



计算机科学

COMPUTER SCIENCE

基于特征注意力融合网络的遥感变化检测研究

蓝凌翔, 池明旻

引用本文

蓝凌翔, 池明旻. 基于特征注意力融合网络的遥感变化检测研究[J]. 计算机科学, 2022, 49(6): 193-198.

LAN Ling-xiang, CHI Ming-min. Remote Sensing Change Detection Based on Feature Fusion and Attention Network[J]. Computer Science, 2022, 49(6): 193-198.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于注意力机制和门控网络相结合的混合推荐系统](#)

Hybrid Recommender System Based on Attention Mechanisms and Gating Network

计算机科学, 2022, 49(6): 158-164. <https://doi.org/10.11896/jsjcx.210500013>

[基于解耦-检索-生成的图像风格化描述生成模型](#)

Stylized Image Captioning Model Based on Disentangle-Retrieve-Generate

计算机科学, 2022, 49(6): 180-186. <https://doi.org/10.11896/jsjcx.211100129>

[基于样本分布损失的图像多标签分类研究](#)

Study on Multi-label Image Classification Based on Sample Distribution Loss

计算机科学, 2022, 49(6): 210-216. <https://doi.org/10.11896/jsjcx.210300267>

[多分支 RA 胶囊网络及在图像分类中的应用](#)

Multi-branch RA Capsule Network and Its Application in Image Classification

计算机科学, 2022, 49(6): 224-230. <https://doi.org/10.11896/jsjcx.210400087>

[基于时空图卷积和注意力模型的航拍暴力行为识别](#)

Aerial Violence Recognition Based on Spatial-Temporal Graph Convolutional Networks and Attention

Model

计算机科学, 2022, 49(6): 254-261. <https://doi.org/10.11896/jsjcx.210400272>

基于特征注意力融合网络的遥感变化检测研究

蓝凌翔 池明旻

复旦大学上海市数据科学重点实验室 上海 200438

(lxlan18@fudan.edu.cn)

摘要 变化检测是遥感的重要任务之一,通常被认为是像元级的分类问题。近年来,深度神经网络由于对双时相图像具有强大的层次表示能力,在变化检测中得到了广泛应用。文中基于编码器-融合-解码器框架,提出了一种基于特征注意力融合的变化检测网络(FFAN),将其编码器生成的特征与经由注意力机制增强后的双时相差异特征进行融合,以更好地捕获双时相变化信息。特别地,通过由注意力机制增强的双时相特征,可以显著增强深层网络中间层中变化信息的传播,该特征显式地建模双时相输入的相互依赖性并自适应地重新校准FFAN中的变化激活。在开源数据集上进行的实验表明,与现有方法相比,所提FFAN具有更优异的检测性能。

关键词: 变化检测;遥感;深度学习;注意力机制;特征融合

中图分类号 TP391

Remote Sensing Change Detection Based on Feature Fusion and Attention Network

LAN Ling-xiang and CHI Ming-min

Shanghai Key Laboratory of Data Science, Fudan University, Shanghai 200438, China

Abstract Change detection is one of the essential tasks in remote sensing, which is usually regarded as a pixel-level classification problem. In recent years, deep neural networks have also been widely used in the change detection task due to their powerful hierarchical representation of bi-temporal images. A feature fusion and attention network (FFAN) is proposed based on neural encoder-fusion-decoder framework. It integrates features generated by encoder with the bi-temporal difference feature enhanced by attention mechanism, to better capture the bi-temporal change information. In particular, bi-temporal features enhanced by attention mechanism can significantly enhance the propagation of change information in the intermediate layers of deep networks, which adaptively recalibrates the change activation in FFAN by explicitly modeling the interdependence of bi-temporal inputs. Experiments conducted on open-source dataset demonstrate that, compared with existing methods, FFAN obtains better performance.

Keywords Change detection, Remote sensing, Deep learning, Attention mechanism, Feature fusion

1 引言

遥感技术的蓬勃发展使得动态观测土地利用/土地覆盖的变化成为可能。变化检测是遥感任务中一项重要的应用,通常,双时相变化检测讨论的是如图1所示的基于双时相图像的像素级土地利用/土地覆盖变化检测。这一任务广泛应用于城市发展监测^[1]、山体滑坡检测^[2]、溢油检测^[3]等领域。




图1 变化检测任务示例图

Fig.1 Example of change detection task

在传统方法中,变化检测通常基于单个像元的变化进行检测,如图像差分法^[4]、图像比值法^[5]等。此外,还出现了一些基于特征变换的方法,如变化向量分析法^[6]、Kaulr-Thomas变换法^[7]、多元变化检测法^[8]、主成分分析法^[9]等。对于上述方法而言,定义一个适当的决策函数来判别区域变化与否至关重要。上述这类基于光谱或数据本身的物理特性经由统计分析得出变化的方法通常需要应用阈值来区分变化区域和非变化区域。因此,选择一个合适的阈值来判别变化也成为了一项巨大的挑战。近几十年来,随着机器学习的发展,这类以分类为基础的方法^[10-11]被广泛地用于替代基于阈值的方法。

特别地,近年来随着深度学习的发展,这些基于深度学习的方法被成功应用于双时相变化检测任务^[12-14]。早期,深度学习方法通常将深度神经网络与传统方法相结合,其中深度

到稿日期:2021-05-10 返修日期:2021-06-04

基金项目:国家重点研发计划(2017YFA0402600);中国石油化工股份有限公司科技攻关项目(PE19003-3)

This work was supported by the National Key R & D Program of China(2017YFA0402600) and Science and Technology Research Project of Sinopec(PE19003-3).

通信作者:池明旻(mmchi@fudan.edu.cn)

神经网络通常被用作一种特征提取器,例如,文献[15]利用卷积神经网络(Convolutional Neural Network, CNN)来提取图像特征,随后利用基于阈值的传统方法对提取的特征进行分割以生成最终的变化图。为了利用 CNN 端到端的特性,学者们提出了一些利用神经网络的端到端方法,如 GET-NET^[14]。由于基于编解码器(Encoder-decoder)框架的全卷积网络(Fully Convolutional Networks, FCN)能够对图像进行逐像素分析,并被成功地用于语义分割任务,因此这类基于 FCN 网络的完全端到端模型也被广泛应用于变化检测任务中,如文献[16-18]。

然而,如何利用这类基于 FCN 的模型来融合双时相图像的时空特征信息是一个关键问题。通常有两种特征可供研究者进行进一步的决策,即利用 FCN 的编码器分别为时刻 1 的图像和时刻 2 的图像生成两个独立的特征(f_1 和 f_2),以及它们的差分特征($f_1 - f_2$)。根据对双时相特征的使用方法,现有的基于 FCN 的深度学习的方法可分为以下 3 种,即对差分特征的研究^[17]、对两个双时相特征进行拼接后的研究^[2]、将差分特征与两个双时相特征共同拼接后的研究^[19-20]。现有的深度学习的方法大多是先提取双时相特征,并根据上述特征融合方法进行时相特征的融合,然后利用 Softmax 函数进行分类(检测变化与否),但 these 方法可能会逐渐削弱误差反向传播过程中的变化信息。此外,为了获得包含更丰富信息的特征表示,注意力机制通常通过空间注意力^[18]或通道注意

力^[21]机制被引入变化检测任务。然而,这些方法通常采用拼接或差分特征作为主要特征,忽略了时相间的特征关系捕捉,因此难以充分利用时空信息。

本文提出了一个端到端的基于特征注意力融合的变化检测网络(Feature Fusion Attention Network, FFAN),在编码器-融合-解码器的框架下对双时相遥感图像进行变化检测。特别地,FFAN 利用一个权值共享编码器对时刻 T_1 和 T_2 的图像分别生成特征 f_1 和 f_2 ,并对这两个特征进行拼接以供后续处理,这一过程被认为是对变化信息的聚合。此外,利用注意力机制将差分特征 $f_1 - f_2$ 生成一种包含全局差异信息的辅助特征,用于增强聚合的变化信息中差异特征表示。将上述两部分组合为一个时空特征融合单元,即基于注意力机制的变化聚合(Change Aggregation and Attention, CAA)模块以融合双时相特征的时空特征。

2 基于特征注意力融合的变化检测网络

本节首先分析了利用基于编解码器框架提出的编码器-融合-解码器框架来解决变化检测问题的可行性。随后介绍了基于该框架提出的基于特征注意力融合的变化检测网络 FFAN,其中包含了一个基于注意力机制的变化聚合模块,该模块通过拼接双时相特征,并结合一种注意力机制来增强网络中差异特征表示。提出的 FFAN 结构如图 2 所示。

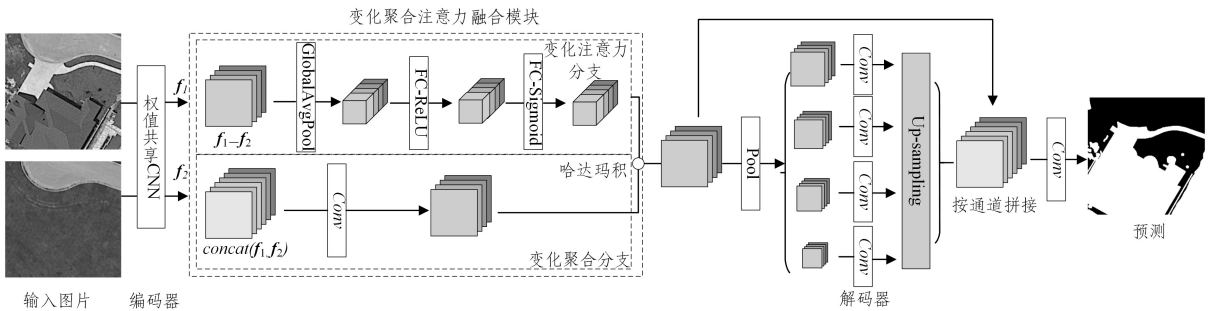


图 2 基于特征注意力融合的变化检测网络(FFAN)结构图

Fig. 2 Architecture of FFAN

2.1 可行性分析

利用编解码器网络对图像进行逐像素分析最早被应用于语义分割任务^[22],其可被描述为:

$$y = d(e(x))$$

其中, e 和 d 分别为编码器和解码器,它们分别负责特征提取和对提取的特征进行像素级的语义分类,即将输入的图像 x 转换为像素级的语义分类输出 y 。用于语义分割的编解码器的本质为对输入 x 拟合一个像素级的分类函数。

基于编码器-融合-解码器的框架,在保留编解码器框架的基础上,增加了特征融合模块,其解决变化检测任务的过程可以描述为:

$$y = d(f(c(x_1), c(x_2)))$$

其中, c , f 和 d 分别为编码器、融合模块和解码器,即将输入的双时相图像 x_1 和 x_2 转换为包含像素级变化分类的输出 y 。其中,权值共享的编码器和融合模块对输入的双时相图像进行特征提取,并生成一个包含双时相差异的特征以供后续

解码器对其进行像素级分类。

用于变化检测任务的编码器生成两个 $H \times W \times C$ 的特征,而用于语义分割任务的编码器生成一个该特征。使用特征融合模块 f ,将两个特征与语义分割任务解码器输入的一个特征进行形式化等价转换,即可利用解码器对特征实现像素级分类。在物理意义中,语义分割网络的编码器负责提取图像类别特征,并利用提取特征使用解码器生成像素级的语义分割图像;在变化检测任务中,编码器分别提取双时相图像的类别特征,随后使用融合模块将类别特征转化为双时相特征间的类别差异特征,并利用解码器对差异特征生成像素级变化检测图像。因此,利用编码器-融合-解码器框架来解决变化检测问题具有可行性。

2.2 编码器与解码器

为了利用 CNN 出色的特征提取能力,编码器部分利用 ResNet-101^[23]对双时相特征分别进行提取。ResNet 中的基本单元为残差层(Residual Layer),其将常规神经网络中串联

的层重新构造为结合输入特征的层以学习残差函数,它由 3 个串行卷积($1 \times 1, 3 \times 3, 1 \times 1$)和 1 个从输入到输出的连接组成。ResNet-101 由 3 个卷积层和 4 个残差块(Residual Block)串联组成,这 4 个残差块中分别包含 3, 4, 23, 3 个基本的残差层,详细设置如表 1 所列。同时,为了更好地捕捉微小的变化特征,在 ResNet-101 的第 3 和第 4 个残差块中应用膨胀系数为 2 和 4 的空洞卷积^[24]来扩大感受野。将双时相原始图像输入到编码器,然后使用权重共享主干生成两个独立的特征映射,即 f_1 和 f_2 。

表 1 编码器各层的卷积核大小、通道数及堆叠数量

Table 1 Convolution kernel size, channel number and stacking number of each layer of encoder

| 层名称 | 卷积核大小 | 卷积通道数 | 堆叠数量 |
|-------|--|-------------------|------|
| 卷积层 1 | ($3 \times 3, 3 \times 3, 3 \times 3$) | (3, 64, 128) | 1 |
| 残差块 1 | ($1 \times 1, 3 \times 3, 1 \times 1$) | (128, 64, 256) | 3 |
| 残差块 2 | ($1 \times 1, 3 \times 3, 1 \times 1$) | (256, 128, 512) | 4 |
| 残差块 3 | ($1 \times 1, 3 \times 3, 1 \times 1$) | (512, 256, 1024) | 23 |
| 残差块 4 | ($1 \times 1, 3 \times 3, 1 \times 1$) | (1024, 512, 2048) | 3 |

为了丰富上下文信息,FFAN 的解码器采用了一种金字塔多尺度池策略。如图 2 所示,在解码器中将 CAA 模块生成的特征利用平均池化操作下采样至 4 个不同的尺度,分别为 $1 \times 1, 2 \times 2, 3 \times 3$ 和 6×6 。在这 4 个下采样的特征后使用 4 个独立的 1×1 卷积,并通过双线性将其插值至相同输入尺寸后与输入的特征按通道进行拼接;同时,后接两个 1×1 的卷积,将特征的通道数分别降至 512 和 2,并通过双线性插值将生成的特征还原至原始尺寸,最后经由一个 Softmax 层计算输出的类别。

2.3 变化聚合注意力融合模块

现有的变化检测方法通常是基于双时相特征拼接或差分特征来构造的,而双时相特征通常被视为后续变化决策的主要特征。在提出的 CAA 模块中,通过拼接特征来保留双时相图像各自独立的特征,并将差分特征作为一种全局差异的辅助特征信息,自适应地计算拼接的双时相特征中各通道的影响,并重新校准变化信息的特征表征。CAA 模块作为连接 FFAN 中编码器和解码器的桥梁,是变化增强的关键组件。

CAA 模块是一个神经网络计算单元,执行以下变换:

$$F_{rr}: f_1, f_2 \rightarrow y(f_1, f_2)$$

其中, $f_1, f_2, y \in \mathbb{R}^{H \times W \times C}$; F_{rr} 是卷积操作,其将由编码器生成的两个独立特征 f_1 及 f_2 进行转换生成一种包含全局差异的辅助信息。CAA 模块共包含两个分支,即变化聚合分支和变化注意力分支。变化聚合分支按通道的特征拼接操作最大限度地保留双时相特征的原始信息;变化注意力分支利用差分特征进行一系列非线性变换,将全局的变化特征信息作为辅助来帮助变化聚合分支更好地进行特征提取,并校正其中的变化特征表示。

变化聚合分支旨在对不同时相特征进行融合,并最大限度地保留原始特征。首先对两个特征按通道拼接生成 $H \times W \times 2C$ 维度的特征,其中 H 和 W 分别表示输入特征的和和宽, C 表示特征 f_1 及 f_2 的通道数;随后,由卷积核大小为 1×1 的卷积操作将其降至 $H \times W \times C$ 维。它的形式化定义如下:

$$d = BN(\delta \cdot Conv(\lambda(f_1, f_2)))$$

其中, λ 代表按通道拼接操作, $Conv$ 表示卷积操作, δ 表示线性整流函数; BN 表示批标准化操作。这一操作对双时相特征提供了一种聚合操作。

有别于传统方法中将差分特征作为待检测主要特征的方法,本文提出将差分特征作为辅助信息,引导变化聚合分支更好地表达差异特征,以供后续解码器上采样使用。变化注意力分支的形式化定义如下:

$$g = p(f_1 - f_2) \times W_1$$

其中, p 代表全局平均池化操作^[25],即对于原始的 $H \times W \times C$ 矩阵中的每一通道采用平均池化操作生成 $1 \times 1 \times C$ 维的矩阵。这里引入了差异特征 $f_1 - f_2$,以显式增强变化检测任务中核心的双时相特征间的差异信息表征。 $W_1 \in \mathbb{R}^{C \times \frac{C}{k}}$ 代表全连接层中学习的参数,将原有的 $1 \times 1 \times C$ 维的矩阵降至 $1 \times 1 \times \frac{C}{k}$ 维的矩阵。同时,执行如下线性整流函数操作:

$$r_i = \max(0, g_i)$$

其中, $r \in \mathbb{R}^{\frac{C}{k}}$ 代表经过线性整流函数处理后的向量。通过以下方式进行升维:

$$u = r \times W_2$$

其中, $W_2 \in \mathbb{R}^{\frac{C}{k} \times C}$ 代表全连接层中学习的参数,将原有的维的矩阵升至 $1 \times 1 \times C$ 维的矩阵,并使用 Sigmoid 函数对特征进行进一步学习:

$$z = \frac{1}{1 + e^{-u}}$$

这里引入差异特征 $f_1 - f_2$ 并进行分线性变换,旨在使用神经网络自适应地学习两个特征不同通道间的依赖关系,并使用 Sigmoid 进一步区分其差异程度。

随后,使用包含全局变化信息的特征去引导变化聚合分支中拼接的双时相特征,以更好地学习变化特征,其形式化定义如下:

$$y_i = z_i \times d_i$$

其中, $i \in [1, 2, \dots, C]$, 即 y_i 中每一矩阵由对应通道的 z_i 与矩阵 d_i 计算所得。 d_i 可以被认为是在第 i 个通道对双时相特征 f_1 和 f_2 的聚合; z_i 可以认为是包含对应第 i 个通道的差异程度,即通过 z_i 显式地引导神经网络区分差异特征。该过程可以看作是利用注意力机制生成的差异程度 z_i 自适应地重新校准 FFAN 中的变化激活 d_i , 其对变化与非变化区域的表征差异更为突出,以供解码器分类。

3 实验结果及分析

3.1 数据集

实验中使用的数据集^[26]是同一地区随季节变化的遥感 RGB 图像,这些从 Google Earth(DigitalGlobe)获得的图像包含 7 对像素为 4725×2700 的图片。这些图像对被预先裁剪为 16000 个图像,每个图像的像素为 256×256 ,其中,10000 个样本用于训练,3000 个样本用于验证,3000 个样本用于测试。

3.2 对比方法及实验设置

为了比较 FFAN 和现有先进模型的性能,本实验采用了

4种不同的指标,即总体准确率(Overall Accuracy)、精确率(Precision)、召回率(Recall)和F1值(F1-Score)。同时,将FFAN与现有的针对RGB双时相图像提出的先进方法进行比较以验证其性能。随着遥感检测技术的发展,许多不同的数据融合方法都被应用于遥感领域^[27]。本节列出的实验中用于比较的数据融合检测方法包括DASNet, FCN-PP, SS-CD,以及DSIFN。

(1)DASNet^[28]通过一个权值共享的深度语义分割网络独立生成两个特征,并通过度量学习方法计算两个特征的距离并生成预测结果。

(2)FCN-PP^[2]是应用于山体滑坡检测的网络。其首先使用多元形态学重建对原始数据进行处理,并将预处理后的数据按通道拼接输入一个U型结构的编码器-解码器神经网络中,然后在编码器与解码器中添加一种基于金字塔特征池化操作的多尺度特征融合策略。

(3)SSCD^[17]利用全卷积神经网络^[22]学习经由差分预处理的双时相图像的差异特征,以生成像素级的变化预测结果。

(4)DSIFN^[19]提出了一个共享编码器的特征提取网络,用于提取双时相数据的特征,以及使用了转置卷积组成上采样网络,将深度特征还原至原尺寸并生成变化图,同时在网络结构中也保留了多尺度特征以提升融合性能。

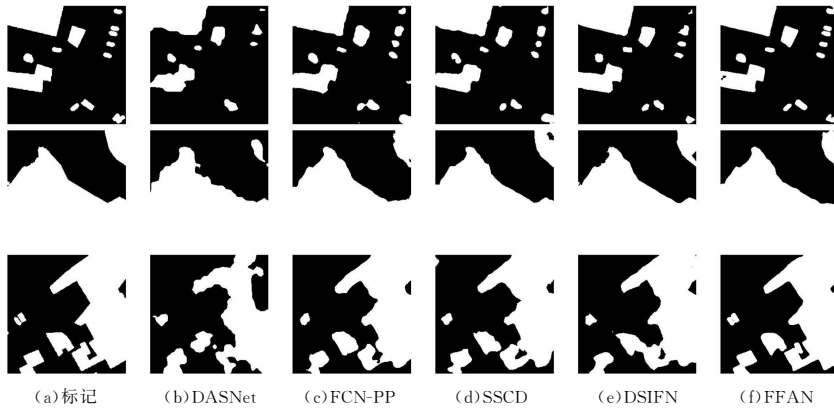


图3 不同深度变化检测模型生成的变化图

Fig. 3 Change maps generated by different deep change detection models

具体地,与对比方法相比,FFAN在总体准确率、召回率和F1值方面都取得了更好的性能。从表2可以看出,FFAN在召回率上相比性能最好的对比方法也提升了3.85%,而召回率是变化检测任务中衡量模型性能的一项关键指标,其衡量了模型对变化区域的检出能力;同时,FFAN的F1值提升了1.95%。此外,由生成的变化图可得,相对对比方法,FFAN对细粒度的变化区域有更好的检测效果。我们认为,相比其他方法,在FFAN中的CAA模块对时空特征进行了更充分的融合,通过引入全局的变化特征并结合注意力机制,显式地引导变化聚合分支学习双时相特征间的相互依赖关系。此外,在编码器中引入了空洞卷积,在解码器中引入了金字塔多尺度融合策略,这使得FFAN对于细粒度的变化有更好的检测效果。

3.4 消融实验与讨论

3.3节的实验结果表明,FFAN相比其他方法取得了

上述对比实验的实验设置均参照原文的超参数设定。同时,本文提出的FFAN算法设置学习率为 1×10^{-3} ,批大小为24,设置训练迭代次数为150,使用交叉熵作为损失函数并使用Adam优化器进行优化。实验基于Linux系统的PyTorch深度学习框架,硬件环境为Intel(R) Xeon(R) CPU E5-2620 v4 @ 2.10 GHz处理器,4块Nvidia GeForce GTX 1080 Ti显卡及128GB内存。

3.3 实验结果与讨论

FFAN和其他先进方法的性能比较结果如表2所列,生成的变化图对比结果如图3所示。实验结果表明,FFAN方法的性能优于其他对比方法。

表2 基于遥感变化检测数据的实验结果

Table 2 Experimental results based on remote sensing change detection data

| (单位:%) | | | | |
|--------|-------|-------|-------|-------|
| 方法 | 总体准确率 | 精确率 | 召回率 | F1值 |
| DASNet | 98.13 | 76.92 | 73.70 | 73.95 |
| FCN-PP | 98.68 | 83.33 | 78.54 | 79.90 |
| SSCD | 98.30 | 82.31 | 75.50 | 77.60 |
| DSIFN | 99.14 | 90.79 | 80.25 | 84.29 |
| FFAN | 99.16 | 89.53 | 83.34 | 85.93 |

更好的性能。本文进一步探究了FFAN中CAA模块结合注意力机制和引入全局差异特征的有效性。具体地,CAA模块有两个分支,即变化聚合分支和变化注意力分支。变化注意力分支提供了一种辅助的全局差异信息,以帮助变化聚合分支更好地学习双时相特征间的相互依赖关系。

消融实验设计了CAA模块中的变化注意分支是否被去除的两组对比实验。此外,在变化聚合分支中应用了3种融合策略来组合来自编码器的两个特征映射,包括特征差分、特征和以及特征拼接。实验结果如表3所列。从表3中的实验结果可以看出,变化注意分支对使用不同融合策略的变化聚合分支均有显著影响,即引入的全局差异信息可以有效地引导变化聚合分支学习双时相特征的相互依赖关系。值得注意的是,采用特征拼接融合策略的模型比其他模型具有更好的性能,我们认为这一策略为后续网络保留了更多的原始特征。

表3 针对不同融合策略是否包含基于注意力机制的变化聚合模块实验

Table 3 Experiment of change aggregation module based on attention mechanism for different fusion strategies

(单位:%)

| CAA 模块 | 融合方式 | 总体准确率 | 精确率 | 召回率 | F1 值 |
|--------|------|-------|-------|-------|-------|
| ✓ | 特征差分 | 98.11 | 83.70 | 70.58 | 75.18 |
| | 特征和 | 98.62 | 85.36 | 74.38 | 78.09 |
| | 特征拼接 | 98.76 | 85.53 | 79.39 | 80.71 |
| | 特征差分 | 98.78 | 87.57 | 82.19 | 84.05 |
| | 特征和 | 99.00 | 88.37 | 82.19 | 85.16 |
| | 特征拼接 | 99.16 | 89.53 | 83.34 | 85.93 |

此外,为了探索注意力机制对 FFAN 中间层激活传播的影响,我们应用类激活映射(Class Activation Mapping)^[29]可视化 CAA 模块和解码器之间的层,如图 4 所示,包含注意力机制的模型(见图 4(e))相比未包含注意力机制的模型(见图 4(d))对变化区域的表征显著增强,而对非变化区域有一定的抑制作用。我们认为,这种引入的全局变化特征直接作用于变化聚合分支,同时通过引入注意力机制自适应地校准其变化激活,能更好地表示双时相图像间的差异特征,提升了模型的性能。

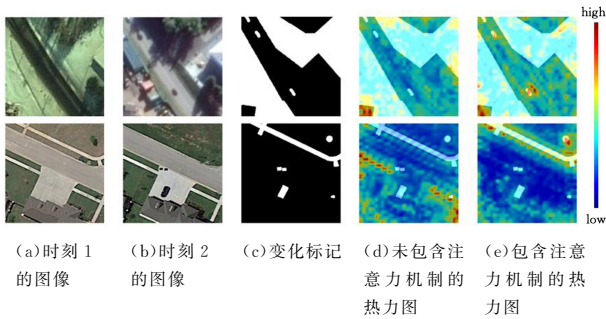


图4 FFAN 中间层激活情况的可视化图

Fig. 4 Visualization of FFAN middle layer activation

结束语 本文基于神经编码-融合-译码器框架,提出了一种端到端的遥感变化检测网络 FFAN,FFAN 的编码器设计为分别从双时相图像中提取特征。在此基础上,本文提出了用于双时相图像特征融合的基于注意力机制的变化聚合 CAA 模块。首先,双时相特征被拼接(即变化聚合),同时差分特征经由全局池化操作压缩;然后通过定义的两个全连接层来获得全局的变化信息,以供聚合的信息增强变化信息的表达。相比传统的针对单个图像的注意力机制,本文提出的 CAA 模块能够更充分地学习时空特征,并明显地增强传播中双时相特征之间的变化信息;最后,使用基于解码器中的金字塔融合特征生成变化图。在开源 RGB 变化检测数据集上的实验结果验证了 FFAN 的有效性,其在总体准确率、召回率和 F1 值方面均达到了最先进的水平。

然而,在编码器-融合-解码器框架下,不同的融合策略对变化检测性能有很大的影响,以差分特征作为主要特征的网络性能均低于基于特征和或特征拼接融合模型的结果。这一结果不同于传统使用差分图像/特征的变化检测方法。未来,我们将从模型解释的角度进一步研究变化聚合和变化注意力机制的有效性。

参考文献

[1] LIANG B,WENG Q. Assessing urban environmental quality change of Indianapolis, United States, by the remote sensing and GIS integration[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2010, 4(1): 43-55.

[2] LEI T,ZHANG Y,LV Z, et al. Landslide inventory mapping from bitemporal images using deep convolutional neural networks[J]. IEEE Geoscience and Remote Sensing Letters, 2019, 16(6): 982-986.

[3] LIU S,CHI M,ZOU Y, et al. Oil spill detection via multitemporal optical remote sensing images: A change detection perspective[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(3): 324-328.

[4] QUARMBY N A,CUSHNIE J L. Monitoring urban land cover changes at the urban fringe from SPOT HRV imagery in south-east England [J]. International Journal of Remote Sensing, 1989, 10(6): 953-963.

[5] HOWARTH P J,WICKWARE G M. Procedures for change detection using Landsat digital data[J]. International Journal of Remote Sensing, 1981, 2(3): 277-291.

[6] CARVALHO J O A,GUIMARÃES R F,GILLESPIE A R, et al. A new approach to change vector analysis using distance and similarity measures[J]. Remote Sensing, 2011, 3(11): 2473-2493.

[7] JIN S,SADER S A. Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances[J]. Remote sensing of Environment, 2005, 94(3): 364-372.

[8] NIELSEN A A,CONRADSEN K,SIMPSON J J. Multivariate alteration detection (MAD) and MAF postprocessing in multispectral, bitemporal image data: New approaches to change detection studies [J]. Remote Sensing of Environment, 1998, 64(1): 1-19.

[9] DENG J S,WANG K,DENG Y H, et al. PCA-based land-use change detection and analysis using multitemporal and multisensor satellite data[J]. International Journal of Remote Sensing, 2008, 29(16): 4823-4838.

[10] MANTERO P, MOSER G, SERPICO S B. Partially supervised classification of remote sensing images through SVM-based probability density estimation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 559-570.

[11] IM J,JENSEN J R. A change detection model based on neighborhood correlation image analysis and decision tree classification[J]. Remote Sensing of Environment, 2005, 99(3): 326-340.

[12] ZHAO J,GONG M,LIU J, et al. Deep learning to classify difference image for image change detection[C]// International Joint Conference on Neural Networks. IEEE, 2014: 411-417.

[13] ZHANG H,GONG M,ZHANG P, et al. Feature-level change detection using deep representation and feature change analysis for multispectral imagery [J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(11): 1666-1670.


[14] WANG Q,YUAN Z,DU Q, et al. GETNET: A general end-to-end 2-D CNN framework for hyperspectral image change detection[J]. IEEE Transactions on Geoscience and Remote Sensing,

2018,57(1):3-13.


- [15] EL AMIN A M, LIU Q, WANG Y. Convolutional neural network features based change detection in satellite images[C]// First International Workshop on Pattern Recognition. International Society for Optics and Photonics.2016.
- [16] DAUDT R C, LE SAUX B, BOULCH A. Fully convolutional siamese networks for change detection[C]// International Conference on Image Processing. IEEE, 2018;4063-4067.
- [17] LAN L, WU D, CHI M. Multi-temporal Change Detection based on Deep Semantic Segmentation Networks[C]// International Workshop on the Analysis of Multitemporal Remote Sensing Images. IEEE, 2019;1-4.
- [18] 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.
- [19] 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, 6(166):183-200.
- [20] PENG D, ZHANG Y, GUAN H. End-to-end change detection for high resolution satellite images using improved UNet++ [J]. Remote Sensing, 2019, 11(11):1382.
- [21] CHEN L, ZHANG D, LI P, et al. Change Detection of Remote Sensing Images Based on Attention Mechanism[J]. Computational Intelligence and Neuroscience, 2020, (1):1-11.
- [22] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]// Computer Vision and Pattern Recognition. IEEE, 2015;3431-3440.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Computer Vision and Pattern Recognition. IEEE, 2016;770-778.
- [24] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]// Winter Conference on Applications of Computer Vision. IEEE, 2018;1451-1460.
- [25] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//

Computer Vision and Pattern Recognition. IEEE, 2018; 7132-7141.

- [26] 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.
- [27] HE J, ZHANG C Q, LI X Z, et al. Survey of Research on Multimodal Fusion Technology for Deep Learning[J]. Computer Engineering, 2020, 46(5):1-11.
- [28] CHEN J, YUAN Z, PENG J, et al. DASNet: Dual attentive fully convolutional siamese networks for change detection of high resolution satellite images[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020, 14:1194-1206.
- [29] ZHOU B, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization[C]// Computer Vision and Pattern Recognition. IEEE, 2016;2921-2929.



LAN Ling-xiang, born in 1996, post-graduate. His main research interests include deep learning, remote sensing and change detection.



CHI Ming-min, born in 1976, Ph.D, associate professor. Her main research interests include data science, big data, and machine learning with applications to remote sensing, intelligent manufacturing, oil and gas exploration, computer vision and astronomy.

(责任编辑:李亚辉)