

基于机器学习的黄河右岸河南段崩塌易发性评价¹

王浩¹, 杨京昂¹, 赵梦鑫¹, 张建伟¹, 张树森¹, 徐邳杰²

(1. 河南大学 建筑工程学院, 河南 开封 475004; 2. 河南省自然资源监测和国土整治院, 河南 郑州 450003)

摘要:【目的】构建一种适用于数据稀缺条件下的高精度崩塌易发性预测方法, 并评估特征优化与模型集成策略的效果, 以为黄河中游黄土崩塌灾害的风险防控提供实践指导与技术参考。【方法】以黄河中游右岸河南段为研究区, 选取地形地貌、水文条件、人类活动等 11 个特征因子。分别基于原始数据集与频率比转换数据集, 构建并对比支持向量机、随机森林、轻量级梯度提升机、极端梯度提升树、多层感知机及 Stacking 集成 6 种机器学习模型, 系统分析模型性能与特征优化作用, 进而采用最优模型进行易发性区划。【结果】①模型比较表明, 集成学习模型性能显著优于单一模型, 其中 Stacking 集成模型的预测精度最高 (AUC=0.896 7)。②采用频率比转换特征能有效提升各模型的性能, 缓解了因样本稀缺与分布不均对模型学习的限制。③基于 Stacking 模型的预测结果显示, 研究区崩塌高、极高风险区面积占比达 31%, 空间上呈“中部连片为主体、西部零散分布、东部局部集中、北部沿廊道延伸”的格局, 与历史灾害分布高度吻合。【结论】融合频率比特征优化与 Stacking 集成学习, 能够有效提升在数据稀缺条件下的崩塌易发性预测精度, 所得风险区划结果可靠。未来研究可进一步融合时序监测数据构建动态风险评估模型, 并将本预测成果与实地防灾规划相结合, 进行风险防控措施实地检验与优化。

关键词: 崩塌易发性; 机器学习; 频率比; 黄河中游

中图分类号: P642.2; TP18

文献标识码: A

黄河中游右岸河南段地质条件复杂, 部分地区地形起伏明显, 降雨集中, 临近黄河地下水含量丰富, 这些因素都使得该区域崩塌灾害频发。仅 2024 地质灾害调查中, 该区域的崩塌灾害就有 161 起, 灾害的发生通常造成大量经济损失以及人员伤亡。

崩塌易发性是指在特定的地理环境条件下, 某一区域发生崩塌的可能性大小^[1]。目前, 国内外研究人员对崩塌灾害易发性的研究方法主要分为基于统计分析的方法^[2-3]和基于机器学习的方法两大类。随着近年来人工智能领域的不断发展, 机器学习方法被越来越多地用于崩塌灾害易发性预测中。目前主要的机器学习预测方法有决策树^[4]、逻辑回归^[5]、支持向量机^[6-7]等单一学习器预测模型, 随机森林^[8-9]、轻量级梯度提升机^[10]、极端梯度提升树^[11]、Stacking^[12-13]等集成学习模型以及神经网络^[14-15]等深度学习模型。其中, 单一学习器对特征间非线性关系的捕捉能力较弱, 集成学习与深度学习对数据量的要求较高, 对于样本量较少的研究区域, 这些常用算法都有明显的局限性。此外, 崩塌易发性的准确预测依赖于合理选择评价因子, 地形地貌、水

文条件、地质构造、人类活动及地表覆被是控制崩塌发生的主要因素, 这些因素通过影响坡体应力、侧蚀掏空、岩土完整性及人类扰动等共同作用^[2,14]。本文结合研究区崩塌特征, 选取了高程、坡度、坡向、平面曲率、剖面曲率、地表起伏度、植被类型、年降水量、距居民区距离、距断层距离、距河流距离共 11 个影响因子。

基于此, 本文以黄河中游右岸河南段为研究区域, 基于研究区域内 161 个崩塌灾害数据资料, 分别构建了原始数据集与基于频率比计算的频率比数据集^[5,16], 使用支持向量机、随机森林、轻量级梯度提升机、极端梯度提升树、多层感知机和 Stacking 集成学习 6 种机器学习算法构建预测模型, 分析不同机器学习模型的预测性能以及频率比计算对模型性能的提升。这不仅可为区域防灾减灾提供直接参考, 还能为后续的土地规划和工程建设提供科学依据。

1 研究区概况

研究区位于黄河中游右岸的河南段, 地跨三门

收稿日期/Received: 2025-12-31

修回日期/Revised: 2026-03-25

基金项目: 国家自然科学基金项目(42577217); 河南省科技攻关项目(242102321012)。

第一作者: 王浩(1986—), 男, 副教授, 博士, 从事土木水利工程方面的研究。E-mail: wanghao8023@henu.edu.cn。

峡、洛阳及郑州三市，共涵盖 11 个区县，如图 1 所示。该区地貌类型多样，其中黄河流经地带自西向东依次发育有河谷平原、峡谷（位于中条山与秦岭支脉之间）以及洪冲积平原^[17-18]。就全区地貌结构而言，东部与西部以冲积平原、谷地、侵蚀黄土台塬、丘陵为主，中部则以侵蚀剥蚀中山、低山和丘陵为主^[19-20]。

该区域属暖温带季风气候，年均降水量 613.5~760.6 mm，空间分布不均^[21]。受复杂地貌、气候及密集人类活动（如工程建设、土地开垦与灌

溉）的综合影响^[6]，该区域崩塌灾害多发，主要集中在分布于山区、丘陵区及黄河沿岸。根据已有调查资料，该区域崩塌灾害以土质崩塌为主（约占 93.1%），岩质崩塌较少（占 6.8%）；按规模划分，小型崩塌占 78%，中型崩塌占 20%，大型崩塌仅占 2%。综合类型与规模特征可知，该地区崩塌灾害以中小型土质崩塌为主导。此类崩塌在发生过程中往往伴随大量松散物质产生，因此将成为流域内水土流失的重要物源，对河道淤积及生态环境具有持续影响。

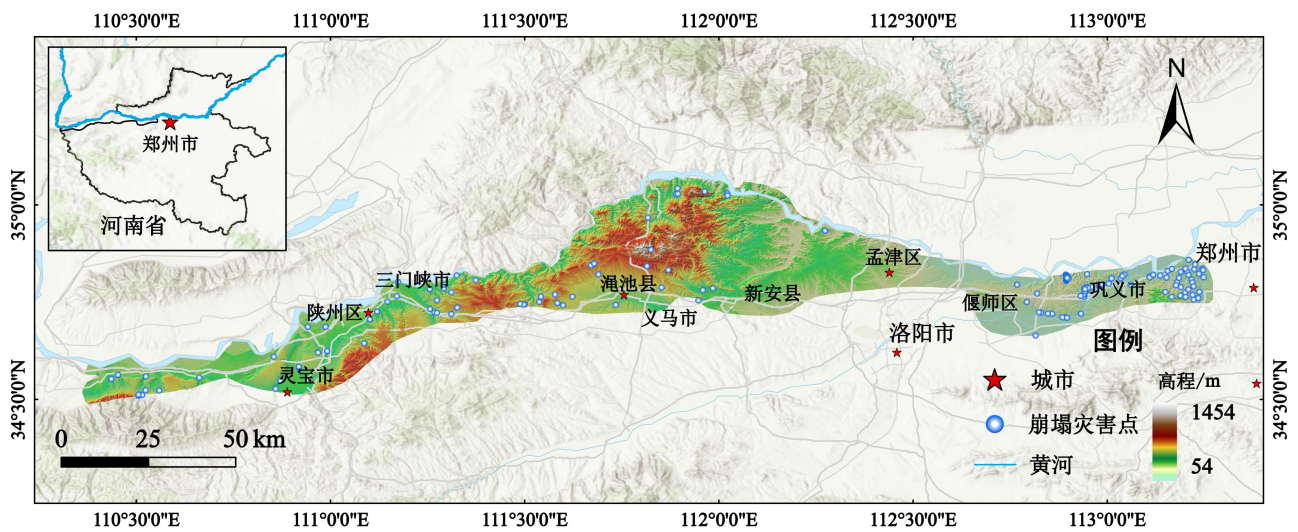


图 1 研究区崩塌灾害点分布概况图

Fig.1 Distribution map of collapse sites in the study area

2 致灾因子选择及数据集构建

2.1 致灾因子选择

研究区位于黄河右岸河南段，近岸处河流两岸受流水冲蚀，稍远处又与山区、丘陵地带接壤，有明显起伏，加之地下水充沛，多种因素共同作用导致地质灾害频发。基于这些特点，本研究从地形地貌、水文地质条件等多个方面，选取了高程、坡度、坡向、平面曲率、剖面曲率、地表起伏度、植被类型、年降水量、距居民区距离、距断层距离、距河流距离共计 11 个影响崩塌的特征因子^[2]，各影响

因子在研究区域内的分布情况如图 2 所示。

2.2 数据来源

研究所用崩塌灾害数据集来源于河南省自然资源部门应急调查结果；高程、断层分布、水系分布、居民区分布、植被类型与降水量等特征来源于地理遥感生态网平台；坡度、坡向、曲率等由高程计算得到，距离特征由致灾因子分布位置计算得到。为统一提取特征与预测研究区崩塌风险，本研究将所有数据资料统一调整为 WGS-84 大地坐标系，且重采样为 30 m×30 m 的分辨率的栅格数据集。

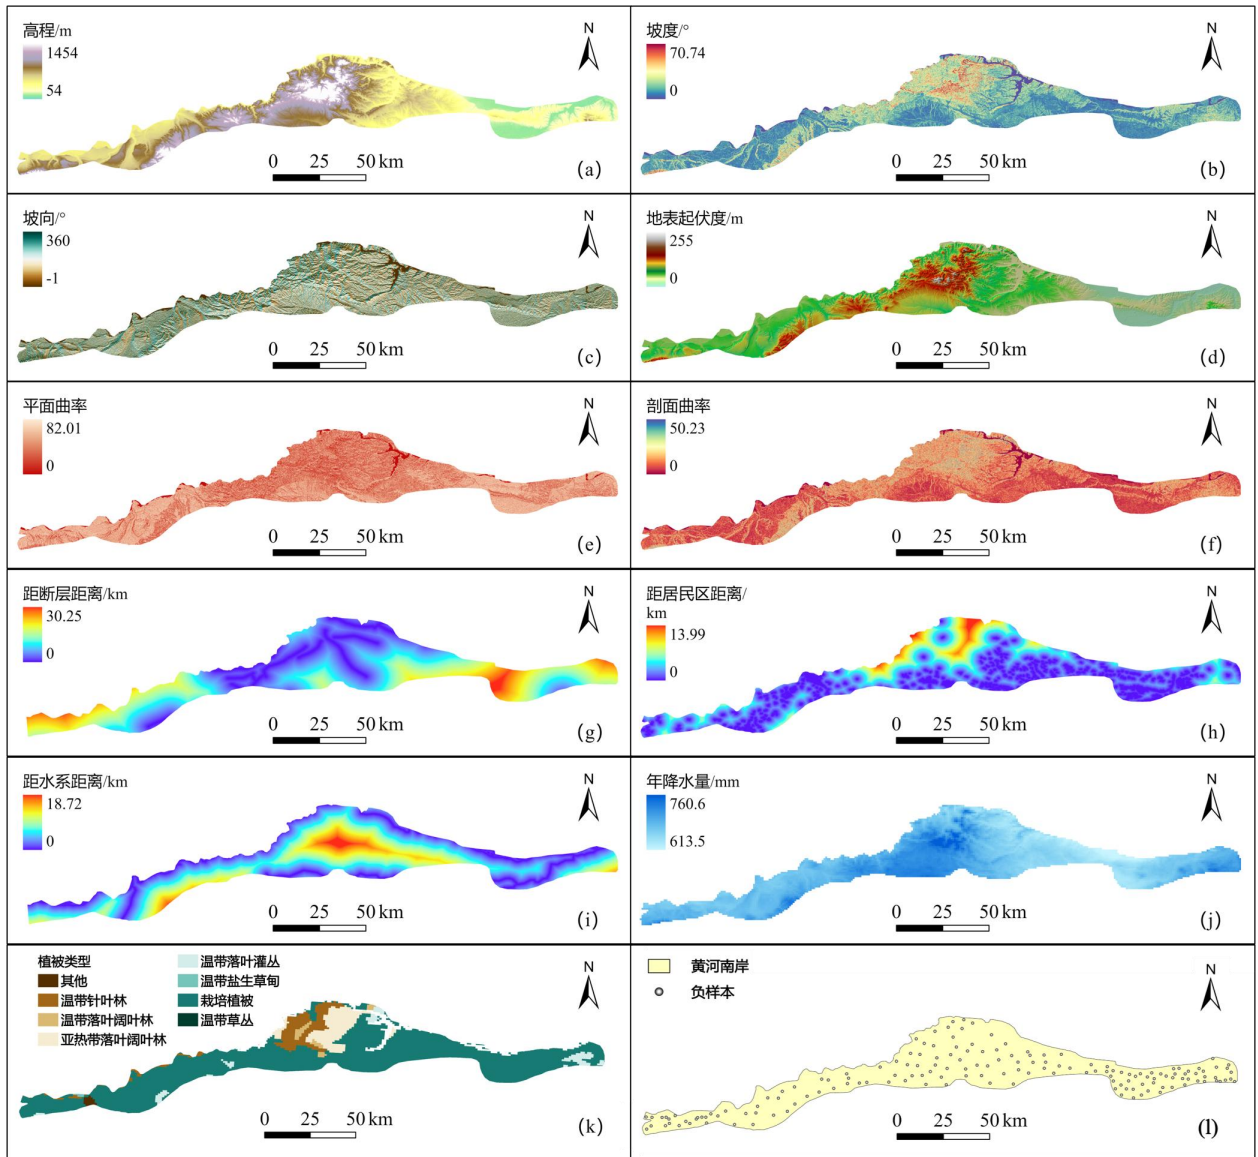


图 2 致灾因子与负样本分布情况

Fig.2 Distribution of conditioning factors and non-collapse samples

2.3 频率比计算

频率比模型是一种分析致灾因子与灾害分布的空间相关性的方法。其基本原理是：比较特定致灾因子类别内灾害发生的概率与研究区整体灾害发生的概率。在崩塌灾害易发性预测中若频率比值大于 1，表明该因子类别对灾害发生具有积极的促进作用；反之，若小于 1，则表示其具有抑制作用；等于 1 则说明该因子类别与灾害分布无显著相关性^[5]。

将研究区域内连续型数据按照 Jenks 自然断点法^[16]与等间距法^[5]结合的方法进行分类统计，距断层、距居民区、距河流等距离因子，考虑到超远距离对崩塌影响微弱且可能存在数据冗余，采用等间

距法进行分级；其他连续型变量采用 Jenks 自然断点法分类。对于离散型致灾因子，以现有分类为主，根据数据实际情况进行重分类^[1]，最后计算出各特征因子的频率比作为新的特征输入模型进行建模和预测，结果如图 3 所示。

根据频率比计算结果，下列因子对崩塌灾害易发性具有显著促进作用：坡度大于 35.51° 、坡向为南向、地表起伏度大于 52 m、剖面曲率大于 11、距离水系 1 km 以内，以及地表覆盖为栽培植被。同时，坡度与地表起伏度的增大均会明显提升崩塌风险；而随着距居民区和水系距离的增加，崩塌发生的可能性则显著降低。

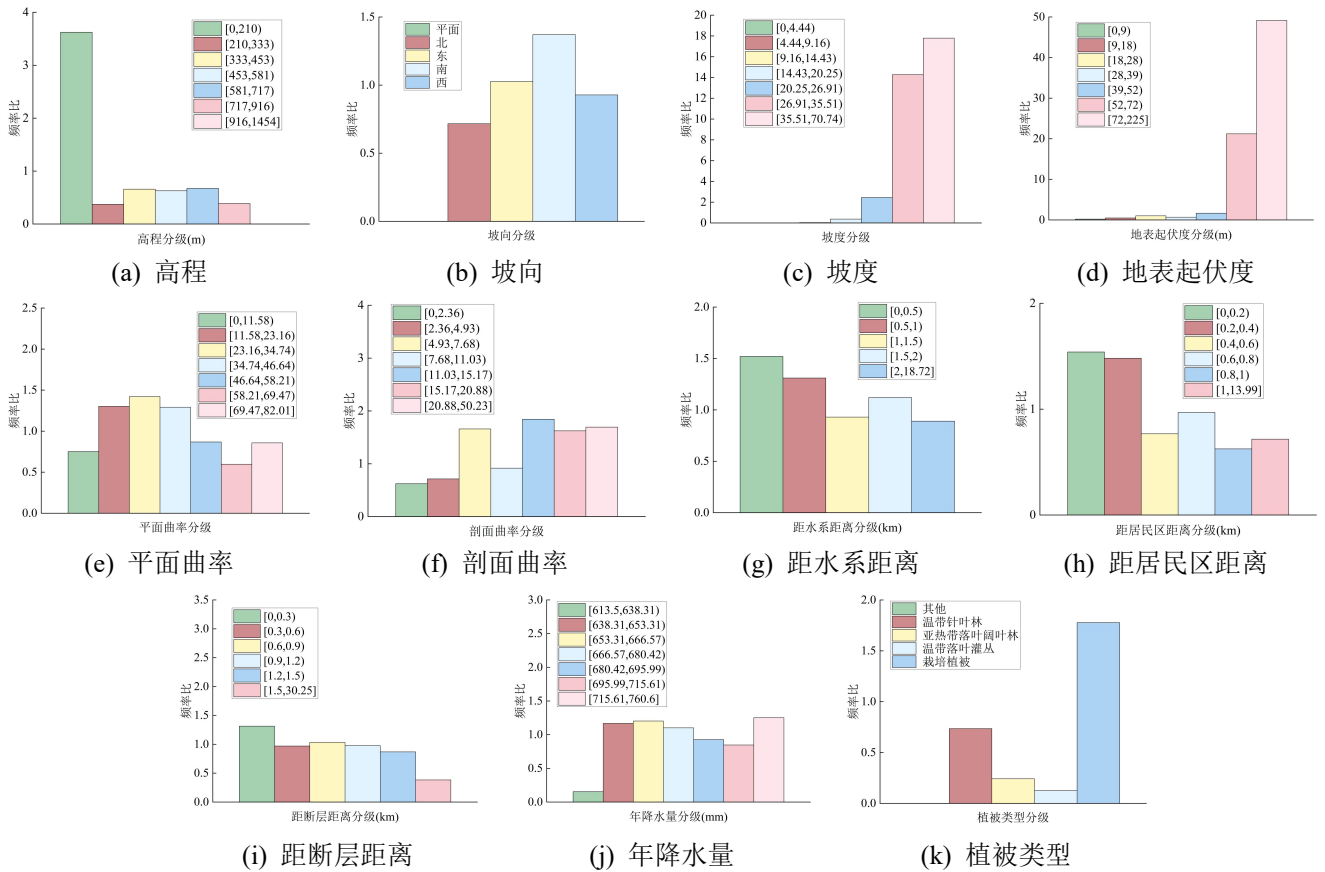


图 3 致灾因子频率比计算结果

Fig.3 Calculation results of the frequency ratio of disaster-causing factors

2.4 数据集构建

以河南省自然资源部门提供的 161 处崩塌灾害点(图 1)为正样本构建数据集。负样本采用分层随机采样与补充采样相结合的策略,根据崩塌地形分布特征,将研究区划分为北部岸坡区、中部山区、西部台塬区及东部丘陵与台塬区四个崩塌高发区,按各区域内正样本数量等比例随机抽取 141 个非崩塌点;同时,为保障无灾害发生的平原区亦能提供学习样本,单独随机补充 20 个负样本点,总计 161 个负样本,其空间分布见图 2 (1)。正样本定义为 1,负样本定义为 0,全部 322 个样本按 70%和 30%随机划分为训练集和测试集,用于模型训练与验证。

此外,为了验证频率比置换原特征值对预测模型的提升效果,在原始数据集基础上建立频率比数据集进行建模,并使用相同的模型进行建模和评估。本研究使用的机器学习模型均基于 Python 3.12 搭建,地理计算与图像绘制则基于 Arcgis Pro 3.1.6。

3 基于机器学习的崩塌易发性预测

3.1 机器学习模型

1) LGBM 模型: 轻量级梯度提升机 (Light Gradient Boosting Machine) 是一种基于梯度提升

框架的高效机器学习算法,在二分类预测任务中有着广泛的应用^[10]。在崩塌易发性预测中, LGBM 模型将历史崩塌点与非崩塌点视为二分类样本,通过梯度提升技术集成多个弱学习器,以学习形成一道复杂的决策边界,从而实现对研究区域崩塌发生概率的精准预测。

2) RF 模型: 随机森林 (Random Forest) 是一种基于 Bagging 的集成学习算法,它通过构建多个决策树来提高模型的预测性能^[9]。在崩塌易发性预测中,随机森林模型能够处理地形、地质等多类复杂特征。该模型将历史崩塌点与非崩塌点视为二分类样本,通过集成多棵决策树的预测结果,并利用其内置的随机性来有效降低模型过拟合的风险,从而获得一个鲁棒性更强的崩塌易发性分类模型。

3) SVM 模型: 支持向量机 (Support Vector Machine) 是一种基于统计学习理论的分类算法,它通过寻找最优分割超平面来将不同类别的数据分开^[23]。在崩塌易发性预测中, SVM 可以将崩塌点和非崩塌点看作两类数据,通过构建最优分割超平面来实现对崩塌易发性的分类预测。

4) XGBoost 模型: 极致梯度提升 (eXtreme Gradient Boosting) 是一种基于梯度提升决策树的高效机器学习算法,通过引入正则化项和二阶泰勒

展开优化损失函数,在崩塌分类预测中表现出色^[11]。在崩塌易发性预测中,XGBoost 将历史崩塌点与非崩塌点视为二分类样本,通过迭代训练决策树并优化目标函数,有效捕捉致灾因子与崩塌之间的复杂非线性关系,从而实现对崩塌发生概率的准确预测。

5) MLP 模型: 多层感知机 (Multilayer Perceptron) 是一种前馈人工神经网络,由输入层、多个隐藏层和输出层组成,通过非线性激活函数学习特征与目标之间的映射关系^[22]。在崩塌易发性预测中,MLP 将崩塌点与非崩塌点作为训练样本,利用反向传播算法优化网络参数,能够处理高维特征并拟合复杂的非线性决策边界,实现对崩塌易发性的分类识别。

6) Stacking 模型: Stacking 是一种集成学习方法,通过组合多个不同的基学习器,并训练一个元模型对基学习器的预测结果进行融合,从而提升预测性能^[12]。本研究选取 LGBM、随机森林 (RF)、支持向量机 (SVM)、XGBoost 和多层感知机 (MLP) 作为基学习器。元模型采用逻辑回归,其工作原理如下: 首先,基学习器在训练集上通过 5 折交叉验证生成各崩塌样本的预测概率,构成新的特征矩阵; 然后,将该矩阵作为输入训练逻辑回归模型。逻辑回归通过 sigmoid 函数对各基学习器的预测概率进行线性加权组合^[13]:

$$P(y = 1) = \frac{1}{1 + e^{-(w_0 + \sum_{i=1}^k w_i p_i)}} \quad (1)$$

式中: $P(y = 1)$ 为崩塌发生的预测概率; p_i 为第 i 个基学习器输出的崩塌发生概率; w_0 为偏置项; w_i 为可学习的权重系数; k 为基学习器个数。通过最小化交叉熵损失函数,模型自动学习最优权重。

3.2 致灾因子分析

为了识别影响黄河崩塌的主要环境因子,并定量评估各因子在模型预测中的相对贡献,本研究采用随机森林 (Random Forest) 模型内置的特征重要性指标进行分析。随机森林由多棵决策树集成,每棵树在节点分裂时,会选择能最大程度降低节点基尼不纯度的特征进行分裂。基尼不纯度衡量节点样本的混杂程度,其值越小表示节点越纯。将特征在所有树、所有节点上带来的不纯度降低值进行累加,并归一化至总和为 1,即得到该特征的特征重要性 (Mean Decrease in Impurity, MDI)。特征重要性取值在 0 到 1 之间,所有特征的重要性之和为 1,数值越高,表示特征在构建决策树时对提升节点纯度的贡献越大,对预测结果越重要^[24]。

特征重要性计算结果如图 4 所示。由图 4 可知,研究区总体特征中坡度、断层、降水量、居民区、

水系、起伏度占相对主导地位。这表明,研究区崩塌的发生主要受地形条件 (坡度、起伏度)、地质构造 (断层) 和水文气象条件 (降水、距水系距离) 的共同控制,人类活动 (距居民区距离) 也具有一定影响。




图 4 特征重要性

Fig.4 Feature importance

此外,研究区崩塌灾害发生在不同地貌单元,各单元的主导因子可能存在差异。为定量分析这种差异,采用 Pearson 相关系数分区计算各因子与崩塌灾害的相关性。Pearson 相关系数适用于衡量两个变量之间的线性相关程度,其计算公式为:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2)$$

式中: r 为 Pearson 相关系数; x_i 为连续因子值; y_i 为崩塌标签 (1 表示崩塌, 0 表示非崩塌); \bar{x} 、 \bar{y} 分别为 x 、 y 的均值; n 为样本数量。相关系数 r 的取值范围为 $[-1,1]$, 正值表示因子值越大崩塌概率越高, 负值表示因子值越大崩塌概率越低; 绝对值越大表明因子与崩塌的相关性越强。通常, $|r| \geq 0.7$ 视为强相关, $0.4 \leq |r| < 0.7$ 为中等相关, $|r| < 0.4$ 为弱相关。同时,通过显著性检验得到 p 值, $p < 0.05$ 表示显著相关, $p < 0.01$ 表示极显著相关,用以判断相关性是否具有统计意义^[24]。

3.3 模型性能分析

本研究采用 AUC (Area Under the Curve) 值作为模型性能的评价指标, AUC 值是受试者工作特征曲线下的面积,该值表示了模型对于崩塌灾害预测分类性能。AUC 值的正常范围为 $[0.5,1]$, AUC 值越接近 0.5, 证明模型对崩塌灾害的判别能力越弱,其表现接近随机猜测; 反之, AUC 值越接近于 1, 则证明模型能极好地区分崩塌与非崩塌样本, 判别能力越强^[7,25]。此外,为增强模型评估的稳健性,引入 5 折交叉验证: 将数据集随机均分为 5

份，每次用 4 份训练、1 份验证，重复 5 次，取 5 次 AUC 的平均值作为最终性能指标，并以标准差衡量模型的稳定性^[24]。

基于原始数据集与频率比数据集，分别使用 4 种模型方法进行建模，最终统计了 8 种模型的 AUC 值，结果见表 1。

表 1 AUC 计算结果

Tab.1 AUC results

模型	原始数据集		频率比数据集	
	AUC	标准差	AUC	标准差
Stacking	0.8862	0.030	0.8967	0.019
LGBM	0.8840	0.034	0.8943	0.024
XGBoost	0.8782	0.039	0.8884	0.030
RF	0.8683	0.055	0.8786	0.043
SVM	0.8559	0.042	0.8661	0.039
MLP	0.8235	0.059	0.8332	0.047

在原始特征与频率比两种数据集上，Stacking 等集成学习模型的平均 AUC 均高于单一模型 SVM 和 MLP，表明集成方法在本研究崩塌预测中具有明显优势。其中，XGBoost 作为梯度提升的另一种实现，其性能与 LGBM 相近，在频率比数据集上 AUC 达 0.8884，略低于 LGBM 但优于 RF。MLP 作为神经网络模型，受限于样本量较小，表现相对较低（频率比数据集 AUC=0.8332），且标准差较大（0.047），说明在小样本场景下深度学习模型易过拟合，集成学习更具鲁棒性。此外，相较于原始数据集，使用频率比数据集的模型性能有明显提升，说明频率比特征优化对所有模型均有正向作用。

其中，Stacking 算法在两类数据上均表现最佳（在原始数据集上的 AUC=0.8862，而在频率比数据集上的 AUC=0.8967），显示出最强的判别性能，这主要归因于 Stacking 集成策略，其核心在于能够有效融合不同基学习器的优势。该结果与 Stacking 在滑坡风险预测中表现最优相似^[26]，进一步证明其

在崩塌灾害预测中同样具有较高的可靠性与适用性。

综上所述，6 种算法中 Stacking 算法的性能最为出色，频率比数据替换原始致灾因子后模型性能得到显著提升。因此，后续将采用基于频率比数据集的 Stacking 模型进行研究区崩塌易发性区划。

3.4 研究区崩塌易发性预测

使用 Stacking 算法基于频率比数据集进行了预测模型的构建，并对研究区域总体的崩塌灾害易发性进行了预测。之后，基于自然间断法对研究区域内的崩塌风险进行了 5 级分类，分为极低风险区:[0,0.22)、低风险区:[0.22,0.38)、中风险区:[0.38,0.55)、高风险区:[0.55,0.76)、极高风险区:[0.76,1.0]，预测结果如图 5 所示。由图 5 可知，极低风险区占比 28.2%，低风险区占比 19.5%，中风险区占比 21.3%，高风险区占比 19.2%，极高风险区占比 11.8%。这一结果与同类黄土区研究^[14]相似，处于合理范围之内。




图 5 Stacking 算法预测结果

Fig.5 Prediction results of the Stacking algorithm

值得注意的是，黄河岸坡的高风险区域在空间上并非均匀分布，而是高度集中于中部的峡谷地貌

单元。由此可见，峡谷地形是影响黄河岸坡稳定性的重要因素^[8]，这凸显了在地质灾害评价中考虑地

貌单元控制作用的必要性。

3.5 研究区崩塌高风险区分布特征

基于 Stacking 算法的预测结果,本研究提取了黄河右岸河南段崩塌灾害的极高、高风险核心区域,

其分布情况如图 6 所示。图中显示,除极个别灾害点外,约 98%的已有灾害点均落在预测的极高风险区内,有效验证了模型的精准性。

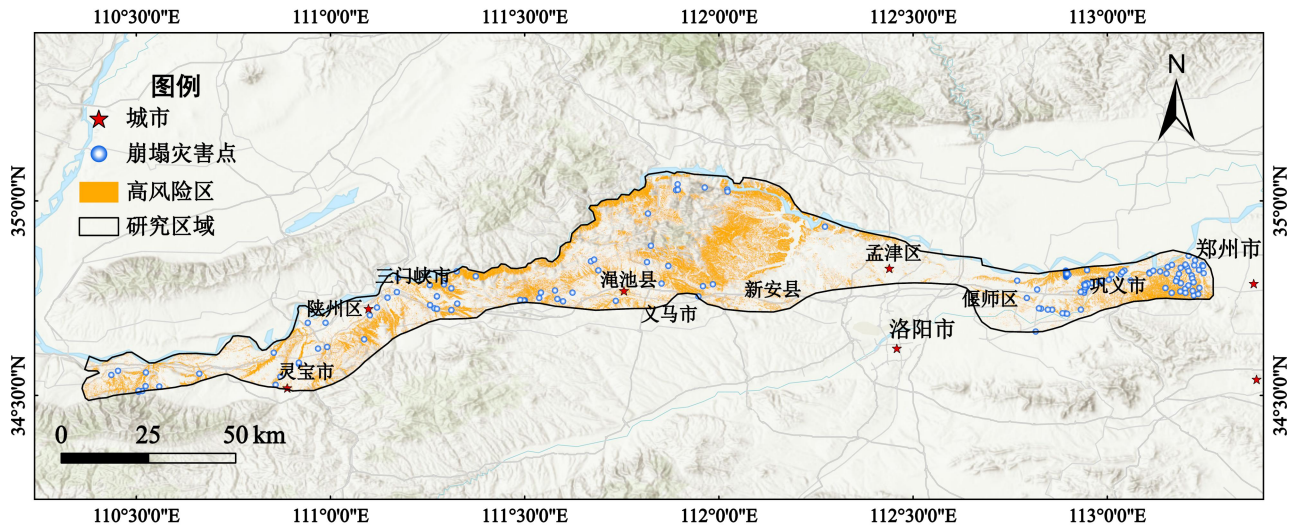


图 6 高风险区分布图

Fig.6 High-Risk susceptibility map

研究区地跨三门峡、洛阳、郑州市共 11 个区县,地貌类型复杂。在多种致灾因子共同作用下,崩塌高风险区呈现出明显的空间分异格局,主要集中在分布于西部、北部、中部及东部 4 个地带,且各

区域的主要影响因素与分布形态各不相同。

为了进一步探究各区域的主要影响因素,我们使用了 Pearson 相关性系数分别计算各了区域内 11 个因子与崩塌的相关系数及显著性,结果见表 2。

表 2 相关性系数计算结果

Tab.2 Calculation results of correlation coefficient

影响因子	研究区西部		研究区中部		研究区北部		研究区东部	
	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>	<i>r</i>	<i>p</i>
高程	0.282	0.089	0.153	0.334	0.302	0.133	0.277	0.256
坡度	0.695	0.004	0.865	0.006	0.805	0.002	0.866	0.001
坡向	0.195	0.133	0.061	0.702	-0.198	0.331	-0.019	0.797
起伏度	0.850	0.002	0.647	0.012	0.645	0.004	0.591	0.026
平面曲率	0.375	0.071	0.464	0.197	0.636	0.005	0.470	0.078
剖面曲率	0.460	0.056	0.323	0.373	0.455	0.019	0.342	0.095
降水量	0.675	0.007	0.626	0.016	0.148	0.470	0.171	0.181
植被类型	0.329	0.074	0.526	0.072	0.590	0.012	0.668	0.006
距居民区距离	-0.675	0.032	-0.176	0.265	-0.027	0.895	-0.626	0.009
距断层距离	-0.426	0.051	-0.693	0.009	-0.084	0.684	-0.073	0.311
距水系距离	-0.267	0.126	-0.337	0.292	-0.774	0.002	-0.611	0.013

研究区西部,高风险区离散分布于三门峡市湖滨区、陕州区及灵宝市的部分区域。该区域整体属河谷平原,地势平缓,而高风险区则集中分布于区内残留的黄土塬与丘陵地带。这些区域地形起伏与坡度较大,在降雨作用下,干黄土易局部饱和,从而诱发坡面崩塌^[27]。相关分析显示,该区域崩塌与起伏度($r=0.850, p<0.01$)、降水量($r=0.675, p<0.01$)和坡度($r=0.695, p<0.01$)呈显著正相关,与距居

民区距离呈显著负相关($r=-0.675, p<0.05$)。这说明降雨和地形是该区域崩塌的主要控制因素,同时人类活动也加剧了风险。

研究区中部风险区为面积最大、连续性最高的高风险区域,占高风险区总面积的 54%,主要位于渑池市、义马市及新安县北部。该区地处秦岭余脉,地表起伏剧烈、地质结构复杂,且为研究区内的降雨高值区^[19]。相关性分析表明,坡度($r=0.865,$

$p < 0.01$)、距断层距离 ($r = -0.693$, $p < 0.01$) 和起伏度 ($r = 0.647$, $p < 0.05$) 是该区域的主导因子, 降水量也呈显著相关 ($r = 0.626$, $p < 0.05$)。复杂山地丘陵地形、脆弱岩土体条件与集中降雨三者共同作用, 致使该区域成为崩塌灾害的高易发区。

研究区北部风险区紧密沿黄河岸坡分布, 形成了一条起三门峡市陕州区, 东至洛阳市孟津区的高风险廊道。该段黄河穿行于秦岭余脉与中条山之间的峡谷, 岸坡陡峻, 天然稳定性较差^[17]; 加之河道于此由东北向东南急剧转折, 水流侧蚀与坡脚冲刷作用强烈。相关性计算显示, 坡度 ($r = 0.805$, $p < 0.01$) 是最强相关因子, 其次为距水系距离 ($r = -0.774$, $p < 0.01$) 和平面曲率 ($r = 0.636$, $p < 0.01$), 剖面曲率和植被类型也呈显著相关。这表明河流侧蚀与地形陡峻是该区域崩塌的主要控制因素。受峡谷地形约束与强烈流水侵蚀共同控制, 该区域形成了沿河岸坡失稳型高风险带。

研究区东部的高风险区高度集中于洛阳市偃师区、郑州市巩义市与上街区。该区域地貌以黄土丘陵与黄土塬为主, 人口密集, 人类工程活动强烈。相关性分析显示, 坡度 ($r = 0.866$, $p < 0.01$) 和起伏度 ($r = 0.591$, $p < 0.05$) 仍是控制崩塌的重要地形因子; 植被类型 ($r = 0.668$, $p < 0.01$)、距居民区距离 ($r = 0.626$, $p < 0.01$) 与崩塌灾害呈显著正相关, 反映了农业灌溉与工程切坡等人类活动对边坡稳定性的显著影响^[28]; 距水系距离 ($r = -0.611$, $p < 0.05$) 与崩塌呈显著负相关, 凸显黄河侧蚀的持续作用。图 3-k 中栽培植被的高频率比也印证了农业灌溉对边坡的扰动。频繁的工程建设与农业灌溉等人类活动、黄河侧向侵蚀、地形因子共同作用, 使该区域成为高度集中的崩塌高风险区。

上述量化分析结果与高风险区空间分布特征高度吻合, 证实了不同地貌单元崩塌主控因子的差异性, 也为区域差异化防灾提供了科学依据。

4 结论与展望

本研究以黄河右岸河南段崩塌灾害分布区为研究区域, 探究了不同机器学习算法对崩塌易发性预测模型的性能和频率比特征转换方式对崩塌易发性预测结果的影响, 得出了以下结论:

1) 集成学习模型在崩塌易发性评价中具有显著优势。在 6 种对比模型中, Stacking 集成模型通过将 SVM、RF、LGBM、XGBoost 和 MLP 作为基学习器进行堆叠学习, 取得了最优的预测效果。在频率比数据集上, Stacking 模型的 AUC 值达到 0.8967, 较 MLP 模型 (AUC=0.8332) 提升约 7.6%,

且模型标准差最小 (0.019), 表现出更强的泛化能力和鲁棒性, 在样本特征分布不均的情况下具有显著优势。

2) 频率比特征优化可有效提升模型预测性能。相较于原始数据集, 采用频率比转换后的特征输入使 6 种模型的 AUC 值均得到提升, 其中 Stacking 算法的提升效果最佳, 达到了 0.0105。该方法通过增强致灾因子与崩塌灾害之间的空间相关性表达, 在样本数量较少的条件下有效缓解了数据稀疏性与分布不均对模型学习的限制, 实现了更精准的分类预测。

3) 研究区崩塌易发性呈现明显的空间分异格局。使用 Stacking 对研究区的崩塌易发性进行了预测, 其中, 高与极高风险区合计占比 31.0%。空间分布上, 崩塌高风险区呈“中部连片为主体、西部离散分布、东部局部集中、北部沿廊道延伸”的格局。近 98% 的历史灾害点落在高与极高风险区内, 验证了模型的精准性。不同区域的主控因子存在差异: 中部以坡度 ($r = 0.865$)、距断层距离 ($r = -0.693$) 为主控因子; 北部以坡度 ($r = 0.805$)、距水系距离 ($r = -0.774$) 为主导; 东部以坡度 ($r = 0.866$)、植被类型 ($r = 0.668$) 和距居民区距离 ($r = -0.626$) 共同作用; 西部则以起伏度 ($r = 0.850$) 和降水量 ($r = 0.675$) 为主导。

未来研究可将预测成果与防灾规划实践相结合, 选取典型高风险区开展实地隐患排查, 进一步检验模型的实用性。同时, 拟纳入时序降水、地表变形等监测数据构建动态风险评估模型, 实现风险防控措施的动态优化与精准施策, 为黄河中游黄土崩塌灾害的预警与防治提供更全面的科学支撑。

参考文献

- [1] 胡涛, 樊鑫, 王硕, 等. 基于径向基神经网络的思南县崩塌易发性评价[J]. 科学技术与工程, 2019, 19(35): 61-69. [Hu T, Fan X, Wang S, et al. Collapse susceptibility assessment of Sinan county based on radial basis function neural network[J]. Science Technology and Engineering, 2019, 19(35): 61-69.]
- [2] 陈丹璐, 安雪莲, 邵怀勇, 等. 黄土塬地貌区滑坡灾害易发性量化评估及关键驱动因子[J]. 北京师范大学学报(自然科学版), 2025, 61(2): 255-267. [Chen D L, An X L, Shao H Y, et al. Quantitative assessment of landslide hazard susceptibility and key driving factors in loess plateau geomorphologic area [J]. Journal of Beijing Normal University (Natural Science), 2025, 61(2): 255-267.]

- [3] 刘翠然,许铜建,樊德军.河南省西峡县地质灾害分布规律研究[J].华北水利水电大学学报(自然科学版),2016,37(3):71-75.[Liu C R,Xu T J,Xu T J. Investigation on the Distribution of geological disasters in Xixia county in Henan province [J] .Journal of North China University of Water Resources and Electric Power(Natural Science Edition), 2016,37(3):71-75.]
- [4] 田乃满,兰恒星,伍宇明,等.人工神经网络和决策树模型在滑坡易发性分析中的性能对比[J].地球信息科学学报,2020,22(12):2304-2316.[Tian N M,Lan H X, Wu Y M,et al.Performance comparison of BP artificial neural network and CART decision tree model in land-slide susceptibility prediction[J].Journal of Geo-information Science,2020, 22(12):2304-2316.]
- [5] 吴常润,角媛梅,王金亮,等.基于频率比-逻辑回归耦合模型的双柏县滑坡易发性评价[J].自然灾害学报,2021,30(4):213-224.[Wu C R,Jiao Y M,Wang J L,et al. Frequency ratio and logistic regression models based coupling analysis for susceptibility of landslide in Shuangbai County [J].Journal of Natural Disasters,2021,30(4):213-224.]
- [6] Liu X K,Shao S,Zhang C,et al.Landslide susceptibility prediction in the loess tableland considering geomorphic evolution[J].Catena,2025,249:108668.
- [7] Kong L H,Feng W K,Yi X Y,et al.Enhanced landslide susceptibility mapping in data-scarce regions via unsupervised few-shot learning[J].Gondwana Research, 2025,138:31-46.
- [8] 郑元勋,周康康,胡少伟,等.基于集成学习和考虑滑坡负样本的滑坡易发性评价[J].人民黄河,2025,47(7):116-123.[Zheng Y X, Zou K K, Hu S W, et al.Landslide susceptibility evaluation based on integrated learning and considering landslide negative samples [J].Yellow River, 2025,47(7):116-123.]
- [9] Sun D L,Wen H J,Wang D Z,et al.A random forest model of landslide susceptibility mapping based on hyperparameter optimization using Bayes algorithm[J].Geomorphology, 2020,362:107201.
- [10] Wang Y L,Ling Y B,Chan T O,et al.High-resolution earthquake-induced landslide hazard assessment in Southwest China through frequency ratio analysis and LightGBM[J].International Journal of Applied Earth Observation and Geoinformation,2024,131:103947.
- [11] He Y F,Ding M T,Duan Y,et al.Exploring the dynamic impact of urbanization on landslide susceptibility in Sichuan Province using an explainable XGBoost model [J]. Engineering Geology,2025,357: 108372.
- [12] 王浩,晏田田,郭剑波,等.基于 Stacking 集成算法的抛石护岸水毁破坏预测研究 [J]. 水电能源科学,2024,42(1):185-188. [Wang H, Yan T T, Guo J B,et al.Stacking integration algorithm-base water damage prediction in riprap revetments [J].Water Resources and Power,2024,42(1): 185-188.]
- [13] Li W J,Fang Z C,Wang Y.Stacking ensemble of deep learning methods for landslide susceptibility mapping in the Three Gorges Reservoir area, China[J]. Stochastic Environmental Research and Risk Assessment,2021, 36(8):2207-2228.
- [14] 胡祥祥,石亚亚,胡良柏,等.融合 InSAR 与信息量-机器学习耦合模型的黄土滑坡易发性评价[J].西北地质, 2025,58(2):159-171.[Hu X X,S Y Y,Hu L B,et al. Evaluation of loess landslide susceptibility by combining InSAR and information-machine learning coupling model[J].Northwestern Geology,2025,58(2):159-171.]
- [15] Fang Z C,Wang Y,Peng L,et al.Integration of convolutional neural network and conventional machine learning classifiers for landslide susceptibility mapping[J]. Computers & Geosciences,2020,139:104470.
- [16] 盛明强,刘梓轩,张晓晴,等.基于频率比联接法和支持向量机的滑坡易发性预测 [J]. 科学技术与工程,2021, 21(25):10620-10628.[Sheng M Q,Liu Z X,Zhang X Q,et al. Landslide susceptibility prediction based on frequency ratio analysis and support vectormachine [J] .Science Technology and Engineering,2021,21(25):10620-10628.]
- [17] 杜金花,卢演铸,王旭龙,等.晋豫间黄河峡谷黄土状沙丘的光释光年代学探讨 [J]. 第四纪研究, 2010, 30(5): 946-955.[Du J H, Lu Y C, Wang X L, et al.Optically stimulated luminescence dating of loess-like sand-dune along the yellow river valley between Henan and Shanxi provinces [J] .Quaternary Sciences,2010,30(5):946-955.]
- [18] 何梦真,张乐涛,魏仪媛,等.黄河中游不同地貌分区景观格局脆弱性及其驱动力[J].环境科学,2024,45(6):3363-3374. [He M Z,Zhang L T,Wei Y Y,et al.Landscape pattern vulnerability and its driving forces in different geomorphological divisions in the Middle Yellow River [J]. Environmental Science,2024,45(6):3363-3374.]
- [19] 任圆圆,张学雷.河南省多级地貌特征及与土壤多样性的关系[J].土壤, 2019, 51(1): 142-151.[Ren Y Y, Zhang X L. Multi-class geomorphic diversity and its relationship with pedodiversity in Henan province [J] . Soils, 2019, 51(1): 142-151.]
- [20] 刘汉东,张艺冰,鲁丽萍.豫西锁固型滑坡类型研究[J].华北

- 水利水电大学学报(自然科学版),2018,39(6):1-7.[Liu H D,Zhang Y B,Lu L P.Types of the Locked Section Landslide in the Western Henan Province [J] . Journal of North China University of Water Resources and Electric Power(Natural Science Edition),2018,39(6):1-7.]
- [21] 马泉来,杨崇科,周浩,等.秦岭东段洛河流域农业生产空间水分供需效应及其管控分区[J].农业机械学报,2025,56(11):667-676.[Ma Q L,Yang C K,Zhou H,et al.Water supply and demand effect and control zoning of agricultural production space in Luohe river basin of eastern Qinling mountain [J] .Transactions of the Chinese Society for Agricultural Machiner,2025,56(11):667-676.]
- [22] Binh T P,Dieu T B,Indra P,et al.Hybrid integration of Multilayer Perceptron Neural Networks and machine learning ensembles for landslide susceptibility assessment at Himalayan area (India) using GIS [J]. CATENA,2017,149(1):52-63.
- [23] Marjanović M,Kovačević M,Bajat B,et al.Landslide susceptibility assessment using SVM machine learning algorithm [J].Engineering Geology,2011,123(3): 225-234.
- [24] 林琴,郭永刚,吴升杰,等.基于梯度提升的优化集成机器学习算法对滑坡易发性评价:以雅鲁藏布江与尼洋河两岸为例[J].西北地质,2024,57(1):12-22.[Lin Q, Guo Y G,Wu S J,et al. Evaluation of landslide susceptibility by optimization integrated machine learning algorithm based on gradient boosting: take both banks of Yarlung Zangbo River and Niyang River as examples[J].Northwestern Geology, 2024,57(1):12–22.]
- [25] Duan Y,Ding M T,He Y F,et al.Global projections of future landslide susceptibility under climate change[J]. Geoscience Frontiers,2025,16(4):102047.
- [26] Yu L B, Wang Y, Pradhan B. Enhancing landslide susceptibility mapping incorporating landslide typology via stacking ensemble machine learning in Three Gorges Reservoir, China [J]. Geoscience Frontiers, 2024,15(4): 101802.
- [27] Guo W Z,Luo L,Wang W L,et al.Sensitivity of rainstorm-triggered shallow mass movements on gully slopes to topographical factors on the Chinese Loess Plateau[J]. Geomorphology,2019,337:69-78.
- [28] Peng J B,Wang S K,Wang Q Y,et al.Distribution and genetic types of loess landslides in China[J]. Journal of Asian Earth Sciences,2019,170:329-350.

Evaluation of Collapse Susceptibility in the Henan Section of the Right Bank of the Yellow River Based on Machine Learning

WANG Hao¹, YANG Jingang¹, ZHAO Mengxin¹, ZHANG Jianwei¹,

ZHANG Shumiao¹, XU Zhijie²

(1. School of Civil Engineering and Architecture, Henan University, Kaifeng 475004, China; 2.Henan Natural Resources Monitoring and Land Consolidation Institute , Zhengzhou 450003, China)

Abstract: 【Objective】 To develop a high-precision landslide susceptibility prediction method suitable for data-scarce conditions, and to evaluate the effectiveness of feature optimization and model ensemble strategies, with the aim of providing practical guidance and technical reference for risk prevention and control of loess landslides in the middle reaches of the Yellow River. **【Methods】** Taking the right bank section of the middle Yellow River in Henan as the study area, 11 characteristic factors including topography, hydrological conditions, and human activities were selected. Based on the original dataset and the frequency ratio-transformed dataset, four machine learning models—Support Vector Machine, Random Forest, Light Gradient Boosting Machine, eXtreme Gradient Boosting, Multilayer Perceptron, and Stacking ensemble—were constructed and compared. The model performance and the role of feature optimization were systematically analyzed, and the optimal model was then applied for susceptibility zoning. **【Results】** (1) Model comparison showed that the ensemble learning models significantly outperformed the single model, with the Stacking ensemble model achieving the highest prediction accuracy (AUC=0.8967). (2) The use of frequency ratio-transformed

features effectively enhanced the classification performance of all models, mitigating the limitations imposed by scarce and unevenly distributed samples on model learning. (3) The prediction results based on the Stacking model indicated that high and very high landslide risk zones in the study area accounted for 31% of the total area, spatially exhibiting a pattern of "central contiguous area as the main body, scattered distribution in the west, localized concentration in the east, and extension along corridors in the north," which aligns closely with the distribution of historical landslide events.

【 Conclusion 】 The integration of frequency ratio feature optimization and Stacking ensemble learning effectively improves the accuracy of landslide susceptibility prediction under data-scarce conditions, yielding reliable risk zoning results. Future research could further incorporate time-series monitoring data to develop dynamic risk assessment models and combine the prediction outcomes with on-site disaster prevention planning to test and optimize risk mitigation measures in practice.

Keywords: susceptibility to collapse; machine learning; frequency domain ratio; middle reaches of the Yellow River