

# 基于移动性预测的车联网联邦学习资源调度<sup>①</sup>



赵梓源<sup>1</sup>, 金子龙<sup>2</sup>

<sup>1</sup>(南京信息工程大学 软件学院, 南京 210044)

<sup>2</sup>(浙江理工大学 信息科学与工程学院 (网络空间安全学院), 杭州 310018)

通信作者: 金子龙, E-mail: [zljn@outlook.com](mailto:zljn@outlook.com)

**摘要:** 联邦学习被广泛应用于移动网络, 采用分布式的方法进行本地和全局模型训练, 可以有效确保数据安全. 但是联邦学习在车联网中的应用又面临着 3 大挑战: 频繁的全局通信导致高延迟, 车辆有限的计算和电力资源以及高动态网络环境引起的带宽波动. 这些因素共同对联邦学习系统的执行造成了阻碍, 显著地降低了系统效率. 为了解决这些问题, 本文提出一种融合了移动性和带宽预测与多智能体强化学习的自适应资源调度策略. 在该策略中提出一个多维度预测模型, 将小波神经网络 (WNN) 和扩展的长短期记忆 (xLSTM) 网络结合作为预测模型, 针对车辆移动位置和带宽这两个维度进行预测, 为多智能体强化学习框架提供了准确输入. 同时采用多代理深度 Q 网络 (MADQN) 的动态资源调度算法来解决资源分配和功率控制挑战, 以此降低拖尾问题对系统效率的影响, 使边缘节点能够自主决策. 实验结果表明, 与传统方法相比, 本文方法有效地降低了系统成本和能耗, 同时模型性能也有一定提升, 并提高了传输成功率.

**关键词:** 联邦学习; 车联网 (IoV); 多智能体强化学习; 带宽预测; 资源调度

引用格式: 赵梓源, 金子龙. 基于移动性预测的车联网联邦学习资源调度. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10084.html>

## Resource Scheduling Based on Mobility Prediction for Federated Learning in Internet of Vehicles

ZHAO Zi-Yuan<sup>1</sup>, JIN Zi-Long<sup>2</sup>

<sup>1</sup>(School of Software, Nanjing University of Information Science & Technology, Nanjing 210044, China)

<sup>2</sup>(School of Information Science and Engineering (School of Cyber Science and Technology), Zhejiang Sci-tech University, Hangzhou 310018, China)

**Abstract:** Federated learning is widely applied in mobile networks, utilizing a distributed approach for both local and global model training, effectively ensuring data security. However, its application in Internet of Vehicles faces three major challenges: frequent global communication causing high latency, limited computational and power resources of vehicles, and bandwidth fluctuations induced by highly dynamic network environments. These factors collectively hinder the execution of federated learning systems and significantly reduce efficiency. To address these issues, this study proposes an adaptive resource scheduling strategy integrating mobility and bandwidth prediction with multi-agent reinforcement learning. This strategy introduces a multidimensional prediction model combining wavelet neural network (WNN) and extended long short-term memory (xLSTM) to forecast vehicle mobility positions and bandwidth, providing accurate inputs for the multi-agent reinforcement learning framework. Concurrently, a multi-agent deep Q-network (MADQN) dynamic resource scheduling algorithm is employed to tackle resource allocation and power control challenges, thus mitigating the impact of the tail problem on system efficiency and enabling autonomous decision-making by edge nodes. Experimental results show that, compared to traditional methods, this approach significantly reduces system costs and energy consumption, while improving model performance and transmission success rates.

<sup>①</sup> 基金项目: 国家自然科学基金面上项目 (62271264); 浙江省“尖兵领雁+X”重大科技计划 (2025C02033)

收稿时间: 2025-08-05; 修改时间: 2025-08-28; 采用时间: 2025-09-26; csa 在线出版时间: 2026-01-08

**Key words:** federated learning (FL); Internet of Vehicles (IoV); multi-agent reinforcement learning; bandwidth prediction; resource scheduling

随着智能交通系统的蓬勃发展,车载自组织网络(VANET)<sup>[1]</sup>作为其核心支撑技术之一,日益成为研究与实践的热点.该网络通过将行驶中的车辆及路边基础设施动态地组织成一个无需固定基础设施即可通信的移动自组织网络,实现车辆间(V2V)以及车辆与基础设施间(V2I)实时、可靠的信息交互.这种独特的网络形态,旨在显著提升道路交通安全、大幅优化交通运行效率,并为驾乘人员提供丰富的信息服务.然而,车辆的高速移动性<sup>[2]</sup>、网络拓扑的剧烈动态变化<sup>[3]</sup>、对通信时延与可靠性的严苛要求以及大规模部署中的安全隐私挑战,都使得VANET的设计、优化与部署面临着系列待解决的关键科学问题与技术难点.深入探究VANET的关键技术与性能保障机制,对于构建安全、高效、智慧的下一代交通体系具有重要的理论意义和广阔的应用前景.

车辆节点固有的高移动性导致通信和计算资源可用性的毫秒级波动,使得传统的资源分配方案不足.使这一挑战更加复杂的是,车辆身份隐私、车辆位置隐私以及车辆数据隐私<sup>[4]</sup>都限制了集中式机器学习范式的适用性.联邦学习(federated learning, FL)<sup>[5]</sup>作为一种突破性的隐私保护机器学习范式,通过分布式模型训练机制实现了“数据不动模型动”以及“数据可用不可见”的核心思想.该技术允许多个终端设备在本地处理原始数据,仅将加密的模型参数更新上传至中央服务器进行聚合,从根本上规避了集中式数据处理带来的隐私泄露风险.然而,在VANET中部署FL面临着重大挑战.一方面,汽车集群的资源极其有限.另一方面,车辆的高移动性导致信道状态的快速动态变化,使传统的信道分配和功率控制方案无效,这加剧了资源供需的高度动态性.高速移动车辆不断切换连接的服务器,进一步导致对通信和计算资源的需求随着时间的推移而发生剧烈变化.

因此,本研究关注高移动性VANET场景,旨在通过多智能体强化学习解决车辆移动性带来的信道分配和功率控制挑战,实现自适应资源调度.具体而言,本研究从车辆机动性预测入手,预测车辆的运动轨迹,并将预测信息作为多智能体强化学习的输入,以学习自

适应资源调度策略.本文的贡献如下.

(1) 提出一种多维度预测模型,该模型将小波神经网络和扩展的长短期记忆网络进行了结合,通过小波神经网络解决了车辆轨迹非平稳的问题,并将带宽数据和轨迹数据通过扩展的长短期记忆网络进行预测,为后续的资源调度过程提供准确可靠的输入.

(2) 介绍一种基于多智能体强化学习的自适应资源调度策略.该策略为给车辆带来高移动性的VANET中的信道分配和功率控制困难提供了一种有效的解决方案.

(3) 我们引入了Diffie-Hellman密钥交换协议以及HKDF进行密钥派生,以确保在参数聚合阶段进行加密通信.

(4) 我们采用NYU-METS数据集提取带宽数据,并采用NGSIM数据集提取车辆移动数据进行实验,以此来模拟真实环境中车联网的影响.

本文第1节总结联邦学习中进行资源分配的相关研究工作.第2节介绍FL框架的信道以及消耗模型.第3节对所解决的问题进行描述.第4节详细介绍我们对车辆移动性和带宽预测的策略.第5节对应用了多智能体强化学习的自适应资源分配方案进行介绍.第6节中与传统的方法进行了对比.最后,这项工作的贡献总结在第7节中.

## 1 相关工作

在联邦学习中,资源调度是实现高效模型训练的关键因素.

### 1.1 静态资源分配

传统的资源调度策略主要侧重于参与者选择和通信资源管理.Nguyen等人<sup>[6]</sup>提出了一种用于多个联邦学习服务的联合计算和通信资源分配框架.Xu等人<sup>[7]</sup>提出了一种用于无线边缘网络中多个联邦学习服务的资源分配框架.Salh等人<sup>[8]</sup>通过提出物联网边缘智能的节能框架,解决了联邦学习中的能耗问题.Dinh等人<sup>[9]</sup>研究了无线网络上联邦学习中的收敛分析和资源分配问题.Sun等人<sup>[10]</sup>提出了一种基于FL的框架,优化上行链路资源分配和参数量化,以减少通信开销并改善FL

训练. Liu 等人<sup>[11]</sup>提出了一种存储感知的用户调度和带宽分配算法, 通过数据清理减轻了存储压力.

静态的资源分配方法在初始化后资源分配是固定的, 无法响应动态的变化, 会造成资源利用不均, 同时面对扩大的规模时, 会造成资源分配的冲突加剧. 因此在车联网环境下静态分配方案不再适合.

## 1.2 动态资源分配

随着网络规模的扩大和场景的日益复杂, 传统的静态资源分配方法已不足以应对动态网络环境和频繁的参与者加入或者退出. 强化学习 (RL) 技术已被采用, 以实现资源分配的智能和动态优化. 深度 Q 学习 (DQL) 和深度强化学习 (DRL) 已被广泛应用于联邦学习中的资源管理. Zhan 等人<sup>[12]</sup>提出了一种基于 DRL 的经验驱动资源分配方法, 以解决联邦学习中移动设备的资源约束问题. Wu 等人<sup>[13]</sup>介绍了一种自适应深度强化学习方法, 用于在动态网络环境中优化负载均衡. Zhang 等人<sup>[14]</sup>研究了无线网络上联邦学习中的设备调度和带宽分配问题. 此外, Zhou 等人<sup>[15]</sup>提出了一种基于局部差分隐私的协作强化学习方法. Wu 等人<sup>[16]</sup>提出了一种基于 DRL 的自适应用户调度和资源分配方案, 以最小化通信成本并确保 FL 收敛. Wang 等人<sup>[17]</sup>提出了一种基于联邦多智能体强化学习的资源分配模型, 以最小化平均信息年龄 (AoI) 并最大化最近任务的数量. Cui 等人<sup>[18]</sup>提出了一种基于强化学习的设备调度方案, 以适应间歇性的可再生能源供应, 并引入了整数线性规划带宽管理方案, 以优化通信效率. Sun 等人<sup>[19]</sup>提出 FL-EDDPG 框架, 该框架结合 LSTM 层学习设备状态和双评论家网络减少估计误差并动态地分配设备 CPU 频率和发射功率以优化训练时间和能耗. Wang 等人<sup>[20]</sup>集成了多智能体深度确定性策略梯度以及线性二次调节器以及 CVXPY 求解器, 实现动态轨迹控制和资源分配的实时优化以最小化加权能耗和延迟. Liu 等人<sup>[21]</sup>关注于无人机联邦学习的环境, 通过实时响应位置和信道变化来适应无人机移动性. Jiang 等人<sup>[22]</sup>在分层联邦架构 (HLFLM) 下, 通过进化学习优化子载波和功率分配. Fan 等人<sup>[23]</sup>提出延迟感知贪婪搜索算法 (DAGSA), 每轮通信根据位置和信道重分配资源.

而蔡玉等人<sup>[24]</sup>在车联网资源分配问题中通过多智能体强化学习的方法将每个车辆作为一个智能体最大化 V2I 总容量和 V2V 数据包交付率. 方维维等人<sup>[25]</sup>采用多智能体深度确定性策略梯度 MADDPG 的算法提

升 V2V 负载传输成功率以及 V2I 总容量. 宋晓勤等人<sup>[26]</sup>采用增强型双深度 Q 网络算法联合优化频谱共享与功率控制, 最小化网络总成本. 孙彦景等人<sup>[27]</sup>采用改进 DDQN 框架利用 DNN 压缩环境状态降低输入维度, 最大化 V2I 和 V2V 总速率保证 V2V 链路可靠性. 王辛果等人<sup>[28]</sup>在联邦 DRL 框架下, 通过深度 Q 网络优化信道接入, 来平衡 V2I 容量与 V2V 传输成功率, 实时响应频谱.

现有研究一部分采用了基于 DRL 的资源调度算法, 但它们通常优先考虑资源利用率或模型训练效率, 忽视了移动边缘网络场景的细微差别, 因此缺乏对高度动态环境的适应性. 还有一部分研究采用了进化算法的方式, 这种方式需要在每一轮迭代重新评估种群, 当场景规模变大时, 计算复杂度会很高以致无法响应信道的变化. 因此, 为了应对高度移动边缘网络中资源分配和联邦学习训练的挑战, 需设计一个自适应资源调度方案, 以全面考虑由于移动性和节点异构性对模型训练的复杂影响而导致的资源动态变化, 确保联邦学习模型训练的稳定性和可靠性.

## 2 模型构建

如图 1 所示, 本研究包括一个网络化道路场景, 该网络由一个基站 (BS)、几个配备移动边缘计算服务器的路侧单元 (RSU)、任务车 (TV) 和空闲车 (IV) 集成而得. 在这种情况下, 车辆可与基础设施、其他车辆进行通信. 将车辆到基础设施 (V2I) 的链路集定义为  $N_m = \{1, 2, \dots, m\}$ , 车辆到车辆 (V2V) 的链路集定义为  $N_k = \{1, 2, \dots, k\}$ , 车辆集定义为  $N_n = \{1, 2, \dots, n\}$ .

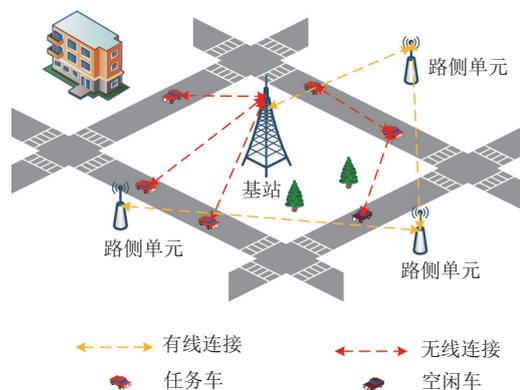


图 1 系统概述图

### 2.1 信道模型

正交频分复用 (OFDM) 将 V2I 上行链路信道划分

为多个子带, 每个子带都经历平坦衰落. V2I 链路具有固定的频谱和功率分配, 使用一个子带. V2V 链路重用这些子带. 第  $m$  条 V2I 链路和第  $k$  条 V2V 链路的信道增益可以表示如下:

$$g_m = h_m \alpha_m L(d_m) \quad (1)$$

$$g_k[m] = h_k[m] \alpha_k L(d_k) \quad (2)$$

其中,  $h_m$  表示小尺度快衰落功率分量, 假设其遵循单位均值的指数分布.  $\alpha_m$  表示第  $m$  条 V2I 链路的阴影衰落效应,  $L(d_m)$  表示其路径损耗.  $\alpha_k$  表示第  $k$  条 V2V 链路的阴影衰落效应,  $d_k$  表示设备之间的相对距离. 路径损耗模型通常表示为:

$$L(d) = L_0 \left( \frac{d}{d_0} \right)^{-\eta} \quad (3)$$

其中,  $L_0$  是参考路径损耗,  $d_0$  为参考距离,  $\eta$  是路径损耗指数.

类似地, 利用第  $m$  个子带的第  $k$  条 V2V 链路的信道增益可以表示为  $g_k[m]$ . 第  $k$  条 V2V 链路的直接信道增益由  $g_{k',k}[m]$  表示, 而从第  $k$  条 V2V 链路到 BS 的信道增益表示为  $g_k[m]$ . 因此, 共享第  $m$  个子带的第  $m$  条 V2I 链路和第  $k$  条 V2V 链路的信干噪比 (SINR) 可表示为:

$$\gamma_m^c = \frac{P_m^c g_m}{\sigma^2 + \sum_k \rho_k[m] P_k^d[m] g_k[m]} \quad (4)$$

$$\gamma_k^d[m] = \frac{P_k^d[m] g_k[m]}{\sigma^2 + I_k[m]} \quad (5)$$

其中,  $P_m^c$  和  $P_k^d[m]$  表示第  $m$  个 V2I 发射机和第  $k$  个 V2V 发射机分别第  $k$  个子带上运行.  $\sigma^2$  表示加性噪声功率.  $\rho_k[m]$  表示 V2V 链路第  $m$  个子带的使用状态, 1 表示使用, 0 表示不使用.

为简单起见, 每个 V2V 链路的每个时隙最多可以重用一个子载波, 即  $\sum_m \rho_k[m] \leq 1$ .  $I_k[m]$  是干扰功率, 定义为:

$$I_k[m] = P_m^c g_{m,k} + \sum_{k' \neq k} \rho_{k'}[m] P_{k'}^d[m] g_{k',k}[m] \quad (6)$$

假设第  $m$  个子带 V2I 链路和第  $k$  个子带 V2V 链路的带宽为  $W_m$  和  $W_k$ , 则第  $m$  个子带 V2I 链路和第  $k$  个子带 V2V 链路的信道容量为:

$$C_m^c = W_m \log(1 + \gamma_m^c) \quad (7)$$

$$C_k^d[m] = W_k \log(1 + \gamma_k^d[m]) \quad (8)$$

## 2.2 能耗模型

在这项研究中,  $c_n$  表示处理单个数据样本所需的

平均 CPU 周期数. 在第  $k$  轮训练中, 车辆  $n$  消耗  $|D_n^k| c_n$  CPU 周期来处理其本地数据集. 设  $f_n$  表示车辆  $n$  的计算能力, 以每秒 CPU 周期为单位. 然后, 单个局部训练迭代的持续时间可以计算为:

$$T_l^k(n) = \frac{|D_n^k| c_n}{f_n} \quad (9)$$

CPU 每单位时间的计算能力由  $e(n) = \rho_n f_n^3$  表示. 设  $\rho_n$  表示开关电容效率. 因此, 按车辆  $n$  计算的本地训练能耗计算如下:

$$E_l^k(n) = e(n) T_l^k(n) = \rho_n c_n |D_n^k| f_n^2 \quad (10)$$

设  $w_n$  表示车辆  $n$  的模型更新的大小. 将这些更新上传到服务器所需的上行链路传输延迟为  $T_c^k(n) = \frac{|w_n|}{c_m}$ . 因此, 数据上传过程所需的能耗定义如下:

$$E_c^k(n) = P_n T_c^k(n) \quad (11)$$

其中,  $P_n$  是车辆  $n$  的发射功率.

## 3 问题描述

该优化旨在提高 V2I 传输速率, 同时确保 V2V 连接的可靠性并满足其延迟需求. 这涉及两个主要方面, 如第 3.1 和 3.2 节所述.

### 3.1 V2I 数据传输速率

为确保车辆用户在高速移动场景中获得流畅的服务体验. V2I 链路的总传输速率需在一定时间内最大化:

$$\max \sum_{m \in M} C_m^c \quad (12)$$

### 3.2 V2V 可靠性

由于 V2V 链路传输安全关键信息, 因此必须保证可靠性. 为了检查大小为  $B$  的数据包是否在时间  $T$  内成功传输, 将问题定义为:

$$\Pr \left( \sum_{t=1}^T \sum_{m=1}^M \rho_k[m, t] C_k^d[m] \geq B/T \right) \quad (13)$$

优化目标可以概括如下:

$$\begin{cases} \max_{\rho_k[m], P_k^d[m]} \left\{ \sum_{m \in M} C_m^c, \Pr \left( \sum_{t=1}^T \sum_{m=1}^M \rho_k[m, t] C_k^d[m] \geq B/T \right) \right\} \\ \text{s.t.} \begin{cases} \text{C1: } 0 \leq P_k^d[m] \leq P_{\max}^d \\ \text{C2: } \sum_{m \in M} \rho_k[m] = 1 \end{cases} \end{cases} \quad (14)$$

## 4 多维度预测模型

本文所提模型的主要结构如图2所示。

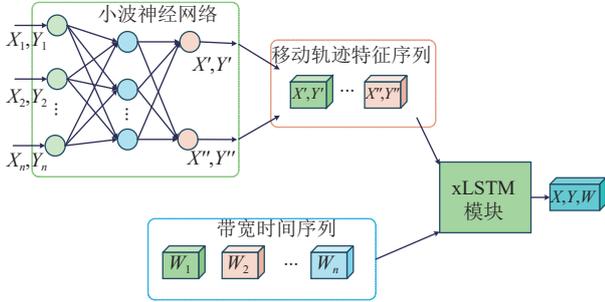


图2 预测模型图

### 4.1 小波神经网络模型

车辆在行驶中会经历匀速、加速、急转弯等状态切换,导致数据统计特性随时间剧烈变化,为了处理车辆这样不平稳的数据,首先使用小波变换对车辆的历史轨迹数据  $x(t)$  进行多尺度分解,以提取不同时间尺度的特征。小波变换可以表示为:

$$W(a, b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}^*(t)dt \quad (15)$$

其中,  $\psi_{a,b}(t) = \frac{1}{\sqrt{a}}\psi\left(\frac{t-b}{a}\right)$  是尺度为  $a$ 、平移为  $b$  的小波基函数,  $*$  表示复共轭。通过调整尺度  $a$  和平移  $b$ , 可以分别提取车辆轨迹的短期变化和长期趋势分量。

### 4.2 xLSTM 模型

本文在 xLSTM 模型中采用指数门控机制来取代传统的 Sigmoid 函数。这种设计增强了门控输出范围的动态调整能力,特别是在处理复杂的非线性变化时。指数门控函数可以表示为:

$$G(x) = \exp(W \cdot x + b) \quad (16)$$

其中,  $W$  和  $b$  是门控参数。该机制通过调整激活强度增强了模型对细粒度变化的敏感性,并在建模多尺度特征方面提供了更大的灵活性。

输出门和隐藏状态更新: 根据当前内存状态更新隐藏状态。

$$o_t = \exp(W_o \cdot [h_{t-1}, x_{input}(t)] + b_o) \quad (17)$$

$$h_t = o_t \otimes \tanh(M_t) \quad (18)$$

其中,  $\tanh$  表示双曲正切函数,  $h_t$  是隐藏状态, 作为车辆位置预测以及带宽预测的输出。

### 4.3 移动性预测

我们将小波神经网络提取到的特征作为输入, 通

过 xLSTM 模型获取预测位置结果。假设预测的未来车辆位置为  $\hat{x}(t+k)$ , 预测函数可以定义为:

$$\hat{x}(t+k) = f_{\text{LSTM}}(x_{\text{input}}(t), h_t) \quad (19)$$

其中,  $k$  表示未来预测步长,  $f_{\text{LSTM}}$  表示 xLSTM 的非线性映射函数。

### 4.4 带宽预测

因为问题优化第1个目标是最大化信道容量总和, 而信道容量依赖于发射功率以及带宽等, 因此需要得知每一个信道的带宽值才能进行之后的信道分配工作, 因此将未来带宽定义为:

$$\hat{W}(t+k) = f_{\text{LSTM}}(W_{\text{input}}(t), h_t) \quad (20)$$

## 5 基于多智能体强化学习的自适应资源调度方案

### 5.1 多智能体强化学习框架

我们将每个 V2V 链路建模为在未知环境中执行协作探索的强化学习代理。在每个时间步  $t$ , 每个代理都会获得当前环境状态  $S_t$  并选择执行动作  $A_t = \{a_t^1, a_t^2, \dots, a_t^k\}$ 。这些单独的动作被组合成一个联合动作  $a$ 。随后, 环境根据共享的奖励函数为每个代理提供奖励  $r_{t+1}$ 。下面详细描述了使用到的关键组件。

- 状态空间: 主要由当前车辆状态信息、车辆通信信息和基于预测的未来信息以及相邻车辆的资源信息组成。

因此, 状态空间设计可以表示为:

$$Z(S_t, k) = \{T_k, \{I_k[m]\}_{m \in M}, \hat{W}(t+k)\{G_k[m]\}_{m \in M}, \hat{x}(t+k), N_t\} \quad (21)$$

其中,  $N_t$  表示邻居位置和 resource 需求信息。

- 动作空间: 主要关注 V2V 链路的频谱分配和功率选择。

$$a_k = \{a_k^s, a_k^p\} \quad (22)$$

其中,  $a_k^p \in [23, 15, 5, -100]$  ( $-100$  dBm 表示零发射功率)。

- 奖励: 对于第1个目标, 本研究侧重于最大化 V2I 链路的整体通信容量  $\sum_{m \in M} C_m^c$ 。对于第2个目标, 引入了与 V2V 数据包传输相关的度量, 具体表述方式如下:

$$L_k(t) = \begin{cases} \sum_{m=1}^M \rho_k[m] C_k^d[m, t], & \text{if } B_k \geq 0 \\ \beta, & \text{otherwise} \end{cases} \quad (23)$$

在数据传输尚未完成的情况下,奖励函数被定义为 V2V 通信的传输速率.具体计算如式 (24):

$$r_t = \lambda_1 \sum_m C_m^c[t] + \lambda_2 \sum_k L_k(t) \quad (24)$$

其中,  $\lambda_1 + \lambda_2 = 1$ , 可以平衡 V2I 的容量和 V2V 的传输速率性能.

### 5.2 隐私增强

联邦学习的“数据不出域”特性本质上是对数据隐私的一种保护,但是车联网固有的高移动性导致网络拓扑快速变化, V2V 和 V2I 链路会间歇性连接且依赖中继的空闲车辆节点, 这为攻击者创造了潜在的利用窗口.

车辆节点存在一定隐患, 我们假设参与联邦学习的任务车辆以及 RSU 节点是可信的, 这些可信节点不会有恶意行为, 但是作为中继的空闲车辆本身可能会被攻击者控制或者本身存在恶意行为, 他们可能窃听模型数据造成隐私泄露问题. 与此同时攻击者可能在网络拓扑变化时伪装成中继的空闲节点进行中间人攻击 (MIMT), 当中间人与任务车辆建立连接后可能会选择性转发模型数据或者直接丢弃, 这会对整个系统性能造成影响.

因此为了进一步增强隐私安全, 我们需要对上传的模型参数进行加密, 首先我们将 Diffie-Hellman 密钥交换协议纳入联邦学习通信过程, 以确保安全通信. 如图 3 所示, Diffie-Hellman 密钥交换协议中双方共同选择一个大素数  $p$  和一个生成器  $g$ . 各方生成自己的私钥, 计算相应的公钥, 并交换这些公钥. 然后, 利用对方的公钥和自己的私钥来独立计算一个相同的共享密钥, 通过对数据的加密能够有效地确保数据隐私. 通信双方也就是密钥交换的双方是任务车辆和 RSU 节点, 这两个节点都是可信的, 但是经过动作空间的选择, 任务车辆可能会选择空闲车辆进行中转上传, 此时进行中转的车辆是否可信是无法确定的. 因此采用数字签名的方式, 由可信的 RSU 节点为这些需要中转的车辆颁发数字证书. 在进行中转转发时, 任务车辆需要先获得空闲车辆的数字证书来确定该车辆是否可信. 而数字签名也存在伪造的可能, 因此采用临时的数字签名, 当空闲车辆进入到 RSU 范围后会更新数字证书, 可以一定程度上解决中间人攻击的问题.

长期使用固定的公钥仍存在一定隐患, 给予了攻

击者更多机会去破解密钥, 并以此获取后续上传的数据. 而如果每一轮迭代都进行密钥交换来更新密钥, 需要频繁握手会造成一定的通信压力, 所以我们采用 HKDF 进行密钥派生.

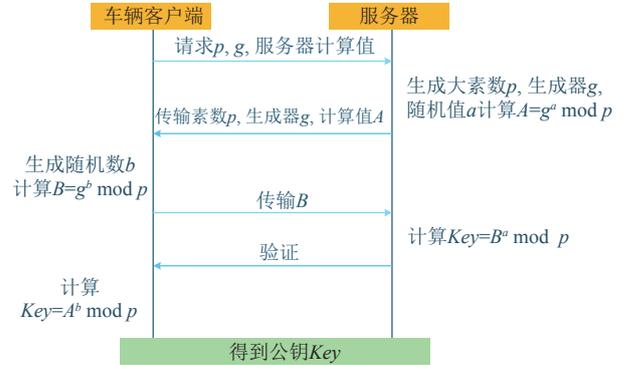


图 3 Diffie-Hellman 密钥交换协议

HKDF<sup>[29]</sup>是一种基于 HMAC 的密钥派生函数, 用于从原始密钥材料生成多个加密密钥. 由于盐值和信息参数具有随机性和不可预测性, 可以防止攻击者通过猜测或者暴力破解获取原始密钥材料, 能够有效地保护历史通信数据. HKDF 由提取和扩展两个阶段组成.

- 提取阶段:

$$PRK = \text{HMAC-Hash}(\text{salt}, IKM) \quad (25)$$

其中,  $\text{salt}$ 为随机盐, 用于增加熵值和安全性, 其长度为哈希函数的散列值长度;  $IKM$ 是原始密钥材料, 即通过 Diffie-Hellman 密钥交换协议所得到的密钥.

- 扩展阶段:

$$OKM = \text{HKDF-Expand}(PRK, \text{INFO}, L) \quad (26)$$

其中,  $\text{INFO}$ 是可选上下文和特定信息, 包含了任务车辆和 RSU 双方的信息以及联邦学习轮次;  $L$ 是密钥的长度, 当生成的密钥达到  $L$  就会输出为  $OKM$ .  $OKM$ 即为用来加密的派生密钥, 每一轮迭代都会执行 HKDF 操作.

### 5.3 理论性能分析

#### (1) 时间复杂度分析

资源调度包含了 4 个核心环节: 首先是通过小波神经网络对移动轨迹进行特征提取, 小波变换具有线性时间复杂度, 受移动轨迹序列  $L$  和小波基函数的维度  $d_w$  影响, 因此其时间复杂度为  $O(L \times d_w)$ .

其次是由 xLSTM 对提取的特征和带宽序列进行预测, 它受到特征维度  $d_f$ 、带宽数据维度  $d_b$ 、xLSTM

的隐藏层大小 $H$ 以及预测的步长 $k$ 的影响,因此其时间复杂度为 $O(k \times (d_f + d_b) \times H + H^2)$ .

然后进行智能体决策,决策由状态空间大小 $|State|$ 以及动作空间大小 $|Action|$ 来决定.由于多智能体决策是分布式决策,每个智能体单独与环境进行交互决策,因此不受参与决策的车辆数量 $N$ 影响,所以时间复杂度为 $O(|State| \times |Action|)$ .

最后,在每次选取中继的空闲节点时,需要进行证书验证.证书验证采用基于哈希链的方案,其时间复杂度为 $O(\log_2 n)$ ,其中 $n$ 为证书链的长度,由此可知单次验证复杂度不会超过 $O(\log_2 n)$ .

因此总的复杂度为:

$$O(L \times d_w + k \times (d_f + d_b) \times H + H^2 + |Action| \times |State| + \log_2 n)$$

## (2) 收敛性分析

针对状态空间 $S$ 、动作空间 $A$ 以及奖励函数 $r_t$ ,本算法收敛性由策略梯度理论保证.其满足以下3个基本假设.

假设1:奖励函数满足 Lipschitz 连续性 $\|r_t(S, A_1) - r_t(S, A_2)\| \leq L_r \|A_1 - A_2\|$ ,其中, $r_t(S, A_1)$ 表示在状态 $S$ 下采用动作 $A_1$ 得到的奖励,奖励函数的连续性仅依赖动作空间的变化.

假设2:策略函数 $\pi_\theta(A|S)$ 的梯度是有上界的,其公式为 $\mathbb{E}[\|\nabla_\theta \log \pi_\theta(A|S)\|^2] \leq G^2$ , $\nabla_\theta \log \pi_\theta(A|S)$ 是参数变化对动作选择概率的影响强度, $G^2$ 则是预先存在的常数边界,确保影响强度不会失控,有界性可以避免参数更新幅度过大.

假设3:在车联网环境下,马尔可夫决策过程的状态分布能以指数速率收敛至平稳分布,使 $\sup_{S_t \in S} \|P(S_{t+k}|S_t) - \rho^\pi\| \leq e^{-k/\tau_{\text{mix}}}$ , $\forall k > 0$ ,也就是说当前状态 $S_t$ 对 $k$ 步后的状态 $S_{t+k}$ 的影响随着 $k$ 增大而指数性衰减,衰减的速率由 $\tau_{\text{mix}}$ 决定.

策略迭代 $\theta_{k+1} = \theta_k + \eta_k \nabla_\theta J(\theta_k)$ 在熵正则化约束下满足单调提升:

$$J(\theta_{k+1}) - J(\theta_k) \geq -\frac{\eta_k L_r^2 G^2}{2} + \eta_k \|\nabla_\theta J(\theta_k)\|^2$$

经过 $K$ 次迭代后 $\min_k \mathbb{E}[\|\nabla_\theta J(\theta_k)\|] = O(1/\sqrt{K})$ .在满足这3个假设的前提下能够确保策略梯度算法的严格收敛性.

## 5.4 算法设计

本文实现了一个标准的联邦学习框架,其中每个V2V通信链路都充当一个独立的代理,负责训练本地

模型.基站扮演服务器的角色,从每个代理收集和集成模型参数.

本地训练:每个代理首先从中央服务器同步最新的全局模型参数,以初始化其本地模型.然后,使用自己的累积数据,计算模型梯度并更新其局部模型参数.

$$\theta_k^{(g)} = \theta_k^{(g-1)} - \alpha \nabla J(\theta_k^{(g-1)}) \quad (27)$$

其中, $\theta_k^{(g)}$ 表示代理 $k$ 的局部模型第 $g$ 次迭代, $\theta_k^{(g-1)}$ 是之前的全局模型, $\alpha$ 是学习率.

上传:第1次上传前,所有代理都会使用 Diffie-Hellman 密钥交换协议在每个V2V代理和基站之间建立共享密钥.在完成本地模型更新后,所有代理和基站会基于HKDF进行密钥派生.然后,此密钥用于在上传和下载过程中加密模型参数.

模型聚合:基站从所有V2V代理接收本地模型共享.只有当接收到的共享数量达到阈值 $t$ 时,基站才能执行秘密重建以恢复每个代理的本地模型参数.重建后,执行聚合操作以更新全局模型:

$$\theta^{(g)} = \frac{1}{K} \sum_{k \in K} \theta_k^{(g)} \quad (28)$$

算法1中给出了详细的过程.

### 算法1.基于MARL的联邦学习自适应资源分配

输入:车载网络的模拟环境参数,智能体神经网络参数.

输出:智能体神经网络参数.

- 1) 使用随机参数 $\theta_e$ 初始化网络;并基于 Diffie-Hellman 密钥交换协议初始化所有原始密钥材料
- 2) 开启全局迭代循环
- 3) 初始化通信链路并获得初始环境状态,进行移动性预测以及带宽预测
- 4) 每个智能体与服务器基于HKDF计算派生密钥OKM,然后根据当前观察 $Z_t$ 选择一个动作 $a_t$
- 5) 服务器根据联合动作 $A_t$ 计算全局奖励 $r_{t+1}$ ,并验证中继的空闲车辆的数字证书
- 6) 每个智能体获得下一个观察状态 $Z_{t+1}$ 并存储历史经验
- 7) 智能体基于 $\theta_k^{(g)} = \theta_k^{(g-1)} - \alpha \nabla J(\theta_k^{(g-1)})$ 更新其本地模型
- 8) 智能体经过加密后上传参数
- 9) 结束全局迭代循环

## 6 实验结果与性能分析

在本节中,研究设定了仿真参数和度量并根据不同的基线对提出的方案进行了评估.

### 6.1 实验设置

#### (1) 实验环境设置

实验环境由 Windows 11 操作系统、Intel Core i5、

NVIDIA GeForce GTX 1080Ti, 主频率为 2.5 GHz, 存储容量为 8 GB. 具体实验参数见表 1.

表 1 实验参数设置

参数	值
车辆数	20
噪声功率	-100 dBm
最大上行传输功率	17 dBm
衰减指数	2.2
单位能耗	0.003 J

## (2) 数据集设置

我们使用 MNIST 数据集<sup>[30]</sup>和 Fashion-MNIST 数据集<sup>[31]</sup>来评估所提方法在提高性能和算法准确性方面的优势, 同时采用 NYU-METS 数据集<sup>[32]</sup>提取带宽数据, 同时采用 NGSIM 数据集<sup>[33]</sup>中的数据作为车辆的真实移动数据. NYU-METS 数据集是一个在美国纽约市大都市区现场测量捕获的 LTE 移动带宽集合数据集, 用以模拟车辆的带宽. NGSIM 数据集采集于美国的 4 个不同地区, 分别是加州南向的 US101 号公路、加州洛杉矶的 Lankershim Boulevard 地图、加州埃默里维尔的东向的 I-80 号公路, 以及佐治亚州亚特拉大的 Peachtree Street. 本文使用 US101 和 I-80 号公路的相关数据.

## 6.2 性能比较

为了比较所提解决方案的优越性, 将其与多种基线方法进行比较, 包括基于 DRL 的 FL-MADDPG 算法、FL-DDPG 算法以及 FL-Greedy 算法等人工智能方法. 此外, 还有固定发射功率、以距离为优先级的调度方法以及轮流使用信道的传统方法.

如图 4 所示, 所有算法在 200 轮训练前都表现出不稳定的行为. 具体来说, 本文方法在 200 轮后收敛并稳定, 而 FL-MADDPG、FL-DDPG 和 FL-Greedy 算法分别需要大约 300、450 和 650 轮才能达到稳定. 这种差异源于 FL-DDPG 算法在非合作策略下训练, 主要侧重于个体优化. 因此, 与多代理强化学习算法相比, FL-DDPG 和 FL-Greedy 的计算成本更高. 关于系统奖励, 本文方法分别比 FL-MADDPG、FL-DDPG 和 FL-Greedy 算法提高了 4.07%、6.71% 和 15.24%.

为了评估本文方法对联邦学习模型训练的影响, 我们重点研究了模型准确性在训练轮次之间的演变.

图 5 和图 6 分别展示了 Fashion-MNIST 和 MNIST 数据集上不同算法的模型精度随训练轮次变化的曲线.

结果表明, 我们的方法在两个数据集上都达到了最高的模型精度. 具体而言, 在 Fashion-MNIST 数据集上, 本文方法最终准确率约为 88%, 比 3 种基线算法分别提高了 1.5%、2.68% 和 7.23%. 同样, 在 MNIST 数据集上, 所提方法实现了 93.2% 的最终准确率, 明显优于其他 3 种方法.

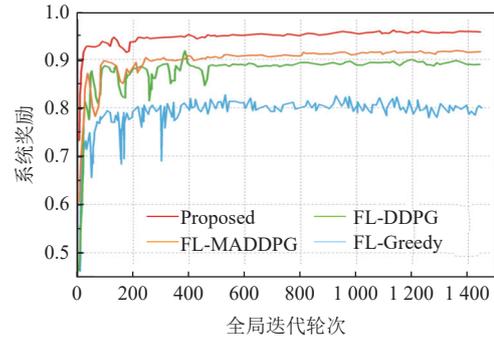


图 4 系统奖励变化

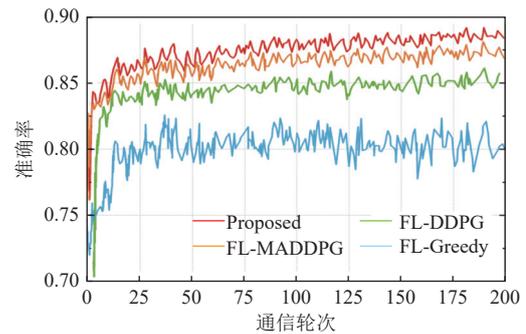


图 5 Fashion-MNIST 数据集

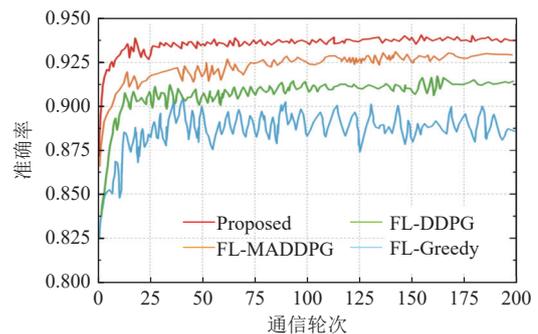


图 6 MNIST 数据集

此外, 我们评估了随着训练的进行, 每种算法在 Fashion-MNIST 数据集上的系统成本, 以及在不同批大小下的能耗, 如图 7 和图 8 所示. 由于高维状态和动作空间内的学习经验有限, 所有比较算法最初都表现出较高的系统成本. 与基线相比, 本方法具有较低的系统成本, 在最小化本地延迟和能耗方面具有显著优势.

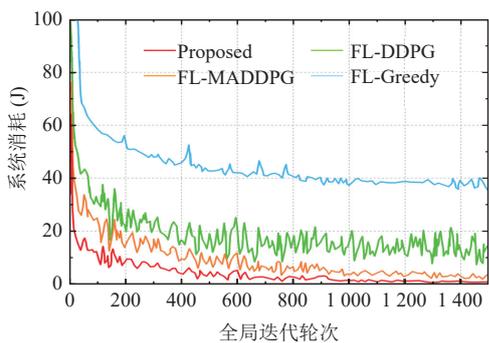


图7 系统消耗

图8描述了不同数据采样大小(批大小)下各种算法的能耗特性. 结果表明, 所有具有较大数据采样量的算法的能耗都有所增加. FL-Greedy算法表现出最高的能耗, 随着数据采样量的增加, 其增长率更加明显. 总体而言, 就能量批量大小而言, 本文方法的性能明显优于其他算法.

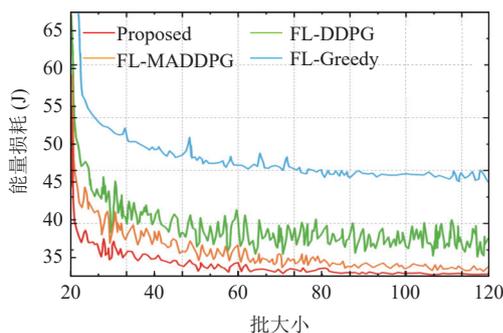


图8 批大小与能耗的相关性

图9展示了4种算法在不同数据采样大小下的传输成功率性能. 传输成功率定义为在给定时间窗口内成功传输的数据比例, 公式为 $\rho = \frac{N_{succ}}{N_{test}}$ , 其中 $\rho$ 表示传输成功率,  $N_{succ}$ 表示成功传输数据的量,  $N_{test}$ 表示测试迭代次数. 结果表明, 本文方法在传输成功率曲线上的下降速度最慢, 表明即使在大规模数据采样下, 它也能保持优异的性能. 在所有测试的样本量中, 本文方法始终优于3种基线方法. 例如, 在较大的采样尺度下, 本文方法实现了约90%的传输成功率, 而FL-MADDPG、FL-DDPG和FL-Greedy分别实现了88%、85%和80%的传输成功率.

我们还评估了本方法与传统方法的通信时间比较情况. 从图10中可以看出在这几种方法中, 基于多智能体强化学习的方法在初期花费时间高于传统方法, 这是因为强化学习方法需要进行探索学习. 随着通信

轮次的增加, 本方法的通信时间逐渐平稳. 而固定发射功率的方法在150轮以前表现出比其他传统方法更好的效果. 但此时信道的变化并不频繁, 在150轮以后, 固定功率方法无法满足快速通信的需要, 出现了大幅上升. 以距离优先的调度方式, 是以预测车辆的位置和RSU之间的距离为标准, 距离越长优先级越高. 最后由于采用轮流使用信道的方式, 通信时间呈现出一定的规律, 从图10中可见这种规律. 但如果每个车辆没有使用适合的信道, 则对于通信能力的提升并没有帮助. 整体而言, 我们的方法优于这些传统的资源分配方法.

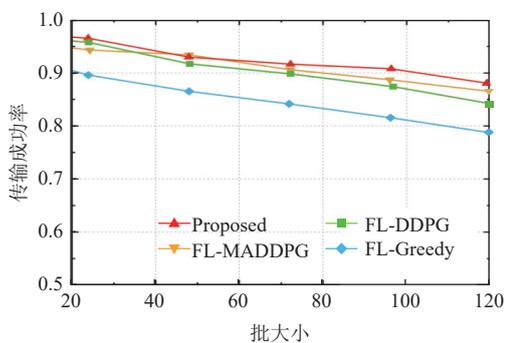


图9 批大小与传输成功率之间的相关性

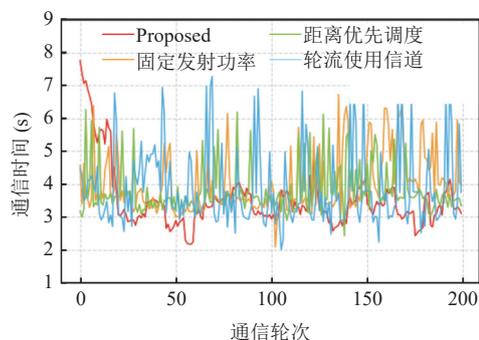


图10 与传统资源分配方案的通信时间对比

下面评估本方法与传统方法的能量损耗情况, 我们将批大小固定为60进行实验. 如图11所示, 固定发射功率的能量损耗与设置的功率值呈正相关. 而距离优先调度策略需要优先服务远距离车辆, 因此需要使用更大的功率去补偿路径损耗, 因此该方法的能量损耗更大一些. 轮流使用信道的话因为通信资源是以一定的周期进行分配, 使得每个车辆拿到的资源不稳定, 因此使用的功率也不稳定最终导致能量损耗较高. 相比较这些传统资源分配方法, 我们的方法能量损耗虽然不是最低, 但是考虑到通信时间与能量损耗的权衡, 整体是优于其他方法的.

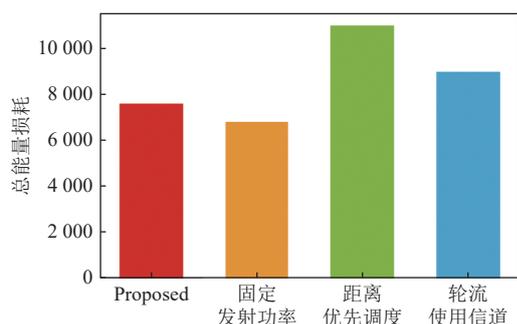


图 11 与传统资源分配方案的能量损耗对比

## 7 结论

本研究介绍了一种新的自适应资源调度策略, 该策略利用联邦 MARL 为高移动性 VANET 设计. 该策略有效地解决了车辆移动性引起的动态信道条件以及带宽变化和功率控制问题的挑战. 本文方法集成了基于 WNN 和 xLSTM 的多维度预测模型, 以提供准确的未来位置信息和带宽信息. 此外, 我们还实现了用于安全通信过程的 Diffie-Hellman 密钥交换协议以及降低密钥交换次数的 HKDF 密钥派生. 实验结果表明, 与传统方法和基线算法相比, 所提方法具有更优的性能.

### 参考文献

- Al-Shareeda MA, Alazzawi MA, Anbar M, *et al.* A comprehensive survey on vehicular ad hoc networks (VANETs). *Proceedings of the 2021 International Conference on Advanced Computer Applications*. Maysan: IEEE, 2021. 156–160.
- 钟有佳. 移动通信技术在自动驾驶中的应用与安全性研究. *中国宽带*, 2025, 21(3): 146–148. [doi: 10.20167/j.cnki.ISSN1673-7911.2025.03.49]
- 王雪飞, 王芳, 邱玉辉. 一种具有动态拓扑结构的粒子群算法研究. *计算机科学*, 2007, 34(3): 205–207, 233. [doi: 10.3969/j.issn.1002-137X.2007.03.054]
- 徐小雅, 于海洋, 崔志勇, 等. 车联网环境下的隐私安全度量方法. *同济大学学报 (自然科学版)*, 2022, 50(12): 1693–1702.
- Li T, Sahu AK, Talwalkar A, *et al.* Federated learning: Challenges, methods, and future directions. *IEEE Signal Processing Magazine*, 2020, 37(3): 50–60. [doi: 10.1109/MSP.2020.2975749]
- Nguyen MNH, Tran NH, Tun YK, *et al.* Toward multiple federated learning services resource sharing in mobile edge networks. *IEEE Transactions on Mobile Computing*, 2023, 22(1): 541–555. [doi: 10.1109/TMC.2021.3085979]
- Xu J, Wang HQ, Chen LX. Bandwidth allocation for multiple federated learning services in wireless edge networks. *IEEE Transactions on Wireless Communications*, 2022, 21(4): 2534–2546. [doi: 10.1109/TWC.2021.3113346]
- Salh A, Ngah R, Audah L, *et al.* Energy-efficient federated learning with resource allocation for green IoT edge intelligence in 5G. *IEEE Access*, 2023, 11: 16353–16367. [doi: 10.1109/ACCESS.2023.3244099]
- Dinh CT, Tran NH, Nguyen MNH, *et al.* Federated learning over wireless networks: Convergence analysis and resource allocation. *IEEE/ACM Transactions on Networking*, 2021, 29(1): 398–409. [doi: 10.1109/TNET.2020.3035770]
- Sun EC, Zhang H, He RL, *et al.* A joint resource allocation and efficient communication scheme based on FL for the Internet of vehicles. *Proceedings of the 22nd IEEE International Conference on Communication Technology*. Nanjing: IEEE, 2022. 351–356. [doi: 10.1109/ICCT56141.2022.10072709]
- Liu SL, Shen YN, Yuan JT, *et al.* Storage-aware joint user scheduling and bandwidth allocation for federated edge learning. *IEEE Transactions on Cognitive Communications and Networking*, 2025, 11(1): 581–593. [doi: 10.1109/TCCN.2024.3451711]
- Zhan YF, Li P, Guo S. Experience-driven computational resource allocation of federated learning by deep reinforcement learning. *Proceedings of the 2020 IEEE International Parallel and Distributed Processing Symposium*. New Orleans: IEEE, 2020. 234–243. [doi: 10.1109/IPDPS47924.2020.00033]
- Wu D, Xu YT, Li J, *et al.* Learning to adapt: Communication load balancing via adaptive deep reinforcement learning. *Proceedings of the 2023 IEEE Global Communications Conference*. Kuala Lumpur: IEEE, 2023. 2973–2978. [doi: 10.1109/GLOBECOM54140.2023.10437528]
- Zhang TH, Lam KY, Zhao J, *et al.* Joint device scheduling and bandwidth allocation for federated learning over wireless networks. *IEEE Transactions on Wireless Communications*, 2025, 24(1): 3–18. [doi: 10.1109/TWC.2023.3291701]
- Zhou W, Zhu TQ, Ye DY, *et al.* A concurrent federated reinforcement learning for IoT resources allocation with local differential privacy. *IEEE Internet of Things Journal*, 2024, 11(4): 6537–6550. [doi: 10.1109/JIOT.2023.3312118]
- Wu CX, Ren YJ, So DKC. Adaptive user scheduling and resource allocation in wireless federated learning networks: A deep reinforcement learning approach. *Proceedings of the*

- 2023 IEEE International Conference on Communications. Rome: IEEE, 2023. 1219–1225. [doi: [10.1109/ICC45041.2023.10279678](https://doi.org/10.1109/ICC45041.2023.10279678)]
- 17 Wang C, Yao TY, Fan TS, *et al.* Modeling on resource allocation for age-sensitive mobile-edge computing using federated multiagent reinforcement learning. *IEEE Internet of Things Journal*, 2024, 11(2): 3121–3131. [doi: [10.1109/JIOT.2023.3294535](https://doi.org/10.1109/JIOT.2023.3294535)]
- 18 Cui YG, Cao K, Wei TQ. Reinforcement learning-based device scheduling for renewable energy-powered federated learning. *IEEE Transactions on Industrial Informatics*, 2023, 19(5): 6264–6274. [doi: [10.1109/TII.2022.3210008](https://doi.org/10.1109/TII.2022.3210008)]
- 19 Sun Y, Wang JR, Jia KK. A DRL agent for federated learning resource allocation in the Internet of things. *Proceedings of the 10th International Conference on Computer and Communications*. Chengdu: IEEE, 2024. 2178–2182. [doi: [10.1109/ICCC62609.2024.10942155](https://doi.org/10.1109/ICCC62609.2024.10942155)]
- 20 Wang ZW, Wang HW, Liu LH, *et al.* Dynamic trajectory design for multi-UAV-assisted mobile edge computing. *IEEE Transactions on Vehicular Technology*, 2025, 74(3): 4684–4697. [doi: [10.1109/TVT.2024.3485182](https://doi.org/10.1109/TVT.2024.3485182)]
- 21 Liu TZ, Zhang TK, Loo J, *et al.* Deep reinforcement learning-based resource allocation for UAV-enabled federated edge learning. *Journal of Communications and Information Networks*, 2023, 8(1): 1–12. [doi: [10.23919/JCIN.2023.10087243](https://doi.org/10.23919/JCIN.2023.10087243)]
- 22 Jiang B, Cai LX, Yue GH, *et al.* Energy-efficient wireless resource allocation for heterogeneous federated multitask networks based on evolutionary learning. *IEEE Transactions on Industrial Informatics*, 2025, 21(5): 4094–4104. [doi: [10.1109/TII.2025.3538096](https://doi.org/10.1109/TII.2025.3538096)]
- 23 Fan KC, Chen W, Li J, *et al.* Mobility-aware joint user scheduling and resource allocation for low latency federated learning. *Proceedings of the 2023 IEEE/CIC International Conference on Communications in China*. Dalian: IEEE, 2023. 1–6. [doi: [10.1109/ICCC57788.2023.10233347](https://doi.org/10.1109/ICCC57788.2023.10233347)]
- 24 蔡玉, 官铮, 王增文, 等. 基于多智能体深度强化学习的车联网区分业务资源分配算法. *计算机工程与科学*, 2024, 46(10): 1757–1764. [doi: [10.3969/j.issn.1007-130X.2024.10.005](https://doi.org/10.3969/j.issn.1007-130X.2024.10.005)]
- 25 方维维, 王云鹏, 张昊, 等. 基于多智能体深度强化学习的车联网通信资源分配优化. *北京交通大学学报*, 2022, 46(2): 64–72. [doi: [10.11860/j.issn.1673-0291.20210070](https://doi.org/10.11860/j.issn.1673-0291.20210070)]
- 26 宋晓勤, 张文静, 雷磊, 等. 多目标联合优化的车联网动态资源分配算法. *东南大学学报(自然科学版)*, 2025, 55(1): 266–274.
- 27 孙彦景, 余政达, 陈瑞瑞, 等. 车联网中基于深度强化学习的高可靠资源分配算法. *重庆邮电大学学报(自然科学版)*, 2023, 35(4): 706–714. [doi: [10.3979/j.issn.1673-825X.202205230123](https://doi.org/10.3979/j.issn.1673-825X.202205230123)]
- 28 王辛果, 王昶. 一种采用联邦深度强化学习的车联网资源分配方法. *电讯技术*, 2024, 64(7): 1065–1071.
- 29 Almomani H, Alsarhan A, AlJamal M, *et al.* Securing Internet of vehicles IoV communications: A biometric and hash-key derivation function HKDF-based approach. *Proceedings of the 25th International Arab Conference on Information Technology*. Zarqa: IEEE, 2024. 1–7. [doi: [10.1109/ACIT62805.2024.10877191](https://doi.org/10.1109/ACIT62805.2024.10877191)]
- 30 LeCun Y, Bottou L, Bengio Y, *et al.* Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324. [doi: [10.1109/5.726791](https://doi.org/10.1109/5.726791)]
- 31 Kayed M, Anter A, Mohamed H. Classification of garments from fashion MNIST dataset using CNN LeNet-5 architecture. *Proceedings of the 2020 International Conference on Innovative Trends in Communication and Computer Engineering (ITCE)*. Aswan: IEEE, 2020. 238–243. [doi: [10.1109/ITCE48509.2020.9047776](https://doi.org/10.1109/ITCE48509.2020.9047776)]
- 32 Mei LF, Hu RC, Cao HW, *et al.* Realtime mobile bandwidth prediction using LSTM neural network and Bayesian fusion. *Computer Networks*, 2020, 182: 107515. [doi: [10.1016/j.comnet.2020.107515](https://doi.org/10.1016/j.comnet.2020.107515)]
- 33 FHWA. NGSIM: Next generation simulation. <https://ops.fhwa.dot.gov/trafficanalysis/tools/ngsim.htm>. (2024-02-22)[2025-07-31].

(校对责编: 张重毅)