

# 基于姿态引导特征增强的遮挡行人重识别

刘志刚<sup>1,2</sup>, 王 森<sup>1</sup>, 刘苗苗<sup>1</sup>

(1. 东北石油大学 计算机与信息技术学院, 黑龙江 大庆 163318;  
2. 黑龙江省石油大数据与智能分析重点实验室, 黑龙江 大庆 163318)

**摘要:**为解决遮挡行人重识别在特征提取过程中的特征丢失、特征匹配过程中的噪声干扰问题,提出了一种姿态引导的特征增强模型。首先,在关键点信息的辅助下,设计一种对称区域特征修复模块,将被遮挡区域丢失的局部特征替换为未遮挡区域的局部特征;其次,为挖掘局部特征的内在语义联系,设计一种相邻区域特征补偿模块,通过相邻区域特征修正局部特征表示;最后,通过引入广义均值池化对特征图的中心区域再次进行特征提取,提升行人特征向量的表达能力,以获得更加准确的全局特征。仿真实验表明,该模型在常见的全身数据集、半身数据集和遮挡数据集的 Rank-1 和 mAP 均优于绝大部分算法,其中在遮挡数据集 Occluded-Duke、Occluded-REID 上的 Rank-1 分别达到了 56.7% 和 72.4%。

**关键词:**行人重识别;遮挡;特征修复;特征补偿;广义均值池化

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2024)04-0089-06

doi:10.20165/j.cnki.ISSN1673-629X.2024.0014

## Occluded Person Re-identification Based on Pose-guided Feature Enhancement

LIU Zhi-gang<sup>1,2</sup>, WANG Miao<sup>1</sup>, LIU Miao-miao<sup>1</sup>

(1. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China;  
2. Heilongjiang Provincial Key Laboratory of Oil Big Data & Intelligent Analysis, Daqing 163318, China)

**Abstract:** To address the problems of feature loss during feature extraction and noise interference during feature matching in occluded person re-identification, a pose-guided feature enhancement model is proposed. Firstly, with the assistance of key point information, a symmetrical region feature repair module is proposed to replace the locally lost features in the occluded region with the features in the non-occluded region. Secondly, to explore the semantic relationship between local features, an adjacent region feature compensation module is proposed to update the feature representation of each local feature by combining the features of adjacent regions. Finally, by leveraging the generalized mean pooling to extract features from the central region of the feature map, the expression ability of person feature vectors is improved to obtain more accurate global features. Simulation experiments show that the proposed model outperforms most algorithms in common holistic datasets, partial datasets, and occluded datasets in terms of Rank-1 and mAP, achieving 56.7% and 72.4% Rank-1 on Occluded-Duke and Occluded-REID datasets, respectively.

**Key words:** person re-identification; occlusion; feature repair; feature compensation; generalized mean pooling

## 0 引言

行人重识别(Person Re-identification, Re-Id)是指在多个非重叠摄像头拍摄的场景下,通过对行人特征提取和行人特征匹配完成对目标行人在监控视频或图像序列中的检索任务。实际监控场景中,行人全身或某些部分可能被一些障碍物遮挡,导致模型在特征提取过程中面临行人特征丢失、噪声干扰的问题,因此

引起国内外研究的关注<sup>[1]</sup>。传统方法<sup>[2-4]</sup>通过手动裁剪目标图像并利用可见部分作为新的目标图像,但识别性能较低,目前业界主要研究方法为深度学习<sup>[5]</sup>。Wang 等人<sup>[6]</sup>利用关键点信息学习可见局部特征的高阶关系和拓扑信息,以便更好地与图库图像匹配。Lin 等人<sup>[7]</sup>使用人体解析模型生成的解析掩码作为自注意力机制中的查询,对关联区域进行图像匹配,以缓解

收稿日期:2023-06-25

修回日期:2023-10-26

基金项目:国家自然科学基金(42002138);黑龙江省自然科学基金(LH2020F003, LH2021F004);黑龙江省高等教育教学改革项目(SJGY20210109)

作者简介:刘志刚(1979-),男,博士,副教授,CCF高级会员(57560S),研究方向为机器学习、计算机视觉;通信作者:王 森(1999-),女,硕士研究生,研究方向为机器学习、计算机视觉;刘苗苗(1980-),女,博士,教授,研究方向为机器学习与知识图谱。

遮挡带来的噪声信息。Jia 等人<sup>[8]</sup>提出 DRL-Net,即利用训练集中出现的障碍物合成更多样、更逼真的遮挡样本来指导对比度特征学习,以减轻遮挡噪声的干扰。Kim 等人<sup>[9]</sup>提出 OCNet,即由两个全连接共享层组成的关系自适应模块来捕获不同区域特征之间的关系,使用关系权重来细化区域特征,以抑制被遮挡或不重要的信息。这些研究成果均是通过抑制遮挡区域引入的噪声来解决,在一定程度上提高了遮挡 Re-Id 性能,但未从遮挡区域的特征补偿角度进行研究。因此,针对遮挡 Re-Id 中被遮挡区域特征缺失的问题,该文提出一种姿态引导的特征增强模型 (Pose-Guided Feature Enhancement model, PGFE)。包括:(1)特征修

复模块 (Feature Repair Module, FRM):利用人体对称区域特征相似的特点,通过将遮挡区域的特征替换为其对称区域的特征的方式,修复行人被遮挡区域丢失的局部特征;(2)特征补偿模块 (Feature Compensation Module, FCM):通过聚合相邻区域的特征,挖掘局部特征间的相互联系,进一步对严重被遮挡区域进行特征修复;(3)突出前景的全局特征提取模块 (Global Feature Extraction Module, GFEM):通过在全局特征提取的过程中通过引入广义均值池化 (Generalized-Mean pooling, GeM)<sup>[10]</sup>,使网络更加关注具有判别力的特征,从而有效提高模型的识别性能。

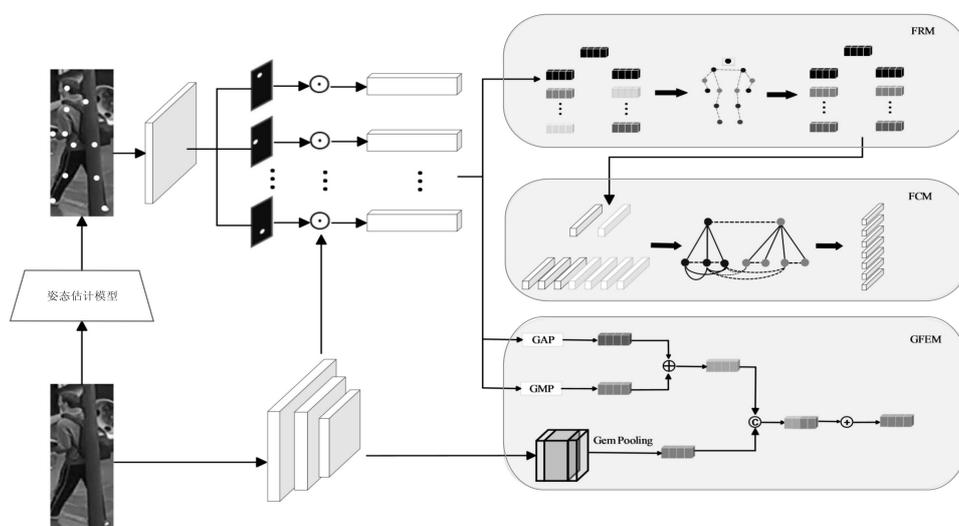


图1 姿态引导特征增强模型 PGFE 结构

## 1 姿态引导的特征增强模型 PGFE

PGFE 采用 ResNet50 作为特征提取主干网络,从上至下依次为局部特征提取分支和全局特征提取分支,其中局部特征提取分支包括特征修复模块 (FRM)、特征补偿模块 (FCM);全局特征提取分支即突出前景的全局特征提取模块 (GFEM)。该模型通过将局部与全局特征融合的方式增强鲁棒性。具体结构如图1所示。

### 1.1 特征修复模块 (FRM)

基于局部特征的方式可有效处理遮挡 Re-Id 问题,基本思想是将行人分成若干局部区域,并对每个局部区域提取出相应特征,最终将这些局部特征组合以获得行人特征表示<sup>[11]</sup>。局部特征提取的过程中,姿态估计模型可以更准确地划分出局部区域,并对其进行特征提取和组合,从而提高 Re-Id 模型的准确性<sup>[12]</sup>。鉴于此,在该模块中首先利用姿态估计模型提取人体关键点特征,然后将遮挡区域的关键点特征替换为其对称区域的关键点特征来达到对遮挡区域进行特征修复的目的。具体如下:对于给定的一张输入图像,

首先利用 HR-Net<sup>[13]</sup>在 COCO 数据集<sup>[14]</sup>上预训练以获取图像中行人的关键点向量,该文假设图像中的关键点由6对左右对称的关键点和头部关键点组成,然后通过得到的关键点热图获得如下局部特征:

$$f_l^i = G(m_l^i \odot F_x) \quad (1)$$

$$f_r^i = G(m_r^i \odot F_x) \quad (2)$$

$$f_h = G(m_h \odot F_x) \quad (3)$$

其中,  $i \in [1, 2, \dots, 6]$ ,  $F_x$  为主干网络提取的特征,  $f_l^i$ ,  $f_r^i$  和  $f_h$  分别表示人体左、右第  $i$  个关键点和头部关键点对应的局部特征,  $m_l^i$  和  $m_r^i$  分别表示由姿态估计模型得到的除头部外的左、右第  $i$  个关键点特征向量,  $m_h$  表示头部对应的关键点特征向量,  $\odot$  为按元素相乘,  $G$  为全局平均池化 (GAP) 操作。

对于每一个关键点,姿态估计模型给出其相应的置信度,如果某个关键点被遮挡,那么其置信度很小,因此,该文通过设置阈值确定是否存在遮挡的关键点。此外,由于行人身体呈现左右对称,除头部关键点外,其余关键点(由左右关键点组成)成对出现,如果局部区域被遮挡,根据行人关键点的左右对称特征相似的特点,通过将遮挡区域的特征替换为其对称且未遮挡

区域特征的方式,实现对称关键点特征的修复。最后,在该模块的关键点特征计算如下:

$$\mathbf{f}_l^i \begin{cases} \mathbf{f}_l^i & s_l^i > \lambda \\ \mathbf{f}_r^i & s_l^i < \lambda \quad s_r^i > \lambda \\ 0 & s_l^i < \lambda \quad s_r^i < \lambda \end{cases} \quad (4)$$

$$\mathbf{f}_r^i \begin{cases} \mathbf{f}_r^i & s_r^i > \lambda \\ \mathbf{f}_l^i & s_r^i < \lambda \quad s_l^i > \lambda \\ 0 & s_r^i < \lambda \quad s_l^i < \lambda \end{cases} \quad (5)$$

其中,  $s_l^i$ ,  $s_r^i$  分别表示左右第  $i$  个关键点对应的置信度,  $\lambda$  表示阈值,在该模块中设置为 0.2。

### 1.2 特征补偿模块 (FCM)

图卷积网络<sup>[15]</sup>通过将图数据中每个节点的特征向量与其邻居节点的特征向量进行加权求和,并结合自身特征向量得到一个新的特征向量表示,实现节点间信息的传递。受图卷积更新节点特征的启发,在该模块中设计了一种特征聚合方法,通过聚合相邻区域

的特征,增强局部特征之间的语义联系,使得当相互对称的区域均被遮挡时 FRM 不能很好处理的情况下,可以利用相邻区域的特征进行补偿。具体为:将姿态估计模型提取的关键点局部特征分为七个区域,因为上半身特征相对稳定,对称划分为两块,遮挡经常发生在下半身,因此根据关键点信息将下半身划分四块。每个区域的特征表示如下:

$$\mathbf{f}_p = G(\sum \mathbf{f}_k) \quad (6)$$

其中,头部特征  $\mathbf{f}_1$  为  $\mathbf{f}_h$ ,  $\mathbf{f}_k$  表示姿态估计模型提取的局部特征,即  $\mathbf{f}_k \in [\mathbf{f}_l^i, \mathbf{f}_r^i]$ ,  $\mathbf{f}_p$  表示所划分的七个区域特征,其中  $p \in [2, 3, \dots, 7]$ ,  $\mathbf{f}_p$  与  $\mathbf{f}_k$  根据人体结构特点建立映射关系。由于人体各部位之间存在着一种固定而稳定的联系,例如,头和肩膀有直接的联系,但头和腿没有,因此利用图卷积网络中更新每个节点的思想设计如下特征聚合的方式,图 2(a) 是根据关键点划分的区域得到的特征拓扑图。

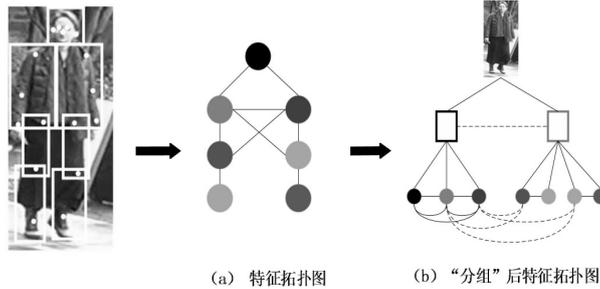


图 2 特征补偿机制示意图

为了在保证模型性能的情况下提高模型的效率,该文根据人体的结构特点对这个拓扑图的特征进行了“分组”表示。先将特征粗略分为上、下半身特征  $\mathbf{f}_{up}$  和  $\mathbf{f}_{down}$ ,然后在半身特征的基础上精确划分每个区域的特征,并分别计算每个区域的特征。如图 2(b),其中,实线代表“同组”特征,虚线代表“不同组”特征。因为“同组”特征语义联系略强,因此按一定权重聚合“同组”特征和“不同组”特征,最后特征中既包含了自身特征,又融合相邻区域特征。

$$\mathbf{f}_{agg} = \omega(\sum \mathbf{f}_p) + \mathbf{f}_{agg} \quad (7)$$

$$\mathbf{f}_{agg} = \omega(\sum \mathbf{f}_p) + (1 - \omega)\mathbf{f}_g + \mathbf{f}_{agg} \quad (8)$$

其中,  $\omega$  表示可学习的权重。式 7 中  $\mathbf{f}_{agg}$  分别表示  $\mathbf{f}_1(p=2, 3)$ ,  $\mathbf{f}_6(p=4)$ ,  $\mathbf{f}_7(p=5)$ 。式 8 中  $\mathbf{f}_{agg}$  分别表示  $\mathbf{f}_2(p=1, 3; g=down)$ ,  $\mathbf{f}_3(p=1, 2; g=down)$ ,  $\mathbf{f}_4(p=6; g=up)$ ,  $\mathbf{f}_5(p=7; g=up)$ 。

### 1.3 突出前景的全局特征提取模块 (GFEM)

当对行人进行特征提取时,全局特征能够对不同行人之间的共性进行捕捉,局部特征则更加关注行人的细节信息来发现不同行人之间的差异性。因此采用

全局特征与局部特征相结合的方式可以提高 Re-Id 的准确率。但 FRM 和 FCM 均通过对局部特征进行处理来解决 Re-Id 的遮挡问题。为了提取更加鲁棒的全局特征,该文基于前景一般在图像的中心,而背景大多在边缘的先验知识<sup>[9]</sup>,设计一种突出前景特征的 GFEM,通过额外对图像的中心区域进行特征提取来消除背景杂波的干扰,同时又可以抑制遮挡引起的噪声影响,使最终行人全局特征更具有判别性。具体为:首先将骨干网络得到的特征图与姿态估计模型得到的特征图相结合,然后将结合后的特征分别进行 GAP 和全局最大池化 (GMP),最后将特征相加得到特征  $\mathbf{f}_p$ 。为提取更加准确的全局特征,同时又不完全依赖姿态估计模型,通过提取骨干网络所得特征图的中心区域来过滤背景干扰,即在不改变特征图的长度和通道数的情况下提取宽度为原来二分之一的中心区域特征。

为弥补 GAP 容易引入背景噪声、GMP 容易丢失信息的不足,对中心区域特征进行 GeM 池化操作。因为 GeM 池化是介于 GMP 和 GAP 之间的一种池化操作,它通过引入一个可调参数,可以让网络关注更多的人体区域,帮助模型学习到更加抽象和稳定的特征。

因此,经过 GeM 池化后得到中心特征  $F_i$ ,之后将特征  $F_p$  与特征  $F_i$  相连接并与特征  $F_p$  相加得到最后的特征  $F_G$ ,如下:

$$F_G = T(F_p, F_i) \quad (9)$$

其中,  $T$  表示特征相连接。

#### 1.4 损失函数

为提高模型的准确性和泛化能力,该文选择 softmax 和 TriHard 对模型进行训练。在该模型中,对于特征  $f_i$ , softmax 损失的表达式如下:

$$L_{\text{softmax}} = -\frac{1}{n} \sum_{i=1}^N \log \frac{\exp(\mathbf{w}_y^T \mathbf{f}_i)}{\sum_{k=1}^C \exp(\mathbf{w}_k^T \mathbf{f}_i)} \quad (10)$$

其中,  $\mathbf{w}_k^T$  为第  $k$  类的权重向量,  $N$  为批次大小,  $C$  为类别数,  $\mathbf{w}_y^T$  为正确类别  $y_i$  的权重向量。改进后的 TriHard 损失能自主地选择每个训练批次中最困难的正样本对以及负样本对来构成三元组,使同类样本更加接近,而不同类样本之间的距离更大,从而提高特征表示区分度。因此,可以较好地解决相同行人间差距较大而不同行人间更加相似的问题。该模型 TriHard 损失的表达式如下:

$$L_{\text{TriHard}} = \frac{1}{P \times K} \sum_{a \in \text{batch}} (\max d_{a,p} - \min d_{a,n} + \alpha)_+ \quad (11)$$

其中,超参数  $\alpha$  控制距离的差异;  $d_{a,p}$  和  $d_{a,n}$  表示锚点图像与正样本、负样本之间的欧氏距离;  $[Z]_+$  表示  $\max(z, 0)$ ;  $P$  和  $K$  分别表示单个批次包含的行人数和每个行人相应的图像数。

全局特征  $F_G$  同时使用 softmax 损失和 TriHard 损失进行约束,分别表示为  $L_{\text{softmax}}^G$  和  $L_{\text{TriHard}}^G$ 。对于局部特征

$f_i (i = 1, 2, \dots, 7)$  使用 softmax 进行约束,分别表示为  $L_{\text{softmax}}^i$ ,最后整合的损失函数如下:

$$L = \sum_{i=1}^7 L_{\text{softmax}}^i + L_{\text{softmax}}^G + L_{\text{TriHard}}^G \quad (12)$$

## 2 实验结果与分析

### 2.1 实验数据集

该模型主要解决遮挡 Re-Id 问题,选择遮挡数据集 Occluded-Duke<sup>[16]</sup>、Occluded-Re-ID<sup>[17]</sup> 对模型性能进行评估。同时,为了验证模型对于传统 Re-Id 的鲁棒性,选用全身数据集 Market-1501<sup>[18]</sup>、DukeMTMC-reID<sup>[19]</sup> 和半身数据集 Partial-REID<sup>[20]</sup>、Partial-iLIDS<sup>[3]</sup>。

### 2.2 实验结果与分析

#### 2.2.1 文中方法与其它主流方法的比较

表 1 给出了 PGFE 与当前主流方法在半身数据集和遮挡数据集的实验结果。由表 1 可知,文中方法在遮挡数据集上的性能优于绝大部分主流方法,略逊于 HOREID。原因分析:(1) PGFE 从遮挡区域的特征补偿角度进行研究,充分利用可见区域特征,对比其他仅抑制噪声的方法整体上较优;(2) PGFE 结合人体结构特点,充分挖掘相邻局部特征之间的语义相关性,对比其他单独处理局部特征的方法获得了更鲁棒的行人特征信息;(3) PGFE 直接利用姿态估计模型输出的关键点置信度,在严重遮挡情况下性能略低于 HOREID。然而, HOREID 参数量很大,在训练过程中消耗大量资源,而 PGFE 采用参数共享的策略,在保证模型性能的同时节约资源。

表 1 半身与遮挡数据集准确率对比结果 %

| 方法                           | Partial-REID |             | Partial-iLIDS |             | Occluded-Duke |             | Occluded-REID |             |
|------------------------------|--------------|-------------|---------------|-------------|---------------|-------------|---------------|-------------|
|                              | Rank-1       | mAP         | Rank-1        | mAP         | Rank-1        | mAP         | Rank-1        | mAP         |
| SpindleNet <sup>[21]</sup>   | 67.0         | -           | 66.3          | -           | -             | -           | -             | -           |
| Part-Aligned <sup>[22]</sup> | 55.9         | 24.6        | 55.2          | 63.7        | 36.3          | 20.0        | 25.1          | 18.6        |
| PCB <sup>[11]</sup>          | 56.3         | 50.5        | 68.9          | 73.0        | 49.6          | 36.8        | 46.7          | 40.3        |
| VPM <sup>[23]</sup>          | 67.7         | -           | 65.5          | -           | -             | -           | -             | -           |
| STNReID <sup>[24]</sup>      | 66.7         | -           | 54.6          | -           | -             | -           | -             | -           |
| DSR <sup>[3]</sup>           | 43.0         | -           | 54.6          | -           | -             | 30.4        | 72.8          | 62.8        |
| PGFA <sup>[16]</sup>         | 69.0         | 61.5        | 69.1          | -           | 51.4          | 37.3        | -             | -           |
| PVPM <sup>[6]</sup>          | 75.3         | 71.4        | -             | -           | 47.0          | 37.7        | 70.4          | 61.4        |
| HOREID <sup>[25]</sup>       | <b>85.3</b>  | -           | 72.6          | -           | 55.1          | <b>43.8</b> | <b>80.3</b>   | <b>70.2</b> |
| PGFE                         | 78.2         | <b>72.8</b> | <b>73.6</b>   | <b>78.6</b> | <b>56.7</b>   | 43.5        | 72.4          | 64.6        |

表 2 是 PGFE 与当前主流方法在全身数据集上的比较结果。可以看出, PGFE 在全身数据集上,尤其是 Market1501 的性能比较突出,其 mAP 和 Rank-1 均领

先于其它方法,分别为 95.5% 和 86.3%。实验表明,通过额外提取特征图的中心区域特征可以很好地抑制背景干扰,使模型学习更具鲁棒的行人特征,从而提升

性能。

表2 全身数据集准确率对比结果 %

| 方法                           | DuckMTMC-ReID |             | Market1501  |             |
|------------------------------|---------------|-------------|-------------|-------------|
|                              | Rank-1        | mAP         | Rank-1      | mAP         |
| PGFA <sup>[16]</sup>         | 82.6          | 65.5        | 91.2        | 76.8        |
| PVPM <sup>[6]</sup>          | 84.9          | 71.8        | 93.1        | 82.3        |
| PFRFN <sup>[26]</sup>        | 90.0          | 77.1        | 95.4        | 86.0        |
| SVDNet <sup>[27]</sup>       | 76.7          | 56.8        | 82.3        | 62.1        |
| Part-Aligned <sup>[22]</sup> | 82.1          | 64.2        | 90.2        | 76.0        |
| PCB <sup>[11]</sup>          | 81.8          | 66.1        | 92.3        | 77.4        |
| PGFE                         | <b>89.8</b>   | <b>77.9</b> | <b>95.5</b> | <b>86.3</b> |

2.2.2 不同分支的消融实验

为验证 PGFE 模型中三个模块 (FRM、FCM、GFEM) 的有效性,在 Market1501、DukeMTMC-reID 上进行消融实验,结果如表3所示。实验分4个部分:分组 I 只采用 ResNet50 作为基线;分组 II 只添加了 FRM;分组 I II 添加了 FRM 和 FCM;分组 IV 在分组 I II 的基础上添加 GFEM,提取更具判别力全局特征。

表3 不同模块消融实验结果 %

| 实验<br>分组 | 方法            | Market1501  |             | DukeMTMC-reID |             |
|----------|---------------|-------------|-------------|---------------|-------------|
|          |               | Rank-1      | mAP         | Rank-1        | mAP         |
| I        | ResNet50      | 87.4        | 71.2        | 80.3          | 61.8        |
| II       | +FRM          | 92.6        | 78.1        | 86.5          | 72.3        |
| I II     | +FRM+FCM      | 94.0        | 85.6        | 88.5          | 77.1        |
| IV       | +FRM+FCM+GFEM | <b>95.5</b> | <b>86.3</b> | <b>89.8</b>   | <b>77.9</b> |

结果表明,以 Market1501 为例,在基线网络上添加 FRM 后,Rank-1 和 mAP 分别提高 5.2 个百分点和 6.9 百分点。由于 FRM 在抑制遮挡噪声的同时修复了遮挡区域的特征,从而提升了模型特征提取的能力。在分组 I II 引入 FCM 后,与分组 II 相比,Rank-1 和 mAP 分别提高 1.4 个百分点和 7.5 百分点。由于 FCM 不仅考虑局部特征之间的语义联系,还在一定程度上缓解关键点预测不准确的问题。在整个框架下 Rank-1 和 mAP 准确率相对于分组 I II 分别提高 1.5 个百分点和 0.7 百分点,表明突出前景的 GFEM 可很好消除背景干扰。

2.2.3 聚合系数影响分析

该文进一步讨论 FCM 中聚合系数  $\omega$  的不同取值的影响,不同的  $\omega$  值表示聚合策略的权重不同。以左侧小腿特征为例,当  $\omega = 1$  时,仅仅聚合了下半身特征  $f_{down}$ ;然而,当  $\omega \in (0, 1)$ , 这特征按一定的权重聚合上半身特征  $f_{up}$  和下半身特征  $f_{down}$ 。因此,所提网络可以使提取的语义部分特征更加具有鲁棒性。

由于 Occluded-REID 包含更多被遮挡的图像,因此,在该数据集上进行  $\omega$  参数取值分析实验。因为相

邻特征的语义联系会更强,特征经“分组”表示后,“同一组”特征具有较多聚合权重,“相邻组”特征具有较少聚合权重。如图3所示,mAP 和 Rank-1 随  $\omega$  变化明显。 $\omega = 0.8$  时,识别精度最好。

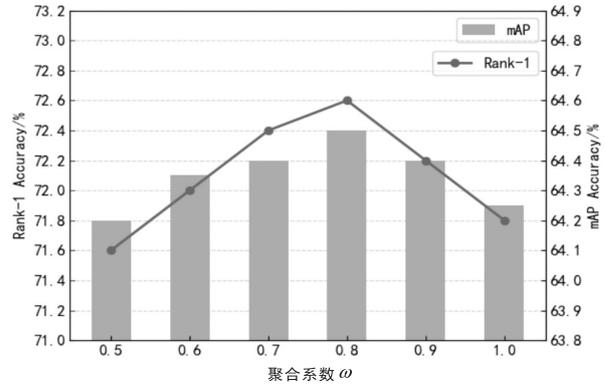


图3 不同情况聚合系数  $\omega$  对比结果

3 结束语

该文提出一种姿态引导的特征增强模型。首先,模型在关键点信息的辅助下通过 FRM 和 FCM 对遮挡区域丢失的特征进行修复。其次,在全局特征提取的过程中通过额外提取特征图中心区域的特征,使模型学习到更具有鲁棒性的全局特征。损失函数采用 softmax 和 TriHard 损失来联合约束,充分利用样本的信息。在公开数据集上对模型进行了验证,结果表明,与其它 Re-Id 模型相比,该模型展现出了良好性能,并在遮挡场景下具有较强竞争力。

参考文献:

- [1] 杨婉香,严 严,陈 思,等. 基于多尺度生成对抗网络的遮挡行人重识别方法[J]. 软件学报,2020,31(7):1943-1958.
- [2] LIAO S C, HU Y, ZHU X Y, 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: IEEE, 2015: 2197-2206.
- [3] HE L, LIANG J, LI H, et al. Deep spatial feature reconstruction for partial person re-identification: alignment-free approach[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City: IEEE, 2018:7073-7082.
- [4] HE L, SUN Z, ZHU Y, et al. Recognizing partial biometric patterns[J]. arXiv:1810.07399, 2018.
- [5] 朱松豪,赵云斌,焦 森,等. 融合空间相关性和局部特征转换器的遮挡行人重识别[J]. 南京邮电大学学报:自然科学版,2022,42(5):62-73.
- [6] GAO S, WANG J, LU H, et al. Pose-guided visible part matching for occluded person reid[C]//Proceedings of the

- IEEE/CVF conference on computer vision and pattern recognition. Seattle;IEEE,2020;11744–11752.
- [7] LIN C S, WANG Y C F. Self-supervised bodymap to appearance coattention for partial person re-identification [C]//2021 IEEE international conference on image processing (ICIP). Singapore;IEEE,2021;2299–2303.
- [8] JIA M, CHENG X, LU S, et al. Learning disentangled representation implicitly via transformer for occluded person re-identification [J]. IEEE Transactions on Multimedia, 2022, 25:1294–1305.
- [9] KIM M, CHO M A, LEE H, et al. Occluded person re-identification via relational adaptive feature correction learning [C]//ICASSP 2022–2022 IEEE international conference on acoustics, speech and signal processing (ICASSP). Singapore;IEEE,2022;2719–2723.
- [10] RADENOVIC F, TOLIAS G, CHUM O. Fine-tuning CNN image retrieval with no human annotation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 41 (7):1655–1668.
- [11] 杨永胜, 邓森磊, 李 磊, 等. 基于深度学习的行人重识别综述 [J]. 计算机工程与应用, 2022, 58(9):51–66.
- [12] 李 杲, 蒋 敏. 基于姿态估计与特征相似度的行人重识别算法 [J]. 激光与光电子学进展, 2023, 60(6):37–45.
- [13] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seoul;IEEE,2019;5693–5703.
- [14] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft coco: common objects in context [C]//Computer vision – ECCV 2014:13th European conference. Zurich;Springer,2014;740–755.
- [15] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [J]. arXiv:1609.02907, 2016.
- [16] MIAO J, WU Y, LIU P, et al. Pose-guided feature alignment for occluded person re-identification [C]//Proceedings of the IEEE/CVF international conference on computer vision. Seoul;IEEE,2019;542–551.
- [17] ZHUO J, CHEN Z, LAI J, et al. Occluded person re-identification [C]//2018 IEEE international conference on multimedia and expo (ICME). San Diego;IEEE,2018;1–6.
- [18] ZHENG L, SHEN L, TIAN L, et al. Scalable person re-identification: a benchmark [C]//Proceedings of the IEEE international conference on computer vision. Santiago;IEEE,2015;1116–1124.
- [19] ZHENG Z, ZHENG L, YANG Y. Unlabeled samples generated by gan improve the person re-identification baseline in vitro [C]//Proceedings of the IEEE international conference on computer vision. Venice;IEEE,2017;3754–3762.
- [20] ZHENG W S, LI X, XIANG T, et al. Partial person re-identification [C]//Proceedings of the IEEE international conference on computer vision. Santiago;IEEE,2015;4678–4686.
- [21] ZHAO H, TIAN M, SUN S, et al. Spindle net: person re-identification with human body region guided feature decomposition and fusion [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu;IEEE,2017;1077–1085.
- [22] ZHANG Z, YANG X, YU Z, et al. Joint discriminative and generative learning for person re-identification [C]//proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach;IEEE,2019;2138–2147.
- [23] SUN Y, XU Q, LI Y, et al. Perceive where to focus: Learning visibility-aware part-level features for partial person re-identification [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach;IEEE,2019;393–402.
- [24] LUO H, JIANG W, FAN X, et al. Stnreid: deep convolutional networks with pairwise spatial transformer networks for partial person re-identification [J]. IEEE Transactions on Multimedia, 2020, 22(11):2905–2913.
- [25] WANG G, YANG S, LIU H, et al. High-order information matters: learning relation and topology for occluded person re-identification [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Seattle;IEEE,2020;6449–6458.
- [26] XIE G, WEN X, YUAN L, et al. Pose-guided feature region-based fusion network for occluded person re-identification [J]. Multimedia Systems, 2023;29:1771–1783.
- [27] SUN Y, ZHENG L, DENG W, et al. Svdnet for pedestrian retrieval [C]//Proceedings of the IEEE international conference on computer vision. Venice;IEEE,2017;3800–3808.