交互。扩展后的特征与注意力结果经残差连接融合,经过前置网络逐点增强,输出高分辨率且具有丰富的语义信息的特征图。

1.2.2 杯盘联合分割模型 尽管 CoAtUNet 可提取视杯特征,但其单一编解码器设计未能对视杯与视盘在空间关系上的复杂性进行建模,导致视杯分割精度下降。本研究创新性提出双重编码 CoAtUNet(dual CoAtUNet, DCoAtUNet),以增强分割精度和鲁棒性(图 4)。

DCoAtUNet 架构融合了 U 型架构和多尺度特征建模的优势,通过双重编码-解码设计实现了视杯与视盘特征的有效分离。第一阶段的编码-解码模型基于 CoAtUNet 的 U 型结构,专注于视盘分割任务,能够直接输出高精度的视盘分割结果,确保视盘边界的清晰性和位置的准确性。同时,为增强视杯特征提取能力,该阶段还生成了引导性特征图,旨在识别对视杯区域具有正向激励作用的图像区域。引导性特征图与原始图像进行元素级相乘,作为第二阶段编码-解码的输入。

在第二阶段中,DCoAtUNet 对视杯分割任务进行了针对性的优化。该解码部分采用特征金字塔结构,通过多尺度特征融合有效整合来自不同分辨率的特征信息,增强模型对视杯细节感知能力。该模块通过以下 2 个关键步骤实现多尺度特征融合:首先通过卷积层提取不同尺度的特征,采用 1×1 卷积调整特征图的通道数,使得各尺度特征具有一致的通道数;然后利用自顶向下的路径将较高分辨率的特征上采样,与低分辨率特征进行融合。上采样操作采用最近邻插值,恢复特征图的空间分辨率。融合后的特征图经过 3×3 卷积进一步处理整合特征信息。

1.2.3 后处理模块 本研究在 DCoAtUNet 的基础上引入了 CRF 作为后处理手段,结合初步分割结果和原始图像信息细化分割边界,进一步提升分割精度和稳定性^[20]。分割视杯和视盘时,由于视杯嵌套于视盘内部,二者的边界通常较为模糊,特别在病变区域或图像质量较差的情况下,这种模糊性往往导致分割结果边界不清或区域混淆。CRF 的核心机制在于通过构建像素间的上下文依赖关系,优化数据项和平滑项的贡献。CRF 将分割模型生成的概率图作为数据项来刻画每个像素属于视杯或视盘的可能性,平滑项则通

过高斯核函数建模像素间的相似性,综合考虑颜色、纹理和空间位置等多维特征,消除分割中的噪声和误差。特别是在视杯和视盘的重叠区域,CRF 的平滑项优化机制能够有效减少类别混淆,为后续病理参数测量提供了可靠的数据支持。




图3 移动倒残差卷积块特征提取图 A:上采样 B:下采样 C_i 和 C_o 分别代表输入和输出通道数, H 和 W 分别代表输入特征图的高和宽

Figure 3 Mobile inverted residual convolution feature extraction diagram A: Upsampling B: Downsampling C_i and C_o represented the number of input and output channels, respectively, while H and W denoted the height and width of the input feature map, respectively




图4 DCoAtUNet 模型结构

Figure 4 DCoAtUNet model architecture

1.2.4 测量模块 测量模块以 CRF 优化后的视杯和视盘的分割结果为基础,通过计算垂直方向的直径比值,为青光眼的诊断提供关键量化指标,其计算公式为 $CDR = \frac{V_{cup}}{V_{disc}}$,其中 V_{cup} 和 V_{disc} 分别代表视杯和视盘的垂直直径。测量模块从分割结果中提取视杯和视盘的垂直直径,然后通过比值计算得出垂直 CDR 值。当 CDR 值超过 0.6 时,被视为青光眼的潜在诊断标志。

1.3 评价方法

为了对测量结果进行定量分析,本研究采用 Dice 系数,交并比(intersection over union, IoU)作为主要评估指标。Dice 系数是一种常用的相似性度量,能够有效评估 2 个样本之间的重叠程度。其计算公式为 $Dice\ 系数 = \frac{2|A \cap B|}{|A| + |B|}$,其中, A 表示预测的分割区域, B 表示真实的标注区域。Dice 系数值为 0~1,值越接近 1 表示预测结果与真实标注的重叠程度越高。IoU 同样是评估分割结果的重要指标,其计算方式为预测区域与真实区域的交集与并集的比值,公式为 $IoU = \frac{|A \cap B|}{|A \cup B|}$,IoU 值为 0~1,值越高表示模型的分割效果越好。

为全面评估模型在青光眼筛查任务中的分类性能,采用准确率、精确度、召回率和 F1 值作为主要评价指标。其中,准确率反映模型整体预测正确的比例;精确度衡量被模型判定为青光眼的样本中实际为阳性的比例;召回率反映所有真实青光眼样本中被模型正确识别的比例;F1 值为精确度与召回率的调和平均,用于综合衡量模型在检测灵敏度与判别准确性之间的平衡。对于视杯或视盘分割任务,真阳性率(true positive, TP)记为正确分割的像素数;假阳性率(false positive, FP)记为被错误分割为目标的像素数;真阴性率(true negative, TN)记为被正确判定为非目标的像素数;假阴性率(false negative, FN)记为漏分割的目标像素数。各评价指标计算公式如下:准确率 = $\frac{TP+TN}{TP+TN+FP+FN}$ 、精确度 = $\frac{TP}{FP+TP}$ 、召回率 = $\frac{TP}{TP+FN}$ 、F1 值 = $\frac{2 \times 精确度 \times 召回率}{精确度 + 召回率}$ 。

为了进一步评估模型在青光眼诊断任务中的性能,本研究对分割结果进行了受试者工作特征(receiver operating characteristic, ROC)曲线及曲线下面积(area under the curve, AUC)分析。ROC 曲线用于评估模型在不同阈值下的敏感性与特异性变化,AUC 则用于量化模型整体的诊断能力。

本研究使用 Python 3.9 环境下的 scikit-learn 库进行 ROC 曲线绘制和 AUC 计算。通过对分割结果生成的 CDR 进行阈值扫描,构建 ROC 曲线并计算 AUC,以客观评估模型的青光眼判别能力。

2 结果

2.1 消融实验

DCoAtUNet 结合 CRF 的模型在视盘与视杯分割任务中均表现出优于 CoAtUNet 的性能。其中, DCoAtUNet 在视盘和视杯分割的 Dice 系数上分别较 CoAtUNet 提升约 0.5%和 0.6%(表 1),说明双重编码解码结构在特征表达与边界刻画方面具有更强的能力。DCoAtUNet 结合 CRF 后处理后,模型分割视盘和视杯的 Dice 系数提升至 0.976 0 和 0.908 1,对应的 IoU 分别达到 0.953 4 和 0.837 9,表明 CRF 能够有效优化边界平滑性与区域一致性。综上, DCoAtUNet + CRF 模型在多项指标上均取得最佳表现,表明该方法在视杯与视盘精确分割任务具有较高的准确性和稳定性。

表 1 不同模型间的定量性能指标对比 Table 1 Quantitative performance comparison among different models				
模型	Dice 系数		IoU	
	视盘	视杯	视盘	视杯
CoAtUNet	0.969 4	0.901 0	0.941 1	0.828 7
DCoAtUNet	0.974 8	0.907 1	0.951 0	0.837 1
DCoAtUNet+CRF	0.976 0	0.908 1	0.953 4	0.837 9

注:CoAtUNet:卷积注意力网络;CRF:条件随机场;IoU:交并比
Note:CoAtUNet:convolutional attention network;CRF:conditional random field;IoU:intersection over union

为更直观地比较不同模型在视杯和视盘分割任务中的性能,本研究对分割结果进行了可视化分析。图 5 展示了各模型在视盘分割任务中的表现,视盘是眼底图像中具有较为显著特征的结构,大多数模型能够对其实现较高精度分割。然而模型受到血管特征的干扰导致视盘区域被错误扩展,CoAtUNet 分割结果会受到干扰。DCoAtUNet 在相同场景下的分割结果能够有效避免这种问题,边界更为规整意味着解码器的设计显著提升模型在复杂背景下的抗干扰能力。DCoAtUNet 引入 CRF 后,分割结果边界细节进一步优化,证明后处理策略在细化模型分割能力方面的价值。在视杯分割中,CoAtUNet 虽然能够捕获大部分视杯区域,但在处理复杂边界时表现较为粗糙。DCoAtUNet 和 DCoAtUNet+CRF 的分割结果则有显著提升(图 6)。




图5 不同模型对视盘的分割结果 CoAtUNet 的视盘分割结果中,右下角出现了明显的形状异常,而 DCoAtUNet 和 DCoAtUNet+CRF 视盘分割边界规整 CoAtUNet:卷积注意力网络;DCoAtUNet:双重编码 CoAtUNet;CRF:条件随机场

Figure 5 Optic disc segmentation results across different models In the CoAtUNet segmentation results, a noticeable shape anomaly appeared in the lower right corner, while the segmentation boundaries for DCoAtUNet and DCoAtUNet + CRF were regular CoAtUNet: convolutional attention network; DCoAtUNet: dual CoAtUNet; CRF: conditional random field




图6 不同模型对视杯的分割结果 CoAtUNet 在处理复杂视杯边界时表现较为粗糙, DCoAtUNet 和 DCoAtUNet+CRF 的分割结果较 CoAtUNet 有了显著提升 CoAtUNet:卷积注意力网络;DCoAtUNet:双重编码 CoAtUNet;CRF:条件随机场

Figure 6 Segmentation results of the optical cup by different models CoAtUNet exhibited relatively coarse segmentation when handling complex optic cup boundaries, while DCoAtUNet and DCoAtUNet + CRF demonstrated significantly improvement CoAtUNet: convolutional attention network; DCoAtUNet: dual CoAtUNet; CRF: conditional random field

2.2 模型对比

为了全面比较不同模型在视盘和视杯分割任务中的性能,本研究对多种模型进行评估,不同模型在分割任务中的表现存在显著差异(表2)。传统 U-Net 模型在视盘分割任务中的表现较为出色,但在视杯分割任务中相对较弱, Dice 系数仅为 0.888 7, U-Net 在处理视杯区域时受限于边界模糊和区域混淆问题,难以充

分捕捉视杯的复杂特征。引入 ResNet34 和 ResNet50 作为 U-Net 编码器,视杯分割性能有所改善,精确度和召回率更加均衡,反映更深层次编码器在特征提取能力上的优势。U-Net++ 和 EfficientNet+U-Net 在视杯分割任务中并未显著突破性能瓶颈,精确度和召回率存在一定程度的波动。PSPNet 在视盘分割任务中召回率表现良好,但其 Dice 系数和精确度相对较低,说明在捕捉全局特征时牺牲了一定边界细节。本研究提出的 DCoAtUNet 在视盘和视杯分割任务中均展现了显著的性能提升,尤其是在视杯分割方面, Dice 系数达到 0.907 1。这一结果充分验证双重编码-解码结构在应对视杯与视盘重叠区域复杂性的有效性。引入 CRF 作为后处理模块进一步增强模型在视杯与视盘分割任务中的表现。

将预测结果与真实标注相减,可以对不同模型的分割误差进行直观的可视化。各模型视盘分割误差,通常集中在视盘边界或复杂背景区域。相比于其他模型,本研究构建的 DCoAtUNet + CRF 的误差分布最小,展现了其在视盘分割任务中的优越性能(图7)。

对视杯分割误差进行可视化分析, DCoAtUNet+CRF 的视杯分割误差区域呈现不连续分布趋势,这表明模型对视杯边界的预测具有较高的准确性。与其他模型相比, DCoAtUNet+CRF 模型在左侧区域的误差最小,进一步验证模型对视杯分割的稳定性(图8)。

2.3 青光眼筛查

本研究基于测试集中视杯与视盘的分割结果计算 CDR,并以 $CDR > 0.6$ 作为青光眼的潜在判定阈值,评估受试者青光眼风险。结果表明,本研究方法在青光眼诊断中的准确率为 0.843 1,精确度为 0.840 9,召回率达 0.973 7, F1 值为 0.902 4。

本研究进一步对青光眼诊断 ROC 曲线及 AUC 分析。青光眼诊断的 AUC 达 0.920,表明模型具有良好的区分能力。ROC 曲线直观呈现了不同 CDR 阈值(如 0.6、0.7、0.8)下灵敏度与特异性的动态变化:当

表 2 不同模型视杯和视盘分割性能对比
Table 2 Performance comparison of optic cup and disc segmentation among different models

模型	Dice 系数		精确度		召回率	
	视盘	视杯	视盘	视杯	视盘	视杯
U-Net	0.970 0	0.888 7	0.975 8	0.908 9	0.965 2	0.890 2
Resnet34+U-Net	0.970 6	0.889 3	0.977 0	0.901 2	0.965 3	0.900 6
Resnet50+U-Net	0.964 3	0.893 8	0.973 6	0.903 7	0.957 0	0.903 4
EfficientNet+U-Net	0.962 7	0.892 2	0.962 3	0.903 4	0.965 3	0.905 8
U-Net++	0.966 8	0.890 7	0.975 3	0.879 8	0.959 8	0.929 7
PSPNet	0.965 9	0.887 2	0.968 5	0.889 6	0.964 6	0.910 5
DCoAtUNet	0.974 8	0.907 1	0.974 4	0.899 2	0.971 8	0.928 7
DCoAtUNet+CRF	0.976 0	0.908 1	0.979 6	0.903 5	0.973 0	0.930 3

注:DCoAtUNet;双重编码-解码卷积注意力网络;CRF:条件随机场
Note:DCoAtUNet;dual convolutional attention network;CRF:conditional random field




图 7 各模型视盘区域分割误差 白色区域为模型分割视盘区域与真实标注的差值。不同模型视盘右下角均有明显的误差区域,DCoAtUNet+CRF 显示出最小的误差分布
DCoAtUNet;双重编码-解码卷积注意力网络;CRF:条件随机场
Figure 7 Optic disc segmentation error of each model The white regions indicated the difference between the model segmentation of the optic disc area and the ground truth annotations. All models exhibited noticeable error zones in the lower-right corner of the optic disc, with DCoAtUNet + CRF showing the smallest error distribution DCoAtUNet; dual convolutional attention network; CRF; conditional random field




图 8 各模型视杯区域分割误差 白色区域为模型分割视杯区域与真实标注的差值。与其他模型相比,DCoAtUNet+CRF 模型在左侧区域的误差最小 DCoAtUNet;双重编码-解码卷积注意力网络;CRF:条件随机场
Figure 8 Segmentation error in the cup region for each model The white regions indicated the difference between the model segmentation of the fundus cup area and the ground truth annotations. Compared to other models,the DCoAtUNet+CRF model exhibited the smallest error in the left region DCoAtUNet; dual convolutional attention network; CRF; conditional random field

阈值为 0.6 时,模型灵敏度达到 0.97,特异性为 0.53;将阈值提高至 0.7 后,灵敏度下降至 0.92,特异性提升至 0.73;继续增大阈值至 0.8 时,灵敏度降至 0.58,相应的特异性提高到 0.92(图 9A)。CDR 阈值在全范围(0~1,步长 0.01)内变化时,随着阈值的提高,灵敏度呈下降趋势,特异性逐渐上升(图 9B)。

3 讨论

本研究提出的基于深度学习的青光眼筛查系统在视盘和视杯分割以及垂直 CDR 计算任务中表现出优异的性能。为进一步验证所提模型的有效性,本研究将 DCoAtUNet+CRF 模型与近年来发表的多种主流视盘与视杯分割方法进行系统对比(表 3)。所有对比方法均在相同公开数据集 Drishti-GS 数据集上进行训练和评估,该比较具有较高的可比性和客观性。

通过与既往研究中所提方法进行对比,可以看出 DCoAtUNet+CRF 在分割性能上表现出显著优势,视盘和视杯 Dice 系数分别达到 0.976 0 和 0.908 1,均优于现有文献中报道的结果,这说明所提出的双重编解码结构能够有效融合卷积和自注意机制的特征表达能力,捕捉眼底图像中多层次的上下文信息,在边界模糊和结构复杂区域保持较高的分割鲁棒性。引入 CRF 的后处理模块进一步优化分割结果的边缘连续性和结构完整性,减少了误分割现象,为后续 CDR 精确计算奠定坚实基础。

在青光眼筛查方面,本研究基于分割结果实现 CDR 自动化计算,并以 CDR>0.6 作为青光眼高风险判定标准,与 Pawar 等^[37]提出的基于 CNN,诊断精确率为 0.837 8 的自动筛查模型相比,本研究通过优化分割结构和计算策略,将诊断精确率提升至 0.840 9。与现有基于视杯与视盘分割的青光眼诊断方法相比,本研究的性能表现出显著优势。这些结果充分表明,本方法在准确




图 9 青光眼诊断的 ROC 曲线及阈值动态变化分析图 A:青光眼诊断 ROC 曲线 B:阈值动态变化分析图 ROC:受试者工作特征;AUC:曲线下面积

Figure 9 ROC curve and dynamic threshold analysis chart for glaucoma diagnosis

A:ROC curve for glaucoma diagnosis B: Dynamic change analysis diagram of diagnostic threshold ROC:receiver operating characteristic;AUC:area under curve

表 3 本研究方法与现有方法性能对比
Table 3 Performance comparison between the method proposed in this study and existing methods

年份	作者	论文所提方法	Dice 系数	
			视盘	视杯
2021	Imtiaz 等 ^[21]	基于语义分割的方法	0.948 6	0.860 1
	Pachade 等 ^[22]	NENet	0.963 2	0.840 1
	Luo 等 ^[23]	BGA-Net	0.975 0	0.898 0
	Zhao 等 ^[24]	TAU	0.963 8	0.879 3
2022	Sun 等 ^[25]	GNAS-U2	0.969 5	0.876 9
	Liu 等 ^[26]	ECSD-Net	0.965 0	0.876 0
	Jiang 等 ^[27]	RSAP-Net	0.954 7	0.859 3
	Liu 等 ^[28]	GlauNet	0.970 1	0.895 9
2023	Sun 等 ^[29]	ResFPN-Net	0.975 9	0.896 1
	Tadisetty 等 ^[30]	优化的 U-Net 端到端网络	0.943 0	0.889 0
	Chen 等 ^[31]	RDR-Net	0.971 2	0.893 4
	Jiang 等 ^[32]	BEAC-Net	0.861 4	0.808 7
2024	Chen 等 ^[33]	MBG-Net	0.974 0	0.900 0
	Yu 等 ^[34]	LC-MANet	0.972 3	0.903 4
	Liu 等 ^[35]	增强型生成对抗网络	0.964 0	0.853 0
	Li 等 ^[36]	DDF-UDA	0.969 0	0.893 0
2025	本研究	DCoAtUNet+CRF	0.976 0	0.908 1

注:DCoAtUNet;双重编码卷积注意力网络;CRF:条件随机场

Note:DCoAtUNet;dual convolutional attention network;CRF:conditional random field

识别青光眼患者方面具备较高可靠性,能够有效降低漏诊风险。

在不同临床应用场景下,青光眼筛查的策略重点存在差异,在人群普筛阶段,更需关注模型的高灵敏度,尽可能发现潜在患者,在针对高危人群的进一步排查中,则应注重提高特异性以减少误诊。本研究通过 ROC 曲线与 AUC 的综合分析,为临床医生提供了阈

值选择与权衡的量化依据,使该方法能够根据不同筛查目标灵活调整判定策略,在多种临床应用场景中具备较高的实用性和推广潜力。

从临床意义上看,该系统实现了对青光眼筛查关键指标 CDR 的自动量化,不仅降低了人工评估的主观偏差,也提升了筛查的效率与一致性。这在基层医疗机构、体检中心以及眼科高负荷筛查场景中具有潜在应用价值,特别是在眼科专业人力资源匮乏地区,可显著减轻医生的工作负担,促进青光眼的早期发现和干预。

然而,本研究仍存在若干局限性。首先,双重编解码结构虽在特征提取上具备优势,但较高的计算复杂度与显存占用量限制了其在低性能硬件上的直接部署,可能影响在资源受限地区的推广。其次,CRF 后处理模块的参数依赖人工设定,缺乏自适应优化机制,在不同数据分布下需人工调节以维持最佳效果。此外,CDR 的准确计算高度依赖分割结果,当视杯或视盘边界因病变或图像噪声而模糊时,分割偏差可能导致 CDR 值波动,从而影响最终诊断决策的可靠性。尤其在临界病例或跨人群应用中,分割误差可能放大 CDR 测量偏差,降低模型在不同人群或不同临床场景下的稳定性。本研究的训练与验证数据集存在潜在偏倚:数据集来源有限,病例与对照样本比例可能不均衡且样本的疾病严重程度或合并病变情况具有局部局限性,这可能导致模型在特定场景适配性过强,在更广泛临床应用中出现性能波动。

针对上述问题,未来研究可从以下几个方向开展优化:(1)在分割网络中引入多尺度特征融合与边界注意力机制,以增强模型对模糊边界与局部细节的敏感性;(2)在 CDR 计算环节,尝试结合三维形态重建或曲面拟合算法,突破二维投影假设的限制,更真实反映视杯与视盘的立体结构特征;(3)通过网络轻量化设计与自动化超参数调整方法(如贝叶斯优化或强化学习),降低计算成本,提高模型在便携式设备与嵌入式平台上的可部署性;

(4)引入多中心、多模态数据集进行验证,以进一步评估系统在不同人群、成像条件及病程阶段下的泛化能力,减少数据偏倚带来的影响。青光眼初筛的诊断依据并非仅限于 CDR 这一单一指标,还包括眼压水平、视盘边缘形态异常及视网膜神经纤维层厚度变化等多维信息。未来研究可考虑将这些结构与功能性参数进行联合建模,实现更为全面和精准的青光眼风险评估。

本研究所提出的青光眼智能筛查系统在技术性能方面取得了显著提升,尤其在视杯和视盘分割精度及 CDR 自动化计算的稳定性上表现出较高水平。该系统的设计思路与实现框架为基于影像的青光眼智能筛查提供了一种可行方案。未来,随着模型结构的持续优化、算法自动化程度的提升及多场景适配性的增强,该系统有望在更广泛的临床应用中发挥作用,为人工智能在眼科青光眼早期辅助诊断领域的深入发展奠定基础。

利益冲突 所有作者声明不存在利益冲突

作者贡献声明 吕晓轩:实验设计、文章撰写及修改;杨阳:数据统计分析、制图;赵佳妮:数据集整理;俞秋丽:临床数据判读、诊断标准制定;万程:研究指导、论文审阅及定稿

参考文献

- [1] Iqbal S, Khan TM, Naveed K, et al. Recent trends and advances in fundus image analysis: a review [J]. Comput Biol Med, 2022, 151(Pt A): 106277. DOI: 10.1016/j.combiomed.2022.106277.
- [2] Tham YC, Li X, Wong TY, et al. Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis [J]. Ophthalmology, 2014, 121(11): 2081–2090. DOI: 10.1016/j.ophtha.2014.05.013.
- [3] 徐军, 陈强, 牛四杰. 青光眼视神经头参数与视网膜神经纤维层的相关性分析 [J]. 计算机辅助设计与图形学学报, 2017, (6): 977–983. DOI: 10.3969/j.issn.1003-9775.2017.06.001.
- Xu J, Chen Q, Niu SJ. Correlation between optic nerve head parameters and retinal nerve fiber layer in glaucoma [J]. J Comput Aided Des Comput Graph, 2017, (6): 977–983. DOI: 10.3969/j.issn.1003-9775.2017.06.001.
- [4] Flaxman SR, Bourne R, Resnikoff S, et al. Global causes of blindness and distance vision impairment 1990–2020: a systematic review and meta-analysis [J/OL]. Lancet Glob Health, 2017, 5(12): e1221–e1234 [2025-06-03]. https://pubmed.ncbi.nlm.nih.gov/29032195/. DOI: 10.1016/S2214-109X(17)30393-5.
- [5] Abdull MM, Chandler C, Gilbert C. Glaucoma, "the silent thief of sight": patients' perspectives and health seeking behaviour in Bauchi, northern Nigeria [J]. BMC Ophthalmol, 2016, 16: 44. DOI: 10.1186/s12886-016-0220-6.
- [6] Michelson G, Wärtges S, Hornegger J, et al. The papilla as screening parameter for early diagnosis of glaucoma [J]. Dtsch Arztebl Int, 2008, 105(34–35): 583–589. DOI: 10.3238/arztebl.2008.0583.
- [7] Moreno MV, Houriet C, Grounauer PA. Ocular phantom-based feasibility study of an early diagnosis device for glaucoma [J]. Sensors (Basel), 2021, 21(2): 579. DOI: 10.3390/s21020579.
- [8] 于舒扬, 袁鑫, 郑秀娟. 融合感受野模块的卷积神经网络视杯视盘联合分割 [J]. 中国生物医学工程学报, 2022, 41(2): 167–176. DOI: 10.3969/j.issn.0258-8021.2022.02.005.
- Yu SY, Yuan X, Zheng XJ. Joint optic cup and disc segmentation using convolutional neural network with receptive field module [J]. Chin J Biomed Eng, 2022, 41(2): 167–176. DOI: 10.3969/j.issn.0258-8021.2022.02.005.
- [9] Medeiros FA, Zangwill LM, Bowd C, et al. Use of progressive glaucomatous optic disk change as the reference standard for evaluation of diagnostic tests in glaucoma [J]. Am J Ophthalmol, 2005, 139(6): 1010–1018. DOI: 10.1016/j.ajo.2005.01.003.
- [10] Ashtari-Majlan M, Dehshibi MM, Masip D. Glaucoma diagnosis in the era of deep learning: a survey [J]. Expert Syst Appl, 2024, 256: 124888. DOI: 10.1016/j.eswa.2024.124888.
- [11] Fu H, Cheng J, Xu Y, et al. Disc-aware ensemble network for glaucoma screening from fundus image [J]. IEEE Trans Med Imaging, 2018, 37(11): 2493–2501. DOI: 10.1109/TMI.2018.2837012.
- [12] Prastyo PH, Sumi AS, Nuraini A. Optic cup segmentation using U-net architecture on retinal fundus image [J]. J Info Technol Comput Engi, 2020, 4(2): 105–109.
- [13] Tabassum M, Khan T M, Arsalan M, et al. CDED-Net: joint segmentation of optic disc and optic cup for glaucoma screening [J]. IEEE access, 2020, 8: 102733–102747. DOI: 10.1109/ACCESS.2020.2998635.
- [14] Hervella ÁS, Rouco J, Novo J, et al. End-to-end multi-task learning for simultaneous optic disc and cup segmentation and glaucoma classification in eye fundus images [J]. Applied Soft Computing, 2022, 116: 108347.
- [15] Hua K, Fang X, Tang Z, et al. DCAM-NET: a novel domain generalization optic cup and optic disc segmentation pipeline with multi-region and multi-scale convolution attention mechanism [J]. Comput Biol Med, 2023, 163: 107076. DOI: 10.1016/j.combiomed.2023.107076.
- [16] Nawaz M, Nazir T, Javed A, et al. An efficient deep learning approach to automatic glaucoma detection using optic disc and optic cup localization [J/OL]. Sensors (Basel), 2022, 22(2): 434 [2025-06-06]. https://pubmed.ncbi.nlm.nih.gov/35062405/. DOI: 10.3390/s22020434.
- [17] He H, Qiu J, Lin L, et al. JOINEDTrans: prior guided multi-task transformer for joint optic disc/cup segmentation and fovea detection [J]. Comput Biol Med, 2024, 177: 108613. DOI: 10.1016/j.combiomed.2024.108613.
- [18] Fan R, Alipour K, Bowd C, et al. Detecting glaucoma from fundus photographs using deep learning without convolutions: transformer for improved generalization [J]. Ophthalmol Sci, 2023, 3(1): 100233. DOI: 10.1016/j.xops.2022.100233.
- [19] Dai Z, Liu H, Le Q V, et al. Coatnet: marrying convolution and attention for all data sizes [J/OL]. arXiv e-prints, 2021, 34: 3965–3977 [2025-06-06]. https://doi.org/10.48550/arXiv.2106.04803.
- [20] Lafferty J, McCallum A, Pereira F. Conditional random fields: probabilistic models for segmenting and labeling sequence data [C]. Proceedings of the Eighteenth International Conference on Machine Learning, 2001: 282–289.
- [21] Imtiaz R, Khan TM, Naqvi SS, et al. Screening of glaucoma disease from retinal vessel images using semantic segmentation [J]. Comput Electr Eng, 2021, 91(22): 107036. DOI: 10.1016/j.compeleceng.2021.107036.
- [22] Pachade S, Porwal P, Kokare M, et al. NENet: Nested EfficientNet and adversarial learning for joint optic disc and cup segmentation [J]. Med Image Anal, 2021, 74: 102253. DOI: 10.1016/j.media.2021.102253.
- [23] Luo L, Xue D, Pan F, et al. Joint optic disc and optic cup segmentation based on boundary prior and adversarial learning [J]. Int J Comput Assist Radiol Surg, 2021, 16(6): 905–914. DOI: 10.1007/s11548-021-02373-6.
- [24] Zhao X, Wang S, Zhao J, et al. Application of an attention u-net incorporating transfer learning for optic disc and cup segmentation [J]. Signal Image Video P, 2021, 15(8): 913–921. DOI: 10.1007/s11760-020-01815-z.
- [25] Sun J D, Yao C, Liu J, et al. GNAS-U 2 net: a new optic cup and optic disc segmentation architecture with genetic neural architecture search [J]. IEEE Signal Proc Lett, 2022, 29: 697–701. DOI: 10.1109/LSP.2022.3151549.
- [26] Liu B, Pan D, Shuai Z, et al. ECSD-Net: a joint optic disc and cup



- segmentation and glaucoma classification network based on unsupervised domain adaptation [J]. Comput Methods Programs Biomed, 2022, 213: 106530. DOI: 10. 1016/j. compb. 2021. 106530.
- [27] Jiang Y, Ma Z, Wu C, et al. RSAP-Net: joint optic disc and cup segmentation with a residual spatial attention path module and MSRCR-PT pre-processing algorithm [J]. BMC Bioinformatics, 2022, 23 (1): 523. DOI: 10. 1186/s12859-022-05058-2.
- [28] Liu Z, Chen Y, Xiang X, et al. Anend-to-end real-time lightweight network for the joint segmentation of optic disc and optic cup on fundus images [J]. Mathematics, 2022, 10 (22): 4288. DOI: 10. 3390/math10224288.
- [29] Sun G, Zhang Z, Zhang J, et al. Joint optic disc and cup segmentation based on multi-scale feature analysis and attention pyramid architecture for glaucoma screening [J]. Neural Comput Appl, 2023, 35: 16129-16142.
- [30] Tadisetty S, Chodavarapu R, Jin R, et al. Identifying the edges of the optic cup and the optic disc in glaucoma patients by segmentation [J]. Sensors (Basel), 2023, 23 (10): 4668. DOI: 10. 3390/s23104668.
- [31] Chen Z, Pan Y, Xia Y. Reconstruction-driven dynamic refinement based unsupervised domain adaptation for joint optic disc and cup segmentation [J]. IEEE J Biomed Health Inform, 2023, 27 (7): 3537-3548. DOI: 10. 1109/JBHI. 2023. 3266576.
- [32] Jiang L, Tang X, You S, et al. BEAC-Net: boundary-enhanced adaptive context network for optic disk and optic cup segmentation [J]. Applied Sciences, 2023, 13 (18): 10244.
- [33] Chen Y, Liu Z, Meng Y, et al. Lightweight optic disc and optic cup segmentation based on MobileNetv3 convolutional neural Network [J]. Biomimetics (Basel), 2024, 9 (10): 637. DOI: 10. 3390/biomimetics9100637.
- [34] Yu J, Chen N, Li J, et al. LC-MANet: location-constrained joint optic disc and cup segmentation via multiplex aggregation network [J]. Comput Electr Eng, 2024, 118: 109423.
- [35] Liu Y, Wu J, Zhu Y, et al. Combined optic disc and optic cup segmentation network based on adversarial learning [J]. IEEE Access, 2024, 12: 104898-104908.
- [36] Li C, Liu D, Cai W. Rethinking domain adaptive optic disc and cup segmentation in fundus image through dynamic diffusion flow [C/OL]. The 35th British Machine Vision Conference, Glasgow, 2024. <https://bmvc2024.org/proceedings/421/>.
- [37] Pawar DJ, Kanse YK, Patil SS. Insights into fundus images to identify glaucoma using convolutional neural network [C/OL]. Third International Conference on Image Processing and Capsule Networks, 2022, 514: 654-663. https://doi.org/10.1007/978-3-031-12413-6_51.
- (收稿日期: 2025-09-04 修回日期: 2025-10-09)
- (本文编辑: 张宇 骆世平)

读者 · 作者 · 编者

本刊对中英文摘要的要求

论著或综述文稿正文请撰写中英文摘要。原创性论著文稿要求为结构式摘要, 包括目的 (Objective)、方法 (Methods)、结果 (Results) 和结论 (Conclusions) 4 个要素, 摘要应能够回答以下问题: (1) 为什么进行这项研究。 (2) 主要用什么方法进行研究。 (3) 获得什么主要结果。 (4) 通过研究得出什么结论等。其中目的部分为本课题对上述提出问题设立的目标。方法部分应提供研究对象、样本量、分组情况、各组的干预情况、与研究相适应的观察或检测指标, 获得结局指标的手段和设备等。临床研究请说明是前瞻性研究、回顾性研究还是观察性研究。结果部分请客观描述研究的主要发现, 包括主要的形态学检查表现、相关的关键性或主要的量化资料以及相应的统计学比较结果, 须写明统计学量值及其概率值。结论部分请提出与本研究论据直接相关的、必然的推论, 避免得出过度推测性、评价性和扩大化的结论。摘要请用第三人称客观表述, 不列图表, 不引用文献, 不加评论和解释。英文摘要应与中文摘要内容相对应, 但为了对外交流的需要, 可以略详细。英文摘要应包括论文文题 (正体) 及全部作者姓名 (汉语拼音, 姓在前, 首字母大写, 名在后, 首字母大写, 双字连写。如: Yin Xiaohui)、标准化的单位名称、城市名称 (汉语拼音)、邮政编码及国家名称 (全部为斜体)。请在另起一行处提供通信作者姓名的汉语拼音和 Email 地址, 如 *Corresponding author: Yin Xiaohui, Email: xiaohuih@126.com*。专家述评或综述类文稿请撰写指示性中英文摘要, 摘要内容应包含研究涉及的概念、研究的目的、综述资料的来源、复习的文献量、研究的新发现或应用领域、综合的结果和结论及其意义等必要的信息。

研究论文为前瞻性研究者应在中英文摘要结束处提供临床试验注册号, 以“临床试验注册 (Trial registration)”为标题, 提供注册机构名称和注册号。前瞻性临床研究的论著摘要应注明遵循 CONSORT 声明 (Consolidated Standards of Reporting Trials) (<http://www.consort-standard.org/home>)。

本刊对存在科研诚信问题或发表流程中存在严重缺陷稿件的撤稿及其流程

依据中华医学会系列杂志论文发表后撤稿的推荐规范, 如发生下列情况本刊将予以撤稿处理: (1) 编辑部收到举报并已经证实论文存在较严重的不可信、学术不端或非主观的错误, 以至于该论文所报道的发现和结果不可信。 (2) 论文存在剽窃问题。 (3) 论文所报道的研究违反医学伦理规范。 (4) 未被允许的重复发表。 (5) 在稿件发表流程中存在严重缺陷。上述问题经编辑部严格调查属实后将按照撤稿流程分别在纸版期刊、本刊网站刊登撤稿声明, 刊登前编辑部和所有作者就撤稿声明的内容达成一致, 以保证各方利益。但在无法就撤稿声明的内容与作者达成一致时, 如已有充足证据表明必须撤稿, 本刊将尽快刊出撤稿声明。撤稿声明对所有读者免费开放, 以最大限度地减少该论文发表带来的负面影响。编辑对存在科研诚信问题或发表流程中存在严重缺陷稿件的撤稿拥有最终决定权。

(本刊编辑部)