

# 结合循环提取器与自蒸馏的目标检测方法

仲林伟, 陈丹伟

(南京邮电大学 计算机学院, 江苏 南京 210003)

**摘要:**在深度学习时代,目标检测方法不断发展,且在良好的视觉环境中已经具有较高的水平。但是,在特殊天气下,常规的目标检测方法的检测性能大幅下降,甚至失效,而特殊天气环境的行车安全一直是社会广泛关注的问题。为了解决上述问题,该文主要设计了一个目标检测器的模型,即引入循环解纠缠、自蒸馏方法的改进 YOLO 模型。在循环解纠缠模块,从输入图像中循环提取域不变特征,通过循环操作,可以在不依赖域相关注释的情况下,提高图像域特征和域不变特征的解缠能力;在自蒸馏模块,以提取到的域不变特征为教师对象,进一步提高泛化能力。并且该检测器在只有一个源域进行训练的情况下,面对许多未曾训练过的目标域上仍然表现良好,提高了检测器在未知域的鲁棒性。实验验证了模型在各种天气下城市场景目标检测的效果,实验数据表明,该方法优于基线约 8 个百分点,相比基线方法获得了性能提升。

**关键词:**深度学习;目标检测;特殊天气;循环解纠缠;自蒸馏;域不变特征

中图分类号:TP391.41

文献标识码:A

文章编号:1673-629X(2024)04-0070-06

doi:10.20165/j.cnki.ISSN1673-629X.2024.0011

## An Object Detection Method Combining Circular Extractor and Self Distillation

ZHONG Lin-wei, CHEN Dan-wei

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**Abstract:**In the era of deep learning, object detection methods are constantly developing and have reached a high level in a good visual environment. However, the detection performance of conventional target detection methods in adverse weather conditions has significantly decreased or even failed, and driving safety in adverse weather environments has always been a widespread concern in society. In order to solve the above problems, we mainly design a model of the target detector, which is an improved YOLO model that introduces cyclic-disentanglement and self-distillation methods. In the cyclic disentanglement module, domain invariant features are extracted from the input image in a cyclic manner. Through cyclic operations, the ability to unwrap image domain features and domain invariant features can be improved without relying on domain related annotations; in the self-distillation module, the extracted domain invariant features are used as the teacher's object to further improve generalization ability. Moreover, the detector performs well in many untrained target domains even when trained in only one source domain, improving its robustness in the unknown domain. The experiment verifies the effectiveness of the model in detecting urban scene targets under various weather conditions. The experimental data show that the proposed method outperforms the baseline by about 8 percentage points and achieves performance improvement compared to the baseline method.

**Key words:**deep learning; object detection; adverse weather; cyclic-disentangled; self-distillation; domain-invariant representations

### 0 引言

目标检测是一项重要的计算机视觉任务,主要任务是正确检测图像中目标对象的存在并准确定位。作为计算机视觉中重要的研究方向,目标检测发挥着关键作用,目标检测能够为图像的语义理解提供有价值的信息,并且与许多应用相关,一直受到极大的关注。目标检测涵盖不同的应用目标,例如行人检测、人脸检测、文本检测等。目标检测的目的是开发高效的计算模型和技术,同时它也是许多其他高级计算机视觉任

务的基础,比如实例分割、语义分割、目标跟踪等。

随着 2012 年 Alex Net<sup>[1]</sup> 的诞生,基于深度学习的目标检测时代由此揭开序幕。以卷积神经网络为代表的深度学习方法能够学习更高级、更深层次的特征。在深度学习时代,随着基于深度学习的目标检测方法的不断发展,目标检测<sup>[2-5]</sup>在良好的天气环境中已经具有较高的水平。但是特殊天气条件下的目标检测<sup>[6-7]</sup>问题一直都是交通领域研究的重点和难点。特殊天气是相对一般晴朗天气的,造成视程障碍现象:包

收稿日期:2023-07-27

修回日期:2023-11-29

作者简介:仲林伟(1995-),男,硕士,通信作者,研究方向为计算机视觉;陈丹伟(1979-),男,教授,博士,研究方向为信息安全及计算机应用。

括雾霾、沙尘、降雨和降雪等天气情况。特殊天气会造成图像模糊、特征无法辨识等问题,会让常规的目标检测方法的检测性能大幅下降,甚至失效。而特殊天气环境的行车安全一直是社会广泛关注的问题。根据国家统计局和地方部门发布的交通事故<sup>[8]</sup>调查报告显示,车辆在雨天、雪天、雾霾天最容易发生交通事故,这三类天气中所发生的交通事故占据了特殊天气总交通事故的99%;另外,特殊天气也更容易引发重大交通事故,调查显示发生在晴天的重大交通事故仅占42%,而发生在特殊天气的重大交通事故占58%。交通事故在中国居民综合死亡因素中排名第五,也是低年龄段人群最主要的死亡因素,交通事故严重影响人民群众的生命和财产安全,因此,如何减少不良天气的交通事故是提高居民出行安全,构建智慧城市出行的关键。

根据相关综述<sup>[9-11]</sup>,目前特殊天气条件下的目标检测主要有几个研究趋势:(1)基于数据集的构建,针对不同特殊天气的目标检测任务分别收集和制作数据

集,按数据集的属性分成真实数据集与合成数据集,并对合成数据集部分以合成方式展开为物理驱动和数据驱动。(2)基于图像恢复的目标检测,将原始数据先恢复成清晰图片,再在此基础上进行检测。(3)基于迁移学习的目标检测,以特征对齐机制的研究和多步域自适应等,尤其是领域自适应方法是近些年研究发展的趋势。

在综合成本以及算法效率的考量下,基于迁移学习的目标检测方案被大多数研究人员采用。但是,在实际应用中,将基于源域数据训练的目标检测器应用于未知的目标域时,由于域偏移<sup>[12-13]</sup>的影响,这些检测器通常具有较差的通用性。为了进一步探索提高目标检测器的泛化能力,该文设计了单域目标检测模型,如图1所示。给定一个用于训练的源域数据集,例如,在晴天良好的视觉环境下的数据集训练,模型的目标是将目标检测器很好地推广到多个未曾训练过的目标域,例如,夜晚、雨天、雾天等环境。

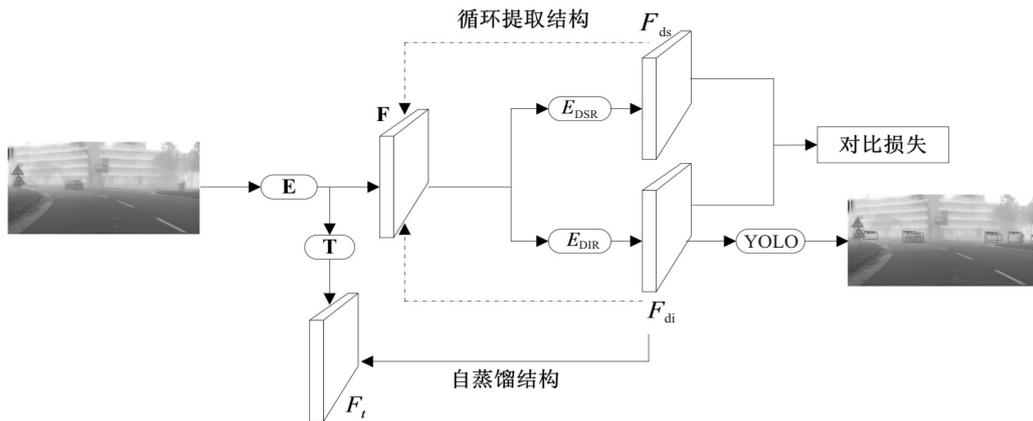


图1 单域目标检测模型结构

## 1 相关工作

为了减轻域偏移的影响,现有的研究主要集中在两方面:域自适应和域泛化。另外,自蒸馏机制也能在域特征提取方面发挥重要作用。

域自适应。一般来说,域自适应<sup>[14-17]</sup>的目的是将一个带注释的源域的数据分布与一个没有注释的目标域的数据分布对齐。为了减轻领域转移的影响,大多数现有方法<sup>[18-19]</sup>试图在源域和目标域之间对齐特征级分布。Chen等人<sup>[12]</sup>提出使用对抗性机制<sup>[20]</sup>来对齐特征级和实例级分布。在此基础上,Saito等<sup>[13]</sup>提出对局部和全局特征分布进行对齐,以提高检测器的泛化能力。此外,一些方法<sup>[21]</sup>采用生成式对抗网络将源域的风格转换为目标域的风格,直接减小了域差异。同时,也有一些方法<sup>[14]</sup>探索提取实例不变特征来增强泛化能力。虽然这些方法已被证明是有效的,但在训

练期间,它们通常需要访问源和目标领域数据。在训练过程中,对齐方法往往需要同时访问源域和目标域的数据,这导致对齐方法不能很好地适应其他未知的目标域。此外,当目标域是多个不同数据分布的复合域时,对齐方法的泛化能力往往较弱,从而降低了目标检测的性能。因此,这些方法不能用于解决单域泛化问题。

单域泛化<sup>[22-26]</sup>。旨在通过从多个源域学习将模型泛化到未知的目标域,这比域自适应更具挑战性。大多数现有方法采用数据增强和特征归一化来解决此任务。Volpi等人<sup>[27]</sup>和Qiao等人<sup>[28]</sup>探索利用对抗机制来解决这一任务。一般来说,大多数单域泛化方法试图学习跨多个源域的共享表示。然而,这些方法的性能高度依赖于源域的数量。而在实际中,收集多个源数据集既耗时又费力,这限制了单域泛化方法的应用。

自蒸馏机制。自蒸馏机制<sup>[29-31]</sup>的目的是在没有教师网络的情况下,利用自己的知识培养一个有效的学生网络。基于数据增强的方法和基于辅助网络的方法是两种常用的自蒸馏方法。具体而言,基于数据增强的自蒸馏<sup>[30]</sup>引入了原始数据与其增强数据之间的预测一致性损失。基于辅助网络的方法<sup>[29]</sup>在模型的中间层增加了分支。额外的分支被用来产生与网络预测相似的输出。虽然这些方法已被证明是有效的,但它们很少用于提高目标检测器的泛化能力。该文在提取 DIR 的基础上,利用自蒸馏进一步提高泛化能力。

## 2 模型结构

### 2.1 骨干网络

该文采用了广泛使用的 YOLO<sup>[4]</sup>作为基础检测模型,具体版本为 YOLOv5,因为此版本已被广泛运用在各个具体研究项目中。传统 YOLOv5 检测模型是对图片进行直接处理,得到最终检测结果,但是在图片质量不高时,检测效果会明显降低。与 YOLOv5 检测模型不同的是,该文引入了两个结构:循环特征提取结构和自蒸馏结构,用于图像特征提取以及泛化能力的提

升。此外,在最终的损失函数上,也做了相应的改动。

### 2.2 循环特征提取结构

最近的研究<sup>[20,32-33]</sup>表明,提取包含对象本质特征的域不变特征表示有助于提高泛化能力。为此,许多方法<sup>[34-35]</sup>直接利用域相关注释作为监督,将 DIR 从领域特定表示(DSR)中分离出来。然而,当领域相关的注释不可用时,如何从输入的视觉特征中很好地提取 DIR 仍然有待研究。因此,该文主要关注在不使用域相关注释的情况下提取出 DIR。

在原有的骨干网之前引入一个循环解纠缠模块,给定输入图像,使用图片特征提取层  $E$  来获得特征图  $F \in \mathbb{R}^{w \times h \times c}$ ,其中  $w, h$  和  $c$  分别表示宽度,高度和通道数。首先,加入了两个提取器,即  $E_{\text{DIR}}$  和  $E_{\text{DSR}}$ 。该特征提取器由多个卷积层和注意力模块组成,分别提取域不变特征  $F_{\text{di}} \in \mathbb{R}^{w \times h \times c}$  和域特征  $F_{\text{ds}} \in \mathbb{R}^{w \times h \times c}$ 。流程如下:

$$F_{\text{di}} = E_{\text{DIR}}(F), \quad F_{\text{ds}} = E_{\text{DSR}}(F) \quad (1)$$

接下来,如图 2 右侧所示,在反向方向上,  $E_{\text{DIR}}$  和  $E_{\text{DSR}}$  分别以  $F_{\text{di}}$  和  $F_{\text{ds}}$  作为输入进行再解缠。

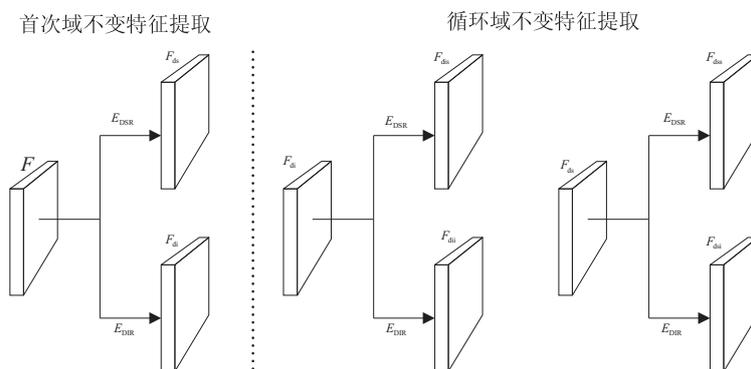


图 2 循环特征提取结构

$$F_{\text{dii}} = E_{\text{DIR}}(F_{\text{di}}), \quad F_{\text{dis}} = E_{\text{DSR}}(F_{\text{di}}) \quad (2)$$

$$F_{\text{dsi}} = E_{\text{DIR}}(F_{\text{ds}}), \quad F_{\text{dss}} = E_{\text{DSR}}(F_{\text{ds}}) \quad (3)$$

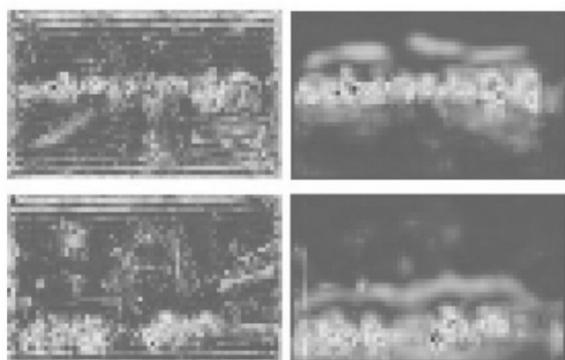


图 3 循环特征提取效果对比

再解纠缠后,进一步提取特征信息。当 DIR 和 DSR 提取器具有较好的解缠能力时,向 DIR 提取器输入  $F_{\text{di}}$ ,特征提取器  $E_{\text{DIR}}$  会输出更多的域不变信息,输

入  $F_{\text{ds}}$ ,特征提取器  $E_{\text{DSR}}$  的输出也会包含更多特定于该域的信息。实验也证实该假设,如图 3,上下两行分别为两张测试图经过特征提取器  $E_{\text{DIR}}$  后提取出的域不变特征,而第一列是两张测试图首次经过提取器后提取的特征图,第二列是循环经过提取器后的特征图,对比图中可以明显看出循环经过提取器后的特征图明显拥有更多域不变特征信息。

该文使用了一个对比损失来约束这个假设。当  $F_{\text{di}}$  包含丰富的域不变信息时,相对于  $F_{\text{di}}$ ,  $F_{\text{dii}}$  应该包含更多与  $F_{\text{di}}$  相关的域不变信息;同时,当  $F_{\text{ds}}$  包含足够的特定领域信息时,与  $F_{\text{ds}}$  相比,  $F_{\text{dss}}$  应该包含更多与  $F_{\text{ds}}$  相关的特定领域信息,用全局级的对比损失来约束这个假设。 $\text{sim}(a, b)$  表示特征映射  $a$  和  $b$  的所有对应元素的余弦相似度的平均值。全局对比损失计算如下:

$$L_{cd} = - \left( \log \frac{\exp(\text{sim}(F_{di}, F_{dii})/\tau)}{\sum_{j=0}^1 \exp(\text{sim}(F_{di}, G[j])/\tau)} + \log \frac{\exp(\text{sim}(F_{ds}, F_{dss})/\tau)}{\sum_{j=0}^1 \exp(\text{sim}(F_{ds}, D[j])/\tau)} \right) \quad (4)$$

其中,  $G = [F_{dii}, F_{dis}]$ ,  $D = [F_{dsi}, F_{dss}]$ 。 $\tau$  是一个超参数。在实验中,  $\tau$  设为 1.0。通过优化  $L_{cd}$ , 有利于扩大  $F_{dii}$  与  $F_{dis}$  之间、 $F_{dsi}$  与  $F_{dss}$  之间、 $F_{di}$  与  $F_{ds}$  之间的差距。同时, 这种损失有利于促进  $F_{di}$  和  $F_{ds}$  提取出领域不变特征和域特征, 从而提高解纠缠能力。

### 2.3 自蒸馏结构

其次, 为了进一步增强泛化能力, 使用自蒸馏来提炼当前检测器的知识。具体就是将解耦后的 DIR 作为教师表示。通过缩小特征映射与骨干网中间层生成的特征映射之间的差异, 可以促进特征映射包含更多的域不变信息, 有利于提高泛化能力和检测性能。在实验中, 该方法在城市场景目标检测中得到了验证。在不同天气条件的场景中进行的实验证明了该方法的优越性。

$$L_{sd} = \text{dist}(\Phi(F_t), F_{di}) \quad (5)$$

其中,  $\text{dist}(\cdot, \cdot)$  表示距离函数, 如 L2 范数。通过缩小距离, 教师表征  $F_{di}$  可以引导骨干网络提取的表征学习域不变信息, 增强了目标检测器的泛化能力。

在整个训练过程中, 联合训练损失定义为:

$$L = L_{\text{box}} + L_{\text{obj}} + L_{\text{cls}} + \lambda (L_{cd} + L_{sd}) \quad (6)$$

式中,  $L_{\text{box}}$ ,  $L_{\text{obj}}$ ,  $L_{\text{cls}}$  分别为 YOLO 中的损失函数, 用来计算边定位损失 (预测框与标定框之间的误差 (GIoU))、置信度损失 (网络的置信度)、分类损失。 $\lambda$  为超参数, 在实验中设置为 0.01。在下一步的目标检测推理过程中, 将最终获得的域不变特征作为检测对象, 实现最终的目标检测任务。

## 3 实验结果与分析

### 3.1 数据集与数据预处理

为了验证方法的有效性, 实验中所用的数据集主要来自 Cityscape Dataset, 图像是拍摄的城市街道的场景, 有汽车行人等, 比较适合交通的目标检测训练。另外, 还有不同天气下的场景, 主要是较为常见的雾天、雨天。实验所用数据集可以验证模型泛化能力, 符合实验需求。有效的训练图片为 2 000 张雾天图片、1 000 张雨天图片, 按照 7 : 2 : 1 的比例划分训练集、测试集与验证集。

### 3.2 实验配置与模型训练

实验运行环境: 系统镜像为 Windows10 cuda11, GPU 为 GeForce RTX 3060, 显存为 12G。参数: Mini-

batch 为 16, 迭代次数为 400, 初始学习率为 0.001。

基于上述实验运行环境和模型参数, 对比分析了 YOLO 模型与添加域不变特征提取器以及自蒸馏结构的改进 YOLO 模型在雨、雾天的目标检测效果, 如图 4、图 5 所示。图中第一行为 YOLO 模型的检测效果, 第二行是改进后的模型检测效果图, 由图可知: 改进后的 YOLO 模型在特殊天气下的目标检测效果优于 YOLO 模型。



图4 雨天与基础 YOLO 模型的检测效果对比



图5 雾天与基础 YOLO 模型的检测效果对比

### 3.3 与主流目标检测方法对比分析

为了更全面地评估模型的有效性, 结合相关领域的基线方法: YOLOv51, 图像去模糊方法: GridDehaze, 域适应方法: DAYOLO 和改进后的模型进行性能评估比较。以 mAP 作为模型精度的评价指标, 分别比较不同分类下的 mAP 及全部分类的 mAP 均值。在同等实验条件下, 且天气条件为雾天、雨天的验证集上进行对比实验。由表 1、表 2 可知, 改进后的 YOLO 模型在各分类上的 mAP 指标普遍高于其他模型, 且全部分类的 mAP 均值都高于其他模型。另外, 在检测速度方面, 用 FPS 指标进行评估, 在表中可以看出, 其他相关算法虽然提高了检测精度, 但是因为加入了图像的前处理过程, 检测速度明显降低。而该文提出的方法在精度提升的基础上也满足了速度的要求。

### 3.4 消融实验

使用在雾天场景上训练的模型进行消融实验, 结果见表 3。

表 1 雾天不同模型的检测效果对比

方法		bus	bike	car	motor	person	rider	truck	mAP/%	FPS/s
Baseline	YOLOv5l	30.5	25.1	47.2	25.2	28.2	35.1	22.4	30.5	<b>65.4</b>
Dehaze	GridDehaze	35.2	32.2	<b>55.6</b>	32.5	32.7	40.2	30.2	36.9	41.2
DA	DAYOLO	32.4	34.1	51.2	27.0	32.7	38.8	32.2	35.5	60.2
Ours	Proposed	<b>35.8</b>	<b>35.6</b>	53.4	<b>34.5</b>	<b>34.5</b>	<b>42.6</b>	<b>34.1</b>	<b>38.6</b>	64.1

表 2 雨天不同模型的检测效果对比

方法		bus	bike	car	motor	person	rider	truck	mAP/%	FPS/s
Baseline	YOLOv5l	33.8	15.8	48.2	22.8	18.9	21.4	37.5	28.3	<b>63.2</b>
Dehaze	GridDehaze	36.5	16.7	50.3	23.0	21.1	22.6	40.2	30.1	40.3
DA	DAYOLO	35.8	17.9	49.5	23.5	<b>22.6</b>	23.4	39.5	30.3	58.2
Ours	Proposed	<b>37.1</b>	<b>21.2</b>	<b>51.9</b>	<b>24.2</b>	22.4	<b>26.9</b>	<b>40.8</b>	<b>32.0</b>	62.5

表 3 使用不同改进策略的 YOLO 检测效果对比

组别	方法	mAP/%
1	DT	30.8
2	Cyc-DT	31.7
3	SD	31.5
4	DT、SD	32.3
5	Cyc-DT、SD	33.1

从表中数据可以看出,仅使用一步前向特征提取时解纠缠的性能非常弱。这表明当没有可用的域相关注释时,只使用一步前向提取操作不能较好地提取出域不变特征。同时,仅使用自蒸馏模块能获得比 YOLO 更好的检测结果。这表明在自蒸馏中,采用域不变特征作为教师表示有利于提高目标检测器的泛化能力。最后,在仅仅使用循环解纠缠模块的情况下提高了检测性能,这表明使用循环操作和对比损失确实有助于提取域不变特征。其次,借助自蒸馏机制,进一步增强模型的泛化能力,两者结合从而提高模型的整体性能。

#### 4 结束语

针对在特殊天气下图像模糊、特征无法辨识,常规的目标检测方法的检测性能不佳的问题,该文提出了一种新的目标检测模型,旨在将目标检测器在一个源域推广到多个未训练过的目标域。针对这个单域泛化检测模型,重点参照了不依赖域相关注释的 DIR 提取方法,加入了一种循环解纠缠的自蒸馏方法。首先,使用了一个循环解纠缠模块来获取域不变特征 DIR。然后,以 DIR 作为教师表示,利用自蒸馏模块进一步增强目标检测器的泛化能力。实验结果和可视化分析都表明了该方法的优越性。

其实造成检测效果变差的主要原因是天气条件使得图像退化,所以如何把各种常见天气条件作为先验知识引入到整个模型中需要进一步研究。为此,接下来的研究工作中需考虑如何利用知识图谱等技术将天

气条件等隐性知识融入到模型之中,使模型具备自动知识学习和知识推理的能力。

#### 参考文献:

- [1] KRIZHEVSKY A, SUTSKEVER I, GEOFFREY E H. Image net classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [2] KRVIOLA P, JONES M. Rapid object detection using a boosted cascade of simple features [C]//Proceedings of the 2001 IEEE computer society conference on computer vision and pattern recognition. Kauai; IEEE, 2001: 511-518.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Columbus; IEEE, 2014: 580-587.
- [4] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas; IEEE, 2016: 779-788.
- [5] GIRSHICK R. Fast R-CNN [C]//Proceedings of the IEEE international conference on computer vision. Washington; IEEE, 2015: 1440-1448.
- [6] FURSA I, FANDI E, MUSAT V, et al. Worsening perception; real-time degradation of autonomous vehicle perception performance for simulation of adverse weather conditions [J]. arXiv: 2103.02760, 2021.
- [7] AHMED M M, YANG G, GAWEESH S. Assessment of drivers' perceptions of connected vehicle - human machine interface for driving under adverse weather conditions: preliminary findings from Wyoming [J]. Frontiers in Psychology, 2020, 11: 1889.
- [8] 丁雨蕾. 重特大交通事故特征及影响因素分析 [D]. 南京: 东南大学, 2016.
- [9] 陈飞, 刘云鹏, 李思远. 复杂环境下的交通标志检测与识别方法综述 [J]. 计算机工程与应用, 2021, 57(16): 65-

- 73.
- [10] 董天天,曹海啸,阚希,等.复杂天气下交通场景多目标识别方法研究[J].信息通信,2020(11):72-74.
- [11] 林猛,周刚,杨亚伟,等.特殊天气条件下的目标检测方法综述[J].计算机工程与应用,2022,58(13):36-47.
- [12] CHEN Y, LI W, SAKARIDIS C, et al. Domain adaptive faster r-cnn for object detection in the wild[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City:IEEE,2018:3339-3348.
- [13] SAITO K, USHIKU Y, HARADA T, et al. Strong-weak distribution alignment for adaptive object detection[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach:IEEE,2019:6956-6965.
- [14] CHEN C, ZHENG Z, HUANG Y, et al. I3net: implicit instance-invariant network for adapting one-stage object detectors[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Nashville:IEEE,2021:12576-12585.
- [15] DENG J, LI W, CHEN Y, et al. Unbiased mean teacher for cross-domain object detection[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Nashville:IEEE,2021:4091-4101.
- [16] SHEN Z, MAHESHWARI H, YAO W, et al. Scl: towards accurate domain adaptive object detection via gradient detach based stacked complementary losses[J]. arXiv:1911.02559, 2019.
- [17] XU C D, ZHAO X R, JIN X, et al. Exploring categorical regularization for domain adaptive object detection[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle:IEEE,2020:11724-11733.
- [18] LI W, LI F, LUO Y, et al. Deep domain adaptive object detection: a survey[C]//2020 IEEE symposium series on computational intelligence (SSCI). Canberra:IEEE,2020:1808-1813.
- [19] OZA P, SINDAGI V A, SHARMINI V V, et al. Unsupervised domain adaptation of object detectors: a survey[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2023(1):1-24.
- [20] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//International conference on machine learning. Lille:PMLR,2015:1180-1189.
- [21] CHEN C, ZHENG Z, DING X, et al. Harmonizing transferability and discriminability for adapting object detectors[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle:IEEE,2020:8869-8878.
- [22] LI D, ZHANG J, YANG Y, et al. Episodic training for domain generalization[C]//Proceedings of the IEEE/CVF international conference on computer vision. Long Beach:IEEE,2019:1446-1455.
- [23] LI H, PAN S J, WANG S, et al. Domain generalization with adversarial feature learning[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City:IEEE,2018:5400-5409.
- [24] WANG J, LAN C, LIU C, et al. Generalizing to unseen domains: a survey on domain generalization[J]. IEEE Transactions on Knowledge and Data Engineering,2023,35(8):8052-8072.
- [25] WANG X, CAI Z, GAO D, et al. Towards universal object detection by domain attention[C]//Proceedings of the IEEE/CVF international conference on computer vision. Long Beach:IEEE,2019:7289-7298.
- [26] ZHAO S, GONG M, LIU T, et al. Domain generalization via entropy regularization[J]. Advances in Neural Information Processing Systems,2020,33:16096-16107.
- [27] VOLPI R, NAMKOONG H, SENER O, et al. Generalizing to unseen domains via adversarial data augmentation[J]. arXiv:1805.12018,2018.
- [28] QIAO F, ZHAO L, PENG X. Learning to learn single domain generalization[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle:IEEE,2020:12556-12565.
- [29] KIM K, JI B M, YOON D, et al. Self-knowledge distillation: a simple way for better generalization[J]. arXiv:2006.12000,2020.
- [30] XU T B, LIU C L. Data-distortion guided self-distillation for deep neural networks[C]//Proceedings of the AAAI conference on artificial intelligence. Honolulu:AAAI,2019:5565-5572.
- [31] YUN S, PARK J, LEE K, et al. Regularizing class-wise predictions via self-knowledge distillation[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle:IEEE,2020:13876-13885.
- [32] CHEN X, WANG S, LONG M, et al. Transferability vs. discriminability: batch spectral penalization for adversarial domain adaptation[C]//International conference on machine learning. New Long Beach:PMLR,2019:1081-1090.
- [33] HE Z, ZHANG L. Multi-adversarial faster-rcnn for unrestricted object detection[C]//Proceedings of the IEEE/CVF international conference on computer vision. Long Beach:IEEE,2019:6668-6677.
- [34] PENG X, HUANG Z, SUN X, et al. Domain agnostic learning with disentangled representations[C]//International conference on machine learning. Long Beach:PMLR,2019:5102-5112.
- [35] WU A, HAN Y, ZHU L, et al. Instance-invariant domain adaptive object detection via progressive disentanglement[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2021,44(8):4178-4193.