

基于信息量优化策略和CNN-LSTM模型的地质灾害易发性制图：以西盟县为例

谷 雨

云南师范大学地理学部，云南 昆明

收稿日期：2025年10月23日；录用日期：2026年3月20日；发布日期：2026年3月30日

摘 要

云南省西盟佤族自治县位于“中印缅孟经济走廊”战略枢纽，开展精细化地质灾害易发性评价研究，对于保障该区域重大基础设施建设安全、优化国土空间开发格局具有重要意义。针对一般评价流程中负样本选取策略对评价模型精度的影响以及传统深度学习方法中的数据依赖，分类结果的不可解释性等问题，利用信息量法(Information Value, IV)结合卷积神经网络(CNN)进行静态空间特征深度提取以及长短期记忆网络(LSTM)捕捉降雨时序动态，创新性地提出了一种IV-CNN-LSTM耦合模型架构。通过与CNN-LSTM模型、RF模型和XGBoost模型的预测结果进行对比评估表明：信息量模型的应用有效提高了CNN-LSTM模型的预测效果，IV-CNN-LSTM模型的ROC曲线下面积(area under curve, AUC)值为0.9845，具有更好的预测效果，同时其他四项指标也均优于单一模型。灾害点的94.51%落入中易发等级以上区域，71.95%落入高易发等级以上区域，易发等级为高以上的区域主要沿公路网分布，结合SHAP分析方法，揭示了人类工程活动是该区域地质灾害的主要诱因。本文研究结果可为滇西南边境地区灾害链式防控提供了科学决策依据和有效参考。

关键词

模西盟县，信息量，IV-CNN-LSTM，SHAP分析，灾害易发性评价

Mapping Geological Hazard Susceptibility Using an Information Content Optimization Strategy and a CNN-LSTM Model: A Case Study of Ximeng County

Yu Gu

Faculty of Geography, Yunnan Normal University, Kunming Yunnan

Received: October 23, 2025; accepted: March 20, 2026; published: March 30, 2026

文章引用：谷雨. 基于信息量优化策略和 CNN-LSTM 模型的地质灾害易发性制图：以西盟县为例[J]. 地球科学前沿, 2026, 16(3): 430-449. DOI: 10.12677/ag.2026.163039

Abstract

Ximeng Wa Autonomous County in Yunnan Province is in the “China-India-Myanmar-Bangladesh Economic Corridor” strategic hub. It is of great importance to conduct a geological hazard vulnerability assessment study to ensure the safety of the major infrastructure construction in the region and to optimise the spatial development pattern of the national territory. Considering the influence of the negative sampling strategy on the accuracy of the evaluation model in the general evaluation process, as well as the data dependency and non-interpretability of the classification results in the traditional deep learning method, an innovative approach is proposed by using the Information Value (IV) method in combination with the Convolutional Neural Network (CNN) for the deep extraction of the static spatial features and the Long Short-Term Memory (LSTM) for the acquisition of the rainfall temporal sequences. Dynamics, an innovative coupled IV-CNN-LSTM model architecture, is proposed. The evaluation results are compared and evaluated with the prediction results of the CNN-LSTM model, RF model and XGBoost model. The research results show that applying the informative model effectively improves the prediction effect of the CNN-LSTM model. The IV-CNN-LSTM model, with a value of 0.9845 for the area under the curve (AUC) of the ROC curve, has a better prediction effect, while the other four indicators are also better than the single model. 94.51% of the disaster sites fall into the area above the medium susceptibility level, 71.95% fall into the area above the high susceptibility level, and the areas with high susceptibility levels are mainly distributed along the highway network, which combined with the SHAP analysis method proves that the main causative factor of geohazards in this region is human engineering activities. The results of this paper can provide a scientific basis for decision-making and a practical reference for preventing and controlling the disaster cascade in the border area of southwest Yunnan.

Keywords

Ximeng County, Information Value, IV-CNN-LSTM, SHAP Analysis, Hazard Susceptibility Assessment

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

在全球气候变化与高强度人类活动的双重作用下，地质灾害已成为威胁山区可持续发展的重要致灾因子[1]。根据应急管理部最新发布的《2024 年全国自然灾害基本情况》[1]，我国去年共发生地质灾害 3897 起，造成直接经济损失 2630.4 亿元，占全年自然灾害总损失的 65.6%，其中滑坡、崩塌、泥石流等突发性灾害导致 709 人死亡失踪，占全部自然灾害伤亡人数的 82.8%。特别是以云南、四川为代表的西南地区地质灾害的发生频率高且危害严重，这些地区常常处于自然灾害高发区，亟需进行有效的灾害评估和防范[2] [3]。传统易发性评价主要依赖层次分析法(AHP)、频率比法(FR)及逻辑回归(LR)为代表的统计方法，随着研究的深入，学者们不断尝试通过更精确的模型和多维度的数据处理手段，提升预测的精度与适用性[2]。近年来，遥感技术凭借多源数据获取(如 Sentinel-2 光学影像、Sentinel-1 InSAR 形变数据)与时空连续性优势，为滑坡动态监测提供了新手段。然而，现有研究多采用支持向量机(SVM)、随机森林(RF)等传统机器学习模型，在数据处理和模型构建方面表现出较高的灵活性和适应性，能够有效应对不同类型的地质灾害，尤其在捕捉高维数据特征、提高模型泛化能力和预测精度方面展现出明显优势[3]，

此外,多模型集成技术的引入进一步提升了评价结果的稳健性和适用性[4]。崔婷婷[5]等通过机器学习模型结合贝叶斯优化算法,提高了三峡库区易发性评价的精度;杨灿[6]在机器学习的基础上进一步分析了多因子组合特征的影响并提出考虑组合特征的 AFM 模型解释了灾害发生的内在原因。但其特征工程依赖于时空耦合建模能力不足的问题制约了预测精度。

随着人工智能技术的发展,深度学习在各个领域的应用得到了广泛关注。国内外学者已将深度学习方法引入灾害易发性评价,以进一步提高预测准确性,特别是卷积神经网络(convolution neural network, CNN)和长短期记忆网络(Long Short-Term Memory, LSTM),在地质灾害的研究中显示出巨大的潜力。CNN 能够自动提取空间特征,而 LSTM 擅长捕捉时序数据中的动态特性,二者结合能够有效提升地质灾害易发性预测的精度和时效性。尽管深度学习模型(如 CNN、LSTM)在单模态数据处理中展现出优势,但在时空特征解耦、可解释性缺失、数据集的质量直接影响深度学习网络的预测结果等方面仍有许多待持续优化的问题,针对这些现状,王守华[7]等基于卷积神经网络(convolution neural network, CNN)和长短期记忆网络(Long Short-Term Memory, LSTM),结合确定性系数法(certainty factor, CF)提出的 CF-CNN-LSTM 模型通过引入确定性系数法优化非滑坡样本选择,显著提升了模型对正负样本特征的区分能力,其 AUC 值达 0.953,较单一 CNN 或 LSTM 模型提高 10%~15%。该研究进一步验证了时空耦合模型在复杂地质环境中的应用潜力,为本文提出的“IV-CNN-LSTM”模型提供了重要方法论参考;徐胜华[8]等利用深度增强模块(deep feature enhancement module, DFEM)和多尺度特征融合模块(multi-scale feature fusion module, MSFF)建立多尺度特征学习轻量化网络,在精度和轻量化方面均取得了提升,提出的多尺度特征学习轻量化网络(MFL-LN)通过深度可分离卷积与注意力机制,在保持模型精度的同时将参数量降低至 0.081M,浮点运算量减少至 41.102GFLOPS,为解决深度学习模型复杂度问题提供了新路径;邓日朗[9]等提出一种结合信息量(information value, IV)和间谍技术(Spy)的两步卷积神经网络框架(Spy-CNN),达到从低信息量样本中识别出高置信度样本的目的,从而确保了评价结果的准确性;缪亚敏[10]等提出基于地理环境相似度的负样本可信度量方法,通过量化样本与滑坡正样本的环境相似性识别潜在危险点,有效提升了负样本质量,为解决样本不平衡问题提供了新思路。刘帅[11]等通过地理探测器与遗传算法优化随机森林模型,在西秦岭极端降雨事件中实现了 0.877 的 AUC 值,其基于面状滑坡数据的缓冲区样本筛选方法及多因子定量表征技术,为本研究的样本优化与因子融合提供了新的技术路径。该研究特别强调极端降雨条件下前期有效降雨与地形因子的耦合作用,与本研究关注的多源数据动态融合具有显著互补性[12][13]。本研究将进一步借鉴其思想,探索时空特征解耦与多模态数据融合的协同优化,以突破现有模型的局限性。

本文以西盟县为研究区,提出“IV-CNN-LSTM”模型架构,选取了 10 个静态空间因子和 1 个时序动态因子构建多特征矩阵,并与 CNN-LSTM、RF 及 XGBoost 模型进行了对比实验,全面分析评估了各模型的性能指标,验证 IV-CNN-LSTM 模型用于西盟县的灾害易发性评价的可行性。深入研究西盟的地质情况,可为未来区域的资源开发、环境保护和基础设施建设提供科学依据,助力经济走廊的可持续发展,为《全国地质灾害防治“十四五”规划》提出的“精细化风险管控”提供技术支撑。

2. 研究方法

2.1. CNN 模型

近年来,卷积神经网络(CNN)已成为深度学习的核心研究领域,并在多个应用场景中取得了显著成效。作为一种自动化特征提取工具,CNN 能够通过学习数据中的显著特征,避免了人工设计复杂规则的需求[14][15]。典型的 CNN 架构包括卷积层、池化层和全连接层,它们交替堆叠,其中卷积层是 CNN 的核心模块。每一层的卷积操作负责从上一层提取更加精细的特征[16]-[18]。卷积运算公式如下:

$$Y = f(W \otimes X + b) \tag{1}$$

其中, W 表示卷积核的权重, X 为输入特征, Y 为输出, b 为偏置项, f 为激活函数, \otimes 表示卷积操作。CNN 的共享权重策略使得与传统全连接网络相比, 所需参数更少, 从而提高了训练效率。池化层的主要功能是通过下采样减少特征的维度, 同时保留重要的信息, 从而提高模型的泛化能力, 减少过拟合的风险[16]。池化操作的公式为:

$$Y = pool(X) \tag{2}$$

其中, X 为输入特征, Y 为池化后的输出。全连接层则负责将卷积和池化层提取的高维特征映射到最终的分类或回归结果。通过 CNN 模型提取特征, 能够有效去除数据中的冗余信息, 保留与灾害易发性评价相关的关键信息。

2.2. LSTM 模型

长短期记忆网络(LSTM)是循环神经网络(RNN)的一个变种, 旨在解决 RNN 中的长期依赖问题, 以及梯度爆炸和梯度消失等问题。与传统神经网络不同, LSTM 的结构包含输入层、一个或多个隐藏层以及输出层。典型的 LSTM 单元包括遗忘门、输入门和输出门, 这些门控制信息的流动和记忆的更新。具体而言, LSTM 通过遗忘门决定当前单元状态中应该丢弃哪些信息, 通过输入门决定新信息的更新量, 通过输出门控制当前单元状态对输出的影响。假设在时刻 t , 遗忘门、输入门和输出门的向量分别为 f_t 、 i_t 、 o_t , 则时刻 t 的隐藏层状态可以通过以下计算公式更新

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \tag{3}$$

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \tag{4}$$

$$f_o = \sigma(W_o [h_{t-1}, x_t] + b_o) \tag{5}$$

$$g_t = \tanh(W_g [h_{t-1}, x_t] + b_g) \tag{6}$$

$$c_t = f_t \times c_{t-1} + i_t \times g_t \tag{7}$$

$$h_t = o_t \times \tanh(c_t) \tag{8}$$

其中, f_t 为遗忘门, i_t 为输入门, o_t 为输出门, c_t 为记忆单元状态, h_t 为隐藏状态, x_t 为当前输入。

模型的最终输出通过全连接层融合静态和时序特征, 生成灾害发生的概率 P :

$$P = \sigma(W_{final} [h_t, Z] + b_{final}) \tag{9}$$

其中, σ 为 sigmoid 激活函数, W_{final} 和 b_{final} 为权重和偏置。

2.3. 信息量模型

信息量模型是以信息论为基础建立的用于统计评测的数学模型, 属于贝叶斯模型的一种, 该方法利用信息熵来分析在各因素的综合作用下地质灾害的易发性程度的模型, 其基本观点认为, 地质灾害的产生与否或发生概率与预测过程中所获取的已变形或破坏区域信息的数量和质量有关[19]-[22], 事件发生的概率越低那么在其发生时其表现出的信息量越大, 表示该指标的“贡献率”越大, 且相互独立事件所体现的信息量相互之间不受影响。基于这一理论对评价地质体稳定性的各评价因子的信息量的计算, 把影响不良地质现象的各种因素的实测值转变为信息量值, 该信息量值可以用来反映其易发性[23] [24]。信息量法的关键就在于计算并比较各评价因子对研究区地质灾害所贡献的信息量大小[25]。

信息量用概率来计算，其公式如下：

$$I(Y, x_1, x_2, \dots, x_n) = \ln \frac{P(Y, x_1, x_2, \dots, x_n)}{P(Y)} \quad (10)$$

式中： $I(Y, x_1, x_2, \dots, x_n)$ 为各因子组合 x_1, x_2, \dots, x_n 对地质灾害所提供的信息量值， $P(Y, x_1, x_2, \dots, x_n)$ 为各因子 x_1, x_2, \dots, x_n 组合下地质灾害发生的概率， $P(Y)$ 是地质灾害发生的概率。

通过建立信息量模型，对研究区域内的地质灾害进行评价并对其灾害易发性进行预测，结合各评价因子特征进行叠加分析，针对区域内离散分布的灾害点区域进行整合，总结出具有一定地质规律的高完整度分区情。

通常情况下，地质灾害成因复杂，孕灾及诱灾因素多，且存在相互影响，所以在信息量模型的建立过程中，一般对各评价因子的信息值进行独立计算，再根据实际的权重占比，将各评价因子独立的信息量值进行综合叠加分析。信息量模型公式为：

$$I = \sum_{i=1}^n I_i = \sum_{i=1}^n \ln \frac{N_i/N}{S_i/S} \quad (i=1, 2, 3, \dots, n) \quad (11)$$

式中： I 表示研究区内总的信息量，当评价因子的信息量值越大，说明该因子引发地质灾害的可能性就越高； I_i 为所选取的评价因子 x_i 的信息量； N 为研究区已知地质灾害点的单元总数； N_i 为研究区内对应评价因子 x_i 范围内的地质灾害点的单元数； S 为研究区评价单元总数； S_i 为因子 x_i 的分布单元数。

2.4. IV-CNN-LSTM 模型

本研究提出了一种 IV-CNN-LSTM 的地质灾害易发性评价模型架构。首先，以 IV 模型作为先验模型对研究区进行初步的易发性评估并通过自然间断法将其分为四个等级(低易发区、中易发区、高易发区和极高易发区)，同时结合以历史灾害样本点为中心设立缓冲区并随机生成负样本点，以 IV 模型划分的易发区域作为约束，对生成的负样本点进行优化选取，在高易发区和极高易发区外选取与历史灾害样本同样数量的负样本构建数据集，该方法通过空间约束避免负样本选择的随机性带来的误差。基于历史灾害点和非灾害点构建数据集，将 70%数据作为训练集，30%作为验证集，分别用于模型的训练和评估。数据通过输入层传入，CNN 层提取关键特征，提取的特征随后传递到 LSTM 层进行深入分析。最后，通过全连接层和 Softmax 层输出最终的预测结果，流程见图 1。




Figure 1. IV-CNN-LSTM model structure
图 1. IV-CNN-LSTM 模型结构

该方法通过优化负样本选择策略和利用 IV 模型进行初步评估，并将 CNN 在提取重要的地质灾害特征及 LSTM 解决传统循环神经网络中的长期依赖和梯度问题[26]的优势相结合。结合传统统计方法与深度学习方法，从而提高了模型的准确性，显著提高了易发性评价的精度和预测能力。与一般机器学习和深度学习模型相比，该组合模型在处理复杂灾害特征数据时表现更为优越。模型的工作流程如图 2 所示。

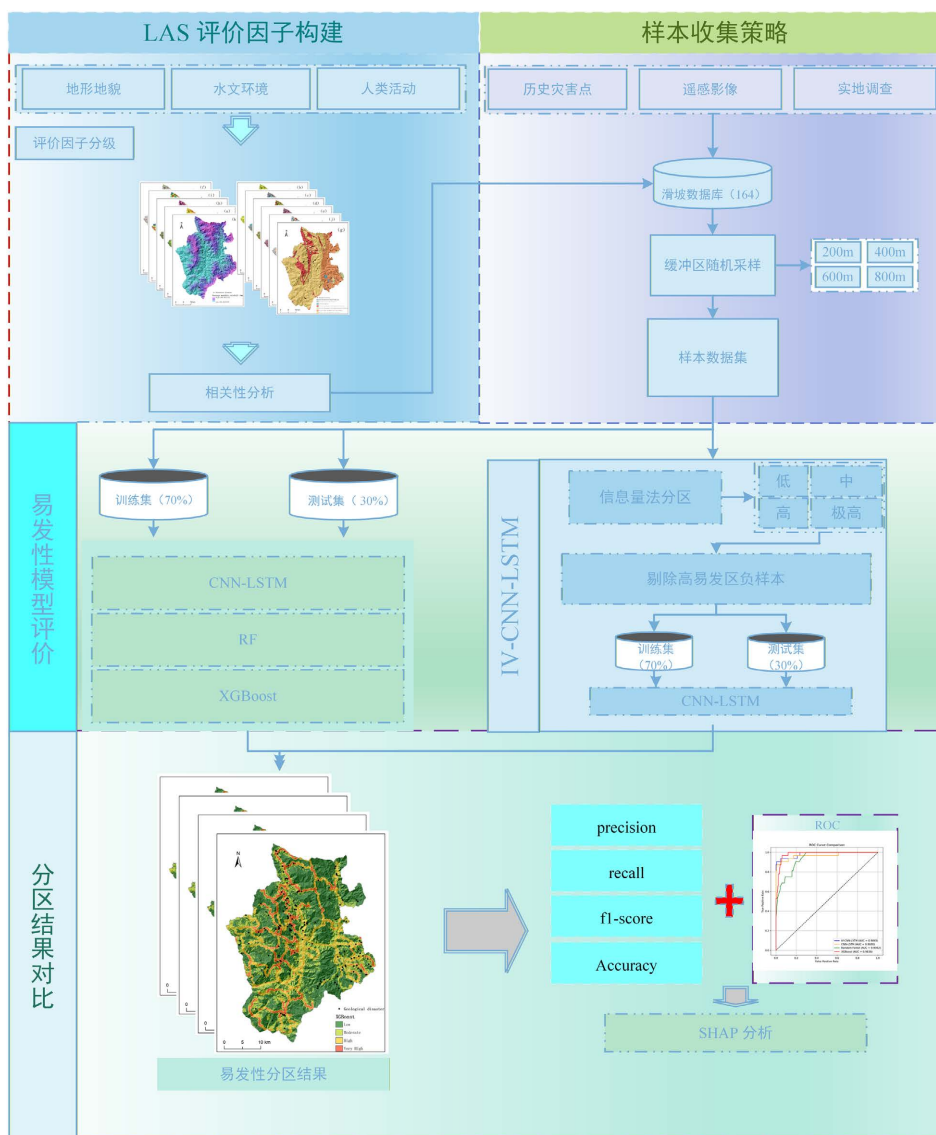


Figure 2. Flowchart of the evaluation process
图 2. 评价流程示意图

3. 研究区概况及数据源

3.1. 研究区概况

西盟佤族自治县位于 99°18'~99°43'E, 22°25'~22°57'N, 作为“中印缅孟经济走廊”的重要节点, 同时是“兴边富民”重点县, 东南与澜沧县、孟连县接壤, 西北与缅甸交界, 国境线长达 89.33 公里, 行政辖区面积为 1353.57 km², 位于怒山山脉南段与澜沧江断裂带交汇区, 山区占比达 99.9%, 新构造运动活跃, 地层发育完整, 属中高山深切峡谷地貌, 地势东北高、西南低, 相对高差达 1869.9 m, 具有显著垂直分异特征。年均降雨量 2758.3 毫米, 雨季降水量占全年降水的 85% 以上。人类活动频繁, 主要表现为居住区的斜坡坡脚开挖以及公路网的建设, 形成以瑞孟高速为骨架、山区公路为支线的路网格局, 不可避免地影响到边坡的稳定性。复杂的地质环境、强降雨及人类工程活动的密集, 成为该区域地质灾害的重要诱因, 研究区范围及灾害点分布情况见图 3。

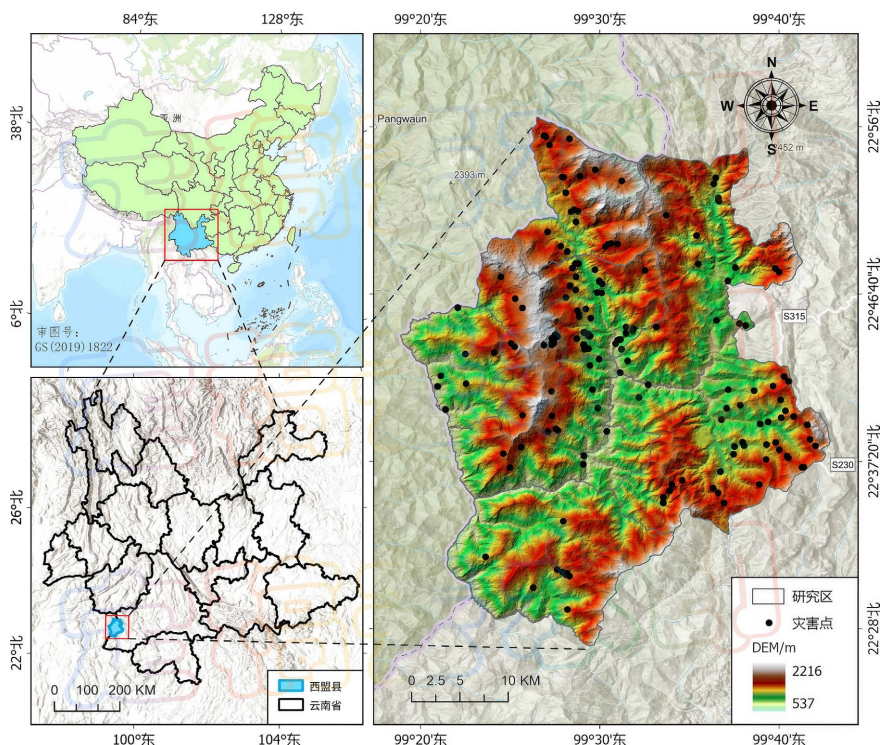


Figure 3. Ximeng county location map
图 3. 研究区历史灾害点分布图

3.2. 数据来源

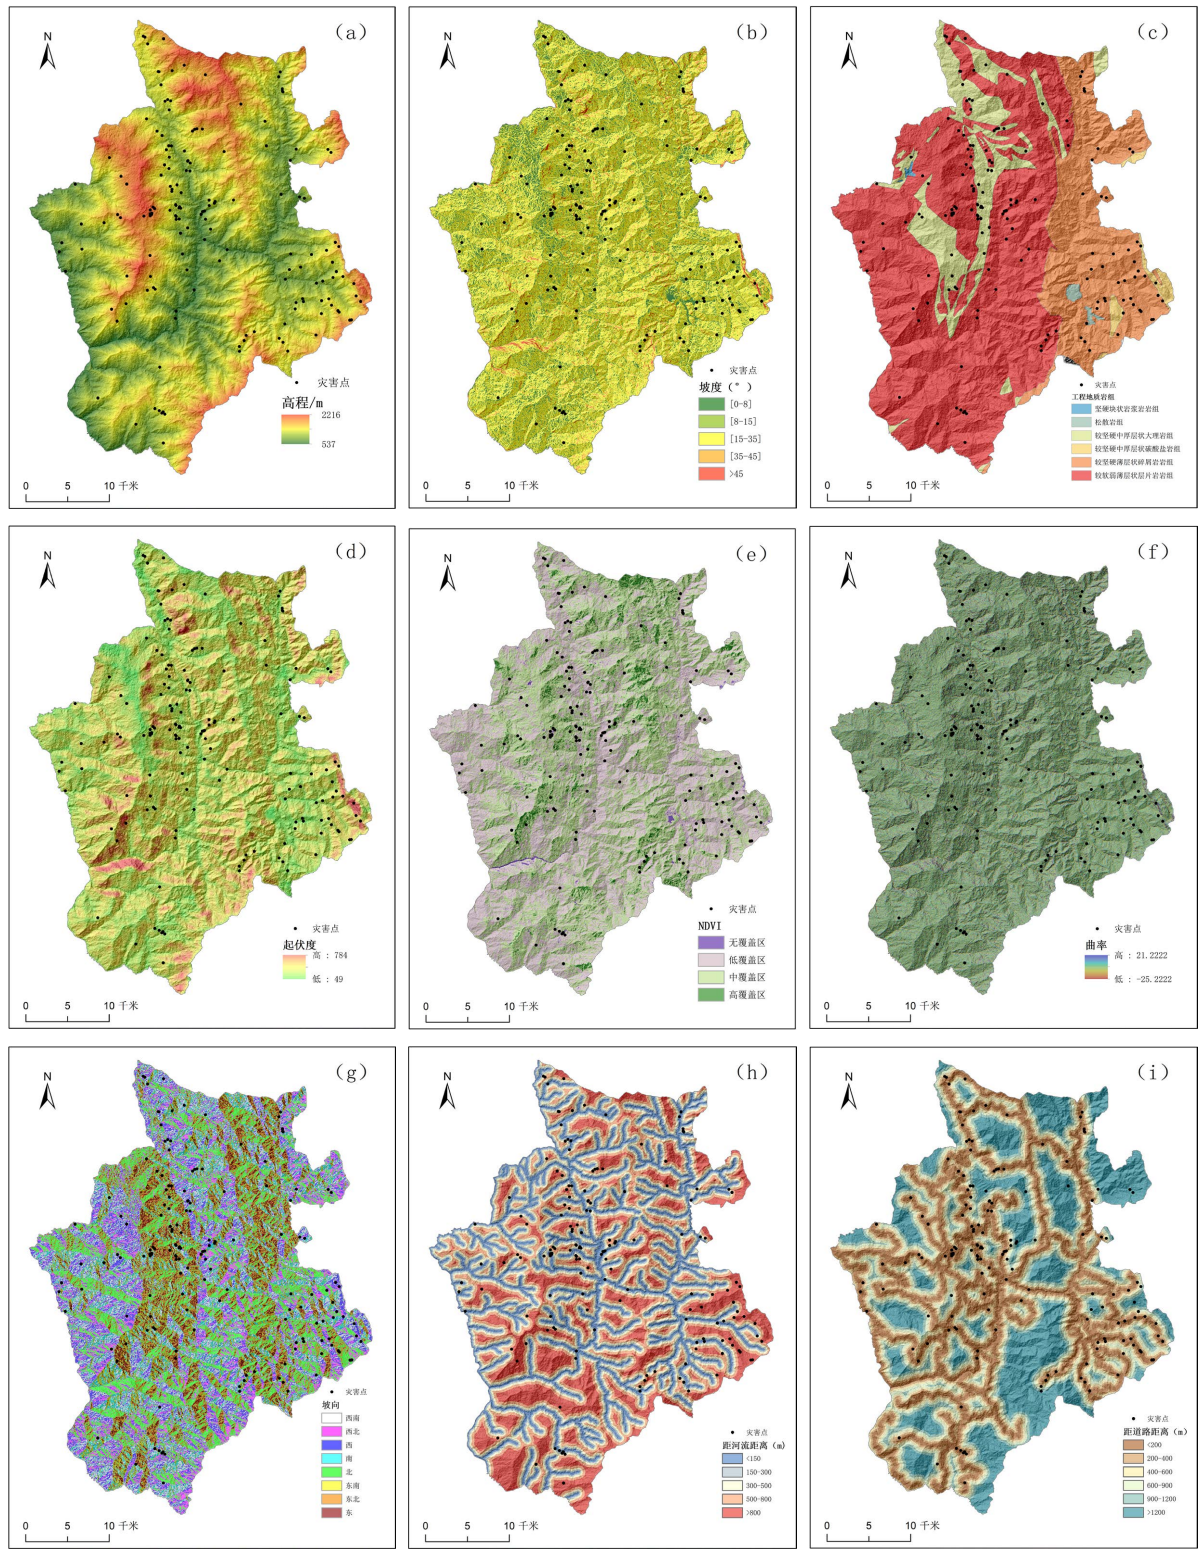
影响地质灾害的因素很多，且各因素间关系复杂，影响程度大小也各不相同，选取合适的评价因子尤为重要[27]。本文数据来源包括：① 云南省地质科学研究所西盟佤族自治县地质环境与地质灾害 1:50,000 详细调查成果，以获取道路、岩土结构、地质断层及灾害点历史数据等信息，根据 2016~2020 年地质灾害历史数据，该地区地质灾害类型主要分为滑坡、崩塌、地面塌陷及泥石流，区域内发育地质灾害 164 处(图 1)，其中滑坡 142 处，占总数的 86.6%；崩塌 11 处，占总数的 6.6%；地面塌陷 6 处，占总数的 3.7%；泥石流 5 处，占总数的 3.1%；② 使用 Landsat-8 遥感数据(Google Earth Engine, <https://earthengine.google.com/>)用于提取 NDVI 指数；③ 数字高程模型(digital elevation model, DEM)数据来源于地理空间数据云(<https://www.gscloud.cn/>)。所有数据均统一为 30 m × 30 m 空间分辨率。

4. 数据集构建

4.1. 评价因子的选取

选取高程、坡度、坡向、起伏度、曲率、岩性、断层、NDVI、道路、水系等 10 个静态因子以及降雨作为动态因子，共计 11 个评价因子，其中，岩土体的物理化学特性决定了灾害发育的可能性[28] [29]；高程变化不仅为坡体滑动提供了势能，还反映了人类活动的范围；坡度、坡向和曲率等其它地形因子反映了坡体自然结构对地质灾害发育的影响，一般坡度越大越容易引发地质灾害，不同坡度范围的灾害类型也有不同侧重[29]；断层因子影响了地质层的稳定性，对地质灾害形成有重要影响[30]；水系因子代表研究区内重要水流侵蚀对灾害发育的贡献程度；归一化植被指数(NDVI)作为衡量植被状况的指标，直接反映了地表植被的茂盛程度，低 NDVI 值区域植被覆盖较少，土壤容易被雨水冲刷，导致斜坡稳定性降

低；距道路的距离能够反映人类工程活动对地表扰动的强度，道路修建过程中对山体开挖容易造成边坡失稳[30]，评价因子分级结果如见图 4。



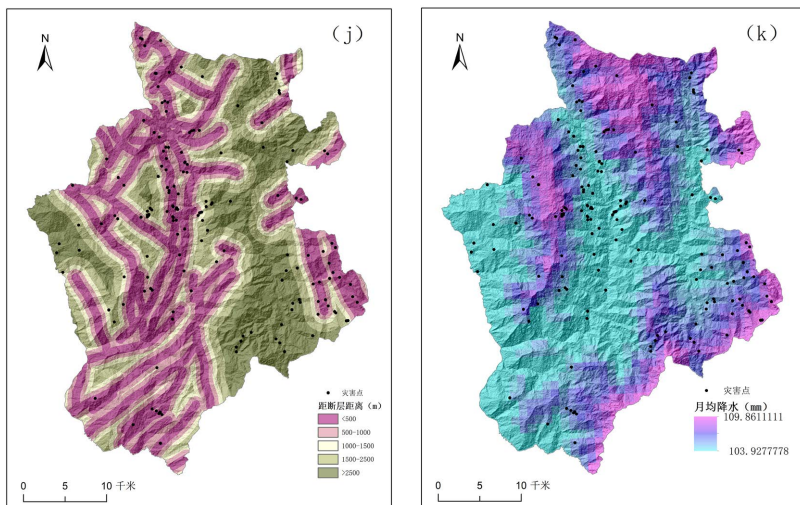


Figure 4. Grading of evaluation factors
图 4. 评价因子分级

4.2. 因子独立性分析

地质灾害的致灾因子间常存在复杂相关性，尽管传统统计模型(如逻辑回归)可通过方差膨胀因子(VIF)等手段诊断共线性并调整参数，其影响在合理预处理后相对可控，但对于深度学习模型，因子相关性可能导致特征权重分配偏差、过拟合风险加剧或计算效率下降，因此在特征工程阶段必须系统考量[31]，本文采用方差膨胀因子(variance inflation factor, VIF)和容忍度(tolerance, TOL)对各因子进行共线性分析，通过皮尔逊相关性系数检验因子间的独立性。在 90%置信区间下各因子共线性分析结果如表 1 所示。各因子的 VIF 值均小于 5，TOL 值均高于 0.2，证明因子不存在共线性。皮尔逊相关性分析结果如图 5 所示，可知所有因子相关系数均低于 0.6，故可判断所选择的所有因子相互独立，不存在共线性关系，可全部用于评价建模。

Table 1. Factor collinearity
表 1. 因子共线性

评价因子	VIF	TOL
高程	1.158	0.863
坡度	1.317	0.760
岩性	1.244	0.804
起伏度	1.208	0.828
NDVI	1.449	0.690
曲率	1.067	0.937
坡向	1.089	0.918
河流	1.167	0.857
道路	1.565	0.639
断层	1.584	0.631
降雨	1.108	0.903




Figure 5. Pearson correlation coefficient diagram of characteristic factors
图 5. 特征因子皮尔逊相关系数图

4.3. 非灾害点样本选取及数据集建立

利用(11)式计算各因子信息量值(表 2)，通过 ArcGIS 软件进行加权叠加处理，获取研究区易发性指数，根据自然间断法将研究区划分为四个易发等级，得到信息量模型下的易发性分区结果如图 6。

Table 2. Information content calculation results

表 2. 信息量值计算结果

评价因子	评价因子分级	灾害点数/处	信息量值	评价因子	评价因子分级	灾害点数/处	信息量值
坡度(°)	0~8	15	0.2879	距断层距离(m)	0~500	69	0.3492
	8~15	37	0.2776		500~1000	35	-0.0310
	15~35	107	-0.0723		1000~1500	15	-0.3651
	35~45	5	-0.7494		1500~2500	19	-0.3262
	45~90	0	0		>2500	26	-0.1852
高程(m)	0~900	15	-0.2153	距道路距离(m)	0~200	63	1.2574
	900~1300	82	0.0765		200~400	19	0.2518
	1300~1700	54	0.0847		400~600	6	-0.7820
	1700~2000	13	-0.2370		600~900	7	-0.8971
	>2000	0	0		900~1200	3	-1.5850

续表

曲率	凹形坡	81	0.0132	坡向	>1200	66	-0.2692
	平坡	3	-0.5095		北	33	-0.1995
	凸形坡	80	0.0117		东北	13	-0.1995
NDVI	无覆盖	40	0.7909	坡向	东	21	0.0472
	低覆盖	46	-0.0382		东南	17	0.4180
	中覆盖	53	-0.0497		南	29	0.0014
	高覆盖	25	-0.5275		西南	25	0.2931
距河流距离(m)	0~150	28	-0.2475	起伏度	西	16	0.1072
	150~300	46	0.1609		西北	12	-0.3953
	300~500	14	0.1634		49~350	10	-0.3793
	500~800	50	-0.1404		350~500	117	-0.0893
	>800	26	-0.0849		500~600	33	0.0148
工程地质岩组	较坚硬中厚层状大理岩组	31	0.4369	月均降雨(mm)	600~700	3	0.1375
	较软弱薄层状层片岩岩组	78	0.3006		>700	1	0.3958
	较坚硬薄层状碎屑岩岩组	31	-0.1555		103~104.5	103	0.0025
	较坚硬中厚层状碳酸盐岩组	2	0.2466		104.5~106	47	0.1542
	松散岩	22	3.4714		106~107.5	12	-0.4633
	坚硬块状岩浆岩岩组	0	0		107.2~109	2	0.0490

在深度学习模型的训练数据集中,历史灾害点通常作为正样本,而非灾害点(负样本)则常通过随机选取与正样本数量相等的非灾害区域点获得,然而,这种随机选择策略存在明显缺陷:可能将实际位于潜在高易发区的点误选为负样本,造成数据集的可信度波动较大,影响最终的评价精度。针对这一现状,大多数研究采用以历史灾害点为中心,设立不同距离的缓冲区范围,并在一定缓冲距离缓冲区外随机选择非灾害点作为负样本的方法[28][32],该方法只根据非灾害点与灾害点的距离判断负样本可信度,缺乏空间约束,导致非灾害点特征不明显,无法全面代表非灾害区域的特征,从而使正负样本的特征差异不够明显,进而引发过拟合和梯度爆炸等问题,最终影响预测精度。

为避免这种问题,本文采用信息量(IV)模型对西盟县进行初步的易发性评价(图6)。剔除高易发区和极高易发区,在低易发区和中易发区随机选取与历史灾害点(正样本)数量相等的非灾害点作为负样本。将所有样本按照7:3划分为训练集和测试集,训练集用于对IV-CNN-LSTM模型的训练,测试集用于验证。通过这种方法引入空间约束,使负样本的选择更具代表性,确保其特征更加鲜明,从而有效减少模型过拟合的风险,提高预测精度。

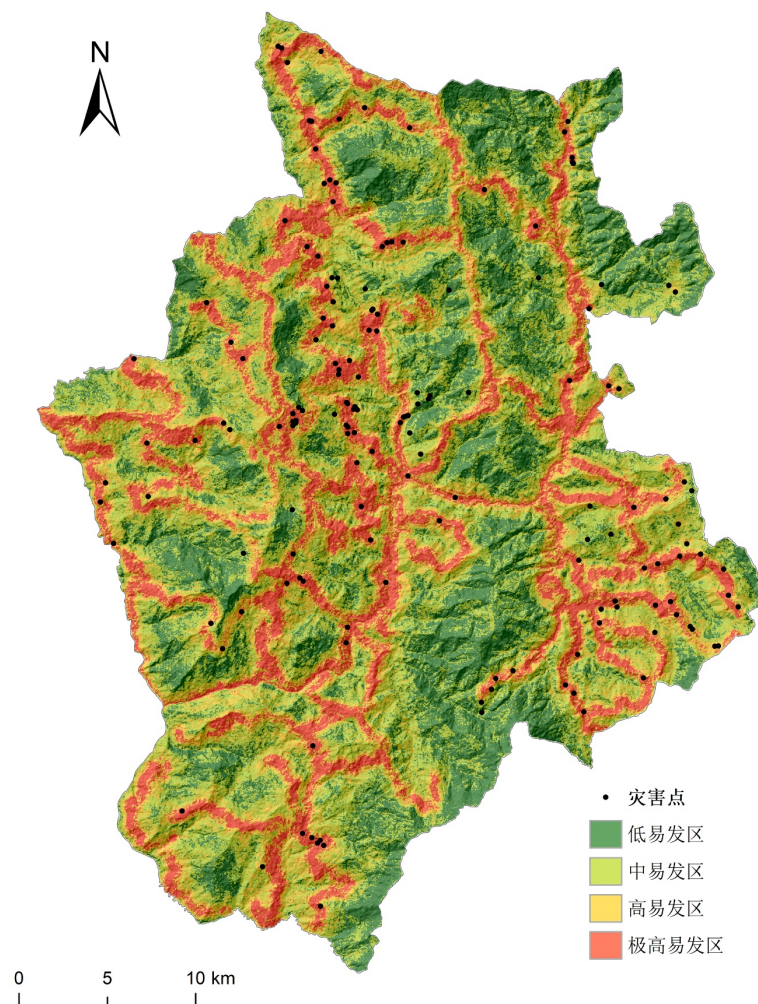


Figure 6. Information model susceptibility evaluation
图 6. 信息量模型易发性评价

5. 结果分析

5.1. 基于 IV-CNN-LSTM 模型的灾害易发性评价

本文结合信息量模型的先验分区结果，优化高易发区的负样本，将得到的最终数据集输入 CNN-LSTM 模型进行训练。该模型基于 PyTorch 框架构建，设置了 80 个隐藏层节点，学习率为 0.0053，训练迭代次数为 800 次，并设立了早停机制避免出现过拟合。完成模型训练后，作为模型的输入，并绘制相应的地质灾害易发性评价图(见图 7)。

5.2. 精度对比

为评估 IV-CNN-LSTM 模型的可靠性，选取 CNN-LSTM、XGBoost 和随机森林(RF)模型进行了对比实验。CNN-LSTM 模型的参数设置与 IV-CNN-LSTM 一致。将研究区的所有栅格数据输入各模型，计算得到每个栅格的地质灾害发生概率，即灾害易发性指数，根据灾害易发性指数，根据模型输出的灾害发生概率值，采用累积百分比法将研究区划分为四个易发等级：低易发区(0%~45%)、中易发区(45%~60%)、高易发区(60%~85%)和极高易发区(85%~100%)。各模型的易发性分区结果见图 8。

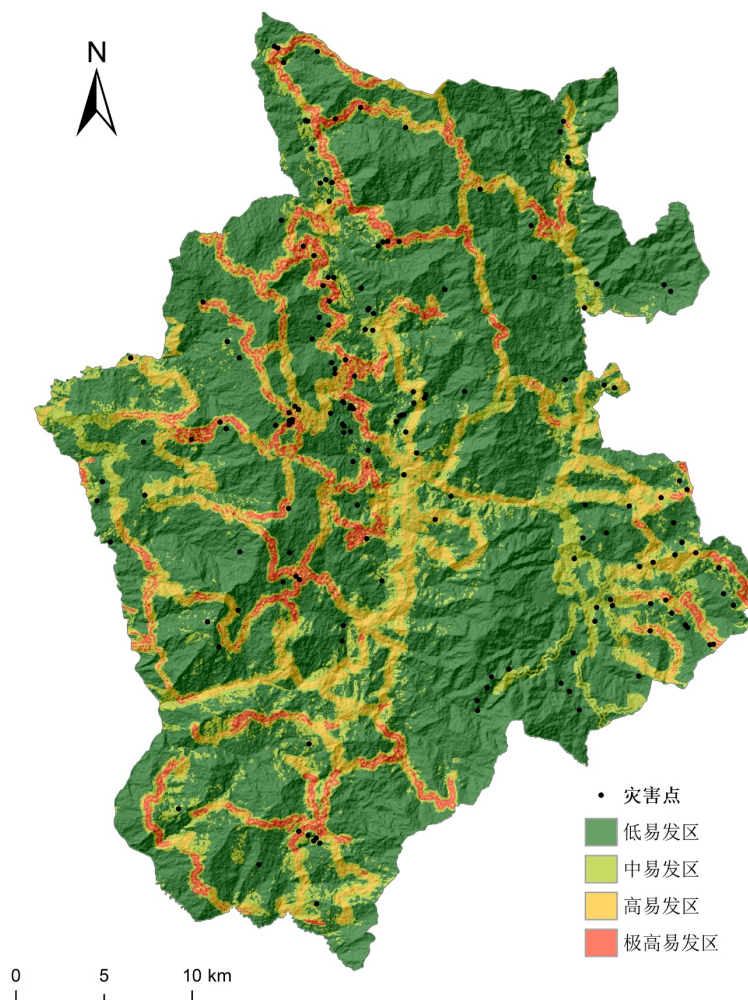


Figure 7. Results of the vulnerability assessment for the IV-CNN-LSTM model
图 7. IV-CNN-LSTM 模型易发性评价结果

为量化灾害易发性评价的统计结果，将历史灾害点的分布与研究区的易发性评估结果进行比较，开展易发区的统计分析，相关统计结果见表 3。结果显示：IV-CNN-LSTM 模型在极高易发区(18.72%面积)捕获 52.44%的历史灾害点，灾害密度达 3.39 处·10 km⁻²，较次优模型 XGBoost(42.07%、2.40 处·10 km⁻²)分别提升 24.6%和 41.3%。在高-极高易发区(合计 42.03%面积)，IV-CNN-LSTM 累计捕获 71.95%灾害点，较 RF 模型(68.90%)提升 3.05%。该区域 93%范围位于松散岩组(IV = 3.4714)与断层 500 m 影响带的叠加区，验证了模型对多因子耦合致灾的识别能力。在中易发区(32.81%面积)，模型捕获 22.56%灾害点，低于 CNN-LSTM 的 29.88%，这与该区域较坚硬碳酸盐岩组(IV = 0.2466)的准稳定态特征一致。低易发区(25.16%面积)仅 5.49%误判率(9 处)，且全部位于平坡(曲率 IV = -0.5095)与高植被覆盖区(NDVI 高覆盖 IV = -0.5275)，误判率波动范围为[4.82%, 6.16%]，证明预测稳定性。IV-CNN-LSTM 的极高-低易发区密度比达 13.0，均优于传统模型。在多指标综合评估中，IV-CNN-LSTM 展现出最优分类性能(表 4)。其 AUC 值达 0.9846，表明对正负样本的排序区分能力显著；准确率 0.9531 与精确率 0.9682 均为最高，体现整体分类正确性及正例预测的可靠性；F1 值达到 0.9515 虽略低于 XGBoost 模型，但调和了精确率与召回率(0.9353)的平衡关系。该模型在类别区分度、预测准确性及泛化能力上的综合优势，优于其他对比模型，尤其适用于对分类鲁棒性及低误判率有严格要求的任务场景。显示对小样本波动的强鲁棒性。

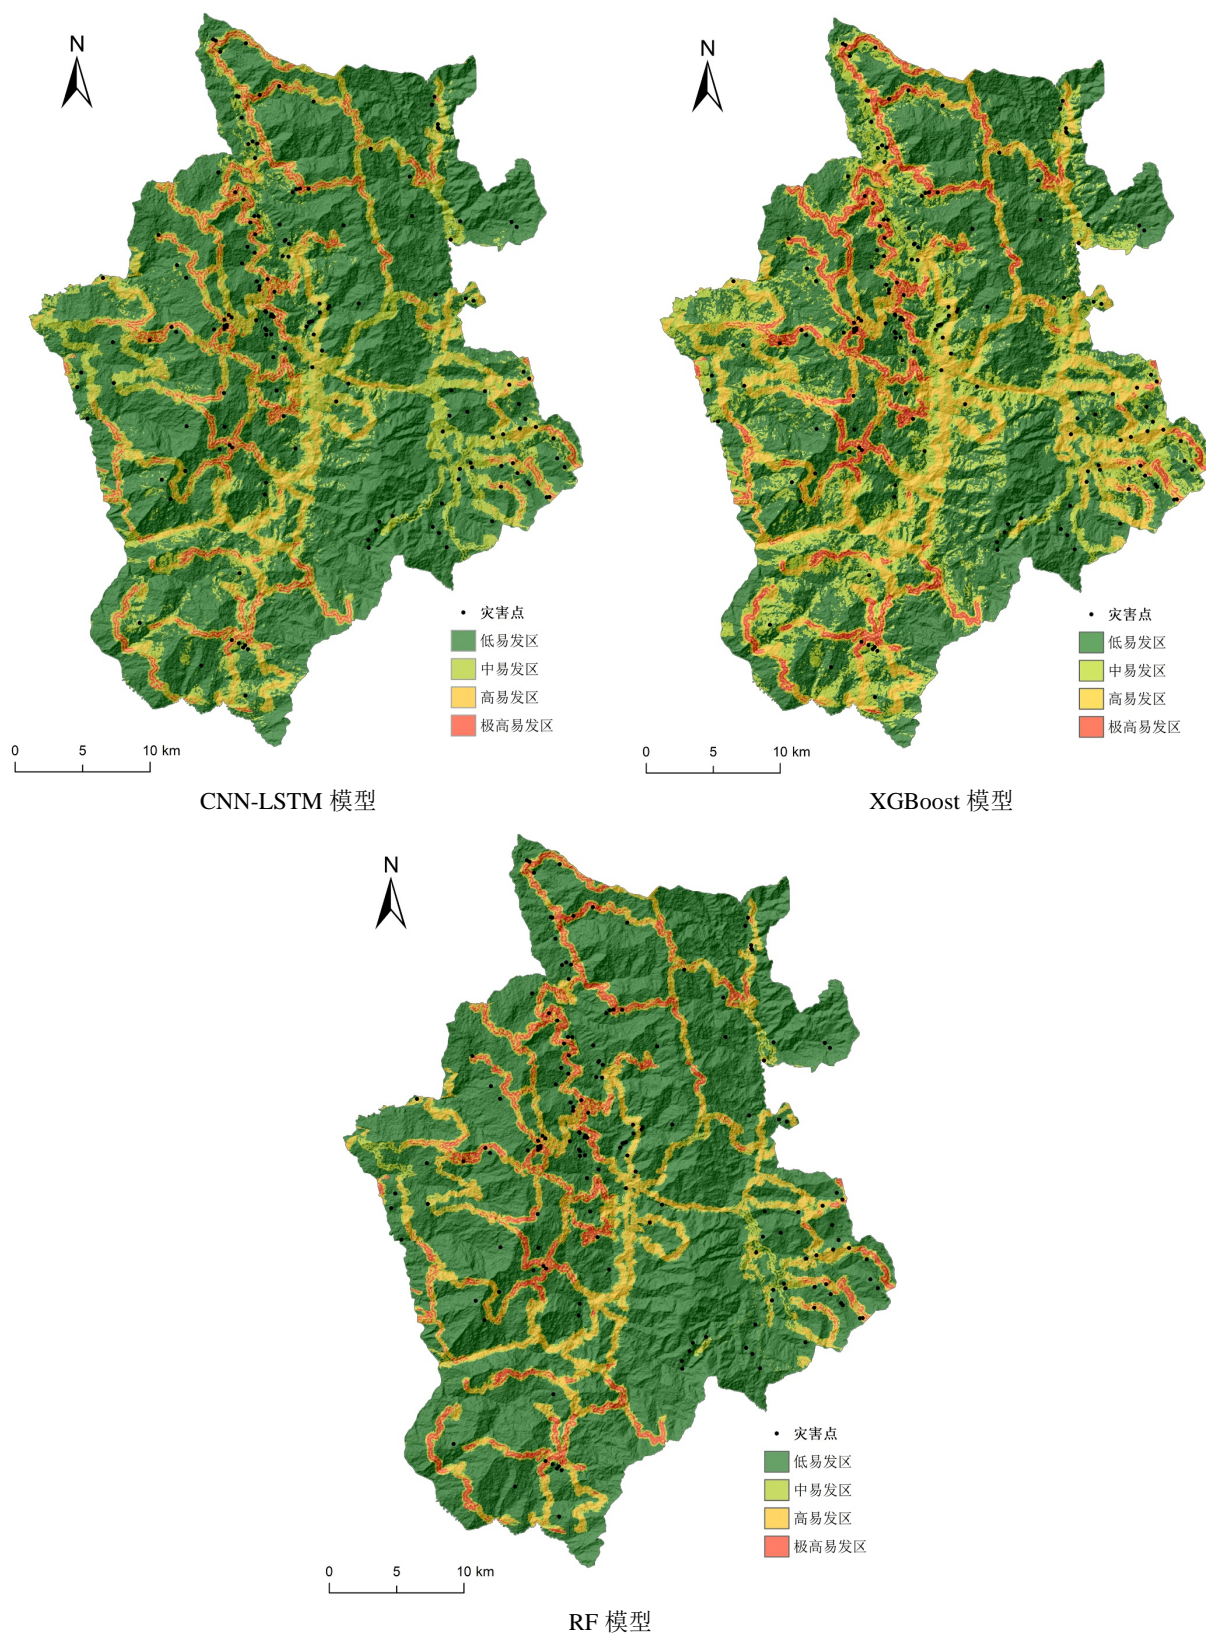


Figure 8. Geological hazard susceptibility zoning map of Ximeng County
图 8. 西盟县地质灾害易发性分区图

Table 3. Statistical table of distribution of geological disaster prone areas in Ximeng County
表 3. 西盟县地质灾害易发区分布统计表

模型	分级	面积占比	面积/km ²	灾害点数	灾害点密度/(处 *10 km ⁻²)	占总灾害数量比
IV-CNN-LSTM	低易发区	25.16%	340.56	9	0.26	5.49%
	中易发区	32.81%	444.43	37	0.83	22.56%
	高易发区	23.31%	315.98	32	1.01	19.51%
	极高易发区	18.72%	253.95	86	3.39	52.44%
CNN-LSTM	低易发区	32.67%	426.78	18	0.42	10.98%
	中易发区	30.07%	407.32	49	1.20	29.88%
	高易发区	17.20%	233.16	36	1.54	21.95%
	极高易发区	19.36%	287.73	61	2.12	37.20%
RF	低易发区	32.55%	440.59	15	0.34	9.15%
	中易发区	27.54%	373.05	36	0.97	21.95%
	高易发区	17.15%	232.48	51	2.19	31.10%
	极高易发区	23.76%	322.32	62	1.92	37.80%
XGBoost	低易发区	21.08%	285.54	14	0.31	8.54%
	中易发区	33.61%	454.93	40	1.40	24.39%
	高易发区	24.10%	326.69	41	1.26	25.00%
	极高易发区	21.21%	287.73	69	2.40	42.07%

Table 4. Comparison of landslide results from different models
表 4. 模型的精度结果对比

	precision	recall	f1-score	Accuracy	AUC
IV-CNN-LSTM 模型	0.9682	0.9353	0.9515	0.9531	0.9846
CNN-LSTM 模型	0.9404	0.9333	0.9368	0.9461	0.9541
RF 模型	0.9451	0.9114	0.9280	0.9127	0.9362
XGBoost 模型	0.9647	0.9431	0.9530	0.9309	0.9836

5.3. SHAP 分析

地质灾害的成因较为复杂, 识别主要致灾因子对于制定有效的防灾措施至关重要[33]。本文选取的 11 个影响因子对于灾害发生的影响程度各不相同, 应用 SHAP 分析方法, 评估了各影响因子在 IV-CNN-LSTM 模型预测中的相对重要性, 得到影响因子重要性排序图(图 9), 分析结果显示, 距道路距离的影响最大, 其次为降雨、NDVI 和高程。研究表明, 人类工程活动是引发地质灾害的主要因素, 低植被覆盖区域和高海拔山区也是灾害频发的重点区域。

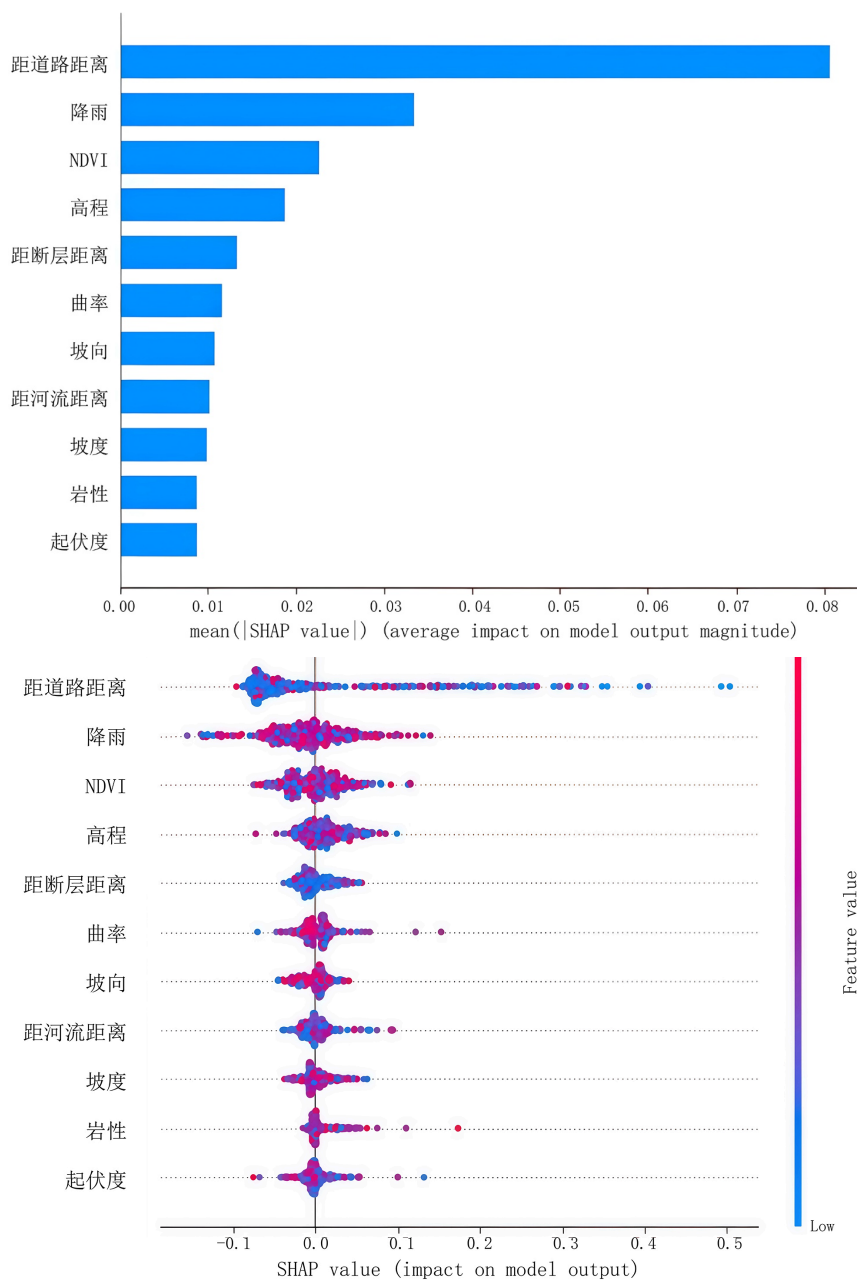


Figure 9. Ranking chart of importance of influencing factors; SHAP's Feature Summary Plot
图 9. 影响因子重要性排序图; SHAP 的特征摘要图

基于 SHAP 可视化影响因子重要性排序图前 4 个主导因子分别为道路、降雨、高程、NDVI(如图 10), 直观揭示影响因子的不同特征值在研究区内对地质灾害易发性预测结果的影响, 以增加模型的可解释性。分析结果显示: ① 道路距离的 SHAP 依赖关系显示(图 10(a)), 0~200 m 缓冲区的 SHAP 值达 0.62, 该范围内历史灾害点占比 63% (103/164 处), 印证人类工程活动对边坡稳定性的显著扰动; ② 降雨因子的特征重要性排序仅次于人类活动, 在月均降雨 104.5~106 mm 区间出现 SHAP 峰值 0.41 (图 10(b)), 对应研究区雨季降雨量占比 85% 的气候特征, 揭示降雨入渗 - 孔隙水压力的致灾机制。③ 高程 < 1000 m 时 SHAP = -0.15 (河流切割岸坡但人类活动少, 灾害点仅占 9%), 1300~1700 m 时与县城建成区重合, 该区

域为聚集区, 各种人类活动频繁, 为地质灾害发生提供了条件, >1800 m 出现 SHAP 值为负的情况, 这一区域海拔较高, 缺少为活动干预, 同时植被茂密, 呈现出较稳定的地质结构环境; ④ NDVI < 0.3 时 SHAP = 0.25 (表 2 中 IV = 0.7909, 滑坡占比 40%), NDVI > 0.7 时 SHAP = -0.31 (NDVI 每增加 10%, 灾害密度降低 0.5 处·10km²), 呈现明显负相关关系。⑤ 松散岩组(IV = 3.4714)与断层 500 m 复合区的灾害密度达 4.1 处·10 km² (表 3), 为单一因子区的 2.3 倍, 验证多因子耦合致灾规律。

传统地质因子如断层和岩性在本区地质灾害形成中的重要性相对较低, 而道路等人类工程活动因子则占据主导地位。这一现象与研究区断裂活动性较弱、岩性差异度有限以及大规模工程扰动对天然地质环境的显著破坏密切相关。工程切坡、边坡扰动及其与降雨作用的耦合成为灾害发生的直接诱因, 从而使得传统地质因子在统计模型中的解释力降低。因子分析结果与表 2 信息量值、表 3 灾害点分布及野外调查数据完全吻合, 揭示研究区“人类活动触发 - 降雨诱发 - 地形控制”的致灾模式。在应急管理过程中, 应特别关注这些因素, 并针对性地采取预防和应对措施, 从而有效减少地质灾害的风险。

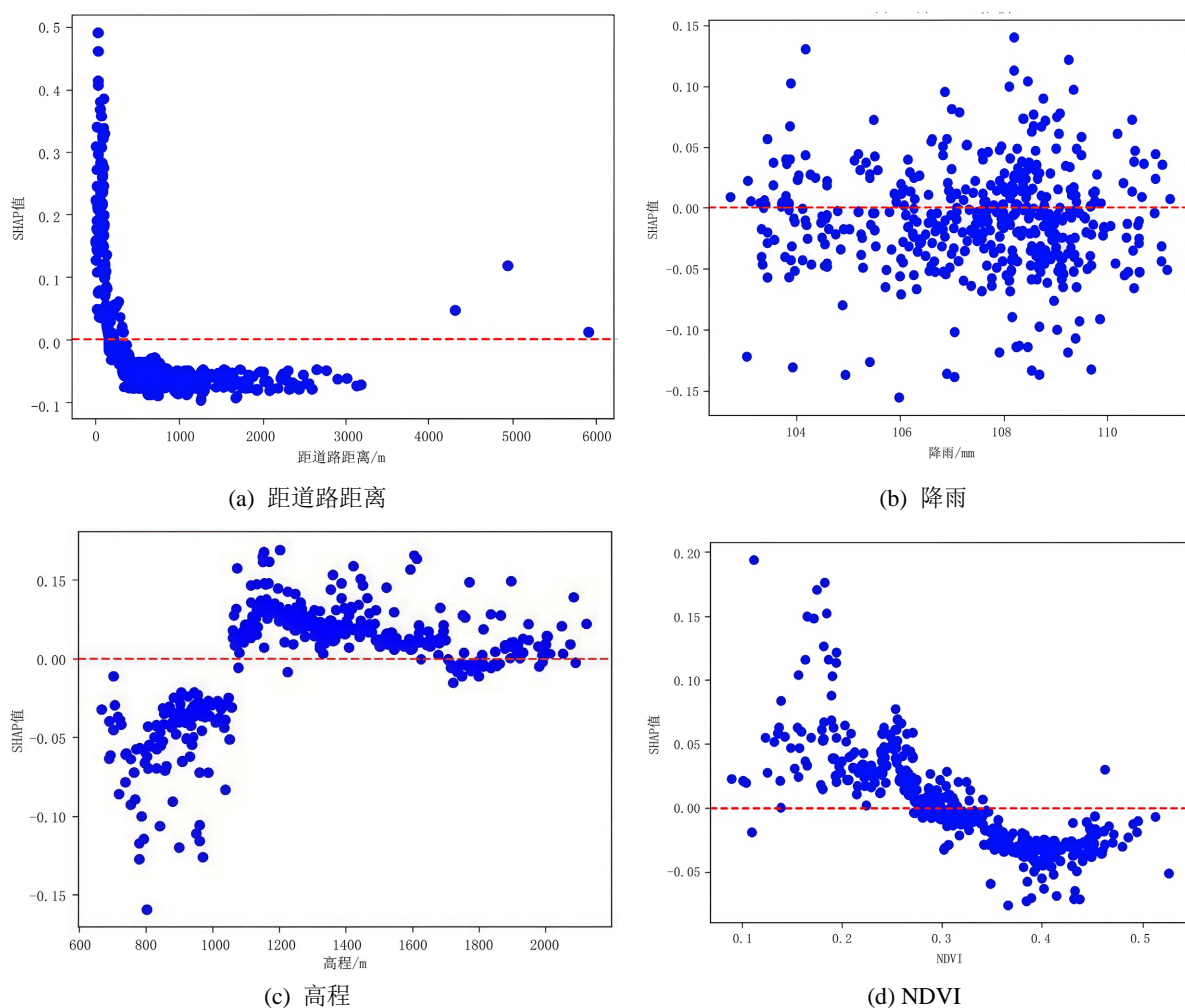


Figure 10. The dependence relationship between the dominant factors and the model prediction results

图 10. 主导因子与模型预测结果的依赖关系

6. 讨论

IV-CNN-LSTM 模型的核心优势在于有效融合了信息量法(IV)对关键地质环境特征的敏感性、卷积神

神经网络(CNN)强大的空间特征提取能力以及长短期记忆网络(LSTM)对降雨时序动态的建模能力。通过这一设计,模型能够从复杂的地质环境中提取有效的空间和时序特征,提升了灾害易发性评价的准确性和可靠性。与 CNN-LSTM 的模型相比,IV-CNN-LSTM 通过结合深度学习和统计学方法,使得其在处理复杂数据时的表现得到进一步改善,但模型也存在一定的局限性:

① 仅使用 164 个历史灾害点,样本量较小,虽然我们采用了 IV 优化样本和正则化技术(如早停)来缓解,但样本量的限制仍是模型泛化能力的一个潜在制约因素。未来研究可考虑整合时序 InSAR (如 Sentinel-1)监测数据,识别潜在不稳定区域以扩充样本,探索迁移学习技术,利用其他区域丰富样本进行预训练等方法进一步优化。

② 研究区面积相对较小,使用的月均降雨数据空间分辨率可能不足以充分捕捉降雨在局部的差异性及其对灾害的精细化影响。

③ 将不同地质灾害(滑坡、崩塌、泥石流)进行混合建模存在显著局限性。由于三者成因机制(剪切、拉裂、固液两相流)、关键控制因子(如结构面、物源量)和响应尺度上存在本质差异,强行融合会平滑其独特的物理过程,导致模型精度下降,并系统性地低估灾害链风险(如滑坡为泥石流提供物源)。这进而扭曲因子重要性排序,使共性因子(如坡度)重要性被高估,而关键区分性因子(如沟道密度)贡献被掩盖。未来研究应转向“分治-集成”策略,优先发展基于各自物理机制的专用模型,再通过动态耦合与灾害链规则进行集成,并深化不确定性量化,以构建更精准的风险评估体系。

7. 结论

本文提出的 IV-CNN-LSTM 模型在西盟县地质灾害易发性评价中的应用展示了其在数据整合和特征学习方面的潜力。通过结合多源遥感数据与地理因子,模型能够较好地捕捉地质灾害的空间分布特征及其时序动态变化,并在预测精度上显著超越了对比的传统机器学习模型(RF 和 XGBoost)以及未使用 IV 优化的 CNN-LSTM 模型,尤其在处理降雨等时序数据时表现出一定的优势。

(1) 利用信息量法作为先验模型对负样本选取策略进行了优化,在通过共线性分析保证各因子独立性的前提下,以优化后的负样本点与历史灾害点建立了易发性评价的数据库,通过易发区灾害点统计表进一步表明 IV-CNN-LSTM 模型在易发性分区的合理性上要优于单一模型,结合信息量(IV)模型优化样本后的分区结果与历史灾害的分布相似度更高,因此利用该模型得到的研究区易发性评价结果可以对防治和管理给出可靠的建议。

(2) 以信息量法优化样本的策略下,提出 IV-CNN-LSTM 评价模型对研究区进行灾害易发性评价,评价结果在 precision、recall、f1-score、Accuracy、AUC 值上均优于其他单一模型,其 AUC 值为 0.9845,相比 CNN-LSTM、XGBoost、随机森林(RF)等模型,AUC 值分别提升了 0.0305、0.0484、0.0010,达到了更好的评价效果,IV-CNN-LSTM 在极高易发区(18.72%面积)捕获 52.44%历史灾害点(表 3),密度达 $3.39 \text{ 处} \cdot 10 \text{ km}^{-2}$,较次优模型 XGBoost (42.07%、 $2.40 \text{ 处} \cdot 10 \text{ km}^{-2}$)提升 24.6%和 41.3% (表 3)。

(3) 通过 SHAP 分析方法,对各特征因子进行了全面分析,探讨了不同特征值对灾害发生的具体影响。结果表明:地形地貌因子的重要性排序均较低,表明研究区内地质情况较为稳定;人类工程活动和降雨是影响灾害孕发的主要因子。量化人类活动对滇西南山区灾害的主导作用,建立“人为扰动-降雨触发”双驱动理论框架。

总体而言,IV-CNN-LSTM 模型在地质灾害防控中表现出较强的应用潜力。通过生成高分辨率的地质灾害易发性分区图,可以为政府和相关决策者提供更为精准的风险评估依据,有助于制定更加科学的防灾减灾措施。

参考文献

- [1] 国家防灾减灾救灾委员会办公室, 应急管理部. 2024 年全国自然灾害基本情况[EB/OL]. 2025-01-17. https://www.mem.gov.cn/xw/yjglbgzdt/202501/t20250117_516032.shtml, 2025-03-10.
- [2] 吴兴贵, 王宇栋, 王蓝婷, 等. 加权信息量模型在云南澜沧县滑坡危险性评价中的应用[J]. 中国地质灾害与防治学报, 2024, 35(3): 119-128.
- [3] 安全, 李思发, 李亮, 等. 基于信息量与 Logistic 模型的矿区滑坡灾害易发性评[J]. 贵州地质, 2023, 40(3): 284-295.
- [4] 林幸佛. 基于信息量法罗源县地质灾害易发性评价[J]. 能源与环境 2023(3): 2-6+10.
- [5] 崔婷婷, 安雪莲, 孙德亮, 等. 基于 SHAP 的可解释机器学习的滑坡易发性评价模型[J]. 成都理工大学学报(自然科学版), 2025, 52(1): 153-172.
- [6] 杨灿. 基于机器学习的滑坡灾害易发性评价——以安化县为例[D]: [硕士学位论文]. 长沙: 中南大学, 2022.
- [7] 王守华, 王睿菴, 孙希延, 等. 基于 CF-CNN-LSTM 模型的滑坡易发性评价[J]. 自然灾害学报, 2024, 33(5): 84-95.
- [8] 徐胜华, 马钰, 刘纪平, 等. 多尺度特征学习的轻量化滑坡易发性评价方法[J]. 武汉大学学报(信息科学版), 2025, 50(6): 1175-1190.
- [9] 邓日朗, 张庆华, 刘伟, 等. 基于改进两步法采样策略和卷积神经网络的崩塌易发性评价[J]. 地质科技通报, 2024, 43(2): 186-200.
- [10] 缪亚敏, 朱阿兴, 杨琳, 等. 一种基于地理环境相似度的滑坡负样本可信度度量方法[J]. 地理科学进展, 2016, 35(7): 860-869.
- [11] 刘帅, 王涛, 曹佳文, 等. 基于优化随机森林模型的降雨群发滑坡易发性评价——以西秦岭极端降雨事件为例[J]. 地质通报, 2024, 43(6): 958-970.
- [12] Lv, L., Chen, T., Dou, J. and Plaza, A. (2022) A Hybrid Ensemble-Based Deep-Learning Framework for Landslide Susceptibility Mapping. *International Journal of Applied Earth Observation and Geoinformation*, **108**, Article ID: 102713. <https://doi.org/10.1016/j.jag.2022.102713>
- [13] 杨延晨, 周超, 施佳涓. 基于卷积神经网络的区域滑坡易发性评价: 以三峡库区万州区为例[J]. 测绘通报, 2023(11): 1-6.
- [14] 马欣蕊, 徐胜华, 王琢璐, 等. 融合自编码与密集残差网络的滑坡易发性评价[J]. 测绘科学, 2023, 48(7): 146-154.
- [15] 高秉海, 何毅, 张立峰, 等. 顾及 InSAR 形变的 CNN 滑坡易发性动态评估——以刘家峡水库区域为例[J]. 岩石力学与工程学报, 2023, 42(2): 450-465.
- [16] 张越. 基于机器学习的滑坡空间易发性评价——以云南省昆明市东川区为例[D]: [硕士学位论文]. 昆明: 昆明理工大学, 2022.
- [17] 王志良, 年玉泽, 申林方, 等. 植被发育斜坡土体大孔隙三维重构模型渗流场的 LBM 数值模拟[J]. 岩土力学, 2018, 39(10): 3821-3829.
- [18] 崔成敏. 基于遥感的滑坡地质灾害研究——以云南鹤庆地区为例[D]: [硕士学位论文]. 北京: 中国地质大学(北京), 2020.
- [19] 朱新婷. 基于本底因子滑坡易发性评价的滑坡体识别[D]: [硕士学位论文]. 绵阳: 西南科技大学, 2022.
- [20] Ji, J., Tong, B., Cui, H., Tang, X., Hürlimann, M. and Du, S. (2025) A QGIS Framework for Physically-Based Probabilistic Modelling of Landslide Susceptibility: QGIS-FORM. *Environmental Modelling & Software*, **183**, Article ID: 106258. <https://doi.org/10.1016/j.envsoft.2024.106258>
- [21] 吉日伍呷, 田宏岭, 韩继冲. 基于不同机器学习算法的地震滑坡易发性评价——以鲁甸地震为例[J]. 昆明理工大学学报(自然科学版), 2022, 47(2): 47-56.
- [22] 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): 37-50.
- [23] 刘杰. 长时间尺度下基于机器学习的滑坡易发性评价——以礼县为例[D]: [硕士学位论文]. 兰州: 中国地震局兰州地震研究所, 2022.
- [24] 周超, 甘露露, 王悦, 等. 综合非滑坡样本选取指数与异质集成机器学习的区域滑坡易发性建模[J]. 地球信息科学学报, 2023, 25(8): 1570-1585.
- [25] 李璐. 基于机器学习法的黑方台典型滑坡体易发性评价及高精度位移预测分析[D]: [硕士学位论文]. 西安: 长安大学, 2022.

-
- [26] 胡旭东. 基于集成学习的地质灾害易发性评价研究——以云南省泸水县为例[D]: [硕士学位论文]. 北京: 中国地质大学, 2019.
- [27] 马俊杰. 基于机器学习的遵义市滑坡灾害易发性评价研究[J]. 河南科技, 2022, 41(6): 129-132.
- [28] Badavath, N. and Sahoo, S. (2025) Geospatial Assessment and Integrated Multi-Model Approach for Landslide Susceptibility Mapping in Meghalaya, India. *Advances in Space Research*, **75**, 2764-2791. <https://doi.org/10.1016/j.asr.2024.11.052>
- [29] 黄发明, 陈彬, 毛达雄, 等. 基于自筛选深度学习的滑坡易发性预测建模及其可解释性[J]. 地球科学, 2023, 48(5): 1696-1710.
- [30] Van Westen, C.J., Rengers, N., Terlien, M.T.J. and Soeters, R. (1997) Prediction of the Occurrence of Slope Instability Phenomenal through Gis-Based Hazard Zonation. *Geologische Rundschau*, **86**, 404-414. <https://doi.org/10.1007/s005310050149>
- [31] Yang, Y., Peng, S., Huang, B., Xu, D., Yin, Y., Li, T., *et al.* (2024) Multi-Scale Analysis of the Susceptibility of Different Landslide Types and Identification of the Main Controlling Factors. *Ecological Indicators*, **168**, Article ID: 112797. <https://doi.org/10.1016/j.ecolind.2024.112797>
- [32] Shu, H., He, J., Zhang, F., Zhang, M., Ma, J., Chen, Y., *et al.* (2024) Construction of Landslide Warning by Combining Rainfall Threshold and Landslide Susceptibility in the Gully Region of the Loess Plateau: A Case of Lanzhou City, China. *Journal of Hydrology*, **645**, Article ID: 132148. <https://doi.org/10.1016/j.jhydrol.2024.132148>
- [33] 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): 1960-1976.