

# 控制与决策

Control and Decision

## 行人重识别中度量学习方法研究进展

邹国锋, 傅桂霞, 高明亮, 彭祥, 刘征

引用本文:

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.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0801>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 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>

### 移动机器人运动规划中的深度强化学习方法

Deep reinforcement learning for motion planning of mobile robots

*控制与决策*. 2021, 36(6): 1281–1292 <https://doi.org/10.13195/j.kzyjc.2020.0470>

### 面向复杂网络的异常检测研究进展

Research progress of anomaly detection for complex networks

*控制与决策*. 2021, 36(6): 1293–1310 <https://doi.org/10.13195/j.kzyjc.2020.0055>

### 融合稀疏编码与深度学习的草图特征表示

A feature representation of sketch based on fusion of sparse coding and deep learning

*控制与决策*. 2021, 36(3): 699–704 <https://doi.org/10.13195/j.kzyjc.2019.0941>

### 基于共享隐空间的多视角SVM

Multi view SVM based on common hidden space

*控制与决策*. 2021, 36(3): 534–542 <https://doi.org/10.13195/j.kzyjc.2019.0829>

# 行人重识别中度量学习方法研究进展

邹国锋<sup>1†</sup>, 傅桂霞<sup>1</sup>, 高明亮<sup>1</sup>, 彭祥<sup>2</sup>, 刘征<sup>2</sup>

(1. 山东理工大学 电气与电子工程学院, 山东 淄博 255049;  
2. 不列颠哥伦比亚大学 工程学院, 不列颠哥伦比亚 基洛纳 V1V1V7)

**摘要:** 行人重识别是计算机视觉领域极具挑战的研究课题. 近年来, 伴随大规模行人数据集推出和深度学习发展, 针对行人特征提取与描述、距离度量学习两大关键技术的研究取得众多成果. 已有综述文献主要对特征提取与描述方法开展了归纳总结, 尚缺乏对度量学习方法的全面分析. 同时, 鉴于度量学习在提升重识别性能中的关键作用, 有必要对行人重识别中度量学习研究现状进行系统梳理. 基于此, 从距离度量方式、度量学习算法和重排序 3 方面系统总结了行人重识别度量学习方法, 比较了部分典型方法的实验效果, 并对未来可能的研究方向作了展望.

**关键词:** 行人重识别; 距离度量; 度量学习算法; 重排序

中图分类号: TP391

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.0801

开放科学(资源服务)标识码(OSID):



**引用格式:** 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.

## A survey on metric learning in person re-identification

ZOU Guo-feng<sup>1†</sup>, FU Gui-xia<sup>1</sup>, GAO Ming-liang<sup>1</sup>, PENG Xiang<sup>2</sup>, LIU Zheng<sup>2</sup>

(1. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China;  
2. School of Engineering, University of British Columbia-Okanagan, Kelowna V1V1V7, Canada)

**Abstract:** Person re-identification is a very challenging research topic in the field of computer vision. In recent years, with the emergence of large-scale datasets and development of deep learning, many results have been obtained in the study of person feature extraction and description, distance metric learning. In the existing literature, feature extraction and description have been well summarized, but there is no comprehensive analysis of metric learning. Considering the key role of metric learning in improving person re-identification, it is necessary to systematically review the research status of metric learning in person re-identification. This survey gives a systematic summary of metric learning methods from three perspectives: distance metric methods, metric learning algorithms and re-ranking algorithms. Then, the performance of some representative methods are compared and analyzed. Finally, we make a prospect for the future research direction of metric learning.

**Keywords:** person re-identification; distance metric; metric learning algorithm; re-ranking algorithm

## 0 引言

行人重识别(person re-identification)是确立不同摄像机所得行人图像间对应关系的过程,属于典型的图像检索问题.目前,在学术界和工业界均得到广泛关注,已成为计算机视觉领域的研究热点.但是,受不同摄像机分辨率差异、拍摄视角、光照、遮挡及行人姿态等因素影响,行人重识别面临众多技术挑战.

2003年,跨视域目标匹配问题研究<sup>[1]</sup>被认为是“重识别”技术的起源,2006年“行人重识别”概念<sup>[2]</sup>被正式提出.2014年,文献[3]首次对行人重识别定

义、现状和挑战,及主要数据集作了分析和综述.同年,深度网络在ImageNet竞赛中夺冠<sup>[4]</sup>,基于深度学习的行人重识别受到研究者的青睐.2018年,李幼蛟等<sup>[5]</sup>再次对行人重识别的现状进行综述,涉及到部分深度行人重识别方法的归纳和比较.2019年,罗浩等<sup>[6]</sup>针对基于深度学习的行人重识别现状作了更为深入的对比分析.

行人重识别系统如图1所示.其中,行人检测与跟踪<sup>[7-8]</sup>已成为计算机视觉领域独立的研究课题,经过多年发展已比较成熟.目前,行人重识别研究主要

收稿日期: 2020-06-18; 修回日期: 2020-10-29.

基金项目: 国家自然科学基金项目(61601266, 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).

<sup>†</sup>通讯作者. E-mail: zgf841122@163.com.

包括:行人特征提取与描述、距离度量学习。




图1 行人重识别系统流程

文献[3,5-6]重点梳理了行人重识别中的特征提取与描述方法,对行人距离度量的分析较少。同时,鉴于可靠度量在重识别准确率提升中的关键作用,有必要对近年来行人重识别中的度量学习方法进行系统总结。

行人重识别中的度量学习通常将“度量”和“度量学习”作为整体对待,但两者存在本质区别。度量,是原始特征(或样本)通过度量矩阵映射,求取嵌入空间中特征间距离或相似度的过程。度量学习,是设计一种目标函数,通过优化问题求解获取度量矩阵的过程。因此,为更好地梳理行人重识别中度量学习方法,本文将“度量”与“度量学习”分开讨论。考虑到完成距离度量后,需要对度量结果做进一步优化和重排序,本文将“重排序算法”作为行人重识别度量学习的一项内容进行归纳。

综上所述,本文对2015年以来行人重识别中的度量学习方法进行综述,从度量方法、度量学习算法和重排序3方面展开讨论,并对比分析部分代表性方法的实验结果。在此基础上,探讨行人重识别中度量学习的热点问题和未来可能的研究方向,以为研究者提供借鉴和参考。

## 1 行人重识别中的度量方法

### 1.1 马氏距离度量

马氏距离度量,是行人重识别中样本对距离或相似性度量的经典方式。给定 $R^d$ 空间上的 $n$ 个特征 $[x_1, x_2, \dots, x_n]$ ,则马氏距离<sup>[9]</sup>定义为

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

其中半正定阵 $M$ 为待求解马氏距离度量矩阵。

带约束马氏距离度量。针对小样本导致的度量过拟合问题,齐美彬等<sup>[10]</sup>借鉴平滑正则化算法<sup>[11]</sup>提出正则化约束的马氏度量矩阵。Zhou等<sup>[12]</sup>利用原始数据 $X$ 构建参考集合 $R$ ,并定义了新的带参考约束的马氏度量矩阵

$$M = (A)^{-1} X^T R R^T X (A)^{-1}. \quad (2)$$

其中: $A = X^T X + \lambda n I$ , $\lambda$ 表示约束项平衡权重参

数, $I$ 表示单位阵, $n$ 表示集合中样本个数。

### 1.2 非对称距离度量

针对行人视角变化导致特征失效和度量效果差的问题,Chen等<sup>[13]</sup>提出非对称距离度量概念,通过非对称变换将视图不匹配特征转换到公共空间,然后提取鉴别特征,并定义了跨视角和同视角距离

$$d(x_i^p, x_j^q) = \|U^{pT} x_i^p - U^{qT} x_j^q\|_2^2, \quad (3)$$

$$d(x_i^p, x_j^p) = \|U^{pT} x_i^p - U^{pT} x_j^p\|_2^2. \quad (4)$$

其中: $U^p$ 、 $U^q$ 表示针对视角 $p$ 和 $q$ 的非对称度量矩阵, $x_i^p$ 表示视角 $p$ 中第 $i$ 个样本。

Yu等<sup>[14]</sup>提出一种无监督非对称度量方法,通过非对称映射将不同视角行人图像变换到共享空间,使不同视角样本的差异得到缓解。Feng等<sup>[15]</sup>针对常用度量仅考虑视图共享特征,而忽略视图特定特征,易导致信息丢失的问题,提出基于数据分布特性的无监督跨视角度量,通过求解共享映射和特定视角映射获得投影度量矩阵。

### 1.3 基于超图的相似性度量

针对常用度量仅考虑测试样本与目标样本的两两相似性,而忽视样本间高阶相关性的问题,An等<sup>[16]</sup>提出基于超图的行人匹配方案。通过超图学习挖掘测试样本与目标样本的两两关系和高阶关系,得到改进的相似度评分,提升重识别效果,算法流程如图2所示。Zhao等<sup>[17]</sup>提出基于多超图联合学习的相似性度量,针对输入图像对分别提取gBicov、HLCNL和LOMO特征,然后采用多超图联合学习算法学习多特征相关性,确定行人身份。基于超图的距离度量利用图模型综合考虑了测试数据和目标数据集之间的高阶相关性,实现了不同特征的充分表达和信息传递,是一种有效的行人多特征相似性度量方法。




图2 基于超图的行人匹配方案

### 1.4 基于集合的度量

样本集合间的相关性为改善行人重识别效果提供了重要信息。2015年,Li等<sup>[18]</sup>以成对图像集为输入,定义了集合-集合差异性,用于构建类内紧致、类间离散的局部度量域,然后采用集合级近邻建模实现集合-集合的数据匹配。Tan等<sup>[19]</sup>将成对图像序列划分为不同小组,基于组内全连接和组间无连接规则,

得到集合相似性差异特征,最后采用Adaboost分类器实现不同视角行人图像序列匹配. Cho等<sup>[20]</sup>针对输入图像对集合,分别估计行人前、后、左、右4种姿态,实现不同视角行人信息关联,然后以行人姿态为先验信息,将行人重识别转换为固定姿态下行人图像集的匹配问题.

基于集合的度量将单一的成对样本匹配扩展为成对样本集的匹配,利用样本集局部邻域的相关结构信息和上下文信息,克服了单一行人图像的可变性和稀疏性,缓解了传统度量判别能力被弱化和过拟合问题,有助于提升重识别准确率.

### 1.5 矩阵距离度量

2017年,Wang等<sup>[21]</sup>提出一种差异矩阵行人特征表达模式,并定义行人特征矩阵度量方式

$$d(X_p^A, X_q^B) = \|L_1(X_p^A - X_q^B)L_2\|_F^2. \quad (5)$$

其中: $(X_p^A, X_q^B)$ 表示两输入图像集的特征矩阵, $L_1$ 和 $L_2$ 表示待求解的类内投影矩阵和类间投影矩阵.基于此度量方式,Chen等<sup>[22]</sup>提出双向参考集的矩阵度量学习方法,与文献[21]不同,采用双向互近邻参考集描述样本外观差异特征,解决了外观差异不显著导致特征描述不准确的问题.

度量方式改进是改善行人重识别性能的重要手段,但新度量方式的提出难度较大,且度量矩阵学习需要与特定目标函数相关联,通用性受到一定限制.因此,相比设计新度量方式,在已有度量方式基础上,设计或改进度量学习的目标函数更受到研究者青睐,且取得了较多研究成果.考虑到深度学习对度量学习的影响,本文将度量学习算法划分为“经典度量学习算法”和“深度度量学习算法”.

## 2 经典度量学习算法

经典度量学习是在某种约束下,定义一种显式目标函数,并通过求解最优化问题获取鉴别力强、鲁棒性好的度量矩阵.尽管经典度量学习已得到较多应用<sup>[23-28]</sup>,但所得度量矩阵仍面临过拟合、分类能力弱、鲁棒性差等问题.因此,研究者从度量学习目标函数改进和多度量融合两个角度提出相应的改进.

### 2.1 改进度量学习目标函数

针对度量学习算法鲁棒性差的问题,Zhou等<sup>[29]</sup>提出融合贡献度的LMNN目标函数.通过样本加权使同类样本紧致,不同类样本远离,通过局部特征加权实现不同特征奖惩.Tan等<sup>[30]</sup>设计了一种同时最大化间隔和最小化融合特征误差的排序模型,将模型约束融入RankSVM的优化目标函数,辅助求解最优度量.Wang<sup>[31]</sup>和Zhou等<sup>[32]</sup>提出改进的等距约束度

量学习,将同类样本映射到单纯形同一顶点,不同类样本映射到不同顶点,定义了最小化类内距离和最大化类间最小间隔的目标函数,提升了图像特征可分性和度量矩阵鲁棒性.

针对成对约束度量学习的数据不平衡问题,Ding等<sup>[33]</sup>提出距离中心化的相似性度量学习算法,利用中心特征值定义类间距离,类内距离保持传统计算方式,目标函数采用对数相对距离比较模型,有效缓解了因类别不平衡引起的过拟合.Dong等<sup>[34]</sup>提出大间隔相对距离学习方法,以三元组为输入,提取行人不同条形区域的颜色和纹理特征,以最小类间距离强制惩罚三元组,同时采用逻辑损失函数实现相对距离比较,目标函数如下:

$$L_M(x_i, z_j, z_k) = \log(1 + \exp(\Delta_M(x_i, z_j, z_k))). \quad (6)$$

其中: $(x_i, z_j, z_k) \in T$ 为三元组集合; $\Delta_M(x_i, z_j, z_k) = d_M^2(x_i, z_j) - \min_k d_M^2(x_i, z_k) + \delta$ , $d_M^2(\cdot)$ 是马氏距离度量, $\delta$ 是距离空间中正负样本对间的最小间隔.

为克服传统度量模型的过拟合问题,He等<sup>[35]</sup>提出环推度量学习算法.与惩罚类间距离过小的度量学习不同,该方法既惩罚类间距离过小的度量,也惩罚类间距离过大的度量,其目标函数为

$$L = \frac{1}{N} \sum_{i=1}^N l_p(x_i, z_i) + \frac{1}{N(N-1)} \sum_{i \neq j} l_n(x_i, z_j). \quad (7)$$

其中: $N$ 为样本对数, $l_p(x_i, z_i)$ 为相似图像对损失, $l_n(x_i, z_j)$ 为不相似图像对损失.

### 2.2 多度量融合方法

针对度量学习目标函数的改进主要是实现单一距离度量阵的性能提升,但单一度量往往无法兼顾不同目标行人的不同视觉特征度量,因此研究者从多特征子空间度量融合的角度出发,设计了不同的多度量融合算法.Li等<sup>[36]</sup>提出基于不同候选集优化学习不同视觉度量的思想,基于样本视觉相似性,将大规模训练集划分为不同候选集,并赋予不同权重,然后基于不同候选集进行训练学习,得到多个不同的最大间隔度量.Syed等<sup>[37]</sup>提出自适应加权多核方法,针对输入图像对提取颜色和纹理特征,并将两种特征采用不同核函数映射到对应子空间.度量学习中,对不同特征进行自适应加权,然后采用Fisher判别分析获得不同核空间的加权重度量阵,增强了度量的鲁棒性.Barman等<sup>[38]</sup>针对输入图像对,采用SDALF、SDC\_knn、SDC\_ocsvm和XQDA四种度量方法计算图像对间的距离,然后采用加权分数距离聚合框架实现多度量融合,提升重识别准确性.齐美彬等<sup>[39]</sup>针对

不同特征融合后度量学习容易忽略不同特征间的差别,且所得度量矩阵不能准确表达样本间相似性与差异性的问题,提出基于多特征子空间与核学习的行人重识别算法.通过核学习将特征映射到不同核子空间,在核子空间中定义相似度量函数为

$$S(k_i, k_j) = (k_i - k_j)^T M (k_i - k_j). \quad (8)$$

其中:  $M$  是待学习的度量阵,  $k_i$  是核空间中的  $i$  个非线性特征.基于不同行人特征能够学习到不同的相似测度,通过加权方式计算不同子空间的相似度和为

$$S = \alpha S_C + (1 - \alpha) S_T, \quad (9)$$

其中  $S_C$ 、 $S_T$  是两个不同特征子空间的相似度量函数,对应不同的度量阵.

多度量融合采用行人图像的多种特征训练度量矩阵,丰富了具有区别性的训练数据,达到数据增强的效果;另一方面,不同特征训练获得的度量矩阵具有不同的度量能力和优势,融合的度量阵则具有更强的鉴别力、泛化能力和鲁棒性.

### 3 深度度量学习算法

深度度量学习是通过深度网络模型提取目标图像特征,并基于深度特征构造损失函数,通过损失函数优化求解,实现目标图像本质特征提取和可靠分类.损失函数是除网络结构外,影响深度学习算法的关键因素,研究者通常将损失函数设计等价于基于深度网络的度量学习.本文将深度网络损失概括为 Softmax 损失、对比损失、三元组损失、联合损失和集群损失.

#### 3.1 Softmax 损失

Softmax 函数<sup>[4,40]</sup>是深度度量学习的经典损失形式,函数的对数表达式如下:

$$L_s = - \sum_{i=1}^m \log \left( \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^C e^{W_j^T x_i + b_j}} \right). \quad (10)$$

其中:  $W_j$  为最终全连接层权重矩阵  $W$  的第  $j$  列,  $b$  为偏置项,  $C$  为类别数,  $m$  为批训练样本规模.

Softmax 损失直接用于行人重识别无法同时实现深度特征类内紧致和类间分离,影响重识别精度,研究者从不同角度对该损失做了改进. Zhu 等<sup>[41]</sup>引入中心化损失,并与 Softmax 损失联合实现最大限度的类间分散和类内紧致. Borgia 等<sup>[42]</sup>提出引导元中心项损失和增强中心分散项损失,将两个损失项与 Softmax 损失结合形成新损失函数,降低了类间干扰,同时克服了跨视角模糊问题.针对视角变化导致类内特征分化的挑战, Feng 等<sup>[43]</sup>提出跨视角欧氏约束和跨视角中心损失约束的概念,并将两种约束分别与

Softmax 损失结合形成联合损失.跨视角欧氏约束实现了不同视角深度特征对齐,中心化损失约束缩小了不同视角特征间的差距.综上,通过联合中心化损失和特殊约束惩罚项有效改善了 Softmax 损失函数的性能,有助于深度网络参数优化和度量性能提升.

#### 3.2 对比损失

对比损失 (contrastive loss)<sup>[44]</sup>能有效表达行人样本对的匹配程度,同时较好地指导深度网络训练,其函数形式如下:

$$L = \frac{1}{2N} \sum_{n=1}^N y d^2 + (1 - y) \max(m - d, 0)^2. \quad (11)$$

其中:  $N$  为样本对数量,  $d$  为两样本间欧氏距离,  $y$  为类别匹配标签,  $m$  为距离阈值.

因行人图像受复杂因素干扰,对比损失直接用于计算行人相似度时,特征匹配准确度往往不高. Wang 等<sup>[45]</sup>提出由相似度比较项和正则化项组成的自适应间隔损失,达到最小化同类样本特征对距离,最大化不同类样本特征对距离的目的. Zhu 等<sup>[46]</sup>提出加权融合混合相似度量,定义了一种带正则化项的平均对数对比损失,达到合理分配特征学习和度量学习复杂性的目的. Sarfraz 等<sup>[47]</sup>定义了扩展交叉邻近距离,将样本对之间的距离度量扩展为样本对交叉邻域集合间的距离度量,并构建了面向邻域集合的双向对比损失函数,实现了单测试样本与训练样本邻域集,以及单训练样本与测试样本集的双向距离度量.

对比损失以图像对为输入,通过最小化同类样本对的距离惩罚不同类样本间距离小于阈值的方式,实现网络参数优化和相似性度量.它通常会与新距离度量方法、正则化约束项或行人数据集的特点结合,定义新损失形式.改进的对比损失拓展了经典对比损失的使用范围,既能减轻网络参数训练难度,也能有效增强网络提取判别特征的能力.

#### 3.3 三元组损失

Schroff 等<sup>[48]</sup>提出三元组损失 (triplet loss),其目标是 minimized 锚点和正例间的距离,最大化锚点和负例间的距离,同时使负样本对间的距离与正样本对间的距离保持最小间隔.损失函数为

$$l = \sum_i^N [d(f(x_i^a), f(x_i^p)) - d(f(x_i^a), f(x_i^n)) + \alpha]. \quad (12)$$

其中:  $x_i^a$  为锚点样本,  $x_i^p$  为正例,  $x_i^n$  为负例,  $N$  为三元组个数,  $f(\cdot)$  为网络模型,  $\alpha$  为距离阈值.

三元组损失仅比较了单个正负样本间的距离,只能促进测试样本与选中的负样本保持较大距离,不能

保证与其他未被选择的负样本也保持较大距离. 因此, 研究者提出多种改进的三元组损失. Yang等<sup>[49]</sup>针对三元组损失收敛速度慢和局部最优, 以及困难正样本在网络训练中未得到足够重视的问题, 提出结构深度度量学习方法, 减小了正/负样本对的距离方差, 增强了损失函数的泛化能力. He等<sup>[50]</sup>针对三元组损失无法充分利用批处理信息的问题, 提出改进的提升结构损失函数, 用于监督深度网络学习更好的特征嵌入. Chen等<sup>[51]</sup>针对三元组损失更加关注训练集, 测试集中泛化能力较弱的问题, 提出改进输入元组构建方法, 在原三元组损失基础上, 引入了由负例与第二负例构建得到的一种新约束项, 构成四元组损失. 四元组损失能更好地实现类间距离最大化、类内距离最小化, 增强训练模型的泛化能力.

### 3.4 联合损失

以上3节介绍了Softmax损失、对比损失和三元组损失, 3种损失在不同的识别任务中展现出各自的特点. 为融合不同损失的优点, 提升行人重识别准确率, 研究者提出多任务学习、多特征度量等思路, 因此多种损失函数的联合学习被广泛采用.

McLaughlin等<sup>[52]</sup>和Ling等<sup>[53]</sup>采用行人身份验证、身份识别和属性识别构成多任务目标, 将不同任务的目标损失加权融合, 形成联合损失, 通过多任务联合学习和损失融合提升网络综合学习能力. Li等<sup>[54]</sup>和Zhou等<sup>[55]</sup>基于行人局部和全局特征的互补效应, 分别构建局部和全局深度网络, 并形成局部损失和全局损失, 引入正则化约束构建联合损失. 全局和局部损失联合能克服视角和遮挡干扰, 保证网络获得鲁棒且可分性好的特征. Cheng等<sup>[56]</sup>利用三元组特征分别计算非对称三元组损失和Softmax损失, 两种损失融合获得联合目标函数, 既能使同类行人特征更紧凑, 不同行人特征远离, 又有助于学习与行人身份相关的判别特征.

### 3.5 集群损失

行人样本充足时, 局部空间分布关系、样本对与局部区域内其他样本对的相互关系在行人相似性度量中展现出独特优势. Li等<sup>[57]</sup>针对每个锚点样本定义了包含上下文信息和邻域结构的正、负支持邻域集, 基于这些邻域集提出一种支持邻域损失函数, 能将正样本近邻与负样本近邻可靠分离, 同时保证正样本邻域内的变化最小. Yuan等<sup>[58]</sup>提出一种微型集群聚类损失, 将属于相同身份的样本作为一个微型集群, 在训练中将其作为一个整体使用. 在每个集群中各点之间最大的距离定义为内部散度, 与外部点之间

的最小距离定义为其外部散度, 通过限制外部散度大于内部散度, 在保持类多样性分布的同时, 利用微型集群损失实现了更紧凑的微型集群结构, 提升了模型的泛化能力.

## 4 重排序算法

度量方式和度量学习算法研究在不同程度上克服了行人重识别面临的众多挑战, 但仅依靠这些改进有时并不能获得最优重识别效果. 重排序作为行人相似性度量的一种后处理方式, 为改善重识别准确度提供了重要思路. 现有重排序算法可概括为聚合重排序、图模型重排序和奖惩重排序3类.

### 4.1 聚合重排序

聚合重排序是通过某种融合算法, 将不同的初始排序结果进行聚合, 改善最终相似度排序. Wang等<sup>[59]</sup>和Zhang等<sup>[60]</sup>基于输入行人图像衍生出不同尺度的局部人体区域, 经特征提取后计算各对应局部区域相似度形成初始度量, 最后通过加权平均得到相似度重排序结果, 算法流程见图3. Zhang等<sup>[61]</sup>为保证跨视域行人个体保持结构上的一致性匹配, 提出结构化匹配方法, 通过小区域划分和聚类获取局部敏感视觉模式, 最终通过不同敏感区加权图实现匹配识别. 该方法通过不同敏感区加权突显了人体结构化特征对重识别的不同贡献度.

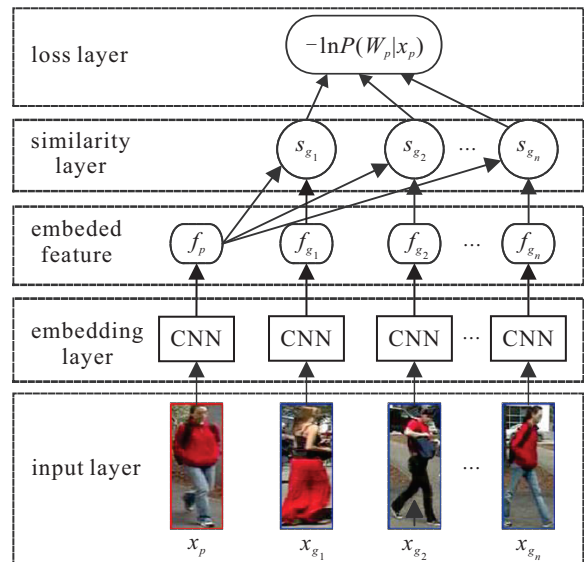


图3 多相似度加权融合算法流程

Chen等<sup>[62]</sup>采用深度网络对行人图像进行多尺度特征嵌入, 并计算测试样本与目标样本在不同尺度空间的相似度, 然后采用连续条件随机场融合所有的“组相似度”. Jaceques等<sup>[63]</sup>采用深度全局网络和卷积网络提取行人前景/背景信息, 形成行人特征描述, 并构建行人多项式特征图, 通过多项式特征图匹配实

现测试样本和目标样本的相似度计算. 因多项式特征图可采用不同组合方式获得, 基于不同特征图可获得多组相似度初始度量结果, 最后采用 DCIA 算法实现聚合重排序.

#### 4.2 图模型重排序

图模型重排序是将初始度量结果映射为一种图模型, 然后通过图模型优化, 获取最优重排序结果. Xie 等<sup>[64]</sup> 针对单一特定度量方法易导致度量结果过拟合的问题, 提出基于图模型的多度量结果融合方法, 如图4所示. Barman 等<sup>[65]</sup> 提出基于分数距离图的行人重识别, 通过某种度量计算测试样本与图库样本相似度分数, 然后将图库样本表达为图模型顶点, 相似度分数表达为图模型连接边强度, 最后采用贪心算法和蚁群算法优化图模型, 实现重排序.

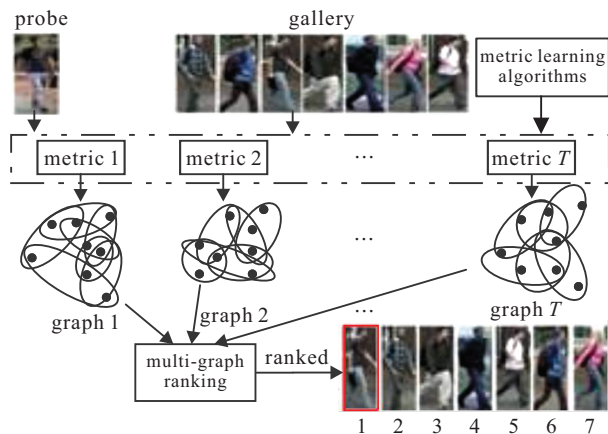


图4 基于图模型的多相似度度量融合

#### 4.3 奖惩重排序

奖惩重排序是通过引入奖惩因子对初始重排序结果进行二次修正, 提升排序结果准确性. Leng 等<sup>[66]</sup> 提出基于反向查询结果修正初始排序列表的重排序方法, 通过反向查询, 将与样本特征相似的  $k$  近邻上下文信息考虑在内, 提升行人匹配正确率. Zhong 等<sup>[67]</sup> 提出基于  $k$  互近邻编码的重排序, 针对初始排序选定一幅图像, 通过其  $k$  互近邻样本编码得出新的  $k$  互特征, 并基于  $k$  互特征计算 Jaccard 距离, 重排序通过初始度量和 Jaccard 距离加权融合获得. 该方法综合利用了样本间相互关系, 通过 Jaccard 距离修正了初始度量结果的偏差. Ye 等<sup>[68]</sup> 提出使用相似和不相似线索的排序优化框架, 利用相似关系得到排序结果, 利用不相似关系产生惩罚因子, 将排序结果和惩罚项结合, 优化了最终排序. Chen 等<sup>[69]</sup> 基于行人图像对深度特征计算相似度分数作为初始排序, 针对未正确匹配的样本集和测试样本共同构建新的错误匹配惩罚损失, 增强对误匹配样本的学习, 使排序混乱代价最小化.

重排序作为针对行人重识别结果的二次优化步骤, 综合利用了行人多局部区域或多特征的度量结果, 实现了信息互补度量融合, 提升了重识别度量结果的合理性和可靠性.

## 5 性能分析与讨论

本节对部分典型算法在常用行人数据集上的实验结果进行了比较和分析. 文献[3, 5-6] 已对常用行人数据集作了详细介绍, 因此本文未对数据集作更多说明. 与前文章节层次一致, 本节分别对度量方法、经典度量学习算法、深度度量学习算法和重排序的实验结果作了归纳, 如表1~表4所示.

衡量行人重识别性能的准则包括累计匹配性能曲线(cumulative match characteristic, CMC)和 Rank- $N$  表格, 其中 Rank- $N$  表格是以数值形式给出关键匹配点的累积匹配准确率. Rank- $N$  表格形式相比 CMC 曲线更加直观, 因此本文采用 Rank- $N$  表格对不同算法性能作了对比展示.

表1的数据表明, 马氏度量及马氏度量改进方法的整体性能较其他度量方式有一定差距. 文献[13] 的非对称距离度量在克服视角和姿态影响中展现出卓越性能; 文献[14-15] 因受无监督限制, 识别性能有所降低, 但整体性能较马氏度量仍有提高. 这表明非对称距离度量在非理想行人重识别中性能优异. 超图相似性度量和集合相似性度量综合利用了上下文关系和邻域关系, 对度量结果改善较为显著.

表2和表3的数据表明, 相比经典度量学习, 深度度量学习 Rank-1 准确度展现出较大提升, 但深度度量学习在 VIPeR 训练样本不充分的数据集上, 并未表现出比经典度量学习优异的性能. 这表明, 深度度量学习更适用于较大规模数据集. 对比 Rank-20 准确度, 经典度量学习和深度度量学习的性能差异非常小. 因此, 在期望获取较大范围重识别候选集时, 经典度量学习对大规模训练集的依赖性弱且算法训练快速, 展现出更明显的优势. 在追求精准重识别时, 因训练样本多样性和深度度量模型较强的非线性特征提取能力, 使深度度量学习具有更大优势.

经典度量学习行人重识别中特征提取与距离度量相对独立. 特征提取常采用人工设计方法捕获颜色和纹理特征、局部显著区域特征, 以及行人衣着、性别、体型等属性特征, 然后将特征或特征组合用于相似性度量, 实现身份判别. 在这种方式下, 行人重识别的两个关键步骤作为相对独立的问题被优化, 忽略了联合优化对重识别性能提升的重要作用. 基于深度度量学习的行人重识别, 则实现了特征提取网络与距离度量的联合优化, 能更好地改善行人重识别性能.

表1 度量方法的性能比较分析

度量方式	算法/文献	数据集	Rank-1	Rank-5	Rank-10	Rank-20	
马氏距离度量	文献[10]	VIPeR	30.0	57.3	69.1	81.9	
		iLIDS	51.0	78.7	85.3	91.4	
		CUHK01	22.9	44.6	54.9	65.9	
	文献[12]	PRID2011	70.9	78.7	82.7	87.3	
		iLIDS	42.00	52.67	60.03	66.67	
非对称距离度量	文献[13]	VIPeR	43.29	72.66	83.51	92.18	
		PRID450S	57.60	82.67	89.24	93.20	
		CUHK01	47.80	74.16	83.44	89.92	
	文献[14]	VIPeR	30.9	51.7	61.6	72.3	
		CUHK01	57.3	80.0	86.3	91.8	
		CUHK03	31.9	59.4	70.1	80.0	
	文献[15]	VIPeR	38.1	56.3	63.1	70.6	
		CUHK01	56.6	78.9	86.2	92.3	
		iLIDS	19.7	38.6	48.9	62.4	
	超图相似性度量	文献[16]	VIPeR	34.18	66.60	79.75	90.19
			CUHK01	35.01	58.25	69.28	80.62
		文献[17]	VIPeR	45.35	71.49	83.99	92.53
CUHK01			64.45	83.53	91.11	95.26	
GRID			23.68	43.92	52.56	61.76	
集合相似性度量	文献[18]	iLIDS	65.90	87.30	—	—	
		Caviar-4REID	32.60	65.40	—	—	
	文献[20]	PRID2011	76.0	94.0	98.0	99.0	
		iLIDS	57.3	79.3	87.3	93.3	

表2 经典度量学习算法的性能比较分析

经典度量学习	算法/文献	数据集	Rank-1	Rank-5	Rank-10	Rank-20
改进目标函数	文献[29]	VIPeR	36.6	67.5	80.1	90.2
		iLIDS	43.5	63.9	75.2	86.8
	文献[30]	VIPeR	29.35	50.66	61.93	74.94
		CUHK01	33.46	50.88	60.97	70.97
	文献[31]	VIPeR	51.46	79.56	89.08	95.85
		CUHK01	74.22	90.51	94.42	96.91
		CUHK03	73.21	94.48	97.93	—
	文献[32]	CUHK03	58.72	89.07	95.28	—
	文献[34]	VIPeR	52.18	80.54	88.92	95.60
		GRID	24.32	46.24	57.12	68.08
	文献[35]	VIPeR	47.66	77.65	87.18	94.78
		Market1501	57.69	77.20	82.87	—
CUHK01		69.42	88.79	93.97	97.10	
多度量融合	文献[37]	VIPeR	36.97	69.87	80.31	90.44
		CUHK01	31.19	57.93	70.66	81.39
	文献[39]	VIPeR	40.7	72.37	83.95	92.08
		iLIDS	38.3	66.5	79.0	88.3
		CUHK01	36.10	62.68	72.61	81.90

深度度量学习可归纳为3种思路: 1) 目标函数改进; 2) 多任务联合学习; 3) 样本集群复合关系损失构建. 深度度量学习通过复杂的网络架构和最优化损失在行人重识别的特征提取和度量中展现出巨大优势, 已成为当前应对行人重识别中挑战的主流方法. 但深度度量学习的有效性依赖于对训练数据集的高质量要求, 当训练集中蕴含复杂噪声、异常点入

侵、类别不均衡、小样本等问题时, 其有效性往往无法得到保证.

重排序是对行人重识别结果的二次修正, 通过互补信息融合、图模型联合优化、奖惩二次修正, 增强了有利于准确排序的因素, 弱化了可能的干扰项, 降低了重排序结果混乱的可能性. 表4的实验数据表明: 执行重排序处理后的Rank-1准确度, 相比于经典

表3 深度度量学习算法的性能比较分析

损失函数	算法/文献	数据集	Rank-1	Rank-5	Rank-10	Rank-20
Softmax 损失	文献[42]	Market-1501	80.31	91.27	94.09	96.02
		CUHK03	69.55	90.96	95.07	97.54
	文献[43]	VIPeR	51.90	76.60	85.40	93.40
		CUHK01	83.50	95.20	97.30	98.80
		CUHK03	88.60	98.20	99.20	99.70
Market1501	88.40	94.80	96.50	98.00		
对比损失	文献[45]	RRID2011	73.30	—	97.50	98.30
		CUHK01	71.90	91.80	95.80	97.20
		2DPeS	58.30	74.00	—	88.50
	文献[46]	GRID	21.20	—	54.24	65.84
		VIPeR	44.87	—	86.01	93.70
三元组损失	文献[49]	Market1501	84.26	93.59	95.99	—
		DUKE	74.50	87.66	90.98	—
	文献[50]	VIPeR	47.3	76.6	88.1	—
		CUHK03	81.9	96.7	98.7	—
		CUHK01	70.2	90.2	95.5	—
联合损失	文献[54]	CUHK01	77.89	93.22	96.61	98.68
		CUHK03	63.58	89.17	93.75	98.25
		PRID2011	72.54	94.61	100.00	100.00
	文献[55]	iLIDS	59.7	81.8	90.9	96.9
		PRID2011	26.0	—	49.0	58.0
CUHK03	84.7	97.6	98.9	99.6		
集群损失	文献[57]	CUHK01	79.3	94.0	97.2	—
		CUHK03	90.2	98.8	—	—

表4 重排序算法的性能比较分析

重排序分类	算法/文献	数据集	Rank-1	Rank-5	Rank-10	Rank-20
聚合重排序	文献[59]	VIPeR	40.51	69.15	81.04	91.17
		CUHK01	57.02	80.43	87.90	93.40
		CUHK03	55.89	86.26	93.74	98.00
	文献[60]	VIPeR	35.8	69.9	80.4	89.6
		CUHK01	52.0	71.8	79.9	85.9
		iLIDS	22.0	43.3	52.0	73.3
	文献[61]	VIPeR	44.02	—	85.40	92.83
		CUHK01	65.03	—	91.26	95.33
	文献[63]	VIPeR	67.21	87.78	93.39	97.82
		CUHK01	66.91	86.95	92.12	95.7
图模型重排序	文献[64]	VIPeR	52.59	82.50	91.14	96.84
	文献[65]	VIPeR	45.19	73.58	85.35	93.99
CUHK01		68.64	88.00	92.74	95.80	
奖惩重排序	文献[69]	VIPeR	52.85	81.96	90.51	95.73
		CUHK01	57.28	81.07	88.44	93.46

度量学习,具有一定提升,但幅度较小;对比 Rank-20 准确度,相比经典度量学习,重排序后的提升较为显著. 这表明,重排序对初始度量结果的优化和修正是有有效的.

## 6 总结与展望

近年来,基于度量学习的行人重识别理论取得了卓越进展,但仍面临众多挑战: 1) 不同度量学习方法适用于不同的重识别任务或场景,难以找到一种普遍

适用的度量或度量学习方法; 2) 当前已有度量学习理论在实际视频监控的行人重识别中未得到成熟应用; 3) 开放环境下的行人重识别已成为基于度量学习行人重识别的新挑战.

未来的工作中,除做好普适性度量和度量学习方法的持续研究,为克服开放环境下行人重识别面临的困难,并促进技术实用化进程,应当从以下几个方面对度量学习理论开展深入探索和研究:

1) 小样本度量学习. 开放环境下, 目标行人处于非配合状态, 捕获高质量可用行人样本十分困难. 在规模较小的样本数据下, 许多深度度量学习方法无法充分训练, 导致所得距离度量矩阵泛化能力弱、鲁棒性差. 近年来, 研究者已经关注到小样本行人重识别难题, 但更多的研究是从数据增强和迁移学习角度提出解决方案, 直接针对小样本行人数据的度量或度量学习方法研究较少. 因此, 未来研究中, 除更好地研究小样本数据增强方法, 还应当从度量学习的角度开展多样化研究.

2) 跨图像域度量学习. 当前针对单一情况下的跨域行人度量学习已有较多研究, 但开放式视频监控下的行人重识别通常是多种跨域图像识别问题的综合, 因此, 如何融合多种跨域情况, 定义适应性和鲁棒性更强的综合度量或度量学习方法具有重要的理论意义和实用价值.

3) 半监督和无监督度量学习. 当前众多行人重识别方法, 包括度量学习方法都是有监督的, 而监督信息的数据标注过程成本代价较高. 因此, 半监督和无监督度量学习更适合现实视频监控下的行人重识别, 但已有无监督和半监督度量学习在性能上远不及监督度量学习. 因此, 设计可靠、高效的无监督和半监督度量学习算法, 提升监督信息缺失情况下的度量学习性能, 对行人重识别实现更广泛应用具有重要的推动作用.

4) 新距离度量定义和重排序技术. 除针对度量学习算法的改进, 借鉴已有距离度量概念, 定义新的距离度量方式, 对改善行人重识别性能具有本质性的提升作用. 另外, 利用优化算法对初始度量结果进行更深层次的综合判断, 对提升行人重识别决策准确度至关重要. 未来研究中, 融合度量学习理论与优化算法的重排序策略应得到更多关注.

#### 参考文献(References)

- [1] Porikli F. Inter-camera color calibration by correlation model function[C]. Proceedings of the 2003 International Conference on Image Processing. Barcelona: IEEE, 2003: II-133.
- [2] Gheissari N, Sebastian T B, Hartley R. Person reidentification using spatiotemporal appearance[C]. 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2006: 1528-1535.
- [3] 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.
- [4] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [5] 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.)
- [6] 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.)
- [7] 邹逸群, 肖志红, 唐夏菲, 等. Anchor-free的尺度自适应行人检测算法[J]. 控制与决策, 2021, 36(2): 295-302.  
(Zou Y Q, Xiao Z H, Tang X F, et al. Control and Decision, Anchor-free Scale adaptive Pedestrian Detection Algorithm[J]. Control and Decision, 2021, 36(2): 295-302.)
- [8] 彭梦, 蔡自兴, 陈白帆. 一种融合多级稀疏表达和度量学习的目标跟踪方法[J]. 控制与决策, 2015, 30(10): 1791-1796.  
(Peng M, Cai Z X, Chen B F. A target tracking method combining multi-level sparse representation and metric learning[J]. Control and Decision, 2015, 30(10): 1791-1796.)
- [9] De Maesschalck R, Jouan-Rimbaud D, Massart D L. The mahalanobis distance[J]. Chemometrics and Intelligent Laboratory Systems, 2000, 50(1): 1-18.
- [10] 齐美彬, 王运侠, 檀胜顺, 等. 正则化独立测度矩阵的行人再识别[J]. 模式识别与人工智能, 2016, 29(6): 511-518.  
(Qi M B, Wang Y X, Tan S S, et al. Person re-identification based on regularization of independent measure matrix[J]. Pattern Recognition and Artificial Intelligence, 2016, 29(6): 511-518.)
- [11] Tao D P, Jin L W, Wang Y F, 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.
- [12] Zhou J, Su B, Wu Y. Easy identification from better constraints: Multi-shot person re-identification from reference constraints[C]. 2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 5373-5381.
- [13] 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.
- [14] Yu H X, Wu A, Zheng W S. Cross-view asymmetric metric learning for unsupervised person re-identification[C]. 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 994-1002.
- [15] Feng Y C, Yuan Y, Lu X Q. Person reidentification via unsupervised cross-view metric learning[J]. IEEE Transactions on Cybernetics, 2019, DOI: 10.1109/TCYB.2019.2909480.
- [16] An L, Chen X J, Yang S F. Person re-identification via hypergraph-based matching[J]. Neurocomputing, 2016, 182: 247-254.

- [17] Zhao X B, Wang N, Zhang Y B, et al. Beyond pairwise matching: Person reidentification via high-order relevance learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(8): 3701-3714.
- [18] Li W, Wu Y, Mukunoki M, et al. Locality based discriminative measure for multiple-shot human re-identification[J]. *Neurocomputing*, 2015, 167: 280-289.
- [19] Tan F G, Liu W M, Huang L, et al. Person re-identification across multiple non-overlapping cameras by grouping similarity comparison model[J]. *Chinese Journal of Electronics*, 2017, 26(5): 905-911.
- [20] Cho Y J, Yoon K J. Pamm: Pose-aware multi-shot matching for improving person re-identification[J]. *IEEE Transactions on Image Processing*, 2018, 27(8): 3739-3752.
- [21] Wang Z, Hu R, Chen C, et al. Person reidentification via discrepancy matrix and matrix metric[J]. *IEEE Transactions on Cybernetics*, 2017, 48(10): 3006-3020.
- [22] Chen Y, Xu X Y. Matrix metric learning for person re-identification based on bidirectional reference set[J]. *Journal of Electronics & Information Technology*, 2020, 42(2): 394-402.
- [23] Weinberger K Q, Saul L K. Distance metric learning for large margin nearest neighbor classification[J]. *Journal of Machine Learning Research*, 2009, 10: 207-244.
- [24] Koestinger M, Hirzer M, Wohlhart P, et al. Large scale metric learning from equivalence constraints[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition. Rhode Island: IEEE, 2012: 2288-2295.
- [25] Zheng W S, Gong S, Xiang T. Reidentification by relative distance comparison[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 35(3): 653-668.
- [26] Pedagadi S, Orwell J, Velastin S, et al. Local fisher discriminant analysis for pedestrian re-identification[C]. 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland: IEEE, 2013: 3318-3325.
- [27] 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: IEEE, 2015: 2197-2206.
- [28] Liao S C, Li S Z. Efficient PSD constrained asymmetric metric learning for person re-identification[C]. *Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015: 3685-3693.
- [29] Zhou Q, Zheng S B, Yang H, et al. Joint instance and feature importance re-weighting for person reidentification[C]. 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Shanghai: IEEE, 2016: 1546-1550.
- [30] Tan S, Zheng F, Liu L, et al. Dense invariant feature-based support vector ranking for cross-camera person reidentification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, 28(2): 356-363.
- [31] Wang J, Wang Z, Liang C, et al. Equidistance constrained metric learning for person re-identification[J]. *Pattern Recognition*, 2018, 74: 38-51.
- [32] Zhou Z H, Liu K Y, Huang J C, et al. Improved metric learning algorithm for person re-identification based on equidistance[J]. *Journal of Electronics & Information Technology*, 2019, 41(2): 477-483.
- [33] Ding Z Y, Wang H Y, Chen F H, et al. Person re-identification based on distance centralization and projection vectors learning[J]. *Journal of Computer Research and Development*, 2017, 54(8): 1785-1794.
- [34] Dong H S, Gong S R, Liu C P, et al. Large margin relative distance learning for person re-identification[J]. *IET Computer Vision*, 2017, 11(6): 455-462.
- [35] He B T, Yu S H. Ring-push metric learning for person reidentification[J]. *Journal of Electronic Imaging*, 2017, 26(3): 033005.
- [36] Li W, Zhao R, Wang X G. Human reidentification with transferred metric learning[C]. *Computer Vision-ACCV 2012*. Berlin: Springer Heidelberg, 2013: 31-44.
- [37] Syed M A, Jiao J B. Multi-kernel metric learning for person re-identification[C]. *Proceedings 2016 IEEE International Conference on Image Processing*. Orlando: IEEE, 2016: 784-788.
- [38] Barman A, Shah S K. Distance aggregation based score fusion for improving person re-identification[C]. 2017 IEEE International Symposium on Technologies for Homeland Security. Waltham: IEEE, 2017: 1-8.
- [39] 齐美彬, 檀胜顺, 王运侠, 等. 基于多特征子空间与核学习的行人再识别[J]. *自动化学报*, 2016, 42(2): 299-308.  
(Qi M B, Tan S S, Wang Y X, et al. Multi-feature subspace and kernel learning for person re-identification[J]. *Acta Automatica Sinica*, 2016, 42(2): 299-308.)
- [40] Bridle J S. Alpha-nets: A recurrent 'neural' network architecture with a hidden Markov model interpretation[J]. *Speech Communication*, 1990, 9(1): 83-92.
- [41] Zhu F Q, Kong X W, Wu Q, et al. A loss combination based deep model for person re-identification[J]. *Multimedia Tools and Applications*, 2018, 77(3): 3049-3069.
- [42] Borgia A, Hua Y, Kodirov E, et al. Cross-view discriminative feature learning for person re-identification[J]. *IEEE Transactions on Image Processing*, 2018, 27(11): 5338-5349.
- [43] Feng Z X, Lai J, Xie X. Learning view-specific deep networks for person re-identification[J]. *IEEE Transactions on Image Processing*, 2018, 27(7): 3472-3483.
- [44] Hadsell R, Chopra S, LeCun Y. Dimensionality reduction by learning an invariant mapping[C]. *Proceedings of 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. New York: IEEE, 2006: 1735-1742.

- [45] Wang J Y, Zhou S P, Wang J J, et al. Deep ranking model by large adaptive margin learning for person re-identification[J]. *Pattern Recognition*, 2018, 74: 241-252.
- [46] Zhu J Q, Zeng H Q, Liao S C, et al. Deep hybrid similarity learning for person re-identification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, 28(11): 3183-3193.
- [47] Sarfraz M S, Schumann A, Eberle A, et al. A pose-sensitive embedding for person re-identification with expanded cross neighborhood re-ranking[C]. *Proceedings of 2018 IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 420-429.
- [48] Schroff F, Kalenichenko D, Philbin J. Facenet: A unified embedding for face recognition and clustering[C]. *2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015: 815-823.
- [49] Yang X, Zhou P C, Wang M. Person reidentification via structural deep metric learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(10): 2987-2998.
- [50] He Z P, Zhang Z D, Jung C. Deep feature embedding learning for person re-identification using lifted structured loss[C]. *2018 IEEE International Conference on Acoustics, Speech and Signal Processing*. Seoul: IEEE, 2018: 1957-1961.
- [51] Chen W, Chen X, Zhang J, et al. Beyond triplet loss: A deep quadruplet network for person re-identification[C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 1320-1329.
- [52] McLaughlin N, del Rincon J M, Miller P C. Person reidentification using deep convnets with multitask learning[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2016, 27(3): 525-539.
- [53] Ling H F, Wang Z Y, Li P, et al. Improving person re-identification by multi-task learning[J]. *Neurocomputing*, 2019, 347: 109-118.
- [54] Li W, Zhu X T, Gong S G. Person re-identification by deep joint learning of multi-loss classification[C]. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*. Melbourne: IJCAI, 2017: 2194-2200.
- [55] Zhou S, Wang J, Shi R, et al. Large margin learning in set-to-set similarity comparison for person reidentification[J]. *IEEE Transactions on Multimedia*, 2017, 20(3): 593-604.
- [56] Cheng D, Gong Y H, Shi W W, et al. Person re-identification by the asymmetric triplet and identification loss function[J]. *Multimedia Tools and Applications*, 2018, 77(3): 3533-3550.
- [57] Li K, Ding Z, Li K, et al. Support neighbor loss for person re-identification[C]. *Proceedings of the 26th ACM International Conference on Multimedia*. New York: ACM, 2018: 1492-1500.
- [58] Yuan C H, Guo J J, Feng P, et al. Learning deep embedding with mini-cluster loss for person re-identification[J]. *Multimedia Tools and Applications*, 2019, 78(15): 21145-21166.
- [59] Wang J, Wang Z, Gao C X, et al. Deeplist: Learning deep features with adaptive listwise constraint for person reidentification[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2016, 27(3): 513-524.
- [60] Zhang Z, Huang M Y. Discriminative structural metric learning for person reidentification in visual Internet of things[J]. *IEEE Internet of Things Journal*, 2018, 5(5): 3361-3368.
- [61] Zhang Z M, Saligrama V. Prism: Person reidentification via structured matching[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2017, 27(3): 499-512.
- [62] Chen D D, Xu D, Li H S, et al. Group consistent similarity learning via deep CRF for person re-identification[C]. *2018 IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018: 8649-8658.
- [63] Jacques J C S J, Baró X, Escalera S. Exploiting feature representations through similarity learning, post-ranking and ranking aggregation for person re-identification[J]. *Image and Vision Computing*, 2018, 79: 76-85.
- [64] Xie Y, Levine M D, Yu H M. Person re-identification by graph-based metric fusion[J]. *Electronics Letters*, 2016, 52(17): 1447-1449.
- [65] Barman A, Shah S K. Shape: A novel graph theoretic algorithm for making consensus-based decisions in person re-identification systems[C]. *2017 IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 1124-1133.
- [66] Leng Q M, Hu R M, Liang C, et al. Person re-identification with content and context re-ranking[J]. *Multimedia Tools and Applications*, 2015, 74(17): 6989-7014.
- [67] Zhong Z, Zheng L, Cao D L, et al. Re-ranking person re-identification with  $k$ -reciprocal encoding[C]. *2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 1318-1327.
- [68] Ye M, Liang C, Yu Y, et al. Person reidentification via ranking aggregation of similarity pulling and dissimilarity pushing[J]. *IEEE Transactions on Multimedia*, 2016, 18(12): 2553-2566.
- [69] Chen S Z, Guo C C, Lai J H. Deep ranking for person re-identification via joint representation learning[J]. *IEEE Transactions on Image Processing*, 2016, 25(5): 2353-2367.

## 作者简介

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;

傅桂霞(1985—),女,讲师,博士,从事行人重识别、视觉跟踪技术等研究, E-mail: fgx45101@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;

彭祥(1992—),男,博士生,从事信息处理与融合技术的研究, E-mail: xiangpeng\_buaa@outlook.com;

刘征(1969—),男,教授,博士生导师,从事信息处理、数据融合、数字孪生技术等研究, E-mail: zheng.liu@ubc.ca.