

融合物理机制的负样本优化策略与地震滑坡易发性评价

刘磊磊^{1,2,3,4}, 段灿^{2,3,4}, 许冲⁵, 鄂忠虎^{6,*}

1. 贵州华佑通工程技术有限公司, 贵州贵阳 550025

2. 有色金属成矿预测与地质环境监测教育部重点实验室(中南大学), 湖南长沙 410083

3. 湖南省有色资源与地质灾害探查湖南省重点实验室, 湖南长沙 410083

4. 中南大学地球科学与信息物理学院, 湖南长沙 410083

5. 应急管理部国家自然灾害防治研究院, 北京 100085

6. 贵州大学土木工程学院, 贵州贵阳 550025

摘要: 准确的地震滑坡易发性评价对于震后应急响应与风险管理至关重要。然而, 滑坡易发性建模中负样本选取存在较强的随机性, 且缺乏基于物理机制(如考虑安全系数、永久位移和失效概率等物理评价指标)的稳定性判别, 影响模型的预测能力。为探究不同物理机制驱动下的负样本选取策略对地震滑坡易发性评价结果的影响, 本文基于三类典型的稳定性评价指标: 安全系数(Fs)、永久位移(Dn)和滑坡失效概率(Pf), 划定稳定区域构建滑坡负样本数据集, 结合逻辑回归(LR)、随机森林(RF)和卷积神经网络(CNN)三种模型进行系统对比研究。结果表明, 基于Dn策略构建的负样本更能反映地震诱发滑坡的物理机制, 评价精度最高, AUC最大为0.924, 明显优于Pf策略(0.912)和Fs策略(0.908)。在模型选择方面, CNN模型凭借其深层特征提取和非线性表达能力, 在滑坡识别和分类性能方面均优于RF和LR模型, 表现出更强的稳定性和泛化能力。SHAP分析显示, 地震动峰值加速度、坡度、坡位以及距断层距离是滑坡发生的主控因素。研究表明, 融合物理机制的Dn策略与CNN模型组合(Dn-CNN), 在地震滑坡易发性评价中预测效果最好, 研究成果可为地震滑坡易发性预测中负样本选择和模型选取提供参考。

关键词: 地震滑坡; 易发性评价; 负样本选取; 评价模型; 机器学习

中图分类号: P642.22

收稿日期: 2025-08-24

A Physically-Informed Negative Sampling Strategy for Earthquake-Induced Landslide Susceptibility Assessment

Lei-Lei Liu^{1,2,3,4}, Can Duan^{2,3,4}, Chong Xu⁵, Zhong-Hu Wu^{6,*}

1. Guizhou Huayoutong Engineering Technology Co., Ltd., Guiyang, 550025

2. Key Laboratory of Metallogenic Prediction of Nonferrous Metals and Geological Environment Monitoring, Ministry of Education, School of Geosciences and Info-Physics, Central South University, Changsha 410083, P. R. China

3. Hunan Key Laboratory of Nonferrous Resources and Geological Hazards Exploration, Changsha 410083, P. R. China

4. School of Geosciences and Info-Physics, Central South University, Changsha 410083, P. R. China

5. National Institute of Natural Hazards, Ministry of Emergency Management of China, Beijing 100085, P. R. China

6. College of Civil Engineering, Guizhou University, Guiyang 550025, P. R. China

基金项目: 贵州省科技支撑计划项目(黔科合支撑[2023]一般 137)

作者简介: 刘磊磊(1987-), 男, 博士, 副教授, 主要从事地质灾害防治与风险控制方面的研究工作。E-mail: csulll@foxmail.com

***通讯作者:** 鄂忠虎(1989-), 男, 博士, 教授, 主要从事固废资源利用与地质灾害防控方面的研究工作。E-mail: zhwul@gzu.edu.cn

Abstract: Accurate landslide susceptibility assessment (LSA) for earthquake-induced landslides is critical for post-earthquake emergency response and disaster risk management. However, conventional models often rely on randomly selected negative samples, which lack physically grounded stability criteria (e.g., considering physical evaluation indicators such as factor of safety, permanent displacement, and failure probability), and consequently compromise prediction reliability. To investigate the influence of different physically-informed negative sampling strategies on the accuracy of co-seismic LSA, this study utilizes three representative stability evaluation indicators: Factor of Safety (Fs), Newmark Displacement (Dn), and Landslide Failure Probability (Pf) are employed to delineate stable regions for constructing negative sample datasets. These were integrated with three commonly used models: Logistic Regression (LR), Random Forest (RF), and Convolutional Neural Network (CNN), to conduct a systematic comparative analysis. The results show that the Dn-based sampling strategy more effectively characterizes the physical triggering mechanisms of earthquake-induced landslides, achieving the highest predictive accuracy (AUC = 0.924), outperforming both the Pf-based (AUC = 0.912) and Fs-based (AUC = 0.908) strategies. Among the three models, CNN consistently exhibited superior performance in spatial prediction and classification accuracy due to its robust capability in nonlinear learning and hierarchical feature extraction. SHAP analysis further indicates that peak ground acceleration (PGA), slope, relative slope position, and distance to fault are the dominant factors controlling landslide occurrence. Overall, the Dn-CNN combination yielded the most accurate and interpretable susceptibility results, offering valuable insights for improving negative sample construction and model selection in seismic LSA.

Key Words: Earthquake-induced landslide; Susceptibility assessment; Negative sample selection; Evaluation models; Machine learning

0 引言

地震滑坡是强震作用下最主要的次生地质灾害之一，具有突发性强、数量多、分布范围广、破坏性大等特点，往往造成严重的经济损失和人员伤亡 (李永威等, 2023)。根据国家统计局的相关统计，2004年至2024年间我国共发生地震灾害294次，造成486845名人员伤亡。其中，2008年汶川地震诱发了197481处滑坡，由地震滑坡导致的人员死亡约20000人，约占地震死亡人员总数的1/4。因此，开展精确的地震滑坡易发性评价与制图，对于滑坡灾害防控、风险管理以及灾后恢复重建具有重要的意义 (Dou et al., 2025)。

目前，常用的滑坡易发性评价模型可分为知识驱动模型、物理驱动模型和数据驱动模型 (窦杰等, 2023)。知识驱动模型通常属于定性方法，典型代表如层次分析法，该方法主要依赖于专家经验进行滑坡灾害评价，但由于其较强的主观性应用受限。物理驱动模型则从滑坡发生的物理机制出发，通过构建力学模型模拟边坡在外部荷载作用下的稳定性。其中，Newmark位移模型是研究地震诱发滑坡灾害的经典方法 (Newmark, 1965)，其本质是当地震动荷载产生的地震动加速度超出滑块所能承受的临界加速度时，滑块位移逐渐累积，最终导致滑块产生永久变形。该模型因其物理意义明确，广泛应用于多个重大地震事件的滑坡易发性评价，如2022年四川泸定地震 (刘甲美等, 2023)和2023年甘肃积石山地震 (曾营等, 2024)等。然而，由于岩土体参数和地震参数简化，影响了评价结果的精度和可靠性。

数据驱动模型通过分析滑坡影响因素与过去及现在滑坡分布的关系，实现对滑坡易发区域的预测。常见的有决策树模型、支持向量机模型、逻辑回归模型 (Logistic Regression, LR)、随机森林模型 (Random

Forest, RF) 等 (Ersayin and Uzun, 2025)。其中, LR 模型能够直观地揭示影响因素与滑坡发生之间的线性关系。Xie et al. (2018)探讨了 LR 模型在中国山区地震诱发滑坡易发性评估中的应用, 证明了其具有较好的预测效果和可解释性。同时, RF 模型基于集成学习思想, 能够有效处理非线性关系和高维数据, 在许多研究中表现出良好的稳定性与预测性能 (Chen et al., 2023)。然而, 传统机器学习模型在复杂特征提取、非线性关系建模和模型解释性等方面存在不足。为此, 深度学习被逐渐引入滑坡预测研究中, 其中卷积神经网络模型 (Convolutional Neural Network, CNN) 凭借其出色的特征提取能力和高效的复杂非线性关系建模能力, 已经成为地震滑坡易发性评价的重要工具 (郑德凤等, 2024)。例如, Jiang et al. (2023)比较了 CNN 模型和其它 6 种机器学习方法在地震滑坡易发性中的表现, 结果表明, CNN 模型在预测精度和稳定性方面均优于传统机器学习模型。Ge et al. (2023)的研究结果进一步验证了 CNN 模型在滑坡评价中的优越性。因此, 本文选取 LR、RF 与 CNN 三类具有代表性的模型, 从线性统计到空间特征学习逐级递进, 以探讨不同算法结构在地震滑坡易发性预测中的适用性与表现差异。

另一方面, 在滑坡易发性建模过程中, 训练样本数据集的质量直接影响模型的性能表现和滑坡易发性评价结果。训练样本数据集由正样本数据和负样本数据组成。正样本 (滑坡样本) 依据历史滑坡编目, 通过历史灾害调查、遥感解译及实地核查等手段获取, 其空间位置明确、可靠性较高 (Liu et al., 2025)。相比之下, 负样本 (非滑坡样本) 的选取仍缺乏统一标准, 是当前研究中的关键难点。负样本的不合理选取易引入潜在不稳定区域作为非滑坡样本, 降低模型泛化能力与预测准确性 (王悦等, 2024)。例如, 赵腾远等 (2025)的研究表明, 通过优化滑坡负样本的空间分布, 能够显著提升滑坡易发性评价模型的预测性能, 进一步验证了高质量负样本构建在保证模型可靠性中的关键作用。目前, 已有研究提出了多种滑坡负样本选取策略, 主要包括随机选取法、缓冲区法、耦合信息量法、半监督机器学习法及基于物理机制的选取方法等。其中, 随机选取法在滑坡区以外随机选取负样本, 但获取的负样本随机性较强且质量可靠性较低 (张玘恺等, 2020)。缓冲区选取法在滑坡边界外设定排除距离进行负样本选取, 但缓冲距离设定较为主观 (Gu et al., 2022)。耦合信息量法根据滑坡点与周围环境因子的差异性提取稳定区域, 能够一定程度上提升负样本质量 (郭衍昊等, 2024)。半监督学习方法通过少量可信负样本进行模型训练, 在大量未标注样本中自动识别可靠负样本, 具有较强的学习能力 (Huang et al., 2024)。

近年来, 基于物理机制的负样本选取方法逐渐受到关注。该方法通过引入滑坡稳定性分析中的物理评价指标, 判别斜坡在地震荷载或其他诱发因素作用下的稳定状态, 具备明确的力学依据与可解释性。目前常用的稳定性评价指标主要包括安全系数 (Factor of safety, F_s)、永久位移 (Newmark displacement, D_n) 和滑坡失效概率 (Failure probability, P_f) 等。 F_s 用于评估边坡稳定性, 当 F_s 值显著大于 1 的区域通常处于稳定状态, 可用于构建可信的负样本数据集 (Liu et al., 2023)。 D_n 表征地震作用下边坡的累计滑移量, D_n 值趋近于零的区域通常被视为地震扰动响应弱、稳定性较高的单元, 可作为负样本筛选依据 (Xi et al., 2022)。 P_f 反映边坡在地震扰动下的失稳可能性, P_f 值较低区域具有较强的稳定性特征 (Ji et al., 2022)。然而, 现有研究在利用物理稳定性指标优化负样本选取时仍存在一定局限性: 一方面, 多数研究仅基于单一物理稳定性评价指标进行负样本构建, 缺乏对不同稳定性评价指标下负样本选取策略的系统比较; 另一方面, 不同物理稳定性评价指标构建的负样本策略在不同架构机器学习模型中的适用性及其对预测性能的影响, 尚缺乏系统而深入的研究。

因此，本研究基于 F_s 、 D_n 和 P_f 三类典型稳定性评价指标，分别进行负样本选取，构建滑坡样本数据集，并引入 LR、RF 和 CNN 三种代表性模型开展地震滑坡易发性评价。利用 AUC 值、混淆矩阵、滑坡密度等评价指标，对比三种稳定性评价指标用于负样本选取时对评价结果的影响，旨在为负样本数据的科学构建提供更具物理依据与可解释性的选取方法。

1 研究区与数据源

1.1 研究区概况

本研究选取四川省汶川县为研究区（图 1）。汶川县地处青藏高原东缘，四川盆地西北部，地理坐标为 $102^{\circ}51' - 103^{\circ}44'$ 、 $30^{\circ}45' - 31^{\circ}43'N$ ，总面积约为 4084 km^2 。区内地形以高山峡谷为主，地势西北高东南低，起伏较大，海拔高度为 $780 - 5904\text{m}$ 。县境内水系较为发育，主要由岷江及其支流构成，沿途形成了众多的高山、深谷。区域构造位置复杂，受龙门山断裂带（包括茂汶断裂、映秀-北川断裂和灌县-江油断裂）的影响，地质构造运动强烈。研究区地层主要出露于前寒武纪至三叠纪，岩石类型多样，主要包括花岗岩、闪长岩、砂岩、灰岩、板岩、页岩等，为滑坡等地质灾害的孕育与诱发提供了物质基础。

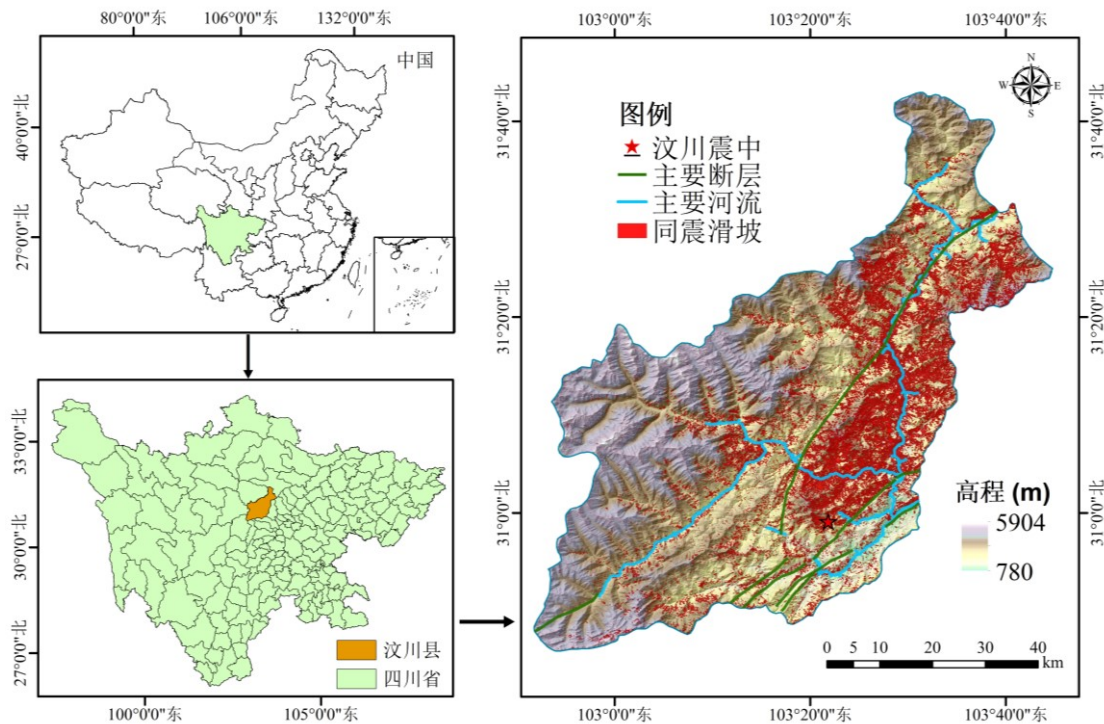


图 1 研究区地理位置及同震滑坡分布图

Fig. 1 Geographic location of the study area and distribution of co-seismic landslides

1.2 数据源

1.2.1 同震滑坡编录

数据的准确性直接决定了模型预测结果的可靠性，高质量的滑坡编录数据是构建精确滑坡易发性评估模型的关键。汶川地震发生后，众多研究者开展了系统的滑坡遥感调查与编目工作 (Dai et al., 2011; Parker et al., 2011)。本研究同震滑坡清单数据来源于 Xu et al. (2014)构建的遥感解译成果，该数据详细记录了滑坡的数量、大小、形态，具有高质量性和完整性。该清单共包括 197481 处同震滑坡，以浅层

扰动型滑坡为主，并包含少量岩石崩塌类型，考虑研究面向区域尺度易发性评价，本文未对滑坡类型进行区分，而统一作为分析样本。同时，鉴于研究采用 $30\text{ m}\times 30\text{ m}$ 的栅格单元（像元面积为 900 m^2 ），为确保样本数据与环境因子在空间尺度上的匹配度与可靠性，本研究将最小面积阈值 1000 m^2 ，对滑坡进行筛选，最终得到 46405 个单体滑坡，体积范围为 1000 m^3 至 397408 m^3 ，平均体积为 7659 m^3 （图 1）。

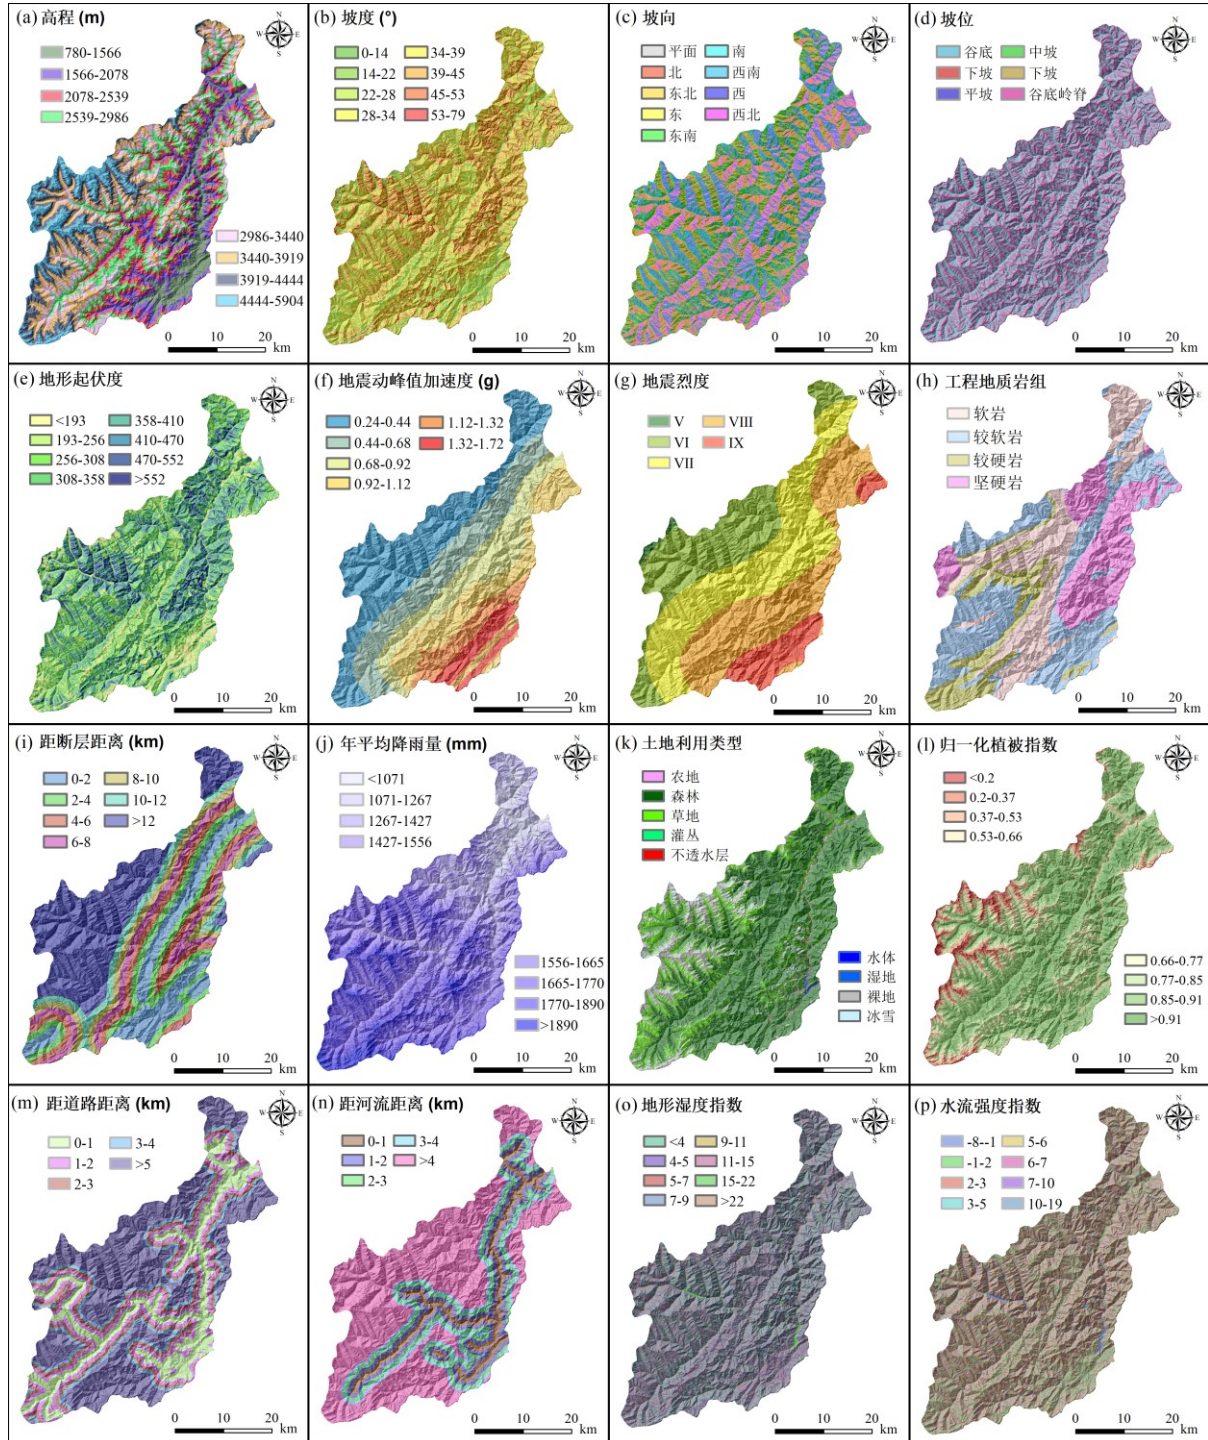


图 2 滑坡评价因子分级图

Fig. 2 Classification of landslide evaluation factors

1.2.2 滑坡评价因子

滑坡评价因子的选取是易发性评价的重要基础。尽管当前尚未形成统一的选取标准，但普遍认为地

形、地质、水文、地震及人类活动等因素对滑坡的发生具有显著影响 (Chang et al., 2021)。本研究初步选取 16 个滑坡影响因素：高程、坡度、坡向、坡位、地形起伏度、地震动峰值加速度、地震烈度、工程地质岩组、距断层距离、年平均降雨量、土地利用类型、归一化植被指数、距道路距离、距河流距离、地形湿度指数、水流强度指数 (图 2)。

各因子具体数据来源见表 1。由表可知，高程、坡度、坡向、坡位、地形起伏度指数、地形湿度指数和径流强度指数由数字高程模型 (DEM) 生成；地震动峰值加速度和地震烈度数据来自 USGS 网站；工程地质岩组和断层信息提取自 1:25 万地质图；NDVI 由 Landsat 8 OLI 影像计算得到；道路、河流数据从地理空间数据云中获取；土地利用数据采用 1990-2021 年中国 30m 土地覆被数据；降雨数据则基于气象部门历史气象记录统计生成。

表 1 滑坡评价因子数据来源
Table 1 Data sources of landslide susceptibility factors

数据名称	类型	分辨率	评价因子	数据来源
ASTER DEM	栅格	30m	高程、坡度、坡向、坡位、地形起伏度、 地形湿度指数、水流强度指数	www.earthdata. nasa.gov
地震数据	矢量		地震动峰值加速度、 地震烈度	earthquake. usgs.gov
地质数据	矢量	1:25 万	工程地质岩组、 距断层距离	geocloud.cgs. gov.cn
地理数据	矢量	1:25 万	距河流距离、距道路距离	www.gscloud.cn
土地利用数据	栅格	30m	土地利用类型	www.resdc.cn
Landsat 8 OLI	栅格	30m	归一化植被指数	www.gscloud.cn
降雨数据	栅格	1km	年平均降雨量	www.cma.gov.cn




图 3 因子多重共线性分析计算结果

Fig. 3 Results of factor multicollinearity analysis

此外，综合考虑研究区的空间尺度 (4084 km²) 以及 DEM 数据 (ASTER GDEM V3) 的分辨率，本研究将所有数据统一转换成 30m×30m 的栅格单元。该分辨率在空间细节刻画与大尺度计算效率之

间实现了良好平衡。已有研究表明, 30m 的空间分辨率能够满足区域尺度滑坡易发性制图的需求, 且对高易发区的划分影响较小(Yang et al., 2024)。因此, 采用 30m 栅格不仅与既有研究保持一致, 也为后续易发性分级提供了可靠的数据基础。

为避免评价因子间存在较强共线性对模型训练造成干扰, 本研究采用皮尔逊相关系数和多重共线性分析方法对候选因子进行相关性分析。方差膨胀因子 (VIF) 用于分析各评价因子之间的多重共线性程度, 当 VIF 值小于 5 时, 认为各影响因素之间的多重共线性较低 (杜继龙和徐元进, 2025)。计算结果如图 3 所示, VIF 值最大为 4.06, 均小于 5, 表明各评价因子之间不存在多重共线性。

皮尔逊相关系数用于衡量两个变量之间的线性相关性, 当皮尔逊相关系数的绝对值超过 0.5 时, 表明两个变量之间的相关性比较显著 (Zhao et al., 2024)。通过绘制皮尔逊相关系数热力图 (图 4), 直观展现 16 个评价因子之间的相关性。结果表明, 高程与距道路距离和距河流距离的相关系数均大于 0.5 (0.65、0.61); 距河流距离和距道路距离的相关系数为 0.78; 地形湿度指数和水流强度指数的相关系数为 0.71; 地震动峰值加速度与地震烈度的相关系数为 0.73, 而其它评价因子之间的相关性较弱。道路往往和河流相伴而生, 与高程和道路相比, 河流对滑坡的促进作用更加明显。在滑坡易发性评价中, 地形湿度指数在模拟地形和水文过程方面效果相比水流强度指数更显著。此外, 地震动峰值加速度作为地震滑坡的关键触发因素, 对滑坡的发生密切相关。因此, 综合考虑上述情况, 剔除高程、距道路距离、地震烈度、水流强度指数四个评价因子, 最终选择坡度、坡向、坡位、地形起伏度、地震动峰值加速度、工程地质岩组、距断层距离、年平均降雨量、土地利用类型、归一化植被指数、距河流距离、地形湿度指数共 12 个评价因子。需要说明的是, 岩土体力学参数 (如内聚力、内摩擦角等) 虽未直接作为机器学习模型的输入特征, 但已作为计算安全系数和 Newmark 位移的关键参数, 为本研究基于物理机制的负样本优化策略提供了重要支撑。




图 4 皮尔逊相关系数热力图

Fig. 4 Pearson correlation coefficient heat map

2 研究方法

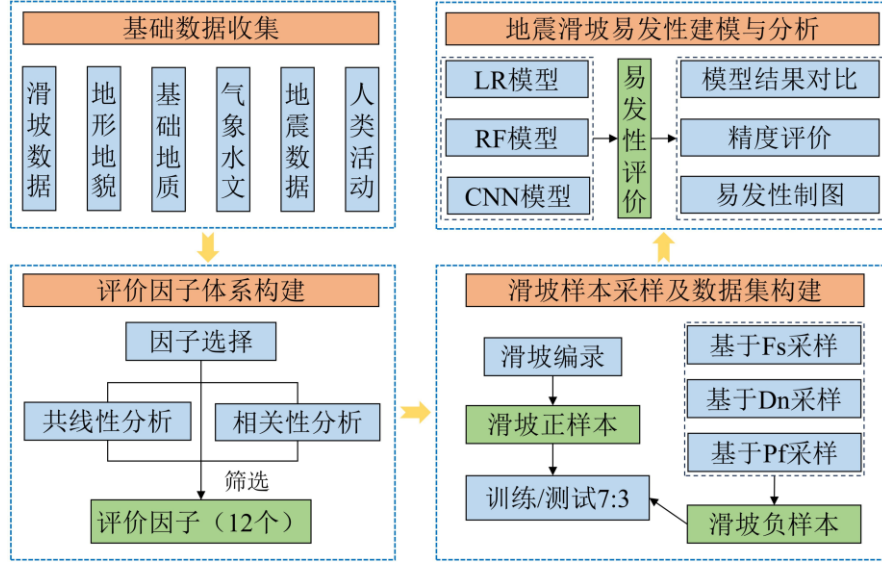


图 5 基于不同滑坡负样本选择策略的滑坡易发性评价流程

Fig. 5 Flowchart of landslide susceptibility assessment based on different sampling strategies

本研究基于安全系数（Fs）、永久位移（Dn）和滑坡失效概率（Pf）三类典型稳定性评价指标为基础，分别构建负样本数据集，并引入逻辑回归（LR）、随机森林（RF）和卷积神经网络（CNN）三种模型开展地震滑坡易发性评价。本研究的总体技术路线如图 5 所示，整体研究流程包括以下五个步骤：

（1）收集和整理研究区的滑坡分布、评价因子、岩土体参数等数据；（2）筛选并选取地震滑坡评价因子，构建滑坡评价因子数据集；（3）计算 Fs、Dn 和 Pf 指标，划定稳定区域进行负样本选取，并结合滑坡编目构建滑坡与非滑坡样本数据集；（4）基于三类滑坡样本数据集，选取 LR、RF 和 CNN 三种模型进行训练，其中 70%用于训练，30%用于测试；（5）通过 AUC 值、混淆矩阵、滑坡密度等指标对模型性能进行评价，比较基于不同稳定性评价指标的负样本选取策略的适用性及其对预测效果的影响。

2.1 滑坡负样本选取策略

滑坡易发性模型的训练依赖于正负样本数据的合理构建。尽管正样本可由历史滑坡编录明确获取，而负样本的选取方式尚无统一标准。不合理的选取方法可能将潜在不稳定区识别为非滑坡样本，从而影响模型准确性与泛化能力。为系统评估不同物理驱动下的负样本构建策略对模型表现的影响，本研究以安全系数（Fs）、永久位移（Dn）与滑坡失效概率（Pf）三类典型稳定性评价指标为依据，分别划定稳定区域开展负样本选取，构建三组具有物理依据的滑坡样本数据集。

（1）Fs 计算

安全系数（Fs）是衡量潜在滑体稳定性的重要指标，为滑体的抗滑力和下滑力的比值（陈帅等, 2022）。根据滑体的岩体物理力学参数和滑动面倾角，基于摩尔-库仑准则按式（1）计算获得，如图 6（a）所示。

$$Fs = \frac{c'}{\gamma t \sin \alpha} + \frac{\tan \varphi'}{\tan \alpha} - \frac{m\gamma_w \tan \varphi'}{\gamma \tan \alpha} \quad (1)$$

式中： c' 和 φ' 为岩土体有效内聚力和有效内摩擦角； γ 和 γ_w 分别为岩土体重度和地下水重度； t 为潜在滑体厚度； α 为斜坡坡角； m 为饱和潜在滑坡体所占的比例。

表 2 不同岩组的物理力学参数

Table 2 Mechanical parameters of different lithologies

工程地质岩组	有效内聚力 c' (kPa)	有效内摩擦角 φ' (°)	岩土体重度 γ (kN/m ³)
坚硬岩	35	40	25
较硬岩	30	35	23
较软岩	25	30	20
软岩	20	25	17

岩土体物理力学参数的获取是 Fs 计算的关键。本研究根据 1: 25 万的地质图, 并参考工程岩体分类标准和前人研究 (陈帅等, 2022), 将研究区的岩性按照坚硬程度和完整程度等要素分为四类: 坚硬岩、较硬岩、较软岩、软岩 (图 2 (h))。同时, 参考 Ma and Xu (2019) 的研究, 确定研究区不同岩体的物理力学参数 (有效内聚力、有效内摩擦角和岩土体重度), 见表 2。

(2) Dn 计算

本研究选择 (Jibson, 2007) 基于全球强震动记录拟合建立的经验位移方程 (式 (3)) 计算研究区永久位移值 (Dn), 即利用临界加速度 (式 (2)) 和地震动峰值加速度 (PGA) 获得 Newmark 位移图 (图 6 (b))。该模型基于全球强震数据构建, 具有良好的普适性, 且已有研究验证了其在汶川地震滑坡评价中的适用性与可靠性 (Chen et al., 2023), 能够有效反映该区域地震滑坡的动力响应特征。

$$a_c = (Fs - 1)g \sin \alpha \quad (2)$$

式中: g 为重力加速度; α 为滑动面倾角。

$$\lg Dn = 0.215 + \lg \left[\left(1 - \frac{a_c}{PGA} \right)^{2.341} \times \left(\frac{a_c}{PGA} \right)^{-1.438} \right] \quad (3)$$

式中: a_c 为临界加速度, PGA 为地震动峰值加速度。

(3) Pf 计算

滑坡失效概率 (Pf) 用于描述在地震动作用下斜坡发生失稳的可能性。Jibson et al. (2000) 将滑坡实际分布与预测的 Dn 图进行了比较, 利用 Weibull 曲线对不同位移水平下的滑坡概率进行了拟合, 定量地评估了地震区内斜坡的失效概率 (式 (4))。该公式基于全球多次强震事件的统计回归建立, 涵盖了多种地震动强度与地形地质条件, 具有较好的物理基础与跨区域适用性。已有研究在我国西部强震山区对该模型进行了验证。例如, Ma and Xu (2019) 已证实该模型在汶川地震区具有良好的适用性, 能够有效反映区域尺度上滑坡的空间分布规律。此外, 值得注意的是, 岩土体参数具有固有的空间变异性和不确定性, 近年来基于可靠度理论的概率分析方法逐渐被应用于滑坡易发性评价中, 以量化参数不确定性的影响 (Ji et al., 2022)。然而, 考虑到区域尺度计算的效率以及本研究主要旨在利用物理指标构建差异化的负样本数据集, 因此本文仍采用经典的 Jibson 经验模型作为 Pf 样本选取的依据。在本研究中, 我们利用该回归曲线, 基于 2008 年汶川地震的 Dn 图编制了滑坡灾害概率图 (图 6 (c))。失稳概率范围为 0-0.335。

$$Pf = 0.335[1 - \exp(-0.048Dn^{1.565})] \quad (4)$$

式中: Dn 为 Newmark 位移值, Pf 为某一位移区间内滑坡单元格所占的百分比。

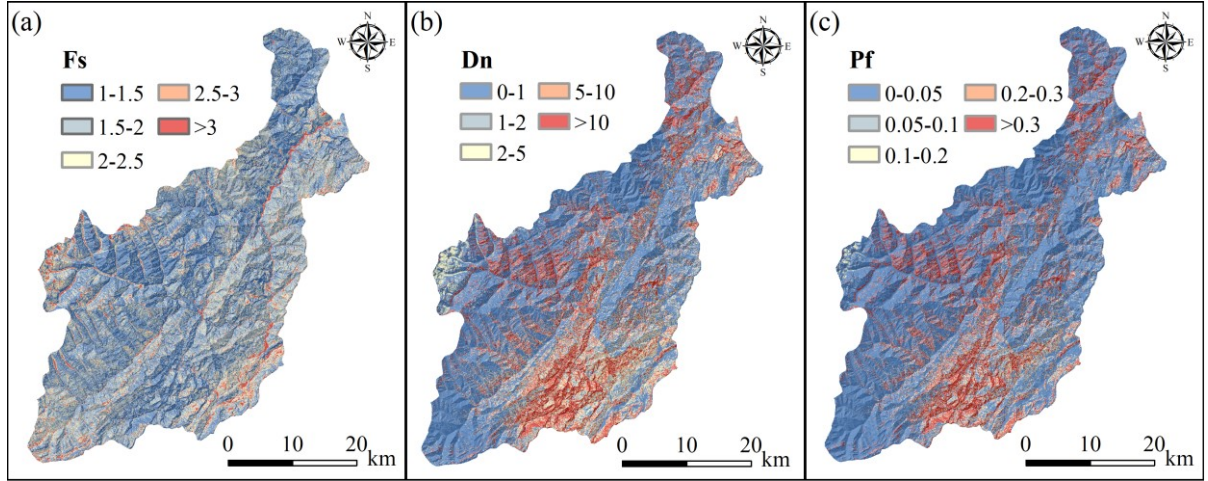


图 6 三类稳定性评价指标的空间分布图：(a) Fs；(b) Dn；(c) Pf

Fig. 6 Spatial distribution of three stability indicators: (a) Fs, (b) Dn, and (c) Pf

2.2 易发性评价模型

2.2.1 LR 模型

逻辑回归模型（LR）是处理二分类问题的统计方法，用于预测事件的发生概率，近年来广泛运用于地震滑坡易发性评价中（Zeng et al., 2023）。该算法使用极大似然估计函数构建预测因素与结果之间的关系。在地震滑坡易发性评价中，将滑坡发生的影响因素作为自变量，滑坡是否发生（1 表示发生，0 表示不发生）作为因变量，其表达式如下：

$$Z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n \quad (5)$$

$$P = 1/(1 + e^{-Z}) \quad (6)$$

式中： P 表示同震滑坡发生的概率，其取值范围为 $[0, 1]$ ； x_i ($i = 1, 2, 3, \dots, n$)代表各个影响因素； β_0 为常数； β_i ($i = 1, 2, 3, \dots, n$)表示逻辑回归系数，反映各影响因素 x_i 对 P 的影响程度， Z 为变量叠加后的线性权重值。

2.2.2 RF 模型

随机森林模型（RF）是由 Breiman 提出的一种高效的集成学习算法（Breiman, 2001）。该模型使用 Bagging 算法，从不同的训练数据集中随机选取样本及其特征，构建多个独立的决策树模型。这种方法使得每棵树都在不同的数据和特征空间上进行训练，具有较高的预测能力和鲁棒性。当需要对某个样本进行预测时，通常使用投票少数服从多数或者取平均值得到最终的预测结果（图 7）。

2.2.3 CNN 模型

卷积神经网络（CNN）是一类深度前馈神经网络，具备强大的自动特征提取与非线性建模能力，近年来被广泛应用于滑坡易发性评价研究中（丁明涛等, 2025）。其结构主要包括输入层、卷积层、池化层、全连接层和输出层。其中，卷积层通过卷积核对输入样本的位置进行线性变换映射，获得输入数据局部特征信息。池化层用于压缩数据减少参数体量，以防止过拟合并提高计算效率。全连接层的作用是对提取的特征进行非线性组合以完成分类任务。

在本研究中，使用筛选后的 12 个地震滑坡评价因子作为 CNN 模型的输入，依次经过多层卷积与

最大池化操作提取关键特征，再通过全连接层对高阶特征进行整合，最终输出滑坡发生概率（图 8）。其核心计算表达式如下：

$$C_j = f(\sum_{i=1}^N w_{ij} \cdot x_i + b_j) \quad (7)$$

式中： C_j 为卷积层输出特征图； f 为激活函数； $x_i (i = 1, 2, 3, \dots, N)$ 为输入滑坡数据， N 为滑坡评价因子数量； w_{ij} 为卷积核权重； b_j 为偏置。

在模型训练阶段，为了保证神经网络能够充分学习输入数据中的非线性特征，并确保损失函数平稳收敛，本研究将模型的最大训练迭代次数（Epochs）设定为 200 次，以获得可靠的预测结果。

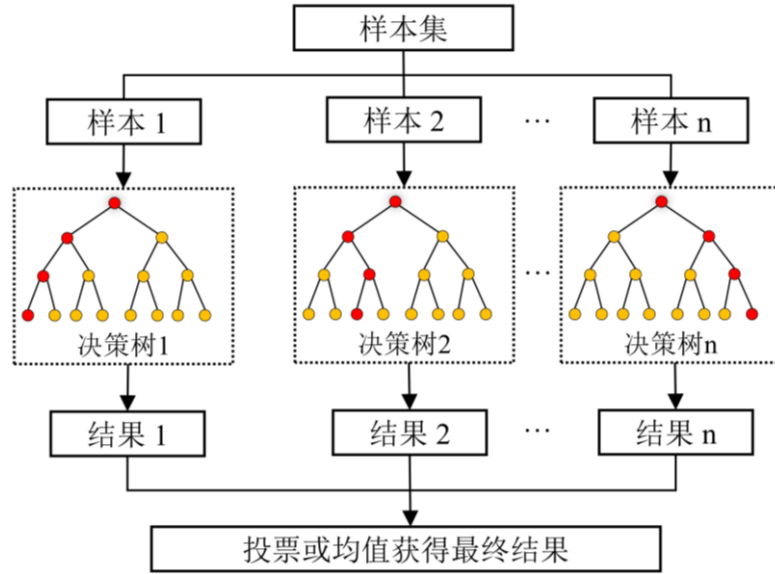


图 7 RF 模型流程图

Fig. 7 Flowchart of the RF model

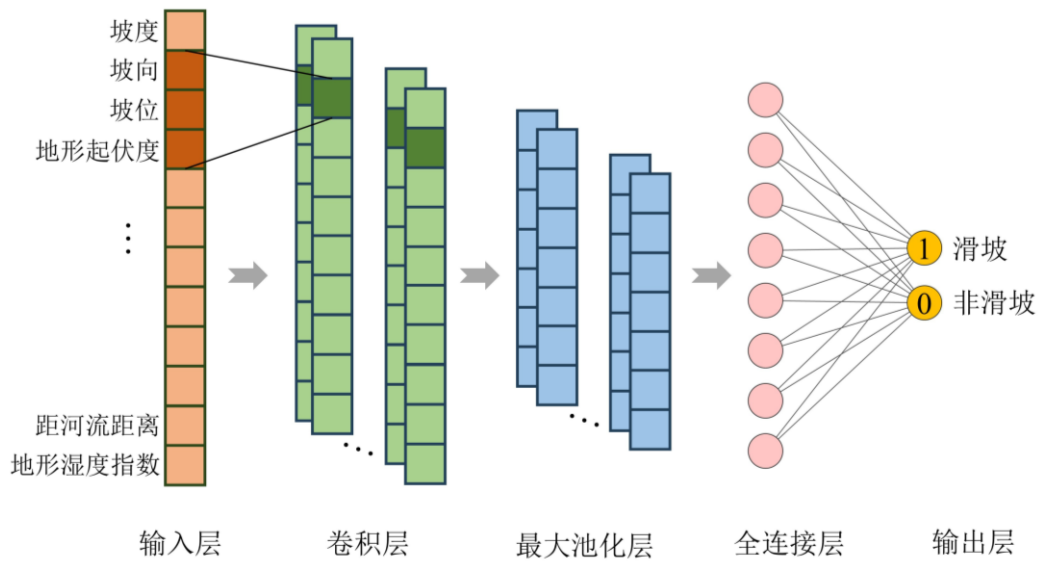


图 8 CNN 模型结构图

Fig. 8 CNN model architecture diagram

2.3 模型性能评估方法

滑坡易发性评价结果的可靠性主要取决于所采用预测模型的精度。为了全面评估模型性能,本研究选取受试者特征曲线(receiver operating characteristic curve, ROC)、曲线下面积(area under curve, AUC)、准确率(accuracy)、灵敏度(sensitivity)和特异度(specificity)。其中,ROC曲线根据不同的阈值计算模型的真阳性率(true positive rate, TPR)和假阳性率(false positive rate, FPR),即以FPR为横坐标和TPR为纵坐标绘制曲线。AUC表示ROC曲线下的面积,其值在0.5-1之间,且AUC值越大,模型预测效果越好。其他模型评价指标计算公式如下:

$$Accuracy = \frac{TP+TN}{TP+TN+FN+FP} \quad (8)$$

$$Sensitivity = \frac{TP}{TP+FN} \quad (9)$$

$$Specificity = \frac{TN}{TN+FP} \quad (10)$$

式中:TP(true positive)表示正确预测滑坡样本的数量;TN(true negative)表示正确预测非滑坡样本的数量;FP(false positive)表示错误预测滑坡样本的数量;FN(false negative)表示错误预测非滑坡样本的数量。

同时,本研究统计各易发性分区内的历史同震滑坡数量,并与实际滑坡编目进行对比分析。当同震滑坡主要集中于高易发性区,且在低易发性区分布较少时,说明模型具有较强的空间识别能力,与实际灾害分布高度吻合。

3 地震滑坡易发性评价

3.1 地震滑坡样本数据集构建

本节根据第3.1节中计算得到的三种稳定性评价指标分区图(Fs、Dn、Pf),分别划定稳定区域并从中进行滑坡负样本选取。首先,参考已有研究成果,通常将安全系数Fs>1.5的区域视为稳定单元,该标准在滑坡易发性评价中被广泛应用(Liu et al., 2024),能有效规避处于临界稳定状态的潜在不稳定区域;其次,根据Rodríguez-Peces et al. (2014)提出的位移划分标准,将Dn<2cm划分为低位移区,表明该区域受地震扰动响应微弱,未发生明显的累积破坏位移;最后,借鉴Liu et al. (2024)的概率分级体系,将Pf<0.1区域作为低失稳概率区。总体而言,上述阈值的设定对模型结果具有重要影响:若设定过低(如Fs>1.0),容易将临界稳定状态的斜坡误标记为负样本,引入“标签噪声”从而降低预测精度;若设定过高,虽提升了样本的稳定性,但可能导致负样本仅分布于平原或极缓坡区域,造成地形特征维度的代表性缺失。因此,本研究采用前人研究中常用的阈值设置,旨在兼顾负样本的可靠性与特征空间的代表性。基于此,分别基于三类稳定性评价指标划定稳定区域。为了避免样本类别不平衡对模型训练的影响,保证不同负样本策略之间对比分析的可比性,本研究采用1:1的正负样本比例进行采样。具体而言,在划定的稳定区域内随机提取与滑坡正样本数量相等的46405个栅格单元作为滑坡负样本,分别构建“Fs-样本集”、“Dn-样本集”与“Pf-样本集”。同时,为避免将滑坡周边潜在不稳定区误判为负样本,并确保正负样本在空间上的独立性,本研究在滑坡边界外构建100m缓冲区,并在缓冲区范围之外选取负样本。

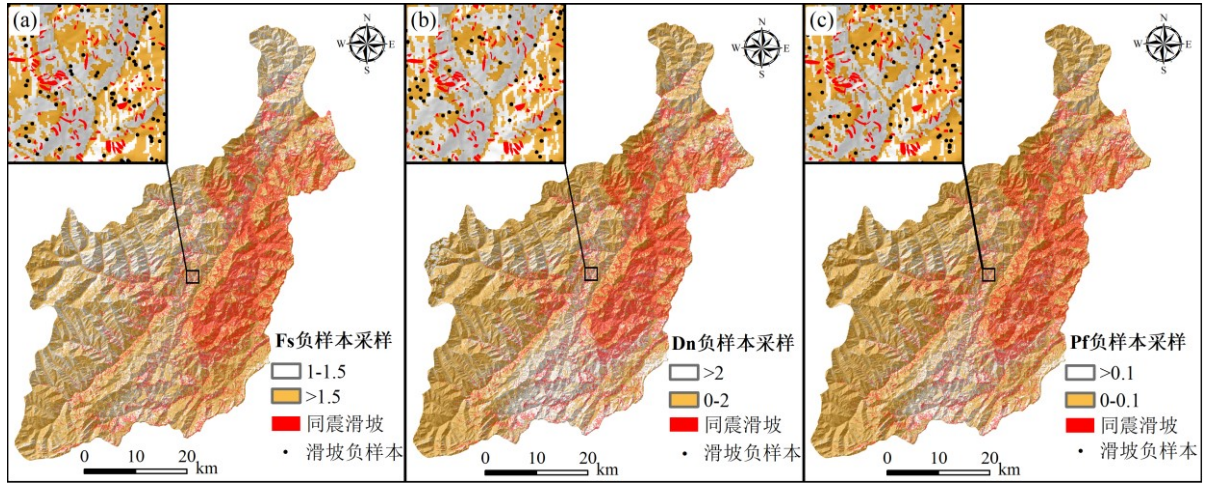


图 9 基于三类稳定性评价指标的滑坡负样本分布图

Fig. 9 Spatial distribution of negative sample based on three stability indicators

图 9 展示了三类滑坡负样本在研究区内的空间分布特征，图中红色区域为已识别的同震滑坡，黑色点为对应策略下选取的滑坡负样本。可见，三种策略所划定的稳定区域在空间范围上存在一定差异，但总体分布格局较为一致。此外，多数同震滑坡分布于稳定区域之外，表明基于 Fs、Dn 和 Pf 构建的负样本具有较好的代表性与合理性。

3.2 地震滑坡易发性制图

为系统评估不同负样本选取策略与模型算法对地震滑坡易发性预测结果的影响，本研究基于三类负样本数据集与三种机器学习算法构建了 9 种组合模型，分别为 Fs-LR、Fs-RF、Fs-CNN，Dn-LR、Dn-RF、Dn-CNN，以及 Pf-LR、Pf-RF、Pf-CNN。所有模型的输入均为统一筛选得到的 12 个滑坡影响因子，输出为研究区各单元的地震滑坡发生概率。为保证不同负样本构建策略与模型之间对比分析的可比性，所有样本数据集统一采用固定的训练/测试划分比例（70:30）进行模型训练与验证。在模型训练过程中，本文采用贝叶斯优化算法对 LR、RF 和 CNN 三种模型的关键超参数进行自动调优。各模型超参数在优化前均设置合理搜索范围，例如 CNN 模型的卷积核数量（Filters）设为[32, 64, 128]，因此不同负样本选取策略下得到的超参数最优值可能存在差异。同理，LR 和 RF 模型的正则化系数、最大深度及决策树数量等参数亦通过同样方式自动确定。表 3 为各模型在训练集上的最优超参数设置。

在完成训练后，利用 9 种模型进行研究区地震滑坡易发性评价，得到所有栅格单元的滑坡易发性指数。然后，利用 ArcGIS 软件中的自然断点法将研究区划分为 5 个易发性分区：极低、低、中、高、极高易发区，结果如图 10 所示。从图中可以看出，虽然 9 种模型的预测结果在细节上存在一些差异，但总体趋势一致。高和极高易发区分布广泛，主要集中于研究区的东部、东南部和中部。研究区的西部和西南部主要由低和极低易发区组成。研究区整体的易发性趋势与地形、河流、地震等特征密切相关。

此外，为了量化各个模型在滑坡易发性评价结果上的差异，统计了上述 9 种模型易发性分区面积、滑坡面积占比和滑坡密度，如表 4 所示。统计结果显示，随着滑坡易发性等级的升高，滑坡数量和滑坡密度呈逐级增长趋势，尤其在“极高”易发区内，滑坡占比和密度均显著高于其他等级，各模型能够较好地识别滑坡高风险区域。例如，Dn-CNN 模型在“极高”易发区内滑坡占比为 56.32%、滑坡密度为 2.227，均为所有组合中最高，Pf-CNN 次之（55.42%、1.921），Fs-CNN 略低（49.80%、1.910），说明

基于 Dn 与 Pf 负样本选取策略更有助于聚焦高风险区。在“极低”易发区中，Dn-CNN 的滑坡密度最低，仅为 0.060，表明其具备更强的非滑坡区域识别能力。

表 3 三种模型主要超参数设置

Table 3 The main hyperparameters in the three models

模型	主要超参数	解释	模型数据集		
			Fs	Dn	Pf
LR	C	正则化系数，用于降低欠拟合	1	40	10
	solver	优化算法，采用随机平均梯度下降法求解 损失函数	sag	sag	sag
	max_iter	最大迭代次数，用于确保优化过程收敛	8000	5000	10000
RF	max_depth	决策树的深度，影响模型的复杂度与过拟合 风险	8	10	8
	max_features	最大特征的比例，有助于增强模型的随机 性与泛化能力	0.8	0.8	1
	min_samples_split	内部节点再划分所需的最小样本数，防止 模型过拟合	2	2	6
	n_estimators	决策树的数量，影响模型稳定性和精度	145	120	220
CNN	learning_rate	学习率，决定模型权重更新的步长大小	$1e^{-3}$	$1e^{-3}$	$1e^{-3}$
	dropout_rate	Dropout 丢弃率，用于防止过拟合，提高 模型的泛化能力	0.2	0.4	0.2
	Filters	卷积核数量，提取输入特征的空间模式	64	128	64
	kernel_size	卷积核大小，影响局部特征提取能力	2	2	2

表 4 不同评价模型易发性分区结果统计表

Table 4 Statistics on the results of susceptibility zones of different evaluation models

模型名称	易发等级	Fs-LR	Fs-RF	Fs-CNN	Dn-LR	Dn-RF	Dn-CNN	Pf-LR	Pf-RF	Pf-CNN
易发性面积 百分比/%	极低	24.11	29.33	33.72	26.74	29.77	33.80	26.76	21.12	30.65
	低	20.58	19.56	14.67	18.49	15.47	12.58	20.27	19.40	13.45
	中	17.92	12.87	12.55	15.87	13.37	10.46	14.36	14.70	10.80
	高	15.47	15.65	12.98	16.48	15.98	17.87	16.17	18.13	15.86
	极高	21.92	22.59	26.08	22.42	25.41	25.29	22.44	26.65	28.84
滑坡面积百 分比/%	极低	4.80	1.87	2.38	4.31	2.21	2.03	3.95	3.12	3.13
	低	10.0	9.10	7.76	8.64	7.41	6.80	9.45	7.68	7.68
	中	16.66	17.63	15.98	13.20	14.30	13.09	14.40	14.56	13.81
	高	27.58	29.04	24.08	30.73	23.74	21.76	30.10	24.40	19.96
	极高	40.96	42.36	49.80	43.12	52.34	56.32	42.10	50.24	55.42
滑坡密度	极低	0.199	0.064	0.071	0.161	0.074	0.060	0.148	0.148	0.102
	低	0.487	0.465	0.529	0.467	0.479	0.541	0.466	0.396	0.571
	中	0.930	1.369	1.273	0.831	1.070	1.250	1.003	0.990	1.277
	高	1.782	1.855	1.854	1.864	1.485	1.218	1.862	1.346	1.259
	极高	1.869	1.876	1.910	1.923	2.060	2.227	1.877	1.885	1.921

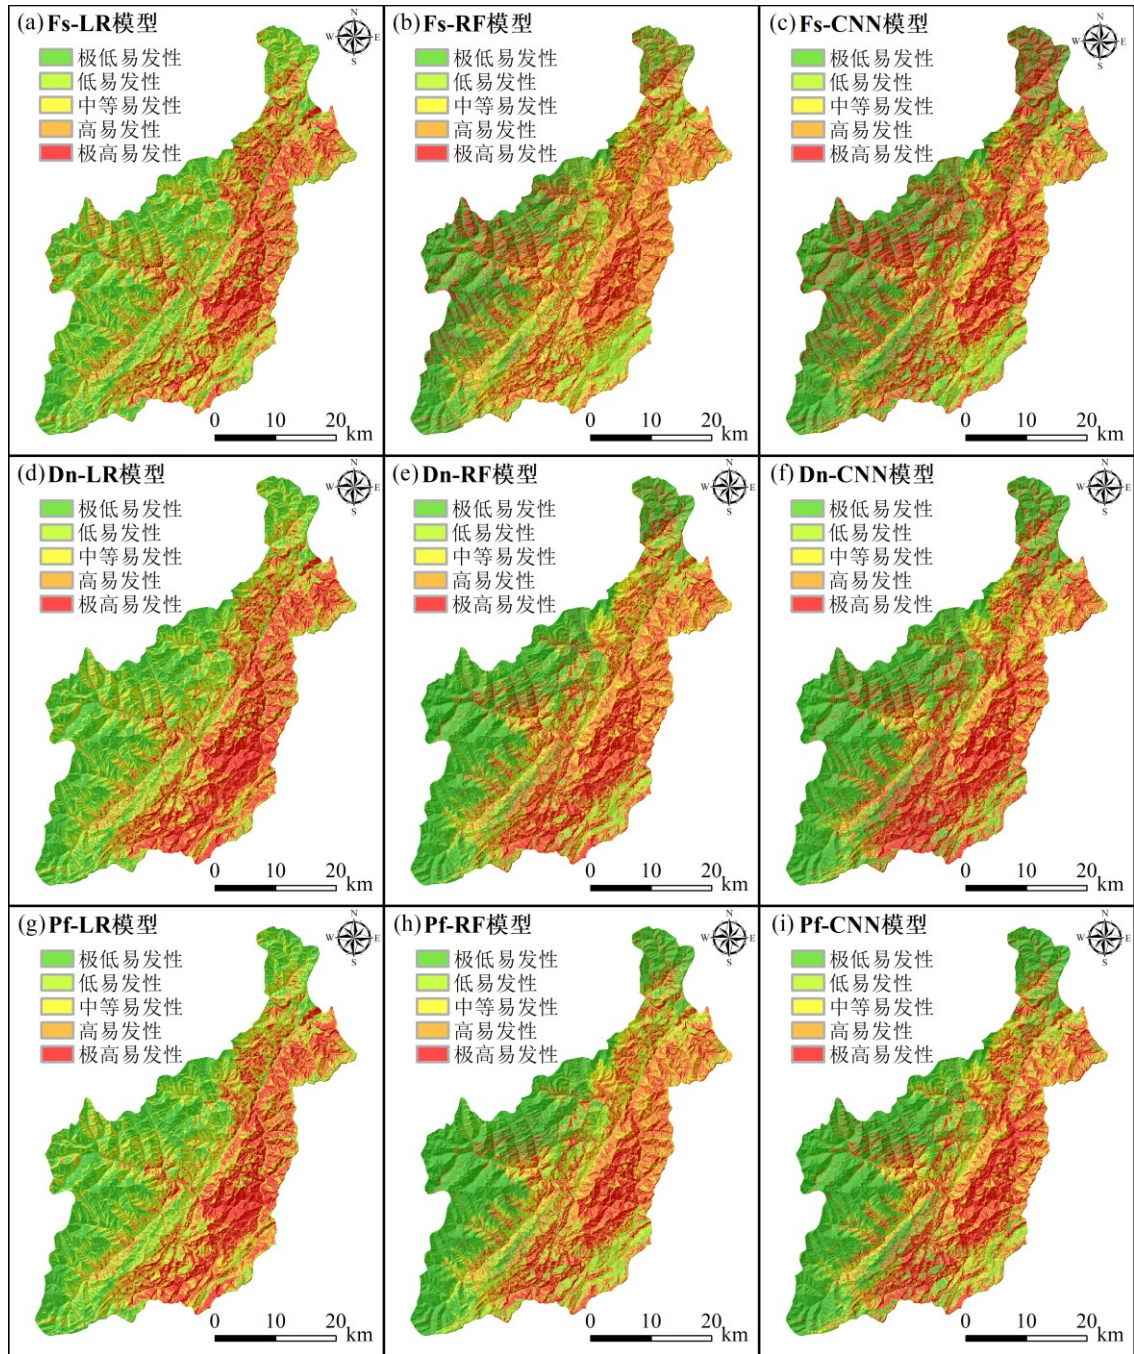


图 10 不同评价模型地震滑坡易发性分区图

Fig. 10 Landslide susceptibility zones maps for different evaluation models

3.3 模型性能评估

基于测试集样本，绘制了不同评价模型的 ROC 曲线，以评估模型的预测性能，结果见图 11。结果显示，这 9 种模型的 AUC 值均超过 0.85，表明整体预测性能较好。其中，Dn-CNN 模型表现最优，AUC 值达到 0.924；Dn-CNN 和 Fs-CNN 模型亦表现突出，AUC 值分别为 0.912 和 0.908。相比之下，Fs-LR 模型的 AUC 值相对较低，为 0.860，但仍具备良好的识别能力。从同一负样本选取策略下的模型表现来看，CNN 模型的表现均优于 RF 和 LR，显示出其在复杂地形与多因子背景下更强的特征提取能力；RF 模型则普遍优于 LR 模型，验证了集成方法在滑坡分类任务中的鲁棒性优势。从同一模型在不同策

略下的表现来看，基于 Dn 选取策略的模型普遍取得更高 AUC 值，其次为 Pf 选取策略，Fs 选取策略相对较低。这表明，Dn 选取策略通过引入地震动参数进行稳定性刻画，能够构建更具物理代表性的非滑坡样本，进而提高模型的预测能力与泛化性能。总体来看，基于三种稳定性评价指标（Fs、Pf、CNN）的负样本选取策略与不同评价模型（LR、RF、CNN）的组合均展现出较高的鲁棒性和滑坡识别能力。




图 11 不同负样本选取策略下各模型的 ROC 曲线图：(a) Fs 负样本选取；(b) Dn 负样本选取；(c) Pf 负样本选取

Fig. 11 ROC curves of different models under three negative sample selection strategies: (a) Fs-based sampling; (b) Dn-based sampling; (c) Pf-based sampling




图 12 模型性能评价指标

Fig. 12 Evaluation index of the model performance

同时，使用准确率、灵敏度、特异度三种模型性能指标对 9 种模型进行分类能力进行评估，结果如图 12 所示。总体来看，各模型取得了较高的性能指标，表现出良好的分类能力，准确率范围为 0.776-0.839，灵敏度为 0.778-0.845，特异度为 0.774-0.833。其中，Dn-CNN 模型在三项指标中均为最高，分别达到

0.839（准确率）、0.845（灵敏度）和 0.833（特异度），显示出在地震滑坡识别任务中最优的综合性能；Pf-CNN 次之，三项指标分别为 0.824、0.827 和 0.822；Fs-CNN 略低，但依然保持较高水平。而在同一模型结构下，Dn 策略对应的模型性能均优于 Pf 与 Fs 策略，进一步验证了其在负样本构建中的有效性。相比之下，Fs-LR 模型在三项指标中均为最低，表明线性模型在处理复杂地震滑坡分类任务中的适用性有限。上述结果进一步证实了深度学习模型与基于物理机制的负样本构建策略相结合的有效性。

4 讨论

4.1 地震滑坡评价因子重要性分析

在地震滑坡易发性评价中，评价因子重要性分析是揭示滑坡致灾主导因素和区域特征分布的关键。本研究基于最优模型 Dn-CNN 利用 SHAP（SHapley additive exPlanations）方法对滑坡评价因子进行重要性分析，结果如图 13 所示。当特征重要性评分越高，表明该评价因子对滑坡发生的影响越大。从图中可以看出，地震动峰值加速度的重要性评分显著高于其他因子，表明滑坡的发生与地震密切相关，与实际情况一致。坡度和坡位的重要性紧随其后，说明地形陡峭程度及地形部位对滑坡形成具有重要影响，符合地震作用下高位陡坡更易失稳的地质力学特征。此外，距断层距离、地形起伏度和工程地质岩组等因子也具有较高的重要性，反映了构造条件、岩性特征及地形复杂程度在地震滑坡中的关键作用。

图 14 为 SHAP 计算结果的特征摘要图，展示了影响因子重要性及其特征值分布的全局解释。其中每个点代表一个真实的样本，点的颜色反映评价因子值的大小：值越大颜色越红，值越小颜色越蓝。横坐标为 SHAP 值，用于衡量各影响因子对模型预测的贡献程度和影响。当 SHAP 值为正时，表明该因子对滑坡发生具有显著的正向作用。从图中可以看出，地震动峰值加速度是对滑坡影响最显著的因子，且随其值的增加，SHAP 值显著增大，滑坡发生的概率也随之提高。同时，坡度和坡位的高值对应较大的 SHAP 正值，表明陡坡及特定坡位更容易发生滑坡。而距断层距离的 SHAP 值呈负相关的趋势，随着距离的增加，其对滑坡发生的贡献逐渐减弱，反映断裂带附近地震动放大效应或岩体破碎影响显著。此外，地形起伏度和工程地质岩组这两个因子对滑坡的影响也较大，说明地形起伏较大的区域往往坡陡谷深，地表破碎，易诱发滑坡；而松软岩层在地震作用下更易失稳，滑坡风险显著增加。相比之下，地形湿度指数与距河流距离的 SHAP 值最小，表明其在地震诱发滑坡中的作用有限。




图 13 滑坡评价因子的特征重要性排序

Fig. 13 Feature importance ranking of landslide evaluation factors




图 14 SHAP 特征摘要图

Fig. 14 Summary map of SHAP feature

4.2 负样本选取策略对评价结果影响

本研究系统对比了三种滑坡负样本选取策略：基于安全系数（Fs）、永久位移（Dn）和滑坡失效概率（Pf）的方法。通过分析各策略下模型在不同易发区的滑坡面积占比、滑坡密度及分类性能指标，可以清晰揭示各方法在识别滑坡风险区域方面的差异。

从“极高”易发性区域的滑坡面积占比来看（表 4），采用 Dn 和 Pf 选取策略的模型整体优于 Fs 策略。以 CNN 模型为例，Dn-CNN 和 Pf-CNN 的滑坡占比分别为 56.32%和 55.42%，显著高于 Fs-CNN 的 49.80%；RF 模型中，Dn-RF 和 Pf-RF 为 52.34%和 50.24%，亦明显高于 Fs-RF 的 42.36%；即便是相对性能较弱的 LR 模型，Dn-LR 和 Pf-LR（43.12%、42.10%）也优于 Fs-LR（40.96%）。这表明无论在何种评价模型下，基于 Dn 和 Pf 的负样本选取策略均能更有效聚焦实际滑坡区域，提高地震滑坡高风险区的识别能力。

滑坡密度的比较结果进一步验证了上述趋势。在“极高”易发区，Dn-CNN 模型的滑坡密度最高（2.227），Pf-CNN 次之（1.921），Fs-CNN 最低（1.910）。RF 与 LR 模型亦呈现相同顺序，Dn-RF（2.060）>Pf-RF（1.885）>Fs-RF（1.876）；Dn-LR（1.923）>Pf-LR（1.877）>Fs-LR（1.869）。与此同时，Dn 在“极低”易发性区域中的滑坡密度更低，特别是 Dn-CNN 在“极低”易发性区域的密度仅为 0.060，表明其在低风险区域具有更强的非滑坡识别能力。

在模型性能指标方面（图 11 和图 12），Dn 选取策略在三类模型（LR、RF、CNN）中均表现出更优的分类能力。Dn-CNN 在四项指标中表现最优，AUC 值达 0.924，准确率为 0.839，灵敏度为 0.845，特异度为 0.833。其次是 Pf-CNN 模型，AUC 值为 0.912，准确率为 0.824，灵敏度为 0.827，特异度为 0.822。相比之下，Fs-CNN 模型表现略逊，AUC 值为 0.908，准确率（0.818）、灵敏度（0.814）和特异度（0.821）均低于 Dn 和 Pf 选取策略。类似趋势在 RF 与 LR 模型中同样存在。

综上所述, Dn 负样本选取策略在地震滑坡识别中表现最优, 其次为 Pf, Fs 相对较弱。Fs 策略仅依据静态安全系数构建负样本, 未考虑地震等外部扰动因素, 容易误判临界不稳定区域, 降低模型区分能力。Pf 策略在一定程度上引入了地震因素, 但其通过经验公式将 Dn 转换为概率指标, 更侧重对滑坡发生可能性的统计描述, 使位移信息在表达过程中被重新整合, 导致不同斜坡单元之间的差异特征有所减弱。从而使负样本的物理约束不如 Dn 明确。尽管 Pf 与 Dn 在理论上具有较高相关性, 但二者在数值分布形式及对斜坡稳定性信息的表征重点上仍存在差别, 进而使基于二者构建的负样本策略在模型性能和空间识别能力上表现出一定差异。相比之下, Dn 策略以 Newmark 永久位移刻画潜在斜坡的变形程度, 能够更直观、敏感地反映不同斜坡单元之间的稳定性差异, 其构建的负样本更具物理意义和区分度, 从而显著提升模型在不同易发性区域中的识别精度与稳定性。总体而言, Dn 选取方法在兼顾物理机制与数据分布特征的基础上, 展现出更高的预测能力和泛化能力, 为地震滑坡易发性建模提供了更为可靠的负样本构建思路。

4.3 评价模型对评价结果影响

为探讨评价模型本身对地震滑坡易发性评价结果的影响, 本研究在相同负样本选取策略下, 系统比较了逻辑回归 (LR)、随机森林 (RF) 与卷积神经网络 (CNN) 三类模型在空间识别能力与分类性能方面的差异。

从“极高”易发性区域的滑坡面积占比来看 (表 4), CNN 模型在三种选取策略下的表现均优于 RF 与 LR 模型。例如在 Dn 策略下, Dn-CNN 的滑坡占比为 56.32%, 高于 Dn-RF (52.34%) 和 Dn-LR (43.12%); Pf 策略下为 Pf-CNN (55.42%) > Pf-RF (50.24%) > Pf-LR (42.10%); Fs 策略下则为 Fs-CNN (49.80%) > Fs-RF (42.36%) > Pf-LR (40.96%)。滑坡密度亦呈现一致趋势, CNN 模型在“极高”易发性区域密度普遍最高, 同时在“极低”区密度较低, 表现出更强的高风险识别和划分能力。

在模型性能评估方面 (图 11 和图 12), CNN 模型在各项指标上均取得最优结果。在三种选取策略下, Fs-CNN、Pf-CNN 和 Dn-CNN 的 AUC 值分别为 0.908、0.924 和 0.912, 均为最高。RF 模型次之, AUC 在 0.898-0.921 之间; LR 模型相对较低, AUC 范围为 0.860-0.883。准确率、灵敏度和特异度三项指标中, CNN 模型同样表现最优, Dn-CNN 为 0.839 (准确率)、0.845 (灵敏度) 和 0.833 (特异度), 全面优于 Dn-RF 和 Dn-LR。表明 CNN 模型有更强的特征提取能力与非线性拟合能力, 更适用于地震滑坡这一类成因复杂、影响因素多样的易发性评价。

相比之下, RF 模型作为一种集成学习方法, 表现亦较为稳健, 在多项指标上显著优于线性模型 LR, 且对选取策略的适应性较强。LR 模型则由于其线性结构限制, 在处理复杂且高度非线性数据的表现上相对较弱, 尤其在地质条件复杂的地震区域, 其滑坡占比与模型精度均明显低于 CNN 与 RF 模型。

综上所述, 评价模型的选取对地震滑坡易发性评价结果具有显著影响。CNN 模型凭借深层特征提取和预测能力, 在滑坡识别和滑坡分类方面均表现最优; RF 模型次之, 兼具较强泛化能力与模型稳定性; LR 模型虽计算效率高, 但预测精度受限, 适用性相对较低。特别是结合图 11 的对比结果可以看出, 相较于传统机器学习模型, CNN 在不同负样本策略下均能取得更优的预测效果, 这表明深度学习模型在挖掘高维特征和提升整体识别能力方面具有关键的主导作用; 但与此同时, 不同负样本构建策略之间仍存在稳定的性能差异, 说明合理引入物理约束以优化样本质量, 是进一步提升模型预测能力的重要基

础。由此可见，CNN 模型结构优势与物理约束负样本策略在本研究中发挥了相互协同的作用，共同促进了地震滑坡易发性评价精度的提升。因此，在构建地震滑坡易发性评价模型时，应优先考虑具备高度非线性建模能力和空间泛化能力的深度学习模型，以提升风险识别的精度与可靠性。

5 结论

本研究针对地震滑坡易发性评价中负样本选择的科学性问题，采用融合物理机制的负样本优化策略，基于安全系数（Fs）、永久位移（Dn）和滑坡失效概率（Pf）三类稳定性评价指标划分稳定区域，构建滑坡样本数据集，并结合逻辑回归（LR）、随机森林（RF）和卷积神经网络（CNN）模型，系统评估了不同负样本策略与模型选择对评价结果的影响，得出以下结论：

（1）基于三种负样本选取策略与三种模型的 9 种组合均表现出较优的分区效果和预测性能。结果表明，高易发性区主要集中于研究区东部、中部和东南部，低易发性区域则分布于西部边缘地带，区划结果整体与地形、断裂和地震动分布较为吻合。

（2）在所有负样本选取策略中，基于 Dn 选取策略的滑坡预测效果最好，模型精度整体高于 Fs 与 Pf 策略。相较于仅考虑静态稳定性的 Fs 选取策略，以及基于统计概率的 Pf 选取策略，Dn 选取策略综合考虑了地震动参数及位移响应特征，构建的负样本更能反映地震诱发滑坡的物理机制。

（3）在相同负样本选取策略下，CNN 模型在滑坡识别任务中整体表现优于 LR 与 RF 模型。其凭借其强大的特征提取能力与非线性表达能力，能够更有效地捕捉滑坡成因因子之间的复杂耦合关系。

（4）利用 SHAP 进行滑坡评价因子重要性分析，结果表明地震动峰值加速度对滑坡的影响最为显著。此外坡度、坡位和断层距离等因子也具有较高的重要性，表明滑坡受地震动、地形特征和构造活动等多重因素的综合控制作用

综上所述，基于 Dn 选取策略与 CNN 构建的 Dn-CNN 模型在滑坡划分效果和预测精度等方面表现最好，具有较高的预测能力和物理解释性。该方法充分融合地震物理机制与深度学习优势，为地震滑坡易发性评价中负样本构建与模型选取提供参考。

References

- Breiman, L. 2001. Random Forests. *Machine learning*, 45 (1): 5-32. doi:10.1023/A:1010933404324.
- Chang, M., Zhou, Y., Zhou, C., et al. 2021. Coseismic Landslides Induced by the 2018 Mw 6.6 Iburi, Japan, Earthquake: Spatial Distribution, Key Factors Weight, and Susceptibility Regionalization. *Landslides*, 18 (2): 755-772. doi:10.1007/s10346-020-01522-3.
- Chen, C., Shen, Z., Weng, Y., et al. 2023. Modeling Landslide Susceptibility in Forest-covered Areas in Lin'an, China, Using Logistical Regression, a Decision Tree, and Random Forests. *Remote Sensing*, 15 (18): 4378. doi:10.3390/rs15184378.
- Chen, S., Miao, Z. L., Wu, L. X. 2022. A Method for Seismic Landslide Hazard Assessment Using Simplified Newmark Displacement Model Based on Modified Strength Parameters of Rock mass. *Acta Seismologica Sinica*, 44 (3): 512-527 (in Chinese with English abstract). doi:10.11939/jass.20210008.
- Chen, S., Wu, L.X., Miao, Z.L. 2023. Regional Seismic Landslide Susceptibility Assessment Considering the Rock Mass Strength Heterogeneity. *Geomatics Natural Hazards and Risk*, 14 (1): 1-27. doi:10.1080/19475705.2022.2152392.
- Dai, F.C., Xu, C., Yao, X., et al. 2011. Spatial Distribution of Landslides Triggered by the 2008 Ms 8.0 Wenchuan

- Earthquake, China. *Journal of Asian Earth Sciences*, 40 (4): 883-895. doi:10.1016/j.jseaes.2010.04.010.
- Ding M.T., Jiang H., Li Z.H., et al. 2025. Earthquake-Induced Landslide Susceptibility Assessment by Fusing Convolutional Fuzzy Neural Network and SHAP Feature Optimization Strategy. *Geomatics and Information Science of Wuhan University*, 1-26 (in Chinese with English abstract). doi:10.13203/J.whugis20250017.
- Dou, J., Xing, K., Wang, L., et al. 2025. Air-Space-Ground Synergistic Observations for Rapid Post-Seismic Disaster Assessment of 2025 Ms6.8 Xigazê Earthquake, Xizang. *Earth Science*, 36 (04): 1605-1622. doi:10.1007/s12583-025-0160-2.
- Dou, J., Xiang, Z. L., Xu, Q., et al. 2023. Application and Development Trend of Machine Learning in Landslide Intelligent Disaster Prevention and Mitigation, *Journal of Earth Science*, 48 (05): 1657-1674 (in Chinese with English abstract). doi:10.3799/dqkx.2022.419.
- Du J.L., Xu Y.J. 2025. Landslide Susceptibility Assessment Based on Random Forest and Convolutional Neural Network. *World Nuclear Geoscience*, 42(4) (in Chinese with English abstract). doi:10.3969/j.issn.1672-0636.2025.04.018.
- Ersayin, K., Uzun, A. 2025. A Comprehensive Analysis of Landslide Susceptibility in Iyidere Basin (NE, Turkey) Using Machine Learning Techniques and Statistical Bivariate Methods. *Natural Hazards*, 121 (12): 14283-14319. doi:10.1007/s11069-025-07354-5.
- Ge, Y., Liu, G., Tang, H., et al. 2023. Comparative Analysis of Five Convolutional Neural Networks for Landslide Susceptibility Assessment. *Bulletin of Engineering Geology and the Environment*, 82 (10): 377. doi:10.1007/s10064-023-03408-9.
- Guo, Y. H., Dou, J., Xiang, Z. L., et al. 2024. Susceptibility Evaluation of Wenchuan Coseismic Landslides by Gradient Boosting Decision Tree and Random Forest Based on Optimal Negative Sample Sampling Strategies. *Bulletin of Geological Science and Technology*, 43 (03): 251-265 (in Chinese with English abstract). doi:10.19509/j.cnki.dzkq.tb20230037.
- Gu, T., Li, J., Wang, M., et al. 2022. Landslide Susceptibility Assessment in Zhenxiong County of China Based on Geographically Weighted Logistic Regression Model. *Geocarto International*, 37 (17): 4952-4973. doi:10.1080/10106049.2021.1903571.
- Huang, F.M., Xiong, H.W., Jiang, S.H., et al. 2024. Modelling Landslide Susceptibility Prediction: A Review and Construction of Semi-supervised Imbalanced Theory. *Earth-Science Reviews*, 250: 104700. doi:10.1016/j.earscirev.2024.104700.
- Ji, J., Cui, H., Zhang, T., et al. 2022. A GIS-Based Tool for Probabilistic Physical Modelling and Prediction of Landslides: GIS-FORM Landslide Susceptibility Analysis in Seismic Areas. *Landslides*, 19 (9): 2213-2231. doi:10.1007/s10346-022-01885-9.
- Jiang, Z., Wang, M., Liu, K. 2023. Comparisons of Convolutional Neural Network and Other Machine Learning Methods in Landslide Susceptibility Assessment: A Case Study in Pingwu. *Remote Sensing*, 15 (3): 798. doi:10.3390/rs15030798.
- Jibson, R.W. 2007. Regression Models for Estimating Coseismic Landslide Displacement. *Engineering geology*, 91 (2-4): 209-218. doi:10.1016/j.enggeo.2007.01.013.
- Jibson, R.W., Harp, E.L., Michael, J.A. 2000. A Method for Producing Digital Probabilistic Seismic Landslide Hazard Maps. *Engineering Geology*, 58 (3-4): 271-289. doi:10.1016/S0013-7952(00)00039-9.
- Li, Y. W., Xu, L. R., Zhang, L. L., et al. 2023. Study on Development Patterns and Susceptibility Evaluation of Coseismic Landslides within Mountainous Regions Influenced by Strong Earthquakes. *Earth Science*, 48 (05): 1960-1976 (in Chinese with English abstract). doi: 10.3799/dqkx.2022.224.
- Liu, J.M., Wang, T., Du, J.J., et al. 2023. Emergency Rapid Assessment of Landslides Induced by the Luding Ms6.8

- Earthquake in Sichuan of China. *Hydrogeology & Engineering Geology*, 50 (2): 84-94 (in Chinese with English abstract). doi:10.16030/j.cnki.issn.1000-3665.202209057.
- Liu, L.C., Wang, P.Q., Su, L.B., et al. 2025. Landslide Data Sample Augmentation and Landslide Susceptibility Analysis in Nyingchi City Based on the MCMC Model. *Scientific Reports*, 15 (1): 25624. doi:10.1038/s41598-025-10651-5.
- Liu, S., Wang, L., Zhang, W., et al. 2023. A physics-informed data-driven model for landslide susceptibility assessment in the Three Gorges Reservoir area. *Geoscience Frontiers*, 14 (5): 101621. doi:10.1016/j.gsf.2023.101621.
- Liu, S., Wang, L., Zhang, W., et al. 2024. Physics-informed optimization for a data-driven approach in landslide susceptibility evaluation. *Journal of Rock Mechanics and Geotechnical Engineering*, 16 (8): 3192-3205. doi:10.1016/j.jrmge.2023.11.039.
- Liu, T., Zang, M., Peng, J., et al. 2024. Evaluating Coseismic Landslide Susceptibility Following the 2022 Luding Earthquake: A Comparative Analysis of Six Displacement Regression Models Integrating Epicentral and Seismogenic Fault Distances within the Permanent-Displacement Framework. *Remote Sensing*, 16 (14): 2675. doi:10.3390/rs16142675.
- Ma, S., Xu, C. 2019. Applicability of Two Newmark Models in the Assessment of Coseismic Landslide Hazard and Estimation of Slope-Failure Probability: An Example of the 2008 Wenchuan Mw 7.9 Earthquake Affected Area. *Journal of Earth Science*, 30 (5): 1020-1030. doi:10.1007/s12583-019-0874-0.
- Newmark, N.M. 1965. Effects of Earthquakes on Dams and Embankments. *Geotechnique*, 15 (2): 139-160. doi:10.1680/geot.1965.15.2.139.
- Parker, R.N., Densmore, A.L., Rosser, N.J., et al. 2011. Mass Wasting Triggered by the 2008 Wenchuan Earthquake Is Greater Than Orogenic Growth. *Nature Geoscience*, 4 (7): 449-452. doi:10.1038/ngeo1154.
- Rodríguez-Peces, M., García-Mayordomo, J., Azañón, J., et al. 2014. GIS Application for Regional Assessment of Seismically Induced Slope Failures in the Sierra Nevada Range, South Spain, Along the Padul Fault. *Environmental Earth Sciences*, 72 (7): 2423-2435. doi:10.1007/s12665-014-3151-7.
- Wang, Y., Cao, Y., Xu, F.D., et al. 2024. Reservoir Landslide Susceptibility Prediction Considering Non-Landslide Sampling and Ensemble Machine Learning Methods. *Earth Science*, 49 (05): 1619-1635 (in Chinese with English abstract). doi:10.3799/dqkx.2022.407.
- Xi, C., Han, M., Hu, X., et al. 2022. Effectiveness of Newmark-Based Sampling Strategy for Coseismic Landslide Susceptibility Mapping Using Deep Learning, Support Vector Machine, and Logistic Regression. *Bulletin of Engineering Geology and the Environment*, 81 (5): 174. doi:10.1007/s10064-022-02664-5.
- Xie, P., Wen, H., Ma, C., et al. 2018. Application and Comparison of Logistic Regression Model and Neural Network Model in Earthquake-Induced Landslides Susceptibility Mapping at Mountainous Region, China. *Geomatics, Natural Hazards and Risk*, 9 (1): 501-523. doi:10.1080/19475705.2018.1451399.
- Xu, C., Xu, X., Yao, X., et al. 2014. Three (Nearly) Complete Inventories of Landslides Triggered by the May 12, 2008 Wenchuan Mw 7.9 Earthquake of China and Their Spatial Distribution Statistical Analysis. *Landslides*, 11 (3): 441-461. doi:10.1007/s10346-013-0404-6.
- Yang, S., Li, D., Sun, Y., et al. 2024. Effect of Landslide Spatial Representation and Raster Resolution on the Landslide Susceptibility Assessment. *Environmental Earth Sciences*, 83 (4): 132. doi:10.1007/s12665-024-11442-3.
- Zhang, Q.K., Ling, S.X., Li, X.N., et al. 2020. Comparison of Landslide Susceptibility Mapping Rapid Assessment Models in Jiuzhaigou County, Sichuan Province, China. *Chinese Journal of Rock Mechanics and Engineering*, 39 (8): 1595-1610 (in Chinese with English abstract). doi:10.13722/j.cnki.jrme.2020.0029.

- Zeng, Y., Zhang, Y.B., Liu, J., et al. 2023. Assessment of Earthquake-Induced Landslide Hazard Zoning Using the Physics-Environmental Coupled Model. *Journal of Mountain Science*, 20 (9): 2644-2664. doi:10.1007/s11629-023-7947-3.
- Zeng Y., Zhang Y.B., Chu F., et al. 2024. Rapid Assessment of Landslides Induced by Jishishan Ms6.2 Earthquake in Gansu Province. *Journal of Southwest Jiaotong University*, 60: 1-10 (in Chinese with English abstract).
- Zhao, F., Miao, F., Wu, Y., et al. 2024. Refined Landslide Susceptibility Mapping in Township Area Using Ensemble Machine Learning Method under Dataset Replenishment Strategy. *Gondwana Research*, 131: 20-37. doi:10.1016/j.gr.2024.02.011.
- Zhao, T. Y., Peng, H. Z., Wang, Y., et al. 2025. Improving Landslide Susceptibility Assessment by Optimization of Spatial Locations of Non-Landslide Samples. *Journal of Engineering Geology*, 1-11 (in Chinese with English abstract). doi:10.13544/j.cnki.jeg.2023-0160.
- 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 (05): 1654-1664 (in Chinese with English abstract). doi:10.3799/dqkx.2023.113.

中文参考文献

- 陈帅, 苗则朗, 吴立新. 2022. 基于修正岩土体强度参数的简化纽马克位移法地震滑坡危险性快速评估技术. *地震学报*, 44 (3): 512-527.
- 丁明涛, 江辉, 李振洪, 等. 2025. 融合卷积模糊神经网络与 SHAP 特征优化的地震诱发滑坡易发性评价. *武汉大学学报 (信息科学版)* doi: 1-26.
- 窦杰, 向子林, 许强, 等. 2023. 机器学习在滑坡智能防灾减灾中的应用与发展趋势. *地球科学*, 48 (05): 1657-1674.
- 杜继龙, 徐元进. 2025. 基于随机森林和卷积神经网络的滑坡易发性评价. *世界核地质科学*, 42 (4).
- 郭衍昊, 窦杰, 向子林, 等. 2024. 基于优化负样本采样策略的梯度提升决策树与随机森林的汶川同震滑坡易发性评价. *地质科技通报*, 43 (03): 251-265.
- 李永威, 徐林荣, 张亮亮, 等. 2023. 强震山区地震诱发滑坡发育规律与易发性评估. *地球科学*, 48 (05): 1960-1976.
- 刘甲美, 王涛, 杜建军, 等. 2023. 四川泸定 M S 6.8 级地震诱发崩滑灾害快速评估. *水文地质工程地质*, 50 (2): 84-94.
- 王悦, 曹颖, 许方党, 等. 2024. 考虑非滑坡样本选取和集成机器学习方法的水库滑坡易发性预测. *地球科学*, 49 (05): 1619-1635.
- 曾莹, 张迎宾, 储峰, 等. 2024. 甘肃积石山 Ms6.2 级地震诱发滑坡快速评估. *西南交通大学学报*, 60: 1-10.
- 张玘恺, 凌斯祥, 李晓宁, 等. 2020. 九寨沟县滑坡灾害易发性快速评估模型对比研究. *岩石力学与工程学报*, 39 (8): 1595-1610.
- 赵腾远, 彭洪振, 王宇, 等. 2025. 借助非滑坡点空间位置优化的滑坡易发性评价性能提升研究. *工程地质学报*, 1-11.
- 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 (05): 1654-1664.