引文格式:丁明涛,江辉,李振洪,等.融合卷积模糊神经网络与SHAP特征优化的地震诱发滑坡易发性评价[J].武汉大学学报(信息科学版),2026,51(7):1404-1422.DOI:10.13203/j.whugis20250017

Citation: DING Mingtao, JIANG Hui, LI Zhenhong, et al. Earthquake-Induced Landslide Susceptibility Assessment by Fusing Convolutional Fuzzy Neural Network and SHAP Feature Optimization[J].Geomatics and Information Science of Wuhan University,2026,51(7):1404-1422.DOI:10.13203/j.whugis20250017

融合卷积模糊神经网络与SHAP特征优化的地震诱发滑坡易发性评价

丁明涛[1,2,3,4] 江 辉[2,5] 李振洪[2,3,4] 申传庆[6] 卢昭龙[2,5]

1 智慧地球重点实验室,北京,100029
2 长安大学地质工程与测绘学院,陕西 西安,710054
3 黄土科学全国重点实验室,陕西 西安,710054
4 西部矿产资源与地质工程教育部重点实验室,陕西 西安,710054
5 长安大学地学与卫星大数据研究中心,陕西 西安,710054
6 自然资源部陕西基础地理信息中心,陕西 西安,710054

摘 要:地震诱发滑坡是一种破坏性极强、危险性极高的地质灾害,准确评估地震诱发滑坡易发性对于震后救灾减灾及灾后重建至关重要。针对卷积神经网络(convolutional neural network, CNN)在处理地震诱发滑坡样本时,易出现过拟合和多源数据不确定性的问题,提出了一种基于卷积模糊神经网络(convolutional fuzzy neural network, CFNN)的地震诱发滑坡易发性方法。同时,引入夏普利加性解释(Shapley additive explanations, SHAP)特征优化策略,通过定量评估特征重要性,对模型输入进行筛选和优化,提升模型的预测精度。选取2017年九寨沟Ms 7.0地震、2022年芦山Ms 6.1地震及2022年泸定Ms 6.8地震组成研究区,涵盖5 990个滑坡实例,覆盖总面积为72.147 km^2,选取16个滑坡影响因子构建并优化CFNN模型,完成了研究区地震诱发滑坡易发性评价。结果表明,距河流的距离、地震峰值加速度、高程、土壤覆盖类型以及距断层的距离是影响滑坡发育的关键因素。在模型性能对比中,相比于传统CNN模型,CFNN模型展现出更优的预测精度和显著的防过拟合能力。通过引入SHAP特征优化策略进一步优化后,CFNN模型在受试者工作特征曲线下的面积值可达0.942 0,表现出极高的预测性能。研究结果验证了CFNN模型在地震滑坡易发性评价中的可靠性,为地震滑坡灾害的预防和监测提供了新的理论依据和技术支持,同时也为深度学习模型在地质灾害领域的应用拓展提供了重要参考。

关键词:CFNN;SHAP特征优化;地震诱发滑坡;滑坡易发性评价

中图分类号:P237 **文献标识码**:A **收稿日期**:2025-06-19

DOI:10.13203/j.whugis20250017 **文章编号**:1671-8860(2026)07-1404-19

Earthquake-Induced Landslide Susceptibility Assessment by Fusing Convolutional Fuzzy Neural Network and SHAP Feature Optimization

DING Mingtao[1,2,3,4] *JIANG Hui*[2,5] *LI Zhenhong*[2,3,4] *SHEN Chuanqing*[6] *LU Zhaolong*[2,5]

1 Key Laboratory of Smart Earth, Beijing 100029, China
2 College of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China
3 State Key Laboratory of Loess Science, Xi'an 710054, China
4 Key Laboratory of Western China's Mineral Resources and Geological Engineering, Ministry of Education, Xi'an 710054, China
5 Big Data Center for Geosciences and Satellites (BDCGS), Chang'an University, Xi'an 710054, China
6 Shaanxi Basic Geographic Information Center, Ministry of Natural Resources, Xi'an 710054, China

Abstract: **Objectives**: Earthquake-induced landslides is a highly destructive and dangerous geologic hazard, and the accurate assessment of their susceptibility is crucial for post-earthquake relief, mitigation,

基金项目:国家自然科学基金(42374027);智慧地球重点实验室基金(KF2023YB04-01);浙江省"尖兵""领雁"研发攻关计划项目(2023C03177);陕西省科技创新团队(2021TD-51);陕西省地学大数据与地质灾害防治创新团队(2022)。

第一作者:丁明涛,博士,教授,主要从事机器学习、遥感影像处理研究。mingtaoding@chd.edu.cn

and reconstruction. **Methods**: To address the limitations of convolutional neural network (CNN), such as susceptibility to overfitting and uncertainty in multi-source data, a novel approach based on a convolutional fuzzy neural network (CFNN) is proposed. The proposed method combines the efficient feature extraction capability of CNN with the strong uncertainty handling capability of fuzzy logic to achieve accurate modeling and feature optimization of landslide influencing factors. Additionally, the Shapley additive explanations (SHAP) feature optimization strategy is introduced to quantitatively evaluate feature importance, enabling the selection and optimization of model inputs. The 2017 Jiuzhaigou Ms 7.0, the 2022 Lushan Ms 6.1, and the 2022 Luding Ms 6.8 earthquakes are selected as the study area, which includes a total of 5 990 landslide instances covering an area of 72.147 km^2. A total of 16 landslide impact factors are selected for comprehensive analysis. The CFNN model is constructed and optimized to evaluate earthquake-induced landslide susceptibility in the study area. **Results**: The results indicate that the distance to rivers, peak ground acceleration, elevation, soil cover type, and distance to faults are the key factors influencing landslide development. Compared with the traditional CNN models, the CFNN model demonstrates superior performance and exhibits significant overfitting resistance. Furthermore, after incorporating the SHAP-based feature optimization strategy, the performance of the CFNN model is further enhanced, achieving an area under the receiver operating characteristic curve of 0.942 0, indicating excellent predictive accuracy. **Conclusions**: The results verify the reliability of the CFNN model in earthquake-induced landslide susceptibility evaluation, providing a new theoretical basis and technical support for the prevention and monitoring of such disasters. Moreover, these results provide a valuable reference for advancing the application of deep learning models in geohazard studies.

Key words: CFNN; SHAP feature optimization; earthquake-induced landslides; landslide susceptibility assessment

地震是全球最常见的自然灾害之一,尤其是强震,因破坏性极强常引发滑坡等灾害,导致严重的经济损失和人员伤亡[1-2]。根据文献[3]的统计,1968—2008年记录的所有死亡人数中,地震造成的死亡人数占总死亡人数的比例约80%,而地震引起的滑坡造成的死亡人数占总死亡人数的比例约5%。近年来,中国西南部的复杂地形和频繁的断层活动使得该地区成为强震的多发区,相继发生了2017年九寨沟地震[4]、2022年泸定地震[5-6]和2023年积石山地震[7-8]等事件,导致严重的建筑和交通破坏及巨大的经济损失。这些事件进一步强调了开展地震诱发滑坡易发性评价研究的紧迫性和必要性。

地震诱发滑坡易发性评价是指在地震作用下,结合地质环境、地形地貌、气象水文和地质构造等多种因素,对特定区域或地段发生滑坡灾害的可能性进行评估的过程。然而,这一评估过程面临的首要难题在于解决数据获取与数据不确定性的问题。文献[9]指出,遥感数据与地质调查数据的融合在滑坡易发性评估中至关重要,同时强调了不同数据集成中尺度与分辨率差异带来的不确定性;文献[10]通过敏感性分析与贝叶斯方法,探讨了滑坡模型的验证和不确定性评估策略,以增强模型的可靠性;文献[11]则提出了证据融合方法,进一步降低了多源数据的不确定性。尽管多源数据的使用日益增多,但现有研究往往忽视了不确定性问题,这在滑坡易发性评估中仍然是一个亟待关注的挑战。

除了数据不确定性问题外,地震诱发滑坡易发性评价的另一个关键问题是如何选择合适的评估模型来准确预测滑坡易发性。近年来,随着科学技术的快速发展,大量学者在区域地震诱发滑坡易发性评价上取得了显著进展。当前的研究方法大致可以分为基于物理的方法(如无限斜坡稳定性分析)、启发式方法、统计分析、机器学习和深度学习等几类。其中,深度学习凭借强大的数据处理和模式识别能力,逐渐成为滑坡易发性评价的重要工具[12]。卷积神经网络(convolutional neural network, CNN)作为深度学习中最具代表性的技术之一,具有强大的特征提取能力,已被广泛应用于滑坡易发性建模。文献[13]使用CNN模型在中国燕山进行滑坡易发性建模,将CNN与机器学习模型的结果进行比较,发现CNN的性能优于传统机器学习模型;文献[14]进一步验证了CNN在滑坡评价中的优越性。然而,在地震诱发滑坡易发性评价过程中,

深度学习模型在实际应用中还处于探索阶段,一个重要原因是深度学习模型的黑盒性质限制了其在实际应用中的解释性和可靠性,这成为制约其进一步发展的关键因素。

为解决深度学习模型在滑坡易发性评价中的解释性问题,夏普利加性解释(Shapley additive explanations, SHAP)作为一种模型解释技术,逐渐受到关注[15]。文献[16]考虑到模型可解释性的重要性,以CNN为基础模型进行滑坡易发性建模,并利用SHAP对模型加以解释,推动了模型可解释性在该领域研究中逐渐受到重视;文献[17]进一步利用SHAP分析了同震滑坡易发性模型的作用机制,为揭示模型内部机制提供了新的视角。然而,现有研究主要将SHAP应用于模型的可解释性分析,未充分挖掘其在模型优化中的潜力。其中,传统的特征筛选方法通常通过减少特征冗余来优化输入数据,但理论上这种方法与深度学习建模本身在特征分析上的弱解释性存在割裂,难以充分利用特征的重要性信息。相比之下,SHAP特征优化策略可以基于深度学习模型对特征贡献度进行量化评估,筛选出关键特征并剔除冗余特征,从而有效提高模型的预测精度[18]。例如,文献[19]结合SHAP与随机森林(random forest, RF)算法对城市卫星全球数字高程模型进行校正,可显著提高模型的精度。这表明SHAP特征优化策略不仅能够增强模型的可靠性,还能够为数据驱动模型的优化提供有力支持。在地震滑坡易发性评价领域,SHAP方法的应用尚处于起步阶段,其在深度学习模型优化方面的潜力仍需进一步挖掘。充分利用SHAP特征优化策略,有望在深度学习建模中实现更高效的特征选择,从而显著提升模型的预测性能,为滑坡易发性评价提供新的技术路径。

鉴于上述背景,本文提出了一种融合模糊神经网络(fuzzy neural networks, FNN)与CNN的卷积模糊神经网络(convolutional FNN, CFNN),旨在处理滑坡数据和影响因子数据中的不确定性。其中,FNN专为处理具备不确定性、模糊性和复杂性的问题而设计,并且能在集成模型中增强稳健性[20]。大量研究表明[21-22],将FNN集成于模型中,有助于有效抑制过拟合现象并提高模型的泛化能力。本文利用CFNN模型,选取2017年九寨沟Ms 7.0地震、2022年芦山Ms 6.1地震和2022年泸定Ms 6.8地震组成研究区,结合地震、地形、水文、地质和人类活动等16个影响因子,构建了地震诱发滑坡易发性CFNN模型,并与CNN模型进行对比。同时,通过空间统计分析方法,探讨了不同影响因子下的地震诱发滑坡分布规律。进一步引入SHAP特征优化策略,对CFNN模型进行了可解释分析,并优化其模型性能。最后,应用优化后的模型与支持向量机(support vector machine, SVM)和RF模型进行对比,利用最优模型对研究区的地震诱发滑坡易发性进行评价,并分析评价结果。研究成果不仅可为未来地震诱发滑坡的研究提供有价值的参考,也可为研究区的防灾减灾提供重要的科学依据。

1 研究区与数据源

1.1 研究区概况

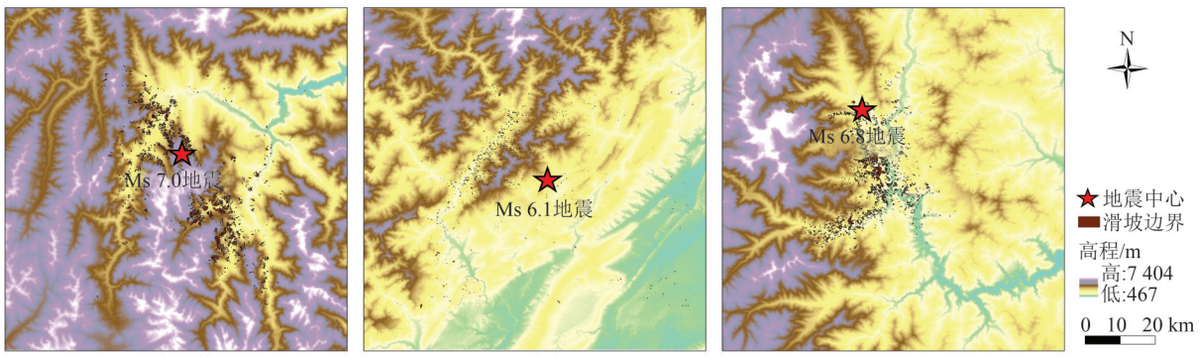
本文选取中国四川省内3个受强震直接诱发滑坡灾害密集的区域作为核心研究区,分别是九寨沟县(2017-08-08发生Ms 7.0地震[23])、芦山县(2022-06-01发生Ms 6.1地震[24])和泸定县(2022-09-05发生Ms 6.8地震[25-26])。3个地震事件的位置、震后诱发滑坡的分布以及各区域的高程如图1所示。这些区域发生的地震事件不仅突显出四川省作为亚欧大陆板块与印度板块交界区域的高地震频发性,同时也展示了在复杂的地质构造背景下地震对滑坡等地质灾害的显著诱发作用。此外,四川省以山高谷深、地势陡峭的地形而闻名,这种自然环境为地震后的滑坡等次生地质灾害的发生提供了条件。

1.2 数据源

1.2.1 地震诱发滑坡清单

本文收集了3次地震诱发滑坡事件的数据,其中,九寨沟地震[23]和泸定地震的滑坡编录数据[26-27]基于已有的滑坡编录数据修正获得,芦山地震滑坡编录数据则通过人工解译地震前后哨兵2号(Sentinel-2)影像数据获得。由于不同滑坡编录数据可能基于不同的高分辨率影像进行解译,部分滑坡事件存在位置偏移等问题,统一数据源有助于提高建模的准确性。

为解决多源数据在尺度与分辨率方面的差异,本文主要采用以下处理方法:对于已有的九寨沟和泸定地震滑坡编录数据,基于空间分辨率为10 m的Sentinel-2影像进行了位置偏移修正,以确保滑坡位置的空间精度;芦山地震滑坡数据则直接基于Sentinel-2影像进行人工解译,从源头上确保了数据的高空间分辨率和精准定位。为统一不同数据源的空间尺度,本文对所有滑坡



(a) 九寨沟　(b) 芦山　(c) 泸定

图 1　研究区概况

Fig. 1　Overview of the Study Area

编录数据进行投影坐标系统一处理,并保持了影像的原始分辨率,避免因重采样导致的空间精度损失。最终解译出的3个地震事件诱发滑坡数据如表1所示。

表 1　地震诱发滑坡数据

Table 1　Data of Earthquake-Induced Landslides

研究区	解译面积/km²	Sentinel-2影像获取时间		滑坡解译数量/处
		震前	震后	
九寨沟	1 107	2017-02-19 2017-05-30	2017-09-07	2 017
芦山	3 645	2022-05-04	2022-07-23 2022-07-28	1 009
泸定	6 039	2022-07-23 2022-08-07	2022-10-01	2 964

1.2.2　地震诱发滑坡影响因子

基于收集的滑坡编录数据和相关研究[23,26,28-29],综合考虑地质灾害的成灾机理,结合地形、地质、地震、水文以及人类活动等因素,利用深度学习算法构建了地震诱发滑坡易发性预测模型。本文选择了16个影响因子用于建模,包括高程、坡度、坡向、平面曲率、剖面曲率、地形粗糙度指数(topographic roughness index, TRI)、岩性、距断层的距离、月均降水量、距河流的距离、地形湿度指数(topographic wetness index, TWI)、归一化差异植被指数(normalized differential vegetation index, NDVI)、土地利用类型、土壤覆盖类型、距道路的距离及地震峰值加速度(peak ground acceleration, PGA)。影响因子的数据信息如表2所示。

表 2　影响因子的数据信息

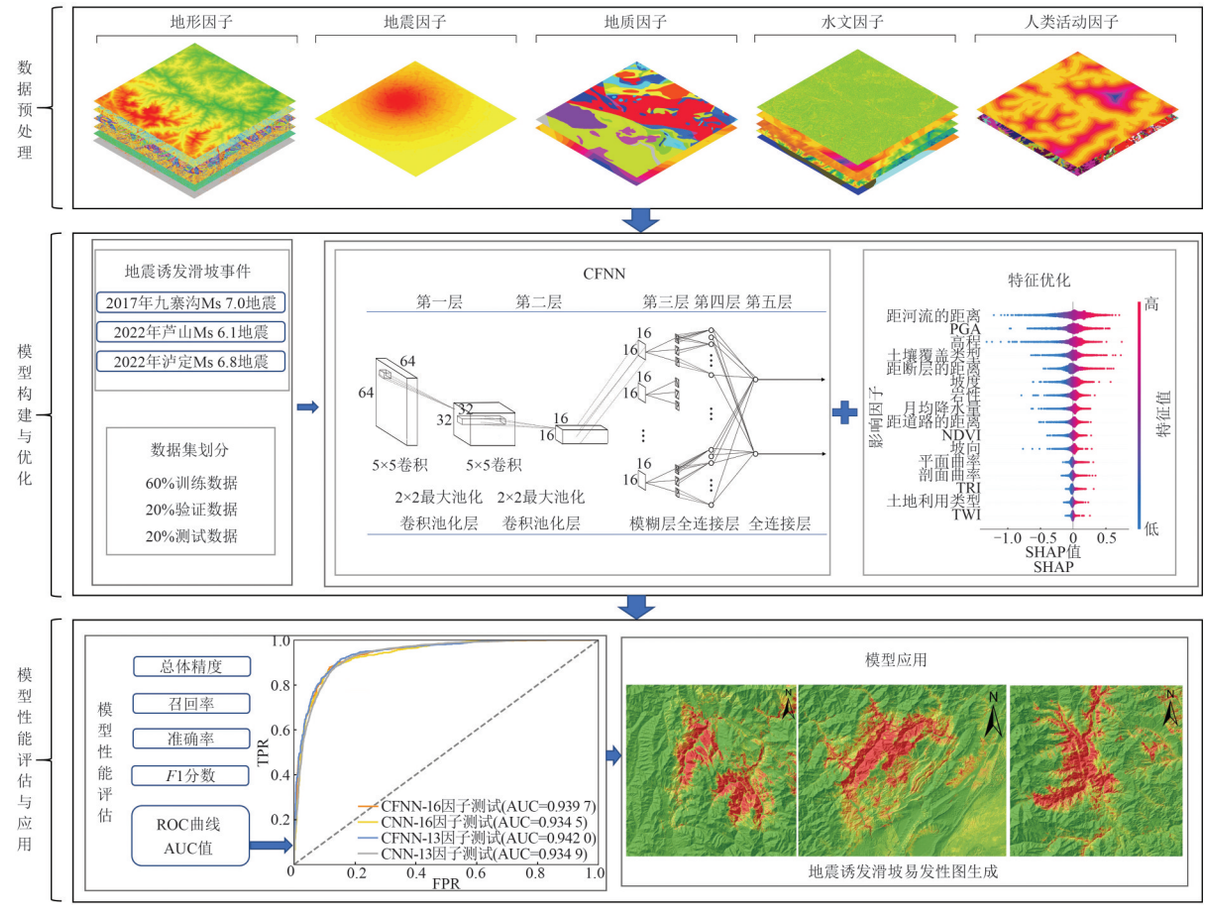
Table 2　Data Information of Impact Factors

数据名称	数据类型	空间分辨率	影响因子	数据来源	数据时间
ALOS数字高程模型数据	栅格	12.5 m	高程、坡度、坡向、平面曲率、剖面曲率、TWI、TRI	https://www.earthdata.nasa.gov	2011年
陆地卫星8号搭载的陆地成像仪影像	栅格	25 m	NDVI	https://www.gscloud.cn	震前
地质数据	矢量	1:25万	岩性、距断层的距离	https://geocloud.cgs.gov.cn	2020年
基础地理数据	矢量	1:25万	距道路的距离、距河流的距离	https://www.webmap.cn	震前
降水数据	矢量	1 km	月均降水量	https://www.gis5g.com	2001—2022年
土壤数据	矢量	1:400万	土壤覆盖类型	https://soil.geodata.cn	2000年
土地利用数据	栅格	30 m	土地利用类型	https://www.resdc.cn	2015年
地震数据	矢量	0.1°	PGA	https://earthquake.usgs.gov	震后

注:ALOS(advanced land observing satellite)为先进陆地观测卫星。

2　地震诱发滑坡易发性评价模型构建与优化方法

地震诱发滑坡易发性评估流程如图2所示,主要包含3个步骤:(1)数据预处理,涵盖相关数据的收集与处理。(2)模型构建与优化,包括SVM、RF、CNN和CFNN模型的构建,并利用SHAP对构建的CFNN模型进行解释,通过SHAP特征优化策略对模型输入影响因子进行筛选优化,最终使用优化后的数据训练地震滑坡易



注：ROC(receiver operating characteristic)为受试者工作特征；AUC(area under curve)为曲线下面积；TPR(true positive rate)为真正例率；FPR(false positive rate)为假正例率。

图2 地震诱发滑坡易发性评价流程图

Fig. 2 Flowchart of Earthquake-Induced Landslide Susceptibility Assessment

发性模型。(3)模型性能评估与应用，对CNN和CFNN两种模型在特征优化前后的训练和测试结果进行对比分析，选出最优模型。为进一步说明本文所提CFNN模型的优越性，利用选取的最优模型与传统的滑坡易发性评价模型(SVM和RF)进行对比。

2.1 数据预处理

数据预处理包含滑坡数据预处理和影响因子预处理两部分。首先利用ArcGIS 10.8软件，按照滑坡与非滑坡1∶1的比例，随机生成非滑坡点数据；然后，对影响因子进行处理，由于本文涵盖了地形、地质、土地利用、气象和地震等多源数据，所以采用栅格化方法进行统一处理，并将分辨率统一调整为25 m，以确保不同数据层之间的空间一致性，并与遥感数据相匹配，还能有效提取各影响因子的空间特征。选择25 m作为统一分辨率主要有两个原因：(1)在大多数地质灾害分析中，认为25 m分辨率既能保持足够的空间细节，又能避免分辨率过高所带来的计算压力[30]。尤其是当研究区域较大时，分辨率过高可能会导致计算效率下降，影响评估的可行性[31]，同时对细节的提高作用也逐渐减弱；分辨率过低则可能丧失一些重要的空间信息。(2)ALOS数字高程数据的空间分辨率为12.5 m，而NDVI栅格数据的分辨率为25 m。

数据预处理具体包括矢量数据的栅格化处理，首先，将所有矢量数据进行投影统一，确保空间参考一致；然后，使用栅格化工具将其转换为栅格数据，栅格大小统一调整为25 m。对于其他空间分辨率的栅格数据，采用双线性插值法将其采样至25 m分辨率，以确保所有数据的统一尺度，并避免因分辨率差异导致的空间误差。经过栅格化和分辨率统一后，本文采用空间叠加分析技术对不同类型的影响因子数据进行融合与叠加，利用滑坡与非滑坡数据生成完整的数据集，将其随机划分为训练集、验证集和测试集，比例为3∶1∶1，以确保不同数据之间的代表性与独立性。

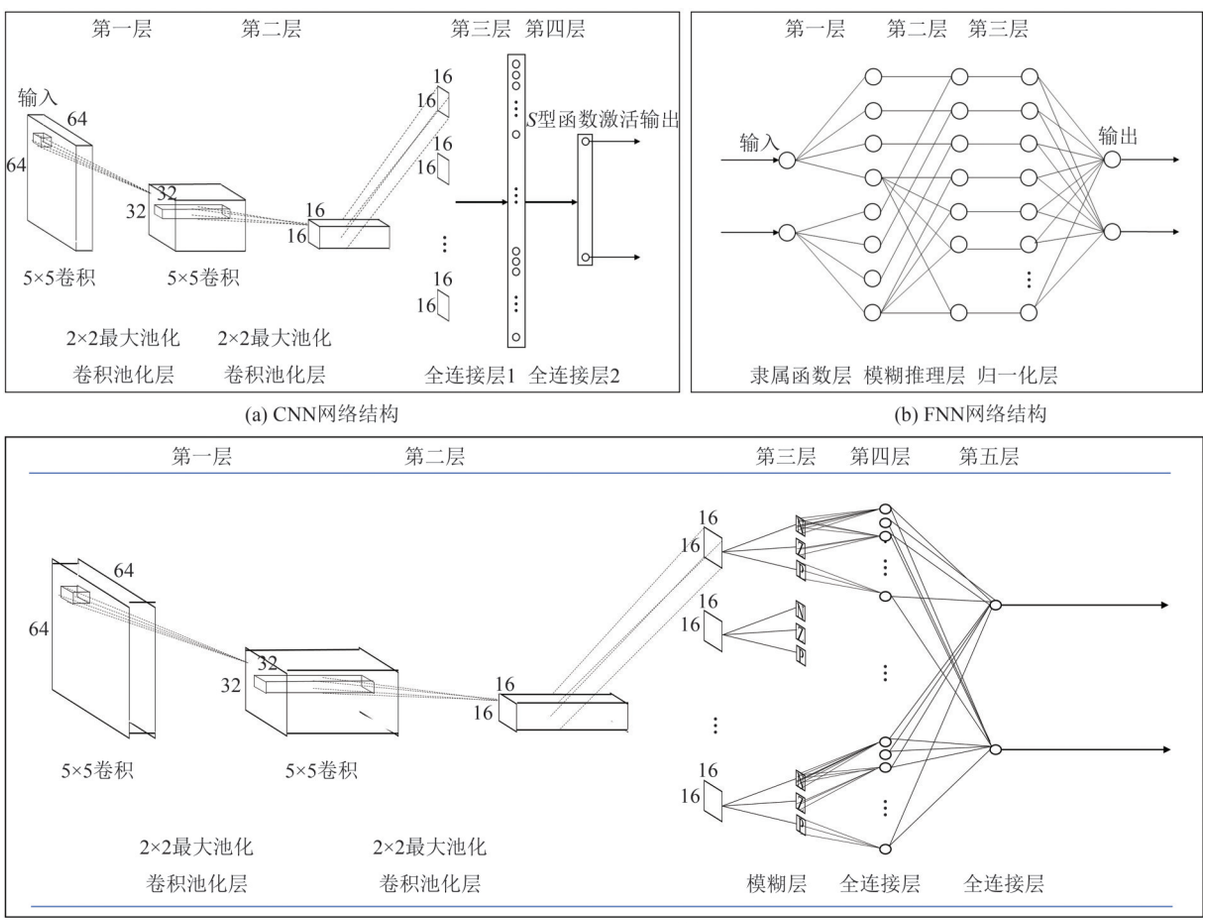
2.2　模型构建与优化

2.2.1　模型构建

SVM是一种强大的监督学习算法,广泛用于分类和回归问题。在震后滑坡易发性建模中,SVM通过构建最大化边界的超平面,将不同易发性区域区分开[26]。其优点在于能够处理高维数据和非线性关系,尤其适用于小样本、高维特征的地质灾害预测。SVM的核函数能够将数据有效映射到更高维空间中,从而实现复杂的非线性分类,提升模型预测的准确性[32]。

RF是一种集成学习方法,通过构建多个决策树并进行投票的方式来决定最终分类。在震后滑坡易发性建模中,RF能够处理大量的多维数据,自动捕捉变量间的复杂关系[24]。其优点在于高效的特征选择和较强的抗过拟合能力,适用于大样本、高维特征的地质灾害预测。RF通过多次训练随机子集,减少了单一决策树可能带来的误差,提高了模型的泛化能力和稳定性[33]。

由于CNN具备强大的特征提取能力和参数共享等优点,在图像处理中表现优异,已被广泛应用于地质灾害领域[13,34],本文采用的CNN模型结构如图3(a)所示。



(a) CNN网络结构　(b) FNN网络结构

(c) CFNN网络结构

图3　3种模型的网络结构

Fig. 3　Network Structures of Three Models

FNN结合了模糊系统与神经网络的优势,模糊系统擅长处理不确定性信息,而神经网络则擅长从大量数据中学习复杂的模式。FNN通过融合两者,在解决模糊性和非线性问题上表现出色,基础的FNN模型结构如图3(b)所示。

CFNN模型是通过将FNN引入CNN的一种模型架构,其结构主要包括卷积层、池化层、激活层、模糊逻辑层和全连接层,其中,模糊逻辑层主要由FNN的隶属函数层和模糊推理层构成,其余层的结构和功能与CNN相同。此外,传统的FNN计算量较大,尤其在结合CNN时,计算复杂度大幅上升,甚至导致难以计算。为了提高运算效率并确保模型的可行性,本文利用构建的CNN模型,结合文献[35]优化后的模糊逻辑层,构建了CFNN模型,如图3(c)所示。其中,模糊逻辑层通过隶属函数对输入数据进行模糊化处理。隶属函数中包含N、Z和P 3个模糊集,计算公式分别为:

$$\begin{cases} N=\mathrm{e}^{-\frac{(y+n)^2}{2\sigma^2}} \\ Z=\mathrm{e}^{-\frac{y^2}{2\sigma^2}} \\ P=\mathrm{e}^{-\frac{(y-n)^2}{2\sigma^2}} \end{cases} \tag{1}$$

式中,y表示输入特征;n和σ分别表示特征映射分布的均值和标准差。

将模糊化后的数据输入模糊推理层以计算模糊输出,并通过全连接层代替传统的去模糊化过程来实现分类结果的输出。在本文构建的CFNN模型中,模糊层涉及两个超参数设置,分别为n和σ,利用网格搜索的方法确定n=1.5,σ=1.2。

选择CFNN模型用于地震诱发滑坡易发性建模拥有显著优势,显著提高了模型的鲁棒性。从模型对多源数据的适应性来看,地形、气象数据等多源数据之间通常具有较大的异质性,CFNN模型能够充分挖掘并融合多源异质数据源的信息,尤其擅长捕捉数据间的复杂空间和非线性关系,从而提升数据的适宜性,并显著增强模型的预测能力。此外,本文采用栅格单元进行地震诱发滑坡易发性建模与评估,尽管这种方法在整体上能有效评估滑坡易发性,但在一些复杂地形和边界区域,滑坡边界的影响可能未得到充分考虑,导致预测结果受到一定程度的影响。CFNN通过卷积层自动提取局部区域的空间特征,并结合模糊推理机制,能够有效处理这些边界区域,展现出较强的适应性。模糊逻辑的引入,允许模型在滑坡易发性较为模糊的区域做出合理预测,进一步提高了评估的准确性和可靠性。

2.2.2 SHAP特征优化策略

SHAP是一种可解释性技术[36],将其引入机器学习领域,用于揭示“黑箱”模型的预测结果,从而提高了模型的透明度和用户对模型的信任度[37]。SHAP值衡量了每个特征对模型预测结果的贡献,能够量化各个特征在模型预测中的影响。SHAP解释包括局部解释和全局解释两个层次:在局部层面,SHAP将Shapley值用于特征归因分析,每次观测的预测结果可以表示为各个特征的SHAP值之和,即通过加性方式得出模型的整体预测结果。在全局层面,SHAP通过对所有样本的SHAP值进行平均,衡量每个特征的平均贡献,以此揭示特征在整体模型中的重要性。对于特征集合A中的特征x_i,Shapley值的计算公式为:

$$\phi_i=\sum_{A\subseteq\{x_1,x_2,\cdots,x_M\}\backslash\{x_i\}}\frac{|A|!(M-|A|-1)!}{M!}\left[f_x(A\cup\{x_i\})-f_x(A)\right] \tag{2}$$

式中,ϕ_i表示第i个特征的Shapley值;M表示特征总数;$f_x(A\cup\{x_i\})$表示在特征子集A的基础上加入特征x_i时的模型预测值;$f_x(A)$表示仅使用特征子集A时的模型预测值。

利用Python软件中的SHAP库,能够轻松估计各个特征对深度学习模型的影响。SHAP特征优化策略的具体流程如图4所示。首先,基于全因子构建深度学习模型;其次,创建一个SHAP解释器对象,该对象使用训练样本作为背景数据,基于这些背景数据对测试样本的特征进行解释分析;然后,生成一幅特征摘要图,展示各个特征从最重要到最不重要的排序;最后,依次剔除对模型影响最小的特征,将剩余的特征重新输入模型中,并通过迭代分析,选出最优的特征组合,找出最优模型。

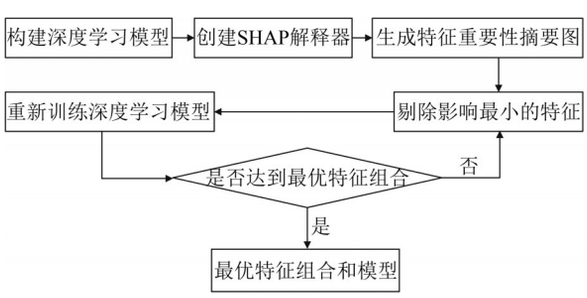


图4 SHAP特征优化策略的具体流程

Fig. 4 Specific Process of SHAP Feature Optimization Strategy

2.3 实验设置及模型评估

2.3.1 实验设置

本文所有代码均在配置为Intel(R) Core(TM) i5-13400F的CPU与GeForce RTX4080(16 GB)GPU的台式计算机上完成,深度学习模型采用TensorFlow 2.10框架构建。模型训练使用Adam(adaptive moment estimation)优化器,初始学习率设为0.000 1,训练轮数为500,批次大小为32。本文未采用任何预训练模型,训练过程中选取验证集中$F1$分数最高的模型进行性能测试。

2.3.2 模型性能评估方法

对于滑坡易发性模型,完成训练集与影响因子数据的模型构建后,需基于测试数据,采用多种指标对模型性能进行全面评估。鉴于滑坡易发性评估可以视为二分类问题,常用的评估指标可通过混淆矩阵计算得出,包括总体精度(A)、召回率(R)、准确率(P)、$F1$分数、ROC曲线及其

AUC,各指标数值越接近1,表明模型性能越好。

本文选取0.5作为二分类问题的分类阈值[15,38-39],当预测结果大于0.5时,将其判定为滑坡样本(正类);反之,则为非滑坡样本(负类)。混淆矩阵中的真正例(true positive, TP)表示正类样本被正确分为正类的数量,假正例(false positive, FP)表示负类样本被误分为正类的数量,真负例(true negative, TN)表示负类样本被正确分为负类的数量,假负例(false negative, FN)则表示正类样本被误分为负类的数量。基于这些定义,使用混淆矩阵计算各项评估指标,计算公式分别为:

$$A=\frac{N_{TP}+N_{TN}}{N_{TP}+N_{TN}+N_{FP}+N_{FN}} \tag{3}$$

$$R=\frac{N_{TP}}{N_{FN}+N_{TP}} \tag{4}$$

$$P=\frac{N_{TP}}{N_{TP}+N_{FP}} \tag{5}$$

$$F1=\frac{2N_{TP}}{2N_{TP}+N_{FP}+N_{FN}} \tag{6}$$

与此同时,ROC曲线作为一种衡量模型敏感度(即灵敏度)和特异性的综合指标,是一条以横轴为FPR、纵轴为TPR的曲线,被广泛应用于二分类模型的优劣评估。通过计算AUC值,可以量化模型的分类性能。AUC值越接近1,说明模型的分类能力越强,整体性能越佳。一般而言,当AUC值介于[0.7,0.8)时,模型表现较好;当AUC值介于[0.8,0.9)时,模型表现较为优良;而AUC值介于[0.9,1]时,则表明模型具备极为出色的性能,具有极好的预测准确性,这种高AUC值的模型能够为用户提供可靠且精确的预测结果。

3　模型性能分析与地震诱发滑坡易发性评价结果

3.1　结果

3.1.1　地震诱发滑坡影响因子分析

地震诱发滑坡的影响因子具有复杂组成,准确识别并选取重要的致灾因子,对评估滑坡易发性及制定有效的防灾减灾策略至关重要。本文选取了16个影响因子,每个因子在滑坡发生过程中的作用均有所不同。3个研究区的地震滑坡共5 990处,采用空间统计分析方法来分析滑坡面积在不同因子数据区间的关系,滑坡面密度等于对应影响因子区间内的滑坡分布面积与研究区总面积的比值。图5、图6展示了不同影响因子下的地震诱发滑坡分布规律。

1)地震因子:根据PGA的计算结果分析(见图5(a)),地震诱发的滑坡主要集中在PGA值为[0.1,1.3)g的范围内,此区间内滑坡发育程度较高;当PGA值大于等于0.3g时,滑坡面积在整个研究区内占比较小,地震诱发滑坡发育程度显著减弱。

2)地形因子:地震诱发滑坡主要分布在高程为[1 000,3 500) m、坡度为[30°,60°)的东北、东、东南及南向坡地(图5(b)~图5(d))。根据图5(e)和图5(f),滑坡面积与平面曲率及剖面曲率的关系均呈现先增后减的单峰特征,在平面曲率为[10,20)区间内,滑坡面积达到峰值,然后随曲率增大整体呈下降趋势,高曲率区间滑坡面积显著减小。在TRI为[1.1,1.6)范围内,滑坡分布较为集中(图5(g))。

3)地质因子:由图5(h)可以看出,砂岩中滑坡发育程度最高,其次为乐平统火山岩、花岗岩和闪长岩。滑坡面积与距断层的距离呈负相关关系,滑坡主要集中于距断层2 km范围内(见图6(a))。

4)水文因子:由图6(b)可以看出,滑坡面积与距河流的距离呈负相关关系,滑坡多发于距河流2 km范围内。然而,当距河流6 km以外时,由于该区域分级面积较大,滑坡发育面积显著增大。从图6(c)可以看出,滑坡主要分布在TWI为[0,8)的区域。月均降水量基于多年平均月降水量计算所得,由图6(d)可知,滑坡集中在月均降水量为[55,65) mm和[70,90) mm的范围。NDVI反映了植被覆盖情况,由图6(e)可知,滑坡主要分布在NDVI为[0.5,0.7)的区域。由图6(f)可知,滑坡面积集中于棕壤覆盖的区域。

5)人类活动因子:由图6(g)可知,滑坡面积与距道路的距离呈负相关关系,滑坡主要集中于距道路1 km以内。由图6(h)可知,滑坡主要分布于林地与草地,符合地震主要发生在多山地区的特征。

3.1.2　SHAP特征摘要分析及地震诱发滑坡影响因子的全局解读

图7为SHAP计算结果的特征摘要图,它提供了一种全局解释,能够显示影响因子的相对重要性,同时反映每个样本的特征值大小。本文选取了16个影响因子,结合SHAP可解释性技术和CFNN模型对其重要性进行了评估,并对九寨沟、芦山和泸定3组测试数据分别进行了独立SHAP分析,综合评价3个区域的混合测试数据。从纵向上观察,图7中的影响因子按照重要性从

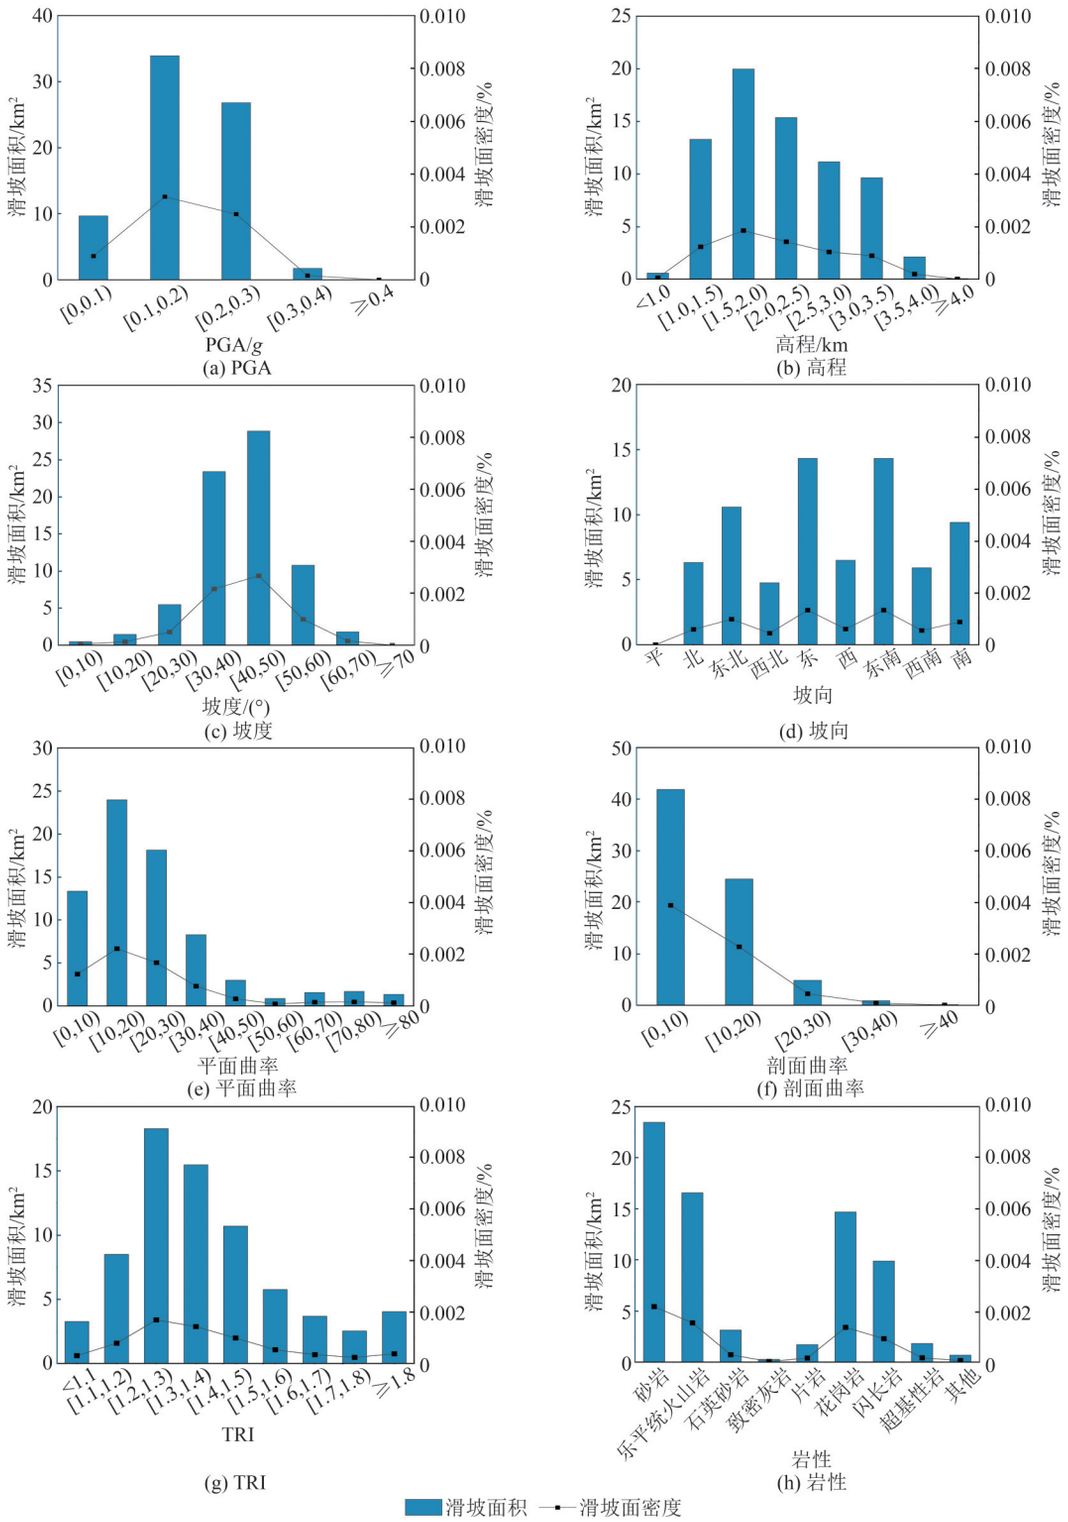


图5 不同影响因子(第一组)下的地震诱发滑坡分布规律

Fig. 5 Distribution Pattern of Earthquake-Induced Landslides Under Different Impact Factors (Group One)

高到低排序,每个点代表一个真实样本,宽度较宽的区域表示大量样本点的聚集。当SHAP值为正时,表明该影响因子对模型产生正向作用;SHAP值为负时,则表明其产生负向作用。从横向上观察,图7样本SHAP值的绝对值越大,表示该特征对预测结果的影响越显著。

由图7(a)可知,在九寨沟地震诱发滑坡的影响因子中,距断层的距离表现出最显著的影响,且大部分样本的特征值较大,呈现正向影响。九寨沟地处青藏高原边缘,地震活动频繁,尤其是局部断层和断裂带的地质活动,使得该地区的滑坡易发性受到地震波传播的显著影响。距河流的距离和高程两个影响因子次之,绝大多数样本的特征值较大并呈现正向影响,这一现象与九寨沟

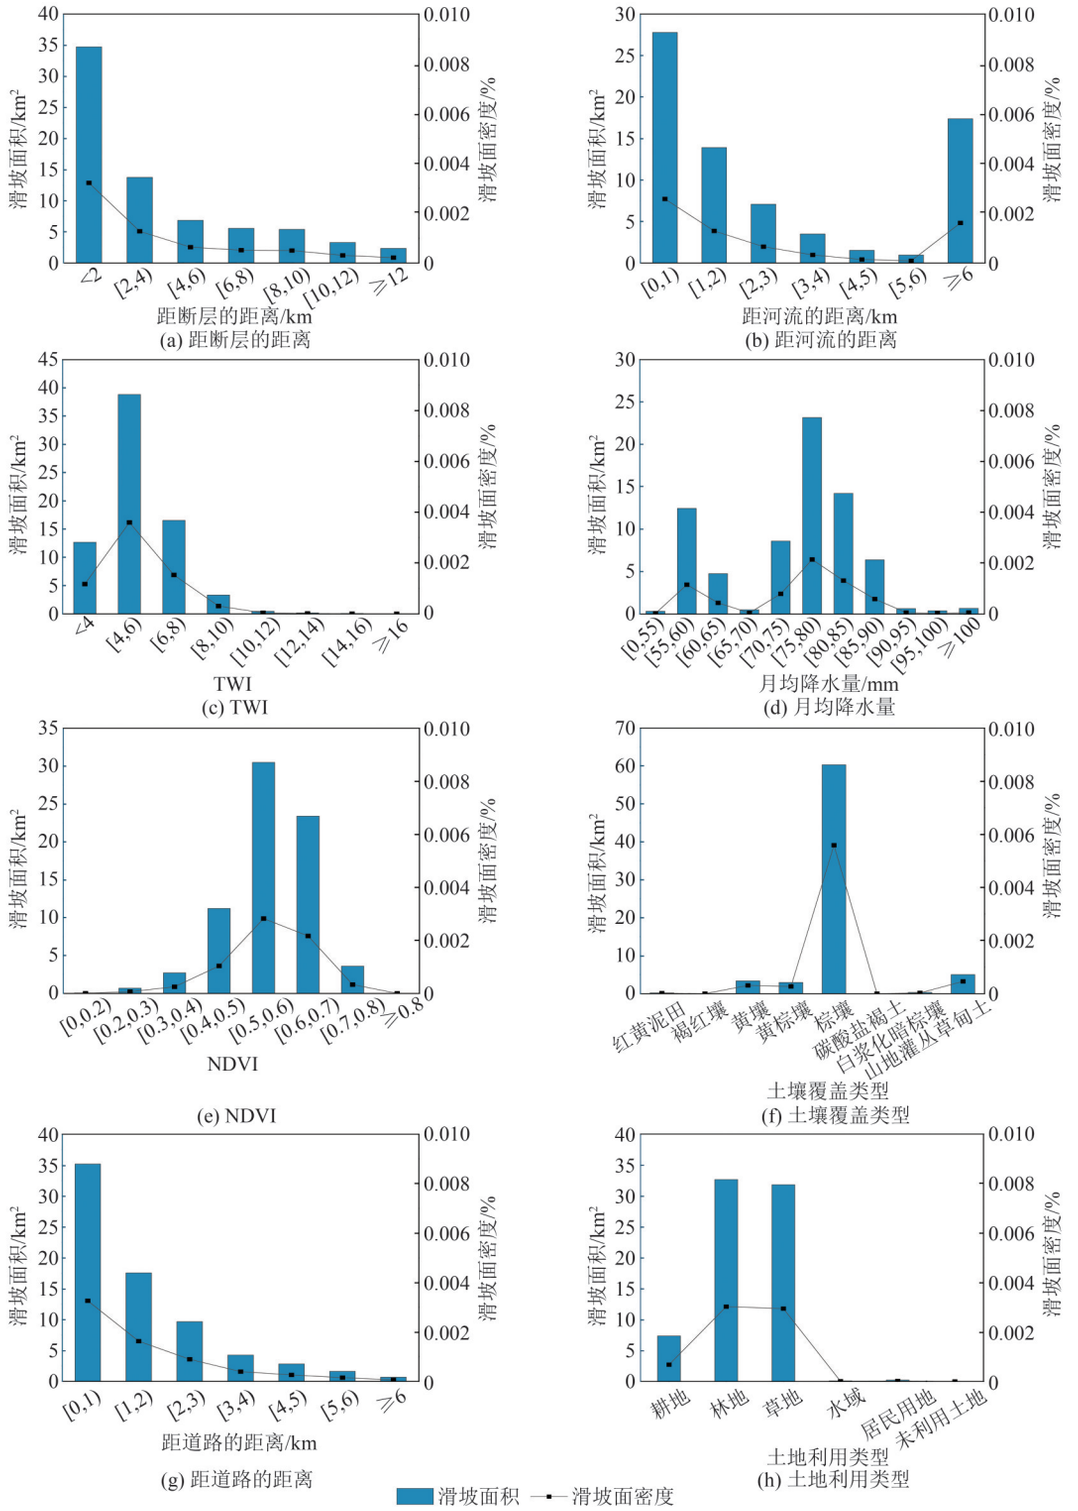
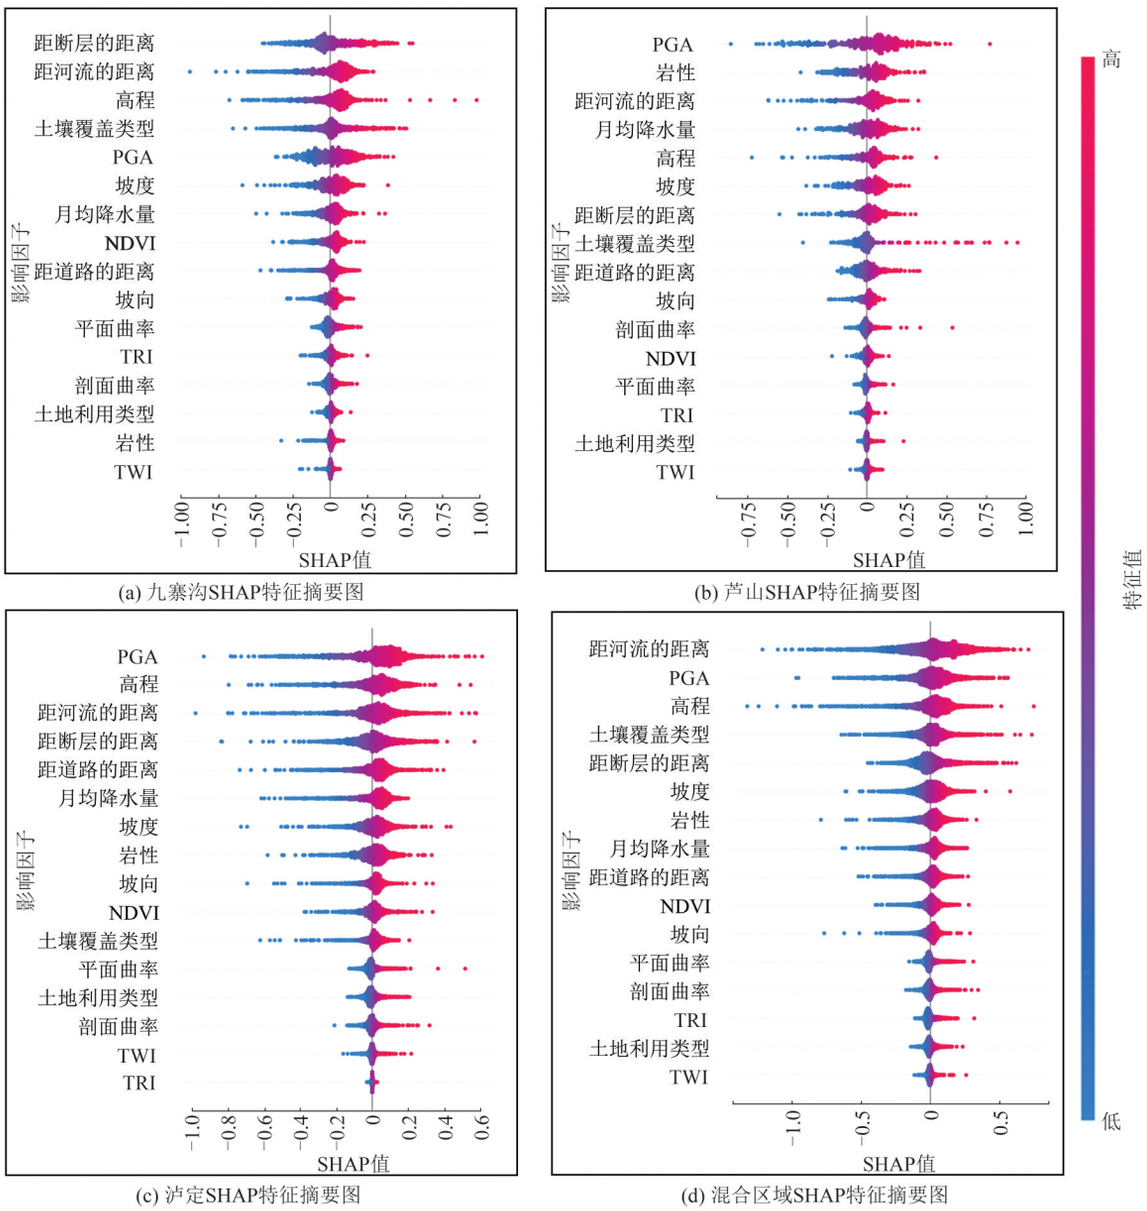


图 6　不同影响因子(第二组)下的地震诱发滑坡分布规律

Fig. 6　Distribution Pattern of Earthquake-Induced Landslides Under Different Impact Factors (Group Two)

山区特殊的水文条件和地势起伏密切相关。该区域多为高山峡谷地形,山区土壤结构松散,加之河流对地形的侵蚀作用,使得距离河流较近的区域具有较高的滑坡风险。特别需要注意的是,九寨沟地质岩性对模型贡献不大,这是由于九寨沟区域较小,尽管区域内地质岩性复杂,但区域内岩性差异较小。由此可见,岩性本身对滑坡的发生并不总是起决定性作用。

由图 7(b)可知,PGA 对芦山地震诱发滑坡影响最大,表现出强烈的正向影响,且样本特征值分布较为分散。芦山地区地震活动较为频繁,地壳运动强烈,导致该区域地震加速度对滑坡发生的影响显著。同时,岩性、距河流的距离和月均降水量这 3 个因子对滑坡的影响也较大,绝大部



(a) 九寨沟SHAP特征摘要图 (b) 芦山SHAP特征摘要图

(c) 泸定SHAP特征摘要图 (d) 混合区域SHAP特征摘要图

图7 SHAP特征摘要图

Fig. 7 Summary Maps of SHAP Feature

分样本的特征值较大且为正向影响。芦山位于四川盆地边缘,地质构造复杂,断层密布。受岩性差异影响,加之松软岩层抗震能力弱,滑坡发生的风险随之加剧。此外,该地区的降水量较高,结合水文条件,强降水与地震的共同作用可能加剧滑坡的发生。

由图7(c)可知,PGA依然是影响滑坡发生的最关键的因子,样本特征值大且分布较为分散,大多呈正向影响。高程、距河流的距离和距断层的距离这3个因子对滑坡的影响也较大,其样本特征值较为集中且呈正向影响。泸定地区地处青藏高原与四川盆地的交界处,地质构造复杂,地震活动频繁。高程较高的地区常常伴随较强的地震活动,造成山体的不稳定性;而距离河流较近的区域,在水文条件和地震的共同作用下,也更容易发生滑坡。距断层的距离对泸定的滑坡影响较大,且该地区的断层活动强烈,因此,距断层的距离对滑坡的触发也起到了关键作用。

由图7可知,PGA在芦山和泸定地震诱发滑坡的影响因子中最重要,在九寨沟地震诱发滑坡的影响因子中排第5;综合来看,其在地震诱发滑坡的影响因子中排第2(图7(d)),说明PGA在诱发滑坡的影响因子中具有关键作用,该结果与地震滑坡致灾因子的普遍认识一致。此外,综合评价显示,距河流的距离对滑坡影响最大,在单独分析中其重要性也位居前3,说明距河流的距离对地震诱发滑坡具有显著影响。平面曲率、剖面曲率、TRI、土地利用类型及TWI的影响最小,显示其在

地震诱发滑坡中的作用有限。

3.1.3　模型性能对比分析

本文的核心目标是探讨CFNN模型的预测准确性,以及SHAP特征优化策略对模型性能的提升效果。为验证CFNN模型的准确性,首先利用CNN模型和CFNN模型对初次选择的16个影响因子进行训练与测试。然后,为了验证CFNN模型在防止过拟合方面的优势,除了利用初次选择的16个因子进行训练外,还基于§3.1.2的SHAP特征重要性排序,剔除了TWI、土地利用类型、TRI 3个影响因子。最后,将剩余的13个影响因子分别输入CNN模型和CFNN模型进行训练,对比分析了二者在训练过程中的损失和$F1$分数指标的波动程度。CNN和CFNN模型基于不同因子的训练、验证和测试结果如图8所示。

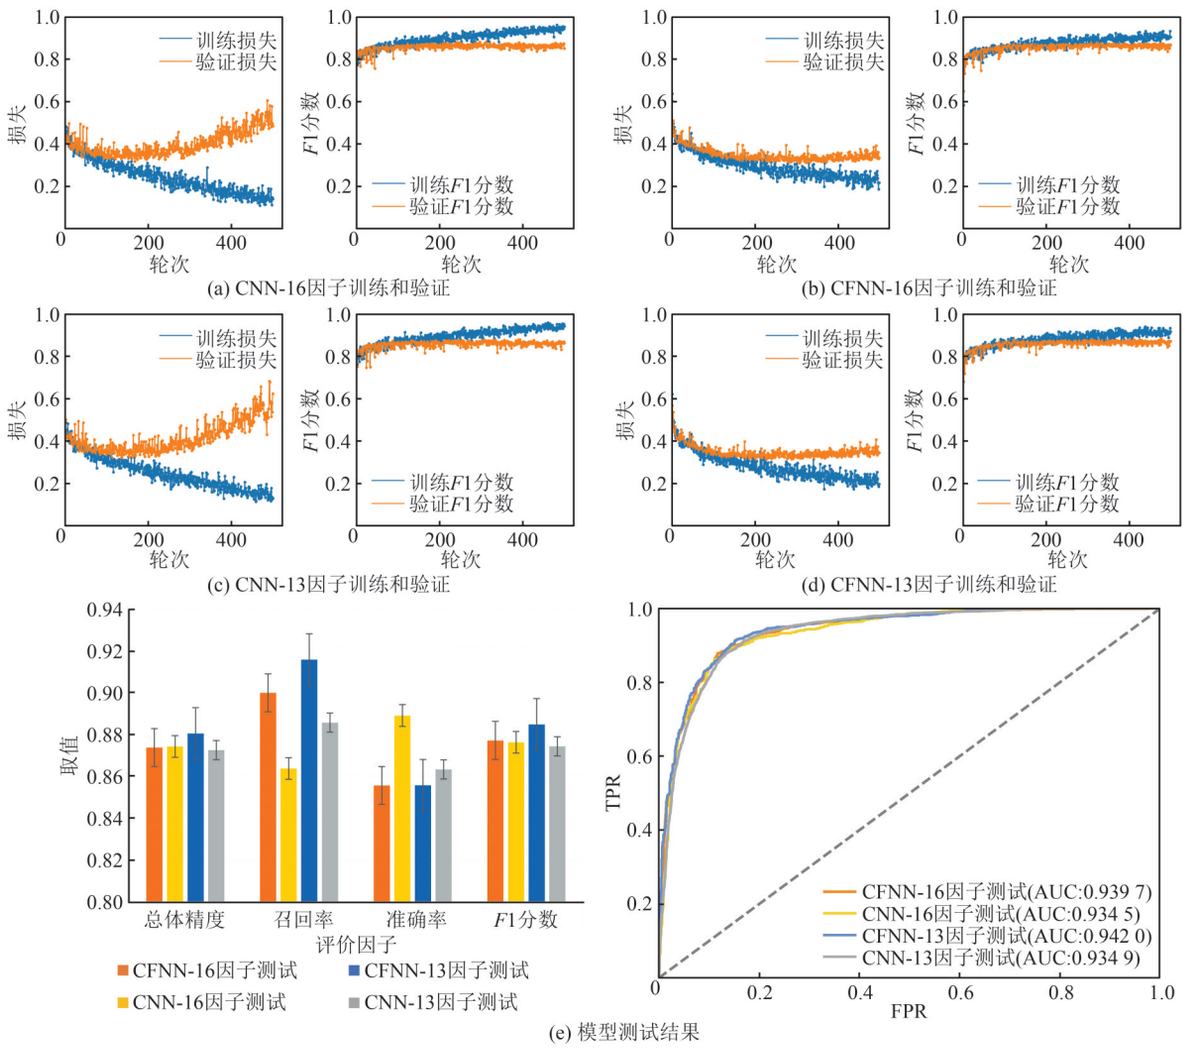


图8　CNN与CFNN模型的训练、验证和测试结果

Fig. 8　Training, Validation and Testing Results of CNN and CFNN Models

由图8(a)~图8(d)可知,在超过200个训练轮次后,CNN模型的训练和验证结果明显出现过拟合现象,而CFNN模型的验证结果则保持平稳,表现出良好的防过拟合能力。由图8(e)可知,在特征筛选前后,CFNN模型的性能均优于CNN模型。总体而言,CFNN模型的预测准确性更高,且能很好地防止训练过程中的过拟合现象。

为了评估SHAP特征优化策略对于提升CFNN模型性能的有效性,本文利用§3.1.2的特征重要性排序,依次剔除TWI、土地利用类型、TRI、剖面曲率和平面曲率5个影响因子,并将剩余特征重新输入CFNN模型进行建模测试。基于SHAP特征优化策略逐步迭代的CFNN模型测试结果如表3所示。

由表3可知,在未剔除任何影响因子时,CFNN模型的整体性能最差;当逐一剔除不重要的影响因子时,模型性能先提升后降低。特别地,当剔除TWI、土地利用类型和TRI这3个影响因子后,模型整体性能达到最佳,测试的$F1$分数最高,为0.884 7,AUC值为0.942 0,且召回率最高,

表3 SHAP特征优化策略对CFNN模型性能的影响

Table 3 Impact of SHAP Feature Optimization Strategy on the Performance of CFNN Model

影响因子数/个	评估指标				
	总体精度	召回率	准确率	*F*1分数	AUC
11	0.872 9	0.902 3	0.852 5	0.876 7	0.943 6
12	0.877 9	0.893 2	0.867 1	0.879 9	0.941 5
13	0.880 4	0.915 7	0.855 7	0.884 7	0.942 0
14	0.879 6	0.909 0	0.858 8	0.883 2	0.941 1
15	0.875 8	0.904 0	0.856 1	0.879 4	0.940 6
16	0.873 7	0.899 8	0.855 6	0.877 1	0.939 7

达到0.915 7。因此,最终模型基于剩余的13个影响因子构建CFNN地震滑坡易发性评估模型。为进一步评估CFNN模型性能的优越性,将其与SVM和RF模型进行对比,结果如表4所示。

表4 不同模型的性能对比

Table 4 Performance Comparison of Different Models

模型	评估指标				
	总体精度	召回率	准确率	*F*1分数	AUC
SVM	0.872 9	0.886 3	0.863 2	0.874 6	0.941 3
RF	0.871 7	0.867 1	0.875 1	0.871 1	0.941 6
CFNN	0.880 4	0.915 7	0.855 7	0.884 7	0.942 0

由表4可知,CFNN模型在所有性能指标上均表现出较为优异的性能,尤其是在召回率和AUC值上明显优于SVM和RF模型。尽管CFNN模型在准确率上略低于其他模型,但其更高的召回率和AUC值表明,CFNN模型在滑坡预测中能够更好地识别潜在滑坡区域,特别适用于对召回率要求较高的场景。因此,本文最终选定CFNN模型作为震后滑坡易发性评估的最佳模型。最优CFNN模型的关键参数为:训练轮数为309,学习率为0.000 1,批量大小为32,激活采用ReLU函数,优化器选择Adam,损失函数为二分类交叉熵。

3.1.4 地震诱发滑坡易发性评估

本文使用最优CFNN模型来预测各研究区域滑坡的发生概率,并在ArcGIS 10.8中将预测结果按等间隔法分为极低、低、中、高、极高5个滑坡易发性区间,区间概率分别为(0,0.2]、(0.2,0.4]、(0.4,0.6]、(0.6,0.8]、(0.8,1]。生成的滑坡易发性分区图如图9所示。对各个区域的滑坡易发性分区结果进行统计分析,结果如表5所示。

如表5所示,本文对图9中的震后诱发滑坡易发性评估结果进行了统计分析。其中,频率比[40]是指某一区域内属于某一易发等级的滑坡点数与该等级面积占总面积的比例之比,可用于衡量滑坡易发性制图的准确性。为了更加直观地展示这一分析结果,本文通过统计图进行了可视化,以便于更好地理解不同区域的滑坡易发性分布,结果如图10所示。

由图9(a)可知,九寨沟滑坡易发性等级较高的区域主要集中在山区和坡度较大的地带,在高易发性区域和极高易发性区域,滑坡数量和面积显著增加。由表5可知,九寨沟区域极高易发区的滑坡数量和滑坡密度表明,该区域地震诱发滑坡频率极高,其滑坡频率比为11.875 6%,说明该地区的滑坡易发性与地震活动密切相关。由图9(b)可知,芦山区域的滑坡易发性等级分布较为分散,尤其是中和高易发性区域。由表5可知,芦山地区极高易发区的滑坡数量、滑坡密度和滑坡频率比均较低,这表明芦山地区的滑坡发生频率较低。由图9(c)可知,泸定区域的滑坡易发性等级分布较为广泛,多处滑坡高、极高易发区主要分布于陡坡及山地地带。由表5可知,泸定区域极高易发区的滑坡数量、滑坡密度、滑坡面积和滑坡频率比均较高,这表明泸定地区的滑坡发生频率较高,尤其是在极高易发性区域,地震诱发的滑坡发育程度较高。

综合来看,由图9可知,通过将实际发生的滑坡位置与易发性分区图叠加进行对比分析,大部分滑坡分布于3次地震事件的极高易发区,即模型预测结果与实际滑坡分布具有高度一致性。通过结合图9和表5的具体分析可以看出,所构建的模型在地震诱发滑坡易发性评估的概率预测方面取得了较高的预测准确性。由表5和图10可知,滑坡频率比随着滑坡易发性等级的提升而显著增大,其中极高易发区的滑坡频率比远高于极低易发区,这一结果进一步证明了CFNN模型在地震诱发滑坡预测中展现了较强的判别能力和可靠性。

3.2 讨论

3.2.1 特征优化方法的对比分析

本文在地震诱发滑坡易发性分析中引入了SHAP特征优化策略,对影响因子进行优化,以提升模型的预测性能。为验证本文方法的可行性与有效性,将本文方法与传统特征筛选方法进行对比[34],利用皮尔逊相关系数(Pearson correlation coefficient, PCC)和信息增益比(information gain ratio, IGR)对特征进行优化。图11展示了PCC和IGR的计算结果。本次对比实验采用

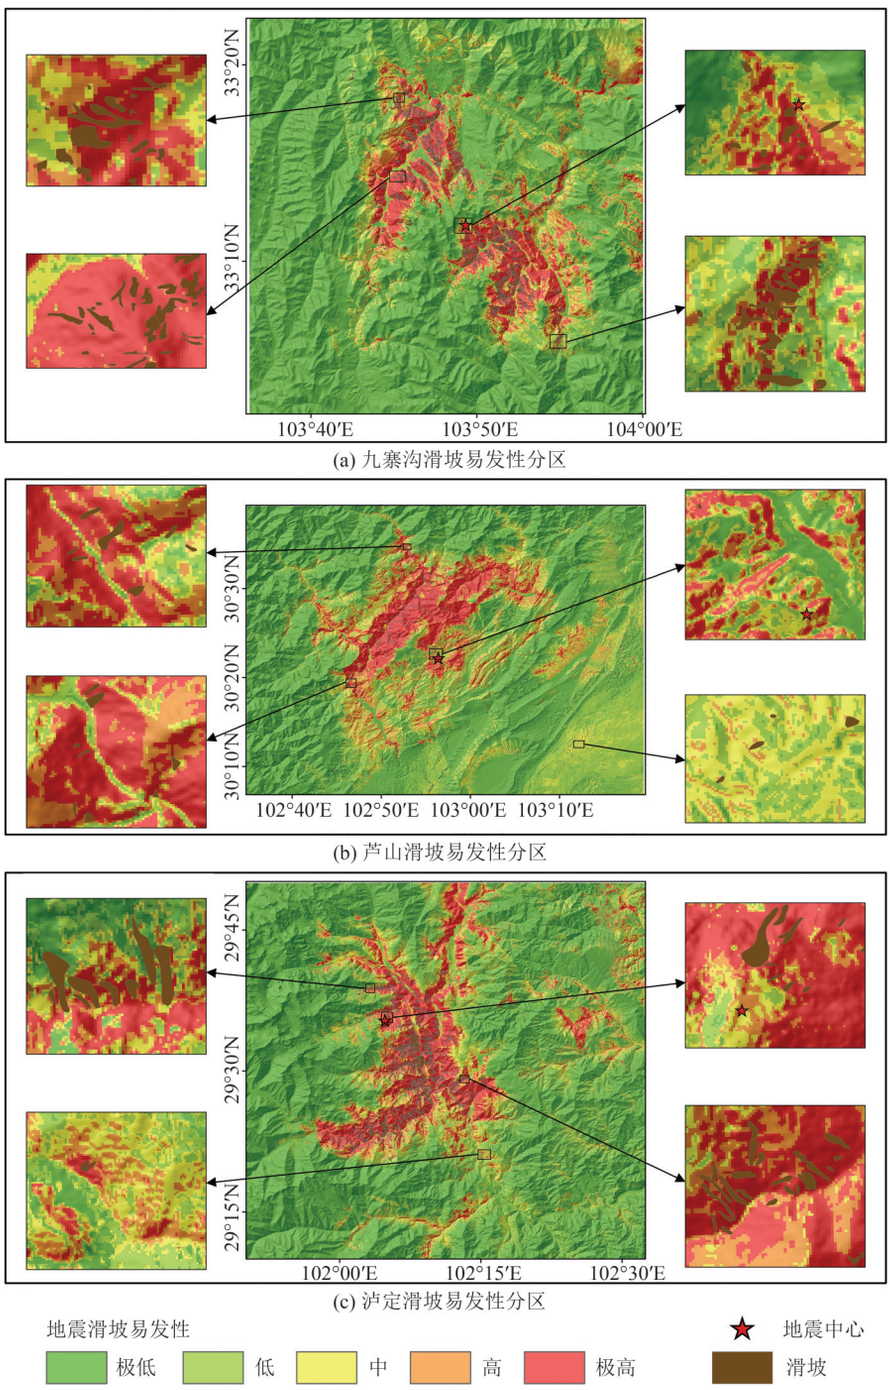


图 9　地震诱发滑坡易发性分区结果

Fig. 9　Zoning Results of Earthquake-Induced Landslide Susceptibility

CFNN模型,考察3种特征优化方法对CFNN模型的影响:

1)方法一根据图7的SHAP特征重要性排序,逐步剔除特征重要性低的因子,即剔除TWI、土地利用类型和TRI 3个影响因子,利用剩余的13个影响因子进行建模。

2)方法二依据图11的计算结果,剔除PCC大于0.5且特征重要性低的因子,即剔除高程、坡度和土地利用类型3个因子,利用剩余的13个影响因子进行建模。

3)方法三根据图11的PCC结果与图7的SHAP特征重要性排序,剔除PCC大于0.5且SHAP特征重要性低的因子,即剔除高程、TRI和土地利用类型这3个影响因子,保留剩余的13个影响因子用于建模。

图12展示了3种方法的模型测试结果,纵轴表示各个指标数值,范围为(0,1),各指标越接近1,表明模型性能越好。结果显示,方法一的AUC最高,性能最优,其次是方法三,而方法二表现最差。这表明传统特征筛选方法对模型性能的提

表5 各区域地震诱发滑坡易发性统计分析

Table 5 Statistical Analysis of Earthquake-Induced Landslide Susceptibility in Each Region

区域	滑坡易发性分区	分区面积/km²	滑坡数/个	滑坡面积/km²	滑坡密度/(个·km⁻²)	频率比/%
九寨沟	极低	975.136 9	35	0.446 4	0.035 9	0.045 8
	低	131.718 8	48	0.354 9	0.364 4	0.269 4
	中	77.382 5	101	0.662 8	1.305 2	0.856 6
	高	67.193 8	187	1.466 5	2.783 0	2.182 5
	极高	123.101 3	1 646	14.619 0	13.371 1	11.875 6
芦山	极低	2 532.528 8	50	0.444 7	0.019 7	0.017 6
	低	755.114 4	61	0.345 5	0.080 8	0.045 8
	中	358.981 9	63	0.495 6	0.175 5	0.138 1
	高	272.897 5	86	0.409 7	0.315 1	0.150 1
	极高	358.409 4	749	4.169 1	2.089 8	1.163 2
泸定	极低	4 179.510 6	77	0.700 8	0.018 4	0.016 8
	低	761.516 3	100	0.862 4	0.131 3	0.113 2
	中	392.145 6	126	1.376 9	0.321 3	0.351 1
	高	307.210 0	274	3.148 5	0.891 9	1.024 9
	极高	554.025 0	2 387	42.644 0	4.308 5	7.697 1

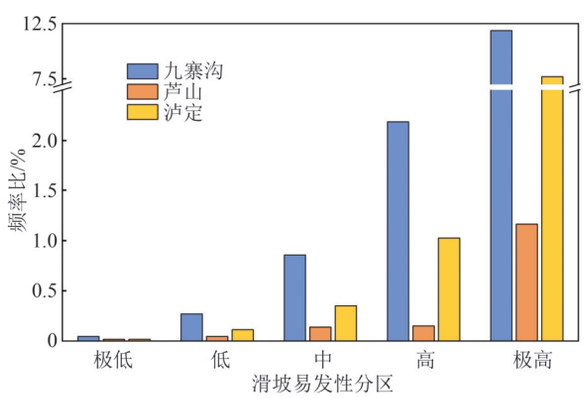


图10 研究区的各易发等级滑坡频率比

Fig. 10 Ratio of Landslide Frequency of Each Susceptibility Level in the Study Area

升效果有限,且难以解释各因子在模型中的具体影响,PCC和IGR方法在深度学习模型特征筛选方面具有一定局限性。相比之下,方法一和方法三中的SHAP特征筛选有助于提升模型性能,其中方法一效果最佳。因此,利用SHAP特征优化策略来优化深度学习的模型性能是最优的选择。

3.2.2 局限性分析

本文虽已利用SHAP特征重要性分析对滑坡预测模型的特征进行了筛选,并有效提升了模型性能,但仍存在一定的局限性。具体而言,本文仅停留在利用SHAP进行全局分析和特征优化的层面,未深入挖掘SHAP在解析单个影响因子对滑坡发生的具体影响方面的潜力,这阻碍了深入探究各单一因子对滑坡的作用机制。本文只选择了16个影响因子进行实验,实际影响滑坡的因子可能更多。此外,尽管本文验证了CFNN模型在处理滑坡灾害预测中的优越性,并展示了FNN在深度学习领域的应用前景,特别是在处理不确定性问题上的优势,但面对多源数据应用日益增长的现实需求,数据质量的不确定性问题愈发凸显。随着数据源的不断丰富,如何有效应对数据不确定性,将模糊逻辑及FNN更深入地融入深度学习模型中,成为未来研究亟待解决的关键问题。这些局限性指明了后续的研究方向,未来将进一步研究各种影响因子对地震诱发滑坡的内在作用机制,同时深入研究数据不确定性问题以及深度学习模型的可解释性问题,以期在滑坡灾害预测领域取得更有突破性的进展。

4 结 语

本文通过CFNN建立了地震诱发滑坡易发性预测模型,综合考虑2017年九寨沟Ms 7.0地震、2022年芦山Ms 6.1地震以及2022年泸定Ms 6.8地震,利用SHAP特征优化策略优化了模型性能。研究的主要成果及结论如下:

1)基于3个地震诱发的滑坡事件,利用地震前后Sentinel-2影像对现存的九寨沟和泸定地震滑坡清单进行修正,并对芦山地震引发的滑坡进行解译。

2)对地震、地形、地质、水文和人类活动5大类共16个影响因子与地震诱发滑坡的空间分布规律进行分析,结果显示,地震诱发滑坡主要分布在高程为[1 000,3 500) m、坡度为[30°,60°)的

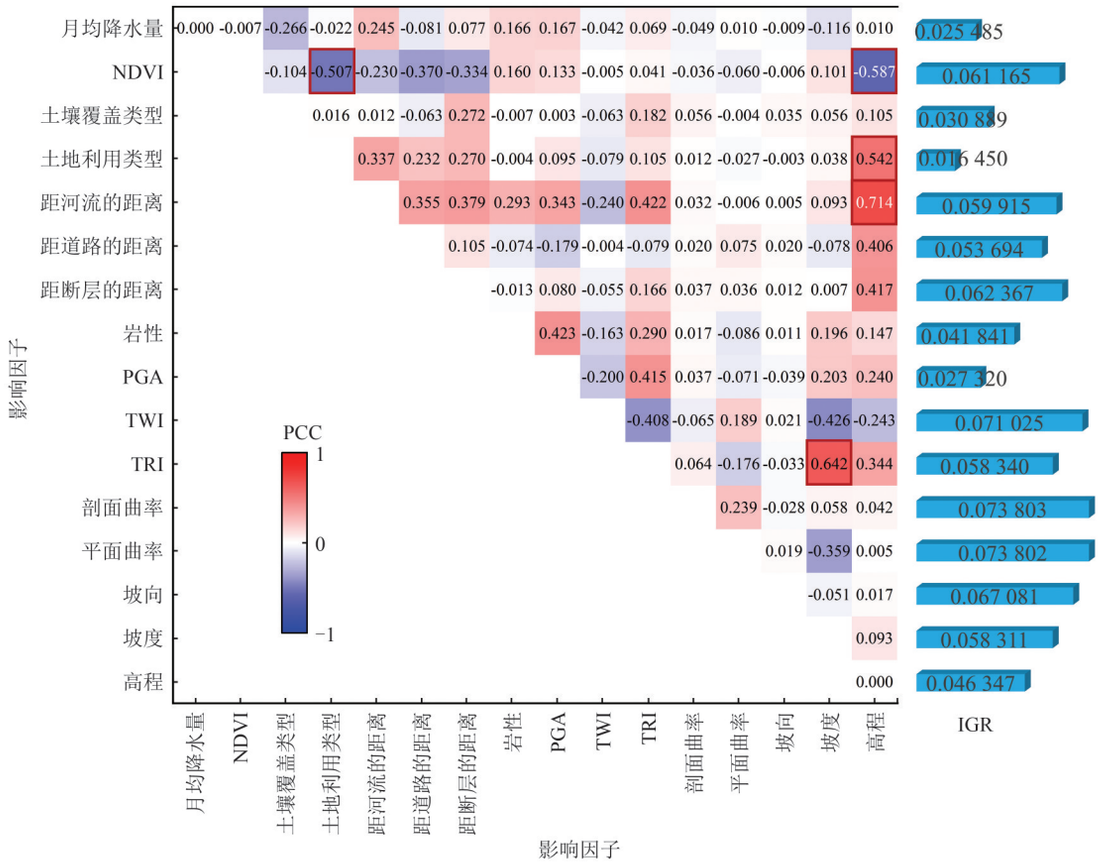


图 11　PCC 和 IGR 计算结果

Fig. 11　Calculation Results of PCC and IGR

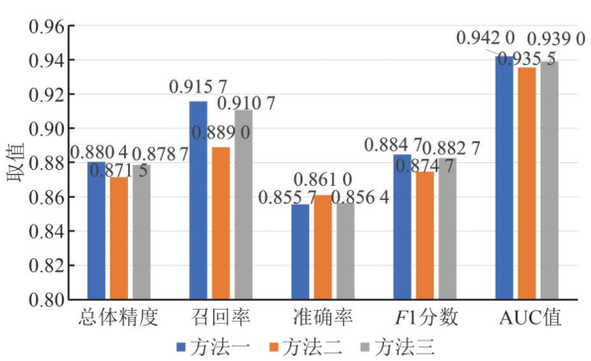


图 12　3种特征筛选方法中CFNN模型的性能测试结果

Fig. 12　Performance Test Results of CFNN Model in Three Feature Screening Methods

东北、东、东南及南向坡地上;距断层 2 km 范围内滑坡密度显著增加。此外,滑坡密度与平面曲率、剖面曲率、距河流的距离和距道路的距离呈负相关关系,大部分滑坡距河流和道路在 2 km 以内。同时,滑坡多发区域的月均降水量主要在[55,65) mm 和[70,90) mm 范围内,表明降水在地震诱发滑坡中有控制作用。

3)本文基于 16 个影响因子初步构建 CFNN 模型,利用 SHAP 对模型进行可解释性分析。SHAP 结果显示,距河流的距离、PGA、高程、土壤覆盖类型和距断层的距离是影响滑坡的主要因子。

4)首先,将 CFNN 模型与 CNN 模型进行对比,发现 CFNN 模型在训练过程中能够有效防止过拟合现象,且测试性能优于 CNN 模型,说明 CFNN 模型性能更优。其次,通过 SHAP 特征优化策略,依次剔除 SHAP 排序中影响最小的因子并反馈至模型后,发现剔除 TWI、土地利用类型和 TRI 时模型性能最佳。然后,将 CFNN 模型与 SVM 和 RF 模型进行对比分析,结果表明,CFNN 模型在地震滑坡易发性评估中的建模表现最为优越,能够准确反映滑坡易发性的空间分布。最后,利用最优模型生成了研究区地震诱发滑坡易发性等级分布图,通过对比实际滑坡与模型预测结果,验证了 CFNN 模型在地震诱发滑坡易发性研究中的准确性。

5)与传统特征筛选方法在地震诱发滑坡易发性评价中的应用相比,SHAP 特征优化策略在深度学习建模过程中展现了显著优势。它通过量化特征贡献度,优化了输入特征,从而有效提升了模型的精度与可靠性,充分证明了 SHAP 可解释性技术在地震诱发滑坡易发性评估中的应

用潜力。本文从数据不确定性与模型可解释性两方面来提升模型性能,鉴于深度学习模型内部机制的复杂性,未深入研究模糊逻辑在深度CNN中的具体作用,仅从概念上分析了其在处理不确定性问题方面的优势。未来应进一步探讨模糊逻辑在深度学习模型内部的机制,以便在数据优化和模型可解释性方面提升模型的可靠性和在滑坡易发性研究中的可信度。

参考文献

[1] 王莞瞳,马思远,严武建,等. 2014年Mw 6.2鲁甸地震滑坡易发性评估:基于卷积神经网络与随机森林算法的对比[J]. 地震地质,2026,48(2):497-519.
WANG Wantong, MA Siyuan, YAN Wujian, et al. Landslide Susceptibility Assessment of the 2014 Ludian Earthquake: Comparative Study Based on Convolutional Neural Network and Random Forest [J]. *Seismology and Geology*, 2026, 48(2): 497-519.

[2] LIU J, ZHANG Y B, WEI J T, et al. Hazard Assessment of Earthquake-Induced Landslides by Using Permanent Displacement Model Considering Near-Fault Pulse-Like Ground Motions[J]. *Bulletin of Engineering Geology and the Environment*, 2021, 80(11): 8503-8518.

[3] MARANO K D, WALD D J, ALLEN T I. Global Earthquake Casualties Due to Secondary Effects: A Quantitative Analysis for Improving Rapid Loss Analyses [J]. *Natural Hazards*, 2010, 52(2): 319-328.

[4] SUN J B, YUE H, SHEN Z K, et al. The 2017 Jiuzhaigou Earthquake: A Complicated Event Occurred in a Young Fault System [J]. *Geophysical Research Letters*, 2018, 45(5): 2230-2240.

[5] AN Y R, WANG D, MA Q, et al. Preliminary Report of the September 5, 2022 Ms 6.8 Luding Earthquake, Sichuan, China [J]. *Earthquake Research Advances*, 2023, 3(1): 100184.

[6] XIAO Z K, XU C, HUANG Y D, et al. Analysis of Spatial Distribution of Landslides Triggered by the Ms 6.8 Luding Earthquake in China on September 5, 2022[J]. *Geoenvironmental Disasters*, 2023, 10(1): 3.

[7] HAN G J, DAI D Q, LI Y, et al. Rapid Report of the December 18, 2023 Ms 6.2 Jishishan Earthquake, Gansu, China[J]. *Earthquake Research Advances*, 2024, 4(2): 100287.

[8] 陈博,宋闯,陈毅,等. 2023年甘肃积石山Ms 6.2地震同震滑坡和建筑物损毁情况应急识别与影响因素研究[J]. 武汉大学学报(信息科学版),2025,50(2):322-332.
CHEN Bo, SONG Chuang, CHEN Yi, et al. Emergency Identification and Influencing Factor Analysis of Coseismic Landslides and Building Damages Induced by the 2023 Ms 6.2 Jishishan (Gansu, China) Earthquake [J]. *Geomatics and Information Science of Wuhan University*, 2025, 50(2): 322-332.

[9] GUZZETTI F. Landslide Hazard Assessment and Risk Evaluation: Limits and Prospectives [C]//The 4th EGS Plinius Conference, Mallorca, Spain, 2003.

[10] GLADE T, CROZIER M J. The Nature of Landslide Hazard Impact[M]//CROZIER M J, GLADE T. Landslide Hazard and Risk. Chichester: Wiley, 2005: 15-46.

[11] CHEN W Y, ZHANG L M. Resilience Assessment of Regional Areas Against Earthquakes Using Multi-source Information Fusion[J]. *Reliability Engineering & System Safety*, 2021, 215: 107833.

[12] 赵占鹜,王继周,毛曦,等. 多维CNN耦合的滑坡易发性评价方法[J]. 武汉大学学报(信息科学版),2024,49(8):1466-1481.
ZHAO Zhan'ao, WANG Jizhou, MAO Xi, et al. A Multi-dimensional CNN Coupled Landslide Susceptibility Assessment Method [J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(8): 1466-1481.

[13] WANG Y, FANG Z C, HONG H Y. Comparison of Convolutional Neural Networks for Landslide Susceptibility Mapping in Yanshan County, China [J]. *Science of the Total Environment*, 2019, 666: 975-993.

[14] GE Y F, LIU G, TANG H M, et al. Comparative Analysis of Five Convolutional Neural Networks for Landslide Susceptibility Assessment [J]. *Bulletin of Engineering Geology and the Environment*, 2023, 82(10): 377.

[15] 秦佳松,李为乐,周胜森,等. 考虑InSAR地表形变的滑坡易发性评价负样本选取与结果优化[J]. 武汉大学学报(信息科学版),2026,51(6):1228-1241.
QIN Jiasong, LI Weile, ZHOU Shengsen, et al. Negative Sample Selection and Result Optimization for Landslide Susceptibility Assessment Considering InSAR Surface Deformation [J]. *Geomatics and Information Science of Wuhan University*, 2026, 51(6): 1228-1241.

[16] PRADHAN B, DIKSHIT A, LEE S, et al. An Explainable AI (XAI) Model for Landslide Suscepti-

bility Modeling[J]. *Applied Soft Computing*, 2023, 142: 110324.

[17] YANG Q Y, WANG X M, YIN J, et al. A Novel CGBoost Deep Learning Algorithm for Coseismic Landslide Susceptibility Prediction[J]. *Geoscience Frontiers*, 2024, 15(2): 101770.

[18] SHARMA S, DUTTA S, ALBINI E, et al. REFRESH: Responsible and Efficient Feature Reselection Guided by SHAP Values[C]//AAAI/ACM Conference on AI, Ethics, and Society, Montreal, Canada, 2023.

[19] CHEN C F, LIU Y, LI Y Y, et al. Explainable Artificial Intelligence Framework for Urban Global Digital Elevation Model Correction Based on the SHapley Additive Explanation-Random Forest Algorithm Considering Spatial Heterogeneity and Factor Optimization[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 129: 103843.

[20] XU X Z, CAO D, ZHOU Y, et al. Application of Neural Network Algorithm in Fault Diagnosis of Mechanical Intelligence[J]. *Mechanical Systems and Signal Processing*, 2020, 141: 106625.

[21] KORSHUNOVA K P. A Convolutional Fuzzy Neural Network for Image Classification[C]//The 3rd Russian-Pacific Conference on Computer Technology and Applications, Vladivostok, Russia, 2018.

[22] LIN C J, YANG T Y. A Fusion-Based Convolutional Fuzzy Neural Network for Lung Cancer Classification[J]. *International Journal of Fuzzy Systems*, 2023, 25(2): 451-467.

[23] FAN X M, SCARINGI G, XU Q, et al. Coseismic Landslides Triggered by the 8th August 2017 Ms 7.0 Jiuzhaigou Earthquake (Sichuan, China): Factors Controlling Their Spatial Distribution and Implications for the Seismogenic Blind Fault Identification[J]. *Landslides*, 2018, 15(5): 967-983.

[24] 范宣梅, 方成勇, 戴岚欣, 等. 地震诱发滑坡空间分布概率近实时预测研究: 以2022年6月1日四川芦山地震为例[J]. 工程地质学报, 2022, 30(3): 729-739.
FAN Xuanmei, FANG Chengyong, DAI Lanxin, et al. Near Real Time Prediction of Spatial Distribution Probability of Earthquake-Induced Landslides: Take the Lushan Earthquake on June 1, 2022 as an Example[J]. *Journal of Engineering Geology*, 2022, 30(3): 729-739.

[25] 方荣新, 陈智潜, 李大炜, 等. 基于北斗PPP-B2b改正信号的地震同震形变实时监测方法[J]. 武汉大学学报(信息科学版), 2026, 51(3): 567-575.
FANG Rongxin, CHEN Zhiqian, LI Dawei, et al. A Method for Real-Time Coseismic Displacement Monitoring Based on BDS PPP-B2b Correction Signals[J]. *Geomatics and Information Science of Wuhan University*, 2026, 51(3): 567-575.

[26] 陈博, 李振洪, 黄武彪, 等. 2022年四川泸定Mw 6.6级地震诱发地质灾害空间分布及影响因素[J]. 地球科学与环境学报, 2022, 44(6): 971-985.
CHEN Bo, LI Zhenhong, HUANG Wubiao, et al. Spatial Distribution and Influencing Factors of Geohazards Induced by the 2022 Mw 6.6 Luding (Sichuan, China) Earthquake[J]. *Journal of Earth Sciences and Environment*, 2022, 44(6): 971-985.

[27] 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.

[28] CAO J, ZHANG Z, WANG C Z, et al. Susceptibility Assessment of Landslides Triggered by Earthquakes in the Western Sichuan Plateau[J]. *Catena*, 2019, 175: 63-76.

[29] LING S X, SUN C W, LI X N, et al. Characterizing the Distribution Pattern and Geologic and Geomorphic Controls on Earthquake-Triggered Landslide Occurrence During the 2017 Ms 7.0 Jiuzhaigou Earthquake, Sichuan, China[J]. *Landslides*, 2021, 18(4): 1275-1291.

[30] YANG S, LI D Y, SUN Y Q, et al. Effect of Landslide Spatial Representation and Raster Resolution on the Landslide Susceptibility Assessment[J]. *Environmental Earth Sciences*, 2024, 83(4): 132.

[31] YU L B, WANG Y, PRADHAN B. Enhancing Landslide Susceptibility Mapping Incorporating Landslide Typology via Stacking Ensemble Machine Learning in Three Gorges Reservoir, China[J]. *Geoscience Frontiers*, 2024, 15(4): 101802.

[32] 武雪玲, 沈少青, 牛瑞卿. GIS支持下应用PSO-SVM模型预测滑坡易发性[J]. 武汉大学学报(信息科学版), 2016, 41(5): 665-671.
WU Xueling, SHEN Shaoqing, NIU Ruiqing. Landslide Susceptibility Prediction Using GIS and PSO-SVM[J]. *Geomatics and Information Science of Wuhan University*, 2016, 41(5): 665-671.

[33] 郭飞, 吴迪, 葛民荣, 等. 连续变量因子分级和机器学习模型对滑坡易发性评价精度的影响[J]. 武汉大学学报(信息科学版), 2026, 51(2): 236-248.

GUO Fei, WU Di, GE Minrong, et al. Influence of Continuous Variable Factor Classification and Machine Learning Model on the Accuracy of Landslide Susceptibility Evaluation[J]. *Geomatics and Information Science of Wuhan University*, 2026, 51(2): 236-248.

[34] HUANG W B, DING M T, LI Z H, et al. Landslide Susceptibility Mapping and Dynamic Response Along the Sichuan-Tibet Transportation Corridor Using Deep Learning Algorithms [J]. *Catena*, 2023, 222: 106866.

[35] HSU M J, CHIEN Y H, WANG W Y, et al. A Convolutional Fuzzy Neural Network Architecture for Object Classification with Small Training Database[J]. *International Journal of Fuzzy Systems*, 2020, 22(1): 1-10.

[36] SHAPLEY L S. A Value for N-Person Games [M]//KUHN H W, TUCKER A W. Contributions to the Theory of Games: Vol. 2. Princeton: Princeton University Press, 1953: 307-317.

[37] LUNDBERG S M, LEE S I. A Unified Approach to Interpreting Model Predictions[C]//The 31st International Conference on Neural Information Processing Systems, Long Beach, USA, 2017.

[38] YANG J, DING M T, HUANG W B, et al. A Generalized Deep Learning-Based Method for Rapid Co-seismic Landslide Mapping[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 16970-16983.

[39] 黄武彪, 丁明涛, 王栋, 等. 基于层数自适应加权卷积神经网络的川藏交通廊道沿线滑坡易发性评价[J]. 地球科学, 2022, 47(6): 2015-2030.
HUANG Wubiao, DING Mingtao, WANG Dong, et al. Evaluation of Landslide Susceptibility Based on Layer Adaptive Weighted Convolutional Neural Network Model Along Sichuan-Xizang Traffic Corridor[J]. *Earth Science*, 2022, 47(6): 2015-2030.

[40] YU L B, CAO Y, ZHOU C, et al. Landslide Susceptibility Mapping Combining Information Gain Ratio and Support Vector Machines: A Case Study from Wushan Segment in the Three Gorges Reservoir Area, China[J]. *Applied Sciences*, 2019, 9(22): 4756.