

基于深度学习的双时相光学遥感图像变化检测方法综述

史振威, 张浩田, 郭 涵, 邹征夏

(北京航空航天大学宇航学院, 北京 100191)

摘 要: 双时相光学遥感图像变化检测任务是遥感领域的一个重要分支,旨在通过分析同一区域、不同时刻获取的遥感图像,刻画该区域的地表变化情况。随着遥感图像数据规模的持续增长以及深度学习技术的飞速发展,该领域正经历着快速迭代与演进。在此背景下,本文以时间轴为主线,系统性地梳理了近20年来基于深度学习的双时相光学遥感图像变化检测方法,对比分析了其在主流数据集上的性能与效率,并对相关公开数据集与评测指标进行总结。同时,对变化检测任务的整体处理流程进行拆分,详细介绍了各个环节的进展。最后,对该领域的未来研究方向进行了展望,希望为后续的相关研究提供参考。

关键词: 变化检测;双时相遥感图像;深度学习;综述文献

中图分类号: TP391.4 **文献标志码:** A

引用格式: 史振威,张浩田,郭涵,等.基于深度学习的双时相光学遥感图像变化检测方法综述[J].数据采集与处理,2026,41(2):566-591. SHI Zhenwei, ZHANG Haotian, GUO Han, et al. A review of deep learning-based change detection methods for bi-temporal optical remote sensing images[J]. Journal of Data Acquisition and Processing, 2026, 41(2):566-591.

引 言

遥感图像变化检测旨在根据同一区域不同时刻获取的遥感图像进行分析,识别该区域在该时间段内的地表变化情况。作为遥感领域的一项基础性任务,遥感图像变化检测对变化描述、时空演化解译以及智能体解译等方面具有显著的共性支撑作用,其输出结果可以为高层次时序建模与语义推理提供关键先验信息。在应用层面,该技术在土地资源规划^[1-5]、生态环境保护^[6-10]、突发灾害评估^[11-12]、城市化进程与新增建筑监测^[13]等关键领域具有广泛的应用前景,可以为相关响应部门提供较为精确的引导,摆脱对实际应用中传统目视解译和实地勘测的过度依赖。

遥感图像变化检测的研究可以追溯至1977年,Weismiller等^[14]通过差分的方式对沿海地区的遥感图像进行分析,由此开始打开了变化检测领域的大门。此后,各类算法竞相涌现,涵盖了从经典的图像差分法^[6]、图像比例法^[15]、主成分分析法^[16]、变化向量分析法^[17],到基于机器学习的K近邻^[18]、支持向量机^[19-20]、人工神经网络^[21]等多种方法。然而,随着高空间分辨率对地观测时代的到来,光学遥感数据呈现爆发式增长。高分辨率光学影像在提供丰富地物细节与精细边缘特征的同时,也对算法的鲁棒性提出了更高要求。传统方法在应对高分辨率图像时,逐渐暴露出适应性差、特征表达能力不足等问题,难以满足当前高精度监测的需求。

深度学习技术的出现为克服上述技术瓶颈提供了新的范式。通过在大量标注的双时相遥感数据

集上进行监督学习,驱使深度学习模型学习高分辨率光学遥感图像更丰富的深层特征表示,从而显著提升变化检测的精度与鲁棒性。随着深度学习技术的不断发展,在其不断为变化检测领域注入新活力的同时也吸引了大量研究者沿这一方向进行探索。如图1所示(Web of science 检索),利用深度学习开展变化检测的研究文献量呈逐年攀升趋势,充分表明该方向已成为当前遥感领域的前沿研究热点。

尽管近年来光学遥感图像变化检测方法不断涌现,整体性能持续提升,但其仍面临诸多挑战,包括但不限于以下方面。例如,双时相光学遥感图像中普遍存在光照变化、视角差异等成像条件的变化,使得判别性特征表示难以获取;此外,变化检测任务中样本类别高度不平衡,模型训练过程中容易产生类别偏置,从而增加变化目标的漏检风险等。因此,该领域仍需开展深入的研究。

近年来已有一些学者对变化检测领域进行了综述^[22-29],但其大多着眼于技术模块,而对技术演化过程的梳理相对匮乏。鉴于此,本文旨在从多角度对光学遥感图像变化检测技术进行总结,凸显其在技术层面的演变过程。具体而言,以技术演化的时间线为主轴,探究各阶段关键技术及前沿趋势,同时系统性地介绍数据集与评测指标。

1 变化检测任务发展历程

本节旨在以时间轴为主线,系统梳理变化检测任务从二元变化检测向语义变化检测的技术演进,如图2所示,并对后续所介绍的变化检测方法按照图2中的解构方式进行分析与阐述(详见第2节)。同时对该发展脉络中具有里程碑意义的研究工作展开叙述,图3进一步以时间为线索呈现了不同方法的演进,有助于读者从纵向发展视角把握变化检测方法的演进逻辑。

1.1 二元和语义变化检测任务定义

二元变化检测旨在通过训练模型,以二值掩码的形式提取感兴趣区域的变化,是该领域最具代表性且研究最为广泛的任务,其一般性定义如下:给定已配准的双时相光学遥感图像 $I_1 \in \mathbf{R}^{C \times H \times W}$ 和 $I_2 \in \mathbf{R}^{C \times H \times W}$,其中 C, H 与 W 分别表示输入图像的通道数、高度与宽度。二元变化检测的目标在于构建映射函数以获取与




图1 基于深度学习的光学遥感图像变化检测方法发文章量(Web of science 检索)

Fig.1 Number of publications on deep learning-based change detection methods for optical remote sensing images (Source: Web of science)

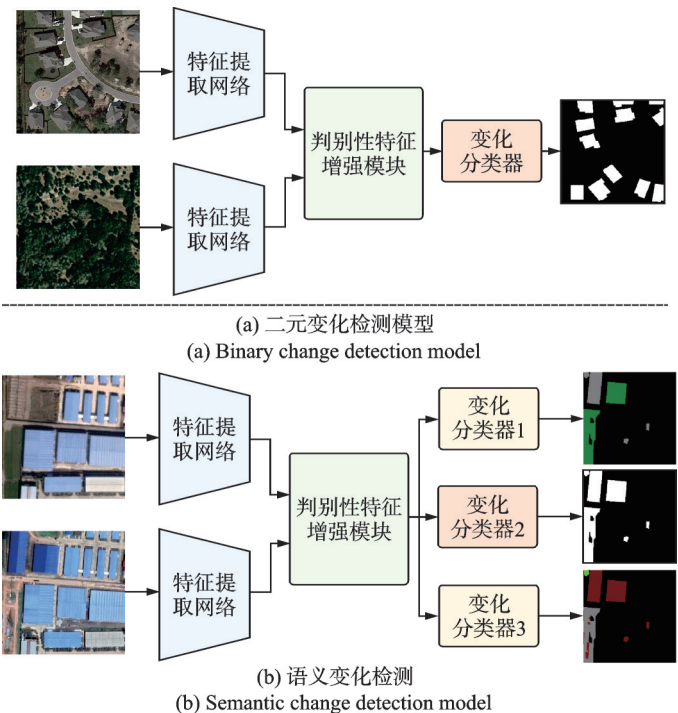


图2 二元和语义变化检测典型模型

Fig.2 Typical models for binary and semantic change detection

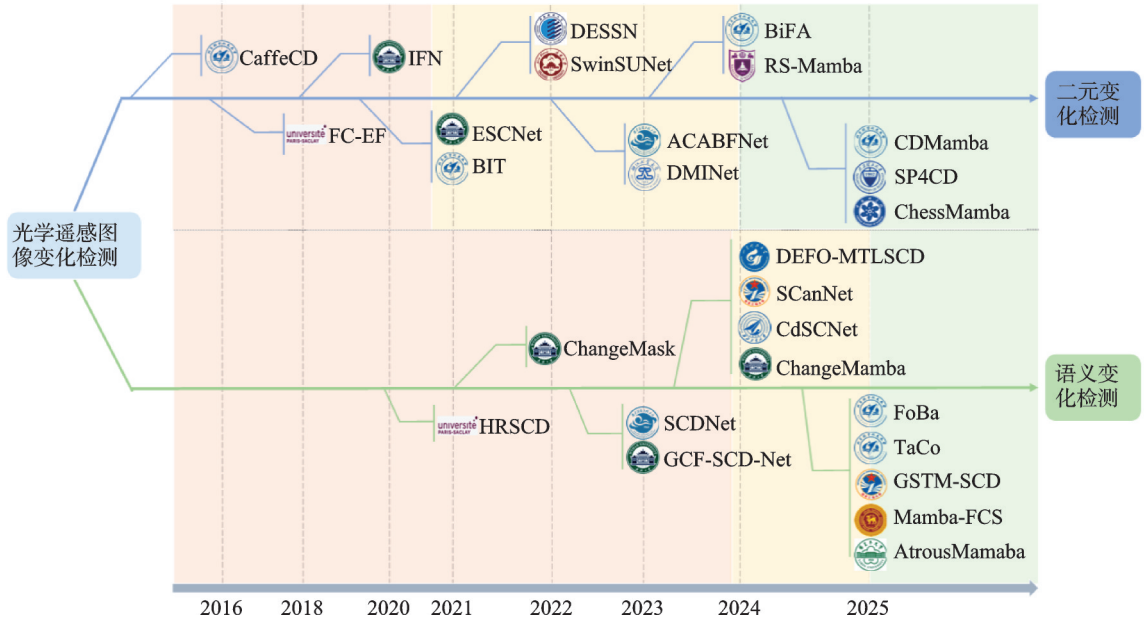


图3 二元和语义变化检测代表性方法

Fig.3 Representative methods of binary and semantic change detection

输入影像空间维度一致的变化检测结果图 $M \in \{0, 1\}^{H \times W}$ 。

$$M = F(I_1, I_2; \theta) \quad (1)$$

式中 F 表示参数为 θ 的二元变化检测模型。具体而言, 主流的二元变化检测架构通常可解构为 3 个部分: 特征提取网络 F_1 、判别性特征增强模块 F_2 以及变化分类器 F_3 (图 2(a))。据此, 二元变化检测任务可进一步形式化描述为

$$M = F_3(F_2(F_1(I_1, I_2; \theta_1); \theta_2); \theta_3) \quad (2)$$

式中: θ_1 、 θ_2 和 θ_3 分别表示各部分的可学习参数。

尽管二元变化检测能够有效识别感兴趣变化, 但其单一类别属性难以刻画丰富的地物演变过程, 限制了其在精细化监测场景中的应用。故研究者在二元变化检测任务的语义维度上进行拓展。其中, 具有代表性的工作为 2019 年 Daudt 等^[30] 提出的语义变化检测范式。与二元变化检测类似, 语义变化检测以多类别掩码的形式同步提取感兴趣变化区域的位置及其对应的语义类别, 实现从“感知变化”到“理解变化”的跨越。目前, 语义变化检测较通用的任务定义如下: 给定已配准的双时相光学遥感图像 I_1 和 I_2 , 模型旨在获取与其空间维度一致的并且分别与 I_1 和 I_2 对应的语义变化图 M_1 和 M_2 , 以及感兴趣变化区域 M_3 , 即

$$M_1, M_2, M_3 = F(I_1, I_2; \theta) \quad (3)$$

与二元变化检测流程类似, 语义变化检测模型也可大致解构为 3 个部分: 特征提取网络 F_1 、判别性特征增强模块 F_2 以及变化分类器 F_3 (图 2(b)), 故语义变化检测任务可进一步描述为

$$M_1, M_2, M_3 = F_3(F_2(F_1(I_1, I_2; \theta_1); \theta_2); \theta_3) \quad (4)$$

1.2 二元变化检测发展历程与部分代表性方法

卷积神经网络^[31]的再度兴起带来了计算机视觉领域的变革, 其强大的特征学习能力为复杂场景下的图像解译提供了可能。在此背景下, 一个很自然的问题: 能否将其强大特征表示的能力引入光学遥

感图像变化检测任务中以突破传统手工特征的局限。

1.2.1 基于卷积神经网络的方法

Amin等^[32]率先将卷积神经网络引入到二元变化检测领域,其核心在于利用深度网络特征替代传统手工特征。该方法将 1024×1024 大小的双时相影像划分为 227×227 大小的图块,并依次输入经过预训练的CaffeNet^[33]以提取多尺度特征表示。接着利用欧氏距离度量双时相特征间的差异程度,并结合大津法^[34]实现变化信息提取。尽管该方法验证了卷积神经网络特征的有效性,但其非端到端的框架仍依赖于人工设定的阈值,对不同场景的泛化性较弱。这一挑战在随后提出的早期融合全卷积网络(Fully convolutional early fusion, FC-EF)中得到了解决。

FC-EF:在2018年,Daudt等^[35]基于U-Net架构^[36]提出了FC-EF及其两种变体:孪生拼接全卷积网络FC-Siam-conc与孪生差异全卷积网络FC-Siam-diff。FC-EF采用早期融合策略,将双时相光学遥感图像在通道维度进行拼接,构建六通道输入,随后利用全卷积网络预测变化结果。然而,这种直接融合原始图像的策略缺乏显式的差异特征建模,限制了其在复杂场景中的判别能力。相比之下,FC-Siam-conc与FC-Siam-diff引入了权重共享的孪生分支,使网络能够独立提取双时相特征,为后续差异特征的提取提供了基础。前者将提取的双时相多尺度特征在通道维度进行级联,保留了较完整的特征信息。后者则通过计算双时相特征的绝对差异值来构建差异特征图,更直接地引导网络聚焦于变化区域。作为早期典型端到端的变化检测方法,该系列模型为后续基于深度学习的变化检测研究奠定了重要基础。

IFNet:在2020年,Zhang等^[37]提出了深度监督图像融合网络IFNet。该模型的核心贡献在于引入了注意力机制与深度监督策略,以提取更具判别性的变化特征。在编码器提取双时相图像的多尺度特征后,模型分别引入空间注意力与通道注意力模块对特征进行增强,旨在获取精细化的变化图。此外,该方法在解码器的中间层嵌入了辅助损失函数,通过深度监督机制增强了解码器的判别能力。

ESNet:在2021年,Zhang等^[38]提出了基于超像素增强的变化检测网络ESNet,通过超像素网络与卷积神经网络相结合的方式,显著提升了检测精度。具体而言,其设计了超像素化模块,利用生成的超像素边界抑制同一地理对象内部的变化,进而降低对象内部的特征差异,并通过相似度矩阵动态更新超像素特征,实现了超像素的自适应调整。作为首个端到端的基于超像素的变化检测框架,ESNet为结合几何约束与深度学习提供了新的思路。

DESSN:在2022年,Lei等^[39]提出了基于差异增强与空谱非局部网络DESSN。为抑制噪声干扰并获取高质量的差异表征,DESSN将差异图提取置于特征提取阶段,以此过滤无关的伪变化,聚焦真正的感兴趣变化。同时,该架构引入了空谱非局部模块,通过整合多尺度空间全局特征,建模地物大范围变化特性,进而增强变化地物边缘的完整性。

尽管基于卷积神经网络的方法可以较好地处理高分辨率光学遥感图像,但其在构建地物对象间关系方面仍存在不足。随着Transformer^[40]在自然语言处理领域展现出卓越的长序列建模能力,研究者开始致力于探索将其引入光学遥感影像变化检测领域,旨在利用其全局注意力机制提升地物对象间的关系建模能力。

1.2.2 基于Transformer的方法

BIT:在2021年,Chen等^[41]首次将Transformer引入变化检测领域,提出了双时相图像Transformer(BIT)。其核心思想为:地物变化的高层语义概念可由少量的视觉“单词”有效表示。为此,BIT首先将双时相光学遥感图像压缩为稀疏的视觉“单词”,并利用Transformer编码器进行全局关系建模。随后,通过Transformer解码器将蕴含丰富全局关系的特征映射回像素空间,以实现原始特征的增强。BIT凭借较少的视觉“单词”实现了高效的全局关系建模,显著提升了二元变化检测的性能与计算效率。

SwinSUNet:在2022年,Zhang等^[42]提出了首个完全基于Transformer架构的二元变化检测网络

SwinSUNet。该网络以 Swin Transformer 块^[43]为基础单元构建孪生编码器,利用权重共享机制提取双时相多层次特征。同时,借鉴了 U-Net 的对称结构,通过跳跃连接将编码器的多尺度特征与解码器对应层进行融合。

ACABFNet:在 2022 年,Song 等^[44]提出了基于轴向交叉注意力的双分支融合网络 ACABFNet。该网络采用异构双分支架构,利用卷积神经网络和 Transformer 编码器分别提取双时相遥感影像的多尺度局部和全局特征。随后,使用轴向注意力机制,通过在高度或宽度维度与通道维度间进行交互建模,以此有效地学习双时相图像间的特征关系。

DMINet:在 2023 年,Feng 等^[45]提出了双分支多层次交互变化检测网络 DMINet。该网络提出了时相内联合注意力模块,通过改进传统的交叉注意力机制,使用共享查询特征引导模型学习双时相影像的全局特征分布,促进同一层级内信息的耦合。

BiFA:在 2024 年,Zhang 等^[46]提出了双时相对齐变化检测方法 BiFA,旨在从通道、空间及多尺度维度实现特征对齐。该方法通过显式预测双时相影像间的差异流场,实现像素级的空间对齐。同时,基于隐神经表示^[47]进行多尺度特征对齐,使用坐标查询的方式在特征层面进行插值,以此获取精确的变化检测结果。

尽管基于 Transformer 的方法可以较好地构建双时相图像间的全局关系,但其平方级的计算复杂度在处理大规模遥感数据时面临挑战。基于上述原因,研究者们开始关注近期在自然语言处理领域具备高效全局建模能力的 Mamba^[48],并将其引入光学遥感图像变化检测领域。

1.2.3 基于 Mamba 的方法

RS-Mamba:在 2024 年,Zhao 等^[49]提出专为高分辨率遥感影像设计的 RS-Mamba。针对遥感影像特有的俯视成像视角以及地物分布的任意方向性,该方法提出了全向扫描策略,通过整合前向、后向、水平、竖直及对角线、反对角线的扫描路径对全局上下文进行动态建模,相较于原生 Mamba 的双向扫描策略,该方法显著增强了模型对复杂地物关系的表征能力。

CDMamba:在 2025 年,Zhang 等^[50-51]提出了 CDMamba,该模型提出了放缩残差卷积 Mamba 块,旨在利用 Mamba 高效提取全局关系的能力与卷积增强局部细节的优势,缓解当前基于 Mamba 的方法缺乏细节线索、难以在二元变化检测任务中实现精细检测的问题。同时,考虑到光学变化检测任务需要双时相特征交互的需求,提出自适应全局-局部引导融合模块,通过引入另一时相作为引导动态促进双时相特征间的交互。

SP4CD:在 2025 年,Qu 等^[52]提出了 SP4CD,该方法设计了一种补丁级跨时相通道融合策略,通过对图像补丁执行交换、拼接、选择与解耦等操作,以近乎零参数开销的方式实现了双时相特征聚合。此外,该方法还使用串行与并行互补的扫描机制,进一步增强了变化区域的刻画能力。

ChessMamba:在 2025 年,Ding 等^[53]提出了 ChessMamba。该方法引入了双向蛇形扫描的棋盘式混洗机制,在邻域空间内显式解耦多时相特征,同时保证一维序列中的拓扑一致性,降低模型对预配准误差的敏感度。此外,该架构采用单时相上下文聚合状态融合机制,在单时相内部有选择地建模中心与顶点邻域上下文信息,以增强结构一致性表征。

1.2.4 二元变化检测代表性方法性能对比

为直观展示上述代表性二元变化检测方法在性能与效率方面的差异,表 1 汇总了各方法在经典二元变化检测数据集 LEVIR-CD 上的实验结果。评测指标选取了 F1 分数和 IoU(详细定义将在第 4 节阐述),以及衡量计算复杂度的参数量与浮点运算次数。

从模型性能来看,LEVIR-CD 数据集上的实验结果显示,基于卷积神经网络、Transformer 及 Mamba 的方法在检测精度上总体呈现递增趋势。这一提升主要归因于 Transformer 与 Mamba 架构在全局关

系建模上的优势,这也与前文所述的二元变化检测技术演进路线相契合。此外,进一步比较具有全局建模能力的两类方法,在参数量处于同一量级时(如 SP4CD 与 DMINet、BiFA 的对比),基于 Mamba 的方法展现出更优越的检测性能。同时,基于 Mamba 的方法(如 SP4CD)在保持高性能的同时显著降低了计算开销(浮点运算次数)。这主要得益于 Mamba 架构的线性计算复杂度设计,从而有效克服了 Transformer 架构二次复杂度带来的计算瓶颈。

表 1 二元变化检测代表性方法性能对比

Table 1 Performance comparison of representative binary change detection methods

| 类型 | 名称 | LEVIR-CD | | 参数量/ 10^6 | 浮点运算次数/ 10^9 |
|--------------------|--------------|----------|-------|-------------|----------------|
| | | F1 | IoU | | |
| 基于卷积神经网络的方法 | FC-EF | 88.90 | 80.03 | 1.35 | 3.57 |
| | FC-Siam-conc | 89.89 | 81.64 | 1.54 | 5.33 |
| | FC-Siam-diff | 89.69 | 81.31 | 1.34 | 4.72 |
| | IFNet | 88.11 | 78.75 | 50.71 | 41.1 |
| | ESNet | | | | |
| | DESSN | 91.36 | | 19.35 | 36.75 |
| 基于 Transformer 的方法 | BIT | 90.03 | 81.87 | 3.04 | 8.75 |
| | SwinSUNet | 87.77 | 78.21 | 39.28 | 43.50 |
| | ACABFNet | 89.18 | 80.48 | 102.32 | 28.28 |
| | DMINet | 90.46 | 82.59 | 6.24 | 14.55 |
| | BiFA | 90.69 | 82.96 | 5.58 | 53.00 |
| 基于 Mamba 的方法 | RS-Mamba | 91.10 | 83.66 | 51.95 | |
| | CDMamba | 90.75 | 83.07 | 11.90 | 49.68 |
| | SP4CD | 94.78 | 90.45 | 12.24 | 6.05 |
| | ChessMamba | 92.01 | 85.20 | 22.67 | 60.43 |

1.3 语义变化检测发展历程与部分代表性方法

语义变化检测任务的技术演变路径大体与二元变化检测任务相似,经历了从卷积神经网络^[30,54-57]到 Transformer^[58-61],再到近期 Mamba 的演变过程。下文将对语义变化检测领域中具有代表性的方法进行梳理与介绍。

1.3.1 基于卷积神经网络的方法

HRSCD:在 2019 年,Daudt 等^[30]提出了 4 种名为 HRSCD 的方法(HRSCD str1,2,3,4)以解决语义变化检测任务。HRSCD str1 采用解耦的方式,首先预测双时相光学遥感图像的地物分类结果,然后通过直接比较的方法获取语义变化结果图。HRSCD str2 则采用端到端直接预测的方式生成语义变化结果。HRSCD str3 和 HRSCD str4 基于多任务学习的统一框架,将二元变化检测与地物分类任务统一建模,并使用二元掩码引导语义变化结果的产生。

SCDNet:在 2021 年,Peng 等^[54]提出了名为 SCDNet 的语义变化检测网络。该方法在编码阶段引入了多尺度空洞卷积^[62],通过扩大感受野来捕捉地物的多尺度变化信息。在解码阶段,通过注意力机制融合双时相差分特征与原始语义特征,有效缓解语义差异问题。

GCF-SCD-Net:在 2021 年,Xiang 等^[55]提出了 GCF-SCD-Net,其构建了生成式变化场,利用双时相图像的差分特征与原始特征生成变化场。该变化场一方面用于定位二元变化检测的区域,另一方面作

为引导信息注入到两个时相的语义分割分支,实现精细的语义预测。

DEFO-MTLSCD:在2024年,Li等^[56]提出了面向解码器的多任务语义变化检测网络DEFO-MTLSCD,该方法针对语义变化检测中子任务特征交互不足的问题,在解码阶段设计了跨子任务特征交互模块,旨在通过逐层融合两个语义分支的特征,增强差异分支的判别能力。

1.3.2 基于Transformer的方法

ChangeMask:在2022年,Zheng等^[58]提出了ChangeMask。该方法从任务先验的角度引入语义变化因果关系与时间对称性两类关键归纳偏置,通过语义感知编码器学习语义表示,随后通过Transformer从语义表示中学习变化信息。

SCanNet:在2024年,Ding等^[59]提出了一种联合时空建模的语义变化检测网络SCanNet。该方法设计了语义变化Transformer,将双时相语义特征与变化特征统一映射至“令牌”空间,并利用CSWin^[63]的自注意力机制同步建模全局空间依赖与时序语义关联。

CdSCNet:在2024年,Wang等^[60]提出了名为交叉差分语义一致性的语义变化检测网络CdSCNet。该方法通过对双时相特征进行通道级交互,并结合3D卷积^[64]在空间与通道维度充分挖掘变化信息。此外还设计了语义上下文增强模块,利用双时相语义特征对差分特征进行注意力引导,进而缓解语义表示和变化信息之间的差距。

TaCo:在2025年,Guo等^[61]提出了时空语义一致性网络TaCo。该方法在空间差异感知的基础上引入了语义迁移建模,利用预训练视觉-语言模型生成的类别文本嵌入作为语义锚点,提取判别性特征。此外,还构建了双时相重构约束与迁移约束,用于对齐重构特征与原始特征,以确保双时相特征间的语义一致性。

1.3.3 基于Mamba的方法

ChangeMamba:在2024年,Chen等^[65]提出了ChangeMamba,首次探索了Mamba在语义变化检测任务中的潜力,提出了时空顺序建模、时空交叉建模以及时空并行建模3种方式以捕获复杂的时空关联。自此以后,大量基于Mamba的语义变化检测方法相继涌现出来。

FoBa:在2025年,Zhang等^[66]提出了FoBa。该方法提出了前景-背景协同引导的策略,旨在驱动模型聚焦感兴趣区域的同时还能融入丰富的上下文信息。该策略有效缓解了复杂场景中(尤其是感兴趣对象边界处)的语义模糊问题,同时改善了模型过度关注显著变化区域而忽略微小变化的现象。此外,还考虑到语义变化检测任务语义一致的特性,引入不变区域一致性损失以确保语义预测结果的一致性。

GSTM-SCD:在2025年,Liu等^[67]提出了GSTM-SCD,将图优化与Mamba相结合。该方法首先构建了时空图优化机制,在促进多时相遥感图像交互的同时,保持特征的空间连续性。同时还提出了时序语义变化检测任务专用目标函数,利用任务中固有的多时相变化拓扑结构进行正则化约束。

Mamba-FCS:在2025年,Wijenayake等^[68]提出了Mamba-FCS。该方法在Mamba的基础上进行改进,提出联合时空频率特征融合策略,通过融入对数振幅频域特征,有效抑制了光照波动产生的伪影干扰。同时,还提出了分离卡帕损失函数,将语义变化检测的评价指标转化为可优化的训练目标,提升了模型对于稀疏变化的学习能力。

AtrousMamba:在2025年,Wang等^[69]提出了AtrousMamba。该方法在Mamba的基础上引入空洞窗口选择性扫描机制,以可调节的速率逐步扩大扫描范围,其缩短了相邻令牌之间的距离,使模型能够更有效地捕获细粒度局部特征与全局上下文信息。

1.3.4 语义变化检测代表性方法性能对比

为直观地展示上述代表性语义变化检测方法在性能与效率方面的差异,表2展示了各代表性方法

在常用语义变化检测数据集 SECOND 上的实验结果。评测指标选取了 SeK 与 mIoU(其详细定义将在第 3 节中阐述),同时与表 1 保持一致,统计了参数量和浮点运算次数以衡量模型的计算开销。

在模型性能方面,语义变化检测任务呈现出与表 1 中二元变化检测相一致的演进规律,即从基于卷积神经网络到 Transformer,再到基于 Mamba 方法的检测精度总体呈递增趋势。此外,相较于同样具有全局建模能力的两类方法,在具有相当参数量时,基于 Mamba 的方法(如 GSTM-SCD)相较于基于 Transformer 的方法(如 CdSCNet),具有更优的检测性能,同时还保持了更低的浮点运算次数。综上所述,无论是在二元还是语义变化检测任务中,基于 Mamba 的方法均展现出了其在计算效率方面高效的优势。

表 2 语义变化检测代表性方法性能对比

Table 2 Performance comparison of representative semantic change detection methods

| 类型 | 名称 | SECOND | | 参数量/ 10^6 | 浮点运算次数/ 10^9 |
|--------------------|--------------|--------|-------|-------------|----------------|
| | | SeK | mIoU | | |
| 基于卷积神经网络的方法 | HRSCD str4 | 17.71 | 71.08 | 13.71 | 43.97 |
| | SCDNet | 23.66 | 73.06 | 39.62 | 116.98 |
| | GCF-SCD-Net | 14.10 | 67.60 | 25.57 | 56.10 |
| | DEFO-MTLSCD | 23.91 | 73.65 | 26.02 | 100.27 |
| 基于 Transformer 的方法 | ChangeMask | 17.89 | | 10.62 | |
| | SCanNet | 23.58 | 73.43 | 27.90 | 264.95 |
| | CdSCNet | 22.60 | 73.26 | 33.86 | 134.80 |
| | TaCo | 24.73 | 73.77 | 23.75 | 108.57 |
| 基于 Mamba 的方法 | ChangeMamba | 23.93 | 73.47 | 89.99 | 211.55 |
| | FoBa | 24.61 | 74.50 | 86.32 | 183.68 |
| | GSTM-SCD | 24.18 | 73.50 | 52.77 | 113.81 |
| | Mamba-FCS | 25.50 | 74.07 | 189.54 | 263.15 |
| | AtrousMamaba | 24.95 | 73.66 | 54.63 | 36.89 |

2 变化检测关键组件与关键方法

从光学遥感图像变化检测的任务流程来看,其架构通常由特征提取网络、判别性特征增强以及损失函数 3 部分构成。目前的大多数研究围绕上述视角开展,旨在从不同阶段提升算法的整体效能。需要说明的是,本节并非引入新的方法,而是从技术模块的角度对光学遥感图像变化检测方法进行深入剖析,重点关注各关键组件的设计原理与实现机制。下文将围绕上述 3 个核心组件进行阐述。

2.1 特征提取

特征提取作为光学遥感图像变化检测的初始环节,发挥着至关重要的作用,其不仅是构建高质量特征表示的基础,更是后续检测阶段实现精准变化检测的前提。

2.1.1 基于卷积神经网络的方法

早期光学遥感图像变化检测框架多基于卷积神经网络构建,得益其较强的局部线索提取能力,此类方法可以实现精细的边缘结构刻画。其中,最具代表性的工作为 Daudt 等^[35]提出的 3 种基于 U-Net 结构的全卷积方法:FC-EF、FC-Siam-diff、FC-Siam-conc。该框架确定了双时相光学遥感图像处理的基本范式,并掀起了后续基于 ResNet^[70]等卷积骨干网络提取特征的研究浪潮^[30,38-39,54-56,71-72]。

2.1.2 基于Transformer的方法

然而,受限于卷积神经网络的局部感受野,传统卷积骨干网络难以有效建模全局依赖关系,显著限制了对全局上下文信息敏感的光学遥感图像变化检测任务。为此,研究者们开始引入具有强大全局建模能力的Transformer作为特征提取网络^[42,44,46]。如Zhang等^[42]提出的SwinSUNet,作为早期的代表性方法,以Swin Transformer作为特征提取网络,以缓解全局建模能力不足的问题。Zhang等^[46]提出了BiFA,该方法基于改进的SegFormer^[73]结构,使用跨时相引导机制实现双时相特征的提取与交互,取得了较好的检测效果。

2.1.3 基于Mamba的方法

尽管,基于Transformer的特征提取网络可以建模更强的全局关系,但其自注意力机制固有的高额计算代价(即计算复杂度随输入序列长度呈平方增长),限制了其在高分辨率遥感图像变化检测任务中的应用。为此,研究者们开始积极探索更高效的全局关系提取方法。Mamba的出现给这一方向带来了可能。凭借其线性计算复杂度与可媲美Transformer的全局建模能力,Mamba被迅速地引入光学遥感图像变化检测领域,并展现出较大的潜力^[49-53,65-69]。被广为熟知的如Chen等^[65]提出的ChangeMamba,其首次将Mamba应用于光学遥感图像特征提取。与之同期的RS-Mamba^[49]通过改进Mamba的扫描策略,将前向-后向的双向扫描扩展为全向扫描,显著提升了全局特征提取能力。随后,Zhang等^[50]提出了CDMamba。不同于以往侧重于扫描范式的改进,其提出了ConvMamba模块并以此构建特征提取网络,实现全局关系与局部线索的协同提取。

2.1.4 基于基础模型的方法

此外,受益于基础模型在各个领域展现出卓越的能力,利用视觉基础模型提取高质量表征已逐渐成为光学遥感图像变化检测领域的研究热点。现有研究大致可归纳为两类,一类是将基于大规模自然图像预训练的基础模型迁移至光学遥感图像变化检测任务中^[74-80]。Chen等^[74]提出了TTP,利用低秩微调(LoRA)^[81]技术,将基于自然图像预训练的SAM^[82]模型成功应用于双时相特征提取。与之相似,Dong等^[75]提出的PefCD将LoRA扩展至性能更优的SAM2^[83]与DINOv3^[84]。此外,Li等^[76]提出了基于“桥接”的方法,通过构建轻量化桥接模块,将冻结的基础模型所提取的特征映射至轻量化特征提取器中,从而高效获取基础模型的通用知识。

尽管上述研究验证了基于自然图像预训练的基础模型在迁移至遥感领域时具备优势,由于自然图像与遥感图像间存在的差异(如成像视角等),一些研究者致力于构建基于遥感图像的基础模型。其中,最具代表性的是“灵眸”(RingMo)系列。Sun等^[77]基于200余万幅光学遥感图像,利用MAE^[85]自监督预训练策略构建了遥感专用基础模型,并将其成功应用于变化检测的特征提取阶段。随后,该团队在此基础上拓展,提出了RingMoE^[78],不仅在网络设计中引入了混合专家模型^[86]以实现特征的动态选择,还在数据维度引入了多模态信息(如合成孔径雷达),增强了模型的特征表示能力。与之相似,Guo等^[79]提出的SkySense利用2000余万幅光学与合成孔径雷达的时间序列数据,通过多粒度对比学习进行预训练,并结合地理上下文先验增强其特征表现能力。

总的来说,尽管目前仍广泛使用上述各类特征提取方法,但随着蕴含海量知识的基础模型在变化检测领域的优势愈发凸显,当前研究正逐步展现出使用基础模型,尤其是面向遥感场景预训练的基础模型提取特征的趋势。

2.2 判别性特征增强

判别性特征的增强是实现精准变化检测的关键环节。目前,大多数方法侧重于模型结构层面的改进,以提升特征的判别能力,进而提升整体的检测性能。现有方法大致可以分为以下3类:多尺度特征融合、手工特征集成以及注意力机制改进。

2.2.1 多尺度特征融合

多尺度特征融合在光学遥感图像变化检测中应用较为广泛。由于特征提取网络的不同阶段呈现出异质的特征属性,即浅层特征具备较高的空间分辨率,蕴含丰富的几何细节,但语义特性较弱。深层特征空间分辨率较低,空间细节发生退化,但具备更强的抽象语义表征。为了兼顾二者,主流的方法在各阶段采用级联、差分等策略提取到多尺度特征后,通过跨尺度融合生成更具判别性的特征。此类方法^[87-91]多借鉴U-Net及其变体。如Peng等^[90]采用特征拼接的策略,结合具有多侧分支融合机制的UNet++^[92]实现多尺度特征的融合。类似地,Fang等^[91]提出的SNUNet-CD通过在编码器与解码器之间引入密集连接以融合多尺度信息。

2.2.2 结合手工特征

同时还有一些研究者将手工设计的算子引入到变化检测模型中以获取高质量的判别性特征^[93-94],应用较为广泛的是Sobel和Canny算子。通过其提取光学多时相图像丰富的边缘信息作为补充,从而引导模型聚焦精准的几何变化。如Wang等^[93]使用Sobel算子构建图结构,并通过图卷积模块扩展感受野以提取边缘信息。与之相似,Chen等^[94]使用性能更强的Canny算子提取手工边缘特征,进一步增强特征的判别性。

2.2.3 注意力机制改进

使用注意力机制增强判别性特征,是当前变化检测研究中最常用的方法。注意力的核心思想在于从海量信息中快速筛选出高价值的信息。此概念早期被广泛应用于自然图像领域,凭借其卓越的特征选择能力,进而被引入到光学遥感图像变化检测领域中。从机理来说,注意力机制本质上是一种加权重构方法,旨在通过差异化分配权重以关注数据的不同方面,其可大致分为空间注意力、通道注意力、自注意力、交叉注意力以及Transformer。具体而言,空间注意力通常压缩通道维度得到空间中各个位置的重要性。而通道注意力则通过对空间维度进行聚合得到各个通道的重要性。Lei等^[39]基于通道注意力机制设计了差异增强模块,通过在空间维度同步执行平均池化与最大池化操作,生成多种空间上下文描述以增强特征的判别性。后续研究,如方法^[91,95-96]等,同样侧重于通道维度的增强。然而空间信息对于光学遥感变化检测任务同样重要,部分学者着手探究多维协同增强。Wang等^[97]提出了一种融合空间与通道特征的自适应注意力机制,以捕获跨尺度变化间的关联。Lv等^[98]的方法亦沿用此思想提升特征的判别性。

自注意力、交叉注意力以及Transformer均源于自然语言处理领域,其核心在于通过注意力得分矩阵凸显不同特征的重要性。强大的全局信息捕获能力使其能够有效构建双时相图像的全局语义关联,从而凸显判别性特征。Chen等^[99]提出了时空注意力网络,利用自注意力机制捕获全局空间相关性,并将其嵌入到空间金字塔结构中进一步增强判别性特征。此后,大量基于三者提取判别性特征的方法涌现出来^[41,44-46,58-61,99]。Chen等^[41]提出了双时相图像Transformer,通过将特征图稀疏表征为视觉令牌,实现高效的判别性特征提取。Feng等^[100]提出了尺度内与尺度间特征交互网络,利用Transformer同时建模双时相特征单尺度与跨尺度间的关联。随后,该团队提出双分支多层级跨时相网络(DMINet)^[45],将沿通道拼接的双时相特征作为共享查询,用于建模不同时相图像之间的时空关系。此外,Song等^[44]引入了基于Transformer的轴向交叉注意力以增强判别性特征。

近期,同样源于自然语言处理领域的Mamba,凭借其更高效的全局建模机制以及与Transformer相媲美全局建模能力,引起了变化检测领域广泛关注^[49-53,65-69]。自从Chen等^[65]基于Mamba构建时空顺序建模、时空交叉建模以及时空并行建模方式学习双时相图像间的时空关系以来,基于Mamba增强判别性特征的方法便相继涌现。例如,Qu等^[52]基于Mamba设计了补丁级的融合策略,通过对图像补丁执行交换、拼接、选择与解耦等操作,以近乎零参数开销的方式实现判别性特征的增强提取。Zhang等^[66]

基于Mamba,结合前景与背景协同引导的机制驱使模型在学习显著变化前景的同时补充具有丰富上下文的背景信息,以此增强判别性特征。

总的来说,上述方法分别从多尺度特征融合、结合手工特征以及注意力机制改进3个方面出发,旨在增强特征的判别性,从而提升光学遥感图像变化检测方法的性能。由于手工特征往往基于先验知识构建,并且泛化能力较弱,故相关研究相对有限。相比之下,多尺度特征融合以及注意力机制改进凭借其显著的性能提升与较高的适应性,已经成为目前变化检测模型中不可或缺的部分。

2.3 损失函数

损失函数作为光学遥感图像变化检测模型的核心组成部分,通过设计更具针对性的损失函数,可以显著提升模型的判别能力。目前,基于损失函数的改进研究主要包括以下3个方面:加权损失函数解决样本不平衡问题,半监督学习方式缓解小样本问题以及生成对抗网络缓解双时相图像间的域差异。

2.3.1 结合加权损失

光学遥感图像变化检测任务存在正负样本严重不平衡的现象,即感兴趣变化区域(正样本)的像素占比远低于非感兴趣区域(负样本)。这是由于真实世界中变化发生的低频性决定的。一些学者通过损失函数对不同类别施加差异化权重以解决该问题。常见的加权损失函数有加权交叉熵损失^[101-102]、加权Dice损失^[103]、加权对比损失^[104]以及加权Focal损失^[105]等。Zhang等^[101]引入了先验知识引导的加权交叉熵损失,利用变化向量分析生成变化幅度图,并据此动态调整交叉熵函数的权值。Zhan等^[103]则基于类别出现的频率确定加权对比损失的权重。Liu等^[105]对Focal损失进行了改进,提出了加权Focal损失,以非线性形式考虑变化样本与未变化样本权重之间的关系,缓解样本不平衡的问题。

2.3.2 结合半监督学习

上述结合加权损失函数的方法着眼于变化样本与未变化样本的相对数量,而另一些研究者则聚焦于变化样本绝对数量,即将变化样本视为小样本,结合半监督学习的方式缓解这一问题。此类型方法的思想为:在仅有少量标注数据的情况下,通过利用大规模无标注数据,提升有监督模型的性能。Peng等^[106]提出了SemiCDNet,该方法在训练阶段的同时预测有标注与无标注数据,对于有标注数据采用交叉熵损失监督,同时引入对抗判别器,约束无标注数据与有标注数据的预测图及熵图分布一致,以此达到使用无标注数据提升性能的目的。Sun等^[107]提出基于伪标签与一致性正则化的半监督方法。该方法先利用有限的标注数据对网络进行训练,并借助像素级阈值滤波器为未标注遥感影像生成高置信度伪标签。随后,通过使修正预测的结果与伪标签保持一致,从而提升模型的检测性能。

2.3.3 结合生成对抗网络

将生成对抗网络应用于变化检测任务主要分为2类。一类是将其嵌入变化检测框架中进行联合训练,此类方法将模型生成的预测概率图与真实标签视为两个不同的域,约束模型预测结果向真实分布逼近,可当作是传统像素级损失(如交叉熵损失)的补充。Lebedev等^[108]最早将对抗生成网络应用在光学遥感图像变化检测领域,其采用Pixel2Pixel^[109]的架构,设计了基于U-Net的生成器,并引入PatchGAN^[110]作为判别器,交替进行训练。另一类研究将生成对抗网络视作有效的数据预处理手段,旨在通过学习多时相图像间的域转换关系来消除风格差异,以此降低检测任务的难度^[111-112]。Fang等^[111]采用CycleGAN^[113]学习双时相遥感图像间的映射关系,将源时相图像迁移至目标时相的表征域后再进行检测。

总的来说,上述方法针对光学遥感图像变化检测任务中普遍存在的正负样本不平衡、变化样本稀缺以及双时相图像域间差异显著等问题,提出了解决方案。其中,由于加权损失策略易于实现且效果提升显著,已成为变化检测任务中常用的技术手段。结合对抗生成网络的方法,尤其是将其作为双时相图像预处理手段,能够有效缓解图像间的成像差异,被广泛应用于域差异较大的场景以显著降低任

务难度。尽管目前结合半监督学习的变化检测研究相对有限,但其通过海量未标注数据与少量标注数据提升检测性能的范式具有较大的潜力,值得未来进一步探究。

3 变化检测数据集以及评价指标

光学遥感图像变化检测方法性能的验证依赖于高质量的数据集作为实验基础,同时还需要客观、统一的评价指标对不同方法的检测效果进行定量评估。基于此,本节将围绕数据集构建与评价指标两个方面,对相关内容展开介绍。

3.1 变化检测数据集

3.1.1 二元变化检测数据集

作为遥感领域研究历史较为悠久的任务之一,二元变化检测受到学术界的广泛关注,大量研究者致力于构建高质量的二元变化检测数据集,以评估各类算法的有效性。本文以时间演进为主线,系统地调研了2009年至2025年间发布的22个常用的二元变化检测数据集,如表3所示,旨在梳理该领域数据集的发展趋势。

表3 二元变化检测数据集

Table 3 Binary change detection datasets

| 数据集 | 图像尺寸/(像素×像素) | 图像数量 | 空间分辨率/m | 图像来源 | 发布时间 |
|---------------------------------|--------------------------|--------|-----------|-------------|---------|
| SZTAKI ^[114] | 952×640 | 13 | 1.5 | 航拍图像 | 2009-07 |
| OSCD ^[115] | 600×600 | 24 | 10 | Sentinel-2 | 2018-07 |
| CDD ^[108] | 4 725×2 700 | 7 | 0.03~1.00 | 谷歌地球 | 2018-06 |
| WHU-CD ^[116] | 32 507×15 354 | 1 | 0.3 | 航拍图像 | 2018-08 |
| LEVIR-CD ^[99] | 1 024×1 024 | 637 | 0.5 | 谷歌地球 | 2020-05 |
| DSIFN ^[37] | 512×512 | 394 | | 谷歌地球 | 2020-08 |
| GZ-CD ^[106] | 1 006×1 168~4 936×5 224 | 19 | 0.55 | 谷歌地球 | 2020-08 |
| MUDS ^[117] | 1 024×1 024 | 2 389 | 4 | | 2021-02 |
| SYSU-CD ^[118] | 256×256 | 20 000 | 0.5 | 航拍图像 | 2021-06 |
| S2Looking ^[119] | 1 024×1 024 | 5 000 | 0.5~0.8 | 谷歌地球 | 2021-10 |
| CLCD ^[120] | 512×512 | 600 | 0.5~2.0 | Gaofen-2 | 2022-05 |
| CRCD ^[121] | 512×512 | 3 237 | 0.2 | 谷歌地球 | 2022-07 |
| NanjingDataset ^[122] | 14 231×11 381 | 1 | 0.3 | 谷歌地球 | 2022-07 |
| GVLM ^[123] | 1 748×1 748~10 808×7 424 | 17 | 0.59 | 谷歌地球 | 2022-11 |
| HRCUS-CD ^[124] | 256×256 | 11 388 | 0.5 | | 2023-08 |
| EGY-BCD ^[125] | 256×256 | 6 091 | 0.25 | 谷歌地球 | 2023-06 |
| Hi-CNA ^[126] | 512×512 | 6 797 | 0.8 | GF-2 | 2024-06 |
| TUE-CD ^[127] | 256×256 | 1 656 | 1.8 | WorldView-2 | 2024-08 |
| MSRS-CD ^[128] | 1 024×1 024 | 842 | 0.5 | | 2024-10 |
| MineNetCD ^[129] | 256×256 | 71 711 | 1.2 | 谷歌地球 | 2024-11 |
| MLCD ^[130] | 256×256 | 10 000 | 0.5~2.0 | 谷歌地球 | 2025-06 |
| CWSCD ^[131] | 2 048×2 048 | 200 | 1 | BJ-2、GF2 | 2025-01 |

SZTAKI^[114]:作为较早提出的光学遥感变化检测数据集之一,其由13张大小为952×640像素采集于2000年和2005年的光学遥感图像构成。数据集覆盖总面积约9.5 km²,空间分辨率为1.5 m/像素,并提供了人工精确标注的变化掩膜。

OSCD^[115]:该数据集聚焦于城市区域变化,仅将城市扩张及相关的人为活动变化标注为“变化”类

别,而不考虑自然变化因素。数据集基于哨兵-2号卫星数据构建,在全球范围内选取了24个具有不同城市化水平且城市变化显著的区域作为研究对象。图像的空间分辨率为10 m/像素,单幅图像大小为 600×600 像素。

CDD^[108]:该数据集基于谷歌地球共收集了7对具有显著性季节变化光学图像,并使用人工标注产生变化掩膜。图像大小为 $4\,725 \times 2\,700$ 像素,空间分辨率为0.03~1.00 m/像素,覆盖从小型目标(如车辆)到大型建筑结构的多尺度对象。

WHU-CD^[116]:该数据集专注于建筑物变化检测,包含一对大小为 $32\,507 \times 15\,354$ 像素的航空图像,空间分辨率为0.3 m/像素。数据集中包括超2 587个变化实例,凭借其多样的建筑风格及大量的变化建筑实例,WHU-CD已成为目前最广泛使用的建筑物变化检测评测基准之一。

LEVIR-CD^[99]:该数据集用于城市建筑物变化检测研究,由637对大小为 $1\,024 \times 1\,024$ 像素的谷歌地球图像构成,空间分辨率为0.5 m/像素。图像覆盖美国得克萨斯州20个不同城市区域,观测时间跨度长达15年。该数据集共包含31 333个变化实例,其样本规模约为WHU-CD数据集的12倍,凭借较大的数据规模,LEVIR-CD数据集迅速成为二元变化检测领域最常用的基准之一。

DSIFN^[37]:该数据集包含394对来源于谷歌地球的光学遥感图像,图像大小为 512×512 像素,覆盖北京、成都、深圳、重庆和武汉5个城市。

GZ-CD^[106]:该数据集聚焦于中国广州郊区的变化,共包含19对空间分辨率为0.55 m/像素的谷歌地球图像,采集时间跨度为2006年至2019年,图像大小范围为 $1\,006 \times 1\,168$ 像素至 $4\,936 \times 5\,224$ 像素。

MUDS^[117]:该数据集共包含2 389幅大小为 $1\,024 \times 1\,024$ 像素的遥感图像,时间跨度为18至26个月,空间分辨率为4 m/像素,共覆盖 $41\,250\text{ km}^2$ 。

SYSU-CD^[118]:该数据集聚焦于香港区域的检测,包含20 000对空间分辨率为0.5 m/像素的航空影像,观测时间跨度为2007年至2014年。主要变化包括城市新建建筑物、植被变化、道路扩建及海洋工程建设等。

S2Looking^[119]:与侧重于城市场景的LEVIR-CD数据集不同,S2Looking将研究视角转向了农村区域。该数据集包含约5 000幅大小为 $1\,024 \times 1\,024$ 像素,来自谷歌地球的光学遥感图像,空间分辨率为0.5~0.8 m/像素。

CLCD^[120]:该数据集由获取自高分二号(Gaofen-2)卫星的600对农田图像构成,分别拍摄于2017年和2019年,覆盖中国广东省区域。图像的空间分辨率介于0.5~2.0 m/像素,单幅图像大小为 512×512 像素。数据集中标注的主要变化包括建筑物、道路、湖泊及裸地等。

CRCD^[121]:该数据集覆盖美国新泽西州约 20 km^2 ,空间分辨率为0.2 m/像素,共包含3 237张大小为 512×512 像素的图像。

NanjingDatase^[122]:该数据集面向建筑物变化,采用来源于谷歌地球的遥感图像,分别获取于2014年和2018年,覆盖南京市区域。图像大小为 $14\,231 \times 11\,381$ 像素,空间分辨率为0.3 m/像素。

GVLM^[123]:该数据集专为滑坡灾害监测任务设计,采用来源于谷歌地球的双时相光学遥感图像,覆盖亚洲、非洲、北美洲、南美洲、欧洲和大洋洲六大洲多个国家和地区的典型滑坡区域。共包含17对图像,总覆盖面积为 163.77 km^2 ,空间分辨率为0.59 m/像素,图像大小为 $1\,748 \times 1\,748 \sim 10\,808 \times 7\,424$ 像素。

HRCUS-CD^[124]:该数据集聚焦于中国珠海市区域,共包含11 388对光学遥感图像,图像大小为 256×256 像素,空间分辨率为0.5 m/像素,涵盖了超12 000个变化实例。

EGY-BCD^[125]:该数据集面向建筑物变化检测任务,采用来源于谷歌地球的卫星图像,覆盖埃及境内4个城市及其沿海区域,观测时间跨度为2015年至2022年。数据集中共包含6 091对大小为 $256 \times$

256像素的图像,空间分辨率为0.25 m/像素。

Hi-CNA^[126]:该数据集面向耕地变化检测任务,旨在覆盖不同类型耕地演变过程。数据集共包含6 797对来源于高分2号的图像,单幅图像大小为512×512像素,空间分辨率为0.8 m/像素,是目前耕地变化检测领域中规模最大的公开数据集之一。值得一提的是,该数据集中变化像素与未变化像素的数量分布较为均衡,未出现显著的样本不平衡问题。

TUE-CD^[127]:该数据集面向地震后的建筑物变化检测任务,采用由WorldView-2卫星获取的双时相遥感图像,研究地区为土耳其。数据集中共包含1 656对大小为256×256像素的图像,空间分辨率为1.8 m/像素,共有2 338个受损建筑物实例标注,为灾后损失评估提供了数据基础。

MSRS-CD^[128]:该数据集由842对采集于2019至2023年中国区域的图像构成,每幅图像大小为1 024×1 024像素,空间分辨率为0.5 m/像素。

MineNetCD^[129]:该数据集专为露天采矿区而设计,采用来源于谷歌地球覆盖六大洲多个国家和地区的典型露天采矿区域的遥感图像。共包含超过7万对空间分辨率为1.2 m/像素的图像,总覆盖面积约为6 756.88 km²。

MLCD^[130]:作为首个针对澳门地区构建的海陆变化检测数据集,其包含了10 000对大小为256×256像素来源于谷歌地球的光学遥感图像。时间跨度约20年(2004年至2023年),空间分辨率为0.5~2.0 m/像素,重点关注填海区域的地理演化过程及其周边植被覆盖的动态变化。

CWSCD^[131]:该数据集主要关注中国河北地区的新增建设用地变化,其数据来源于北京2号和高分2号卫星,共包含200对大小为2 048×2 048像素的光学遥感图像,空间分辨率为1 m/像素。

总的来说,当前二元变化检测领域数据资源丰富,整体呈现出大数据量、大图像尺度以及高空间分辨率的趋势,这与深度学习模型对高质量数据驱动的需求而契合。同时,现有二元变化检测数据集主要着眼于城市变化场景,大多聚焦城市化的扩张。相比之下,针对特定行业场景(如MineNetCD关注矿区监测)或地貌演变的数据基准相对匮乏,有待进一步拓展。

3.1.2 语义变化检测数据集

尽管语义变化检测任务的发展晚于二元变化检测,但近年来诸多学者已致力于构建高质量的语义变化检测数据集。与上述二元变化检测数据集的介绍类似,本节同样以时间轴为主线,梳理了2019年至2025年间发布的15个常用语义变化检测数据集,如表4所示。

HRSCD^[30]:该数据集是首个大规模语义变化检测数据集,其图像来源于法国国家地理与森林信息研究所发布的航空图像。共包含291对大小为10 000×10 000像素的样本,空间分辨率为0.5 m/像素,涵盖水体、森林等5类典型地物语义变化类别。

xBD^[132]:该数据集专为自然灾害场景下的建筑物损毁评估设计,共包含11 034张1 024×1 024像素大小的光学遥感图像,空间分辨率为0.8 m/像素,涵盖“无损毁”、“轻微受损”、“严重受损”以及“完全摧毁”4个类别,为灾后的精准评估提供了数据基础。

Hi-UCD^[133]:该数据集同样面向城市场景,研究区域为爱沙尼亚首都塔林。由2017年至2019年获取的1 293对大小为1 024×1 024像素的航空图像构成,空间分辨率为0.1 m/像素,是目前公开数据集中分辨率最高的数据集之一,其涵盖了水体、草地、林地、裸地、建筑物、温室、道路和桥梁等9类土地变化类别。

JL1-SCD:该数据集是面向农田类型变化检测的竞赛数据集,由吉林一号遥感卫星获取的6 000幅光学图像构成,每幅图像的空间分辨率为0.75 m/像素,大小为256×256像素。与SECOND等数据集采用的“从-到”标注方式不同,JL1-SCD采用单标签标注形式,共包含耕地-建筑、耕地-道路等8种变化类型和5种变化类别。

表 4 语义变化检测数据集

Table 4 Semantic change detection datasets

| 数据集 | 图像尺寸/(像素×像素) | 图像数量 | 变化类别 | 空间分辨率/m | 图像来源 | 发布时间 |
|-----------------------------------|--------------------------|--------|------|---------|---------------------------|---------|
| HRSCD ^[30] | 10 000×10 000 | 291 | 5 | 0.5 | 航拍图像 | 2019-10 |
| xBD ^[132] | 1 024×1 024 | 11 034 | 3 | 0.8 | Maxar | 2019-11 |
| Hi-UCD ^[133] | 1 024×1 024 | 1 293 | 9 | 0.1 | 航拍图像 | 2020-11 |
| JL1-SCD | 256×256 | 6 000 | 5 | 0.75 | 吉林一号 | 2020-12 |
| SECOND ^[134] | 512×512 | 4 662 | 6 | 0.5~3.0 | 航拍图像 | 2021-10 |
| SpaceNet 8 ^[135] | 1 300×1 300 | 12 | 4 | 0.3~0.8 | Maxar | 2022-06 |
| Dynamic EarthNet ^[136] | 1 024×1 024 | 54 750 | 7 | 3 | Fusion monitoring product | 2022-06 |
| Landsat-SCD ^[137] | 416×416 | 8 468 | 9 | 30 | Landsat | 2022-08 |
| BANDON ^[138] | 2 048×2 048 | 2 283 | | 0.6 | 谷歌地球 | 2023-03 |
| WUSU ^[139] | 6 358×6 382, 7 025×5 500 | 3 | 11 | 1 | GF2 | 2023-03 |
| CNAM-CD ^[140] | 512×512 | 2 503 | 5 | 0.5 | 谷歌地球 | 2023-05 |
| ChangNet ^[141] | 1 900×1 200 | 31 000 | 5 | 0.3 | WayBack 平台 | 2024-04 |
| CropSCD ^[142] | 512×512 | 4 141 | 8 | 0.5~2.0 | | 2024-07 |
| EBD ^[143] | 512×512 | 18 215 | 4 | 0.3~0.5 | WorldView-3 | 2025-08 |
| LevirSCD ^[66] | 256×256 | 3 225 | 16 | 1~2 | GF1、谷歌地球 | 2025-11 |

SECOND^[134]: 该数据集面向城市市场语义变化检测任务, 是当前最广泛使用的数据集之一, 共包含 4 662 对航空图像, 覆盖杭州、成都、上海等多个城市。单幅图像大小为 512×512 像素, 空间分辨率介于 0.5~3.0 m/像素, 包含建筑物、水体、不透水表面等 6 类变化类别及 30 种具体变化类型。

SpaceNet 8^[135]: 该数据集是一个面向洪水灾害场景的竞赛数据集, 主要针对淹没道路与建筑物。数据集中共包含 12 对洪水事件发生前后的图像, 图像大小为 1 300×1 300 像素, 空间分辨率为 0.3~0.8 m/像素, 包含 4 类变化类型。

DynamicEarthNet^[136]: 该数据集包含 2018 年至 2019 年期间获取的全球范围卫星影像, 覆盖全球 75 个感兴趣区域。共包含 54 750 张大小为 1 024×1 024 像素, 空间分辨率为 3 m/像素的光学遥感图像, 涵盖不透水面、农业用地等 7 类变化类别。

Landsat-SCD^[137]: 该数据集聚焦于 1990 年至 2020 年间新疆图木舒克市的地表变化, 共包含 9 类语义变化类型, 图像空间分辨率为 30 m/像素, 且覆盖建筑物规模较小, 分布较为分散。

BANDON^[138]: 该数据集聚焦于建筑屋顶变化, 共包含来源于谷歌地球, 大小为 2 048×2 048 像素, 空间分辨率为 0.6 m/像素的光学遥感图像, 覆盖北京、上海、武汉、深圳等代表性城市。

WUSU^[139]: 该数据集针对武汉区域开展研究, 采用 2 张来源于高分 2 号, 时间跨度为 2016 年至 2018 年的双时相光学遥感图像, 图像大小分别为 6 358×6 382 和 7 025×5 500 像素, 空间分辨率为 1 m/像素, 共包含 11 类语义变化类别以及 60 种变化类型。

CNAM-CD^[140]: 该数据集包含 2 503 对来源于谷歌地球, 时间跨度 2013 年至 2022 年的光学遥感图像, 图像大小为 512×512 像素, 空间分辨率为 0.5 m/像素, 覆盖裸地、植被、水体等 5 类语义变化类别。

ChangNet^[141]: 该数据集面向城市下的景语义变化检测, 共包含 31 000 张光学遥感图像, 空间分辨率为 0.3 m/像素, 图像大小为 1 900×1 200 像素, 覆盖中国 100 个城市, 涵盖 5 类语义变化类别。

CropSCD^[142]:该数据集包含4 141对图像大小为512×512像素,空间分辨率为0.5~2.0 m/像素的光学遥感图像。所有样本均随机采集自中国广东省农村地区,共涵盖8种语义变化类别。

EBD^[143]:该数据集是一个面向灾害评估的数据集,主要关注受灾区域的实时变化。共包含18 215张来源于WorldView-3,大小为512×512像素,空间分辨率为0.3~0.5 m/像素的光学遥感图像,其覆盖了12个分布于全球不同地区的灾害事件,且这些事件均未被纳入xBD数据集中,对现有灾害数据集实现了进一步的扩充。

LevirSCD^[66]:该数据集聚焦于北京区域,共包含来自高分1号和谷歌地球的3 225对,大小为256×256像素,空间分辨率为1~2 m/像素的光学遥感图像。共覆盖约684 km²,涵盖16类语义变化类别与210种变化类型。该数据集是当前覆盖变化类型最多的数据集,相较于常用的SECOND数据集,变化类型约为其6倍。此外,相较于当前覆盖变化语义类别最多的WUSU数据集而言,LevirSCD数据集约提升了50%。

总的来说,语义变化检测数据集呈现出从简单场景向复杂场景的发展趋势,所提出的数据集覆盖更多的语义变化类别与变化类型。从应用场景分布来看,现有的语义变化检测数据集主要聚焦于城市与自然灾害两大场景,针对其他复杂地理环境场景的语义变化检测数据集有待进一步的拓展。

3.2 变化检测任务常用评价指标

3.2.1 二元变化检测常用评价指标

对于二元变化检测任务,绝大多数评价指标均基于混淆矩阵进行构建。具体而言,混淆矩阵包含4个基本统计量:真阳性(True positive, TP)、真阴性(True negative, TN)、假阳性(False positive, FP)和假阴性(False negative, FN),分别表示被正确划分为变化类、被正确划分为未变化类、被错误划分为变化类和被错误划分为未变化类的像素的数量。基于上述统计量,代表性评价指标以及混淆矩阵 Q 如下

$$Q = \begin{bmatrix} q_{00} & q_{01} \\ q_{10} & q_{11} \end{bmatrix} \quad (5)$$

$$TP = q_{00}, TN = q_{11}, FP = q_{10}, FN = q_{01} \quad (6)$$

式中: $q_{00} \sim q_{11}$ 表示混淆矩阵中的像素数。

准确率(Overall accuracy, OA):表示所有正确分类的变化类和未变化类样本占所有样本的比例,即

$$OA = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

召回率(Recall, Rec):又称为查全率,表示的是变化类的样本有多少被预测正确,即在检测结果的所有正例中被正确找出来的比例,主要用于评估检测器对变化类的检测覆盖率。Rec被定义为

$$Rec = \frac{TP}{TP + FN} \quad (8)$$

精确率(Precision, Pre):又称为查准率,表示的是预测为变化类的样本中有多少是真正的变化类样本,即预测结果中真阳性的比例,主要用于评估检测器在成功检测的基础上的正确率。Pre被定义为

$$Pre = \frac{TP}{TP + FP} \quad (9)$$

F1分数(F1 score, F1):是统计学中用来衡量二分类模型精确度的一种指标。它同时兼顾了分类模型的精确率和召回率。F1分数是精确率和召回率的调和平均值,范围从0到1,即

$$F1 = \frac{2}{Rec^{-1} + Pre^{-1}} \quad (10)$$

交并比(Intersection over union, IoU):为了更直观地反映各类样本的区域覆盖情况,通常可使用交

并比指标来衡量真实值和预测值的交集和并集之比。值得注意的是,在二元变化检测任务中,由于未变化区域较多,如无特殊说明出现的IoU均统计变化区域。

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (11)$$

卡帕系数(Kappa coefficient, KC):KC可以较好地反映各类的性能,对检测结果进行全局的评估,其计算公式为

$$\text{KC} = \frac{\text{OA} - P_e}{1 - P_e} \quad (12)$$

$$P_e = \frac{(\text{TP} + \text{FP})(\text{TP} + \text{FN}) + (\text{TN} + \text{FN})(\text{TP} + \text{TN})}{(\text{TP} + \text{TN} + \text{FP} + \text{FN})^2} \quad (13)$$

3.2.2 语义变化检测常用评价指标

相较于二元变化检测,语义变化检测需要对变化区域及地物的变化类型或演化趋势进行更加精细的区分与刻画。与二元变化检测类似,在对多分类变化检测任务的性能进行评估之前需要进行混淆矩阵的统计计算,多分类下的混淆矩阵为

$$\mathbf{Q} = \begin{bmatrix} q_{00} & \cdots & q_{1n} \\ \vdots & & \vdots \\ q_{n1} & \cdots & q_{nm} \end{bmatrix} \quad (14)$$

准确率(Overall accuracy, OA):在语义变化检测任务中,OA的计算方式与二元变化检测一致,其定义为混淆矩阵主对角线元素之和与样本总数之比,衡量模型整体的分类准确性。

$$\text{OA} = \frac{\sum_{i=0}^N q_{ii}}{\sum_{i=0}^N \sum_{j=0}^N q_{ij}} \quad (15)$$

式中: N 表示类别数, q_{ii} 与 q_{ij} 分别表示混淆矩阵中第 i 类被正确分类的像素数以及真实类别为 i 、预测类别为 j 的像素。

分离Kappa系数(Separated Kappa coefficient, SeK)^[69]:是一个基于Kappa系数的改进变体,主要用于语义变化检测。在传统KC的计算过程中,未变化类的真阳性样本 q_{00} 常常占据主导作用,从而掩盖对于变化类别的评价。为缓解这一问题,在计算SeK时将 q_{00} 从整体统计中进行分离,以削弱未变化类别对评价结果的影响。同时为了加强变化类的比重,SeK引入额外的指数计算形式强调变化类别的作用,其定义如下

$$\text{SeK} = \frac{e^{\text{IoU}_c - 1}(\rho - \eta)}{1 - \eta} \quad (16)$$

$$\text{IoU}_c = \frac{\sum_{i=1}^N \sum_{j=1}^N q_{ij}}{\sum_{i=0}^N \sum_{j=0}^N q_{ij} - q_{00}} \quad (17)$$

$$\rho = \frac{\sum_{i=1}^N q_{ii}}{\sum_{i=0}^N \sum_{j=0}^N q_{ij}} \quad (18)$$

$$\eta = \frac{\sum_{i=1}^N \left(\sum_{j=0}^N q_{ij} * \sum_{j=0}^N q_{ji} \right)}{\left(\sum_{i=0}^N \sum_{j=0}^N q_{ij} \right)^2} \quad (19)$$

式中:IoU_c表示变化类别的交并比, ρ 为正样本的全局准确率, η 为正样本预测结果与真实分布的匹配程度。

在变化检测任务中,由于未变化像素通常占据绝大多数,整体精度易受到类别不平衡问题的显著影响,而难以准确反映模型的实际检测性能。因此,一般取F1、IoU以及SeK作为主要评价指标。其中,F1重点衡量模型在变化区域上的检测能力;IoU能够综合反映变化区域与未变化区域的整体分割精度;而SeK通过有效削弱未变化像素对评价结果的干扰,更加关注变化区域的语义判别准确性。

4 总结及展望

本文以时间演进为主线,系统梳理了近年来基于深度学习的光学遥感图像变化检测方法,并对相关数据集与评测指标进行了全面总结。同时,围绕变化检测方法的整体处理流程进行拆解,详细分析了各环节的进展与现状,旨在帮助读者对该领域形成更加系统性的认识。总的来说,光学遥感图像变化检测领域正在稳步前进,但在未精准配准条件下的变化检测、广域尺度下的变化感知以及时序建模等方面仍探索不足,未来具有潜在研究价值的方向包括但不限于以下方面:

(1)未精确配准的变化检测。现有变化检测方法几乎均依赖于高精度配准的双时相光学遥感图像进行训练与验证,而在实际应用中,实现双时相图像的精确配准往往具有较高难度。尤其是在应急响应等场景下,受限于时间与人力成本,难以达到精确配准的效果。尽管已有部分研究^[46,144]对该问题进行了初步探索,但仍主要局限于配准误差较小的情形。因而,研究面向较大程度未精确配准甚至完全未配准条件下的变化检测方法是未来值得探究的一个方向。

(2)广域变化检测。遥感图像的本质在于对大范围地理区域的观测,然而现有变化检测方法多在较小或经裁剪的图像块上进行训练与验证,这在一定程度上限制了对全局信息的捕获。针对上述问题,研究超长距离上下文信息的高效建模机制,增强模型对跨区域语义关联及全局结构演变的刻画能力是未来值得研究的一个方向。

(3)时序变化检测。随着遥感卫星观测能力的持续提升,密集多时相高分辨率遥感图像已逐渐成为地表变化监测的重要数据支撑。然而,现有光学遥感图像变化检测方法多集中于时间跨度较大的双时相范式,难以充分刻画地物的连续演化过程。相比之下,时序变化检测通过利用丰富的时序信息,能够更为细致地建模地物的演化规律与变化趋势。因此,时序变化检测是未来值得研究的一个方向。

站在技术快速演进的大道上,本文有望为读者构建一条较为完整的光学遥感图像变化检测研究路线,并为把握该领域未来的发展方向提供有益参考。

参考文献:

- [1] 李德仁. 利用遥感影像进行变化检测[J]. 武汉大学学报(信息科学版), 2003, 28(S1): 7-12.
LI Deren. Change detection from remote sensing images[J]. Geomatics and Information Science of Wuhan University, 2003, 28(S1): 7-12.
- [2] 李德仁,夏松,江万寿. 基于正射影像匹配的地形变化检测与更新算法[J]. 地理与地理信息科学, 2006, 22(6): 9-11.
LI Deren, XIA Song, JIANG Wanshou. Approach for terrain change detection and updating based on orthoimage matching[J]. Geography and Geo-Information Science, 2006, 22(6): 9-11.

- [3] 李德仁,夏松,江万寿,等.一种地形变化检测与DEM更新的方法研究[J].武汉大学学报(信息科学版),2006,31(7): 565-568.
LI Deren, XIA Song, JIANG Wanshou, et al. Approach for terrain change detection and DEM updating[J]. *Geomatics and Information Science of Wuhan University*, 2006, 31(7): 565-568.
- [4] COPPIN P, LAMBIN E, JONCKHEERE I, et al. Digital change detection methods in natural ecosystem monitoring: A review[J]. *Analysis of Multi-temporal Remote Sensing Images*, 2002, 2: 3-36.
- [5] 杜俊翰,赖健,王雪,等.基于多尺度注意力特征与李生判别的遥感影像变化检测及其抗噪性研究[J]. *数据采集与处理*, 2022, 37(1): 35-48.
DU Junhan, LAI Jian, WANG Xue, et al. Change detection of remote sensing image based on siamese multi-scale attention network and its anti-noise ability research[J]. *Journal of Data Acquisition and Processing*, 2022, 37(1): 35-48.
- [6] 王光辉,张涛,刘宇,等.遥感智能解译大模型发展及其耕地变化检测应用展望[J]. *国土资源导刊*, 2025, 22(4): 10-23.
WANG Guanghui, ZHANG Tao, LIU Yu, et al. Development of large-scale remote sensing intelligent interpretation model and its application prospects in farmland change detection[J]. *Land & Resources Herald*, 2025, 22(4): 10-23.
- [7] 马智,王鹏,胡秋萍,等.面向复杂场景的矿区建筑物变化检测模型[J]. *能源科技*, 2025, 23(5): 27-32, 61.
MA Zhi, WANG Peng, HU Qiuping, et al. Discussion on data acquisition and cybersecurity protection for integrated management of power utility operations[J]. *Energy Science and Technology*, 2025, 23(5): 27-32, 61.
- [8] SINGH A. Change detection in the tropical forest environment of northeastern India using Landsat[J]. *Remote Sensing and Tropical Land Management*, 1986, 44: 273-254.
- [9] 史大义,毛学刚.基于中空间分辨率遥感影像的县域尺度森林覆盖变化检测[J]. *森林工程*, 2025, 41(5): 912-921.
SHI Dayi, MAO Xuegang. Forest cover change detection at county scale based on medium spatial resolution remote sensing images[J]. *Forest Engineering*, 2025, 41(5): 912-921.
- [10] THIEN B B, PHUONG V T. Using landsat satellite imagery for assessment and monitoring of long-term forest cover changes in Dak Nong province, Vietnam[J]. *Geographica Pannonica*, 2023, 27(1): 69-82.
- [11] 郭擎,朱丽娅,李安,等.基于NDVI变化检测的滑坡遥感精细识别[J]. *遥感技术与应用*, 2022, 37(1): 17-23.
GUO Qing, ZHU Liya, LI An, et al. Landslide identification method based on NDVI change detection[J]. *Remote Sensing Technology and Application*, 2022, 37(1): 17-23.
- [12] DONG L, SHAN J. A comprehensive review of earthquake-induced building damage detection with remote sensing techniques [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2013, 84: 85-99.
- [13] HAFNER S, FANG H, AZIZPOUR H, et al. Continuous urban change detection from satellite image time series with temporal feature refinement and multi-task integration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5627118.
- [14] WEISMILLER R A, KRISTOF S J, SCHOLZ D K, et al. Change detection in coastal zone environments[J]. *Photogrammetric Engineering and Remote Sensing*, 1977, 43(12): 1533-1539.
- [15] TODD W J. Urban and regional land use change detected by using Landsat data[J]. *Journal of Research of the U.S. Geological Survey*, 1977, 5(5): 529-534.
- [16] CELIK T. Unsupervised change detection in satellite images using principal component analysis and k-means clustering[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 6(4): 772-776.
- [17] BOVOLO F, BRUZZONE L. A theoretical framework for unsupervised change detection based on change vector analysis in the polar domain[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 45(1): 218-236.
- [18] SUN Y, LEI L, GUAN D, et al. Iterative robust graph for unsupervised change detection of heterogeneous remote sensing images[J]. *IEEE Transactions on Image Processing*, 2021, 30: 6277-6291.
- [19] NEGRI R G, FRERY A C, CASACA W, et al. Spectral-spatial-aware unsupervised change detection with stochastic distances and support vector machines[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(4): 2863-2876.
- [20] HUO C, ZHOU Z, LU H, et al. Fast object-level change detection for VHR images[J]. *IEEE Geoscience and Remote Sensing Letters*, 2009, 7(1): 118-122.
- [21] ZHONG P, WANG R. A multiple conditional random fields ensemble model for urban area detection in remote sensing optical images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(12): 3978-3988.
- [22] 殷守敬,吴传庆,王桥,等.多时相遥感影像变化检测方法研究进展综述[J]. *光谱学与光谱分析*, 2013, 33(12): 3339-3342.

- YIN Shoujing, WU Chuanqing, WANG Qiao, et al. Review of change detection methods using multi-temporal remotely sensed images[J]. *Spectroscopy and Spectral Analysis*, 2013, 33(12): 3339-3342.
- [23] 陆海刚, 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.
- [24] 卓力, 于婉婷, 贾童瑶, 等. 基于 Transformer 的遥感图像变化检测研究进展[J]. *北京工业大学学报*, 2025, 51(7): 851-866.
ZHUO Li, YU Wanting, JIA Tongyao, et al. Research progress of Transformer-based remote sensing image change detection [J]. *Journal of Beijing University of Technology*, 2025, 51(7): 851-866.
- [25] 程焱, 王光兴, 韩军伟. 深度学习遥感变化检测综述: 典型算法及发展趋势[J]. *遥感学报*, 2025, 29(6): 1587-1597.
CHENG Gong, WANG Guangxing, HAN Junwei. Deep learning for change detection in remote sensing: A review and new outlooks[J]. *National Remote Sensing Bulletin*, 2025, 29(6): 1587-1597.
- [26] 佟国峰, 李勇, 丁伟利, 等. 遥感影像变化检测算法综述[J]. *中国图象图形学报*, 2015, 20(12): 1561-1571.
TONG Guofeng, LI Yong, DING Weili, et al. Review of remote sensing image change detection[J]. *Journal of Image and Graphics*, 2015, 20(12): 1561-1571.
- [27] 姜凯悦, 赵竹新, 马璐, 等. 基于深度学习的遥感影像变化检测方法进展综述[J]. *无线电工程*, 2025, 55(2): 343-356.
JIANG Kaiyue, ZHAO Zhuxin, MA Lu, et al. Review of development on changing detection methods of remote sensing images based on deep learning[J]. *Radio Engineering*, 2025, 55(2): 343-356.
- [28] 孙剑明, 赵梦鑫, 郝旭耀. 遥感图像变化检测方法研究综述[J]. *计算机工程与应用*, 2024, 60(20): 30-48.
SUN Jianming, ZHAO Mengxin, HAO Xuyao. Research review of remote sensing image change detection methods[J]. *Computer Engineering and Applications*, 2024, 60(20): 30-48.
- [29] LV Z, LIU T, BENEDIKTSSON J A, et al. Land cover change detection techniques: Very-high-resolution optical images: A review[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2021, 10(1): 44-63.
- [30] DAUDT R C, LE SAUX B, BOULCH A, et al. Multitask learning for large-scale semantic change detection[J]. *Computer Vision and Image Understanding*, 2019, 187: 102783.
- [31] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2012, 25: 1097-1105.
- [32] AMIN A M E, LIU Q, WANG Y. Convolutional neural network features based change detection in satellite images[C]// *Proceedings of First International Workshop on Pattern Recognition*. [S.l.]: SPIE, 2016: 181-186.
- [33] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding[C]// *Proceedings of the 22nd ACM International Conference on Multimedia*. [S.l.]: ACM, 2014: 675-678.
- [34] OTSU N. A threshold selection method from gray-level histograms[J]. *Automatica*, 1975, 11: 23-27.
- [35] DAUDT R C, LE SAUX B, BOULCH A. Fully convolutional siamese networks for change detection[C]// *Proceedings of 2018 25th IEEE International Conference on Image Processing (ICIP)*. [S.l.]: IEEE, 2018: 4063-4067.
- [36] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]// *Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, 2015: 234-241.
- [37] 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.
- [38] ZHANG H, LIN M, YANG G, et al. ESCNet: An end-to-end superpixel-enhanced change detection network for very-high-resolution remote sensing images[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 34(1): 28-42.
- [39] LEI T, WANG J, NING H, et al. Difference enhancement and spatial-spectral nonlocal network for change detection in VHR remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 4507013.
- [40] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017, 30: 5998-6008.
- [41] CHEN H, QI Z, SHI Z. Remote sensing image change detection with transformers[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2021, 60: 5607514.
- [42] ZHANG C, WANG L, CHENG S, et al. SwinSUNet: Pure transformer network for remote sensing image change detection

- [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5224713.
- [43] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]//*Proceedings of the IEEE/CVF International Conference On Computer Vision*. [S.l.]: IEEE, 2021: 10012-10022.
- [44] SONG L, XIA M, WENG L, et al. Axial cross attention meets CNN: Bibranch fusion network for change detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 16: 21-32.
- [45] FENG Y, JIANG J, XU H, et al. Change detection on remote sensing images using dual-branch multilevel intertemporal network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 4401015.
- [46] ZHANG H, CHEN H, ZHOU C, et al. BIFA: Remote sensing image change detection with bitemporal feature alignment[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5614317.
- [47] HU H, CHEN Y, XU J, et al. Learning implicit feature alignment function for semantic segmentation[C]//*Proceedings of European Conference on Computer Vision*. Cham: Springer, 2022: 487-505.
- [48] GU A, DAO T. Mamba: Linear-time sequence modeling with selective state spaces[C]//*Proceedings of First Conference on Language Modeling*. San Francisco: Openreview, 2024.
- [49] ZHAO S, CHEN H, ZHANG X, et al. RS-Mamba for large remote sensing image dense prediction[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5633314.
- [50] ZHANG H, CHEN K, LIU C, et al. CDMamba: Incorporating local clues into mamba for remote sensing image binary change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 3545012.
- [51] ZHOU S, XU C, FAN G, et al. SPRMamba: A mamba-based saliency proportion reconciliatory network with squeezed windows for remote sensing change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 3587704.
- [52] QU Z, XU L, CHEN Z, et al. SP4CD: A hierarchical stripe patch-based method for change detection in remote sensing images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5652415.
- [53] DING L, LIU T, LIU X, et al. ChessMamba: Structure-aware interleaving of state spaces for change detection in remote sensing images[J]. *arXiv preprint arXiv: 2511.19882*, 2025.
- [54] PENG D, BRUZZONE L, ZHANG Y, et al. SCDNet: A novel convolutional network for semantic change detection in high resolution optical remote sensing imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2021, 103: 102465.
- [55] XIANG S, WANG M, JIANG X, et al. Dual-task semantic change detection for remote sensing images using the generative change field module[J]. *Remote Sensing*, 2021, 13(16): 3336.
- [56] LI Z, WANG X, FANG S, et al. A decoder-focused multitask network for semantic change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5609115.
- [57] ZHOU C, ZHANG H, GUO H, et al. A late-stage bitemporal feature fusion network for semantic change detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2025, 22: 6001105.
- [58] ZHENG Z, ZHONG Y, TIAN S, et al. ChangeMask: Deep multi-task encoder-transformer-decoder architecture for semantic change detection[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 183: 228-239.
- [59] DING L, ZHANG J, GUO H, et al. Joint spatio-temporal modeling for semantic change detection in remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5610814.
- [60] WANG Q, JING W, CHI K, et al. Cross-difference semantic consistency network for semantic change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4406312.
- [61] GUO H, LIU C, ZHANG H, et al. TaCo: Capturing spatio-temporal semantic consistency in remote sensing change detection [J]. *arXiv preprint arXiv: 2511.20306*, 2025.
- [62] ZHANG Z, WANG X, JUNG C. DCSR: Dilated convolutions for single image super-resolution[J]. *IEEE Transactions on Image Processing*, 2018, 28(4): 1625-1635.
- [63] DONG X, BAO J, CHEN D, et al. CSWin transformer: A general vision transformer backbone with cross-shaped windows [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2022: 12124-12134.
- [64] JI S, XU W, YANG M, et al. 3D convolutional neural networks for human action recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 35(1): 221-231.
- [65] CHEN H, SONG J, HAN C, et al. ChangeMamba: Remote sensing change detection with spatiotemporal state space model

- [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 4409720.
- [66] ZHANG H, GUO H, CHEN K, et al. FoBa: A foreground-background co-guided method and new benchmark for remote sensing semantic change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 5653919.
- [67] LIU X, DAI C, DING L, et al. GSTM-SCD: Graph-enhanced spatio-temporal state space model for semantic change detection in multi-temporal remote sensing images[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2025, 230: 73-91.
- [68] WIJENAYAKE B, RATNAYAKE A, SUMANASEKARA P, et al. Mamba-FCS: Joint spatio-frequency feature fusion, change-guided attention, and SeK loss for enhanced semantic change detection in remote sensing[J]. arXiv preprint arXiv: 2508.08232, 2025.
- [69] WANG T, BAI T, XU C, et al. AtrousMamba: An atrous-window scanning visual state space model for remote sensing change detection[J]. arXiv preprint arXiv: 2507.16172, 2025.
- [70] 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. [S.l.]: IEEE, 2016: 770-778.
- [71] LIU M, SHI Q, CHAI Z, et al. PA-Former: Learning prior-aware transformer for remote sensing building change detection[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 6515305.
- [72] BASAVARAJU K S, SRAVYA N, LAL S, et al. UCDNet: A deep learning model for urban change detection from bi-temporal multispectral Sentinel-2 satellite images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5408110.
- [73] XIE E, WANG W, YU Z, et al. SegFormer: Simple and efficient design for semantic segmentation with transformers[J]. Advances in Neural Information Processing Systems, 2021, 34: 12077-12090.
- [74] CHEN K, LIU C, LI W, et al. Time travelling pixels: Bitemporal features integration with foundation model for remote sensing image change detection[C]//Proceedings of 2024 IEEE International Geoscience and Remote Sensing Symposium. [S.l.]: IEEE, 2024: 8581-8584.
- [75] DONG S, HU Y, WANG L B, et al. PefCD: Leveraging vision foundation models with parameter-efficient fine-tuning for remote sensing change detection[J]. arXiv preprint arXiv: 2509.09572, 2025.
- [76] LI K, CAO X, MENG D. A new learning paradigm for foundation model-based remote-sensing change detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5610112.
- [77] SUN X, WANG P, LU W, et al. RingMo: A remote sensing foundation model with masked image modeling[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5612822.
- [78] BI H, FENG Y, TONG B, et al. RingMoE: Mixture-of-modality-experts multi-modal foundation models for universal remote sensing image interpretation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 48: 4388-4405.
- [79] GUO X, LAO J, DANG B, et al. SkySense: A multi-modal remote sensing foundation model towards universal interpretation for earth observation imagery[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2024: 27672-27683.
- [80] WU K, ZHANG Y, RU L, et al. A semantic-enhanced multi-modal remote sensing foundation model for Earth observation[J]. Nature Machine Intelligence, 2025, 7(8): 1235-1249.
- [81] HU E J, SHEN Y, WALLIS P, et al. LoRA: Low-rank adaptation of large language models[J]. arXiv preprint arXiv: 2016.09685, 2021.
- [82] KIRILLOV A, MINTUN E, RAVIN, et al. Segment anything[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. [S.l.]: IEEE, 2023: 4015-4026.
- [83] RAVIN, GABEUR V, HU Y T, et al. SAM 2: Segment anything in images and videos[C]//Proceedings of the Thirteenth International Conference on Learning Representations. Singapore: Openreview, .
- [84] SIMÉONI O, VO H V, SEITZER M, et al. Dinov3[J]. arXiv preprint arXiv: 2508.10104, 2025.
- [85] HE K, CHEN X, XIE S, et al. Masked autoencoders are scalable vision learners[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2022: 16000-16009.
- [86] DAI D, DENG C, ZHAO C, et al. DeepSeekMoE: Towards ultimate expert specialization in mixture-of-experts language models[C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics. [S.l.]: [s.n.], 2024: 1280-1297.
- [87] DE BEM P P, DE CARVALHO JUNIOR O A, FONTES GUIMARÃES R, et al. Change detection of deforestation in the

- Brazilian amazon using landsat data and convolutional neural networks[J]. *Remote Sensing*, 2020, 12(6): 901.
- [88] HOU B, LIU Q, WANG H, et al. From W-Net to CDGAN: Bitemporal change detection via deep learning techniques[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 58(3): 1790-1802.
- [89] BAO T, FU C, FANG T, et al. PPCNET: A combined patch-level and pixel-level end-to-end deep network for high-resolution remote sensing image change detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 17(10): 1797-1801.
- [90] 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.
- [91] 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: 8007805.
- [92] ZHOU Z, RAHMAN SIDDIQUEE M M, TAJBAKHS N, et al. UNet++: A nested U-Net architecture for medical image segmentation[C]//*Proceedings of International Workshop on Deep Learning in Medical Image Analysis*. Cham: Springer, 2018: 3-11.
- [93] WANG L, YOU Z H, LU W, et al. Attention-aware sobel graph convolutional network for remote sensing image change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4409912.
- [94] CHEN H, ZHANG H, CHEN K, et al. Continuous cross-resolution remote sensing image change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5623320.
- [95] HUANG J, SHEN Q, WANG M, et al. Multiple attention Siamese network for high-resolution image change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5406216.
- [96] LI Z, YAN C, SUN Y, et al. A densely attentive refinement network for change detection based on very-high-resolution bitemporal remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4409818.
- [97] WANG D, CHEN X, JIANG M, 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.
- [98] LV Z, WANG F, CUI G, et al. Spatial-spectral attention network guided with change magnitude image for land cover change detection using remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4412712.
- [99] 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.
- [100] FENG Y, XU H, JIANG J, et al. ICIF-Net: Intra-scale cross-interaction and inter-scale feature fusion network for bitemporal remote sensing images change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 4410213.
- [101] ZHANG M, SHI W. A feature difference convolutional neural network-based change detection method[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 58(10): 7232-7246.
- [102] PAPADOMANOLAKI M, VERMA S, VAKALOPOULOU M, et al. Detecting urban changes with recurrent neural networks from multitemporal Sentinel-2 data[C]//*Proceedings of IGARSS 2019—2019 IEEE International Geoscience and Remote Sensing Symposium*. [S.l.]: IEEE, 2019: 214-217.
- [103] 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.
- [104] CAO Z, WU M, YAN R, et al. Detection of small changed regions in remote sensing imagery using convolutional neural network[C]//*Proceedings of IOP Conference Series: Earth and Environmental Science*. [S.l.]: IOP Publishing, 2020: 012017.
- [105] LIU Y, PANG C, ZHAN Z, et al. Building change detection for remote sensing images using a dual-task constrained deep siamese convolutional network model[J]. *IEEE Geoscience and Remote Sensing Letters*, 2020, 18(5): 811-815.
- [106] PENG D, BRUZZONE L, ZHANG Y, et al. SemiCDNet: A semisupervised convolutional neural network for change detection in high resolution remote-sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 59(7): 5891-5906.
- [107] SUN C, WU J, CHEN H, et al. SemiSAnet: A semi-supervised high-resolution remote sensing image change detection model using siamese networks with graph attention[J]. *Remote Sensing*, 2022, 14(12): 2801.
- [108] LEBEDEV M A, VIZILTER Y V, VYGOLOV O V, et al. Change detection in remote sensing images using conditional adversarial networks[J]. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2018, 42: 565-571.

- [109] ISOLA P, ZHU J Y, ZHOU T, et al. Image-to-image translation with conditional adversarial networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2017: 1125-1134.
- [110] LIU A, LIU X, FAN J, et al. Perceptual-sensitive GAN for generating adversarial patches[C]//Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2019: 1028-1035.
- [111] FANG B, PAN L, KOU R. Dual learning-based siamese framework for change detection using bi-temporal VHR optical remote sensing images[J]. *Remote Sensing*, 2019, 11(11): 1292.
- [112] LIU J, XUAN W, GAN Y, et al. An end-to-end supervised domain adaptation framework for cross-domain change detection [J]. *Pattern Recognition*, 2022, 132: 108960.
- [113] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]// Proceedings of the IEEE International Conference on Computer Vision. [S.l.]: IEEE, 2017: 2223-2232.
- [114] BENEDEK C, SZIRÁNYI T. Change detection in optical aerial images by a multilayer conditional mixed Markov model[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(10): 3416-3430.
- [115] DAUDT R C, LE SAUX B, BOULCH A, et al. Urban change detection for multispectral earth observation using convolutional neural networks[C]//Proceedings of IGARSS 2018—2018 IEEE International Geoscience and Remote Sensing Symposium. [S.l.]: IEEE, 2018: 2115-2118.
- [116] JI S, WEI S, LU M. Fully convolutional networks for multisource building extraction from an open aerial and satellite imagery data set[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 57(1): 574-586.
- [117] VAN ET TEN A, HOGAN D, MANSO J M, et al. The multi-temporal urban development spacenet dataset[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2021: 6398-6407.
- [118] SHI Q, LIU M, LI S, 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*, 2022, 60: 5604816.
- [119] 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.
- [120] LIU M, CHAI Z, DENG H, et al. A CNN-transformer network with multiscale context aggregation for fine-grained cropland change detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 4297-4306.
- [121] ZHOU M, SUI H, CHEN S, et al. UGRoadUpd: An unchanged-guided historical road database updating framework based on bi-temporal remote sensing images[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(11): 21465-21477.
- [122] SHEN Q, HUANG J, WANG M, et al. Semantic feature-constrained multitask siamese network for building change detection in high-spatial-resolution remote sensing imagery[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 189: 78-94.
- [123] ZHANG X, YU W, PUN M O, et al. Cross-domain landslide mapping from large-scale remote sensing images using prototype-guided domain-aware progressive representation learning[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2023, 197: 1-17.
- [124] ZHANG J, SHAO Z, DING Q, et al. AERNet: An attention-guided edge refinement network and a dataset for remote sensing building change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5617116.
- [125] HOLAIL S, SALEH T, XIAO X, et al. AFDE-Net: Building change detection using attention-based feature differential enhancement for satellite imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 1-5.
- [126] SUN Z, ZHONG Y, WANG X, et al. Identifying cropland non-agriculturalization with high representational consistency from bi-temporal high-resolution remote sensing images: From benchmark datasets to real-world application[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024, 212: 454-474.
- [127] LIU Y, ZHANG K, GUAN C, et al. Building change detection in earthquake: A multi-scale interaction network with offset calibration and a dataset[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5635217.
- [128] LIU S, ZHAO D, ZHOU Y, et al. Network and dataset for multiscale remote sensing image change detection[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 18: 2851-2866.
- [129] YU W, ZHANG X, GLOAGUEN R, et al. MineNetCD: A benchmark for global mining change detection on remote sensing imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 5647916.
- [130] HUANG J, BAO J, XIA M, et al. SAM-based efficient feature integration network for remote sensing change detection: A

- case study on macao sea reclamation[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 16916-16928.
- [131] ZHANG H, YANG S, NING X, et al. Hyper-neighborhood context-aware transformer network for high-resolution remote sensing change detection[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2025, 144: 104861.
- [132] GUPTA R, GOODMAN B, PATEL N, et al. Creating xBD: A dataset for assessing building damage from satellite imagery [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.]: IEEE, 2019: 10-17.
- [133] TIAN S, MA A, ZHENG Z, et al. Hi-UCD: A large-scale dataset for urban semantic change detection in remote sensing imagery[J]. *arXiv preprint arXiv: 2011.03247*, 2020.
- [134] YANG K, XIA G S, LIU Z, et al. Asymmetric siamese networks for semantic change detection in aerial images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5609818.
- [135] HÄNSCH R, ARNDT J, LUNGA D, et al. Spacenet 8-the detection of flooded roads and buildings[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2022: 1472-1480.
- [136] TOKER A, KONDMANN L, WEBER M, et al. DynamiCearthNet: Daily multi-spectral satellite dataset for semantic change segmentation[C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2022: 21158-21167.
- [137] YUAN P, ZHAO Q, ZHAO X, et al. A transformer-based siamese network and an open optical dataset for semantic change detection of remote sensing images[J]. *International Journal of Digital Earth*, 2022, 15(1): 1506-1525.
- [138] PANG C, WU J, DING J, et al. Detecting building changes with off-nadir aerial images[J]. *Science China Information Sciences*, 2023, 66(4): 140306.
- [139] SHI S, ZHONG Y, LIU Y, et al. Multi-temporal urban semantic understanding based on GF-2 remote sensing imagery: From tri-temporal datasets to multi-task mapping[J]. *International Journal of Digital Earth*, 2023, 16(1): 3321-3347.
- [140] ZHOU Y, WANG J, DING J, et al. Signet: A siamese graph convolutional network for multi-class urban change detection[J]. *Remote Sensing*, 2023, 15(9): 2464.
- [141] JI D, GAO S, TAO M, et al. Changenet: Multi-temporal asymmetric change detection dataset[C]//*Proceedings of ICASSP 2024—2024 IEEE International Conference on Acoustics, Speech and Signal Processing*. [S.l.]: IEEE, 2024: 2725-2729.
- [142] LIU M, LIN S, ZHONG Y, et al. A memory-guided network and a novel dataset for cropland semantic change detection[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 4410013.
- [143] WANG Z, WU C, ZHANG F, et al. Constructing an extensible building damage dataset via semi-supervised fine-tuning across 12 natural disasters[J]. *Journal of Remote Sensing*, 2025, 5: 0733.
- [144] JING W, CHI K, LI Q, et al. ChangeRD: A registration-integrated change detection framework for unaligned remote sensing images[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2025, 220: 64-74.

作者简介:



史振威(1977-),通信作者,男,教授,博士生导师,研究方向:图像处理、模式识别、深度学习、遥感图像处理等, E-mail: shizhenwei@buaa.edu.cn。



张浩田(1996-),男,博士研究生,研究方向:深度学习、遥感图像解译、变化检测等。



郭涵(2001-),男,博士研究生,研究方向:遥感图像处理、深度学习、模式识别等。



邹征夏(1991-),男,教授,博士生导师,研究方向:深度学习、遥感图像处理、计算机视觉等。

A Review of Deep Learning-Based Change Detection Methods for Bi-temporal Optical Remote Sensing Images

SHI Zhenwei*, ZHANG Haotian, GUO Han, ZOU Zhengxia

(School of Astronautics, Beihang University, Beijing 100191, China)

Abstract: Bi-temporal optical remote sensing image change detection constitutes a pivotal domain within the broader field of Earth observation, aimed at systematically quantifying terrestrial surface dynamics. By conducting comparative analyses of co-registered imagery acquired over identical geographical coordinates at distinct temporal intervals, this methodology facilitates critical applications ranging from urban expansion monitoring and resource management to disaster damage assessment. The exponential expansion of remote sensing data, coupled with the precipitous maturation of deep learning paradigms, has instigated a transformative era for this discipline. Consequently, the field is witnessing a phase of rapid algorithmic iteration and profound evolutionary growth, significantly enhancing the capability to interpret complex spatiotemporal patterns. Against this backdrop, this manuscript employs a comprehensive chronological framework to systematically represent deep learning-based change detection architectures established over the past two decades. Complementing this survey, it rigorously conducts a comparative analysis, explicitly evaluating both the detection accuracy and computational efficiency of these state-of-the-art methodologies across mainstream benchmark datasets. Beyond mere algorithmic review, the paper consolidates widely utilized public datasets and essential evaluation metrics, thereby providing a standardized reference for benchmarking model performance. Furthermore, this study structurally deconstructs the comprehensive change detection pipeline into its fundamental components. Subsequently, the specific technological advancements and methodological innovations driving the evolution of each critical stage are scrutinized in granular detail to illustrate the workflow's maturation. Ultimately, prospective research frontiers are delineated to forecast the field's developmental trajectory. This outlook aims to serve as a roadmap, offering essential reference and guidance to steer subsequent investigations and foster continued innovation within the domain.

Highlights:

1. Adopting a rigorous chronological framework, this paper systematically surveys the landscape of deep learning-based change detection methodologies designed for bi-temporal optical remote sensing imagery. It meticulously maps the algorithmic evolution spanning the past two decades, illustrating the trajectory from foundational neural networks to complex, contemporary deep learning architectures.
2. This study structurally deconstructs the comprehensive change detection pipeline, dissecting the task into its fundamental components. It offers a granular analysis of the technological evolution within each key module, meticulously scrutinizing the specific algorithmic innovations and architectural refinements that have driven the progressive maturation of the entire processing framework.
3. This manuscript systematically consolidates mainstream public datasets and standard evaluation metrics, serving as a resource for algorithmic benchmarking. Furthermore, it projects a forward-looking vision of emerging research hotspots to provide direction for future scholarly inquiries in this domain.

Key words: change detection; bi-temporal remote sensing images; deep learning; review paper

Foundation items: National Natural Science Foundation of China (Nos.62125102,U24B20177).

Received: 2026-01-11; **Revised:** 2026-02-26

***Corresponding author, E-mail:** shizhenwei@buaa.edu.cn.