

# 基于机器学习的滑坡易发性评价多模型对比与 SHAP 解释分析

王龙辉<sup>1</sup> 唐亚明<sup>2\*</sup> 周永恒<sup>3</sup> 刘志恒<sup>2</sup>

1. 中国地质科学院, 北京 100037

2. 中国科学院地球环境研究所, 陕西 西安 710061

3. 中国地质大学(武汉), 湖北 武汉 430074

**摘要:**【目的】黄土高原滑坡灾害频发, 严重威胁区域安全。传统易发性评价方法难以处理高维非线性因子, 机器学习模型虽应用广泛, 但存在“黑箱”局限, 且多模型对比与可解释性研究尚显不足。【方法】以山西省乡宁县为研究区, 选取高程、坡度、坡向、曲率、地形起伏度、地层岩性、河流距、断裂距、道路距、NDVI、土地利用类型 11 个评价因子, 构建支持向量机(SVM)、人工神经网络(ANN)、随机森林(RF)、极端梯度提升(XGBoost)四种滑坡易发性评价模型。采用混淆矩阵与 ROC 曲线对比模型精度, 并引入 SHAP 算法对最优模型进行全局与局部可解释性分析, 量化各因子对滑坡发生的贡献程度。【结果】四种模型 AUC 值分别为 0.8984、0.9031、0.9935、0.9999, RF 与 XGBoost 模型性能显著优于 SVM 和 ANN, 其中 XGBoost 综合表现最优。SHAP 解释表明, 坡度和土地利用类型是研究区滑坡发育的主导控制因子, 地表起伏度、地层岩性次之; 坡度越大, 滑坡发生概率越高。【结论】集成学习模型在黄土滑坡易发性评价中具有更高精度与稳定性, SHAP 算法有效增强了模型的可解释性, 研究结果可为黄土高原地质灾害防治与风险管理提供科学参考。

**关键词:** 滑坡易发性; 机器学习; 模型对比; SHAP; 黄土高原; 乡宁县

## 0 引言

滑坡是黄土高原最为常见且危害性极强的地质灾害之一, 其发生受地形地貌、岩土结构、降雨、地震、植被覆盖以及人类工程活动等多种因素综合影响, 具有空间分布复杂、触发机制多样和预测难度大的特点。随着全球气候变化与极端降雨事件增多, 滑坡灾害的发生频率呈上升趋势, 严重威胁区域生态安全、基础设施建设与居民生命财产安全<sup>[1][2][3]</sup>。因此, 构建科学、高效的滑坡易发性预测模型, 对于地质灾害调查、预警、防治和土地利用管理具有重要意义。

滑坡易发性评价是通过分析历史滑坡的空间分布特征, 同时结合地形、地貌、水文、植被及人类工程活动等环境因子来预测未来可能发生的滑坡空间位置和概率。传统的易发性评价方法如信息量法<sup>[4]</sup>、综合指数法<sup>[5]</sup>等在一定程度上推动了滑坡灾害研究的发展, 但这些方法通常依赖线性假设或专家经验, 对高维多源及非线性环境因子的处理能力有限, 难以全面揭示滑坡形成机制中的复杂耦合关系。

随着地理信息系统(GIS)与遥感(RS)技术的发展, 研究者能够获取高精度的空间地理数据与灾害信息, 机器学习技术在滑坡预测中的应用得到快速发展, 基于数据驱动的预测方法逐渐成为滑坡易发性研究的重要趋势<sup>[6][7]</sup>。其中支持向量机(SVM)<sup>[8][9]</sup>、随机森林(RF)<sup>[10][11][12][13][14]</sup>、人工神经网络(ANN)<sup>[15]</sup>、极端

梯度提升(XGBoost)<sup>[16][17]</sup>等机器学习方法在自主学习滑坡发生的潜在规律、提高滑坡空间预测精度和提升模型鲁棒性方面已经表现出显著优势。然而, 不同机器学习模型在理论基础、结构形式及建模假设等方面均存在差异, 因而在滑坡易发性预测中的表现亦具有一定局限性, 在适用范围和预测准确性方面也存在显著差异。因此, 有必要通过对比多种机器学习模型来选取性能最优的开展应用<sup>[18]</sup>, 从而获得更稳定、可靠且具有实践意义的滑坡易发性评价结果。

此外, 大多数机器学习模型属于黑箱模型, 尽管部分模型在预测精度方面表现优异, 但模型可解释性相对不足, 难以明确量化单一环境因子对滑坡发生的贡献。目前已有研究表明通过 SHAP 解释机器学习模型, 可量化评估每个影响因子对滑坡发生概率的贡献度, 揭示影响因子对滑坡发育的影响, 增强模型可信度与可解释性<sup>[19]</sup>, 故本研究通过多模型对比选取性能优异的模型, 通过 SHAP 实现对模型预测结果进行解释。

在此背景下, 本文以山西省临汾市乡宁县为研究区, 选取高程、坡度、坡向、曲率、地形起伏度、地层岩性、河流距、断裂距、道路距、归一化植被覆盖指数(NDVI)、土地利用类型 11 个评价因子, 支持向量机、随机森林、人工神经网络、极端梯度提升 4 种机器学习模型开展研究。目标对各模型滑坡易发性预测结果进行评估对比, 选取最佳模型通过 SHAP 进行模型解释, 分析研究区滑坡发育的主控因子, 直

观展示不同特征对滑坡易发性评价结果的影响, 希望为黄土高原地区滑坡灾害预测提供科学参考。

### 1 研究区

#### 1.1 研究区概况

乡宁县隶属于山西省临汾市, 位于黄河中游, 吕梁山脉南端, 临汾市西隅。地理位置介于: 东经 110° 30' 18" —111° 16' 57" , 北纬 35° 41' 30" —36° 09' 07" 之间(图1), 县域总面积约 2029km<sup>2</sup>。乡宁县为临汾盆地与吕梁山的结合部, 大地构造为山西台背斜, 属中国台区华北地台的一个隆起区, 全县总体地势北东高, 南西略低, 海拔在 334m—1788m, 地貌单元主要为中起伏中山、小起伏中山、黄土高原与丘陵和堆积河谷地貌。

乡宁县属暖温带半干旱大陆季风性气候, 大陆气候特征明显, 季风强盛。多年平均降雨量为 524.8mm (乡宁县气象局 1985—2024 年降雨数据)。县内水系发育丰富, 河流分别自东向西直入黄河和自北向南流入汾河再汇入黄河。境内河流与沟谷切割深度极限值可达近千米, 县内长度大于 1km 的沟道有 253 条, 其中 10km 以上沟道 36 条, 5km 以上沟道 46 条。

县内岩性出露主要为灰岩、砂岩、泥岩等, 表层覆盖风成黄土及松散堆积物, 岩土体性质软弱, 断层、节理发育, 县域地震设防烈度为 VII—VIII 度。研究区内地质环境脆弱, 地质灾害分布广泛(图1), 受限于地形条件, 乡宁县人口密集区多位于山地坡脚及河流阶地, 抵抗自然灾害能力较弱, 在极端降雨条件下, 人民生命财产安全受到极大威胁。

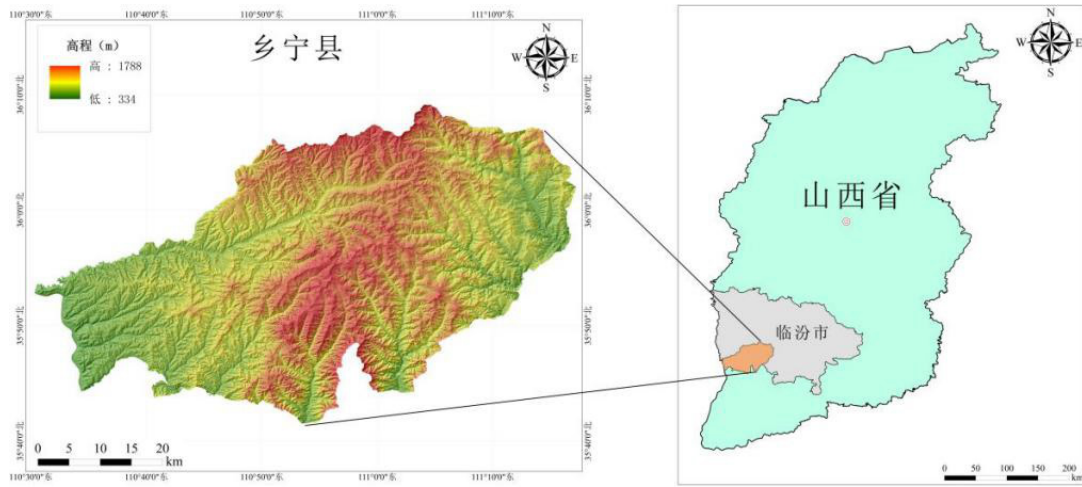


图1 乡宁县地理位置图

#### 1.2 数据来源

滑坡数据来源于 2005~2019 年间黄土高原

区实施的 1: 5 万地质灾害调查数据和乡宁县野外调查补充滑坡点, 共计 10463 处。环境因子选取用到的具体数据来源如下表 1 所示。

表1 数据来源

数据名称	数据来源	类型	精度
历史滑坡	西安地质调查中心	数据表	---
DEM	Global digital elevation model(GDEM)	栅格	30m
地质资料	国家地质资料数据中心	矢量	1: 500000
河网	中科院资源环境科学数据中心	矢量	1: 100000
道路	中科院资源环境科学数据中心	矢量	1: 100000
NDVI	Landsat 8卫星	栅格	30m
土地利用	地理国情监测云平台	矢量	1: 100000

环境因子的选择与建模性能密切相关, 本研究通过分析研究区滑坡发育规律和已有文献的因子选择方案, 并结合环境因子的获取难易程度, 最终确定选取 11 个滑坡环境因子进行分析, 具体为高程、坡度、坡向、曲率、地形起伏度、

与滑坡的发育密切相关; 地层岩性别决定了斜坡岩土体的密度、强度和剪切模量等物理力学特性, 对坡体稳定性有直接影响; 断层走向垂直方向易于地震波传导, 传播能量更大<sup>[20]</sup>, 断层影响距离关系到滑坡是否易于触发; 人类交通建设对坡体会造成扰动, 包括坡脚破坏等类似问题改变了坡体稳定性; 河流作用对沟谷不断侵蚀会削减坡体稳定性<sup>[21]</sup>, 也需作为影响因子考虑; 植被覆盖影响着降雨入渗和坡体含水率以及雨水对坡体的侵蚀强度, 在黄土地区影

地层岩性、河流距、断裂距、道路距、归一化植被覆盖指数 (NDVI)、土地利用类型(图2)。其中, 高程代表着坡体的势能, 关系到滑坡的滑动距离和范围; 坡度、坡向、曲率、地表起伏度等地形因子反映了斜坡自然结构情况,

响更甚;土地利用能够反映人类活动强度大小,是影响斜坡稳定性的一个重要因素。

栅格单元形状规则、易于分割、建模效率高,用30m分辨率既能保证栅格可以相对代表滑坡特征且计算量适中便于实现<sup>[7][22]</sup>,因此本研究所用数据均统一为30m空间分辨率栅格,在此基础上建立样本数据集。

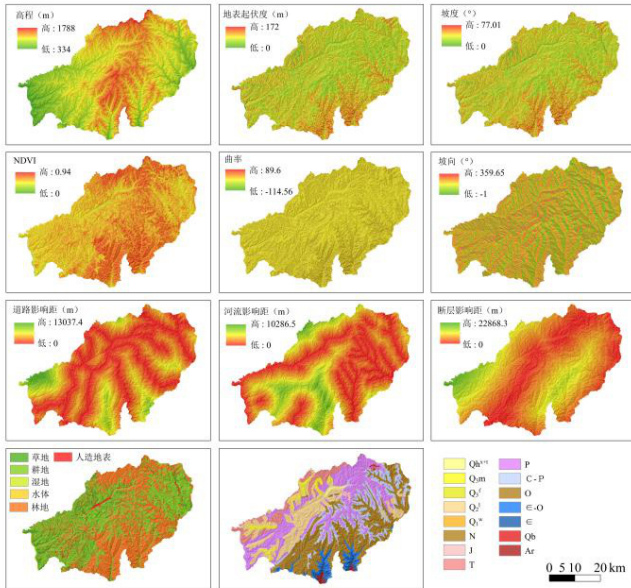


图2 环境因子图

## 2 研究方法

本研究基于SVM、RF、ANN、XGBoost算法构建滑坡易发性区划模型。训练样本集中正样本来源于2005~2019年间黄土高原区实施的1:5万地质灾害调查数据,涉及黄土高原范围内的陕、甘、宁、青、晋等省(区)的地质灾害高和极高易发区,包括滑坡10464处。负样本从无滑坡区中坡角为20°~50°的斜坡<sup>[2]</sup>中等比例随机生成,对于最终训练样本以7:3比例随机划分,其中70%用于模型训练,剩余30%用于测试检验,通过混淆矩阵和ROC曲线评价模型精度,最后通过SHAP算法进一步解释影响因子对滑坡发育的影响。

### 2.1 评价因子处理

#### 2.1.1 方差膨胀因子

本研究通过方差膨胀因子(variance inflation factor, VIF)方法计算各评价因子的VIF值来评估其共线性程度,筛选VIF值小于10的因子。公式(1)如下:

$$VIF_i = \frac{1}{1-R_i^2} \quad (1)$$

式中,  $R_i^2$  为第*i*个因子与其他因子之间的决定系数。

#### 2.1.2 归一化处理

所有环境评价因子转化为30m栅格后,对因子进行归一化处理,以消除量纲差异影响,公式(2)如下:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

式中,  $X$  为原始数据,  $X_{\min}$  与  $X_{\max}$  分别表示样本的最小值与最大值,  $X'$  为归一化后的数值。归一化处理后能够将各因子不同数值区间统一转换到  $[0,1]$ , 有助于平衡不同特征的数值范围,避免特征尺度差异过大导致模型倾向于选择数值较大的特征,可进一步提升模型的稳定性。

### 2.2 机器学习模型

#### 2.2.1 支持向量机 (Support Vector Machine, SVM)

SVM是一种基于统计学习理论的监督学习方法,通过引入核函数将原始输入空间中的样本映射至高维特征空间,使得原本非线性数据在映射空间中转化为线性可分问题。最大化不同类别样本之间的间隔,同时最小化分类误差,从而在保证模型泛化能力的同时提高预测精度。目标函数(2)和约束条件(3)为:

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (3)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (4)$$

式中,  $w$  为权重向量,  $b$  为偏置,  $\xi_i$  为松弛变量,  $C$  为惩罚系数。

#### 2.2.2 随机森林 (Random Forest, RF)

RF是一种基于集成学习思想的监督学习方法,采用自助采样法从原始训练数据集中进行有放回随机抽样,生成多个与原始样本规模相同的子样本集,每个子集训练一棵决策树。在决策树的节点分裂过程中,从所有输入特征中随机选取部分特征构成候选特征子集,并从中选择最优特征进行节点划分。通过引入样本随机性和特征随机性,有效削弱单一决策树模型对训练样本的依赖,降低过拟合风险。RF通过对所有相互独立决策树的预测结果进行投票得到最终的预测结果。

多数投票分类输出:

$$\hat{y} = \arg \max_c \sum_{k=1}^K I(h_k(x) = c) \quad (5)$$

概率输出:

$$P(y = 1 | x) = \frac{1}{K} \sum_{k=1}^K h_k(x) \quad (6)$$

式中,  $I()$  为指示函数,  $K$  为决策树数量,  $h_k(x)$  为第*k*棵树的预测结果,  $c$  表示类别标签。

#### 2.2.3 人工神经网络 (Artificial Neural Network, ANN)

ANN是一种受生物神经系统启发而来的机器学习方法,其通过多层神经元之间的非线性映射关系,学习输入特征与输出结果之间的复杂函数关系。神经元首先对输入特征进行加

权求和，并加入偏置项形成净输入，随后通过非线性激活函数得到神经元的输出，实现信息的逐层传递与特征提取。训练阶段以已知样本为基础，采用误差反向传播（Backpropagation, BP）算法，通过最小化损失函数不断调整网络权值和偏置参数，使模型输出逐步逼近真实结果。

$$Op = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (7)$$

式中， $x_i$  为输入特征， $w_i$  为对应权重， $b$  为偏置项， $f()$  为激活函数。

### 2.2.4 极端梯度提升 (eXtreme Gradient Boosting, XGBoost)

XGBoost 是一种基于梯度提升决策树 (Gradient Boosting Decision Tree, GBDT) 的集成学习算法。XGBoost 采用向前分步加法策略，通过逐步建立多个弱学习器并进行加权组合为一个强学习器，并将样本经过每颗树的预测结果累加，实现对复杂非线性问题的高精度建模。该算法的关键在于用于衡量模型预测值与真实值之间差异的损失函数和用于约束模型的正则化项。

$$Op = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (7)$$

式中， $l()$  为损失函数， $\Omega(f_k)$  为正则化项，用于约束模型的复杂度，防止过拟合。

### 2.3 SHAP (SHapley Additive exPlanations)

SHAP 是一种基于博弈论的模型解释方法，旨在定量刻画各输入特征对模型预测结果的贡献程度。SHAP 算法的一个显著特点是能够同时提供全局和局部的模型解释。全局可解释整个数据集上特征的重要性分布，局部还可解释每个特征对该预测结果的贡献度。

### 3.2 模型精度对比

为客观对比这 4 种模型在黄土滑坡上易发性评价的性能，本文采用固定比例的样本划分方式，将原始样本数据按照 7:3 的比例随机划分为训练集和测试集，同时保证训练集和测试集中正负样本比例均为 1:1。所有对比模型均基于相同的训练集和测试集进行构建与验证，以避免因样本差异引入的随机误差。混淆矩阵结果及性能指标如表 3 所示，ROC 曲线如图 3 所示。

由表 3 可知，四种模型均有良好的表现，其中 RF 和 XGBoost 模型性能表现更好。SVM

$$\phi_i = \sum_{S \subseteq N(i)} \frac{|S|!(n-|S|-1)!}{n!} [f(S \cup \{i\}) - f(S)] \quad (8)$$

$N$  表示所有评价因子的集合， $S$  表示给定预测的评价因子的子集， $f(S \cup \{i\})$  和  $f(S)$  分别表示有和无第  $i$  个评价因子的模型结果。

### 2.4 模型评价指标

本研究通过混淆矩阵得到的多种评价指标如：准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall)、F1 值 (F1-score) 和 ROC 曲线及曲线下面积 (Area under curve, AUC) 对模型的预测精度进行评价。混淆矩阵以 0.5 为阈值对预测结果进行二分类，即大于 0.5 视为预测结果为滑坡，小于 0.5 为非滑坡。计算公式如下：

$$\text{准确率} = \frac{TP+TN}{TP+FP+TN+FN} \quad (9)$$

$$\text{精确率} = \frac{TP}{TP+FP} \quad (10)$$

$$\text{召回率} = \frac{TP}{TP+FN} \quad (11)$$

$$F1 = \frac{2 \times \text{精确率} \times \text{召回率}}{\text{精确率} + \text{召回率}} \quad (12)$$

式中，TP(true positive) 为正样本中被预测为正类的，FP(false positive) 为负样本中被预测为正类的；TN(true negative) 为负样本中被预测为负类的，FN (falsenegative) 为正样本中被预测为负类的。

## 3 结果

### 3.1 因子共线性检验

当  $0 < VIF < 10$  时，表明不存在多重共线性； $10 \leq VIF < 100$  时，表明存在较强的多重共线性；当  $VIF \geq 100$  时，表明存在严重的多重共线性<sup>[23]</sup>。本文计算方差膨胀因子结果如表 2。本文所筛选的高程、坡度、坡向等 11 个影响因子的 VIF 值均小于 10，各因子之间均不存在共线性问题，因此选取 11 个因子继续进行模型训练。

表2 VIF值表

影响因子	高程	坡度	坡向	曲率	地表起伏度	地层岩性	河流距	道路距	断裂距	NDVI	土地利用类型
容差	0.769	0.714	0.998	0.998	0.712	0.906	0.898	0.904	0.890	0.851	0.925
VIF	1.300	1.400	1.002	1.002	1.404	1.104	1.114	1.106	1.124	1.175	1.082

和 ANN 模型的各项性能指标相差不大，SVM 模型的准确率、精确率、召回率和 F1 值均略大于 ANN 模型，而 ANN 模型的 AUC 值略大于 SVM 模型；RF 模型和 XGBoost 模型的性能指标相差不大，但均优于 SVM 和 ANN 模型，其中 XGBoost 模型的各项指标均略大于 RF 模型；由图 3 可发现 XGBoost 模型的 ROC 曲线相较其他模型更贴近左上角，四种模型 (SVM、ANN、RF、XGBoost) 在测试集上的 AUC 值分别为 0.8984、0.9031、0.9935、0.9999，表明 RF 和 XGBoost 模型的预测结果更加准确，性能更加优异。

表3 各模型性能指标对比

模型	Accuracy	Precision	Recall	F1-score	AUC
支持向量机 (SVM)	0.8229	0.8800	0.7477	0.8085	0.8984
人工神经网络 (ANN)	0.8200	0.8781	0.7432	0.8050	0.9031
随机森林 (RF)	0.9565	0.9783	0.9338	0.9555	0.9935
XGBoost	0.9968	0.9984	0.9952	0.9968	0.9999




图3 模型ROC曲线对比

### 3.3 SHAP 解释

#### 3.3.1 影响因子重要性

滑坡的发生机制复杂，特征重要性值反映

了各因子在模型分类决策中的相对贡献程度，可用于识别控制滑坡发生的主导因素，准确识别主导致灾因子对于制定科学、有效的滑坡灾害防治与风险管理策略具有重要意义。根据本文选取的11个影响因子，利用SHAP算法结合RF和XGBoost模型对其进行了重要性分析，并绘制因子重要性排序图。结果表明，不同因子对滑坡发生的影响程度存在明显差异，RF模型中，坡度和土地利用类型对滑坡易发性贡献最大，其次是地层岩性和地表起伏度等因子；XGBoost模型中，同样坡度和土地利用类型对滑坡易发性贡献最大，地表起伏度、地层岩性和曲率稍低，其次是NDVI和高等因子。两个模型因子重要性排序的前两名都是坡度和土地利用类型，上述结果表明，在地质灾害风险评估与防治实践中，应对坡度和土地利用类型等高重要性因子予以重点关注，以有效降低滑坡灾害发生的风险，提高区域地质灾害防治与管理水平。

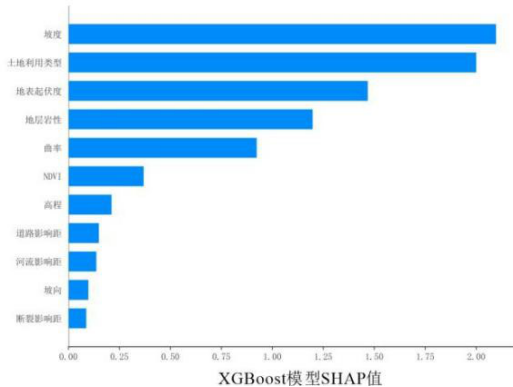
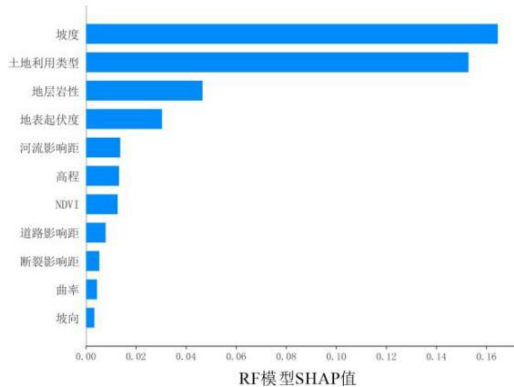


图4 影响因子重要性排序图

#### 3.3.2 不同特征值影响解释

SHAP 特征摘要图中的各个点都代表一个真实的样本，点的颜色反映影响因子值的大小，值越大颜色越红，值越小颜色越蓝；横坐标为SHAP值用以衡量影响因子对模型预测值的贡

献程度，SHAP值为正时表明该影响因子对滑坡发生的影响很大。如图5所示（左为RF，右为XGBoost），两个模型中对滑坡影响最大的因子是坡度，坡度越大，SHAP值越大，发生滑坡的概率也就越大




图5 SHAP特征摘要图

#### 4 结论

本研究以山西省乡宁县为研究区,选取11个环境因子,对比分析了SVM、ANN、RF和XGBoost四种机器学习模型在滑坡易发性评价中的性能,并引入SHAP算法对最优模型进行可解释性分析,主要结论如下:

(一)在模型性能方面,集成学习模型RF和XGBoost的预测精度(AUC值分别为0.9935和0.9999)显著优于单一模型SVM(0.8984)和ANN(0.9031)。这表明在处理黄土高原复杂、非线性的滑坡环境因子时,集成学习模型通过组合多个弱学习器,能够更有效地捕捉因子与滑坡之间的内在关联,具有更强的泛化能力和更高的预测稳定性。

(二)通过SHAP解释分析,成功揭示了模型的决策机制,量化了各环境因子的贡献。

结果表明,坡度和土地利用类型是控制研究区滑坡发育的两个最关键因子。SHAP摘要图进一步显示,坡度值与滑坡发生概率呈正相关,即坡度越大,滑坡风险越高。此外,地表起伏度、地层岩性和曲率等地质地形因子也发挥了重要作用。

(三)综合来看,将高精度的XGBoost模型与具有可解释性的SHAP算法相结合,不仅能绘制准确的滑坡易发性区划图,还能深入理解滑坡的主控因素及其作用规律。该方法有效克服了机器学习模型的“黑箱”局限,为黄土高原地质灾害的成因分析、风险管理与防治决策提供了更加科学、直观的参考依据。未来研究可考虑引入时间维度的降雨因子,进一步探索滑坡的时空预测。

#### 参考文献:

- [1] 彭建兵等,黄土地质灾害研究中的关键问题与创新思路. 工程地质学报, 2014. 22(04): 第684-691页.
- [2] 孙萍萍等,黄土高原地质灾害发生规律. 山地学报, 2019. 37(05): 第737-746页.
- [3] 孙萍萍等,中国西部黄土区地质灾害调查研究进展. 西北地质, 2022. 55(03): 第96-107页.
- [4] 冯凡等,不同尺度下地质灾害风险评价方法探讨——以陕西吴堡县为例. 中国地质灾害与防治学报, 2022. 33(02): 第115-124页.
- [5] 唐晓娜,基于卷积神经网络和综合指数模型的吕梁市滑坡灾害易发性评价, 2019,太原理工大学.
- [6] Dikshit, A., B. Pradhan and A.M. Alamri, Pathways and challenges of the application of artificial intelligence to geohazards modelling. GONDWANA RESEARCH, 2021. 100: p. 290-301.
- [7] 黄发明等,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: 第1-30页.
- [8] Gameiro, S., et al., Artificial neural networks applied to landslide susceptibility: The effect of sampling areas on model capacity for generalization and extrapolation. APPLIED GEOGRAPHY, 2021. 137.
- [9] 王卫东,刘攀与龚陆,基于支持向量机模型的四川省滑坡灾害易发性区划. 铁道科学与工程学报, 2019. 16(05): 第1194-1200页.
- [10] Sun, D.L., et al., A random forest model of landslide susceptibility mapping based on hyperparameter optimization using Bayes algorithm. GEOMORPHOLOGY, 2020. 362.
- [11] Sun, D.L., et al., An Optimized Random Forest Model and Its Generalization Ability in Landslide Susceptibility Mapping: Application in Two Areas of Three Gorges Reservoir, China. JOURNAL OF EARTH SCIENCE, 2020. 31(6): p. 1068-1086.
- [12] Tanyu, B.F., et al., Landslide susceptibility analyses using Random Forest, C4.5, and C5.0 with balanced and unbalanced datasets. CATENA, 2021. 203.
- [13] 仇文岗等,基于水系分区的滑坡易发性机器学习分析方法:以重庆市奉节县为例. 地球科学, 2023. 48(05): 第2024-2038页.
- [14] 吴润泽等,基于随机森林的滑坡空间易发性评价:以三峡库区湖北段为例. 地球科学, 2021. 46(01): 第321-330页.
- [15] 田乃满等,人工神经网络和决策树模型在滑坡易发性分析中的性能对比. 地球信息科学学报, 2020. 22(12): 第2304-2316页.
- [16] 崔婷婷等,基于SHAP的可解释机器学习的滑坡易发性评价模型. 成都理工大学学报(自然科学版), 2025. 52(01): 第153-172页.
- [17] 张潇远等,一种利用贝叶斯算法优化XGBoost的滑坡易发性评价方法. 测绘科学, 2023. 48(06): 第140-150页.
- [18] 薛一凡等,基于多模型对比的甘肃庆阳地区滑坡易发性评价. 地球科学与环境学报, 2025.

47(04): 第 600-617 页 .

[19]Chen, L., et al., A knowledge-aware deep learning model for landslide susceptibility assessment in Hong Kong. SCIENCE OF THE TOTAL ENVIRONMENT, 2024. 941.

[20] 黄赠等, 隐伏断层地震诱发滑坡易发性评价. 浙江大学学报(工学版), 2017. 51(11): 第 2136-2143 页 .

[21] 张茂省与李同录, 黄土滑坡诱发因素及其形成机理研究. 工程地质学报, 2011. 19(04): 第 530-540 页 .

[22] 黄发明等, 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, 2024. 56(01): 第 169-182 页 .

[23] 郭衍昊等, 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, 2024. 43(03): 第 251-265 页 .

**作者简介:** 王龙辉(2000.05—), 男, 汉族, 山西省晋城市, 硕士研究生, 研究方向: 地质工程与地质灾害。

**通讯作者:** 唐亚明(1973.11—), 女, 汉族, 湖南永州, 博士, 研究员, 研究方向: 黄土地质灾害。