



计算机科学

COMPUTER SCIENCE

基于深度学习的OCT/OCTA视网膜图像分析方法综述

薛静艳, 夏佳楠, 霍蕊莉, 刘杰, 周雪忠

引用本文

薛静艳, 夏佳楠, 霍蕊莉, 刘杰, 周雪忠. 基于深度学习的OCT/OCTA视网膜图像分析方法综述[J]. 计算机科学, 2026, 53(1): 128-140.

XUE Jingyan, XIA Jianan, HUO Ruili, LIU Jie, ZHOU Xuezhong. [Review of Retinal Image Analysis Methods for OCT/OCTA Based on Deep Learning](#) [J]. Computer Science, 2026, 53(1): 128-140.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[EvR-DETR:融合事件与RGB图像的轻量级端到端目标检测](#)

EvR-DETR:Event-RGB Fusion for Lightweight End-to-End Object Detection

计算机科学, 2026, 53(1): 153-162. <https://doi.org/10.11896/jsjcx.250300021>

[基于KAN的无监督多元时间序列异常检测网络](#)

KAN-based Unsupervised Multivariate Time Series Anomaly Detection Network

计算机科学, 2026, 53(1): 89-96. <https://doi.org/10.11896/jsjcx.241200190>

[图嵌入学习研究综述:从简单图到复杂图](#)

Review of Graph Embedding Learning Research:From Simple Graph to Complex Graph

计算机科学, 2026, 53(1): 58-76. <https://doi.org/10.11896/jsjcx.250300081>

[基于异构图和指令序列的智能合约字节码漏洞检测方法](#)

Smart Contract Bytecode Vulnerability Detection Method Based on Heterogeneous Graphs and Instruction Sequences

计算机科学, 2025, 52(12): 367-373. <https://doi.org/10.11896/jsjcx.241100076>

[人工智能在金融领域的预测方法综述](#)

Survey of Data Prediction Methods Using Artificial Intelligence in the Financial Sector

计算机科学, 2025, 52(12): 271-284. <https://doi.org/10.11896/jsjcx.250700166>

基于深度学习的 OCT/OCTA 视网膜图像分析方法综述

薛静艳¹ 夏佳楠¹ 霍蕊莉² 刘杰¹ 周雪忠¹

1 北京交通大学计算机科学与技术学院 北京 100044

2 中国中医科学院 北京 100700

(23111129@bjtu.edu.cn)

摘要 深度学习是人工智能的一个分支,其依赖深度神经网络进行数据处理与分析。近年来,深度学习在医学影像领域,尤其在图像分类、分割及疗效评估方面取得了显著突破。在眼科领域,应用深度学习技术高效、准确分析光学相干断层扫描成像(Optical Coherence Tomography,OCT)和光学相干断层扫描血管成像(Optical Coherence Tomography Angiography,OCTA)的需求日益增加。相比传统的手工方法,深度学习方法在处理复杂眼底结构和病理变化时展现出更高的精度和更强的自动化能力。然而,以往的综述多侧重于单一成像模式或单一任务的研究,往往忽视了不同成像技术之间的相关性以及任务间的承接性和关联性。对此,不仅详细总结了常用数据集,系统回顾了基于不同 OCT 和 OCTA 设备的视网膜相关疾病生物标志物的分割方法,还从不同疾病特性的角度总结了视网膜相关疾病的典型分类方法。最后,从数据隐私与安全性、模型可解释性,以及模型通用性等角度展望了未来的研究方向,为后续研究提供了有价值的参考。

关键词: OCT/OCTA;深度学习;生物标志物;图像分割;疾病分类

中图分类号 TP391

Review of Retinal Image Analysis Methods for OCT/OCTA Based on Deep Learning

XUE Jingyan¹, XIA Jianan¹, HUO Ruili², LIU Jie¹ and ZHOU Xuezhong¹

1 School of Computer Science and Technology, Beijing Jiaotong University, Beijing 100044, China

2 Academy of Chinese Medical Sciences, Beijing 100700, China

Abstract Deep learning is a branch of artificial intelligence that relies on deep neural networks for data processing and analysis. In recent years, deep learning has made significant breakthroughs in the field of medical imaging, especially in image classification, segmentation and efficacy evaluation. In the field of ophthalmology, there is an increasing need to apply deep learning techniques for efficient and accurate analysis of OCT and OCTA. Compared with traditional manual methods, deep learning methods show higher accuracy and automation in dealing with complex fundus structure and pathological changes. However, most of the previous reviews focus on single imaging mode or single task research, and often ignore the correlation between different imaging technology, as well as the acceptability and correlation between tasks. This paper not only summarizes the commonly used data sets, systematically reviews the segmentation methods of retina-related disease biomarkers based on different OCT and OCTA devices, but also summarizes the typical classification methods of retina-related diseases from the perspective of different disease characteristics. Finally, this paper also looks forward to the future research direction from the perspectives of data privacy and security, model interpretability, and model universality, which provides a valuable reference for subsequent research.

Keywords OCT/OCTA, Deep learning, Biomarkers, Image segmentation, Classification of diseases

1 引言

眼健康状况在不同地区和人群中存在差异,但总体而言,眼健康已成为全球关注的焦点问题。数据显示,截至 2019 年,全球约有 7.1 亿人受到各种眼科疾病的影响,这些疾病包

括青少年近视、年龄相关性黄斑变性,以及视神经性疾病等。眼科疾病已经成为一项不容忽视的健康问题,它不仅导致患者生活质量下降,还给社会经济带来沉重负担^[1]。医学影像在眼科诊疗中发挥着关键作用,通过多种成像技术,如眼底摄影、眼部超声、光学相干断层扫描成像(OCT)以及光学相干断

到稿日期:2024-11-07 返修日期:2025-03-14

基金项目:中央高校基本科研业务费(2024JBMC007);国家重点研发计划(2023YFC3502604,2022YFC2403902)

This work was supported by the Fundamental Research Funds for the Central Universities(2024JBMC007) and National Key Research and Development Program of China(2023YFC3502604,2022YFC2403902).

通信作者:夏佳楠(xiain@bjtu.edu.cn)

层扫描血管成像(OCTA)等,医生能够详细观察眼部结构,从而精确诊断眼部疾病、制定个性化治疗方案,成像技术还能辅助医生在治疗过程中进行有效的监控与评估^[2]。相对于眼底摄影、眼部超声等成像技术,OCT 和 OCTA 具有无创且高分辨率成像的能力,能客观、定量地反映眼底的 3D 结构,提供眼科疾病中极其重要的细节信息,尤其在视网膜结构和血流动力学分析方面具有无可比拟的优势。因此,本文结合成像特点、临床应用广泛性、技术发展趋势等因素,聚焦于 OCT 和 OCTA 技术,分析其在当前眼科诊断和治疗中的临床价值。

OCT 是一种非侵入式成像技术,通过检测参考镜反射信号与生物组织后向散射信号之间的干扰信号生成高分辨率的活体组织结构图像^[3]。OCT 技术能够客观、定量地可视化眼球结构。例如,利用图像处理方法对视网膜进行分层和分割,并进行横断面形态分析,提供精确的厚度测量和更详细的病理评估^[4]。OCTA 是 OCT 的一种技术变体,通过运动对比在无创条件下提供血管结构和血流信息。OCTA 能够精确量化视网膜微血管系统的血流信息,准确呈现视网膜疾病特征,为临床研究和诊断提供新工具^[5-6]。视网膜组织的异常与多

种疾病密切相关,包括眼科疾病、神经退行性疾病和血管性疾病等,尤其是在中枢神经系统疾病中,视网膜病变表现往往早于大脑症状出现^[6]。因此,OCT/OCTA 新型成像方式为研究各类血管疾病提供了新的可能性,如糖尿病视网膜病变(Diabetic Retinopathy,DR)、糖尿病黄斑水肿(Diabetic Macular Edema,DME)、年龄性黄斑病变(Age-related Macular Degeneration,AMD)和青光眼(Glaucoma,GL)等。

在过去十年里,随着深度学习模型以及硬件计算能力的不断提升,人工智能在各类医疗领域得到了迅速应用。尤其在以影像为主的眼科专业,深度学习展示出极大的应用潜力,应用深度学习技术高效、准确分析 OCT 和 OCTA 的需求日益增加。以往的综述多侧重于单一成像模式或单一任务的研究,往往忽视了不同成像技术之间的相关性,以及不同任务间的承接性和关联性,对此,如图 1 所示,本文总结了常用数据集,系统回顾了基于不同 OCT 和 OCTA 设备的视网膜相关疾病生物标志物的分割方法,从不同疾病特性的角度总结了视网膜相关疾病的典型分类方法,并对未来可能的研究方向进行了展望。

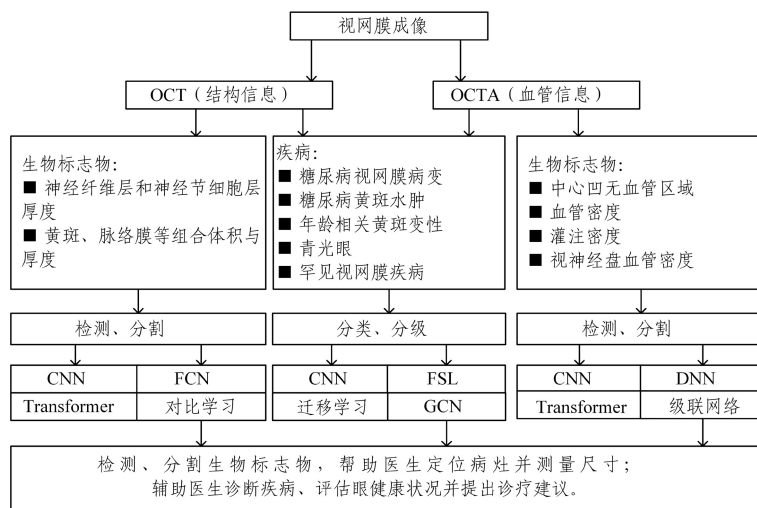


图 1 眼部研究结构图

Fig. 1 Structure chart of eye study

2 开源数据集

OCT 和 OCTA 技术能够提供眼部结构和血管的三维(3D)视图,分别产生 B-scan 和 En-face 图像,每种图像能够提供独特的视角和信息,各有其优势和应用场景。其中,B-scan 提供了组织的横断面视图,适合评估深层结构和血管;而 En-face 提供了组织的正面视图,有助于识别和评估病变的分布和范围。这两种图像类型在眼科诊断和治疗中都扮演着重要角色,并且常常结合使用,以获得更全面的眼部健康信息。

在眼科研究中,OCT 的 B-scan 和 OCTA 的 En-face 是两种常用的视图。B-scan 是 OCT 图像的一种重要表现形式,其通过对视网膜的纵向切片成像,能够提供视网膜各层次的结构信息。在数据集中,B-scan 图像通常用于视网膜层的分割、病变区域的检测和视网膜厚度的分析。En-face 图像是一种二维投影图像,其显示的是组织表面的正面视图,常用于血

管网络的可视化。在 OCTA 图像中,En-face 视图展示了视网膜血管的分布情况,能够直观地揭示血流的状态以及异常血管的形态。

然而,由于医学数据的隐私性以及 OCT/OCTA 数据的三维结构和血管信息的高度复杂性,人工标注成为一项任务驱动和劳动密集型的工作,因此往往缺少高精度标注的数据集。这种情况阻碍了研究人员进行有效的临床分析,使得 OCT/OCTA 研究大多处于“概念验证”阶段,缺乏临床可用性。本章从成像模式、疾病状态、标签类型等角度汇总了近年视网膜疾病研究中常用的数据集,主要聚焦于与研究目标相关的专用眼科开源数据集(针对分割任务或具体眼科疾病的分类任务)。表 1 和表 2^[7-23] 分别列出了常用的 OCT 与 OCTA 数据集。可以看出,专家会根据不同任务给出不同级别的标签。例如,针对血管分割任务,专家通常提供像素级的标签,而在疾病诊断任务中,标签可能更侧重于宏观的分类信息,如病变类型和疾病阶段。

表 1 OCT 数据集信息
Table 1 OCT dataset information

名称	年份	数据集大小	标签	疾病	任务	隐私性
2011_IOVS_Chui ^[12]	2011	25 个患者的 volumes	ILM 内侧边界、RPEDC 内侧边界和 Bruch 膜外侧边界	AMD	层分割	开源
RPEDC_Ophth_2013_datase ^[13]	2013	269 名 AMD 患者和 115 名正常受试者的 38400 个 B-scan	中央凹为中心的 5 mm 直径上的相应分割边界	AMD/正常	分类	开源
BOE_CHIU ^[8]	2015	10 名患者 110 次 B-scan	7 个视网膜层和视网膜液体区域	DME	分割	开源
UMN ^[7]	2017	600 张	视网膜内液、视网膜下液、色素上皮脱离	AMD	液体分割	开源
OCTAMNIST ^[14]	2018	109309 张 OCT B-scan	疾病、患者 ID、图片编号等	CNV/DME/DRUSEN/NORMAL	分类	开源
Retouch ^[15]	2019	70 volumes	视网膜内液、视网膜下液、色素上皮脱离	AMD/RVO	液体分割	开源
Gao ^[16]	2019	52 volumes	—	CSC	液体分割	受限
Yang ^[17]	2020	103 volumes	神经性视网膜脱离	—	液体分割	受限
Pawan ^[18]	2021	25 volumes	SRF	CSC	液体分割	受限
DRAC	2022	1103 张图像	疾病分级标签、病灶区域标签等	DR	病变分割 DR 分级	开源
OCTDL ^[19]	2023	821 名患者的 064 张图像	性别、年龄、疾病、状况等	AMD/DME/EMR/RAO/RVO/VID	分类	开源

表 2 OCTA 数据集信息
Table 2 OCTA dataset information

名称	年份	数据集大小	图片大小	视野范围	标签	疾病	隐私性
OCTAGON ^[9]	2019	183 张图像	320 * 320	3 * 3 6 * 6	FAZ 标签	糖尿病/近视	开源
OCTA-25K-IQA-SEG ^[20]	2019	1 101 张图像	320 * 320	3 * 3	FAZ 标签	DR/DME/AMD 等	开源
FAZID ^[21]	2020	304 张图像	420 * 420	6 * 6	FAZ 标签	糖尿病/近视/正常	开源
ROSE ^[10]	2020	ROSE-1:117 张 ROSE-2:112 张	304 * 304	3 * 3	中心线水平和像素水平的血管标签	AD/黄斑疾病/正常	开源
OCTA-500 ^[11]	2020	500 只眼睛的 80GB 影像	304 * 304	3 * 3 6 * 6	视网膜血管标签和 FAZ 标签	AMD/DR/CNV/CSC/RVO NORMAL/OTHERS	开源
Guo 等 ^[22]	2021	45 名患者的 45 张图像	704 * 704	3 * 3	FAZ 标签	高度近视/非高度近视	隐私
Soul ^[23]	2024	53 名患者的 283 张多随诊数据	304 * 304	6 * 6	视网膜血管标签	BRVO	开源

2.1 OCT 开源数据集

对这些结构进行分析,眼科医生可以诊断和监测多种眼病(见图 2)。

OCT 的 B-scan 提供了详细的视网膜层结构图像,通过

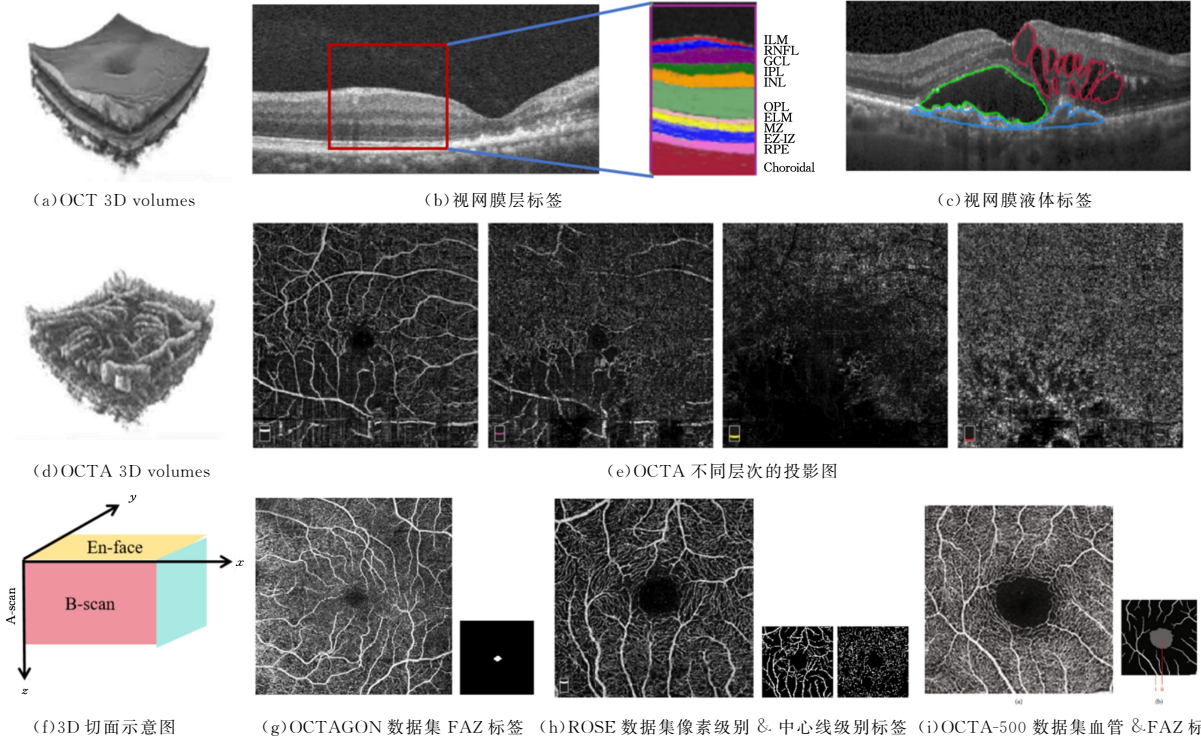


图 2 开源数据集不同标签示意图

Fig. 2 Different label schematics of public dataset

视网膜由多个不同的层次构成,包括内核层、外核层、视网膜色素上皮层等。每一层的厚度、形态和完整性都能反映眼部的健康状况。而视网膜流体(如液体积聚)是许多眼科疾病中的关键生物标志物,特别是在黄斑水肿和糖尿病视网膜病变等疾病中。众多研究团队针对不同患者、不同疾病状态的 OCT 图像提供了不同视网膜层以及视网膜流体的标注数据,能够支持疾病检测算法的开发,尤其是早期诊断的 AI 模型。例如,UMN 数据集^[7]给出了 600 张 OCT B-scan 图像中视网膜内液、视网膜下液和色素上皮脱离等流体区域的手动注释,BOE_CHIU^[8]给出了 DME 患者 OCT 数据中的 7 个视网膜层以及充满液体的区域。

2.2 OCTA 开源数据集

OCTA 的 En-face 能够提供眼底血管的“俯视”图像,特别是在评估中心凹区域和血管变化方面具有独特的优势。中心凹(Fovea)是视网膜的一个关键区域,位于黄斑区,是视觉最敏锐的地方,这个区域的无血管结构是其显著特点,也是 OCTA En-face 成像中的一个重要生物标志物。OCTA En-face 图像的另一个关键生物标志物是视网膜血管网络的结构和分布,尤其是血管的密度、形态、分布和流动情况。通过对这些生物标志物的观察,OCTA En-face 能够为临床医生提供更精确的疾病评估和治疗决策支持,特别是在血管性眼病的诊断和治疗监测中发挥着至关重要的作用。针对 OCTA 成像模式数据,OCTAGON^[9]给出了糖尿病患者和健康人群 OCTA 图像中的黄斑无血管区域(FAZ)注释,ROSE^[10]给出了像素级别以及中心线级别的视网膜血管注释,而 OCTA-500^[11]不仅给出了血管注释,还包含 FAZ 手动注释。

图 2 给出了上述开源数据不同数据类型、不同标签类型的示意图,这些不同的注释可以帮助提升下游任务的性能。一方面,精确的像素级标签能够在细粒度的分割任务中提供更加准确的训练数据,尤其在血管、病灶或视网膜层次分割等任务中,可以显著提高模型的分割效果。另一方面,基于类别的宏观标签(如疾病类型或病变区域)对疾病分类、病理预测和疗效评估等任务具有重要价值,能够帮助模型识别疾病的不同阶段及其临床特征,进而提高诊断的准确性与可靠性。

3 基于 OCT 的 B-scan 研究

OCT 因其安全性和高细节水平而闻名,其可以利用低相干干涉原理对眼底进行断层扫描,从而清晰地显示视网膜的每一层结构,生成横断面视图,是一种无创、非侵入式成像方式。通过 OCT 成像可以发现细微的早期病变,减少误诊、漏诊,从而为眼底病变的诊断提供“金标准”,堪称眼科界的 CT。本章将从生物标志物检测分割以及相关疾病诊断总结现有方法,并分析 OCT 在临床应用中的优势。

3.1 生物标志物检测分割

3.1.1 视网膜层分割

对于多种视网膜相关疾病而言,准确定量视网膜层厚度对评估疾病严重程度以及疾病的潜在发展有很大的帮助。由于视网膜层的手工分割需要相关医学知识背景,手动分割过程费时费力且参杂主观因素,因此随着深度学习的发展,大量学者开始研究视网膜层的自动提取^[24]。由于缺乏大量可靠

的标记数据,许多研究者将 CNN 与其他数学模型相结合以弥补数据不足的缺陷。Fang 等^[25]提出了 CNN-GS 模型,用于对 AMD 患者的 OCT 图像进行视网膜 9 层边界的自动分割,其结果相较于 OCTExplorer 和 DOCTRAP 等软件表现更优。该模型的优势在于通过深度学习显著提升了视网膜边界的自动分割性能。但该方法对数据依赖性较强,在数据不足的情况下容易导致过拟合问题。Pekala 等^[26]提出自动化方法,使用完全卷积网络(FCN)和基于高斯过程(GP)的回归作为后处理步骤来分割图像,以提高估计质量,并在 Miami OCT 开源数据集中使用 10 倍交叉验证,通过计算自动估计值与第一位手动评分员生成的注释之间的每像素无符号误差(距离)来评估算法的性能。该方法通过后处理步骤对估计值进行了有效修正,但其计算量较大且对交叉验证过程有较高要求。Hu 等^[27]通过融合 MCNN 架构,以学习有关视网膜层边界的多尺度信息。同时,他们引入了一种改进的图搜索算法来从概率图中检测最终的层边界。虽然上述深度学习方法在视网膜层分割任务中取得了巨大进展,但噪声、眼底积液以及伪影等干扰,导致出现层内假阳性和层间边界偏差问题,在处理复杂病变区域时容易出现较大的误差。为了解决该问题,Tan 等^[28]提出了一种结合 Transformer、边界回归与特征极化的方法,展示了该方法在处理假阳性和边界失真方面的优势,尤其是在复杂病变区域的表现,但也指出了该模型的训练复杂度较高,且对参数设置较为敏感。同时,由于 OCT volume 的 B-scan 之间存在较大的空间间隙,这些基于单个 B-scan 的 2D 分割会丢失 3D 数据的空间信息,因此 Liu 等^[29]提出了一种新颖的结合 2D-3D 数据的框架用于生成对齐位移向量和层分割,通过结合空间信息克服了单一 B-scan 分割的局限性。该方法的优势在于能够更好地保留空间信息,但其实现难度较大,且对计算资源要求较高。

3.1.2 视网膜流体分割

OCT 图像中不同类型的视网膜液体在临床上被认为是视力和再治疗适应症的相关影像标志物,不同类型视网膜液体的检测与分割对临床诊断具有重要意义。例如,视网膜内液是与视力丧失相关的最重要变量之一,视网膜下积液与 AMD 患者可能良好的视觉预后相关,色素上皮脱离被认为是疾病活动进展的主要指标^[30]。传统方法通常需要先对视网膜层进行分割,再分割视网膜下液。然而,Gao 等^[16]提出了一种创新的双分支和面积约束的 DA-FCN 模型,实现了无需分割视网膜层即可直接分割视网膜下液。该方法显著提高了分割效率,但在面对复杂病变区域时,可能存在精度不足的问题。由于不同视网膜液体在临床诊疗中具有不同的诊断意义,精确的检测并测量每种液体的类型及其变化至关重要。Bogunovic 等^[15]介绍了一个基准 RETOUCH 并对其进行了视网膜液体的检测和分割,首次实现了对 3 种视网膜液体类型以及多中心数据的统一分析。尽管该模型在多液体分割和跨中心数据适应性方面表现优异,但其对标注数据的依赖性较高,限制了其在数据匮乏场景中的应用。而从 OCT 图像中获取逐像素掩码需要专业知识,耗时耗力。随着半监督学习和无监督学习的提出,大量研究将其应用于视网膜流体分割领域并且实现了较好的性能。He 等^[31]使用对比学习来学习

视觉表征,通过挖掘未标记数据固有的相似性和不确定性进行点监督学习。在 AI challenger 和 RETOUCH 两个开源数据集上的实验表明,该方法在一定程度上缓解了模型数据标签的依赖性,但模型性能相对较差。针对预训练的监督模型在未标记域中性能下降的问题,Gomariz 等^[32]结合半监督学习和对比学习,引入了切片配对方案,将通道聚合作为对比特征图投影代替传统的空间池化聚合方法。在两个不同采集设备的源域和目标域中,该方法实现了与监督学习相当的性能。然而,其在高维特征计算中对资源的需求较高,可能会增加实际应用的复杂性。此外,Wang 等^[33]提出一种致力于半监督液体分割的模型 AMSC-Net,该模型通过引入多标签语义一致性损失(MSC-Loss)模块和解剖轮廓一致性损失(ACC-Loss)模块,互补地提升了伪标签的质量。在仅使用 5% 标注

数据的情况下,该方法在分割性能上达到了 73.95 的 Dice 分数,展现了其在小样本场景中的优越性。该方法可能对特定解剖结构的依赖性较强,在跨个体数据适应性方面仍需进一步验证。

综上,这些方法在视网膜层分割以及流体分割领域各有特色,但也存在局限性。例如,部分方法在高质量标注数据集上表现良好,但在数据稀缺或数据质量较差的情况下,模型的性能可能显著下降。此外,许多深度学习方法对计算资源的需求较高,尤其在处理大规模数据集时,训练和推理过程可能面临较大的计算压力。未来研究可以进一步关注模型的泛化能力和计算效率,同时探索数据稀缺条件下的稳健解决方案,以确保其在实际应用中的可靠性和实用性。

OCT 生物标志物分割任务相关信息如表 3 所列^[25-41]。

表 3 OCT 生物标志物分割任务
Table 3 OCT biomarker segmentation task

任务	年份	作者	关键技术	数据集
层分割	2017	Fang 等 ^[25]	CNN+graph search	私有数据集/Fang 等 ^[25]
	2018	Pekala 等 ^[26]	FCN+高斯过程	私有数据集/Tian 等 ^[34]
	2019	Hu 等 ^[27]	多尺度 CNN+图搜索	私有数据集/Tian 等 ^[34]
	2021	He 等 ^[35]	全卷积回归网络	私有数据集/He 等 ^[36] /Chiu 等 ^[8]
	2023	Man 等 ^[37]	U-Net	私有数据集/Man 等 ^[37]
	2024	Tan 等 ^[28]	高亮交叉卷积 Transformer+边界回归 特征极化	Duke DME/HEG/HCMS/GOALS
	2024	Liu 等 ^[29]	2D-3D CNN	私有数据集/Farsiu 等 ^[38] /He 等 ^[36] /Chiu 等 ^[8]
流体分割	2019	Gao 等 ^[16]	双分支结构+面积约束项 区域对抗 FCN	私有数据集/Gao 等 ^[16]
	2020	Alsaih 等 ^[39]	DCNNs/FCN/U-Net/Seg-Net	RETOUCH ^[15] ,PTIMA ^[7]
	2021	Liu 等 ^[40]	U-Net+注意力机制	OPTIMA ^[7]
	2022	He 等 ^[31]	类内-类间对比学习 点监督	AI challenger ¹ ,RETOUCH ^[15]
	2022	Gomariz 等 ^[32]	无监督域自适应 对比学习	私有数据集/Gomariz 等 ^[32]
	2023	Li 等 ^[41]	自训练对抗学习 无监督域自适应	RETOUCH ^[15]

3.2 视网膜相关疾病诊断

OCT 由于能获取视网膜高分辨率横截面图像,显示视网膜不同的层次结构,精准识别黄斑水肿、黄斑裂孔、视网膜脱离,量化视网膜层,因此特别适用于 DME、年龄相关性黄斑变性以及青光眼等疾病的诊断。

3.2.1 糖尿病性黄斑水肿

糖尿病性黄斑水肿(DME)是指由糖尿病引起的黄斑中心凹一个视盘直径范围内的细胞外液积聚所致的视网膜增厚或硬性渗出沉积。OCT 能够清晰显示视网膜的各层结构,准确测量视网膜厚度,从而区分不同类型的水肿,例如弥散性黄斑水肿、囊性黄斑水肿等。它还能够根据黄斑中心凹厚度等测量标准,客观地反映水肿严重程度,为治疗效果提供评价依据。Awais 等^[42]将预先训练好的 VGG-16 模型与随机森林结合,对新加坡眼科研究所收集的 32 名患者的 OCT 数据进行健康/DME 二分类任务,实验结果显示,该模型的准确率达到 87.5%,灵敏度和特异性分别为 93.5% 和 81%,表明了深度学习与传统机器学习方法结合在分类任务中的可行性和高效性。为了进一步有效区分 AMD 与 DME,并应对医学成像临床决策支持算法可靠性和可解释性方面的挑战,Kermany

等^[14]建立了一个基于深度学习框架的诊断工具,该工具利用迁移学习技术,使用小样本数据训练神经网络,能够有效地对黄斑变性以及视网膜病变图像进行分类,展现了在样本有限的医疗数据场景中进行精确诊断的潜力。此外,糖尿病性黄斑水肿(DME)包含多种类型(如出血、微动脉瘤等),精确检测和分类不同类型的 DME 对于临床诊断和治疗至关重要。Saini 等^[43]提出一种基于病灶的 CNN 算法(LCNN),通过强化病灶区域的特征提取,更好地分类不同类型的 DME OCT 图像。实验结果显示,该模型在准确率方面优于 ResNet, VGG16 和 Inception 等常见模型,将分类准确率提高至 96%。此类方法进一步验证了以病灶为导向的深度学习模型在 OCT 图像分类任务中的优势。

3.2.2 年龄相关性黄斑变性

年龄相关黄斑变性(AMD)是老年患者视力损害的主要原因之一。新生血管、纤维血管瘢痕以及视网膜内或视网膜下积液引起的黄斑水肿,是 AMD 患者的典型表现,这些结构改变可通过 OCT 成像清晰显现。许多研究表明,深度学习在 OCT 图像 AMD 检测中的应用前景广阔。Treder 等^[44]发现,通过预先训练的 Intercept-v3 网络开发的深度学习模型,可以

在横断面 OCT B-scan 中检测 AMD,灵敏度为 100%,特异性为 92.0%,准确率为 96.0%,展现出其在 AMD 检测任务中的卓越性能。由于精确区分 AMD 亚型(湿型和干型)对治疗决策具有重要意义,Motozawa 等^[45]提出了两种基于深度学习的模型,分别从 OCT 2D B-scan 中区分 AMD 和正常患者,以及湿型和干型 AMD。实验结果显示,这两种模型的受试者工作特征曲线下面积(AUROC)值分别为 0.995 和 0.991,灵敏度分别为 100%和 98.4%,特异性分别为 98.8%和 91.1%,准确率分别为 99.0%和 93.3%。这些成果进一步证明了深度学习在 AMD 分类任务中的潜力。在 OCT 图像分析领域,先进的预处理方法对提升模型性能起到关键作用。Rong 等^[46]提出了一种替代辅助 CNN(Auxiliary-assisted CNN),利用多种方法(如图像去噪、阈值分割及形态扩张)生成用于 CNN 训练的替代图像。实验结果显示,该模型在内部验证数据集和外部测试数据集上的 AMD 检测 AUROC 值分别为 0.978 和 0.986,表明有效的图像预处理技术能够显著提升深度学习模型的诊断精度。

3.2.3 青光眼

研究表明,使用深度学习对 OCT 视盘扫描区分青光眼和正常眼有良好的表现。例如,Thompson 等^[47]开发了一种基于 OCT 2D 圆形 B-scan 的无分割深度学习算法,研究表明,该算法在检测青光眼相关的结构变化方面表现优异,其受试者工作特征曲线下面积(AUROC)达到了 0.960,相较于传统的视网膜神经纤维层(RNFL)厚度参数(AUROC 为 0.870)的性能更为出色。这些结果表明,深度学习算法在无需依赖传统分割步骤的情况下,能够更加精准地检测结构性病变。Ran 等^[48]开发并验证了一种 3D 深度学习模型,该模型使用了 volumes 数据,并取得了与 2 名具有 10 年以上青光眼治疗经验的专家相当的性能。由类激活图生成的热图显示,3D 深度学习模型在检测青光眼性视神经病变时最具鉴别能力的区域与眼科医生在临床中观察到的区域相似。这不仅验证了模型的可解释性,还证明了其在临床应用中的潜在价值。

视网膜疾病辅助诊断的相关研究如表 4 所列^[42-64]。

表 4 视网膜疾病辅助诊断研究
Table 4 Research on auxiliary diagnosis of retinal diseases

疾病	年份	作者	关键技术/模型	分类	数据集
DME	2017	Awais 等 ^[42]	VGG-16+KNN+随机森林	健康/DME	SERI,32 个患者,128 个 B-scan
	2018	Rasti 等 ^[49]	MCME;多尺度卷积混合专家模型	健康/DME/AMD	NEH,148 名受试者,148 张图片;哈佛大学等机构公开的包含 45 名受试者的开源数据 ^[46]
	2018	Kermany 等 ^[14]	迁移学习	DME/DR	来自加州大学、北京同仁等多所机构的回顾性队列研究,4686 个患者,207130 张图片
	2022	Mittal 等 ^[50]	SVM+HOG 描述符	DME/正常	20 名患者,DME,正常各 10 例
	2023	Saini 等 ^[43]	LCNN	健康/DME(MN/EXD/HEH)	UCSD,4686 名患者,84484 张图片 ^[14] ; NEH,148 张图片 ^[49]
AMD	2019	Serener 等 ^[51]	深度卷积神经网络	干性 AMD/湿性 AMD/DME/健康	Serener 等 ^[51]
	2021	Xu 等 ^[52]	双模深度卷积神经网络	AMD/PCV	Xu 等 ^[52]
	2022	Sotoudeh 等 ^[53]	对尺度 CNN+特征金字塔网络	Drusen/CNV; CNV/DME/drusen/normal	Sotoudeh 等 ^[53] ;Kermany 等 ^[14]
	2024	Hamid 等 ^[54]	深度特征提取+LSTM	干性 AMD/湿性 AMD/健康	Kaggle
青光眼	2019	Chan 等 ^[55]	局部相位量化+PCA 分析+信息融合	青光眼/健康	新加坡眼科医院,200 左右受试者
	2021	Schottenhamml 等 ^[56]	CNN	青光眼/健康	Erlanger Glaucoma Registry,199 名患者,259 只眼,OCTA 3×3 投影 En-face 图像
	2022	Sunija 等 ^[57]	深度可分离卷积(DSC)网络	青光眼/健康	200 名青光眼 398 只眼 1105 张 OCT 图片;180 名健康受试者 272 只眼 1 049 张图片
	2024	Yang 等 ^[58]	小样本学习	青光眼/健康	Yang 等 ^[58]
	2022	Li 等 ^[59]	多层次信息+领域知识	健康/DR	OCTA-500
DR	2022	Hou 等 ^[60]	UNet/UNet++	3 种不同的糖尿病视网膜病变	DRAC dataset
	2023	Ebrahimi 等 ^[61]	CNN+不同融合策略	健康/NoDR/NPDR	46 只健康对照眼,26 只 NoDR)患者和 64 只 NPDR 患者的 6×6 mm ² OCTA 图像
	2024	Bidwai 等 ^[62]	Inception V3	无 DR 征兆/轻度 DR/中度 DR	262 张高分辨率 OCTA 图像,代表了糖尿病视网膜病变不同阶段的各种视网膜状况
	2021	Yoo 等 ^[63]	生成对抗网络+小样本学习	中心性浆液性脉络膜视网膜病变、黄斑毛细血管扩张、黄斑裂孔等	Kernany 等 ^[14]
罕见视网膜疾病	2023	Vali 等 ^[64]	U-Net+迁移学习+十二分类	1 型 CNV/2 型 CNV	101 名 CNV 患者的 130 张图像

4 基于 OCTA 的 En-face 研究

4.1 生物标志物分割

4.1.1 血管分割

视网膜血管是视网膜的重要组成部分,负责为视网膜提供氧气和营养物质,并带走代谢废物,以维持视觉通路的正常功能。血管结构的病理改变不仅是诊断各种眼底疾病的重要依据,而且与全身性疾病密切相关。研究人员已经将 OCTA 与深度学习结合使用,以实现血管的自动分割。Wang 等^[65]提出利用卷积神经网络提取特征,集成随机森林作为分类器,用有监督解决视网膜血管分割的问题。该方法结合了深度学习的特征提取能力和传统分类器的鲁棒性,具有较高的稳定性和可靠性。然而,这种方法的特征提取与分类过程分离,无法实现端到端训练,且随机森林对高维数据的处理效率有限,在面对更复杂的图像特征时可能表现不佳。Gu 等^[66]提出一种基于上下文编码的网络对医学图像进行分割,使用 ResNet 经典架构作为特征提取器。该方法能够结合全局和局部上下文信息,提升对复杂结构的理解能力,但由于网络架构本身的局限性,其在细小血管的精确分割上可能存在不足,同时对计算资源的需求较高。Ma 等^[10]首次建立专门的数据集,并提出一种基于分裂的由粗到细的血管分割网络(OCTA-Net),该网络具有分别检测粗血管和细血管的能力。这种设计适用于复杂血管结构的检测,尤其在细小血管的分割中表现突出,同时,专用数据集的引入为后续研究提供了良好的基础。但由于数据集规模较小,该模型的泛化能力可能受到限制,且由粗到细的分割策略增加了训练时间和计算复杂度。Li 等^[67]提出一种创新性思路,将分割的任务重新定义为从视网膜图像到血管图的跨通道数据转换问题,可以输出给定图像块所有像素的标签结果,而不是中心像素的单个标签。这一方法充分利用全图信息,显著提升了分割的整体性能,并简化了任务定义。然而,在训练过程对标注数据的依赖较大,且输出全像素标签的设计可能增加模型的训练复杂度和计算成本。Li 等^[68]提出 IPN: end-to-end,实现了 OCTA 中 3D 到 2D 的图像分割。IPN 能够总结三维数据投影方向上的有效特征,将分割结果输出到二维平面,减少了三维数据冗余,提升了分割效率。然而,三维到二维的投影过程中可能丢失部分信息,导致细节分割精度下降,同时网络的复杂性对硬件资源提出了较高要求。

4.1.2 FAZ 和非灌注区域分割

中心凹无血管区域(FAZ)是位于视网膜中心凹区域的一个特殊区域,它没有视网膜毛细血管分布。FAZ 的存在对于视网膜的正常功能至关重要,因为它保证了该区域的光线不受血管阻挡,从而可以实现最清晰的视觉。FAZ 的大小和形状在不同个体之间存在差异,并且会随着年龄的增长而发生变化。研究表明,FAZ 的异常变化与许多视网膜相关疾病的严重程度和进展有关。Takase 等^[69]发

现,所有具有或者不具有 DR 特征的糖尿病患者的医学图像的 FAZ 区域都有所增加,这是由周围毛细血管的缺失引起的。基于深度学习的分割方法可以应用于 FAZ 区域的测量和分割,其能够快速处理复杂的 OCTA 图像,提高分割效率并减少人工误差。然而,这种方法依赖高质量的标注数据,对数据集规模的要求较高。Mirshahi 等^[70]提出了一个级联网络,同时实现监督的血管分割和有监督的 FAZ 分割,在两个数据集(OCTAGON3 和 sFAZDATA)上进行了实验评价,得到的 Dice 得分分别为 0.9263 和 0.9784。该方法的优势在于可以同时血管和 FAZ 的分割,减少了任务分离可能导致的信息丢失。其多任务学习框架增强了网络对整体图像特征的理解能力。然而,这种级联方法的训练过程较为复杂,对硬件性能要求较高,可能在实时性应用场景中存在局限性。同样地,Guo 等^[71]也提出了一种具有编码器-解码器架构的深度学习网络,该网络可以在不同亮度/对比度设置下自动对 FAZ 区域进行分割和量化,自动分割结果与真实标注重叠部分的相似度为 0.976 ± 0.01 ,自动分割结果与真实值计算 FAZ 面积的相关系数为 0.997。该方法具有较高的鲁棒性,能够适应不同成像条件下的 OCTA 图像,其自动化程度和分割精度使其适用于临床应用。然而,该网络在处理异常复杂或病变严重的图像时可能会出现性能下降。

视网膜非灌注区域指的是视网膜上没有血管供应的区域,这些区域通常位于视网膜的边缘。非灌注面积(NPA)是表征视网膜缺血的定量生物标志物。据报道,视网膜缺血的严重程度不仅影响解剖和功能结果^[7],还与临床病程和对治疗的反应性有关^[41-42]。如果视网膜非灌注区域的面积过大,或者出现异常变化,则可能预示着一些眼部疾病,如视网膜缺血、DR、高血压视网膜病变。血管密度测量通常用于量化整个图像的灌注损失。然而,某些疾病(如 DR)的灌注损失往往局限于特定的区域,通过计算非灌注面积(NPA)可以更好地捕捉这种灌注损失模式。

Guo 等^[72]提出的算法在 DR 检查的每个阶段(轻度或中度 DR、重度 DR、健康对照),NPA 检测的准确率最低为 95%,该算法的突出优点在于其对图像质量的鲁棒性,能够在成像条件不佳的情况下依然达到高精度的检测结果。这为其在实际临床环境中的广泛应用提供了可能。Nagasato 等^[73]使用深度卷积神经网络(DNN)算法构建深度学习模型的训练,并且使用支持向量机的一个带有径向基函数核的 scikit-learn 库对 NPA 进行验证,结果表明,深度学习图像与 OCTA 图像联合检测 NPA 具有较高的准确性,在临床和视网膜筛查中具有一定的应用价值。

如表 5 所列^[71-84],上述方法各自展现了优点与不足,提供了对 OCTA 图像生物标志物分割的多种技术路径,通过结合更高效的网络架构与优化技术,未来有望进一步提升分割精度和应用广泛性。

表 5 OCTA 不同分割任务
Table 5 OCTA different segmentation tasks

任务	年份	模型	关键技术	数据集
血管分割	2020	Li 等 ^[11]	图像投影网络+平面感知器	OCTA-500 ^[11]
	2021	Ma 等 ^[10]	粗分割模块+细化分割模块	ROSE ^[10]
	2022	Chen 等 ^[74]	双一致性半监督+多尺度自监督+双一致性正则化	ROSE ^[10] , Chen 等 ^[74]
	2023	Tan 等 ^[75]	Transformer+动态聚合	OCTA-500 ^[11] , ROSE ^[10] , OCTA-SS ^[76]
	2024	Shen 等 ^[77]	自监督预训练+拓扑连接+一致性正则化	OCTA-500 ^[11] , ROSE ^[10] , Shen 等 ^[77]
FAZ& 血管	2021	Liang 等 ^[78]	一致性损失+迁移学习	OCTAGON ^[9] , sFAZDATA ^[79]
	2021	Lin 等 ^[80]	边界形状+距离感知	OCTA-500 ^[11] , OCTAGON ^[9] , and FAZ-ID ^[21]
	2022	Li 等 ^[81]	双向投影学习模块+全局感知特征+局部补充细节	OCTA-500 ^[11]
	2024	Kreitner 等 ^[82]	基于空间定值血管生成模型+轻量级模拟+对比度自适应通道	OCTA-500 ^[11] , ROSE ^[10] , Giarratano 等 ^[76]
新生血管、脉络膜等	2020	Wang 等 ^[83]	CNN	Wang 等 ^[83]
	2021	Guo 等 ^[71]	ResNet 的残差模块+U-Net	Guo 等 ^[71]
	2023	Feng 等 ^[84]	分组卷积+注意力机制+空间金字塔池化模块	Feng 等 ^[84]
	2024	Guo 等 ^[72]	并行 U-Net 模块+深度卷积网络	Guo 等 ^[72]

4.2 辅助诊疗任务

OCT 和 OCTA 在眼科疾病和神经退行性疾病中具有重要的临床研究意义,利用深度学习方法,不仅能够及时发现之前检测出微小的结构和血流变化,从而实现早期诊断和干预,而且能够利用连续扫描和血管评估,帮助医生追踪病情进展,调整治疗策略,实现疾病分期和治疗监测等。深度学习的应用不仅提高了临床诊断的精确度,也推动了对疾病病理机制的深入理解。因此,本文将从不同的视网膜相关疾病角度对深度学习方法的应用进行阐述。

OCTA 能够清晰显示黄斑区以及视网膜周围的血管网络,在无症状阶段发现微血管病变,这是因为 OCTA 成像适用于检测与血管异常相关的疾病,对糖尿病视网膜病变、脉络膜新生血管等视网膜血管疾病的检测具有独特的优势。

4.2.1 糖尿病视网膜病变

糖尿病视网膜病变(DR)是一种累及视网膜微血管的广泛性糖尿病并发症,主要表现为视网膜血管的病变和损伤。根据前期相关研究可以发现,其影像表现主要包括微动脉瘤、视网膜中央凹无血管的区域(FAZ)大小和形态,以及非灌注区域等变化。因此,本节将总结 OCTA 对 DR 患者疾病诊断的临床研究。Lu 等^[85]提出自动化算法对 OCTA 的中心凹缺血区进行量化,并对其诊断糖尿病视网膜病变(DR)的性能以及与最佳矫正视力(BCVA)与中央凹外缺血区(EAA)的相关性进行比较。该算法的优点在于,其通过量化关键参数,为 DR 的早期诊断和严重程度评估提供了可靠的客观指标。此外,算法能揭示与视功能相关的区域性缺血影响,具有重要的临床应用价值。然而,FAZ 轮廓模糊或高度不规则的情况,可能会影响量化的准确性。Abdelsalam 等^[86]提出一种基于多重分形几何的 DR 早期检测方法,使用有监督的机器学习方法作为支持向量机算法来进行自动化诊断,该方法的分类准确性高达 98.5%。该方法的主要优势在于利用多重分形几何捕捉了 DR 早期血管结构的细微变化,同时结合 SVM 提升了分类性能。然而,复杂的多重分形几何特征提取可能需要较高的计算成本。一些可解释的基于反向传播的方法能够

生成与 DR 相关病变的热图,例如 Keel 等^[87]提出的方法突出了 DR 诊断图像中的 Ex、HE 和血管异常。该方法的优点在于增强了模型的可解释性,使医生能够理解算法的决策依据,增加临床信任度和适用性。然而,其缺点在于热图的分辨率和精确性可能不足,尤其是在病变较小或较难区分的情况下,会影响临床的可操作性。

以上 3 种方法分别侧重于量化缺血区、早期结构检测和模型可解释性,均在不同方面提升了 DR 诊断的自动化能力。未来的研究可以探索将这些方法进行集成,以进一步提高诊断的全面性和可靠性,同时突破各自的局限性。

4.2.2 罕见视网膜疾病

除了常见的视网膜疾病,用于小数据集的深度学习技术的进步,如短片段学习(FSL),在很大程度上提高了深度学习应用于罕见视网膜疾病检测的可行性。Yoo 等^[63]提出了一种利用生成对抗网络(GAN)的 FSL 模型,该模型在 9 种视网膜疾病分类中取得了 93.9% 的准确率。他们证明了 GAN 不仅可以提高罕见的视网膜疾病检测的准确性(即中央浆液黄斑毛细血管扩张、黄斑孔、黄斑变性疾病和色素性视网膜炎),而且可以维护普遍的视网膜疾病的诊断性能检测(即 DME、CNV 和脉络膜小疣)。虽然目前基于深度学习的 OCT 和 OCTA 模型可以针对罕见疾病进行进一步升级,但在医学上使用 GAN 等先进的深度学习技术时应谨慎,因为伪图像可能包含不可观察或无法解释的特征,反之则可能会丢失真实图像中的部分特征。

5 实验分析

本文在第 3 章和第 4 章详细阐述了多种算法,包括但不限于模型关键技术、所用数据集、实验结果以及模型的优缺点。然而,由于这些算法涉及的数据集(如 OCT, OCTA)和任务(如不同液体分割、不同视网膜层分割)的多样性,难以从统一维度全面呈现各模型的优缺点。在生物标志物分割任务部分,本文专注于 FAZ 分割和血管分割,针对这些典型任务进行了实验分析,从定量的角度展示了不同方法在多个数据

集上的优缺点。其实验结果如表 6 和表 7 所列。可见,引入全局感知特征以及局部细节特征在血管分割任务中能够显著提升模型的性能和鲁棒性。全局感知特征能够帮助模型捕捉到血管的整体结构和布局,而局部细节特征则有助于模型更精确地识别血管的微小结构,如细小血管和分支点。结合这两种特征,模型能够在处理复杂血管网络时,更好地平衡整体结构与细节信息,从而提高分割精度,并在不同数据集上展现出较好的泛化能力和鲁棒性。而引入轻量级模拟概念虽然能够有效降低计算资源消耗和缓解计算压力,提升模型的计算效率,尤其是在硬件资源有限的环境中具有较大的优势,但这种优化往往伴随着性能的下降。轻量化的模型在减少计算量和存储需求的同时,可能会失去一些关键特征的表达能力,导致在细粒度任务中的精度降低。尤其在血管分割任务中,细微的血管特征和复杂的血管结构是分割准确性的关键,轻量化模型可能无法充分捕捉这些细节,从而影响最终的分割效果。

因此,在实际应用中,选择合适的模型需要综合考虑任务的具体要求、硬件条件以及实时性需求。如果应用场景对计算资源和处理速度有较高要求,则可以考虑采用轻量化模型,以确保在有限的硬件资源下仍能获得相对较好的性能。而对于需要高精度分割的任务,尤其是血管结构复杂、分割精度要求较高的场景,则应选择更为精细的模型,尽管它们可能需要更多的计算资源和训练时间。总之,选择合适的模型应基于任务需求的具体特点,进行性能与效率之间的权衡。

表 6 ROSE 数据集性能分析

Table 6 Performance analysis of ROSE

模型	Dice	FDR	JAC
Ma 等 ^[10]	0.7576	0.2089	—
Chen 等 ^[74]	0.7612	0.1733	0.5306
Tan 等 ^[75]	87.9700	—	78.5500
Shen 等 ^[77]	0.7658	0.1795	0.6226
Kreitner 等 ^[82]	0.6660	—	0.5634

表 7 OCTA-500 数据集性能分析

Table 7 Performance analysis of OCTA-500

模型	Dice	JAC	BACC
Li 等 ^[11]	89.41 92.74	80.95 86.67	93.46 95.22
Tan 等 ^[74]	89.45 2.06	80.99 85.13	94.11 95.46
Shen 等 ^[75]	0.8954	0.8111	—
Lin 等 ^[80]	96.07	92.72	—
Li 等 ^[81]	89.89 91.55	81.73 84.48	93.91 94.96
Kreitner 等 ^[82]	0.916	—	—

注:A|B 分别表示在 OCTA-500 6 mm * 6 mm 和 3mm * 3mm 视角下的性能。

结束语 本文总结了 OCT/OCTA 相关指标在视网膜血管疾病的诊断、分期以及疗效评价研究中的重要作用,并进一步讨论了人工智能方法未来可能的研究方向。

1) 数据隐私性问题与安全性问题

迄今为止,基于 OCT/OCTA 的深度学习图像分析模型大多仅在单中心数据集上进行训练和验证,缺乏外部测试。外部测试面临的主要挑战在于缺乏公开可用的高质量 OCT/OCTA 数据,且跨机构数据共享可能引发隐私和安全问题。联邦学习作为一种新型的学习范式,可以帮助解决这一问题。与传统机器学习数据集中存储在中心化服务器不同,联邦学

习能够在不同机构独立训练模型,并通过整合局部模型特征(如参数和梯度)更新全局模型。因此,联邦学习新范式的提出不仅可以实现个人患者数据的隐私性安全保护,还能进一步提高医疗数据模型的分析准确性和适用性。

2) 3D 医学影像问题

在医学影像中,相较于 2D 影像,3D 影像数据能够提供更全面的立体信息,实现跨切面图像的连续性。在 2D 图像中,分割通常依赖单个切片,容易丢失深度信息;而 3D 分割能够同时捕获器官组织的三维形态和空间结构,整合多张切片数据,确保器官或病灶的连续性和完整性。尽管深度学习在 3D 医学领域已经取得了显著进展,但仍面临数据稀缺、标注复杂、计算资源需求高昂以及高分辨三维图像带来的巨大内存开销等问题。未来研究需要在突破这些局限性的基础上,进一步推动深度学习在医学影像处理、疾病诊断和治疗任务中的临床应用,充分发挥其潜在价值。

3) 可解释性问题

深度学习具有自动提取和学习特征的能力,因而无需手工设计特征,这使得其决策过程变得难以揭示和解释,即存在“黑盒”问题。许多研究通过激活图或显著图生成热图,以突出显示与病理位置或最重要特征的位置可能相关的特定区域。最近,名为可解释/可解释 AI(XAI)的子学科正在兴起,以应对“黑箱”现象。未来的研究可能会进一步提高基于 OCTA 的深度学习模型的可解释性,并评估其输出在特定成像场景下的适用性。

4) 多模态问题

传统的医学图像分析方法大多基于单模态方法,且仅依赖于单一图像模态,其只能提供单一类型的信息,无法全面反映患者的健康状况。随着眼科影像技术的发展,结合不同成像模式的数据可以提供更全面的生物医学信息,通过整合这些信息能够更准确地识别眼部疾病,帮助医生实时跟踪疾病进展和治疗效果,调整治疗方案。尤其在眼科手术中,集合 OCT, OCTA 与其他影像模式,可以为外科医生提供更准确的手术视图,从而帮助医生做出更好的决策。因此,多模态医学影像方法能推动眼科临床实践,提高眼科疾病的诊断和治疗水平,研究前景十分广阔。

5) 模型通用性

在通用模型趋势来临之前,解决分割问题的方法主要分为两种:第一种是交互式分割,通过用户提供少量交互,完成对目标物体的分割;第二种是自动分割,需要大量的人工注释训练模型。随着计算机视觉领域模型泛化能力的提升,通用视觉 AI 模型在医学领域得到了快速的发展。Meta AI^[88] 提出首个计算机视觉分割大模型 Segment Anything Model (SAM 模型),在 SA-1B 数据集上进行训练,通过 prompt 范式实现了精准的图像分割,突破性地提升了图像分割的效率。由于自然图像和医学图像之间存在显著差异,因此将 SAM 应用到医学图像分割中仍然会受到限制。为了使 SAM 适应于医学图像的分割, Ma 等^[89] 提出了 MedSAM 模型。该模型选择一个合适的用户提示符和网络的组成部分来进行微调,在加速诊断工具的发展和治疗计划的个性化方面具有巨大潜力。同时,针对眼科图像分析的分割问题, Deng 等^[90] 提出一

种多框提示触发的 SAM 提示不确定性估计,通过使用多个框提示来提高分割准确性,以证明分割病变或组织的可靠性。Qiu 等^[91]介绍了一种针对眼科图像分析的新型方法——眼科 SAM 模型,通过可学习提示层解决多模态图像分割的不一致性问题,提升了 OCT 图像中对视网膜层的精确分割和对小目标物的识别。通用模型在增强模型泛化能力、推动个性化诊疗和大规模筛查中有巨大潜力,能够从多方面推动眼科领域的发展。

参 考 文 献

- [1] SOMMER A, TAYLOR H R, RAVILLA T D, et al. Challenges of ophthalmic care in the developing world [J]. *Jama Ophthalmology*, 2014, 132(5): 640-644.
- [2] SPAIDE R F, FUJIMOTO J G, WAHEED N K, et al. Optical coherence tomography angiography [J]. *Progress in Retinal and Eye Research*, 2018, 64: 1-55.
- [3] BILLE J F. High resolution imaging in microscopy and ophthalmology; new frontiers in biomedical optics [M]. Springer, 2019.
- [4] REBOLLEDA G, DIEZ-ALVAREZ L, CASADO A, et al. OCT: new perspectives in neuro-ophthalmology [J]. *Saudi Journal of Ophthalmology*, 2015, 29(1): 9-25.
- [5] DE CARLO T E, ROMANO A, WAHEED N K, et al. A review of optical coherence tomography angiography (OCTA) [J]. *International Journal of Retina and Vitreous*, 2015, 1: 1-15.
- [6] LONDON A, BENHAR I, SCHWARTZ M. The retina as a window to the brain—from eye research to CNS disorders [J]. *Nature Reviews Neurology*, 2013, 9(1): 44-53.
- [7] WU J, PHILIP A M, PODKOWINSKI D, et al. Multivendor Spectral-Domain Optical Coherence Tomography Dataset, Observer Annotation Performance Evaluation, and Standardized Evaluation Framework for Intraretinal Cystoid Fluid Segmentation [J]. *Journal of Ophthalmology*, 2016, 2016: 3898750.
- [8] CHIU S J, ALLINGHAM M J, METTU P S, et al. Kernel regression based segmentation of optical coherence tomography images with diabetic macular edema [J]. *Biomed Opt Express*, 2015, 6(4): 1172-1194.
- [9] DIAZ M, NOVO J, CUTRIN P, et al. Automatic segmentation of the foveal avascular zone in ophthalmological OCT-A images [J]. *PLoS One*, 2019, 14(2): e0212364.
- [10] MA Y H, HAO H Y, XIE J Y, et al. ROSE: A Retinal OCT-Angiography Vessel Segmentation Dataset and New Model [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(3): 928-939.
- [11] LI M C, ZHANG Y H, JI Z X, et al. Ipn-v2 and octa-500: Methodology and dataset for retinal image segmentation [J]. arXiv: 2012.07261, 2020.
- [12] CHIU S J, IZATT J A, O'CONNELL R V, et al. Validated automatic segmentation of AMD pathology including drusen and geographic atrophy in SD-OCT images [J]. *Investigative Ophthalmology & Visual Science*, 2012, 53(1): 53-61.
- [13] FARSIU S, CHIU S J, O'CONNELL R V, et al. Quantitative classification of eyes with and without intermediate age-related macular degeneration using optical coherence tomography [J]. *Ophthalmology*, 2014, 121(1): 162-172.
- [14] KERMANY D S, GOLDBAUM M, CAI W, et al. Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning [J]. *Cell*, 2018, 172(5): 1122-1131.
- [15] BOGUNOVIC H, VENHUIZEN F, KLIMSCHA S, et al. RE-TOUCH: The Retinal OCT Fluid Detection and Segmentation Benchmark and Challenge [J]. *IEEE Transactions on Medical Imaging*, 2019, 38(8): 1858-1874.
- [16] GAO K, NIU S J, JI Z X, et al. Double-branched and area-constraint fully convolutional networks for automated serous retinal detachment segmentation in SD-OCT images [J]. *Computer Methods and Programs in Biomedicine*, 2019, 176: 69-80.
- [17] YANG J, JI Z X, NIU S J, et al. RMPPNet: residual multiple pyramid pooling network for subretinal fluid segmentation in SD-OCT images [J]. *OSA Continuum*, 2020, 3(7): 1751-1769.
- [18] PAWAN S, SANKAR R, JAIN A, et al. Capsule Network-based architectures for the segmentation of sub-retinal serous fluid in optical coherence tomography images of central serous chorioretinopathy [J]. *Medical & Biological Engineering & Computing*, 2021, 59(6): 1245-1259.
- [19] KULYABIN M, ZHDANOV A, NIKIFOROVA A, et al. OCT-DL: Optical Coherence Tomography Dataset for Image-Based Deep Learning Methods [J]. *Scientific Data*, 2024, 11(1): 365.
- [20] WANG Y F, SHEN Y Q, YUAN M, et al. A deep learning-based quality assessment and segmentation system with a large-scale benchmark dataset for optical coherence tomographic angiography image [J]. arXiv: 210710476, 2021.
- [21] AGARWAL A, JANARTHANAM J B, RAMAN R, et al. The Foveal Avascular Zone Image Database (FAZID) [DB/OL]. <https://www.openicpsr.org/openicpsr/project/117543/version/V2/view>.
- [22] GUO M L, ZHAO M, CHEONG A M Y, et al. Can deep learning improve the automatic segmentation of deep foveal avascular zone in optical coherence tomography angiography? [J]. *Biomedical Signal Processing and Control*, 2021, 66: 102456.
- [23] XUE J, FENG Z, ZENG L, et al. Soul: An OCTA dataset based on Human Machine Collaborative Annotation Framework [J]. *Scientific Data*, 2024, 11(1): 838.
- [24] SCHMITT J M. Optical coherence tomography (OCT): a review [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 1999, 5(4): 1205-1215.
- [25] FANG L, CUNEFARE D, WANG C, et al. Automatic segmentation of nine retinal layer boundaries in OCT images of non-exudative AMD patients using deep learning and graph search [J]. *Biomed Opt Express*, 2017, 8(5): 2732-2744.
- [26] PEKALA M, JOSHI N, LIU T Y A, et al. Deep learning based retinal OCT segmentation [J]. *Computers in Biology and Medicine*, 2019, 114: 103445.
- [27] HU K, SHEN B W, ZHANG Y, et al. Automatic segmentation of retinal layer boundaries in OCT images using multiscale convolutional neural network and graph search [J]. *Neurocomputing*, 2019, 365: 302-313.
- [28] TAN Y, SHEN W D, WU M Y, et al. Retinal Layer Segmentation

- tion in OCT Images With Boundary Regression and Feature Polarization [J]. *IEEE Transactions on Medical Imaging*, 2024, 43(2):686-700.
- [29] LIU H, WEI D, LU D, et al. Simultaneous alignment and surface regression using hybrid 2D-3D networks for 3D coherent layer segmentation of retinal OCT images with full and sparse annotations [J]. *Medical Image Analysis*, 2024, 91:103019.
- [30] WALDSTEIN S M, PHILIP A M, LEITNER R, et al. Correlation of 3-dimensionally quantified intraretinal and subretinal fluid with visual acuity in neovascular age-related macular degeneration [J]. *Jama Ophthalmology*, 2016, 134(2):182-190.
- [31] HE X X, FANG L Y, TAN M K, et al. Intra- and Inter-Slice Contrastive Learning for Point Supervised OCT Fluid Segmentation [J]. *IEEE Transactions on Image Processing*, 2022, 31:1870-1881.
- [32] GOMARIZ A, LU H, LI Y Y, et al. Unsupervised domain adaptation with contrastive learning for OCT segmentation [C] // *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2022.
- [33] WANG Y Q, DAN R L, LUO S, et al. AMSC-Net: Anatomy and multi-label semantic consistency network for semi-supervised fluid segmentation in retinal OCT [J]. *Expert Systems with Applications*, 2024, 249:123496. 1-123496. 14.
- [34] TIAN J, VARGA B, TATRAI E, et al. Performance evaluation of automated segmentation software on optical coherence tomography volume data [J]. *J Biophotonics*, 2016, 9(5):478-489.
- [35] HE Y F, CARASS A, LIU Y H, et al. Structured layer surface segmentation for retina OCT using fully convolutional regression networks [J]. *Medical Image Analysis*, 2021, 68:101856.
- [36] HE Y F, CARASS A, SOLOMON S D, et al. Retinal layer parcellation of optical coherence tomography images: Data resource for multiple sclerosis and healthy controls [J]. *Data Brief*, 2019, 22:601-604.
- [37] MAN N, GUO S, YIU K F C, et al. Multi-layer segmentation of retina OCT images via advanced U-net architecture [J]. *Neurocomputing*, 2023, 515:185-200.
- [38] FARSIU S, CHIU S J, O'CONNELL R V, et al. Quantitative Classification of Eyes with and without Intermediate Age-related Macular Degeneration Using Optical Coherence Tomography [J]. *Ophthalmology*, 2014, 121(1):162-172.
- [39] ALSAIH K, YUSOFF M Z, TANG T B, et al. Deep learning architectures analysis for age-related macular degeneration segmentation on optical coherence tomography scans [J]. *Comput Methods Programs Biomed*, 2020, 195:105566.
- [40] LIU X M, WANG S C, ZHANG Y, et al. Automatic fluid segmentation in retinal optical coherence tomography images using attention based deep learning [J]. *Neurocomputing*, 2021, 452:576-591.
- [41] LI X, NIU S, GAO X, et al. Self-training adversarial learning for cross-domain retinal OCT fluid segmentation [J]. *Computers in Biology and Medicine*, 2023, 155:106650.
- [42] AWAIS M, MÜLLER H, TANG T B, et al. Classification of sd-oct images using a deep learning approach [C] // *Proceedings of the 2017 IEEE International Conference on Signal and Image Processing Applications*. 2017.
- [43] SAINI D J B, SIVAKAMI R, VENKATESH R, et al. Convolution neural network model for predicting various lesion-based diseases in diabetic macula edema in optical coherence tomography images [J]. *Biomedical Signal Processing and Control*, 2023, 86(B):105180.
- [44] TREDER M, LAUERMANN J L, ETER N. Automated detection of exudative age-related macular degeneration in spectral domain optical coherence tomography using deep learning [J]. *Graefe's Archive for Clinical and Experimental Ophthalmology*, 2018, 256(2):259-265.
- [45] MOTOZAWA N, AN G, TAKAGI S, et al. Optical Coherence Tomography-Based Deep-Learning Models for Classifying Normal and Age-Related Macular Degeneration and Exudative and Non-Exudative Age-Related Macular Degeneration Changes [J]. *Ophthalmology and Therapy*, 2019, 8(4):527-539.
- [46] RONG Y, XIANG D, ZHU W, et al. Surrogate-Assisted Retinal OCT Image Classification Based on Convolutional Neural Networks [J]. *IEEE Journal of Biomedical and Health Informatics*, 2019, 23(1):253-263.
- [47] THOMPSON A C, JAMMAL A A, BERCHUCK S I, et al. Assessment of a Segmentation-Free Deep Learning Algorithm for Diagnosing Glaucoma From Optical Coherence Tomography Scans [J]. *JAMA Ophthalmology*, 2020, 138(4):333-339.
- [48] RAN A R, CHEUNG C Y, WANG X, et al. Detection of glaucomatous optic neuropathy with spectral-domain optical coherence tomography: a retrospective training and validation deep-learning analysis [J]. *The Lancet Digital Health*, 2019, 1(4):e172-e182.
- [49] RASTI R, RABBANI H, MEHRIDEHNAVI A, et al. Macular OCT Classification Using a Multi-Scale Convolutional Neural Network Ensemble [J]. *IEEE Transactions on Medical Imaging*, 2018, 37(4):1024-1034.
- [50] MITTAL P, BHATNAGAR C. Detection of DME by Classification and Segmentation Using OCT Images [J]. *Webology*, 2022, 19(1):601-612.
- [51] SERENER A S S. Dry and wet age-related macular degeneration classification using oct images and deep learning [C] // *2019 Scientific Meeting on Electrical-Electronics & Biomedical Engineering and Computer Science (EBBT)*. 2019:1-4.
- [52] XU Z, WANG W, YANG J, et al. Automated diagnoses of age-related macular degeneration and polypoidal choroidal vasculopathy using bi-modal deep convolutional neural networks [J]. *The British Journal of Ophthalmology*, 2021, 105(4):561-566.
- [53] SOTOUDEH-PAIMA S, JODEIRI A, HAJIZADEH F, et al. Multi-scale convolutional neural network for automated AMD classification using retinal OCT images [J]. *Computers in Biology and Medicine*, 2022, 144:105368.
- [54] HAMID L, ELNOKRASHY A, ABDELHAY E H, et al. A deep learning LSTM-based approach for AMD classification using OCT images [J]. *Neural Computing and Applications*, 2024, 36(31):19531-19547.

- [55] CHAN Y M, NG E Y K, JAHMUNAH V, et al. Automated detection of glaucoma using optical coherence tomography angiogram images [J]. *Computers in Biology and Meicine*, 2019, 115: 103483.
- [56] SCHOTTENHAMML J, WURFL T, MARDIN S, et al. Glaucoma classification in 3×3 mm en face macular scans using deep learning in a different plexus [J]. *Biomed Opt Express*, 2021, 12(12):7434-7444.
- [57] SUNIJA A P, GOPI V P, PALANISAMY P. Redundancy reduced depthwise separable convolution for glaucoma classification using OCT images [J]. *Biomedical Signal Processing and Control*, 2022, 71(B):103192.
- [58] YANG K O, LEE J M, SHIN Y, et al. Diagnosis of Glaucoma Based on Few-Shot Learning with Wide-Field Optical Coherence Tomography Angiography [J]. *Biomedicines*, 2024, 12(4):741.
- [59] LI Q, ZHU X R, SUN G, et al. Diagnosing Diabetic Retinopathy in OCTA Images Based on Multilevel Information Fusion Using a Deep Learning Framework [J]. *Computational and Mathematical Methods in Medicine*, 2022, 2022:4316507.
- [60] HOU J L, XIAO F, XU J L, et al. Deep-OCTA: ensemble deep learning approaches for diabetic retinopathy analysis on OCTA images [M]// *MICCAI Challenge on Mitosis Domain Generalization*. Springer, 2022:74-87.
- [61] EBRAHIMI B, LE D, ABTAHI M, et al. Optimizing the OCTA layer fusion option for deep learning classification of diabetic retinopathy [J]. *Biomed Opt Express*, 2023, 14(9):4713-4724.
- [62] BIDWAI P, GITE S, PRADHAN B, et al. Harnessing deep learning for detection of diabetic retinopathy in geriatric group using optical coherence tomography angiography-OCTA: A promising approach [J]. *MethodsX*, 2024, 13:102910.
- [63] YOO T K, CHOI J Y, KIM H K. Feasibility study to improve deep learning in OCT diagnosis of rare retinal diseases with few-shot classification [J]. *Medical & Biological Engineering & Computing*, 2021, 59(2):401-415.
- [64] VALI M, NAZARI B, SADRI S, et al. CNV-Net: Segmentation, Classification and Activity Score Measurement of Choroidal Neovascularization Using Optical Coherence Tomography Angiography [J]. *Diagnostics*, 2023, 13(7):1309.
- [65] WANG S L, YIN Y L, CAO G B, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning [J]. *Neurocomputing*, 2015, 149:708-717.
- [66] GU Z, CHENG J, FU H, et al. CE-Net: Context Encoder Network for 2D Medical Image Segmentation [J]. *IEEE Transactions on Medical Imaging*, 2019, 38(10):2281-2292.
- [67] LI Q, FENG B, XIE L, et al. A Cross-Modality Learning Approach for Vessel Segmentation in Retinal Images [J]. *IEEE Transactions on Medical Imaging*, 2016, 35(1):109-118.
- [68] LI M C, CHEN Y R, JI Z X, et al. Image Projection Network: 3D to 2D Image Segmentation in OCTA Images [J]. *IEEE Transactions on Medical Imaging*, 2020, 39(11):3343-3354.
- [69] TAKASE N, NOZAKI M, KATO A, et al. Enlargement of foveal avascular zone in diabetic eyes evaluated by en face optical coherence tomography angiography [J]. *Retina*, 2015, 35(11):2377-2383.
- [70] MIRSHAHI R, ANVARI P, RIAZI-ESFAHANI H, et al. Foveal avascular zone segmentation in optical coherence tomography angiography images using a deep learning approach [J]. *Scientific Reports*, 2021, 11(1):1031.
- [71] GUO Y K, HORMEL T T, GAO L Q, et al. Quantification of Nonperfusion Area in Montaged Widefield OCT Angiography Using Deep Learning in Diabetic Retinopathy [J]. *Ophthalmology Science*, 2021, 1(2):100027.
- [72] GUO Y, HORMEL T T, GAO M, et al. Multi-Plexus Nonperfusion Area Segmentation in Widefield OCT Angiography Using a Deep Convolutional Neural Network [J]. *Translational Vision Science & Technology*, 2024, 13(7):15.
- [73] NAGASATO D, TABUCHI H, MASUMOTO H, et al. Automated detection of a nonperfusion area caused by retinal vein occlusion in optical coherence tomography angiography images using deep learning [J]. *PLoS One*, 2019, 14(11):e0223965.
- [74] CHEN Z, XIONG Y, WEI H, et al. Dual-consistency semi-supervision combined with self-supervision for vessel segmentation in retinal OCTA images [J]. *Biomed Opt Express*, 2022, 13(5):2824-2834.
- [75] TAN X, CHEN X, MENG Q, et al. OCT(2)Former: A retinal OCT-angiography vessel segmentation transformer [J]. *Comput Methods Programs Biomed*, 2023, 233:107454.
- [76] GIARRATANO Y, BIANCHI E, GRAY C, et al. Automated Segmentation of Optical Coherence Tomography Angiography Images: Benchmark Data and Clinically Relevant Metrics [J]. *Translational Vision Science & Technology*, 2020, 9(13):5.
- [77] SHEN H L, TANG Z, LI Y J, et al. HAIC-NET: Semi-supervised OCTA vessel segmentation with self-supervised pretext task and dual consistency training [J]. *Pattern Recognition*, 2024, 151:110429.
- [78] LIANG Z, ZHANG J, AN C. Foveal Avascular Zone Segmentation of Octa Images Using Deep Learning Approach with Unsupervised Vessel Segmentation [C]// *2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2021:1200-1204.
- [79] GUO M, ZHAO M, CHEONG A M Y, et al. Automatic quantification of superficial foveal avascular zone in optical coherence tomography angiography implemented with deep learning [J]. *Visual Computing for Industry, Biomedicine, and Art*, 2019, 2(1):21.
- [80] LIN L, WANG Z H, WU J W, et al. Bsd-net: A boundary shape and distance aware joint learning framework for segmenting and classifying octa images [C]// *Proceedings of the Medical Image Computing and Computer Assisted Intervention*. 2021.
- [81] LI W, ZHANG H, LI F, et al. RPS-Net: An effective retinal image projection segmentation network for retinal vessels and foveal avascular zone based on OCTA data [J]. *Medical Physics*, 2022, 49(6):3830-3844.
- [82] KREITNER L, PAETZOLD J C, RAUCH N, et al. Synthetic Optical Coherence Tomography Angiographs for Detailed Retinal Vessel Segmentation Without Human Annotations [J].

- IEEE Transactions on Medical Imaging, 2024, 43 (6): 2061-2073.
- [83] WANG J, HORMEL T T, GAO L, et al. Automated diagnosis and segmentation of choroidal neovascularization in OCT angiography using deep learning [J]. Biomed Opt Express, 2020, 11(2): 927-944.
- [84] FENG W, DUAN M H, WANG B J, et al. Automated segmentation of choroidal neovascularization on optical coherence tomography angiography images of neovascular age-related macular degeneration patients based on deep learning [J]. Journal of Big Data, 2023, 10(1): 111.
- [85] LU Y, SIMONETT J M, WANG J, et al. Evaluation of Automatically Quantified Foveal Avascular Zone Metrics for Diagnosis of Diabetic Retinopathy Using Optical Coherence Tomography Angiography [J]. Investigative Ophthalmology & Visual Science, 2018, 59(6): 2212-2221.
- [86] ABDELSALAM M M, ZAHRAN M A. A Novel Approach of Diabetic Retinopathy Early Detection Based on Multifractal Geometry Analysis for OCTA Macular Images Using Support Vector Machine [J]. IEEE Access, 2021, 9: 22844-22858.
- [87] KEEL S, WU J, LEE P Y, et al. Visualizing Deep Learning Models for the Detection of Referable Diabetic Retinopathy and Glaucoma [J]. JAMA Ophthalmol, 2019, 137(3): 288-292.
- [88] KIRILLOV A, MINTUN E, RAVI N, et al. Segment anything [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023.
- [89] MA J, HE Y, LI F, et al. Segment anything in medical images [J]. Nature Communications, 2024, 15(1): 654.
- [90] DENG G Y, ZOU K, REN K, et al. SAM-U: Multi-box prompts triggered uncertainty estimation for reliable SAM in medical image [C] // Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, 2023.
- [91] QIU Z X, HU Y, LI H, et al. Learnable ophthalmology sam [J]. arXiv:230413425, 2023.



XUE Jingyan, born in 1998, Ph.D, is a member of CCF (No. X3986G). Her main research interest is multimodal medical image analysis.



XIA Jianan, born in 1990, Ph.D, lecturer, master's supervisor, is a member of CCF (No. P2378M). Her main research interests include time series analysis and medical image analysis.

(责任编辑:何杨)