

多源异构传感器数据融合和算力优化研究

丁凯^{1,2}, 蒋超越¹, 陶铭¹, 谢仁平¹

- 东莞理工学院计算机科学与技术学院, 广东 东莞 523808;
- 人工智能与数字经济广东省实验室(深圳), 广东 深圳 518107

摘要: 多传感器系统通过整合多种传感器数据, 实现了全面且精准的环境感知, 然而, 如何有效融合异构数据并实现实时处理的高效性, 仍然是当前研究的热点和难点问题。为此, 围绕多源异构传感器的数据融合和算力优化展开研究, 提出了一种创新的解决方案。首先, 基于主/从架构设计数据融合系统, 解决多源异构数据处理难题; 其次, 构建了“云—边—端”3层架构, 利用边缘服务器分担云服务器的计算压力, 权衡任务调度策略, 实现网络资源与计算资源的协同管理; 最后, 针对任务的时延与能耗需求进行建模, 在资源约束下构建最小化系统成本的优化问题, 将问题转化为马尔可夫决策过程(MDP, Markov decision process), 使用深度确定性策略梯度(DDPG, deep deterministic policy gradient)算法进行求解。仿真结果表明, 所提出的架构和调度策略在降低时延和能耗方面表现优异, 为多传感器系统中的高效数据融合与算力优化提供了新思路。

关键词: 多源异构数据; 数据融合; 传感器; 算力优化

中图分类号: TP393

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2024.00449

Research on heterogeneous data fusion and arithmetic optimization in multi-sensor systems

DING Kai^{1,2}, JIANG Chaoyue¹, TAO Ming¹, XIE Renping¹

- School of Computer Science and Technology, Dongguan University of Technology, Dongguan 523808, China
- Guangdong Laboratory of Artificial Intelligence and Digital Economy (Shenzhen), Shenzhen 518107, China

Abstract: Multi-sensor systems integrate diverse sensor data to achieve comprehensive and accurate environmental perception. However, how to effectively fuse heterogeneous data and realize the efficiency of real-time processing is still a hot and difficult issue in current research. Therefore, focusing on data fusion and arithmetic optimization of multi-source heterogeneous sensors, an innovative solution was proposed. Firstly, a data fusion system based on master-slave architecture was designed to solve the problem of multi-source heterogeneous data processing. Secondly, a three-layer “cloud-edge-end” architecture was implemented, leveraging edge servers to offload computational pressure from cloud servers, optimizing task scheduling strategies, and enabling coordinated management of network and computing resources. Finally, the delay and energy consumption requirements of tasks were modeled, and the optimization problem of minimizing system cost was constructed under resource constraints, which was transformed into Markov decision process (MDP) and solved with deep deterministic policy gradient (DDPG) algorithm. Simulation experiments show that the proposed architecture and scheduling algorithm exhibit excellent performance in reducing both latency and energy consumption, and provide a new idea for efficient data fusion and arithmetic optimization in multi-sensor systems.

Key words: multi source heterogeneous data, data fusion, sensor, arithmetic optimization

收稿日期: 2024-10-14; 修回日期: 2024-12-09

通信作者: 陶铭, taom@dgut.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62001113); 广东省基础与应用基础研究基金项目 (No. 2021A1515010656)

Foundation Items: The National Natural Science Foundation of China (No. 62001113), The Basic and Applied Basic Research Funding Program of Guangdong Province (No. 2021A1515010656)

0 引言

在当今信息技术迅速发展的背景下，多传感器系统已被广泛应用于智能交通、环境监测、工业自动化和医疗健康等多个领域^[1]。这些系统通过集成来自不同类型传感器的数据，提升信息的准确性与可靠性。然而，随着传感器种类和数量的增加，异构数据的融合面临着越来越多的挑战。不同传感器的数据不仅在结构和格式上存在差异，而且在获取频率、实时性以及可靠性方面也各不相同。这些差异使得传统的数据处理和融合算法难以有效应用，导致数据融合效率低下且决策质量下降。

Machina Research 统计数据显示，2010—2018 年全球物联网设备连接数量高速增长，由 2010 年的 20 亿增长至 2018 年的 91 亿，复合增长率达 20.9%，预计到 2025 年，全球物联网设备（包括蜂窝及非蜂窝）联网数量将达到 251 亿^[2]。如此庞大数量的终端分布在不同的行业、领域及应用场景^[3]，而供应商为满足不同的设计需求，就算在同一应用场景下，由于产品供应商的不同，所使用的通信协议也存在明显的差异，这使得多源传感器系统面临着兼容难的问题。此外，传感器大部分工作在较为恶劣的环境中，导致数据频繁出现质量问题，噪声、数据缺失和不一致性使得融合结果的可靠性受到影响^[4]。这些问题不仅影响了系统的整体性能，还可能导致不安全的决策，给社会和经济带来潜在风险^[5]。因此，研究高效的异构数据融合算法，成为提升多传感器系统性能的关键所在。

与此同时，在现代多传感器系统中，数据量的迅速增长给系统的实时处理功能带来了前所未有的挑战。随着传感器数量的增加，生成的数据量呈指数级增长，这使得传统的处理架构难以应对^[6]。在实际应用场景中，采集后的数据需要传输至云服务器进行处理，这种集中式的计算模式虽然能够借助强大的云服务器资源，但受限于系统总带宽。在数据传输过程中，数据需要通过网络从各个传感器传送到云服务器，这一过程受到网络带宽、传输协议和时延等多种因素的影响。特别在高流量时段，网络拥堵进一步加剧传输时延，导致原本应实时处理的数据变得滞后。此外，云服务器的高负载也会影响系统整体运行时间^[7]。当多个应用同时向云服务器传输数据时，服务器的计算能力无法及时处理所

有请求，造成处理队列的延长，增加系统响应时间^[8]。为此，研究者就新型系统架构展开研究和讨论。文献[9]提出了空地一体化云边模型协同演化架构，通过联合任务分配和资源分配，提升系统的性能和精度。文献[10]提出了一种任务卸载方案，通过对计算任务分类，实现计算资源的合理分配。这些研究从不同角度探讨了如何提高计算系统的性能和效率，体现云边协同的优势。本文通过多源系统的计算负载和网络状态构建优化模型，将优化问题转化为马尔可夫决策过程（MDP, Markov decision process），通过使用深度确定性策略梯度（DDPG, deep deterministic policy gradient）算法来解决任务调度和资源分配问题，为提高“云一边一端”系统的效率和扩展性提供了新的视角和解决方案。

算力优化日益成为这一研究领域的重要组成部分。随着数据量的激增，传统的处理方式往往难以满足实时性和效率的双重需求^[11]。改进算法和算力配置，可以显著提高数据处理的速度和效率，这不仅能降低系统的运行成本，还能够在资源有限的情况下，确保数据融合结果的准确性和实时性。例如，借助深度学习和分布式计算等先进技术，可以更有效地处理复杂的异构数据，提高系统的智能化水平^[12]。

综上所述，针对多传感器系统中异构数据融合算法及算力优化的研究，不仅具有重要的理论意义，也具有显著的现实应用价值。本文通过提升数据融合的精度和效率，可为各行业的智能决策提供更可靠的支持，从而推动社会的可持续发展。在这一背景下，本文基于主/从（master/slave）框架，开发设计数据融合系统，深入研究和探索创新的融合算法与优化策略，为实现高效的多传感器系统提供参考。

1 异构数据融合系统总体设计

在当前多传感器应用的背景下，异构数据融合系统的设计与架构显得尤为重要。这些系统通过整合来自不同类型传感器的数据，提高信息的准确性与决策的有效性^[13]。在同构数据融合系统中，数据都源自相同类型或相同模式的设备。这类数据通常具有统一的格式、分辨率和结构，由于数据结构的一致，通常使用简单的统计方法或滤波技术就能实

现简单的合并。然而，在异构数据融合系统中，数据来自不同类型或模式的设备，这些数据往往具有不同的格式、尺度和维度，需要考虑数据间的语义关联、时空一致性等复杂问题，这要求在设计融合架构时，必须考虑如何高效处理这些差异，以实现实时、可靠的数据融合^[14]。针对上述问题，本文对数据融合系统进行设计。

1.1 总体架构设计

在多传感器系统中，随着传感器数量的增加以及数据复杂性的提升，传统的集中式架构已经难以应对多源异构数据的融合需求和巨大的算力消耗。为了解决这一问题，本文采用“云—边—端”3层架构，系统框架如图1所示。

系统通过在边缘层和云层之间分配计算任务和数据处理，提升网络资源和计算资源的利用率，同时对数据进行实时处理，并下放部分决策到边缘层，以减少数据传输时延。在边缘层部署任务调度算法实现系统负载均衡，提高整体系统的运算效率。最后，由云层对多传感器数据进行展示和分析。边缘层作为3层架构中的中间层，负责端数据的采集和初步处理。

为了应对多样化的传感器数据来源，终端采用主/从框架设计。在该框架下，多个从节点负责从不同类型的传感器获取数据，主节点对各个从节点

的数据进行聚合和数据校验，通过应答（ACK, acknowledgment）机制确保数据正确传输，并能够进行异常监测。当某些传感器数据出现异常时，主节点能够及时反馈并触发数据重传机制。通过这种设计，主节点能够实现对多源异构传感器数据的有效采集，还能够对数据进行初步筛选和清洗，为上层数据传输提供高质量的基础数据。

1.2 主/从框架

多源异构传感器系统的关键挑战在于如何高效地整合不同硬件通信协议和数据格式的传感器数据，最终实现统一的数据融合与分析。基于此需求，本文设计了一种基于主/从框架的数据融合系统，从节点接口示意图如图2所示。作为数据采集的核心节点，从节点通过集成多种通信协议（如I2C、RS485等）采集来自不同类型传感器的数据，并将这些数据的格式转换为统一结构、统一特征的格式。这一过程旨在解决不同数据结构带来的入网和处理困难问题^[15]。由于来自不同传感器的数据在格式、精度、采样频率等方面存在显著差异，统一化的处理不仅能够提高系统的兼容性，还能为后续的数据融合和分析奠定基础。通过对数据进行标准化和特征提取，从节点可以有效地减少数据处理的复杂性，提升系统整体的处理效率^[16]。

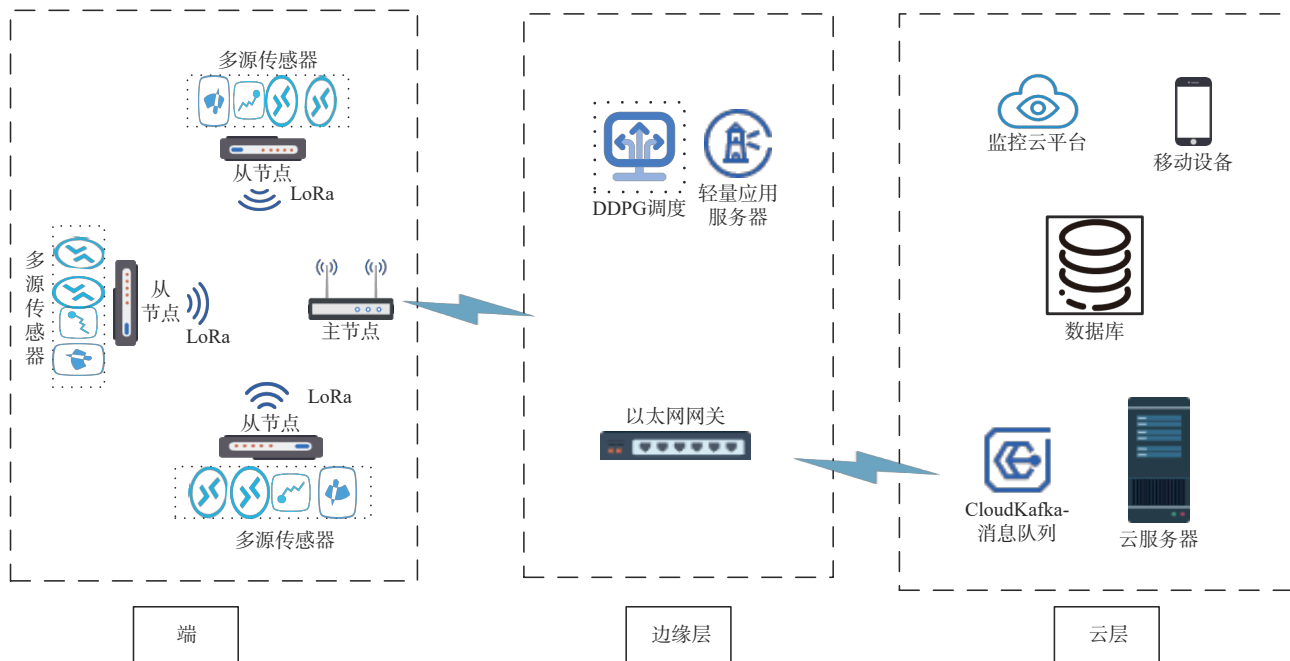


图1 系统框架

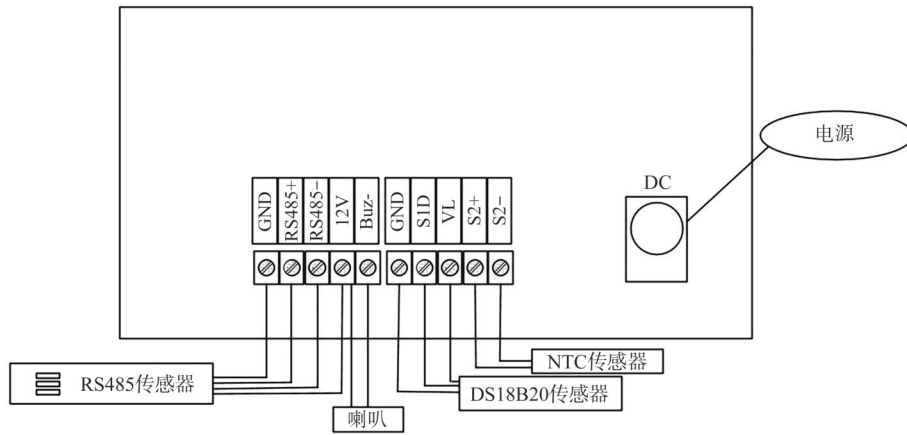


图2 从节点接口示意图

为了保证数据的实时性和同步性，从节点还在发送的数据包中携带时间戳信息。在多源异构传感器系统中，采样频率的差异可能导致数据流的时间步长不一致，影响数据融合的准确性。时间戳信息不仅能够标记数据采集的时间，还为数据的同步处理提供了依据。与此同时，针对低频传感器（如负温度系数传感器）的数据，可通过线性插值方法生成额外的数据点，使其与高频数据流对齐。线性插值公式如下

$$x(t) = x_1 + \frac{t - t_1}{t_2 - t_1} \times (x_2 - x_1) \quad (1)$$

其中， x_1 、 x_2 分别表示两个相邻采集点的数据值， t_1 、 t_2 表示对应的时间戳， t 表示插值点的时间。

主节点在整个系统中扮演协调与决策的角色，其主要功能包括汇总从节点上传的数据、检查数据一致性以及执行全局数据融合。主节点从多个从节点接收已标准化的数据流，并对数据进行汇总和初步校验。主节点不仅需要负责协调和管理各个从节点，还需要通过对接收的数据进行全局监控，尤其是利用时间戳信息进行设备监测。如果某些数据包在时间上出现偏差或内容不符合预期，主节点通过反馈机制要求对应的从节点重新采集或修正数据，从而提升系统的鲁棒性和可靠性^[7]。主节点采用卡尔曼滤波算法对多源数据进行融合，充分利用各传感器数据的冗余性和互补性，提高环境感知的准确性。融合步骤如下。

1) 状态预测：基于前一时刻的状态估计和系统动态模型，预测当前的环境状态

$$\hat{x}_{k|k-1} = A\hat{x}_{k-1|k-1} \quad (2)$$

其中， A 为状态转移矩阵，考虑系统状态随时间变化的平稳性，定义为单位矩阵。

预测当前时刻的误差协方差矩阵

$$P_{k|k-1} = AP_{k-1|k-1}A^T + Q \quad (3)$$

其中， Q 为过程噪声协方差矩阵。

2) 状态更新：结合当前时刻各传感器的观测值更新预测状态

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - H\hat{x}_{k|k-1}) \quad (4)$$

其中， z_k 为传感器观测值； H 为观测矩阵，表示观测值与系统状态的关系，设置为单位矩阵； K_k 为卡尔曼增益。卡尔曼增益计算如下

$$K_k = P_{k|k-1}H^T(H P_{k|k-1}H^T)^{-1} \quad (5)$$

其中， $P_{k|k-1}$ 为预测误差协方差矩阵。

通过将各传感器的测量数据融合到状态估计中，利用卡尔曼增益调整每个传感器数据的权重。融合过程充分考虑各传感器的误差特性和数据不确定性，确保输出结果的高准确性和高可靠性，为后续应用提供可靠的数据支撑。

1.3 通信协议

在多传感器系统中，通信协议的设计对于数据传输的效率与准确性至关重要^[8]。为了解决多源异构传感器的数据传输问题，本文采用Modbus 协议进行通信。Modbus 是一种应用广泛的工业通信协议，其设计简洁、可靠，能够确保数据的正确传输，并且由于其灵活性强、信息负载率高，在多传感器系统中具有显著的优势^[9]。首先，Modbus 协议具有良好的数据传输可靠性。在本文设计的主/从多传感器系统中，从节点负责采集各种传感器数据，并将数据转换为统一格式。在数据传输过程中，Modbus 协议内部集成数据校验机制，提供循环冗余校验（CRC, cyclic redundancy check），确保传输的数据在网络中不会因噪声、干扰或传输错误

而损坏。这种数据校验机制能有效确保数据的完整性和正确性，避免数据丢失或错误传输，提升了系统的稳定性^[20]，确保系统在恶劣的环境中数据传输的可靠性。

与此同时，Modbus 协议具有应答机制。每次从节点发送数据后，主节点都会通过 ACK 报文确认数据是否成功接收。如果数据传输过程中发生错误，主节点可以通过 ACK 回报信息检测到错误，请求从节点重新发送数据。这种应答机制确保了多源异构传感器的数据在传输过程中不丢失、不重复，极大地提高了通信的可靠性和数据的完整性^[20]。特别是在复杂环境下，多种传感器不同的采集频率和通信协议可能导致传输不稳定的情况，ACK 应答机制能确保主节点准确接收到每一个从节点的数据，避免数据丢失或遗漏。

此外，Modbus 协议的数据包格式简洁，能够避免因为携带大量无用数据而增加数据发送时延。在许多协议中，数据包设计复杂且携带大量冗余信息，导致传输效率低下，特别是在多传感器系统中，这种额外的负载可能会造成网络拥塞和时延。而 Modbus 协议的数据结构简单，该数据包仅包含必要的信息，如设备地址、功能码和校验字段等，极大地减少了不必要的数据传输^[21]。这样不仅可以提高传输效率，还能有效减少时延，尤其在系统资源有限的情况下。通过使用 Modbus 协议进行通信设计，不仅能确保数据传输的正确性，还能够通过简洁的数据包结构减少时延，并通过 ACK 应答机制确保数据的完整性和可靠性，从而为整个系统的稳定运行提供保障。

2 基于低时延的数据融合系统算力优化

多传感器系统广泛应用于各个领域，从智慧城市到工业自动化，面对海量数据的快速生成与处理需求，提高系统的算力优化成为亟待解决的关键问题。传统的集中式架构在处理数据时常常面临高时延和资源瓶颈的挑战^[22]。为此，本文采用 3 层“云一边一端”架构来实现低时延需求。该架构通过将数据处理任务分散到边缘层，减少数据传输距离，降低网络时延，提高响应速度^[23-24]。边缘层使用基于 DDPG 的任务调度算法，可为系统提供强大的负载均衡能力。该调度算法可以有效管理各层之间的任务分配，确保资源的合理利用和高效调度。构建基

于“3 层架构”和 DDPG 的高效数据融合系统，可以满足多传感器系统对实时性和计算资源的双重需求，为智能决策提供可靠支持。

2.1 边缘层设计

在多传感器数据融合系统中，传统的集中式架构需要终端设备将所有数据直接发送至云端处理，传输距离长、数据量大，容易导致网络拥堵、系统时延较高和计算负担大^[25]。本文通过引入边缘层，将数据在边缘层进行预处理，可以显著提升整体效率，减少云端的计算压力，实现整体系统高效运行^[26]。在本文设计中，边缘层的任务调度使用 DDPG 训练的调度算法。

首先，终端直接将数据发送给边缘层，数据传输距离大幅缩短。相较于直接将原始数据发送到远端云端，边缘服务器作为中间层可以对数据进行预处理，如数据过滤、聚合、压缩等操作，不需要将大量原始数据发送到云端，而是发送经过处理后的数据，即关键的、有价值的信息，减少数据的传输量和传输时间，从而降低网络时延^[27]。

其次，边缘层能够有效减少云端的数据接收负担。在没有边缘层的集中式架构中，云端需要处理来自所有边缘节点的大量原始数据，这不仅增加了云端的计算压力，还导致数据处理和决策的时延。而通过边缘层的预处理，经过筛选、处理和整合的数据才会上传至云端。这种方式减少了云端的工作量，使得云端能够专注于复杂的计算任务和全局性的数据融合与分析。通过减少云端接收的数据量，系统能够提高整体计算效率，同时降低不必要的数据传输开销^[28]。

引入边缘层节点，能够有效减轻云端的计算压力，确保对关键任务的快速响应，避免全量数据传输到云端所带来的时延^[29]。通过减少远距离的数据传输和分布式的数据处理，整个系统的通信时延显著降低，整体效率提高。此外，边缘层节点能分担部分计算任务，实现整体系统的算力优化，避免了计算资源的浪费，提升了系统的实时响应能力^[30]。

2.2 任务模型

在多源传感器系统中，任务模型的设计至关重要，尤其是在资源受限的情况下，如何高效处理计算任务非常关键。为简化模型，假设在系统运行时，时间被视为一个离散序列，可以划分为多个离散间隙，表示为 $\{1, 2, 3, \dots, T\}$ ，每个间隙对应

一个周期性的任务处理窗口。在每个时隙开始，每个主节点可以生成一个计算密集型且时间敏感的任务 $M_i(t) = (a_i(t), b_i(t))$ ，其中 i 表示主节点编号， a_i 表示任务的数据量大小， b_i 表示所需的计算资源。 $M_i(t)$ 表示第 i 个主节点在时隙 t 时刻产生的任务量。为了优化计算资源和降低系统时延，本文设计了一种任务分级处理和卸载机制。在边缘层的调度过程中，边缘节点可以选择将部分任务卸载至本地处理，或者将较复杂的任务转发到云端。任务卸载决策可以表示为 $C_n = \{0, 1\}$ ，其中 n 表示任务编号。若 C_n 取值为 0，则表示边缘节点对于任务 n 只进行数据校验、数据清洗、格式转换、缺失值补充等基础操作。若 $0 < C_n < 1$ ，则表示边缘节点进行部分任务卸载、数据分析和特征提取，将部分的计算任务在边缘层完成。如果 C_n 取值为 1，则表示任务全部卸载至边缘层，可将计算结果传输至云端服务器。

2.2.1 数据传输时延

在多源传感器系统中，为有效提高通信效率，通过使用正交频分多址接入 (OFDMA, orthogonal frequency division multiple access) 技术与边缘节点进行通信，有效分配频谱资源，减少信道干扰^[11]。假设每一个信道的带宽为 B ，每个主节点之间的干扰忽略不计，则根据香农定理，主节点与边缘节点的最大数据传输效率为

$$R_{DE} = \gamma_i B \log\left(1 + \frac{P_i^D h_i}{N_0}\right) \quad (6)$$

其中， γ_i 表示节点 i 的信道数， B 为信道的通信带宽， P_i^D 表示主节点的传输功率， h_i 表示主节点到边缘节点的增益， N_0 为高斯噪声的功率。因此，主节点 i 到边缘节点的无线传输时延为

$$T_i^{DE} = \frac{a_i}{R_{DE}} + a_i \cdot \frac{d_{DE}}{V} \quad (7)$$

为了保障系统的稳定性，边缘节点与云服务之间采用有线传输方式，以提供更可靠的数据传输路径，则主节点 i 的计算任务从边缘节点到云服务的有线传输时延为

$$T_i^{EC} = \frac{(1 - C_i)a_i}{R_{EC}} + (1 - C_i)a_i \cdot \frac{d_{EC}}{V} \quad (8)$$

s.t. $C_i \in (0, 1]$

在式(7)和式(8)中， a_i 表示编号为 i 的主节点任务的数据量大小， V 表示信号的传输速率， d_{DE} 表示主节点到边缘节点的距离， d_{EC} 表示边缘节点到云服务

器的距离， R_{DE} 表示边缘节点到云服务的有线传输速率， R_{EC} 表示边缘节点到云服务的有线传输速率， C_i 表示编号为 i 的主节点任务卸载至边缘节点处理的比例。

2.2.2 数据处理时延

T_p^E 和 T_p^C 分别表示边缘节点的数据处理时延和云端服务器的数据处理时延，其计算式为

$$T_p^E = \frac{C_i a_i b_i}{\alpha_E^i W_E} \quad (9)$$

$$T_p^C = \frac{(1 - C_i) a_i b_i}{\alpha_C^i W_C} \quad (10)$$

$$\text{s.t. } C_i \in (0, 1]$$

在式(9)和式(10)中， b_i 表示需要的系统资源， α_E^i 和 α_C^i 分别表示边缘节点和云服务器分配给编号为 i 的任务计算资源， W_E 和 W_C 分别表示边缘节点和云服务器的总计算资源。

3) 系统总成本

对于编号为 i 的主节点总时延 T_i 表示如下

$$T_i = T_i^{DE} + T_i^{EC} + T_p^E + T_p^C \quad (11)$$

总能耗表示如下

$$E_i = T_i^{DE} \times P_i^D + T_i^{EC} \times P_i^E + T_p^E \times \alpha_E^i \times P_p^E + T_p^C \times \alpha_C^i \times P_p^C \quad (12)$$

在式(11)和式(12)中， T_i^{DE} 、 T_i^{EC} 分别表示主节点传输至边缘节点的传输时延和边缘节点至云服务器的传输时延， T_p^E 、 T_p^C 分别表示边缘节点的处理时延和云服务器的处理时延， P_i^D 、 P_i^E 分别表示主节点和云服务的数据传输功率， α_E^i 、 α_C^i 分别表示边缘节点和云服务器分配给编号为 i 的任务的计算资源， P_p^E 、 P_p^C 则分别表示边缘节点和云服务器的计算功率。

为了考虑不同用户在不同场景下的不同需求，需要对时延和能耗做一个权重分配，使用户能自行分配时延与能耗偏好。总成本函数如下

$$G_i(t) = \theta T_i(t) + (1 - \theta) E_i(t) \quad (13)$$

$$\text{s.t. } \theta \in [0, 1]$$

其中， θ 为权重因子。

3 模型分析与仿真实验

在多传感器系统中，终端设备往往会产生海量的异构数据，特别是物联网应用中的传感器网络，数据量随着设备数量的增加而迅速增长。在传统的“云一端”架构中，所有传感器数据都需要传输到云端进行处理。当终端的数据量非常大时，云端处

理能力会受到严重影响，出现时延增加和算力不足的问题^[32]。为了证明本文提出的“云一边一端”3层架构和DDPG的调度算法可以有效解决大数据量场景下的时延和算力优化问题，本文通过算法分析和模拟仿真其优势。

3.1 模型分析

本文针对多源异构传感器系统中有限网络资源与庞大数据处理需求之间的矛盾，旨在动态、随机的环境中，通过“云一边一端”一体化架构与分布式算力调度技术，联合优化任务卸载与资源分配策略，以最小化系统长期运行过程中的总成本函数，并有效解决多传感器系统中算力不足与分布不均的问题。为实现这一目标，定义优化问题如下

$$\begin{aligned}
 \text{P1: } & \min_{C_i, \gamma_i, \alpha_E^i, \alpha_C^i} \lim_{t \rightarrow \infty} \sum_{i=1}^N G_i(t) & (14) \\
 \text{s.t. } & \text{C1: } \sum_{i=1}^N \alpha_E^i = 1, \quad \forall i \in N \\
 & \text{C2: } \sum_{i=1}^N \alpha_C^i = 1, \quad \forall i \in N \\
 & \text{C3: } 0 < \alpha_E^i W_E \leq W_E, \quad \forall i \in N \\
 & \text{C4: } 0 < \alpha_C^i W_C \leq W_C, \quad \forall i \in N \\
 & \text{C5: } \sum_i \gamma_i \leq S_{\text{total}}, \quad \forall i \in N
 \end{aligned}$$

目标函数P1表示在多源异构传感器系统中，最小化系统的长期总成本 $G_i(t)$ ，其中成本函数综合考虑了任务的执行时延与能耗开销， N 表示主节点总数， C_i 、 γ_i 、 α_E^i 、 α_C^i 分别代表最优化问题中的决策变量、子信道数量以及资源分配比例。约束条件C1与C2分别表示边缘节点和云服务器的资源约束条件，C3与C4分别表示边缘节点和云服务器的资源分配约束，C5表示通信资源的约束， S_{total} 表示总通信资源。

3.1.1 MDP问题定义

为了实现多源异构传感器系统中资源的动态优化与任务调度，将上述优化目标问题转化为MDP，以便在动态、不确定的环境中通过强化学习方法求解^[33]。MDP问题主要包括3个关键要素，即 $P = \{\text{State}, \text{Action}, \text{Reward}\}$ 。其中，State为一个有限的状态集合，Action为一个有限的动作集合，Reward为即时奖励函数^[34]。

状态空间State表示多源传感器系统在每个时间步的状态。每个状态包含任务到达的情况、系统的可用资源状态（计算资源和通信资源可用分

配量）。因此系统的状态空间可以定义为 $s(t) = (a_i, b_i, F_E(t), F_C(t), B(t))$ ，其中， a_i 表示待处理任务数据量大小， b_i 表示待处理任务的计算资源， $F_E(t)$ 、 $F_C(t)$ 分别表示边缘服务器和云服务器可分配的计算机资源量， $B(t)$ 表示时间为 t 时的带宽资源。

动作空间State表示每个状态下采取的资源分配和任务处理决策，表示为 $a(t) = (A_C, A_{aE}, A_{aC}, A_B)$ 。其中， A_C 表示任务处理决策， $A_C = \{C_1, C_2, \dots, C_N\}$ ， C_N 表示每一个节点任务卸载至边缘服务器的比例； A_{aE} 和 A_{aC} 分别表示边缘服务器和云服务器给每个节点任务分配的计算机资源比例，即 $A_{aE} = \{\alpha_E^1, \alpha_E^2, \dots, \alpha_E^N\}$ ， $A_{aC} = \{\alpha_C^1, \alpha_C^2, \dots, \alpha_C^N\}$ ； A_B 表示每个节点所分配的通信资源， $A_B = \{\gamma_1, \gamma_2, \dots, \gamma_N\}$ ， r_N 表示分配的子信道数。

奖励函数Reward的设计目的是为激励系统选择能最小化总成本的动作，即回报奖励函数设计为

$$R(t) = \frac{G(\text{CS}) - G(S, a)}{G(\text{CS})} \quad (15)$$

其中， $G(\text{CS})$ 表示所有任务在云服务器上执行时的系统的总成本，CS表示所有任务在云服务处理的情况， $G(S, a)$ 表示当前状态 S 和动作 a 执行后的系统总成本。

3.1.2 DDPG任务处理策略

传统强化学习算法的样本利用效率较低，需要大量的交互数据才能有效学习。例如，传统 Q 学习在状态空间较大时难以应用，因为存储所有状态一动作的 Q 值表会导致维度灾难。传统的策略梯度方法在高维度问题中容易出现高方差，导致训练过程不稳定。为了避免这些问题，本文使用DDPG算法设计实现任务调度算法，DDPG算法结合了深度 Q 网络和策略梯度方法的优点，能够高效地处理高维、复杂的状态空间^[35]。

DDPG引入了经验回放和目标网络技术，打破数据相关性，改善数据分布的平稳性和样本利用率^[36]。同时，DDPG基于Actor-Critic框架^[37]，通过使用深度神经网络分别近似策略函数（Actor）和价值函数（Critic），能够高效处理多源异构传感器任务调度中的高维复杂问题。其中Critic网络和Actor网络分别优化以下目标。

1) Critic网络损失函数：通过最小化Critic网络的损失均方误差更新Critic网络

$$L(\theta^0) = E[(y - Q(S, A; \theta^0))^2] \quad (16)$$

其中， E 表示对状态 S 、动作 A 以及下一个状态的

所有组合取期望, $Q(S, A; \theta^Q)$ 表示当前Critic网络估计的 Q 值函数, θ^Q 表示Critic网络的参数, y 表示目标 Q 值, 定义如下

$$y = R + \delta Q^{\text{target}}(S', \pi^{\text{target}}(S', \theta^\pi); \theta^Q) \quad (17)$$

其中, R 为即时奖励, δ 为折扣因子, Q^{target} 表示目标Critic网络的输出值, S' 表示下一状态, π^{target} 表示目标Actor网络输出的动作, θ^π 与 θ^Q 分别表示目标Actor网络和目标Critic网络的参数。

2) Actor网络更新: 通过策略梯度最大化Critic网络输出的 Q 值:

$$\nabla_{\theta^\pi} J = E_S [\nabla_A Q(S, A; \theta^Q)|_{A=\pi(S)} \nabla_{\theta^\pi} \pi(S; \theta^\pi)] \quad (18)$$

其中, $\nabla_{\theta^\pi} J$ 表示Actor网络的梯度, E_S 表示对状态 S 取期望, $\nabla_A Q(S, A; \theta^Q)$ 表示Critic网络对动作 A 的梯度, $A = \pi(S)$ 表示Actor网络在状态 S 下生成的动作, $\nabla_{\theta^\pi} \pi(S|\theta^\pi)$ 表示Actor网络参数 θ^π 对生成动作的梯度。DDPG任务调度算法代码如下。

算法1 DDPG任务调度算法

初始化经验回放池 R 大小为 N

初始化Actor网络 $\pi(S; \theta^\pi)$ 和Critic网络 $Q(S, A; \theta^Q)$

初始化目标网络参数 $\pi^{\text{target}}(S, \theta^\pi)$ 和 $Q^{\text{target}}(S, A; \theta^Q)$, 并设 $\theta^\pi \leftarrow \theta^\pi$, $\theta^Q \leftarrow \theta^Q$

随机噪声生成器 \mathcal{N}

for episode = 1 to M **do**

初始化状态 S

重置随机噪声生成器 \mathcal{N}

for step = 1 to T **do**

策略选择动作 $A(t) = \pi(S; \theta^\pi) + \mathcal{N}_t$

在环境中执行动作 $A(t)$, 计算奖励 $R(t)$ 和下一个状态 S' 将经验 $(S(t), A(t), R(t), S(t+1))$ 存入经验回放池 R 中, 从回放池随机采样一个小批量经验 (S_t, A_t, R_t, S_{t+1}) Critic网络更新:

计算目标 Q 值:

$$y_t = R_t + \delta Q^{\text{target}}(S_{t+1}, \pi^{\text{target}}(S_{t+1}, \theta^\pi); \theta^Q)$$

最小化损失函数更新 θ^Q :

$$L(\theta^Q) = \frac{1}{N} \sum_{i=1}^N (y_i - Q(S_i, A_i; \theta^Q))^2$$

Actor网络更新:

$$\nabla_{\theta^\pi} J = \frac{1}{N} \sum_{i=1}^N \nabla_A Q(S_i, A; \theta^Q)|_{A=\pi(S_i)} \nabla_{\theta^\pi} \pi(S_i; \theta^\pi)$$

更新目标网络参数:

$$\theta^Q \leftarrow \tau \theta^Q + (1 - \tau) \theta^Q$$

$$\theta^\pi \leftarrow \tau \theta^\pi + (1 - \tau) \theta^\pi$$

end for

end for

保存模型参数 θ^Q 和 θ^π

算法结束, 保存参数

3.2 模拟仿真

本文采用仿真实验的方式验证本文设计的“云一边一端”3层架构和任务调度算法的有效性, 仿真环境为64位Ubuntu 24.04.1 LTS操作系统, Intel(R) Xeon(R) Silver 4210R CPU @ 2.40 GHz, 64 GB内存, NVIDIA GeForce RTX 3090 GPU, Pycharm 2023.3.4编程实现。

在多源传感器中, 为了方便仿真计算, 只考虑一个边缘服务器和云服务器情况, 其终端设备到边缘服务器的距离 d_{DE} 为0.5 km, 边缘服务器到云服务器的距离 d_{EC} 为20 km。边缘服务器和云服务器的计算能力分别设置为 $W_E = 1 \times 10^8$ Hz, $W_C = 2 \times 10^{10}$ Hz, 其中主节点发射功率 $P_D^i = 2$ W, 边缘节点有线传输速率 $R_{EC} = 10$ Mbit/s, 边缘节点发射功率 $P_t^E = 1$ W, 高斯噪声功率 $N_0 = -174$ dBm/Hz, 信道增益 $h_i = 127 + 30 \lg d$ 。多源异构传感器系统总带宽为20 MHz, 每一个子信道带宽为1 MHz。对于DDPG算法, 学习率设置为0.001, 经训练, 通过实验发现学习率为0.001时, 训练收敛速度最快。为了评估不同数据量对多源异构传感器系统成本的影响, 并验证基于DDPG算法的任务卸载与资源分配策略的优越性。为了实现这一目标, 本文选择了以下算法进行对比: 边缘卸载 (EO, edge offloading)、云卸载 (CO, cloud offloading)、随机卸载 (RO, random offloading)、DDPG算法。

图3展示了任务数据量对成本 G 的影响。实验中模拟了不同大小的数据量 (主节点所产生任务数据量范围为1~12 MB), 并记录系统在不同策略下的总成本。从图3中可以看出, 随着任务数据量的增加, 系统总成本也会增加。曲线显示CO策略的时延随着数据量增加显著上升, 这是因为边缘服务器没有对数据做任何处理, 数据全部传输至云服务器的代价较大。而RO策略与EO策略较为接近, RO策略由于任务调度的随机性, 时延在一定范围内波动, 但整体时延仍显著高于EO和DDPG。DDPG策略表现最佳, 时延最低且增长最缓, 说明DDPG算法可以整合系统当前和未来的状态, 并更

好地优化系统总成本。

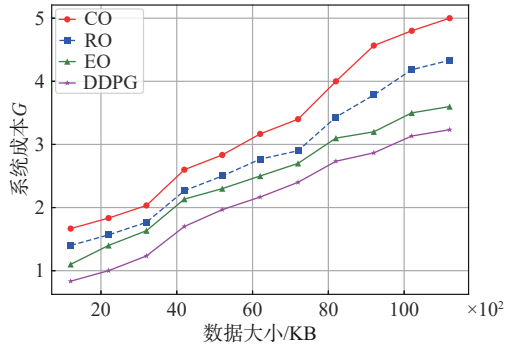


图3 任务数据量对成本G的影响

最后, 本文研究了边缘服务器计算能力的不同设置对系统总成本的影响。实验通过调整边缘服务器的计算资源, 对比分析了4种任务卸载策略的性能变化情况。具体而言, 服务器计算能力通过调整每个服务器可分配的CPU资源来模拟, 其中边缘服务器计算能力范围为 $1 \times 10^8 \sim 8 \times 10^8$ Hz。图4展示了边缘节点计算能力对成本G的影响。实验结果表明, 服务器计算能力的提升有助于降低系统总成本。DDPG算法通过深度强化学习实现了高效的任務卸载和资源分配, 在各种计算能力设置下均能显著降低成本。EO策略次之, 但在高计算能力下逐渐接近DDPG性能, 而CO和RO策略在计算资源增加时的表现相对较差, 尤其是CO策略受网络时延影响显著。这表明, DDPG在多传感器系统中的能耗、时延控制和可靠性优于基准策略。




图4 边缘节点计算能力对成本G的影响

4 结束语

本文围绕多源异构传感器数据融合和算力优化展开了深入研究, 提出了一种创新的设计方案, 旨在解决传感器系统中的关键问题。首先, 通过引入主/从框架, 有效应对多源异构传感器之间的不兼

容性和数据处理的复杂性, 提高了数据融合的精度和稳定性。此外, 本文设计了3层“云—边—端”架构, 进一步优化系统的整体性能。该架构利用边缘计算降低了数据传输时延, 并通过智能任务分配缓解了云端计算资源的压力。在此基础上, 为实现高效的任务调度, 本文引入了基于DDPG的任务调度算法。DDPG算法能够根据动态网络环境和任务需求实时优化资源分配, 与传统的集中式架构相比, 显著提高了系统运行效率, 降低了能耗和时延。仿真实验表明, 本文提出的方案在多源异构环境中表现出色, 系统响应速度和资源利用率均优于现有方法。随着物联网和智能技术的不断发展, 该设计方案为未来的多传感器系统提供了新思路和实践指导。在未来的应用中, 结合人工智能和大数据技术, 本研究有望在更广泛的场景中发挥重要作用, 为智能化决策和自动化管理提供坚实的技术支持。

参考文献:

- [1] 黄媛, 牛传俊, 余博. 基于多源异构数据融合的高速公路建设项目可视化关键技术[J]. 价值工程, 2024, 43(26): 7-9.
HUANG Y, NIU C J, YU B. Research on key technology of visualization management of expressway construction project based on multi-source heterogeneous data fusion[J]. Value Engineering, 2024, 43(26): 7-9.
- [2] 宋慧欣. “新基建”, 工业物联网发展新引擎[J]. 自动化博览, 2020, 37(6): 3.
SONG H X. “New infrastructure”, the new engine of industrial Internet of things development[J]. Automation Panorama, 2020, 37(6): 3.
- [3] 余文科, 程媛, 李芳, 等. 物联网技术发展分析与建议[J]. 物联网学报, 2020, 4(4): 105-109.
YU W K, CHENG Y, LI F, et al. Analysis and suggestions on the development of IoT technology[J]. Chinese Journal on Internet of Things, 2020, 4(4): 105-109.
- [4] 闫佳怡, 赵宝奇, 汤陈, 等. 基于信息熵和优劣解距离法的多传感器信息评价融合算法[J]. 电光与控制, 2024: 1-9.
YAN J Y, ZHAO B Q, TANG C, et al. Multi-sensor information evaluation fusion algorithm based on information entropy and TOPSIS[J]. Electronics Optics & Control, 2024: 1-9.
- [5] 元晋, 王微, 陈孟玺, 等. 工业互联网的概念、体系架构及关键技术[J]. 物联网学报, 2022, 6(2): 38-49.
QI J, WANG W, CHEN M X, et al. Concept, architecture and key technologies of industrial Internet[J]. Chinese Journal on Internet of Things, 2022, 6(2): 38-49.
- [6] TRAN M Q, LIU M K, ELSISI M. Effective multi-sensor data fu-

- sion for chatter detection in milling process[J]. *ISA Transactions*, 2022, 125: 514-527.
- [7] CAO K Y, LIU Y F, MENG G J, et al. An overview on edge computing research[J]. *IEEE Access*, 2020, 8: 85714-85728.
- [8] 王旭, 陈南希, 张柔佳. 智能自适应边缘系统: 探索与挑战[J]. *物联网学报*, 2021, 5(1): 1-10.
WANG X, CHEN N X, ZHANG R J. Intelligent adaptive edge systems: exploration and open issues[J]. *Chinese Journal on Internet of Things*, 2021, 5(1): 1-10.
- [9] 于馨博, 张舒航, 张泓亮. 面向低空物联网的云-边协同演进模型与通信范式[J]. *物联网学报*, 2024, 8(3): 76-90.
YU X B, ZHANG S H, ZHANG H L. An edge-cloud collaborative model evolution and communication paradigm in Internet of low-altitude UAV[J]. *Chinese Journal on Internet of Things*, 2024, 8(3): 76-90.
- [10] 庞笛, 魏喆, 陈墨, 等. 一种基于场景人物数量的任务卸载方案: 针对云边协同的智能监控系统[J]. *工程设计学报*, 2024: 1-8.
PANG D, WEI Z, CHEN M, et al. A task offloading scheme based on the number of scene characters: for cloud-edge collaborative intelligent surveillance system[J]. *Chinese Journal of Engineer Design*, 2024: 1-8.
- [11] 孙国玮, 许方敏, 朱瑾瑜, 等. 算力网络中的确定性调度与路由联合智能优化方案[J]. *北京邮电大学学报*, 2023, 46(2): 9-14.
SUN G W, XU F M, ZHU J Y, et al. Deterministic scheduling and routing joint intelligent optimization scheme in computing first network[J]. *Journal of Beijing University of Posts and Telecommunications*, 2023, 46(2): 9-14.
- [12] 熊凯, 冷甦鹏, 张可, 等. 车联雾计算中的异构接入与资源分配算法研究[J]. *物联网学报*, 2019, 3(2): 20-27.
XIONG K, LENG S P, ZHANG K, et al. Research on heterogeneous radio access and resource allocation algorithm in vehicular fog computing[J]. *Chinese Journal on Internet of Things*, 2019, 3(2): 20-27.
- [13] SUN D Y, LI Y B, JIA S X, et al. Non-contact diagnosis for gearbox based on the fusion of multi-sensor heterogeneous data[J]. *Information Fusion*, 2023, 94: 112-125.
- [14] 赵小强, 李森. 基于多传感器数据融合的互异网络轴承故障诊断方法[J]. *计算机工程与应用*, 2024: 1-14.
ZHAO X Q, LI S. Heterogeneous network bearing fault diagnosis method based on multi-sensor data fusion[J]. *Computer Engineering and Applications*, 2024: 1-14.
- [15] 于继江, 姜杰斯, 董中平. 基于异构数据源的信息网络安全态势感知方法[J]. *自动化与仪器仪表*, 2024(8): 55-58.
YU J J, JIANG J S, DONG Z P. Information network security situation awareness method based on heterogeneous data sources[J]. *Automation & Instrumentation*, 2024(8): 55-58.
- [16] 邢文革, 桂佑林, 顾万里. 多传感器系统误差特性匹配的动态估计与补偿算法[J]. *电子科技大学学报*, 2021, 50(2): 186-192.
XING W G, GUI Y L, GU W L. A dynamic estimation and compensation algorithm for matching the error characteristics of multi-sensor system[J]. *Journal of University of Electronic Science and Technology of China*, 2021, 50(2): 186-192.
- [17] 黄莹. 复杂系统多传感器数据智能融合方法研究[J]. *机械工程学报*, 2024: 1-7.
HUANG Y. Research on intelligent fusion method for multi sensor data in complex systems[J]. *Journal of Mechanical Engineering*, 2024: 1-7.
- [18] 杨澳钦, 宫傲宇, 房婷, 等. 传输时限约束下的能量收集无线传感器网络多址接入优化[J]. *物联网学报*, 2022, 6(3): 58-70.
YANG A Q, GONG A Y, FANG T, et al. Optimization of multiple access in the energy harvesting wireless sensor network with delivery deadline constraint[J]. *Chinese Journal on Internet of Things*, 2022, 6(3): 58-70.
- [19] 史先传, 张本阳, 卢鸿运, 等. 基于 Modbus RTU 协议的多传感器数据采集系统设计[J]. *仪表技术与传感器*, 2024(7): 46-50, 76.
SHI X C, ZHANG B Y, LU H Y, et al. Design of multi-sensor data acquisition system based on modbus RTU protocol[J]. *Instrument Technique and Sensor*, 2024(7): 46-50, 76.
- [20] GĀITAN V G, ZAGAN I. Modbus protocol performance analysis in a variable configuration of the physical fieldbus architecture[J]. *IEEE Access*, 2022, 10: 123942-123955.
- [21] 宋海鹰, 陈志文, 邱佰平, 等. 基于物联网和边缘计算的智能化建筑管理系统及应用[J]. *物联网学报*, 2020, 4(4): 98-104.
SONG H Y, CHEN Z W, QIU B P, et al. Building intelligent integrated management system based on Internet of Things and edge computing and its application[J]. *Chinese Journal on Internet of Things*, 2020, 4(4): 98-104.
- [22] 吴善滨, 曹灵芝, 禹晋. 基于雾计算节点的智能交通管控平台的设计与实现[J]. *交通世界*, 2024(22): 14-17.
WU S B, CAO L Z, YU J. Design and implementation of intelligent traffic management and control platform based on fog computing node[J]. *TranspoWorld*, 2024(22): 14-17.
- [23] 陈星延, 张雪松, 谢志龙, 等. 面向“云-边-端”算力系统的计算和传输联合优化方法[J]. *计算机研究与发展*, 2023, 60(4): 719-734.
CHEN X Y, ZHANG X S, XIE Z L, et al. A computing and transmission integrated optimization method for cloud-edge-end computing first system[J]. *Journal of Computer Research and Development*, 2023, 60(4): 719-734.
- [24] SUN Y K, LEI B, LIU J L, et al. Computing power network: a survey[J]. *China Communications*, 2024, 21(9): 109-145.
- [25] 韩坤, 王政, 段俊勇, 等. 基于雾计算的制造物联网数据处理技术综述[J]. *计算机与现代化*, 2024(1): 13-20.
HAN K, WANG Z, DUAN J Y, et al. Overview of data processing techniques for MIoT based on fog computing[J]. *Computer and Modernization*, 2024(1): 13-20.
- [26] 袁培燕, 邵赛珂, 魏然, 等. 基于时延和能耗约束的感知数据协作卸载策略研究[J]. *物联网学报*, 2023, 7(1): 109-117.
YUAN P Y, SHAO S K, WEI R, et al. Research on the cooperative offloading strategy of sensory data based on delay and energy constraints[J]. *Chinese Journal on Internet of Things*, 2023, 7(1): 109-117.

- 109-117.
- [27] JIN C Q, BAI X L, YANG C, et al. A review of power consumption models of servers in data centers[J]. Applied Energy, 2020, 265: 114806.
- [28] RAEISI-VARZANEH M, DAKKAK O, HABBAL A, et al. Resource scheduling in edge computing: architecture, taxonomy, open issues and future research directions[J]. IEEE Access, 2023, 11: 25329-25350.
- [29] HUANG H C, LIAO W H, LEI X H, et al. An urban DEM reconstruction method based on multisource data fusion for urban pluvial flooding simulation[J]. Journal of Hydrology, 2023, 617: 128825.
- [30] LI Y J, HUYNH D V, NGUYEN V L, et al. Multiagent UAV-aided URLLC mobile edge computing systems: a joint communication and computation optimization approach[J]. IEEE Systems Journal, 2024(99): 1-11.
- [31] 申怡飞. 极化码译码算法与实现研究[D]. 南京: 东南大学, 2022. SHEN Y F. Decoding algorithms and implementations for polar codes[D]. Nanjing: Southeast University, 2022.
- [32] JAIN A, SINGHAL P. Fog computing: Driving force behind the emergence of edge computing[C]//Proceedings of the 2016 International Conference System Modeling & Advancement in Research Trends (SMART). Piscataway: IEEE Press, 2017: 294-297.
- [33] 肖易寒, 陈志亮, 李虎, 等. 基于双重竞争深度正则化Q学习的干扰探测一体化波形设计[J]. 应用科技, 2024: 1-8. XIAO Y H, CHEN Z L, LI H, et al. Design of jamming-detection shared waveform based on double dueling deep Q-learning network based on regularization[J]. Applied Science and Technology, 2024: 1-8.
- [34] 王琴, 宁洛函, 张钰璋, 等. 基于WPT的去蜂窝mMIMO系统中无人机轨迹与充放电联合优化方法[J]. 物联网学报, 2024, 8(3): 26-35. WANG Q, NING L H, ZHANG Y X, et al. Joint optimization method for UAV trajectory and charging/discharging in cell-free mMIMO system on WPT[J]. Chinese Journal on Internet of Things, 2024, 8(3): 26-35.
- [35] GAO H H, WANG X J, WEI W, et al. Com-DDPG: task offloading based on multiagent reinforcement learning for information-communication-enhanced mobile edge computing in the Internet of vehicles[J]. IEEE Transactions on Vehicular Technology, 2024, 73(1): 348-361.
- [36] 刘延飞, 李超, 王忠, 等. 多智能体深度强化学习及可扩展性研

究进展[J]. 计算机工程与应用, 2024: 1-27.

LIU Y F, LI C, WANG Z, et al. Research progress on multi-agent deep reinforcement learning and scalability[J]. Computer Engineering and Applications, 2024: 1-27.

- [37] HU H, WU D G, ZHOU F H, et al. Intelligent resource allocation for edge-cloud collaborative networks: a hybrid DDPG-D3QN approach[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 10696-10709.

[作者简介]



丁凯(1985-), 男, 博士, 东莞理工学院计算机科学与技术学院副教授, 主要研究方向为物联网、智慧城市、机器人技术和移动互联应用等。



蒋超越(2000-), 男, 东莞理工学院计算机科学与技术学院硕士生, 主要研究方向为物联网工程、异常检测和人工智能等。



陶铭(1986-), 男, 博士, 东莞理工学院计算机科学与技术学院教授、副院长, 主要研究方向为人工智能、边缘计算和云计算等。



谢仁平(1989-), 男, 博士, 东莞理工学院计算机科学与技术学院特聘副研究员, 主要研究方向为计算机视觉、图像处理、目标检测、图像分割、图像融合、图像拼接和桥梁检测机器人等。

勘误：2024年（第8卷）第3期《面向3GPP ISAC标准化的低空无人机场景路径损耗测量与建模》作者张建华的单位为北京邮电大学网络与交换技术国家重点实验室，特此说明。