

中图分类号: TP18; TP391 文献标识码: A 文章编号: 1006-8961(2026)04-1108-17

论文引用格式: Yang L R, Wang J Q, Zhai Y J and Su P. 2026. Domain adaptive object detection via joint negative teaching and negative learning. Journal of Image and Graphics, 31(4): 1108-1124(杨立然, 王佳琪, 翟永杰, 苏攀. 2026. 融合负教学和负学习的域自适应目标检测. 中国图象图形学报, 31(4): 1108-1124)[DOI: 10. 11834/jig. 250264]

## 融合负教学和负学习的域自适应目标检测

杨立然<sup>1,2</sup>, 王佳琪<sup>1</sup>, 翟永杰<sup>3</sup>, 苏攀<sup>1,4\*</sup>

1. 华北电力大学计算机系, 保定 071003; 2. 复杂能源系统智能计算教育部工程研究中心, 保定 071003;

3. 华北电力大学自动化系, 保定 071003; 4. 河北省能源电力知识计算重点实验室, 保定 071003

**摘要:** 目的 域自适应目标检测旨在解决检测模型在不同域数据间迁移应用时面临的性能下降问题。目前流行的基于平均教师框架的域自适应目标检测方法多采用基于类别置信度的单向评估机制。当伪标签存在噪声时, 学生模型会沿错误方向更新参数, 导致教师模型累积误差, 最终制约模型的性能。为此, 提出融合负教学和负学习策略的域自适应目标检测方法(negative teaching and negative learning, NTNL)。**方法** 不同于已有的平均教师框架方法, 本文方法NTNL采用双向评估机制。一方面引入负学习方法, 指导学生模型判别伪标签的互补标签, 使学生模型在噪声伪标签的影响下仍能构建鲁棒的决策边界; 另一方面添加负教学策略, 降低教师模型对困难样本做出错误分类的概率, 提升伪标签的可靠程度与质量。此外, 提出一种自适应加权机制, 通过动态调节负教学权重, 平衡不同学习任务中的负教学尺度, 增强模型的泛化能力。**结果** 在3个公开基准跨域目标检测任务上验证本文方法的有效性, 与其他先进方法相比, 平均精度均值(mean average precision, mAP)分别提升了8.0%、4.7%和1.7%。消融实验以及特征可视化等进一步验证了本文方法的有效性。**结论** 提出的NTNL通过引入负向思维, 减轻了噪声伪标签的影响, 在天气条件适应、城市道路跨风格适应和真实至插画风格适应3类典型场景中都取得了优越的性能。

**关键词:** 域自适应; 目标检测; 负教学; 负学习; 自适应加权机制

## Domain adaptive object detection via joint negative teaching and negative learning

Yang Liran<sup>1,2</sup>, Wang Jiaqi<sup>1</sup>, Zhai Yongjie<sup>3</sup>, Su Pan<sup>1,4\*</sup>

1. Department of Computer, North China Electric Power University, Baoding 071003, China; 2. Engineering Research

Center of Intelligent Computing for Complex Energy Systems, Ministry of Education, Baoding 071003, China;

3. Department of Automation, North China Electric Power University, Baoding 071003, China;

4. Hebei Key Laboratory of Knowledge Computing for Energy and Power, Baoding 071003, China

**Abstract: Objective** In recent years, domain adaptive object detection has become an important area of research with the growing demand for robust object detection systems across different environmental conditions. Traditional object detectors that use deep learning methods obtain relatively high performance, but they largely rely on large-scale labeled datasets. However, labeling large-scale datasets requires high costs. This challenge motivates the exploration of domain adaptation

收稿日期: 2025-06-17; 修回日期: 2025-10-31; 预印本日期: 2025-11-07

\* 通信作者: 苏攀 supan@ncepu.edu.cn

基金项目: 河北省自然科学基金项目(F2024502002); 中央高校基本科研业务费专项资金项目(2024MS127)

Supported by: Natural Science Foundation of Hebei Province, China(F2024502002); Fundamental Research Funds for the Central Universities (2024MS127)

that aims to maintain good detection performance by learning domain-invariant features or training models with cross-domain generalization ability. Recent studies in domain adaptive object detection have increasingly adopted the mean teacher paradigm, which leverages the stability of the parameters of the teacher model during training to address critical challenges in cross-domain scenarios. The method can enhance the invariance of the model to specific domain shift while preserving the discriminant ability of the feature representations by enforcing the consistency between the predictions of the student model and the outputs of the teacher model. However, these studies often overlook the fact that the student model may learn noisy pseudo-labels generated by the teacher model. This situation can consequently lead to performance degradation. If the teacher model produces a noisy pseudo-label, then it could potentially steer the student model toward an incorrect objective, ultimately leading to the generation of erroneous feedback for the teacher model. Thus, a novel domain adaptive object detection framework named negative teaching and negative learning (NTNL) which integrates a negative teaching module, a negative learning module, and an adaptive weighting mechanism, is proposed in this study to alleviate the aforementioned problem. **Method** NTNL not only considers the positive aspects but also incorporates negative thinking; that is, it evaluates the probability that an object does not belong to a certain class. In particular, NTNL introduces the negative teaching strategy to the teacher model, which can iteratively reduce the likelihood of generating incorrect pseudo-labels for uncertain samples, thereby improving the quality of guidance for the student model. Moreover, NTNL employs negative learning such that the student model can be guided to recognize complementary labels. Furthermore, this study designs an adaptive weighting mechanism to address the scale variation of negative teaching due to the different number of classes in diverse tasks. This mechanism can ensure that the proportion of negative teaching loss in the total loss is roughly consistent across different transfer learning tasks. **Result** Extensive experiments are conducted on three cross-domain object detection tasks for performance evaluation, including weather adaptation (Cityscapes to Foggy Cityscapes), cross-style city road adaptation (Cityscapes to Bdd100k), and real-world to clipart adaptation (Pascal VOC to Clipart1k). The proposed method NTNL generally obtains better performance than the compared methods. The mean average precision values of NTNL on the above three tasks are 63.4%, 52.5%, and 45.4%, which are 8.0%, 4.7% and 1.7% higher than the mean average precision values of the recent methods, respectively. The proposed NTNL achieves such good performance, probably because it employs the negative teaching and negative learning, both of which help in predicting the class of hard samples correctly. In addition, NTNL can balance the weight of negative teaching in different cross-domain object detection tasks because of the design of the adaptive weighting mechanism, thereby improving the generalization ability of the model. This study conducts a series of ablation experiments, and the resultant findings confirm the effectiveness of each component within the proposed NTNL framework. This study also analyzes the parameter sensitivity to reveal the impact of these parameters on performance. Finally, this study utilizes t-distributed stochastic neighbor embedding (t-SNE) to represent the image features extracted by different models, thereby demonstrating the advantages of the proposed NTNL intuitively. The visualization reveals that the feature clusters generated by NTNL exhibit a high degree of separation, particularly for semantically similar categories, such as riders and people, which are difficult to distinguish; thus, the discriminative effect becomes pronounced. **Conclusion** This study proposes a novel domain adaptive object detection method, NTNL, which reduces the impact of noisy pseudo-labels via negative teaching and negative learning. This method also improves the generalization ability of the model with an adaptive weighting mechanism. Comprehensive comparisons with other domain adaptive object detection methods show that the proposed NTNL can achieve superior performance on public cross-domain object detection tasks, thereby proving its validity. Future work will explore incorporating the degree of the domain shift and task difficulty into the adaptive weighting mechanism to improve model generalization further.

**Key words:** domain adaptation; object detection; negative teaching; negative learning; adaptive weighting mechanism

## 0 引言

目标检测在各种应用中发挥着越来越重要的作

用,如工业缺陷检测(白艳峰等,2024)、异物检测(Su等,2022)和自动驾驶(李昌财等,2024)等。近年来,基于深度学习的目标检测研究取得了很大的进展(张昀等,2024),但是,这些方法通常需要足够

的带标签样本进行训练才能获得令人满意的性能。在实践中,对每个应用领域的样本进行标注需要昂贵的人力和物力,因此获取充足的标记样本比较困难(Deng等,2009)。为解决这一问题,研究人员提出使用相关的有标签的源域数据进行训练,使模型能够从中学习知识并应用于无标签的目标数据。在实际应用场景中,受光照强度、拍摄视角以及背景复杂度等多重因素影响,这种策略不可避免地会面临域偏移问题(钟安雨等,2023),即源域数据与目标域数据在特征空间中呈现显著分布差异。这种跨域分布差异导致训练的模型难以直接泛化到目标域数据,性能大幅度下降。为突破这一跨域应用瓶颈,域自适应技术(Yang等,2024;周洋等,2024)得以提出,其通过学习领域不变性表征缩小源域与目标域的分布差异,提升模型在跨域场景下的泛化性能。

域自适应目标检测的最新工作越来越多地采用了平均教师框架(Tarvainen和Valpola,2017),利用教师模型参数在训练期间的稳定性解决跨域场景中的关键挑战。通过约束学生模型的预测和教师模型的输出之间的一致性,该方法增强了模型对域不变特征的学习,同时保留了可判别特征表示。然而,教师模型有时会产生错误的实例分类结果,通常称

为噪声伪标签(Freire等,2024;吕学强等,2024)。在这种情况下,学生模型会向着错误的方向学习,进而给教师模型带来错误的反馈。如图1所示,Kennerley等人(2024)提出的类感知教师(class-aware teacher, CAT)已经取得了较好的检测效果,但由于周围环境的影响,难免错误地为人类实例分配一个骑手标签。这一问题在该领域现有的研究中往往被忽略,容易导致视觉特征相近的实例被误分类,影响模型在目标域的表现。

为了缓解上述问题,本文提出了一种融合负教学模块(negative teaching, NT)、负学习模块(negative learning, NL)和自适应加权机制的域自适应目标检测方法。主要贡献总结如下:1)通过引入负教学策略,减小教师模型对难以辨识的实例产生错误分类的可能性,从而提高对学生模型指导的质量;2)通过引入负学习方法,学生模型可以学习到互补标签的分类知识,有助于防止学生模型学习到噪声伪标签;3)通过设计自适应加权机制,本文方法 NTNL(negative teaching and negative learning)可以根据类别数自适应调整负教学的权重,缓解了不同任务中负教学损失尺度不稳定的问题;4)在不同天气、不同成像设备检测条件下的综合实验验证了所提方法的有效性。




图1 天气适应任务中容易产生噪声伪标签的样本示例

Fig. 1 Sample example of weather adaptation prone to generating noisy pseudo labels ((a) ground truth; (b) CAT; (c) NTNL)

## 1 相关工作

### 1.1 基于对抗训练的域自适应目标检测方法

基于对抗训练的方法以额外的域分类器作为辅助网络,通过对抗训练的方式减小源域和目标域之间的特征分布差异。Ganin等人(2016)提出一种神经网络域对抗训练(domain-adversarial training of

neural networks, DANN)方法,其核心是通过梯度反转层使特征提取器生成域无关的特征表示,实现跨域知识迁移。联合训练域分类器和特征提取网络,可以对齐源域和目标域的特征分布。对抗训练的概念在后续研究中得到了广泛应用。例如,Chen等人(2018)在快速区域卷积神经网络(faster regions with convolutional neural network, Faster R-CNN)(Ren等,2017)基础上引入全局与局部的对抗对齐机制,提出

域自适应快速区域卷积神经网络(domain adaptive faster regions with convolutional neural network, DA-Faster),实现多层次域不变特征学习。Saito等人(2019)融合强局部对齐和弱全局对齐策略,提出强弱分布对齐(strong-weak distribution alignment, SWDA),将对齐损失聚焦于全局相似的图像。Hsu等人(2020a)提出一种中心感知特征对齐(center-aware feature alignment, CAFA)方法解决跨域目标检测问题。该方法通过预测像素级的对象性和中心性,允许识别器专注于来自目标区域的特征,并通过对抗学习实现更精准的特征对齐。Hsu等人(2020b)构建中间域,将源图像转换为与目标图像相似的图像,实现了像素级特征对齐。Xu等人(2020)引入图像级多标签分类器捕获关键区域,提出类别正则化域自适应(categorical regularization for domain adaptive, CRDA),通过图像级与实例级的类别一致性进行跨域对齐,可以作为即插即用组件使用。Chen等人(2021)在对抗训练中引入尺度感知机制,提出尺度感知域自适应(scale-aware domain adaptive, SADA),可以有效缓解图像级域偏移和实例级域偏移。Wang等人(2021)提出序列特征对齐(sequence feature alignment, SFA),借助域查询机制进行全局特征对齐,通过逐令牌对齐机制实现局部特征对齐。Huang等人(2022)提出对抗查询变换器(adversarial query transformers, AQT),将对抗训练机制引入检测变换器中,通过令牌查询与交叉注意力实现特征对齐,为后续研究提供了灵活的结构框架。Gong等人(2022)提出对象感知对齐与最优传输对齐网络(object-aware alignment and optimal transport based alignment network, O<sup>2</sup>net),通过引入对象感知对齐以强化前景区域特征对齐,并在解码器中引入基于最优传输的对齐以保留位置信息,从而在像素级与实例级实现跨域特征对齐。Zhao和Wang(2022)引入辅助预测器,提出特定于任务的不一致性对齐(task-specific inconsistency alignment, TIA),将跨域行为不一致性作为度量,有效提升检测器的适应性能。Bai等人(2024)融合基于掩码的域判别器和定位判别器,提出抗失调域自适应(misalignment-resistant domain adaptive, MRDA),提升了模型关注前景实例和定位目标的能力。Qiao等人(2024)引入了一种用于对抗训练和伪标签自训练的双路径架构,提出联合特征区分与交互(joint fea-

ture differentiation and interaction, JFDI),可以同时学习域不变特征和目标特定特征。Shi和Zheng(2024)从间接角度出发,提出冲突缓解梯度下降(conflict-alleviated gradient descent, CAGrad),通过在对齐与检测任务间调整梯度方向改善特征对齐效果,即插即用以往研究中取得了性能提升。Jiang等人(2025)整合了自适应前景感知注意力模块和类别感知原型对齐模块,提出自适应特征对齐网络(adaptive feature alignment network, AFAN),有效提升了多级特征对齐的效果。Xiao等人(2025)融合了编码器特征对齐和实例级特征对齐,提出无监督域自适应检测变换器(unsupervised domain adaptation detection transformer, UDA-DETR),同时利用对比学习和对抗损失实现全局与类特定特征的跨域对齐。

## 1.2 基于图像变换的域自适应目标检测方法

基于图像变换的方法直接从输入层面缩小源域和目标域图像之间的差异。图像到图像的变换可以使目标图像具有源域的风格或源图像具有目标域的风格。在训练中使用转换后的图像更有利于学习源域和目标域的共同特征。Tian等人(2019)提出全卷积单阶段目标检测(fully convolutional one-stage object detector, FCOS),为后续跨域特征建模提供了无锚框检测架构。Kim等人(2019a)提出多样化与匹配(diversify and match, DM),通过生成多个源域偏移域增加标记数据多样性,降低源域偏差的影响。Chen等人(2020)探索了不同局部区域、图像和实例的可转换性,提出分层迁移校准网络(hierarchical transferability calibration network, HTCN),可以在对抗自适应环境中协调目标检测器的可迁移性和可判别性。Zhu等人(2021)利用注意力机制,提出可变形检测变换器(deformable detection transformer, Def DETR),有效提升模型对多尺度与小目标的建模能力。Li等人(2022a)借助图匹配理论,提出语义完备图匹配(semantic-complete graph matching, SIGMA),可以强化跨域语义关联,提升检测语义一致性。Hoyer等人(2023)提出掩码图像一致性(masked image consistency, MIC),通过掩码图像的预测和完整图像的伪标签之间的一致性约束帮助模型学习上下文关系,以便识别具有相似外观的类别。Lang等人(2023)引入双分支结构和双重注意力机制,提出隐式域不变(implicit domain-invariant, IDF),可以同时学习显式与隐式域不变特征,以处理目标域中多

模态、多尺度样本。Wang等人(2024)引入多层解耦模块和循环解耦模块,提出三重特征解耦合(triple feature disentanglement, TFD),可以有效学习域不变特征表示,减少域特定信息的干扰。Li等人(2025)融合多尺度注意力与统一尺度自适应机制,提出基于多尺度注意力的统一尺度域自适应机制驱动目标检测网络(unified-scale domain adaptation mechanism driven object detection network with multi-scale attention, UMS<sup>2</sup>-ODNet),提升了模型的特征表示能力。

### 1.3 基于伪标签自训练的域自适应目标检测方法

基于伪标签自训练的方法通过在源域上预训练的检测模型生成目标域样本的伪标签,并通过设置阈值不断选择并优化目标域样本伪标签的质量。此类方法依赖伪标签预测的准确性。研究学者常将其与多种先进技术相结合,如对抗学习、平均教师框架、主动学习以及对比学习,以改善伪标签的预测精度,提升模型的域自适应能力。Deng等人(2021)提出无偏平均教师(unbiased mean teacher, UMT),通过像素级适配增强样本,结合跨域蒸馏与分布外样本筛选,缓解了跨域检测中的模型偏差。Li等人(2021)将无源域目标检测建模为带噪标签学习问题,提出无源域自适应目标检测(source-free domain adaptive object detection, SFDAOD),通过自熵下降选择伪标签置信阈值,并利用假阴性模拟提升伪标签质量。Li等人(2022b)提出自适应教师(adaptive teacher, AT),通过强弱数据增强和对抗训练实现性能提升。Chen等人(2022)提出概率教师(probabilistic teacher, PT),通过伪标签不确定性建模引导学生的自训练学习,利用动态一致性约束提升分类与定位的适应能力。Yu等人(2022)提出平均教师变换器(mean teacher transformer, MTTrans),设计一种多级特征对齐策略提高伪标签质量。Zhao等人(2023)提出掩码再训练师生(masked retraining teacher-student, MRT),借助特征掩蔽再恢复策略帮助编码器学习目标数据的上下文特征,通过选择性参数初始化允许组件暂时偏离局部最优值以寻求更好的参数组合。Cao等人(2023)结合对比学习,提出对比平均教师(contrastive mean teacher, CMT),可以增强跨域特征表示,提升模型的适应性能。Krishna等人(2023)引入记忆模块存储源域实例特征,提出基于记忆的实例级自适应(memory-based instance-level adaptation, MILA),在目标实例对齐时

从记忆中检索最相似的源实例,实现更精确的实例级域对齐。Nakamura等人(2024)提出主动域适应方法,考虑模型漏检的对象,有效提升模型的召回率。Kay等人(2025)在特征金字塔网络(feature pyramid networks, FPN)(Lin等,2017)的多尺度检测基础上提出对齐与蒸馏框架,在早期训练阶段使用指数移动平均(exponential moving average, EMA)(Tarvainen和Valpola,2017)以稳定模型更新,在蒸馏过程中使用软标签分数进行特征优化,提升模型的跨域检测性能。Lavoie等人(2025)提出无标签自蒸馏教师(self-distillation with no labels teacher, DINO Teacher),借助大型预训练网络生成标签,实现了模型对目标域数据生成和学习标签的解耦合。

在这些域自适应目标检测方法中,基于平均教师框架的训练方法与本文提出的NTNL方法最接近。近年来基于平均教师框架的方法取得了较大的进展,但仍存在一些不足。现有的研究只考虑了正学习,难以有效地处理含有噪声的伪标签。为此,本文引入了负教学和负学习,可以对分类结果进行更全面的学习,而无需担心噪声的影响。此外,本文还设计了一种自适应加权机制,使负教学的尺度在不同的跨域目标检测任务中保持相对稳定。

## 2 方法

### 2.1 问题陈述

域自适应目标检测旨在将源域训练的目标检测模型迁移到未标注的目标域,以解决因域偏移导致的性能下降问题。给定两个分布不同的域,分别为有标签的源域 $D_s = \{(\mathbf{x}_i^s, \mathbf{b}_i^s, \mathbf{y}_i^s)\}_{i=1}^n$ 和无标签的目标域 $D_t = \{\mathbf{x}_i^t\}_{i=1}^m$ ,其中 $\mathbf{x}_i^s$ 和 $\mathbf{x}_i^t$ 分别表示源域和目标域的第 $i$ 幅图像, $\mathbf{b}_i^s$ 表示源域第 $i$ 幅图像对应的边界框, $\mathbf{y}_i^s$ 表示源域第 $i$ 幅图像对应的标签向量(独热编码,正确的类别位置为1,其余位置为0), $n$ 和 $m$ 分别表示源域和目标域样本总数。本文所提方法旨在学习一个自适应检测器,使其在目标域 $D_t$ 上有较好的检测性能。

### 2.2 总体框架

NTNL方法以平均教师框架为基础,并引入负教学模块、负学习模块和自适应加权机制,其框架如图2所示。

### 2.2.1 平均教师框架

在平均教师框架中,教师模型 $\theta_T$ 和学生模型 $\theta_s$ 具有相同的结构。学生模型的参数通过反向传播更新。教师模型的参数使用EMA更新,具体为

$$\theta_T = \alpha\theta'_T + (1 - \alpha)\theta_s \quad (1)$$

式中, $\alpha$ 为预设超参数, $\theta'_T$ 表示教师模型进行EMA更新前的参数。

为了增加样本的多样性并学习源域和目标域的共同特征,输入模型前对样本图像进行了增强处理。输入到教师模型的图像进行了弱增强处理以提供可靠的标签,而输入到学生模型的图像进行了强增强处理以激发学习的多样性。弱增强包括随机翻转、随机裁剪和多尺度变换。强增强包括随机擦除、亮度调整、随机灰度、高斯模糊和掩码图像一致性。

训练分为两个阶段:早期训练阶段和蒸馏训练

阶段。在早期训练阶段,模型基于源域的有标签图像进行监督学习,其监督损失的计算式为

$$L_s(\mathbf{x}^s, \mathbf{b}^s, \mathbf{y}^s) = L_{\text{cls}}^{\text{rpn}}(\mathbf{x}^s, \mathbf{b}^s, \mathbf{y}^s) + L_{\text{reg}}^{\text{rpn}}(\mathbf{x}^s, \mathbf{b}^s, \mathbf{y}^s) + L_{\text{cls}}^{\text{roi}}(\mathbf{x}^s, \mathbf{b}^s, \mathbf{y}^s) + L_{\text{reg}}^{\text{roi}}(\mathbf{x}^s, \mathbf{b}^s, \mathbf{y}^s) \quad (2)$$

式中, $\mathbf{x}^s$ 表示源域图像, $\mathbf{b}^s$ 和 $\mathbf{y}^s$ 分别表示源域图像的边界框和类别标签, $L_{\text{cls}}^{\text{rpn}}$ 是区域提议网络(region proposal network, RPN)的分类损失, $L_{\text{reg}}^{\text{rpn}}$ 是RPN的回归损失, $L_{\text{cls}}^{\text{roi}}$ 是感兴趣区域(region of interest, ROI)的分类损失, $L_{\text{reg}}^{\text{roi}}$ 是ROI的回归损失。

在蒸馏训练阶段,教师模型为无标签的目标域图像生成伪标签,用于指导学生模型的训练,其无监督损失的计算式为

$$L_{\text{un}}(\mathbf{x}^t, \mathbf{b}^t, \mathbf{y}^t) = L_{\text{cls}}^{\text{rpn}}(\mathbf{x}^t, \mathbf{b}^t, \mathbf{y}^t) + L_{\text{cls}}^{\text{roi}}(\mathbf{x}^t, \mathbf{b}^t, \mathbf{y}^t) \quad (3)$$

式中, $\mathbf{x}^t$ 表示目标域图像, $\mathbf{b}^t$ 和 $\mathbf{y}^t$ 分别表示目标域图像的伪边界框和伪类别标签。

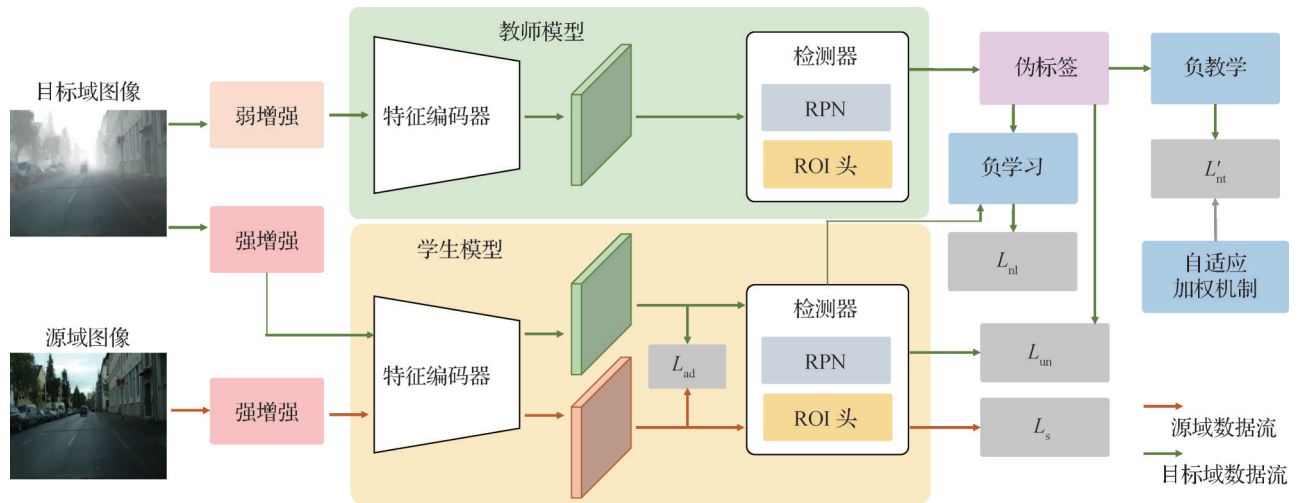


图2 NTNL框架

Fig. 2 The framework of NTNL

### 2.2.2 负学习

平均教师框架中,教师模型为检测到的实例生成伪标签,供学生模型使用。当前基于平均教师框架的域自适应目标检测方法多采用正向思维,即仅基于类别置信度评估生成伪标签。受负向思维相关研究(Kim等,2019b)的启发,本文设计了双向评估机制,不仅考虑实例属于某一确信类的可能性,还学习该实例不属于某个类别的可能性。

为了更清晰地描述双向评估机制,本文展示了一个有猫、狗、牛、羊4种类别的例子,如图3所示。图中方格内的数字表示学生模型对不同实例各种类

别的预测置信度,蓝色数字对应的类别是伪标签,黑色数字对应的类别是互补标签,即除了伪标签外的其他标签。正学习直接作用于实例的伪标签,在图中以绿色背景块表示。负学习作用于随机选择一个互补标签,在图中以黄色背景块表示。这样的双向评估机制可以兼顾学习伪标签的知识和互补标签的知识。

学生模型通过目标样本的伪标签设计交叉熵损失。对每个类别计算损失,然后对所有类求和形成该实例的总损失。正学习交叉熵的形式为

$$L_{pl} = -\sum_{i=1}^m \sum_{j=1}^C y_{i,j} \log p_{i,j} \quad (4)$$

式中,  $C$  表示类别总数,  $y_{i,j}$  表示第  $i$  个样本的标签独热编码向量的第  $j$  个分量,  $p_{i,j}$  表示学生模型对第  $i$  个样本属于第  $j$  类别预测的置信概率。通过正学习, 具有较高预测分数的伪标签有较小的交叉熵损失, 意味着在这些情况下学习更置信。

如果伪标签是不正确的, 即教师模型生成了有噪声的伪标签, 正学习会将这个有噪声的伪标签视为正常标签, 从而导致错误积累, 无法进行有益的学习。为此, 本研究引入负学习策略, 从伪标签的互补标签中随机选择一个, 用以计算交叉熵损失, 计算式为

$$L_m = -\sum_{i=1}^m \bar{y}_{i,k} \log(1 - p_{i,k}) \quad (5)$$

式中,  $\bar{y}_{i,k}$  表示标签为  $k$  的第  $i$  个样本的随机选择的互补标签独热编码向量的非 0 分量,  $p_{i,k}$  表示学生模型对第  $i$  个样本属于第  $k$  类别预测的置信概率。

采用负学习策略后, 真实伪标签被误判为互补标签的概率仅为  $1/(C - 1)$ , 从而在很大程度上缓解了现有研究工作中由噪声伪标签导致的错误逐步累积的问题。




图3 正学习和负学习示例

Fig. 3 Examples of positive learning and negative learning

### 2.2.3 负教学

在学生模型中加入负学习方法有助于为教师模型提供更全面的学习反馈, 间接提升伪标签的质量。在传统的基于平均教师框架的域自适应目标检测中, 教师模型生成的伪标签直接被学生模型使用, 没有对伪标签进行额外的处理。但是, 教师模型也可以利用负向思维(Kim等, 2019b)直接提高伪标签的质量。负教学交叉熵的形式为

$$L_m = -\sum_{i=1}^m \bar{y}'_{i,k} \log(1 - p'_{i,k}) \quad (6)$$

式中,  $\bar{y}'_{i,k}$  表示标签为  $k$  的第  $i$  个样本的随机选择的互补标签独热编码向量的非 0 分量,  $p'_{i,k}$  表示教师模型

对第  $i$  个样本属于第  $k$  类别预测的置信概率。

对于具有  $C$  个类别的目标检测任务, 如果伪标签是噪声伪标签, 则负教学有  $(C - 2)/(C - 1)$  的概率避免教师模型在后续迭代中产生噪声伪标签。随着类别数  $C$  的增加, 负教学产生有益效果的可能性也增加。

### 2.2.4 自适应加权机制

不同的迁移学习任务可能具有不同的类别数、图像分布和学习难度, 从而导致负教学损失的尺度存在差异。根据负教学的设计, 类别数的多少直接影响负教学损失的尺度。类别数越高, 负教学的错误概率越低, 从而负教学损失的尺度越小。此外, 类别数是一个可量化的变量。为保持不同迁移学习任务中负教学损失在总损失中的占比相对稳定, 在负教学中添加了自适应加权机制。自适应加权的负教学损失的计算式为

$$L'_m = w_m \times L_m \quad (7)$$

式中,  $w_m$  为负教学损失的自适应权重。通过自适应加权机制, 迁移学习任务的负教学损失的尺度会根据类别数进行调整。对于涉及类别数较多的任务, 负教学损失的尺度较小, 但权重较大, 放大了负教学损失; 对于涉及类别数较少的任务, 负教学损失的尺度较大, 但权重较小, 缩小了负教学损失。自适应加权机制有利于不同迁移学习任务中负教学损失在总损失中的占比保持稳定。

负教学损失的自适应加权机制的设计是理论和实践综合考虑的结果。理论分析表明, 迁移学习任务中负教学损失的权重与类别数呈正相关。为表示正相关, 采用了线性回归。线性回归方程为

$$w_m = \max(0.001, w \times C - b) \quad (8)$$

式中,  $\max$  表示取最大值,  $w = 0.00683916667$  是线性回归的权重,  $b = 0.046783333$  是线性回归中的偏置项。 $w$  和  $b$  的计算在下文中给出。将线性回归方程作为负教学损失的权重, 可以平衡不同的迁移学习任务中负教学损失的尺度。

解释式(8)中的  $w$  和  $b$  计算过程。V→C 任务比其他任务表现出更大的域偏移, 所以首先在此任务中估计了负教学损失占总损失的比例。使用不同负教学权重进行实验的结果如图4所示。

为了获得较优结果, 将 V→C 任务的负教学损失权重设置为 0.09。为了保持不同迁移学习任务中




图4 V→C任务使用不同负教学权重的结果

Fig. 4 Results of the V→C task using different weights of the negative teaching

负教学损失占总损失的比例, C→F和C→B任务的负教学损失权重分别设置为0.005 3和0.010 56。可以看出,将Cityscapes作为源域的两个任务的类别

数相同时,负教学损失权重存在差异,这可能是由于图像分布和学习难度等难以量化的因素造成的。对这两个权重取平均值,得到0.007 93。因此,对于包含20类的任务,负教学损失的权重为0.09;对于包含8类的任务,负教学损失的权重为0.007 93。将这两组值代入式(8)进行线性回归分析,可算出 $w$ 值为0.006 839 166 67, $b$ 值为0.046 783 333。

为了验证自适应加权机制的有效性,在其他任务上使用不同的负教学权重进行了实验,结果如图5所示,图中 $w_{nt}$ 是由式(8)计算得到。从图5可以看出,当负教学损失的权重为 $w_{nt}$ 时,结果是较优的。当负教学损失的权重高于或低于 $w_{nt}$ 时,性能会降低,证实了自适应加权机制可以在不同的任务中发挥作用。

根据图4和图5的结果可以得出结论,本文设计的自适应加权机制使模型具备了更强的泛化能力,在不同的迁移学习任务中取得了较优的性能。

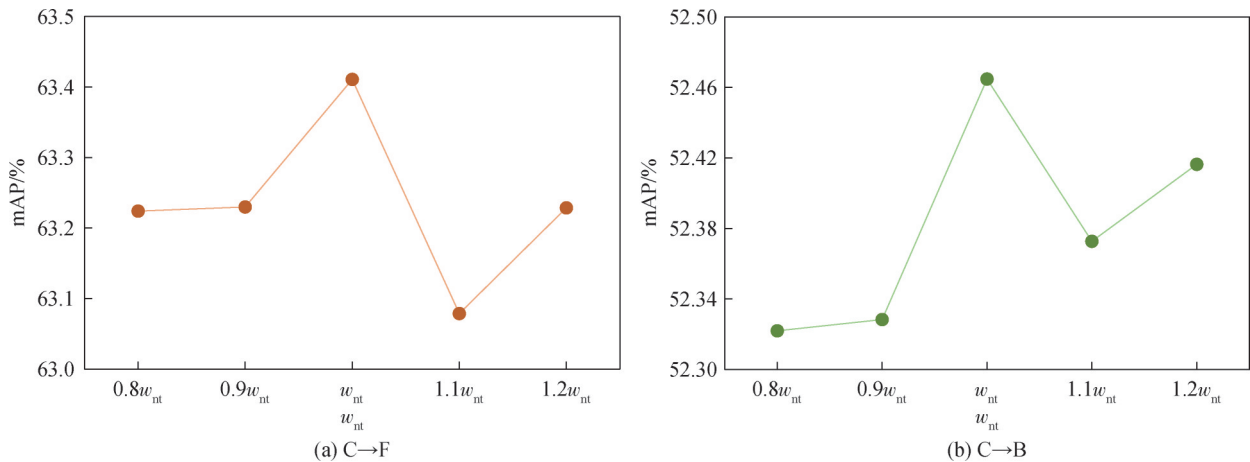


图5 其他任务使用不同负教学权重的结果

Fig. 5 Results of other tasks using different weights of the negative teaching ((a) C→F; (b) C→B)

### 2.2.5 总体表述

由于对抗性训练有利于学习源域和目标域的共同特征,本文引入对抗性损失 $L_{ad}$ 以减轻源域和目标域的域间分布差异,并结合式(2)、(3)、(5)和(7),最终优化目标为

$$L = L_s + L_{un} + \lambda_1 L_{nt} + L'_{nt} + \lambda_2 L_{ad} \quad (9)$$

式中, $\lambda_1$ 和 $\lambda_2$ 是控制相应项的参数。

## 3 实验

### 3.1 数据集

本文在 Cityscapes (Cordts 等, 2016)、Foggy

Cityscapes (Sakaridis 等, 2018)、Bdd100k (Yu 等, 2020)、Pascal VOC(pattern analysis, statistical modeling and computational learning visual object classes) (Everingham 等, 2010)和Clipart1k (Inoue 等, 2018) 5个公开数据集上进行了实验。根据现有的域自适应目标检测方法(Li 等, 2022b; Zhao 等, 2023; Kay 等, 2025),本研究设置了以下任务用于性能评估:

1)天气条件适应(Cityscapes→Foggy Cityscapes, C→F)。Cityscapes是在晴朗天气条件下用车载相机拍摄的街道场景数据集,由训练集(2 975幅图像)和验证集(500幅图像)组成,具有8类带注释的边界框。Foggy Cityscapes是一个基于Cityscapes的带有

雾天噪声的合成数据集。因此,两个数据集的图像和标注是兼容的。一般地,研究者将前者 and 后者分别作为源域和目标域。

2) 城市道路跨风格适应(Cityscapes→Bdd100k, C→B)。Bdd100k是一个大规模的城市景观数据集,包含来自不同城市的100 000幅图像,涵盖6种天气、6种不同的场景和3种不同的时间段。在域适应场景实验中,研究者提取标记为daytime的子集,包括36 728幅训练图像和5 258幅验证图像,具有7类带注释的边界框。一般地,研究者将Cityscapes和Bdd100k分别作为源域和目标域。

3) 真实至插画风格适应(Pascal VOC→Clipart1k, V→C)。Pascal VOC是一个真实世界数据集,包含2007和2012两个子集,共20个常见的类别和16 551幅图像。Clipart1k是带有抽象、艺术和滑稽风格的图像数据集,包含500幅训练图像和500幅验证图像,并与Pascal VOC共享20个类别。一般地,研究者将Pascal VOC作为源域,Clipart1k作为目标域。

### 3.2 实现细节

本研究以Faster R-CNN(Ren等,2017)为基础检

测模型,以Detectron2为集成框架,以ResNet50-FPN(residual network-50 with feature pyramid network)为预训练网络。在实验中,将式(1)中的 $\alpha$ 设置为0.999 6,式(9)中的 $\lambda_1$ 设置为0.000 001,式(9)中的 $\lambda_2$ 依据任务不同分别设置为0.001、0.001和0.1。所有实验均在1块NVIDIA RTX4090 GPU上进行。参考之前的域自适应目标检测研究(Li等,2022b; Zhao等,2023; Kay等,2025),报道的平均精度(average precision, AP)值均为AP50值。为了避免意外的结果,实验结果是3次重复实验的平均值。

### 3.3 实验结果

天气条件适应的实验结果如表1所示。由表1可以看出,本文方法NTNL的平均精度均值(mean average precision, mAP)为63.4%,相比于最近的方法DINO Teacher提升了8.0%。值得注意的是,本文方法在众多类别上均实现了性能提升,尤其在person、rider和bicycle等易混淆类别中,性能提升幅度超过了10%,主要原因是NTNL使用了负向思想缓解了对特定天气条件的过拟合,从而使模型更具鲁棒性。

城市道路跨风格适应的实验结果如表2所示。

表1 从Cityscapes到Foggy Cityscapes适应的平均精度结果

Table 1 Results of average precision for adaptation from Cityscapes to Foggy Cityscapes

方法	person	rider	car	truck	bus	train	mcycle	bicycle	mAP
SFDAOD(Li等,2021)	33.2	40.7	44.5	25.5	39.0	22.2	28.4	34.1	33.5
SADA(Chen等,2021)	48.5	52.6	62.1	29.5	50.3	31.5	32.4	45.4	44.0
SIGMA(Li等,2022a)	44.0	43.9	60.3	31.6	50.4	51.5	31.7	40.6	44.2
PT(Chen等,2022)	43.2	52.4	63.4	33.4	56.6	37.8	41.3	48.7	47.1
AT(Li等,2022b)	45.5	55.1	64.2	35.0	56.3	<b>54.3</b>	38.5	51.9	50.9
MIC(Hoyer等,2023)	50.9	55.3	67.0	33.9	52.4	33.7	40.6	47.5	47.6
MILA(Krishna等,2023)	45.6	52.8	64.8	34.7	61.4	54.1	39.7	51.5	50.6
CMT(Cao等,2023)	47.0	55.7	64.5	39.4	63.2	51.9	40.3	53.1	51.9
IDF+CAGrad(Shi和Zheng,2024)	38.4	51.4	54.7	33.5	51.0	43.1	35.0	42.5	43.7
MRDA(Bai等,2024)	48.7	50.1	64.1	25.6	46.0	50.5	34.3	38.8	44.8
JFDI(Qiao等,2024)	45.8	53.6	64.1	36.4	58.7	39.2	38.6	49.2	48.2
CAT(Kennerley等,2024)	44.6	57.1	63.7	40.8	66.0	49.7	44.9	53.0	52.5
AFAN(Jiang等,2025)	38.5	45.2	55.9	30.1	44.6	40.3	37.4	40.9	41.6
UDA-DETR(Xiao等,2025)	48.0	50.3	64.1	30.6	52.5	41.6	34.9	45.4	46.0
UMS <sup>2</sup> -ODNet(Li等,2025)	48.0	51.1	61.0	35.9	52.2	54.0	40.6	43.6	48.3
DINO Teacher(Lavoie等,2025)	48.5	60.0	65.4	47.2	<b>66.5</b>	52.9	46.2	56.7	55.4
NTNL(本文)	<b>70.1</b>	<b>70.3</b>	<b>79.7</b>	<b>47.8</b>	64.9	54.1	<b>52.9</b>	<b>67.5</b>	<b>63.4</b>

注:加粗字体表示各列最优结果。

由表2可以看出,本文方法的mAP值为52.5%,相比于DINO Teacher提升了4.7%。虽然场景布局和成像设备的变化使目标域与源域存在较大的域偏移,模型难以取得较大的性能提升,但是由于NTNL同时学习了伪标签知识和互补标签知识,使得模型具有较强的泛化能力,在多数类别仍然获得了相对令人满意的性能。

从真实至插画风格适应的实验结果如表3所

示。相比于前两个场景,该场景具有更大的域偏移,更具挑战性。由表3可以看出,NTNL的mAP值为45.4%,相比于先进方法AFAN提升了1.7%。尽管NTNL在该任务上的平均性能没有超过MRDA,但仍取得了相当有竞争的性能。特别地,NTNL在bike和mbike等难以区分的类别上取得了比MRDA更好的性能。主要原因是NTNL整合了负教学和负学习,降低了噪声伪标签的影响。

表2 从Cityscapes到Bdd100k-daytime适应的平均精度结果

Table 2 Results of average precision for adaptation from Cityscapes to Bdd100k-daytime

方法	person	rider	car	truck	bus	mecyle	bicycle	mAP
Faster R-CNN(Ren等,2017)	28.8	25.4	44.1	17.9	16.1	13.9	22.4	24.1
DA-Faster(Chen等,2018)	28.9	27.4	44.2	19.1	18.0	14.2	22.4	24.9
FCOS(Tian等,2019)	38.6	24.8	54.5	17.2	16.3	15.0	18.3	26.4
CRDA(Xu等,2020)	31.4	31.3	46.3	19.5	18.9	17.3	23.8	26.9
CAFA(Hsu等,2020a)	39.6	26.8	55.8	18.8	19.1	14.5	20.1	27.8
Def DETR(Zhu等,2021)	38.9	26.7	55.2	15.7	19.7	10.8	16.2	26.2
SFA(Wang等,2021)	40.2	27.6	57.5	19.1	23.4	15.4	19.2	28.9
AQT(Huang等,2022)	38.2	33.0	58.4	17.3	18.4	16.9	23.5	29.4
O <sup>2</sup> net(Gong等,2022)	40.4	31.2	58.6	20.4	25.0	14.9	22.7	30.5
MTTrans(Yu等,2022)	44.1	30.1	61.5	25.1	26.9	17.7	23.0	32.6
MRT(Zhao等,2023)	48.4	30.9	63.7	24.7	25.5	20.0	22.6	33.7
SFA+CAGrad(Shi和Zheng,2024)	43.0	30.3	59.1	23.0	25.4	16.8	23.5	31.6
UDA-DETR(Xiao等,2025)	42.7	29.3	58.1	17.8	23.9	16.0	23.2	30.2
DINO Teacher(Lavoie等,2025)	51.6	47.0	66.6	<b>44.3</b>	<b>45.9</b>	38.3	40.8	47.8
NTNL(本文)	<b>66.5</b>	<b>51.1</b>	<b>79.0</b>	43.1	43.7	<b>42.2</b>	<b>41.6</b>	<b>52.5</b>

注:加粗字体表示各列最优结果。

### 3.4 消融实验

为验证所提方法的有效性,将改进的对齐蒸馏(align and distill ++, ALDI++)框架(Kay等,2025)作为基础架构,运用对抗性训练策略(Li等,2022b),通过逐步添加负教学模块和负学习模块的方式开展消融实验。为方便起见,将基于对抗性训练的ALDI++框架命名为联合模型(union previous, UnionPre)。实验结果如表4所示,其中w/o表示移除其后面的模块。

从表4可以观察到,NTNL中的每个组件都发挥着重要的作用。本文使用负教学或负学习都实现了性能提升,同时使用负教学和负学习可以获得更好

的性能。需要注意的是,负学习模块可以独立消融,而负教学模块与自适应加权机制是默认组合的。这是因为自适应加权机制的目的是平衡不同任务中负教学损失占总损失的比例,而不是具体提高模型在某一个任务中的性能。

为更直接且清晰地呈现本文模型的检测效果,将部分检测结果展示于图6中。得益于负教学和负学习的作用,NTNL通常可以取得更高的分类置信度和更准确的主要目标定位,并且可以纠正UnionPre对容易混淆实例的错误预测。如图6(d)和图6(g)所示,NTNL可以正确识别一辆被UnionPre错误预测为汽车的卡车。

表3 从Pascal VOC到Clipart1k适应的平均精度结果

Table 3 Results of average precision for adaptation from Pascal VOC to Clipart1k

方法											/%
	aero	bike	bird	boat	bottle	bus	car	cat	chair	cow	table
SWDA(Saito等,2019)	26.2	48.5	32.6	33.7	38.5	54.3	37.1	18.6	34.8	58.3	17.0
DM(Kim等,2019a)	25.8	63.2	24.5	42.4	47.9	43.1	37.5	9.1	47.0	46.7	26.8
CRDA(Xu等,2020)	28.7	55.3	31.8	26.0	40.1	63.6	36.6	9.4	38.7	49.3	17.6
HTCN(Chen等,2020)	33.6	58.9	34.0	23.4	45.6	57.0	39.8	12.0	39.7	51.3	21.1
UMT(Deng等,2021)	39.6	59.1	32.4	35.0	45.1	61.9	48.4	7.5	46.0	<b>67.6</b>	21.4
TIA(Zhao和Wang,2022)	<b>42.2</b>	66.0	36.9	37.3	43.7	71.8	49.7	18.2	44.9	58.9	18.2
CMT(Cao等,2023)	39.8	56.3	<b>38.7</b>	39.7	60.4	35.0	<b>56.0</b>	7.1	<b>60.1</b>	60.4	35.8
TFD(Wang等,2024)	27.9	64.8	28.4	29.5	25.7	64.2	47.7	13.5	47.5	50.9	<b>50.8</b>
MRDA(Bai等,2024)	39.9	64.6	35.5	<b>43.5</b>	57.0	<b>77.5</b>	46.8	<b>21.1</b>	43.6	60.6	35.9
AFAN(Jiang等,2025)	39.5	63.6	36.7	34.2	42.7	62.4	41.9	12.6	44.2	59.9	16.5
NTNL(本文)	38.3	<b>67.1</b>	36.0	43.4	<b>66.0</b>	39.5	46.4	21.0	55.7	58.1	47.6

方法											mAP
	dog	horse	mbike	prsn	plant	sheep	sofa	train	tv		
SWDA(Saito等,2019)	12.5	33.8	65.5	61.6	52.0	9.3	24.9	54.1	49.1	38.1	
DM(Kim等,2019a)	24.9	48.1	78.7	63.0	45.0	21.3	36.1	52.3	<b>53.4</b>	41.8	
CRDA(Xu等,2020)	14.1	33.3	74.3	61.3	46.3	22.3	24.3	49.1	44.3	38.3	
HTCN(Chen等,2020)	20.1	39.1	72.8	63.0	43.1	19.3	30.1	50.2	51.8	40.3	
UMT(Deng等,2021)	<b>29.5</b>	48.2	75.9	70.5	56.7	25.9	28.9	39.4	43.6	44.1	
TIA(Zhao和Wang,2022)	29.1	40.7	<b>87.8</b>	67.4	49.7	27.4	27.8	<b>57.1</b>	50.6	46.3	
CMT(Cao等,2023)	28.1	<b>67.8</b>	84.5	<b>80.1</b>	55.5	20.3	32.8	42.3	38.2	47.0	
TFD(Wang等,2024)	21.3	33.9	60.2	65.6	42.5	15.1	40.5	45.5	48.6	41.2	
MRDA(Bai等,2024)	22.2	41.1	59.4	60.5	55.0	<b>36.3</b>	<b>43.8</b>	47.4	52.5	<b>47.2</b>	
AFAN(Jiang等,2025)	25.4	37.3	79.1	69.4	53.7	25.1	21.3	55.9	52.1	43.7	
NTNL(本文)	7.1	43.4	79.8	70.5	<b>62.7</b>	21.0	28.7	30.3	45.0	45.4	

注:加粗字体表示各列最优结果。

表4 消融实验的结果

Table 4 Results of ablation experiment

方法	基线	负 教学	负 学习	mAP/%		
				C→F	C→B	V→C
UnionPre	√	-	-	63.2	52.3	44.9
NTNL w/o NL	√	√	-	63.3	52.4	45.0
NTNL w/o NT	√	-	√	63.3	52.4	45.0
NTNL	√	√	√	<b>63.4</b>	<b>52.5</b>	<b>45.4</b>

注:加粗字体表示各列最优结果。“√”表示使用对应模块,“-”表示未采用。

### 3.5 参数敏感性分析

为了验证本文超参数取值的合理性,进行了超

参数敏感性实验。不同任务中参数 $\lambda_1$ 和 $\lambda_2$ 的取值对平均精度均值mAP的影响分别如图7和图8所示。通过图7和图8可以发现,按照本文设定 $\lambda_1$ 和 $\lambda_2$ 的值进行实验可以获得较优的性能,调高或调低超参数的值都会导致性能下降。

### 3.6 特征可视化

为直观展示所提出NTNL方法的优越性,本小节使用t-分布领域嵌入算法(t-distributed stochastic neighbor embedding, t-SNE)(van der Maaten和Hinton, 2008)对已有方法CAT、DINO Teacher和Union-Pre以及本文方法NTNL学习的特征进行可视化,如

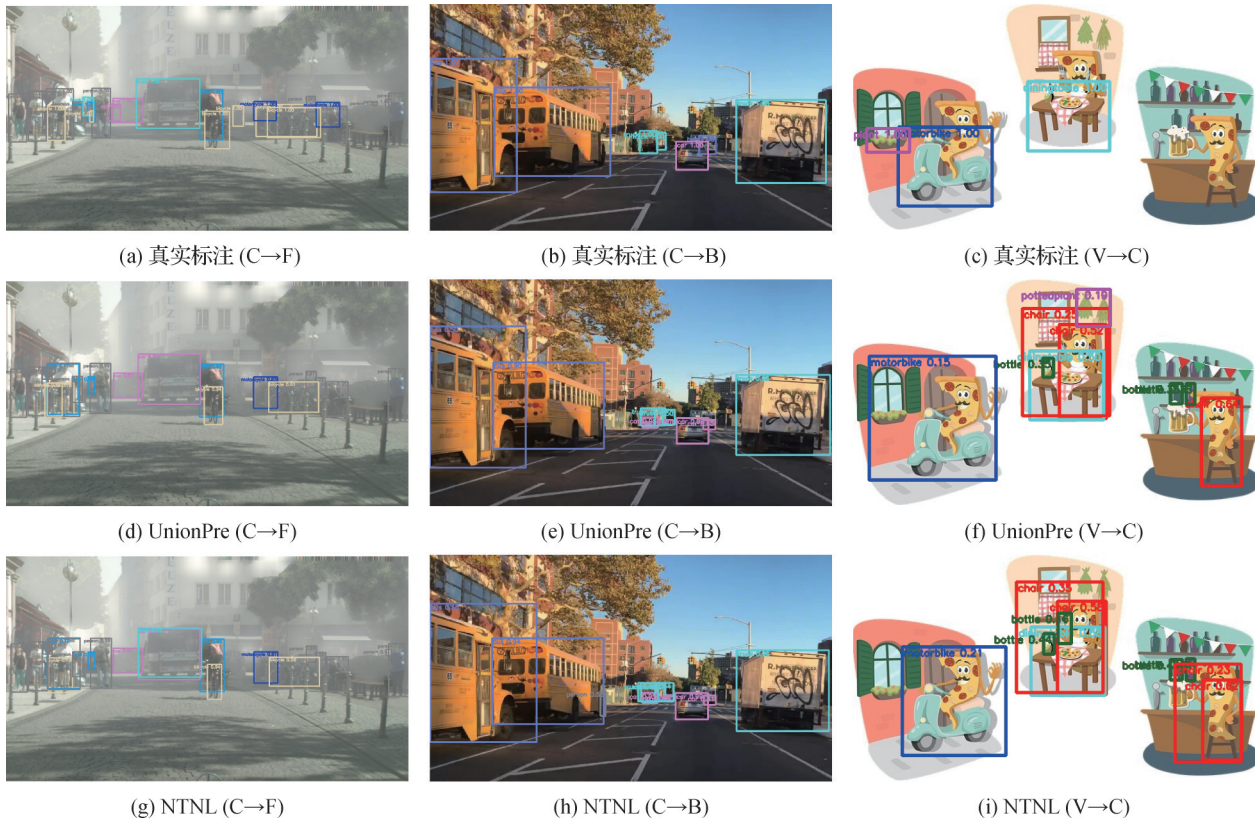


图6 不同任务的检测结果示例

Fig. 6 Example detection results of different tasks ((a) ground truth (C→F); (b) ground truth (C→B); (c) ground truth (V→C); (d) UnionPre (C→F); (e) UnionPre (C→B); (f) UnionPre (V→C); (g) NTNL (C→F); (h) NTNL (C→B); (i) NTNL (V→C))




图7 超参数  $\lambda_1$  对3个任务 mAP 值的影响

Fig. 7 Impact of the hyperparameter  $\lambda_1$  on mAP for three tasks ((a) C→F; (b) C→B; (c) V→C)

图9所示。图9展示了不同方法在天气条件适应 C→F 任务上目标域的2维嵌入特征,其中不同颜色代表不同类别。

通过观察图9(a)可以发现,CAT的特征分布较为分散,这在一定程度上限制了模型对各类别的置信度预测。尤其是在实例数量较少的类别上,CAT的预测更为保守,导致对应类别的检测结果不足。在图9(b)中,DINO Teacher在实例稀缺类别上展现

出更积极的探索能力,但特征分布仍然较为分散。相比之下,图9(c)所展示的特征多数按照类别聚集,这表明 UnionPre 具有较好的特征判别性。与 UnionPre 相比,NTNL产生的特征簇间分离度更高、类别更清晰,尤其对骑手、人等语义相近以及易混类别的区分效果更为显著,这说明本文方法具有强大的表征学习能力,有利于获得更高的分类置信度和更准确的主要目标定位。此外,得益于负向思维的


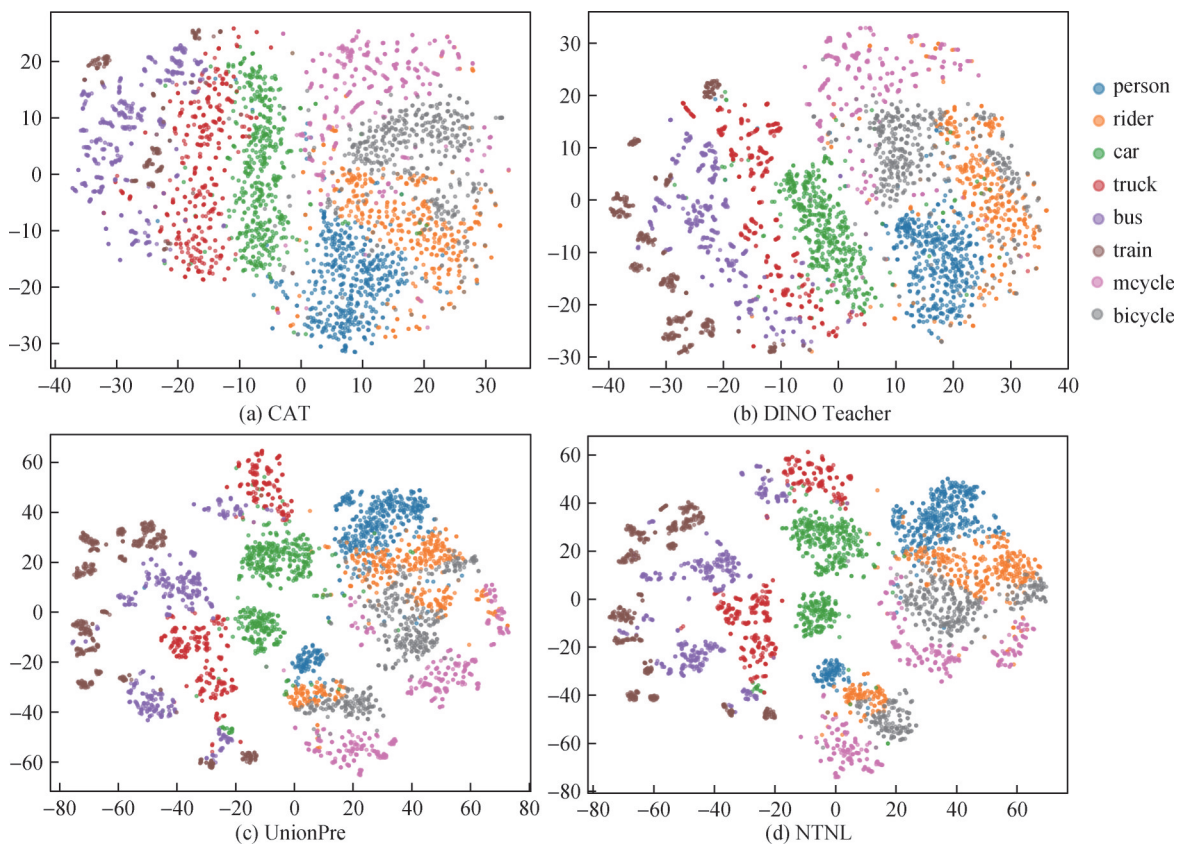
图8 超参数 $\lambda_2$ 对3个任务mAP值的影响Fig. 8 Impact of the hyperparameter  $\lambda_2$  on mAP for three tasks ((a) C→F; (b) C→B; (c) V→C)

图9 特征可视化(C→F任务)

Fig. 9 Feature visualization of the C→F task ((a) CAT; (b) DINO Teacher; (c) UnionPre; (d) NTNL)

作用,NTNL在类边界处呈现出自然的模糊过渡,可以缓解噪声伪标签的干扰,增强模型的鲁棒性。

### 3.7 时间复杂度分析

本节对所提方法以及对比方法的时间复杂度进行分析。在确保硬件配置与实验环境一致的前提下,对不同方法在天气条件适应C→F任务中的训练时间与推理时间进行了对比,结果如表5所示。通过表5可以看出,CAT的训练时间最短,但是由表1可知其检测准确率欠佳。相较于DINO Teacher,NTNL在

保持近似训练时间的前提下,提升了检测准确性;相较于UnionPre,NTNL在保证检测准确性提升的同时,仅增加了约15%的训练时间开销。值得注意的是,各种方法在推理阶段的耗时均在数分钟以内,几乎没有额外开销。因此,NTNL在保持较小额外训练时间的前提下,实现了更优的检测准确性。

### 3.8 收敛性分析

为了验证模型的收敛性,在不同任务上跟踪并记录了目标函数值在训练迭代过程中的变化,如

表5 不同方法的耗时

Table 5 Time consumption of different methods

方法	训练时间/min	推理时间/min
CAT	800	0.65
DINO Teacher	1 074	0.78
UnionPre	930	1.10
NTNL	1 070	1.13

图10所示。天气条件适应任务的收敛曲线如图10(a)所示。第10 000次迭代时的跳变值表示从监督训练到无监督训练的转换。曲线在有监督阶段约3 000次迭代和无监督阶段约9 000次迭代时趋于稳定。真实至插画风格适应任务的收敛曲线如图10(c)所示。第3 000次迭代时的跳变值表示从监督训练到无监督训练的转换。曲线在有监督阶段约2 000次迭代和无监督阶段约9 000次迭代时趋于稳定。值得注意的是,伪标签的质量在迭代过程中不断提高,随机选取的互补标签的交叉熵值变大,导致整体目标函数值在一段时间内有增加的趋势,最终趋于稳定。




图10 NTNL的收敛性能

Fig. 10 Convergence performance of NTNL

((a) convergence curve of C→F; (b) convergence curve of C→B; (c) convergence curve of V→C)

## 4 结论

本文提出了一种融合负教学、负学习和自适应加权机制的域自适应目标检测方法(NTNL),缓解了噪声伪标签的影响。具体而言,NTNL引入负教学策略,减轻了教师模型在不确定样本上产生噪声伪标签的可能性,提高了对学生模型指导的质量。其

稳定。城市道路跨风格适应任务的收敛曲线如图10(b)所示。第4 000次迭代时的跳变值表示从监督训练到无监督训练的转换。曲线在有监督阶段约3 000次迭代和无监督阶段约9 000次迭代时趋于稳定。真实至插画风格适应任务的收敛曲线如图10(c)所示。第3 000次迭代时的跳变值表示从监督训练到无监督训练的转换。曲线在有监督阶段约2 000次迭代和无监督阶段约9 000次迭代时趋于稳定。值得注意的是,伪标签的质量在迭代过程中不断提高,随机选取的互补标签的交叉熵值变大,导致整体目标函数值在一段时间内有增加的趋势,最终趋于稳定。

次,引入负学习方法,可以引导学生模型认识互补标签,间接提高了学习效果。此外,设计的自适应加权机制有利于保持不同迁移学习任务中负教学损失在总体损失的比例相对稳定。最后,本文在Cityscapes、Foggy Cityscapes、Bdd100k、Pascal VOC和Clipart1k跨域目标检测数据集上进行了实验,验证了NTNL的有效性。虽然本文方法取得了不错的识别效果,但设计的加权机制仅考虑了类别数对负教

学尺度的影响,未考虑域偏移程度和学习难度的影响,未来的研究将尝试度量域偏移程度和学习难度,以设计更有效的自适应加权机制。

## 参考文献 (References)

- Bai Y F, Liu C, Yang R and Li X M. 2024. Misalignment-resistant domain adaptive learning for one-stage object detection. *Knowledge-Based Systems*, 305: #112605 [DOI: 10.1016/j.knsys.2024.112605]
- Bai Y F, Wang L B, Gao W D and Ma Y L. 2024. Multi-modal hierarchical classification for power equipment defect detection. *Journal of Image and Graphics*, 29(7): 2011-2023 (白艳峰, 王立彪, 高卫东, 马应龙. 2024. 面向电力设备缺陷检测的多模态层次化分类. *中国图象图形学报*, 29(7): 2011-2023) [DOI: 10.11834/jig.230269]
- Cao S C, Joshi D, Gui L Y and Wang Y X. 2023. Contrastive mean teacher for domain adaptive object detectors//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada: IEEE: 23839-23848 [DOI: 10.1109/CVPR52729.2023.02283]
- Chen C Q, Zheng Z B, Ding X H, Huang Y and Dou Q. 2020. Harmonizing transferability and discriminability for adapting object detectors//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 8866-8875 [DOI: 10.1109/CVPR42600.2020.00889]
- Chen M L, Chen W J, Yang S C, Song J, Wang X C, Zhang L, et al. 2022. Learning domain adaptive object detection with probabilistic teacher//*Proceedings of the 39th International Conference on Machine Learning*. [s.l.]: PMLR: 3040-3055
- Chen Y H, Li W, Sakaridis C, Dai D X and Van Gool L. 2018. Domain adaptive faster R-CNN for object detection in the wild//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 3339-3348 [DOI: 10.1109/CVPR.2018.00352]
- Chen Y H, Wang H R, Li W, Sakaridis C, Dai D X and Van Gool L. 2021. Scale-aware domain adaptive faster R-CNN. *International Journal of Computer Vision*, 129(7): 2223-2243 [DOI: 10.1007/s11263-021-01447-x]
- Cordts M, Omran M, Ramos S, Rehfeld T, Enzweiler M, Benenson R, et al. 2016. The cityscapes dataset for semantic urban scene understanding//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, USA: IEEE: 3213-3223 [DOI: 10.1109/CVPR.2016.350]
- Deng J, Dong W, Socher R, Li L J, Li K and Li F F. 2009. ImageNet: a large-scale hierarchical image database//*Proceedings of 2009 IEEE Conference on Computer Vision and Pattern Recognition*. Miami, USA: IEEE: 248-255 [DOI: 10.1109/CVPR.2009.5206848]
- Deng J H, Li W, Chen Y H and Duan L X. 2021. Unbiased mean teacher for cross-domain object detection//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 4089-4099 [DOI: 10.1109/CVPR46437.2021.00408]
- Everingham M, Van Gool L, Williams C K I, Winn J and Zisserman A. 2010. The PASCAL visual object classes (VOC) challenge. *International Journal of Computer Vision*, 88(2): 303-338 [DOI: 10.1007/s11263-009-0275-4]
- Freire A, De S Silva L H, De Andrade J V R, Azevedo G O A and Fernandes B J T. 2024. Beyond clean data: exploring the effects of label noise on object detection performance. *Knowledge-Based Systems*, 304: #112544 [DOI: 10.1016/j.knsys.2024.112544]
- Ganin Y, Ustinova E, Ajakan H, Germain P, Larochelle H, Laviolette F, et al. 2016. Domain-adversarial training of neural networks. *Journal of Machine Learning Research*, 17(59): 1-35
- Gong K X, Li S, Li S G, Zhang R, Liu C H and Chen Q. 2022. Improving transferability for domain adaptive detection transformers//*Proceedings of the 30th ACM International Conference on Multimedia*. Lisboa, Portugal: ACM: 1543-1551 [DOI: 10.1145/3503161.3548246]
- Hoyer L, Dai D X, Wang H R and Van Gool L. 2023. MIC: masked image consistency for context-enhanced domain adaptation//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada: IEEE: 11721-11732 [DOI: 10.1109/CVPR52729.2023.01128]
- Hsu C C, Tsai Y H, Lin Y Y and Yang M S. 2020a. Every pixel matters: center-aware feature alignment for domain adaptive object detector//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow, UK: Springer: 733-748 [DOI: 10.1007/978-3-030-58545-7\_42]
- Hsu H K, Yao C H, Tsai Y H, Hung W C, Tseng H Y, Singh M, et al. 2020b. Progressive domain adaptation for object detection//*Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision*. Snowmass, USA: IEEE: 738-746 [DOI: 10.1109/WACV45572.2020.9093358]
- Huang W J, Lu Y L, Lin S Y, Xie Y S and Lin Y Y. 2022. AQT: adversarial query transformers for domain adaptive object detection//*Proceedings of the 31st International Joint Conference on Artificial Intelligence*. Vienna, Austria: Morgan Kaufmann: 972-979 [DOI: 10.24963/ijcai.2022/136]
- Inoue N, Furuta R, Yamasaki T and Aizawa K. 2018. Cross-domain weakly-supervised object detection through progressive domain adaptation//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 5001-5009 [DOI: 10.1109/CVPR.2018.00525]
- Jiang W, Luan Y J, Tang K W, Wang L J, Zhang N, Chen H L, et al. 2025. Adaptive feature alignment network with noise suppression for cross-domain object detection. *Neurocomputing*, 614: #128789

- [DOI: 10.1016/j.neucom.2024.128789]
- Kay J, Haucke T, Stathatos S, Deng S Q, Young E, Perona P, et al. 2025. Align and distill: unifying and improving domain adaptive object detection. *Transactions on Machine Learning Research*, [EB/OL]. [2025-05-12]. <https://arxiv.org/pdf/2403.12029.pdf>
- Kennerley M, Wang J G, Veeravalli B and Tan R T. 2024. CAT: exploiting inter-class dynamics for domain adaptive object detection//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 16541-16550 [DOI: 10.1109/CVPR52733.2024.01565]
- Kim T, Jeong M, Kim S, Choi S and Kim C. 2019a. Diversify and match: a domain adaptive representation learning paradigm for object detection//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA: IEEE: 12448-12457 [DOI: 10.1109/CVPR.2019.01274]
- Kim Y, Yim J, Yun J and Kim J. 2019b. NLNL: negative learning for noisy labels//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South): IEEE: 101-110 [DOI: 10.1109/ICCV.2019.00019]
- Krishna O, Ohashi H and Sinha S. 2023. MILA: memory-based instance-level adaptation for cross-domain object detection//*Proceedings of the 34th British Machine Vision Conference*. Aberdeen, UK: BMVA Press: #192
- Lang Q H, Zhang L, Shi W X, Chen W J and Pu S L. 2023. Exploring implicit domain-invariant features for domain adaptive object detection. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(4): 1816-1826 [DOI: 10.1109/TCSVT.2022.3216611]
- Lavoie M A, Mahmoud A and Waslander S L. 2025. Large self-supervised models bridge the gap in domain adaptive object detection//*Proceedings of 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 4692-4702 [DOI: 10.1109/CVPR52734.2025.00442]
- Li C C, Chen G, Hou Z X, Huang K and Zhang W. 2024. Survey of 3D object detection algorithms for autonomous driving. *Journal of Image and Graphics*, 29(11): 3238-3264 (李昌财, 陈刚, 侯作勋, 黄凯, 张伟. 2024. 自动驾驶中的三维目标检测算法研究综述. *中国图象图形学报*, 29(11): 3238-3264) [DOI: 10.11834/jig.230779]
- Li W Y, Liu X Y and Yuan Y X. 2022a. SIGMA: semantic-complete graph matching for domain adaptive object detection//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA: IEEE: 5281-5290 [DOI: 10.1109/CVPR52688.2022.00522]
- Li X F, Chen W J, Xie D, Yang S C, Yuan P, Pu S L, et al. 2021. A free lunch for unsupervised domain adaptive object detection without source data//*Proceedings of the 35th AAAI Conference on Artificial Intelligence*. Palo Alto, USA: AAAI Press: 8474-8481 [DOI: 10.1609/aaai.v35i10.17029]
- Li Y J, Dai X L, Ma C Y, Liu Y C, Chen K, Wu B C, et al. 2022b. Cross-domain adaptive teacher for object detection//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA: IEEE: 7571-7580 [DOI: 10.1109/CVPR52688.2022.00743]
- Li Y Z, Zhang Y, Yang C L and Chen Y. 2025. UMS<sup>2</sup>-ODNet: unified-scale domain adaptation mechanism driven object detection network with multi-scale attention. *Neural Networks*, 181: #106890 [DOI: 10.1016/j.neunet.2024.106890]
- Lin T Y, Dollár P, Girshick R, He K M, Hariharan B and Belongie S. 2017. Feature pyramid networks for object detection//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 936-944 [DOI: 10.1109/CVPR.2017.106]
- Lyu X Q, Quan W J, Han J, Chen Y Z and Cai Z T. 2024. Text self-training and adversarial learning-relevant domain adaptive industrial scene text detection. *Journal of Image and Graphics*, 29(10): 3090-3103 (吕学强, 权伟杰, 韩晶, 陈玉忠, 才藏太. 2024. 结合文本自训练和对抗学习的领域自适应工业场景文本检测. *中国图象图形学报*, 29(10): 3090-3103) [DOI: 10.11834/jig.230519]
- Nakamura Y, Ishii Y and Yamashita T. 2024. Active domain adaptation with false negative prediction for object detection//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 28782-28792 [DOI: 10.1109/CVPR52733.2024.02719]
- Qiao Z T, Shi D X, Jin S C, Shi Y Y, Wang Z and Qiu C P. 2024. JFDI: joint feature differentiation and interaction for domain adaptive object detection. *Neural Networks*, 180: #106682 [DOI: 10.1016/j.neunet.2024.106682]
- Ren S Q, He K M, Girshick R and Sun J. 2017. Faster R-CNN: towards real-time object detection with region proposal networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137-1149 [DOI: 10.1109/TPAMI.2016.2577031]
- Saito K, Ushiku Y, Harada T and Saenko K. 2019. Strong-weak distribution alignment for adaptive object detection//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA: IEEE: 6949-6958 [DOI: 10.1109/CVPR.2019.00712]
- Sakaridis C, Dai D X and Van Gool L. 2018. Semantic foggy scene understanding with synthetic data. *International Journal of Computer Vision*, 126(9): 973-992 [DOI: 10.1007/s11263-018-1072-8]
- Shi W X and Zheng B H. 2024. Conflict-alleviated gradient descent for adaptive object detection//*Proceedings of the 33rd International Joint Conference on Artificial Intelligence*. Jeju Island, Korea (South): Morgan Kaufmann: 1236-1244 [DOI: 10.24963/ijcai.2024/137]
- Su J Y, Su Y K, Zhang Y, Yang W Q, Huang H C and Wu Q Y. 2022. EpNet: power lines foreign object detection with edge proposal net-

- work and data composition. *Knowledge-Based Systems*, 249: #108857 [DOI: 10.1016/j.knosys.2022.108857]
- Tarvainen A and Valpola H. 2017. Mean teachers are better role models: weight-averaged consistency targets improve semi-supervised deep learning results//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA: Curran Associates Inc.: 1195-1204
- Tian Z, Shen C H, Chen H and He T. 2019. FCOS: fully convolutional one-stage object detection//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South) : IEEE: 9626-9635 [DOI: 10.1109/ICCV.2019.00972]
- Van Der Maaten L and Hinton G. 2008. Visualizing data using t-SNE. *Journal of Machine Learning Research*, 9(86): 2579-2605
- Wang H A, Jia S L, Zeng T Y, Zhang G X and Li Z. 2024. Triple feature disentanglement for one-stage adaptive object detection//*Proceedings of the 38th AAAI Conference on Artificial Intelligence*. Vancouver, Canada: AAAI Press: 5401-5409 [DOI: 10.1609/aaai.v38i6.28348]
- Wang W, Cao Y, Zhang J, He F X, Zha Z J, Wen Y G, et al. 2021. Exploring sequence feature alignment for domain adaptive detection transformers//*Proceedings of the 29th ACM International Conference on Multimedia*. New York, USA: ACM: 1730-1738 [DOI: 10.1145/3474085.3475317]
- Xiao H G, Zhou T T, Xiong S D, Li J L, Li Z H, Liu X, et al. 2025. Unsupervised domain-adaptive object detection: an efficient method based on UDA-DETR. *Neurocomputing*, 631: #129711 [DOI: 10.1016/j.neucom.2025.129711]
- Xu C D, Zhao X R, Jin X and Wei X S. 2020. Exploring categorical regularization for domain adaptive object detection//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 11721-11730 [DOI: 10.1109/CVPR42600.2020.01174]
- Yang L R, Zhou Q H and Lu B. 2024. Marginal subspace learning with group low-rank for unsupervised domain adaptation. *IEEE Transactions on Neural Networks and Learning Systems*, 35(7): 9122-9135 [DOI: 10.1109/TNNLS.2022.3218554]
- Yu F, Chen H F, Wang X, Xian W Q, Chen Y Y, Liu F C, et al. 2020. BDD100K: a diverse driving dataset for heterogeneous multi-task learning//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 2633-2642 [DOI: 10.1109/CVPR42600.2020.00271]
- Yu J Z, Liu J M, Wei X B, Zhou H Y, Nakata Y, Gudovskiy D, et al. 2022. MTTrans: cross-domain object detection with mean teacher transformer//*Proceedings of the 17th European Conference on Computer Vision*. Tel Aviv, Israel: Springer: 629-645 [DOI: 10.1007/978-3-031-20077-9\_37]
- Zhang Y, Huang C, Shi J, Zhang Y Y, Huang J W, Yu S J, et al. 2024. An enhanced algorithm for object detection based on generative adversarial structure. *Chinese Journal of Computers*, 47(3): 647-661 (张昀, 黄橙, 施健, 张玉瑶, 黄经纬, 于舒娟, 等. 2024. 一种基于生成对抗架构的目标检测增强算法. *计算机学报*, 47(3): 647-661) [DOI: 10.11897/SP.J.1016.2024.00647]
- Zhao L and Wang L M. 2022. Task-specific inconsistency alignment for domain adaptive object detection//*Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. New Orleans, USA: IEEE: 14197-14206 [DOI: 10.1109/CVPR52688.2022.01382]
- Zhao Z J, Wei S T, Chen Q C, Li D H, Yang Y F, Peng Y X, et al. 2023. Masked retraining teacher-student framework for domain adaptive object detection//*Proceedings of 2023 IEEE/CVF International Conference on Computer Vision*. Paris, France: IEEE: 18993-19003 [DOI: 10.1109/ICCV51070.2023.01745]
- Zhong A Y, Wang R, Zhang H, Zou C and Jing L H. 2023. Consistency-aware domain adaptive object detection via orthogonal disentangling and contrastive learning. *Chinese Journal of Computers*, 46(4): 827-842 (钟安雨, 王蕊, 张华, 邹聪, 荆丽桦. 2023. 基于域内域间语义一致性约束的域自适应目标检测方法. *计算机学报*, 46(4): 827-842) [DOI: 10.11897/SP.J.1016.2023.00827]
- Zhou Y, Han B, Gao X B, Yang Z and Chen W M. 2024. Domain adaptive object detection based on attention mechanism and cycle domain triplet loss. *Acta Automatica Sinica*, 50(11): 2188-2203 (周洋, 韩冰, 高新波, 杨铮, 陈玮铭. 2024. 基于注意力机制和循环域三元损失的域自适应目标检测. *自动化学报*, 50(11): 2188-2203) [DOI: 10.16383/j.aas.c220938]
- Zhu X Z, Su W J, Lu L W, Li B, Wang X G and Dai J F. 2021. Deformable DETR: deformable transformers for end-to-end object detection//*Proceedings of 2021 International Conference on Learning Representations*. Virtual Event: OpenReview.net: #1041

## 作者简介

杨立然,女,讲师,主要研究方向为计算机视觉和机器学习。

E-mail: yangliran@ncepu.edu.cn

苏攀,通信作者,男,副教授,主要研究方向为模糊系统和机器学习。E-mail: supan@ncepu.edu.cn

王佳琪,男,硕士研究生,主要研究方向为计算机视觉。

E-mail: wangjiaqi@ncepu.edu.cn

翟永杰,男,教授,主要研究方向为模式识别、数字图像处理 and 计算机控制系统。E-mail: zhaiyongjie@ncepu.edu.cn