

一种基于等距度量学习策略的行人重识别改进算法

周智恒* 刘楷怡 黄俊楚 陈增群

(华南理工大学电子与信息学院 广州 510000)

摘要: 为了提高行人重识别距离度量MLAPG算法的鲁棒性, 该文提出基于等距度量学习策略的行人重识别Equid-MLAPG算法。MLAPG算法中正负样本对在映射空间的分布不均衡导致间距超参数受负样本对距离影响更大, 因此该文设计的Equid-MLAPG算法要求正样本对映射成为变换空间中的一个点, 即正样本对在变换空间中距离为零, 使算法收敛时正负样本对距离分布不存在交叉部分。实验表明Equid-MLAPG算法能在常用的行人重识别数据集上取得良好的实验效果, 具有更好的识别率和广泛的适用性。

关键词: 行人重识别; 等距度量; MLAPG算法

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2019)02-0477-07

DOI: 10.11999/JEIT180336

Improved Metric Learning Algorithm for Person Re-identification Based on Equidistance

ZHOU Zhiheng LIU Kaiyi HUANG Junchu CHEN Zengqun

(School of Electronic and Information Engineering, South China
University of Technology, Guangzhou 510000, China)

Abstract: In order to improve the robustness of MLAPG algorithm, a person re-identification algorithm, called Equid-MLAPG algorithm is proposed, which is based on the equidistance measurement learning strategy. Due to the imbalanced distribution of positive and negative sample pairs in the mapping space, sample spacing hyper-parameter of MLAPG algorithm is more affected by the distance of negative sample pairs. Therefore, Equid-MLAPG algorithm tends to map the positive sample pair to be a point in the transform space. That is, the distance of a positive sample pair in the transform space is mapped to be zero, resulting in no intersection in the distribution of positive and negative sample pairs in the transform space when algorithm convergences. Experiments show that the Equid-MLAPG algorithm can achieve better experimental results on commonly used person re-identification datasets with better recognition rate and wide applicability.

Key words: Person re-identification; Equidistance; MLAPG algorithm

1 引言

行人重识别问题^[1]是指在多个监控摄像头数据中对给定行人目标进行检索的任务, 是监控视频数据分析利用的一个很重要的应用, 对社会公共安全的提升具有重要的作用。行人重识别技术相比人脸

识别等计算机图像检索任务而言, 受到复杂实际拍摄环境、摄像头分辨率差异、低分辨率、拍摄视角变化、拍摄背景变化和行人姿态变化等诸多因素的影响, 问题更具有难度和挑战性。目前阶段的行人重识别技术距离实际落地应用仍然有较大差异, 近几年受到了越来越多学者和研究机构的关注, 大量相关的研究工作都在积极开展当中。文献[2]引入的六边形超像素方法以最小化诸如视角变化及背景干扰等导致的错误识别率, 文献[3]则利用超图来描述行人重识别图像之间的高阶关系, 对行人重识别结果进行重排序获得性能增益。目前行人重识别的研究工作主要从行人特征提取和特征距离度量两个方面进行, 本文重点关注特征度量方法的研究。在特征距离度量研究工作上, 大量研究工作的核心在于如何将原始特征映射到一个更有区分性的特征空间

收稿日期: 2018-04-11; 改回日期: 2018-09-13; 网络出版: 2018-09-20

*通信作者: 周智恒 zhouzh@scut.edu.cn

基金项目: 国家自然科学基金(U1401252, 61871188), 国家重点研发计划(2018YFC0309400), 中央高校基本科研业务费专项资金(2017MS062), 广州市产学研协同创新重大专项(201604016133)

Foundation Items: The National Natural Science Foundation of China (U1401252, 61871188), The National Key R&D Program of China (2018YFC0309400), The Fundamental Research Funds for the Central Universities SCUT (2017MS062), Guangzhou City Science and Technology Research Projects (201604016133)

中。LDFA算法^[4]将线性判别分析LDA算法的投影后类内方差最小，类间方差最大的思想引入行人重识别特征子空间的求解中；另外还有一类行人重识别距离度量算法是基于求解特征样本马氏距离设计的。LMNN算法^[5]通过为锚点样本定义目标邻近样本和入侵者样本来生成三元组样本对，构造损失函数最小化锚点样本与目标邻近样本间距离同时最大化入侵者样本与锚点样本的距离，最后基于损失函数求解马氏矩阵；ITML算法^[6]基于信息理论提出一个结构性约束施加于度量矩阵上来减轻度量矩阵的过拟合现象；LMNN-R算法^[7]基于LMNN算法改进，主要是为了进一步约束负样本，通过基于锚点样本的近邻圈计算全局平均的近邻圈作为LMNN算法要求的入侵者样本与锚点样本距离和目标近邻样本与锚点样本距离差距最小值；PRDC算法^[8]将概率相对距离约束应用于距离度量矩阵求解；KISSME算法^[9,10]将样本对的相似性度量问题建模成一个似然比检验问题，假设正负样本差异符合高斯分布，利用统计推断方式构造距离度量函数；Liao等人^[11]引入非对称样本权重解决基于马氏距离度量学习中正负样本不均衡问题，并通过保持PSD特性有效提高度量矩阵的鲁棒性。从本质上分析，基于马氏矩阵的行人重识别距离度量学习算法也是在找寻更有利刻画特征关系的变换空间，本文会首先说明马氏距离度量学习是一种特征空间映射算法，然后分析行人重识别MLAPG算法^[11]学习到的变换空间中正负样本对的分布情况，指出MLAPG算法由于正负样本对不均衡导致间距超参数受负样本对距离影响更大，算法收敛时正负样本对在变换空间中距离分布仍存在交叉分布的问题，降低了MLAPG算法在测试阶段对噪声的鲁棒性。为了解决这一问题，本文将等距度量学习策略引入MLAPG算法，提出了Equid-MLAPG算法以提高行人检测匹配的准确度。

2 Equid-MLAPG算法

2.1 基于马氏距离的行人特征距离度量模型

在行人重识别问题中，基于马氏距离的度量学习定义为求取一个半正定矩阵 $\mathbf{M}$ 使得来自同一个行人的图像之间的距离小于来自不同行人的图像之间的距离，使得训练样本对之间保持同类样本关系密切，异类样本关系疏远的关系。具体来说，给定多摄像头图像训练集 $\{\mathbf{X}, \mathbf{Y}, \mathbf{Z}\}$ ，图像集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\} \in R^{d \times n}$ 表示来自摄像头A的 n 个样本，图像集 $\mathbf{Z} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_m\} \in R^{d \times m}$ 表示来自摄像头B的 m 个样本。 $\mathbf{Y} \in R^{n \times m}$ 表示 $\mathbf{X}$ 与 $\mathbf{Y}$ 之间两两匹配是否来自同一行人的标签，当 $\mathbf{x}_i$ 和 $\mathbf{z}_j$ 来自同一行人时 $y_{ij} = 1$ ，否则 $y_{ij} = -1$ ，由此得到相似集

合 $S = \{(\mathbf{x}_i, \mathbf{z}_j) | y_{ij} = 1\}$ 和非相似集合 $D = \{(\mathbf{x}_i, \mathbf{z}_j) | y_{ij} = -1\}$ 。则任意样本 $\mathbf{x}_i \in \mathbf{X}$ 和 $\mathbf{z}_j \in \mathbf{Z}$ 的马氏距离表示如式(1)所示。

$$\left. \begin{aligned} D_M^2(\mathbf{x}_i, \mathbf{z}_j) &= \|\mathbf{x}_i - \mathbf{z}_j\|_{\mathbf{M}}^2 \\ &= (\mathbf{x}_i - \mathbf{z}_j)^T \mathbf{M} (\mathbf{x}_i - \mathbf{z}_j) \end{aligned} \right\} \quad (1)$$

s.t. $\mathbf{M} \geq 0$

其中， $\mathbf{M}$ 定义为马氏矩阵，且为了满足距离定义的非负性和对称性，要求 $\mathbf{M}$ 是一个半正定对称矩阵，即 $\mathbf{M} \geq 0$ 。对马氏矩阵 $\mathbf{M}$ 进行奇异值分解可以得到 $\mathbf{M} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H$ ， $\mathbf{U}$ 和 $\mathbf{V}$ 都是酉矩阵， $\mathbf{V}^H$ 是 $\mathbf{V}$ 的共轭转置。由于马氏矩阵 $\mathbf{M}$ 是一个对称矩阵，所以左酉矩阵会是右酉矩阵的转置，即 $\mathbf{U} \mathbf{V}^H = \mathbf{I}$ ，因此马氏矩阵 $\mathbf{M}$ 可以进一步表示为 $\mathbf{M} = \mathbf{H} \mathbf{\Sigma} \mathbf{H}^T$ 。 $\mathbf{\Sigma}$ 是一个对角矩阵，对角元素是该矩阵的奇异值。因此，式(1)可以重写为式(2)：

$$\begin{aligned} D_M^2(\mathbf{x}_i, \mathbf{z}_j) &= (\mathbf{x}_i - \mathbf{z}_j)^T \mathbf{H} \mathbf{\Sigma} \mathbf{H}^T (\mathbf{x}_i - \mathbf{z}_j) \\ &= (\mathbf{H}^T \mathbf{x}_i - \mathbf{H}^T \mathbf{z}_j)^T \mathbf{\Sigma} (\mathbf{H}^T \mathbf{x}_i - \mathbf{H}^T \mathbf{z}_j) \end{aligned} \quad (2)$$

从式(1)、式(2)中可以看出马氏距离使用最优正交矩阵 $\mathbf{H}$ 能去除特征之间的耦合，将原始特征映射到新特征空间中。同时对角矩阵 $\mathbf{\Sigma}$ 通过对新坐标系下新特征分配相应权值来消除量纲影响。

行人重识别问题中马氏距离矩阵 $\mathbf{M}$ 要满足的学习目标可以是式(3)所示的成对距离限制条件(pairwise constraints)也可以是式(4)所示的三元距离限制条件(triplet constraints)：

$$\left. \begin{aligned} D_M^2(\mathbf{x}_i, \mathbf{z}_j) &< \mu_1, \quad (\mathbf{x}_i, \mathbf{z}_j) \in S \\ D_M^2(\mathbf{x}_i, \mathbf{z}_k) &> \mu_2, \quad (\mathbf{x}_i, \mathbf{z}_k) \in D \end{aligned} \right\} \quad (3)$$

$$D_M^2(\mathbf{x}_i, \mathbf{z}_k) > D_M^2(\mathbf{x}_i, \mathbf{z}_j) + m \quad (4)$$

其中， μ_1 、 μ_2 和 m 都是算法预设置的“距离”参数，对算法性能具有重要的影响。

2.2 MLAPG算法

如何基于成对距离限制条件或者3元距离限制条件设计马氏矩阵 $\mathbf{M}$ 求解算法是相关研究工作的核心。不同于其他算法使用不可导函数 $\max(0, \cdot)$ 作为损失函数形式，MLAPG算法取软间隔对数逻辑函数作为损失函数，即样本对 $(\mathbf{x}_i, \mathbf{z}_j)$ 的损失函数如式(5)所示。

$$f_M(\mathbf{x}_i, \mathbf{z}_j) = \lg \left(1 + e^{y_{ij}(D_M^2(\mathbf{x}_i, \mathbf{z}_j) - \mu)} \right) \quad (5)$$

其中 $\mu = ED_I^2(\mathbf{X}, \mathbf{Z})$ ，表示1个正偏置，即替换掉式(1)–式(3)中的 μ_1 和 μ_2 ，且取 $\mu_1 = \mu_2 = \mu$ 。则对于图像集 $\{\mathbf{X}, \mathbf{Y}, \mathbf{Z}\}$ 来说，全局代价函数表示为

$$F(\mathbf{M}) = \sum_{i=1}^n \sum_{j=1}^m w_{ij} f_{\mathbf{M}}(\mathbf{x}_i, \mathbf{z}_j) \quad (6)$$

w_{ij} 是非对称样本权重,用来平衡图像集构造正负样本对存在的样本不均衡问题,对 $y_{ij}=1$ 取 $w_{ij}=1/N_{\text{pos}}$,对 $y_{ij}=-1$ 取 $w_{ij}=1/N_{\text{neg}}$,其中 N_{pos} 和 N_{neg} 分别表示正样本对数量和负样本对数量。算法最终的优化目标如式(7)所示。

$$\left. \begin{array}{l} \min_{\mathbf{M}} F(\mathbf{M}) \\ \text{s.t. } \mathbf{M} \geq 0 \end{array} \right\} \quad (7)$$

式(1)—式(7)将式(1)—式(5)损失函数中的正样本距离上界和负样本距离下界取为初始化马氏矩阵 $\mathbf{M}$ (通常初始化马氏矩阵 $\mathbf{M}$ 为单位矩阵 $\mathbf{I}$)后所有正负样本对马氏距离的均值,且不随训练过程中 $\mathbf{M}$ 的变化而变化。图1给出了MLAPG算法在VIPeR数据集上 μ 取值和所有样本对马氏距离均值随训练过程变化的示意图,实线是训练过程中所有样本对马氏距离变化情况,虚线表示训练过程中使用同一个 μ 值。

由图1可知,训练过程中所有样本对马氏距离均值具有增大趋势,这是因为正负样本比例不均衡,在计算均值时负样本主导均值变化趋势。通过对 μ 取初始固定值可以避免因为负样本对距离增大

而导致的正样本对的距离上限随之增大,但 μ 值受初始样本对距离影响较大。假设正负样本对均匀散落在空间中,则 μ 取值偏大。从图2对数逻辑损失函数分布可知当正样本对距离略小于 μ 时,损失值快速接近0,且梯度迅速减小,则算法收敛时即使满足训练集中负样本对距离大于正样本距离,但正样本在新的特征空间中的分布仍然相对分散,测试时基于距离度量在噪声影响下容易受到影响。

2.3 等距度量学习策略

基于2.2节对MLAPG算法中间隔参数 μ 取值的分析,将等距度量引入马氏度量学习算法,对于来自同一行人的样本对 $\mathbf{x}_i$ 和 $\mathbf{z}_j$,学习度量矩阵满足 $D_{\mathbf{M}}^2(\mathbf{x}_i, \mathbf{z}_j) = 0$,即在通过度量矩阵转化得到的特征空间中,将来自同一行人的图像特征映射成一个空间中的一个点,图3说明等距条件约束如何解决正负样本对在变换空间中距离分布存在交叉分布的问题。

图3给出在不同限制条件下正负样本对距离变化情况,图3(a)给出初始的正负样本对距离分布,这里假设初始条件下,正负样本对特征距离分布近似正态分布,且正样本对特征平均距离小于负样本对平均距离。在图中使用黑色线标示出均值取值,MLAPG算法使用它作为正负样本对距离的上下界,由于负样本对距离主导初始样本对距离均值,




图1 MLAPG算法中 μ 取值和训练过程中所有样本对马氏距离均值对比示意图




图2 对数逻辑损失函数变化趋势




图3 在不同限制条件下正负样本对距离情况

因此图(a)中黑色线的取值更偏向负样本对距离均值位置。图3(b)给出MLAPG算法收敛时正负样本对距离分布,正样本对距离大多数分布在初始样本对距离均值左侧,负样本对距离大多数分布在初始样本对距离均值右侧,但正负样本对距离分布仍存在交叉部分,即图中阴影所示,而在图3(c)中,由于 $D_M^2(\mathbf{x}_i, \mathbf{z}_j) = 0$ 的限制,正样本对距离分布接近于0,正负样本对距离分布不存在交叉部分,即使负样本对受噪声信息影响被映射到图中均值线左边,也不会落入正样本对有效距离范围内造成误判。

从图3中可以看到即使MLAPG算法收敛,同类样本距离分布与异类样本距离分布仍存在交叉重叠区域,在图4表现为实心点类中大部分样本间距离和星状类大部分样本间距离均受限于一个较小距离,均分布在圆形区域内,但存在样本,如正样本A和负样本B,恰巧落于图3的重叠区域,在图4表现为分布在方框内圆形外的区域。




图4 正负样本分布区域重叠示意图

对于收敛的MLAPG算法,任意给定一个正样本C,理想情况下当样本C在变换空间中落于图5(a),图5(b)所示位置时能得到正确的分类。若受到外部信息干扰,样本C在变换空间中映射的位置产生“偏移”,容易落于图5(c),从而造成误判。

2.4 Equid-MLAPG算法的模型和代价函数求解

假设在特征空间中,来自同一行人的图像能映

射成一个点,而不同行人的图像能保持一定间隔,如式(8)所示。

$$\left. \begin{aligned} D_M^2(\mathbf{x}_i, \mathbf{z}_j) &= 0, & (\mathbf{x}_i, \mathbf{z}_j) &\in S \\ D_M^2(\mathbf{x}_i, \mathbf{z}_k) &> \mu, & (\mathbf{x}_i, \mathbf{z}_k) &\in D \end{aligned} \right\} \quad (8)$$

其中, $\mu = ED_I^2(\mathbf{X}, \mathbf{Z})$, 即 μ 依然取初始化马氏矩阵 $\mathbf{M}$ (通常初始化马氏矩阵 $\mathbf{M}$ 为单位矩阵 $\mathbf{I}$)后所有正负样本对马氏距离的均值。则Equid-MLAPG算法的代价函数重新定义为

$$\begin{aligned} F(\mathbf{M}) &= \frac{\gamma}{|S|} \sum_{(\mathbf{x}_i, \mathbf{z}_j) \in S} \lg(1 + \exp(D_M^2(\mathbf{x}_i, \mathbf{z}_j))) \\ &+ \frac{1-\gamma}{|D|} \sum_{(\mathbf{x}_i, \mathbf{z}_j) \in D} \lg(1 + \exp(\mu \\ &- D_M^2(\mathbf{x}_i, \mathbf{z}_j))) + \frac{2}{\lambda} \times \|\mathbf{M} - \mathbf{I}\|_F^2 \end{aligned} \quad (9)$$

λ 是正则项系数, $\mathbf{I}$ 是单位阵, γ 用于改变正负样本对损失程度对总代价函数的贡献程度, $|S|$, $|D|$ 表示对正样本对集 S 和负样本对集 D 取个数, $\|\cdot\|_F$ 表示矩阵的F范数。算法最终的优化目标如式(9)所示。

和MLAPG算法相同,本文使用APG算法^[12,13]求解式(9)。APG是一种收敛速率为 $O(1/t^2)$ 的1阶优化算法,其中 t 指迭代次数。给定一个解路径 $\{\mathbf{M}_t\}_{t \geq 0}$, APG算法在每一轮迭代过程中通过式(10)线性联合两个最新的解 $\mathbf{M}_{t-1}$ 和 $\mathbf{M}_{t-2}$ 构造聚合序列 $\{\mathbf{V}_t\}_{t \geq 1}$ 来加速优化速度。

$$\mathbf{V}_t = \mathbf{M}_{t-1} + \frac{\alpha_{t-1} - 1}{\alpha_t} (\mathbf{M}_{t-1} - \mathbf{M}_{t-2}) \quad (10)$$

其中, α_t 的更新公式如式(11)所示。

$$\alpha_t = (1 + \sqrt{4\alpha_{t-1}^2 + 1})/2 \quad (11)$$

通过前向聚合矩阵 $\mathbf{V}_t$ 可以得到一个可以线性化目标公式(12)的近似操作:

$$\begin{aligned} P_{\eta_t}(\mathbf{M}, \mathbf{V}_t) &= F(\mathbf{V}_t) + \langle \mathbf{M} - \mathbf{V}_t, \nabla F(\mathbf{V}_t) \rangle \\ &+ \frac{1}{2\eta_t} \|\mathbf{M} - \mathbf{V}_t\|_F^2 \end{aligned} \quad (12)$$




图5 交换空间中样本分类情况

其中, $\nabla F(\mathbf{V}_t)$ 表示优化目标函数 F 对时刻 t 的前向聚合矩阵 $\mathbf{V}_t$ 的导数, $\langle \mathbf{A}, \mathbf{B} \rangle = \text{Tr}(\mathbf{A}^T \mathbf{B})$ 表示矩阵内积, $\|\cdot\|_F$ 表示矩阵的F范数, 步长 η_t 要求大于0。文献[14]证明在一个合适步长 η_t 下, 式(12)是优化目标函数 $F(\mathbf{M})$ 的上界, 所以优化式(7)可以等价于优化式(13):

$$\left\{ \begin{array}{l} \min_{\mathbf{M}} P_{\eta_t}(\mathbf{M}, \mathbf{V}_t) \\ \text{s.t. } \mathbf{M} \geq 0 \end{array} \right\} \quad (13)$$

文献[13]证明了式(13)的解可以使用式(14)更新:

$$\mathbf{M}_t = \mathbf{U}_t \mathbf{\Lambda}_t^+ \mathbf{U}_t^T \quad (14)$$

其中, $\mathbf{U}_t, \mathbf{\Lambda}_t$ 是对称矩阵 $\mathbf{C}_t = \mathbf{V}_t - \eta_t \nabla F(\mathbf{V}_t)$ 进行SVD分解得到的酉矩阵和对角矩阵。对包含 $\mathbf{C}_t$ 奇异值的对角矩阵 $\mathbf{\Lambda}_t$ 取 $\mathbf{\Lambda}_t^+ = \max\{0, \mathbf{\Lambda}_t\}$ 。对称矩阵 $\mathbf{C}_t = \mathbf{V}_t - \eta_t \nabla F(\mathbf{V}_t)$ 中的 η_t 通过线性搜索使得 $F(\mathbf{M}_t) \leq P_{\eta_t}(\mathbf{M}_t, \mathbf{V}_t)$ 成立来确定。

Equid-MLAPG算法的代价函数的改进主要影响了优化目标函数 F 对时刻 t 的前向聚合矩阵 $\mathbf{V}_t$ 的导数 $\nabla F(\mathbf{V}_t)$, $\nabla F(\mathbf{V}_t)$ 的具体计算公式如式(15):

$$\begin{aligned} \nabla F(\mathbf{V}_t) &= \frac{\partial F(\mathbf{V})}{\partial \mathbf{V}} \big|_{\mathbf{V} = \mathbf{V}_t} \\ &= \sum_{i=1}^n \sum_{j=1}^m g_{ij}^{(t)} (\mathbf{x}_i - \mathbf{z}_j) (\mathbf{x}_i - \mathbf{z}_j)^T \\ &\quad + \lambda (\mathbf{M} - \mathbf{I}) \\ &= \mathbf{X} \mathbf{A}_t \mathbf{X}^T - \mathbf{X} \mathbf{G}_t \mathbf{Z}^T - (\mathbf{X} \mathbf{G}_t \mathbf{Z}^T)^T \\ &\quad + \mathbf{Z} \mathbf{B}_t \mathbf{Z}^T + \lambda (\mathbf{M} - \mathbf{I}) \end{aligned} \quad (15)$$

其中, g_{ij} 具体表达式为

$$g_{ij}^{(t)} = \begin{cases} \frac{\gamma}{|S|} \frac{1}{1 + e^{-D_{V_t}^2(\mathbf{x}_i, \mathbf{z}_j)}}, & (\mathbf{x}_i, \mathbf{z}_j) \in S \\ \frac{1-\gamma}{|D|} \frac{1}{1 + e^{(D_{V_t}^2(\mathbf{x}_i, \mathbf{z}_j) - \mu)}}, & (\mathbf{x}_i, \mathbf{z}_j) \in D \end{cases} \quad (16)$$

3 实验结果与分析

本节实验在VIPeR^[14], CUHK01^[15], CUHK03^[16], Market1501^[17]和DukeMTMC-reID^[18]等多个数据集上将Equid-MLAPG算法和线性距离度量算法XQDA^[19], MLAPG^[11]。于核变换距离度量算法Nullspace^[20]进行对比, 性能评价方法使用累计匹配特性曲线^[21]和mAP^[17]。

3.1 基于LOMO特征^[19], GOG特征^[22]的多种度量学习算法性能对比实验

在VIPeR数据集上使用Equid-MLAPG算法和MLAPG等对比算法使用10折交叉验证计算平均CMC值, 得到的CMC曲线图如图6所示。从CMC曲线可以看出Equid-MLAPG算法识别准确率高于MLAPG算法, 尤其在GOG特征表现更为突出。但是Equid-MLAPG算法的性能略低于Nullspace, Equid-MLAPG算法是基于核变换计算距离的, 在训练阶段需要计算一个与训练集样本数目相同的方阵, 当训练样本增多时, Nullspace算法的训练时间急剧增加。在图7中可以看到Equid-MLAPG算法的性能比Nullspace算法在LOMO特征和GOG特征上均有明显提升, 在排名等级为1时相应提升了2.53%和5.1%。实验证明, Equid-MLAPG算法对行人重识别问题识别精度有提升作用, 且算法对不同特征上实验性能稳定, 具有很好的鲁棒性。

3.2 不同数据集上多种度量学习算法对比实验

为了进一步说明等距度量策略的有效性, 本文还进行了在CUHK03, Market1501和DukeMTMC-reID 3个大规模数据集上基于LOMO特征的对比实验, 实验结果如表1和表2所示, 其中表1中检测标注表示在CUHK03数据集通过DPM算法标注的行人框进行实验, 人工标注表示在CUHK03数据集人工标注的行人框上进行实验。表1和表2中第N匹配率表示在排名等级为N时行人匹配的正确率。为了保证实验结果的可对比性, 在每一个数据集上均使




图6 VIPeR数据集上Equid-MLAPG算法与其他距离度量算法CMC曲线图




图7 CUHK01数据集上Equid-MLAPG算法与其他距离度量算法CMC曲线图

表1 CUHK03数据集上多种距离度量算法对比

算法	检测标注			人工标注		
	第1匹配率(%)	第5匹配率(%)	第10匹配率(%)	第1匹配率(%)	第5匹配率(%)	第10匹配率(%)
XQDA	46.25	78.90	88.55	52.20	82.23	92.14
MLAPG	51.15	83.55	92.05	57.96	87.09	94.74
Nullspace	53.70	83.05	90.30	58.90	85.60	92.45
Equid-MLAPG	52.41	85.25	92.84	58.72	89.07	95.28

表2 Market1501, DukeMTMC-reID数据集上多种距离度量算法对比

算法	Market1501数据集		DukeMTMC-reID数据集	
	第1匹配率(%)	平均准确率(%)	第1匹配率(%)	平均准确率(%)
XQDA	43.23	22.00	31.37	17.17
MLAPG	42.52	21.45	36.58	19.10
Nullspace	54.60	29.80	45.02	26.11
Equid-MLAPG	44.25	24.38	39.25	21.54

用相同的训练集/测试集划分结果。

Equid-MLAPG算法基于MLAPG算法提出,在CUHK03_DETECTED数据集、CUHK03_LABELLED数据集、Market1501数据集和DukeMTMC-reID数据集相比MLAPG算法性能分别提升1.26%, 0.76%, 1.73%和2.67%,说明对同一行人引入的等距离度量方案的有效性。在和线性距离度量算法XQDA的比较中, Equid-MLAPG算法也表现更优。尽管基于核变换的Nullspace算法性能表现更好,但是Equid-MLAPG算法随着排名等级增加,识别率的提升速度要高于Nullspace算法,可见等距离度量策略有效地对一些噪声样本有更强的剔除作用,在图像库中要求检索的图像数目较多的情况下可以快速检索到正确目标,具有更强的实用性。

4 结束语

行人重识别距离度量MLAPG算法基于马氏矩阵得到的变换空间中同类样本间的距离分布范围

宽,测试时对噪声敏感,本文通过引入等距离度量学习策略,约束同类样本在变换空间中映射成一个点,以此来提高算法对任意样本在变换空间中由于干扰信息导致的映射位置的“偏移”和相似度量误差的鲁棒性。通过在多个数据集上跟不同距离度量算法的对比,验证了等距离度量学习策略的正确性和有效性, Equid-MLAPG算法具有更好的识别率,同时设计了在不同特征上与不同距离度量学习算法的对比,说明了等距离度量学习策略的广泛适用性。

参考文献

- [1] ZHENG Liang, YANG Yi, and HAUPTMANN A G. Person re-identification: Past, present and future[OL]. arXiv preprint arXiv: 1610.02984, 2016.
- [2] SHAH J H, LIN Mingqiang, and CHEN Zonghai. Multi-camera handoff for person re-identification[J]. *Neurocomputing*, 2016, 191: 238-248. doi: 10.1016/j.neucom.2016.01.037.

- [3] REHMAN S U, CHEN Zonghai, RAZA M, *et al.* Person re-identification post-rank optimization via hypergraph-based learning[J]. *Neurocomputing*, 2018, 287: 143–153. doi: [10.1016/j.neucom.2018.01.086](https://doi.org/10.1016/j.neucom.2018.01.086).
 - [4] PEDAGADI S, ORWELL J, VELASTIN S, *et al.* Local fisher discriminant analysis for pedestrian re-identification[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Portland, USA, 2013: 3318–3325.
 - [5] WEINBERGER K Q, BLITZER J, and SAUL L K. Distance metric learning for large margin nearest neighbor classification[C]. *Advances in Neural Information Processing Systems*. Vancouver, Canada, 2006: 1473–1480.
 - [6] DAVIS J V, KULIS B, JAIN P, *et al.* Information-theoretic metric learning[C]. *Proceedings of the 24th International Conference on Machine Learning*, Corvalis, USA, 2007: 209–216.
 - [7] DIKMEN M, AKBAS E, HUANG T S, *et al.* Pedestrian recognition with a learned metric[C]. *Asian Conference on Computer Vision*, Queenstown, New Zealand, 2010: 501–512.
 - [8] ZHENG Weishi, GONG Shaogang, and XIANG Tao. Person re-identification by probabilistic relative distance comparison[C]. *Computer Vision and Pattern Recognition*, IEEE, Colorado, USA, 2011: 649–656.
 - [9] KOESTINGER M, HIRZER M, WOHLHART P, *et al.* Large scale metric learning from equivalence constraints[C]. *Computer Vision and Pattern Recognition (CVPR)*, Rhode Island, USA, 2012: 2288–2295.
 - [10] TAO Dapeng, JIN Lianwen, WANG Yongfei, *et al.* Person re-identification by regularized smoothing kiss metric learning[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2013, 23(10): 1675–1685. doi: [10.1109/tcsvt.2013.2255413](https://doi.org/10.1109/tcsvt.2013.2255413).
 - [11] LIAO Shengcai, and LI S Z. Efficient PSD constrained asymmetric metric learning for person re-identification[C]. *Proceedings of the IEEE International Conference on Computer Vision*. Santiago, USA, 2015: 3685–3693.
 - [12] NESTEROV Y. *Introductory Lectures on Convex Optimization: A Basic Course*[M]. New York, USA, Springer Science & Business Media, 2013: 15–20.
 - [13] TSENG P. On accelerated proximal gradient methods for convex-concave optimization[OL]. <http://www.mit.edu/~dimitrib/PTseng/papers/apgm.pdf>.
 - [14] GRAY D and TAO Hai. Viewpoint invariant pedestrian recognition with an ensemble of localized features[C]. *European Conference on Computer Vision*, Marseille, France, 2008: 262–275.
 - [15] LI Wei, ZHAO Rui, and WANG Xiaogang. Human reidentification with transferred metric learning[C]. *Asian Conference on Computer Vision*. Daejeon, Korea, 2012: 31–44.
 - [16] LI Wei, ZHAO Rui, XIAO Tong, *et al.* Deepreid: Deep filter pairing neural network for person re-identification[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus, USA, 2014: 152–159.
 - [17] ZHENG Liang, SHEN Liye, TIAN Lu, *et al.* Scalable person re-identification: A benchmark[C]. *Proceedings of the IEEE International Conference on Computer Vision*. Santiago, USA, 2015: 1116–1124.
 - [18] ZHENG Zhedong, ZHENG Liang, and YANG Yi. Unlabeled samples generated by GAN improve the person re-identification baseline in vitro[C]. *IEEE International Conference on Computer Vision*. Venice, Italy, 2017: 3774–3782.
 - [19] LIAO Shengcai, HU Yang, ZHU Xiangyu, *et al.* Person re-identification by local maximal occurrence representation and metric learning[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, 2015: 2197–2206.
 - [20] ZHANG Li, XIANG Tao, and GONG Shaogong. Learning a discriminative null space for person re-identification[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, USA, 2016: 1239–1248.
 - [21] 曾明勇, 吴泽明, 田畅, 等. 基于外观统计特征融合的人体目标再识别[J]. *电子与信息学报*, 2014, 36(8): 1844–1851. doi: [10.3724/SP.J.1146.2013.01389](https://doi.org/10.3724/SP.J.1146.2013.01389).
ZENG Mingyong, WU Zeming, TIAN Chang, *et al.* Fusing appearance statistical features for person re-identification[J]. *Journal of Electronics & Information Technology*, 2014, 36(8): 1844–1851. doi: [10.3724/SP.J.1146.2013.01389](https://doi.org/10.3724/SP.J.1146.2013.01389).
 - [22] MATSUKAWA T, OKABE T, SUZUKI E, *et al.* Hierarchical gaussian descriptor for person re-identification[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, USA, 2016: 1363–1372.
- 周智恒: 男, 1977年生, 教授, 博士生导师, 研究方向为模式识别与人工智能。
- 刘楷怡: 女, 1994年生, 硕士生, 研究方向为图像处理与模式识别。
- 黄俊楚: 男, 1994年生, 博士生, 研究方向为图像处理与模式识别。
- 陈增群: 男, 1995年生, 本科生, 研究方向为图像处理与模式识别。