

基于改进 ResU-Net 的中分辨率遥感影像 滑坡检测方法

王颖, 吴旭, 冷小鹏, 余戈

(成都理工大学计算机与网络安全学院(牛津布鲁克斯学院), 四川成都 610059)

摘要:针对基于中分辨率遥感影像滑坡检测精度低的问题,提出了一种基于注意力机制的改进 ResU-Net 模型,并且基于多光谱遥感影像数据集得出了有益于滑坡检测的多特征模型输入组合。本研究所用的原始数据集共 14 个特征,首先剔除无效特征,并加入归一化植被指数和归一化水体指数,生成新数据集。然后将新数据集应用于改进的 ResU-Net 与 U-Net, ResU-Net, Attention U-Net, BiSeNet, Semantic FPN, U-Net++ 的对比实验,结果表明改进的 ResU-Net 在测试集上可获得 76.91% 的 F1 分数,同时精确率和召回率分别为 77.34% 和 76.49%,在该任务中优于其他对比模型,且比 ResU-Net 模型的 F1 分数高了 0.43 个百分点,有效提高了中分辨率遥感影像的滑坡检测精度。最后,再向数据集中依次加入归一化湿度指数和坡向特征,对比不同特征组合数据集产生的检测效果,结果发现加入坡向特征可最大化提升滑坡检测精度, F1 分数可达 77.03%。

关键词:滑坡检测;多光谱;图像语义分割;注意力机制;ResU-Net

中图分类号: TP753

文献标识码: A

文章编号: 1673-629X(2023)11-0182-07

doi: 10.3969/j.issn.1673-629X.2023.11.027

Landslide Detection Method Using Improved ResU-Net of Medium Resolution Remote Sensing Images

WANG Ying, WU Xu, LENG Xiao-peng, YU Ge

(School of Computer Science and Cyber Security (Oxford Brookes College),
Chengdu University of Technology, Chengdu 610059, China)

Abstract: Aiming at the problem of low accuracy of landslide detection based on medium resolution remote sensing images, we propose an improved ResU-Net model based on attention mechanism, and multi-feature model input combination that is beneficial to landslide detection is obtained based on multispectral remote sensing imagery dataset. The original dataset used has a total of 14 features. Firstly, the invalid features are removed, and the normalized difference vegetation index and the normalized difference water index are added to generate a new dataset. Secondly, The new dataset is applied in the comparative experiments of the improved ResU-Net with U-Net, ResU-Net, Attention U-Net, BiSeNet, Semantic FPN, U-Net++. It is showed that the improved ResU-Net can obtain the F1 score of 76.91% on the test set, while the precision and recall are 77.34% and 76.49%, respectively, which are better than that of other comparison models in this task, and it is 0.43 percentage points higher than the F1 score of the ResU-Net model, which effectively improves the landslide detection accuracy based on medium resolution remote sensing images. Finally, the normalized difference moisture index and aspect features are added to the dataset in turn, and the detection accuracy of different feature combinations is compared. The results show that adding aspect features can maximize the accuracy of landslide detection, and the F1 score reaches 77.03%.

Key words: landslide detection; multispectral; image semantic segmentation; attention mechanism; ResU-Net

0 引言

滑坡一直是频繁发生的地质灾害之一,及时发现滑坡并更新滑坡清单,可以有效减少生命、财产的损

失。另外,准确检测已存在滑坡的位置是加强滑坡灾害预防的先决条件^[1]。由于传统的实地野外调查和利用航空影像进行目视解译的检测方式效率较低,近几

收稿日期: 2022-12-15

修回日期: 2023-04-18

基金项目: 四川省科技应用基础研究项目(2021YJ0335)

作者简介: 王颖(1997-),女,硕士研究生,研究方向为计算机视觉;通信作者: 吴旭(1979-),男,讲师,博士,研究方向为计算机科学与技术。

年滑坡检测的主要研究方向转换到利用遥感影像和深度神经网络来进行自动滑坡检测。Wang 等人^[2]采用基于注意力机制的 YOLOv5 模型实现了高分辨率遥感影像的滑坡识别。Su 等人^[3]针对双时程 RGB 航拍图像和数字地形模型提出了基于 ResNet 的 LanDCNN 滑坡识别模型。张蕴灵等人^[4]提出了基于 ResNet 的多尺度特征融合的 CNN 模型用于高分辨率遥感影像滑坡检测。张倩雯等人^[5]将 Faster RCNN, YOLO, SSD 应用于遥感图像滑坡检测,对比实验结果表明 Faster RCNN 更适合小数据集的检测,而 YOLO 和 SSD 分别有检测精度高和推理速度快的优势。Xia 等人^[6]提出了适用于高分辨率多源数据集的 FSTF-Net 模型来检测滑坡。以上研究中的 YOLO, Faster RCNN, SSD 模型都是针对目标检测任务,只能检测出滑坡的位置,无法检测滑坡的规模、形状。虽然其他研究提出的模型是基于图像分割的,但所适用的数据集都是高分辨率的,且数据源较单一。高分辨率遥感影像不仅获取成本高,而且解译困难。相比较而言,中分辨率的遥感影像,如 Sentinel-2,不仅可以通过开放的哨兵中心(Sentinel Hub)或谷歌地球引擎(Google Earth Engine, GEE)直接完成预处理,使得滑坡检测更方便、及时。而且其包含了 13 个波段,可以提供更多有益于滑坡检测的特征,从数据源方面提升滑坡检测精度。

2021 年, Ghorbanzadeh 等人^[7]基于 Sentinel-2 影像中的 RGB 波段和近红外波段,研究了两种经典的全卷积网络(Fully Convolutional Network, FCN)对滑坡检测的效果,分别是 U-Net 和 ResU-Net,其中 ResU-Net 获得了更高的 F1 分数:73.32%。后续, Ghorbanzadeh 等人^[8]基于 Sentinel-2 影像的 12 个波段和 ALOS PALSAR 的数字高程模型(Digital Elevation Model, DEM)、坡度层生成了一个用于遥感图像滑坡检测的基准数据集,并以此对比了 11 种语义分割模型(PSPNet, ContexNet, DeepLab-v2, DeepLab-v3+, FCN-8s, LinkNet, FRRN-A, FRRN-B, SQNet, U-Net, ResU-Net),实验结果表明,仍是 ResU-Net 模型表现最优,F1 分数达 71.65%。

由上述研究可知,ResU-Net 模型在针对中分辨率遥感多光谱影像的滑坡检测任务上效果较好,但就滑坡自身的特殊性上该模型还有待改进。本研究考虑了两点特殊性:(1)滑坡特征不具有统一性。受不同地质、水文、天气条件等因素的影响,滑坡的地表特征可能有很大的差异^[9];(2)滑坡形状不规则,主要展示为各种多边形^[10]。以上两点特殊性会限制 ResU-Net 模型的滑坡检测精度。对此,该文对 ResU-Net 模型提出了对应的改进策略:(1)添加注意力机制,提升模型提取关键信息的能力;(2)加深网络结构,以获得更丰

富的语义信息。除了模型改进以外,该文还探讨了不同特征组合的数据集对滑坡检测精度的影响,实验结果发现剔除原始数据集中无效(对滑坡不敏感)的特征,添加归一化植被指数(Normalized Difference Vegetation Index, NDVI)、归一化水体指数(Normalized Difference Water Index, NDWI)和坡向特征可以最大化提升滑坡检测的精度。

1 相关方法

1.1 损失函数

数据集中滑坡像素点与非滑坡像素点的比例大约为 2.4%,类别占比极不平衡,针对此类问题,使用复合损失函数性能更佳,也更稳定^[11]。常使用的有 Dice 损失+交叉熵损失、Dice 损失+Focal 损失,但在本研究任务中均表现不佳,故本研究使用了另一个效果更好的损失函数——Unified Focal loss^[12]。这是一个将各种基于分布的(如交叉熵损失)、基于区域的(如 Dice 损失)以及复合损失函数(如 Combo 损失)统一到一个框架里面进行计算的损失函数。实验选择了文献[12]中非对称的 Unified Focal loss,计算公式如下:

$$L_{\text{aUF}} = \lambda L_{\text{maF}} + (1 - \lambda) L_{\text{maFT}} \quad (1)$$

其中, L_{maF} 计算公式如下:

$$L_{\text{maF}} = -\frac{\delta}{N} \mathbf{y}_{i,r} \log(\mathbf{p}_{i,r}) - \frac{1 - \delta}{N} \sum_{c \neq r} (1 - \mathbf{p}_{i,c})^{\gamma} \log(\mathbf{p}_{i,c}) \quad (2)$$

L_{maFT} 计算公式如下:

$$L_{\text{maFT}} = \sum_{c \neq r} (1 - \text{mTI}) + \sum_{c=r} (1 - \text{mTI})^{1-\gamma} \quad (3)$$

其中, mTI 的计算公式如下:

$$\text{mTI} = \frac{\sum_{i=1}^N p_{0i} g_{0i}}{\sum_{i=1}^N p_{0i} g_{0i} + \delta \sum_{i=1}^N p_{0i} g_{1i} + (1 - \delta) \sum_{i=1}^N p_{1i} g_{0i}} \quad (4)$$

式(1)至(4)中: λ 用于控制 L_{maF} 和 L_{maFT} 的比例; δ 用于控制各类别的权重; N 是待分割样本的所有像素点个数; p_{0i} 是像素 i 属于滑坡类的概率; p_{1i} 是像素 i 属于非滑坡类的概率; g_{0i} 为 1 表示像素 i 属于滑坡类,为 0 则属于非滑坡类; g_{1i} 为 1 表示像素 i 属于非滑坡类,为 0 则属于滑坡类; c 表示所有类别,即滑坡类和非滑坡类; r 表示稀有类,在本研究中就是滑坡类; $\mathbf{y}_{i,r}$ 是一个真实标签中每个像素是否属于滑坡类的矩阵,1 表示属于,0 表示不属于; $\mathbf{p}_{i,r}$ 是一个预测标签中每个像素是否属于滑坡类的矩阵,1 表示属于,0 表示不属于; $\mathbf{p}_{i,c}$ 是一个预测标签中每个像素是否属于非滑坡类的矩阵,1 表示属于,0 表示不属于; γ 用于控制背景

抑制和前景增强的程度。

1.2 优化算法

本研究使用的是 Loshchilov 等人^[13]提出的 AdamW 优化算法,该算法解决了 Adam 配合权重衰减反而导致性能下降的问题,其在图像分类的数据集上与使用动量的 SGD 优化性能相当。另外,由于在大多数深度学习框架中权重衰减与批量归一化一起使用会削弱权重衰减的效果^[14],所以本实验均不对批量归一化层的参数做权重衰减。

1.3 注意力机制

本研究使用的注意力机制是 Woo 等人^[15]于 2018 年提出的卷积注意力模块 (CBAM),其是一种混合注意力机制,同时包含了通道注意力模块 (CAM) 和空间注意力模块 (SAM),两者结合可以更稳定地增强特征提取的能力;另外,与以往注意力机制的不同点还在于 CBAM 引入了全局最大池化作为全局平均池化的补

充,更有利于重要特征的提取。其计算方式如下:

$$F_{out} = F_{in} \otimes M_c(F_{in}) \otimes M_s(F_{in} \otimes M_c(F_{in})) \quad (5)$$

其中, $F_{out} \in R^{C \times H \times W}$ 代表 CBAM 的输出, C 为通道数, H 为高, W 为宽; $F_{in} \in R^{C \times H \times W}$ 代表输入; \otimes 代表两个特征映射逐元素对应相乘的操作; $M_c \in R^{C \times 1 \times 1}$ 代表 CAM; $M_s \in R^{1 \times H \times W}$ 代表 SAM。

$$M_c(F_{in}) = \sigma(f_2^{1 \times 1}(f_1^{1 \times 1}(\text{Avg}(F_{in})))) + f_2^{1 \times 1}(f_1^{1 \times 1}(\text{Max}(F_{in}))) \quad (6)$$

$$M_s(F_{in}) = \sigma(f^{3 \times 3}([\text{Avg}(F_{in}); \text{Max}(F_{in})])) \quad (7)$$

其中, σ 代表 sigmoid 激活函数; $f^{1 \times 1}$ 代表卷积核大小为 1×1 的卷积操作; Avg 代表全局平均池化; Max 代表全局最大池化; $f^{3 \times 3}$ 代表卷积核大小为 3×3 的卷积操作。

2 改进的 ResU-Net 模型

改进的 ResU-Net 模型网络结构见图 1。

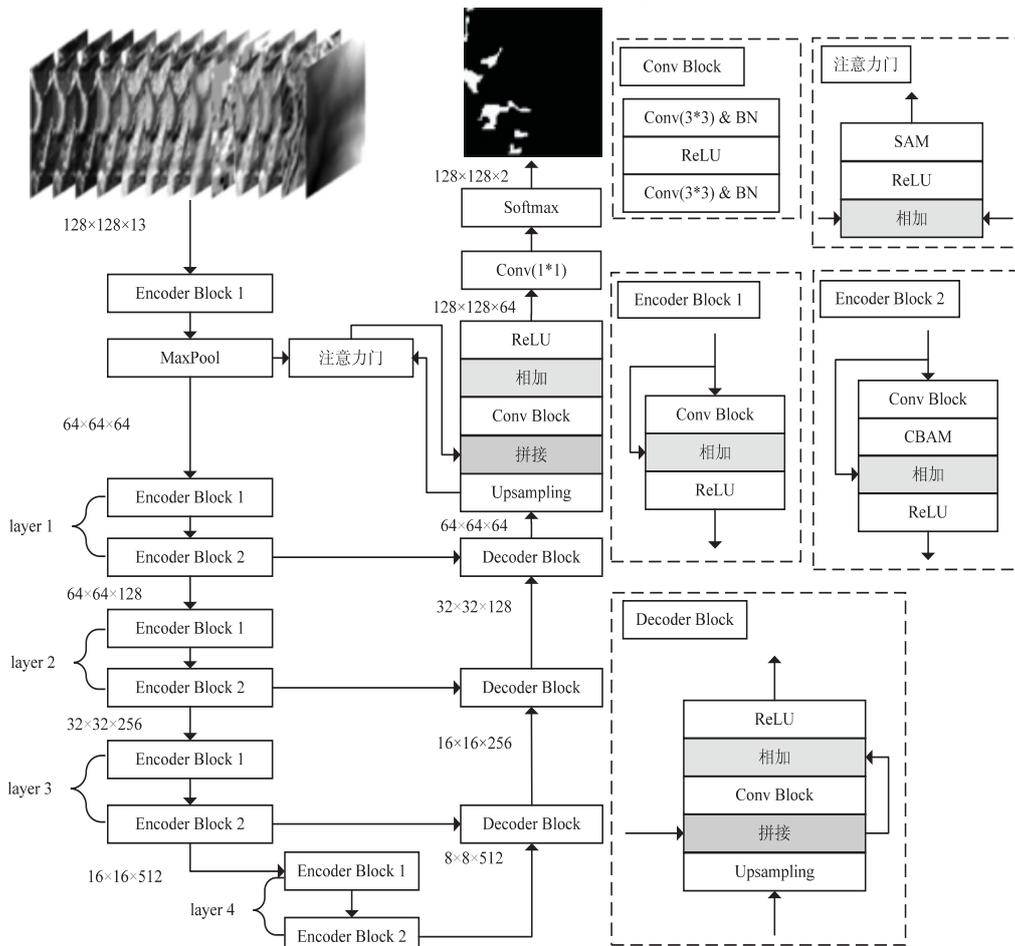


图 1 改进的 ResU-Net 模型网络结构

(1)在编码器中添加 CBAM(见 1.3 小节)。除了提升模型提取关键信息的能力,还能缓解编码器与解码器两边特征映射拼接时,编码器前几层带来很多冗余信息的问题。(2)在编码器与解码器之间的第 1 个桥连接中添加 SAM(见 1.3 小节)。因为编码器第 1

个残差块产生的特征映射冗余信息太多,添加注意力模块容易对后续残差块的特征提取造成负面影响,所以没有添加,但参考文献[16]可以在桥连接之间添加一个注意力门,缓解两边特征映射拼接时冗余信息太多的问题。本研究经过实验对比发现,此处只添加

SAM 比添加 CBAM 得到的 F1 分数略高一些。(3) 加深网络结构。除了获得更大的感受野和更丰富的语义信息以外,还因为注意力机制需要多层叠加才会有增强效果,所以原始 ResU-Net 编码器的 5 层残差块不够。对此,本研究参考了 ResNet18^[17] 的网络结构,在编码器中使用了 9 层残差块,每个残差块包含两次卷积,既获得了更丰富的语义信息,又可叠加注意力效应。(4) 增加一次下采样。原 ResU-Net 一共使用 3 次步距为 2 的下采样,而改进的 ResU-Net 增加了 1 次,共下采样 16 倍,进一步获得更大的感受野和更丰富的语义信息。经过实验对比也证实了在本研究任务中下采样 16 倍得到的 F1 分数更高。下采样的位置分别位于编码器的 MaxPool 层和 layer2、layer3、layer4 的第 1 个残差块中的第 1 个卷积层。

3 数据集

3.1 数据集说明

实验数据取自 LandSlide4Sense 2022^[8],共 3 799 个样本,各样本大小都为 128×128 像素,都包含 14 个特征(见表 1)。对应的标签则包含两个特征,0 表示非滑坡,1 表示滑坡,均以 HDF5 格式存储。此数据集的滑坡域分别取自全球 4 个不同的地区,地形多样且滑坡类型丰富。

表 1 数据集的 14 个特征

特征	名称	分辨率/m
B1	沿海气溶胶 (Coastal aerosol)	60
B2	蓝 (Blue)	10
B3	绿 (Green)	10
B4	红 (Red)	10
B5	红边 1 (Red Edge 1)	20
B6	红边 2 (Red Edge 2)	20
B7	红边 3 (Red Edge 3)	20
B8	近红外 (NIR)	10
B9	水蒸气 (Water vapor)	60
B10	卷云 (Cirrus)	60
B11	短波红外 1 (SWIR 1)	20
B12	短波红外 2 (SWIR 2)	20
B13	坡度 (Slope)	12.5
B14	DEM	12.5

3.2 合成新数据集

文献 [8] 在“Benchmark Dataset Statistics and Shape”一节中,分别对 4 个地区的训练集、测试集中的滑坡类和非滑坡类各个特征的平均值进行了统计,从统计结果可知 B1, B2, B3, B4, B5, B6, B10, B11, B12, B13, B14 的滑坡类平均值和非滑坡类平均值存在差异,且差异的方向在 4 个地区对应的训练集、测试集上大致相同,故保留这 11 个特征(剔除无效特征 B7、B8、

B9)。另外,通过文献 [18] 可知,NDVI、NDWI 与滑坡的易发性相关,故引入这两个特征。由此生成包含 13 个特征的新数据集(流程见图 2),也是做消融实验和模型对比实验时用的数据集,其中训练集 2 553 个、验证集 524 个、测试集 722 个。

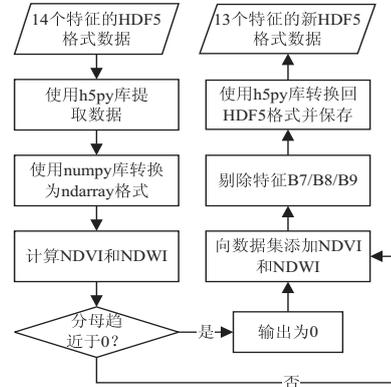


图 2 新数据集合成流程

注:h5py 和 numpy 均是 python 环境中安装的工具库。

$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (8)$$

$$NDWI = \frac{(Green - NIR)}{(Green + NIR)} \quad (9)$$

4 实验与结果分析

4.1 实验环境及参数设置

本研究使用的深度学习框架是 Pytorch,运行环境如下:Linux 系统,NVIDIA RTX A4000 显卡(内存 16G),英特尔 12 核 Xeon(R) Gold 5320 @ 2.20 GHz 处理器(内存 32G)。为了保证对比实验的公平性,所有实验的训练设计都保持一致:用训练集的平均值和方差做输入标准化处理;参数初始化方式是 He 初始化^[19];初始学习率为 0.01,采用热身(warm up)的方式开始,衰减策略为多项式衰减,计算方式见公式;优化器用 AdamW(见 1.2 小节), $\beta_1 = 0.9$, $\beta_2 = 0.999$,权重衰减为 $5e-4$;损失函数用 Unified Focal loss(见 1.1 小节), $\lambda = 0.5$, $\delta = 0.4$, $\gamma = 0.2$;批量大小为 32,共训练 100 次;数据增强方式只用随机上下翻转和随机水平翻转。

$$PolynomialLRDecay = \left(1 - \frac{iter}{max_iter}\right)^{power} \quad (10)$$

其中,iter 为迭代次数,max_iter = 160,power = 4.0。

4.2 评估指标

本研究采用召回率(Recall)、精确率(Precision)、F 分数来评估分割结果,其计算公式如下:

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

$$Precision = \frac{TP}{TP + FP} \quad (12)$$

$$F_{\beta} = (1 + \beta^2) \times \frac{\text{Precision} \times \text{Recall}}{\beta^2 \times \text{Precision} + \text{Recall}} \quad (13)$$

所有评估指标的计算均只针对滑坡类。式中 TP、FP、FN 分别表示滑坡类被正确识别的数量、将非滑坡类预测为滑坡类的数量、将滑坡类预测为非滑坡类的数量。召回率表示样本中所有滑坡被检测到的比例。精确率表示模型预测为滑坡的结果中,预测正确的比例。F 分数是综合召回率和精确率的评估指标,可更加客观地反映整体的性能,是主要的评估指标。在本研究任务中召回率和精确率同样重要,故设置 $\beta = 1$, 即使用 F1 分数。

4.3 消融实验

基线模型就是 ResU-Net(下采样 16 倍),另外针对其改进策略共有 3 个对比模型:(1)添加注意力机制。在 ResU-Net 编码器中添加 CBAM(第 1 个残差块除外),以及在编码器与解码器之间的第 1 个桥连接中添加 SAM;(2)加深网络结构。去掉改进的 ResU-Net 中的 CBAM 和 SAM。(3)添加注意力机制和加深网络结构相结合,即改进的 ResU-Net 模型。消融实验的结果如表 2 所示。

实验结果表明,添加注意力机制和加深网络结构都可以提升模型的分割精度,其中网络结构的加深帮

助最大,在 ResU-Net 的基础上提升了 0.27 百分点,再通过添加注意力机制则可以进一步提升。

表 2 改进 ResU-Net 模型的消融实验结果

模型	F1/%
ResU-Net	76.48
ResU-Net 添加注意力机制	76.54
加深 ResU-Net 的网络结构	76.75
改进的 ResU-Net	76.91

4.4 模型对比实验

在对比实验中,除了 U-Net 和 ResU-Net 模型,在文献[8]中已做过对比实验的语义分割模型之外,额外选择了 4 种具有代表性的主流语义分割模型: Attention U-Net, BiSeNet, Semantic FPN, U-Net++, 以丰富此类研究的对比工作。表 3 对 6 种对比模型的特点进行了简单的总结。针对 LandSlide4Sense 2022 数据集进行模型对比实验的结果如表 4 所示。经实验证明,在该任务中 Attention U-Net、U-Net 以及 ResU-Net 下采样 16 倍比原文献中下采样 8 倍效果更好,且与本研究改进的 ResU-Net 下采样倍数相同,所以对比实验中,这 3 个模型使用的是 16 倍下采样结构,以此保证对比实验的公平性。

表 3 6 种对比模型特点的总结

对比模型	特点
BiSeNet ^[20]	一种实时的语义分割模型。通过一种创新的双边分割结构(空间路径和上下文路径)解决了以往实时分割模型中因为降低空间分辨率导致检测性能下降的问题,实现了速度与精度的平衡
Semantic FPN ^[21]	一种基于特征金字塔(FPN)的语义分割模型。针对全景分割任务提出的 Panoptic FPN 模型中的语义分割分支网络,可以有效解决分割任务中目标多尺度变化的问题
U-Net ^[22]	标准的编码器和解码器结构,两边使用桥连接来实现低层特征与高层特征的融合,为抽象的高层特征添加位置信息,以提升分割精度
Attention U-Net ^[16]	注意力机制与 U-Net 结合的语义分割模型。在桥连接中添加注意力门,以自动抑制不相关的区域,同时加强对重要区域的关注,有效解决了两边特征拼接时,编码器输出特征冗余信息较多的问题
U-Net++ ^[23]	密集卷积网络与 U-Net 结合的语义分割模型。其在 U-Net 上主要有两个改进:(1)将编码器和解码器通过一系列嵌套的、密集的跳跃路径连接,减少了两边特征映射的语义差距;(2)添加了深度监督设计,模型有两种预测模式:精确模式和快速模式,本研究做对比实验时用的是精确模式
ResU-Net ^[24]	残差网络(ResNet)与 U-Net 结合的语义分割模型。将其 U-Net 的每个子模块都加上了残差连接,不仅增强了特征提取能力,还防止梯度消失 ^[24] 。在遥感影像领域已有很多应用 ^[7-8,25]

表 4 改进的 ResU-Net 与 6 种对比模型的滑坡检测结果

模型	召回率 /%	精确率 /%	F1 /%	推理时间 /(ms/4 张)
BiSeNet	68.24	67.19	67.71	9.02
Semantic FPN	73.95	68.51	71.13	11.61
Attention U-Net	76.09	76.26	76.17	14.76
U-Net++	73.43	79.14	76.18	21.71
U-Net	75.14	77.33	76.22	12.31
ResU-Net	74.43	78.64	76.48	17.42
改进的 ResU-Net	76.49	77.34	76.91	20.45

注:推理时间是使用 Pytorch. Profiler 包计算得到的 CUDA total 值。输入尺寸是(4, 13, 128, 128),等于 4 张通道数为 13,大小为 128×128 的图像。运行环境同对比实验一致。

从表 4 可以发现,改进的 ResU-Net 的性能最好, F1 分数达到 76.91%,比 ResU-Net 高 0.43 百分点,而推理时间只多了 3.03 ms(每 4 张图像),平均每张图像 0.76 ms,增加的时间代价较小;另外,改进的 ResU-Net 的召回率也是最高的,比第二的 Attention U-Net 高 0.4 百分点,说明其能预测出最多的真实滑坡点;而在精确率方面,则是 U-Net++ 得分最高,达到 79%,说

明其预测出的滑坡点可信度最高,但其召回率偏低,即对真实滑坡点的预测较少。还值得注意的是,改进的 ResU-Net 得到的召回率和精确率最接近,只相差 0.85 百分点,这说明该模型得出的预测平衡性较好,预测结果不会太激进也不会太保守。反观 ResU-Net、Semantic FPN 和 U-Net++ 的平衡性就差一些,召回率和精确率的差值分别为 4.21、5.44 和 5.71 百分点。从推理时间来看,BiSeNet、Semantic FPN 以及 U-Net 推理最快,但精度与改进的 ResU-Net 有差距,其中最接近的是 U-Net。在本实验环境下,改进的 ResU-Net 相比于 U-Net,用每 4 张图像多出 8.14 ms 推理时间的代价换取了 0.69 百分点的精度提升。而根据目前 GPU 运行速度的提升和并行计算技术的增强,增加的推理时间还可以缩短一些,故提出的改进的 ResU-Net

模型在此类任务中是可行的。

为了展示模型的分割效果,图 3 可视化了表 4 中 7 种模型的预测结果。前 5 个样本从测试集抽取,最后一个是用 GEE 在 Sentinel-2 MSI 数据集上提取 B1 至 B12 的特征和用 ASF Data Search 在 ALOS PALSAR 数据集上提取 B13、B14 特征合并得到的,该滑坡点取自四川省雅安市汉源县,由于采集数据的特征分布与实验数据有差异,所以分割精度降低。从图中可以看出,整体上改进的 ResU-Net 分割最准确。但所有模型都表现出对小分支滑坡分割效果不好的问题,如图 3 中“image_1456”底部的小分叉 7 个模型都没预测出来。滑坡形状繁杂,提升模型对各样式滑坡检测的兼容性是改善模型性能的重点之一,也是后续的研究工作之一。

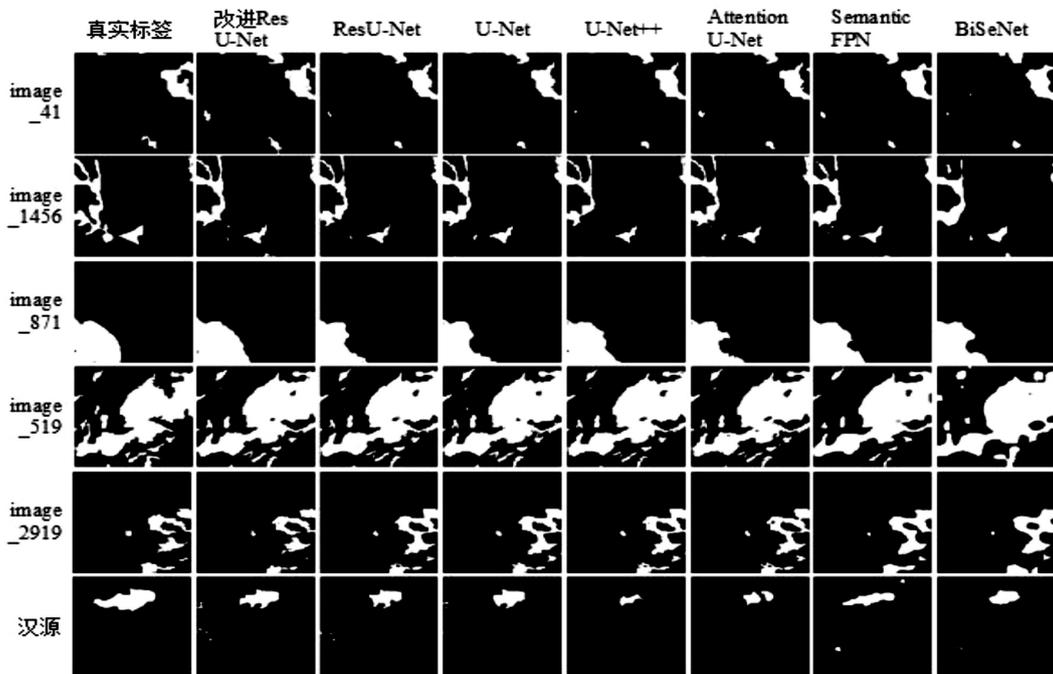


图 3 模型预测可视化

4.5 特征组合对比实验

由文献[18]可知,坡向可通过影响地表降水流向、植被生长及繁茂程度,对滑坡的产生造成间接影响,其值可通过 python 的 richde.TerrainAttribute 函数传入 B14 (DEM) 计算得到。另外,归一化湿度指数 (Normalized Difference Moisture Index, NDMI) 可以描述作物的水分胁迫等级^[26],与滑坡产生有间接联系,其计算公式如下:

$$NDMI = \frac{(NIR - SWIR1)}{(NIR + SWIR1)} \quad (14)$$

首先,向 3.2 小节生成的新数据集依次加入坡向和 NDMI 特征,生成另两个对比数据集;然后分别送入改进的 ResU-Net 进行训练、评估。评估结果见表 5。

从中可以看出通过剔除无效特征,添加 NDVI 和

NDWI 特征、添加坡向特征都可以提升检测精度,而对原始数据集同时进行以上 3 种优化,可将精度提升最大化,F1 分数可达 77.03%,比使用原始数据集高了 0.36 百分点。另外,使用新数据集+NDMI 比仅使用新数据集得到的 F1 分数减少了 0.15 百分点,这说明 NDMI 的加入无益于滑坡检测。

表 5 特征组合对比结果

数据集	F1/%
原始数据集(见 3.1 小节)	76.67
原始数据集剔除无效特征	76.75
新数据集(剔除无效特征,并添加 NDVI, NDWI, 见 3.2 小节)	76.91
新数据集+坡向	77.03
新数据集+NDMI	76.76

5 结束语

针对基于中分辨率遥感影像滑坡检测精度低的问题,提出了一种改进的 ResU-Net 模型。实验结果证明改进的 ResU-Net 优于 ResU-Net, U-Net, Attention U-Net, BiSeNet, Semantic FPN 和 U-Net++, 其 F1 分数达 76.91%, 并且由文献[8]中已做的 11 种语义分割模型的对比实验结果为 ResU-Net 的 F1 分数最高, 可推断改进的 ResU-Net 在本研究任务上优于大多数主流的语义分割模型。另外, 基于 Landslide4Sense 2022 的数据集, 生成了不同特征组合的对比数据集, 实验结果表明 Sentinel-2 的 B1、B2、B3、B4、B5、B6、B10、B11、B12 和 ALOS PALSAR 的 DEM、坡度层以及 NDVI、NDWI、坡向共 14 个特征的数据组合最有利于滑坡检测。

参考文献:

- [1] 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.
- [2] WANG T, LIU M, ZHANG H, et al. Landslide detection based on improved YOLOv5 and satellite images[C]//2021 4th international conference on pattern recognition and artificial intelligence (PRAI). Yibin: IEEE, 2021:367-371.
- [3] SU Z, CHOW J K, TAN P S, et al. Deep convolutional neural network - based pixel-wise landslide inventory mapping [J]. *Landslides*, 2021, 18(4):1421-1443.
- [4] 张蕴灵, 傅宇浩, 孙雨, 等. 结合深度神经网络的高分辨率遥感影像滑坡检测[J]. *公路*, 2021, 66(5):188-194.
- [5] 张倩莹, 王俊英, 雷冬冬. 基于深度学习目标检测算法的滑坡检测研究[J]. *信息通信*, 2019(1):16-18.
- [6] XIA W, CHEN J, LIU J, et al. Landslide extraction from high-resolution remote sensing imagery using fully convolutional spectral - topographic fusion network[J]. *Remote Sensing*, 2021, 13(24):5116.
- [7] GHORBANZADEH O, CRIVELLARI A, GHAMISI P, et al. A comprehensive transferability evaluation of U-Net and ResU-Net for landslide detection from Sentinel-2 data (case study areas from Taiwan, China, and Japan) [J]. *Scientific Reports*, 2021, 11(1):1-20.
- [8] GHORBANZADEH O, XU Y, GHAMISI P, et al. Landslide4Sense: reference benchmark data and deep learning models for landslide detection[J]. *arXiv*:2206.00515, 2022.
- [9] 马玉林. 基于遥感影像判识的滑坡自动识别方法[D]. 拉萨: 西藏大学, 2022.
- [10] 黄发明, 曹昱, 范宣梅, 等. 不同滑坡边界及其空间形状对滑坡易发性预测不确定性的影响规律[J]. *岩石力学与工程学报*, 2021, 40(S2):3227-3240.
- [11] MA J, CHEN J, NG M, et al. Loss odyssey in medical image segmentation [J]. *Medical Image Analysis*, 2021, 71:102035.
- [12] YEUNG M, SALA E, SCHÖNLIEB C B, et al. Unified focal loss: generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation [J]. *Computerized Medical Imaging and Graphics*, 2022, 95:102026.
- [13] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization [J]. *arXiv*:1711.05101, 2017.
- [14] VAN LAARHOVEN T. L2 regularization versus batch and weight normalization [J]. *arXiv*:1706.05350, 2017.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [J]. *arXiv*:1807.06521, 2018.
- [16] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: learning where to look for the pancreas [J]. *arXiv*:1804.03999, 2018.
- [17] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//2016 IEEE conference on computer vision and pattern recognition (CVPR). Las Vegas: IEEE, 2016:770-778.
- [18] 赵良军, 杨号, 王泽, 等. 釜溪河流域滑坡易发性评价及致灾因子分析 [J]. *四川轻化工大学学报: 自然科学版*, 2022, 35(2):70-78.
- [19] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: surpassing human-level performance on imagenet classification [C]//2015 IEEE international conference on computer vision (ICCV). Santiago: IEEE, 2015:1026-1034.
- [20] YU C, WANG J, PENG C, et al. BiSeNet: bilateral segmentation network for real-time semantic segmentation [J]. *arXiv*:1808.00897, 2018.
- [21] KIRILLOV A, GIRSHICK R, HE K, et al. Panoptic feature pyramid networks [C]//2019 IEEE/CVF conference on computer vision and pattern recognition (CVPR). Long Beach: IEEE, 2019:6399-6408.
- [22] 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. Munich: Springer, 2015:234-241.
- [23] ZHOU Z, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: a nested U-Net architecture for medical image segmentation [J]. *arXiv*:1807.10165, 2018.
- [24] ZHANG Z, LIU Q, WANG Y. Road extraction by deep residual u-net [J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5):749-753.
- [25] QI W, WEI M, YANG W, et al. Automatic mapping of landslides by the ResU-net [J]. *Remote Sensing*, 2020, 12(15):2487.
- [26] TALOOR A K, MANHAS D S, KOTHYARI G C. Retrieval of land surface temperature, normalized difference moisture index, normalized difference water index of the Ravi basin using Landsat data [J]. *Applied Computing and Geosciences*, 2021, 9:100051.