引文格式:刘瑞阳,许强,蒲川豪,等.湖南省资兴市2024年7月台风"格美"诱发滑坡特征及其地质控制作用[J].武汉大学学报(信息科学版),2026,51(7):1452-1469.DOI:10.13203/j.whugis20250027
Citation: LIU Ruiyang, XU Qiang, PU Chuanhao, et al. Characteristics of Landslides Induced by Typhoon "Gaemi" in Zixing City, Hunan Province, July 2024, and Their Geological Control Factors[J].Geomatics and Information Science of Wuhan University,2026,51(7):1452-1469.DOI:10.13203/j.whugis20250027

湖南省资兴市2024年7月台风"格美"诱发滑坡特征及其地质控制作用

刘瑞阳[1] 许 强[1] 蒲川豪[1] 徐繁树[1] 王晓晨[1] 赵浩星[1]
朱 星[1] 何 娜[2]
1 成都理工大学地质灾害防治与地质环境保护全国重点实验室,四川 成都,610059
2 广西壮族自治区地质环境监测站,广西 南宁,530201

摘 要:2024-07-26,台风"格美"袭击中国湖南省资兴市,诱发了大规模滑坡灾害,造成房屋损毁和多处道路阻断,并导致严重人员伤亡。目前,对于台风"格美"诱发滑坡的发育分布与形成条件仍不清晰,影响灾后重建和风险隐患排查。基于灾后遥感影像,采用深度学习结合人工校核建立滑坡数据库,分析孕灾环境下滑坡的分布规律;采用可解释性机器学习进行易发性建模,探讨地质条件对滑坡形成的控制作用。结果表明,台风"格美"在资兴市共诱发约16 120处滑坡,总面积约32.16 km^2,主要分布于海拔200~600 m、坡度20°~30°的斜坡上,最大点密度达129个/km^2,群发性效应显著。滑坡主要受地质条件控制,其中63.5%的滑坡分布在花岗岩区域,29.4%分布在砂岩及其浅变质岩区域。不同岩性区域,滑坡的主控因子具有显著差异。

关键词:台风"格美";群发性滑坡;智能识别;易发性建模;可解释机器学习
中图分类号:P237 **文献标识码**:A **收稿日期**:2025-09-12
DOI:10.13203/j.whugis20250027 **文章编号**:1671-8860(2026)07-1452-18

Characteristics of Landslides Induced by Typhoon "Gaemi" in Zixing City, Hunan Province, July 2024, and Their Geological Control Factors

LIU Ruiyang[1] *XU Qiang*[1] *PU Chuanhao*[1] *XU Fanshu*[1] *WANG Xiaochen*[1]
ZHAO Haoxing[1] *ZHU Xing*[1] *HE Na*[2]
1 State Key Laboratory of Geohazard Prevention and Geoenvironment Protection, Chengdu University of Technology, Chengdu 610059, China
2 Geological Environment Monitoring Station of the Guangxi Zhuang Autonomous Region, Nanning 530201, China

Abstract: **Objectives**: On July 26, 2024, Typhoon "Gaemi" struck Zixing City, Hunan Province, China, triggering large-scale landslide disasters that caused extensive damage to buildings, blocked several roads, and resulted in significant casualties. However, the development, distribution, and formation conditions of the landslides triggered by Typhoon "Gaemi" remain unclear, which impacts post-disaster reconstruction and risk assessment. **Methods**: We present the identification and analysis of landslides induced by Typhoon "Gaemi" through three main parts: landslide recognition, spatial and statistical analysis, and explainable machine learning. First, historical rainfall-induced landslide data from regions like Longxi, Yan'an, and Shaoguan are used to train and optimize the YOLOv8 model for improved accuracy and robustness. The model is applied to post-disaster optical remote sensing imagery for automatic identification,

基金项目:国家重点研发计划(2022YFC3003205);四川省科技计划(2025ZNSFSC1206);广西桂东南花岗岩地区暴雨诱发群发性地质灾害成灾机理综合调查(GXZC2024-G3-002922-GXCJ)。
第一作者:刘瑞阳,博士生,主要从事地质灾害评价与预测研究。727836599@qq.com
通信作者:许强,博士,教授。xq@cdut.edu.cn

with manual verification and the creation of a landslide database for Zixing City. Next, spatial distribution characteristics of the landslides are analyzed using environmental data, revealing the spatial patterns and controlling factors of landslides induced by Typhoon “Gaemi”. Finally, statistical data are used to train a machine learning model to assess landslide susceptibility, with Shapley additive explanations (SHAP) employed to interpret the model and identify key factors influencing landslide occurrence. These methods provide a comprehensive analysis of landslide risks and serve as a basis for disaster prevention. **Results:** Using the deep learning model YOLOv8 and manual verification, we identify approximately 16 120 landslides triggered by Typhoon “Gaemi” in Zixing City, covering a total area of 32.16 km^2. These landslides are predominantly concentrated in the eastern mountainous areas of Zixing City, with a peak point density of 129 per km^2, exhibiting a notable clustering effect. Statistical analysis reveals that most of the landslides occur on slopes with an elevation range of 200-600 m and a slope gradient of 20°-30°. Further analysis demonstrates that the occurrence of these landslides is significantly influenced by geological conditions, with 63.5% of landslides occurring in granite regions and 29.4% in sandstone and shallow metamorphic rock areas. Random forest modeling and SHAP analysis identify lithology as the primary factor controlling landslide formation. The importance of disaster-triggering factors varies across different lithological regions. In granite areas, faults are the most significant factor influencing landslide occurrence, while human activities also contribute notably to landslide formation. In sandstone regions, river erosion is the dominant factor controlling landslide formation. **Conclusions:** The deep learning and machine learning models used in this study demonstrate clear advantages in landslide identification, susceptibility assessment, and analysis of disaster-triggering factors. The identified distribution patterns of landslides and the geological control mechanisms can provide scientific evidence for analyzing the landslide formation conditions and disaster prevention and control in Zixing City and similar regions with comparable geological conditions.

Key words: Typhoon “Gaemi”; cluster landslides; intelligent identification; susceptibility modeling; interpretable machine learning

2024 年 7 月 26 日—28 日,受台风“格美”影响,中国湖南省郴州市普降暴雨、特大暴雨,资兴市位于此次暴雨的中心区域。此次特大暴雨事件不但在降雨量上突破历史极值,其引起的自然灾害更是对人民生命安全和财产造成了重大影响。据不完全统计[1],暴雨诱发的群发性山体滑坡和泥石流等次生灾害(图 1(a))造成 149 个村 66 793 户电力中断,152 个村 1 896 个组道路中断(图 1(b)),78 个村通信中断,1 714 户 11 869 间房屋倒塌,受灾人口 12.8 万人,造成 50 人死亡、15 人失踪,引起了社会的广泛关注。

传统的地质调查和排查是地质灾害隐患识别的主要手段,但单纯依靠人工方法往往力不从心,特别是对于高位和隐蔽隐患点。此次台风诱发的滑坡事件发生在丘陵及山地区域,滑坡导致道路受阻,使得地面调查无法及时抵达灾害中心进行评估,进而影响了应急救援工作的及时开展。随着人工智能的快速发展,深度学习、机器学习将成为推动地质灾害隐患识别智能化和自动化的重要工具[2-3]。目前,已有大量群发性降雨型滑坡采用深度学习模型进行快速识别[4],这显示出深度学习模型在滑坡灾害应对中的广阔应用前景。

滑坡通常是由多种因素相互作用引发,传统数理统计方法难以揭示各因子间的复杂关系。基于机器学习算法的滑坡因子评价不仅能够揭示滑坡诱发因素之间的内在关系,还能预测滑坡发生的空间概率[5]。近年来,随着人工智能技术的迅猛发展,越来越多的研究开始采用各种机器学习方法评价滑坡易发性[6]。然而,目前的主流应用主要停留在易发性评价方面,对于各评价因子对滑坡形成的作用机制仍然不清晰[7]。模型可解释性分析在金融[8]、医疗[9]等行业取得了显著效果,利用可解释分析结果优化模型算法具有广阔的研究前景。揭示机器学习黑箱模型的内部机制,不仅有助于提升滑坡易发性预测算法的性能,还对深入理解滑坡形成条件具有重要意义。

尽管台风“格美”诱发了大量滑坡,导致显著人员伤亡和经济财产损失,目前对于台风“格美”诱发滑坡的发育分布与形成条件仍不清晰,严重



(a) 资兴市八面山瑶族乡7月30日航拍图(据新华社发布) (b) 资兴市八面山滑坡导致道路受阻(据湖南日报发布)

图1 湖南省资兴市2024年7月台风“格美”诱发群发性滑坡灾害

Fig. 1 Landslide Disasters Induced by Typhoon “Gaemi” in Zixing City, Hunan Province in July 2024

影响灾后恢复重建和风险隐患排查。本文首先采用深度学习模型对资兴市灾后遥感影像进行滑坡智能识别,并通过人工校核建立滑坡数据库;然后,结合孕灾地质环境条件,开展滑坡的空间与统计分析,揭示滑坡的发育分布规律;最后,利用机器学习模型对研究区滑坡进行易发性建模,并通过可解释性分析深入探讨孕灾环境对滑坡形成的作用模式,揭示地质环境条件对群发性滑坡的控制作用。研究结果不仅为资兴市的风险评估和灾后重建提供了重要支撑,也为台风诱发滑坡的形成条件研究提供了科学参考。

1 研究区概况

1.1 研究区域

本文研究区资兴市位于湖南省东南部,地处郴州市的东部,全市总面积约2 746.79 km^2,地貌以山地和丘陵为主,地势东高西低,海拔差异明显。最高点八面山海拔2 032 m,最低点程江口海拔仅106 m,全市平均海拔630 m。山地和丘陵面积约占总面积的3/4,地貌复杂多样。此外,资兴市境内的东江水库面积达160 km^2,是湖南省最大的水库之一(图2),底图来源于天地图,原审图号为GS(2024)0650,行政边界未作改动。研究区的地质覆盖层以砂岩和花岗岩为主,气候类型为亚热带季风气候。每年4月—6月是雨水集中期,暴雨频繁且雨势强烈,而7月—8月降雨则常受到台风的影响。由于资兴市独特的地形、地貌以及岩性特征,该地区极易发生各类地质灾害[10]。

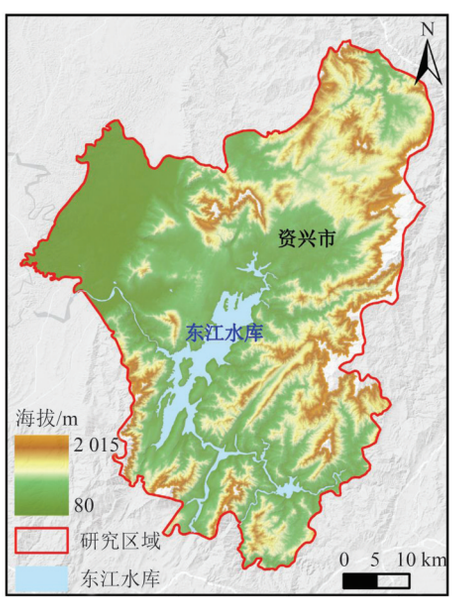


图2 研究区位置

Fig. 2 Location of the Study Area

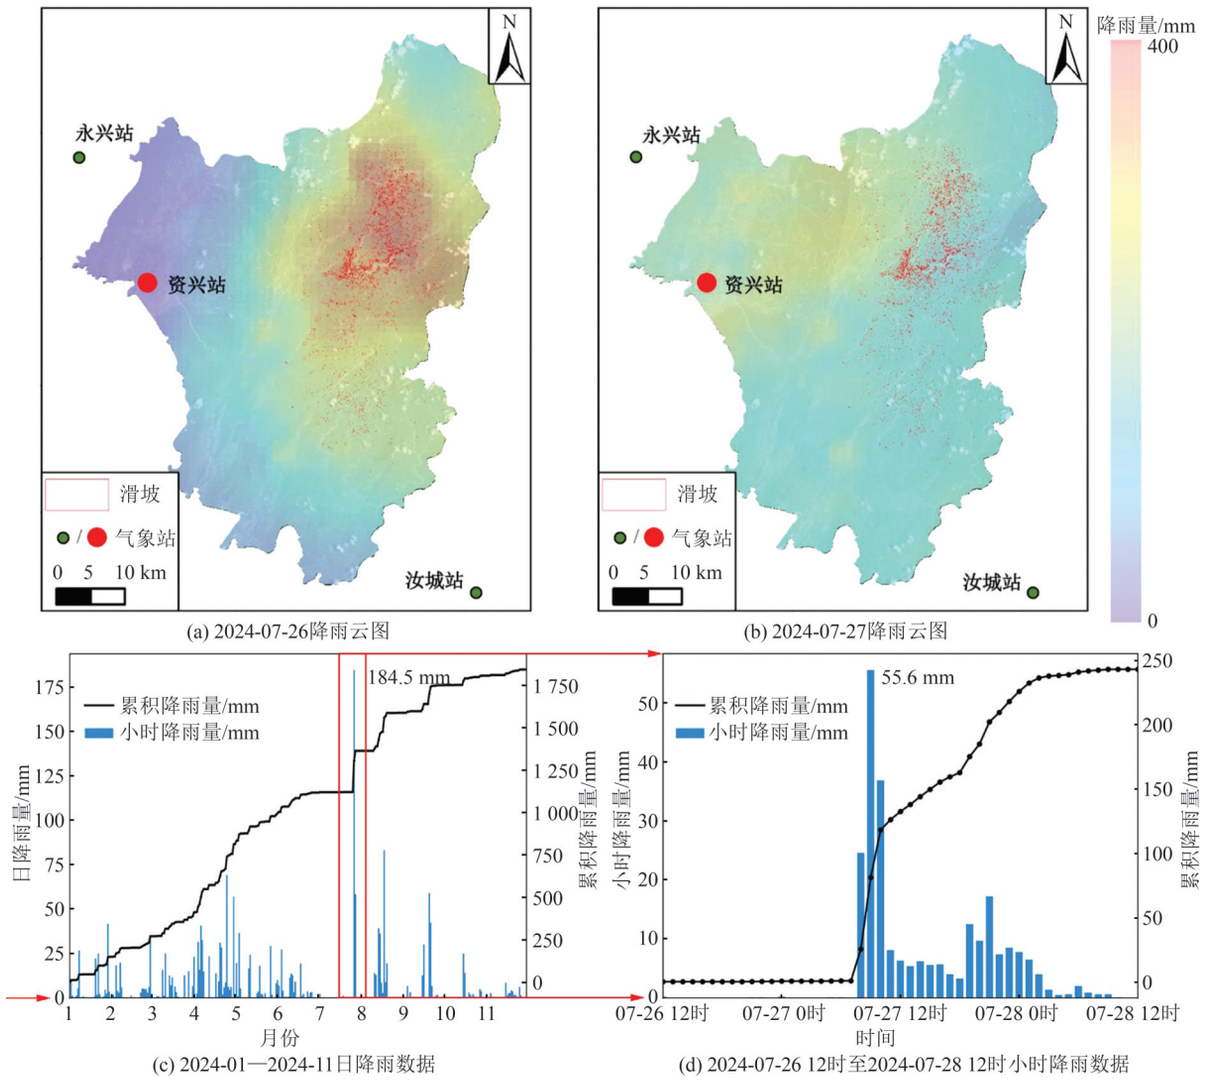
1.2 2024年7月台风“格美”事件

2024年第3号台风“格美”于7月20日下午14时在菲律宾以东洋面生成,随后向北偏西方向移动,其强度逐渐加强。7月26日,台风“格美”抵达资兴市,并在夜间引发了首轮暴雨。根据资兴市气象站的记录,2024年7月全月降雨量达到246.4 mm,其中7月27日的降雨量就高达184.5 mm(图3(c))。根据气象雷达数据显示,7月26日0时至24时,资兴市的最大累积降雨量为392.2 mm(图3(a)),突破郴州市365.4 mm的历史极值[1]。7月26日的降雨云图显示,强降雨区域与滑坡发生地高度重合,可以推测,当日的暴雨是引发滑坡的主要外在因素。

2 数据与方法

本文将对台风“格美”诱发滑坡进行识别与分析的过程分为3个部分(图4):

1)滑坡识别。将陇西、延安、韶关等区域降雨诱发的历史群发性滑坡数据应用于YOLOv8



(a) 2024-07-26降雨云图　(b) 2024-07-27降雨云图

(c) 2024-01—2024-11日降雨数据　(d) 2024-07-26 12时至2024-07-28 12时小时降雨数据

图3　资兴市降雨数据

Fig. 3　Precipitation Data in Zixing City

模型进行训练和优化。利用优化后的模型,在灾后光学遥感影像上进行滑坡识别,并对识别结果进行人工校核,从而构建资兴市的滑坡数据库。

2)空间分析和统计分析。对滑坡数据的空间分布特征进行分析,再结合数字高程模型(digital elevation model, DEM)、地质图等孕灾环境数据对滑坡的发育分布规律进行统计分析。

3)可解释性机器学习。利用统计分析中的孕灾环境数据作为特征因子训练机器学习模型,使用训练好的模型对研究区域进行易发性分析,并利用可解释机器学习方法SHAP(Shapley additive explanations)[11]对模型进行解释分析,揭示滑坡的主控因子重要性排序及其作用模式。

2.1　遥感影像数据选取

研究区域的光学遥感数据来源于Planet Labs公司的卫星群,该卫星群主要由Dove卫星和SkySat卫星两类卫星组成。Dove卫星的空间分辨率通常为3~5 m[12],而SkySat卫星则提供0.5 m的高分辨率[13]。尽管SkySat卫星具有更高的空间分辨率,但由于其卫星数量有限、覆盖频次较低且成本较高,并不适合用于大范围的滑坡识别。因此,考虑到Dove卫星提供的3 m分辨率已足以满足滑坡识别需求,并且其覆盖频次较高、成本较低,本文选择了Dove卫星影像进行滑坡识别。

受台风引起的降雨天气影响(图3),资兴市的灾后遥感影像大范围被云层遮蔽。为确保滑坡识别的准确性,本文选取了最接近滑坡事件发生时间且云量较少的影像。考虑到研究区域较大,单一时间点的影像难以满足要求,因此,本文选取了8月5日、8月7日和8月9日期间的影像,并对满足条件的区域进行拼接,以确保数据的完整性和滑坡识别的精度。

台风“格美”诱发的资兴市群发性滑坡事件前后的Planet遥感影像如图5所示,在台风过后,

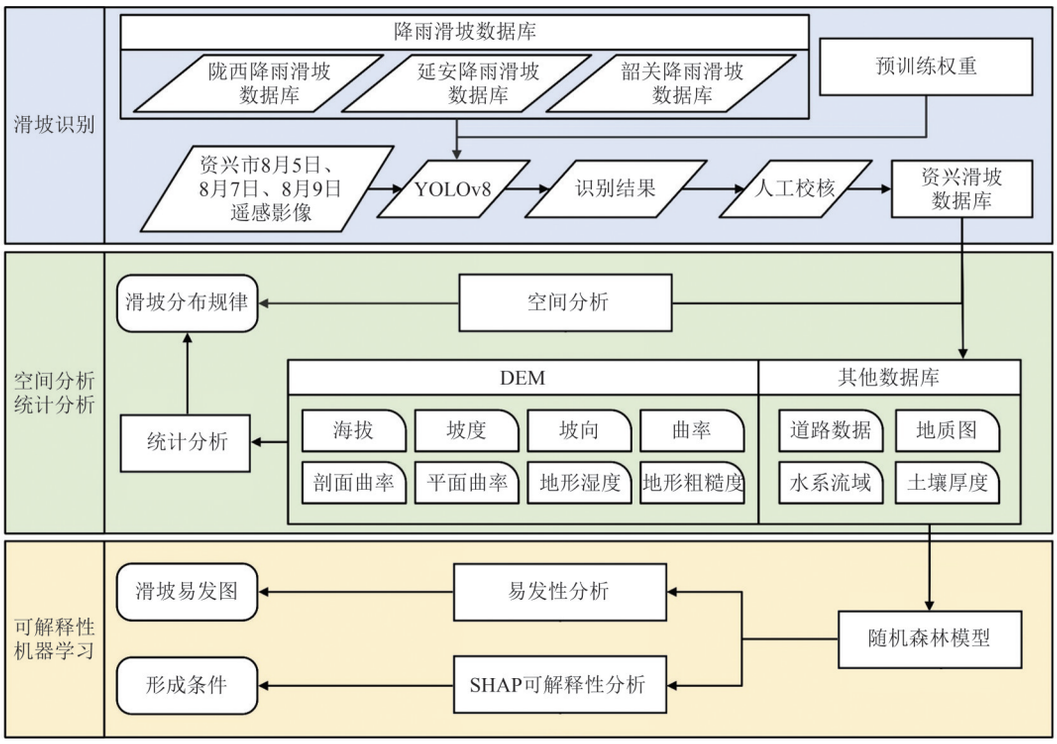
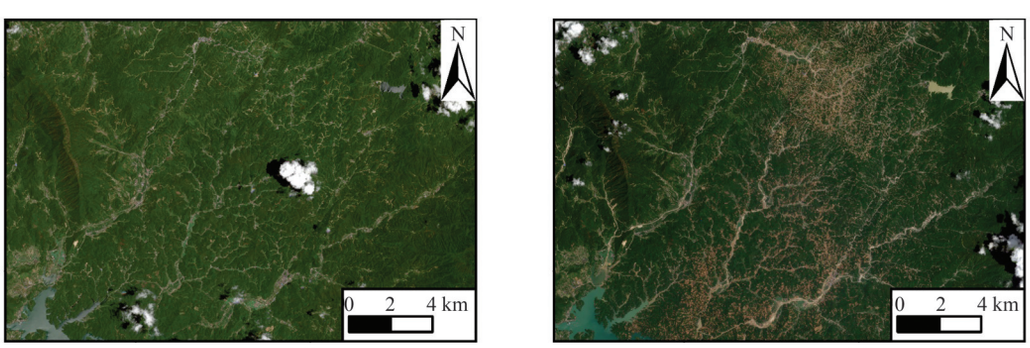


图4 整体流程图

Fig. 4 Overall Workflow



(a) 2024-07-22影像 (b) 2024-08-05影像

图5 研究区滑坡前后Planet遥感影像

Fig. 5 Planet Remote Sensing Images Before and After the Landslide in the Study Area

资兴市八面山区域发生了大量且密集的滑坡灾害,这为确定滑坡发生的时间区间提供了依据,并为自动识别与人工校核提供了可靠的数据支持与现实参考。为确保滑坡样本均在台风“格美”影响下产生,本文通过对比台风前后影像,结合降雨量等气象数据,并辅以人工校核,排除了非台风诱发的滑坡,确保了样本的准确性和可靠性。

2.2 滑坡智能识别模型构建

传统的滑坡灾害分析通常依赖于遥感数据进行野外勘探和人工目视解译。尽管这些方法在准确性上表现较好,但过于依赖专家经验,且过程繁琐、耗时耗力。由于滑坡灾害的严重性,滑坡的快速自动化识别近年来受到了研究人员的广泛关注[14]。

本文使用YOLOv8模型进行滑坡智能识别,模型结构主要由输入、骨干网络、颈部网络和头部网络组成,对于计算机视觉模型来说,模型的骨干网络是最关键的组件。YOLOv8继承了YOLOv5骨干网络的设计,并将CSPLayer模块替换为C2f模块。C2f模块通过结合上下文信息与跨阶段部分瓶颈的高级特征,并采用两次卷积,显著提升了目标检测的准确性。因此,YOLOv8在整体效率和精度上都得到了改善[15]。

由于本次资兴市滑坡灾害的遥感图像为滑坡发生一年内的影像,这种新发生的滑坡在光谱特征和形状纹理上与陇西[16]、延安[17]及韶关[4]地

区的降雨诱发群发性滑坡相似,尤其是植被覆盖区域和裸露地表的光谱响应曲线高度吻合[18],因此选择这3个历史滑坡数据库对模型进行预训练和参数优化。

YOLOv8模型的识别过程如图6所示。首先,将资兴市滑后影像裁剪为512×512×3的若干图像块,依次输入模型进行识别;其次,在骨干网络中,图像经过卷积、特征融合等手段获取图像多尺度、深层次的特征;然后,在颈部网络中,特征图融合、增强,使得不同尺度的特征能够得到有效利用;最后,头部网络根据颈部网络处理后的特征图,输出最终的目标检测结果(滑坡、非滑坡),再通过上采样恢复为输入尺寸大小。为实现快速且准确的模型,选用了中等大小的预训练参数,并经过100轮迭代优化,最终选取了精度最高的参数作为本次智能识别任务的模型。

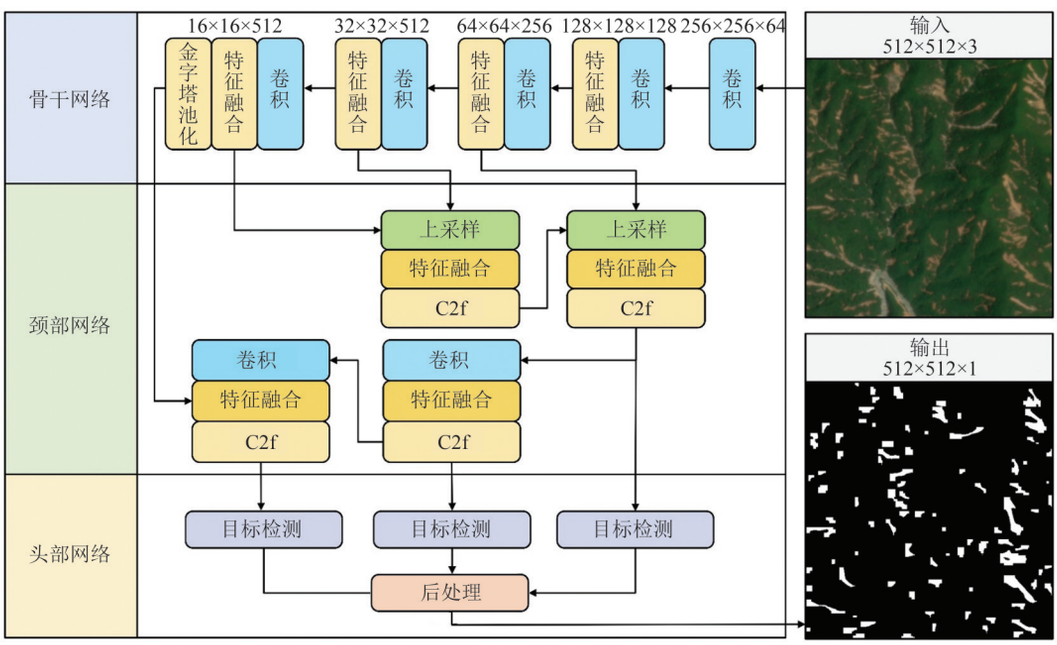


图6　基于YOLOv8的滑坡智能识别模型

Fig. 6　Landslide Intelligent Recognition Model Based on YOLOv8

为进一步提升模型的检测精度和泛化能力,利用陇西、延安、韶关等地区的遥感影像和滑坡标注数据,通过人工修正、数据增强(如Mosaic、随机旋转)、学习率调整(如余弦退火)和模型结构调优(如更换锚框),迭代优化YOLOv8模型。最终,使用优化后的YOLOv8模型输出检测结果,并将结果转换为矢量文件用于GIS空间分析。

2.3　滑坡发育分布特征分析

在对滑坡识别结果进行人工校核后,构建2024年7月台风“格美”诱发滑坡数据库。首先,在此基础上,统计滑坡的数量和面积,分别绘制滑坡面积-概率密度图、滑坡点密度图以及面积密度图分析台风“格美”诱发滑坡的规模大小与空间分布特征。然后,通过单因子统计定量分析滑坡发育分布规律,本文选取的因子主要考虑滑坡所处的孕灾环境(地形地貌、地质条件、人类工程活动)[19-20],从DEM、土壤厚度、地质图、道路、河流等数据库(表1)中提取相关数据,包括高程、坡度、坡向、曲率、地形湿度指数(terrain wetness index, TWI)、地形粗糙度指数(topographic ruggedness index, TRI)、土壤厚度、与道路的距离、与河流的距离、与断层的距离、岩性等11个环境因子(图7)。

表1　滑坡特征因素数据库

Table 1　Landslide Feature Factor Database

类型	来源	时间	分辨率
DEM	ALOS卫星[21]	2006—2011年	12.5 m
土壤厚度	中国科学院南京土壤研究所[22-23]	2010—2018年	90 m
地质图	中国地质调查局[24]	2001—2002年	1∶25万
道路数据	高德地图	2020年	3 m

2.4　基于可解释性机器学习的易发性建模

本文采用随机森林模型对此次滑坡进行建模,其由BREIMAN[25]开发,通过构建大量相互独立且略有不同的决策树来完成分类或回归任务,该方法已被广泛应用于滑坡易发性分析[26]。对于本文中的分类问题(滑坡与非滑坡),随机森林通过对所有决策树的预测结果进行投票,选择

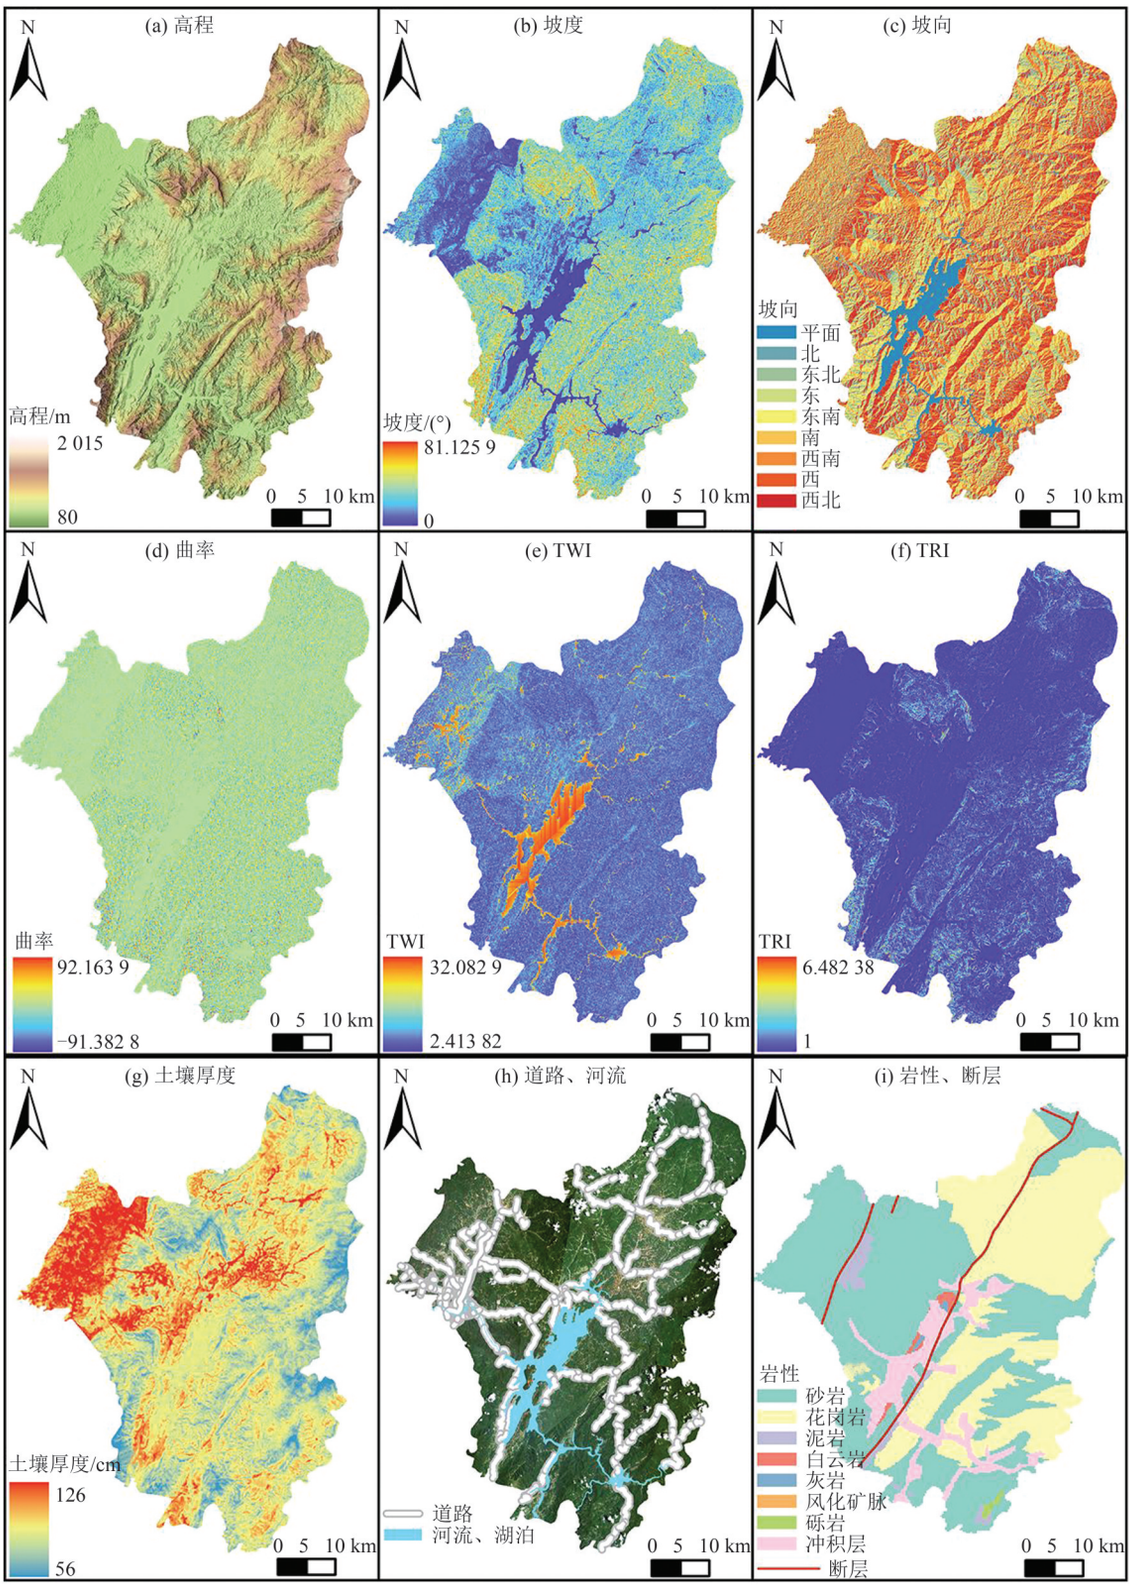


图7 滑坡孕灾环境因子数据集

Fig. 7 Landslide Hazard-Inducing Environmental Factor Dataset

得票最多的类别作为最终的预测结果。此次训练选取了前文发育分布规律分析中的11个环境因子作为训练变量,各个环境因子的皮尔逊相关系数计算结果如图8所示,表明各环境因子有着相对良好的独立性。

训练随机森林模型需要准备等量的正样本和负样本作为训练样本,正样本来自人工校核后的资兴降雨滑坡数据库,负样本通过ArcGIS软件随机生成。其中,70%的训练样本用于训练,剩余30%用于测试。通过测试集评估模型性能,

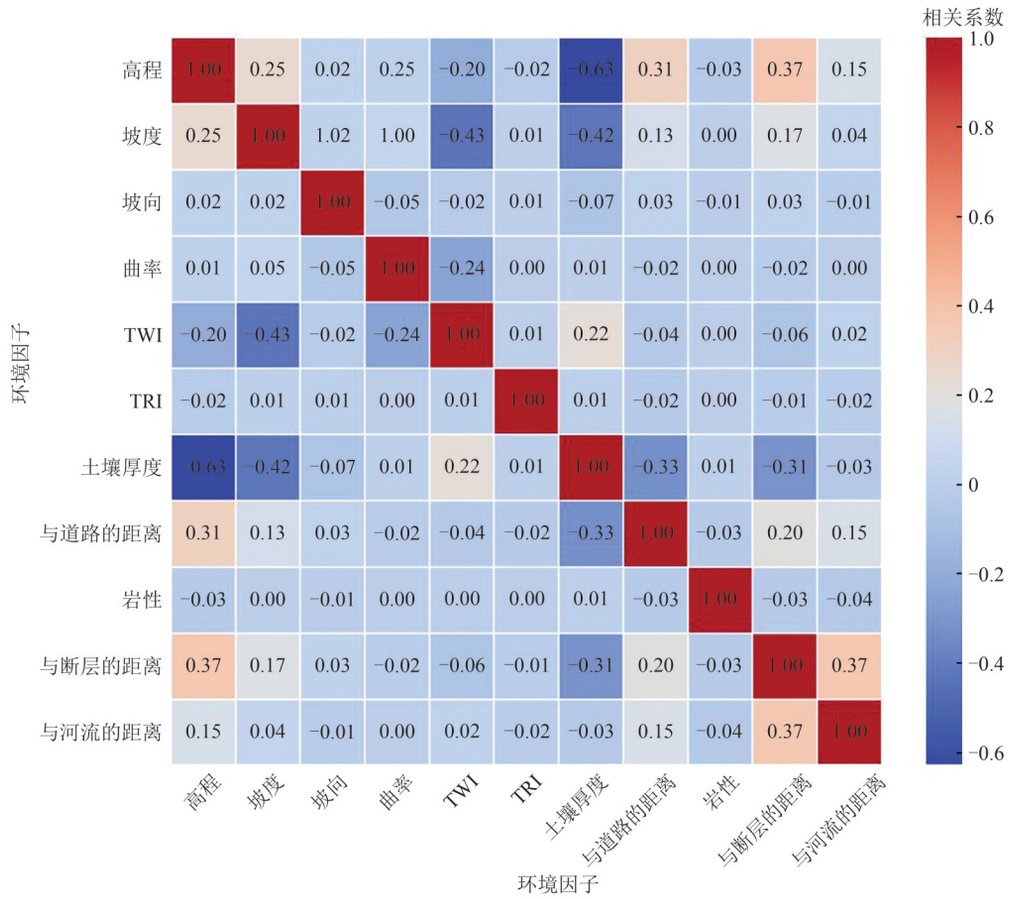


图8　皮尔逊相关系数

Fig. 8　Pearson Correlation Coefficient

计算模型的准确率、精确度、召回率、$F1$分数、受试者工作特征曲线(receiver operating characteristic curve, ROC)和曲线下面积(area under curve, AUC),对模型性能进行综合评价。

由于随机森林算法是一个黑箱模型,无法直接从模型中提取出每个特征的具体贡献。在机器学习领域,理解单个特征对模型预测的影响至关重要。SHAP是一种基于合作博弈论的方法,通过量化每个特征对模型预测的贡献,为深入理解模型决策过程提供了可靠的解释,在优化机器学习模型、提升模型预测效果上发挥着关键作用[27]。在计算SHAP值时,考虑到特征的边际贡献,模型会通过评估所有可能的特征组合来量化每个特征的贡献,这一过程可以通过公式表示为:

$$E_{\mathrm{SHAP}_j}=\sum_{s\subseteq F\backslash\{j\}}\frac{|S|!\left(|F|-|S|-1\right)!}{|F|!}\left[f(S\cup\{j\})-f(S)\right] \tag{1}$$

式中,F为所有特征的集合;S为不包含特征j的特征子集;$f(S)$为基于特征子集S训练的模型所得的预测结果;$f(S\cup\{j\})$为当特征j被加入时的预测结果。式(1)评估了特征j在不同特征组合中对模型预测的平均影响,从而突出其独特的贡献。基于SHAP分析,黑箱模型的预测过程变得更加透明,最终可以揭示每个特征对模型预测的具体贡献,包括特征的重要性和影响方向(正向或负向),从而为深入分析台风诱发滑坡的形成条件提供了更加清晰的视角。

3　结果与分析

3.1　滑坡智能识别结果

将资兴市总面积约为2 746.79 km^{2}的雨后光学遥感影像导入构建的滑坡智能识别模型进行处理,初步识别出17 832个疑似滑坡区域。经过人工校核,最终共解译出滑坡16 120处,总面积达到32.16 km^2。根据自动识别结果与人工修正结果的对比,模型精确率为85.27%,召回率为83.18%。滑坡主要分布在东江水库的东部和东北部区域,不仅集中在坪田村、八面山瑶族乡、烟

坪村等丘陵地带,还在中洞村、龙溪村等山地区域集中分布。图9展示了基于YOLOv8的滑坡智能识别模型解译结果,表明该模型基本能够完整且准确地识别滑坡位置和轮廓。尽管道路和山谷低洼区域的颜色和纹理等特征与滑坡区域非常相似,但模型并未将这些区域误识别为滑坡。由此可见,本文构建的滑坡识别模型识别结果具有较高的可靠性。

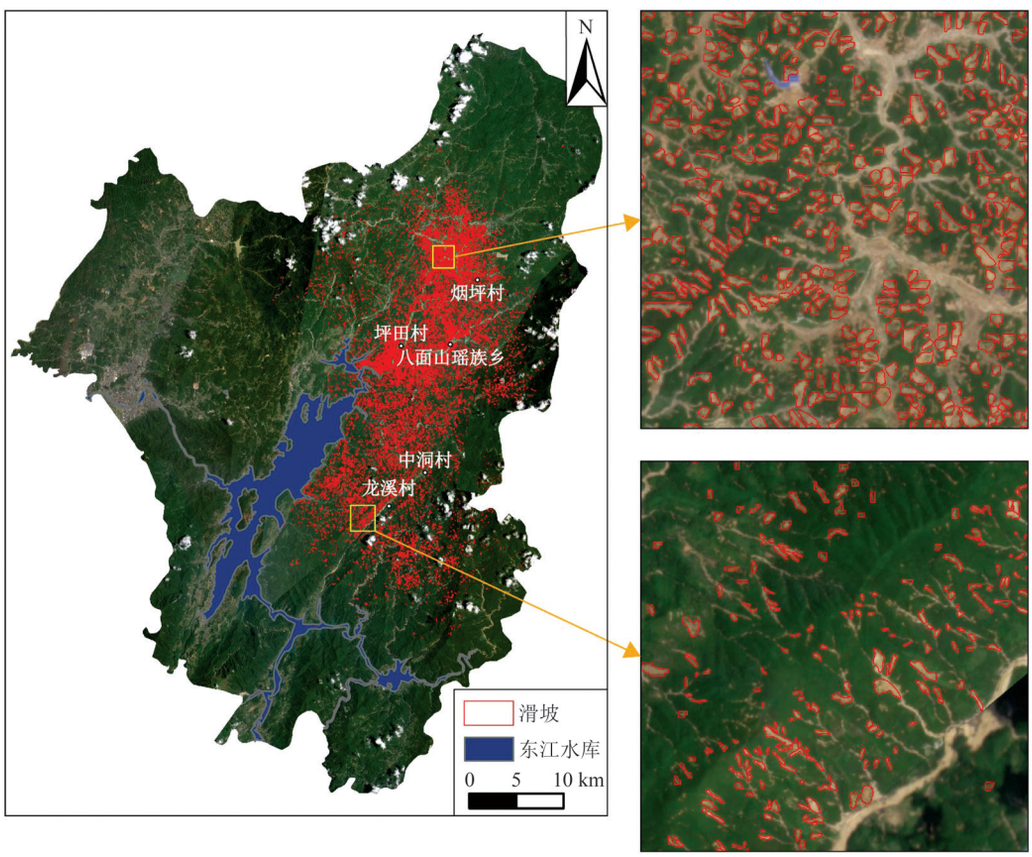


图9 模型识别结果

Fig. 9 Identification Result of the Model

3.2 滑坡发育分布特征

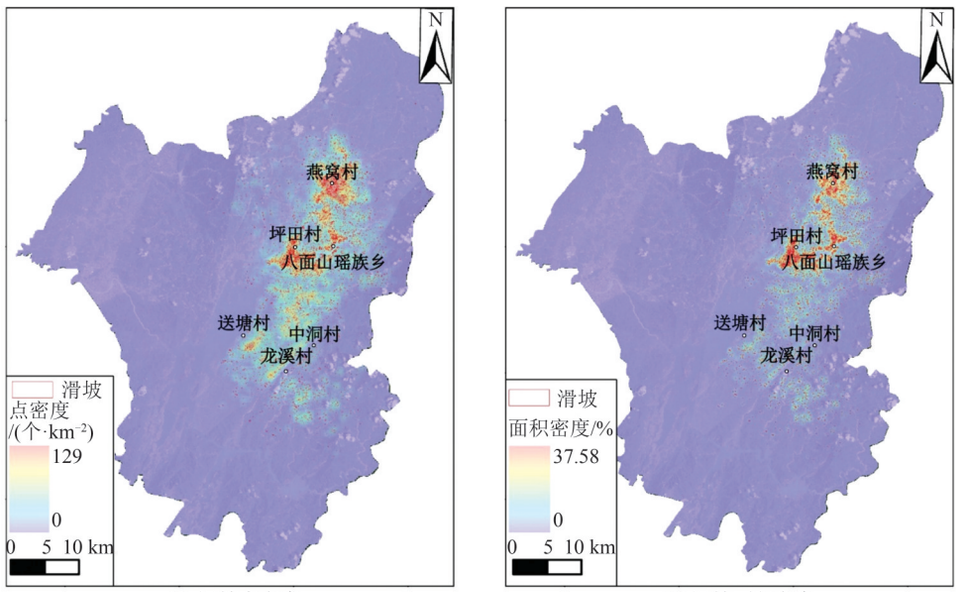
将人工校核后的滑坡解译结果作为资兴市降雨滑坡数据库,进一步进行空间分析。滑坡点密度指单位面积内的滑坡数量,滑坡面积密度指单位面积内滑坡面积的占比[28]。由滑坡点密度图(图10(a))可知,台风"格美"诱发滑坡多集中于资兴市东部的丘陵山区。中洞村和龙溪村的滑坡主要集中在沟谷区域,并沿沟谷呈北东-南西向带状分布;而燕窝村、坪田村和八面山瑶族乡则是滑坡最为密集的区域,其中燕窝村附近的点密度最高,达129个/km^2。

将滑坡面积密度图(图10(b))与点密度图对比,燕窝村、坪田村和八面山瑶族乡附近的滑坡面积密度明显高于中洞村和龙溪村,表明滑坡虽然在这两个区域中存在较为集中的趋势,然而燕窝村、坪田村和八面山瑶族乡附近地区的滑坡影响范围更广,未发生滑坡的区域面积占比较小。面积密度最高的区域位于坪田村,高达37.58%的土地发生了滑坡灾害。

基于资兴市降雨滑坡数据库,进一步对滑坡发育规模进行统计分析,并绘制滑坡面积-概率密度图,如图11所示。此次台风"格美"诱发滑坡的面积大部分在5×10^2~5×10^3 m^2,约占滑坡总量的67.48%。此外,面积小于1×10^3 m^2的滑坡共有5 243处,占滑坡总数的32.52%。此外,此次台风"格美"诱发滑坡的平均面积约1 995.39 m^2,最大面积约24 612.63 m^2。

基于资兴市降雨滑坡数据库,以每个滑坡相对高程2/3处的等高线中点作为滑源区中心,提取滑坡孕灾数据集(图7)的对应数据,近似表征每个滑坡对应的孕灾环境特征,最后进行分级统计[29],统计结果如图12所示。

1)地形地貌因子。台风"格美"诱发的滑坡主要分布在海拔200~600 m、坡度20°~30°的斜坡上,且未表现出明显的阴阳坡差异。滑坡的曲率主要集中在-10~10之间,且在凸起地形处



(a) 滑坡点密度　　(b) 滑坡面积密度

图 10　资兴市台风“格美”诱发群发性滑坡密度图

Fig. 10　Landslide Density Map Induced by Typhoon“Gaemi”in Zixing City

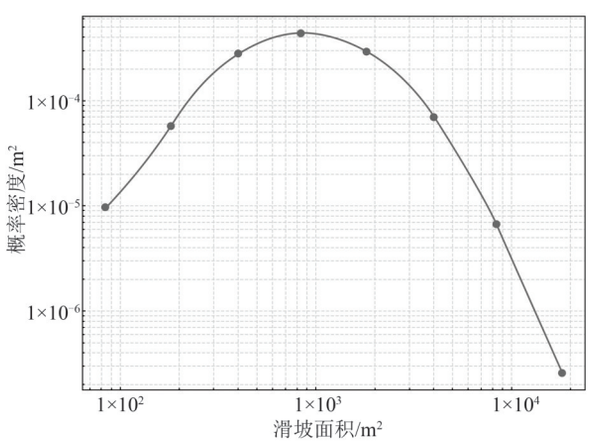


图 11　滑坡面积-概率密度图

Fig. 11　Plot of Landslide Area-Probability Density

发生的概率较高。TWI值在3～12的区域更容易发生滑坡,表明相较于高积水区,滑坡更易发生在具有水力梯度的流通区域。滑坡主要分布在低TRI区域,但不同TRI区域的滑坡分级面积密度相差不大。同时,滑坡的发育密度与距河流的距离整体上呈负相关关系,表明河流侵蚀作用对滑坡形成具有一定的贡献。

2)地质环境条件。断层对滑坡发育的影响与河流相似,整体呈负相关关系,尤其在距离断层3～9 km范围内滑坡密度最高。发生滑坡的区域土壤厚度大约为80～100 cm,其中以90～100 cm的土壤厚度区段滑坡分级面积密度最高。据资兴市地质图(图7(i))可知,资兴市分布最广的岩石类型是砂岩,其次是花岗岩。然而,花岗岩组在所有地层中滑坡灾害发生的密度最高,共发生滑坡10 216处,占所有滑坡的63.37%,滑坡总面积为20.47 km^2。其次,滑坡分布较为密集的是砂岩组区域,共发生滑坡4 724处,占29.30%,总面积8.81 km^2。

3)人类工程活动。滑坡的分布与道路距离呈明显相关性,距离道路越近的区域滑坡越为密集,表明斜坡人工开挖在一定程度上对台风暴雨诱发滑坡具有重要的影响作用。

3.3　滑坡易发性制图

参数调整是提升模型性能的关键步骤。在训练随机森林模型时,本文通过循环优化选择分数最高的参数作为最终训练参数,并使用外部评价方法对模型进行全面评估。训练后的模型在测试集上表现优异,准确率为85.79%,精确率为83.55%,召回率为88.71%,$F1$分数为86.05%。此外,ROC(图13(b))显示,随机森林的AUC值达到0.94,显著高于支持向量机的0.73和多层感知器的0.84,进一步验证了随机森林在滑坡易发性预测中的优越性。结果表明,该模型的性能能够满足实际预测需求。

将资兴市孕灾环境数据库导入训练好的随机森林模型进行预测,得出每个像素点的预测值(表2),并将结果导入ArcGIS中生成滑坡易发性评价图(图13(a))。可以看出,预测结果中的高易发性区域(红色区域)与台风“格美”诱发滑坡的分布(蓝色区域)高度重合,滑坡易发区主要集中在资兴市东部和东北部。由于此次预测仅基于滑坡孕灾环境条件,并未考虑台风降雨等触发

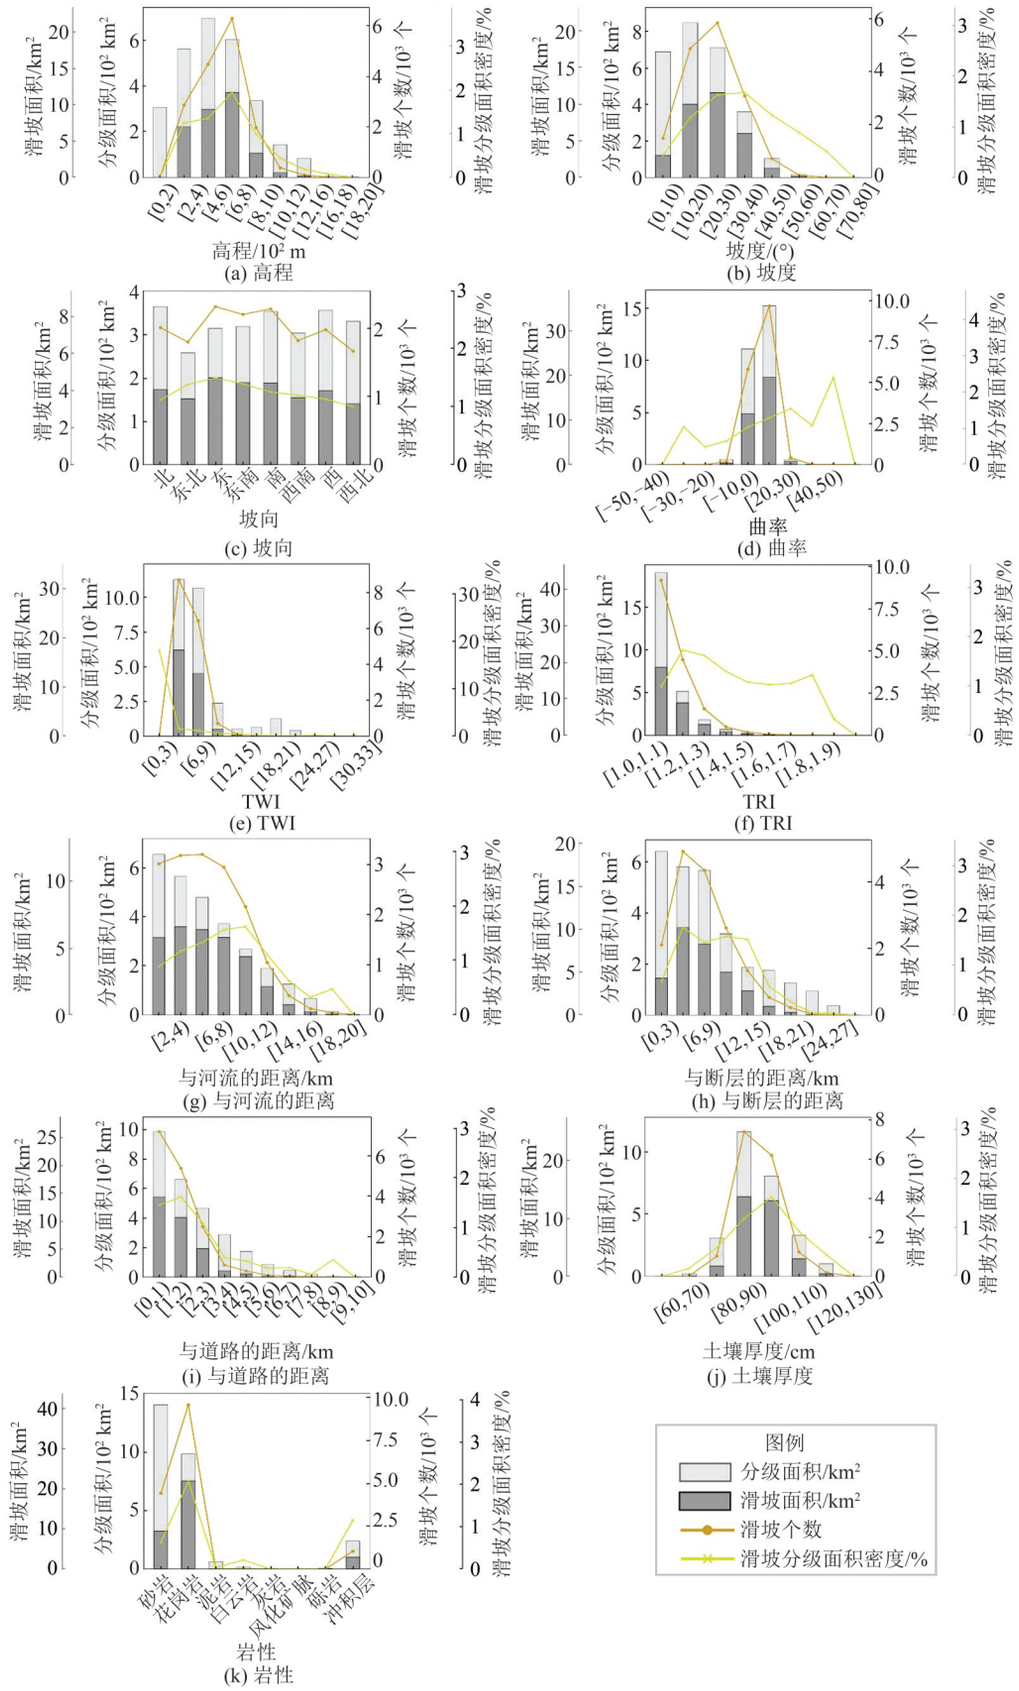
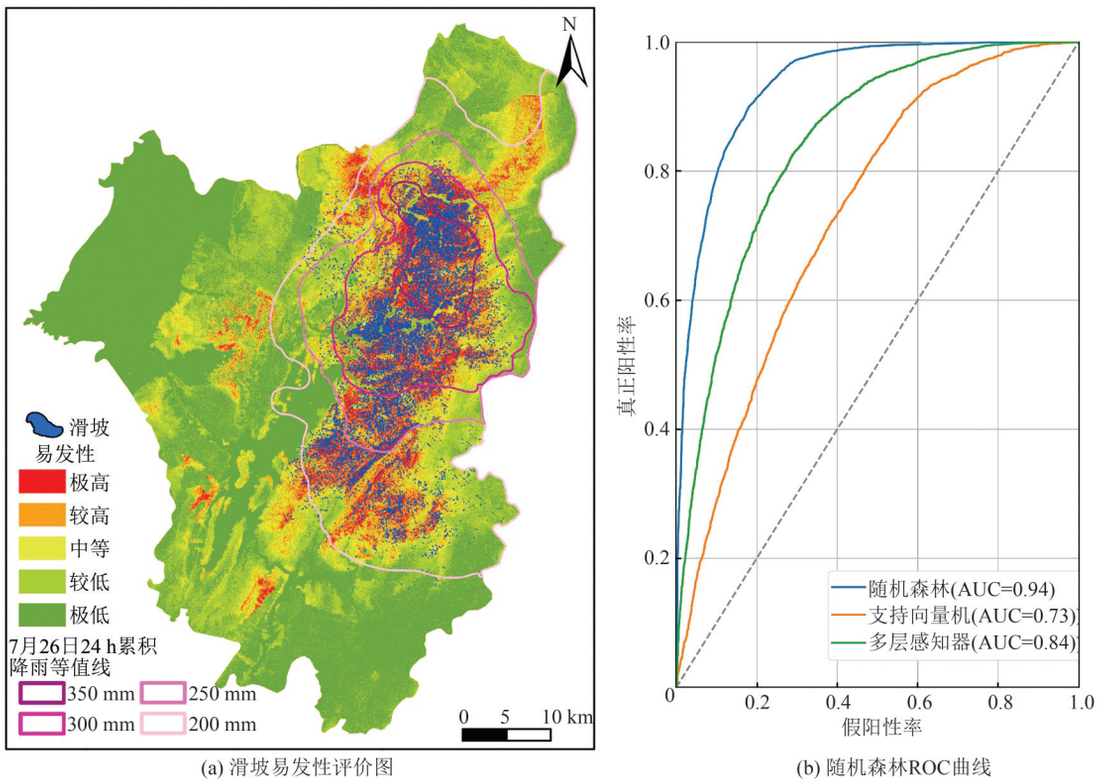


图12 不同因子下滑坡分布规律

Fig. 12 Landslide Distribution Patterns Under Different Factors

因素,因此在资兴市西部地区仍然出现局部滑坡高易发性区域。根据降雨雷达数据(图3(a)),台风“格美”引发的极端降雨区域主要位于资兴市东部和东北部。进一步统计结果显示,7月26日24 h降雨量大于350 mm的区域发育滑坡约4 237处,(350～300] mm区域约6 470处,(250～300] mm



(a) 滑坡易发性评价图　　(b) 随机森林ROC曲线

图 13　易发性分析图

Fig. 13　Susceptibility Analysis Map

表 2　易发性评价灾害点分布统计表

Table 2　Susceptibility Assessment Disaster Point Distribution Statistics Table

易发性	易发性分区面积/km^2	易发性分区占比/%	AUC
极高	186.86	6.8	
较高	259.16	9.4	
中等	319.58	11.6	0.94
较低	462.51	16.8	
极低	1 518.68	55.3	

区域约2 022处,250 mm以下区域约3 391处。可见,对于资兴市东部地区,由于该区域本身具有较高的滑坡易发性,因此在孕灾地质环境条件与台风降雨触发条件的耦合作用下,最终导致了资兴市东部区域群发性滑坡的发生。

4　讨　论

4.1　模型可解释性分析

SHAP值[27]能够揭示每个特征如何影响模型的预测(图14),尤其是它们如何使预测结果偏离基准值,通常基准值为训练集目标值的均值。SHAP方法的核心原则是一致性原则,即确保模型对某个特征的依赖变化能够在SHAP值中准确反映。由于训练模型中的正样本(值为1)和负样本(值为0)数量相等,所以训练集目标值的均值为0.5。训练好的模型会为测试集中的每个样本的11个孕灾环境因子进行打分(SHAP值),分数累加后得到该样本的SHAP值,因此SHAP方法可以更直观地展示机器学习模型如何处理样本。此外,SHAP还可以分析每个滑坡所处孕灾环境因子值的大小与预测值的关系,基于此,可以对基于资兴市台风“格美”诱发滑坡数据库所构建的随机森林模型进行深入解析,结果如图15所示。

图14中,在纵轴上因子按重要性从上到下排列,表示因子在模型预测中的影响力逐渐减弱,横轴展示了每个样本点的SHAP值,红色代表特征值较高,而蓝色则表示特征值较低。横轴上区域的宽度越大,表示该样本的集中度越高。SHAP分析结果表明,本次台风“格美”诱发滑坡最主要的影响因子是地层岩性,其次依次为与断层的距离、高程、与道路的距离、与河流的距离、曲率、TRI、坡度、土壤厚度、TWI和坡向,其中地层岩性、与断层的距离、高程、与道路的距离、与河流的距离5个因子的贡献率之和超过了70%,表明这5个因子是资兴市台风“格美”诱发滑坡的主要控制因素。该规律在图15的热力显示中也得到了很好的体现:因子贡献率越高,其对应的热力显示对比度越强,SHAP值的绝对值也越大;

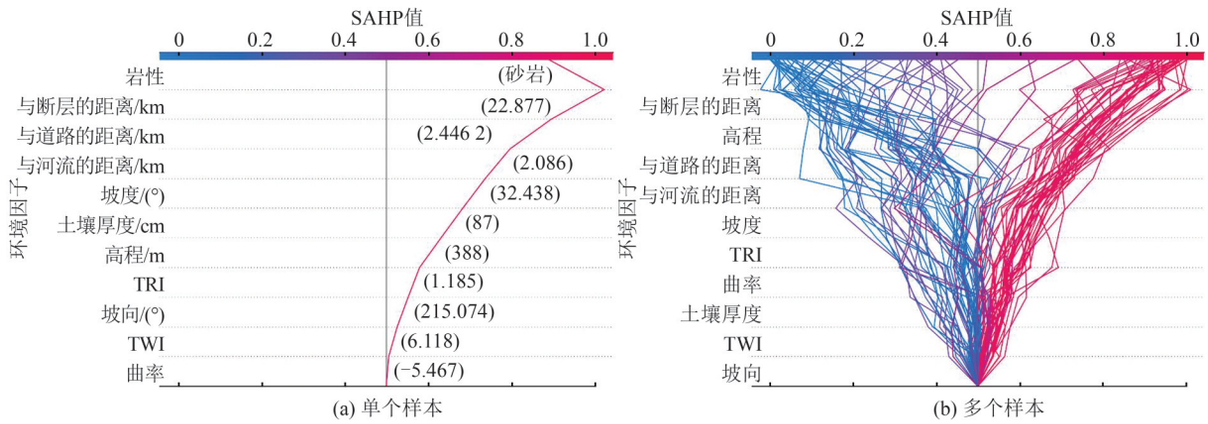


图14 SHAP解释随机森林模型示意图

Fig. 14 SHAP Explanation of the Random Forest Model

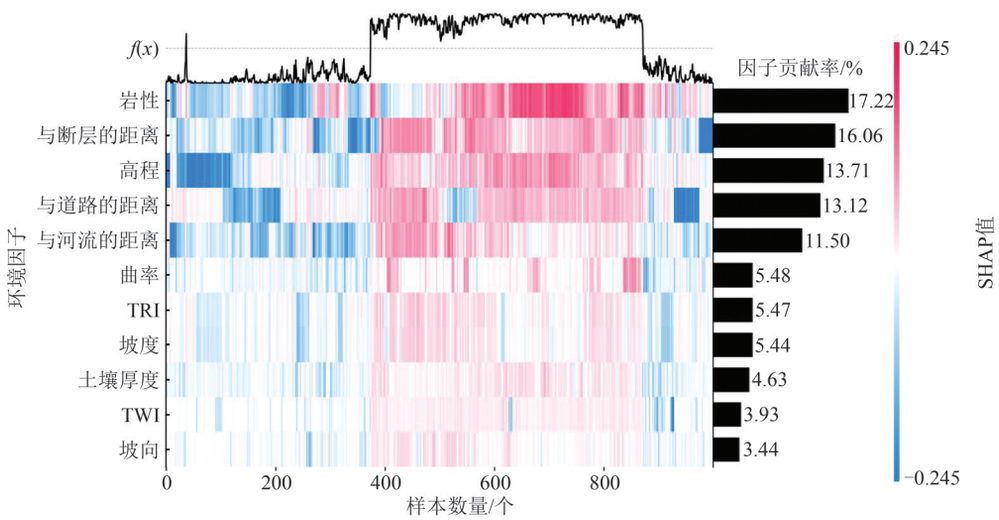


图15 滑坡孕灾因子的SHAP计算结果

Fig. 15 SHAP Calculation Results of Landslide Hazard-Inducing Factors

而贡献率较低的因子则表现为热力显示颜色较淡,SHAP值的绝对值较小。

4.2 滑坡地质控制作用

通过对资兴市台风“格美”诱发滑坡数据库的统计分析(图12)以及基于该数据库构建的随机森林模型的可解释性分析(图15),可以发现,资兴市台风“格美”诱发的滑坡主要受地质条件控制。由于资兴市台风“格美”诱发滑坡主要分布在花岗岩和砂岩区域,因此本文进一步分析了不同地质条件下滑坡孕灾环境因子的影响差异及其控制作用。

在花岗岩区,台风“格美”诱发滑坡的主要影响因子是与断层的距离,其次依次为道路、高程、与河流的距离、曲率、土壤厚度、TWI、坡度、TRI和坡向(图16)。这表明台风诱发的滑坡在花岗岩区域主要受地质构造的显著影响,同时人类工程活动对该区域滑坡的形成也具有重要贡献。资兴市的花岗岩地层主要为早古生代的二长花岗岩[30],断层活动通过引发岩体裂隙化、破碎以及裂隙通道的开放,促进了水分、氧气等因素的渗透,加剧了花岗岩的风化过程,从而在坡表形成花岗岩残积土。然而,花岗岩残积土土质松散、渗透性强,在降雨作用下,雨水快速入渗,坡体自重增加,土体强度迅速衰减,土体粘聚力急剧下降且原有结构也随之遭到破坏[31],因此在强降雨条件下,花岗岩残积土斜坡极易形成滑坡。再加上人类工程活动对坡体结构的改造和人为加卸载作用,导致在花岗岩区域形成的浅层滑坡相比砂岩区域具有更大的点密度和面积密度。

通过对资兴市花岗岩区台风“格美”诱发滑坡的10个孕灾环境因子进行分析,进一步绘制了部分依赖图(图17)。图17展示了当一个或多个环境因子的值发生变化时模型预测值的变化趋势,不仅可以直观观测到环境因子影响的方向(正向或负向),还能够看出是否存在概率贡献的临界点或非线性关系。

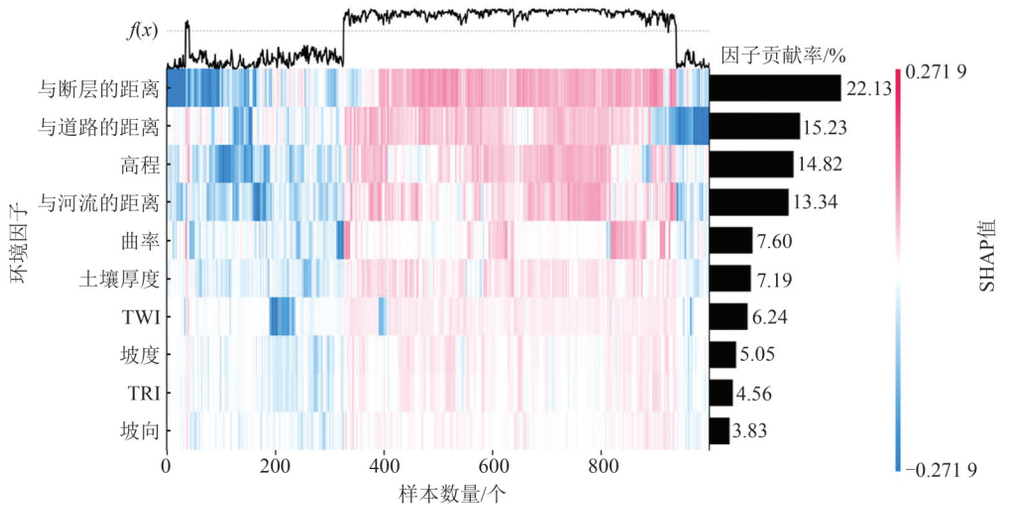


图 16　资兴市花岗岩区域滑坡孕灾因子的 SHAP 计算结果

Fig. 16　SHAP Calculation Results of Landslide Hazard-Inducing Factors in the Granite Area of Zixing City

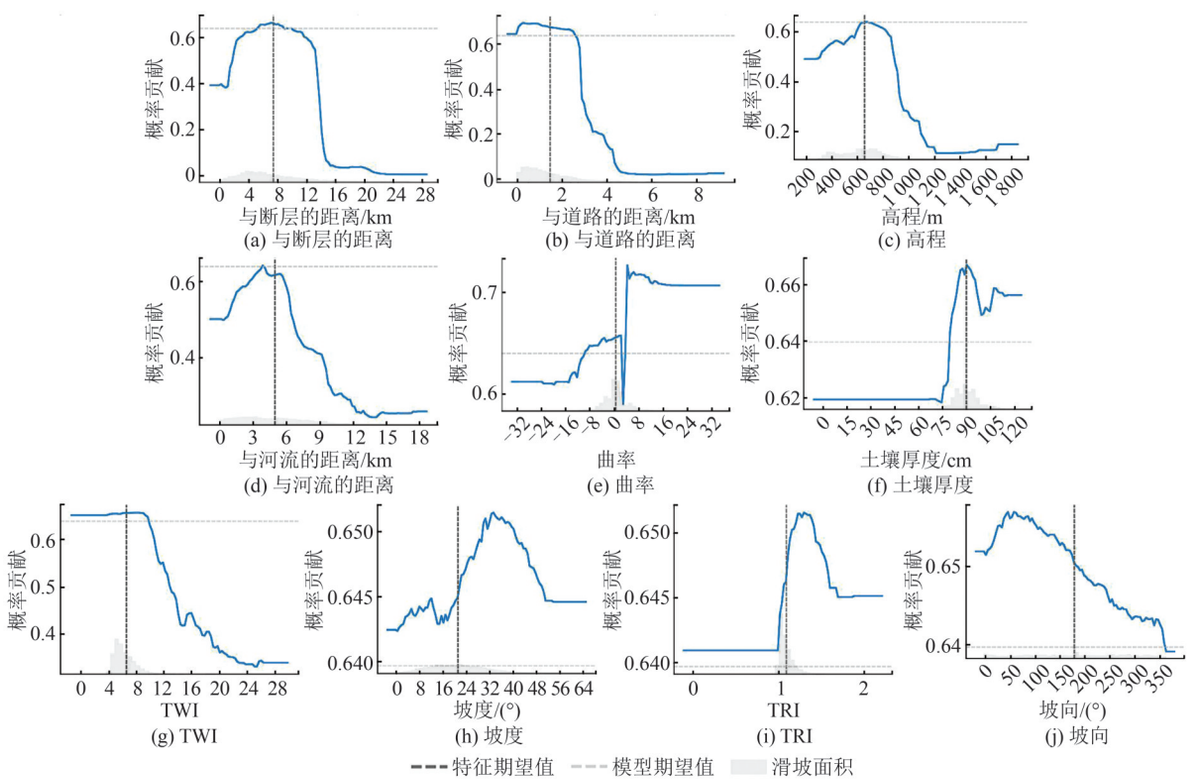


图 17　资兴市花岗岩区域滑坡孕灾因子部分依赖图

Fig. 17　Partial Dependence Plot of Landslide Hazard-Inducing Factors in the Granite Area of Zixing City

从贡献率的变化来看,坡度、坡向、TRI 和土壤厚度这 4 个孕灾环境因子的变化对贡献率的影响不明显(其区间范围小于 1%),因此不予进一步分析。TWI 和与道路的距离两个孕灾环境因子与滑坡贡献率整体上呈负相关关系,表明地形汇水区域和靠近道路的区域,TWI 及与道路的距离是影响滑坡发生的主要因素。高程、与河流的距离以及与断层的距离这 3 个孕灾环境因子在某些取值范围内表现出明显的临界点。例如,在高程 400～800 m、与河流的距离为 6～9 km、与断层的距离约为 3～6 km 的花岗岩区域,通常为台风暴雨作用下滑坡高易发区域。

对于砂岩区域,台风“格美”诱发滑坡的主要影响因子是与河流的距离,其次依次为与断层的距离、高程、与道路的距离、TRI、坡度、土壤厚度、坡向、曲率和 TWI(图 18)。与花岗岩区不同,资兴市砂岩区台风“格美”诱发滑坡受河流影响最为显著。对于资兴市的砂岩,其地质年代主要为

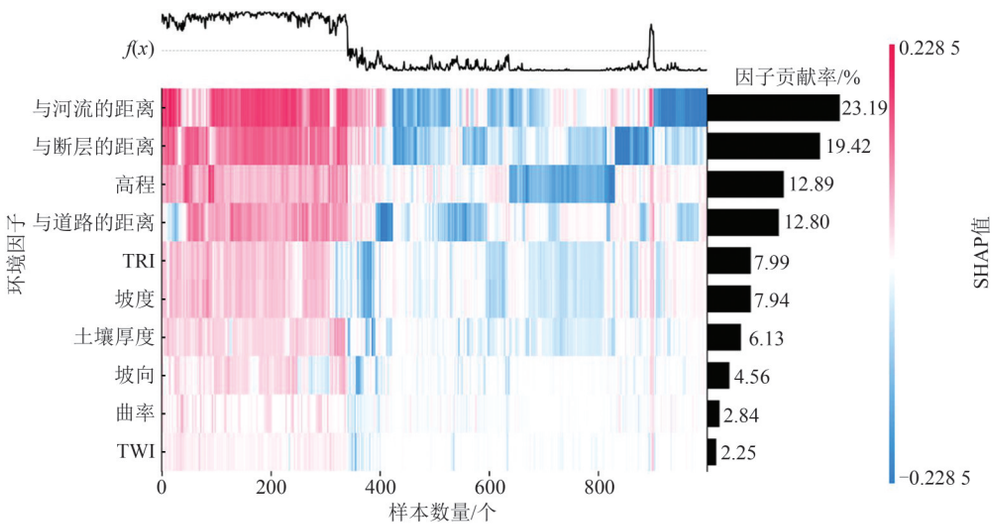


图18 资兴市砂岩区域滑坡孕灾因子的SHAP计算结果

Fig. 18 SHAP Calculation Results of Landslide Hazard-Inducing Factors in the Sandstone Area of Zixing City

寒武纪和震旦纪[32],通常还夹有板岩、砂质板岩等浅变质岩。这些浅变质岩层面摩擦系数小,当顺层斜坡岩层(或断层)倾角小于坡度时,易形成滑坡。此外,长期区域构造活动促进了砂岩的变质,而河流长期冲刷侵蚀进一步加剧了这些浅变质岩的改造和风化[33]。同时,显著的高程变化加剧了雨水对地形的侵蚀与切割作用。风化后的松散土体本身强度较低、渗透性好,雨水入渗后坡体自重增加、强度降低,使得这些浅变质岩边坡在强降雨作用下易发生滑坡。

与花岗岩区相比,砂岩区域滑坡孕灾因子的贡献率变化较小,表明砂岩区域滑坡孕灾因子的贡献较为均衡(图19)。砂岩区域的一些因子的高贡献率临界点较花岗岩区域更为明显,这意味着在砂岩区,台风诱发滑坡更易受到孕灾因子突变的控制。对于与河流的距离以及与断层的距离,滑坡概率随着距离增大均呈先增加、后减少的趋势,特别是在与河流的距离5~12 km、与断层的距离6~16 km的区域滑坡概率最大。此外,高程、TRI和坡度对滑坡的概率贡献均呈正相关关系,随着高程、TRI和坡度的增加,滑坡概率显著增加,然后趋于稳定,在高程大于300 m、TRI大于1.1以及坡度大于21°时滑坡概率最大;滑坡概率与道路的距离呈负相关关系,当与道路的距离小于2 km时,滑坡概率最大,表明人类工程活动的影响显著。

5 结 语

2024年7月下旬,湖南省资兴市受台风"格美"影响突发极端降雨天气,在资兴市诱发大量山体滑坡,造成严重损失。本文结合YOLOv8深度学习模型和Planet影像对此次台风诱发滑坡进行了智能识别,利用统计学方法和可解释性机器学习建模对滑坡的发育分布规律和主控因素进行了分析,主要结果如下:

1)基于深度学习模型YOLOv8和人工校核对资兴市台风"格美"诱发滑坡进行解译,构建了此次台风暴雨诱发的滑坡数据库。结果显示,台风"格美"在约2 746.79 km^2的资兴市范围内共触发滑坡约16 120处,总面积达到32.16 km^2。

2)台风"格美"诱发的滑坡面积区间主要为5×10^2~5×10^3 m^2,集中分布于资兴市东部山区,最大点密度达129个/km^2,群发性效应显著。统计分析显示,台风"格美"诱发的滑坡主要集中发育在高程200~600 m、坡度20°~30°的斜坡上。此外,台风"格美"诱发的滑坡受地质条件显著控制,其中63.37%的滑坡分布在花岗岩区域,29.30%分布在砂岩及其浅变质岩区域。

3)利用随机森林模型对台风"格美"诱发的资兴市滑坡进行了易发性建模,并基于SHAP可解释性分析研究了各孕灾环境因子尤其是地质条件对滑坡形成的控制作用。结果显示,地层岩性是控制资兴市台风"格美"诱发滑坡形成的主要因素。此外,对于不同岩性区域,控制滑坡的孕灾环境因子的重要性存在差异。在花岗岩区域,断层是控制滑坡的最主要因素,同时人类活动也对该区域滑坡的形成具有重要贡献;而在砂岩区域,河流冲刷侵蚀是控制滑坡形成最主要的因素。

随着全球气候变化,极端气候事件将呈现频发、广发、强发、并发的趋势,东南沿海丘陵山区

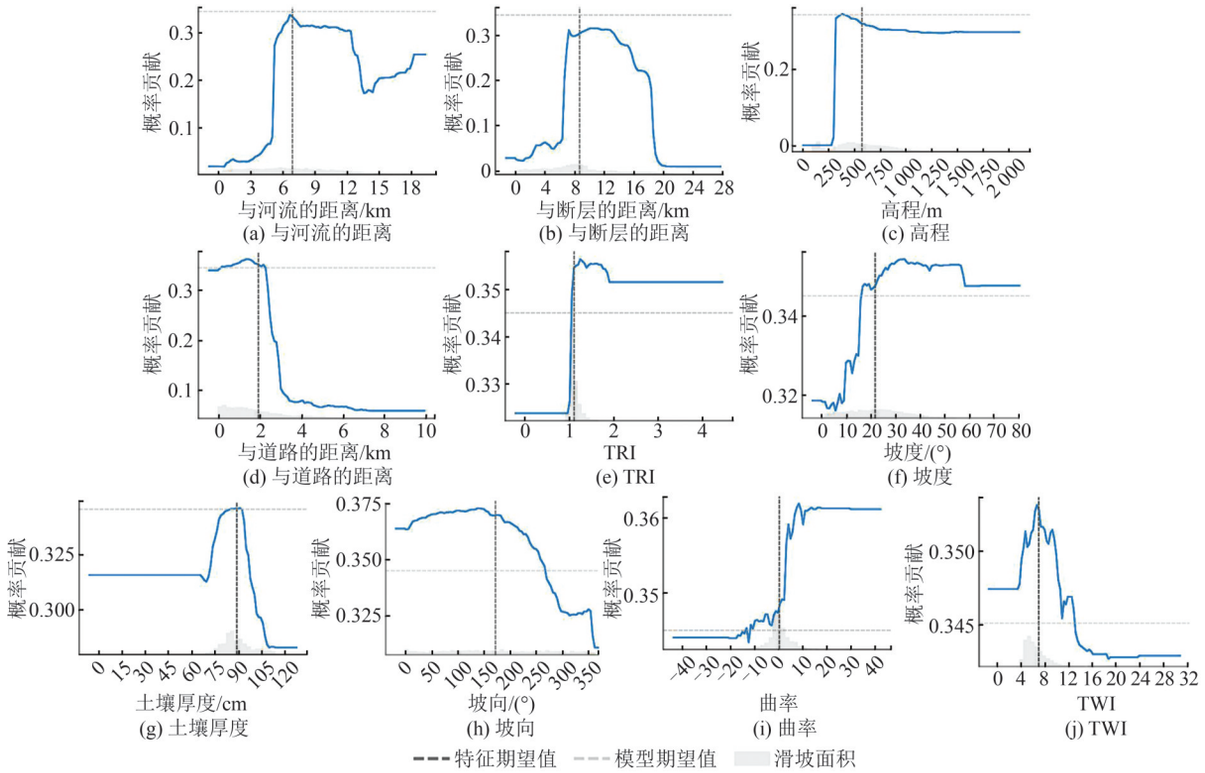


图 19　资兴市砂岩区域滑坡孕灾因子部分依赖图

Fig. 19　Partial Dependence Plot of Landslide Hazard-Inducing Factors in the Sandstone Area of Zixing City

滑坡风险将进一步增加,提前识别滑坡易发区域与掌握滑坡形成条件对于灾害风险超前防控具有重要意义。本文以台风“格美”极端降雨诱发群发性滑坡为例,通过机器学习与人工校核快速构建了滑坡数据库,揭示了滑坡发育分布特征,可为快速了解此次滑坡事件提供基础数据支撑。此外,基于可解释性机器学习的易发性建模,不仅可以快速评估广域滑坡易发性分区,服务于区域滑坡风险区划,为灾后重建提前规避滑坡高易发区,还可以揭示滑坡形成的孕灾环境条件,明确滑坡形成的主控因子及其控制作用,提升类似滑坡隐患排查的精准度和高效性。

参　考　文　献

[1] 梁可庭, 刘雨菲, 罗徽. 共筑抗洪救灾坚固防线[N]. 湖南日报, 2024-07-29.
LIANG Keting, LIU Yufei, LUO Hui. Building a Solid Defense Line Together for Flood Relief [N]. Hunan Daily, 2024-07-29.

[2] 许强. 对地质灾害隐患早期识别相关问题的认识与思考[J]. 武汉大学学报(信息科学版), 2020, 45(11): 1651-1659.
XU Qiang. Understanding and Consideration of Related Issues in Early Identification of Potential Geohazards[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1651-1659.

[3] PRAKASH N, MANCONI A, LOEW S. Mapping Landslides on EO Data: Performance of Deep Learning Models vs. Traditional Machine Learning Models[J]. *Remote Sensing*, 2020, 12(3): 346.

[4] 许强, 徐繁树, 蒲川豪, 等. 2024年4月广东韶关江湾镇极端降雨诱发群发性滑坡初步分析[J]. 武汉大学学报(信息科学版), 2024, 49(8): 1264-1274.
XU Qiang, XU Fanshu, PU Chuanhao, et al. Preliminary Analysis of Extreme Rainfall-Induced Cluster Landslides in Jiangwan Township, Shaoguan, Guangdong, April 2024[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(8): 1264-1274.

[5] KORNEJADY A, OWNEGH M, BAHREMAND A. Landslide Susceptibility Assessment Using Maximum Entropy Model with Two Different Data Sampling Methods[J]. *Catena*, 2017, 152: 144-162.

[6] 窦杰, 向子林, 许强, 等. 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, 2023, 48(5): 1657-1674.
DOU Jie, XIANG Zilin, XU Qiang, et al. Application and Development Trend of Machine Learning in Landslide Intelligent Disaster Prevention and Mitigation[J]. *Earth Science*, 2023, 48(5): 1657-1674.

[7] GAUR M, FALDU K, SHETH A. Semantics of

the Black-Box: Can Knowledge Graphs Help Make Deep Learning Systems more Interpretable and Explainable?[J]. *IEEE Internet Computing*, 2021, 25(1): 51-59.

[8] 马朔, 李钊, 赵军. 基于CatBoost用信预测模型的TreeSHAP解释性研究[J]. 计算机系统应用, 2023, 32(3): 338-344.
MA Shuo, LI Zhao, ZHAO Jun. Research on Interpretative TreeSHAP Based on CatBoost's Credit Utilization Prediction Model[J]. *Computer Systems & Applications*, 2023, 32(3): 338-344.

[9] 聂卉, 吴晓燕. 结合梯度提升树算法与可解释机器学习模型SHAP的抑郁症影响因素研究[J]. 数据分析与知识发现, 2024, 8(3): 41-52.
NIE Hui, WU Xiaoyan. Detecting Depression Factors with Gradient Boosting Tree and Explainable Machine Learning Model SHAP[J]. *Data Analysis and Knowledge Discovery*, 2024, 8(3): 41-52.

[10] 陈伟, 冷谦, 钟丽华, 等. 郴州市2016—2022年地质灾害及致灾降雨特征分析[J]. 黑龙江环境通报, 2023, 36(7): 14-16.
CHEN Wei, LENG Qian, ZHONG Lihua, et al. Analysis of Geological Hazard Characteristics and Causative Rainfall in Chenzhou from 2016 to 2022[J]. *Heilongjiang Environmental Journal*, 2023, 36(7): 14-16.

[11] LUNDBERG S M, ERION G, CHEN H, et al. From Local Explanations to Global Understanding with Explainable AI for Trees[J]. *Nature Machine Intelligence*, 2020, 2(1): 56-67.

[12] PAPAGEORGIOU D, TOPOUZELIS K. Experimental Observations of Marginally Detectable Floating Plastic Targets in Sentinel-2 and Planet Super Dove Imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 134: 104245.

[13] BHUSHAN S, SHEAN D, ALEXANDROV O, et al. Automated Digital Elevation Model (DEM) Generation from Very-High-Resolution Planet SkySat Triplet Stereo and Video Imagery[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 173: 151-165.

[14] HOU H Y, CHEN M X, TIE Y B, et al. A Universal Landslide Detection Method in Optical Remote Sensing Images Based on Improved YOLOX[J]. *Remote Sensing*, 2022, 14(19): 4939.

[15] TERVEN J, CÓRDOVA-ESPARZA D M, ROMERO-GONZÁLEZ J A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS[J]. *Machine Learning and Knowledge Extraction*, 2023, 5(4): 1680-1716.

[16] 魏林森, 丁宏伟, 王婷, 等. 降水对陇西黄土滑坡的诱发作用及时空影响分析[J]. 冰川冻土, 2017, 39(3): 609-615.
WEI Linsen, DING Hongwei, WANG Ting, et al. Loess Landslide in Longxi of Gansu Province: Precipitation Inducted Function and Space-Time Effect[J]. *Journal of Glaciology and Geocryology*, 2017, 39(3): 609-615.

[17] WANG G L, LI T L, XING X L, et al. Research on Loess Flow-Slides Induced by Rainfall in July 2013 in Yan'an, NW China[J]. *Environmental Earth Sciences*, 2015, 73(12): 7933-7944.

[18] 巨袁臻, 许强, 金时超, 等. 使用深度学习方法实现黄土滑坡自动识别[J]. 武汉大学学报(信息科学版), 2020, 45(11): 1747-1755.
JU Yuanzhen, XU Qiang, JIN Shichao, et al. Automatic Object Detection of Loess Landslide Based on Deep Learning[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1747-1755.

[19] 许强, 汤明高, 徐开祥, 等. 滑坡时空演化规律及预警预报研究[J]. 岩石力学与工程学报, 2008, 27(6): 1104-1112.
XU Qiang, TANG Minggao, XU Kaixiang, et al. Research on Space-Time Evolution Laws and Early Warning-Prediction of Landslides[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2008, 27(6): 1104-1112.

[20] 黄润秋, 李为乐. "5·12"汶川大地震触发地质灾害的发育分布规律研究[J]. 岩石力学与工程学报, 2008, 27(12): 2585-2592.
HUANG Runqiu, LI Weile. Research on Development and Distribution Rules of Geohazards Induced by Wenchuan Earthquake on 12th May, 2008[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2008, 27(12): 2585-2592.

[21] MUKUL M, MUKUL M. Uncertainties in Digital Elevation Models from Global Advanced Land Observing Satellite (ALOS) Digital Topography Data in the Indian Subcontinent[J]. *Journal of Earth System Science*, 2021, 130(1): 51.

[22] LIU F, WU H Y, ZHAO Y G, et al. Mapping High Resolution National Soil Information Grids of China[J]. *Science Bulletin*, 2022, 67(3): 328-340.

[23] LIU F, ZHANG G L, SONG X D, et al. High-Resolution and Three-Dimensional Mapping of Soil Texture of China[J]. *Geoderma*, 2020, 361: 114061.

[24] 叶天竺, 黄崇轲, 邓志奇. 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, 2017, 44(A1): 19-24.
YE Tianzhu, HUANG Chongke, DENG Zhiqi. Spatial Database of 1∶ 2 500 000 Digital Geologic Map of People's Republic of China[J]. *Geology in China*, 2017, 44(A1): 19-24.

[25] BREIMAN L. Random Forests [J]. *Machine Learning*, 2001, 45(1): 5-32.

[26] 陈力, 丁雨淋, 朱庆, 等. 基于元学习的广域范围滑坡易发性小样本预测[J]. 武汉大学学报(信息科学版), 2024, 49(8): 1367-1376.
CHEN Li, DING Yulin, ZHU Qing, et al. Few-Shot Prediction of Landslide Susceptibility Based on Meta-Learning Paradigm[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(8): 1367-1376.

[27] SHAPLEY L S. A Value for N-Person Games [M]//KUHN H W, TUCKER A W. Contributions to the Theory of Games (AM-28), Volume II. Princeton: Princeton University Press, 1953.

[28] 宋静园, 刘洋, 董秀军, 等. “9·5”泸定地震人口密集区域地震诱发滑坡空间分布规律[J]. 地质科技通报, 2025, 44(5): 202-214.
SONG Jingyuan, LIU Yang, DONG Xiujun, et al. Spatial Distribution of Earthquake-Induced Landslide in Densely Populated Area of the Luding 9·5 Earthquake[J]. *Bulletin of Geological Science and Technology*, 2025, 44(5): 202-214.

[29] 范宣梅, 王欣, 戴岚欣, 等. 2022年Ms 6.8级泸定地震诱发地质灾害特征与空间分布规律研究[J]. 工程地质学报, 2022, 30(5): 1504-1516.
FAN Xuanmei, WANG Xin, DAI Lanxin, et al. Characteristics and Spatial Distribution Pattern of Ms 6.8 Luding Earthquake Occurred on September 5, 2022 [J]. *Journal of Engineering Geology*, 2022, 30(5): 1504-1516.

[30] 马丽芳. 中国地质图集[M]. 北京: 地质出版社, 2002.
MA Lifang. Geological Atlas of China[M]. Beijing: Geological Publishing House, 2002.

[31] 刘好正. 风化花岗岩工程特性与路基工程[J]. 路基工程, 2003(5): 41-46.
LIU Haozheng. Engineering Performance of Weathered Granite with Subgrade Engineering[J]. *Subgrade Engineering*, 2003(5): 41-46.

[32] 唐晓珊, 黄建中, 张纯臣. 华南地体北缘(湖南部分)前寒武纪地层[J]. 中国区域地质, 1994, 13(4): 303-310.
TANG Xiaoshan, HUANG Jianzhong, ZHANG Chunchen. The Precamerian on the Northern Margin of the South China Terrane (Hunan Part)[J]. *Geological Bulletin of China*, 1994, 13(4): 303-310.

[33] BUCHER K. Metamorphism of Quartzo-Feldspathic Rocks [M]//BUCHER K Petrogenesis of Metamorphic Rocks. Cham: Springer International Publishing, 2023.