文章编号:1671-4598(2026)07-0091-08 DOI:10.16526/j.cnki.11-4762/tp.2026.07.012 中图分类号:TP751 文献标识码:A

基于候选关联重组的飞机变化检测方法

卢 天[1,2],李 峰[1,2],王士成[1,2],林晓勇[1,2],
张学亮[1,2],齐 凯[1,2],王俊芳[1]

(1.中国电子科技集团公司 第五十四研究所,石家庄 050081;
2.中国电子科技集团公司 第五十四研究所 航天系统与应用专业部,石家庄 050081)

摘要:针对飞机变化检测中检测—关联解耦导致的误差累积与密集特征融合引发的实例混叠问题,提出基于候选关联重组的端到端方法;该方法以双时相候选实例为基本单元,构建候选生成、候选关联、候选重组与预测三模块框架:候选生成模块利用共享参数旋转检测器提取候选;候选关联模块融合多维特征,通过背景增广的全局分配显式建模不变、消失与出现关系;候选重组与预测模块在关联引导下重组特征,联合输出类别、变化状态与旋转边界框;在ACD-v1.5数据集上,该方法取得70.6%的*mAP*,较最优对比方法提升3.0个百分点;研究结果可有效支撑机场停机坪飞机清点、航空目标动态追踪与重点空域态势感知等实际业务需求。

关键词:遥感;飞机变化检测;旋转目标检测;候选关联;特征重组;联合预测

Candidate Association and Reorganization for Multi-Class Aircraft Change Detection

LU Tian[1,2], LI Feng[1,2], WANG Shicheng[1,2], LIN Xiaoyong[1,2], ZHANG Xueliang[1,2], QI Kai[1,2], WANG Junfang[1]

(1. The 54th Research Institute of China Electronics Technology Group Corporation, Shijiazhuang 050081, China;
2. Key Laboratory of Aerospace Information Applications, The 54th Research Institution of China Electronics Technology Group Corporation, Shijiazhuang 050081, China)

Abstract: To address error accumulation caused by detection-association decoupling and instance confusion induced by dense feature fusion in multi-class aircraft change detection, a candidate-based association-reorganization end-to-end method is proposed. The method takes bitemporal candidate instances as the basic reasoning unit and constructs a three-module framework comprising candidate generation, candidate association, and candidate reorganization with joint prediction. The candidate generation module employs a shared-weight oriented object detector to extract aircraft candidates from bi-temporal images; the candidate association module fuses visual features, class probabilities, and geometric relationships, and explicitly models unchanged, disappeared, and appeared relationships via background-augmented global one-to-one assignment; the candidate reorganization and prediction module, guided by association results, unifies matched and unmatched candidates into semantically complete fused features, and jointly outputs aircraft class, change states, and oriented bounding boxes. On the ACD-v1.5 dataset, the method achieves 70.6% mean average precision (*mAP*), outperforming the best baseline by 3.0 percentage points. The results support practical applications including aircraft inventory at airport aprons, dynamic tracking of aerial targets, and situational awareness in key airspace regions.

Keywords: remote sensing; aircraft change detection; oriented object detection; candidate association; feature reorganization; joint prediction

收稿日期:2026-06-12; **修回日期**:2026-06-25。

作者简介:卢 天(1996-),男,博士研究生。

引用格式:卢 天,李 峰,王士成,等.基于候选关联重组的飞机变化检测方法[J].计算机测量与控制,2026,34(7):91-98.

0 引言

遥感图像变化检测是遥感智能解译领域的重要研究方向，旨在通过分析不同时相影像识别地表目标或地物状态的变化[1]。根据输出粒度不同，现有变化检测任务通常包括场景级、像素级、语义级和目标级等形式。其中，场景级变化检测[2-4]主要判断图像块或区域是否发生变化，难以给出精确位置；像素级变化检测[5-7]能够获得变化区域的空间分布，但缺乏明确的目标实例信息；语义级变化检测[8-10]进一步引入地物类别，增强了变化结果的语义解释能力，但对于具有独立边界和方向属性的人工目标，仍难以满足目标清点、几何测量和状态判定等精细化应用需求。目标级变化检测[11-13]虽然可区分单个实例，但现有方法多集中于单类目标的二值变化判定，将“是否变化”压缩为单一前景类别，既无法区分“出现”“消失”等细粒度时序状态，也忽视了静止但关键的“不变”目标。因此，面向高分辨率遥感影像的多类别目标变化检测逐渐受到关注。

飞机作为高价值人工目标，其基于高分辨率光学遥感影像的变化检测在机场停机坪飞机清点、航空目标动态追踪、重点空域态势感知等实际业务中至关重要。该任务不仅要求判断目标区域飞机是否发生变化，还需要进一步给出飞机的空间位置、类别属性以及具体的跨时相变化状态。因此，飞机变化检测本质上是集目标几何测量、语义识别和时序状态判定于一体的综合感知任务。

现有飞机变化检测方法大致可分为两类。第一类方法[14]采用目标检测与关联相解耦的两阶段处理流程，即先分别检测双时相影像中的飞机目标，再依据检测框之间的空间关系进行关联匹配，最后根据匹配结果判定目标是不变、消失或出现。该类方法流程简单、易于实现，但其最终结果高度依赖前端检测质量。一旦检测阶段出现类别误判或边界框定位偏差，错误会进一步传递到关联和状态判定环节，造成误差累积。第二类方法[15]尝试在图像特征层对双时相影像进行融合，通过端到端网络直接学习各类飞机的变化特征。该类方法能够增强双时相信息交互，但在飞机密集分布或小尺度飞机检测等场景中，密集特征融合容易将相邻飞机、停机坪背景、阴影和局部纹理共同编码，造成实例边界弱化和目标身份混淆。对于飞机这种对象级变化检测而言，若无法保持单个实例的独立表示，后续类别识别和状态判定均会受到影响。

为解决上述问题，本文提出一种基于候选关联重组的多类飞机变化检测方法。方法以飞机候选实例为基本单元，首先分别提取双时相飞机作为候选实例，避免在早期阶段进行密集融合；随后，融合候选飞机的视觉特征、类别概率和几何关系等多维特征，并通过背景增广的全局分配显式建模跨时相候选间的不变、消失与出现关系；最后，在三类关联关系的引导下重组候选飞机特征为统一的结构化表示，并在同一特征空间内联合输出类别、变化状态与旋转边界框。实验结果表明，所提方法在 ACD-v1.5 数据集上显著优于现有解耦与密集融合方法，可有效缓解检测误差累积与特征混淆问题，提升变化检测的精度与稳定性。

1 网络设计

1.1 总体框架

本文方法由候选生成模块、候选关联模块和候选重组与预测模块组成。整体流程如图 1 所示。

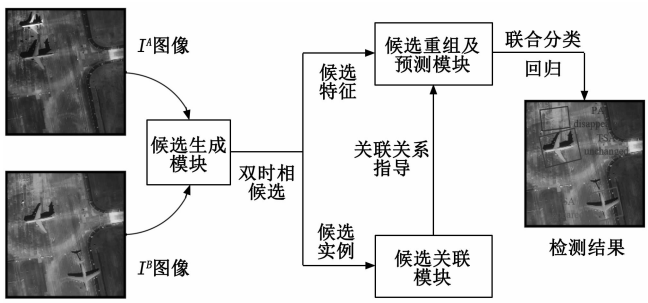

图 1 总体框架图

首先，将双时相遥感影像 I^A 和 I^B 输入共享参数的旋转目标检测网络，提取两期影像中的飞机候选实例，得到候选框、候选特征及类别概率分布等信息。随后，针对双时相候选实例构建跨时相关联关系，综合利用候选的视觉特征、类别概率和空间几何约束计算候选对关联得分，并通过背景增广的全局一对一分配机制对关联得分矩阵进行解码，获得匹配候选、时相 I^A 未匹配候选和时相 I^B 未匹配候选，分别对应不变、消失和出现三类变化关系。在此基础上，候选重组与预测模块根据关联结果对双时相候选特征进行重组：对于匹配候选，直接融合两期目标特征；对于未匹配候选，则从另一时相对应位置提取真实背景特征进行补充，以避免缺失时相采用零填充造成的语义不完整。重组后的候选变化实例进一步输入联合预测头，同步输出目标细粒度类别、变化状态以及旋转边界框。

该框架以候选实例为核心处理单元，将目标检测、跨时相关联、候选重组和变化预测统一建模，能够在保持旋转目标边界表达能力的同时，缓解密集特征融合引起的特征混叠以及解耦流程中的误差传播问题，适用于飞机目标密集分布、方向任意和类别细粒度区分困难的机场遥感场景。

1.2 候选生成模块

飞机目标在遥感影像中通常具有明显方向性和较强实例边界。若在早期阶段直接对双时相特征进行密集融

合，容易引入相邻目标及复杂背景的干扰。为获得稳定的实例级表达，方法首先对双时相影像分别进行飞机目标提取，将图像级输入转化为结构化候选实例。

候选生成模块采用共享参数的旋转目标检测网络分别处理双时相遥感影像，输出双时相候选实例集合：

$$O^A = \{o_i^A\}_{i=1}^{N_A}, \quad O^B = \{o_j^B\}_{j=1}^{N_B} \tag{1}$$

其中：N^A 和 N^B 分别表示两期影像中的候选目标数量。每个候选实例定义为：

$$o_i^t = \{f_i^t, p_i^t, b_i^t\}, \quad t \in \{A, B\} \tag{2}$$

式中，$f_i^t \in R^D$ 为对象级视觉特征，$p_i^t \in R^C$ 为飞机类别概率分布，$b_i^t \in \{x_i^t, y_i^t, w_i^t, h_i^t, \theta_i^t\}$ 为五参数飞机目标旋转框。

飞机目标具有细粒度类别差异，且检测器输出的类别结果存在一定的不确定性。相比直接采用离散类别标签，类别概率分布能够更完整地保留候选目标的语义响应。通过该模块，双时相影像被表示为具有明确边界、类别响应和视觉语义的候选实例集合，为后续跨时相关联提供稳定输入。

1.3　候选关联模块

飞机变化检测的关键在于判断双时相中的候选是否对应同一物理实例。由于机场场景中飞机目标密集且外观相似，仅依赖空间距离、重叠度或单一视觉特征均难以稳定完成关联。因此，本文从几何空间、类别概率和视觉特征三个方面约束构建候选对表示，并进一步学习跨时相候选之间的关联置信度。候选关联模块的流程如图 2 所示。

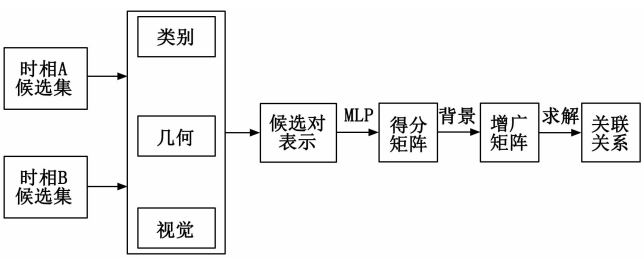

图 2　候选关联模块

1.3.1　关系构建

对于任意跨时相候选对 (o_i^A, o_j^B)，首先构建几何约束。若两候选实例对应同一物理飞机，其中心位置、尺度大小及空间覆盖范围通常具有一定一致性。据此，定义几何约束为：

$$g_{ij}^{AB} = \left[\frac{x_j^B - x_i^A}{w_i^A}, \frac{y_j^B - y_i^A}{h_i^A}, \log\frac{w_j^B}{w_i^A}, \log\frac{h_j^B}{h_i^A}, IoU_{ij}^{AB}\right] \tag{3}$$

其中：前两项表示以时相 A 候选尺度归一化后的中心偏移；第三、四项表示宽度和高度的对数尺度比；IoU_{ij}^{AB} 表示两个旋转框之间的交并比。该几何关系能够同时刻画候选对之间的相对平移、尺度变化和空间重叠程度，可为候选关联提供几何可达性约束。

然后构建类别约束。本文利用双时相候选的类别概率分布构建粗类别约束：

$$c_{ij}^{AB} = [p_i^A, p_j^B, p_i^A \odot p_j^B, |p_i^A - p_j^B|] \tag{4}$$

其中，$\odot$ 表示逐元素乘积。该类别关系包含两候选自身的类别概率、类别响应一致性以及类别分布差异，可为候选关联提供语义兼容性约束。

1.3.2　候选对表示与关联评分

在完成几何和类别约束后，进一步结合视觉特征构造候选对联合表示：

$$q_{ij}^{AB} = [f_i^A, f_j^B, |f_i^A - f_j^B|, g_{ij}^{AB}, c_{ij}^g] \tag{5}$$

其中：几何约束、类别约束和视觉特征需先投影到相同维度的几何嵌入。该表示同时融合了外观一致性、几何可达性和语义兼容性信息。

将候选对表示输入多层感知机关联并进一步通过 Sigmoid 函数得到关联得分：

$$s_{ij}^{AB} = \sigma[MLP(q_{ij}^{AB})] \tag{6}$$

其中，$s_{ij}^{AB} \in (0,1)$ 表示候选对 (o_i^A, o_j^B) 对应同一飞机目标的置信度。对所有跨时相候选对计算关联概率，得到关联得分矩阵 $\boldsymbol{S} \in \boldsymbol{R}^{N_A \times N_B}$。

1.3.3　候选关联求解

关联得分矩阵仅刻画了双时相候选之间的局部相似性。直接进行贪婪匹配，容易导致低置信候选被强制关联；直接采用标准二部图匹配，则难以显式建模出现和消失两种变化状态。为此，本文参考文献 [14]，将跨时相候选关联建模为带背景增广的全局一对一最优分配问题。具体而言，通过引入虚拟背景节点，将原始的矩形候选匹配问题扩展为方阵分配问题，使未匹配候选能够被分配至虚拟的背景节点，从而在统一的一对一分配框架下建模不变、消失与出现三种状态关系。

具体地，令 $N = N_A + N_B$，构造增广代价矩阵 $\boldsymbol{C} \in \boldsymbol{R}^{N \times N}$：

$$\boldsymbol{C} = \begin{bmatrix} 1 - \boldsymbol{S} & \boldsymbol{C}_{bg}^A \\ \boldsymbol{C}_{bg}^B & \boldsymbol{D} \end{bmatrix} \tag{7}$$

其中：$1 - S$ 对应前景候选之间的匹配代价。$\boldsymbol{C}_{bg}^A \in \boldsymbol{R}^{N_A \times N_A}$ 和 $\boldsymbol{C}_{bg}^B \in \boldsymbol{R}^{N_B \times N_B}$ 分别表示 A 时相候选分配至背景和 B 时相候选由背景分配而来的代价矩阵。二者均为对角矩阵形式，其对角线元素设为背景分配代价 c_{bg}，用于表示候选未在另一时相中找到可靠匹配的情况。右下角 $\boldsymbol{D} \in \boldsymbol{R}^{N_B \times N_A}$ 为 0 填充矩阵，表示背景占位节点之间的虚拟匹配，仅用于补全方阵，不具有实际语义含义。背景分配代价定义为：

$$c_{bg} = (1 - \tau_m)/2 \tag{8}$$

其中：τ_m 为匹配阈值。由于拒绝一个前景候选对通常对应两个背景分配，此时其总代价应为 $2c_{bg} = 1 - \tau_m$。因此，如此定义背景分配代价可使候选对关联得分低于 τ_m 时，将两个候选分别分配至背景节点比强制进行前景匹配代价更低。

1.4 候选重组与预测模块

尽管候选关联模块建立了跨时相候选之间的对应关系，但其关联的对象仍是前置检测阶段生成的候选实例，所以仍存在以下局限：(1) 检测不确定性未消除。前端检测器产生的候选可能包含定位偏差、类别误判、候选冗余等不确定性误差，这些误差无法仅靠关联匹配予以修正。(2) 特征表达未对齐。匹配对中的两个候选虽被判定为同一物理目标，但其视觉特征、类别概率与几何表示仍分别源自独立检测分支，存在语义不一致与表征异质性。

为克服上述问题，本文提出候选重组与预测模块，如图 3 所示。其核心动机在于将关联结果转化为结构化、语义完备的变化实例表示，并在统一特征空间中同步完成类别识别、状态判别与旋转框预测。

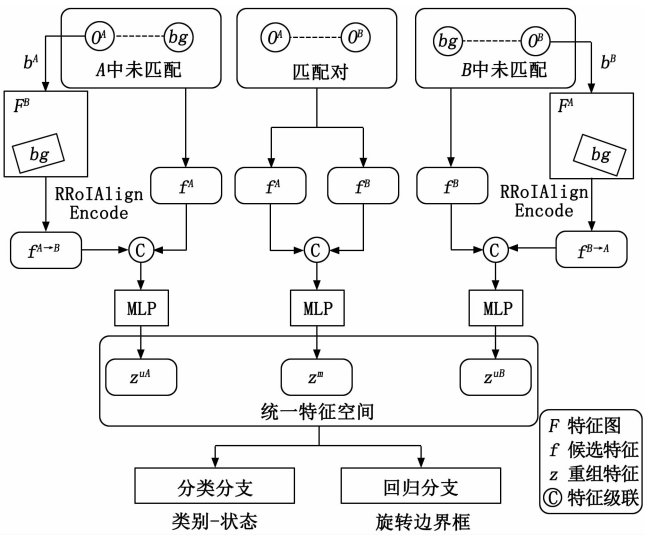

图 3 候选重组与预测模块

1.4.1 候选重组

将全局匹配结果解码为三类候选关系，并依据候选关系将候选实例统一重组为一组语义完备的变化实例：

1) 对成功匹配的候选对 (o_i^A, o_j^B)，认为该目标在两个时相中均存在，其重组实例特征表示可直接由双时相候选特征拼接：

$$z^m = MLP[concat(f_i^A, f_j^B)] \tag{9}$$

2) 对于时相 A 中未匹配候选 o_i^A，认为该目标仅在时相 A 中存在，而在时相 B 中消失。若直接以零向量填充缺失对应特征，会引入语义空洞，难以准确反映该空间位置在另一时相中的真实背景信息。为此，利用该候选的旋转框 b_i^A 作为空间查询，在时相 B 的特征图 F^B 上提取对应区域特征 $f_i^{A\to B}$，并将其作为跨时相背景特征与原候选特征共同构造重组实例特征表示：

$$z^{uA} = MLP[concat(f_i^A, f_i^{A\to B})] \tag{10}$$

3) 类似的，对于时相 B 中未匹配候选 o_j^B，认为其为新增目标，仅在时相 B 中存在，而在时相 A 中不存在。此时从时相 A 的特征图 F^A 中提取其对应空间区域特征 $f_j^{B\to A}$，并构造融合表示为：

$$z^{uB} = MLP[concat(f_j^{B\to A}, f_j^B)] \tag{11}$$

跨时相背景特征的提取方式与候选生成模块中的候选特征编码过程保持一致。具体地，对于时相 A 中未匹配候选 o_i^A，其跨时相背景特征表示为：

$$f_i^{A\to B} = Enc[RRoIAlign(F^B, b_i^A)] \tag{12}$$

其中：F^B 表示时相 B 的特征金字塔输出，RRoIAlign (·) 表示旋转目标特征提取操作，$Enc(\cdot)$ 表示候选特征编码器。类似地，对于时相 B 中未匹配候选 o_j^B，其跨时相背景特征为：

$$f_j^{B\to A} = Enc(RRoIAlign(F^A, b_j^B)) \tag{13}$$

最终，通过候选特征与跨时相背景特征的联合建模，将匹配候选与未匹配候选统一重组为结构一致的融合表示，为后续联合预测提供语义完备且统一的结构化输入。

1.4.2 联合预测

候选级重组为缓解前端检测误差带来的不确定性提供了有效基础。联合预测头进一步对重组特征同时执行类别－变化状态联合分类与旋转框回归，从而输出最终的变化检测结果。

将每个变化候选实例的语义类别与变化状态统一编码为一个 3C 维标签空间，其中 C 表示飞机类别数，3 表示三种变化状态：不变、消失和出现。给定第 k 个重组实例的特征 z_k，分类分支输出其在全部联合标签上的预测响应：

$$\hat{p} = ClsHead(z_k) \tag{14}$$

其中，$\hat{p} \in R^{3C}$ 表示对所有类别－状态联合标签的预测得分。最终预测标签由最大响应对应的标签索引得出：

$$l_k^* = \arg\max_{l\in\{0,1,\ldots,3C-1\}} \hat{p}_{k,l} \tag{15}$$

该建模方式将语义类别识别与变化状态判别统一到同一分类分支中，使模型能够在端到端训练过程中学习不同类别－状态组合之间的判别边界，从而增强细粒度飞机变化识别能力。

同时，回归分支基于重组特征预测旋转边界框：

$$b^* = \mathrm{RegHead}(z_k) \tag{16}$$

综上，候选重组与预测模块在全局关联结果的引导下，将离散的候选飞机转化为统一、完备的变化实例表示，并通过联合分类与旋转框预测实现最终输出。

1.5 监督与损失函数

本文采用端到端联合训练策略，对双时相候选生成模块、候选关联模块以及候选重组与预测模块进行统一优化。整体训练目标由这三个模块的损失共同组成：

$$L = L_1 + L_2 + L_3 \tag{17}$$

1.5.1　候选生成模块损失

候选生成模块采用 RoI Transformer [16] 目标检测器分别对时相图像进行候选提取。其监督由两阶段的分类与旋转框回归共同构成，损失定义为：

$$L_1 = \sum_{t\in\{A,B\}}(L^t_{rpn_cls} + L^t_{rpn_reg} + L^t_{roi_cls} + L^t_{roi_reg}) \tag{18}$$

其中：t 表示时相，前两项损失分别表示第 t 个时相在区域生成网络（RPN，region proposal network）阶段的分类损失与回归损失；后两项分别表示对应感兴趣区域（ROI，region of interest）提取阶段的分类损失与旋转框回归损失。该损失保证双时相图像能够被稳定地转换为具有类别语义和几何边界信息的候选实例集合。

1.5.2　候选关联模块损失

候选关联模块负责学习双时相候选之间的对应关系，其优化目标为候选对层面的关联判别，损失定义为：

$$L_2 = L_{rel} \tag{19}$$

其中，L_{rel} 表示候选对关联分类损失，用于监督任意跨时相候选对是否对应同一物理目标。

1.5.3　候选重组与预测模块损失

候选重组与预测模块基于重组后的变化实例特征完成类别－状态联合分类和旋转边界框预测。因此，该模块损失定义为：

$$L_3 = L_{joint_cls} + L_{joint_reg} \tag{20}$$

其中，L_{joint_cls} 用于监督变化实例在联合标签空间中的类别预测；L_{joint_reg} 用于监督旋转边界框回归。

1.5.4　损失函数设置

实验中，候选生成和候选重组与预测模块中的所有分类损失均采用 Focal Loss[17]，以缓解正负样本不均衡及难易样本分布不均问题；边界框回归损失均采用 Smooth L1 Loss[18]，以提高旋转框回归的稳定性。候选关联模块中的候选对关联监督采用二元交叉熵损失。损失权重均设为 1.0。

2　实验结果与分析

2.1　数据集

ACD-v1.5 [15] 是面向多类别飞机变化检测的专用基准数据集。该数据集包含由吉林一号卫星获取的 68 幅光学遥感图像，空间分辨率为 0.5 米，覆盖 13 个机场区域，每个区域包含 2～10 个时相。经过图像配准与裁剪后，共生成 5 890 对尺寸为 1 024×1 024 像素的双时相图像对，其中包括 4 662 对训练样本和 1 228 对验证样本。该数据集共包含 20 541 个完整标注的变化实例，其中 17 163 个用于训练，3 378 个用于验证。每个实例均标注有旋转边界框、细粒度飞机类别以及变化状态。其中，飞机类别包括运输机（TSA，transport aircraft）、教练机（TNA，trainer aircraft）、无人机（UAV，unmanned aerial vehicle）和客机（PA，passenger aircraft）。变化状态包括未变化（UCND，unchanged）、消失（DISAPP，disappeared）和出现（APP，appeared）。

2.2　实验细节

实验基于 PyTorch 实现，并在 4090D GPU 上运行。为缓解过拟合问题，训练过程中采用了随机水平翻转和随机尺度缩放等数据增强策略。模型优化采用带动量的随机梯度下降算法，其中动量设置为 0.9，权重衰减系数设置为 1e－4，初始学习率设置为 5e－3。受硬件条件限制，批量大小设置为 2。模型共训练 12 个轮次，并分别在第 8 和第 11 轮时，将学习率衰减为原来的 0.1，以促进模型稳定收敛。

2.3　评价指标

参考已有工作[15]，本文采用平均精度均值（mAP，mean average precision）[19] 作为飞机变化检测任务的主要评价指标。mAP 定义如下：

$$mAP = \frac{1}{3C}\sum_{i=0}^{3C-1}\int_0^1 P_i(R)\mathrm{d}R \tag{21}$$

其中：C 表示目标类别数。积分项表示第 i 个类别在精确率－召回率（PR，precision-recall curve）曲线下的面积。最终 mAP 通过对所有 $3C$ 个联合类别取平均得到，即 C 个目标类别与 3 种变化状态的组合类别。其中，精确率（P，precision）和召回率（R，recall）定义如下：

$$P = \frac{TP}{TP + FP} \tag{22}$$

$$R = \frac{TP}{TP + FN} \tag{23}$$

其中，TP、FP 和 FN 分别表示真正例、假正例和假负例的数量。

2.4　对比实验分析

为系统评估所提方法性能，选取代表性方法进行对比：检测－关联解耦的方法 PD-Net[14] 选取 RoI Transformer[16] 和 Oriented R-CNN[20] 为目标检测器，记为 RoI-CD 与 Oriented-CD；密集特征融合方法包括 SFDA-OCDet[21] 和 FIF-Net[15]。其中，SFDA-OCDet 原用于单类飞机变化检测，为公平比较，保留其骨干网络与融合机制，仅替换预测头为多类别－多状态联合分支。

本文方法与代表性方法的定量对比、可视化对比和效率对比分别如表 1、图 4 和表 2 所示。

2.4.1　定量分析

如表 1 所示，本文方法在 12 个联合类别（4 类飞机×3 种变化状态）上的 mAP 达到 70.6%，显著优于所有对比方法，提升幅度为 3.0 至 5.3 个百分点。在细粒度对比中，本文在 6 个子类上取得最高精度，包括运输机的不变与消失状态，教练机的不变、消失与出现状态，以及客机的出现状态。

表 1 不同方法在 ACD-v1.5 数据集上的性能对比

方法		运输机			教练机			无人机			客机			mAP ↑
		不变	消失	出现	不变	消失	出现	不变	消失	出现	不变	消失	出现	
检测关联解耦	Oriented-CD	59.8	71.9	71.9	70.6	49.0	45.1	86.2	40.2	48.3	79.6	81.2	79.6	65.3
	RoI-CD	57.4	70.2	69.3	78.8	60.4	49.0	78.4	32.2	49.4	88.8	85.5	80.4	66.6
密集特征融合	SFDA-OCDet	67.0	74.1	76.8	62.4	54.5	49.2	78.7	34.1	52.4	88.4	88.3	78.8	67.1
	FIF-Net	66.5	76.0	82.8	69.9	51.2	48.4	78.6	34.7	47.4	87.2	88.2	79.7	67.6
本文方法		70.3	78.5	82.1	81.8	63.5	57.9	79.4	33.8	51.3	75.6	87.3	85.2	70.6

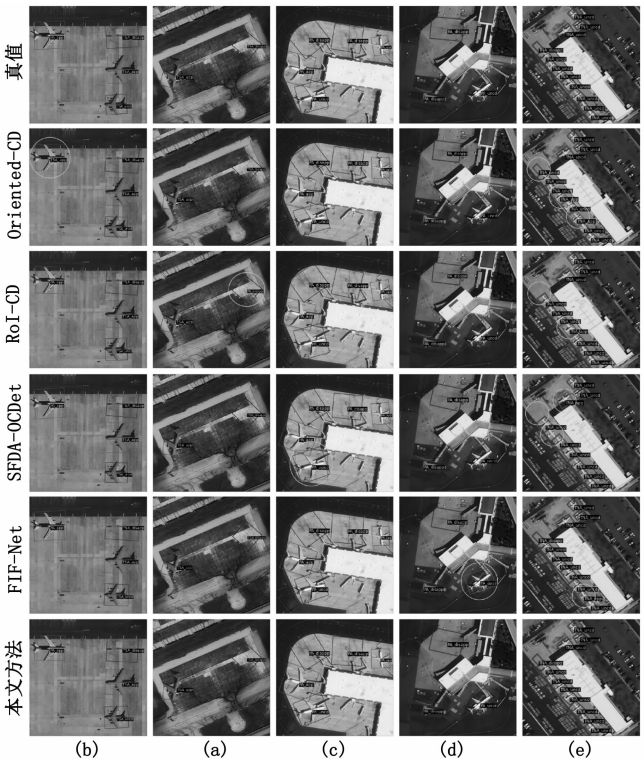

图 4 不同方法在 ACD-v1.5 数据集上检测结果的可视化展示

相较于 Oriented-CD 和 RoI-CD 等检测－关联解耦的两阶段方法，本文提出的方法性能提升显著，并在 12 个类别中的 9 个子类展现出最高的性能优势，尤其是在运输机与教练机的全部三类变化状态上均实现全面领先。该结果表明，联合建模有效缓解了前端检测误差向关联与判别环节的传递，显著提升了模型对目标定位偏差与类别不确定性的鲁棒性。

相较于密集特征融合方法，本文提出的方法仍在多数子类中占优。值得指出的是，本文方法在教练机这一典型小尺度目标类别上展现出表现突出：其不变、消失与出现状态的精度均高于 SFDA-OCDet 与 FIF-Net，平均提升达 10 个百分点。这一结果表明，密集特征融合方法易将相邻飞机与背景纹理混叠编码，而该缺陷在教练机这类特征纹理模糊、响应较弱的小尺度目标中尤为突出；相比之下，本文方法在候选级进行关联与重组，可有效缓解密集特征融合所引发的特征混淆问题。

2.4.2 可视化分析

图 4 可视化了不同方法在五组样本下的检测结果，具体变化实例用文字标识，如“客机－出现”对应“PA _ app”；各方法的错误结果以圆圈标记。五组样本覆盖了类别相似目标混淆、变化状态误判、密集排列、小目标检测和复杂背景干扰等典型困难场景。

在图 4（a）和图 4（b）样本中，Oriented-CD 和 RoI-CD 分别将出现的客机归为运输机，将消失的运输机归为客机。这表明检测－关联解耦的方法会将前置目标检测阶段的误差直接传递至最终预测结果。在图 4（c）和图 4（d）样本中，SFDA-OCDet 和 FIF-Net 均出现了预测状态不一致的问题，说明密集特征融合虽然能够增强双时相特征交互，但在缺乏实例级身份约束时，仍容易在目标邻近或外观相似区域产生实例混叠，进而影响变化状态判别。在图 4（e）所示的密集区域和小目标场景下，对比方法出现多种错误类型，包括误检、漏检以及跨时间状态误分类。这些失败案例主要归因于背景杂波、邻近实例干扰、小目标特征表达不足以及前端检测误差累积。

相比之下，本文方法通过候选实例提取与关联保持了实例级别的身份一致性及状态稳定性，并通过候选特征重组与联合预测进一步抑制检测相关误差，从而获得更可靠的变化检测结果。该可视化结果与定量实验结论一致，进一步验证了本文方法在类别相似、目标密集及小目标变化检测场景下的有效性。

2.4.3 效率分析

如表 2 所示，本文方法的参数量、浮点运算量和推理帧率分别为 63.6 M、225.2 G 和 12.8 FPS，并取得最高的 mAP。就模型复杂度而言，本文方法的参数量略高于解耦的方法，主要原因在于候选关联模块引入了先验编码与成对关系建模结构，同时候选重组阶段的跨时相特征提取也带来了一定的额外参数开销。就计算量而言，本文方法的 FLOPs 为 225.2 G，与解耦的方法基本相当，却优于 SFDA-OCDet 和 FIF-Net，说明所提出的候选级融合策略有效避免了全图密集特

征融合造成的高计算冗余。就推理效率而言，本文方法达到12.8 FPS，虽略低于解耦的方法，但明显高于FIF-Net 和 SFDA-OCDet。

表 2　不同方法在 ACD-v1.5 数据集上效率与精度对比

方法	参数量(M)↓	浮点数(G)↓	帧率↑	mAP↑
Oriented-CD	41.1	221.4	15.3	65.3
RoI-CD	55.1	199.5	13.4	66.6
SFDA-OCDet	55.5	311.6	1.7	67.1
FIF-Net	55.5	311.6	2.8	67.6
本文方法	63.6	225.2	12.8	70.6

综合精度与效率来看，与最优对比方法 FIF-Net 相比，本文方法在 mAP 上提升 3.0%，同时推理帧率提高 10 FPS；与 解耦类方法相比，本文方法在仅略微增加计算开销并牺牲少量推理速度的情况下，实现了 4.0%～5.3%的 mAP 提升。上述结果表明，本文方法能够在保持较高推理效率和可控计算复杂度的同时，获得更优的检测精度，体现出良好的精度－效率权衡。

2.5　消融实验分析

为进一步验证各关键模块的有效性，本文分别对候选关联模块和候选重组与预测模块进行消融实验。定量消融实验结果如表 3 所示。

2.5.1　候选关联模块消融

为验证所构建候选关联模块的有效性，本文将其替换为轻量级成对关联基线。该基线仅依赖特征相似性与相互最近邻解码，未引入几何/类别先验，亦无全局一对一约束。表 3 的定量结果显示，基线方法性能下降 10.2 个百分点。这表明，引入先验信息与全局约束可有效提升关联准确性，进而更可靠地引导候选重组与预测，获得更精确的检测结果。

图 5 进一步对预测结果进行了 t-SNE 特征可视化对比。从图可以看出基线方法的预测结果在特征空间中混叠更为严重，无法有效区分不变、消失和出现三类变化状态。这一现象表明关联关系失准会直接导致重组候选特征的时序关系混乱，进而削弱联合预测的判别能力。而本文构建的候选关联模块利用多种约束提升关联判别性，引入全局匹配机制显式建模三类变化关系，确保重组阶段获得结构清晰、语义完备的输入，从而支撑后续联合预测生成高判别性的变化检测结果。

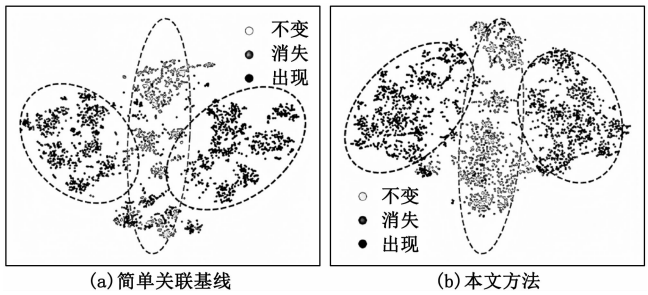

图 5　候选关联模型消融可视化展示

2.5.2　候选重组与预测模块消融

为验证真实背景补充的作用，本文在重组过程中移除未匹配候选对应时相的真实背景信息。表 3 的定量结果显示，移除真实背景特征后性能下降 4.2 个百分点。这一结果表明真实背景信息对于准确表征未匹配的重组候选至关重要。对于消失与出现实例，若缺失端时相特征仅采用零值或非信息性占位符填充，会导致重组后的变化表征将语义缺失，难以有效区分真实目标变化与前端检测的不确定性。

图 6 从状态级的 TP 置信度分布和 mAP 对比两个角度进一步说明了这一点：对于消失和出现两类变化实例，未引入真实背景补充时，TP 得分更分散且整体偏向低置信度区域；引入真实背景特征后，TP 得分更加集中于高置信度区域，mAP 显著提升。这表明，真实背景补充能够为缺失时相提供有效的上下文参考，增强重组后变化实例表征的语义完整性，从而提升出现与消失状态的判别可靠性。

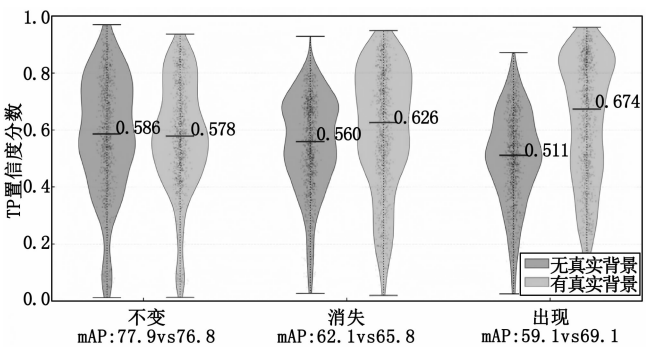

图 6　候选重组与预测模块消融可视化展示

3　结束语

本文提出一种基于候选关联重组的多类飞机变化检

表 3　在 ACD-v1.5 数据集的消融实验结果

消融模块	运输机			教练机			无人机			客机			mAP↑
	不变	消失	出现	不变	消失	出现	不变	消失	出现	不变	消失	出现	
关联模块	44.3	58.2	59.0	63.5	52.2	58.7	61.9	46.8	56.0	53.1	84.9	86.9	60.4
重组模块	74.0	72.8	75.3	85.9	57.4	53.4	81.1	35.7	36.6	70.5	82.4	71.1	66.4
完整方法	70.3	78.5	82.1	81.8	63.5	57.9	79.4	33.8	51.3	75.6	87.3	85.2	70.6

测方法，以双时相候选实例为基本单元，将检测、关联、重组与预测统一于端到端框架，实现了不变、消失与出现三类变化关系与细粒度飞机类别的联合建模。通过融合类别与几何约束提升关联可靠性，借助背景增广的全局一对一分配显式建模变化状态，并利用真实背景信息增强未匹配候选的语义表征完整性。在 ACD-v1.5 数据集上，方法以 70.6%的 *mAP* 显著优于现有解耦与密集融合方法；消融实验验证了候选关联与重组策略的关键作用。结果表明，该方法有效缓解了误差传播与特征混叠问题，为高精度、鲁棒的多类飞机变化检测提供了可行路径。未来将聚焦于模型轻量化及多目标通用性的提升，以期为机场动态监测和重点空域态势感知等工程应用提供更高效的技术支撑。

参考文献：

[1] SINGH A. Digital change detection techniques using remotely-sensed data [J]. International Journal of Remote Sensing, 1989, 10 (6): 989 - 1003.

[2] WU C, ZHANG L, DU B. Kernel slow feature analysis for scene change detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55 (4): 2367 - 2384.

[3] WANG J, ZHONG Y, ZHANG L. Contrastive scene change representation learning for high-resolution remote sensing scene change detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5618118.

[4] SHI S, LIU Y, LI D, et al. Multi-temporal high-resolution urban land-use mapping and change analysis based on a deep geospatial-temporal adaptation network [J]. Remote Sensing of Environment, 2025, 328: 114912.

[5] 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, 2019, 57 (1): 574 - 586.

[6] XIE W, SHAO W, LI D, et al. MIFNet: multi-scale interaction fusion network for remote sensing image change detection [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2025, 35 (3): 2725 - 2739.

[7] XU G, LIU Y, DENG L, et al. SMNet: a semantic-guided mamba network for remote sensing change detection [J]. IEEE Transactions on Aerospace and Electronic Systems, 2025, 61 (5): 11116 - 11127.

[8] TIAN S, ZHONG Y, ZHENG Z, et al. Large-scale deep learning based binary and semantic change detection in ultra high resolution remote sensing imagery: From benchmark datasets to urban application [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 193: 164 - 186.

[9] LONG J, LI M, WANG X, et al. Semantic change detection using a hierarchical semantic graph interaction network from high-resolution remote sensing images [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 211: 318 - 335.

[10] LONG J, LIU S, LI M, et al. BGSNet: a boundary-guided siamese multitask network for semantic change detection from high-resolution remote sensing images [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2025, 225: 221 - 237.

[11] ZHANG L, HU X, ZHANG M, et al. Object-level change detection with a dual correlation attention-guided detector [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 177: 147 - 160.

[12] TAO S, YANG M, WANG M, et al. Small object change detection in UAV imagery via a siamese network enhanced with temporal mutual attention and contextual features: a case study concerning solar water heaters [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2024, 218: 352 - 367.

[13] GAO Q, FENG Z, YANG S, et al. Heterogeneous object-level aircraft change detection via cross-modal interaction and imbalanced learning [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5632115.

[14] LU T, WANG Z, WANG J, et al. A postdetection framework with optimal transport for multiclass object change detection [J]. IEEE Geoscience and Remote Sensing Letters, 2025, 22: 6004005.

[15] LU T, LI Y, LI Z, et al. FIF-Net: feature interaction and fusion network for multiclass object change detection [J]. Geo-spatial Information Science, 2026.

[16] DING J, XUE N, LONG Y, et al. Learning RoI transformer for oriented object detection in aerial images [C] //2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 2019: 2844 - 2853.

[17] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C] //2017 IEEE International Conference on Computer Vision (ICCV). 2017: 2999 - 3007.

[18] GIRSHICK R. Fast R-CNN [C] //2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 1440 - 1448.

[19] EVERINGHAM M, VAN GOOL L, Williams C K I, et al. The pascal visual object classes (VOC) challenge [J]. International Journal of Computer Vision, 2010, 88 (2): 303 - 338.

[20] XIE X, CHENG G, WANG J, et al. Oriented R-CNN for object detection [C] //2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 3500 - 3509.

[21] JIE Y, HE H, WANG P, et al. SFDA-OCDet: spatial-frequency difference attention network for remote sensing object-level change detection [J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 5638823.