

# 基于分层提议与解耦监督的目标检测增量学习

梁嘉伟<sup>1</sup>, 梁思源<sup>2</sup>, 陈若愚<sup>3,4</sup>, 刘宽融<sup>1</sup>, 黄健杰<sup>1</sup>, 操晓春<sup>1\*</sup>

(1. 中山大学网络空间安全学院, 广东深圳 518102; 2. 南洋理工大学计算机与数据科学学院, 新加坡 639798;  
3. 中国科学院信息工程研究所, 北京 100093; 4. 中国科学院大学网络空间安全学院, 北京 100049)

**摘要:** 增量目标检测 (Incremental Object Detection, IOD) 旨在使模型从流式数据中持续学习新类别的识别与精确定位能力, 同时有效保持对已学旧类别的检测性能。然而, 当前主流目标检测器在增量训练过程中易遭遇灾难性遗忘问题: 当仅利用新类别标注数据微调时, 其对旧类别的检测性能显著退化。现有方法多依赖知识蒸馏或样本重放策略以缓解遗忘, 但普遍忽视增量训练中的两个关键挑战: 一是区域提议生成中的标签分配冲突, 二是基于有限旧样本的硬标签监督所引发的过拟合风险。本文指出, 现有方法在区域提议生成阶段采用不一致的标签分配策略: 新类别与背景提议依据其与真实标注的交并比 (Intersection over Union, IoU) 匹配生成, 而旧类别提议则依赖旧模型置信度进行推断。当两类提议在空间上重叠时, 同一候选区域可能被赋予矛盾标签, 导致分类与回归任务接收到冲突监督信号, 干扰模型有效训练。此外, 即使引入少量回放旧样本, 若对其施加硬标签监督, 模型仍易在小规模子集上过拟合, 难以复现其在原始大规模旧数据集上获得的泛化能力, 反而削弱旧知识保留效果。为此, 本文提出一种面向增量目标检测的解耦学习框架。首先设计分层解耦的候选区域分配机制, 依据“新类别→旧类别→背景类”提议的优先级顺序, 对重叠区域进行互斥筛选, 从源头消除标签冲突。进而引入双路径解耦监督策略: 对新类别及背景区域采用真实标注训练, 其中背景区域基于无偏背景定义进行监督; 而对所有旧类别区域, 无论是否在回放样本中显式标注, 均仅通过知识蒸馏施加软监督, 使其预测分布与旧模型输出对齐, 避免硬标签诱导的局部过拟合, 协同保障整个检测器训练过程的监督一致性与学习稳定性。在 Pascal VOC 与 MS COCO 标准基准上的实验表明, 所提方法在单步及多步增量设置下均优于当前最先进 (State-Of-The-Art, SOTA) 方法, 尤其在多步增量场景中, 本文方法在平均精度 (mean Average Precision, mAP) 上分别提升 2.0% 和 2.9% 以上, 有效验证了其在协同保留旧知识与学习新任务方面的优越性。本工作不仅提升了增量目标检测的持续学习能力, 也揭示了区域提议生成与监督策略协同设计在缓解灾难性遗忘中的关键作用。

**关键词:** 增量学习; 目标检测; 知识蒸馏; 样本重放; 灾难性遗忘

**基金项目:** 国家自然科学基金 (No.62025604)

**中图分类号:** TP391.4

**文献标识码:** A

**文章编号:** 0372-2112(2025)12-4494-13

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20250673

## Towards Incremental Object Detection via Hierarchical Proposal and Decoupled Supervision

LIANG Jia-wei<sup>1</sup>, LIANG Si-yuan<sup>2</sup>, CHEN Ruo-yu<sup>3,4</sup>, LIU Kuan-rong<sup>1</sup>, HUANG Jian-jie<sup>1</sup>, CAO Xiao-chun<sup>1\*</sup>

(1. School of Cyber Science and Technology, Sun Yat-sen University, Shenzhen, Guangdong 518102, China;

2. College of Computing and Data Science, Nanyang Technological University, Singapore 639798, Singapore;

3. Institute of Information Engineering, Chinese Academy of Sciences, Beijing 100093, China;

4. School of Cyber Security, University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** Incremental object detection (IOD) aims to enable models to continuously learn the recognition and localization of new categories from streaming data, while effectively maintaining detection performance on previously learned old classes. However, current mainstream object detectors often suffer from catastrophic forgetting during incremental training: their performance on old classes degrades significantly when fine-tuned only with labeled data from new classes. Existing methods mostly rely on knowledge distillation or exemplar replay strategies to mitigate forgetting, but generally over-

look two critical challenges: first, label assignment conflicts in region proposal generation, and second, the overfitting risk induced by hard-label supervision on limited old samples. This paper points out that existing methods adopt inconsistent label assignment strategies in the proposal generation stage: new category and background proposals are matched based on the intersection over union (IoU) with ground truth, whereas old category proposals rely on inferences from the old model. When these two types of proposals overlap spatially, the same candidate region may be assigned contradictory labels, leading to conflicting supervision signals for classification and regression tasks and interfering with effective training. Furthermore, even with a few replayed old samples, applying hard-label supervision makes the model prone to overfitting on small subsets, making it difficult to reproduce the generalization ability gained from the original large-scale datasets, which in turn weakens old knowledge preservation. To address these issues, we propose a decoupled learning framework for incremental object detection. First, a hierarchically decoupled region proposal assignment mechanism is designed to perform mutually exclusive screening of overlapping regions according to a priority order of “new categories  $\rightarrow$  old categories  $\rightarrow$  background”, eliminating label conflicts. Subsequently, a dual-path decoupled supervision strategy is introduced: new categories and background regions are trained with ground-truth annotations (using an unbiased background definition), while all old category regions, regardless of whether they are explicitly labeled in replayed samples, are supervised solely through knowledge distillation to align their prediction distributions with the old model’s outputs. This avoids local overfitting induced by hard labels and ensures supervision consistency and learning stability throughout the training process. Experiments on Pascal VOC and MS COCO benchmarks demonstrate that the proposed method outperforms state-of-the-art (SOTA) methods in both single-step and multi-step incremental settings. Notably, in multi-step scenarios, our method improves the mean average precision (mAP) by over 2.0% and 2.9% respectively, validating its superiority in synergistically preserving old knowledge and learning new tasks. This work not only enhances the continual learning capability of IOD but also reveals the critical role of the collaborative design of proposal generation and supervision strategies in mitigating catastrophic forgetting.

**Key words:** incremental learning; object detection; knowledge distillation; exemplar replay; catastrophic forgetting  
**Foundation Item(s):** National Natural Science Foundation of China (No.62025604)

## 1 引言

现有的基于深度学习的目标检测器<sup>[1-6]</sup>通常在大规模静态数据集上完成训练,且性能表现优异.然而,在实际应用场景中,往往要求目标检测器能够从流数据中持续学习,实现对新出现类别的检测<sup>[7]</sup>,这种需求正日益增长.现有目标检测器在增量学习过程中,常常会面临灾难性遗忘(Catastrophic Forgetting)问题<sup>[8]</sup>.当利用新类别的数据进行增量训练时,模型对先前已学得类别的检测能力显著下降.这一性能衰减现象,一方面是由于对旧类别数据的受限获取,另一方面则源于现有目标检测器训练范式未充分考虑增量学习场景的特性,缺乏对新旧知识协同学习的机制支持<sup>[9]</sup>.因此,如何使目标检测器更好地适应增量学习场景,仍是一项亟待解决的重大挑战.

在增量目标检测中,灾难性遗忘的一个关键成因在于新任务数据中可能包含未标注的旧类别实例,而这些实例在训练过程中会被错误地视为背景,导致模型对旧类别的判别能力逐渐退化.为缓解这一问题,现有方法<sup>[10,11]</sup>主要采用知识蒸馏<sup>[12]</sup>技术,通过约束新模型在前景分数最高的感兴趣区域(Regions of Interest, RoIs)<sup>[5]</sup>上的输出与旧模型保持一致,以保留旧类别知识.尽管此类方法在分类或检测框输出的一致性建模方面取得一定成效,却普遍忽视了区域提议(Region

Proposals)生成机制中存在的固有冲突.具体来说,如图1(a)所示,旧模型会依据置信度分数生成旧类别的潜在候选提议,而新类别与背景的背景提议则基于真实标注通过交并比(Intersection over Union, IoU)匹配获得.两种不同的策略可能会导致旧类别的提议与新类别或背景类别的提议之间出现重叠,导致同一候选区域被赋予不同标签.这种标签分配的不一致性在后续分类与回归任务中引入了冲突监督信号,进而干扰模型的学习稳定性.

另一个导致遗忘的原因是旧类别样本的获取受限.现有方法普遍采用样本重放(replay)策略,通过存储少量旧样本并在增量阶段进行样本重放,即利用所存储的标注信息对模型进行监督,从而缓解模型对旧类别知识的遗忘.然而,本文研究发现,即便标注准确,仅依赖有限的重放样本对旧类别施加硬标签监督,仍可能导致模型整体性能下降.如图1(b)所示,其原因在于:模型在小规模旧样本数据子集上训练时发生过拟合,难以保持最初在大规模旧类别数据集上训练时的性能.

为应对上述挑战,本文提出目标检测解耦增量学习(Decoupled Incremental Learning for Object Detection, DILOD)方法.为解决标签冲突问题,该方法首先对不同类型的区域提议确定优先级:新类别提议( $P_N$ )和背景提议( $P_{BG}$ )基于IoU分数从真实标注中获取,旧类别

提议( $P_O$ )则基于置信度分数从旧模型中获得. 优先级顺序确定为: $P_N \rightarrow P_O \rightarrow P_{BG}$ . 与高优先级提议存在重叠的低优先级提议将被舍弃, 剩余的提议则被送入分类或回归头进行训练. 值得注意的是, 在提议生成训练过程中(例如使用区域提议网络(Region Proposal Network, RPN)<sup>[5]</sup>时), 同样会依据该优先级方案来解决提议冲突问题. 为减轻对旧类别使用硬标签所带来的不利影响, 本文提出一种双路径监督方法. 对于通过上述解耦提议策略筛选出的 $P_N$ 和 $P_{BG}$ , 采用真实标注进行监督; 而对于 $P_O$ , 则通过知识蒸馏, 借助无偏蒸馏损失使预测分布与旧模型的输出保持一致, 且无需进行标签监督. 需要说明的是, 这种解耦策略同样适用于提议生成训练过程. 在Pascal-VOC和MS COCO数据集上对

所提方法进行的全面评估结果显示, 在多步增量设置下, 与目前最先进的方法相比, 平均精度(mean Average Precision, mAP)分别提升了2.0%以上和2.9%以上. 本文的主要贡献如下:

(1)发现了增量目标检测中的两个关键问题: 一是由不兼容的区域提议策略引发的标签冲突, 二是因使用有限重放的旧实例硬标签进行监督而导致的过拟合.

(2)提出了DILOD方法, 该方法通过基于优先级的筛选机制解决标签冲突, 并引入双路径监督策略, 对旧实例和新实例实施差异化监督.

(3)所提方法在Pascal-VOC和MS COCO数据集的单步及多步增量设置中, 均显著优于当前最先进的方法, 充分验证了其有效性.

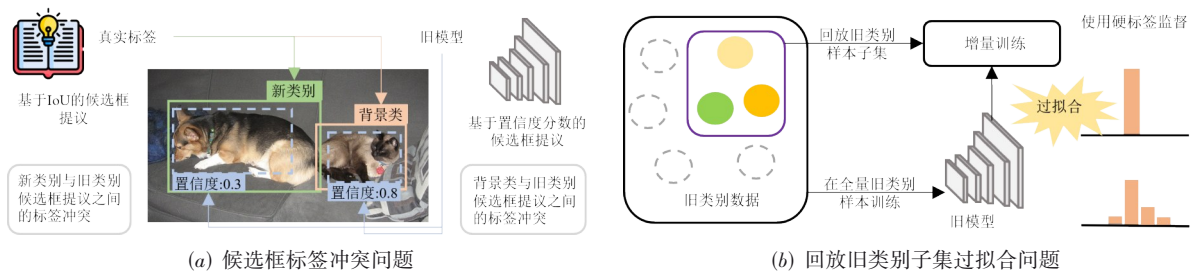


图1 本文聚焦的目标检测增量学习中的两个挑战问题

## 2 相关工作

### 2.1 目标检测

作为计算机视觉领域的一项基础任务, 基于深度学习的目标检测<sup>[13]</sup>方法取得了显著进展. 现有方法主要包括基于锚框的两阶段检测器<sup>[4-6]</sup>, 该类方法通过RPN生成候选框, 并在后续阶段进行分类与回归; 以及单阶段检测模型<sup>[14,15]</sup>, 这类模型将目标检测建模为直接回归任务, 以实现实时性能. 此外, 无锚框方法<sup>[16]</sup>通过预测关键点或中心点直接定位目标, 避免了锚框设计带来的超参数依赖. 近年来, DETR(DEtection TRansformer)<sup>[17]</sup>引入Transformer架构, 实现了端到端的目标检测. 然而, 这些方法多基于静态数据集训练, 在增量学习场景下易出现性能下降. 本文聚焦于扩展现有两阶段检测器(如Faster R-CNN)以支持类别增量学习.

### 2.2 类别增量学习

类别增量学习(Class-Incremental Learning, CIL)<sup>[7,18]</sup>的核心挑战是灾难性遗忘, 即模型在增量数据集上学习新类别时会遗忘旧类别知识. 产生遗忘的一个关键原因是旧类别数据的受限获取. 基于记忆的方法<sup>[19,20]</sup>通过存储或合成少量旧类别数据, 并将其与新数据一起用于训练模型, 来缓解遗忘. 另一个导致遗忘的因素是不同任务间共享参数. 基于参数隔离的方法<sup>[21-23]</sup>通

过设计动态结构以隔离新旧任务参数. 此外, 基于正则化的方法<sup>[24,25]</sup>则通过约束参数更新过程来保护关键权重, 典型手段包括重要参数感知与更新<sup>[26]</sup>和知识蒸馏<sup>[27]</sup>, 后者通过保留旧模型的输出分布实现知识迁移. 尽管基于正则化的方法无需存储旧数据或扩展模型参数, 但性能往往不够理想. 因此, 研究重点放在融合记忆重放与知识蒸馏的混合策略.

### 2.3 增量目标检测

为使目标检测器适应增量学习场景, 现有方法主要围绕知识蒸馏与样本重放两类技术路径展开, 最近工作尝试融合二者以兼顾效率与性能. 知识蒸馏通过将旧模型(教师模型)的知识迁移至新模型(学生模型), 避免显式存储旧数据. 早期工作<sup>[10,28]</sup>利用旧模型在旧类别上的输出(如分类logits或回归结果)作为软监督信号, 引导新模型保持旧类别知识. 后续研究进一步探索蒸馏位置, 包括中间特征图<sup>[29,30]</sup>和检测头输出<sup>[31]</sup>的对齐. 然而, 这类方法面临一个挑战: 新任务图像中旧类别实例常未标注, 会被错误地当作背景进行监督学习, 导致监督偏差. 为缓解此问题, 近期研究<sup>[32]</sup>提出了无偏损失函数以减轻此类偏差影响. 有研究<sup>[28]</sup>采用粗粒度方法对区域提议网络进行蒸馏, 但忽略了提议生成过程中的标签冲突. 样本重放则通过保留少量旧类别样本进行联合训练, 在保持旧知识上往往有更优

的性能. 早期方法<sup>[33,34]</sup>会存储并重放旧类别的部分完整图像. 近期的进展还提出使用元学习<sup>[35]</sup>, 结合样本重放进行模型训练梯度重塑. 与重放完整图像相比, ABR (Augmented Box Replay) 方法<sup>[36]</sup>提出重放检测框实例, 融合知识蒸馏技术, 在降低存储开销同时取得性能提升. 尽管融合记忆重放与知识蒸馏的方法性能较好, 但仍面临区域提议策略不兼容的问题, 可能引发标签冲突; 此外, 还存在有限回放数据上施加硬标签监督易导致过拟合的问题.

### 3 本文方法

#### 3.1 问题定义

目标检测旨在训练模型同时完成目标定位与分类, 即通过检测框精确定位物体并将其归类至预定义类别. 本文聚焦于 Faster R-CNN<sup>[5]</sup>, 这是一种两阶段目标检测器, 由 RPN 和区域分类网络 (Region Classification Network, RCN) 组成. RPN 负责生成区域提议, 而 RCN 则对 RoIs 进行类别预测和检测框输出. 设数据样本表示为  $(X, Y) \in D$ , 其中  $Y = \left\{ \left( \hat{b}_i, \hat{y}_i \right) \right\} (i=1, 2, \dots, N_{gt})$  代表真实检测框  $\hat{b}_i$  及其对应类别标签  $\hat{y}_i$  的集合. 在 RPN 训练过程中, 生成提议集  $P = \left\{ \left( b_i, y_i \right) \right\} (i=1, 2, \dots, N_p)$ , 每个提议的标签基于与真实标注的 IoU 确定. 这些提议随后用于 RCN 网络训练. RCN 输出预测结果  $O = \left\{ \left( b_i, y_i \right) \right\} (i=1, 2, \dots, N_r)$ , 其中  $b_i$  和  $y_i$  分别为预测的检测框坐标和类别标签. RPN 或 RCN 的损失函数通常定义为

$$\mathcal{L}_t = \frac{1}{N} \sum_{i=1}^N \mathcal{L}_{cls}(y_i, \hat{y}_i) + \mathcal{L}_{reg}(b_i, \hat{b}_i) \quad (1)$$

其中,  $\mathcal{L}_{cls}$  和  $\mathcal{L}_{reg}$  分别表示分类损失和回归损失.

在增量学习场景中, 目标检测器需要在受限访问旧类别数据的情况下, 依次在新数据上训练<sup>[10]</sup>. 形式上, 设  $T = \left[ (C_1, D_1), (C_2, D_2), \dots, (C_m, D_m) \right]$  表示类别增量任务序列. 对于第  $t$  个任务  $T_t = (C_t, D_t)$ ,  $C_t = (c'_1, c'_2, \dots, c'_k)$  表示任务  $t$  中的新类别集合,  $D_t = \left\{ \left( X'_i, Y'_i \right) \right\} (i=1, 2, \dots, n)$  为对应数据集, 该数据集仅包含  $C_t$  中类别的标注. 当使用式(1)定义的检测损失在任务  $C_t$  的数据集  $D_t$  上进行增量训练时, 模型在旧类别  $C_{1:t-1}$  上的性能往往会下降. 为缓解这种灾难性遗忘问题, 现有方法<sup>[36]</sup>通过使当前模型  $f_{\theta^t}$  与旧模型  $f_{\theta^{t-1}}$  在旧模型生成的具有高置信度提议  $P^{t-1} = \left\{ \left( b_i, y_i \right) \right\} (i=1, 2, \dots, N_d)$  上的输出保持一致来实现. 蒸馏损失定义为

$$\mathcal{L}_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \mathcal{L}_{cls}(y'_i, y_i^{t-1}) + \mathcal{L}_{reg}(b'_i, b_i^{t-1}) \quad (2)$$

其中,  $(y'_i, b'_i)$  和  $(y_i^{t-1}, b_i^{t-1})$  分别表示当前模型  $f_{\theta^t}$  和旧模型  $f_{\theta^{t-1}}$  在相同提议上的分类与检测框预测结果. 此外, 现有方法会存储部分旧任务数据 (记为  $D_{1:t-1}^s$ ), 并将其与当前任务的新数据结合形成联合数据集  $D_t^s = D_{1:t-1}^s \cup D_t$ . 模型在该数据集上联合优化检测损失和蒸馏损失, 以进一步缓解遗忘.

当前增量目标检测方法存在两个关键缺陷.

(1) 区域提议标签冲突, 这是由不同区域提议生成策略的不兼容所导致. 在标准训练中, 若提议与真实检测框的 IoU 较高, 则被标记为前景, 否则为背景. 然而, 在用于保留旧知识知识蒸馏中, 区域提议基于置信度分数生成, 具有高置信度分数的提议被视为旧类别的潜在前景实例. 这种提议策略的差异可能导致当前任务基于 IoU 分数生成的提议  $P^t = P$  与旧模型基于置信度分数生成的提议  $P^{t-1}$  存在重叠. 具体而言:

$$P^t \cap P^{t-1} \neq \emptyset \quad (3)$$

这种重叠会导致单个提议可能存在多个冲突的标签, 例如式(1)中的真实标签  $(\hat{y}_i, \hat{b}_i)$  与式(2)中来自旧模型的软输出  $(y_i^{t-1}, b_i^{t-1})$ . 考虑一个旧类别的提议, 其在当前任务中未被标注, 并且其与新类真实框的 IoU 较低, 该提议被归类为背景; 但结合旧模型的软输出, 该提议具有较高的旧类别置信度分数或分类分数. 这种冲突导致同一提议在 RPN 和 RCN 训练时接收到矛盾监督, 干扰模型学习.

(2) 过拟合风险, 这源于对当前模型在存储的旧类别数据子集上进行硬标签监督. 在基于重放的方法中, 旧类别的实例和标签被存储, 并在新类别的增量训练中重放. 然而, 本文发现使用存储的旧类别数据子集的硬标签进行监督, 难以实现对旧知识的充分保留. 这是由于旧模型是在更大的数据集上训练的, 在旧数据的小子集上使用硬标签进一步训练可能导致过拟合, 进而降低模型先前获得的对旧类别的检测能力.

为解决上述问题, 本文提出一种解耦增量学习方案. 首先, 通过预定义区域提议优先级, 对基于 IoU 生成的新类提议  $P^t$  与基于置信度生成的旧类提议  $P^{t-1}$  进行互斥分配, 消除二者在空间重叠区域可能引发的标签冲突, 确保每个提议仅接受唯一的监督标签. 其次, 对新类与背景类采用当前任务的真实标注进行监督, 而对所有旧类实例, 无论是否在回放样本中显式标注, 均通过固定参数的旧模型施加软监督, 即采用知识蒸馏损失, 使其输出对齐旧模型在完整旧数据集上学习到的分布. 与现有方法相比, 本文的核心改进在于: 现有工作通常独立地在  $P^t$  与  $P^{t-1}$  上施加监督, 未处理二者重叠带来的矛盾监督标签, 而本文通过优先级机制显式去除冲突; 同时, 现有方法往往依据候选框的标签

定义损失函数,对回放的旧类样本也采用硬标签监督,易导致模型过拟合于小规模子集的局部分布,偏离旧任务在全集上建立的泛化能力,而本文方法根据候选

框类别来定义损失,对有标签的旧样本也采用蒸馏监督,从而更有效地保留旧知识的完整性. 本文方法的整体框架如图2所示.

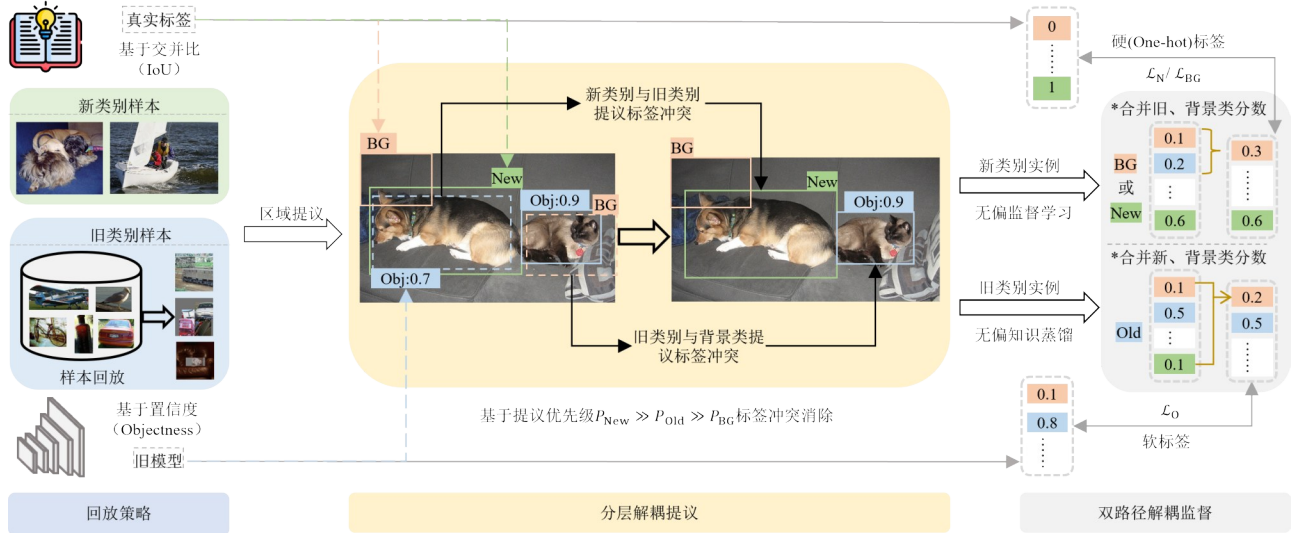


图2 目标检测解耦增量学习整体框架

### 3.2 分层解耦提议

为解决区域提议监督标签分配冲突问题,引入分层解耦提议(Hierarchical Decoupled Proposals, HDP)策略,通过优先级策略确保每个提议仅接受唯一标签. 具体而言,将候选提议划分为三类:新类别提议( $P_N$ )、背景提议( $P_{BG}$ )和旧类别提议( $P_O$ ). 其中,新类别提议( $P_N$ )和背景提议( $P_{BG}$ )基于与真实标注的IoU进行标注,而旧类别提议( $P_O$ )基于旧模型预测的置信度分数分配软标签. 由于 $P_N$ 和 $P_{BG}$ 采用统一的基于IoU的策略生成,潜在的标签冲突仅发生在 $P_O$ 与 $P_N$ 或 $P_{BG}$ 之间. 为解决这些冲突,采用以下预定义的提议标注优先级:

$$P_N \rightarrow P_O \rightarrow P_{BG} \quad (4)$$

该优先级顺序的依据如下:首先, $P_N$ 直接使用真实标签标注,其可靠性本质上高于 $P_O$ ( $P_O$ 由旧模型生成,可能包含不可靠预测),因此分配 $P_N$ 最高优先级;其次,由于新类别数据集缺乏旧类别的标注,部分属于旧类别的目标可能被误分类为背景;通过将 $P_{BG}$ 分配为最低优先级,旨在更好地保留旧类别的知识. 为判断两个提议是否重叠,采用常用的IoU阈值 $\tau=0.5$ . 基于上述定义,第 $t$ 个任务的提议集表示为

$$\hat{P}^t = P_N \cup P_O \cup P_{BG} \quad (5)$$

其中,各组成部分定义为

$$P_N = \{(b_i, y_i) \in P^t \mid y_i \in C_i\} \quad (6)$$

$$P_O = \{(b_i, y_i) \in P^{t-1} \mid \forall (b_j, y_j) \in P_N, H(b_i, b_j)\} \quad (7)$$

$$P_{BG} = \{(b_i, y_i) \in P^t \setminus P_N \mid \forall (b_j, y_j) \in P_O, H(b_i, b_j)\} \quad (8)$$

$$H(b_i, b_j) \equiv \text{IoU}(b_i, b_j) < \tau \quad (9)$$

该定义可确保不同类别的提议不重叠,且每个提议都有唯一的监督标签. 这种分层提议分配方法适用于RPN和RCN的训练流程. 值得注意的是,若存储的旧类别样本被包含在训练数据中,提议集 $P^t$ 可能也包含标注为旧类别的提议(即 $y_i \in C_{1:t-1}$ ). 此时,若旧模型对其预测置信度较高,仍将其归入 $P_O$ . 该策略旨在与新数据集中未标注的旧类别处理方式保持一致,保证提议生成机制的统一性.

### 3.3 双路径解耦监督

在类别增量学习任务中,往往难以维持模型在旧类别上的性能,尤其是当新数据集中没有旧类别的实例时. 现有基于重放的方法通过存储旧类别实例的子集,并在增量学习中重放这些实例来解决该问题. 然而,直接使用该有限子集的硬标签进行监督可能导致过拟合,降低模型对旧类别的检测能力.

具体而言,在增量学习之前,模型在旧任务的完整数据集 $D_{1:t-1}$ 上训练. 由于模型限制,其在 $D_{1:t-1}$ 上的预测可能无法完美匹配真实标注(例如,预测置信度为0.7而非1),这反映了在整个旧数据集上达成的折中. 当在存储的旧类别数据子集( $|D_{1:t-1}^s| \ll |D_{1:t-1}|$ )上进行增量训练时,模型可能更好地拟合该子集,但会降低原本的泛化能力.

为解决这一问题,本文提出双路径解耦监督策略

(Dual-Path Decoupled Supervision, DPDS), 对新类别、背景与旧类别实施差异化监督. 一方面, 对所有旧类别实例(包括重放的和未标注的)仅采用蒸馏方式, 使预测与旧模型的预测保持一致. 对于新类别实例, 模型使用真实标注监督训练, 因为这些类别在旧类别训练中不存在, 或被旧模型误分类为背景. 此外, 模型必须区分背景区域. 然而, 背景标签并非直接可用, 因为基于与新类别的 IoU 确定的区域可能包含潜在的旧类别实例. 参考先前工作, 采用无偏损失进行背景类学习, 将背景定义为不包含新类别的区域, 以确保更准确的背景学习.

形式上, 为了在  $P_N$  上学习新类别, 使用真实标注和式(1)所示的任务损失函数(适用于 RPN 和 RCN). 对于 RPN,  $\hat{y}_i$  指与类别无关的标签(前景或背景); 对于 RCN,  $\hat{y}_i$  指类别相关的标签:

$$\mathcal{L}_N = \frac{1}{|P_N|} \sum_{i=1}^{|P_N|} [\mathcal{L}_{\text{cls}}(y_i, \hat{y}_i) + \mathcal{L}_{\text{reg}}(b_i, \hat{b}_i)] \quad (10)$$

其中,  $\mathcal{L}_{\text{cls}}$  采用交叉熵损失;  $\mathcal{L}_{\text{reg}}$  采用平滑 L1 损失;  $(\hat{b}_i, \hat{y}_i)$  表示真实标签. 对于  $P_{\text{BG}}$  上的背景类学习, 使用无偏交叉熵损失  $\mathcal{L}_{\text{cls}}^{\text{ub}}$ :

$$\mathcal{L}_{\text{BG}} = \frac{1}{|P_{\text{BG}}|} \sum_{i=1}^{|P_{\text{BG}}|} [\mathcal{L}_{\text{cls}}^{\text{ub}}(y_i, \hat{y}_i)] \quad (11)$$

$$\mathcal{L}_{\text{cls}}^{\text{ub}}(y_i, \hat{y}_i) = - \left( \sum_{c \in \mathcal{C}'} \hat{y}_i^c \right) \log \left( \sum_{c \in \mathcal{C}'} y_i^c \right) \quad (12)$$

该损失用于背景区域的分类, 由于  $P_{\text{BG}}$  中不存在新类别实例, 因此将背景和旧类别(即所有  $c \in \mathcal{C}'$ ) 的概率聚合, 将其总和作为背景.

为保留旧类别的知识, 本文摒弃对旧实例的硬标签监督, 转而通过蒸馏机制维持旧模型的输出分布. 这种方法考虑到重放样本数量有限以及可能存在未标注的旧实例. 本文应用无偏 KL 散度损失 (Kullback-Leibler Divergence Loss)  $\mathcal{L}_{\text{KL}}^{\text{ub}}$  使软分类输出与旧模型的输出对齐, 并使用平滑  $\mathcal{L}_1$  损失进行检测框回归. 损失函数定义如下:

$$\mathcal{L}_O = \frac{1}{|P_O|} \sum_{i=1}^{|P_O|} [\mathcal{L}_{\text{KL}}^{\text{ub}}(y_i^t, y_i^{t-1}) + \mathcal{L}_{\text{reg}}(b_i^t, b_i^{t-1})] \quad (13)$$

其中,

$$\mathcal{L}_{\text{KL}}^{\text{ub}}(y_i^t, y_i^{t-1}) = \sum_{c \in \mathcal{C}^{t-1}} y_i^{t-1, c} \log \left( \frac{y_i^{t-1, c}}{y_i^{t, c}} \right) + y_i^{t-1, \text{bg}} \log \left( \frac{y_i^{t-1, \text{bg}}}{\sum_{c \in \mathcal{C}^{t-1}} y_i^{t, c}} \right) \quad (14)$$

在  $\mathcal{L}_{\text{KL}}^{\text{ub}}$  损失中, 将新类别与背景的概率聚合(即  $\sum_{c \in \mathcal{C}^{t-1}} y_i^{t, c}$ ), 并使其与旧模型的背景概率(即  $y_i^{t-1, \text{bg}}$ ) 对

齐. 这是因为旧模型将新类别分类为背景. 这种策略有助于保留旧模型为旧类别建立的决策边界, 同时促进新类别的学习.

最终, 整体损失表示为

$$\mathcal{L}_{\text{all}} = \mathcal{L}_N + \mathcal{L}_{\text{BG}} + \alpha \cdot \mathcal{L}_O \quad (15)$$

其中,  $\alpha$  是平衡旧类别保留与新类别学习的超参数. 算法 1 展示了本文所提出的目标检测解耦增量学习方法的整体算法流程. 首先, 依据式(4)计算的优先级对检测框提议进行解耦; 随后, 针对解耦后的检测框分别采用不同的损失函数进行优化.

#### 算法 1 目标检测解耦增量学习算法

输入: 联合数据集  $D_t^S = D_{t-1}^S \cup D_t$ , 旧模型参数  $\theta^{t-1}$ , 旧类别损失权重  $\alpha$ , IoU 阈值  $\tau$

输出: 新模型参数  $\theta^t$

FOR  $(X, Y) \in D_t^S$

1. 通过真实标签生成提议集  $P^t = f_{\theta^t}^{\text{RPN}}(X, Y)$

2. 通过旧模型生成提议集  $P^{t-1} = f_{\theta^{t-1}}^{\text{RPN}}(X)$

// 分层解耦提议

3.  $P_N \leftarrow \{(b_i, y_i) \in P^t | y_i \in \mathcal{C}'\}$  // 新类别

4.  $P_O \leftarrow \{(b_i, y_i) \in P^{t-1} | \forall (b_j, y_j) \in P_N, \text{IoU}(b_i, b_j) < \tau\}$  // 旧类别

5.  $P_{\text{BG}} \leftarrow \{(b_i, y_i) \in P^t \setminus P_N | \forall (b_j, y_j) \in P_O, \text{IoU}(b_i, b_j) < \tau\}$  // 背景类别

// 双路径解耦监督

6.  $\forall (b_i, y_i) \in P_N$ , 计算  $\mathcal{L}_N$ (式(10))

7.  $\forall (b_i, y_i) \in P_O$ , 计算  $\mathcal{L}_O$ (式(13))

8.  $\forall (b_i, y_i) \in P_{\text{BG}}$ , 计算  $\mathcal{L}_{\text{BG}}$ (式(11))

9. 计算总损失  $\mathcal{L}_{\text{all}} = \mathcal{L}_N + \mathcal{L}_{\text{BG}} + \alpha \cdot \mathcal{L}_O$

10. 更新模型参数  $\theta^t$

END FOR

## 4 实验结果与分析

### 4.1 实验设置

实验在两个公开数据集上对所提方法进行评估, 分别是 PASCAL VOC 2007<sup>[37]</sup> 和 MS COCO 2017<sup>[38]</sup>. PASCAL VOC 2007 包含 20 个目标类别, 共 9 963 张图像, 其中 5 011 张用于训练, 其余用于测试. MS COCO 2017 是一个更具挑战性的数据集, 包含 80 个目标类别, 12 万张训练图像和 5 千张测试图像. 实验遵循先前工作<sup>[36]</sup> 的评估设置, 对于 PASCAL VOC 2007, 报告 IoU 阈值为 0.5 时的平均精度 (Average Precision, AP), 记为 AP@0.5; 对于 MS COCO 2017, 提供 IoU 阈值从 0.5 到 0.95 的 mAP, 记为 mAP@[50:95].

实验遵循先前工作<sup>[32, 36, 39, 40]</sup> 中增量目标检测的设定. 每个训练任务包含所有至少含一个新类别检测框的图像, 且仅对这些新类别进行标注; 旧类别与未来类别均不标注, 允许图像在不同任务间重复出现. 实验采

用 Faster R-CNN<sup>[5]</sup>架构,以在 ImageNet<sup>[41]</sup>上预训练的 ResNet-50<sup>[42]</sup>作为骨干网络,训练过程使用随机梯度下降(Stochastic Gradient Descent,SGD)优化器,其动量设置为0.9,权重衰减设置为 $10^{-4}$ .对于PASCAL VOC 2007数据集,旧类别样本存储数量设为2 000,混合(mixup)、拼接(mosaic)、替换(substitute)与新图像的比例为1:1:1:3,以此平衡旧目标与新目标.不同策略下旧类别重放实例如图3所示.初始训练任务的学习率为 $5 \times 10^{-3}$ ,训练迭代次数为15 000;后续任务中,当增加5、10或15个类别时,保持15 000迭代次数不变,超参数 $\alpha$ 设

置为0.2;当增加1或2个类别时,迭代次数减至5 000,超参数 $\alpha$ 设置为1.0.后续任务的学习率设置为:增加10或15个类别时,保持 $5 \times 10^{-3}$ ;增加1、2或5个类别时,降至 $2 \times 10^{-3}$ .所有实验的批处理大小均为4.对于MS COCO 2017数据集,旧类别样本存储数量设为5 000,混合、拼接、替换与新图像的比例为1:1:1:9,以保证代表性平衡.初始任务的学习率为 $2 \times 10^{-2}$ ,训练迭代次数为90 000,实现参数的充分优化;后续任务采用较低学习率 $5 \times 10^{-3}$ ,训练迭代次数为45 000,超参数 $\alpha$ 设置为0.5.MS COCO数据集的批处理大小设为16.



图3 旧类别实例重放示意图

## 4.2 实验结果

遵循先前工作<sup>[36]</sup>,实验在不同增量设置下对方法进行评估,包括初始任务类别数量不同和单步或多步增量任务的情况.除了两个基线方法(微调(Fine-tuning,在不使用正则化或数据重放的情况下进行增量训练)和联合训练(Joint Training,在整个数据集上使用所有标注进行训练)外,还与多种最先进的方法进行了比较,包括 ILOD(Incremental Learning of Object Detectors)<sup>[10]</sup>、Faster ILOD<sup>[28]</sup>、PPAS(Pseudo-Positive Aware Sampling)<sup>[30]</sup>、MVC(Multi-View Correlation)<sup>[29]</sup>、MMA(Modeling Missing Annotations)<sup>[32]</sup>、ORE(Open World Object Detector)<sup>[33]</sup>、OW-DETR(Open World DETR)<sup>[34]</sup>、Meta-ILOD<sup>[35]</sup>、ABR<sup>[36]</sup>、DTD(Dual-Teacher Distillation)<sup>[43]</sup>和BPF(Bridge Past and Future)<sup>[44]</sup>.所有实验结果均在最后一个任务训练完成后报告.

### 4.2.1 PASCAL VOC 2007上的结果

实验基于先前工作<sup>[36]</sup>的设置开展.对于单步增量任务,采用19-1、15-5、10-10和5-15的配置,分别增加1、5、10和15个类别.对于多步增量任务,采用10-5、5-5、10-2、15-1和10-1的配置,每步分别增加5、5、2、1和1个类别,直至涵盖所有20个类别.

将所提DILOD方法与现有方法进行了基准测试,单步增量结果如表1所示.可以观察到,微调在所有设置下都存在灾难性遗忘问题,这体现在其在旧类别上的性能较差.所提方法在整体性能上优于所有其他方法,尤其是在增量训练更多类别时.例如,在19-1的小增量设置下略低于先进的DTD<sup>[43]</sup>方法,但在更具挑战性的15-5和10-10大增量设置中,DILOD均取得了更优的性能.DTD方法通过对旧类别施加更强的蒸馏约束正则(包括利用假阳性样本),能够更好地保持旧类

识,在以旧类别为主的19-1设定中表现更佳.而DILOD注重平衡新旧类别的学习过程,在新旧类别数量均衡的10-10设定下,整体性能更为稳定.进一步地,与最先进的基于重放的方法ABR<sup>[36]</sup>相比,DILOD在10-10设置下的AP@0.5提高了0.6%;在5-15设置中,AP@0.5提高了2.0%.此外,所提方法在旧类别和新类别上均持续表现出色,表明在稳定性和可塑性之间取得了更好的平衡.

多步增量结果如表2所示,在多步增量场景中,灾难性遗忘的挑战更为明显.值得注意的是,当增量类别的总数相同时,随着增量步骤的增加,所有方法的性能都会下降,如10-5和10-1设置所示.然而,所提方法始终优于其他方法,在所有多步设置中,无论是整体性能还是在旧类别和新类别上的单独表现都表现出色,这与单步观察结果一致.具体而言,与先进的BPF<sup>[44]</sup>方法相比,随着增量步数的增加,所提方法的提升越加明显,在最具挑战的10-1设置下,取得了9.0%的AP@0.5提升.进一步地,在10-5设置中,所提方法比最先进的ABR<sup>[36]</sup>高出2.0%的AP@0.5;在10-1设置中,高出5.3%的AP@0.5.在5-5任务中取得的改进最为显著,这归因于在新类别上的优异表现,凸显了所提方法在减轻遗忘的同时有效学习新类别的能力.

### 4.2.2 MS COCO 2017上的结果

实验采用单步增量任务设置40-40、50-30、60-20和70-10进行实验,分别增加40、30、20和10个类别.对于多步增量设置,评估40-20和60-10配置下的性能,每步分别增加20和10个类别,直至涵盖所有80个类别.

当在更大的MS COCO数据集上进行评估时,所提方法始终表现出更优的整体性能,如表3所示.具体而

表1 单步增量设置下,在PASCAL VOC 2007数据集上不同方法的AP@0.5结果

Method	19-1			15-5			10-10			5-15		
	1-19	20	1-20	1-15	16-20	1-20	1-10	11-20	1-20	1-5	6-20	1-20
Joint Training	74.2	75.7	74.3	76.4	67.8	74.3	75.5	73.0	74.3	70.1	75.7	74.3
Fine-tuning	11.8	64.7	14.4	15.9	54.2	25.5	2.6	63.4	32.9	6.9	63.1	49.1
ILOD	69.8	64.5	69.6	72.5	58.5	68.9	69.8	53.7	61.7	61.0	37.3	43.2
Faster ILOD	70.9	63.2	70.6	73.1	57.3	69.2	70.3	53.0	61.7	62.0	37.1	43.3
PPAS	70.5	53.0	69.2	—	—	—	63.5	60.0	61.8	—	—	—
MVC	70.2	60.6	69.7	69.4	57.9	66.5	66.2	66.0	66.1	—	—	—
MMA	70.9	62.9	70.5	72.7	60.6	69.7	69.8	63.9	66.8	66.8	57.2	59.6
DTD	<b>73.8</b>	68.5	<b>73.5</b>	<b>74.6</b>	58.6	70.6	70.6	71.1	70.9	—	—	—
ORE*	69.4	60.1	68.9	71.8	58.7	68.5	60.4	68.8	64.6	—	—	—
OW-DETR*	70.2	62.0	69.8	72.2	59.8	69.1	63.5	67.9	65.7	—	—	—
Meta-ILOD*	70.9	57.6	70.2	71.7	55.9	67.8	68.4	64.3	66.3	—	—	—
ABR†	71.0	69.7	70.9	73.0	<b>65.1</b>	71.0	71.2	72.8	72.0	64.7	71.0	69.4
Ours†	72.0	<b>71.4</b>	71.9	74.0	63.9	<b>71.5</b>	<b>72.7</b>	<b>72.6</b>	<b>72.6</b>	<b>69.5</b>	<b>72.0</b>	<b>71.4</b>

注:标\*的方法表示使用了图片样本重放策略,标†的方法表示采用了目标实例重放策略.每列的最佳结果用粗体突出显示.

表2 多步增量设置下,在PASCAL VOC 2007数据集上不同方法的AP@0.5结果

Method	10-5(2步增量)			5-5(3步增量)			10-2(5步增量)			15-1(5步增量)			10-1(10步增量)		
	1-10	11-20	1-20	1-5	6-20	1-20	1-10	11-20	1-20	1-15	16-20	1-20	1-10	11-20	1-20
Joint Training	75.5	73.0	74.3	70.1	75.7	74.3	75.5	73.0	74.3	76.4	67.8	74.3	75.5	73.0	74.3
Fine-tuning	5.3	30.6	18.0	0.5	18.3	13.8	3.79	13.6	8.7	0.0	10.47	5.3	0.0	5.1	2.55
ILOD	67.2	59.4	63.3	58.5	15.6	26.3	62.1	49.8	55.9	65.6	47.6	60.2	52.9	41.5	47.2
Faster ILOD	68.3	57.9	63.1	55.7	16.0	25.9	64.2	48.6	56.4	66.9	44.5	61.3	53.5	41.0	47.3
MMA	67.4	60.5	64.0	62.3	31.2	38.9	65.7	52.5	59.1	67.2	47.8	62.3	57.9	44.6	51.2
BPF	69.1	68.2	68.7	60.6	63.1	62.5	68.7	56.3	62.5	71.5	53.1	66.9	62.2	48.3	55.2
ABR†	68.7	67.1	67.9	64.7	56.4	58.4	67.0	58.1	62.6	68.7	56.7	65.7	62.0	55.7	58.9
Ours†	<b>70.9</b>	<b>68.9</b>	<b>69.9</b>	<b>66.1</b>	<b>65.3</b>	<b>65.5</b>	<b>68.7</b>	<b>62.3</b>	<b>65.5</b>	<b>72.0</b>	<b>58.2</b>	<b>68.5</b>	<b>66.1</b>	<b>62.3</b>	<b>64.2</b>

注:标†的方法表示采用实例重放策略.每列的最佳结果用粗体突出显示.

表3 单步增量设置下,在MS COCO 2017数据集上不同方法的mAP@[50:95]结果

Method	40-40			50-30			60-20			70-10		
	1-40	41-80	1-80	1-50	51-80	1-80	1-60	61-80	1-80	1-70	71-80	1-80
Joint Training	41.6	32.0	36.8	38.4	34.1	36.8	37.1	35.7	36.8	37.9	29.0	36.8
Fine-tuning	0.0	<b>28.0</b>	14.0	0.0	<b>33.1</b>	12.4	0.0	<b>34.0</b>	8.5	0.0	24.7	3.1
ILOD	35.5	24.1	29.8	30.6	27.6	29.5	28.8	30.2	29.2	28.4	23.4	27.8
Faster ILOD	37.9	16.4	27.1	<b>36.0</b>	21.0	30.4	34.2	22.6	31.3	32.5	19.1	30.9
MMA	38.2	25.3	31.8	35.3	28.4	32.7	34.2	29.6	33.1	34.9	24.3	33.5
ABR†	37.1	26.9	32.0	35.0	29.1	32.8	33.9	30.4	33.0	34.0	24.1	32.8
Ours†	<b>40.5</b>	26.8	<b>33.7</b>	35.2	31.9	<b>33.9</b>	<b>35.8</b>	32.4	<b>34.9</b>	<b>36.7</b>	<b>26.6</b>	<b>35.5</b>

注:每列的最佳结果用粗体突出显示.标有†的方法表示采用实例重放策略.

言,在70-10设置中,所提方法比最先进的方法高出2.7%的mAP@[50:95].值得注意的是,微调虽然导致在旧类别上的性能完全下降,但在新类别上取得了更好的结果.这表明在更大的数据集中,更难在减轻旧类别遗忘和增强新类别学习之间取得平衡.

实验在MS COCO数据集的多步增量设置中进行实验,多步增量结果如表4所示,与单步增量设置相比,所

提方法取得了更大的改进.具体而言,与最先进的方法相比,所提方法在40-20和60-10设置中分别提高了2.9%和3.4%的mAP@[50:95].这表明所提方法在这些更具挑战性的设置中更有效.

#### 4.2.3 消融实验与分析

为验证各模块在持续目标检测任务中的有效性,本文开展了系统的消融实验,结果如表5所示.HDP针

对区域提议中监督标签分配存在的歧义问题,提出基于优先级的解耦标签分配策略,从而降低不同类别间的学习干扰.如第1行与第2行对比所示,引入HDP后,单步增量19-1设置下旧类别的AP@0.5从69.9%提升至70.9%,多步增量10-5设置下旧类别的AP@0.5也从68.8%提升至69.8%,表明该模块有效增强了对旧类别知识的记忆保持能力,缓解了灾难性遗忘.DPDS通过解耦新旧类别的监督范式,在保留旧类别判别信息的同时促进新类别的学习.如第1行与第3行对比可见,在19-1设定下,单独引入DPDS时,旧类别的AP@0.5提升至71.2%(+1.3%),新类别性能亦由72.8%升至73.6%,该增益在15-5设置下同样稳定存在;在多步增量10-5设定下,DPDS在新旧任务上的综合提升(+1.6%)显著,验证了其在提升模型整体性能方面的有效性.当HDP与DPDS联合使用时(第4行),模型在两类设定下均取得最优的整体性能:在19-1和15-5设置中,整体AP@0.5分别达到71.9%和71.5%,在多步增量

设定(10-5和15-1)下,联合HDP与DPDS取得最优性能,优于各单一配置.这表明二者在机制上具有互补优势:HDP通过提议阶段的标签解耦减少学习冲突,DPDS则在分类和回归网络训练过程中实现新旧类别知识学习平衡.

表4 多步增量设置下,在MS COCO 2017数据集上不同方法的mAP@[50:95]结果

Method	40-20(2步增量)			60-10(2步增量)		
	1-40	41-80	1-80	1-60	61-80	1-80
Joint Training	41.6	32.0	36.8	37.1	35.7	36.8
Fine-tuning	0.0	16.2	8.1	0.0	11.4	2.8
ILOD	27.6	21.6	24.6	18.5	25.7	20.3
Faster ILOD	31.2	15.3	23.3	28.6	20.9	26.7
MMA	30.9	23.2	27.1	26.7	27.4	26.9
ABR†	31.9	23.1	27.5	26.9	27.6	27.1
Ours†	<b>33.1</b>	<b>27.7</b>	<b>30.4</b>	<b>31.4</b>	<b>27.8</b>	<b>30.5</b>

注:每列的最佳结果用粗体突出显示.标有†的方法表示采用实例重放策略.

表5 对本文所提各组件的消融实验

模块		19-1(1步增量)			15-5(1步增量)			10-5(2步增量)			15-1(5步增量)		
HDP	DPDS	1-19	20	1-20	1-15	16-20	1-20	1-10	11-20	1-20	1-15	16-20	1-20
		69.9	72.8	70.0	71.7	63.7	69.7	68.8	66.4	67.6	68.9	54.3	65.3
√		70.9	70.2	70.9	73.0	64.0	70.8	69.8	66.2	68.0	69.9	55.6	66.3
	√	71.2	73.6	71.3	73.6	63.7	71.1	69.9	68.4	69.2	69.7	57.6	66.7
√	√	72.0	71.4	71.9	74.0	63.9	71.5	70.9	68.9	69.9	72.0	58.2	68.5

为验证所提出的HDP的有效性,本文通过对比实验进行了系统评估.如图4所示,与现有基于粗粒度增量提议(图示为“CG RPN”)的方法<sup>[36]</sup>相比,HDP在新旧类别上的性能均表现出显著提升.这一效果主要得益于HDP能够有效解耦不同类别提议

之间的冲突,使模型在新旧类别上均能充分学习.具体而言,在19-1的增量设定下,HDP相较于现有粗粒度增量提议方法,旧类别的AP@0.5从71.3%提升至72.0%,新类别的AP@0.5从71.0%提升至71.4%.




图4 分层解耦提议(HDP)有效性分析

本文提出直接利用旧类别重放实例的硬标签(one-hot标注)对RCN网络进行监督可能导致次优性能,主要原因在于有限的重放实例易引发模型过拟合.为验证该假设,本节设计对比实验,将本文策略(不使用硬标签监督,记为“w/o cls&reg”)与分别或联合使用分类与回归硬标签监督的变体进行比较.如图5所示,当

采用硬标签监督分类分支时,旧类别的性能显著下降;而仅在回归分支引入标注监督时,性能退化较为轻微.这一现象表明,在增量学习中直接依赖少量重放实例的显式类别标签进行监督,会加重对旧类别知识的遗忘.相比之下,本文所采用的解耦监督机制,即仅通过知识蒸馏隐式引导旧类别特征的学习,避免对




图5 双路径蒸馏策略(DPDS)必要性分析

分类与回归头施加硬监督,在新旧类别上均实现了更优的平衡性能.

为评估本文方法对超参数 $\alpha$ 的敏感性,本节在不同增量设定下测试其对模型在新类、旧类及整体性能的影响. 实验结果如图6所示,随着 $\alpha$ 增大,模型更倾向于保留旧知识,但新类性能相应下降. 值得注意的是,在较宽的取值区间内(如10-10设定中 $\alpha \in [0.05, 0.2]$ ),模型均能保持优异的整体性能,表明该方法对 $\alpha$ 具有较低

的参数敏感性.

鉴于大内存大小带来的巨大存储成本,实验分析了它们的影响. 在不同内存大小下进行了实验,并将所提方法与ABR<sup>[36]</sup>进行了比较. 通过测量旧类别和所有类别的AP@0.5来进行评估. 如图7所示,虽然两种方法都随着内存大小的增加而有所改进,但所提方法在各种内存和增量大小下始终优于ABR,表明具有更高的内存效率.




图6 超参数 $\alpha$ 对新旧任务性能影响

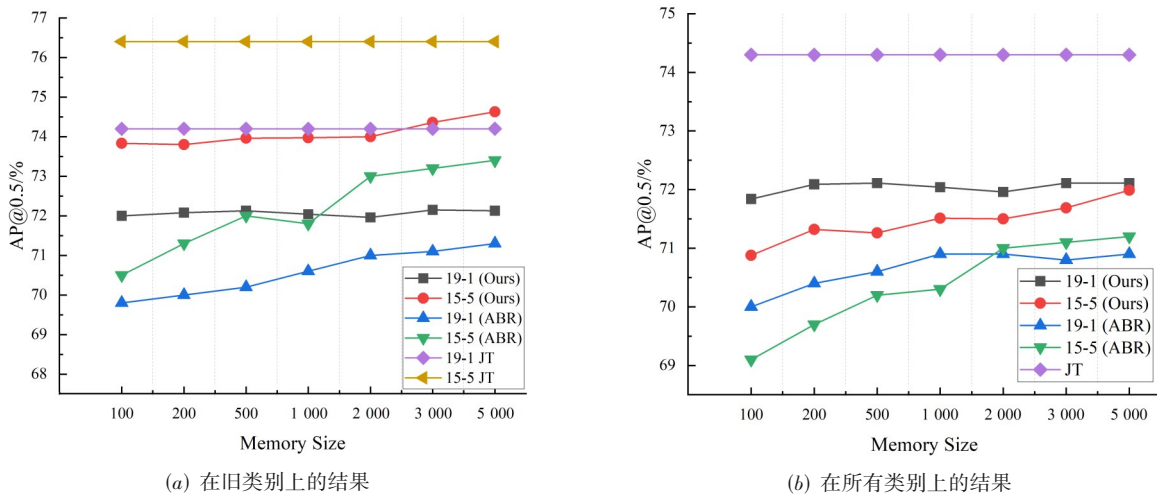


图7 本文方法与ABR在不同实例存储数量下的AP@0.5结果对比

## 5 未来工作

本文针对增量目标检测中候选框标签冲突及回放下子集硬标签监督易导致过拟合的问题,提出了一种解耦增量学习方法,并在两阶段检测器 Faster R-CNN 上进行了验证. 未来工作将探索该方法在单阶段检测器,比如 YOLO(You Only Look Once),以及基于 Transformer 的检测器(如 DETR<sup>[17]</sup>)等不同架构的检测模型<sup>[45]</sup>上的适配与泛化能力,以进一步提升其适用性. 具体而言,尽管 YOLO 和 DETR 不依赖显式的区域提议网络,但在其预测机制中,如 YOLO 的网格预测或 DETR 的对象查询(Object query)分配,仍需为每个预测单元分配标签,因此,在增量目标检测场景下,同样面临新旧任务标签冲突的问题. 本文提出的 HDP 策略可迁移适配,用于定义预测单元的优先级顺序,缓解此类冲突. 此外,DPDS 作为一种与网络架构无关的监督策略,在损失层面区分硬监督(新类)与软蒸馏(旧类),可适配于不同检测框架的训练流程.

## 6 结论

本文针对增量目标检测中的两个关键挑战展开研究:其一是基于置信度与基于 IoU 的区域提议机制不兼容所引发的标签分配冲突,其二是有限旧样本下硬监督易导致的过拟合问题. 为此,本文提出一种 DILOD 方法. 该方法通过引入优先级引导的提议机制,统一协调新类别、旧类别与背景区域的标签分配,有效缓解增量训练过程中的监督冲突;同时设计双路径监督策略,即对新类别采用真实标注进行强监督,对旧类别则通过无偏知识蒸馏施加软监督,从而避免在小规模重放样本上发生过拟合. 在 Pascal VOC 和 MS COCO 数据集上的实验表明,无论是在单步还是多步增量设置下,DILOD 均能有效平衡新知识学习与旧知识保留. 本工作不仅提升了模型在持续学习过程中兼顾新旧任务的能力,也揭示了区域提议生成与监督策略的协同设计对增量目标检测的关键影响.

### 参考文献

- [1] 秦嘉奇, 江泽涛, 雷晓春. 基于 ICFIE-YOLO 的低照度图像目标检测方法[J]. 电子学报, 2025, 53(2): 514-526.  
QIN J Q, JIANG Z T, LEI X C. Low illumination image object detection method based on ICFIE-YOLO[J]. Acta Electronica Sinica, 2025, 53(2): 514-526. (in Chinese)
- [2] 刘文犀, 张家榜, 李悦洲, 等. 基于边界特征融合和前景引导的伪装目标检测[J]. 电子学报, 2024, 52(7): 2279-2290.  
LIU W X, ZHANG J B, LI Y Z, et al. Boundary feature fusion and foreground guidance for camouflaged object detection[J]. Acta Electronica Sinica, 2024, 52(7): 2279-2290. (in Chinese)
- [3] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//Computer Vision - ECCV 2020. Cham: Springer, 2020: 213-229.
- [4] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2016: 1440-1448.
- [5] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 2980-2988.
- [7] MASANA M, LIU X L, TWARDOWSKI B, et al. Class-incremental learning: Survey and performance evaluation on image classification[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5513-5533.
- [8] MCCLOSKEY M, COHEN N J. Catastrophic interference in connectionist networks: The sequential learning problem[M]//Psychology of Learning and Motivation. Amsterdam: Elsevier, 1989: 109-165.
- [9] MENEZES A G, DE MOURA G, ALVES C, et al. Continual object detection: A review of definitions, strategies, and challenges[J]. Neural Networks, 2023, 161: 476-493.
- [10] SHMELKOV K, SCHMID C, ALAHARI K. Incremental learning of object detectors without catastrophic forgetting[C]//2017 IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 3420-3429.
- [11] CERMELLI F, MANCINI M, ROTA BULÒ S, et al. Modeling the background for incremental learning in semantic segmentation[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 9230-9239.
- [12] 刘颖, 薛家昊, 张伟东, 等. 基于坐标重要性池化和解耦类别对齐蒸馏的图像分类算法[J]. 电子学报, 2025, 53(3): 962-973.  
LIU Y, XUE J H, ZHANG W D, et al. Image classification algorithm based on coordinate importance pooling and decoupled class alignment distillation[J]. Acta Electronica Sinica, 2025, 53(3): 962-973. (in Chinese)
- [13] ZOU Z X, CHEN K Y, SHI Z W, et al. Object detection in 20 years: A survey[J]. Proceedings of the IEEE, 2023, 111(3): 257-276.

- [14] REDMON J, FARHADI A. YOLOv3: An incremental improvement[EB/OL]. (2018-04-08)[2025-07-10]. <https://arxiv.org/abs/1804.02767>.
- [15] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot MultiBox detector[C]//Computer Vision - ECCV 2016. Cham: Springer, 2016: 21-37.
- [16] DUAN K W, BAI S, XIE L X, et al. CenterNet: Keypoint triplets for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2020: 6568-6577.
- [17] ZHU X Z, SU W J, LU L W, et al. Deformable DETR: Deformable transformers for end-to-end object detection[EB/OL]. (2021-03-18)[2025-12-12]. <https://arxiv.org/abs/2010.04159>.
- [18] ZHOU D W, WANG Q W, QI Z H, et al. Class-incremental learning: A survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9851-9873.
- [19] CASTRO F M, MARÍN-JIMÉNEZ M J, GUIL N, et al. End-to-end incremental learning[M]//Computer Vision - ECCV 2018. Cham: Springer International Publishing, 2018: 241-257.
- [20] LI M X, CONG Y, LIU Y Y, et al. Class-incremental gesture recognition learning with out-of-distribution detection[C]//2022 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway: IEEE, 2022: 1503-1508.
- [21] YOON J, YANG E, LEE J, et al. Lifelong learning with dynamically expandable networks[EB/OL]. (2018-06-11)[2025-12-12]. <https://arxiv.org/abs/1708.01547>.
- [22] LIU Y Y, CONG Y, SUN G, et al. L3DOC: Lifelong 3D object classification[J]. IEEE Transactions on Image Processing, 2021, 30: 7486-7498.
- [23] WANG F Y, ZHOU D W, YE H J, et al. FOSTER: Feature boosting and compression for class-incremental learning[C]//Computer Vision - ECCV 2022. Cham: Springer, 2022: 398-414.
- [24] LEE J, HONG H G, JOO D, et al. Continual learning with extended kronecker-factored approximate curvature[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2020: 8998-9007.
- [25] KANG M, PARK J, HAN B. Class-incremental learning by knowledge distillation with adaptive feature consolidation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 16050-16059.
- [26] KIRKPATRICK J, PASCANU R, RABINOWITZ N, et al. Overcoming catastrophic forgetting in neural networks[J]. Proceedings of the National Academy of Sciences of the United States of America, 2017, 114(13): 3521-3526.
- [27] HINTON G, VINYALS O, DEAN J. Distilling the knowledge in a neural network[EB/OL]. (2015-03-09)[2025-07-10]. <https://arXiv.org/abs/1503.02531>.
- [28] PENG C, ZHAO K, LOVELL B C. Faster ILOD: Incremental learning for object detectors based on faster RCNN[J]. Pattern Recognition Letters, 2020, 140: 109-115.
- [29] YANG D B, ZHOU Y, ZHANG A T, et al. Multi-view correlation distillation for incremental object detection[J]. Pattern Recognition, 2022, 131: 108863.
- [30] ZHOU W, CHANG S Y, SOSA N, et al. Lifelong object detection[EB/OL]. (2020-09-02)[2025-07-10]. <https://arXiv.org/abs/2009.01129>.
- [31] FENG T, WANG M, YUAN H J. Overcoming catastrophic forgetting in incremental object detection via elastic response distillation[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 9417-9426.
- [32] CERMELLI F, GERACI A, FONTANEL D, et al. Modeling missing annotations for incremental learning in object detection[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE, 2022: 3699-3709.
- [33] JOSEPH K J, KHAN S, KHAN F S, et al. Towards open world object detection[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2021: 5826-5836.
- [34] GUPTA A, NARAYAN S, JOSEPH K J, et al. OW-DETR: Open-world detection transformer[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2022: 9225-9234.
- [35] JOSEPH K J, RAJASEGARAN J, KHAN S, et al. Incremental object detection via meta-learning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(12): 9209-9216.
- [36] LIU Y Y, CONG Y, GOSWAMI D, et al. Augmented box replay: Overcoming foreground shift for incremental object detection[C]//2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2024: 11333-11343.
- [37] 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.
- [38] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: Common objects in context[C]//Computer Vision - ECCV 2014. Cham: Springer, 2014: 740-755.
- [39] CHEN R Y, ZHANG H, LI J Z, et al. Generalized semantic contrastive learning via embedding side information for few-shot object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(8): 6496-6514.
- [40] CHEN R Y, LIANG S Y, LI J Z, et al. Interpreting object-level foundation models via visual precision search[C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2025: 30042-30052.
- [41] DENG J, DONG W, SOCHER R, et al. ImageNet: A large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 248-255.
- [42] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2016: 770-778.
- [43] DONG N, ZHANG Y Q, DING M L, et al. Towards non co-occurrence incremental object detection with unlabeled in-the-wild data[J]. International Journal of Computer Vision, 2024, 132(11): 5066-5083.
- [44] MO Q J, GAO Y P, FU S H, et al. Bridge past and Future: Overcoming information asymmetry in Incremental object detection[C]//Computer Vision - ECCV 2024. Cham: Springer, 2025: 463-480.
- [45] 陈立, 张帆, 郭威, 等. 基于级联式逆残差网络的遥感图像轻量目标检测算法[J]. 电子学报, 2023, 51(9): 2588-2597.
- CHEN L, ZHANG F, GUO W, et al. Cascaded inverse residual network for lightweight object detection model in remote sensing image[J]. Acta Electronica Sinica, 2023, 51(9): 2588-2597. (in Chinese)

### 作者简介



**梁嘉伟** 男, 1997年5月出生于广东省广州市. 现为中山大学网络空间安全学院博士研究生. 研究方向为计算机视觉、人工智能安全. 中国电子学会会员编号: E190161229A.  
E-mail: liangjw57@mail2.sysu.edu.cn



**刘宽融** 男, 2001年5月出生于海南省海口市. 现为中山大学网络空间安全学院硕士研究生. 研究方向为计算机视觉、后门攻击.  
E-mail: liukr5@mail2.sysu.edu.cn



**梁思源** 女, 1996年5月出生于湖北省十堰市. 现为新加坡南洋理工大学计算机与数据科学学院博士后研究员. 研究方向为多模态基础模型、可信AI.  
E-mail: pandaliang521@gmail.com



**黄健杰** 男, 1998年11月出生于广东省东莞市. 现为中山大学网络空间安全学院博士研究生. 研究方向为多模态大模型安全.  
E-mail: huangjj67@mail2.sysu.edu.cn



**陈若愚** 男, 1999年6月出生于安徽省滁州市. 现为中国科学院信息工程研究所与中国科学院大学网络空间安全学院博士研究生. 研究方向为可解释人工智能. 中国电子学会会员编号: E190188988A.  
E-mail: chenruoyu@iie.ac.cn



**操晓春** 男, 1980年3月出生于安徽省安庆市. 现为中山大学网络空间安全学院院长、教授、博士生导师, 国家杰出青年/优秀青年基金获得者. 研究方向为人工智能基础研究和网络空间内容安全应用研究. 中国电子学会会员编号: E190013018S.  
E-mail: caoxiaochun@mail.sysu.edu.cn