

基于双层多重编码结构的 GIS 遥感影像变化检测与异常识别模型设计

高 越¹, 董典伟²

(1. 马里兰大学帕克分校 社会与行为科学学院, 马里兰州 20742;

2. 北京京天威科技发展有限公司, 北京 100193)

摘要: 针对地理信息系统遥感变化检测异常识别中边界模糊、语义建模薄弱及异常区域响应不敏感的问题, 提出了一种基于 DLMC 的遥感影像变化检测与异常识别方法; 通过融合交叉编码、结构差分与多时相语义融合模块, 构建了递进式变化表征路径, 并引入显著性图与异常因子联合建模机制, 以增强对局部突变与局部非一致性区域的感知能力; 实验结果表明, DLMC 在 F_1 分数 (0.902)、Kappa 系数 (0.849) 与结构异常响应 (0.781) 上均取得最优性能, 能够有效提升遥感变化检测中的边界清晰度与异常识别能力。

关键词: 遥感影像变化检测; 多时相建模; 双层多重编码; GIS

Detection and Anomaly Recognition Model for GIS Remote Sensing Images Based on Dual-Layer Multi-Encoding Structure

GAO Yue¹, DONG Dianwei²

(1. College of Behavioral and Social Sciences, University of Maryland, College Park, MD 20742, USA;

2. Beijing Jingtianwei Technology Development Co., Ltd., Beijing 100193, China)

Abstract: To address the issues of boundary ambiguity, weak semantic modeling, and insensitivity to anomalous regions in change detection and anomaly identification in geographic information system-based remote sensing, a novel method based on dual-layer multi-encoding construction (DLMC) is proposed. By integrating cross-encoding, structural differences, and multi-temporal semantic fusion modules, a progressive change representation pathway is constructed. Furthermore, a joint modeling mechanism combining significant maps and anomaly factors is introduced, enhancing the perception capability for local abrupt changes and locally inconsistent regions. Experimental results demonstrate that the DLMC achieves optimal performances with an F_1 -score of 0.902, a Kappa coefficient of 0.849, and a structural anomaly response index of 0.781, effectively improving boundary clarity and anomaly detection accuracy in remote sensing image change detection.

Keywords: remote sensing image change detection; multi-temporal modeling; dual-layer multi-encoding; GIS

0 引言

随着遥感成像技术与地理信息系统 (GIS, geographic information system) 的迅猛发展, 基于遥感影像的地表变化检测与异常结构识别已成为国土监测、灾害评估、城市扩张分析等领域的关键研究任务^[1-2]。通过对不同时相遥感图像的对比分析, 能够有效捕捉地物演化趋势、建筑形态变化以及潜在的突发性事件, 从而为政府决策、应急管理与环境保护提供重要数据支持。

传统变化检测方法主要包括基于像素差值的阈值判别法^[3]以及基于统计学习的监督分类方法^[4]。尽管这些方法在特定条件下表现良好, 但往往依赖于大量标注数据、对地物光谱变化敏感, 且难以捕捉结构性、语义层级的深层次变化。此外, 传统方法缺乏对复杂边界、非规则变化区域以及局部异常事件的建模能力, 限制了其在实际遥感场景中的应用效果。

随着深度学习的发展, 越来越多的研究者将卷积神经网络 (CNN, convolutional neural network) 引入变

收稿日期: 2025-07-11; 修回日期: 2025-08-25。

作者简介: 高 越 (2001-), 男, 硕士研究生。

引用格式: 高 越, 董典伟. 基于双层多重编码结构的 GIS 遥感影像变化检测与异常识别模型设计[J]. 计算机测量与控制, 2026, 34(6): 55-61.

化检测任务中。文献 [5] 将两幅遥感图像堆叠后送入全卷积网络进行特征提取, 实现端到端的变化检测。文献 [6] 提出 SNUNet-CD 模型, 采用孪生 U-Net 结构分别提取两时相图像特征, 并通过跳跃连接实现多尺度特征融合, 显著提升了检测精度与边界清晰度。文献 [7] 在此基础上进一步提出 BIT-CD 模型, 引入边界感知分支与注意力机制, 使得模型对微小结构变化更加敏感。Transformer 结构在遥感领域的引入也推动了变化检测模型的升级。文献 [8] 提出了 ChangeFormer 模型, 将双时相图像特征分别送入编码器, 通过交叉注意力模块实现深层语义建模, 显著提高了长距离变化模式的捕捉能力。此外, 文献 [9] 设计了 CLNet 模型, 通过引入跨层通道注意机制, 强化了浅层边缘特征与深层语义特征的融合, 进一步提高了边界检测的精度。

然而, 现有深度模型仍面临一些挑战。1) 在多尺度变化区域中, 模型往往难以保持对细粒度结构的连续感知, 尤其在处理高频纹理或边缘模糊的区域时易产生虚警或漏检; 2) 当前方法大多专注于“是否变化”的二值判别, 缺乏对局部非一致性区域(如突发建设、灾害破坏等)进行异常响应与解释建模的能力; 3) 多时相遥感图像在获取过程中易受大气干扰、姿态偏差及光照变化等因素影响, 导致配准误差和语义偏移, 这对变化检测模型的鲁棒性提出了更高要求。

为应对上述问题, 近年来有研究尝试将语义显著性机制与多时相融合策略结合, 以提高模型对变化区域的感知强度。文献 [10] 引入基于显著图的注意力控制机制, 引导模型聚焦于潜在变化热点区域; 文献 [11] 提出语义引导多时相特征聚合网络, 在提高检测精度的同时增强对异常事件的响应能力。此外, 文献 [12] 提出了一种基于多阶段显著性引导的变化检测框架, 在特征提取过程中逐层引入语义显著图以增强对细粒度变化的关注, 从而有效缓解了边界模糊与小目标漏检的问题。文献 [13] 设计了融合空间位置感知的 Transformer 模型, 通过引入位置编码注意力机制提升模型对遥感图像中结构性区域变化的建模能力。文献 [14] 则采用多视

角图卷积网络对多时相遥感图像进行结构建模与语义对齐, 显著提升了模型在复杂城市场景下对局部突变和形态异构区域的识别准确率。

尽管上述模型在整体性能上取得了显著提升, 但在处理具有结构复杂性或变化不显著的遥感图像时, 仍存在诸多不足。一方面, 现有方法大多采用并行提取与简单差分策略, 未能充分建模两时相间的语义交互关系; 另一方面, 在面对微尺度、突发性或非对称结构变化时, 模型往往缺乏足够的鲁棒性和异常响应能力。为此, 本文提出了一种基于双层多重编码结构(DLMC, double-layer multi-coding)的遥感变化检测与异常识别模型, 以实现变化特征的逐层提炼与异常响应的精准建模。

1 模型设计

1.1 整体架构

图 1 为基于 DLMC 的遥感影像变化检测模型的整体框架。该模型主要由 3 部分构成: 多时相遥感影像输入、递进式双层编码模块堆叠、以及变化显著性与异常识别输出。

模型首先对两个时相的遥感影像进行统一预处理与特征嵌入, 生成初始空间语义特征图。随后, 输入特征进入由若干 DLMC 单元堆叠而成的主干结构, 每一 DLMC 单元内部依次包含交叉编码、差分编码和多时相融合 3 个功能模块。交叉编码用于捕捉不同时间节点之间的语义互补关系, 提升变化建模的上下文一致性; 差分编码显式刻画影像间的结构性差异, 并通过非线性映射增强对细粒度变化的敏感性; 多时相融合模块则对当前阶段的差异特征与上一阶段的累积特征进行整合, 实现语义层级的逐步增强与深层表示的渐进优化。多层 DLMC 的串联结构构建了一个由浅入深的变化特征提取路径, 最终生成的高维融合特征输入至变化显著性建模与异常因子分析模块, 输出空间分布图用于变化区域判别与异常检测。

1.2 GIS 遥感影像的特征嵌入

受制于影像获取条件、传感器参数及地物变化的多




图 1 模型整体架构

样性, 不同时间节点的遥感图像在空间对齐、光谱一致性与语义表达方面存在显著差异。因此, 本文首先构建一套系统化的预处理与特征嵌入流程, 为后续的双层多重编码结构提供一致性输入。

GIS 遥感影像的预处理流程主要包括几何校正、辐射归一化、大气校正与云遮掩处理等步骤^[15-16]。具体而言, 对于给定的两时相遥感图像 $I^{(t_1)}$ 与 $I^{(t_2)}$, 首先需实现空间配准操作, 以确保图像对应像素在空间上具有一致的地理参考坐标系。设影像尺寸为 $H \times W$, 图像对经过配准后满足如下关系:

$$I^{(t_1)}(x, y) \cong I^{(t_2)}(x + \Delta x, y + \Delta y) \quad \forall (x, y) \in \{1, H[\times]1, W\} \quad (1)$$

其中: $(\Delta x, \Delta y)$ 为微小的空间位移误差, 通过基于相位相关的频域配准进一步最小化该误差。辐射归一化通过将多时相影像的像素值调整至统一尺度, 消除光照、季节等非地物因素带来的差异。采用直方图匹配^[17-18]对参考影像与目标影像的光谱分布进行一致性校正:

$$I_{\text{norm}}^{(t_2)}(x, y) = a \cdot I^{(t_2)}(x, y) + b \quad (2)$$

$I_{\text{norm}}^{(t_2)}(x, y)$ 表示归一化后的目标影像在时相 t_2 下的像素值, 位置为 (x, y) , 其中系数 a, b 可通过最小化以下目标函数获得:

$$\min_{a, b} \sum_{x, y} [a \cdot I^{(t_2)}(x, y) + b - I^{(t_1)}(x, y)]^2 \quad (3)$$

此外, 云层、阴影区域等遮挡信息通过 Fmask 算法进行掩膜处理, 保证输入图像的有效性。

为进一步提升后续变化建模的准确性, 引入基于通道注意力机制的特征对齐模块^[19-20], 解决因地物语义偏移所导致的编码失配问题。设两个时相的特征图为 $F^{(t_1)}$ 与 $F^{(t_2)}$, 引入通道加权系数 γ_c , 其由全局平均池化获取:

$$\gamma_c = \sigma\{W_2 \cdot \text{ReLU}[W_1 \cdot \text{GAP}(F_c)]\} \quad (4)$$

其中: σ 表示 Sigmoid 激活函数, 用于将加权系数限制在 0 和 1 之间。 W_1, W_2 为训练得到的权重矩阵, 用于对特征进行线性变换。

接着调整特征图的通道 $F_c^{(t)}$ 的权重, 实现语义对齐:

$$F_c'^{(t)} = \gamma_c \cdot F_c^{(t)} \quad (5)$$

经过上述预处理与特征嵌入, 得到统一尺度、语义对齐的双时相遥感影像特征表示, 为后续的 DLMC 结构提供输入基础。

1.3 双层多重编码模块

为有效建模遥感影像多时相间的变化特征及潜在异常信息, 本文设计了一种双层多重编码结构作为变化检测主干模块。该结构以时间序列遥感影像的深度特征为输入, 依托于交叉编码、差分建模与多时相融合机制, 逐层递进地挖掘跨时空的语义差异与结构性变异。DLMC 模块总体采用堆叠式递归结构, 由若干个结构

相同的编码单元串联构成。每一单元中包含 3 个关键子模块: 交叉编码、差分编码以及多时相融合。在第 n 层中, 设输入特征张量为 $F_{t_1}^{(n)}$ 与 $F_{t_2}^{(n)}$, 分别对应两个时相的嵌入特征, DLMC 模块通过如下步骤依次完成特征变换:

首先, 交叉编码模块利用注意力机制实现时相间的信息互导与语义互补, 避免单一特征提取路径造成的局部信息缺失。其核心思想为在编码过程中, 将一个时相的特征作为上下文信息引入另一个时相的表示建构中, 定义如下:

$$\begin{aligned} \hat{F}_{t_1}^{(n)} &= \text{CrossEncode}[F_{t_1}^{(n)}, F_{t_2}^{(n)}] \\ \hat{F}_{t_2}^{(n)} &= \text{CrossEncode}[F_{t_2}^{(n)}, F_{t_1}^{(n)}] \end{aligned} \quad (6)$$

交叉编码操作可以具体表示为通道注意力引导下的特征重构:

$$\hat{F}_t^{(n)} = F_t^{(n)} + \text{MLP}\{\sigma[F_t^{(n)} \cdot \text{Softmax}(F_{t'}^{(n)})^T]\} \quad (7)$$

其中: $F_{t'}^{(n)}$ 表示对方时相特征, σ 为激活函数, MLP 为多层感知机。

随后, 差分编码模块用于对两个时相间的特征差异进行建模, 通过高阶变换增强局部结构变化的表达能力。传统的变化检测方法多采用简单的像素差分, 然而这在复杂地物环境中容易受到纹理、光照等干扰因素影响。为此, 本文引入非线性残差差分编码结构:

$$\Delta F^{(n)} = \varphi[\hat{F}_{t_1}^{(n)} - \hat{F}_{t_2}^{(n)}] \quad (8)$$

其中: $\varphi(\cdot)$ 为带参数的非线性变换函数, 通过卷积一归一化一激活操作实现。此外, 为强化模型对空间变化模式的捕捉能力, 还引入结构感知差分核:

$$\Delta F_{\text{structure}}^{(n)} = \sum_{i=1}^K w_i \cdot |\nabla_i \hat{F}_{t_1}^{(n)} - \nabla_i \hat{F}_{t_2}^{(n)}| \quad (9)$$

其中: ∇_i 表示第 i 个方向的空间梯度算子, K 为方向数量, w_i 为方向加权系数。在完成交叉编码与差分编码后, 模型进入多时相融合阶段, 即将当前阶段的变化特征与上一阶段的高阶特征进行多尺度信息融合, 实现变化模式的递进增强。设第 n 层的融合输出为 $F_{\text{fusion}}^{(n)}$, 则有:

$$F_{\text{fusion}}^{(n)} = \text{Fusion}[\Delta F^{(n)}, F_{\text{fusion}}^{(n-1)}] \quad (10)$$

融合函数采用加权残差连接方式实现跨层特征传递:

$$F_{\text{fusion}}^{(n)} = \alpha \cdot \Delta F^{(n)} + \beta \cdot F_{\text{fusion}}^{(n-1)} + \gamma \cdot \text{Conv}\{[\Delta F^{(n)} \parallel F_{\text{fusion}}^{(n-1)}]\} \quad (11)$$

其中: α, β, γ 为可学习融合权重, $\parallel$ 表示通道维度拼接操作。

通过上述 DLMC 结构的迭代堆叠, 每一层均在时空维度上提炼出更加鲁棒的变化表示。最终的融合特征将传递至变化检测与异常识别模块。

1.4 多阶段编码级联与异常识别机制

在完成单个 DLMC 单元内部的交叉建模、差分提

取与融合增强后,仅依赖浅层单次编码往往难以充分捕捉遥感影像中跨时间尺度的深层语义变化,尤其在存在地物缓变、区域异质性强或扰动环境复杂的情形下,浅层变化特征存在表达不充分、边界模糊等问题。为此,本文进一步将 DLMC 模块以递进方式进行多级串联,通过多阶段编码结构实现变化表示的层级提炼与结构重构。与此同时,在变化响应输出阶段引入显著性建模与异常识别机制,以增强模型对非典型变化、突发事件或局部异常行为的感知能力。

在前述的 DLMC 模块中,每一级编码单元都会对输入的两时相特征进行交叉建模、差分变换与多时相融合,得到当前阶段的变化特征表示。设 DLMC 总共迭代 N 层,则最终的变化特征可表示为:

$$F_{\text{final}} = F_{\text{fusion}}^{(N)} \in \mathbb{R}^{C \times H \times W} \quad (12)$$

该张量保留了由浅入深提炼出的语义差异与空间变化信息,为进一步实现异常检测功能,本文引入一种融合变化显著性度量与残差增强机制的检测策略。

首先,定义一个变化显著性映射函数,用于衡量每一空间位置处在两个时相间是否存在结构性或语义性差异。具体而言,针对融合特征 F_{final} ,在空间维度上施加通道加权注意机制,得到变化响应图 $S(x, y)$:

$$S(x, y) = \sum_{c=1}^C \omega_c \cdot |F_{\text{final}}(c, x, y)| \quad (13)$$

其中: ω_c 为第 c 通道的重要性权重,可通过 Sigmoid 激活后的多层感知机学习获得。该响应图反映了图像每个像素点在编码后特征空间中的变化强度,数值越高代表变化越显著。

基于变化响应图 $S(x, y)$,进一步引入异常检测模块,识别变化模式异常、在训练分布中罕见或空间一致性较差的区域。此模块采用统计残差建模方法^[21],即将变化特征与其时空邻域中的均值差异进行归一化分析,定义异常因子 $A(x, y)$ 为:

$$A(x, y) = \frac{|S(x, y) - \mu_{N(x, y)}|}{\sigma_{N(x, y)} + \epsilon} \quad (14)$$

其中: $\mu_{N(x, y)}$ 和 $\sigma_{N(x, y)}$ 分别为像素点 (x, y) 在其局部邻域 $N(x, y)$ 上的变化响应均值与标准差, ϵ 为避免除零的小常数。异常因子越高,代表该位置在局部区域中具有越明显的非一致性,可能代表异常结构或突发事件。

此外,为提升异常检测对复杂边界结构的表达能力,本文还引入多尺度空洞卷积残差分支,将原始差分编码模块中的输出 $\Delta F^{(n)}$ 与局部纹理梯度进行融合,增强模型对非对称边缘、微小变化的识别能力。融合公式如下:

$$\tilde{\Delta F}^{(n)} = \text{Conv}_{\text{dilated}}^{(r)}[F^{(n)}] + \text{EdgeGrad}[F_{t_1}^{(n)}, F_{t_2}^{(n)}] \quad (15)$$

其中: $\text{EdgeGrad}(\cdot)$ 表示图像边缘梯度差分操作,用于提取结构边界的变动性; $\text{Conv}_{\text{dilated}}^{(r)}$ 表示扩张率为 r

的空洞卷积操作,增大感受野以融合上下文异常信息。最终,变化检测与异常识别的决策输出 $M(x, y)$ 通过如下形式综合表达:

$$M(x, y) = \sigma\{W_2 \cdot \text{ReLU}\{W_1 \cdot [S(x, y) \parallel (x, y)]\}\} \quad (16)$$

其中: $[\cdot \parallel \cdot]$ 表示特征拼接, W_1, W_2 为全连接参数, σ 为 Sigmoid 函数,用于输出变化概率图。该图用于二值化的变化检测图(通过设定阈值 τ ,令 $M(x, y) > \tau$ 处为变化区域)以及变化强度排序。

2 实验与分析

2.1 实验设置

本文所采用的实验平台包括: Ubuntu 22.04 操作系统, Intel Xeon Gold 6226R 处理器, NVIDIA RTX A6000 GPU (48 GB 显存), TensorFlow 2.13 框架。所有模型均采用 Adam 优化器,初始学习率设为 0.001,批大小为 8,并引入 Cosine Annealing 策略进行动态调整,最小学习率为 1×10^{-5} ,训练总轮数上限设为 200 轮。为防止过拟合问题,训练过程中采用早停机制(Early Stopping):若验证集 F_1 分数在连续 15 个 epoch 内无显著提升(提升幅度小于 0.002),则提前终止训练并恢复性能最优模型权重。损失函数方面,为兼顾变化显著性检测与异常响应建模,本文联合采用二值交叉熵损失与结构一致性损失。

实验数据集包括以下 3 类: 1) LEVIR-CD^[22]: 包含 1 024 对遥感图像对,每幅图像的尺寸为 512×512 ,主要涵盖城市区域中的建筑物变化。图像对中的变化类型较为明确,通常包括建筑物的新增或拆除,以及建筑物周围环境的变化; 2) WHU-CD^[23]: 由武汉大学提供,覆盖大尺度非结构性变化区域(如农田、水体等),图像噪声较强,适用于评估模型在复杂背景下的鲁棒性; 3) GF-Change-GIS(本文自建): 选取中国若干城市典型 GIS 区域,手工标注关键变化区域与异常结构,图像分辨率为 0.5 m/pixel,支持精细级变化检测与异常点定位。

2.2 超参数设置

图 2 展示了 DLMC 模型在不同正则强度 λ 条件下,超参数组合对 F_1 性能指标的三维响应曲面变化趋势,其中横轴为 DLMC 模块的堆叠层数 N 与空洞卷积的扩张率 r 。

随着 DLMC 层数的增加,模型性能整体上升,在 $N=3$ 时达到性能峰值;继续增加层数至 $N=4$ 后,性能略有下降,可能由于过深结构导致梯度消散与特征冗余。同时,扩张率 r 在 2~4 之间呈现良好响应,若过小则局部感受野不足,若过大则造成边缘信息扩散不稳定。正则系数 λ 的分析显示,模型在 $\lambda=0.5$ 时显著性




图 2 参数敏感性分析

学习最为稳定, 此时网络对通道注意的权重分配最为平衡, 有效避免了过拟合风险。

综上分析, 本文最终选取的最优超参数组合为: DLMC 层数 $N=3$ 、空洞卷积扩张率 $r=4$ 、正则强度 $\lambda=0.5$ 。后续所有实验均在此参数配置下进行。

2.3 模型对比结果

为验证 DLMC 模型的性能优势, 本文选取 5 种代表性变化检测方法作为对比对象。FC-EF^[5]为早期特征融合模型, 通过全卷积网络直接学习变化模式; SNU-Net-CD^[6]采用孪生嵌套 U-Net 结构强化多尺度语义对齐; BIT-CD^[7]结合了边界感知机制与 Transformer 结构; ChangeFormer^[8]为典型的 Transformer 检测框架, 具备良好的上下文建模能力; CLNet^[9]引入了跨层注意机制, 强化浅层边缘与深层语义特征融合。模型对比结果如表 1 所示。

表 1 模型在不同遥感数据集上的性能对比

模型名称	F_1 分数 (LEVIR-CD)	Kappa 系数 (WHU-CD)	SAR(GF- Change-GIS)
FC-EF	0.829	0.728	0.645
SNUNet-CD	0.878	0.802	0.703
BIT-CD	0.885	0.818	0.715
ChangeFormer	0.891	0.829	0.729
CLNet	0.867	0.796	0.691
Ours(DLMC)	0.902	0.849	0.781

如表 1 所示, 本文提出的 DLMC 模型在 3 个关键评价指标上均优于现有主流变化检测模型。具体而言, 在 LEVIR-CD 数据集中, 其 F_1 分数达到了 0.902, 相比 FC-EF (0.829)、SNUNet-CD (0.878) 与 ChangeFormer (0.891) 分别提高了 8.8%、2.7% 与 1.2%, 说明 DLMC 在规则地物变化识别方面具有更强的端到端表征能力, 具体而言, 交叉编码模块强化了双时相语义互导, 缓解了配准误差造成的语义偏移; 结构差分模块引入多方向梯度增强与非线性映射, 使得对边界细节变化的响应更敏锐, 提升了微尺度结构变化的检测能

力; 而多时相融合模块通过残差连接优化了深浅特征整合效果, 提升了整体上下文一致性表达。在 WHU-CD 数据集中, DLMC 的 Kappa 系数为 0.849, 显著优于 BIT-CD (0.818) 与 CLNet (0.796), 表明其在复杂背景与非均质区域中的变化一致性判别能力更为突出。值得注意的是, 在 GF-Change-GIS 数据集上引入的结构异常响应指标 (SAR, structural anomaly response) 上, DLMC 表现尤为优异, SAR 值高达 0.781, 显著超过 SNU-Net-CD (0.703) 与 ChangeFormer (0.729)。这一结果表明 DLMC 不仅能够有效捕捉大尺度地物变化, 还具备出色的微尺度结构异常感知能力, 尤其适用于实际 GIS 遥感应用中对突发、细粒度、非对称变化区域的检测需求。

2.4 消融实验

图 3 展示了 DLMC 模型在不同结构变体下的消融实验结果, 分别针对 LEVIR-CD、WHU-CD 和 GF-Change-GIS 数据集, 评估其对 F_1 分数、Kappa 系数和 SAR 的影响。

本文在设计各结构变体时, 仅对目标模块进行单独修改, 其余模块结构、超参数设置、训练策略与损失函数均与完整 DLMC 模型保持一致。

总体来看, 完整 DLMC 模型在各项指标上均取得最优性能, 表明其在遥感变化检测与异常识别任务中的结构合理性及表达能力。如图 3 (a) 所示, 在 LEVIR-CD 数据集上, 完整 DLMC 模型的 F_1 分数达到 0.902, 显著优于去除交叉编码模块 (w/o Cross) 后的 0.869 与去除差分建模模块 (w/o Diff) 后的 0.878, 表明 DLMC 在提取规则地物变化方面具备更高的语义一致性建模能力。如图 3 (b) 所示, WHU-CD 数据集中, 完整模型在 Kappa 指标上取得 0.849, 优于去除融合模块 (0.835) 与注意力模块 (0.843), 进一步说明 DLMC 具备良好的鲁棒性与上下文感知能力, 适应非结构性变化区域的复杂判别需求。而在 GF-Change-GIS 数据集上, 完整模型在 SAR 指标上显著领先, 达到




图3 不同模块在三类遥感数据集上的消融实验结果

0.781, 相比于 w/o Cross (0.735) 与 w/o Diff (0.747) 均有明显提升, 验证了 DLMLC 对微尺度结构异常与突发变化的高度敏感性, 如图 3 (c) 所示。

2.5 变化检测预测结果

为进一步验证各模型在遥感变化检测任务中的可靠性与误差分布特性, 图 4 展示了 FC-EF、ChangeFormer 与本文提出的 DLMLC 模型在代表性样本上的误差热力图。




图4 模型变化检测误差热力图对比

从图中可以观察到, FC-EF 模型存在大面积的误检区域, 模型对变化区域的边界识别不准确, 容易受背景纹理的影响, 导致误检区域的扩展。此外, 图像中的光照变化也对模型的表现产生了负面影响, 导致边界不清晰和变化区域的错误识别。

相比之下, ChangeFormer 模型在误检控制方面有所改善, 误检区域有所减少, 但仍然存在多个不连续的漏检片段, 尤其是在变化边界的表达上仍然不够清晰, 导致一些变化区域未能被准确捕捉。尽管其对变化区域的响应有所增强, 但仍缺乏足够的细致度, 尤其是在处理复杂背景或弱变化区域时, 容易出现不连续的漏检情况。与此相比, DLMLC 模型在误差热力图中的表现显著优于前两者。该模型的误检区域高度集中且边界响应精准, 几乎没有出现大面积的误检。进一步观察图 4 中变化边界区域的误差分布可发现, DLMLC 模型在边界判别上展现出更高的一致性与精度。相较于 FC-EF 在边界处产生大量连续性误检, 以及 ChangeFormer 在弱边界区的局部漏检现象, DLMLC 所预测的边界响应更加贴合真实变化轮廓, 且误差主要集中在孤立像素点, 未形成连片错误。这种优势主要得益于 DLMLC 引入的结构差分编码与多阶段融合机制, 使得模型在特征空间

中对边界处的微小结构变化具有更强的辨识能力。该结果充分验证了 DLMLC 结构中多阶段差分建模与交叉编码机制在提升变化检测精度、减少误差和提升判别一致性方面的有效性, 尤其是在复杂背景下的表现。

3 结束语

本文提出了一种用于遥感影像结构变化检测与异常识别的 DLMLC 模型。该方法通过引入交叉编码机制, 有效解决了多时相图像之间语义偏移所带来的特征匹配不一致问题; 结构差分模块增强了模型对微小结构变化的辨识能力, 提升了变化边界的准确性; 多时相融合策略实现了变化特征的递进式建模, 有效缓解了单阶段建模对复杂演化模式的适应不足。此外, DLMLC 在输出阶段引入显著性响应图与异常因子联合建模方法, 强化了模型对局部突变与非对称结构的异常感知能力。整体结构设计有针对性地解决了现有模型在语义交互、结构差异建模和异常区域检测方面的短板, 展现出良好的性能稳定性与适应性。

未来, 模型可以通过轻量化设计和多模态数据融合提高效率, 扩展在灾害监测、城市规划和环境保护等实际应用中的适应性。结合高分辨率遥感图像和智能化处理, DLMLC 将更好地支持精确农业、城市监控等领域, 推动遥感技术向自动化和智能化发展。

参考文献:

- [1] 郑宗生, 高 萌, 周文晔, 等. 基于样本迭代优化策略的密集连接多尺度土地覆盖语义分割 [J]. 自然资源遥感, 2025, 37 (2): 11-18.
- [2] 李明圆. 基于遥感数据的建筑工程变形研究 [J]. 北斗与空间信息应用技术, 2025 (2): 13-15.
- [3] 赵子昕, 赫佳妮. 基于超像素的 CD-BS 遥感影像变化检测方法 [J]. 科学技术创新, 2021 (22): 44-45.
- [4] 梁锦涛, 陈 超, 张自力, 等. 一种融合指数与主成分分量的随机森林遥感图像分类方法 [J]. 自然资源遥感, 2023, 35 (3): 35-42.

- [5] LI S, HUO L. Remote sensing image change detection based on fully convolutional network with pyramid attention [C] //2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS, IEEE, 2021: 4352–4355.
- [6] WATANABE Y, KAMIYA T. Detection of temporal changes from satellite images based on improved SNUNet-CD [C] //2024 Joint 13th International Conference on Soft Computing and Intelligent Systems and 25th International Symposium on Advanced Intelligent Systems (SCIS&ISIS), IEEE, 2024: 1–4.
- [7] 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.
- [8] BANDARA W G C, PATEL V M. A transformer-based Siamese network for change detection [C] //IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium, IEEE, 2022: 207–210.
- [9] ZHENG Z, WAN Y, ZHANG Y, 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.
- [10] 史再峰, 康 泰, 王云峰, 等. 基于显著性双流分层感知的 NR-IQA 方法 [J]. 天津大学学报 (自然科学与工程技术版), 2025, 58 (2): 189–198.
- [11] 冯星宇, 朱灵龙, 张永宏, 等. 基于多边特征引导聚合网络的变化检测算法 [J]. 计算机工程与应用, 2025, 61 (3): 264–274.
- [12] QIN J, GU C, YU J, et al. Multilevel saliency-guided self-supervised learning for image anomaly detection [J]. Signal, Image and Video Processing, 2024, 18 (8): 6339–6351.
- [13] 吴 菲, 陈嘉诚, 杨 俊, 等. 基于自适应双域注意力网络的遥感图像重建 [J]. 光电工程, 2025, 52 (4): 91–106.
- [14] GUAN R, TU W, WANG S, et al. Structure-adaptive multi-view graph clustering for remote sensing data [C] //Proceedings of the AAAI Conference on Artificial Intelligence, 2025, 39 (16): 16933–16941.
- [15] MENG Q. Remote sensing data preprocessing technology [M] //Remote Sensing of Urban Green Space, Singapore: Springer Nature Singapore, 2023: 9–26.
- [16] APOSTOLOPOULOS D, NIKOLAKOPOULOS K. A review and meta-analysis of remote sensing data, GIS methods, materials and indices used for monitoring the coastline evolution over the last twenty years [J]. European Journal of Remote Sensing, 2021, 54 (1): 240–265.
- [17] 刘超群, 余顺超, 顾祝军, 等. 一种基于影像直方图匹配的 Brovey 融合方法 [J]. 测绘通报, 2025 (4): 139–144.
- [18] WANG X, JIANG L, WANG F, et al. Disparity refinement for stereo matching of high-resolution remote sensing images based on Gis data [J]. Remote Sensing, 2024, 16 (3): 487.
- [19] 何 强, 向寺钦, 霍连志, 等. 基于多分支特征对齐的遥感图像旋转目标检测网络 [J]. 河北师范大学学报 (自然科学版), 2023, 47 (6): 541–552.
- [20] ZHANG Y, LAN C, ZHANG H, et al. Multimodal remote sensing image matching via learning features and attention mechanism [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 1–20.
- [21] LU Y, LI H, ZHANG C, et al. Object-based semi-supervised spatial attention residual UNet for urban high-resolution remote sensing image classification [J]. Remote Sensing, 2024, 16 (8): 1444.
- [22] 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.
- [23] PAN F, SHIN I, RAMEAU F, et al. Unsupervised intra-domain adaptation for semantic segmentation through self-supervision [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 3764–3773.
- [10] HAMACHI S, SUPITAYAKUL P, YÜCEL Z, et al. Investigation of the relation between task engagement and eye gaze [C] // IEEE 13th International Congress on Advanced Applied Informatics Winter (IIAI-AAI-Winter), 2022: 163–167.
- [11] GOLDBERG P, SUMER Ö, STÜRMER K, et al. Attentive or not? Toward a machine learning approach to assessing students' visible engagement in classroom instruction [J]. Educational Psychology Review, 2021, 33: 27–49.
- [12] LI H, WANG B, CHENG Y, et al. DSFNet: Dual space fusion network for occlusion-robust 3D dense face alignment [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 4531–4540.
- [13] GAO F, LI S, LU S F. How frontal is a face? Quantitative estimation of face pose based on CNN and geometric projection [J]. Neural Computing and Applications, 2021, 33 (8): 3035–3051.

(上接第 54 页)