

糖尿病视网膜病变预测模型的研究现状： 从传统风险因素到人工智能

李银娟^{1*}, 王 倩², 甘胜莲^{3#}, 向明钧¹

¹吉首大学医学院, 湖南 吉首

²南华大学衡阳医学院, 湖南 衡阳

³中南大学湘雅医学院附属常德医院(常德市第一人民医院)内分泌科, 湖南 常德

收稿日期: 2025年12月1日; 录用日期: 2025年12月26日; 发布日期: 2025年12月31日

摘 要

本文围绕糖尿病视网膜病变(diabetic retinopathy, DR)的核心发病机制、病变危险因素、预测模型研究进展展开论述。重点阐述了人工智能(AI)在糖尿病视网膜病变筛查与诊断中的应用, 旨在为构建更为优化、简单、有效的风险预测模型提供借鉴。

关键词

糖尿病视网膜病变, 危险因素, 预测模型, 人工智能, 深度学习

Research Status of Diabetic Retinopathy Prediction Models: From Traditional Risk Factors to Artificial Intelligence

Yinjuan Li^{1*}, Qian Wang², Shenglian Gan^{3#}, Mingjun Xiang¹

¹Medical College, Jishou University Jishou Hunan

²Hengyang Medical College of South China University, Hengyang Hunan

³Department of Endocrinology, Changde Hospital Affiliated to Xiangya Medical College of Central South University (The First People's Hospital of Changde City), Changde Hunan

Received: December 1, 2025; accepted: December 26, 2025; published: December 31, 2025

*第一作者。

#通讯作者。

文章引用: 李银娟, 王倩, 甘胜莲, 向明钧. 糖尿病视网膜病变预测模型的研究现状: 从传统风险因素到人工智能[J]. 临床个性化医学, 2026, 5(1): 332-340. DOI: 10.12677/jcpm.2026.51048

Abstract

This article focuses on the core pathogenesis, risk factors and prediction models of diabetic retinopathy (DR). This paper focuses on the application of artificial intelligence (AI) in the screening and diagnosis of diabetic retinopathy, aiming to provide reference for the construction of a more optimized, simple and effective risk prediction model.

Keywords

Diabetic Retinopathy, Risk Factors, Prediction Model, Artificial Intelligence, Deep Learning

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

糖尿病视网膜病变(diabetic retinopathy, DR)是糖尿病常见的并发症之一,累及近三分之一的糖尿病患者,已成为各年龄段人群视力丧失的主要原因,且其导致的视力损害通常不可逆转[1]-[3]。全球 DR 患病率持续增高,预计到 2045 年患者总数将增至 1.605 亿[4]。在我国,DR 同样成为一项严峻的公共卫生挑战。2010 年数据显示,我国糖尿病人群 DR 患病率为 18.45%,45 岁以上 DR 患者约 1316 万人[5]。早期糖尿病视网膜病变发病隐匿、症状不明显,若未及时干预,易迅速发展为威胁视力的病变,引发玻璃体出血、牵拉性视网膜脱离等严重并发症。然而,目前 DR 的诊断主要依赖于眼底摄影和眼底荧光血管造影,这些方法在大规模筛查中成本高、劳动强度大、耗时长[6]。这也不适用于基层和大规模人群流行病学调查,特别是在偏远地区,DR 的筛查极具挑战性。因此,建立更加简单、有效、更具成本效益的风险预测模型,对于提升 DR 的筛查效率与普及性、改善患者预后以及节省医疗资源具有重要的意义。

2. 糖尿病视网膜病变的核心发病机制

DR 的核心病理特征包括周细胞丢失、微动脉瘤形成及新生血管生成等。持续的高血糖状态可通过激活炎症细胞释放 IL-1 β 等因子,触发 NF- κ B/HIF-1 α 信号通路,上调血管内皮生长因子(VEGF)导致血管功能障碍。同时高血糖状态促使晚期糖基化终末产物(AGEs)形成,经 RAGE 信号加剧氧化应激,共同推动血-视网膜屏障破坏和病理性新生血管形成,最终促进 DR 进展[7] [8]。

3. 糖尿病视网膜病变的危险因素

DR 的发生与发展涉及多种危险因素的交互作用。其中,糖化血红蛋白(HbA1c)、糖尿病病程、尿微量蛋白以及高血压被证实为 DR 的显著危险因素[9]-[12]。研究表明,收缩压每升 1 mmHg,DR 风险约增加 1.01 倍;HbA1c 每升 1%,DR 风险增加 1.26 倍[13]。在糖尿病病程少于 8 年的患者中,病程每增加 1 年,DR 患病率上升 24% [14]。其他还包括高甘油三酯、肥胖、吸烟、维生素 D 缺乏以及炎症标志物升高等因素,均与糖尿病视网膜病变风险增加相关[15]-[18]。这些发现强调了严格控制血糖与管理多重危险因素对于延缓 DR 发生和发展中的重要性。

4. 基于回归分析与列线图的 DR 预测模型研究进展

临床预测模型是一种能够对特定研究对象的某临床结局事件发生概率进行预测的模型,其中包括诊断模型和预后模型,并且在疾病风险分层、预后预测及精准医疗决策等领域具有重要价值[19][20]。在众多建模方法中,基于 logistic 回归或 COX 风险回归构建的列线图模型应用尤为广泛。此类模型是一种整合已知的 DR 危险因素,能够量化估计个体发病风险,便于快速、大规模地识别高危人群,提高 DR 筛查阳性率。

多项研究在此领域进行了探索,例如,Gao 等人[21]纳入 2585 名 T2DM 患者,利用糖化血红蛋白、血清尿素及糖尿病病程构建了预测 1、3、5 年 DR 风险的列线图,该模型在训练集与验证集中均表现出良好的判别能力,但其在不同人群中的适用性仍需外部验证。Guo 等人[22]整合 21 项队列研究,构建了包含性别、吸烟史、糖尿病病程、蛋白尿、糖化血红蛋白、收缩压及甘油三酯共 7 项危险因素的 DR 预测模型,经中位 32 个月随访验证,该模型表现出高度可靠性,且有效实现了风险分层管理,对于低危患者可适当延长筛查间隔,高危人群则需加强随访次数并实施早期干预。Zhu 等人[23]纳入了减重手术、近视、降脂药物、强化血糖控制、糖尿病病程、HbA1c、空腹血糖、高血压等危险因素,其构建的模型的 AUC 值达 0.912,并据此开发了便于患者自我管理的智能手机应用程序。Li 等人[24]基于 2381 例新疆 T2DM 患者,构建了纳入中性粒细胞、25-羟基维生素 D3、2 型糖尿病病程、糖化血红蛋白和载脂蛋白 A1 建立的预测 DR 风险列线图。该模型在开发与外部验证中 AUC 分别达 0.834 和 0.851,该模型为缺乏眼底检查条件的初级保健机构提供了有效的 DR 风险评估工具,尤其适用于医疗资源不均衡地区。刘乙君[25]等收集 1276 例 2 型糖尿病患者的临床资料,采用多因素 logistic 逐步回归法筛选模型变量,最终纳入年龄、收缩压、糖化血红蛋白、尿微量白蛋白/肌酐比值和血肌酐,构建预测非增殖性糖尿病视网膜病变(NPDR)发病风险的列线图模型,并开发了网页版动态列线图。临床医师通过利用这种成本低廉且方便快捷的可视化工具,可有效地及时识别 NPDR 高危患者,提高早期筛查率。此外,有研究尝试将糖尿病周围神经病变纳入预测模型,但因研究对象地域局限且该病变本身筛查率低,其普适性有待进一步探讨[26]。总体而言,现有模型多基于单中心数据,普遍存在缺乏外部验证、难以确定因果关系等局限性,因此,未来研究亟需通过多中心、前瞻性的多队列对现有模型进行优化与验证,并进一步探索人工智能技术,以最终实现 DR 的精准、个体化风险预警。

5. 人工智能在 DR 中的应用与研究进展

近年来,人工智能(AI)技术日益成为医疗领域的变革性力量,尤其在数据分析、模式识别和预测建模方面展现出强大的潜力[27][28]。其中,深度学习是机器学习的分支,它主要使用人工神经网络作为学习模型,已广泛应用于生物医学数据分析[29]。基于眼底图像的 AI 辅助诊断系统,凭借其准确性高、更加快速和高效的优势,已在 DR 早期筛查中广泛应用。基于深度学习 DR 诊断的一般框架包括数据获取、医学影像标注、病灶区域检测、病变等级分类及模型评估等步骤。这类技术从公共数据集以及医疗机构获取数据,深度学习大量眼底照片,自动识别并提取出眼底图片中不同 DR 病变特征,并根据这些特征提供辅助诊断意见,在成本效益方面优于传统人工分级[30][31]。相比于早期传统机器学习方法,深度学习模型性能更高,灵敏度和特异性均达到 95% [32]。当前,美国食品药品监督管理局(FDA)已批准数种 AI 筛查设备投入临床使用,如 IDx-DR、EyeArt 和 AEYE-DS [33]。且有多项研究验证了 AI 筛查的有效性,例如,Heydon 等人[34]基于英国大规模筛查计划的数据证实, EyeArt 软件能高灵敏度地识别需转诊的视网膜病变,并能将人工阅片工作量减少一半。有望解决专业人手不足的问题,实现高效大规模筛查。Shah 等人[35]回顾性分析 1533 张黄斑中心眼底图像,由两名视网膜专家将图像分级,并与 AI 结果进行比较。

研究发现,一种基于深度卷积神经网络的 AI 算法在检测 DR 时,敏感性与特异性分别高达 99.7%和 98.5%,并且该算法能对病变区域进行标注,增强了结果的可解释性。临床医生通过病变标注从而理解人工智能的判断依据,也能进一步利用这一高效的筛查工具监测病变进展。一项基于泰国筛查的项目[36]比较了通过深度学习和人工分级两种方式进行 DR 筛查的情况,结果显示深度学习在纵向随访筛查中的预测性能优于人工分级。吴娜等人[37]发现 AI 系统筛查 DR 的阳性预测值高达 99.34%,且漏诊率低(3.85%),效能可靠。该研究提出,长病程、高血压、血糖及血脂异常是 DR 的危险因素。因此,在利用 AI 进行高效筛查的同时,积极控制血糖、血压和血脂,对预防和延缓 DR 至关重要。还有更多研究结论一致[38]-[41],认为与人工阅片组诊断结果相比, AI 在 DR 初级筛查中具有较高的准确性及敏感度,适合大规模推广应用。虽有研究如 Eliot R 等报告 AI 特异性略低于专家诊断,但通过构建 AI 与人工协作的工作流程,可在保证诊断准确性的同时减轻专家负担[42]。

除了基于眼底影像的分析,利用临床指标预测 DR 风险的机器学习模型同样也展现出良好性能。Tao 等人[43]采用分类回归树模型,从 96 项临床指标中筛选出 C 反应蛋白等 11 个核心指标,基于这 11 项指标的 CART 模型的预测性能不逊于复杂 AI 模型,且模型分析显示,当糖尿病患者出现尿肌酐(Ucr) ≥ 127.75 mg/dl 且皮质醇 ≥ 318.8 ug/l 时, DR 的患病率高达 100%。此外,即使上述两项指标均未超出正常范围,当 C 反应蛋白(CRP) ≥ 10.11 mg/l 时, DR 的发生风险也会显著增加,这也揭示了 DR 与肾功能损伤、胰岛素抵抗及炎症反应的关联。Jiang 等人[44]通过 LASSO 回归模型筛选出 5 个临床特征,包括病程、糖尿病周围神经病变、胰岛素剂量、尿蛋白及白蛋白,比较了决策树(DT)、k 近邻(KNN)、逻辑回归模型(LM)、随机森林(RF)、支持向量机(SVM)和 XGBoost (XGB)六种机器学习算法预测 DR 的能力,结果显示 LM 算法表现最佳(AUC 0.894)。基于此 LM 算法的预测模型展现出稳健的区分能力以及广泛的临床适用性,这一模型也为内科医生提供了一种量化 DR 发生风险的方法,从而有助于早期识别并转诊高危患者。Li 等人[45]回顾性分析 32,452 名 2 型糖尿病患者的电子健康数据记录,纳入了 17 个变量,结果显示 XGBoost 模型为最佳预测模型, AUC 为 0.90, 研究分析显示 HbA1c $> 8\%$ 、肾病、血清肌酐值 > 100 μ mol/L、胰岛素治疗和糖尿病性下肢动脉疾病均与 DR 风险增加相关,并指出该 XGBoost 预测模型的性能不及专门的眼底影像 AI 系统,但二者的应用目标不同:前者侧重于糖尿病患者健康管理与提高筛查依从性,后者则专注于眼科诊断。

多模态数据融合技术(MDF)是人工智能领域中的一种数据处理技术,是指利用计算机对多模态数据,如图片、文字、音频与视频等进行综合处理的技术。近年来,该技术在眼科领域的应用研究取得了较大进展,并能提高人工智能辅助诊断的准确性[46]。Jesse A. Most [47]评估 4 种多模态大语言模型(MLLMs)通过眼底照片对 DR 检测和分级的准确性,研究发现部分模型(如 ChatGPT、Claude)准确性超 60%,且能够生成诊断理由的文字描述,便于医生理解和验证,但整体敏感性和严重程度分级能力未达临床标准,仅使用超广角眼底图像,未结合多模态影像或临床信息。Min-Yen Hsu [48]通过融合眼底图像与电子健康记录中的非图像数据,如年龄、性别、实验室检查结果等,构建到深度学习模型以提高 DR 筛查的准确性。该研究显示,融合模型在区分可转诊 DR 与非转诊 DR 时, AUC 达 97.96%,灵敏度 96.84%,特异性 89.44%,显著优于单独图像模型(AUC 94.63%)和非图像模型(AUC 最高 81.90%)。这一结果表明了融合数据不仅提升了模型准确性,还降低了对大规模图像标注的依赖,有助于推动 AI 辅助 DR 筛查在资源有限地区的应用。Sadhu 等人同样[49]发现,将 OCT/OCTA 数据与年龄、性别、高血压、高脂血症和 HbA1c 等常规临床指标结合可显著提升非增殖性糖尿病视网膜病变诊断效能,该系统的准确率为 96%,灵敏度为 100%,特异性为 94%。总的来说,这种融合方法不仅增强了计算机辅助诊断能力,更有助于 DR 患者的筛查、转诊、治疗,从而减轻临床负担,降低医疗成本[50]。

6. 人工智能在真实世界临床实践中的整合策略与挑战

一项在印度公共卫生机构开展的评估 AI 驱动 DR 筛查研究,其工作流程分为两阶段,验证阶段用低成本非散瞳眼底相机采集 250 名糖尿病患者眼底图像,筛选出表现最佳的 AI 模型,实施阶段将其集成至社区卫生中心。实施过程中,验光师经培训采集图像,AI 进行实时分析,专家监督质控,从而建立“验光师-AI-眼科医师”转诊路径[51]。在成本效益方面,AI 成本包括初始成本(研发、数据集验证等)和维护成本(算法升级、硬件维护等),成本效益分析显示,AI 单独或与人类结合用于 DR 筛查比人工筛查更具成本效益,半自动化模型常为最经济策略[52]。来自新加坡的一项研究发现,半自主模型比自主筛查更节省成本。在这项研究中,人工分级的成本为每位患者每年 77 美元,而自主筛查的成本为每位患者每年 66 美元,半自主模式的成本为每位患者每年 62 美元[53]。

当前 AI 系统在 DR 防治中的临床应用中仍面临以下诸多挑战。首先,深度学习网络的参数具有复杂性,通常需要大量高质量的标注数据用于训练,而获取医生标注的成本较高,导致用于模型训练的数据相对不足[54]。其次,深度学习模型本具有“黑盒”特性,可解释性较差,且识别模式与传统病灶识别技术存在差异,这也在一定程度上影响了临床医生对模型结果的信任[55]-[57]。此外,医学数据往往涉及到患者隐私保护、知情同意、伦理规范及法律合规等问题[58][59]。另一方面,模型存在泛化能力不足及过拟合问题,且不同 DR 类别之间存在严重的数据不平衡,且各类别之间存在相似性问题,模型难以准确分级[60]。另外将 AI 模型集成到摄像系统及如何将 AI 与现有医院管理系统或电子病历系统集成到 DR 筛查系统也是临床实施的另一个挑战[61]。

7. 人工智能在糖尿病视网膜病变的应用价值及未来展望

尽管面临上述挑战,人工智能在 DR 防治中已呈现出多方面的应用价值。在基层眼科医师数量有限、糖尿病患者随访困难、医疗资源分布不均的背景下,AI 辅助筛查系统凭借操作简便、判读迅速、准确度较高等优势,有助于提升基层医疗机构的筛查能力与诊断效率。这种技术手段也有助于促进形成以“筛查-转诊-确诊-随访”为路径的 DR 管理模式[37]。其次,基于人工智能的筛查方案具有显著的成本效益优势,尤其适合在医疗条件有限的地区进行推广与应用[62]-[64]。另外,AI 系统能够整合患者的糖尿病病程、糖化血红蛋白动态变化等多项临床指标,从而为医生提供更全面的风险评估依据,辅助制定个性化治疗方案,推动 DR 防治从标准化诊疗向精准管理转型[59]。最后,随着远程医疗平台的快速发展,AI 技术也有助于构建跨地域的数字健康服务体系,能够进一步拓展筛查服务的覆盖范围,提升其可及性。

在未来的 DR 研究中,AI 有望筛选出免疫及基因相关新型生物标志物,并在此基础上构建早期诊断模型并探索靶向治疗药物[65]。已有研究证实 miRNA 可作为 DR 分期的生物标志物,且其表达水平与 OCT 检测的视网膜高反射斑点(HRS)相关,生物信息学分析进一步表明这些 miRNA 与肿瘤坏死因子 α (TNF- α)信号通路相关,或为潜在药物靶点[66]。然而在诊断应用的深度学习模型开发过程中,模型训练通常需要大规模患者数据,而全球相应的隐私法规与标准对这些数据的共享和使用构成了巨大挑战。例如,美国的 HIPAA、欧盟的 GDPR、加拿大的 PIPEDA、日本的 APPI,澳大利亚的 My Health Records Act 以及中国的 PIPL,均对健康数据的管理有严格限制[67]。目前,联邦学习不仅可在保持数据隐私的同时,更在模型基准测试上展现出更优性能,从而为数据共享限制提供了可解决方案[68]。另一方面,为增强预测的透明度和准确性,提高临床信任度,可解释人工智能(XAI)技术也正被整合至 DR 模型中,协助眼科医生做出精确、个性化且及时的诊断决策[69]。

8. 小结

综上所述,糖尿病视网膜病变风险预测模型通常纳入糖化血红蛋白、糖尿病病程、尿微量蛋白及高

血压等核心变量,且国内外研究构建 DR 预测模型的方法大多采用传统模型,如基于回归分析与列线图的传统模型,未来可进一步开发和验证不同模型的性能,增加多中心验证或增加新变量以提高模型预测效能[70]。另外,人工智能在 DR 风险预测及分级领域具有巨大的潜能,无论是在眼底影像的自动判读,还是融合多维度临床数据的风险预测方面,均表现出卓越性能。尽管面临一系列挑战,但 AI 技术凭借其高效、便捷和成本效益高的优势,有望未来在基层医疗与分级诊疗体系中发挥越来越重要的作用。也相信未来基于 AI 的 DR 预测模型,可以帮助临床医生更精准地评估风险、实现疾病分级,并推动 DR 的个性化诊疗。

参考文献

- [1] Khalil, H. (2017) Diabetes Microvascular Complications—A Clinical Update. *Diabetes & Metabolic Syndrome: Clinical Research & Reviews*, **11**, S133-S139. <https://doi.org/10.1016/j.dsx.2016.12.022>
- [2] 刘明珠, 管怀进. 糖尿病前期和糖尿病视网膜病变临床前期的视网膜改变[J]. 眼科学报, 2023, 38(6): 454-460+489.
- [3] Al-Namaeh, M. (2022) Common Causes of Visual Impairment in the Elderly. *Medical Hypothesis Discovery and Innovation in Ophthalmology*, **10**, 191-200. <https://doi.org/10.51329/mehdiophthal1438>
- [4] Teo, Z.L., Tham, Y., Yu, M., Chee, M.L., Rim, T.H., Cheung, N., et al. (2021) Global Prevalence of Diabetic Retinopathy and Projection of Burden through 2045: Systematic Review and Meta-Analysis. *Ophthalmology*, **128**, 1580-1591. <https://doi.org/10.1016/j.ophtha.2021.04.027>
- [5] Song, P., Yu, J., Chan, K.Y., Theodoratou, E. and Rudan, I. (2018) Prevalence, Risk Factors and Burden of Diabetic Retinopathy in China: A Systematic Review and Meta-Analysis. *Journal of Global Health*, **8**, Article 010803. <https://doi.org/10.7189/jogh.08.010803>
- [6] Zhang, Y., Shi, J., Peng, Y., Zhao, Z., Zheng, Q., Wang, Z., et al. (2020) Artificial Intelligence-Enabled Screening for Diabetic Retinopathy: A Real-World, Multicenter and Prospective Study. *BMJ Open Diabetes Research & Care*, **8**, e001596. <https://doi.org/10.1136/bmjdr-2020-001596>
- [7] Seo, H., Park, S.J. and Song, M. (2025) Diabetic Retinopathy (DR): Mechanisms, Current Therapies, and Emerging Strategies. *Cells*, **14**, Article 376. <https://doi.org/10.3390/cells14050376>
- [8] 徐荣锦, 刘洪涛, 李明波. 糖尿病视网膜病变的发病机制及炎症因素的研究现状[J]. 中国临床药理学杂志, 2025, 41(12): 1789-1794.
- [9] Chawla, S., Trehan, S., Chawla, A., Jaggi, S., Chawla, R., Kumar, V., et al. (2021) Relationship between Diabetic Retinopathy Microalbuminuria and Other Modifiable Risk Factors. *Primary Care Diabetes*, **15**, 567-570. <https://doi.org/10.1016/j.pcd.2021.01.012>
- [10] Alshahrani, A.M., Alshahrani, A.M., Al-Boqami, B.A.H., Alqahtani, A.A., Alzahrani, B., Bassi, Y., et al. (2024) Prevalence and Predictors of Diabetic Retinopathy in Saudi Arabia: Insights from a Systematic Review and Meta-Analysis. *Bio-molecules*, **14**, Article 1486. <https://doi.org/10.3390/biom14121486>
- [11] Cui, X., Wen, D., Xiao, J. and Li, X. (2025) The Causal Relationship and Association between Biomarkers, Dietary Intake, and Diabetic Retinopathy: Insights from Mendelian Randomization and Cross-Sectional Study. *Diabetes & Metabolism Journal*, **49**, 1087-1105. <https://doi.org/10.4093/dmj.2024.0731>
- [12] Liu, Y., Wang, M., Morris, A.D., Doney, A.S.F., Leese, G.P., Pearson, E.R., et al. (2013) Glycemic Exposure and Blood Pressure Influencing Progression and Remission of Diabetic Retinopathy: A Longitudinal Cohort Study in GoDARTS. *Diabetes Care*, **36**, 3979-3984. <https://doi.org/10.2337/dc12-2392>
- [13] Xiao, B., Duan, F., Gu, X., Zuo, J., Chan, V.F., Virgili, G., et al. (2025) Differences in Prevalence and Risk Factors of Diabetic Retinopathy among Rural and Urban Residents with Diabetes in South China: A Cross-Sectional Study. *BMJ Open*, **15**, e092526. <https://doi.org/10.1136/bmjopen-2024-092526>
- [14] Zhang, D., Zhang, Y., Kang, J. and Li, X. (2024) Nonlinear Relationship between Diabetes Mellitus Duration and Diabetic Retinopathy. *Scientific Reports*, **14**, Article No. 30223. <https://doi.org/10.1038/s41598-024-82068-5>
- [15] Perais, J., Agarwal, R., Evans, J.R., Loveman, E., Colquitt, J.L., Owens, D., et al. (2023) Prognostic Factors for the Development and Progression of Proliferative Diabetic Retinopathy in People with Diabetic Retinopathy. *Cochrane Database of Systematic Reviews*, **2023**, CD013775. <https://doi.org/10.1002/14651858.cd013775.pub2>
- [16] Su, Z., Wu, Z., Liang, X., Xie, M., Xie, J., Li, H., et al. (2023) Diabetic Retinopathy Risk in Patients with Unhealthy Lifestyle: A Mendelian Randomization Study. *Frontiers in Endocrinology*, **13**, Article 1087965. <https://doi.org/10.3389/fendo.2022.1087965>

- [17] Gverović Antunica, A., Znaor, L., Ivanković, M., Puzović, V., Marković, I. and Kaštelan, S. (2023) Vitamin D and Diabetic Retinopathy. *International Journal of Molecular Sciences*, **24**, Article 12014. <https://doi.org/10.3390/ijms241512014>
- [18] Bulu, A. and Keser, S. (2025) The Relationship between Pan-Immune Inflammation Value and Different Stages of Diabetic Retinopathy in Patients with Type 2 Diabetes Mellitus: A Prospective Cross-Sectional Study. *BMC Endocrine Disorders*, **25**, Article No. 184. <https://doi.org/10.1186/s12902-025-02007-x>
- [19] 帅雨杏, 神雪薇, 王婧怡, 等. 2024 临床预测模型开发逐步指南解读[J]. 中国循证医学杂志, 2025, 25(10): 1226-1232.
- [20] 谷鸿秋, 周支瑞, 章仲恒, 等. 临床预测模型: 基本概念、应用场景及研究思路[J]. 中国循证心血管医学杂志, 2018, 10(12): 1454-1456+1462.
- [21] Gao, J.J., Liu, H., Zhang, T.Y., et al. (2025) A Simple and Accessible Diabetic Retinopathy Risk Prediction Model: Establishment and Validation in a Hospital-Based Cohort of Type 2 Diabetes Patients. *Diabetes Research and Clinical Practice*, **224**, Article 112211. <https://doi.org/10.1016/j.diabres.2025.112211>
- [22] Guo, H., Han, F., Qu, J., Pan, C., Sun, B. and Chen, L. (2024) Scoring and Validation of a Simple Model for Predicting Diabetic Retinopathy in Patients with Type 2 Diabetes Based on a Meta-Analysis Approach of 21 Cohorts. *Annals of Medicine*, **56**, Article No. 2413920. <https://doi.org/10.1080/07853890.2024.2413920>
- [23] Zhu, C., Zhu, J., Wang, L., Xiong, S., Zou, Y., Huang, J., et al. (2023) Development and Validation of a Risk Prediction Model for Diabetic Retinopathy in Type 2 Diabetic Patients. *Scientific Reports*, **13**, Article No. 5034. <https://doi.org/10.1038/s41598-023-31463-5>
- [24] Li, Y., Hu, B., Lu, L., Li, Y., Caika, S., Song, Z., et al. (2024) Development and External Validation of a Predictive Model for Type 2 Diabetic Retinopathy. *Scientific Reports*, **14**, Article No. 16741. <https://doi.org/10.1038/s41598-024-67533-5>
- [25] 刘乙君, 王彦, 赵英, 等. 山西省 2 型糖尿病患者非增殖性糖尿病视网膜病变现况调查及预测模型的构建[J]. 中华糖尿病杂志, 2023, 15(7): 622-629.
- [26] Yang, J. and Jiang, S. (2022) Development and Validation of a Model That Predicts the Risk of Diabetic Retinopathy in Type 2 Diabetes Mellitus Patients. *Acta Diabetologica*, **60**, 43-51. <https://doi.org/10.1007/s00592-022-01973-1>
- [27] Bajwa, J., Munir, U., Nori, A. and Williams, B. (2021) Artificial Intelligence in Healthcare: Transforming the Practice of Medicine. *Future Healthcare Journal*, **8**, e188-e194. <https://doi.org/10.7861/fhj.2021-0095>
- [28] Maleki Varnosfaderani, S. and Forouzanfar, M. (2024) The Role of AI in Hospitals and Clinics: Transforming Healthcare in the 21st Century. *Bioengineering*, **11**, Article 337. <https://doi.org/10.3390/bioengineering11040337>
- [29] 王瑞松, 王胜男, 石铁流. 深度学习在生物医学领域中的应用简介[J]. 中国科学:生命科学, 2025, 55(6): 1268-1287.
- [30] Murali, N. and Forster, S. (2018) Re: Lee et al.: Machine Learning Has Arrived! (Ophthalmology. 2017; 124: 1726-1728). *Ophthalmology*, **125**, e85. <https://doi.org/10.1016/j.ophtha.2018.06.027>
- [31] Bhaskaranand, M., Ramachandra, C., Bhat, S., Cuadros, J., Nittala, M.G., Sadda, S., et al. (2016) Automated Diabetic Retinopathy Screening and Monitoring Using Retinal Fundus Image Analysis. *Journal of Diabetes Science and Technology*, **10**, 254-261. <https://doi.org/10.1177/1932296816628546>
- [32] Gulshan, V., Peng, L., Coram, M., Stumpe, M.C., Wu, D., Narayanaswamy, A., et al. (2016) Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *Journal of the American Medical Association*, **316**, 2402-2410. <https://doi.org/10.1001/jama.2016.17216>
- [33] Rajesh, A.E., Davidson, O.Q., Lee, C.S. and Lee, A.Y. (2023) Artificial Intelligence and Diabetic Retinopathy: AI Framework, Prospective Studies, Head-to-Head Validation, and Cost-Effectiveness. *Diabetes Care*, **46**, 1728-1739. <https://doi.org/10.2337/dci23-0032>
- [34] Heydon, P., Egan, C., Bolter, L., Chambers, R., Anderson, J., Aldington, S., et al. (2021) Prospective Evaluation of an Artificial Intelligence-Enabled Algorithm for Automated Diabetic Retinopathy Screening of 30,000 Patients. *British Journal of Ophthalmology*, **105**, 723-728. <https://doi.org/10.1136/bjophthalmol-2020-316594>
- [35] Shah, P., Mishra, D., Shanmugam, M., Doshi, B., Jayaraj, H. and Ramanjulu, R. (2020) Validation of Deep Convolutional Neural Network-Based Algorithm for Detection of Diabetic Retinopathy—Artificial Intelligence versus Clinician for Screening. *Indian Journal of Ophthalmology*, **68**, 398-405. https://doi.org/10.4103/ijo.ijo_966_19
- [36] Limwattanayingyong, J., Nganthavee, V., Seresirikachorn, K., Singalavanija, T., Soonthornworasiri, N., Ruamviboonsuk, V., et al. (2020) Longitudinal Screening for Diabetic Retinopathy in a Nationwide Screening Program: Comparing Deep Learning and Human Graders. *Journal of Diabetes Research*, **2020**, Article 8839376. <https://doi.org/10.1155/2020/8839376>
- [37] 吴娜, 刘昊楠, 李博宇, 等. 糖尿病视网膜病变危险因素及人工智能辅助 DR 筛查的应用价值[J]. 中国老年学杂志

- 志, 2025, 45(1): 61-65.
- [38] Ruamviboonsuk, P., Tiwari, R., Sayres, R., Nganthavee, V., Hemarat, K., Kongprayoon, A., *et al.* (2022) Real-Time Diabetic Retinopathy Screening by Deep Learning in a Multisite National Screening Programme: A Prospective Interventional Cohort Study. *The Lancet Digital Health*, **4**, e235-e244. [https://doi.org/10.1016/s2589-7500\(22\)00017-6](https://doi.org/10.1016/s2589-7500(22)00017-6)
 - [39] 郑武, 阮坤炜, 吴天添, 等. 人工智能糖尿病视网膜病变筛查系统与眼科医师诊断结果的一致性分析[J]. 眼科新进展, 2020, 40(12): 1170-1173.
 - [40] 李政章, 顾建芬, 梁伟, 等. 人工智能读片对评估糖尿病视网膜病变及预测慢性并发症的价值分析[J]. 中国糖尿病杂志, 2022, 30(11): 817-820.
 - [41] 王曼丽, 李博, 张瑞瑞, 等. 免散瞳眼底照相联合人工智能糖尿病视网膜病变筛查系统在内分泌科的应用价值[J]. 中国糖尿病杂志, 2022, 30(11): 808-811.
 - [42] Dow, E.R., Khan, N.C., Chen, K.M., Mishra, K., Perera, C., Narala, R., *et al.* (2023) Artificial Intelligence-Human Hybrid Workflow Enhances Teleophthalmology for the Detection of Diabetic Retinopathy. *Ophthalmology Science*, **3**, Article 100330. <https://doi.org/10.1016/j.xops.2023.100330>
 - [43] Tao, T., Liu, K., Yang, L., Liu, R., Xu, Y., Xu, Y., *et al.* (2025) Predicting Diabetic Retinopathy Based on Biomarkers: Classification and Regression Tree Models. *Diabetes Research and Clinical Practice*, **222**, Article 112091. <https://doi.org/10.1016/j.diabres.2025.112091>
 - [44] Jiang, W. and Li, Z. (2024) Comparison of Machine Learning Algorithms and Nomogram Construction for Diabetic Retinopathy Prediction in Type 2 Diabetes Mellitus Patients. *Ophthalmic Research*, **67**, 537-548. <https://doi.org/10.1159/000541294>
 - [45] Li, W., Song, Y., Chen, K., Ying, J., Zheng, Z., Qiao, S., *et al.* (2021) Predictive Model and Risk Analysis for Diabetic Retinopathy Using Machine Learning: A Retrospective Cohort Study in China. *BMJ Open*, **11**, e050989. <https://doi.org/10.1136/bmjopen-2021-050989>
 - [46] 陈铭海, 白芳, 陶海. 多模态数据融合技术及其在眼科领域的应用研究进展[J]. 眼科新进展, 2024, 44(3): 248-252.
 - [47] Most, J.A., Walker, E.H., Mehta, N.N., Nagel, I.D., Chen, J.S., Russell, J.F., *et al.* (2025) Can Multimodal Large Language Models Diagnose Diabetic Retinopathy from Fundus Photos? A Quantitative Evaluation. *Ophthalmology Science*, **6**, Article 100911. <https://doi.org/10.1016/j.xops.2025.100911>
 - [48] Hsu, M.Y., Chiou, J.Y., Liu, J.T., *et al.* (2021) Deep Learning for Automated Diabetic Retinopathy Screening Fused with Heterogeneous Data from EHRs Can Lead to Earlier Referral Decisions. *Translational Vision Science & Technology*, **10**, Article 18. <https://doi.org/10.1167/tvst.10.9.18>
 - [49] Sandhu, H.S., Elmogy, M., Taher Sharafeldeen, A., Elsharkawy, M., El-Adawy, N., Eltanboly, A., *et al.* (2020) Automated Diagnosis of Diabetic Retinopathy Using Clinical Biomarkers, Optical Coherence Tomography, and Optical Coherence Tomography Angiography. *American Journal of Ophthalmology*, **216**, 201-206. <https://doi.org/10.1016/j.ajo.2020.01.016>
 - [50] Li, X., Wen, X., Shang, X., Liu, J., Zhang, L., Cui, Y., *et al.* (2024) Identification of Diabetic Retinopathy Classification Using Machine Learning Algorithms on Clinical Data and Optical Coherence Tomography Angiography. *Eye*, **38**, 2813-2821. <https://doi.org/10.1038/s41433-024-03173-3>
 - [51] Duggal, M., Chauhan, A., Gupta, V., Kankaria, A., Budhija, D., Verma, P., *et al.* (2025) Real-World Evaluation of AI-Driven Diabetic Retinopathy Screening in Public Health Settings: Validation and Implementation Study. *JMIR Medical Informatics*, **13**, e67529. <https://doi.org/10.2196/67529>
 - [52] Ruamviboonsuk, P., Chandra, S., Seresirikachorn, K., Ruamviboonsuk, V. and Sangroongruangsri, S. (2021) Economic Evaluations of Artificial Intelligence in Ophthalmology. *Asia-Pacific Journal of Ophthalmology*, **10**, 307-316. <https://doi.org/10.1097/apo.0000000000000403>
 - [53] Xie, Y., Nguyen, Q.D., Hamzah, H., Lim, G., Bellemo, V., Gunasekaran, D.V., *et al.* (2020) Artificial Intelligence for Teleophthalmology-Based Diabetic Retinopathy Screening in a National Programme: An Economic Analysis Modelling Study. *The Lancet Digital Health*, **2**, e240-e249. [https://doi.org/10.1016/s2589-7500\(20\)30060-1](https://doi.org/10.1016/s2589-7500(20)30060-1)
 - [54] 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[J]. 自动化学报, 2021, 47(5): 985-1004.
 - [55] Rudin, C. and Radin, J. (2019) Why Are We Using Black Box Models in AI When We Don't Need To? A Lesson from an Explainable AI Competition. *Harvard Data Science Review*, **1**, 1-9. <https://doi.org/10.1162/99608f92.5a8a3a3d>
 - [56] Evans, N.G., Wenner, D.M., Cohen, I.G., Purves, D., Chiang, M.F., Ting, D.S.W., *et al.* (2022) Emerging Ethical Considerations for the Use of Artificial Intelligence in Ophthalmology. *Ophthalmology Science*, **2**, Article 100141. <https://doi.org/10.1016/j.xops.2022.100141>

- [57] Cross, J.L., Choma, M.A. and Onofrey, J.A. (2024) Bias in Medical AI: Implications for Clinical Decision-Making. *PLOS Digital Health*, **3**, e0000651. <https://doi.org/10.1371/journal.pdig.0000651>
- [58] Xu, X., Zhang, M., Huang, S., Li, X., Kui, X. and Liu, J. (2024) The Application of Artificial Intelligence in Diabetic Retinopathy: Progress and Prospects. *Frontiers in Cell and Developmental Biology*, **12**, Article 1473176. <https://doi.org/10.3389/fcell.2024.1473176>
- [59] Sheng, B., Chen, X., Li, T., Ma, T., Yang, Y., Bi, L., et al. (2022) An Overview of Artificial Intelligence in Diabetic Retinopathy and Other Ocular Diseases. *Frontiers in Public Health*, **10**, Article 971943. <https://doi.org/10.3389/fpubh.2022.971943>
- [60] 孙石磊, 李明, 刘静, 等. 深度学习在糖尿病视网膜病变分类领域的研究进展[J]. 计算机工程与应用, 2024, 60(8): 16-30.
- [61] Grzybowski, A., Singhanetr, P., Nanegrungsunk, O. and Ruamviboonsuk, P. (2023) Artificial Intelligence for Diabetic Retinopathy Screening Using Color Retinal Photographs: From Development to Deployment. *Ophthalmology and Therapy*, **12**, 1419-1437. <https://doi.org/10.1007/s40123-023-00691-3>
- [62] Kong, M. and Song, S.J. (2024) Artificial Intelligence Applications in Diabetic Retinopathy: What We Have Now and What to Expect in the Future. *Endocrinology and Metabolism*, **39**, 416-424. <https://doi.org/10.3803/enm.2023.1913>
- [63] Lee, A.Y., Yanagihara, R.T., Lee, C.S., Blazes, M., Jung, H.C., Chee, Y.E., et al. (2021) Multicenter, Head-to-Head, Real-World Validation Study of Seven Automated Artificial Intelligence Diabetic Retinopathy Screening Systems. *Diabetes Care*, **44**, 1168-1175. <https://doi.org/10.2337/dc20-1877>
- [64] Fuller, S.D., Hu, J., Liu, J.C., Gibson, E., Gregory, M., Kuo, J., et al. (2022) Five-Year Cost-Effectiveness Modeling of Primary Care-Based, Nonmydriatic Automated Retinal Image Analysis Screening among Low-Income Patients with Diabetes. *Journal of Diabetes Science and Technology*, **16**, 415-427. <https://doi.org/10.1177/1932296820967011>
- [65] Tao, Y., Xiong, M., Peng, Y., Yao, L., Zhu, H., Zhou, Q., et al. (2025) Machine Learning-Based Identification and Validation of Immune-Related Biomarkers for Early Diagnosis and Targeted Therapy in Diabetic Retinopathy. *Gene*, **934**, Article 149015. <https://doi.org/10.1016/j.gene.2024.149015>
- [66] Trotta, M.C., Gesualdo, C., Platania, C.B.M., De Robertis, D., Giordano, M., Simonelli, F., et al. (2021) Circulating miRNAs in Diabetic Retinopathy Patients: Prognostic Markers or Pharmacological Targets? *Biochemical Pharmacology*, **186**, Article 114473. <https://doi.org/10.1016/j.bcp.2021.114473>
- [67] Naaz, S., Kamran, H., Hussain, S.J., et al. (2025) FedGAN: Federated Diabetic Retinopathy Image Generation. *PLOS ONE*, **20**, e0326579.
- [68] Lee, G.H. and Shin, S. (2020) Federated Learning on Clinical Benchmark Data: Performance Assessment. *Journal of Medical Internet Research*, **22**, e20891. <https://doi.org/10.2196/20891>
- [69] Ikram, A. and Imran, A. (2025) ResViT FusionNet Model: An Explainable AI-Driven Approach for Automated Grading of Diabetic Retinopathy in Retinal Images. *Computers in Biology and Medicine*, **186**, Article 109656. <https://doi.org/10.1016/j.compbiomed.2025.109656>
- [70] 刘哲宇, 陈雪霞, 冯耀清, 等. 糖尿病病人视网膜病变风险预测模型研究进展[J]. 护理研究, 2025, 39(13): 2316-2320.