引用格式：孙萍，张帅，柯超英，等，2025. 黄土高原滑坡易发性评价及其关键驱动因子贡献度分析[J]. 地质力学学报，31（5）：972−989. DOI：10.12090/j.issn.1006-6616.2025088

Citation: SUN P，ZHANG S，KE C Y，et al.，2025. Evaluation of landslide susceptibility and contribution analysis of key driving factors on the Loess Plateau[J]. Journal of Geomechanics，31（5）：972−989. DOI：10.12090/j.issn.1006-6616.2025088

黄土高原滑坡易发性评价及其关键驱动因子贡献度分析

孙　萍[1,2]，张　帅[1,2]，柯超英[1,2]，李　冉[1,2]，桑康云[1,2]，李　坤[1,2]，王浩杰[1,2]
SUN Ping[1,2]，ZHANG Shuai[1,2]，KE Chaoying[1,2]，LI Ran[1,2]，SANG Kangyun[1,2]，LI Kun[1,2]，WANG Haojie[1,2]

1. 中国地质科学院地质力学研究所，北京 100081；
2. 自然资源部陕西宝鸡地质灾害野外科学观测研究站，陕西 宝鸡 721001
1. *Institute of Geomechanics*, *Chinese Academy of Geological Sciences*, *Beijing* 100081, *China*;
2. *Observation and Research Station of Geological Disaster in Baoji*, *Shaanxi Province*, *Ministry of Natural Resources*, *Baoji* 721001, *Shaanxi*, *China*

Evaluation of landslide susceptibility and contribution analysis of key driving factors on the Loess Plateau

Abstract: ［**Objective**］The Loess Plateau is a region critically susceptible to landslides, posing significant risks to human life and infrastructure. Accurate identification of prone areas is vital for disaster mitigation. However, current coupled models often suffer from limitations: they rely on simplistic combinations or default parameters without systematic hyperparameter optimization and fail to achieve deep integration at the feature level, resulting in suboptimal performance and interpretability. This study aims to overcome these shortcomings by developing systematically optimized models and leveraging interpretability tools to elucidate the underlying mechanisms of landslide occurrence. ［**Methods**］Based on a multicollinearity analysis, thirteen evaluation factors were selected for model construction. We developed three landslide susceptibility models: an extreme gradient boosting (XGBoost) model, a frequency ratio-coupled XGBoost (FR–XGBoost) model, and a frequency ratio-coupled random forest (FR–RF) model. A key advancement in our methodology was the employment of the Optuna framework for the systematic and automated optimization of model hyperparameters to enhance predictive performance. Furthermore, to overcome the “ black-box” nature of machine learning models and gain mechanistic insights, we applied shapley additive explanations (SHAP) and partial dependence plots (PDPs) to interpret the models, identify key driving factors, and reveal their interaction effects. ［**Results**］The results demonstrated significant performance differences among the three models. The coupled models, FR–XGBoost and FR–RF, substantially outperformed the single XGBoost model, with AUC values of 0.968 and 0.963, respectively, compared to 0.805 for the single model. This not only confirms the superior predictive capability achieved by integrating the frequency ratio but also validates the effectiveness of the systematic hyperparameter optimization using the Optuna framework and the selection of evaluation factors. Interpretability analysis using SHAP provided quantitative insights into the factor contributions. Annual average rainfall was identified as the most critical driving factor, with a SHAP contribution value of 26.59%. Soil

基金项目：国家重点研发计划课题（2023YFC3007002）；国家自然科学基金重点项目 (42130720)；国家自然科学基金重大项目 (42293352，42293350)；国家自然科学基金青年科学基金项目 (42207234，42302333，42307267)；中国地质科学院地质力学所基本科研业务费项目（DZLXJK202411）

This research is financially supported by the National Key R&D Program of China (Grant No. 2023YFC3007002), the Key Program of the National Natural Science Foundation of China (NSFC) (Grant No. 42130720), the NSFC Major Programs (Grant Nos. 42293352 and 42293350), the NSFC Fund for Young Scholars (Grant Nos. 42207234, 42302333 and 42307267), and the Scientific Research Fund of the Institute of Geomechanics, Chinese Academy of Geological Sciences (Grant No. DZLXJK202411).

第一作者：孙萍（1978—），女，研究员，主要从事重大地质灾害机理与风险防控研究。Email：sunpingcgs@foxmail.com
通信作者：张帅（1988—），男，副研究员，主要从事重大地质灾害机理与风险防控研究。Email：13269675138@163.com

收稿日期：2025−07−18；**修回日期**：2025−09−07；**录用日期**：2025−09−07；**网络出版日期**：2025−09−23；**责任编辑**：王婧

erodibility and slope gradient followed, contributing 20.80% and 14.66% to the model output, respectively. These three factors collectively dominated the landslide susceptibility pattern in the study area. Further analysis using PDPs revealed the specific functional relationships and interactions between these key factors. The influence of annual average rainfall and soil erodibility on landslide occurrence was predominantly positive and monotonically increasing; their predictive contributions became particularly pronounced above thresholds of approximately 400 mm and 0.04, respectively. Conversely, the relationship between slope gradient and landslide susceptibility was non-monotonic. The effect exhibited a distinct single-peak pattern, where susceptibility increased with slope up to an optimal interval of 5° to 20°, beyond which it gradually decreased. Critically, PDPs revealed significant nonlinear interactions among key driving factors. A distinct synergistic effect was observed under the combined conditions of moderate-low slope gradients (5°–20°), high annual average rainfall (>400 mm), and high soil erodibility (>0.04), defining a characteristic high-risk scenario where landslide probability is substantially amplified. This specific combination pattern provides a quantifiable criterion for identifying the highest-risk areas within the Loess Plateau. We recommend prioritizing enhanced monitoring and engineering interventions in zones where these three factors overlap, and incorporating the established thresholds into local disaster prevention plans as key indicators for early risk identification. [**Conclusion**] This study demonstrates that the coupled model achieves higher predictive accuracy than the single model. Annual average rainfall, soil erodibility, and slope gradients were identified as the key driving factors for landslide development in the study area. Furthermore, complex nonlinear interactions exist among these key factors, which significantly influence landslide occurrence. [**Significance**] This study delivers a high-precision landslide susceptibility map for the Loess Plateau, supporting practical disaster prevention and land-use planning; more profoundly, the interpretability analysis (SHAP and PDP) provides mechanistic insights into landslide initiation, establishing a vital scientific basis for risk management and infrastructure development.

Keywords: Loess Plateau; Landslide; Susceptibility assessment; Machine learning; Model interpretabili

摘　要：黄土高原滑坡灾害高发，明确滑坡易发区格局及识别关键驱动因子对该区域防灾减灾及重大工程建设具有重要意义。文章以黄土高原滑坡为研究对象，通过多重共线性分析筛选出13个评价因子，构建了极端梯度上升模型（XGBoost）、频率比耦合XGBoost模型（FR−XGBoost）和频率比耦合随机森林（FR−RF）的优化评价模型；从模型可解释性的角度深入探讨了关键驱动因子的作用机制与交互关系。结果表明：耦合模型（FR−XGBoost与FR−RF）预测性能优于单一XGBoost模型，其中FR−XGBoost模型AUC值达0.968，表现最优；年均降雨量、土壤侵蚀性和坡度是影响滑坡发育的关键驱动因子，其对模型的输出贡献占比分别为26.59%、20.80%和14.66%。此外，通过偏依赖图揭示了关键因子之间的非线性交互作用，显示坡度与降雨、土壤特性在特定区间内对滑坡发生具有耦合增强效应。

关键词：黄土高原；滑坡；易发性评价；机器学习；模型可解释性

中图分类号：P694　　**文献标识码：**A　　**文章编号：**1006−6616(2025)05−0972−18

DOI：10.12090/j.issn.1006-6616.2025088

0　引言

黄土高原受地形破碎、土质疏松、降雨集中、强震频发等自然因素控制，加之黄土本身具有垂直节理、结构疏松和水敏性等特殊性质，导致区内滑坡、崩塌、泥流等地质灾害频发，不仅严重威胁人民生命安全，还造成油气管道损毁、交通基础设施破坏以及耕地资源流失等一系列严重后果（Li et al., 2013; 彭建兵等, 2014）。黄土高原地质灾害具有数量多、密度高、分布广的特点，占中国国土面积的6%，但其孕育了中国30%的地质灾害（刘东生，1985; 陈丹璐等, 2025）。极端天气、人类工程活动、地震等多因素耦合作用下，黄土高原滑坡灾害频繁发生，并呈现增长的趋势（彭建兵等, 2020）。例如，2013年7月，甘肃天水市遭遇3次日降水量大于100 mm的暴雨，随后发生数千次浅层黄土滑坡，造成24人死亡，经济损失82.75亿元（Wang et al., 2022; Zhang et al., 2022, 2023）；2021年，区内又遭遇暴雨，引发了聚集性黄土滑坡，并造成许多滑坡复活（Wang et al., 2022; Zhang et al., 2022）；2023年12月18日，甘肃积石山M_S 6.2地震在青海省海东市民和县中川乡金田村和草滩村触发了一起灾难性的地震液化型滑坡−泥流（许强等, 2025）；2025年7月16日，受持续降雨影响，甘肃省天水市境内陇海铁路元龙站至建河站间突发山体滑坡，一辆货物列车

通过时撞上正在滑落的塌体，致机车脱线，上行线路中断行车。因此，揭示黄土高原滑坡的空间分布规律和易发性分布格局及其致灾主控因子，对于灾害风险防控与土地空间规划具有重要现实意义。

滑坡易发性评价是地质灾害风险评估与空间区划的核心内容，其核心目标是揭示滑坡发生的空间概率（吴树仁等，2012）。随着遥感技术、地理信息系统、全球定位系统以及人工智能等先进技术的应用，滑坡易发性评价方法得到了极大的创新与提升，这些技术为滑坡易发性评价提供了强有力的支持（许强等，2019；佟彬等，2025）。评价模型由传统的统计学模型逐渐发展成近年来广泛应用的机器学习模型，例如随机森林（Random Forest, RF）、自适应增强（AdaBoost）、神经网络等，甚至深度学习模型（Hong et al., 2016; Ke et al., 2025; Hussain et al., 2025）。纵观现有研究，传统统计学模型原理简单、解释性强，但难以捕捉复杂的非线性关系；单一的机器学习模型能有效提升预测精度，但模型性能严重依赖参数设置且普遍被视为“黑箱”；而耦合模型与优化策略，旨在融合不同方法的优势以突破性能瓶颈（Reichenbach et al., 2018；窦杰等，2023; Ke et al., 2023）。

为追求更高精度，模型耦合策略及参数优化成为当前研究的前沿。例如，Ke et al.（2023）利用平均影响值（Mean Impact Value, MIV）对BP神经网络进行优化，同时耦合频率比对会昌县城及周边地区进行滑坡易发性评价，较传统的BP神经网络模型精度提升了0.7% ～ 0.8%。周超等（2020）以三峡库区龙驹坝为研究区，对比耦合模型（径向基神经网络和Adaboost集成学习）、径向基神经网络和逻辑回归模型进行易发性评价，得到耦合模型优于单一模型的结果。然而，现有耦合优化研究仍存在明显局限：在机制上，多侧重于模型的简单组合或默认参数的浅层应用，缺乏对超参数的系统性优化；在深度上，未能实现特征层面的深度融合，致使模型性能与解释性均未达到最优。

尽管机器学习模型能训练数据获取较高的精度，但由于其复杂的数学机制，被认为普遍存在“黑箱”问题，其决策过程不透明，限制了对滑坡致灾机制的深入理解。为增强模型的可解释性，近年来兴起的SHAP（SHapley Additive Explanations）等解释工具被广泛应用于多领域研究中。Pradhan et al.（2023）利用SHAP分析了卷积神经网络模型的决策逻辑，实现了滑坡易发性建模的可解释性。南淑荷等（2025）通过XGBoost−SHAP模型的流域水质指标分析了溶解氧的驱动与协同影响。Lv et al.（2025）构建了RF、XGBoost、ResNet（残差网络）及DenseNet（密集连接卷积网络）4种模型，并选取了表现最佳的XGBoost和DenseNet分别进行解译，有效揭示了研究区滑坡主控因子的地理空间异质性。而部分偏依赖图（Partial Dependence Plot, PDP）也是一种用于解释机器学习模型的工具，可揭示两个特征间的交互作用或一个特征在不同取值下对预测模型结果的影响。Fu et al.（2025）通过PDP揭示了非渗透表面和植物覆盖度与粤港澳大湾区城市内涝风险之间的非线性关系。

综上所述，文章针对现有研究中模型优化机制与可解释性融合方面的不足，结合黄土高原滑坡易发性研究基础相对薄弱的现状，采用Optuna框架对模型超参数系统进行自动化调优，并融合SHAP与PDP可解释性分析方法，旨在识别关键驱动因子，量化其对模型输出的贡献程度，并揭示关键因子之间的非线性交互机制。研究成果可为黄土高原滑坡灾害的成因机制认知、防灾减灾措施制定和重大工程选址提供理论支撑与技术参考。

1 研究区概况

黄土高原是中国四大高原之一，东起太行山，西到青海日月山，南界秦岭，北抵鄂尔多斯高原，地势总体西北高东南低，自西北向东南呈波状下降（图1），面积约65×10^4 km^2。黄土高原地处青藏高原东北缘及鄂尔多斯地块周缘，活动构造发育，具体表现为鄂尔多斯周缘活动断裂系及包围的区域，以及冷龙岭−海原断裂系与拉脊山−西秦岭北缘断裂系及其包围的区域（徐锡伟等，2016；许冲等，2018）。黄土高原及周缘历史强震多发，据统计，1900—2022年共发生2.5级以上地震266起，其中1920年海原大地震为近代发生最为强烈的地震事件，造成20余万人死亡（王兰民等，2020）。黄土高原面积广、范围大，不同区域的新生代构造演化有较大差别。根据新生代构造运动特征与沉积过程的差异，可将其划分为鄂尔多斯黄土地貌区、陇西黄土地貌区和汾渭裂谷黄土地貌区3个单元（袁宝印等，2012）。区内海拔58～5208 m，高差达5150 m，发育了黄土侵蚀−构造堆积地貌、黄土现代构造（变形）地貌、黄土湿陷地貌、黄土侵蚀地貌等典型的黄土地貌类型（柴

慧霞等，2006）。该区以大陆型干旱半干旱气候为主，气温日差大，降雨时空分布不均（李曼等，2025）。区内广泛分布沉积的泥岩、砂岩等沉积岩，上覆疏松黄土层，抗侵蚀能力弱。在长期水流侵蚀下，该区形成了沟壑纵横的特殊地貌。

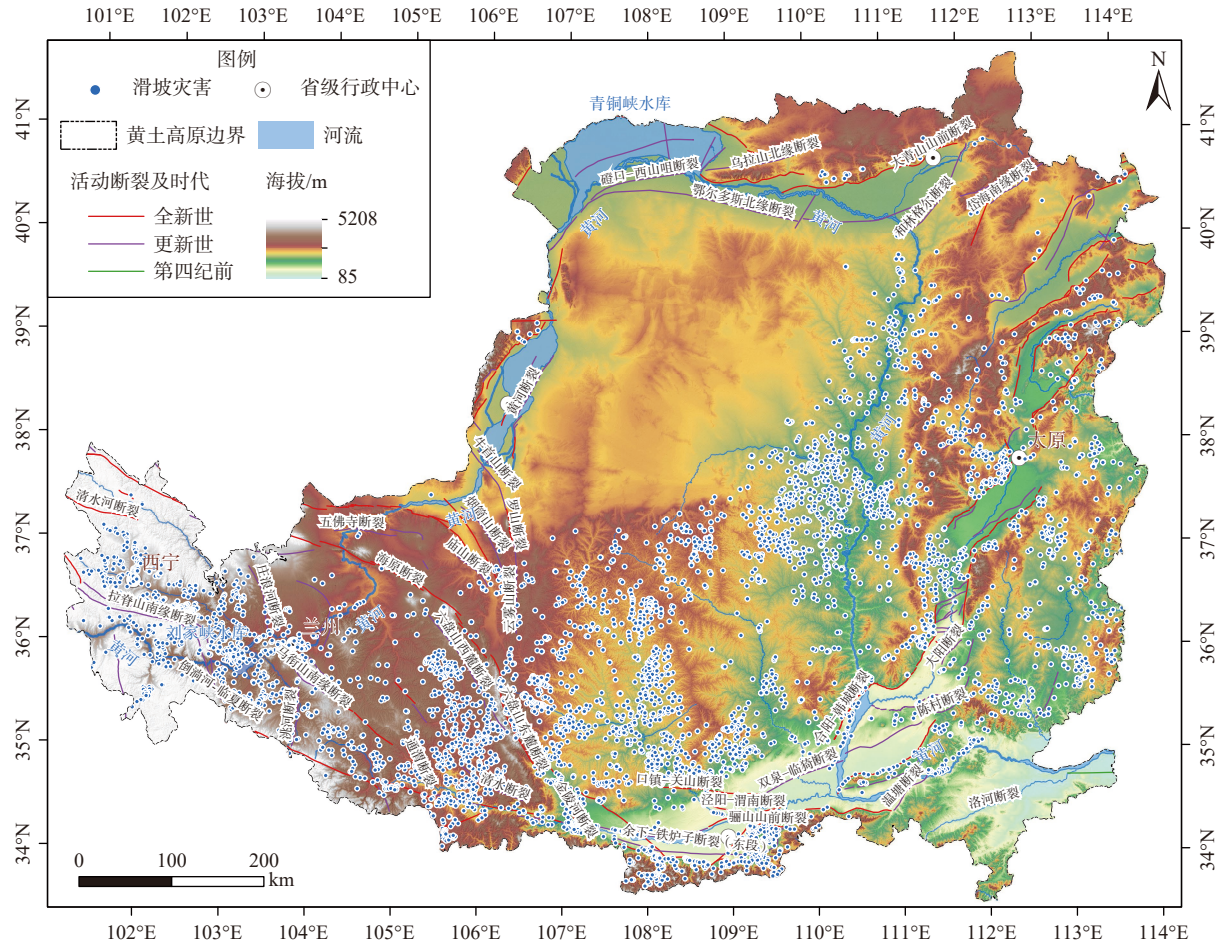


图 1　黄土高原滑坡灾害分布图

Fig. 1　Distribution map of landslides on the Loess Plateau

黄土高原广泛出露中新统—上新统红层和第四系黄土，周缘断陷盆地和山间盆地中沉积了数千米的河湖相沉积，典型地层剖面多为中国北方晚新生代地层划分对比的标准剖面，建立了许多具有深远影响的代表性新近系等地层单位（魏荣珠等，2022）。据 1∶250 万《中华人民共和国地质图》（叶天竺等，2017）统计，黄土高原地区第四系黄土（马兰黄土、离石黄土、午城黄土等）面积约 22.4×10^4 km^2，占黄土高原总面积 34.4%，主要分布在中部的陕甘黄土高原；新近系红层出露面积约 3.04×10^4 km^2，占黄土高原总面积 4.7%，主要分布在西部的陇西高原（图 2）。根据收集的地质灾害数据显示，黄土高原共发育地质灾害 14760 处，包括滑坡 5784 处、崩塌 5668 处、泥石流 3308 处。其中，2383 处滑坡分布在新近系泥岩出露或下伏地区，占比约 41.2%。黄土高原滑坡在群集分布方面表现出明显的区带性，分为 8 个滑坡高发区带，分别是临夏–陇西–天水群发带、海东–兰州–通渭群发带、靖远–西吉–静宁群发带、海原–固原–平凉群发带、陇东群发区、陕北群发区、吕梁群发区和汾渭盆地群发带（彭建兵等，2020）。

2　数据来源和评价因子选取

2.1　数据来源

该研究使用的滑坡点数据共计 5784 处，其空间分布如图 1 所示。断层数据来源于中国地震局地质研究所“中国及其邻域活动断层数据（2016）”（徐锡

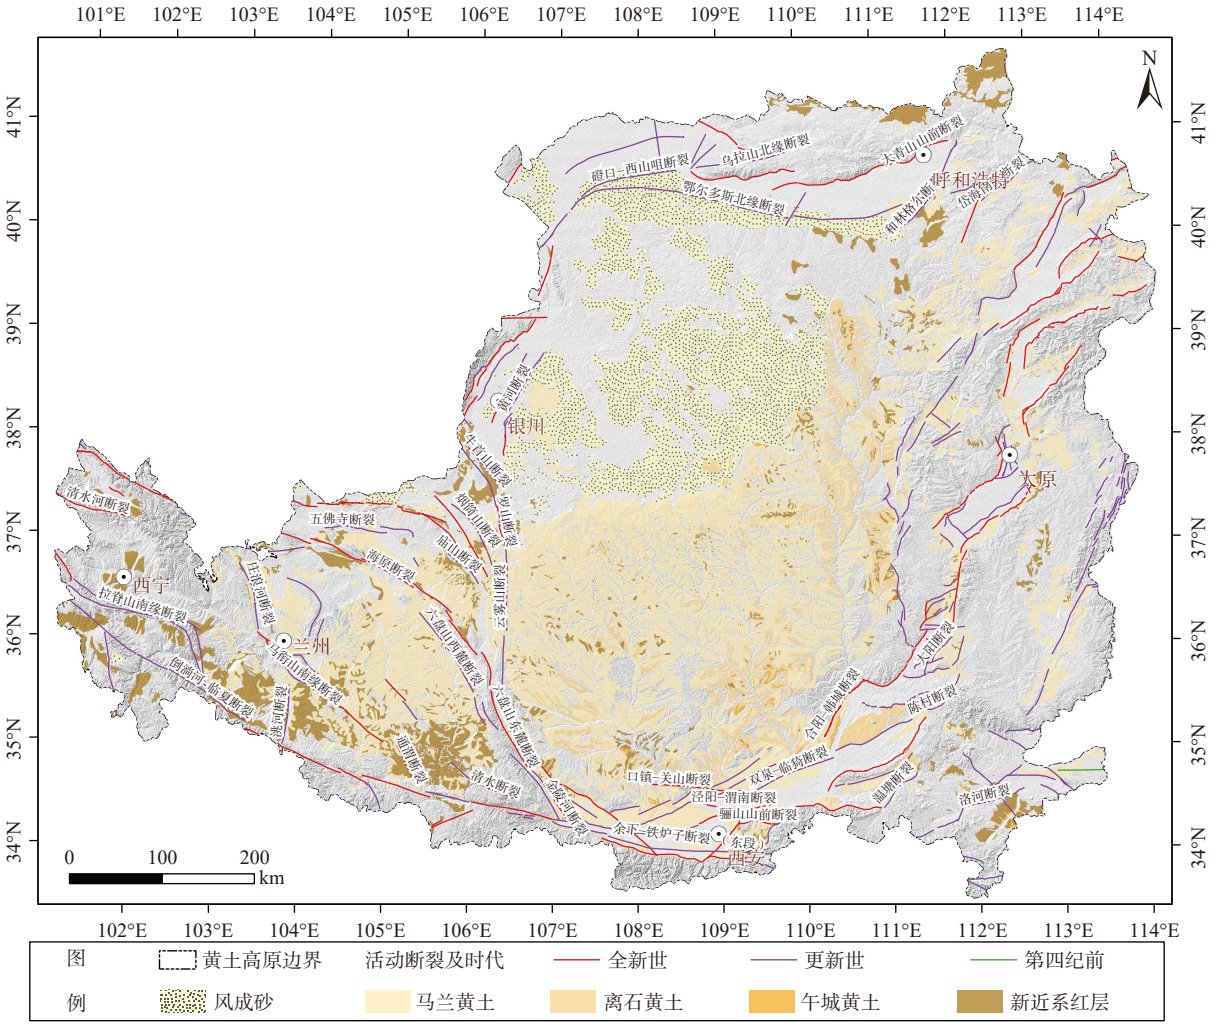


图 2 黄土高原新近纪以来黄土–红层分布图

Fig. 2 Loess–red beds since the Neogene in the study area

伟等, 2016)；道路数据来源于 Open Street Map 开放平台；地震数据来源于美国地质调查局(USGS)；数字高程模型 DEM(Digital Elevation Model)数据来源于日本宇宙航空研究所(JAXA)，分辨率 90 m；1∶250 万地质图公开版数据来源于全国地质资料馆(https://www.ngac.cn/125cms/c/qggnew/index.htm)； 土壤可蚀性因子来源于地理遥感生态网(https://www.gisrs.cn/)，分辨率为 250 m；多年平均降雨数据(1991—2020 年)来源于中国科学院成都山地灾害与环境研究所发起的“高分辨率山地环境制图计划”，分辨率为 30 m；土地利用类型数据分辨率为 30 m，引自 Yang and Huang(2021)的研究成果。NDVI 数据来源于国家生态科学数据中心 2000—2022 年中国 30 m 年最大 NDVI 数据集，分辨率为 30 m(董金玮等，2021)。该 NDVI 数据将理论值[−1, 1]乘以缩放因子 10000 后以整型存储，故其原始值域为[−10000, 10000]。鉴于所使用的机器学习算法对线性缩放具有不变性，后续分析均基于此缩放后的值直接进行，该处理不影响模型输出结果的可靠性。由于数据来源分辨率的空间坐标不统一，考虑研究区范围广，因此所有数据均经过空间配准和统一重采样(90 m 分辨率)。

2.2 评价因子的选取

滑坡易发性评价通过类比已知灾害点的地质环境特征，结合黄土高原的地质背景进行区划，评价因子的选取即基于这一假设。基于长期调查研究，文章全面分析了黄土高原的地质和水文背景，并综合考虑了滑坡灾害的发育特征、分布规律、数据可获取性及评价可行性，同时参考既有研究成果，初步选取了 14 个影响因子，包括坡度、坡向、海拔、剖面曲率、平面曲率、距断层距离、震中距、年均降雨量、土壤可蚀性、归一化植被指数(NDVI)、

土地利用类型、地层岩性、人口密度和距道路距离(图 3)，涵盖了地形地貌、地质构造、水文和地表以及人类工程活动。此外，若因子间存在较强的相关性，可能导致训练模型的运行速率下降和模型复杂

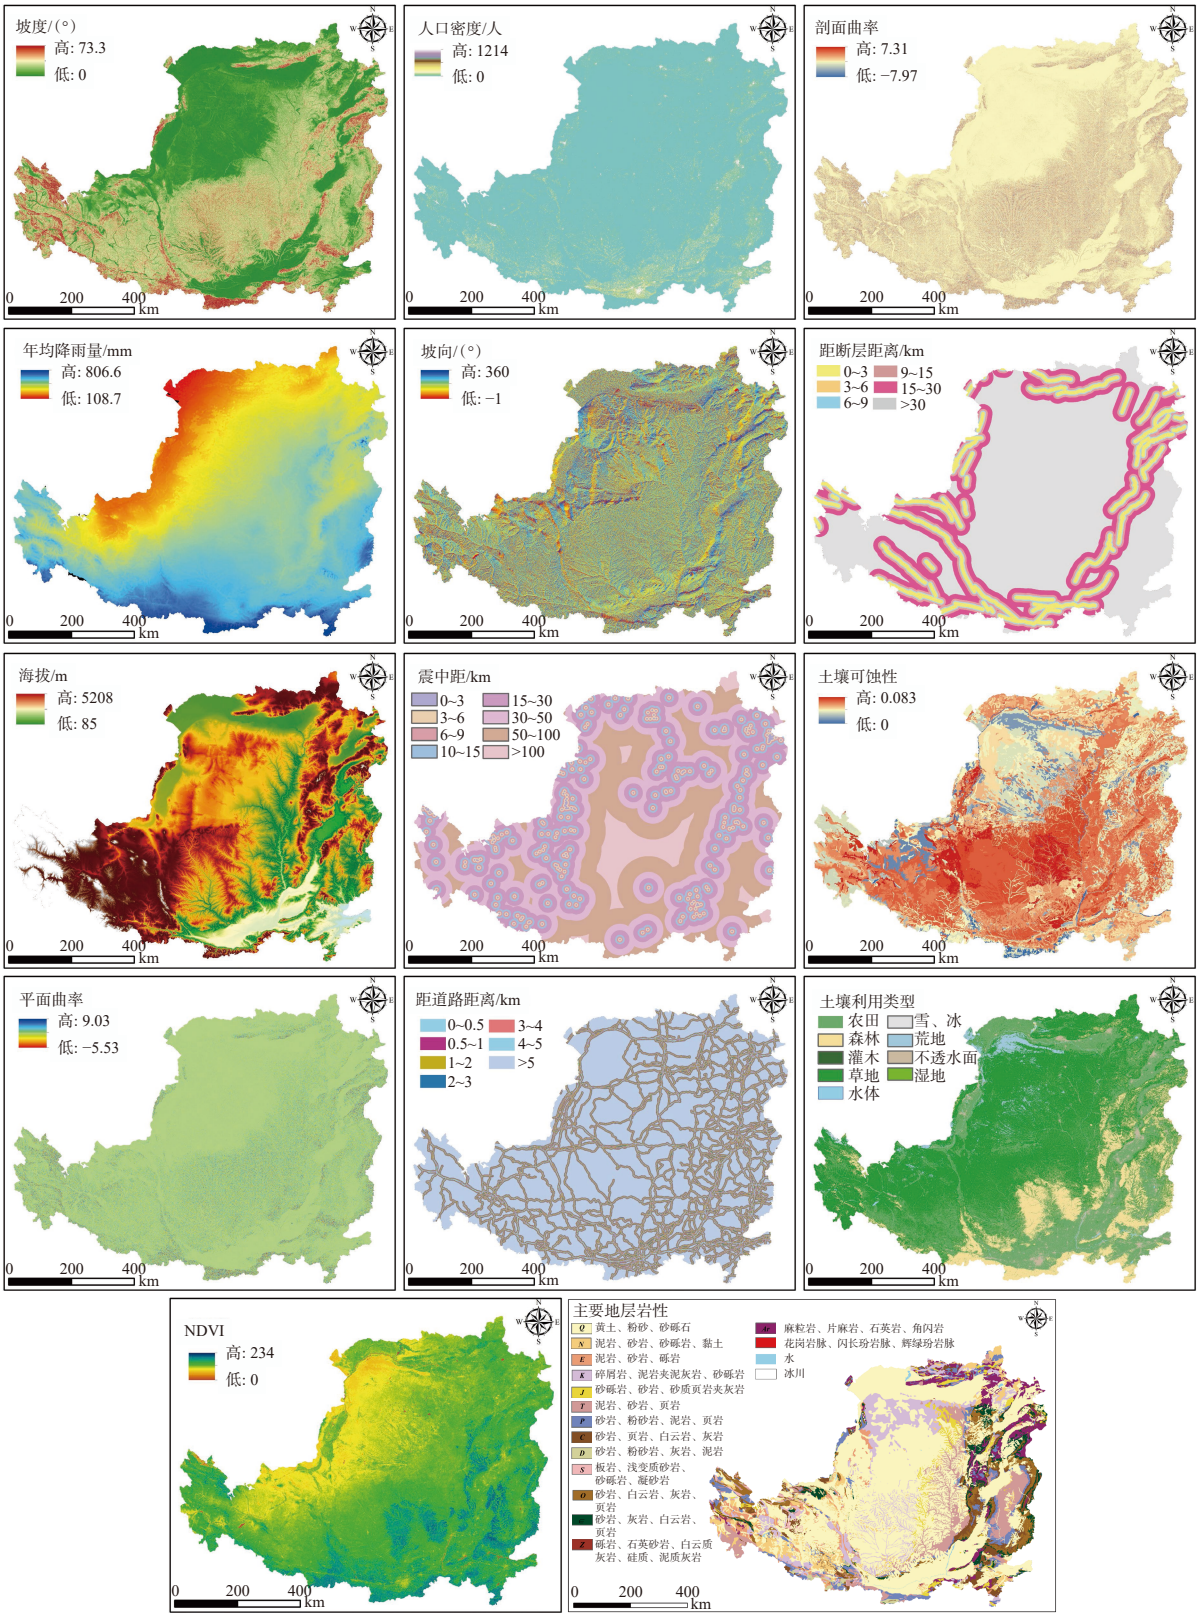


图 3　初选评价因子

Fig. 3　Preliminary Evaluation Factors in the Study Area

化，使得滑坡易发性评价的精度降低。故而，有必要进行多重共线性分析，了解因子间的相关性大小（Ke et al., 2025）。

若因子间存在多重共线性，会影响评价模型的稳健性。文章基于现有研究（Qin et al., 2021），利用方差膨胀因子（*VIF*）或容忍度（*TOL*）进行多重共线性分析。通常认为，当 *VIF* 值为0～2时，表明各评价因子多重共线性较弱；当 *VIF* >2时，表明各评价因子多重共线性较强，需要剔除相关影响因子。*VIF* 的计算公式如下：

$$VIF = \frac{1}{1-R_i^2} \tag{1}$$

式中：R_i为自变量对其他变量回归分析时的相关系数。初选评价因子的多重共线性分析见表1，其中NDVI的 *VIF* 值大于2，出于保守考虑，剔除该影响因子。剩余的13个评价因子作为后续建立模型的输入特征。

表1 多重共线性分析

Table 1 Multicollinearity analysis

影响因子	*TOL*	*VIF*
距断层距离	0.901	1.110
距道路距离	0.893	1.120
地层岩性	0.905	1.104
NDVI	0.499	2.003
震中距	0.837	1.194
人口密度	0.934	1.071
土壤侵蚀性	0.924	1.082
土地利用类型	0.782	1.279
平面曲率	0.728	1.373
剖面曲率	0.725	1.380
年均降雨量	0.557	1.795
坡向	0.998	1.002
坡度	0.748	1.336
高程	0.763	1.310

3 模型方法

该研究以频率比（Frequency Ratio, FR）模型作为非滑坡样本点采样的基础方法，并构建了FR−XGBoost与FR−RF2种耦合模型进行对比分析。为进一步评估耦合模型与单一模型的精度差异，同时将单一模型（XGBoost）作为对比基准，以全面评价各类方法在滑坡易发性评价中的的效能与适用性。为增强上述模型在决策过程的可解释性，引入SHAP方法以量化各特征变量对预测结果的贡献程度，进而识别关键评价因子；此外，采用PDP可视化关键评价因子与滑坡发生概率之间的边际依赖关系，揭示其非线性影响及特征间交互效应，深化对滑坡成因机制的理解。

3.1 FR模型

频率比方法通过计算滑坡数量在影响因子属性区间的占比来确定属性区间的权重，某一属性区间内滑坡数量越多，其对应的频率比值越高。为便于对比研究和服务于后续建模，将FR值进行归一化处理（NFR），其计算公式如下（Ke et al., 2025）：

$$FR_{ij} = \frac{N_{ij}/N}{S_{ij}/S} \tag{2}$$

$$NFR_{ij} = \frac{FR_{ij}}{\sum FR_{ij}} \tag{3}$$

式中：FR_{ij}为第 i 类评价因子第 j 级的频率比值；N_{ij}为第 i 类评价因子第 j 级滑坡点的数量或者面积；N 为研究区总滑坡数量；S_{ij}为第 i 类评价因子第 j 级的面积；S 为研究区总面积；NFR_{ij}为第 i 类评价因子第 j 级区间的归一化频率比值。

3.2 XGBoost模型

XGBoost是极端梯度上升（Extreme Gradient Boosting）的简称，其基本元素是决策树（即弱分类器），由先后顺序的多个决策树集成。其核心在于引入正则化项来控制模型复杂度，从而避免过拟合（Chen and Guestrin, 2016）。XGBoost的建模过程主要包括以下关键步骤：首先，通过二阶泰勒展开优化目标函数，计算各叶子节点的最优权重并评估特征分裂的信息增益；随后，基于信息增益确定特征重要性排序，采用贪心算法逐层选择最优分裂特征；进而，利用加权分位法高效计算分裂点构建决策树；最后，通过迭代优化逐步构建多棵决策树，并将其预测结果加权求和得到最终输出（王凯等, 2025）。

采用Optuna框架对XGBoost的超参数进行自动优化，以提高模型性能。优化后的关键参数包括：决策树数量（n_estimators）=300、最大树深度（max_depth）=11、学习率（learning_rate）=0.063、样本采样比例（subsample）=0.963、特征采样比例（colsample_bytree）=0.6025以及节点分裂最小损失下降（gamma）=1.3150（表2）。

3.3 FR−XGBoost模型

为了与单一模型作比较，该研究构建了耦

表 2　优化后的关键参数

Table 2　Optimized key parameters

超参数	说明	XGBoost	FR−XGBoost	FR−RF
n_estimators	决策树数量	300	300	352
max_depth	最大树深度	11	13	15
learning_rate	学习率	0.063	0.222	—
subsample	样本采样比例	0.963	0.659	—
colsample_bytree	特征采样比例	0.6025	0.812	—
gamma	节点分裂最小损失下降	1.3150	0.354	—
min_samples_split	节点分裂最小样本数	—	—	9
min_samples_leaf	叶节点最小样本数	—	—	1
max_features	特征选择策略	—	—	log2

合模型(FR−XGBoost)进行滑坡易发性评价。FR−XGBoost 的核心流程包括：首先，基于 FR 模型对各评价因子进行属性区间划分，并计算归一化频率比值(NFR)；然后，将 NFR 值作为特征权重输入 XGBoost 模型进行训练，计算各评价因子的相对权重值，并将其赋予黄土高原的评价因子图层；最后，通过叠加各因子图层，构建滑坡易发性制图。其计算公式如下：

$$LSI_{(M)} = \sum NFR_{ij} \times w_i \tag{4}$$

式中，$LSI_{(M)}$为耦合模型下的滑坡易发性指数；w_i为评价因子的相对权重值；NFR_{ij}为第 i 类评价因子第 j 级区间的归一化频率比值。

同样使用 Optuna 实现超参数自动优化，以验证集均方误差最小化为优化目标。经过 100 轮参数搜索，最终确定最优参数组合为：决策树数量(n_estimators)=300、最大树深度(max_depth)=13、学习率(learning_rate)=0.222、样本采样比例(subsample)=0.659、特征采样比例(colsample_bytree)=0.812、节点分裂最小损失下降(gamma)=0.354(表 2)。

3.4　FR−RF 模型

随机森林(Random Forest, RF)是一种基于装袋法(Bagging)的集成学习算法，通过构建多棵分类回归树提升模型鲁棒性，结果由投票得分最多或取平均决定(刘坚等, 2018)。采用非自助采样模式的随机森林算法进行分类任务建模，每颗决策树使用原始训练集的完整样本进行构建；点分裂时，仅从随机特征子集选择最优分裂点，最终分类结果通过多数投票法集成。基于上述原理构建的 FR−RF 模型通过公式(4)得到滑坡易发性指数。在模型构建过程汇总中，采用 Optuna 框架进行超参数优化，以验证集准确率最大化为目标，经过 100 轮参数搜索获得最优参数组合：决策树数量(n_estimators)=352，最大树深度(max_depth)=15，节点分裂最小样本数(min_samples_split)=9，叶子节点最小样本数(min_samples_leaf)=1，特征选择策略(max_features)=log2(表 2)。

3.5　SHAP 解释

SHAP (SHapley Additive exPlanation)模型是一种解释工具，其将所有特征视为贡献者(Lundberg and Lee, 2017)，通过计算各特征加入模型时的平均边际贡献，量化其对模型预测结果的贡献程度。第 i 个特征的 SHAP 计算公式如下(王火根等, 2025)：

$$\Phi_i \sum_{s \subseteq N \setminus \{i\}} \frac{|S|!(|N|-|S|-1)!}{|N|!}(v(S \cup \{i\}) - v(S)) \tag{5}$$

式中：N 为多有特征的集合；S 为不包含第 i 个特征的集合；$|S|$为集合 S 中的特征数；$v(S)$ 为集合 S 对模型预测输出的贡献；$v(S\cup\{i\})$ 为包含第 i 个特征的集合 $S\cup\{i\}$对模型预测输出的贡献。

3.6　PDP

PDP(部分偏依赖图)是一种模拟算法，其通过顺序修改目标特征的值来获取预测值，从而反映一个或两个特征的边际效应(Zhou et al., 2022)。PDP 使用公式(6)计算(Fu et al., 2025)：

$$\hat{f}_s x_s = E_{Xc} = \hat{f} x_s, Xc \int \hat{f}(x_s, Xc) dPXc \tag{6}$$

式中，x_s是待分析的 1 个或 2 个特征；Xc 表示剩余的特征；$\hat{f}$代表研究中使用的模型。$\int \hat{f}(x_s, Xc) dPXc$表示在 Xc 的概率测度 $dPXc$ 上对模型预测进行积分，即计算期望。

4　结果与验证

4.1　基于 FR 的评价因子属性区间划分

在 ArcGIS 软件中，通过等间距法将连续型的

表 3 评价因子频率比值

Table 3 Frequency ratio of evaluation factors

评价因子	属性区间	滑坡占比/%	分类面积占比/%	FR值	NFR值
海拔/m	85～939	20.29	14.05	1.44	30
	939～1793	56.96	68.17	0.84	17
	1793～2647	19.07	13.28	1.44	29
	2647～3500	3.68	3.18	1.16	24
	3500～4354	0.00	1.27	0.00	0
	4354～5208	0.00	0.06	0.00	0
坡度/(°)	0～12	53.91	17.14	3.14	54
	12～24	40.54	17.68	2.29	40
	24～36	5.02	15.93	0.32	5
	36 ～48	0.52	17.16	0.03	1
	48～61	0.00	16.89	0.00	0
	61～74	0.00	15.20	0.00	0
坡向/(°)	−1～60	13.89	17.14	0.81	14
	60～120	18.79	17.68	1.06	18
	120～180	18.77	15.93	1.18	20
	180～240	18.18	17.16	1.06	18
	240～300	17.17	16.89	1.02	17
	300～360	13.20	15.20	0.87	14
年均降雨量/mm	108.7～225	0.21	7.93	0.03	0
	225～341.3	2.42	20.04	0.12	2
	341.3～457.7	40.61	32.92	1.23	21
	457.6～573.9	42.28	32.11	1.32	22
	573.9～690.2	13.98	6.56	2.13	36
	690.2～806.6	0.49	0.44	1.10	19
剖面曲率	−7.967～−5.420	0.00	0.00	0.00	0
	−5.420 ～−2.874	0.00	0.00	0.00	0
	−2.874～−0.327	6.74	5.56	1.21	10
	−0.328～2.218	93.24	94.44	0.99	8
	2.218～4.765	0.02	0.00	9.79	82
	4.765～7.311	0.00	0.00	0.00	0
平面曲率	−5.526 ～−3.099	0.00	0.00	0.00	0
	−3.099～−0.673	0.75	0.69	1.08	52
	−0.673～1.753	99.25	99.30	1.00	48
	1.753～4.180	0.00	0.00	0.00	0
	4.180～6.606	0.00	0.00	0.00	0
	6.606～9.032	0.00	0.00	0.00	0
人口密度/人	0～202	99.43	99.79	1.00	8
	202～405	0.40	0.16	2.55	21
	405～607	0.14	0.05	2.77	23
	607～809	0.03	0.01	5.84	48
	809～1012	0.00	0.00	0.00	0
	1012～1214	0.00	0.00	0.00	0
土壤侵蚀性	0～0.014	2.51	6.54	0.38	9
	0.014 ～0.028	4.40	13.05	0.34	8
	0.028～0.041	19.90	29.20	0.68	16
	0.041～0.055	65.36	43.76	1.49	34
	0.055～0.069	7.80	7.38	1.06	24
	0.069～0.083	0.03	0.08	0.44	10

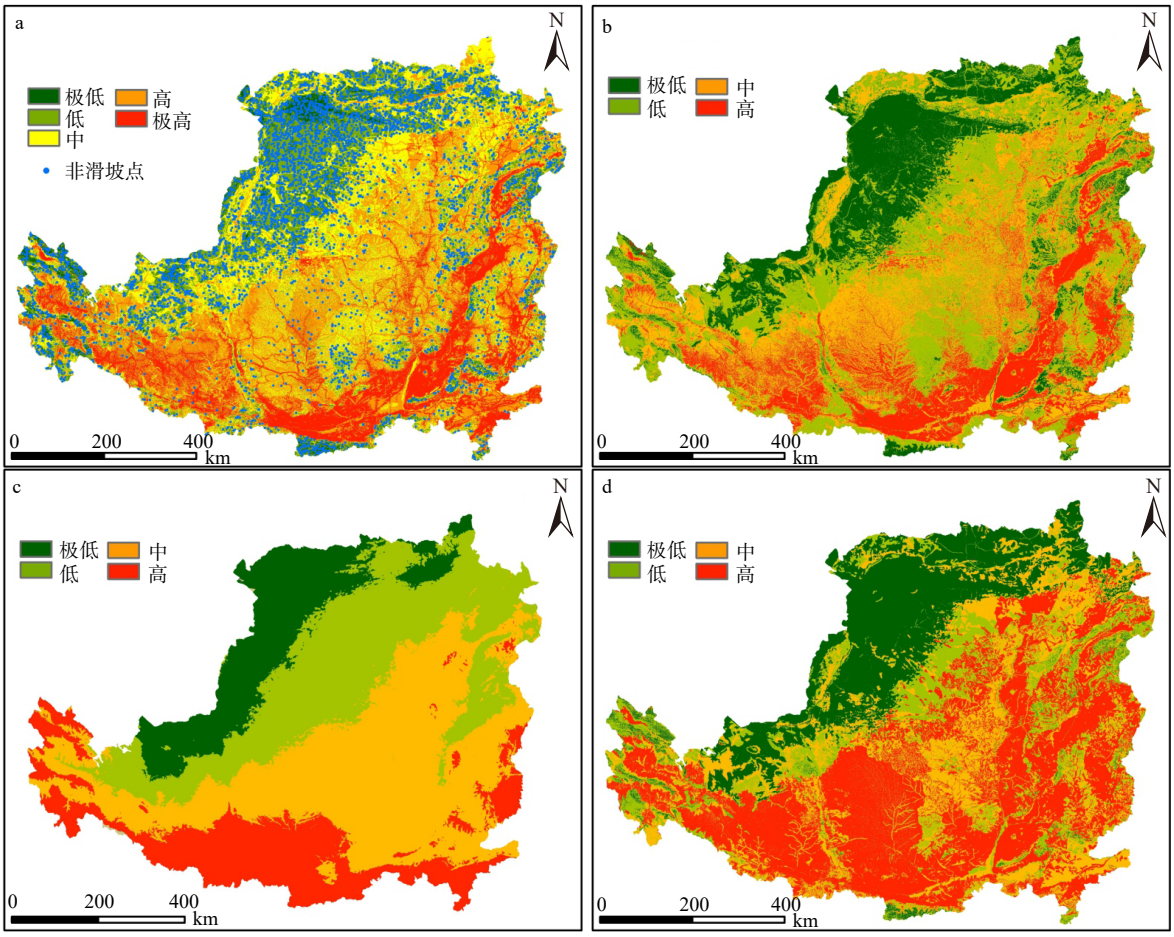
续表 3

评价因子	属性区间	滑坡占比/%	分类面积占比/%	FR值	NFR值
地层岩性	新近系泥岩、砂岩	10.41	5.09	2.05	13
	二叠系砂岩、粉砂岩	6.39	4.71	1.36	9
	白垩系碎屑岩、泥岩	8.65	8.53	1.01	6
	三叠系泥岩、砂岩	9.33	7.78	1.20	8
	侏罗系砂砾岩、砂岩	3.05	2.37	1.29	8
	太古宙麻粒岩、片麻岩	2.12	4.50	0.47	3
	奥陶系砂岩、白云岩	2.86	4.52	0.63	4
	石炭系砂岩、页岩	7.33	3.75	1.95	12
	震旦系砾岩、石英砂岩	0.00	0.02	0.00	0
	寒武系砂岩、灰岩	0.96	3.00	0.32	2
	水体	0.05	0.17	0.31	2
	泥盆系砂岩、粉砂岩	0.52	0.69	0.76	5
	花岗岩脉、闪长玢岩脉	0.00	0.00	0.00	0
	古近系泥岩、砂岩	6.63	2.07	3.20	20
	志留系板岩、浅变质砂岩	0.24	0.57	0.43	3
	冰川	0.00	0.01	0.00	0
	第四系黄土、粉砂	41.45	52.22	0.79	5
震中距/km	0～3	0.66	1.06	0.62	8
	3～6	2.02	2.67	0.76	10
	6～9	4.44	5.16	0.86	11
	9～15	6.84	7.81	0.88	11
	15～30	25.12	24.46	1.03	13
	30～50	22.79	24.83	0.92	12
	50～100	27.73	27.79	1.00	13
	>100	10.39	6.21	1.67	22
土地利用类型	农田	42.61	29.55	1.44	15
	森林	9.23	14.84	0.62	6
	灌木	0.02	0.29	0.06	1
	草地	44.13	49.03	0.90	9
	水体	0.00	0.47	0.00	0
	雪/冰	0.14	0.03	5.46	56
	荒地	0.26	2.67	0.10	1
	不透水面	3.62	3.11	1.16	12
	湿地	0.00	0.00	0.00	0
距断层距离/km	0～3	6.84	4.79	1.43	23
	3～6	5.71	4.85	1.18	19
	6～9	5.21	4.78	1.09	17
	9～15	7.28	8.96	0.81	13
	15～30	13.81	17.04	0.81	13
	>30	61.16	59.58	1.03	16
距道路距离/km	0～0.5	17.82	8.14	2.19	27
	0.5～1	8.89	6.53	1.36	17
	1～2	12.30	10.83	1.14	14
	2～3	8.62	8.97	0.96	12
	3～4	7.28	7.73	0.94	11
	4～5	6.03	6.77	0.89	11
	>5	39.06	51.03	0.77	9

评价因子划分为 6 个属性区间，离散型因子依据原始数据划分属性区间。根据公式(3)计算的频率比值(FR)及公式(4)计算的归一化频率比值(NFR)如表 3 所示。结果表明，不同评价因子的属性区间存

在显著差异，其频率比值呈现较大波动。以海拔评价因子为例，在海拔85～939 m、1793～2647 m及2647～3500 m区间内，频率比值均大于1；经过归一化处理后，这些区间均表现出较高的NFR值，分别为30、29和24。尽管在939～1793 m海拔区间内，滑坡数量占比达到56.96%，但由于该区间的面积占研究区总面积的68.17%，因此NFR值相对较低。而在海拔3500～5208 m范围内，未发生滑坡实践，因此NFR值为0。

将各属性区间的NFR赋予对应评价因子图层，通过空间叠加生成基于FR模型的滑坡易发性指数图。采用自然断点法将易发性划分为5个等级：极高、高、中、低、极低（图4a）。最终，在低与极低易发区内随机选取5784处非滑坡样本点，作为后续机器学习模型的训练与验证数据。



a—FR模型；b—FR−RF模型；c—XGBoost模型；d—FR−XGBoost模型

图4 黄土高原滑坡易发性区划图

Fig. 4 Landslide Susceptibility Zoning Map of the Study Area

(a) FR model; (b) FR–RF model; (c) XGBoost model; (d) FR–XGBoost model

4.2 滑坡易发性评价结果

在模型训练过程中，采用分层两阶段拆分策略划分数据集：首先保留20%样本作为独立测试集，剩余80%样本进一步按7∶1比例拆分为训练集（70%）与验证集（10%），以实现超参数优化和评估。使用训练集分别训练XGBoost、FR−XGBoost和FR−RF模型及优化超参数，然后使用SHAP算法计算各模型下评价因子的绝对SHAP值，通过计算其占比输出评价因子的相对权重（表4）。3个模型训练出的结果都显示年均降雨量和土壤侵蚀性是研究区的关键因子。在XGBoost模型中，坡度也较为重要，重要性占比14.66%。基于公式（4），将NFR和各模型下的评价因子相对权重叠加，得到各模型对应的滑坡易发性指数。最后，通过重分类即可得到

表 4　评价因子相对权重

Table 4　Relative weight of evaluation factors

评价因子	XGboost	FR−XGBoost	FR−RF
距道路距离	0.0750	0.0751	0.0733
地层岩性	0.0266	0.0435	0.0767
距断层距离	0.0091	0.0114	0.0235
震中距	0.0100	0.0129	0.0335
人口密度	0.0538	0.0000	0.0002
土壤侵蚀性	0.2080	0.3105	0.2645
土地利用类型	0.0738	0.0829	0.0987
平面曲率	0.0172	0.0011	0.0022
剖面曲率	0.0222	0.0013	0.0075
年均降雨量	0.2659	0.3171	0.2728
坡向	0.0222	0.0237	0.0267
坡度	0.1466	0.0768	0.0552
海拔	0.0695	0.0438	0.0651

滑坡易发性区划图(图 4b—4d)。

受试者工作特征曲线(Receiver Operating Characteristic curve, 简称 ROC 曲线)通过 ROC 曲线下面积(Area Under Curve, 简称 AUC)判断模型的预测性能, 已被广泛使用于二分类问题中。在滑坡易发性建模预测中, 模型的任务是将样本点分类为“滑坡”与“非滑坡”。ROC 曲线以真阳性率(TPR), 即命中率为纵坐标, 表示模型正确预测滑坡的比例; 以假阳性率(FPR), 即误报率为横轴, 表示模型将非滑坡错误地预测成滑坡的比例(Ke et al., 2025)。ROC 曲线下的面积(AUC)用于量化模型的整体性能, AUC 值越高, 模型的预测性能越好。整体来看, 3 个模型下的 ROC 曲显示其性能均表现良好(图 5)。其中, 单一模型(XGBoost)的 AUC 值达到了 0.805, 表明该模型具备良好的判别能力; 耦合模型 FR−RF 和 FR−XGBoost 模型则表现更佳, AUC 值进一步提升为 0.963 和 0.968。相较于单一 XGBoost 模型, FR−XGBoost 耦合模型的预测性能显著提高(相对提升幅度 16.3%), 验证了频率比模型与机器学习模型耦合的优势, 即通过融合评价因子客观权重与机器学习非线性模式识别能力, 有效提升了滑坡易发性预测的精度。该研究在验证模型预测性能的基础上, 进一步开展模型可解释性分析, 旨在深入探究各驱动因子对预测结果的贡献程度与作用方向, 识别关键因子间的交互作用机制, 并揭示其对模型输出的非线性影响。

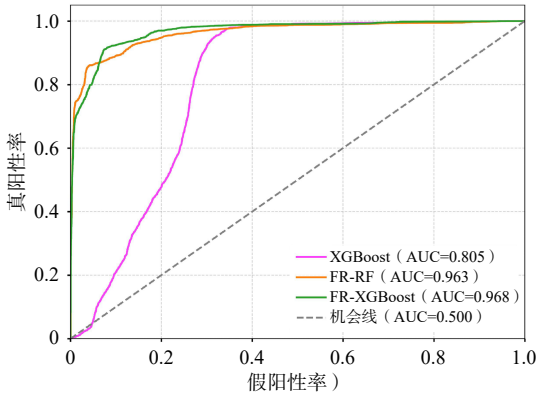


图 5　不同模型的 ROC 曲线和 AUC 值

Fig. 5　ROC curves and AUC values of different models

验证模型的实际预测能力, 研究选取了预测结果中 3 处位于高易发区的典型滑坡案例进行深入剖析。甘肃省天水市娘娘坝镇中寨滑坡是 1 处典型的降雨型黄土−基岩界面滑坡, 曾于 2013 年 7 月及 2021 年 10 月 2 次因极端强降雨事件而激活滑动, 滑动面主要位于马兰黄土与下伏粉砂质板岩的接触界面, 强降雨入渗导致界面软化并最终诱发灾难性破坏(Wang et al., 2022)。甘肃省定西市通渭县常河镇滑坡是 1 处大型古滑坡体复活的典型案例, 该滑坡于 2019 年 9 月在持续降雨作用下重新活动。该滑坡体体积约 774×10^4 m^3, 其复活机制与降雨入渗导致滑带土孔隙水压力升高、力学性质显著劣化密切相关, 揭示了深厚堆积体在水分运移下的失稳过程(Wang et al., 2020)。甘肃省天水市麦积区渭南镇王旗村滑坡则是 1 处人类工程活动诱发的推移式滑坡, 其关键诱发因素为坡体上方人工修建的储水井发生长期渗漏, 水体不断软化黄土−泥岩接触带, 使得抗剪强度下降, 最终在重力作用下导致坡体沿软弱面发生推移式滑动(Wang et al., 2023)。这 3 处案例不仅在地质成因和诱发机制上具有代表性, 且均被研究构建的模型准确预测为高易发区, 证实了模型所采纳的评价因子体系及机器学习算法在识别复杂致灾机理、实现空间精准预测方面的有效性与可靠性。

4.3　模型可解释性分析

4.3.1　驱动因子的贡献与作用方向探讨

为直观揭示评价因子对模型输出的影响, 采用原始数值(即不经过频率比计算的单一 XGBoost 模型)作为输入, 通过 SHAP 值进一步探究关键评价因子如何驱动模型输出。通过计算各评价因子的平均绝对 SHAP 值在所有评价因子平均绝对 SHAP 值

总和中的占比，量化其相对贡献程度，结果如表4所示，可与上文输入的相对权重相呼应。在所有评价因子中，年均降雨量、土壤可侵蚀性和坡度是影响滑坡发生的主要驱动因子，对模型的输出贡献分别为26.59%、20.80%和14.66%（表4）；距道路距离、土地利用类型、海拔和人口密度为次要影响因子（影响值大于5%，小于30%），对模型输出的贡献分别为7.50%、7.38%、6.95%和5.38%；其余评价因子，包括地层岩性、坡向、剖面曲率、平面曲率、震中距和距断层距离对滑坡发生的贡献极低，分别为2.66%、2.22%、2.22%、1.72%、1.00%和0.91%。因此，后续分析将重点讨论年均降雨量、土壤侵蚀性和坡度对滑坡易发性的影响。

评价因子对XGBoost模型输出的影响分布图如图6所示，若特征值（即输入的评价因子）和对应的SHAP值均为正时，模型认为该评价因子的增加有利于滑坡发生；反之则表示其增加不利于滑坡发生。为方便理解，以影响滑坡的主驱动因子为例：当年均降雨量较低（蓝色区域）时，SHAP值为负；年均降雨量较高时（红色区域），SHAP值为正，说明年均降雨量越高对预测滑坡的贡献越大。土壤侵蚀性整体上与滑坡发生呈正相关，即土壤侵蚀性越强（红色区域），对预测滑坡的贡献越大；然而，在少数情况下，高侵蚀性土壤对滑坡发生的贡献呈反作用（紫色区域，红色和蓝色重合）。值得注意的是，坡

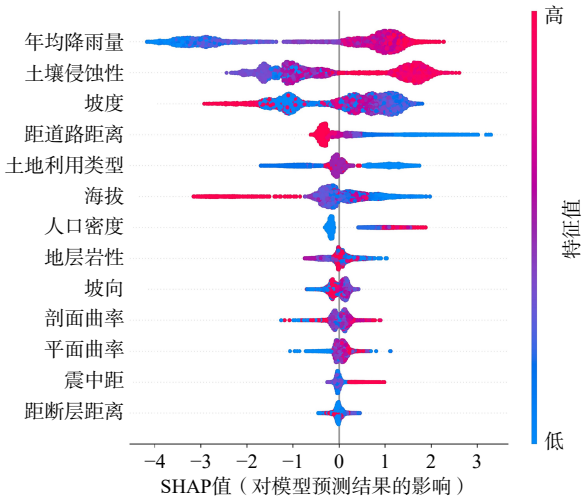
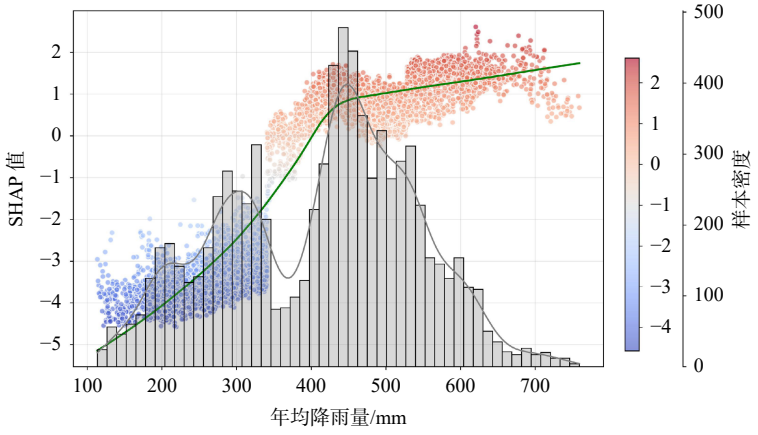


图6 评价因子对XGBoost模型输出的影响分布图

Fig. 6 Distribution of feature impacts on XGBoost model output

度对模型预测滑坡的贡献并非随坡度越陡而单调增加，部分高陡坡度区域的SHAP值为负。另外，图中红蓝点混杂分布的现象说明评价因子对滑坡发生的影响可能并非简单的单调关系，或者该因子与其他特征有较强的相互作用。

年均降雨量、土壤侵蚀性分布范围很广且明显集中在SHAP>0（红点）和SHAP<0（蓝点）的区域，说明这两个因子对区分滑坡高低易发区作用巨大。整体而言，年均降雨量越高、土壤侵蚀性越强的区域，发生滑坡的可能性越大。而震中距、距断层距



散点颜色表示SHAP值的正负（红色为正影响，蓝色为负影响），散点纵坐标对应左侧SHAP值轴；绿色曲线为局部加权回归平滑线，揭示年均降雨量对模型预测的非线性影响模式；灰色直方图及灰色核密度曲线表示年均降雨量的样本分布密度，对应右侧样本密度轴

图7 年均降雨量SHAP分布特征

Fig. 7 Distribution characteristics of SHAP values for annual average rainfall

The scatter point colors represent the sign and magnitude of SHAP values (red indicates positive influence, blue indicates negative influence), with the vertical coordinates corresponding to the left SHAP value axis. The green curve shows the locally weighted regression smoothing line, revealing the nonlinear influence pattern of annual average rainfall on model predictions; the gray histogram and gray kernel density curve represent the sample distribution density of annual average rainfall, corresponding to the right sample density axis.

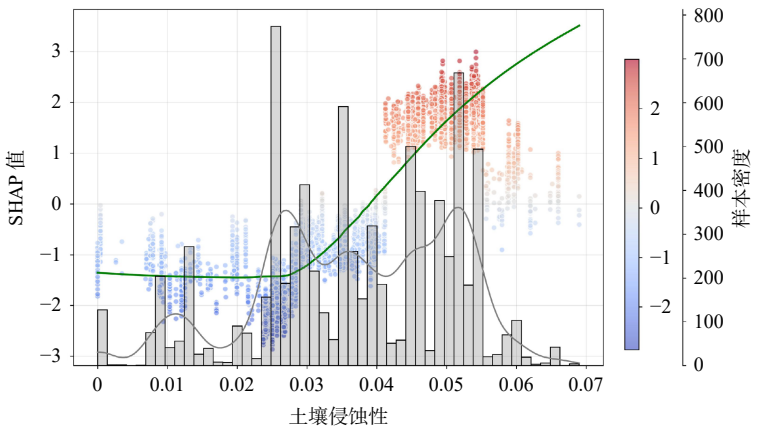
离的 SHAP 值分布范围较窄且靠近 0，说明其在这个模型中整体影响力较弱。

4.3.2　关键评价因子的 SHAP 分布特征

年均降雨量的 SHAP 分布特征如图 7 所示，红点代表正向 SHAP 值（即该特征值增大时对滑坡预测结果起促进作用），蓝点表示负向 SHAP 值；绿色曲线代表局部回归线（LOWESS），用来刻画特征值与 SHAP 值之间的非线性趋势；灰色直方图和右纵轴表示样本密度值。

整体而言，年均降雨量的增大对滑坡预测具有正向推动作用；研究区滑坡事件主要集中分布在年降雨量 400～500 mm 的区间，也揭示该降雨量范围内历史滑坡发生的频次最高。年均降雨量达到 300 mm 左右时，SHAP 值由负转正，表明降雨对滑坡的驱动作用开始显现；在 400～500 mm 区间，该因子对滑坡预测的贡献达到峰值。

土壤侵蚀性 SHAP 分布特征（图 8）显示，土壤侵蚀性对模型预测结果的影响表现为初期变化平缓，随后呈指数上升的趋势。在土壤侵蚀性大于 0.04 的区间内（图中红点区域），其值增大会提升对滑坡预测的贡献率，表明在此区间内土壤侵蚀性与滑坡发生可能呈正相关关系；而蓝点所在区域则表示在相应范围内，土壤侵蚀性的增加会降低滑坡预测的贡献率，呈现负相关关系。局部回归线刻画了土壤侵蚀性超过 0.03 后，滑坡发生的概率急剧增加。



散点颜色表示 SHAP 值的正负（红色为正影响，蓝色为负影响），散点纵坐标对应左侧 SHAP 值轴；绿色曲线为局部加权回归平滑线，揭示土壤侵蚀性对模型预测的非线性影响模式；灰色直方图及灰色核密度曲线表示土壤侵蚀性的样本分布密度，对应右侧样本密度轴

图 8　土壤侵蚀性 SHAP 分布特征

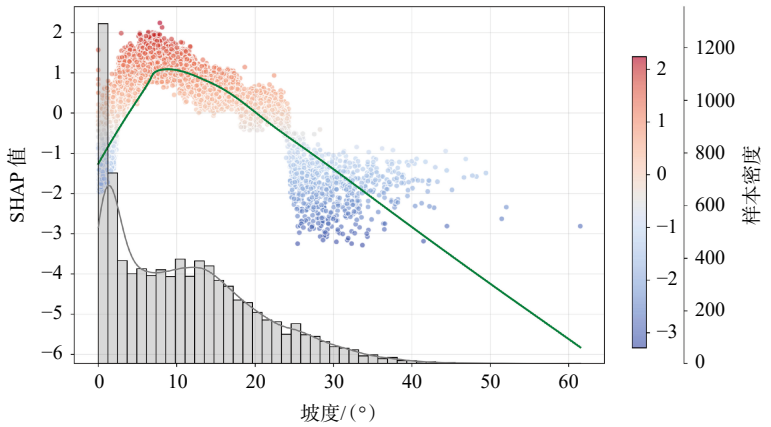
Fig. 8　Distribution characteristics of SHAP values for soil erodibility

The scatter point colors represent the sign and magnitude of SHAP values (red indicates positive influence, blue indicates negative influence), with the vertical coordinates corresponding to the left SHAP value axis. The green curve shows the locally weighted regression smoothing line, revealing the nonlinear influence pattern of soil erodibility on model predictions; the gray histogram and gray kernel density curve represent the sample distribution density of soil erodibility, corresponding to the right sample density axis.

不同坡度值对应的 SHAP 值通过红点和蓝点清晰区分（图 9）。坡度对模型预测结果的影响表现为先增强后减弱的趋势。当坡度较小时（0°～5°），SHAP 值为负，表明坡度对滑坡发生起抑制作用；随着坡度增大至中等范围（5°～15°），SHAP 值逐渐升高并转为正值，模型预测结果随之增加，说明此时坡度对滑坡发生具有促进作用，为模型最为敏感的区间；而当坡度继续增大（>20°）时，SHAP 值又明显下降，甚至转为负值，意味着坡度在大于 25°时对滑坡发生的贡献减弱甚至起反作用。结合样本密度分布可见，大多数样本集中在低坡度区，而高坡度区域样本数量较少。这种分布特征与研究区滑坡机制相呼应：在缓坡范围内（如 5°～20°），黄土滑坡的典型模式是剪切滑动，通常沿一个清晰的圆弧形或平面滑面整体下滑；而当坡度过陡时，由于垂直节理发育，土体破坏模式会发生改变，更容易发生倾倒式的崩塌，而不是整体滑动。总体而言，坡度对模型输出的影响呈单峰型变化，5°～20°区间最易诱发滑坡。

4.3.3　关键驱动因子的偏依赖特征

为深入探讨关键因子之间的交互关系及其对滑坡易发性的联合作用机制，基于 PDP 揭示了主要

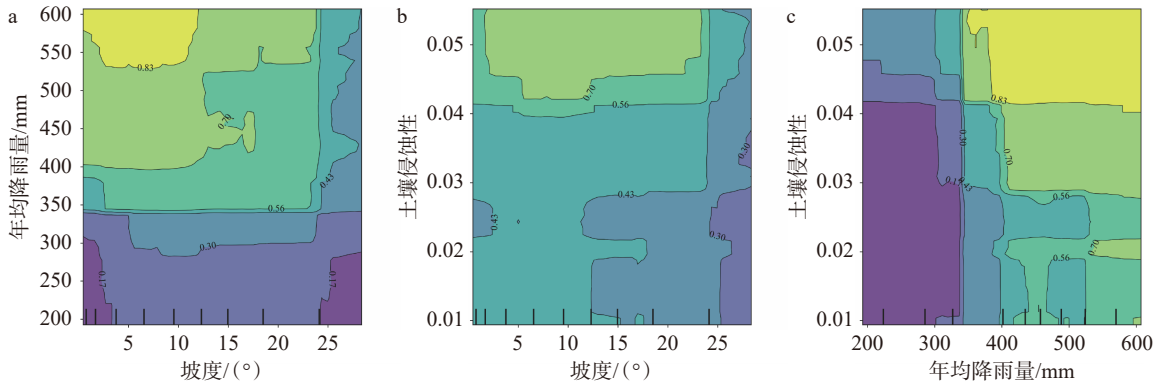


散点颜色表示 SHAP 值的正负(红色为正影响，蓝色为负影响)，散点纵坐标对应左侧 SHAP 值轴；绿色曲线为局部加权回归平滑线，揭示坡度对模型预测的非线性影响模式；灰色直方图及灰色核密度曲线表示坡度的样本分布密度，对应右侧样本密度轴

图 9 坡度 SHAP 分布特征

Fig. 9 Distribution characteristics of SHAP values for slope gradient

The scatter point colors represent the sign and magnitude of SHAP values (red indicates positive influence, blue indicates negative influence), with the vertical coordinates corresponding to the left SHAP value axis. The green curve shows the locally weighted regression smoothing line, revealing the nonlinear influence pattern of slope gradient on model predictions; the gray histogram and gray kernel density curve represent the sample distribution density of slope gradient, corresponding to the right sample density axis.



a—坡度与年均降雨量的交互效应；b—坡度与土壤侵蚀性的交互效应；c—年均降雨量与土壤侵蚀性的交互效应

图 10 关键驱动因子的偏依赖特征

Fig. 10 Partial dependence characteristics of key driving factors

(a) Interaction effect between slope gradient and annual average rainfall; (b) Interaction effect between slope gradient and soil erodibility; (c) Interaction effect between annual average rainfall and soil erodibility

因子之间的非线性交互作用特征。通过将原始特征变量输入至已训练完成的 XGBoost 模型中，构建了 3 组二维 PDP 图进行分析(图 10)。

坡度与年均降雨量对滑坡预测结果表现出明显的非线性交互特征(图 10a)。在坡度介于 0°～13°且年均降雨量超过 500 mm 的情境下，模型预测的滑坡概率最高；相反，当坡度小于 5°或大于 25°，且年均降雨量低于 300 mm 时，模型预测的滑坡概率显著降低。这表明坡度与降雨量对滑坡的发生具有耦合增强效应。

坡度与土壤可侵蚀性的交互效应如图 10b 所示。当坡度大于 25°时，即使土壤侵蚀性较高(>0.04)，其对滑坡预测值的影响也较为有限；而在 0°～25°坡度范围内，土壤侵蚀性超过 0.04 时，对滑坡预测的贡献显著增强。这表明在这一坡度范围区域的高侵蚀性土壤更易引发滑坡事件，两者联合起到了放大作用。

年均降雨量与土壤侵蚀性之间的交互关系如图 10c 所示。当年均降雨量低于 300 mm，无论土壤侵蚀性强弱，其对滑坡预测结果的影响均较小。而

当土壤侵蚀性大于 0.04 且年均降雨量超过 400 mm 时，模型预测的滑坡概率显著升高。该结果说明在一定阈值条件下，降雨与土壤特性的协同作用将显著增加滑坡发生的可能性。综上所述，关键因子间存在复杂的非线性交互作用，不同变量组合对模型预测结果呈现出明显差异，PDP 图所展现的这些交互特征有助于深化对滑坡形成机制的理解。

5　结论

以黄土高原为研究区，构建并对比分析了优化的 XGBoost、FR−XGBoost 和 FR−RF 滑坡易发性评价模型，系统评估了区域滑坡易发性分布格局，并深入对比了单一模型与耦合模型的预测性能。进一步从模型可解释性的角度，探讨了研究区关键驱动因子的作用机制及其交互关系。

（1）在模型预测性能方面，耦合频率比加权机制的 FR−XGBoost 与 FR−RF 模型（AUC 分别达 0.968 和 0.963）显著优于单一 XGBoost 模型（AUC=0.805）。这一结果验证了频率比与机器学习方法相结合在滑坡易发性建模中的有效性。通过频率比方法，模型不仅能够保留因子的权重信息，还能够进一步挖掘评价因子与滑坡响应之间的复杂非线性关系。该发现为今后滑坡易发性建模提供了更加精准的预测工具，并为其他区域的类似研究提供参考。

（2）在模型可解释性方面，借助 SHAP 方法对模型的可解释性进行量化分析，识别出年均降雨量（SHAP 贡献度 26.59%）、土壤侵蚀性（20.80%）和坡度（14.66%）是滑坡易发性预测中最为关键的驱动因子。年均降雨量与土壤侵蚀性呈正向驱动关系，且在较高值区间对滑坡预测的贡献显著增强；而坡度对滑坡易发性的影响则表现出非单调性，模型的响应呈现单峰型，坡度在 5°～20°之间为最敏感区间。这一发现揭示了黄土高原滑坡发育的主控机制，指出降雨−侵蚀−坡度三者共同构成了该区域滑坡发生的核心动力系统。

（3）因子交互作用分析揭示出关键变量间的非线性协同效应显著改变滑坡风险判别边界。具体而言，“中低坡度（5°～20°）−强降雨（>400 mm）−强侵蚀（>0.04）”的组合模式定义了该类地区一类典型的高风险环境类型，其滑坡发生概率显著增长。该发现不仅从机理层面阐释了多因子耦合如何驱动风险临界状态转变，也为区域风险判别提供了明确的量化依据。

（4）研究结果对黄土高原地区地质灾害防控与空间规划具有明确的政策启示。建议在“中低坡度−强降雨−强侵蚀”重合区域实施重点监测与工程治理，将上述因子阈值作为风险早期识别的重要指标纳入地方防灾规划。此外，研究提出的可解释机器学习框架也可为其他灾害风险评价提供方法论借鉴，推动地质灾害管理从经验判断向智能化决策转型。

References

CHAI H X, CHENG W M, QIAO Y L, 2006. Classification system of 1: 1 000 000 digital loess geomorphology in China[J]. Journal of Geo-information Science, 8(2): 6-13. (in Chinese with English abstract)

CHEN D L, AN X L, SHAO H Y, et al., 2025. Quantitative assessment of landslide hazard susceptibility and key driving factors in Loess Plateau geomorphologic area[J]. Journal of Beijing Normal University (Natural Science), 61(2): 255-267. (in Chinese with English abstract)

CHEN T Q, GUESTRIN C, 2016. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco: ACM: 785-794.

DONG J W, ZHOU Y, YOU N S, et al. , 2021. A 30-m annual maximum NDVI dataset in China from 2000 to 2022 [DS/OL]. National Ecosystem Science Data Center.

DOU J, XIANG Z L, XU Q, et al., 2023. Application and development trend of machine learning in landslide intelligent disaster prevention and mitigation[J]. Earth Science, 48(5): 1657-1674. (in Chinese with English abstract)

FU X P, WANG M, ZHANG D Q, et al., 2025. An XGBoost-SHAP framework for identifying key drivers of urban flooding and developing targeted mitigation strategies[J]. Ecological Indicators, 175: 113579.

HONG H Y, POURGHASEMI H R, POURTAGHI Z S, 2016. Landslide susceptibility assessment in Lianhua County (China): a comparison between a random forest data mining technique and bivariate and multivariate statistical models[J]. Geomorphology, 259: 105-118.

HUSSAIN M A, CHEN Z L, ZHOU Y L, et al., 2025. Landslide susceptibility mapping using artificial intelligence models: a case study in the Himalayas[J]. Landslides, 22(6): 2089-2103.

KE C Y, HE S, QIN Y G, 2023. Comparison of natural breaks method and frequency ratio dividing attribute intervals for landslide susceptibility mapping[J]. Bulletin of Engineering Geology and the Environment, 82(10): 384.

KE C Y, SUN P, ZHANG S, et al., 2025. Influences of non-landslide sampling strategies on landslide susceptibility mapping: a case of Tianshui city, Northwest of China[J]. Bulletin of Engineering Geology and the Environment, 84(3): 123.

LI M, HE H, WU D L, et al., 2025. The spatial-temporal evolution of soil erosion in the Loess Plateau under the context of climate change[J]. Acta Ecologica Sinica, 45(16): 7793-7807. (in Chinese with English abstract)

LI T L, WANG C Y, LI P, 2013. Loess deposit and loess landslides on the Chinese loess plateau[M]//WANG F W, MIYAJIMA M, LI T L, et al.

Progress of geo-disaster mitigation technology in Asia. Berlin Heidelberg: Springer: 235-261.

LIU J, LI S L, CHEN T, 2018. Landslide susceptibility assesment based on optimized random forest model[J]. Geomatics and Information Science of Wuhan University, 43(7): 1085-1091. (in Chinese with English abstract)

LIU T S, 1985. Loess and the environment[M]. Beijing: Science Press. (in Chinese)

LUNDBERG S M, LEE S I, 2017. A unified approach to interpreting model predictions[C]//Proceedings of the 31st international conference on neural information processing systems. Long Beach: Curran Associates Inc. : 4768-4777.

LV L, CHEN T, LIU G, et al., 2025. A comparative study of model interpretability considering the decision differentiation of landslide susceptibility models[J]. IEEE Transactions on Geoscience and Remote Sensing, 63: 4401218.

NAN S H, LI J J, WEI J F, et al., 2025. Driving and synergistic effects of water quality indexes on dissolved oxygen in basin based on XGBoost-SHAP model[J]. Water Resources and Power, 43(7): 52-56. (in Chinese with English abstract)

PENG J B, LIN H C, WANG Q Y, et al., 2014. The critical issues and creative concepts in mitigation research of loess geological hazards[J]. Journal of Engineering Geology, 22(4): 684-691. (in Chinese with English abstract)

PENG J B, WANG Q Y, ZHUANG J Q, et al., 2020. Dynamic formation mechanism of landslide disaster on the Loess Plateau[J]. Journal of Geomechanics, 26(5): 714-730. (in Chinese with English abstract)

PRADHAN B, DIKSHIT A, LEE S, et al., 2023. An explainable AI (XAI) model for landslide susceptibility modeling[J]. Applied Soft Computing, 142: 110324.

QIN Y G, YANG G L, LU K P, et al., 2021. Performance evaluation of five GIS-based models for landslide susceptibility prediction and mapping: a case study of Kaiyang County, China[J]. Sustainability, 13(11): 6441.

REICHENBACH P, ROSSI M, MALAMUD B D, et al., 2018. A review of statistically-based landslide susceptibility models[J]. Earth-Science Reviews, 180: 60-91.

TONG B, YIN Y P, LI B, et al., 2025. Review on artificial intelligence-based large language models for geological hazards[J]. The Chinese Journal of Geological Hazard and Control, 36(2): 1-12. (in Chinese with English abstract)

WANG H G, HU M T, LIU X C, 2025. Reconstruction and interpretability analysis of China's food security level based on machine learning and SHAP algorithm[J]. Journal of China Agricultural University, 30(7): 264-274. (in Chinese with English abstract)

WANG H J, SUN P, ZHANG S, et al., 2020. Rainfall-induced landslide in loess area, Northwest China: a case study of the Changhe landslide on September 14, 2019, in Gansu Province[J]. Landslides, 17(9): 2145-2160.

WANG H J, SUN P, ZHANG S, et al., 2022. Evolutionary and dynamic processes of the Zhongzhai landslide reactivated on October 5, 2021, in Niangniangba, Gansu Province, China[J]. Landslides, 19(12): 2983-2996.

WANG H J, SUN P, REN J, et al., 2023. Reactivation mechanism and run-out processes of the Wangqi landslide induced by water leakage on April 30, 2022, in Tianshui City, Gansu Province, China[J]. Landslides, 20(5): 999-1011.

WANG K, WU L Y, YIN K L, et al., 2025. Shallow landslide susceptibility assessment based on BO-XGBoost model in Quzhou[J]. Safety and Environmental Engineering, 32(3): 197-209. (in Chinese with English abstract)

WANG L M, GUO A N, WANG P, et al., 2020. Characteristics and Revelation of Great Haiyuan Earthquake Disaster[J]. City and Disaster Reduction, (06): 43-53. (in Chinese)

WEI R Z, WANG Q, ZHUANG Q et. al., 2022. Discussion on late cenozoic stratigraphic features and earth surface processes in the middle reaches of the Yellow River and its adjacent regions[J]. Quaternary Sciences, 42(03): 823-842. (in Chinese with English abstract)

WU S R, SHI J S, WANG T, et al. , 2012. Theory and methodology of landslide risk assessment[M]. Beijing: Science Press. (in Chinese)

XU C, WU X Y, XU X W, 2018. Earthquake-triggered landslides in the Loess Plateau and its adjacent areas[J]. Journal of Engineering Geology, 26(S1): 260-273. (in Chinese with English abstract)

XU Q, DONG X J, LI W L, 2019. Integrated space-air-ground early detection, monitoring and warning system for potential catastrophic geohazards[J]. Geomatics and Information Science of Wuhan University, 44(7): 957-966. (in Chinese with English abstract)

XU Q, PENG D L, FAN X M, et al., 2025. Preliminary study on the characteristics and initiation mechanism of Zhongchuan flowslide due to liquefaction triggered by the Ms 6.2 Jishishan earthquake in Gansu Province[J]. Geomatics and Information Science of Wuhan University, 50(2): 207-222. (in Chinese with English abstract)

XU X W, HAN Z J, YANG X P, et al. , 2016. Seismotectonic map of China and adjacent areas[M]. Beijing: Seismological Press. (in Chinese with English abstract)

YUAN B Y, TANG G A, ZHOU L P, et al. , 2007 Control action of the Cenozoic tectogenesis on the geomorphic differentiation in Loess Plateau and the formation of Yellow River[J]. Quaternary Sciences. 32(05): 829-838. (in Chinese with English abstract)

YANG J, HUANG X, 2021. The 30 m annual land cover dataset and its dynamics in China from 1990 to 2019[J]. Earth System Science Data, 13(8): 3907-3925.

YE T Z, HUANG C K, DENG A Q. 2017. Spatial database of 1: 2500000 digital geologic map of People's Republic of China[J]. Geology in China, 44(S1): 19−24. (in Chinese with English abstract)

ZHANG S, SUN P, REN J, et al., 2022. Successful emergency evacuation from a catastrophic loess landslide reactivated by the torrential rain in October 2021 in Tianshui, Ganusu, NW China[J]. Geoenvironmental Disasters, 9(1): 19.

ZHANG S, SUN P, LI R, et al., 2023. Preliminary investigation on a catastrophic loess landslide induced by heavy rainfall on 1 September 2022 in Qinghai, China[J]. Landslides, 20(7): 1553-1559.

ZHOU C, YIN K L, CAO Y, et al., 2020. Landslide susceptibility assessment by applying the coupling method of radial basis neural network and adaboost: a case study from the three gorges reservoir area[J]. Earth Science, 45(6): 1865-1876. (in Chinese with English abstract)

ZHOU S Q, LIU Z Y, WANG M, et al., 2022. Impacts of building configurations on urban stormwater management at a block scale using XGBoost[J]. Sustainable Cities and Society, 87: 104235.

附中文参考文献

柴慧霞，程维明，乔玉良，2006. 中国“数字黄土地貌”分类体系探讨[J]. 地球信息科学，8(2)：6-13.

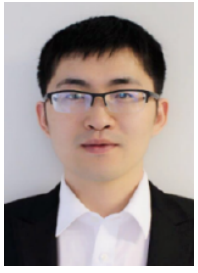
陈丹璐，安雪莲，邵怀勇，等，2025. 黄土塬地貌区滑坡灾害易发性量化评估及关键驱动因子[J]. 北京师范大学学报(自然科学版)，61(2)：255-267.
董金玮，周岩，尤南山，等，2021. 2000-2022 年中国 30 米年最大 NDVI 数据集[DS/OL]. 国家生态科学数据中心.
窦杰，向子林，许强，等，2023. 机器学习在滑坡智能防灾减灾中的应用与发展趋势[J]. 地球科学，48(5)：1657-1674.
李曼，何昊，吴东丽，等，2025. 气候变化背景下黄土高原土壤侵蚀时空演变[J]. 生态学报，45(16)：7793-7807.
刘东生，1985. 黄土与环境[M]. 北京：科学出版社.
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[J]. 武汉大学学报(信息科学版)，43(7)：1085-1091.
南淑荷，李进军，魏佳芳，等，2025. 基于 XGBoost-SHAP 模型的流域水质指标对 DO 的驱动与协同影响分析[J]. 水电能源科学，43(7)：52-56.
彭建兵，林鸿州，王启耀，等，2014. 黄土地质灾害研究中的关键问题与创新思路[J]. 工程地质学报，22(4)：684-691.
彭建兵，王启耀，庄建琦，等，2020. 黄土高原滑坡灾害形成动力学机制[J]. 地质力学学报，26(5)：714-730.
佟彬，殷跃平，李昊，等，2025. 地质灾害人工智能大语言模型研究展望[J]. 中国地质灾害与防治学报，36(2)：1-12.
王兰民，郭安宁，王平，等，2020. 1920 年海原大地震震害特征与启示[J]. 城市与减灾，(06)：43-53.
王火根，胡梦婷，刘小春，2025. 基于机器学习和 SHAP 算法的我国粮食安全水平测度重构及可解释性分析[J]. 中国农业大学学报，30(7)：264-274.
王凯，邬礼扬，殷坤龙，等，2025. 基于 BO-XGBoost 模型的衢州市浅层滑坡易发性评价[J]. 安全与环境工程，32(3)：197-209.
吴树仁，石菊松，王涛，等，2012. 滑坡风险评估理论与技术[M]. 北京：科学出版社.
魏荣珠，王权，庄其天，等，2022. 黄河中游及邻区晚新生代地层特征及地表过程讨论[J]. 第四纪研究，42(03)：823-842.
许冲，吴熙彦，徐锡伟，2018. 黄土高原及邻区的地震滑坡[J]. 工程地质学报，26(S1)：260-273.
许强，董秀军，李为乐，2019. 基于天-空-地一体化的重大地质灾害隐患早期识别与监测预警[J]. 武汉大学学报(信息科学版)，44(7)：957-966.
许强，彭大雷，范宣梅，等，2025. 甘肃积石山 Ms 6.2 地震触发青海中川乡液化型滑坡-泥流特征与成因机理[J]. 武汉大学学报(信息科学版)，50(2)：207-222.
徐锡伟，韩竹军，杨晓平，等，2016. 中国及邻近地区地震构造图[M]. 北京：地震出版社.
叶天竺，黄崇轲，邓志奇. 2017. 1：250 万中华人民共和国数字地质图空间数据库[J]. 中国地质，44(S1)：19-24.
袁宝印，汤国安，周力平，等，2012. 新生代构造运动对黄土高原地貌分异与黄河形成的控制作用[J]. 第四纪研究，32(05)：829-838.
周超，殷坤龙，曹颖，等，2020. 基于集成学习与径向基神经网络耦合模型的三峡库区滑坡易发性评价[J]. 地球科学，45(6)：1865-1876.

第一作者简介：



孙萍，研究员，博士生导师，自然资源部高层次科技创新领军人才、自然资源部地质灾害陕西宝鸡野外科学观测研究站首席科学家。先后主持国家自然科学基金重点项目、国家重点研发计划课题、国家自然科学基金重大项目课题、香港研究资助局项目、中国地质调查项目等 10 余项。以第一作者（通讯作者）发表论文 50 余篇、专著 1 部。现任中国地质科学院地质力学研究所科学技术委员会副主任与地质安全风险评价研究室副主任、中国地质学会工程地质专委会委员、中国岩石力学与工程学会工程地质力学分会常务理事、中国岩石力学与工程学会红层工程分会常务理事与副秘书长、国际地质灾害与减灾联合会（ICGdR）执行理事、中国地震学会地震灾害链专业委员会副主任委员；担任 *Geoenvironmental Disasters* 期刊副主编，以及 *Landslides*、《地质力学学报》、*Engineering Geology*、*Bulletin of Engineering Geology and the Environment* 等期刊编委和审稿人。

通信作者简介：



张帅，博士，副研究员。现任国际地质灾害与减灾协会（ICGdR）主席助理、中国岩石力学与工程学会红层工程分会理事，担任 *Geoenviromental disasters*、*China Geology* 及《地震工程学报》等期刊青年编委，并为 *Landslides*、*Scientific Reports*、*Bulletin of Engineering Geology and the Environment* 等期刊的审稿人。先后主持国家自然科学基金青年项目、重点项目课题、重点国际合作研究项目课题等 10 余项。以第一作者或通讯作者发表学术论文 10 余篇，获授权国家发明专利 2 项。曾获得 ICGdR 优秀博士论文奖、*Geoenviromental disasters* 期刊最佳论文奖、ICGdR“周地英才”称号等多项荣誉。