引文格式: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.DOI:10.13203/j.whugis20230479

Citation: 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.DOI:10.13203/j.whugis20230479

基于多特征交叉融合孪生网络的SAR影像地震滑坡识别

陈立福[1] 金昱忱[1] 李振洪[2,3,4,5] 宋 闯[2,3,4] 王小华[1] 陈昊达[1]
刘亚武[1] 赵俊淇[1]

1 长沙理工大学电气与信息工程学院,湖南 长沙,410004
2 长安大学地质工程与测绘学院,陕西 西安,710054
3 长安大学地学与卫星大数据研究中心,陕西 西安,710054
4 自然资源部生态地质与灾害防控重点实验室,陕西 西安,710054
5 西部矿产资源与地质工程教育部重点实验室,陕西 西安,710054

摘 要:由地震引发的群发性大规模地震滑坡是一类非常严重的震后次生灾害,会造成严重的人员伤亡和巨大的经济财产损失。地震发生后迅速准确地识别出这些地震滑坡,可为国家应急部门评估灾害程度和制定救灾措施提供非常重要的信息指导。合成孔径雷达(synthetic aperture radar,SAR)具有全天时、全天候成像特性,但由于地震滑坡背景极为复杂,在SAR影像中特征不显著,因此目前识别效果较差。对此,提出一个使用SAR图像进行滑坡识别的差异特征与聚合特征交叉融合孪生网络。该网络由编码-解码结构组成,编码器采用孪生结构的特征提取网络对地震前后的SAR图像进行不同分辨率的特征提取;解码器中通过构建多尺度差异特征和聚合特征生成模块,对不同尺度地震滑坡的特征图进行差异提取与特征聚合,以此来充分表征地震滑坡特性。并通过提出的多特征交叉融合模块对不同尺度的聚合特征和差异特征进行密集连接逐层解码,提升细节特征与语义特征的提取性能,最终得到识别结果。利用Sentinel-1数据对巴布亚新几内亚地震和中国西藏米林地震滑坡进行了实验,独立测试实验的滑坡识别精度为:查准率分别为70.75%和76.52%,召回率分别为60.92%和71.20%,$F1$分数分别为65.46%和74.03%,总体准确率分别为91.00%和86.14%。利用该网络,地震滑坡发生后可利用SAR影像迅速识别滑坡区,进行灾害应急响应。

关键词:SAR图像;地震滑坡;目标识别;深度学习;孪生网络

中图分类号:P237 **文献标识码**:A **收稿日期**:2024-01-26

DOI:10.13203/j.whugis20230479 **文章编号**:1671-8860(2025)05-0917-11

SAR Image Earthquake Landslide Recognition Based on Multi-feature Cross-Fused Siamese Network

CHEN Lifu[1] *JIN Yuchen*[1] *LI Zhenhong*[2,3,4,5] *SONG Chuang*[2,3,4] *WANG Xiaohua*[1]
CHEN Haoda[1] *LIU Yawu*[1] *ZHAO Junqi*[1]

1 School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410004, China
2 College of Geological Engineering and Geomatics, Chang'an University, Xi'an 710054, China
3 Big Data Center for Geosciences and Satellites, Chang'an University, Xi'an 710054, China
4 Key Laboratory of Ecological Geology and Disaster Prevention, Ministry of Natural Resources, Xi'an 710054, China
5 Key Laboratory of Western China's Mineral Resources and Geological Engineering, Ministry of Education, Xi'an 710054, China

Abstract: **Objectives**: Earthquake-induced mass landslides are a severe type of secondary disaster following earthquakes, causing significant casualties and substantial economic losses. Rapidly and accurately identifying

基金项目:西部矿产资源与地质工程教育部重点实验室开放基金(300102263506);湖南省教育厅重点项目(24A0247);国家自然科学基金(42304029);深空探测省部共建协同创新开放课题(SKTC202301,SKTC202203)。

第一作者:陈立福,博士,副教授,主要从事SAR智能感知方面的研究。lifu_chen@csust.edu.cn

通信作者:李振洪,博士,教授。zhenhong.li@chd.edu.cn

these earthquake-induced landslides after an event is crucial for national emergency departments to assess disaster severity and formulate relief measures. Although synthetic aperture radar (SAR) offers all-time, all-weather imaging capabilities, its effectiveness in identifying landslides is currently limited due to the complexity of the background and the less prominent features of landslides in SAR images. **Methods:** This paper proposes a siamese network for landslide identification in SAR images, named the difference and aggregated feature cross fusion siamese network (DACS-Net). This network, composed of an encoder-decoder structure, utilizes a siamese feature extraction network in the encoder to extract features of pre- and post-earthquake SAR images at different resolutions. In the decoder, multi-scale difference feature and aggregated feature generation modules are constructed to perform difference extraction and feature aggregation for landslide feature maps at different scales, fully representing the characteristics of earthquake-induced landslides. The proposed multi-feature cross-fusion module densely connects and decodes different scales of aggregated and difference features layer by layer, enhancing the extraction of detail and semantic features, leading to the identification results. **Results:** Experiment utilized Sentinel-1 data on earthquake-triggered landslides in Papua New Guinea and Milin, results show that the proposed method could effectively identify earthquake-induced landslides. The landslide identification precision could reached 70.75% and 76.52%, recall were 60.92% and 71.20%, $F1$ score were 65.46% and 74.03%, and overall accuracy were 91.00% and 86.14%. **Conclusion:** By utilizing this network, achievements have been made in the recognition of landslides in SAR images, enhancing the practical application value of deep learning networks in landslide detection. This holds significant importance for disaster emergency response.
Key words: SAR images; seismic landslides; target recognition; deep learning; siamese networks

地震滑坡是指由地震活动而引发的严重自然灾害之一,由于地表松动、土壤液化和山体崩塌等原因,导致土壤、岩石等物质沿斜坡或山体表面发生快速滑动和下滑的现象[1]。因其破坏性强、影响面积大和突发性等特点,给人们的生存和自然环境带来了巨大危害。因此,准确检测和识别地震滑坡对于减灾、应急和灾后重建工作具有重要意义。

近几十年来,随着遥感技术的快速发展,遥感卫星的数量激增,给研究工作提供了大量数据支持,因此采用光学遥感影像或合成孔径雷达(synthetic aperture radar,SAR)图像的研究逐年增多,其中光学遥感影像由于其分辨率高且具备多光谱特性,当前有许多研究者在农业、军事、地质环境监测等多个领域对其展开了研究[2-3]。但光学遥感影像极易受到自然条件的影响,在地震滑坡检测的任务中由于地震发生时通常伴有云、雨、雾等恶劣天气,导致光学遥感影像在此情况下受限,而SAR图像穿透云层和雾霾的特点得以体现,因此基于SAR图像开展滑坡检测任务具有十分重要的价值。由于单一震后SAR图像中仅包含有限的时间分辨率,且无法提供地表变化的历史信息,因此在进行地物检测任务中,有不少学者通过多时相的SAR图像数据来捕获更加精细的变化信息[4]。

在传统遥感图像变化检测中,通常先根据两张影像构建差异图,再通过无监督的分类或聚类方法对差异图进行分析。差异图的构建方法现阶段常采用图像差分法、比值法、均值比法、对数比法等[5]。无监督分类通常采用阈值分割法对图像进行分类,方法包括Kittler-Illingworth法[6-7]、Expectation-Maximization法[8]和大津法[9]等。聚类方法常采用K均值聚类[10]、模糊C均值聚类[11]、模糊局部信息C均值聚类[12]等方法。而上述方法大多需要根据阈值手动过滤特征,忽略了像素之间的语义关系,在构建差异图时只能通过两张影像的浅层像素信息来获取变化,难以捕获深层次信息。

近年来,深度学习发展迅速。深度卷积神经网络提取的高维特征具有抽象的语义信息,低维特征又包含丰富的纹理细节信息,因此在SAR图像分类[13-14]、变化检测[15]、目标识别[16]等方面得到广泛应用。Zhang等[17]采用去噪编码结构对多源遥感影像数据进行了变化检测,其精度优于传统的变化检测方法。Wang等[18]利用Faster R-CNN对高分辨率遥感图像进行了变化检测。Gao等[19]将双树复小波变换引入到卷积神经网络中降低了散斑噪声的影响,对SAR进行了海面冰层的变化检测。

在滑坡检测领域,Wang等[20]选取空间信息相同但时间序列信息不同的光学遥感图像进行波段融合,提出了一种基于混合谱特征卷积神经网络的遥感识别方法进行滑坡识别。Yi等[21]针对光学遥感数据提出了一种用于端到端训练的

深度学习网络 LandsNet，以学习滑坡的各种特征，并通过形态学处理对识别出的滑坡图进行了优化，取得了较好的检测效果。Gao 等[22]针对光学遥感数据提出了一种语义分割网络全卷积 DenseNet用于滑坡识别，证明了全卷积网络在滑坡识别与测绘领域的价值。Nova 等[23]通过深度卷积神经网络比较了光学遥感影像（Sentinel-2）和 SAR 图像（Sentinel-1）对 2018-09-06 在日本北海道发生的地震滑坡的检测能力，研究结果表明，综合使用SAR组合数据也可以实现较高精度的滑坡检测。2022 年，Nova 等[24]又通过在语义分割网络 U-Net 的基础上引入注意力机制，对 2018 年日本北海道的同震滑坡分割展开研究。结果表明，利用深度学习技术并采用 3 个时相的升轨 SAR 图像可以实现滑坡提取，$F1$ 分数达到了 61%。综上所述，目前利用光学遥感图像进行滑坡检测的研究工作已取得较好的进展，但通过SAR图像开展的研究工作较少。对此，本文将变化检测引入到该任务中，通过震前、震后不同时相的SAR图像提供的地表变化信息进行特征提取，最终达到滑坡边界的识别。为解决传统变化检测中SAR图像分辨率较低、难以提取滑坡特征且滑坡尺度多样等问题，本文提出了一种差异特征与聚合特征交叉融合孪生网络（difference and aggregated feature cross fusion siamese network，DACS-Net），利用 Sentinel-1 提供的两张不同时间的SAR图像对地震滑坡进行实验，取得了较好的识别效果。主要贡献如下：

1）提出一种基于深度学习方法的变化检测网络DACS-Net，该模型采用孪生结构的编码-解码形式构成，实现了基于SAR图像的地震滑坡自动识别。

2）为了充分学习两个时相SAR影像的差异性和相似性特征，本文在孪生架构的编码器提取出特征后，在解码器中构建了一个多尺度差异特征和聚合特征生成模块（mutil-scale difference and aggregated feature generate module，MDAG），该模块用于在高维特征中生成差异特征和聚合特征，将孪生网络提取的不同维特征转化为更具有代表性的变化信息，为后续的变化检测任务提供更有价值的输入，提高检测的准确性和鲁棒性。

3）在解码器中提出了一个多特征交叉融合模块（mutil-feature cross fusion module，MFCM），该模块充分利用提取到的差异性特征和聚合特征，通过巧妙设计的跨层连接来融合不同分辨率的特征，并逐层上采样得到滑坡识别结果。

1　基于孪生网络的SAR图像滑坡识别方法

1.1　整体网络框架

本文提出的DACS-Net整体网络结构如图1所示。首先将地震前后的两景SAR图像输入DACS-Net模型，经过参数共享的ResNet网络提取不同时相的地震滑坡特征，进而利用MDAG模块对输入的特征进行处理，获取地震滑坡的差异性特征和聚合特征，并经解码器中构建的MFCM模块进行反卷积和跨层级的特征融合细化，依次产生不同分辨率的特征图，并充分融合不同分辨率中滑坡的特征。最后将解码器输出的4个特征融合堆叠后经过卷积模块和双线性插值上采样得到与原始图像分辨率一致的地震滑坡识别结果。

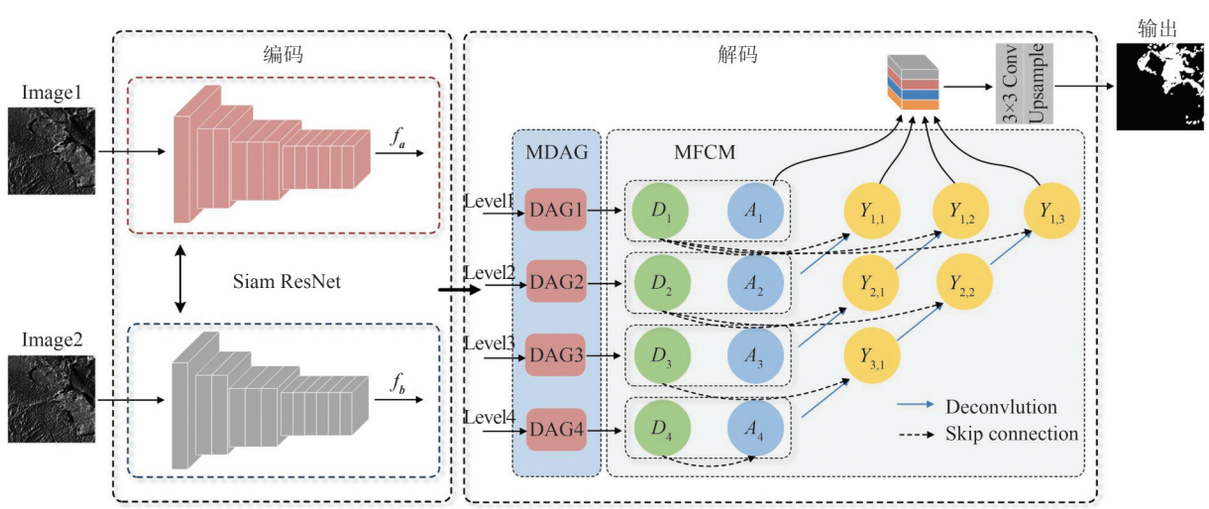


图1　DACS-Net整体网络结构图

Fig. 1　Overall Network Structure of DACS-Net

1.2 编码器

变化检测是指通过对多个时间点或多源数据进行比较,以发现其场景中的变化情况,用于监测自然或人为引起的变化现象。能够进行端到端训练的深度学习方法目前主要可分为早期融合和后期融合两种方式[25],如图2所示。早期融合(图2(a))是指在深度网络的输入阶段进行多个时相影像的数据融合,形成多通道的输入。这种方法能够使得网络模型直接学习多时相数据之间的复杂关系,有助于提取更丰富的特征信息。但在该方法中数据融合在一开始就已完成,使得属于不同时相的特征可能会相互影响。后期融合(图2(b))是指在深度网络的中间或末端阶段通过特征拼接等方式将多个时相的特征图进行融合,将原始影像的特征提取功能和差异识别功能通过多层网络链接在同一个网络中。这种方法充分利用网络在不同阶段提取的特征信息,增加了特征的多样性和表达能力。后期融合常采用孪生网络结构对不同时相的图像数据进行特征提取,在变化检测任务中,该结构可以有效地学习图像的差异性和相似性,从而实现对两幅图像之间的变化检测。文献[26]中提出了3种基于全卷积神经网络的变化检测网络,并通过孪生网络与样本早期融合网络的对比证明了孪生结构网络在变化检测中的优势。文献[27]通过全卷积神经网络结构的孪生网络用于对高分辨率图像的变化检测,引入双注意力机制捕获长距离依赖,获得更具判别性的特征表示,从而增强模型的识别性能。

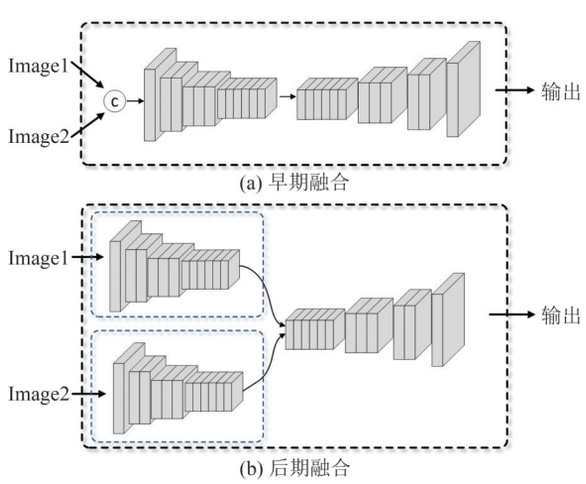


图2 早期融合与后期融合

Fig. 2 Early Fusion and Late Fusion

因此,本文采用后期融合的方法,并在编码网络中采用ResNet50作为主干特征提取网络[28]。ResNet作为一种深度卷积神经网络,具有多个层级的特征表示能力,可以学习更加丰富和复杂的特征。它通过跳跃连接(也称残差连接)在网络中传递原始输入的信息,使得网络可以更好地学习残差特征,有效地缓解了梯度消失问题;同时也使得ResNet可以训练更深的网络,提高了网络的性能和表达能力。本文提出的DACS-Net中采用孪生结构的ResNet50作为共享的特征提取器,这种参数共享使得两个孪生网络可以共享相同的特征表示能力,从而减少了网络的参数量,提高了模型的训练效率和特征提取性能。

1.3 解码器

1.3.1 MDAG模块

解码器中构建的MDAG模块由4个相同的差异特征与聚合特征生成模块(difference and aggregated feature generate module, DAG)构成。DAG模块的主要功能是将编码器中得到的同一尺度、不同时相的特征信息转化为差异性特征和聚合特征提取,如图3所示,其中f_a和f_b为编码器捕获的不同时相的特征信息;$D(\boldsymbol{a},\boldsymbol{b})$表示差异性特征,$A(\boldsymbol{a},\boldsymbol{b})$表示聚合特征。

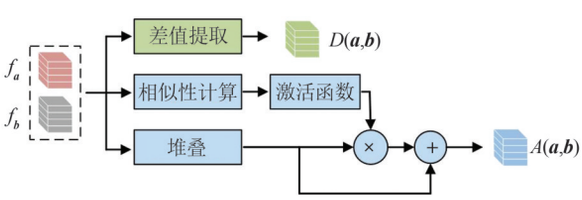


图3 差异特征与聚合特征生成模块

Fig. 3 Difference and Aggregated Feature Generate Module

在传统的图像变化检测中,常采用差值法、比值法、均值比法等构建能体现变化特征的差异图[29-30],再通过无监督或有监督的方法进行变化特征检测。因此DAG模块通过对不同时相的特征进行差异运算,用于捕捉图像之间的差异和变化信息,公式如下:

$$D(\boldsymbol{a},\boldsymbol{b})=\mathrm{Sub}\left(f_a,f_b\right) \tag{1}$$

式中,Sub( )函数为差异提取,即矩阵相减。

通过差值运算对两个特征图对应像素进行比较,获取能够反映图像变化的差异图,帮助人们更清晰地识别和定位变化区域。通过该操作将震前、震后的特征信息转化为更具有代表性的变化信息,为后续的变化检测任务提供更有价值的输入,提高变化检测的准确性和鲁棒性。聚合特征是指将不同时相的特征进行融合后得到的特征,通过引入注意力机制,对变化剧烈区域给予更大的关注度和权重来获取更有利于滑坡识

别的特征信息。其具体操作为:首先计算两个时相特征矩阵的余弦相似度,获取两个影像的相似度信息。该方法是一种用于衡量两个向量在多维空间中的相似程度的方法,公式如下:

$$h=\frac{f_a \cdot f_b}{\| f_a \| \| f_b \|}=\frac{\sum_{i=1}^{n} f_{ai} \times f_{bi}}{\sqrt{\sum_{i=1}^{n} {f_{ai}}^2} \times \sqrt{\sum_{i=1}^{n} {f_{bi}}^2}} \tag{2}$$

式中,a、b为两个时相的特征矩阵;f_{ai}和f_{bi}分别是f_a和f_b在第i维上的对应元素。进而将得到的相似度特征通过增维和Sigmoid函数转化为注意力特征图,公式如下:

$$g=\sigma\left(\gamma(h)\right) \tag{3}$$

式中,$\gamma(h)$用于对相似度特征增加维度;$\sigma(\ )$表示Sigmoid函数。生成的注意力图g大小为$H\times W\times 1$。

然后将震前、震后提取到的特征进行堆叠,如图3所示,并利用注意力特征图完成聚合特征的提取,公式如下:

$$A(\boldsymbol{a},\boldsymbol{b})=\left(f_a \oplus f_b\right) \otimes g+\left(f_a \oplus f_b\right) \tag{4}$$

式中,$\oplus$表示多维特征矩阵的通道堆叠;$\otimes$表示采用哈达马乘积实现。

MDAG模块将4组不同分辨率的特征经过上述步骤得到4组差异性特征$D(\boldsymbol{a},\boldsymbol{b})$和聚合特征$A(\boldsymbol{a},\boldsymbol{b})$。

1.3.2　MFCM模块

U-Net解码结构通过跳跃连接将编码器取得的多分辨率特征进行结合,充分利用语义信息丰富的高维特征,同时考虑低维特征的细节与纹理信息,使网络在变化特征提取任务中更好地捕捉细节和边界信息[31]。但在语义分割任务中,编码阶段提取到的不同层级特征具备不同的重要性。受UNet++[32]和SNUNet[33]的启发,结合跨层级连接的特点,本文提出了MFCM模块,在解码过程中分层加入MDAG模块提取的不同分辨率的差异性特征,结构如图4所示。

图4中,S和P分别代表DAG模块提取到的差异性特征和聚合特征,n代表不同分辨率的特征维度。在解码过程中,设$\boldsymbol{Y}_{i,j}$为第i个维度的第j个张量矩阵,其计算公式如下:

$$\boldsymbol{Y}_{i,j}=\begin{cases} Y_{i+1,j-1}+S_i, & j\neq 1 \\ P_{i+1}+S_i, & j=1 \end{cases} \tag{5}$$

该解码结构能更好地识别不同尺度的滑坡,并自适应地调整不同尺度特征对预测结果的权重占比。这样的跨层级的连接方式将低层特征和高层特征进行有效融合,在解决特征丢失问题的同时,提高了模型的稳定性和鲁棒性,在保留高分辨率特征的同时,通过逐步融合更丰富的语义信息和变化特征,提升了分割的准确性。

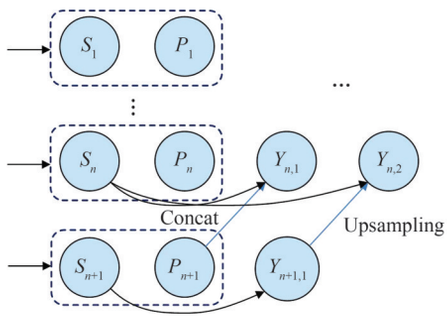


图4　MFCM结构

Fig. 4　Structure of Multi-feature Cross Fusion Module

MFCM模块中对高维特征进行上采样的操作(图4)由反卷积实现,通过反卷积将低分辨率特征图进行上采样。反卷积相比于传统插值法进行的上采样,具有更强的学习能力,可以通过反向传播来调整卷积核的权重,使得模型能够自动学习更适合特定任务的上采样方式,从而提高了模型的表示能力和性能,并且在上采样的过程中能够更好地捕获特征之间的空间关系,实现特征的融合,有助于保留更多的语义信息,从而提升上采样后图像的质量和准确性。将上采样后的特征图与变化特征图通过跨层级链接进行特征融合,从而保留了全局和局部的上下文信息。

最终编码器生成的不同尺度的特征通过MDAG模块和MFCM模块进行处理,得到4个大小为$\frac{H}{4}\times\frac{W}{4}$的特征图,通道堆叠后利用3×3卷积模块和双线性插值进行像素二分类和4倍上采样,得到与网络输入原始图像尺寸相同的滑坡识别结果。

2　实验结果分析

2.1　实验数据与评估指标

本文对巴布亚新几内亚2018-02-26发生的7.5级逆冲型地震引发的大量滑坡进行实验研究。该地区地处太平洋板块、印度洋板块及澳大利亚板块的交界地带,震中(6.19°S,142.77°E)位于巴布亚新几内亚波尔盖拉西南92 km处,震源深度35 km。由于不同地区以及不同滑坡之间在SAR图像中所呈现出的特点差异较大,可能会导致不同地区的滑坡数据在检测上效果不同。但由于当前没有公开的滑坡数据集,而且其他的SAR传

感器数据获取难度较大,数据购买较贵,因此本文仅采用公开的Sentinel-1传感器获取的5 m×20 m分辨率的单视复数影像(single look complex,SLC)数据进行实验。其他的SAR传感器数据在后续研究中也会进一步通过其他渠道获取,并展开相关研究。

震前、震后的SAR图像(Sentinel-1)分别拍摄于2018-02-19与2018-03-03,实验所用的滑坡目录由HakanTanyaş[34]提供。图5(a)所示为Sentinel-2光学遥感影像展示的该地震滑坡的重要区域,实验采用的SAR影像由图5(b)中黑色方框所提供的Sentinel-1数据拼接而成(如图5(b)中红色方框所示)。图5中红色区域为地震滑坡目录,黄色方框S_1和S_2为本文选用的独立测试区域。首先将巴布亚新几内亚地震滑坡区Sentinel-1数据与Sentinel-2遥感影像进行配准,在ArcGIS软件中将SAR图像与滑坡目录进行匹配;进而将震前和震后两张SAR图像和对应滑坡目录裁剪成512×512像素的样本。在训练集中按照10:1划分出验证集,并对训练样本进行数据增强,包括水平翻转、垂直翻转、顺时针旋转90°、顺时针旋转180°、逆时针旋转90°共5种数据增强方式,产生最终的数据集。此外,图5所示黄框范围内的滑坡留出作为独立测试区域,不参与数据集制作。

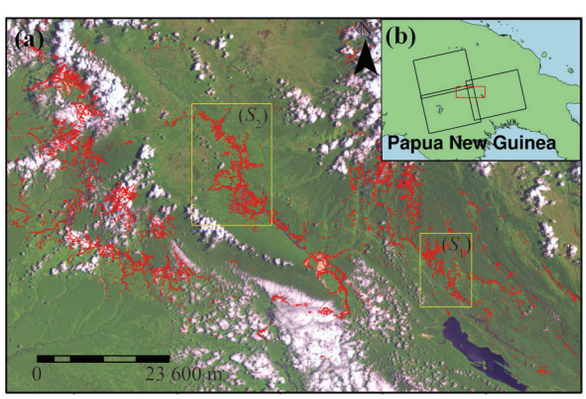


图5 巴布亚新几内亚地区光学遥感影像(a)及滑坡目录(b)

Fig. 5 Optical Remote Sensing Images (a) and Landslide Catalogue (b) in Papua New Guinea Region

为了评估本文所提方法的性能,选择查准率(P)、召回率(R)、$F1$分数、总体准确率(overall accuracy,OA)和平均交并比(mean intersection over union,mIoU)作为评价指标。查准率P是模型预测为正类的样本中真正为正类的比例,召回率R表示真正为正类的样本中被模型正确预测为正类的比例,$F1$分数是综合考虑查准率和召回率的一个综合评价指标,描述为模型正确预测的样本占总样本数量的比例,mIoU衡量预测结果和真实标签的重叠情况,用于度量分割精度。计算公式如下:

$$P=\frac{N_{TP}}{N_{TP}+N_{FP}}\times 100\% \tag{6}$$

$$R=\frac{N_{TP}}{N_{TP}+N_{FN}}\times 100\% \tag{7}$$

$$F1=2\times\frac{PR}{P+R}\times 100\% \tag{8}$$

$$OA=\frac{N_{TP}+N_{TN}}{N_{TP}+N_{TN}+N_{FP}+N_{FN}}\times 100\% \tag{9}$$

$$mIoU=\frac{1}{k+1}\sum_{i=0}^{k}\frac{N_{TP}}{N_{FN}+N_{FP}+N_{TP}}\times 100\% \tag{10}$$

式中,TP(true positive)为真阳性,即正确预测为滑坡的像素点数(用N_{TP}表示);TN(true negative)为真阴性,即正确预测为背景的像素点数(用N_{TN}表示);FP(false positive)为假阳性,即错误预测为滑坡的像素点数(用N_{FP}表示);FN(false negative)为假阴性,即错误预测为负类的像素点数(用N_{FN}表示);k表示目标的类别。

2.2 实验环境与参数设置

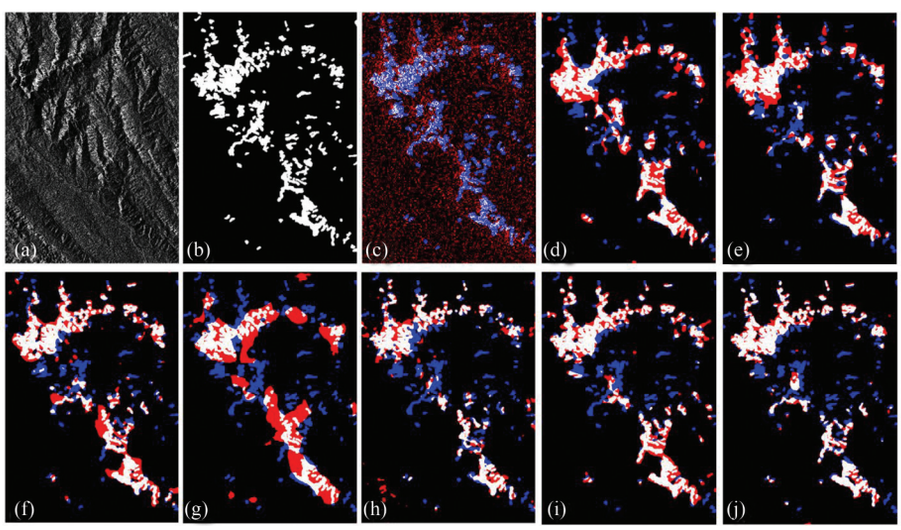
本文实验通过PyTorch框架实现,软件环境为PyTorch 1.7.1,CUDA 11.3和Python 3.8;硬件环境为GPU(单)NVIDIA RTX 3090。所有实验将随机数种子设置为20,优化器采用Adam优化算法,初始学习率设置为0.000 1,学习率策略选用ReduceOnPlateau策略,其中Patience参数设置为15。训练模型时输入的Batch size设置为16,所有样本共训练200个epoch,且每轮训练后均进行验证,并根据验证结果的$F1$分数选取最优模型权重。

2.3 实验结果分析

为了验证本文方法的有效性,与采用均值比算法构建差异图,再通过K均值聚类算法进行分类结果对比实验。同时,由于当前有很多针对SAR图像的工作都采用经典的语义分割网络进行,如Kong等[35]将DeepLabV3+网络应用到SAR图像的多分类检测任务中;Nava等[24]在U-Net网络的基础上引入了一种注意力机制完成滑坡绘制。由此可见,在SAR图像的各项任务中,这些经典的语义分割网络的检测能力已得到充分证明,因此本文选择经典的U-Net和DeepLabV3+网络进行对比,而MFAFNet网络正是在DeepLabV3+基础上进行改进而来,其具备经典网络优秀检测能力的同时也在SAR图像上进行了应用[36],在对比实验中具备重要的参考价值。

同时增加用于变化检测任务的SNUNet、ChangeNet和FC-Siam-diff网络做进一步对比，以说明本文方法的可靠性。在实验中将不同的方法统一了主干网络，对比实验结果如图6、图7所示。

由滑坡目录（图6(b)）可知，该场景的滑坡面积小且位置相对分散，由于Sentinel-1系统分辨率较低（约5 m × 20 m），很多滑坡在SLC影像中只有几十个像素。这要求网络具备较好的细节特征提取能力，从检测结果可以看出，ChangeNet检测结果较差（图6(g)），在该区域存在较大面积的虚警和漏警，滑坡特征的细节提取能力不佳；MFAFNet网络（图6(f)）检测结果也存在类似问题；而采用传统方法通过构建差异图再由K均值聚类算法（图6(c)）检测的效果最差，且在背景上存在很多误检；DeepLabV3+网络（图6(d)）和U-Net网络（图6(e)）检测结果差距较小，对滑坡的边界区域和细节提取的效果不理想，存在很多虚警；SNUNet网络（图6(h)）和FC-Siam-diff网络（图6(i)）的检测效果相对较好，但在右下角区域FC-Siam-diff网络虚警较多，而SNUNet则存在较多漏检；本文提出的DACS-Net（图6(j)）检测结果明显优于其他网络，尽管在一些细小滑坡上仍然存在漏检，但大部分滑坡区域的形状、位置都更接近滑坡目录，表明该网络对细节特征提取能力优于其他网络。



(a) 震后SAR图像；(b) 滑坡目录；(c) K均值聚类滑坡识别结果；(d) DeepLabV3+滑坡识别结果；(e) U-Net滑坡识别结果；(f) MFAFNet滑坡识别结果；(g) ChangeNet滑坡识别结果；(h) SNUNet滑坡识别结果；(i) FC-Siam-diff滑坡识别结果；(j) DACS-Net滑坡识别结果

注：白色部分为滑坡区域，红色为滑坡虚警，蓝色为滑坡漏警。

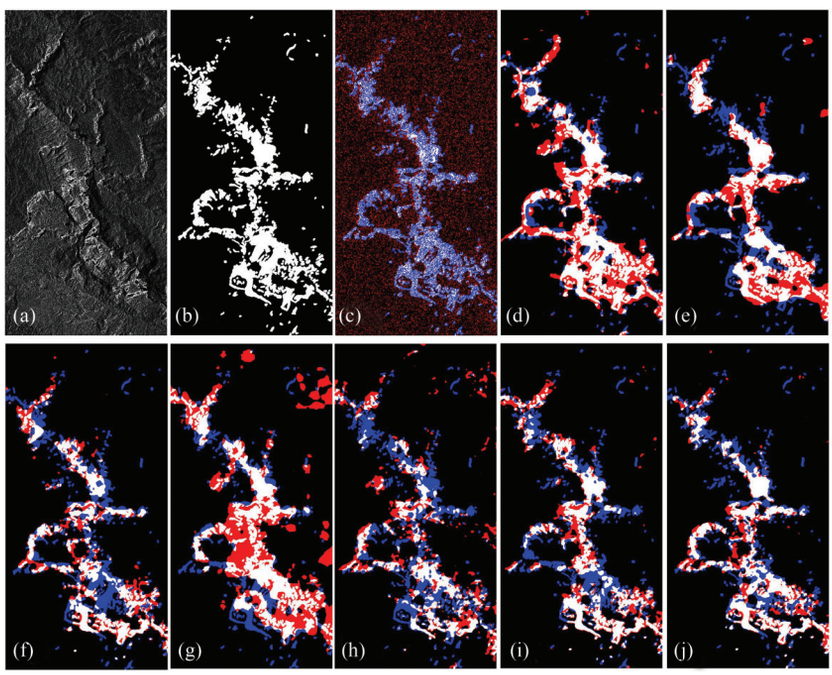
图6　场景Ⅰ滑坡识别实验结果

Fig. 6　Landslides Identification Results of Scene Ⅰ

图7为场景Ⅱ的滑坡识别结果。与图6不同，该区域内的滑坡位置相对集中，但其结构和背景更为复杂，要求网络具备更好的全局语义信息提取能力。从结果可以看出，K均值聚类算法（图7(c)）正确检测到的像素点最少，且背景存在大量细碎的误检；而ChangeNet网络（图7(g)）的滑坡识别结果在深度学习方法中较差，存在大面积的虚警；DeepLabV3+网络（图7(d)）同样存在较多的虚警，而U-Net网络（图7(e)）的虚警虽然比DeepLabV3+网络有所降低，但漏检明显增多；MFAFNet（图7(f)）的检测结果在滑坡边界也存在很多漏检；SNUNet网络（图7(h)）和FC-Siam-diff网络（图7(i)）滑坡识别结果效果类似，在各处都出现了大量尺度不一的漏检以及虚警；而DACS-Net网络（图7(j)）在细节提取上取得了最好的效果，且识别结果边界清晰，漏检和误检均大大少于其他网络，表明该网络的全局语义信息提取能力更强。

根据图6和图7对两个场景滑坡识别实验可知，不同的网络模型在同一个区域中检测结果差距很大。为更好地对结果进行分析，表1给出了两个场景滑坡识别实验的平均评估指标。由表1可以看出，SNUNet、FC-Siam-diff和MFAFNet在$F1$分数上取得了不错的表现，且两者在查准率和召回率上的表现差距较小。ChangeNet除召回率以外，其他各项指标上效果都较差，结合检测结果图可以看出，该网络在大面积误检带来更高的召回率的同时，其准确率下降，在目标定位、目标大小变化和背景区域的处理上存在很多问题，识别出目标类别时存在较多误判，将一些背景区域误分为滑坡，在排除背

景误判方面还有较大改进空间。两种前期融合方式的DeepLabV3+网络和U-Net网络在总体准确率以及$F1$分数上结果较为接近,但同时都存在着较多误检导致精度偏低。



(a)震后SAR图像;(b)滑坡目录;(c)K均值聚类滑坡识别结果;(d)DeepLabV3+滑坡识别结果;(e)U-Net滑坡识别结果;(f)MFAFNet滑坡识别结果;(g)ChangeNet 滑坡识别结果;(h)SNUNet滑坡识别结果;(i)FC-Siam-diff滑坡识别结果;(j)DACS-Net滑坡识别结果

注:白色部分为滑坡区域,红色为滑坡虚警,蓝色为滑坡漏警。

图7 场景Ⅱ滑坡识别实验结果

Fig. 7 Landslides Identification Results of Scene Ⅱ

表1 不同网络算法评估指标对比/%

Table 1 Index Comparison of Different Network Algorithms/%

算法	P	$F1$分数	R	OA	mIoU
K均值	24.17	27.40	31.69	76.39	45.59
DeepLabV3+	58.59	60.50	62.56	88.74	66.61
U-Net	60.38	60.33	60.28	88.87	65.51
MFAFNet	63.91	61.48	59.24	89.16	66.29
ChangeNet	52.19	56.24	61.05	84.48	58.48
SNUNet	64.34	61.21	58.46	88.14	61.94
FC-Siam-diff	64.41	61.63	59.55	89.80	67.02
DACS-Net	70.75	65.46	60.92	91.00	69.23

表2给出了不同网络模型的模型推理时间和模型参数。DACS-Net因采用孪生结构编码器,推理时间比早期融合方式的几个网络稍长,但由于编码器采用参数共享进行特征提取,因此并未显著增加其参数量。从网络结构原理上看,采用传统方法先构建差异图时提取的是不同时相同位置的像素与像素之间的差异,无法通关长距离依赖构建不同位置像素点间的语义特征,因此该方法通过K均值聚类进行检测的效果最差。与SNUNet相比,DACS-Net通过DAG模块将差异性特征和聚合特征分离,通过不同时相间的差异性特征更好地捕获滑坡的变化量,以提升检测效果。与ChangeNet和FC-Siam-diff网络相比,DACS-Net在引入差异性特征的基础上,通过MFCM模块进行跨层级连接,逐层将不同分辨率的差异性特征和聚合特征进行融合,在充分利用深层语义特征的同时保留和还原了低层的细节特征。而在DeepLabV3+和U-Net中,早期融合方式使得两个时相的特征在进入深度网络前完成融合,因此在特征提取过程中相互影响,降低了其检测效果,DACS-Net则通过孪生结构的编码结构分别进行不同时相的特征提取,保留了震前震后滑坡特征,方便其在后期更好地捕获变化量。与MFAFNet网络相比,该网络将不同分辨率的特征分别处理,特征融合时更加注重深层的语义信息,而DACS-Net针对滑坡检测任务的特点和难点,在解码器中通过MDAG和MFCM模块将两个时相的特征进行处理并逐层进行不同分辨率的特征融合,给予低层细节信息更多的权重,更有效地保留了语义信息和细节信息。因此本文提出的DACS-Net在多个关键指标上表现出显著的优越性(表1),其P达到70.75%,远高于其他网络,意味着该网络对于正

样本的识别和预测非常精确；而$F1$分数作为P和R的调和平均也取得了最好的结果，达到65.46%，表明DACS-Net在预测准确性和正样本捕捉能力之间取得了更好的平衡，在捕捉正样本方面表现优秀。此外，DACS-Net在mIoU上也表现出了更好的能力，其值为69.23%，体现了其在真实结果和预测结果的重叠度方面具备出色的性能，虚警更少。同时该网络在OA上的检测指标为91.00%，强调其对整体预测的高准确性和稳定性。综合来看，DACS-Net的滑坡识别效果更好，采用孪生网络充分利用了网络在不同阶段提取的特征信息，显著增加了特征的多样性和表达能力，并通过差异特征与聚合特征密集连接和逐层融合的特点带来了更好的全局语义信息学习能力和细节特征提取能力。

表 2　不同网络算法的推理时间

Table 2　Inference Time of Different Network Algorithms

算法	参数量/MB	模型推理时间/s		
		区域Ⅰ	区域Ⅱ	平均推理时间
U-Net	31.80	0.428	0.903	0.665
DeepLabV3+	40.35	0.518	0.834	0.676
MFAFNet	49.26	0.532	0.893	0.712
ChangNet	36.64	0.724	1.108	0.916
SNUNet	43.92	0.961	1.431	1.196
FC-Siam-diff	40.32	0.672	1.250	0.961
DACS-Net	47.67	0.792	1.316	1.054

为进一步证明本文方法的普适性，另外选择了2017-11-18发生在中国西藏米林地区6.9级地震引发的滑坡区域进行了实验，米林县地处中国西藏东部、雅鲁藏布江中游、念青唐古拉山与喜马拉雅山之间，位于28°39′N～29°50′N，93°07′E～95°12′E。分别使用了震前2017-11-11和震后2017-11-23 Sentinel-1的SAR图像。该地区的光学遥感图像与滑坡目录的融合图如图8所示。

由于中国西藏米林地区与巴布亚新几内亚地区的地形、地质环境以及滑坡规模相差较大，本文利用所提方法对该地区在图8中两个方框外的数据进行训练，并对两个方框内的数据进行独立测试。DACS-Net网络的检测结果如图9所示，其中图9(a1)、(a2)是两个检测区域的震后SAR图像，图9(b1)、(b2)是滑坡目录真值标签，图9(c1)、(c2)是DACS-Net网络的检测结果。最终的P为76.52%，R为71.20%，$F1$分数为74.03%，OA为86.14%，mIoU为73.32%。由该结果可以发现，对于规模较大的滑坡可以实现较好检测，但滑坡检测的边缘部分容易出现少许漏检，在结果中也出现了几处类似滑坡特征的小虚警目标，但整体上验证了本文方法在SAR图像滑坡检测上的有效性。

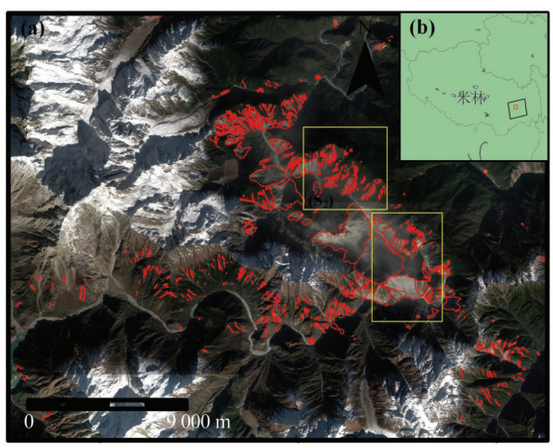
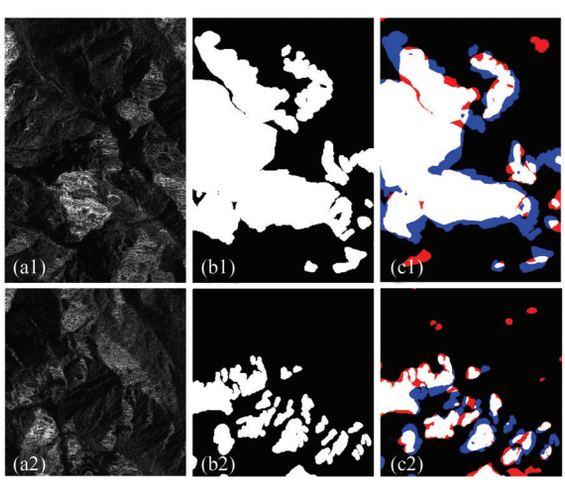


图 8　米林地区光学遥感影像及其滑坡目录融合图

Fig. 8　Fusion Map of Landslide Inventory and Optical Remote Sensing Iamge in Milin



(a1)、(a2) 两个检测区域的震后SAR图像；(b1)、(b2) 滑坡目录真值标签；(c1)、(c2) DACS-Net网络的检测结果

图 9　米林地震滑坡识别实验结果

Fig. 9　Identification Results of Milin Earthquake-Triggered Landslides

3　结　语

本文针对SAR图像滑坡识别这一复杂且具有挑战性的问题，提出了一种基于深度学习算法的DACS-Net网络，该网络利用SAR影像实现了较高精度的滑坡自动识别。通过震前震后两个时相的SAR图像作为网络模型的输入，采用孪生结构的主干网络作为编码器以提取不同时相的滑坡特征；在解码器中构建了MDAG模块，用于将编码器捕获的4种尺度的特征进行不同时相的差异提取和特征聚合，进而经过设计的MFCM

模块实现跨层级连接,对不同尺度的特征进行充分融合,最后还原至原始图像大小,获取滑坡识别结果。从巴布亚新几内亚和中国西藏米林地震滑坡实验结果可以看出,DACS-Net与其他6个深度网络模型和一个传统变化检测提取方法相比,滑坡识别结果具有明显优势。本文将基于SAR图像进行的滑坡识别任务与深度学习算法、孪生网络相结合,并针对差异性特征和多尺度问题进行优化,为其他学者开展滑坡检测任务提供了新的思路。本文方法虽然对于较小滑坡有部分漏检,但当使用更高分辨率的SAR图像数据时,同时借助迁移学习等方法,DACS-Net网络将可以获得更好的滑坡识别结果,为地震发生后的应急救灾提供第一手信息支持发挥重要作用。

参 考 文 献

[1] HU X, WANG T, PIERSON T C, et al. Detecting Seasonal Landslide Movement Within the Cascade Landslide Complex (Washington) Using Time-Series SAR Imagery[J]. *Remote Sensing of Environment*, 2016, 187: 49-61.

[2] 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.

[3] 张成龙, 李振洪, 张双成,等. 综合遥感解译2022年Mw 6.7青海门源地震地表破裂带[J]. 武汉大学学报(信息科学版), 2022, 47(8): 1257-1270.
ZHANG Chenglong, LI Zhenhong, ZHANG Shuangcheng,et al. Surface Ruptures of the 2022 Mw 6.7 Menyuan Earthquake Revealed by Integrated Remote Sensing[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(8): 1257-1270.

[4] VINHOLI J G, SILVA D, MACHADO R, et al. CNN-Based Change Detection Algorithm for Wavelength-Resolution SAR Images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 19: 4003005.

[5] REN W L, SONG J S, ZENG J, et al. A Novel Asymmetrical Probability Density Function for Modeling Log-Ratio SAR Images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 369-373.

[6] BAZI Y, BRUZZONE L, MELGANI F. An Unsupervised Approach Based on the Generalized Gaussian Model to Automatic Change Detection in Multitemporal SAR Images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(4): 874-887.

[7] MOSER G, SERPICO S B. Generalized Minimum-Error Thresholding for Unsupervised Change Detection from SAR Amplitude Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(10): 2972-2982.

[8] BRUZZONE L, PRIETO D F. Automatic Analysis of the Difference Image for Unsupervised Change Detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2000, 38(3): 1171-1182.

[9] OTSU N. A Threshold Selection Method from Gray-Level Histograms[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.

[10] YETGIN Z. Unsupervised Change Detection of Satellite Images Using Local Gradual Descent[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(5): 1919-1929.

[11] GHOSH A, MISHRA N S, GHOSH S. Fuzzy Clustering Algorithms for Unsupervised Change Detection in Remote Sensing Images[J]. *Information Sciences*, 2011, 181(4): 699-715.

[12] KRINIDIS S, CHATZIS V. A Robust Fuzzy Local Information *C*-Means Clustering Algorithm[J]. *IEEE Transactions on Image Processing*, 2010, 19(5): 1328-1337.

[13] CHEN L F, CAI X M, XING J, et al. Towards Transparent Deep Learning for Surface Water Detection from SAR Imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 118: 103287.

[14] CAI X M, CHEN L F, XING J, et al. Automatic Extraction of Layover from InSAR Imagery Based on Multilayer Feature Fusion Attention Mechanism[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 4017705.

[15] KHELIFI L, MIGNOTTE M. Deep Learning for Change Detection in Remote Sensing Images: Comprehensive Review and Meta-Analysis[J]. *IEEE Access*, 2020, 8: 126385-126400.

[16] CHEN L F, LUO R, XING J, et al. Geospatial Transformer Is What You Need for Aircraft Detection in SAR Imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5225715.

[17] ZHANG P Z, GONG M G, SU L Z, et al. Change Detection Based on Deep Feature Representation and Mapping Transformation for Multi-Spatial-Resolution Remote Sensing Images[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2016, 116: 24-41.

[18] WANG Q, ZHANG X D, CHEN G Z, et al. Change Detection Based on Faster R-CNN for

High-Resolution Remote Sensing Images[J]. *Remote Sensing Letters*, 2018, 9(10): 923-932.

[19] GAO F, WANG X, GAO Y H, et al. Sea Ice Change Detection in SAR Images Based on Convolutional-Wavelet Neural Networks[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(8): 1240-1244.

[20] WANG Y, WANG X F, JIAN J F. Remote Sensing Landslide Recognition Based on Convolutional Neural Network[J]. *Mathematical Problems in Engineering*, 2019, 2019(1): 8389368.

[21] 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.

[22] GAO X, CHEN T, NIU R Q, et al. Recognition and Mapping of Landslide Using a Fully Convolutional DenseNet and Influencing Factors[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 7881-7894.

[23] NAVA L, MONSERRAT O, CATANI F. Improving Landslide Detection on SAR Data Through Deep Learning[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 4020405.

[24] NAVA L, BHUYAN K, MEENA S R, et al. Rapid Mapping of Landslides on SAR Data by Attention U-Net[J]. *Remote Sensing*, 2022, 14(6): 1449.

[25] 梁哲恒，黎宵，邓鹏，等. 融合多尺度特征注意力的遥感影像变化检测方法[J]. 测绘学报，2022，51(5)：668-676.
LIANG Zheheng, LI Xiao, DENG Peng, et al. Remote Sensing Image Change Detection Fusion Method Integrating Multi-scale Feature Attention[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(5): 668-676.

[26] DAUDT R C, SAUX B L, BOULCH A. Fully Convolutional Siamese Networks for Change Detection[C]//The 25th IEEE International Conference on Image Processing (ICIP), Athens, Greece, 2018.

[27] CHEN J, YUAN Z Y, PENG J, et al. DASNet: Dual Attentive Fully Convolutional Siamese Networks for Change Detection in High-Resolution Satellite Images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 1194-1206.

[28] HE K M, ZHANG X Y, REN S Q, et al. Identity Mappings in Deep Residual Networks[C]// European Conference on Computer Vision, Cham, Switerland, 2016.

[29] ZHUANG H F, FAN H D, DENG K Z, et al. A Spatial-Temporal Adaptive Neighborhood-Based Ratio Approach for Change Detection in SAR Images[J]. *Remote Sensing*, 2018, 10(8): 1295.

[30] GONG M G, CAO Y, WU Q D. A Neighborhood-Based Ratio Approach for Change Detection in SAR Images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2012, 9(2): 307-311.

[31] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional Networks for Biomedical Image Segmentation[C]//Medical Image Computing and Computer-Assisted Intervention, Lausanne, Switzerland, 2015.

[32] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHSH N, et al. UNet++: A Nested U-Net Architecture for Medical Image Segmentation[C]// Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support, Cham, Switzerland, 2018.

[33] FANG S, LI K Y, SHAO J Y, et al. SNUNet-CD: A Densely Connected Siamese Network for Change Detection of VHR Images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2021, 19: 8007805.

[34] TANYAŞ H, HILL K, MAHONEY L, et al. The World's Second-Largest, Recorded Landslide Event: Lessons Learnt from the Landslides Triggered During and After the 2018 Mw 7.5 Papua New Guinea Earthquake[J]. *Engineering Geology*, 2022, 297: 106504.

[35] KONG Y Y, LIU Y J, YAN B Y, et al. A Novel DeepLabV3+ Network for SAR Imagery Semantic Segmentation Based on the Potential Energy Loss Function of Gibbs Distribution[J]. *Remote Sensing*, 2021, 13(3): 454.

[36] 陈立福，龙凤琪，李振洪，等. 面向多源 SAR 图像的多级特征注意力水体提取网络[J]. 武汉大学学报（信息科学版），2023，DOI：10.13203/J.whugis20230041.
CHEN Lifu, LONG Fengqi, LI Zhenhong, et al. Multi-level Feature Attention Fusion Network for water extraction from multi-source SAR images[J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI:10.13203/J.whugis20230041.