

## 论 著

## 基于人工智能平台的CT冠状动脉血流储备分数联合机器学习算法诊断MACE\*

郭 杨<sup>1</sup> 吴方锦<sup>2</sup> 高丽珊<sup>2</sup>  
龚丽波<sup>2</sup> 徐 悦<sup>2</sup> 秦将均<sup>2,\*</sup>

1.海南医科大学第一附属医院

(海南 海口570000)

2.三亚中心医院(海南省第三人民医院)

放射科(海南 三亚 572000)

**【摘要】目的** 探讨冠状动脉CT血管造影(CCTA)后处理平台(数坤)所测的无创血流储备分数(CT-FFR)与冠周脂肪及斑块定量数据联合机器学习算法诊断稳定型心绞痛(SAP)患者发生MACE的可行性。**方法** 选取三亚中心医院226名诊断为SAP患者的临床及影像数据,根据诊疗过程中患者是否出现MACE将样本划分为未出现MACE的正常组(n=165),出现MACE的异常组(n=61)采用数坤平台测量病变段CT-FFR与斑块及冠周脂肪、冠状动脉管腔的定量数据,通过ROC曲线评估CT-FFR与冠周脂肪及斑块定量数据联合机器学习算法对患者发生MACE的诊断效能。**结果** 通过机器学习模型分析,包括XGBoost、SVM、随机森林和Logistic回归模型,这些模型诊断MACE的准确率均超过0.9。其中,XGBoost模型表现最佳,表明其在诊断MACE具有高度的有效性。**结论** 基于人工智能平台的CT-FFR联合机器学习算法XGBoost模型是诊断MACE的新方法,对于SAP患者出现MACE具有更好的诊断价值。

**【关键词】** 心血管不良事件(MACE); CT-FFR; 稳定型心绞痛; 机器学习

**【中图分类号】** R543.3

**【文献标识码】** A

**【基金项目】** 海南省自然科学基金  
资助项目(822RC873)

**DOI:**10.3969/j.issn.1672-5131.2026.02.023

## Diagnostic Accuracy of AI-based CT-derived Fractional Flow Reserve Combined with Machine Learning Algorithms for Predicting Major Adverse Cardiac Events (MACE)\*

GUO Yang<sup>1</sup>, WU Fang-jin<sup>2</sup>, GAO Li-shan<sup>2</sup>, GONG Li-bo<sup>2</sup>, XU Yue<sup>2</sup>, QIN Jiang-jun<sup>2,\*</sup>.

1.The First Affiliated Hospital of Hainan Medical University, Haikou 570000, Hainan Province, China

2.Department of Radiology, Sanya Central Hospital (Hainan Third People's hospital), Sanya 572000, Hainan Province, China

## ABSTRACT

**Objective** Exploring the feasibility of using a machine learning algorithm that combines non-invasive fractional flow reserve (CT-FFR), as measured by the post-processing platform (Shukun), with pericoronary fat and plaque quantification data from coronary CT angiography (CCTA) to diagnose major adverse cardiac events (MACE) in patients with stable angina pectoris (SAP). **Methods** Clinical and imaging data from 226 patients diagnosed with stable angina pectoris (SAP) at Sanya Central Hospital were selected. Based on whether the patients experienced major adverse cardiac events (MACE) during diagnosis and treatment, the samples were divided into a normal group without MACE (n=165) and an abnormal group with MACE (n=61). The Shukun platform was used to measure lesion segment CT-FFR, plaque, pericoronary fat, and coronary lumen quantitative data. The diagnostic performance of the machine learning algorithm, combining CT-FFR with pericoronary fat and plaque quantification data, in predicting MACE was evaluated using ROC curve analysis. **Results** Machine learning models, including XGBoost, SVM, random forest, and logistic regression, were analyzed. All models achieved an accuracy of over 0.9 in diagnosing MACE, with the XGBoost model performing the best, indicating its high effectiveness in diagnosing MACE. **Conclusion** The CT-FFR combined with the XGBoost machine learning algorithm, based on an artificial intelligence platform, represents a new method for diagnosing MACE. It offers superior diagnostic value for predicting MACE in patients with stable angina pectoris (SAP).

**Keywords:** Major Adverse Cardiovascular Events(MACE); CT-FFR; Stable Angina Pectoris; Machine Learning

冠状动脉性心脏病(coronary artery disease, CAD)是一种严重的心血管疾病,全世界范围内的病例呈明显增长趋势,且发病年龄愈发年轻化,CAD往往伴随着心血管不良事件(major adverse cardiovascular events, MACE)的发生<sup>[1]</sup>,MACE包括心肌梗死,接受血运重建(介入包括球囊和支架,或者外科搭桥手术),心源性死亡<sup>[2]</sup>。其中稳定型心绞痛(stable angina pectoris, SAP)的作为CAD的重要临床表现,伴SAP的患者出现MACE事件的概率高于无SAP的患者<sup>[3]</sup>。由此可见,提前预测SAP患者发生MACE的可能性对于制定治疗方案和获得良好的临床结局至关重要。

目前对于CAD的诊断与冠状动脉狭窄程度的判断、分析冠脉病变的形态以及预测MACE的发生依赖有创冠状动脉造影(invasive coronary angiography, ICA),但其作为有创检查,成本昂贵且易发生过敏反应等问题,限制了其作为稳定型心绞痛患者常规筛查手段<sup>[4]</sup>。冠状动脉血流储备分数(fractional flow reserve, FFR)是评价冠状动脉病变血流动力学意义的金标准。但是压力导丝测定FFR是有创性检查且价格昂贵,且少数病人可能出现不良反应<sup>[5]</sup>。近年来,随着高级计算流体力学和深度学习等技术的发展,综合人工智能融合图像处理技术、解剖学等多学科技术通过计算机分析CCTA断层扫描血管成像获取的CT-FFR在准确评估狭窄和血流动力学变化方面为医生提供了更为全面的丰富信息,且在预测患者出现MACE的效果明显,在MACE诊断和随访中具有显著优势<sup>[6-7]</sup>。

机器学习是一种通过在数据中寻找模式,使计算机能够学习和预测的技术。它利用大规模数据来构建自动化算法,帮助临床医生更好地预测尚未发生的临床情况,从而为治疗决策提供指导。近期,一些机器学习技术被应用于判断患者冠心病情,因为它们具有较高的准确性<sup>[8]</sup>。然而,目前尚未存在将CT-FFR结合SAP影像指标用于诊断MACE的研究。

因此,本研究的目标是使用CT-FFR作为评估MACE的主要指标,利用机器学习算法结合CT-FFR与冠周脂肪定量数据、斑块信息评估稳定型心绞痛患者发生MACE的可行性,并通过机器学习进一步判断增加患者MACE的危险因素。通过整合不同的影像特征并联合机器学习算法,期望能够提高MACE的诊断准确性,为临床医生提供更可靠的决策依据,为患者的治疗和管理提供更好的支持。

## 1 资料与方法

**1.1 一般资料** 选取2022年7月至2023年6月就诊于三亚中心医院临床诊断为稳定型心绞痛的226名患者为研究对象。从本院病历管理系统收集患者的一般临床资料,包括年龄、

**【第一作者】** 郭 杨,女,住院医师,主要研究方向:心血管影像诊断。E-mail: guoyang961120@163.com

**【通讯作者】** 秦将均,男,主任医师,主要研究方向:心血管影像诊断。E-mail: qjj68312@163.com

性别、BMI值等以及相关实验室检查结果，包括总胆固醇、甘油三酯等。根据后续诊疗过程中患者是否出现MACE将样本划分为未出现MACE的正常组(n=165)，出现MACE的异常组(n=61)。纳入标准：有症状的稳定性心绞痛患者。排除标准：患有III~IV级(NYHA分级)心功能不全的病人。冠脉畸形、动脉夹层患者、影像显示质量差者；冠脉支架介入手术史者；冠状动脉旁路移植手术史者；人工心脏瓣膜植入手术史者；心脏起搏器植入手术史者；植入型心律转复除颤器手术史者；临床数据不完整或失访。本研究流程均已得到三亚中心医院伦理委员会批准(伦理编号：LLKY211038)。

**1.2 影像数据采集** 使用型号为西门子SOMATOM Force CT VB10的128排CT扫描仪进行扫描。病人检查前进行屏气训练，所有受检者均予舌下含服硝酸甘油(0.3mg)，心率过快者(>65次/min)于检查1h口服25-75mg倍他乐克。扫描范围自气管隆突下至膈面。CCTA扫描参数:管电压100kV,管电流288mA,准直器宽度192mm×0.8mm,机架转速0.25s/r。使用团注追踪的方法进行CCTA数据采集,预监测层面在主动脉根部,感兴趣区放在主动脉,使用370mg/ml的碘普罗胺40-60ml(优维显370)和生理盐水30ml进行静脉注射,同步进行监测触发模块,10s后启动动态监测,阈值达到100HU后自动触发,延迟6s后即启动冠脉CTA扫描,此时间点能够得到较优质图像。选取伪影最小的图像传输到工作站,图像以DICOM格式储存。




图1 数坤平台一站式处理CT-FFR部分操作流程。图2 数坤平台处理斑块部分操作流程。

**1.4 机器学习** 本研究采用Python3.9完成所有机器学习算法。模型中的变量纳入包括常见最狭窄程度、最小管腔面积、非钙化斑块、混合斑块、钙化斑块、斑块体积、脂类成分体积占比、纤维脂类成分体积占比、纤维成分体积占比、钙化成分体积占比、斑块长度、跨病变 $\Delta$ CT-FFR值、靶病变CT-FFR值、最狭窄处冠周脂肪体积。本研究曾尝试使用多种机器学习模型,最终选取随机森林、XGBoost、SVM、Logistic回归这几个模型进行训练,其中在总体样本中随机抽取测试集n=23例,剩余样本作为训练集进行10折交叉验证。最后得到每个模型的质量评价参数,如精确率、召回率、准确率和F1值。其中,随机森林模型参数:最大树深度为40,最大树木数为1500,最大叶子数为3;XGBoost模型参数:学习速率为0.3,最大树深度为6,最小分叉权重和为1,L1与L2正则化强度为2;Logistic回归模型参数:迭代次数为1000,收敛度量为lbfgs。SVM模型参数:正则化参数为10,核函数为RBF核。最终以ROC曲线下面积(area under curve, AUC)、准确率和F1值来评价模型预测效果,其中F1值为模型的核心评价指标。在机器学习模型中,预测因子的重要性通过Shapley加法解释(shapley additive explanation, SHAP)值体现,通过SHAP柱状图展现按重要性排序的预测因子。

**1.5 统计学分析** 本研究采用Python3.9软件进行统计分析与数据

### 1.3 影像数据处理

**1.3.1 CT-FFR数据分析** 向人工智能平台数坤平台导入患者的DICOM格式图像数据,平台通过对图像进行预处理,消除因心跳和呼吸引起的伪影,并增强冠状动脉与周围组织的对比度。两名中级以上的影像医师利用自动化人工算法及手动切割冠状动脉,提取血管结构,以确保分割的准确性。选取靶病变血管狭窄段的近端、远端,以及距离狭窄段20mm处,病变血管的最远段作为分析位点(参考本领域的权威期刊以及专家共识<sup>[9-10]</sup>),计算各个位置的CT-FFR值,评估冠状动脉狭窄的功能学意义。结果以颜色编码的方式在三维模型上直观展示,自动标注CT-FFR值低于阈值(此阈值通过《CT血流储备分数操作规范及临床应用中国专家共识》<sup>[10]</sup>设定,CTFFR $\leq$ 0.75为心肌缺血,CTFFR值在0.76-0.8范围内称为“灰区”,提示可疑心肌缺血,CTFFR $>$ 0.80为无心肌缺血)的狭窄部位,据此提示病变区域,操作详见图1。

**1.3.2 冠周脂肪及斑块数据分析** 由两名中级以上的影像医师采用数坤平台一站式操作完成测定冠周脂肪参数,以冠脉最狭窄处为中心(靶病变区域),血管壁边缘向外扩展4mm的管径为范围,长度为20mm区域内提取脂肪组织,平台通过算法分析该区域内脂肪组织的CT值分布等信息,评估脂肪组织的特性,如脂类成分的含量和纤维化程度、形态学特征等,并完成钙化斑块、混合钙化斑块、非钙化斑块、脂质成分、纤维脂质成分、纤维成分和钙化成分,以及脂类成分体积占比、纤维脂类成分体积占比、纤维成分体积占比和钙化成分体积占比参数的测定。详见图2。

可视化。计数资料以例(%)表示,计量资料以( $\bar{x} \pm s$ )表示。计数资料的组间对比采用卡方Fisher精确检验。采Shapiro-Wilk检验分析计量资料的正态性。计量资料满足正态分布和方差齐性采用单因素方差分析,计量资料无法满足正态分布和方差齐性,使用Kruskal-Wallis检验, $P < 0.05$ 有统计学意义。采用ROC曲线评估CT-FFR诊断MACE的诊断效能。

## 2 结果

**2.1 一般临床资料** 本研究一共纳入226名受试者,未出现MACE的正常组165例,出现MACE的异常组61例,异常组中男性35例(57.4%),女性26例(42.6%),年龄66.902 $\pm$ 8.441,两组受试者的年龄、BMI、糖尿病等危险因素与MACE事件的发生无明确相关统计意义( $P > 0.05$ ),详见表1。

**2.2 本研究中不同CT-FFR值患者发生MACE的例数与MACE类型统计** 根据《CT血流储备分数操作规范及临床应用中国专家共识解读》<sup>[10]</sup>,对入组受试者按照不同CT-FFR的数值区间划分为三组,CT-FFR $\leq$ 0.75为60例,CT-FFR(0.76-0.80)为“灰区”的受试者共25例,CT-FFR $>$ 0.80为141例。其中CT-FFR $\leq$ 0.75的受试者发生MACE事件几率较大,详见图7。本组研究中发生MACE事件的类型中,心肌梗死(6.6%)与心源性死亡(4.9%)占比较低,其余

发生MACE事件均为接受了介入手术的病例，详见图4。

**2.3 CT-FFR测值与冠周脂肪及斑块特征分析** 与正常组相比较，病变处管腔最狭窄程度MLD与最小管腔面积MLA对于提示MACE有统计学意义( $P < 0.05$ )，斑块性质及成分分析结果表明，非钙化斑块与混合钙化斑块对于MACE也是危险因素。另外，斑

块长度、斑块体积与最狭窄处冠周脂肪体积、纤维脂类成分体积占比与纤维成分体积影响MACE具有统计学意义( $P < 0.05$ )。靶病变CT-FFR值与跨病变 $\Delta$ CT-FFR值通过差异性分析结果显示有统计学意义( $P < 0.05$ )。详见表2。

表1 受试者一般临床基线

临床资料	正常组(n=165)	异常组(n=61)	P值
性别			
男	104(63.0%)	35(57.4%)	—
女	61(37.0%)	26(42.6%)	—
年龄(岁)	66.455±6.660	66.902±8.441	0.505
BMI(kg/m <sup>2</sup> )	24.116±2.527	23.829±2.489	0.206
糖尿病(例)	59(35.8%)	13(21.3%)	0.530
高血脂症(例)	46(27.9%)	47(77.0%)	<0.001
高血压(例)	119(72.1%)	33(54.1%)	0.016
吸烟史(例)	57(34.5%)	22(36.1%)	0.876
总胆固醇(mmol/L)	4.551±0.787	4.233±0.795	<0.001
甘油三酯(mmol/L)	1.739±1.136	1.357±0.437	<0.001
高密度脂蛋白胆固醇(mmol/L)	1.263±0.255	1.146±0.279	<0.001
低密度脂蛋白胆固醇(mmol/L)	2.830±0.631	2.772±0.692	<0.001

表2 CT-FFR测值与冠周脂肪及斑块特征

定量数据	正常组(n=165)	异常组(n=61)	P值
最狭窄程度MLD(%)	64.39±18.99	85.13±9.20	<0.001
最小管腔面积MLA(mm <sup>2</sup> )	4.322±2.831	1.842±1.670	<0.001
斑块性质			
非钙化斑块(例)	16(9.7%)	21(34.4%)	<0.001
混合钙化斑块(例)	120(72.7%)	35(57.4%)	0.036
钙化斑块(例)	29(17.6%)	5(8.2%)	0.095
斑块体积(mm <sup>3</sup> )	68.871±47.917	105.084±104.748	<0.001
脂类成分体积占比(%)	7.038±7.352	8.761±10.015	0.243
纤维脂类成分体积占比(%)	23.271±16.183	32.334±20.046	<0.001
纤维成分体积占比(%)	21.656±9.721	14.972±7.020	<0.001
钙化成分体积占比(%)	44.53±25.68	39.28±27.05	0.078
斑块长度(mm)	16.537±8.512	19.557±10.464	0.011
跨病变 $\Delta$ CT-FFR值	0.082±0.073	0.177±0.098	<0.001
靶病变CT-FFR值	0.849±0.079	0.720±0.081	<0.001
最狭窄处冠周脂肪体积(mm <sup>3</sup> )	306.570±166.891	173.705±83.430	<0.001





图3 不同CT-FFR值人群发生MACE的分组柱状图。图4 MACE具体类型分组柱状图。

**2.4 机器学习建立的不同诊断模型诊断MACE的准确性评价** 通过机器学习模型建立的4种算法诊断心肌缺血的准确率均在0.9以上,尤其是XGBoost的准确率高达0.958, F1值为0.959, AUC为0.983; 其次是随机森林模型和SVM模型、Logistic回归模型的准确率分别为0.948和0.936、0.918, F1值分别为0.951和0.940、0.918, AUC分别为0.980和0.971、0.957(图5~8与表3)。

**2.5 机器学习建立的不同诊断模型诊断MACE的危险因素分布** 通过计算SHAP值得出判断影响MACE变量的重要性排布, XGBoost模型中靶病变CT-FFR值的SHAP值>1.2, 位列第一。跨病变 $\Delta$ CT-FFR值、最狭窄程度、最狭窄处冠周脂肪体积也被认为是重要的变量特征(图9)。





图5 随机森林模型。图6 XGBoost模型。





图7 SVM模型。图8 Logistic模型。




表3 不同机器学习诊断模型评估MACE的准确性评价(训练集n=203 测试集n=23)

模型	数据集	AUC	准确率	灵敏度	特异度	阳性预测值	阴性预测值	F1
随机森林	训练集	1.000	0.985	0.996	0.974	0.975	0.996	0.985
随机森林	测试集	0.980	0.948	0.982	0.916	0.926	0.980	0.951
XGBoost	训练集	1.000	1.000	1.000	1.000	1.000	1.000	0.998
XGBoost	测试集	0.983	0.958	0.981	0.935	0.939	0.980	0.959
Logistic回归	训练集	0.976	0.939	0.954	0.925	0.927	0.953	0.940
Logistic回归	测试集	0.957	0.918	0.932	0.905	0.908	0.935	0.918
SVM	训练集	0.988	0.958	0.993	0.923	0.928	0.993	0.959
SVM	测试集	0.971	0.936	0.982	0.893	0.906	0.980	0.940

### 3 讨论

本研究主要发现,伴有稳定型心绞痛(stable angina pectoris, SAP)的冠状动脉性心脏病(coronary artery disease, CAD)患者的CT-FFR测值是发生心血管不良事件(major adverse cardiovascular events, MACE)的重要预测因子,特别是CT-FFR $\leq 0.75$ 的SAP患者出现MACE事件机率较大。本研究构建的机器学习算法,将CT-FFR相关测值与冠周脂肪定量数据、斑块特征作为学习特征,对于预测MACE的发生具有较高的敏感性与准确性,具有潜在的临床应用价值,可协助临床医师及时制定诊疗策略。

对于SAP患者而言,观测病情变化尤其重要,特别是CT-FFR $\leq 0.75$ 的SAP患者有更高的危险系数<sup>[11]</sup>,如果出现危险的MACE事件,如心肌梗死,及时的血运重建进而得到更好的临床结局。因此提升无创诊断与随访SAP患者出现MACE事件的评估准确性成为许多研究人员关注的方向。CAD相关的实验室检查、心电图和CTA得出的斑块特征等检查手段组合运用于评估SAP患者出现MACE,尽管取得一些研究进展,但是准确性仍然有限。

CT-FFR是一项无创图像后处理技术,基于常规CCTA所获得冠状动脉三维图像,辅以计算机人工智能平台,根据冠状动脉解剖模型,联合冠状动脉生理学的数学模型、流体动力学的物理定律,模拟冠状动脉血流情况,得出冠状动脉血流量和压力,计算出冠状动脉树任意位置的CTFFR值,采用彩色编码影像呈现结果<sup>[6]</sup>。而发生MACE的SAP患者往往出现心血管的狭窄等变化,CT-FFR较容易捕捉此类血流动力学的变化特征<sup>[12]</sup>。冠周脂肪与斑块参数对于狭窄血管的判断也具有不错的诊断价值<sup>[13]</sup>,这些结论与本研究结果一致。

在机器学习分析中,使用CT-FFR相关测值与冠周脂肪定量数据、斑块特征构建了传统回归模型与基于机器学习的模型评估SAP患者出现MACE,结果表明所构建的模型诊断效能表现优秀:4种模型的准确率达0.9以上。为增加机器学习的可解释性,研究中还使用SHAP值确定了各特征值的变量对于MACE事件发生的影响,发现除了靶病变CT-FFR值外,跨病变 $\Delta$ CT-FFR值、最狭窄程度、最狭窄处冠周脂肪体积等也被认为是重要的变量特征,而纤维之类成分占比的SHAP值较低,这与差异性检验的结果不完全一致,也体现出机器学习算法建立的模型对潜在的危险因素有较强的辨别能力与挖掘潜力。

与Logistic回归模型相比较,XGBoost、随机森林、SVM模型对于SAP患者出现MACE诊断能力更佳。可能原因是Logistic回归模型回归假设的每个变量都是独立的,且难以判断变量的非线性关系,且超参数调优灵活性不足<sup>[14-16]</sup>。当危险因素与疾病之间的关联受到各种混杂因素的影响时,Logistic回归模型偏差较大、精度较低。相比之下,XGBoost和随机森林、SVM是非参数算法,无需依靠假设特征和结果之间存在特定的函数关系<sup>[17-18]</sup>,因此在复杂的建模环境下显得更加灵活。

然而,该研究存在一些不足之处。首先,由于本研究仅采用了单中心数据,导致模型的结果验证可能存在一定偏差;其他与CAD的相关验证变量,如重要的病理结果无法直接获取。其次,可供学习的样本量相对较小,从而限制了机器学习的训练样本数量,模型泛化能力受到影响。此外,机器学习算法存在不可解释性,其本质为黑盒模型<sup>[19]</sup>,难以解释各个危险因素的关联程度,

并且无法提供各个危险因素的风险截断值。因此,今后还需要开展更大规模的多中心研究,测试更多模型的诊断能力,建立大样本以及随访队列,以验证本次开发的风险模型的诊断效果。

### 参考文献

- [1] PEERWANI G, HANIF B, RAHIM K A, et al. Presentation, management, and early outcomes of young acute coronary syndrome patients- analysis of 23,560 South Asian patients from 2012 to 2021[J]. BMC Cardiovasc Disord, 2024, 24 (1): 378.
- [2] BOSCO E, HSUEH L, MCCONEGHY K W, et al. Major adverse cardiovascular event definitions used in observational analysis of administrative databases: a systematic review[J]. BMC Med Res Methodol, 2021, 21 (1): 241.
- [3] WINCHESTER D E, PEPINE C J. Angina treatments and prevention of cardiac events: an appraisal of the evidence[J]. Eur Heart J Suppl, 2015, 17 (Suppl G): G10-G8.
- [4] GROUP T D T. Age and computed tomography and invasive coronary angiography in stable chest pain: a prespecified secondary analysis of the dischargerandomized clinical trial[J]. JAMA cardiology, 2024, 9 (4): 346-56.
- [5] CHA J J, NGUYEN N L, TRAN C, et al. Assessment of fractional flow reserve in intermediate coronary stenosis using optical coherence tomography-based machine learning[J]. Front Cardiovasc Med, 2023, 10 (1082214).
- [6] YANG Y T, XU P P, ZHOU F, et al. Coronary computed tomography angiography derived flow fractional reserve: the state of the art[J]. Chinese Journal of Academic Radiology, 2020, 3 (2): 84-93.
- [7] 孙刚, 常艺桐, 徐娜, 等. 冠状动脉周围脂肪CT衰减指数联合CT-FFR对急性冠状动脉综合征患者MACE事件预测价值[J]. 中国CT和MRI杂志, 2024, 22 (7): 90-92.
- [8] 王丽, 计礼丽, 陆浩轩, 等. 机器学习在心血管疾病辅助诊断中的研究: 现状与未来进展[J]. 宁波大学学报: 理工版, 2023, 36 (3): 102-107.
- [9] RAJIAH P, CUMMINGS K W, WILLIAMSON E, et al. CT fractional flow reserve: a practical guide to application, interpretation, and problem solving[J]. Radiographics, 2022, 42 (2): 340-358.
- [10] 中华医学会放射学分会心胸学组, 中国医师协会放射医师分会心血管学组, 北京医学会放射学分会心血管学组. CT血流储备分数操作规范及临床应用中国专家共识[J]. 中华放射学杂志, 2023, (7): 711-722.
- [11] LIU X, WANG Y, ZHANG H, et al. Evaluation of fractional flow reserve in patients with stable angina: can CT compete with angiography?[J]. European Radiology, 2019, 29 (7): 3669-3677.
- [12] 虎智英, 杨飞, 苏亚英, 等. 冠状动脉CT血管成像联合基于CT的血流储备分数预测阻塞性冠心病主要不良心脏事件的价值[J]. 实用医学杂志, 2021, 37 (20): 2675-2680.
- [13] WANG M, QIN L, BAO W, et al. Epicardial and pericoronary adipose tissue and coronary plaque burden in patients with Cushing's syndrome: a propensity score-matched study[J]. Journal of Endocrinological Investigation, 2024, 47 (8): 1995-2005.
- [14] SCHAEFEN H. Logistic Regression, Weights of Evidence, and the Modeling Assumption of Conditional Independence[M]. Encyclopedia of Mathematical Geosciences. Springer, 2022: 1-9.
- [15] LAVALLEY M P. Logistic regression[J]. Circulation, 2008, 117 (18): 2395-2399.
- [16] STEYERBERG E W, STEYERBERG E W. Assumptions in regression models: Additivity and linearity[J]. Clinical prediction models: a practical approach to development, validation, and updating, 2019, 227-245.
- [17] TAO M, ZHAO Q, ZHAO R, et al. A new method of rockburst prediction for categories with sparse data using improved XGBoost algorithm[J]. Natural Resources Research, 2024, 1-20.
- [18] BENTÉ JAC C, CSÖRÖG A, MARTÍNEZ-MUÑOZ G. A comparative analysis of gradient boosting algorithms[J]. Artificial Intelligence Review, 2021, 54: 1937-1967.
- [19] HASSIJA V, CHAMOLA V, MAHAPATRA A, et al. Interpreting Black-box models: a review on explainable artificial intelligence[J]. Cognitive Computation, 2023, 16 (1): 45-74.

(收稿日期: 2024-09-27)

(校对编辑: 姚丽娜)