

文章编号: 2095-2163(2021)12-0184-06

中图分类号: TP391

文献标志码: A

基于区域生成网络的行人重识别算法优化

徐振国, 张旭, 丁亚男, 汤健

(上海工程技术大学 航空运输学院, 上海 201620)

摘要:为解决行人重识别场景中图像背景噪声对行人特征提取的干扰问题,本文提出了一种基于区域生成网络(RPN)的行人重识别改进算法。使用RPN获取具有不同尺度信息的感兴趣区域(ROI),再通过感兴趣池化(ROI pooling)层实现ROI多尺度信息的协调统一,抑制了图像背景噪声对行人信息表征的影响;搭建了以全局特征、切块局部特征及基于RPN的ROI特征的多分支网络结构,增强了行人特征信息;在难样本采样的三元组损失上加入正样本的最小距离为类内距离,提高正样本之间的聚类性能;最后,结合了优化的三元组损失函数和交叉熵损失函数来监督训练,防止训练结果过拟合。为验证该方法的可靠性,在Market1501数据集上进行验证,本文方法在Market1501数据集上的Rank1精度为94.7%,mAP精度为85.8%,表明本文方法具有较好的行人识别效果。

关键词:行人重识别;区域生成网络;多分支网络;三元组损失

Optimization of pedestrian re-identification algorithm based on area generating network

XU Zhenguo, ZHANG Xu, DING Yanan, TANG Jian

(School of Air Transportation, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] In order to solve the problem of interference of image background noise on the extraction of pedestrian features in the task of pedestrian re-recognition, this paper proposes an improved algorithm for pedestrian re-recognition based on a region proposal network (RPN). RPN is introduced to obtain regions of interest (ROI) with different scale information, and then the coordination and unification of ROI multi-scale information is realized through the ROI pooling layer, which suppresses the influence of image background noise on pedestrian information representation. Later the multi-branch network structure is built based on global features, block local features, and RPN-based ROI features to enhance pedestrian feature information. Then the minimum distance of positive samples is added to the triple loss of difficult sample sampling as the intra-class distance, which improves the clustering performance between positive samples. Finally, the optimized triple loss function and the cross-entropy loss function are combined to supervise the training and prevent the training results from overfitting. In order to verify the reliability of the method, some experiment is carried out on the Market1501 dataset. The accuracy of Rank1 of this method on the Market1501 dataset is 94.7%, and the accuracy of mAP is 85.8%. The results show that this method has a good pedestrian recognition performance.

[Key words] pedestrian re-recognition; region proposal network; multi-branch network; triple loss

0 引言

行人重识别是指用给定待识别的行人图像,从采集自不同时间点、不同摄像头的图像或者视频中检索特定行人的任务。行人重识别可以弥补目前固定摄像头的视觉局限,并可与目标检测、目标跟踪技术相结合,应用于视频监控、智能安防等领域^[1]。在实际情况中,因摄像头安装位置、拍摄视角、环境光照变化及遮挡干扰等因素的影响,造成行人的姿态变化及外观差异,给行人识别带来巨大挑战。

行人的特征表示的鲁棒性对行人重识别算法的

准确度有很大的影响,越好的特征表示能够获取到更加全面的特征信息,对应算法的效果就越好。早期的行人重识别一般都是提取手工设计的特征,包括颜色、方向梯度直方图、LOMO、SIFT等,之后利用KISSME或XQDA度量相似性^[2-3]。但在复杂场景下,传统的手工特征描述能力有限,相似性度量也会很难求解,随着深度特征在各任务中表现出相较于传统特征更强的表征能力,目前行人重识别都是基于深度卷积神经,自动提取深度特征。起初基于深度学习的行人重识别方法主要是用深度网络学习图像的全局特征,用分类损失或者度量损失进行训练,

作者简介:徐振国(1995-),男,硕士研究生,主要研究方向:行人跟踪与重识别;张旭(1973-),女,博士,副教授,硕士生导师,主要研究方向:民航信息控制;丁亚男(1996-),女,硕士研究生,主要研究方向:室内定位追踪;汤健(1994-),男,硕士研究生,主要研究方向:交通通信与智能信息处理。

通讯作者:张旭 Email:zx_sues@163.com

收稿日期:2021-06-22

文献[4]提出了一个基于难样本采样的三元组损失算法,通过在一个训练批量中挑选出特征距离较大的正样本和特征距离较小的负样本进行训练,能够明显加快模型的收敛,提高网络的泛化能力;当只用图像的全局特征作为特征,表示识别的方法遇到瓶颈,文献[5]提出一种基于水平切块的局部特征的模型,将每一个局部特征作为一个独立的特征连接损失函数单独训练,将局部特征拼接起来,得到最终的特征。引入基于局部的精确池化(Refined part pooling, RPP)方法,用注意力机制对水平切块进行修正,进一步提升了算法的性能。但使 RPP 需预先训练好网络模型,再冻结模型参数重新训练,因此整个模型不能端到端的训练,且仅使用单一尺度的局部特征会丢失一部分有用的视觉信息。文献[6]引入人体骨架关键点模型,提取人体关键点,利用关键点通过区域候选网络提取 7 个身体子区域,然后根据子区域的不同语义层次与关系在不同的阶段将特征向量进行融合,得到一个联合全局特征和多阶段局部特征的行人重识别特征;文献[7]提出了一种全局到局部对齐的描述子学习方法(Global-Local-Alignment Descriptor, GLAD),通过估计人体的 4 个关键点把图像分成头部、上半身和下半身,然后将原图和 3 个局部图像一起连接到一个 4 分支共享权重的卷积网络中,分别学习 3 个局部特征和全局特征,利用全局平均池化(Global average pooling, GAP)来提取各自的特征,最后特征融合了全局以及 3 个

局部图像的信息。上述方法利用行人姿态点提取特征,虽然可以对齐不同图像中的人体结构信息,但是需要一个额外的姿态估计模型,算法效率低,且分块区域共享权重可能会导致信息丢失,影响行人识别的准确度^[8]。

为减少图像背景对行人信息表征的影响,本文将 RPN 引入到行人重识别算法中,通过 RPN 获取不同尺度信息的候选区域,更关注图像中的行人区域,将候选区域投影到特征图上,经过后处理筛选得到最终的候选区域;再结合 ROI 池化层处理不同尺度大小的特征图,实现多尺度信息的协调统一;搭建了一个联合全局特征、水平切块的局部特征以及基于 RPN 和 ROI 特征的多分支网络结构,利用局部分支关注细粒度的行人特征弥补全局分支中的信息缺失,进而得到一个联合全局和局部多尺度信息的多分支网络。另外,训练阶段在难样本采样的三元组损失上引入正样本的最小距离为类内距离,提高正样本之间的聚类性能,防止结果过拟合。

1 基本原理

1.1 网络结构

本文的模型结构如图 1 所示,采用联合全局特征、水平切块的局部特征以及经过区域生成网络提取 ROI 的多尺度特征。全局特征关注行人整体特征,水平切块的局部特征关注细粒度的行人特征,区域生成网络提取 ROI 的多尺度特征抑制背景噪声。

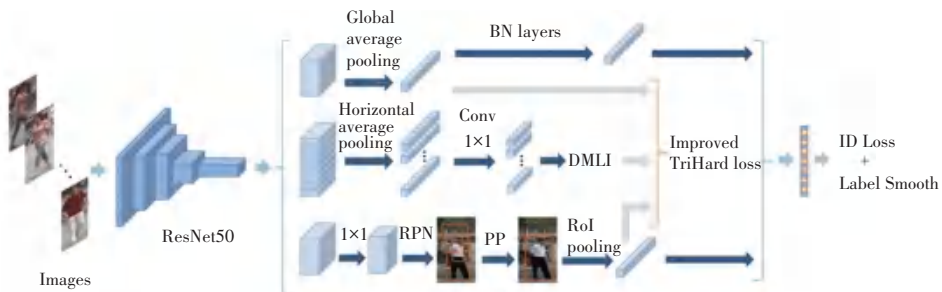


图 1 网络模型结构

Fig. 1 Structure of the network model

模型的主干网络采用 Resnet50 网络,在原来网络的基础上移除最后的平均池化层和全连接层,定义特征维度并添加分类器。将骨干网络最后一个残差块的最后一层卷积层的步长设置为 1,将提取的特征图尺寸增大一倍,提取更加细粒度的特征。

将经过主干网络提取的特征图分别经过 3 个分支:

(1)全局分支:经过全局平均池化得到 2048 维的特征,再经过一个 BNNeck 结构;

(2)局部分支:利用水平池化得到 8 个局部特征,经由 BN 层对特征向量和权重向量作归一化处理,之后采用 1×1 卷积对特征向量降维,最后利用动态对齐算法(DMLI)对齐局部信息;

(3)区域生成网络分支:在特征图上生成候选区域并提取 ROI 的多尺度特征。

使用带标签平滑的分类损失和难样本采样的改进三元组损失进行联合训练优化,测试阶段联合 3

个分支进行相似性匹配。

1.2 融合区域生成网络 ROI 池化的多尺度特征

图像切块是一种简洁有效的提取局部特征方法。考虑到在行人重识别数据集中,一部分图像背景噪声区域过大,一部分图像只包含部分前景,造成识别的困难,本文引入区域生成网络选择候选区域,再通过 ROI 池化层提取 ROI 的多尺度特征,降低背景噪声的影响。

区域生成网络(Region Proposal Network, RPN)由 Faster R-CNN 一文提出,RPN 网络在特征图上生成目标候选区域,并对目标候选区域的位置进行回归^[9]。具体操作为:首先,在卷积网络提取的特征图上,用一个 3×3 的滑动窗口检测,找到与滑动窗口中心点对应原始图像上的区域,将框的中心作为锚点,并生成预先定义的 K 个候选窗口,滑动窗口每滑动一个位置,生成一个 256 维的特征向量,遍历




图 2 区域生成网络分支结构

Fig. 2 Structure of the region proposal network

(1) 本文主干采用 Resnet50 网络,输出 2 048 维的特征图,为了减少计算量,在区域生成网络之前先进行一次 1×1 卷积,得到 512 维的特征,经过区域生成网络之后输出 $16 \times 8 \times 512$ 维的特征;

(2) 对于上述得到的特征,可以看作是 16×8 的 512 通道的图像,在图像上的每个位置定义候选窗口,考虑到特征提取网络的图像是 256×128 像素的行人图像,因此定义 3 种比例的矩形锚框,分别是 $H : W = \{2 : 1, 3 : 2, 1 : 1\}$;

(3) 利用分类层输出每个位置候选框属于行人的概率,筛选得分排序低的结果,再经过非极大值抑制得到最终的预测;

(4) 利用 ROI 池化层统一特征向量大小时,首先将每个候选区域划分为 8×1 块,对各部分进行平均池化;接着将得到的 8×1 维的特征张量水平切分成 8 个特征向量;将 ROI 池化后的特征先联合全局分支和局部分支连接三元组损失训练优化;对 8×1

得到一个新的特征图;其次,对整个特征图分别进行两次 1×1 卷积,得到每个特征向量的类别分数和候选框的回归参数;最后,通过筛选越界的候选框、非极大值抑制及偏移,得到最终的候选框。

使用 RPN 网络生成候选区域后,将 RPN 网络生成的候选框投影到特征图上,获得相应的特征矩阵,由于经过 RPN 网络生成的候选区域具有不同的尺度和形状,不能直接通过全连接层预测分类,因此本文又将每个特征矩阵通过一个 ROI 池化层获得统一大小的特征图。具体操作为:首先,将经过 RPN 网络生成的候选区域映射到特征图上;其次,对映射后的区域进行划分,使之与输出的维度相同;最后,对划分后的每个部分进行最大池化,得到固定大小的特征图。

本文在区域生成网络的基础上做出修改,如图 2 所示。

维的特征张量再进行全局平均池化,通过全连接层计算分类损失。

1.3 损失函数

分类损失可以看作是在特征空间学习几个超平面,把不同类别的特征划分到不同的子空间里。将特征归一化到超球面,再优化分类损失,取得更好的效果。基于分类损失的方法比较鲁棒,训练也比较稳定,但当训练的 ID 数过多时,分类损失会容易过拟合。而三元组损失(Triplet loss)可以缩短正样本对之间的距离,增加负样本对之间的距离,最终在特征空间中让同一行人的图像形成聚类。

由于三元组损失适合在自由的欧式空间里约束,如果把特征约束到超球面上,特征分布的自由区域会大大减小,导致三元组损失把正负样本对推开的难度增加,因此若将特征归一化到超球面上,再用三元组损失优化网络,网络的性能通常会变差。文献[10]提出一种 BNNeck 结构,将网络全局池化得

到的特征 f_i 直接连接一个三元组损失, 再将 f_i 经过一个 BN 层的归一化得到 f_i , 使一个批量里面 f_i 的各个维度近似地分布在超球面附近, 最后再经过一个分类的全连接层连接一个 ID 损失, 这样可以使得三元组损失能够在自由的欧式空间里约束特征, 而分类损失可以在一个超球面附近约束特征。

本文使用 BNNeck 结构的分类损失和三元组损失联合优化的训练方法。分类损失函数采用交叉熵损失 (CrossEntropy Loss), 利用行人 ID 作为训练标签来训练模型。由于传统的三元组随机从训练数据中采样的样本大部分都是简单易区分的样本对, 而且三元组损失没有考虑到正样本对之间的绝对距离, 不利于网络学习到更好的表示。本文使用难样本采样三元组损失 (TriHard Loss), 用更难的本样本来训练网络, 并在此基础上引入样本的类内距离, 提高网络的泛化能力。本文的 TriHard 损失表示式如下:

$$L_{th} = \frac{1}{p} \sum_{a \in batch} \min_{p \in A} d_{a,p} + (\max_{p \in A} d_{a,p} - \min_{n \in B} d_{a,n} + \alpha)_+$$

其中, $(z)_+$ 表示 $\max\{z, 0\}$; α 是设定的阈值参数; $d_{a,p}$ 为行人正样本对特征向量的欧式距离; $d_{a,n}$ 为行人负样本对特征向量的欧式距离; A 为与 a 相同行人 ID 的图像集; B 为不同行人 ID 的图像集。

对于每一个训练 batch, 随机挑选 p 个同一行人 ID 的行人, 每个行人随机选择 k 张不同的图片, 即一个 batch 含有 $p \times k$ 张图片。对于 batch 中的每一张图片 a , 可以挑选一个最难的正样本和一个最难的负样本与 a 组成一个三元组。TriHard Loss 会计算 a 和 batch 中的每一张图片在特征空间的欧式距离, 选出与 a 距离最远的正样本 p 和距离最近的负样本 n 来计算三元组损失, 再增加一项 $\min_{p \in A} d_{a,p}$ 优化类内损失。

2 实验结果与分析

2.1 数据集及评估指标

为了验证本文算法的有效性, 在 Market1501、DukeMTMC-reID 数据集上进行实验, 评估算法的性能。使用 Rank-1 和 mAP 这两个指标评估模型的性能。Rank-1 表示在 ReID 算法返回的行人识别排序列表中第 1 位命中检索的行人; mAP 指标反应检索的人在数据库中所有正确的图片排在列表前面的程度, 能更加全面的衡量 ReID 算法的性能。

2.2 实验环境和参数设置

实验平台使用搭载 NVIDIA GTX1060 GPU, 16G

内存的计算机。实验采用 PyTorch 深度学习框架, 使用在 ImageNet 数据集上预训练的 ResNet50 的残差卷积网络为骨架, 调整行人图像的尺寸为 256×128 像素, 将 ResNet50 的最后一个残差块的最后一层卷积层的步长设置为 1, 移除最后的平均池化层和全连接层, 在原来模型的基础上重新定义分类器, 行人图像经过骨架网络输出的特征图的尺寸为 $16 \times 8 \times 2048$ 。在定义网络前向传播时, 使用 ROI 池化, 最后对特征进行归一化处理。设置训练过程中初始学习率为 0.000 2, 每训练 100 个 epoch 学习率衰减 10%, 权重衰减系数为 0.000 5, 采用 Adam 优化器进行参数更新。

2.3 对比实验及结果分析

为了验证本文所提算法的有效性, 将所提算法与基准模型在 Market1501 和 DukeMTMC-reID 两个数据集上进行对比实验, 实验结果见表 1 和图 3 所示。采用 Alignedreid 模型作为本文的基准模型并对基准模型重新复现, 结果显示在 Market1501 数据集上, Rank1 精度为 89.6%, 平均精确度 mAP 为 76.2%, 在 Duke MTMC-reID 数据集上, Rank1 精度为 79.3%, 平均精确度 mAP 为 64.9%。采用 BNNeck 结构, 使用原始的 TriHard 损失训练模型, 结果显示模型的性能有了大幅度的提升。

为了验证所提引入样本类内距离的 TriHard 损失的有效性, 将原始的 TriHard 损失改为引入正样本类内距离的 TriHard 损失, 保证实验中除了 TriHard 损失不同, 其他的设置完全一致。如图 3 所示, 图 3(a) 表示所提算法在 Market1501 数据集的 CMC, 图 3(b) 表示所提算法在 Duke MTMC-reID 数据集的 CMC。绿色虚线表示采用原始的 TriHard 损失训练的结果, 蓝色实线表示采用引入样本类内距离的 TriHard 损失的结果。实验结果表明, 引入样本类内距离后的 TriHard 损失模型在 Market1501 和 Duke MTMC-reID 数据集上的性能更好。

为了验证区域生成网络分支在本文模型中的有效性, 在上述模型的基础上引入区域生成网络分支进行训练, 保持其他的设置完全一致。从表 1 可以看出, 加入区域生成网络分支一起训练后, 在数据集 Market1501 上的 Rank1 精度提高到了 94.7%, mAP 精度提高到了 85.8%; 在数据集 Duke MTMC-reID 上的 Rank1 精度提高到了 86.8%, mAP 精度提高到了 74.3%。图 3 给出了所提算法 CMC 曲线对比, 其中红色实线表示加入区域生成网络分支后的 CMC 曲线。对比实验表明, 引入区域生成网络分支, 行人

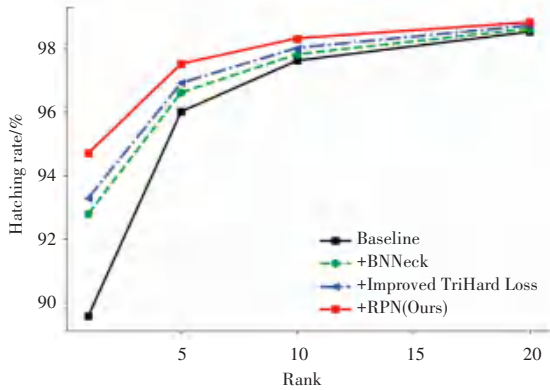
重识别的检测效果有显著的提升,验证了区域生成网络模块的有效性。加入区域生成网络分支后识别率提高的原因是区域生成网络分支可以有效降低图像中噪声区域的干扰,从而提取到判别性更强的行人特征。

表 1 实验结果分析对比

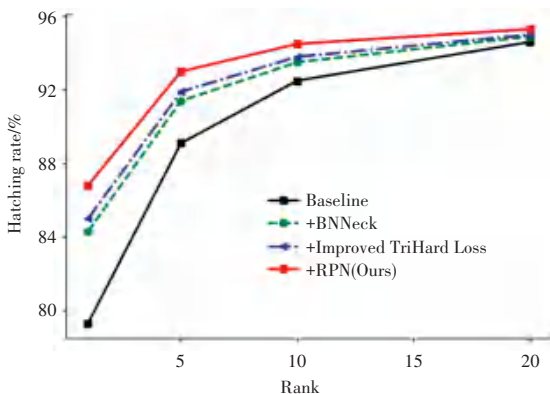
Tab. 1 Analysis and comparison of experimental results

Model	Market1501		Duke MTMC-reID	
	Rank1	mAP	Rank1	mAP
Baseline	89.6	76.2	79.3	64.9
+ BNNeck	92.8	83.4	84.3	72.1
+ Improved TriHard Loss	93.3	83.6	84.7	72.5
+ RPN(Ours)	94.7	85.8	86.8	74.3
+ Re-ranking	95.3	93.5	88.6	86.1

综上所述,当模型同时采用 BNNeck 结构、引入样本类内距离的 TriHard 损失以及加入区域生成网络分支进行训练时,所提算法能够明显提升模型性能,验证了所提算法的有效性。



(a) Market1501 数据集结果



(b) Duke MTMC-reID 数据集结果

图 3 改进算法在 Market1501 数据集和 Duke MTMC-reID 数据集 CMC 曲线对比

Fig. 3 Comparison of CMC curve of the improved algorithm between Market1501 dataset and Duke MTMC-reID dataset

使用 Re-ranking 算法后,本文算法在 Market1501 数据集上的 Rank1 精度为 95.3%, mAP 精度为 93.5%,在 Duke MTMC-reID 数据集上的 Rank1 精度为 88.6%, mAP 精度为 86.1%。部分行人识别 Rank10 的结果如图 4 所示。实验查询图像分别选择行人遮挡、图像模糊、背景复杂的情况,其中右侧虚线框内红框标记的图像表示匹配错误,绿色图像表示匹配正确。从结果可以看出本文算法取得了较好的结果。



图 4 在 Market1501 数据集的部分图像查询识别效果

Fig. 4 Some image query recognition effect in the Market1501 dataset

2.4 实验结果与主流算法比较

为了验证所提算法的有效性,将本文算法与 SCPNet、PCB、Pyramid、GLAD、MGN、Multi-Scale、MLFN、HPM、HACNN 等主流算法进行对比,结果见表 2,可以看出本文算法在 Market1501 和 Duke MTMC-reID 这两个数据集上的 Rank1 精度和 mAP 精度优于绝大部分对比的算法。

表 2 本文算法在 Market1501 和 Duke MTMC-reID 上与其他主流算法的对比

Tab. 2 Comparison of our algorithm with other mainstream algorithms on Market1501 and Duke MTMC-reID

Algorithm	Market1501		Duke MTMC-reID	
	Rank1	mAP	Rank1	mAP
SCPNet	91.2	75.2	80.3	62.6
PCB	93.8	81.6	83.3	69.2
Pyramid	95.7	88.2	89.9	79.0
GLAD	89.9	73.9	-	-
MGN	95.7	86.9	88.7	78.4
Multi-Scale	88.9	73.1	79.2	60.6
MLFN	90.0	74.3	81.0	62.8
HPM	94.2	82.7	86.6	74.3
HACNN	91.2	75.7	80.5	63.8
Baseline	89.6	76.2	81.2	67.4
Ours	94.7	85.7	86.8	74.3
+Re-ranking	95.3	93.5	88.6	86.1

3 结束语

本文提出了一种基于区域生成网络的行人重识别改进算法。算法采用联合全局分支、水平切块的局部分支以及区域生成网络 ROI 池化分支的三分支网络结构。其中全局分支关注行人整体特征, 水平切块的局部分支关注细粒度的行人特征, 通过引入区域生成网络选取候选区域, 使用 ROI 池化层提取不同尺度的特征, 抑制数据集中部分图像背景噪声过大的影响, 使学习到的特征具有更强的判别性。本文使用交叉熵损失函数和三元组损失联合优化的训练方法, 在难样本采样三元组损失的基础上引入正样本的类内距离, 提高网络的泛化能力。通过在 Market1501 和 Duke MTMC-reID 数据集上进行实验验证, 该方法取得了较好的识别效果, 进一步提高了行人重识别的精度, 表明所提方法的有效性。

参考文献

- [1] 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.
- [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 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015. 2197-

2206.

- [3] KOSTINGER M, HIRZER M, WOHLHART P, et al. Large scale metric learning from equivalence constraints [C]// Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA: IEEE, 2012: 2288-2295.
- [4] HERMANS A, BEYER L, LEIBE B. In defense of the triplet loss for person re-identification [J/OL]. (2017-5-17) [2021-03-20]. <https://arxiv.org/abs/1703.07737>.
- [5] SUN Y, ZHENG L, YANG Y, et al. Beyond part models: Person retrieval with refined part pooling (and a strong convolutional baseline) [C]// European Conference on Computer Vision (ECCV), September 8-14, Munich, Germany. Cham Springer: 2018, 11208: 501-518.
- [6] ZHAO H, TIAN M, SUN S, et al. Spindle Net: Person Re-identification with Human Body Region Guided Feature Decomposition and Fusion [C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017.
- [7] WEI L, ZHANG S, YAO H, et al. GLAD: global-local-alignment descriptor for scalable person re-identification [J]. IEEE Transactions on Multimedia, 2018, 21(4): 986-999.
- [8] XU L Z, PENG L. Person Reidentification Based on Multiscale Convolutional Feature Fusion [J]. Laser & Optoelectronics Progress, 2019, 56(14): 141504.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
- [10] LUO H, JIANG W, GU Y, et al. A Strong Baseline and Batch Normalization Neck for Deep Person Re-identification [J]. IEEE Transactions on Multimedia, 2019.

(上接第 183 页)

参考文献

- [1] 张松灿, 普杰信, 司彦娜, 等. 蚁群算法在移动机器人路径规划中的应用综述 [J]. 计算机工程与应用, 2020, 56(8): 10-19.
- [2] 李龙澍, 喻环. 改进蚁群算法在复杂环境中机器人路径规划上的应用 [J]. 小型微型计算机系统, 2017, 38(9): 2067-2071.
- [3] 胡杰, 张华, 傅海涛, 等. 改进人工势场法在移动机器人路径规划中的应用 [J]. 机床与液压, 2021, 49(3): 6-10.
- [4] 芦红利, 闫娟, 余星宝, 等. 基于遗传模糊算法爬壁机器人避障仿真研究 [J]. 轻工机械, 2021, 39(1): 82-85.
- [5] BAE Youngseok, JANG Sunghoon, YOO Sungjun, et al. Automatic Bias Control Technique of Dual-Parallel Mach-Zehnder Modulator Based on Simulated Annealing Algorithm for Quadrupled Signal Generation [J]. Photonics, 2021, 8(3): 80.
- [6] 吴庆洪, 张颖, 马宗民. 蚁群算法综述 [J]. 微计算机信息, 2011, 27(3): 1-2, 5.
- [7] 谭会生, 廖雯, 贺迅宇. 一种改进蚁群算法的移动机器人快速路径规划算法研究 [J]. 动力学与控制学报, 2019, 17(2): 104-111.
- [8] 于洲, 陈圣军, 李小平. 改进蚁群算法的研究综述 [J]. 信息与电脑 (理论版), 2021, 33(11): 57-59.

- [9] ZHANG W, SAUPPE J J, JACOBSON S H. Comparison of the number of nodes explored by cyclic best first search with depth contour and best first search [J]. Computers & Operations Research, 2021, 126: 105129.
- [10] 李龙澍, 喻环. 改进蚁群算法在复杂环境中机器人路径规划上的应用 [J]. 小型微型计算机系统, 2017, 38(9): 2067-2071.
- [11] CHAKRABORTY F, ROY P K, NANDI D. Elephant Herding Optimization for Multi-Level Image Thresholding [J]. International Journal of Applied Metaheuristic Computing (IJAMC), 2020, 11(4): 64-90.
- [12] WANG G G, DEB S, GAO X Z, et al. A new metaheuristic optimisation algorithm motivated by elephant herding behaviour [J]. International Journal of Bio-Inspired Computation, 2016, 8(6): 394-409.
- [13] 董凌艳, 徐红丽. 基于改进型蚁群算法的 AUV 路径规划 [J]. 自动化与仪表, 2017, 32(3): 1-4.
- [14] 蒋强, 易春林, 张伟, 等. 基于蚁群算法的移动机器人多目标路径规划 [J]. 计算机仿真, 2021, 38(2): 318-325.
- [15] 孟冠军, 陈信华, 陶佃佩, 等. 基于混合蚁群算法的 AGV 路径规划 [J]. 组合机床与自动化加工技术, 2021(1): 70-73.