

人工智能在视网膜新生血管性疾病中的应用进展

金 玲, 王成虎

引用: 金玲, 王成虎. 人工智能在视网膜新生血管性疾病中的应用进展. 国际眼科杂志, 2026, 26(1):135-141.

基金项目: 中国医药教育协会 2022 重大科学攻关问题和医药技术难题重点课题 (No.2022KTM028)

作者单位: (210029) 中国江苏省南京市, 南京医科大学眼科医院

作者简介: 金玲, 女, 硕士, 副主任医师, 研究方向: 斜弱视、智能眼科。

通讯作者: 王成虎, 男, 博士, 主任医师, 研究方向: 斜弱视、儿童眼病及智能眼科. wangchenghu1226@163.com

收稿日期: 2025-07-02 **修回日期:** 2025-11-24

摘要

视网膜新生血管性疾病是视网膜疾病中的一类, 严重影响患者视力, 甚至导致患者失明。近年来, 人工智能 (AI) 凭借强大的图像识别与数据分析能力, 在医学领域尤其是眼科疾病诊断中取得了突破性的应用。作为 AI 核心技术的机器学习与深度学习能够从海量医学影像数据中精准提取特征、构建预测模型, 为视网膜新生血管性疾病的辅助诊断与疾病预测提供新方法。文章综述了 AI 在糖尿病视网膜病变、视网膜静脉阻塞、早产儿视网膜病变及年龄相关性黄斑变性等视网膜新生血管性疾病研究中的最新研究成果, 深入探讨其在临床应用中面临的局限性和挑战。文章旨在为推动 AI 在视网膜新生血管性疾病诊疗中的进一步发展提供参考, 助力疾病的早期诊断与疾病预测。

关键词: 人工智能; 视网膜新生血管性疾病; 糖尿病视网膜病变; 视网膜静脉阻塞; 早产儿视网膜病变; 年龄相关性黄斑变性

DOI:10.3980/j.issn.1672-5123.2026.1.24

Application progress of artificial intelligence in retinal neovascular diseases

Jin Ling, Wang Chenghu

Foundation item: China Medicine Education Association 2022 Major Scientific Research Problems and Medical Technology Challenges Project (No.2022KTM028)

The Affiliated Eye Hospital of Nanjing Medical University, Nanjing 210029, Jiangsu Province, China

Correspondence to: Wang Chenghu. The Affiliated Eye Hospital of Nanjing Medical University, Nanjing 210029, Jiangsu Province, China. wangchenghu1226@163.com

Received:2025-07-02 Accepted:2025-11-24

Abstract

• Retinal neovascular diseases represent a critical subset of retinal diseases that severely impair vision and can lead

to blindness. In recent years, artificial intelligence (AI) has demonstrated breakthrough applications in the medical field, particularly in ophthalmology, leveraging its robust capabilities in image recognition and data analysis. Machine learning and deep learning, as core AI technologies, enable precise feature extraction from vast volumes of medical imaging data and the construction of predictive models, offering novel approaches for the auxiliary diagnosis and prognosis of retinal neovascular diseases. This review synthesizes the latest advancements in AI applications for neovascular retinal diseases, including diabetic retinopathy, retinal vein occlusion, retinopathy of prematurity, and age - related macular degeneration. It further discusses the limitations and challenges in clinical implementation. Through a comprehensive summary and analysis, this review aims to provide insights for advancing AI-driven diagnosis and treatment strategies, ultimately facilitating early detection and predictive management of these vision - threatening diseases.

• **KEYWORDS:** artificial intelligence; retinal neovascular diseases; diabetic retinopathy; retinal vein occlusion; retinopathy of prematurity; age - related macular degeneration

Citation: Jin L, Wang CH. Application progress of artificial intelligence in retinal neovascular diseases. Guoji Yanke Zazhi (Int Eye Sci), 2026, 26(1):135-141.

0 引言

视网膜新生血管性疾病是一类以病理性视网膜新生血管形成为特征的致盲性眼病^[1], 主要包括糖尿病视网膜病变 (diabetic retinopathy, DR)、视网膜静脉阻塞 (retinal vein occlusion, RVO)、早产儿视网膜病变 (retinopathy of prematurity, ROP) 及 湿性 年龄 相关性 黄 斑 变 性 (neovascular age - related macular degeneration, nARMD) 等。这些疾病的共同病理生理机制在于视网膜缺血缺氧诱导血管内皮生长因子 (VEGF) 等促血管生成因子过度表达, 进而引发异常血管增殖^[2]。新生血管结构脆弱, 易发生渗漏、出血及纤维增殖, 最终导致黄斑水肿、玻璃体积血、牵拉性视网膜脱离等严重并发症, 造成不可逆的视力损害^[3]。因此, 早期筛查和精准干预是改善预后的关键。然而, 传统诊断依赖眼科医师对眼底彩照、荧光素血管造影 (FFA) 或光学相干断层扫描 (OCT) 的主观判读, 不仅耗时且存在观察者间差异。在医疗资源匮乏地区, 许多患者因未能及时确诊而错过最佳治疗窗口。

人工智能 (artificial intelligence, AI) 是计算机科学的重要分支, 旨在开发能够模拟、延伸和扩展人类智能的算法与系统, 以执行复杂认知任务^[4]。机器学习 (machine

learning, ML) 作为 AI 的核心子领域, 通过统计学习方法从海量数据中提取规律并构建预测模型, 使计算机能够基于经验自主优化决策^[5]。深度学习(deep learning, DL) 是机器学习的前沿方向, 依靠多层神经网络(如卷积神经网络、生成对抗网络) 实现高阶特征提取, 在图像识别、自然语言处理等领域展现出超越传统算法的性能^[6]。

近年来, AI 技术在医学领域的应用呈爆发式增长, 尤其在眼科这一高度依赖影像学诊断的学科中表现突出。AI 已成功应用于眼表疾病、眼前节疾病、白内障、青光眼及眼底疾病^[7-10] 等疾病的自动化筛查与辅助诊断, 显著提升了诊疗效率与准确性。目前, AI 在视网膜新生血管性疾病的图像识别和处理方面取得了一系列研究成果。本综述系统梳理了 AI 在视网膜新生血管性疾病中的应用进展, 并深入讨论了当前面临的局限和挑战, 期望可以为 AI 在视网膜新生血管性疾病中的进一步应用提供帮助。

1 AI 在视网膜新生血管性疾病中的应用

1.1 AI 在 DR 中的应用

糖尿病是一种常见的代谢性疾病, 可引起全身许多组织和器官的广泛损害, 其中 DR 既是糖尿病最严重的微血管并发症之一, 也是一种常见的致盲眼病, 其早期诊断对防止视力丧失至关重要^[11-12]。AI 模型能够通过分析眼底图像中的特征性病变(如微动脉瘤、出血、硬性渗出和新生血管等) 实现 DR 的自动化检测, 显著提高了筛查效率并减轻了临床工作负担。Hassan 等^[13] 采用 VGG-16、ResNet-50 和 U-Net 构建了一个高性能 DR 检测模型, 该模型在包含 1 804 张眼底图像的数据集上训练, 并在外部验证集上达到了 0.9938 的准确率, 展现了出色的泛化能力。类似地, Islam 等^[14] 提出了一种基于 supervised contrastive learning 的 AI 模型, 使用多个公共

数据集进行训练和测试, 最终模型的测试准确率为 0.9836, AUC 值达 0.9850, 表明其在 DR 检测方面具有极高的可靠性。相比之下, Hardas 等^[15] 采用支持向量机构建的 DR 筛查模型, 在 DIARETDB1 数据集上的准确率为 0.773, 具备一定的临床应用潜力。此外, Elgafi 等^[16] 探索了基于 OCT 图像的 DR 检测方法, 利用 188 张图像训练深度学习模型, 最终模型的准确率达到 0.9681, 表明 OCT 图像结合 AI 在 DR 诊断中同样具有重要价值。AI 不仅能够实现 DR 的自动化检测, 还能辅助医生提高诊断效率和准确性。Li 等^[17] 基于 Inception-v4 网络开发了一个 DR 智能诊断模型, 该模型在包含 8 739 张眼底图像的数据集上完成训练后, 在 Messidor-2 数据集上进行性能评估, 结果显示其 AUC 值高达 0.992, 敏感度和特异性分别达到 0.925 和 0.961。在该研究设定的受控实验环境中, 针对“眼底彩照中 DR 及糖尿病黄斑水肿的自动化检测”这一特定任务, 该模型的诊断一致性与效率表现优于参与对比的专业眼科医生。Zhao 等^[18] 对比了五种机器学习算法在 DR 预测中的表现, 研究纳入 7 943 例患者的眼部数据, 结果显示 XGBoost 模型的性能最优, 其 AUC 值、准确度、敏感度和特异性分别为 0.803、0.889、0.740 和 0.811, 为 DR 风险预测提供了新的方法学参考。DR 的临床分级对于制定个体化治疗方案至关重要, 而 AI 在自动化分级方面也展现出巨大潜力。上述不同 AI 模型在 DR 中的应用差异与性能对比见表 1。

1.2 AI 在 RVO 中的应用

RVO 是仅次于 DR 的第二大常见视网膜血管性疾病, AI 技术通过自动化分析视网膜影像, 为 RVO 的早期识别、精准分型及严重程度评估提供了创新解决方案。多项研究证实, 卷积神经网络(CNN) 在 RVO 的眼底影像分类任务中表现出卓越性能。

表 1 DR 中不同 AI 模型在架构设计与核心技术特点及优势与局限等方面的比较

| 模型架构 | 核心技术特点 | 优势与局限 |
|---|---|---|
| VGG-16、ResNet-50 和 U-Net 组合模型 ^[13] | 多模型融合, 结合分类网络(VGG-16/ResNet-50) 的病变识别能力与分割网络(U-Net) 的定位能力, 实现“检测-定位”一体化 | 优势: 泛化能力强, 可同时输出病变位置与诊断结果 局限: 模型参数多, 训练需大量计算资源 |
| 监督对比学习模型 ^[14] | 引入监督对比损失函数, 通过拉近同类样本特征距离、拉远异类样本距离, 增强模型对细微病变的区分度 | 优势: 在多中心数据集上表现稳定, 抗干扰能力强 局限: 需标注样本量较大, 对标注质量要求高 |
| 支持向量机模型 ^[15] | 基于人工提取的纹理特征构建分类器, 模型结构简单 | 优势: 计算成本低, 易部署 局限: 依赖人工特征设计, 对复杂病变漏诊率较高 |
| OCT 图像深度学习模型 ^[16] | 针对 OCT 图像的层状结构, 优化卷积核尺寸, 增强对视网膜各层(如视网膜神经上皮层、色素上皮层) 异常的识别 | 优势: 可检测眼底彩照难以发现的早期黄斑水肿 局限: 仅适用于有 OCT 设备的医疗机构, 数据获取成本较高 |
| Inception-v4 诊断模型 ^[17] | 采用多尺度卷积核设计, 能同时捕捉微小病变(如微动脉瘤) 与大范围病变(如片状出血) 特征, 支持端到端诊断 | 优势: 性能超越专业眼科医生, 适用于大规模筛查 局限: 对低质量图像(如屈光介质混浊) 鲁棒性不足 |
| XGBoost 风险预测模型 ^[18] | 基于梯度提升树算法, 整合患者年龄、血糖水平等临床数据与眼底图像特征, 实现 DR 发病风险预测 | 优势: 可提前预警 DR 发生风险, 助力一级预防 局限: 依赖完整临床数据, 数据缺失时性能下降 |

Chen 等^[19]系统比较了四种主流深度学习架构(ResNet-50、Inception-v3、DenseNet-121、SE-ReNeXt-50)对8 600张眼底彩照的分析能力,发现Inception-v3模型综合性能最优,其敏感度(0.93)、特异性(0.99)、F1分数(0.95)及AUC值(0.99)均接近完美分类水平。类似地,Anitha等^[20]基于人工神经网络构建了AI诊断模型,用于辅助诊断视网膜中央静脉阻塞等4种视网膜疾病。经过验证,该模型诊断的准确率为0.977,敏感度为0.960,特异性为0.980。为进一步提升AI模型的性能,Kang等^[21]利用2 992张多中心眼底照片开发的CNN模型,在BRVO与CRVO分型任务中分别实现了AUC值0.959和0.988;Abitbol等^[22]则通过DenseNet121网络分析超广角眼底图像,虽数据量较小(224张),仍达到了0.884的准确率(AUC值为0.912)。Xu等^[23]以ResNet18为框架构建AI模型,用于辅助RVO分类。研究中他们将收集的501张眼底图像(将其分为四组)用于模型的研发和测试。经过测试,该模型分类的准确率超过0.97,敏感度超过0.95,F1分数超过0.97。值得注意的是,Zhang等^[24]提出的VGG-CAM网络通过引入类激活映射(CAM)机制,在本地数据库测试中展现出超越ResNet-34等模型的分类能力。对CRVO的敏感度与特异性分别为0.99和0.96(AUC 0.99),BRVO为0.94和0.99(AUC 0.99),且Kappa系数(0.88-0.97)提示其与人工标注高度一致。除疾病筛查外,AI在RVO特征性病变的定位与定量分析中同样表现突出。RVO中上述不同AI模型的差异与性能对比见表2。

1.3 AI 在 ROP 中的应用 ROP 是一种发生于未成熟或低体重早产儿的增殖性视网膜病变^[25]。在 ROP 的自动化诊断方面,Brown 等^[26]采用 U-Net 和 Inception-v1 构建了诊断模型,使用 5 511 张视网膜图像(涵盖不同胎龄、体重

早产儿的 ROP 病变及正常眼底图像)进行训练和测试。该模型针对 ROP 关键征象“Plus 病”(视网膜后极部血管扩张迂曲)的诊断表现出优异性能,敏感度达 0.93,特异性达 0.94,准确率为 0.91;在相同测试数据集(5 511 张视网膜图像)的对比实验中,该模型的诊断准确率显著优于 8 位眼科专家(含 3 位视网膜专科医师、5 位综合眼科医师)的平均诊断准确率(专家平均准确率为 0.83)。类似地,Chen 等^[27]基于 CNN 开发了 ROP 分期辅助诊断系统,利用 10 894 张眼底图像进行模型优化,最终模型的 AUC 值为 0.99,敏感度为 0.94,展现出极高的判别能力。Mao 等^[28]结合 U-Net 与 DenseNet 构建的 AI 模型不仅能够诊断 ROP(特异性为 0.978,敏感度为 0.951),还可预测疾病进展,对病情恶化的识别敏感度和特异性分别达到 0.924 和 0.974。Peng 等^[29]提出的 ADS-Net 模型在 8 733 张眼底图像的验证中表现突出,准确率(0.9776)、召回率(0.9714)、精确率(0.9835)、F1 分数(0.9774)和 Kappa 值(0.9552)均接近完美,进一步证实了 AI 在 ROP 诊断中的可靠性。在 ROP 分级与分期任务中,AI 模型同样展现出显著优势。Tong 等^[30]整合 ResNet 与 Faster R-CNN 开发的系统,通过 36 231 张视网膜图像的训练后,在特定测试数据集的 ROP 分级任务中准确率达到 0.903;该性能在相同测试任务与评价标准下(即针对统一标注的 ROP 分级数据集进行盲法判读,以专家共识结果为金标准),优于两位视网膜专家的平均判读准确率。在 ROP 分期任务中,该系统对 1-5 期 ROP 的识别准确率分别为 0.876、0.942、0.968、0.998 和 0.999(同样基于上述测试数据集的标注标准),展现了 AI 模型在 ROP 分期中的应用潜力。Peng 等^[31]对比了 ResNet18、DenseNet121 和 EfficientNetB2 三种架构的 ROP 分期性能,最终模型在 635 张图像的测

表 2 RVO 中不同 AI 模型在架构设计与核心技术特点及优势与局限等方面比较

| 模型架构 | 核心技术特点 | 优势与局限 |
|---|--|--|
| ResNet - 50/Inception - v3/DenseNet - 121/SE - ReNeXt - 50 对比模型 ^[19] | 横向对比四种主流 CNN 架构, Inception-v3 采用多尺度卷积, DenseNet-121 通过密集连接复用特征, SE-ReNeXt-50 引入注意力机制 | 优势: 系统对比验证了不同架构的适配性, 为模型选择提供参考 局限: 未针对 RVO 的病变特点进行架构优化 |
| 人工神经网络多疾病诊断模型 ^[20] | 采用全连接层构建多分类模型, 输入为眼底图像的灰度直方图特征, 可同时诊断 RVO、DR 等 4 种视网膜疾病 | 优势: 多疾病兼容, 适用于基层医院的综合筛查 局限: 依赖手工特征提取, 对 RVO 与其他疾病的相似病变(如出血)区分能力较弱 |
| 多中心 CNN 分型模型 ^[21] | 采用多中心数据集训练, 引入数据增强技术(如旋转、翻转、亮度调整)模拟不同拍摄条件, 提升模型对数据异质性的适应能力 | 优势: 多中心数据训练增强泛化能力, 适用于不同医疗机构 局限: 数据来源复杂, 需统一图像预处理标准 |
| DenseNet121 超广角模型 ^[22] | 利用 DenseNet121 的密集连接特性, 减少梯度消失问题, 适配小样本(224 张)训练, 专注于超广角图像的 RVO 识别 | 优势: 小样本场景下性能稳定, 适合数据积累较少的机构 局限: 样本量不足导致对罕见亚型(如半侧 RVO)识别能力差 |
| ResNet18 分类模型 ^[23] | 简化 ResNet 架构, 减少卷积层数量(18 层), 降低计算复杂度, 同时采用批量归一化技术加速训练收敛 | 优势: 模型轻量化, 可部署于移动端设备, 适合基层筛查 局限: 简化架构导致对细微病变(如早期静脉迂曲)的识别灵敏度下降 |
| VGG-CAM 可视化模型 ^[24] | 在 VGG 网络基础上引入类激活映射(CAM)机制, 通过热力图直观显示模型关注的病变区域, 增强诊断可解释性 | 优势: 可解释性强, 便于临床医生验证模型决策 局限: CAM 热力图分辨率较低, 难以精确定位微小病变 |

试中精确率(0.9092)、F1 分数(0.9043)、准确率(0.9827)和 Kappa 值(0.9786)均表现优异。Huang 等^[32]的 CNN 分期模型在 11 372 张图像的验证中整体准确率为 0.9223, 灵敏度为 0.9614, 特异性为 0.9595; 其对 1 期和 2 期 ROP 的识别敏感度分别为 0.9182 和 0.8981, 特异性分别为 0.9450 和 0.9899, 显示出对早期病变的精准捕捉能力。ROP 中上述不同 AI 模型的差异与性能对比见表 3。

1.4 AI 在年龄相关性黄斑变性中的应用 年龄相关性黄斑变性 (age-related macular degeneration, ARMD), 又称老年性黄斑变性 (senile macular degeneration), 是欧美等发达国家 50 岁以上人群致盲的首要原因, 其发病率随年龄增长呈显著上升趋势^[33]。在 ARMD 的诊断与分类方面, 多项研究利用卷积神经网络构建了高性能 AI 模型。Han 等^[34]采用 VGG-16、VGG-19 和 ResNet 三种 CNN 网络, 对 4 749 张 OCT 图像进行分析, 构建了新生血管性 ARMD 诊断模型。该模型在验证集上的准确率达 0.874, 与眼科医生的诊断能力相当。为进一步区分 ARMD, Tak 等^[35]基于 CNN 开发了分类模型, 采用 420 张超广角眼底图像进行训练, 最终 AI 模型的准确率达到 0.88。Chou 等^[36]则利用 EfficientNet-B3 网络构建了新生血管性 ARMD 诊断模型, 通过对 699 张眼底照片的分析, 该模型表现出优异的综合性能 (准确率为 0.8367, 灵敏度为 0.8076, 特异性为 0.8472, AUC 值 0.8857)。Heo 等^[37]的研究更进一步, 其基于 VGG16 框架开发的 ARMD 分类模型 (用于区分干性与新生血管性年龄相关性黄斑变性), 在包含 399 张眼底图像的特定测试数据集上取得了 0.9086 的准确率。在该研究设定的 ARMD 亚型鉴别任务中, 该模型的诊断一致性 (如

与资深眼科专家标注结果的吻合度) 及判断效率, 显著优于参与同期对比实验的住院医师群体。这些研究表明, AI 不仅能实现 ARMD 的自动化筛查, 还能精确区分不同的 ARMD 类型, 为精准治疗奠定基础。除诊断外, AI 在预测 ARMD 严重程度和疾病进展方面也取得显著成果。Ganjdanesh 等^[38]开发的 LONGL-Net 模型通过分析约 30 000 张彩色眼底照片, 实现了 ARMD 严重程度分级和进展预测, 平均准确率为 0.905, AUC 值为 0.762。Song 等^[39]结合分类 CNN 和全卷积神经网络, 利用 671 张 SD-OCT 图像构建预测模型, 在新生血管性 ARMD 识别中表现优异 (准确率为 0.930, Dice 系数为 0.873)。ARMD 中上述不同 AI 模型的差异与性能对比见表 4。

2 局限和挑战

尽管 AI 技术在视网膜新生血管性疾病的图像识别、定量分析及临床决策支持等领域优势显著, 但现有研究仍面临多重关键挑战, 制约模型优化与临床转化: (1) 图像质量^[40]。在人工智能研究领域, 图像质量堪称影响 AI 模型性能的核心要素之一, 其重要性不言而喻。高质量图像能为模型提供清晰准确的病变特征, 而拍摄设备差异 (如分辨率、色彩还原度不同)、操作人员专业水平不足 (如角度偏差、参数设置不当) 及患者配合度低 (如眼球移动、屈光介质混浊), 均会导致图像模糊、失真或信息缺失。为此, 可通过图像预处理技术 (如自适应去噪算法、反光去除模块) 修复低质量图像, 提升模糊、伪影图像的可用特征; 制定多中心统一的图像采集标准, 减少设备与操作差异导致的质量波动; 开发智能图像质量评估模块, 在模型训练前自动筛选合格图像等方法提高 AI 研究中的图像质

表 3 ROP 中不同 AI 模型在架构设计与核心技术特点及优势与局限等方面比较

| 模型架构 | 核心技术特点 | 优势与局限 |
|--|---|---|
| U-Net + Inception-v1 诊断模型 ^[26] | U-Net 负责分割病变区域, Inception-v1 基于分割结果进行分类, 形成“分割-诊断”的模式, 同时采用交叉验证减少过拟合 | 优势: 诊断性能优于 8 位眼科专家平均水平, 适用于大规模筛查 局限: 模型分两阶段执行, 推理时间较长 |
| CNN 分期辅助系统 ^[27] | 采用深度残差网络 (ResNet) 作为骨干网络, 引入批量标准化和 dropout 技术防止过拟合, 针对 ROP 分期的序数特性优化损失函数 | 优势: 分期准确率高, 可快速区分需治疗的 ROP 局限: 对早期 1 期 ROP 的识别敏感度较低 |
| U-Net + DenseNet 预后模型 ^[28] | U-Net 分割病变区域, DenseNet 提取病变特征并结合临床数据 (如胎龄), 构建多变量预测模型, 同时输出诊断结果与进展风险 | 优势: 兼顾诊断与预后, 为个体化治疗提供依据 局限: 需收集完整临床数据, 数据缺失时预测性能下降 |
| ADS-Net 检测模型 ^[29] | 引入注意力机制 (通道注意力+空间注意力) 和深度监督技术, 在训练过程中对中间层输出进行监督, 提升对细微病变的捕捉能力 | 优势: 各项性能指标接近完美, 对早期嵴状病变识别灵敏 局限: 注意力机制增加模型复杂度, 训练需更多计算资源 |
| ResNet + Faster R-CNN 分级系统 ^[30] | Faster R-CNN 负责定位病变区域 (如 Plus 病血管), ResNet 基于定位结果进行分级, 同时采用多尺度训练适配不同分辨率图像 | 优势: 分期覆盖全阶段, 对晚期 4-5 期 ROP 识别准确率极高 局限: 对 1 期 ROP 的分级一致性较低 |
| ResNet18/DenseNet121/EfficientNetB2 分期对比模型 ^[31] | 横向对比三种架构, EfficientNetB2 采用复合缩放 (宽度、深度、分辨率) 策略, 在参数量较少的情况下提升性能 | 优势: EfficientNetB2 在性能与效率间平衡最优, 适合移动端部署 局限: 小样本测试 (635 张) 可能存在性能偏倚 |
| CNN 分期模型 ^[32] | 采用轻量化 CNN 架构, 优化卷积核尺寸以适配早产儿眼底的纤细血管, 同时引入数据增强 (如弹性形变) 模拟不同拍摄角度 | 优势: 对早期 1-2 期 ROP 识别灵敏, 助力早干预 局限: 模型轻量化导致对复杂病变 (如伴纤维增殖) 的分级精度下降 |

表 4 ARMD 中不同 AI 模型在架构设计与核心技术特点及优势与局限等方面的比较

| 模型架构 | 核心技术特点 | 优势与局限 |
|---|---|--|
| VGG-16/VGG-19/ResNet 对比模型 ^[34] | 横向对比三种 CNN 在 OCT 图像上的表现, VGG 系列擅长捕捉局部细节(如 RPE 层异常), ResNet 通过残差连接提升深层特征提取能力 | 优势:与眼科医生诊断能力相当,适用于 OCT 设备普及的机构 局限:未区分 ARMD 亚型,仅实现“正常-ARMD”二分类 |
| CNN 超广角分类模型 ^[35] | 针对超广角眼底图像的大视野优势,优化输入层以覆盖黄斑区周边,重点识别玻璃膜疣和 RPE 萎缩的分布特征 | 优势:可同时筛查黄斑区与周边视网膜病变,适用范围广 局限:超广角图像边缘畸变可能影响黄斑区病变判断 |
| EfficientNet-B3 诊断模型 ^[36] | 采用复合缩放策略(宽度、深度、分辨率),在参数量较少的情况下实现高效特征提取,同时引入标签平滑技术减少标注误差影响 | 优势:模型轻量化,可部署于基层医院 局限:对早期干性 ARMD 的识别敏感度较低 |
| VGG16 分类模型 ^[37] | 在预训练 VGG16 基础上,针对 ARMD 亚型(干性/湿性)优化全连接层,采用交叉熵损失函数进行多分类训练 | 优势:亚型区分精度高,性能优于住院医师 局限:依赖高质量眼底图像,屈光介质混浊时性能下降 |
| LONGL-Net 预测模型 ^[38] | 引入时序注意力机制,分析连续眼底照片的病变变化(如玻璃膜疣增多、RPE 萎缩扩大),构建 ARMD 进展预测模型 | 优势:可预测 ARMD 长期进展,助力二级预防 局限:需长期随访的时序数据,数据获取周期长 |
| 分类 CNN+全卷积神经网络模型 ^[39] | 分类 CNN 负责 ARMD 亚型诊断,FCN 负责病变区域分割(如 CNV),两者共享特征提取层,实现“诊断-分割”协同 | 优势:可同时输出诊断结果与病变位置,为治疗靶点定位提供参考 局限:模型参数多,训练需大量标注数据 |

量;(2)图像标注^[41]。在 AI 研究中,图像的人工标注是不可或缺的重要环节,人工标注的准确性决定 AI 模型性能,标注误差会导致模型学习错误特征,而标注工作对人员专业素养要求高、耗时耗力且易存主观偏差,即便采用多人标注与交叉验证,准确性仍受制约。通过开发半监督学习框架,利用少量专家标注数据引导模型自主学习未标注图像的病变特征,可减少对全量标注的依赖,同时持续优化标注标准,从而提高图像标注的准确性及效率;(3)样本量大小^[42]。在 AI 模型的构建过程中,样本量大小与模型的准确性之间存在着紧密的关联。AI 模型需通过大量样本学习全面规律,样本量越小泛化能力越弱,部分研究因条件限制样本量小,难以覆盖疾病复杂类型,导致模型对新数据判断不准确。需通过数据增强技术(如旋转、翻转、亮度调整、生成对抗网络合成虚拟样本)扩充样本量,尤其针对小样本研究;同时,应推动多中心、跨种族协作构建数据集,提升数据多样性,减少模型的人群偏倚,从而降低样本量不足对 AI 研究的影响;(4)患者的异质性^[43]。在 AI 模型的研究过程中,不可避免地会受到不同患者群体的影响,患者年龄、性别、种族、地区等差异会导致视网膜病变特征不同,若数据集仅含特定群体数据,模型无法适配其他群体,降低普适性。因此,在 AI 模型的研究中,必须充分考虑患者的异质性问题,尽可能收集多样化的患者数据,以提高模型的普适性和适应性;(5)AI 模型的临床应用^[44]。尽管在 AI 研究中, AI 模型在外部验证数据集上展现出了优越的性能,看似具备了良好的临床应用前景,但当真正将其应用于临床实践时,却面临着诸多问题。研究环境中数据质量高、一致性好,而临床场景患者复杂、设备操作差异大,且需满足模型实时性、稳定性要求,导致模型实际应用效果不佳。通过学习临床真实数据与研究数据的分布差异,自动调整模型参数,降低

环境迁移导致的性能下降,从而促进 AI 模型的临床应用;(6)AI 模型的可解释性^[45]。主流深度学习模型仅输出诊断结论,无法说明判断依据,当 AI 结果与医生判断冲突时,医生难以验证合理性,且模型未结合病史等临床信息,降低接纳度。通过优化可视化工具,结合病变类型标注与临床相关指标,让决策依据更贴合医生的临床思维逻辑,从而提高 AI 模型输出结果的可解释性。

3 未来展望

未来研究需从五大方向突破:(1)构建高质量数据生态,推动多中心、跨种族协作制定视网膜影像采集与标注标准,通过数据增强、联邦学习技术扩充样本量并保护数据隐私,为模型训练提供标准化、多样化的大样本数据基础;(2)开发鲁棒可解释的模型,重点研发基于因果推理的可解释性 AI 方法,结合热力图、规则提取技术实现“决策依据可视化”,同时通过迁移学习、自适应算法提升模型对异质性患者的适配性;(3)加强真实世界验证,开展多中心、前瞻性临床试验,评估 AI 模型在不同临床场景(如三级医院、社区医院、偏远地区)的实际性能,建立 AI 医疗设备的临床验证与监管标准;(4)优化临床工作流整合,开发 AI 与电子病历、PACS 系统的无缝集成接口,设计人机交互功能(如医生可调置信度阈值、标记可疑区域重分析),将 AI 融入“影像采集-诊断-治疗-随访”全流程;(5)关注可及性与伦理规范,开发轻量化 AI 模型(如适用于移动端的 DR 筛查模型)降低设备门槛,同时制定 AI 应用的伦理指南(如患者知情同意、数据隐私保护、责任界定),确保技术公平、安全地服务于广大患者。随着技术的不断迭代, AI 有望从“辅助诊断工具”升级为“全流程诊疗伙伴”,通过多模态数据融合(影像+基因+临床数据)实现视网膜新生血管性疾病的“风险预测-早期筛查-精准诊断-个体化治疗-疗效评估”闭环管理,最终降低患者失明风险。

4 总结

目前,利用 AI 和深度学习技术通过研究眼科图像等眼科检查数据辅助临床医生工作是世界关注的焦点。AI 与眼科结合的成果将会大大提高眼科疾病的诊断水平,尤其是在视网膜血管疾病领域。眼底图像蕴含着丰富的血管形态、病变特征等信息, AI 技术通过对这些图像的深度解析,能够精准识别早期微小病变,极大地提升了疾病诊断的效率与准确性。基于 AI 的辅助诊断模型能够快速筛查海量眼底图像,助力视网膜血管疾病的早发现、早诊断和早治疗,为降低患者失明风险、改善预后提供了新的可能。随着研究的不断深入, AI 技术将不再局限于图像处理与识别。随着 AI 技术的不断发展, AI 技术将为广大眼科患者带来更高效、更优质的医疗服务。

利益冲突声明: 本文不存在利益冲突。

作者贡献声明: 金玲论文选题,初稿撰写与修改,文献检索;王成虎选题指导,论文修改及审阅。所有作者阅读并同意最终的文本。

参考文献

- [1] Henry A, Boulagnon-Rombi C, Menguy T, et al. CD160 expression in retinal vessels is associated with retinal neovascular diseases. *Invest Ophthalmol Vis Sci*, 2018, 59(7):2679.
- [2] Zhang SX, Ma JX. Ocular neovascularization: Implication of endogenous angiogenic inhibitors and potential therapy. *Prog Retin Eye Res*, 2007, 26(1):1-37.
- [3] Sunaga T, Maeda M, Saulle R, et al. Anti-vascular endothelial growth factor biosimilars for neovascular age - related macular degeneration. *Cochrane Database Syst Rev*, 2024, 6(6):CD015804.
- [4] Waisberg E, Ong J, Kamran SA, et al. Generative artificial intelligence in ophthalmology. *Surv Ophthalmol*, 2025, 70(1):1-11.
- [5] Deo RC. Machine learning in medicine. *Circulation*, 2015, 132(20):1920-1930.
- [6] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553):436-444.
- [7] Zhang ZH, Wang Y, Zhang HZ, et al. Artificial intelligence - assisted diagnosis of ocular surface diseases. *Front Cell Dev Biol*, 2023, 11:1133680.
- [8] Jin K, Grzybowski A. Advancements in artificial intelligence for the diagnosis and management of anterior segment diseases. *Curr Opin Ophthalmol*, 2025, 36(4):335-342.
- [9] Oshika T. Artificial intelligence applications in ophthalmology. *JMA J*, 2025, 8(1):66-75.
- [10] Ji YK, Ji Y, Liu YF, et al. Research progress on diagnosing retinal vascular diseases based on artificial intelligence and fundus images. *Front Cell Dev Biol*, 2023, 11:1168327.
- [11] Wu JH, Alvin Liu TYA, Hsu WT, et al. Performance and limitation of machine learning algorithms for diabetic retinopathy screening: meta-analysis. *J Med Internet Res*, 2021, 23(7):e23863.
- [12] Xia HY, Long J, Song SX, et al. Multi-scale multi-attention network for diabetic retinopathy grading. *Phys Med Biol*, 2023, 69(1).
- [13] Hassan D, Gill HM, Happe M, et al. Combining transfer learning with retinal lesion features for accurate detection of diabetic retinopathy. *Front Med*, 2022, 9:1050436.
- [14] Islam MR, Abdulrazak LF, Nahiduzzaman M, et al. Applying supervised contrastive learning for the detection of diabetic retinopathy and its severity levels from fundus images. *Comput Biol Med*, 2022, 146:105602.
- [15] Hardas M, Mathur S, Bhaskar A, et al. Retinal fundus image classification for diabetic retinopathy using SVM predictions. *Phys Eng Sci Med*, 2022, 45(3):781-791.
- [16] Elgafi M, Sharafeldeen A, Elnakib A, et al. Detection of diabetic retinopathy using extracted 3D features from OCT images. *Sensors*, 2022, 22(20):7833.
- [17] Li F, Wang YG, Xu TY, et al. Deep learning-based automated detection for diabetic retinopathy and diabetic macular oedema in retinal fundus photographs. *Eye (Lond)*, 2022, 36(7):1433-1441.
- [18] Zhao YD, Li XY, Li S, et al. Using machine learning techniques to develop risk prediction models for the risk of incident diabetic retinopathy among patients with type 2 diabetes mellitus: a cohort study. *Front Endocrinol*, 2022, 13:876559.
- [19] Chen Q, Yu WH, Lin S, et al. Artificial intelligence can assist with diagnosing retinal vein occlusion. *Int J Ophthalmol*, 2021, 14(12):1895-1902.
- [20] Anitha J, Vijila CK, Selvakumar AI, et al. Automated multi-level pathology identification techniques for abnormal retinal images using artificial neural networks. *Br J Ophthalmol*, 2012, 96(2):220-223.
- [21] Kang EY, Yeung L, Lee YL, et al. A multimodal imaging-based deep learning model for detecting treatment - requiring retinal vascular diseases: model development and validation study. *JMIR Med Inform*, 2021, 9(5):e28868.
- [22] Abitbol E, Miere A, Excoffier JB, et al. Deep learning-based classification of retinal vascular diseases using ultra-widefield colour fundus photographs. *BMJ Open Ophthalmol*, 2022, 7(1):e000924.
- [23] Xu W, Yan ZP, Chen N, et al. Development and application of an intelligent diagnosis system for retinal vein occlusion based on deep learning. *Dis Markers*, 2022, 2022:4988256.
- [24] Zhang GH, Sun B, Zhang ZX, et al. Hypermixed convolutional neural network for retinal vein occlusion classification. *Dis Markers*, 2022, 2022:1730501.
- [25] Barnett JM, Hubbard GB. Complications of retinopathy of prematurity treatment. *Curr Opin Ophthalmol*, 2021, 32(5):475-481.
- [26] Brown JM, Campbell JP, Beers A, et al. Automated diagnosis of plus disease in retinopathy of prematurity using deep convolutional neural networks. *JAMA Ophthalmol*, 2018, 136(7):803-810.
- [27] Chen JS, Coyner AS, Ostmo S, et al. Deep learning for the diagnosis of stage in retinopathy of prematurity: accuracy and generalizability across populations and cameras. *Ophthalmol Retina*, 2021, 5(10):1027-1035.
- [28] Mao JB, Luo YH, Liu L, et al. Automated diagnosis and quantitative analysis of plus disease in retinopathy of prematurity based on deep convolutional neural networks. *Acta Ophthalmol*, 2020, 98(3):e339-e345.
- [29] Peng YY, Chen ZY, Zhu WF, et al. ADS-Net: attention-awareness and deep supervision based network for automatic detection of retinopathy of prematurity. *Biomed Opt Express*, 2022, 13(8):4087-4101.
- [30] Tong Y, Lu W, Deng QQ, et al. Automated identification of retinopathy of prematurity by image - based deep learning. *Eye Vis (Lond)*, 2020, 7:40.

- [31] Peng YY, Zhu WF, Chen ZY, et al. Automatic staging for retinopathy of prematurity with deep feature fusion and ordinal classification strategy. *IEEE Trans Med Imaging*, 2021, 40 (7): 1750–1762.
- [32] Huang YP, Basanta H, Kang EY, et al. Automated detection of early – stage ROP using a deep convolutional neural network. *Br J Ophthalmol*, 2021, 105 (8): 1099–1103.
- [33] Thomas CJ, Mirza RG, Gill MK. Age – related macular degeneration. *Med Clin N Am*, 2021, 105 (3): 473–491.
- [34] Han J, Choi S, Park JI, et al. Classifying neovascular age-related macular degeneration with a deep convolutional neural network based on optical coherence tomography images. *Sci Rep*, 2022, 12 (1): 2232.
- [35] Tak N, Reddy AJ, Martel J, et al. Clinical wide – field retinal image deep learning classification of exudative and non – exudative age – related macular degeneration. *Cureus*, 2021, 13 (8): e17579.
- [36] Chou YB, Hsu CH, Chen WS, et al. Deep learning and ensemble stacking technique for differentiating polypoidal choroidal vasculopathy from neovascular age – related macular degeneration. *Sci Rep*, 2021, 11 (1): 7130.
- [37] Heo TY, Kim KM, Min HK, et al. Development of a deep – learning – based artificial intelligence tool for differential diagnosis between dry and neovascular age – related macular degeneration. *Diagnostics (Basel)*, 2020, 10 (5): 261.
- [38] Ganjdanesh A, Zhang JP, Chew EY, et al. LONGL-Net: temporal correlation structure guided deep learning model to predict longitudinal age – related macular degeneration severity. *PNAS Nexus*, 2022, 1 (1): pgab003.
- [39] Song X, Xu Q, Li HM, et al. Automatic quantification of retinal photoreceptor integrity to predict persistent disease activity in neovascular age – related macular degeneration using deep learning. *Front Neurosci*, 2022, 16:952735.
- [40] Wang JY, Wang YX, Zeng D, et al. Artificial intelligence – enhanced retinal imaging as a biomarker for systemic diseases. *Theranostics*, 2025, 15 (8): 3223–3233.
- [41] Galante N, Cotroneo R, Furei D, et al. Applications of artificial intelligence in forensic sciences: Current potential benefits, limitations and perspectives. *Int J Legal Med*, 2023, 137 (2): 445–458.
- [42] Ran AR, Tham CC, Chan PP, et al. Deep learning in glaucoma with optical coherence tomography: a review. *Eye*, 2021, 35 (1): 188–201.
- [43] 杨卫华, 许言午, 迟玮. 人工智能时代:智能眼科发展的关键问题思考. *国际眼科杂志*, 2025, 25 (1): 13–16.
- [44] Milea D, Singhal S, Najjar RP. Artificial intelligence for detection of optic disc abnormalities. *Curr Opin Neurol*, 2020, 33 (1): 106–110.
- [45] 杨卫华, 邵毅, 许言午, 等. 眼科人工智能临床研究评价指南 (2023). *国际眼科杂志*, 2023, 23 (7): 1064–1071.