

面向群车协同感知的车载视频压缩算法

江子贤, 喻赛萱, 黄瑞雪, 沈鑫, 黄河清

引用本文

江子贤, 喻赛萱, 黄瑞雪, 沈鑫, 黄河清. 面向群车协同感知的车载视频压缩算法[J]. 计算机科学, 2026, 53(4): 308-317.

JIANG Zixian, YU Saixuan, HUANG Ruixue, SHEN Xin, HUANG Heqing. [Vehicle-mounted Video Compression Algorithm for Collaborative Vehicle Crowdsensing](#) [J]. Computer Science, 2026, 53(4): 308-317.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于去噪扩散模型增强的换电需求数据生成算法](#)

Denoising Diffusion Model-enhanced Algorithm for Battery Swap Demand Data Generation
计算机科学, 2026, 53(4): 163-172. <https://doi.org/10.11896/jsjcx.250600205>

[融合ByteTrack的EAP-YOLOv8无人机Marker点检测与追踪](#)

Integrate ByteTrack's EAP-YOLOv8 UAV Marker Point Detection and Tracking
计算机科学, 2026, 53(3): 266-276. <https://doi.org/10.11896/jsjcx.241100115>

[基于多目标追踪的视频无关人员自动识别](#)

Automatic Recognition of Irrelevant Individuals in Videos Based on Multi-object Tracking
计算机科学, 2025, 52(11A): 241100155-8. <https://doi.org/10.11896/jsjcx.241100155>

[适于高动态视频场景下的城市道路违停检测算法](#)

Urban Illegal On-road Parking Detection Algorithm for High Dynamic Video Scenarios
计算机科学, 2024, 51(12): 190-198. <https://doi.org/10.11896/jsjcx.231100096>

[面向绿色节能的智能网联电动车调度方法](#)

Intelligent Networked Electric Vehicles Scheduling Method for Green Energy Saving
计算机科学, 2023, 50(12): 285-293. <https://doi.org/10.11896/jsjcx.230100099>

面向群车协同感知的车载视频压缩算法

江子贤¹ 喻赛萱² 黄瑞雪¹ 沈鑫³ 黄河清⁴

1 重庆大学计算机学院 重庆 400044

2 四川财经职业学院信息学院 成都 610101

3 联勤保障部队工程大学勤务指挥系 重庆 401331

4 重庆开放大学重庆工商职业学院 重庆 400053

(202314131102T@stu.cqu.edu.cn)

摘要 群车协同感知通过大幅度拓展汽车的感知范围,能够极大地提升自动驾驶和辅助驾驶的安全性。但在传输高精度、大容量车载视频感知数据时,其仍面临时延大的问题。为了解决该问题,一些研究通过去除车载视频中包含无效信息的冗余帧,来有效降低数据传输时延。然而,由于车载视频中关键信息动态变化且特征复杂,存在表征帧间关键与冗余信息难、平衡关键信息保留率与压缩率难两个挑战。对此,提出面向群车协同感知的车载视频压缩算法,旨在兼顾信息保真与压缩效率。首先,利用目标检测和多目标追踪算法,跨视频帧提取关键信息的连续特征。然后,基于提取特征的低秩特性,将复杂的关键与冗余信息表征转化为低秩稀疏矩阵分解问题,并通过非精确增广拉格朗日法进行迭代优化,以准确提取视频的关键部分。最后,基于重庆市真实道路数据集和公共数据集 BDD100K 的部分数据对所提算法进行性能评估。实验结果表明,相比 4 种对比算法,所提算法在不同交通状况下的关键信息保留率平均提高 12.99%,且传输时间平均缩短 61.24%。

关键词: 视频压缩;群车协同感知;低秩稀疏分解;多目标追踪;增广拉格朗日法

中图分类号 TP393

Vehicle-mounted Video Compression Algorithm for Collaborative Vehicle Crowdsensing

JIANG Zixian¹, YU Saixuan², HUANG Ruixue¹, SHEN Xin³ and HUANG Heqing⁴

1 College of Computer Science, Chongqing University, Chongqing 400044, China

2 College of Information, Sichuan Vocational College of Finance and Economics, Chengdu 610101, China

3 Department of Logistics Command, Engineering University of the Joint Logistics Support Force, Chongqing 401331, China

4 College of Chongqing Technology and Business, Chongqing Open University, Chongqing 400053, China

Abstract Collaborative vehicle crowdsensing significantly extends the perception range of individual cars, thereby greatly enhancing the safety of autonomous and assisted driving. However, it also faces the challenge of high transmission latency when dealing with high-precision, large-volume sensory data such as vehicle-mounted video. To solve this problem, the data transmission delay can be effectively reduced by removing redundant frames with invalid information from vehicle-mounted video. However, the dynamics and complexity of key information in vehicle-mounted video pose significant challenges in representing key and redundant information between frames and balancing the key information retention rate and compression rate. To solve the above challenges, this paper proposes a vehicle-mounted video compression algorithm for collaborative vehicle crowdsensing, aiming to balance information fidelity and compression efficiency. Specifically, it first employs target detection and multi-target tracking algorithms to extract continuous features of key information across video frames. Then, based on the low-rank property of video features, it converts the complex key and redundant information representation into a low-rank sparse matrix decomposition problem. Furthermore, it leverages the inexact augmented Lagrangian method to solve the problem. Finally, it evaluates the performance of the proposed algorithm using the real road dataset in Chongqing city and selected data from the public dataset BDD100K. Experimental results show that the proposed algorithm achieves an average 12.99% improvement in key information retention over four baseline methods under different traffic conditions, while reducing the transmission delay by 61.24% on average compared to the original video transmission.

到稿日期:2025-04-22 返修日期:2025-07-25

基金项目:重庆市教委重点科技项目(KJZD-K202404002);合川区科技项目(HCKJ-2024-112)

This work was supported by the Chongqing Municipal Education Commission(KJZD-K202404002) and Hechuan District Science and Technology Bureau(HCKJ-2024-112).

通信作者:沈鑫(sxfrank0216@163.com)

Keywords Video compression, Collaborative vehicle crowdsensing, Low rank and sparse decomposition, Multiple targets tracking, Augmented Lagrangian method

1 引言

近年来,随着人工智能技术的迅猛发展,自动驾驶汽车逐渐成为了一种高效、便捷的出行新模式。据公安部最新统计,截止到2024年,自动驾驶汽车累计已发放1.6万辆,同时开放了3.2万千米的公共测试道路^[1]。然而,最近的商业试点部署中发生的事故引发了社会对自动驾驶汽车可靠性和安全性的担忧^[2-3]。这些事故的主要原因在于自动驾驶汽车的感知范围有限且易受环境干扰^[4],其无法准确识别并及时避让受害者。例如,大多数摄像头无法捕捉200米以外的行人和车辆^[5]。此外,道路中的车辆与周边建筑会遮挡感知视线,形成视野盲区^[6]。

为了提升单辆自动驾驶汽车对道路环境的感知能力,群车协同感知成为了一种有效的解决方案。面向自动驾驶的群车协同感知范式(见图1),自动驾驶汽车将道路感知数据(如位置、车载视频等)上传至运营商的云服务器。在云端,通过融合多个车辆的感知数据,构建全局化的道路环境感知图景,并将生成的道路全景图卸载至各个车辆。自动驾驶群车协同感知利用视角共享,显著扩展了单辆汽车的感知范围^[7]。

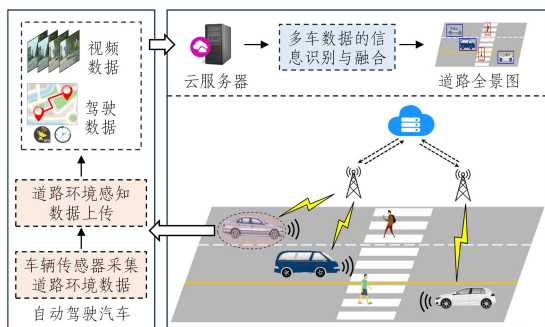


图1 自动驾驶群车协同感知

Fig. 1 Cooperative perception of autonomous driving

在自动驾驶群车协同感知共享的数据中,车载视频包含丰富的环境信息,是目标检测和测行为预测等下游任务的基础。然而,在有限的网络带宽限制下,传输高分辨率车载视频数据面临严重的时延问题^[8]。这一问题直接影响了数据处理的实时性,可能导致云端生成的融合感知结果滞后于实际交通状况,从而限制群车协同感知在实际场景中的有效性和可靠性。因此,降低数据传输时延,成为当前自动驾驶群车协同感知亟待解决的问题之一。

本文提出了一种降低自动驾驶群车协同感知传输时延的方案,该方案通过识别并去除传输视频中包含重复信息的冗余帧,来减少传输数据量,进而降低数据的传输时延。然而,实现上述方案需要应对以下两方面的挑战。

1) 关键信息完整性与压缩率平衡难。在视频压缩过程中,过度去除视频的帧间冗余可能会破坏关键信息的连续性和完整性,从而导致后期云端分析丢失重要的目标信息;而如果冗余去除不足,则会导致视频压缩效果不显著,影响视频的传输效率。因此,平衡关键信息的完整性与压缩率极具挑战性。

2) 帧间关键与冗余信息表征难。视频压缩方案的核心在于关键信息与冗余信息的区分。然而,帧间信息复杂多样,既包含动态时变的关键信息(如运动的车辆和行人),又涵盖了静态低变的冗余信息(如道路、建筑等),且两类信息相互耦合关联。因此,有效表征并分离帧间的关键与冗余信息十分困难。

为了应对上述挑战,本文提出面向群车协同感知的车载视频压缩算法。具体地,针对关键信息完整性与压缩率平衡的挑战,提出基于多目标感知与环境融合的特征提取算法。该算法首先采用目标检测和多目标追踪技术,跨视频帧提取关键目标的连续特征;然后将其与环境信息融合,构建完备的车载视频特征矩阵。基于该特征矩阵,在后续去除帧间冗余的过程中,能够在最大程度保留关键信息完整性的同时,实现高效压缩。针对帧间关键与冗余信息表征难的挑战,首先通过奇异值分解(Singular Value Decomposition, SVD)分析了视频特征矩阵的低秩特性。然后,基于上述分析结果,借助低秩稀疏分解方法将特征矩阵分解为低秩部分和稀疏部分,其分别对应视频中重复不变的冗余信息和动态变化的关键信息,从而将复杂的关键与冗余信息表征转化为低秩稀疏矩阵分解问题。最后,提出基于非精确增广拉格朗日法的特征驱动视频压缩算法,通过对低秩与稀疏部分的联合迭代优化,确保在保留关键信息的同时,最大程度地减少帧间冗余。

综上所述,本文主要有以下两方面的贡献。

1) 提出面向群车协同感知的车载视频压缩算法。该方法面向感知任务,通过目标检测和多目标追踪技术提取车载视频特征,并结合帧间结构冗余建模将关键信息表征转化为低计算复杂性的低秩稀疏矩阵分解问题,最后利用非精确增广拉格朗日法进行迭代优化,在有效保留关键信息的同时,最小化帧间冗余,从而有效降低感知数据的传输负载。

2) 基于重庆市真实道路数据集及公共数据集 BDD100K 的部分数据,对所提算法进行了全面且深入的实验评估。其中,重庆市数据集包含233千米的车辆轨迹,覆盖区域面积达125平方千米。结果表明,所提算法在不同交通状况下的关键信息保留率相比4种对比算法平均提升12.99%,且传输时间平均缩短61.24%。此外,该算法在不同道路类型和视频分辨率下的关键信息保留率平均分别达到84.33%和80.87%。

本文第2章介绍国内外相关工作的研究现状;第3章分析研究动机;第4章详细介绍面向群车协同感知的车载视频压缩算法的框架;第5章进行实验评估并展示实验结果;最后总结全文并展望未来研究方向。

2 相关工作

为保障自动驾驶群车协同感知的高效运行,并促进智慧城市的进一步发展,大量研究工作聚焦于群车协同感知的优化和边缘端视频的压缩处理,以降低传输时延。

1) 群车协同感知

随着自动驾驶汽车和传感器技术的迅速发展,群车协同感知这一概念受到了广泛关注。相比于传统的单车感知,群车协同感知不仅具有更高的灵活性,还能覆盖更广泛的区域^[9-10]。当前,自动驾驶群车协同感知的相关研究主要聚焦于对驾驶环境的感知优化^[11]。例如,Duan等^[12]提出的基于PVRCNN视觉特征的环境感知框架,结合V2X通信提升了自动驾驶汽车在交叉口场景下的感知能力。为进一步扩大感知范围,Zhang等^[13]构建了基础设施增强系统。该系统将车辆采集的图像与点云上传至路侧设施进行融合处理,并通过智能交通云实现大范围协同感知。在此过程中,如何在云端实现高效精确的数据融合已成为群车协同感知的关键问题之一^[14]。例如,Zhang等^[15]通过将多辆自动驾驶汽车的点云数据与图像数据进行融合,显著提升了3D物体检测的性能;Danapal等^[16]则将点云生成的伪图像与RGB图像拼接起来作为模型的输入,提高了道路物体的检测精度。然而,群车协同感知需要在车辆与云端之间持续进行大规模的数据传输,这导致车载网络面临巨大的负载压力^[17-18]。为此,部分研究致力于在有限的传输带宽下,通过优化资源分配策略来提升系统的整体性能。例如,He等^[19]通过结合图神经网络和多智能体强化学习的方法,有效地优化了群车协同感知中的频谱利用效率;Aoki等^[20]利用深度强化学习优化车辆数据传输选择策略,从而有效缓解了网络负载压力。

2) 边缘端视频压缩处理

随着物联网的快速发展,边缘设备日益具备强大的图像处理能力,使得在边缘端进行视频压缩成为可能,从而有效减少数据量并降低传输延迟。对边缘视频进行高效编码是减小视频传输体积的重要手段。例如,Lu等^[21]利用光流网络和自动编码器学习像素级运动信息,通过在速率和失真率之间进行联合优化,实现高效的视频编码;Cohen等^[22]则提出一种新型轻量级压缩技术,结合熵约束量化器算法对神经网络层的激活信息进行编码。除高效编码外,有研究尝试通过压缩边缘图像来减小视频传输体积^[23]。例如,Zhang等^[24]提出的结合注意力机制与压缩感知的方法,通过识别感兴趣区域内的关键像素并对其采样,生成紧凑的精细化特征层;Shaham等^[25]设计的误差度量方法,通过对输入视频图像进行轻微变形来提高其可压缩性。此外,还有研究聚焦于通过分离视频图像中的前景与背景,对不同区域采用差异化的压缩策略。例如,Chen等^[26]提出的基于视觉相关性的像素级纹理分割方法,在保障视觉质量的同时实现了高效编码与传输压缩;Sengar等^[27]提出的基于自适应粒子群优化的运动分割视频压缩方法,通过补偿前景运动来实现更高效的压缩。

综上,现有视频压缩方法大多侧重于像素级别的编码与重建效率,强调压缩率与图像质量的平衡。然而,在群车协同感知场景中,数据压缩的目标已不再局限于还原原始视频,而是更侧重于语义信息的保留与高效传输。因此,本文关注面向感知任务的语义冗余压缩方法,通过结构化建模帧间冗余信息与关键信息,识别并去除冗余帧,从而在保障感知语义完整性的前提下,有效降低数据传输时延。

3 研究动机

3.1 问题发现

本文通过实地实验来探究群车协同感知中的数据传输时延问题,发现占据传输数据主体的高分辨率车载视频是影响时延的主要因素之一。具体地,利用开发的数据采集APP采集了不同时间的车载视频并将其上传至云端,同时记录了上传所消耗的时间和数据流量。从图2可以看出,随着上传视频数据量的增加,所消耗的流量和传输时间均呈现出快速上升的趋势。例如,在固定带宽的移动网络环境下,上传一段分辨率为1080P、帧率为30FPS的5min视频,大约需要3min并消耗723MB的数据流量,这极大地限制了群车协同感知的实时性。因此,需要对车载视频数据进行压缩,以降低数据传输时延。




图2 视频数据传输消耗

Fig. 2 Video data transmission cost

3.2 机遇探究

为了压缩车载视频数据,解决群车协同感知中的数据传输时延问题,深入分析了上传视频数据的特征。使用结构相似度(Structural Similarity, SSIM)对视频连续帧之间的视觉特征关系进行分析。SSIM是一种衡量两幅图像相似度的常用方法,它综合考虑了图像的亮度、对比度和结构信息,能够准确反映两幅图像的视觉质量。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (1)$$

其中, x 和 y 表示两幅图像, μ_x 和 μ_y 分别表示它们的平均亮度, σ_x 和 σ_y 分别表示它们的标准差, σ_{xy} 表示它们的协方差; C_1 和 C_2 是常数。

如图3所示,连续视频帧之间具有较高的相似性。例如,在第80至160帧和第180至250帧之间,相邻帧的结构相似度超过70%。




图3 车载视频帧间相似度

Fig. 3 Inter-frame similarity of in-vehicle video

根据上述发现,可以推断车载视频中存在大量相似度较高的冗余帧。基于这一点,本文提出通过去除车载视频中高

度相似的冗余帧来减少传输数据量,从而有效降低数据传输时延的方案。

4 面向群车协同感知的车载视频压缩算法

为实现对车载视频的低时延传输,本文提出面向群车协同感知的车载视频压缩算法。该算法旨在保留视频关键信息的前提下,尽可能压缩视频的体积,从而降低传输时延。如图4所示,该算法由3部分组成:基于多目标感知与环境融合的特征提取,基于低秩稀疏矩阵的问题建模,以及基于非精确增广拉格朗日法的特征驱动视频压缩。

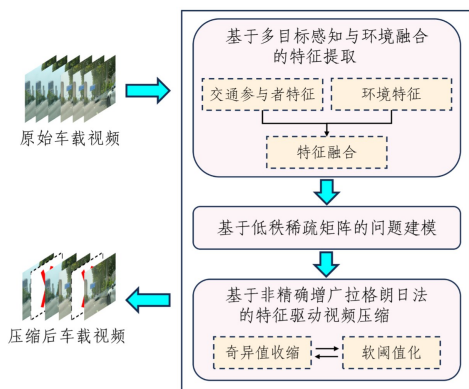


图4 算法架构

Fig. 4 Architecture of the proposed algorithm

1) 基于多目标感知与环境融合的特征提取(见4.1节)。采用Yolov5目标检测算法和SORT追踪算法,对车载视频中的交通参与者(如车辆、行人等)进行检测与追踪,从而提取其在连续帧中的关键特征。然后,将这些目标特征与对应帧的环境特征融合,最终构建出完整的车载视频特征矩阵。

2) 基于低秩稀疏矩阵的问题建模(见4.2节)。通过分析提取的视频特征矩阵,发现其具有低秩特性,该特性通常表明数据中存在冗余结构。基于此特性,利用低秩稀疏分解方法将特征矩阵分解为低秩部分和稀疏部分,其分别对应视频中重复不变的冗余信息和动态变化的关键信息,从而将复杂的键与冗余信息表征转化为低秩稀疏矩阵分解问题。

3) 基于非精确增广拉格朗日法的特征驱动视频压缩(见4.3节)。为解决基于低秩稀疏矩阵的问题建模中提出的问题,提出了一种基于非精确增广拉格朗日法的求解算法。该算法迭代优化特征矩阵的低秩部分和稀疏部分,直至满足预设的终止条件,从而能够准确识别车载视频中的冗余帧,实现帧间冗余的有效去除。

4.1 基于多目标感知与环境融合的特征提取

为提取车载视频每帧的关键特征,首先对交通参与者进行检测与追踪。考虑到实时性与计算资源的限制,采用基于SORT的轻量级多目标追踪算法,实现检测驱动的高效追踪。同时,本文还提取每帧环境特征,并与交通参与者特征融合,形成完整的车载视频特征。

1) 交通参与者特征。为从车载视频中高效提取交通参与者的检测框,选用Yolov5作为目标检测器,以兼顾检测精度和效率。基于检测结果,采用SORT算法实现多目标追踪。具体地,先将每个检测框初始化为独立追踪器,并通过卡尔曼

滤波器^[28]预测其状态,生成下一帧的预测框。最后,利用匈牙利算法^[29],基于IoU(Intersection over Union)在检测框和预测框之间进行匹配,并设定IoU阈值以降低误匹配风险。

在完成对交通参与者的检测和追踪后,可以获得每个目标在图像中的位置信息及其追踪序号。首先,计算图像中每个追踪目标在空间上的相对分布密度图 r_i^f 。

$$r_i^f = \sum_{x \in I} c_i^f \cdot \delta(x - d_i^f) * G_{\sigma_i}(x) \quad (2)$$

其中, I 表示第 f 帧图像中所有像素点的坐标集合; c_i^f 和 d_i^f 分别表示第 f 帧中追踪目标 i 的置信度和中心坐标; $G_{\sigma_i}(x)$ 表示二维高斯核; $\delta(x - d_i^f)$ 表示脉冲响应函数。

接下来,将图像中所有追踪目标的密度图分别进行全局平均池化,并基于帧序号和追踪序号对池化后的密度图进行拼接操作,得到第 f 帧的交通参与者密度分布图 T_f 。

$$T_f = [r_1^f \ r_2^f \ \dots \ r_n^f] \quad (3)$$

其中, n 表示整个视频中所有的追踪序号。对于图像中没有出现或消失的追踪目标,使用零元素进行填充。

最后,将拼接得到的交通参与者密度分布图 T_f 作为第 f 帧的交通参与者特征。为提升文章的可读性,表1列出了本文主要的数学符号及其说明。

表1 主要数学符号说明

Table 1 Explanation of main mathematical symbols

Symbols	Meaning of symbols
c_i^f, d_i^f	第 f 帧中追踪目标 i 的置信度与中心坐标
r_i^f	第 f 帧中追踪目标 i 的密度图
T_f, E_f	第 f 帧的交通参与者特征与环境特征
S	车载视频的特征矩阵
M, N	特征矩阵的低秩部分与稀疏部分
$\mathcal{F}_{ori}, \mathcal{F}_{out}$	视频压缩算法的输入与输出帧序列

2) 环境特征。在车辆行驶过程中,车载视频中的交通参与者数量、位置与场景会不断变化。因此,需要结合交通参与者特征与环境特征共同构建视频特征。环境特征通过提取视频图像的频域与结构信息生成。

在频域信息提取中,使用二维离散余弦变换将图像转为频域,提取低频区域以表征图像整体轮廓,并将其量化(高于则均值为1,反之则为0)作为帧的低频特征。

在结构信息提取中,将第 f 帧图像均匀划分为多个矩形区域,然后计算各区域的局部亮度和对比度,并将其分别拼接为亮度特征和对比度特征。最后,将低频信息、亮度和对比度这3类特征合并为第 f 帧的环境特征,记作 E_f 。

3) 特征融合。基于上述特征提取流程,可为车载视频的每帧图像构建对应的特征向量。具体地,对于原始车载视频帧序列 $\mathcal{F}_{ori} = \{K_1, K_2, \dots, K_H\}$,其特征向量可以表示为 $\{X_1, X_2, \dots, X_H\}$,其中向量 X_H 由交通参与者特征 T_H 和环境特征 E_H 组成。如图5所示,这些特征向量合并后生成车载视频的特征矩阵 S 。

$$S = \begin{pmatrix} X_1 \\ X_2 \\ \dots \\ X_H \end{pmatrix} = \begin{bmatrix} x_{1,1} & x_{1,2} & \dots & x_{1,Q} \\ x_{2,1} & x_{2,2} & \dots & x_{2,Q} \\ \dots & \dots & \ddots & \dots \\ x_{H,1} & x_{H,2} & \dots & x_{H,Q} \end{bmatrix} \quad (4)$$

其中, H 表示车载视频的总帧数; Q 表示单帧特征向量的最大长度,对于长度不足的行,使用零元素进行填充。

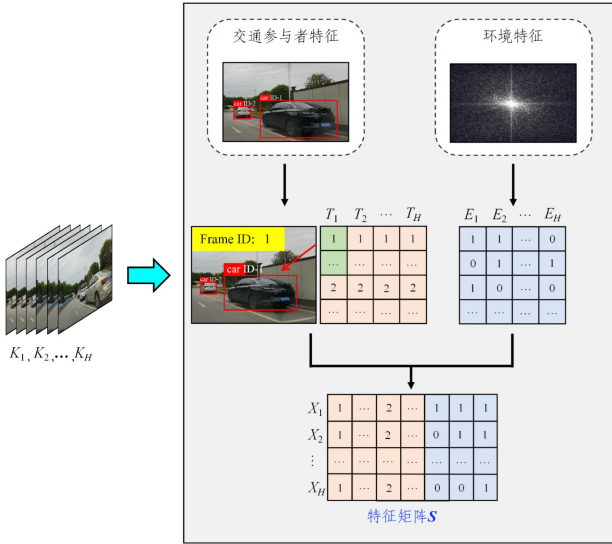


图5 视频特征矩阵的构建

Fig. 5 Construction of video feature matrix

4.2 基于低秩稀疏矩阵的问题建模

为验证车载视频特征矩阵 S 的低秩特性,对其采用奇异值分解。

$$S = U\Sigma V^T \quad (5)$$

其中, U 和 V 均为正交矩阵,每个列向量都是 SS^T 的特征向量; Σ 为对角矩阵,主对角线上的非零元素表示为 $\{\sigma_1, \sigma_2, \dots, \sigma_r\}$, 这些值称为矩阵 S 的奇异值。

对多段不同场景下的车载视频特征矩阵进行 SVD 分解实验,结果如图 6 所示。在所有视频场景中,前 10 个奇异值的累计贡献率约占所有奇异值的 85%。根据矩阵低秩性原理^[30],如果矩阵的奇异值权重集中在少数元素上,则该矩阵可以近似为低秩矩阵。因此,车载视频特征矩阵在绝大多数场景下均表现出明显的低秩性。这一现象反映了车载视频在较长时间窗口内,背景场景通常保持稳定,而前景目标(如车辆、行人)在帧间发生局部变化,从而使视频特征矩阵整体呈现低秩结构,同时在局部具备稀疏扰动。




图6 不同场景下的视频特征矩阵低秩分析

Fig. 6 Low-rank analysis of video feature matrices in different scenes

根据低秩矩阵分解理论^[31],若特征矩阵 S 具备低秩特性,则可将其分解为低秩部分 M 和稀疏部分 N 。其中, M 表征视频中重复的冗余信息, N 则对应具有判别性的关键信息。由此,车载视频中的关键与冗余信息表征可转化为低秩稀疏分解问题。

$$\min_{M, N} \text{rank}(M) + \gamma \|N\|_0 \quad (6)$$

$$\text{s. t. } S = M + N \quad (7)$$

其中, $\text{rank}(\cdot)$ 为用于计算矩阵的秩的函数,即非零奇异值的数量; $\|\cdot\|_0$ 表示用 l_0 范数衡量矩阵的稀疏性; γ 为权重系数。通过求解式(6)和式(7),可以提取特征矩阵中的关键信息即稀疏部分,并将其映射回原始视频,以最大程度地去除帧间冗余。不同于依赖像素差异与运动估计的传统压缩方法难以应对车载视频中复杂的时空变换,低秩稀疏矩阵建模从语义结构层面出发,能够更有效地实现冗余信息与关键信息的区分。另一方面,相比于近年来流行的深度学习压缩方法,低秩稀疏矩阵建模无需大规模训练,模型结构轻量,更适用于群车协同感知等实时性和资源约束要求较高的应用场景。

4.3 基于非精确增广拉格朗日法的特征驱动视频压缩

由于 $\text{rank}(\cdot)$ 函数和 l_0 范数具有非凸性和非光滑性,因此上述问题为 NP-hard 问题。为了求解该问题,可以分别使用核范数 $\|\cdot\|_*$ 和 l_1 范数来近似替代 $\text{rank}(\cdot)$ 和 l_0 范数,从而将原本的 NP-hard 问题转化为可处理的最优化问题。

为解决该优化问题,本文提出基于非精确增广拉格朗日法^[32]的特征驱动视频压缩方法。该方法以特征矩阵为基础,通过对低秩部分与稀疏部分进行迭代优化,识别出冗余帧与关键帧,并据此去除视频序列中的冗余帧,从而在保留语义完整性的同时有效压缩视频内容。具体地,通过构造增广拉格朗日函数,可以将该问题转化为:

$$(M_{k+1}^*, N_{k+1}^*) = \arg \min_{M, N} L(M, N, Y_k, \mu_k) \quad (8)$$

其中,令 $D = S - M - N$,则增广拉格朗日函数 $L(M, N, Y, \mu)$ 可以表示为:

$$\|M\|_* + \gamma \|N\|_1 + \langle Y, D \rangle + \frac{\mu}{2} \|D\|_F^2 \quad (9)$$

其中, $\langle Y, D \rangle$ 表示 Y 与 D 的内积; Y 表示拉格朗日乘子矩阵,用于将约束条件合并到目标函数中; μ 为惩罚参数,用于控制约束条件对目标函数的影响。

该算法包括两个关键步骤。

1) 奇异值收缩。给定稀疏部分 N 后,通过式(10)来更新低秩部分 M :

$$M_{k+1} = \mathcal{D}_{\frac{\mu_k}{2}} \left(S - N_{k+1} + \frac{Y_k}{\mu_k} \right) \quad (10)$$

其中, $\mathcal{D}(\cdot)$ 为奇异值收缩算子,且 $\mathcal{D}_\tau(R) = U S_\tau(\Sigma) V^T$; U, Σ 和 V^T 是 R 通过 SVD 分解得到的。 $S_\tau(\cdot)$ 为软阈值算子,其定义如下:

$$S_\tau(\varphi) = \begin{cases} \varphi - \tau \cdot \text{sign}(\varphi), & |\varphi| > \tau \\ 0, & |\varphi| \leq \tau \end{cases} \quad (11)$$

其中, τ 是收缩阈值,并且 $\tau > 0$ 。具体是对矩阵或向量中的每个元素应用该算子。

2) 软阈值化。给定低秩部分 M 后,通过式(12)来更新稀疏部分 N :

$$N_{k+1} = \mathcal{S}_{\frac{\mu_k}{2}} \left(S - M_{k+1} + \frac{Y_k}{\mu_k} \right) \quad (12)$$

其中, $\mathcal{S}_{\frac{\mu_k}{2}}(\cdot)$ 为式(11)中的软阈值算子。

在上述两个步骤的每次迭代结束后,按照 $Y_{k+1} = Y_k + \mu_k(S - M_{k+1}^* - N_{k+1}^*)$ 的更新规则对拉格朗日乘子矩阵进行更新。迭代过程终止须满足以下任一条件:(1)达到设定的最大迭代次数;(2)第 $k+1$ 次迭代所得的低秩部分 M 和稀疏部分

N 的分解误差不超过设定的误差阈值 ϵ_0 。最后,通过计算优化后的稀疏部分 N 中每帧特征的稀疏性评分来衡量帧的变化程度,并以稀疏性评分的平均值为阈值,筛选出稀疏性不小于阈值的帧。这些帧通常对应显著的运动或场景切换,能够有效表示视频的主要动态信息。

综上所述,本文提出面向群车协同感知的车载视频压缩算法,如算法 1 所示。该算法以原始车载视频帧序列 \mathcal{F}_{ori} 作为输入,最终输出压缩后的视频帧序列 \mathcal{F}_{out} 。具体地,首先,基于 4.1 节的视频特征提取模块,提取视频帧的交通参与者特征和环境特征,并将其融合为特征矩阵 S (第 2 行)。然后,利用非精确增广拉格朗日法迭代优化 S 的低秩部分 M 和稀疏部分 N (第 3-9 行)。最后,根据优化后的 N 中每帧特征的稀疏性生成压缩后的视频帧序列 (第 10-11 行)。

算法 1 面向群车协同感知的车载视频压缩算法

输入:原始车载视频帧序列 $\mathcal{F}_{ori} = \{K_1, \dots, K_H\}$

输出:压缩后的视频帧序列 $\mathcal{F}_{out} = \{K_i, \dots, K_j\}, 1 \leq i, j \leq H$

1. 初始化 $\mathcal{F}_{out} \leftarrow \emptyset$;
2. $S = \text{FeatureExtract}(\mathcal{F}_{ori})$;
3. 令 $k=0; \mu_0 > 0; \rho > 1; Y_0 = 0; N_0 = 0$
4. while 达到迭代结束条件 do
5. 给定 N , 根据式(10)计算 M_{k+1} ;
6. 给定 M , 根据式(12)计算 N_{k+1} ;
7. $Y_{k+1} = Y_k + \mu_k(S - M_{k+1}^* - N_{k+1}^*)$;
8. $\mu_{k+1} = \rho \mu_k; k = k + 1$;
9. end while
10. $\mathcal{F}_{keep} = \{K_i, \dots, K_j\} \leftarrow \text{MappingFrame}(N) / * K_i$ 为保留的关键帧 $*/$;
11. 更新 $\mathcal{F}_{out} \leftarrow \mathcal{F}_{out} \cup \mathcal{F}_{keep}$ 。

5 实验评估

5.1 数据集和实验方法

5.1.1 实验数据集

本文使用重庆市真实道路数据集以及公共数据集 BDD100K 的部分数据^[33]进行实验评估。其中,重庆市数据集主要由不同分辨率下帧率为 30 FPS 的车载视频构成。同时,每个车载视频均详细记录了视频的时间戳(采样间隔为 1s)、GPS 坐标等关键数据。表 2 列出了本文所使用的重庆市道路数据集的概要说明。此外,为进一步验证本文算法在多种交通场景下的适应性与泛化能力,额外从 BDD100K 数据集中选取了 926 条视频数据作为补充,其主要涵盖城市主干道、高速公路等典型道路类型。

表 2 实验数据集说明

Table 2 Explanation of experimental dataset

Items	Contents & meaning
车载视频	240~1080 P, 30 FPS
时间戳记录	Unix 时间戳(s), 如: 1721 205387
GPS 坐标	数据格式: (longitude, latitude)
加速度数据	数据格式: (Acc-x, Acc-y, Acc-z)
陀螺仪数据	数据格式: (Gyr-x, Gyr-y, Gyr-z)

5.1.2 实验方法和参数设置

为了评估面向群车协同感知的车载视频压缩算法的性能,在实验中综合考虑了不同交通状况、不同道路类型以及不同车载视频分辨率对算法性能的影响。此外,在实验参数

设置方面,本文将权重系数 γ 设置为 0.1,算法最大迭代次数默认设置为 1000,迭代终止条件中的误差阈值 ϵ_0 默认设置为 $(\|M_0\|_1 + \|N_0\|_1)/40$,以自适应地平衡视频压缩过程中的收敛速度与有效性。

为全面评估所提算法的性能,将其与以下 4 种性能不同的视频压缩算法进行对比。

1) CTS^[34]: 利用轮廓波变换在多尺度和多方向上提取视频帧特征,并在变换域内计算结构相似性指数,以识别帧间冗余区域,从而实现冗余帧的有效压缩。

2) SCFD^[35]: 基于分段聚类 and 帧间差异的视频压缩算法,通过计算帧间差分对视频进行自适应的时段划分,并在各时段内利用聚类策略高效去除低变化区域。

3) OMIE^[36]: 基于光流和互信息熵的视频压缩算法,首先选取光流变化剧烈的帧作为候选关键帧,然后结合互信息熵进一步去除帧间的信息冗余。

4) RAN: 随机视频帧压缩算法,在每 10 帧中随机选择 5 至 6 帧进行存储。

本文在实验中采用两种性能评估指标: 1) 关键信息保留率,即压缩后视频中关键交通参与者数量占原始视频中关键交通参与者数量的比例,用于衡量压缩后视频的语义信息完整性; 2) 平均传输时间,即压缩后视频从车辆端传输到云服务器的平均时延,用于评估视频压缩在降低网络传输负担方面的实际效果。所有实验均在相同网络环境和带宽条件下进行,以确保可比性。

5.2 实验结果

5.2.1 算法总体性能评估

1) 不同交通状况下的性能

依据道路上交通参与者的流量,将交通状况划分为空旷、正常和拥挤 3 种类型。实验结果如图 7 所示,本文算法在不同交通状况下的关键信息保留率均优于其他 4 种对比算法。具体地,在交通空旷场景下,本文算法的关键信息保留率达到了 92.12%,相比之下,CTS, SCFD, OMIE 和 RAN 算法分别降低了 5.88 个百分点, 7.68 个百分点, 13.76 个百分点和 18.62 个百分点。在交通正常和拥挤场景下,本文算法的关键信息保留率分别为 78.69% 和 75.16%。随着交通流量的增加,本文算法的关键信息保留率逐渐下降。产生这一现象的主要原因在于,交通参与者数量的增加,使得全面准确地追踪目标状态变得困难,导致视频特征提取出现误差,从而影响后续的视频压缩。平均传输时间方面的实验结果如图 8 所示, 5 种压缩算法均显著缩短了视频的传输时延。具体地,在不同交通状况下,本文算法的传输时间相比原始视频平均降低了 61.24%。

图 9 展示了在正常交通状况下,车载视频经过不同压缩算法后关键交通参与者的保留情况。其中,第 1 行对原始视频中实际存在的关键交通参与者进行了标注,其余各行为不同压缩算法处理后保留的关键交通参与者。结果表明,对比算法由于未能充分关注视频中出现的 key 目标(如路边行人),导致这些目标被错误删除。而使用本文算法压缩后的视频,保留的关键交通参与者数量与原始视频标注数量基本保持一致。




图 7 不同交通状况对关键信息保留率的影响

Fig. 7 Impacts of different traffic conditions on the retention of key information




图 8 不同交通状况对平均传输时间的影响

Fig. 8 Impacts of different traffic conditions on the average transmission time



图 9 关键交通参与者保留结果示意图

Fig. 9 Diagram of key transportation participant retention results

2) 不同道路类型下的性能

本文选取城市主干道、道路交叉口以及高速公路开展实验评估。实验结果如图 10 所示,本文算法在 3 种类型道路上的关键信息保留率均优于其他 4 种对比算法。




图 10 不同道路类型对关键信息保留率的影响

Fig. 10 Impacts of different road types on the retention of key information

具体地,在城市主干道上,本文算法的关键信息保留率达到了 87.77%,相比之下,CTS,SCFD,OMIE 和 RAN 算法的保留率分别降低了 3.39 个百分点、6.98 个百分点、6.48 个百分点和 12.95 个百分点。在道路交叉口和高速公路上,本文算法的关键信息保留率略有下降,分别为 84.17% 和 81.04%。这主要是由于交叉口区域存在大量遮挡以及高速公路上车速过快,导致视频特征提取不准确,从而在压缩过程中遗漏了关键信息。平均传输时间方面的实验结果如图 11

所示。具体地,在 3 种类型道路上,本文算法的传输时间相比原始视频平均缩短了 78.67%,显著缩短了传输时延。




图 11 不同道路类型对平均传输时间的影响

Fig. 11 Impacts of different road types on the average transmission time

3) 不同车载视频分辨率下的性能

车载视频分辨率涵盖 240P,480P,720P 和 1080P。实验结果如图 12 所示,本文算法在所有分辨率下的关键信息保留率均优于其他 4 种对比算法。其中,在 1080P 和 720P 分辨率下,本文算法的关键信息保留率保持在 85% 左右,整体表现较为稳定。然而,当分辨率下降至 480P 和 240P 时,本文算法的关键信息保留率分别降至 77.93% 和 74.03%。这一下降趋势主要是由于视频分辨率的降低导致画面质量下降,进而影响了特征提取的准确性。平均传输时间方面的实验结果如图 13 所示,本文算法相较于传输原始视频,在不同视频分

分辨率下的平均传输时间缩短了 54.34%。




图 12 不同视频分辨率对关键信息保留率的影响

Fig. 12 Impacts of different video resolutions on the retention of key information




图 13 不同视频分辨率对平均传输时间的影响

Fig. 13 Impacts of different video resolutions on the average transmission time

5.2.2 算法时间开销评估

为了全面评估算法的时间开销,针对主要耗时阶段进行了测试分析,实验结果如图 14 所示。其中,经算法压缩后的车载视频上传时间 T_{is} 占总时间的 54.83%;而算法的核心阶段,包括交通参与者特征提取 T_{tfc} 、环境特征的提取 T_{efc} 和迭代优化 T_{opt} 仅占据了较小比例的总时间。这些结果表明,本文算法的设计具备轻量级特性,能够适应计算能力受限的车辆环境。




图 14 各阶段时间开销占比

Fig. 14 Proportion of time cost in each stage

5.2.3 算法参数评估

为探究权重系数阈值 γ 对本文算法性能的影响,在多个不同取值下进行了测试,分析其对关键信息保留率和压缩率的影响趋势。如图 15 所示,随着 γ 的增大,算法的关键信息保留率逐渐下降,而压缩率则不断提高。这是由于较大的 γ 会导致稀疏矩阵保留更少的稀疏元素,从而将更多的关键信息误判为冗余信息。这种方式尽管能够显著压缩车载视频的体积,但也会不可避免地引发更多关键信息的丢失。为在关键信息保留与压缩效率之间取得平衡,将 γ 设置为 0.1。在此参数下,

本文算法的关键信息保留率为 86.24%,压缩率为 50.64%。




图 15 权重系数阈值的影响

Fig. 15 Impacts of weight coefficient threshold

6 总结与展望

6.1 工作总结

本文提出一种面向群车协同感知的车载视频压缩算法,以解决自动驾驶群车协同感知中的数据传输时延问题。具体地,首先分析车载视频中普遍存在的大量冗余帧,挖掘压缩优化空间。其次,利用目标检测与多目标追踪技术提取关键信息特征,并将其环境特征融合为特征矩阵。然后,基于低秩矩阵分解理论,将特征矩阵分解为低秩部分和稀疏部分,从而将复杂的关键与冗余信息表征建模为低秩稀疏矩阵分解问题。最后,通过非精确增广拉格朗日法优化求解,在最大程度去除帧间冗余的同时保留关键信息。基于重庆市道路数据集与 BDD100K 的部分数据进行评估,结果表明,所提算法在不同交通状况、道路类型和视频分辨率下均优于对比算法,在显著提升关键信息保留率的同时,有效缩短了平均传输时间,验证了其在提升数据传输效率方面的有效性。

6.2 研究展望

在未来的研究工作中,还需进一步改进和完善本文算法,主要包括以下 3 个方面。1) 本文仅提出面向群车协同感知的车载视频压缩算法,并验证了算法的可行性,未来将基于现有算法,从视频图像内容的角度进行更深入的压缩^[37],以进一步提高压缩效率。2) 本文当前主要针对车载视频中帧间冗余建模进行压缩,未来将结合视频浓缩技术,探索压缩与浓缩的融合策略,进一步提升对关键信息的提取能力与压缩效率,推动在群车协同感知场景下实现更高效的任务导向视频传输。3) 隐私保护是群车协同感知中的关键问题,本文目前尚未涉及此部分内容,未来将全面考虑数据传输过程中的用户隐私保护问题,例如采用差分隐私等机制^[38]。

参考文献

- [1] 人民网. 公安机关已累计发放自动驾驶汽车测试号牌 1.6 万张 [EB/OL]. (2024-08-27) [2024-12-17]. https://www.gov.cn/lianbo/bumen/202408/content_6970854.htm.
- [2] 澎湃新闻. 蔚来 31 岁车主车祸身亡背后的自动驾驶盲区 [EB/OL]. (2021-08-18) [2024-12-17]. https://www.thepaper.cn/newsDetail_forward_14087952.
- [3] NTSB. Collision Between Vehicle Controlled by Developmental Automated Driving System and Pedestrian [EB/OL]. (2018-03-18) [2024-12-17]. <https://www.nts.gov/investigations/Ac->

- cidentReports/Reports/HAR1903.pdf.
- [4] ZHANG Q, ZHANG X, ZHU R, et al. Robust Real-Time Multi-Vehicle Collaboration on Asynchronous Sensors[C]// Proceedings of the International Conference on Mobile Computing and Networking. ACM, 2023:1-15.
- [5] 智能汽车网. 自动驾驶传感器能“看”多远 [EB/OL]. (2021-08-24) [2024-12-20]. <https://www.smartautoclub.com/p/10250/>.
- [6] XIAO Z, SHU J, JIANG H, et al. Toward Collaborative Occlusion-Free Perception in Connected Autonomous Vehicles[J]. IEEE Transactions on Mobile Computing, 2024, 23(5):4918-4929.
- [7] CHAN Q, TANG S, YANG Q, et al. Cooper: Cooperative Perception for Connected Autonomous Vehicles Based on 3D Point Clouds[C]// Proceedings of the IEEE International Conference on Distributed Computing Systems. IEEE, 2019:514-524.
- [8] JIANG X, YU F R, SONG T, et al. Intelligent Resource Allocation for Video Analytics in Blockchain-Enabled Internet of Autonomous Vehicles With Edge Computing[J]. IEEE Transactions on Network Science and Engineering, 2020, 7(4):2205-2218.
- [9] XIANG C, ZHANG Z, QU Y, et al. Edge Computing-Empowered Large-Scale Traffic Data Recovery Leveraging Low-Rank Theory[J]. IEEE Transactions on Network Science and Engineering, 2020, 7(4):2205-2218.
- [10] ZHOU E, LI Z, LIU D, et al. Balancing Electric Scooter Battery Swapping Network by Spatio-Temporal Recommendation[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12):21315-21326.
- [11] HAN Y, ZHANG H, LI H, et al. Collaborative Perception in Autonomous Driving: Methods, Datasets, and Challenges[J]. IEEE Intelligent Transportation Systems Magazine, 2023, 15(6):131-151.
- [12] DUAN X, JIANG H, TIAN D, et al. V2I Based Environment Perception for Autonomous Vehicles at Intersections[J]. China Communications, 2021, 18(7):1-12.
- [13] ZHANG K, LIU Y, ZHANG W, et al. π -Learner: A Lifelong Roadside Learning Framework for Infrastructure Augmented Autonomous Driving[J]. Computer, 2022, 55(6):30-39.
- [14] XIANG C, CHENG W, LIN C, et al. LSTAlloc: A Driver-Oriented Incentive Mechanism for Mobility-on-Demand Vehicular Crowdsensing Market[J]. IEEE Transactions on Mobile Computing, 2023, 23(4):3106-3122.
- [15] ZHANG Y, LIU K, BAO H, et al. PMPF: Point-Cloud Multiple-Pixel Fusion-Based 3D Object Detection for Autonomous Driving[J]. Remote Sensing, 2023, 15(6):1580-1603.
- [16] DANAPAL G, SANTOS G A, DA COSTA J P C L, et al. Sensor Fusion of Camera and LiDAR Raw Data for Vehicle Detection[C]// Proceedings of Workshop on Communication Networks and Power Systems. IEEE, 2020:1-6.
- [17] XIANG C, LI Y, ZHOU Y, et al. A Comparative Approach to Resurrecting the Market of MOD Vehicular Crowdsensing[C]// Proceedings of IEEE Conference on Computer Communications. IEEE, 2022:1479-1488.
- [18] XIANG C, ZHOU Y, DAI H, et al. Reusing Delivery Drones for Urban Crowdsensing[J]. IEEE Transactions on Mobile Computing, 2021, 22(5):2972-2988.
- [19] HE Z, WANG L, YE H, et al. Resource Allocation based on Graph Neural Networks in Vehicular Communications[C]// Proceedings of the IEEE Global Communications Conference. IEEE, 2020:1-5.
- [20] AOKI S, HIGUCHI T, ALTINTAS O. Cooperative Perception with Deep Reinforcement Learning for Connected Vehicles[C]// Proceedings of the IEEE Intelligent Vehicles Symposium. IEEE, 2020:328-334.
- [21] LU G, ZHANG X, OUYANG W, et al. An End-to-End Learning Framework for Video Compression[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(10):3292-3308.
- [22] COHEN R A, CHOI H, BAJIC I V. Lightweight Compression of Neural Network Feature Tensors for Collaborative Intelligence[C]// Proceedings of the IEEE International Conference on Multimedia and Expo. IEEE, 2020:1-6.
- [23] TAN T, CAO G. Deep Learning on Mobile Devices Through Neural Processing Units and Edge Computing[C]// Proceedings of the IEEE Conference on Computer Communications. IEEE, 2022:1209-1218.
- [24] ZHANG X, WU X. Attention-Guided Image Compression by Deep Reconstruction of Compressive Sensed Saliency Skeleton[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021:13354-13364.
- [25] SHAHAM T R, MICHAELI T. Deformation Aware Image Compression[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018:2453-2462.
- [26] CHEN D, CHEN Q, ZHU F. Pixel-Level Texture Segmentation Based AV1 Video Compression[C]// Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing. IEEE, 2019:1622-1626.
- [27] SENGAR S S, MUKHOPADHYAY S. Motion Segmentation-Based Surveillance Video Compression Using Adaptive Particle Swarm Optimization[J]. Neural Computing and Applications, 2020, 32(15):11443-11457.
- [28] GUO G, ZHAO S. 3D Multi-Object Tracking With Adaptive Cubature Kalman Filter for Autonomous Driving[J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(1):512-519.
- [29] MA H, WEI X, WANG P, et al. Multi-Arm Global Cooperative Coal Gangue Sorting Method Based on Improved Hungarian Algorithm[J]. Sensors, 2022, 22(20):7987-8007.
- [30] STRANG G. Introduction to Linear Algebra, Sixth Edition [M]. Wellesley-Cambridge Press, 2022:1-12.
- [31] ZHANG X, LIN W, XIONG R, et al. Low-Rank Decomposition-Based Restoration of Compressed Images via Adaptive Noise Estimation[J]. IEEE Transactions on Image Processing, 2016, 25(9):4158-4171.
- [32] NIE F, YUAN J, HUANG H. Optimal Mean Robust Principal

- Component Analysis[C]//Proceedings of the International Conference on Machine Learning. JMLR, 2014;1062-1070.
- [33] XIA Y,ZHANG D,KIM J, et al. Predicting Driver Attention in Critical Situations[C]//Proceedings of the Computer Vision. Springer, 2018; 658-674.
- [34] SURESH M,SAM I S. Exponential Fractional Cat Swarm Optimization for Video Steganography[J]. Multimedia Tools and Applications, 2021, 80(9): 13253-13270.
- [35] MU H, LI J, SU J, et al. Fast Detection Method for Pedestrian Video Abnormal Behavior Based on Keyframe Extraction and Multi-Task Mixed Model[C]//Proceedings of the IEEE International Symposium on Parallel and Distributed Processing with Applications. IEEE, 2024; 1925-1930.
- [36] BAO G, LI D, MEI Y. Key Frames Extraction Based on Optical-Flow and Mutual Information Entropy[C]//Proceedings of the Journal of Physics:Conference Series. IOP, 2020; 1646-1652.
- [37] WANG Y, CHAN P H, DONZELLA V. Semantic-Aware Video Compression for Automotive Cameras[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(6): 3712-3722.
- [38] SHI Y, YANG Y, WU Y. Federated Edge Learning With Differential Privacy: An Active Reconfigurable Intelligent Surface Approach[J]. IEEE Transactions on Wireless Communications, 2024, 23(11): 17368-17383.



JIANG Zixian, born in 2001, master. His main research interests include vehicular crowdsensing and urban computing.



SHEN Xin, born in 1983, master. His main research interests include big data intelligence, service computing and AI.

(责任编辑:何杨)