

自然资源快速执法模型优化方法研究

吴 伟

辽宁省自然资源事务服务中心, 辽宁 沈阳

收稿日期: 2026年3月27日; 录用日期: 2026年4月22日; 发布日期: 2026年4月28日

摘 要

本文针对自然资源执法效率低的问题, 提出基于深度学习的快速执法模型优化方法。构建高质量多时相遥感变化样本库, 优化样本结构与多层级标签体系。在商汤预训练模型基础上, 引入CNN-ViT融合、特征对齐及边界-区域复合损失, 实现高精度双时相变化检测。实验与实际应用表明, 模型识别精度高达95.96%, 检测效率较人工提升约10倍, 实现执法由“被动核查”向“主动发现”转变。

关键词

自然资源, 变化检测, 执法模型, 优化方法研究

Research on Optimization of Rapid Enforcement Models for Natural Resource Management

Wei Wu

Liaoning Provincial Natural Resources Service Center, Shenyang Liaoning

Received: March 27, 2026; accepted: April 22, 2026; published: April 28, 2026

Abstract

This paper addresses the low efficiency of natural resource law enforcement and proposes a deep learning-based rapid enforcement model optimization method. A high-quality multi-temporal remote sensing change detection sample library is constructed, with optimized sample structure and multi-level label system. Based on Sense Time's pre-trained model, CNN-ViT fusion, feature alignment, and boundary-region composite loss are introduced to achieve high-precision bi-temporal change detection. Experiments and practical applications show that the model achieves a recognition accuracy of 95.96% and a detection efficiency approximately 10 times higher than manual interpretation, enabling a shift from "passive inspection" to "active discovery" in law enforcement.

Keywords

Natural Resources, Change Detection, Law Enforcement Model, Optimization Method

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

自然资源监管面临违法占地、非法采矿及生态破坏等问题的持续压力，传统依赖人工巡查与遥感目视解译的执法方式在效率、覆盖范围和时效性方面存在明显局限。随着人工智能技术在遥感影像分析领域的应用不断深化，深度学习变化检测逐渐成为自然资源监管的重要技术手段。以商汤科技的 Sense Remote Layers 为代表的智能遥感解译平台在实际管理中已取得一定成效[1]，但现有通用变化检测模型在自然资源场景中仍存在样本适应性和时空特征匹配精度不足等问题[2]。为此，本文对前后时相变化检测模型进行针对性优化，以提升自然资源快速执法中的变化识别能力与应用效率。

2. 技术路线设计

自然资源快速执法模型优化技术路线见图 1。

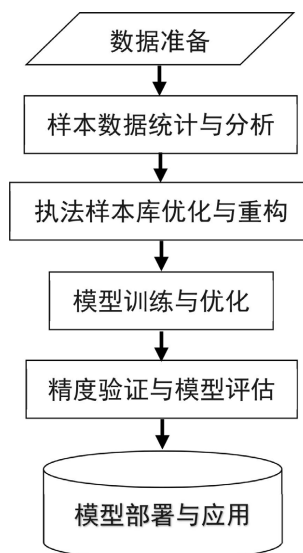


Figure 1. Model optimization technical roadmap

图 1. 模型优化技术路线图

3. 数据准备

模型训练数据来源于辽宁省历年遥感解译样本库及自然资源执法历史数据，涵盖多时相、多源高分辨率卫星影像。数据统一采用 2000 国家大地坐标系、1985 国家高程基准和高斯 - 克吕格投影。影像空间分辨率为 1 m，矢量数据采集精度控制在 3 个像素以内。通过统一空间基准与精度控制，为模型训练提供了可靠的数据基础[3] [4]。

4. 样本数据统计与分析

为提高模型在复杂自然资源场景中的泛化能力，构建了覆盖多区域、多地貌类型的遥感变化检测样本数据集，总规模约 147 万组。样本区域选取辽宁省 36 个县(区)，涵盖平原、丘陵、山地及沿海等典型地貌类型，空间分布相对均衡，可较好反映不同自然地理条件下的地表变化特征[5]。

样本影像来源于多源高分辨率遥感数据。为保证数据质量，对多时相影像进行了辐射校正、几何校正及精确配准，并将配准误差控制在 3 个像素以内，以减少几何偏移带来的伪变化[2]。

样本类别涵盖建设用地、耕地、林地、草地、水体等主要自然资源类型，其中主要变化类别样本数量充足，低频类别样本规模均在 1 万组以上，能够满足深度学习模型训练对样本规模与类别多样性的要求[6]。

4.1. 样本切片与生成方式

采用滑动窗口方法对多时相遥感影像进行切片生成变化检测样本。参数设置如下：

- 切片尺寸：512 × 512 像素；
- 空间分辨率：1 m；
- 覆盖范围：512 m × 512 m；
- 重叠率：50%；
- 滑动步长：256 像素。

通过设置 50% 的重叠率，可提高边界区域样本利用率，减少变化目标位于影像边缘导致的特征信息缺失问题，从而增强模型对小尺度变化目标的识别能力。最终共生成约 147 万组双时相变化样本。

4.2. 样本类别构成与不平衡分析

样本类别统计结果见图 2 所示。




Figure 2. Statistics of change detection samples for law enforcement

图 2. 执法变化检测类样本统计

统计结果表明，建设用地、耕地、林地和草地变化样本占比较高，而水体及其他类别样本相对较少，

整体存在一定程度的类别不均衡现象，该分布与自然资源变化实际发生频率基本一致[7]。

像素级统计显示，变化像素比例约为 6%~12%，明显低于未变化像素比例，呈现典型的前景—背景不平衡特征。该问题在遥感变化检测任务中较为普遍，易导致模型训练对未变化区域产生偏置，因此在后续训练过程中需要结合样本均衡或损失函数优化策略进行处理[8]。

5. 执法样本库优化与重构

针对原始样本结构单一、标签体系不完善及类别不均衡等问题，对执法样本库进行结构重构与标签体系优化，构建融合时序信息与执法语义属性的高质量训练样本体系[5]。

5.1. 样本结构扩展与字段重构

在原有样本矢量数据基础上对数据结构进行扩展，新增前后时相地物分类、执法属性标签及变化类型标识等关键字段，引入时序信息与执法语义信息，使样本由单一空间对象扩展为具有时序语义特征的训练样本。

结构重构后的样本体系可同时支持变化检测、误判分析、执法类型识别及困难样本挖掘等任务，从而提升样本在深度学习模型训练中的表达能力[5] [7]。

5.2. 地物分类体系优化

为统一执法场景下的语义表达，构建标准化地物分类体系，共设置 41 类，涵盖耕地、园地、林地、草地、建筑物、构筑物、露天采矿区及其他典型自然资源类型[3]。

同时建立统一分类编码规则，实现多源数据语义对齐与标签表达一致，提高样本体系的标准化程度及跨区域应用能力[4]。

5.3. 执法标签体系构建

结合变化检测与执法识别需求，设计多层次标签体系，以增强样本区分能力[7]。

1) 变化类标签

- 正例：Tag 值为 1，真实变化；
- 负例：Tag 值为 2，伪变化。

用于区分真实违法变化与光照、配准误差等伪变化情况[2]。

2) 非变化类标签

- 正例：Tag 值为 3，非变化；
- 负例：Tag 值为 4，误判(实际为变化)。

用于优化模型对边界模糊区域的识别能力[6]。

3) 执法辅助标签

- Tag1 值为 5 的样本，真实变化，非执法重点关注样本；
- Tag1 值为 6 的样本，真实变化，困难样本。

用于增强模型对复杂场景与边缘样本的学习能力[5]。

通过多标签监督机制，提高模型训练过程中的判别能力与识别精度[7]。

5.4. 样本均衡优化与数据增强

针对样本类别不均衡问题，采用重采样与数据增强策略进行优化[8]。

在数据分布调整方面，通过对低频类别进行过采样、对高频类别进行适度降采样，以平衡训练数据

结构。

在样本增强方面，通过影像旋转、翻转、尺度变化、光照扰动及时序扰动等方式扩展样本多样性，提高模型泛化能力。

此外，通过模型初步训练结果进行困难样本挖掘，识别误分类样本和高损失样本，并将其加入后续训练过程，形成迭代优化机制[5]。

6. 模型训练与优化

基于重构后的执法样本数据，构建面向自然资源快速执法场景的双时相遥感变化检测模型。模型以商汤遥感变化检测大模型为基础，通过结构适配、特征融合及训练策略优化，提高复杂地物变化识别的精度与稳定性[1][9]。

6.1. 模型架构

模型整体采用双时相输入 - 孪生特征提取 - 多尺度融合 - 变化预测 - 损失监督的结构，包括 Backbone、Neck、Head 与 Loss 四个部分。

- **Backbone:** 孪生共享编码器，提取双时相多尺度特征；
- **Neck:** 多尺度特征差分与融合，增强变化判别能力；
- **Head:** 像素级变化，输出变化概率图；
- **Loss:** 交叉熵、Dice 与边界损失组合，缓解类别不平衡问题[8]。

6.1.1. Backbone: ViT-CNN 混合编码器

主干网络采用 CNN 与 Vision Transformer 混合结构，利用 CNN 提取局部纹理特征，ViT 建模全局语义关系。双时相输入共享权重，以保证特征表达一致性。

核心公式：

$$F_{\text{cnn},t} = C(I_t), F_{\text{cnn},t+\Delta t} = C(I_{t+\Delta t}), F_{\text{vit},t} = V(F_{\text{cnn},t}), F_{\text{vit},t+\Delta t} = V(F_{\text{cnn},t+\Delta t}),$$

$$F_t = \text{Concat}(F_{\text{cnn},t}, F_{\text{vit},t}), F_{t+\Delta t} = \text{Concat}(F_{\text{cnn},t+\Delta t}, F_{\text{vit},t+\Delta t})$$

参数说明：

- $I_t, I_{t+\Delta t}$: t 与 $t + \Delta t$ 时刻双时相遥感影像，形状[B, C, H, W]；
- $B = 16, C = 3/4, H = W = 512$ ；
- $C(\bullet)$: CNN 编码器(ResNet 系列)，输出通道 256；
- $V(\bullet)$: ViT 编码器，输出通道 512；
- $F_t, F_{t+\Delta t}$: 主干融合特征，通道 768，尺寸[B, 768, H/16, W/16]；
- **Concat:** 通道维度拼接，融合局部与全局特征。

6.1.2. Neck: 双时相差异特征融合

用于衔接主干与检测头，通过特征差值、拼接与通道压缩，强化变化差异、抑制不变背景，输出紧凑高效的变化特征图，降低 Head 计算开销。

核心公式：

$$\Delta F_{\text{abs}} = |F_t - F_{t+\Delta t}|;$$

$$\Delta F_{\text{concat}} = \text{Concat}(F_t, F_{t+\Delta t}, \Delta F_{\text{abs}});$$

$$F_{\text{neck}} = B(\Delta F_{\text{concat}})。$$

参数说明:

- ΔF_{abs} : 双时相特征绝对差, 突出变化区域;
- ΔF_{concat} : 三重拼接特征, 通道数 2304;
- $B(\bullet)$: 1×1 卷积瓶颈层, 压缩通道至 256;
- F_{neck} : Neck 输出特征, [B, 256, H/16, W/16]。

6.1.3. Head: 变化区域预测

由上采样、 1×1 卷积与 Sigmoid 激活组成, 将特征图恢复至原图分辨率, 输出逐像素变化概率图, 实现像素级变化检测。

核心公式:

$$\begin{aligned} F_{\text{up}} &= U(F_{\text{neck}}) \\ P &= \sigma(H(F_{\text{up}})) \end{aligned}$$

参数说明:

- $U(\bullet)$: 双线性上采样, 恢复尺寸 512×512 ;
- $H(\bullet)$: 1×1 卷积分类层, 输出通道 1;
- $\sigma(\bullet)$: Sigmoid 函数, 映射到[0, 1]概率区间;
- P : 变化概率图, $P(i, j) = 1$ 表示变化像素。

6.1.4. 基础损失函数

采用交叉熵与 Dice 损失加权组合, 缓解变化检测正负样本不均衡问题, 兼顾分类精度与区域重合度, 为遥感变化检测基准损失[8]。

核心公式:

$$\begin{aligned} L_{\text{base}} &= \lambda_{\text{ce}} L_{\text{ce}} + \lambda_{\text{dice}} L_{\text{dice}} \\ L_{\text{ce}} &= -\frac{1}{N} \sum_{i=1}^N [y_i \log p_i + (1 - y_i) \log (1 - p_i)] \\ L_{\text{dice}} &= 1 - \frac{2 \sum_{i=1}^N y_i p_i + \delta}{\sum_{i=1}^N y_i + \sum_{i=1}^N p_i + \delta} \end{aligned}$$

参数说明

- $\lambda_{\text{ce}} = 0.5$, $\lambda_{\text{dice}} = 0.5$;
- $N = 512 \times 512 = 262,144$, 单图总像素数;
- $y_i \in \{0, 1\}$: 真值标签, 1 为变化, 0 为不变;
- $p_i \in [0, 1]$: 模型输出概率;
- $\delta = 10^{-8}$: 数值稳定项。

6.1.5. 优化策略函数

1) 数据自适应增强

$$I_{\text{norm}} = \frac{I - I_{\mu}}{\sigma + \epsilon} \times \alpha + \beta$$

- I : 原始影像; I_{μ} 波段均值; (σ): σ 波段标准差;

- $\epsilon = 10^{-8}$, $\alpha = 1$, $\beta = 0$ 。
- 2) 双时相特征对齐损失

$$L_{\text{align}} = 1 - \frac{F_t \cdot F_{t+\Delta t}}{\|F_t\|_2 \|F_{t+\Delta t}\|_2}$$

$F_t, F_{t+\Delta t}$: 双时相主干特征;

- 向量点积; $\|\cdot\|_2$: L_2 范数;
- $L_{\text{align}} \in [0, 2]$, 值越小对齐程度越高。
- 3) 边界 - 区域复合损失

$$L_{\text{brcl}} = 0.4L_{\text{cc}} + 0.4L_{\text{dice}} + 0.2L_{\text{boundary}}$$

$$L_{\text{boundary}} = \sum_{b \in \Omega} |p_b - \hat{p}_b|$$

- L_{boundary} : 边界 L_1 损失; p_b : 真值边界; \hat{p}_b : 预测边界。
- Ω : 边界像素集合; 权重 0.4/0.4/0.2。
- 4) 全组合总损失 + 困难样本加权

$$L_{\text{total}} = 0.3L_{\text{cc}} + 0.35L_{\text{dice}} + 0.2L_{\text{boundary}} + 0.15L_{\text{align}}$$

$$W_i = \begin{cases} 2.5, & \text{IoU} < 0.3 \\ 1, & \text{IoU} \geq 0.3 \end{cases}$$

- W_i : 样本权重; IoU: 交并比;
- 困难样本阈值 0.3, 加权系数 2.5。

6.2. 模型训练策略

模型训练基于遥感 AI 生产平台完成, 并采用预训练变化检测模型进行迁移学习[1] [9]。训练初期冻结 Backbone 底层参数, 仅更新高层语义层与预测头, 以提高收敛速度; 随后逐步解冻网络并进行全模型联合训练。

学习率采用 Warm-up + Cosine 衰减策略, 先逐步提升学习率稳定训练, 再通过余弦退火实现平滑下降。

针对变化检测任务中前景与背景比例失衡问题, 引入类别均衡采样策略, 通过变化样本过采样与高频类别限制采样, 提高模型对少数类目标的识别能力。同时利用训练损失统计识别困难样本, 并加入后续训练以增强复杂场景识别能力[5] [7]。

主要训练参数如下:

- 初始学习率: 1×10^{-5} ;
- Batch Size: 16;
- Epoch: 100;
- 损失函数: 全组合总损失 + 困难样本加权。

训练过程中通过实时监控损失与精度变化判断模型收敛情况, 并结合 Dropout 与 Early Stopping 防止过拟合。在模型迭代阶段, 通过分析误检与漏检区域对样本库进行补充, 并对特征融合模块进行进一步优化, 从而提升模型在复杂地物变化场景中的检测能力。

7. 精度验证与模型评估

为验证优化模型在自然资源变化检测任务中的有效性与稳定性, 从评价指标、对比实验、消融实验

及实际应用等方面对模型性能进行综合评估。

7.1. 评价指标体系

采用独立测试集对模型性能进行评估，主要指标包括 Precision、Recall、F1、IoU、Accuracy 和 Loss 等。

具体评估指标如下：

- Precision (精确率)：模型识别出的变化区域中，实际发生变化的区域占比。精确率高意味着假正例(伪变化)较少；
- Recall (召回率)：模型成功识别的实际变化区域占所有实际变化区域的比例。召回率高则漏检的区域较少；
- F1 值：精确率和召回率的调和平均数，综合评估模型的检测性能；
- IoU (交并比)：预测变化区域与真实变化区域的交集与并集之比，是变化检测任务的关键量化指标，最理想情况是完全重叠，即比值为 1；
- Accuracy (准确率)：又称正确率，每一类别分类正确(包括正预测为正，负预测为负)的数量除以总数量；
- Loss (损失)：真值与预测值的差异，最理想值为 0。

7.2. 对比实验分析

实验中以商汤变化检测预训练模型作为基础模型，以引入全组合损失函数和困难样本加权等策略进行优化训练后的模型作为优化模型[1]。

实验数据选取北票市、开原市和盖州市三个区域的样本数据，共约 2 万组变化检测样本，并按照训练集:验证集:测试集 = 6:2:2 的比例进行划分。

7.2.1. 收敛性分析

在训练过程中记录 Loss 与验证集 F1 变化曲线，用于分析模型收敛特性。基础模型和优化模型收敛对比变化情况见图 3。




Figure 3. Comparison of model convergence curves

图 3. 模型收敛曲线对比

实验结果表明：

- 优化模型与基础模型均能稳定收敛；
- 优化模型 Loss 相比基础模型降低 0.13；

- F1 提升 0.17，整体稳定性更高。

7.2.2. 精度对比分析

在相同数据集条件下，对基础模型与优化模型在 Precision、Recall、IoU 和 Accuracy 指标上进行对比评估，精度对比情况见图 4。

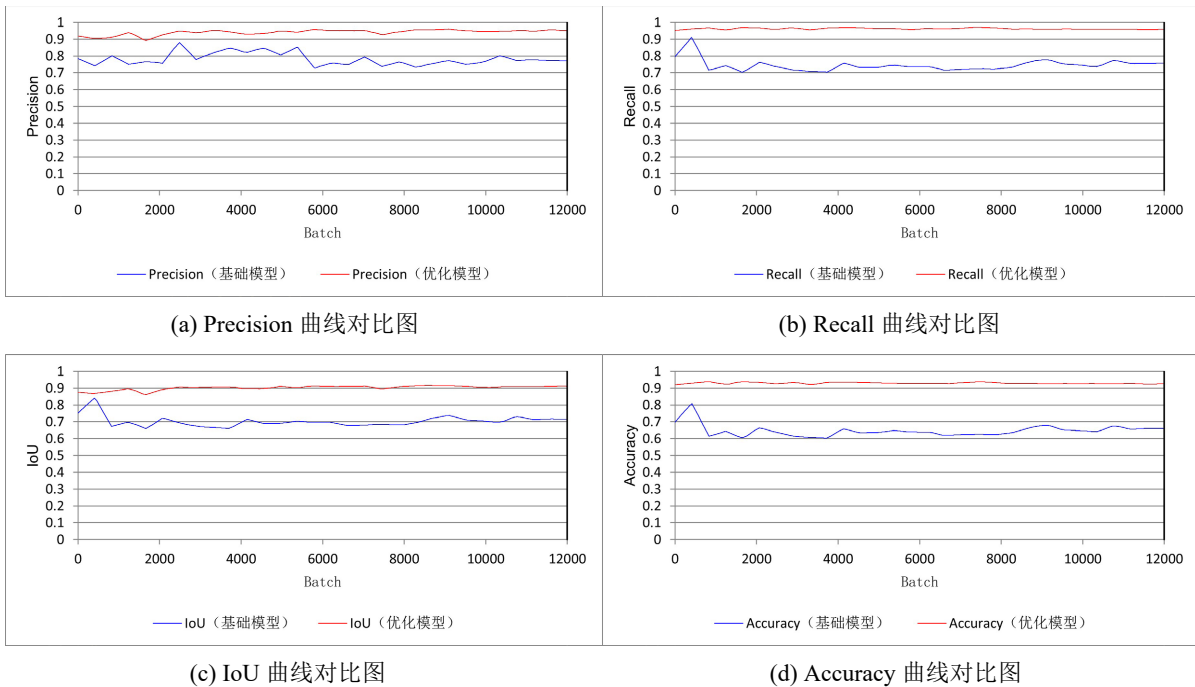


Figure 4. Comparison of model accuracy curves
图 4. 模型精度曲线对比

实验结果表明，两种模型在训练过程中均表现出稳定收敛趋势，而优化模型在各项指标上均明显优于基础模型，其中：

- Precision 提升 0.18；
- Recall 提升 0.20；
- IoU 提升 0.19；
- Accuracy 提升 0.27。

说明通过特征融合优化、损失函数改进和训练策略调整，可有效提升模型在复杂地物变化场景下的检测精度。

7.2.3. 可视化对比分析

选取水域、露天采矿区、体育场、林地、建筑物及构筑物等典型变化场景，对双时相影像、真值标注、基础模型预测结果和优化模型预测结果进行可视化对比，变化真值与模型预测值对比情况见图 5。

结果表明，优化模型在变化区域完整性、边界贴合度及误检与漏检控制方面均优于基础模型，对复杂变化目标具有更好的识别能力。

7.2.4. 主流模型对比实验

为进一步验证方法性能，将本文模型与 FC-Siam-diff、FC-Siam-conc 以及 UNet++ 等主流变化检测模

型进行对比。实验结果见表 1。



Figure 5. Comparison of change ground truth and model predictions
图 5. 变化真值与模型预测值对比

Table 1. Comparison results of mainstream models
表 1. 主流模型对比实验结果

Model	Precision	Recall	F1	IoU
FC-Siam-diff	0.821	0.812	0.822	0.741
FC-Siam-conc	0.807	0.805	0.807	0.718
UNet++	0.832	0.833	0.834	0.791
本文优化模型	0.950	0.9596	0.9501	0.9115

对比结果表明，本文方法在 F1 与 IoU 等关键指标上均优于对比模型，变化区域识别精度更高。

7.3. 消融实验与优化策略验证

为验证各优化策略的贡献，设计五组消融实验，以基础模型为基准逐步加入优化模块。实验结果见表 2。

Table 2. Ablation study results
表 2. 消融实验结果

方案	Precision	Recall	F1	IoU
基础模型	0.7709	0.7576	0.7804	0.714
基础模型 + 数据自适应增强	0.8160	0.8452	0.84	0.811
基础模型 + 双时相特征对齐	0.8367	0.8797	0.874	0.8546
基础模型 + 边界 - 区域复合损失	0.8628	0.8935	0.891	0.8582
全组合策略	0.95	0.9596	0.9501	0.9115

实验结果表明：

- 1) 单一策略效果排序为：边界 - 区域复合损失 > 双时相特征对齐 > 数据增强；
- 2) 全组合策略效果最佳，IoU 提升 5.3%~19.7%，F1 提升 5.9%~16.9%；
- 3) 在精度提升的同时，对模型参数规模和推理速度影响较小。

7.4. 实际应用验证

在测试集上，优化模型 Precision 为 0.950，Recall 为 0.9596，F1 为 0.9501，各项指标均明显优于基础模型。通过补充困难样本与优化数据分布，可进一步提升模型泛化能力。

在实际执法应用中,选取4个典型区域进行验证,模型识别的疑似违法区域与人工核查结果一致率超过90%,表明该模型能够有效支撑自然资源执法监测工作。

8. 模型部署与应用

优化训练后的变化检测模型已部署至商汤AI平台,并应用于辽宁省自然资源快速执法场景。系统具备较高的自动化处理与实时推理能力,可在短时间内完成大范围遥感影像的变化检测,并自动输出疑似违法区域的位置、面积及地物类型等信息,显著提升执法效率。

在辽宁省实际应用中,2025年系统识别出多起违规占地和非法采矿等疑似违法行为,线索识别准确率达到95.96%。相比传统人工解译方式,变化检测效率提升10倍以上[1][3][9],明显缩短了违法线索发现周期,推动自然资源执法由“被动核查”向“主动发现”转变。

此外,该系统支持按区域和执法类型进行灵活部署,可适应不同业务场景需求,具有良好的扩展性与应用推广价值。

9. 结束语

本文针对自然资源执法中人工核查效率低、响应周期长的问题,提出基于深度学习的快速执法模型优化方法。研究首先构建了覆盖多区域、多地貌类型的遥感变化检测样本库,并对样本结构、地物分类体系及多层级标签体系进行了优化和均衡处理,以形成高质量、适用于执法场景的训练数据。

在模型设计方面,本文在商汤预训练遥感变化检测模型基础上,引入CNN与ViT融合主干、多尺度特征融合、双时相特征对齐及边界-区域复合损失,并结合迁移学习与困难样本迭代策略,构建了高精度、稳定的双时相变化检测模型。训练策略包括动态学习率调整、类别均衡采样及高损失样本再训练,进一步提升了模型对复杂变化区域的识别能力。

实验评估显示,优化模型在测试集上的Precision、Recall和F1值分别达到0.950、0.9596和0.9501,优于基础模型及主流开源模型。在实际应用中,模型能够快速识别疑似违法占地、非法采矿等区域,线索准确率高达95.96%,检测效率较人工解译提升约10倍,实现了自然资源执法从“被动核查”向“主动发现”的转变。

综上所述,本研究通过数据重构、模型优化及实际应用验证,构建了一套可落地、高效、精确的自然资源快速执法技术体系,为自然资源管理的智能化、自动化提供了可靠技术支撑,并具备良好的扩展性和推广价值。

参考文献

- [1] 商汤科技. 智能遥感解译平台 Sense Remote 技术白皮书[R]. 上海: 商汤科技, 2023.
- [2] 宁晓刚, 张翰超, 张瑞倩. 遥感影像高可信智能不变检测技术框架与方法实践[J]. 测绘学报, 2024, 53(6): 1098-1112.
- [3] 丁忆, 李朋龙, 张冕, 等. 国土资源典型要素变化遥感智能监测关键技术及应用[J]. 地理信息世界, 2021, 28(6): 65-71.
- [4] 王云凯, 李安民, 林楠, 等. 基于无人机地理信息视频技术的自然资源调查外业核查方法[J]. 自然资源遥感, 2025, 37(1): 76-81.
- [5] 李彦胜, 钟振宇, 孟庆祥, 等. 遥感时空知识图谱驱动的自然要素变化图斑智能净化[J]. 地球信息科学学报, 2025, 27(2): 350-366.
- [6] 宫金杞. 复杂城市场景的高分辨率遥感影像建筑物变化检测[J]. 测绘学报, 2023, 52(7): 1233.
- [7] 康停军, 陈纳新, 孙颖, 等. 基于深度学习的新增违法建设监测框架研究与应用[J]. 测绘通报, 2023(11): 116-121.
- [8] 王儒壮, 李小群, 刘春霞, 等. 基于高分遥感影像的海口市违法建筑监测[J]. 北京测绘, 2021, 35(10): 1329-1332.
- [9] 李庆君. 基于遥感影像深度学习的违法用地查处应用研究[J]. 中国地名, 2020(4): 60.