

## 基于反事实注意力学习的无监督域自适应行人再识别

代雪松, 李小红, 张晶晶, 齐美彬, 刘一敏

### 引用本文

代雪松, 李小红, 张晶晶, 齐美彬, 刘一敏. 基于反事实注意力学习的无监督域自适应行人再识别[J]. 计算机科学, 2023, 50(7): 160-166.

DAI Xuesong, LI Xiaohong, ZHANG Jingjing, QI Meibin, LIU Yimin. [Unsupervised Domain Adaptive Pedestrian Re-identification Based on Counterfactual Attention Learning](#) [J]. Computer Science, 2023, 50(7): 160-166.

---

### 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

#### Similar articles recommended (Please use Firefox or IE to view the article)

#### [基于对偶流形重排序的无监督特征选择算法](#)

Unsupervised Feature Selection Algorithm Based on Dual Manifold Re-ranking  
计算机科学, 2023, 50(7): 72-81. <https://doi.org/10.11896/jsjcx.221000143>

#### [基于FlexUDA模型的SQL注入检测研究](#)

Study on SQL Injection Detection Based on FlexUDA Model  
计算机科学, 2023, 50(6A): 220600172-6. <https://doi.org/10.11896/jsjcx.220600172>

#### [基于预训练模型的无监督剧本摘要](#)

Unsupervised Script Summarization Based on Pre-trained Model  
计算机科学, 2023, 50(2): 310-316. <https://doi.org/10.11896/jsjcx.211100039>

#### [亮度自调节的无监督图像去雾与低光图像增强算法研究](#)

Study on Unsupervised Image Dehazing and Low-light Image Enhancement Algorithms Based on Luminance Adjustment  
计算机科学, 2023, 50(1): 123-130. <https://doi.org/10.11896/jsjcx.211100058>

#### [基于域自适应的肿瘤识别模型](#)

Tumor Recognition Method Based on Domain Adaptive Algorithm  
计算机科学, 2022, 49(12): 250-256. <https://doi.org/10.11896/jsjcx.220600008>

# 基于反事实注意力学习的无监督域自适应行人再识别

代雪松 李小红 张晶晶 齐美彬 刘一敏

合肥工业大学计算机与信息学院 合肥 230601

(978548365@qq.com)

**摘要** 现有的无监督域自适应行人重新识别方法大多是将基于聚类的伪标签预测与特征微调相结合。由于域间存在差异,聚类过程中产生了不正确的伪标签,使伪标签存在一定的不可靠性,误导特征表示学习,从而影响域自适应模型的性能。基于此,首先设计一个新颖的基于反事实注意力学习的无监督域自适应网络,通过衡量注意力学习的质量对训练过程进行指导优化,促使模型关注更加精准的注意力特征,减少噪声伪标签的生成;其次提出了一种基于不确定性评估的噪声样本优化方法,通过测量基于平均教师方法的学生模型和教师模型输出特征之间的不一致性水平,将其作为目标域行人样本的不确定性分布,进而利用样本的不确定性对网络总体损失的各个部分进行合理加权,修正具有高不确定性的样本对模型总体损失的错误影响,进一步提升目标域的识别性能。实验数据表明,所提方法在源域 DukeMTMC-reID/Market-1501 和目标域 Market-1501/DukeMTMC-reID 上的实验结果都有显著提高,mAP 和 Rank-1 分别达到了 82.9%,93.6%和 71.8%,84.4%。

**关键词:** 行人再识别;无监督;域自适应;反事实注意力;不确定性评估

中图法分类号 TP391

## Unsupervised Domain Adaptive Pedestrian Re-identification Based on Counterfactual Attention Learning

DAI Xuesong, LI Xiaohong, ZHANG Jingjing, QI Meibin and LIU Yimin

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China

**Abstract** Most of the existing unsupervised domain adaptive pedestrian re-identification methods combine clustering-based pseudo-label prediction with feature fine-tuning. Due to the differences between domains, incorrect pseudo-labels are generated during the clustering process, making pseudo-labels unreliable to a certain extent, misleading feature representation learning, and affecting the performance of domain-adaptive models. First, a novel unsupervised domain adaptive network based on counterfactual attention learning is designed, which guides and optimizes the training process by measuring the quality of attention learning, prompting the model to focus on more accurate attention features and reducing the generation of noisy pseudo-labels. Secondly, a noisy samples optimization method based on uncertainty evaluation is proposed. By measuring the inconsistency level between the output features of the student model and the teacher model, as the uncertainty distribution of pedestrian samples in the target domain. The teacher model and the student model are both constructed based on the average teacher method. The uncertainty of the sample is used to reasonably weight each part of the overall loss of the network, and the erroneous influence of the sample with high uncertainty on the overall loss of the model is corrected, and the recognition performance of the target domain is further improved. Experimental data show that the proposed method significantly improves the experimental results in both the source domain DukeMTMC-reID/Market-1501 and the target domain Market-1501/DukeMTMC-reID, with mAP and Rank-1 reaching 82.9%, 93.6% and 71.8%, 84.4%, respectively.

**Keywords** Person re-identification, Unsupervised, Domain adaptive, Counterfactual attention, Uncertainty estimation

### 1 引言

无监督域适应(Unsupervised Domain Adaptive, UDA)旨在

将有标签的源域数据集上训练的模型应用到另一个任务相关但特征分布不同且无标签的目标域数据集。通常,源域和目标域数据集之间存在一定差异,如果直接拿源域模型对目标

到稿日期:2022-06-16 返修日期:2022-11-08

基金项目:国家自然科学基金(62172137);合肥市自然科学基金(2021050)

This work was supported by the National Natural Science Foundation of China(62172137) and Natural Science Foundation of Hefei, China(2021050).

通信作者:李小红(jsjlxh@hfut.edu.cn)

域数据集进行行人检索,其性能势必会急剧下降。因此,一些主流的域自适应方法都致力于研究如何减少域间差异,使得源域模型可以在无标签的目标域上有效使用。

无监督域自适应借助带标签数据集对模型进行预训练,然后把在源域中学习到的知识应用于目标域,并最小化源域和目标域之间的特征差异。Fan等<sup>[1]</sup>提出了一种渐进式无监督学习(PUL)方法,以自训练的方式迭代地获取硬聚类标签。SSG<sup>[2]</sup>方法分别利用全局身体部位和局部身体部位的潜在相似性来构建多个独立的聚类集群,然后为这些集群分配伪标签来监督模型训练。文献<sup>[3]</sup>提出了一种递进增强框架(PAST)的自训练方法,该模型使用三重态损失函数获取目标域数据集的局部结构,在聚类结果基础上添加分类层优化分类损失,以使用关于数据分布的全局信息。为了解决聚类方法在大规模数据集上应用的难题,文献<sup>[4]</sup>提出了一种元聚类学习(MCL)方法,它通过聚类对整个未标注数据的一个子集进行伪标签生成,然后将学习到的聚类中心点视为一个代理标注器,对其余未标记的数据进行软性标注,以进一步优化模型。

然而,无监督聚类产生的噪声伪标签一直是自训练过程的障碍,这种不正确的伪标签会误导特征学习方向,阻碍识别准确率的提升。最近,一些方法引入了在2个或3个协作网络之间相互学习的方法,通过相互利用对等网络修正软伪标签作为监督信号。为了抑制伪标签中的噪声,Ge等<sup>[5]</sup>提出了一个同步平均教学(MMT)框架,通过离线修正硬伪标签和在线修正软伪标签的训练方式从目标域中学习更具判别力的特征,从而精准地对噪声伪标签进行修正。此外,文献<sup>[6]</sup>提出了一种抗噪声相互训练(NRMT)方法,该方法在训练过程中同时使用两个网络来进行协作聚类和相互选择实例。一方面,协作聚类通过维护两个网络并使用彼此提供的伪标签作为额外的监督来缓解其各自的标签错误问题;另一方面,相互实例选择根据网络中相邻样本的信任度和关系差异,进一步选择可靠和信息量大的实例进行训练。此外,基于存储库的方法也被广泛应用于无监督表示学习,这有助于引入对比损失函数。He等<sup>[7]</sup>构建了一个带有队列和平均编码器的存储库,利用样本与全局存储库中样本间的相似性促进对比性的

无监督学习。文献<sup>[8]</sup>提出了一个记忆模块,利用内存库帮助网络利用全局训练数据实施样本不变性、相机不变性和领域不变性,从而使准确率得到显著提高。

现有的无监督域自适应行人再识别方法<sup>[9-11]</sup>通常包括3个步骤:1)使用有标签的源域数据对网络进行预训练;2)针对目标域数据进行基于聚类的伪标签预测;3)特征表示学习和伪标签微调。一般迭代地进行最后两个步骤以相互促进学习过程,直到模型稳定。但此过程中也存在问题。1)由于源域数据和目标域数据之间存在差异/域间隙以及聚类算法的不完善性质,通过聚类分配的伪标签通常包含不正确的标签。这种嘈杂的标签会误导特征学习并损害域自适应性能。因此,缓解噪声伪标签样本的负面影响对提升域自适应模型检索的性能十分重要。2)目标域数据行人图像存在背景杂波和遮挡,因此很难获取具有判别性的特征表示,从而给聚类带来巨大的困难。本文设计了一个新颖的基于反事实注意力学习的域自适应网络,来增强目标域行人图像的判别性特征学习,减少噪声伪标签对训练过程的影响,提高无监督行人再识别的准确率。针对聚类中的噪声标签问题,现有的一些域自适应算法<sup>[12-13]</sup>通过在线修正不正确的样本来帮助模型学习更具鲁棒性的特征表示。尽管这些域自适应算法已经取得了显著的进步,但是相对于有监督行人再识别而言,其识别准确率依旧不尽人意。本文利用反事实注意力(Counterfactual Attention Learning, CAL),通过比较事实(即学习到的注意力权重)和反事实(即虚假的注意力权重)对最终预测结果的影响来量化注意力的质量。参照文献<sup>[14-15]</sup>,通过最大化差异促进网络学习更有效的视觉注意力,从而减少有偏训练集的影响。此外,基于不确定性理论<sup>[16]</sup>,即模型对输入样本的预测存在不确定性,通过测量两个模型(基于平均教师方法的学生模型和教师模型)的输出特征的不一致性水平,将其作为目标域样本的不确定性分布。通过估计和利用样本的不确定性来减轻噪声伪标签的负面影响,从而实现更加高效的域自适应算法。

## 2 无监督域自适应行人再识别网络

图1给出了本文提出的基于反事实注意力学习的无监督域自适应网络的整体框架。




图1 本文网络模型总体框架

Fig. 1 Overall framework of the proposed network model

设计该网络的目的是减少基于聚类框架下产生的噪声伪标签对训练造成的负面影响。该框架首先利用改进的 Res-Net50 网络在源域数据集上进行有监督训练,生成一个强大的预训练模型。然后利用该模型提取目标域数据集中行人图像的判别性特征,并使用 DBSCAN 聚类算法为目标域行人图像生成相应的伪标签,再通过有监督的方式进行迭代训练。特别地,在聚类阶段使用了反事实注意力学习方法<sup>[17]</sup>,通过衡量注意力质量来更好地指导学习过程,增强网络提取判别性特征的能力,从而更准确地对目标域数据进行聚类,生成伪标签。

由于噪声伪标签的产生是不可避免的,因此我们在联合微调阶段利用不确定性评估模块(Uncertainty Estimation Module, UNEM)来计算伪标签的可靠性,并将不确定性加入 ID 分类损失、三元组损失和对比损失中,以减轻不正确的伪标签在微调阶段对训练造成负面影响。

## 2.1 反事实注意力学习

注意力模块是行人再识别框架中指导网络提取行人图像最具判别力特征的重要组成部分。现有的大多数注意力模块都以弱监督的方式进行训练,例如,仅对行人再识别任务中的分类损失函数和三重态损失函数进行监督。由于这种监督并不是专门为注意力模块设计的,因此它可能会导致学习到的注意力并不是最优的。为了解决这个问题,本文使用反事实注意力学习方法,学习到更好的注意力特征,从而充分发挥注意力的有效性,提取更为鲁棒的行人特征,减少聚类过程中噪声伪标签的产生。该方法通过在训练过程中衡量网络学习到的注意力特征和反事实注意力特征对分类结果的影响,分析学习到的注意力质量,对训练过程进行指导优化。通过这种对比监督的方式,可以有效地判断注意力是否被正确学习并进行自我调整。

如图 2 所示,反事实注意力学习方法的输入是骨干网络输出的特征映射  $F$ ,其大小为  $c \times h \times w$ ,其中  $c, h, w$  分别是通道的维度、高度和宽度。实验中,采用时空注意力模块对卷积神经网络特征进行改进,因为它可以直接结合对象的结构知识来发现图像的判别区域。




图 2 反事实注意力学习方法结构

Fig. 2 Structure of counterfactual attention learning method

具体地,通过时空注意力模块 *attention* 后,注意力特征可以用式(1)表示:

$$X = \{X_1, X_2, \dots, X_m\} = \text{attention}(F) \quad (1)$$

其中,  $m$  为注意力个数,  $X_i \in \mathbb{R}^{h \times w}$  是包含某个区域的注意力特征图,如行人的背包、鞋子、衣服等。该时空注意力模块

*attention* 使用一个 2D 卷积层和一个 Relu 激活函数来实现。然后,使用注意力特征图对原始特征映射  $F$  进行加权,并通过全局平均池化操作进行聚合,具体如式(2)所示:

$$Z_i = \text{GAP}(F * X_i) \quad (2)$$

其中,  $*$  表示向量内积。参照文献[17]中的方式,将不同部分的特征表示  $Z_i$  进行组合形成全局特征表示  $Z$ 。

$$Z = \text{normalize}([Z_1, Z_2, \dots, Z_M]) \quad (3)$$

把这些特征表示连接起来,然后对全局特征表示进行归一化。最后,通过一个分类层  $C$ ,可以得到使用空间注意力加权后网络最终的预测结果  $Y(X)$ 。

$$Y(X) = C(\text{BN}[Z_1, Z_2, \dots, Z_M]) \quad (4)$$

为了评估注意力模型的质量,本文使用反事实注意力通过假想出一个注意力图来对各变量进行调整。在实验中,这个反事实注意力图可以使用随机注意力、统一注意力或者反向注意力等。根据式(3)和式(4)可以得到基于反事实注意力的最终预测。

$$Y(\bar{X}) = C(\text{BN}[\text{GAP}(F * \bar{X}_1), \dots, \text{GAP}(F * \bar{X}_M)]) \quad (5)$$

与文献[18]中的处理方式一样,学习到的注意力对预测的影响可以用真实注意力特征得到的预测  $Y(X)$  与反事实注意力得到的预测  $Y(\bar{X})$  之间的差异来表示。

$$Y_{\text{effect}} = Y(X) - Y(\bar{X}) \quad (6)$$

其对预测的影响可以表示为  $Y_{\text{effect}}$ 。简单地说,注意力的有效性可以解释为,与错误注意力相比,注意力如何改善最终预测。因此,通过衡量学习注意力的质量,监督注意力学习方向,指导模型优化,可以有效提高提取特征的判别性,减少聚类过程中的噪声伪标签。

## 2.2 基于不确定性评估的噪声样本优化

无监督聚类引起的伪标签噪声一直是无监督域自适应行人再识别模型性能提升的障碍。不正确的伪标签会在训练的微调阶段误导特征学习,影响域自适应模型的性能。

为了解决该问题,比较常见的方法是通过 2,3 个协作网络之间的相互学习,以相互利用对等网络的精细软伪标签作为监督信息,使用彼此提供的伪标签作为额外的监督来缓解各自的伪标签错误问题。或者如 NRMT<sup>[6]</sup> 一般在训练期间维护两个网络,以执行协作聚类和相互实例选择,通过相互监督和可靠实例选择来减少对噪声实例的拟合,从而达到抑制伪标签噪声的目的。现有的常见伪标签噪声优化方法通常需要两个或多个网络进行相互学习,并且较为复杂。

在本文中,我们基于平均教师方法构建了一个简单而高效的框架,该框架通过计算同一样本在教师模型与学生模型输出之间的不一致性,评估目标域样本伪标签的可信度来减少噪声伪标签的负面影响,并在总的损失函数中将样本的不确定性作为权重参数加以利用,抑制行人再识别损失中具有错误伪标签样本的贡献以减轻易受噪声影响的样本的负面影响。由于我们的平均教师模型的参数更新仅使用学生模型的权重做加权平均,因此本文方法并不需要多个模型相互学习与训练。

通俗地说,模型对样本输出的不确定性越高,输出的可靠性就越低(预测噪声越大),然后通过聚类更可能成为一个

噪声伪标签。因此本文方法主要是通过计算教师模型和学生模型之间输出的不一致性来估计不确定性分布。对于目标域的样本  $x_i$ , 将从学生模型中提取的特征表示为  $f_i \in \mathbb{R}^{c \times h \times w}$ , 从教师模型中获取的特征表示为  $\tilde{f}_i \in \mathbb{R}^{c \times h \times w}$ 。特别地, 本文方法将源域数据集的类中心特征矩阵  $\mathbf{R}_s \in \mathbb{R}^{P_s \times c \times h \times w}$  和目标域数据集的聚类中心特征矩阵  $\mathbf{R}_t \in \mathbb{R}^{P_t \times c \times h \times w}$  进行组合, 形成参考中心的集合  $\mathbf{R} = [\mathbf{R}_s, \mathbf{R}_t] \in \mathbb{R}^{P_s + P_t \times c \times h \times w}$ 。对于学生模型的特征向量  $f_i$ , 通过计算其与参考中心矩阵  $\mathbf{R}$  的相似度得出样本数据的软多标签, 具体公式如下:

$$L_i = \text{Softmax}(\mathbf{R} \cdot f_i) \quad (7)$$

同理, 对于教师模型的特征  $\tilde{f}_i \in \mathbb{R}^{c \times h \times w}$ , 把获得的软多标签表示为  $\tilde{L}_i = \text{Softmax}(\mathbf{R} \cdot \tilde{f}_i)$ 。使用 KL 散度来测量同一样本  $x_i$  经过教师和学生模型所计算得到的软多标签概率分布之间的差异作为样本的不确定性  $u_i$ , 计算式为:

$$u_i = D_{\text{KL}}(\tilde{L}_i \parallel L_i) = \sum_{k=1}^K \tilde{L}_{i,k} \log \frac{\tilde{L}_{i,k}}{L_{i,k}} \quad (8)$$

### 2.3 迭代优化策略

本文使用混合源域数据集和目标域伪标签数据集的方式进行训练, 当源域数据集在验证集上收敛时, 停止训练。基于上文的叙述, 本文利用不确定性来估计样本伪标签的不可靠性, 并使用它来重新衡量样本在各个损失函数中的权重。利用式(8)得到的不确定性  $u_i$  来计算可信度权重  $\omega_i$ , 计算式为:

$$\omega_i = \exp(-u_i) \quad (9)$$

该网络将不确定评估用于训练中的 ID 分类损失、三元组损失以及对比损失中。在 batch 大小为  $N_t$  的目标域样本中将不确定评估的分类损失函数定义为:

$$\mathcal{L}_{\text{class}} = -\frac{1}{N_t} \sum_{i=1}^{N_t} \omega_i \log p(\tilde{y}_i | x_i) \quad (10)$$

其中,  $p(\tilde{y}_i | x_i)$  表示样本  $x_i$  为类  $\tilde{y}_i$  的概率,  $\tilde{y}_i$  表示聚类生成的伪标签。对于具有高不确定性的样本, 使用较小的权重来减少其对总体损失的贡献, 从而减轻在微调阶段的负面影响。

三重态损失函数被广泛应用于样本对相似性优化任务中, 目的是使 anchor 样本与正样本之间的相似性远大于其与负样本之间的相似性。对于 anchor 样本、正样本和负样本对应于 3 个伪标签的第  $j$  个三元组, 用两个不确定度的函数来近似估计样本对的可靠性。本文将正样本对的可靠性表示为:

$$\omega_{ap}^j = \varphi(u_a^j, u_p^j) \quad (11)$$

其中,  $u_a^j$  和  $u_p^j$  分别表示第  $j$  个三元组中 anchor 样本和正样本的估计不确定性。为了简便起见, 将这对可信度定义为两个可信度的平均值。

$$\varphi(u_a^j, u_p^j) = \frac{(\omega_a^j + \omega_p^j)}{2} \quad (12)$$

基于此方法, 可以得到负样本对的可靠性表示。对于三重态损失, 将每个 batch 中使用样本对的不确定性估计的三重态损失函数定义为:

$$\mathcal{L}_{\text{triplet}} = \sum_{j=1}^P \sum_{a=1}^K \max \left[ \left( \max_{p=1 \dots K} (\omega_{ap}^j) d(x_a^j, x_p^j) - \max_{n=1 \dots P, i=1 \dots P, i \neq j} (\omega_{an}^j) d(x_a^j, x_n^j) + m \right), 0 \right] \quad (13)$$

其中,  $d(x_a^j, x_p^j)$  表示第  $j$  个正样本对的相似性距离。从数学的角度分析, 样本对的可信度越低(不确定性越高), 相似性权重就越小。因此, 对应的优化中的梯度就越小, 即对优化的贡献越小。

对于对比损失, 给定一个 query 样本, 在 memory bank 中有  $N_q^+$  个正样本和  $N_q^-$  个负样本。在一个包含  $N_t$  个目标域样本的 batch 中, 引入样本可信度权重的对比损失可表示为:

$$\mathcal{L}_{\text{contrastive}} = \frac{1}{N_t} \sum_{q=1}^{N_t} \log \left[ \sum_{j=1}^{N_q^-} \omega_{qj}^- \exp(s_{qj}^-) \sum_{i=1}^{N_q^+} \omega_{qi}^+ \exp(-s_{qi}^+) + 1 \right] \quad (14)$$

其中,  $S_{qj}^-$  表示 query 样本和第  $j$  个负样本之间的相似性,  $\omega_{qj}^-$  表示样本对的近似可靠性。由于样本对的可信度越低, 梯度越小, 对样本对优化的贡献就越小, 因此本文使用自定义权重, 通过给较硬(Hard)的样本对更大的权重来获得最优的更新。

此外, 该网络还使用注意力质量度量作为监督信号来指导注意力学习过程。将 batch 中的源域样本数量表示为  $N_s$ ,  $y_{s,i}$  为源域样本  $x_{s,i}$  的身份标签,  $Y_{\text{effect}}$  为 2.1 节中通过式(6)得到的样本  $x_{s,i}$  对应的注意力对预测的影响表示, 由此得到注意力度量损失公式如下:

$$\mathcal{L}_{\text{effect}} = -\frac{1}{N_s} \sum_{i=1}^{N_s} \log p(y_{s,i} | Y_{\text{effect}}) \quad (15)$$

因此, 整个训练过程中的优化总损失可表示为:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{class}} + \mathcal{L}_{\text{triplet}} + \lambda_{\text{ct}} \mathcal{L}_{\text{contrastive}} + \lambda_{\text{eff}} \mathcal{L}_{\text{effect}} \quad (16)$$

其中,  $\lambda_{\text{ct}}$  和  $\lambda_{\text{eff}}$  为加权因子。

## 3 实验结果与分析

### 3.1 数据集与评价指标

本文在行人再识别的两个常用行人数据集 Market-1501<sup>[19]</sup> 和 DukeMTMC-reID<sup>[20]</sup> 上进行训练与评估。其中, 评价指标使用累计匹配曲线(CMC)中的 Rank-1, Rank-5, Rank-10 和平均精度(mAP)。

### 3.2 实验配置

本文使用经典的 ResNet50 网络作为无监督域自适应框架的骨干网络。为了使其能够提取到更加精细的特征, 以更好地适用于无监督行人再识别任务, 文中对骨干网络做了相应的修改, 即在网络中添加了 4 个通道注意力模块。与文献[12]一样, 将输入图像的大小重新调整为  $256 \times 128$ , 并采用随机增强、裁剪和翻转进行数据增强。针对源域预训练, 每个 batch 中包含 4 个行人身份的 64 张图像。在模型微调阶段, 将源域数据和目标域数据混合, 每个 batch 中包含 4 个行人身份的 64 张源域图像和 4 个伪身份的 64 张目标域图像, 其中每个行人身份有 16 张图像。此外, 该网络中采用 DBSCAN 算法进行聚类生成伪标签。对于 DBSCAN, 将其相邻样本之间的最大距离阈值 eps 设为 0.6, 密集点的最少邻居样本数设置为 4。该网络模型使用 Adam 优化器来优化模型参数, Adam 优化器的超参数  $\beta_1$  和  $\beta_2$  分别设置为 0.9 和 0.999。学习速率被初始化为 0.00035。对于损失函数中对比损失  $\lambda_{\text{ct}}$  和反事实注意力影响的权重因子  $\lambda_{\text{eff}}$  分别被设置为 0.08 和 0.06。

### 3.3 与现有主流方法的对比实验

本文将所设计的无监督域自适应网络在 Market-1501 和 DukeMTMC-reID 两个数据集上的实验结果与现有主流的一些方法进行比较,充分展现了所提方法的有效性,如表 1 所列。本文方法在 DukeMTMC $\rightarrow$ Market1501, Market1501 $\rightarrow$ DukeMTMC 上进行域自适应实验的结果明显优于现有的 UDA 方法,其 mAP 精度值相比 CVPR2021 年提出的 GLT 方法分别高出 3.4% 和 2.6%。SSG 是对全局身体特征和局部身体特征进行了多次聚类。DAAM 引入了一个注意力模块,并且结合了域对齐约束。MMT 使用 2 个网络(4 个模型),MEB-Net 使用 3 个网络(6 个模型)进行相互平均教师训练,这导致了训练过程计算的高复杂性。相比之下,本文提出的方法仅仅使用了 1 个网络(2 个模型),但是性能明显优于复杂的 MEB-Net 算法。本文方法取得如此优异性能的原因

主要有两点:1)使用反事实注意力学习方法监督预测和注意力之间的因果关系,从而更好地指导整个训练过程,增强提取特征的判别性,减少噪声标签的产生;2)基于当前聚类算法的不完善性,通过估计学习模型和教师模型输出特征的不一致性,并将其作为目标域样本的不确定分布,以此来减轻噪声伪标签对训练过程造成的负面影响。本节还分别把 Market-1501 和 DukeMTMC-reID 作为源域数据集对网络进行预训练,并将得到的模型迁移到 MSMT17 目标域数据集中进行评估,结果如表 2 所列。由于 MSMT17 数据集包含室内和室外两种场景图像,与 Market-1501 和 DukeMTMC-reID 数据集存在较大的差异,因此 Market-1501 $\rightarrow$ MSMT17 和 DukeMTMC-reID $\rightarrow$ MSMT17 的迁移效果比 DukeMTMC-reID $\rightarrow$ Market-1501 和 Market-1501 $\rightarrow$ DukeMTMC-reID 的要差。但是和其他主流方法相比,本文提出的方法仍然具有优越性。

表 1 Market1501 和 DukeMTMC-ReID 数据集上不同算法性能指标对比

Table 1 Comparison of performance metrics of different algorithms on Market1501 and DukeMTMC-ReID datasets (单位:%)

Algorithm	DukeMTMC $\rightarrow$ Market1501				Market1501 $\rightarrow$ DukeMTMC			
	Rank-1	Rank-5	Rank-10	mAP	Rank-1	Rank-5	Rank-10	mAP
BUC <sup>[21]</sup>	66.2	79.6	84.5	38.3	47.4	62.6	68.4	27.5
ECN <sup>[8]</sup>	75.1	87.6	91.6	43.0	63.3	75.8	80.4	40.4
MAR <sup>[22]</sup>	67.7	81.9	—	40.0	67.1	79.8	—	48.0
PDA-Net <sup>[23]</sup>	75.2	86.3	90.2	47.6	63.2	77.0	82.5	45.1
PCB <sup>[3]</sup>	78.4	—	—	54.6	72.4	—	—	54.3
SSG <sup>[2]</sup>	80.0	90.0	92.4	58.3	73.0	80.6	83.2	53.4
MPLP <sup>[24]</sup>	84.4	32.8	95.0	60.4	72.4	82.9	85.0	51.4
AD-Cluster <sup>[11]</sup>	86.7	94.4	96.5	68.3	72.6	82.5	85.5	54.1
MMT <sup>[5]</sup>	87.7	94.9	96.9	71.2	78.0	88.8	92.5	65.1
NRMT <sup>[6]</sup>	87.8	94.6	96.5	71.7	77.8	86.9	89.5	62.2
UNRN <sup>[12]</sup>	91.9	96.1	97.8	78.1	82.0	90.7	93.5	69.1
GLT <sup>[13]</sup>	92.2	96.5	97.8	79.5	82.0	90.2	92.8	69.2
本文	93.6	97.5	98.4	82.9	84.4	91.3	93.4	71.8

表 2 MSMT17 数据集上不同算法性能指标对比

Table 2 Comparison of performance metrics of different algorithms on MSMT17 datasets (单位:%)

Algorithm	DukeMTMC $\rightarrow$ MSMT17				Market1501 $\rightarrow$ MSMT17			
	Rank-1	Rank-5	Rank-10	mAP	Rank-1	Rank-5	Rank-10	mAP
ECN <sup>[8]</sup>	25.3	36.3	42.1	8.5	30.3	41.5	46.8	10.2
SSG <sup>[2]</sup>	31.6	—	49.6	13.2	32.2	—	51.2	13.3
DDAM <sup>[25]</sup>	44.5	—	—	20.8	46.7	—	—	21.6
MMT <sup>[5]</sup>	49.2	63.1	68.8	22.9	50.1	63.9	69.8	22.3
NRMT <sup>[6]</sup>	43.7	56.5	62.2	19.8	45.2	57.8	63.3	20.6
UNRN <sup>[12]</sup>	52.4	64.7	69.7	25.3	54.9	67.3	70.6	26.2
本文	53.9	65.3	70.4	26.8	56.8	69.2	71.5	28.3

### 3.4 参数分析

为了对实验中的超参数进行合理配置,我们探索了损失函数中的权重因子  $\lambda_{ct}$  与  $\lambda_{eff}$  的取值对本文所设计的无监督域自适应网络性能的影响。将 DukeMTMC-reID 作为源域数据集,将 Market-1501 作为目标域数据集进行了域自适应实验,以平均精度(mAP)作为参数分析实验的评价标准。首先固定  $\lambda_{ct}$  的值为 0.05,  $\lambda_{eff}$  在 0~0.1 之间以 0.02 为间隔取值,图 3 给出了  $\lambda_{eff}$  取不同值时网络的表现。可以看出,当  $\lambda_{eff}$  取值为 0.06 时,mAP 精度值最高。




图 3 超参数  $\lambda_{eff}$  对实验结果的影响

Fig. 3 Effect of hyperparameter  $\lambda_{eff}$  on experimental results

根据上述实验,我们固定超参数  $\lambda_{eff}$  为 0.06,  $\lambda_{ct}$  在 0~

0.1 之间以 0.02 为间隔取值,图 4 给出了  $\lambda_{ct}$  取不同值时网络的表现。可以看出,当  $\lambda_{ct}$  取值为 0.08 时,模型性能达到最优。因此我们最终取  $\lambda_{ct}=0.08$  和  $\lambda_{eff}=0.06$  的最优超参数组合。




图 4 超参数  $\lambda_{ct}$  对实验结果的影响

Fig. 4 Effect of hyperparameter  $\lambda_{ct}$  on experimental results

### 3.5 消融实验

为了证明本文使用的两个模块对域自适应任务的有效性,在基线模型的基础上,对 DukeMTMC  $\rightarrow$  Market-1501 和 Market1501  $\rightarrow$  DukeMTMC 任务进行了消融实验。根据 UDA 方法中常用的基线<sup>[10-11]</sup>建立了基础基线网络,在微调阶段,身份分类损失和三重损失用于基于目标域数据的伪标签对网络进行微调。在基础基线模型之上,该网络在 ResNet50 中添加了 4 个注意力模块,建立了一个的强大的基线模型 (Strong-Baseline, 后文统称强基线模型)。本节在强大的基线基础上对所提方法的作用进行验证。通常,基线越强,检索性能就越难获得提升。因为对于身份信息较为清晰的行人图片样本,强基线模型已经能够对该部分简单样本所属的行人身份做出较为准确的判断。但如果新的方法能够与强基线互补,将极大地推进技术的发展。在强基线模型中,对于目标域样本,使用身份分类损失、三元组损失和对比损失进行基于伪标签的监督。为了减少噪声伪标签的负面影响,使用反事实注意力学习方法和不确定性噪声样本修正策略,两种方法

相辅相成能够共同提升检索性能。表 3 列出了比较结果。

我们认为,由无监督聚类算法的不完善性引起的伪标签噪声是影响无监督域自适应行人再识别算法性能提升的最大障碍。而在我们设计的强基线模型中添加基于不确定性的噪声样本修正策略,可以通过对样本进行不确定性评估,基于样本的不确定性来重新加权样本在各种损失函数中的贡献,有效修正伪标签噪声对总体损失的不正确影响。表 3 展示的消融实验有力印证了这一点,当在强基线模型基础上加入基于不确定性评估的噪声样本修正策略时,在 DukeMTMC  $\rightarrow$  Market1501 和 Market1501  $\rightarrow$  DukeMTMC 上的 mAP 准确率分别提高了 3.3% 和 3.6%。

我们构建的强基线模型已经在基础 ResNet50 网络中插入了 4 个空间注意力模块,从表 3 可以看出,与基于基础 ResNet50 网络构建的强基线模型相比,基于插入空间注意力模块的 ResNet50 网络构建的 Baseline 模型在性能上遥遥领先,强基线模型在 DukeMTMC  $\rightarrow$  Market1501 和 Market1501  $\rightarrow$  DukeMTMC 上的 mAP 准确率分别提高了 9.6% 和 5.8%。这充分证明了注意力机制能够有效地促进行人再识别模型在特征提取阶段关注与任务更相关的图像区域,从而指导网络提取出更加优秀的特征。而在强基线模型的基础上再添加反事实注意力学习方法,强基线模型的 mAP 准确率也得到了提升,在 DukeMTMC  $\rightarrow$  Market1501 和 Market1501  $\rightarrow$  DukeMTMC 上的 mAP 准确率分别提高了 1.0% 和 0.3%。这也印证了反事实注意力学习能够促进强基线模型学习到更好的注意力特征。当在强基线模型上同时加入 CAL 和 UNEM 两个模块时,在 DukeMTMC  $\rightarrow$  Market1501 和 Market1501  $\rightarrow$  DukeMTMC 上的 mAP 值分别达到了 82.9% 和 71.8%。可见反事实注意力学习方法与基于不确定性评估的噪声样本修正策略可以相辅相成,共同促进行人再识别模型的性能提升。

表 3 在 Duke-MTMC 和 Market1501 数据集上评估各模块的有效性

Table 3 Evaluation of the effectiveness of modules on DukeMTMC and Market1501 datasets

(单位: %)

Algorithm	DukeMTMC $\rightarrow$ Market1501				Market1501 $\rightarrow$ DukeMTMC			
	Rank-1	Rank-5	Rank-10	mAP	Rank-1	Rank-5	Rank-10	mAP
Pretrain	65.1	78.9	83.5	34.6	52.6	68.4	73.5	35.5
Baseline	85.7	93.2	95.0	69.1	77.3	97.3	90.9	62.6
StrongBaseline	91.8	96.4	97.3	78.7	82.0	90.5	92.4	68.4
+CAL	92.0	96.6	97.6	79.7	81.5	90.2	92.1	68.7
+UNEM	93.5	97.3	98.2	82.0	84.2	91.5	93.5	72.0
+CAL+UNEM	93.6	97.5	98.4	82.9	84.4	91.3	93.4	71.8

**结束语** 本文提出了一种反注意力学习方法和一种基于不确定性评估的噪声样本优化方法来解决基于聚类的无监督域自适应行人再识别中的噪声伪标签问题。首先,针对数据集中行人图像存在背景杂波和遮挡的问题,利用反注意力学习方法通过监督预测和注意力之间的因果关系,比较真实注意力和反事实注意力对最终预测的影响来量化注意力质量。并利用差异最大化来增强网络学习更有效的视觉注意力,从而减少噪声伪标签的产生。其次,基于聚类产生的噪声伪标签样本通常在教师模型和学生模型的输出之间存在一定的

差异性。本文提出使用不确定性来评估样本伪标签的可靠性,减轻噪声伪标签对训练过程造成的负面影响。在 3 个公共数据集上的实验结果验证了本文提出的方法可以有效提升行人再识别模型的性能。

### 参考文献

- [1] FAN H, ZHENG L, YAN C, et al. Unsupervised person re-identification: Clustering and finetuning[J]. ACM Transactions on Multimedia Computing, Communications, and Applications

- (TOMM), 2018, 14(4):1-18.
- [2] FU Y, WEI Y, WANG G, et al. Self-similarity grouping: A simple unsupervised cross domain adaptation approach for person re-identification[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:6112-6121.
- [3] ZHANG X, CAO J, SHEN C, et al. Self-Training with progressive augmentation for unsupervised cross-domain person re-identification[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:8222-8231.
- [4] JIN X, HE T, YIN Z, et al. Meta clustering learning for large-scale unsupervised person re-identification [J]. arXiv: 2111.10032, 2021.
- [5] GE Y, CHEN D, LI H, et al. Mutual mean-teaching: Pseudo label refinery for unsupervised domain adaptation on person re-identification[J]. arXiv:2001.01526, 2020.
- [6] ZHAO F, LIAO S, XIE G, et al. Unsupervised domain adaptation with noise resistible mutual-training for person re-identification[C] // European Conference on Computer Vision. Springer, 2020:526-544.
- [7] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:9729-9738.
- [8] ZHONG Z, ZHENG L, LUO Z, et al. Invariance matters: Exemplar memory for domain adaptive person re-identification[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:598-607.
- [9] LIU J, ZHA Z J, CHEN D, et al. Adaptive transfer network for cross-domain person re-identification[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:7202-7211.
- [10] SONG L, WANG C, ZHANG L, et al. Unsupervised domain adaptive re-identification: Theory and practice[J]. Pattern Recognition, 2020, 102:107173.
- [11] ZHAI Y, LU S, YE Q, et al. Ad-cluster: Augmented discriminative clustering for domain adaptive person re-identification[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020:9021-9030.
- [12] ZHENG K, LAN C, ZENG W, et al. Exploiting sample uncertainty for domain adaptive person re-identification[J]. arXiv: 2012.08733, 2020.
- [13] ZHENG K, LIU W, HE L, et al. Group-aware label transfer for domain adaptive person re-identification[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:5310-5319.
- [14] PEARL J. Direct and indirect effects [M]. Probabilistic and Causal Inference: The Works of Judea Pearl. 2022:373-392.
- [15] VANDERWEELE T. Explanation in causal inference: Developments in mediation and interaction[J]. International Journal of Epidemiology, 2016, 45(6):1904-1908.
- [16] KENDALL A, GAL Y. What uncertainties do we need in Bayesian deep learning for computer vision? [J]. arXiv:1703.04977, 2017.
- [17] RAO Y, CHEN G, LU J, et al. Counterfactual attention learning for fine-grained visual categorization and re-identification[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021:1025-1034.
- [18] VANDERWEELE T. Explanation in causal inference: methods for mediation and interaction[M]. New York: Oxford University Press, 2015.
- [19] ZHENG L, SHEN L, TIAN L, et al. Scalable person re-identification: A benchmark [C] // Proceedings of the IEEE International Conference on Computer Vision. 2015:1116-1124.
- [20] RISTANI E, SOLERA F, ZOU R, et al. Performance measures and a data set for multi-target, multi-camera tracking[C] // European Conference on Computer Vision. Springer, 2016:17-35.
- [21] LIN Y, DONG X, ZHENG L, et al. A bottom-up clustering approach to unsupervised person re-identification [C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2019: 8738-8745.
- [22] YU H, ZHENG W, WU A, et al. Unsupervised person re-identification by soft multilabel learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:2148-2157.
- [23] LI Y, LIN C, LIN Y, et al. Cross-dataset person re-identification via unsupervised pose disentanglement and adaptation[C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019:7919-7929.
- [24] WANG D, ZHANG S. Unsupervised person re-identification via multi-label classification [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020: 10981-10990.
- [25] HUANG Y, PENG P, JIN Y, et al. Domain adaptive attention model for unsupervised cross-domain person re-identification[J]. arXiv:1905.10529, 2019.



**DAI Xuesong**, born in 1998, postgraduate, is a member of China Computer Federation. His main research interests include computer vision and model compression.



**LI Xiaohong**, born in 1970, postgraduate, associate professor, master supervisor. Her main research interests include computer vision and model compression.