

doi: 10.6046/zrzyyg.2021204

引用格式: 杨昭颖, 韩灵怡, 郑向向, 等. 基于卷积神经网络的遥感影像及 DEM 滑坡识别——以黄土滑坡为例[J]. 自然资源遥感, 2022, 34(2): 224–230. (Yang Z Y, Han L Y, Zheng X X, et al. Landslide identification using remote sensing images and DEM based on convolutional neural network: A case study of loess landslide[J]. Remote Sensing for Natural Resources, 2022, 34(2): 224–230.)

基于卷积神经网络的遥感影像及 DEM 滑坡识别 ——以黄土滑坡为例

杨昭颖^{1,2}, 韩灵怡¹, 郑向向¹, 李文吉¹, 冯磊¹, 王轶¹, 杨永鹏^{1,2}

(1. 中国自然资源航空物探遥感中心, 北京 100083; 2. 自然资源部航空地球物理与遥感地质重点实验室, 北京 100083)

摘要: 我国是滑坡灾害频发的国家之一, 近年来发生的灾难性地质灾害事件有 70% 以上都不在已知的地质灾害隐患点范围内, 亟须通过自动高效的滑坡识别技术方法开展大规模滑坡灾害排查。为了从海量遥感影像中快速识别滑坡的位置, 确定滑坡重点区, 支撑后续的解译与研究, 以黄土滑坡为例, 基于 GF-1 影像与数字高程模型 (digital elevation model, DEM) 数据开展滑坡识别研究。首先构建了遥感影像和 DEM 滑坡样本库, 然后应用通道融合卷积神经网络模型对滑坡样本进行分类, 最后将分类结果按照位置信息还原到遥感影像图中。实验结果表明模型的滑坡识别精度可达 95.7%, 召回率为 100.0%。研究所用模型的网络层数较少, 收敛速度快, 具有更高的效率与识别精度, 解决了在样本有限的情况下, 从遥感影像中快速确定滑坡重点区的问题, 以支撑大规模滑坡灾害排查。

关键词: 卷积神经网络; 滑坡识别; 遥感分类; DEM; 黄土滑坡

中图法分类号: TP 751; TP 399 **文献标志码:** A **文章编号:** 2097-034X(2022)02-0224-07

0 引言

我国是滑坡灾害频发的国家之一, 每年由滑坡造成的人员伤亡和财产损失极为严重。从 20 世纪 90 年代起, 国家先后开展了系统全面的地质灾害人工排查和群测群防。但是近年来发生的灾难性地质灾害事件有 70% 以上都不在已知的地质灾害隐患点范围内^[1], 亟须通过自动、高效的滑坡识别技术方法开展面向全国范围的大规模地质灾害排查。随着对地观测技术的迅猛发展, 遥感技术在大范围地质灾害调查中的应用也越来越普遍。从大量的遥感数据中快速、全面和准确地识别出滑坡对防灾减灾具有重要意义。

利用遥感技术识别滑坡先后经历了目视解译、基于像元的提取方法、面向对象的提取方法以及基于深度学习的提取方法 4 个阶段。目视解译的准确性一般比较高, 但是比较依赖专家的知识经验和主观性强, 费时费力, 难以满足大范围的遥感影像快速解译滑坡的需求。基于像元的滑坡提取方法是以

像元为分析单元, 基于某些算法模型, 从遥感影像中自动地提取出滑坡, 速度快, 也能保证一定的精度^[2], 但是基于像元的滑坡提取方法只能在同一分辨率基础上处理所有地物信息, 而且不能充分利用影像中丰富的结构、纹理等信息, 造成信息浪费, 提取结果也存在“椒盐现象”, 空间不连续^[3]。面向对象的信息提取方法最重要的特点是其处理的单元是单个对象, 不再是单个像元, 同时能在一定程度上模拟人脑对事物的认知过程, 把具有相同特征的对象分为同一类, 该方法能够有效避免“椒盐现象”, 提高识别精度。周志华等^[4]采用面向对象的方法, 用 eCognition 软件对实验数据进行了分割, 通过分析对象在影像上的植被指数、纹理、水体指数等规则特征, 实现了滑坡体对象的分类提取; 丁辉等^[5]采用面向对象的分类方法, 基于波段选择、尺度分析, 利用影像分割, 结合光谱特征、空间特征和地貌特征进行区域黄土滑坡识别, 得出滑坡后壁比滑坡体更易于识别的结论。

近年来, 越来越多的学者开始关注于基于深度学习的滑坡识别研究。Ye 等^[6]提出具有约束条件

收稿日期: 2021-06-30; 修订日期: 2021-12-28

基金项目: 自然资源部航空物理与遥感地质重点实验室课题“基于深度学习的滑坡体识别方法研究”(编号: 2020YFL26)和中国地质调查局项目(编号: DD20191006)共同资助。

第一作者: 杨昭颖(1992-), 女, 硕士, 工程师, 研究方向为数据挖掘与人工智能。Email: zhaoyingzhaoting@163.com。

通信作者: 韩灵怡(1990-), 女, 博士, 工程师, 研究方向为通讯工程与人工智能。Email: hanlingyi@mail.cgs.gov.cn。

的深度学习模型,应用到高光谱图像滑坡检测中,并将结果与支持向量机、光谱信息散度、光谱角度匹配方法做比较,得出深度学习提取高级特征对于滑坡检测的精度提升具有巨大潜力的结论;Ghorbanzadeh 等^[7]基于光学遥感和数字高程模型(digital elevation model, DEM)数据,比较了卷积神经网络、神经网络、支持向量机和随机森林方法在尼泊尔 Rasuwa 地区滑坡提取中的效果,得出尽管卷积神经网络的结果只比其他方法略占优势,但是如果存在足够的样本,卷积神经网络的提升空间将会比较大的结论;Wang 等^[8]使用集成的地理数据库,对比了卷积神经网络、随机森林、逻辑回归、强化学习、支持向量机 5 种机器学习方法在识别自然地形滑坡时的识别精度,在 5 种方法中,卷积神经网络的识别精度最高,同时指出基于机器学习和深度学习的识别技术在滑坡识别研究中具有出色的鲁棒性和解决问题的巨大潜力;巨袁臻等^[9]利用 Mask R-CNN 掩模区域卷积神经网络目标检测模块进行黄土滑坡自动识别,准确率虽然尚未达到 60%,但是证实了 Mask R-CNN 模型在黄土滑坡识别中的可行性;Ji 等^[10]使用注意力增强卷积神经网络从开放的卫星图像和 DEM 数据集识别滑坡,得出注意力机制和 DEM 数据能够有效提升滑坡识别精度的结论;Yu 等^[11]基于 Landsat 影像,构建了端到端的滑坡检测深度学习框架,并对 2015 年尼泊尔的滑坡进行检测,结果表明该框架的准确度比类似研究高出 44%,有可能适用于国家级的滑坡检测;Ullo 等^[12]基于无人机影像数据,利用 Mask R-CNN 和迁移学习算法进行山体滑坡检测,结果表明该方法在算法性能和稳健性方面均优于现有研究;Cheng 等^[13]在 YOLOv4 模型的基础上提出了一种新的 YOLO-SA 滑坡检测模型,对中国云南省乔家县和鲁甸县进行滑坡检测,并与 11 种现有的目标检测模型进行比较,结果表明 YOLO-SA 模型在参数数量、检测精度和运行速度方面均有所提升,并且可有效用于潜在滑坡检测;Catani^[14]提出了一种新的深度学习分类器 LanDLC,用于自动识别非标准图片中的滑坡和大规模位移,结果表明,该方法的平均准确率可达 87%~90%,并且始终高于现有常用的卷积神经网络算法;Hacıfendioglu 等^[15]分别使用 Resnet-50, VGG-19, Inception-V3 和 Xception 的预训练模型,对 2010 年土耳其 Gündoğdu 地区的山体滑坡进行自动检测,结果表明 Resnet-50 和 VGG-19 的成功率均达到 90% 以上。

在已有的使用深度学习进行滑坡识别的研究中,对于老滑坡的识别难度要高于对新滑坡的识别,

新滑坡和老滑坡的划分标准主要以发生的时间为主,老滑坡的发生时间比较久远,容易被环境改变原有的特征;新滑坡的发生时间与被发现的时间往往比较接近,例如植被覆盖较为丰富的西南地区,老滑坡很容易被植被覆盖而难以判断,而新滑坡则因为表面裸土未被植被覆盖而容易识别,因此西南地区主要以研究新滑坡为主,对老滑坡的研究还少之又少。相比于西南地区,黄土高原地区因植被覆盖相对较少,滑坡形态特征典型,边界轮廓清晰,老滑坡相对容易识别^[5]。在现有研究中,滑坡识别模型往往较为复杂,特别是在样本有限的情况下,识别精度不高,且泛化能力有限,其原因可能是滑坡识别中需兼顾滑坡的位置与范围。本研究以黄土滑坡为例,基于高分一号(GF-1)影像与 DEM 数据开展滑坡识别研究,使用卷积神经网络对融合后的数据进行分类,从而实现滑坡的快速识别。以期从海量遥感影像中快速识别滑坡的位置,用于滑坡重点区的确定,支撑后续的解译与研究。

1 研究区概况与数据源

研究区选取了甘肃省东南部的静宁县、庄浪县和张家川回族自治县(简称张家川县)3 个县,总面积约 5 058 km²。研究区地处黄土高原丘陵沟壑区,地理位置接壤,地貌类型主要为侵蚀构造低山丘陵、剥蚀堆积黄土丘陵、侵蚀堆积河谷平原等。滑坡特征以低速蠕滑为主,高速滑动较少。收集灾害领域专家结合遥感影像和 DEM 数据对研究区滑坡灾害进行解译,得到老滑坡 320 处,其中滑坡面积最大为 1 261 620 m²,最小为 4 989 m²,平均为 122 658 m²。滑坡的分布情况如图 1 所示。图 1 中底图为 GF-1





图1 研究区滑坡分布图

Fig. 1 Typical landslide examples

B3(R), B2(G), B1(B)合成影像。在这些解译的老滑坡中,主要有未改造老滑坡和已改造老滑坡之分。未改造老滑坡基本具备滑坡的主要特征,如滑坡后壁、侧壁、前缘堆积等,识别难度相对较小。已改造老滑坡又分为自然改造和人为改造,自然改造主要为降雨、风化、植被覆盖等自然因素,变化相对缓慢,往往能够保留老滑坡的大部分特征;人为改造对老滑坡的影响往往较大,比如将老滑坡改造为梯田,或

者在滑坡体上建造房屋、道路等,会使老滑坡边缘模糊,甚至会与周围环境融为一体,在滑坡解译过程中影响滑坡边界的界定,甚至无法分辨出滑坡的特征。图2为典型滑坡的示例,(a)为未改造老滑坡,(b)为已改造老滑坡,图中可见老滑坡被改造为梯田,(c)为已改造为梯田和房屋的老滑坡,(d)为已改造老滑坡,滑坡前缘部分被改造为道路。



(a) 未改造老滑坡

(b) 已改造老滑坡 1

(c) 已改造老滑坡 2

(d) 已改造老滑坡 3

图2 典型滑坡示例

Fig. 2 Typical landslide examples

2 数据处理与方法

2.1 数据处理

数据处理主要解决样本制作和样本增广问题。制作样本的数据源采用 2 m 空间分辨率的 GF-1 影像和 30 m 空间分辨率的 DEM 数据,标签部分用收集到的专家解译矢量数据进行标注。为了使遥感影像与 DEM 数据在空间上能够匹配,首先对 DEM 数据进行重采样,重采样后的 DEM 数据空间分辨率为 2 m。通过分析所有滑坡外接矩形的长和宽,得出将滑坡样本的大小设为 512 像素×512 像素最为合适。对重采样后的 DEM 和遥感影像以相同的方式进行裁切,将裁切后的图像分为有滑坡和无滑坡 2 类,有滑坡的图像为正样本,用 1 表示;无滑坡的图像为负样本,用 0 表示。

正样本的裁切方式分为以滑坡为中心、滑坡在左上角、左下角、右上角、右下角 5 种策略,主要是因为背景对滑坡的识别有重要的影响,在背景和滑坡区分度不大的情况下,如果只是采用中心裁切,模型很可能会学到滑坡的位置特征,即滑坡在图像中心的规律,这并不是真正想要的滑坡的特征。此外,这也是一种有效的解决样本有限的方法,能够扩充正样本的数据规模。

负样本的裁切方式比较简单,理论上可以认为除了正样本分布的区域,其他区域都是负样本。但是由于滑坡解译具有人为主观性,在解译的过程中,可能会有一些滑坡被漏掉,而且负样本的数量远远超过正样本的数量,因此,制作负样本时,在剔除滑坡的部分,将影像裁切为 512 像素×512 像素大小的图像,选取与正样本数量均衡的负样本。对于每一张图像,人工挑选没有滑坡发育的图像纳入负样本。DEM 样本制作与影像样本制作一致,每一张影像对应相同位置的 DEM 数据。最终生成的样本由裁切后的影像图像、DEM 数据和标签构成,一共形成 2 154 个样本。

2.2 研究方法

从样本制作的方式可以看出,本文将滑坡识别问题定义为分类问题,即只判断每张图像上是否存在滑坡,无需确定滑坡在图像上的具体位置及范围,这样可以在海量遥感影像中快速地确定滑坡重点区,缩小人工解译滑坡的范围,提升滑坡识别的精度和效率。

本文识别滑坡主要采用卷积神经网络的方法。卷积神经网络是一种解决图像分类问题的方法,由输入层、卷积层、池化层和全连接层组成。在经过多次调整网络结构并实验验证后,综合考虑训练精度与学习效率,设计了如图 3 所示的模型结构。




图3 模型结构图

Fig.3 Model structure diagram

卷积层采用 5×5 和 3×3 的滤波器,设 $F(s,t)$ 为滤波器, $G(x,y)$ 为图像在 (x,y) 点的值,是一个三维数组, $G(x,y) \in [0,255]$ 表示每一维的数据值都在 $0 \sim 255$ 之间,则 (x,y) 点的卷积值 $C(x,y)$ 计算公式为:

$$C(x,y) = \sum_{t=-\infty}^{\infty} \sum_{s=-\infty}^{\infty} F(s,t) \times G(x-s,y-t), \quad (1)$$

式中: $G(x,y) \in [0,255]$; $x,y \in [0,512)$ 。

池化层采用最大输出方式,滑动窗口大小为 2×2 ,步幅为 2。隐藏层的激活函数为 ReLU,全连接层的激活函数为 Sigmoid。损失函数采用公式为:

$$E = -\frac{1}{N} \sum_{j=1}^N \sum_{i=1}^k y_i \cdot \log_2 p_i, \quad (2)$$

式中: y_i 为类别 i 的真实标签; p_i 为第 i 类的概率; N 为样本总数; k 为类别数。

由于样本包含遥感图像和 DEM 数据,因此在输入卷积神经网络进行训练前,首先对两种数据源做通道融合处理。由于 DEM 为单通道数据, (x,y) 点的值表示该点的高程值,在本文研究区内高程范围为 $[1\ 288, 2\ 846]$ m,因此,在通道融合前需要对 DEM 数据进行归一化处理,使高程值的范围在 $[0, 255]$ 之间。归一化公式为:

$$Q(x,y) = \frac{P(x,y) - v_{\min}}{v_{\max} - v_{\min}} \times 255, \quad (3)$$

式中: $Q(x,y)$ 为归一化之后的高程值; $P(x,y)$ 为原始高程值; $v_{\min}$ 和 $v_{\max}$ 分别为原始高程值的最小值和最大值。

遥感图像在 (x,y) 点的值为 $G(x,y) = [r_{xy}, g_{xy}, b_{xy}]$,其中 $r_{xy}, g_{xy}, b_{xy} \in [0,255]$,为三维数组,归一化的 DEM 数据在 (x,y) 点的值 $Q(x,y) = [p_{xy}]$, $p_{xy} \in [0,255]$ 为一维数组,对遥感图像和归

一化后的 DEM 数据进行通道融合,得到 $H(x,y) = [r_{xy}, g_{xy}, b_{xy}, p_{xy}]$ 。对应的卷积神经网络中的卷积公式(1)改为:

$$C(x,y) = \sum_{t=-\infty}^{\infty} \sum_{s=-\infty}^{\infty} F(s,t) \times H(x-s,y-t), \quad (4)$$

式中: $H(x,y) \in [0,255]$; $x,y \in [0,512)$ 。 $H(x,y) \in [0,255]$ 表示每一维的数据值都在 $0 \sim 255$ 之间。

将测试数据输入到训练好的卷积神经网络模型后,得到每张图像的预测类别及概率,预测类别为每张图像是否存在滑坡,概率为每张图像所在区域存在滑坡的概率。将预测为 1 的图像按照图像自带的地理坐标叠加到影像底图中,并对预测区域用高亮显示,即可得到预测的滑坡重点区。

3 实验与分析

研究区总共有样本 2 154 个,分布在静宁县、庄浪县和张家川县,实际训练时,设计了 2 组实验。将庄浪县划分为训练部分和测试部分,图 1 红框内为测试部分,红框外为训练部分。实验一用静宁县和张家川县的样本数据作为训练数据,庄浪县的测试数据用来测试。实验二用静宁县、张家川县和庄浪县训练部分作为训练数据,庄浪县的测试数据用来测试。实验训练与测试样本的统计信息如表 1 所示。

表 1 训练与测试样本统计信息表

Tab.1 Training and test sample statistics table

实验划分	样本组成	正样本数量	负样本数量	样本总数
实验一训练	静宁县 + 张家川县	608	626	1 234
实验二训练	静宁县 + 张家川县 + 庄浪县训练部分	798	818	1 616
测试	庄浪县测试部分	155	383	538

在实验过程中,通过不断调整 batch_size 和 ep-

och 的参数值,得到结果精度最高时,设置 $batch_size = 8, epoch = 100$ 。实验一训练集的精度和损失情况如

图 4 所示。实验二的训练集精度 (acc) 和损失情况 (loss) 如图 5 所示。




图 4 实验一训练精度与损失

Fig. 4 Experiment 1 training accuracy and loss




图 5 实验二训练精度与损失

Fig. 5 Experiment 2 training accuracy and loss

利用准确率 (Accuracy)、精度 (Precision)、召回率 (Recall)、F1 指标评价定量实验结果。各项指标计算方法如下:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}, \quad (5)$$

$$Precision = \frac{TP}{TP + FP}, \quad (6)$$

$$Recall = \frac{TP}{TP + FN}, \quad (7)$$

$$F1 = \frac{(1 + a^2) \cdot Precision \cdot Recall}{a^2 \cdot (Precision + Recall)}, a = 1, \quad (8)$$

式中: TP 为当标签为正样本时分类为正样本的数目; FN 为标签为正样本时分类为负样本的数目; FP 为当标签为负样本时分类为正样本的数目; TN 为当标签为负样本时分类为负样本的数目。

表 2 展示了实验一与实验二的测试结果,从表中可以看到,实验二模型的正确率、精度和 F1 均有提升。将实验二的识别为 1 的结果按照图像自带的位置信息叠加到影像底图中,并将图像的边缘用高亮显示,得到预测的滑坡重点区,其中,如果预测为

1 的图像之间接壤,则在显示的时候将其合并在一起显示,如图 6 所示。图 6 中,预测的滑坡重点区用紫红色框圈出,叠加上绿色线条圈出的滑坡矢量数据,可以看到,除了少量识别区域没有包含滑坡,大

表 2 实验一与实验二的测试结果

Tab. 2 Test results of experiment 1 and experiment 2

实验	TP	FP	FN	TN	正确率/%	精度/%	召回率/%	F1/%
实验一	155	17	0	366	96.8	90.1	100.0	94.8
实验二	155	7	0	376	98.7	95.7	100.0	97.8




图 6 滑坡识别结果图

Fig. 6 Results of landslide recognition

部分滑坡都在识别的重点区范围内,能够大大减少人工解译的范围。

实验二的测试结果要优于实验一的测试结果,表现在准确率、精度和 $F1$ 均有所提升,主要因为实验二中 FP (即 0 判断为 1)的值有所下降,这说明加入了部分庄浪县的样本参与模型的训练,一方面样本量增加对于模型精度的提升有帮助,另一方面增加部分具有同测试区相同特点的样本,对于模型的泛化能力有提升,因此从整体上看,降低了负样本的误判。但是两次实验并没有提升 TP (1 判断为 1)的值,所以两次实验的召回率是一样的。至于召回率在保证测试数据没有参加过训练的情况下,经过多次实验验证,确实能达到 100%。分析原因可能是因为模型在决策时倾向于将测试样本判断为 1,再通过一次次迭代逐渐将预测为 1 的数量减少,因此出现了一些 0 判断为 1 的情况。

4 结论

本文以黄土滑坡为例,基于 GF-1 影像与 DEM 数据开展滑坡识别研究,构建了研究区黄土滑坡遥感影像与 DEM 分类样本库;应用通道融合卷积神经网络模型对滑坡样本进行分类,实验结果表明模型的识别精度为 95.7%,召回率达到 100%。本文所用模型的网络层数较少,能够快速收敛,具有更高的效率与提取精度,解决了在样本有限的情况下,从遥感影像中快速确定滑坡重点区的问题,对大规模滑坡灾害排查提供了技术支撑。

在实验过程中发现,由于研究区内滑坡数量有限,因此扩大实验规模需要增加研究区域的范围,而研究区域越大,滑坡的特征就会更多样化,对于滑坡的提取也会越困难。因此,对滑坡的识别是一个渐进的过程,通过小规模研究区域的训练样本,训练出识别模型,对邻近的区域进行滑坡识别,在后续的工作中,新识别出的样本将继续加入到模型中继续优化,逐步积累样本,优化模型,不断扩大研究区域,直至扩展到整个黄土区。此外,还应从进一步增加训练样本类型提升模型的泛化能力,对大规模滑坡快速自动识别具有重要意义。

志谢: 感谢童立强、郭兆成、王珊珊等地质灾害调查监测团队成员提供的滑坡解译数据,为本文研究提供了数据支撑。感谢林雪敏为本文制图提供的建议和帮助。

参考文献 (References):

- [1] 许强,董秀军,李为乐. 基于天-空-地一体化的重大地质灾害隐患早期识别与监测预警[J]. 武汉大学学报(信息科学版),2019,44(7):957-966.
- [2] 李松,李亦秋,安裕伦. 基于变化检测的滑坡灾害自动识别[J]. 遥感信息,2010(1):27-31.
- [3] 张帅娟. 变化检测和面向对象结合的高分辨率遥感影像滑坡体提取方法研究[D]. 成都:西南交通大学,2017.
- [4] 周志华,林维芳,许高程,等. 基于面向对象的滑坡快速识别技术研究[J]. 安徽农业科学,2012,40(5):3017-3018,3071.
- [5] 丁辉,张茂省,朱卫红,等. 黄土滑坡高分辨率遥感影像识别——以陕西省延安市地区为例[J]. 西北地质,2019,52(3):231-239.
- [6] Ye C M, Li Y, Cui P, et al. Landslide detection of hyperspectral remote sensing data based on deep learning with constraints [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(12):5047-5060.
- [7] 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):1-21.
- [8] Wang H J, Zhang L M, Yin K S, et al. Landslide identification using machine learning[J]. Geoscience Frontiers, 2020, 12(1):351-364.
- [9] 巨袁臻,许强,金时超,等. 使用深度学习方法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.
- [10] Ju Y Z, Xu Q, Jin S C, 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.
- [11] Ji S P, Yu D W, Shen C Y, et al. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks[J]. Landslides, 2020:1-16.
- [12] Yu B, Chen F, Xu C. Landslide detection based on contour-based deep learning framework in case of national scale of Nepal in 2015[J]. Computers & Geosciences, 2020, 135:104388.
- [13] Xu Q, Dong X J, Li W L. Integrated space-air-ground early detection, monitoring and warning system for potential catastrophic geohazards[J]. Geomatics and Information Science of Wuhan University, 2019, 44(7):957-966.
- [14] Li S, Li Y Q, An Y L. Automatic recognition of landslides based on change detection[J]. Remote Sensing Information, 2010(1):27-31.
- [15] Zhang S J. Research on landslide body extraction method from high-resolution remote sensing image based on change detection and object-oriented [D]. Chengdu: Southwest Jiaotong University, 2017.
- [16] Zhou Z H, Lin W F, Xu G C, et al. Research of fast landslide recognition based on object-oriented technology[J]. Journal of Anhui Agricultural Sciences, 2012, 40(5):3017-3018,3071.
- [17] Ding H, Zhang M S, Zhu W H, et al. High resolution remote sensing for the identification of loess landslides: Example from Yan'an City[J]. Northwestern Geology, 2019, 52(3):231-239.
- [18] Wang H J, Zhang L M, Yin K S, et al. Landslide identification using machine learning[J]. Geoscience Frontiers, 2020, 12(1):351-364.
- [19] Ju Y Z, Xu Q, Jin S C, 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.
- [20] Ji S P, Yu D W, Shen C Y, et al. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks[J]. Landslides, 2020:1-16.
- [21] Yu B, Chen F, Xu C. Landslide detection based on contour-based deep learning framework in case of national scale of Nepal in 2015[J]. Computers & Geosciences, 2020, 135:104388.
- [22] Ullo S L, Mohan A, Sebastianelli A, et al. A new Mask R-CNN-based method for improved landslide detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 13(12):5047-5060.

- ing, 2021, 14: 3799 – 810.
- [13] Cheng L, Li J, Duan P, et al. A small attentional YOLO model for landslide detection from satellite remote sensing images[J]. *Landslides*, 2021, 18(8): 2751 – 65.
- [14] Catani F. Landslide detection by deep learning of non – nadir and crowdsourced optical images[J]. *Landslides*, 2021, 18(3): 1025 – 44.
- [15] Hacıfendioglu K, Demir G, Başağa H B. Landslide detection using visualization techniques for deep convolutional neural network models[J]. *Natural Hazards*, 2021, 109(1): 329 – 50.

Landslide identification using remote sensing images and DEM based on convolutional neural network: A case study of loess landslide

YANG Zhaoying^{1,2}, HAN Lingyi¹, ZHENG Xiangxiang¹, LI Wenji¹,
FENG Lei¹, WANG Yi¹, YANG Yongpeng^{1,2}

(1. *China Aero Geophysical Survey and Remote Sensing Center for Natural Resources, Beijing 100083, China*; 2. *Key Laboratory of Airborne Geophysics and Remote Sensing Geology, Ministry of Natural Resources, Beijing 100083, China*)

Abstract: China is one of the countries with frequent landslide disasters. In recent years, more than 70% of the catastrophic geological hazards have occurred not within the scope of known hidden danger points of geological hazards in China. Therefore, there is an urgent need for investigating large – scale landslide disasters using automatic and efficient technologies and methods for landslide identification. To quickly identify the location of landslides from massive remote sensing images, it is necessary to determine the key areas of landslides to support subsequent interpretation and research. This study investigated loess landslide identification based on GF – 1 images and digital elevation model (DEM) data. First, a database of remote sensing images and DEM landslide samples was constructed. Second, the landslide samples were classified using the channel fusion convolutional neural network model. Finally, the classification results were restored to the remote sensing images according to the location information. Experimental results showed that the model yielded landslide identification accuracy of 95.7% and a recall rate of 100.0%. The model used in this study has a small number of network layers, a high convergence speed, and higher efficiency and identification accuracy. As a result, it allows for the quick identification of key landslide areas from remote sensing images in the case of a limited number of samples, thus supporting the investigation of large – scale landslide disasters.

Keywords: convolutional neural network; landslide identification; remote sensing classification; DEM; loess landslide

(责任编辑: 张 仙)