

· 临床研究 ·

基于深度学习的 PACG 患者眼前节 UBM 图像分割

于欣琪¹ 赵志远¹ 苗清豪¹ 周游¹ 王晓春¹ 林松² 周盛¹¹中国医学科学院 北京协和医学院 生物医学工程研究所 医学超声工程实验室, 天津 300192; ²天津医科大学眼科医院特检科, 天津 300384

通信作者: 周盛, Email: zhousheng@bme.pumc.edu.cn

【摘要】 目的 开发一种基于深度学习的眼前节超声生物显微镜(UBM)图像分割模型, 以实现自动分割原发性闭角型青光眼(PACG)患者的眼前节组织。**方法** 采用单中心回顾性病例系列研究方法, 收集2022年7月12日至2023年2月20日在天津医科大学眼科医院接受UBM检查的156例PACG患者的468张房角闭合UBM图像构建小数据集。采用计算机随机种子法将UBM图像按照6:4比例分为训练数据集228张和测试数据集152张。通过骨干网络为MobileNet V2和ResNet50的PSPNet模型、骨干网络为MobileNet V2和Xception的DeepLab v3+模型, 以及骨干网络为MiT-B0和MiT-B2的SegFormer模型进行训练, 使用测试集进行结果预测, 实现角膜与巩膜、虹膜、睫状体和晶状体前缘4个区域的分割。以眼前节各结构分割的良好性能为标准, 采用平均交并比(mIoU)、Dice系数、精确率和召回率、漏检率和特异度多项指标评价模型性能, 对不同模型的测试结果进行对比分析。**结果** 分割性能较好的2个模型为PSPNet和DeepLab v3+, 其中骨干网络为ResNet50的PSPNet模型的mIoU为85.11%、Dice系数为91.38%、精确率为91.83%、召回率为90.94%、漏检率为9.06%、特异度为98.89%。骨干网络为MobileNet V2的DeepLab v3+模型的mIoU为85.84%、Dice系数为92.01%、精确率为92.67%、召回率为91.36%、漏检率为8.64%、特异度为98.90%。在mIoU、Dice系数、召回率、漏检率和特异度这5个关键指标中, DeepLab v3+模型均表现出最好的分割效果。此外, 骨干网络为Xception的DeepLab v3+模型精确率高于其他模型, 达92.77%。**结论** 基于深度学习的PACG眼前节UBM图像分割模型DeepLab v3+可精准分割眼前节组织结构, 为临床诊断提供辅助支持。

【关键词】 深度学习; 原发性闭角型青光眼; 超声生物显微镜; 自动分割

基金项目: 天津市科技重大专项与工程项目(24ZXZSS00110); 天津市卫生健康科技项目(TJWJ2025MS056); 天津市计量科技项目(2024TJMT035、2025TJMT018); 中国医学科学院医学与健康科技创新工程(2022-I2M-2-003、2023-I2M-2-008)

DOI: 10.3760/cma.j.cn115989-20250513-00151

Deep learning-based image segmentation of anterior segment UBM images for primary angle-closure glaucoma

Yu Xinqi¹, Zhao Zhiyuan¹, Miao Qinghao¹, Zhou You¹, Wang Xiaochun¹, Lin Song², Zhou Sheng¹¹Chinese Academy of Medical Sciences, Peking Union Medical College, Institute of Biomedical Engineering, Medical Ultrasound Engineering Laboratory, Tianjin 300192, China; ²Special Examination Department, Tianjin Medical University Eye Hospital, Tianjin 300384, China

Corresponding author: Zhou Sheng, Email: zhousheng@bme.pumc.edu.cn

[Abstract] Objective To develop a deep learning-based segmentation model for anterior segment ultrasound biomicroscopy (UBM) images to automatically segment the anterior segment tissues of patients with primary angle-closure glaucoma (PACG). **Methods** A single-center retrospective case series was conducted. A small-scale dataset comprised 468 UBM images of the anterior chamber angle closure from 156 patients with PACG who underwent the UBM examination at Tianjin Medical University Eye Hospital between July 12, 2022, and February 20, 2023. The UBM images were randomly split into a training dataset of 228 images and a testing dataset of 152 images using a random seed method in a ratio of 6:4. The models were trained using the PSPNet model with MobileNet V2 and

ResNet50 as backbones, the DeepLab v3+ model with MobileNet V2 and Xception as backbones, and the SegFormer model with MiT-B0 and MiT-B2 as backbones. The testing dataset was used for result prediction and to achieve segmentation of four regions: the cornea and sclera, iris, ciliary body, and anterior lens surface. To evaluate the performance of the models in segmenting the anterior segment structures, multiple metrics were assessed, including the mean intersection over union (mIoU), Dice coefficient, precision, recall, false negative rate, and specificity. A comparative analysis of the test results across the different models was subsequently performed. This study adhered to the Declaration of Helsinki. The study protocol was approved by the Ethics Committee of Tianjin Medical University Eye Hospital (No. 2023KY-05). **Results** The two models with the best segmentation performance were PSPNet and DeepLab v3+. The PSPNet model with ResNet50 as the backbone achieved the mIoU of 85.11%, Dice coefficient of 91.38%, precision of 91.83%, recall of 90.94%, false negative rate of 9.06%, and specificity of 98.89%. The DeepLab v3+ model with MobileNet V2 as the backbone achieved an mIoU of 85.84%, Dice coefficient of 92.01%, precision of 92.67%, recall of 91.36%, false negative rate of 8.64%, and specificity of 98.90%. Among the five key metrics, mIoU, Dice coefficient, recall, false negative rate, and specificity, DeepLab v3+ exhibited the best segmentation performance. In addition, the DeepLab v3+ model with Xception as the backbone had the highest precision among all models, reaching 92.77%. **Conclusions** The deep learning-based DeepLab v3+ model achieves precise segmentation of anterior segment tissue structures in PACG anterior segment UBM image segmentation, providing auxiliary support for clinical diagnosis.

[Key words] Deep learning; Primary angle-closure glaucoma; Ultrasound biomicroscopy; Automatic segmentation

Fund program: Tianjin Municipal Science and Technology Project (24ZXZSS00110); Tianjin Health Research Project (TJWJ2025MS056); Tianjin Metrology Technology Foundation (2024TJMT035, 2025TJMT018); CAMS Innovation Fund for Medical Sciences (2022-I2M-2-003, 2023-I2M-2-008)

DOI:10.3760/cma.j.cn115989-20250513-00151

青光眼是导致不可逆视力丧失的主要原因,其特征为视网膜神经节细胞的进行性丢失和视神经损伤。全世界近 9 500 万人患有青光眼,其中约 1 000 万人至少有一侧眼因该病致盲^[1]。原发性闭角型青光眼(primary angle-closure glaucoma, PACG)通常由于周边虹膜与小梁网表面贴附或粘连导致房水流出受阻,房角关闭,进而引发眼压急剧升高^[2]。PACG 在发病前期常无明显症状,导致大部分患者病程晚期才被发现,延误诊断和治疗,极大增加了致盲风险^[3]。因此 PACG 早期筛查和及时治疗对降低视功能丧失风险至关重要。

前房评估是青光眼疾病检查的重要组成部分。超声生物显微镜(ultrasound biomicroscopy, UBM)是一种高分辨率超声成像设备,能够对眼前节组织进行在体无创成像,可以清晰识别角膜、巩膜、虹膜、睫状体、晶状体前沿以及巩膜突等结构^[4],对眼前节组织进行精准分割,不仅可量化结构异常、避免漏诊,还可从前房结构参数的精确测量提供支持,使小梁-虹膜夹角、房角开放距离和房角隐窝面积等青光眼相关重要定量参数测量结果更加精准^[5]。

近年来,随着人工智能技术的飞速发展,深度学习方法在眼前节结构精准分割领域的应用日益广泛^[6]。

Hao 等^[7]基于 UNet 卷积神经网络对虹膜进行分割,通过虹膜根部位置确定前房角(anterior chamber angle, ACA)位置,并据此将 ACA 分为开角型、贴附型和粘连型,为青光眼不同阶段的临床管理提供了指导。针对有晶状体眼后房型人工晶状体(implantable collamer lens, ICL)植入手术患者的眼前节全景 UBM 图像, Zhu 等^[8]采用深度学习方法将眼前节组织精准分割为中央角膜、晶状体、双侧虹膜、双侧角巩膜缘和睫状体区域,并实现了前房参数的自动测量。为获取前房组织内侧边界以定量测量前房角度参数,多项研究采用了不同的分割方式。Wang 等^[9]将角膜、巩膜、虹膜和睫状体作为一类标记进行了分割。Jiang 等^[5]将前房结构分割为虹膜、巩膜和睫状体 3 个独立区域,同时实现了巩膜突的自动定位。Yang 等^[10]则采用基于 UNet 卷积神经网络,对眼前节光学相干断层扫描图像进行虹膜前表面和角膜后表面的分割,该方法能够评估 PACG 患者白内障手术联合人工晶状体植入疗效,以及具有 PACG 潜在风险的高度近视患者 ICL 植入术后效果。PACG 的发病机制与房角关闭密切相关,其核心病理机制与眼前节解剖结构异常,包括前房过浅、虹膜高褶形态改变和睫状体位置变化等^[11]高度相关。因此对 PACG 患者眼前节相关结构进行精准分割在临

床诊疗中具有重要意义。然而,目前针对 PACG 患者眼前节近景 UBM 图像进行精准分割的研究仍较为有限,多数研究仅采用单一模型对前房区域进行分割,尚未系统探索适用于眼前节图像的最优分割模型。分割边缘的精确度与清晰度是实现 PACG 眼前节区域组织结构关键参数精准定量测量的基础,也是房角关闭机制判断、病情进展和手术预后评估的重要依据。

因此,本研究旨在开发一种基于深度学习的眼前节 UBM 图像分割模型,实现对 PACG 患者眼前节组织结构,包括角膜与巩膜、虹膜、睫状体和晶状体前缘 4 个区域的自动分割,并通过对比 3 种常用分割模型基于不同骨干网络的性能表现,确定在 PACG 眼前节 UBM 图像数据集上性能最优的模型,以期 PACG 的临床辅助诊断以及大规模筛查场景的应用提供支持。

1 资料与方法

1.1 一般资料

采用单中心回顾性病例系列研究方法,收集 2022 年 7 月 12 日至 2023 年 2 月 20 日在天津医科大学眼科医院接受 UBM (MD-300L, 天津迈达医学科技有限公司) 检查的 156 例 PACG 患者的 468 张房角闭合 UBM 图像。UBM 图像均由具有 8 年以上临床经验的资深眼科超声医师采集;医师在图像采集前根据统一的操作规范接受培训。超声探头频率为 50 MHz,扫描范围为 8.25 mm×5.50 mm,以垂直于角巩膜缘(子午线,即穿过角膜中心的放射状轴线)的扫描方向对单侧房角任意位置进行扫描。患者在正常室内光线条件下采取仰卧位检查。每例患者随机抽取 3 张图像纳入数据集,每幅图像仅含一侧 ACA 结构。专业眼科超声医师以房角不完整、扫描平面不在子午线上以及由于其他原因造成不清晰的图像为排除标准,从采集图像中筛选患者合格图像,最终 380 张 UBM 图像纳入研究。采用计算机随机种子法,将 UBM 图像按照 6:4 比例随机分为训练数据集 228 张和测试数据集 152 张,其中训练数据集用于眼前节结构多模型的分割训练,测试数据集用于测试预测结果与手动分割结果之间的相似性及各模型间的性能对比评估。本研究遵循《赫尔辛基宣言》,研究方案经天津医科大学眼科医院伦理委员会批准(批文号:2023KY-05)。本研究属于回顾性研究,所有 UBM 图像进行了脱敏处理,豁免患者知情同意。

1.2 方法

1.2.1 UBM 图像标注 将数据集的 UBM 图像转换为 PNG 格式,由 2 名具有丰富经验的眼科超声医师采

用 labelme 软件(v 5.5.0)独立对图像进行手动标注,将眼前节组织分为角膜与巩膜、虹膜、睫状体和晶状体前缘(图 1)。若 2 名医师的分割结果有分歧,则由另一名具有 8 年以上临床经验的眼科超声医师进行裁定并标注。




图 1 分割任务标注 A:原图像 B:手动标注图像 红色表示角膜与巩膜,绿色表示虹膜,黄色表示睫状体,蓝色表示晶状体前缘

Figure 1 Segmentation task annotations A: Original image B: Manually annotated image Red represents the cornea and sclera, green represents the iris, yellow represents the ciliary body, and blue represents the anterior lens surface

1.2.2 分割模型选择 眼前节组织分割的目的是精准提取各解剖结构的边界和区域,为 PACG 临床诊断及后续研究提供支持。医学图像分割常用的性能较好的网络有 PSPNet^[12]、DeepLab v3+^[13] 和 SegFormer^[14] 等。在分割任务中,骨干网络的选择影响模型性能。MobileNet V2 凭借深度可分离卷积和反向残差结构能够显著降低计算量,保持高效轻量化的同时兼顾分割任务中的精度与速度^[15]。ResNet 通过残差连接机制缓解了深层网络的梯度消失问题,其准确率随深度增加而提升,且结构通用性强,易于集成到其他网络架构中。但网络深度增加也会产生深层网络参数规模膨胀的问题,因此本研究选取 ResNet50 以平衡精度和速度^[16]。本研究分别将 MobileNet V2、ResNet50 嵌入 PSPNet 模型作为骨干网络,采用 MobileNet V2、Xception^[13] 作为 DeepLab v3+模型的骨干网络。与基于 CNN 的骨干网络不同,SegFormer 模型采用基于 MiT 的编码器架构。其中,MiT-B0 具有轻量化特征,实时性突出但分割精度不足;MiT-B5 性能优异但参数规模过大。综合考虑模型效率与精度,本研究选择 MiT-B0 和 MiT-B2 作为 SegFormer 模型的骨干网络。

1.2.3 训练设置 本研究采用 Python 3.10 作为编程语言;PyTorch 2.1.0 作为深度学习框架,在一台配备 4 张 NVIDIA GeForce RTX 2080 Ti 显卡的服务器上进行了模型训练。在训练过程中均采用 Adam 优化器,初始学习率设定为 0.000 1。模型训练 100 个轮次,批大小设置为 2。将 PACG 眼前节 UBM 图像数据集训练集,分别输入基于骨干网络为 MobileNet V2、

ResNet50 的 PSPNet 模型、骨干网络为 MobileNet V2、Xception^[13] 的 DeepLab v3+ 模型和骨干网络为 MiT-B0、MiT-B2 的 SegFormer 模型进行训练。各模型经训练收敛并获得最优权重参数后,使用测试集进行结果预测,实现角膜与巩膜、虹膜、睫状体和晶状体前缘 4 个区域的分割。在数据集上完成训练与测试后,以眼前节各结构分割的良好性能为标准,对不同模型的测试结果进行对比分析(图 2)。

1.2.4 评价指标 为评估各模型性能,以测试结果与人工标注结果作为对比依据,采用平均交并比(mean intersection over union, mIoU)、Dice 系数、精确率和召回率、漏检率和特异度^[18] 多项指标评价模型性能。计算公式如下:单类别交并比 = $TP / (TP + FP + FN)$ 、Dice 系数 = $2 \times TP / (2 \times TP + FP + FN)$ 、精确率 = $TP / (TP + FP)$ 、召回率 = $TP / (TP + FN)$ 、漏检率 = $1 - TP / (TP + FN)$ 、特异度 = $TN / (TN + FP)$ 。其中 TP 为真阳性, TN 为真阴性, FP 为假阳性, FN 为假阴性。

2 结果

比较各模型在 UBM 原图像测试集上对角膜与巩膜、虹膜、睫状体和晶状体前缘分割的评估指标,结果显示,分割性能较好的 2 个模型为 PSPNet 和 DeepLab v3+(表 1,图 3)。其中骨干网络为 ResNet50 的 PSPNet 模型 mIoU 为 85.11%、Dice 系数为 91.38%、精确率为 91.83%、召回率为 90.94%、漏检率为 9.06%、特异度为 98.89%。骨干网络为 MobileNet V2 的 DeepLab v3+模型 mIoU 为 85.84%、Dice 系数为 92.01%、精确率为 92.67%、召回率为 91.36%、漏检率为 8.64%、特异度为 98.90%。在 mIoU、Dice 系数、召回率、漏检率和特异度这 5 个关键指标中,DeepLab v3+均表现出最好的分割效果,其分割效果见图 4。此外,骨干网络为 Xception 的 DeepLab v3+模型精确率为 92.77%,高于其他模型(表 1)。




图 2 结构流程图 系统输入为眼前节原始图像。对眼前节组织进行分割,比较分割模型,选取性能最好的模型将其分割为角膜与巩膜、虹膜、睫状体和晶状体前缘。红色表示角膜与巩膜,绿色表示虹膜,黄色表示睫状体,蓝色表示晶状体前缘

Figure 2 Schematic flowchart The system input was the original anterior segment image. The anterior segment tissue was segmented, and the models were compared. The best-performing model was selected to segment the image into the cornea and sclera, iris, ciliary body, and anterior lens surface. Red represented the cornea and sclera, green represented the iris, yellow represented the ciliary body, and blue represented the anterior lens surface

表 1 各分割模型定量评价指标
Table 1 Quantitative evaluation metrics for different segmentation models

模型	骨干网络	mIoU (%)	Dice 系数 (%)	精确率 (%)	召回率 (%)	漏检率 (%)	特异度 (%)
PSPNet	MobileNet V2	80.27	87.89	90.20	85.70	14.40	98.62
	ResNet50	85.11	91.38	91.83	90.94	9.06	98.89
DeepLab v3+	MobileNet V2	85.84	92.01	92.67	91.36	8.64	98.90
	Xception	83.17	90.27	92.77	87.91	12.09	98.43
SegFormer	MiT-B0	78.76	87.31	91.36	83.60	16.40	98.51
	MiT-B2	83.37	90.35	92.42	88.37	11.63	98.65

注:mIoU:平均交并比

Note:mIoU:mean intersection over union

3 讨论

青光眼的发病进程具有隐匿性,其早期常缺乏典型的临床症状。研究显示,50%的青光眼患者直至病程晚期出现视力损伤等显著表现时才就诊,是全球主要的致盲眼病之一^[18]。流行病学调查数据表明,目前中国中老年 PACG 患者人数达 1 010 万,该疾病已成为中国视觉健康领域严重的公共卫生问题之一^[19]。人工智能辅助青光眼的诊断与筛查在提升诊疗效率、优化诊断精确度和拓展筛查范围等方面展现出显著优势。在既往青光眼深度学习研究中,有研究者基于眼底照相和视野检查结果,采用不同的卷积神经网络模




图3 各模型对晶状体前缘、睫状体、虹膜、角膜和巩膜的分割指标 A1~A4:PSPNet 模型,骨干网络为 ResNet50 B1~B4:DeepLab v3+模型,骨干网络为 MobileNet V2 mIoU:平均交并比;背景为非目标分割区域

Figure 3 Segmentation metrics of each model for the anterior lens surface, ciliary body, iris as well as cornea and sclera A1~A4: PSPNet model with ResNet50 as the backbone network B1~B4: DeepLab v3+ model with MobileNet V2 as the backbone network mIoU: mean intersection over union; Background referred to the non-target segmentation area




图4 DeepLab v3+分割结果图 A:UBM 原图 B:分割结果

Figure 4 DeepLab v3+ segmentation result image A: Original UBM image B: Segmentation result

型对青光眼严重程度进行分级^[20],该模型虽能实现高准确率诊断,但主要围绕青光眼整体病情展开,未能深入探索眼前节具体组织结构特征。另有针对 PACG 的研究报道,通过结合深度学习对睫状体实现 3 个区域分割和睫状体前位自动评估,可准确、快速判断睫状体前位因素在 PACG 患者房角闭合机制中的影响^[21]。本研究聚焦于 PACG 患者眼前节组织结构的全域分割,范围涵盖角膜、巩膜、虹膜、睫状体和晶状体前缘所有区域,相较于仅针对单一组织的研究,本研究实现了眼前节解剖结构的系统性呈现。对眼前节 UBM 图像的全区域分割不仅能为房角闭合机制分析提供多维度的结构参数,如虹膜形态、晶状体与睫状体空间关系等,同时也弥补了眼底照相等其他成像技术对眼前节微观结构关注不足的局限。本研究采用模型间的交叉验证,通过比较不同模型架构及相同模型的不同骨干网络,对适用于眼前节组织分割的模型进行系统性探索,结果显示性能最优模型的各项指标均处于当前领域内较优水平。

青光眼的结构性损伤通常早于功能性损伤^[22]。因此眼前节组织的自动分割在临床中,尤其在疾病的

早期预警与分型诊断方面发挥着重要作用。PACG 的核心病理机制是由房角关闭、眼压升高所引起,而眼前节组织 4 个关键结构区域形态的关联性反映房角状态最直观的表现。自动分割可作为精准量化房角闭合关键参数的基础,包括虹膜厚度与曲率、睫状体位置和晶状体-虹膜接触距离等。通过对上述参数的综合分析,不仅能够实现 PACG 的亚分型,如瞳孔阻滞型和非瞳孔阻滞型^[23],还可对高风险人群进行房角关闭风险分级,为疾病的早期干预提供客观量化依据。

本研究对比了常用的 3 种分割模型,各模型分别采用 2 种骨干网络进行测试。PSPNet^[12] 的核心架构是金字塔池化模块,通过多尺度上下文聚合增强全局场景理解能力;该模块能够有效捕获全局场景先验与局部细节,解决复杂场景中物体类别混淆、小目标漏检等问题,显著提升分割精度^[12]。基于 PSPNet 的自动分割网络模型已在前列腺磁共振成像^[24]、冠状动脉造影图像^[25]和胃肠道肿瘤磁共振成像^[26]等医疗数据集上验证了高精度分割性能。DeepLab v3+采用编码器-解码器结构架构,融合多尺度上下文信息提取与边界细节恢复能力,其优势在于编码器可高效捕获多尺度语义信息,解码器则通过低层次特征优化边界分割效果,提升复杂场景下的分割精度;但该解码器设计简单,对极复杂边界的处理能力有限,易存在误分割问题^[13]。DeepLab v3+模型适用于胃肿瘤病理切片分割^[27]、结肠镜息肉分割^[28]和脑肿瘤分割^[29]等医疗领域,在分割精度要求高的复杂场景中具有显著优势。SegFormer 模型由分层 Transformer (mix transformer, MiT) 编码器和轻量级全多层感知机解码器组成,具有

高效轻量特点,参数数量少,计算成本远低于传统复杂解码器;通过多尺度特征融合,其边缘细节和上下文建模能力得到进一步提升^[14]。SegFormer 已在左心室分割^[30]、骨肉瘤和肾细胞癌组织病理学图像的肿瘤分割^[31]以及新生儿骨盆分割^[32]等医疗领域中,展现出广泛的应用价值。

与其他模型相比,SegFormer (MiT-B0/B2) 在多项指标表现显著低于 DeepLab v3+ 和 PSPNet 模型,性能较弱,特别是在晶状体前缘和睫状体区域,该模型存在组织结构分割不完整的问题。分割性能最佳的模型是 DeepLab v3+ 模型(骨干网络为 MobileNet V2)和 PSPNet 模型(骨干网络为 ResNet50)。其中 DeepLab v3+ 模型(骨干网络为 MobileNet V2)的各项评价指标均优于其他模型,能够将眼前节组织结构精准分割为角膜与巩膜、虹膜、睫状体和晶状体前缘 4 个区域。但由于晶状体前缘部分本身存在边界模糊且结构纤细的特性,尽管该模型整体性能表现突出,但相较于其他 3 个结构的分割效果,其在该结构细微边缘的连续性处理及灰度渐变区域的细节识别有待进一步优化。

在模型性能的影响因素中,骨干网络的选择尤为关键,不同的骨干网络带给模型的性能差异也十分显著。如 DeepLab v3+ 模型,当骨干网络采用 MobileNet V2 时,多项指标明显优于骨干网络为 Xception 的模型,mIoU 和 Dice 系数分别提升了 2.67% 和 1.74%。这表明,选择适配的骨干网络对于模型在分割任务中的性能提升显著。

本研究仍存在一定的局限性。首先,受限 PACG 患病人群的特异性和医疗图像标注获取难度大、成本高的客观条件制约,本研究用于训练和测试的数据集样本量较小,难以全面覆盖 PACG 不同病程阶段的眼前节 UBM 影像表现,可能导致模型在面对未包含的病例类型时出现差错,因此模型泛化能力仍有待于在更大规模、更多元化的数据集下进一步验证。其次,数据集的标注依赖于人工手动操作,受主观因素影响的人为误差难以完全避免。最后,本研究仅聚焦于基础分割任务的实现,在 PACG 的临床实际应用方面仍存在一定的局限性。为提高小数据集上测试结果的可靠性,后续研究将进一步扩大数据集规模。一方面,本团队将持续扩大样本采集范围,与医院建立长期数据积累的合作,获取更多具有代表性的数据;另一方面,本团队将尝试结合数据增强和数据生成等技术手段扩充样本数量,同时运用半监督学习等方法,探索小样本条件下提升模型性能的有效路径,进而更全面地验证本研究结论的普适性,提升研究的可靠性与泛化性。

本研究开发了一种基于深度学习的 PACG 眼前节 UBM 图像分割模型,通过比较多种深度学习分割模型的性能指标,最终筛选出骨干网络为 MobileNet V2 的 DeepLab v3+ 模型综合性能最佳。该模型针对 UBM 图像中角膜与巩膜、虹膜、睫状体和晶状体前缘 4 个区域,实现自动精准分割。该方法能够辅助医师对 PACG 进行精准诊断,还可作为提取房角开放面积、房角隐窝面积和前房深度等 PACG 临床参数的重要工具。基于本研究成果,后续可进一步结合机器学习在参数量化、分析等方面展开深入研究,建立可解释性强的预测模型,为 PACG 的早期预警和精准医疗提供具有更有价值的辅助诊断工具。

利益冲突 所有作者均声明不存在利益冲突

作者贡献声明 于欣琪:设计试验、实施研究、分析/解释数据、文章撰写;赵志远:实施研究、采集数据、分析数据;苗清豪:设计试验、采集数据;周游:采集数据、参与人工智能模型测试;王晓春:设计试验、参与人工智能模型训练;林松:采集数据、数据支持与分析;周盛:设计试验、文章知识性内容审阅、修改及定稿

参考文献

- [1] Jayaram H, Kolko M, Friedman DS, et al. Glaucoma; now and beyond [J]. Lancet, 2023, 402 (10414): 1788–1801. DOI: 10.1016/S0140-6736(23)01289-8.
- [2] Lai J, Choy BNK, Shum JWH. Management of primary angle-closure glaucoma [J]. Asia Pac J Ophthalmol (Phila), 2016, 5 (1): 59–62. DOI: 10.1097/APO.0000000000000180.
- [3] Ahram DF, Alward WL, Kuehn MH. The genetic mechanisms of primary angle closure glaucoma [J]. Eye (Lond), 2015, 29 (10): 1251–1259. DOI: 10.1038/eye.2015.124.
- [4] Dada T, Gadia R, Sharma A, et al. Ultrasound biomicroscopy in glaucoma [J]. Surv Ophthalmol, 2011, 56 (5): 433–450. DOI: 10.1016/j.survophthal.2011.04.004.
- [5] Jiang W, Yan Y, Cheng S, et al. Deep learning-based model for automatic assessment of anterior angle chamber in ultrasound biomicroscopy [J]. Ultrasound Med Biol, 2023, 49 (12): 2497–2509. DOI: 10.1016/j.ultrasmedbio.2023.08.013.
- [6] Sharma P, Ninomiya T, Omodaka K, et al. A lightweight deep learning model for automatic segmentation and analysis of ophthalmic images [J]. Sci Rep, 2022, 12 (1): 8508. DOI: 10.1038/s41598-022-12486-w.
- [7] Hao H, Zhao Y, Yan Q, et al. Angle-closure assessment in anterior segment OCT images via deep learning [J]. Med Image Anal, 2021, 69: 101956. DOI: 10.1016/j.media.2021.101956.
- [8] Zhu J, Yan Y, Jiang W, et al. A deep learning model for automatically quantifying the anterior segment in ultrasound biomicroscopy images of implantable collamer lens candidates [J]. Ultrasound Med Biol, 2024, 50 (8): 1262–1272. DOI: 10.1016/j.ultrasmedbio.2024.05.004.
- [9] Wang W, Wang L, Wang X, et al. A deep learning system for automatic assessment of anterior chamber angle in ultrasound biomicroscopy images [J]. Transl Vis Sci Technol, 2021, 10 (11): 21. DOI: 10.1167/tvst.10.11.21.
- [10] Yang G, Li K, Yao J, et al. Automatic measurement of anterior chamber angle parameters in AS-OCT images using deep learning [J]. Biomed Opt Express, 2023, 14 (4): 1378–1392. DOI: 10.1364/BOE.481419.
- [11] 吴梦楠, 吴仁毅. 眼球生物学测量参数与原发性闭角型青光眼的研究进展 [J]. 国际眼科杂志, 2020, 20 (10): 1752–1755. DOI: 10.3980/j.issn.1672-5123.2020.10.19.
Wu MN, Wu RY. Advances in the research on correlation between ocular biometry parameters and primary angle-closure glaucoma [J]. Int Eye Sci, 2020, 20 (10): 1752–1755. DOI: 10.3980/j.issn.1672-5123.2020.10.19.
- [12] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Los Alamitos: IEEE Computer Society, 2017: 6230–6239. DOI: 10.1109/CVPR.2017.660.
- [13] Chen LC, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [J/OL]. ArXiv

- e-prints, 2018 [2025 - 06 - 16]. <https://doi.org/10.48550/arXiv.1802.02611>.
- [14] Xie E, Wang W, Yu Z, et al. SegFormer: simple and efficient design for semantic segmentation with transformers [J/OL]. arXiv e-prints, 2021, 34 : 12077 - 12090 [2025 - 06 - 16]. <https://doi.org/10.48550/arXiv.2105.15203>.
- [15] Sandler M, Howard A, Zhu M, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018 : 4510 - 4520. DOI: 10.1109/CVPR.2018.00474.
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016 : 770 - 778. DOI: 10.1109/CVPR.2016.90.
- [17] 杨卫华, 邵毅, 许言午, 等. 眼科人工智能临床研究评价指南 (2023) [J]. 国际眼科杂志, 2023, 23 (7) : 1064 - 1071. DOI: 10.3980/j.issn.1672-5123.2023.7.03.
- [18] 钟云龙, 谢伯林, 钟华. 青光眼知晓度研究进展 [J]. 中华实验眼科杂志, 2017, 35 (4) : 372 - 376. DOI: 10.3760/cma.j.issn.2095-0160.2017.04.017.
- Zhong YL, Xie BL, Zhong H. Research progress of awareness of glaucoma [J]. Chin J Exp Ophthalmol, 2017, 35 (4) : 372 - 376. DOI: 10.3760/cma.j.issn.2095-0160.2017.04.017.
- [19] 马明利, 孙静波, 原慧萍. 原发性闭角型青光眼发病因素的再认识 [J]. 中华实验眼科杂志, 2023, 41 (2) : 188 - 191. DOI: 10.3760/cma.j.cn115989-20200812-00586.
- Ma ML, Sun JB, Yuan HP. New understandings of the pathogenesis of primary angle-closure glaucoma [J]. Chin J Exp Ophthalmol, 2023, 41 (2) : 188 - 191. DOI: 10.3760/cma.j.cn115989-20200812-00586.
- [20] 钱朝旭, 周凌翔, 冯雪丽, 等. 基于多模态数据的深度学习在青光眼诊断和严重程度分级中的应用 [J]. 中华实验眼科杂志, 2024, 42 (12) : 1149 - 1154. DOI: 10.3760/cma.j.cn115989-20240104-00005.
- Qian CX, Zhou LX, Feng XL. Application of deep learning with multimodal data in glaucoma diagnosis and severity grading [J]. Chin J Exp Ophthalmol, 2024, 42 (12) : 1149 - 1154. DOI: 10.3760/cma.j.cn115989-20240104-00005.
- [21] 丛钰玉, 蒋维艳, 朱剑, 等. 基于深度学习的原发性闭角型青光眼睫状体前位的自动评估 [J]. 中华实验眼科杂志, 2024, 42 (12) : 1134 - 1141. DOI: 10.3760/cma.j.cn115989-20240328-00085.
- Cong YY, Jiang WY, Zhu J, et al. An automatic evaluation study for anterior located ciliary body of primary angle-closure glaucoma based on deep learning [J]. Chin J Exp Ophthalmol, 2024, 42 (12) : 1134 - 1141. DOI: 10.3760/cma.j.cn115989-20240328-00085.
- [22] 吴倩如, 张纯. 青光眼视功能损伤进展评估方法 [J]. 中华实验眼科杂志, 2024, 42 (6) : 569 - 575. DOI: 10.3760/cma.j.cn115989-20200622-00447.
- Wu QR, Zhang C. Advances in methods to assess progression of glaucomatous visual impairment [J]. Chin J Exp Ophthalmol, 2024, 42 (6) : 569 - 575. DOI: 10.3760/cma.j.cn115989-20200622-00447.
- [23] 肖亮, 梁亮. 手术治疗原发性闭角型青光眼的研究进展 [J]. 现代医学与健康研究 (电子版), 2024, 8 (2) : 131 - 134. DOI: 10.3969/j.issn.2096-3718.2024.02.040.
- [24] Yan L, Liu D, Xiang Q, et al. PSP net-based automatic segmentation network model for prostate magnetic resonance imaging [J]. Comput Methods Programs Biomed, 2021, 207 : 106211. DOI: 10.1016/j.cmpb.2021.106211.
- [25] Zhu X, Cheng Z, Wang S, et al. Coronary angiography image segmentation based on PSPNet [J]. Comput Methods Programs Biomed, 2021, 200 : 105897. DOI: 10.1016/j.cmpb.2020.105897.
- [26] Sharma N, Gupta S, Rajab AH, et al. Semantic segmentation of gastrointestinal tract in MRI scans using PSPNet model WITH ResNet34 feature encoding network [J]. IEEE Access, 2023, 11 : 132532 - 132543. DOI: 10.1109/ACCESS.2023.3336862.
- [27] Wang J, Liu X. Medical image recognition and segmentation of pathological slices of gastric cancer based on Deeplab v3+ neural network [J]. Comput Methods Programs Biomed, 2021, 207 : 106210. DOI: 10.1016/j.cmpb.2021.106210.
- [28] Gangrade S, Sharma PC, Sharma AK, et al. Modified DeeplabV3+ with multi-level context attention mechanism for colonoscopy polyp segmentation [J]. Comput Biol Med, 2024, 170 : 108096. DOI: 10.1016/j.combiomed.2024.108096.
- [29] Singh R, Sharma N. Improving brain tumor detection and segmentation with DeepLabV3 and ResNet-50 [C]. 2024 5th IEEE Global Conference for Advancement in Technology (GCAT). 2024 : 1 - 6. DOI: 10.1109/GCAT62922.2024.10923939.
- [30] Wu H, Qu G, Xiao Z, et al. Enhancing left ventricular segmentation in echocardiography with a modified mixed attention mechanism in SegFormer architecture [J/OL]. Heliyon, 2024, 10 (15) : e34845 [2025 - 06 - 19]. <https://pubmed.ncbi.nlm.nih.gov/39170227/>. DOI: 10.1016/j.heliyon.2024.e34845.
- [31] Saleena TS, Ilyas PM, Kutty SV. SegFormer-based approach for semantic segmentation of necrotic tissues from histopathology images [C]. 2024 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER). 2024 : 383 - 387. DOI: 10.1109/DISCOVER62353.2024.10750697.
- [32] Hers B, Bonta M, Du S, et al. SegFormer3D: improving the robustness of deep learning model-based image segmentation in ultrasound volumes of the pediatric hip [J]. Ultrasound Med Biol, 2025, 51 (5) : 751 - 758. DOI: 10.1016/j.ultrasmedbio.2024.12.013.

(收稿日期:2025-05-13 修回日期:2025-07-29)

(本文编辑:张宇 骆世平)

消息

《角膜皮样瘤》出版发行

由蔺琪、潘志强主编的《角膜皮样瘤》已于 2025 年 10 月由人民卫生出版社出版发行。

本书为人民卫生出版社眼表疑难病口袋书系列之一,对角膜皮样瘤的病因、病理基础、多样的临床表现、罕见的相关综合征、围手术期医护配合、婴幼儿手术后屈光矫正、感知觉学习视觉康复训练等方面进行全面阐述,并对术前诊断、手术操作、及术后视觉康复等全流程进行了系统剖析。集合角膜医师、儿童斜弱视医师、视光医师等多学科的专业视角,对角膜皮样瘤疾病进行详细梳理。本书讲解透彻、突出实用性,书中辅以角膜皮样瘤典型病例并配套手术及操作视频,以帮助提升临床眼科医师对这一疾病的诊治能力。

本书大 32 开精装,155 页,共 13.8 万字,定价:89.00 元。如需订购,可通过全国新华书店、人民卫生出版社官网进行购买,或与靳晴(电话:18611134562)联系购买。联系地址:北京市朝阳区潘家园南里 19 号,邮政编码:100021。

(本刊编辑部)



中华医学杂志社
Chinese Medical Association Publishing House

版权所有 违者必究