

# 用于高分辨率遥感影像度量变化检测的 多路径非对称融合网络

闫利, 李希

(武汉大学测绘学院, 湖北武汉 430079)

**摘要:** 现有的基于深度学习的度量变化检测方法侧重于高级变化语义特征的提取, 难以捕获细粒度地物的变化, 检测的变化边界模糊. 一些方法引入了包含高分辨率和细节特征的低级视觉特征, 但这些特征更容易受到内部细节等伪变化的干扰, 缺少可靠的远程依赖关系. 针对上述问题, 提出了一种基于深度学习的端到端的度量变化检测网络, 称为用于高分辨率遥感影像度量变化检测的多路径非对称融合网络 (Multi-path Asymmetric Fusion network, MAFNet), 可以检测到更清晰的边界和更完整的细粒度地物. MAFNet 提出了一种多路径非对称融合网络用于捕获长短路径依赖关系, 用细粒度的低级视觉特征细化粗略的高级语义特征. MAFNet 提出了一种基于深度监督的度量模块, 获取更具判别力的特征, 端对端的测量变化. 实验表明, 与其他6种基准方法相比, MAFNet 网络在 SYSU 数据集和 CDD 数据集上都实现了最高的精度, F1 分别为 80.56%, 95.02%.

**关键词:** 遥感影像; 变化检测; 多路径非对称融合网络; 度量学习; 深度监督; 深度学习

**基金项目:** 国家重点研发计划 (No.2020YFD1100203); 湖北省科技重大专项 (No.2021AAA010)

**中图分类号:** P237

**文献标识码:** A

**文章编号:** 0372-2112(2023)07-1781-10

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20221071

## MAFNet: A Multi-Path Asymmetric Fusion Network for Metric-Based Change Detection in High-Resolution Remote Sensing Images

YAN Li, LI Xi

(School of Geodesy and Geomatics, Wuhan University, Wuhan, Hubei 430079, China)

**Abstract:** Existing deep learning-based metric change detection methods focus on the extraction of high-level change semantic features, which is difficult to capture changes in fine-grained targets, and the detected change boundaries are blurred. Some methods introduce low-level visual features containing high-resolution and detailed features, but these features are more susceptible to interference from pseudo-change such as internal details and lack reliable long-range dependencies. In response to the above problems, an end-to-end metric-based change detection network based on deep learning is proposed, named multi-path asymmetric fusion network (MAFNet) for metric-based change detection in high resolution remote sensing images, which can detect sharper boundaries and more complete fine-grained targets. MAFNet proposes a multi-path asymmetric fusion network to capture long and short range dependencies, and refine coarse high-level semantic features with fine-grained low-level visual features. MAFNet proposes a metric module based on deep supervision to obtain more discriminative features and end-to-end measure changes. Experiments show that compared with other six benchmark methods, MAFNet achieves the highest accuracy on both the SYSU dataset and the CDD dataset, with F1 scores at 80.56% and 95.02%, respectively.

**Key words:** remote sensing images; change detection; multi-path asymmetric fusion network; metric learning; deep supervision; deep learning

**Foundation Item(s):** National Key Research and Development Program of China (No.2020YFD1100203); Science and Technology Major Project of Hubei Province (No.2021AAA010)

## 1 引言

变化检测通过分析同一区域的双时相遥感图像来识别地表变化<sup>[1]</sup>。由于自然事件和人类活动<sup>[2]</sup>等众多因素,地球表面不断发生着变化,因此常态化检测地表变化对于管理资源十分必要。一种有效的方法是利用遥感技术进行变化检测<sup>[3,4]</sup>,已广泛应用于灾害评估<sup>[5]</sup>、土地覆盖制图<sup>[6]</sup>和城市发展监测<sup>[7]</sup>等方面。随着高分辨率光学传感器的发展,高分辨率遥感的可用性越来越高,且变化检测数据集也得到了开发,这些都拓宽了变化检测的潜在应用范围。

传统的遥感变化检测方法主要分为三类:(1)基于图像算术的方法;(2)基于图像变换的方法;(3)基于对象分类方法<sup>[8]</sup>。在基于图像算术的方法中,直接对两幅图像的对应像素进行算术运算以创建差分图。基于图像变换的方法将图像光谱组合变换到特定的特征空间以区分变化的像素。基于对象分类的变化检测方法利用双时相图像的结构和几何特征进行相似性分析。重要的是,上述变化检测方法都是人工设计的特征,通常不仅复杂而且鲁棒性差。

近年来,深度学习在目标检测<sup>[9]</sup>、变化检测<sup>[10,11]</sup>等遥感任务中取得了突出的表现。作为使用最广泛的深度学习框架之一,卷积神经网络(Convolutional Neural Network, CNN)在遥感变化检测任务中取得了突出的表现。一般来说,基于 CNN 的变化检测方法可分为三类:(1)基于特征的方法;(2)基于补丁的方法;(3)基于图像的方法<sup>[12]</sup>。基于特征的方法使用网络提取鲁棒的深层特征,然后用这些特征生成差异图实现变化检测<sup>[13]</sup>。基于补丁的方法将图像补丁输入网络,以确定中心像素是否发生了变化<sup>[14]</sup>。但上述两种方法采用分段处理,仍然存在明显的误差传播问题<sup>[12]</sup>。全卷积网络(Fully Convolutional Network, FCN)的出现实现了像素级密集预测<sup>[15]</sup>,具有 FCN 架构的基于图像的方法通过端到端的训练从图像到图像生成变化图<sup>[16]</sup>,最大限度地减少误差传播。基于图像的深度学习变化检测方法采用 FCN 架构,主要分为基于分类的变化检测方法和基于度量的变化检测方法。

度量变化检测<sup>[17-21]</sup>,属于深度学习图像变化检测方法的一种。度量变化检测通过比较双时相数据的参数化距离来确定变化<sup>[19]</sup>,通过损失函数缩小不变对的距离,拉大变化对的距离,端对端的测量特征间的距离来检测变化<sup>[22]</sup>。文献[18]提出了一种基于深度度量学习的遥感变化检测方法,使用双注意力模块来提高特征识别能力。文献[19]提出了一种基于孪生网络的时空注意力神经网络,充分利用时空关系来生成鲁棒特征。文献[20]提出了一种深度监督注意力度量网络,集成了卷积注意力模块以在空间方面和通道方面提供更

多的判别特征。文献[21]提出了一种局部相似性孪生网络,提出了基于变化注意力图的内容损失函数。

相对而言,度量变化检测方法的研究较少,而且现有的度量变化检测方法仍然存在一些问题。大多数方法侧重于获取 FCN 的高级变化语义特征,但它们的分辨率较粗糙,难以捕获细粒度地物的变化,检测的变化边界模糊。一些方法引入了 FCN 中包含高分辨率和细节特征的低级视觉特征,但这些特征更容易受到内部细节等伪变化的干扰,缺少可靠的远程依赖关系。为了解决上述问题,提出了一种基于深度学习的端到端的度量变化检测网络,称为用于高分辨率遥感影像度量变化检测的多路径非对称融合网络(MAFNet)。本文的主要贡献如下:(1)提出了一种基于深度学习的端到端的度量变化检测网络,称为 MAFNet,检测到的边界更清晰,更能准确识别细粒度地物的变化;(2)提出了一种多路径非对称融合网络,可以捕获长短路径的依赖关系,用细粒度的低级视觉特征细化粗略的高级语义特征,保持高分辨率、细粒度的表示;(3)提出了一个基于深度监督的度量模块,获取更具判别力的特征,端对端的测量特征间的距离检测变化;(4)在 SYSU<sup>[20]</sup>和 CDD<sup>[23]</sup>数据集上的实验结果表明,与其他基准方法相比,所提出的方法在 F1 上分别提高了 3.40% 和 2.87%。

## 2 本文方法

### 2.1 MAFNet

MAFNet 是一个端到端的基于孪生网络的全卷积网络,整体架构见图 1,由三部分组成:特征提取器、多路径非对称融合网络、基于深度监督的度量模块。在特征提取器模块,选择了 ResNet-50<sup>[24]</sup>作为骨干网络,提取多尺度特征。提出了一种多路径非对称融合网络,用于捕获远程依赖关系,用细粒度低级特征细化粗略的高级语义特征,有效地利用多级特征来生成高分辨率预测。提出了一种基于深度监督的度量模块,通过比较双时态数据的参数化距离来检测变化,同时引入了深度监督模块,增强特征提取器的学习能力。

如图 1 和图 2 所示,网络的详细流程如下:

(1)给定 T1 和 T2 双时相影像,将其输入到孪生特征提取器中,分别生成 4 个多尺度特征 Res-1~ Res-4;

(2)将每支网络的多尺度特征 Res-1~Res-4 输入到孪生多路径非对称融合网络中,用细粒度低级特征细化粗略的高级语义特征;

(3)将融合的最后—个特征和一个中间特征输出到基于深度监督的度量模块,通过比较双时相特征间的距离来检测变化。

### 2.2 特征提取器

如图 1 和图 2 所示,使用孪生 ResNet-50 作为骨干

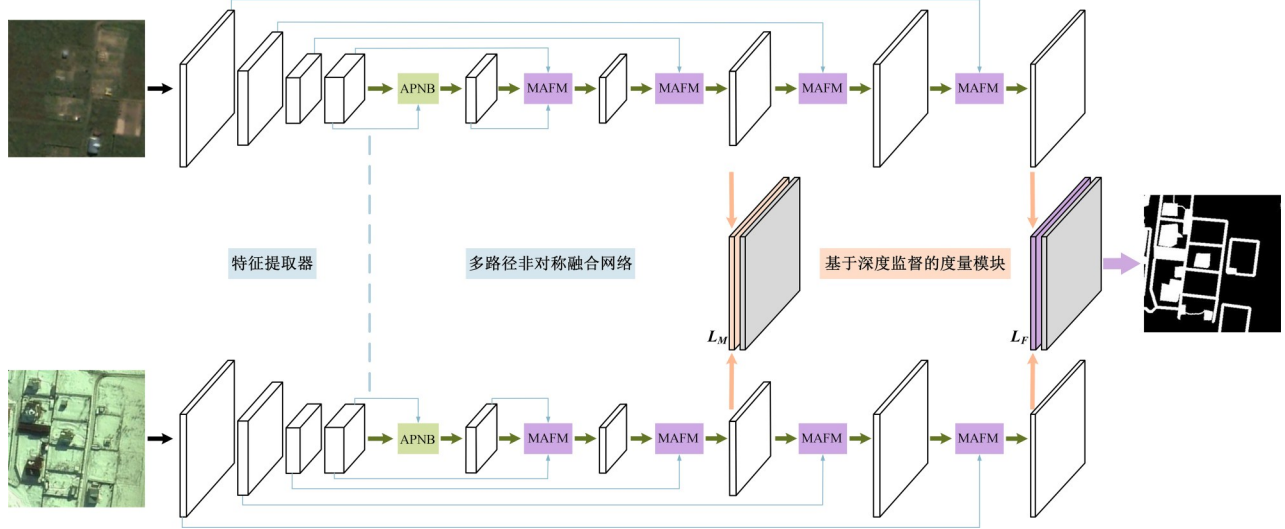


图1 MAFNet网络总体架构

网络来提取特征,省略了原始 ResNet50 的全局池化层和全连接层. 其余部分可以分为 4 个阶段 Res-1~Res-4, 参考 DeepLab-V3<sup>[25]</sup> 的结构, 在最后一个模块 Res-4 中使用了空洞卷积、步长设置为 1, 防止特征图分辨率过低. 双时相图像 T1 和 T2 分别输入到孪生网络的两个分支中, 两个分支之间共享参数.

仅用少量计算捕获长距离依赖关系, 同时保持原始非局部模块的出色性能.




图2 单只网络架构图

### 2.3 多路径非对称融合网络

提出了一种轻量级的多路径非对称融合网络, 能够有效地结合高级语义特征和低级视觉特征, 生成高分辨率变化图. 多路径非对称融合网络包含 1 个捕获远程依赖关系的非对称金字塔非局部块 (Asymmetric Pyramid Nonlocal Block, APNB) 和 4 个多路径非对称融合模块 (Multi-path Asymmetric Fusion Module, MAFM), 见图 1 和图 2. 有效地利用了多尺度特征来生成高分辨率预测, 能检测到更清晰的边界和更完整的细粒度地物. 可以在充分考虑远程路径依赖的情况下融合多层次特征, 产生具有远程交互的融合特征.

#### 2.3.1 非对称金字塔非局部块

在 Res-4 阶段后面, 使用了一个非对称金字塔非局部块 (APNB)<sup>[26]</sup>, 用于捕获远程依赖关系, 见图 1、图 2 和图 3. 独特地结合了非局部块的金字塔采样策略, 以

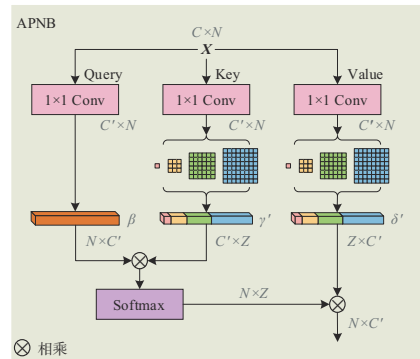


图3 非对称金字塔非局部块

输入特征  $X \in \mathbf{R}^{C \times H \times W}$ ,  $C, H$  和  $W$  分别表示通道数、高度和宽度. 首先使用 3 个  $1 \times 1$  卷积  $W_\beta, W_\gamma$  和  $W_\delta$  将  $X$  转换为 3 个特征  $\beta \in \mathbf{R}^{C' \times H \times W}$ ,  $\gamma \in \mathbf{R}^{C' \times H \times W}$  和  $\delta \in \mathbf{R}^{C' \times H \times W}$ ,  $C'$  是新的通道数, 计算公式如下:

$$\beta = W_\beta(X), \gamma = W_\gamma(X), \delta = W_\delta(X) \quad (1)$$

然后使用空间金字塔平均池化模块 (见图 4) 将  $\gamma$  和  $\delta$  采样为  $\gamma' \in \mathbf{R}^{C' \times H' \times W'}$  和  $\delta' \in \mathbf{R}^{C' \times H' \times W'}$ .  $H'$  和  $W'$  是新的高度和宽度, 然后将  $\beta$  展平大小为  $C' \times N$ , 将  $\gamma'$  和  $\delta'$  展平大小为  $C' \times Z$ , 其中,  $N = H \times W, Z = H' \times W'$ , 且  $Z \ll N$ .

然后利用式 (2) 得到相似性矩阵  $S \in \mathbf{R}^{N \times Z}$ , 使用 softmax 对  $S$  进行归一化, 得到统一的相似度矩阵  $\hat{S}$ :

$$S = \beta^T \times \gamma' \quad (2)$$

$$\hat{S} = f(S) \quad (3)$$

对于  $\delta'$  中的每个位置, 注意力层的输出为  $A \in \mathbf{R}^{N \times C'}$ :

$$A = \widehat{S} \times \delta'^T \quad (4)$$

网络最终输出 Res-5 特征如下,  $W_0$  是一个  $1 \times 1$  卷积, cat 是指在通道上串联起来,  $Y \in \mathbf{R}^{C \times N}$ :

$$Y = \text{cat}(W_0(A^T), X) \quad (5)$$




图4 空间金字塔平均池化模块

### 2.3.2 多路径非对称融合模块

提出了一种轻量级的多路径非对称融合模块 (MAFM), 使用了 4 个 MAFM 以递归的方式用细粒度的低级特征细化粗略的高级语义特征, 有效地利用多尺度特征来生成高分辨率预测, 见图 1 和图 2. MAFM 可以作为一个轻量模块插入到基于深度学习的变化检测结构中. MAFM 主要包括非对称融合非局部块 (Asymmetric Fusion Non-local Block, AFNB) 和链式残差池 (Chained Residual Pooling, CRP) 模块, 见图 5(a).

#### (1) 非对称融合非局部块 (AFNB)

融合不同级别的特征有助于提高变化检测的精度. 常见的融合操作, 例如加法、连接, 是以像素为单位和局部的方式进行的. 通过 AFNB 利用远程依赖关系来融合多级特征<sup>[26]</sup>, 见图 5(b). AFNB 计算低级特征图和高级特征图的每个像素之间的相关性, 从而生成具有长距离交互作用的融合特征.

对于高级语义特征  $X_h \in \mathbf{R}^{C_h \times N_h}$ , 低级特征  $X_l \in \mathbf{R}^{C_l \times N_l}$ ,  $N_h = H_h \times W_h$  和  $N_l = H_l \times W_l$  分别是  $X_h$  和  $X_l$  的高度和宽度的乘积, 即空间位置数.  $C_h$  和  $C_l$  分别是  $X_h$  和  $X_l$  的通道数. 使用  $1 \times 1$  卷积  $W_h$  和  $W_l$  将  $X_h$  和  $X_l$  转换为  $\phi_h \in \mathbf{R}^{\widehat{C} \times N_h}$  和  $\phi_l \in \mathbf{R}^{\widehat{C} \times N_l}$ .

$$\phi_h = W_h(X_h), \phi_l = W_l(X_l), \phi_{lv} = W_{lv}(X_l) \quad (6)$$

同样使用空间金字塔平均池化模块 (见图 4) 将  $\phi_l$  和  $\phi_{lv}$  采样为  $\phi'_l \in \mathbf{R}^{\widehat{C}' \times N'_l}$  和  $\phi'_{lv} \in \mathbf{R}^{\widehat{C}' \times N'_l}$ .  $N'_l = H'_l \times W'_l$ ,  $H'_l$  和  $W'_l$  是新的高度和宽度, 其中,  $N'_l \ll N_l$ .

然后, 得到相似性矩阵  $M \in \mathbf{R}^{N_h \times N'_l}$

$$M = \phi_h^T \times \phi'_{lv} \quad (7)$$

使用 softmax 对  $M$  进行归一化, 得到统一的相似矩阵  $\widehat{M} \in \mathbf{R}^{N_h \times N'_l}$ :

$$\widehat{M} = f(M) \quad (8)$$

得到注意力层的输出为  $E \in \mathbf{R}^{N_h \times \widehat{C}}$

$$E = \widehat{M} \times \phi'_{lv}^T \quad (9)$$

最后得到输出  $Y_F \in \mathbf{R}^{C_h \times N_h}$ ,  $W_1$  是一个  $1 \times 1$  卷积:

$$Y_F = \text{cat}(W_1(E^T), X_h) \quad (10)$$

#### (2) 链式残差池 (CRP)

CRP<sup>[27,28]</sup> 捕获丰富的背景上下文信息, 见图 5(c). CRP 包含四个池化块, 每个池化块由一个最大池化层和一个卷积层组成. 当前池化块重用上一个池化的结果, 可以在不使用大池化窗口的情况下访问大区域的特征. 所有池化块的输出特征图通过残差连接的求和与输入特征图融合在一起.




图5 多路径非对称融合模块 (a) 多路径非对称融合模块; (b) 非对称融合非局部块; (c) 链式残差池

### 2.4 基于深度监督的度量模块

在这里, 提出了一种基于深度监督的度量模块. 已有的方法证明基于深度度量学习的变化检测方法<sup>[17-21]</sup> 取得了领先的性能. 度量变化检测通过比较双时相影像的参数化距离来确定变化, 通过损失函数缩小不变的距离, 拉大变化对的距离, 端对端的测量特征间的距离来检测变化.

度量模块见图 1, 具体来说, 将最后一个 MAFM 融合得到的特征图调整为输入图像的一半后, 度量模块选用欧氏距离直接测量双时相特征图中每个像素对之间的距离, 并生成距离图  $d$ . 变化图  $L_F$  是通过简单阈值分割距离图  $d$  得到.

#### (1) 距离度量

$$L_F = \begin{cases} 1, & d > \mu \\ 0, & \text{else} \end{cases} \quad (11)$$

$\mu$  是一个固定的阈值, 用于分隔变与不变区域. 在

训练阶段,利用批量平衡对比损失(BCL)比较变化图与真值标签获得对比损失,使用BCL扩大变化特征间的距离,缩小未变化特征间的距离.而在预测阶段,将在距离图 $d$ 上应用简单的阈值分割以获得变化图 $L_F$ .

### (2) 损失函数

遥感变化检测中存在类别不均衡问题,既变化区域和不变区域比例不均衡.为了减少这一影响,引入BCL,定义如下:

$$BCL(y, d) = \sum_{b, i, j} \frac{1}{2} \left[ \frac{1}{n_{b, un}} (1 - y_{b, i, j}) d_{b, i, j}^2 + \frac{1}{n_{b, ch}} y_{b, i, j} \max(d_{b, i, j} - m, 0)^2 \right] \quad (12)$$

真值标签 $y_{b, i, j} \in \{0, 1\}$ ,  $d_{b, i, j}$ 是双时相特征间的距离值,大于参数 $m$ 的值不参与损失运算,设置为2.  $n_{b, un}$ 是不变像素对数目,  $n_{b, ch}$ 是变化像素对数目. 下标 $b, i, j$ 分别表示批次、高度和宽度的索引.

### (3) 深度监督

已有工作证明深度监督可以提高隐藏层的有效性<sup>[20, 29, 30]</sup>,因此,引入了深度监督模块,来帮助隐藏层捕获更多有用的特征.同时监督隐藏层和输出层,目的是帮助隐藏层学习并获得更健壮和判别性的特征.考虑到时间性能,仅引入1个深度监督,见图1和图2.

为了效率起见,使用1个中间层特征通过度量模块生成最终的变化图 $L_M$ 对损失函数进行深度监督,最后一个MAFM融合的特征通过度量模块生成最终的变化图 $L_F$ ,2个特征都使用同样的损失函数,最终得到的损失表示如下:

$$LOSS = l_{bw1} + l_{bw2} \quad (13)$$

## 3 实验结果及分析

### 3.1 实验数据集

为了评估提出的方法,在两个变化检测数据集上设计了一系列对比实验.第一个SYSU数据集<sup>[20]</sup>包含20 000对0.5 m/pixel的大小为256×256的航拍影像,这些影像是在2007年至2014年间在香港拍摄的.按照文献[20]中的6:2:2比例将图像对分为训练集、验证集和测试集.第二个CDD数据集<sup>[23]</sup>是从Google Earth获得的真实季节变化遥感影像,包含16 000对大小为256×256的图像集:10 000个训练集,3 000个验证集和3 000个测试集.图像的空间分辨率为0.03~1 m/pixel.

### 3.2 对比方法

为了评估本文提出的方法有效性,选择了6种先进的基于深度学习的变化检测方法作对比分析,其中STANet和DASNet是基于度量的变化检测方法.6种方法的特性概括如下:

(1)FC-EF FC-EF<sup>[31]</sup>直接基于UNet模型改进而来,该网络的输入是双时相图像的连接;

(2)FC-Sima-conc FC-Siam-conc<sup>[31]</sup>是FC-EF模型的连体扩展,孪生架构的在编码步骤中分别通过具有共享结构和参数的相同分支,然后在解码步骤中连接两个分支;

(3)FC-Sima-diff FC-Siam-diff<sup>[31]</sup>与FC-Sima-conc的编码步骤相同,区别在于解码步骤中不是连接两个分支,而是连接它们差异的绝对值;

(4)STANet STANet<sup>[19]</sup>是一种基于孪生网络的时空注意力神经网络,由孪生FCN特征提取器、注意模块和度量模块组成,属于基于度量的变化检测方法;

(5)DASNet DASNet<sup>[18]</sup>提出了一种基于深度度量学习的遥感变化检测方法,该方法使用双注意力模块来提高特征识别能力;

(6)IFN IFN<sup>[29]</sup>是一种深度监督图像融合网络,由双流架构的深度特征提取网络和差异鉴别网络组成,同时采用了空间注意力模块和通道注意力模块.

### 3.3 实施细节

#### (1) 参数设置

本文中的所有实验都使用Pytorch 1.7.1框架实现,训练的硬件是单个GeForce GTX 1080 Ti.在新方法的训练过程中,batch size设为16,Adam作为优化器,学习率设为 $1e^{-4}$ .每个卷积层的权重由KaiMing初始化,训练100个epoch以使模型收敛.为了增加训练数据的多样性,应用随机旋转( $-15^\circ \sim 15^\circ$ )用于数据增强.对比方法中使用的参数尽量保持与原文相同.由于有的对比方法仅公布了部分代码,因此复现精度与作者的有些许差异.

#### (2) 评估指标

将任务视为网络最终输出的二元分割,即变化或不变.为了衡量所提出的网络的性能,使用了精确率(Precision)、召回率(Recall)和F1作为评估指标.更具体地说,精确率也叫查准率,反映了误报率.召回率也叫查全率,反映了模型的漏报率.由于Recall和Precision相互制约,而F1将这两个指标都考虑在内,可作为整体性能的衡量指标,较大的F1分数表示更好的模型.这些指标定义如下:

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (16)$$

其中,TP表示预测正确的正样本数,FP表示预测错误的正样本数,TN表示预测正确的负样本数,FN表示预测错误的负样本数.

### 3.4 在 SYSU 数据集上的对比分析

为了评价提出方法的有效性,在两个数据集上将本文提出方法的结果与6种基准方法对比.首先是SYSU数据集,各种变化检测方法结果的定量比较见表1,分别从Precision, Recall, F1三个方面比较.由表1可知,本文方法优于SYSU数据集上的所有基准方法,分别实现了81.53%和80.56%的最高Recall和F1, F1上提高了3.40%. STANet和DASNet都是基于度量的方法, F1排名分别为第二、第四,同时也证实了基于度量的变化检测方法的有效性.尽管FC-Sima-diff达到了88.90%的最高Precision,但F1最低,这可能归因于SYSU数据集有相对复杂的场景.

SYSU数据集上不同方法的变化检测结果展示在图6,第1、2行展示了提出的模型在识别郊区的变化方面的性能;第3、4行展示了提出的模型在识别海上建设

表1 在SYSU数据集上的MAFNet和六种基准方法的定量结果

方法	Precision/%	Recall/%	F1/%
FC-Sima-diff	88.90	52.20	65.78
FC-Sima-conc	70.78	72.08	71.43
FC-EF	85.10	69.02	76.22
DASNet	79.09	74.22	76.58
IFN	75.94	77.81	76.86
STANet	75.18	79.24	77.16
MAFNet	79.62	81.53	80.56

的变化方面的性能;第5、6行展示了提出的模型检测城市变化方面的性能.这些证实MAFNet在郊区、海上建设、城市三种情景下都表现良好.无论是第1、5行的大范围地物变化,还是第3、4行的细小地物变化,与其他基准方法相比,MAFNet检测到的边界更清晰,更能准确识别细粒度地物的变化.

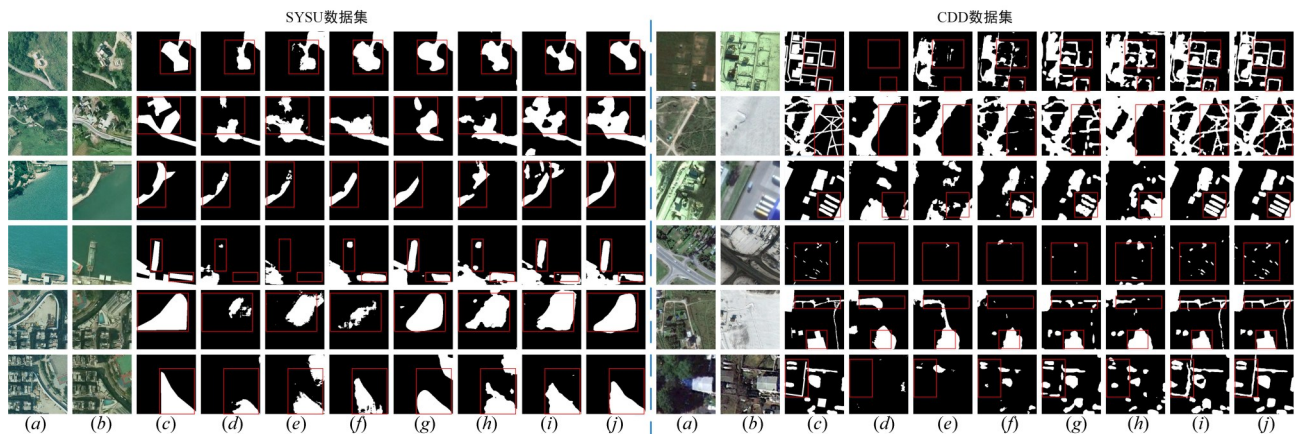


图6 各种变化检测方法在SYSU和CDD数据集上的可视化对比(a)图像T1;(b)图像T2;(c)真值标签;(d)FC-Sima-diff;(e)FC-Sima-conc;(f)FC-EF;(g)DASNet;(h)IFN;(i)STANet;(j)MAFNet

### 3.5 在 CDD 数据集上的对比分析

表2展示了各种变化检测方法结果在CDD数据集上的定量比较,提出的方法在Precision, Recall, F1分数上均领先于所有基准方法,分别达到了93.36%, 96.73%, 95.02%, F1值提高了2.87%.这意味着MAFNet对伪变化的鲁棒性更高,因为该方法可以有效地利用多级特征来生成高分辨率预测. DASNet和STANet都是基于度量的变化检测方法, F1分别排名第二和第三,分别为92.15%, 91.58%,进一步证实了基于度量的变化检测方法的有效性.

在CDD数据集上选取了三个典型场景进行可视化,图6展示了道路、车辆和建筑物场景的变化检测结果.第1、2行展示了提出的模型在识别道路变化方面的性能;第3、4行展示了提出的模型在识别车辆变化方面的性能;第5、6行展示了提出的模型在识别建筑和道路变化方面的性能.提出的网络检测到的变化边界更

表2 在CDD数据集上的MAFNet和六种基准方法的定量结果

方法	Precision/%	Recall/%	F1/%
FC-Sima-diff	64.65	42.07	50.97
FC-Sima-conc	81.17	58.69	68.12
FC-EF	91.85	80.68	85.90
DASNet	92.40	91.90	92.15
IFN	81.23	77.17	79.15
STANet	88.96	94.37	91.58
MAFNet	93.36	96.73	95.02

清晰,对于细粒度地物检测性能依然很好.对于复杂道路场景,提出的网络在第1、2行检测到的道路边界更为清晰.特别是第4行微小的车辆变化,提出的网络可以检测到几乎所有的车辆变化.这些都证实了提出的网络在识别复杂场景中的微小变化方面的性能,且能识别更为清晰的边界.

### 3.6 消融实验

#### (1) 核心模块消融实验

对多路径非对称融合网络的核心模块在 CDD 数据集上设计了消融实验,以验证每个模块的有效性,包括非对称金字塔非局部块和多路径非对称融合模块. 在下面的实验中,“Base”表示基础模型. “APNB”表示引入了非对称金字塔非局部块,“MAFM”表示集成了多路径非对称融合模块,MAFNet 表示同时集成了非对称金字塔非局部块和多路径非对称融合模块,即多路径非对称融合网络.


表 3 显示了以上方法在 CDD 数据集上的消融实验,表 3 的更直观形式见图 7(a). 实验表明,非对称金字塔非局部块和多路径非对称融合模块对变化检测算法是有效且鲁棒的. 这主要是因为非对称金字塔非局部块可以捕获远程依赖关系,准确定位变化区域. 多路径非对称融合模块可以用细粒度低级特征细化粗略高级语义特征,有效地利用多级特征来

生成高分辨率预测,获取细粒度的细节信息. 同时它们组合具有增益效果.

图 8 显示了更直观的视觉效果. Base 模型能检测到大部分变化,但产生的结果边界不明显,对细粒度地物的变化不敏感. APNB 模型在 Base 模型上将 F1 提高了 0.88%,APNB 的引入增加了查准率,减少了漏报率. 与 Base 模型相比,MAFM 的 F1 提高了 2.49%,减少变化图中的漏报和误报,产生清晰的边界和增强细粒度地物的检测能力. APNB 和 MAFM 的同时加入,在 Base 模型上将 F1 提高了 4.09%,具有增益效果,可以提取更精确的变化图.

表 3 MAFNet 在 CDD 数据集上的消融实验

方法	Precision/%	Recall/%	F1/%
Base	90.26	91.62	90.93
APNB	91.61	92.00	91.81
MAFM	91.65	95.25	93.42
MAFNet	93.36	96.73	95.02



#### (2) 损失函数权重消融实验

对损失函数权重进行了消融实验,参见表 4,更直观形式见图 7(b). 可以看出,等权重训练的模型在 CDD 数据集上取得了最好的性能. 还可以得出,对于不同损失加权设置,虽然性能不大相同,但整体性能差异相对较小. 本次实验表明,损失权重的设置应符合网络的设计,由实验验证得出,以充分发挥模型的性能.

#### (3) MAFM 模块个数消融实验

所提出的多路径非对称融合网络使用了 4 个 MAFM 来融合 5 种不同尺度的特征信息. 为了验证 MAFM 融合多尺度特征的有效性,对 MAFM 做了消融研究. 消融实验在 CDD 数据集上执行,结果见表 5,更直观形式见图 7(c). 可以看出,加入 1~4 个 MAFM 后的 F1 分别提升了 1.03%,0.31%,0.67%,1.20%. 因此,通过增加 MAFM 个数,变化检测结果越来越准确,表明本文采用 4 个 MAFM 的有效性和合理性.

### 3.7 网络复杂性分析

从参数个数(Params.)、训练一个 epoch 所需的时




图 8 MAFNet 在 CDD 数据集上的消融实验示例 (a) 图像 T1; (b) 图像 T2; (c) 真值标签; (d) Base; (e) APNB; (f) MAFM; (g) MAFNet

表 4 不同损失函数权重消融实验

不同损失函数	$\lambda_1$	$\lambda_2$	Precision/%	Recall/%	F1/%
Loss_1	0	1	92.55	96.24	94.36
Loss_2	0.2	0.8	92.62	96.64	94.59
Loss_3	0.4	0.6	93.41	96.37	94.87
Loss_4	1	1	93.36	96.73	95.02

表5 MAFM 模块个数消融实验


MAFM 模块个数	Precision/%	Recall/%	F1/%
MAFM_0	91.61	92.00	91.81
MAFM_1	90.84	94.93	92.84
MAFM_2	90.97	95.43	93.15
MAFM_3	91.98	95.74	93.82
MAFM_4	93.36	96.73	95.02

间、浮点运算(FLOPs)和F1四个方面分析了MAFNet和六种基准方法的性能。四个指标的具体数值见表6,图9更清晰地呈现不同网络的综合性能。使用的图像大小是 $1 \times 3 \times 256 \times 256$ ,但计算训练时间的batch size设置为8。可以看出,在7种方法中,所提出的MAFNet获得了最高的F1,和相对较低的Params、FLOPs和训练时间。具有简单架构的网络(FC-EF、FC-Sima-conc和FC-Sima-diff)具有较低的计算成本和模型复杂度,但这些


网络表现出较差的精度,这可能是因为它们特征提取能力较弱。MAFNet的Params. 小于DASNet和IFN, FLOPs和训练时间远小于DASNet和IFN。虽然MAFNet在Params、FLOPs和训练时间上落后于STANet,但F1比STANet高3.44%。提出的网络通过牺牲可接受的参数量来实现最大的改进,证明了MAFNet在复杂性和准确性之间取得了更好的平衡。

表6 网络性能对比


方法	Params./M	FLOPs/G	时间/s	F1/%
FC-Sima-diff	1.35	4.73	346	50.97
FC-Sima-conc	1.55	5.33	348	68.12
FC-EF	1.10	2.02	338	85.90
DASNet	48.22	100.72	2330	92.15
IFN	50.44	82.26	1245	79.15
STANet	16.89	6.43	171	91.58
MAFNet	43.89	17.49	619	95.02



(a) Params



(b) FLOPs



(c) 训练一个epoch所需的时间

图9 网络性能对比

## 4 结论

本文提出了一种基于深度学习的端到端的度量变化检测网络,称为用于高分辨率遥感影像度量变化检测的多路径非对称融合网络(MAFNet)。MAFNet包括3个模块:特征提取器、多路径非对称融合网络和基于深度监督的度量模块。MAFNet提出了一种多路径非对称融合网络,包括1个非对称金字塔非局部块和4个多路径非对称融合模块,来捕获远程依赖关系和用细粒度低级特征细化粗略高级语义特征,产生具有远程交互的融合特征;MAFNet提出了一种基于深度监督的度量模块,获取更具判别力的特征,端对端的测量特征间的距离来检测变化。与6种深度学习变化检测方法相比,提出的方法在SYSU和CDD数据集上表现良好,F1值分别提高了3.40%和2.87%,检测到的边界更清晰,更能准确识别细粒度地物的变化。在CDD数据集上设计了核心模块消融实验、损失函数权重消融实验和多路径非对称融合模块个数消融实验共3种消融实验来证明架构的有效性。对网络复杂性进行了对比分析,实验表明提出的方法在复杂性和准确性间取得了更好的平

衡。由于数据集的限制,今后的工作将尝试研究对抗学习变化检测方法。

## 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] PEDUZZI P. The disaster risk, global change, and sustainability nexus[J]. Sustainability, 2019, 11(4): 957.
- [3] 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 L P, WU C. Advance and future development of change detection for multi-temporal remote sensing imagery[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1447-1459. (in Chinese)
- [4] 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 H G, FENG W Q, LI W Z, et al. Review of change de-

- tection methods for multi-temporal remote sensing imagery [J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(12): 1885-1898. (in Chinese)
- [5] BRUNNER D, LEMOINE G, BRUZZONE L. Earthquake damage assessment of buildings using VHR optical and SAR imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(5): 2403-2420.
- [6] 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.
- [7] DEMIR B, BOVOLO F, BRUZZONE L. Updating land-cover maps by classification of image time series: A novel change-detection-driven transfer learning approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(1): 300-312.
- [8] WANG D C, CHEN X N, JIANG M Y, et al. ADS-Net: An attention-based deeply supervised network for remote sensing image change detection[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 101: 102348.
- [9] 肖进胜, 张舒豪, 陈云华, 等. 双向特征融合与特征选择的遥感影像目标检测[J]. *电子学报*, 2022, 50(2): 267-272. XIAO J S, ZHANG S H, CHEN Y H, et al. Remote sensing image object detection based on bidirectional feature fusion and feature selection[J]. *Acta Electronica Sinica*, 2022, 50(2): 267-272. (in Chinese)
- [10] 刘国强, 房胜, 李哲. 用于遥感图像变化检测的全尺度特征聚合网络[J]. *北京航空航天大学学报*, 2022, 48(8): 1464-1470. LIU G Q, FANG S, LI Z. A full-scale feature aggregation network for remote sensing image change detection[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2022, 48(8): 1464-1470. (in Chinese)
- [11] 王鑫, 张香梁, 吕国芳. 基于融合边缘变化信息全卷积神经网络的遥感图像变化检测[J]. *电子与信息学报*, 2022, 44(5): 1694-1703. WANG X, ZHANG X L, LÜ G F. Remote sensing image change detection based on fully convolutional neural networks with edge change information[J]. *Journal of Electronics & Information Technology*, 2022, 44(5): 1694-1703. (in Chinese)
- [12] PENG D F, ZHANG Y J, GUAN H Y. End-to-end change detection for high resolution satellite images using improved UNet++[J]. *Remote Sensing*, 2019, 11(11): 1382.
- [13] ZHAN Y, FU K, YAN M L, 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.
- [14] HEDJAM R, ABDESSELAM A, MELGANI F. Change detection in unlabeled optical remote sensing data using Siamese CNN[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 4178-4187.
- [15] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2015: 3431-3440.
- [16] ZHENG Z, WAN Y, ZHANG Y J, et al. CLNet: Cross-layer convolutional neural network for change detection in optical remote sensing imagery[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2021, 175: 247-267.
- [17] ZHANG M Y, XU G L, CHEN K M, et al. Triplet-based semantic relation learning for aerial remote sensing image change detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 266-270.
- [18] 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.
- [19] CHEN H, SHI Z W. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection[J]. *Remote Sensing*, 2020, 12(10): 1662.
- [20] SHI Q, LIU M X, LI S C, et al. A deeply supervised attention metric-based network and an open aerial image dataset for remote sensing change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 1-16.
- [21] LEE H, LEE K, KIM J H, et al. Local similarity Siamese network for urban land change detection on remote sensing images[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 4139-4149.
- [22] GUO E Q, FU X S, ZHU J W, et al. Learning to measure change: Fully convolutional siamese metric networks for scene change detection[EB/OL]. (2018) [2022]. <https://doi.org/10.48550/arXiv.1810.09111>.
- [23] LEBEDEV M A, VIZILTER Y V, VYGOLOV O V, et al. Change detection in remote sensing images using conditional adversarial networks[J]. *International Archives of*

the Photogrammetry, Remote Sensing & Spatial Information Sciences, 2018, 42(2): 565-571.

- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2016: 770-778.
- [25] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation[EB/OL]. (2017)[2022]. <https://doi.org/10.48550/arXiv.1706.05587>.
- [26] ZHU Z, XU M D, BAI S, et al. Asymmetric non-local neural networks for semantic segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 593-602.
- [27] NEKRASOV V, SHEN C H, REID I. Light-weight refinenet for real-time semantic segmentation[EB/OL]. (2018)[2022]. <https://doi.org/10.48550/arXiv.1810.03272>.
- [28] LIN G S, MILAN A, SHEN C H, et al. RefineNet: Multi-path refinement networks for high-resolution semantic segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2017: 5168-5177.
- [29] ZHANG C X, 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.
- [30] DING Q, SHAO Z F, HUANG X, et al. DSA-Net: A novel deeply supervised attention-guided network for building change detection in high-resolution remote sensing images[J]. International Journal of Applied Earth Observation and Geoinformation, 2021, 105: 102591.
- [31] CAYE DAUDT R, LE SAUX B, BOULCH A. Fully convolutional Siamese networks for change detection[C]//2018 25th IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2018: 4063-4067.



李 希(通讯作者) 女, 1994年1月出生, 山东菏泽人. 现为武汉大学测绘学院博士研究生. 主要研究方向是遥感影像变化检测、多时相 SAR干涉测量与形变监测.

E-mail: lixi2019@whu.edu.cn

#### 作者简介



闫 利 男, 1966年8月出生, 山西山阴人. 现为武汉大学测绘学院教授、博士生导师. 主要研究方向是摄影测量与遥感、图像理解与分析、精密图像测量.

E-mail: liyan@sgg.whu.edu.cn