

•智能交叉科学与工程•

DOI:10.12454/j.jsuese.202400651



本刊网刊

基于 VGG-Unet 模型的黄土地震滑坡自动识别方法

王连升¹,李平^{1,2*},穆松伟¹,拓籽含¹,李晨¹

(1. 防灾科技学院 河北省地震灾害防御与风险评估重点实验室,河北 廊坊 065201;
2. 中国地震局工程力学研究所 地震工程与工程振动重点实验室,黑龙江 哈尔滨 150080)

摘要:黄土地区是地震滑坡的易发区和频发区,为了获得详细的黄土地震滑坡分布情况,需对黄土地区地震滑坡进行快速识别,野外调查和遥感技术是滑坡识别工作的两种重要手段。本文在野外调查滑坡数据的基础上,基于卫星影像平台,应用 VGG-Unet 模型对黄土地震滑坡进行自动识别。首先,以在甘肃省、宁夏回族自治区调查的部分黄土地震滑坡为基础,准确总结了其在卫星影像上的地形、坡度、滑体长度、滑体宽度、平面形态、剖面、色调等特征,并以这些特征辅助遥感卫星影像目视解译,提取卫星影像黄土地震滑坡数据库,最终共提取了 494 幅原始图像,涵盖黄土地震滑坡 1 052 个,作为输入图像,以提高模型的泛化能力。其次,应用 VGG-Unet 模型,采用 Python 编程语言,基于 PyTorch 框架,对基于卫星影像黄土地震滑坡数据库的实验数据集进行训练与验证,并对验证集黄土地震滑坡图像进行自动分割,以提高模型的识别精度。为了使模型的分割预测效果达到最佳,用 3 组数据集、4 组实验进行对比分析,选取最佳模型性能指标。并对验证集黄土地震滑坡典型区域的预测效果进行检验。结果表明:VGG-Unet 模型在经裁剪扩充至 613 幅图像的数据集上展现出了最优的训练与验证性能,尤其在未知数据集(验证集)中表现较好,其验证准确率可达 89.57%,均交并比可达 70.13%, F_1 可达 81.11% 且召回率达到了 80.53%,模型性能指标均较高。并且,模型在地形与剖面特征发育较好的黄土地震滑坡处识别效果往往更加准确,而对于色调和剖面特征较为模糊的滑坡及小型滑坡存在少量漏判,在地层凹凸不平等复杂地形处则存在少量误判。但总体而言,VGG-Unet 模型可以有效预测黄土地震滑坡区域,结果较为准确且时间、人力成本更低。因此,本文方法可用于迅速分割识别同类型滑坡区域,在野外调查前自动分割识别滑坡位置,以此辅助现场寻找黄土地震滑坡,为大规模滑坡灾害排查工作提供技术支持。

关键词: VGG-Unet 模型;黄土地震滑坡;滑坡识别;卫星影像;野外调查

中图分类号:P65

文献标志码:A

文章编号:2096-3246(2026)02-0084-12

中国西北黄土高原地区面积广,地质灾害频发,尤其以滑坡灾害居多^[1]。大多数黄土地震滑坡的滑动速度快、覆盖范围广、具有突发性及不可预测性^[2],严重威胁人民生命财产安全。在黄土地区滑坡灾害与危险评估的研究^[3]中,滑坡识别结果可以呈现滑坡发展状态并反映其分布情况,为已发生滑坡地区的安全性、易损性和滑坡治理等问题提供基础数据,因此开展滑坡识别方法研究具有重要意义^[4]。传统的滑坡识别工作大多依赖专业人员开展野外研究,面临工程量巨大、成本高、耗时费力等问题。随着科技的发展,利用遥感技术进行滑坡识别具有方便、快捷和成本低等优点,成为主要发展趋势。

近年来,利用遥感技术进行滑坡识别的方法主要有目视解译、基于像元分类、面向对象分类和深度学习。目视解译方法的准确性、便捷性一般较高,但要求解译人员具有丰富的知识和经验,且受较强的主观性和解译效率低等限制^[5],很难满足在较大区域迅速识别滑坡的需要。基于像元分类方法由于每个像元之间是相互独立的,相邻像元的分类结果可能并不相同,处理结果存在大量椒盐噪声,同种地物可能被分类成不同类别,导致了地物的分类精度降低。Baatz 等^[6]提出了面向对象分类方法,其基本思路是:首先对研究区影像进行分割,将拥有相同特征的像元组成一个同质对象;其次对目标地物的光谱、形状、纹理、阴影、空间位

收稿日期:2024-08-15 修回日期:2024-10-23 网络出版日期:2024-12-17

基金项目:中国地震局地震工程与工程振动重点实验室重点专项(2020EEEEVL0303);国家自然科学基金项目(U1939209)

作者简介:王连升(1999—),男,硕士生。研究方向:岩土地震工程。E-mail: 2995494799@qq.com

*通信作者:李平,教授,E-mail: chinaliping1981@126.com

置等^[7]进行相关特征属性分析;最后建立对应的识别规则,对分割获得的同质对象进行信息提取和影像分类^[8]。目前,该方法对遥感影像进行分割时^[9]无法第一时间选取最优分割尺度参数^[10],需要人工多次尝试和调整,费时费力,难以满足实际需求。

深度学习方法在处理滑坡特征时会自动构建和选择特征图层,减少了人为干预造成的不完备性,且深度学习所容纳的样本量更大,所以更适用于大范围区域的滑坡识别,更多的学者开始采用此方法,开展滑坡识别研究。巨袁臻等^[11]基于开源谷歌地球影像创建黄土滑坡训练样本数据库,应用Mask R-CNN深度学习网络模型对大范围黄土历史滑坡进行了自动识别,证明了深度学习方法的可行性^[12],但识别准确率较低,仅为56%;杨昭颖等^[13]基于高分一号(GF-1)卫星影像并结合数字高程模型数据^[14-15]构建黄土滑坡数据库,应用通道融合卷积神经网络模型^[16]对滑坡与非滑坡进行了自动分类,但仍需将分类结果按图像自带的位置信息叠加到影像底图中,所以该方法仍处于半自动处理模式,且样本数量有限,导致模型的泛化能力较弱;李震等^[17]提出了一种利用迁移学习技术从GF-1卫星影像中提取汶川地震后滑坡信息的方法,通过在ImageNet数据集上预训练一个ResNet网络,再将其迁移到LinkNet架构中,实现了对滑坡区域的精确提取,但对于特征不明显的滑坡,提取时存在一定误差;姜万冬等^[18]使用Mask R-CNN结合困难样本进行学习,在贵州省毕节市的实验结果显示出低误报率的高性能表现,还提出了一种在频域内的小样本学习方法,即便数据输入减半,也能提升性能;赵通等^[19]提出了一种改进的DeepLabV3+模型,通过使用谷歌地球和高分6号遥感影像创建并公开了一个样本数量超过10 000、空间分辨率为2 m的深度学习滑坡数据集,用于在地震后的高分辨率遥感影像中快速识别滑坡。

然而,上述方法均未充分阐明如何准确提取滑坡信息,因此不能保证用于训练的滑坡数据的可靠性、真实性与准确性。此外,上述几种深度学习方法,均无大量野外调查滑坡数据与卫星影像中滑坡数据的对比验证,无法保证在卫星影像中提取的滑坡数据的准确性与可靠性,如可能将梯田误判为滑坡、漏提隐蔽小型滑坡、无法将植被覆盖的滑坡提取完整等。本文引入大量黄土地震滑坡的野外调查及卫星影像数据,经过滑坡边界划定和位置偏差修正,进行定量与定性分析,确定黄土地震滑坡在卫星影像中的提取参数,并利用这些参数精准提取黄土地震滑坡,以此建立滑坡样本数据库来训练模型。

目前,Unet模型^[20]已被广泛应用于医学图像处理、遥感图像分割、自动驾驶等领域。随着PyTorch和TensorFlow等框架的出现,学习和应用Unet模型更加便捷,也更容易将其与遥感卫星数据相结合,非常适合黄土地震滑坡图像的自动分割识别。VGG模型具有强大的特征提取能力,且结构简单、适应性强、拥有丰富的预训练权重,使得Unet网络在预测阶段能更准确地分类每个像素点。为提高黄土地震滑坡的准确性,采用VGG16作为Unet模型的主干特征提取网络构成VGG-Unet模型,基于PyTorch框架,在卫星影像平台上对黄土地震滑坡图像进行分割识别,通过对比实验发现,与直接使用Unet模型自动分割识别滑坡相比,VGG-Unet模型的识别结果更为准确。

1 研究区概况与数据源

本文研究区为甘肃省、宁夏回族自治区的部分黄土地震滑坡区域,该区域黄土覆盖广泛,覆盖率高达90%以上,主要发育为分布最为广泛的第四纪黄土,该类黄土颜色较单一,多为浅黄、灰黄、褐黄;粒径0.500~0.005 mm的颗粒含量大,约占一半;质地疏松、孔隙度大(孔隙一般为2~3 mm),垂直节理发育,有较强的湿陷性,常形成落水洞、陡壁。黄土堆积在新近纪或古近纪红岩丘陵之上,黄土滑坡极为发育,诱发因素多数为地震,少数为降雨、河流及沟谷腐蚀等。研究区出露地层自下而上依次为第三系红色泥岩、离石黄土、古土壤层、马兰黄土。第三系红色泥岩含粉砂较多,成块状,裂缝较发育,常构成滑坡体的滑面,其岩性对区域黄土滑坡的形成影响较大;离石黄土厚10~30 m,黏粒含量相对较高;古土壤层厚2~14 m,结构密实,具水平层理,黏粒含量很高,相对隔水;马兰黄土厚30~65 m,结构疏松、多孔,具垂直节理和强湿陷性,落水洞发育。黄土与下伏不同岩性的基岩组合,呈现出不同规模和类型的黄土地震滑坡。总结发现,一次大震或强震引发的黄土滑坡^[21]往往具有以下特征:单体规模大、平面形态多样、空间分布范围广、成群连片发育、发生滑坡处地层不连续且后壁和侧壁发育明显、低坡度、滑速高、滑距远,通常会堵塞河道、危害性巨大^[22]。通过野外调查辅助卫星影像解译发现,研究区黄土地震滑坡类型较全、数量较多,非常具有研究价值。

2021年,防灾科技学院地震滑坡研究团队对甘肃省和宁夏回族自治区的黄土地震滑坡开展了野外调查工作。为保证所选数据的代表性与多样性,基于野外调查结果选用了在甘肃省调查的552处、在宁夏回族自治区固原市西吉县调查的500处,共计1 052处黄土地震滑坡作为研究样本。这些样本包含了剪切型、

液化型、震陷型等自然形成的多种类型滑坡,以及经过人工改造的滑坡;同时包含了不同地理位置、不同震级、不同季节、不同天气条件下的黄土地震滑坡影像。此样本数据集可以确保模型学习到不同类型滑坡的特征,以此保证模型的泛化能力和在实际应用中的可靠性和有效性。根据野外调查结果及卫星影像分析,确定了黄土地震滑坡在卫星影像中的提取参数,并基于此参数在卫星影像中对黄土地震滑坡进行了精准提取与处理。本文遥感卫星影像是底图分辨率为 1.94 m 的天地图影像。

2 数据提取与处理

2.1 数据提取

2.1.1 定量分析参数

通过将大量野外调查数据与遥感影像数据进行比较与分析,最终确定所选用的定量分析参数,即识别标志分别是:1)地层、地形特征;2)坡度;3)滑体长度、滑体宽度。

野外调查发现,每处黄土滑坡发生地点均导致了地层的不连续。典型示例如权岔村王大汉组 1 号黄土滑坡,如图 1 所示。在野外调查图(图 1(a))中,红虚线处即为滑坡发生地点,明显可见出现了凹陷,即导致了地层的不连续;而在卫星影像图(图 1(b))中也表现为地形不连续,白线位置的条状纹理会突然发生错位或终止。所以,其为解译黄土地震滑坡的重要特征之一。




图 1 权岔村王大汉组 1 号黄土滑坡

Fig. 1 Loess Landslide No.1 in Wang Dahan Group, Quancha Village

野外调查还发现,大多数黄土滑坡的前缘经过了人工改造,因此识别黄土滑坡时需要关注完整的滑坡后壁和侧壁^[23]。在统计分析黄土滑坡坡度时发现,侧壁、后壁与滑坡体交界处的坡度呈现明显的跳跃变化,其坡度值域大多在 $0^{\circ}\sim 38^{\circ}$ 。图 2 为固原市西吉县吉强镇夏家大路村上堡子滑坡。由卫星影像图(图 2(a))可见,目视解译无法准确发现滑坡区域细微的坡度变化,因此可利用遥感图像处理软件 ENVI 提取高程数据中的坡度特征,并用蓝色波段表示地势急剧变化的区域(图 2(b)),可帮助圈定滑坡的侧壁与后壁,从而描绘出滑坡的轮廓特征。


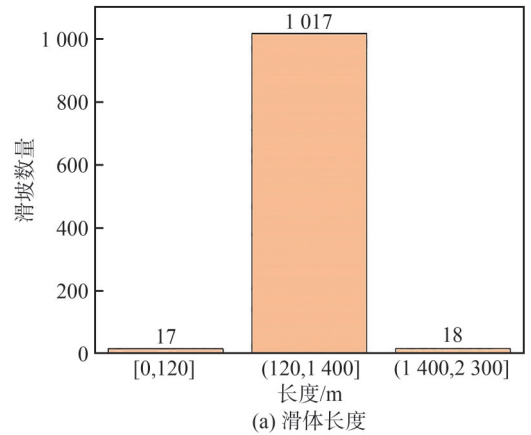



图 2 固原市西吉县吉强镇夏家大路村上堡子滑坡
Fig. 2 Upper Fortress Landslide in Xiajia Dalu Village, Jiqiang Town, Xiji County, Guyuan City

图 3 为黄土地震滑坡滑体长度与最宽滑体宽度统计。由图 3 可见,大多数黄土地震滑坡的滑体长度介于 120~1 400 m,最宽滑体宽度介于 100~1 200 m,可将其作为提取黄土地震滑坡的重要特征之一。



(a) 滑体长度



(b) 最宽滑体宽度

图 3 黄土地震滑坡滑体长度与最宽滑体宽度统计
Fig. 3 Statistical of length and maximum width of loess earthquake landslide

2.1.2 定性分析参数

通过历史回顾、文献分析及野外调查与遥感影像观察等手段,最终确定所选用的定性分析参数,即识别标志分别是:1)平面形态;2)剖面特征;3)色调特征。

将所调查黄土滑坡的平面形态进行分类发现,即

使一些滑坡已有数百年历史,但仍保留着原始的平面形态,包括圈椅形、圆弧形、矩形、三角形、舌形、马蹄形等,在遥感影像上非常明显,因此这是识别滑坡的先决条件。典型示例如和平村阳坡 1 号滑坡、苏堡村何家湾滑坡。图 4 为和平村阳坡 1 号滑坡矩形平面图,图 5 为苏堡村何家湾滑坡三角形平面图。



(a) 野外调查图 (b) 卫星影像图

图 4 和平村阳坡 1 号滑坡矩形平面图

Fig. 4 Rectangular plan of Landslide No. 1 in Yangpo, Heping Village



(a) 野外调查图 (b) 卫星影像图

图 5 苏堡村何家湾滑坡三角形平面图

Fig. 5 Triangular plan of the Hejiawan Landslide in Subao Village

以立眉村杨湾滑坡为典型实例,进行黄土地震滑坡剖面特征提取,图 6 为其对应的剖面形态标志图。图 7 和图 8 分别为其沿主滑方向和沿垂直主滑方向剖面图。由图 7 可见,沿滑坡的主滑方向,滑坡后壁的高程明显高于滑坡体;由图 8 可见,在垂直主滑方向,滑坡两侧壁的高程明显高于滑坡体,整体呈现出 3 侧高、中间低的剖面特征^[24]。将野外调查的黄土滑坡数据在卫星影像中进行解译发现,几乎所有滑坡都拥有此剖面特征,所以这是解译黄土地震滑坡的重要特征之一。



(a) 野外调查图 (b) 卫星影像图

图 6 立眉村杨湾滑坡剖面形态标志图

Fig. 6 Profile morphological marker map of Yangwan Landslide in Limei Village

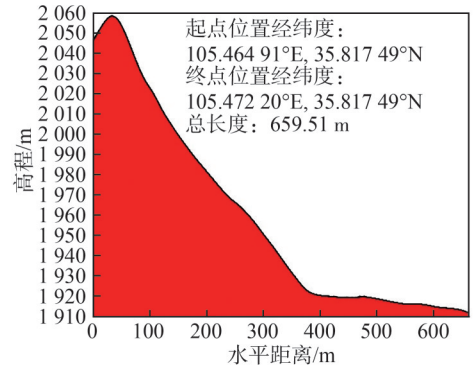


图 7 立眉村杨湾滑坡沿主滑方向剖面图

Fig. 7 Profile of Yangwan Landslide in Limei Village along the direction of the main slide

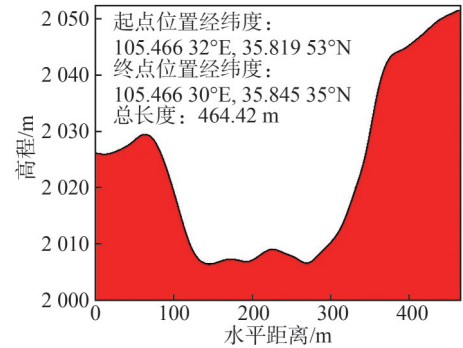


图 8 立眉村杨湾滑坡沿垂直主滑方向剖面图

Fig. 8 Profile of Yangwan Landslide in Limei Village along the direction of the vertical main slide

提取影像色调特征^[25]也可以解译黄土地震滑坡。图 9 为黄家三岔村上阳山 1 号滑坡色调标志图。通常情况下,高程发生急剧变化的交界处色调较深,即滑坡后壁和侧壁与滑坡体的交界处通常色调较深,而滑坡体与未滑区的色调较浅。经在卫星影像中观察分析发现,所调查的黄土滑坡数据中,绝大多数滑坡拥有此类色调特征,少数滑坡由于植被生长、雨水冲刷等,此类特征被掩盖,所以其可作为辅助识别黄土地震滑坡的重要特征之一。




图 9 黄家三岔村上阳山 1 号滑坡色调标志图

Fig. 9 Hue and tone sign map of Landslide No. 1 in Shangyangwa, Huangjia Sancha Village

2.2 数据处理

首先,建立实验数据集。从卫星影像中下载研究区内的黄土地震滑坡图像,每幅图像覆盖面积为 0.5~

图 10 中,输入图像尺寸为 512×512,通道数为 3。在 VGG 网络中,每经过一次最大池化操作,图像边长减半;在加强特征提取网络中,每一层由两部分组成,一部分由 2×2 反卷积层的上采样组成,另外一部分由 VGG 网络对应层输出进行复制和中心裁剪后得到,最后对这两部分进行拼接。

3.2 模型训练与验证

在深度学习模型训练中,设定适当的训练参数至关重要,参数的选择会直接影响模型的准确性和训练效率。为了找到最佳参数组合,本文实验采用不断调试的方法。最终确定将模型的最大学习率设置为 1×10^{-4} ,最小学习率设置为 1×10^{-6} ,并选择了学习率下降的 cos 方式,采用 Python 编程语言,基于 Pytorch^[31] 框架,在操作系统为 Windows 10, GPU 为 NVIDIA Quadro P2000(显存 20.9 GB)的环境下使用优化器 adam 进行训练,训练过程分为冻结阶段和解冻阶段。设置冻结阶段是因为在本文环境下机器性能不足。在冻结阶段,模型的主干被冻结,特征提取网络不变,仅

对网络进行微调,占用的显存较小;而在解冻阶段,模型的主干不再被冻结,特征提取网络会发生改变,占用的显存较大,网络所有的参数都会发生改变。为满足机器运行性能的最佳训练需求,通过不断调整冻结轮次(freeze epoch)和解冻轮次(unfreeze epoch),找到最佳组合,即冻结轮次和解冻轮次分别设置为 50 和 100。

在此基础上,为了获得最佳模型实验结果,设计了 4 组实验:首先,将数据集 1 分别输入以 ResNet 和 VGG16 作为主干特征提取网络的模型中,即原始 Unet 模型与 VGG-Unet 模型,分别对应实验 1、2。接着,分别将数据集 2、3 输入前两次实验中结果较好的模型,即 VGG-Unet 模型,对应实验 3、4。模型每 5 轮次(epoch)输出一次训练集精度,每 10 轮次输出一次验证集精度,同时每轮次都输出损失值。尽管 4 次实验均历时 7~9 h 才完成训练,但输出验证集分割结果仅在 5 min 内即可完成。这充分证明了训练后的模型在此环境下能够快速识别黄土地震滑坡区域。图 11 为训练流程图。

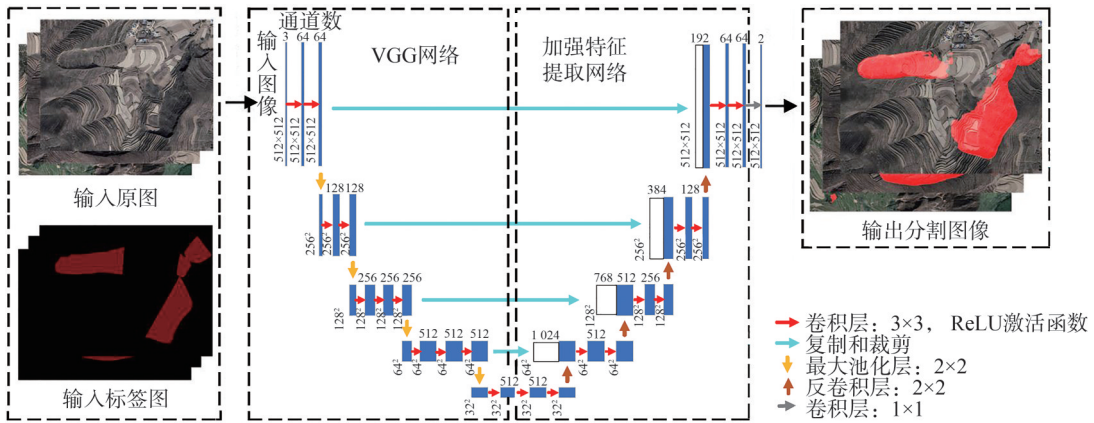


图 11 训练流程图

Fig. 11 Training flowchart

训练损失和验证损失在深度学习中起着至关重要的作用,不仅有助于评估模型的拟合能力和泛化能力,还能指导模型的优化和调参过程。训练损失的大小可用于判断模型是否收敛,验证损失是判断模型是否发生过拟合的重要依据之一。本文使用的损失由两部分组成,分别为交叉熵损失(cross entropy loss)和 Dice 损失。其中,交叉熵损失用于在语义分割平台利用 Softmax 函数对像素点进行分割,而 Dice 损失则常用于评价语义分割的效果,在类别较少时效果较好,而本文样本只被划分为滑坡与非滑坡两类,所以可用其提升模型对滑坡区域的识别能力。当模型训练损失持续下降且基本不变时,表明模型基本已经收敛,可终止训练,输出模型的分割结果。

图 12 为训练损失曲线。由图 12 可见:模型在冻结训练时,训练损失持续下降;在解冻训练时,训练损失

会暂时回升,然后持续下降。实验 1 的训练损失由 1.01 降至 0.59,实验 2 由 1.00 降至 0.16,实验 3 由 0.89 降至 0.10,实验 4 由 0.96 降至 0.22。




图 12 训练损失曲线

Fig. 12 Training loss curves

图 13 为验证损失曲线。由图 13 可见:在实验 1、2 中,模型的验证损失变化较为复杂,在 60~100 轮次,损失出现了回升,经判断这可能是模型发生过拟合的信号,验证损失分别由 0.87 降至 0.59、由 0.86 降至 0.57;在实验 3、4 中,模型的验证损失整体呈下降趋势,分别由 0.78 降至 0.23、由 0.85 降至 0.41。




图 13 验证损失曲线

Fig. 13 Validation loss curves

3.3 模型分割结果及评价

在深度学习中,模型的性能评价是一个复杂且关键的过程。训练集精度反映了模型在训练集上的性能表现,验证集精度体现了模型在未知数据(验证集)上的表现。虽然训练集精度提供了关于模型学习效果的初步信息,但验证集精度才是衡量模型泛化能力的关键指标。因此,模型的性能评价应更多地依据验证集精度。一个优秀的深度学习模型不仅需要在训练集上表现良好,更重要的是要在未知的新数据上也能保持较好的性能。为了分析本文模型对黄土地震滑坡的分割识别效果,以验证集上的准确率(accuracy,记为 A)、均交并比(MIoU,记为 M_{IoU})、召回率(recall,记为 R)和综合评价指标(F_1)为主,以训练集上的均交并比、类别平均像素准确率(precision,记为 P)、准确率为辅,评价模型的性能。具体而言,准确率是指所有预测正确的样本(包括正样本和负样本)占总样本的比例;均交并比是指模型预测的分割结果与实际标记间的重叠程度,即将每个类别的预测结果和真实值的交集与并集的比值求和再平均的结果;召回率是指模型捕获了多少真正的阳性结果,在滑坡识别中是指模型提取了多少真正的滑坡区域^[32],反映了模型对滑坡识别的鲁棒性,可作为模型应用于滑坡识别效果的重要指标;类别平均像素准确率是正确预测为正样本占全部预测为正样本的比例; F_1 为准确率和召回率的调和平均值^[33],暗示了预测模型的泛化性能。各项指标计算方法如下:

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (1)$$

$$M_{IoU} = \left(\frac{T_P}{T_P + F_P + F_N} + \frac{T_N}{T_N + F_P + F_N} \right) / 2 \quad (2)$$

$$R = \frac{T_P}{T_P + F_N} \quad (3)$$

$$P = \frac{T_P}{T_P + F_P} \quad (4)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (5)$$

式(1)~(5)中: T_P 为被模型判定为滑坡区域,实际也为滑坡区域的数目; F_N 为被模型判定为滑坡区域,但实际为非滑坡区域的数目; F_P 为被模型判定为非滑坡区域,但实际为滑坡区域的数目; T_N 为被模型判定为非滑坡区域,实际也为非滑坡区域的数目。

在模型停止训练后,输出其训练与验证结果并结合上述方法计算相关指标。表 2、3 分别为模型训练、验证性能指标^[34]结果。由表 2、3 可见,实验 2 的各项性能指标结果均高于实验 1,证明以 VGG16 作为 Unet 模型主干特征提取网络可以提高模型的各项性能。由表 2 可见,在训练集上,实验 3 的均交并比高达 82.96%、准确率达 94.43%、类别平均像素准确率达 90.35%,均高于实验 1、2、4。但由表 3 可知:实验 3 在验证集上的性能表现远低于训练性能指标结果,召回率仅达 75.09%、均交并比为 62.93%、准确率为 85.73%、 F_1 为 75.09%;而实验 4 在验证集上的召回率达 80.53%、均交并比为 70.13%、准确率为 89.57%、 F_1 为 81.11%,均高于实验 1~3 且其训练性能指标结果同样较好,训练均交并比达 68.96%、准确率为 89.20%、类别平均像素准确率为 79.15%。

表 2 模型训练性能指标结果

Tab. 2 Results of model training performance index

实验编号	均交并比/%	准确率/%	类别平均像素准确率/%
1	65.41	85.63	78.68
2	67.97	88.21	78.81
3	82.96	94.43	90.35
4	68.96	89.20	79.15

表 3 模型验证性能指标结果

Tab. 3 Results of model validation performance index

实验编号	均交并比/%	准确率/%	召回率/%	F_1 /%
1	65.47	86.57	76.46	77.55
2	67.86	87.75	79.49	79.43
3	62.93	85.73	75.09	75.09
4	70.13	89.57	80.53	81.11

鉴于实验4模型在训练与验证阶段均展现出了较好的性能指标,将其与3种已有的前沿滑坡识别方法进行比较,分别为:1)陈立福等^[35]提出的一种基于多特征交叉融合孪生网络(DACS-Net)的高分辨率雷达影像地震滑坡识别方法,其利用哨兵一号数据对巴布亚新几内亚和中国米林地震滑坡进行了实验,独立测试实验的滑坡识别精度分别可达70.75%和76.50%,召回率分别可达60.92%和71.20%, F_1 分别为65.46%和74.00%,准确率分别为91.0%和86.1%;2)刘佳等^[36]提出的一种自动识别和分析震后滑坡的方法,该方法融合了Google Earth Engine(GEE)的数据处理能力和Unet神经网络模型强大识别能力,在最佳参数组合下,不同地区滑坡分割准确率为72%~87%,平均交并比为57%~65%,召回率为36%~57%;3)Xiang等^[37]利用双特征Unet(DFPU-Net)模型,基于卫星光学影像对震后滑坡进行了深入研究,实现了快速、准确的识别,最终准确率达到了95.32%,交并比为68.02%,召回率为74.20%, F_1 为80.97%。通过与这些前沿研究的对比发现,除个别性能指标外,本文模型的绝大多数性能指标均较上述3种方法有所提高。辛鲁斌等^[38]通过收集光学遥感影像、数字高程模型(DEM)、地质和降雨等多种数据源,构建了一个滑坡数据集,并将多源数据输入Res-Unet模型,滑坡识别性能指标(P 、 R 、 F_1 、 M_{IOU})均在85%以上。尽管模型的识别性能同样较好,但本文的实验数据经过了野外调查的检验,与上述直接使用遥感影像采集的数据相比,更具可靠性、准确性与真实性。上述对比进一步验证了本文模型在黄土地震滑坡分割识别领域的有效性和先进性。

为了测试模型在验证集的应用效果,选取了实验4验证集的典型区域进行了分割效果展示,如图14所示。在模型分割效果图中,用蓝色实线框标注了滑坡位置,框内红色区域表示模型正确分割的结果,未标红区域为模型漏判区域,蓝色框外红色区域为模型误判区域。图14中:A类滑坡的坡度、滑坡体、地层与剖面特征清晰可辨,模型的识别效果较好,几乎没有出现漏判现象,仅有少量区域出现了误判;B类滑坡的平面形态、色调、地形和剖面等特征清晰可辨,模型识别效果同样较好,只有少数区域出现了漏判或误判;对于C类滑坡,由于部分滑坡轮廓被遮挡,且滑坡的地形特征较为模糊,模型出现了多处误判,如将梯田、地层凹凸不平处等误判为滑坡,同时少量滑坡发生了漏判,分割识别效果尚可;对于D类滑坡,由于色调和剖面特征较为模糊,模型出现了多处漏判,少数地方发生了误判,分割识别的效果不佳。上述分析表明:地形与剖面特征发育较好的滑坡,模型的识别效

果往往更加准确;对于色调和剖面特征较为模糊的滑坡及小型滑坡,模型容易产生漏判;对于地层凹凸不平复杂地形处则容易产生误判。总体而言,采用VGG-Unet模型的深度学习影像分割识别方法,可以有效预测黄土地震滑坡区域,结果较为准确且需要的时间、人力成本更低。




图14 验证集典型区域分割效果

Fig. 14 Typical area split effects of validation set

4 结论

本文首先在防灾科技学院地震滑坡研究团队进行野外调查的基础上,构建了可用于深度学习的黄土地震滑坡遥感影像样本数据集。其次,建立了VGG-Unet网络模型,并输入该数据集,采用Python编程语言,基于PyTorch框架,进行了训练与验证,得出最佳验证准确率为89.57%、均交并比为70.13%、召回率为80.53%、 F_1 为81.11%。最后,使用该模型对黄土地震滑坡验证集典型区域进行了测试,结果表明,VGG-Unet网络模型具有良好的泛化性和适应性,对于同类型区域具有很好的实际应用效果,能够自动分割识别大部分黄土地震滑坡,是进一步研究滑坡分布特征和进行危险性评价的基础,具有推广和深入研究的价值。主要结论如下:

1)基于野外调查的黄土地震滑坡特征标志,准确总结了黄土地震滑坡在卫星影像中的平面形态、剖面特征、色调特征、滑体长度与宽度、地形特征和坡度6种识别标志,并根据这些标志提取滑坡数据,使数据更为精准。与仅依赖有限样本或直接使用卫星、航空影像获取的数据相比,利用这一方法提取的滑坡训练集更为真实、可靠,且所训练的模型具有更强的泛化

能力。

2)通过实验 1、2 的对比分析发现,VGG16 作为 Unet 模型的主干特征提取网络,凭借其强大的特征提取能力、简洁的结构设计及丰富的预训练权重,在滑坡数据集的分割识别任务中展现出了显著的优势。当采用 VGG-Unet 模型进行上采样时,利用加强特征提取网络直接进行两倍上采样并进行特征融合,不仅方便了网络的构建,还赋予了网络更好的通用性。相较于传统的 Unet 模型,这种改进显著提升了模型的各项性能指标。

3)通过实验 2~4 的对比分析发现,VGG-Unet 模型在经裁剪扩充至 613 幅图像的数据集上展现出了优异的训练与验证性能。相比之下,在原始 494 幅图像的数据集上,模型的训练与验证性能指标均较低。这一现象可能源于裁剪操作增加了数据的多样性,使模型能够学习到更丰富的特征,进而提升了其性能。然而,在经旋转扩充至 920 幅图像的数据集上,虽然模型的训练性能指标在 3 次实验中最高,但其验证性能指标却降至最低。这暗示着旋转操作虽有效增加了数据量,但并未实质性地提高数据的多样性。在此类情况下,模型可能只是机械地记忆了训练集中的数据样本,而未能深入理解数据的特征及分布规律,导致其在验证集上泛化能力不足,验证性能指标下降。因此,在未来的研究中,应考虑采用更多样化的数据增强方法,不仅要增加数据的数量,更重要的是丰富数据的多样性和复杂性,从而全面提升模型的性能表现。

4)VGG-Unet 模型在验证集上的分割效果表明,黄土地震滑坡所具备的特征标志越清晰且完备,模型在分割工作中表现越出色。其高精度和准确性使计算机能够快速、准确地自动识别目标区域并进行定位。对于特征标志模糊、不完备的滑坡,虽然模型在分割过程中发生了少量误判和漏判,但大部分区域仍可准确进行分割识别。因此,本文方法可在野外调查前自动分割识别滑坡位置,辅助现场寻找黄土地震滑坡。同时,本文方法在大规模滑坡灾害排查和同震滑坡的详细编录工作中具有重要的实际应用价值,可以为滑坡灾害风险防控研究提供有力支撑。

【致谢】感谢防灾科技学院黄土地震滑坡研究团队提供的地震滑坡数据库,为研究开展提供了基础数据。

参考文献:

[1] Wang Lanmin, Chai Shaofeng, Bo Jingshan, et al. Triggering types, characteristics and disaster mechanism of seismic loess landslides[J]. Chinese Journal of Geotechnical Engineering, 2023, 45(8): 1543–1554. [王兰民, 柴少峰, 薄景

山, 等. 黄土地震滑坡的触发类型、特征与成灾机制[J]. 岩土工程学报, 2023, 45(8): 1543–1554.]

- [2] Peng Da, Bo Jingshan, Li Xiaobo, et al. Current status of research on Haiyuan earthquake-triggered landslides[J]. Journal of Institute of Disaster Prevention, 2017, 19(3): 28–36. [彭达, 薄景山, 李孝波, 等. 海原特大地震诱发滑坡灾害的研究现状[J]. 防灾科技学院学报, 2017, 19(3): 28–36.]
- [3] Peng Da, Yang Shun, Li Xiaobo. Distribution and mechanism of loess landslides induced by earthquake in Tongwei, Gansu Province[J]. The Chinese Journal of Geological Hazard and Control, 2017, 28(3): 31–38. [彭达, 杨顺, 李孝波. 甘肃通渭县黄土地震滑坡分布特征及发育机理[J]. 中国地质灾害与防治学报, 2017, 28(3): 31–38.]
- [4] Huangfu Wenchao, Qiu Haijun, Cui Peng, et al. Quick and automatic detection of co-seismic landslides with multi-feature deep learning model[J]. Scientia Sinica(Terrae), 2024, 54(7): 2347–2362. [皇甫文超, 邱海军, 崔鹏, 等. 利用多特征深度学习模型的同震滑坡智能化提取[J]. 中国科学: 地球科学, 2024, 54(7): 2347–2362.]
- [5] Dou Hongqiang, Huang Siyi, Jian Wenbin, et al. Research on rapid identification technology of highway landslide in mountainous areas of southeast Fujian based on remote sensing data[J]. Journal of Natural Disasters, 2023, 32(1): 217–227. [豆红强, 黄思懿, 简文彬, 等. 基于遥感数据的闽东南山区公路滑坡快速识别技术研究[J]. 自然灾害学报, 2023, 32(1): 217–227.]
- [6] Baatz M, Schäpe A. Object-oriented and multi-scale image analysis in semantic networks introduction: The necessity for integration of remote sensing and GIS[C]//Proceedings of the 2nd International Symposium on Operationalization of Remote Sensing(1999). Enschede: ITC, 1999: 1–7.
- [7] Martha T R, Kerle N, Jetten V, et al. Characterising spectral, spatial and morphometric properties of landslides for semi-automatic detection using object-oriented methods[J]. Geomorphology, 2010, 116(1/2): 24–36.
- [8] Lin Jiayuan, Wang Meimei, Yang Jia, et al. Landslide identification and information extraction based on optical and multispectral UAV remote sensing imagery[J]. IOP Conference Series: Earth and Environmental Science, 2017, 57(1): 012017.
- [9] Ding Hui, Zhang Maosheng, Zhu Weihong, 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. [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.]
- [10] Peng Ling, Xu Suning, Mei Junjun, et al. Earthquake-induced landslide recognition using high-resolution remote sensing images[J]. Journal of Remote Sensing, 2017, 21(4): 509–518. [彭令, 徐苏宁, 梅军军, 等. 地震滑坡高分辨率遥感影像识别[J]. 遥感学报, 2017, 21(4): 509–518.]

- [11] Ju Yuanzhen, Xu Qiang, Jin Shichao, 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. [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.]
- [12] Ji Shunping, Yu Dawen, Shen Chaoyong, et al. Landslide detection from an open satellite imagery and digital elevation model dataset using attention boosted convolutional neural networks[J]. *Landslides*, 2020, 17(6): 1337–1352.
- [13] Yang Zhaoying, Han Lingyi, Zheng Xiangxiang, 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. [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.]
- [14] Jian Xiaoting, Zhao Kang, Zuo Xiaoqing, et al. Landslides risk identification based on Faster R-CNN—A case study in Fugong county[J]. *Industrial Minerals & Processing*, 2022, 51(12): 19–24. [简小婷, 赵康, 左小清, 等. 基于 Faster R-CNN 目标检测的滑坡隐患识别——以福贡县城区为例[J]. *化工矿物与加工*, 2022, 51(12): 19–24.]
- [15] Tan Qiuyan, Wu Caiyan, Jia Jutao, et al. Automatic extraction of landslide from remote sensing image based on optimized FGFCM method[J]. *Journal of Southwest University of Science and Technology*, 2023, 38(1): 54–60. [谭秋焰, 吴彩燕, 贾菊桃, 等. 基于优化 FGFCM 方法的滑坡遥感影像自动提取[J]. *西南科技大学学报*, 2023, 38(1): 54–60.]
- [16] Cheng Libo, Li Jia, Duan Ping, et al. A small attentional YOLO model for landslide detection from satellite remote sensing images[J]. *Landslides*, 2021, 18(8): 2751–2765.
- [17] Li Zhen, Li Shanshan, Ge Xiaoqing. Transfer learning method for landslide extraction from GF-1 images after the Wenchuan earthquake[J]. *Journal of Remote Sensing*, 2023, 27(8): 1866–1875. [李震, 李山山, 葛小青. 迁移学习方法提取高分一号影像汶川地震震后滑坡[J]. *遥感学报*, 2023, 27(8): 1866–1875.]
- [18] Jiang Wandong, Xi Jiangbo, Li Zhenhong, et al. Landslide detection and segmentation using mask R-CNN with simulated hard samples[J]. *Geomatics and Information Science of Wuhan University*, 2023, 48(12): 1931–1942. [姜万冬, 席江波, 李振洪, 等. 模拟困难样本的 Mask R-CNN 滑坡分割识别[J]. *武汉大学学报(信息科学版)*, 2023, 48(12): 1931–1942.]
- [19] Zhao Tong, Zhang Shuangcheng, He Xiaoning, et al. Improved DeepLabV³⁺ model for landslide identification in high-resolution remote sensing images after earthquakes[J]. *National Remote Sensing Bulletin*, 2024, 28(9): 2293–2305. [赵通, 张双成, 何晓宁, 等. 改进的 DeepLabV³⁺ 模型用于震后高分遥感影像滑坡识别[J]. *遥感学报*, 2024, 28(9): 2293–2305.]
- [20] Jiang Song, Li Yanbo, He Xuqian, et al. Intelligent identification of landslide disaster based on deep learning of UAV images[J]. *China Safety Science Journal*, 2024, 34(7): 229–238. [江松, 李研博, 何旭乾, 等. 基于无人机影像深度学习的滑坡灾害智能识别[J]. *中国安全科学学报*, 2024, 34(7): 229–238.]
- [21] Wang Lanmin, Pu Xiaowu, Chen Jinchang. Distribution feature and disaster risk of earthquake-induced landslide in Loess Plateau[J]. *City and Disaster Reduction*, 2019(3): 33–40. [王兰民, 蒲小武, 陈金昌. 黄土高原地震诱发滑坡分布特征与灾害风险[J]. *城市与减灾*, 2019(3): 33–40.]
- [22] Lin Na, Feng Shanshan, Wang Bin, et al. Rapid landslide extraction and analysis based on XGBoost from high resolution remote sensing[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(8): 1300–1313. [林娜, 冯珊珊, 王斌, 等. 基于 XGBoost 模型的高分辨率遥感滑坡快速提取与分析研究[J]. *武汉大学学报(信息科学版)*, 2024, 49(8): 1300–1313.]
- [23] Mao Zhengjun, Yu Haiyong, Liang Wei, et al. Identification and feature analysis of regional loess landslides based on UAV tilt photogrammetry 3D modeling[J]. *Geology in China*, 2024, 51(2): 561–576. [毛正君, 于海泳, 梁伟, 等. 基于无人机倾斜摄影测量三维建模的区域黄土滑坡识别及特征分析[J]. *中国地质*, 2024, 51(2): 561–576.]
- [24] Chang Chaoyu, Yang Shun, Bo Jingshan, et al. A satellite image recognition method for loess seismic landslides[J]. *China Earthquake Engineering Journal*, 2022, 44(4): 811–818. [常晁瑜, 杨顺, 薄景山, 等. 黄土地震滑坡卫星影像识别方法[J]. *地震工程学报*, 2022, 44(4): 811–818.]
- [25] Li Xun, Yang Huan, Yin Zongmin, et al. Regional loess landslide recognition method research based on DEM and remote sensing image[J]. *Geography and Geo-Information Science*, 2017, 33(4): 86–92. [李勋, 杨环, 殷宗敏, 等. 基于 DEM 和遥感影像的区域黄土滑坡体识别方法研究[J]. *地理与地理信息科学*, 2017, 33(4): 86–92.]
- [26] Zhang Yuan, Kong Xiangsi, Zhang Shuo, et al. Application of deep learning technology in remote sensing image landslide identification[J]. *Beijing Surveying and Mapping*, 2022, 36(10): 1385–1390. [张圆, 孔祥思, 张烁, 等. 深度学习技术在遥感影像滑坡识别中的应用[J]. *北京测绘*, 2022, 36(10): 1385–1390.]
- [27] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[EB/OL]. (2015–05–18)[2024–08–15]. <https://arxiv.org/abs/1505.04597>.
- [28] Chen Jixing, Lu Pengfei, Yuan Zhaolin, et al. CUNet deep learning method and its application in fault recognition[J]. *Progress in Geophysics*, 2024, 39(2): 561–571. [陈继兴, 路鹏飞, 袁兆林, 等. CUNet 断层智能识别方法及其在断层识别中的应用研究[J]. *地球物理学进展*, 2024, 39(2): 561–571.]
- [29] Haciefendioğlu K, Demir G, Başağa H B. Landslide detec-

- tion using visualization techniques for deep convolutional neural network models[J]. *Natural Hazards*, 2021, 109(1): 329–350.
- [30] Chen Yan, Lu Jiahao, Hu Xiaochun, et al. Automated measurement method of phenotypic parameters of edible mushroom mycelium based on VGG–UNet[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(1): 233–240. [陈燕, 陆嘉豪, 胡小春, 等. 基于 VGG–UNet 的食用菌菌丝体表型参数自动测量方法[J]. *农业机械学报*, 2024, 55(1): 233–240.]
- [31] Jiang Weijie, Zhang Chunju, Xu Bing, et al. AED-net: Semantic segmentation model for landslide recognition from remote sensing images[J]. *Journal of Geo-Information Science*, 2023, 25(10): 2012–2025. [蒋伟杰, 张春菊, 徐兵, 等. AED-Net: 滑坡灾害遥感影像语义分割模型[J]. *地球信息科学学报*, 2023, 25(10): 2012–2025.]
- [32] Yu Xianyu, Yang Sen. Research on automatic landslide identification based on faster R-CNN and mask R-CNN[J]. *Journal of Geodesy and Geodynamics*, 2025, 45(1): 1–4. [于宪煜, 杨森. 基于 Faster R-CNN 和 Mask R-CNN 的滑坡自动识别研究[J]. *大地测量与地球动力学*, 2025, 45(1): 1–4.]
- [33] Cai Haojie, Han Haihui, Zhang Yulian, et al. Convolutional neural network landslide recognition based on terrain feature fusion[J]. *Journal of Earth Sciences and Environment*, 2022, 44(3): 568–579. [蔡浩杰, 韩海辉, 张雨莲, 等. 基于地形特征融合的卷积神经网络滑坡识别[J]. *地球科学与环境学报*, 2022, 44(3): 568–579.]
- [34] Tang Xiaochuan, Tu Zihan, Ren Xuqing, et al. A multi-modal deep neural network model for forested landslide detection[J]. *Geomatics and Information Science of Wuhan University*, 2024, 49(9): 1566–1573. [唐小川, 涂子涵, 任绪清, 等. 一种识别植被覆盖滑坡的多模态深度神经网络模型[J]. *武汉大学学报(信息科学版)*, 2024, 49(9): 1566–1573.]
- [35] Chen Lifu, Jin Yuchen, Li Zhenhong, et al. SAR image earthquake landslide recognition based on multi-feature cross-fused Siamese network[J]. *Geomatics and Information Science of Wuhan University*, 2025, 50(5): 917–927. [陈立福, 金昱忱, 李振洪, 等. 基于多特征交叉融合孪生网络的 SAR 影像地震滑坡识别[J]. *武汉大学学报(信息科学版)*, 2025, 50(5): 917–927.]
- [36] Liu Jia, Wu Yuming, Gao Xing, et al. Image recognition of co-seismic landslide based on GEE and U-Net neural network[J]. *Journal of Geo-Information Science*, 2022, 24(7): 1275–1285. [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(7): 1275–1285.]
- [37] Xiang Xuyang, Gong Wenping, Zhao Fumeng, et al. Earthquake-induced landslide mapping in mountainous areas using a semantic segmentation model combined with a dual feature pyramid[J/OL]. *Journal of Earth Science*, 2025[2025–06–18]. <http://en.earth-science.net/en/article/doi/10.1007/s12583-023-1956-6>.
- [38] Xin Lubin, Han Ling, Li Liangzhi. Landslide intelligent recognition based on multi-source data fusion[J]. *Journal of Earth Sciences and Environment*, 2023, 45(4): 920–928. [辛鲁斌, 韩玲, 李良志. 基于多源数据融合的滑坡智能识别[J]. *地球科学与环境学报*, 2023, 45(4): 920–928.]

Research on Automatic Identification Method of Loess Earthquake Landslide Based on VGG–Unet Model

WANG Liansheng¹, LI Ping^{1,2*}, MU Songwei¹, TUO Zihan¹, LI Chen¹

(1. Hebei Provincial Key Laboratory of Earthquake Disaster Prevention and Risk Assessment, Institute of Disaster Prevention, Langfang 065201, China;

2. Key Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China)

Abstract:

Objective Loess areas are highly prone to frequent earthquake-induced landslides. Rapid and accurate identification in loess regions is essential to obtain a detailed spatial distribution of loess earthquake landslides. The identification results of landslides reflect their development status and spatial distribution, serving as a theoretical foundation for research on landslide safety, vulnerability, and management. Field investigations and remote sensing technology are two primary approaches for landslide identification. However, relying solely on field surveys consumes substantial human, material, and financial resources. Similarly, depending exclusively on remote sensing technology for landslide identification does not ensure the authenticity and reliability of the database. This research applies the VGG–Unet network for the automatic identification of loess earthquake landslides based on landslide data obtained from field surveys.

Methods Firstly, based on loess earthquake landslides investigated by the earthquake landslide research team of the College of Disaster Prevention Science and Technology during field surveys in Gansu Province and Ningxia Hui Autonomous Region, the quantitative and qualitative parameters for extracting loess earthquake landslides on the satellite imagery platform through visual interpretation were systematically summarized. The quantitative parameters included stratigraphy, topography, slope, slide length, and slide width characteristics, and the qualitative parameters included planar morphology, profile, and color tone characteristics. These features supported the visual interpretation of remote sensing satellite imagery and facilitated the extraction of a database of loess landslides triggered by seismic events. Ultimately, a total of 494 original images were extracted, covering 1 052 loess landslides induced by seismic events, which served as input images to improve the model's generalization

ability. Secondly, due to the exceptional feature extraction capability of the VGG16 network, its simple yet effective structural design, and its extensive pre-trained weights, it facilitated the construction of a Unet network model using it as the primary backbone feature extraction network, enhancing performance. Therefore, this study applied the VGG-Unet network model using the Python programming language based on the PyTorch framework under the Windows 10 environment, with a GPU of NVIDIA Quadro P2000 20.9 GB, to train and validate loess earthquake landslides on the satellite imagery platform and to achieve automatic segmentation of loess earthquake landslides in the validation area, improving recognition accuracy. Three databases were established to optimize the segmentation prediction performance of the model. Database 1 contained 494 original loess earthquake landslide maps, Database 2 contained 920 loess earthquake landslide maps obtained after expansion through rotation, and Database 3 contained 613 maps obtained after expansion through cropping. The database 1 was input into the original Unet model and the VGG-Unet model, corresponding to Experiment 1 and Experiment 2, respectively. Then, Databases 2 and 3 were input into the model that produced better results in the first two tests, namely the VGG-Unet model, corresponding to Experiment 3 and 4, respectively. The four sets of tests were compared and analyzed to determine the optimal model performance metrics. Landslides within the study area were extracted from satellite imagery with coverage areas of $0.5\sim 1.0\text{ km}^2$, ensuring that each image contained an appropriate number of landslide patches and effective training data, providing the model with sufficient landslide pixels for feature learning. A total of 494 raw images were obtained, covering 1 052 landslides, designated as Database 1. A portion of the images was expanded through rotation, yielding 920 image panels, designated as Database 2, while another portion was expanded through cropping, yielding 613 image panels, designated as Database 3. Database 1 was input into models utilizing ResNet and VGG16 as backbone features, namely the original Unet model and the VGG-Unet model, corresponding to Experiments 1 and 2, respectively. Then, Databases 2 and 3 were input into the model that yielded superior results in the preceding two experiments, namely the VGG-Unet model, corresponding to Experiment 3 and 4, respectively. Finally, the VGG-Unet model, which demonstrated the best performance among the four tests, was utilized to generate prediction results for typical loess earthquake landslide areas within the validation area. The researchers compared the predicted identification results of the model with the field-investigated landslide locations one by one to ensure experimental accuracy.

Results and Discussions The results showed that the VGG-Unet model demonstrated the best training and validation performance on the dataset that was cropped and expanded to 613 frames, and performed particularly well on the unknown dataset. The accuracy was 89.57%, the MIoU was 70.13%, the F_1 value was 81.11%, and the Recall reached 80.53%, and all model performance indices were high. In contrast, on the original 494-frame dataset, the performance of the original Unet model was the lowest, followed by the VGG-Unet model, and both were lower than the results of Test 3. However, on the dataset expanded through rotation to 920 frames, although the training performance metrics of the VGG-Unet model reached the highest values among the three tests, the validation performance metrics decreased to the lowest. This method identified loess landslides triggered by earthquakes. The model showed higher accuracy in identifying loess earthquake landslides with well-developed topographic and profile features, whereas it tended to miss landslides with ambiguous tonal and profile features, as well as small-scale landslides, and tended to misinterpret complex terrains such as uneven strata. Overall, the VGG-Unet model effectively predicted areas prone to loess landslides. The clearer and more complete the characteristic markers of loess landslides were, the more effectively the VGG-Unet model performed in segmentation tasks. Its high precision and accuracy enabled computers to rapidly and accurately identify target areas and determine their locations. For landslides with blurred or incomplete characteristic markers, although the model produced a limited number of misclassifications and omissions during segmentation, most areas were still accurately segmented and identified.

Conclusions Therefore, the method proposed in this study can efficiently segment and recognize the same type of landslide areas and can automatically segment and recognize the locations of landslides before field investigations. This approach assists field teams in locating loess earthquake-induced landslides and provides technical support for large-scale landslide disaster investigations.

Key words: VGG-Unet model; loess earthquake landslide; landslide identification; satellite images; field investigation

(编辑 李轶楠)

引用格式: Wang Liansheng, Li Ping, Mu Songwei, et al. Research on automatic identification method of loess earthquake landslide based on VGG-Unet model[J]. Advanced Engineering Sciences, 2026, 58(2): 84-95. [王连升, 李平, 穆松伟, 等. 基于 VGG-Unet 模型的黄土地震滑坡自动识别方法[J]. 工程科学与技术, 2026, 58(2): 84-95.]