

# Exploring Implicit Domain-Invariant Features for Domain Adaptive Object Detection

---

汇报人：程志鹏 刘爽 赖华宇

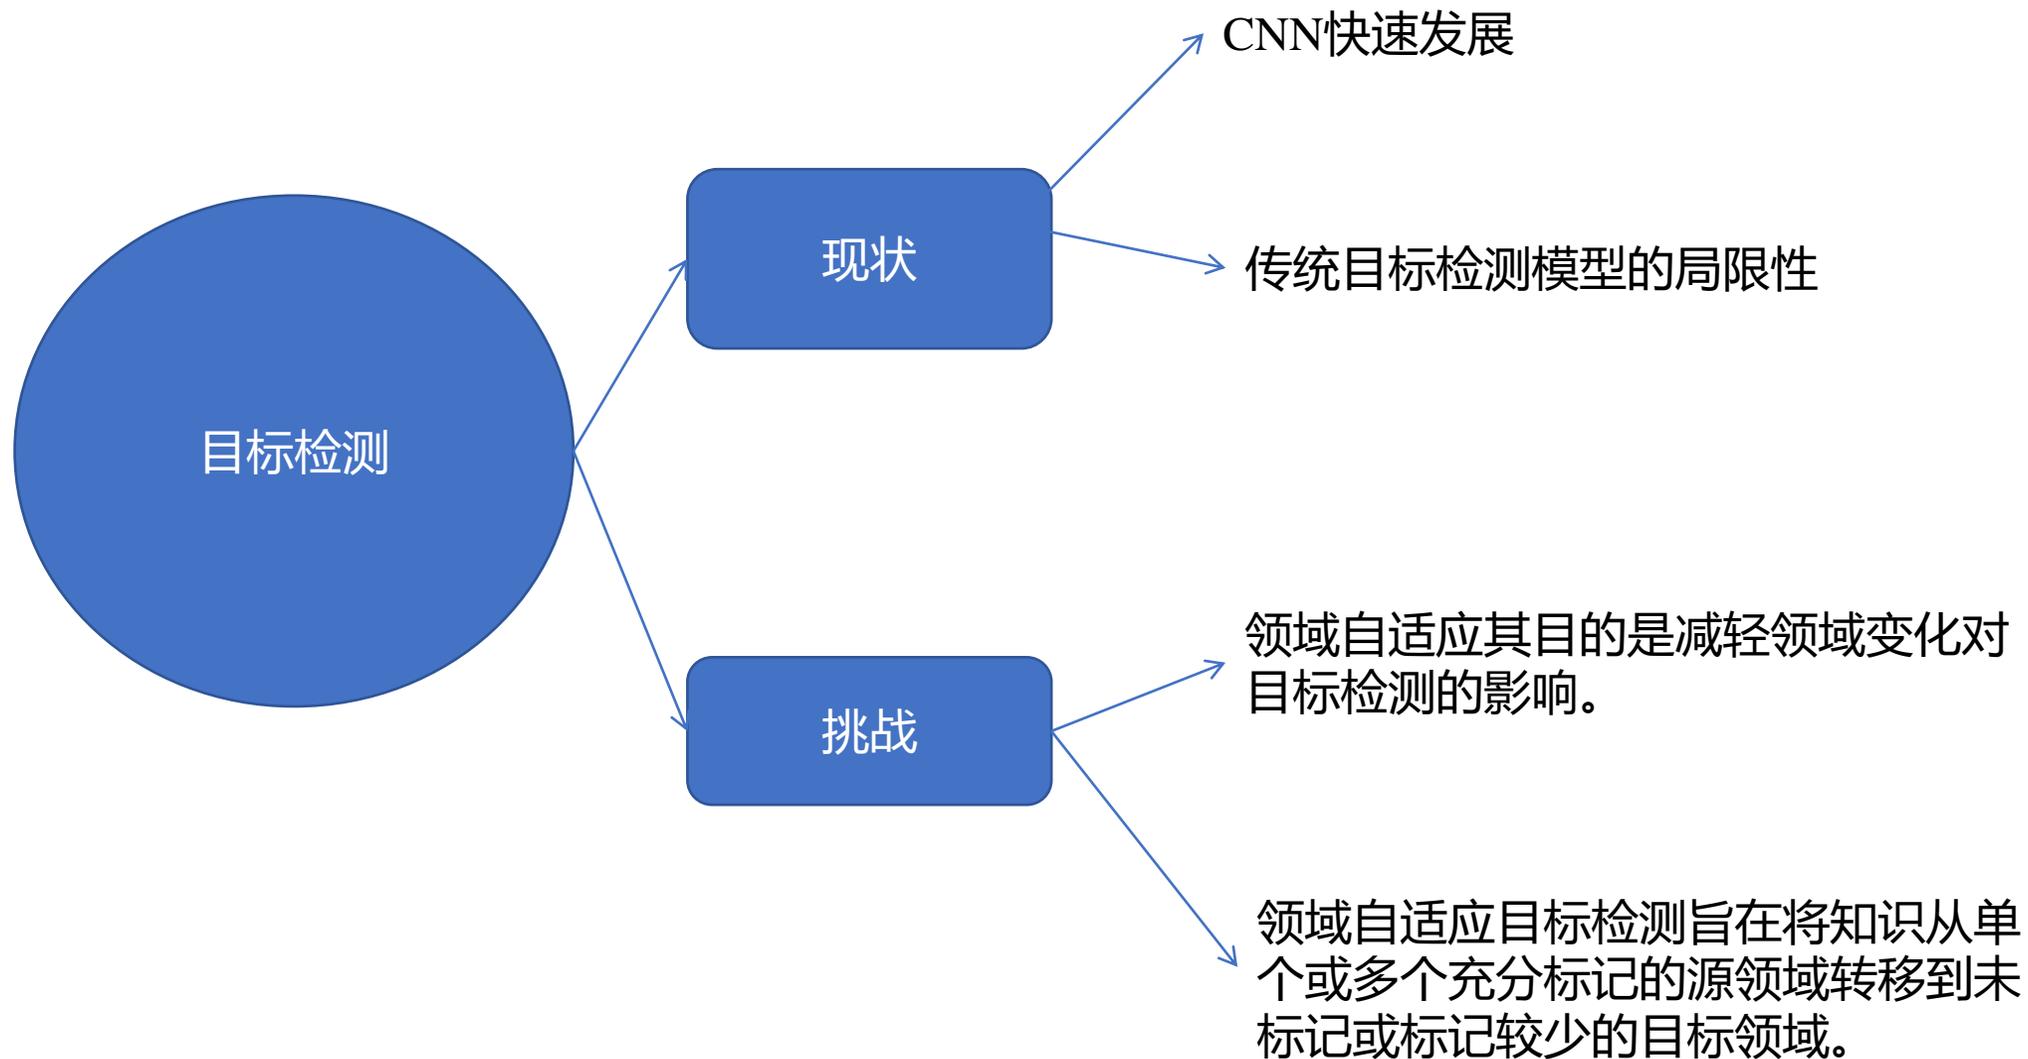


重慶大學  
CHONGQING UNIVERSITY

01

## 背景介绍

# 目标检测简介及领域转移挑战



# 现有自适应检测器存在的问题

## 忽略隐式的领域不变特征

目前的检测器仅关注学习显式的领域不变特征，而忽略了包含在领域特定特征中的信息知识，即隐式的领域不变特征。

## 无法有效利用领域特定特征

这些检测器忽视了领域特定特征仍然包含信息丰富、具有判别性和领域不变的对象特征的事实，从而无法有效利用这些特征。

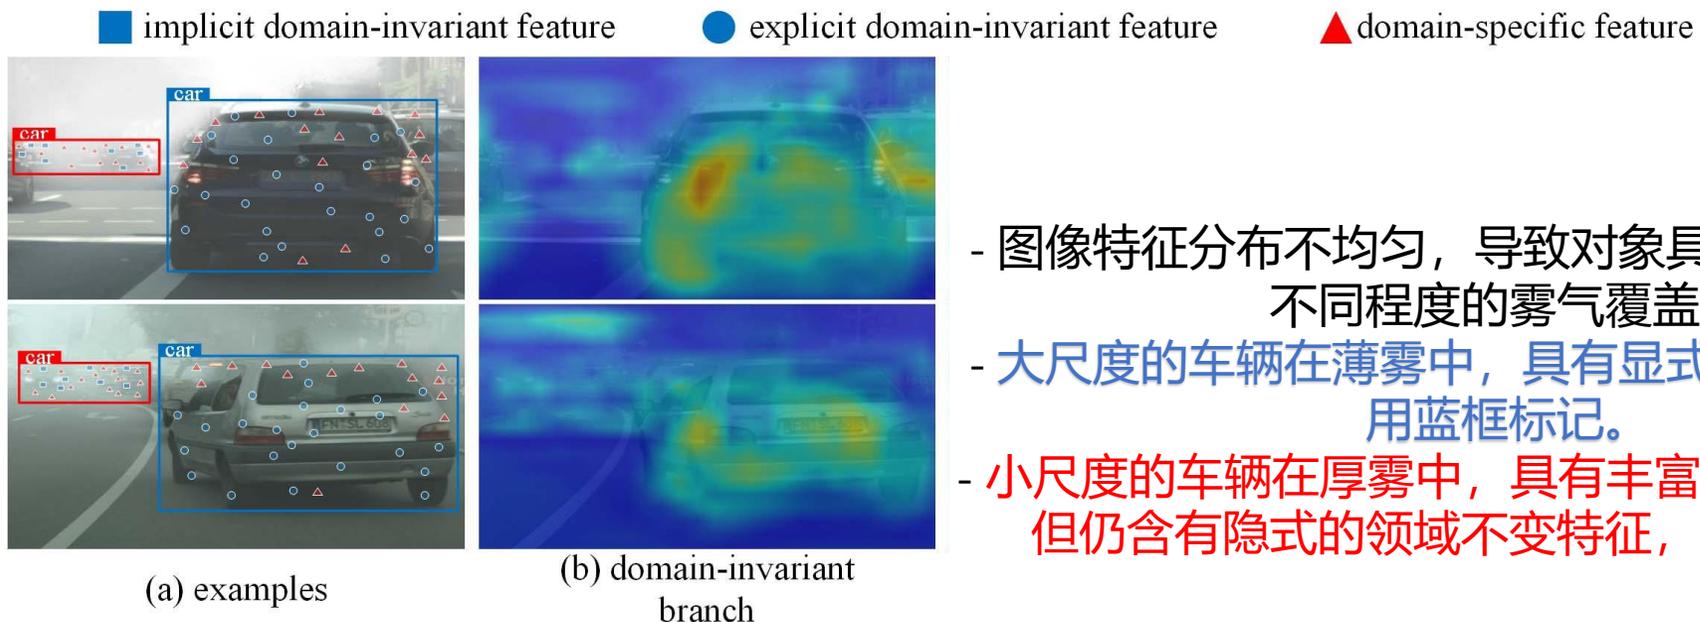
## 多模式结构导致问题

目标分布底层的多模式结构特征具有不同的尺度和类别，这导致了检测器无法充分利用这些特征进行跨域检测

## 对难样本的忽视

先前的方法可能会将具有丰富领域特定特征的对象视为背景，而忽视了这些对象中隐式的领域不变特征，从而限制了跨域检测的性能。

# 现有自适应检测器存在的问题



- 图像特征分布不均匀，导致对象具有不同尺度和被不同程度的雾气覆盖。
- 大尺度的车辆在薄雾中，具有显式领域不变特征，用蓝框标记。
- 小尺度的车辆在厚雾中，具有丰富的领域特定特征，但仍含有隐式的领域不变特征，用红框标记。

以往的方法可能会将红框标记的对象作为背景，因为其具有丰富的域特异性

显然忽略了红框内对象(即硬样本)的隐式域不变特征，如图1 (b)所示。如果不探索这些可转移性低的硬对象样本，跨域检测性能自然会受到限制。

# IDF算法应用的可行性

隐式领域不变 Faster R-CNN (Implicit Domain-invariant Faster R-CNN)

01

## 双分支架构

IDF采用了两个分支的改进架构，即领域不变分支和领域特定分支。这种双分支结构有助于同时学习领域不变特征和领域特定特征。

02

## 领域不变分支

该分支旨在学习领域不变特征，通过对抗训练和梯度反转层（GRL）等技术来减轻不同域之间的分布差异，从而实现跨域泛化能力的提升。

03

## 领域特定分支

该分支专注于学习领域特定的特征，并通过非对抗领域判别器（NADD）来区分源域和目标域，以更好地适应目标域的特征分布。

04

## 选择性特征感知 (SFP) 损失

IDF引入了SFP损失，通过感知性和选择性地关闭一些特征，将领域特定分支学到的有用信息传递给领域不变分支，以提取隐式领域不变信息。

05

## 双注意力模块 (DAM)

DAM设计用于从领域特定分支的特征中提取有用的隐式领域不变信息，并滤除背景噪声或领域特定知识等无用信息。同时，DAM通过直接加权领域不变分支的特征空间，帮助该分支关注具有信息量的困难样本，从而提高了模型的鲁棒性。

这是一种用于解决目标检测领域自适应问题的方法。

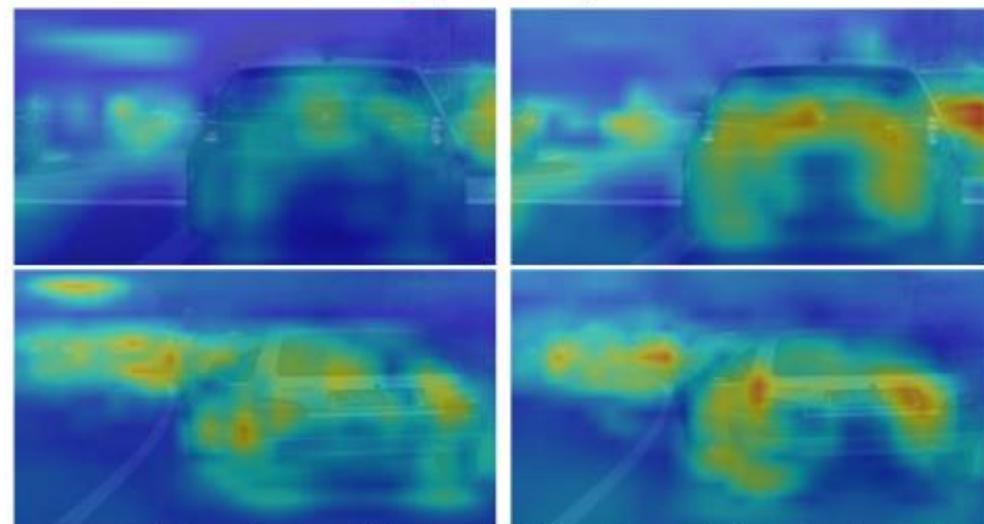
# IDF算法中的关键组成部分和创新点

■ implicit domain-invariant feature

● explicit domain-invariant feature

▲ domain-specific feature

SFP  $\text{Loss}_{\text{DAM}}$ 通过直接对域不变分支的特征空间进行加权，帮助域不变分支注意到信息丰富的硬样本，如图1 (d)所示。此外，DAM还可以增强域特定分支。



(c) domain-specific branch

(d) enhanced domain-invariant branch

**SFP Loss目标：**将特定领域分支学到的信息传递给领域不变分支。

**DAM：**从特定领域分支的特征中提取有用的信息，并滤除无信息的背景噪声或特定领域知识。

02

## THEORETICAL INSIGHTS

## THEORETICAL INSIGHTS

输入图像的不同分布会引起域差异，这会导致分类器或检测器的性能降低。迁移学习的目的就是为了降低域差异。目前被广泛运用的域适应方法是Ben-David等人提出的领域自适应理论（理论1），其描述如下：

设 $\mathcal{H}$ 为假设模型，给定两个不同分布的域（源域 $\mathcal{D}_s$ 和目标域 $\mathcal{D}_t$ ） $\epsilon_s(h)$ ,  $\epsilon_t(h)$ 分别为假设 $h \in \mathcal{H}$ 在两个域上的泛化误差，基于此有：

$$\epsilon_t(h) \leq \epsilon_s(h) + d_{\mathcal{H}\Delta\mathcal{H}}(\mathcal{D}_s, \mathcal{D}_t) + \lambda \quad (1)$$

其中 $d_{\mathcal{H}\Delta\mathcal{H}}(\mathcal{D}_s, \mathcal{D}_t)$ 是两个域之间的离散度。 $\lambda$ 是模型拟合过程中的方差定义 $h^* = \arg \min_{h \in \mathcal{H}} (\epsilon_s(h) + \epsilon_t(h))$ . 那么可以得到

$$\lambda = \epsilon_s(h^*) + \epsilon_t(h^*) \quad (2)$$

## THEORETICAL INSIGHTS

随着域差异的增大，两个域之间的离散度  $d_{\mathcal{H}\Delta\mathcal{H}}(\mathcal{D}_s, \mathcal{D}_t)$  也会增大，这将使模型在目标域中的性能不可避免的降低，为了解决这一问题本文采用A-distance来解决。

A-distance理论：

对于输出的样本  $x$ ，域分辨器  $D$  输出一个分数  $d$  (0-1)，预测源样本为1，目的样本为0，使鉴别器  $D$  尽可能区分源样本和目的样本，然后跨域的距离可以表示为：

$$d_{\mathcal{A}}(\mathcal{D}_s, \mathcal{D}_t) = 2(1 - 2 \min_D \text{err}(d(x))) \quad (3)$$

其中  $\text{err}(d(x))$  是鉴别器  $D$  的预测误差， $\min_D \text{err}(d(x))$  是它的最小预测误差，由上式可知 A-distance 的距离越小，预测误差越大。

## THEORETICAL INSIGHTS

为了将A-distance最自然地最小化，设G是用于提取特征表示的特征生成器网络，为了学习域对齐的特征表示（即域不变特征），使A-distance最小化，有

$$\begin{aligned} \min_G d_{\mathcal{A}}(\mathcal{D}_s, \mathcal{D}_t) &\propto \min_G 2(1 - 2 \min_D \text{err}(d(x))) \\ &\propto \max_G \min_D \text{err}(d(x)) \end{aligned} \quad (4)$$

使用梯度翻转层(GRL)将误差反转向后传递，特征生成器G和域鉴别器D之间的对抗性学习来解决，从而实现域对齐。

现有的域自适应对象检测器学习域不变特征，通过求解等式来降低定理1中的  $d_{\mathcal{H}\Delta\mathcal{H}}(\mathcal{D}_s, \mathcal{D}_t)$  有利于完全对齐和检测。

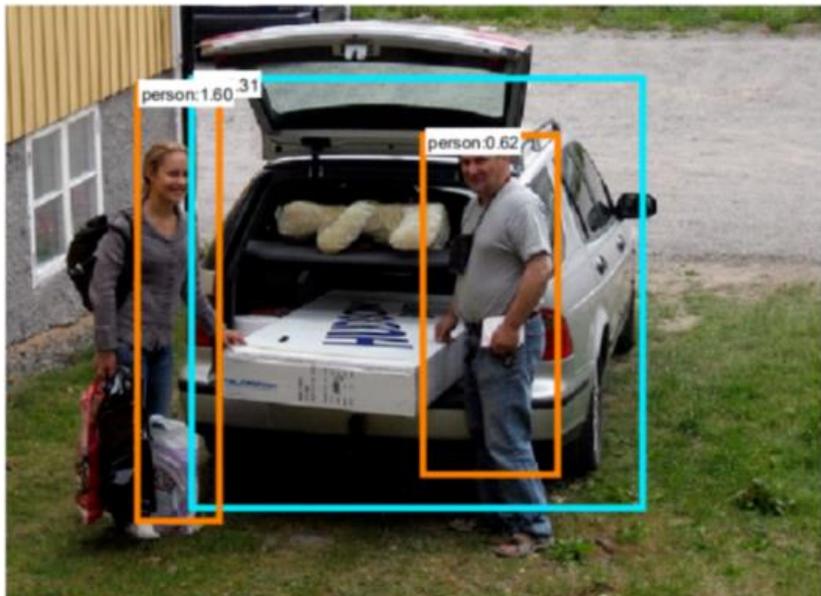
03

## RELATED WORK

## RELATED WORK

### 1. 目标检测

卷积神经网络（CNN）被运用在目标检测领域并取得了巨大的突破，根据训练过程，目标检测算法可大致分为两种类型：一级检测器和二级检测器。



计算效率较高，因为它不需要区域建议网络（RPN）来产生大量的区域建议网络。可以实现实时的目标检测

一级检测器

具有高精度的特点，由于它的可伸缩性，大多数领域自适应对象检测器选择它作为主干。

二级检测器

## RELATED WORK

### 2. 领域自适应

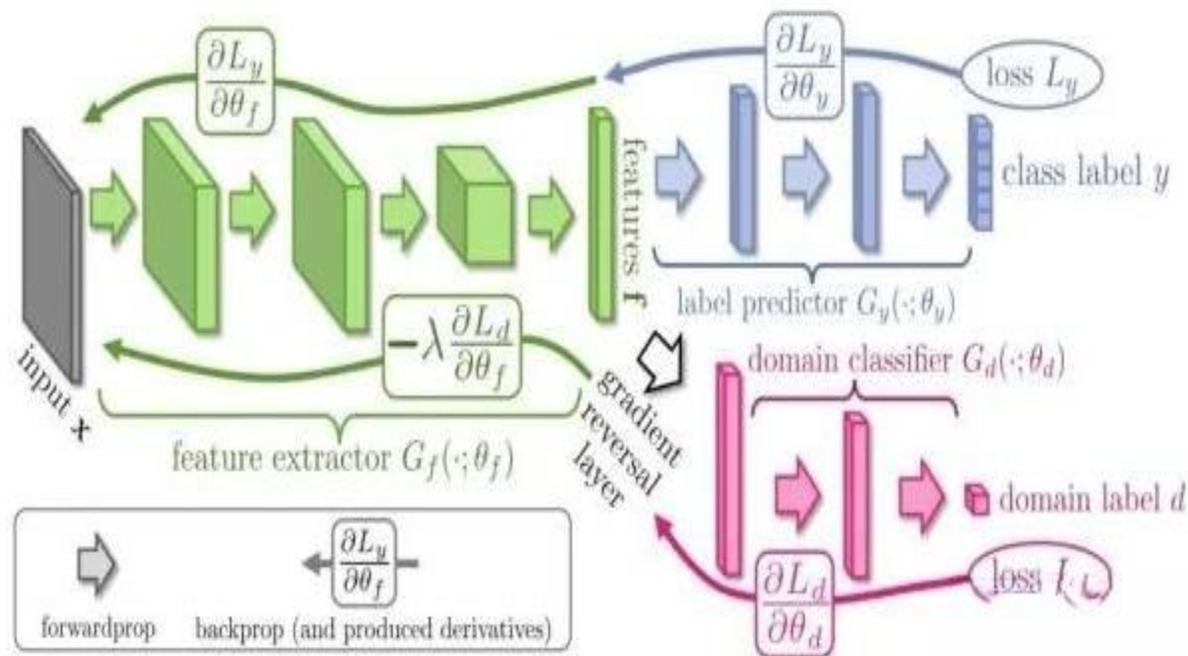
领域自适应是迁移学习中的一种代表性方法，思路是将不同领域（如两个不同的数据集）的数据特征映射到同一个特征空间，这样可利用其它领域数据来增强目标领域训练。领域自适应（Domain Adaptation）是迁移学习中的一种代表性方法，指的是利用信息丰富的源域样本来提升目标域模型的性能。它试图通过减少分布差异，将知识从单个或多个充分标记的源域转移到未标记的目标域。近年来被广泛运用在图像分类、目标检测、人再识别等领域。

为了解决这一问题，提出了一组不同域间的域自适应模型，如最大平均差异（MMD）、加权MMD和多核MMD。这一类方法是设计提取域不变的特征，以对齐域之间的特征分布。

# 探索域自适应对象检测的隐式域不变特征

## RELATED WORK

对抗性学习策略被应用于领域自适应，这是关于特征提取器和领域鉴别器之间的双人博弈，类似于GAN [14]。Ganin和兰皮茨基[11]提出了一个梯度反转层（GRL）来逆转梯度的反向传播，以实现对抗性的极大极小优化。这种方法是设计提取域不变的特征，以对齐域之间的特征分布。



## RELATED WORK

### 3. 域自适应对象检测

目前存在源域和目标域之间域移的问题，

Chen等人[5]首次提出了域自适应目标检测任务，分别采用图像级和实例级两种域分类器，通过学习域不变特征来减少域视差。

He和Zhang等人[46]提出了一种层次结构，该结构旨在在源域和目标域之间以不同的尺度对齐特征。

Kim等人[22]提出了一个通过学习多个领域间不变特征表示的模型，从多样性的角度解决领域适应问题。

然而，现有的领域自适应对象检测器只关注于提取显式的域不变特征，而忽略了领域特定的特征，其中仍然包含信息性和域不变的对象特征。与这些方法不同，我们提出的方法旨在探索隐式域不变特征，以实现更好的对齐和检测。

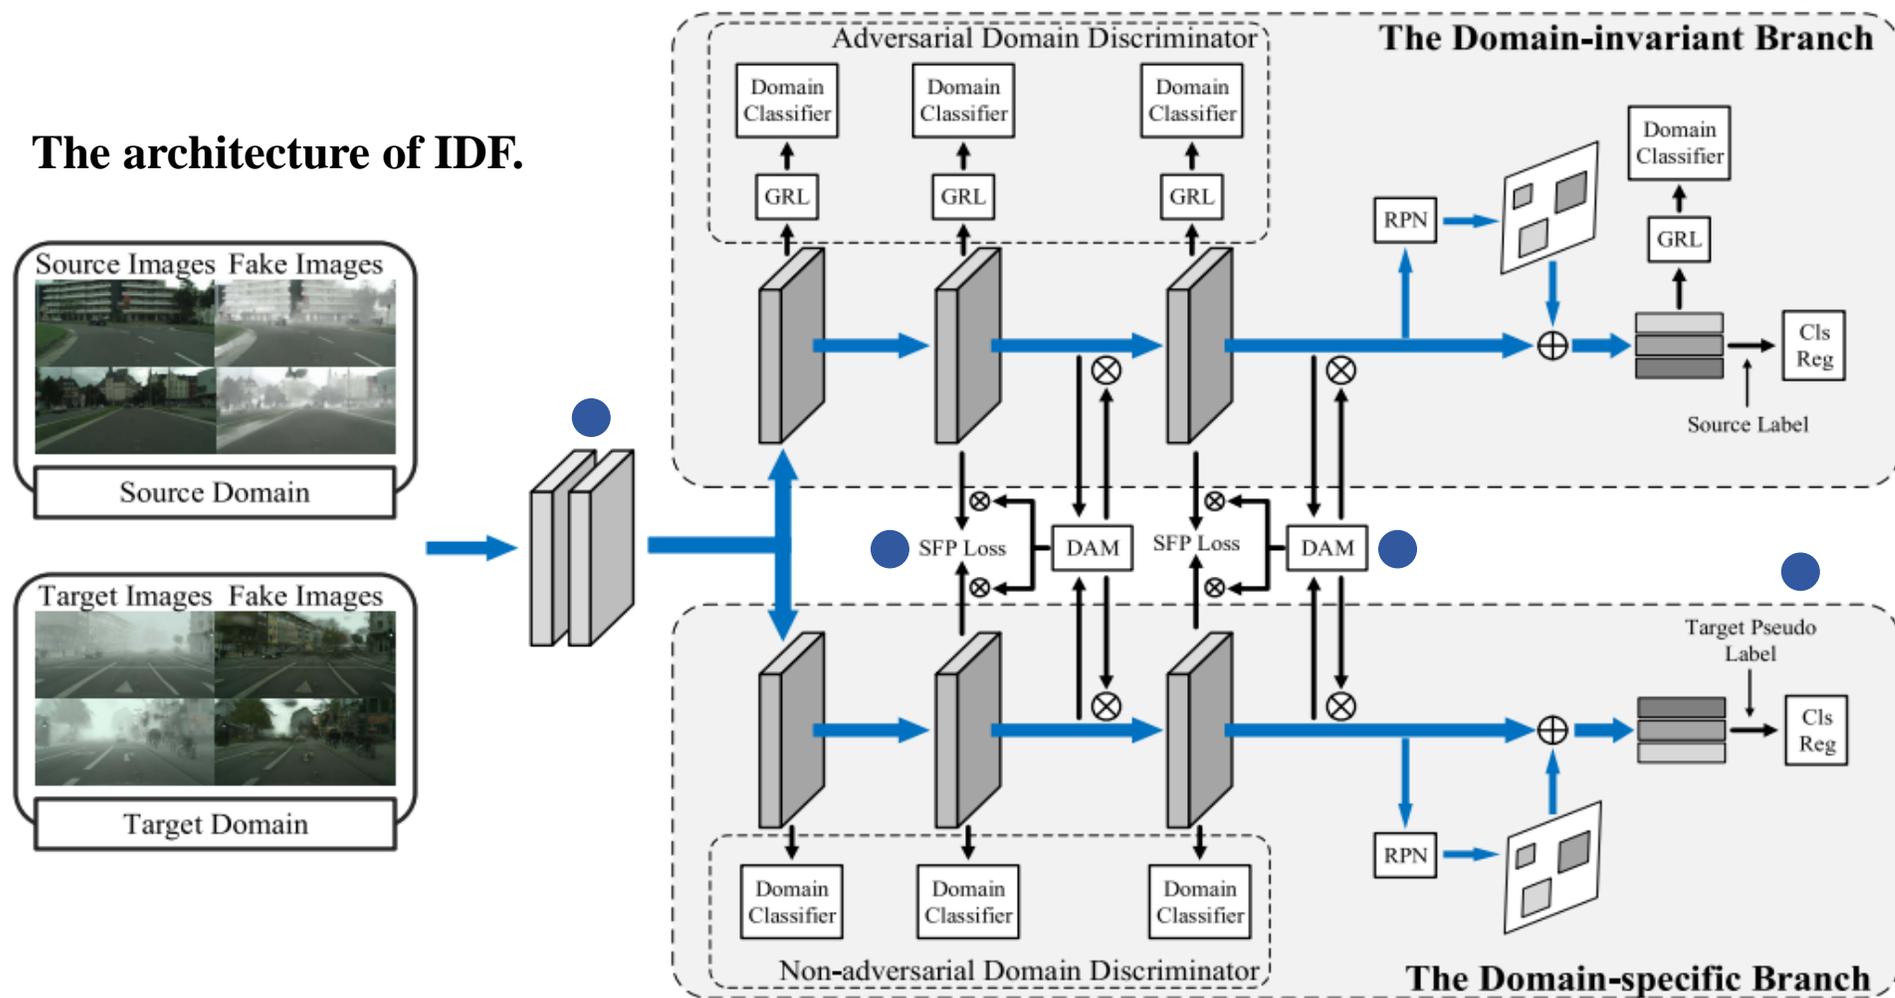
04

## THE PROPOSED IDF DETECTOR

# 探索域自适应对象检测的隐式域不变特征

## Implicit Domain-invariant Faster R-CNN (IDF) Detector.

### ➤ The architecture of IDF.



## R-CNN(Region with CNN Feature)

R-CNN在2014年横空出世，作者是目标检测领域的大神Ross Girshick，Ross Girshick也是其后序迭代版本Fast RCNN和Faster RCNN联名作者。是第一个成功将深度学习应用到目标检测上的算法。R-CNN基于卷积神经网络(CNN)，线性回归，和支持向量机(SVM)等算法，实现目标检测技术。

## Mainstream Domain Adaptive Detection Methods

- [4] C. Chen, Z. Zheng, X. Ding, Y. Huang, and Q. Dou, “Harmonizing transferability and discriminability for adapting object detectors,” in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2020, pp. 8869–8878.
- [5] Y. Chen, W. Li, C. Sakaridis, D. Dai, and L. Van Gool, “Domain adaptive faster R-CNN for object detection in the wild,” in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit., Jun. 2018, pp. 3339–3348.
- [33] D.-K. Nguyen, W.-L. Tseng, and H.-H. Shuai, “Domain-adaptive object detection via uncertainty-aware distribution alignment,” in Proc. 28th ACM Int. Conf. Multimedia, Oct. 2020, pp. 2499–2507.
- [46] Z. He and L. Zhang, “Multi-adversarial faster-RCNN for unrestricted object detection,” in Proc. IEEE/CVF Int. Conf. Comput. Vis. (ICCV), Oct. 2019, pp. 6668–6677.

## Source Domain

➤ The Fully Labeled Source Domain.

$$\mathcal{D}_s = \left\{ (x_i^s, b_i^s, y_i^s) \right\}_i^{n_s}$$

➤ The Unlabeled Target Domain

$$\mathcal{D}_t = \left\{ (x_i^s) \right\}_i^{n_t}$$

$x_i^s$  : 第i个图像

$y_i^s$  : 类别标签

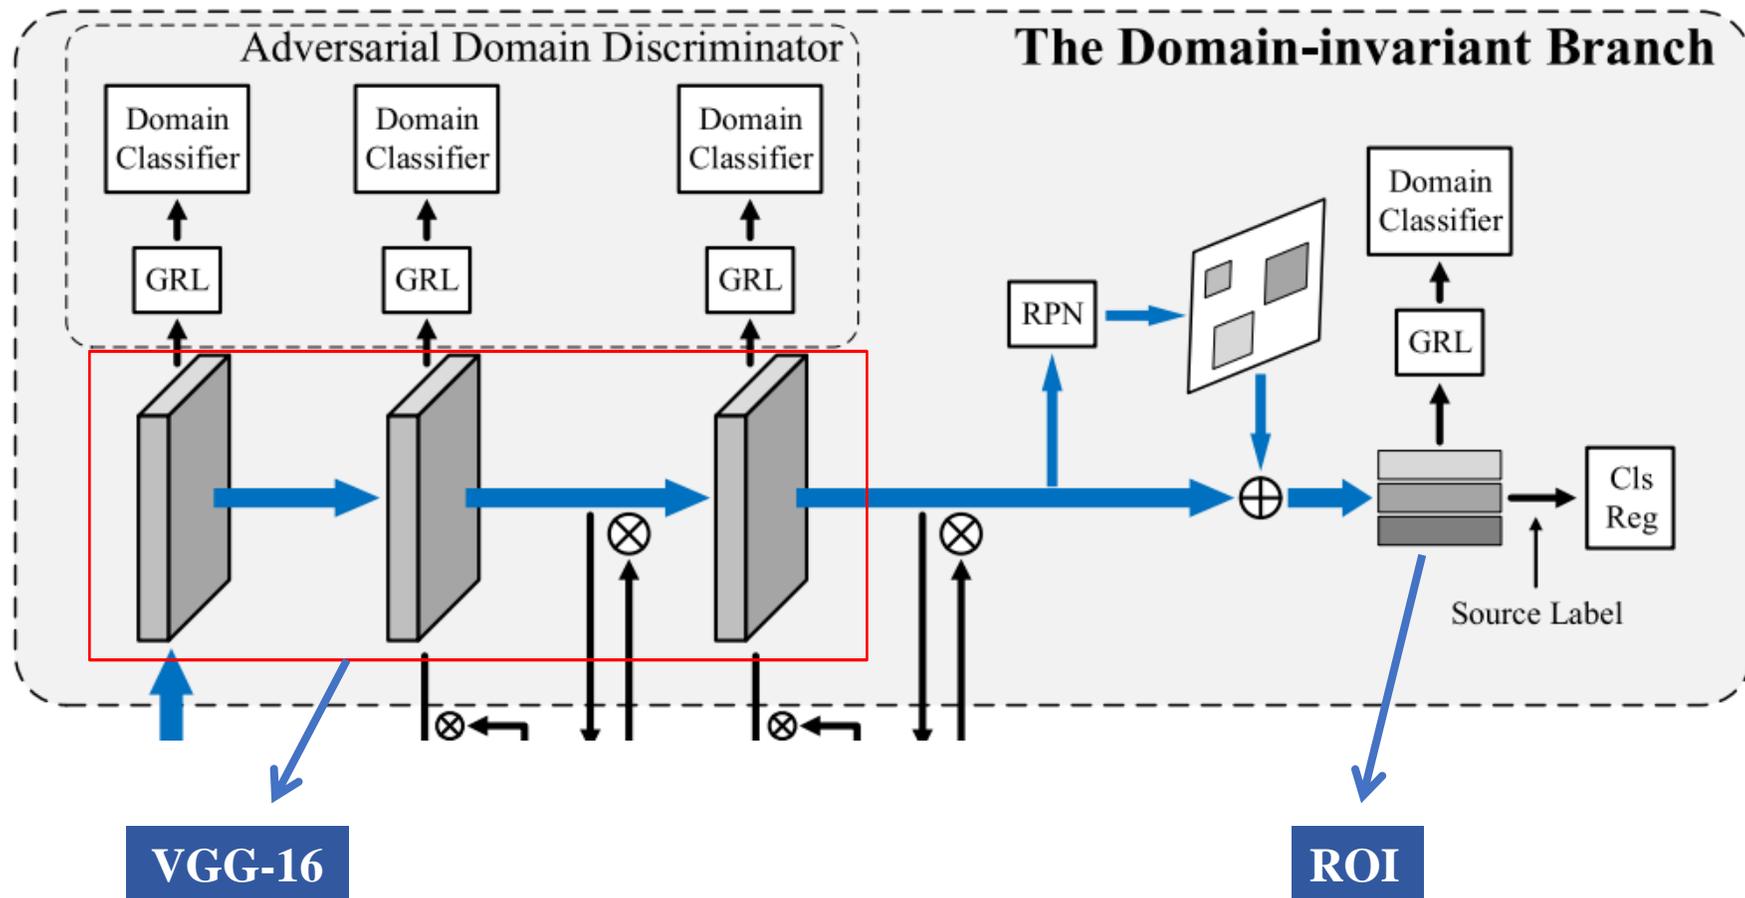
$b_i^s$  : 边界框的坐标位置标签

$n_s$  : 来自源域的样本数量

# 探索域自适应对象检测的隐式域不变特征

## The Domain-invariant Branch

### ➤ The Domain-invariant Branch.

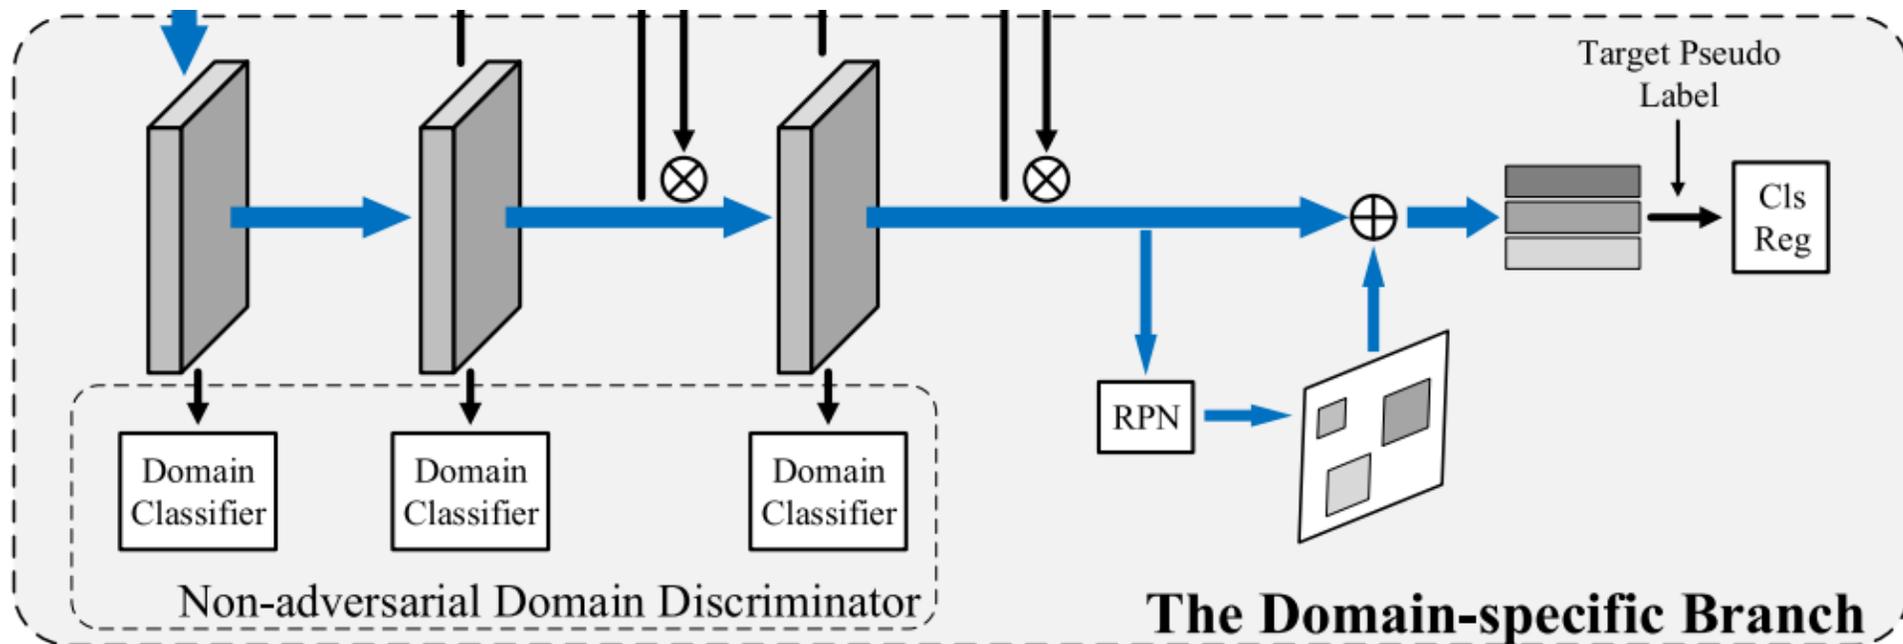


$$\mathcal{L}_{det} = \mathcal{L}_{rpn} + \mathcal{L}_{reg} + \mathcal{L}_{cls}$$

$$\mathcal{L}_{adv} = \sum_{m=3}^5 \mathcal{L}_m + \mathcal{L}_{ins}$$

## The Domain-specific Branch

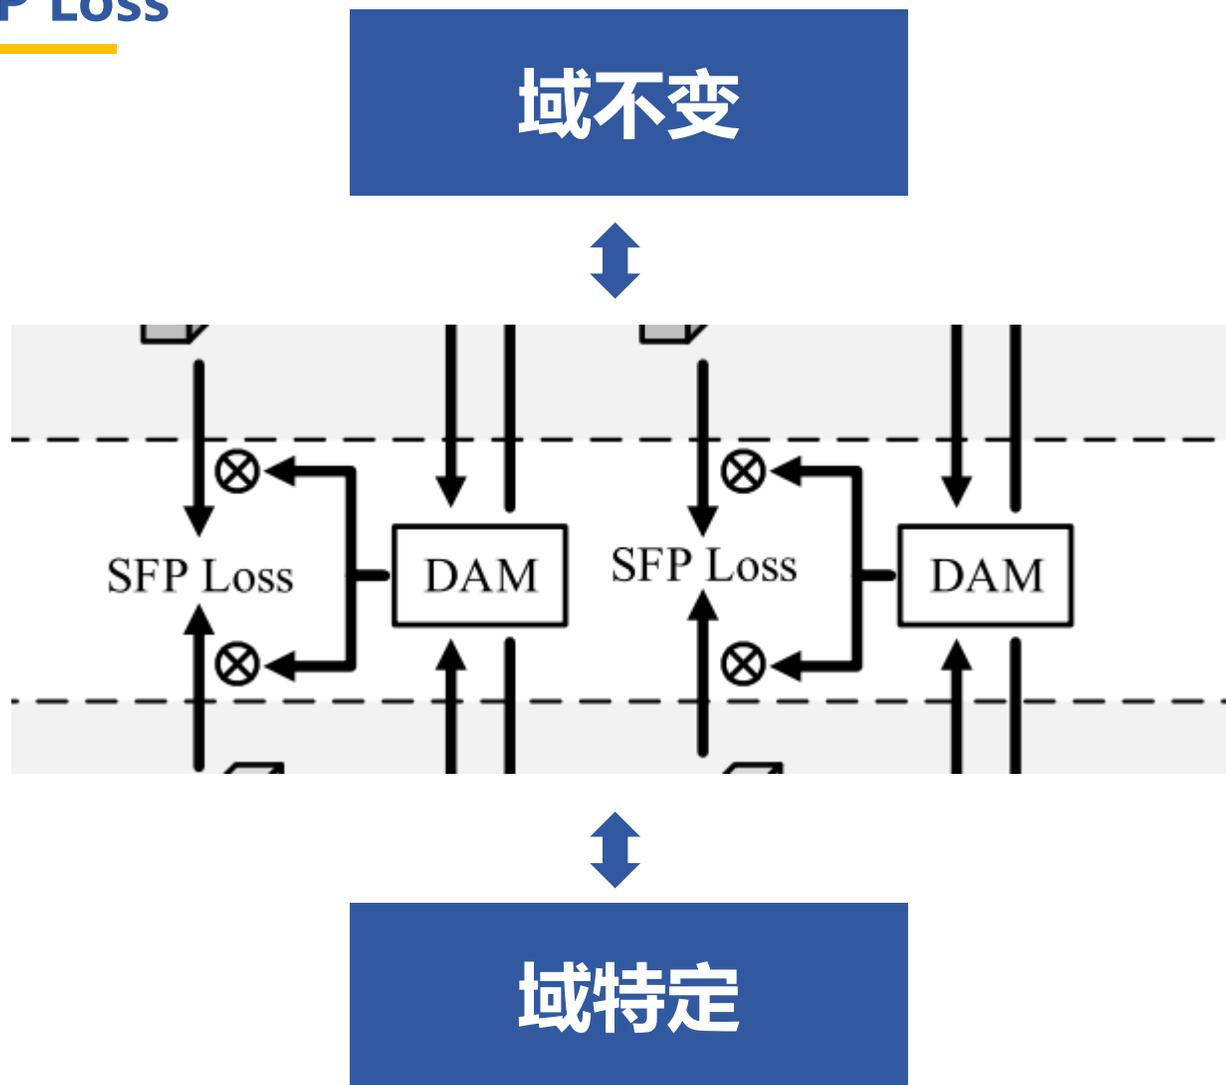
### ➤ The Domain-specific Branch.



$$\mathcal{L}_{nadd} = \sum_{n=3}^5 \mathcal{L}_n = \sum_{n=3}^5 L_c(D'_n(G'_n(x_i)), d_i)$$

# 探索域自适应对象检测的隐式域不变特征

## SFP Loss



域不变特征

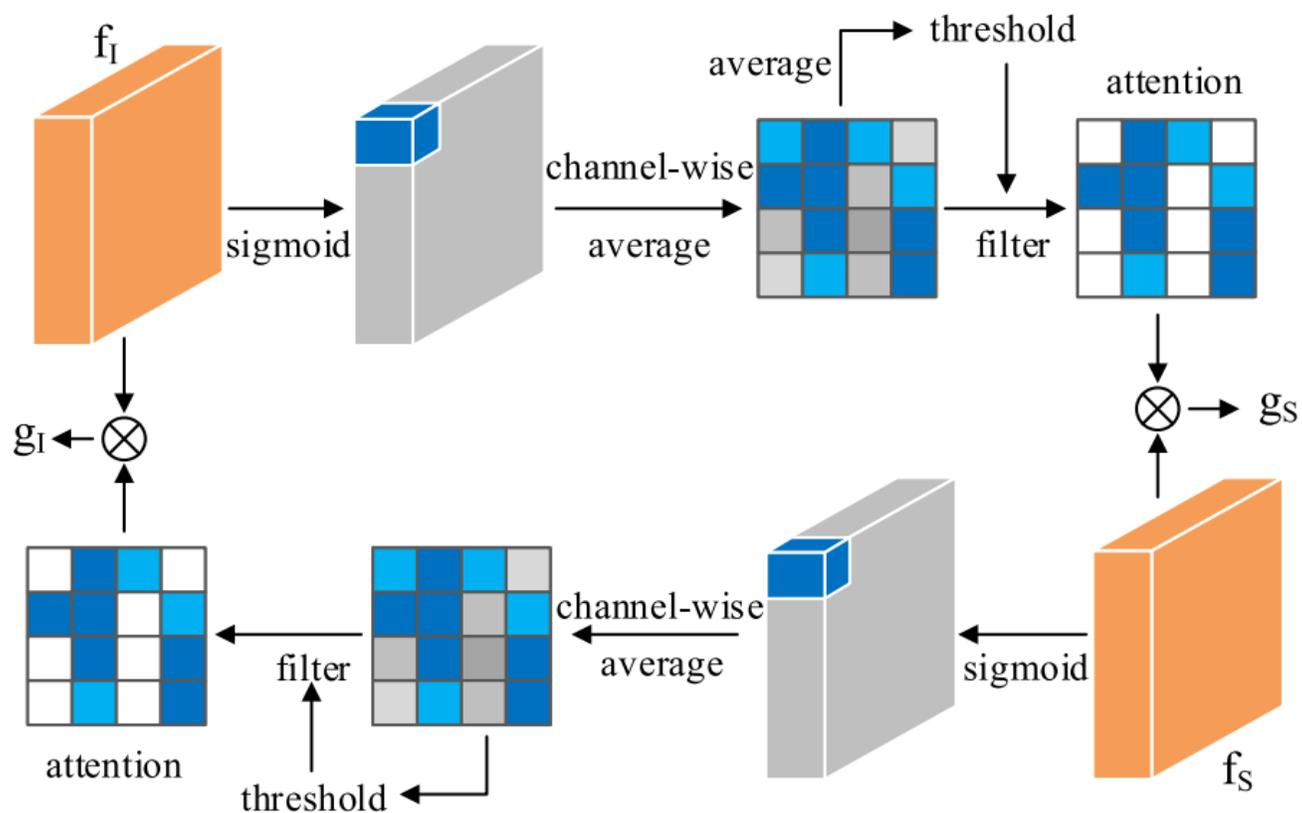
- 显式域不变特征 (易对齐样本)
- 隐式域不变特征 (难对齐样本)

$$\mathcal{L}_{sfp} = \alpha \sum_{n=4}^5 dist(f_I^n \times A, f_S^n \times A)$$

# 探索域自适应对象检测的隐式域不变特征

## DAM

### ➤ Structure of DAM module.



$$M_{S \rightarrow I}^n = \frac{1}{C} \sum_C \text{Sig}(f_S^n)$$

$$T_{S \rightarrow I}^n = \frac{1}{H \times W} \sum_{h,w} M_{S \rightarrow I}^n(h, w)$$

$$A_{S \rightarrow I}^n = \begin{cases} M_{S \rightarrow I}^n, & M_{S \rightarrow I}^n \geq T_{S \rightarrow I}^n \\ 0, & M_{S \rightarrow I}^n < T_{S \rightarrow I}^n \end{cases}$$

$$g_I = f_I \times (1 + A_{S \rightarrow I}^n)$$
$$g_S = f_S \times (1 + A_{I \rightarrow S}^n)$$

$$A = A_{S \rightarrow I}^n$$

## Pseudo Target Label

步骤一、  $D_s$   $\xrightarrow{\text{CycleGan}}$   $D_f(s \rightarrow t)$



步骤二、源域的可用标签将直接应用于类似目标的假图像 $D_f(s \rightarrow t)$ ，然后，通过使用 $D_f(s \rightarrow t)$ 和 $D_s$ 的真实标签来训练一个更快的R-CNN模型。



步骤三、采用步骤二中训练模型来预测每个真实目标图像的检测边界盒，并将检测结果作为伪目标标签

可靠性



置信阈值

$$\mathcal{L}'_{det} = \mathcal{L}'_{rpn} + \mathcal{L}'_{reg} + \mathcal{L}'_{cls}$$

05

# EXPERIMENTS

# 探索域自适应对象检测的隐式域不变特征

## 数据集选择



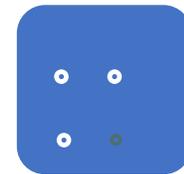
城市景观



SIM10k



雾蒙蒙城市景观



## 实现细节

### 模型

使用 Faster R-CNN 结合 VGG-16主干网

### 源域

有充足的标注数据（包含边界框和类别）

### 图像尺寸和批次

将输入图像的短边调整为 600 像素，每次迭代输入2张图像（源域图像或  $D f(s \rightarrow t)$  伪造图像 和 目标域图像或  $D f(t \rightarrow s)$  伪造图像）

### 预训练

在 ImageNet上预训练

### 目标域

有充足的标注数据（包含边界框和类别）

### 学习率及迭代次数

初始为 0.001，50k 次迭代后降至 0.0001  
总共 70k 次迭代

# 探索域自适应对象检测的隐式域不变特征

## 域自适应检测结果

Methods	Person	Rider	Car	Truck	Bus	Train	Motorcycle	Bicycle	mAP
Source Only [38]	24.1	33.1	34.3	4.1	22.3	3.0	15.3	26.5	20.3
DAF [5]	25.0	31.0	40.5	22.1	35.3	20.2	20.0	27.1	27.6
SCDA [54]	33.5	38.0	48.5	26.5	39.0	23.3	28.0	33.6	33.8
MAF [46]	28.2	39.5	43.9	23.8	39.9	33.3	29.2	33.9	34.0
SWDA [40]	29.9	42.3	43.5	24.5	36.2	32.6	30.0	35.3	34.3
DD-MRL [22]	30.8	40.5	44.3	27.2	38.4	34.5	28.4	32.2	34.6
SCL [43]	31.6	44.0	44.8	30.4	41.8	40.7	33.6	36.2	37.9
MDA [48]	33.2	44.2	44.8	28.2	41.8	28.7	30.5	36.5	36.0
ATF [18]	34.6	48.0	50.0	23.7	43.3	38.7	33.4	38.8	38.7
HTCN [4]	33.2	47.5	47.9	31.6	47.4	40.9	32.3	37.1	39.8
CFA [52]	34.0	46.9	42.1	30.8	43.2	29.9	<b>34.7</b>	37.4	38.6
MEAA [33]	34.2	48.9	52.4	30.3	47.4	46.0	33.2	36.2	40.5
UMT [10]	33.0	45.9	48.6	<b>34.1</b>	<b>56.5</b>	<b>46.8</b>	30.4	37.3	41.7
Ours (Baseline)	32.2	45.0	48.4	29.8	44.3	43.9	29.3	34.7	38.5
Ours (IDF)	<b>37.4</b>	<b>50.1</b>	<b>52.8</b>	31.3	50.6	42.0	33.7	<b>41.7</b>	<b>42.4</b>

正常到有雾适应场景下，从城市景观到有雾城市景观的域自适应检测结果(%)。

# 探索域自适应对象检测的隐式域不变特征

## 实验内容

城市景观



源域

雾蒙蒙的城市景观



目标域



**Source-only 方法:** 仅在源域上训练的 Faster R-CNN [38]

**Baseline 方法:** 包含域不变分支的 Faster R-CNN 和四个域分类器

**我们的方法:** IDF (取得了显著提升)

IDF 方法相较 Source-only 方法提升:  
+22.1%

mAP 提升: 从 38.5% 增加到 42.4%,  
提升了 +3.9%

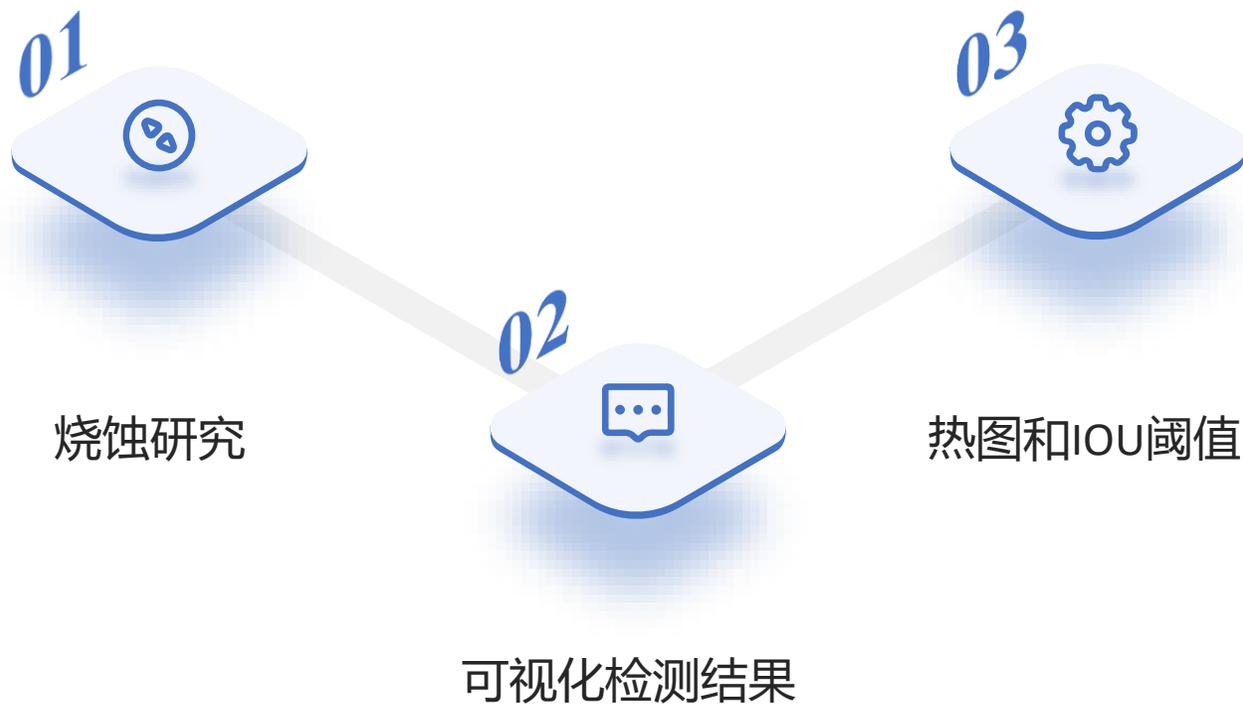
# 探索域自适应对象检测的隐式域不变特征

## 实验结果



图4。Source Only[38]、HTCN[4]、我们的方法和Ground Truth的可视化检测结果。第一行是从SIM10K[21]到合成到真实场景中的城市景观[7]。最后两行是从正常到大雾场景中的城市景观[7]到雾蒙蒙城市景观[41]。与对比的方法相比，我们的模型可以准确地检测出浓雾中具有隐式域不变特征的物体或远处的小物体。

## 进一步实证分析



# 探索域自适应对象检测的隐式域不变特征

## 烧蚀研究

Methods	Person	Rider	Car	Truck	Bus	Train	Motorcycle	Bicycle	mAP
Source Only	24.1	33.1	34.3	4.1	22.3	3.0	15.3	26.5	20.3
Baseline	32.2	45.0	48.4	29.8	44.3	43.9	29.3	34.7	38.5
IDF w/o data augmentation	35.1	48.0	51.7	30.0	44.3	45.9	33.0	37.4	40.7
IDF w/o enhanced pseudo label	36.7	48.2	52.7	34.3	47.9	39.8	32.4	38.3	41.3
IDF w/o SFP Loss	37.5	47.3	52.7	34.0	52.9	30.9	33.5	40.6	41.1
IDF w/o DAM Module	37.7	50.1	52.8	31.6	46.2	28.5	36.6	40.1	40.4
IDF (full)	37.4	50.1	52.8	31.3	50.6	42.0	33.7	41.7	<b>42.4</b>

消融研究：Cityscapes 到 Foggy Cityscapes “无数据增强”表示我们没有使用 CycleGAN [53] 生成的隐式可转移样本。“无增强伪标签”表示我们没有使用本文提出的伪标签方法。每个组件取消后，模型的 mAP 都会降低，这表明本文提出的每个组件的有效性。

**删除IDF的一部分会导致性能相应下降**

**移除SFP Loss或DAM模块时，性能会显著下降**

# 探索域自适应对象检测的隐式域不变特征

## 热图可视化结果



该可视化实验在 Foggy Cityscapes [41] 数据集上实施。我们从 IDF 模型的最后一层主干网络中提取特征以生成热图。第一行的图像是原始图像，第二行的图像是相应的热图。黄色像素表示感兴趣的区域。可以观察到，我们的模型仍然能够在浓雾中关注具有隐含域不变特征的物体，而现有方法由于丰富的域特定特征的影响，忽略了这些物体。最好在彩色显示中查看。



06 CONCLUSION

# 突出贡献



提出了隐式领域不变 Faster R-CNN (IDF) 检测器，是首个在领域自适应目标检测中考虑隐式领域不变特征的工作。



采用改进的双分支架构，引入了非对抗领域判别器 (NADD)、选择性特征感知损失 (SFP Loss)、双注意力模块 (DAM) 和新颖的伪目标标签，有助于网络充分探索隐式领域不变特征。

## PART 02



在多个基准域自适应检测数据集上进行了广泛实验，包括Cityscapes、Foggy Cityscapes、KITTI和SIM10K等，结果显示我们方法优于现有方法，探索隐式特征能够在不使用技巧的情况下提升性能达3.9%

## PART 03



## 尺度信息的忽略

当前的DAOD算法通常忽视目标实例的尺度信息，直接对不同尺度的实例进行对齐。这会导致由于尺度差异而降低对齐性能。



## 泛化到未知目标域的困难

现有的DAOD方法在许多情况下不能很好地适应未知的目标域。然而，实际应用中经常会遇到许多未知的目标域



## 利用多样化的源域训练通用检测器

如何利用足够多样化的源域数据，训练一个能够同时适应更多未知目标域的通用检测器，是未来研究中的一个挑战

Thanks