

智能交通中通信—感知—计算 三元协同关键技术研究

Research on Key Technologies of Communication–Perception–Computation
Tripartite Collaboration in Intelligent Transportation

汪保友, 沈佳庆, 李泉宏 (中国联通上海分公司, 上海 200050)

Wang Baoyou, Shen Jiaqing, Li Quanhong (China Unicom Shanghai Branch, Shanghai 200050, China)

摘要:

基于车路云协同体系架构, 系统研究了智能交通系统中的关键技术, 介绍了通感融合基站的资源分配优化与协同组网方法; 构建了面向交通场景的多模态行业大模型, 引入视觉提示机制优化策略, 提升复杂交通事件的定位精度; 设计了基于贡献度评估的个性化联邦学习框架, 克服数据异构性对联邦学习性能下降的影响。通过上述技术的协同创新, 有效解决智能交通系统中的实时响应、场景理解与隐私保护等核心问题。

关键词:

智能交通系统; 车路云协同; 通感一体; 多模态大模型; 联邦学习

doi: 10.12045/j.issn.1007-3043.2026.04.002

文章编号: 1007-3043(2026)04-0008-08

中图分类号: TN929.5

文献标识码: A

开放科学(资源服务)标识码(OSID):



Abstract:

Based on the vehicle–road–cloud collaborative architecture, it systematically investigates the key technologies in intelligent transportation systems. It introduces a resource allocation optimization and collaborative networking method for integrated sensing and communication base stations, develops a multi–modal industry large model for transportation scenarios and introduces an optimization strategy based on visual prompt mechanisms to improve the positioning accuracy of complex traffic events, designs a personalized federated learning framework based on contribution evaluation to mitigate the adverse effects of data heterogeneity on federated learning performance. Through the collaborative innovation of these technologies, the core challenges of real–time responsiveness, scenario understanding, and privacy protection in intelligent transportation systems are effectively addressed.

Keywords:

Intelligent transportation system; Vehicle–road–cloud collaboration; ISAC; Multi–modal large models; Federated Learning

引用格式: 汪保友, 沈佳庆, 李泉宏. 智能交通中通信—感知—计算三元协同关键技术研究[J]. 邮电设计技术, 2026(4): 8–15.

0 引言

智能交通利用现代信息技术、通信技术和控制技术, 对城市道路交通规划、设计、建设、运营和管理等方面进行智能化改造和升级, 从安全、效率、节能等方面改善人们的出行体验。《“十四五”现代综合交通运输体系发展规划》中提出积极稳妥发展工业互联网

和车联网, 聚焦人工智能等关键技术的研发与迭代应用, 构建与数字经济发展相适应的政策法规体系。车路云协同是智能交通的关键实现路径, 融合了车辆智能化、道路智能化以及云端计算与通信能力, 其核心在于通过高速可靠的通信网络, 实现车—车 (Vehicle-to-Vehicle, V2V)、车—路 (Vehicle-to-Infrastructure, V2I)、车—网 (Vehicle-to-Network, V2N)、车—人 (Vehicle-to-Pedestrian, V2P) 之间四联交互, 实现车辆、道路基础设施与云端平台之间的高效、实时信息

收稿日期: 2026-02-05

共享与协同决策,形成具有“线上资源合理分配,线下高效优质运行”的新业务模式,提升交通安全、缓解交通拥堵、优化出行效率。

近年来,通感一体、行业大模型、联邦学习等新兴技术在智能交通领域展现出巨大的应用潜力。通感一体技术打破了传统通信与感知相互独立的模式,实现了通信与感知功能的深度融合,可有效提升交通系统的信息获取能力。行业大模型基于大规模交通数据进行训练,能够对复杂的交通场景进行准确理解和预测,为智能交通决策提供强大支持。联邦学习则在保障数据隐私安全的前提下,实现了跨机构、跨区域的交通数据联合建模与分析,促进了交通数据的共享与利用。因此,深入研究这些技术在智能交通中的应用具有重要的现实意义。

文献[1-4]提出基于LTE的车联网技术(LTE-V2X),奠定了蜂窝车联网(Cellular Vehicle-to-Everything, C-V2X)系统架构和技术路线。C-V2X以蜂窝通信技术为基础,利用移动通信的产业规模经济降低成本。同时提出基于车联网“聪明的车、智慧的路、协同的云”的智能交通发展模式。

通感一体(Integrated Sensing and Communication, ISAC)技术^[5-10],作为5G-A的一项革新技术,将通信与感知能力融合在同一硬件平台和同一频段中,能够有效降低系统硬件开销、提高频谱效率。ISAC也是6G中的一项重要发展方向。

多模态大模型是融合了文本、图像、视频、音频等多种模态信息处理能力的新一代AI模型^[11-16],主要由3个核心模块组成:模态编码器、预训练语言模型和模态接口。多模态大模型在智能交通领域具有显著优势,多模态信息融合能力,能够有效整合视觉图像、传感器数据等多种信息源,可辅助实现目标识别、环境感知、交通事件检测、交通流量预测、交通信号优化、出行路线规划等交通场景需求。

联邦学习是一种在不披露数据隐私的前提下,让各参与方协作进行模型训练的分布式机器学习框架^[17-19]。联邦学习常常面临着数据异构的严峻挑战,为此研究者提出多种个性化联邦学习算法^[20-24]。其核心逻辑是:“压缩传输内容+减少无效通信+适配异构特性”。通过模型压缩降低单次通信量,通过动态策略减少总轮次,同时结合个性化模型设计减少全局与本地的参数差异,最终在保护数据隐私和适应数据异构的前提下,提升模型的准确性和效能。

本文首先对车路云协同系统^[25-26]的网络架构进行概述;接着分别针对通感融合基站、多模态行业大模型、个性化联邦学习等关键技术要点展开阐述。

1 车路云协同系统网络架构

车路云协同系统网络架构如图1所示,可概括为“聪明的车、智慧的路、协同的网和融合的脑”。

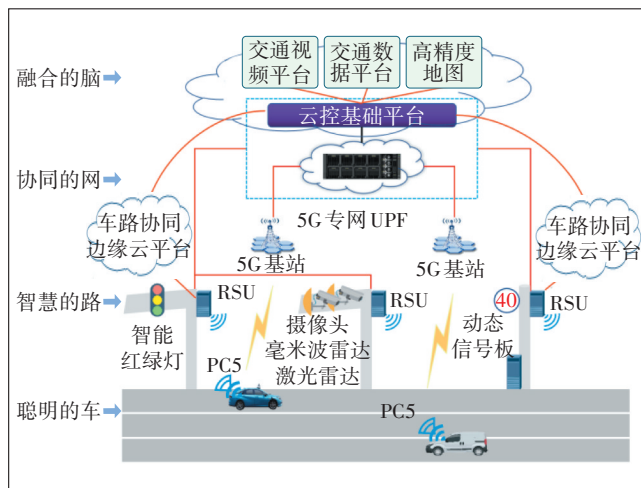


图1 车路云协同系统网络架构

a) 聪明的车。作为移动的感知节点和计算终端,安装部署高精度GNSS、多种传感器、5G CPE和计算单元,实时采集周边环境信息,通过PC5直连通信接口,实现车辆、路侧单元(Road Side Unit, RSU)之间的短距离直接通信;通过5G Uu口与RSU和云端进行通信;通过计算技术实现辅助驾驶、智能导航等功能;通过对卫星导航、惯性导航、PPP/IMU融合导航、视觉辅助等多源融合的高可靠定位技术在车载终端上的实际应用,使车智能起来。

b) 智慧的路。在路口及重要路段(事故多发地、长路段等)部署雷视一体机、多种传感器和5G通信模块,通过采集路口感知信息和交通信号灯数据,实现对交通状况的实时监测;通过有线光纤(或5G Uu口)回传信息至云控平台;通过与车辆和云端的交互,实现交通信号的智能控制、路况预警等功能。

c) 协同的网。基于5G和C-V2X、基础光纤网络、北斗卫星等技术打造一张空天地一体的融合通信网络;由边缘—区域—中心三级云分层结构组成的交通云,形成物理分散、逻辑协同的云控基础平台;满足远近期信息交互,实现“人—车—路—云”协同交互。近程信息交互,实现车与车、车与路、车与弱势交通参与

者等的通信,有低时延、高可靠的严苛要求,与智能驾驶紧相关。远程信息服务,指V2N,实现交通全局优化和娱乐信息服务,对实时性要求没有那么强,但要求通信覆盖性好,对高带宽、大容量有极高要求。

d) 融合的脑。由云控基础平台负责对车辆和道路上传的海量数据进行存储、分析和处理,通过5G Uu口向车辆和RSU发送交通路况与路口感知信息,为车辆和道路提供智能决策支持;还可以通过与交通视频AI平台、交通数据平台等其他系统的交互,实现智能导航、交通管理、城市规划、娱乐信息服务等功能。

车路云协同系统的业务逻辑框架如图2所示。

在图2中,感知层利用车端、路侧的感知设备,感知、测量和捕获交通运行信息,实现交通运行状态的可视和可测。网络层利用5G/5G-A无线网、GPON/专线/IPRAN有线网等打造的通信基座,实现人、车、路、环境这四大要素的互联互通。智算平台层是由边缘云、区域云、中心云组成的算力平台,集数据管理、存储和计算环境于一体,实现交通管理部门、公安交警、城管、交通运输企业等之间的信息共享和交换。智慧应用层依托智算平台构建的多模态行业大模型、实时信息数据,提供车路协同辅助驾驶服务,包括交通信息服务、道路交通管控、定位地图服务、辅助驾驶服务等。

为实现“聪明的车、智慧的路、协同的网、融合的脑”这一智能交通体系愿景,众多学者与工程技术人员正积极投入通感融合技术、多模态行业大模型以及

个性化联邦学习等关键技术研究,以期充分释放这些新兴技术在智能交通领域的巨大应用潜力。

通感一体化基站具备“看得远”(探测距离远超传统交通雷达)和“看得清”(识别准确、误判率低)的优势,通过共享通信与感知的硬件和频谱资源,显著提升了系统效率。部署于路侧后,该技术可有效增强复杂交叉路口和恶劣天气等场景下的感知精度,消除传统交通雷达覆盖盲区,实现对路况的更全面监控。

联邦学习作为一种突破性的分布式机器学习框架,在充分保护隐私的前提下释放数据价值,实现了隐私保护与数据利用的有效平衡。该技术还可大幅减少数据传输量,降低通信开销;适用于由边缘云、区域云和中心云构成的算力平台,有力促进交通管理部门、公安交警、城管、交通运输企业等多方主体之间的信息共享与协同交互。多模态行业大模型能够显著提升车路云协同系统的智商IQ,增强“融合智能中枢”的认知与决策能力。

2 车路云协同系统关键技术

2.1 通感融合基站

感知对于交通的价值体现在如下3个方面:及时发现路面的异常情况(违章、事故、停车)等,通知交警及时处理,降低事故发生的概率,提升安全系数;统计车道车流、上报路网车流等信息,通知业主和交警及时进行匝道控制和拥堵控制等,提升通行效率,减少拥堵;在雨雾等恶劣天气状况下,对道路状况进行精

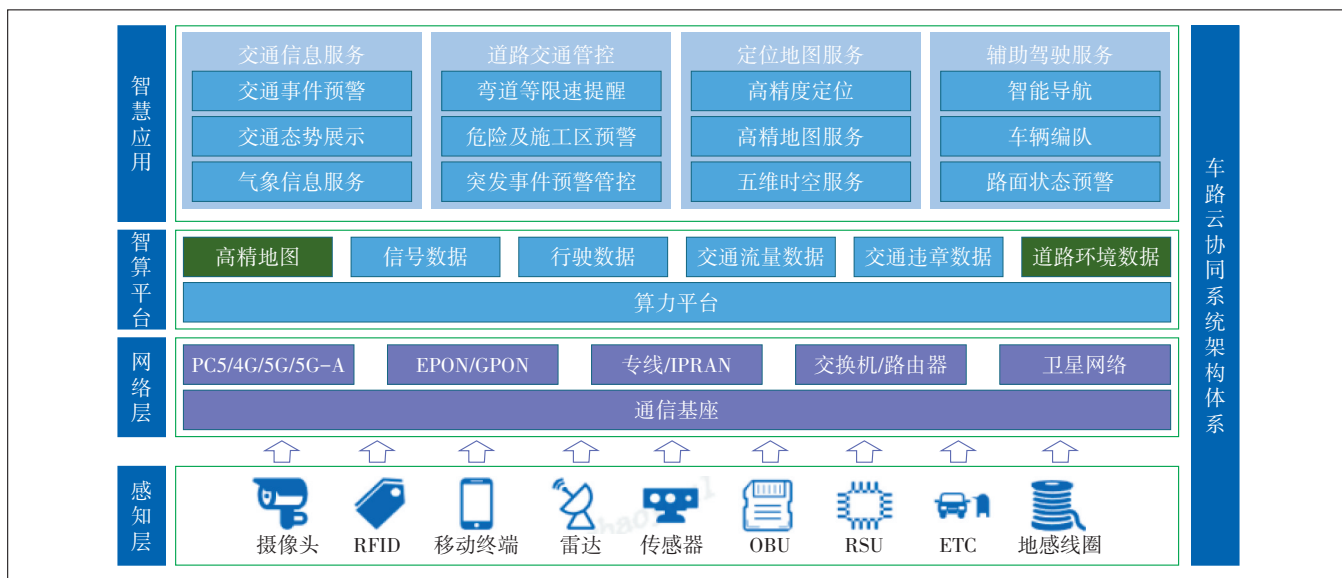


图2 车路云协同系统的业务逻辑框架

确感知,并将信息下发到车端,给车主提供更好的服务。传统的感知通过雷达来完成目标检测、参数估计、目标跟踪和识别等任务,通信则是通过无线网络实现信息的传输和交换。由于传统交通雷达的带宽和发射功率局限,其探测距离范围相对较小(200 MHz@24 GHz的雷达覆盖距离为200 m;500 MHz@77 GHz的雷达覆盖距离为500 m)。而在高速公路上,用于安装有源电子设备的基础设施间距一般超过1 km,这导致高速公路上交通雷达无法连续覆盖,存在较大的监控盲区。因此产生了通信感知融合的新业务需求。通感一体技术是3GPP在5G-Advanced-R19中重点推进技术,它通过通感一体化波形设计、时频域感知资源分配、多天线技术、通感融合信道建模以及AI与算力融合协同部署等手段,实现通信感知一体化,使无线网络在进行高质量通信交互的同时,可以实现高精度、精细化的感知功能。ISAC技术使无线网络能够在保持稳健通信性能的同时,提供高精度、精细化的感知能力,有效弥补了传统系统中的覆盖差距。

通感融合基站利用无线电波的传输、反射和散射,从无线信号中获取距离、速度、角度等信息,实现“网络即传感器”(Network as a Sensor)。另一方面,感知所提供的高精度定位、成像和环境重构能力,可以帮助提升通信性能,实现“感知辅助通信”。相比雷达,通感融合基站在覆盖、距离分辨率、测角精度等方面优势明显。通感融合基站通常采用毫米波频段,工作带宽更大(800 MHz@26 GHz),具有更大规模的阵列;空口时延更低,吞吐量能力更高(>10 Gbit/s);窄波束赋型能力强,可以形成很窄的空间波束,具有很好的空间角度分辨率;相比低频段,毫米波可实现更高精度定位、更高精度目标检测。同时由于波长短,被感知物体的微小动作可引起信道状态的相位变化,支持如手势识别、姿态识别等人机交互的场景应用。另外毫米波频段对多普勒偏移的感知能力更强,适合高速移动场景下的目标跟踪和运动速度测量,能使基站实现“雷达”功能,识别车辆和低空飞行物的位置、速度与方向等。此外可灵活部署帧结构,除常规帧结构(Option1: DDSU),还可选择上行增强帧结构(Option2: DSUUU)、上下行均衡帧结构(Option3: DDSUU),以提升上行速率。通感融合基站在时域和空域将少量的频谱配置为专用的感知资源(见图3),通信与感知共享硬件和频谱。

通感一体化波形设计首选OFDM波形,即感知采

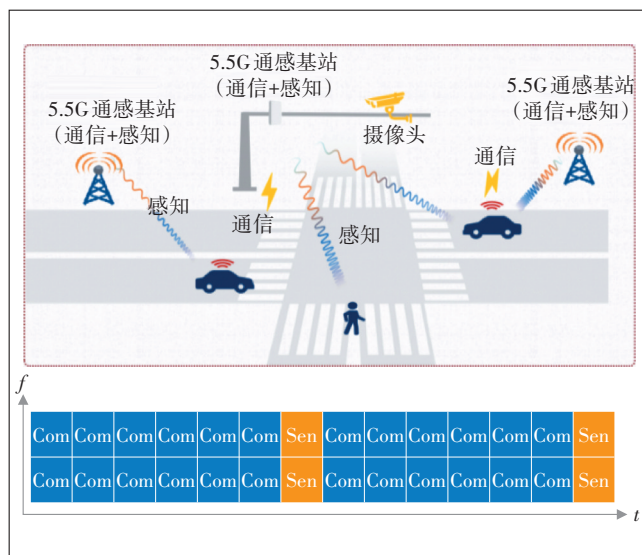


图3 通感融合基站共频谱资源

用与通信相同的OFDM波形,如图4所示,让通信与感知复用相同的发送和接收流程,不但能够避免增加硬件的复杂度,而且能够使感知兼容现有通信的帧结构。经测试验证:采用OFDM波形的5G-A通感融合基站能够实现500 m范围内车辆的车道级跟踪,500 m范围行人入侵100%检测,和1 km范围内无人机的分米级感知。




图4 通感一体化波形OFDM Chirp

在实际组网层面,可以通过部署多频多站协同技术,在提升感知能力的同时优化通信性能。具体实现方式如下。

a) 多站协同感知。利用多个站点对其重叠覆盖区域内的同一目标进行多角度探测,提升感知精度或扩大感知范围。通过多站协同不但能够降低环境遮挡概率,大幅提升目标的探测成功率,而且在测量精度方面,可以弥补位置精度低的短板,将感知目标位置精度提升至分米级。多站协同感知的关键是需要抑制多站之间的感知信号干扰以及多站信号数

据的融合处理。

b) 高低频感知。低频信号覆盖广、穿透强,适于大范围初步感知;高频信号带宽大、分辨率高,适于局部精准定位与成像。通过协同调度高低频感知资源,系统能够根据通信与感知的实时需求,灵活兼顾感知范围与精度,从而提升通感一体化系统的整体效率。在实施过程中解决了多频段数据的去冗余、感知路径优化、异构数据融合及格式统一等技术问题。

通过上述协同组网机制,可在增强环境感知能力的同时,提升频谱利用效率和通信链路质量,实现感知与通信性能的协同优化。

2.2 多模态行业大模型

多模态大模型契合城运管理的智能化需求,但在多模态数据处理、领域适配模型架构等环节面临技术瓶颈,需要研究面向交通运输管理行业的多模态行业大模型。首先,需要基于半自动化数据清洗与智能标注技术,构建适配城运管理场景的多模态语料库;其次,多模态大模型需要行业微调与优化,实现通用多模态大模型与专业需求的精准对齐。

Transformer架构不仅在自然语言处理领域取得了显著进展,在计算机视觉领域也有一些应用研究。2020年, Dosovitskiy 等人提出的 Vision Transformer (ViT)模型^[11],将输入图像划分为不重叠的等尺寸图像块,通过线性投影编码为嵌入向量序列,并引入可学习位置编码以保留空间拓扑信息。其核心突破在于采用多头自注意力机制,有效捕获图像块间的长程依赖关系,成功实现了全局上下文建模。在Transformer架构的支持下,由于嵌入层能够将不同模态的信息统一转换为嵌入向量形式,使得这些向量成为处理多模态数据的理想基本单元。2021年,OpenAI Radford等人提出了 CLIP(Contrastive Language-Image Pre-Training)模型,通过双塔结构分别提取视觉与文本特征,采用对比学习框架建立图像与文本模态间的语义对齐关系。CLIP验证了海量弱监督数据在跨模态关联学习中的有效性,对多模态模型训练策略产生深远影响。

在多模态任务中,单纯依赖文本提示学习,往往面临模型泛化性能不足以及文本与视觉特征语义不一致等局限性。针对语言大模型在视觉信息理解方面的局限性,Tsimpoukelli等人提出了 FROZEN 多模态学习框架^[27],该框架的核心在于构建跨模态特征映射机制,其中视觉特征提取器负责将图像数据编码为

语义空间的嵌入表示,从而生成视觉语义提示。该模型采用参数冻结策略,在任务优化阶段仅对视觉编码模块进行参数更新,而保持语言模型的原始参数不变。

为进一步提升多模态大模型在事件定位任务中的表现,本文提出了一种基于视觉提示的优化策略,旨在强化模型对复杂场景的理解能力。现有开源预训练多模态大模型中,视觉编码器的输入图像分辨率受限,无法通过整合更丰富的视觉上下文信息来增强模型对图像细节的解析能力。因此,需要针对视觉编码器进行优化改进,以增强对图像语义信息的捕获与特征提取能力,使其能够在保持相同编码长度的前提下,提供更为丰富和全面的视觉特征信息,更好地支持交通运输管理行业的多模态任务需求。图5所示为视觉提示优化模型架构,该架构包含2个关键组件:频域滤波适配器(FFA)微调模块和视觉提示生成模块。

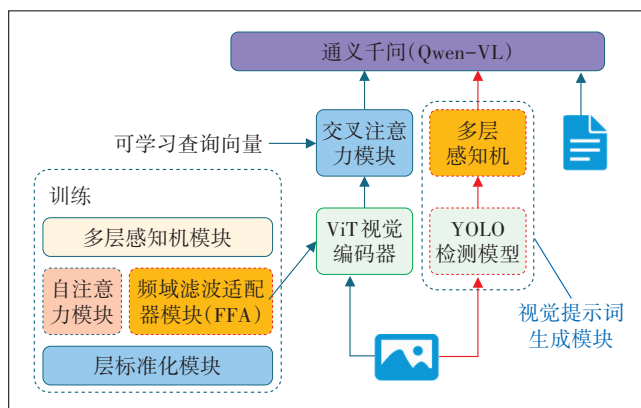


图5 视觉提示优化模型架构

频域滤波适配器(FFA)微调模块用于提升多模态大模型对城运管理场景中细节特征的理解能力。训练时,大部分Qwen-VL模型的参数被冻结,仅允许视觉编码器中的多层感知机模块、频域滤波适配器(FFA)微调模块以及交叉注意力模块进行参数更新。FFA从频域角度对图像特征进行提取,能够获取更多区别于传统视觉编码器的新特征,使模型可以从更多维度感知图像。该方法可以在不增加视觉编码器输出编码长度的情况下,实现更丰富的图像特征表达,从而显著提升模型对图像细节的感知能力。

视觉提示词生成模块采用YOLO检测模型与多层感知机模块级联的设计,其中YOLO检测模型负责提取目标的视觉特征,随后将这些特征输入多层感知机模块进行深度特征融合及语义对齐。通过针对多层

感知机模块的训练,视觉特征能够在语义层面上与语义千问语言大模型实现有效对齐,从而为多模态大模型提供精确的视觉定位参考信息。该优化策略能够显著提升模型在跨模态理解任务中的准确性和可靠性,使模型能够生成更加精准的预测结果。

2.3 个性化联邦学习

联邦学习作为一种突破性的分布式机器学习框架,在隐私保护与数据价值释放之间找到了平衡。它能够在严格保护数据机密性的同时,实现去中心化的协同训练。其核心思想是“数据不动模型动,数据可用不可见”,允许多个参与方在不共享原始数据的前提下,通过迭代优化实现模型的逐步改进,迭代优化过程步骤如下。

a) 协调方建立基本模型,并将模型的基本结构与参数告知各参与方。

b) 各参与方利用本地数据,在本地独立进行模型训练;并将本地模型参数返回给协调方。

c) 协调方汇总各参与方的模型参数,构建更精准的全局模型,以整体提升模型性能和效果。

d) 协调方将聚合后的全局模型分发给所有参与方。

这个联邦优化循环会持续进行,直到模型达到收敛标准,并且在整个工作流程中,所有原始训练数据都严格保存在本地。该架构确保敏感信息不会离开其原始管辖范围,同时仍能实现集体知识的提炼。

经典联邦学习算法是谷歌提出的联邦平均(FedAvg)算法。其核心思想是,在多个客户端对模型进行本地训练后,服务器对所有客户端的模型参数进行加权平均,从而得到新的全局模型。这种算法不仅能有效保护客户端的数据隐私,还能显著降低协同模型训练中的通信开销。

智能交通系统中的数据通常分布在不同的机构和部门之间,包括交通管理部门、运输企业和互联网公司。由于种种原因,这些数据难以共享,形成了数据孤岛。联邦学习支持跨机构、跨部门的数据协同,且无需进行数据传输,这打破了数据孤岛,充分利用了各方的数据资源,提升了智能交通模型的准确性和泛化能力。例如,交通管理部门和互联网地图公司可以通过联邦学习开展合作,利用前者的实时交通流量数据和后者的用户出行数据,共同训练交通拥堵预测模型,从而为公众提供更精准的交通信息服务。

尽管联邦学习在隐私保护和去中心化协同方面

具有显著优势,但它面临着一个关键挑战:各参与方之间的数据异构性(数据在标签、特征、质量及数量上的不均衡性)。这种情况下,每个客户端的本地数据分布可能与全局分布存在显著差异。这种差异会导致如下2个关键问题。

a) 目标不一致。本地模型更新的优化目标与全局模型的优化目标存在偏差。

b) 收敛次优。服务器分发的全局模型可能与各个客户端的最优解存在较大差距,从而降低整体性能。

为了减轻数据异构性带来的影响,客户端的贡献评估变得至关重要。有效的评估能够通过筛选出恶意或低质量的参与者,增强模型的稳健性;能够通过量化每个客户端对全局模型性能的影响,提高公平性。

常见的评估方法包括参与者上报(操作简单,但容易出现不实情况)、个体表现评估(例如,验证准确率)、效用博弈(例如,基于效用的激励机制)和基于沙普利值(Shapley Value)的方法(由于其具有公平性保障,是目前应用最广泛的方法)。

为了克服数据异构性对联邦学习性能下降的影响,众多学者提出多种个性化联邦学习(Personalized Federated Learning, PFL)算法,旨在缓解非独立同分布(non-Independent and Identically Distributed, non-IID)场景下的性能下降问题。这些先进方法主要围绕如下3个关键目标展开。

a) 情境化模型适配:调整全局模型知识,使其与本地数据分布相匹配;在保留领域特定模式的同时,维持协同优势。

b) 泛化性-个性化平衡:优化模型通用性与客户端定制性之间的权衡;开发用于参数聚合的自适应加权机制。

c) 非独立同分布收敛优化:采用新颖的优化技术以改善收敛效果;解决异构数据环境中的梯度冲突问题。

针对数据异构导致的联邦学习模型性能下降问题,本文提出一种基于贡献度评估的个性化联邦学习算法(Personalized Federated Learning based on Contribution Evaluation, pFedCE)。该算法利用生成的评估数据集计算客户端之间的沙普利值作为个性化贡献度,并基于该指标引导个性化模型聚合,使得每个客户端获得更符合其数据分布的模型。如图6所示,基

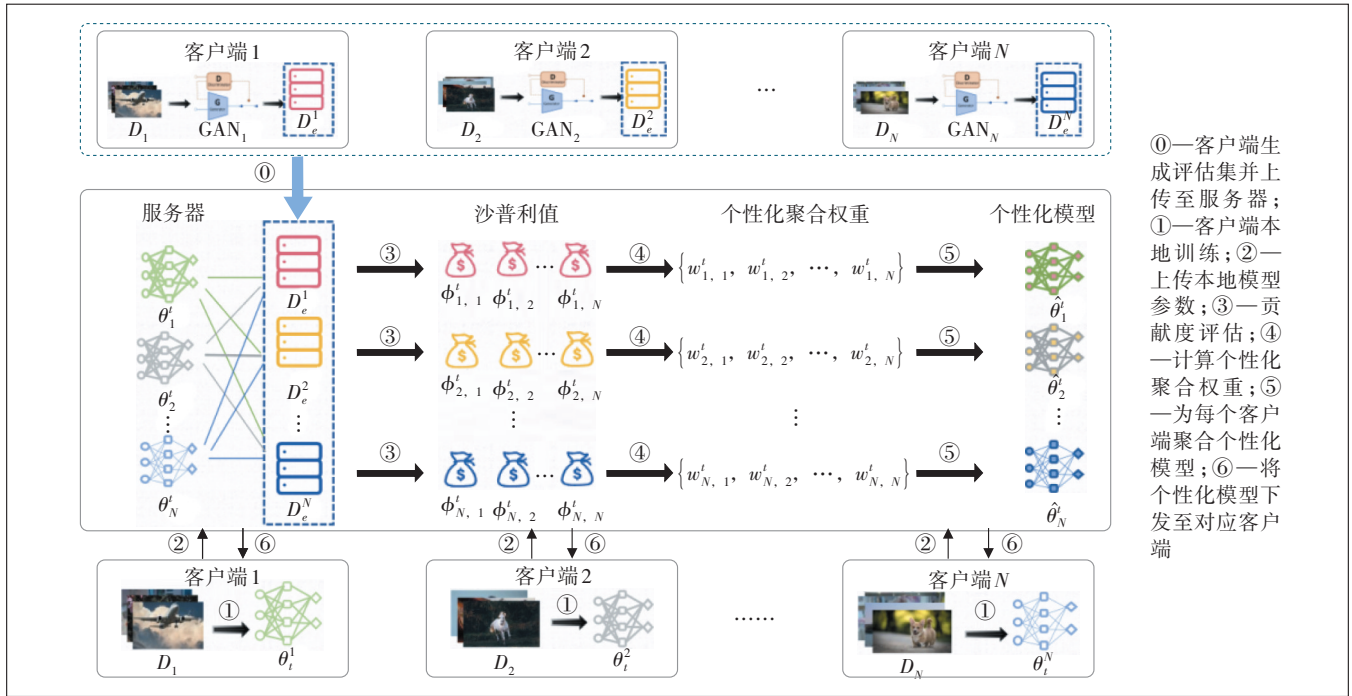


图6 pFedCE 算法框架

于贡献评估的个性化联邦学习算法(pFedCE)框架通过引入沙普利值动态计算机制,实现了客户端模型聚合权重的精准分配,从而构建了一个兼具个性化特征与贡献感知能力的模型聚合系统。

为了评估 pFedCE 的有效性,本文采用计算机视觉中的2个基准数据集(MNIST、Cifar-10)进行了测试对比。实验结果如表1所示,从表1可以看出,pFedCE在数据实际异构场景下的测试准确率较传统联邦学习算法最高提升43.02%,较最先进个性化联邦学习算法最高提升4.73%。

3 总结与展望

本文对智能交通中通信—感知—计算三元协同

表1 实际异构场景下各算法的测试准确率(单位:%)

算法	Fashion-MNIST	Cifar-10
FedAvg	70.36±0.53	46.91±0.51
FedProx	71.40±0.46	47.27±0.41
Per-FedAvg	97.27±0.39	85.02±0.53
FedRep	98.56±0.21	86.92±0.47
Ditto	97.17±0.24	88.15±0.54
FedAMP	98.01±0.28	88.69±0.59
FedFomo	98.67±0.22	87.91±0.55
APPLE	98.38±0.35	87.55±0.40
pFedCE	98.87±0.33	89.93±0.43

关键技术展开了深入研究,详细阐释了通感一体、多模态行业大模型、个性化联邦学习等关键技术要点。这些技术相互融合、协同作用,为智能交通系统的智能化、高效化发展提供了有力支撑。通感一体技术通过将通信与感知功能深度融合,提升了智能交通系统的信息获取能力,为交通感知提供了新的思路和方法,但在信号干扰、系统复杂度和标准规范等方面仍面临挑战。多模态行业大模型基于大规模交通数据训练,能够对复杂交通场景进行准确理解和预测;为进一步提升多模态大模型在事件定位任务中的性能,本文提出了一种基于视觉提示的优化策略,可大幅提升复杂交通事件的定位准确性。联邦学习在保障数据隐私的前提下,实现多源数据联合建模与分析;针对联邦学习参与方数据分布异构性问题的挑战,本文提出一种基于贡献度评估的个性化联邦学习算法框架,克服数据异构性对联邦学习性能下降的影响。通过上述技术的协同创新,有效解决智能交通系统中的实时响应、场景理解与隐私保护等核心问题。

随着政策支持力度不断加大,智能交通系统未来将朝着车路云一体化深度融合,研究可从以下方向展开:一是深化通感一体技术的理论研究和应用实践,探索更高效的信号设计与处理算法,提升通感系统在复杂交通环境下的性能,并推动相关标准规范的完善;二是进一步优化多模态行业大模型,结合知识图

谱、检索增强生成(RAG)、强化学习等技术,增强模型对交通复杂场景的理解和决策能力,同时降低模型训练和部署成本;三是推进联邦学习技术在智能交通中的应用,研究更高效的通信优化和异构数据处理方法,加强安全防护体系建设,促进跨区域、跨部门交通数据的深度融合与共享。

参考文献:

[1] 丁飞,张楠,李升波,等.智能网联车路云协同系统架构与关键技术研究综述[J].自动化学报,2022,48(12):2863-2885.

[2] CHEN S Z, HU J L, SHI Y, et al. LTE-V: a TD-LTE-based V2X solution for future vehicular network[J]. IEEE Internet of Things Journal, 2016, 3(6):997-1005.

[3] 陈山枝,葛雨明,时岩.蜂窝车联网(C-V2X)技术发展、应用及展望[J].电信科学,2022,38(1):1-12.

[4] 陈山枝. C-V2X车联网赋能智能驾驶和智能交通[J].智能网联汽车,2023(1):36-39.

[5] IMT-2020(5G)推进组. 5G-Advanced场景需求与关键技术[R/OL]. [2025-08-26]. <https://www.docin.com/p-4664396723.html>.

[6] 3GPP. Service requirements for integrated sensing and communication: 3GPP TS 22.137 V19.1.0 [S/OL]. [2025-08-26]. https://www.3gpp.org/ftp/specs/archive/22_series/22.137.

[7] 高鹏,周飞飞,王启兴,等. 6G协同通感一体化技术的性能评估与系统设计[J].电信科学,2024,40(8):94-107.

[8] 华为技术有限公司. 迈向智能世界白皮书:加速迈向5.5G,使能从万物互联到万物智联[EB/OL]. [2025-08-26]. <https://www.fx-baogao.com/detail/5064834>.

[9] 高帅,李福昌,张忠皓,等. 5G-A毫米波移动通信产业现状与应用挑战[J].邮电设计技术,2025(1):33-38.

[10] CHEPURI S P, SHLEZINGER N, LIU F, et al. Integrated sensing and communications with reconfigurable intelligent surfaces: from signal modeling to processing [J]. IEEE Signal Processing Magazine, 2023, 40(6):41-62.

[11] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16x16 words: transformers for image recognition at scale [EB/OL]. [2025-08-26]. <https://arxiv.org/abs/2010.11929>.

[12] RADFORD A, KIM J W, HALLACY C, et al. Learning transferable visual models from natural language supervision [C]//Proceedings of the 38th International Conference on Machine Learning. Online: PMLR, 2021:8748-8763.

[13] KIM W, SON B, KIM I. Vilt: vision-and-language transformer without convolution or region supervision [C]//Proceedings of the 38th International Conference on Machine Learning. Online: PMLR, 2021: 5583-5594.

[14] SOMVANSHI S, BARUA S, LIU J L, et al. Gen-AI for transportation planning [J]. Journal of the Association for Computing Machinery, 2024, 37(4):1-13.

[15] 沈佳庆. 面向城运管理的多模态行业大模型研究[D].杭州:中国科学院大学杭州高等研究院,2025.

[16] YIN S K, FU C Y, ZHAO S R, et al. A survey on multimodal large language models [J]. National Science Review, 2024, 11(12): nwae403.

[17] MCMAHAN B, MOORE E, RAMAGE D, et al. Communication-efficient learning of deep networks from decentralized data [C]//Proceedings of the 20th International Conference on Artificial Intelligence and Statistics. Florida: PMLR, 2017:1273-1282.

[18] YANG Q, LIU Y, CHEN T J, et al. Federated machine learning: Concept and applications [J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2019, 10(2):1-19.

[19] HUANG X W, HUANG T, GU S S, et al. Responsible federated learning in smart transportation: outlooks and challenges [J]. IEEE Internet of Things Magazine, 2024, 7(5):22-28.

[20] SUN Q H, LI X, ZHANG J Y, et al. ShapleyFL: robust federated learning based on shapley value [C]//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. New York: Association for Computing Machinery, 2023:2096-2108.

[21] LUO J, WU S D. Adapt to adaptation: learning personalization for cross-silo federated learning [M]//DE RAEDT L. Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence, (IJCAI-22). California: International Joint Conferences on Artificial Intelligence Organization, 2022:2166-2173.

[22] WU L J, GUO S, DING Y H, et al. Rethinking personalized client collaboration in federated learning [J]. IEEE Transactions on Mobile Computing, 2024, 23(12):11227-11239.

[23] MARFOQ O, NEGLIA G, BELLET A, et al. Federated multi-task learning under a mixture of distributions [C]//Proceedings of the 35th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2021:15434-15447.

[24] 李泉宏. 面向数据异构场景的联邦学习技术研究[D].杭州:中国科学院大学杭州高等研究院,2025.

[25] 史春磊,蔡超,邱佳慧,等.车路协同网络实现方案[J].邮电设计技术,2023(6):41-46.

[26] 3GPP. Architecture enhancements for 5G system (5GS) to support network data analytics services: 3GPP TS 23.288 V19.3.0 [S/OL]. [2025-08-26]. <https://www.3gpp.org>.

[27] TSIMPOUKELLI, MariaRafailia, MENICK, et al. Multimodal Few-Shot Learning With Frozen Language Models: AU2024227407A [P]. 2024-11-07.

作者简介:

汪保友,毕业于复旦大学,正高级工程师,博士,主要研究方向为5G-A无线通信技术、大数据与人工智能、车联网;沈佳庆,毕业于中国科学院大学杭州高等研究院,硕士,主要研究方向为多模态大模型、电子信息工程;李泉宏,毕业于中国科学院大学杭州高等研究院,硕士,主要研究方向为联邦学习、人工智能。