https://doi.org/10.3799/dqkx.2026.201

基于半监督非对称策略的滑坡易发性综合评价及可解释性研究

贾 卓,单泳烨,张 芸,江炳辰*,殷中弟,李火坤,黄发明

南昌大学工程建设学院,江西南昌 330031

摘 要: 为突破传统滑坡易发性建模中滑坡与非滑坡样本等比例选取、非滑坡样本二元标签赋值及缺乏可解释性分析等局限,提升预测精度与模型透明度.以江西省武宁县为例,引入半监督非对称策略:兼顾滑坡与非滑坡样本筛选以构建高质量训练集,突破等比例采样与传统二元标签模式,以初始易发性指数作为非滑坡样本的连续型标签值,结合多比例采样构建XGBoost模型,并通过多指标评估及SHAP等可解释性方法进行系统验证.结果表明,非滑坡样本比例增至1∶140时建模效果最优,AUC与频率比精度分别达0.981和0.912;半监督非对称模型在预测精度及易发性分布合理性上均优于监督与常规半监督模型.半监督非对称策略通过高质量样本筛选、样本比例与标签值设定方式优化,显著提升模型性能、降低不确定性,为滑坡风险精准防控提供可靠技术支撑.

关键词: 半监督非对称;滑坡易发性建模;非滑坡样本;XGBoost模型;可解释性;工程地质.

中图分类号: P642.22 **文章编号:** 1000－2383(2026)10－3838－25 **收稿日期:** 2026-03-10

Comprehensive Evaluation and Interpretability Research of Landslide Susceptibility Based on a Semi-Supervised Imbalanced Strategy

Jia Zhuo, Shan Yongye, Zhang Yun, Jiang Bingchen*, Yin Zhongdi, Li Huokun, Huang Faming

School of Infrastructure Engineering, Nanchang University, Nanchang 330031, *China*

Abstract: In order to break through the limitations of traditional landslide susceptibility modeling, such as the equal proportion selection of landslide and non-landslide samples, the binary label assignment of non-landslide samples, and the lack of interpretability analysis, and to improve the prediction accuracy and model transparency, taking Wuning County, Jiangxi Province as an example, a semi-supervised imbalanced strategy was introduced: considering both landslide and non-landslide sample screening to construct a high-quality training set, breaking the equal proportion sampling and binary label mode, using the initial susceptibility index as the continuous label value of non-landslide samples, and combining multi-proportion sampling to build an XGBoost model. The model was systematically verified through multiple indicators and interpretability methods such as SHAP. The results show that the modeling effect is optimal when the ratio of non-landslide samples increases to 1∶140, with AUC and

基金项目: 江西省自然科学基金项目(Nos.20242BAB20238, 20252BAC240688);江西省水利厅科技项目(No.202527ZDKT05);国家自然科学基金项目(No.42377164).

作者简介: 贾卓(1992－),男,讲师,博士,滑坡易发性预测建模与机制模拟. ORCID: 0009-0006-5709-1101. E-mail:jiazhuo@ncu.edu.cn

* **通讯作者:** 江炳辰(2001－),男,博士研究生. 滑坡风险智能预警理论与软件研发. ORCID: 0009-0000-7184-1622. E-mail:jiangbingchen@email.ncu.edu.cn

引用格式: 贾卓,单泳烨,张芸,江炳辰,殷中弟,李火坤,黄发明,2026.基于半监督非对称策略的滑坡易发性综合评价及可解释性研究.地球科学,51(10):3838－3862.

Citation: Jia Zhuo, Shan Yongye, Zhang Yun, Jiang Bingchen, Yin Zhongdi, Li Huokun, Huang Faming, 2026. Comprehensive Evaluation and Interpretability Research of Landslide Susceptibility Based on a Semi-Supervised Imbalanced Strategy. *Earth Science*, 51(10):3838－3862.

frequency ratio accuracy reaching 0.981 and 0.912 respectively. The semi-supervised imbalanced model outperforms the supervised and conventional semi-supervised models in terms of prediction accuracy and the rationality of susceptibility distribution. The semi-supervised imbalanced strategy significantly improves model performance and reduces uncertainty through the optimization of sample screening, sample proportion, and label value setting, providing reliable technical support for precise landslide risk prevention and control.

Key words: semi-supervised imbalance; landslide susceptibility modeling; non-landslide sample; XGBoost model; interpretability; engineering geology.

0　引言

滑坡是我国发生最频繁、危害最广泛的地质灾害之一,严重破坏资源环境,并直接威胁人民生命财产安全.其易发性建模与评价是区域危险性与全过程风险评估的基础,为防灾减灾提供科学依据,支撑区域经济社会可持续发展(崔玉龙等,2024).

随着计算机科学、GIS与机器学习技术的快速发展,多学科交叉融合推动滑坡易发性建模及不确定性分析研究走向系统化.当前建模流程已形成规范范式,涵盖滑坡编录与环境因子数据获取、样本集划分、预测模型构建及结果不确定性量化等核心环节(He *et al*, 2023; Huang *et al*, 2024; 贾卓等, 2025).影响预测精度的关键不确定性来源包括预测单元空间尺度、机器学习模型类型、非滑坡样本构建策略,以及滑坡与环境因子间物理驱动与统计响应的耦合机制(Guo *et al.*, 2020, 2025; Li and Tian, 2025).近期研究聚焦建模方法选择、样本比例及标签值设定等可调控因素对预测性能的影响,为提升模型稳健性、可解释性及实际适用性提供了理论与方法支撑(熊浩文, 2024; Chen *et al.*, 2025; Li and Tian, 2025).

当前滑坡易发性建模的主流方法分为无监督学习与监督机器学习两类.无监督模型以环境因子为输入,无需样本标注即可建模,典型方法包括K均值聚类(刘福臻等, 2021)和SOM神经网络(Ye *et al.*, 2023),但因缺乏滑坡先验信息,难以刻画环境因子与滑坡分布的内在关联,预测精度受限.相比之下,监督机器学习模型兼具输入与输出变量,可利用已知滑坡样本先验信息,在运行效率与预测准确性上具有优势;刘福臻等(2021)也明确指出,监督模型的整体预测性能优于无监督模型.然而其存在野外滑坡调查耗时、正样本稀缺,以及随机选取非滑坡样本易引入空间偏差等局限.为此,Reichenbach *et al.*(2014)将半监督建模理念引入该领域,融合两类模型优势,仅需少量标记样本即可利用未标记样本降低模型不确定性,常见模型包括决策树(Decision Tree, DT)(Pham *et al.*, 2022)、随机森林(Random Forest, RF)(刘坚等, 2018)和极端梯度提升算法(Extreme Gradient Boosting, XGBoost)(Chen and Guestrin, 2016).近年,部分学者将半监督学习与深度学习及现有模型结合,提升了预测性能.例如,黄发明等(2024)采用半监督方法筛选非滑坡样本,并与随机森林RF模型耦合,显著提高了预测精度,验证了该策略的有效性与优势.

半监督学习在滑坡易发性预测中具有优势,但当前研究多等比例选取非滑坡样本,忽视滑坡发生概率的空间异质性,限制了模型精度提升.滑坡点集中于特定地形、地质与水文条件耦合区域,而非滑坡区域分布广泛、面积远超滑坡区.为此,部分学者已围绕非滑坡样本的空间代表性与比例设置开展研究.例如,Yang *et al.*(2023)以湖南安化为研究区,发现RF模型在样本比例1∶6.18时表现最优;Chen *et al.*(2025)在宜宾市建模中指出,适当增加非滑坡样本比例可提升预测性能;Li and Tian(2025)在峨眉山市测试表明,1∶5的样本比例下ROC曲线下面积最高且易发性指数分布合理.现有研究普遍将滑坡样本标签设为“1”、非滑坡样本设为“0”,但非滑坡样本仅代表滑坡概率较低区域,并非绝对稳定,简单二元赋值存在局限.针对上述等比例采样与传统二元标签的双重局限,半监督非对称策略通过优化样本比例、连续化标签值实现突破.Huang *et al.*(2020)基于江西寻乌县数据提出半监督非对称理论,张崟琅(2023)在会昌县应用该理论发现,模型性能随非滑坡样本数量增加而提升,且在1∶25时趋于稳定.目前,系统探讨非滑坡样本比例与标签设定影响的研究较少,半监督非对称策略应用有限,限制了模型充分性与可靠性的验证.

值得注意的是,滑坡易发性建模结果的可解释性常被忽视,尤其在半监督非对称建模领域,相关理论不成熟,建模过程易陷入“黑箱”,增加结果不

确定性，影响其在防灾减灾决策中的应用.亟须引入科学的可解释性方法，解析建模不确定性来源，提升模型透明度与可信度.目前，可解释性方法已在多领域成功应用，如Chen and Moraga(2025)采用SHAP模型(SHapley Additive Explanation)识别登革热疫情关键驱动因素；田烨等(2023)利用积分梯度法(Integral Gradient，IG)解析LSTM模型在流域短期径流预测中的不确定性来源；Sun *et al.*(2024)结合SHAP模型与部分依赖图(Partial Dependence Plot，PDP)，系统分析滑坡发生的关键环境因子及其作用机制.上述各类方法可有效揭示环境因子对滑坡发生的贡献程度，深化灾害成因认知，但现有研究尚未实现可解释性方法与各类不确定性建模因素的系统整合，制约了模型的科学解释深度与泛化能力.

综上所述，本研究以江西省武宁县为研究区，基于19项环境因子，引入半监督非对称策略，按1∶1至1∶220比例选取非滑坡样本，并以其初始易发性数值为标签，耦合XGBoost模型开展易发性建模；通过AUC值、频率比精度、易发性指数均值与标准差等指标综合评估，确定最优比例，并与监督及常规半监督模型对比；同时开展多因素敏感性分析；最后，融合SHAP、积分梯度法与部分依赖图，解析致灾机制，验证该策略的有效性与可行性.

1 滑坡易发性建模方法

1.1 研究思路与方法

为探究引入半监督非对称策略后，非滑坡样本比例及标签值设定方式的优化对滑坡易发性建模结果不确定性的影响，本研究的研究方法和建模过程(图1)如下：

(1)收集滑坡编录、DEM及遥感影像等数据，并结合研究区水系图与地质图获取基础资料；

(2)基于DEM数据，利用ArcGIS 10.2平台提取19种致灾环境因子，并通过统计各因子区间内栅格总数与滑坡栅格数，计算频率比(Frequency Ratio，FR)；

(3)以FR值为输入变量，采用滑坡与非滑坡等比样本(标签分别为“1”和“0”)，构建并训练监督XGBoost模型，生成初始易发性指数，并依自然断点法划分为极低、低、中、高、极高5级；

(4)将落于(3)中极低和低区的滑坡样本剔除，并在极低易发区内按1∶1～1∶220比例选取非滑坡样本，构建常规半监督XGBoost模型；

(5)将(3)中所得初始易发性数值作为(4)中各比例非滑坡样本的连续型标签，滑坡样本标签保持“1”不变，重构模型，记为半监督非对称XGBoost模型；

(6)基于AUC值、ROC曲线、易发性指数分布特征、频率比精度及混淆矩阵等指标，开展不同样本策略下的预测结果不确定性评估；

(7)通过敏感性分析量化各类不确定性因素对建模结果的影响程度；

(8)结合SHAP法、积分梯度法及PDP双因子图，分析半监督非对称策略下样本比例变化对易发性预测结果的影响机制.

1.2 XGBoost建模过程

XGBoost又称极端梯度提升算法，是一种基于GBDT改进的集成决策树模型(Chen and Guestrin，2016).其核心在于通过加权累加多个弱决策树的预测结果，提升整体预测可靠性.该算法利用泰勒展开对损失函数的一阶与二阶导数进行精确估计，以达到对预测结果进一步优化的目的(吴宏阳等，2023).

通过对模型中n_estimators(迭代次数)、learning_rate(学习率)、gamma(正则化项)、max_depth(树的最大深度)等参数进行调整优化，可提高其准确率和精度.经多次迭代计算后，XGBoost算法生成的最优解公式如下：

$$\mathrm{obj}=\sum_{t=1}^{n}L\left[y_k,\hat{y}_k^{\,t-1}+f_t(x_k)\right]+\sum_t\Omega\left(f_t\right),\quad(1)$$

式中：obj表示损失函数的整体数值；$\sum_{t=1}^{n}L\left(y_k,\hat{y}_k^{\,t-1}\right)$表示样本$x_k$在前$t-1$轮的训练误差之和；$\sum_{t=1}^{n}Lf_t(x_k)$表示样本在前$t-1$轮训练的基础上，新增添的一棵决策树；$\sum_t\Omega\left(f_t\right)$表示前$t$棵树的正项则之和.

1.3 滑坡易发性预测的半监督非对称理论构建

针对传统滑坡易发性建模存在的3类关键局限——历史滑坡样本质量参差不齐、滑坡与非滑坡样本空间分布严重失衡，以及非滑坡样本采用统一二元标签(1/0)而忽略其内在易发性梯度.本研究引入半监督非对称建模方法开展易发性预测.

该策略可同步优化滑坡与非滑坡训练样本.极低、低易发区内的历史滑坡，多受点位编录误差、人

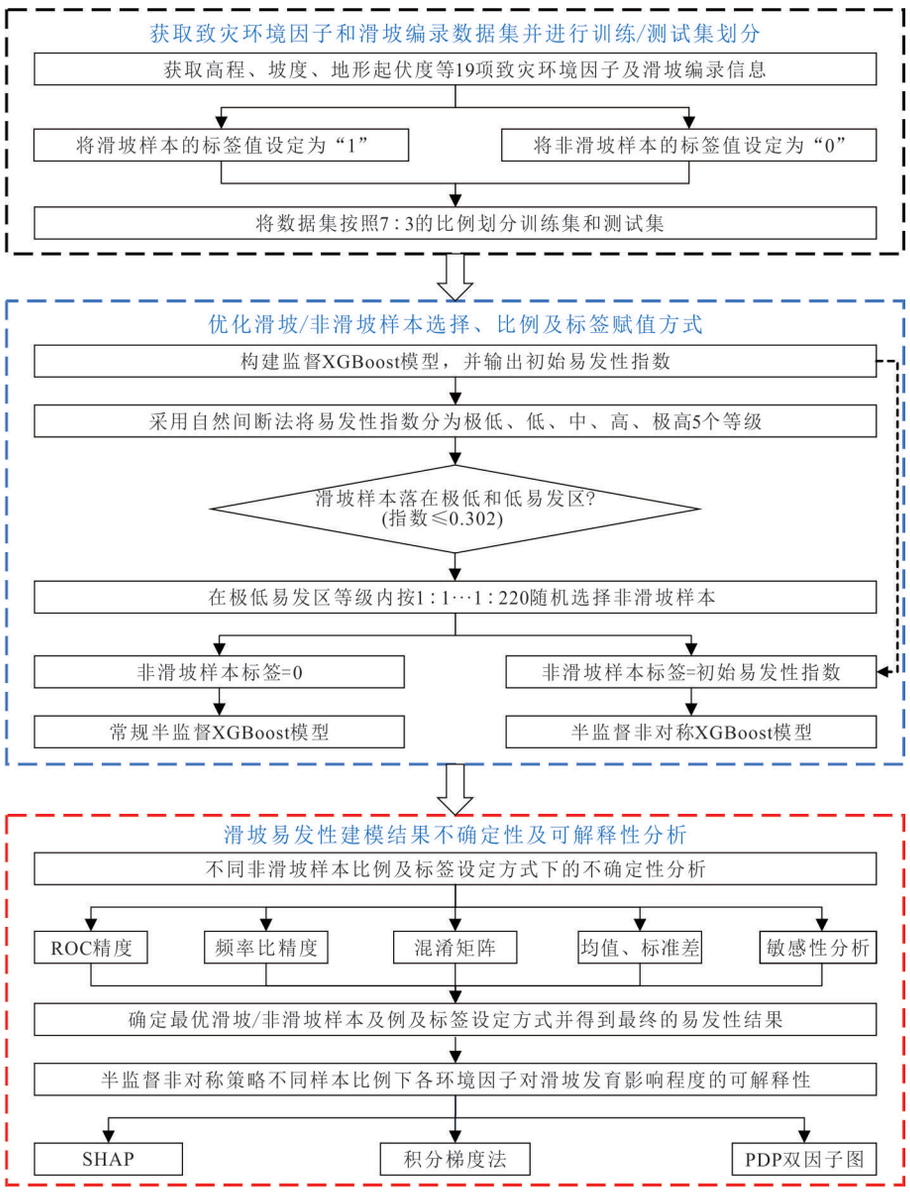

图 1　滑坡易发性建模流程

Fig.1　Modeling flowchart of landslide susceptibility

工切坡等局部扰动影响,其环境特征与区域整体致灾机制相悖.此类低质量样本参与建模易引入假阳性噪声,降低模型对滑坡致灾规律的识别精度.因此,本研究剔除异常滑坡样本,依托监督模型生成初始易发性指数,通过自然断点法完成五级分级,仅从极低易发区筛选高置信度非滑坡样本,构建优质训练数据集(Huang *et al.*,2024).极低易发区受地形、岩性、水文等地质条件限制,滑坡发育条件匮乏,以此筛选的非滑坡样本纯度较高,可有效规避潜在风险的伪非滑坡样本干扰.

同时,突破传统等比例采样与硬性二元标签模式,以初始易发性指数作为非滑坡样本的标签值,结合不同比例采样策略建模,最终通过多指标综合评价确定最优参数组合(Huang *et al.*,2024).

1.4　滑坡易发性建模结果分析

建模结果的不确定性分析是滑坡易发性预测建模的关键部分,构建合理评价体系有助于提升模型可靠性、降低预测不确定性(邓明东等,2024).因此,本研究采用ROC精度、易发性指数分布特征、频率比精度、混淆矩阵相关参数对建模结果进行综合性评估.

1.4.1　ROC精度分析　ROC曲线是评估滑坡易发性模型判别能力的核心指标,通过不同阈值下真阳性率与假阳性率的关系反映模型性能(司康平等,

2009).AUC值越接近1,模型整体预测精度越高.

针对半监督建模中非滑坡样本比例扩大、标签连续化带来的评估偏差,本研究采用平衡子集法:在测试集中随机抽取与滑坡样本等量的非滑坡样本,构建1:1正负比子集,据此绘制ROC曲线并计算AUC,确保评估结果可比、可靠.同时,为反映模型在真实非平衡场景下的表现,本研究同步报告原始不平衡测试集上的AUC值,作为模型泛化能力的补充评估.

1.4.2 易发性指数分布特征 易发性指数分布特征作为滑坡易发性评价体系的关键指标,通常用平均值与标准差量化(周天游等,2023).均值反映滑坡易发性指数的整体倾向,标准差体现其离散程度.一般来说,均值越小,易发性指数越偏向低或极低易发区,预测越准;标准差越大,易发性指数对滑坡的识别能力越强.

1.4.3 频率比精度对比 在滑坡易发性图中,某易发性等级区间实际滑坡栅格占比与该区间栅格占全区占比的比值即为频率比(郑迎凯等,2020).频率比精度是高、极高易发性区频率比之和占总频率比之和的比值,其值越高,模型预测的可靠性与确定性越佳(贾卓等,2025).

1.4.4 混淆矩阵相关参数分析 混淆矩阵相关参数能反映预测结果与真实情况的关联,既可体现分类准确性,也能揭示分类错误情况.本研究以0.5为阈值判定,预测值>0.5且为正样本的栅格是*TP*(True Positive);预测值>0.5但为负样本的栅格是*FP*(False Positive);预测值<0.5且为负样本的栅格是*TN*(True Negative);预测值<0.5但为正样本的栅格是*FN*(False Negative).这4类基础参数是分类性能评价的关键,可进一步算出准确率等评估指标.不过,非滑坡样本比例扩大可能使*FP*和*FN*增大,召回率等指标不再适用,而准确率、特异性几乎不受影响.因此,拟使用准确率和特异性分析不同样本比例下的建模结果.

1.5 不确定性问题敏感性分析

敏感性分析是评估不同影响因素对模型预测结果贡献程度的重要方法.在滑坡易发性建模中,敏感性反映各类不确定因素对预测精度的影响,通常通过各环境因子与对应AUC值的相关性分析实现(Huang *et al.*,2023).本研究采用皮尔逊相关系数量化该关系,所得系数称为"分类变量",取值范围为[−1, 1],最终分析采用其绝对值计算,具体计算公式如下:

$$R=\frac{\operatorname{cov}(x,y)}{\sigma(x)\sigma(y)}, \tag{2}$$

式中:x表示不确定因素下对应的数值,通常用0和1表示;y表示所对应的预测数值精度值,即AUC值.同一类不确定问题分析中,敏感性数值为各"分类变量"的求和平均值.通常情况下,数值越大,表明该因素对模型预测结果的影响越强.

皮尔逊相关系数衡量的是线性关联强度,可能低估不确定因素与AUC之间的非线性关系.为此,本研究同步引入Spearman秩相关系数作为互补验证方法.该方法基于变量的秩次而非原始数值计算相关性,能够捕捉单调非线性关联(Wu *et al.*,2019),其计算公式为:

$$\rho_{(S)}=\frac{6\sum d_i^2}{n(n^2-1)}, \tag{3}$$

式中:d_i为两变量秩次之差;n为样本量;$\rho_{(S)}$取值范围与皮尔逊相关系数一致,为[−1, 1];绝对值越接近1表明单调关联越强.两类方法互为补充,共同支撑敏感性排序的可靠性.

1.6 建模结果的可解释性方法

在滑坡易发性研究中,可解释性指依托特定模型与科学方法,对全域与局部样本开展机理阐释,识别影响滑坡发育的促进、抑制类关键环境因子.本研究联合采用SHAP、积分梯度法与部分依赖图,解析半监督非对称策略下样本比例优化的影响机制.其中,SHAP用于量化单因子全局重要性,积分梯度法按地形、水文、地表覆盖、岩性4大类别判别因子归因净贡献方向,部分依赖图刻画关键因子交互效应.三者从单因子贡献到类别归因再到因子交互,构成递进式解释框架,互为补充.

1.6.1 SHAP算法模型 SHAP算法基于博弈论Shapley值原理,通过计算各特征对模型输出的贡献度并绘制摘要图,解释不同样本的模型行为(Lundberg and Lee,2017).Shapley值用φ_i来衡量某一特定i对预测结果的贡献,设某一个模型f,输入所有特征值的集合为N,具体计算过程如公式(4)所示:

$$\varphi_i(f)=\sum_{S\subseteq N\setminus\{i\}}\frac{|S|(N-|S|-1)!}{|N|!}\left[f(S\cup\{i\})-f(S)\right], \tag{4}$$

式中:S表示不包含特征i的任何子集;N为特征集合;$|S|$表示集合S的大小;$|N|$代表所有的特征总

数;$f(S)$为集合S对模型的输出贡献;$f(S\cup\{i\})$是在考虑特征i的模型输出结果.

1.6.2　积分梯度　积分梯度(Sundararajan *et al.*, 2017)通过输入路径对梯度进行积分,量化各特征对预测结果的正向或负向边际贡献.计算时,先确定基准输入和目标输入,分别定义为g_{base}和g_{obj},将路径函数定义为$h(t)=g_{\text{base}}+h\cdot(g_{\text{obj}}-g_{\text{base}})$,对路径函数上每一点,随后计算预测结果相对于滑坡易发性预测模型输入的梯度,并沿该路径积分,所得积分梯度法如公式(5)所示:

$$IG(g_{\text{obj}})=(g_{\text{obj}}-g_{\text{base}})\cdot\int_0^1\frac{\partial y}{\partial g}\Big|_{g=h(t)}\mathrm{d}t\,. \quad (5)$$

1.6.3　部分依赖图　PDP反映单因子或双因子对模型预测结果的边际效应(Huang *et al.*, 2024),可直观揭示预测结果与环境因子间的线性或非线性关系,适用于全域机制解释.鉴于双因子PDP更能刻画因子交互作用,本研究采用其解析关键环境因子的协同影响.首先选取2个目标因子,输入模型获取预测值;随后按因子组合对预测结果取均值;最后,以因子特征值为横坐标、均值为纵坐标绘图,即得双因子PDP该方法的表达式如公式(6):

$$f_S(x_S)=E_{x_N}\left[f(x_S,x_N)\right]=\int f(x_S,x_N)\mathrm{d}P(x_N)\,, \quad (6)$$

式中:f_S表示部份依赖函数;x_S表示函数需要绘制的特征,本研究为2个特征;x_N表示除x_S以外的其余特征,两者组成了整个特征空间集;$E_{x_N}\left[f(x_S,x_N)\right]$为当$x_S$保持不变时且$x_N$在边际分布上变化时,偏函数$f(x_S,x_N)$的期望值;$P(x_N)$表示$x_N$的概率分布函数.通过对$x_N$的边缘化,获得$x_S$与预测结果的关系,避免无关特征变量的干扰.

2　研究区概况及数据源简介

2.1　武宁县基本概况

武宁县隶属江西省九江市,位于省西北部、湘鄂赣三省交界处,地理坐标为北纬28°53′~29°35′,东经114°29′~115°27′(图2a).县域东西长93.3 km,南北宽77.4 km,总面积3 506.6 km².地形以山地、丘陵为主,海拔57.15~1 712.81 m,北缘幕阜山脉为修河的发源地.属亚热带湿润季风气候,四季分明,水热条件优越,年均气温16.6 ℃,多年平均降水量1 488.3 mm.研究区地处幕阜山与九岭山之间,研究区内地层岩性多样,沉积岩(页岩、泥岩)分布广泛且易风化;然而,岩浆岩出露区多地处中低山地貌,地势陡峻、风化壳深厚,与地形条件耦合作用下同样易发滑坡,全区滑坡易发性较高.

2.2　滑坡编录

滑坡编录数据提供发生位置、规模、面积与类型等关键信息,是划分正负样本、构建机器学习模型及实现滑坡易发性精准预测的基础(郑德凤等, 2024).据武宁县年鉴及滑坡编录报告,截至2022

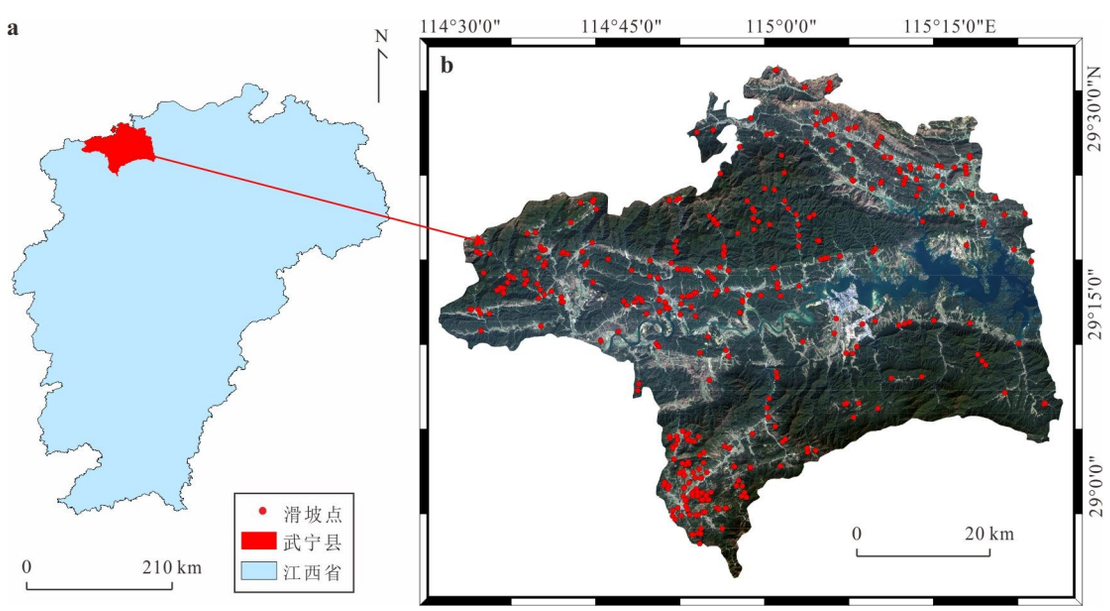

图2　研究区位置和滑坡编录分布

Fig.2　Location of the study area and distribution of the landslide inventory

a.武宁县地理位置图;b.武宁县航拍图

年,研究区共记录滑坡379处(图2b).滑坡主要集中于东北部丘陵、西部平原及西南部低山地带;幕阜山与九岭山延伸区地形起伏大,为高发区,高程多为60～500 m,坡度约17°～32°.受季风气候影响,降雨充沛,强降雨诱发滑体位移是主要触发机制.总体而言,研究区内滑坡类型以中小型崩塌型和牵引式滑坡为主.

2.3 研究区数据源

研究区数据包括滑坡编录数据及致灾环境因子,来源如下:(1)武宁县自然资源局历史滑坡编录资料与全国地质灾害点分布数据;(2)20 m分辨率数字高程模型(DEM),源自地理数据云(http://www.gscloud.cn),用于提取坡度、坡位、河网密度等地形水文因子;(3)1∶250万地质图用于提取断层密度与地层岩性;(4)30 m分辨率Landsat 8影像(2020年4月13日,轨道121/122、42/43,重采样至20 m),用于计算NDVI、NDBI及MNDWI等地表覆盖因子;(5)年均降雨量、人口密度与土壤数据来自中科院资源环境科学数据中心(https://www.resdc.cn).

滑坡编录原始数据为灾害点位,但滑坡是具备面积与形态的地质体,仅以点位表征易丢失规模与空间特征,难以与20 m分辨率的环境因子栅格精准匹配.为此,结合野外调查与遥感解译划定滑坡完整边界并构建面状矢量,依托ArcGIS 10.2平台通过面转栅格工具转换为栅格单元并标记为正样本,最终由379处灾害点位提取获得5 637个滑坡栅格单元.

2.4 环境因子概况和分析

滑坡是内部环境因子与外部触发条件共同作用的结果.本研究基于现场勘察与多源数据,结合武宁县气候、地质及地貌特征,遵循“信息丰富、冗余度低”原则,筛选地形地貌、水文环境、地表覆盖和地层岩性4类共19项环境因子用于易发性建模.高程、坡度、地形起伏度等连续变量采用自然断点法划分为8级;岩性等离散变量依其地质成因与工程特性归类.

滑坡与环境因子间多呈非线性响应关系,频率比法是建立易发性指数与因子关联的关键方法,可量化各属性区间对滑坡发生的贡献(Mao *et al.*, 2025).一般而言,当$FR>1$表明该区间条件利于滑坡发育;当$FR<1$则反映其抑制作用;部分结果如表1所示.

表1 部分致灾环境因子的频率比

Table 1 Frequency ratios of partial disaster-causing environmental factors

环境因子	变量值	全区栅格数(个)	滑坡栅格数(个)	频率比
高程(m)	57.15～167.53	2 694 281	2 086	1.113
	167.53～303.87	1 808 204	1 199	0.954
	303.87～446.72	1 243 324	1 174	1.358
	446.72～596.05	963 696	751	1.121
	596.05～758.37	638 147	359	0.809
	758.37～946.66	433 787	68	0.225
	946.66～1 206.37	245 610	0	0
	1 206.37～1 712.81	78 927	0	0
坡度(°)	0～5.76	1 128 075	94	0.120
	5.76～12.05	1 129 608	372	0.474
	12.05～17.81	1 231 979	1 094	1.277
	17.81～23.05	1 269 466	1 484	1.681
	23.05～28.02	1 206 208	1 458	1.738
	28.02～32.74	1 000 255	840	1.208
	32.74～37.98	785 717	214	0.392
	37.98～66.79	354 668	81	0.328
地形起伏度(m)	0～44.21	1 277 839	821	0.924
	44.21～78.95	1 480 570	1 570	1.525
	78.95～112.11	1 383 064	1 288	1.339
	112.11～142.11	1 241 437	1 055	1.222
	142.11～172.12	1 131 299	461	0.586

续表 1

环境因子	变量值	全区栅格数(个)	滑坡栅格数(个)	频率比
	172.12～203.70	845 772	279	0.474
	203.70～244.75	564 206	129	0.329
	244.75～402.66	181 789	34	0.269
河网密度(km/km^2)	0.25～0.94	168 802	79	0.673
	0.94～1.30	336 845	92	0.393
	1.30～1.57	881 350	432	0.705
	1.57～1.78	1 473 715	736	0.718
	1.78～1.99	1 679 346	988	0.846
	1.99～2.19	1 731 962	1 516	1.259
	2.19～2.43	1 299 212	1 462	1.618
	2.43～3.11	534 744	332	0.893
年均降雨量(mm)	1165.59～1241.96	324 420	72	0.319
	1241.96～1286.97	589 744	305	0.744
	1286.97～1322.42	917 972	696	1.090
	1322.42～1356.52	1 041 859	995	1.373
	1356.52～1389.25	1 334 864	719	0.775
	1389.25～1420.61	1 431 781	830	0.834
	1420.61～1451.98	1481123	1 117	1.084
	1451.98～1513.35	984 213	903	1.319
岩性	变质岩	1 999 089	1 062	0.764
	沉积岩	5 166 786	2 690	0.749
	岩浆岩	940 101	1 885	2.883
NDVI	0～0.11	873 294	767	1.263
	0.11～0.24	1 393 906	1 013	1.045
	0.24～0.34	1 565 525	1 176	1.080
	0.34～0.45	1 428 263	939	0.945
	0.45～0.56	1 143 230	707	0.889
	0.56～0.69	873 301	582	0.958
	0.69～0.85	501 966	314	0.900
	0.85～1	326 491	139	0.612

2.4.1　地形地貌因子　通过借助 ArcGIS 10.2 平台,从 DEM 中提取高程、坡度、平面曲率、剖面曲率、地形起伏度及高程变异系数等地形地貌因子.如图 3 与表 1 所示,武宁县高程介于 57～1 713 m,地势起伏显著,导致气候与植被分布呈明显空间分异.高程 57.15～596.05 m、坡度 12.05°～32.74°区间,FR>1,表明低海拔与中等坡度利于滑坡发生.平面曲率和剖面曲率分别反映了地表在水平平面、垂直平面上的不规则程度.当平面曲率介于 0～51.12 m^{-1}且剖面曲率大于 2.85 m^{-1}时,FR>1,说明该组合地形有利于滑坡发育.地形起伏度表征地表复杂性,其值为 44.21～142.11 m 时滑坡概率较高.

2.4.2　水文环境因子　水文环境因子是孕育滑坡的重要因素,本研究选取河网密度、年均降雨量和地形湿度指数等因子来反映水文条件对滑坡孕育的影响.通过图 4 和表 1 可知,河网密度较高区域滑坡频次更高.年均降雨量决定地表径流与地下水补给,反映区域水资源禀赋;武宁县超 65% 的滑坡栅格集中于 1 286.97～1 356.52 mm 与 1 420.61～1 513.35 mm 区间,表明适宜的降雨更利于滑坡发育.地形湿度指数是评估地表湿润程度和水体分布的重要参数,当其值介于 2.40～5.51 之间,FR>1,证明适当的地表湿度对滑坡发育具有促进作用.

2.4.3　地表覆盖因子　地表覆盖因子反映地表物体空间分布特征,是滑坡形成的关键条件.本研究选取 NDVI、总辐射及路网密度表征其对滑坡发育的影响.NDVI 表示区域内植被覆盖情况,如图 5 和

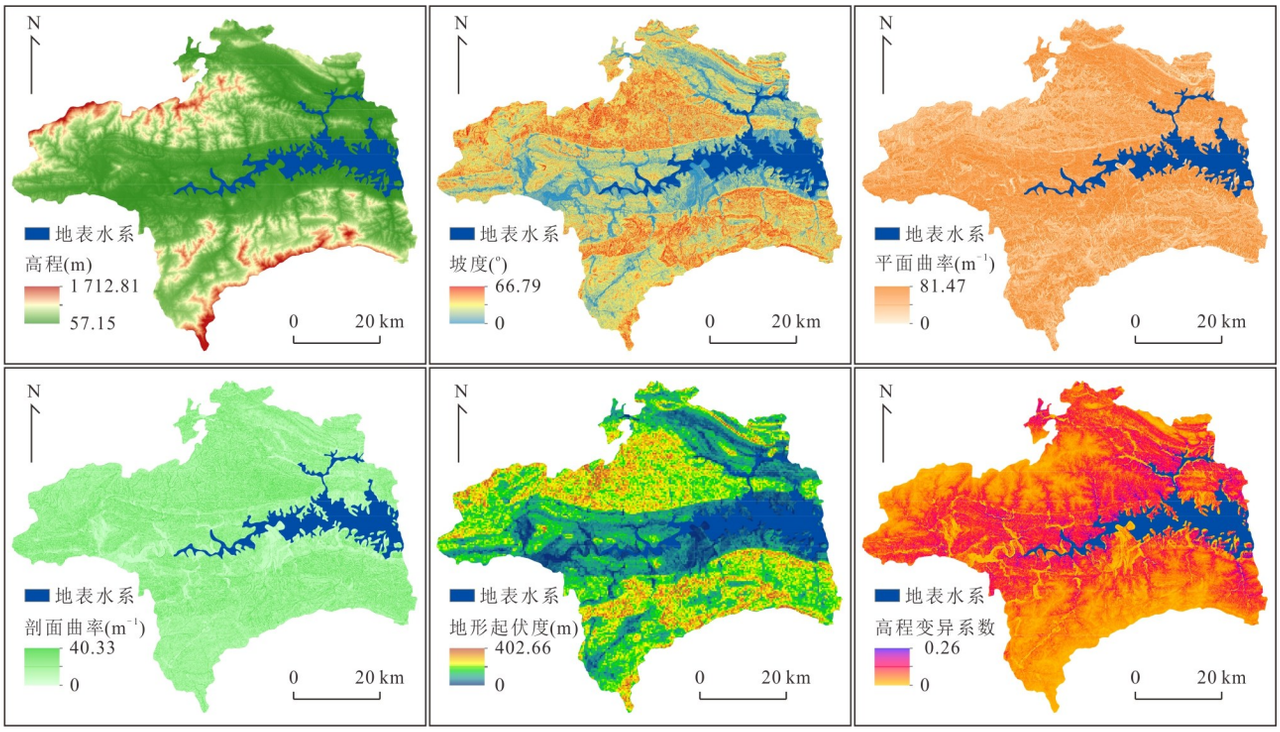

图 3 武宁县部分地形地貌因子

Fig.3 Partial topographic and geomorphic factors in Wuning County

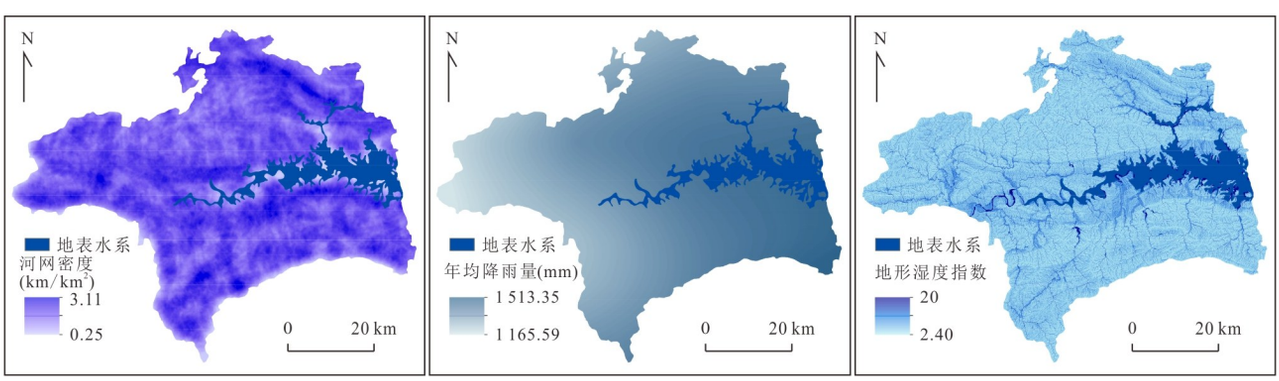

图 4 武宁县部分水文环境因子

Fig.4 Partial hydrological environmental factors in Wuning County

表 1 所示，当其值介于 0～0.34 范围内时，$FR>1$，植被覆盖密度较低的区域更易发生滑坡现象．总辐射是衡量某一区域地表接受太阳能量的定量指标，当其值处在 180.43～228.32 范围内时，$FR>1$，因高辐射致土温升高、土壤含水量降低，抗剪强度减弱，从而推动了滑坡的形成和发展．此外，超 85% 的滑坡栅格集中于路网密度 0.47～5.06 km/km^{2}区间，且 FR 随路网密度增加而上升，表明高密度路网可通过加剧人为扰动，提升滑坡发生概率．

2.4.4 地层岩性因子 本研究基于 1∶250 万地质图，将岩性按三大岩类进行划分．地层岩性反映研究区岩性分布与地质属性，显著影响滑坡发生频率与规模．作为地质环境关键组分，岩石是滑坡演化必要条件．研究区岩性多样、分布不均，涵盖沉积岩、变质岩和岩浆岩三大类，如图 5 和表 1 所示．武宁县岩浆岩区域的 $FR=2.883$，表明其在强降雨与河流侵蚀作用下更易促发滑坡；而变质岩与沉积岩区 $FR<1$，滑坡发生概率较低．断层密度表征地质构造发育程度，与地表稳定性密切相关．当断层密度值处于 0.06～0.20 km/km^{2}或 0.32～0.38 km/km^2 范围时，$FR>1$，该区域为滑坡现象高发区．

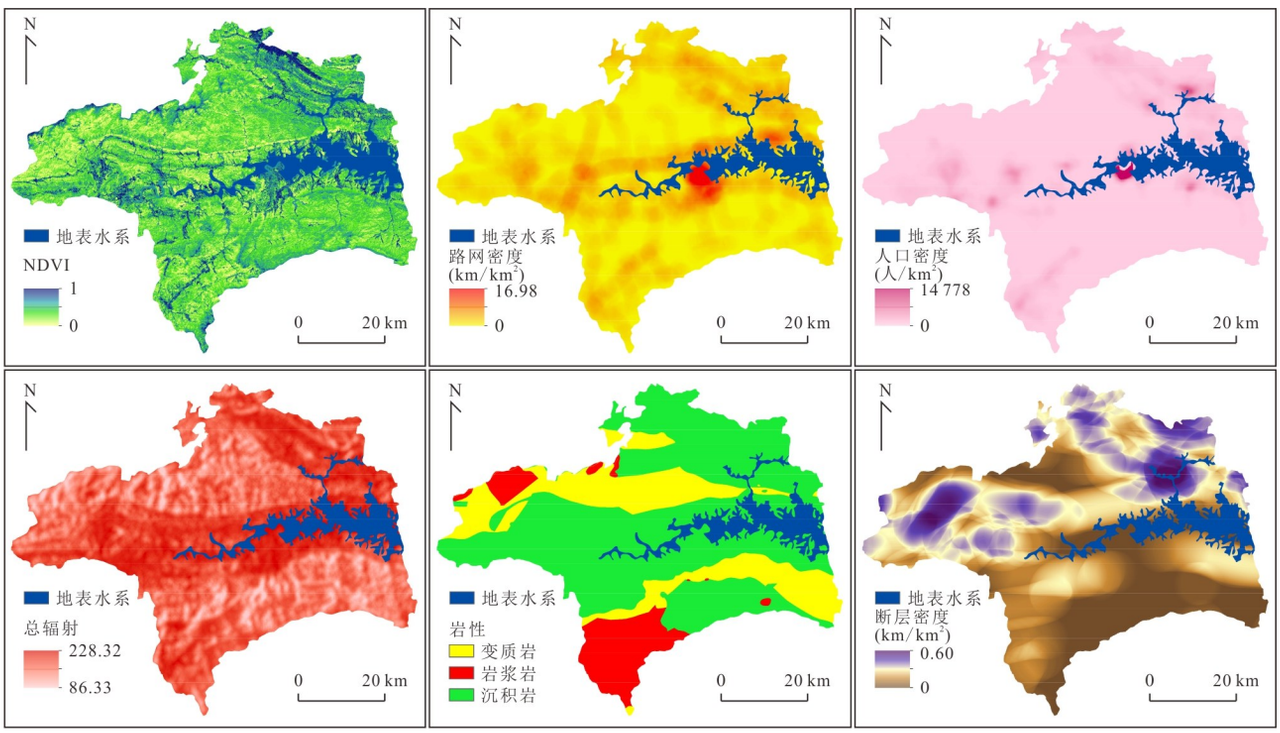

图5　武宁县部分地表覆盖因子和地层岩性因子

Fig.5　Partial surface cover and stratum lithology factors in Wuning County

3　不同样本优化策略下的滑坡易发性结果

3.1　数据准备

基于武宁县滑坡编录资料、GIS数据及遥感影像,将研究区划分为8 105 976个栅格单元,其中滑坡样本栅格5 637个.为构建监督XGBoost模型,从非滑坡区随机选取5 637个非滑坡样本,形成平衡数据集.

在构建半监督XGBoost模型时,依据监督模型输出的初始易发性分区,剔除低易发区与极低易发区内的滑坡样本,最终保留滑坡样本5 028个;随后,在极低易发区内按1∶1, 1∶2, …, 1∶220的比例逐级增加非滑坡样本,构建系列非平衡数据集.其中,比例上限1∶220的设定,一方面参照了黄发明等(2025)在江西寻乌－安远县及Huang *et al.*(2024)在九江市的探索性实验结果.另一方面,基于本研究区先期预实验,当非滑坡样本比例增至1∶220附近时,AUC值已呈下降趋势并趋于平稳,故以此作为本实验的比例上限.

3.2　致灾环境因子多重共线性检验

为避免各致灾环境因子间存在高度相关性导致模型分类模糊及预测精度下降,在滑坡易发性建模前,需对19项环境因子进行多重共线性检验.本研究采用方差膨胀因子(Variance Inflation Factor, VIF)与容忍度(Tolerance, TOL)作为诊断指标.当VIF＞10或TOL＜0.1时,表明该因子共线性严重,应予剔除(郑迎凯等,2020).如表2所示,所有因子的VIF均小于10、TOL均大于0.1,不存在显著的共线性问题,19项因子均可用于后续建模.

3.3　滑坡易发性建模

基于Python 3.9.7编程语言,采用二分类方法构建监督XGBoost均衡样本模型,用于滑坡易发性预测.以19个环境因子的频率比值为输入变量,5 637个滑坡与等量非滑坡样本分别标记为“1”和“0”作为输出变量,按7∶3随机划分训练集与测试集,并结合交叉验证评估性能.模型参数设置如下:n_estimators＝600, learning_rate＝0.4, gamma＝3, max_depth＝5.

在监督模型基础上继续构建常规半监督XGBoost模型.将优化后的5 028个滑坡样本与不同比例非滑坡样本分别标记为“1”和“0”,同法划分数据并交叉验证.该策略虽提升样本稳定性,但易导致滑坡样本减少、非滑坡选择受限,增加过拟合与噪声风险,故微调参数增强鲁棒性:n_estimators＝600保持不变,learning_rate、gamma、max_depth分

别调至 0.42、3.2、4.

针对半监督非对称 XGBoost 模型，将监督模型输出的初始易发性指数直接赋值给非滑坡样本（如某单元初值为 0.06，则以该值替代原标签“0”），滑坡样本仍标为“1”. 常规半监督模型适用于二分类任务，半监督非对称模型则通过将非滑坡标签替换为连续型初始易发性指数，实现建模任务由分类向回归转换. XGBoost 可为两类任务提供统一建模框架，模型集成机制与梯度提升策略一致，仅损失函数存在差异. 由此可知，两种建模策略的性能差异主要源于标签信息量的不同，而非模型结构差异. 回归输出的连续预测值通过 Sigmoid 函数归一化至 [0，1] 区间：

$$\sigma(x)=\frac{1}{1+e^{-x}}, \tag{7}$$

式中：x 为模型原始输出. 归一化后的数值与易发性指数物理意义兼容，可直接用于后续分级分区.

表 2 致灾环境因子多重共线性检验

Table 2 Test for multicollinearity of disaster-causing environmental factors

环境因子	TOL	VIF
高程	0.862	1.160
坡度	0.776	1.289
坡向	0.723	1.383
剖面曲率	0.926	1.080
平面曲率	0.806	1.241
地形起伏度	0.759	1.318
坡形	0.881	1.135
岩性	0.741	1.350
断层密度	0.876	1.142
NDVI	0.902	1.108
年均降雨量	0.708	1.413
总辐射	0.812	1.232
人口密度	0.661	1.514
路网密度	0.697	1.436
地形湿度指数	0.764	1.310
高程变异系数	0.844	1.185
坡位	0.931	1.074
河网密度	0.827	1.209
流向	0.734	1.363

3.4 滑坡易发性预测结果

基于不同样本优化策略构建的数据集，采用 XGBoost 模型对研究区栅格单元进行滑坡易发性预测，并在 ArcGIS 10.2 中可视化易发性指数. 所有结果均按自然断点法分为 5 级：极低、低、中、高、极高，具体建模结果如图 6～8 所示.

3.4.1 监督模型滑坡易发性预测 由监督模型生成的研究区滑坡易发性预测区划图及易发性指数分布图（图 6）可见，低与极低易发区面积最大，极高易发区面积最小且空间集聚. 表 3 列出了各易发性等级对应的栅格数、滑坡栅格数及其 FR 值. 结果显示，极低、低、中、高、极高易发区占研究区面积比例分别为 31.8%、24.5%、19.5%、15.3% 和 9.1%；FR 值随等级升高而递增，其中高、极高易发区 FR 值分别为 1.738 和 5.364，均大于 1. 上述结果表明，监督模型分区符合“高和极高易发区 FR 值高、面积占比小”的实际规律. 结合图 3、图 5 与表 1 可知，高与极高易发区主要集中于研究区西部平原边缘过渡带及中南部低山丘陵区，海拔 100～700 m，坡度 10°～40°，NDVI 普遍低于 0.5，且人类活动频繁，整体契合滑坡发生的典型地质与环境条件.

3.4.2 常规半监督模型滑坡易发性预测 不同样

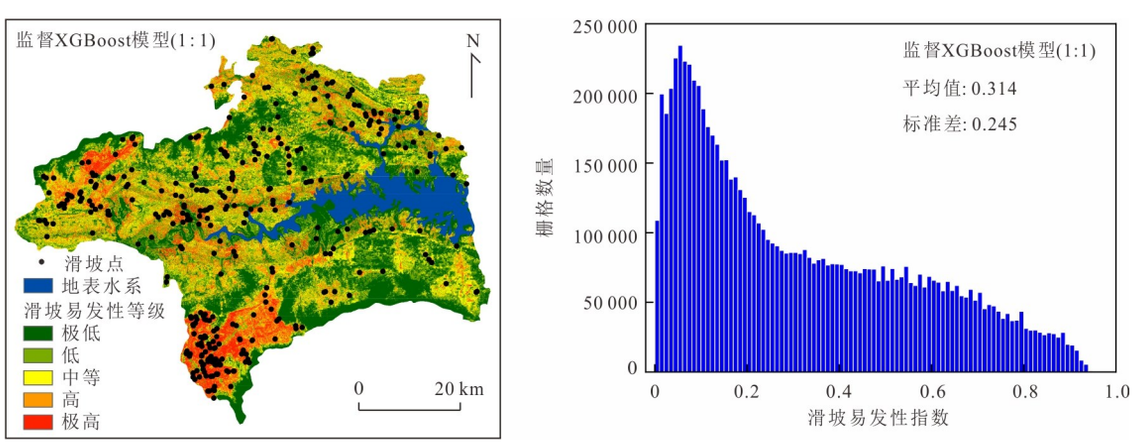

图 6 监督 XGBoost 模型的滑坡易发性区划及指数分布

Fig.6 Landslide susceptibility zoning and index distribution of supervised XGBoost model

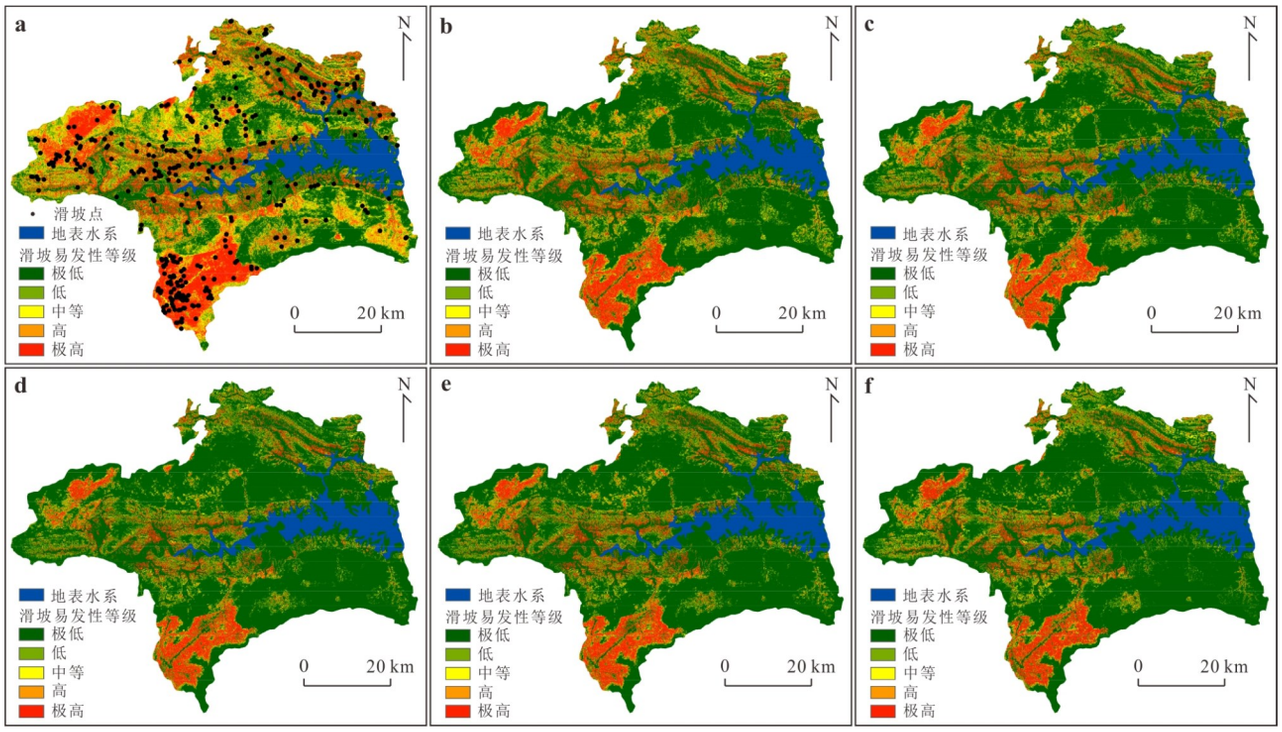

图 7　多样本比例下常规半监督 XGBoost 模型易发性区划

Fig.7　Susceptibility zoning of conventional semi-supervised XGBoost models under multiple sample proportions

a.常规半监督模型(1∶1);b.常规半监督模型(1∶10);c.常规半监督模型(1∶20);d.常规半监督模型(1∶60);e.常规半监督模型(1∶100);f.常规半监督模型(1∶140)

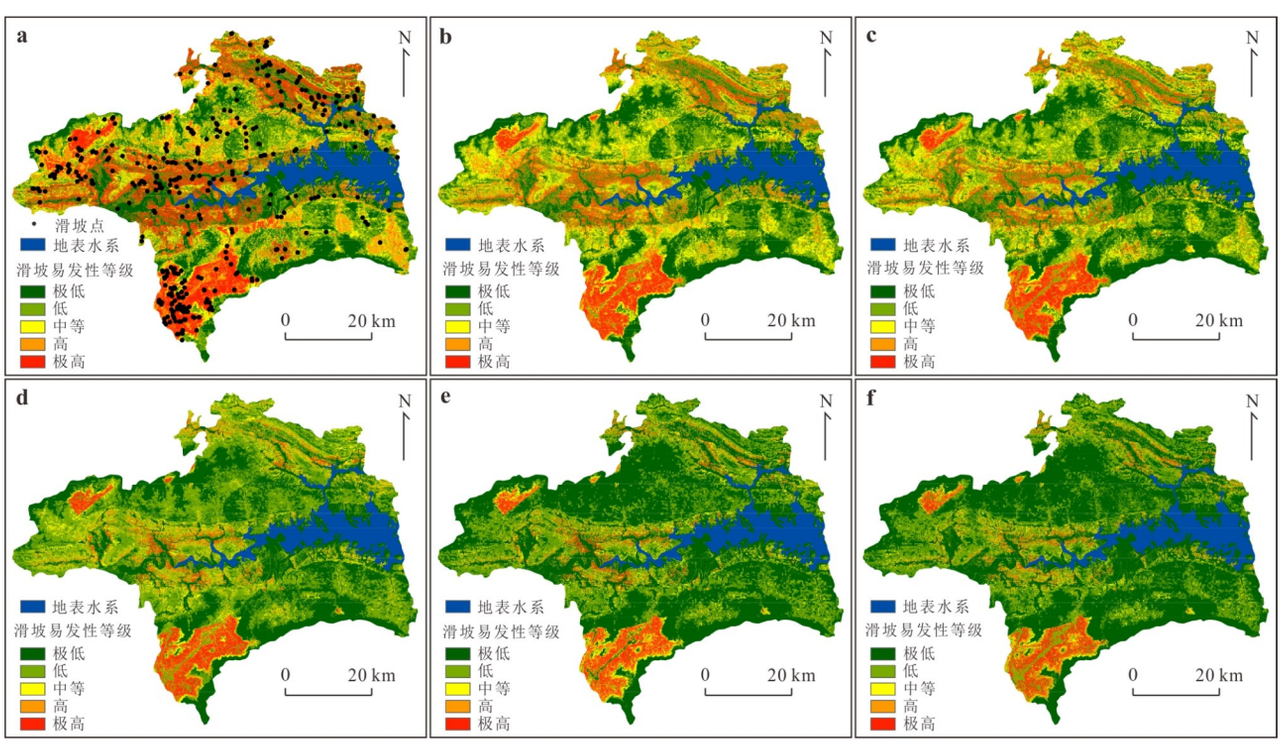

图 8　多样本比例下半监督非对称 XGBoost 模型易发性区划

Fig.8　Susceptibility zoning of semi-supervised imbalanced XGBoost models under multiple sample proportions

a.半监督非对称模型(1∶1);b.半监督非对称模型(1∶10);c.半监督非对称模型(1∶20);d.半监督非对称模型(1∶60);e.半监督非对称模型(1∶100);f.半监督非对称模型(1∶140)

表3 监督XGBoost模型的频率比值

Table 3 Frequency ratios of supervised XGBoost model

模型类型	分类	全区栅格数(个)	滑坡栅格数(个)	区域面积占比	频率比
监督XGBoost模型	极低	2 573 848	47	0.318	0.026
	低	1 985 111	268	0.245	0.193
	中等	1 576 047	1 092	0.195	0.992
	高	1 236 360	1 500	0.153	1.738
	极高	734 610	2 750	0.091	5.364

表4 多样本比例下两种半监督模型的频率比值

Table 4 Frequency ratios of two semi-supervised models under multiple sample proportions

滑坡/非滑坡比例	分类	常规半监督XGBoost模型			半监督非对称XGBoost模型		
		全区栅格数(个)	滑坡栅格数(个)	频率比	全区栅格数(个)	滑坡栅格数(个)	频率比
1:1	极低	2 811 548	9	0.005	2 166 237	43	0.032
	低	1 291 097	50	0.062	1915 729	41	0.035
	中等	1 080 929	436	0.650	1 109 767	478	0.694
	高	1 145 450	686	0.966	1 434 625	1 043	1.172
	极高	1 776 952	3 847	3.490	1 479 618	3 423	3.730
1:10	极低	5 182 426	148	0.046	2 348 159	88	0.060
	低	813 853	376	0.745	2 474 149	304	0.198
	中等	542 997	426	1.265	1 380 791	621	0.725
	高	557 430	860	2.487	1 194 996	1 708	2.304
	极高	1 009 270	3 218	5.140	707 881	2 307	5.254
1:40	极低	5 832 980	468	0.129	3 117 285	50	0.031
	低	626 431	442	1.138	2 581 213	624	0.323
	中等	414 785	553	2.149	1 197 315	616	0.829
	高	418 689	761	2.930	645 258	1 456	3.638
	极高	813 091	2 804	5.560	564 905	2 282	6.513
1:100	极低	6 142 451	625	0.164	3 814 140	166	0.070
	低	555 572	492	1.428	2 744 212	799	0.469
	中等	367 254	582	2.555	680 152	400	0.948
	高	362 665	644	2.863	495 415	1 736	5.649
	极高	678 034	2 685	6.384	372 057	1 927	8.350
1:140	极低	6 176 092	909	0.237	3 902 291	171	0.071
	低	534 885	435	1.311	2 753 986	856	0.501
	中等	398 627	602	2.435	659 404	369	0.902
	高	392 509	744	3.056	456 543	1 733	6.120
	极高	683 863	2 338	5.512	333 752	1 899	9.173

本比例下常规半监督模型的滑坡易发性制图结果如图7所示.总体来看,随着非滑坡样本比例升高,易发性等级分布呈现显著的“两极分化”特征.具体而言,极低易发区面积在样本比例较低时迅速扩大,约1:40后趋于稳定;其余4类区域面积在比例增至1:10前明显减小,随后减缓并逐步稳定.表4展示了各比例下模型*FR*值变化及对应滑坡点分布特征.除极低易发区*FR*值保持稳定外,其余等级*FR*值均呈上升或波动趋势.其中,低、高易发区*FR*值在1:40前持续上升,随后分别于1:100和1:140趋于稳定;中、极高易发区*FR*值在1:100前显著升高,之后缓慢下降并趋于平稳.值得注意的是,当样本比例达1:40后,低易发区*FR*值超过1且持续缓慢上升,表明模型预测开始偏离实际滑坡规律.通过进一步分析模型在各易发性等级区间内历史滑坡点的分布情况可以发现,尽管各易发性等级

的FR值随样本比例的增加而上升,但高与极高易发区内的滑坡点占比却持续下降,说明增加非滑坡样本可能削弱模型对非集中滑坡单元的识别能力.此外,对比图7与图6还可以看出,常规半监督模型识别的极高和高易发区虽仍集中于监督模型的核心区域,但覆盖面积显著缩减.

3.4.3　半监督非对称模型滑坡易发性预测　在半监督非对称模型下,随非滑坡样本比例增加,各易发性等级的面积及FR值变化趋势呈现显著差异,如图8和表4所示.当样本比例为1:1时,高、极高易发区面积均大于中易发区,偏离了滑坡易发性等级"由高到低递减"的分布规律;但随着非滑坡样本增加,二者面积快速缩减.当样本比例达到1:140时,二者合计约占研究区总面积9.7%,对应FR值亦达到峰值.中等易发区面积在比例上升前期缓慢扩大,1:40后逐步下降,其FR值最终稳定在0.9左右.极低、低易发区面积持续扩大后,于1:140左右趋于稳定,FR值分别维持在0.03~0.08和0.03~0.50区间.此外,高、极高易发区内历史滑坡点占比呈"先降后升"趋势,最终稳定在0.73左右;其空间分布亦随比例增大而逐渐集中于南部山区,在中西部平原与丘陵地带呈零星分布.

与监督模型和常规半监督模型相比,半监督非对称模型的易发性等级面积分布随比例增加更趋合理:极低与低易发区面积逐步扩大,中、高、极高易发区则持续缩小,整体空间离散性增强,更真实地反映各环境因子对全区滑坡易发性的综合影响.同时,半监督非对称模型中FR值的分布规律也优于其他两种模型,展现出更强的预测合理性与稳定性.

4　建模结果不确定性分析

4.1　ROC精度评价

为评估XGBoost模型在不同样本优化策略下的预测性能,本研究采用ROC曲线及其对应的AUC值进行验证,结果如图9和表5所示.当滑坡与非滑坡样本比例为1:1时,常规半监督与半监督非对称模型的AUC值最低,分别为0.926和0.923;监督模型AUC仅为0.869,显著低于二者,表明引入半监督学习策略能够有效提升模型在滑坡易发性预测任务中的准确性.随非滑坡样本比例增加,两类半监督模型AUC整体呈缓慢上升趋势;当样本比例达1:10后,半监督非对称模型AUC超越常规模型,并持续保持优势;当比例达至1:140时,2种模型均达到峰值,分别为0.981和0.956.然而,随着非滑坡样本比例的进一步扩大,两者的AUC值均略有下降.同时,在原始不平衡测试集下,各模型AUC的变化趋势与平衡子集法结果高度一致,最优样本比例均为1:140,且同一模型同一比例下,两种评估方式所得的AUC数值偏差均不超过0.002,表明平衡子集法在本研究中未引入显著的评估偏倚.综合分析上述结果可知,优化样本比例并改进标签赋值方式,有助于提升模型对滑坡与非滑坡单元的整体识别能力.

4.2　频率比精度对比分析

不同样本优化策略下各XGBoost模型的频率比精度如表5所示.当滑坡与非滑坡样本比例为1:1时,半监督非对称模型的精度值最高,达到0.866;其次是常规半监督模型和监督模型,其精度值分别为0.861和0.854.常规半监督模型的频率比精度随非滑坡样本比例增加持续下降,当样本比例为1:140时其降至0.682,表明单纯增加非滑坡样本不仅无法提升精度,反而因极低易发区面积显著扩张而削弱对滑坡单元的识别能力.然而,半监督非对称模型的频率比精度则随非滑坡样本数量的增加呈现持续上升趋势,并在1:140左右趋于稳定,此时精度值达到0.912.综上所述,改进后的半监督模型频率比精度始终优于常规模型,说明经过标签赋值优化的半监督模型能够更准确地识别滑坡发生区域,具有更低的不确定性.

4.3　混淆矩阵相关指标分析

通过计算不同优化策略下样本与滑坡易发性指数的混淆矩阵,获取准确率与特异性两个关键评估指标,用于分析模型分类误差.由表5可知,当滑坡与非滑坡样本比例为1:1时,常规半监督模型展现出较高的准确率与特异性,分别为0.900和0.904,高于半监督非对称模型的0.887和0.896,而监督模型的准确率与特异性最低,分别仅为0.802和0.763.随非滑坡样本比例增加,两类半监督模型的准确率与特异性均持续上升,并于1:140时均达0.99以上.由此,两类半监督模型的分类准确性显著优于监督模型;同时,适当增加非滑坡样本比例可进一步降低误差、提升预测性能.然而,本研究的标签赋值改进策略可能在一定程度上延缓了分类准确性随比例增长的上升趋势.

4.4　易发性指数分布特征

随着非滑坡样本比例的扩大,两类半监督模型

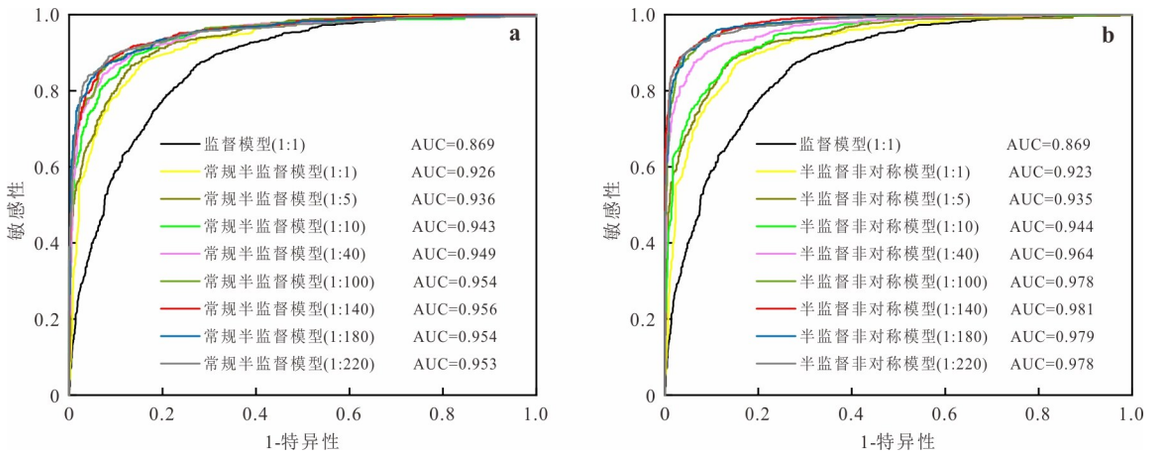

图 9 监督及两种半监督 XGBoost 模型在多样本比例下的 ROC 曲线

Fig.9 ROC curves of supervised and two semi-supervised XGBoost models under multiple sample proportions

表 5 各建模方法下预测精度及易发性分布特征

Table 5 Prediction accuracy and susceptibility distribution characteristics under each modeling method

模型类型	滑坡/非滑坡比例	平衡子集 AUC	原始 AUC	频率比精度	准确率	特异性	均值	标准差
监督 XGBoost 模型	11	0.869	0.869	0.854	0.802	0.763	0.245	0.314
常规半监督 XGBoost 模型	1:1	0.926	0.926	0.861	0.900	0.904	0.352	0.429
	1:5	0.936	0.936	0.818	0.942	0.946	0.249	0.396
	1:10	0.943	0.942	0.788	0.962	0.966	0.224	0.337
	1:20	0.946	0.945	0.754	0.975	0.977	0.198	0.327
	1:40	0.949	0.948	0.713	0.984	0.985	0.175	0.315
	1:60	0.951	0.950	0.695	0.990	0.991	0.161	0.304
	1:100	0.954	0.952	0.690	0.991	0.993	0.152	0.294
	1:140	0.956	0.954	0.682	0.992	0.995	0.146	0.289
	1:180	0.954	0.954	0.689	0.992	0.996	0.146	0.288
	1:220	0.953	0.952	0.687	0.991	0.995	0.147	0.288
半监督非对称 XGBoost 模型	1:1	0.923	0.923	0.866	0.887	0.896	0.508	0.262
	1:5	0.935	0.934	0.875	0.932	0.942	0.385	0.232
	1:10	0.944	0.942	0.885	0.958	0.961	0.337	0.211
	1:20	0.953	0.952	0.889	0.972	0.973	0.286	0.182
	1:40	0.964	0.962	0.895	0.980	0.981	0.233	0.153
	1:60	0.971	0.970	0.900	0.986	0.987	0.215	0.142
	1:100	0.978	0.976	0.904	0.990	0.992	0.190	0.135
	1:140	0.981	0.979	0.912	0.991	0.994	0.183	0.131
	1:180	0.979	0.978	0.916	0.992	0.995	0.183	0.130
	1:220	0.978	0.977	0.915	0.992	0.995	0.182	0.130

的易发性指数均值与标准差变化趋势基本一致，具体结果见图 6、图 10、图 11 和表 5. 当样本比例为 1:1 时，监督模型下的易发性指数均值最小，为 0.314；常规半监督与半监督非对称模型均值更高，分别为 0.352 和 0.508. 此时，常规半监督模型标准差最大，达到 0.429，其次为半监督非对称模型的 0.262 和监督模型的 0.245. 随非滑坡样本比例持续增加，两类半监督模型均值稳步下降，至 1:140 时分别收敛于 0.146 和 0.183；标准差亦逐步降低，并于 1:140 时趋于稳定，分别达至 0.289 和 0.131. 根据上述结果可知，随着非滑坡样本比例的不断增大，常规半监督模型的均值显著下降，标准差仍维持较高水平，两

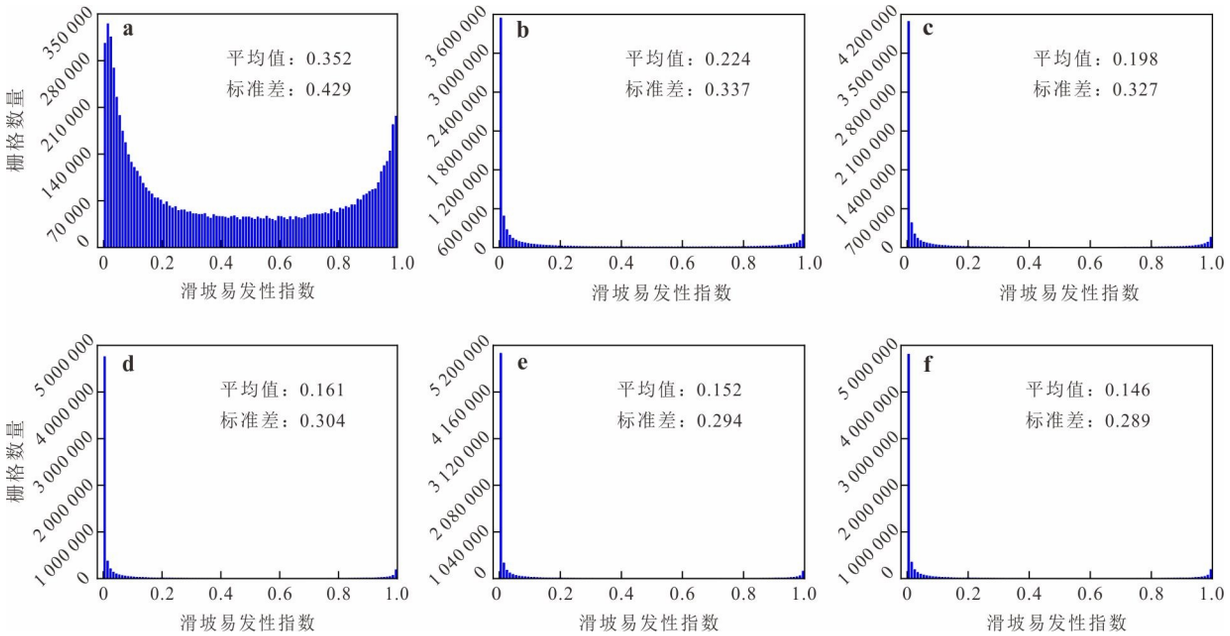

图 10　多样本比例下常规半监督 XGBoost 模型易发性指数分布

Fig.10　Susceptibility index distribution of conventional semi-supervised XGBoost models under multiple sample proportions

a.常规半监督模型(1∶1)；b.常规半监督模型(1∶10)；c.常规半监督模型(1∶20)；d.常规半监督模型(1∶60)；e.常规半监督模型(1∶100)；f.常规半监督模型(1∶140)

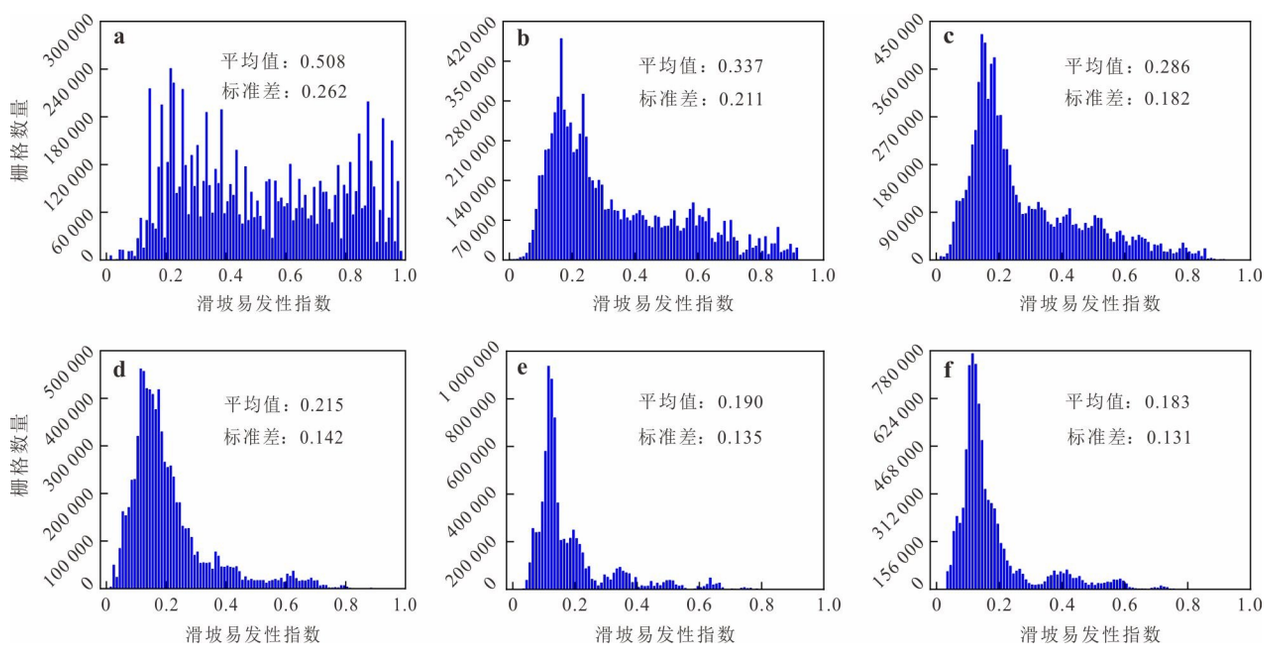

图 11　多样本比例下半监督非对称 XGBoost 模型易发性指数分布

Fig.11　Susceptibility index distribution of semi-supervised imbalanced XGBoost models under multiple sample proportions

a.半监督非对称模型(1∶1)；b.半监督非对称模型(1∶10)；c.半监督非对称模型(1∶20)；d.半监督非对称模型(1∶60)；e.半监督非对称模型(1∶100)；f.半监督非对称模型(1∶140)

极分化愈加明显,其易发性建模结果已严重偏离实际滑坡的空间分布规律;相比之下,改进后的半监督模型促使易发性值更集中于极低与低易发区,空间离散性更优,更能准确反映指数真实空间分布,有效降低不确定性.

4.5　不确定性问题的敏感性分析

为量化监督与半监督建模方法、非滑坡样本比例及标签值设定方式对滑坡易发性预测性能的影

响程度，本研究将这3项不确定性因素以“分类变量”的形式进行表示，如表6所示.随后计算其与易发性指数建模精度的相关系数，并求取各因素在所有分类变量组合下相关系数的绝对均值.该类指标可反映各不确定性因素对模型输出的敏感程度，具体数值见表7和表8.

由表7可见，建模方法的皮尔逊相关系数均值最高，达到0.870，表明其对预测精度的影响最为显著；其次为非滑坡样本比例，其相关系数均值为0.161，标签值设定方式的影响相对最小，相关系数均值为0.143.此外，非滑坡样本比例的相关系数随比例扩大而持续上升，表明其影响正逐步增强.

为验证上述结果的稳健性，进一步计算了各因素与AUC值的Spearman秩相关系数，结果列于表8.建模方法的秩相关系数绝对均值为0.866，样本比例为0.147，标签设定方式为0.169，三者敏感性排序与皮尔逊相关分析完全一致.其中，样本比例的秩相关系数同样由1∶1时的0.035升至1∶140时的0.344，呈现随比例递增的趋势.上述结果表明，敏感性分析结论不受相关性度量方法选择的影响，具有较好的稳健性.

表6 各不确定性因素与易发性建模精度之间的分类变量关系

Table 6 Categorical variable relationships between uncertainty factors and susceptibility modeling accuracy

建模方法		非滑坡样本比例				标签值设定方式		相关系数
监督	半监督	1∶1	1∶40	1∶100	1∶140	1/0	1/0-1	AUC值
1	0	1	0	0	0	1	0	0.869
1	0	0	1	0	0	1	0	0.895
1	0	0	0	1	0	1	0	0.906
1	0	0	0	0	1	1	0	0.911
1	0	1	0	0	0	0	1	0.837
1	0	0	1	0	0	0	1	0.853
1	0	0	0	1	0	0	1	0.861
1	0	0	0	0	1	0	1	0.865
0	1	1	0	0	0	1	0	0.926
0	1	0	1	0	0	1	0	0.949
0	1	0	0	1	0	1	0	0.954
0	1	0	0	0	1	1	0	0.956
0	1	1	0	0	0	0	1	0.923
0	1	0	1	0	0	0	1	0.964
0	1	0	0	1	0	0	1	0.978
0	1	0	0	0	1	0	1	0.981

5 讨论

5.1 半监督学习下不同样本比例的滑坡易发性建模

5.1.1 不同样本比例下各模型结果对比 监督模型虽可满足滑坡易发性预测基本需求，但在易发性指数空间分布规律的刻画精度上仍有提升空间.为此，本研究构建半监督非对称XGBoost模型，同步优化滑坡与非滑坡样本，并与传统监督模型对比.结果表明，半监督模型各项评估指标整体更优，与Shua *et al.*(2024)结论基本一致：其基于XGBoost的半监督模型在AUC、准确率等方面显著提升，易发性空间分布更合理，且证实非滑坡样本数量是关键影响因素.由此可见，半监督学习能有效增强正负样本识别能力，其通过剔除误分类样本、利用高质量样本训练，显著提升滑坡与非滑坡区域判别精度，故建模方法对降低预测不确定性作用最显著.

表7 各不确定性因素与易发性建模精度之间的皮尔逊相关系数

Table 7 Pearson correlation coefficients between uncertainty factors and susceptibility modeling accuracy

不确定性问题		建模方法		标签值设定方式		非滑坡样本比例			
		监督	半监督	1/0	1/0-1	1∶1	1∶40	1∶100	1∶140
相关系数	绝对值	0.870	0.870	0.143	0.143	0.013	0.133	0.177	0.323
	平均值	0.870		0.143		0.161			

表8 各不确定性因素与易发性建模精度之间的Spearman秩相关系数

Table 8 Spearman rank correlation coefficients between uncertainty factors and susceptibility modeling accuracy

不确定性问题		建模方法		标签值设定方式		非滑坡样本比例			
		监督	半监督	1和0	1和0-1	1∶1	1∶40	1∶100	1∶140
相关系数	绝对值	0.866	0.866	0.147	0.147	0.035	0.124	0.174	0.344
	平均值	0.866		0.147		0.169			

当采取滑坡与非滑坡样本比例为1∶1建模时,半监督模型预测精度虽显著提升,但该比例与野外实际空间分布不符,既未充分考虑非滑坡样本数量对建模结果的影响,又与实际地质场景的客观规律相悖,易造成局部区域滑坡概率被严重高估(Yang *et al.*,2023).本研究中,1∶1比例下易发性指数整体偏高,呈明显二元分化,极低与极高易发区面积异常扩大,部分非滑坡被误判为滑坡,加剧不确定性.因此,需系统探索适配研究区的最优非滑坡样本比例.

由前文建模结果不确定性分析可知,随非滑坡样本增加,半监督学习模型的AUC值及混淆矩阵各项指标整体上升,并在比例为1∶140时趋于稳定.这源于非滑坡样本增多有效降低了其被误判为滑坡的概率,使识别出的滑坡区更具空间聚集性,样本区分能力显著增强.Huang *et al.*(2024)在半监督RF模型中将比例由1∶1增至1∶200,发现精度持续提升并在1∶180达最优,与本研究趋势一致.同时,两项研究均表明,当比例进一步增大,精度微降、分区合理性减弱,可能因非滑坡样本饱和,导致模型过度学习其特征,削弱对真实滑坡的识别,部分滑坡被划入极低易发区,从而降低模型稳定性与可靠性.

5.1.2　样本比例对模型影响性分析　为进一步探究半监督非对称模型在不同样本比例下对滑坡演化机制的影响,本研究采用SHAP、积分梯度法与部分依赖图开展因子作用解析.基于SHAP结果,绘制各比例下前10位环境因子贡献图,如图12所示.结果显示,在不同样本比例条件下,年均降雨量、地形起伏度、河网密度、坡度和高程始终位居前五.其中,年均降雨量是主导水文因子,河网密度为关键诱发因素;地形起伏度、高程与坡度呈显著负向贡献.过量降雨增加土体自重、降低抗剪强度、加速入渗,提高滑坡概率(Tang *et al.*,2024;申振宏等,2025);适度降雨则促进植被生长,增强根系固土能力.河网密度高区多属水系发育带,渗透强于侵蚀,

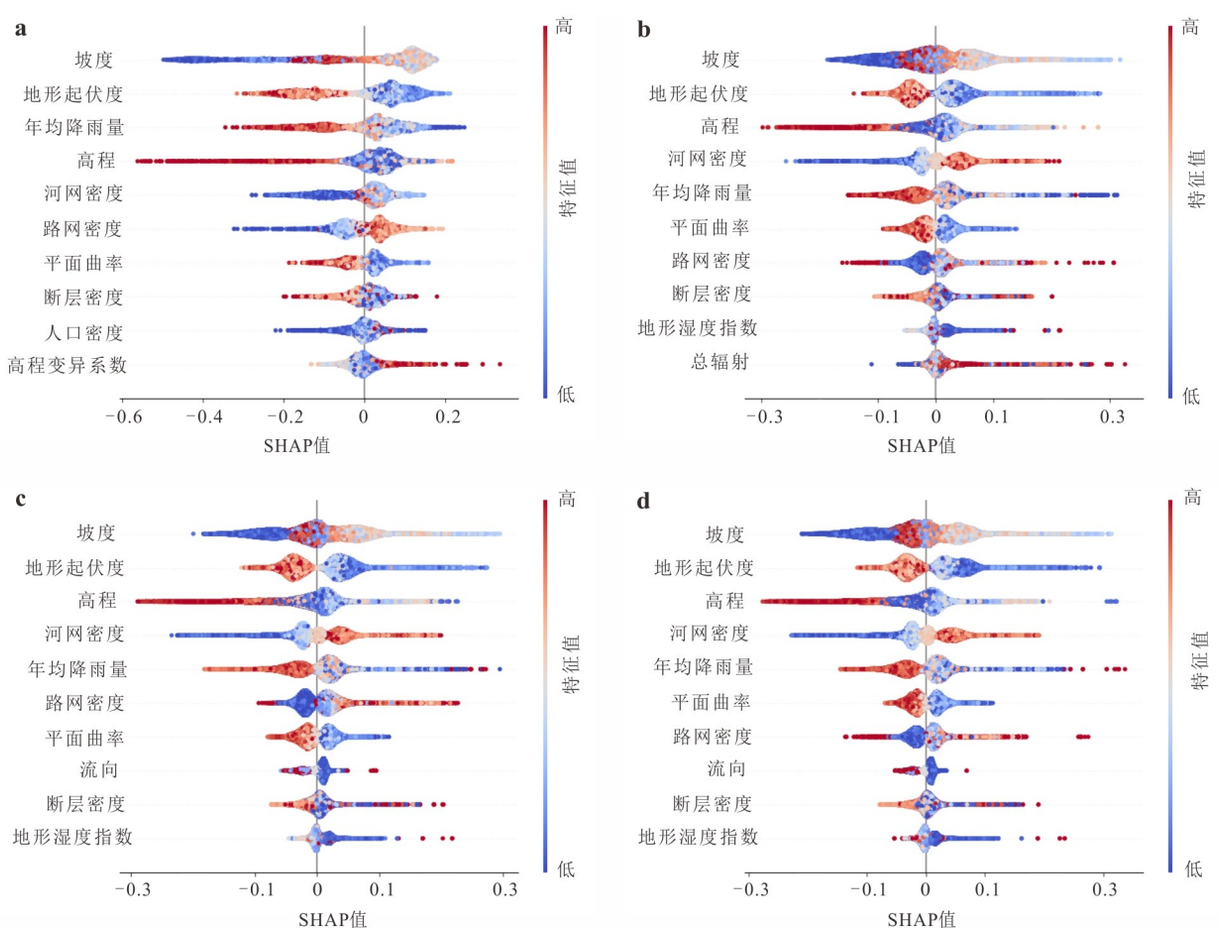

图12　多样本比例下半监督非对称XGBoost模型SHAP概要图

Fig.12　SHAP summary plots of semi-supervised imbalanced XGBoost models under multiple sample proportions

a.半监督非对称模型(1∶1);b.半监督非对称模型(1∶40);c.半监督非对称模型(1∶100);d.半监督非对称模型(1∶140)

易致土壤饱和、抗剪强度下降，促进滑移面形成（吴宏阳等，2023）.此外，坡度对滑坡的影响具有非线性特征，过低或过高均抑制滑坡物质积累与滑动面形成.中海拔区滑坡风险较高，主要原因是该区域人类活动频繁，如切坡建房、山林开垦等，这些行为改变了地质环境，削弱了边坡稳定性（郑德凤等，2024）.本研究中，武宁滑坡点主要集中于海拔 60～500 m、坡度 17°～32°的平原与低丘河谷地带；该区降雨充沛、地势平缓、地形起伏度小，易致地表排水不畅，使土体长期饱和，既增大自重又显著改变力学性质，最终形成有利孕灾环境（冯霄等，2022）.此外，岩性、断层密度等地层岩性类因子的全局 SHAP 贡献相对靠后，未进入前十，但该结果仅反映其在全局平均视角下被连续型主导因子稀释，并不表示该类因子对滑坡发育不重要.

积分梯度法从全局视角揭示了不同样本比例下各环境因子对滑坡发育的正负贡献程度（图 13）.当滑坡与非滑坡样本比例为 1∶1 时，地形地貌表现出较显著的正向贡献，积分梯度值为 0.301；水文环境与地表覆被因子则起主要抑制作用，对应的积分梯度值分别为 −0.231 和 −0.199.随非滑坡样本比例增大，各类因子的促进作用逐渐减弱.当样本比例达至 1∶140 时，地形因子转为显著抑制，总贡献度达 −0.763，其中坡度、地形起伏度和高程的负向贡献分别为 −0.286、−0.246 和 −0.201，与 SHAP 结果基本一致.滑坡点分布与地形因子具有较强空间一致性，且该耦合关系随非滑坡样本增加而强化——更多非滑坡样本有助于模型更准确学习其稳定分布模式，从而显著提升地形因子在特征空间中的决策权重，降低样本偏差引发的预测不确定性（Li and Tian，2025）.

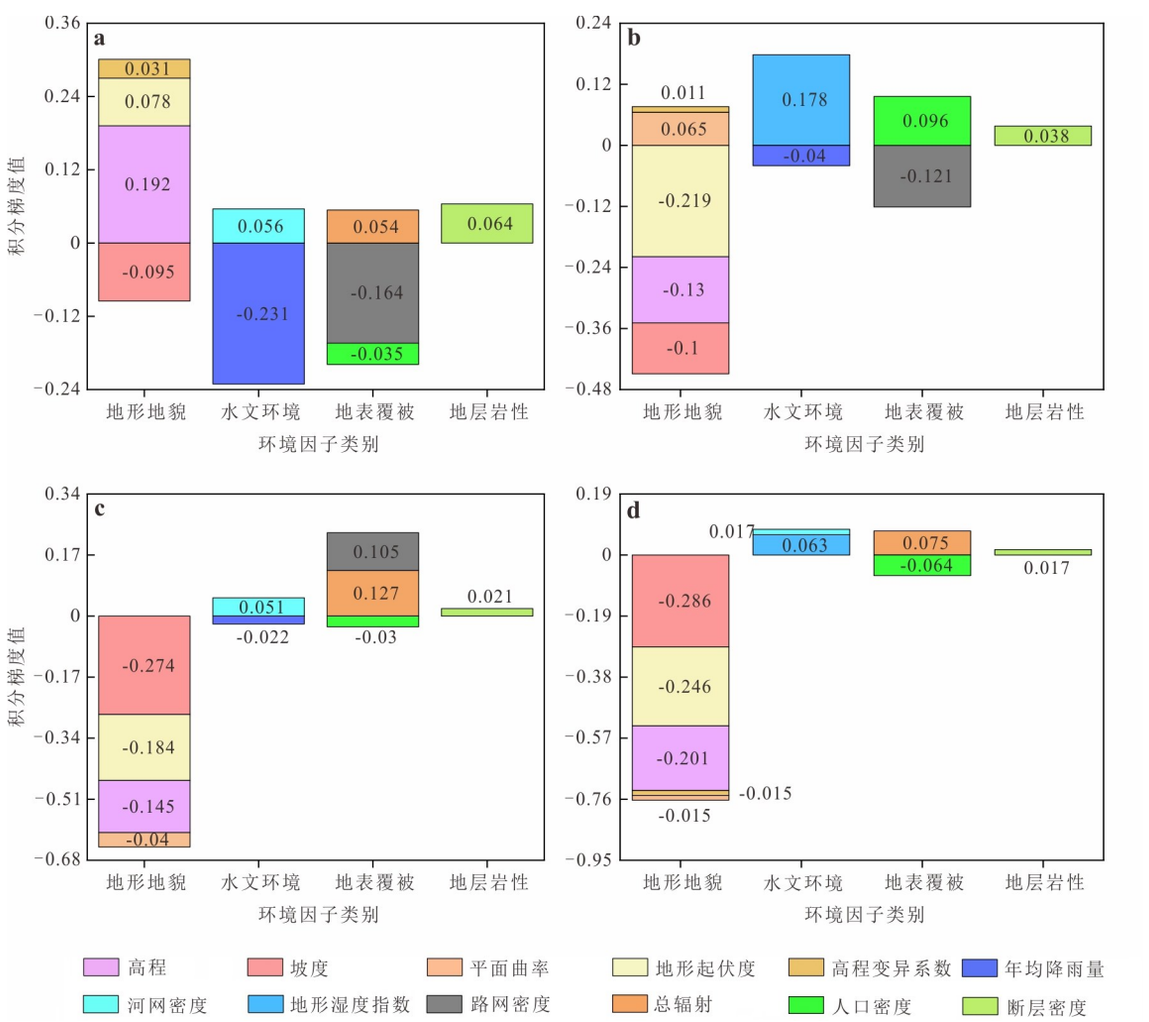

图 13 多样本比例下半监督非对称 XGBoost 模型积分梯度

Fig.13 Integral gradient plots of semi-supervised imbalanced XGBoost models under multiple sample proportions

a.半监督非对称模型（1∶1）；b.半监督非对称模型（1∶40）；c.半监督非对称模型（1∶100）；d.半监督非对称模型（1∶140）

高程与坡度是地形地貌的核心特征,不仅显著影响人类活动、植被演化及堆积层分布,其差异更直接改变土体应力与稳定性,进而主导滑坡孕育与发展(陆昊等,2025).因此,本研究选取二者作为示例,分析不同样本比例下双因子交互作用及其对滑坡易发性的影响,具体结果见图 14.本研究以易发性指数变化幅度超过 0.28 作为阈值,将高程与坡度协同作用最强烈的区间界定为“显著变化区”.当样本比例为 1∶1 时,显著变化区主要集中于高程 0～1 200 m、坡度 2°～30°范围内;然而,该区域含大量非滑坡样本,模型预测精度较低,易发性指数空间分布亦不合理.随非滑坡样本比例增大,显著变化区逐步收缩,并向“低海拔、中等坡度”聚集.至 1∶140 时,显著变化区仅集中于高程 60～480 m、坡度 17°～28°,该范围恰与该比例下极高和高易发区主体分布一致,且覆盖大部分滑坡点.

5.2　考虑标签值优化的滑坡易发性建模

以往基于机器学习的滑坡易发性建模研究常将非滑坡样本标签统一设为“0”,虽已成惯例,却忽略了非滑坡区域可能蕴含的潜在滑坡风险,从而影响模型预测的准确性与可信度.为此,本研究引入半监督非对称理论,构建半监督非对称模型,并与常规半监督模型开展不确定性对比分析,系统验证其建模优势.

根据前文分析可知,当滑坡与非滑坡样本比例低于 1∶10 时,半监督非对称模型尚未显现明显优势.原因在于该模型对非滑坡样本赋予非零标签,在负样本数量有限时易导致全区易发性指数整体偏高,少量非滑坡点被误判为滑坡,进而削弱模型性能;而此时,常规半监督模型对非滑坡样本的识别能力则相对较强.但随着非滑坡样本持续增加,半监督非对称模型对两类样本的区分能力及潜在滑坡识别能力显著提升,AUC 增速加快,频率比精

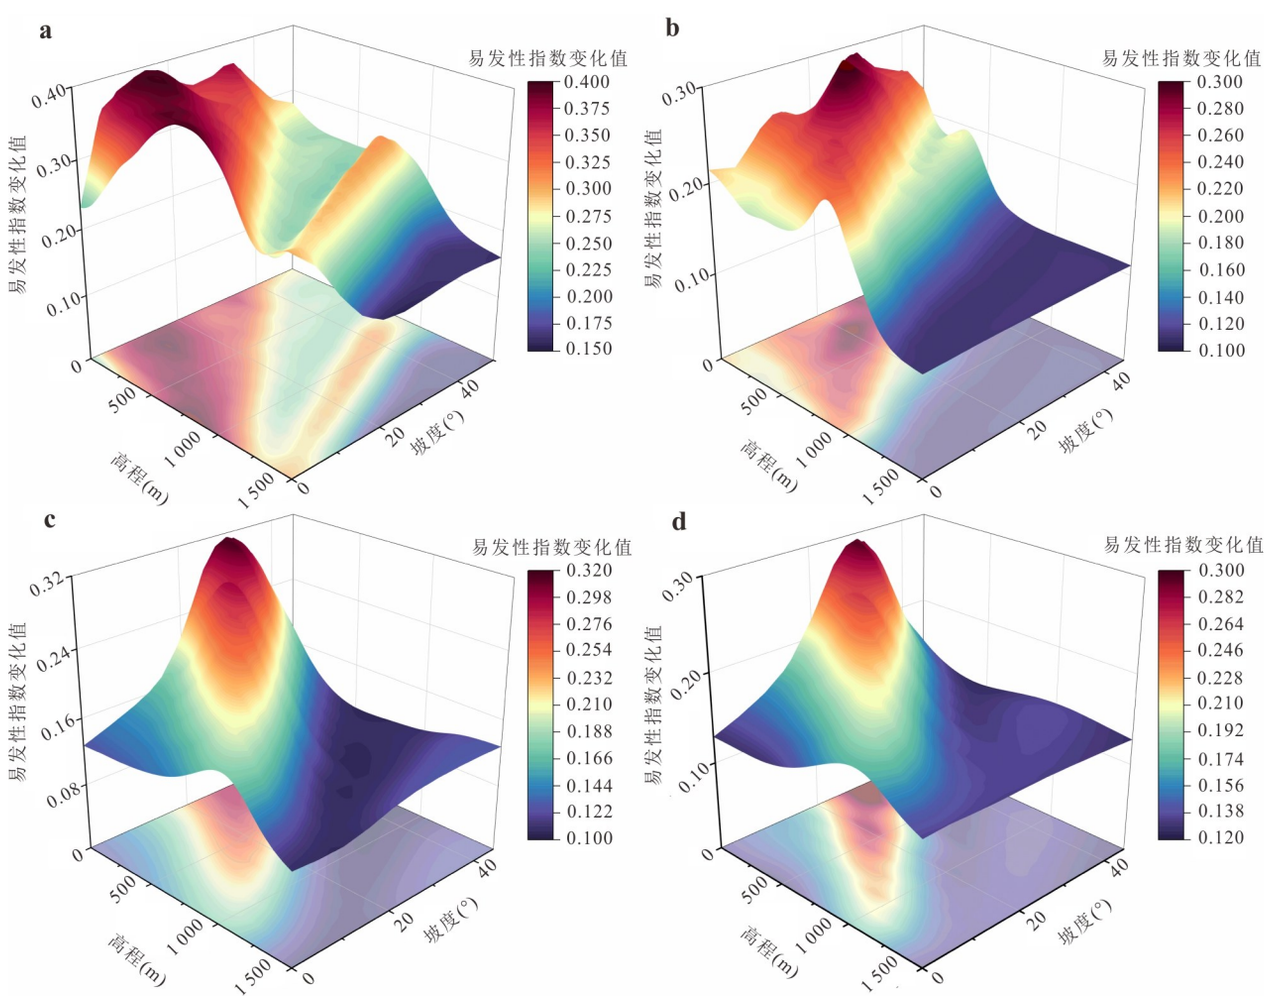

图 14　多样本比例下半监督非对称 XGBoost 模型高程与坡度交互 PDP 图

Fig.14　PDP of elevation-slope interaction for semi-supervised imbalanced XGBoost models under multiple sample proportions

a.半监督非对称模型(1∶1);b.半监督非对称模型(1∶40);c.半监督非对称模型(1∶100);d.半监督非对称模型(1∶140)

度持续上升，且逐步超越并拉开与常规模型的差距.相比之下，对于常规半监督模型而言，尽管增加非滑坡样本在一定程度上有助于提升整体识别能力，但当非滑坡比例过高时，其对滑坡样本的判别能力趋于下降，AUC增长趋缓，频率比精度甚至急剧降低.在易发性指数分布方面，半监督非对称模型的均值随非滑坡样本比例扩大逐渐下降，最终稳定于0.183；其易发性等级分布亦更趋合理：极低和低易发区面积逐步扩大并趋于稳定，极高、高易发区则持续缩减.该结果与熊浩文(2024)基于RF与半监督非对称框架的研究结论基本一致，印证了本研究样本赋值策略的有效性.

5.3 半监督非对称策略下的非滑坡样本选取区间的效果验证

在本研究初始阶段，于极低和低易发区按1∶1～1∶220的不同样本比例选取非滑坡样本，并结合半监督非对称策略建模.结果表明：各比例下的预测精度均有较大的提升空间，且易发性指数普遍偏高，集中于低至中易发等级，分区梯度模糊，风险识别能力不足，如图15，图16和表9所示.即使样本比例达1∶140，低至中易发区仍占全区约50%，违背“极低与低易发区应大面积分布”的实际规律.

调整策略为仅在极低易发区选取非滑坡样本后，模型性能显著优化.随非滑坡样本比例增加，各预测精度指标整体呈上升趋势，至1∶140时趋于稳定；此时，高和极高易发区面积缩减，中易发区分布更合理，极低和低易发区成为主体，如图8、图11和表5所示.与前一策略在最优比例1∶140下的结果相比，调整后的策略AUC值提升0.005、频率比精度提升0.012，准确率与特异性亦保持较高水平；易发性指数均值降至0.183，较前一策略降低0.053.该策略有效增强了模型对滑坡与非滑坡区域的区分能力，削弱了潜在滑坡风险样本对建模的干扰，从而提升了模型的整体预测能力.究其缘由，武宁县滑坡以小型为主，隐性风险区广泛；而极低易发区受地形、岩性及水文条件制约，滑坡发生所需地质力学条件普遍不充分，样本纯度高、代表性强，可避免将具潜在风险的“伪非滑坡样本”混入训练集，从而提升等级划分清晰度与风险识别精度.

实际应用中，需充分考虑研究区水文地质环境.若地质条件稳定、隐性风险易排查，可采用极低—低易发区混合采样；若滑坡样本丰富、地质复杂且隐性风险广泛，则应优先限定于极低易发区采样，以保障样本质量与预测精度.

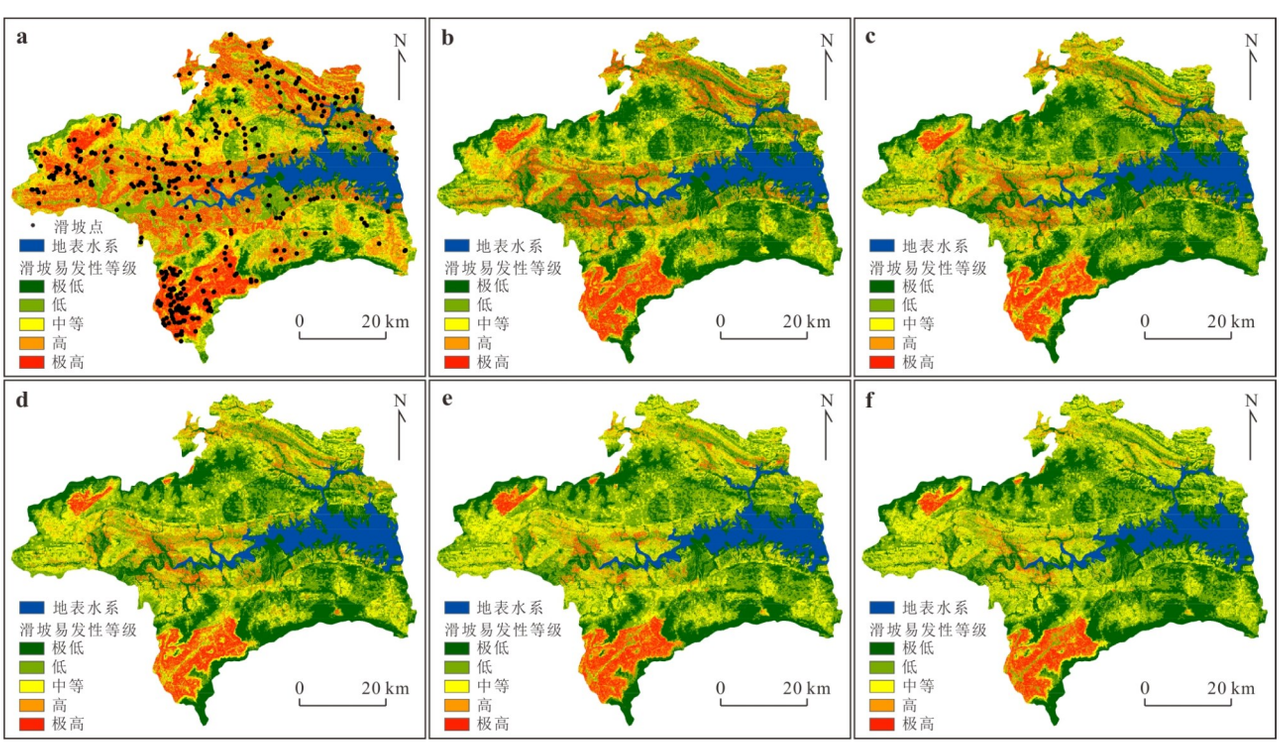

图15 多样本比例下半监督非对称XGBoost模型易发性区划(极低和低易发区采样)

Fig.15 Susceptibility zoning of semi-supervised imbalanced XGBoost models under multiple sample proportions (sampled from extremely low and low susceptibility areas)

a.半监督非对称模型(1∶1)；b.半监督非对称模型(1∶10)；c.半监督非对称模型(1∶20)；d.半监督非对称模型(1∶60)；e.半监督非对称模型(1∶100)；f.半监督非对称模型(1∶140)

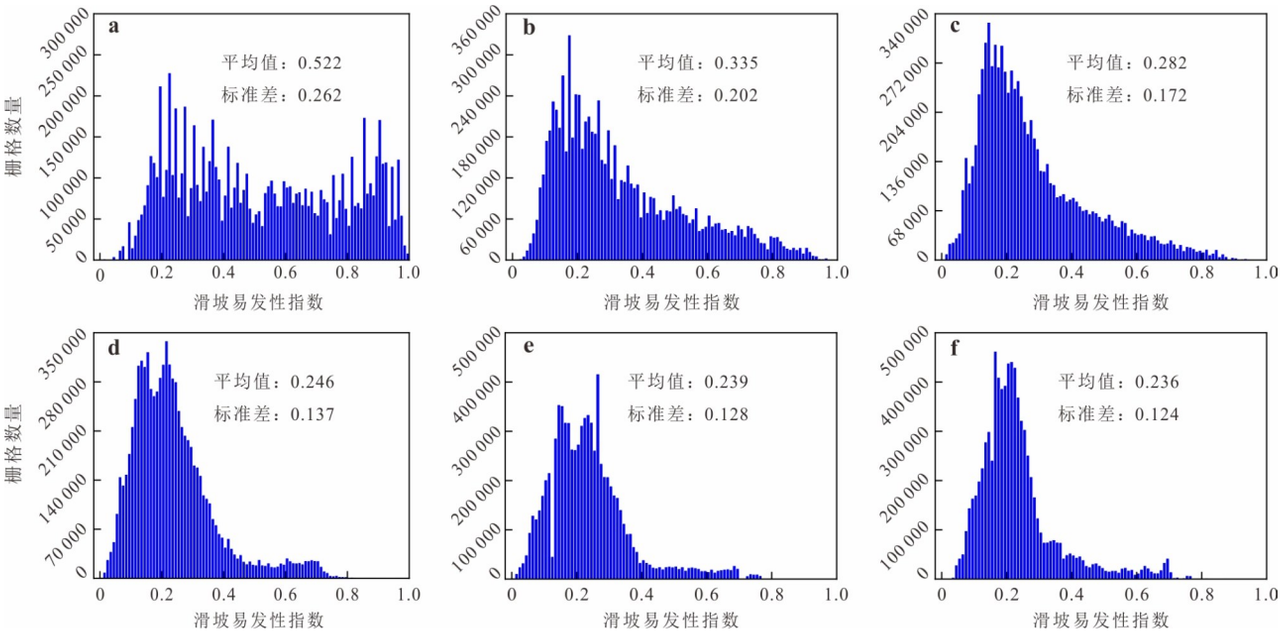

图 16　多样本比例下半监督非对称 XGBoost 模型易发性指数分布(极低和低易发区采样)

Fig.16　Susceptibility index distribution of semi-supervised imbalanced XGBoost models under multiple sample proportions (sampled from extremely low and low susceptibility areas)

a.半监督非对称模型(1∶1); b.半监督非对称模型(1∶10);c.半监督非对称模型(1∶20);d.半监督非对称模型(1∶60);e.半监督非对称模型(1∶100);f.半监督非对称模型(1∶140)

表 9　半监督非对称模型预测精度及易发性分布特征(极低和低易发区采样)

Table 9　Prediction accuracy and susceptibility distribution characteristics of semi-supervised imbalanced model (sampled from extremely low and low susceptibility areas)

模型类型	滑坡/非滑坡比例	AUC	频率比精度	准确率	特异性	均值	标准差
半监督非对称 XGBoost 模型	1∶1	0.922	0.863	0.864	0.878	0.522	0.262
	1∶5	0.934	0.872	0.917	0.921	0.394	0.228
	1∶10	0.942	0.881	0.942	0.946	0.335	0.202
	1∶20	0.953	0.885	0.962	0.965	0.282	0.172
	1∶40	0.960	0.890	0.972	0.974	0.255	0.150
	1∶60	0.971	0.893	0.980	0.981	0.246	0.137
	1∶100	0.974	0.897	0.986	0.988	0.239	0.128
	1∶140	0.976	0.900	0.988	0.991	0.236	0.124
	1∶180	0.975	0.903	0.989	0.992	0.236	0.124
	1∶220	0.975	0.903	0.990	0.992	0.237	0.123

5.4　半监督非对称策略的应用前景

本研究引入半监督非对称策略开展滑坡易发性建模与预测.相较于传统监督学习及常规半监督方法,该策略优势显著,一方面,在 AUC、频率比等关键精度指标上均显著提升,易发性区划结果更合理,有效降低了预测不确定性;另一方面,模型深度融合野外滑坡实际空间分布特征及潜在滑坡单元的影响,输出结果与研究区真实滑坡分布高度吻合.此外,通过强化滑坡样本识别能力,揭示了各环境因子对滑坡孕育的内在驱动机制,为防灾减灾提供科学可靠的决策支持.

同时,该策略已验证跨区域适用性:率先落地于江西寻乌—安远县,当样本比例为 1∶180 时,半监督非对称 RF 模型的 AUC 精度值达到峰值 0.957(黄发明等,2025);后推广至九江市,各项指标均在样本比例为 1∶160 时表现最佳(Huang *et al.*,2024);本研究中武宁县则为 1∶140,此时 AUC 值、频率比精度、准确率、易发性指数分布等指标均为最优.多地实践均证实预测结果与实际滑坡分布高度匹配,逐步形成一套高效、可行、客观准确的滑坡易发性

建模与评估框架,支撑滑坡风险精准防控,并为智能预警平台建设奠定基础.

未来,半监督非对称理论仍需持续优化与拓展,例如:当前研究仅依赖单一机器学习模型,后续应引入多模型集成与多模型对比验证机制,综合分析非滑坡样本比例、标签设定与模型结构间的协同效应(黄发明等,2025);现有方法仅扩增非滑坡样本,尚未补充滑坡样本,建议结合地质判识适度扩充滑坡单元,并采用差异化赋值;应用范围目前限于东南丘陵区,亟需拓展至高原、山地、黄土等多元地貌与地质背景以检验普适性;此外,当前依赖监督模型初筛样本存在主观性,应发展自动化、客观化的样本筛选方法;最后,样本比例由1∶1扩展至1∶180虽提升鲁棒性,但流程冗长,亟需开发支持比例智能优化与建模全流程自动集成的程序系统(Panahi *et al.*,2025);在验证方法层面,本研究采用随机划分法划分训练集与测试集,后续研究将引入空间交叉验证等更严格的空间留出策略,以进一步检验模型在空间独立样本上的泛化性能.

6 结论

本研究以江西省武宁县为研究区,基于不同非滑坡样本比例与标签设定,构建常规半监督XGBoost与半监督非对称XGBoost模型,开展滑坡易发性建模;结合预测精度与易发性指数分布评估不确定性,并利用SHAP、积分梯度法和部分依赖图解析致灾因子机制,旨在提升建模可信度.主要结论如下:

(1)半监督非对称策略通过非滑坡样本比例优化与标签值连续化,突破传统滑坡易发性建模中等比例采样与硬性二元标签的双重局限.相较于样本比例1∶1的设定,该策略的AUC值(0.981)和频率比精度(0.912)分别提升了6.3%和5.3%,验证了其合理性与有效性.

(2)非滑坡样本比例由1∶1增至1∶140时,模型性能持续提升并趋于稳定.敏感性分析表明,建模方法对预测结果的影响最为显著,其次为非滑坡样本比例,标签值设定方式的影响相对较小,为同行在建模策略选择上提供了明确参考.

(3)高程、坡度和地形起伏度为研究区滑坡关键致灾因子,极高和高易发区主要集中于高程60~500 m、坡度17°~32°的平原与低丘河谷地带.上述区域应作为武宁县滑坡风险防控的重点,建议加强地质环境监测与工程防护.该策略可推广至东南丘陵区及其他地质背景相似地区.

References

Chen, C. F., Liu, Y. T., Li, Y. Y., et al., 2025. Mapping Landslide Susceptibility with the Consideration of Spatial Heterogeneity and Factor Optimization. *Natural Hazards*, 121(4): 4067−4093. https://doi. org/10.1007/s11069-024-06955-w

Chen, T.Q., Guestrin, C., 2016. XGBoost: A Scalable Tree Boosting System. *CoRR*, abs/1603.02754.

Chen, X., Moraga, P., 2025. Forecasting Dengue across Brazil with LSTM Neural Networks and SHAP-Driven Lagged Climate and Spatial Effects. *BMC Public Health*, 25(1): 973. https://doi. org/10.1186/s12889-025-22106-7

Cui, Y. L., Zhu, L. L., Xu, M., et al., 2024. Optimizing TSES Method Based on the Environmental Factors to Select Negative Samples and Its Application in Landslide Susceptibility Evaluation. *Bulletin of Geological Science and Technology*, 43(3): 192−199 (in Chinese with English abstract).

Deng, M. D., Ju, N. P., Wu, T. W., et al., 2024. Vulnerability Evaluation under Different Landslide Sample Points and Polygon Expression Modes. *Earth Science*, 49(5): 1565−1583(in Chinese with English abstract).

Feng, X., Wang, Y., Liu, Y., et al., 2022. Susceptibility Assessment of a Translational Rockslide Considering the Control Mechanism and Spatial Uncertainty of a Weak Interlayer: Application Study in Tiefeng Township, Wanzhou District. *Bulletin of Geological Science and Technology*, 41(2): 254−266 (in Chinese with English abstract).

Guo, Z. Z., Chen, L. X., Yin, K. L., et al., 2020. Quantitative Risk Assessment of Slow-Moving Landslides from the Viewpoint of Decision-Making: A Case Study of the Three Gorges Reservoir in China. *Engineering Geology*, 273: 105667. https://doi. org/10.1016/j. enggeo.2020.105667

Guo, Z. Z., Cheng, M. C., Wang, Y. G., et al., 2025. Landslide Hazard Prediction under an Extreme Rainfall Scenario by Considering Multiple Timescale Rainfalls and Effective Recharge. *Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards*, 19(4): 775−803. https://doi. org/10.1080/17499518.2025.2570863

He, Y., Wang, W. H., Zhang, L. F., et al., 2023. An Identification Method of Potential Landslide Zones Using InSAR Data and Landslide Susceptibility. *Geomatics, Natural Hazards and Risk*, 14: 2185120. https://doi.org/10.1080/19475705.2023.2185120

Huang, F. M., Cao, Z. S., Jiang, S. H., et al., 2020. Landslide Susceptibility Prediction Based on a Semi-Supervised Multiple-Layer Perceptron Model. *Landslides*, 17(12): 2919−2930. https://doi. org/10.1007/

s10346-020-01473-9

Huang, F. M., Mao, D. X., Jiang, S. H., et al., 2024. Uncertainties in Landslide Susceptibility Prediction Modeling: A Review on the Incompleteness of Landslide Inventory and Its Influence Rules. *Geoscience Frontiers*, 15(6): 101886. https://doi. org/10.1016/j.gsf.2024.101886

Huang, F. M., Teng, Z. K., Guo, Z. Z., et al., 2023. Uncertainties of Landslide Susceptibility Prediction: Influences of Different Spatial Resolutions, Machine Learning Models and Proportions of Training and Testing Dataset. *Rock Mechanics Bulletin*, 2(1): 100028. https://doi.org/10.1016/j.rockmb.2023.100028

Huang, F. M., Yang, Y., Jiang, S. H., et al., 2025. A Comprehensive Review of Key Issues in Landslide Susceptibility Prediction and Their Solutions Using Semi-Supervised Imbalanced Theory. *Chinese Journal of Rock Mechanics and Engineering*, 44(12): 3139－3169 (in Chinese with English abstract).

Huang, F. M., Zeng, S. Y., Yao, C., et al., 2024. Uncertainties of Landslide Susceptibility Prediction Modeling: Influence of Different Selection Methods of "Non-Landslide Samples". *Advanced Engineering Sciences*, 56(1): 169－182 (in Chinese with English abstract).

Jia, Z., Cheng, Z. J., Chang, Z. L., et al., 2025. Modeling and Uncertainty in Landslide Susceptibility Prediction Considering Coupling Mode of Landslide Types. *Earth Science*, 50(6): 2311－2329(in Chinese with English abstract).

Li, M. Y., Tian, H. L., 2025. Insights from Optimized Non-Landslide Sampling and SHAP Explainability for Landslide Susceptibility Prediction. *Applied Sciences*, 15(3): 1163. https://doi.org/10.3390/app15031163

Liu, F. Z., Wang, L., Xiao, D. S., 2021. Application of Machine Learning Model in Landslide Susceptibility Evaluation. *The Chinese Journal of Geological Hazard and Control*, 32(6): 98－106(in Chinese with English abstract).

Liu, J., Li, S. L., Chen, T., 2018. Landslide Susceptibility Assesment Based on Optimized Random Forest Model. *Geomatics and Information Science of Wuhan University*, 43(7): 1085－1091(in Chinese with English abstract).

Lu, H., Lu, S. Q., Li, J. L., et al., 2025. Interpretable Landslide Susceptibility Evaluation Using a BP Neural Network Model Optimized by Multiple Algorithms. *The Chinese Journal of Geological Hazard and Control*, 36(4): 160－174(in Chinese with English abstract).

Lundberg, S. M., Lee, S. I., 2017. A Unified Approach to Interpreting Model Predictions. Proceedings of the 31st International Conference on Neural Information Processing Systems. ACM: 4768－4777. https://doi. org/10.5555/3295222.3295230

Mao, Z. M., Jiao, Y. Y., Tan, F., et al., 2025. Susceptibility Mapping of Ground Collapse Caused by Anthropogenic Activities. *Journal of Earth Science*, 36(3): 1168－1180. https://doi.org/10.1007/s12583-022-1644-y

Panahi, M., Rezaie, F., Khosravi, K., et al., 2025. Beyond Boundaries: AI-Optimized Global Landslide Susceptibility Mapping. *Geomatics, Natural Hazards and Risk*, 16: 2493222. https://doi. org/10.1080/19475705.2025.2493222

Pham, Q. B., Chandra Pal, S., Chakrabortty, R., et al., 2022. Predicting Landslide Susceptibility Based on Decision Tree Machine Learning Models under Climate and Land Use Changes. *Geocarto International*, 37(25): 7881－7907. https://doi. org/10.1080/10106049.2021.1986579

Reichenbach, P., Busca, C., Mondini, A. C., et al., 2014. The Influence of Land Use Change on Landslide Susceptibility Zonation: The Briga Catchment Test Site (Messina, Italy). *Environmental Management*, 54(6): 1372－1384. https://doi.org/10.1007/s00267-014-0357-0

Shen, Z. H., He, S. T., Wang, D. J., et al., 2025. Landslide Susceptibility Evaluation and Driving Force Analysis for Jiuzhaigou Scenic Area Based on Explainable Machine Learning. *Bulletin of Soil and Water Conservation*, 45(6): 213－226(in Chinese with English abstract).

Shua, Q. Q., Peng, H. B., Li, J. K., 2024. Landslide Susceptibility Prediction Modelling Based on Semi-Supervised XGBoost Model. *Geological Journal*, 59(9): 2655－2667. https://doi.org/10.1002/gj.4936

Si, K. P., Tian, Y., Wang, D. M., et al., 2009. Comparison of Three Statistical Methods on Landslide Susceptibility Analysis: A Case Study of Shenzhen City. *Acta Scientiarum Naturalium Universitatis Pekinensis*, 45(4): 639－646 (in Chinese with English abstract).

Sun, D. L., Ding, Y. K., Wen, H. J., et al., 2024. SHAP-PDP Hybrid Interpretation of Decision-Making Mechanism of Machine Learning-Based Landslide Susceptibility Mapping: A Case Study at Wushan District, China. *The Egyptian Journal of Remote Sensing and Space Sciences*, 27(3): 508－523. https://doi. org/10.1016/j.ejrs.2024.06.005

Sundararajan, M., Taly, A., Yan, Q. Q., 2017. Axiomatic Attribution for Deep Networks. Proceedings of the 34th International Conference on Machine Learning-Volume 70. ACM: 3319－3328. https://doi. org/10.5555/3305890.3306024

Tang, X. G., Wang, L. J., Wang, H. Y., et al., 2024. Predicted Climate Change Will Increase Landslide Risk in Hanjiang River Basin, China. *Journal of Earth Science*, 35(4): 1334－1354. https://doi. org/10.1007/s12583-021-1511-2

Tian, Y., Tan, W. L., Wang, G. Q., et al., 2023. Perfor-

mance of Variant LSTM Models in Runoff Prediction and Their Interpretability. *Water Resources Protection*, 39(3): 188－194 (in Chinese with English abstract).

Wu, C. Y., Hung, S. J., Lin, K. C., et al., 2019. Responsiveness, Minimal Clinically Important Difference, and Validity of the MoCA in Stroke Rehabilitation. *Occupational Therapy International*, 2019: 2517658. https://doi.org/10.1155/2019/2517658

Wu, H. Y., Zhou, C., Liang, X., et al., 2023. Assessment of Landslide Susceptibility Mapping Based on XGBoost Model: A Case Study of Yanshan Township. *The Chinese Journal of Geological Hazard and Control*, 34(5): 141－152 (in Chinese with English abstract).

Xiong, H. W., 2024. Study of Interpretability of Landslide Susceptibility Assessment under Different Prediction Units and Semi-Supervised Imbalanced Theory (Dissertation). Nanchang University, Nanchang (in Chinese with English abstract).

Yang, C., Liu, L. L., Huang, F. M., et al., 2023. Machine Learning-Based Landslide Susceptibility Assessment with Optimized Ratio of Landslide to Non-Landslide Samples. *Gondwana Research*, 123: 198－216. https://doi.org/10.1016/j.gr.2022.05.012

Ye, C. M., Tang, R., Wei, R. L., et al., 2023. Generating Accurate Negative Samples for Landslide Susceptibility Mapping: A Combined Self-Organizing-Map and One-Class SVM Method. *Frontiers in Earth Science*, 10: 1054027. https://doi.org/10.3389/feart.2022.1054027

Zhang, Y. L., 2023. Semi-Supervised Asymmetric Theory of Landslide Susceptibility Prediction Modeling and the Influence Law of Basic Data Error(Dissertation). Nanchang University, Nanchang (in Chinese with English abstract).

Zheng, D. F., Gao, M., Yan, C. L., et al., 2024. Susceptibility Assessment of Landslides Based on Convolutional Neural Network Model: A Case Study from Xianrendong National Nature Reserve in Southern Liaoning Province. *Earth Science*, 49(5): 1654－1664 (in Chinese with English abstract).

Zheng, Y. K., Chen, J. G., Wang, C. B., et al., 2020. Application of Certainty Factor and Random Forests Model in Landslide Susceptibility Evaluation in Mangshi City, Yunnan Province. *Bulletin of Geological Science and Technology*, 39(6): 131－144 (in Chinese with English abstract).

Zhou, T. Y., Liu, C., Xue, P., et al., 2023. Post-Seismic Landslide Susceptibility Modeling Based on Different Machine Learning Methods. *Journal of Natural Disasters*, 32(5): 177－185 (in Chinese with English abstract).

中文参考文献

崔玉龙, 朱路路, 徐敏, 等, 2024. 基于环境因子优化 TSES 法选择负样本及其在滑坡易发性评价中的应用. 地质科技通报, 43(3): 192－199.

邓明东, 巨能攀, 吴天伟, 等, 2024. 不同滑坡样本点和多边形表达模式下的易发性评价. 地球科学, 49(5): 1565－1583.

冯霄, 王禹, 刘洋, 等, 2022. 考虑软弱夹层控滑机制及其空间不确定性的顺层岩质滑坡易发性评价: 万州区铁峰乡应用研究. 地质科技通报, 41(2): 254－266.

黄发明, 曾诗怡, 姚池, 等, 2024. 滑坡易发性预测建模的不确定性: 不同“非滑坡样本”选择方式的影响. 工程科学与技术, 56(1): 169－182.

黄发明, 杨阳, 蒋水华, 等, 2025. 滑坡易发性关键问题综述及其基于半监督非对称理论的解决方案. 岩石力学与工程学报, 44(12): 3139－3169.

贾卓, 程志金, 常志璐, 等, 2025. 考虑滑坡类型耦合方式的滑坡易发性预测建模与不确定性分析. 地球科学, 50(6): 2311－2329.

刘福臻, 王灵, 肖东升, 2021. 机器学习模型在滑坡易发性评价中的应用. 中国地质灾害与防治学报, 32(6): 98－106.

刘坚, 李树林, 陈涛, 2018. 基于优化随机森林模型的滑坡易发性评价. 武汉大学学报(信息科学版), 43(7): 1085－1091.

陆昊, 卢书强, 李佳乐, 等, 2025. 可解释性结合多算法优化 BP 模型的滑坡易发性评价. 中国地质灾害与防治学报, 36(4): 160－174.

申振宏, 何松膛, 王道杰, 等, 2025. 基于可解释性机器学习的九寨沟景区滑坡易发性评价及驱动力分析. 水土保持通报, 45(6): 213－226.

司康平, 田原, 汪大明, 等, 2009. 滑坡灾害危险性评价的 3 种统计方法比较: 以深圳市为例. 北京大学学报(自然科学版), 45(4): 639－646.

田烨, 谭伟丽, 王国庆, 等, 2023. LSTM 变体模型在径流预测中的性能及其可解释性. 水资源保护, 39(3): 188－194.

吴宏阳, 周超, 梁鑫, 等, 2023. 基于 XGBoost 模型的三峡库区燕山乡滑坡易发性评价与区划. 中国地质灾害与防治学报, 34(5): 141－152.

熊浩文, 2024. 不同预测单元下的滑坡易发性评价可解释性及半监督非对称理论研究(硕士学位论文). 南昌: 南昌大学.

张崟琅, 2023. 滑坡易发性预测建模的半监督非对称理论及基础数据误差的影响规律(硕士学位论文). 南昌: 南昌大学.

郑德凤, 高敏, 闫成林, 等, 2024. 基于卷积神经网络的滑坡易发性评价: 以辽南仙人洞国家级自然保护区为例. 地球科学, 49(5): 1654－1664.

郑迎凯, 陈建国, 王成彬, 等, 2020. 确定性系数与随机森林模型在云南芒市滑坡易发性评价中的应用. 地质科技通报, 39(6): 131－144.

周天游, 刘畅, 薛鹏, 等, 2023. 基于不同机器学习的震后滑坡易发性建模研究. 自然灾害学报, 32(5): 177－185.