

控制与决策

Control and Decision

基于分布约束的非对称度量学习无监督行人重识别

刘月, 邹国锋, 陈贵震, 翟文哲, 高明亮

引用本文:

刘月, 邹国锋, 陈贵震, 翟文哲, 高明亮. 基于分布约束的非对称度量学习无监督行人重识别[J]. *控制与决策*, 2023, 38(6): 1703–1711.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1598>

您可能感兴趣的其他文章

Articles you may be interested in

[基于通道信息对齐的素描行人重识别](#)

Channel information alignment for sketch re-identification

控制与决策. 2022, 37(12): 3129–3138 <https://doi.org/10.13195/j.kzyjc.2021.0988>

[自适应感受野网络的行人重识别](#)

Adaptive receptive network for person re-identification

控制与决策. 2022, 37(1): 119–126 <https://doi.org/10.13195/j.kzyjc.2020.0505>

[融合块对角约束的鲁棒低秩多核聚类](#)

Low-rank robust multiple kernel clustering with block diagonal constraints

控制与决策. 2022, 37(11): 2977–2983 <https://doi.org/10.13195/j.kzyjc.2021.0566>

[行人重识别中度量学习方法研究进展](#)

A survey on metric learning in person re-identification

控制与决策. 2021, 36(7): 1547–1557 <https://doi.org/10.13195/j.kzyjc.2020.0801>

[人脸性别约束下的深度随机森林表情识别](#)

Facial expression recognition using deep random forest under gender constraints

控制与决策. 2021, 36(7): 1693–1698 <https://doi.org/10.13195/j.kzyjc.2019.1703>

基于分布约束的非对称度量学习无监督行人重识别

刘月, 邹国锋[†], 陈贵震, 翟文哲, 高明亮

(山东理工大学 电气与电子工程学院, 山东 淄博 255049)

摘要: 在无监督行人重识别中, 针对传统非对称度量学习方法无法克服不同视角的数据分布差异问题, 提出一种基于分布约束的非对称度量学习无监督行人重识别方法. 首先, 采用 JSTL 技术对特征提取网络预训练, 得到具有较强鲁棒性的特征表示; 然后, 提出基于分布约束的非对称度量学习算法, 通过在传统非对称度量学习目标函数中引入分布约束, 实现不同摄像视角下行人图像非对称特征变换的同时, 有效克服特征空间中行人数据分布差异导致的识别精确度低的问题; 最后, 采用梯度下降法优化目标函数, 并通过广义特征值问题求解获得最优度量矩阵. 基于 Market 和 Duke 两个公共数据集的实验表明, 该算法的 rank1 值分别达到 57.01% 和 32.32%, MAP 值分别达到 27.91% 和 16.00%, 与传统非对称度量学习算法相比识别性能有明显提升.

关键词: 行人重识别; 无监督; 特征变换; 非对称度量学习; 分布约束; 特征空间

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1598

引用格式: 刘月, 邹国锋, 陈贵震, 等. 基于分布约束的非对称度量学习无监督行人重识别[J]. 控制与决策, 2023, 38(6): 1703-1711.

Asymmetric metric learning approach based on distribution constraints for unsupervised person re-identification

LIU Yue, ZOU Guo-feng[†], CHEN Gui-zhen, ZHAI Wen-zhe, GAO Ming-liang

(School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China)

Abstract: In unsupervised person re-identification, to solve the problem that the traditional asymmetric metric learning method cannot overcome the difference of data distribution from different views, an asymmetric metric learning approach based on distribution constraints for unsupervised person re-identification is proposed. Firstly, JSTL technology is used to pre-train the feature extraction network to obtain a robust feature representation. Then, the asymmetric metric learning method based on distribution constraints is proposed. By introducing distribution constraints into the traditional asymmetric metric learning objective function, this method not only realizes the asymmetric feature transformation of person images from different camera views, but also effectively overcomes the problem of low recognition accuracy caused by the difference of person data distribution. Finally, the objective function is optimized by using the gradient descent method, and the optimal measure matrix is obtained by solving the generalized eigenvalue problem. Experiments are implemented on Market and Duke datasets, and the results show that the rank1 value of the algorithm is 57.01% and 32.32%, the MAP value is 27.91% and 16.00%, respectively, and the recognition performance of the algorithm is significantly improved compared with the traditional asymmetric metric learning algorithm.

Keywords: person re-identification; unsupervised; feature transformation; asymmetric metric learning; distribution constraints; feature space

0 引言

行人重识别 (person re-identification) 是跨视域行人身份关系的匹配过程, 属于典型的图像检索问题^[1-2]. 目前, 行人重识别已成为智能视频监控领域的

研究热点, 但遮挡、行人姿态变化、摄像机分辨率差异、拍摄视角不同等因素给行人重识别研究带来了巨大挑战^[3-4].

目前, 行人重识别的研究工作主要集中于行人的

收稿日期: 2021-09-13; 录用日期: 2022-03-15.

基金项目: 国家自然科学基金项目 (61801272); 淄博市张店区校城融合项目 (118228); 山东省自然科学基金项目 (ZR2015FL029, ZR2016FL14); 山东省重点研发计划项目 (重大科技创新工程项目) (2019JZZY010119).

责任编辑: 张文安.

[†]通讯作者. E-mail: zgf841122@163.com.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

特征表示^[5-6]和距离度量^[6-7].特征表示通过机器学习算法捕获有较强判别性和鲁棒性的特征,其中基于深度学习算法^[8-10]的特征提取性能展现了较大的优势.度量学习是通过设计一种度量损失函数,用最优化方法求得距离度量矩阵的过程.已有研究成果能有效缓解上述挑战,但这些方法多数为有监督算法,严重依赖于海量的高质量标注图像.然而,图像标注成本昂贵,且标注准确度难以保证,有监督行人重识别方法也面临较多的限制,因此,近年来基于无监督学习的行人重识别越来越受到研究者的青睐.

在特征表示方面,Matsukawa等^[11]提出了一种高层次高斯区域描述符,所提出的描述符可以同时描述每个块和区域层次中像素特征的均值和协方差信息,用以生成描述颜色和纹理信息的鉴别性和鲁棒性特征;除提取颜色、纹理、属性等特征以外,行人步态也可作为识别特征,责睨焯等^[12]对行人步态识别的现状进行综述,并对步态识别的各种方法进行了总结与分析.Zhang等^[13]针对长时间行走轨迹问题提出了SpTSkM的双流网络框架学习混合特征表示,该网络同时学习身份属性和运动形态,对长时间行人重识别中的外观变化具有鲁棒性,同时保持足够的判别能力区分不同的行人;Fan等^[14]提出了一种渐进式无监督学习方法,该方法在深度学习网络的聚类与微调之间进行迭代;Feng等^[15]提出了一种针对特定视角的深度网络,其目的是学习与视角相关的深度特征表示;在度量学习方面,He等^[16]提出了非对称稀疏表示方法,将来自不同视角的样本使用不同映射投影到共享空间,并在该空间中学习稀疏表示;Chen等^[17]提出了一种针对视角的度量学习算法,将不相交视角的特征投影到新的自适应空间中,在自适应空间中计算行人图像之间的距离;Chen等^[18]设计了一种非对称度量学习算法,为每个摄像头视角分配一个变换矩阵,以缓解特定视角带来的偏差.

基于度量学习的行人重识别是所有行人图像学习一致性特征变换,进而实现距离度量.但受遮挡、光照和不同拍摄角度等不可控因素干扰,跨视角行人图像存在较大偏差,同时跨视角行人图像通常没有标签引导,因此已有度量学习方法难以实现同一行人不同视角图像的分布对齐,而学习得到的一致性特征变换很难捕捉到显著的判别特征.针对该问题,Yu等^[19]和Feng等^[20]提出了基于聚类的非对称度量学习算法,并将其用于无监督行人重识别.该方法针对不同视角行人图像,采用聚类算法优化目标函数,学习获得非一致特征变换,将不同视角行人图像映射到共享空间,弱化了不同视角行人图像的偏差,但该方法无

法完全解决跨视角行人图像分布未对齐的问题.

综上所述,本文提出一种基于分布约束的非对称度量学习无监督行人重识别方法.首先,采用JSTL预训练技术对特征提取网络预训练,得到具有较强判别性和鲁棒性的特征表示.其次,对行人特征进行特征投影.考虑到不同视角行人图像偏差问题,采用非对称度量方法,即每个视角学习非一致的特征变换函数,投影到共享空间中,得到两样本之间的距离度量函数.行人图像经过非对称度量投影到特征空间中,但行人特征仍存在分布差异,因此在特征空间中,提出分布约束的思路,即采用最大均值差异方法提高行人图像在变换空间后分布的相似性.最后,采用广义特征值方法实现带分布约束目标函数的优化求解,获得最优度量矩阵,并基于Market和Duke两个公共数据集的实验验证所提算法的有效性.

1 非对称度量学习算法简介

1.1 度量和非对称度量的定义

假设两个行人样本为 x_i 和 x_j ,经典度量学习是通过学习一个特征变换矩阵,将样本投影到共享空间,在共享空间中实现两样本距离度量.经典距离度量的定义为

$$d(x_i, x_j) = \sqrt{(x_i - x_j)^T M (x_i - x_j)}. \quad (1)$$

其中: $M = UU^T$ 为距离度量矩阵, U 为变换矩阵.

由于跨视角采集行人图像的视角存在较大差异,基于经典度量学习方法获取的特征变换矩阵难以克服不同视角的偏差,无法获取判别性较强的行人特征.因此,Chen等^[18]提出了非对称距离度量学习的概念,其定义如下:

$$d(x_i^p, x_j^q) = \|U^{pT} x_i^p - U^{qT} x_j^q\|_2. \quad (2)$$

其中: U^p 为第 p 个视角的变换矩阵, x_i^p 为第 p 个视角下的第 i 个样本, x_j^q 为第 q 个视角下的第 j 个样本.

非对称度量学习方法是针对不同视角的行人图像学习一种非一致特征变换,将特征投影到共享空间的同时,缓解不同视角的偏差,达到更好的匹配效果,算法原理如图1所示.

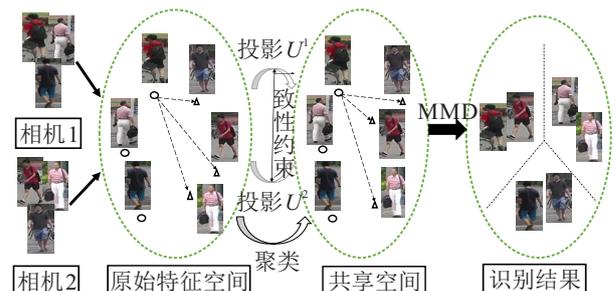


图1 非对称度量的行人重识别

如图1所示,圆圈表示相机1的多人行人图像分布,三角表示相机2的多人行人图像分布,带箭头的虚线表示特征距离. 行人图像在不同视角下采集,相机1光照暗沉,采集行人背面图像,相机2光照明亮,采集行人正面图像,导致行人图像在原始特征空间分布未对齐. 采用非对称度量学习方法,针对视角1学习特征变换 U^1 ,针对视角2学习特征变换 U^2 ,将不同视角的行人特征投影到一共享空间,在共享空间中,相同行人的特征分布更近,不同行人的特征距离更远,从而缓解了不同视角带来的偏差.

1.2 非对称度量学习目标函数

假设监控网络由 V 个摄像机视角组成,从每个视角中收集 $N_p(p = 1, 2, \dots, V)$ 幅行人图像,因此总共有 $N = N_1 + N_2 + \dots + N_v$ 幅行人图像作为训练样本. 在第 V 个视角中,捕获了 N_v 幅行人图像 $X^V = [x_1^V, x_2^V, \dots, x_{N_v}^V] \in R^{M \times N}$,每一列 x_i^V 表示第 V 个视角的第 i 幅行人图像. 本文的目标是学习 V 个特征映射,即 U^1, U^2, \dots, U^V ,其中 $U^P \in R^{M \times T}$,可以将原空间 R^M 中的 x_i^V 投影到共享空间 R^T 中,以减小不同视角带来的偏差.

由于无监督情况下缺乏类别标签指导,非对称度量学习中采用了聚类方法生成伪标签,其目标函数为

$$\begin{aligned} \min_{U^1 \dots U^V} F_{\text{int ra}} &= \sum_{k=1}^K \sum_{i \in C_K} \|U^{pT} x_i^p - Z_k\|^2; \\ \text{s.t. } U^{pT} C^p U^p &= I, P = 1, 2, \dots, V. \end{aligned} \quad (3)$$

其中: U^{pT} 为第 p 个摄像机视角的特定转换; Z_k 为第 k 个簇的聚类中心; $C^p = X^p X^{pT} / N_p + I$ 为协方差矩阵; I 为单位矩阵,用来避免协方差矩阵的奇异性.

特征变换阵 U^p 的最优解依赖于第 p 个视角下的样本分布,一对相似图像的特征表示为 x_i^p 和 x_j^q ,则对应的特征变换阵 U^p 和 U^q 应当是一致的. 但是,由于遮挡和行人视角姿态差异,导致 U^p 与 U^q 并不一致,使特征匹配的难度大大增加. 为解决该问题,非对称度量学习算法将每个投影基对的差值用布雷格曼散度^[21]衡量,即给定一个严格的凸函数 $F: R^{d \times c} \rightarrow R$,则投影基对布雷格曼散度为

$$\begin{aligned} d_F(U^p, U^q) &= \\ F(U^p) - F(U^q) - \nabla F(U^q)^T (U^p - U^q). \end{aligned} \quad (4)$$

其中: ∇F 为 F 的导数, $d_F(U^p, U^q) \geq 0$.

凸函数 F 的选择对算法性能和计算复杂度非常重要,当 $F(x) = x^T x$ 时,布雷格曼散度简化为欧氏距离 $\|U^p - U^q\|_F^2$. 对于所有摄像机视角,该距离为 $\sum_{p \neq q} \|U^p - U^q\|_F^2$,该距离项即为跨视角一致性约束项

$$F_{\text{consistency}} = \sum_{p \neq q} \|U^p - U^q\|_F^2. \quad (5)$$

其中: U^p 和 U^q 为 p 与 q 视角的特征变换, $\|\cdot\|_F$ 为矩阵的Frobenius范数.

综上分析,非对称度量学习的最优化目标函数为

$$\begin{aligned} \min F_{\text{obj}} &= \frac{1}{N} F_{\text{int ra}} + \alpha F_{\text{consistency}} = \\ \frac{1}{N} \sum_{k=1}^K \sum_{i \in C_K} \|U^{pT} x_i^p - Z_k\|^2 &+ \alpha \sum_{p \neq q} \|U^p - U^q\|_F^2; \\ \text{s.t. } U^{pT} C^p U^p &= I. \end{aligned} \quad (6)$$

其中: $F_{\text{int ra}}$ 为无监督聚类损失项, $F_{\text{consistency}}$ 为跨视角一致性约束项, α 为跨视角一致性项权重系数, Z_k 为第 k 个簇的聚类中心, N 为训练样本总数, K 为簇的数目.

该目标函数的目的是学习非一致的特征映射函数,将不同视角的行人图像映射到一个特征空间,在该特征空间中不同视角行人图像的偏差得到缓解.

2 基于分布约束的非对称度量学习算法

2.1 基于分布约束的非对称度量学习目标函数定义

在行人重识别中,存在许多影响因素,如摄像头拍摄视角、场景变化、行人衣着变化等. 采用非对称度量学习的方法,不同视角学习不同特征变换,投影到特征空间,有效克服了摄像头拍摄视角的影响. 但经过非对称度量学习获得的行人特征在特征空间中仍然存在分布差异,即相同行人图像在对应的特征空间位置不相近,如图2所示,其主要原因在于已有的非对称度量学习算法无法克服视角之外的其他干扰. 因此在行人特征空间中,定义了分布约束条件,用于实现行人特征的分布对齐.

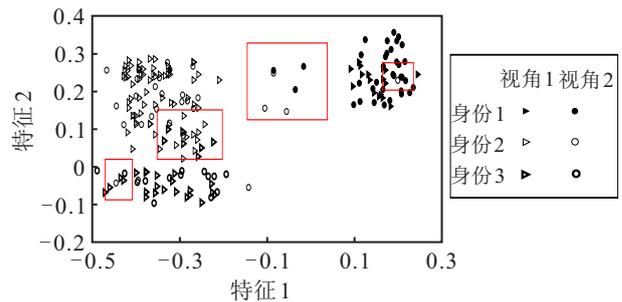


图2 在特征空间中行人特征可视化分布

图2中不同的形状代表不同的视角,实心、空心、半实心代表不同的行人类型. 显然,采用非对称度量学习可以有效缓解拍摄视角带来的偏差,但在矩形框中仍有部分行人特征分布未对齐的情况,因此已有的非对称度量学习并未完全解决分布对齐的情况.

针对已有非对称度量学习算法的不足,本文提出一种融合分布约束的非对称度量学习算法. 在行人特征空间中,采用最大均值差异(maximum mean

discrepancy, MMD)^[20,22]的方法度量不同视角之间分布差异,其本质上是寻找一个变换函数 f ,使得变换后的两域距离最小.最大均值差异是通过计算不同视角的均值差来衡量两个分布间的相似性,其定义为

$$\begin{aligned} \text{MMD}^2 &= \left\| \frac{1}{N_p} \sum_i U^{pT} x_i^p - \frac{1}{N_q} \sum_j U^{qT} x_j^q \right\|_2^2 = \\ & \left\| U^{pT} \frac{1}{N_p} \sum_i x_i^p - U^{qT} \frac{1}{N_q} \sum_j x_j^q \right\|_2^2 = \\ & \|U^{pT} m^p - U^{qT} m^q\|_2^2. \end{aligned} \quad (7)$$

其中: N_p 为第 p 个视角的样本数量, $m^p = \sum_i x_i^p / N_p$ 为在原始特征空间中第 p 个视角的均值.为了提高不同视角下行人图像在变换空间中行人特征分布的相似性,令所有摄像机视角间的均值差异为

$$F_{\text{mmd}} = \sum_{p,q} \text{MMD}^2 = \sum_{p,q} \|U^{pT} m^p - U^{qT} m^q\|_2^2. \quad (8)$$

综上分析,本文提出的基于分布约束的非对称度量学习目标函数定义为

$$\begin{aligned} \min F_{\text{obj}} &= \frac{1}{N} F_{\text{int ra}} + \alpha F_{\text{consistency}} + \beta F_{\text{mmd}} = \\ & \frac{1}{N} \sum_{k=1}^K \sum_{i \in C_k} \|U^{pT} x_i^p - Z_k\|_2^2 + \alpha \sum_{p \neq q} \|U^p - U^q\|_F^2 + \\ & \beta \sum_{p,q} \|U^{pT} m^p - U^{qT} m^q\|_2^2; \\ \text{s.t. } & U^{pT} C^p U^p = I. \end{aligned} \quad (9)$$

其中: F_{mmd} 为数据分布约束项, β 为数据分布约束项权重系数, m^p 为第 p 个视角的均值, m^q 为第 q 个视角的均值.

该目标函数在学习非一致的特征映射函数过程中,考虑投影到特征空间的行人特征仍存在分布差异,采用最大均值差异方法衡量不同视角行人图像分布距离,进而提升行人图像特征在变换子空间分布的相似性.

2.2 基于分布约束的非对称度量学习目标函数求解

为实现基于分布约束的非对称度量学习目标函数求解,首先,分别将无监督聚类损失项、跨视角一致性约束项、数据分布约束项数转化为矩阵表达形式,然后采用梯度下降法对目标函数进行参数优化,最终将参数优化问题转化为广义特征值问题求解.

2.2.1 无监督聚类损失项矩阵表达形式

从行人图像数据集中随机选取一个样本作为聚类中心,由 k -均值聚类可知

$$Z_k = \sum_{k=1}^{n_k} \frac{y_k}{n_k} = \frac{Y e_k}{n_k}. \quad (10)$$

其中: Z_k 为第 k 个簇的聚类中心, $y_k = U^{pT} x_k^p$ 为行人图像转换后的特征表示, $Y = [y_1, y_2, \dots, y_N]$, n_k 为第 k 个视角的样本个数, $e_k = [0, \dots, 0, 1, \dots, 1, 0, \dots, 0]^T$ 为第 k 个簇的聚类样本.

首先,将 y_k 和 Z_k 代入到式(3)中,然后通过 L_2 范数将公式化简,将 \sum 形式转换为 Tr 的形式,则无监督聚类损失项^[23]化简为

$$\begin{aligned} \frac{1}{N} \min F_{\text{int ra}} &= \frac{1}{N} \sum_{k=1}^K \sum_{i \in C_k} \|U^{pT} x_k^p - Z_k\|_2^2 = \\ & \frac{1}{N} \sum_{i \in C_k} \left\| Y - \frac{Y e_k e_k^T}{n_k} \right\|_2^2 = \\ & \frac{1}{N} \sum_{i \in C_k} \text{Tr} \left(Y^T \left(I - \frac{e_k e_k^T}{n_k} \right) Y \right). \end{aligned} \quad (11)$$

其次,设置 $h_k = e_k / \sqrt{n_k}$, $H = [h_1, h_2, \dots, h_k]$,

$h_k^T h_l = \begin{cases} 0, & k \neq l, \\ 1, & k = l, \end{cases}$ 则式(11)化简为

$$\begin{aligned} & \frac{1}{N} \sum_{i \in C_k} \text{Tr} \left(Y^T \left(I - \frac{e_k e_k^T}{n_k} \right) Y \right) = \\ & \frac{1}{N} [\text{Tr}(Y^T Y) - \text{Tr}(H^T Y^T Y H)]. \end{aligned} \quad (12)$$

然后,设置

$$\begin{aligned} \tilde{U} &= [U^{1T}, U^{2T}, \dots, U^{vT}]^T, \\ \tilde{X} &= \begin{bmatrix} x_1^1 & \dots & x_{N_1}^1 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \dots & 0 & x_1^2 & \dots & x_{N_2}^2 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 0 & x_1^v & \dots & x_{N_v}^v \end{bmatrix}. \end{aligned} \quad (13)$$

由式(11)可知

$$Y = \tilde{U}^T \tilde{X}. \quad (14)$$

最后,把式(14)代入(12)中,可得无监督聚类损失项矩阵表达形式为

$$\begin{aligned} \frac{1}{N} \min F_{\text{int ra}} &= \frac{1}{N} \sum_{k=1}^K \sum_{i \in C_k} \|U^{pT} x_i^p - Z_k\|_2^2 = \\ & \frac{1}{N} \text{Tr}(\tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X}) - \frac{1}{N} \text{Tr}(H^T \tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X} H). \end{aligned} \quad (15)$$

其中:

$$\tilde{U} = [U^{1T}, U^{2T}, \dots, U^{vT}]^T, \quad h_k = e_k / \sqrt{n_k},$$

$$H = [h_1, h_2, \dots, h_k],$$

$$\tilde{X} = \begin{bmatrix} x_1^1 & \dots & x_{N_1}^1 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \dots & 0 & x_1^2 & \dots & x_{N_2}^2 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 0 & x_1^v & \dots & x_{N_v}^v \end{bmatrix}.$$

2.2.2 跨视角一致性约束项矩阵表达形式

首先,对于跨视角一致性约束项,由Frobenius范数化简可得

$$\alpha \sum_{p,q} \|U^p - U^q\|_F^2 =$$

$$a\text{Tr}\left((V-1)\sum_{k=1}^V U^{K^T} U^K - 2\sum_{p=1}^{V-1}\sum_{q=p+1}^V U^{p^T} U^q\right). \quad (16)$$

其次, 设置 $\tilde{U} = [U^{1^T}, U^{2^T}, \dots, U^{V^T}]^T, D = \begin{bmatrix} (V-1)I & -I & \dots & -I \\ -I & (V-1)I & \dots & -I \\ \vdots & \vdots & \ddots & \vdots \\ -I & -I & \dots & (V-1)I \end{bmatrix}$, 则跨视角一致性约束项矩阵表达式为

$$\alpha \sum_{p \neq q} \|U^p - U^q\|_F^2 = \alpha \text{Tr}(\tilde{U}^T D \tilde{U}). \quad (17)$$

其中: α 为跨视角一致性项权重系数, V 为相机视角, I 为单位矩阵.

2.2.3 数据分布约束项矩阵表达式

首先, 对于数据分布约束项, 由 L2 范数化简可得

$$\begin{aligned} \beta \min F_{\text{mmd}} &= \beta \sum_{p,q} \|U^{p^T} m^p - U^{q^T} m^q\|_2^2 = \\ &= \beta \text{Tr}\left((V-1)\sum_{k=1}^V U^{K^T} U^K m^{k^T} m^k - \right. \\ &\quad \left. 2\sum_{p=1}^{V-1}\sum_{q=p+1}^V U^{p^T} U^q m^{p^T} m^q\right). \end{aligned} \quad (18)$$

然后, 设置 $\tilde{U} = [U^{1^T}, U^{2^T}, \dots, U^{V^T}]^T$, 则数据分布约束项矩阵表达式为

$$\beta \min F_{\text{mmd}} = \beta \text{Tr}(\tilde{U}^T \tilde{m} L \tilde{m}^T \tilde{U}). \quad (19)$$

其中: $\tilde{m} = \begin{bmatrix} m^1 & 0 & \dots & 0 \\ 0 & m^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & m^v \end{bmatrix}$, m^i 为第 i 个视角的均值;

$L = W - \mathbf{1}$, L 为一个图拉普拉斯矩阵^[24], W 为一个对角矩阵, 即 $W_{ii} = V$, $\mathbf{1}$ 为一个全是 1 的方阵; β 为数据分布约束项权重系数.

约束项表达式为 s.t. $U^{p^T} C^p U^p = I, P = 1, 2, \dots, V$, 改写为 s.t. $\tilde{U}^T \tilde{C} \tilde{U} = VI$, 其中 $\tilde{C} = \text{diag}(C^1, C^2, \dots, C^V)$ 为协方差矩阵. 该约束项能防止 U^p 变为零矩阵, 更能减少繁琐的计算.

综合以上分析, 本文所提基于分布约束的非对称度量学习目标函数矩阵表达式为

$$\begin{aligned} \min_{H, \tilde{U}} F_{\text{obj}} &= \\ &= \frac{1}{N} \text{Tr}(\tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X}) + \alpha \text{Tr}(\tilde{U}^T D \tilde{U}) - \\ &= \frac{1}{N} \text{Tr}(H^T \tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X} H) + \beta \text{Tr}(\tilde{U}^T \tilde{m} L \tilde{m}^T \tilde{U}); \\ \text{s.t. } &\tilde{U}^T \tilde{C} \tilde{U} = VI. \end{aligned} \quad (20)$$

2.2.4 优化过程

由式(20)可知, 目标函数矩阵形式有两个优化参数 H 和 \tilde{U} , 整个优化过程使用交叉优化.

固定 H , 优化 \tilde{U} , 利用拉格朗日乘子法, 将优化任务转化为广义特征值问题如下: 构造拉格朗日函数

$$\begin{aligned} L &= \frac{1}{N} \text{Tr}(\tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X}) + \alpha \text{Tr}(\tilde{U}^T D \tilde{U}) - \\ &= \frac{1}{N} \text{Tr}(H^T \tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X} H) + \beta \text{Tr}(\tilde{U}^T \tilde{m} L \tilde{m}^T \tilde{U}) - \\ &= \lambda \tilde{U}^T \tilde{C} \tilde{U}, \end{aligned} \quad (21)$$

其中 λ 为拉格朗日乘数.

在式(21)上对 \tilde{U} 求偏导数, 可得

$$\begin{aligned} \frac{\partial L}{\partial \tilde{U}} &= \frac{1}{N} \frac{\partial \text{Tr}(\tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X})}{\partial \tilde{U}} + \alpha \frac{\partial \text{Tr}(\tilde{U}^T D \tilde{U})}{\partial \tilde{U}} - \\ &= \frac{1}{N} \frac{\partial \text{Tr}(H^T \tilde{X}^T \tilde{U} \tilde{U}^T \tilde{X} H)}{\partial \tilde{U}} + \\ &= \beta \frac{\partial \text{Tr}(\tilde{U}^T \tilde{m} L \tilde{m}^T \tilde{U})}{\partial \tilde{U}} - \lambda \frac{\partial (\tilde{U}^T \tilde{C} \tilde{U})}{\partial \tilde{U}} = \\ &= \frac{2}{N} \tilde{X} \tilde{X}^T \tilde{U} + 2\alpha D \tilde{U} - \\ &= \frac{2}{N} \tilde{X} H H^T \tilde{X}^T \tilde{U} + 2\beta \tilde{m} L \tilde{m}^T \tilde{U} - \lambda \tilde{C} \tilde{U}. \end{aligned} \quad (22)$$

令 $\frac{\partial L}{\partial \tilde{U}} = 0$, 可得

$$\left(\frac{1}{N} \tilde{X} \tilde{X}^T + \alpha D - \frac{1}{N} \tilde{X} H H^T \tilde{X}^T + \beta \tilde{m} L \tilde{m}^T\right) \tilde{U} = \lambda \tilde{C} \tilde{U}. \quad (23)$$

由式(23)可知

$$G \tilde{U} = \lambda \tilde{U}, \quad (24)$$

其中

$$G = \tilde{C}^{-1} \left(\frac{1}{N} \tilde{X} \tilde{X}^T + \alpha D - \frac{1}{N} \tilde{X} H H^T \tilde{X}^T + \beta \tilde{m} L \tilde{m}^T \right).$$

根据式(24)可转化为广义特征值问题, 进而求解特征值和特征向量.

固定 \tilde{U} , 优化 H . $H = [h_1, h_2, \dots, h_k]$, 每一列 h_k 代表每一类的聚类结果, 因此 H 与聚类结果有关系. 所以在特征空间中进行 k -means 聚类, 然后根据聚类结果构造 H . 通过以上优化过程, 可以得到转换矩阵 U .

3 实验与分析

3.1 实验设置

3.1.1 数据集介绍

为验证所提算法性能, 本文基于 Market^[24] 和 Duke^[25] 两个数据集进行实验, 数据集介绍如下.

Market-1501(Market) 包括 1501 个身份的 32 668 幅图像, 每个行人图像由 6 台摄像机拍摄. 该数据

集被分为训练集和测试集,训练集有751个身份的12936幅图像,测试集有750个身份的19732幅图像,从测试集的750个身份中选取3368幅图像作为查询集.在这个数据集中,由于所有图像由行人检测器裁剪,存在许多未被检测到的甚至是非人的图像.

DukeMTMC-reID(Duke)包括1812个身份的36411幅图像,每个行人图像由8台摄像机拍摄.其中有1404个行人出现在大于2个摄像头下,有408个行人出现在一个摄像头下.训练集有702个身份的16522幅图像,测试集有1110个身份的17611幅图像,查询集有702个行人身份的2228幅图像.

3.1.2 评价指标介绍

本文使用2个评价指标衡量在Market和Duke数据集上所提算法性能,包括累计匹配特征(cumulative match characteristic, CMC)曲线、均值平均精度(mean average precision, MAP). 累积匹配特征曲线表示top- k 的击中概率的曲线. rank n 表示在前 n 个检索结果中存在待检测行人的概率. 通常CMC曲线由rank 1、rank 5、rank 10、rank 20表示,其中rank 1表示一次击中的概率,则CMC曲线表达式为

$$\text{CMC}(n) = \frac{1}{N} \sum_{i=1}^N m_i.$$

$$m_i = \begin{cases} 0, & z_i > n; \\ 1, & z_i \leq n; \end{cases} \quad n = 1, 2, \dots, N. \quad (25)$$

其中: N 为检索的行人的个数, n 为前 n 个检索结果, z_i 为在候选集正确匹配结果的位置序号.

均值平均精度是计算所有类别平均精度(average precision, AP)的均值,MAP用来衡量模型在

所有类别上的检测能力的好坏. MAP表达式为

$$\text{MAP} = \frac{1}{Q} \sum_{Q=1}^n \text{AP}(n).$$

$$\text{AP} = \frac{1}{m} \sum_{i=1}^n (p(i) \times a(i)).$$

$$a(i) = \begin{cases} 0, & \text{correct match;} \\ 1, & \text{incorrect match.} \end{cases} \quad (26)$$

其中: i 为检索行人图像序号, $p(i)$ 为第 i 张图像在所有检索图像中的比例, $a(i)$ 为第 i 张图像与待查询图像匹配特性, m 为与待查询图像匹配个数, Q 为待查询图像的个数.

3.1.3 特征提取网络设置

实验采用ResNet50网络作为特征提取网络,并提取64维的特征表示. 为了得到具有较强区别性和鲁棒性的特征表示,采用JSTL预训练技术^[26]对该网络进行预训练. JSTL预训练技术是用来对多个数据集的样本进行训练的,有7个数据集被用来训练网络,包括iLIDS、CUHK01、CUHK03、VIPeR、PRID、3DpeS、Shinpuhan. 本实验中,在原来的JSTL预训练技术上再训练Market和Duke两个数据集.

3.2 参数调优及结果分析

3.2.1 参数调优分析

由式(9)和(10)可知,实验共有4个参数. 包括 α 、 β 、 D 、 K . 其中: α 为跨视角一致性项权重系数, β 为数据分布约束项权重系数, D 为转换后的特征维数, K 为簇的数目. 首先针对 α 和 β 对rank和MAP的影响做实验,实验结果如图3所示.

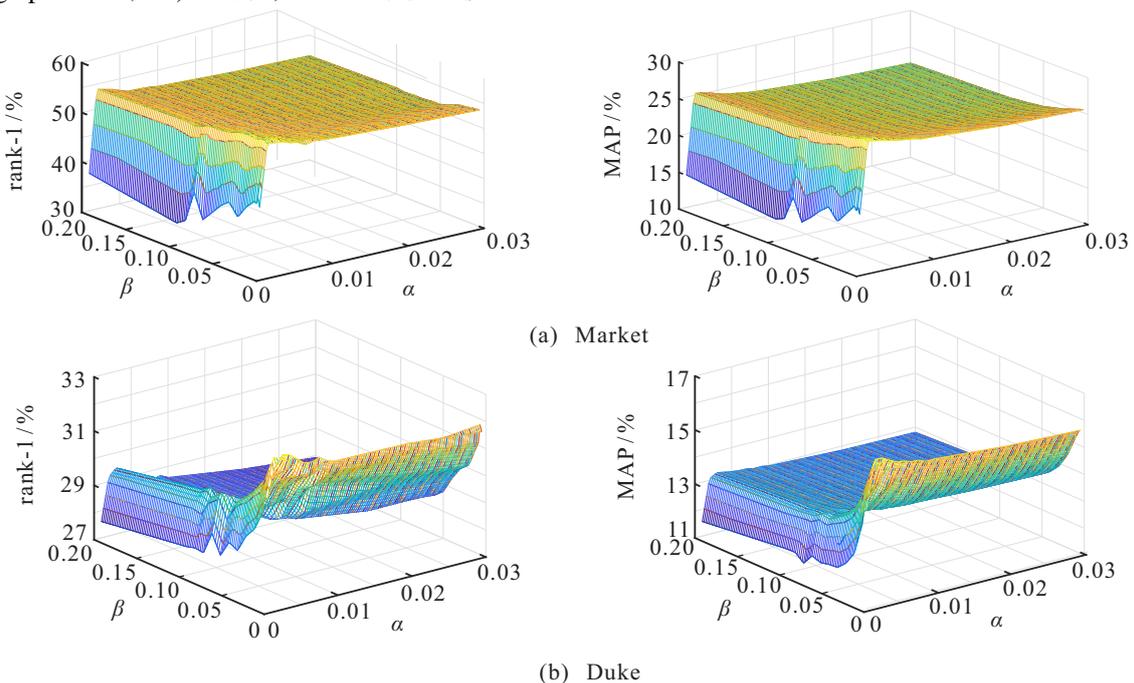


图3 α 和 β 的值对rank 1和MAP值的影响

实验结果显示: 对于 Market, 固定 α, β 逐渐增大时, rank 1 和 MAP 呈先上升后下降趋势; 固定 β, α 逐渐增大时, rank 1 和 MAP 呈下降趋势. 因此, 当 α 最优取值为 0.002, β 最优取值为 0.01 时, Market 的 rank 1 和 MAP 值为 57.01% 和 27.91%. 对于 Duke, 不管调节

α 或 β , rank 1 和 MAP 都呈现下降趋势. 因此, 当 α 取值为 0.003, β 取值为 0.005 时, rank 1 和 MAP 达到最大值 32.32% 和 16.00%.

K 表示簇的数目, K 值也是影响实验结果的主要因素之一, K 值对 rank 和 MAP 的影响如表 1 所示.

表1 K 值对 rank 和 MAP 值影响

| K 值 | Market | | | | | Duke | | | | |
|-------|--------|--------|---------|---------|-------|--------|--------|---------|---------|-------|
| | rank 1 | rank 5 | rank 10 | rank 20 | MAP | rank 1 | rank 5 | rank 10 | rank 20 | MAP |
| 200 | 56.06 | 75.62 | 81.83 | 86.88 | 27.23 | 31.82 | 43.40 | 47.44 | 50.63 | 15.80 |
| 250 | 56.95 | 76.4 | 82.27 | 87.08 | 27.65 | 31.96 | 43.63 | 47.67 | 50.76 | 15.78 |
| 300 | 56.53 | 75.83 | 81.71 | 86.70 | 27.38 | 31.91 | 43.72 | 47.67 | 50.85 | 15.91 |
| 350 | 56.21 | 75.92 | 82.13 | 86.88 | 27.57 | 32.09 | 43.81 | 47.49 | 50.85 | 16.02 |
| 400 | 56.77 | 76.13 | 82.33 | 87.29 | 27.91 | 31.78 | 43.67 | 47.44 | 50.90 | 15.89 |
| 450 | 56.41 | 75.92 | 82.13 | 87.17 | 27.82 | 32.00 | 44.03 | 47.49 | 50.76 | 15.94 |
| 500 | 57.01 | 76.07 | 82.42 | 87.11 | 27.91 | 32.32 | 43.67 | 47.40 | 50.99 | 16.00 |
| 550 | 56.68 | 76.22 | 82.33 | 87.08 | 27.93 | 31.78 | 43.81 | 47.53 | 51.17 | 15.92 |
| 600 | 56.5 | 76.31 | 82.21 | 87.11 | 27.9 | 32.09 | 43.85 | 47.80 | 50.90 | 15.99 |
| 650 | 56.74 | 76.34 | 82.39 | 87.08 | 28.01 | 32.50 | 43.36 | 47.80 | 51.03 | 16.01 |
| 700 | 56.56 | 75.74 | 81.83 | 87.14 | 27.73 | 31.96 | 43.85 | 47.44 | 50.85 | 15.94 |

实验结果显示: K 值对实验结果影响在两个数据集上表现出相似的变化趋势. 当 K 值不同时, 对于 rank 1 而言, $K = 500$ 时表现为最优值. 在 rank 5 ~ rank 20 时, K 值变大, 实验结果基本相似. 但对于 K 值的选取, K 值不能太大也不能太小, 如果 K 值过大, 则会产生噪声, 产生错误的分类, 因此选择 $K = 500$ 时, 达到最优. 当 $K = 500$ 时, Market 和 Duke 的

rank 1 值为 57.01% 和 32.32%, rank 5 值为 76.07% 和 43.67%, rank 10 值为 82.42% 和 47.40%, rank 20 值为 87.11% 和 50.99%, MAP 值为 27.91% 和 16.00%.

经过上述调优, 实验结果 rank 和 MAP 的值都有一定的提升, 为了更好地了解参数对实验的影响, 对转换后的特征的维数 D 进行分析, 实验结果如表 2 所示.

表2 转换后的特征维数 D 对 rank 和 MAP 值的影响

| D 值 | Market | | | | | Duke | | | | |
|-------|--------|--------|---------|---------|-------|--------|--------|---------|---------|-------|
| | rank 1 | rank 5 | rank 10 | rank 20 | MAP | rank 1 | rank 5 | rank 10 | rank 20 | MAP |
| 64 | 57.01 | 76.07 | 82.42 | 87.11 | 27.91 | 32.32 | 43.67 | 47.4 | 50.99 | 16 |
| 62 | 56.41 | 76.16 | 82.13 | 87.56 | 27.64 | 32.09 | 43.54 | 47.53 | 51.26 | 15.99 |
| 60 | 54.63 | 73.81 | 79.87 | 86.16 | 26.06 | 31.87 | 42.95 | 46.59 | 50.31 | 15.36 |
| 58 | 53.06 | 72.45 | 79.07 | 84.74 | 24.64 | 30.75 | 42.15 | 46.36 | 49.78 | 14.9 |
| 56 | 51.34 | 71.64 | 77.94 | 83.91 | 23.43 | 30.03 | 40.53 | 44.75 | 47.76 | 13.75 |
| 54 | 49.17 | 69.36 | 75.83 | 81.98 | 21.8 | 28.64 | 39.54 | 43.85 | 47.71 | 12.97 |
| 52 | 47.18 | 67.1 | 74.58 | 80.97 | 20.3 | 26.3 | 37.88 | 41.83 | 46.59 | 11.84 |
| 50 | 45.81 | 66.18 | 72.83 | 79.48 | 19.2 | 25.04 | 36.13 | 40.57 | 44.97 | 10.73 |
| 48 | 42.25 | 61.76 | 70.19 | 76.34 | 16.63 | 24.37 | 34.69 | 39.72 | 43.72 | 10.05 |
| 46 | 37.95 | 58.55 | 66.45 | 73.6 | 14.82 | 23.34 | 33.8 | 38.38 | 43 | 9.3 |
| 44 | 36.52 | 55.29 | 64.37 | 72.36 | 13.97 | 20.96 | 31.96 | 37.12 | 41.61 | 8.31 |
| 42 | 33.7 | 52.08 | 61.16 | 69.71 | 12.56 | 18.81 | 30.57 | 35.19 | 39.95 | 7.55 |
| 40 | 32.27 | 50.98 | 59.65 | 67.76 | 11.73 | 18.13 | 28.82 | 33.21 | 38.11 | 6.77 |

实验结果显示: 随着特征维度 D 的降低, rank 值和 MAP 值呈下降趋势. 因此, 当 D 为 64 时, rank 值和 MAP 达到最大值. 当特征维数 D 为 64 时, Market 和 Duke 的 rank 1 值为 57.01% 和 32.32%, rank 5 值为 76.07% 和 43.67%, rank 10 值为 82.42% 和 47.40%, rank 20 值为 87.11% 和 50.99%, MAP 值为 27.91% 和 16.00%.

通过实验参数调优, Market 和 Duke 的 rank 值和 MAP 都有一定的提升. 故最优配置是跨视图一致性

项权重系数 α 为 0.002, 数据分布约束项权重系数 β 为 0.01, 转换后的特征维数 $D = 64$, 簇的数目 $K = 500$.

3.2.2 消融实验分析

为了验证数据分布约束对算法性能的影响, 本文针对不同方法组合的情况, 开展消融实验, 实验结果如表 3 所示. 其中: LAM 为非对称度量学习方法, LCD 为数据分布约束项, LOMO 为提取特征的方法.

表3 不同方法组合的消融实验

%

| 方法 | Market | | | | | Duke | | | | |
|--------------|--------|--------|---------|---------|-------|--------|--------|---------|---------|-------|
| | rank 1 | rank 5 | rank 10 | rank 20 | MAP | rank 1 | rank 5 | rank 10 | rank 20 | MAP |
| LOMO+LAM | 31.4 | — | — | — | 13.1 | 15.1 | — | — | — | 8.56 |
| JSTL+LAM | 54.51 | 73.04 | 79.57 | 84.62 | 26.27 | 31.82 | 42.82 | 46.59 | 50 | 15.99 |
| JSTL+DGD | 44.49 | 61.51 | 71.2 | 76.8 | 18.36 | 29.35 | 41.35 | 46.12 | 49.8 | 12.17 |
| JSTL+LAM+LCD | 57.01 | 76.07 | 82.42 | 87.11 | 27.91 | 32.32 | 43.67 | 47.4 | 50.99 | 16 |

表3实验数据表明:将数据分布约束项加到非对称度量学习中,准确度得到明显提升.对于Market,将数据分布约束项添加到目标函数上可以得出rank 1、rank 5、rank 10提升3个百分点左右,rank 20提升2个百分点左右,MAP提升1个百分点.对于Duke,将数据分布约束项添加到目标函数上,rank 1、rank 5、rank 10、rank 20提升1个百分点左右,MAP有一定提

升.

通过消融实验可以得出,加入数据分布约束项对行人重识别精确度有提升作用.

3.2.3 对比实验分析

为了验证基于分布约束的非对称度量学习对实验的有效性,分别与JSTL^[26]、Dic^[27]、SAE^[28]3种无监督模型进行对比实验,实验结果如表4所示.

表4 与其他无监督行人重识别方法的对比实验

%

| 方法 | Market | | | | | Duke | | | | |
|----------------------|--------|--------|---------|---------|-------|--------|--------|---------|---------|-------|
| | rank 1 | rank 5 | rank 10 | rank 20 | MAP | rank 1 | rank 5 | rank 10 | rank 20 | MAP |
| Dic ^[27] | 50.21 | 67.2 | 75.21 | 82.93 | 22.68 | 30.56 | 40.36 | 43.22 | 48.5 | 12.5 |
| JSTL ^[26] | 44.69 | 64.35 | 71.23 | 76.82 | 18.36 | 29.35 | 34.15 | 40.67 | 46.6 | 12.17 |
| SAE ^[28] | 42.42 | 62.32 | 68.51 | 75.92 | 16.22 | 27.21 | 34.83 | 39.2 | 43.3 | 11.42 |
| DC-UAML | 57.01 | 76.07 | 72.42 | 87.11 | 27.91 | 32.32 | 43.67 | 47.4 | 50.99 | 16 |

表4实验数据表明,DC-UAML比以上无监督方法有所提升,其主要原因是:首先,DC-UAML采用JSTL预训练技术对网络进行预训练,得到具有较强区别性和鲁棒性的特征表示;其次,DC-UAML为每个视角学习非一致的特征变换,根据不同的特征变换将特征投影到共享空间中,使共享空间中不同视角的偏差得到缓解,进而得到准确的距离度量函数;最后,在进行特征投影的过程中,由于考虑投影到特征空间的行人特征的分布差异,提出用最大均值差异提高不同视角的行人图像特征在变换子空间的分布的相似性.

4 结论

针对行人图像被遮挡、拍摄视角不同等因素,导致行人图像出现偏差,使得行人重识别精准度不高的问题,本文提出了一种基于分布约束的非对称度量学习无监督行人重识别方法.该方法采用非对称度量学习方法,缓解不同摄像视角带来的行人图像偏差的问题.此外,在非对称度量学习上加入数据分布约束项,进而减少在变换子空间中的行人特征分布差异.基于Market和Duke两个数据集进行实验,实验结果表明,所提出的无监督行人重识别方法具有较好的性能.但其只能解决线性数据,对于一些非线性数据

不能更好地解决,今后研究重点在于如何解决非线性数据,进而提升行人重识别性能.

参考文献(References)

- [1] Bedagkar-Gala A, Shah S K. A survey of approaches and trends in person re-identification[J]. Image and Vision Computing, 2014, 32(4): 270-286.
- [2] 李幼蛟, 卓力, 张菁, 等. 行人再识别技术综述[J]. 自动化学报, 2018, 44(9): 1554-1568.
(Li Y J, Zhuo L, Zhang J, et al. A survey of person re-identification[J]. Acta Automatica Sinica, 2018, 44(9): 1554-1568.)
- [3] Li X L, Liu L N, Lu X Q. Person reidentification based on elastic projections[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(4): 1314-1327.
- [4] Jiao J, Zheng W S, Wu A, et al. Deep low-resolution person re-identification[C]. Proceedings of the AAAI Conference on Artificial Intelligence. Louisiana, 2018: 6967-6974.
- [5] 卢健, 王航英, 陈旭, 等. 基于多尺度特征表示的行人再识别[J]. 控制与决策, 2021, 36(12): 3015-3022.
(Lu J, Wang H Y, Chen X, et al. Multi-scale feature representation for person re-identification[J]. Control and Decision, 2021, 36(12): 3015-3022.)
- [6] Liao S C, Hu Y, Zhu X Y, et al. Person re-identification by local maximal occurrence representation and metric learning[C]. 2015 IEEE Conference on Computer Vision

- and Pattern Recognition. Boston, 2015: 2197-2206.
- [7] 邹国锋, 傅桂霞, 高明亮, 等. 行人重识别中度量学习方法研究进展[J]. 控制与决策, 2021, 36(7): 1547-1557.
(Zou G F, Fu G X, Gao M L, et al. A survey on metric learning in person re-identification[J]. Control and Decision, 2021, 36(7): 1547-1557.)
- [8] 罗浩, 姜伟, 范星, 等. 基于深度学习的行人重识别研究进展[J]. 自动化学报, 2019, 45(11): 2032-2049.
(Luo H, Jiang W, Fan X, et al. A survey on deep learning based person re-identification[J]. Acta Automatica Sinica, 2019, 45(11): 2032-2049.)
- [9] 王松, 纪鹏, 张云洲, 等. 自适应感受野网络的行人重识别[J]. 控制与决策, 2022, 37(1): 119-126.
(Wang S, Ji P, Zhang Y Z, et al. Adaptive receptive network for person re-identification[J]. Control and Decision, 2022, 37(1): 119-126.)
- [10] Ye M, Shen J B, Lin G J, et al. Deep learning for person re-identification: A survey and outlook[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(6): 2872-2893.
- [11] Matsukawa T, Okabe T, Suzuki E, et al. Hierarchical aussian descriptor for person re-identification[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016, 1363-1372.
- [12] 贲晔焯, 徐森, 王科俊. 行人步态的特征表达及识别综述[J]. 模式识别与人工智能, 2012, 25(1): 71-81.
(Ben X Y, Xu S, Wang K J. Review on pedestrian gait feature expression and recognition[J]. Pattern Recognition and Artificial Intelligence, 2012, 25(1): 71-81.)
- [13] Zhang P, Xu J S, Wu Q, et al. Learning spatial-temporal representations over walking tracklet for long-term person re-identification in the wild[J]. IEEE Transactions on Multimedia, 2021, 23: 3562-3576.
- [14] Fan H H, Zheng L, Yan C G, et al. Unsupervised person re-identification[J]. ACM Transactions on Multimedia Computing, Communications, and Applications, 2018, 14(4): 1-18.
- [15] Feng Z X, Lai J H, Xie X H. Learning view-specific deep networks for person re-identification[J]. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 2018, 27(7): 3472-3483.
- [16] He W X, Chen Y C, Lai J H. Cross-view transformation based sparse reconstruction for person re-identification[C]. The 23rd International Conference on Pattern Recognition (ICPR). Cancun, 2016: 3410-3415.
- [17] Chen Y C, Zhu X T, Zheng W S, et al. Person re-identification by camera correlation aware feature augmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(2): 392-408.
- [18] Chen Y C, Zheng W S, Lai J H, et al. An asymmetric distance model for cross-view feature mapping in person reidentification[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(8): 1661-1675.
- [19] Yu H X, Wu A C, Zheng W S. Cross-view asymmetric metric learning for unsupervised person re-identification[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 994-1002.
- [20] Feng Y C, Yuan Y, Lu X Q. Person reidentification via unsupervised cross-view metric learning[J]. IEEE Transactions on Cybernetics, 2021, 51(4): 1849-1859.
- [21] Si S, Tao D C, Geng B. Bregman divergence-based regularization for transfer subspace learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(7): 929-942.
- [22] Li J J, Lu K, Huang Z, et al. Transfer independently together: A generalized framework for domain adaptation[J]. IEEE Transactions on Cybernetics, 2019, 49(6): 2144-2155.
- [23] Ding C, He X F, Simon H D. On the equivalence of nonnegative matrix factorization and spectral clustering[C]. Proceedings of the 2005 SIAM International Conference on Data Mining. Philadelphia, 2005: 606-610.
- [24] Zheng L, Shen L Y, Tian L, et al. Scalable person re-identification: A benchmark[C]. 2015 IEEE International Conference on Computer Vision. Santiago, 2015: 1116-1124.
- [25] Zheng Z D, Zheng L, Yang Y. Unlabeled samples generated by GAN improve the person re-identification baseline in vitro[C]. 2017 IEEE International Conference on Computer Vision. Venice, 2017: 3774-3782.
- [26] Xiao T, Li H S, Ouyang W L, et al. Learning deep feature representations with domain guided dropout for person re-identification[C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 1249-1258.
- [27] Kodirov E, Xiang T, Gong S G. Dictionary learning with iterative Laplacian regularisation for unsupervised person re-identification[C]. Proceedings of the British Machine Vision Conference 2015. Swansea, 2015: 3-8.
- [28] Lee H, Ekanadham C, Ng A. Sparse deep belief net model for visual area V2[J]. Advances in Neural Information Processing Systems, 2007, 20: 873-880.

作者简介

刘月(1998—), 女, 硕士生, 从事行人重识别的研究, E-mail: liuyue_sdut@163.com;

邹国锋(1984—), 男, 讲师, 博士, 从事行人重识别、人脸识别、视频监控技术等研究, E-mail: zgf841122@163.com;

陈贵震(1997—), 男, 硕士生, 从事行人重识别的研究, E-mail: chen17853309228@163.com;

翟文哲(1998—), 男, 硕士生, 从事群体密度估计的研究, E-mail: wenzhezhai@163.com;

高明亮(1985—), 男, 副教授, 博士, 从事运动目标检测与跟踪、视频分析技术等研究, E-mail: sdut_mlga@163.com.