

引文格式:徐胜华,马钰,刘纪平,等.多尺度特征学习的轻量化滑坡易发性评价方法[J].武汉大学学报(信息科学版),2025,50(6):1175-1190.DOI:10.13203/j.whugis20240301



Citation: XU Shenghua, MA Yu, LIU Jiping, et al. A Lightweight Network Based on Multi-scale Feature Learning for Landslide Susceptibility Assessment[J]. Geomatics and Information Science of Wuhan University, 2025, 50(6): 1175-1190. DOI: 10.13203/j.whugis20240301

# 多尺度特征学习的轻量化滑坡易发性评价方法

徐胜华<sup>1</sup> 马钰<sup>2,3</sup> 刘纪平<sup>1</sup> 王琢璐<sup>3</sup>

<sup>1</sup> 中国测绘科学研究院,北京,100830

<sup>2</sup> 中国地质大学(武汉)计算机学院,湖北 武汉,430078

<sup>3</sup> 辽宁工程技术大学测绘与地理科学学院,辽宁 阜新,123000

**摘要:**现有面向滑坡易发性评价的深度学习网络在不同层次的网络结构中往往仅利用单一尺度特征信息,且模型复杂造成较大的参数量和计算复杂度。提出了多尺度特征学习的轻量化滑坡易发性评价方法,利用深度特征增强模块(deep feature enhancement module, DFEM)和多尺度特征融合模块(multi-scale feature fusion module, MSFF)建立多尺度特征学习的轻量化网络,挖掘滑坡易发性与评价因子之间的深层次关联关系。引入通道增强的注意力机制和深度可分离卷积构建DFEM,动态学习不同通道特征的关注度,增强模型对重要特征的感知和利用能力;将传统卷积优化为深度可分离卷积,减少参数量和计算量,实现模型轻量化。采用空洞空间金字塔池化策略优化设计MSFF,对编码部分下采样提取的特征进行多尺度融合,在融合后的深层特征上进行信息交互,同时自适应地调整特征权重,更好地捕捉滑坡区域的全局和局部空间特征,以弥补下采样带来的特征损失。以陕西省安康市为研究区开展滑坡易发性分析,与多种经典模型对比,从模型精度和性能轻量化两个角度进行分析。结果表明,所提方法能有效降低模型训练成本,提高滑坡易发性预测的精度,易发性分区效果更好。

**关键词:**滑坡;易发性;轻量化;注意力;多尺度特征学习

中图分类号:P208

文献标识码:A

收稿日期:2024-11-20

DOI:10.13203/j.whugis20240301

文章编号:1671-8860(2025)06-1175-16

## A Lightweight Network Based on Multi-scale Feature Learning for Landslide Susceptibility Assessment

XU Shenghua<sup>1</sup> MA Yu<sup>2,3</sup> LIU Jiping<sup>1</sup> WANG Zhuolu<sup>3</sup>

<sup>1</sup> Chinese Academy of Surveying and Mapping, Beijing 100830, China

<sup>2</sup> School of Computer Science, China University of Geosciences (Wuhan), Wuhan 430078, China

<sup>3</sup> School of Geomatics, Liaoning Technical University, Fuxin 123000, China

**Abstract: Objectives:** Landslide susceptibility assessment can provide scientific basis and technical support for disaster prevention and mitigation. Additionally, factors such as engineering projects, land use, and heavy rainfall contribute to the frequent occurrence of landslides. In response to the challenges of inaccurate landslide prediction caused by using single-scale feature extraction in different levels of network structures, and the high resource demands and computational costs due to model complexity, a lightweight network based on multi-scale feature learning (MFL-LN) for landslide susceptibility assessment is proposed. **Methods:** Combining the geological environment characteristics of landslide development, the Spearman correlation analysis was conducted on evaluation factors. This analysis led to the identification of 13 evaluation factors across four categories, including human activity factors, hydrological factors, topographical factors and vegetation factor. These factors were used to establish a landslide susceptibility evalua-

基金项目:国家重点研发计划(2022YFC3005705)。

第一作者:徐胜华,博士,研究员,主要研究方向为应急地理信息服务、时空数据地学分析、个性化位置智能推荐服务。xushh@casm.ac.cn

通信作者:马钰,博士生。974829885@qq.com

tion factor system. The MFL-LN method employed the deep feature enhancement module (DFEM) to construct the network architecture, reducing the number of parameters and computational load to achieve model lightweighting. Additionally, it dynamically adjusted the attention to different channel features, enhancing the ability to perceive and utilize important features. Subsequently, the multi-scale feature fusion module (MSFF) was employed to integrate the features extracted through down-sampling in the encoding phase, enabling information interaction on the fused deep features and adaptively adjusting the feature weights. It can effectively capture both global and local spatial characteristics of landslides and compensate for the feature extraction loss caused by down-sampling, thereby improving the predictive capability for landslide susceptibility. **Results:** An ablation study was conducted on the MFL-LN method, and it was compared with the five traditional models. The accuracy of the susceptibility evaluation models was analyzed from three perspectives: landslide susceptibility zoning maps, landslide hazard point density zoning statistics, and evaluation model accuracy. The hazard point density for very low and very high susceptibility areas in the MFL-LN model was 0.009 and 0.557, respectively, ensuring that the hazard point density is lower in very low susceptibility areas and highest in very high susceptibility areas. Additionally, the area under the receiver operating characteristic curve was the highest at 0.837. The proposed model was analyzed for lightweight optimization based on parameter count and floating-point operations. The parameter count of the MFL-LN model was 0.081, and the floating-point operation count was 41.102. It effectively reduced the model training costs and improved the accuracy of landslide susceptibility zoning. **Conclusions:** By selecting Ankang City in Shaanxi Province as the study area and analyzing the historical landslide hazard data, the MFL-LN model was constructed utilizing the DFEM and MSFF with an encoder-decoder structure to evaluate landslide susceptibility. It improved computational efficiency while maintaining the performance of model, making the landslide prediction model more efficient and practical.

**Key words:** landslide; susceptibility; lightweighting; attention; multi-scale feature learning

滑坡是中国最常见的地质灾害之一,受多种环境因素影响,具有突发性、高危害性和频发性等特点。频繁的人类工程活动严重影响了自然气候和地质环境,加剧滑坡发生的频率和破坏程度。国家统计局发布的《中国统计年鉴2023》地质灾害统计数据显示,全国共发生地质灾害5 659起,其中滑坡3 919起,占地质灾害总数的63.95%。开展滑坡易发性分析研究对于滑坡灾害预警、资源规划和灾后重建具有重要的现实意义<sup>[1]</sup>。

根据驱动模式不同,滑坡易发性评价方法可分为经验驱动模型和数据驱动模型两类。经验驱动模型通过对地质、地貌、水文等因素的分析和评价,基于专家知识和滑坡演化过程与物理机制构建规则系统来获取滑坡发生概率。经验驱动模型主要有层次分析法<sup>[2]</sup>、专家打分法<sup>[3]</sup>、模糊逻辑法<sup>[4-5]</sup>等,这类方法原理较简单且易于实现和理解,对数据和计算资源要求不高,适用于数据不完备情况下滑坡易发性预测。经验驱动模型存在主观性和不确定性,无法挖掘数据之间的复杂关系,往往导致模型预测精度不高,评价结果缺乏足够的可靠性和稳定性。数据驱动模型则

利用统计分析、传统机器学习、深度学习等方法,从大量数据中分析挖掘滑坡特征和规律,构建预测模型实现滑坡易发性评价。其中,统计分析方法主要包括证据权法<sup>[6]</sup>、信息量法<sup>[7]</sup>、确定性系数法<sup>[8]</sup>、频率比<sup>[9]</sup>等;传统机器学习方法主要有逻辑回归<sup>[10-12]</sup>、随机森林<sup>[13-16]</sup>、决策树<sup>[17-18]</sup>、支持向量机(support vector machine, SVM)<sup>[19-21]</sup>等;深度学习方法中最典型的是卷积神经网络(convolutional neural network, CNN),其具有局部连接、权值共享、池化操作等特点,在滑坡易发性评价中应用十分广泛<sup>[22-28]</sup>。数据驱动模型往往未充分考虑多源滑坡评价因子的冗余性,没有聚焦重要特征对滑坡的贡献,未顾及复杂网络模型带来的资源需求和成本较高的不利因素。

针对上述问题,本文提出了多尺度特征学习的轻量化滑坡易发性评价方法(lightweight network based on multi-scale feature learning, MFL-LN),设计深度特征增强模块(deep feature enhancement module, DFEM)和多尺度特征融合模块(multi-scale feature fusion module, MSFF),并使用编码-解码结构组建多尺度特征学习的轻量化网络。MFL-LN通过深入挖掘和融合不同尺

度滑坡特征,提高了模型对重要特征的感知和利用能力,减少了网络的参数数量和计算量,并在保持模型性能的同时提高了计算效率,使得滑坡易发性预测模型更高效和实用。

## 1 研究区概况及数据来源

### 1.1 研究区概况

本文研究区安康市位于陕西省东南部,地处  $108^{\circ}00'E \sim 110^{\circ}12'E$ ,  $31^{\circ}42'N \sim 33^{\circ}50'N$ 。总面积约  $23\,500\text{ km}^2$ ,其中山地约占  $92.5\%$ ,丘陵约占  $5.7\%$ ,川道平坝占  $1.8\%$ 。研究区最低海拔  $170\text{ m}$ ,最高海拔  $2\,964.6\text{ m}$ 。安康市地质构造十分复杂,属秦岭和巴山两大地质构造单元,主体为秦岭地槽褶皱带,部分为四川台面斜边圆弧形褶皱带,地层以古生代海相建造为主。属亚热带大陆性季风气候,平均气温介于  $15 \sim 17^{\circ}\text{C}$ ,水量丰沛,多年平均降水量为  $926.2\text{ mm}$ 。水系主要属于长江流域和汉江水系,河网密度为  $1.43\text{ km/km}^2$ ,呈叶脉状排列的独特格局。

### 1.2 数据源

本研究所需的数据包括滑坡点分布数据和评价因子数据。滑坡点分布数据来源于中国科学院资源环境科学数据中心的地质灾害点空间分布数据,评价因子数据来源于中国科学院资源环境科学数据中心的地质灾害点空间分布数据集、中国自 1980 年以来年降水的空间插值数据集及第一次全国地理国情普查成果数据、开放街道地图数据和国家地震科学数据中心全国活动断层矢量数据,主要数据来源和类型见表 1。构建评价因子数据集时,以数字高程模型为基准,按照  $30\text{ m} \times 30\text{ m}$  的格网栅格单元对研究区进行划分,共计  $4\,279$  个滑坡灾害单元。顾及滑坡点与非滑坡点之间的距离不小于  $500\text{ m}$ 、非滑坡点与非滑坡点之间的距离不小于  $500\text{ m}$  距离约束条件,在研究区内随机选择与滑坡灾害单元数目一致的非滑坡灾害单元。从由滑坡灾害单元和非滑坡灾害单元共同组成的样本数据集中随机选择  $70\%$  作为训练集,剩下  $30\%$  作为测试集,每个数据集包含滑坡决策属性(即是否滑坡)和特征属性(即各项评价因子值)。

表 1 数据来源和类型

Table 1 Data Sources and Data Types

数据	来源	类型
地质灾害点	中国科学院资源环境科学数据中心资源环境科学数据平台地质灾害点空间分布数据集	矢量
植被指数	中国科学院资源环境科学数据中心资源环境科学数据平台中国植被指数遥感反演数据集	栅格
降雨量	中国科学院资源环境科学数据中心资源环境科学数据平台中国自 1980 年以来年降水的空间插值数据集	栅格
高程	第一次全国地理国情普查成果数据	栅格
距居民点距离	第一次全国地理国情普查成果数据	矢量
距道路距离	开放街道地图数据	矢量
距河流距离	开放街道地图数据	矢量
距断裂带距离	国家地震科学数据中心全国活动断层矢量数据	矢量

### 1.3 评价因子处理

滑坡的影响因素较多,评价因子选取对易发性评价结果至关重要,本文结合研究区的地理环境背景分析,从地形地貌、植被、水文、人类活动因素 4 个方面选取 13 个评价因子。考虑安康市三山夹两川的特殊地形及其多样地貌特点,选取高程、坡度、坡向、地貌、平面曲率、坡度变率、剖面曲率、坡向变率为评价因子;考虑植被能提高土体的渗透性、根系对土体的加固效应,选取植被指数为评价因子;考虑水文条件对滑坡体滑动起到润滑剂的作用,选取年降雨量、距河流距离为评价因子;考虑频繁的人类活动易破坏斜坡稳定条件而诱发滑坡,选取距道路距离、距居民点

距离为评价因子,如图 1 所示。

由于评价因子的量纲不同,需将数据归一化到  $[0,1]$ 。滑坡灾害的发生受多种评价因子的综合影响,而这些因子之间可能存在共线性问题。如果利用共线性强的因子构建滑坡易发性评价模型,会导致模型数据冗余,不仅增加了计算量,还会影响模型预测精度。斯皮尔曼(Spearman)等级相关系数是衡量两个变量的相关性的非参数指标,被定义为等级变量之间的皮尔逊相关系数,利用单调函数评价两个统计变量的相关性。将每个评价因子按升序排序并为每个对应值分配秩次,计算两个评价因子的每个观测值的秩差的平方和,从而计算相关系数,计算式为:

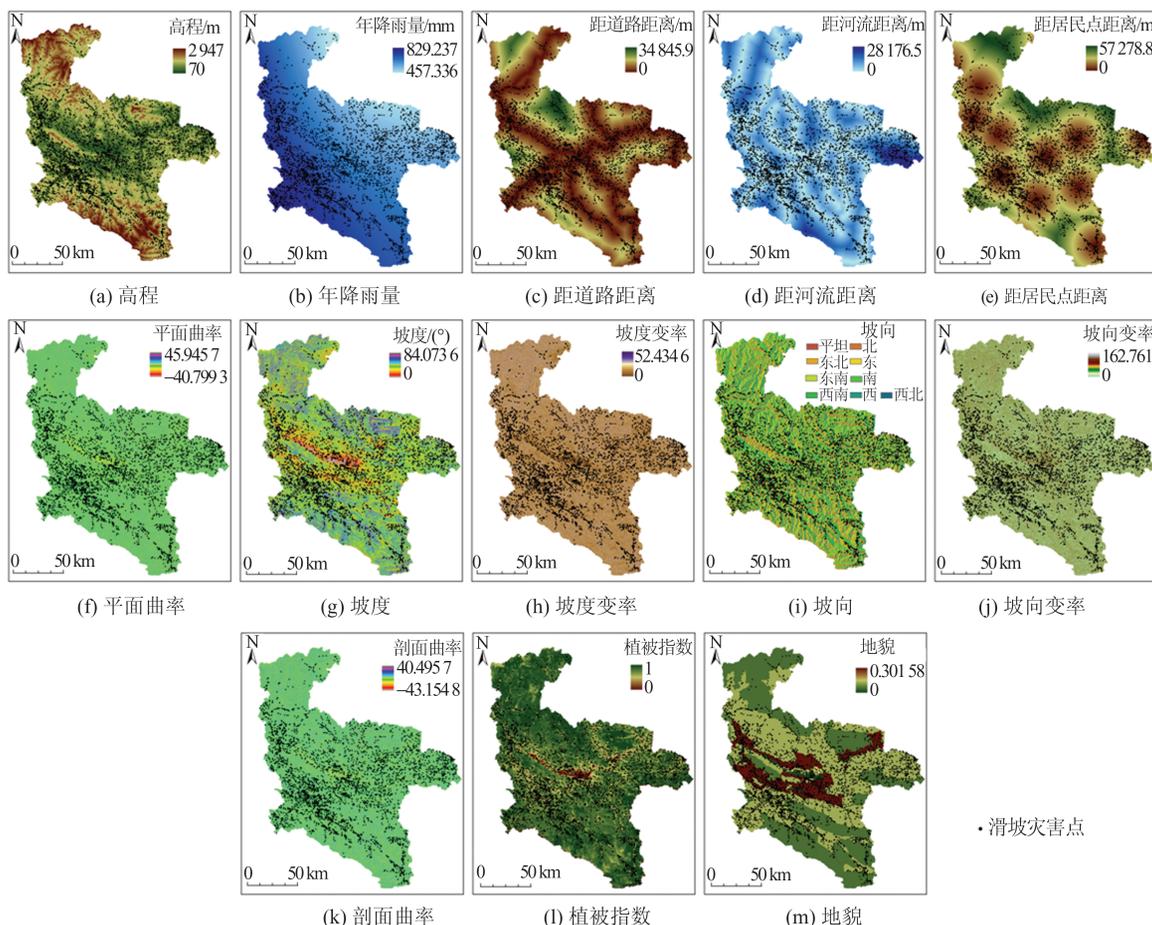


图1 滑坡评价因子

Fig. 1 Landslide Evaluation Factors

$$\rho = 1 - (6 \sum_{i=1}^n d_i^2) / (N^3 - N) \quad (1)$$

式中,  $d_i$  为两个评价因子的第  $i$  个观测值的秩次差,  $i=1, 2, \dots, n$ ;  $N$  为评价因子的个数; Spearman 等级相关系数的取值范围通常为  $-1 \sim 1$ 。当相关系数  $\rho > 0$  时, 评价因子呈正相关; 当  $\rho < 0$  时, 呈负相关; 当  $\rho = 0$  时, 则无线性关系。

13 个评价因子的 Spearman 等级相关性系数如图 2 所示, 评价因子间相关性较低, 可以保留全部评价因子进行滑坡易发性评价模型的训练和预测。

## 2 研究方法

### 2.1 总体研究流程

本文以陕西省安康市为研究区, 利用深度可分离卷积 (depthwise separable convolution, DSC)、通道增强的注意力机制和空洞空间金字塔池化 (atrous spatial pyramid pooling, ASPP) 策略, 构建 DFEM 和 MSFF 实现多尺度特征学习, 以挖

掘滑坡易发性与评价因子之间的深层次关联关系, 多尺度特征学习的轻量化滑坡易发性评价方法总体研究流程如图 3 所示。

1) 评价因子选择。从地形地貌、植被、水文以及人类活动因素 4 个方面选取 13 个评价因子, 对所有不同量纲的评价因子进行归一化处理, 统一量纲, 采用 Spearman 等级相关系数法确保选取的特征不存在冗余。

2) 样本数据集构建。采用距离约束方法选取与滑坡灾害点等数量的非滑坡点构建样本数据集。以样本点作为标注像元, 空间邻域大小为  $9 \times 9$ , 通道数为评价因子数量的数据块作为输入, 以高程因子为底图, 将其他 12 个评价因子重采样到底图上, 以保证各评价因子数据遵循严格的一致性<sup>[29]</sup>, 并赋予每个样本数据集滑坡决策属性。

3) MFL-LN 模型预测。设计 DFEM 和 MSFF 构建 MFL-LN 滑坡易发性评价模型, 融合不同层级的特征实现滑坡易发性预测, MFL-LN 能更好地捕捉滑坡区域的全局和局部空间特征, 同时减少参数量和计算量, 实现了模型的轻量化。

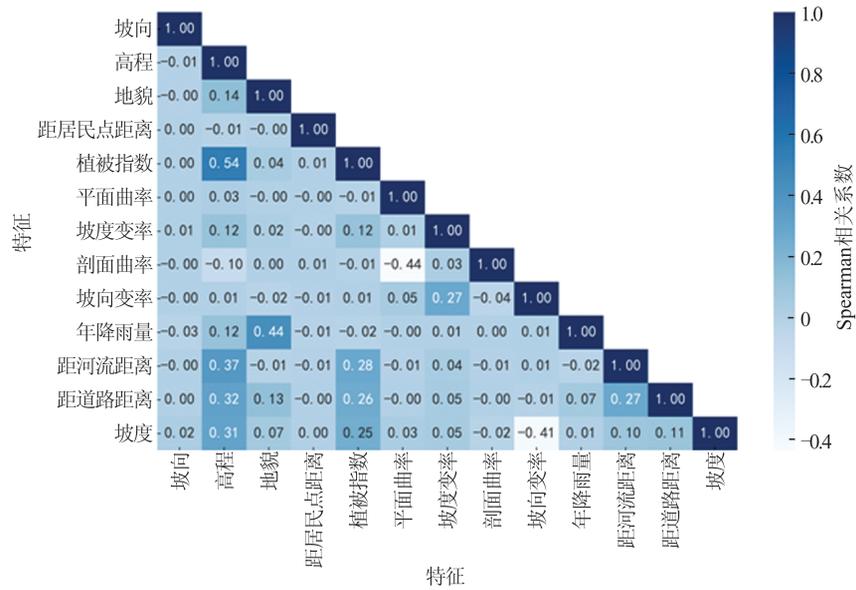


图 2 Spearman 等级相关系数  
Fig. 2 Spearman Rank Correlation Coefficient

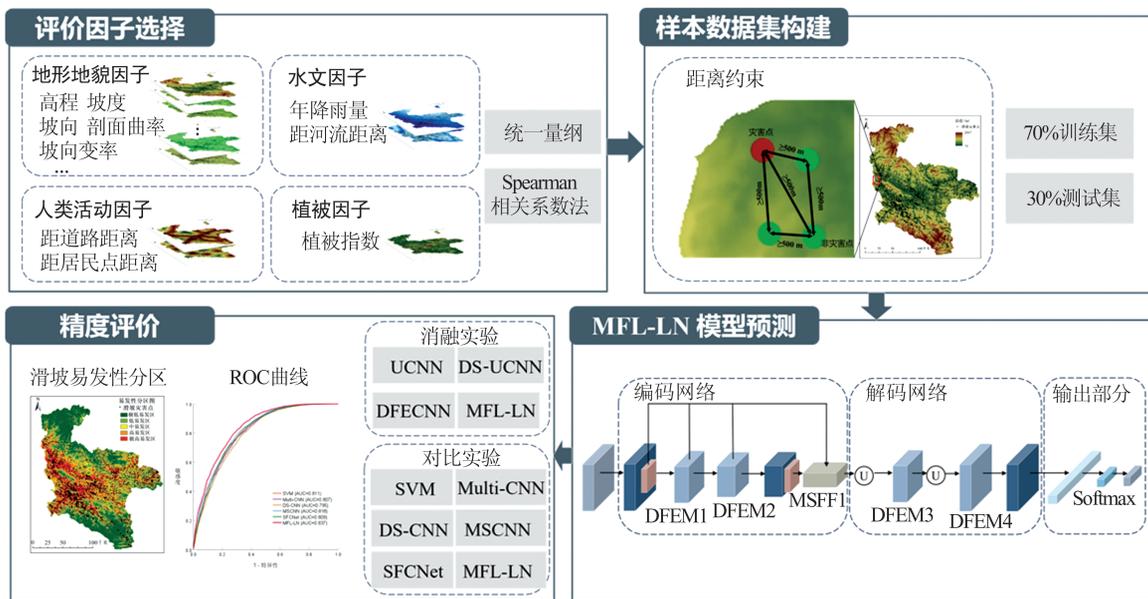


图 3 总体研究流程  
Fig. 3 General Research Flowchart

4)精度评价。从最优空间邻域大小分析、消融实验、易发性评价模型对比分析、模型轻量化分析 4 个方面,结合相关评价指标对滑坡易发性评价模型进行定性和定量分析。

### 2.2 多尺度特征学习的轻量化网络框架

现有方法没有考虑全局特征与局部特征融合及其对滑坡区域的影响差异,且复杂模型结构导致资源需求和计算成本较高。面向滑坡易发性评价,设计 DFEM 和 MSFF,构建多尺度特征学习的轻量化网络,整个网络结构由编码网络、解码网络和输出部分组成,如图 4 所示。

编码网络利用 DFEM 捕获更多的滑坡特征和细节,同时对特征维度进行压缩并提取重要特征信息;利用 MSFF 进行融合不同尺度、不同层次的特征,可以更准确地预测滑坡易发性,提高特征表达能力和网络鲁棒性。

解码网络将编码网络提取的特征表示转换回原始数据空间,通过学习最小化输入数据与重构数据之间的差异,实现数据重构和信息损失补偿,更好地捕捉到滑坡特征的细微差异,在此过程中减少参数数量和计算量,聚焦滑坡重要特征的感知和利用。

输出部分将重构后维度为 $13 \times 9 \times 9$ 的特征输入到全连接层,输入神经元数量为1 053,输出神经元数量为2,按照0.5的概率随机丢弃神经

元,防止评价模型过拟合。最后进行Softmax分类,输出归一化后的一维向量,即滑坡发生的概率值。

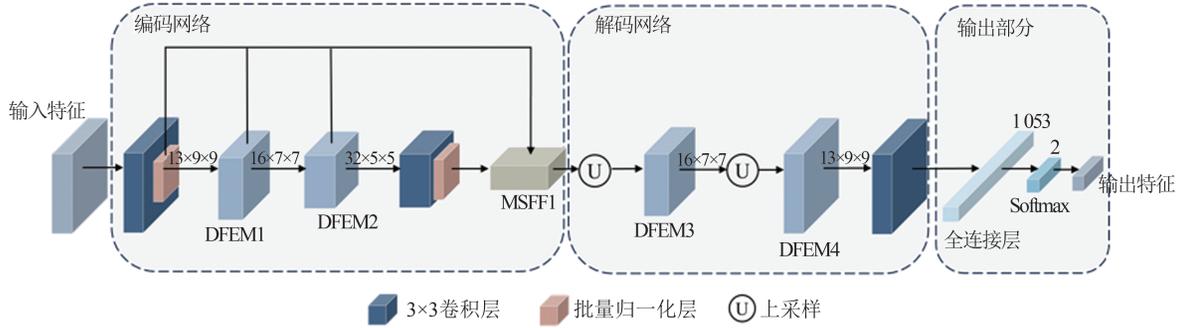


图4 MFL-LN网络结构

Fig. 4 MFL-LN Network Structure

### 2.3 深度特征增强模块

以CNN为基础构建基于深度学习网络的滑坡评价模型时,往往通过增加卷积层数来提高模型预测精度,导致模型越来越复杂,模型训练和预测成本也越来越高。利用DSC构建的轻量级卷积神经网络可以在不降低模型精度的同时减少参数量<sup>[30]</sup>。DSC结构如图5所示,主要包括深度卷积和 $1 \times 1$ 逐点卷积。其中深度卷积将标准卷积在每个输入通道上单独执行,以捕获每个通道上的空间特征;逐点卷积则是对深度卷积后的通道特征通过 $1 \times 1$ 逐点卷积进行线性组合操作,以实现轻量化的效果<sup>[31]</sup>。

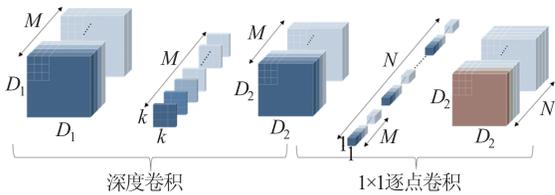


图5 深度可分离卷积

Fig. 5 Depthwise Separable Convolution

假设输入特征维度为 $D_1 \times D_1 \times M$ ,深度卷积的卷积核大小为 $k \times k \times M$ ,通过深度卷积对每个通道单独执行,得到的特征维度为 $D_2 \times D_2 \times M$ ,再对该特征进行逐点卷积,卷积核大小为 $1 \times 1 \times M$ ,卷积核个数为 $N$ ,通过 $1 \times 1$ 逐点卷积后得到的输出特征维度则为 $D_2 \times D_2 \times N$ 。传统卷积参数量 $P_{\text{Norm}}$ 、浮点运算量 $F_{\text{Norm}}$ 、DSC参数量 $P_{\text{DSC}}$ 、浮点运算量 $F_{\text{DSC}}$ 的计算式分别为:

$$P_{\text{Norm}} = k \times k \times M \times N \quad (2)$$

$$F_{\text{Norm}} = D_2 \times D_2 \times k \times k \times M \times N \quad (3)$$

$$P_{\text{DSC}} = k \times k \times M + M \times N \quad (4)$$

$$F_{\text{DSC}} = D_2 \times D_2 \times k \times k \times M + M \times N \times D_2 \times D_2 \quad (5)$$

DSC与传统卷积的参数量和浮点运算量的比值分别为:

$$\frac{P_{\text{DSC}}}{P_{\text{Norm}}} = \frac{k \times k \times M + M \times N}{k \times k \times M \times N} = \frac{1}{N} + \frac{1}{k^2} \quad (6)$$

$$\frac{F_{\text{DSC}}}{F_{\text{Norm}}} = \frac{D_2 \times D_2 \times k \times k \times M + M \times N \times D_2 \times D_2}{D_2 \times D_2 \times k \times k \times M \times N} = \frac{1}{N} + \frac{1}{k^2} \quad (7)$$

由式(6)、式(7)可知,当卷积核个数增加或者卷积核尺寸较大时,DSC相比于传统卷积可有效减少参数量和浮点运算量,从而起到了模型轻量化的作用。

不同滑坡评价因子对滑坡的影响程度不同,现有方法大多未能区分不同评价因子的重要性及重点关注重要评价因子对滑坡易发性的贡献,通过引入通道增强的注意力机制<sup>[32]</sup>,设计改进DSC的DFEM模块来动态学习滑坡评价因子致灾程度,赋予不同的权重,增强模型对重要评价因子的感知和利用。DFEM模块结构如图6所示。

对输入特征进行深度卷积和批量归一化(batch normalization, BN)操作得到特征 $X_2$ ,分别进行全局平均池化和全局最大池化,得到最大池化特征和平均池化特征;对特征信息进行聚合,将两个池化特征输入共享网络中进行权重共享,对输出的两个特征向量进行合并,采用Sigmoid函数激活并与 $X_2$ 相乘得到 $X_3$ ;结合原特征和对不同通道的增强特征 $X_1$ 进行合并,特征图依次执行ReLU、逐点卷积、BN、ReLU,实现深度特征增强。

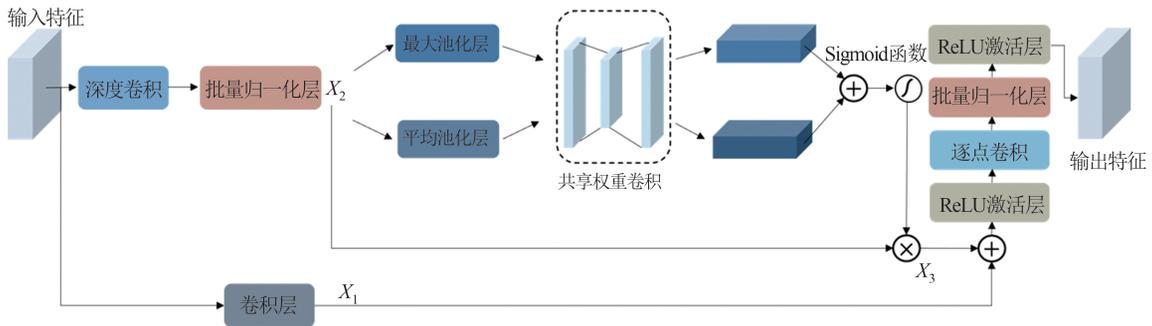


图6 深度特征增强模块

Fig. 6 Depth Feature Enhancement Module

2.4 多尺度特征融合模块

由于不同评价因子包含丰富而复杂的信息，基于编码解码网络结构的滑坡易发性评价模型仅通过单一尺度提取特征信息导致滑坡特征挖掘不够、易发性预测不准确。ASPP能够对不同采样率下的特征并行执行空洞卷积操作挖掘多尺度上下文信息，提升模型对多尺度特征的感知能力<sup>[33]</sup>；可变形卷积具有灵活调整卷积核的位置和形状，自动学习复杂特征交互的优势<sup>[34]</sup>；自注

意力机制将融合的深层次特征信息映射为查询(Query)矩阵、键(Key)矩阵和值(Value)矩阵，通过自适应调整特征权重，有效减少冗余信息干扰<sup>[35]</sup>。基于ASPP策略并结合可变形卷积和自注意力机制优化设计MSFF，可深入挖掘评价因子的深层次特征信息以降低下采样造成的特征损失，并通过编码部分下采样提取的深层特征进行多尺度信息融合来提升模型预测准确性。自注意力结构如图7所示。

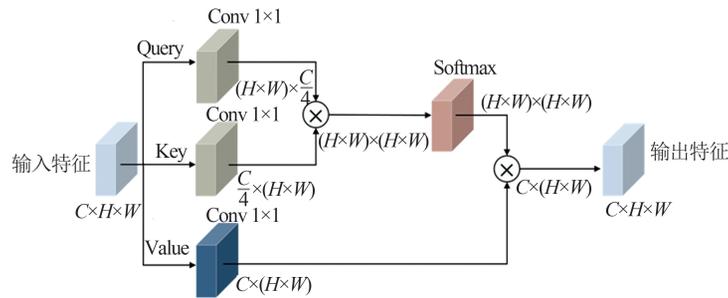


图7 自注意力机制

Fig. 7 Self-Attention Mechanism

MSFF在融合多尺度信息时具有明显的优势，一方面，通过使用不同的卷积核和空洞率对特征进行提取，不同的感受野能够获取多尺度信息，提高模型捕获空间特征能力；另一方面，从编码网络各层次提取的不同维度特征作为后续输入特征进行融合，编码后的深层特征具有较高的稳定性和局部容错性，输入的浅层特征虽然泛化能力不高，但能详细描述特征信息，深层和浅层特征融合能充分利用评价因子信息，对融合后的深层特征进行信息交互，同时自适应地调整特征权重，使得学习特征更加全面和丰富，更好地捕捉到滑坡区域的全局和局部空间特征信息，弥补编码部分下采样带来的特征损失。MSFF结构见图8。

在编码网络中，首先不同尺度输入特征进行

融合，对提取的特征进行拼接和卷积操作，得到同维度大小的特征 $X_i$ ；然后，对特征进行可变形卷积处理，并进行BN、ReLU激活、自注意力模块和卷积操作，更好地挖掘空间特征信息；最后，通过合并操作得到融合原特征和多尺度特征的输出特征。

2.5 评价指标

易发性评价模型的输入是由滑坡评价因子的标注像元及其对应空间邻域内的所有像元所组成的三维数据块，空间邻域范围决定了模型所接受的特征信息量大小，直接影响滑坡易发性预测精度。为了确定最优空间邻域大小，使用精确度 $P$ 、召回率 $R$ 、总体准确度(overall accuracy, OA)和 $F1$ 值来评价不同空间邻域大小下模型预测结果<sup>[24]</sup>，计算式分别为：

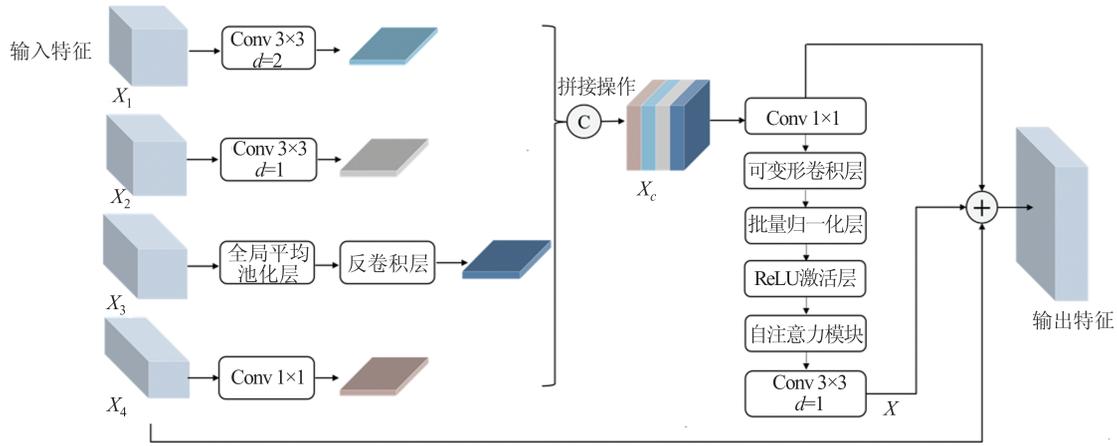


图8 多尺度特征融合模块

Fig. 8 Multi-scale Feature Fusion Module

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (8)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (9)$$

$$OA = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \quad (10)$$

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (11)$$

式中, TP(true positive)为真正例,  $N_{TP}$ 为滑坡样本被正确分类为滑坡样本的数量; TN(true negative)为真负例,  $N_{TN}$ 为非滑坡样本被正确分类为非滑坡样本的数量; FP(false positive)为假正例,  $N_{FP}$ 为滑坡样本被错误分类为非滑坡样本的数量; FN(false negative)为假负例,  $N_{FN}$ 为非滑坡样本但被错误分类为滑坡样本的数量。

消融实验和易发性评价模型对比分析中模型精度主要从滑坡易发性分区图、滑坡灾害点密度分区统计及评价模型精度3个方面进行评价, 滑坡易发性分区图是利用自然间断法将滑坡易发性分区分为极低、低、中、高和极高易发区。滑坡灾害点密度分区统计是计算不同易发性分区内滑坡灾害点数, 进而得到滑坡灾害点密度<sup>[36]</sup>; 点占比是统计不同易发性分区的灾害点数量占灾害点总数的百分比; 分区占比是统计不同易发性分区的面积占研究区总面积的百分比; 受试者工作特征(receiver operating characteristic, ROC)曲线简单直观并能准确反映模型特异性和敏感性的关系, 因而采用ROC曲线下面积(area under the curve, AUC)值对滑坡易发性模型进行评价<sup>[37]</sup>。

模型轻量化效果采用网络模型的参数量和浮点运算量两个指标进行评价, 参数量主要关注

网络模型中需要学习的权重和偏置, 其大小直接反映模型空间复杂度。浮点运算量是指在滑坡易发性评价模型训练时所需要执行的浮点运算操作数量, 用于衡量模型的处理能力, 其大小直接反映模型时间复杂度。

### 3 实验分析

以陕西省安康市为研究区开展滑坡易发性分析, 首先, 讨论空间邻域大小, 确定既包含丰富空间信息又合理占用计算成本的输入特征维度; 然后, 通过消融实验验证MFL-LN各个模块的有效性; 最后, 与传统机器学习方法和深度学习方法进行对比实验和对模型轻量化效果进行分析, 验证MFL-LN的准确性和可靠性。

#### 3.1 最优空间邻域大小分析

当空间邻域过小时, 其包含的像元较少, 导致感受野受限, 网络只能学习到小范围内局部特征, 忽视周边的评价因子对滑坡的影响, 造成精度较低。当空间邻域过大时, 往往弱化了小目标的空间特征, 导致精度下降, 同时会造成训练时间过长。为了选择合适的空间邻域大小, 选取4种不同空间邻域大小输入特征进行网络训练和分析, 结果如表2所示。从表2中可以看出, 立方体数据块最优空间邻域大小为 $9 \times 9$ , 此时模型的 $R$ 、 $OA$ 和 $F1$ 值最高, 虽然 $P$ 较低, 这是因为数据集中的负样本选择具有随机性, 依赖样本空间分布, 模型倾向于将不确定的样本标记为正类。

#### 3.2 消融实验

参考图4, 以本文设计的UCNN(U-connected CNN)为基准模型, 定义如下模型:

表 2 不同空间邻域大小的结果比较

Table 2 Results Comparison of Different Spatial Neighborhood Sizes

尺度	<i>P</i>	<i>R</i>	OA	<i>F1</i>
7×7	0.724 5	0.751 9	0.733 0	0.737 9
9×9	0.724 0	0.815 0	0.752 1	0.766 8
11×11	0.706 2	0.790 9	0.730 9	0.746 2
13×13	0.714 5	0.770 6	0.731 4	0.741 5

1)UCNN:网络仅使用替换 DFEM 的 CNN。

2)DS-UCNN(depthwise separable UCNN):网络结构仅使用 DFEM 中未改进的 DSC 模块,残差结构在逐点卷积后。

3)DFECNN(depth feature enhanced CNN):将 DS-UCNN 中的 DSC 模块修改为 DFEM,聚焦重要特征的感知和利用。

4)MFL-LN:在 DFECNN 中增加 MSFF,对编码网络提取的深层和浅层特征进行多尺度融合。

图 9 展示了不同模型的滑坡易发性分区结果,其中 UCNN 模型仅采用基础的卷积层结构,DS-UCNN 模型在 UCNN 模型的基础上对卷积层进行改进,替换为具有残差结构的 DSC,因此这两种方法在安康市滑坡易发性分区结果上呈现出相似的趋势,但仍存在一些差异。

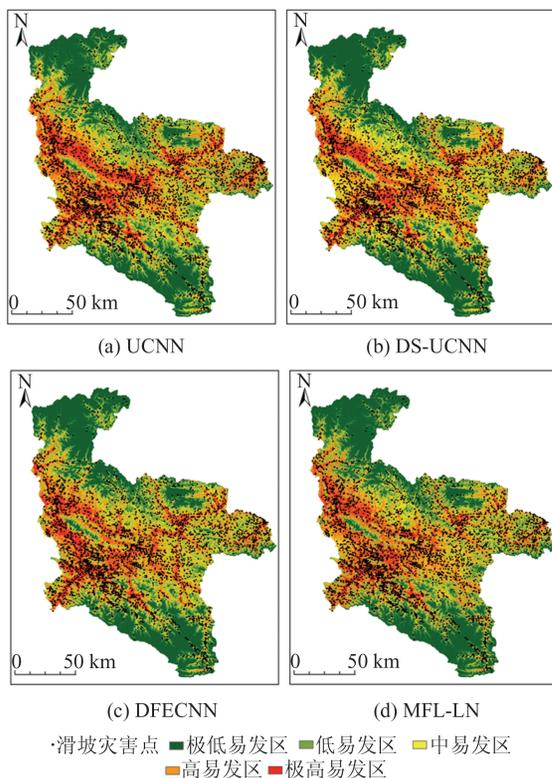


图 9 MFL-LN 不同子模型的滑坡易发性分区  
Fig. 9 Landslide Susceptibility Zones for Various MFL-LN Submodels

由图 9 可以看出,在安康市的中部区域,DS-UCNN 模型较 UCNN 模型能够将部分分区细划为极高易发区、高易发区和中易发区,使得分区结果更加合理,这是因为残差结构能够有效地在保留原始特征的同时学习新的特征,减少信息损失,提高网络表达能力。在安康市的西北部、北部和东南部区域,DS-UCNN 模型仅将部分含有滑坡点区域分为中易发区,DFECNN 模型能够将该区域合理划分为极高易发区、高易发区和中易发区,分区结果更加符合灾害点实际分布情况,这是因为 DFECNN 模型中采用的 DFEM 更加注重对重要特征的感知与表达,从而提高了灾害点所在高易发区识别的准确性。DFECNN 模型通过采用包含 DFEM 的编码解码结构,更加注重局部细节,而 MFL-LN 模型通过增加 MSFF,能够将编码前后的浅层丰富特征与深层局部细节特征相结合,提升预测的准确性。从整体上看,基于 MFL-LN 模型的滑坡易发性分区图中大部分灾害点位于高易发性区域,且滑坡易发性分区更符合安康市实际情况,表现出较好的分区效果。

对滑坡易发性分区进行统计分析,由图 10 和图 11 可以看出,随着灾害易发性等级的提高,各分区滑坡灾害点占比亦逐渐增加,MFL-LN 模型相比于其他子模型,灾害点占比在极低易发区和低易发区均较低,在高易发区和极高易发区均较高,验证了各个模块的有效性。在易发性分区面积占比方面,MFL-LN 模型在极低易发区面积占比最大,在极高易发区面积占比有所减小,但与其他子模型相差不大。在灾害点密度分区统计方面,在极低易发区,UCNN、DS-UCNN、DFECNN 和 MFL-LN 模型的点密度依次为 0.007、0.009、0.007、0.009;在极高易发区,点密度依次为 0.509、0.532、0.528、0.557。其中 DS-UCNN 模型在极高易发区点密度较高,超过 UCNN 模型 0.023,然而在极低易发区也比 UCNN 模型高出 0.002,这表明引入残差结构的 DS-UCNN 模型能够更有效地传递滑坡相关特征信息和模型梯度,从而提升了低、高和极高易发区的点密度。DFECNN 模型能够关注不同滑坡评价因子信息,细划为极低和极高易发区,因此极低和极高易发区点密度略有降低。MFL-LN 模型通过学习不同滑坡特征的重要性,融合局部细节和丰富的特征信息,保证了极低易发区点密度较低,极高易发区点密度最高,分区效果更加精确。

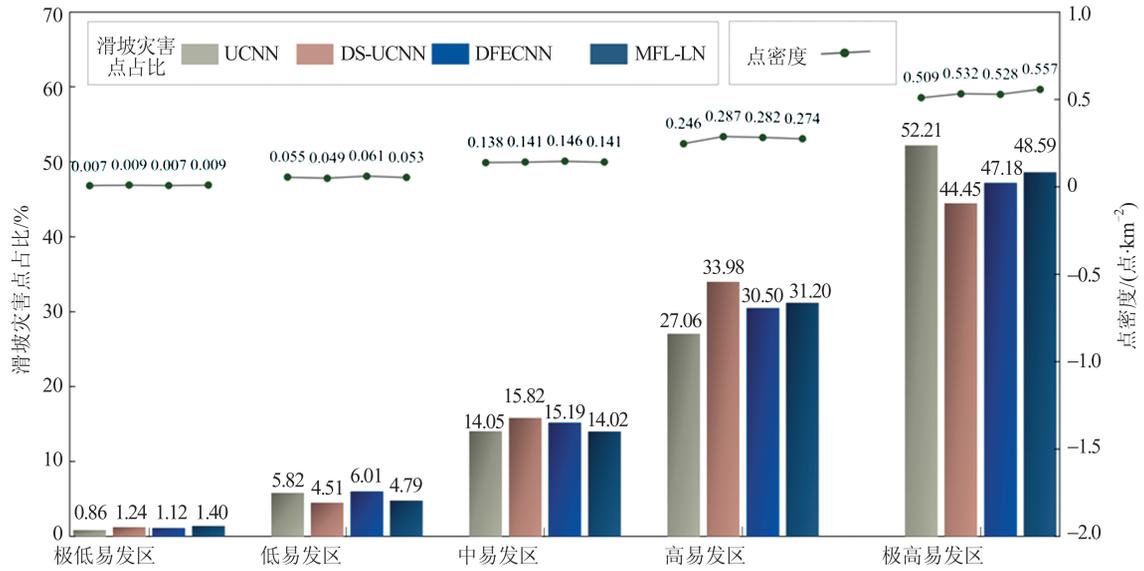


图10 不同子模型滑坡易发性分区点密度统计

Fig. 10 Point Density Statistics of Landslide Susceptibility Zones for Different Submodels

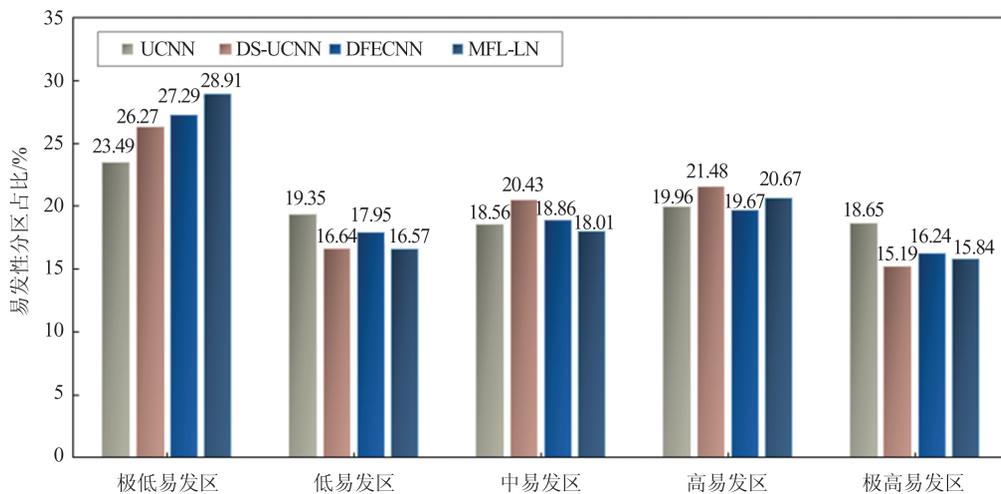


图11 不同子模型滑坡易发性分区占比统计

Fig. 11 Proportion Statistics of Landslide Susceptibility Zones for Different Submodels

UCNN、DS-UCNN、DFECNN 和 MFL-LN 的 ROC 曲线如图 12 所示。由图 12 可以发现,通过增加不同模块,模型的精度在不断提高,MFL-LN 模型的 ROC 曲线上最靠近左上角的点离纵坐标最近,且 AUC 值最大。结合图 9~图 11 可知,MFL-LN 模型能够更好地对安康市进行滑坡易发性分区,进一步验证了其有效性。

### 3.3 易发性评价模型对比分析

采用如下传统机器学习方法和深度学习方法进行对比实验:

1) SVM<sup>[38]</sup>: 以训练误差作为优化问题的约束条件,通过最大化类别间隔的超平面进行分类的监督学习模型。

2) 多维 CNN 耦合方法 (multi-dimensional convolutional neural network coupled, Multi-

CNN)<sup>[39]</sup>: 利用多维卷积核参数共享捕获各滑坡评价因子不同维度及其深层耦合特征,充分利用特征信息,并有效防止过拟合。

3) 深度可分离卷积神经网络 (depthwise separable convolutional neural network, DS-CNN)<sup>[40]</sup>: 采用可分离卷积层,可以在不降低模型精度的同时减少参数量。

4) 多尺度卷积神经网络 (multi-scale convolutional neural network, MSCNN)<sup>[41]</sup>: 融合深层和浅层特征,提升模型分类结果准确性,增强模型泛化能力。

5) 轻量级可分离因式卷积网络<sup>[42]</sup> (light-weight separable factorized convolution network, SFCNet): 采用可分离卷积和因式分解卷积,减少了参数数量和计算复杂度。

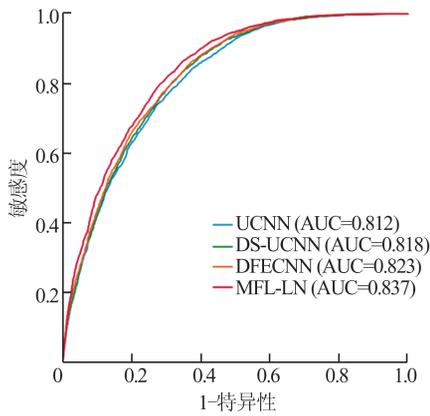


图 12 MFL-LN 不同子模型的 ROC 曲线

Fig. 12 ROC Curves of Different Submodels of MFL-LN

不同模型的滑坡易发性分区如图 13 所示。从整体上看, MFL-LN 方法得到的滑坡易发性分区结果与其他模型的分区趋势大致相似, 符合研究区的实际情况。极高易发区、高易发区主要分布在高山及河流沿线; 中易发区、低易发区围绕高易发区分布, 主要分布在中部河谷盆地; 极低易发区主要集中在坡度较缓的山地。

在安康市西部, SVM 方法将高易发区和中易发区误分为极高易发区, 在西北部则将中易发区和低易发区误分为极低易发区, 这表明 SVM 对数据的挖掘程度不够。Multi-CNN 方法将安康市的山脊线区域均划为极高易发区, 过于依赖地形特征, 忽略了其他滑坡评价因子的影响。在安康市西部和中部, DS-CNN 方法将其划分为极高易发区, 未考虑到高易发区和中易发区的影响, 仅采用 DSC 的网络结构在减小参数数量和计算量上起到了很好的效果, 但对复杂的特征学习和表示不充分。在安康市东北部, MSCNN 方法将高易发区和中易发区误分为极高易发区, 虽然该方法融合了多尺度信息, 但未聚焦重要特征对滑坡易发性的作用。在安康市中部, SFCNet 方法仅将其划分为极高易发区, 与 DS-CNN 方法类似, 可分离卷积和因式分解卷积将模型进行轻量化处理, 但没有对不同层次、不同粒度的特征信息融合。本文方法采用编码解码网络结构, 融合深层和浅层特征, 并加强对重要特征的感知和利用, 提高了网络的鲁棒性和特征表达能力。

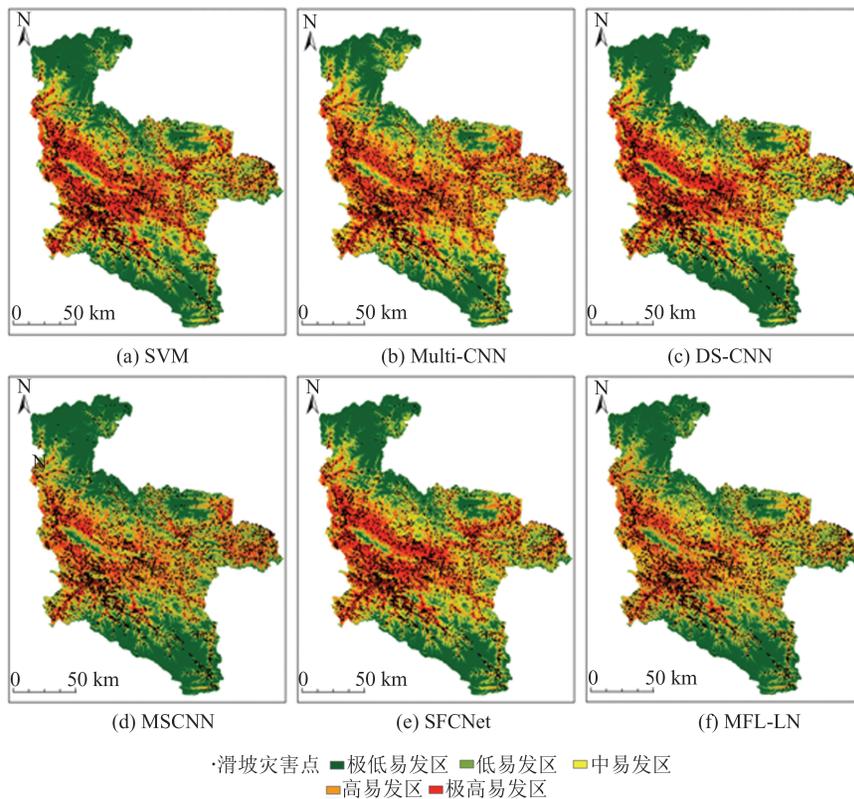


图 13 不同模型的滑坡易发性分区

Fig. 13 Landslide Susceptibility Zones for Different Models

对不同模型的滑坡易发性分区进行统计分析, 如图 14 和图 15 所示。结果显示, 不同方法的灾害点占比与滑坡易发性等级呈正相关, 在

极高易发区均达到最大值, MFL-LN 模型相比于其他模型, 灾害点占比在极低易发区和低易发区处于较低水平, 高易发区灾害点占比最高,

但存在极高易发区灾害点占比最低的情况,这是因为其他模型划分的极高易发区面积较大,造成该区域内的灾害点数量增加,但由于面积划分过大,导致点密度较低。MFL-LN模型在极低易发区面积占比较大,在极高易发区面积占比虽然最低,但其包含了更多的灾害点,评价结果更准确和可靠。与其他5种方法相比,MFL-LN方法在极高易发区灾害点密度最大、极低易发区灾害点密度较小,更符合滑坡易发区灾害点的实际分布情况。MSCNN方法相比本文方法,在中、高易发区点密度分别高0.013和0.002,但在极高易发区比本文方法低0.021,低易发区和极低易发区的点密度分别比本文方法高0.026和0.004,表明MSCNN方法通过融合多层特征对高易发区具有较好的学习和表征能力,但未能聚焦于重要特征,导致无法细化部

分低易发区,因此其分区精度相对较低。Multi-CNN方法在极低易发区和低易发区点密度均低于本文方法,分别低了0.006和0.025,但本文方法在极高易发区和高易发区点密度远高于Multi-CNN方法,分别高了0.115和0.069,安康市滑坡灾害易发区主要位于山脊线、河流走向和河谷盆地,而Multi-CNN方法采用2D-CNN和1D-CNN网络结构,未能动态地学习和调整不同特征的关注度,因此仅将安康市少部分区域划分为低易发区和极低易发区,灾害点在这些区域的分布较少,所以点密度较低。SFCNet方法在极低易发区点密度比本文方法低0.001,SVM方法在低易发区点密度比本文方法低0.004,然而,两种方法未能有效融合滑坡区域的全局和局部空间特征,导致特征挖掘不足,造成在其他等级易发区的精度较低。

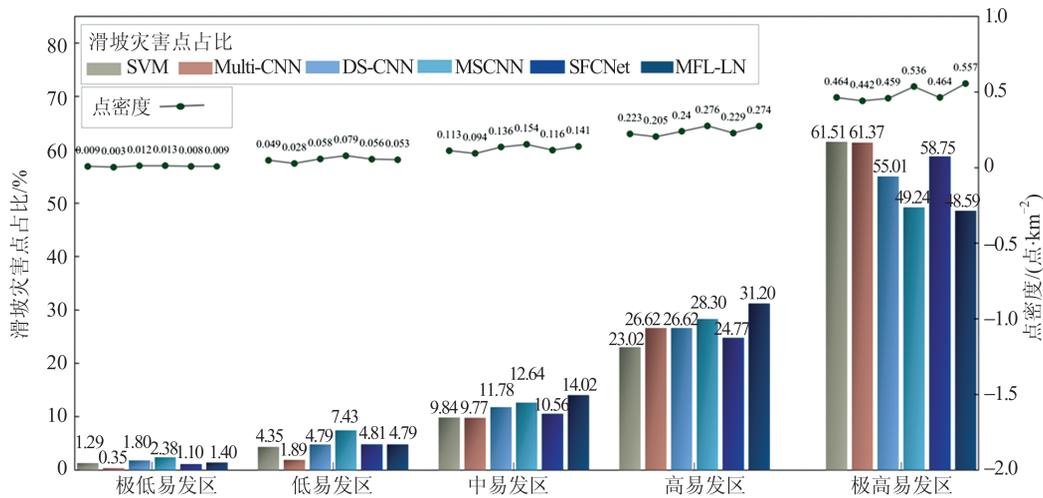


图 14 不同模型滑坡易发性分区点密度统计

Fig. 14 Point Density Statistics of Landslide Susceptibility Zones for Different Models

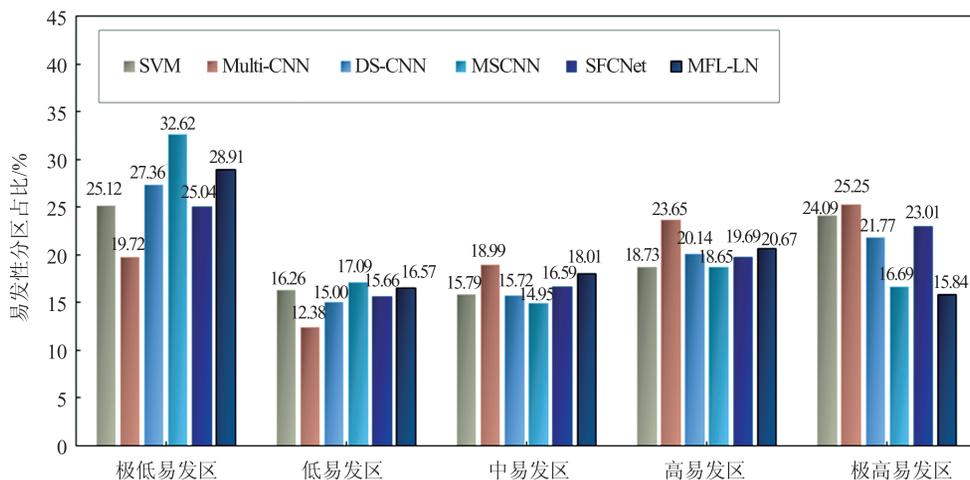


图 15 不同模型滑坡易发性分区占比统计

Fig. 15 Proportion Statistics of Landslide Susceptibility Zones for Different Models

SVM、Multi-CNN、DS-CNN、MSCNN、SFCNet 和 MFL-LN 模型的 ROC 曲线如图 16 所示。DS-CNN 精度最低,其仅使用可分离卷积导致特征表达能力受限,部分重要特征信息丢失。Multi-CNN、SFCNet 和 SVM 精度较低,Multi-CNN 通过特征图非对称聚合连接 2D-CNN 和 1D-CNN,维持网络深度而限制模型参数,减少了计算量,但没有顾及对滑坡影响较大的评价因子的作用;SFCNet 利用可分离卷积和因式分解卷积降低了模型复杂度,但未能有效融合不同层次的滑坡特征;SVM 虽然具有解决非线性高维模式识别问题的优势,但存在特征信息挖掘不够的问题。MSCNN 方法精度相对较高,然而参数过多,计算成本较高。MFL-LN 方法精度最高,其考虑到不同特征对滑坡的影响程度不同,并进行了重要特征增强处理。

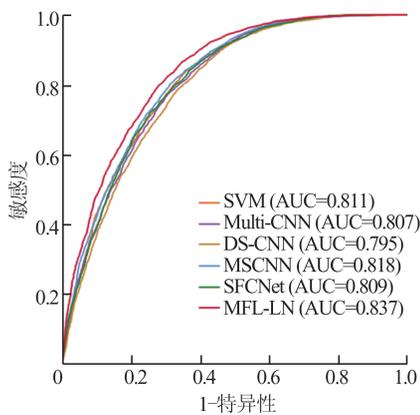


图 16 不同模型的 ROC 曲线

Fig. 16 ROC Curves of Different Models

### 3.4 模型轻量化效果分析

模型轻量化效果分析见表 3。由表 3 可知, MSCNN 方法参数数量和浮点运算量最大,这是因为该模型使用多层卷积层和池化层,同时在进行多尺度特征融合时,使用了大量全连接层,导致了较大的内存消耗;Multi-CNN 方法先采用 2D-CNN,后转换为 1D-CNN 进行特征提取,在保证参数数量不高的同时,大幅度减少了运算量;SFCNet 方法采用可分离卷积和因式分解卷积,将参数数量减小了一个数量级,然而该方法中使用了逐点卷积、可分离卷积和因式分解卷积的拼接操作,因此运算量仍处于较高水平;DS-CNN 方法仅采用 DSC,由于该方法采用 2D 输入数据,与其他对比方法输入不同,因此参数数量和运算量均较小。本文提出的 MFL-LN 方法结合 DFEM 和 MSFF,大幅度降低了模型的参数数量和运算量,使

得该方法达到轻量化水平,从而验证了其有效性。

表 3 模型轻量化效果分析/MB

Table 3 Model Lightweighting Analysis/MB

模型	参数量	浮点运算量
Multi-CNN	0.351	32.210
DS-CNN	0.015	1.795
MSCNN	1.521	443.967
SFCNet	0.130	123.853
MFL-LN	0.081	41.102

## 4 结 语

滑坡易发性评价可以为滑坡灾害防治工作提供科学依据,是相关部门开展滑坡防灾减灾应用的基础。本文以陕西省安康市为研究区,采用 Spearman 等级相关系数法对滑坡评价因子冗余性进行分析,基于 DSC 和通道增强的注意力机制构建 DFEM 模块,利用 ASPP 策略构建 MSFF 模块,在此基础上提出多尺度特征学习的轻量化网络,对研究区滑坡易发性进行评价,从滑坡易发性分区图、滑坡灾害点密度分区统计及评价模型精度 3 个方面与 SVM 模型、Multi-CNN 模型、DS-CNN 模型、MSCNN 模型、SFCNet 模型进行了易发性精度对比分析,从参数量和浮点运算量与 Multi-CNN 模型、DS-CNN 模型、MSCNN 模型、SFCNet 模型进行了模型轻量化效果分析。实验结果表明,MFL-LN 模型利用 DFEM 搭建网络架构,具有较低的参数数量和计算复杂度,能够动态地学习不同滑坡评价因子之间的重要性,增强了模型对数据的表征能力;采用 MSFF 将编码后的浅层丰富特征与深层局部细节特征相结合,有效提升了滑坡预测的准确性。由于滑坡是一个长期且复杂的时空演化过程,本文方法没有考虑滑坡的时序预测,后续研究可以基于时间序列数据评估滑坡发生的时间和空间概率分布并提供动态的滑坡易发性信息,以捕捉滑坡易发性的时空动态变化,有效提高预测时效性。

## 参 考 文 献

- [1] 严俊. 滑坡易发性预测建模的不确定性: 滑坡边界及环境因子误差的影响[D]. 南昌: 南昌大学, 2022.  
YAN Jun. Uncertainties in Landslide Susceptibility Prediction Modeling: Influence of Landslide Boundary and Conditioning Factor Error [D].

- Nanchang: Nanchang University, 2022.
- [2] 牛鹏飞. 基于综合指数模型的舟曲县滑坡易发性评价[D]. 石家庄: 河北地质大学, 2021.  
NIU Pengfei. Landslide Susceptibility Evaluation in Zhouqu County Based on Comprehensive Index Model[D]. Shijiazhuang: Hebei GEO University, 2021.
- [3] ZHOU S H, ZHOU S K, TAN X. Nationwide Susceptibility Mapping of Landslides in Kenya Using the Fuzzy Analytic Hierarchy Process Model[J]. *Land*, 2020, 9(12): 535.
- [4] 崔志超, 王俊豪, 崔传峰, 等. 基于层次分析法和模糊数学相结合的甘肃东乡八丹沟泥石流易发性评价[J]. 中国地质灾害与防治学报, 2020, 31(1): 44-50.  
CUI Zhichao, WANG Junhao, CUI Chuanfeng, et al. Evaluation of the Susceptibility of Debris Flow in Badan Gully of Dongxiang County of Gansu Based on AHP and Fuzzy Mathematics[J]. *The Chinese Journal of Geological Hazard and Control*, 2020, 31(1): 44-50.
- [5] 刘福臻, 王灵, 肖东升, 等. 基于模糊综合评判法的宁南县滑坡易发性评价[J]. 自然灾害学报, 2021, 30(5): 237-246.  
LIU Fuzhen, WANG Ling, XIAO Dongsheng, et al. Evaluation of Landslide Susceptibility in Ningnan County Based on Fuzzy Comprehensive Evaluation [J]. *Journal of Natural Disasters*, 2021, 30(5): 237-246.
- [6] 胡燕, 李德营, 孟颂颂, 等. 基于证据权法的巴东县城滑坡灾害易发性评价[J]. 地质科技通报, 2020, 39(3): 187-194.  
HU Yan, LI Deying, MENG Songsong, et al. Landslide Susceptibility Evaluation in Badong County Based on Weights of Evidence Method[J]. *Bulletin of Geological Science and Technology*, 2020, 39(3): 187-194.
- [7] 周晓亭, 黄发明, 吴伟成, 等. 基于耦合信息量法选择负样本的区域滑坡易发性预测[J]. 工程科学与技术, 2022, 54(3): 25-35.  
ZHOU Xiaoting, HUANG Faming, WU Weicheng, et al. Regional Landslide Susceptibility Prediction Based on Negative Sample Selected by Coupling Information Value Method[J]. *Advanced Engineering Sciences*, 2022, 54(3): 25-35.
- [8] WANG Q Q, GUO Y H, LI W P, et al. Predictive Modeling of Landslide Hazards in Wen County, Northwestern China Based on Information Value, Weights-of-Evidence, and Certainty Factor [J]. *Geomatics, Natural Hazards and Risk*, 2019, 10(1): 820-835.
- [9] PANCHAL S, SHRIVASTAVA A K. A Comparative Study of Frequency Ratio, Shannon's Entropy and Analytic Hierarchy Process (AHP) Models for Landslide Susceptibility Assessment[J]. *ISPRS International Journal of Geo-Information*, 2021, 10(9): 603.
- [10] 许嘉慧, 张虹, 文海家, 等. 基于逻辑回归的巫山县滑坡易发性区划研究[J]. 重庆师范大学学报(自然科学版), 2021, 38(2): 48-56.  
XU Jiahui, ZHANG Hong, WEN Haijia, et al. Landslide Susceptibility Mapping Based on Logistic Regression in Wushan County [J]. *Journal of Chongqing Normal University (Natural Science)*, 2021, 38(2): 48-56.
- [11] LIU Y, ZHAO L J, BAO A M, et al. Chinese High Resolution Satellite Data and GIS-Based Assessment of Landslide Susceptibility Along Highway G30 in Guozigou Valley Using Logistic Regression and MaxEnt Model[J]. *Remote Sensing*, 2022, 14(15): 3620.
- [12] 钱紫玲, 王平, 李娜, 等. 基于信息量和逻辑回归耦合模型的黄土地震滑坡危险性分析[J]. 地震工程学报, 2023, 45(3): 706-715.  
QIAN Ziling, WANG Ping, LI Na, et al. Risk Analysis of Loess Seismic Landslides Based on an Information Value-Logistic Regression Coupling Model[J]. *China Earthquake Engineering Journal*, 2023, 45(3): 706-715.
- [13] 刘睿, 施嫻嫻, 孙德亮, 等. 基于GIS与随机森林的巫山县滑坡易发性区划[J]. 重庆师范大学学报(自然科学版), 2020, 37(3): 86-96.  
LIU Rui, SHI Shuxian, SUN Deliang, et al. Based on GIS and Random Forest Model for Landslide Susceptibility Mapping in Wushan County [J]. *Journal of Chongqing Normal University (Natural Science)*, 2020, 37(3): 86-96.
- [14] 吴润泽, 胡旭东, 梅红波, 等. 基于随机森林的滑坡空间易发性评价: 以三峡库区湖北段为例[J]. 地球科学, 2021, 46(1): 321-330.  
WU Runze, HU Xudong, MEI Hongbo, et al. Spatial Susceptibility Assessment of Landslides Based on Random Forest: A Case Study from Hubei Section in the Three Gorges Reservoir Area[J]. *Earth Science*, 2021, 46(1): 321-330.
- [15] KAVZOGLU T, TEKE A. Predictive Performances of Ensemble Machine Learning Algorithms in Landslide Susceptibility Mapping Using Random Forest, Extreme Gradient Boosting (XGBoost) and Natural Gradient Boosting (NGBoost)[J]. *Arabian*

- Journal for Science and Engineering*, 2022, 47(6): 7367-7385.
- [16] 孙德亮, 陈丹璐, 密长林, 等. 基于随机森林-特征递归消除模型的可解释性缓丘岭谷地貌滑坡易发性评价[J]. *地质力学学报*, 2023, 29(2): 202-219.
- SUN Deliang, CHEN Danlu, MI Changlin, et al. Evaluation of Landslide Susceptibility in the Gentle Hill-Valley Areas Based on the Interpretable Random Forest-Recursive Feature Elimination Model [J]. *Journal of Geomechanics*, 2023, 29(2): 202-219.
- [17] FANG Z C, WANG Y, DUAN G H, et al. Landslide Susceptibility Mapping Using Rotation Forest Ensemble Technique with Different Decision Trees in the Three Gorges Reservoir Area, China[J]. *Remote Sensing*, 2021, 13(2): 238.
- [18] ZHAO Q F, CHEN W, PENG C H, et al. Modeling Landslide Susceptibility Using an Evidential Belief Function-Based Multiclass Alternating Decision Tree and Logistic Model Tree [J]. *Environmental Earth Sciences*, 2022, 81(15): 404.
- [19] 郭天颂, 张菊清, 韩煜, 等. 基于粒子群优化支持向量机的延长县滑坡易发性评价[J]. *地质科技情报*, 2019, 38(3): 236-243.
- GUO Tiansong, ZHANG Juqing, HAN Yu, et al. Evaluation of Landslide Susceptibility in Yanchang County Based on Particle Swarm Optimization Support Vector Machine [J]. *Geological Science and Technology Information*, 2019, 38(3): 236-243.
- [20] 徐胜华, 刘纪平, 王想红, 等. 熵指数融入支持向量机的滑坡灾害易发性评价方法: 以陕西省为例[J]. *武汉大学学报(信息科学版)*, 2020, 45(8): 1214-1222.
- XU Shenghua, LIU Jiping, WANG Xianghong, et al. Landslide Susceptibility Assessment Method Incorporating Index of Entropy Based on Support Vector Machine: A Case Study of Shaanxi Province [J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(8): 1214-1222.
- [21] 林荣福. 基于优化支持向量机模型的滑坡易发性评价: 以陕西省商洛市为例[D]. 阜新: 辽宁工程技术大学, 2021.
- LIN Rongfu. Landslide Susceptibility Evaluation Based on Optimized Support Vector Machine Model - Taking Shangluo City of Shaanxi Province as an Example [D]. Fuxin: Liaoning Technical University, 2021.
- [22] 王世宝, 庄建琦, 郑佳, 等. 基于深度学习的CZ铁路康定—理塘段滑坡易发性评价[J]. *工程地质学报*, 2022, 30(3): 908-919.
- WANG Shibao, ZHUANG Jianqi, ZHENG Jia, et al. Landslide Susceptibility Evaluation Based on Deep Learning Along Kangding - Litang Section of CZ Railway [J]. *Journal of Engineering Geology*, 2022, 30(3): 908-919.
- [23] LIU R, YANG X, XU C, et al. Comparative Study of Convolutional Neural Network and Conventional Machine Learning Methods for Landslide Susceptibility Mapping [J]. *Remote Sensing*, 2022, 14(2): 321.
- [24] YI Y N, ZHANG Z J, ZHANG W C, et al. Landslide Susceptibility Mapping Using Multiscale Sampling Strategy and Convolutional Neural Network: A Case Study in Jiuzhaigou Region [J]. *CATENA*, 2020, 195: 104851.
- [25] WANG Z L, XU S H, LIU J P, et al. A Combination of Deep Autoencoder and Multi-scale Residual Network for Landslide Susceptibility Evaluation [J]. *Remote Sensing*, 2023, 15(3): 653.
- [26] LIU T, CHEN T, NIU R Q, et al. Landslide Detection Mapping Employing CNN, ResNet, and DenseNet in the Three Gorges Reservoir, China [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 11417-11428.
- [27] 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.
- [28] 马欣蕊, 徐胜华, 王琢璐, 等. 融合自编码与密集残差网络的滑坡易发性评价[J]. *测绘科学*, 2023, 48(7): 146-154.
- MA Xinrui, XU Shenghua, WANG Zhuolu, et al. A Combination of Autoencoder and Dense Residual Network for Landslide Susceptibility Evaluation [J]. *Science of Surveying and Mapping*, 2023, 48(7): 146-154.
- [29] 蔡超. 基于多源数据与尺度分割的滑坡易发性评价方法研究: 以上犹县为例[D]. 赣州: 江西理工大学, 2021.
- CAI Chao. Landslide Susceptibility Evaluation Method Based on Multi-source Data and Scale Segmentation - The Example of Shangyou Country [D]. Ganzhou: Jiangxi University of Science and Technology, 2021.
- [30] HOWARD A G, ZHU M L, CHEN B, et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications [EB/OL]. [2018-

- 04-17]. <https://arxiv.org/abs/1704.04861>.
- [31] 庞沛东. 基于深度卷积神经网络的高光谱图像分类方法研究[D]. 开封: 河南大学, 2021.
- PANG Peidong. Research on Hyperspectral Image Classification Method Based on Deep Convolution Neural Network [D]. Kaifeng: Henan University, 2021.
- [32] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C]// European Conference on Computer Vision (ECCV), Munich, Germany, 2018.
- [33] CHEN L C, PAPANDEOU G, SCHROFF F, et al. Rethinking Atrous Convolution for Semantic Image Segmentation [EB/OL]. [2023-01-17]. <https://arxiv.org/abs/1706.05587>.
- [34] DAI J F, QI H Z, XIONG Y W, et al. Deformable Convolutional Networks [C]//IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017.
- [35] HAN L T, LV H Y, ZHAO Y C, et al. ConvFormer: A Novel Network Combining Convolution and Self-Attention for Image Quality Assessment [J]. *Sensors*, 2022, 23(1): 427.
- [36] AZARAFZA M, AZARAFZA M, AKGÜN H, et al. Deep Learning-Based Landslide Susceptibility Mapping[J]. *Scientific Reports*, 2021, 11(1): 24112.
- [37] 刘纪平, 梁恩婕, 徐胜华, 等. 顾及样本优化选择的多核支持向量机滑坡灾害易发性分析评价[J]. *测绘学报*, 2022, 51(10): 2034-2045.
- LIU Jiping, LIANG Enjie, XU Shenghua, et al. Multi-kernel Support Vector Machine Considering Sample Optimization Selection for Analysis and Evaluation of Landslide Disaster Susceptibility [J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(10): 2034-2045.
- [38] ZHAO Z, LIU Z Y, XU C. Slope Unit-Based Landslide Susceptibility Mapping Using Certainty Factor, Support Vector Machine, Random Forest, CF-SVM and CF-RF Models [J]. *Frontiers in Earth Science*, 2021, 9: 589630.
- [39] 赵占骛, 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.
- [40] YILMAZ E O, TEKE A, KAVZOGLU T. Performance Evaluation of Depthwise Separable CNN and Random Forest Algorithms for Landslide Susceptibility Prediction [C]//IEEE International Geoscience and Remote Sensing Symposium, Kuala Lumpur, Malaysia, 2022.
- [41] ZHAO Z A, HE Y, YAO S, et al. A Comparative Study of Different Neural Network Models for Landslide Susceptibility Mapping [J]. *Advances in Space Research*, 2022, 70(2): 383-401.
- [42] JANARTHANAN S S, SUBBIAN D, SUBBARAYAN S, et al. SFCNet: Deep Learning-Based Lightweight Separable Factorized Convolution Network for Landslide Detection [J]. *Journal of the Indian Society of Remote Sensing*, 2023, 51(6): 1157-1170.