

DOI:10.13364/j.issn.1672-6510.20210298

## 基于冗余特征正则化的车辆重识别算法

王 媛<sup>1,2</sup>, 王广义<sup>1</sup>, 曾磊磊<sup>1</sup>, 熊 宁<sup>1</sup>, 闫潇宁<sup>3</sup>, 许能华<sup>3</sup>

(1. 天津科技大学人工智能学院, 天津 300457; 2. 普迈康(天津)精准医疗科技有限公司, 天津 300000;  
3. 深圳市安软科技股份有限公司, 深圳 518131)

**摘 要:** 基于深度学习的车辆重识别算法使用空间关系不明确的滤波器提取特征, 这些互不独立的滤波器会导致特征提取互相依赖且冗余, 阻碍模型寻找数据的潜在规律. 为此, 提出一种显式的基于冗余特征正则化的车辆重识别算法 Res-GC (ResNet grouping convolution). 利用残差分组卷积网络阻止特征相互适应, 以获取带有正则特性的车辆特征. 引入 BNNeck (batch normalization neck) 方法解决交叉熵损失函数和三元组损失函数适用的车辆特征空间不一致的问题, 提升正则特征使用效率. 在车辆重识别的公共数据集 VeRi-776 和 VehicleID 上, Res-GC 算法的实验结果均优于现有模型, 验证了算法的有效性.

**关键词:** 车辆重识别; 分组卷积; 正则化; 残差网络

**中图分类号:** TP391.41; TP183

**文献标志码:** A

**文章编号:** 1672-6510(2022)05-0056-07

## Vehicle Re-Identification Algorithm Based on Redundant Features Regularization

WANG Yuan<sup>1,2</sup>, WANG Gangyi<sup>1</sup>, ZENG Leilei<sup>1</sup>, XIONG Ning<sup>1</sup>, YAN Xiaoning<sup>3</sup>, XU Nenghua<sup>3</sup>

(1. College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China;  
2. Population and Precision Health Care Co., Ltd., Tianjin 300000, China;  
3. Shenzhen Softsz Co., Ltd., Shenzhen 518131, China)

**Abstract:** The vehicle re-identification algorithm based on deep learning uses filters with ambiguous spatial relationships to extract features. These non-independent filters will cause feature extraction to be interdependent and redundant, and hinder the model from finding potential patterns in the data. To this end, an explicit vehicle re-identification algorithm ResNet grouping convolution (Res-GC) based on redundant feature regularization is proposed in this article. The residual grouped convolutional network is used to prevent the mutual adaptation of features to obtain vehicle features with regular characteristics. The batch normalization neck (BNNeck) method is introduced to solve the problem of the inconsistency of the vehicle feature space applicable to the cross-entropy loss and the triple loss function, thereby improving the efficiency of the use of regular features. On the public data sets VeRi-776 and VehicleID for vehicle re-identification, the experimental results of the Res-GC are ahead of the existing models, thus verifying the effectiveness of the proposed algorithm.

**Key words:** vehicle re-identification; grouped convolution; regularization; residual network

车辆重识别在视频监控、智能交通等领域有着广泛应用, 对提升公安监控系统的安全性和可靠性有着深远意义. 但是, 基于真实场景下采集的数据进行车辆重识别算法的研发是一项艰巨的任务. 现实生活中自然环境十分复杂, 例如光照变化以及阴天、雾霾

等环境因素的影响<sup>[1-4]</sup>. 以复杂环境为模型, 提取有效的车辆特征有较大难度, 导致车辆重识别模型失效, 鲁棒性较差. 同时, 由于在现实生活中同一厂商出品型号类似的车辆之间存在着相似性, 而同型号车辆的外观几乎相同, 导致车辆重识别模型提取的相似

收稿日期: 2021-12-30; 修回日期: 2022-03-09

基金项目: 国家自然科学基金项目(61976156); 天津市企业科技特派员项目(20YDTPJC00560)

作者简介: 王 媛(1989—), 女, 天津人, 副教授, wangyuan23@tust.edu.cn

特征不具备辨识性. 因此, 提取更具鲁棒性和辨识性的车辆特征对车辆重识别任务非常重要.

随着神经网络的发展, 深度学习模型越来越地被应用于车辆重识别任务. 为了得到更具辨识性和鲁棒性的特征以提高车辆重识别的准确率, 许多车辆特征提取方法被提出. Chu 等<sup>[5]</sup>提出 VANet 网络, 将相同视角与不同视角的图像分开处理, 通过设计空间内和跨空间损失函数, 尽可能多地学习车辆的全局特征, 从而提高车辆重识别的准确率. Liu 等<sup>[6]</sup>提出的 PROVID 方法是一种基于深度神经网络的渐进式车辆重识别框架, 通过从整体到局部搜索特征域, 在学习全局特征的同时学习细节特征, 包括视觉特征、车牌、摄像头位置等, 有效提高了识别的准确率. 上述两种方法均是启发式降低冗余特征提取的方法. He 等<sup>[7]</sup>开发了 PNVR 框架, 提出一种简单而有效的部分正则化鉴别特征保留方法, 以增强细微差异的感知能力, 通过提取局部细节特征降低模型提取的冗余特征, 进一步提高了车辆重识别的准确率. 窦鑫泽等<sup>[8]</sup>提出一种基于高置信局部特征的车辆重识别优化算法, 利用车辆不同区域置信度不同, 训练特征提取模型, 以提取高置信局部特征, 减少模型提取的冗余特征. 上述两种方法通过隐式降低冗余特征提取提高了车辆重识别的准确率.

上述方法具有一定的代表性, 证实降低特征之间的冗余可以有效提升模型特征的辨识度和鲁棒性, 更好地引导模型学习车辆数据的潜在视觉规律. 目前大多数方法均是隐式或启发式特征提取方法降低特征的冗余. 隐式特征提取方法会导致模型学习到的特征有较强的自适应特点, 特征提取过程中特征相互适应, 未能显著规避特征的互相依赖和冗余. 启发式特征提取方法是基于人工依赖直觉与经验设定的规则, 特征是否冗余以及冗余程度难以被有效估计, 与最优解也存在一定的偏差.

针对以上问题, 本文提出一种显式的基于冗余特征正则化的车辆重识别算法 Res-GC (ResNet grouping convolution). 在车辆特征提取阶段, 基于卷积神经网络, 使用分组卷积显式地对单个卷积核进行分组, 引入卷积核分组数作为超参数, 便于模型显式地搜索最适应的正则组数, 从而降低相邻层滤波器的相关性, 正则化冗余的特征, 提取更具区分性的车辆特征, 同时引入残差网络, 避免因网络加深而带来的网络退化问题. 在损失函数阶段, 先后使用三元组损失函数<sup>[9]</sup>和交叉熵损失函数指导车辆特征空间建模, 引入 BNNeck (batch normalization neck) 方法<sup>[10-11]</sup>在损

失函数作用的特征之间增加批量归一化层, 解决交叉熵损失函数和三元组损失函数适用的车辆特征空间不一致的问题. 在车辆重识别图像检索阶段, 引入重排序策略<sup>[12]</sup>, 提高同一辆车图像检索性能. 实验结果表明, 在车辆重识别的公共数据集 VeRi-776 和 VehicleID 上, Res-GC 算法的检索性能优于现有模型, 验证了算法的有效性.

## 1 算法分析

### 1.1 模型整体架构

图 1 为本文提出的基于冗余特征正则化的车辆重识别算法的整体架构. 在数据增强阶段, 输入训练集中的车辆图像和图像标签, 对输入的车辆图像进行随机擦除、翻转和切割; 在车辆特征提取阶段, 使用分组卷积对卷积神经网络的卷积核进行分组, 提取正则化的车辆特征, 同时在车辆特征提取阶段引入残差网络; 在损失函数阶段, 采用三元组损失函数和交叉熵损失函数进行参数学习, 引入 BNNeck 方法在交叉熵损失函数前增加批量归一化层, 减少交叉熵损失函数和三元组损失函数适用的车辆特征空间不一致的问题. 模型预测后处理阶段引入重排序策略<sup>[12]</sup>进行结果处理, 进一步提高同一辆车的图像检索性能.




图 1 本文的车辆重识别模型整体架构

Fig. 1 Overall architecture of vehicle re-identification model in this article

### 1.2 特征提取模块

为了防止随着网络深度的增加导致网络的退化, 在车辆特征提取阶段引入了残差网络进行提取. 残差网络<sup>[12-15]</sup>是通过尽可能地加深网络来提取更多丰富的图片特征进行训练并测试模型的一种网络. 它克服了因网络深度加大而带来的退化问题, 增强了模型的鲁棒性和健壮性, 从而达到更好的效果.

本文模型使用了基于分组卷积的 ResNet50 模型, 因而正则化冗余的卷积核能够提取更具鲁棒性和辨识性的车辆特征(图 2<sup>[12]</sup>). 从相邻层滤波器的相关性角度出发, 在每个块结构的特征提取步骤中, 将单

个卷积核分成 32 组进行车辆特征提取. 单个卷积核提取特征的过程存在耦合, 使特征相互依赖, 而卷积分组可以降低滤波器的相关性, 在降低网络参数的同时正则化冗余的卷积核, 获得正交的车辆特征, 提取具有区分性的车辆特征.




图2 ResNet50模型的一个残差单元  
Fig. 2 A residual unit of ResNet50 model

分组卷积最先在 ResNeXt 模型的应用中被证实有效<sup>[16]</sup>, 与标准残差网络不同的是在每个块结构中使用多个低维度的卷积核进行网络拓扑, 降低滤波器的相关性, 通过减少网络参数以正则化冗余的卷积核, 提升网络寻找数据潜在规律的能力(图 3<sup>[16]</sup>).

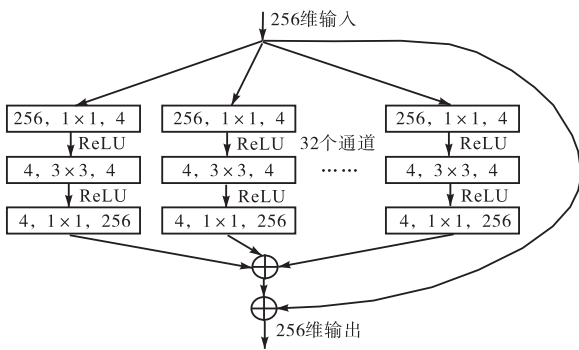


图3 分组卷积层块结构  
Fig. 3 Block structure of grouped convolutional layer

### 1.3 损失函数

在损失函数阶段, 由于仅使用交叉熵损失函数或仅使用三元组损失函数只能挖掘部分车辆特征指导信息, 因此本文使用交叉熵损失函数和三元组损失函数共同指导车辆特征空间建模.

为了更好地发挥两个损失函数的组合性能, 本文引入了 BNNeck<sup>[10-11]</sup>方法, 通过减少交叉熵损失函数和三元组损失函数之间的不一致性, 从而获得可以更好优化网络性能的损失函数. 交叉熵损失函数主要优化余弦距离, 三元组损失函数主要优化欧氏距离, 但直接在训练过程中同时使用两种损失, 可能导致当一种损失减少时, 另一种损失振荡或增加的现象. 本

文通过在残差网络提取特征之后在分类器全连接层之前添加一个批量归一化层. 通过归一化得到适用于余弦距离度量的维度特征, 促使不同的损失函数收敛程度一致.

三元组损失函数采用软间距版本<sup>[9]</sup>, 为

$$L_{\text{triplet}} = \log \left[ 1 + \exp \left( \left\| f_i - f_p \right\|_2^2 - \left\| f_i - f_n \right\|_2^2 \right) + m \right] \quad (1)$$

式中:  $f_i$  为没有经过批量归一化层的车辆图像特征;  $f_p$ 、 $f_n$  分别为车辆图像特征  $f_i$  对应的正、负样本;  $m$  为正、负样本之间的欧氏距离, 在本文中取值为 0.3.

批量归一化计算方法为

$$f_i = \gamma \frac{f_i - E[f_i]}{\sqrt{D[f_i] + \epsilon}} + \beta \quad (2)$$

其中:  $\gamma$ 、 $\beta$  为批量归一化过程中产生的参数;  $E[f_i]$  与  $D[f_i]$  分别表示特征  $f_i$  的均值与方差; 为防止分母为零, 设置参数  $\epsilon$ , 在本文中取值为  $10^{-8}$ .

交叉熵损失函数计算方法为

$$H(P, Q) = - \sum_{j=1}^n P((f_i)_j) \log Q((f_i)_j) \quad (3)$$

式中:  $f_i$  为经过批量归一化层的车辆图像特征,  $P$  为概率分布的期望输出,  $Q$  为概率分布的实际输出.

### 1.4 重排序策略

在模型预测后处理阶段, 本文引入重排序策略<sup>[12]</sup>进一步提高车辆图像的检索性能. 具体描述为: 使用查询集中车辆图像的检索结果作为新的查询集进行检索, 如果新的查询集中车辆图像的检索结果包括原始的查询图像, 则该车辆图像在原始的检索结果中得以保留, 否则将该车辆图像从原始的检索结果中删除. 利用上述方法对查询集所检索的结果重新排序, 使用新序列对车辆重识别结果进行预测. 重识别策略计算方法为

$$R(p, k) = \{g_i \mid (g_i \in N(p, k)) \cap (p \in N(g_i, k))\} \quad (4)$$

式中:  $N(p, k)$  表示车辆图像  $p$  检索结果相似度排名前  $k$  的检索序列,  $R(p, k)$  表示车辆图像  $p$  检索结果重新排序后相似度排名前  $k$  的检索序列.

## 2 实验

### 2.1 数据集与数据预处理

#### 2.1.1 数据集

VeRi-776 数据集<sup>[6,16-18]</sup>是北京邮电大学构建的用

于车辆重识别的数据集,该数据集由 20 个摄像机捕捉 776 辆车的 50 000 多张图像构成. 每个车辆图像均由 2~18 个摄像机从不同的视角、照明环境、遮挡情况下捕获,具备同样的标注(包括时空信息).

VehicleID 数据集<sup>[19]</sup>是北京大学构建的用于车辆重识别的大规模数据集,该数据集由 26 267 辆车的 221 763 张图像构成,每张图像根据车牌号均标注有相应的 ID. 为了使车辆重识别算法的性能测评更加全面,将测试集按照车辆图像尺寸划分为大、中、小 3 个子集. 本文使用小尺寸测试集(包含 800 张查询图像,6 532 张候选图像)进行测评.

### 2.1.2 数据预处理

在数据预处理阶段, VeRi-776 数据集集中的 576 辆车的 37 778 张图像作为训练集,200 辆车的 11 579 张图像作为验证集,200 辆车的 1 678 张图像作为测试集. VehicleID 数据集按照原始数据集标签划分,13 164 辆车的 113 346 张图像作为训练集,800 辆车的 5 693 张图像作为验证集,800 辆车的 800 张图像作为测试集. 对训练集使用随机擦除、翻转、切割的方法进行数据增强,增强后数据集的规模扩大到原始数据集的 4 倍,然后输入神经网络.

## 2.2 评价指标

为了评价本文模型的准确率,实验采用平均精度均值(mAP)和 Rank-N 表格作为评价指标.

mAP 用于评价车辆重识别方法的整体性能,表示所有检索结果精度的平均值<sup>[3]</sup>,计算公式为

$$AP = \frac{\sum_{k=1}^n P(k) \times gt(k)}{N} \quad (5)$$

$$mAP = \frac{\sum_{q=1}^Q AP(q)}{Q} \quad (6)$$

其中: AP 为每一个查询集图像  $q$  的检索结果的平均精度,  $k$  为图库集图像序号,  $n$  为图库集图像总数,  $N$  表示目标车辆的图像总数,  $P(k)$  为在检索序列中第  $k$  位之前车辆图像检索正确的概率,  $gt(k)$  为第  $k$  位图像是否是目标车辆,  $Q$  为查询图像的总数, mAP 为所有查询集检索结果的平均精度的均值.

Rank-N 表格: 车辆重识别任务,即在所有车辆图片中寻找与被查询车辆最相似的车辆图片,对所有车辆图片按照与被查询车辆的相似度进行排序; Rank-N 即表示排序后的结果, Rank-1 表示排序后第一张车辆图像为正确预测的概率, Rank-N 表示排序后前  $N$  张车辆图像为正确预测的概率. 本文选用 Rank-1 与 Rank-5 作为评价指标.

## 2.3 实验设置

实验环境: PyCharm 2020.2.1、Python 3.6、GTX 1080Ti.

实验配置: 本文使用 ResNet50 模型作为骨干网络,并删除该骨干网络的平均池化层及其后续层. 同时,将最后一个卷积层的滑动步长从 2 更改为 1. 前述卷积层的每个块结构中的卷积核被分成 32 组,以降低相邻层滤波器的相关性. 最后对每个  $1 \times 1 \times 2048$  维度的特征向量采用核大小为  $1 \times 1$  的卷积运算以执行降维运算,最终获得  $1 \times 1 \times 2000$  维的特征向量. 本文使用了动量值为 0.9、权重衰减值为  $5 \times 10^{-4}$  的 Adam 优化器.

## 2.4 实验结果与分析

### 2.4.1 整体性能结果分析

将 Res-GC 算法与现有的其他车辆重识别算法在 VeRi-776 数据集上的实验结果进行对比. 选择的对比算法包括引言部分提及的隐式或启发式降低特征冗余的算法 PROVID<sup>[6]</sup>、VANet<sup>[5]</sup>、PNVR<sup>[7]</sup>以及目前性能最佳的车辆重识别算法 TBE-Net<sup>[20]</sup>、SGFDVIA<sup>[21]</sup>、PRN<sup>[22]</sup>、TransReID<sup>[23]</sup>. 其他数据集的结果采用发表论文报道的结果.

不同算法在 VeRi-776 数据集上的评价结果对比见表 1. 从表 1 可以看出: Res-GC 算法在 VeRi-776 数据集上的 mAP 达到了 89.0%, Rank-1 的值达到了 97.5%, 相比于列表中效果最好的 PRN 算法分别提高了 3.2%、0.4%, 达到了更高的水平. 在 VeRi-776 数据集上, 实验结果验证了本文算法的有效性.

表 1 不同算法在 VeRi-776 数据集上的评价结果对比

Tab. 1 Comparison of evaluation results of different algorithms on VeRi-776 datasets

| 方法        | 评价指标/%      |             |             |
|-----------|-------------|-------------|-------------|
|           | mAP         | Rank-1      | Rank-5      |
| PROVID    | 53.4        | 81.5        | 95.1        |
| VANet     | 66.3        | 89.7        | 95.9        |
| PNVR      | 74.3        | 94.3        | 98.7        |
| TBE-Net   | 79.5        | 96.0        | 98.5        |
| SGFDVIA   | <u>86.2</u> | 96.7        | <u>98.6</u> |
| PRN       | 85.8        | <u>97.1</u> | <b>99.4</b> |
| TransReID | 82.0        | <u>97.1</u> | —           |
| Res-GC    | <b>89.0</b> | <b>97.5</b> | <u>98.6</u> |

注: 加粗数据为最优结果, 加下划线数据为次优结果

Res-GC 算法与现有的其他车辆重识别算法在 VehicleID 数据集(选用小尺寸测试集)上的实验结果对比见表 2. 选择的对比算法包括 VANet<sup>[5]</sup>、PNVR<sup>[7]</sup>、TBE-Net<sup>[20]</sup>、SGFDVIA<sup>[21]</sup>、PRN<sup>[22]</sup>、Trans ReID<sup>[23]</sup>, 均包括在 VeRi-776 数据集对比算法内, 但

是 PROVID<sup>[6]</sup>算法并未选用 VehicleID 数据集进行算法验证。

表 2 不同算法在 VehicleID 数据集上的评价结果对比  
Tab. 2 Comparison of evaluation results of different algorithms on VehicleID datasets

| 方法        | 评价指标/%      |             |
|-----------|-------------|-------------|
|           | Rank-1      | Rank-5      |
| VANet     | 83.2        | 95.9        |
| PNVR      | 78.4        | 92.3        |
| TBE-Net   | 86.0        | <u>98.4</u> |
| SGFDVIA   | <u>86.8</u> | 97.4        |
| PRN       | 78.9        | 94.8        |
| TransReID | 85.2        | 97.5        |
| Res-GC    | <b>97.4</b> | <b>99.1</b> |

注：加粗数据为最优结果，加下划线数据为次优结果

从表 2 可以看出，Res-GC 算法在 VehicleID 数据集上的 Rank-1 和 Rank-5 的值分别达到了 97.4%、99.1%。在 VehicleID 数据集上，验证了本文算法 (Res-GC) 的有效性。

#### 2.4.2 消融实验

不同算法在 VeRi-776 数据集和 VehicleID 数据集上的消融实验结果分别见表 3 和表 4。

表 3 不同算法在 VeRi-776 数据集上的消融实验结果  
Tab. 3 Ablation experiment results of different algorithms on VeRi-776 datasets

| 方法             | 评价指标/%      |             |             |
|----------------|-------------|-------------|-------------|
|                | mAP         | Rank-1      | Rank-5      |
| 仅不使用分组卷积和重排序   | 80.9        | 96.4        | 98.2        |
| 仅不使用分组卷积       | 87.8        | <u>97.1</u> | 97.9        |
| 仅不使用重排序        | 81.3        | 96.8        | <u>98.3</u> |
| 仅不使用三元组损失      | 86.0        | <u>97.1</u> | 98.0        |
| 仅不使用交叉熵损失      | <u>88.9</u> | 97.0        | <u>98.3</u> |
| 仅不使用 BNNeck 方法 | 85.9        | 96.2        | 97.7        |
| Res-GC         | <b>89.0</b> | <b>97.5</b> | <b>98.6</b> |

注：加粗数据为最优结果，加下划线数据为次优结果

在 VeRi-776 数据集上，相比于 Res-GC 的实验结果：仅不使用分组卷积的 mAP、Rank-1 以及 Rank-5 的值均有明显下降，验证了分组卷积正则冗余特征的有效性；仅不使用重排序后 mAP 值、Rank-1 值和 Rank-5 值均有所下降，证明了重排序可以有效提升车辆重识别的效果。在损失函数的消融实验中，仅不使用交叉熵损失函数和仅不使用三元组损失函数的 mAP、Rank-1、Rank-5 的值均有明显下降，两者直接叠加，即仅不使用 BNNeck 方法的 mAP、Rank-1、Rank-5 的值相比于分别仅不使用两种损失函数均有所下降，证明了交叉熵损失函数和三元组损失函数共同指导车辆特征空间建模 (使用 BNNeck 方法) 的有

效性。

表 4 不同算法在 VehicleID 数据集上的消融实验结果  
Tab. 4 Ablation experiment results of different algorithms on VehicleID datasets

| 方法             | 评价指标/%      |             |             |
|----------------|-------------|-------------|-------------|
|                | mAP         | Rank-1      | Rank-5      |
| 仅不使用分组卷积和重排序   | 85.4        | <b>97.4</b> | <u>99.1</u> |
| 仅不使用分组卷积       | 87.2        | <u>97.1</u> | 98.8        |
| 仅不使用重排序        | 87.4        | <b>97.4</b> | <b>99.4</b> |
| 仅不使用三元组损失      | 87.1        | <u>97.1</u> | 98.7        |
| 仅不使用交叉熵损失      | <u>87.9</u> | <u>97.1</u> | 98.8        |
| 仅不使用 BNNeck 方法 | 87.3        | <b>97.4</b> | 99.0        |
| Res-GC         | <b>88.3</b> | <b>97.4</b> | <u>99.1</u> |

注：加粗数据为最优结果，加下划线数据为次优结果

在 VehicleID 数据集上，相比于 Res-GC 的实验结果：仅不使用分组卷积后 mAP、Rank-1、Rank-5 的值分别下降了 1.1%、0.3%、0.3%，验证了分组卷积的有效性；仅不使用重排序的 mAP 值下降了 0.9%，证明了重排序可以有效提升车辆重识别的 mAP 值。与 VeRi-776 数据集一致，在损失函数的消融实验中，仅不使用三元组损失函数和仅不使用交叉熵损失函数的 mAP、Rank-1、Rank-5 均有明显下降，两者直接叠加，即仅不使用 BNNeck 方法的 mAP 值相比于仅不使用交叉熵损失函数有明显下降，与 VeRi-776 数据集一致，证明了交叉熵损失函数和三元组损失函数共同指导车辆特征空间建模 (使用 BNNeck 方法) 的有效性。

因此，在 VeRi-776 数据集和 VehicleID 数据集上的消融实验结果表明了本文算法的有效性。

#### 2.4.3 可视化分析

在 VeRi-776 数据集中随机选取 6 个不同车辆构成测试集，使用本文算法 Res-GC 进行训练，重识别结果按照相似度从高到低进行可视化排序，选取相似度排名前 10 的案例，可视化结果如图 4 所示。经人工初步辨认，测试集中第 1 辆车型号为丰田理念 s1，其中识别错误案例型号为众泰 Z300；第 4 辆车型号为奥迪 Q3，识别错误案例型号为奥迪 Q5。从图 4 中可以看出，识别错误案例主要集中在相似或相同车型之间的区分错误。同时，对于从不同角度、不同光照以及有遮挡物情况下拍摄的车辆照片，本文算法均能进行准确识别。不同角度、不同光照以及有遮挡物情况下提取的车辆特征均具有独立性，会降低查询车辆与目标车辆特征之间的余弦相似度，本文算法正是一种通过显式的冗余特征正则化的方式提取更具区分性的车辆特征，从而直接提高模型的重识别性能。





虚线框标出的为识别错误案例

图 4 本文算法相似度排名前 10 的检索结果

Fig. 4 Top 10 search results in similarity in this algorithm

### 3 结 语

使用空间关系不明确的滤波器提取车辆特征会导致特征互相依赖且冗余,阻碍模型找寻数据潜在的规律,从而影响车辆重识别的性能.针对上述问题,本文提出一种显式的基于冗余特征正则化的车辆重识别算法 Res-GC.通过对单个卷积核进行分组,降低相邻层滤波器的相关性,阻止特征的相互适应,以获取带有正则特征的非冗余车辆特征,相比于隐式的或启发式的降低特征冗余的方法,本文方法进一步提升了模型学习特征的辨识度和鲁棒性.在 VeRi-776 数据集与 VehicleID 数据集上的实验结果表明,本文模型进一步提高了车辆重识别技术的准确率.本文算法按照理论还可以广泛地应用于人工智能计算机视觉的其他研究中,在后续研究中将进行模型迁移,进一步完善计算机视觉其他领域的研究.

致谢:感谢校企合作项目(复杂场景下车辆属性信息提取与重识别)对本研究的支持.

#### 参考文献:

- [1] SU V H, NGUYEN N H, NGUYEN N T, et al. A strong baseline for vehicle re-identification[EB/OL]. [2022-03-08]. <https://arxiv.org/abs/2104.10850>.
- [2] LI H, LI C, ZHU X, et al. Multi-spectral vehicle re-identification : a challenge[EB/OL]. [2021-12-29]. <http://dx.doi.org/10.1609/aaai.v34i07.6796>.
- [3] 刘凯,李滢东,林伟鹏.车辆再识别技术综述[J].智能科学与技术学报,2020,2(1):10-25.
- [4] 张强,李嘉锋,卓力.车辆识别技术综述[J].北京工业大学学报,2018,44(3):382-392.
- [5] CHU R, SUN Y, LI Y, et al. Vehicle re-identification with viewpoint-aware metric learning[C]//IEEE. The IEEE International Conference on Computer Vision. New York: IEEE, 2019: 8282-8291.
- [6] LIU X, LIU W, MEI T. PROVID: progressive and multi-modal vehicle re-identification for large-scale urban surveillance[J]. IEEE Transactions on multimedia, 2018, 20(3): 645-658.
- [7] HE B, LI J, ZHAO Y, et al. Part-regularized near-duplicate vehicle re-identification[C]//IEEE. The IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2019: 3997-4005.
- [8] 窦鑫泽,盛浩,吕凯,等.基于高置信局部特征的车辆重识别优化算法[J].北京航空航天大学学报,2020,46(9):1650-1659.
- [9] HERMANS A, BEYER L, LEIBE B. In defense of the triplet loss for person re-identification [EB/OL]. [2021-12-29]. <https://arxiv.org/abs/1703.07737>.
- [10] HAO L. Bags of tricks and a strong baseline for deep person re-identification[EB/OL]. [2021-12-29]. <http://arxiv.org/pdf/1903.07071>.

- [ 11 ] 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 , 2019,22(10) :2597–2609.
- [ 12 ] ZHONG Z,LIANG Z,CAO D,et al. Re-ranking person re-identification with k-reciprocal encoding[C]//IEEE. 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). New York : IEEE , 2017 : 3652–3661.
- [ 13 ] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition[C]//IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). New York:IEEE,2016:770–778.
- [ 14 ] 赵志成,罗泽,王鹏彦,等. 基于深度残差网络图像分类算法研究综述[J]. 计算机系统应用,2020,29(1) : 14–21.
- [ 15 ] HE K,ZHANG X,REN S,et al. Identity mappings in deep residual networks[C]//European Conference on Computer Vision. Berlin:Springer International Publishing,2016:630–645.
- [ 16 ] XIE S,GIRSHICK R,P DOLLÁR,et al. Aggregated residual transformations for deep neural networks[C]// IEEE. 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). New York : IEEE , 2017 : 5987–5995.
- [ 17 ] LIU X,LIU W,MA H,et al. Large-scale vehicle re-identification in urban surveillance videos[C]//IEEE. IEEE International Conference on Multimedia and Expo(ICME). New York:IEEE,2016:1–6.
- [ 18 ] LIU X,WU L,TAO M,et al. A deep learning-based approach to progressive vehicle re-identification for urban surveillance[C]//European Conference on Computer Vision. Berlin:Springer International Publishing, 2016:869–884.
- [ 19 ] LIU H,TIAN Y,WANG Y,et al. Deep relative distance learning: tell the difference between similar vehicles[C]// IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). New York:IEEE,2016: 2167–2175.
- [ 20 ] SUN W,DAI G,ZHANG X,et al. TBE-Net:a three-branch embedding network with part-aware ability and feature complementary learning for vehicle re-identification[EB/OL]. [2022–03–08]. <https://ieeexplore.ieee.org/document/9635721>.
- [ 21 ] LI M,HUANG X,ZHANG Z. Self-supervised geometric features discovery via interpretable attention for vehicle re-identification and beyond[C]//IEEE. Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). New York:IEEE,2021:194–204.
- [ 22 ] CHEN H,LAGADEC B,BREMOND F. Partition and reunion: a two-branch neural network for vehicle re-identification[C]//IEEE. The IEEE Conference on Computer Vision and Pattern Recognition Workshops. New York:IEEE,2019:184–192.
- [ 23 ] HE S,LUO H,WANG P,et al. TransReID: transformer-based object re-identification[EB/OL]. [2022–03–08]. <https://arxiv.org/abs/2102.04378v2>.

责任编辑: 郎婧