何峰，罗燚，曹运江，等. 置信度加权样本与因子变异系数集成的滑坡易发性建模[J]. 水利水电技术(中英文)，2026，57(8)：274-286. DOI：10. 13928/j. cnki. wrahe. 2026. 08. 020

HE Feng，LUO Yi，CAO Yunjiang，et al. Landslide susceptibility modeling based on integration of confidence-weighted samples and factor coefficient of variation[J]. Water Resources and Hydropower Engineering，2026，57(8)：274-286. DOI：10. 13928/j. cnki. wrahe. 2026. 08. 020

置信度加权样本与因子变异系数集成的滑坡易发性建模

何　峰[1]，罗　燚[1]，曹运江[2]，肖正辉[2]，肖巍峰[2]，唐　豪[2]

(1. 湖南省水文地质环境地质调查监测所，湖南 长沙　410129；2. 湖南科技大学 地球科学与空间信息工程学院，湖南 湘潭　411201)

摘　要：【目的】针对滑坡易发性评估中数据不确定性导致的模型精度不足问题，提出一种置信度加权样本与因子变异系数(*COV*)集成的建模方法。【方法】以湖南省平江县为研究区，构建三级样本置信度评价体系(1.0、0.8、0.5)对滑坡样本加权，并通过变异系数量化坡度(*COV*=0.15)、降雨强度(*COV*=0.12)等关键因子的不确定性，结合贝叶斯神经网络(BNN)和 XGBoost 模型开展双维度不确定性集成建模。【结果】结果表明：双维度集成方法显著提升模型性能，XGBoost 模型准确率从 0.721 提升至 0.867，*AUC* 值从 0.745 升至 0.892；BNN 模型准确率从 0.715 提升至 0.861，*AUC* 值从 0.738 升至 0.885。BNN 通过概率密度函数直观展示区域滑坡概率分布的不确定性，XGBoost 通过置信区间反映预测偏差。【结论】研究成果为数据稀缺、地质复杂区域的滑坡易发性评估提供了新范式，未来可通过多源数据融合和物理模型耦合进一步提升模型鲁棒性。

关键词：滑坡易发性；数据不确定性；置信度加权样本；变异系数；双维度集成；机器学习；贝叶斯神经网络；影响因素

DOI：10. 13928/j. cnki. wrahe. 2026. 08. 020　　**开放科学(资源服务)标志码(OSID)**：

中图分类号：P642. 22　　**文献标志码**：A　　**文章编号**：1000-0860(2026)08-0274-13

听语音　聊科研　与作者互动

Landslide susceptibility modeling based on integration of confidence-weighted samples and factor coefficient of variation

HE Feng[1]，LUO Yi[1]，CAO Yunjiang[2]，XIAO Zhenghui[2]，XIAO Weifeng[2]，TANG Hao[2]

(1. Survey and Monitoring Institute of Hydrogeology and Environmental Geology of Hunan Province，Changsha 410129，Hunan，China；2. School of Earth Sciences and Spatial Information Engineering，Hunan University of Science and Technology，Xiangtan　411201，Hunan，China)

Abstract：[Objective] To address the problem of insufficient model accuracy caused by data uncertainty in landslide

收稿日期：2025-07-13；**修回日期**：2025-10-23；**录用日期**：2026-03-09；**网络出版日期**：2026-04-21

基金项目：湖南省自然资源科研(标准)后补助项目(HBZ20240112)；国家自然科学基金项目(42377453)

作者简介：何　峰(1984—)，男，高级工程师，硕士，主要从事地质灾害、生态环境修复研究。E-mail：120659323@qq. com

通信作者：曹运江(1967—)，男，教授，博士，主要从事地质灾害研究。E-mail：caoyj-xt@sohu. com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

susceptibility assessment, a modeling approach is proposed that integrates confidence-weighted samples with coefficient of variation (*COV*) of factors. [Methods] Taking Pingjiang County, Hunan Province as the study area, a three-level sample confidence evaluation system (1.0, 0.8, 0.5) was established to weight landslide samples, and *COV* was used to quantify the uncertainties of key factors such as slope (*COV* = 0.15) and rainfall intensity (*COV* = 0.12). On this basis, Bayesian neural network (BNN) and XGBoost models were employed to develop a dual-dimensional uncertainty integration model. [Results] The results showed that the proposed dual-dimensional integration method significantly improved model performance, with the accuracy of the XGBoost model increasing from 0.721 to 0.867, and its *AUC* value rising from 0.745 to 0.892. The BNN model achieved an accuracy improvement from 0.715 to 0.861, with its *AUC* value increasing from 0.738 to 0.885. BNN visually demonstrated the uncertainty of landslide probability distribution through probability density function, while XGBoost reflected prediction deviations via confidence intervals. [Conclusion] The findings provide a new paradigm for landslide susceptibility assessment in data-scarce and geologically complex regions. In the future, model robustness can be further improved through multi-source data fusion and physical model coupling.

Keywords: landslide susceptibility; data uncertainty; confidence-weighted samples; coefficient of variation; dual-dimensional integration; machine learning; Bayesian neural network; influencing factors

0　引　言

滑坡作为全球范围内危害最为严重的地质灾害之一，其易发性评估是灾害风险管理与防控的关键环节。近年来，基于机器学习的滑坡易发性建模方法凭借其强大的数据挖掘能力与非线性关系处理优势，在地质灾害研究领域得到广泛应用[1-3]。这类方法通过构建滑坡正、负样本与地形、地质、水文等易发性影响因子的复杂映射关系，实现区域滑坡发生概率预测[4-8]。然而，现有研究多聚焦于模型算法优化与因子筛选[9-10]，往往忽视数据本身的不确定性，导致模型预测结果与实际情况存在偏差，限制了研究成果在地质灾害防控实践中的有效应用。

数据不确定性广泛存在于滑坡易发性研究的各个环节[11-14]，主要表现为样本可靠性差异和因子变异性两个层面。在样本层面，滑坡样本的获取主要依赖野外调查、遥感解译或历史文献记录等多种途径。野外调查虽能获取高精度滑坡信息，但受地形条件、人力物力限制，难以实现全域覆盖；遥感解译虽具有效率高、范围广的优势，却受植被覆盖、影像分辨率等因素影响，容易出现小型滑坡漏判或边界识别不准确的问题[15-16]；历史文献记录的滑坡数据，由于年代久远，可能存在定位误差、属性缺失或灾情描述模糊等情况。这些问题使得样本的可靠性参差不齐，若将低可信度样本与高可信度样本同等对待，会引入数据噪声，干扰模型训练，进而降低预测精度[17-18]。

在影响因子层面，地形、岩土力学、水文等参数的测量和估算过程中，也不可避免地存在误差[19-21]。以地形因子为例，数字高程模型（DEM）分辨率直接影响坡度、坡向等参数的提取精度[22]；岩土力学参数获取通常需要通过有限的钻孔取样和室内试验测定，由于岩土体具有高度的空间变异性，少量试验数据难以代表区域整体特性，使得参数估算存在较大不确定性[23-24]；水文参数方面，降雨数据的时空分布不均，依赖气象站点插值得到的降雨强度数据在地形复杂区域容易出现较大误差[25-26]。这些因子的不确定性若未得到有效处理，将在模型运算中逐级传导，最终导致易发性评估结果的不可靠。

针对数据不确定性问题，现有研究主要分为三类方法：第一类是数据质量改进方法，通过增加样本数量、提高数据采集精度或采用多源数据融合来减少误差[27-29]，如利用无人机航测获取高分辨率地形数据，结合地面雷达监测实时获取滑坡变形信息[30]，但这类方法在数据稀缺或复杂地质条件下实施成本高且效果有限；第二类是参数不确定性量化方法，引入变异系数（*COV*）量化岩土参数的空间变异性，通过蒙特卡洛模拟等方法分析其对滑坡稳定性的影响[31]，但此类研究通常仅关注单一类型数据的不确定性，未将样本可靠性纳入统一框架；第三类是样本权重赋值方法，通过为样本赋予权重来反映其重要性[32]，但权重确定多基于主观经验，缺乏科学量化依据。此外，针对滑坡正负样本可信度度量问题，ZHU 等[33]提出基于相似性的负样本数据采样方法，洪浩源等[34]建立了面向机器学习的训练样本采样方法，为样本可靠性评估提供了重要参考。然而，现有研究多聚焦于单一维度的不确定性处理，缺乏将样本可靠性与因子变异性统一集成的系统性方法。因此，如何系统性地集成样本可靠性与因子变异性，构建更具鲁棒性的滑坡易发性模型，成为当前亟待解决的核心科学问题。

本文以湖南省平江县为例，提出一种置信度加权样本与因子变异系数集成的滑坡易发性建模方法，旨在解决数据可靠性与参数变异性对模型精度的制约。通过对滑坡样本进行可信度分级并赋予权重，结合变异系数量化因子不确定性，构建双维度不确定性集成框架。研究将重点回答3个科学问题：(1)如何科学量化样本与因子的不确定性？(2)如何将双重不确定性集成至机器学习框架？(3)该方法对提升预测精度的实际效果如何？研究成果不仅可为类似地质环境复杂、数据质量参差不齐区域的滑坡防控提供科学依据，也将为数据稀缺条件下的易发性评估提供新的方法范式。

1　研究区及数据

1.1　研究区概况

平江县位于湖南省东北部，总面积4 125 km^2，地处幕阜山脉与罗霄山脉交汇处。地形以山地丘陵为主，高程变化范围为50～1 606 m，平均高程约580 m，坡度范围为0～78°，平均坡度28.5°，沟谷切割深度为200～800 m。地质构造上，该区域受北东向断裂带影响，构造活动导致岩体破碎。区内主要岩石类型为元古界板溪群浅变质砂岩和板岩、中生代燕山期花岗岩，以及白垩系-古近系紫红色砾岩、砂岩和泥岩。气候方面，平江县属于亚热带季风湿润区，年均气温为16.8 ℃，年降雨量为1 450～1 650 mm，4—6月降雨量占全年的48%以上。2024年6月16日至7月3日，岳阳市平江县累计降雨量达到808.8 mm，是常年同期的4.6倍，导致多地发生山体滑坡、道路中断等严重灾情。该区域“样本数量丰富但数据质量参差不齐”的特征，使其成为研究双维度数据不确定性问题的典型区域。

1.2　滑坡样本特征与分类

本研究收集了平江县366处滑坡样本，初始数据为多边形矢量，经GNSS实地验证后转化为质心点数据(见图1)。图1展示了土地利用和岩性对滑坡分布

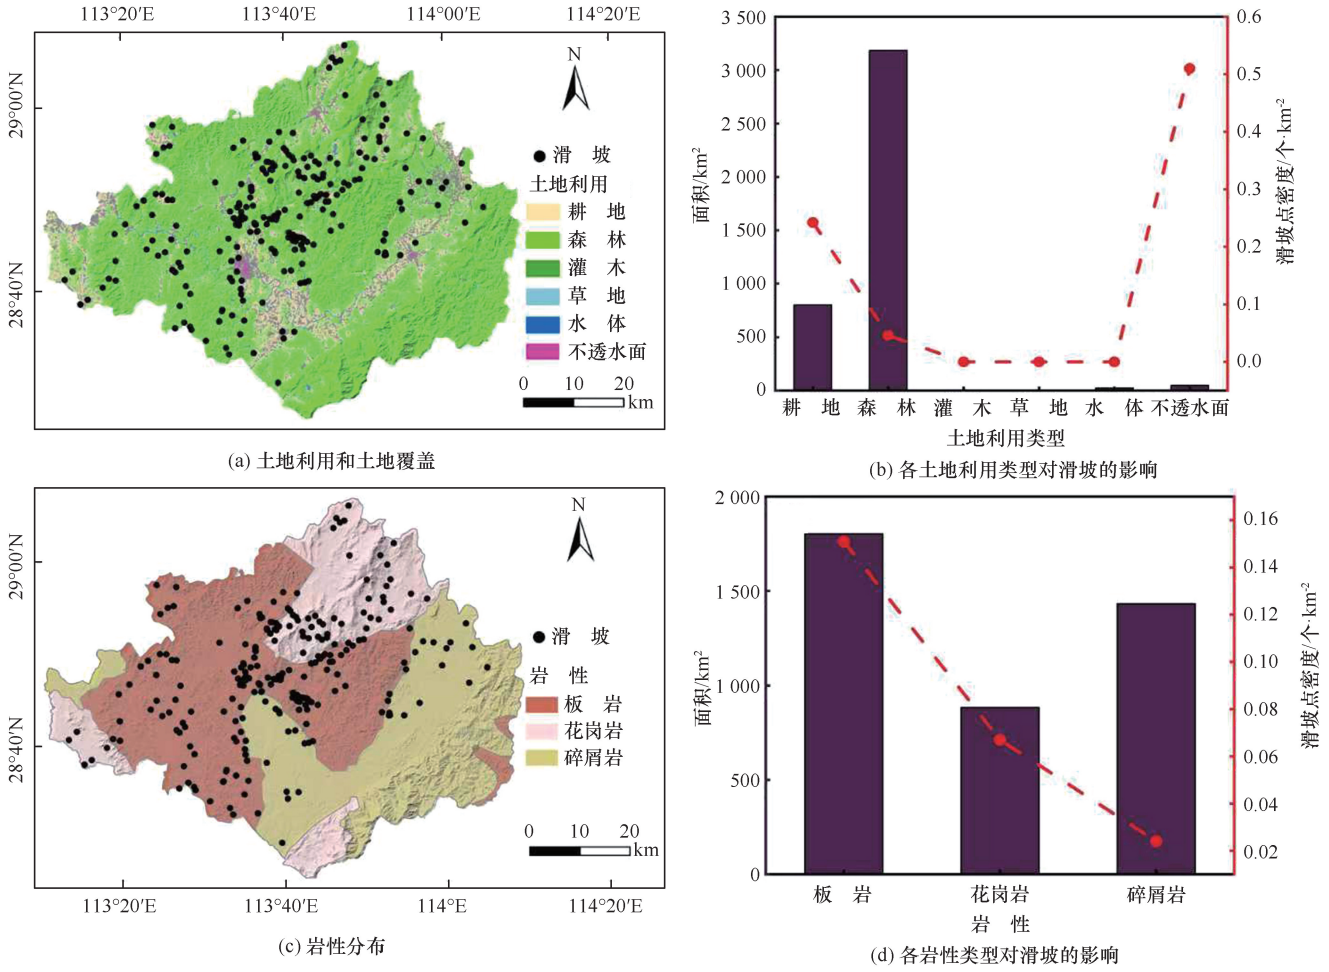


图1　土地利用、岩性分布及其对滑坡的影响

Fig. 1　Land use, lithological distribution and their influence on landslides

的影响，选择这两个因子可视化基于以下考虑：（1）二者是滑坡空间分布最直观的控制因素，能清晰反映宏观分布特征；（2）作为分类型因子，其空间分异特征适合通过分布图展示。

由图 1 可看出，滑坡点主要分布在森林和耕地区域。频率比分析表明，耕地滑坡密度（约 0.3 个/km^2）显著高于森林（0.008 个/km^2），反映了农业活动对边坡稳定性的影响。但考虑到土地利用与人类活动强度高度相关，且本研究已选取“居民区周边”和“道路沿线”滑坡作为人类活动的代理变量，为避免因子间多重共线性，最终未将土地利用纳入评价体系。此外，考虑人类活动因子后，土地利用对模型精度的增益有限[6,19,33]。岩性方面，板岩和花岗岩地区滑坡点较为集中。板岩区域滑坡密度最高（约 0.15 个/km^2），花岗岩区域次之（约 0.07 个/km^2），碎屑岩区域最低（约 0.02 个/km^2），表明不同岩性对易发性的控制作用存在显著差异，因此地层岩性被纳入最终的 10 个评价因子。

滑坡规模以中小型为主，面积 50～5 000 m^2（平均 800 m^2），滑面深度 1.5～8.0 m，多为浅层土质滑坡。根据数据获取方式、空间分布及致灾机制差异，样本划分为 3 类：

（1）居民区周边滑坡（185 处）分布于城镇村落周边，因切坡建房、开挖地基等工程活动引发。数据来源于 2024 年 6 月应急调查，结合无人机航测（精度±2 m）与地面实测，详细记录滑坡中心点、滑动方向及工程扰动痕迹，可靠性高。

（2）道路沿线滑坡（83 处）集中于山区道路两侧，受路基切坡、排水不畅影响。数据源于 2024 年应急调查，辅以道路工程档案，重点核查滑坡与开挖、排水沟堵塞等因素的关联性，定位精度±5 m，可靠性中等。

（3）无人区滑坡（98 处）位于偏远山区，人为扰动微弱，主要由强降雨或岩土体自然失稳触发。通过历史遥感影像（高分二号卫星）解译及地方志文献整理获取，结合地形地貌特征推断成因与规模，定位精度±10 m，不确定性相对较高。

1.3　影响因子选取与数据来源

基于滑坡发生机理[20-21]和数据可获取性，选取 10 个影响因子，涵盖地形、地质、水文、岩土力学四大类别（见表 1）。

本研究选取选择坡度、降雨强度、黏聚力、内摩擦角进行 *COV* 量化的原因包括：（1）这 4 个因子是滑坡发生的关键控制因素[6-8]，对预测结果影响显著；（2）这些因子在数据获取过程中存在明显的测量误差和空间变异性；（3）相关研究表明这些参数的不确定性对滑坡稳定性分析影响最为显著[19-21,23]。

1.4　数据预处理

1.4.1　样本置信度分级量化

基于数据获取方式、定位精度和专家经验，构建定量化置信度评价体系。

（1）居民区周边滑坡：数据获取方式得分 0.4（无人机+实测）+定位精度得分 0.3（±2 m）+验证程度得分 0.3（现场核实）= 1.0。

（2）道路沿线滑坡：数据获取方式得分 0.3（应急调查）+定位精度得分 0.25（±5 m）+验证程度得分 0.25（档案核对）= 0.8。

（3）无人区滑坡：数据获取方式得分 0.2（遥感解译）+定位精度得分 0.15（±10 m）+验证程度得分 0.15（文献推断）= 0.5。

为验证该评分体系的合理性，选取 30 个发生二次变形的滑坡进行回溯性检验。将原始编目位置与二次变形后的高精度 RTK-GPS 复测位置（精度±0.5 m）进行空间配准，计算位置偏差作为可靠性指标。结果显示，高置信度样本（$C \geqslant 0.8$）的平均位置偏差为 3.2 m（$n=22$，标准差 1.3 m），低置信度样本（$C=0.5$）的平均偏差为 8.7 m（$n=8$，标准差 2.3 m）。Pearson 相关分析表明置信度与位置偏差呈显著负相关（$r=-0.86$，$p<0.01$），线性回归方程为：偏差（m）= $12.4-9.1\times C$（$R^2=0.74$），即置信度每提升 0.1，位

表 1　数据类型与来源

Table 1　Data types and sources

数据类型	具体指标	数据来源	数据分辨率/精度
滑坡样本	位置、规模、诱发因素	居民区/道路：应急调查；无人区：遥感解译、文献整理	定位精度±5 m
地形因子	高程、坡度、坡向、曲率	30 m 分辨率 SRTM DEM	垂直精度±3 m
地质因子	地层岩性、距断层距离	1∶5万区域地质图	制图精度±20 m
水文因子	降雨强度、标准化降水指数（*SPI*）	24 个气象站点插值	降雨误差±8%
岩土力学参数	黏聚力、内摩擦角	实测、类比	—

置偏差平均减少 0.91 m。

1.4.2　因子 *COV* 计算与扰动生成

（1）坡度因子（*COV*=0.15）：基于 30 m DEM 分辨率误差统计分析，参考 CHEN 等[35]在类似地形条件下的研究成果确定。

（2）降雨强度因子（*COV*=0.12）：根据 24 个气象站点监测数据的空间插值误差统计，通过交叉验证方法计算得出。

（3）岩土力学参数：收集平江县及邻近区县 127 个钻孔岩土试验数据（钻孔集中于历史滑坡点周边 500 m 范围），涵盖板岩残坡积土（58 个）、花岗岩残坡积土（43 个）和砂岩残坡积土（26 个）。统计结果显示：板岩黏聚力 *COV*=0.40、内摩擦角 *COV*=0.20；花岗岩黏聚力 *COV*=0.38、内摩擦角 *COV*=0.19；砂岩黏聚力 *COV*=0.35、内摩擦角 *COV*=0.18。研究区板岩和花岗岩合计占比 67.9%，两者 *COV* 差异<5%，采用板岩参数（黏聚力 *COV*=0.40，内摩擦角 *COV*=0.20）作为区域代表值引入的系统误差<3%。该取值与同类地层研究结果[23, 31]及《岩土工程勘察规范》的推荐范围总体相符。机器学习模型通过岩性因子已捕捉不同岩性的参数均值差异，统一 *COV* 值反映各岩性内部固有空间变异性，符合区域尺度研究的国际通行做法。

（4）扰动数据生成：对每个样本的上述 4 个因子，基于对数正态分布（岩土参数）或正态分布（地形、水文参数），生成 1000 组随机扰动数据用于模型训练。

1.4.3　负样本生成策略优化

负样本数量设定为正样本的 3 倍（366×3=1 098 个），该比例确定依据如下：（1）已有研究表明正负样本比例在 1∶2至 1∶4时模型性能最优[33-34]；（2）针对本研究数据集开展敏感性分析，对比 1∶1、1∶2、1∶3、1∶4、1∶5这 5 种比例下 BNN 和 XGBoost 模型的综合表现，发现 1∶3时训练效率与预测精度达到最佳平衡。负样本生成遵循空间约束原则（距滑坡点大于 100 m）并结合分层采样策略（按地形地貌分区），利用遥感影像和地形分析剔除潜在不稳定斜坡，保证负样本可靠性。

2　研究方法

本研究构建“双维度不确定性集成”技术框架（见图 2），核心流程包括：（1）样本维度，建立定量化置信度评价体系，通过加权机制降低低可信度样本的训练权重；（2）因子维度，基于 *COV* 量化关键因子的变异性，通过随机扰动模拟参数不确定性；（3）集成维度，将两类不确定性统一纳入机器学习框架，实现鲁棒性建模。

2.1　样本置信度加权机制

2.1.1　XGBoost 加权训练

在 XGBoost 模型中，置信度权重作用于目标函数的损失计算公式为

$$Obj = \sum_{i=1}^{n} w_i \times l(y_i, \hat{y}_i) + \sum_{t=1}^{T} \Omega(f_t) \qquad (1)$$

式中，w_i 为第 i 个样本的置信度权重；$l(y_i, \hat{y}_i)$ 为损失函数；$\Omega(f_t)$ 为正则化项。

权重直接影响梯度和海森矩阵计算，使模型优先学习高置信度样本特征。

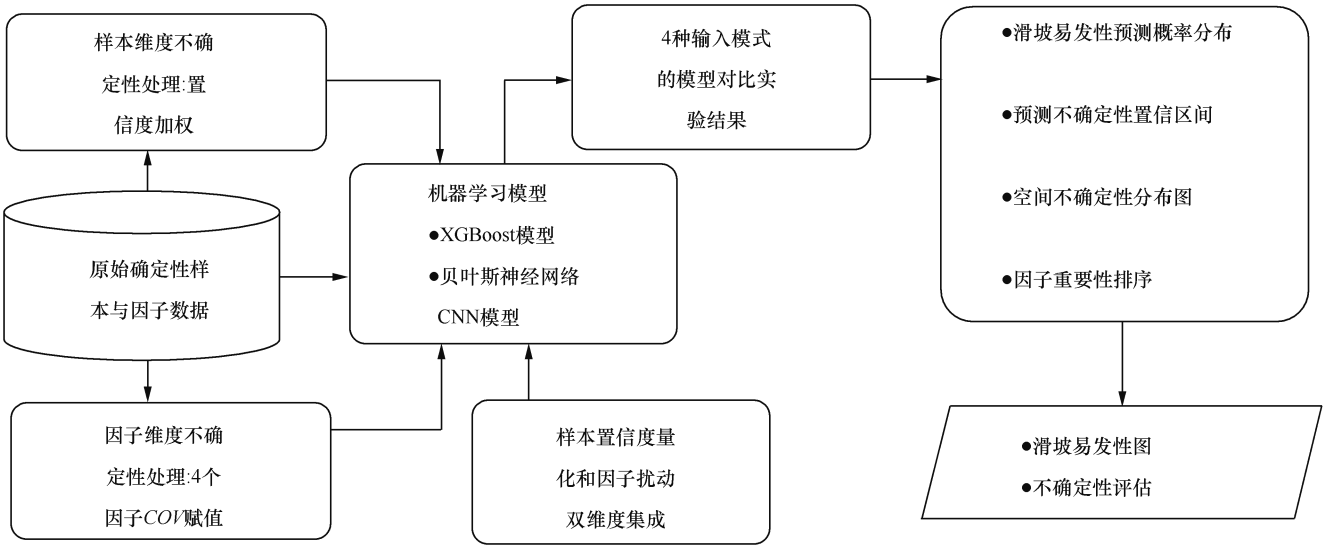


图 2　双维度滑坡预测不确定性集成技术路线

Fig. 2　Flowchart of dual-dimensional uncertainty integration for landslide prediction

2.1.2　BNN 加权贝叶斯推断

在贝叶斯神经网络中，将置信度权重融入似然函数

$$L_{\text{weighted}}(\theta)=\prod_{i=1}^{N}\left[p(y_i\mid x_i,\ \theta)\right]^{w_i} \tag{2}$$

加权似然函数引导 MCMC 采样过程更倾向于高置信度样本的参数空间，提高后验分布的可靠性。

2.2　因子 COV 扰动建模

对关键因子进行随机扰动

$$X_{\text{perturbed}}=X_{\text{original}}\times(1+COV\times\varepsilon) \tag{3}$$

式中，$\varepsilon\sim N(0,\ 1)$ 为标准正态分布随机数。

通过生成 20 组扰动数据，构建因子不确定性的概率分布，量化参数变异对预测结果的影响。

2.3　模型构建与优化

2.3.1　XGBoost 模型优化

XGBoost 作为一种高效的集成学习算法，在处理复杂地质环境下的滑坡易发性预测问题时表现出色[36]。考虑到本研究数据的高维性和双维度不确定性特征，采用贝叶斯优化算法进行系统性超参数寻优。设定超参数搜索空间：树的最大深度[4，8]、学习率[0.05，0.2]、子采样率[0.6，0.9]、最小叶子节点样本数[1，5]、正则化参数 λ[0.1，1.0]。

贝叶斯优化采用高斯过程作为代理模型，以 5 折交叉验证的平均 *AUC* 值为优化目标，通过 50 轮迭代寻找最优参数组合。经系统性优化，最终确定最优超参数为：max_*depth* = 6，*learning_rate* = 0.1，*subsample* = 0.8，min_*child_weight* = 3，*reg_lambda* = 0.5，对应的交叉验证 *AUC* 值为 0.887±0.012。该参数组合在保证模型复杂度的同时，有效控制了过拟合风险，为后续双维度不确定性建模奠定基础。

2.3.2　贝叶斯神经网络 BNN 优化

BNN 的网络架构设计需要平衡表达能力与计算复杂度，同时确保贝叶斯推断的收敛性。通过系统性试验比较不同网络结构的性能表现，确定采用 3 层隐藏层结构，神经元配置为递减式设计[64－32－16]，激活函数选择 ReLU 以处理地质参数的非线性关系，输出层采用 Sigmoid 函数输出滑坡发生概率[0，1]。该架构既保证了特征提取能力，又避免了参数过多导致的过拟合问题。

MCMC 采样策略采用哈密顿蒙特卡罗（HMC）算法进行贝叶斯推断，通过收敛性诊断确定总采样轮次 1 500 次，其中 burn-in 期 500 次用于参数预热。采用 NUTS（No-U-Turn Sampler）自动调节步长提高采样效率，使用 Gelman-Rubin 统计量（$\hat{R}<1.01$）和有效样本数（*ESS*>400）双重标准验证参数收敛性。训练过程中实时监控训练损失、验证 *AUC* 和参数后验分布，设置早停机制防止过拟合，确保模型能够有效量化预测不确定性。

2.3.3　模型对比试验设计

设计 4 种输入条件进行对比：（1）基线模型，对应原始确定性数据；（2）样本加权模型，仅考虑样本置信度权重；（3）因子扰动模型，仅考虑 *COV* 扰动；（4）集成模型，对应双维度不确定性集成。

2.4　模型评估与不确定性量化

2.4.1　性能评估指标

采用准确率（Accuracy）、精确率（Precision）、召回率（Recall）、*F*1 分数和 *AUC* 值进行定量评估。易发性分级方法则采用自然断点法（Jenks）将预测概率分为极低、低、中等、高、极高五个等级。

2.4.2　不确定性定量分析

BNN 不确定性量化：通过后验分布计算预测概率的置信区间，用概率密度函数展示不同区域的预测不确定性。

XGBoost 不确定性估计：采用 Bootstrap 方法训练 100 个子模型，计算预测结果的标准差作为不确定性指标。

3　结　果

3.1　*COV* 扰动因子特征分析

为验证 *COV* 扰动方法的有效性，分析了扰动后因子数据的统计特征。表 2 对比了 4 个关键因子扰动前后的统计参数变化。结果显示，扰动后各因子均值变化幅度为 0.6%～1.1%，标准差增幅与 *COV* 设定值基本一致（偏差<3%），验证了扰动方法的有效性。黏聚力表现出最大变异性（*COV* = 0.4），符合平江县花岗岩风化残坡积土空间异质性强的地质特征；降雨强度变异性最小（*COV* = 0.12），反映了气象观测数据的相对稳定性。Kolmogorov-Smirnov 检验显示所有扰动数据符合设定分布（p>0.05），表明 *COV* 扰动方

表 2　扰动因子统计特征对比

Table 2　Comparison of statistical characteristics of disturbance factors

因子名称	*COV* 设定值	原始数据均值	扰动数据均值	标准差增幅/%	分布特征
坡度/(°)	0.15	32.4	32.7	14.6	轻微右偏
降雨强度 /mm·h^{-1}	0.12	15.3	15.2	12.3	近似正态
黏聚力/kPa	0.4	18.5	18.3	40.1	对数正态
内摩擦角/(°)	0.2	32.1	32.3	19.4	近似正态

法在量化参数不确定性的同时有效保持了数据的统计特征，为滑坡风险评估提供了可靠基础。

3.2　模型预测性能评估

表 3 展示了 BNN 和 XGBoost 模型在不同数据输入条件下的性能表现。基线模型（原始确定性数据）中，XGBoost 模型的准确率为 0.721，*AUC* 值为 0.745；BNN 模型的准确率为 0.715，*AUC* 值为 0.738，两模型性能相近但整体表现一般。

单维度不确定性处理效果分析：样本置信度加权显著改善了模型性能，XGBoost 和 BNN 的 *AUC* 值分别提升至 0.868 和 0.862，准确率分别达到 0.843 和 0.837。这表明通过科学量化样本可靠性差异，能有效减少低质量数据对模型训练的负面影响。因子 *COV* 扰动同样带来性能提升，XGBoost 和 BNN 的 *AUC* 值分别达到 0.859 和 0.851，验证了参数变异性量化的有效性。

双维度集成效果验证：集成模型取得最优性能，XGBoost 模型各项指标均达到最高水平，准确率为 0.867，*AUC* 值为 0.892；BNN 模型准确率为 0.861，*AUC* 值为 0.885。相比基线模型，两种算法的 *AUC* 值分别提升了 19.7% 和 19.9%，充分验证了“双维度不确定性集成”方法的显著效果。值得注意的是，集成模型的 *F*1 分数也达到最高（XGBoost 为 0.838，BNN 为 0.831），表明该方法在平衡精确率和召回率方面表现优异。

3.3　因子重要性分析

通过 Shapley 值分析不同输入条件下各因子的重要性变化（见图 3），揭示了双维度不确定性处理对因子贡献度评估的影响。

XGBoost 模型因子重要性演变［见图 3(a)］：在双维度不确定性集成输入下，坡度（0.23）和降雨强度（0.21）的重要性显著提升，成为主导因子。这一结果符合滑坡发生的物理机制，即地形坡度提供失稳条件，降雨强度触发滑坡事件。显著变化包括：（1）内摩擦

表 3　不同数据输入条件下 BNN 和 XGBoost 模型性能指标

Table 3　Performance indicators of BNN and XGBoost models under different data input conditions

模　型	数据输入条件	准确率	精确率	召回率	*F*1 分数	*AUC* 值
XGBoost	原始确定性	0.721	0.686	0.693	0.690	0.745
	样本置信度加权	0.843	0.812	0.805	0.809	0.868
	因子 *COV* 扰动	0.835	0.801	0.798	0.799	0.859
	双维度不确定性集成	0.867	0.842	0.835	0.838	0.892
BNN	原始确定性	0.715	0.678	0.685	0.681	0.738
	样本置信度加权	0.837	0.805	0.801	0.803	0.862
	因子 *COV* 扰动	0.829	0.793	0.792	0.792	0.851
	双维度不确定性集成	0.861	0.835	0.828	0.831	0.885

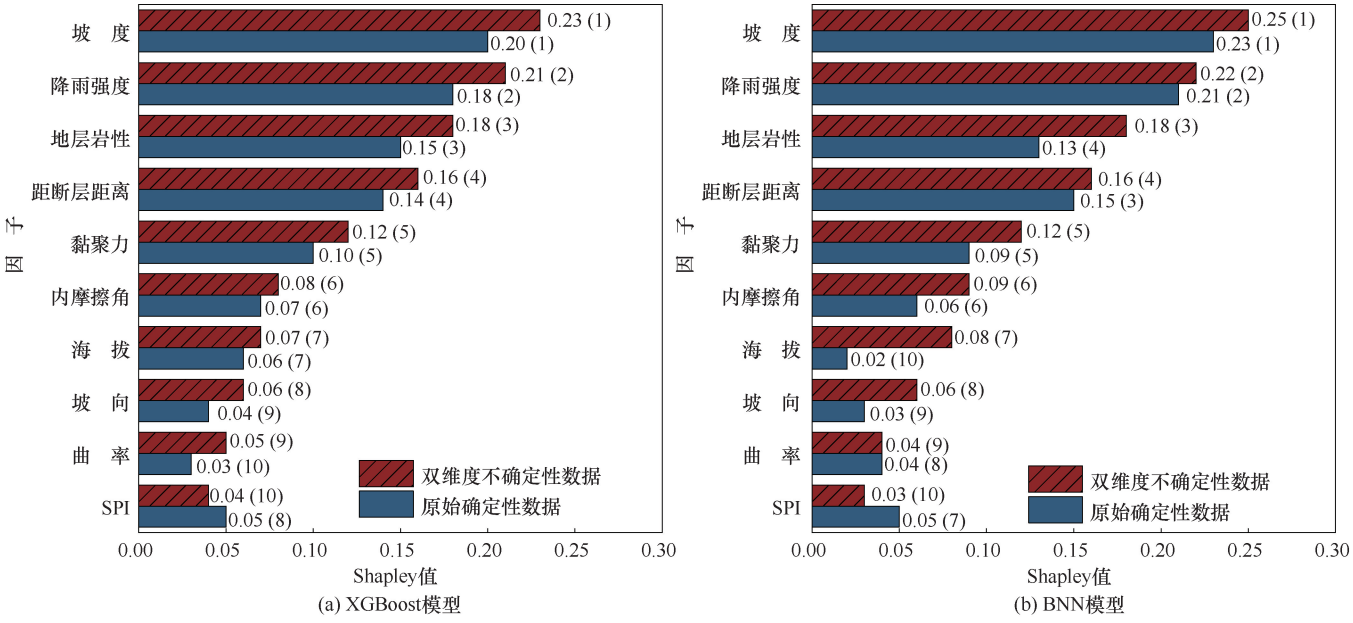


图 3　两种输入条件下的因子重要性对比

Fig. 3　Comparison of factor importance under two input conditions

角重要性从 0.14 升至 0.15，反映岩土参数不确定性处理后其真实贡献得到凸显；（2）距断层距离重要性从 0.04 跃升至 0.14，表明构造控制作用在消除数据噪声后更加明显；（3）*SPI* 和曲率等次要因子重要性略有下降，说明低可信度样本对这些因子的干扰得到有效控制。

BNN 模型因子重要性特征［见图 3(b)］：BNN 模型呈现相似趋势，坡度（0.25）、降雨强度（0.22）、地层岩性（0.18）和距断层距离（0.16）构成核心因子组合。与 XGBoost 不同的是，BNN 模型中黏聚力的重要性从 0.12 降至 0.09，可能因贝叶斯推断过程中该参数的不确定性被更充分地量化，导致其权重调整。总体而言，两种模型均体现了“地形控制+水文触发+地质约束”的滑坡易发性主控机制。

3.4　不确定性量化与空间分布分析

3.4.1　模型不确定性量化对比

图 4 展示了 BNN 模型在不同区域滑坡概率分布及 95%置信区间。居住区周边（红色曲线）和道路沿线（蓝色曲线）的概率密度函数呈现高峰值、窄分布特征，滑坡发生概率集中在[0.6，1.0]区间，置信区间较窄，表明这些区域不仅滑坡风险高，而且模型预测的不确定性小。相比之下，无人区（绿色曲线）的概率密度分布相对平缓，峰值较低且分布较宽，反映了该区域较低的滑坡风险和较高的预测不确定性，这与历史遥感数据质量相对较差的实际情况高度吻合。

图 5 展示了 XGBoost 模型基于 Bootstrap 方法的预测置信区间分布。预测不确定性呈现明显的空间分异

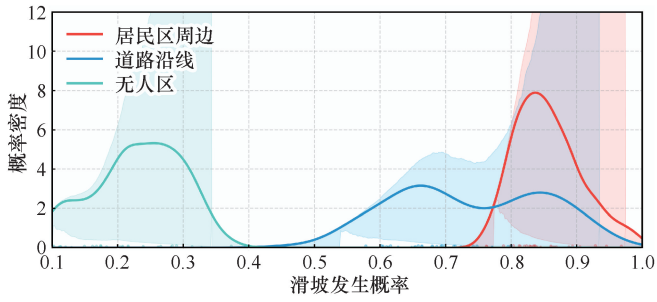


图 4　不同区域滑坡概率分布及 95%置信区间

Fig. 4　Probability distributions of landslides in different areas and their 95% confidence intervals

特征：(1)地质构造复杂区域（如多组断层交汇处）不确定性较高；(2)数据稀疏的无人区不确定性显著增加；(3)地形平缓、地质条件简单的平原区域不确定性最低。这一空间分布规律为风险管控提供了重要参考，即在高不确定性区域应增加地质调查投入，获取更可靠的基础数据。

3.4.2　空间易发性分布对比分析

图 6 和图 7 分别展示了 BNN 和 XGBoost 模型的滑坡易发性空间分布结果。在确定性数据输入下，BNN 模型显示 53.0%的滑坡点位于极高、高易发性区域，30.6%位于极低易发性区域；XGBoost 模型对应比例为 48.5%和 16.1%。采用双维度不确定性集成后，预测精度显著提升：BNN 模型中 80.6%的滑坡点正确归类至极高、高易发性区域，极低易发性区域的错分率降至 1.4%；XGBoost 模型的对应指标为 72.9%和 7.4%。

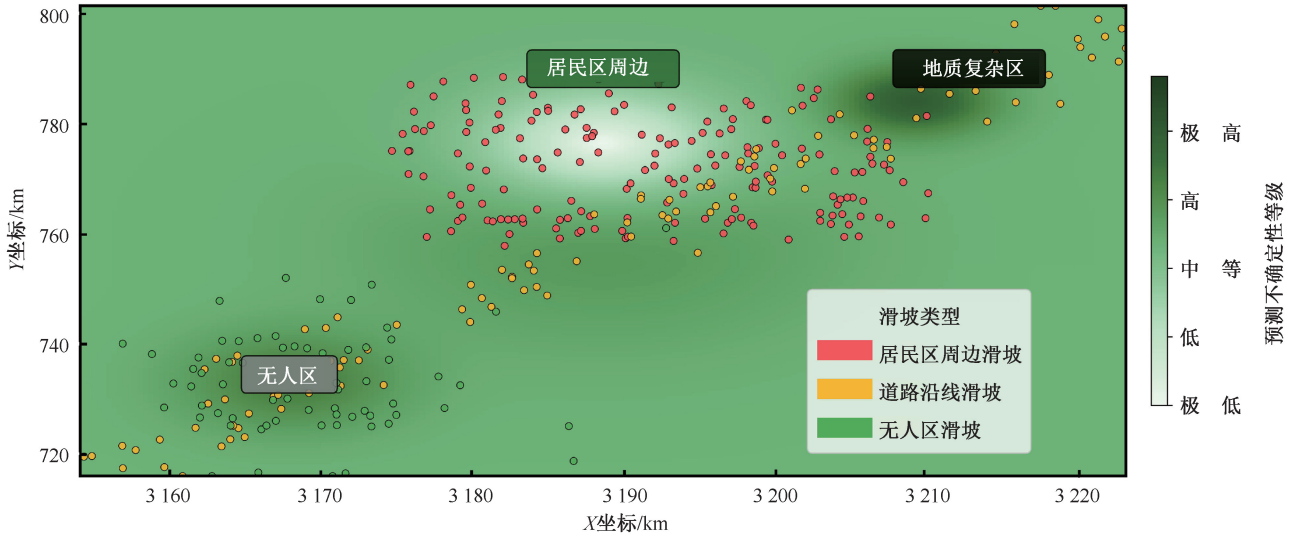


图 5　滑坡预测不确定性与区域关联分析

Fig. 5　Uncertainty in landslide prediction and regional correlation analysis

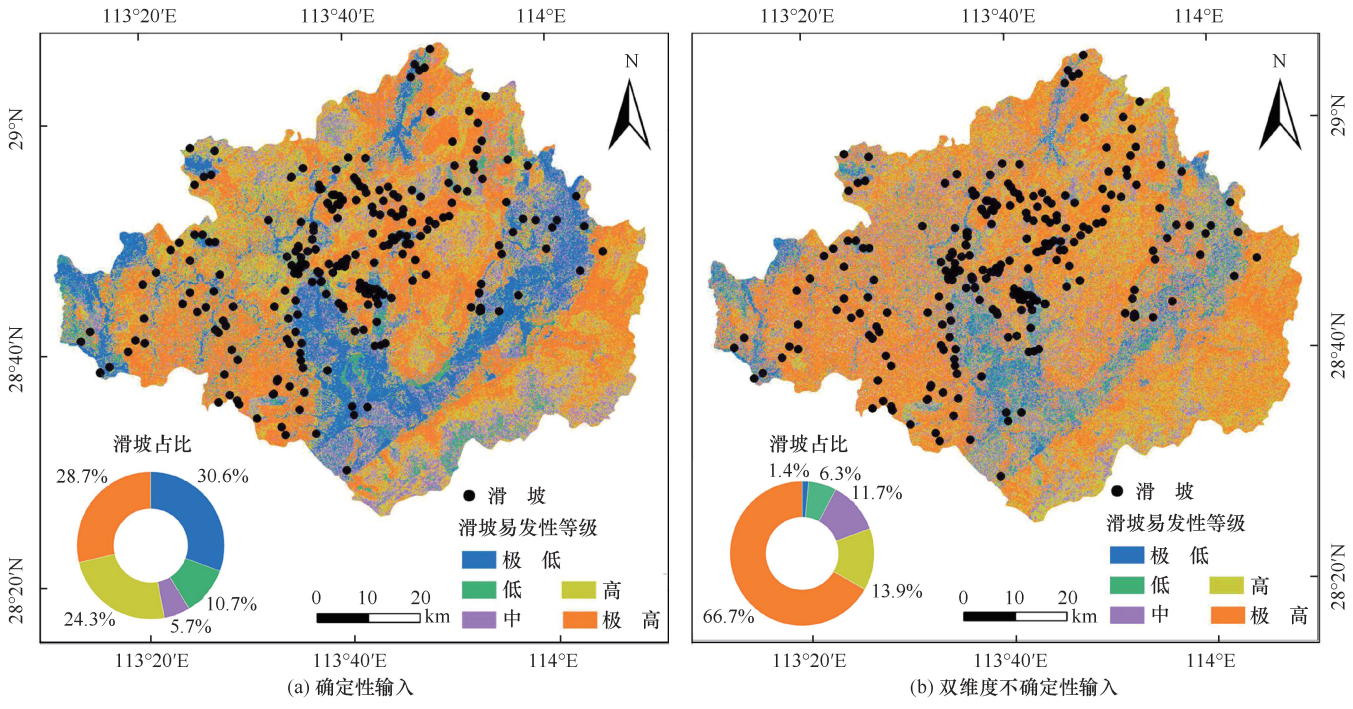


图 6　基于 BNN 模型的滑坡易发性及滑坡点空间分布对比

Fig. 6　Comparison of landslide susceptibility and spatial distribution of landslide points using BNN model

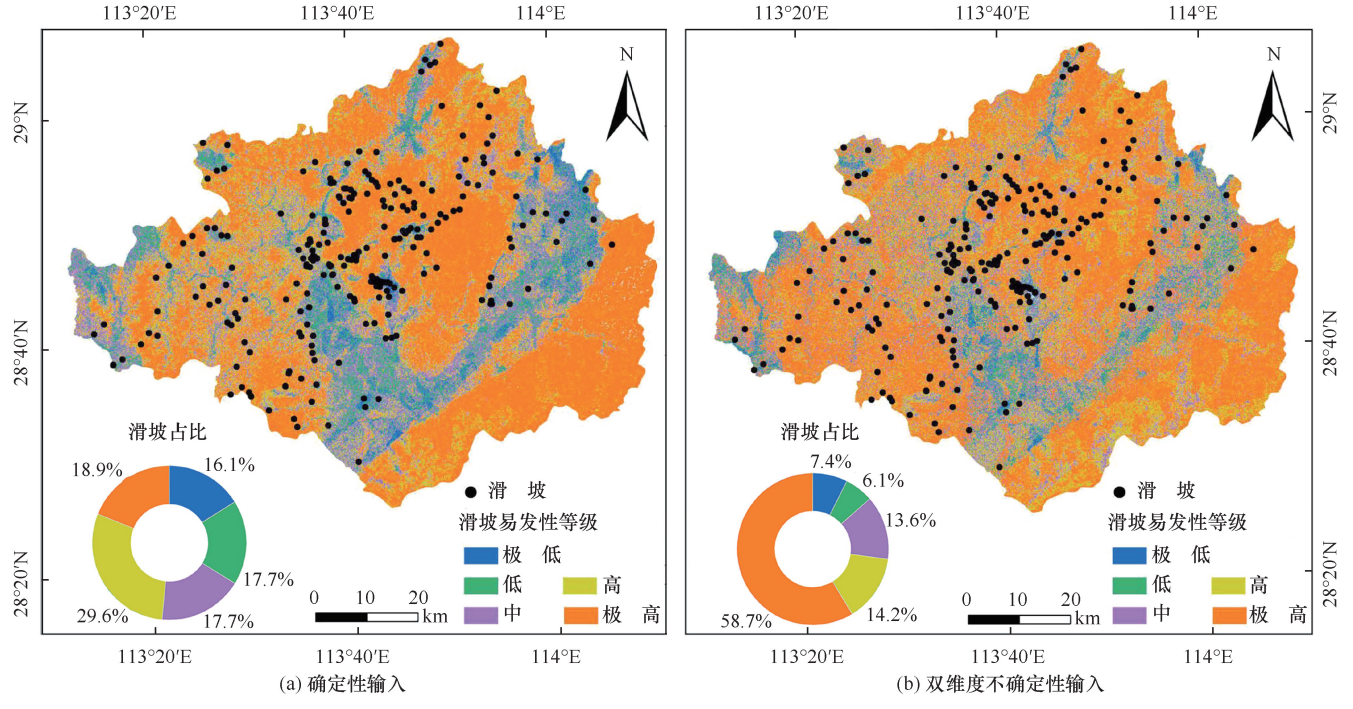


图 7　基于 XGBoost 模型的滑坡易发性及滑坡点空间分布对比

Fig. 7　Comparison of landslide susceptibility and spatial distribution of landslide points using XGBoost model

4　讨　论

4.1　双维度不确定性集成方法的有效性

传统滑坡易发性研究多聚焦于单一维度的数据不确定性处理。如 CUI 等[31]虽引入变异系数量化岩土参数变异性，但未考虑样本可靠性差异；ZHU 等[33]提出负样本采样优化方法，但缺乏对因子变异性的系统处理。本研究提出的置信度加权样本与因子变异系数集成方法，首次系统性地将样本可靠性与因子变异性纳入统一框架，具有较好的创新性。

在样本层面，构建的三级置信度评价体系有效解决了多源数据可靠性参差不齐的问题。居民区滑坡（置信度 1.0）、道路沿线滑坡（置信度 0.8）和无人区滑坡（置信度 0.5）的差异化赋值，显著降低了低可信度样本对模型训练的干扰。在因子层面，通过 *COV* 量化坡度（0.15）、降雨强度（0.12）、黏聚力（0.4）和内摩擦角（0.2）的变异性，并生成 20 组随机扰动数据，全面考虑了参数不确定性对预测结果的影响。

模型性能验证结果充分证明了方法有效性。相比原始确定性数据，双维度集成使 XGBoost 模型 *AUC* 值从 0.745 提升至 0.892（提升 19.7%），BNN 模型从 0.738 提升至 0.885（提升 19.9%）。更重要的是，集成模型在空间预测精度上显著改善：BNN 模型中 80.6%的滑坡点正确归类至高、中高易发性区域，相比确定性输入的 53.0%大幅提升；低易发性区域错分率从 30.6% 降至 1.4%，有效减少了“漏报”风险。

4.2　不同模型对不确定性处理的响应差异

BNN 和 XGBoost 模型在处理双维度不确定性方面展现出不同特征。BNN 模型凭借贝叶斯推断特性，在不确定性量化上具有天然优势[35]。通过后验分布计算，BNN 能够输出预测概率的置信区间，直观展示空间不确定性分布：居住区周边和道路沿线区域的概率密度函数呈现高峰值、窄分布特征，反映高滑坡风险和低预测不确定性；无人区则呈现相对平缓的分布，与历史遥感数据质量较差的实际情况高度吻合。

XGBoost 模型虽缺乏直接量化不确定性的机制，但通过样本置信度加权机制在目标函数中调整损失权重，使模型优先学习高可信度样本特征[37]。因子重要性分析显示，双维度集成后坡度重要性从 0.18 提升至 0.23，距断层距离从 0.04 跃升至 0.14，表明消除数据噪声后关键控制因子的真实贡献得到凸显。通过 Bootstrap 方法估计的预测不确定性呈现明显空间分异：地质构造复杂区域和数据稀疏的无人区不确定性较高，地形平缓的平原区域不确定性最低。

两种模型的互补性为实际应用提供了重要参考：BNN 在不确定性可视化和概率推断方面更优，适用于风险评估和决策支持；XGBoost 在处理大规模数据和复杂非线性关系上更高效，适用于区域性快速评估。

4.3　双维度不确定性集成对高易发区扩大的机制解释

与传统确定性建模相比，本研究的双维度不确定性集成导致极高、高易发区范围扩大，这一现象具有深层的科学机制和实际意义。从不确定性传播机理看，双维度集成本质上采用了保守性风险评估策略，这与黄发明等[11]提出的“滑坡边界形状不确定性理论”相符。样本置信度加权机制使低置信度样本以降权方式参与建模，而非完全排除，系统保留了潜在风险信息；*COV* 扰动通过 1 000 组参数变化探索了李文彬等[19]强调的“环境参数空间不确定性边界”，使模型识别出在岩土参数变异条件下可能失稳的区域。此外，传统确定性建模中存在的“噪声掩蔽效应”被有效消除，使原本被低质量样本干扰而被忽视的真实风险区域得以显现，如距断层距离重要性从 0.04 跃升至 0.14，体现了构造控制风险的准确识别。

平江县地质构造复杂、岩体破碎度高，*COV* 扰动充分考虑了岩土参数空间变异性（黏聚力 *COV* = 0.4），而这在多数确定性研究中被系统性忽视[36-37]。2024 年 6 月极端降雨事件验证了该区域的广泛易发性，与预测结果相互印证。更重要的是，方法将极低易发区漏报率从 30.6%降至 1.4%，80.6%的实际滑坡被正确归类至极高、高易发区，*AUC* 值达 0.885～0.892，表明高易发区扩大并非“过度预测”，而是基于不确定性量化的科学预测。相比“漏报”造成的生命财产损失，适度“误报”的社会成本更可接受，这种保守性策略为复杂地质环境下的滑坡精准防控提供了更可靠的技术支撑。

4.4　研究局限性与未来展望

尽管本研究取得一定成果，但仍存在局限性。数据方面，岩土力学参数主要依赖文献类比，缺乏大量原位实测数据验证，可能导致参数不确定性量化存在偏差；气象站点数据的空间插值在地形复杂区域容易产生较大误差，影响降雨因子不确定性的准确量化。就方法而言，当前仅考虑了 4 个关键因子的变异性，未涵盖所有影响因子；*COV* 扰动采用独立随机生成，未充分考虑因子间的相关性和耦合效应。

未来研究可从以下方向深化：（1）加强多源数据融合，利用先进调查技术获取更准确的数据，降低数据不确定性；（2）探索因子间相互作用的不确定性传播机制，发展考虑时空变异性的动态不确定性量化方法，如结合 Copula 函数描述多因子联合分布特征；（3）构建物理机制约束的深度学习模型，将边坡稳定性理论与数据驱动方法相结合，提升模型的物理可解释性和泛化能力，为滑坡灾害防控提供更科学的技术支撑。

5 结　论

（1）构建了系统性的双维度不确定性集成框架。样本维度通过定量化置信度评价体系实现差异化加权；因子维度通过变异系数量化坡度、降雨强度、黏聚力和内摩擦角的不确定性并生成随机扰动。该方法使 XGBoost 和 BNN 模型的 *AUC* 值分别从 0.745 和 0.738 提升至 0.892 和 0.885，验证了双维度不确定性集成的显著效果。

（2）揭示了不确定性处理对因子重要性评估的影响规律。双维度集成后，坡度和降雨强度成为主导控制因子，距断层距离重要性从 0.04 跃升至 0.14，反映了消除数据噪声后地质构造控制作用得到真实体现，形成了“地形控制+水文触发+地质约束”的滑坡易发性主控机制。

（3）实现了预测不确定性的有效量化与空间可视化。BNN 模型通过后验分布计算置信区间，XGBoost 模型基于 Bootstrap 方法估计预测标准差，均显示地质构造复杂区域和数据稀疏的无人区不确定性较高，为风险分区管控和地质调查布设提供了科学依据。

（4）该方法在平江县 366 个滑坡样本的应用中，使极高、高易发性区域的滑坡点正确归类率从 53.0%提升至 80.6%，极低易发性区域错分率从 30.6%降至 1.4%，有效减少了滑坡灾害的“漏报”风险，为类似地质环境复杂、数据质量参差不齐区域的滑坡防控提供了新的方法范式。

所有作者声明不存在利益冲突。

The authors declare that no competing interests exist.

参考文献(References)：

[1] JIANG B D, LI X C, LUO H Y, et al. A comparative analysis of heterogeneous ensemble learning methods for landslide susceptibility assessment [J]. China Civil Engineering Journal, 2023, 56 (10): 170-179.

[2] 陈航，刘惠军，王韬，等. 基于频率比-深度神经网络耦合模型的滑坡易发性评价：以盐源县为例[J]. 水文地质工程地质，2024，51(5)：161-171.
CHEN Hang, LIU Huijun, WANG Tao, et al. Landslide susceptibility evaluation based on FR-DNN coupling model: A case study on Yanyuan County[J]. Hydrogeology & Engineering Geology, 2024, 51(5): 161-171.

[3] 邬礼扬，曾韬睿，刘谢攀，等. 基于集成学习建模的滑坡易发性评价[J]. 地球科学，2024，49 (10)：3841-3854.
WU L Y, ZENG T R, LIU X P, et al. Landslide susceptibility assessment based on ensemble learning modeling. Earth Science, 2024, 49(10): 3841-3854.

[4] LIU S, WANG T, CAO J W, et al. Susceptibility assessment of precipitation-induced mass landslides based on optimal random forest model: Taking the extreme precipitation event in western Qinling mountains as an example[J]. Geological Bulletin of China, 2024, 43 (6): 958-970.

[5] 江宝得，李秀春，罗海燕，等. 异质集成学习在滑坡易发性评价中的对比研究[J]. 土木工程学报，2023，56 (10)：170-179.
JIANG B D, LI X C, LUO H Y, et al. Comparative study of heterogeneous ensemble learning in landslide susceptibility assessment [J]. Journal of Civil Engineering, 2023, 56 (10): 170-179.

[6] 黄发明，陈杰，杨阳，等. 滑坡易发性相关致灾环境因子研究的综述与展望[J]. 地质科技通报，2025，44 (2)：14-37.
HUANG F M, CHEN J, YANG Y, et al. A review and prospect of disaster-causing environmental factors related to landslide susceptibility prediction [J]. Bulletin of Geological Science and Technology, 2025, 44(2): 14-37.

[7] 骆飞，凌斯祥，高凤欣，等. 基于不同滑坡负样本选取策略和随机森林方法的岷江上游大型滑坡易发性评价[J]. 水利水电技术(中英文)，2025，56(9)：42-59.
LUO F, LING S X, GAO F X, et al. Large-scale landslide susceptibility evaluation in upper reaches of Minjiang River based on different selection methods for landslide negative samples and random forest algorithm[J]. Water Resources and Hydropower Engineering, 2025, 56(9): 42-59.

[8] CHEN Y T, LI N, ZHAO B J, et al. Comparison of informative modelling and machine learning methods in landslide vulnerability evaluation: A case study of Wenchuan County, China[J]. Geocarto International, 2024, 39(1): 2361714.

[9] HUANG F M, LIU K J, JIANG S H, et al. Optimization method of conditioning factors selection and combination for landslide susceptibility prediction [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2025, 17(2): 722-746.

[10] 周天游，刘畅，薛鹏，等. 基于不同机器学习的震后滑坡易发性建模研究[J]. 自然灾害学报，2023，32(5)：177-185.
ZHOU T Y, LIU C, XUE P, et al. Post-seismic landslide susceptibility modeling based on different machine learning methods [J]. Journal of Natural Disasters, 2023, 32(5): 177-185.

[11] 黄发明，曹昱，范宣梅，等. 不同滑坡边界及其空间形状对滑坡易发性预测不确定性的影响规律[J]. 岩石力学与工程学报，2021，40(S2)：3227-3240.
HUANG F M, CAO Y, FAN X M, et al. The influence of different landslide boundaries and their spatial shapes on the uncertainty of landslide susceptibility prediction [J]. Journal of Rock Mechanics and Engineering, 2021, 40(S2): 3227-3240.

[12] 崔玉龙，朱路路，徐敏，等. 基于环境因子优化 TSES 法选择负样本及其在滑坡易发性评价中的应用[J]. 地质科技通报，2024，

43(3)：192-199.
CUI Y L, ZHU L L, XU M, et al. Optimizing TSES method based on the environmental factors to select negative samples and its application in landslide susceptibility evaluation[J]. Bulletin of Geological Science and Technology, 2024, 43(3): 192-199.

[13] 王悦，曹颖，许方党，等. 考虑非滑坡样本选取和集成机器学习方法的水库滑坡易发性预测[J]. 地球科学，2024，49(5)：1619-1635.
WANG Y, CAO Y, XU F D, et al. Reservoir landslide susceptibility prediction considering non-landslide sampling and ensemble machine learning methods[J]. Earth Science, 2024, 49(5): 1619-1635.

[14] 郑德凤，高敏，闫成林，等. 基于卷积神经网络的滑坡易发性评价：以辽南仙人洞国家级自然保护区为例[J]. 地球科学，2024，49(5)：1654-1664.
ZHENG D F, GAO M, YAN C L, et al. Susceptibility assessment of landslides based on convolutional neural network model: a case study from Xianrendong national nature reserve in Southern Liaoning Province[J]. Earth Science, 2024, 49(5): 1654-1664.

[15] 张璇钰，刘桂卫，孙琪皓，等. 综合遥感技术在山区铁路泥石流勘察中的应用[J]. 铁道勘察，2024，50(1)：16-22.
ZHANG X Y, LIU G W, SUN Q H, et al. Application of comprehensive remote sensing technology in mountain railway debris flow survey[J]. Railway Investigation and Surveying, 2024, 50(1): 16-22.

[16] 丁明涛，陈浩杰，李振洪，等. 利用光学遥感影像光流场模型进行地表形变分析[J]. 武汉大学学报(信息科学版)，2024，49(8)：1314-1329.
DING M T, CHEN H J, LI Z H, et al. Analysis of surface deformations on the basis of optical flow field models from optical remote sensing images[J]. Geomatics and Information Science of Wuhan University, 2024, 49(8): 1314-1329.

[17] 白石，唐攀攀，苗朝，等. 基于高分辨率遥感影像和改进 U-Net 模型的滑坡提取：以汶川地区为例[J]. 自然资源遥感，2024，36(3)：96-107.
BAI S, TANG P P, MIAO Z, et al. Information extraction of landslides based on high-resolution remote sensing images and an improved U-Net model: A case study of Wenchuan, Sichuan[J]. Remote Sensing for Natural Resources, 2024, 36(3): 96-107.

[18] 冯谕，曾怀恩，涂鹏飞. 一种滑动检测算法下的滑坡位移时序分解方法[J]. 长江科学院院报，2024，41(3)：126-133.
FENG Y, ZENG H E, TU P F. A time series decomposition method for landslide displacement based on sliding detection algorithm[J]. Journal of Changjiang River Scientific Research Institute, 2024, 41(3): 126-133.

[19] 李文彬，范宣梅，黄发明，等. 不同环境因子联接和预测模型的滑坡易发性建模不确定性[J]. 地球科学，2021，46(10)：3777-3795.
LI W B, FAN X M, HUANG F M, et al. Uncertainties of landslide susceptibility modeling under different environmental factor connections and prediction models. Earth Science, 2021, 46(10): 3777-3795.

[20] 刘柄材，江兴元，孟生勇，等. 降雨与地下水联合入渗下斜坡变形机理研究[J]. 水利水电技术(中英文)，2025，56(3)：202-211.
LIU B C, JIANG X Y, MENG S Y, et al. Study on slope deformation mechanism under combined infiltration of rainfall and groundwater[J]. Water Resources and Hydropower Engineering, 2025, 56(3): 202-211.

[21] 吴 琼，王晓晗，唐辉明，等. 巴东组易滑地层异性层面剪切特性及水致劣化规律研究[J]. 岩土力学，2019，40(5)：1881-1889.
WU Q, WANG X H, TANG H M, et al. Shear property and water-induced deterioration of discontinuities between different types of rocks in Badong formation[J]. Rock and Soil Mechanics, 2019, 40(5): 1881-1889.

[22] 周毅阳，代文，王春，等. 数字高程模型空间分辨率对精细尺度地形变化检测的影响[J]. 山地学报，2023，41(3)：446-458.
ZHOU Y Y, DAI W, WANG C, et al. Spatial resolution of digital elevation models on fine-Scale topographic change detection[J]. Mountain Research, 2023, (3): 446-458.

[23] 宗振邦，王长虹，孙德安. 随机场-贝叶斯方法应用于非饱和土边坡稳定性可靠度分析[J]. 自然灾害学报，2021，30(2)：127-137.
ZONG Z B, WANG C L, SUN D A. Application of random field-Bayesian method in stability reliability analysis of unsaturated soil slope[J]. Journal of Natural Disasters, 2021, 30(2): 127-137.

[24] 谢洋义，殷坤龙，杜娟，等. 基于不同地质环境分区的重庆市滑坡降雨阈值模型研究[J]. 地质科技通报，2025，44(1)：126-137.
XIE Y Y, YIN K L, DU J, et al. Threshold model of landslide rainfall in Chongqing based on different geological environment zones[J]. Bulletin of Geological Science and Technology, 2025, 44(1): 126-137.

[25] SHAO W, CHEN S J, LI M J, et al. Reducing uncertainties in hydromechanical modeling with a recently developed Rosetta 3 podeotransfer function[J]. Engineering Geology, 2023, 324: 107250.

[26] 孙萍，张帅，柯超英，等. 黄土高原滑坡易发性评价及其关键驱动因子贡献度分析[J]. 地质力学学报，2025，31(5)：972-989.
SUN P, ZHANG S, KE C Y, et al. Evaluation of landslide susceptibility and contribution analysis of key driving factors on the Loess Plateau[J]. Journal of Geomechanics, 2025, 31(5): 972-989.

[27] ZHAI S Y, SUN Y, LEI J T, et al. An improved information quantity method for non-landslide selection to enhance landslide susceptibility evaluation: a case study in Yongfeng, South China[J]. Natural

Hazards，2025，121(10)：11773-11797.

[28] 曹文庚，潘登，徐郅杰，等. 河南省滑坡灾害易发性制图研究：多种机器学习模型的对比[J]. 地质科技通报，2025，44(1)：101-111.
CAO W G，PAN D，XU Z J，et al. Landslide disaster vulnerability mapping study in Henan Province：Comparison of different machine learning models[J]. Bulletin of Geological Science and Technology，2025，44(1)：101-111.

[29] 田尤，高波，殷红，等. 滑坡易发性评价中样本不均衡问题处理研究[J]. 水文地质工程地质，2024，51(6)：171-181.
TIAN You，GAO Bo，YIN Hong，et al. Handling imbalanced samples in landslide susceptibility evaluation[J]. Hydrogeology & Engineering Geology，2024，51(6)：171-181.

[30] 高志良，解明礼，巨能攀，等. 堆积层滑坡多源遥感动态演变特征分析研究[J]. 武汉大学学报（信息科学版），2024，49(8)：1482-1491.
GAO Z L，XIE M L，JU N P，et al. Multi-source remote sensing dynamic deformation monitoring of accumulation landslide[J]. Geomatics and Information Science of Wuhan University，2024，49(8)：1482-1491.

[31] CUI H Z，MEDINA V，HUERLIMANN M，et al. Fast physically-based probabilistic modelling of rainfall-induced shallow landslide susceptibility at the regional scale considering geotechnical uncertainties and different hydrological conditions[J]. Computers and Geotechnics，2024，172：106400.

[32] 白光顺，杨雪梅，朱杰勇，等. 基于证据权法的昆明五华区地质灾害易发性评价[J]. 中国地质灾害与防治学报，2022，33(5)：128-138.
BAI G S，YANG X M，ZHU J Y，et al. Susceptibility assessment of geological hazards in Wuhua District of Kuming，China using the weight evidence method[J]. The Chinese Journal of Geological Hazard and Control，2022，33(5)：128-138.

[33] ZHU A X，MIAO Y M，LIU J Z，et al. A similarity-based approach to sampling absence data for landslide susceptibility mapping using data-driven methods[J]. Catena，2019，183：104188.

[34] 洪浩源，王德生，朱阿兴. 面向机器学习型区域滑坡易发性评价的训练样本采样方法[J]. 地理学报，2024，79(7)：1718-1736.
HONG H Y，WANG D S，ZHU A X. A new training data sampling method for machine learning-based landslide susceptibility mapping[J]. Acta Geographica Sinica，2024，79(7)：1718-1736.

[35] CHEN C Z，SHEN Z Q，FANG L M，et al. Incorporating modelling uncertainty and prior knowledge into landslide susceptibility mapping using Bayesian neural networks[J]. Georisk-Assessment and Management of Risk for Engineered Systems and Geohazards，2024，11：2422498.

[36] 吴宏阳，周超，梁鑫，等. 基于 XGBoost 模型的三峡库区燕山乡滑坡易发性评价与区划[J]. 中国地质灾害与防治学报，2023，34(5)：141-152.
WU H Y，ZHOU C，LIANG X，et al. Assessment of landslide susceptibility mapping based on XGBoost model：A case study of Yanshan Township[J]. The Chinese Journal of Geological Hazard and Control，2023，34(5)：141-152.

[37] 王中羽，李素敏，袁利伟，等. 考虑影响因子重要性选择和土壤含水率的滑坡易发性评价[J]. 水文地质工程地质，2025，52(3)：211-221.
WANG Z Y，LI S M，YUAN L W，et al. Landslide susceptibility evaluation considering the importance selection of influencing factors and soil moisture content[J]. Hydrogeology & Engineering Geology，2025，52(3)：211-221.

（责任编辑　王海锋）