

基于4种机器学习模型的东北黑土区沟蚀敏感性

李欣雨¹, 郑粉莉^{1,2}, 毋冰龙², 李蓉¹

(1. 西北农林科技大学水土保持科学与工程学院(水土保持研究所), 水土保持与荒漠化整治全国重点实验室, 陕西 杨陵 712100; 2. 中国科学院水利部水土保持研究所, 陕西 杨陵 712100)

摘要: [目的] 构建沟蚀敏感评价模型, 为东北黑土区沟蚀发生预警及其精准治理提供重要科学依据。[方法] 以典型厚层黑土区的黑龙江省克东县为研究区, 基于0.4 m高分辨率遥感影像提取侵蚀沟, 通过方差膨胀因子剔除冗余变量, 选取涵盖线性、非线性及集成学习架构的4种机器学习模型(逻辑回归-LR、支持向量机-SVM、随机森林-RF、极端梯度提升-XGBoost)进行对比, 并引入SHAP(Shapley Additive exPlanations)可解释性模型量化各影响因子对沟蚀敏感性的贡献作用。[结果] 1) XGBoost对沟蚀敏感性的预测能力最佳(训练集AUC=0.81, 测试集AUC=0.75), 其次是SVM与RF(测试集AUC=0.74), 而LR对沟蚀敏感性的预测能力最弱(AUC=0.67)。2) 4个模型预测的沟蚀敏感性在县域尺度均呈周边低、中部高的空间分布特征, 但沟蚀敏感性等级则存在明显差异。RF模型预测的高沟蚀敏感性占比最大, 其值为45.0%; SVM和XGBoost模型预测的研究区沟蚀敏感性均以中、极低为主, 二者占比分别为56.2%和59.2%; 而LR预测结果则研究区以低沟蚀敏感性为主, 其值为39.4%。3) SHAP分析结果表明, DEM(数字高程模型)是影响沟蚀敏感性的主导因子(SHAP为0.55), 且具有显著正向作用; SPI(径流功率指数)对沟蚀敏感性的正向驱动作用仅次于DEM(SHAP为0.30), NDVI则对沟蚀敏感性呈现明显负向作用(SHAP为0.37)。[结论] 在厚层黑土区克东县, 基于4种机器学习模型评价的沟蚀敏感性等级存在明显差异, XGBoost模型与SHAP方法融合, 增强机器学习模型预测沟蚀敏感性的可解释性; 且沟蚀敏感性受“地形主控-植被调控-汇流水动力触发”耦合作用的共同驱动, 研究结果加深对沟蚀发生的认知, 并为黑土区侵蚀沟治理的措施优化提供理论指导。

关键词: 机器学习; 沟蚀敏感性; 东北黑土区; SHAP

中图分类号: S157.1

文献标识码: A

文章编号: 1009-2242(2026)04-0420-10

Gully Erosion Susceptibility in Black Soil Region of Northeast China Based on Four Machine Learning Models

Li Xinyu¹, Zheng Fenli^{1,2}, Wu Binglong², Li Rong¹

(1. State Key Laboratory of Soil and Water Conservation and Desertification Control, College of Soil and Water Conservation Science and Engineering (Institute of Soil and Water Conservation), Northwest A&F University, Yangling, Shaanxi 712100, China; 2. Institute of Soil and Water Conservation, Chinese Academy of Sciences and Ministry of Water Resources, Yangling, Shaanxi 712100, China)

Abstract: [Objective] This study aims to construct a gully erosion susceptibility assessment model in order to provide an important scientific basis for early warning of gully erosion occurrence and its precise management in the black soil region of Northeast China. [Methods] Kedong County in Heilongjiang Province, a typical thick-layer black soil region, was selected as the study area. Erosion gullies were extracted based on 0.4 m high-resolution remote sensing images. Redundant variables were eliminated using the variance inflation factor (VIF). Four machine learning models covering linear, nonlinear, and ensemble learning architectures-logistic regression (LR), support vector machine (SVM), random forest (RF), and extreme gradient boosting (XGBoost)-were compared. The

收稿日期: 2026-01-03

修回日期: 2026-02-18

录用日期: 2026-03-15

网络首发日期(www.cnki.net): 2026-03-25

资助项目: 国家自然科学基金面上项目(42177326)

第一作者: 李欣雨(2001—), 女, 硕士研究生, 主要从事黑土区沟蚀对土壤生产力的影响研究。E-mail: 122656111@qq.com

通信作者: 郑粉莉(1960—), 女, 博士, 教授, 博士生导师, 主要从事土壤侵蚀与环境效应评价研究。E-mail: flzh@ms.iswc.ac.cn

http://stbxb.alljournal.com.cn

SHAP (Shapley Additive exPlanations) interpretability model was introduced to quantify the contribution of each influencing factor to gully erosion susceptibility. **[Results]** 1) XGBoost demonstrated the best predictive capability for gully erosion susceptibility (training set AUC=0.81, test set AUC=0.75), followed by the SVM and RF (test set AUC=0.74), while LR showed the weakest predictive capability (AUC=0.67). 2) The gully erosion susceptibility predicted by the four models all exhibited a spatial distribution pattern of "low in the periphery and high in the center" at the county scale, but there were significant differences in the susceptibility levels. The RF model predicted the largest proportion of high gully erosion susceptibility, accounting for 45.0%. The gully erosion susceptibility predicted by the SVM and XGBoost models in the study area was predominantly moderate and very low levels, accounting for 56.2% and 59.2%, respectively. In contrast, the LR prediction results indicated that low gully erosion susceptibility was dominant, covering 39.4% of the study area. 3) SHAP analysis revealed that the digital elevation model (DEM) was the dominant factor influencing gully erosion susceptibility (SHAP value=0.55), exhibiting a significant positive effect. The stream power index (SPI) had the second strongest positive driving effect on gully erosion susceptibility (SHAP value=0.30), while the normalized difference vegetation index (NDVI) showed a clear negative effect on gully erosion susceptibility (SHAP value=0.37). **[Conclusion]** In the thick-layer black soil region of Kedong County, significant differences are observed in the gully erosion susceptibility levels evaluated by the four machine learning models. The integration of the XGBoost model with the SHAP method enhances the interpretability of machine learning models in predicting gully erosion susceptibility. Moreover, gully erosion susceptibility is jointly driven by the coupled effects of "terrain-dominated control, vegetation regulation, and confluence hydrodynamics triggering". These findings deepen the understanding of gully erosion occurrence and provide theoretical guidance for optimizing gully erosion control measures in black soil regions.

Keywords: machine learning; gully erosion susceptibility; black soil region of Northeast China; SHAP

Received: 2026-01-03

Revised: 2026-02-18

Accepted: 2026-03-15

Online(www.cnki.net): 2026-03-25

土壤侵蚀是全球最具破坏力的土地退化过程之一,而沟蚀作为其关键表现形式,因其发育过程快速和治理困难,对全球生态安全构成严重威胁^[1]。全球范围内,沟蚀导致每年超过1 000万hm²的耕地丧失,造成粮食减产比例高达12%~15%^[2]。如非洲萨赫勒地带埃塞俄比亚北部高地因沟蚀吞噬17%的耕地,导致玉米减产37%^[3];美国中西部玉米带因沟蚀导致玉米产量下降19%~28%^[4]。我国东北黑土区沟蚀严重且形成演变过程快速。2013年普查^[5]结果表明,该区侵蚀沟总数为29.5万条;而2022年普查^[6]结果显示,该区侵蚀沟总数为66.67万条,且农田侵蚀沟数量占比在74.2%以上^[7],因沟蚀造成的土壤侵蚀量占农田土壤侵蚀总量的20%以上^[8]。因此,识别东北黑土区的沟蚀敏感性,可为侵蚀沟发生预警和精准治理提供重要科学依据。

沟蚀敏感性评价作为沟蚀灾害风险研究的重要内容,旨在通过统计模型或智能算法定量刻画沟蚀在空间上的发生概率及其分布格局^[9]。随着遥感与GIS技术的发展,机器学习方法因其对非线性关系和多源变量的良好适应能力,被广泛引入沟蚀敏感性评价研究中^[10-11]。如Liu等^[12]研究表明,在我国东北

黑土区,Transformer模型的性能优于卷积神经网络(CNN)和随机森林(RF)方法;Li等^[13]研究发现,在青藏高原地区,随机森林(RF)模型对沟蚀敏感性的判别效果优于支持向量机(support vector machine, SVM)和逻辑回归(logistic regression, LR)模型,且数字高程模型(DEM)和归一化植被指数(NDVI)是沟蚀敏感性的主要影响因素。尽管机器学习在沟蚀敏感性评价领域取得进展,但现有研究仍存在不足:一是多数研究依赖于单一的机器学习模型,缺乏不同模型间的对比与融合,其结果可能导致预测结果的不确定性增加;二是机器学习固有的“黑箱”特性使得模型预测结果缺乏可解释性,难以揭示驱动因子对沟蚀发生的具体作用机制及其关键阈值,在一定程度上限制研究结果在实际沟蚀治理中的指导价值^[10]。而近年来研发的SHapley Additive exPlanations模型(SHAP),基于合作博弈论中的Shapley值原理,可将机器学习模型的预测结果分解为各驱动因子的边际贡献,从而量化不同因子对沟蚀敏感性预测结果的正负影响及其相对重要性。该方法能够有效解决机器学习模型的“黑箱”问题,并能揭示驱动因子与沟蚀敏感性间的非线性关系及其潜在阈值特征,

为关键影响因子识别与机理解释提供方法支持^[14-15]。

针对以上分析,本研究以东北典型厚层黑土区克东县为例,在多维度地形、环境与人类活动因子基础上,基于方差膨胀因子(variance inflation factor, VIF)剔除冗余变量,应用逻辑回归(logistic regression, LR)、支持向量机(support vector machine, SVM)、随机森林(random forest, RF)与极端梯度提升(extreme gradient boosting, XGBoost)4种机器学习模型,对比分析典型厚层黑土区沟蚀的敏感性,结合SHAP方法阐明各驱动因子对沟蚀敏感性的影响及其阈值,以期为东北黑土区侵蚀沟精准治理与黑土资源可持续利用提供科学依据。

1 材料与方法

1.1 研究区概况

克东县位于黑龙江省齐齐哈尔市(47°43′~48°18′N,126°01′~126°41′E)(图1),总面积为2 083 km²。全县属温带大陆性季风气候,年平均气温2.4℃,年平均降雨量526.5 mm,无霜期111~159 d。地形属于漫川漫岗区,以丘陵起伏和缓坡为主,海拔220~380 m,地势北高南低。全县土壤类型为典型黑土、草甸土和水稻土,其中典型黑土面积占耕地面积的78.6%。农作物以玉米、大豆为主。自然植被零散分布,优势群落主要是小叶杨、桦树等落叶阔叶林及人工樟子松落叶松等。全县共有2 062条侵蚀沟,沟壑密度为0.36 km/km²。该县位于松嫩平原东北部,地表覆盖深厚的第四纪松散沉积物,土层深厚,有机质含量高。然而表层土壤结构疏松、抗蚀性较弱,因此,在集中降雨和耕作活动的影响下,容易发生土壤侵蚀,为侵蚀沟形成提供物质基础。

1.2 数据来源

本研究使用的高分辨率遥感影像来源于 Google

Earth(2022年,空间分辨率约0.4 m),通过“91卫图”平台下载。Google Earth影像是多源遥感影像(包括商业卫星和航空影像)融合而成,经过正射校正和色彩融合处理,提供全球覆盖的高分辨率多时相数据。影像细节丰富,适合用于小尺度地形特征(如侵蚀沟)的遥感解译与空间分析。本研究所需的其他数据还包括归一化植被指数(normalized difference vegetation index, NDVI)和数字高程模型(digital elevation model, DEM)。其中,DEM作为地表高程信息的数字化表达,被广泛用于表征地形条件。在ArcGIS平台支持下,基于DEM提取坡度、坡长和坡向等地形因子,并进一步计算地形湿度指数(topographic wetness index, TWI)、地形位置指数(topographic position index, TPI)、地形崎岖度指数(terrain ruggedness index, TRI)、径流功率指数(stream power index, SPI)和汇流指数(topographic convergence index, CI),分别用于表征地形形态特征、坡面汇流条件、水动力侵蚀能力及植被覆盖状况,并作为沟蚀敏感性评价的影响因子输入模型(表1)。




图1 研究区地理位置与DEM
Fig.1 Geographic location of study area and DEM

表 1 数据来源
Table 1 Data sources

类型	数据来源与计算说明
高分辨率遥感影像	2022年0.4 m Google Earth遥感影像
高程(DEM)	NASA地球科学数据网站的ALOS DEM数据,12.5 m分辨率
坡度(Slope gradient)	由DEM在ArcGIS中利用Slope工具提取
坡向(Aspect)	由DEM在ArcGIS中利用Aspect工具提取,并进行归一化处理
地形湿度指数(TWI)	基于DEM,依据公式 $TWI = \ln(A_s / \tan \alpha)$ 计算,其中 A_s 为上坡汇水面积; α 为坡度
地形位置指数(TPI)	$TPI = Z_0 - \bar{Z}$,其中 $\bar{Z} = (\sum_{i \in R} Z_i) / n_R$ 计算某点高程与周围区域平均高程之差
地形崎岖度指数(TRI)	$TRI = \sqrt{\sum (Z_{center} - Z_{neighbor})^2}$ 计算中心点高程与周围邻域高程差的平均值
坡度长度因子(LS)	$LS = (flowacc \times cellsize / 22.13)^m$,其中 $m = \beta / (\beta + 1)$, $\beta = (\sin \alpha / 0.0896) / [3 \times (\sin \alpha)^{0.8} + 0.56]$,综合反映坡长与坡度对侵蚀的共同影响
径流功率指数(SPI)	$SPI = A_s \times \tan \alpha$ 。式中: A_s 为上坡汇水面积; α 为坡度,表征水流侵蚀能力
归一化植被指数(NDVI)	基于Landsat数据计算, $NDVI = (NIR - RED) / (NIR + RED)$,其中NIR为近红外波段;RED为红外波段
汇流指数(CI)	$CI = \ln(\alpha / \tan \beta)$ 基于DEM计算,表征径流汇集能力

1.3 侵蚀沟解译及其精度评价

1.3.1 侵蚀沟解译 参考水利部松辽水利委员会提出的侵蚀沟遥感解译方法及侵蚀沟大小分类^[16](小型侵蚀沟的面积 $\leq 0.3\text{ hm}^2$, 中型侵蚀沟的面积为 $0.3\sim 1.4\text{ hm}^2$, 大型侵蚀沟的面积 $\geq 1.4\text{ hm}^2$), 建立侵蚀沟的遥感解译标志(图 2), 然后基于构建的解译标志提取克东县全境内的侵蚀沟。表明克东县共有侵蚀沟 2 038 条, 沟壑密度达到 0.33 km/km^2 。其中, 小型、中型和大型侵蚀沟分别为 1 222、738、78 条。为构建机器学习数据集, 首先将该县 2 038 条侵蚀沟矢量数据转换为栅格格式, 并将沟蚀区域赋值为 1, 非侵蚀沟区域赋值为 0(图 3)。随后, 将研究区每个栅

格单元的环境因子值与标签提取为数据框。为保证正负样本的代表性, 采用分层随机抽样的方式, 从沟蚀与非沟蚀区域分别抽取样本; 为保证随机样本生成过程的可重复性, 本研究在样本抽取与数据划分过程中对随机性进行统一控制。具体而言, 在基于沟蚀与非沟蚀区域的分层随机抽样过程中, 通过设置固定随机种子, 确保每次运行时生成的样本点位置及样本组合保持一致。在此基础上, 采用相同的随机种子对样本数据进行训练集与测试集的随机划分(比例为 7:3), 从而保证模型训练与验证结果具有良好的可复现性。所有涉及随机过程的分析均在相同随机种子条件下完成。




图 2 不同类型侵蚀沟的遥感解译图像
Fig.2 Remote sensing interpretation images of different erosion gully types




图 3 基于机器学习模型的克东县训练和测试样点分布及侵蚀沟空间分布

Fig.3 Distribution of training and testing sample points and spatial distribution of erosion gullies in Kedong County based on machine learning models

1.3.2 侵蚀沟解译的精度评价 为评估侵蚀沟的解译精度, 本研究选取 146 条侵蚀沟(其中, 小型、中型和大型侵蚀沟数量分别为 87、53、6 条), 于 2022 年 10 月和 2023 年 4 月(剔除植被影响)采用 DJI Phantom 4 RTK 无人机进行航拍(设计的飞行参数为航高 100 m、速度 7.9 m/s、旁向/航向重叠度 80%, 地面分辨率 2.74 cm), 对比 0.4 m 高分辨率的遥感影像, 以此评价

侵蚀沟解译的精度(图 4)。表明在 146 条侵蚀沟中, 小型侵蚀沟验证精度为 88.5%, 中型和大型侵蚀沟的验证精度均为 100%, 总体精度达 93.2%。表明基于 0.4 m 分辨率遥感影像解译的侵蚀沟精度较高, 可满足研究需求。

1.4 沟蚀影响因子筛选

为消除因子间的多重共线性以避免模型失真,

本研究采用 VIF 和容忍度 (Tolerance) 作为量化指标对沟蚀影响因子进行筛选。参照前人^[17]研究结果, 当 $VIF > 10$ 或容忍度 < 0.1 时, 说明因子间存在强共线性, 因此需要剔除该因子。VIF 和容忍度的计算公式为:

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

$$R_i^2 = \frac{\sum (y_{cal,i} - \bar{y})^2}{\sum (y_{obs,i} - \bar{y})^2} \quad (2)$$

$$Tolerance = \frac{1}{VIF} = 1 - R_i^2 \quad (3)$$

式中: VIF 为方差膨胀因子; R_i 为决定系数; $y_{cal,i}$ 为从回归模型计算出的第 i 个因变量的值; $y_{obs,i}$ 为第 i 个因变量的观测值; Tolerance 为容忍度指标。




图 4 基于 UAV 影像对遥感影像侵蚀沟提取结果的验证
Fig.4 Verification of erosion gully extraction results from remote sensing images based on UAV images

1.5 4 种机器学习模型

本研究选择逻辑回归 (LR)、支持向量机 (SVM)、随机森林 (RF) 和极端梯度提升 (XGBoost) 4 种机器学习模型, 主要基于以下考虑: 一方面, 该类模型涵盖线性 (LR)、非线性 (SVM) 及集成学习 (RF, XGBoost) 方法, 能够全面评估不同类型算法在沟蚀敏感性预测中的表现差异; 另一方面, RF 与 XGBoost 分别代表 Bagging 与梯度提升算法, 可对比稳健性与预测精度; 同时, LR 与 SVM 理论成熟、可解释性强, 可辅助理解因子对沟蚀的影响。选取的 4 种机器学习模型组合既保证预测能力, 又便于通过 SHAP 分析定量评估各因子贡献, 从而兼顾预测精度与可解释性。

1.5.1 逻辑回归 (logistic regression, LR) 逻辑回归是一种广义线性模型, 通过 Sigmoid 函数将线性预测值映射为 $[0, 1]$ 区间内的概率值, 适用于二分类问题^[18]。逻辑回归数学本质是构建对数几率 (Logit) 与自变量间的线性关系, 模型参数可通过极大似然估计求解; 其优势在于模型结构简单、计算效率高, 且参数具有明确的统计学意义 (如发生比 Odds Ratio), 便于对因子影响方向与强度的解释^[19]。

1.5.2 随机森林 (random forest, RF) 随机森林是一种基于 Bagging 的集成学习算法, 通过构建多棵决策树并集成其输出以提升模型稳定性和泛化能力^[20]。该模型能够有效处理高维数据, 对异常值和噪声不敏感, 且自带 OOB (Out Of Bag) 误差估计功能, 无需额外划分验证集^[21]。此外, RF 可输出特征重要性排序, 为因子筛选提供参考。

1.5.3 支持向量机 (support vector machine, SVM) 支持向量机通过核函数将数据映射到高维特征空间, 并寻找最优超平面以实现类别分割, 尤其适用于小样本分类问题^[22]。其优势在于理论完备、全局优化解唯一, 且对样本噪声具有较好鲁棒性。在沟蚀预测中, 径向基 (RBF) 核函数最常用, 可灵活捕捉非线性关系。但其性能高度依赖超参数的选择, 计算复杂度随样本量增加而显著增长, 在大规模数据应用中受限^[23]。

1.5.4 极端梯度模型 (extreme gradient boosting, XGBoost) XGBoost 是一种基于梯度提升框架的高效集成算法, 通过迭代训练一系列弱分类器并优化残差来不断提升模型性能^[24]。其核心优势包括: 引入二阶泰勒展开与正则化项以提升精度并抑制过拟合^[25]; 支持并行处理与缺失值自动处理, 计算效率高; 提供增益、覆盖度等多种特征重要性指标。XGBoost 在处理结构化数据和复杂非线性关系方面通常表现出优异的性能, 但其超参数较多, 调优复杂度较高。

1.6 模型评估与超参数调优

鉴于机器学习模型对超参数设置具有一定敏感性, 本研究在模型构建过程中对各模型的关键超参数进行明确设定, 以控制模型复杂度并避免潜在的过拟合风险。需要说明的是, 本研究未采用系统性的超参数优化方法 (如网格搜索或贝叶斯优化), 而是结合研究中常用的参数设置、算法默认推荐值及对模型稳定性与泛化能力的经验性考量, 确定各模型的超参数取值。

逻辑回归 (LR) 模型采用经典的极大似然估计进行拟合, 以保持其参数清晰的统计学解释性, 并作为后续复杂模型性能比较的基准模型。

随机森林 (RF) 模型通过构建较多决策树 ($n_{tree} = 300$) 以提高集成结果的稳定性; 同时, 通过限制每棵树随机选取的特征数 ($m_{try} = \sqrt{p}$)、设定叶节点最小样本数 ($nodesize = 20$) 及限制最大节点数 ($maxnodes = 30$), 有效控制单棵树的复杂度, 从而在捕捉主要环境因子组合的同时降低过拟合风险, 并增强模型的空间泛化能力。

支持向量机(SVM)模型选用径向基函数(RBF)核以刻画非线性分类关系,正则化参数 C 设为1.0,有助于在复杂特征空间中构建相对平滑的决策边界,从而识别研究区主导的沟蚀风险空间格局。

XGBoost模型采用相对保守的参数配置,通过限制树的最大深度(max_depth=4)并设置较低的学习率(eta=0.05),以降低模型复杂度并促进稳定收敛;同时引入样本子采样(subsample=0.8)与特征子采样(colsample_bytree=0.7),以增加训练过程的随机性,进一步提升模型的泛化能力与鲁棒性,并结合早停策略防止过拟合。

1.7 模型精度评价方法

为客观比较LR、RF、SVM和XGBoost 4种机器学习模型在克东县沟蚀敏感性评价中的性能,本研究采用混淆矩阵(confusion matrix),并结合ROC曲线对模型精度进行综合评价。

1.7.1 混淆矩阵 混淆矩阵是评估二分类模型性能的基础工具,包含真正类(TP)、假正类(FP)、真负类(TN)和假负类(FN)4种预测结果。本研究采用准确率(accuracy)作为核心评价指标之一,其计算公式为:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (4)$$

高准确率意味着模型能同时正确识别侵蚀沟与非侵蚀区,与单纯依赖召回率(recall)或精确率(precision)相比,准确率更适合黑土区沟蚀的均衡样本场景^[26]。

1.7.2 ROC曲线 ROC曲线(receiver operating characteristic curve)是评估二分类模型性能的另一重要工具^[19]。该曲线以假正率(false positive rate, FPR)为横坐标,真正率(true positive rate, TPR,又称召回率recall)为纵坐标绘制而成。

$$\text{ROC} = \frac{\text{TPR}}{\text{FPR}} \quad (5)$$

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (6)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (7)$$

式中:TPR为沟蚀样本被正确识别的概率;FPR为非沟蚀区域被误判的概率。

ROC曲线越靠近左上角,代表模型在保持高真正率的同时拥有低假正率,即综合分类性能越优。作为ROC曲线的量化指标,曲线下面积(area under curve, AUC)被用于直接衡量模型的分类精度。AUC的取值在[0,1],其值越接近1,表明模型性能越好。本研究参考国际通用标准^[27]:AUC>0.9时,模型精度极高;0.7<AUC<0.9时,模型精度较高;0.5<AUC<0.7时,模型精度较低。在本研究中,将

综合运用混淆矩阵、准确率及ROC曲线与AUC值,全面评估和比较各模型的沟蚀预测能力。

1.7.3 SHAP方法 SHAP(shapley additive explanations)是一种基于博弈论的模型可解释性方法,其核心思想来源于Shapley值。该方法将模型预测结果表示为各输入特征贡献之和,通过计算特征在不同组合中的边际贡献,量化其对模型输出的影响程度^[15]。在本研究中,SHAP主要用于模型的全局可解释性分析,即通过计算各环境因子的平均绝对SHAP值对其重要性进行排序,并结合SHAP蜂群图(beeswarm plot)展示不同因子在全体样本中的贡献分布及其对沟蚀敏感性预测结果的正负影响方向。

2 结果与分析

2.1 沟蚀影响因子的多重共线性分析

在构建模型前,本研究对选取的10个侵蚀沟驱动因子进行了多重共线性分析(表2)。TRI的VIF值为11.04,VIF>10,表明其与其他因子存在较强共线性^[28],而其他9个因子均满足独立性要求。据此,本研究剔除TRI因子,并以DEM、Slope gradient、Aspect、TWI、TPI、LS、SPI、NDVI和CI作为后续建模的变量集。

表2 沟蚀影响因子的多重共线性分析

Table 2 Results of multicollinearity analysis of influencing factors of gully erosion

变量	剔除前		变量	剔除后	
	VIF	Tolerance		VIF	Tolerance
TWI	1.65	0.61	TWI	1.65	0.61
TPI	1.08	0.93	TPI	1.08	0.93
TRI	11.04	0.09	TRI	—	—
SPI	1.03	0.97	SPI	1.03	0.97
NDVI	1.04	0.96	NDVI	1.04	0.96
Slope gradient	1.25	0.80	Slope gradient	1.25	0.80
CI	1.23	0.90	CI	1.23	0.90
DEM	1.11	0.90	DEM	1.11	0.90
Aspect	1.10	0.91	Aspect	1.10	0.91
LS	1.61	0.62	LS	1.61	0.62

2.2 模型预测性能评估

由4个模型的训练集与测试集ROC曲线(图5)可知,4个机器学习模型在克东县的沟蚀敏感性预测中呈显著差异。其中,XGBoost模型性能最佳,训练阶段和测试阶段的AUC分别为0.81、0.75;其次是SVM模型,训练阶段和测试阶段的AUC分别为0.76、0.74;与SVM表现相近的为RF模型,训练阶段和测试阶段的AUC分别为0.75、0.73;LR性能相对最低,训练阶段和测试阶段的AUC均为0.67。




图 5 4种机器学习模型训练阶段和测试阶段的ROC曲线对比

Fig.5 Comparison of ROC curves during training and testing phases of four machine learning models

2.3 沟蚀敏感性的空间分布特征

本研究基于二分类机器学习模型开展沟蚀敏感性评价,模型为每个栅格单元预测其属于“沟蚀”类别的概率(取值为0~1)。该概率值反映不同环境条件下栅格发生沟蚀的相对可能性,可作为连续型沟蚀敏感性指标。为便于空间分析与可视化,采用自然断点法(Jenks)将连续概率值划分为极低敏感性(0~0.31)、低敏感性(0.31~0.48)、中敏感性(0.48~0.62)、高敏感性(0.62~1)4个敏感性等级^[29]。从沟蚀敏感性空间分布(图6)可以看出,4种

模型的预测结果虽在空间细节上存在差异,但均表明克东县沟蚀敏感性存在显著的空间异质性,克东县高敏感性区域主要分布在西北部、中部和西南部,整体呈“周边低、中间高”的分布格局。从沟蚀敏感性各等级占比(图7)可看出,RF模型预测的高沟蚀敏感性占比最大,其值为45.0%,明显高于其他3种模型;SVM和XGBoost预测的研究区沟蚀敏感性均以极低、中为主,其占比分别为56.2%和59.2%;而LR预测结果则显示,研究区以低沟蚀敏感性为主,其值为39.4%。




图 6 基于4种机器学习模型的克东县沟蚀敏感性分布

Fig.6 Distribution of gully erosion susceptibility in Kedong County based on four machine learning models




图 7 沟蚀敏感性各类型占比

Fig.7 Proportion of different types of gully erosion susceptibility

2.4 模型的可解释度

基于XGBoost的模拟结果,并结合SHAP方法,量化各因子对沟蚀敏感性的贡献作用(图8a)。DEM是影响沟蚀敏感性最重要的因子,其SHAP为0.55;其次是NDVI和SPI,二者的SHAP分别为0.37、0.30;坡向、坡度和CI因子对沟蚀敏感性也有一定的影响,其SHAP为0.11~0.18;而TPI、LS和TWI对沟蚀敏感性的影响较小,SHAP为0.04~0.05。从蜂群图(图8b)可以看出,DEM对沟蚀敏感性表现出最强的正向驱动效应。SPI对沟蚀敏感性的正向驱动效应仅次于DEM;而NDVI则对沟蚀敏感性具有明显的负向作用。




图8 SHAP重要性排名和蜂群图
Fig.8 SHAP importance ranking and beeswarm plot

3 讨论

3.1 不同机器学习模型在沟蚀敏感性预测中的表现差异

本研究系统比较逻辑回归(LR)、支持向量机(SVM)、随机森林(RF)和极端梯度提升(XGBoost) 4种模型在克东县黑土区沟蚀敏感性评价中的性能。结果表明,XGBoost预测精度最高(测试集AUC=0.75),SVM与RF次之且相近(AUC均为0.74),而LR表现最弱(AUC=0.67),证实传统线性模型难以充分描述黑土区典型的非线性侵蚀过程。

XGBoost的优越性源于其Boosting集成与正则化策略XGBoost采用梯度提升(Boosting)框架,通过序列化构建弱学习器(决策树)并迭代优化前一模型的残差,能够以自适应方式重点学习难以拟合的样本,从而实现对复杂非线性关系的高精度逼近,与Liu等^[30]研究结论一致,说明其在描述地形、汇水、植被等非线性因子耦合驱动的沟蚀过程方面具有显著优势。

对于SVM与RF模型,虽然二者在模拟精度方面相似(AUC均为0.74),但在沟蚀敏感性空间分布预测上存在显著差异。SVM预测的敏感性等级分布相对均匀,而RF预测的高敏感性区域呈聚集现象且占比极高(45.0%)。该差异可能源于RF对训练数据细节的过度学习,在样本量有限或数据噪声较大的情况下,RF容易产生过拟合,表现为训练精度与测试精度差距大,或预测结果出现极端化的空间聚集,刘从坦等^[9]在东北地区小流域沟蚀敏感性评估研究中多次指出,其采用的RF在研究中存在显著过拟合现象。本研究基于多模型对沟蚀敏感性预测结果对比,不仅降低单模型预测偏差带来的不确定性,也有助于明确不同模型在不同情境下的适用性。

3.2 沟蚀敏感性的关键驱动因子及其解释机制

本研究基于XGBoost的模拟结果并结合SHAP

方法,分析沟蚀敏感性的关键驱动因子及其贡献作用。研究结果不仅量化因子的重要性,而且还揭示影响因子对模型预测结果的贡献,克服模型预测结果机器学习固有的“黑箱”特性导致的可解释性不足问题。本研究发现,DEM是影响沟蚀敏感性的主导因子($\text{SHAP}=0.55$),反映地形对沟蚀发生的控制作用。DEM通过调控侵蚀能量、汇水面积和径流路径等方式,直接影响侵蚀沟发育过程,与已有研究^[31-33]对地形主导机制的认识一致。李建军等^[31]在拉萨河流域基于地理探测器的研究发现,DEM是沟蚀发生的最主要控制因子;Liu等^[32]研究表明,在黑土区汇水指数是决定沟蚀风险空间异质性的首要地形因子,也印证DEM通过控制汇水面积和水流路径,对沟蚀发育起到主控作用^[33]。

其次,NDVI对沟蚀敏感性的影响仅次于DEM($\text{SHAP}=0.37$),说明植被在抑制沟蚀过程中的调节作用显著。Gao等^[11]研究表明,8月NDVI是影响沟蚀敏感性最主要的因子,是因为研究区夏季植被生长旺盛,使得植被有较强的减弱径流侵蚀动力和增强土壤抗蚀能力,进而有效抑制沟蚀的发生发展。SPI($\text{SHAP}=0.30$)代表坡面径流累积能力,其对沟蚀敏感性的影响作用次于NDVI,但明显大于其他6个影响因子(Slope gradient、Aspect、TWI、TPI、LS和CI),表明研究区沟蚀敏感性的空间异质性主要受到径流集中的控制;与此同时,坡度和坡向在模型中的贡献相对较小,与东北黑土区整体地形相对平缓、坡度变化幅度较小密切相关。在该种起伏地貌背景下,坡面倾角和朝向对坡面水流能量和流向的调节作用被弱化,削弱其对沟蚀敏感性的影响;而SPI的增加,使坡面径流更容易汇集,导致水动力侵蚀作用增强,进而增加沟蚀发生的潜力。总体上,研究区沟蚀敏感性由地形主控-植被调控-汇流水动力触发耦合作用共同驱动。

3.3 研究局限与展望

本研究虽在县域尺度沟蚀敏感性评价方面取得一定进展,但仍存在不足。首先在数据与计算层面,受限于计算资源,当前模型在处理更大规模数据集时面临挑战,未来可借助高性能计算平台整合深度学习模型,以促进研究结果在更广泛的空间应用。此外,该模型主要依赖于静态的地形和植被变量,对气候变化和人类活动等动态因素的考虑有限。因此,未来的研究应考虑反映动态变化的数据集,以更好地反映沟蚀过程的发展变化,从而为黑土资源的精准保护与持续监测提供直接、有力的空间决策支撑。

4 结 论

1) 基于多重共线性分析,地形崎岖度指数(TRI)为冗余变量($VIF=11.04$),予以剔除;然后选取 9 个因子(DEM、Slope gradient、Aspect、TWI、TPI、SPI、LS、NDVI、CI)构建模型变量的数据集。

2) XGBoost 模型在沟蚀敏感性预测中表现最佳(训练集 $AUC=0.81$,测试集 $AUC=0.75$),SVM 与 RF 对沟蚀敏感性的预测结果相近(测试集 AUC 均为 0.74),而 LR 模型对沟蚀敏感性的预测结果最差($AUC=0.67$)。

3) 4 种机器学习模型模拟的沟蚀敏感性空间分布格局均呈明显的周边低、中间高特征,高敏感区主要集中在西北部、中部和西南部。

4) 基于 XGBoost 和 SHAP 方法的模拟结果表明,DEM 是影响沟蚀敏感性的最重要因子(SHAP 为 0.55),并表现出显著的正向驱动作用;SPI 对沟蚀敏感性的正向驱动作用仅次于 DEM(SHAP 为 0.30),NDVI 则对沟蚀敏感性呈现明显负向作用(SHAP 为 0.37)。本研究提出的“XGBoost+SHAP”方法,不仅增强机器学习模型预测沟蚀敏感性的可解释性,也为优先识别沟蚀发生高风险区及其精准治理提供科学支撑。

参考文献:

- [1] Valentin C, Poesen J, Li Yong. Gully erosion: Impacts, factors and control[J]. Catena, 2005, 63(2/3): 132-153.
- [2] Poesen J, Nachtergaele J, Verstraeten G, et al. Gully erosion and environmental change: Importance and research needs[J]. Catena, 2003, 50(2/3/4): 91-133.
- [3] Nyssen J, Poesen J, Moeyersons J, et al. Dynamics of soil erosion rates and controlling factors in the northern Ethiopian Highlands-towards a sediment budget[J]. Earth Surface Processes and Landforms, 2008, 33(5): 695-711.
- [4] Gordon L M, Bennett S J, Alonso C V, et al. Modeling long-term soil losses on agricultural fields due to ephemeral gully erosion[J]. Journal of Soil and Water Conservation, 2008, 63(4): 173-181.
- [5] Yang Jiuchun, Zhang Shuwen, Chang Liping, et al. Gully erosion regionalization of black soil area in north-eastern China[J]. Chinese Geographical Science, 2017, 27(1): 78-87.
- [6] 李珊. 水利部组织完成东北黑土区侵蚀沟调查(节选)[J]. 水利科学与寒区工程, 2023, 6(8): eF0003.
Li Shan. The Ministry of Water Resources organized the investigation of erosion gully in the black soil area of Northeast China (excerpt)[J]. Hydro Science and Cold Zone Engineering, 2023, 6(8): eF0003.
- [7] Dong Yifan, Wu Yongqiu, Qin Wei, et al. The gully erosion rates in the black soil region of northeastern China: Induced by different processes and indicated by different indexes[J]. Catena, 2019, 182: e104146.
- [8] 李珊珊, 王春梅, 唐杰, 等. 东北黑土区典型小流域浅沟向切沟发育及其地形临界研究[J]. 武汉大学学报(信息科学版), 2026, 51(2): 345-356.
Li Shanshan, Wang Chunmei, Tang Jie, et al. Development processes from ephemeral to permanent gullies and their critical terrain thresholds in a typical watershed of the mollisol region, Northeast China[J]. Geomatics and Information Science of Wuhan University, 2026, 51(2): 345-356.
- [9] 刘从坦, 范昊明. 基于统计学模型的沟道侵蚀敏感性评估的研究进展与展望[J]. 农业工程学报, 2024, 40(4): 29-40.
Liu Congtan, Fan Haoming. Research advances and prospects on gully erosion susceptibility assessment based on statistical modeling[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(4): 29-40.
- [10] Hitouri S, Meriame M, Sk Ajim A, et al. Gully erosion mapping susceptibility in a Mediterranean environment: A hybrid decision-making model[J]. International Soil and Water Conservation Research, 2024, 12(2): 279-297.
- [11] Gao Ruilu, Gao Maofang, Yao Shuihong, et al. Gully erosion susceptibility mapping considering seasonal variations of NDVI using a machine learning approach in the mollisol region of China[J]. Soil and Tillage Research, 2025, 245: e106322.
- [12] Liu Congtan, Fan Haoming, Jiang Yanyan, et al. Gully erosion susceptibility assessment based on machine learning: A case study of watersheds in Tuquan County in the black soil region of Northeast China[J]. Catena, 2023, 222: e106798.
- [13] Li Jianjun, Chen Yulan, Jiao Juying, et al. Gully erosion susceptibility maps and influence factor analysis in the

- Lhasa River basin on the Tibetan Plateau, based on machine learning algorithms[J].Catena,2024,235:e107695.
- [14] Shapley L S. 17. a value for n-person games[M]//Contributions to the Theory of Games (AM-28), Volume II. Princeton: Princeton University Press, 1953:307-318.
- [15] Lundberg S M, Lee S I. A unified approach to interpreting model predictions[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems.2017:4768-4777.
- [16] 白建宏. 东北黑土区侵蚀沟分级初探[J]. 中国水土保持, 2017(10):41-42.
- Bai Jianhong. Preliminary study on classification of erosion gully in black soil area of Northeast China[J]. Soil and Water Conservation in China, 2017(10):41-42.
- [17] Arabameri A, Saha S, Roy J, et al. Landslide susceptibility evaluation and management using different machine learning methods in the gallicash river watershed, Iran [J].Remote Sensing, 2020, 12(3):e475.
- [18] Hosmer D W Jr, Lemeshow S, Sturdivant R X. Applied logistic regression[M].Hoboken:Wiley, 2013.
- [19] Pourghasemi H R, Yousefi S, Kornejady A, et al. Performance assessment of individual and ensemble data-mining techniques for gully erosion modeling[J].Science of the Total Environment, 2017, 609:764-775.
- [20] Breiman L. Random forests[J].Machine Learning, 2001, 45(1):5-32.
- [21] Ho T K. The random subspace method for constructing decision forests[J].IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(8):832-844.
- [22] Cortes C, Vapnik V. Support-vector networks[J].Machine Learning, 1995, 20(3):273-297.
- [23] Pumain D, Kanevski M, Pozdnoukhov A, et al. 2009, Machine learning for spatial environmental data: Theory, applications and software, EPFL Press, 2009, 377 p[J].Cybergeo, 2010:371-377.
- [24] Kanevski M, Timonin V, Pozdnukhov A. Machine learning for spatial environmental data: Theory, applications, and software[M].EPFL press, 2009.
- [25] Friedman J H. Greedy function approximation: A gradient boosting machine[J].The Annals of Statistics, 2001, 29(5):1189-1232.
- [26] Li Sijin, Xiong Liyang, Hu Guanghui, et al. Extracting check dam areas from high-resolution imagery based on the integration of object-based image analysis and deep learning[J].Land Degradation and Development, 2021, 32(7):2303-2317.
- [27] Arabameri A, Chen Wei, Loche M, et al. Comparison of machine learning models for gully erosion susceptibility mapping[J].Geoscience Frontiers, 2020, 11(5):1609-1620.
- [28] Garosi Y, Sheklabadi M, Conoscenti C, et al. Assessing the performance of GIS- based machine learning models with different accuracy measures for determining susceptibility to gully erosion[J].Science of the Total Environment, 2019, 664:1117-1132.
- [29] Huang Donghao, Zhao Xinrui, Yin Zhe, et al. Utilizing geodetectors to identify conditioning factors for gully erosion risk in the black soil region of Northeast China[J]. International Soil and Water Conservation Research, 2024, 12(4):808-827.
- [30] Liu Xin, Wang Dichen, Guo Mingming, et al. Determination of future gully erosion risk and its spatially quantitative interpretability of driving factors in regional scale using machine learning algorithms [J].Geoderma, 2025, 459:e117396.
- [31] 李建军, 陈玉兰, 焦菊英, 等. 基于多元非线性空间建模的拉萨河流域沟蚀发生风险探测[J]. 农业工程学报, 2022, 38:73-82.
- Li Jianjun, Chen Yulan, Jiao Juying, et al. Detecting gully occurrence risks using multivariate nonlinear spatial modeling in the Lhasa River basin of China[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38:73-82.
- [32] Liu Congtan, Fan Haoming, Wang Yixuan. Gully erosion susceptibility assessment using three machine learning models in the black soil region of Northeast China[J]. Catena, 2024, 245:e108275.
- [33] Sørensen R, Zinko U, Seibert J. On the calculation of the topographic wetness index: Evaluation of different methods based on field observations [J]. Hydrology and Earth System Sciences, 2006, 10(1):101-112.