

基于特征金字塔的协作式变化检测网络

吕宁, 刘亦高, 张增辉
(西安电子科技大学 西安 710000)

摘要: 基于深度学习的变化检测方法在高分辨率遥感图像的应用越来越多。然而, 在处理大尺寸遥感图像上, 为适应 GPU (图形处理器) 内存限制而采用的降采样和裁剪策略, 往往会导致语义信息不完整和图像细节丢失。本文提出了一种基于特征金字塔的协作式监督网络, 使网络能够从裁剪和降采样的图像块中学习局部和整体特征。此外, 还引入了一种特征共享机制来融合整体特征和局部特征。在 LEVIR-CD (遥感变化检测数据集) 和 S2Looking (建筑物变化检测数据集) 上对该网络进行了评估, 并将其与一些代表性的变化检测网络进行了比较。对比实验表明: 所提出的网络在多尺度变化检测方面表现更好, 在 LEVIR-CD 数据集上精确率提高了 2.69%, 在 S2Looking 数据集上精确率和召回率分别提高了 6.83%、2.68%。

关键词: 变化检测; 遥感卫星影像; 特征金字塔; 特征共享

中图分类号: TP751 **文献标志码:** A **文章编号:** 2095-1000(2024)05-0120-09

DOI: 10.12347/j.ycyk.20240123001

引用格式: 吕宁, 刘亦高, 张增辉. 基于特征金字塔的协作式变化检测网络[J]. 遥测遥控, 2024, 45(5): 120-128.

A Collaborative Change Detection Network Based on Feature Pyramids

LYU Ning, LIU Yigao, ZHANG Zenghui
(Xidian University, Xi'an 710000, China)

Abstract: There are more and more applications of change detection methods based on deep learning in high-resolution remote sensing images. However, downsampling and cropping strategies deployed to fit the GPU (Graphic Processing Unit) memory constraints on processing large-size remote sensing images often result in incomplete semantic information and loss of fine details. In this paper, a collaborative supervised network based on feature pyramids is proposed to enable the network to learn local and overall features from cropped and downsampled image blocks. In addition, a feature-sharing mechanism is introduced to fuse global features and local features. We evaluated the network on the LEVIR-CD (a remote sensing change detection dataset) and S2Looking (a building change detection dataset) by comparing it with some representative change detection networks. The comparison experiments show that the proposed network performs better in multi-scale change detection, with a 2.69% improvement in precision on LEVIR-CD, and 6.83% and 2.68% improvement in precision and recall on the S2Looking dataset, respectively.

Keywords: Change detection; Remote sensing images; Feature pyramid; Feature sharing

Citation: LYU Ning, LIU Yigao, ZHANG Zenghui. A Collaborative Change Detection Network Based on Feature Pyramids[J]. Journal of Telemetry, Tracking and Command, 2024, 45(5): 120-128.

0 引言

遥感变化检测是观测和分析地理信息的重要方法, 是指对同一地区、不同时间获取的多幅遥感图像来识别物体或现象之间差异的技术^[1]。这项技术应用广泛, 包括城市规划、灾害评估、环境监测、农业调查和地图修订^[2]。遥感图像包含丰富的地面物体信息, 如颜色、形状、位置、纹理和

分布密度等, 这些信息构成了变化检测任务的主要基础。随着遥感观测技术的发展, 现在的图像分辨率越来越高, 甚至达到了超高分辨率。这些高分辨率图像所包含的详细地面物体信息为更精确的变化探测提供了有利条件。然而, 复杂的场景和不同大小的物体给变化检测带来了挑战^[3]。

近年来, 深度学习依靠其出色的表征数据特征能力和非线性建模能力^[4], 在计算机视觉领域得

到了广泛应用。随着遥感大数据和人工智能的发展,深度学习方法被迅速引入遥感图像解译领域^[5],在分类、去噪、分割^[6]等任务中表现出了强大的应用潜力。深度学习可以自动学习遥感图像,通过分层非线性特征提取器获得分层复杂特征,突破了传统方法构造特征的局限性,显著提高了变化检测的精度。基于深度学习的方法具有精度高、端到端检测自动化^[7]等特点,逐渐成为现阶段变化检测的主流算法。目前,在遥感解译实际应用中,通常获取到的遥感数据为大尺寸、大面积的高分辨率图像。对于大尺寸图像,现有的变化检测方法往往采用降采样或裁剪的方式来缩小图像尺寸,然后再作为模型数据输入,以减轻计算机计算的负载。例如Chen等人^[8]提出的STANet和BIT算法,针对GPU内存容量的限制,均采用了裁剪的方式,事先将每张1 024×1 024尺寸的图像裁剪为16块256×256尺寸的图像作为训练数据集,从而减少网络的训练时间。但是裁剪后的图像往往会将单个物体分割为多部分,丢失了物体内部的空间特征信息和物体之间的空间依赖关系,降采样处理则会模糊图像细节,丢失精确的图像特征信息,所以,对图像进行裁剪或降采样的方式会导致网络在处理多尺度空间信息^[9]时存在不足,从而影响变化检测的精度。

为解决这一问题,本文提出了一种基于特征金字塔^[10]的变化检测网络。该网络引入了特征共享的机制,采用由粗到细的检测思想。首先,使用降采样策略处理数据,让模型检测整体变化;然后,使用裁剪策略处理数据,在整体检测模型的基础上,共享提取到的整体变化特征,使用局部检测模型提取变化主体边缘细节;最后,通过共享局部检测模型提取到的局部特征信息来增强整体检测模型的细节检测能力。在保证检测图像空间信息和语义信息完整的情况下,实现对大尺寸高分辨率多时相遥感图像变化信息的提取。

1 基于特征金字塔的协作式变化检测网络

1.1 总体框架

为了检测大尺度遥感图像中的变化,本文提出了一种协作式监督网络,即整体-局部变化检测网络(Global-Local Change Detection Network, GLCDNet)。该网络利用了整体信息更容易检测变化对象和局部信息能提取更详细细节信息的特点,并引入了一种特征共享机制使提取的整体和局部的特征进行融合,从而保证大尺寸图像的空间完整性和局部变化信息的精确检测。GLCDNet的模型分为整体分支和局部分支,两个分支的网络结构相同。网络模型的流程示意图如图1所示。

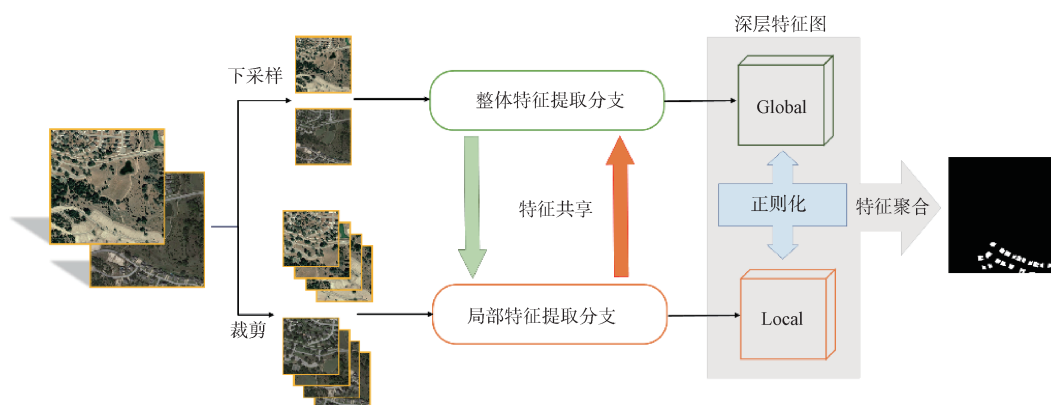


图1 GLCDNet模型流程图

Fig. 1 Flowchart of GLCDNet

两个分支的模型参数分别在三个训练阶段进行训练。在第一阶段,只训练整体分支的模型参数。将两时相图像降采样为小尺寸图像,然后输入模型,训练检测整个图像粗略变化的能力。在第二阶段,将第一阶段训练的整体分支参数加载到模型中,只训练局部分支的模型参数。使用降

采样和裁剪方式将输入图像处理成相同的小尺寸,分别输入到整体分支和局部分支中。从整体分支提取的特征图经过裁剪和上采样后与局部分支特征共享。输出层聚合整体分支和局部分支最后一层的特征图,通过卷积层输出预测结果。在第三阶段,将第一阶段训练的整体分支和第二阶段训

训练的局部分支的参数加载到模型中, 只训练整体分支的模型参数。数据加载方法与第二阶段相同, 除整体到局部的特征共享之外, 局部分支提取的

特征经过合并和降采样后, 与整体分支的特征进行共享, 最后通过输出层输出预测结果。网络模型结构如图 2 所示。

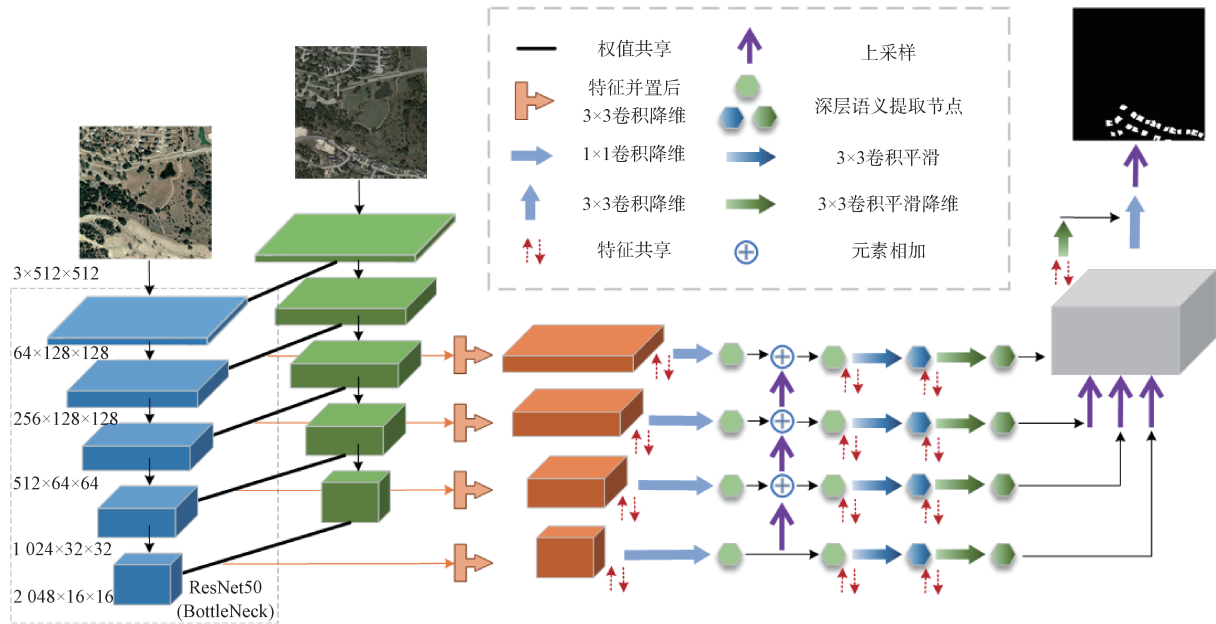


图 2 GLCDNet 模型结构图

Fig. 2 Structure of GLCDNet

1.2 特征提取主干

在特征提取阶段, 采用孪生结构^[11]提取两时相图像各层次的特征。特征提取的主干是 ResNet50^[12], ResNet 使用残差块赋予模型更深的结构, 获得更大的感受野, 增强网络对图像空间信息的获取^[13], 并使深度神经网络更容易训练。

ResNet50 采用了 Bottleneck 残差结构^[12], 依次使用 1×1、3×3 和 1×1 卷积层, 按照卷积层、BN 层和 ReLU 层的方式排列, 其中第一个 1×1 卷积层用于降维, 第二个 1×1 卷积层用于升维。ResNet50 中使用了两种 Bottleneck 结构, 即 BTNK1 和 BTNK2。与 BTNK2 相比, BTNK1 在常量映射分支上增加了一个卷积层, 与残差块的输入和输出特征映射通道数量相匹配。

如图 3 所示, ResNet50 的网络结构分为 5 个阶段(STAGE 0~STAGE 4)。初始阶段(STAGE 0)用于提取浅层图像特征, 不使用残差块。第一阶段增加了特征图通道数, 并使用了三个残差块。第一个残差块使用 BTNK1 来扩展特征图的通道数, 另外两个残差块为 BTNK2。因为 BTNK1 的滑动步长为 1, 所以第一阶段不会缩小特征图的大小。第二至第四阶段分别使用 4 个、6 个和 3 个残差

块, 每个阶段的第一个残差块使用 BTNK1, 其他两个残差块使用 BTNK2。在这三个阶段中, BTNK1 的滑动步长为 2, 因此在每个阶段中, 输入特征图的宽度和高度都会减小到原始高度的 1/2。经过 ResNet50 特征提取, 可以得到多层次不同尺度的图像特征。

1.3 特征金字塔

对于卷积神经网络而言, 通常提取的浅层特征语义信息较少, 但物体的空间信息较丰富; 深层特征更善于表示抽象的语义信息, 但物体的位置信息较模糊^[14]。一般来说, 感受野较小的浅层网络可以提供细粒度目标的空间位置信息, 而大尺寸目标则需要深层网络来保证足够大的感受野以提供必要的深层上下文语义信息, 实际遥感图像中的目标尺度跨度大, 很难用一个固定的感受野表达多尺度的特征^[15]。为了整合图像的多尺度信息, 提升网络的多尺度特征表达能力, 在网络中引入特征金字塔结构^[10], 以实现深层特征和浅层特征的融合, 进一步提高检测的精度。GLCDNet 使用 ResNet50 作为特征提取主干网络, 利用 STAGE 1~STAGE 4 输出的特征图构建特征金字塔结构, 不同尺度的特征信息在处理通过双线性插值实

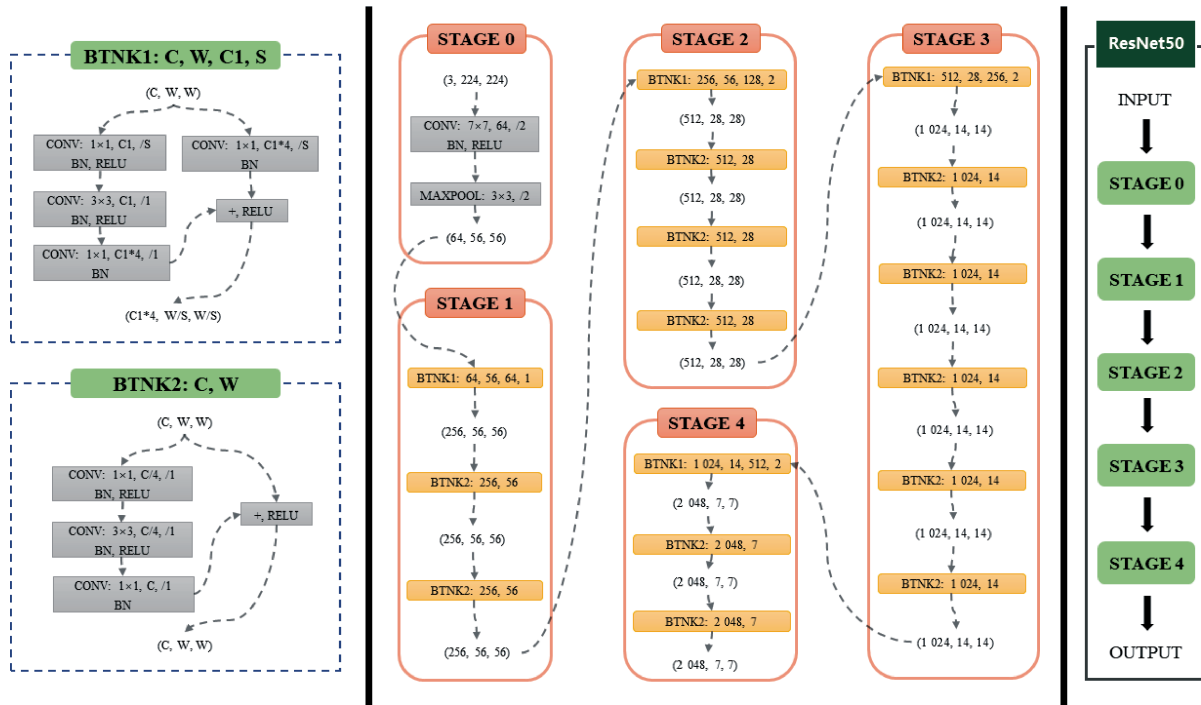


图3 ResNet50模型结构图
Fig. 3 Structure of ResNet50

现上采样，将多尺度的特征信息聚合。

1.4 特征共享

特征共享与GLCDNet的训练阶段有关。在第一个训练阶段，模型只训练整体分支，不进行特征共享。在第二个训练阶段，模型只训练局部分支，从整体到局部分支进行特征共享。在第三个训练阶段，模型只训练整体分支，从整体分支到局部分支以及从局部分支到整体分支进行特征共享。

特征共享机制如图4所示。整体到局部的特征共享，通过对整体分支的特征图进行裁剪和上采样，使特征图的位置与局部分支的特征图相对应，然后将整体和局部的特征通道并置^[16]。局部到整体的特征共享通过对局部分支的特征图进行降采样和合并，缩小特征图的尺寸，然后按位置顺序合并特征图块，再将合并后的特征图与整体特征通道并置。在对输入图像进行裁剪并用于特征图裁剪和合并时，会记录裁剪位置与图像大小的比例。特征共享后，整体特征和局部特征得到了融合，使模型具有更加精确的表达。

1.5 损失函数

在变化检测数据集中，变化像素样本的数量与无变化和少变化样本相比要少得多。为解决这




图4 特征共享机制
Fig. 4 Feature sharing mechanism

种样本不平衡的问题，使用焦点损失(Focal Loss)^[17]作为GLCDNet训练的主要损失函数。此外，局部分支在训练过程中往往会过度学习图像细节，而学习到的图像细节对输出结果的影响会盖过整体分支的特征共享效果，因此引入了均方误差(Mean Square Error, MSE)损失函数来衡量整体分支和局部分支输出特征图之间的差异，并将其作为总损失函数的正则项。总损失函数如式(1)所示。

$$L = L_{curr} + L_{aux} + \lambda L_{mse} \quad (1)$$

其中, L_{curr} 是损失函数的主要部分, 代表训练分支的焦点损失; L_{aux} 是辅助损失函数, 代表通过聚合训练分支和参数不变分支的输出特征图而得到的变化图的焦点损失。 L_{mse} 是正则项, 用于计算整体分支和局部分支输出特征图之间的欧氏距离, 计算方式如式(2)所示, λ 表示损失函数中正则化项的权重, 表示对特征图差异的重视程度。

$$MSE = \ell(x, y) = L = \{l_1, \dots, l_n, \dots, l_N\}^T, \quad l_n = (x_n - y_n)^2 \quad (2)$$

其中, x 和 y 分别表示整体分支和局部分支的输出特征图, N 表示批标准化的样本量。

2 实验结果和分析

2.1 数据集

为了验证所提方法的有效性, 在 LEVIR-CD 和 S2Looking 数据集上对模型进行研究。选取数据集的影像尺寸均为 $1\ 024 \times 1\ 024$, 属于大尺寸高分辨率遥感图像。

LEVIR-CD 数据集^[8]由 637 对图像组成, 图像类型为 RGB(红绿蓝)图像, 空间分辨率为 $0.5\ \text{m}/\text{pixel}$ 。该数据集的采集来源为谷歌地球, 其图像来自美国得克萨斯州的 20 个不同城市。这些双时相影像拍摄于 2002 年~2018 年之间, 时间跨度为 5~14 年, 特意拍摄于不同的季节和光照条件下。该数据集重点关注建筑相关的变化, 全部标注包含 31 333 个独立的变化实例, 包括别墅、高层公寓、小型车库和大型仓库等建筑物。LEVIR-CD 数据集图例如图 5 所示。




图 5 LEVIR-CD 数据集图例
Fig. 5 Samples of LEVIR-CD dataset

S2Looking 数据集^[18]由 5 000 对 RGB 图像组成, 空间分辨率为 $0.5\sim 0.8\ \text{m}/\text{pixel}$ 。该数据集的图像来源是高分(GaoFen)卫星、高景(SuperView)卫星和北京二号遥感卫星于 2017 年~2020 年拍摄的

遥感图像, 时间跨度为 1~3 年。数据集覆盖了全球分布的广泛农村地区, 并包含各种变化广泛的复杂场景, 例如村庄、农场、别墅、零售中心和工业区。该数据集提供了两种标签图, 分别标记了新增和拆除的建筑。S2Looking 数据集图例如图 6 所示。




图 6 S2Looking 数据集图例
Fig. 6 Samples of S2Looking dataset

2.2 实验环境和参数配置

本次实验基于深度学习框架 Pytorch 实现, 计算机操作系统为 Ubuntu 18.04 LTS; 硬件环境的 CPU 型号为 Intel(R) Xeon E5-2687W CPU@3.00 GHz, GPU 型号为 2 块 Nvidia GeForce GTX1080 Ti。

在设置训练参数时, 优化算法使用 Adam 优化方法, 根据经验将优化器的平滑常数设置为 $\beta=0.9$, $\beta=0.999$, 衰减系数设置为 $5\text{E}-4$ 。在第一、三训练阶段, 初始学习率设置为 $5\text{E}-4$, 迭代次数设置为 120; 在第二训练阶段, 初始学习率设置为 $2\text{E}-4$, 迭代次数设置为 50。

2.3 对比实验

为比较本文提出的 GLCDNet 和其他变化检测网络的性能表现, 选择了一些具有代表性的孪生变化检测网络, 即 SNUNet^[19](稠密连接孪生网络)、DSIFN^[20](深度监督的图像融合网络)和 BIT^[21](双时相图像转换器), 作为对比的基准。SNUNet 基于 UNet++ 密集连接的变化检测网络结构, 并设计通道注意力模块, 融合网络各层级输出的特征图。DSIFN 的网络特点是解码器的各级都可以输出变化图, 将损失传递到网络编码器的浅层, 并利用

级联的空间和通道注意力来融合不同域的特征。BIT将卷积主干中提取的特征图转换为视觉语义单词，然后输入到Transformer编码器中，对全局上下文关系进行建模。这三种网络都具有良好的信息表示和多尺度信息聚合能力。在本次对比实验中，训练上述三个网络使用的初始学习率为 $5E-4$ ，迭代次数为120。在训练过程中动态调整学习率，使用Poly策略指数减小学习率。

表1和表2展示了GLCDNet与其他三个变化检测网络在LEVIR-CD和S2Looking数据集的对比实验结果，其中GLCDNet在这两个数据集上的表现都更好。与BIT相比，GLCDNet在LEVIR-CD数据集上的性能除了召回率稍差外，精确率、F1分数和交并比分别提高了2.69%、1.05%和1.67%；在S2Looking数据集上GLCDNet表现出了更大的性能差距，相较于BIT四个指标分别提高了6.83%、2.68%、4.21%和4.91%。GLCDNet在两个数据集上都表现出了更好的准确性，表明该网络具有良好的泛化性能。从LEVIR-CD的表现可以看出，GLCDNet在保证高召回率的同时提高了准确率，从而使IoU有了较大的提高。在S2Looking上的表现说明，面对复杂场景，GLCDNet仍然具有较强的变化检测能力。同时，基于LEVIR-CD和S2Looking数据集统计了各个模型的参数量，用于评估模型的计算需求和存储需求，如表1和表2所示。

表1 GLCDNet对比实验结果

方法	LEVIR-CD				
	Pre/(%)	Rec/(%)	F1/(%)	IoU/(%)	Params.(M)
SNUNet	86.41	79.07	82.59	70.33	13.501
DSIFN	89.18	84.61	86.84	76.73	35.729
BIT	89.12	85.54	87.29	77.45	3.037
GLCDNet	91.81	85.13	88.34	79.12	15.107

表2 GLCDNet对比实验结果

方法	S2Looking				
	Pre/(%)	Rec/(%)	F1/(%)	IoU/(%)	Params.(M)
SNUNet	62.41	42.55	50.60	33.87	13.501
DSIFN	75.32	49.94	60.06	42.92	35.729
BIT	72.56	53.59	61.65	44.56	3.037
GLCDNet	79.39	56.27	65.86	49.47	15.107

由于整体局部特征共享机制的引入，在一定程度上增加了模型的参数量，相较于其他对比的模型，GLCDNet的参数量适中，与参数量相似的SNUNet相比，本文所提出的方法在多出1.606 M的参数量的情况下，精确率、召回率、F1分数和交并比在两个数据集上分别提高了5.4%、6.06%、5.75%、8.79%和16.98%、13.72%、15.26%、15.6%，说明提出的方法在具有中等计算消耗的同时能够达到更高的精度。

图7展示了GLCDNet和其他三种变化检测方法的检测结果示例，从LEVIR-CD和S2Looking数据集中选取了三个具有代表性的样本图进行展示。

从图7中可以看出，这些方法对不同尺度的变化物体都有很好的检测能力，但在检测变化物体边缘、小物体和复杂场景方面存在明显差异。在图7(a)中，GLCDNet对变化物体的边缘检测能力最强，在检测小物体变化方面比表现较好的DSIFN更有优势；在图7(b)中，GLCDNet能更完整地保留土堆的变化；在图7(c)和图7(d)中，GLCDNet对零星小物体的检测更准确，误检率更低；在图7(f)中，GLCDNet能更清晰地分离物体边界，同时误检率更低。结果表明，GLCDNet在检测小型物体和复杂场景方面优于其他网络。

2.4 消融实验

为证明模型中引入的整体和局部分支以及特征共享机制的有效性，在LEVIR-CD数据集上进行消融实验。设计了不同网络分支效果对比试验和不同位置特征共享效果对比实验，分别对整体和局部分支、特征共享进行了验证。

2.4.1 不同网络分支实验效果对比

为测试整体和局部分支在不同协作情况下的模型表现，设计了4种网络结构，分别为Global only、Local only、 $G \rightarrow L$ 、 $G \rightleftharpoons L$ 。其中Global only表示模型只使用了整体分支，图像经过采样处理后再输入模型；Local only表示模型只使用了局部分支，图像经裁剪处理后再输入图像。对于这两种情况，模型只进行一次训练，损失函数使用focal loss。 $G \rightarrow L$ 表示只有整体分支到局部分支进行了特征共享； $G \rightleftharpoons L$ 表示整体到局部分支和局部到整体分支都进行了特征共享，是所提出模型的完整结构；对于这两种情况，模型进行三次训练，模型分支间发生了四次特征共享，损失函数使用式(1)所示的损失函数，其中正则项的权重系数




图 7 GLCDNet 变化检测结果对比图
Fig. 7 GLCDNet comparison change images

为 0.15。

从表 3 中可以看出 Global only 的表现在精确率和交并比上要弱于 Local only, 在召回率上略有优势, 说明降采样策略会损失部分细节, 导致精确率和交并比指标略差, 裁剪策略会损失物体的整体语义信息, 导致召回率略差。在 $G \rightarrow L$ 中, 模型的局部分支可以获得整体的感受野, 但整体分支没有获得局部的细节信息, 所以 $G \rightarrow L$ 相较于单分支的模型, 在召回率上有较大提升, 在较高的准确率和召回率的前提下, F1 分数和交并比分别提升了 4.37% 和 5.04%。在 $G \rightleftharpoons L$ 中, 整体和局部分支之间都进行了特征共享, 在结合了整体分支的大感受野和局部分支的细节信息之后, 实验性能指标有较大的提升, 精确率和召回率较之前分别提升了 4.5% 和 3.89%, F1 分数和交并比指标分别提升了 4.17% 和 6.72%, 可见整体分支和局部分支

的协作可以有效提高网络的检测性能。

表 3 不同网络分支实验结果

Table 3 Experimental results on different network branches

模型结构	Pre/(%)	Rec/(%)	F1/(%)	IoU/(%)
Global only	84.26	75.61	79.70	66.04
Local only	85.24	75.02	79.80	67.36
$G \rightarrow L$	87.31	81.24	84.17	72.40
$G \rightleftharpoons L$	91.81	85.13	88.34	79.12

2.4.2 不同位置特征共享实验效果对比

根据图 2 中模型发生特征共享的位置, 分别记为第一、第二、第三和第四次特征共享。在本次对比实验中, 模型的整体分支和局部分支都进行特征共享, 对特征共享发生的位置做出了区分, 分为只进行第一次特征共享, 进行第一、第二次特征共享, 进行第一、第二、第三次特征共享,

进行完整的特征共享, 记为 Share(1)、Share(1+2)、Share(1+2+3)、Share(1+2+3+4), 使用式(1)所示的损失函数, 正则项的权重系数为 0.15。

由表 4 可见, 随着特征共享位置的增加, 变化检测的精确率和召回率逐步提升。Share(1)模型的表现相较于单分支模型, 精确率和召回率的提升微弱, 因为第一次特征共享发生在特征金字塔前, 此时特征图还未融合多尺度信息, 所以特征共享对于性能提升有限。如图 2 所示, 第二次特征共享发生在第一次卷积平滑之前, 第三次特征共享在第二次卷积平滑之前, 从 Share(1+2)、Share(1+2+3)的结果可以看到模型精度都有明显提升, 但由于经过特征金字塔融合多尺度信息的特征图需经过两次卷积平滑操作, 会稀释特征共享的效果, 所以 Share(1+2+3)的表现要比 Share(1+2)的表现更好。第四次特征共享发生在第三次卷积平滑之前, 此处的特征共享靠近输出层, 使整体特征和局部特征得到充分融合, 进一步细化检测的结果, 使模型表现达到较高的水平, 精确率、召回率、F1 分数、交并比较之前分别提升了 2.24%、2.45%、2.35%、2.29%。

表 4 不同位置特征共享实验结果

Table 4 Experimental results on feature sharing at different position

特征共享	Pre/(%)	Rec/(%)	F1/(%)	IoU/(%)
Share(1)	85.83	76.15	80.70	70.21
Share(1+2)	86.12	79.42	82.63	71.76
Share(1+2+3)	89.57	82.68	85.99	76.83
Share(1+2+3+4)	91.81	85.13	88.34	79.12

3 结束语

为了解决大尺寸遥感图像变化检测中, 由于裁剪和降采样造成的空间信息和语义信息丢失问题, 本文提出了整体-局部变化检测网络(GLCDNet)。该模型使用特征金字塔结构的特征提取主干, 提取多尺度多层次的特征信息, 并在网络中引入特征共享机制将整体和局部的特征信息进行融合处理, 使网络能够更好地表达图像多尺度的信息。通过使用 LEVIR-CD 和 S2Looking 这两个大尺寸遥感图像数据集与当前具有代表性的孪生变化检测网络进行对比实验, GLCDNet 在这两个数据集上都表现出较高的准确性和良好的泛化性能。

同时, GLCDNet 能更准确地分辨变化对象的边缘, 误检率较低。从结果来看, GLCDNet 方法在变化检测方面优于其他网络, 表明该网络能更有效地获取和利用大尺寸图像中的详细信息。

参考文献

- [1] SINGH A. Review article digital change detection techniques using remotely-sensed data[J]. International Journal of Remote Sensing, 1989, 10(6): 989-1003.
- [2] 张良培, 武辰. 多时相遥感影像变化检测的现状与展望[J]. 测绘学报, 2017, 46(10): 1447-1459.
ZHANG Liangpei, WU Chen. Advance and future development of change detection for multi-temporal remote sensing imagery[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1447-1459.
- [3] HUSSAIN M, CHEN D, CHENG A, et al. Change detection from remotely sensed images: From pixel-based to object-based approaches[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2013, 80: 91-106.
- [4] 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.
- [5] 眭海刚, 冯文卿, 李文卓, 等. 多时相遥感影像变化检测方法综述[J]. 武汉大学学报(信息科学版), 2018, 43(12): 1885-1898.
SUI Haigang, FENG Wenqing, LI Wenzhuo, et al. Review of change detection methods for multi-temporal remote sensing imagery[J]. Geomatics and Information Science of Wuhan University, 2018, 43(12): 1885-1898.
- [6] CHEN C, WANG C, LIU B, et al. Edge intelligence empowered vehicle detection and image segmentation for autonomous vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(11): 13023-13034..
- [7] JIANG H, PENG M, ZHONG Y, et al. A survey on deep learning-based change detection from high-resolution remote sensing images[J]. Remote Sensing, 2022, 14(7): 1552.
- [8] CHEN H, SHI Z. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection[J]. Remote Sensing, 2020, 12(10): 1662.

- [9] HUYNH C, TRAN A T, LUU K, et al. Progressive semantic segmentation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 16755-16764.
- [10] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 2117-2125.
- [11] ZHAN Y, FU K, YAN M, et al. Change detection based on deep siamese convolutional network for optical aerial images[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(10): 1845-1849.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.
- [13] 韩星, 韩玲, 李良志, 等. 基于深度学习的高分辨率遥感图像建筑物变化检测[J]. 激光与光电子学进展, 2022, 59(10): 55-63.
HAN Xing, HAN Ling, LI Liangzhi, et al. Building change detection in high-resolution remote-sensing images based on deep learning[J]. Laser & Optoelectronics Progress, 2022, 59(10): 55-63.
- [14] 陈璐, 管霜霜. 基于深度学习的城市高分遥感图像变化检测方法的研究[J]. 计算机应用研究, 2020, 37(S1): 320-323.
- [15] 金宇伟. 基于深度学习的高分辨率遥感影像建筑物识别及变化检测[D]. 成都: 电子科技大学, 2022.
- [16] GONG M, ZHAO J, LIU J, et al. Change detection in synthetic aperture radar images based on deep neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 27(1): 125-138.
- [17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// Proceedings of the IEEE International Conference on Computer Vision. IEEE, 2017: 2980-2988.
- [18] SHEN L, LU Y, CHEN H, et al. S2Looking: A satellite side-looking dataset for building change detection[J]. Remote Sensing, 2021, 13(24): 5094.
- [19] FANG S, LI K, SHAO J, et al. SNUNet-CD: A densely connected Siamese network for change detection of VHR images[J]. IEEE Geoscience and Remote Sensing Letters, 2021, 19: 1-5.
- [20] ZHANG C, YUE P, TAPETE D, et al. A deeply supervised image fusion network for change detection in high resolution bi-temporal remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 166: 183-200.
- [21] CHEN H, QI Z, SHI Z. Remote sensing image change detection with transformers[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60: 1-14.

[作者简介]

吕 宁 1979年生, 讲师, 硕士生导师。

刘亦高 2000年生, 硕士研究生。

张增辉 2000年生, 硕士研究生。

(本文编辑: 傅 杰)

(英文编辑: 赵尹默)