

基于改进 DeepLabv3+ 的高分辨率遥感影像变化检测研究

常振良^{1*}, 杨小冈¹, 卢瑞涛¹, 庄昊²

¹火箭军工程大学导弹工程学院, 陕西 西安 710025;

²解放军 32023 部队, 辽宁 大连 116085

摘要 为解决传统 DeepLabv3+ 算法在遥感影像变化检测上出现的边缘目标分割不精确、分类结果差的问题, 提出了一种改进 DeepLabv3+ 的高分辨率遥感影像变化检测方法。首先, 基于深度分离卷积与空洞卷积构建了 DeepLabv3+ 模型, 大大降低了模型的计算量和参数量。其次, 通过引入异感受野改进池化金字塔结构, 同时在解码器模块中加入多尺度特征张量, 对中间流结构进行残差改造, 优化 Xception 骨干网络, 并通过设置权重系数对网络通道进行权重配置优化, 从而改进 DeepLabv3+ 模型。最后, 采用非生成性和生成性样本扩充方法构建数据集, 并通过实验对比分析了所提方法的检测精度与泛化性能。实验结果表明, 所提方法能够有效改善图形的输出分辨率和细节特征, 具有良好的泛化性能和较高的检测准确率, 且与其他对比方法相比, 所提方法的图像检测准确率较高, 整体精度指标最高可达 96.4%。

关键词 遥感; 遥感影像; 变化检测, 深度学习, DeepLabv3+; 检测精度

中图分类号 TP751

文献标志码 A

DOI: 10.3788/LOP202259.1228006

High-Resolution Remote Sensing Image Change Detection Based on Improved DeepLabv3+

Chang Zhenliang^{1*}, Yang Xiaogang¹, Lu Ruitao¹, Zhuang Hao²

¹College of Missile Engineering, Rocket Force Engineering University, Xi'an 710025, Shaanxi, China;

²The 32023 Unit of the People's Liberation Army, Dalian 116085, Liaoning, China

Abstract To solve the problem of inaccurate segmentation of edge targets and poor classification results in the traditional DeepLabv3+ algorithm in remote sensing image change detection, an improved DeepLabv3+ high-resolution remote sensing image change detection method is proposed. First, a DeepLabv3+ model is developed based on deep separation and hole convolutions, which significantly reduces the amount of calculation and model parameters. Second, the pooling pyramid structure is improved by introducing different receptive fields. Moreover, multiscale feature tensors are added to the decoder module; the intermediate stream structure is reconstructed; and the Xception backbone network is optimized. Then, the network channel is adjusted by setting weight coefficients. The weight configuration is optimized to improve the DeepLabv3+ model. Finally, non-generative and generative sample expansion methods are used to develop the dataset. The detection accuracy and generalization performance of the proposed method are confirmed via experimental comparison and analysis. The experimental results demonstrate that the proposed method can effectively improve the output resolution and detailed characteristics of graphics. This

收稿日期: 2021-06-22; 修回日期: 2021-07-19; 录用日期: 2021-08-31

基金项目: 国家自然科学基金(61806209)

通信作者: *wnsh63@163.com

shows that the proposed method has good generalization performance and higher detection accuracy compared to other traditional methods. Furthermore, the proposed method has the highest image detection accuracy compared with other traditional methods, and the overall accuracy index can reach 96.4%.

Key words remote sensing; remote sensing image; change detection; deep learning; DeepLabv3+; detection accuracy

1 引言

遥感影像变化检测是通过一系列方法从同一场景中不同时间的两幅或多幅图像中提取自然或人工变化区域的过程^[1-2]。目前遥感影像变化检测被广泛应用于土地覆盖研究、灾害评估、医学诊断、视频监控等领域。特别是,当发生自然灾害时,遥感影像变化检测技术可快速有效地识别出受灾地区,为灾害救助提供精准研判^[3-4]。

近年来,随着卫星遥感技术的不断进步,可通过遥感影像反映被摄物体的外貌信息和空间结构特征,为地物数据的处理、解释和分析提供了良好的技术条件^[5]。目前,卫星遥感技术已进入亚米级高分辨率时代,使得地物的精细变化检测已成为遥感影像的重要研究方向之一^[6]。然而,更高分辨率的遥感影像也意味着需要处理的数据量更大。同时,空间分辨率的提高会影响图像的光谱分辨率,使得同一类目标之间的方差增大,从而难以识别变化区域,增加遥感影像变化检测难度^[7]。此外,获取的遥感影像数据还可能受到阳光、传感器和人为因素等干扰,从而增加遥感影像变化检测误差^[8]。而传统的遥感影像变化检测方法需要进行大量的预处理,且变化检测图可能包含大量的椒盐噪声,使得检测结果准确率低、误差大,严重限制了遥感影像变化检测技术的实际应用效果^[9-10]。为此,改善遥感影像变化检测技术的准确率和可靠性,对提高遥感影像变化检测的实际应用具有重要意义。

因此,基于上述原因,众多专家学者对遥感影像变化检测技术的优化与改进进行了大量研究。文献^[11]提出了一种基于矢量数据的遥感影像变化检测方法,该方法利用旧时相的矢量约束,对新时相遥感影像进行分割,并运用孤立森林法获取图像变化指数,从而减少图斑的干扰误差。文献^[12]提出了一种基于支持向量的卫星遥感影像变化检测方法,该方法通过提取深度和抽象特征获得分类结果图,并比较分类结果图以获得变化检测结果。文献^[13]提出了一种基于脉冲耦合神经网络和归一化转动惯量的变化检测方法,该方法首先利用神

经网络对变化前后的图像进行分类,然后利用差分方法生成变化检测图,通过改变前后的图像重叠训练神经网络,将变化检测问题转化为二分法问题,从而直接得到变化区域。但上述方法对复杂样本的适应性较差,容易产生分类器参数估计误差,从而降低检测准确率。近年来,DeepLabv3+语义分割网络逐渐被应用于遥感影像变化检测方面,然而该网络普遍存在边缘目标分割精度差、收敛速度慢等问题。为了解决该问题,文献^[14]通过在DeepLabv3+网络中增加Inception v2卷积网络来提高网络训练速度,然而该方法的网络分割效果不佳。文献^[15]在传统DeepLabv3+网络中增加了卷积块注意模型,从而有效提高了原网络在边缘目标分割上的不足,但是由于未考虑模型的复杂性,导致网络的训练速度慢。

鉴于此,本文提出了一种基于改进DeepLabv3+的高分辨率遥感影像变化检测方法。首先,为降低模型计算量和参数量,构建了DeepLabv3+模型。其次,在原DeepLabv3+模型基础上提出了改进型DeepLabv3+模型,通过引入异感受野,加入多尺度特征张量,改进池化金字塔(ASPP)结构,优化Xception骨干网络,并对网络通道进行权重配置优化。最后,通过样本扩充方法提高样本容量构建实验数据集,并通过对比实验验证所提方法的有效性。

2 DeepLabv3+模型构建

图1为DeepLabv3+模型的网络结构。从图1可以看出,模型的骨干网络为改进的Xception网络,图像输入编码器模块后,分别经过输入流卷积运算、中间流卷积运算、输出流卷积运算,得到分辨率降低为0.0625的特征张量。随后,将该特征张量作为ASPP模块的输入,在3个扩张率相异的并行空洞卷积层和一个全域池化特征层的作用下进行拼接处理,而后再通过 1×1 卷积进行通道压缩,输出一个处理后的特征张量至解码器模块。最后,通过解码器模块中的双线性插值4倍上采样对特征张量进行处理,并与编码器模块输入流卷积运算层输出

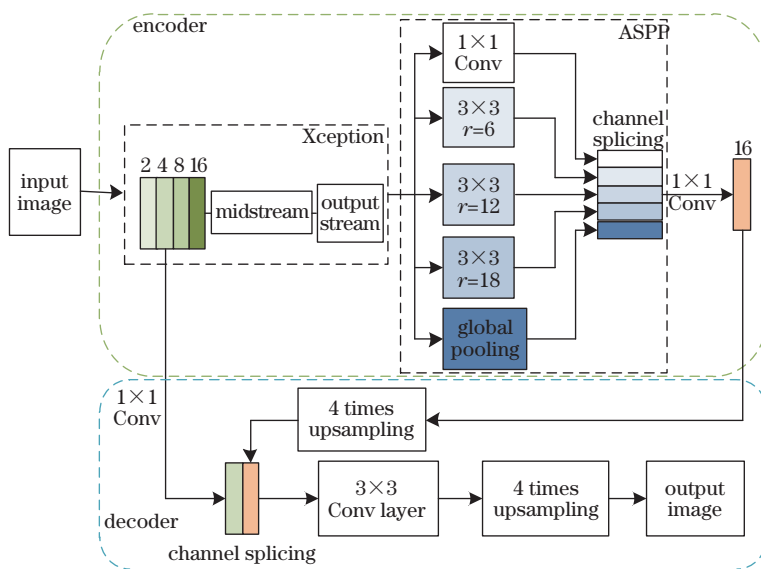


图 1 DeepLabv3+基础模型的网络结构

Fig. 1 Network structure of DeepLabv3+ basic model

的特征图进行拼接处理,通过 3×3 卷积层运算,再对其进行4倍上采样操作,最后得到输出图像。

由上述分析可知,DeepLabv3+模型中运用了大量的深度分离卷积,相较于传统模型的常规卷积,该模型的计算量、参数量都大幅降低,实现了模型的轻量化。同时,该模型利用了空洞卷积代替了传统的下采样,增加了卷积感受野,对改善输出分辨率、图形细节特征等具有良好的作用。此外,DeepLabv3+模型通过上采样实现了低级和高级特征的融合,能够有效

兼顾图像的细节信息和语义信息。

3 改进的DeepLabv3+模型构建

为使DeepLabv3+模型能够适应遥感图像,对原DeepLabv3+模型的ASPP、Xception骨干网络进行了改进和优化,并在条件接收模块(CAM)中融入特征张量对网络通道进行权重配置的优化,从而改进DeepLabv3+模型。图2为改进后的DeepLabv3+模型结构。

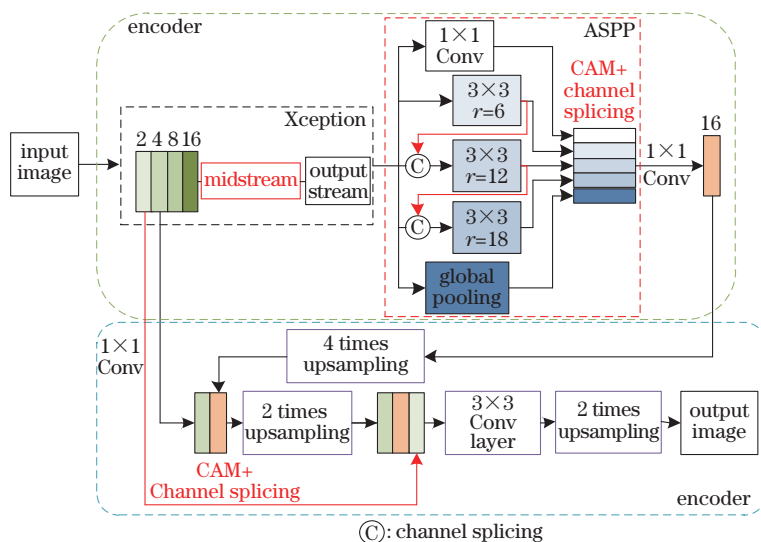


图 2 改进DeepLabv3+模型结构

Fig. 2 Model structure of improved DeepLabv3+

3.1 池化金字塔结构改进

在DeepLabv3+模型中,ASPP中的空洞卷积扩大感受野的扩张率分别为18,12,6,通过卷积核

补零实现了空洞卷积,并得到了非零采样点的卷积结果。在扩张率不断增长的情况下,非零采样点所占比例迅速降低,导致空洞卷积所得到的信息严

重丢失,进而影响信息的利用率,此时通过网络训练得到的特征相关性也较差。同时,ASPP的输出结果是对骨干网络输出特征张量的线性运算,与原输入特征图相比,其卷积核感受野扩张较小,存在一定限制。此外,ASPP的扩张率较为单一,无法考虑不同扩张率空洞卷积之间所存在的相关性。

根据上述分析,通过引入异感受野,将ASPP与异感受野融合形成了改进的ASPP结构,图3为异感受野融合ASPP的空洞卷积过程,其中[图3(a)]表示通道拼接过程,通过扩张率 $r=12$ 的卷积层对原始特征图像进行处理,将处理后的特征图与

原始特征图进行拼接处理,并把拼接后的特征图像输入到 $r=12$ 的卷积层中;[图3(b)]表示通过 $r=12$ 的卷积层对原始输入的特征图像进行采样点分布的操作过程,width表示感受野的大小;[图3(c)]表示 $r=12$ 的卷积层对 $r=6$ 的卷积层输出特征图像进行的采样点分布操作过程, $r=6$ 的卷积层对于原始特征图像也存在采样点分布操作,可通过空洞卷积的级联作用使原始特征图上的感受野大小倍增,最终可达到37。此外,有效的运算参与元素数也得到了巨大增加,参与运算的元素可达到49个。




图3 异感受野融合的空洞卷积。(a)通道拼接;(b) $r=12$ 卷积层在原始特征图中的采样点分布;(c) $r=12$ 卷积层在 $r=6$ 特征图中的采样点分布

Fig. 3 Hollow convolution of fusion of different receptive fields. (a) Channel stitching; (b) sampling point distribution of $r=12$ convolutional layer in original feature map; (c) sampling point distribution of $r=12$ convolutional layer in $r=6$ feature map

为有效地评估信息利用率 η ,将其定义为原始特征图中可参与有效运算的元素数量和感受野中的元素数量的比。表1为融合异感受野前的空洞卷积和融合异感受野之后的空洞卷积的相关数据。由表1可知,融合异感受野后, $r=12$ 、 $r=18$ 的空洞卷积感受野得到有效提升,其信息利用率也得到较大提高。通过融合异感受野,可对不同感受野之间存在的信息相关性进行有效利用和增强,进而能够更容易地对单一像素类别进行识别,降低信息的损失。

表1 异感受野融合对空洞卷积的影响

Table 1 Effect of fusion of different receptive fields on convolution of holes

Expansion rate r	Effective operation element	Receptive field	Information utilization
6	9	13	5.33
12	9	25	1.44
18	9	37	0.66
12+6	49	37	3.58
18+12	81	61	2.18

但是异感受野与ASPP融合后,网络运算量将大大增加,其模块参数量也会发生相应改变。在原来的ASPP模块中,输入空洞卷积的特征图通道数为2048,输出通道数为256,输入和输出图像的分辨率相同,其参数量为

$$N_1 = 2048 \times 3^2 \times 256 \times 3 = 14155776. \quad (1)$$

改进后的ASPP中,在空洞卷积扩张率为6的情况下,原始特征图像先通过 1×1 卷积将通道数量缩减至1280,然后再进行卷积运算。而在空洞卷积扩张率为12和18的情况下,原始特征图像先通过 1×1 卷积将通道数量缩减1024后,再将1024通道图像与上级卷积层的输出图像进行拼接得到处理后的1280特征张量,最后再进行卷积运算。参数量为

$$N_2 = 2048 \times 1280 + 1280 \times 3^2 \times 256 + (2048 \times 1024 + 1280 \times 3^2 \times 256) \times 2 = 15663104. \quad (2)$$

由上述分析可知,相较于未改进的ASPP结构,改进后的ASPP结构的参数量提高了10.65%,信息利用率和感受野都有较大程度的提高,同时其网络复杂性增加较小。

3.2 骨干网络的优化与多尺度融合

在 DeepLabv3+ 模型中, Xception 骨干网络的特征学习模块为中间流结构, 其内部为 8 个相同的直连的分离卷积模块(DSCM), 每个 DSCM 由三个通道数量相同的深度分离卷积运用残差结构相连而成。为解决 DeepLabv3+ 模型中, 特征利用不充分及冗余计算不足等问题, 可对中间流结构进行密集连接, 但密集连接会使形成的网络较为复杂, 而通道拼接方式会大大增加计算量, 增加模型的复杂程度。因此, 可对中间流结构进行残差连接改造, 改造后的模型如图 4 所示。

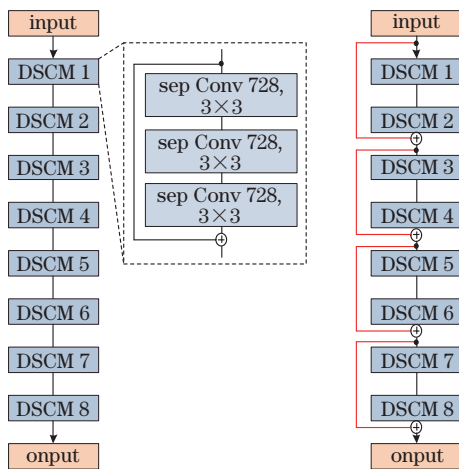


图 4 骨干网络中间流结构优化

Fig. 4 Optimization of intermediate flow structure of backbone network

通常, 分离卷积模块直连会形成直接映射管理, 但根据残差理论, 直接映射对于特征学习存在不利影响。因此, 首先通过 1×1 的卷积将输入特征张量的通道数进行压缩, 使之降低为 600。然后, 将 8 个分离卷积模块分成 4 组残差连接, 再通过 1×1 的卷积把 600 通道数恢复成 728。此处理可提升模块间的信息相关性, 一方面有利于提高网络的特征

学习能力, 另一方面也能够实现网络运算的轻量化。

为进一步提高分割精度, 减少图像的细节损失, 将更低层特征引入特征图中, 并通过多尺度的特征融合形成新的特征图, 对解码器模块进行改造。具体处理方式如下: 对 ASPP 输出的特征图进行 4 倍上采样处理, 然后将其与输入流采样率为 4 的特征图进行融合拼接, 对融合后的特征图进行 2 倍上采样, 并与输入流采样率为 2 的特征图进行融合拼接, 再通过 1×1 卷积进行通道数的调整和处理。最后, 通过 3×3 卷积处理、2 倍上采样处理调整和恢复特征图的分辨率, 使其与原特征图分辨率相同。

3.3 通道注意力模块

在 DeepLabv3+ 模型中, 通道压缩、拼接、融合等操作较多, 不同通道特征在经过多次卷积后, 所得到的特征语义可能较为抽象, 不同的卷积操作可能会导致不同的语义特征, 且对后续的特征学习也存在不同的影响。因此, 为研究不同特征通道与不同语义对特征学习的影响, 设置了描述不同特征通道所占权重的权重系数, 对于网络影响较为重大的通道特征则对应权重越大。权重系数能够使特征学习更有针对性, 也能有效抑制通道冗余信息, 并提高网络的泛化能力和学习能力。

图 5 为通道注意力模块的结构。由图可知, 通道注意力模块主要由压缩模块和奖励模块两个部分组成。在压缩过程中, 首先使用全局平均池化层对通道信息进行统计, 即

$$z_i = \frac{1}{W \times H} \sum_{p=1}^W \sum_{q=1}^H u_i(p, q), \quad (3)$$

式中: z_i 表示 i 通道的特征映射量; 通道总数量为 C ; $W \times H$ 表示输入原始图像的分辨率; $u_i(p, q)$ 表示坐标为 (p, q) 的第 i 个通道的元素。




图 5 通道注意力模块的结构

Fig. 5 Structure of channel attention module

在奖励过程中, 首先对通道数进行降低处理, 即通过全连接层(FC, 权重为 W_1)将通道数降低为原通道数的 $1/h$ 。其次, 使用 ReLU 函数进行激活,

并将其输入权重为 W_2 的全连接层中使得通道数得以恢复。最后, 在 Sigmoid 函数的作用下得到尺度为 $1 \times 1 \times C$ 的归一化通道权重 $s \in \mathbf{R}^C$, 并将原特征

图对应的通道与归一化通道权重进行相乘,从而获得注意力特征图。在改进 Deeplabv3+ 模型中,通过样本训练可知,当 ASPP 多感受野特征融合和 decoder 模块两处多尺度融合部分采用通道减少率为 $h=16$ 的通道注意力模块、骨干网络中间流采用通道减少率为 $h=15$ 的通道注意力模块时,网络训练效果最好。

4 实验结果与分析

4.1 样本数据扩充

因为改进型 DeepLabv3+ 需要大量的训练样本,所以在建立变化检测网络前,需要解决样本数

据不足的问题。此外,最终的检测结果可能会受到来自不同传感器的图像差异的影响。因此,所提方法采用来自同一传感器的图像构建数据集,并进行样本增加操作,以满足改进型 DeepLabv3+ 对足够样本的需求。

本研究拟采用 SZTAKI Air Change Benchmark Set 数据,该数据集共包含 13 对 3 波段图像,图像大小为 952×640 ,分辨率为 1.5 m/pixel ,并包含二进制变化。在标记变更区域时,将新建区域、建筑作业、种植大群树木、新垦耕地、竣工前的地面工作等 5 项差异视为变更内容。图 6 为该数据集的部分样本图片。



图 6 部分训练样本

Fig. 6 Part of training samples

在实际中,改进型 DeepLabv3+ 的训练过程往往需要大量的样本数据,否则容易导致网络过拟合。因此,采用非生成性数据扩充和生成性数据扩充两种方法来扩大变更样本的数量,具体方法如下:

1) 非生成性数据扩充方法。首先,使用各种非生成性数据扩充方法扩展数据规模,通过反转、旋转、锐度调整和高斯噪声添加等操作,使每组原始图像被随机转换成不同的形式。同时,在数据增强过程中,对时间相位为 1 和 33 的图像进行同时处理。非生成性数据扩充方法进行的样本扩充可增加深度学习网络的训练数据量,降低模型拟合不足的风险。

2) 生成性数据扩充方法。由于生成对抗网络(GAN)的基本结构由生成器 G 和鉴别器 D 组成,而鉴别器 D 的输入是生成器 G 的输出,鉴别器 D 能够有效判断生成器 G 产生样本的真假概率。因此,鉴

别器 D 的输出为二进制。若鉴别器输出为 0,则表示输入图像为假;如果鉴别器输出为 1,则表示输入图像为真。若生成器 G 的输入为随机噪声,为欺骗鉴别器 D,则该噪声中将产生一个假样本图像。

通常,生成器 G 的网络结构是一个反进化的神经网络,采用 4 个分数阶卷积进行卷积运算,用反卷积代替汇集层,从而学习模型自身的空间采样。鉴别器 D 的网络结构类似于一个耦合神经网络(CNN),用带步长的卷积代替空间池进行空间采样。在采样过程中,生成器 G 和鉴别器 D 既要互相学习,又要互相对抗。随着网络训练次数的增加,生成器 G 生成的样本越来越真实。经过数千次迭代后,生成器网络可将随机噪声向量从潜在空间转换为数据集的真实样本,而鉴别器很难识别其真实性,此时鉴别器 D 的输出为 0.5。训练生成对抗网络过程中,生成器 G 和鉴别器 D 是同时训练的,随

随着网络训练时间的增加,两者的性能都会有所提高,但生成器 G 生成的样本越来越逼真,经过上千次迭代,生成器网络可以完美生成逼真的假图像。

此时,即构建了一个完美的生成器模型 G,可用于生成样本图像进行深度学习。图 7 为所构建的深度学习卷积的生成对抗网络的基本结构。

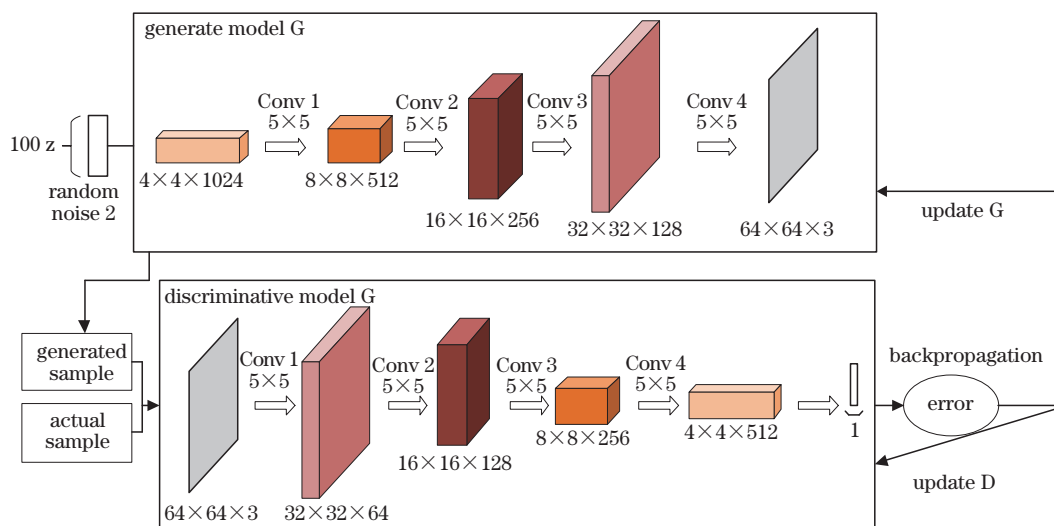


图 7 深度卷积的生成对抗网络基本结构

Fig. 7 Basic structure of deep convolutional generative confrontation network

4.2 基于改进 DeepLabv3+ 的遥感影像变化检测

实验中使用两个数据集进行验证, SZTAKI Airchange Benchmark Set 通过非生成性数据方法进行扩充, 将 13 组原始图像扩展成 78 对, 并将图像切割成 1206 对, 每对大小为 256×256 ; DCGAN, 该网络由生成的 146 对数据集组成, 其中 114 对是有用的。在

样本数据中, 随机选取 70% 的数据进行训练 (即 SZTAKI Airchange Benchmark Set 数据集进行 844 次训练, DCGAN 进行 80 次训练), 其余图像作为测试集。训练和测试数据的比例是 7:3。图 8 为两个不同场景在不同时间段的变化情况, 在掩模图中, 白色区域表示已更改的部分, 黑色区域表示未更改的部分。




图 8 不同场景和时间段的变化情况。(a) 场景 1; (b) 场景 2

Fig. 8 Changes in different scenarios and time periods. (a) Scene 1; (b) scene 2

图 9 和图 10 为改进前、后的精度曲线和损耗曲线结果。由图可知, 当迭代次数达到 50 次时, 网络开始收敛, 经过 60 次训练后, 结果趋于收敛。

图 11 为 DeepLabv3+ 和改进型 DeepLabv3+ 方法的变化检测结果。由图可知, 改进后的网络性能优于原网络, 其中方框标注的区域为明显的改

进。为了进一步评估改进的网络, 将获得的变化检测图与手动标记的参考区域进行比较。

此外, 还将所提出方法与文献 [11]、文献 [12]、文献 [13] 的遥感影像变化检测方法进行了对比分析, 对比结果如表 2 所示。由表可知, 所提改进的 DeepLabv3+ 方法的整体精度最高。同时, 由表可




图 9 DeepLabv3+网络的精度曲线和损耗曲线。(a)精度曲线;(b)损耗曲线

Fig. 9 Accuracy curve and loss curve of DeepLabv3+ network. (a) Accuracy curve; (b) loss curve




图 10 改进型DeepLabv3+网络的精度曲线和损耗曲线。(a)精度曲线;(b)损耗曲线

Fig. 10 Accuracy curve and loss curve of improved DeepLabv3+ network. (a) Accuracy curve; (b) loss curve




图 11 DeepLabv3+(左)和改进型 DeepLabv3+(右)的变化检测结果。(a)场景 1;(b)场景 2

Fig. 11 Change detection results of DeepLabv3+ (left) and improved DeepLabv3+ (right). (a) Scene 1; (b) scene 2

知,文献[13]和文献[14]的处理速度是最快的(均小于 1 s),但其准确性较差,主要原因是这 3 类算法相对简单,可通过不同于深度学习方法的高效代码

实现。文献[12]中的算法不像基于 DeepLabv3+那样将大规模图像分成标准大小的块,所以其具有更高的处理速度,然而对于数据集的变化检测,其性能

表 2 不同方法的变化检测结果比较

Table 2 Comparison of change detection results of different methods

Evaluation index (EI)	Improved DeepLabv3+	DeepLabv3+	Literature [11]	Literature [12]	Literature [13]
Kappa coefficient (Kappa)	0.75	0.64	0.58	0.19	0.35
Overall accuracy (OA)	95.1%	93.6%	92.8%	95.1%	87.7
Omission rate (OR)	4.6%	5.2%	3.4%	78.1%	5.0%
Error rate (ER)	5.6%	18.0%	21.2%	2.5%	37.2%
Sensitivity (SS)	94.4%	81.2%	68.6%	21.8%	65.9%
Specificity (SP)	95.2%	94.9%	94.0%	97.4%	94.2%
Balance accuracy (BA)	94.8%	88.1%	81.3%	59.6%	80.1%
F1-score (F1)	77.8%	69.7%	70.1%	21.5%	64.3%
Time required /s	12.71	12.65	16.06	1.10	0.26

并不理想。特别是由于公共标准网络的预处理模型主要基于建筑的变更数据,标准网络的漏检率很高,因此,会将大多数检测区域区分为未改变的区域。对比 DeepLabv3+ 算法和改进型 DeepLabv3+ 算法可以发现,两者时间复杂度相近,一幅 1048×724 分辨率图像的平均处理时间约为 10 s,虽然改进型 DeepLabv3+ 网络的时间耗费略高于 DeepLabv3+ 网络,但其变化检测精度明显增强,且检测错误率要低得多。

4.3 泛化性能验证

为了验证所提遥感影像变化检测方法的泛化性能,分别在 Landsat 8 数据集和 Onera 卫星变化探

测数据集上进行检测实验,具体如下所示:

1) Landsat 8 数据集结果。为验证所提改进型 DeepLabv3+ 的综合性能,选取 Landsat8 号卫星图像数据集,该数据集包含 8 个区域的 30 m 分辨率遥感影像,但每个影像组的大小不一,选择的两个图像组的尺寸大小分别为 1600×1600 和 1600×1206。图 12 为两个不同场景的两幅图像。

将原始和改进的 DeepLabv3+ 方法分别用两组图像进行测试,其变化检测结果如图 13 所示。将两个基于 DeepLabv3+ 网络的变化检测结果与手动标记进行比较,可获得检测指标,结果如表 3 所示。




图 12 Landsat 8 测试图像。(a) 场景 3; (b) 场景 4

Fig. 12 Landsat 8 test images. (a) Scene 3; (b) scene 4

由表 3 可知,两种基于 DeepLabv3+ 的方法性能均有所下降,主要是由于 Landsat 8 卫星图像和 SZTAKI 数据集之间的分辨率存在差异,虽然两种网络的检测性能都有所下降,但基于改进型

DeepLabv3+ 的算法仍然具有较大优势。

2) Onera 卫星变化探测数据结果。图 14 为选取的两组图片数据。

分别用两个图像对原始和改进的 DeepLabv3+




图 13 DeepLabv3+(左)和改进型 DeepLabv3+(右)检测结果。(a)场景 3;(b)场景 4

Fig. 13 DeepLabv3+ (left) and improved DeepLabv3+ (right) detection results. (a) Scene 3; (b) scene 4

表 3 基于 Landsat 8 数据的深度卷积方法的变化探测结果

Table 3 Change detection results of deep convolution method based on Landsat 8 data

Evaluation index (EI)	Kappa	OA%	OR%	ER%	SP%	BA%	FI%
DeepLabv3+	0.41	95.7	48.6	3.1	96.9	74.1	43.1
Improved DeepLabv3+	0.56	96.4	20.0	3.1	96.8	88.4	57.7




图 14 OSCD 数据集的部分图像。(a)场景 5;(b)场景 6

Fig. 14 Part of images of OSCD dataset. (a) Scene 5; (b) scene 6

网络进行测试,其变化检测结果如图 15 所示。将两个基于 DeepLabv3+ 的网络变化检测结果与手动标记进行比较,可计算得到检测精度指标,结果

如图 4 所示。由表可知,在两个基于 DeepLabv3+ 的网络变化检测方法下,OSCD 数据集结果的准确性最低。




图 15 DeepLabv3+(左)和改进型DeepLabv3+(右)变化检测结果。(a)场景5;(b)场景6

Fig. 15 DeepLabv3+ (left) and improved DeepLabv3+ (right) change detection results. (a) Scene 5; (b) scene 6

表 4 基于 OSCD 数据的深度变化探测结果比较

Table 4 Comparison of depth change detection results based on OSCD data

Evaluation index (EI)	Kappa	OA%	OR%	ER%	SP%	BA%	FI%
DeepLabv3+	0.39	75.2	8.7	35.5	83.7	76.8	39.0
Improved DeepLabv3+	0.44	83.6	5.3	27.2	89.1	80.3	44.8

5 结 论

针对基于深度学习网络的遥感影像变化检测方法样本获取难度大、分类结果差、准确度不高的问题,提出了一种改进DeepLabv3+的高分辨率遥感影像变化检测方法,并通过对比实验得出以下结论:1)所提改进型DeepLabv3+能够有效改善遥感影像的输出分辨率和细节特征,有效降低模型计算的复杂度,具有良好的泛化性能和较高的检测准确率;2)与其他方法相比,所提方法的图像检测准确率最高,其整体精度指标最高可达96.4%。

参 考 文 献

- [1] 李竺强,朱瑞飞,马经宇,等.联合连续学习的残差网络遥感影像机场目标检测方法[J].光学学报,2020,40(16):1628005.
Li Z Q, Zhu R F, Ma J Y, et al. Airport detection method combined with continuous learning of residual-based network on remote sensing image[J]. Acta Optica Sinica, 2020, 40(16): 1628005.
- [2] 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.

- [3] 常京新,王双喜,杨元维,等.高分遥感影像建筑物轮廓的逐级优化方法[J].中国激光,2020,47(10):1010002.
Chang J X, Wang S X, Yang Y W, et al. Hierarchical optimization method of building contour in high-resolution remote sensing images[J]. Chinese Journal of Lasers, 2020, 47(10): 1010002.
- [4] Li W, Lu M, Chen X W. Automatic change detection of urban land-cover based on SVM classification[C]//2015 IEEE International Geoscience and Remote Sensing Symposium, July 26-31, 2015, Milan, Italy. New York: IEEE Press, 2015: 1686-1689.
- [5] 黄亮.多时相遥感影像变化检测技术研究[J].测绘学报,2020,49(6):801-802.
Huang L. Research on change detection technology in multi-temporal remote sensing images[J]. Acta

- Geodaetica et Cartographica Sinica, 2020, 49(6): 801-802.
- [6] 刘红超, 张磊. 面向类型特征的自适应阈值遥感影像变化检测[J]. 遥感学报, 2020, 24(6): 728-738.
Liu H C, Zhang L. Adaptive threshold change detection based on type feature for remote sensing image[J]. Journal of Remote Sensing, 2020, 24(6): 728-738.
- [7] 佃袁勇, 方圣辉, 姚崇怀. 一种面向地理对象的遥感影像变化检测方法[J]. 武汉大学学报·信息科学版, 2014, 39(8): 906-912.
Dian Y Y, Fang S H, Yao C H. The geographic object-based method for change detection with remote sensing imagery[J]. Geomatics and Information Science of Wuhan University, 2014, 39(8): 906-912.
- [8] 黄亮, 左小清, 於雪琴. 遥感影像变化检测方法探讨[J]. 测绘科学, 2013, 38(4): 203-206.
Huang L, Zuo X Q, Yu X Q. Review on change detection methods of remote sensing images[J]. Science of Surveying and Mapping, 2013, 38(4): 203-206.
- [9] Lü P Y, Zhong Y F, Zhao J, et al. Unsupervised change detection based on hybrid conditional random field model for high spatial resolution remote sensing imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(7): 4002-4015.
- [10] Zhuang H F, Deng K Z, Fan H D, et al. Strategies combining spectral angle mapper and change vector analysis to unsupervised change detection in multispectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(5): 681-685.
- [11] 张春森, 李国君, 崔卫红. 一种基于矢量数据的遥感影像变化检测方法[J]. 武汉大学学报·信息科学版, 2021, 46(3): 309-317.
Zhang C S, Li G J, Cui W H. A change detection method for remote sensing image based on vector data [J]. Geomatics and Information Science of Wuhan University, 2021, 46(3): 309-317.
- [12] 付青, 罗文浪, 吕敬祥. 基于 AlexNet 和支持向量机相结合的卫星遥感影像土地利用变化检测[J]. 激光与光电子学进展, 2020, 57(17): 172802.
Fu Q, Luo W L, Lü J X. Land utilization change detection of satellite remote sensing image based on AlexNet and support vector machine[J]. Laser & Optoelectronics Progress, 2020, 57(17): 172802.
- [13] Zhong Y F, Liu W F, Zhao J, et al. Change detection based on pulse-coupled neural networks and the NMI feature for high spatial resolution remote sensing imagery[J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(3): 537-541.
- [14] 陈天华, 郑司群, 于峻川. 采用改进 DeepLab 网络的遥感图像分割[J]. 测控技术, 2018, 37(11): 34-39.
Chen T H, Zheng S Q, Yu J C. Remote sensing image segmentation based on improved DeepLab network[J]. Measurement & Control Technology, 2018, 37(11): 34-39.
- [15] 袁立, 袁吉收, 张德政. 基于 DeepLab-v3+ 的遥感影像分类[J]. 激光与光电子学进展, 2019, 56(15): 152801.
Yuan L, Yuan J S, Zhang D Z. Remote sensing image classification based on DeepLab-v3+ [J]. Laser & Optoelectronics Progress, 2019, 56(15): 152801.