

陈龙, 葛澄, 戴颖超, 等. 基于深度学习的高分辨率遥感影像滑坡体识别方法研究[J]. 华南地震, 2025, 45(2): 66-74. [CHEN Long, GE Cheng, DAI Yingchao, et al. Research on Landslide Detection in High-Resolution Remote Sensing Image Based on Deep Learning [J]. South China journal of seismology, 2025, 45(2): 66-74]

基于深度学习的高分辨率遥感影像 滑坡体识别方法研究

陈龙¹, 葛澄¹, 戴颖超^{2,3}, 王宏宇⁴, 刘维维²

(1. 成都大数据产业技术研究院有限公司, 成都 610095; 2. 四川天府新区创新装备研究院, 成都 610299; 3. 重庆大学自动化学院, 重庆 400044; 4. 北京理工大学, 北京 100081)

摘要: 针对现有滑坡体检测精度低的现实问题, 提出了一种基于深度学习的滑坡体检测框架。该框架包含数据采集与处理、特征选择、检测模型三个部分, 可融合多源数据有效提高对滑坡体检测能力。提出了多模态的KIAlexNet模型, 可实现像素级分割预测, 有效地融合空间特征。实验结果表明, 所提KIAlexNet模型具备高精度的滑坡体检测能力。与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等方法相比具备优势。实验结果验证了所提方法的有效性和实用性, 该方法具有广阔的应用前景。

关键词: 深度学习; 滑坡检测; 卷积神经网络; 特征提取; 损失函数

中图分类号: TP393

文献标识码: A

文章编号: 1001-8662(2025)02-0066-09

DOI: 10.13512/j.hndz.2025.02.09

Research on Landslide Detection in High-Resolution Remote Sensing Image Based on Deep Learning

CHEN Long¹, GE Cheng¹, DAI Yingchao^{2,3}, WANG Hongyu⁴, LIU Weiwei²

(1. Chengdu Big Data Industry Technology Research Institute Co., Ltd., Chengdu 610095, China; 2. Innovative Equipment Research Institute of Beijing Institute of Technology in Sichuan Tianfu New Area, Chengdu 610299, China; 3. School of Automation, Chongqing University, Chongqing 400044, China; 4. Beijing Institute of Technology, Beijing 100081, China)

Abstract: In response to the current issue of low precision in landslide detection, a deep learning-based landslide detection framework was proposed. This framework included three parts: data collection and processing, feature selection, and detection model, which can effectively improve the detection capability of landslides by integrating multi-source data. A multimodal KIAlexNet model was proposed, which could achieve pixel-level segmentation prediction and effectively fuse spatial features. Experimental results indicate that the proposed KIAlexNet model has high precision in landslide detection. Compared with methods such as U-Net, U-Net++, FC_DenseNet, and YOLOv9-seg, it demonstrates advantages. The experimental results validate the effectiveness and practicality of the proposed method, indicating its broad application prospects.

Keywords: Deep learning; Landslide detection; Convolutional neural networks; Feature extraction; Loss function

收稿日期: 2024-07-26

基金项目: 基于天空地一体化的滑坡监测评估与应急系统研发与应用(2023-CY02-00002-GX)

作者简介: 陈龙(1988-), 男, 工程师, 硕士, 研究方向为大数据、人工智能。

E-mail: Su_XH99@163.com

0 引言

滑坡作为一种以突发、迅速且不可逆为特点的地质灾害,常见于山坡、河岸及岩土边坡等地形^[1-2]。该现象由重力等因素驱动,涉及土壤与岩石的下滑运动。鉴于中国复杂山地地貌、人类工程活动(诸如采矿)以及天气灾害频发,滑坡灾害频繁发生,严重威胁民众生命与财产安全。滑坡受外部因素(如强降水、地震、人类活动)与内部因素(如岩土结构松动、地质构造破坏)共同影响,展现出强烈的破坏性和高风险性^[3-4]。因此,迅速且准确地获取滑坡灾害信息,并构建滑坡区域分析图,对于有效应对滑坡风险至关重要。

近年来,滑坡识别研究日益深入。早期识别主要依赖人工检测,但易受主观判断影响,且耗时较长,难以满足大规模信息处理需求^[5]。随着机器学习技术发展,许多学者将支持向量机^[6](Support vector machine, SVM)、随机森林^[7](Random forest, RF)等方法引入滑坡体识别领域。然而,这些方法在处理大量遥感数据及从多元图像数据源中提取深层信息时仍面临挑战。深度学习^[8](Deep learning, DL)方法,凭借其自动提取图像高维特征表示的能力、高鲁棒性及广泛应用性,在图像、文本、信号等领域取得了成功应用。文献[9]提出了一种基于GEE和U-net的滑坡体识别方法。文献[10]提出了一种基于YOLO的地震滑坡自动识别框架。该方法以收集的无人机正射影像和视频流提取特征,利用卷积神经网络模型实现高分辨率下地震滑坡检测。文献[11]提出了一种全卷积DenseNet(fully convolutional DenseNet, FC_DenseNet)的滑坡识别方法,有效解决传统DL方法特征提取不足导致检测精度低的问题。然而,滑坡环境复杂多变,涉及地貌、植被及土地利用类型的显著变化,且恶劣天气条件,特别是云层覆盖,会影响光学图像质量,增加地表变化监测的难度。为解决这一问题,学者们探索利用多源数据,如合成孔径雷达(Synthetic aperture radar, SAR)与光学影像的结合^[12-13],以提高滑坡检测精度。尽管现有研究通过整合多种数据源和技术手段提升了滑坡识别能力,但多数研究仍侧重于外部触发与内部地质因素,缺乏对这些因素间相关性及滑坡复杂演变和变形过程的深入分析,滑坡因素的选择尚缺乏坚实的理论基础。

为提升滑坡体识别精度,本研究基于多源高

分辨率遥感图像,提出了一套包含数据采集与处理、特征选择、检测模型构建三个阶段的滑坡体识别方法,旨在实现像素级的滑坡分割预测。

1 遥感影像滑坡体识别方法

本研究提出的遥感影像滑坡体识别方法结构图如图1所示。该方法分为数据采集与预处理、特征选择、预测模型三个主要部分。第一部分为数据采集与处理,主要包括滑坡数据采集(如Sentinel-1、Sentinel-2、Google Earth、数字高程模型(Digital elevation model, DEM)等)、标签制作等过程。第二部分为特征选择,旨在找到最佳滑坡成因因子。第三部分为检测模型构建,包括模型设计、训练、参数优化等。该过程,本研究在语义分割的基础上建立了一个多模态的KIAlexNet模型,可实现像素级分割预测,有效地融合空间特征。

1.1 数据采集与预处理

本研究中使用的滑坡数据主要采集自Sentinel-1图像提供地表变形信息,以及Sentinel-2图像提供地表特征细节。同时,利用DEM和Google Earth区域地质图及其衍生因子提供地质构造信息。其中,Sentinel-1和Sentinel-2均源于欧洲空间局提供。Sentinel-1A具有全天候观测能力,广泛应用于地面监测。为了保证基础数据源质量和获取研究区地表变形信息的准确性,选取了2021年1月9日至2023年5月29日的103幅Sentinel-1A影像。此外,本研究中InSAR成像方式为干涉宽带成像,分辨率为 $5\text{ m}\times 20\text{ m}$,中心入射角为 39.17° ,VV单偏振模式。从数据中共生成了310个原始影像图,研究区域的形变率范围为 $-136.52\sim 44.14\text{ mm/a}$ 。Sentinel-2的图像包括4个场景,成像日期为2022年6月23日和2022年6月29日。在辐射定标和大气校正等预处理步骤之后,选择分辨率为 10 m 的波段2、3、4和8进行波段融合、裁剪和嵌入,以提高可解释性。此外,本研究中使用的DEM来自阿拉斯加卫星设施,空间分辨率为 12.5 m 。

对于标签制作过程,首先根据历史滑坡数据,通过可视化解译,在Google Earth上对研究区滑坡进行矢量化标注。然后,将标记好的滑坡矢量数据导入ArcMap 10.5中,将其转换为栅格数据,导出为二值图像,获得真值(ground truth),并作为深度学习模型训练的标签。其中前景(白色)代表滑坡区,背景(黑色)代表非滑坡区。

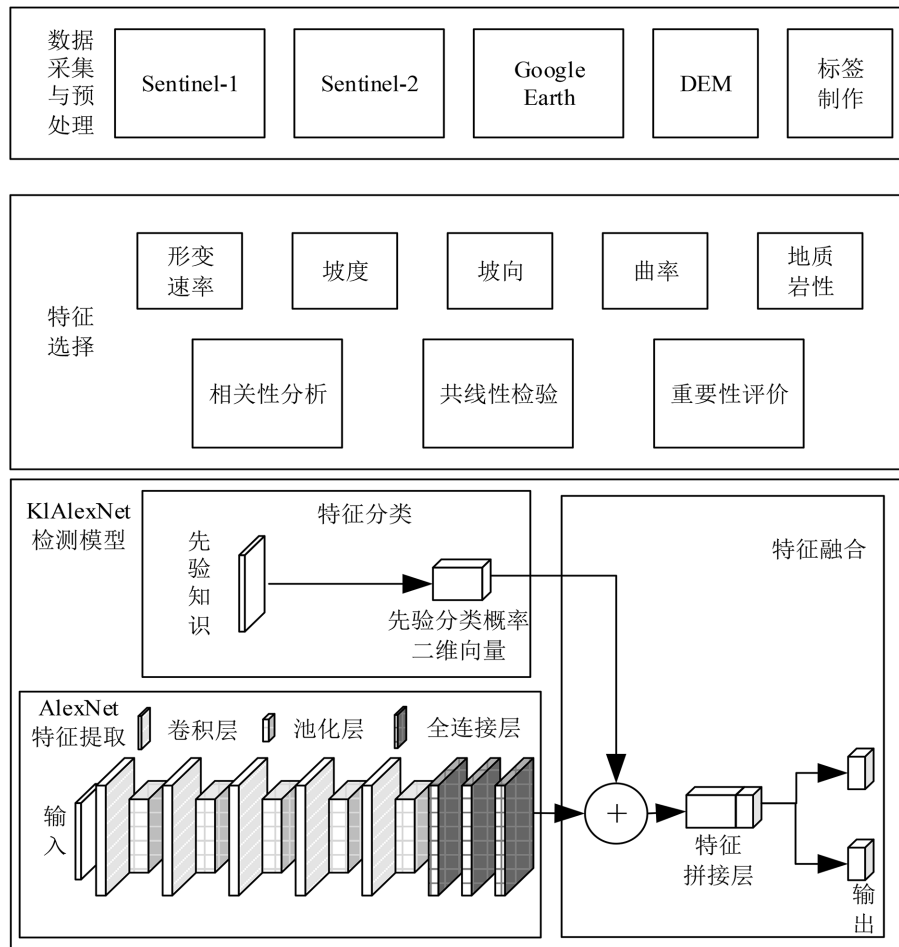


图1 所提遥感影像滑坡体识别方法结构图

Fig.1 Structure diagram of landslide detection method based on remote sensing image

完成数据集制作以及样本标注后，为了规范数据格式，对 Sentinel-2A 图像进行与地面真值相同的切割和数据增强。为了保证像素位置匹配，所有因子的空间分辨率重采样到 12.5 m。为了规范数据在不同维度上的分布，加快模型的收敛速度，采用 Z-score 方法对输入数据的各个通道进行归一化。考虑到滑坡样本比例较小，采用数据增强策略生成更多的训练样本。增强方法是将切割后的图像进行镜像、逆时针旋转等。接着，利用 200×200 像素的滑动窗口大小扫描并生成不重叠的样本块，重叠大小为 50 像素。最终，将滑坡和非滑坡样本按 8:1:1 的比例划分为训练集、验证集和测试集。其中，训练数据集用于学习滑坡特征；验证集用于调节参数；测试集为检测模型从未学习过的“未知”样本，用以评估模型的扩展能力及鲁棒性。

1.2 特征选择

考虑到滑坡地质灾害的发生与滑坡成因因子

的密切关系，本研究选择形变速率、DEM 衍生的坡度、坡向、曲率、地质岩性等因素作为滑坡成因因子。所有滑坡成因因子均基于 ENVI5.3、SARscape 平台和 ArcGIS10.7 进行处理。

滑坡的形成是多种因素相互作用的复杂结果。探讨内外部因子与滑坡发生的关系，旨在提高输入模型的数据质量进而提高预测模型的准确性。因此，选取光学影像和地质因素作为滑坡成因因子，与变形速率一起进行回归。然而，当滑坡成因因子表现出较高的相关性，即不同因子之间存在较强的线性或非线性关系时，不仅会给模型带来过多的数据负担，还会干扰特征学习过程中不同特征的权重分配。因此，本研究对滑坡成因因子进行了相关性分析、共线性检验和重要性评价。

一般情况下，Pearson 相关系数是量化两个变量之间线性相关性的度量。该系数通过评估两组数据的协方差和标准差计算：

$$f_{\text{per}} = \frac{C_{\text{ov}}(X, Y)}{\sigma_X \sigma_Y} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (1)$$

式(1)中: n 为样本总数; $C_{\text{ov}}(X, Y)$ 为变量 X 与变量 Y 之间的协方差; σ_X 和 σ_Y 为所有样本的标准差; \bar{X} 和 \bar{Y} 为变量 X 与变量 Y 的平均值。

共线性检验是指检验自变量之间的线性相关性。共线性检验可通过容忍度(trlrance)和方差膨胀系数(variance inflation factor, VIF)计算。容忍度是每个自变量作为因变量对其他自变量进行回归建模时得到的残差比例,大小用1减得到的决定系数来表示。VIF是容忍度的倒数,值越大则共线性问题越明显。VIF计算公式如下:

$$f_{\text{vif}} = \frac{1}{1 - R_i^2} \quad (2)$$

式(2)中: f_{vif} 为方差膨胀系数; R_i^2 为第 i 个变量的线性回归模型中对应的决策系数。需注意, f_{vif} 值越接近1,数据之间的相关性越弱;反之, f_{vif} 值越高,数据之间的相关性越明显。

考虑到不同因素对模型性能的贡献不同,本研究使用基尼指数对滑坡成因因子的重要性进行排序。基尼指数已广泛使用于机器学习中,尤其在构建随机森林中已被证实具有挖掘重要特征能力。如果一个特征在构建随机森林时经常被选择用于节点分区,并且分区后能够提高模型性能,那么这个特征很可能是一个重要的特征;相反,如果一个特征在随机森林的构造中很少被选择,或者在划分后对模型性能的影响很小,那么这个特征很可能是一个不重要的特征。基于上述机理,本研究利用基尼指数对特征的重要性进行排序。基尼指数计算如下:

$$f_{\text{Gini}} = 1 - \sum_{k=1}^K p_k (1 - p_k) = 1 - \sum_{k=1}^K p_k^2 \quad (3)$$

式(3)中: K 为特征的总数; p_k 为第 k 个特征被选择的概率。

1.3 检测模型

本研究提出了一种基于融合先验知识和 AlexNet 网络模型的遥感图像滑坡识别方法,称为知识 - AlexNet (knowledge-AlexNet, KIAlexNet)。受 FC_DenseNet 启发,所提 KIAlexNet 将基础 FC_DenseNet 中 DenseNet 特征提取模块换成 AlexNet 特征提取模块,并融合先验滑坡知识图以及深度特征进行遥感滑坡图像识别,从而提升滑

坡检测精度。KIAlexNet 检测模型结构如图2所示。该模型分为三部分:特征提取、特征分类、特征融合。

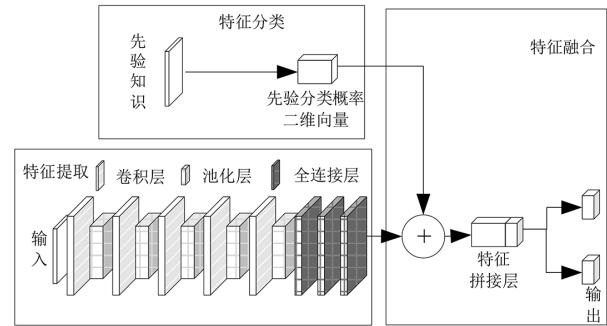


图2 KIAlexNet 检测模型结构

Fig.2 Structure of KIAlexNet detection model

1.3.1 特征提取

通过特征选择将重要滑坡因子带入特征提取网络,将提取的特征向量馈送到分类器,从而计算并输出待检测向量的基于滑坡先验知识的先验分类概率向量。本研究使用 AlexNet 模型通过卷积层和全连通层提取待检测遥感图像的特征。

AlexNet 模型是卷积神经网络(Convolutional neural network, CNN)的一种变体,其克服了CNN梯度爆炸的局限性,具备优异的特征提取性能。AlexNet的架构类似于LeNet模型。然而,与LeNet模型相比,AlexNet有更多的滤波器。AlexNet由卷积、池化层和全连接层组成。卷积层用于获取抽象和潜在特征,池化层用于获取高级特征,减少了维数问题的困扰。此外,使用 dropout 层代替正则化技术控制过拟合问题。然而,dropout 层增加了 AlexNet 模型的训练时间。AlexNet 模型的基本架构如图3所示。




图3 AlexNet 模型的基本架构

Fig.3 The basic architecture of AlexNet model

卷积层是 CNN 的重要组成部分,可在输入图像上应用二维过滤器以提取与预测标签高度相关的高级特征。在本研究中,将混合电力数据转换成二维数据,并在输入特征向量上移动二维滤波器,从而创建不同的特征映射。此外,本研究使

用随机梯度下降法获得了这些滤波器的最优值。卷积层学习过程描述为:

$$y_{\text{con}}(X_i^{f_i}) = \sigma \left(\sum_{f_i=1}^{f_i} W_i^{f_i} X_i^{f_i} + b_i^{f_i} \right) \quad (4)$$

式(4)中: $X_i^{f_i}$ 为滤波器 f_i 后的输出特征映射; y_{con} 为经卷积层学习后的特征映射; $W_i^{f_i}$ 和 $b_i^{f_i}$ 为可学习的权重和偏置参数; σ 为激活函数。

卷积层可从数据中提取底层特征。因此, 输入数据的微小变化会创建不同的特征映射。然而随着卷积层数的加深, 计算维度呈几何倍数剧增, 将会严重降低深度学习模型的性能。池化层在不影响输入数据的原始分辨率的情况下减小了特征图的空间维度, 可有效克服计算开销问题。常用的池化操作包括: 平均池化、最大池化等。本研究采用最大池化策略降低数据的空间维度。最大池化策略只保留特征图特定区域中最大的值, 而丢弃其余的值。最大池化层的数学表示如下:

$$y^m = \max_{i,j} R(y_{i,j}) \quad (5)$$

式(5)中: y^m 为最大池化操作后的结果; $y_{i,j}$ 为输入最大池化层的特征图; R 为实数值; i 和 j 分别为第 i 个卷积层和第 j 个神经元。

在卷积运算之后, 将激活函数应用于提取的特征图。常用的激活函数包括 tanh、线性、sigmoid、ReLU、Leaky ReLU (LReLU) 等。每个函数都有自己的优点和缺点, 如 sigmoid 和 tanh 函数会产生爆炸和消失的梯度问题, 这会干扰模型的学习性能。本研究使用 ReLU 作为每个卷积层之后的激活函数。该函数将负值转换为零, 并将剩余值传递给即将到来的卷积层, 而不做任何更改。ReLU 函数可有效克服模型的梯度爆炸和消失问题, 提高了学习性能。ReLU 函数的数学方程如下:

$$f_{\text{ReLU}} = \max(0, f) \quad (6)$$

式(6)中: f_{ReLU} 为 ReLU 函数的输出值; f 为代入 ReLU 函数的输入值。

本研究引入 dropout 层以用不同的架构模拟单个神经网络。通过 dropout 层去激活隐藏层的一些神经元, 以克服过拟合和泛化能力差的问题。dropout 层的平均丢失率设置为 0 到 1 之间的随机值。本研究中丢失率设置为 0.5 时, 即一半数量的神经元在训练过程中被去激活。

通过全连接层将前一层的神经元与后一层的神经元连接起来, 可从提供的特征映射中提取全局特征。全连接层的数学公式如下所示:

$$f_0 = \sigma(W_i X_i + b_i) \quad (7)$$

式(7)中: X_i 为输入特征向量; W_i 和 b_i 分别为权重因子和偏倚因子; σ 为 ReLU 函数; f_0 为最终输出。

1.3.2 特征分类

随机给定 m 组先验知识, 即滑坡特征向量 S_i 和非滑坡特征向量 P_i 。将滑坡特征向量 S_i 和非滑坡特征向量 P_i 与待检测的特征向量 T 的得分距离函数定义为:

$$d_1 = \sum_{i=1}^m [(S_i + r_{\text{sim}}) - T]^2 \quad (8)$$

$$d_2 = \sum_{i=1}^m [(P_i + r_{\text{sim}}) - T]^2 \quad (9)$$

式(8)、(9)中: d_1 为待检测的特征向量 T 和滑坡特征向量 S_i 之间的得分距离; r_{sim} 为相似性关系系数; d_2 为待检测的特征向量 T 和非滑坡特征向量 P_i 之间的得分距离。

当获取 d_1 和 d_2 这两个值之后, 可基于先验知识将距离较小的特征向量作为预测结果。换言之, 如果 d_1 的值大于 d_2 的值, 则意味着在相似关系 r_{sim} 下, 待检测的特征向量 T 与滑坡向量 S_i 之间的得分距离大于待检测的特征向量 T 与非滑坡特征向量 P_i 之间的得分距。这意味着待检测的特征向量 T 与滑坡特征向量 S_i 更相似。当比较 m 组滑坡特征向量 S_i 和非滑坡特征向量 P_i 之后, 可获得维度为 m 的特征向量。该特征向量中的元素都是 0 或 1, 0 表示非滑坡结果, 1 表示滑坡结果。然后, 本研究利用分类器统计该特征向量中 0 元素和 1 元素的分布, 从而得到基于滑坡先验知识的先验分类概率二维向量。接着, 将先验分类概率二维向量输入到积分器, 并使用多元贝叶斯公式对特征向量进行组合, 以获得分类结果。

1.3.3 特征融合

基于特征拼接的融合机制是一种多模态滑坡数据融合方法, 可用于拼接不同模态的滑坡特征向量, 以获得综合的特征表示。本研究使用特征拼接的融合机制对滑坡先验知识和遥感图像深度特征进行特征向量融合, 构建了基于特征拼接融合方法的滑坡体识别模型。

首先, 将预处理后的滑坡图像输入到 AlexNet 模型中, 通过卷积层提取滑坡图像特征并转换为滑坡特征图。然后, 通过批量归一化、非线性激活层和全局平均池化层输出滑坡图像的特征向量。在 AlexNet 全连接层之后添加 ReLU 层进行非线性激活, 然后将滑坡先验知识特征向量与图像特征向量拼接, 得到 512 维特征拼接层。特征拼接层在维度上拼接了滑坡先验知识特征和图像的深度特

征,从而形成更高维度的综合特征向量。这种方法允许模型利用滑坡先验知识特征和图像的信息进行更全面的滑坡分类。拼接操作可以通过简单地执行两个矢量之间的连接操作实现。随后,将特征拼接层中融合的特征向量用于滑坡数据的二元分类,以确定是否发生了滑坡。这样,可以通过解释分类器的输出解释和分析基于特征拼接融合方法的滑坡分类结果。基于特征拼接的融合机制的优点是实现简单易行,可以将不同模态的信息直接融合在一起,从而充分利用多模态数据信息。

2 实验与分析

2.1 实验设置

本节基于数据集对 K1AlexNet 进行训练和模型评估。训练时环境设置如下:硬件 CPU 为英特尔® 酷睿™ i7-12700H 处理器(24 M 高速缓存,睿频至高可达 4.70 GHz),内存为 DDR4 32G,存储为 4T 希捷硬盘, GPU 为 GeForce RTX™ 3090 Ti 显卡,操作系统为 ubuntu 20.04;改进 AlexNet 网络主要基于 python 3.8 编写,主要模块包括 pytorch 1.12.0、CUDA 11.3、torchvision 0.10.0。经过预实验测试,考虑到硬件限制和模型的计算效率,实验过程中的迭代次数(epoch)设置为 3000 次,初始学习率设置为 10^{-4} ,优化器选择自适应矩估计(Adaptive moment estimation, Adam)。Adam 算法是对梯度下降 Adagrad 算法和 Rmsprop 算法的优化。同时,当参数更新时,Adam 算法不受梯度尺度变换的影响,可以自动调整学习率,易于实现,计算效率高。本文研究图像像素的二值分类,因此选择二值交叉熵作为损失函数:

$$L = -\frac{1}{N} \sum_{i=1}^N y_i \log [p(y_i)] + (1 - y_i) \log [1 - p(y_i)] \quad (10)$$

式(10)中: N 为类别的个数; y 为二进制标签; $p(y_i)$ 为输出属于 y 标签的概率。

模型评估时,本研究选择了五个常用的评价指标定量分析模型的综合性能。这些指标包括精度(precision)、召回率(recall)、 F_1 分数(F1 score)、Kappa 系数和平均交并比(mean intersection over union, MIoU)。其中,精度是指正确预测的阳性样本占预测阳性样本总数的比例。召回率是指正确预测的阳性样本占所有阳性样本的比例。通常, F_1 分数为精度和召回率的调和平均值,可用于综合

评价分类模型的性能。各指标的计算公式如下:

$$f_{\text{pre}} = \frac{T_p}{T_p + F_p} \quad (11)$$

$$f_{\text{rec}} = \frac{T_p}{T_p + F_N} \quad (12)$$

$$f_{F1} = \frac{2f_{\text{pre}}f_{\text{rec}}}{f_{\text{pre}} + f_{\text{rec}}} \quad (13)$$

式(11)~(13)中: f_{pre} 为精度指标; f_{rec} 为召回率指标; f_{F1} 为 F_1 分数指标; T_N 为预测值和实际值均为负样本的数量; F_p 为预测值为正样本,但实际为负样本的数量; F_N 为预测为负样本,实际为正样本的数量; T_p 预测和实际均为正样本的数量。

Kappa 系数是一种评价一致性的方法,取值范围为[-1, 1]。该系数值越高,模型的分类精度越高。Kappa 系数与总体精度相互验证,并对结果进行客观评价,其公式计算如下:

$$\begin{cases} f_{\text{kappa}} = \frac{p_o - p_e}{1 - p_e} \\ p_o = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \\ p_e = \frac{1}{n^2} [(T_p + F_N)(T_p + F_p) + (F_p + T_N)(T_N + F_N)] \end{cases} \quad (14)$$

MIoU 指标旨在计算每个类别中像素的相交和并的比率,并将所有类别的结果平均。当真实值与预测值相同时,MIoU 值为 1,表示在理想情况下完全匹配。MIoU 指标公式计算如下:

$$f_{\text{MIoU}} = \frac{1}{2} \left(\frac{T_p}{T_p + F_p + F_N} + \frac{T_N}{T_N + F_p + F_N} \right) \quad (15)$$

2.2 特征选择

本节对 6 种常用的地质因子,包括:形变速率、高程、坡度、坡向、曲率、地质岩性进行特征选择实验,从而提高输入模型的数据质量。特征选择实验包括相关分析、共线性检验和重要性评价等过程。实验过程设置如下:首先,基于所提数据预处理和特征选择方案,即选取光学影像和地质因素作为滑坡成因因子,与变形速率一起进行回归,从而选取最佳输入特征。

首先,对不同地质因子进行相关分析实验。该实验以 Pearson 相关系数为指标。不同滑坡成因因子 Pearson 相关系数统计表如表 1 所示。一般情况下, Pearson 相关系数中正值和负值表示数据之间的正相关和负相关,值越大表明相关度越强,值越小表明相关度越低。

可以看出,形变速率与高程和坡度特征呈正相关, Pearson 相关系数约为0.05以上。与坡向、曲率、地质岩性等地质因子相关度不大, Pearson 相关系数约为0作用。实验结果表明随着区域高度和坡度的增加,地表变形速率也随之增大。分析

原因,相对较高的海拔和陡峭的坡度的地区更容易产生滑坡事件,实验结果符合实际。因此,输入应选择高程和坡度特征作为重要输入特征,从而提升输入数据质量。

表1 不同滑坡成因因子 Pearson 相关系数统计表

Table 1 Pearson correlation coefficients of different landslide formation factors

地质因子	形变速率	高程	坡度	坡向	曲率	地质岩性
形变速率	1.0	0.18	0.15	0.01	0.01	-0.15
高程	0.18	1.0	-0.02	0.03	0.05	-0.08
坡度	0.15	-0.01	1.0	0.01	-0.05	-0.01
坡向	0.01	0.05	0.01	1.0	0.01	0.00
曲率	0.00	0.05	-0.05	0.01	1.0	0.00
地质岩性	-0.15	-0.05	-0.01	0.00	0.00	1.0

接下来对不同地质因子进行共线性检验。该实验选取 VIF 和容忍度为指标。共线性检验结果如图4所示。可以看出,不同地质因子之间存在弱正相关。每个地质因子的 VIF 和容忍度值均在1.0左右,说明不同地质因子之间相关性不强。实验结果验证了所选地质因子的稳健性。

最后,对不同地质因子进行重要性评价实验。该实验选取基尼指数为指标。不同地质因子的重

要性排序分布如表3所示。可以看出,地表形变率的重要性值最高,高程排名第2,曲率第3。分析原因,高形变速率表明地质体加速或快速沉降,则发生滑坡的概率更高。此外,高曲率和高海拔陡坡的应力集中区域也容易发生滑坡,因此其重要性也很高。最后,地质岩性的重要性最低。分析原因,地质岩性种类多,分布复杂,与发生滑坡无直接关系。




图4 共线性检验结果

Fig.4 Results of collinearity test

表2 不同地质因子的重要性排序分布

Table 2 Distribution of importance ranking of different geological factors

地质因子	基尼指数
形变速率	0.28
高程	0.19
坡度	0.13
坡向	0.15
曲率	0.17
地质岩性	0.04

综合以上分析,实验选取的形变速率、高程、坡度、坡向、曲率、地质岩性等指标具有一定的代表性,可对分析滑坡起到一定支撑作用。同时,形变速率、高程、曲率、坡向为相对重要特征,坡度、地质岩性为一般特征。

接下来,分析特征选择数量和检测精度的趋势。实验时按照重要性排序的结果,选择前1至前5名地质因子进行测试。不同特征选择数量下滑坡识别精度如表3所示。其中横轴表示特征选择的数量,纵轴为滑坡检测的精度。

表3 不同特征选择数量下滑坡识别精度

Table 3 Landslide detection accuracy under different feature selection quantities

特征选择数量	精度
1	0.7960
2	0.8843
3	0.9038
4	0.9236
5	0.8344

可以看出,随着特征选择数量的增加,检测的准确性呈先增加后下降的趋势,即特征选择数量超过4时,检测的精度反而有所降低。分析原因:当特征选择数量超过一定阈值,检测模型可能会将部分非高相关性的特征聚类,即将一些非重要特征聚类为重要特征,从而给训练过程带来干扰。因此本文最终确定了代表滑坡的4种特征因子:形变速率、高程、曲率、坡向。

2.3 与主流检测模型对比

为了验证所提KIAlexNet的性能,本节对比了主流检测方法的滑坡体识别性能。对比指标选择精度、召回率、 F_1 分数、Kappa系数、MIoU。对比的主流方法包括:U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等。不同方法对比结果如图5所示。可以看出,所提KIAlexNet各项指标均具有明显提升。与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等

主流方法相比,所提KIAlexNet精度指标分别提升34.4%、25.6%、16.7%、10.2%;与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等方法相比,所提KIAlexNet召回率指标分别提升60.2%、24.2%、6.4%、2.45%;与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等方法相比,所提KIAlexNet F_1 分数指标分别提升44.0%、32.1%、13.1%、4.2%;与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等方法相比,所提KIAlexNet的Kappa系数指标分别提升43.3%、31.5%、13.2%、6.2%;与U-Net、U-Net++、FC_DenseNet、YOLOv9-seg等方法相比,所提KIAlexNet的MIoU指标分别提升27.2%、24.3%、26.4%、12.6%。分析原因:所提KIAlexNet可融合滑坡先验知识特征和图像深度特征,从而多维度学习滑坡特征因子,通过充分利用多模态数据信息,具备高精度的滑坡检测。

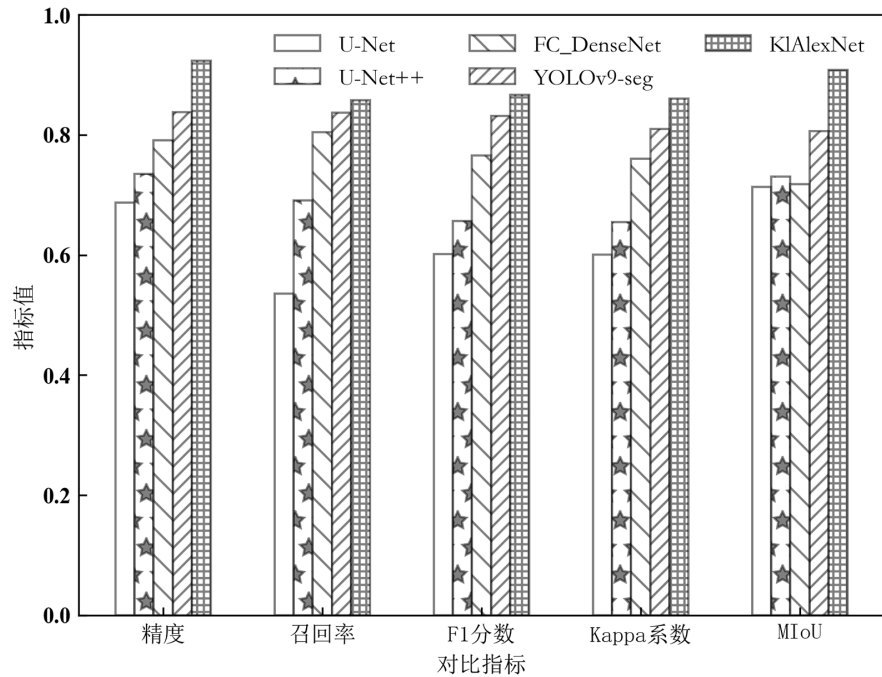


图5 不同方法对比结果

Fig.5 Comparison results of different methods

综合以上分析,所提K1AlexNet具有更优的检测性能,具备一定工程化推广价值。

3 结语

为实现高精度遥感影像滑坡体识别,本文研究了一种基于深度学习的高分辨率遥感影响滑坡体识别方法。该方法包括数据预处理、特征选择、特征提取等过程。通过实验验证,所提方法具备更优的性能。该方法可为精细化识别滑坡体提供指导,在实际应用中具有重要意义。

现有研究主要分析了高分辨率下滑坡体检测问题,考虑到高分辨率遥感图像获取周期较长,未来可对低分辨率的滑坡体检测进行研究,从而推广所提滑坡体检测方法适用范围。此外,未来还可对深度学习模型轻量化剪枝,嵌入式移植等技术进行研究,从而在保持模型性能同时进一步缩小模型计算以及存储开销。同时,考虑到滑坡灾害的复杂性,以及不同地区地质条件的差异性,后续研究可能会考虑引入更多与滑坡发生相关的地质因子,如降雨量、植被覆盖度、土壤类型等,以进一步提高滑坡识别模型的准确性和鲁棒性。

参考文献

[1] 高茂宁,魏冠军,雷传金,等.顾及时序InSAR的海东市辖区滑坡敏感性评价[J].地理空间信息,2024,22(05):97-101.

[2] 崔晨.智能微动勘探在滑坡体中的应用[J].水利技术监督,2024(05):254-256.

[3] 陶妍,角媛梅,丁银平,等.降雨诱发型滑坡的降雨阈值及机理研究进展与展望[J].云南师范大学学报(自然科学版),2023,43(04):71-78.

[4] 丁丽,郭凯,张郝哲.基于不同评价单元的地质灾害易发性评价对比[J].云南师范大学学报(自然科学版),2023,43(02):62-68.

[5] 李冉,杨军,宁玉富,等.基于深度学习的黄土滑坡自动识别[J].电视技术,2024,48(04):37-39.

[6] 唐烽顺,郝利娜,宋雨洋,等.目标检测算法在滑坡识别中的应用[J].兰州大学学报(自然科学版),2024,60(02):229-234.

[7] 高星月,王世杰,高鹏程.D-InSAR与随机森林模型耦合的活动性滑坡识别方法探究[J].中国地质灾害与防治学报,2022,33(05):102-108.

[8] Yann L C, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[9] 刘佳,伍宇明,高星,等.基于GEE和U-net模型的同震滑坡识别方法[J].地球信息科学学报,2022,24(07):1275-1285.

[11] 乐子扬.深度学习在地震滑坡自动识别中的应用[D].三河:防灾科技学院,2023.

[12] 燕飒.基于多源遥感数据的滑坡隐患综合识别与易发性评价[D].南昌:东华理工大学,2023.

[13] 於心竹.基于SBAS-InSAR技术的温泉县滑坡形变监测与预测研究[D].南昌:东华理工大学,2023.