

DOI: 10.20098/j.cnki.1001-5132.2025.0722

基于机器学习算法的老年人慢性肾脏病预测模型

张 良^{1,2}, 冯 伟³, 李 宁², 纪 威², 许国章^{1*}

(1.宁波大学 医学部, 浙江 宁波 315211; 2.宁波市疾病预防控制中心, 浙江 宁波 315010;

3.宁波市奉化区疾病预防控制中心, 浙江 宁波 315500)

摘要: 采用机器学习算法构建老年人慢性肾脏病预测模型, 为早期发现老年人慢性肾脏病高风险人群提供理论依据。选取宁波市某区 82 196 名老年人作为研究对象, 使用 R 4.0.5 软件构建 Logistic 回归、分类回归树、梯度提升机和支持向量机 4 种机器学习算法的老年人慢性肾脏病风险预测模型, 并采用准确度、灵敏度、特异度、受试者工作曲线 (ROC) 及曲线下面积 (AUC) 来评估 4 种机器学习算法的预测效果。结果表明, 共有 40 585 名纳入本研究的老年人新发慢性肾脏病的发病率为 5.43%; 多因素 Logistic 回归分析结果显示, 年龄、体质指数、腰围、糖尿病、血脂异常与老年人慢性肾脏病呈正相关 ($P<0.05$); 经 4 种算法比较后, 发现梯度提升机在训练集和验证集中的 AUC 均为最高, 其值分别为 0.939 和 0.941, 表明其综合预测性能最好。

关键词: 机器学习; 梯度提升机; 慢性肾脏病; 预测模型

中图分类号: R692

文献标志码: A

文章编号: 1001-5132 (2026) 02-0053-06

Prediction model for chronic kidney disease in the elderly people based on machine learning

ZHANG Liang^{1,2}, FENG Wei³, LI Ning², JI Wei², XU Guozhang^{1*}

(1. Health Science Center, Ningbo University, Ningbo 315211, China; 2. Ningbo Center for Disease Control and Prevention, Ningbo 315010, China; 3. The Center for Disease Control and Prevention of Fenghua District, Ningbo 315500, China)

Abstract: This paper aims to construct a prediction model for Chronic Kidney Disease (CKD) in the elderly by using machine learning algorithms, so as to provide a basis for the early detection of high-risk groups of CKD in these people. A total of 82 196 elderly individuals in a certain district of Ningbo City were selected as the research subjects. Four machine learning algorithms, namely logistic regression, Classification and Regression Tree (CART), Gradient Boosting Machine (GBM), and Support Vector Machine (SVM), were used to construct CKD risk prediction models for the elderly using R 4.0.5. The prediction performance of the four machine learning algorithms was evaluated using accuracy, sensitivity, specificity, Receiver Operating Characteristic (ROC) curve, and Area Under the Curve (AUC). A total of 40 585 elderly individuals included in this study got new-onset CKD, and its incidence in the elderly was 5.43%. The multivariate logistic regression analysis showed that age, body mass index, waist circumference, diabetes, and dyslipidemia were positively correlated with CKD in the elderly ($P<0.05$). Among the four algorithms, the Gradient Boosting Machine (GBM) had the highest AUC of 0.939 in the training set and 0.941 in the validation set, demonstrating the best overall prediction performance.

Keywords: machine learning; gradient boosting machine; chronic kidney disease; prediction model

收稿日期: 2025-07-29

宁波大学学报(理工版)网址: <http://journalg.nbu.edu.cn/>

基金项目: 国家自然科学基金 (72074011); 宁波市医疗卫生高端团队重大攻坚项目 (2023020713)

第一作者: 张 良, 高级工程师, 主要研究方向为信息化建设与大数据。E-mail: johnllen@qq.com

*通信作者: 许国章, 博士/教授, 主要研究方向为现场流行病学。E-mail: xuguo Zhang@nbu.edu.cn

慢性肾脏病(Chronic Kidney Disease, CKD)是指肾脏结构或功能异常持续3个月以上的疾病。近年来CKD患病率持续上升,疾病负担日益严重,已成为全球性公共卫生问题之一^[1-2]。基于全球疾病负担数据的研究显示,2021年中国CKD患病率为8.32%^[3],预计到2029年比例将升至11.7%^[4]。尽管CKD患病率较高,但其起病隐匿,且公众对该疾病的知晓率偏低,导致患者容易错过早期干预机会,进而发展为终末期肾病。此外,CKD还与心血管疾病等并发症存在高度关联^[5-6]。因此,探索CKD的预测因素并对患者进行早期干预,对控制疾病进展具有重要意义。

老年人是CKD的高危人群,然而目前针对老年人CKD发病的风险预测模型仍较为缺乏。近年来,机器学习被广泛用于疾病预测模型的开发,并展示出较高的预测精度^[7-8]。基于此,本研究以社区老年人健康管理队列为基础,首先分析老年人CKD的危险因素,随后采用Logistic回归、分类回归树(Classification and Regression Tree, CART)、梯度提升机(Gradient Boosting Machine, GBM)和支持向量机(Support Vector Machine, SVM)等机器学习算法构建预测模型,旨在为社区老年人CKD的防控工作提供理论依据。

1 资料与方法

1.1 资料来源

选取2017年1月至2023年12月在宁波市某区参与基本公共卫生服务老年人健康管理项目的82 196名老年人作为研究对象。纳入标准:(1)年龄 ≥ 60 岁;(2)连续2 a参加老年人年度体检。排除标准:(1)既往有CKD病史;(2)基线肾小球滤过率(estimated Glomerular Filtration Rate, eGFR)小于60 mL/(min $\cdot$ 1.73 m²)标准值(为在不同人群之间进行eGFR的比较,医学界采用一个标准化方法,即按照统一体表面积1.73 m²进行校正);(3)健康体检资料缺失而无法分析者;(4)患有严重心脑血管疾病、恶性肿瘤等疾病者。

82 196名老年人中41 611名因不符合纳入标准被排除,其中,278名年龄小于60岁,30 966名未连续2 a参加老年人年度健康体检,5 399名缺少基线eGFR值,426名基线eGFR值小于标准界限,

2 648名患有严重心脑血管疾病,1 894名患有恶性肿瘤,最终纳入研究对象为40 585名。研究的基本情况包含老年人年龄、性别、高血压、糖尿病等慢性病史,体育锻炼、吸烟等行为生活方式,体质指数、腰围等人体测量指标,还有血尿素氮、总胆固醇、甘油三酯、低密度脂蛋白和高密度脂蛋白等实验室检查指标。上述所有指标均来自纳入研究的老年人健康档案和年度老年人健康体检数据。

1.2 诊断标准

eGFR使用CKD流行病学协作组织推荐公式进行计算^[9],CKD指连续2 a老年人eGFR值小于标准界限。血脂异常:甘油三酯 ≥ 2.3 mmol/L,总胆固醇 ≥ 6.2 mmol/L,高密度脂蛋白 < 1.0 mmol/L,低密度脂蛋白 ≥ 4.1 mmol/L,有以上情况之一者均判断为血脂异常^[10]。体质指数(BMI)计算方法为体质量(kg)除以身高(m)的平方。高血压、糖尿病指既往已经被诊断患有两种慢性病。

1.3 统计分析

统计分析使用R 4.0.5软件进行。采用K最邻近方法(K-Nearest Neighbor, KNN)对缺失值进行填补。采用人工少数类过采样法(Synthetic Minority Oversampling Technique, SMOTE)对数据均衡性进行调整。采用卡方检验进行分类资料的组间比较,采用 t 检验进行数值资料的组间比较。数据集以75:25比例划分为训练集和验证集,使用训练集训练模型,验证集验证模型的性能。使用Logistic回归、分类回归树(CART)、梯度提升机(GBM)和支持向量机(SVM)建立CKD风险预测模型,并做交叉验证。采用准确度、灵敏度、特异度、受试者工作曲线(Receiver Operating Characteristic, ROC)及曲线下面积(Area Under Curve, AUC)对模型进行评价。采用DeLong检验比较各模型AUC的统计学差异(检验水准为0.05)。

2 结果

2.1 调查对象的基本情况

调查对象的基本情况详见表1。本研究共纳入40 585名老年人,其中男性17 911人、女性22 674人。随访期间,共有2 205名(占比5.43%)发展为CKD。将发生和未发生CKD的老年人基线特征进行比较后,发现发生CKD的老年人其平均年龄、

表 1 调查对象的基本情况

变量	CKD 全部案例 (<i>n</i> =40 585)	未患 CKD 案例 (<i>n</i> =38 380)	新发 CKD 案例 (<i>n</i> =2 205)	<i>P</i> 值
男/人	17 911 (44.13%)	16 930 (44.11%)	981 (44.49%)	0.745
女人	22 674 (55.87%)	21 450 (55.89%)	1 224 (55.51%)	
年龄/岁	69.0 ± 6.3	68.8 ± 6.3	71.3 ± 6.5	<0.001
BMI/(kg·m ⁻²)	23.4 ± 3.1	23.3 ± 3.1	24.0 ± 3.1	<0.001
腰围/cm	82.7 ± 9.3	82.6 ± 9.2	84.7 ± 10.1	<0.001
体育锻炼/人	30 656 (75.54%)	28 996 (75.55%)	1 660 (75.28%)	0.791
吸烟/人	6 673 (16.44%)	6 364 (16.58%)	383 (17.37%)	0.350
糖尿病/人	6 633 (16.34%)	6 058 (15.78%)	575 (26.08%)	<0.001
高血压/人	19 800 (48.79%)	18 302 (47.69%)	1 498 (67.94%)	<0.001
血尿素氮/(mmol·L ⁻¹)	5.6 ± 1.7	5.6 ± 1.7	6.3 ± 2.0	<0.001
总胆固醇/(mmol·L ⁻¹)	4.9 ± 1.0	4.9 ± 1.0	5.0 ± 1.1	0.097
甘油三酯/(mmol·L ⁻¹)	1.8 ± 1.2	1.8 ± 1.2	2.0 ± 1.3	<0.001
低密度脂蛋白/(mmol·L ⁻¹)	2.8 ± 0.9	2.8 ± 0.8	2.9 ± 0.9	<0.001
高密度脂蛋白/(mmol·L ⁻¹)	1.3 ± 0.5	1.3 ± 0.5	1.2 ± 0.4	<0.001

注: 括号内数据表示变量占统计案例的百分率。

体质指数和腰围均高于未发生 CKD 老年人。两组之间的体育锻炼率和吸烟率差异无统计学意义。在慢性病患病情况方面, 新发 CKD 组老年人的高血压和糖尿病比例高于未发 CKD 组。实验室检查结果方面, 与未发生 CKD 组比较, 新发 CKD 组老年人的血尿素氮、甘油三酯、低密度脂蛋白水平高, 而高密度脂蛋白水平则低。

2.2 老年人 CKD 多因素 Logistic 回归分析

由表 2 的 CKD 多因素 Logistic 回归分析结果显示, 年龄、体质指数、腰围、糖尿病、高血压、血脂异常与老年人 CKD 呈正相关。其中, 年龄、腰围和血尿素氮以连续变量形式纳入, 结果显示: 年龄每增加 1 岁, CKD 患病风险为 1.185 倍; 腰围

每增加 1 cm, CKD 患病风险为 1.017 倍; 血尿素氮每增加 1 mmol/L, CKD 患病风险为 1.329 倍。

2.3 机器学习算法预测老年人 CKD 性能对比

首先, 通过 Logistic 回归筛选出对 CKD 患病有显著影响的变量, 随后以此作为特征变量, 并将 CKD 患病作为预测目标, 再进一步使用 CART、GBM 和 SVM 模型预测发病风险, 并对所有模型(含 Logistic 回归)进行性能验证和横向比较。由表 3 结果显示, 4 种算法所建预测模型的各项评价指标在训练集和验证集中表现较为一致, 差异较小, 说明各模型均具有较高的稳定性。其中, GBM 表现最为优异, 训练集中, 其 AUC 值为 0.939, 准确度为 0.930, 灵敏度为 0.774, 特异度为 0.985;

表 2 老年人 CKD 多因素 Logistic 回归分析

因素	β 值	标准误差	Wald 值	OR 值	95%CI	<i>P</i> 值
年龄	0.170	0.002	78.397	1.185	1.180~1.191	<0.001
性别	0.054	0.032	1.690	1.055	0.991~1.124	0.091
BMI	0.063	0.008	7.787	1.066	1.049~1.083	<0.001
腰围	0.016	0.003	5.669	1.017	1.011~1.022	<0.001
糖尿病	0.361	0.037	9.728	1.435	1.334~1.543	<0.001
高血压	0.505	0.034	14.686	1.657	1.549~1.772	<0.001
血脂异常	0.507	0.033	15.368	1.661	1.557~1.772	<0.001
血尿素氮	0.284	0.010	29.334	1.329	1.304~1.354	<0.001

表3 机器学习算法预测性能比较

机器学习 算法	训练集				验证集			
	AUC	准确度	灵敏度	特异度	AUC	准确度	灵敏度	特异度
Logistic	0.872	0.847	0.595	0.935	0.860	0.834	0.526	0.938
CART	0.928	0.930	0.772	0.985	0.927	0.922	0.732	0.986
GBM	0.939	0.930	0.774	0.985	0.941	0.930	0.765	0.987
SVM	0.863	0.862	0.565	0.964	0.837	0.808	0.328	0.971

表4 机器学习算法 DeLong 检验结果比较

类别	训练集					验证集				
	算法 1	算法 2	AUC ₁	AUC ₂	P 值	算法 1	算法 2	AUC ₁	AUC ₂	P 值
类别 1	Logistic	CART	0.872	0.928	<0.001	Logistic	CART	0.860	0.927	<0.001
类别 2	Logistic	GBM	0.872	0.939	<0.001	Logistic	GBM	0.860	0.941	<0.001
类别 3	Logistic	SVM	0.872	0.863	<0.001	Logistic	SVM	0.860	0.837	<0.001
类别 4	CART	GBM	0.928	0.939	<0.001	CART	GBM	0.927	0.941	<0.001
类别 5	CART	SVM	0.928	0.863	<0.001	CART	SVM	0.927	0.837	<0.001
类别 6	GBM	SVM	0.939	0.863	<0.001	GBM	SVM	0.941	0.837	<0.001

验证集中,其 AUC 值为 0.941,准确度为 0.930,灵敏度为 0.765,特异度为 0.987。表 4 数据进一步证实,GBM 的 AUC 值不仅高于其他 3 种机器学习算法,且该差异有统计学意义,表明其综合预测性能显著优于 CART、SVM 和 Logistic 回归模型。

3 讨论

本研究结果显示,宁波市某区 60 岁及以上老年人群在随访 6 a 期间,共有 5.43% 的老年人进展为 CKD,此发病率与其他研究存在明显差异。广东省对 2017 年 1 月至 2021 年 7 月期间至少 2 次参加老年人健康管理体检的 5 416 名老年人进行过调查,在中位 2.3 a 的随访期内,新发 CKD 发生率为 20.1%^[11]。韩国一项包含 7 743 名平均年龄 52 岁的成年人研究中,在 11.5 a 中位数的随访期内,CKD 发病率为 18.2%^[12]。本研究老年人群的 CKD 发病率明显低于上述两项研究,推测主要与两方面因素有关。(1) 研究人群与随访时间差异:本研究对象为 60 岁及以上,且随访时间约 6 a;(2) CKD 诊断标准差异:根据 CKD 的定义,慢性肾脏病肾功能异常要持续 3 个月以上方可确诊,因此本研究将“连续 2 a 老年人体检结果中 $eGFR < 60 \text{ mL}/(\text{min} \cdot 1.73 \text{ m}^2)$ ”作为 CKD 诊断依据,而其他研究均以“单次检查结果 $eGFR < 60 \text{ mL}/(\text{min} \cdot 1.73 \text{ m}^2)$ ”即判定为

CKD。

已有研究^[13]证实,年龄和 $eGFR$ 密切相关,是肾功能恶化的重要影响因素。一项包含 5 112 名中国老年人的队列研究显示,年龄每增加 1 岁,女性 $eGFR$ 会下降 $1.06 \text{ mL}/(\text{min} \cdot 1.73 \text{ m}^2)$,男性 $eGFR$ 下降 $0.91 \text{ mL}/(\text{min} \cdot 1.73 \text{ m}^2)$ ^[14]。但需注意的是,随着年龄增长, $eGFR$ 会随机体衰老而出现生理性下降,这种情况很难与肾脏疾病相关的 $eGFR$ 病理性下降进行区分。文献[15]报道,70 岁以上老年人中,约有一半人群的 $eGFR < 60 \text{ mL}/(\text{min} \cdot 1.73 \text{ m}^2)$ 。若在临床诊断中,不考虑 $eGFR$ 随年龄增长而出现的生理性下降特点,直接以固定标准判定肾功能异常,则有可能导致老年人 CKD 的过度诊断^[16]。

本研究发现 BMI 和腰围均与 CKD 发病风险存在显著相关性。有研究^[17]表明,高 BMI 会增加 CKD 风险,一项纳入超过 500 万人的 Meta 分析显示,超重和肥胖人群 CKD 风险分别增加 23% 和 83%。腰围作为中心性肥胖的指标,与 CKD 发病风险存在独立于 BMI 的相关性。一项韩国队列研究^[18]显示,腰围每增加 1 个标准差,CKD 风险增加 34%。因此,加强老年人群的体重管理(维持健康 BMI)和腰围管理(减少中心性肥胖),对于降低 CKD 发病风险具有重要的实践意义。

本研究发现老年糖尿病与 CKD 患病存在显著

相关性, 此与多项流行病学研究结果一致^[19-20]。一项纳入 11 140 名 2 型糖尿病受试者的研究^[21]发现, 与传统降糖治疗相比, 强化降糖治疗持续 5 a, 可使 CKD 发病风险降低 21.15%, 严格控制血糖可以降低糖尿病患者发生 CKD 的风险。从机制上看, 糖尿病的高血糖状态主要通过多种途径损伤肾脏。一方面, 长期高血糖引发能量代谢异常和线粒体功能障碍, 导致肾脏细胞受损; 另一方面, 高血糖还可诱发氧化应激、炎症与纤维化, 破坏肾小球滤过屏障, 进一步加剧肾脏炎症反应和组织纤维化, 最终导致肾功能不可逆损害^[22]。此外, 老年糖尿病患者常合并血管老化, 其自身肾脏储备功能本就受限, 使得高血糖的肾脏毒性作用更易显现。基于上述研究结果与机制分析, 临床中须重点加强老年糖尿病患者的肾功能定期筛查与综合管理, 以尽早发现肾脏损伤并干预, 延缓疾病进展。

本研究还发现高血压和血脂异常同样是 CKD 的危险因素, 且这些危险因素的协同效应不容忽视。与无高血压或糖尿病人群相比, 同时患有高血压与糖尿病者的 CKD 发病风险可达前者的 4.915 倍^[23]。另有研究^[24]显示, 高血压与糖尿病共存时, 患者 CKD 进展为严重肾损害或肾衰竭的风险相较于无此两种疾病的人群增加 77% 的概率。血脂异常方面, 其作为 CKD 的重要且可干预风险因素, 尤其以高甘油三酯的影响最为突出。有研究^[25]显示, 当甘油三酯水平 ≥ 1500 mg/L 时, 人群出现低 eGFR 的风险会增加 26%。糖尿病患者中, 甘油三酯每升高 885 mg/L, 其 CKD 分期加重风险增加 24%^[26]。老年人存在多种危险因素协同作用的特征, 因此, 对于老年糖尿病患者 CKD 的预防与管理应整合血糖控制、血压控制和血脂调节等综合性干预措施, 以便更全面地降低疾病风险和延迟疾病的进一步发展。

机器学习算法在 CKD 发病预测中的应用为 CKD 早期发现和风险分层提供了新的技术途径, 相较于传统统计分析方法, 预测精度有着显著的提升^[27]。本研究系统比较了 Logistic 回归、分类回归树、支持向量机以及梯度提升机 4 种典型机器学习算法在 CKD 风险预测中的表现, 结果显示梯度提升机在预测老年人 CKD 发病风险时, AUC 值、准确度、灵敏度和特异度均处于较高水平, 综合预测

性能最优。其优势主要体现在两方面: 一方面, 能自动捕捉并建模高维特征和复杂非线性关系, 并在迭代训练中能不断优化误差, 极大地提升对 CKD 早期风险的识别能力; 另一方面, 梯度提升机内置的特征重要性评估功能不仅为模型提供了可解释性, 还能量化每个临床特征对发病风险的贡献度, 为疾病预测模型的解读提供了新视角。基于此, 本研究采用梯度提升机建立的针对 60 岁及以上老年人 CKD 的机器学习模型可结合年度健康体检对纳入健康管理的老年人进行初步评估, 助力早期识别高风险人群并进行精准干预。总体而言, 机器学习算法在 CKD 发病预测中展现出了巨大潜力, 未来通过持续的技术创新和临床验证, 有望成为实现精准医疗、改善患者预后的重要工具。

参考文献:

- [1] 上海市肾内科临床质量控制中心专家组. 慢性肾脏病早期筛查、诊断及防治指南(2022 年版)[J]. 中华肾脏病杂志, 2022, 38(5):453-464.
- [2] GUO J X, LIU Z, WANG P J, et al. Global, regional, and national burden inequality of chronic kidney disease, 1990—2021: a systematic analysis for the global burden of disease study 2021[J]. Frontiers in medicine, 2025, 11: 1501175.
- [3] 卞帅博, 张亮, 杨璇. 1990—2021 年中国慢性肾脏病疾病负担变化趋势及发病预测分析[J]. 实用临床医药杂志, 2025, 29(6):89-93, 98.
- [4] LI Y, NING Y, SHEN B, et al. Temporal trends in prevalence and mortality for chronic kidney disease in China from 1990 to 2019: an analysis of the global burden of disease study 2019[J]. Clinical kidney journal, 2022, 16(2):312-321.
- [5] LAFFIN L J, BAKRIS G L. Intersection between chronic kidney disease and cardiovascular disease[J]. Current cardiology reports, 2021, 23(9):117.
- [6] MATSUSHITA K, BALLEW S H, WANG A Y, et al. Epidemiology and risk of cardiovascular disease in populations with chronic kidney disease[J]. Nature reviews nephrology, 2022, 18(11):696-707.
- [7] 李婷婷, 苏鹏, 陈晋波, 等. 基于机器学习比较 2 型糖尿病患者发生糖尿病肾脏疾病风险预测模型的研究[J]. 中国糖尿病杂志, 2025, 33(4):241-247.
- [8] 王淑玉, 杜红阳, 赵晨昊, 等. 基于深度学习和机器学习的胃癌预测模型构建及评估[J]. 青岛大学学报(医学

- 版), 2025, 61(1):54-58.
- [9] DELGADO C, BAWEJA M, CREWS D C, et al. A unifying approach for GFR estimation: recommendations of the NKF-ASN task force on reassessing the inclusion of race in diagnosing kidney disease[J]. *American journal of kidney diseases*, 2022, 79(2):268-288.
- [10] 诸骏仁, 高润霖, 赵水平, 等. 中国成人血脂异常防治指南(2016 年修订版)[J]. *中国循环杂志*, 2016, 31(10): 937-953.
- [11] LUO W, LEI L, LAI J C, et al. A risk prediction model for new-onset chronic kidney disease in the elderly[J]. *American journal of nephrology*, 2025, 56(1):58-69.
- [12] JOO Y S, KIM H W, LEE S M, et al. Dietary zinc intake and incident chronic kidney disease[J]. *Clinical nutrition*, 2021, 40(3):1039-1045.
- [13] GUPPY M, THOMAS E T, GLASZIOU P, et al. Rate of decline in kidney function with age: a systematic review[J]. *BMJ open*, 2024, 14(11):e089783.
- [14] JIANG Y, CAO Q, HONG W Q, et al. Age and estimated glomerular filtration rate in Chinese older adults: a cohort study from 2014 to 2020[J]. *Frontiers in public health*, 2024, 12:1392903.
- [15] EBERT N, JAKOB O, GAEDEKE J, et al. Prevalence of reduced kidney function and albuminuria in older adults: the Berlin initiative study[J]. *Nephrology dialysis transplantation*, 2017, 32(6):997-1005.
- [16] LIU P, QUINN R R, LAM N N, et al. Accounting for age in the definition of chronic kidney disease[J]. *JAMA internal medicine*, 2021, 181(10):1359-1366.
- [17] WANG Y, CHEN X, SONG Y, et al. Association between obesity and kidney disease: a systematic review and meta-analysis[J]. *Kidney international*, 2008, 73(1):19-33.
- [18] CHOI J R, KOH S B, CHOI E. Waist-to-height ratio index for predicting incidences of hypertension: the ARIRANG study[J]. *BMC public health*, 2018, 18(1):767.
- [19] JITRAKNATEE J, RUENGORN C, NOCHAIWONG S. Prevalence and risk factors of chronic kidney disease among type 2 diabetes patients: a cross-sectional study in primary care practice[J]. *Scientific reports*, 2020, 10(1): 6205.
- [20] JOSHI R, SUBEDI P, YADAV G K, et al. Prevalence and risk factors of chronic kidney disease among patients with type 2 diabetes mellitus at a tertiary care hospital in Nepal: a cross-sectional study[J]. *BMJ open*, 2023, 13(2):e067238.
- [21] KIRKMAN M S, MAHMUD H, KORYTKOWSKI M T. Intensive blood glucose control and vascular outcomes in patients with type 2 diabetes[J]. *Endocrinology and metabolism clinics of north America*, 2018, 47(1):81-96.
- [22] SINHA S K, NICHOLAS S B. Pathomechanisms of diabetic kidney disease[J]. *Journal of clinical medicine*, 2023, 12(23):7349.
- [23] WANG M Z, XIA M, YANG H Y, et al. Interaction effect of blood glucose and pressure on the risk of chronic kidney disease: a population-based prospective cohort study[J]. *Endocrine*, 2022, 77(2):252-261.
- [24] CUNILLERA-PUÉRTOLAS O, VIZCAYA D, COBO-GUERRERO S, et al. Chronic kidney disease progression in patients with previous type 2 diabetes and/or hypertension: a population-based cohort study from primary care in Spain[J]. *BMJ open*, 2025, 15(1):e086919.
- [25] RUSSO G T, DE COSMO S, VIAZZI F, et al. Plasma triglycerides and HDL-C levels predict the development of diabetic kidney disease in subjects with type 2 diabetes: the AMD annals initiative[J]. *Diabetes care*, 2016, 39(12): 2278-2287.
- [26] MIGDALIS I N, IOANNIDIS I M, PAPANAS N, et al. Hypertriglyceridemia and other risk factors of chronic kidney disease in type 2 diabetes: a hospital-based clinic population in Greece[J]. *Journal of clinical medicine*, 2022, 11(11):3224.
- [27] SONG W Z, LIU Y F, QIU L X, et al. Machine learning-based warning model for chronic kidney disease in individuals over 40 years old in underprivileged areas, Shanxi province[J]. *Frontiers in medicine*, 2023, 9:930541.

(责任编辑 章践立)