科学通报 2026 年 第 71 卷 第 15 期: 3426 ~ 3439
人工智能驱动的数字医疗新实践专题 论 文
《中国科学》杂志社 SCIENCE CHINA PRESS

基于双模块U-Net深度学习技术定量评估超声生物显微镜下的闭角房角参数

杨丰瑞[1], 王博辉[2], 吕坤[1], 胡亦桐[1], 孟祥[1], 贺泽宇[2*], 吴慧娟[1*]

1. 北京大学人民医院眼科, 北京 100044
2. 北京信息科技大学计算机学院计算机科学技术系, 北京 100101
* 联系人, E-mail: 20222638@bistu.edu.cn; dr_wuhuijuan@126.com

2025-06-30 收稿, 2025-09-29 修回, 2026-04-27 接受, 2026-04-28 网络版发表
首都卫生发展科研专项(2024-2-4087)、北京大学人民医院研究与发展基金(RDGS2024-06)和北京信息科技大学“青年骨干教师”支持计划资助

摘要 原发性房角关闭疾病(primary angle closure disease, PACD)是一种以房角解剖结构关闭为典型病理特征的眼科疾病. 超声生物显微镜(ultrasound biomicroscopy, UBM)作为关键评估工具, 可提供房角的高分辨率图像. 本研究设计并实现了一套基于深度学习的UBM图像自动分析系统, 该系统针对PACD相关房角参数进行量化测量. 实验数据来源于正常对照受试者和PACD患者的UBM图像样本. 模型构建采用U-Net神经网络架构, 分设两个独立模块: 前者用于眼前节组织分割, 后者则负责巩膜突定位任务. 基于分割与定位结果, 本研究应用计算机视觉算法自动计算多项房角参数, 包括小梁虹膜角、房角开放距离、小梁网虹膜间面积以及睫状突面积. 系统性能评估表明, 眼前节组织分割的并集交并比均值均表现优异(角膜-巩膜为0.93、虹膜为0.93、睫状体为0.87); 巩膜突定位的平均误差低至94.12 μm; 参数测量的一致性通过类内相关系数(intraclass correlation coefficient, ICC)验证, 各参数ICC值皆高于0.97. 这反映自动测量与人工标注的高度一致性. 本研究构建的自动化系统具备高效性与准确性, 显著提升了UBM在PACD临床诊疗及科研活动中的应用潜力.

关键词 深度学习, 计算机视觉, 图像分割, 原发性房角关闭疾病, 超声生物显微镜

原发性房角关闭疾病(primary angle closure disease, PACD)作为一类眼科疾病, 其核心特征为前房角关闭并引发房水流出受阻[1]. 这一病变过程导致眼压升高和青光眼性视神经损害, 从而构成其主要病理学基础. PACD包括三种临床亚型: 可疑原发性房角关闭、原发性房角关闭以及原发性闭角型青光眼(primary angle closure glaucoma, PACG)[2]. 若无积极干预, 这些亚型常随年龄增长而逐步进展, 患者视功能损害也随之加重. 青光眼是全球发病率最高的不可逆性致盲眼病, 其中PACD在亚洲地区发病率最高, 成为地域性流行病学特征[3,4]. 在中国, 青光眼总体患病率约为2.58%, 而PACG占比高达54.42%, 体现了其作为主要亚型的流行病学地位[5]. 鉴于PACD对患者生活质量的显著影响及由此衍生的社会经济负担, 优化其筛查、诊断和治疗策略具有重要的临床和公共卫生意义.

PACD的三种亚型均具备前房角关闭这一核心病理特征. 超声生物显微镜(ultrasound biomicroscopy, UBM)作为当前评估前房角状态的核心客观工具[6], 在临床实践中发挥着关键作用. 然而, 对于UBM图像的判读仍主要依赖于定性方法, 例如通过巩膜突(scleral spur, SS)的可视性判断房角开放与否. 这一策略在分类粒度上显得较为粗糙, 易受主观因素影响, 且对操作者经验的依赖性较高, 从而削弱了其诊断一致性. 为弥补这一局限, 研究者们开发了多种基于UBM图像的定量

引用格式: 杨丰瑞, 王博辉, 吕坤, 等. 基于双模块U-Net深度学习技术定量评估超声生物显微镜下的闭角房角参数. 科学通报, 2026, 71: 3426–3439
Yang F, Wang B, Lü K, et al. Quantitative evaluation of angle-closure parameters in ultrasound biomicroscopy based on dual-module U-Net deep learning technology (in Chinese). Chin Sci Bull, 2026, 71: 3426–3439, doi: 10.1360/CSB-2025-5174

© 2026《中国科学》杂志社

参数, 用于系统性评估房角关闭程度及其潜在机制[7,8]. 相关参数涉及众多维度, 如小梁虹膜角(trabecular iris angle, TIA)、房角开放距离(angle-opening distance, AOD)、小梁网虹膜间面积(trabecular iris space area, TISA)、小梁睫状突角(trabecular ciliary angle, TCA)以及睫状突面积(ciliary process area, CPA)等. 尽管诸如TIA和AOD等参数已被证实能够有效量化房角狭窄或关闭的进展程度, 并为揭示关闭机制提供可靠依据, 但由于测量过程复杂耗时, 当前应用仍主要集中在科研探索领域, 难以推广至大规模的临床操作中.

随着人工智能和计算机技术的迅速发展, 深度学习技术已在医学影像分析领域得到广泛应用, 其中眼科UBM图像的研究亦取得显著进展. 在分类任务上, 一项研究利用InceptionV3架构开发卷积神经网络, 以2273例UBM图像进行训练, 实现了房角关闭的高精度诊断, 其准确率高达98%以上[9]; 而针对虹膜高褶和悬韧带异常等与PACD相关的分类难题, 部分研究的准确率尚未达到临床大规模应用的可行水平[10,11]. 组织分割被视为深度学习模型处理医学影像的核心基础任务. 对此, 已有研究借助BAS-Net模型和2017例UBM图像成功实现角膜、巩膜、虹膜及睫状体的精确分区, 其交并比(intersection over union, IoU)稳定维持在0.98[12], 展示了卓越的分割能力. 定位任务方面, 深度学习技术已可高效完成SS的自动定位. 基于训练集样本量超过800例的多种研究结果, 开角图像中SS定位的平均误差维持在约60 μm[9,10,13], 显示出良好的稳定性. 定量任务作为提升效率的重要环节, 其实现面临更高的技术挑战. 当前研究主要集中在利用深度学习方法自动测量AOD和TIA等参数[9,12], 然而其测量精度仍需进一步提高以适应临床要求.

本研究基于大规模前瞻性眼科UBM影像数据集, 采用深度学习算法构建了具有多任务处理能力的分析模型. 该模型实现了两大核心功能: 其一, 完成眼前节结构的自动化精准分区及SS关键解剖标志的定位; 其二, 依据分区与定位结果, 对前房角相关参数进行高精度量化测量. 实验结果表明, 该技术方案显著提升了UBM影像定量分析的效能, 为PACD早期诊断提供了可靠的辅助决策支持.

1 材料与方法

1.1 受试者和数据集

本研究方案符合赫尔辛基宣言并由北京大学人民医院伦理委员会审核通过(2024PHB193-002), 自2024年7月至2025年6月在北京大学人民医院眼科青光眼门诊开展受试者招募工作, 所有入组患者均签署了书面知情同意书. PACD组纳入标准: 经前房角镜检查确认≥270°范围的后部小梁网不可见, 且无论是否存在小梁网阻塞或青光眼性视神经损害[1]. 同时设立正常人群作为前房角开放的对照组. 所有PACD病例的诊断均由同一位资深青光眼专科医生完成. 排除标准涵盖: (1) 既往眼内手术或抗青光眼激光治疗史; (2) 继发性房角关闭; (3) 使用可能影响前房结构的药物; (4) 因各种原因不能配合完成UBM检查. 连续纳入所有符合标准的受试者.

本研究样本量计算主要基于前期研究结果和统计分析, 以SS定位误差为主要指标. 既往研究在开角图像中实现SS定位的平均误差约为60.41 μm, 标准差为49.02 μm[13]. 设定非劣效界值为10 μm, 在α=0.05(双侧)、β=0.20的条件下进行非劣效性检验样本量估算, 每组需要至少378张独立图像. 为应对图像质量不合格等数据剔除情况, 对照组和PACD组各纳入400张图像.

入组受试者确诊后均接受UBM(Aviso, Quantel Medical Inc., 美国)检查. 检查于标准暗室环境下进行, 受试者取仰卧位. 操作者采用盲法设计执行扫描流程, 避免知晓受试者分组信息. 所有受试者双侧眼部分别采集颞侧、鼻侧、上方及下方四个方位的房角结构影像. 由两名资深青光眼专科医师独立完成影像评估, 凡无法清晰呈现SS、前房角、虹膜根部及睫状体冠部解剖结构的图像均予以排除.

1.2 数据集标注和前房角参数人工测量

UBM图像的标注采用LabelMe软件(版本4.5.13)执行. 整个标注过程由两位具有青光眼专业背景的医师协作完成: 一人负责标注, 另一人负责审核, 以确保标注准确性. 标注步骤包括首先识别并标记SS, 随后依次界定角膜与巩膜、虹膜以及睫状体的边界区域. 基于所得的标注结果, 在ImageJ软件(版本1.54p)中顺序测量前房角参数, 包括$AOD_{500/750}$、$TIA_{500/750}$、$TISA_{500/750}$和CPA. 为控制人为测量误差, 这些指标由两位医师分别独立测量, 最终取平均值作为前房角参数的参考值.

上述参数的定义见图1. 从SS点出发, 绘制一个半径为500 μm的圆, 其与角膜后表面相交于点A, 与巩膜后表面相交于点D. 随后, 通过点A绘制垂直角膜后表面的法线, 该法线与虹膜前表面相交于点B, 此时点A

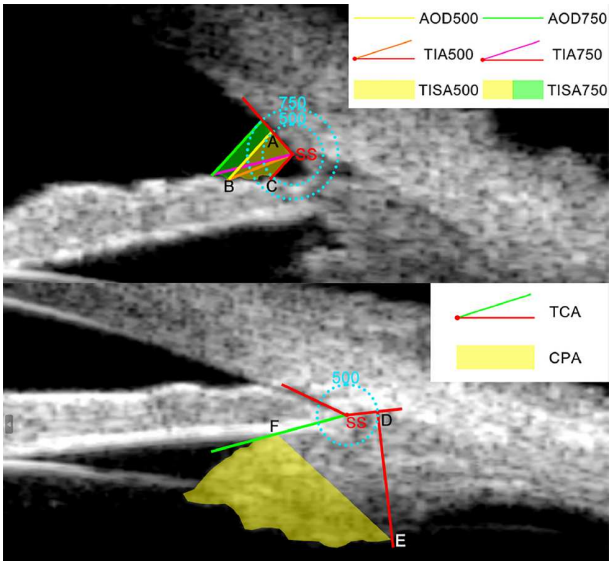


图 1 前房角参数的定义
Figure 1 The definition of anterior chamber angle parameters

与点B之间的欧几里得距离定义为AOD_{500}. 进一步, 以点SS为顶点, 基于点A和点B形成的角度定义为TIA_{500}. 接着, 通过点SS绘制一条平行于线段AB的直线, 此直线与虹膜前表面相交于点C; 线段SS-C、SS-A、AB及虹膜前表面对应的包围面积定义为$TISA_{500}$[14]. 当将绘制圆的半径变更为750 μm时, 类似方法可应用于相应点的确定, 进而得出AOD_{750}、TIA_{750}和$TISA_{750}$等参数. 最后, 通过点D绘制垂直于巩膜后表面的法线, 与睫状体后表面相交于点E; 同时, 定义虹膜后表面与睫状体前表面交点为F, 线段EF与睫状体表面围成的包围面积则定义为CPA[15].

1.3 组织自动分割和巩膜突识别模型搭建

本研究采用两个独立的深度学习模型分别实现组织的自动分割与SS识别. 在模型选择上, 基于临床实际对轻量级、高效率模型的需求, 本研究选定标准U-Net架构, 未使用其复杂度更高的变体(如U-Net++、U-Net3+及基于Transformer的U-Net). 预实验评估表明, 尽管上述复杂模型在所述任务中的精度相较于标准U-Net仅提升了约2%~3%, 但其参数规模和计算资源需求均存在显著上升. 考虑到UBM图像本身具备较高分辨率, 且前房角结构边界较为清晰可辨, 采用规模过大的网络架构并无明显优势. 因此, 在同时平衡算法效率与临床应用可行性的前提下, 本研究最终选定标准U-Net作为核心骨干网络.

为提升模型的泛化能力并抑制过拟合风险, 本研究在训练阶段系统引入了基于几何变换的图像数据增强策略. 具体而言, 采用旋转、平移、缩放及水平翻转等操作扩展训练数据的空间变换维度, 显著提升模型对视角偏移、位置变动及尺度缩放的适应性. 实验表明, 此类增强方法通过生成多样化样本分布, 有效强化了模型在未见数据上的特征提取能力. 在前节多组织分割与SS定位任务中, 优化后的模型鲁棒性与定位精度显著提升, 验证了几何增强对复杂场景适应性的正向促进作用.

前节多组织分割模型设计用于自动分割UBM图像中的角膜与巩膜、虹膜及睫状体三个区域, 其具体架构见图2. 该模型采用U-Net架构, 包括编码器和解码器两个核心模块. 编码器通过多级卷积层与最大池化操作提取图像的多尺度特征, 而解码器则通过逐步上采样恢复空间分辨率, 同时结合跳跃连接来传递编码器的低层次特征, 以强化细节保留. 此外, 考虑到UBM图像存在高分辨率、虹膜-睫状体边界模糊和噪声干扰明显等特性, 模型在U-Net框架中引入了组织位置感知注意力机制, 从而增强对细微解剖结构的建模能力.

SS检测任务的目标在于精确定位UBM图像中SS的坐标位置. 本研究将该任务构建为图像单关键点检测问题, 基于U-Net架构进行开发(图3), 但调整了输出层以区别于传统图像分割模型. 模型的输出呈现为一个单通道热图, 以概率分布的形式表征SS位置. 训练阶段, 真实关键点位置对应高斯分布生成的热图标签.

1.4 模型训练和优化设置

在组织分割任务中, 模型输出多通道掩膜图, 各通道对应特定组织类别. 损失函数采用交叉熵损失(cross entropy loss)与Dice损失的加权组合(权重比为0.3:0.7). 其中, 交叉熵损失负责优化像素级分类精度, 而Dice损失专注于提升组织边界区域的分割性能. 训练阶段使用RMSprop优化器, 初始学习率设为1×10^{-6}, 总迭代周期为200 epoch, 输入图像按0.5比例缩放. 模型性能通过Dice系数评估, 该指标量化预测掩膜与真实标注之间的空间重叠度.

在关键点定位任务中, 采用Adam优化器进行模型训练, 初始学习率为1×10^{-4}, 训练周期为100 epoch, 图像缩放比例保持0.5. 损失函数选用均方误差(mean squared error, MSE), 通过计算预测热图与真实热图的

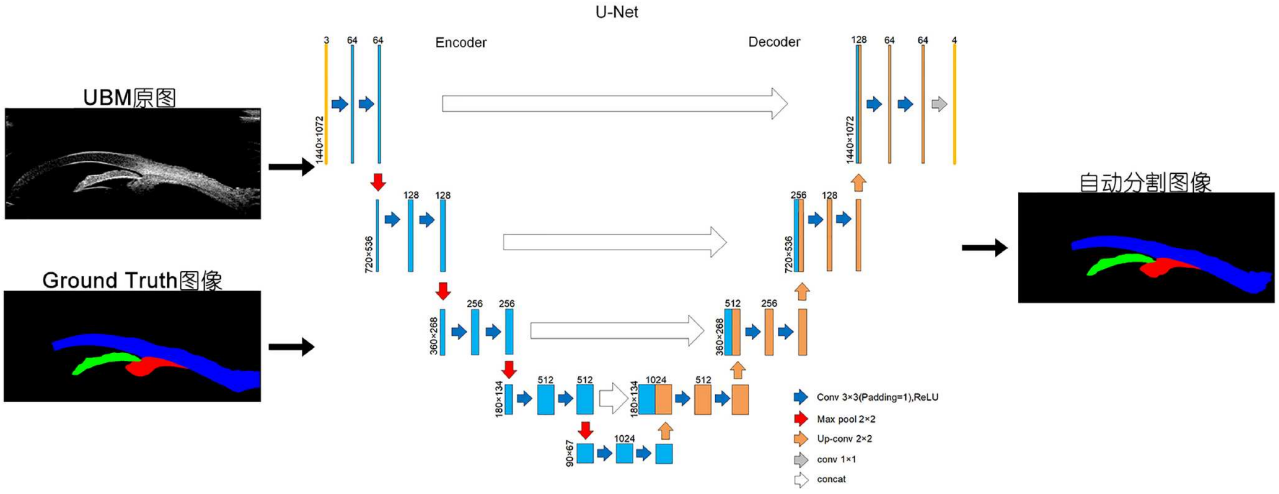


图 2　前节多组织分割模型
Figure 2　Anterior segment multi-tissue segmentation model

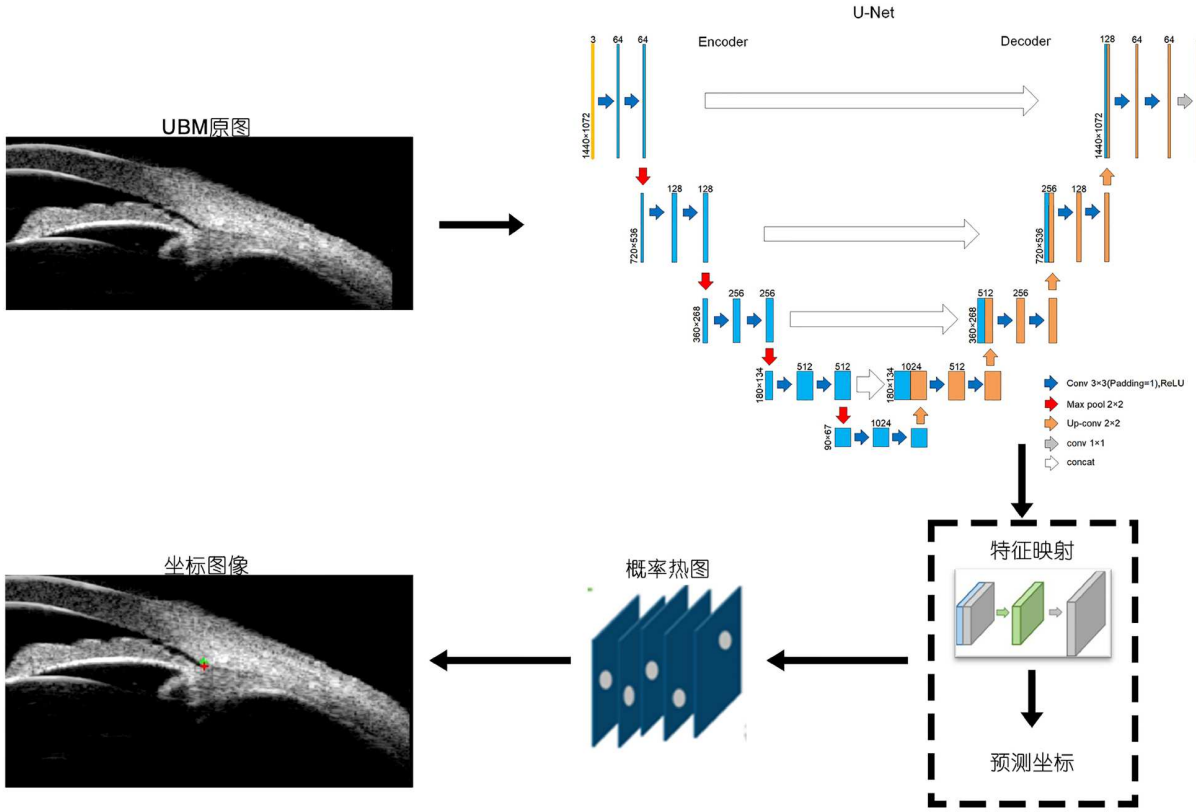


图 3　巩膜突关键点定位模型
Figure 3　Scleral spur key point localization model

像素级差异实现端到端优化.

组织位置感知注意力机制旨在增强模型对细微解剖结构的建模能力，该机制由位置编码注入以及通道-空间注意力(channel-spatial attention)两个阶段构成，如图4所示．我们在U-Net的跳跃连接(skip connection)处引入组织位置感知注意力机制: 对每一层skip特征先注

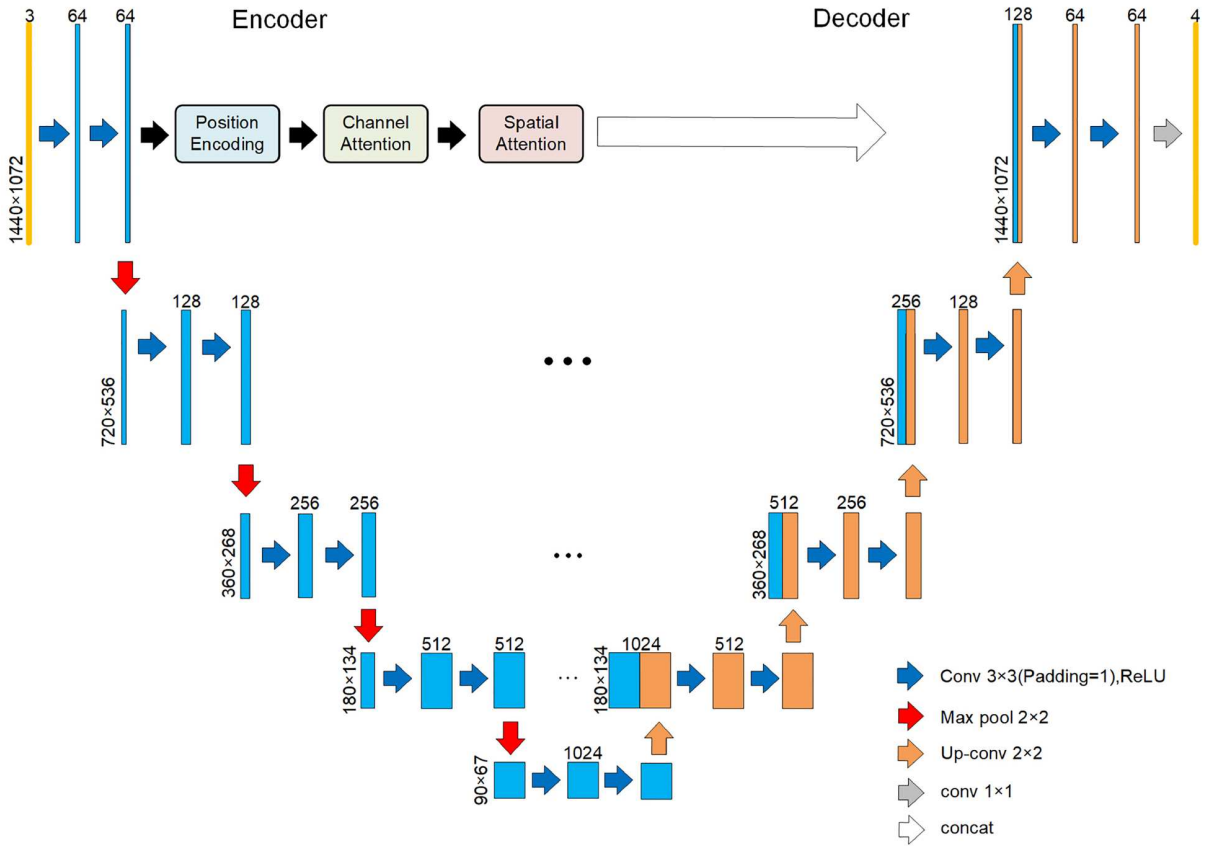


图 4 组织位置感知注意力机制
Figure 4 Organizational location-aware attention mechanism

入水平/垂直方向的可学习位置编码, 再依次施加通道注意力与空间注意力, 得到增强的skip特征$\tilde{F}^{(l)}$, 并与解码器上采样特征拼接融合.

首先, 在位置编码注入(position encoding), 为刻画组织结构在水平/垂直方向上的空间先验, 引入两组可学习位置编码参数:

$$P_H^{(l)} \in \mathbb{R}^{1\times C_l\times M\times 1}, \quad P_W^{(l)} \in \mathbb{R}^{1\times C_l\times 1\times M}, \tag{1}$$

其中M为预设窗口大小. 通过双线性插值将其调整到当前特征分辨率:

$$\widehat{P_H^{(l)}} = \mathrm{Interp}(P_H^{(l)};(H_l,1)), \quad \widehat{P_W^{(l)}} = \mathrm{Interp}(P_W^{(l)};(1,W_l)). \tag{2}$$

然后, 广播到$\mathbb{R}^{B\times C_l\times H_l\times W_l}$, 以加法形式注入特征中:

$$F_{\mathrm{pos}}^{(l)} = F^{(l)} + \widehat{P_H^{(l)}} + \widehat{P_W^{(l)}}. \tag{3}$$

其次, 是通道注意力(channel attention, CA), 对$F_{\mathrm{pos}}^{(l)}$做全局平均池化和全局最大池化:

$$z_{avg} = \mathrm{GAP}(F_{\mathrm{pos}}^{(l)}), \quad z_{max} = \mathrm{GMP}(F_{\mathrm{pos}}^{(l)}), \tag{4}$$

其中z_{avg}、$z_{max} \in \mathbb{R}^{B\times C_l\times 1\times 1}$. 由于全局池化后特征的空间维度为1×1, 通道注意力中的共享MLP在实现上等价于由两层共享的1×1卷积构成, 用以生成通道权重:

$$W_c = \sigma(MLP(z_{avg}) + MLP(z_{max})), \tag{5}$$

其中, $MLP(z) = W_2\delta(W_1 z)$, δ为ReLU, σ为Sigmoid. 最终通道门控为:

$$F_{\mathrm{ca}}^{(l)} = W_c \odot F_{\mathrm{pos}}^{(l)}. \tag{6}$$

最后, 在空间注意力(spatial attention, SA)阶段, 在$F_{\mathrm{ca}}^{(l)}$上沿通道维度计算平均图与最大图:

$$m_{avg} = \mathrm{Mean}_c(F_{\mathrm{ca}}^{(l)}), \quad m_{max} = \mathrm{Max}_c(F_{\mathrm{ca}}^{(l)}), \tag{7}$$

其中m_{avg}、$m_{max} \in \mathbb{R}^{B\times 1\times H_l\times W_l}$. 拼接后经卷积得到空间

权重, 并输出增强特征:

$$W_s = \sigma\left(f^{k\times k}([m_{avg}; m_{max}])\right), \tag{8}$$

$$\tilde{F}^{(l)} = W_s \odot F_{\mathrm{ca}}^{(l)}. \tag{9}$$

1.5 前房角参数自动测量

依据组织自动分割结果和SS自动定位结果对前房角参数进行自动测量. 其参数定义遵循第1.2节的描述. 所有测量过程均采用OpenCV开源计算机视觉库, OpenCV是一种基于Python的通用工具库.

1.6 评价指标与统计分析

在进行人口学参数的组间比较时, 先采用Shapiro-Wilk检验检验定量数据的正态性, 再采用成组t检验进行定量数据的组间比较; 采用卡方检验进行分类数据的组间比较. 在进行UBM测量参数的组间比较时, 先采用Shapiro-Wilk检验检验定量数据的正态性, 再采用线性混合效应模型进行组间比较, 以排除双眼相关性带来的影响. 所有的组间比较均为双侧检验. 针对网络性能评估, 本研究采用了多维度量化策略. 在组织分割任务中, 采用IoU、平均对称表面距离(average symmetric surface distance, ASSD)、95%豪斯多夫距离(Hausdorff distance 95%, HD95)指标作为核心评价标准, IoU是预测分割与真实分割之间的重叠面积与两个分割的并集面积之比, 该指标有效量化平均检测区域覆盖率; ASSD和HD95旨在量化分割结果的边缘贴合度. 在SS定位问题上, 模型性能通过平均欧几里得距离度量, 具体过程是计算预测坐标与人工标记坐标的距离并取均值, 作为定位准确性的直接反映. 对于房角结构参数量化, 为检验人工与深度学习系统测量的一致性, 本研究计算了类内相关系数(intraclass correlation coefficient, ICC)并实施Bland-Altman分析; P值小于0.05时, 判定差异具有统计学意义.

2 结果

2.1 受试者信息

本研究共纳入137例受试者的801张UBM图像样本用于分析. 其中, 对照组包括75例受试者(399张图像), PACD组包含62例患者(402张图像), 两组受试者的人口统计学细节汇总于表1. 在确保测试集独立性的前提下, 以受试者为单位从对照组和PACD组中分别抽取40张图像, 整合为80张的测试集. 剩余样本则构成训练集, 包含对照组和PACD组的图像共计761张.

2.2 图像分割性能

测试集中分别来自对照组和PACD组的两张图像的人工和自动分割结果如图5所示.

以人工分割结果作为参照标准, 本研究模型在分割角膜和巩膜、虹膜及睫状体结构方面的表现如图6所示. 模型分割角膜和巩膜的平均IoU值为0.9325, 虹膜为0.9288, 睫状体则为0.8701. 对比实验中, IoU、ASSD、HD95等指标结果展示了模型在图像多组织分割的性能一致性, 对照组的组织边界分割准确度显著高于PACD组.

2.3 关键点定位性能

如图7所示, 测试集中对照组和PACD组的图像展

表 1 纳入研究的受试者的人口学信息和UBM测量结果

Table 1 Demographic information and UBM measurement results of the patients involved in the research

	对照组	PACD组	P[a)]
受试者数(图像数)	75(399)	62(402)	
年龄	60.04±16.30	64.31±9.64	0.060
性别(男:女)	15:60	11:51	0.737
AOD_{500}(μm)	396.66±250.16	56.15±73.63	**<0.0001**
AOD_{750}(μm)	549.47±355.66	84.35±89.32	**<0.0001**
TIA_{500}(°)	34.83±17.02	6.37±8.07	**<0.0001**
TIA_{750}(°)	35.17±16.79	6.44±6.65	**<0.0001**
$TISA_{500}$(μm^2)	116381.02±64437.48	25100.96±31376.19	**<0.0001**
$TISA_{750}$(μm^2)	233328.39±137686.14	37571.20±51977.37	**<0.0001**
CPA(μm^2)	293020.41±232733.01	582271.06±267128.52	**<0.0001**

a) 加粗数字表示P<0.05; 定量数据格式均为均值±标准差

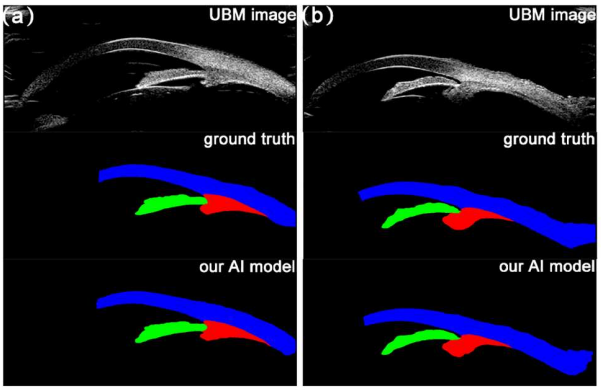


图 5 人工智能模型进行UBM图像多组织分割的代表性结果. (a) 对照组; (b) PACD组

Figure 5 Representative results of the AI model for multi-tissue segmentation in UBM images. (a) Control group; (b) PACD group

示了人工SS位置标注(红色标记)与模型预测SS位置(绿色标记)的对比结果. 模型在SS定位任务中的性能指标详见图6. 在总测试集上, 模型预测值与真实值间的平均误差距离为6.12像素(94.12 μm), 且77.5%的案例误差小于100 μm, 88.75%小于150 μm. 此外, 对照组在SS定位任务中的准确度显著高于PACD组.

2.4 前房角参数自动测量性能

在测试集中, 采用随机数法从对照组和PACD组各抽取20例图像用于评估前房角参数自动测量性能. 采用双向随机效应模型的绝对一致性ICC和Bland-Altman方法分析人工测量结果与自动化方法结果的一致性, 结果见图8. 所有参数的ICC值均大于0.93, 且绝大多数测量值分布在95%一致性界限以内.

2.5 消融实验

为了验证各模块对模型整体性能的具体贡献度, 我们围绕分割任务开展了一系列消融实验, 实验结果如表2所示. 实验结果表明, 各组织的分割任务中, 随着删除位置特征、注意力机制, 所提模型性能逐步降低并具有一致性, 且注意力机制相比于位置特征发挥了

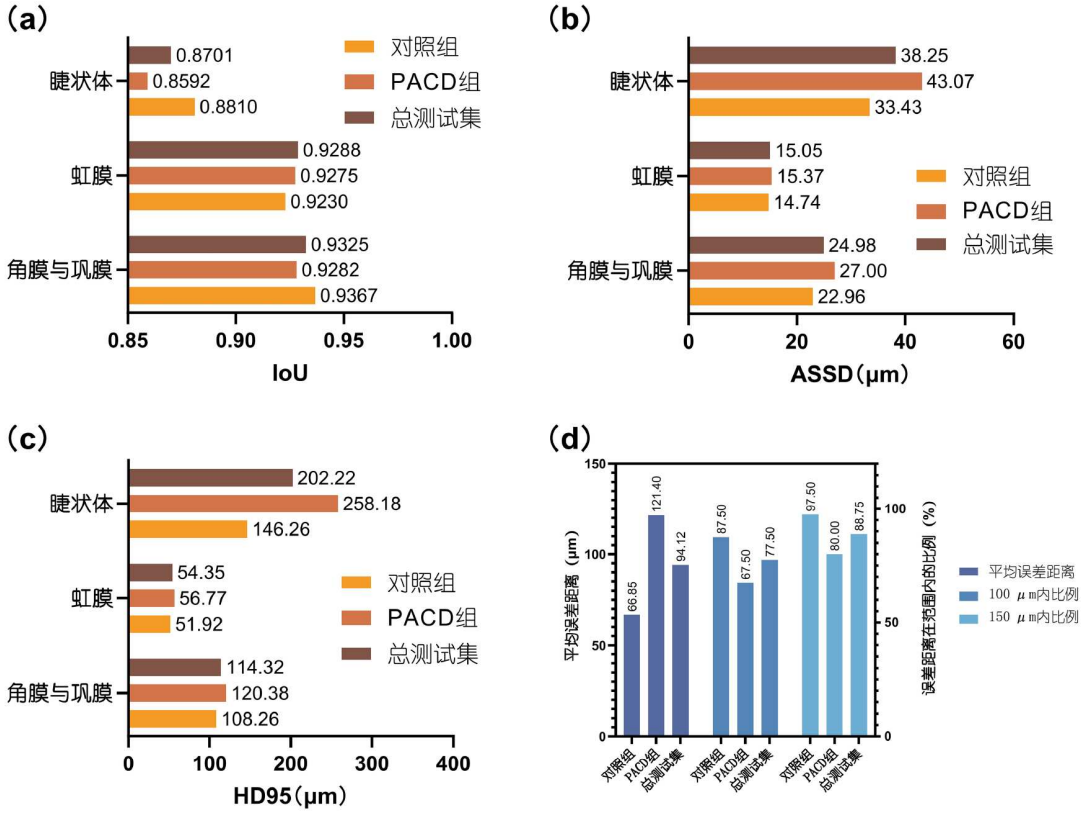


图 6 人工智能模型的图像分割(a~c)和巩膜突定位性能(d)

Figure 6 Image segmentation performance (a–c) and SS localization performance (d) of the artificial intelligence model

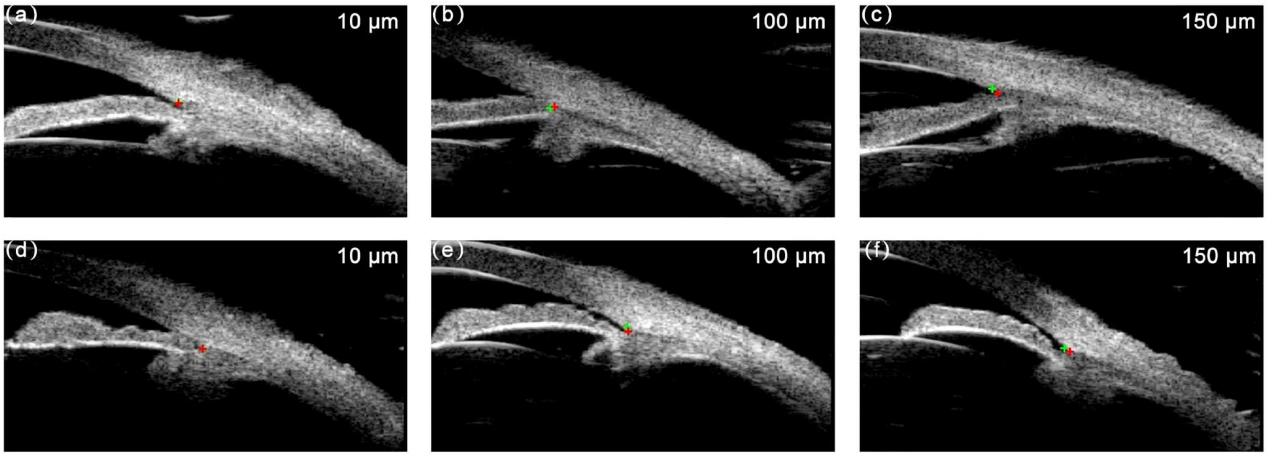


图 7 人工智能模型进行巩膜突定位误差距离不同的代表性结果. (a~c) 对照组; (d~f) PACD组

Figure 7 Representative results of the AI model for scleral spur localization with varying error distances. (a–c) Control group; (d–f) PACD group

表 2 消融实验结果[a)]

Table 2 Ablation experiment results

	角膜/巩膜IoU	虹膜IoU	睫状体IoU
原始U-Net	0.9228±0.0006	0.9004±0.0024	0.8327±0.0022
删除-注意力机制	0.9272±0.0007	0.9101±0.0024	0.8467±0.0015
删除-位置特征	0.9293±0.0005	0.9193±0.0010	0.8579±0.0019
本研究方法	0.9325±0.0007	0.9288±0.0014	0.8701±0.0009

a) 数据格式均为均值±标准差

更大的作用. 此外, 通过与原始U-Net模型的比较, 也证明了所提模型中位置感知注意力机制的有效性.

2.6 系统运行效率

为评估本研究提出的算法运行效率，我们设计了对比实验，通过UBM单张图像处理时间的统计数据分析人工与模型方法的差异，结果详见表3. 在典型任务中，人工图像分割平均耗时约60 s、标注SS约为5 s、前房角参数测量则接近300 s；相较之下，基于U-Net的优化模型在同一场景下分别仅需0.36、0.08和0.67 s. 这种时间效率的显著提升表明，算法能够在保障精度的前提下显著加速处理流程，从而契合临床应用中对实时或准实时性能的需求.

在系统效率与算法精度的综合评估中，本研究选取标准U-Net、U-Net++、U-Net3Plus及TransU-Net作为基线模型，从参数量、推理时间及任务特异性精度三个维度进行对比分析. 其中，巩膜突定位任务以150 μm命中率为评价指标，组织分割任务则采用IoU. 实验结果(表4)表明，不同模型在精度与效率之间存在明显权衡关系，而本文所提方法在两者之间取得了较为均衡的性能表现. 具体而言，在模型复杂度方面，本文方法的参数量为32.07M，与标准U-Net(31.04M)处于相近水平，明显低于U-Net++(36.63M)及TransU-Net (68.45M)，体现了良好的轻量化特性. 在推理效率方面，本文方法在巩膜突定位与组织分割任务中的平均推理时间分别为0.0839 s与0.3571 s，虽未达到最快水平，但仍满足临床实时应用的基本需求. 在精度方面, TransU-Net与本文方法在巩膜突定位任务中均取得了最高命中率(0.8825), 然而, TransU-Net为此引入了显著更高的模型复杂度，其参数量约为本文方法的两倍(68.45M和32.07M). 尽管其在部分任务中的推理时间表现并非始终最慢，但整体计算开销仍显著增加. U-Net++与U-Net3Plus在分割任务中表现出更高的IoU(分别为0.9124和0.9130), 但其定位性能相对较弱, 且模型复杂度较高. 相比之下, 本文方法在保持较低模型复杂度的同时，在定位与分割任务中均取得了较为均衡的

性能表现, 体现出更为均衡的综合性能. 上述结果表明, 模型参数规模与性能提升并非简单的线性关系, 过于复杂的结构未必能够带来稳定的性能增益, 反而可能导致计算成本显著增加. 因此, 在实际临床应用中, 兼

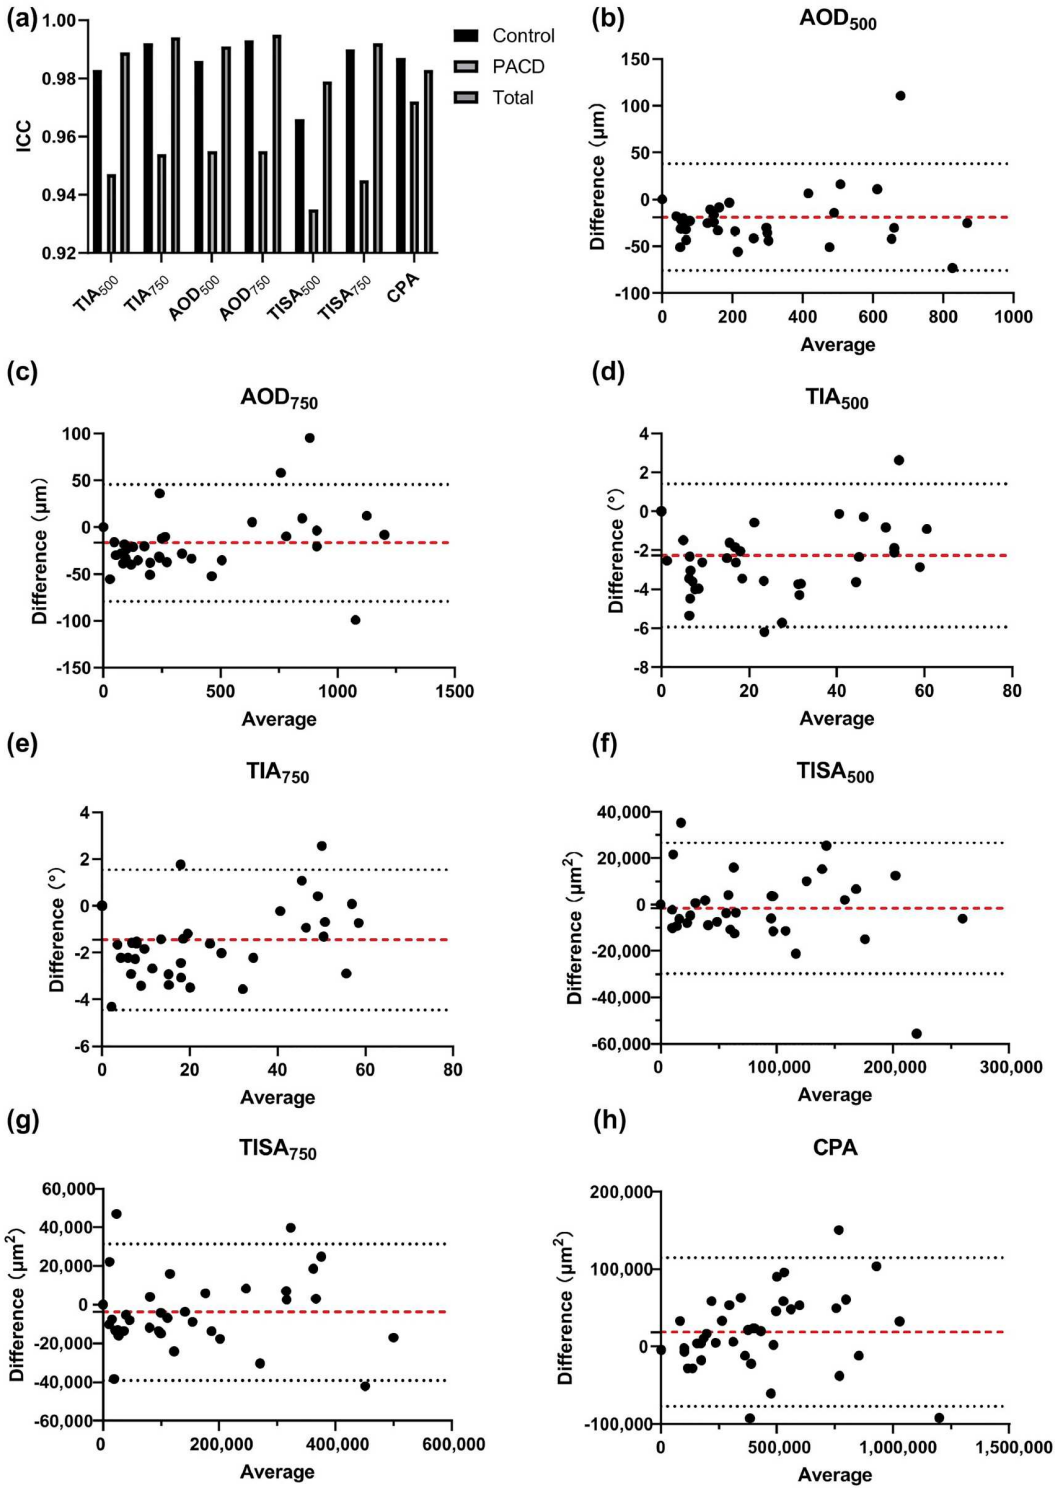


图 8 (网络版彩色)前房角参数人工测量与自动测量结果的ICC(a)和Bland-Altman分析(b~h)

Figure 8 (Color online) (Online Color) ICC (a) and Bland-Altman analysis (b–h) of manual versus automated measurements for anterior chamber angle parameters

表 3 单张UBM图像处理时间对比[a)]

Table 3 Comparison of manual and model processing time per UBM image

任务	人工处理时间(s)	模型处理时间(s)
图像分割	60	0.36±0.0090
关键点定位	5	0.08±0.0014
前房角参数测量	300	0.67±0.0151

a) 模型处理时间数据格式为均值±标准差

表 4 多种模型的组织分割和巩膜突定位精度与效率[a)]

Table 4 Accuracy and efficiency of multiple models in tissue segmentation and scleral spur localization

	参数量(M)	巩膜突定位任务		组织分割任务	
		推理时间(s)	150 μm命中率	推理时间(s)	IoU
U-Net	31.04	**0.0612±0.0008**	0.8450±0.0108	0.3467±0.0084	0.8853±0.0005
U-Net ++	36.63	0.0942±0.0008	0.8500±0.0105	**0.1066±0.0003**	0.9124±0.0007
U-Net3plus	**26.98**	0.1231±0.0014	0.8525±0.0072	0.1332±0.0006	**0.9130±0.0008**
TransU-Net	68.45	0.2006±0.0028	0.8825±0.0132	0.2067±0.0009	0.9089±0.0007
本研究方法	32.07	0.0839±0.0014	**0.8825±0.0083**	0.3571±0.0090	0.9104±0.0090

a) 加粗, 最优结果; 推理时间和150 μm命中率数据格式均为均值±标准差

顾效率与精度的模型设计更具应用价值.

3 讨论

基于深度学习算法，本研究研发了一套UBM图像自动处理系统, 用于对正常人及PACD患者进行前房角组织分割、SS定位及关键参数测量. 该系统在以下任务中表现优异: 前房角结构分割任务中，角膜和巩膜、虹膜与睫状体区域的IoU均超过0.87; SS定位任务中, 自动定位与人工标注的平均位置偏差为94.12 μm; 前房角参数测量任务中，系统自动测量结果与人工测量值呈高度一致性.

UBM和眼前节光学相干断层扫描(anterior segment optical coherence tomography, AS-OCT)作为评估眼前部结构的核心影像学技术，在临床诊断中占据主导地位[16]. 近年来, 基于深度学习的AS-OCT图像自动化处理已逐渐成熟，其在多领域应用中的稳健性获得广泛验证[17~19]. 然而，AS-OCT的光学信号穿透能力有限, 在以PACD为代表的房角相关疾病诊疗中难以全面满足临床需求[20]. 为弥补这一短板, 研究者尝试利用生成对抗网络将AS-OCT图像转换为UBM图像，但合成结果中虹膜睫状体参数的测量值与真实UBM影像存在显著偏差，这凸显了UBM影像的独特价值[21]. 尽管如此, 相较于AS-OCT图像，UBM图像质量常因伪影增多和位姿一致性差而受限，这种固有特性大幅增加了深度学习自动处理模型的构建难度.

本研究对深度学习模型在UBM图像的前房角研究中取得的结果进行了整合总结, 详见表5. 目前, 深度学习模型在UBM图像分类任务中的性能已趋于稳定，尤其能高效区分开角、窄角和闭角类型[22]，以及有晶体眼、人工晶状体眼和无晶体眼病例[23]. 例如, 基于Efficient-NetB3架构的卷积神经网络成功应用于SS关键点定位任务，实现*X*轴与*Y*轴方向平均误差分别为48.06和30.84 μm[13]. 本研究在较小训练集条件下通过多策略优化，取得了可比较的定位精确度. 模型在PACD患者图像中同样实现了可靠SS定位，但其定位精度不如正常受试者图像, 主要原因是PACD患者SS的可视性和解剖位置因虹膜前移、睫状体前旋等病理改变而变得模糊或异常，增加了定位难度. 增加训练集PACD患者图像数量及优化注意力机制将有效提高PACD患者SS定位的准确性. 在组织分割领域, 先前利用大样本训练的UNet++模型已展现出平均IoU达0.877的分割效能[10]. 通过架构创新, 本研究改进了多组织分割模型: 角膜/巩膜与虹膜部分的分割IoU值均超过0.92，而睫状体分割平均IoU也达到0.87. 睫状体分割的准确度与另外两部分相比不够理想，这可能源于睫状体解剖面积较小且连接结构更复杂. 此外, 深度学习模型被广泛应用于前房角参数的定量测定. 既往研究聚焦TIA、TISA和AOD等关键参数以评估房角开放程度. 虽然部分工作

表 5 以前房角相关参数为研究对象使用深度学习技术处理UBM图像的研究结果总结[a)]

Table 5 Summary of research results on deep-learning-based analysis of anterior chamber angle parameters in UBM images

文献	模型	训练集	任务类型	任务内容	评价指标	结果
Li等人[24]	ResNet-18	511(开角:窄角=1:1)	测量	TIA	ICC	0.95
Wang等人[13]	EfficientNet-B3	2328(开角)	定位	SS	误差距离	60.41 μm
Wang等人[9]	InceptionV3	2265(开角:闭角=1285:982)	分类	房角关闭	准确率	98.18%
	EfficientNet-B3		定位	SS	误差距离	65.19 μm
				AR		43.32 μm
	U-Net		测量	TIA_{500}	ICC	0.985
				TIA_{750}		0.989
				AOD_{500}		0.971
				AOD_{750}		0.982
				ARA_{500}		0.939
				ARA_{750}		0.960
Jiang等人[10]	U-Net++	1576(闭角)	分割	虹膜	IoU	0.877
				角膜、巩膜		0.823
				睫状体		0.778
	SVM	3744(闭角)	分类	虹膜高褶	AUC	0.942
	LR	2940(闭角)		基底型虹膜附着		0.966
	SVM	4150(闭角)		房角关闭		0.983
	–	849(闭角)	定位	SS(闭角)	误差距离	106.343 μm
				SS(开角)		71.714 μm
			测量	TIA_{500}	ICC	0.985
				TIA_{750}		0.989
				AOD_{500}		0.989
				AOD_{750}		0.992
				ARA_{500}		0.964
				ARA_{750}		0.977
				$TISA_{500}$		0.984
				$TISA_{750}$		0.989
				IT_{500}(开角)		0.884
				IT_{500}(闭角)		0.925
				CT(开角)		0.967
				CT(闭角)		0.945
Li等人[12]	ASM-Net	2017(开角:闭角=515:1502)	分割	角膜	IoU	0.98
				虹膜		0.98
				睫状体		0.98
			定位	SS	误差距离	26.75 μm
				TCA		0.99
			测量	AOD_{500}	ICC	0.92
				虹膜面积		0.99
Cheng等人[11]	EfficientNet	376(开角:闭角=124:252)	分类	伴/不伴悬韧带异常的APAC发作	AUC	0.9046

a) TIA(trabecular iris angle), 小梁虹膜角; ICC(intraclass correlation coefficient), 类内相关系数; SS(scleral spur), 巩膜突; AR(angle recess), 房角隐窝; TIA(trabecular iris angle), 小梁虹膜角; AOD(angle-opening distance), 房角开放距离; ARA(angle recess area), 房角隐窝面积; IoU (intersection over union), 交并比; AUC(area under curve), 受试者工作特征曲线下面积; TISA(trabecular iris space area), 小梁虹膜间面积; IT(iris thickness), 虹膜厚度; CT(cornea thickness), 角膜厚度; TCA(trabecular ciliary angle), 小梁睫状突角; APAC(acute primary angle closure), 急性原发性房角关闭

使用卷积神经网络直接输出TIA(ICC值0.95)[24]，但多数方法(包括本研究)优先通过SS定位与组织分割生成中间结果，再用算法计算参数，提升测定一致性至0.97以上[9,10]. 本研究在有限训练数据下进一步优化了参数测定精度，对照组图像中所有参数自动测定结果的ICC超过0.96. 相比之下，PACD组由于前房角狭窄、睫状体前旋等病理特征，其测量精度略低，但模型仍表现出稳健的适应性. 值得注意的是，除上述核心参数外，反映房角关闭机制的指标如CPA也受到关注，增大的CPA意味着睫状体前旋，进而推挤虹膜和晶体向前移位[15]. 本研究开创性地实现UBM图像上CPA的自动测量，与人工作业对比的ICC达0.98. 这一突破克服了参数边界不规则点和位点难定义等技术瓶颈，显著扩展了UBM自动测量系统的功能覆盖面. 睫状体的精确成像是眼前部成像的一大难点，光学方法无法观察到隐藏于虹膜后方的睫状体，声学方法也因深度过深而存在更多伪影. 因此，本研究所搭建的模型分割睫状体的准确性仍不够理想(IoU值0.87). 然而，本研究所搭建模型的CPA测量准确性仍比较可观，这可能表明睫状体分割的主要误差来源于睫状体与巩膜的交界面以及后方的睫状体平坦部，对睫状突的影响不大.

基于超声生物显微镜图像的前房角定量参数测量在临床常规应用中仍面临局限性，主要原因在于其操作复杂性较高. 然而，此类定量参数对PACD的诊断、预后评估、疗效监测及发病机制探究具有显著临床价值. 例如，相关研究表明，急性与慢性闭角型青光眼在AOD和TIA等关键指标上存在显著差异[25]；同时，TIA还被证实为浅前房患者在行白内障术后房角开放的可靠预测因素[26]. 此外，前房角参数已用于白内障手术与激光周边虹膜切除术等干预手段的疗效比较分析[27]. 值得关注的是，这些参数不仅适用于PACD，也能拓展至开角型青光眼[28]、新生血管型青光眼[29]等其他青光眼亚型的评估与治疗反应预测. 本研究如能实现临床转化，将有望在临床实践中提供实时或准实时的参数测量，而UBM图像中的房角参数与PACD患者的治疗反应和预后密切相关. 因此，在高效的参数测量的基础上，实时进行更准确的治疗决策和疗效预测成为可能. 当前的PACD诊疗策略中，无论是随访观察还是激光预防，都是医师基于自身经验作出的决策，个体特异性较差. 高效的参数测量将帮助医师更准确地认知PACD患者的房角关闭程度、房角关闭机制以及可能的治疗效果，从而有力支持PACD的诊疗向个性化、精准化方向转变.

本研究于通过轻量化设计、多任务整合及参数创新，实现了高效、系统且临床实用的UBM自动分析. 不同于多数研究聚焦分类、分割或定位等单一任务，本研究构建了集组织分割、SS定位与多参数测量于一体的自动化系统，实现了全流程分析. 相较于TransU-Net等参数量庞大的复杂变体，本研究基于标准U-Net引入轻量化的位置感知注意力机制，在保持高精度的同时参数量显著降低. 本研究首次在UBM上实现了CPA的自动测量，突破了既往研究多限于前房角开放参数的局限，为机制探究提供了新维度. 在训练数据量相对较小的情况下，系统在PACD患者图像上仍表现稳健，验证了模型对复杂病理结构的适应性.

本研究面临一系列局限. PACD患者的巩膜突定位相较于健康人群更具挑战性，加之其前房结构普遍拥挤，这一状况不仅引发组织分割误差增加，还对SS定位造成显著高于对照组的偏差；同时，由于PACD个体的AOD、TIA和TISA值普遍较小，自动测量的相对误差随之增大. 然而，PACD群体是UBM观察的核心对象. 针对这些问题，未来研究亟需拓展样本规模并重构算法模型，以实现更可靠的诊断手段优化. 此外，研究在PACD诊断和人工处理UBM图像的操作过程中存在不规范之处，可能引入了一定的诊断偏倚和测量误差，在增大样本量和优化算法模型过程中需要进一步控制.

4 结论

本研究开发了一种基于深度学习的方法，用于UBM图像中的眼前节多组织分割、 SS检测和前房角参数定量评估. 实验结果显示，该系统实现了对正常人群及PACD患者图像的自动SS识别，并对角膜、巩膜、虹膜和睫状体区域进行高精度分割. 同时，该方法自动化定量评估了多个关键前房角参数，包括AOD_{500}、AOD_{750}、$TISA_{500}$、$TISA_{750}$、TIA_{500}、TIA_{750}及CPA，实测结果与人工测量保持较高一致性. 由此，本方案在UBM影像的临床应用与科学研究中具有显著价值.

参考文献

1 Foster P J. The definition and classification of glaucoma in prevalence surveys. Br J Ophthalmol, 2002, 86: 238–242

2 Xu B Y, Friedman D S, Foster P J, et al. Ocular biometric risk factors for progression of primary angle closure disease. Ophthalmology, 2022, 129: 267–275
3 Bourne R R A. Prevalence of glaucoma in Thailand: a population based survey in Rom Klao District, Bangkok. Br J Ophthalmol, 2003, 87: 1069–1074
4 Sun X, Dai Y, Chen Y, et al. Primary angle closure glaucoma: what we know and what we don't know. Prog Retinal Eye Res, 2017, 57: 26–45
5 Song P, Wang J, Bucan K, et al. National and subnational prevalence and burden of glaucoma in China: a systematic analysis. J Glob Health, 2017, 7: 020705
6 Chansangpetch S, Rojanapongpun P, Lin S C. Anterior segment imaging for angle closure. Am J Ophthalmol, 2018, 188: xvi–xxix
7 Yang K, Liang Z, Lv K, et al. Anterior segment parameter changes after cataract surgery in open-angle and angle-closure eyes: a prospective study. J Clin Med, 2023, 12: 327
8 Lv K, Liang Z, Yang K, et al. Novel discoveries of the relationship between the vitreous zonule and the anterior segment characteristics in eyes with primary angle-closure disease. Invest Ophthalmol Vis Sci, 2022, 63: 16
9 Wang L, Zhang Y, Wei Z, et al. Characteristics of toxic keratopathy, an *in vivo* confocal microscopy study. Trans Vis Sci Tech, 2021, 10: 11
10 Jiang W, Yan Y, Cheng S, et al. Deep learning-based model for automatic assessment of anterior angle chamber in ultrasound biomicroscopy. Ultrasound Med Biol, 2023, 49: 2497–2509
11 Cheng L, Hong J, Chen H, et al. Deep learning-based automatic differentiation of acute angle closure with or without zonulopathy using ultrasound biomicroscopy: a comparison of diagnostic performance with ophthalmologists. BMJ Open Ophth, 2025, 10: e002114
12 Li F, Zhang X, Yang K, et al. Deep learning-based anterior segment identification and parameter assessment of primary angle closure disease in ultrasound biomicroscopy images. BMJ Open Ophth, 2025, 10: e001600
13 Wang W, Wang L, Wang T, et al. Automatic localization of the scleral spur using deep learning and ultrasound biomicroscopy. Trans Vis Sci Tech, 2021, 10: 28
14 Moghimi S, Vahedian Z, Fakhraie G, et al. Ocular biometry in the subtypes of angle closure: an anterior segment optical coherence tomography study. Am J Ophthalmol, 2013, 155: 664–673.e1
15 You S, Liang Z, Yang K, et al. Novel discoveries of anterior segment parameters in fellow eyes of acute primary angle closure and chronic primary angle closure glaucoma. Invest Ophthalmol Vis Sci, 2021, 62: 6
16 Salim S, Dorairaj S. Anterior segment imaging in glaucoma. Semin Ophthalmol, 2013, 28: 113–125
17 Li W, Chen Q, Jiang C, et al. Automatic anterior chamber angle classification using deep learning system and anterior segment optical coherence tomography images. Trans Vis Sci Tech, 2021, 10: 19
18 Yao H, Wang X, Suo Y, et al. Primary angle-closed diseases recognition through artificial intelligence-based anterior segment-optical coherence tomography imaging. Graefes Arch Clin Exp Ophthalmol, 2025, 263: 1081–1087
19 Olyntho M A C, Jorge C A C, Castanha E B, et al. Artificial intelligence in anterior chamber evaluation: a systematic review and meta-analysis. J Glaucoma, 2024, 33: 658–664
20 Salim S. The role of anterior segment optical coherence tomography in glaucoma. J Ophthalmol, 2012, 2012: 1–9
21 Ye H, Yang Y, Mao K, et al. Generating synthesized ultrasound biomicroscopy images from anterior segment optical coherent tomography images by generative adversarial networks for iridociliary assessment. Ophthalmol Ther, 2022, 11: 1817–1831
22 Shi G, Jiang Z, Deng G, et al. Automatic classification of anterior chamber angle using ultrasound biomicroscopy and deep learning. Trans Vis Sci Tech, 2019, 8: 25
23 Le C, Baroni M, Vinnett A, et al. Deep learning model for accurate automatic determination of phakic status in pediatric and adult ultrasound biomicroscopy images. Trans Vis Sci Tech, 2020, 9: 63
24 Li W, Chen Q, Jiang Z, et al. Automatic anterior chamber angle measurement for ultrasound biomicroscopy using deep learning. J Glaucoma, 2020, 29: 81–85
25 Yu Z, Wang X, Wang H, et al. Ultrasound biomicroscopic imaging analysis of lens position and stability in acute and chronic angle-closure glaucoma. Front Ophthalmol, 2025, 5: 1624876
26 Fu Y, Chen Y, Li X, et al. Risk factors of angle opening after lens extraction in patients with shallow peripheral anterior chamber. Graefes Arch Clin Exp Ophthalmol, 2025, 263: 1957–1965
27 Yan C, Yu Y, Wang W, et al. Long-term effects of mild cataract extraction versus laser peripheral iridotomy on anterior chamber morphology in primary angle-closure suspect eyes. Br J Ophthalmol, 2024, 108: 812–817
28 Kesim C. Ultrasound biomicroscopic (UBM) evaluation of anterior segment parameters and surgical area following trabeculectomy surgery. Beyoglu Eye J, 2020, doi: 10.14744/bej.2020.14622
29 Guo L, Liu Y, Huang X, et al. Anterior segment features in neovascular glaucoma: an ultrasound biomicroscopy study. Eur J Ophthalmol, 2025, 35: 214–220

Summary for “基于双模块U-Net深度学习技术定量评估超声生物显微镜下的闭角房角参数”

Quantitative evaluation of angle-closure parameters in ultrasound biomicroscopy based on dual-module U-Net deep learning technology

Fengrui Yang[1], Bohui Wang[2], Kun Lü[1], Yitong Hu[1], Xiang Meng[1], Zeyu He[2*] & Huijuan Wu[1*]

[1] *Department of Ophthalmology, Peking University People's Hospital, Beijing 100044, China*
[2] *Department of Computer Science and Technology, School of Computer Science, Beijing Information Science and Technology University, Beijing 100101, China*
* Corresponding authors, E-mail: 20222638@bistu.edu.cn; dr_wuhuijuan@126.com

This study developed and validated a deep learning-based automated analysis system for quantifying anterior chamber angle parameters from ultrasound biomicroscopy (UBM) images in the context of primary angle closure disease (PACD). UBM is a crucial imaging modality that provides high-resolution visualization of the anterior segment, essential for assessing the anatomical risk factors associated with PACD progression. The proposed system was designed to automate the measurement of key angle parameters, addressing the limitations of time-consuming and subjective manual assessments. The model architecture was built upon the U-Net convolutional neural network, implemented through two dedicated modules: one for the semantic segmentation of anterior segment tissues and another for the precise localization of the scleral spur, a critical anatomical landmark for angle parameter calculation. Following successful segmentation and localization, computer vision algorithms were employed to automatically compute a comprehensive set of clinically relevant angle parameters, including the trabecular iris angle, angle-opening distance, trabecular iris space area, and ciliary process area. The system was trained and evaluated using a dataset comprising UBM images from both normal control subjects and patients diagnosed with PACD. Performance evaluation demonstrated the system's high accuracy and reliability. The segmentation module achieved excellent mean Intersection over Union scores for key structures: 0.93 for the cornea-sclera, 0.93 for the iris, and 0.87 for the ciliary body. The scleral spur localization module exhibited a low mean error of 94.12 μm. Most importantly, the agreement between the system's automated parameter measurements and manual annotations by experts was exceptionally high, as evidenced by intraclass correlation coefficient values exceeding 0.97 for all measured parameters. These results indicate a strong concordance between the automated system and human expert assessment. The developed automated system demonstrates significant potential to enhance the efficiency and objectivity of UBM image analysis in both clinical practice and research for PACD. By providing rapid, consistent, and quantitative assessments of angle anatomy, it can aid in the diagnosis, risk stratification, and management of angle closure diseases, ultimately supporting more personalized treatment strategies.

deep learning, computer vision, image segmentation, primary angle closure disease, ultrasound biomicroscopy

doi: 10.1360/CSB-2025-5174