Large Scale Resource Minimum Latency Scheduling Method for Intelligent Transportation Sensor Network*

YANG Zhonglai[1*], ZHU Tong[2]
(1.Department of Traffic Management, Shanxi Police College, Taiyuan Shanxi 030031, China;
2.School of Transportation Engineering, Chang'an University, Xi'an Shaanxi 710064, China)

Abstract: To solve the problems of data transmission delay and uneven resource allocation caused by the expansion of scale in intelligent transportation sensor networks, a large-scale resource minimum delay scheduling method for intelligent transportation sensor networks is proposed. Long short term memory (LSTM) models are used to predict sensor energy consumption, combined with resource characteristics, large-scale resource decomposition is implemented. Based on the priority of resource packets and link bandwidth, a scheduling model is constructed using the deep Q-network (DQN) algorithm. By iteratively evaluating the value of scheduling schemes at the network layer and storing and replaying high-value scheduling decisions at the memory layer, the most valuable and optimal scheduling scheme with the lowest latency is obtained. The experimental results show that this method reduces the network error rate in real traffic environments, with the maximum network error rate not exceeding 0.000 001, saving an average of 27.4 J of energy, and the resource cost is also relatively low. This indicates that the method can improve the communication efficiency, reliability, and resource utilization efficiency of intelligent transportation sensor networks.

Key words: intelligent transportation system; minimum latency scheduling; DQN algorithm; large scale resources; effective time; resource scheduling
EEACC: 7230 **doi**: 10.3969/j.issn.1004-1699.2026.09.016

智能交通传感网大规模资源最小时延调度方法*

杨忠来[1*], 朱 彤[2]
(1.山西警察学院交通管理系, 山西 太原 030031; 2.长安大学运输工程学院, 陕西 西安 710064)

摘 要: 为解决智能交通传感网中因规模扩大导致的数据传输延迟和资源分配不均问题, 提出智能交通传感网大规模资源最小时延调度方法。利用长短期记忆网络(Long Short-Term Memory, LSTM)模型预测传感器能耗, 结合资源特征, 实施大规模资源分解。并依据资源包优先级和链路带宽, 基于深度 Q 网络(Deep Q-Network, DQN)算法构建调度模型, 通过迭代网络层的调度方案价值评估和记忆层的高价值调度决策存储与回放, 获取价值最高的最优最小时延调度方案。实验结果显示, 该方法在真实交通环境下降低了网络误码率, 网络误码率最大值不超过 0.000 001, 节省的能量均值高达 27.4 J, 且资源成本也较低。这说明, 所提方法能够提升智能交通传感网的通信效率、可靠性和资源利用效率。

关键词: 智能交通系统; 最小时延调度; DQN 算法; 大规模资源; 有效时间; 资源调度
中图分类号: TN929.52 **文献标识码**: A **文章编号**: 1004-1699(2026)09-2052-09

智能交通传感网作为物联网技术在交通领域的重要应用, 在城市化进程的加快和智能交通系统的不断发展下, 逐渐成为支撑现代城市交通管理的关键技术, 且重要性日益凸显[1-2]。智能交通传感网由多个子系统和组件构成, 包括传感器节点、通信模块、数据处理中心以及能源供应系统。其中, 传感器节点包括: 用于监测道路及周边环境的状态, 为交通流量预测、道路安全评估提供数据支持的环境传感器; 用于实时检测车辆数量、速度、类型及行驶方向, 对交通拥堵进行预警的交通流量传感器; 用于监测路面损坏情况, 预防交通事故的路面状态传感器; 以及为恶劣天气条件下的交通管理提供数据依据的气象传感器等。通信模块采用无线通信技术, 用于传感器节点之间以及传感器与数据中心之间的数据传

项目来源: 山西省科学技术厅基础研究计划自由探索类项目(202403021221352)
收稿日期: 2024-08-30 **修改日期**: 2024-09-26

输。数据处理中心负责收集、处理和分析来自各传感器节点的数据,执行调度算法,优化资源配置。能源供应系统为传感器节点提供稳定的电源,可能是太阳能板、电池或混合能源系统。不同类型的数据对资源调度的需求有所不同,交通流量、路面状态等实时性要求高的数据需要快速传输和处理,以确保交通控制的及时性和有效性。调度算法应优先考虑这类数据的传输,降低其时延。环境参数等周期性报告的数据不需要实时传输,可以在满足一定时间间隔后汇总传输,以节省网络资源。事故报警等事件触发型数据具有突发性和重要性,需要立即传输并处理,调度算法应赋予其最高优先级。智能交通传感网的核心在于通过大规模部署的传感器节点,实时感知、传输与处理交通流、路况、环境等多维度交通信息,为交通管理和决策提供科学依据[3]。但随着传感网规模的扩大,数据传输量激增,数据处理的复杂性和资源调度的困难性使大规模资源的最小时延调度实现,成为智能交通传感网面临的一大挑战。特别是在紧急车辆调度、交通事故预警等实时性要求极高的应用场景下,数据传输的延迟将直接影响交通系统的响应速度和决策效果[4]。

在网络大规模资源低时延调度的学术探索历程中,众多学者已投身于广泛而深入的研究之中,并取得了诸多具有里程碑意义的成果。其中,Zheng 等[5]面向多链路速率网络,基于时间敏感网络和多周期循环排队和转发的低延迟流控制机制,实现低延迟调度。但网络在该机制的控制下,可能会出现抖动(即时延的波动),影响实时应用的性能。Bommisetty 等[6]面向基于 IEEE 802.15.4e 标准时隙信道跳频的 IPv6 网络,通过无冲突动态规划求解最大权重无关集问题,实现低延迟调度。但使用保守或贪婪方案同时调度非干扰传输会难以适应网络状态的快速变化,使调度缺乏足够的灵活性。张慎文等[7]分别基于综合数据块的性价比模型和改进深度确定性策略梯度方法,设计出数据排队与拥塞控制策略,实现低延迟智能调度。但性价比模型会因潜在的不公平性,产生优先级问题,影响系统性能。Nardini 等[8]面向车联网,基于支持设备到设备(Device-to-Device,D2D)的蜂窝网络,利用迭代分解下多项式的启发式方法,实现多跳 D2D 的低时延调度。但启发式方法不能很好地衡量精度与效率,无法切实实现全局最优。刘光远等[9]面向虚拟网络,利用人工蜂群与锦标赛策略的融合算法,获取功能链路传输与实例化的最小时延,得到功能映射节点的最优调度。但用于寻优的局部搜索算法搜索策略相对单一,可能无法找到全局最优解。

智能交通传感网在当前城市交通管理面临的交通拥堵、事故频发、环境污染等诸多挑战下,节点数量更加庞大,数据传输量激增,进而导致数据传输延迟和资源分配不均等问题日益突出,使交通传感网的复杂性和运维难度不断上升,整体性能和服务质量不断下降[10]。为解决这些问题,优化智能交通传感网的性能和服务,提出智能交通传感网大规模资源最小时延调度的研究课题,以应对现代城市交通管理的复杂需求。资源的分解处理有助于解决大规模资源管理复杂、难以处理、响应延迟及利用率低等问题;基于 DQN 算法实现资源的低时延调度,能够更好地适应智能交通传感网的动态变化特性,实现资源的高效调度和利用。

1　大规模资源最小时延调度优先级确定

1.1　智能交通传感网资源分解

在传感器节点数量激增、数据传输量爆炸性增长的背景下,确保数据传输的实时性与资源分配的高效性成为核心问题。为高效分配和管理智能交通传感网中的大规模资源,根据 LSTM 模型[11-12]预测的传感器能耗,分解资源。

假设时间步长 $t-1$ 下 LSTM 单元的隐藏状态是 h_{t-1},单元状态是 c_{t-1},利用传感器数量 N_c、时间窗口长度 T_c、每个时间步长记录的传感网特征数量 F_c 组建 $N_c\times T_c\times F_c$ 的矩阵 $\boldsymbol{X}$,得到对应切片 x_{t-1}。将 $\boldsymbol{X}$ 输入 LSTM 模型进行训练:

$$\boldsymbol{X}=\mathrm{LSTM}(x_{t-1},h_{t-1},c_{t-1}) \tag{1}$$

式中:x_t、h_t、c_t 代表 t 步长下 X 的切片与 LSTM 单元的对应状态。

利用训练过的 LSTM 模型,通过下式预测出各传感器的能耗 $\boldsymbol{X}'$,以 $N_c\times F_c$ 的矩阵形式呈现:

$$\boldsymbol{X}'=\mathrm{LSTM}(\boldsymbol{X}) \tag{2}$$

假设传感器数量是 N,信息享有类数是 M,则资源的特征矢量 $\boldsymbol{G}$ 为:

$$\boldsymbol{G}=\begin{bmatrix} g_{11} & g_{12} & \cdots & g_{1M} \\ g_{21} & g_{22} & \cdots & g_{2M} \\ \vdots & \vdots & \ddots & \vdots \\ g_{N1} & g_{N2} & \cdots & g_{NM} \end{bmatrix} \tag{3}$$

在有向无环图[13]中,每个顶点代表一个计算行为或资源处理单元。在智能交通传感网中,这些顶点对应为不同的传感器节点、数据处理中心或数据传输链路等。根据资源分解的需求,顶点进一步细化为不同的计算任务或数据处理阶段,包括数据采

集、预处理、特征提取、模型推理等。有向无环图中的边表示顶点之间的依赖关系或数据流。在智能交通传感网中,这些边代表数据从传感器节点传输到数据处理中心的路径,或者数据处理中心内部不同计算任务之间的依赖关系。边的权重表示数据传输的延迟、资源消耗或计算复杂度,用于在资源调度时进行优化。用有向无环图表征待计算的资源,首先,根据智能交通传感网的架构和数据处理流程,确定有向无环图中的节点和边。然后,根据节点之间的数据流动和计算依赖关系,建立有向无环图中的边。最后,根据资源分配和调度的需求,对有向无环图进行优化调整,以减少数据传输延迟、平衡资源负载等。顶点为计算行为,边为行为关系,对应于传感器数量 N 与信息享有类数 M,则第 k 个资源包的顶点集与边集为 $\boldsymbol{N}_k$、$\boldsymbol{M}_k$。结合 $\boldsymbol{X}'$与 $\boldsymbol{G}$、资源权值矢量 $\boldsymbol{\omega}_z$ 的线性相关[14] 函数 $f_z(\boldsymbol{X}')$,构建资源包分解模型,如式(4)所示,分解资源为 K 个不均等的资源包:

$$\begin{cases}\sum_{k=1}^{K}\boldsymbol{N}_k = N\\ \boldsymbol{M}_k = \gamma_1 g_{n1}+\gamma_2 g_{n2}+\cdots+\gamma_M g_{nM}, g_{n*}\in\boldsymbol{G}, n\in N\\ f_z(\boldsymbol{X}') = \alpha_z \boldsymbol{G}\boldsymbol{\omega}_z\sum_{k=1}^{K}\boldsymbol{N}_k+\beta_z\boldsymbol{M}_k\end{cases} \tag{4}$$

式中:$\gamma_1,\gamma_2,\cdots,\gamma_M$ 代表资源对 M 类享有信息的需求度,α_z、β_z 代表资源的计算密度因子及修正项。

在优化智能交通传感网中的有向无环图中,利用拓扑排序算法对向无环图进行排序,得到一个线性化的处理顺序。这个顺序指导资源分配和调度的执行顺序,确保在计算过程中不会出现循环依赖。在有向无环图的基础上,采用合适的任务调度算法来优化资源分配和减少任务完成时间。根据 LSTM 模型预测的传感器能耗和资源分解模型得到资源包需求,结合有向无环图中的节点和边信息,进行资源的动态分配。确保在满足实时性要求的同时,减少资源消耗和成本。在资源分配过程中,考虑负载均衡问题。通过合理分配任务到不同的节点或处理单元上,避免单个节点或处理单元过载,提高整个系统的稳定性和效率。由于智能交通传感网中的数据传输量和资源需求会随着时间发生变化,因此需要对有向无环图和资源分配方案进行动态调整。通过实时监测系统的运行状态和性能指标,及时调整有向无环图结构和资源分配策略以适应新的需求和环境变化。

1.2 资源包低时延优先级

智能交通传感网资源分解后,各传感器节点散布于不同地域,若数据未能及时且精确地同步至中央处理系统,将削弱系统对交通全局态势的精准判断与决策能力。为此,将资源分解的成效与数据传输的优先级相结合,通过合理的资源调度与分配策略,确保高优先级数据包获得优先处理与传输的特权,从而保障智能交通传感网的高效运行与决策的准确性。

每个资源包都有其有效时间和创建时间。为了评估其紧急程度,需要计算剩余有效时间。剩余有效时间可以通过当前时间与资源包的有效时间之差来确定,同时考虑时间偏差因素。已知当前时间 τ_d,被分解为 K 个不均等的资源包的有效时间为 τ_e,则资源包的剩余有效时间 τ_s 由下式得出:

$$\tau_s=\tau_e-\tau_d+\tau_\varepsilon \tag{5}$$

式中:τ_ε 代表时间偏差。

资源包的重要度取决于其包含的资源属性的重要程度。这些资源属性对系统决策的贡献不同,因此需要去除重要度量纲,得到统一的重要度比值。基于有效时间的数量级[15],根据资源包中音频、视频等 L 个资源属性的重要度 $\{\lambda_1,\lambda_2,\cdots,\lambda_L\}$,通过下式去除重要度量纲,得到资源包重要度的比值 ϕ:

$$\phi=\frac{\lambda_d\times f_z(\boldsymbol{X}')}{\lambda_1+\lambda_2+\cdots+\lambda_L} \tag{6}$$

式中:λ_d 代表当前资源包的重要度值,是基于资源包内容初步计算出的一个重要性度量。

结合资源包的剩余有效时间和重要度,进一步确定其传输和处理的优先级。根据 τ_s 与 ϕ 的离散值[16]域分布特点,结合以上两式,明确低时延下资源包的优先级 Q_b:

$$Q_b=\kappa\frac{\tau_s}{\tau_{\max}}+\mu\frac{\phi}{\phi_{\max}} \tag{7}$$

式中:κ、μ 为权重因子。

2 智能交通传感网大规模资源最小时延调度

在智能交通传感网中,通过 LSTM 模型精准预测的传感器能耗被分解为多个资源块,这一过程一定程度上增加了调度过程的时延。为应对此挑战,利用 DQN 算法构建智能交通传感网调度模型。通过实时捕捉智能交通传感网状态与动态需求,实现资源的精细化分配与高效调度。

基于 DQN 算法[17],构建调度模型,如图 1 所示。输入资源包优先级、智能交通传感网链路带宽等信息后,经各层的调度方案价值评估、高价值调度决策存储与回放以及迭代优化,逐步调整调度策略以实现资源最小时延调度。

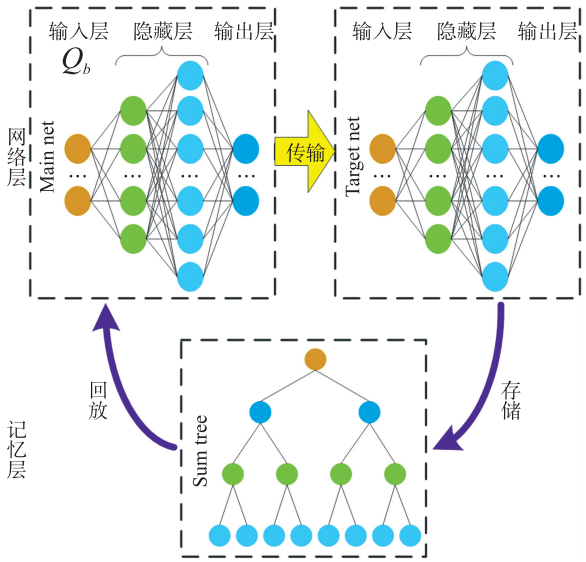

图 1　智能交通传感网资源最小时延调度模型

调度模型中各层的具体实施策略描述如下:

①网络层的调度方案价值评估:将资源包优先级 Q_b、网络链路状态等信息输入网络层,经 Main Net 和 Target Net 网络的前向传播,基于 Q 学习[18]评估各个可能调度方案的价值。假设 τ 时的网络状态、调度方案和对应奖励是 S_τ、A_τ、R_τ,衰减系数是 η,则根据 $\tau-1$ 时的模拟价值 $Q_{\text{MainNet}}(S_{\tau-1},A_{\tau-1})$,推算出 Main Net 网络的模拟价值 $Q_{\text{MainNet}}(S_\tau,A_\tau)$:

$$Q_{\text{MainNet}}(S_\tau,A_\tau)=R_\tau+\eta\max\{Q_{\text{MainNet}}(S_{\tau-1},A_{\tau-1})\} \tag{8}$$

若 $\tau-1$ 时的 Target Net 预测价值是 $Q_{\text{TargetNet},t-1}$,绝对误差提取比例是 φ,则其当前的预测价值 $Q_{\text{TargetNet}}$ 如下,即评估的各调度方案价值:

$$Q_{\text{TargetNet}}=Q_{\text{TargetNet},t-1}+\varphi\{Q_{\text{TargetNet},t-1}-Q_{\text{MainNet}}\} \tag{9}$$

②记忆层的高价值调度决策存储与回放:将价值较高的调度决策的状态转移样本存储到记忆层的 Sum Tree 构式经验池中,通过经验回放,随机抽取状态转移样本。基于此训练网络层,学习不同状态下的最优调度方案。

③迭代优化:将网络层学习的新样本加入经验池,更新池中高价值调度决策的状态转移样本。当经验池的样本不再发生变化时,Target Net 输出的最高价值对应的调度方案即是将用于智能交通传感网的最小时延调度方案。

根据以上过程,运用 LSTM 预测能耗,结合大规模资源特征实施资源分解,并依据资源包重要度与有效时间设定调度优先级。获取优先级后,基于 DQN 算法构建调度模型,通过迭代评估与智能决策,实现智能交通传感网资源的高效分配与最小时延调度。

3　智能交通传感网大规模资源最小时延调度实验

3.1　实验前置工作

本实验选取某市具有代表性的城区作为测试区域,该区域包含了不同类型的交通交叉口共 573 个、多种道路类型包括主、次干道及高速公路等,以及丰富的车辆种类。该区域交通流量大,尤其是在日间时段,适合进行大规模资源调度方法的验证。融合高精度传感器、通信设备、数据处理设备等硬件资源与操作系统、通信协议栈、数据处理软件等软件技术,部署交通传感网系统,并根据大规模资源等环境需求,配置网络拓扑结构、IP 地址、路由协议等。该区域分布 2 486 个雷达、摄像头、红外等高精度传感器,被部署在关键路段、交通交叉口的进出口以及易发生拥堵的热点区域。传感器节点的具体分布依据交通流量、事故多发点、信号控制需求等因素综合确定,以确保数据收集的全面性和准确性。在该传感网中运行调度方法,通过处理、分析收集的实际运行数据,验证其能否达到降低数据传输延迟、优化资源分配的优化效果。收集的数据包括但不限于车辆流量、速度、位置信息、信号灯状态、交通违规记录、行人流量等。这些数据通过不同的传感器以实时或近实时的方式采集,并经过初步处理后,用于后续的调度算法分析和优化。在测试周期内,预计生成的数据量将达到 TB 级别。为了保证数据处理的效率和实时性,采用分布式数据存储和并行处理技术,确保数据能够及时被调度算法访问和利用。此智能交通传感网的具体参数信息如表 1 所示,资源调度的实施现场如图 2 所示。

根据实验区域的地理特征和交通需求,设计并部署了多层次、多路径的网络拓扑结构。该结构包括核心层、汇聚层和接入层,确保数据传输的高效性和可靠性。同时,采用冗余链路和故障恢复机制,提高网络的健壮性。实验采用了标准的网络通信协议和专用的交通通信协议,以确保传感器节点、数据处理中心、信号控制单元等之间的无缝通信。此外,还定制了数据传输格式和加密策略,保障数据传输的安全性和隐私保护。

在部署的智能交通传感网中,实现了基于特定优化目标的调度方法。该方法结合了多种算法和技术,通过实时分析交通数据、预测交通状况、动态调整资源分配等方式,实现智能交通系统的智能化管理和控制。测试时间选择在流量较大的日间,周期

为 60 s,采样间隔为 1 s。在每个测试周期内,记录并分析数据传输延迟、资源利用率、交通状况改善情况等指标,以评估调度方法的有效性和性能。将测试结果与文献[5]基于时间敏感网络、文献[7]基于改进深度确定性策略梯度的两种调度方法作比较,目的是评估所提方法的有效性、优势或差异,更全面地理解其性能和应用潜力。

表 1 智能交通传感网的参数信息

类别	名称	值/释义
交通信息	交通交叉口	573 个
	道路类型	主、次干道及高速公路等
	车道	2 条、4 条、5 条、8 条等
	车辆种类	轿车、货车、公交车等
	信号灯周期	30 s、60 s、90 s、120 s 等
	相位	直行、左转、右转、调头等
网络信息	传感器种类	雷达、摄像头、红外等
	传感器数量	2 486 个
	传感器位置	关键路段、交叉口进出口等
	传感器功耗	0.03 W/s
	带宽	7.8 MHz
	传输功率	51 dBm
	传输速率	2.6 Mb/s
	队列上溢概率	0.09
	缩放比例	0.34
	折扣比例	0.88
	学习率	0.001
	Batch_size	128
	经验池容量	9 500 条
	经验回放采样量	100 条
LSTM 模型	LSTM 层数	3
	批量大小	128
	优化器	Adam
	学习率	0.001
	损失函数	均方误差(MSE)

图 2 目标传感网的资源调度现场

3.2 LSTM 模型预测误差分析

为了验证模型 LSTM 预测的准确性对后续资源调度的影响,LSTM 模型的训练数据集主要来源于智能交通传感网中实际部署的传感器,包括雷达、摄像头、红外传感器等。这些传感器实时采集的数据包括但不限于车辆流量、速度、位置信息、信号灯状态、交通违规记录等。数据集被划分为训练集、验证集和测试集,比例为 7∶2∶1,以确保模型的泛化能力和准确性。使用训练集数据进行模型训练,通过验证集调整模型参数,直至验证集上的性能不再提升。最终,在测试集上评估模型的预测性能。重复多次实验,实验结果如表 2 所示。

表 2 LSTM 模型在测试集上的预测性能

实验编号	能耗预测 RMSE/kWh	能耗预测 MSE/kWh^2	流量预测 RMSE/vehicles/h	流量预测 MAE/vehicles/h
1	0.03	0.031	51	41
2	0.04	0.041	49	38
3	0.041	0.036	48	39
4	0.042	0.034	50	40
5	0.039	0.038	52	42
6	0.037	0.035	54	39
7	0.04	0.036	53	40
8	0.038	0.037	55	38
9	0.040	0.039	48	41
10	0.041	0.04	49	42
平均值	0.039	0.037	51.1	40.2
标准差	0.002	0.002	2.0	1.3

由表 2 可知,从平均值来看,LSTM 模型在能耗预测和流量预测上均表现出较高的准确性。能耗预测的 RMSE 平均值为 0.039 kWh,MSE 平均值为 0.037 kWh^2,表明模型对能耗的预测误差较小。流量预测的 RMSE 平均值为 51.1 vehicles/h,MAE 平均值为 40.2 vehicles/h,同样显示出较好的预测性能。标准差的值较低,说明多次实验的结果波动较小,模型在不同实验中的表现较为稳定。准确的预测为资源调度提供了可靠的依据。在智能交通系统中,基于 LSTM 模型的预测结果,系统动态调整传感器的工作状态,优化数据传输策略,从而降低能耗并减少数据传输延迟。对于流量预测,高精度的预测结果有助于系统提前规划交通流量管理方案,包括调整信号灯配时、引导车辆分流等,从而有效缓解交通拥堵,提升道路通行能力。因此,LSTM 模型在智能交通传感网中

的应用具有广泛的前景。通过实时、准确的预测,系统有效地管理交通资源,提升交通系统的整体运行效率和服务质量,为城市交通管理和规划提供有力支持。

3.3　大规模资源最小时延下的数据传输能力分析

为精准分析所提方法与未使用所提方法在智能交通传感网大规模资源低时延调度场景下的数据传输能力,评估数据传输效率。相同资源规模下的实验结果如图 3 所示。

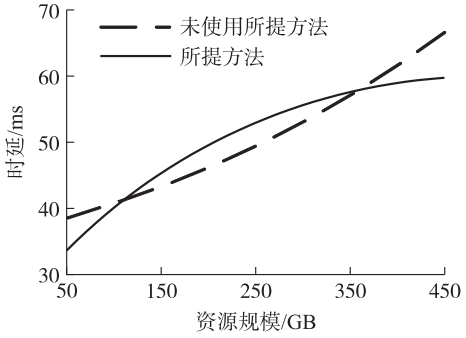

图 3　数据传输能力评估

由图 3 可知,所提方法在相同资源规模下持续展现出更高的数据传输效率。这一优势主要归因于所提方法充分利用了 LSTM 模型在预测传感器能耗方面的精准性,并结合传感器计算行为及其关系,实现了资源的高效分解。这种分解方式有效避免了计算资源的不均衡分配,从而降低了数据传输过程中的丢包率和重传需求,显著提升了数据传输的整体效率。

3.4　大规模资源最小时延下的通信能力分析

为精准分析所提方法与对比方法在智能交通传感网大规模资源低时延调度场景下的通信能力,引入误码率指标作为衡量标准,评估数据传输准确性。不同资源规模下的指标值如图 4 所示。

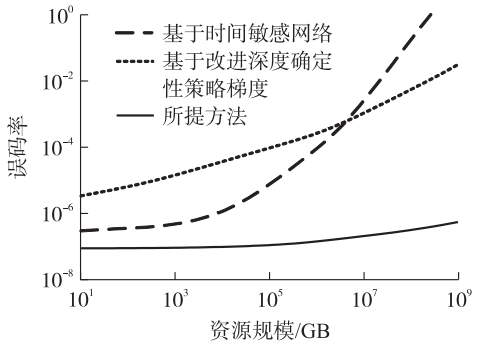

图 4　基于误码率的通信能力评估

图 4 中的误码率对比情况显示,随着资源规模的大幅增加,所提方法的误码率上升趋势相对平缓,甚至能够在资源规模相对较小的情况下始终维持在一个较低且稳定的水平,最大指标值未超过 0.000 001。这充分证明所提方法的通信能力明显优于对比方法,更适用于智能交通传感网中对实时性和可靠性要求较高的应用场景。这一优势归因于所提方法通过 DQN 算法构建的调度模型,能够智能评估并选取最优调度方案,实现资源包的高效、低时延传输,确保在大规模资源环境下信息的准确无误传输,为智能交通系统的稳定运行和高效决策提供了强有力的技术保障。

3.5　大规模资源最小时延下的资源利用效率分析

为精准分析在智能交通传感网大规模资源低时延调度场景下,所提方法与对比方法在资源利用效率上的优劣,综合考量节省的能量与资源成本两个关键维度。不同低时延条件下各方法的表现如图 5 所示。其中,图 5(a)为节省的能量变化,图 5(b)为资源成本的变动情况。

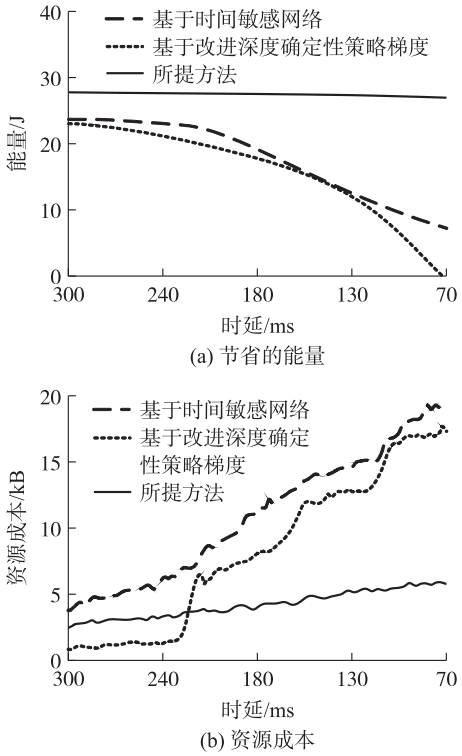

图 5　智能交通传感网资源利用效率评估

通过图 5(a)所示的低时延与节省能量关系曲线可以直观地看到,所提方法相较于对比方法在节省能量方面展现出了更显著的优势,不仅能量值始终位于对比方法上方,节省的能量均值高达 27.4 J,而且随着时延的减少,所节省的能量下降趋势相对平缓,使资源分配得到了有效利用,并在低时延区间内依旧保持着较高的资源利用效率。通过对比图 5(b)中各方法的资源成本曲线走势发现,尽管所提方法在低时延条件下实现高效调度带来了一定的资源成本增加,但仍较对比方法在资源利用效率上的优越性更高,平均资源成本低至 4.3 kB,且随着时延的减少,资源成本的增加速度相对较慢,实现了节

省能量与控制成本之间的平衡。所提方法获取上述优势的主要原因是,通过迭代网络层对调度方案价值的评估和记忆层对高价值调度决策的存储与回放,所提方法能够显著提升资源调度的预见性与效率。因此,在资源调度方面,所提方法表现出了良好的精细管理与优化能力,优化了智能交通传感网资源利用效率。

为了验证所提方法在不同规模智能交通传感网中的可扩展性和鲁棒性,设计实验来评估在不同网络规模下的资源利用效率。实验分别模拟了小型(500 个传感器节点)、中型(1 500 个传感器节点)、大型(3 000 个传感器节点)和超大型(6 000 个传感器节点)四种网络规模。每种规模下,均保持相同的传感器类型、部署位置和数据采集频率,以排除其他因素的干扰。实验结果如表 3 所示。

表 3 不同网络规模下的资源利用效率

网络规模	节省的能量/J	资源成本/kB	时延降低百分比/%
小型	20.2	3.6	12.4
中型	24.8	4.2	15.7
大型	27.5	4.4	18.3
超大型	30.3	4.9	20.6

由表 3 分析可知,随着网络规模的增大,所提方法节省的能量逐渐增加。这归因于 LSTM 模型在大数据集上的预测准确性提高,使得资源调度更加精准,减少了不必要的能耗。在超大型网络中,节省的能量达到了 30.3 J,表明所提方法在大规模网络中仍保持高效的节能效果。资源成本随着网络规模的增加而略有上升,但增长趋势相对平缓。这主要是因为所提方法通过优化调度策略,有效减少了数据传输的冗余和重复,从而控制了资源成本的增加。在超大型网络中,资源成本也仅增加至 4.9 kB,显示出较高的资源利用效率。时延降低百分比随着网络规模的增加而增加。这表明在大规模网络中,所提方法通过智能调度和资源优化,更有效地降低了数据传输的延迟,提升了系统的实时性。在超大型网络中,时延降低百分比达到了 20.6%,说明所提方法在大规模资源调度场景下具有时延优化能力。因此,所提方法在不同规模的网络中均表现出良好的可扩展性和鲁棒性。随着网络规模的增加,资源成本和调度复杂度有所上升,但所提方法仍能保持较高的资源利用效率和较低的传输时延。这是由于所提方法中的智能调度算法和 LSTM 预测模型,通过自适应地调整调度策略,以适应不同规模网络的需求。

3.6 异常情况下的性能评估

为了全面评估所提资源调度方法在面对节点失效时的鲁棒性和恢复能力,设计了实验来模拟不同比例的节点失效情况。选择部分传感器节点 5%、10%、15%等比例进行随机失效模拟,模拟节点突然停止工作或数据传输中断的情况。记录在不同失效比例下,系统数据传输的延迟、误码率、资源利用率等指标的变化情况。实验结果如表 4 所示。

表 4 不同节点失效比例下的实验数据

失效比例/%	数据传输延迟/ms	误码率/%	资源利用率/%
0	115	0.000 001	98.4
5	130	0.000 002	96.1
10	145	0.000 004	93.7
15	165	0.000 005	90.4

由表 4 分析可知,随着节点失效比例的增加,数据传输延迟逐渐增加。这是因为失效的节点无法参与数据传输,导致数据传输路径变长,增加了传输延迟。然而,即使在 15%的节点失效情况下,数据传输延迟也仅增加了约 43%,表明所提方法在面对节点失效时仍能保持相对稳定的性能。误码率随着节点失效比例的增加而略有上升,但整体保持在极低的水平,小于 0.000 01%。这表明所提方法中的错误检测和纠正机制在节点失效情况下仍然有效,确保数据传输的准确性。资源利用率随着节点失效比例的增加而逐渐下降。这是因为失效的节点无法被有效利用,导致整体资源利用率降低。然而,即使在 15%的节点失效情况下,资源利用率仍保持在 90%以上,表明所提方法在面对节点失效时较好地利用剩余资源。因此,所提资源调度方法在面对不同程度的节点失效时表现出良好的鲁棒性和恢复能力。通过智能调度和冗余机制,系统自动调整数据传输路径和资源分配策略,以应对节点失效带来的挑战。同时,系统迅速恢复数据传输和资源利用,确保智能交通传感网的稳定运行。

在数据传输过程中,以 1%、2%、3%等比例随机丢弃部分数据包,模拟网络拥堵、信号干扰等因素导致的数据丢失。分析数据丢失对系统性能的影响,包括调度准确性、资源分配效率等。实验结果如表 5 所示。

由表 5 分析可知,数据包的随机丢失对智能交通传感网系统的性能确实产生了一定影响,但所提资源调度方法在面对这种情况时仍然表现出较强的适应性和稳定性。随着数据包丢失比例的增加,数

据传输延迟逐渐增加。这是因为数据包丢失导致部分数据需要重传或采取其他恢复措施,从而增加了整体传输时间。随着数据包丢失比例的增加,误码率略有上升,但整体仍保持在极低的水平,小于0.000 01%。这表明数据丢失本身并不直接导致误码,系统内的错误检测和纠正机制在数据丢失和重传过程中仍然有效,确保了数据传输的准确性。数据包丢失导致资源利用率逐渐下降。这是因为重传数据包会占用额外的带宽和处理资源,而丢失的数据包则浪费了原始的资源分配。然而,在 3%的数据包丢失情况下,资源利用率仍保持在 96%以上,表明系统能够有效地管理和分配剩余资源,以应对数据丢失带来的挑战。随着数据包丢失比例的增加,调度准确性有所下降。这是因为数据丢失导致调度决策基于不完整的信息进行,从而降低了调度的精准度。然而,从结果来看,调度准确性从 99.8%降至 99.3%,下降幅度相对较小,说明所提调度方法在面对数据丢失时仍能保持较高的准确性,通过动态调整和优化调度策略来适应变化的环境。因此,所提资源调度方法在面对数据包丢失时展现出了良好的适应性和稳定性。通过有效的错误检测、纠正机制以及智能的调度和重传策略,系统有效应对数据丢失带来的挑战,确保智能交通传感网的稳定运行和高效数据传输。这进一步验证了所提方法在实际应用中的可靠性和鲁棒性。

表 5　数据包丢失情况下的系统性能

数据包丢失比例/%	数据传输延迟/ms	误码率/%	资源利用率/%	调度准确性/%
0	114	0.000 001	98.3	99.8
1	119	0.000 002	97.7	99.7
2	127	0.000 0025	97.1	99.5
3	134	0.000 003	96.4	99.3

4　结论

本文研究了在智能交通传感网中,针对大规模资源的最小时延调度问题,提出了一种创新性的资源调度策略。实验结果表明,所提方法在大规模资源调度下,网络误码率最大值不超过 0.000 001,节省的能量均值高达 27.4 J,且资源成本也较低,进一步验证了其在提升数据传输效率方面的显著效果。

参考文献:

[1] 王隆龙,袁涛,汪宇昕. 物联网技术在轨道交通车辆的应用场景分析及试验验证[J]. 铁道机车车辆,2024,44(3):113-118.

[2] 马永杰,程时升,马芸婷,等. 卷积神经网络及其在智能交通系统中的应用综述[J]. 交通运输工程学报,2021,21(4):48-71.

[3] Izhar,Iqbal M,Khan F. Hybrid Acoustic,Vibration,and Wind Energy Harvester Using Piezoelectric Transduction for Self-Powered Wireless Sensor Node Applications[J]. Energy Conversion and Management,2023,277:116635.

[4] 任毅,杨仁法,周继彪,等. 基于 BiLSTM 神经网络的交通事故黑点路段日均事故频次预测方法[J]. 交通信息与安全,2023,41(2):36-49.

[5] Zheng X,Liu Y,Zhan S P,et al. A Novel Low-Latency Scheduling Approach of TSN for Multi-Link Rate Networking[J]. Computer Networks,2024,240(2):110184.

[6] Bommisetty L,Venkatesh T G. Dynamic Programming Based Low-Latency Schedule (DPLLS) for 6TiSCH networks[J]. Ad Hoc networks,2022,124:102708.

[7] 张慎文,许崇海,胡天乐,等. 高 QoE 的低时延智能网络数据传输调度算法[J]. 哈尔滨工业大学学报,2023,55(5):132-138.

[8] Nardini G,Stea G,Virdis A. A Low-Latency and Reliable Multihop D2D Transmissions Scheduling Algorithm for Guaranteed Message Dissemination[J]. Ad Hoc Networks,2022,126:102755.

[9] 刘光远,曹晶仪,庞紫园,等. 一种低时延虚拟网络功能映射及调度优化算法[J]. 西安交通大学学报,2023,57(2):121-130.

[10] 赵恒辉,黄德启,曾蓉,等. 基于时空注意力 Bi-LSTM 模型的短时交通流预测[J]. 计算机仿真,2022,39(9):177-181,455.

[11] 梁乃兴,闫杰,杨文臣,等. 基于 ARIMA-LSTM 的高速公路交通安全组合预测模型研究[J]. 重庆交通大学学报(自然科学版),2023,42(4):131-138.

[12] 李泓钢,缪旻. 基于 ATT-LSTM 网络的多核系统封装温度预测[J]电子器件,2025,48(6):1074-1081.

[13] 姜松岩,廖晓鹃,陈光柱. 基于可满足性模理论的多处理机通信延迟优化任务调度方法[J]. 计算机应用,2023,43(1):185-191.

[14] 宋小冬,张竹君,庞磊,等. 道路可连续直行适宜城市公共交通的假设及其在济南的验证[J]. 城市规划学刊,2021(6):86-91.

[15] 朱旭,魏婧,张琳虎,等. 比例-时滞控制器作用下自主车辆队列系统的最右侧极点配置方法[J]. 北京交通大学学报,2023,47(3):52-60.

[16] 张梦,郑建宏,刘香燕,等. 基于集成学习的全双工中

继系统安全中继选择方案研究[J]. 电子学报,2021,49(9):1852-1856.
[17] 王新凯,王树凤,王世皓. 基于规则约束的深度强化学习智能车辆高速路场景下行驶决策[J]. 汽车技术,2023(9):18-26.
[18] 冯伟杨,林思雨,冯婧涛,等. 基于 Q 学习的蜂窝车联网边缘计算系统 PC-5/Uu 接口联合卸载策略[J]. 电子学报,2024,52(2):385-395.

杨忠来(1977—),男,汉族,山东安丘人,大学本科,山西警察学院交通管理系讲师,主要研究方向:道路交通安全,无人机应用,yzl632147@163.com;

朱 彤(1977—),男,汉族,陕西西安人,博士,长安大学运输工程学院副教授、博士生导师,主要研究方向:交通安全,驾驶心理与行为。