

DOI: 10.13382/j.jemi.B2508260

融合多尺度特征的雾天车辆重识别算法*

张全¹ 刘田甜¹ 刘洋毅² 段昶³ 李艳¹ 彭博¹

(1. 西南石油大学计算机与软件学院 成都 610500; 2. 智能警务四川省重点实验室 泸州 646000;

3. 西南石油大学电气信息学院 成都 610500)

摘要: 车辆重识别技术在智能交通系统中扮演着至关重要的角色,其精准高效的性能对于显著提升城市交通安全性和交通效率具有决定性影响。然而,雾天等复杂天气条件会导致成像可见度降低,使得车辆外观信息严重失真,现有的车辆重识别方法仍然存在重识别平均精度较低和泛化能力不足的问题。为解决这些问题,提出了一种融合多尺度特征的雾天车辆重识别方法,旨在增强雾天真实数据下的重识别能力。该方法分为图像去雾和车辆重识别两个分支,通过共享权重的思想来平衡这两个任务,模型能够在雾天图像中提取稳定且具有代表性的特征。图像去雾模块采用两阶段恢复和金字塔增强技术生成清晰图像,以提供关键的雾天车辆图像特征,减小雾对重识别精度的影响。车辆重识别模块利用特征金字塔和卷积块注意力机制,从不同尺度上捕获更丰富和重要的特征,提升整个分支的重识别能力。在FVRID数据集上进行实验验证并与现有重识别方法进行对比,结果显示,在真实数据中的平均精度均值达到83.32%,首位命中率为94.70%,这两项指标均高于其他方法,这表明所提出的融合多尺度特征的雾天车辆重识别方法显著提升了雾天条件下真实数据的重识别性能,具有更强的准确性和泛化能力。

关键词: 车辆重识别; 多尺度特征; 雾天场景; 特征融合

中图分类号: TP391.4; TN911.73

文献标识码: A

国家标准学科分类代码: 540.4050

Multi-scale feature fusion for foggy weather vehicle re-identification

Zhang Quan¹ Liu Tiantian¹ Liu Yangyi² Duan Chang³ Li Yan¹ Peng Bo¹

(1. School of Computer Science and Software Engineering, Southwest Petroleum University, Chengdu 610500, China;

2. Intelligent Policing Key Laboratory of Sichuan Province, Sichuan Police College, Luzhou 646000, China;

3. School of Electrical Engineering and Information, Southwest Petroleum University, Chengdu 610500, China)

Abstract: Vehicle re-identification technology plays a crucial role in intelligent transportation systems. Its accurate and efficient performance is decisive for significantly enhancing urban traffic safety and efficiency. However, complex weather conditions such as fog can lead to reduced imaging visibility, severely distorting vehicle appearance information. Existing vehicle re-identification methods still suffer from lower average precision and inadequate generalization capabilities under these conditions. To address these issues, a method that integrates multi-scale features for vehicle re-identification in foggy weather has been proposed. This method aims to enhance the re-identification accuracy and robustness on real-world data under foggy conditions. This method is divided into two branches: image dehazing and vehicle Re-ID. By leveraging the concept of shared weights, this approach balances the two tasks, enabling the model to extract stable and representative features from foggy images. The image dehazing module utilizes a two-stage restoration and pyramid enhancement technique to generate clear images, providing key features of vehicles in foggy conditions, there-by reducing the impact of haze on the accuracy of Re-ID. The vehicle Re-ID module leverages a feature pyramid and convolutional block attention mechanism to capture richer and more significant features across different scales, enhancing the entire branch's Re-ID capability. Experiments were conducted on the FVRID dataset, comparing this method with various other Re-ID approaches. The results showed that on real-world data, the mean average precision reached 83.32%, and the cumulative matching characteristic at rank 1 was 94.70%. Both metrics

收稿日期: 2025-03-26 Received Date: 2025-03-26

* 基金项目: 智能警务四川省重点实验室开放课题(ZNJW2024KFMS003)项目资助

outperformed other methods, indicating that the proposed multi-scale feature fusion method for foggy weather vehicle Re-ID significantly improves performance under such conditions, demonstrating stronger accuracy and generalization capability. This research not only advances the current state of technology for foggy weather vehicle re-identification but also provides valuable insights for future studies. As the demand increases for applications such as intelligent traffic management and autonomous driving systems, this improved re-identification method holds great promise for advancing these related fields.

Keywords: vehicle re-identification; multi-scale features; foggy scenes; feature fusion

0 引言

随着智能交通系统的发展,车辆重识别技术作为其中的关键环节,对于提升城市交通安全性和效率具有重要意义。特别是在复杂天气条件下,传统的视觉算法往往受到极大挑战,因为特殊天气情况不仅会降低能见度,还会改变物体的颜色和形状特征,导致车辆的外观信息严重失真。而雾天作为一种典型的复杂天气条件,其特点是对光线的散射和吸收作用显著,这不仅降低了图像的对比度和清晰度,还可能引发颜色偏差,使得基于视觉的车辆识别变得更加困难。

传统的车辆重识别方法通常依赖于手工设计的特征提取技术,如颜色直方图、纹理描述符等。这些特征提取方法在理想条件下可以取得较好的效果,但在实际应用中,尤其是面对复杂环境(如雾天、雨天等),其性能会显著下降。因为这些方法无法有效处理图像中的噪声和模糊现象,导致特征提取不准确,进而影响最终的识别精度。此外,手工设计特征的方法通常需要大量的先验知识和经验,难以适应多变的实际场景。例如,在不同的光照条件下,颜色直方图可能会发生变化,导致特征表示不稳定。

近年来,随着深度学习技术的快速发展,基于卷积神经网络(convolutional neural network, CNN)的端到端模型逐渐成为车辆重识别领域的主流。这些方法通过自动学习图像中的特征表示,避免了手工设计特征的局限性,能够在重识别精度方面取得更好的表现。Meng 等^[1]提出了利用特殊的图像分割方法提取局部特征的车辆重识别算法,并通过引入公共部分注意力机制,提高模型的匹配性能,后续有许多研究者^[2]也在此基础上进行了一系列的改进。但在雾天情况下,共同区域信息可能不明显,会影响车辆部件解析的效果。为了进一步改进车辆重识别算法,如 Xiang 等^[3]引入了一种新的注意力机制——大分离核注意力和混合通道注意力。这些机制有助于模型更有效地捕捉关键特征,但同时也增加了模型复杂度和计算资源需求。与此同时,随着目标检测网络 YOLOv8 的发展,Gu 等^[4]提出了一种结合 YOLOv8 对象检测算法的车辆重识别算法,专门针对长距离小目标的问题。尽管该方法能够在保持较高检测精度的同时有效应对雾天导致的目标模糊问题,但它在实时性和适用范围上仍面

临限制。此外,多模态数据的应用为车辆重识别提供了新的思路。Zheng 等^[5]开发了一个考虑眩光影响的跨模态增强网络,通过对不同模态数据进行融合处理,增强了模型在各种光照条件下的适应能力,包括雾天等恶劣天气情况。然而,这种方法受限于多模态数据获取的难度和不同模态数据融合策略的复杂性。

基于多视角的研究也拓展了车辆重识别的方法。Wang 等^[6]提出的 MP-GIEN 方法通过构建多视角图结构来模拟不同视角下的车辆特征关系,提升了模型在复杂场景下的识别能力。但该方法在处理复杂结构图时计算成本高昂,并对数据标注有较高要求。除此之外,Zhou 等^[7]则介绍了双层次视点学习策略,专注于解决跨域车辆重识别问题。然而,双层次视点学习在处理不同领域间的巨大差异时适应性有限,且模型复杂度较高。

以上方法大部分是针对清晰的车辆图像进行的重识别任务,但在雾天环境中,由于能见度急剧下降,使得基于视觉的特征难以被正确提取,这不仅影响了颜色和纹理特征的表达,也削弱了模型对车辆身份的判别能力,这就导致依赖于高分辨率和清晰图像的车辆重识别方法的有效性大打折扣。早期研究通常将去雾和重识别视为独立任务,导致特征表示不一致。为解决这一问题,Chen 等^[8]提出了 SJDL-Vehicle 模型,这是一种半监督联合除雾学习方法,旨在通过结合图像除雾与车辆重识别任务共同优化网络参数,从而提高在雾天环境中的识别精度。然而,该方法的整体精度仍相对较低,且存在真实世界和合成数据的域差问题。随后,Gao 等^[9]探索了多任务学习框架下的车辆重识别方法,设计了一个能够同时处理多种任务(如去雾、特征提取等)的模型,以增强在复杂天气条件下的鲁棒性和准确性。这种方法不仅提升了车辆重识别的效果,还展示了多任务学习在恶劣天气条件下潜在的优势。然而,多任务学习面临任务间相互干扰以及调参存在困难的挑战。

当前,基于雾天图像的 SJDL-Vehicle 模型在平均精度方面仍有提升空间,且其合成数据与真实数据间存在域差异。为了提高雾天条件下车辆重识别的准确度并缩小这种域差异,本文提出了一种融合多尺度特征的方法来改进车辆重识别效果。本方法采用特征金字塔网络结合 ResNet-50 前 4 个阶段的特征,旨在使网络能够在雾天环境下更有效地提取出具有高度区分性的细节特征。其次,通过引入卷积块注意力模块,对由 ResNet-50 提取的

特征进行通道和空间维度上的优化,以此增强模型对关键特征的关注力,进一步提升模型性能。此外,设计了一项特征融合策略,将经过特征金字塔网络处理以及卷积块注意力机制优化后的特征进行整合。这种方法充分利用了多尺度信息及注意力机制的优势,保留了丰富的细节特征,从而显著提升了模型在雾天环境下的车辆重识别能力。

1 本文方法

本文采用了一种并联双分支的模型框架(图 1),该

框架的两个分支共享部分特征提取模块的参数,并在训练过程中协同更新共享模块的权重,有效地处理了雾天车辆图像并提取了雾天车辆中有利于重识别的特征,能够充分挖掘并融合不同分支的互补信息,从而提升重识别特征的判别性和鲁棒性,最终获得稳定的且更具代表性的雾天车辆重识别特征。本文选用 ResNet-50 作为基础网络,以 Resnet50 的前两个阶段作为公共特征提取模块,并通过整合去雾和车辆重识别两个任务来改善雾天条件下车辆识别的效果,在重识别任务中添加特征金字塔结构和卷积块注意力机制,以提取细节更丰富和具有关键区域的特征图,最终达到提升重识别精度的效果。

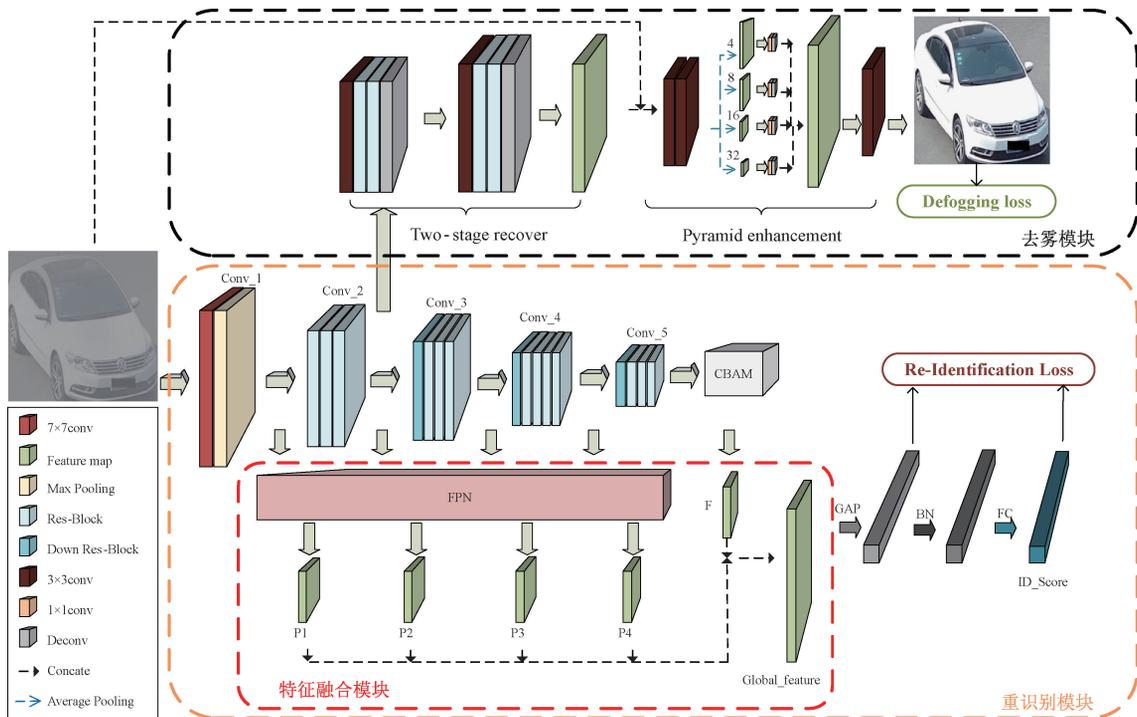


图 1 融合多尺度特征的雾天车辆重识别网络框架

Fig. 1 A multi-scale feature fusion network for foggy weather vehicle re-identification

具体来说,在 ResNet-50 的前两阶段后分裂成两个分支:一个分支负责将雾天车辆图像恢复清晰,其使用两阶段恢复技术和金字塔增强 (pyramid enhancement, PEM)^[10] 技术来提升图像清晰度;另一个分支则专注于车辆身份识别,使用特征金字塔融合 ResNet-50 前 4 个阶段的特征,并与经过卷积块注意力机制处理的第 5 阶段特征相融合,该分支利用学到的特征区分不同车辆。这两个分支共享最初的特征提取层,即使用相同的卷积层和参数进行初步特征学习。这种架构不仅降低了模型参数量,提升了计算效率,还促进了两个任务之间的信息交流与联合优化,使得模型能够在一次训练过程中同时掌握对去雾和重识别有益的特征表示。

在推理时,可以选择性地忽略去雾分支,仅依靠重识

别分支来进行预测。由于特征提取阶段的权重共享机制,模型可以在雾天环境中稳定地提取出有利于重识别的高质量特征。这种方法显著增强了模型的实际应用潜力,尤其适用于资源有限的边缘设备或对延迟敏感的应用场景。此外,权重共享的设计有助于模型更好地适应未见过的数据分布,从而提高了整体的鲁棒性和灵活性。

1.1 重识别模块

1) 特征融合模块

本文将 ResNet-50 前 4 个阶段提取到的特征图送入特征金字塔网络中 (feature pyramid network, FPN)^[11],通过自顶向下路径和横向连接,融合不同层次的特征,生成一组富含语义信息且具有高定位精度的特征图。FPN 模块旨在强化多尺度特征表示,这对目标检测和重识别任

务至关重要。这种多尺度特征表示有助于提高对各种尺寸目标的识别准确性。

FPN 构建过程如图 2 所示,输入图像先统一为 $384 \times 384 \times 3$ 的尺寸,然后送入 Resnet-50 网络中,经过网络中多个卷积层后可以得到不同尺度的特征图。接着,将前 4 个阶段提取到的特征图通过 1×1 的卷积层将每个特征图的输出通道数统一到 256,得到通道数均为 256 的特征图。然后,最深层的特征通过 3×3 卷积得到 P4,并对 P4 进行上采样与 Conv_3 的输出相加,再经过 3×3 卷积得到 P3;P2 和 P1 构建方法与 P3 类似。最后,ResNet-50 最终阶段提取的特征经过卷积块注意力模块 (convolutional block attention module, CBAM)^[12] 处理,与 FPN 模块生成的 4 个特征图进行拼接,形成最终的全局特征图。

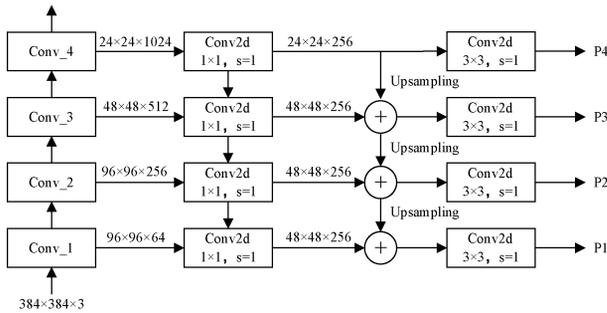


图 2 特征金字塔构建

Fig. 2 Feature pyramid construction diagram

CBAM 是一种集成了通道注意力和空间注意力机制于一体的模块,旨在提升卷积神经网络的特征表达能力,其结构如图 3 所示。

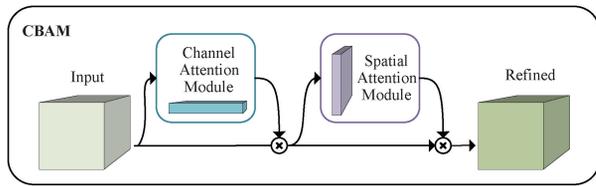


图 3 CBAM 结构

Fig. 3 CBAM structure diagram

首先,输入的特征图会被送入通道注意力组件 (channel attention module, CAM),这里通过全局平均池化与最大池化技术来压缩各通道的空间信息,并经过一系列共享网络的处理后,使用 Sigmoid 激活函数生成每个通道对应的注意力权重,然后将这些权重应用于原始特征图上以增强关键通道的表现。随后,经过调整的特征图会进入空间注意力组件 (spatial attention module, SAM),在该组件中,通过对通道维度执行平均池化和最大池化操作生成单通道的空间特征图,再经由特定的卷积层处理,生成用于强调特征图中关键区域的空间注意

力权重图,并将其应用到特征图上。因此,CBAM 能够有效地优化特征图,帮助模型聚焦于重要特征,进而提升识别精度和整体表现。因为 CBAM 能够动态调整每个通道的重要性,突出显示特征图中的关键区域,从而增强重要信息并抑制不相关信息。最终生成的特征图不仅保留了丰富的局部细节,还结合了上下文信息,为车辆重识别提供了强有力的表征。

2) 重识别模块损失函数

融合后的特征经全局平均池化 (global average pooling, GAP) 与批量归一化 (batch normalization, BN) 操作,生成 3 072 维的嵌入向量,作为最终的重识别表征。GAP 被用于特征编码末端,主要基于以下考虑:首先,其对空间维度的平均操作能够有效抑制由雾天图像光照不均、对比度衰减等退化因素引起的局部激活扰动,从而增强特征的整体稳定性;其次,GAP 不引入额外参数,计算高效,符合并联双分支架构对模型轻量化与训练效率的要求;此外,在多尺度特征融合场景下 (如结合特征金字塔或注意力机制),GAP 能更均匀地聚合跨尺度响应,避免最大池化对局部显著区域的过度依赖,有利于重识别分支学习更具判别性的全局语义表征。

接下来,利用全连接层调整车辆身份的数量,以利于分类任务的执行。在优化过程中,应用了如式 (1) 所示的三元组损失 (L_{Tri})。

$$\begin{cases} D_{\max} = \max_{z_p \in \mathcal{A}(z_i)} D(z_i, z_p) \\ D_{\min} = \min_{z_n \in \mathcal{N}(z_i)} D(z_i, z_n) \\ L_{Tri} = \frac{1}{Q} \sum_{i=1}^Q [D_{\max} - D_{\min} + M]_+ \end{cases} \quad (1)$$

式中: D_{\max} 表示锚点样本与其所有正样本之间的最大距离; $D(\cdot, \cdot)$ 表示两个特征向量之间的欧氏距离; $\mathcal{A}(z_i)$ 表示与第 i 个样本对应的正样本集; z_i 表示从第 i 个输入样本中提取的特征向量; z_p 表示与 z_i 相似的正样本特征向量; D_{\min} 表示锚点样本与其所有负样本之间的最小距离; $\mathcal{N}(z_i)$ 表示与第 i 个样本对应的负样本集; z_n 表示与 z_i 不相似的负样本特征向量; Q 表示批次大小 (batch size),即每次处理的样本数量; M 表示三元组损失中的边距; $[\cdot]_+$ 表示取最大值操作。

使用式 (2) 所示的车辆身份分类损失 (L_{ID}) 对重识别分支进行优化,增强模型性能。

$$L_{ID} = -\frac{1}{Q} \sum_{i=1}^Q \log \frac{\exp(\sigma_i^{y_i})}{\sum_{j=1}^C \exp(\sigma_i^j)} \quad (2)$$

式中: Q 表示批次大小; σ_i^j 表示全连接层对于第 i 个输入图像和第 j 类输出; C 表示车辆的总类别数; y_i 表示第 i 个样本的真实类别标签。

重识别模块的损失函数由上述的三元组损失 L_{Tri} 和

车辆身份分类损失 L_{ID} 共同构成。

1.2 去雾模块

1) 结合 PEM 的两阶段去雾方法

去雾模块采用了 Chen 等^[8]使用的去雾策略,其流程

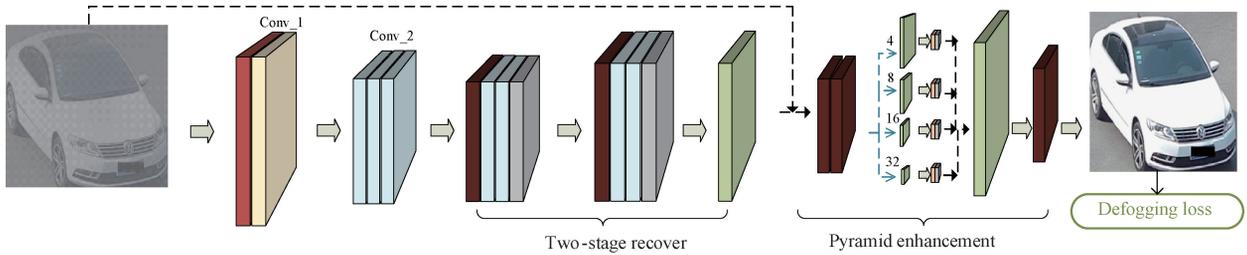


图 4 去雾分支网络结构

Fig. 4 Dehazing branch network architecture

由于特征维度在这一过程中有所降低,随后实施了反卷积用以恢复特征图的分辨率,使其与原始输入图像相匹配。此过程重复两次,旨在加强特征恢复的效果。随后,将处理后的特征送入 PEM^[10]。在 PEM 中,将之前提取到的特征图以不同尺度(如 4、8、16、32)进行划分,每个尺度对应特定分辨率的特征图。采用自顶向下路径,特定分辨率的特征图经由 1×1 的卷积和上采样处理后与其他尺度特征融合,最终使用 3×3 卷积对连接的特征生成输出,所有经过多尺度处理的特征图被汇总,形成一个更加丰富且详尽的特征表示。

此外,还利用半监督学习的优化策略,允许模型在每次迭代过程中交替使用真实场景图像和合成图像进行训练。监督学习阶段通过带有标注的合成数据(即模拟无雾条件下的图像),模型可以学习到清晰图像的关键特征。而无监督学习阶段则是利用未标注的真实场景数据(包括有雾图像),模型能够逐步适应实际环境中的复杂性和多样性。即使在缺乏无雾图像的真实标签时,模型依然可以通过对比学习、自约束损失等技术从真实数据中提取有用的信息,从而改进其对不同天气条件下的鲁棒性。通过这种方式,模型不仅能够从合成数据中获得高质量的监督信号,还能通过真实数据不断调整和优化自身的特征表达能力,使模型更好地应对现实世界中的各种挑战。最终,这种方法确保了模型在难以获取无雾图像真实标签的情况下,依然能够通过合成数据的监督学习和真实数据的无监督学习来提高泛化能力。

2) 去雾模块损失函数

由于去雾模块采用半监督学习,因此,去雾分支的损失(defogging loss)分为监督学习损失和无监督学习损失。

(1) 监督学习阶段的去雾损失函数

首先,该分支模型在监督学习阶段的损失函数(L_{DF})定义如式(3)所示。

的去雾模块如图 4 所示。首先,使用 resnet50 的前两个阶段进行初步特征提取,并通过个卷积层和两组残差学习单元进行处理,以增强特征表示精度和针对性,特别针对减轻雾的影响。

$$L_{DF_i} = \frac{1}{Q} \sum_{i=1}^Q \| J_i - J_i^{GT} \|_2 \quad (3)$$

式中: Q 表示批次大小; J_i 表示第 i 个预测的去雾图像; J_i^{GT} 表示第 i 个对应的地面真实去雾图像(ground truth); $\| \cdot \|_2$ 表示欧几里得(L2)范数,用于计算两个图像之间的欧氏距离。

(2) 无监督学习阶段的去雾损失函数

无监督学习阶段的损失函数 L_{DFu} 由颜色熵损失 L_{CE} 、暗通道损失 L_{DC} 、总变差损失 L_{TV} 和自约束损失 L_{SC} 构成。

通过分析预测图像的直方图并使用对数函数来量化图像的颜色多样性。颜色熵较高意味着图像中包含更广泛的颜色变化,这有助于提升图像的清晰度和对比度效果。颜色熵损失如式(4)所示。

$$L_{CE} = - \frac{1}{Q} \sum_{i=1}^Q \sum_{k=0}^{255} H^k(J_i) \log(H^k(J_i)) \quad (4)$$

式中: Q 表示批次大小; J_i 表示第 i 个预测的去雾图像; $H^k(\cdot)$ 表示归一化直方图在值 k 处的计数。

暗通道指的是在大多数清晰的自然图像中,对于任意一个小区域,在至少一个颜色通道(红色、绿色或蓝色)内总会有一些像素值非常低,甚至接近于零。这种现象主要出现在非天空区域的图像部分,基于这一观察,便有了暗通道先验,它假设在无雾的图像中,每个局部区域至少存在一个颜色通道的像素值极低。而 Tang 等^[13], Chen 等^[14]已经证实暗通道操作^[15]是一种有效的方法来表示雾的密度。因此,通过暗通道操作(dark channel operation),可以得到与雾密度相关的暗通道值,如式(5)所示。

$$DC(J)(x) = * \min_{y \in \Omega(x)} (* \min_{c \in \{r, g, b\}} J^c(y)) \quad (5)$$

式中: $DC(\cdot)$ 表示暗通道操作; $J^c(y)$ 表示图像 J 在位置 y 的颜色通道 c 的强度,通道 c 可以是红色、绿色或者蓝色; $\Omega(x)$ 表示以像素 x 为中心的局部区域。

有了暗通道操作后,便可以进行暗通道损失 L_{DC} 的

相关计算,如式(6)所示。

$$L_{DC} = \frac{1}{Q} \sum_{i=1}^Q \|DC(J_i)\|_1 \quad (6)$$

式中: Q 表示批次大小; J_i 表示第 i 个预测的去雾图像; $\|\cdot\|_1$ 表示 L1 范数,用于计算暗通道值的绝对值之合。该损失函数是为了最小化预测图像的暗通道值,使预测的去雾图像的暗通道值尽可能小,从而减少残留的雾,以此达到优化模型的目的。

为了抑制图像中的噪声,保留图像的内容和结构信息,引入总变差损失 L_{TV} ,总变差损失可以使图像的梯度尽可能小,从而减少噪声并保持图像的清晰度,如式(7)所示。

$$L_{TV} = \frac{1}{Q} \sum_{i=1}^Q \|\nabla_x J_i\|_1 + \|\nabla_y J_i\|_1 \quad (7)$$

式中: Q 表示批次大小; J_i 表示第 i 个预测的去雾图像; $\nabla_x J_i$ 和 $\nabla_y J_i$ 分别表示图像 J_i 在 x 和 y 方向的梯度。

为了确保模型学习到的特征与原始图像的特征保持一致,则引入了自约束损失 L_{SC} 。引入自约束损失后将有助于防止模型学习到不必要的特征,从而提高去雾图像的质量和一致性,如式(8)所示。

$$L_{SC} = -\frac{1}{Q} \sum_{i=1}^Q \frac{\langle \mathcal{F}(J_i), \mathcal{F}(I_i) \rangle}{\|\mathcal{F}(J_i)\|_2 \|\mathcal{F}(I_i)\|_2} \quad (8)$$

式中: I_i 表示输入的第 i 张有雾图像; J_i 表示第 i 张对应的去雾后的图像; $\mathcal{F}(\cdot)$ 表示 Fourier 变换操作; $\langle \cdot, \cdot \rangle$ 表示点积; $\|\cdot\|_2$ 表示欧几里得(L2)范数; Q 表示输入的图像数量。

因此,整合以上损失函数,可以得到无监督学习阶段的去雾损失函数 L_{DFu} ,如式(9)所示。

$$L_{DFu} = L_{CE} + \lambda_1 L_{DC} + \lambda_2 L_{TV} + \lambda_3 L_{SC} \quad (9)$$

式中: L_{CE} 为颜色熵损失; L_{DC} 为暗通道损失; L_{TV} 为总变差损失; L_{SC} 为自约束损失; $\lambda_1, \lambda_2, \lambda_3$ 为权重系数,用于平衡不同损失项。

1.3 总体损失函数

将以上两个分支的损失函数整合得到雾天车辆重识别的总体损失函数,同样分为监督学习阶段的总体损失和无监督学习阶段的总体损失。

监督阶段下的雾天车辆重识别损失函数如式(10)所示。

$$L_{Supervised} = L_{Tri} + L_{ID} + \lambda_4 L_{DFs} \quad (10)$$

式中: L_{Tri} 表示重识别分支的三元组损失; L_{ID} 表示重识别分支的分类损失; L_{DFs} 表示监督学习阶段去雾分支损失; λ_4 是用于平衡去雾分支损失的权重系数。

监督阶段下的雾天车辆重识别损失函数如式(11)所示。

$$L_{Unsupervised} = L_{DFu} + L_{Tri} + L_{ID} \quad (11)$$

式中: L_{DFu} 为无监督学习阶段去雾分支的损失; L_{Tri} 和 L_{ID}

分别为重识别分支的三元组损失和分类损失。

2 数据集及评价指标

2.1 数据集

车辆重识别领域中常见的数据有 VehicleID^[16]、VeRi-776^[17]、Vehicle-1M^[18] 和 VERI-Wild^[19],其中大部分图像都是清晰图像。而 Chen 等^[8] 利用有部分雾天数据的 VehicleID 和 VERI-Wild 这两个数据集,构建了数据集 FVRID,如表 1 所示,专门用于解决雾天条件下车辆重识别的挑战,其中“/”前后的数字分别代表车辆身份的总数和车辆图像的总数,下同。

表 1 FVRID 数据集的构建

Table 1 FVRID dataset construction

Set	Train	Probe	Gallery
VERI-Wild	1 167/19 532	389/389	389/6 125
Vehicle-1M	1 833/23 026	611/611	611/7 093
FVRID_Syn	3 000/42 558	1 000/1 000	1 000/13 218

FVRID 数据集构成如表 2 所示,FVRID 分为真实车辆图像数据集(FVRID_Real)和合成图像数据集(FVRID_Syn)两部分,所有的数据集由训练集(train set)、探针集(probe set)和画廊集(gallery set)构成,探针集包含了一组特定的查询样本,这些样本用来测试系统是否能够在画廊集中正确地找到对应的匹配项。数据集构成如表 2 所示。

表 2 FVRID 数据集的组成

Table 2 FVRID dataset composition

Set	Train	Probe	Gallery
FVRID_Real	403/5 051	1 000/1 000	1 000/12 227
FVRID_Syn	3 000/42 558	1 000/1 000	1 000/13 218

2.2 评价指标

1) 累计匹配特性(cumulative matching characteristic, CMC)曲线

CMC 曲线常用于评估行人重识别和车辆重识别等系统的性能。其中,CMC Rank-1(CMC@1)准确率表示探针样本与画廊集对比时,正确匹配出现在检索结果首位的比例。这一指标对于要求快速确认目标的应用尤为关键,因为它直接反映了系统首次尝试即能找到正确匹配的能力。CMC Rank-1 准确率越高,意味着系统在第一次查询中成功定位正确对象的可能性越大。与 CMC Rank-1 指标类似,CMC Rank-5(CMC@5)和 CMC Rank-

10 (CMC@ 10) 分别表示查询车辆在检索列表的前 5 位内和前 10 位内被正确识别的准确率,这些指标提供了关于系统性能的更全面视角。

2) 平均精度均值 (mean average precision, mAP)

mAP 是衡量车辆重识别系统性能的一个关键指标,尤其适用于评估系统在大规模数据集上的整体表现和稳定性。mAP 通过计算每个探针样本的平均精度 (average precision, AP), 然后对所有探针样本的 AP 值求平均来综合评估系统的效能。AP 是在不同召回率下精确率的平均值。对于每一个探针,系统会生成一个与画廊集中所有车辆匹配的结果列表,并按照相似度评分进行排序,基于这个排序结果来确定该探针的 AP 值。mAP 不仅关注检索结果中是否正确匹配,还重视这些匹配项的位置。即使正确匹配不在首位,只要它们排在前列,就能对整体评分做出正面贡献。在车辆重识别任务中,mAP 常用于评估系统的整体性能,尤其是在需要高召回率的情况下。例如,在智能交通系统、自动驾驶和安全监控等领域,准确识别和追踪车辆的能力至关重要。mAP 可以帮助研究人员和工程师了解其模型在实际应用中的表现,从而进行有针对性的优化和改进。

3 实验分析

3.1 实验设置

在训练阶段,采用在 ImageNet 上预训练的 ResNet-50 作为主干网络,以充分利用其在大规模数据上学习到的通用图像特征表示能力,并加速模型收敛。主干网络的初始化权重通过迁移学习加载,而去雾分支的参数则采用 Kaiming 正态初始化,以适配其独立的训练动态与目标函数。对于车辆重识别任务的身份分类层(即全连接层),其输出维度根据训练数据集的身份数量进行适配:在包含 3 000 个车辆 ID 的合成数据集上设为 3 000,在真实数据集中则设为 403。该设置确保分类层可有效建模各数据集中的细粒度身份分布,同时避免因维度不匹配导致的优化困难。

为缓解训练样本有限可能引发的过拟合问题,训练过程中引入了水平翻转与随机裁剪作为数据增强策略。其中,水平翻转模拟车辆在真实场景中的左右对称性,增强模型对视角变化的鲁棒性;随机裁剪则提升模型对局部遮挡和尺度变化的适应能力。整个模型共训练 120 个 epoch,该轮数经初步实验验证可在收敛性与训练效率之间取得平衡,避免欠拟合与冗余计算。

训练批次大小设为 32,在保证 GPU 显存可行的前提下,兼顾了梯度估计的稳定性与训练速度。优化器选用 Adam,因其在非平稳目标和稀疏梯度下具有良好的收敛性能,适用于本文复杂的多任务目标。初始学习率设为

1.09×10^{-5} , 并采用逐步升温 (warmup) 策略:在前 10 个 epoch 线性提升至 1×10^{-4} ,以稳定网络初期训练,避免因随机初始化导致的梯度震荡。随后保持恒定直至第 90 轮,再逐步衰减,以精细调整模型参数。此外,学习率衰减系数设为 0.6,基于验证集性能观察设定,确保在训练后期平滑收敛而不陷入局部最优。

在整体损失函数中,参照 SJDL 模型设置超参数 λ_1 , λ_2 , λ_3 和 λ_4 的值分别设为 1×10^{-5} , 1×10^{-5} , 300 和 1,用于平衡各损失项的贡献。其中, λ_1 和 λ_2 分别控制颜色熵损失 L_{CE} 与暗通道先验损失 L_{DC} 的权重,二者取较小值是由于这些手工先验在深度网络中仅作为辅助正则项,避免主导优化方向;该设定通过网络搜索在验证集上确定,以兼顾去雾效果与特征保真度。 $\lambda_3 = 300$ 用于增强自约束损失 L_{SC} 的影响,该损失旨在保留输入图像的结构一致性,在雾浓度变化剧烈的场景下尤为重要,较大的权重有助于提升去雾分支的鲁棒性。 $\lambda_4 = 1$ 表示去雾分支与主重识别任务之间的平衡系数,在保证身份识别性能的同时有效提升去雾质量。所有超参数的设定综合考虑了各损失项的数量级差异、任务优先级及模型在验证集上的收敛行为,确保多任务学习的稳定性与协同优化效果。

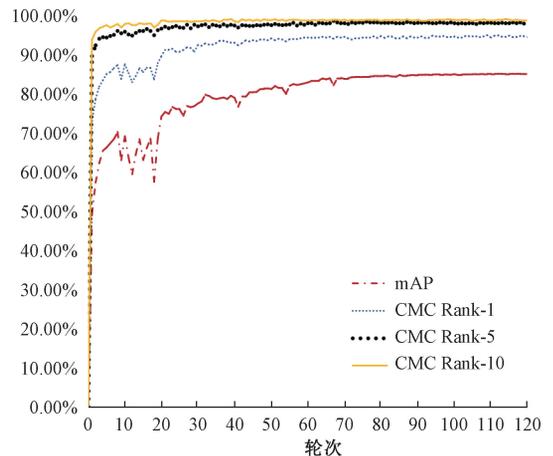


图 5 各指标折线图

Fig. 5 Line charts of various indicators

整个项目是基于 PyTorch 框架实现的,训练在 NVIDIA A100 GPU 上执行,总共训练大约 30 h。该模型训练中的各指标结果如图 5 所示,其中 mAP 达到 85.14%, CMC Rank-1 最终为 95.00%, CMC Rank-5 为 98.10%, CMC Rank-10 为 99.00%,说明模型在雾天条件下对车辆重识别具有较好的性能。

3.2 实验结果

将本文方法与重要的重识别方法进行了相应的对比,对比方法有 Triplet^[20]、VRCF^[21]、VOC^[22]、VEHICLEX^[23]、DMT^[24]、PVEN^[1] 和 SJDL^[8]。所有方法在 FVRID 数据集上的表现如表 3 所示,加粗数据为该列

指标最优数据,下划线数据为该列指标次优数据。在 FVRID_Syn 数据集上,本文方法在多数指标上取得了优异的成绩,仅在 mAP 指标的表现略弱于 SJDL 方法。在更具挑战性的 FVRID_Real 数据集上,本文方法也展现了

显著的优势:在衡量整体检索性能的 mAP 指标上,本文方法达到 83.32%,相较当前最优方法 SJDL^[8]提升了 0.79%;在衡量首位识别准确率的 CMC@1 指标上,本文方法取得的准确率 95.00%,领先 SJDL^[8]1.30%。

表 3 不同重识别方法在 FVRID 数据集上的对比结果

Table 3 Comparison of different re-identification methods on the FVRID dataset (%)

Method	mAP_S	mAP_R	Δ	CMC@1_S	CMC@1_R	CMC@5_S	CMC@5_R	CMC@10_S	CMC@10_R
Triplet	69.10	52.80	16.3	87.80	72.50	95.60	89.40	97.80	94.20
VRCF	69.00	58.00	11.00	88.60	81.10	97.60	93.80	98.40	96.80
VOC	67.10	59.90	7.2	88.70	83.50	95.10	94.00	96.50	97.20
VEHICLEX	77.86	69.01	8.85	91.20	84.80	97.10	96.10	98.70	98.10
DMT	77.30	73.40	3.9	94.00	93.40	97.60	97.60	98.60	98.80
PVEN	84.55	81.92	2.63	76.60	74.09	95.02	92.15	97.84	95.66
TransReID	73.90	72.10	1.8	84.80	82.60	95.20	90.70	98.70	95.60
SJDL	85.15	<u>82.53</u>	2.62	<u>93.90</u>	<u>93.40</u>	98.20	97.80	99.30	98.90
本文	85.14	83.32	1.83	95.00	94.70	<u>98.10</u>	97.80	<u>99.00</u>	98.90

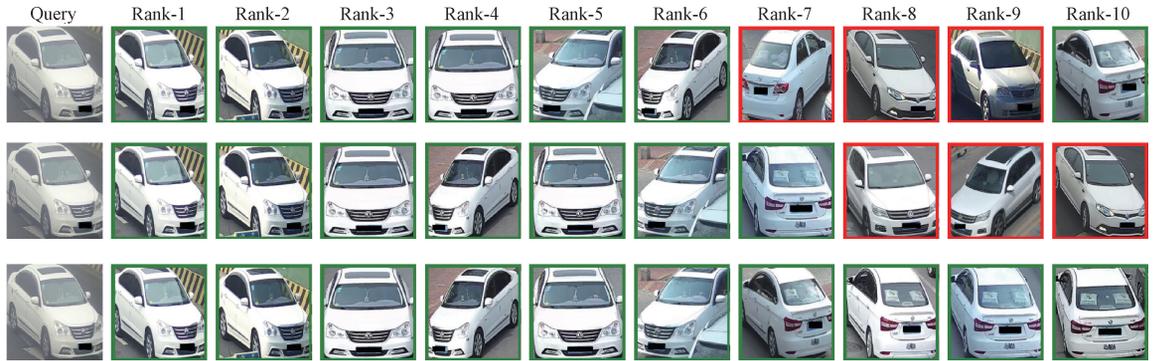


图 6 消融实验可视化

Fig. 6 Ablation experiment visualization

表 3 中,标记黑体数据为最优数据,标记下划线数据为次优数据,其中 Δ 表示合成数据和真实数据的 mAP 差值,其值越小表示模型在合成数据与真实数据上的性能差距越小,也说明模型具有较好的泛化能力。从表 3 中可以看出,本文方法不仅有着较好的性能,也更能从合成数据中学习到真实图像的特征表示,能够较好的减小合成数据和真实世界的域差。

3.3 消融实验

为了深入评估 FPN 和 CBAM 对雾天条件下车辆重识别模型性能的具体贡献,设计并实施了一系列消融实验。使用 FVRID_Real 数据集,通过逐步引入不同组件来精确量化每个模块对整体模型性能的提升效果。表 4 展示了消融实验结果,以 SJDL 模型为基准。该模型在 FVRID_Real 数据集上的 mAP 值为 82.53%,CMC@1_R 准确率为 93.40%。接下来,在基准模型的基础上引入了 FPN。结果显示,仅此一项改进就使得 mAP 提升了 0.63%至 83.16%。这表明,通过利用 FPN 能够更有效地

提取多尺度信息,从而增强模型在复杂天气条件下的识别能力。最后,当进一步将 CBAM 集成到模型中时,其带来的增益也很显著。加入 CBAM 后,模型的 mAP 值进一步提高到了 83.32%,相比基础模型提升了 0.77%;而 CMC@1_R 准确率则升至 94.70%,也增加了 1.3%。

表 4 消融实验

Table 4 Ablation experiment

基准模型	FPN	CBAM	mAP_R/%	CMC@1_R/%
✓			82.53	93.40
✓	✓		83.16	94.30
✓	✓	✓	83.32	94.70

消融实验可视化结果如图 6 所示,其中 Query 表示查询图像,Rank-k 表示对画廊集进行相似度排序后,排名第 k 张图片的检测结果,绿色框表示重识别结果正确,红色框表示结果错误。对于图 6 中的查询图像,基准模型 SJDL 在 Rank-7、Rank-8 以及 Rank-9 位置上出现了重

识别错误;而加入 FPN 后,前 10 张图片中仍然存在 3 张重识别错误的情况,但这些错误的排名相较于 SJDL 更为靠后,这也能说明 FPN 模块有效地提升了模型的整体识别效果,减少了早期排名中的错误率;最后引入 CBAM 后,相似度排名前 10 的结果完全正确,说明该模块进一步优化了特征选择,通过关注关键区域和通道信息,显著提高了模型的识别性能,也进一步验证了这两个模块对该模型的有效性。

4 结 论

通过对现有车辆重识别方法的深入研究,本文提出一种融合多尺度特征的雾天车辆重识别方法,使用联合去雾框架和特殊的融合策略,结合多尺度特征与卷积块注意力机制提取的特征,提升了雾天车辆重识别的平均精度和泛化能力,并通过消融实验验证了 FPN 和 CBAM 对提升雾天车辆重识别模型性能的有效性。该方法在车辆重识别任务中展现了显著的优势,特别是在处理复杂环境下的低能见度条件时表现尤为突出。此外,通过有效利用合成数据来提升模型在真实场景中的性能,本文方法为解决数据稀缺问题提供了一种可行的解决方案。未来的研究可以进一步探索如何优化模型结构和训练策略,以进一步提升在各种恶劣天气条件下的鲁棒性和准确性,从而推动智能交通系统、自动驾驶等领域的发展。

参考文献

- [1] MENG D C, LI L, LIU X J, et al. Parsing-based view-aware embedding network for vehicle re-identification [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 7103-7112.
- [2] 贺晓东,王春艳,孙昊,等. 基于局部特征与视点感知的车辆重识别算法 [J]. 仪器仪表学报, 2022, 43(10): 177-184.
HE X D, WANG CH Y, SUN H, et al. Local-features and viewpoint-aware for vehicle re-identification [J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 177-184.
- [3] XIANG X, MA Z, ZHANG L, et al. LKA-ReID: Vehicle re-identification with large kernel attention [C]. Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2025: 1-5.
- [4] GU C Y, DU H, ZHANG X Z, et al. A vehicle re-identification algorithm for long-distance small targets combining YOLOv8 object detection algorithm [J]. Frontiers in Computing and Intelligent Systems, 2025, 11(1): 53-58.
- [5] ZHENG A H, MA Z Q, SUN Y Q, et al. Flare-aware cross-modal enhancement network for multi-spectral vehicle re-identification [J]. Information Fusion, 2025, 116: 1-9.
- [6] WANG R D, GUO M, MA M. MP-GIEN: Vehicle re-identification method based on multi-view progressive graph interactive embedding network [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2024, 38(15): 2455018.
- [7] ZHOU R H, WANG Q, CAO L, et al. Dual-level viewpoint-learning for cross-domain vehicle re-identification [J]. Electronics, 2024, 13(10): 20.
- [8] CHEN W T, CHEN I H, YEH C Y, et al. SJDL-vehicle: Semi-supervised joint defogging learning for foggy vehicle re-identification [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36: 347-355.
- [9] GAO W C, CHEN Y F, CUI C R, et al. Vehicle re-identification method based on multi-task learning in foggy scenarios [J]. Mathematics, 2024, 12(14): 2247.
- [10] QU Y Y, CHEN Y Z, HUANG J Y, et al. Enhanced Pix2pix dehazing network [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2019: 8160-8168.
- [11] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. Proceedings of the European Conference on Computer Vision, 2018: 3-19.
- [13] TANG K, YANG J C, WANG J. Investigating haze-relevant features in a learning framework for image dehazing [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 2995-3000.
- [14] CHEN W T, DING J J, KUO S Y. Pms-net: Robust haze removal based on patch map for single images [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11681-11689.
- [15] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341-2353.
- [16] LIU H Y, TIAN Y H, YANG Y W, et al. Deep relative distance learning: Tell the difference between similar vehicles [C]. Proceedings of the IEEE Conference on

- Computer Vision and Pattern Recognition, 2016: 2167-2175.
- [17] LIU X C, LIU W, MEI T, et al. Provid: Progressive and multimodal vehicle re-identification for large-scale urban surveillance [J]. IEEE Transactions on Multimedia, 2017, 20(3): 645-658.
- [18] GUO H Y, ZHAO C Y, LIU Z W, et al. Learning coarse-to-fine structured feature embedding for vehicle re-identification[C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 6905-6912.
- [19] LOU Y H, BAI Y, LIU J, et al. VERI-wild: A large dataset and a new method for vehicle re-identification in the wild[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 3235-3243.
- [20] HERMANS A, BEYER L, LEIBE B. In defense of the triplet loss for person re-identification[j]. arXiv preprint arXiv:1703.07737, 2017.
- [21] GAO C Y, HU Y, ZHANG Y, et al. Vehicle re-identification based on complementary features [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 590-591.
- [22] ZHU X Y, LUO Z L, FU P, et al. VOC-ReID: Vehicle re-identification based on vehicle-orientation-camera[C]. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 602-603.
- [23] YAO Y, ZHENG L, YANG X D, et al. Simulating content consistent vehicle datasets with attribute descent [C]. European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 775-791.
- [24] HE S, LUO H, CHEN W, et al. Multi-domain learning and identity mining for vehicle re-identification [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 582-583.

作者简介



张全, 2007 年于西南石油大学获得学士学位, 2011 年于湘潭大学获得硕士学位, 2015 年于电子科技大学获得博士学位, 现为西南石油大学副教授, 主要研究方向为计算机视觉、图像处理、并行计算。

E-mail: zhangquan@swpu.edu.cn

Zhang Quan received his B. Sc. degree from Southwest Petroleum University in 2007, M. Sc. degree from Xiangtan University in 2011 and Ph. D. degree from University of Electronic Science and Technology of China in 2015, respectively. Now he is an associate professor in Southwest Petroleum University. His main research interests include computer vision, image processing and parallel computing.



刘洋溢(通信作者), 2012 年于重庆大学获得学士学位, 2016 年于中国科学院大学获得博士学位, 现为四川警察学院和智能警务四川省重点实验室副教授, 主要研究方向为计算机视觉、智能交通。

E-mail: liuyangyi_ioe@163.com

Liu Yangyi (Corresponding author) received his B. Sc. degree from Chongqing University in 2012 and Ph. D. degree from University of Chinese Academy of Sciences in 2016, respectively. Now he is an associate professor in Sichuan Police College and Intelligent Policing Key Laboratory of Sichuan Province. His main research interests include computer vision and intelligent transportation.