

• 土木工程 •

DOI:10.15961/j.jsuese.202201138



本刊网刊

基于OOD泛化性验证和深度全连接神经网络的 泥石流易发性评价方法

郭鹏宁¹, 邢会歌^{1*}, 李从江^{2,3}, 吴雨鑫¹, 李海波^{2,3}

(1.四川大学 建筑与环境学院, 四川 成都 610065; 2.四川大学 水利水电学院, 四川 成都 610065;
3.四川大学 山区河流保护与治理全国重点实验室, 四川 成都 610065)

摘要: 提升易发性评价精度有助于山区泥石流灾害早期的识别和监测预警。大部分机器学习模型在训练、测试集合上表现良好, 但实际应用过程精度较差, 不利于工程选址规划和防灾减灾, 如何提高机器学习模型评价精度与泛化性具有重要意义。选取深度全连接神经网络, 与梯度提升树、随机森林模型和贝叶斯网络等机器学习方法共同进行模型精确性评价和OOD(out-of-distribution)泛化性验证, 从而找出在训练、预测和应用中均具有较高精度的方法。以四川省雅安市为例, 采用小流域单元进行区域网格划分, 将数据集按7:3比例随机分为训练集和测试集, 使用经验法则(3-sigma)剔除异常数据, 并基于多变量(IterativeImputer)和K-近邻法对缺失值填充进行泥石流灾害易发性评价。在泥石流易发性因子的共线性、敏感性和预测能力的分析结果基础上, 选定14个易发性因子构建模型评价指标体系, 进行泥石流易发性评价与对比。通过对模型的精确性评价及OOD泛化性验证发现: 深度全连接神经网络模型曲线下的面积(AUC)、准确率(Acc)、召回率(Recall)的值比梯度提升树等的计算结果分别超出了0.027、0.02、0.02, 而平均绝对值误差(MAE)降低了0.003; OOD泛化性验证准确度超出了0.056。研究表明, 深度全连接神经网络对于泥石流易发性评价的预测效果较好, 能够提高泥石流评价的精度, 增加评价的适应性, 可为泥石流易发性评价提供新思路。

关键词: 泥石流灾害; 易发性评价; 深度学习算法; OOD泛化性验证; 深度全连接神经网络

中图分类号: P694

文献标志码: A

文章编号: 2096-3246(2024)04-0182-12

中国地形条件复杂, 地质灾害分布广、活动频、危害重, 是世界上地质灾害最为严重的国家之一^[1]。根据自然资源部发布的《2021年全国地质灾害灾情及2022年地质灾害趋势预测》^[2]: 2021年, 全国发生地质灾害4 772起, 造成80人死亡、11人失踪, 产生直接经济损失32亿元。其中, 泥石流灾害尤为严重, 造成巨大的人员伤亡和经济损失, 如: 2021年8月11日, 四川省雅安市宝兴县泥石流造成财产损失达900万元; 2021年9月26日, 四川省雅安天全县泥石流造成7人遇难、7人失联。为了尽可能减少自然灾害造成的损失, 自然资源部明确指出地质灾害早期识别和监测预警工作的核心任务之一是解决“隐患点在哪里”的问题^[3], 这就需要泥石流易发性预测具有一定的精

度, 以提高泥石流预警的成功率。泥石流具有突发性和破坏性, 通常受到地震、强降雨和人类活动的影响, 准确预测泥石流的空间分布和易发区域不仅是防灾减灾工作的重点和难点, 也是泥石流易发性预测中一项迫切的科学任务。

以往的泥石流识别和监测预警研究, 主要是对泥石流形成无分选堆积扇、漫滩堆积等痕迹的地面进行目测调查, 虽然准确率高, 但受人力限制, 识别范围较小^[4]。基于遥感和GIS技术构建相关目视解译标志进行泥石流有效识别^[5], 具有范围大的优势, 但准确率受限。为了兼顾大范围识别和准确率, 学者基于环境因子, 采用多种方法进行泥石流易发性评价, 主要分为3类: 定性方法、传统统计方法和机器学习

收稿日期: 2022-10-20 修回日期: 2023-02-10 网络出版日期: 2023-03-17

基金项目: 国家自然科学基金区域创新发展联合基金(U20A20111); 四川省青年科技创新研究团队项目(2020JDTD0006)

作者简介: 郭鹏宁(1999—), 男, 硕士生。研究方向: 灾害地质风险评价。E-mail: ning46932647@163.com

*通信作者: 邢会歌, 副教授, E-mail: Hgxing@scu.edu.cn

(ML)方法^[6]。定性方法主要依靠专家经验进行打分,结果较为主观。传统统计方法简单直观,但需要稳定性较高的数据,且不能反映非线性因素的影响^[7],如确定性系数模型^[8]、逻辑回归模型^[9]等。机器学习方法具有更高的灵活度、准确率及计算效率,如随机森林模型^[10]、支持向量机^[11]等。刘永垚等^[12]采用随机森林算法预测汶川地震重灾区的泥石流易发性,模型AUC的平均值达0.84。李坤等^[13]采用多粒度级联森林评价东川区泥石流的易发性,验证数据集上gc-Forest模型的AUC值达0.917 6,整体预测性能较好。

深度学习是机器学习的一个重要分支,在分析地质灾害数据方面具有很大潜力^[14]。Ullah等^[15]使用卷积神经网络进行灾害易发性预测,并通过准确率、平均绝对误差等评估模型。Li等^[16]将卷积神经网络与两种进化优化算法结合进行泥石流易发性预测,并使用ROC曲线评估结果的有效性。Prasetya等^[17]使用循环神经网络进行降雨预测,并使用准确率对模型进行评估。现有研究有助于提升对深度学习方法及模型评价的认识。

然而,大多数山区泥石流灾害易发性研究只关注了模型评价的统计指标,对于模型泛化性的关注较少。较高的统计指标分数并不能完全反映模型的实际预测能力,泥石流存在不确定性高、数据特征难以捕捉的问题,部分模型在训练集甚至测试集上表现良好,但对不符合模型数据分布的数据集,预测结果与实际情况存在极大偏差,即模型的外推问题^[18]。为了解决这一问题,Chatterjee等^[19]引入OOD泛化性验证筛选高泛化性模型,提高易发性评价的精度。泛化性指模型经过训练后,应用到新数据集并做出准确预测的能力^[20],一般泛化性指训练集训练的模型在测试集上的性能,而OOD泛化性则考虑与训练、测试数据分布不同数据的泛化能力。目前,关于OOD泛化性研究是机器学习领域的热门问题^[21],提高OOD泛化性的方式主要包括增广数据空间、优化模型求解、减小域间差异等。

栅格单元忽略了实际地形因素,因此导致泥石流易发性预测误差的产生,而流域单元按照一定的地貌特征划分,可以更真实地反映环境变化及存在差别的界限,从而得出客观、精确的评价结果^[22]。

综上所述,采用流域为评价单元研究四川省雅安市2010—2021年的泥石流灾害点数据,并将数据集按7:3的比例随机分为训练集和测试集,使用3-sigma剔除异常数据,采用IterativeImputer和K-近邻法进行缺失值填充,得到完整且没有异常值的数据集。建立泥石流易发性评价指标体系,并采用多重

共线性分析、频率比法和信息增益率法验证指标合理性。分别构建深度全连接神经网络、梯度提升树、随机森林模型和贝叶斯网络,对研究区泥石流易发性进行大范围、高精度评价,并通过Acc、Recall、MAE、AUC这4个指标评价模型精确性。同时,将4种模型(使用泥石流历史数据训练)的预测结果与实际泥石流的发生情况对比,统计实际发生在中、高和极高易发区的泥石流数量,以此计算模型的OOD泛化性,进而筛选出性能优越的模型。研究结果可为管理灾害易发区泥石流风险及选择易发性评价方法提供科学依据。

1 泥石流易发性评价方法

研究技术路线如图1所示。

具体步骤为:1)评价指标初选及数据收集、数据预处理;2)使用多重共线性分析、频率比法和信息增益率法3种方法进行指标筛选;3)分别基于深度全连接神经网络、梯度提升树、随机森林模型和贝叶斯网络构建泥石流易发性评价模型;4)采用AUC、Acc、Recall、MAE进行精确性评价,将模型预测结果与2019—2021年实际发生的泥石流情况对比,进行OOD泛化性验证。

1.1 方法介绍

1.1.1 深度全连接神经网络

深度全连接神经网络是一种前馈神经网络,可实现无监督学习,从而以更快的收敛速度、更高的拟合精度逼近现实^[23]。同时,不同样本的梯度产生相干性,使深度全连接神经网络具有良好泛化性^[19]。

深度全连接神经网络结构如图2所示,由3部分组成:输入层、隐含层和输出层。在输入层选取与泥石流易发相关程度较高的流域面积、流域高差和平均坡度等14个因子作为模型的输入;隐含层由多层构成,通过引入激活函数,将非线性因素引入神经元,使其逼近任何非线性函数,从而对输入数据进行特征提取;输出层将模型提取的特征进行特征转换,结果表示泥石流发生的概率。

与传统神经网络相比,深度全连接神经网络的节点之间为全连接且更强调网络的深度。全连接指的是每个节点与下一层节点之间均有运算关系。深度指的是输出层和隐含层的层数之和。采用试错法及参数网格搜索,以均方根误差的负数为得分,确定隐含层数量、各隐含层神经元数量。激活函数对模型起重要作用,可使模型获得数值间的非线性关系,并加快收敛。Relu函数是非零为中心的输出函数,具有稀疏表达能力;Logistic函数具有数据在传递过程中

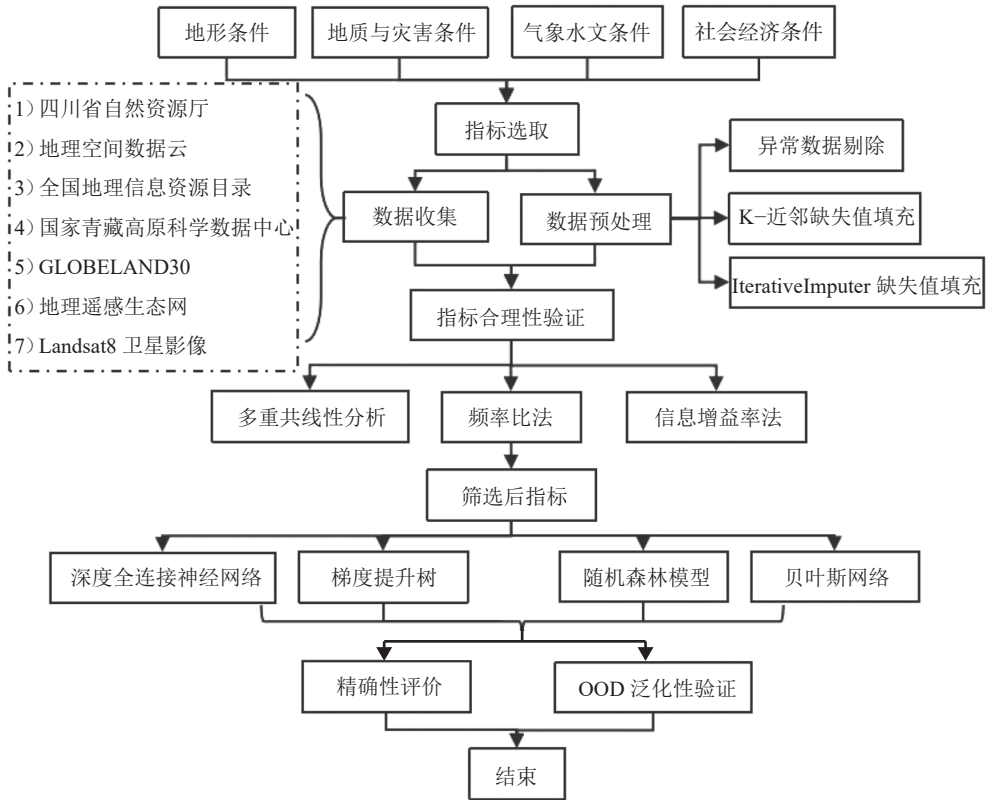


图 1 技术路线

Fig. 1 Technology road




图 2 深度全连接神经网络结构

Fig. 2 Structure of deep fully connected neural networks

不容易发散的优点。通过模型在测试集上的精度变化(图3),确定模型的激活函数为Relu:

$$\text{Relu}(x) = \begin{cases} \max(0, x), & x \geq 0; \\ 0, & x < 0 \end{cases} \quad (1)$$

式中, x 为输入值。

模型采用交叉熵损失函数,通过表示已知数据值的真实分布与预测分布之间的差异,使预测值逐渐逼近输入真实值^[24],从而提高模型的预测精度。交叉熵损失函数如式(2)所示:

$$L(\hat{y}_i, y_i) = -\frac{1}{n} \sum_{i=1}^n (y_i \ln \hat{y}_i - (1 - y_i) \ln(1 - \hat{y}_i)) \quad (2)$$

式中, L 为交叉熵损失函数, n 为样本个数, y_i 为第 i 个样本标签值, \hat{y}_i 为第 i 个样本预测值。

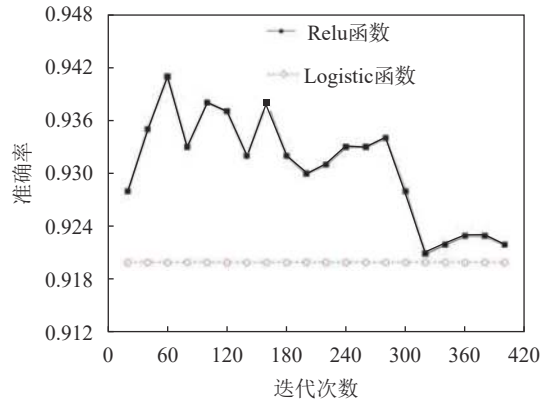


图 3 模型激活函数选择

Fig. 3 Selection of activation function

基于目前使用最广泛的梯度下降法,采用自适应矩估计优化算法,利用梯度的1阶矩估计和2阶矩估计动态调整每个参数的学习率。同时,在传统优化算法优势的基础上,进一步提高模型的学习效率。

1.1.2 其他方法

梯度提升树(GBDT)是一种以回归树为基学习器的集成学习算法,通过每一棵树学习之前所有树的残差和结果,利用损失函数的负梯度在当前模型中的值作为残差近似值,以拟合回归树,并得到最终

预测结果。

随机森林模型是经典的装袋模型(bagging),模型的弱学习器为决策树模型,采用自助法生成训练子集;各个训练子集各自生成决策树之后,通过投票产生分类结果,最终选择 N 个决策树回归预测结果的平均值作为最终预测结果。

贝叶斯网络是一种概率图模型,通过有向无环图刻画属性之间的依赖关系,并使用条件概率表描述属性的联合概率分布。在确定最优网络结构及节点的先验概率、后验概率之后,计算推理出预期事件发生概率分布作为最终结果。

1.2 模型性能比较

以往研究表明,大多数泥石流易发性评价的模型评估在统计性指标AUC和Acc上都取得了大于80%的较高验证分数。然而,高的统计指标验证分数只反映模型对于当前数据集的拟合优度,并不能完全反映对于待预测泥石流数据集的实际预测性能^[25]。因此,在对模型精度进行评价的基础上,进一步通过OOD泛化性验证检验模型的实际预测性能。

1.2.1 精确性评价

运用Acc、Recall、MAE、AUC这4个统计指标对模型精度进行评价。其中:Acc为预测正确的样本在所有样本中的比例,可反映出易发性预测的正确率;Recall为预测泥石流的样本在实际泥石流的样本中的比例;MAE为预测值与真实值之间的平均绝对误差,该值越小表示模型越优秀;AUC指ROC曲线下面积,是衡量评价结果精度的一个标准,AUC的值范围为(0,1),其值越高表示评价结果越精确。具体计算方法如下:

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$R = \frac{TP}{TP + FN} \quad (4)$$

$$M = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|, M \in [0, +\infty) \quad (5)$$

式(3)~(5)中: A 、 R 、 M 分别表示Acc、Recall、MAE的值; TP 表示该小流域单元被正确分类为发生了泥石流; TN 表示被正确分类为未发生泥石流; FP 表示分类为发生泥石流,实际未发生; FN 表示分类为未发生泥石流,实际发生了。

1.2.2 OOD泛化性验证

OOD指的是模型在训练集和测试集中的数据分布与实际运用过程中的数据分布并不相同,具体表示为:

$$P_{tr,te}(X, Y) \neq P_f(X, Y) \quad (6)$$

式中, $P_{tr,te}(X, Y)$ 与 $P_f(X, Y)$ 分别表示训练与实际使用数据分布不同、测试与实际使用数据分布不同。

OOD泛化性验证研究的是模型对于实测数据的预测性能^[26]。在精确性评价的基础上进行OOD泛化性验证的必要性有以下几点:

1)部分模型虽然在训练集与测试集上表现良好,但在运用过程中对不符合当前数据分布特征的数据集预测精度较差,可通过OOD泛化性验证,筛选出高泛化性模型;

2)用于OOD泛化性验证的数据独立于模型训练和测试的数据,OOD泛化性验证对模型评价更客观;

3)泥石流易发性绘图的准确性以更为直观的形式表现出来,能提高泥石流易发性评价的可信度。

OOD泛化性验证,即将4种模型(使用泥石流历史数据训练)的预测结果与实际泥石流的发生情况对比,统计实际发生在中、高、极高易发区的泥石流数量。

2 研究区域及评价指标选取

2.1 研究区域与数据来源

研究区概况如图4所示。雅安市位于四川盆地西缘,介于 $28^{\circ}51' \sim 30^{\circ}56'N$ 、 $101^{\circ}56' \sim 103^{\circ}23'E$ 之间,位于龙门山断裂带南段,相对高差大,山脉纵横。雅安市多数县区年均降雨量为 $1\ 000 \sim 1\ 800\text{ mm}$ ^[27];面积超过 $1\ 000\text{ km}^2$ 的河流有11条,占全市面积的97%,水系丰富。此外,复杂的地形条件和特殊的气候状况,导致其长期饱受泥石流灾害侵扰。因此,选择雅安市作为研究区具有重要现实意义。为了便于模型训练,本文收集多种资料,数据说明如表1所示。

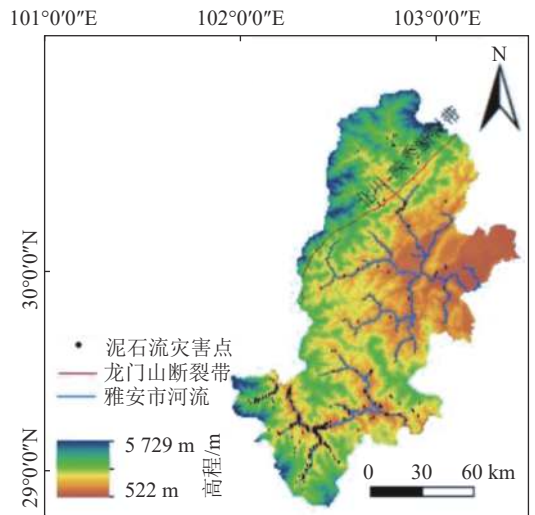


图4 研究区概况

Fig. 4 Overview of the study area

表 1 数据说明

Tab. 1 Data declaration

数据类别	数据源	文件类型	分辨率	处理平台
雅安市泥石流、滑坡灾害点数据	四川省自然资源厅 (http://dnr.sc.gov.cn/)	Excel		ArcGis 10.7
雅安市GDEM V3 30 M 分辨率数字高程数据	地理空间数据云 (http://www.gscloud.cn/)	Img	30 m	ArcGis 10.7
雅安市路网、居民点信息及水系数据	全国地理信息资源目录服务系 (https://www.webmap.cn/)	Shp	点矢量、 线矢量	ArcGis 10.7
雅安市逐月降雨量数据(2010—2021年)	国家青藏高原科学数据中心 (http://data.tpdc.ac.cn/)	Nc	1 000 m	ArcGis 10.7
雅安市用地类型数据	GLOBELAND3 (http://www.globeland30.org/)	Shp	30 m	ArcGis 10.7
雅安市地层岩性、活动断层长度数据	地理遥感生态网 (http://www.gisrs.cn/)	Shp	面矢量、 线矢量	ArcGis 10.7
雅安市Landsat8卫星影像数据(2018年)	美国地质调查局 (https://earthexplorer.usgs.gov/)	Tif	30 m	ENVI5.3

2.2 流域单元划分

目前,采用的栅格单元大多数忽略了泥石流的发育特征,而小流域单元是按照地貌特征对小流域进行划分,不仅可以真实反映出自然环境的变化及存在差别的界限,更符合研究区域泥石流的发育特征,从而得到更加客观的评价结果^[22]。因此,评价单元选择小流域单元。

使用ArcGIS 10.7的水文分析功能,通过对数字高程模型(DEM)的数据进行填注,计算流向、流域、流量和栅格等后对小流域单元进行划分。考虑研究区域泥石流形成情况,在栅格计算及汇水栅格阈值时,经过反复对比及咨询专家意见,最终确定以12 000为阈值提取河网划分小流域,并进行边界校正,最终得到959个小流域单元,平均单元面积为16.34 km²,最小单元面积为0.85 km²,最大单元面积为106.39 km²。小流域划分结果如图5所示。

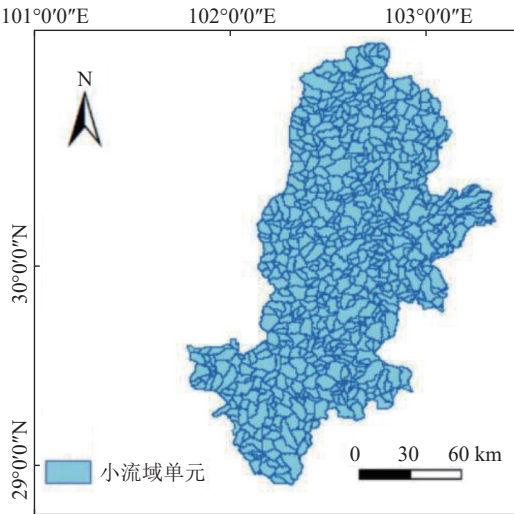


图 5 小流域划分结果

Fig. 5 Division results of watershed units

2.3 模型评价指标选取与验证

2.3.1 指标选取

泥石流发育必备3个基本条件:1)有利于泥石流发生和运动的地形条件;2)丰富的松散土石碎屑物等物源条件;3)充足的水源条件。因此,结合研究区

内的泥石流孕灾条件,从地形条件、地质与灾害条件、气象水文条件和社会经济条件4个方面,选取流域面积、流域高差、平均坡度、平均坡向、沟壑密度、沟床比降、归一化植被指数(NDVI)、活动断层长度、地层岩性、滑坡个数、汛期月均降雨量、用地类型、居民点密度和路网密度共14个环境因子构建模型评价指标体系。

2.3.2 指标合理性验证

采用多重共线性分析验证影响因素之间的共线性,采用频率比法计算各影响因素对于泥石流发生的敏感性,采用信息增益率法衡量各个影响因素的预测能力,以此对影响因素进行评估。

1)多重共线性分析。使用SPSS 27.0软件对选中的14个指标进行多重共线性分析。当且仅当容差小于0.2且方差膨胀系数大于5时,指标之间存在共线性问题。多重共线性分析结果如表2所示。结果表明:最小容差值为0.226,最大方差膨胀系数为4.433。因此,14个影响因素均满足共线性要求。

表 2 多重共线性分析结果

Tab. 2 Results of multicollinearity analysis

影响因素	容差	方差膨胀系数	影响因素	容差	方差膨胀系数
流域面积	0.453	2.206	活动断层长度	0.975	1.026
流域高差	0.226	4.433	地层岩性	0.759	1.318
平均坡度	0.919	1.088	滑坡个数	0.600	1.667
平均坡向	0.978	1.022	汛期月均降雨	0.381	2.625
沟壑密度	0.985	1.015	用地类型	0.569	1.758
沟床比降	0.451	2.218	居民点密度	0.503	1.990
NDVI	0.919	1.088	路网密度	0.500	1.998

2)频率比法。频率比法是一种地理空间评价工具,可计算各个因素对于泥石流发生的敏感性^[28]。其中,1是平均值,当频率比值(FR,用*F*表示)大于1时,认为该因素对于泥石流发生敏感性较高。频率比值计算公式为:

$$F(i_j) = \frac{N_{ij}/N}{S_{ij}/S} \quad (7)$$

式中, N_{ij} 为影响因素 i 的第 j 类泥石流灾害点个数, N

为泥石流灾害点总数, S_{ij} 为对应该分类下的流域面积, S 为流域总面积。

频率比法计算结果如表3所示, 由于篇幅限制, 仅展示各影响因素部分分级及 F 值。

表3 频率比法计算结果

Tab. 3 Results of frequency ratio method

影响因素	分级	F 值
流域面积/km ²	<10	2.319
	[35,60]	1.262
沟壑密度/(m·km ⁻²)	[220,300]	1.398
	>300	1.558
居民点密度/(个·km ⁻²)	<0.070	1.021
	[0.070,0.218]	1.118
活动断层长度/m	<1	1.015
	[1,1 000]	2.619
用地类型	灌木地	1.861
	水体	1.499
	人造地表	1.559
地层岩性	较软岩	3.515
流域高差/m	[1 800,2 600]	1.331
	>2 600	1.173
路网密度/(km·km ⁻²)	[40,200]	1.380
	[1 130,6 000]	2.025
平均坡向	东北坡	1.038
	东南坡	1.030
	西坡	4.138
	平面	8.130
沟床比降/(m·m ⁻¹)	[4.6,70.0]	1.070
	(70.0,100.0]	1.903
	>100.0	1.015
坡度分级/(°)	<5	1.704
	[25,35]	1.208
月均降雨/mm	[1 400,1 600]	1.681
	(1 600,1 800]	1.479
滑坡个数	[3,7]	1.010
	(7,14]	2.361
	(14,26]	2.679
	(26,43]	6.982
平均植被覆盖率	<0.02	1.012
	[0.02,0.26]	1.075
	(0.26,0.41]	1.061

3)信息增益率法。信息增益率(GR, 用 G 表示)指的是某个随机变量的信息增益与该随机变量自信息的比值, 可客观分析各个因素的重要性。计算得到的 G 值越大, 该影响因素的预测能力越强^[29]。

$$G(N_C, C) = \frac{-\sum_i \frac{N_C^i}{N_C} \text{lb} \frac{N_C^i}{N_C} \sum_{m \in M} \frac{N_{Cm}}{N_C} \left(\sum_i \frac{N_{Cm}^i}{N_{Cm}} \text{lb} \frac{N_{Cm}^i}{N_{Cm}} \right)}{-\sum_{m \in M} \frac{|N_{Cm}|}{|N_C|} \text{lb} \frac{|N_{Cm}|}{|N_C|}} \quad (8)$$

式中, N_C 表示节点 C (影响因素 C) 上的样本集合, N_C^i 表示节点 C 的全部样本中属于类别 i (发生了泥石流的类别) 的样本数量, N_{Cm} 表示节点 C 选择属性 m 的样本数量 (属性 m 表示影响因素 C 的分支), N_{Cm}^i 表示在节点 C 选择属性 m 的样本中属于类别 i 的数量, M 表示影响因素 C 所有分支的集合。

信息增益率法计算结果如图6所示, 滑坡的 G 值达到0.220 2, 对泥石流发生的影响较大。




图6 信息增益率法计算结果

Fig. 6 Results of gain ratio method

综上, 经过多重共线性分析、频率比法、信息增益率法分析得到, 14个影响因素均有较强的预测能力。

3 泥石流易发性评价结果及分析

3.1 数据处理

2010年5月至2018年12月, 研究区共发生了393起泥石流灾害, 通过对发生过泥石流的流域记“1”, 未发生过的流域记“0”, 将泥石流易发性研究问题转化为二分类问题。获取各个影响因素指标相关的数据后, 利用Anaconda软件对数据进行预处理。通过sk-learn库中的K-近邻法对数据集中的缺失值进行填充, 并使用3-sigma法则对样本中的异常值进行删除, 再采用IterativeImputer方法进行多变量缺失值填充, 最终得到一组数据完整且没有异常值的数据集。参考相关研究^[30-32], 将包含959条数据的数据集按7:3的比例划分为训练集和测试集, 各包含671和288条数据。

3.2 模型构建

通过调用sklearn中的MLPRegressor函数及GradientBoostingRegressor函数分别构建深度全连接神经网络及梯度提升树模型,采用GridSearchCV方法进行五折交叉验证寻找最优参数,并使用随机森林模型及贝叶斯网络作为对照方法,共同进行泥石流易发性评价,模型参数设置如表4所示。

表 4 模型参数设置

Tab. 4 Model parameter settings

方法	参数名称	参数设置
深度全连接神经网络	最大迭代次数	2 000
	单次训练参数个数	128
	隐含层1神经元数量	20
	隐含层2神经元数量	180
	隐含层3神经元数量	512
	隐含层4神经元数量	256
	激活函数	Relu
	优化算法	adam
	学习速率	adaptive
	梯度提升树	基学习器的数量
子树最大深度		3
子采样		1
损失函数		deviance
随机森林模型	决策树数量	600
	子树最大深度	5
贝叶斯网络	结构构建	ExhaustiveSearch
	评分	BicScore

3.3 泥石流易发性评价

将数据集代入模型运算得到易发性评价结果,利用ArcGIS 10.7的空间连接工具将结果连接到959个小流域,并根据自然断点法将易发性结果分为5个等级:极低易发区、低易发区、中易发区、高易发区和极高易发区。

深度全连接神经网络、梯度提升树、随机森林模型和贝叶斯网络的评价结果分别如图7、8、9、10所示。对比可知,泥石流高易发区、极高易发区均位于滑坡灾害点密集区及降雨量丰富地区。出现这种结果:一方面,雅安市频发的滑坡产生了大量松散堆积物,为泥石流提供了丰富的物源储量;另一方面,汛期大量降雨使松散物源处于饱水状态,稳定性显著降低,为泥石流的启动提供了充分的条件。因此,极高易发区主要分布在滑坡频繁及汛期降雨量大的石棉县(永和乡、回隆镇和蟹螺乡)、汉源县(河南乡、大树镇和安乐镇)及研究区中北部天全县的喇叭河镇、雨城区草坝镇和上里镇、宝兴县穆坪镇等。高易发区、中易发区主要分布在庐山县(双石镇、龙门镇和大川镇)及宝兴县(灵关镇、陇东镇和峰桶寨乡)等。

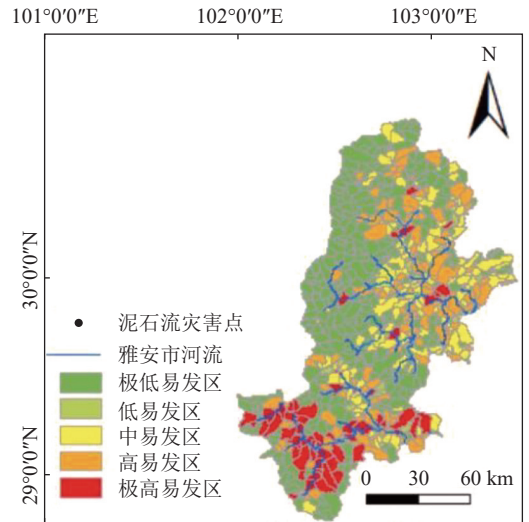


图 7 深度全连接神经网络评价结果

Fig. 7 Calculated results of deep fully connected neural networks

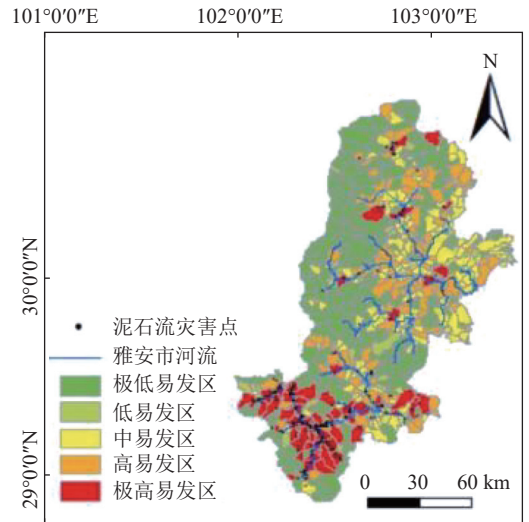


图 8 梯度提升树评价结果

Fig. 8 Calculated results of gradient boosting decision trees

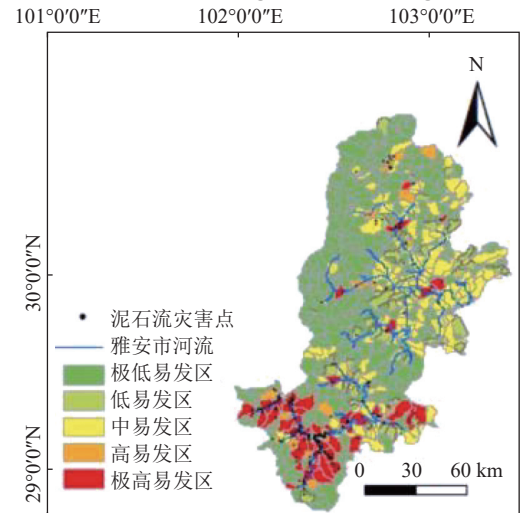


图 9 随机森林模型评价结果

Fig. 9 Calculated results of random forest model

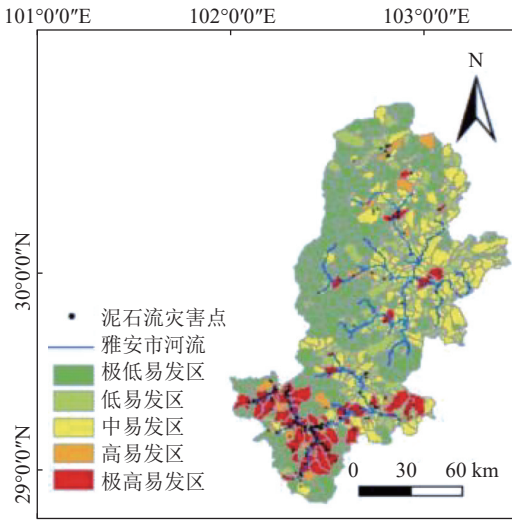


图 10 贝叶斯网络评价结果

Fig. 10 Calculated results of bayesian network model

4 模型性能对比

4.1 模型精确性评价结果

模型在训练集和测试集上ROC曲线分析结果如图11所示, U 为AUC的值。

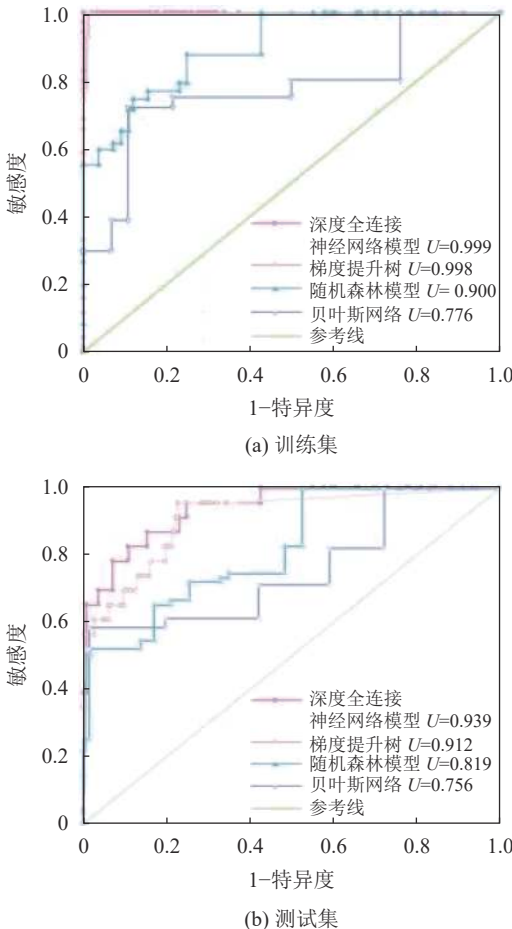


图 11 ROC曲线分析结果

Fig. 11 Analysis results of ROC curves

由图11可知,深度全连接神经网络模型在训练集、测试集上AUC的值比梯度提升树超出0.001、0.027,表明深度全连接神经网络在模型训练、测试集上有良好的预测能力。

模型的Acc、Recall、MAE统计指标结果如图12所示。由图12可知:深度全连接神经网络模型Acc、Recall、MAE的值比梯度提升树等分别超出了0.02、0.02和0.003,表明深度全连接神经网络精确性较高、漏查率较低;同时,MAE的值(0.039)较小,表明误差较小。

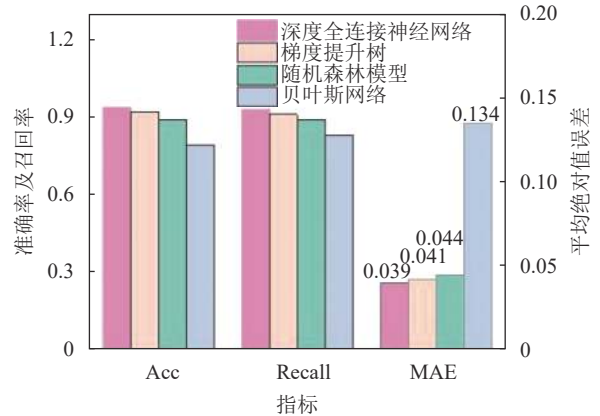


图 12 统计指标汇总结果

Fig. 12 Summarized results of statistical indicators

4.2 模型OOD泛化性验证

4个模型的OOD泛化性验证结果如表5所示。

表 5 OOD泛化性验证结果

Tab. 5 Results of OOD generalization verification

模型	易发性等级	流域个数占比/%	2010—2018年发生泥石流		2019—2021年发生泥石流	
			个数	个数占比/%	个数	个数占比/%
深度全连接神经网络	极低	58.707	19	1.981	24	14.907
	低	3.233	29	3.024	2	1.242
	中	7.821	96	10.010	17	10.559
	高	15.746	335	34.932	53	32.919
	极高	14.494	480	50.052	65	40.373
梯度提升树	极低	62.565	48	5.005	20	12.422
	低	2.086	96	10.010	6	3.727
	中	6.152	269	28.050	15	9.317
	高	16.684	153	15.954	42	26.087
	极高	12.513	393	40.980	78	48.447
随机森林模型	极低	66.840	96	10.010	38	23.602
	低	6.257	86	8.968	5	3.106
	中	9.698	173	18.040	28	17.391
	高	7.299	125	13.034	24	14.907
	极高	9.906	479	49.948	66	40.994
贝叶斯网络	极低	56.517	134	13.973	22	13.665
	低	14.807	259	27.007	24	14.907
	中	19.082	192	20.021	66	40.994
	高	3.545	192	20.021	20	12.422
	极高	6.048	182	18.978	29	18.012

对比4个模型发现,深度全连接神经网络中泥石流灾害点主要集中在极高易发性分区,其他依次分布在高易发区及中易发区。因此,根据流域个数占比分布及泥石流灾害点分布,可以看出深度全连接神经网络的预测结果较为合理。

2019—2021年,针对实际发生在模型中、高和极高易发性分区内的泥石流总数及占比(括号内百分数)情况,各方法预测准确率分析如图13所示。




图 13 各方法预测准确率分析

Fig. 13 Prediction accuracy analysis of each method

由图13可知:2019年以后,雅安市共发生泥石流灾害161起,根据2019年之前的数据,使用深度全连接神经网络预测得到的易发性分区结果中,中易发性、高易发性和极高易发性分区内分别发生17、53和69起泥石流灾害,整体预测准确率达到86.34%;使用

表 6 不同方法综合比较结果

Tab. 6 Comprehensive comparison results of different methods

算法名称	精确性				OOD泛化性/%	原因分析	运算效率	优点
	U	A	R	M				
深度全连接神经网络	0.939	0.94	0.93	0.039	86.34	不同样本梯度产生相干性,使模型具有良好泛化能力	合理设置模型参数,降低复杂度可以保证,较高的运算效率	具有非常强的非线性拟合能力
梯度提升树	0.912	0.90	0.91	0.042	80.75	连续的方式构造树,每棵树都修正前树的误差,预测精度较高	强预剪枝方法,模型占用内存小,运算效率较高	适用于低维数据,可灵活处理各种类型数据
随机森林模型	0.819	0.89	0.89	0.044	73.29	对某些特定噪声数据建模时出现过拟合(超出训练集范围预测)	“随机性”特征数,模型训练时间短,运算效率高	可处理高维度数据,不用做特征选择
贝叶斯网络	0.756	0.79	0.83	0.135	71.43	未采用合适的分类算法	采用合适的多维分类算法,可以有效提高模型运算效率	可以结合定性数据和定量数据进行建模

综上所述,当需要保证模型的精度和适应性且数据样本量大(深度学习模型需要采用大量样本进行训练以达到预期泛化效果)时,可使用深度全连接神经网络;当数据样本量不足且为低维数据时,可采用梯度提升树;当数据样本量不足且为高维数据时,可采用随机森林模型;当有权威专家组支持时,可通过专家知识确定网络结构并指定分布参数,或通过数据学习网络参数,效率远高于直接从数据中学习

梯度提升树、随机森林模型和贝叶斯网络预测得到的易发性分区结果中,整体预测准确率分别达到80.75%、73.29%和71.43%。

总体来看,深度全连接神经网络模型的OOD泛化性比梯度提升树提升了0.056,对泥石流的实际预测表现出较为优异的性能。

4.3 方法综合比较

深度全连接神经网络通过多次迭代更新神经网络每一层节点的参数,减小神经网络输出的误差,同样达到了较高的预测精度。由模型精确性评价可知:深度全连接神经网络的统计指标表现较好,漏查率较低;由OOD泛化性验证结果可知,将2019年之前数据的预测结果与2019年之后实际发生的泥石流情况进行对比,预测准确性高达86.34%,模型的OOD泛化性较强。同时,深度全连接神经网络的非线性拟合能力较强,运算效率同样较高,在泥石流易发性评价中表现良好。

梯度提升树采用连续的方式构造树,每棵树都在试图修正前一棵树的错误,以保证模型的预测精度。随机森林模型的OOD泛化性验证结果较差,原因是无法超越训练集数据范围进行预测,导致对某些特定噪声数据建模时出现过拟合。贝叶斯网络的精确性评价和OOD泛化性验证结果均较差,其原因是采用连续型数据对模型结构寻优需要的运算量过大;采用分类变量也是贝叶斯网络精度中等的原因之一。不同方法综合比较结果如表6所示。

模型结构和参数。

5 结论

基于环境因子采用深度学习方法进行泥石流易发性评价,是泥石流早期识别和监测预警的重要手段。然而,部分模型在实际应用中,预测精度远低于测试和训练集合上的预测精度。为了筛选出在训练、测试及应用过程均具有高性能的模型,以流域单元

为评价单元,以四川省雅安市为研究区,基于泥石流孕灾条件构建指标体系,采用多重共线性分析、频率比法和信息增益率法验证指标合理性,并使用深度全连接神经网络与梯度提升树、随机森林模型和贝叶斯网络共同进行泥石流易发性预测,根据模型的精确性评价及OOD泛化性验证结果,对比筛选出高性能的模型。

结果表明,深度全连接神经网络模型的AUC、Acc、Recall、MAE的值比梯度提升树的值分别超出了0.027、0.02、0.02和0.003。同时,OOD泛化性验证的准确度达到86.34%,超出梯度提升树0.056,表明深度全连接神经网络对于泥石流易发性评价的预测效果较好。采用OOD泛化性验证排除了在测试、训练集合上表现良好、在实际应用中精度较低的模型,进一步提高了易发性评价的精度,也为相关评价方法的选择提供参考。OOD泛化性验证的结果也表明深度全连接神经网络的可行性及研究成果的可靠性,深度学习算法可为山地灾害相关评价领域的研究提供新方法与新思路。

本文仅考虑了实际分布与训练测试集合中数据分布的不同,并未考虑实际分布在模型有效域之外的情况,后续可进一步研究。

参考文献:

[1] Wang Li,Zhang Qin,Huang Guanwen,et al.Experiment results and analysis of landslide monitoring by using GPS PPP technology[J].*Rock and Soil Mechanics*,2014,35(7):2118–2124.[王利,张勤,黄观文,等.GPS PPP技术用于滑坡监测的试验与结果分析[J].*岩土力学*,2014,35(7):2118–2124.]

[2] 中华人民共和国自然资源部.2021年全国地质灾害灾情及2022年地质灾害趋势预测.[EB/OL].(2022–10–11)[2022–01–13].http://mnr.gov.cn/dt/ywbb/202201/t20220113_2717375.html.

[3] Wang Min.Serving the overall situation around the center and providing services and support for geological disaster monitoring and early warning with all one's strength—Speech at the promotion meeting of exchange of new technologies and methods for geological disaster monitoring[J].*The Chinese Journal of Geological Hazard and Control*,2019,30(6):5–8.[汪民.围绕中心服务大局,全力为地质灾害监测预警提供服务与支撑——在地质灾害监测新技术新方法交流推进会上的讲话[J].*中国地质灾害与防治学报*,2019,30(6):5–8.]

[4] Jackson L,Kostaschuk R,MacDonald G.Identification of debris flow hazard on alluvial fans in the Canadian Rocky Mountains[J].*Reviews in Engineering Geology*,1987,7:115–124.

[5] Wei Yongming,Guo Huadong,Chen Yu,et al.High-resolu-

tion remote sensing imagery characters of Zhouqu extra-large-scale debris flow and geological significance of identifying ancient debris flows directly by using remote sensing methods in Gansu Province[J].*Quaternary Sciences*,2014,34(2):325–335.[魏永明,郭华东,陈玉,等.甘肃省舟曲特大泥石流的遥感影像特征及古泥石流遥感识别的地质意义[J].*第四纪研究*,2014,34(2):325–335.]

- [6] Chen Yang,Qin Shengwu,Qiao Shuangshuang,et al.Spatial predictions of debris flow susceptibility mapping using convolutional neural networks in Jilin Province,China[J].*Water*,2020,12(8):2079.
- [7] Ji Lixia,Zhao Yao,Ma Zhengyi,et al.Database workload prediction method based on iForest–BiLSTM–Attention[J].*Journal of Zhengzhou University(Natural Science Edition)*,2022,54(6):66–73.[姬莉霞,赵耀,马郑祎,等.基于 iForest–BiLSTM–Attention的数据库负载预测方法[J].*郑州大学学报(理学版)*,2022,54(6):66–73.]
- [8] Liu Yue,Wang Ningtao,Zhou Chao,et al.Evaluation of landslide susceptibility based on ROC and certainty factor method in Fengjie County,Three Gorges Reservoir[J].*Safety and Environmental Engineering*,2020,27(4):61–70.[刘月,王宁涛,周超,等.基于ROC曲线与确定性系数法集成模型的三峡库区奉节县滑坡易发性评价[J].*安全与环境工程*,2020,27(4):61–70.]
- [9] Wu Saier,Chen Jian,Zhou Wendy,et al.Debris–flow susceptibility assessment and validation based on logistic regression model:An example from the Benzilan–Changbo segment of the upper Jinshajiang River[J].*Geoscience*,2018,32(3):611–622.[吴赛儿,陈剑,Zhou Wendy,等.基于逻辑回归模型的泥石流易发性评价与检验:以金沙江上游奔子栏—昌波河段为例[J].*现代地质*,2018,32(3):611–622.]
- [10] Hu Xiuyu,Qin Shengwu,Dou Qiang,et al.Susceptibility analysis of debris flow based on GIS and random forest—A case study of a mountainous area in northern Taonan city, Jilin province[J].*Bulletin of Soil and Water Conservation*,2019,39(5):204–210.[扈秀宇,秦胜伍,窦强,等.基于GIS和随机森林模型的泥石流敏感性分析——以吉林省洮南市北部山区为例[J].*水土保持通报*,2019,39(5):204–210.]
- [11] Jiao Liang,Liu Jinfeng,You Yong,et al.Research on the occlusion of debris flow window-frame dam based on SVM and RF methods[J].*Journal of Disaster Prevention and Mitigation Engineering*,2020,40(3):439–446.[焦亮,柳雪峰,游勇,等.基于SVM–RF的泥石流窗口坝闭塞度判别研究[J].*防灾减灾工程学报*,2020,40(3):439–446.]
- [12] Liu Yongyao,Di Baofeng,Zhan Yu,et al.Debris flows susceptibility assessment in Wenchuan earthquake areas based on random forest algorithm model[J].*Mountain Research*,2018,36(5):765–773.[刘永堃,第宝峰,詹宇,等.基于随机森

- 林模型的泥石流易发性评价——以汶川地震重灾区为例[J].*山地学报*,2018,36(5):765–773.]
- [13] Li Kun,Zhao Junsan,Lin Yilin,et al.Assessment of debris flow susceptibility based on SMOTE and multi-Grained Cascade Forest[J].*Transactions of the Chinese Society of Agricultural Engineering*,2022,38(6):113–121.[李坤,赵俊三,林伊琳,等.基于SMOTE和多粒度级联森林的泥石流易发性评价[J].*农业工程学报*,2022,38(6):113–121.]
- [14] Ma Zhengjing,Mei Gang.Deep learning for geological hazards analysis:Data,models,applications,and opportunities[J].*Earth Science Reviews*,2021,223:103858.
- [15] Ullah K,Wang Yi,Fang Zhice,et al.Multi-hazard susceptibility mapping based on Convolutional Neural Networks[J].*Geoscience Frontiers*,2022,13(5):101425.
- [16] Li Yang,Chen Wei,Rezaie F,et al.Debris flows modeling using geo-environmental factors:Developing hybridized deep-learning algorithms[J].*Geocarto International*,2022,37(17):5150–5173.
- [17] Prasetya E P,Djamal E C.Rainfall forecasting for the natural disasters preparation using recurrent neural networks[C]//*Proceedings of the 2019 International Conference on Electrical Engineering and Informatics(ICEEI)*.Bandung:IEEE,2019:52–57.
- [18] Reichstein M,Camps-Valls G,Stevens B,et al.Deep learning and process understanding for data-driven Earth system science[J].*Nature*,2019,566:195–204.
- [19] Chatterjee S,Zielinski P.On the generalization mystery in deep learning[EB/OL].(2022–10–11)[2022–06–03].<http://arxiv.org/abs/2203.10036>.
- [20] Wang Ke,Yao Jianguo,Yu Peiyao,et al.Architecture and key technologies of intelligent decision-making of power grid look-ahead dispatch based on deep reinforcement learning[J].*Proceedings of the CSEE*,2022,42(15):5430–5439.[王珂,姚建国,余佩遥,等.基于深度强化学习的电网前瞻调度智能决策架构及关键技术初探[J].*中国电机工程学报*,2022,42(15):5430–5439.]
- [21] Yang Yaoyuan,Rashtchian C,Salakhutdinov R,et al.Close category generalization[EB/OL].(2022–10–11)[2020–11–17].<https://arxiv.org/abs/2011.08485>.
- [22] Zhou Yue,Wang Yunsheng,Zhao Xun,et al.Susceptibility assessment of debris flow in Dimaluo River,branch of Nujiang River[J].*Geological Bulletin of China*,2022,41(4):702–712.[周粤,王运生,赵逊,等.怒江支流迪麻洛河流域泥石流易发性评价[J].*地质通报*,2022,41(4):702–712.]
- [23] Yang Heng,Yue Jianping,Xing Yin,et al.Research on dam deformation prediction based on deep fully connected neural network[J].*Journal of Geodesy and Geodynamics*,2021,41(2):162–166.[杨恒,岳建平,邢尹,等.基于深度全连接神经网络的大坝变形预测研究[J].*大地测量与地球动力学*,2021,41(2):162–166.]
- [24] Xu Haiwen,Shi Jiakai,Wang Teng.Departure flight delay prediction model based on deep fully connected neural network[J].*Journal of Computer Applications*,2022,42(10):3283–3291.[徐海文,史家财,汪腾.基于深度全连接神经网络的离港航班延误预测模型[J].*计算机应用*,2022,42(10):3283–3291.]
- [25] Fleuchaus P,Blum P,Wilde M,et al.Retrospective evaluation of landslide susceptibility maps and review of validation practice[J].*Environmental Earth Sciences*,2021,80(15):485.
- [26] Larson S,Singh N,Maheshwari S,et al.Exploring out-of-distribution generalization in text classifiers trained on tobacco–3482 and RVL–CDIP[C]//*International Conference on Document Analysis and Recognition*.Cham:Springer,2021:416–423.
- [27] Hou Yule,Zhao Jingbo.Study on flood disasters and climate changes in the Ya’an area during the Qing dynasty[J].*Water Resources and Power*,2018,36(6):1–5.[侯雨乐,赵景波.清代(1644~1911年)雅安地区洪涝灾害与气候变化特征[J].*水电能源科学*,2018,36(6):1–5.]
- [28] Kumar A,Sharma R K,Bansal V K.GIS-based comparative study of information value and frequency ratio method for landslide hazard zonation in a part of mid-Himalaya in Himachal Pradesh[J].*Innovative Infrastructure Solutions*,2019,4(1):28.
- [29] Yang Xinhua,Jia Xin,Zhu Ping,et al.Analysis of influencing factors on fatigue performance of spot welded joints based on information gain rate[J].*Transactions of the China Welding Institution*,2020,41(10):73–78.[杨鑫华,贾昕,朱平等.基于信息增益率的点焊接头疲劳性能影响因素分析[J].*焊接学报*,2020,41(10):73–78.]
- [30] Pal S C,Chakraborty R,Saha A,et al.Evaluation of debris flow and landslide hazards using ensemble framework of Bayesian- and tree-based models[J].*Bulletin of Engineering Geology and the Environment*,2022,81(1):55.
- [31] Li Kun,Zhao Junsan,Lin Yilin,et al.Assessment of debris flow susceptibility based on different slope unit division methods and BP neural network[J].2022(8):68–74.[李坤,赵俊三,林伊琳,等.基于不同斜坡单元划分方法和BP神经网络的泥石流易发性评价[J].*测绘通报*,2022(8):68–74.]
- [32] Li Kun,Zhao Junsan,Lin Yilin,et al.Assessment of debris flow susceptibility in Dongchuan based on RF and SVM models[J].*Journal of Yunnan University(Natural Sciences Edition)*,2022,44(1):107–115.[李坤,赵俊三,林伊琳,等.基于RF和SVM模型的东川泥石流易发性评价研究[J].*云南大学学报(自然科学版)*,2022,44(1):107–115.]

Methods for Evaluating Debris Flow Susceptibility Based on OOD Generalization Verification and Deep Fully Connected Neural Networks

GUO Pengning¹, XING Huige^{1*}, LI Congjiang^{2,3}, WU Yuxin¹, LI Haibo^{2,3}

(1.College of Architecture and Environment, Sichuan Univ., Chengdu 610065, China;

2.College of Water Resource & Hydropower, Sichuan Univ., Chengdu 610065, China;

3.State Key Lab. of Hydraulics and Mountain River Eng., Sichuan Univ., Chengdu 610065, China)

Abstract: More-accurate predictions of susceptibility to debris flows would help greatly in the early identification and large-scale monitoring of debris-flow disasters. Some existing models for doing so perform well during training and test but less well in practice, and this has adverse effects on engineering site selection and disaster prevention and mitigation. To find a method with high accuracy in training, prediction, and application, the present study considered four models—i.e., deep fully connected neural network, gradient boosting decision tree, random forest, and Bayesian network and assessed them for accuracy and out-of-distribution (OOD) generalization. Taking Ya'an City in China's Sichuan Province as an example, small watershed units were used for regional meshing, and the data were divided randomly into a training set and a test set at the ratio of 7:3. During data cleansing, missing values were tackled using a K-means and IterativeImputer method, and excrescent data were rejected using the 3-sigma rule. After analyzing the collinearity, sensitivity, and predictive ability of various debris-flow susceptibility factors, 14 were selected for model operation. The four aforementioned models were then constructed for debris-flow susceptibility prediction and model comparison, and accuracy evaluation and OOD generalization verification showed that the deep fully connected neural network model was superior to the other three models in terms of AUC (0.027 higher), Acc (0.02 higher), Recall (0.02 higher), MAE (0.003 lower), and OOD generalization (0.056 higher). The results show that deep fully connected neural networks are good at predicting debris-flow susceptibility, thereby improving the accuracy and adaptability of debris-flow evaluation and providing a new way to evaluate debris-flow susceptibility.

Key words: debris flow disaster; susceptibility evaluation; deep learning algorithm; OOD generalization verification; deep fully connected neural network

(编辑 周璇)

引用格式: Guo Pengning, Xing Huige, Li Congjiang, et al. Methods for evaluating debris flow susceptibility based on OOD generalization verification and deep fully connected neural networks[J]. *Advanced Engineering Sciences*, 2024, 56(4): 182–193.
[郭鹏宁, 邢会歌, 李从江, 等. 基于OOD泛化性验证和深度全连接神经网络的泥石流易发性评价方法[J]. *工程科学与技术*, 2024, 56(4): 182–193.]