

基于深度学习的滑坡灾害易发性评价及系统研发 ——以湖北省十堰市郧阳区为例

葛云峰^{1,2}, 龚曦¹, 赵君³, 赵景昆², 刘耕¹, 陈匡⁵, 张海龙³

1. 中国地质大学 (武汉), 工程学院, 湖北武汉 430074

2. 新疆工业学院, 新疆战略性矿产资源绿色智能开发与高效利用兵团重点实验室, 自然资源科技学院, 新疆和田 848000

3. 东风鸿远工程咨询有限公司, 湖北襄阳 441000

4. 湖南省地震局, 湖南长沙 410004

5. 湖北省水文地质工程地质勘察院有限公司, 湖北武汉 434020

摘要: 为研究不同深度学习模型在滑坡易发性评价中的适用性, 并探索将复杂模型转化为实用工具的途径。以湖北省十堰市郧阳区为研究区, 基于地质与遥感数据筛选出 10 个致灾因子作为数据集, 构建 AlexNet、Inception、ResNet-101、DenseNet-201、GoogLeNet 五种深度学习模型训练与验证, 通过 ROC 曲线、滑坡分区统计、实施难度和与随机森林模型作为对比, 来评估模型性能。在所有模型中, GoogLeNet 模型表现最优, 其 AUC 值最高 (0.84); 高易发区滑坡频率比达到 48%, 滑坡密度统计达 3.06 个/km²。此外, 基于 MATLAB 平台开发了集成筛选、训练、测试、验证等模块的滑坡灾害深度学习易发性评价系统。深度学习方法能有效提升滑坡评价的准确性, GoogLeNet 模型在精度与效率上达到了最佳平衡。

关键词: 滑坡灾害; 易发性评价; 深度学习; 对比分析; 系统开发

中图分类号: P642.22

收稿日期: 2025-11-22

Landslide Susceptibility Assessment in Yunyang District, Shiyan City, Hubei Province Using Deep Learning Methods

GE Yunfeng^{1,2}, GONG Xijun¹, ZHAO Jun³, ZHAO Jingkun², LIU Geng⁴,
CHEN Jiangjun⁵, ZHANG Hailong³

1. Faculty of Engineering, China University of Geosciences (Wuhan), Wuhan 430074, China

基金项目: 国家自然科学基金 (NO.42477177); 湖北省自然科学基金 (NO.2024AFD005); 新疆生产建设兵团第十四师昆玉市科技计划项目重点研发计划 (NO.2025-14-01); 新疆人才发展基金项目 (NO.).

作者简介: 葛云峰 (1985—), 男, 博士, 教授, 主要从事地质工程方面的教学与研究工作. E-mail: geyunfeng@cug.edu.cn. ORCID: 0000-0003-4390-6841.

文章中图分类号: P642

2.Xinjiang Production & Construction Corps Key Laboratory of Green and Intelligent Development and Efficient Utilization of Strategic Mineral Resources, School of Natural Resources Science and Technology, Xinjiang University of Technology, Hotan 848000, China

3.Dongfeng Hongyuan Engineering Consulting Co., Ltd, Xiangyang 441000, China

4.Hunan Earthquake Agency, Changsha 410004, China

5.Hubei Institute of Hydrogeology and Engineering Geological Survey Co., Ltd,Wuhan 434020, China

Abstract:This study aims to evaluate the applicability of various deep learning models in landslide susceptibility assessment and to explore pathways for transforming complex models into practical tools. Taking Yunyang District, Shiyan City, Hubei Province as the study area, ten landslide conditioning factors were selected based on geological and remote sensing data to construct the dataset. Five deep learning models—AlexNet, Inception, ResNet-101, DenseNet-201, and GoogLeNet—were constructed, trained, and validated. Model performance was evaluated using ROC curves, landslide zoning statistics, implementation complexity, and a comparative analysis with a Random Forest model. The results indicate that the GoogLeNet model exhibited the optimal performance, achieving the highest AUC value of 0.84. In the high-susceptibility zone, the landslide frequency ratio reached 48%, and the landslide density was 3.06 landslides/km². Furthermore, a deep learning-based landslide susceptibility evaluation system, integrating factor selection, model training, testing, and validation modules, was developed on the MATLAB platform. Deep learning approaches can effectively enhance the accuracy of landslide susceptibility assessment. Specifically, the GoogLeNet model achieves the best balance between predictive precision and computational efficiency.

Key words: Landslide disaster; Susceptibility assessment; Deep learning; Comparative analysis; System development

引言

滑坡是全球性地质灾害，严重威胁人民生命财产安全，尤其在城市化快速发展的地区 (Dowling and Santi, 2024; 殷坤龙, 1987; Tanyaş, et al., 2017)。科学、准确的滑坡易发性评价对防灾减灾、城乡规划与安全管理具有重要意义。

国内外学者针对滑坡易发性评价已开展大量研究，方法体系随技术发展逐步完善，可分为四个阶段：定性评价阶段 (20 世纪 60 年代)以专家评分法为代表，Dobrovolny (1964)根据美国 Anchorage 地区的地质地形图，采用专家评分法对滑坡易发区进行细分。此方法主要依赖专家经验，主观性较强，对数据质量的要求不高，是一种典型的定性划分方法；半定量评价阶段 (1970 年后)以层次分析法为核心，T.L.Saaty 提出将评价目标分解为目标层-准则层-方案层的层级结构，DeGraff and Romesburg (1980)进一步将其应用于滑坡易发性成图，虽引入矩阵一致性检验以减少主观偏差，但仍需专家对致灾因子分级打分，适用性受经验限制；统计学评价阶段 (1980 年后)统计学方法通过建立滑坡发生与条件参数之间的联系来进行易发性评价(Huang et al., 2020)，主要方法包括分形理论、信息量 (Mandal et al., 2017)、逻辑回归 (Fang et al., 2018)等。殷坤龙采用判别分析和回归分析对斜坡稳定性进行了分析，对潜在滑坡发生规模以及已发生滑坡的复活性进行了定量预测，为国内区域滑坡定量预测开拓了新思路 (殷坤龙, 1986)；机器学习评价阶段 (21 世纪后)主要算法包括支持向量机 (Ge et al., 2021)、随机森林 (Chen et al., 2017)、logistic 回归 (Lombardo and Mai, 2018)、神经网络 (Xiong et al., 2019; Ermini et al., 2005)、决策树 (Yeon et al., 2010; Tien Bui et al., 2012)、深度学习 (Wang et al., 2019)等。这些方法获取易发性评价图准确率有所

提高,目前在地质领域应用较为广泛,但是这些模型只是浅层学习,很难捕获更多隐藏在深层的输入数据之间的内在的特征,难以充分探索输入变量之间的非线性相关性 (Andrieu et al., 2003)。近年来,深度学习因强大的特征提取与数据处理能力,在计算机视觉领域取得突破,逐步向地质领域延伸。经过部分学者不懈努力,深度学习算法取得了一系列突破 (Vincent et al., 2010),可以自动提取训练数据内在的信息以及大数据的深层特征。深度学习算法拥有比常规机器学习算法更加强大的特征提取和数据处理能力 (Wang et al., 2021),已经有部分学者将卷积神经网络,应用到地质领域。例如, Wang et al. (2019)等首次将卷积神经网络应用到滑坡易发性评价,研究 3 种输入数据格式作为卷积神经网络输入数据 (Wang et al., 2019); Sameen et al. (2020)对卷积神经网络进行贝叶斯优化;唐晓娜 (2019)使用卷积神经网络研究山西省吕梁市地区;苏钰桐等 (2021)采用 YOLOv3 模型自动检测识别煤岩数字钻孔图像裂隙;Liu et al. (2020)利用 Faster R - CNN 深度学习的目标检测框架,基于简化的 VGG16 对岩石图像进行特征提取和学习,最终实现了岩石类型的精确智能识别。

已有研究表明,深度学习在滑坡预测中的应用能够显著提高准确性。我们团队在此前的研究中,已成功应用深度学习方法 (如 AlexNet、Inception 等模型)进行甘肃某工程区的滑坡易发性评价,并取得了良好成果 (Ge et al., 2023)。然而,这些研究中对不同模型适用性和优缺点的比较仍需进一步深入。因此,本研究创新点在于(1)对部分模型轻量化处理以适合易发性评价提高计算效率;(2)多维度对比深度学习模型,旨在延续并拓展前期研究,通过横向对比不同深度学习模型在滑坡易发性评价中的表现,深入探讨各模型的特征提取差异,进一步检验该评价体系的泛化能力与稳健性;(3)集成化评价系统的研发,依托 MATLAB 平台开发集“样本筛选—模型训练—测试评估—结果验证”于一体的滑坡易发性评价系统。

1 研究区概况与数据

1.1 研究区概况

研究区为湖北省十堰市郧阳区,总面积约 3863km² (图 1)。该区地处南秦岭印支冒地槽褶皱带内,地质构造复杂,主要发育东西向构造体系、北西向构造体系及联合扭动构造体系。两郧断裂带和白河-石花街断裂带 (公路断裂带)是区内主导性断裂,控制了地层建造与地质灾害的发育。区内出露地层从元古界至新生界均有分布,岩性以碳酸盐岩、碎屑岩及变质岩为主。气候类型为亚热带季风湿润气候,年平均气温 10-16°C,1 月均温 2.8°C,7 月均温 28.5°C;年平均降水量 760.9mm,5-8 月为降雨集中期 (占全年降水量超 50%),7 月降水量最大可达 426mm,人类工程活动 (如丹江口水库与黄龙滩水库建设、209 与 316 国道及襄渝铁路等交通路网建设)强烈,是诱发滑坡的重要外部因素。据统计,区内共发育滑坡 646 处,面密度达 16.57 处/100km²,是进行滑坡易发性评价的典型区域。

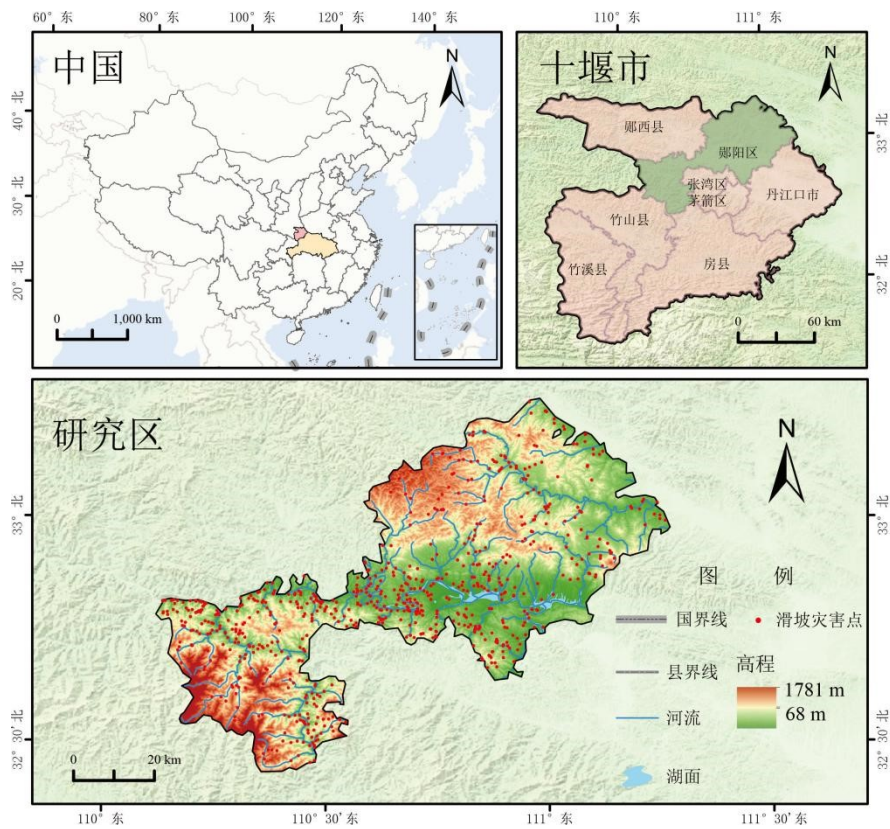


图 1 研究区地理位置及滑坡分布

Fig. 1 Locations of study area and landslides

1.2 数据来源

本研究预测滑坡易发性所提取的致灾因子数据主要来源于五部分，分别是：（1）研究区 30m 分辨率的数字高程模型（DEM）数据，用于提取坡度、坡向、高程、平面曲率、TOBIA 指数等地形因子；（2）Landsat 8 卫星遥感影像提取提取 NDVI 因子；（3）2020 年郟阳区降水数据提取郟阳区年降雨量因子；（4）通过矢量化研究区的水系分布、公路分布，得到水系影响距离因子、道路影响距离因子；（5）使用湖北省十堰市郟阳区 1: 4000 地质灾害详细调查区域工程地质条件分布图，提取地层岩性、断层影响距离因子。研究的滑坡编目表由湖北省水文地质工程地质勘察院提供，具体来源与参数见表 1。

表 1.数据来源表

Table 1. Data Source Table

数据分类	数据名称	原始数据来源	原始分辨率
灾害点	滑坡点	湖北省水文地质工程地质勘察院 1:4000 地质灾害调查图（2020 年）	1:4000 （滑坡编录共 719 条）
地形地貌	高程、坡度、坡向、平面曲率、剖	地理空间数据云 DEM	5 m

	面曲率、平均曲率、地表粗糙度、 TOBIA 指数	http://www.gscloud.cn/	
地质条件	地层岩性、断层影响距离	湖北省水文地质工程地质勘察院 1:4000 地质灾害调查图	1:4000
水文地质	水系影响距离	http://www.resdc.cn/	1:250,000
气候环境	年降雨量	2020 年全国年降雨量数据	150 m
	植被指数(NDVI)	地理空间数据云 Landsat 8 (2020 年) https://www.gscloud.cn	30 m
人类活动	道路影响距离	http://www.resdc.cn/	1:250,000

2 研究方法

本研究主要以郧阳区作为研究对象，主要包含以下 4 个部分：（1）数据处理：通过历史滑坡资料、遥感影像、野外调查获取最新的滑坡记录与滑坡致灾因子并通过相关性分析识别并去除相关系数较高的因素，建立数据集为后续模型训练预测做准备；（2）滑坡灾害易发性评价：构建 AlexNet、Inception-v3、ResNet-101、DenseNet-201 和 GoogLeNet 五种深度学习模型，并将训练好的模型进行滑坡易发性成图；（3）模型验证：主要从 ROC 曲线、滑坡分区统计、实施难度和与传统随机森林模型对比，4 个维度来评价模型。（4）基于本研究流程开发滑坡灾害易发性评价系统。流程图如下（图 2）。

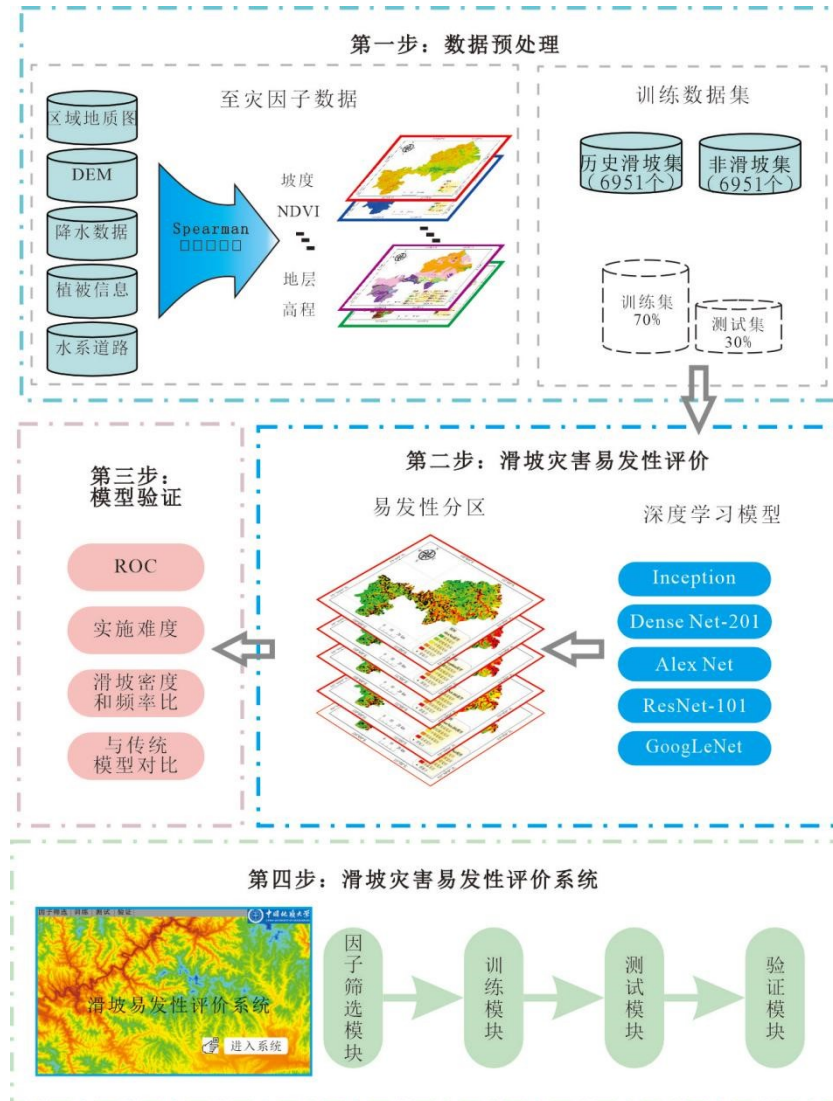


图 2 技术路线图

Fig. 2 Technical roadmap

2.1 致灾因子提取

(1)区域地质因子：地层岩性直接通过矢量化的地质灾害调查图提取。断层利用 ArcGIS 所提供的距离缓冲功能，以 200m 为间隔，制作缓冲区，分别为：0-200m、200-400m、400-600m、600-800m、800-1000m 和 >1000m。

(2)地形地貌因子：此类因子由 DEM 数据经 GIS 换算的到包括：坡度、高程、坡向、斜坡曲率、地表粗糙度、斜坡类型。坡向因子划分为东北向 (0-45°)、东向 (45°-90°)、东南向 (90°-135°)、南向 (135°-180°)、西南向 (180°-225°)、西向 (225°-270°)、西北向 (270°-315°)、北向 (315°-360°) 8 个类别；本文共提取了平面曲率、剖面曲率和平均曲率 3 个不同的曲率因子；地表粗糙度运用 TOBIA 指数表征如式(1)。

$$TOBIA = (\cos \theta \cdot \cos S) + (\sin \theta \cdot \sin S) \cdot \cos(\alpha - A) \quad (1)$$

其中 S: 地表单元的坡度角；A: 地形坡向；θ: 岩层倾角；α: 岩层倾向 (曾忠平等, 2006)。

(3)水文地质因素：基于水系图利用 ArcGIS 的距离缓冲功能，以 200m 为间隔，制作缓冲区，分别为：0-200m、200-400m、400-600m、600-800m、800-1000m 和>1000m。

(4)气候环境条件：由于降雨量数据的缺乏，本研究采用了 2020 年年降雨量分布图作为降雨数据。通过遥感影像数据经过式（2）获得地表植被覆盖率（NDVI）精度为 30 米：

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2)$$

其中 NIR 代表近红外波段的反射率；RED 代表 红光波段的反射率。

(5)人类工程活动：主要提取研究区的公路、铁路线状矢量数据利用 ArcGIS 所提供的距离缓冲功能，以 200m 为间隔，制作缓冲区，分别为：0-200m、200-400m、400-600m、600-800m、800-1000m 和>1000m。

2.2 致灾因子筛选

在分析滑坡致灾因子时，需要结合研究区的实际情况，选取最合适的因子。滑坡致灾因子的选择对易发性评价结果影响较大，本研究从区域地质、地形地貌、水文地质、气候环境、人类工程活动等 5 方面，分别提取地层、断层影响距离、坡度、坡向、高程、地表粗糙度、水系影响距离、NDVI、降雨、道路影响距离等 14 个因子。然而，初步选取的因子体系可能存在以下问题：因子数量过多会导致数据冗余并降低模型效率；部分因子之间的高度相关性会影响评价结果的准确性 (Rossi et al., 2010)；且初步选取的因子对郧阳区的适用性也有待检验。因此，为提高评价结果的可靠性，需要对因子进行筛选，剔除相关性较大的因子，提高易发性结果的可靠性。考虑到地质环境因子多不符合正态分布，故采用对变量分布无要求的 Spearman 相关系数进行分析：

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)} \quad (3)$$

其中 r_s 表示 Spearman 相关系数； d_i 表示第*i*个数据对的位次值之差； n 总的观测样本数；当相关系数的绝对值大于 0.8 时，认为具有高相关性，据此对 14 个致灾因子进行分析。

2.3 数据集准备

为确保所有评价因子在空间上的一致性，本研究以 5 米精度的 DEM 数据为基准，将所有数据图层统一到 5 米分辨率。对于原始分辨率不一致的栅格数据（如 30m 的 NDVI 和 150m 的年降雨量），为保留原始数据的观测值采用了最近邻插值法（Nearest Neighbour Interpolation）将其重采样至 5m，由此将整个研究区划分为 1,334,646 个栅格单元。样本数据集的构建首先从正样本（滑坡）开始：我们对 646 处历史滑坡点设置了 50m 缓冲区，随后通过“要素转栅格”工具将其转换为 6,951 个滑坡栅格点。为构建一个平衡的数据集，我们接着在研究区内滑坡点 1km 缓冲区外随机选取了同等数量（6,951 个）的非滑坡栅格点作为负样本。这两个样本集共同构成了包含 13,902 个样本点的总数据集，并被随机划分为 70% 的训练集（9,732 个样本）和 30% 的测试集（4,170 个样本）。训练集用于深度学习模型的输入与训练，测试集则用于初步测试模型的训练效果。

2.4 深度学习模型构建

基于本团队前期在甘肃某区的研究经验，构建了 AlexNet、Inception-v3、ResNet-101、DenseNet-201 和 GoogLeNet 五种深度学习模型，用于滑坡易发性评价。

(1) AlexNet 模型

AlexNet 是经典深度 CNN 模型，核心优势在于通过 ReLU 激活函数解决梯度消失问题，并引入 Dropout 层防止过拟合，适用于从致灾因子数据中提取深层非线性特征，其结构图如下图 3 所示。

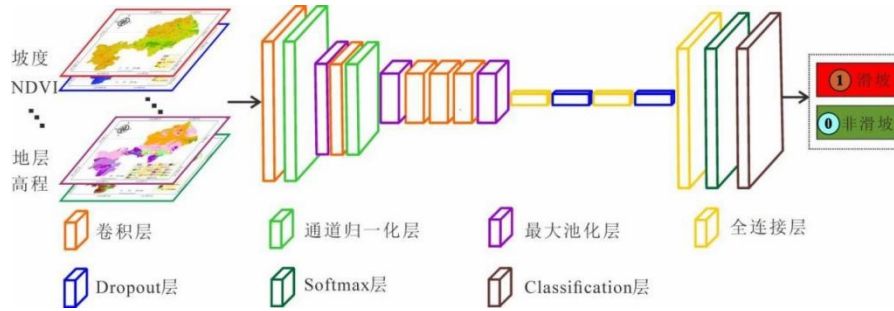


图 3 AlexNet 深度学习模型架构

Fig. 3 Architecture of AlexNet deep learning model

(2) Inception 模型

Inception 模型与传统的卷积神经网络 (AlexNet 模型、LeNet 模型) 完全不同，该模型中将不同尺寸卷积核的卷积层以并联的方式结合在一起。既增加了每个卷积层中卷积核的数量，拓宽了网络的深度和宽度，又不会引入过多的计算量，其结构图如下图 4 所示 (Szegedy et al., 2016)。

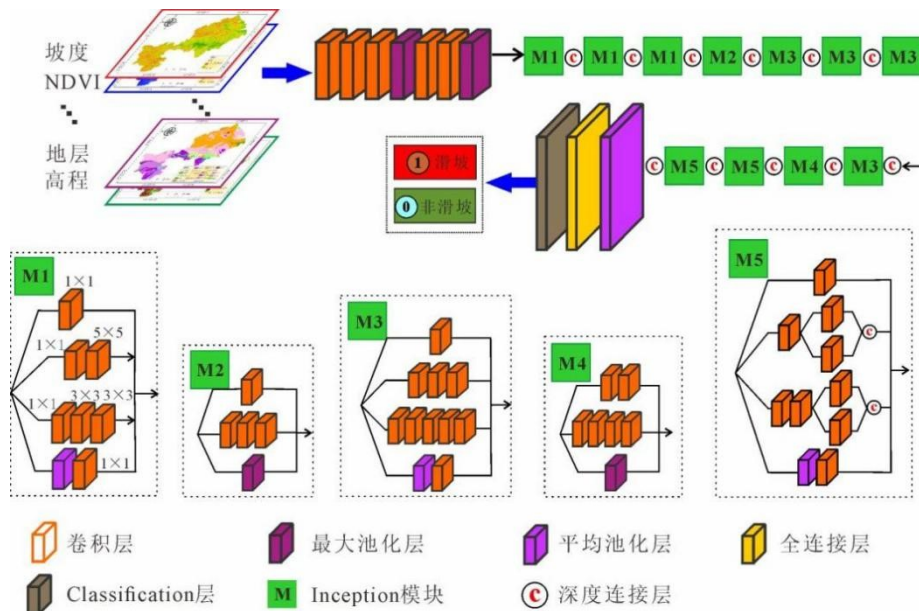


图 4 Inception 深度学习模型架构

Fig. 4 Architecture of Inception deep learning model

(3) ResNet-101 模型

ResNet-101 基于“残差连接”设计，通过残差模块直接学习输入与输出的残差映射，解决深层网络梯度消失问题，提升对复杂致灾因子序列特征的传递与学习效率，其结构图如下图 5 所示。

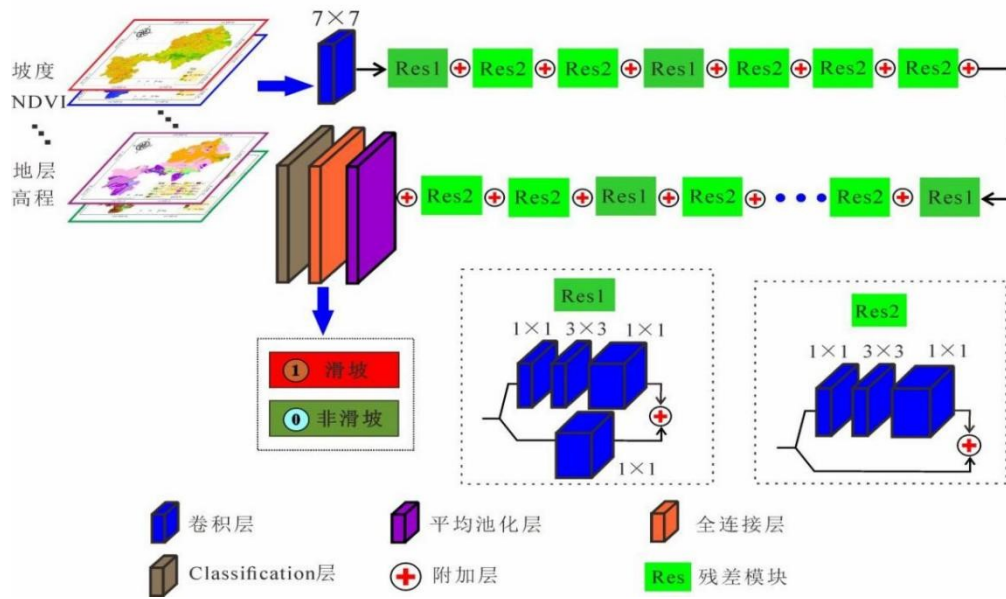


图 5 ResNet-101 深度学习模型架构

Fig. 5 Architecture of ResNet-101 deep learning model

(4) DenseNet-201 模型

DenseNet-201 采用“密集连接”架构，每一层均接收前面所有层的特征输出，最大化特征传递效率，减少信息丢失，适用于挖掘致灾因子间潜在的复杂关联，其结构图如下图 6 所示 (Huang et al., 2017)。

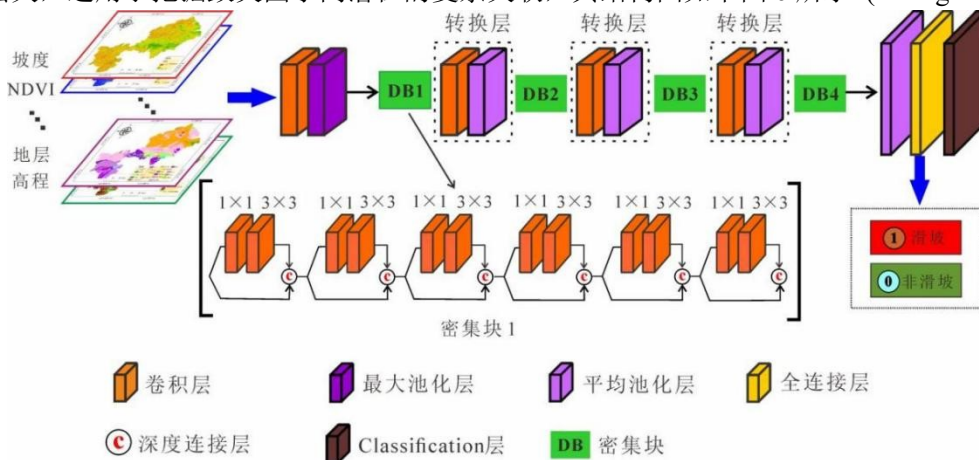


图 6 DenseNet-201 深度学习模型架构

Fig. 6 Architecture of DenseNet-201 deep learning model

(5) GoogLeNet 模型

本研究使用的 GoogLeNet 模型为简化后的 Inception-v1 模型与前文中的 Inception 模型不同之处是：其所有的 Block 模块完全相同，单纯的将多个 Block 模块串联，在保证特征提取能力的同时降低计算复杂度，兼顾评价精度与效率。GoogLeNet 结构图如下图 7 所示。

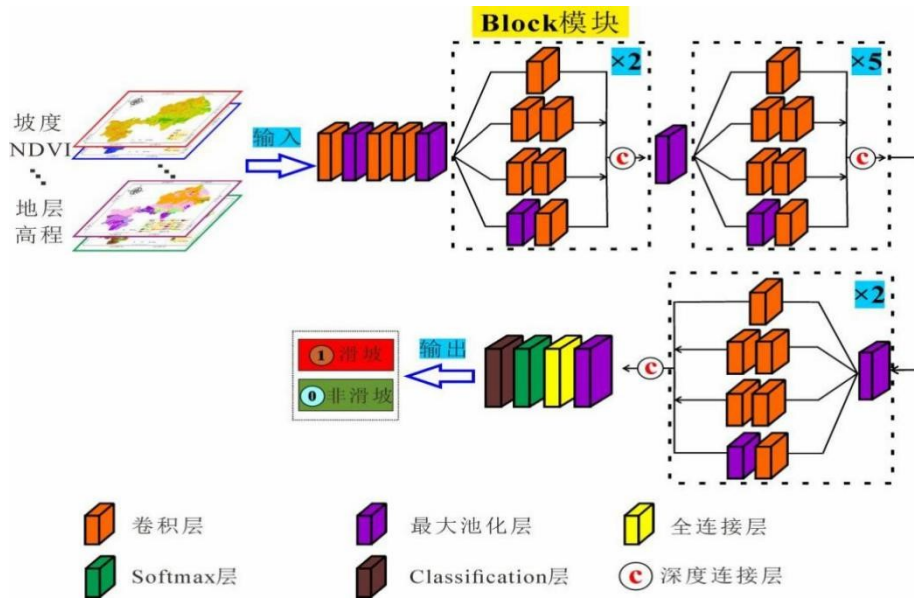


图 7 GoogLeNet 深度学习模型架构

Fig. 7 Architecture of GoogLeNet deep learning model

所有模型都采用 ReLU 激活函数，因其能有效克服梯度消失问题，且计算速度快，加快模型收敛；选用 Adam 优化算法，因其计算高效，对内存需求小，适用于大规模数据集和高维参数的优化。为防止过拟合，AlexNet 模型中加入了 Dropout 层，其余四种模型则采用了提前结束策略。通过试错法对各模型进行参数优化，最终确定的最佳训练参数及测试精度。

2.5 模型的评价

为了对比并筛选出最适合本研究区的深度学习模型，本研究首先利用训练好的五种模型对整个研究区（共 1,334,646 个网格）进行全面的滑坡易发性评价。每个网格单元都被赋予一个 0 到 1 之间的易发性指数，指数越接近 1，代表滑坡风险越高。并在 ArcGIS 中将这些预测结果与地理底图进行关联，生成了五种模型对应的滑坡易发性评价图。为实现更直观的可视化效果，图中采用自然间断法将易发性指数划分为低、较低、中、较高、高五个等级。为对各模型的结果进行系统的对比验证，本文采用了多种评估方法，主要包括：

(1) 统计学方法：为了验证五种模型的预测精度，使用统计学方法，统计 5 种模型的滑坡密度和滑坡频率比。利用 ArcGIS 软件多值提取至点功能，将五种深度学习模型的易发性分区结果提取至滑坡点和非滑坡点，以此计算滑坡密度和滑坡频率比。滑坡密度和滑坡频率比的计算公式如下所示：

$$\text{滑坡频率比} = \frac{N_i}{N} \quad (4)$$

$$\text{滑坡密度} = \frac{N_i / N}{S_i / S} \quad (5)$$

其中， N_i 代表每个等级易发性分区的栅格数量， N 代表易发性分区的栅格总数（某个分区内滑坡发生的频率与该分区面积占总面积比例之间的关系）； S_i 代表每个等级易发性分区的面积， S 代表易发性分区总面积。其数值越高代表模型模拟结果越准确。

(2) ROC 曲线: ROC 曲线通常用于数据量较大的分类统计案例中, 其以真正率 (TPR)为 y 轴, 以假正率 (FPR)为 x 轴, 绘制 ROC 图像。ROC 曲线越接近左上角, 说明模型预测的准确性越高 (Ciurleo et al., 2017; Tsangaratos et al., 2017)。ROC 计算公式如下:

$$TPR = \frac{TP}{TP + FN} \quad (6)$$

$$FPR = \frac{FP}{N} \quad (7)$$

其中, N 为测试样本中未发生滑坡的栅格数, TP 为预测结果和实际结果均为滑坡的栅格数, FN 为预测结果为非滑坡但实际结果却为滑坡的栅格数, FP 为预测结果为滑坡但实际结果为非滑坡的栅格数。此外, 还采用 ROC 曲线下面积对滑坡易发性模型的性能进行定量评价, AUC 值越接近 1, 说明模型预测的准确性越高。取等量已发生滑坡和未发生滑坡共 13902 个栅格数据, 分别赋值 1 和 0, 用易发性值和实际值求取 ROC 曲线。

(3) 模型效率: 五种深度学习方法均基于统一框架构建, 其流程均包含数据预处理、模型训练和易发性评价图可视化三个主要阶段。为评估其优缺点, 本研究统计了各模型完成上述三个阶段的所用时间, 将时间效率作为模型综合性能的评价标准之一。

(4) 与传统模型的对比分析: 本研究同时也运用了在滑坡易发性评价中常用的随机森林 (Random Forest, RF) 方法, 作为传统机器学习模型的代表进行对比分析, 以验证模型的准确性和优缺点。RF 通过构建并结合多棵决策树来进行预测。该算法在训练过程中引入随机性, 即随机抽取样本和随机选取特征来构建每一棵独立的决策树。最后, RF 模型通过对所有决策树的预测结果进行分类或回归来得出最终结论, 这种机制使其具有很高的准确性。

2.6 基于深度学习的滑坡易发性评价系统设计思路

本文基于 MATLAB 平台, 以 App Designer 为开发工具, 开发了一款基于深度学习的滑坡易发性评价 App, 在 App 上实现滑坡易发性快速评价。根据滑坡易发性评价的操作流程, 开发滑坡易发性评价系统, 该系统主要分为 4 个模块。具体设计思路如下:

(1) 因子筛选, 滑坡形成的影响因素众多, 各个研究区的实际地质情况各异, 需要对收集的致灾因子数据进行筛选, 剔除相关性较大的因子。避免因子过多, 导致数据冗余, 同时避免因子相关性过大影响评价结果; (2) 训练模块, 主要包括导入数据集、模型选择、参数设置等。选择不同的深度学习模型, 输入训练数据集, 使用最优参数训练模型; (3) 测试模块, 训练完毕之后, 将测试集应用至训练好的模型, 初步验证训练模型的准确性; (4) 验证模块, 使用统计学方法, 验证易发性预测结果的准确性, 定量评价五种模型的易发性预测准确率。

3 结果

3.1 致灾因子分析

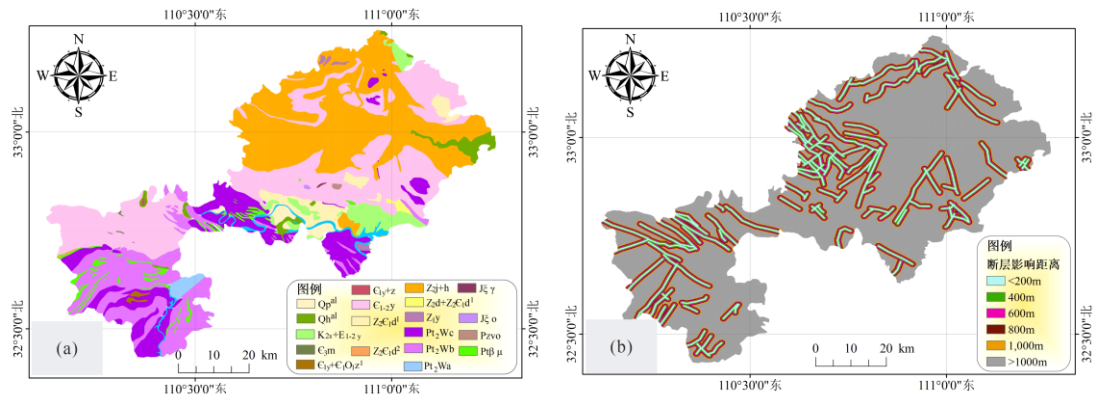
(1) 区域地质因素：地层岩性直接影响岩体力学性质和强度 (Ciurleo, 2017)，对滑坡的稳定性影响较大 (刘汉香, 2013)。研究区地层较为完整，除中生界志留系、二叠系、侏罗系地层缺失外，元古界至新生界地层皆有分布。断层对边坡的稳定性起着关键作用，影响坡体的内部应力平衡，还会降低岩石的强度。Psomiadis et al. (2020)等人指出，随着断层距离的增加，滑坡地质灾害发生的可能性会降低。研究区的主要断裂为：两郧断裂带和公路断裂带，在两处主要断裂带附近分布大量次级断裂，对研究区的滑坡稳定性影响较大，如图 8 (a) - (b)所示。

(2) 地形地貌因素：研究区的地形地貌因子包括：坡度、高程、坡向、斜坡曲率、地表粗糙度、斜坡类型。研究区坡度变化不大，坡度较陡的地段主要分布在西北部以及南部，研究区中部坡度平缓，在汉江流域附近坡度接近 0；本研究区的高程范围为 134-1786m，高差在 1000m 左右，高海拔地区主要集中在研究区的东北部和西南部山区；本文共提取了平面曲率、剖面曲率和平均曲率 3 个不同的曲率因子，曲率决定了地表径流的汇聚和扩散，对斜坡稳定性有一定影响，总体上来说研究区内曲率变化不大 (Xu et al., 2015；许冲等, 2012)。地表粗糙度可表征地表凹凸不平的程度，又称为地表微地形，在地形学的领域内是指地表凹凸不平的程度，在 GIS 领域，地表粗糙度是反映地表起伏和侵蚀程度的重要指标(曾忠平等, 2006)。总体来看，研究区的地表粗糙度变化不大值普遍偏高。结果见图 8 (d)- (f)。

(3) 水文地质因素：研究区内的水系主要包括河流、季节性溪流、地势低缓的冲沟等。主要河流为汉江，以及在郧阳区与郧西县交界处的丹江口水库。由于水库建设，库区附近滑坡频发，形成丹江口库区滑坡不稳定带。汉江各支流众多，密布于郧阳区境内，对研究区的滑坡稳定性影响较大。如图 8 (g) 所示。

(4) 气候环境条件：降雨强度变化，尤其是短时间内的强降雨，会引发山体滑坡。降水的入渗增加了土体容重和坡体自重，软化岩土体，降低其力学强度，是滑坡产生的催化剂和润滑剂。总体上看研究区降雨中部低，西南与东北侧偏高。地表植被覆盖率是影响滑坡的重要因素之一，它通过影响水土流失强度，进而对斜坡的稳定性产生重要作用。研究区的 NDVI 指数西南部高中部较低，有从西南向东北逐渐降低的趋势。结果见图 8 (h)-(i)。

(5) 人类工程活动：道路开挖、建设是人类工程活动的主要类型。在道路建设过程中，由于开挖切坡、人工爆破、回填路基等工程活动，会直接破坏原始山体自然稳定状态，造成高切坡、不稳定边坡、地面不均匀沉降等现象，进而导致各类地质灾害的发生，威胁着经济建设安全 (白世彪等, 2005)。研究区道路覆盖大部地区，中部河谷地区尤为集中。如图 8 (j)所示。



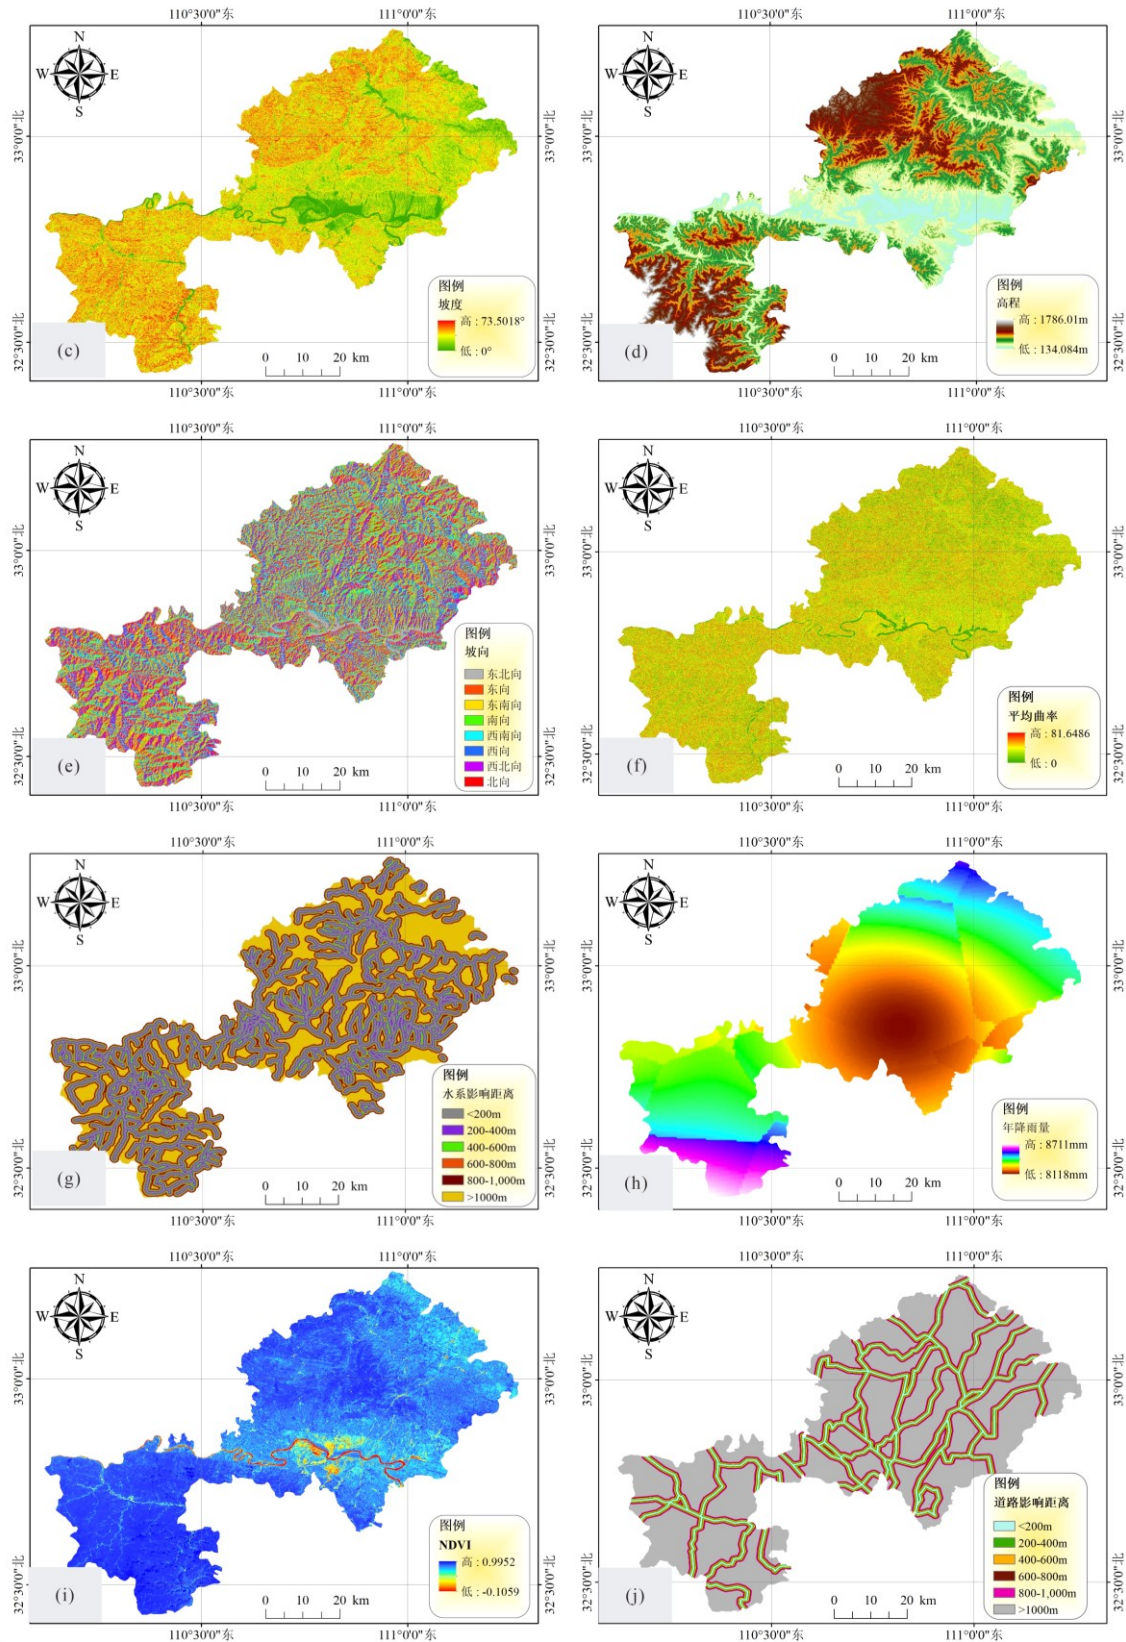


图 8 斜坡易发性评价因子, (a)地质构造, (b)断层影响距离, (c)坡度, (d)高程, (e)坡向, (f)平均曲率, (g)水系影响距离, (h)年降雨量, (i)NDVI, (j)道路影响距离

Fig. 8 Rating factors for slope susceptibility (a) Geological formation, (b) Distance to fault, (c) Slope, (d) Elevation, (e) Aspect, (f) Mean curvature, (g) Distance to drainage, (h) Annual rainfall, (i) NDVI, (j) Distance to road.

3.2 致灾因子筛选

综合前人研究以及研究区的地质背景 (Pham and Prakash, 2018), 结合 Spearman 相关性分析得到各因子间的相关系数, 并绘制热力图, 见下图 9。

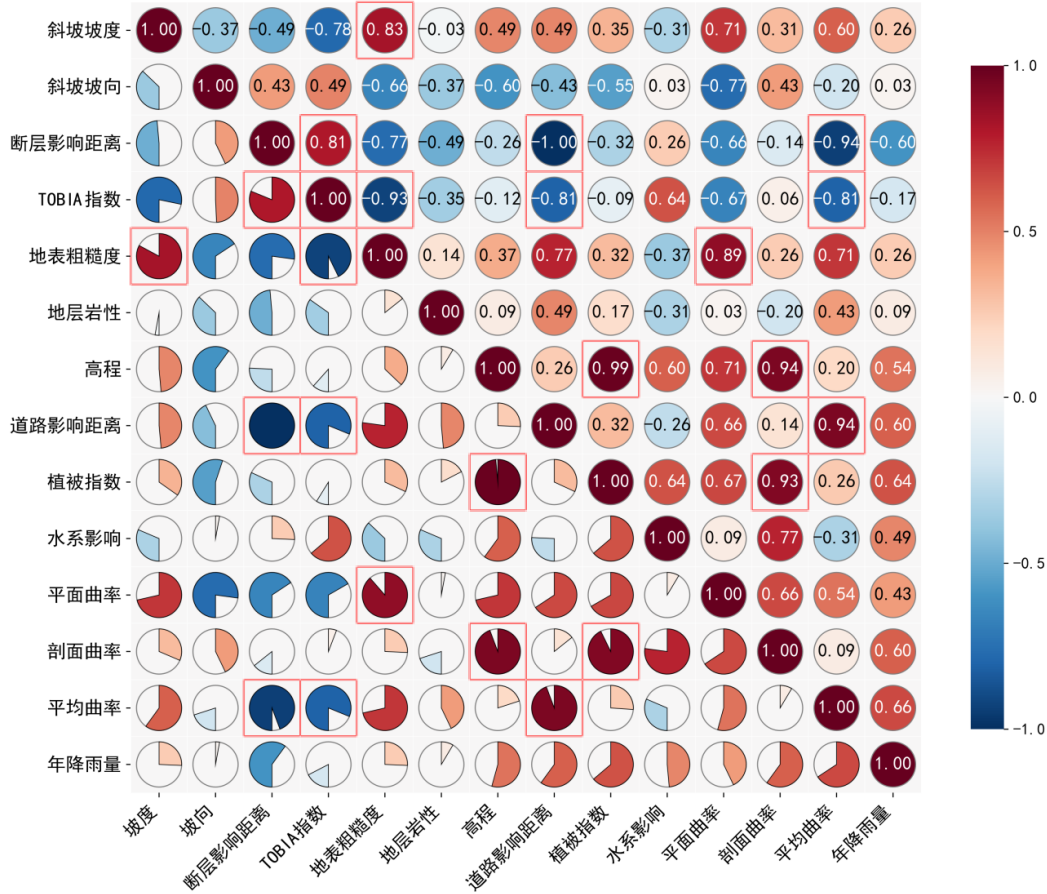


图 9 Spearman 相关性系数热力图

Fig.9 Spearman correlation coefficient heatmap

如图 9 所示, 右上三角矩阵为各因子相关性系数, 左下三角矩阵为各因子相关性系数占比, 本文以相关性系数绝对值大于 0.8 (图中红色线框标注的要素) 为高相关性的判定标准, 筛选至灾因子, 最终删除了 TOBIA 指数、地表粗糙度、剖面曲率、平均曲率四个因子, 保留了 10 个致灾因子作为 CNN 模型的输入数据。分别为: 坡向、坡度、地层、公路影响距离、断层影响距离、河流影响距离、平面曲率、植被指数 (NDVI)、高程和年降水量。

3.3 模型训练结果

使用个人电脑训练深度学习模型, 本次实验所使用的电脑参数为 Intel(R) Core(TM) i5-8300H、CPU 2.30GHz, CUDA 版本 11.0。使用 2020b 版本 MATLAB 进行编程, 训练和测试框架均使用 Deep Network Designer 工具。使用试错法 (试错范围 Epoch: 100-200; 学习率: 0.01-0.0001; 批次: 32-64) 在训练过程中优化, 最佳参数如表 2 所示

表 2 五种模型训练参数

Table 2. Training Parameters for the Five Models

深度学习模型	网络层数	批量大小	学习率	Epoch
AlexNet	8	64	0.001	200
GoogleNet	22	32	0.001	180
Inception	94	64	0.001	150
DenseNet-201	201	64	0.001	100
ResNet-101	101	32	0.001	100

表中参数指模型训练过程所需的参数包含权重、偏置等，以表征模型的复杂程度。应用以上训练参数对五种模型进行训练，得到训练过程截图如图 10 所示：

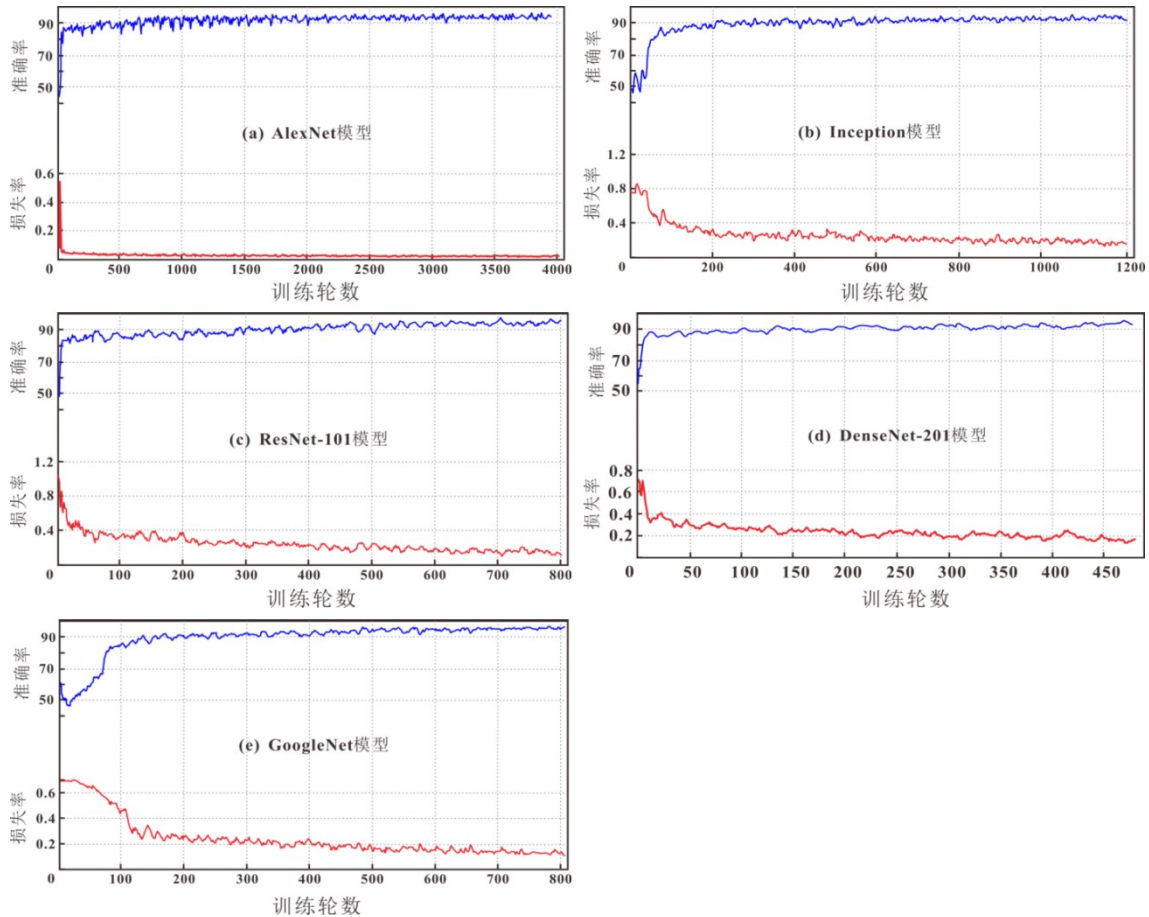


图 10 五种模型的训练过程图：(a)AlexNet, (b)Inception, (c)ResNet-101, (d)DenseNet-201, (e)GoogleNet

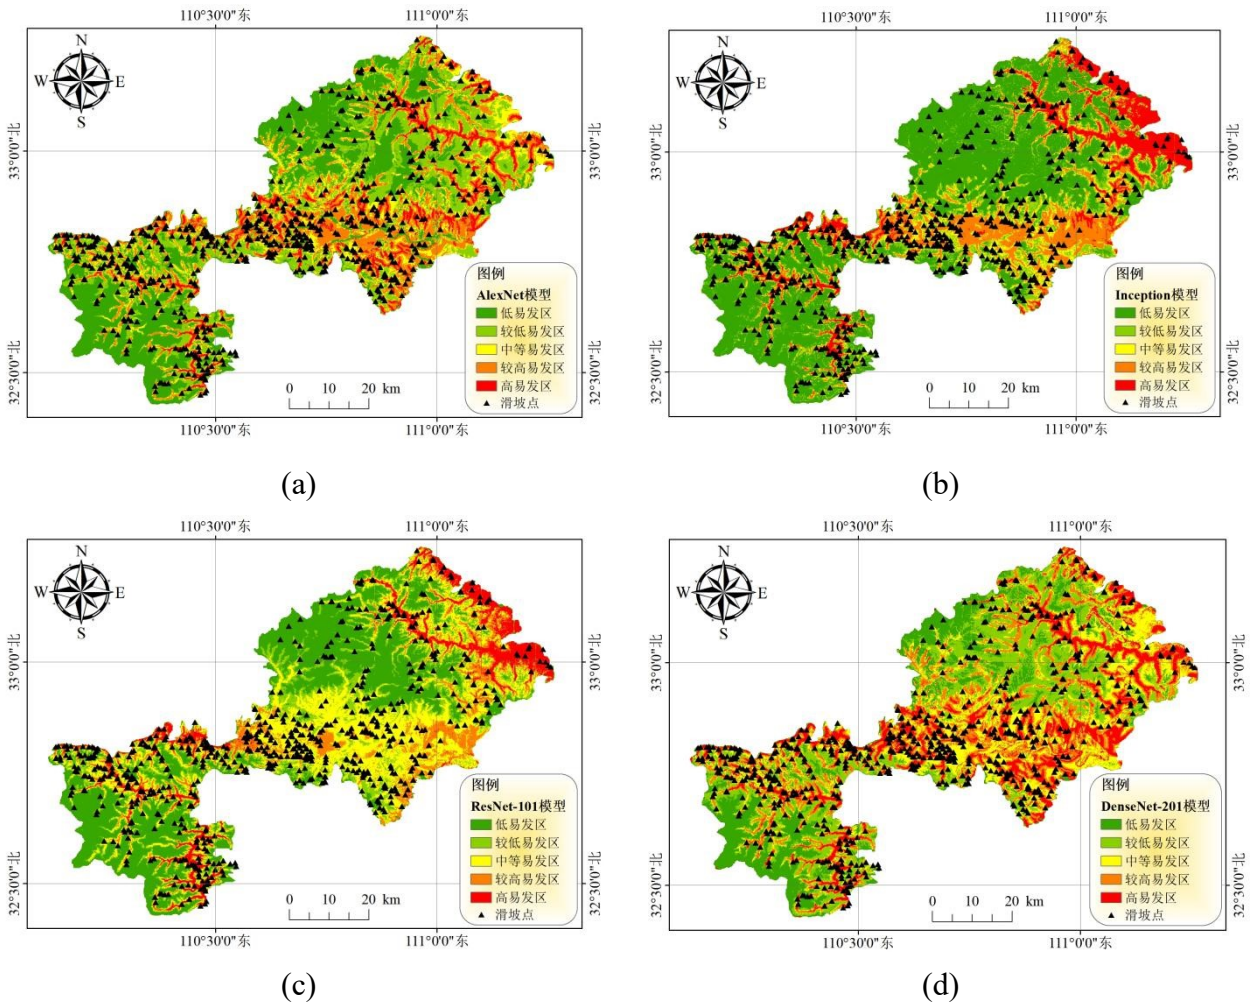
Fig. 10 Training process diagrams for five models: (a) AlexNet, (b) Inception, (c) ResNet-101, (d) DenseNet-201, and (e) GoogleNet.

图中红色曲线代表损失率 (Loss)，蓝色曲线代表准确率。由图可知，随着训练轮数 (Epoch) 的增加，五种模型的损失率均呈现快速下降并逐渐趋于平稳的态势，最终收敛于 0.2；同时，准确率曲线稳步上升并保持在 90%。这表明所有模型在训练过程中均实现了良好的收敛，参数更新稳定，未出现明

显的梯度消失或模型震荡现象。

3.4 易发性分区评价结果

五种深度学习模型（AlexNet, Inception, ResNet-101, DenseNet-201, GoogLeNet）的评价结果在宏观上表现出显著的一致性 (如图 11 所示)。总体上, “较高-高易发区” 在整个研究区分布较均匀, 主要呈线状, 沿着山体走向分布; 东北部、中部、东南部的高易发区较为集中, 并且与地形和断裂带有显著关联。尤其是中部, 两郟断裂带与公路断裂带之间, 为滑坡高易发区如图 11 (f)。尽管总体趋势一致, 但各模型在局部区域的预测细节上存在明显差异。在东北部, Inception、ResNet-101、DenseNet-201 及 GoogLeNet 模型均识别出片状的高易发区, 而 AlexNet 模型的结果中该区域的风险则为中易发区; 在中部地区, AlexNet、Inception、DenseNet-201 和 GoogLeNet 模型均预测为“较高-高”易发区, 但 ResNet-101 模型的预测结果则显著不同, 认为该区域主要为中等易发区。综上所述, 深度学习模型评价结果显示, 研究区的中部受到两郟断裂和公路断裂的影响较大, 存在较大易发性, 需要重点关注断裂不稳定带内, 可以设置滑坡位移监测点等监测手段重点关注; 南部和北部受到地形影响, 在山脉附近的滑坡易发性较大, 部分陡峻山体建议进行加固。



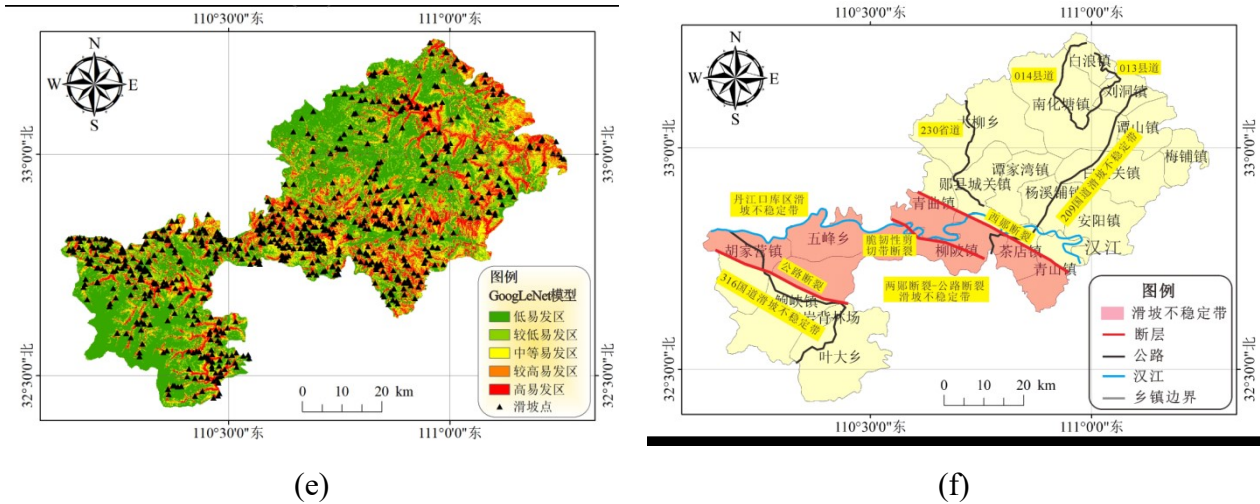


图 11 基于深度学习的滑坡易发性评价结果图, (a) AlexNet, (b) Inception, (c) ResNet-101, (d) DenseNet-201, (e) GoogLeNet, (f) 郧阳区滑坡不稳定带

Fig. 11 Landslide susceptibility assessment results based on deep learning, (a) AlexNet, (b) Inception, (c) ResNet-101, (d) DenseNet-201, (e) GoogLeNet, (f) Landslide instability zones in Yunyang District.

3.5 模型结果对比分析

(1) 滑坡易发性分区统计

从统计结果可以看出, 随着易发性分区等级从“低易发区”向“高易发区”过渡, 所有五个模型的滑坡频率和滑坡密度值都呈现出显著的、持续的增长趋势。这表明这五种模型都能够有效地对滑坡易发性进行分区, 其预测结果与滑坡的实际空间分布规律具有良好的一致性 (图 12)。

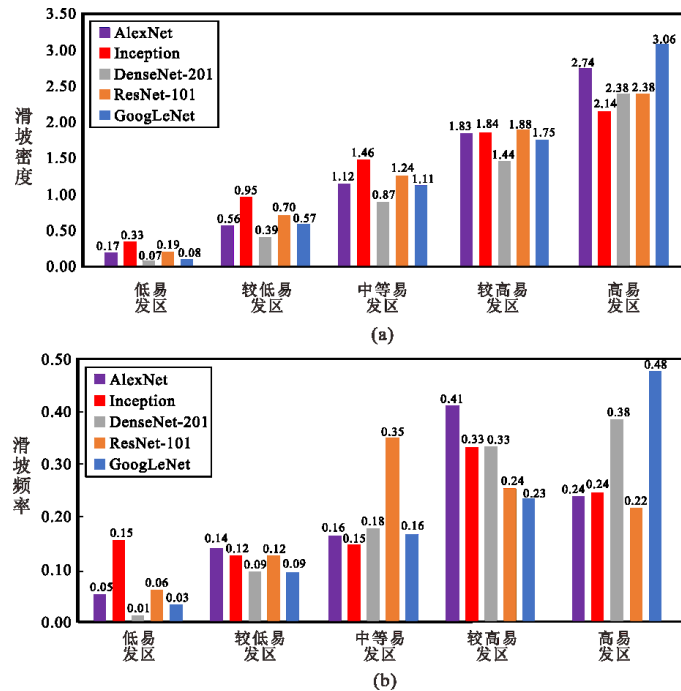


图 12 五种模型滑坡分区统计情况: (a)滑坡频率, (b)滑坡密度

Fig. 12 Statistical conditions of landslide zoning for five models: (a) Landslide frequency, (b) Landslide density
从滑坡频率统计图 (图 12 (a))中可以看出, 在所有易发性分区中, 尤其是在“高易发区”, GoogLeNet

模型的滑坡频率 (0.48)最高, 而 Inception 和 ResNet-101 模型在“高易发区”的滑坡频率 (分别为 0.24 和 0.22)表明它们在识别和划分最高风险区域方面的能力略逊于其他模型; 从滑坡密度统计图 (图 12 (b))分析, 高易发区中, GoogLeNet 模型高于其他四种模型, 达 3.06 个/km², 其次为 AlexNet 模型 (2.74 个/km²), DenseNet-201 模型、ResNet-101 模型一致, 均为 2.38 个/km², Inception 模型最低。在低易发区, 五种模型的滑坡密度均很小, 均小于 0.33 个/km²。滑坡密度和滑坡频率统计验证分析证明, 基于深度学习的五种模型滑坡易发性评价精度很高, 适合滑坡预测; 其中 GoogLeNet 模型的预测结果最准确。

(2) ROC 曲线

对五种模型的预测值进行 ROC 分析, 五种模型得到的 ROC 曲线非常接近左上角, AUC 值也均超过 0.75。5 种方法得到的 ROC 曲线差别较小, 其中 GoogLeNet 模型 ROC 曲线形状最好, 其 AUC 值 (0.837) 最高。ResNet-101 模型的 AUC 值最低, 只有 0.759。AlexNet 模型准确率仅次于 GoogLeNet 模型达到 0.797, Inception 模型和 DenseNet-201 的 ROC 曲线非常接近, 二者模拟效果接近。整体来说, 五种深度学习模型的 ROC 验证曲线较好, AUC 值均大于 0.759 (如图 13 所示), 证明基于深度学习模型的五种模型适合滑坡易发性评价, 其中 GoogLeNet 模型更加适合本研究区。

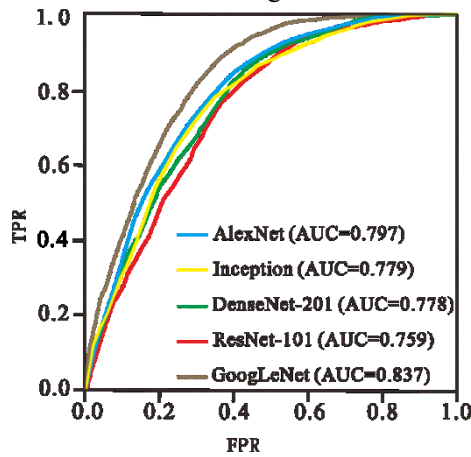


图 13 基于 5 种评价模型的 ROC 曲线图

Fig. 13 ROC curve chart based on five evaluation models




图 14 五种深度学习模型耗费时间统计图

Fig. 14 Statistical chart of time consumption for five deep learning models

(3) 实施难度与优缺点

五种方法均基于深度学习框架进行构建, 整体的流程大同小异, 均分为数据预处理、模型训练、易发性评价图可视化三部分 (表 3)。首先, 数据预处理部分主要在 ArcGIS 软件进行, 该过程的难点在 10 个致灾因子的提取, 需要耗费大约 10 个小时; 将 10 个因子数据进行导出, 这个过程较为简单, 但是需要电脑进行自动处理, 此步骤所耗时间受电脑配置影响较大, 本环节耗时 4 个小时; 再使用导出的数据构建训练集和测试集, 此过程耗时 20min。其次, 模型训练步骤, 该过程主要使用 MATLAB 软件进行, 所耗费的时间受模型的深度和网络层数影响, 理论上, 网络深度越深, 提取的特征越多, 分类性能越好, 所得出的滑坡易发性评价图准确率越高, 但是其耗费时间也越多。

表 3 同一计算机配置下 5 种评价模型的时间消耗统计

Table.3 Statistics of time consumption for five evaluation models under the same computer configuration

项目	过程	时间消耗
----	----	------

	10 因子提取	10 h
预处理	滑坡点和非滑坡点的选择	20 min
	通过多值提取至点功能， 提取并导出 10 因子数据	2 h
	构建训练集和测试集	10 min
	AlexNet	33 min
AlexNet	使用训练模型预测研究区的滑坡易发性	10 min
	Inception	71 min
Inception	使用训练模型预测研究区的滑坡易发性	21 min
	GoogLeNet	37 min
GoogLeNet	使用训练模型预测研究区的滑坡易发性	12 min
	ResNet-101	109 min
ResNet-101	使用训练模型预测研究区的滑坡易发性	30 min
	DenseNet-201	165 min
DenseNet-201	使用训练模型预测研究区的滑坡易发性	50 min
	可视化	20 h
	将预测值导入 ArcGIS 软件， 并进行栅格转换	
电脑配置	笔记本品牌	戴尔
	Windows 版本	Windows 10 professional
	处理器	Intel (R) Core (TM) i5-8300H
		2.30 GHz dual-core
	内存	8 G of RAM
	系统	64 位操作系统

最后一步，将模型输出的预测值导入 ArcGIS 软件，使用要素转栅格功能进行栅格转换，得到滑坡易发性评价图，该过程受电脑配置影响很大，本研究耗时间在 20 小时左右。深度学习模型的训练时间受多方面因素影响，比如深度、层数、Epoch 等参数。网络深度越深、网络总层数越多、Epoch 越大，时间越长。从 AlexNet 到 DenseNet-201，网络深度和总层数呈递增趋势，其训练时间也从 33 分钟至 165 分钟递增 (表 3)。Inception 模型虽然深度较低，但是其网络总层数较多，所以训练时间较长。在五种模型中，AlexNet 模型花费时间最少，其次是 GoogLeNet, Inception, ResNet-101, DenseNet-201 (图 14)。

(4) 传统模型对比

通过粒子群优化算法（PSO）经过 47min 时间得到随机森林的最佳超参数如下表 4：

表 4 基于 PSO 的随机森林超参数表

Table 4. PSO-based Random Forest Hyperparameters

随机森林参数	PSO 找到的最佳值	设置的范围(下限/上限)
树的数量	62.85028477	[50, 300]
最大深度	8.34609569	[3, 15]
分裂节点所需样本数	5	[5, 20]
叶节点最小样本数	3.06775602	[3, 10]

用过最优超参数得到最优模型进行滑坡易发性评价成图结果如图 15。由图 15 可知随机森林结果与上述 5 种深度学习模型大体一致，其中 AUC 值略低于 GoogLeNet，优于其他 4 个深度学习模型，在统计方面，随机森林的高易发区滑坡频率比为 2.81，略低于 GoogLeNet。这从另一方面印证了深度学习尤其是 GoogLeNet 在预测结果上的准确性。

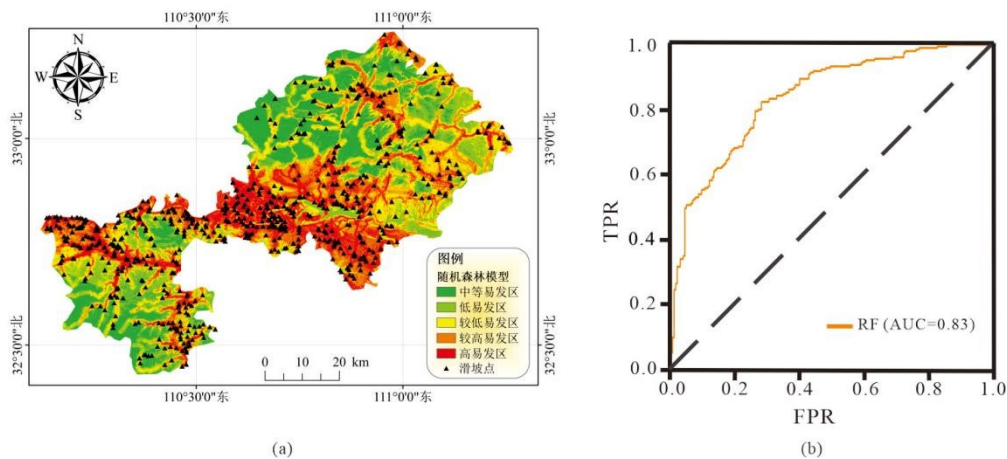
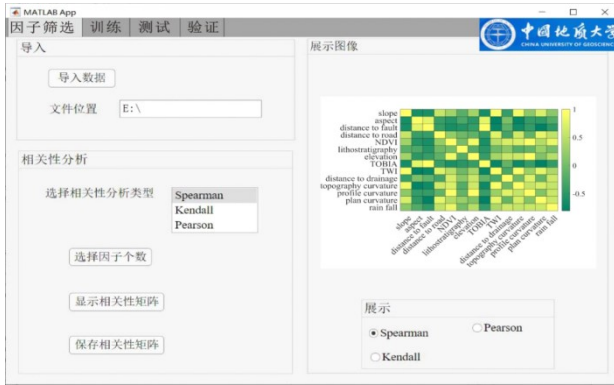


图 15 随机森林结果图(a)随机森林滑坡预测结果;(b)最优随机森林 ROC 曲线

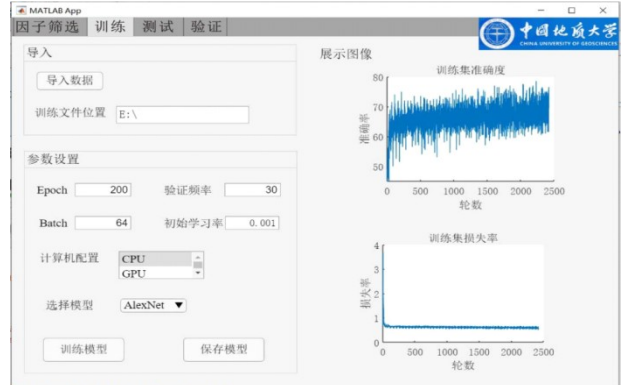
Fig 15. (a) Landslide prediction results from the Random Forest; (b) ROC curve of the optimal Random Forest.

3.6 基于深度学习的滑坡易发性评价系统

基于上述成果，本研究开发的基于深度学习的滑坡易发性评价平台，包含因子筛选、深度学习训练、模型测试和模型验证四个模块。实现了滑坡易发性评价全流程的自动化、可视化与精准化因子筛选模块，如图 16 所示。



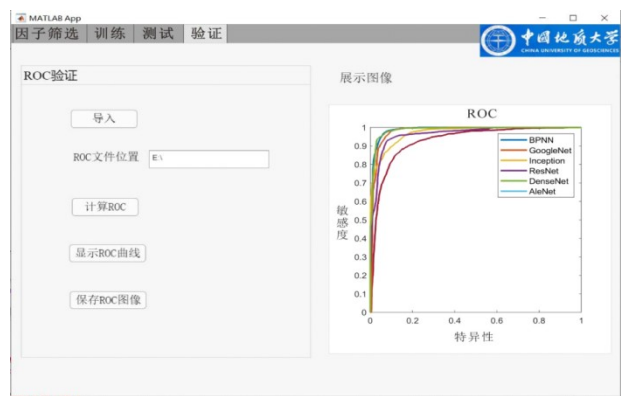
(a)



(b)



(c)



(d)

图 16 基于深度学习的滑坡易发性评价系统 App 界面, (a)因子筛选模块, (b)深度学习训练模块, (c)模型测试模块, (d)验证模块

Fig. 16 Deep Learning-based Landslide Susceptibility Evaluation System App Interface (a) Factor Selection Module (b) Deep Learning Training Module (c) Model Testing Module (d) Validation Module

(1) 因子筛选模块

支持.txt .xls .xlsx 格式的输入数据格式, 提供 Spearman、Kendall、Pearson 三种相关性分析方法供用户使用, 多种方法进行致灾因子筛选, 选择最优结果。而且可以显示致灾因子的相关性矩阵, 并且提供保存相关性矩阵图像功能。如图 16 (a)所示。

(2) 深度学习训练模块

训练参数包括 Epoch、Batch 大小、验证频率、初始学习率、计算机配置。本系统允许用户使用 AlexNet 模型、Inception 模型、ResNet 模型、DenseNet 模型、GoogleNet 模型五种模型, 其他深度学习模型并未纳入本系统。在模型训练结束后, 可以展示模型训练的准确率、损失率。也提供保存训练集的准确率、损失率图像功能, 如图 16 (b)所示。用户根据研究需求自定义 Epoch、Batch 大小、验证频率及初始学习率等关键参数。使用试错法, 不断调整参数, 直至测试集的准确率大于 90%; 若测试集准确率小于 90%, 则表示训练模型欠佳, 需要调整训练参数。当测试集的准确率大于 90%时, 模型训练完毕。

(3) 模型测试模块

首先导入测试数据集, 同时选择训练好的深度学习模型, 依次将五个模型应用至测试集, 测试集的作用是初步验证训练模型的准确性。若测试集准确率过低, 则判断模型训练失败, 需要重复训练模块操

作；当测试数据集的准确率达到 90%以上时，证明模型训练达标。测试集达标后，将模型应用到整个研究区，计算整个研究区的滑坡易发性值，如图 16 (c)所示。用户如需生成全区滑坡易发性图，需将计算得到的易发性值表导入 GIS 软件后点转栅格即可。

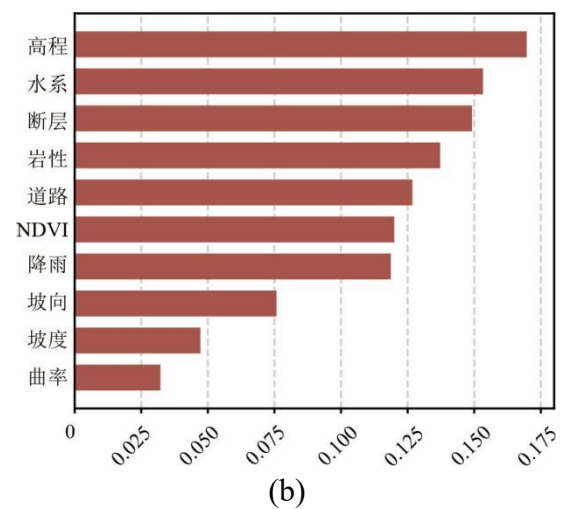

(4) 验证模块


验证模块采用 ROC 曲线分析法对平台输出的易发性结果进行可靠性验证，支持导入滑坡编目数据与易发性评价结果构建的 ROC 验证数据集。点击“计算 ROC 曲线”按钮后，平台自动计算模型的受试者工作特征曲线与 AUC 值，如图 16 (d)所示。

4 讨论

4.1 模型的对比

为进一步探讨不同模型之间的差异性，本文采用置换特征重要性 (Permutation Feature Importance, PFI) 方法对各模型的特征依赖特征进行分析。该方法通过在测试集中随机打乱某一特征的取值 (其余特征保持不变)，并量化模型预测性能指标 (如准确率) 的下降幅度，以衡量该特征对模型预测结果的贡献程度。准确率下降越显著，表明模型对该特征的依赖程度越高 (图 17)。由图 17 可知深度学习模型整体上更倾向于综合多源因子进行联合判别，而随机森林模型则对“高程”、“道路距离”等少数因子表现出较强依赖性，导致其预测的高易发区在空间上与道路网络高度趋同，呈现出明显的线状分布特征，这在一定程度上偏离了区域工程地质实际情况。相比之下，GoogLeNet 模型所识别的高易发区分布更加离散，主要以点状或块状形式分布于断裂带及道路周边，其空间格局与郟阳区的地质环境背景更为一致。传统机器学习模型受限于“像素级”特征输入，难以充分利用空间邻域信息，从而在揭示深层地质构造关联方面存在一定不足；而卷积神经网络能够通过多尺度卷积与特征聚合机制有效挖掘邻域空间特征，在滑坡易发性预测中展现出更强的地质表达能力(Huang et al., 2023)。





注：纵坐标表示因子类别，横坐标表示扰动单一因子后模型准确率的下降幅度；下降幅度越大，说明模型对该因子的依赖性越强。

图 17 各模型特征模型权重对比图 (a) AlexNet, (b) Inception, (c) ResNet-101, (d) DenseNet-201, (e) GoogLeNet, (f) RF

Fig 17. Comparison chart of weight of each model feature model (a) AlexNet, (b) Inception, (c) ResNet-101, (d) DenseNet-201, (e) GoogLeNet, (f) RF

尽管 GoogLeNet 模型的计算耗时略高于 AlexNet 模型，但其在滑坡易发性评估中表现出最高的预测精度。综合权衡模型预测性能与计算效率，GoogLeNet 相较于其他模型更适合用于郧阳区滑坡易发性预测。该结论与本团队在甘肃某区开展的前期研究结果一致，两项研究均表明，在样本数量有限的条件下，层数较浅、参数规模相对较小的网络结构（如 GoogLeNet 和 Xception）反而优于结构更为复杂、深度更大的模型（如 ResNet-101 和 DenseNet-201）。表明过深的网络在小样本情形下更易陷入局部最优或对噪声特征产生过拟合（Wang et al., 2019）。

GoogLeNet 通过 Inception 模块中多尺度卷积核的并行计算，在模型宽度与深度之间实现了有效平衡，使其既能够捕捉局部工程活动相关特征，又能够提取区域尺度的构造与地貌纹理信息。对研究区中部滑坡不稳定带（两郧断裂与公路断裂交汇区）的局部放大对比分析（图 18）表明，AlexNet 与 DenseNet-201 预测的高易发区与道路及河流分布高度重合，而 GoogLeNet 所识别的高易发区则呈现出更符合地质非均质特征的离散化空间格局，并有效剔除了汉江水体的干扰。这一结果与图 17 所示 GoogLeNet 对断层、岩性等主控因子的更高依赖性相一致，进一步验证了其预测结果的地质合理性。

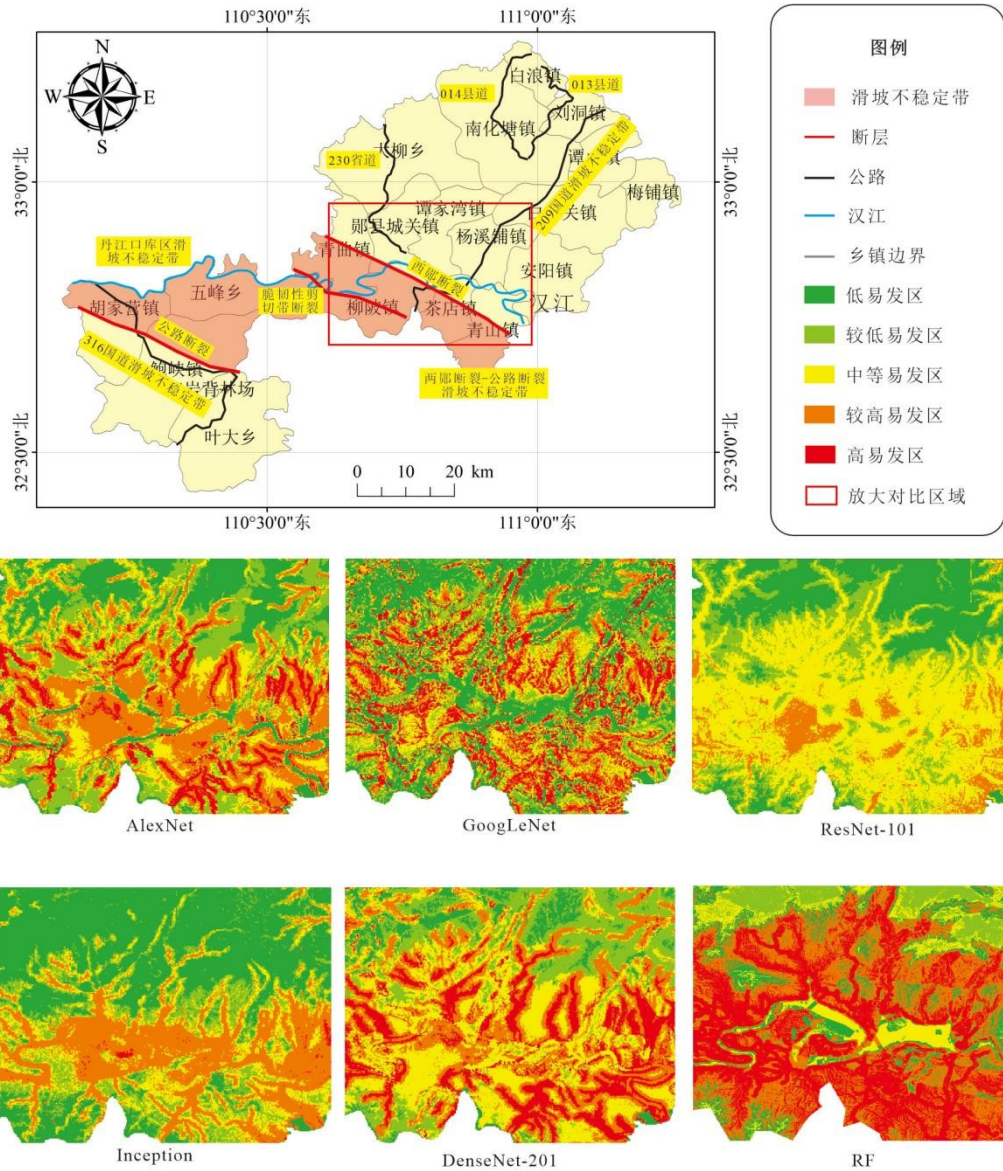


图 18 易发性结果局部对比图
Fig 18 Comparison of susceptibility results

4.2 研究的局限性

滑坡易发性评价受数据精度影响较大，本研究收集的 DEM 数据精度为 5 米，但是 NDVI 因子精度为 30 米、年降雨量因子精度为 150 米，数据精度较低。而且由于数据受限，本研究收集的年降雨量数据、NDVI 数据为 2020 年，一定程度上不能代表最新时间的实际情况，由此得到的评价结果与实际情况会有一定偏差。同时降雨作为滑坡主要的触发因素，以年降雨量这一静态指标作为评价指标可能会忽视季节性变化或极端天气对滑坡的影响。

负样本的选取是滑坡空间预测预报的难点，虽然本研究非滑坡样本采用“缓冲区+随机采样”策略是目前基于机器学习进行滑坡评价的常用方法。然而该方法任可能将未被调查的潜在滑坡纳入非滑坡样本中对模型的精度造成影响。在未来的研究中，我们将尝试地质相似度聚类的半监督采样策略，以进一步

提升样本的地质代表性。

在数据方面，由于深度学习的特点，需要样本数据较大，因此在滑坡编录数据缺失或样本量极少的小型研究区，深度学习容易陷入过拟合，此时传统机器学习模型（如随机森林）可能是更优选择。同时本研究提出了一个集成的深度学习系统，具有较强的可移植性并且该架构在团队前期的甘肃工程区研究中也表现优异，显示了一定的架构普适性，但若将本研究训练好的权重直接迁移至地质环境差异巨大的区域，模型的预测能力可能会因致灾机理的改变而下降。

5 结论

本研究以湖北省十堰市郧阳区为例，基于地质与遥感数据筛选出通过 Spearman 相关分析提取出 10 个致灾因子，通过 AUC、滑坡统计分区、实施难度与效率和传统方法对比多个维度分析 5 种深度学习模型（AlexNet、Inception-v3、ResNet-101、DenseNet-201、GoogLeNet）在滑坡易发性评价中的应用效果，并开发了配套软件。主要结论如下：

本研究从 AUC、统计分析、训练效率和传统模型，5 个维度对比综合得出 GoogLeNet 模型是本研究区滑坡易发性评价任务的最优模型。

深度学习模型并非绝对优于传统模型。随机森林模型（AUC=0.83）的性能优于三种更复杂的深度学习模型（Inception-v3, ResNet-101, DenseNet-201）。这表明在滑坡易发性评价任务中，模型的架构选择至关重要，GoogLeNet 的简易结构，卷积网络与滑坡易发性评价任务高度契合，而更深、更复杂的模型反而可能表现不佳。同时最优模型（GoogLeNet）生成的易发性图（图 10e）准确识别了沿“两郧-公路断裂带”和的高风险区，验证了模型对地质因素的捕捉能力，评价结果可为当地防灾减灾和国土空间规划提供科学依据。

本研究开发的滑坡易发性评价系统，系统主要包含四个模块，分别是因子筛选模块、训练模块、测试模块、验证模块。系统操作简单，对初学者友好，可以使得一些不熟悉编程的地质工作者也可以通过界面按钮顺序来进行滑坡易发性评价。为深度学习模型从学术研究走向地质灾害防灾实践提供了可行途径。

References

- Andrieu, C., De Freitas, N., Doucet, A., et al., 2003. An introduction to MCMC for machine learning. *Machine learning*, 50(1), 5-43.
- Bai, S.B., Lu, G.N., Sheng, Y.H., et al., 2005. Analysis of Landslide Influencing Factors in the Three Gorges Reservoir Area of the Yangtze River Based on GIS. *Journal of Mountain Science* , (01), 63-70 (in Chinese with English abstract).
- Chen, W., Xie, X., Wang, J., et al., 2017. A Comparative Study of Logistic Model Tree, Random Forest, and Classification and Regression Tree Models for Spatial Prediction of Landslide Susceptibility. *Catena*, 151, 147-160. doi: 10.1016/j.catena.2016.11.032
- Ciurleo, M., Cascini, L., Calvello, M., 2017. A Comparative Study of Statistical and Deterministic Methods for Shallow Landslide Susceptibility Zoning in Clayey Soils. *Engineering Geology*, 223, 71-81. doi: 10.1016/j.enggeo.2017.04.023
- Dias, L.O., Bom, C.R., Faria, E.L., et al., 2020. Automatic Detection of Fractures and Breakouts Patterns in Acoustic Borehole Image Logs Using Fast-Region Convolutional Neural Networks. *Journal of Petroleum Science and Engineering*, 2020, 191: 107099. doi: 10.1016/j.petrol.2020.107099
- DeGraff, J.V., Romesburg, H.C., 2020. Regional Landslide-Susceptibility Assessment for Wildland Management: A Matrix Approach. *Routledge*, 2020: 401-414. doi: 10.4324/9781003028697-19
- Dobrovolny, E., 1964. Landslide Susceptibility in and Near Anchorage as Interpreted from Topographic and Geologic Maps. *The Great Alaska Earthquake of 1964*, 1964: 735-745.
- Dowling, C.A., Santi, P.M., 2014. Debris Flows and Their Toll on Human Life: A Global Analysis of Debris-Flow Fatalities from 1950 to 2011. *Natural Hazards*, 71 (1), 203-227. doi: 10.1007/s11069-013-0907-4
- Ermini, L., Catani, F., Casagli, N., 2005. Artificial Neural Networks Applied to Landslide Susceptibility Assessment. *Geomorphology*, 66 (1-4), 327-343. doi: 10.1016/j.geomorph.2004.09.025
- Ge, Y.F., Chen, H.Z., Zhao, B.B., et al., 2018. A Comparison of Five Methods in Landslide Susceptibility Assessment: A Case Study from the 330-kV Transmission Line in Gansu Region, China. *Environmental Earth Sciences*, 2018, 77 (19): 1-15 . doi: 10.1007/s12665-018-7814-7
- Ge, Y.F., Liu, G., Tang, H.M., et al., 2023. Comparative Analysis of Five Convolutional Neural Networks for Landslide Susceptibility Assessment. *Bulletin of Engineering Geology and the Environment*, 82 (10). doi: 10.1007/s10064-023-03408-9
- Huang, F., Cao, Z., Guo, J., et al., 2020. Comparisons of Heuristic, General Statistical and Machine Learning Models for Landslide Susceptibility Prediction and Mapping. *Catena*, 191, 104580. doi: 10.1016/j.catena.2020.104580
- Huang, F.M., Chen, B., Mao, D.X., et al., 2023. Landslide Susceptibility Prediction Modeling Based on Self-Screening Deep Learning and Its Interpretability. *Journal of Earth Science*, 48 (05), 1696-1710. doi: 10.3799/dqkx.2022.247(in Chinese with English abstract).

- Tien, B.D., Pradhan, B., Lofman, O., et al., 2012. Landslide Susceptibility Assessment in Vietnam Using Support Vector Machines, Decision Tree, and Naive Bayes Models. *Mathematical problems in Engineering*, 2012 (1), 974638. doi: 10.1155/2012/974638
- Kalantar, B., Pradhan, B., Naghibi, S.A., et al., 2018. Assessment of the Effects of Training Data Selection on the Landslide Susceptibility Mapping: A Comparison Between Support Vector Machine (SVM), Logistic Regression (LR) and Artificial Neural Networks (ANN). *Geomatics, Natural Hazards and Risk*, 2018, 9 (1): 49-69. doi: 10.1080/19475705.2017.1407368
- Liu, H.X., Xu, Q., Hou, H.J., 2013. Influence of Lithology and Rock Mass Structure on Seismic Acceleration Response of Slopes. *Rock and Soil Mechanics*, 34 (09), 2482-2488 (in Chinese with English abstract). doi: 10.16285/j.rsm.2013.09.020
- Lombardo, L., Mai, P.M., 2018. Presenting Logistic Regression-Based Landslide Susceptibility Results. *Engineering Geology*, 244, 14-24. doi: 10.1016/j.enggeo.2018.07.019
- Mandal, B., Mandal, S., 2017. Landslide Susceptibility Mapping Using Modified Information Value Model in the Lish River Basin of Darjiling Himalaya. *Spatial Information Research*, 25 (2), 205-218. doi: 10.1007/s41324-017-0096-4
- Pham, B.T., Bui, D.T., Prakash, I., 2018. Bagging Based Support Vector Machines for Spatial Prediction of Landslides. *Environmental earth sciences*, 77 (4), 1-17. doi: 10.1007/s12665-018-7268-y
- Psomiadis, E., Papazachariou, A., Soulis, K.X., et al., 2020. Landslide Mapping and Susceptibility Assessment Using Geospatial Analysis and Earth Observation Data. *Land*, 9 (5), 133. doi: 10.3390/land9050133
- Rossi, M., Guzzetti, F., Reichenbach, P., et al., 2010. Optimal Landslide Susceptibility Zonation Based on Multiple Forecasts. *Geomorphology*, 114 (3), 129-142. doi: 10.1016/j.geomorph.2009.09.006
- Sangaratos, P., Ilia, I., Hong, H., et al., 2017. Applying Information Theory and GIS-Based Quantitative Methods to Produce Landslide Susceptibility Maps in Nancheng County, China. *Landslides*, 14 (3), 1091-1111. doi: 10.1007/s10346-017-0803-x
- Sameen, M.I., Pradhan, B., Lee, S., 2020. Application of Convolutional Neural Networks Featuring Bayesian Optimization for Landslide Susceptibility Assessment. *Catena*, 186, 104249. doi: 10.1016/j.catena.2019.104249
- Shahabi, H., Hashim, M., 2015. Landslide Susceptibility Mapping Using GIS-Based Statistical Models and Remote Sensing Data in Tropical Environment. *Scientific Reports*, 5 (1), 1-15. doi: 10.1038/srep09899
- Su, Y.T., Yang, W.Y., Li, J.L., 2021. Intelligent Identification Method of Fractures in Coal-rock Borehole Images Based on YOLO v3. *Safety in Coal Mines*, 52 (04), 156-161 (in Chinese with English abstract). doi: 10.13340/j.cnki.mkaq.2021.04.027
- Szegedy, C., Vanhoucke, V., Ioffe, S., et al., 2016. Rethinking the Inception Architecture for Computer Vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2818-2826). doi: 10.1109/CVPR.2016.308
- Tang, X. N., 2019. Susceptibility assessment of landslide disasters in Lüliang City based on convolutional neural network and comprehensive index model (Master's Thesis). Taiyuan: Taiyuan University of Technology (in Chinese with English abstract).

- Tanyaş, H., VanWesten, C.J., Allstadt, K.E., et al., 2017. Presentation and Analysis of a Worldwide Database of Earthquake-Induced Landslide Inventories. *Journal of Geophysical Research: Earth Surface*, 122 (10), 1991-2015. doi: 10.1002/2017JF004245
- Vincent, P., Larochelle, H., Lajoie, I., et al., 2010. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. *Journal of Machine Learning Research (J Mach Learn Res)*, 11 (12), 3371-3408.
- Wang, Y., Fang, Z., Hong, H., 2019. Comparison of Convolutional Neural Networks for Landslide Susceptibility Mapping in Yanshan County, China. *Science of the Total Environment*, 666, 975-993. doi: 10.1016/j.scitotenv.2019.02.263
- Xiong, J., Sun, M., Zhang, H., et al., 2019. Application of the Levenburg–Marquardt Back Propagation Neural Network Approach for Landslide Risk Assessments. *Natural Hazards and Earth System Sciences*, 19 (3), 629-653. doi: 10.5194/nhess-19-629-2019
- Xu, C., Xu, X.W., Yu, G.H., Wu, X.Y., et al., 2012. Sensitivity Analysis of Influencing Factors of Yushu Earthquake-induced Landslides. *Science & Technology Review*, 30 (01), 18-24 (in Chinese with English abstract).
- Xu, K., Guo, Q., Li, Z., et al., 2015. Landslide Susceptibility Evaluation Based on BPNN and GIS: A Case of Guojiaba in the Three Gorges Reservoir Area. *International Journal of Geographical Information Science*, 2015, 29 (7): 1111-1124. doi: 10.1080/13658816.2015.1011681
- Yeon, Y.K., Han, J.G., Ryu, K. H., 2010. Landslide Susceptibility Mapping in Injae, Korea, Using a Decision Tree. *Engineering Geology*, 116 (3-4), 274-283. doi: 10.1016/j.enggeo.2010.09.009
- Yin, K.L., 1986. Several Issues on Landslide Prediction. *Geological Science and Technology Information*, (02), 50-58 (in Chinese with English abstract).
- Yin, K.L., Yan, T.Z., 1987. Regional Landslide Patterns and Slope Instability Prediction in Xunyang Section of the Hanjiang River Valley. *Earth Science*, (06), 631-638 (in Chinese with English abstract).
- Zhao, B.B., Ge, Y.F., Chen, H.Z., 2021. Landslide Susceptibility Assessment for a Transmission Line in Gansu Province, China by Using a Hybrid Approach of Fractal Theory, Information Value, and Random Forest Models. *Environmental Earth Sciences*, 2021, 80 (12): 1-23. doi: 10.1007/s12665-021-09859-9
- Zeng, Z.P., Fu, X.L., Liu, X.M., et al., 2006. Quantitative Research on Landslide Slope Type and Mapping Supported by GIS. *Geography and Geo-Information Science*, 22(1): 22-25+30 (in Chinese with English abstract).

附中文参考文献

- 白世彪, 阎国年, 盛业华, 杨一鹏, 2005. 基于 GIS 的长江三峡库区滑坡致灾因子分析. *山地学报*, (01), 63-70.
- 黄发明, 陈彬, 毛达雄, 等. 2023 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*, 48(05): 1696-1710
- 刘汉香, 许强, 侯红娟, 2013. 岩性及岩体结构对斜坡地震加速度响应的影响. *岩土力学*, 34 (09), 2482-2488.
- 苏钰桐, 杨炜毅, 李俊霖, 2021. 基于 YOLOv3 的煤岩钻孔图像裂隙智能识别方法. *煤矿安全*, 52 (04), 156-161.

- 唐晓娜, 2019. 基于卷积神经网络和综合指数模型的吕梁市滑坡灾害易发性评价 (硕士学位论文). 太原: 太原理工大学.
- 许冲, 徐锡伟, 于贵华, 吴熙彦, 2012. 玉树地震滑坡致灾因子敏感性分析. 科技导报, 30 (01), 18-24.
- 殷坤龙, 1986. 滑坡预测的若干问题. 地质科技情报, (02), 50-58.
- 殷坤龙, 晏同珍, 1987. 汉江河谷旬阳段区域滑坡规律及斜坡不稳定性预测. 地球科学, (06), 631-638.
- 曾忠平, 付小林, 刘雪梅, 等, 2006. GIS 支持下滑坡斜坡类型定量化及制图研究. 地理与地理信息科学, 22 (1): 22-25+30.