

基于深度学习的地震诱发滑坡自动提取研究

张明鹏, 张 帅, 吕运鸿
(浙江大学 建筑工程学院, 浙江 杭州 310058)

摘要: 地震诱发滑坡的提取是震区工程风险评价的基础, 对震区的灾后重建工作具有重要意义。传统的机器学习方法需要复杂的数据预处理及设计特征工程工作, 而深度学习方法则可以直接输入图像数据进行端到端学习, 从而实现地震诱发滑坡的自动提取。本文探究了 U-Net 与 LinkNet 两种卷积神经网络在地震诱发滑坡自动提取任务中的应用。研究表明 U-Net 和 LinkNet 在地震诱发滑坡自动提取应用中具有巨大的潜力, 召回系数、F1 分数、精确度均达到 0.8 以上。相较之下, LinkNet 网络结构在滑坡的自动提取任务中整体性能优于 U-Net, 召回系数、F1 分数、精确度分别提升 2.0%~8.0%、4.0%~8.0%、8.0%~10.0%。U-Net 网络结构适用于简单背景图像中大型滑坡的提取, 而 LinkNet 网络结构则更适用于复杂背景图像中的滑坡及简单背景图像中小型滑坡的提取。

关键词: 地震; 滑坡; 卷积神经网络; 深度学习; 自动提取; 遥感影像

中图分类号: P237

文献标识码: A

文章编号: 2096-7195(2024)03-0242-08

Automatic extraction of earthquake-induced landslides based on deep learning

ZHANG Ming-peng, ZHANG Shuai, LV Yun-hong

(College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, Zhejiang, China)

Abstract: Extracting earthquake-induced landslides is foundational for engineering risk assessment in seismic regions and holds significant importance for reconstruction efforts. Traditional machine learning methods require complex data preprocessing and feature extraction. In contrast, deep learning methods enable direct input of image data for end-to-end learning, facilitating automatic extraction of earthquake-induced landslides. This work investigates the automatic recognition of regional earthquake-induced landslides using U-Net and LinkNet convolutional neural networks. Experimental results show that U-Net and LinkNet exhibit significant extraction capabilities in automatically identifying earthquake-induced landslides. The recall coefficient, F1-score and precision of evaluation indexes all exceed 0.8. LinkNet outperforms U-Net overall, with improvements in the recall coefficient (2.0%~8.0%), F1-score (4.0%~8.0%), and precision (8.0%~10.0%). The U-Net network structure is well-suited for extracting large landslides in simple background images, whereas the LinkNet network structure is better suited for extracting landslides in complex background images and small landslides in simple background images.

Key words: earthquake; landslide; convolutional neural networks; deep learning; automatic extraction; remote-sensing image

0 引言

地震诱发的滑坡会产生大量的松散堆积体^[1]。松散堆积体为滑坡和泥石流等地质灾害活动提供丰富物源, 导致灾区震后滑坡和泥石流等灾害活动持续活跃, 对灾区的重建工程造成巨大危害^[2]。地

震诱发滑坡的提取是进行工程风险评价及长期演化规律研究的重要基础, 对后期合理规划道路与设计路基等灾区重建工作具有重要的指导作用。传统滑坡提取方法主要有遥感目视解译、现场调查等, 具有准确率高的优点, 但需要耗费大量的人力、物力, 且对于人员的专业水平要求较高^[3-4]。地震诱发

的滑坡范围广且数量多,传统的提取方法效率低下。因此,开展区域性地震诱发滑坡自动提取的研究工作具有重要意义。

滑坡常见的自动提取方法包括阈值法、传统机器学习以及深度学习等^[5]。杨树文等^[6]首次利用改进的MSAVI算法和改进的多峰直方图阈值实现滑坡的自动提取。文广超等^[7]综合地物光谱特征和位置信息对灾后滑体进行了自动提取。郭擎等^[8]基于归一化植被指数的变化提取滑坡。随着人工智能理论的逐渐完善和遥感技术的快速发展,部分学者开始使用机器学习算法在遥感影像上实现滑坡的自动提取。MOOSAVI等^[9]采用田口法对神经网络和支持向量机算法的结构进行优化,并证明面向对象的自动提取方法要优于基于像素的方法。LI等^[10]采用随机森林和SVM算法开发了一种面向对象提取的半自动提取算法,并应用于陡峭崎岖地形中林区滑坡的提取。龙玉洁等^[11]运用随机森林和最大似然算法实现滑坡的自动提取,并表明前者提取效果要好于后者。尽管传统的机器学习方法能够实现滑坡的自动提取,但需要进行数据预处理和设计特征工程等操作,这不仅需要复杂的前期工作,同时也不能充分利用图像的特征。深度学习可以直接输入图像数据,让算法自动选择对提取任务有用的特征,实现端到端学习。这样既有利于简化工作流程,提高提取效率,又能充分运用图像特征提升提取精度。因此深度学习在滑坡自动提取的研究中具有重要意义。卷积神经网络在计算机视觉领域任务中取得了巨大的成功,是深度学习领域最常用的算法之一。DING等^[12]基于CNN和纹理检测办法提出了一种新的滑坡自动提取方法。GHORBANZADEH等^[13]利用ANN、SVM、RF以及CNN提取滑坡,发现只输入光谱数据的CNN网络的提取结果要优于其他算法,并表明将DEM作为辅助数据输入,有助于区分滑坡和人类居住地区。LU等^[14]基于迁移学习和面向对象图像分析提出了一种优于面向对象的最近邻分类滑坡自动提取办法。WANG等^[15]比较了LR、SVM、RF和CNN等算法,发现CNN在特征提取和多维数据处理方面比其他算法具有更好的性能,结合机器学习和深度学习提出了一种鲁棒性强的滑坡自动提取方法。虽然CNN在滑坡自动提取应用方面取得了一些成功,但大多数情况中的滑坡样本数量仍然很小,并且很难对深度学习算法进行训练^[16]。因此,探究基于小样本数据的卷积网络结构在滑坡自动提取中

的应用具有重要意义。U-Net结构能够有效利用图像浅层特征,基于小样本数据结合数据增强方法实现对任务目标较好的提取^[17]。因此,越来越多的学者开始探索U-Net网络对滑坡的自动提取研究^[18-20]。LEI等^[18]采用金字塔池化模块优化FCN、U-Net卷积神经网络算法在滑坡提取中的性能。LIU等^[19]提出了一种改进U-Net的卷积神经网络,并将DSM、坡度和坡向作为补充数据增加样本的特征参数数量。YI等^[20]提出了LandsNet,该网络结构在滑坡的自动提取任务中优于ResNet和DeepUNet。BRAGAGNOLO等^[21]评估了U-Net神经网络结构在滑坡语义分割中的应用,表明该网络结构在滑坡提取应用中具有重大潜力,但是却容易将建筑物及裸土等错误提取为滑坡。U-Net网络结构在滑坡自动提取任务中取得很好的效果,但对于和滑坡具有相同光谱特征的地物却难以分辨,虽然许多学者采用地理环境因子作为输入数据,提高了模型的分辨能力,但高分辨率的地理数据往往难以获得。因此,使用遥感光谱数据作为输入数据以提升卷积神经网络对滑坡的自动提取效果的研究,具有重要意义。LinkNet借鉴了U-Net融合低维度图像特征的思想,同时具有更少参数的优点,可以减少模型的训练时间并提升任务目标提取速度^[22]。

因此,针对现有滑坡自动提取研究的不足及LinkNet网络结构的优点,本文旨在基于遥感目视解译和现场调查建立的滑坡数据库,评估U-Net和LinkNet两种卷积神经网络在地震诱发滑坡自动提取任务中的应用特点。

1 研究区概况

研究区位于四川省阿坝藏族羌族自治州汶川县东部,包括映秀镇、耿达镇及银杏乡等地区,如图1所示。主要的交通干道包括省道303(映秀镇至耿达乡段)以及国道213(映秀镇至银杏乡段),分别沿主要河流鱼子溪和岷江分布。区内主要为高山峡谷地貌,地质情况复杂、构造发育。映秀镇是2008年汶川地震的震中地区,是地震破坏最严重、诱发二次地质灾害数量最多的区域。

研究区内沿线公路震后堆积了大量由地震诱发滑坡产生的松散堆积体。在汶川地震震后十年间,该地区的泥石流和滑坡等灾害活动依然十分活跃,省道303公路重建工作因此遭受了多次毁灭性破坏,见图2,造成了巨大的经济损失和人员伤亡。

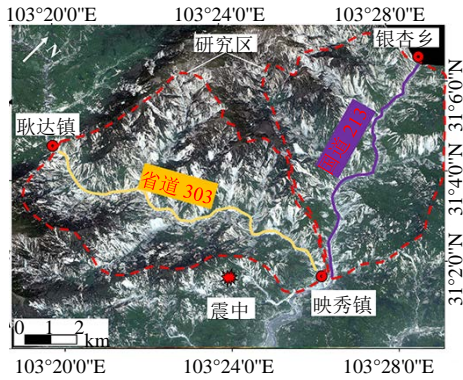


图1 研究区位置

Fig. 1 Location of the study area



图2 省道303震后灾害活动

Fig. 2 Post-earthquake geological hazard activities along PR303

2 数据与方法

2.1 数据获取

本次研究工作的数据基于遥感影像目视解译和现场调查建立的滑坡数据库。遥感影像为美国 QuickBird 遥感数据，地面分辨率为 0.61 m，拍摄于 2008 年 5 月 30 日。运用 ArcGIS 平台软件分割栅格命令将研究区内滑坡的遥感影像分割为 538 张 256 像元×256 像元大小的图片，建立滑坡数据集。基于遥感目视解译和现场调查建立的滑坡数据集，运用开源软件 Labelme 制作样本标签。将数据集划分为训练集、测试集和验证集，训练集和验证集的样本数量比例为 4 : 1。运用训练集和验证集训练卷

积神经网络，并评估卷积神经网络的性能，最终将测试集输入训练好的网络实现滑坡的自动提取。具体的工作流程如图 3 所示。

Labelme 是款开源的语义分割样本标签制作软件，具有易学易用的特点。图像标注好后可以批量转换为标签。不同于图像分类任务中的标签，图像语义分割的标签是图像（见图 4）。标签图像上分为两类：一类为滑坡，在图像矩阵上赋值 1，用红色表示；另一类为背景，即非滑坡，在图像矩阵上赋值为 0，用灰色表示。在样本中可以发现有的图像的背景相当复杂，除了滑坡，还包括河流、桥梁、房屋、裸岩和植被。相反，有的图像背景较为简单，只有植被和滑坡。

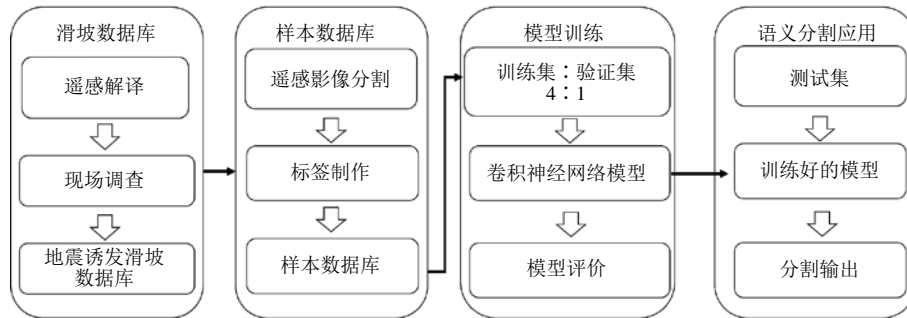


图3 工作流程

Fig. 3 Flowchart of the methodology in this study




图4 代表样本数据

Fig. 4 Typical landslide samples

2.2 深度学习方法

语义分割能够对图像进行像素级别的分类, 相对于图像分类和检测任务, 其不仅可以获得目标的位置, 也可以获取目标的区域面积。本文中滑坡的自动提取是指利用已有的滑坡样本数据库对卷积神经网络进行训练, 通过误差反向传播方法, 对卷积神经网络的参数不断进行更新优化, 从而获取针对滑坡自动提取的最佳参数。基于训练的卷积神经网络对图像中的滑坡区域进行像素级别的分类, 从而实现滑坡的位置和面积的自动提取。

卷积神经网络是语义分割的常用算法。本次研究工作采用的卷积神经网络为 U-Net 网络及 LinkNet 网络。U-Net 网络结构如图 5 所示, 由左侧的收缩路径和右侧的扩展路径组成, 两者左右对称呈 U 形结构。收缩路径重复使用 2 个 3×3 的卷积层和 1 个 2×2 的最大池化层, 卷积层后为 ReLu 激活函数, 最大池化层的步长设置为 2, 用于下采样。在收缩路径中, 图像特征层的维度从 64 逐渐变为 128、256、512、1024。扩展路径重复使用 1 个 2×2 转置卷积层和 2 个 3×3 卷积层。首先使用 1 个 2×2 转置卷积层下采样使得图像特征层的维度减半, 再与对应收缩路径的低级图像特征层叠加, 使得图像特征的维度扩大到原来的两倍, 然后通过 2 个 3×3

的卷积层, 最后通过 ReLu 激活函数输出特征层。在扩张的路径中, 图像特征层的维度由 1024 逐渐恢复到 64, 最终通过 1×1 卷积层输出图像分割结果, 实现滑坡的自动提取。

LinkNet 网络结构如图 6 所示, LinkNet 网络结构与 U-Net 网络结构在整体上相似。如图 6 (a) 所示, /2 代表下采样的倍数为 2, *2 代表上采样的倍数为 2, 每个卷积层之间均采用了批处理归一化, 然后通过 ReLu 激活函数。LinkNet 由左侧的编码器和右侧的解码器组成。编码器部分包含 1 个初始块和 4 个编码模块。初始块包含 1 个 7×7 的卷积层运算和 1 个 3×3 的最大池化层。编码模块则采用 ResNet18, 如图 6 (b) 所示。解码器部分由 4 个解码模块和 1 个剩余块组成。解码模块由 1 个 1×1 的卷积层、1 个 3×3 大小的全卷积层和 1 个 1×1 大小的卷积层组成, 如图 6 (c) 所示。剩余块则由 1 个 3×3 大小的全卷积连接后, 1 个 3×3 大小的卷积和 1 个 2×2 大小的卷积层构成。图片首先输入初始块, 再通过 4 个编码模块提取图像特征, 然后通过 4 个解码模块恢复图像大小。同时, 和 U-Net 网络结构相似, 编码器的输入层连接到相应解码器的输出层以充分利用图像浅层特征。最后, 输入剩余块输出语义分割结果。




图 5 U-Net 网络结构

Fig. 5 U-Net network structure

2.3 评价指标

为了评估卷积神经网络结构的性能, 本次研究采用了精确度 (Precision)、召回系数 (Recall Coefficient) 和 F1 分数 (F1-score) 等常用的性能评价指标, 具体公式如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (1)$$

$$\text{Recall Coefficient} = \frac{TP}{TP + FN} \quad (2)$$

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall Coefficient}}{\text{Precision} + \text{Recall Coefficient}} \quad (3)$$

式中: TP 代表真阳性, 是指滑坡区域正确提取为滑坡的像元数量; FP 代表假阳性, 是指将非滑坡错误

地提取为滑坡的像元数量；FN 代表假阴性，是指将滑坡错误提取为非滑坡的像元数量。F1-score 是精确度和召回系数的调和平均数，可以更好地表征模型的性能。根据公式可知，精确度是指所有被提取为滑坡像素中正确的提取比例，召回系数则是所有真实为滑坡的像元被正确判别的质量比例。

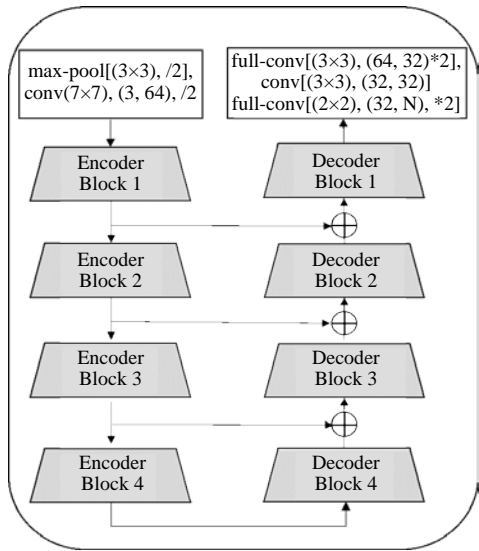
3 训练与验证

本次使用的卷积神经网络结构在 Pytorch 深度学习框架中利用 Python3.8 语言编程实现。选择 Adam 作为优化器，其具有计算效率高、调参简单、易于实现等优点。为了防止模型过拟合，每次训练和验证过程均采用 5 折交叉验证，首先数据集随机平均划分为 5 份，并分别取其中 1 份数据作为验证集，其余 4 份作训练集，进行 5 次的训练，并取评估指标的平均值评价模型的性能。Adam 优化器使用 Pytorch 推荐的参数作为初始值，初始学习率设置为 0.001， β 参数设置为 (0.9, 0.009)。采用等步长学习率衰减策略，每 30 个回次学习率衰减为原来的 0.1 倍。批量大小设置为 5，总共训练 90 回次。损失函数是算法寻找最优权重所必需的指标，选择交叉熵误差函数作为训练网络结构的损失函数。训练、验证和测试等过程均在 3.0 GHz Intel i7-9700 处理器工作站上执行，该工作站具有 32 GB 运行内存，GPU 型号为 NVIDIA GeForce RTX 2060，并在 NVIDIA CUDA Toolkit 10.1 下执行计算。

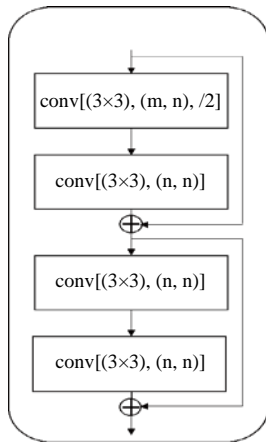
3.1 样本数量对模型的影响

训练样本数量的大小对卷积神经网络有效提取图像特征以实现目标任务具有重要作用。随机在数据库选取训练集数量分别为 100、200、300、400，并通过旋转、翻转、随机裁剪、调整对比度、增加高斯噪点等方式，分别增强训练数据集为 5 倍训练卷积神经网络。

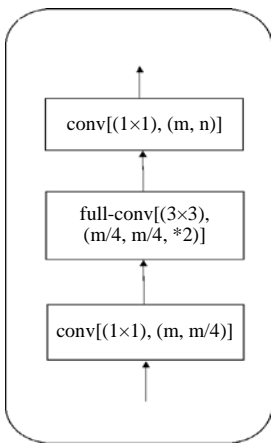
图 7~8 分别为不同样本数量 U-Net 提取精度和不同样本数量 LinkNet 提取精度，如图 7~8 所示，随着训练集样本数量的增多，评价指标逐步上升，当训练集为 400 个时，U-Net 和 LinkNet 模型的评价指标达到最高。



(a) LinkNet 网络



(b) 编码器



(c) 解码器

图 6 LinkNet 网络结构

Fig. 6 LinkNet network structure




图 7 不同样本数量 U-Net 提取精度

Fig. 7 U-Net extraction accuracy with different sample sizes




图8 不同样本数量 LinkNet 提取精度

Fig. 8 LinkNet extraction accuracy with different sample sizes

3.2 模型性能评估

网络参数及训练时间如表 1 所示, 根据 3.1 节可知, 当训练集数量为 400 时, U-Net 和 LinkNet 网络的模型评价指标最好。训练集和验证集按照 4 : 1 的比例, 随机选取 400 个样本作为训练集, 100 个样本作为验证集, 38 个样本作为测试集。因此采用基于该数量的训练集训练卷积神经网络模型, 并对验证集的图像进行滑坡的自动提取。根据表 1 可知, U-Net 和 LinkNet 网络结构的参数数量分别为 34.5×10^6 个和 13.4×10^6 个, 训练和验证的总时间约为 1.0h 和 0.6h。LinkNet 网络相比 U-Net 网络的训练参数数量大幅降低, 因此训练及验证所需的时间也大为减少。

LinkNet 相对于 U-Net 卷积神经网络的评估指标提升比例如图 9 所示。相对于 U-Net 网络结构, LinkNet 网络结构的精确度提升比例最高, 为 8.0%~10.0%左右。其次是 F1 分数, 提升约 4.0%~8.0%, 召回系数的提升比例最低, 为 2.0%~8.0%。因此, LinkNet 网络结构在滑坡自动提取任务中的表现整体上优于 U-Net 网络结构。

表 1 网络参数及训练时间

Table 1 Network parameters and training time

网络结构	参数/个	训练时间/h
U-Net	34.5×10^6	1.0
LinkNet	13.4×10^6	0.6




图9 LinkNet 模型性能提升比例

Fig. 9 LinkNet model performance improvement ratio

4 讨论与分析

为了进一步探究 U-Net 和 LinkNet 两种卷积神经网络在地震诱发滑坡自动提取任务中各自的特点, 选取测试集的样本进行深入对比, 并选出其中典型的滑坡提取情况进行分析。

根据图 10 中复杂背景图像语义分割结果对比, 可知 U-Net 卷积神经网络容易将河流、房屋、道路错误提取为滑坡区域, 其中以河流的错误提取最为明显。LinkNet 卷积神经网络则有助于减少这类将地物错误提取为滑坡区域的情况, 尤其是对于减少河流错误提取的效果最为明显。同时, 在长条状滑坡的提取中, LinkNet 的滑坡区域提取效果要优于 U-Net 卷积神经网络模型 (U-Net 容易将滑坡提取为非滑坡), 但对于滑坡边缘的提取效果则不如 U-Net 卷积神经网络 (见图 11)。

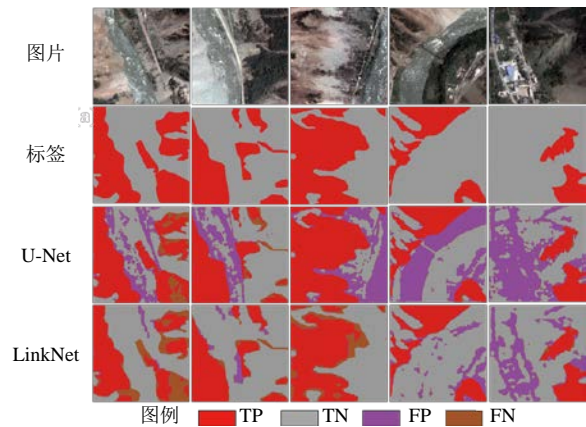


图 10 复杂背景图像语义分割结果对比

Fig. 10 Comparison of semantic segmentation results on complex background images




图 11 简单背景图像小型滑坡的提取

Fig. 11 Extraction of small landslides from simple background images

图 12 为简单背景图像大型滑坡的提取, 根据图 12 可知, 在简单背景图像大型滑坡的提取中,

LinkNet 卷积神经网络的提取效果不如 U-Net 卷积神经网络, 容易将大型滑坡中的部分滑坡区域提取为非滑坡。




图 12 简单背景图像大型滑坡的提取

Fig. 12 Extraction of large landslides from simple background images

5 结 论

在本次研究工作基于多光谱遥感影像建立滑坡数据库, 对比 U-Net 和 LinkNet 两种卷积神经网络在地震诱发滑坡自动提取中各自的特点, 主要结论如下:

(1) U-Net 和 LinkNet 卷积神经网络结构在区域性地震诱发滑坡自动提取中具有重大潜力, 精确度、召回系数和 F1 分数评价指标均达到了 0.8 以上。

(2) 在滑坡的自动提取中, LinkNet 网络结构要优于 U-Net 网络结构。精确度、F1 分数、召回系数提升率分别达到 8.0%~10.0%、4.0%~8.0%和 2.0%~8.0%。

(3) LinkNet 适用于复杂背景图像滑坡的提取及简单背景图像小型滑坡的提取, 而 U-Net 则更适用于简单背景图像大型滑坡的提取。相对于 U-Net 网络结构, LinkNet 网络结构可以减少将河流、房屋、道路等区域错误提取为滑坡的情况。

参考文献

[1] ZHANG S, ZHANG L M, PENG M, et al. Assessment of risks of loose landslide deposits formed by the 2008 Wenchuan earthquake[J]. *Natural Hazards and Earth System Sciences*, 2012, 12(5): 1381-1392.

[2] ZHANG S, ZHANG L M. Impact of the 2008 Wenchuan

earthquake in China on subsequent long-term debris flow activities in the epicentral area[J]. *Geomorphology*, 2017, 276: 86-103.

[3] 许冲. 基于最大似然法的地震滑坡信息自动提取及其可靠性检验[J]. *中国地质灾害与防治学报*, 2013, 24(3): 19-25.

XU Chong. Automatic extraction of earthquake-triggered landslides based on maximum likelihood method and its validation[J]. *The Chinese Journal of Geological Hazard and Control*, 2013, 24(3): 19-25.

[4] 闫琦, 李慧, 荆林海, 等. 灾后高分辨率遥感影像的地震型滑坡信息自动提取算法研究[J]. *激光与光电子学进展*, 2017, 54(11): 416-426.

YAN Qi, LI Hui, JING Lin-hai, et al. Automatic extraction algorithm of seismic landslide information based on after-calimity high-resolution remote sensing image[J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 416-426.

[5] 巨袁臻, 许强, 金时超, 等. 使用深度学习实现黄土滑坡自动识别[J]. *武汉大学学报(信息科学版)*, 2020, 45(11): 1747-1755.

JU Yuan-zhen, XU Qiang, JIN Shi-chao, et al. Automatic object detection of loess landslide based on deep learning[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1747-1755.

[6] 杨树文, 谢飞, 韩惠, 等. 基于SPOT5遥感影像的浅层滑坡体自动提取方法[J]. *测绘科学*, 2012, 37(1): 71-73, 88.

YANG Shu-wen, XIE Fei, HAN Hui, et al. Automatic extraction of shallow landslides based on SPOT-5 remote sensing images[J]. *Science of Surveying and Mapping*, 2012, 37(1): 71-73, 88.

[7] 文广超, 张哲玮, 肖学军, 等. 基于遥感数据的灾后滑坡信息快速提取方法[J]. *中国地质灾害与防治学报*, 2020, 31(2): 80-86.

WEN Guang-chao, ZHANG Zhe-wei, XIAO Xue-jun, et al. Method for rapid extraction information for post-disaster landslide based on remote sensing images[J]. *The Chinese Journal of Geological Hazard and Control*, 2020, 31(2): 80-86.

[8] 郭擎, 朱丽娅, 李安, 等. 基于NDVI变化检测的滑坡遥感精细识别[J]. *遥感技术与应用*, 2022, 37(1): 17-23.

GUO Qing, ZHU Li-ya, LI An, et al. Landslide identification method based on NDVI change detection[J]. *Remote Sensing Technology and Application*, 2022,

- 37(1): 17–23.
- [9] MOOSAVI V, TALEBI A, SHIRMOHAMMADI B. Producing a landslide inventory map using pixel-based and object-oriented approaches optimized by Taguchi method[J]. *Geomorphology*, 2014, 204: 646–656.
- [10] LI X J, CHENG X W, CHEN W T, et al. Identification of forested landslides using LiDar data, object-based image analysis, and machine learning algorithms[J]. *Remote Sensing*, 2015, 7(8): 9705–9726.
- [11] 龙玉洁, 李为乐, 黄润秋, 等. 汶川地震震后10 a绵远河流域滑坡遥感自动提取与演化趋势分析[J]. *武汉大学学报(信息科学版)*, 2020, 45(11): 1792–1800.
LONG Yu-jie, LI Wei-le, HUANG Run-qiu, et al. Automatic extraction and evolution trend analysis of landslides in Mianyuan River basin in the 10 years after Wenchuan earthquake[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(11): 1792–1800.
- [12] DING A Z, ZHANG Q Y, ZHOU X M, et al. Automatic recognition of landslide based on CNN and texture change detection[C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC). IEEE, 2016: 444–448.
- [13] GHORBANZADEH O, BLASCHKE T, GHOLAMNIA K, et al. Evaluation of different machine learning methods and deep-learning convolutional neural networks for landslide detection[J]. *Remote Sensing*, 2019, 11(2): 196.
- [14] LU H, MA L, FU X, et al. Landslides information extraction using object-oriented image analysis paradigm based on deep learning and transfer learning[J]. *Remote Sensing*, 2020, 12(5): 752.
- [15] WANG H J, ZHANG L M, YIN K S, et al. Landslide identification using machine learning[J]. *Geoscience Frontiers*, 2021, 12(1): 351–364.
- [16] CAI H J, CHEN T, NIU R Q, et al. Landslide detection using densely connected convolutional networks and environmental conditions[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 5235–5247.
- [17] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234–241.
- [18] LEI T, ZHANG Y X, LV Z Y, et al. Landslide inventory mapping from bitemporal images using deep convolutional neural networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(6): 982–986.
- [19] LIU P, WEI Y M, WANG Q J, et al. Research on post-earthquake landslide extraction algorithm based on improved U-net model[J]. *Remote Sensing*, 2020, 12(5): 894.
- [20] YI Y N, ZHANG W C. A new deep-learning-based approach for earthquake-triggered landslide detection from single-temporal RapidEye satellite imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 6166–6176.
- [21] BRAGAGNOLO L, REZENDE L R, DA SILVA R V, et al. Convolutional neural networks applied to semantic segmentation of landslide scars[J]. *Catena*, 2021, 201: 105189.
- [22] CHAURASIA A, CULURCIELLO E. LinkNet: exploiting encoder representations for efficient semantic segmentation[C]//2017 IEEE Visual Communications and Image Processing (VCIP). IEEE, 2017: 1–4.