

# 深度学习在糖尿病视网膜病变早期筛查中的应用

尹智邈<sup>1,2</sup>, 李蓉<sup>1,2</sup>

引用:尹智邈,李蓉. 深度学习在糖尿病视网膜病变早期筛查中的应用. 国际眼科杂志, 2026,26(6):1001-1005.

基金项目:四川省卫健委科研项目(No.24WXXT13);中国研究型医院学会眼科基金(No.Y2025FH-YKYSJSJ07-18);川北医学院科研发展计划项目(No.CBY24-QDA01)

作者单位:<sup>1</sup>(637000)中国四川省南充市,川北医学院附属医院

眼科;<sup>2</sup>(637000)中国四川省南充市,川北医学院眼视光医学院

作者简介:尹智邈,男,在读硕士研究生,研究方向:视网膜疾病。

通讯作者:李蓉,女,博士后,教授,博士研究生导师,主任医师,

研究方向:视网膜疾病. rechelrong198222@163.com

收稿日期:2025-11-15 修回日期:2026-04-15

## 摘要

糖尿病视网膜病变(DR)是糖尿病最主要的微血管并发症,也是工作年龄人群视力丧失的首要原因。传统筛查模式依赖专业医生人工判读眼底图像,面临医疗资源分布不均、诊断主观性强等挑战。近年来,深度学习技术凭借其图像识别与特征学习方面的优势,为DR早期筛查提供了自动化、高效率的新途径。文章系统综述了深度学习在DR筛查中的应用,包括其技术原理、主流算法、数据集构建、模型训练策略及多模态数据融合潜力。同时,文章深入分析了当前应用中所面临的数据质量、模型可解释性、系统集成及临床转化壁垒等关键挑战,并对未来发展方向一如轻量化模型设计、多病种联合预测、跨学科协同创新生态构建等进行展望,以期为推动深度学习在DR筛查中的临床落地提供参考。

关键词:糖尿病视网膜病变;深度学习;早期筛查;人工智能;医学影像;临床转化

DOI:10.3980/j.issn.1672-5123.2026.6.12

## Deep learning in the early screening of diabetic retinopathy

Yin Zhimiao<sup>1,2</sup>, Li Rong<sup>1,2</sup>

**Foundation items:** Scientific Research Project of Sichuan Provincial Health Commission (No. 24WXXT13); Ophthalmology Fund of Chinese Research Hospital Association (No. Y2025FH-YKYSJSJ07-18); Scientific Research Development Program Project of North Sichuan Medical College (No. CBY24-QDA01)

<sup>1</sup>Department of Ophthalmology, Affiliated Hospital of North Sichuan Medical College, Nanchong 637000, Sichuan Province, China;

<sup>2</sup>School of Ophthalmology and Optometry, North Sichuan Medical College, Nanchong 637000, Sichuan Province, China

**Correspondence to:** Li Rong. Department of Ophthalmology, Affiliated Hospital of North Sichuan Medical College, Nanchong

637000, Sichuan Province, China; School of Ophthalmology and Optometry, North Sichuan Medical College, Nanchong 637000, Sichuan Province, China. rechelrong198222@163.com

Received:2025-11-15 Accepted:2026-04-15

## Abstract

• Diabetic retinopathy (DR) is the most common microvascular complication of diabetes and a leading cause of vision loss among the working-age population. Conventional screening models rely on manual interpretation of fundus images by ophthalmologists, facing limitations including uneven distribution of medical resources and subjectivity in diagnosis. In recent years, deep learning (DL) technology, with its strengths in image recognition and feature learning, has emerged as a novel and efficient automated approach for early DR screening. This article provides a systematic review of DL applications in DR screening, covering technical principles, mainstream algorithms, dataset construction, model training strategies, and the potential for integrating multi-modal data. It further provides an in-depth analysis of key challenges in current applications, such as data quality, model interpretability, system integration, and obstacles to clinical translation. What's more, future directions are discussed, including the development of light weight models, multi-disease joint prediction, and the establishment of interdisciplinary collaborative frameworks, aiming to support the clinical adoption of DL-based DR screening.

• **KEYWORDS:** diabetic retinopathy; deep learning; early screening; artificial intelligence; medical imaging; clinical translation

**Citation:** Yin ZM, Li R. Deep learning in the early screening of diabetic retinopathy. Guoji Yanke Zazhi (Int Eye Sci), 2026, 26(6):1001-1005.

## 0 引言

糖尿病视网膜病变(diabetic retinopathy, DR)作为糖尿病最主要的微血管并发症,已成为工作年龄人群视力丧失的首要原因<sup>[1]</sup>。全球糖尿病患病率的持续增加进而导致DR患者基数迅速扩大,其中“威胁视力的糖尿病视网膜病变”(vision-threatening diabetic retinopathy, VTDR)患者已高达约2800万,如果不尽快及时干预将导致不可逆的视力损害,造成严重的个人与社会负担。对DR的早期筛查被证实是保护患者视力的关键,但是现如今依赖眼科医生人工判读眼底图像的筛查模式面临双重挑战:合格医生数量严重不足,难以满足基层筛查需求;人工评估易受

主观因素影响,存在诊断差异和漏诊风险,严重制约了筛查效能<sup>[2]</sup>。在此背景下,本研究探索将深度学习(deep learning, DL)技术应用于DR早期筛查的可行性与价值。由于早期DR临床表现隐匿,其识别高度依赖专业经验,而医疗资源分布不均进一步限制了筛查的可获得性。通过构建高效、可靠的识别模型,突破现有人工筛查的瓶颈,提升筛查的灵敏度与标准化程度,为推进DR的早期防控、降低糖尿病患者失明风险提供新的技术路线。

## 1 DR概述

**1.1 流行病学现状** 糖尿病作为一种全球性的慢性代谢性疾病,其发病率正逐年升高,已成为重大公共卫生挑战。国际糖尿病联盟(IDF)数据显示,全球糖尿病患者数量持续增长,对公共卫生系统的压力呈递增趋势。DR作为糖尿病最常见的微血管并发症之一,严重威胁着该疾病患者的视力健康<sup>[1]</sup>。据权威研究估算,全球DR患者总数约9300万<sup>[3]</sup>,而且随着病程延长,DR患病风险显著增加。在病程超过10a的患者中约50%出现不同程度的视网膜病变,20a以上病程的患者的视网膜几乎全部受累<sup>[4]</sup>。在所有DR患者中,VTDR构成了高风险亚群,包括增殖性DR(PDR)、重度非增殖性DR(NPDR)和糖尿病性黄斑水肿(DME)<sup>[5]</sup>。全球糖尿病人群中VTDR患病率估计介于6.17%~10.2%,意味着全球约有2800万患者面临极高的视力丧失风险<sup>[6]</sup>。若未能及时发现和干预,VTDR将导致不可逆的视力损伤甚至失明,严重影响患者生活质量并加重社会医疗负担。

**1.2 病理机制** 长期高血糖引发的代谢紊乱、血流动力学异常及血管内皮功能障碍共同诱发了DR的病理改变。持续高血糖状态使多元醇通路激活和蛋白激酶C(PKC)活化,进而晚期糖基化终末产物(AGEs)积累,导致视网膜血管壁结构完整性被破坏。同时与高血糖状态伴随的胰岛素抵抗进一步诱发炎症反应与氧化应激,加剧视网膜微血管损伤<sup>[7]</sup>。

## 2 DL技术原理及优势

近年来,人工智能(artificial intelligence, AI)技术的飞速发展,在医疗领域的应用规模日益广泛。在DR筛查场景中,基于AI的DL技术展现出强大能力,并凭借这种能力为提升筛查效率与临床应用提供了新的研究方向<sup>[8]</sup>。在不同的AI模型中,算法架构的差异使它们拥有不同的性能优势。

**2.1 DL基本原理** DL是机器学习领域的前沿分支,核心逻辑是通过构建含多个处理层级(即“深度”结构)的人工神经网络对人脑神经元的连接特性和计算机制进行仿真建模。DL能够从大量数据中自动学习并逐层抽取复杂的抽象特征,从而高效完成各类智能识别任务<sup>[9]</sup>。与传统机器学习方法相比,DL的突破在于其具备端到端的特征学习能力,即无需依赖人工设计的特征,直接从原始数据中自主提取出有分辨价值的特征,并通过多个数据处理层实现从点到面的信息整合,因而其在处理非结构化数据时表现出显著优势。

**2.2 常用的DL算法** 在当前的DL体系中,卷积神经网络与循环神经网络是其中常用的两类核心架构。卷积神经网络是一种专门用于处理具有网状拓扑结构数据的DL架构通过局部感受野等机制,仅对部分像素做出响应,高

效的模拟了生物视觉系统处理信息的方式<sup>[10]</sup>。循环神经网络是一种处理序列数据的人工神经网络,通过建立数据的时序性依赖,保证时序不同的信息被模型高效利用,这使其对序列数据进行建模,并捕捉数据中的时间动态特征<sup>[11]</sup>。二者的区别在于卷积神经网络侧重于空间数据,而循环神经网络侧重于时序数据建模。

**2.3 DL在临床应用中的优势** 在医学影像学中,DL对影像的预处理(例如去噪、增强等)有着相当大的提升,其通过自动特征提取,突破了传统机器学习的限制,自动分析图像中的纹理、形态学等特征<sup>[12]</sup>。并且它有着多模态融合潜能,通过不同模型总结临床数据,使临床指标与影像数据相结合,构成整体诊断模型。最后,之所以在医疗数据集中实现准确快捷的模型表现是它通过自身特性,在临床数据集中进行全流程优化,解决医疗数据进一步降低成本。例如,在感染性肾积水的自动计算机断层扫描图像分割和诊断模型中,DL在其中起到重要作用。DL为基础创建的模型与传统临床检查手段相比的优势在于提供了一种快速、无创、准确的解决方案,来评估肾积水是否并发感染,使其在尿石症和肾积水患者的临床管理中起到了强大的作用<sup>[13]</sup>。

DL模型应用于DR早期筛查具有一定的优势,DR在眼底图像中主要呈现为微动脉瘤、出血点等视觉特征,这些形态学改变高度契合DL在图像识别与特征提取方面的技术优势。并且由于全球DR患者基数庞大且持续增长,而基层医疗机构大多面临专业眼科医生数量不足的困境,导致早期筛查覆盖率难以提升,急需引入高效、自动化的筛查方案。基于DL的筛查模型已在多项研究中展现出优异的性能。例如,IDX-DR智能筛查系统已通过美国食品药品监督管理局(FDA)认证,成为全球首个获批用于临床的DR自主诊断系统,标志着该技术已实现从实验研究向临床应用的实质性跨越<sup>[14]</sup>。

## 3 DL在DR早期筛查中的应用实践

**3.1 数据的准备和预处理** DL模型在DR的研究领域,算法的开发与性能评估主要由几个高质量的公开数据集保证质量。目前在研究中广泛使用的数据集包括DRIVE、STARE、Messidor以及EyePACS等。其中EyePACS数据集由美国国家糖尿病视网膜筛查计划构建,其中收录了超过13万张图像并配备了五级分类标签,是目前全球规模最大、标注最全的公开数据集之一。为确保标注质量,公开数据集大多采用多专家协同标注:首先由2-3名眼科医生分别独立完成第一次的标注,随后通过互相证实核对与统一意见来控制个体变异;遇到大多数眼科医生无法达成共识的复杂病例,则进行资深专家会诊或分轮次投票决策机制来决定最终分类标签。以EyePACS为例,其采用的三级标注审核制度(初级标注→专家审核→最终确认)将整体标注错误率控制在3%以内,为模型训练提供了可靠的样本数据<sup>[15]</sup>。

**3.2 模型的构建及训练** 在运用DL技术完成DR分级的研究中,卷积神经网络及其衍生体系模型已成为主流技术路线。其中,残差网络(ResNet)、密集连接网络(DenseNet)等模型凭借其独特的结构,成功在抑制梯度弥散和网络性退化的同时,维持了模型深度特性,大幅增强了模型对病变特征的精细区分能力<sup>[16]</sup>。规范的数据划分

策略被用在训练过程中,这种方法是将数据集按 7:2:1 的比例划分为训练集、验证集和测试集。模型参数的学习和优化在训练集中完成,超参数整定与过拟合遏制由验证集负责,最后应用独立保留的测试集,完成评估模型泛化性能的任务。这种分级方法有效保障了模型的可靠性和跨研究可比性。这种方法即模型的内部验证,其目的是对模型本身进行快速迭代,初步验证该模型在此类数据中的性能<sup>[17]</sup>。

DL 在整合眼底彩照、OCT 等视觉数据方面展现出相当大的优势。眼底彩照以图像形式呈现微血管瘤、出血点等视网膜微血管病变特征,并且采集方便成本较低;OCT 则提供高分辨率的视网膜断面图像,展现了黄斑和神经纤维层等重要解剖位置的结构异常<sup>[18]</sup>。DL 框架整合和分析这两种互补性影像数据,有希望构建出更完善的诊断模型,进而提升 DR 早期筛查的敏感性与判断能力。

**3.3 模型的落地验证分析** 在模型完成初步构建后,其能否实际应用于临床仍需要科学验证。这不只是对模型本身计算能力的考验,更是保证模型在医院复杂环境中能够准确得出结论,满足医务人员的需求。为确保模型满足临床的使用要求,需要对已建立的模型进行逐级验证:(1)对模型本身的计算能力进行验证,使用公开数据集对模型在同源数据中的性能进行估算,目的是对模型自身对同源数据处理上的性能进行评估<sup>[19]</sup>。(2)要使用不同于公开数据集并有明显差异的数据测试模型处理这类数据的效率,例如不同医院、不同人种或地区等,覆盖模型可能应用的所有场景。这是为了验证模型在真实世界不同场景的处理能力,即数据要尽可能覆盖未来模型要应用的所有场景<sup>[20]</sup>。(3)在模型真正被大规模用于临床前,要先将其用于真正临床工作当中,对接受的患者进行实时分析,将结果与诊断金标准进行对比<sup>[21]</sup>。与先前不同的是,该验证评估模型是在不可预知的真实医疗环境中的实际表现,而不是历史数据,故该方法意义在于“前瞻性”地搜集数据并在真实环境中进行测试,也只有通过这种验证方法,才可真实评估模型在特定医疗环境中的临床效用。

**3.4 临床落地应用案例分析** 近年来,在全球范围内已有一批将这类筛查技术推向临床的案例,这为我们理解应用的价值提供了经验。以新加坡为例,其有完善的全国性糖尿病视网膜病变筛查计划(SIDRP),全国的初级诊所都在其覆盖范围内。但随着 DR 患者的增加,眼科医生的阅片压力也随之增加,为了提高效率,新加坡国家眼科中心等机构联合开发了名为 SELENA+ 的深度学习模型,并将其融入到 SIDRP 的工作流程中,该模型首先将所有的图像数据进行初筛,排除其中明确为阴性的图像,后将所有无法判断的图像交给阅片专家进行复核。自 2018 年起,该模型进行了大规模的试点部署。结论表明,半自动的处理方式相对于全自动处理,可以在准确度和反应速度中找到相对较佳的平衡点。研究表明,该系统能够将阅片专家的工作量减少高达 50%<sup>[22]</sup>。如果说新加坡的筛查计划目的在于释放专家资源,那么卢旺达的 DARDERS 项目则是探索在资源受限地区部署模型进行 DR 早期筛查的可能性及初步效果。该项目是典型的探索前瞻性研究,研究人员在卢旺达的 4 个糖尿病诊所使用 AI 解读的视网膜图像对 DR 患者进行诊断,对整个流程进行了评估,并调查了患

者和医务人员对该技术的接受程度,结论是在卢旺达的糖尿病诊所,该技术是可行的,准确度与最近的一项全球初级糖尿病视网膜病变深度学习筛查模型的荟萃分析结果一致,能被医患双方广泛接受<sup>[23]</sup>。该研究虽规模不大,却为技术在最需要它的地方落地使用提供了宝贵的思路和经验,证明该技术有潜力成为平衡健康鸿沟的有力工具。无论是在提升发达国家医疗诊断效率,还是为发展中国家提供筛查机会,都是为临床实践创造价值。

#### 4 DL 应用面对的挑战

**4.1 数据相关问题** 在医学影像数据分析任务中,DL 的应用以高质量的标注影像数据作为基础。模型通过模拟人脑神经元的结构特性,从已标注的影像数据中提取并学习病变的共性特征,最后构建出具有临床价值的指标模型,为病变的分类提供客观的量化支撑。虽然 DL 模型有这种优势,但是在数据方面仍面临许多挑战:初始数据的采集与标注高度依赖专业眼科医生,标注和分类的流程复杂,而专业眼科医生的用人成本也相当高昂;由于临床数据收集被患者隐私等因素限制,可用临床数据较难收集。此外,数据集分布不均衡问题尤为突出。以不同地域、种族、生活习惯进行分类的不同人群,其 DR 的发病率、病理特征和视力损伤程度表现出明显异质性。这种人口学与病理学特征的异质性较为突出,直接使训练数据分布偏倚,进而影响模型训练效果。该模型在这种条件下会形成“人工智能偏见”——当面对分布偏移样本或未见过的新临床表现数据时,模型的泛化性能明显下降,难以保持准确的病变识别与分级性能<sup>[24]</sup>。这一局限性在 DL 技术的临床转化过程中的表现尤为突出,已经成为其实现大规模应用的瓶颈<sup>[25]</sup>。

**4.2 模型自身局限** 模型可解释性的欠缺,降低了其在临床场景的接受度和推广进度。作为典型的“黑箱”系统,DL 模型在图像分类任务中表现优异,却很难生成符合临床需求的逻辑路径。医生诊断需根据具体病理特征,例如微动脉瘤、出血点和硬性渗出,以此来构建证据链,进而做出临床决策,而现有模型无法清晰呈现其识别逻辑与判断依据,导致临床医生对模型输出结果缺乏信任,并且模型自身也难以承担相应的医疗法律责任<sup>[26-27]</sup>。与此同时,数据层面的异质性属性也是局限之一,其限制了模型的跨场景泛化效能,导致模型适用范围被压缩。不同机构使用的影像设备、采集指标和存储结构存在差异,导致数据分布差异出现。当训练数据与临床实际数据分布存在差异时,模型的性能将明显下滑,模型在真实医疗环境中的可靠性被这种数据适配问题直接影响。最后值得指出的是,临床应用落地被系统集成相关问题所阻碍。原因是现有的 DL 模型大多针对单一模态数据设计,但是未来保证临床诊疗的准确性,要求对不同渠道的医疗信息进行整合。并且医院现有信息系统存在架构复杂和标准不一的缺陷,使得现有工作流程很难完美接入模型,实际对模型进行部署时,系统适配以及数据转换需消耗大量资源,增加了实际临床应用的难度。

**4.3 临床模型使用问题** 模型的安全性及可靠性在医疗领域的要求极其严苛。模型作为直接参与临床决策的辅助手段,需满足极高的预测准确性和决策可解释性的要求,同时保证模型依据多样本数据给出的诊断在多中心场

景的可靠性。以DR筛查为例,模型的漏诊或误判可能导致患者错失早期干预的时机,进而造成不可逆的视力损伤。正因如此,全球多个国家与地区,例如美国FDA、中国NMPA等医疗监管机构均已针对AI辅助诊断系统进行严格筛选,为此设立了严格的航工业审批标准框架,以此筛选出真正适用于临床场景、风险可控的可靠模型,确保其符合临床诊疗标准<sup>[28]</sup>。

## 5 未来发展方向与展望

### 5.1 技术的改进与优化

现如今,DL在技术上仍有很大的改进空间,由于高性能模型依赖大量计算资源,这一点与推广低成本、高效率筛查的初衷不一致。因此,构建同时具备优异性能和计算简单的模型架构已成为核心研究方向<sup>[29]</sup>。例如最新的MobileNet-V2轻量化卷积神经网络模型,其通过优化参数结构与计算方式,在保持高精度的同时,还完成了降低计算复杂度和延迟的目标,为在医疗资源贫瘠的基层部署DR早期筛查模型提供了技术路径<sup>[30]</sup>。在优化模型的进程中,主要通过以下方式提升核心性能:迁移学习利用大规模预训练模型作为基础,通过目标领域数据微调,有效缓解数据稀缺问题;注意力机制使模型能够自适应聚焦于病变重点区域,增强特征可判别性并提升决策可解释性<sup>[31]</sup>;而Transformer架构凭借自注意力模块,能够建模图像全局上下文依赖,对识别分布弥散或形态多变的早期病变展现出明显优势<sup>[32-33]</sup>。展望未来,技术发展将致力于三方面:(1)构建更大规模、多中心的标注数据集,从数据源头提升模型泛化能力;(2)推动卷积神经网络与Transformer的混合架构进展,兼顾局部特征提取与全局关系建模;(3)开展严格的多中心临床验证,确保模型在真实医疗场景中的准确性与鲁棒性,为其最终转化为临床可靠工具奠定基础。

### 5.2 临床应用拓展

临床应用需求是诊断模型发展的根本驱动力。目前,大多数现有模型主要用于判定病灶的存在和对其严重程度进行分级,模型未来的核心发展方向在于完成转型,即搭建一个进阶的风险评估模型,能够处理不同来源的异构数据。这种进阶模型将整合随访影像记录、临床遗传数据及其他临床生物标志物,这类模型通过模型关联分析,构建出个体化风险预测图谱,为高风险人群的早期预防性干预提供可靠的理论依据和实践支撑。

作为系统性代谢异常疾病的糖尿病,其多种微血管并发症(如糖尿病肾病、神经病变等)在病理生理机制上存在固有相关性<sup>[29]</sup>。但当前临床诊疗模式通常由不同专科进行单独筛查,没有对这种病理机制的紧密联系进行有效利用。就现有理论层面而言,对一种疾病的多种并发症进行协同判断与风险综合评估可借助统一的DL模型框架。已有研究表明,眼底血管的形态学改变不仅能够特异性反映DR进展,还对心血管隐患及肾功能损伤风险有着高度关联性。最新研究已经初步证实通过眼底影像预测肾小球滤过率(eGFR)这种技术的可行性,为建立基于眼科影像构建的全身健康评估框架提供了全新的思路<sup>[34]</sup>。

### 5.3 跨学科合作与生态构建

技术成果向临床应用转化是一项系统性工程,需依托跨学科团队的长期协作推进。DL模型在DR筛查中的成功,正是信息处理科学与临床医学两门学科进行多学科深度交织的典范。未来要进一步推动此类研究发展,必须要建立更紧密的协同创新机

制。以这项研究为例,计算机专家负责构建更可靠、高效的算法模型;临床医生提供高质量数据与医学理论支撑;生物学机制层面则是由病理医师解释新特征。这几方面在模型中完美融合,能确保技术研发始终针对真实的临床需求痛点,并加速将计算机代码转化为临床应用。将实验室成果转化到能够落实到临床的实际应用模型,仍然需要多方面的共同努力,首先由学术机构提供前沿研究成果给企业,企业再将得到的成果转化为稳定可靠的产品,完成软件开发、用户界面优化、系统部署及持续维护的基础要求,并通过医疗器械注册审批,以此达到投放于临床的技术标准,最后,医疗机构作为最终使用产品的用户,提供真正的临床实践环境,并将该产品的反馈数据进行整合,全面验证其在真实临床场景中的使用结果,与常规的操作进行比较,评估产品的安全性、有效性和临床实际应用效益。通过这种多方协同机制,可以更快促进DL模型在眼科早期筛查应用的尽早落地。

综上所述,DL技术在DR早期筛查中的应用价值已得到充分印证,具有极大的发展前景,但向临床转化的过程中仍然面临着重重挑战,包括但不限于数据、伦理和模型优化方面。为实现技术的持续进化与有效落地,亟需构建一个以临床需求为驱动、多部门协同发展的闭环生态系统:临床实践指引研究方向,学术成果通过企业转化为成熟产品,产品在真实场景中验证迭代,而在应用中发现的新问题又反馈至研究端推动新一轮创新。通过这一良性循环,DL技术有望在基层筛查等重要环节发挥核心作用,最终为DR患者视力的长期保护构筑坚实的技术防线。

**利益冲突说明:** 本文不存在利益冲突。

**作者贡献说明:** 尹智邈论文选题及修改,论文撰写,期刊论文查询及阅读,数据整合;李蓉选题指导,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] Cheung N, Mitchell P, Wong TY. Diabetic retinopathy. *Lancet*, 2010,376(9735):124-136.
- [2] Li RY, Yang ZW, Zhang Y, et al. Cost-effectiveness and cost-utility of traditional and telemedicine combined population-based age-related macular degeneration and diabetic retinopathy screening in rural and urban China. *Lancet Reg Health West Pac*, 2022,23:100435.
- [3] Peng Y, Guo XX, Liu JN, et al. Incidence and risk factors for diabetic retinopathy in the communities of Shenzhen. *Ann Palliat Med*, 2021,10(1):615-624.
- [4] Jonas JB. Diabetic retinopathy. *Asia Pac J Ophthalmol*, 2024,13(3):100077.
- [5] Yau JWY, Rogers SL, Kawasaki R, et al. Global prevalence and major risk factors of diabetic retinopathy. *Diabetes Care*, 2012,35(3):556-564.
- [6] DeLuca NJ, Wertheimer B, Ansari Z. Artificial intelligence in ophthalmic screening: advancing diabetic retinopathy detection in low-income immigrant populations. *Curr Ophthalmol Rep*, 2025,13(1):6.
- [7] Antonetti DA, Silva PS, Stitt AW. Current understanding of the molecular and cellular pathology of diabetic retinopathy. *Nat Rev Endocrinol*, 2021,17(4):195-206.
- [8] Ipp E, Liljenquist D, Bode B, et al. Pivotal evaluation of an artificial intelligence system for autonomous detection of referable and vision-threatening diabetic retinopathy. *JAMA Netw Open*, 2021,4(11):e2134254.

- [9] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015,521(7553):436–444.
- [10] Fukushima K, Miyake S, Ito T. Neocognitron: a neural network model for a mechanism of visual pattern recognition. *IEEE Trans Syst, Man, Cybern*, 1983,SMC-13(5):826–834.
- [11] Lipton ZC, Berkowitz J, Elkan C. A critical review of recurrent neural networks for sequence learning. *arXiv*, 2015.
- [12] Zhang HH, Qie YF. Applying deep learning to medical imaging: a review. *Appl Sci*, 2023,13(18):10521.
- [13] Lai C, Hu ZS, Zhu JM, et al. Development and validation of a deep learning-based automated computed tomography image segmentation and diagnostic model for infectious hydronephrosis: a retrospective multicentre cohort study. *eClinicalMedicine*, 2025,82:103146.
- [14] Huber SL, Parzer V, Ludvik B, et al. Evaluation of IDx – DR software for diabetic retinopathy screening in outpatient clinics: Efficacy, safety, and feasibility in a real – world setting. *J Diabetes Complicat*, 2025,39(10):109120.
- [15] Gulshan V, Peng L, Coram M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *Jama*, 2016,316(22):2402–2410.
- [16] Khzsrj S. Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016:770–778.
- [17] Agsmbugadamms T. Back to the future: gnn-based no<sub>2</sub> forecasting via future covariates. *2024 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, 2024:3872–3876.
- [18] Nanegrungsunk O, Patikulsila D, Sadda SR. Ophthalmic imaging in diabetic retinopathy: a review. *Clin Exper Ophthalmol*, 2022,50(9):1082–1096.
- [19] Djoumessi K, Huang ZW, Kühlewein L, et al. An inherently interpretable AI model improves screening speed and accuracy for early diabetic retinopathy. *PLoS Digit Health*, 2025,4(5):e0000831.
- [20] Wang TW, Luo WT, Tu YK, et al. Systematic review and meta-analysis of regulator-approved deep learning systems for fundus diabetic retinopathy detections. *npj Digit Med*, 2025,9:110.
- [21] Bressler I, Aviv R, Margalit D, et al. Autonomous screening for diabetic macular edema using deep learning processing of retinal images. *Ophthalmol Sci*, 2025,5(4):100722.
- [22] Ta AWA, Goh HL, Ang C, et al. Two Singapore public healthcare AI applications for national screening programs and other examples. *Health Care Sci*, 2022,1(2):41–57.
- [23] Whitestone N, Nkurikiye J, Patnaik JL, et al. Feasibility and acceptance of artificial intelligence-based diabetic retinopathy screening in Rwanda. *Br J Ophthalmol*, 2024,108(6):840–845.
- [24] McClements ME, Steward H, Atkin W, et al. Tropism of AAV vectors in photoreceptor – like cells of human iPSC – derived retinal organoids. *Trans Vis Sci Tech*, 2022,11(4):3.
- [25] Chen Y. Research progress of artificial intelligence application in diabetic retinopathy. *Adv Clin Med*, 2024,14(3):1462–1467.
- [26] 范家伟, 张如如, 陆萌, 等. 深度学习方法在糖尿病视网膜病变诊断中的应用. *自动化学报*, 2021,47(5):985–1004.
- [27] Houssein EH, Gamal AM, Younis EMG, et al. Explainable artificial intelligence for medical imaging systems using deep learning: a comprehensive review. *Clust Comput*, 2025,28(7):469.
- [28] Raman R, Dasgupta D, Ramasamy K, et al. Using artificial intelligence for diabetic retinopathy screening: Policy implications. *Indian J Ophthalmol*, 2021,69(11):2993–2998.
- [29] Sacks D, Baxter B, Campbell BCV, et al. Multisociety consensus quality improvement revised consensus statement for endovascular therapy of acute ischemic stroke. *Int J Stroke*, 2018,13(6):612–632.
- [30] Sheikh S, Qidwai U. Using MobileNetV2 to classify the severity of diabetic retinopathy. *Int J Simul Syst Sci Technol*, 2020,21(2):16.
- [31] Mahendra Singh AS, Tailor S. A review of diabetic retinopathy disease prediction using deep learning techniques. *Ijarce*, 2025,14(3):313–317.
- [32] Harun NN, Jamaludin S, Mohtar NH. Diabetic retinopathy detection with deep learning: a ResNet – CNN model enhanced by attention mechanism and ensemble learning. *OJAppS*, 2025,15(3):688–699.
- [33] Goh JHL, Ang E, Srinivasan S, et al. Comparative analysis of vision transformers and conventional convolutional neural networks in detecting referable diabetic retinopathy. *Ophthalmol Sci*, 2024,4(6):100552.
- [34] Cervera DR, Smith L, Diaz – Santana L, et al. Identifying peripheral neuropathy in colour fundus photographs based on deep learning. *Diagnostics*, 2021,11(11):1943.