Cooperverse：面向混合连接与自动化环境下通用协同感知的移动边缘云框架

Zhengwei Bai，*IEEE*会员，Guoyuan Wu，*IEEE*高级会员，Matthew J. Barth，*IEEE*会士，
Yongkang Liu，Emrah Akin Sisbot，KentaroOguchi

arXiv:2302.03128v1 [cs.CV] 6 Feb 2023

摘要—协同感知（CP）正日益受到关注，并被视为支持协同驾驶自动化的核心基础，有望成为解决当代交通运输系统安全、出行和可持续性问题的关键方案。然而，目前的协同感知研究仍处于起步阶段，尚缺乏系统化的问题表述，而这对于真实世界场景下协同感知系统的系统设计至关重要。本文将通用协同感知系统表述为一个优化问题，并提出名为*Cooperverse*的移动边缘云框架。该系统面向混合连接与自动化环境中的协同感知。本文提出动态特征共享（DFS）方法，以在特定约束条件下支持该协同感知系统，并提出随机优先级筛选（RPF）方法，以高性能地执行动态特征共享。我们基于高保真协同感知平台进行了实验，结果表明，*Cooperverse*框架能够有效支持节点动态参与；所提出的动态特征共享（DFS）方法可将系统协同感知性能提升14.5%，而RPF方法可将移动节点的通信成本降低90%，平均精度仅下降1.7%。

索引词—协同感知、移动边缘云框架、目标检测、物联网、混合连接与自动化

I. 引言

智能车辆技术的进步显著提升了当前交通运输系统的安全性、出行效率和可持续性 [1] 。在人工智能（AI）的赋能下，自动驾驶车辆（AV）正逐步具备卓越的周边环境感知能力，为驾驶自动化奠定了基础 [2]。

在真实世界的交通环境中，传感器遮挡是限制自动驾驶车辆潜力的最大瓶颈之一。物联网（IoT）通过车载通信 [3] 共享信息，突破了上述限制。网联车辆（CV）可以利用车车通信（V2V）和车路通信（V2I） [4]，感知周围车辆或基础设施的状态（即，协同感知），例如交通信号相位与配时（SPaT）信息。然而，在混合交通条件下，由于存在不具备联网能力的传统车辆，实现协同感知更具挑战性。

通过空间上彼此分离的节点协同感知环境，对于解决上述问题至关重要，这种方式被定义为协同感知（CP） [5]。CP依靠连接性和自动化，以协作方式感知环境 [6]。此外，借助车联网通信，CP方法可以利用路侧传感器提升感知性能 [7]。

由于在混合交通中具备完整感知的天然优势，近年来协同感知研究迅速兴起 [8]–[10]。大多数 CP方法从理论角度出发，专注于提升检测性能，却忽略了真实世界条件下无法规避的实际约束，例如计算能力和通信带宽。 [11]。此外，协同感知系统设计主要针对具体案例逐一进行 [5]，，目前仍缺少一种系统的问题表述，以支持在通用交通条件下设计协同感知系统。

因此，本文将协同感知系统设计视为一个优化问题，并考虑计算复杂度、通信容量、融合方案和信息拓扑。根据该问题表述，本文提出了一种移动边缘云（MEC）框架。本文还提出了一种新颖的特征共享方法，以实现在不同系统约束下的动态协作。我们构建了一个协同感知环境，用于实验和评估。

II. 相关工作

A. 基于车辆的目标感知

过去十年来，自动驾驶汽车研发领域受到了广泛关注，车载物体感知技术也取得了长足进展。针对不同传感器（如单目/双目相机、激光雷达）或感知任务（如交通标志识别、车道检测、道路使用者检测），研究人员提出了多种计算机视觉算法 [12]。近年来，基于摄像头的解决方案广泛采用卷积神经网络（卷积神经网络），这也推动了用于分析点云数据（点云数据）的感知流水线设计

Zhengwei Bai、Guoyuan Wu 和 Matthew J. Barth 任职于美国加利福尼亚州河滨市 92507 的加州大学河滨分校电气与计算机工程系（电子邮箱：zbai012@ucr.edu）。Yongkang Liu、Emrah Akin Sisbot 和 Kentaro Oguchi 任职于美国加利福尼亚州山景城 94043 的 Toyota Motor North America 旗下 InfoTech Labs。

基于车载激光雷达传感器的方案 [13]。摄像头与激光雷达相结合，可显著提升自车中心感知的性能：激光雷达可用于检测和跟踪物体，而摄像头和激光雷达则可共同用于对目标进行分类 [14]。

B. 基于基础设施的物体感知

为了支持混合交通环境中的高效自动驾驶，基于基础设施的监控系统可以为目标道路使用者提供额外的物体级信息，弥补基于环形线圈检测器和雷达的传统数据采集（例如流量、点速度） [15]。Hao 等人采用传统的基于模型的方法，设计了一种用于基于基础设施的物体感知的自底向上流程 [16]。Bai 等人利用数据驱动模型展示了 *Cyber Mobility Mirror* 的概念：该系统使用路侧激光雷达，在交叉口实现实时三维物体感知 [17]。

C. 基于 *V2X* 的协同物体感知

通过结合基于车辆的感知和基于基础设施的感知，基于车联网（V2X）的协同物体感知被认为是充分发挥协同式驾驶自动化（CDA）潜力的最有前景途径 [5]。Xu 等人 [8]提出了一种基于 V2X 的协同感知方法，考虑了车辆节点和基础设施节点的异质性以及多尺度感受野。Lou 等人 [11]在真实世界中开展了协同感知的概念验证，通过应用 V2X 使各实体能够共享其感知结果；该项目展示了协同感知系统能够显著提升参与实体的感知能力。

III. 方法

A. 协同感知系统设计的问题表述

协同感知系统设计可表述为一种基于图的约束优化规划（COP），其目标是在满足感知节点 $i\,(i \in \mathcal{N})$ 的计算资源 $c_i \in \mathcal{C}$ 以及节点 i 与节点 j之间的通信带宽 $b_{ij} \in \mathcal{B}$等约束条件下，最大化系统级感知性能指标 $\mathcal{J}(\mathbf{x},\mathbf{y})$。决策变量分为两组。第一组变量 $x_i \in \mathbf{x}$ 用于确定分配给每个节点的信息处理资源，即 $\varepsilon = \{0,1,2\}$，其中 0、1 和 2 分别表示“原始数据保留”（计算成本为 r_0）、“特征提取”（计算成本为 r_1）和“边界框确定”（计算成本为 r_2）。另一组变量 $y_{ij} \in \mathbf{y}$ 用于判断是否存在从节点 i 到节点 j 的数据信息流路由，即，

$$y_{ij} = \begin{cases} 1, & \text{if the data from node } i \text{ to node } j \\ 0, & \text{otherwise} \end{cases} \tag{1}$$

因此，协同感知系统拓扑设计问题可表示如下：

$$\max_{\mathbf{x}} \mathcal{J}(\mathbf{x},\mathbf{y}) \tag{2}$$

满足以下约束

$$\begin{aligned} R(x_i) &\le c_i, && \forall i \in \mathcal{N} \\ D(y_{ij}) &\le b_{ij}, && \forall i,\ j \in \mathcal{N} \\ x_i &= \{0,1,2\}, && \forall i \in \mathcal{N} \\ y_{ij} &= \begin{cases} 1, & \text{if data flows from node } i \text{ to node } j \\ 0, & \text{otherwise} \end{cases}, && \forall i,j \in \mathcal{N} \end{aligned} \tag{3}$$

其中， $R(x_i)$表示节点 i处的计算工作量，该工作量不仅取决于所部署的融合方案（即早期融合、即时融合、后期融合），还取决于数据/信息量（包括自车传感器的数量/类型，以及来自其他节点的输入流）； $D(y_{ij})$表示从节点 i 到节点 j的数据/信息流量。请注意，在实际应用中，所有参数和图结构都可能随时间变化。

*B. MEC*赋能的*CP*框架

基于协同感知系统设计的问题表述，我们从实际应用的角度提出了一种用于设计协同感知系统的移动边缘云（MEC）框架。图1展示了基于MEC的CP系统框架的系统示意图。

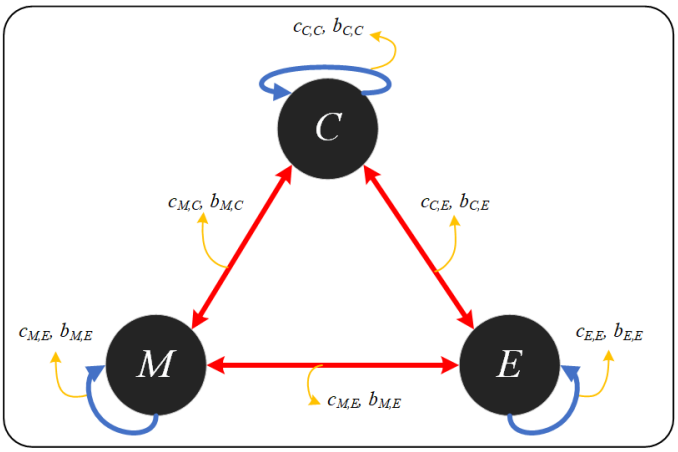

图1：基于MEC的CP系统框架。

设计了三类节点，包括移动节点（道路使用者）、边缘节点（基础设施节点）和云节点（中心计算服务器节点）。具体而言，在真实环境中，移动节点包括协同感知车辆（CPV），它们能够主动感知周围环境，并通过中间融合与其他车辆协作；网联车辆（CV）具备连接能力，但由于缺乏环境感知能力，只能共享自身信息；网联自动驾驶车辆（CAV）能够感知周围状况，并通过车联网通信共享目标列表信息。基于基础设施的感知与通信系统被视为边缘节点。借助路侧传感器的空间位置优势，边缘节点拥有更好的视场 [15]。与此同时，与云通信相比，边缘计算系统能够为某些时间关键型任务（例如碰撞预警）实现更低的时延要求。但要大规模部署协同感知

系统，云计算对于提供处理和存储海量数据以及进行广域消息分发的能力必不可少。通常，移动节点、边缘节点和云节点可在式（3）所列约束条件下相互协作。

本文遵循MEC框架，研究协同感知系统的性能。系统设计基于不同感知节点的特性。图2展示了基于MEC的CP系统框架的具体结构。

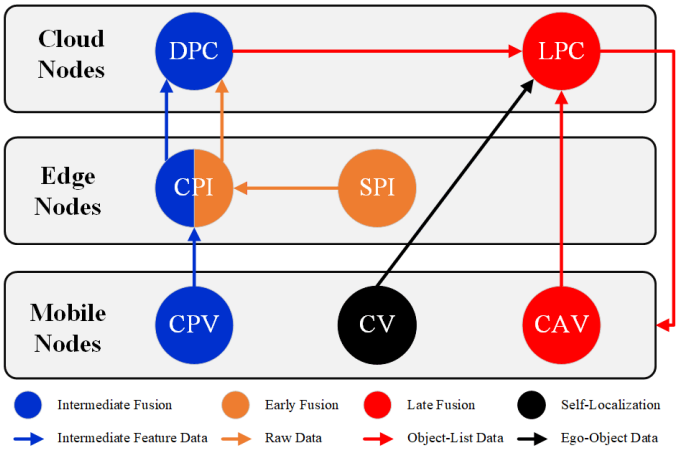

图2：基于MEC的CP系统框架的具体结构。

设计上述协同感知系统结构时，考虑了以下几项核心原则：

- 通信约束：移动节点的数据传输针对目标数据或中间数据进行设计，其所需带宽低于原始数据。得益于高速有线连接，边缘节点与云节点之间可以传输原始数据。

- 计算约束：只有CAV节点、中央感知基础设施（CPI）节点和DeepPerceptionCloud（DPC）节点需要高端计算机，而图2中的其他节点所需的计算能力较低。

- 信息流复杂度：为避免双向信息流导致 $\mathcal{O}(N^2)$通信复杂度，本文设计了前向-后向信息流，以实现 $\mathcal{O}(N)$通信复杂度。

- 融合能力：结合早期融合、中间融合和后期融合，以支持对不同类型节点的临时访问。

C. 动态特征共享

为解决通信带宽造成的限制，本文提出一种动态特征共享（DFS）方法，根据具体的通信带宽筛选要共享的特征数据。例如，为适应较低的通信带宽，需要减少与他人共享的特征单元数量。

本文提出一种随机优先级筛选（RPF）方法，从特征集（全部特征单元）中筛选特征。图 3 展示了可视化示意图，用于说明 RPF 的思路，以及它与选取优先级最高的 Top-$\mathcal{K}$ 项这一基线方法的区别。

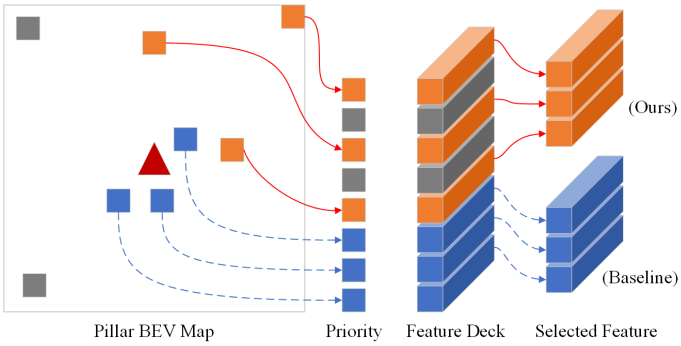

图 3：用于说明 PFF 思路的示意图。

如图 3 所示，三角形表示传感器的空间位置，正方形表示体素化特征单元。RPF 不会根据最高优先级截断特征集（例如图 3 中的 $\mathcal{K}=3$），而是会选择具有随机-$\mathcal{K}$ 优先级的特征。

优先级计算基于特征单元的空间位置与传感器之间的距离。为提高计算效率，优先级采用曼哈顿距离计算，如下所示：

$$\mathcal{D}_m = \mid x_p - x_s \mid + \mid y_p - y_s \mid \tag{4}$$

其中，$\mathcal{D}_m$ 是特征位置（x_p，y_p）与传感器位置（x_s，y_s）之间的曼哈顿距离。

D. 动态特征融合

对于通用CP框架，Cooperverse框架集成了三种融合方案，包括早期融合、中间融合和后期融合。

1) 早期融合：基于MEC结构，设计了全局参考坐标（GRC）系统，用于原始数据预处理和早期融合。具体而言，原始传感器数据将被变换到静态GRC中，以对齐所有信息。

$$\mathcal{P}^{E\to G} = \begin{bmatrix} \mathcal{R}_X & 0 \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \mathcal{R}_Y & 0 \\ 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} \mathcal{R}_Z & 0 \\ 0 & 1 \end{bmatrix} \cdot \mathcal{P}^{E} + \mathcal{T}^{E\to G} \tag{5}$$

其中，$\mathcal{R}_X$、$\mathcal{R}_Y$、$\mathcal{R}_Z$和 $\mathcal{T}^{E\to G}$ 分别表示沿 x–轴、y–轴和 z–轴的旋转矩阵，以及从自车坐标系到GRC的平移矩阵。$\mathcal{P}^{S}$ 和 $\mathcal{P}^{S\to G}$ 分别表示变换前后的原始数据。

然后将按如下方式进行早期融合：

$$\mathcal{P}_{early} = \bigcup_{i=1}^{n} \mathcal{P}_i^{E\to G} \tag{6}$$

其中，n 表示参与早期融合过程的节点数量。

2）中间融合：为支持动态、可扩展且异构条件下的中间融合，采用 VINet [10] 作为基础神经网络，为基于中间融合的节点生成通用特征图。VINet 中的双流融合如图 4 所示，其中提取并融合了来自车辆节点和基础设施节点的特征。

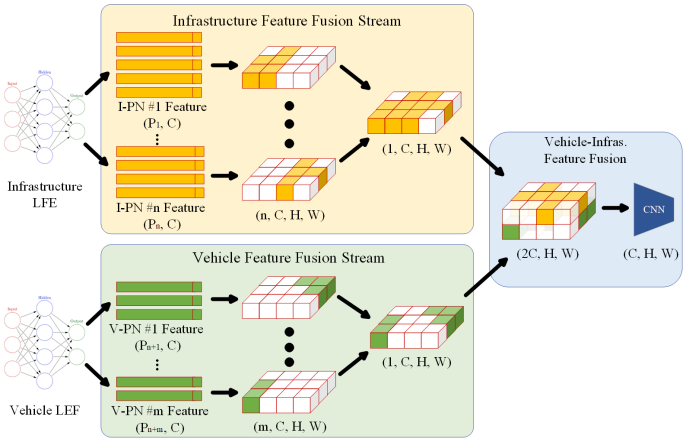

图 4：双流融合流程示意图。

具体而言，RFF 用于生成筛选后的特征，并将其输入 TSF 进行协同融合。

3) 后期融合：对于后期融合，Cooperverse框架采用了非极大值抑制（NMS）。具体而言，采用多类别圆形非极大值抑制，从多个多类别目标列表中过滤出边界框。

IV. 实验

A. 数据集采集

“*CARTI*”（即 **CAR**la-ki**TTI**）平台用于采集激光雷达传感器数据和真实标签，以训练和测试协同感知系统模型。具体而言，部署了两个基础设施节点和三个车辆节点进行数据采集。CARTI 平台中的传感器配置基于真实世界感知系统的经验 [17]，如表 I 所示。总共采集了 8,695 帧三维点云，其中 4,347 帧用于训练，1,449 帧用于评估，2,899 帧用于测试。

表 I：CARTI 平台的参数配置（车载/路侧）

参数	设置
激光雷达通道	64
激光雷达高度	$1.74/4.74m$
激光雷达感知范围	$100.0m$
激光雷达旋转频率	10.0赫兹
上视场角	$+22.5$ / $+0$
下视场角	-22.5 / -22.5
点的标准差	$0.01m$
普通点衰减率	45%
普通点衰减强度	0.8

B. 实验设置

1）感知环境：为了评估和研究 Cooperverse 框架的性能，构建了一个由三个相邻交叉口组成、规模为 $280m \times 80m$ 的交叉路口网络，如图 5 所示



图 5：协同感知环境的俯视图。

2) 训练详情： 训练和测试平台由一颗 Intel® CoreTM i7-10700K CPU 和一块 NVIDIA RTX 3090 GPU 组成。训练流程设置为 160 个训练轮次，批次大小为 2。体素尺寸设为 $[0.23m, 0.23m, 8.00m]$，每个节点的最大体素数 $\mathcal{K}$ 在训练时设为 45，000；测试时则设为从 15，000 递减至 500 的不同数值，以评估不同约束条件下的性能。

3) 评估详情： 检测性能通过交并比 (IoU) 阈值为 0.25（行人）和 0.7（汽车）时的平均精度 (AP) 与平均召回率 (AR) 衡量。此外，根据地面目标所反映的最小点数 (MP)，将每个评估类别进一步划分为三类：MP≥10、MP≥5 和 MP≥1，以考察 CP方法在不同难度等级下的性能。

C. 评估与分析

本节从三个方面评估了不同的协同感知系统：1）用于协同感知的各种节点组合；2）采用动态特征共享（DFS）时，在不同系统约束下的感知性能；3）采用 RPF 时，带宽节省与 AP 降低之间的权衡。由于篇幅有限，对动态特征融合的系统评估仅涵盖中间融合。多种融合方案组合后的性能将在未来工作中进一步讨论。

1）动态节点参与：本文评估了不同节点参与条件下的 AP 性能。值得注意的是，模型仅在所有可用节点均参与的情况下训练一次，随后在不同条件下进行评估，且不再进行微调，以使测试情境更加贴近实际。

测试结果如表 II 所示。通过分析性能数据，可以得出以下三点结论：

表 II：不同节点组合下的 AP 性能。

协同感知节点		AP						
边缘节点	移动节点	总体 AP	行人 交并比@0.25			汽车 交并比@0.7		
			MP≥10	MP≥5	MP≥1	MP≥10	MP≥5	MP≥1
基础设施@1	车辆@0	18.82	2.44	9.44	9.54	32.32	30.31	28.86
基础设施@1	车辆@1	22.43	4.01	5.57	5.73	42.29	38.50	38.49
基础设施@1	车辆@2	25.75	6.04	7.15	7.22	44.77	44.68	44.61
基础设施@1	车辆@3	29.95	10.73	11.94	12.06	48.29	48.32	48.33
基础设施@2	车辆@0	31.42	2.06	9.59	10.05	55.91	55.49	55.39
基础设施@2	车辆@1	36.11	3.72	5.64	7.46	66.64	66.64	66.58
基础设施@2	车辆@2	39.43	5.89	7.41	8.79	71.67	71.51	71.31
基础设施@2	车辆@3	42.21	10.78	12.21	13.61	72.28	72.23	72.16

- 可扩展性：在协同感知系统中，每新增一个节点参与，目标检测的系统性能在很大程度上都会提升。

- 重要性差异：在协同感知系统中，不同类型节点的重要性各不相同。根据表 II，基础设施节点对提升 AP 性能的重要性远高于车辆节点。例如，包含 2 个基础设施节点的协同感知系统，其总体 AP 高于包含 1 个基础设施节点和 3 个车辆节点时的协同感知性能。

- 影响异质性：不同类型的节点对特定目标类别的影响各不相同。例如，基础设施节点主要影响汽车检测，而车辆节点对行人检测的影响更为显著。由于基础设施节点受到的遮挡较少，因此汽车检测效果更好。与基础设施节点相比，车辆节点在空间上更靠近行人，因此车辆节点提供的行人点云信息可能更加充分。

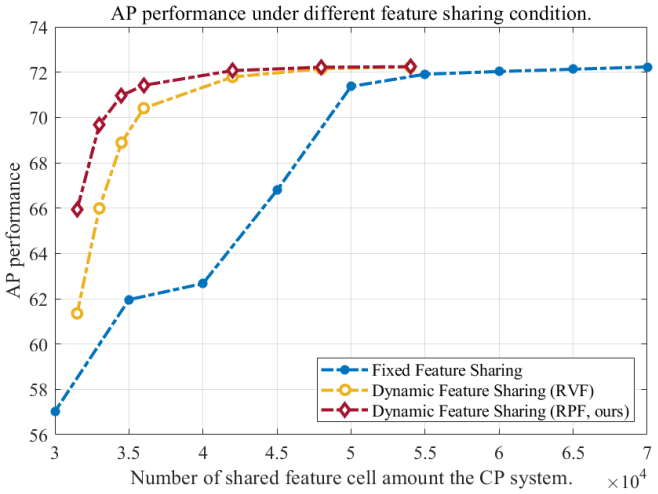

图 6：不同特征共享条件下的 AP 性能。

2）系统级共享条件：如第 III-A 节所述，协同感知系统可以在特定约束下运行。本文评估了协同感知系统在不同系统级通信约束下的表现。借助 VINet 提取的轻量级特征这一特性，通信带宽约束可线性映射为允许共享的最大特征单元数量。考虑到每个轻量级特征单元需要 256 字节进行传输 [10], ，我们测试了系统级总传输特征单元数从 30，000 到 75，000，即每个系统帧约为 7.7MB 到 19.2MB。

根据图 6，传统的固定特征共享方法在系统共享单元数低于 50，000 时，性能会显著下降。然而，我们提出的动态特征共享方法在系统级共享单元数降至 35，000 时仍能保持 AP 性能。具体而言，在每帧 8.9MB 的系统通信约束下，与固定特征共享相比，我们的方法可将 AP 性能提升 14.5%。

3）动态特征共享的权衡：本节将研究不同动态特征共享方法的性能。由于基础设施节点对系统级性能的影响更大，且移动节点的通信带宽往往较低，因此我们将基础设施节点的 $\mathcal{K}$ 固定为 15，000，同时考察不同车辆节点约束下的 AP 性能，评估结果如表 III 所示。

图 7 展示了带宽节省与 AP 降低之间的相关性。在带宽约束更严格时，我们的 RPF 方法最能抵抗性能下降。具体而言，与采用固定特征共享的协同感知系统相比，RPF 可将通信带宽降低 90.0%，而 AP 降低仅为 1.7%。此外，在抵抗 AP 性能下降方面，RPF 比其他动态特征共享方法高出 51.1%。

V. 结论与未来工作

本文提出了一种名为*Cooperverse*的MEC框架，用于支持通用协同感知（CP）。本文构建了一个优化问题，以从数学角度研究协同感知系统的拓扑设计。本文提出动态特征共享 方法，以在特定约束条件下支持协同感知系统，并提出随机优先级过滤 方法，以高性能地执行动态特征共享。我们基于高保真

表 III：不同特征共享约束下的检测性能。

特征共享数量	8,000	6,000	4,000	2,000	1,500	1,000	500
Top-K 最近邻过滤	72.18	71.46	66.32	61.7	61.57	61.49	61.24
Top-K 最远过滤	72.22	72.01	71.58	70.34	68.21	66.29	61.71
随机体素过滤	72.23	72.15	71.79	70.41	68.89	65.99	61.35
随机优先级过滤（我们的方法）	72.24	72.22	72.07	71.42	70.97	69.68	65.93

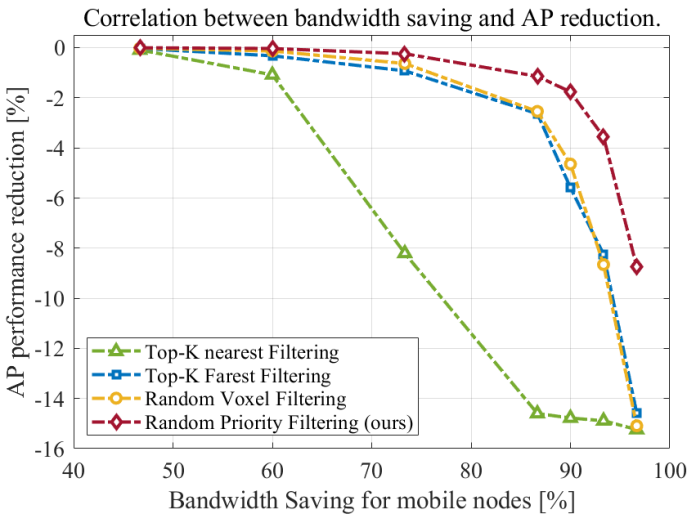

图 7：带宽节省与 AP 减少量之间的相关性。

协同感知平台开展了实验，结果表明，Cooperverse框架有助于实现动态节点参与；所提出的动态特征共享方法可将系统感知性能提升14.5%，而RPF 方法可将移动节点的通信成本降低90%，同时AP仅下降1.7%。

致谢

本研究由 Toyota Motor North America、InfoTech Labs 资助。本文内容反映了作者的观点，作者对本文所述事实及数据的准确性负责。本文内容不一定反映 Toyota Motor North America 的官方观点。

参考文献

[1] Z. Bai、P. Hao、W. Shangguan、B. Cai 和 M. J. Barth，“基于混合强化学习的网联自动驾驶车辆信号交叉口节能驾驶策略”，*IEEE*智能交通系统汇刊，第 1–14 页，2022年。[2] C. Badue、R. Guidolini、R. V. Carneiro、P. Azevedo、V. B. Cardoso、A. Forechi、L. Jesus、R. Berriel、T. M. Paixao、F. Mutz 等，“自动驾驶汽车：综述”，《应用专家系统》，第 165 卷，第 113816 页，2021年。[3] H. Khayyam、B. Javadi、M. Jalili 和 R. N. Jazar，“自动驾驶车辆的人工智能与物联网”，载于《工程应用中的非线性方法》。施普林格，2020年，第 39–68 页。[4] A. Bazzi、B. M. Masini、A. Zanella 和 I. Thibault，“IEEE 802.11p 和 LTE-V2V 在网联车辆协同感知中的性能”，*IEEE*车辆技术汇刊，第 66 卷，第 11 期，第 10 419–10 432 页，2017年。

[5] Z. Bai、G. Wu、M. J. Barth、Y. Liu、E. A. Sisbot、K. Oguchi 和 Z. Huang，“协同感知综述与框架：从异构单体到分层协作”，*arXiv*预印本 *arXiv:2208.10590*，2022年。[6] T.-H. Wang、S. Manivasagam、M. Liang、B. Yang、W. Zeng 和 R. Urtasun，“V2VNet：用于联合感知与预测的车车通信”，载于欧洲计算机视觉会议。施普林格，2020年，第 605–621 页。[7] Z. Bai、G. Wu、X. Qi、Y. Liu、K. Oguchi 和 M. J. Barth，“面向协同驾驶自动化的基础设施目标检测与跟踪：综述”，载于*2022*年 *IEEE*智能车辆研讨会（*IV*），2022年，第 1366–1373 页。[8] R. Xu、H. Xiang、Z. Tu、X. Xia、M.-H. Yang 和 J. Ma，“V2X-ViT：采用视觉Transformer的车联网协同感知”，载于《计算机视觉——*2022*年欧洲计算机视觉大会：第*17*届欧洲计算机视觉会议，特拉维夫，以色列，*2022*年*10*月*23*日至*27*日，论文集，第三十九部分》。施普林格，2022年，第 107–124 页。[9] Q. Chen、X. Ma、S. Tang、J. Guo、Q. Yang 和 S. Fu，“F-Cooper：利用三维点云实现自动驾驶车辆边缘计算系统的基于特征的协同感知”，载于第四届 *ACM/IEEE*边缘计算研讨会论文集，丛书 SEC ’19。美国纽约州纽约市：计算机协会，2019年，第 88–100 页。

[ ] 10 1145 3318216 3363300 在线。可访问：https://doi.org/ 。/ 。Z. Bai、G. Wu、M. J. Barth、Y. Liu、E. A. Sisbot 和 K. Oguchi，“VINet：用于三维目标检测的轻量级、可扩展异构协同感知”，*arXiv*预印本 *arXiv:2212.07060*，2022年。[11] Y. Lou、A. Ghiasi、M. Jannat、S. Racha、D. Hale、W. Goforth、P. Bujanovic 等，“协同自动化研究：CARMA概念验证——TSMO用例测试：CARMA协同感知概念运行说明”，美国联邦公路管理局，技术报告，2022年。[12] E. Marti、A. Miguel、F. Garcia 和 J. Perez，“自动驾驶感知传感器技术综述”，*IEEE*智能交通系统杂志，第 11 卷，第 4 期，第 94–108 页，2019年。[13] A. H. Lang、S. Vora、H. Caesar、L. Zhou、J. Yang 和 O. Beijbom，“PointPillars：用于点云目标检测的快速编码器”，载于*IEEE/CVF*计算机视觉与模式识别会议论文集，2019年，第 12 697–12 705 页。[14] Z. Liu、H. Tang、A. Amini、X. Yang、H. Mao、D. Rus 和 S. Han，“BEVFusion：基于统一鸟瞰视图表示的多任务多传感器融合”，*arXiv*预印本 *arXiv:2205.13542*，2022年。[15] Z. Bai、G. Wu、X. Qi、Y. Liu、K. Oguchi 和 M. J. Barth，“面向协同驾驶自动化的基础设施目标检测与跟踪：综述”，载于*2022*年 *IEEE*智能车辆研讨会（*IV*），2022年，第 1366–1373 页。[16] J. Zhao、H. Xu、H. Liu、J. Wu、Y. Zheng 和 D. Wu，“利用路侧激光雷达传感器检测和跟踪行人与车辆”，《交通研究*C*辑：新兴技术》，第 100 卷，第 68–87 页，2019年。[17] Z. Bai、S. P. Nayak、X. Zhao、G. Wu、M. J. Barth、X. Qi、Y. Liu 和 K. Oguchi，“Cyber Mobility Mirror：基于深度学习、利用路侧激光雷达实现实时三维目标感知与重建”，*arXiv*预印本 *arXiv:2202.13505*，2022年。