



引文格式: 曹嘉一弘, 张立舟, 何德平, 等. 基于集成学习模型的县域地震滑坡易发性研究[J]. 西北地质, 2026, 59(4): 155–167. DOI: 10.12401/j.nwg.2025109

Citation: CAOJIA Yihong, ZHANG Lizhou, HE Deping, et al. Research on County-Level Earthquake-Induced Landslide Susceptibility Mapping Based on Ensemble Learning Models[J]. Northwestern Geology, 2026, 59(4): 155–167. DOI: 10.12401/j.nwg.2025109

基于集成学习模型的县域地震滑坡易发性研究

曹嘉一弘^{1,2}, 张立舟^{1,3,*}, 何德平¹, 白德贵¹, 岳仁宾¹

(1. 重庆市测绘科学技术研究院, 重庆 401121; 2. 自然资源部智能城市时空信息与装备工程技术创新中心, 重庆 401121;
3. 重庆交通大学, 重庆 400074)

摘要: 在县域地震滑坡易发性建模领域, 对集成学习模型的比较分析研究尚显不足。本研究以泸定县为例, 基于历史记录、遥感数据及现场调研收集了 502 个滑坡事件的详细信息, 构建了样本数据库。选定了包括数字高程模型 (DEM)、坡度、坡向、剖面曲率、平面曲率、地形位置指数、岩性、与道路、断层、河流及震源距离和土地利用在内的 12 个关键影响因素。通过对这些因素进行共线性检测后, 采用贝叶斯优化方法优化了 AdaBoost、GBDT、XGBoost、LightGBM 和 CatBoost 等集成学习模型, 进而构建了滑坡易发性评估体系。通过 ROC 曲线和频率比值对比评估了各模型的准确率和预测精度。研究结果显示, 经贝叶斯优化后, 所有模型性能均得到显著提升, 其中 BO-GBDT 模型的 AUC 值提高了 7.4%。频率比值分析进一步表明, BO-XGBoost 模型在高易发性级别的识别能力最强, 频率比值达到 13.73, 表现出其优越的风险区识别能力。尽管 BO-GBDT 在 AUC 值上略显优势 (0.974), 但其在高易发性级别的识别上频率比值仅为 10.14。因此, 选择的 BO-XGBoost 模型揭示了高易发区主要集中在大渡河沿岸及其附近的城镇和交通线路区, 而东部山区的滑坡易发性相对较低。研究成果为未来研究和防灾减灾工作提供了重要的指导意见。

关键词: 滑坡易发性制图; 地震滑坡; 集成学习模型; 泸定县

中图分类号: P642.22

文献标志码: A

文章编号: 1009-6248(2026)04-0155-13

Research on County-Level Earthquake-Induced Landslide Susceptibility Mapping Based on Ensemble Learning Models

CAOJIA Yihong^{1,2}, ZHANG Lizhou^{1,3,*}, HE Deping¹, BAI Degui¹, YUE Renbin¹

(1. Chongqing Institute of Surveying and Mapping Science and Technology, Chongqing 401121, China; 2. Technology Innovation Center for Spatio-temporal Information and Equipment of Intelligent City, Ministry of Natural Resources, Chongqing 401121, China;
3. Chongqing Jiaotong University, Chongqing 400074, China)

收稿日期: 2024-06-17; 修回日期: 2025-06-09; 责任编辑: 曹佰迪

基金项目: 重庆市技术创新与应用发展面上项目 (CSTB2022TIAD-GPX0046), 重庆市建设科技计划项目 (城科字 2023 第 7-7 号), 国家电网重庆市电力公司科技项目 (522-522096250003) 联合资助。

作者简介: 曹嘉一弘 (1988-), 女, 高级工程师, 从事岩土工程勘察和滑坡灾害风险评估工作。E-mail: Caojiayihong@163.com。

* 通讯作者: 张立舟 (1989-), 男, 博士, 正高级工程师, 从事岩土工程测试和滑坡风险评估。E-mail: 28745035@qq.com。

© Editorial Office of *Northwestern Geology*. OA under CC BY-NC-ND

Abstract: In the field of modeling the susceptibility of county-level earthquake-induced landslides, comparative analysis research on ensemble learning models is still insufficient. This study takes Luding County as an example, where detailed information on 502 landslide events was collected based on historical records, remote sensing data, and field surveys to construct a sample database. Twelve key influencing factors were selected, including digital elevation model (DEM), slope, aspect, profile curvature, plan curvature, topographic position index, lithology, and the distances to roads, faults, rivers, and seismic sources, as well as land use. After conducting collinearity tests on these factors, the Bayesian optimization method was used to optimize ensemble learning models such as AdaBoost, GBDT, XGBoost, LightGBM, and CatBoost, thereby constructing a landslide susceptibility assessment system. The accuracy and predictive precision of each model were evaluated through ROC curves and frequency ratio comparison. The results show that after Bayesian optimization, the performance of all models was significantly improved, with the BO-GBDT model's AUC value increasing by 7.4%. Frequency ratio analysis further indicated that the BO-XGBoost model had the strongest identification capability at high susceptibility levels, with a frequency ratio of 13.73, demonstrating its superior risk area identification capability. Although the BO-GBDT model had a slight advantage in AUC value (0.974), its frequency ratio at high susceptibility levels was only 10.14. Therefore, the selected BO-XGBoost model reveals that high-susceptibility areas are mainly concentrated along the Dadu River and its nearby towns and transportation routes, while the landslide susceptibility in the eastern mountainous area is relatively low, providing important guidance for future research and disaster prevention and mitigation efforts.

Keywords: landslide susceptibility mapping; earthquake-induced landslides; ensemble learning models; Luding county

地震滑坡作为地震活动触发的一种重大自然灾害,已在全球众多地区对社会经济与人类安全构成了严重影响(王运生等, 2022)。特别是在中国四川这一地震频发地区,滑坡和泥石流事件频繁发生。以 2008 年四川汶川地震为例,该事件触发的滑坡导致了重大的人员伤亡和财产损失。2022 年 9 月,四川省甘孜州泸定县发生的 Mw 6.6 级地震,震源深度约 16 km,最高烈度达到九度,同样造成了多人伤亡(刘甲美等, 2022; 韩炳权等, 2023)。因此,地震滑坡易发性分析显得尤为重要。这不仅有助于揭示滑坡发生的条件与机制,而且对于预测未来滑坡事件、制订有效的减灾策略和安全土地利用规划至关重要。尽管在地震滑坡易发性分析方面已取得一定成就,但当前研究仍受限于模型精度的局限性以及区域适应性不足等挑战。为了解决这些问题,持续进行高精度的易发性评估研究势在必行,以填补现有研究的空白,并为地震滑坡的预防与减轻提供科学依据。

滑坡易发性建模是用于预测特定区域滑坡发生概率的关键方法,它依据历史滑坡数据预测未来潜在的滑坡发生区域(Dahal et al., 2023; 张茂省等, 2026)。目前,这一建模领域主要涵盖统计模型、物理模型以

及机器学习模型 3 类模型(Reichenbach et al., 2018)。统计模型包括逻辑回归、信息量和层次分析法等,主要依靠主观定性来评价易发性。物理模型基于对滑坡物理过程的理解,如土壤力学、水文地质学和地震动力学等,来模拟滑坡的触发机制。这类模型虽然能够精确模拟特定环境条件下的地质体稳定性,但由于需要进行复杂计算,通常不适用于大范围的易发性评估。与之相比,机器学习模型凭借处理大数据能力和学习数据中复杂非线性关系的优势,已被广泛应用于滑坡易发性评估。例如,Goetz et al.(2015)采用支持向量机模型评估了下奥地利州滑坡易发性的分区情况。Huang et al.(2022)采用决策树模型评估了滑坡易发性评价的区域优化策略。Jin et al.(2022)在青海盐湖区沉降空间预测研究中评估了人工神经网络模型的适用性。与此同时,部分学者已经开始探索这些模型在地震滑坡的应用。张玘恺等(2020)耦合多个模型地对九寨沟县范围内滑坡灾害易发性评价。罗路广等(2021)探究了地震滑坡影响因子选取策略。吴雨辰等(2021)采用粗糙集-BP 神经网络模型对北海道 IBURI 地区的地震滑坡易发性进行评价。尽管滑坡易发性建模在滑坡风险评估和管理中发挥着重要作用,

但目前在地震滑坡易发性建模方面的研究相对较少,并且对于模型使用研究探索较少。

集成模型通过组合多个学习器(通常是决策树)来提高预测性能,其核心思想是通过集成多个较弱的模型来构建一个更强大、更稳健的预测模型。这种方法能够有效地减少过拟合,提高模型的泛化能力。如随机森林(Akinci et al., 2021)、XGBoost(Emrehan et al., 2020)或 CatBoost(曾韬睿等, 2024)等。在滑坡易发性建模中,集成模型由于其优越的性能和灵活性,已经成为一种越来越受欢迎的选择。它们能够处理大量的、高维的数据集,同时自动捕捉到数据中的复杂非线性关系和交互作用,这对于分析地形、地质和气候等多种因素对滑坡易发性的综合影响至关重要。例如,仇文岗等(2022)基于随机森林模型计算了基于水系分区的滑坡易发性分布。Zeng et al.(2023)对比了多种集成模型的使用效果,探索集成学习的应用框架。在当前地质滑坡易发性研究中,尽管机器学习和统计模型已被广泛采用,但集成模型的应用及其优化策略的深入探索仍然不足。因此,本研究选取地震频发的泸定县作为案例区域,整理了滑坡清单和12个关键影响因素的数据集。通过采用贝叶斯优化技术,笔者对比分析了 AdaBoost、GBDT、XGBoost、Light-

GBM 和 CatBoost 等多种集成学习模型在地震引发的滑坡易发性评估中的效能,旨在拓展地震滑坡区域评估的理论基础,并为泸定县及类似地区的灾害预防与减缓提供科学依据。

1 研究区域概况

泸定县位于四川省甘孜藏族自治州,地理位置上属于青藏高原东南缘和川西北丘陵高原东南缘的过渡地带(图1)。这一地区特别因其独特的高山峡谷地貌而著称,地形复杂多变,地势陡峭。泸定县东侧邻接着邛崃山脉,海拔为3 000~4 500 m,而其西侧则是雄伟的大雪山山脉,海拔更是高达4 500~5 500 m,其中贡嘎山作为主峰,海拔超过7 000 m。大渡河穿行于这两大山脉之间,从北向南流淌,创造出壮丽的河谷景观。泸定县境内的地形地貌特点为高山与深谷交错,河流在山谷间蜿蜒,形成了深切的曲流河谷。这些地貌特点不仅提供了丰富的水电资源,也造成了该区域在地震等自然灾害面前的脆弱性。泸定县的地质环境及其地形地貌的特殊性,使其成为研究地质灾害,尤其是地震和滑坡灾害的重要区域。2022年9月5日,泸定发生了6.8级地震,震中位于甘孜藏族自治




图1 研究区地理位置图

Fig. 1 Location of the study area


州泸定县磨西镇,靠近青藏高原东南缘的鲜水河断裂带南东段和磨西断裂附近。这个地区是巴颜喀拉块体与川滇块体之间地走滑活动边界,同时与龙门山断裂带和安宁河断裂带交汇,构成了川西地区的“Y字形”断裂带。鲜水河断裂带是中国最活跃的断裂带之一,该断裂带附近自1725年以来发生了多次强烈的地震活动,包括14次震级为Ms 6.0~Ms 6.9的地震和8次震级大于Ms 7.0的地震。由于这些频繁的地震活动,泸定县及其研究区域诱发了多期地震滑坡灾害。地震波的强烈振动直接导致了地质和地形条件本就脆弱的斜坡失稳。这些地震滑坡灾害的发生不仅破坏了自然景观,也严重威胁了人类生命安全和基础设施。道路、桥梁和电力设施的破坏、交通和电力供应的中断严重影响了当地社区的正常生活和经济活动。此外,滑坡还可能导致河流堵塞,形成堰塞湖,增加洪水和次生灾害的风险。

2 数据及模型

2.1 滑坡清单及影响因素

滑坡清单的精准制定对滑坡易发性建模的科学性至关重要,它提供了关键的地质事件记录,有助于

研究人员解析滑坡发生的规律与频次,进而评估未来滑坡风险,并为构建滑坡预警系统打下坚实的科学基础(常志璐等, 2022)。此外,一个高质量的滑坡事件库能够为滑坡预测模型的训练与验证提供支持,确保模型能够真实地映射和模拟现实世界的复杂性(刘谢攀等, 2022)。鲜水河断裂带附近,特别是泸定县地区,坐落于青藏高原东南边缘和四川盆地的接合部,以其错综复杂的高山峡谷地形而知名。这种地质背景使该地区极易在地震作用下引发滑坡等一系列地质灾害。特别是在2022年9月5日泸定发生的6.8级强震之后,为了全面评估和理解地震诱发的滑坡灾害,本研究结合谷歌历史影像与政府部门提供的数据,详细编制了泸定县的滑坡清单(Zeng et al., 2023)。通过分析2021年12月和2022年12月期间的卫星影像(图1),笔者精确识别并记录了502处滑坡的确切位置与规模。泸定地震引起的滑坡主要呈现为崩塌、落石和浅层滑坡,偶有基岩平面滑动和土体圆弧滑动的现象(邓建辉等, 2024)。滑坡的平均面积约为56 942.73 m²,最大滑坡面积高达726 056.73 m²,而最小的仅为530.61 m²(图2)。浅层滑坡在规模上存在广泛的分布范围,既有小规模局部滑动,也有能造成重大影响的大规模灾害事件。崩塌的平均面积约为2 000 m²,



a. 滑坡面积分布; b. 浅层滑坡面积分布; c. 崩塌面积分布; d. 落石面积分布

图2 滑坡面积频率分布

Fig. 2 Frequency distribution of landslide areas

通常具有突发性强、破坏力集中的特点,多发生在陡峭的岩质边坡或松散堆积物区域。落石灾害其规模通常较小,但发生频率较高,多由边坡表层岩体破碎、风化作用或外力扰动引发,具有分布范围广、随机性强的特点。

在滑坡易发性评估中,关键影响因素的选取是分析的基石。文中综合考虑了地形、地质以及环境条件,在广泛收集区域数据和相关文献研究的基础上(林齐根等, 2017; 罗路广, 2021; 李永威等, 2023),最终确定了包括数字高程模型(DEM)、坡度、坡向、剖面曲率、平面曲率、地形位置指数(TPI)、岩性、与道路、断层、河流以及震源的距离和土地利用等 12 个静态

因素作为模型输入变量。为了形象展现这些因素在滑坡发生中的作用,利用 ArcGIS 10.6 软件制作了反映滑坡影响因素分布的详细图示(图 3)。其中,坡度、坡向、平面曲率、剖面曲率和 TPI 是直接分率为 30 m 的 DEM 数据中提取得到。在地震发生时,地形的坡度、方向以及高程变化都会影响地震波的传播,进而影响地面的稳定性。例如,地形的陡峭区域在地震震动作用下更容易发生岩土体的松动和滑动,从而形成滑坡。此外,DEM 还可以帮助识别地形的结构特征,如山脊、谷底和其他地形线索,这些特征可能是滑坡发生的关键区域。

岩性数据是从比例尺为 1 : 200 000 的地质图中




图3 影响因子

Fig. 3 Influencing factors

提取得到,这些地质图详细记录了不同地区的岩石类型和分布情况,为识别滑坡潜在地质条件提供了基础信息。而与道路、断层、河流以及震源的距离数据,则是通过 ArcGIS 10.6 软件中的欧式距离工具获得的。此外,土地利用数据来源于中国科学院地理科学与资源研究所的资源和环境数据云平台(<http://www.resdc.cn>)。该平台提供了高质量的土地利用数据,这些数据反映了不同地区土地覆盖类型的分布,包括城市建筑区、农田、森林、草地、雪地等。

为了统一分辨率,所有影响因子被转换为 60 m×60 m 的栅格数据集。滑坡敏感性制图被认为是一种二元分类,将输入数据分为滑坡和非滑坡两类。滑坡栅格赋值为“1”,非滑坡栅格赋值为“0”。研究区有 601 393 个栅格,其中滑坡栅格 7 952 个。在接下来的分析中, ArcGIS10.6 软件从非滑坡区域随机生成了 7 952 个非滑坡像素(王运生等, 2022)。样本数据集由滑坡数据和非滑坡数据组成,随机分为训练数据和验证数据两组,比例为 70 : 30。

2.2 AdaBoost 模型

AdaBoost 模型全称为自适应增强方法,是一种创新的集成学习模型(Freund, 1997)。AdaBoost 模型是首次提出了依据前序弱分类器的结果来自适应影响后续建模过程的机制,并在 Boosting 算法中首次引入了综合考虑所有弱分类器结果的输出策略。在滑坡易发性建模领域, AdaBoost 模型显示出其卓越的适用性。该模型通过集成多个弱分类器的预测结果,有效提高了对滑坡易发区域识别的准确性和稳定性,这对于预防和减轻滑坡灾害具有重要意义。AdaBoost 模型的算法实现过程相对简洁,不仅省去了繁杂的特征选择步骤,还能够自动调整各弱分类器之间的权重。然而,鉴于算法会对分类错误的样本进行加权处理,训练数据中的噪声或异常值可能会对模型的性能产生不利影响。

2.3 GBDT 模型

GBDT (Gradient Boosting Decision Tree)模型起源于 Boosting 决策树模型(Friedman, 2001)。该模型的核心原理是结合了多个决策树的预测结果来提高整体预测的准确性,它通过迭代的方式逐步建立决策树,每一棵新树的建立都是为了纠正前一棵树的预测误差。在 GBDT 模型中,每一次迭代都会产生一个新的决策树,该树专注于先前所有树在训练集上的残差,也就是实际观测值与当前模型预测值之间的差异。

通过梯度下降算法,模型会寻找到最佳的方式来减少残差,即找到使损失函数下降最快的方向。随着迭代次数的增加,组合模型将不断改进,减少训练数据上的预测误差。在滑坡易发性建模中,GBDT 模型应用广泛,它可以有效处理各种类型的数据,包括连续和分类变量,并能自动处理变量之间的非线性关系和相互作用。

2.4 XGBoost 模型

XGBoost (eXtreme Gradient Boosting)是一种基于梯度提升框架的高效且灵活的机器学习算法。该算法由 Chen(2016)年开发并发布,其设计初衷是为了优化已有的梯度提升方法。XGBoost 的核心原理是构建多个决策树,并利用梯度提升技术来优化模型。具体来说,它首先建立一个基础的决策树,然后不断添加新的树来纠正前一棵树的错误。每一步的树构建都是为了最小化损失函数,这个过程涉及计算梯度和使用它们来更新模型。XGBoost 的优点包括其高效的运算速度和性能,能够处理大规模数据;它还支持多种损失函数,适用于各类回归、分类和排序问题。此外, XGBoost 还提供了正则化功能,有助于减少模型过拟合,提高模型的泛化能力。

2.5 LightGBM 模型

LightGBM(Light Gradient Boosting Machine)是一种基于梯度提升的高效机器学习算法,由微软研究院的团队开发(Ke et al., 2017)。作为 XGBoost 的进一步优化和扩展, LightGBM 在处理大规模数据时展现出了卓越的速度和效率,特别是在内存使用和计算时间上有显著的优势。LightGBM 的核心特点在于它采用了基于直方图的决策树分裂算法。与传统的基于预排序的决策树算法相比,直方图算法在分裂节点时减少了计算量,因此大幅提高了运算效率。此外, LightGBM 引入了 Gradient-based One-Side Sampling (GOSS)和 Exclusive Feature Bundling (EFB)两种重要的优化策略。GOSS 有效地减少了在梯度提升过程中样本的数量,而不牺牲模型的准确性; EFB 则通过捆绑互斥特征来减少特征的维度,进一步提高了计算效率。

2.6 CatBoost 模型

CatBoost (Categorical Boosting)是一种先进的梯度提升算法,由俄罗斯的 Yandex 公司的研究团队开发(Prokhorenkova et al., 2018)。CatBoost 在处理分类特征 (Categorical Features)时特别有效,这也是其名称的由来。它被设计来自动处理分类数据,而无需进行

繁琐的预处理步骤,这一点与其他许多机器学习算法形成鲜明对比。CatBoost 的核心优势在于其创新的算法设计: ①采用了称为“Ordered Boosting”的技术,这种方法可以减少过拟合,提高模型的泛化能力;②在构建决策树时使用了一种特殊的“对称树”结构,这使得模型的计算更加高效;③引入了一种新的编码方式来处理分类特征,从而提高了模型在处理这类数据时的准确度和速度。

2.7 贝叶斯优化模型

贝叶斯优化是一种高效的全局优化方法,特别适用于优化计算代价高昂且无解析表达式的目标函数(Brochu et al., 2010)。它的核心原理是基于贝叶斯统计理论,通过构建目标函数的概率模型来引导搜索过程,从而有效地寻找到最优解。在实际应用中,贝叶斯优化通常使用高斯过程来建模未知的目标函数,通过观测到的数据更新对函数的认知,然后基于这一模型来预测下一个可能达到最优化目标的参数值。

在优化集成学习模型如 AdaBoost、XGBoost、LightGBM 和 CatBoost 等模型的超参数时,贝叶斯优化显示出其显著优势。这些集成模型通常包含多个超参数,如学习率、树的数量、树的深度等,这些参数的不同组合会显著影响模型的性能。传统的网格搜索或随机搜索方法在大参数空间中往往效率低下,而贝叶斯优化通过建立超参数与模型性能之间的概率模型,能够更智能和高效地指导搜索过程,快速定位到最优的参数组合。

2.8 模型验证

在本研究中,接收者操作特征曲线(ROC)和曲线下面积(AUC)被用于模型验证(仇文岗等, 2022)。ROC/AUC 是评估二分类模型性能的重要工具,尤其适用于衡量模型在不同阈值下的区分能力。ROC 曲线是一个二维图形,横轴表示假阳性率(False Positive Rate, FPR),纵轴表示真阳性率(True Positive Rate, TPR)。AUC 代表 ROC 曲线下的面积,其值介于 0~1。AUC 值越接近 1,表示模型的分类性能越好;AUC 值越接近 0.5,表示模型的分类性能不佳,相当于随机猜测。AUC 评分提供了一个单一的数值来综合评价模型在所有可能的分类阈值上的表现。

频率比法被用于分析滑坡易发性分区的可靠性。理论上,频率比值与易发性等级之间应存在正相关关系,即易发性等级越高,频率比值也应相应增大,从而指示该区域滑坡发生的可能性更大,其计算过程表

达为公式(1)。

$$FR = \frac{L_i/C_i}{L/C} \quad (1)$$

式中: L_i 表示第 i 级易发性等级中滑坡面积; C_i 表示第 i 级易发性等级面积; L 是滑坡总面积; C 代表整个研究区域的总面积。


3 结果

3.1 影响因子共线性分析

在开展机器学习滑坡易发性建模前,共线性分析对于提升模型精度、增强其解释力、预防过拟合以及提高计算效率发挥着至关重要的作用。当预测变量间存在高度相关性时,可能会引起模型估计的不稳定和准确性下降。因此,在本研究中,笔者利用方差膨胀因子(Variance Inflation Factor, VIF)对所选取的 12 个影响因子进行共线性问题的分析(黄发明等, 2020; 曾韬睿等, 2024)。VIF 值的高低直接反映了共线性的严重程度,通常情况下, VIF 值超过 10 便意味着存在显著的共线性。在剖面曲率与平面曲率、坡度与坡向间, VIF 值远超过 10 的阈值,这一结果表明这些因子间存在严重的共线性问题(图 4)。为缓解共线性的影响,笔者移除坡向和剖面曲率这两个高共线性因子,并对剩余因子的 VIF 值进行了重新计算。计算结果表明,剩余因子的共线性问题已得到有效缓解,其 VIF 值普遍降至较低水平。基于此,笔者选取了剩余的 10 个因子,用于进行滑坡易发性的建模。

3.2 ROC 曲线精度评价

在本节中,笔者系统地比较了 AdaBoost、GBDT、XGBoost、LightGBM 和 CatBoost 5 种集成学习模型在滑坡易发性预测任务上的性能。通过 ROC/AUC 分析了这些模型在超参数优化前后的表现。使用模型默认参数情况下 XGBoost 的预测精度最高(AUC 值为 0.963),紧随其后的是 CatBoost(AUC 值为 0.955)和 LightGBM(AUC 值为 0.963),而 GBDT(AUC 值为 0.907)和 AdaBoost(AUC 值为 0.868)的表现相对较弱(图 5a)。通过 Python 环境中的贝叶斯优化技术,笔者对各模型的超参数进行了调优,涉及超参数的名称、范围以及最优化结果的详细概述(表 1)。值得一提的是,AdaBoost 模型因其结构相对简单,仅对两个超参数进行了优化;而 GBDT 和 CatBoost 模型各优化了 6 个超参数, XGBoost 和 LightGBM 则分别优化了 7 个




a. VIF 值; b. 移除高 VIF 值

图4 因子共线性分析

Fig. 4 Factor collinearity analysis

超参数, 获取了最优超参数并生成 ROC 曲线(图 5b~图 5f)。具 AdaBoost 的最优决策树数量和学习率分别为 176 和 0.84, 其 AUC 值由 0.868 提升至 0.882, 增长了大约 1.6%。GBDT 模型在调整决策树数量、学习率和树的最大深度等超参数后, 其 AUC 值从 0.907 显著提升至 0.974, 增幅达到 7.4%。XGBoost 模型虽然只实现了微小的性能提升, 但其决策树数量和学习率等的最优化调整也使得 AUC 值从 0.963 增加至 0.968, 提升了约 0.52%。LightGBM 和 CatBoost 模型分别实现了约 1.7% 和 1.04% 的 AUC 值提升, 反映出经过超参数优化, 这些模型的预测性能均有所提高。

GBDT 模型在所有比较的模型中展现了最显著的性能提升, AUC 值提高了 7.4%, 证明了它在预测滑坡易发性任务上的卓越表现。这表明尽管 XGBoost、LightGBM 和 CatBoost 也经历了性能的提升, 但 GBDT 在特定数据集上可能更能有效捕捉特征关系和模式。这种差异可能来源于模型对数据特征的不同敏感度, 以及 GBDT 天然具备的、对当前研究数据集更优的适应性。GBDT 的优越表现并非仅因其结构复杂或先进, 而是超参数优化的过程、数据特征的匹配度、模型结构的适应性以及优化过程中的随机性等因素的综合影响所致。因此, 采用模型融合策略或许是解



a. 默认超参数的各个模型 ROC 曲线; b. 贝叶斯优化 AdaBoost 模型; c. 贝叶斯优化 GBDT 模型; d. 贝叶斯优化 XGBoost 模型;

e. 贝叶斯优化 LightGBM 模型; f. 贝叶斯优化 CatBoost 模型

图5 ROC 曲线

Fig. 5 ROC Curves

表 1 贝叶斯优化各个模型超参数范围及结果

Tab. 1 Bayesian optimization ranges and results for various model hyperparameters

模型名称	超参数名称	超参数范围	最优超参数
AdaBoost	决策树数量	[10, 200]	176
	学习率	(0.01, 1)	0.84
GBDT	决策树数量	[50, 300]	252
	学习率	(0.01, 1)	0.59
	树的最大深度	[3, 10]	9
	分裂内部节点所需的最小样本数	[2, 10]	9
	叶子节点所需的最小样本数	[1, 10]	5
XGBoost	决策树数量	[50, 300]	285
	学习率	(0.01, 1)	0.11
	树的最大深度	[3, 10]	8
	子节点权重之和的最小值	[1, 10]	2
	最小损失函数下降值	[0, 5]	0.029
	随机选取样本比例	(0.01, 1)	0.848
	随机选取特征比例	(0.01, 1)	0.971
LightGBM	决策树数量	[50, 300]	210
	学习率	(0.01, 1)	0.15
	树的最大深度	[1, 10]	9
	每棵树中叶子的最大数量	[20, 200]	156
	子节点权重之和的最小值	[1, 10]	1
	随机选取样本比例	(0.01, 1)	0.362
CatBoost	随机选取特征比例	(0.01, 1)	0.801
	决策树数量	[50, 300]	287
	学习率	(0.01, 1)	0.13
	树的最大深度	[4, 11]	9
	L2正则化	[1, 10]	1.25
	数值特征分箱的数目	[50, 255]	65
	随机选取样本比例	(0.01, 1)	0.7

决此类问题的最好方法(Reichenbach et al., 2018; 王运生等, 2022)。

3.3 栅格统计分析

对不同模型预测的滑坡易发性等级占比的统计分析(图 6), 易发性等级根据概率 $P(S)$ 分为低易发性 ($0 \leq P(S) < 5\%$)、中易发性 ($5\% \leq P(S) < 35\%$)、高易发性 ($35\% \leq P(S) < 75\%$) 以及极高易发性 ($75\% \leq P(S) \leq 100\%$) 4 个类别(王运生等, 2022)。在采用的样本数据集集中, 滑坡与非滑坡的比例为 1 : 1。分析结果显示, AdaBoost 模型的预测结果主要集中在 5%~75% 的区间内, 这表明其在确定滑坡易发性等级方面存在一定

的模糊性, 可能难以有效区分极低或极高易发性的滑坡区域, 进而影响预测精度。XGBoost 模型的占比最高, 达到 47.59%, 紧随其后的是 CatBoost(45.47%)、LightGBM(44.27%)和 GBDT(35.77%)。XGBoost 在极低易发性等级的预测中也表现最佳, 占比达到 35.02%, 这一结果暗示在默认参数设置下, XGBoost 在预测滑坡易发性方面具有较高的精度。

在应用贝叶斯优化策略后, AdaBoost 模型的预测结果更多集中于中易发性区间, 这一现象表明 AdaBoost 模型可能不最适合于滑坡易发性的精确建模。相比之下, GBDT 模型展现出最佳性能, 其在高易发




图6 未考虑优化策略模型在训练数据集中预测易发性分布(a)、贝叶斯优化模型易发性分布(b)

Fig. 6 (a) Susceptibility distribution predicted by models without considering optimization strategies in the training dataset, (b) susceptibility distribution of Bayesian-optimized models

性和极低易发性的占比分别为 50.96% 和 48.06%，显示出优越的区分能力。LightGBM 和 CatBoost 模型也表现良好，但在这两个极端易发性等级的区分上略逊于 GBDT。这些发现强调了超参数优化在提升模型性能方面的重要性，尤其是在处理具有复杂易发性分级的滑坡预测任务时。GBDT 模型的卓越表现说明了，即使在较为平衡的滑坡与非滑坡样本比例下，通过精细的超参数调优，笔者仍能显著提高模型对于滑坡易发性等级的预测精度和辨识能力。

全区栅格点的属性矩阵作为输入到搭建好的模型中，可以得出全区点易发性指数值及各个模型的易发性图(图 7)，优化策略减少了模型预测空间数据的不确定性，预测概率更加集中于非常低和高易发性分布区间。模型在未优化时多集中分布在低和中等易发性，优化后降低了不确定性，预测概率更为集中。未优化前 GBDT, XGBoost, LightGBM 和 CatBoost 对于高易发性区域的预测占比分别为 7.67%、6.32%、6.30% 和 5.80%。优化后占比分别为 9.72%、7.18%、7.61% 和 7.18%。笔者可以发现即使 XGBoost 的 AUC 值较 BO-XGBoost 的提升仅为 0.05，但是对于整个研究区预测占比的改变却有很大的提升。这些结果说明优化策略有效地降低了模型预测的不确定性，也说明了即使模型只有非常低的提升，但是对于整个研究的准确度提升是更大的。




图7 优化策略模型在全区数据集中预测易发性分布(a)、贝叶斯优化模型全区易发性分布(b)

Fig. 7 (a) Susceptibility distribution predicted by models with optimization strategies in the entire dataset, (b) susceptibility distribution of Bayesian-optimized models in the entire area

3.4 滑坡易发性制图

笔者使用优化后的模型开展全区域的滑坡易发性预测和制图。XGBoost, LightGBM 和 CatBoost 频率比呈较为均衡的增长趋势，GBDT 模型从低到中等易发性的增加较为缓慢(图 8)。XGBoost 模型在高易发性等级的频率比值最大，达到了 13.73，表明该模型可能在识别高风险区域方面具有较强的能力。尽管 GBDT 模型在整体分类性能上(AUC 值为 0.974)略胜一筹，但其在高易发性等级的频率比值为 10.14，相对较低。这表明 GBDT 模型虽然在整体预测性能上表现出色，但其对高风险区域的识别能力不如 XGBoost 模型。LightGBM 和 CatBoost 模型的频率比值分别为 12.79 和 13.48，表现出较为平衡的整体预测性能和空间分布识别能力。




图8 各模型频率比分布图

Fig. 8 Frequency ratio distribution for each model

最终获取的易发性分布图(图9)展现了各模型在空间分布上的易发性预测。明显地,GBDT模型在未经优化前展现出较高的不确定性,其预测的易发性区域在整个研究范围内广泛分布,包括低、中和高易发性等级。然而,经过优化的GBDT模型虽然在精度上有所提升,却出现了过拟合的问题,导致预测结果主要集中在极高和极低易发性区域,缺乏中间过渡。与此相反,XGBoost、LightGBM和CatBoost模型在经过优化后均有效降低了预测的不确定性,表现出更加准确和均衡的易发性分布。本研究分析了包含15,904条数据的数据集,并对比了贝叶斯优化在调整各模型超参数过程中的时间效率。结果表明,模型之间在优

化耗时上存在显著差异。AdaBoost的优化过程耗时208秒,而GBDT的优化时间最长,达到1 849s,远超其他模型。相较而言,XGBoost的优化仅需63s, CatBoost需144s,而LightGBM的超参数优化耗时仅21s,显著低于其他模型。尽管GBDT在优化后达到了较高的预测精度($AUC=0.974$),但其耗时却是LightGBM的88倍,XGBoost的29倍。这一差异在评估模型适用性时尤为重要。尽管精确度是模型评估的关键指标,但在需要快速迭代和部署的实际应用场景中,优化时间的长短也是一个不容忽视的因素。若在数据量更大的应用场景下,模型的运行时间可能会成倍增加,这一点在实际应用中尤为关键。




图9 滑坡易发性制图

Fig. 9 Landslide susceptibility mapping

综合考量精度与运行效率,XGBoost模型展现了在确保高精度同时具有时间效率的优势,能够更准确地描绘易发性分区的空间分布。这种平衡在模型选择时尤为重要,尤其是在大数据量的应用场景中。最终易发性分布图突显了滑坡高易发区域主要集中在大渡河沿岸及其附近的城镇和交通线路区域,而东部山区的滑坡易发性较低。然而,尽管东部高寒山区的居民较少,导致滑坡记录数据有限,该区域的雪崩和

泥石流事件仍不容忽视,指出了未来研究和防灾减灾工作的重点方向。

4 结论

(1) 泸定县的滑坡大多数面积小于 10 万 m^2 , 平均面积约为 $56\,942.73 \text{ m}^2$, 规模为 $530.61 \sim 726\,056.73 \text{ m}^2$ 不等。本研究构建了一个包含DEM、坡度、坡向、

剖面曲率、平面曲率、TPI、岩性以及道路、断层、河流和震源距离及土地利用等 12 个因子的影响因子数据集,易发性建模中移除了剖面曲率和坡向这两个高共线性因子。

(2)对比了 AdaBoost、GBDT、XGBoost、LightGBM 和 CatBoost 等 5 种主流集成学习模型在地震引发的滑坡易发性预测中的效能。在采用模型默认设置的情况下,XGBoost 以 0.963 的 AUC 值领先,表现出最优的预测精度,其次是 CatBoost(AUC=0.955)和 LightGBM(AUC=0.963),而 GBDT 和 AdaBoost 的性能相对较低。应用贝叶斯优化技术对模型超参数进行调整后,所有模型的预测性能都得到了显著提升。尤其是 GBDT 模型,经过超参数优化后,其 AUC 值显著增加了 7.4%。

(3) 栅格统计分析显示,未优化前 GBDT、XGBoost、LightGBM 和 CatBoost 在高易发性区域的预测占比分别为 7.67%、6.32%、6.30% 和 5.80%,优化后这一占比提升至 9.72%、7.18%、7.61% 和 7.18%。尽管 XGBoost 的 AUC 值提升较小(仅 0.05),但对整个研究区的预测准确度上带来显著的改善,证实了优化策略有效降低了预测的不确定性。

(4) 频率比分析结果显示 XGBoost 模型在高易发性级别的频率比值达到了 13.73,突显了其在识别高风险区域的卓越能力。虽然 GBDT 模型在总体预测性能上以 AUC 值 0.974 略占优势,但其在高易发性识别上的频率比值较小,仅为 10.14。滑坡高易发区域主要位于大渡河沿岸及其邻近的城镇和交通线路区域,而东部山区的滑坡易发性相对较低。研究成果对于指导未来的研究和灾害防治工作具有重要意义。

利益冲突声明(Conflict of Interests):

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

参考文献(References):

常志璐,黄发明,蒋水华,等.基于多尺度分割的斜坡单元划分及滑坡易发性研究[J].工程科学与技术,2023,55(1): 184-195.

CHANG Zhilu, HUANG Faming, JIANG Shuihua, et al. Slope Unit Extraction and Landslide Susceptibility Assessment Using Multi-Scale Segmentation Method[J]. Advanced Engineering Sci-

ences, 2023, 55(1): 184-195.

邓建辉,韦晓,戴仕贵,等.泸定地震诱发灾害特征分析[J].工程科学与技术,2024,56(1): 117-126.

DENG Jianhui, WEI Xiao, DAI Shigui, et al. Characterization of Triggered Disasters in the Luding Earthquake[J]. Advanced Engineering Sciences, 2024, 56(1): 117-126.

韩炳权,刘振江,博陈,等.2022 年泸定 Mw 6.6 地震 InSAR 同震形变与滑动分布[J].武汉大学学报(信息科学版),2023, 48(1): 36-46.

HAN Bingquan, LIU Zhenjiang, BO Chen, et al. Coseismic Deformation and Slip Distribution of the 2022 Luding Mw 6.6 Earthquake Revealed by InSAR Observations[J]. Geomatics and Information Science of Wuhan University, 2023, 48(1): 36-46.

黄发明,叶舟,姚池,等.滑坡易发性预测不确定性:环境因子不同属性区间划分和不同数据驱动模型的影响[J].地球科学,2020,45(12): 4535-4549.

HUANG Faming, YE Zhou, YAO Chi, et al. Uncertainties of Landslide Susceptibility Prediction: Different Attribute Interval Divisions of Environmental Factors and Different Data-Based Models[J]. Earth Science, 2020, 45(12): 4535-4549.

李永威,徐林荣,张亮亮,等.强震山区地震诱发滑坡发育规律与易发性评估[J].地球科学,2023,48(5): 1961-1976.

LI Yongwei, XU Linrong, ZHANG Liangliang, et al. Study on Development Patterns and Susceptibility Evaluation of Coseismic Landslides within Mountainous Regions Influenced by Strong Earthquakes[J]. Earth Science, 2023, 48(5): 1961-1976.

林齐根,刘燕仪,刘连友,等.支持向量机与 Newmark 模型结合的地震滑坡易发性评估研究[J].地球信息科学学报,2017, 19(12): 1623-1633.

LIN Qigen, LIU Yanyi, LIU Lianyou, et al. Earthquake-triggered Landslide Susceptibility Assessment Based on Support Vector Machine Combined with Newmark Displacement Model[J]. Journal of Geo-information Science, 2017, 19(12): 1623-1633.

刘甲美,王涛,杜建军,等.四川泸定 6.8 级地震诱发崩滑快速评估[J].水文地质工程地质,2022,50(2): 84-94.

LIU Jiami, WANG Tao, DU Jianjun, et al. Emergency rapid assessment of landslides induced by the Luding Ms 6.8 earthquake, Sichuan, China[J]. Hydrogeology & Engineering Geology, 2022, 50(2): 84-94.

刘谢攀,殷坤龙,肖常贵,等.基于 I-D-R 阈值模型的滑坡气象预警[J].地球科学,2022,47(3): 1-15.

LIU Xiepan, YIN Kunlong, XIAO Changgui, et al. Meteorological early warning of landslide based on I-D-R threshold model[J]. Earth Science, 2022, 47(3): 1-15.

罗路广,裴向军,崔圣华,等.九寨沟地震滑坡易发性评价因子组合选取研究[J].岩石力学与工程学报,2021,40(11): 2306-2319.

LUO Luguang, PEI Xiangjun, CUI Shenghua, et al. Combined selec-

- tion of susceptibility assessment factors for Jiuzhaigou earthquake-induced landslides[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(11): 2306–2319.
- 王运生, 苏毅, 冯卓, 等. 泸定韧性剪切带泸定段及其工程效应[J]. 地球科学, 2022, 47(3): 794–802.
- WANG Yunsheng, SU Yi, FENG Zhuo, et al. Luding Section of Luding Ductile Shear Zone and Its Engineering Effects[J]. Earth Science, 2022, 47(3): 794–802.
- 吴雨辰, 周晗旭, 车爱兰. 基于粗糙集-神经网络的IBURI地震滑坡易发性研究[J]. 岩石力学与工程学报, 2021, 40(6): 1226–1235.
- WU Yuchen, ZHOU Hanxu, CHE Ailan. Susceptibility of landslides caused by IBURI earthquake based on rough set-neural network[J]. Chinese Journal of Rock Mechanics and Engineering, 2021, 40(6): 1226–1235.
- 仇文岗, 何昱苇, 王鲁琦, 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[J]. 地球科学, 2022, 47(5): 1–18.
- ZHANG Wengang, HE Yuwei, WANG Luqi, et al. Machine Learning Solution for Landslide Susceptibility Based on Hydrographic Division: Case Study of Fengjie County in Chongqing[J]. Earth Science, 2022, 47(5): 1–18.
- 张玓恺, 凌斯祥, 李晓宁, 等. 九寨沟县滑坡灾害易发性快速评估模型对比研究[J]. 岩石力学与工程学报, 2020, 39(8): 1595–1610.
- ZHANG Qikai, LING Sixiang, LI Xiaoning, et al. Comparison of landslide susceptibility mapping rapid assessment models in Jiuzhaigou County, Sichuan province, China[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(8): 1595–1610.
- 张茂省, 郭柱国, 闫雨藤, 等. 基于大语言模型(LLMs)的地质灾害风险防控体系建设[J]. 中国地质, 2026, 53(1): 136–157.
- ZHANG Maosheng, GUO Zhuguo, YAN Yuteng, et al. Construction of the geological hazard risk mitigation and management system powered by Large Language Models (LLMs)[J]. Geology in China, 2026, 53(1): 136–157.
- 曾韬睿, 王林峰, 张俞, 等. 基于 CatBoost-SHAP 模型的滑坡易发性建模及可解释性[J]. 中国地质灾害与防治学报, 2024, 35(1): 1–14.
- ZENG Taorui, WANG Linfeng, ZHANG Yu, et al. Landslide susceptibility modeling and interpretability based on CatBoost-SHAP model[J]. The Chinese Journal of Geological Hazard and Control, 2024, 35(1): 1–14.
- Akinci H, Zeybek M. Comparing classical statistic and machine learning models in landslide susceptibility mapping in Ardahan (Artvin), Turkey[J]. Natural Hazards, 2021, 108(2): 1515–1543.
- Brochu E, Cora V M, De Freitas N. A tutorial on Bayesian optimization of expensive cost functions, with application to active user modeling and hierarchical reinforcement learning[J]. 2010, arXiv preprint, arXiv: 1012.2599.
- Chen T, Guestrin C. XGBoost: A Scalable Tree Boosting System[C]. New York, USA: Association for Computing Machinery: 2016.
- Dahal A, Lombardo L. Explainable artificial intelligence in geoscience: A glimpse into the future of landslide susceptibility modeling[J]. Computers & Geosciences, 2023, 176: 105364.
- Emrehan K S. Comparative Analysis of Gradient Boosting Algorithms for Landslide Susceptibility Mapping[J]. Geocarto International, 2020, 37(9): 2441–2465.
- Freund Y, Schapire R E. A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119–139.
- Friedman J H. Greedy function approximation: A gradient boosting machine[J]. Annals of Statistics, 2001, 29(5): 1189–1232.
- Goetz J N, Brenning A, Petschko H, et al. Evaluating machine learning and statistical prediction techniques for landslide susceptibility modeling[J]. Computers & Geosciences, 2015, 81: 1–11.
- Huang F, Yan J, Fan X, et al. Uncertainty pattern in landslide susceptibility prediction modelling: Effects of different landslide boundaries and spatial shape expressions[J]. Geoscience Frontiers, 2022, 13(2): 101317.
- Jin B, Yin K, Li Q, et al. Susceptibility Analysis of Land Subsidence along the Transmission Line in the Salt Lake Area Based on Remote Sensing Interpretation[J]. Remote Sensing, 2022, 14(13): 3229.
- Ke G, Meng Q, Finley T, et al. LightGBM: A highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems (NeurIPS), 2017, 30: 3146–3154.
- Prokhorenkova L, Gusev G, Vorobev A, et al. CatBoost: unbiased boosting with categorical features[J]. Advances in Neural Information Processing Systems (NeurIPS), 2018, 31: 6639–6649.
- Reichenbach P, Rossi M, Malamud B D, et al. A review of statistically-based landslide susceptibility models[J]. Earth-Science Reviews, 2018, 180: 60–91.
- Zeng T, Guo Z, Wang L, et al. Tempo-Spatial Landslide Susceptibility Assessment from the Perspective of Human Engineering Activity[J]. Remote Sensing, 2023, 15(16): 4111.
- Zeng T, Wu L, Peduto D, et al. Ensemble learning framework for landslide susceptibility mapping: Different basic classifier and ensemble strategy[J]. Geoscience Frontiers, 2023, 14(6): 101645.