

# 新增建设用地卫星遥感智能监测技术研究

刘力荣, 唐新明, 甘宇航, 尤淑撑, 刘克, 罗征宇

自然资源部国土卫星遥感应用中心, 北京 100048

**摘要:** 为适应自然资源监测、土地执法督察等对高精度、高频率新增建设用地信息提取的应用需求, 本研究构建了新增建设用地卫星遥感智能监测的技术框架。该框架包括“时空谱类”监测超立方体、监测底图生成、样本标注迭代、组件式AI变化检测模型构建、图斑知识筛选及精化后处理等步骤。为满足大区域、复杂场景的精准应用需求, 本研究充分结合注意力机制、域适应、视觉Transformer等人工智能优势算法及网络结构, 研发了组件式AI变化检测模型, 以提升算法准确性和可靠性。针对自动提取图斑出现的误提取、图斑破碎、边缘不准等问题, 充分利用地学知识进行业务规则约束, 并研究图斑精化后处理方法。本研究通过开展新增建设用地大尺度遥感监测分区时实验, 验证了“时空谱类”监测超立方体思路的可行性; 开展了AI变化检测模型组件消融实验, 对比分析各算法优劣, 结果表明, 视觉Transformer模块在新增建设用地提取的完整性、边缘准确性、查全率方面呈现明显优势; 另外, 基于卫星影像督查执法部分业务数据, 开展了云覆盖筛选实验, 筛选出误提取图斑所占比例约0.84%, 同时, 采用图斑精细化后处理方法, 进一步提升了监测成果的精确性、实用性。本文提出的新增建设用地卫星遥感智能监测技术方法, 目前已在土地执法督查等自然资源监测监管业务中得到应用。

**关键词:** 卫星遥感, 人工智能, 新增建设用地, 变化检测

**中图分类号:** P227

**引用格式:** 刘力荣, 唐新明, 甘宇航, 尤淑撑, 刘克, 罗征宇. 2024. 新增建设用地卫星遥感智能监测技术研究. 遥感学报, 28(11): 2828-2837

Liu L R, Tang X M, Gan Y H, You S C, Liu K and Luo Z Y. 2024. Research on satellite remote sensing-based intelligent monitoring technologies for new construction land. National Remote Sensing Bulletin, 28(11): 2828-2837 [DOI: 10.11834/jrs.20244063]

## 1 引言

地表覆被变化信息提取是自然资源调查监测的主要任务之一, 其中, 新增建设是主要的地表覆被变化和重要的人类活动表征指标。近年来, 受城市化扩张等影响, 土地违法占用问题日渐突出, 新增建设用地成为国土空间开发的重点督查监管对象。随着卫星遥感传感器及应用技术的发展, 卫星遥感已逐步成为中国自然资源高效监测监管的重要技术手段。为有效提高自然资源监测能力, 对各类违法占地行为, 实现“早发现、早制止”的自然资源督查管理目标, 迫切需要利用遥感影像变化检测技术对各类建设用地的变化信息进行高精度、高频次提取。

遥感变化检测是根据不同时相卫星观测影像确定地表覆盖状态变化的过程, 变化检测方法主要分为传统方法与基于深度学习的方法两大类, 传统方法可分为基于差分影像、基于特征以及基于目标的变化检测方法。传统方法存在无法脱离人工干预, 自动化程度较低等问题, 且容易受到影像成像条件、影像获取周期、影像对间匹配质量以及噪声等方面的影响。随着深度学习在遥感领域的逐步推广, 神经网络强大的特征表达和拟合能力, 为影像变化检测任务带来了新思路。自2012年AlexNet网络(Krizhevsky等, 2012)提出以来, 每年都有结构、性能更好的神经网络被提出, 如FCN(Long等, 2015)、U-Net(Ronneberger等, 2015)、ResNet(He等, 2016)、UNet++(Zhou

收稿日期: 2024-02-26; 预印本: 2024-08-21

基金项目: 国家自然科学基金青年科学基金(编号:42101410); 国家重点研发计划(编号:2023YFE0207900); 自然资源部国土卫星遥感应用重点实验室自主研究课题(编号:BN2302-5)

第一作者简介: 刘力荣, 研究方向为地表覆盖遥感监测的理论和应用。E-mail: liulirong1125@163.com

通信作者简介: 唐新明, 研究方向为卫星测绘遥感技术研究和工程应用。E-mail: txm@lasac.cn

等, 2018)、Efficientnet(Tan和Le, 2020)、Transformer(Vaswani等, 2023)等, 基于这些网络衍生出了许多变化检测方法。当前, 大多数深度学习方法将遥感影像变化检测任务视为语义分割任务, 以获得输入像对中每个像素的变化情况, 且多数模型参考了经典模型U-Net的Encoder-Decoder网络架构设计, 使用该架构改进的语义分割模型有DeepLab V3+(Chen等, 2018)、Semantic FPN(Kirillov等, 2019)等, 变化检测模型有SNUNet-CD(Fang等, 2022)、STANet(Chen和Shi, 2020)等。近年来, 大量基于Transformer模块的变化检测算法被提出(Zhang等, 2023b; Ding等, 2024; Zhang等, 2023a; Chen等, 2022; Zhang等, 2022), 在全局特征学习方面表现出强大的性能。

目前, 基于深度学习的影像变化检测方法能够端到端的自主学习影像上变化区域的高维特征, 然而该方法依赖海量的标注数据, 需要耗费大量成本, 使得该类方法在大区域、复杂场景下的遥感影像解译任务中仍然面临诸多挑战(陶超等, 2021)。如模型场景适应性差、知识应用不充分、提取结果边界不准确等(张继贤等, 2022)。实际的卫星遥感监测业务往往涉及影像数据源、样本构建、数据预处理、变化信息提取、后处理等多个环节, 均会对监测成果精度产生影响, 需系统性分析。因此, 本文基于国产多传感器影像, 面对大范围的新增建设用地提取需求, 综合分析监测底图构建、样本标注、AI变化检测模型、图斑知识筛选及后处理等多个技术流程, 构建新增建设用地卫星遥感智能监测技术框架, 同时, 集中优势人工智能算法, 研发组件式AI变化检测模型, 并以全国卫星遥感影像执法督查业务实践, 验证技术框架的可行性和模型精度, 以期为自然资源调查监测、土地执法督察、耕地保护等自然资源管理工作提供技术支撑。

## 2 遥感智能监测技术框架与研究方法

面向耕地保护、执法督查、国土空间规划实施监督等自然资源监测业务对于新增建设用地信息的大范围、高精度、高频次获取需求, 基于多源、多尺度国产卫星遥感数据, 突破“时空谱类”监测超立方体设计、监测底图自动生成、样本标

注迭代、组件式AI变化检测模型构建、图斑知识筛选及后处理等核心技术, 建立新增建设用地卫星遥感智能监测技术框架(图1), 形成智能遥感监测产品及分区域、分时相、分光谱、分类别的卫星遥感监测数据库, 服务于自然资源监测监管工作。该技术框架的具体步骤如下:

(1) “时空谱类”智能监测超立方体。监测底图、样本库及模型池的构建是遥感智能解译的核心环节, 对于影像、样本、模型均从区域、时相、光谱、传感器、要素类型等多个维度进行筛选生成, 建立时、空、谱、类、层等索引机制, 实现高效、精准的新增建设用地智能监测。

(2) 多载荷遥感监测底图自动生成。基于多传感器卫星遥感正射影像DOM数据, 按照星源、分辨率、时相、云量、区域等条件进行自动优选, 并对筛选影像数据开展统计计算、拉伸、镶嵌、缓存切片、监测数据包生成、WMTS服务发布等处理, 形成监测影像底图数据。

(3) 自动/交互式样本采集迭代。根据各类建设用地区域、时相、尺度、波段等遥感影像上的光谱、纹理、形状、几何拓扑、空间上下文关系等特征, 建立样本采集标准。基于长时序国产卫星影像, 采用历史成果图斑自动生成、交互式语义分割标注(Hao等, 2021)、自动解译结果筛选迭代等方法构建低成本、高质量样本。

(4) 组件式AI变化检测模型构建。采用深度学习端到端的变化检测思路, 以“编码—解码—孪生网络”为基础架构, 结合多尺度特征融合、注意力机制、域适应、视觉Transformer、知识图谱耦合等优势算法, 进行灵活的算法组件集成, 构建面向精准监测应用的组件式AI变化检测模型。在“时空谱类”框架下, 基于要素类型、区域、时相、光谱及对应样本量, 选取AI模型组件, 训练精准应用模型。

(5) 图斑知识筛选及精化处理。对智能解译模型提取的变化图斑矢量开展制图综合、边缘规则化等处理, 基于对象置信度及高程信息、云雪覆盖区、水域范围、遥感指数等地学知识构建图斑筛选模型, 通过知识决策, 进一步提升新增建设用地监测图斑的准确性。

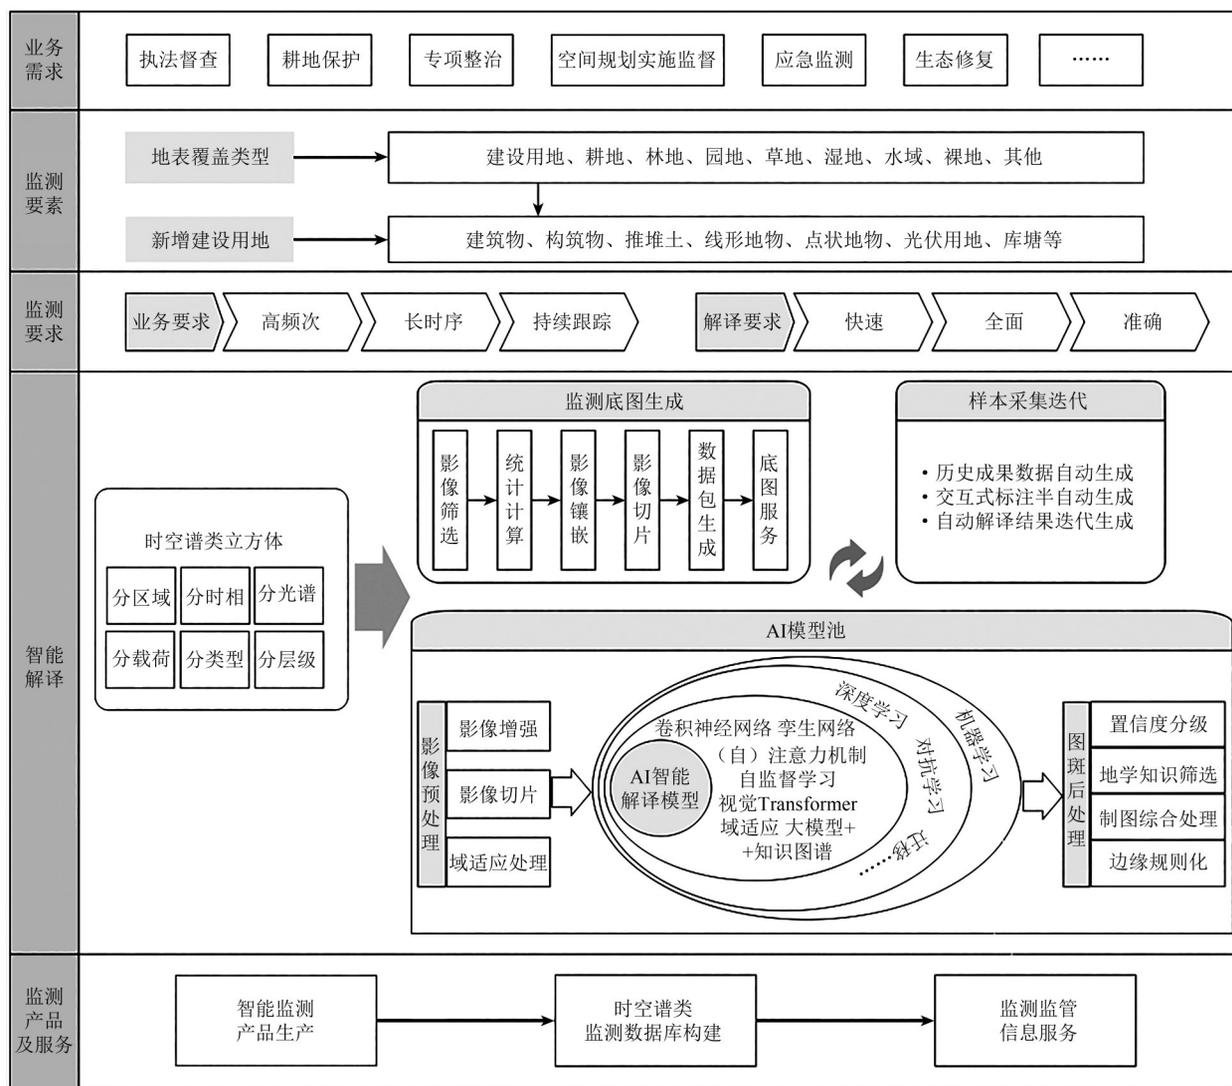


图1 新增建设用地卫星遥感智能监测技术框架

Fig.1 Technical framework for intelligent monitoring of new construction land by satellite remote sensing

2.1 组件式AI变化检测模型

本文将孪生网络和语义分割常用的编码—解码 (Encoder-Decoder) 结构相结合, 构建了“编码—解码—孪生网络”基础变化检测模型框架, 详见图2。编码器采用2个共享权值的孪生CNN特征提取层构成, 特征提取网络支持ResNet、DenseNet (Huang 等, 2017)、Xception (Chollet, 2017)、EfficientNet等典型骨干网络; 编码器的输入为不同时相影像, 经孪生CNN网络处理, 形成多尺度特征, 进而引入空洞空间金字塔池化ASPP (Atrous Spatial Pyramid Pooling) (He等, 2014)、注意力机制、视觉Transformer等AI组件, 可获取多层级的特征差异图并做融合处理; 然后通过解码器的反卷积、特征合并、上采样等计算, 逐渐恢复特征图的细节信息和空间维度, 进而输出是否发生变

化的概率分布, 并通过计算变化预测图和变化参考真值之间的交叉熵等损失来不断更新网络参数, 最终获取与输入尺寸相同的变化预测图。

模型中增加空洞空间金字塔池化、注意力机制、视觉Transformer等AI组件的目的主要是充分利用影像的多尺度、多通道、空间上下文、语义特征等信息, 实现影像特征增强与精化。

另外, 前后时相影像由于拍摄环境、时间不同, 往往在色彩分布、纹理特征和上下文信息上存在明显的辐射特征差异, 因此模型在预处理阶段引入基于统计准则 (Panaretos和Zemel, 2019) 或基于深度网络 (Li等, 2019; Zhu等, 2017) 的域适应方法, 以实现输入影像的风格一致化处理。本文采用基于循环一致性对抗学习 (Zhu等, 2017) 的方法进行域适应处理。

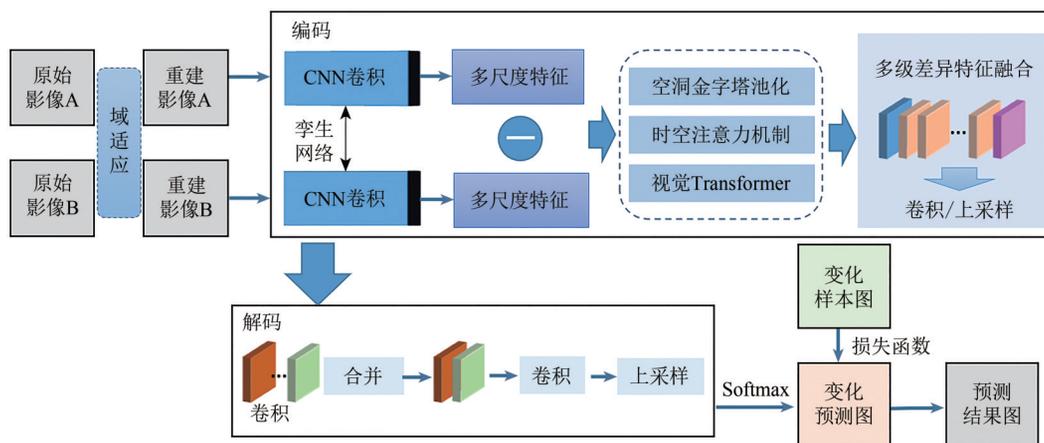


图2 组件式 AI 变化检测模型  
Fig. 2 Component-based AI change detection model

2.2 图斑知识筛选及精化处理

2.2.1 基于地学知识的图斑筛选

在大尺度的新增建设用地提取应用中，由于影像云雾遮挡、冰雪覆盖、阴影、季节变化以及临时的飞机、轮船、集装箱等特殊地物，导致系统性的新增建设目标误提取。因此，对于自动提取图斑，充分利用云雪覆盖区、水域范围、高程信息、植被/水体/建筑面积/阴影指数等地学知识进行决策筛选，以大幅减少误检测。云雪覆盖区对所有的新增建设用地类型均产生影响，需提取其范围，系统剔除伪图斑；对于新增建（构）筑物、推填土、线形地物、光伏、挖湖造景等具体的变化类型，以水域、高程、遥感指数等信息联合国土变更调查等历史数据进行综合筛选。

以云覆盖区域筛选为例，采用 MaskRCNN (He等, 2017) 实例分割算法，自动提取云覆盖矢量范围 (图3)，云覆盖范围内的图斑视为误检测，进行图斑筛选剔除。

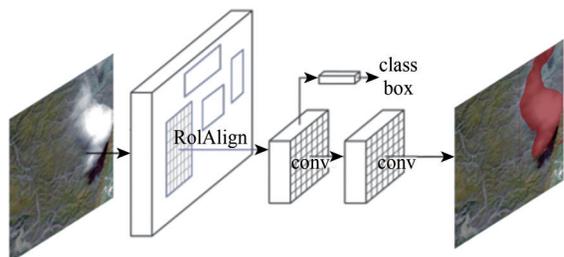


图3 基于实例分割的云检测  
Fig.3 Cloud detection based on instance segmentation

2.2.2 图斑精细化后处理

通过 AI 模型自动提取的新增建设用地变化图

斑 (图4)，往往存在相邻切片对象分割、小图斑零散分布、图斑内孔洞、边界不规则等问题，需进行图斑矢量聚合、筛选填充、边缘简化及规则化等后处理，以进一步精化自动提取结果。

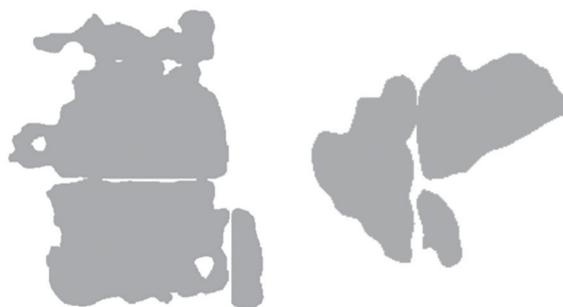


图4 自动提取新增建设用地(推填土)图斑示例  
Fig.4 Automatically extracted parcels of new construction land

(1) 基于邻近度判别的图斑聚合。针对新增建设用地图斑的特点，提出一种综合了图斑置信度语义相似度、空间距离及交叠面积的邻近度判别模型和准则 (Liu 等, 2022)，进行相邻图斑的聚合处理。

对每个图斑矢量进行缓冲区计算，对于任意2个缓冲区相交的图斑对象  $M$ 、 $N$ ，图斑间的邻近度  $P_{com}$  计算公式如下：

$$P_{com}[M, N] = \delta_1 P_{sem\_pre}[M, N] + \delta_2 P_{spa\_dis}[M, N] + \delta_3 P_{are\_lap}[M, N] \quad (1)$$

式中， $P_{sem\_pre}$  为图斑间的语义相似度，与图斑的分类置信度概率相关； $P_{spa\_dis}$  为空间邻近度，基于2个图斑间的最短距离推算； $P_{are\_lap}$  为缓冲区交叠面积率，与缓冲区与图斑的相交相关。 $\delta_1$ 、 $\delta_2$ 、 $\delta_3$  为置信度、空间、面积各影响因素的权值，且  $\delta_1 +$

$\delta_2 + \delta_3 = 1$ 。根据实际应用需求, 设定邻近度阈值  $P_{\text{thresh}}$  进行图斑聚合。

(2) 矢量边缘简化和规则化。针对自动提取的变化图斑存在的形状不规则、边缘呈锯齿状等特点, 为减少冗余节点, 采用道格拉斯—普克算法 (Douglas 和 Peucker, 1973) 进行图斑的边缘简化, 通过识别并移除多边形中影响线要素整体形状的较小节点来简化数据, 其容差参数决定了图斑边缘的简化程度, 容差越大, 简化程度越大。对于图斑的规则化, 以多边形建筑物图斑规则化为例, 采用多边形折线分段线性近似方法 (Gribov 和 Bodansky, 2004) 对图斑轮廓点进行分段规则化, 获得分段折线顶点以拟合建筑物形状。

(3) 筛选和填充。根据不同新增建设用地类别的特点及应用需求, 按照一定的面积阈值  $A_{\text{thresh}}$ , 对较小图斑进行删除处理; 同时设定图斑中孔洞保留的面积阈值  $H_{\text{thresh}}$ , 填充变化图斑中小于该面积的孔洞; 进而, 基于图斑对象的置信度  $p$ , 按照实际业务需求, 输出不同置信范围的变化图斑。

### 3 新增建设用地卫星遥感监测实验

#### 3.1 实验设计

实验采用国产 2 m 级光学卫星遥感影像作为数据源进行新增建设用地样本采集及模型测试, 包括资源三号 ZY3-02/03、高分一号 GF-1 B/C/D 等。样本在全国大部分范围内, 基于历史存档的土地利用变化图斑进行半自动修正采集获取, 样本由前时相、后时相及标签文件构成, 对于新增建设用地样本, 前时相可以为耕、园、林、草等众多地类, 后时相为建(构)筑物、推填土、道路等类型。本文主要采用全国获取的约 7 万个新增建(构)筑物样本开展对比分析实验, 样本尺度统一为 512 像素×512 像素, 样本采集主要基于 2019 年—2022 年的历史数据, 前时相主要为第四季度影像, 后时相分一、二、三和四季度进行归类。

为评价模型精度, 采用平均交并比 MIoU 作为标准度量, 计算真实值和预测值 2 个集合的交集和并集之比, 计算公式如下:

$$\text{MIoU} = \frac{1}{n + 1} \times \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (2)$$

式中,  $n$  为变化类别数, TP 为真正例, 即正确检测出的变化数, TN 为真负例, 即正确检测出的非变化数, FP 为假正例, 即非变化被误检测为变化的数量, FN 为假负例, 即变化区域未被检测的个数, 即漏检数。

组件式 AI 变化检测模型基于 Pytorch 平台开发, 实验中模型训练采用 6 张 Tesla V100 GPU 卡, 设定训练轮次为 200, 初始学习率为 0.0005。

#### 3.2 大尺度监测分区时实验

为验证本文构建的“时空谱类”智能监测框架对于新增建设用地提取精度的影响, 开展大尺度监测分区时实验, 采用统一 AI 变化检测模型, 分区域、分季度分别训练和预测模型, 对比分析检测精度。

区域划分方面, 按照中国四大地理行政区划方式, 可将全国划分为北方地区、南方地区、西北地区和青藏地区。基于 7 万个新增建(构)筑物样本, 按照全国、北方、南方 3 个区域范围筛选样本集  $D_A$ 、 $D_N$ 、 $D_S$ , 并进一步在  $D_N$  和  $D_S$  数据集的基础上分别筛选出第三季度的样本集  $D_{N_s3}$  和  $D_{S_s3}$ , 各样本集数量如表 1 所示。对 5 个样本集分别采用基础的 AI 变化检测模型 (Resnet50 特征提取骨干网结合 UNet++ 密集特征融合及孪生网络), 按照训练集/验证集 8:2 的比例进行模型训练, 并分别选取北方、南方各 2000 张左右的影像测试集  $T_N$  和  $T_S$  开展模型预测及精度分析。

表 1 大尺度监测分区时实验结果

Table 1 Experiment results of large scale monitoring by region and time

| 区域 | 季节  | 样本集        | 样本数/万 | 验证<br>MIoU 值/% | 测试<br>集 | 预测<br>MIoU 值/% |
|----|-----|------------|-------|----------------|---------|----------------|
| 全国 | 全季度 | $D_A$      | 7.2   | 71.10          | $T_N$   | 71.89          |
|    |     |            |       |                | $T_S$   | 70.40          |
| 北方 | 全季度 | $D_N$      | 3.1   | 71.30          | $T_N$   | 72.08          |
|    |     |            |       |                | $T_S$   | 68.62          |
|    | 第三季 | $D_{N_s3}$ | 0.9   | 75.44          | $T_N$   | 75.25          |
|    |     |            |       |                | $T_S$   | 72.05          |
| 南方 | 全季度 | $D_S$      | 2.9   | 71.58          | $T_N$   | 70.30          |
|    |     |            |       |                | $T_S$   | 71.83          |
|    | 第三季 | $D_{S_s3}$ | 0.8   | 73.16          | $T_N$   | 70.20          |
|    |     |            |       |                | $T_S$   | 72.15          |

经分区域、分季节筛选后测得的模型验证 MIoU 精度结果见图 5。相比全国模型 MIoU 71.10% 均有所提升，提升范围在 0.20%—4.34%，经分析，通过区域、季节限定后的样本集受地域差异、季节差异、辐射差异影响更小，其影像域更加集中，训练过程也更加容易拟合，因此样本的验证精度也相应提升。

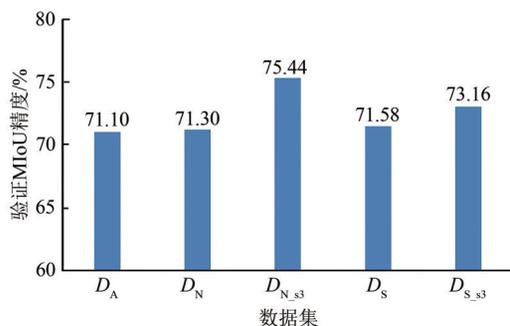


图5 分区分时样本集训练精度

Fig. 5 Validation accuracy of training on different data sets

分区分时的模型预测 MIoU 精度结果见图 6，可见：基于全国、南北区域、季度模型分别在测试集  $T_N$  和  $T_S$  上开展预测， $D_A$ 、 $D_N$ 、 $D_{N,s3}$  与  $D_A$ 、 $D_S$ 、 $D_{S,s3}$  2 组数据集获取的模型预测精度均呈现上升趋势；经过分区、分时模型训练后，同一区域的实际预测结果也有一定提升，本实验 MIoU 提升精度最高可达 3.36%；另外，结合表 1 的结果，经过分区、分时后，同一模型在南、北 2 个测试集上的表现差异也更大，如  $D_{N,s3}$  数据集训练模型在  $T_N$ 、 $T_S$  2 个测试集上的 MIoU 相差 3.46%，而全国  $D_A$  数据集的预测精度差异仅为 1.49%。

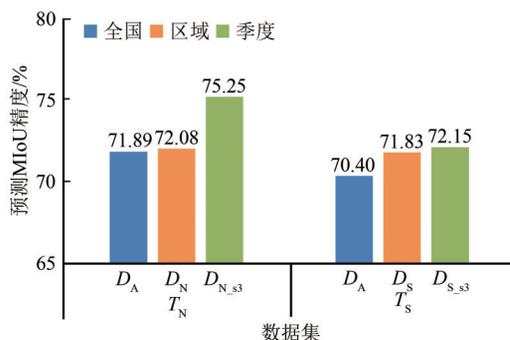


图6 分区分时模型预测精度

Fig. 6 Testing accuracy of different models

实验结果表明，跨区域、跨季节样本及其训练模型对变化检测精度有直接影响，本实验中单季节的模型预测精度相比全季节模型预测 MIoU 提

升可超过 3%，跨区域预测相比本区域模型精度也相差超过 3%。因此在保证一定数量的情况下，应对样本进行区域、时相、光谱等的精细化分类，以满足精准应用需求。

### 3.3 AI变化检测模型组件消融实验

为验证组件式 AI 变化检测模型效果，基于基础变化检测模型 (Base)，分别对域适应 DA (Domain Adaptation)、卷积注意力机制 CBAM (Convolutional Block Attention Module) (Woo 等, 2018)、视觉 Transformer BIT (Bitemporal Image Transformer) (Chen 等, 2022) 等模块开展模型组件消融实验，对比分析不同算法对于新增建设用地智能提取效果的影响。

选取北方第三季度建(构)筑物约 0.9 万样本数据集  $D_{N,s3}$  开展实验，训练和验证数据比例为 8:2，并选取北方区域 2000 张影像切片集  $T_N$  进行测试并进行定量评估。各模型的验证、测试 MIoU 精度结果见表 2。可见：在基础模型中加入注意力机制、域适应及视觉 Transformer 等模块，模型的验证及预测 MIoU 均有所提升，其中，加入视觉 Transformer 模块，验证和预测精度均提升了 5% 以上。结合图 7 中各模型预测结果示例对比分析，加入 CBAM 注意力机制后新增建筑物的提取轮廓精确度有一定提升，经分析，CBAM 将通道与空间注意力机制结合，整体提升了卷积神经网络中的感受野，一方面通道注意力增强了网络的特征表达力，提高模型对重要特征的表达力，另一方面空间注意力增强了图像局部区域表征能力，提升了目标提取的空间准确性。但 CBAM 在关注重要特征边缘细节的同时，模型的泛化性能仍不稳定，出现了新增建设用地部分区域漏提取的情况。模型加入域适应模块 DA 后，模型整体精度略有提升，更容易发现细小的变化，但在提升了查全率的同时也引入了伪变化图斑，经分析，当前的域适应模块进行前后时相影像域一致性处理时不可避免的导致影像部分区域失真、信息丢失等情况，域适应模块算法还需进一步改进。整体上看，视觉 Transformer 模块通过使用多头自注意力机制，可灵活地捕捉全局上下文，充分利用影像语义信息，新增建筑物提取的对象完整性、轮廓准确性、查全率均有一定提升。

表2 模型组件消融实验精度  
Table 2 Model ablation results

| 精度/%      | Base  | Base & CBAM | Base & CBAM & DA | Base & BIT |
|-----------|-------|-------------|------------------|------------|
| 验证 MIoU 值 | 75.44 | 78.07       | 79.82            | 81.31      |
| 预测 MIoU 值 | 75.25 | 77.33       | 77.80            | 80.42      |

### 3.4 筛选及图斑后处理效果

为验证云覆盖区域筛选对实际业务应用中新增建设用地提取结果的影响，实验基于全国区域

的新增建（构）筑样本集  $D_A$  训练的变化检测基础模型，对连续 10 d 获取的 2 m 及卫星影像底图（平均约 20 万  $\text{km}^2/\text{d}$ ，云量  $< 20\%$ ）进行预测提取新增建（构）筑物图斑，统计自动提取的变化图斑量，同时采用 MaskRCNN 云检测模型对每日的底图进行云覆盖区域检测，获取云覆盖矢量范围。通过矢量叠加判断，计算得到自动提取图斑落在云矢量范围内所占比例达到 0.84%，可自动判定为伪图斑。可见在影像底图有一定云雾影响的情况下，基于检测结果的云雾等地理学知识筛选能够从全局上进一步提升检测精度。

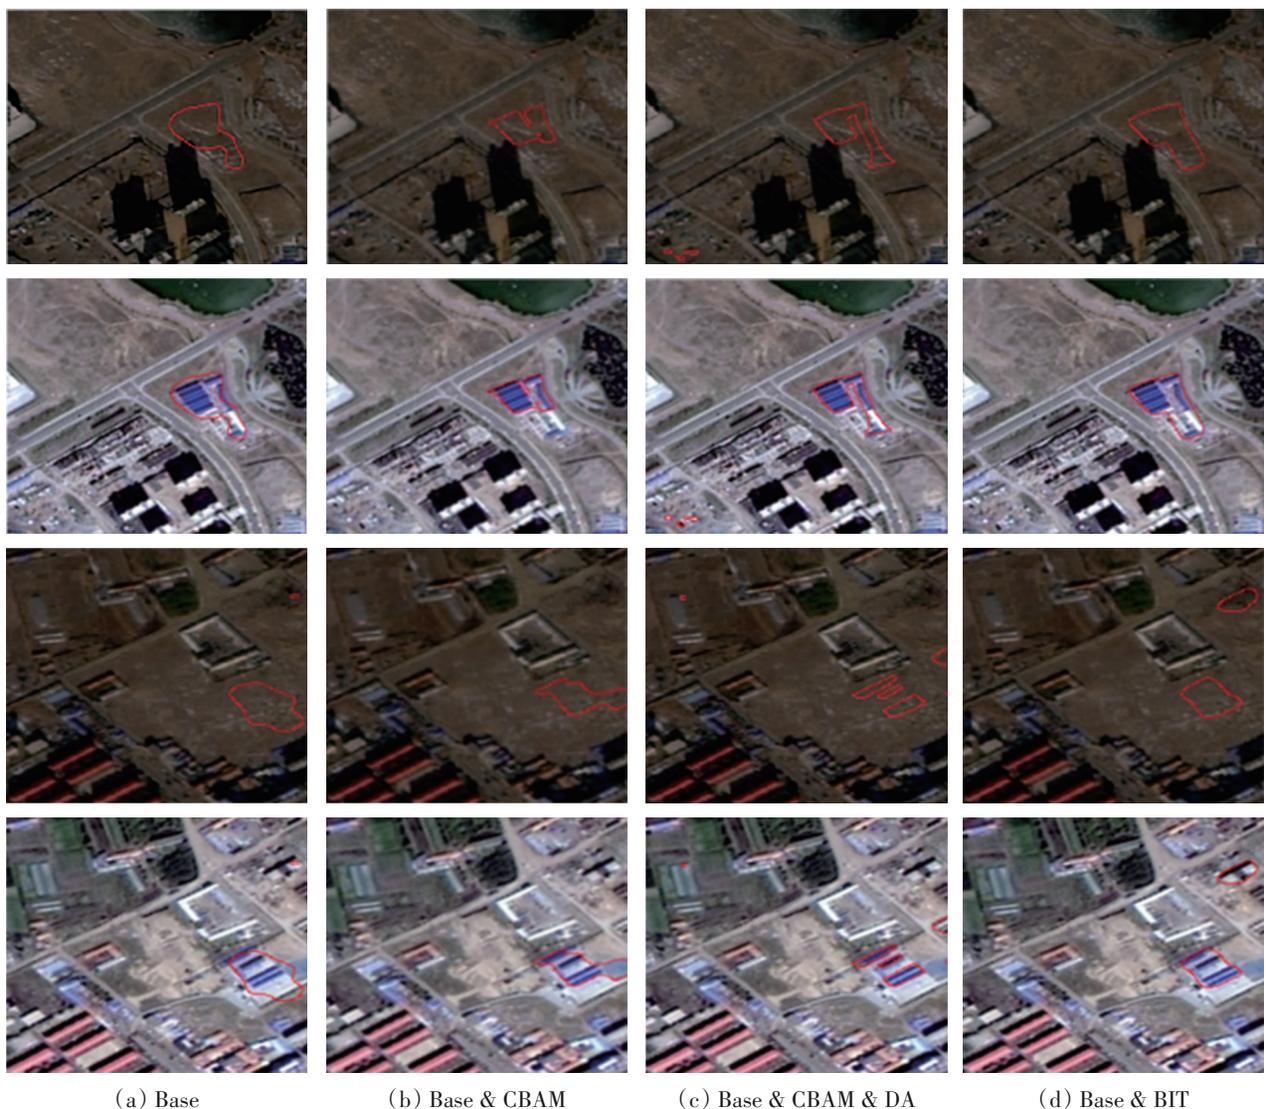


图7 新增建设用地不同模型下的检测结果对比(从上到下4个图,其中第1、2图和第3、4图分别为2组不同检测的前时相和后时相)

Fig.7 Comparison of detection results for newly constructed land

另外，基于本文提出的图斑精细化后处理方法和步骤，图8展示了新增建构筑物、推填土图斑的简化、聚合、筛选等精化后处理效果；图9给出

了新增建筑物的规则化处理效果。按照处理前后的变化图斑数统计，聚合处理可减少图斑破碎度，减少图斑数 5% 左右；面积筛选可进一步删减

2%—5%的小面积图斑，其中新增建（构）筑物相比新增推填土，小图斑所占比例偏高；按照实际业务需求，设置不同阈值进行置信度筛选，可以

大幅减少冗余图斑。整体上，图斑精细化后处理进一步提升了新增建设用地监测成果的精确性、实用性。

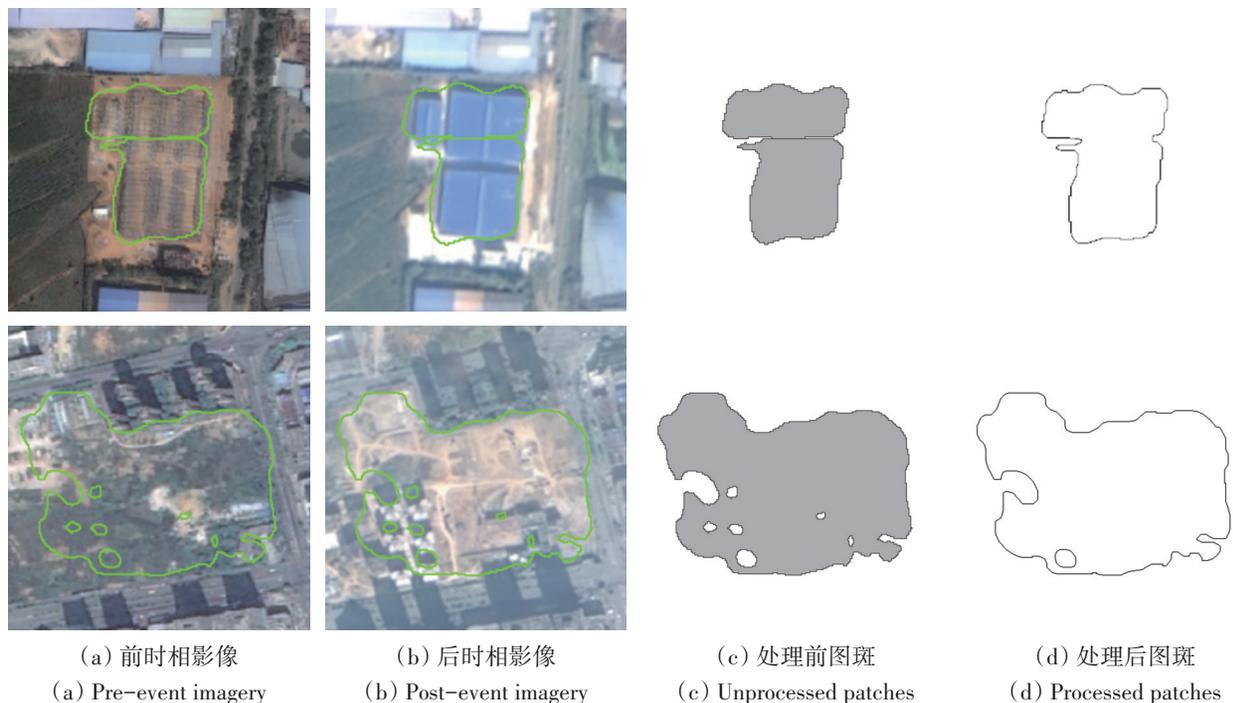


图8 新增建筑物、推填土图斑精细化后处理效果  
Fig.8 Post-processing results of newly constructed buildings and bare land

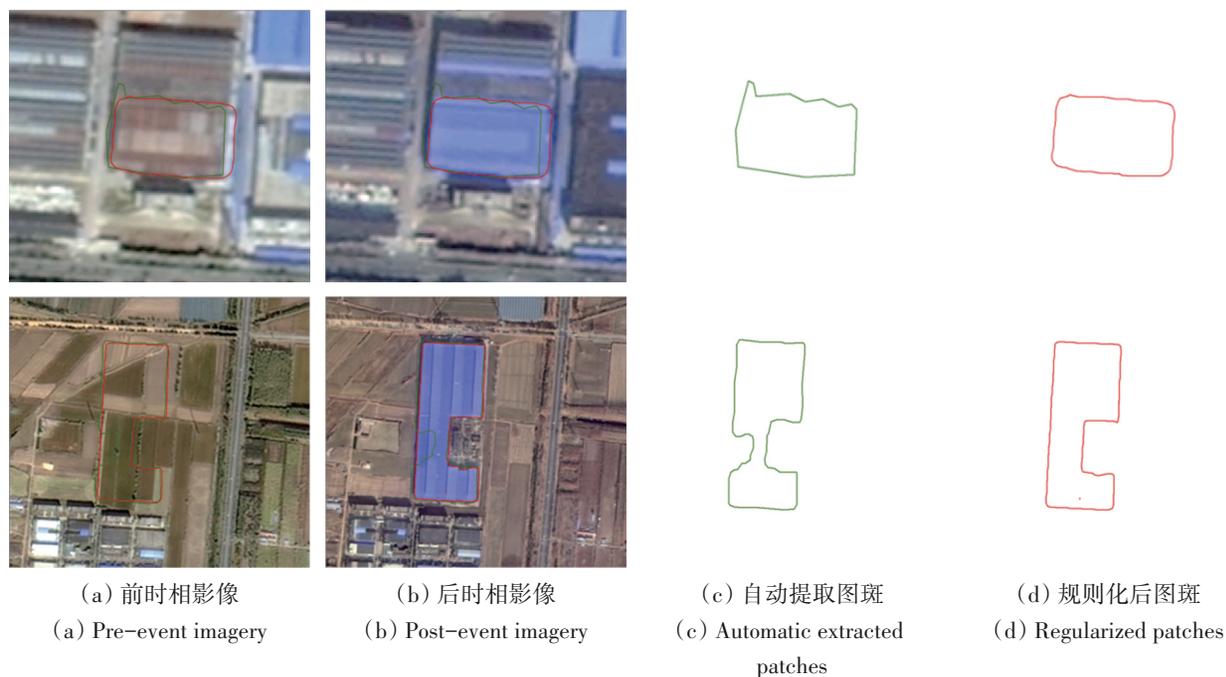


图9 新增建筑物图斑规则化处理效果  
Fig.9 Regularization results on newly constructed building parcels

## 4 结 论

面向新增建设用地的卫星遥感监测需求,从影像、样本、模型3个层面设计了“时空谱类”监测超立方体,形成由监测底图自动生成、样本标注迭代、组件式AI变化检测模型构建、图斑知识筛选及后处理等核心技术构成的新增建设用地卫星遥感智能监测的整套技术框架。重点阐述了组件式AI变化检测模型的结构和图斑知识筛选及精细化处理方法,从影像预处理、模型设计、图斑后处理全链条开展误差消除,以系统性提升新增建设用地监测成果的精确度、实用性。

文中基于国产载荷2 m级卫星遥感影像,开展了大尺度监测区分时实验、AI变化检测模型组件消融实验、云覆盖区域识别筛选及图斑精细化后处理实验,经定量精度评估及处理结果示例表明,提出的关键算法模型达到了预期效果,为新增建设用地监测实际业务应用提供了解决方案。未来随着自然资源调查监测、土地执法督察、耕地保护等自然资源管理工作对新增建设用地信息获取的尺度、频次、精度等需求日益提高及AI大模型技术的发展,需进一步改进变化检测模型结构,完善新增建设用地卫星遥感智能监测技术体系。

## 参考文献(References)

- Chen H, Qi Z P and Shi Z W. 2022. Remote sensing image change detection with transformers. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5607514 [DOI: 10.1109/TGRS. 2021. 3095166]
- Chen H and Shi Z W. 2020. A spatial-temporal attention-based method and a new dataset for remote sensing image change detection. *Remote Sensing*, 12(10): 1662 [DOI: 10.3390/rs12101662]
- Chen L C, Zhu Y K, Papandreou G, Schroff F and Adam H. 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation//15th European Conference on Computer Vision. Munich: Springer: 833-851 [DOI: 10.1007/978-3-030-01234-2\_49]
- Chollet F. 2017. Xception: deep learning with depthwise separable convolutions//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE: 1800-1807 [DOI: 10.1109/CVPR.2017.195]
- Ding L, Zhang J, Guo H T, Zhang K, Liu B and Bruzzone L. 2024. Joint spatio-temporal modeling for semantic change detection in remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5610814 [DOI: 10.1109/TGRS.2024.3362795]
- Douglas D H and Peucker T K. 1973. Algorithms for the reduction of the number of points required to represent a digitized line or its caricature. *Cartographica*, 10(2): 112-122 [DOI: 10.3138/FM57-6770-U75U-7727]
- Fang S, Li K Y, Shao J Y and Li Z. 2022. SNUNet-CD: a densely connected Siamese network for change detection of VHR images. *IEEE Geoscience and Remote Sensing Letters*, 19: 8007805 [DOI: 10.1109/LGRS.2021.3056416]
- Gribov A and Bodansky E. 2004. A new method of polyline approximation//Joint IAPR International Workshops on Structural, Syntactic, and Statistical Pattern Recognition. Lisbon: Springer: 504-511 [DOI: 10.1007/978-3-540-27868-9\_54]
- Hao Y Y, Liu Y, Wu Z W, Han L, Chen Y Z, Chen G W, Chu L T, Tang S Y, Yu Z L, Chen Z Y and Lai B H. 2021. EdgeFlow: achieving practical interactive segmentation with edge-guided flow. *arXiv: 2109.09406* [DOI: 10.48550/arXiv.2109.09406]
- He K M, Gkioxari G, Dollár P and Girshick R. 2017. Mask R-CNN//2017 IEEE International Conference on Computer Vision. Venice: IEEE: 2980-2988 [DOI: 10.1109/ICCV.2017.322]
- He K M, Zhang X Y, Ren S Q and Sun J. 2014. Spatial pyramid pooling in deep convolutional networks for visual recognition//13th European Conference on Computer Vision. Zurich: Springer: 346-361 [DOI: 10.1007/978-3-319-10578-9\_23]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Huang G, Liu Z, Van Der Maaten L and Weinberger K Q. 2017. Densely connected convolutional networks//Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE: 2261-2269 [DOI: 10.1109/CVPR.2017.243]
- Kirillov A, Girshick R, He K M and Dollár P. 2019. Panoptic feature pyramid networks//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE: 6392-6401 [DOI: 10.1109/CVPR.2019.00656]
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks//Proceedings of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe: Curran Associates Inc.: 1097-1105
- Li Y S, Yuan L and Vasconcelos N. 2019. Bidirectional learning for domain adaptation of semantic segmentation. *arXiv: 1904.10620* [DOI: 10.48550/arXiv.1904.10620]
- Liu L R, Tang X M, Gan Y H, You S C, Luo Z Y, Du L and He Y. 2022. Research on optimization of processing parcels of new bare land based on remote sensing image change detection. *Remote Sensing*, 15(1): 217 [DOI: 10.3390/rs15010217]
- Long J, Shelhamer E and Darrell T. 2015. Fully convolutional networks for semantic segmentation//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE: 3431-3440 [DOI: 10.1109/CVPR.2015.7298965]
- Panaretos V M and Zemel Y. 2019. Statistical aspects of Wasserstein distances. *arXiv:1806.05500* [DOI: 10.48550/arXiv.1806.05500]
- Ronneberger O, Fischer P and Brox T. 2015. U-net: convolutional networks for biomedical image segmentation//18th International Conference on Medical Image Computing and Computer-Assisted

- Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4\_28]
- Tan M X and Le Q V. 2020. EfficientNet: rethinking model scaling for convolutional neural networks. arXiv: 1905.11946 [DOI: 10.48550/arXiv.1905.11946]
- Tao C, Yin Z W, Zhu Q and Li H F. 2021. Remote sensing image intelligent interpretation: from supervised learning to self-supervised learning. *Acta Geodaetica et Cartographica Sinica*, 50(8): 1122-1134 (陶超, 阴紫薇, 朱庆, 李海峰. 2021. 遥感影像智能解译: 从监督学习到自监督学习. *测绘学报*, 50(8): 1122-1134)
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser L and Polosukhin I. 2023. Attention is all you need. arXiv: 1706.03762 [DOI: 10.48550/arXiv.1706.03762]
- Woo S, Park J, Lee J Y and Kweon I S. 2018. CBAM: convolutional block attention module//*Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer: 3-19 [DOI: 10.1007/978-3-030-01234-2\_1]
- Zhang C, Wang L J, Cheng S L and Li Y M. 2022. SwinSUNet: pure transformer network for remote sensing image change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5224713 [DOI: 10.1109/TGRS.2022.3160007]
- Zhang J X, Gu H Y, Yang Y, Zhang H, Li H T, Han W L and Shen J. 2022. Research progress and trend of intelligent interpretation for natural resources features. *Acta Geodaetica et Cartographica Sinica*, 51(7): 1606-1617 (张继贤, 顾海燕, 杨懿, 张鹤, 李海涛, 韩文立, 沈晶. 2022. 自然资源要素智能解译研究进展与方向. *测绘学报*, 51(7): 1606-1617)
- Zhang M X, Liu Z, Feng J, Liu L and Jiao L C. 2023. Remote sensing image change detection based on deep multi-scale multi-attention siamese transformer network. *Remote Sensing*, 15(3): 842 [DOI: 10.3390/rs15030842]
- Zhang X F, Cheng S L, Wang L J and Li H J. 2023. Asymmetric cross-attention hierarchical network based on CNN and transformer for bitemporal remote sensing images change detection. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 2000415 [DOI: 10.1109/TGRS.2023.3245674]
- Zhou Z W, Siddiquee M M R, Tajbakhsh N and Liang J M. 2018. UNet++: a nested U-Net architecture for medical image segmentation (2018). arXiv preprint arXiv: 1807.10165 [DOI: 10.48550/arXiv.1807.10165]
- Zhu J Y, Park T, Isola P and Efros A A. 2017. Unpaired image-to-image translation using cycle-consistent adversarial networks//2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE: 2242-2251 [DOI: 10.1109/ICCV.2017.244]

## Research on satellite remote sensing-based intelligent monitoring technologies for new construction land

LIU Lirong, TANG Xinming, GAN Yuhang, YOU Shucheng, LIU Ke, LUO Zhengyu

*Land Satellite Remote Sensing Application Center, Ministry of Natural Resources of the People's Republic of China, Beijing 100048, China*

**Abstract:** The accurate and frequent extraction of information regarding new construction land is essential in natural resource monitoring and land law enforcement supervision. To fulfill these practical demands, this study constructed a technical framework for the intelligent monitoring of new construction land via satellite remote sensing. The framework includes a “spatial-temporal-spectral-classified” monitoring hypercube, a base map generation for monitoring, a sample annotation iteration, component-based artificial intelligence (AI) change detection model establishment, parcel information filtering, and post-processing. To meet the demand for accurate applications in large areas and complex scenes, this study fully combined different AI algorithms and network structures, such as attention mechanism, domain adaptation, and visual transformers, to develop a component-based AI change detection model for improving the accuracy and reliability of the algorithm. Meanwhile, to address issues, such as misidentification during the automatic extraction of new construction land parcels, parcel fragmentation, and edge inaccuracy, geomorphological principles were comprehensively utilized to set constraints and investigate post-processing parcel refinement methods. Experiments by region and time were conducted on large-scale remote sensing monitoring of new construction land to verify the feasibility of the proposed concept of the “spatial-temporal-spectral-classified” monitoring hypercube. Moreover, through ablation analysis of the component-based AI change detection model, the advantages and disadvantages of the algorithms were compared and analyzed. In particular, the visual transformer module exhibits evident advantages in terms of the feature completeness, edge accuracy, and recall rate of new construction land extraction. On the basis of certain operational data of satellite image-based law enforcement and supervision, cloud cover filtering was conducted. Wrongly extracted parcels accounted for about 0.84%. In addition, after the post-processing parcel refinement method proposed in this study was adopted, the accuracy and practicability of the monitoring results were further enhanced. The satellite remote sensing-based technologies and methods for the intelligent monitoring of new construction land proposed in this study have been applied to natural resource monitoring, such as land law enforcement and supervision.

**Key words:** satellite remote sensing, artificial intelligence, newly constructed land, change detection

**Supported by** National Natural Science Foundation of China (No. 42101410); National Key Research and Development Program of China (No. 2023YFE0207900); Key Laboratory of Land Satellite Remote Sensing Application of Ministry of Natural Resources of the People's Republic of China (No. BN2302-5)