

马俊磊, 韩华, 黄丽, 等. 行人重识别中基于特征相似性的伪标签优化方法[J]. 智能计算机与应用, 2026, 16(4): 131-137.
DOI: 10.20169/j.issn.2095-2163.24061801

行人重识别中基于特征相似性的伪标签优化方法

马俊磊, 韩华, 黄丽, 王春媛

(上海工程技术大学 电子电气工程学院, 上海 201620)

摘要: 无监督行人重识别(Re-ID)旨在解决行人在不同摄像机视图下的匹配问题,特别是在不同摄像机拍摄的图像序列中识别和匹配相同的个体。通常,基于聚类生成的伪标签容易包含噪声,导致在图像识别过程中提取的特征存在偏差或冗余,进而引发过拟合。为了克服这个问题,本文利用交叉一致性得分和对比损失来识别局部和全局特征之间的相似性,然后将其用于优化伪标签,从而减少过拟合。并提出了一种基于特征相似性的伪标签优化框架。该框架首先提取局部和全局特征,然后通过聚类生成伪标签,然后通过交叉计算方式得到交叉一致性得分和好的局部特征,使用对比损失得到好的局部特征和对应全局特征的互补信息。使用交叉一致性得分和对比损失得到互补信息来优化伪标签,提高模型的性能。通过在Market-1501数据集上的大量实验结果表明,所提出的方法优于最先进的技术,证明了其有效性。

关键词: 无监督学习; 迁移学习; 局部特征; 全局特征

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2026)04-0131-07

Pseudo-label optimization method based on feature similarity in unsupervised person re-identification

MA Junlei, HAN Hua, HUANG Li, WANG Chunyuan

(School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

Abstract: Unsupervised person re-identification (Re-ID) aims to solve the problem of matching individuals across different camera views, particularly in identifying and matching the same individual in image sequences captured by different cameras. Typically, pseudo-labels generated based on clustering tend to contain noise. This can easily lead to the extraction of incorrect or redundant features during image recognition, resulting in overfitting. To overcome this issue, this paper leverages cross-consistency scores and contrastive loss to identify the similarity between local and global features, which are then used to optimize pseudo-labels, thereby reducing overfitting. A pseudo-label optimization framework based on feature similarity is proposed. This framework first extracts local and global features, then generates pseudo-labels through clustering. Cross-consistency scores are calculated to obtain high-quality local features, and contrastive loss is used to obtain complementary information between good local features and the corresponding global features. The complementary information obtained using cross-consistency scores and contrastive loss is then used to optimize pseudo-labels, enhancing the model's performance. Extensive experimental results on the Market-1501 dataset demonstrate that the proposed method outperforms state-of-the-art techniques, proving its effectiveness.

Key words: unsupervised learning; transfer learning; local features; global features

0 引言

行人重识别(Person Re-Identification, Re-ID)是图像识别领域的一个热点问题,旨在从不重叠视域的摄像头拍摄的图像或视频中,确认目标行人的

身份^[1-5]。近年来,行人重识别技术随着深度学习的发展取得了显著成效。然而,实际应用中这一技术仍然面临诸多挑战。当前,导致行人重识别领域的核心难点主要包括:目标遮挡、光照变化、视角差异、模态差异、场景变换以及行人姿态变化等。

基金项目: 国家自然科学基金(61305014); 上海市自然科学基金(22ZR1426200)。

作者简介: 马俊磊(2001—),男,本科生,主要研究方向:目标识别与跟踪,图像处理;黄丽(1993—),女,博士,讲师,主要研究方向:目标优化,智能计算;王春媛(1983—),女,博士,副教授,主要研究方向:多源信息协同处理,模式识别,机器学习等。

通信作者: 韩华(1983—),女,博士,教授,主要研究方向:目标识别与跟踪,行人重识别。Email:2070967@mail.dhu.edu.cn。

收稿日期: 2024-06-18

针对上述问题,研究者们提出了多种解决方案,相关研究大致可分为两类:基于全局特征的重识别方法与基于局部特征的重识别方法。基于全局特征的重识别方法主要是从整张图像提取特征。这些特征通常包括行人的整体外观、颜色、形状等全局信息,随后对提取的特征进行相似性度量。基于局部特征的重识别方法是从图像中某些特定区域(如行人的头部、躯干、腿部等)提取特征,这些特征可以捕捉到更细粒度的信息。然后将这些特征分别进行相似性度量,从而达到提高重识别准确率的效果。

然而,上述方法都需要对大量的数据进行标注,需要耗费大量的人力和财力,从长期来看,依赖大量人工的标注数据在实际场景中落地是很困难的。但无监督的行人重识别方法可以很好地避免这一问题,因此受到广大学者的广泛关注。

在无监督的行人重识别研究中,不同相机拍摄的图像受到环境因素的影响,容易导致同一行人图片在不同相机下呈现出较大的差异。而聚类算法是通过分析数据的内在结构,将数据点分组,从而生成伪标签。较大的特征差异将导致同一行人的样本难以准确打上相同的标签,使得生成的伪标签含有噪声。

伪标签噪声将严重影响无监督行人重识别的识别性能。为此,很多学者进行了富有成效的研究,比如:Ge等^[6]提出一种对比学习,该方法通过逐步获得更可靠的簇的方式,实现伪标签细化。Zhang等^[7]为了降低标签噪声,提出了一种聚类共识矩阵的标签传播方案,可以让连续两次迭代得到的聚类结果一致。Ge等^[8]和Zhai等^[9]提出了一种相互教与学的方法,这种方法通过两个模型互相之间的监督和指导,可以生成更加准确的伪标签。具体来说,一个模型的预测结果可以作为另一个模型的监督信号,反之亦然。这种双向的监督机制有助于提高伪标签的准确性,从而提升模型的整体性能。Cho等^[10]利用图像样本全局和局部特征的互补特性来优化伪标签。Wu等^[11]提出了一种多质心记忆(MCM)方法,能够自适应地捕捉聚类当中不同身份的信息,从而有效缓解标签噪声问题。此外,提出了两种策略来改进对比学习过程:域特定对比学习(DSCL)机制和二阶最近插值(SONI)。这些方法被集成到一个统一的框架中,称为多质心表示网络(MCRN)。Chen等^[12]提出了一种名为Inter-instance Contrastive Encoding(ICE)的方法,ICE通过利用实例间的成对相似度得分,使用相似度排名

作为硬实例对比的独热编码伪标签来减少类内差异,并使用相似度得分调整增强视图和原始视图之间的特征一致性。从而提升模型的鲁棒性。Chen等^[13]提出了一种协同的双聚类教学网络(Dual Clustering Co-Teaching, DCCT),该方法利用两个网络提取的特征,通过不同参数的聚类分别生成两组伪标签,并用对方网络生成的伪标签进行训练,从而增强网络互补性,减少噪声影响。此外,提出了动态参数双聚类(DCDP),使网络能够适应动态变化的聚类参数,并通过一致样本挖掘(Consistent Sample Mining, CSM)在训练过程中找到标签不变的样本,去除潜在的噪声样本。Lan等^[14]提出了一种标签噪声净化的模块,利用离线教师模型的知识来净化标签噪声。首先从噪声的伪标签中训练一个教师模型,然后利用教师模型指导学生模型的学习,使学生模型能够在教师模型的监督下快速收敛,从而减少噪声标签的干扰^[15]。

本文利用特征的相似性来细化伪标签,降低了全局特征聚类中的噪声。首先,将由全局特征和局部特征得到的交叉一致性得分与对比损失作为衡量特征相似性的标准,然后根据该得分和对比损失对伪标签进行标签平滑处理,再利用局部特征进一步细化伪标签。

本文的贡献如下:

(1)提出了一种基于特征相似性的伪标签优化框架。该方法利用全局特征和局部特征的相似性来优化伪标签,达到提升模型性能的效果。

(2)提出一种特征相似性的获取方法,用于提取局部特征和全局特征的互补信息。

1 方法

1.1 流程框架

如图1所示,本文方法基于聚类方法^[16-18],采用聚类阶段与训练阶段交替执行的策略。

在聚类阶段,本文通过对未标记数据集的全局特征进行聚类来分配伪标签。然后,通过交叉计算得到交叉一致性得分与优质局部特征,通过对比损失得到优质局部特征和对应全局特征的互补信息。交叉一致性得分和对比损失共同构建了局部特征和全局特征的相似性度量准则。

交叉计算方式:通过对每个特征空间执行 k 近邻搜索,并根据全局特征和局部特征的前 k 个排名之间的相似性计算出交叉一致性分数,再依据该分数筛选出优质局部特征。

在训练阶段,使用优化后的伪标签训练模型。优化伪标签时,首先根据每个部分的交叉一致性分数对标签进行平滑处理(标签平滑),再通过汇总局部特征的预测结果来细化全局特征的标签(部分特征引导的标签细化)。

1.2 伪标签优化基础框架流程

形式上,设 $D = \{x_i\}_{i=1}^{N_D}$ 表示未标记的训练数据集,其中 x_i 是单张图像, N_D 表示图像数量。模型首先提取图像 x_i 的全局特征,表示为 $F_g(x_i) \in \mathbb{R}^{C \times H \times W}$,其中, \mathbb{R} 为实数域, C 、 H 和 W 分别表示特征的通道数、高度和宽度,表示全局特征是一个具有 C 个通道、高度为 H 、宽度为 W 的张量,且这些元素

都属于实数。基于该特征图,对整个特征图的所有数值执行全局平均池化,得到一个单一的全局特征 f_i^g 。然后将特征图划分为 N 个均匀划分的区域 $R^{C \times H \times W}$,对每个区域内的数值进行平均池化,从而得到每个区域的特征值。最终,这些区域的特征值就组成了局部特征。

接下来是伪标签的生成,根据文献中基于局部特征的方法^[19-21],采用平滑的方式处理全局特征和局部特征共享的伪标签。其中全局特征和局部特征共享相同的伪标签。对全局特征集执行 DBSCAN 聚类^[22],并使用聚类结果作为伪标签。将图像 x_i 的伪标签表示为 $y_i \in \mathbb{R}^K$ 。

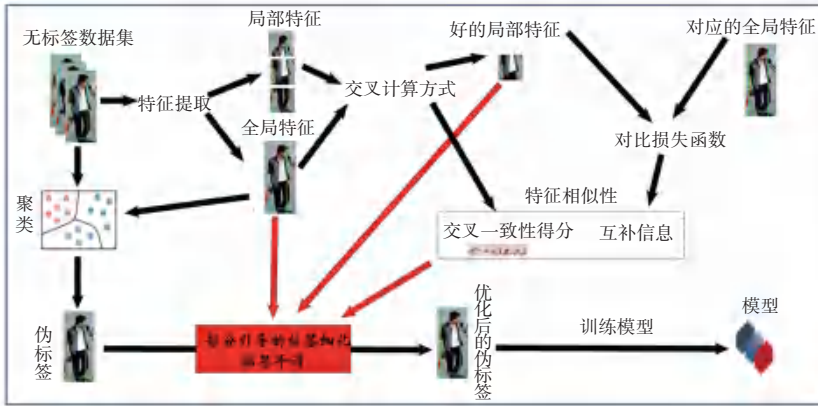


图 1 伪标签优化框架

Fig. 1 Pseudo-label optimization framework

然后使用伪标签得到的全局特征和局部特征训练行人重识别模型。对于全局特征,通过以下方式计算交叉熵损失:

$$\zeta_{gce} = - \sum_{i=1}^{N_D} y_i \times \log(\mathbf{q}_i^g) \quad (1)$$

其中, $\mathbf{q}_i^g = h_{\psi_g}(f_i^g) \in \mathbb{R}^K$ 是全局特征的预测向量, $h_{\psi_g}(\cdot)$ 是由全连接层和 Softmax 函数组成的全局特征分类器。

使用交叉熵损失训练局部特征:

$$\zeta_{pce} = - \frac{1}{N_P} \sum_{i=1}^{N_D} \sum_{n=1}^{N_P} y_i \times \log(\mathbf{q}_i^{p_n}) \quad (2)$$

其中, $\mathbf{q}_i^{p_n} = h_{\psi_{p_n}}(f_i^{p_n}) \in \mathbb{R}^K$ 表示第 n 个局部特征空间 p_n 的预测向量, $h_{\psi_{p_n}}$ 是局部特征空间 p_n 的分类器。

使用的 Softmax 三元组损失如下式:

$$\zeta_{\text{triplet}} = - \sum_{i=1}^{N_D} \log\left(\frac{e^{\|f_i^g - f_{i,n}^g\|}}{e^{\|f_i^g - f_{i,p}^g\|} + e^{\|f_i^g - f_{i,n}^g\|}}\right) \quad (3)$$

其中, $\|\cdot\|$ 表示 L2-形式,下标 (i,p) 和 (i,n)

分别表示通过硬批三元组 (Hard Batch Triplet Selection) 选择^[23]获得的小组图中图像 x_i 的最硬正样本和最硬负样本。

通过硬批三元组选择策略获得锚点样本对应的最硬正样本和最硬负样本后,对具有相同相机标签 a 且属于同一聚类 b 的样本计算其特征质心,该质心被定义为相机感知代理 $c(a,b)$ 。其计算公式如下:

$$c(a,b) = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i \quad (4)$$

式中: N 为相机标签 a 、聚类 b 对应的样本总数,假设特征向量为 \mathbf{x}_i , \mathbf{x}_i 为该集合中第 i 个样本的特征向量 ($i = 1, 2, \dots, N$)。

相机间对比损失^[24] 计算如下式:

$$\zeta_{\text{cam}} = - \sum_{i=1}^{N_D} \frac{1}{|P_i|} \sum_{j \in P_i} \log \frac{\exp(c_j^T f_i^g / \tau)}{\sum_{k \in P_i \cup Q_i} \exp(c_k^T f_i^g / \tau)} \quad (5)$$

其中, P_i, Q_i 为 f_i^g 的正、负相机感知代理的指标集, τ 为温度参数,用于调整相似度的尺度。该损失函数可将同一集群内不同摄像机视角下的图像特征的聚合代表点进行聚合,有效减少了由不相交的摄

像机视图引发的类内方差。

2 框架改进

2.1 伪标签优化-加强全局与局部的互补信息

由于全局特征和局部特征的相似度结构不同,二者存在不可靠的互补信息。部分局部特征包含了与行人无关的冗余信息,难以对全局特征进行有效的伪标签优化。而全局特征仅考虑全局上下文,有时会忽略与局部特征相关的信息。因此,本文引入交叉一致性得分和均方误差损失来降低上述问题带来的负面影响。

交叉一致性得分为全局特征和部分特征的 k 近邻之间的 Jaccard 相似度。首先,本文在全局特征和每个局部特征空间上独立进行 k 近邻搜索,为每个图像生成 $(1 + Np)$ 个排序列表。然后,计算图像 x_i 的全局特征空间 g 和第 n 个部分特征空间 p_n 之间的交叉一致性得分,具体步骤如下:

$$c_i(g, p_n) = \frac{|R_i(g, k) \cap R_i(p_n, k)|}{|R_i(g, k) \cup R_i(p_n, k)|} \in [0, 1] \quad (6)$$

其中, $R_i(g, k)$ 和 $R_i(p_n, k)$ 分别是由 f_i^g 和 $f_i^{p_n}$ 计算出的排序列表中前 k 个样本的索引集合, $|*|$ 表示集合的基数(即集合中元素的数量)。直观来看,较高的得分表明 g 和 p_n 的特征空间在数据点 i 周围具有高度相关的特征相似结构,可以提供可靠的互补信息。较低的得分则表明全局特征和部分特征不是很相关,意味着可能会提供不可靠的信息。

有了交叉一致性得分,可以得到好的局部特征和对应的全局特征。假设有好的局部特征 y_{pred_i} 和对应的全局特征 y_{true_i} , 则均方误差损失函数的计算公式为:

$$\text{MSE}_{\text{loss}} = \frac{1}{n} \sum_{i=1}^n (y_{\text{pred}_i} - y_{\text{true}_i})^2 \quad (7)$$

将计算得到的均方误差损失作为交叉一致性得分的辅助,两者共同构建了全局特征和局部特征的特征相似性。

2.2 伪标签优化-标签平滑

在模型训练过程中,可能存在对训练效果产生负面影响的局部信息。例如,一些区域可能包含与目标无关的信息(如遮挡物)。为降低这些局部特征的影响,本文使用标签平滑^[25-26]方法,依据交叉一致性得分对伪标签进行优化。

给定图像 x_i 的伪标签 y_i , 局部特征 $f_i^{p_n}$ 的标签

平滑公式如下式:

$$y_i^{p_n} = a_i^{p_n} y_i + (1 - a_i^{p_n}) \mathbf{u} \quad (8)$$

其中, \mathbf{u} 为均匀分布的概率向量, $a_i^{p_n}$ 为确定标签平滑强度的权重。与对 $a_i^{p_n}$ 使用恒定权重的传统标签平滑不同,本文使用交叉一致性得分来动态调整每个部分的权重。然后,将优化的伪标签 $y_i^{p_n}$ 代入公式(2)。利用 Kullback-Leibler (KL) 散度^[27]重新表述上文的训练局部特征的交叉熵损失:

$$\zeta_{\text{aals}} = \frac{1}{N_p} \sum_{i=1}^{N_D} \sum_{n=1}^{N_p} (a_i^{p_n} H(y_i, q_i^{p_n}) + (1 - a_i^{p_n}) D_{\text{KL}}(\mathbf{u} \parallel q_i^{p_n})) \quad (9)$$

其中, $H(\cdot, \cdot)$ 和 $D_{\text{KL}}(\cdot \parallel \cdot)$ 分别是交叉熵和 KL 散度,这两项由 $a_i^{p_n}$ 与交叉一致性得分 $C_i(g, p_n)$ 的值共同平衡。

公式(9)中,前一项将预测逼近到 y_i 的高置信度区域,后一项鼓励预测收敛到均匀分布的概率向量 \mathbf{u} , 即希望预测结果更平滑,避免过拟合而产生的错误预测。通过用交叉一致性得分缩放两个相反的项,根据每个循环的伪标签的可靠性来校准局部特征的预测。

2.3 伪标签优化-部分特征引导的标签细化

上下文丰富的局部特征信息可以用来处理全局特征聚类中经常忽略细粒度信息的标签噪声。然而,由于判别性较小的部分可能会提供误导性信息,因此本文根据每个交叉一致分数,将不同权重的局部特征的预测汇总在一起,从而用更可靠的信息精炼伪标签。

本文通过以下方式使用局部特征来优化伪标签 \tilde{y}_i^g :

$$\tilde{y}_i^g = \beta y_i + (1 - \beta) \sum_{n=1}^{N_p} w_i^{p_n} q_i^{p_n} \quad (10)$$

其中, $w_i^{p_n} = \frac{\exp(C_i(g, p_n))}{\sum_k \exp(C_i(g, p_k))}$ 和 $q_i^{p_n}$ 分别是局

部特征 $f_i^{p_n}$ 的权重和预测向量。 $\beta \in [0, 1]$ 是控制一个未标记数据的预测标签与集合预测之比的加权参数。与全局特征不同的是,公式(10)中的部分引导的标签细化额外考虑了局部特征的细粒度预测,其与交叉一致性得分所捕捉的信息可靠性成比例。然后将优化的标签 \tilde{y}_i^g 插入到公式(1)中,重新表述上文训练全局特征的交叉熵损失:

$$\zeta_{\text{pplr}} = - \sum_{i=1}^{N_D} \tilde{y}_i^g \cdot \log(q_i^g) \quad (11)$$

全局特征通过组合多个局部特征的预测结果来获取更准确的标签,学习到更加详细且丰富的特征信息,而这些信息在以前的方法中往往被忽略。此外,与之前使用辅助教师网络细化伪标签的研究不同^[28-29],部分特征引导的标签细化是一种轻量级网络的自学方法,计算效率更高。

本文的方法从3个方面有效地降低了噪声标签的影响。公式(9)中的局部特征具有低交叉一致性,舍去了对训练效果产生负面影响的局部信息;公式(11)的全局特征具有从局部特征中获取可靠的细粒度信息;公式(6)和公式(7)得到的交叉一致性得分和对比损失构成了局部特征和全局特征的相似性,当所有局部特征预测的交叉一致性分数都很低时,由于所有局部特征的标签平滑效应,局部特征引导的标签预测最终会形成一个均匀向量,导致无效的训练,从而达到削弱伪标签噪声的目的,从而获得更好的伪标签。

3 实验结果和分析

3.1 数据集与评价指标

为了评估模型效果,本文在大规模行人重识别公开数据集 Market-1501 上开展实验。Market-1501 数据集是在清华大学校园中,由6台相机拍摄,包含1501名行人的32668张图像。本文采用 CMC 和 mAP 作为评价指标。CMC 是评估图像匹配或检索系统性能的一种指标。用于衡量在前 K 幅图像中出现正确匹配的概率。Rank-1、Rank-5 和 Rank-10 分别表示在不同数量的候选图像中找到正确匹配的概率,从而提供了对系统匹配性能的详细评估。mAP 通过计算每个查询图像的准确率-召回率曲线得出。在这些实验中,本文使用了在 ImageNet 数据集上预训练的 ResNet-50 作为主干模型。在此基础上,本文去除了最后一个卷积层之后的所有层,并添加了一个全局平均池化层。接着,采用 BNNeck^[30] 技术,该方法包括了一个全连接的分层器。在预处理阶段,图片尺寸被调整为 384×128 。为了增加数据的多样性,对图像进行了随机翻转、裁剪和擦除等操作。每个训练批次包含64张图像。由16个伪类和每类4个图像组成。采用权值衰减为 5×10^{-4} 的 Adam^[31] 进行训练。初始学习率设置为 3.5×10^{-4} ,每隔20个 epoch 学习率降低10倍。总共训练50个 epoch,每个 epoch 包含400次迭代。使用基于 Jaccard 距离的 DBSCAN 和 k -倒数编码^[32] 进行聚类。同时设置样本分割的数目 N_p 为

3,权重参数 β 为 0.5,交叉一致分数参数 k 为 20。根据 CAP^[33],本文设置 $\tau = 0.07$, $\lambda_{\text{cam}} = 0.5$,困难负样本的数量为 50。

3.2 结果和分析

本文基于较大数据集 Market-1501 进行实验。表1、图2为无相机标签下的实验结果。由于该数据集规模较大,更接近于真实的监控场景,模型识别的准确率明显优于其它模型。本文算法的 rank-1 为 84.9%,比较 HCT 算法的 rank-1 值高出 4.9%;比 MMCL 高出 4.6%;比 BUC 高出 18.7%;常用行人重识别大多注重全局特征,而忽略了对行人重新识别至关重要的细粒度信息。本文方法考虑了全局特征和局部特征之间的互补关系,利用两者的特征相似性共同减轻了全局特征的标签噪声。

表1 在 Market-1501 上的结果比较(无标签的无监督方法)

Table 1 Comparison results on Market-1501 (Unsupervised methods without any labels)

数据集	Market-1501			
	mAP/%	Rank-1/%	Rank-5/%	Rank-10/%
本文	67.4	84.9	91.5	93.8
HCT ^[34]	56.4	80.0	91.6	95.2
MMCL ^[35]	45.5	80.3	89.4	92.3
BUC ^[36]	38.3	66.2	79.6	84.5

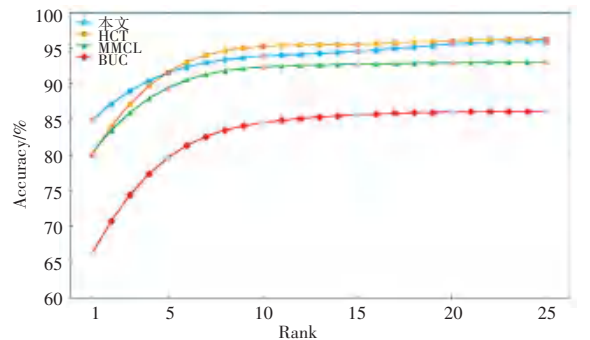


图2 基于 Market-1501 的 CMC 曲线(无标签的无监督方法)

Fig. 2 CMC curve on Market-1501 (Unsupervised methods without any labels)

表2、图3是在有相机标签下的实验结果。本文的方法利用了各种特征相似度结构,专注于利用细粒度行人重新识别所需的全局和局部相似度信息,利用特征相似度结构之间的互补信息。实验中,本文算法的 mAP 为 74.5%,比 SSL 算法的 mAP 高出 36.7%;比 JVTC 高出 27%;比 IICS 高出 1.6%;

在图4中,(1)本文算法在数据集上的 Top-10 排序列表;(2)为基础模型在数据集上的 Top-10 排序列表。其中,没有边框的图像代表查询图像,带有绿色边框的图像表示正确匹配的图像,而带有红色

边框的图像则表示错误匹配的图像。通过图4中的实验结果对比,可以明显地看到本文算法正确率更高,模型性能更好。

表2 在Market-1501上的结果比较(有相机标签的无监督方法)

Table 2 Comparison results on Market-1501 (Unsupervised methods using camera labels)

数据集	Market-1501			
	mAP/%	Rank-1/%	Rank-5/%	Rank-10/%
本文	74.5	88.1	94.8	96.3
SSL ^[37]	37.8	71.7	83.8	87.4
JVTC ^[38]	47.5	79.5	89.2	91.9
HCS ^[39]	72.9	89.5	95.2	97.0




图3 基于Market-1501的CMC曲线(有相机标签的无监督方法)
Fig. 3 CMC curve on Market-1501 (Unsupervised methods using camera labels)



图4 基于Market-150的Top-10排序列表对比图

Fig. 4 Comparison of Top-10 sorting rankedlists on Market-1501

综上所述,本文提出的方法无论在监督情况还是无监督情况下均取得了良好的实验结果,证明了算法的有效性。

4 结束语

本文提出了一种利用迁移学习提取局部特征和全局特征的相似性来优化伪标签的框架,用于无监督行人重识别。该方法利用图像的全局和局部上下文,并利用全局和局部特征之间的互补关系减轻每个特征空间的标签噪声。并且该方法还引入对比损失函数和交叉一致性得分来获得可靠的互补信息,

在此基础上对伪标签进行细化。大量的实验表明了本文方法的有效性,相比先前的优秀方法,取得了更高的准确率。

参考文献

- [1] ZHENG L, YANG Y, HAUPTMANN A G. Person re-identification: past, present and future[J]. arXiv,1610.02984,2016.
- [2] LIN Y, ZHENG L, ZHENG Z, et al. Improving person re-identification by attribute and identity learning [J]. Pattern Recognition, 2019, 95: 151-161.
- [3] LI W, ZHU X, GONG S. Harmonious attention network for person re-identification[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE,2018: 2285-2294.
- [4] YE M, SHEN J, LIN G, et al. Deep learning for person re-identification: A survey and outlook [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2021,44(6):2872-2893.
- [5] ZHENG Z, ZHENG L, YANG Y. Unlabeled samples generated by gan improve the person reidentification baseline in vitro [C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ:IEEE, 2017: 3754-3762.
- [6] GE Y X, ZHU F, CHEN D P, et al. Self-paced contrastive learning with hybrid memory for domain adaptive object reID [C]//Proceedings of the 34th International Conference on Neural Information Processing Systems. NeurIPS, 2020:11309-11321.
- [7] ZHANG X, GE Y X, QIAO Y, et al. Refining pseudo labels with clustering consensus over generations for unsupervised object re-identification [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2021: 3435-3444.
- [8] GE Y X, CHEN D P, LI H S. Mutual mean-teaching: Pseudo label refinery for unsupervised domain adaptation on person reidentification [C]//Proceedings of the 8th International Conference on Learning Representations. ICLR, 2020:1-17.
- [9] ZHAI Y P, YE Q X, LU S J, et al. Multiple expert brainstorming for domain adaptive person re-identification [C]//Proceedings of the 16th European Conference on Computer Vision. Cham: Springer,2020: 594-611.
- [10] CHO Y, KIM W J, HONG S, et al. Part-based pseudo label refinement for unsupervised person reidentification [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ:IEEE,2022: 7298-7308.
- [11] WU Y H, HUANG T T, YAO H T, et al. Multi-centroid representation network for domain adaptive person reID [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2022: 2750-2758.
- [12] CHEN H, LAGADEC B, BREMOND F. ICE: Inter-instance contrastive encoding for unsupervised person reidentification [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway, NJ:IEEE,2021: 14940-14949.
- [13] CHEN Z Q, CUI Z C, ZHANG C, et al. Dual clustering co-teaching with consistent sample mining for unsupervised person reidentification [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33(10): 5908-5920.
- [14] LAN L, TENG X, ZHANG J, et al. Learning to purification for unsupervised person re-identification [J]. IEEE Transactions on

- Image Processing, 2023,33: 3338–3353.
- [15]程思雨,陈莹.伪标签细化引导的相机感知无监督行人重识别方法[J].光电工程,2023,50(12):230239.
- [16]LIN Y T, DONG X Y, ZHENG L, et al. A bottom-up clustering approach to unsupervised person re-identification[C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI,2019: 8738–8745.
- [17]ZENG K E, NING M N, WANG Y H, et al. Hierarchical clustering with hard - batch triplet loss for person re-identification[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ;IEEE,2020: 13654–13662.
- [18]ZHANG X, GE Y X, QIAO Y, et al. Refining pseudo labels with clustering consensus over generations for unsupervised object re-identification[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ; IEEE, 2021;3435–3444.
- [19]SUN Yifan, ZHENG Liang, YANG Yi, et al. Beyond part models: Person retrieval with refined part pooling (and a strong convolutional baseline) [C]//Proceedings of the European Conference on Computer Vision. Cham; Springer, 2018: 501 – 518.
- [20]WANG Guanshuo, CHEN Xiong, et al. Learning discriminative features with multiple granularities for person re - identification [C]//Proceedings of the ACM International Conference on Multimedia. New York;ACM,2018;274–282.
- [21]ZHENG Feng, DENG Cheng, SUN Xing, et al. Pyramidal person re - identification via multi - loss dynamic training [C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ;IEEE, 2019; 8506–8514.
- [22]ESTER M, KRIEGEL H P, SANDER J, et al, et al. A density-based algorithm for discovering clusters in large spatial databases with noise [C]//Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York; ACM, 1996: 226–231.
- [23]HERMANS A, BEYER L, LEIBE B. In defense of the triplet loss for person re-identification[J]. arxiv,1703.07737v4,2017.
- [24]WANG Menglin, LAI Baisheng , HUANG Jianqiang , et al. Camera-aware proxies for unsupervised person re-identification [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI,2021;2764–2772.
- [25]LUKASIK M, BHOJANAPALLI S, MENON A, et al. Does label smoothing mitigate label noise? [C]//Proceedings of the 37th International Conference on Machine Learning. ICML, 2020; 6448–6458.
- [26]SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ;IEEE, 2016: 2818–2826.
- [27]PEREYRA G, TUCKER G, CHOROWSKI J, et al. Regularizing neural networks by penalizing confident output distributions [J]. arXiv preprint arXiv,1701.06548, 2017. DOI:10.48550/arXiv, 1701.06548.
- [28]GE Yixiao, CHEN Dapeng, LI Hongsheng . Mutual mean teaching: Pseudo label refinery for unsupervised domain adaptation on person re-identification [C]//Proceedings of the International Conference on Learning Representations (ICLR). 2020.
- [29]ZHAI Yunpeng, YE Qixiang, LU Shijian, et al. Multiple expert brainstorming for domain adaptive person re-identification [C]//Proceedings of the European Conference on Computer Vision. Cham;Springer,2020: 594–611.
- [30]LUO Hao, JIANG Wei, GU Youzhi, et al. A strong baseline and batch normalization neck for deep person re - identification [J]. IEEE Transactions on Multimedia, 2020, 22(10); 2597–2609.
- [31]KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. arXiv preprint arXiv,1412.6980,2014. DOI:10.48550/arXiv,1412.6980.
- [32]ZHONG Z, ZHENG L, CAO D L, et al. Re-ranking person re-identification with k-reciprocal encoding [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ: IEEE, 2017; 1318–1327.
- [33]WANG Menglin, LAI Baisheng, HUANG Jianqiang, et al . Camera-aware proxies for unsupervised person re - identification [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2021;2764–2772.
- [34]ZENG Kaiwei, NING Munan, WANG Yaohua, et al. Hierarchical clustering with hard-batch triplet loss for person re-identification [C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ;IEEE,2020; 13654–13662.
- [35]WANG Dongkai, ZHANG Shiliang. Unsupervised person reidentification via multi-label classification [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ; IEEE, 2020; 10981 – 10990.
- [36]LIN Yutian, DONG Xuanyi, ZHENG Liang, et al. A bottom-up clustering approach to unsupervised person re-identification [C]// Proceedings of the AAAI Conference on Artificial Intelligence. AAAI,2019: 8738–8745.
- [37]LIN Yutian, XIE Lingxi, WU Yu, et al. Unsupervised person re-identification via softened similarity learning [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ;IEEE,2020; 3387–3396.
- [38]LI Jianing, ZHANG Shiliang. Joint visual and temporal consistency for unsupervised domain adaptive person re - identification [C]//Proceedings of European Conference on Computer Vision. Cham;Springer,2020; 483–499.
- [39]XUAN Shiyu, ZHANG Shiliang. Intra-inter camera similarity for unsupervised person re - identification [C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ; IEEE, 2021; 11921 – 11930.