

基于集中式反向拍卖的物理-虚拟同步资源分配联合决策机制

崔茹云¹⁾ 周月娥¹⁾ 马连博¹⁾ 黄 敏²⁾ 王兴伟³⁾

¹⁾(东北大学软件学院 沈阳 110169)

²⁾(东北大学信息科学与工程学院 沈阳 110801)

³⁾(东北大学计算机科学与工程学院 沈阳 110169)

摘 要 实时物理-虚拟同步是实现高效的数字孪生辅助边缘计算网络(即边缘数字孪生网络)的核心任务,涉及同步对匹配、资源分配、同步优化与任务卸载等一系列相互耦合的环节。该任务需要综合考虑边缘数字孪生网络中的同步对特性、边缘节点的计算与通信能力以及通信覆盖、异构资源容量和时延等复杂本地约束条件,本质上是一种复杂的多维度联合决策问题。然而,现有工作尚未对这些紧密耦合的联合决策优化问题进行系统分析与有效解决。针对此问题,本文提出了一种基于集中式反向拍卖的物理-虚拟同步资源分配联合决策机制(ARAPVS),实现了边缘数字孪生网络系统的稳定、实时物理-虚拟同步。该机制由边缘数字孪生网络中的云服务中心(CSC)进行统一任务调度与资源分配,其核心目标是在满足物理约束的前提下,最大化包含同步实时性收益在内的系统社会福利。具体而言,该机制首先引入数字孪生状态陈旧度模型以量化同步质量,并构建广义成本函数;其次,采用匈牙利-库恩(KM)算法结合机会成本策略求解任务与异构资源束的最小广义权完美匹配,有效解决了多用户资源争用问题;最后,设计了基于 VCG 的支付规则以确保边缘节点如实报价并获得非负收益。理论分析证明了该机制的真实性与个体理性,并分析了其计算复杂度。Python 平台的大量仿真表明:与随机分配(RA)、贪心分配(GA)、McAfee 机制(MM)以及最新的深度强化学习算法(DDPG)相比,ARAPVS 不仅能够有效降低边缘节点总成本,更在平均累积陈旧度和社会福利方面表现出显著优势。在不同规模的同步对和边缘节点网络下,ARAPVS 均表现出最优的综合性能和良好的可扩展性,验证了所提机制的有效性。

关键词 数字孪生;边缘计算;物理-虚拟同步;反向拍卖;资源分配

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2026.02290

A Reverse Auction-Based Joint Decision-Making Mechanism for Physical-Virtual Synchronization Resource Allocation

CUI Ru-Yun¹⁾ ZHOU Yue-E¹⁾ MA Lian-Bo¹⁾ HUANG Min²⁾ WANG Xing-Wei³⁾

¹⁾(Department of Software, Northeastern University, Shenyang 110169)

²⁾(Department of Information Science and Engineering, Northeastern University, Shenyang 110801)

³⁾(Department of Computer Science and Engineering, Northeastern University, Shenyang 110169)

Abstract With the rapid evolution of mobile edge computing and the upcoming sixth-generation wireless networks, the digital twin-aided edge network has emerged as a transformative paradigm for bridging the physical and virtual worlds. In such networks, real-time physical-virtual synchronization is the fundamental task required to maintain high-fidelity digital replicas and enable precise closed-loop control. This synchronization process is inherently complex, involving two

收稿日期:2025-11-06;在线发布日期:2026-05-26。本课题得到国家自然科学基金(62472079)资助。崔茹云,硕士研究生,主要研究领域为数字孪生与边缘计算。E-mail:2471354@stu.neu.edu.cn。周月娥,博士研究生,主要研究领域为联邦学习与边缘计算。马连博(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)杰出会员,主要研究领域为计算智能、边缘计算与联邦学习。E-mail:malb@swc.neu.edu.cn。黄 敏,博士,教授,博士生导师,主要研究领域为工业互联网、供应链与智能优化。王兴伟,博士,教授,博士生导师,中国计算机学会(CCF)会士,主要研究领域为计算机网络、云计算与人工智能。

tightly coupled directions: physical-to-virtual state reporting and virtual-to-physical decision feedback. However, achieving stable and real-time synchronization in dynamic edge environments remains a daunting challenge. This challenge arises from the heterogeneity of edge resources, stringent latency requirements, and the complex interdependencies between synchronization pair matching, resource allocation, and task offloading. Existing research often treats these dimensions as isolated sub-problems, failing to provide a systematic and integrated optimization framework for these tightly coupled decisions.

To address these issues, this paper proposes ARAPVS, a centralized joint decision-making mechanism based on a reverse auction model. The objective is to maximize total social welfare while satisfying constraints including limited communication coverage, heterogeneous resource capacities, and maximum tolerable delay thresholds. At the architectural level, the system follows the design principle of control and data plane separation to avoid communication bottlenecks. The cloud service center acts as a centralized controller and market clearing authority, processing only lightweight metadata via a dedicated signaling channel. Once an auction decision is made, it issues admission tokens to winning nodes. Actual high-bandwidth synchronization data is transmitted directly between physical devices and edge nodes via authorized peer-to-point links, ensuring system scalability and low latency.

The ARAPVS mechanism integrates several key technical innovations. First, we introduce a digital twin state staleness model to quantify synchronization quality, which is incorporated into a generalized cost function. Second, we formulate resource contention as a minimum generalized weight perfect matching problem in a bipartite graph. We employ the Kuhn-Munkres algorithm combined with an opportunity cost strategy to achieve a global optimal matching. Unlike unweighted matching algorithms, the Kuhn-Munkres algorithm handles weighted edges with cubic time complexity, ensuring both theoretical optimality and computational feasibility for large-scale networks. Third, we design a pricing rule based on the Vickrey-Clarke-Groves mechanism. Edge nodes serve as resource sellers submitting competitive bids, while synchronization pairs act as buyers. The cloud service center automatically calculates settlement prices based on social opportunity cost, ensuring that truthful bidding is a weakly dominant strategy.

Rigorous theoretical analysis confirms the mechanism satisfies individual rationality and incentive compatibility. Extensive numerical simulations on the Python platform demonstrate the superiority of ARAPVS. We compared our mechanism with several baselines, including random allocation, greedy allocation, the McAfee mechanism, and deep reinforcement learning algorithms. Quantitative results indicate that ARAPVS significantly reduces total costs and maintains the lowest average accumulative staleness. Notably, the mechanism exhibits robust convergence and sub-linear execution time growth even as the network scales up to hundreds of edge nodes. This research provides a solid theoretical and technical foundation for enabling efficient, real-time synchronization in next-generation edge digital twin ecosystems.

Keywords digital twin; edge computing; physical-virtual synchronization; reverse auction; resource allocation

1 引言

随着移动边缘计算 (MEC) 与第六代无线通信

技术 (6G) 的迅速发展, 数字孪生辅助边缘网络 (DTEN) 作为连接物理世界与虚拟计算世界的有效范式日益受到关注。DTEN 能够对真实的边缘计算环境进行数字化建模, 从而实现物理对象与其虚

拟孪生之间的信息共享与协同联动。其典型应用涵盖了多个关键领域:在智慧工厂场景下,DTEN 通过实时同步高精度工业机器人的数字副本,可实现对生产偏差的超前预判与毫米级路径校正,显著提升产线自动化水平;在智慧电网中,DTEN 能够建立分布式能源节点的实时映像,支撑电网在极端负载波动下的动态平衡调度;在智慧医疗领域,DTEN 可实现对远程手术机器人状态的精准映射与时延感知,确保关键医疗操作的安全可靠。这些实例充分说明,DTEN 能够为复杂物理系统提供实时监控与精准预测,是推动工业 4.0 及智慧城市转型的核心支撑技术。DTEN 系统可从物理实体中采集实时数据,并存储在虚拟孪生模型中,实时感知和监控边缘网络状态^[1-2]。

实现高效 DTEN 的关键在于其双向物理-虚拟同步机制,包括物理向虚拟(P2V)与虚拟向物理(V2P)两个过程^[2]。而这一同步过程对通信和计算资源的消耗极为显著,尤其在边缘计算环境中,终端设备资源受限(如存储、计算能力不足)使该问题更加严重。

示例:如图 1 所示,在 DTVEC 系统中,车载用户(VUs)与智能管理单元(ISUs)之间通过 P2V 与 V2P 过程实现实时同步。P2V 阶段,VUs 向路侧单元(RSUs)上传同步任务以更新其 DT 模型;V2P 阶段,ISUs 利用位置信息对 VUs 生成卸载决策并下发。该过程涉及模型维护与决策交付,资源消耗巨大。虽然 RSUs 具备一定的本地资源,但现有机制受限于信息不对称与动态约束(如资源容量限制、通信范围等),导致同步陈旧度高、能耗高、系统扩展性弱。在上述约束下实现资源的动态调度与同步质量最优化,是当前 DTEN 面临的重要挑战。

在 DTEN 系统中,应对实时同步挑战的常用方案是采用一个动态资源分配框架,该框架能够协调同步对和边缘资源节点。然而,实现这样一个框架需要做出相互适应的决策,这涉及同步对、边缘资源和动态环境之间的复杂联合优化,存在以下挑战:

资源分配中的信息不对称:由于同步对的服务价值、预算等隐私信息不对称,边缘节点难以进行精确响应,导致集中式或静态分配机制在动态环境下表现不佳。一个关键挑战是设计一种可预测同步对需求和边缘资源状态的调度机制,以弥合供需差距、提高资源利用效率。

同步对匹配:同步对在无线范围与信道冲突限制下,其可选边缘节点受限,可能造成任务无法完成



图 1 DTVEC 系统中的物理-虚拟同步过程

匹配。因此,设计一种可适应无线局部约束的匹配机制,确保同步稳定性,是现实部署中必须解决的问题。

资源竞争下的激励与稳定性:同步对倾向于低成本服务,边缘节点则追求利润最大化,双方之间的策略性报价与竞争行为使系统面临稳定性挑战。如何设计激励兼容的机制,使同步对愿意主动参与同步请求,边缘节点愿意稳定供给资源,并实现纳什均衡,是系统运行的关键。

造成上述困难的两个核心原因是:

资源异构性:MEC 环境中各边缘设备的通信与计算能力差异巨大,且具有时空动态性。同时,同步对的服务质量需求多样,进一步增加了匹配的复杂度。

决策耦合性:不同参与方的行为高度耦合,一方的策略变化会影响整个系统的调度效果,必须进行统一协调与决策。

针对上述挑战,本文将同步问题建模为一个多维联合决策问题,涉及同步对匹配、资源分配、同步优化与任务卸载。我们提出一种基于集中式反向拍卖的联合决策机制(ARAPVS),由云服务中心(CSC)在准静态时隙内统一调度。该机制引入“机会成本”策略解决异构资源冲突,并利用 VCG 定价规则确保激励相容。不同于传统成本最小化方法,ARAPVS 旨在最大化包含同步实时性收益在内的系统社会福利。

我们的主要贡献如下:

同步决策建模:提出一个联合优化模型,以最大化社会福利为目标。首次将边缘计算环境中的 DT 同步问题引入 VCG 机制,在满足通信约束、资源容量约束和延迟约束等条件下实现系统稳定性与资源最优分配。

调度与定价机制:构建由 CSC 统一调度的集中式反向拍卖机制。利用数字孪生状态陈旧度模型量化同步质量,结合匈牙利-库恩(KM)算法与机会成本策略实现任务与异构资源束的最小广义权完美匹配,并通过 VCG 定价激励边缘节点诚实投标。

性能评估:在真实测试环境与仿真平台上进行理论分析与大量实验验证。结果表明,与随机分配、贪心分配、McAfee 机制以及最新的 DRL 算法(DDPG)相比,所提机制在社会福利、同步新鲜度及成本控制方面均表现出显著优势,并保证了个体理性和激励兼容性。

2 系统模型


2.1 物理-虚拟双向同步机制

在数字孪生辅助边缘网络(DTEN)系统中,实

时状态对齐与决策优化依赖于物理实体与其虚拟副本之间的实时双向同步机制。不同于传统的单向计算卸载,该过程包括两个紧密耦合的互补方向:一是物理到虚拟(P2V)同步,即物理设备通过边缘节点持续生成并上传状态数据,用于动态更新其数字孪生模型,旨在最小化信息陈旧度(AoI)以保障虚拟模型的保真度;二是虚拟到物理(V2P)同步,即虚拟体利用高精度的实时状态信息,根据当前网络环境和设备状态做出全局优化的计算卸载与调度决策,并将结果反馈至对应的物理设备,实现端-边-云之间的高效协同^[3]。

2.2 系统概述

为提高物理-虚拟同步任务在异构边缘资源环境下的处理效率,本文引入基于云服务中心(CSC)协调的集中式反向拍卖机制,构建统一的同步任务调度模型,如图 2 所示。虽然本架构适用于广泛的数字孪生边缘计算场景,但针对具有高动态特性的场景(如车联网),我们采用准静态时隙模型。将连续的时间划分为若干个短时隙,假设在每个时隙内,物理实体的位置和信道状态保持相对稳定,而 ARAPVS 机制在每个时隙开始时执行一次资源分配。



该系统结构仍由三个基本组成部分构成:同步对、边缘资源节点和云服务中心。同步对通过

云服务中心提交同步任务请求,边缘资源节点对任务进行竞争性报价,由云服务中心统一调度、匹

配并完成资源分配,从而实现双重同步过程的并发执行;数字孪生(DT)模型维护和最优任务卸载决策生成。

云服务中心(CSC): CSC 是部署于云端的中心化调度实体,在反向拍卖模型中充当“市场清算与定价中心”的角色。其主要职责是收集同步请求与各边缘节点的投标信息,并运行算法决策最终的任务分配方案及结算价格;定价内容源于边缘节点提交的竞争性投标成本,由 CSC 依据 VCG 规则自动计算生成。为了规避 CSC 由于处理大规模实时同步数据而产生的通信瓶颈并增强系统扩展性,本文系统设计遵循“逻辑集中控制,数据分布传输”的原则,实现了控制面与数据面的解耦。在具体实现思路上,CSC 作为逻辑中心控制器仅处理轻量级的控制流,通过专用信令通道收集同步对的任务元数据及边缘节点的成本报价;由于此类信息体积极小,确保了 CSC 调度的低延迟特性。而实际消耗带宽的物理-虚拟同步数据流则由数据面承载,在 CSC 完成拍卖匹配并下发包含任务索引与访问密钥的“匹配准入令牌”后,物理设备(ED)与边缘节点(ES)根据令牌直接通过高速数据链路建立点对点直连通道进行数据交互,从而使高通量数据流绕过 CSC 节点,从根本上消除了中心节点的通信瓶颈。

同步对: 同步对是实现物理-虚拟实时状态对齐的基本单元。定义同步对集合为 $S = \{(A_i, B_i) | i = 1, 2, \dots, I\}$, 其中每一对由一个物理边缘设备 A_i (例如具有私有预算 β_i 用于执行其同步任务的移动终端)和其在虚拟域中的对应数字孪生 B_i 组成。同步对协同请求同步任务 Γ_i 用于解决物理-虚拟同步问题。具体而言, Γ_i 包含由边缘设备 A_i 产生的数字孪生(DT)任务以及其对应数字孪生 B_i 产生的计算任务。

边缘资源节点: 边缘资源节点集合为 $\mathcal{E} = \{E_1, E_2, \dots, E_M\}$, 其中每个边缘资源节点 E_m 代表执行同步对任务并处理任务数据的物理基础设施。每个节点 E_m 最多配备有 H 个资源束(RB), 每个资源束仅能供一个同步对独占使用。节点 E_m 的地理位置记为 (c_m, d_m) , 无线覆盖半径为 r_m 。节点 E_m 提供的第 h 个资源束的性能描述为 $RB_{m,h} = \{\mu_{m,h}\}$, 其中 $\mu_{m,h}$ 表示 $RB_{m,h}$ 的处理能力(例如每秒可处理的 CPU 周期数)。此外, 我们假设每个边缘节点维护一组正交信道 $L_m = \{c_{m,1}, c_{m,2}, \dots\}$, 其可用总带宽 B_m 划分为下行带宽 B_m^d 和上行带宽 B_m^u (满足 $B_m^d + B_m^u = B_m$)。

对于每个物理边缘设备 A_i , 记其地理坐标为 (a_i, b_i) 。设备持续产生的数字孪生任务可表示为 $DT_i = \langle d_i^{DT}, c_i^{DT}, \tau_i^{\max} \rangle$, 其中 d_i^{DT} 是 DT 任务的数据大小, c_i^{DT} 是每单位数据所需的 CPU 周期数, $\tau_i^{\max}$ 是该同步任务可容忍的最大时延。每个同步任务还对应一个设备自身的最大预算 β_i , 该预算不仅反映了设备的支付能力, 更量化了其对维持数字孪生模型高保真度(即最小化信息陈旧度 AoD)的紧迫需求。

每个同步对中的虚拟数字孪生 B_i 由参数 $C_i^v = ((a_i', b_i'), \mathbf{\kappa}_i)$ 来表征。其中 (a_i', b_i') 是其在虚拟空间中的坐标(对应其物理设备 A_i 的地理位置 (a_i, b_i)), 用于支持基于空间位置的决策制定。通过该虚拟位置, B_i 能够在虚拟空间中建立与边缘节点及其他孪生体的相对位置关系, 利用全局视图优势弥补物理设备局部感知的局限, 从而动态评估基于距离的任务卸载机会(例如优先选择距离较近的边缘服务器以降低处理延迟)。向该虚拟孪生赋予空间智能的同时, 向量 $\mathbf{\kappa}_i = \langle \kappa_i^{dc}, \kappa_i^{ss} \rangle$ 编码了其算法性能: κ_i^{dc} 反映了优化设备 A_i 任务卸载决策所用算法的复杂度, 而 κ_i^{ss} 度量了将优化决策通过无线链路同步回设备 A_i 的可靠性。

2.3 本地约束条件建模

通信距离约束: 在数字孪生任务的实际执行过程中, 边缘节点 E_m 仅能为其通信覆盖范围内的设备提供服务。设同步对 i 中的物理设备 A_i 位于坐标 (a_i, b_i) , 边缘节点 E_m 位于 (c_m, d_m) , 其无线通信覆盖半径为 r_m , 则只有当设备与节点之间的欧氏距离满足以下条件时, E_m 才具备为 A_i 提供同步服务的物理可达性:

$$(a_i - c_m)^2 + (b_i - d_m)^2 \leq r_m^2 \quad (1)$$

该约束确保同步任务的数据上传与调度反馈均可在稳定通信链路下完成。

资源容量约束: 为了捕捉同步任务的异构性(解决传统仅按信道计数过于简化的问题), 我们考虑每个同步对 S_i 需要特定数量的资源单位 u_i (如带宽块或计算切片)来满足其 QoS 需求。设 $z_{i,j}^{(m)} = 1$ 表示 E_m 的第 i 条信道被分配给同步对 j (否则为 0), C_m 表示边缘节点 E_m 的总可用资源容量。为避免资源争用, 分配给 E_m 上所有同步对的总资源需求必须满足:

$$\sum_i \sum_j u_i \cdot z_{i,j}^{(m)} \leq C_m, \forall E_m \in \mathcal{E} \quad (2)$$

该约束确保边缘节点具备足够的剩余容量来容纳所有卸载同步任务的异构资源需求。

任务时延约束:边缘节点 E_m 为同步对 S_i 完成任务所需的总延迟包含通信延迟与计算延迟两部分:

(1)通信延迟。设 $g_{m,i}$ 为设备 A_i 与边缘节点 E_m 间的信道增益, P_m 为 E_m 的发射功率, σ_i^2 为设备接收端高斯白噪声功率,则下行速率为

$$v_{m,i}^d = B_m^d \cdot \log\left(1 + \frac{g_{m,i} P_m}{\sigma_i^2}\right) \quad (3)$$

同理,设 p_i 为设备 A_i 的发送功率, σ_m^2 为 E_m 接收端噪声功率,则上行速率为

$$v_{m,i}^u = B_m^u \cdot \log\left(1 + \frac{g_{m,i} p_i}{\sigma_m^2}\right) \quad (4)$$

设 d_i^{DT} 与 d_i^{DS} 分别为上传与下发数据大小, $\zeta_{up}(m)$ 和 $\zeta_{down}(m)$ 为带宽分配比率,上下行传输时延为

$$\begin{aligned} t_{(m,i),DT}^{\text{tran}} &= \frac{d_i^{DT}}{\zeta_{up}(m) \cdot v_{m,i}^u}, \\ t_{(m,i),DS}^{\text{tran}} &= \frac{d_i^{DS}}{\zeta_{down}(m) \cdot v_{m,i}^d} \end{aligned} \quad (5)$$

(2)计算延迟。设 i^{DT} 为每单位数据的 CPU 周期需求, $f_{(m,h)}$ 为 E_m 第 h 个资源束的算力,则计算延迟为

$$t_{(m,i),DT}^{\text{comp}} = \frac{d_i^{DT} \cdot c_i^{DT}}{f_{(m,h)}}, t_{(m,i),DS}^{\text{comp}} = \frac{d_i^{DS}}{f_{(m,h)}} \quad (6)$$

总同步延迟为

$$T_{m,i}^{\text{total}} = t_{(m,i),DT}^{\text{tran}} + t_{(m,i),DT}^{\text{comp}} + t_{(m,i),DS}^{\text{tran}} + t_{(m,i),DS}^{\text{comp}} \quad (7)$$

必须满足以下约束条件:

$$T_{m,i}^{\text{total}} \leq T_i^{\text{max}}, \quad \forall i \in \mathcal{S}, \forall m \in \mathcal{E} \quad (8)$$

该约束确保同步任务在允许的最大时延内完成通信与处理过程。

2.4 数字孪生状态陈旧度模型

与仅关注单次执行时延的传统任务卸载不同,物理-虚拟同步的核心目标是维护数字孪生模型在时间维度上的持续新鲜度。受信息年龄(Age of Information, AoI)概念的启发,我们定义累积陈旧度指标来量化这一同步质量。

设 t 表示当前时隙。对于同步对 i ,令 j_1 为上一次成功同步的时刻, j_2 为下一次计划同步的时刻 ($j_2 > j_1$)。物理设备 A_i 在时间区间 $t' \in [j_1, j_2]$ 内产生的任何状态数据,在 j_2 时刻之前都无法同步到虚拟孪生 B_i 。因此,虚拟端的信息在此期间逐渐变得陈旧。

时刻 t 的瞬时陈旧度(或信息年龄)定义为 $\tau_i(t) = t - j_1$ 。我们将累积陈旧度定义为自上次更

新以来瞬时陈旧度在时间上的积分,这意味着同步滞后带来的负面影响呈非线性增长。根据文献[4]的模型,该指标计算如下:

$$d_{v_i}(t) = \sum_{k=j_1}^t (k - j_1) \approx \frac{\tau_i(t) \cdot (\tau_i(t) + 1)}{2} \quad (9)$$

为了将这一物理指标纳入激励机制与社会福利目标函数,我们定义加权陈旧度惩罚(Weighted Staleness Penalty),记为 $\mathcal{E}_i^{\text{staleness}}(t)$:

$$\mathcal{E}_i^{\text{staleness}}(t) = \alpha \cdot d_{v_i}(t) = \alpha \cdot \frac{\tau_i(t) \cdot (\tau_i(t) + 1)}{2} \quad (10)$$

其中, α 为加权因子,反映应用对数据新鲜度的敏感程度。该二次方增长的惩罚机制能够有效激励系统优先调度那些长期未更新的“饥饿”节点,从而确保物理世界与虚拟世界之间的高保真状态一致性。

2.5 通信与计算模型

边缘资源节点 E_m 为同步对 S_i 执行物理-虚拟同步任务时,必然会产生相应的资源消耗成本。同步任务总成本由两部分构成:计算成本与通信成本。我们假设同步对 S_i 使用资源束 $RB_{m,h}$ 处理业务的成本与需处理的数据量成正比。

(1)计算成本。设 α_m 为节点 E_m 下属资源束 $RB_{m,h}$ 处理每单位数据所需的计算成本(如能耗或服务费用),则边缘节点处理同步对 S_i 任务中两个子任务的计算成本分别为

$$C_{(m,h),DT}^{\text{comp}} = \alpha_m \cdot d_i^{DT} \quad (11)$$

$$C_{(m,h),DS}^{\text{comp}} = \alpha_m \cdot d_i^{DS} \quad (12)$$

其中, d_i^{DT} 与 d_i^{DS} 分别为设备 A_i 上传的 DT 任务数据量和虚拟体 B_i 下发的卸载决策数据量。

(2)通信成本。设 β_m^u 与 β_m^d 分别为 E_m 在上行与下行通道中每单位时间的信道使用成本。则用于上传 DT 任务和下发调度决策所需的通信成本分别为

$$C_{(m,h),up}^{\text{tran}} = \beta_m^u \cdot t_{(m,i),DT}^{\text{tran}} = \frac{\beta_m^u \cdot d_i^{DT}}{v_{m,i}^u} \quad (13)$$

$$C_{(m,h),down}^{\text{tran}} = \beta_m^d \cdot t_{(m,i),DS}^{\text{tran}} = \frac{\beta_m^d \cdot d_i^{DS}}{v_{m,i}^d} \quad (14)$$

其中,上传/下载速率 $v_{m,i}^u$ 与 $v_{m,i}^d$ 定义为

$$\begin{aligned} v_{m,i}^u &= B_m^u \cdot \log_2\left(1 + \frac{g_{m,i} p_i}{\sigma_m^2}\right), \\ v_{m,i}^d &= B_m^d \cdot \log_2\left(1 + \frac{g_{m,i} P_m}{\sigma_i^2}\right) \end{aligned} \quad (15)$$

(3)总同步成本。同步对 S_i 在资源束 $RB_{m,h}$ 上

执行任务所带来的总资源消耗成本可定义为

$$C_{(m,h),i}^{\text{total}} = C_{(m,h),DT}^{\text{comp}} + C_{(m,h),DS}^{\text{comp}} + C_{(m,h),up}^{\text{tran}} + C_{(m,h),down}^{\text{tran}} \quad (16)$$

2.6 问题描述

在本系统中,多个同步对需共享有限的边缘资源,以完成物理-虚拟的双向同步任务。为了激励边缘节点参与并实现动态资源匹配,我们需要构建一个能够平衡同步实时性、资源消耗与用户预算的联合优化模型。

我们将同步对 S_i 的策略空间定义为 Φ_i ,涵盖所有可行的资源获取策略。特别地,系统允许 S_i 以最小广义成本匹配资源。因此,基于前文定义的模型,我们首先给出相关的利润与福利定义:

定义 1(边缘资源节点利润). 边缘节点 E_m 将其资源束出售给同步对 S_i , 价格为 $p_{(m,h)}$ 。则 E_m 的利润为支付价格减去执行成本:

$$\theta_{(m,h)} = p_{(m,h)} - C_{(m,h),i}^{\text{total}} \quad (17)$$

定义 2(考虑陈旧度惩罚的同步对利润). 考虑每个物理设备 A_i 拥有用于同步任务的最大预算 β_i 。与传统模型不同, S_i 的效用受到数字孪生新鲜度的直接影响。我们将 2.4 节定义的加权累积陈旧度惩罚 $\mathcal{E}_i^{\text{staleness}}(t)$ 引入效用函数。若支付价格 $p_{(m,h)}$ 低于其净价值,则 S_i 获得的利润为

$$\rho_i = \beta_i - p_{(m,h)} - \mathcal{E}_i^{\text{staleness}}(t) \quad (18)$$

注意,只有当 $\rho_i > 0$ 时, S_i 才愿意购买资源。该公式激励系统优先调度那些累积陈旧度较高的任务,以避免巨大的效用损失。

定义 3(社会福利). 资源分配的首要经济目标是在满足本地约束的前提下,最大化系统中所有边缘节点与同步对的总利润。设 $\Delta_{M,I}$ 为系统的社会福利,则其计算如下:

$$\begin{aligned} \Delta_{M,I} &= \sum_{m,h} \theta_{(m,h)} + \sum_i \rho_i \\ &= \sum_{m,h,i} (\beta_i - C_{(m,h),i}^{\text{total}} - \mathcal{E}_i^{\text{staleness}}(t)) \cdot \xi_{(m,h),i} \end{aligned} \quad (19)$$

基于上述定义,联合协同计算与分配(JCCA)中的社会福利最大化问题可表述为

$$\max \Delta_{M,I} = \sum_{i=1}^I \sum_{m=1}^M \sum_{h=1}^H (\beta_i - C_{(m,h),i}^{\text{total}} - \mathcal{E}_i^{\text{staleness}}(t)) \cdot \xi_{(m,h),i} \quad (20)$$

s. t.

$$(a_i - c_m)^2 + (b_i - d_m)^2 \leq r_m^2, \quad \forall i, m \quad (20.1)$$

$$\sum_{i=1}^I u_i \cdot \xi_{(m,h),i} \leq C_m, \quad \forall m \in \mathcal{E} \quad (20.2)$$

$$T_{m,i}^{\text{total}} \leq T_i^{\text{max}}, \quad \forall i, m \quad (20.3)$$

$$\sum_{m=1}^M \sum_{h=1}^H \xi_{(m,h),i} = 1, \quad \forall i \in \mathcal{S} \quad (20.4)$$

其中,约束(20.2)确保了边缘节点 E_m 承载的总资源需求不超过其总容量 C_m , 这解决了异构任务的资源争用问题。我们的目标是在满足一系列本地约束(距离、容量、时延)的条件下,最大化总社会福利 $\Delta_{M,I}$ 。

定理 1(NP 难): JCCA 中的社会福利最大化问题是 NP 难的。

证明: 实际上, 该问题包含约束(20.4)和(20.2), 本质上归约为多维背包问题(Multidimensional Knapsack Problem)。具体而言, 广义资源容量约束(20.2)直接映射为背包问题中的容量限制, 其中每个任务具有特定的“重量”(u_i)和“价值”。鉴于多维背包问题是已知的 NP 难问题, JCCA 问题亦为 NP 难。

3 物理-虚拟双向同步机制

为优化有限边缘同步资源的利用并最小化系统成本, 本文将资源分配问题建模为集中式反向拍卖机制, 并引入 Vickrey-Clarke-Groves (VCG) 定价规则, 提出了一种基于反向拍卖的物理-虚拟同步资源分配方法。

3.1 机制设计框架

针对边缘数字孪生网络中资源受限与节点自私性带来的挑战, 本文提出 ARAPVS 机制。该机制的设计基于以下核心动机: 首先, 将同步资源分配建模为三方经济博弈模型: 同步对作为“资源买方”发起同步请求, 边缘节点(ES)作为“资源卖方”参与投标, 而云服务中心(CSC)则充当受信任的“拍卖代理人”与“定价清算中心”。鉴于系统中“边缘节点众多、同步对相对稀缺”的市场特征, 采用反向拍卖模型由 CSC 统一调度, 能有效解决分布式决策导致的资源冲突问题。其次, 为保障机制的经济学属性与计算效率, 我们引入匈牙利-库恩(KM)算法求解二分图最小权完美匹配。该算法能在多项式时间 $O(V^3)$ 内找到全局最优解, 既满足了 VCG 机制对最优分配的理论要求, 又保证了在大规模网络下的计算可行性与低延迟特性。在此基础上, 采用 VCG 规则支付“社会机会成本”, 从理论上确保“如实报价”成为边缘节点的弱占优策略, 消除信息不对称带

来的博弈内耗。

基于此设计理念,ARAPVS 的执行流程包含四个紧密耦合的阶段:(1)任务与资源注册阶段,构建全局供需视图;(2)基于 KM 的任务匹配阶段,计算满足时空约束的最小成本预分配方案;(3)基于反向拍卖的中标者选择阶段,结合匹配结果确定最终服务节点;(4)VCG 支付结算阶段,计算并支付边缘节点的机会成本以完成激励闭环。

3.2 任务与资源注册

为适应 DTEN 中物理实体与网络环境的高动态性,系统采用准静态时隙机制,即在每个时隙开始时触发本阶段流程。在此阶段,同步对和边缘节点通过智能合约提供的消息调用接口,分别上传轻量级的任务请求和资源报价信息。为了落实前述控制面与数据面分离的设计原则,此处交互仅涉及信令层面的任务元数据与成本描述符,而不包含高带宽消耗的原始同步数据载荷,从而在流程起始阶段就确保了中心化调度实体的通信轻量化。实现信息的实时登记与透明共享,具体流程如算法 1 所示。首先,同步对提交包含任务数据量、计算需求、时延约束和基于累积陈旧度惩罚评估出的最大预算 β_i 的任务请求,边缘节点上报可用资源束数量、总资源容量 C_m 、计算能力及对应成本信息。随后,智能合约对上传信息进行格式校验和合法性验证,构建全局任务与资源信息库。对于每条任务请求,系统依据通信距离、时延约束及节点剩余容量,筛选出可服务的边缘资源集合。接着,智能合约记录并维护当前任务-资源匹配状态,确保后续阶段中拍卖机制的数据基础准确完整。这种“先参数注册、后决策授信”的机制实现了控制决策路径与数据传输路径的有效解耦,在保障信息交换透明性与不可篡改性的同时,从协议交互层面规避了大规模同步任务对中心节点的带宽冲击,为后续高效的资源调度与分配奠定了坚实基础。

算法 1. 任务与资源注册阶段

输入:同步对集合 $S=\{(A_i, B_i)\}$,边缘节点集合 $\mathcal{E}=\{E_m\}$
 输出:任务请求集合 $\mathcal{I}$,资源报价集合 $\mathcal{R}$,任务-资源匹配候选集 $\mathcal{M}$

1. 初始化 $\mathcal{I} \leftarrow \emptyset, \mathcal{R} \leftarrow \emptyset, \mathcal{M} \leftarrow \emptyset$
2. FOR 每一个同步对 $(A_i, B_i) \in S$ DO
 构造任务请求 Γ_i ,上传至智能合约并加入 $\mathcal{I}$
3. ENDFOR
4. 每一个边缘节点 $E_m \in \mathcal{E}$ DO
5. FOR $h=1$ TO H DO

构造资源报价 $R_{m,h}$,上传至智能合约并加入 $\mathcal{R}$

6. ENDFOR
7. ENDFOR
8. 智能合约验证并登记任务与资源信息
9. FOR 每一个 $\Gamma_i \in \mathcal{I}$ DO
10. FOR 每一个 $R_{m,h} \in \mathcal{R}$ DO
11. IF 满足通信距离和时延约束及资源容量条件
 THEN 将 $(\Gamma_i, R_{m,h})$ 加入候选集 $\mathcal{M}$
12. ENDIF
13. ENDFOR
14. ENDFOR
15. RETURN $\mathcal{I}, \mathcal{R}, \mathcal{M}$

3.3 任务匹配和中标者选择

任务匹配:在完成与资源注册后,由于各路边缘单元中可用资源束数量有限,需要在满足局部性约束与容量约束的前提下,选择一组同步对请求进行执行,以最大化社会福利。为此,我们将任务分配问题建模为一个最小权完美匹配问题^[5]。

具体而言,对于每个 RSU E_m ,构造一个辅助二分图 $G'_m=(V'_m, E'_m)$ 。顶点集 V'_m 由同步对任务集合 V'_a 和资源束集合 V'_b 组成。如果在满足通信距离、时延及资源容量约束的前提下,资源束 $B_{\{m,h\}}$ 能够服务任务 Γ_i ,则在二者之间建立一条边。

为了在匹配过程中体现对高陈旧度任务的优先调度,我们将边 $(\Gamma_i, RB_{\{m,h\}})$ 的权重定义为“广义成本(Generalized Cost)”,其集成了执行成本与累积陈旧度惩罚:

$$\omega(\Gamma_i, RB_{\{m,h\}}) = C_{(m,h),i}^{\text{total}} - \mathcal{E}_i^{\text{staleness}}(t) \quad (21)$$

在此定义下,累积陈旧度 $\mathcal{E}_i^{\text{staleness}}(t)$ 越高的任务,其对应的边权重越小。由于 KM 算法旨在寻找总权重最小的匹配,因此该机制会自适应地优先选择那些长期未更新的“饥饿”任务,从而有效维护数字孪生模型的保真度。

在图的构建过程中,若边 $(\Gamma_i, RB_{\{m,h\}})$ 违反了任意局部约束,则将该边权重设为无穷大(∞),表示匹配非法。为处理任务数与资源束数不相等的情况,引入虚拟节点并设定相关边权为无穷大。如图 3 所示,当且仅当资源束 $RB_{\{m,h\}}$ 满足所有局部约束条件时,才能为同步对任务 Γ_i 提供服务。例如, R_3 与任务 Γ_1 之间的距离 $D_{3,1}$ 不满足通信距离约束,因此任务 Γ_1 无法匹配资源束 $RB_{\{3,1\}}$ 和 $RB_{\{3,2\}}$;又如,任务 Γ_3 在资源束 $RB_{\{2,1\}}$ 上完成所需的最小时延超过了其最大时延限制 T_3^{max} ,故 Γ_3 无法匹配 $RB_{\{2,1\}}$;此外,资源束 $RB_{\{2,2\}}$ 无法为任务 Γ_2 分配足够的通信资源,因此 Γ_2 无法匹配该资源束。若边

$(\Gamma_i, RB_{\{m,h\}})$ 之一的任一局部约束不满足, 则将该边权重设为无穷大 ∞ , 表示 Γ_i 与 $RB_{m,h}$ 之间的匹配非法^[6]。同时, 通常情况下同步对集合与资源束集合的大小相等, 即 $|\mathcal{S}| = |\mathcal{RB}|$, 因此与虚拟节点相关联的边权也设为无穷大^[7]。随后, 利用 Kuhn-Munkres(KM) 算法求解二分图的最小权完美匹配 M_m , 获得在当前陈旧度与成本权衡下的最优预分配方案。




图3 个体理性验证

冲突解决的机会成本原则: 由于引入了异构资源容量约束, 当多个同步对 S_i 同时匹配到边缘节点 E_m , 且它们的聚合资源需求超过了 E_m 的总容量 C_m 时, 即发生“资源容量冲突”。这与传统的单一信道冲突不同, 是一个典型的背包约束问题。

为解决此冲突, 本文设计了基于机会成本的策略。定义机会成本为: 若选择当前同步对集合, 所放弃的未被选中任务中价值最高的替代方案。系统将计算不同组合下的机会成本, 优先保留那些“单位资源带来的社会福利增益”最高的任务, 剔除机会成本最高的任务, 直至满足容量约束^[8-10]。

中标者选择: 在完成匹配与冲突消解后, 云服务中心(CSC)需确定最终的中标者。为保证机制的公平性与激励相容性, 本文采用集中式反向拍卖模型^[11]。

具体流程如下: 对于每个同步对 S_i , CSC 从其可行资源集合中收集所有边缘节点 E_m 的报价 $b_{m,i}$ 。CSC 将报价从低到高排序, 选择报价次低的节点作为中标者。这种次价拍卖机制能够有效抑制边缘节点的虚假高价行为。当出现多个节点报价相同且为次低价时, 再次利用机会成本原则进行裁决。

该阶段的获胜者选择机制不仅保证了任务的执行质量, 还通过结合陈旧度感知的权重设计与容量感知的冲突消解, 确保了全局社会福利的最大化。获胜结果及其次低报价将在下一阶段用于 VCG 支付规则的定价计算。

3.4 支付规则

对于每个中标项目, CSC 需要做出合理的付款决定, 以确保每个边缘节点诚实地报告其资源的价值。在 ARAPVS 机制中, 定价的核心内容源于各边缘节点在注册阶段提交的竞争性投标报价。在本文中, 我们采用了基于标准 VCG 机制的支付规则, 适用于 GWBSM。所提出的支付规则能够在保证个体合理性和真实性的前提下, 鼓励边缘节点参与计算卸载。

在 VCG 机制中, 每个中标者的支付金额等于其被移除后系统广义总成本的增加量, 即其对其他参与者造成的机会成本。这意味着结算价格并非由 CSC 随意设定, 而是由 CSC 依据所有竞争节点的投标信息, 通过量化该节点对系统整体利益的影响(即社会机会成本)自动计算生成。为此, 基于 3.3 节定义的广义成本模型, 我们重新定义计算逻辑:

定义 4(边缘节点广义真实成本). 设 $\mathcal{T}_m$ 为分配给边缘节点 E_m 的同步任务集合。 E_m 的真实广义成本 α_m 定义为该节点执行这些任务的总执行成本减去由此带来的陈旧度收益:

$$\begin{aligned} \alpha_m &= \sum_{\Gamma_i \in \mathcal{T}_m} \omega(\Gamma_i, RB_{\{m,h\}}) \\ &= \sum_{\Gamma_i \in \mathcal{T}_m} (C_{\{m,h\},i}^{\text{total}} - \mathcal{E}_i^{\text{staleness}}(t)) \end{aligned} \quad (22)$$

设 $Y_{\mathcal{E}}$ 为所有可用节点 $\mathcal{E}$ 下的系统最优广义总成本; $Y_{\mathcal{E}/\{m\}}$ 为从一开始就不考虑 E_m 参与时的系统最优广义总成本。根据 VCG 规则, E_m 应该获得的支付金额为

$$p_m = Y_{\mathcal{E}/\{m\}} - (Y_{\mathcal{E}} - \alpha_m) \quad (23)$$

根据式(23), 支付价格 p_m 本质上是由 E_m 的“最佳替代者”的成本(即 $Y_{\mathcal{E}/\{m\}}$)决定的, 而与 E_m 自身的具体报价 α_m 无关。这意味着, 当边缘节点 E_m 的报价在一个特定区间内变化时, 只要它仍然是该任务的最佳执行者, 其对应的 VCG 支付金额将被次优解锁定并保持恒定。这种支付与报价的解耦特性, 从理论上保证了机制的真实性, 即节点无法通过操纵报价来改变支付结果。

支付规则的计算过程如算法 2 所示。核心步骤是在全局最优匹配结果基础上, 分别移除每个中标节点并重新求解最优成本, 从而计算机会成本并确定支付。

算法 2. 支付规则

输入: 中标节点集合 $\mathcal{E}^{\text{win}}$, 系统最优匹配方案 $\{\xi_{m,h}, i\}$

输出: 各中标节点支付金额 $\{p_m\}$

1. 初始化 $p_m \leftarrow 0, \forall m \in \mathcal{E}^{\text{win}}$
2. FOR 每一个中标节点 $E_m \in \mathcal{E}^{\text{win}}$ DO
3. 计算 α_m (定义: E_m 的广义执行成本)
4. 计算 $Y_{\mathcal{E}}$ (当前全局最优广义总成本)
5. 从初始可行匹配集中排除 E_m , 重新运行 KM 匹配, 得到系统最优总成本 $Y_{\mathcal{E}/\{m\}}$
6. 根据式(23) 计算支付金额:
 $p_m \leftarrow Y_{\mathcal{E}/\{m\}} - (Y_{\mathcal{E}} - \alpha_m)$
7. ENDFOR
8. RETURN $\{p_m\}$

3.5 ARAPVS 算法

为了在复杂的边缘计算环境中实现社会福利最大化, 算法 3 展示了 ARAPVS 的整体执行框架, 具体流程如下:

在阶段 1, 调用算法 2 执行任务与资源注册, CSC 验证并构建任务-资源候选匹配集(第 1~2 行)。

在阶段 2, 对于每个边缘节点, CSC 构造辅助二分图并采用 KM 算法求解最小广义权重完美匹配; 若存在资源容量冲突, 则应用机会成本原则裁决(第 3~7 行)。

在阶段 3, CSC 执行集中式反向拍卖, 对于每个同步对, 收集并排序各候选边缘节点的, 选择次低报价节点作为关键定价参考, 若出现并列则按机会成本原则裁决(第 8~12 行)。

在阶段 4, 调用算法执行 VCG 支付规则计算, 确定各中标节点的最终支付金额(第 13 行)。

算法 3. 总流程

输入: 同步对集合 $\mathcal{S}$, 边缘节点集合 $\mathcal{E}$

输出: 最终任务-资源分配结果及支付金额 $\{p_m\}$

1. /* 阶段 1: 任务与资源注册 */
2. 调用算法 3 获取 $\mathcal{I}, \mathcal{R}, \mathcal{M}$
3. /* 阶段 2: 任务匹配与冲突处理 */
4. FOR 每一个边缘节点 $E_m \in \mathcal{E}$ DO
5. 构造二分图 G'_m (基于广义权重 ω) 并使用 KM 算法求解匹配结果 $\mathcal{M}_m$
6. IF 存在资源容量冲突 (Eq. 20.2) THEN
7. 按机会成本原则选择优胜者
8. ENDIF
9. ENDFOR
10. /* 阶段 3: 中标者选择 */
11. FOR 每一个同步对 $S_i \in \mathcal{S}$ DO
12. 收集候选边缘节点广义报价并排序
13. 选择次低报价节点为定价基准
14. IF 次低报价存在并列 THEN
15. 按机会成本原则解决容量争用
16. ENDIF

17. ENDFOR
18. /* 阶段 4: VCG 支付规则 */
19. 调用算法 3 计算 $\{p_m\}$
20. RETURN 最终任务-资源分配结果及支付金额 $\{p_m\}$

3.6 机制性质分析

在本部分中, 我们将证明所提出的支付规则满足两个关键机制性质: 个体理性与真实性。个体理性保证每个中标边缘节点在参与物理-虚拟同步任务执行后, 其效用均为非负, 从而确保节点积极参与资源分配过程。真实性保证边缘节点无法通过虚报其资源成本或性能参数来获得更高的效用, 从而促使所有节点如实上报资源信息, 维持机制的公平性与有效性。

定理 2(个体理性). 采用式(23)给出的支付规则满足个体理性性质。即对任一中标边缘节点 E_m , 其效用

$$\delta_m \triangleq p_m - \sigma_m \geq 0 \quad (24)$$

其中, σ_m 为 E_m 的真实总执行成本。

证明: 由式(23)可得

$$p_m = Y_{\mathcal{E}/\{m\}} - Y_{\mathcal{E}} + \alpha_m \quad (25)$$

又由“移除一重优化”的定义关系可得

$$Y_{\mathcal{E}}^m = Y_{\mathcal{E}} + (\beta_m - \alpha_m) \quad (26)$$

其中, $Y_{\mathcal{E}}^m$ 表示在最优分配中移除 E_m 及其任务后的其他中标者总成本。

将式(22)代入标准 VCG 展开式:

$$p_m = \beta_m - (Y_{\mathcal{E}}^m - Y_{\mathcal{E}/\{m\}}) \quad (27)$$

可得与式(24)等价的形式:

$$\begin{aligned} p_m &= \beta_m - (Y_{\mathcal{E}} + (\beta_m - \alpha_m) - Y_{\mathcal{E}/\{m\}}) \\ &= Y_{\mathcal{E}/\{m\}} - Y_{\mathcal{E}} + \alpha_m \end{aligned} \quad (28)$$

当各边缘节点如实报价时, $\alpha_m = \sigma_m$, 由式(20)

与式(24)可得

$$\begin{aligned} \delta_m &= p_m - \sigma_m = (Y_{\mathcal{E}/\{m\}} - Y_{\mathcal{E}} + \alpha_m) - \sigma_m \\ &= Y_{\mathcal{E}/\{m\}} - Y_{\mathcal{E}} \geq 0 \end{aligned} \quad (29)$$

其中, 不等式由最优性保证: 在最小化系统广义总成本的情形下, 参与者集合更大时的最优值不劣于参与者更少时的最优值, 即 $Y_{\mathcal{E}} \leq Y_{\mathcal{E}/\{m\}}$ 。因此 $\delta_m \geq 0$, 个体理性得证。

定理 3(真实性). 在支付规则

$$p_m = Y_{\mathcal{E}/\{m\}}(\mathcal{A}, \mathcal{F}) - Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F}) + \alpha_m \quad (30)$$

下, 边缘节点如实上报其单位成本是弱占优策略。即对每个中标边缘节点 E_m , 如实申报 $\phi_m = v_m$ (v_m 为真实单位成本) 能够使其效用不小于任意不真实申报时的效用。

证明: 记 v_m 为 E_m 的真实单位成本, ϕ_m 为其申

报价。令

$$\begin{aligned}\sigma_m &\triangleq \sum_{i \in \mathcal{I}_m} \omega(\Gamma_i, RB_{\{m, h\}}) \\ &= \sum_{i \in \mathcal{I}_m} (v_m \cdot f_{i, m} - \mathcal{E}_i^{\text{staleness}})\end{aligned}\quad (31)$$

为 E_m 的真实广义总成本; 当其申报为 ϕ_m 时, 对应的“申报成本”为

$$\alpha_m \triangleq \sum_{i \in \mathcal{I}_m} (\phi_m \cdot f_{i, m} - \mathcal{E}_i^{\text{staleness}}) \quad (32)$$

若 E_m 如实申报, 则有 $\alpha_m = \sigma_m$ 。

设 $(\mathcal{A}, \mathcal{F})$ 为在当前投标集合下使系统广义成本目标 $Y_{\mathcal{E}}(\cdot)$ 最小的最优解; 当 E_m 改变申报为 $\phi_{m'}$ 时, 系统对应的最优解记为 $(\mathcal{A}', \mathcal{F}')$, 并记

$$\alpha_{m'} \triangleq \sum_{i \in \mathcal{I}_{m'}} (\phi_{m'} \cdot f_{i, m} - \mathcal{E}_i^{\text{staleness}}) \quad (33)$$

为此时报价诱导的“申报成本”。根据支付规则(30), E_m 的效用定义为收到的支付减去真实成本:

$$\delta_m \triangleq p_m - \sigma_m \quad (34)$$

第一步: 不真实申报下的效用。当 E_m 申报为 $\phi_{m'}$ 时, 其支付为

$$p_{m'} = Y_{\mathcal{E}/\{m\}}(\mathcal{A}', \mathcal{F}') - Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}') + \alpha_{m'} \quad (35)$$

故其效用为

$$\begin{aligned}\delta_{m'} &= p_{m'} - \sigma_m \\ &= (Y_{\mathcal{E}/\{m\}}(\mathcal{A}', \mathcal{F}') - Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}')) \\ &\quad + \alpha_{m'} - \sigma_m\end{aligned}\quad (36)$$

第二步: 如实申报下的效用。当 E_m 如实申报 ($\phi_m = v_m$) 时, 由 $\alpha_m = \sigma_m$ 与式(26)得到

$$\delta_m = p_m - \sigma_m = (Y_{\mathcal{E}/\{m\}}(\mathcal{A}, \mathcal{F}) - Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F})) \quad (37)$$

第三步: 两种申报下效用之差。令

$$\hat{\delta}_m \triangleq \delta_{m'} - \delta_m \quad (38)$$

由式(32)与(33)可得

$$\begin{aligned}\hat{\delta}_m &= (Y_{\mathcal{E}/\{m\}}(\mathcal{A}', \mathcal{F}') - Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}')) + \alpha_{m'} - \sigma_m \\ &\quad - (Y_{\mathcal{E}/\{m\}}(\mathcal{A}, \mathcal{F}) - Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F})) \\ &= \underbrace{Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F}) - Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}')}_{(i)} + \underbrace{\alpha_{m'} - \sigma_m}_{(ii)} \\ &\quad + \underbrace{Y_{\mathcal{E}/\{m\}}(\mathcal{A}', \mathcal{F}') - Y_{\mathcal{E}/\{m\}}(\mathcal{A}, \mathcal{F})}_{(iii)}\end{aligned}\quad (39)$$

第四步: 最优性与不等式。因为 $(\mathcal{A}, \mathcal{F})$ 是在真实出价集合下最小化 $Y_{\mathcal{E}}(\cdot)$ 的解, 有

$$Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F}) \leq Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}') \quad (40)$$

故式(39)中的项(i)非正:

$$(i) = Y_{\mathcal{E}}(\mathcal{A}, \mathcal{F}) - Y_{\mathcal{E}}(\mathcal{A}', \mathcal{F}') \leq 0 \quad (41)$$

另一方面, $Y_{\mathcal{E}/\{m\}}(\cdot)$ 与 E_m 的申报无关(在移除 E_m 的问题中, 其报价不起作用), 因此 $(\mathcal{A}, \mathcal{F})$ 也

是 $Y_{\mathcal{E}/\{m\}}(\cdot)$ 的一个可行解, 而 $(\mathcal{A}', \mathcal{F}')$ 是在同一候选集下的最优解, 故

$$(iii) = Y_{\mathcal{E}/\{m\}}(\mathcal{A}', \mathcal{F}') - Y_{\mathcal{E}/\{m\}}(\mathcal{A}, \mathcal{F}) \leq 0 \quad (42)$$

至于项(ii), 当 $\phi_{m'}$ 偏离真实值 v_m 时, $\alpha_{m'} - \sigma_m = (\phi_{m'} - v_m) \sum_{i \in \mathcal{I}_{m'}} f_{i, m}$ 的符号取决于偏离方向, 但与(i)、(iii)的非正性叠加后, 总差值满足:

$$\hat{\delta}_m \leq 0 \quad (43)$$

由式(39)可知, E_m 通过不真实申报(无论抬高或压低)都不能提升其效用, 即

$$\delta_m \geq \delta_{m'}, \text{ 对任意 } \phi_{m'} \neq v_m \quad (44)$$

因此, 如实申报 $\phi_m = v_m$ 是 E_m 的弱占优策略, 命题得证。

讨论: 由式(37)可知, 中标节点的效用 δ_m 仅取决于 $Y_{\mathcal{E}/\{m\}}$ 与 $Y_{\mathcal{E}}$ 之差, 而与自身的具体报价数值在一定范围内解耦。这从理论上解释了实验结果中支付“平台区间”的成因, 即只要报价低于关键临界值, 支付金额保持恒定, 进一步验证了机制的真实性。

4 实验结果和性能分析

本文所研究的优化问题属于 NP-hard 问题, 无法在多项式时间内获得最优解, 因此无法从理论上给出所提 ARAPVS 的最优性差距。为此, 我们通过仿真实验对 ARAPVS 的最优性差距进行分析。本节对 ARAPVS 的性能进行系统评估, 并与若干基线方法进行对比, 同时研究关键参数设置对 ARAPVS 性能的影响^[12]。

4.1 仿真实验设置

为了验证所提出的基于反向拍卖的物理-虚拟同步机制(ARAPVS)的性能, 本研究设计了基于 Python 3.9 的数值仿真实验, 并采用表 1 和表 2 所列的参数设置。

表 1 同步任务类型配置

任务类型	任务参数		
	数据量 (MB)	CPU 周期数 (百万周期)	最大可容忍 时延(s)
类型 1	0.1	3000	1.0
类型 2	0.2	2000	1.5
类型 3	0.3	1500	2.0

系统模型为单小区场景, 边缘资源节点均匀分布, 同步对随机分布。

为了模拟边缘环境的异构性, 每个同步任务的

资源需求 u_i 在 $[1, 5]$ 单位内随机生成, 边缘节点的总资源容量 C_m 在 $[20, 50]$ 单位内变化。陈旧度加权因子 α 默认设置为 1.0。

表 2 仿真参数设置

参数	值
同步任务对数	默认 25(敏感性分析:[10—40])
边缘节点数 S	默认 8(敏感性分析:{4, 8, 12, 20, 30})
边缘节点资源容量	$[20, 50]$ 单位
任务资源需求	$[1, 5]$ 单位
上行带宽 B	20/40 MHz
边缘节点空闲算力	$[10, 20]$ GHz
终端发射功率 P_n	20 dBm
背景噪声功率	-100 dBm
路径损耗模型	$L = 140.7 + 36.7 \log_{10} d[\text{km}]$, 阴影标准差 8 dB
陈旧度加权因子 α	默认 1.0

信道模型采用路径损耗公式: $L[\text{dB}] = 140.7 + 36.7 \log_{10} d[\text{km}]$, 并考虑对数阴影衰落。背景噪声功率为 -100 dBm, 终端发射功率为 20 dBm, 边缘节点的单位广义成本报价服从 $[0.1, 0.2]$ 货币单位/百万周期的正态分布。同步任务分为三类(见表 1), 其数据量、CPU 周期数和最大可容忍时延作为 P2V/V2P 同步任务的工作负载参数。

针对 ARAPVS 的同步工作流, 仍采用有向任务图建模, 生成方法参考文献[13]。所有实验均在 Intel(R) Core(TM) i7-10750H@2.60 GHz, 16.0 GB 内存的计算机上完成。除非特别说明, 表 1 和表 2 中的参数均为默认设置。

为了全面评估 ARAPVS 的性能, 我们将所提出的机制与以下四种基准方法进行比较:

随机分配(Random Allocation, RA)^[13]: 将每个同步任务随机分配给满足资源容量约束的相邻边缘节点。

贪心分配(Greedy Allocation, GA): 优先选择执行成本最低的边缘节点进行任务卸载。

McAfee 机制(MM)^[14]: 经典的占优策略双向拍卖机制, 通过关键价格确定交易, 保证诚实报价。

深度确定性策略梯度(DDPG): 代表性的基于深度强化学习(DRL)的资源调度算法。在仿真中, CSC 作为智能体, 通过观察网络状态, 利用 Actor-Critic 架构学习连续的资源分配策略, 以最大化长期累积社会福利。

4.2 个体理性和真实性性质验证

为了验证 ARAPVS 机制的经济学属性, 我们首先通过比较每个中标边缘节点的 VCG 支付与其

真实广义执行成本来验证个体理性(IR)。随后, 我们随机选择一个边缘节点, 观察其效用随申报报价变化的趋势, 以验证机制的真实性(IC)。

图 3 展示了 ARAPVS 机制的个体理性验证结果。可以清晰地观察到, 所有中标节点的支付金额均严格高于或等于其真实成本。这表明, 在 ARAPVS 机制下, 诚实参与竞价的边缘节点能够获得非负效用, 从而验证了定理 2 所述的个体理性。




图 4 真实性验证

图 4 进一步展示了 ARAPVS 机制的真实性验证结果, 我们随机选取一个真实单位广义成本为 0.13、对应总成本为 82.7 的边缘节点进行分析。具体而言, 为了防止恶意节点通过极端低价扰乱市场或因报价不足以覆盖服务质量成本而导致任务失败, ARAPVS 机制引入了“可信报价约束”, 当申报出价显著低于市场基准时, 系统将其判定为无效报价并剔除, 而当申报出价过高时, 节点因成本劣势被 KM 匹配算法淘汰, 只有当申报出价处于合理区间时, 节点保持中标状态, 此时 VCG 支付金额始终锁定在约 110.1, 这验证了支付价格由次优解决定且与节点自身报价解耦的理论分析, 充分证明了 ARAPVS 机制能够保持良好的真实性。

4.3 ARAPVS 的性能表现

我们基于一组关键性能指标对所提出的 ARAPVS 机制进行了评估, 包括社会福利、总任务处理时延以及参与者的收益, 并在不同规模的同步对与边缘资源节点场景下进行了实验, 如图 5 至图 8 所示。我们将其与 RA、GA、MM 以及 DDPG 等基准方法进行了全面对比。

总任务处理时延。如图 5 所示, 随 N 增加, ARAPVS 时延呈适度增长, 体现了 KM 匹配的高效性。相比之下, RA 因盲目分配导致时延剧增; GA 虽时延最低, 但忽略了 AoI 约束。MM 机制因保障真实性牺牲了部分资源效率, 且 DDPG 在处理

大规模离散约束时搜索效率有限,二者时延均高于 ARAPVS。ARAPVS 通过机会成本策略平衡负载,在拥塞场景下表现优于 MM 与 DDPG,且随 M 增加展现出良好的可扩展性。




图 5 不同网络规模下各算法的总任务处理时延对比




图 6 各对比算法的系统利润分布与社会福利评估

同步对与边缘节点的利润。如图 6 所示,系统总利润随任务数量 N 的增加而上升,但由于资源竞争加剧,同步对的平均利润呈现下降趋势。相比仅保证报价真实性的 MM 机制,ARAPVS 通过优化执行成本与陈旧度惩罚之间的权衡,实现了更高的社会福利与组合利润^[15]。由于 DDPG 在处理离散资源匹配约束时易陷入局部最优,其获得的系统利润低于 ARAPVS。而 GA 虽然决策迅速,但因忽视陈旧度带来的效用损失,导致其利润表现较差。ARAPVS 通过势博弈建模与 VCG 定价设计,在多项式时间内实现了对 NP 难社会福利最大化问题的近似求解,展现了优异的可扩展性。

社会福利。如图 7 所示,本文评估了各算法在连续准静态时隙(即实验轮次)下的社会福利表现。ARAPVS 在所有场景中均表现出最优且最稳健的性能。由于该机制采用了基于 KM 算法的精确匹配逻辑,它在每一轮次均能即时计算出全局最优的资源映射方案,因此曲线从初始阶段便保持在高位平稳运行。相比之下,DDPG 算法受限于启发式搜索的本质,需要经历漫长的离线训练轮次以学习复杂的分配策略,导致其在前期福利水平较低且收敛过程伴随明显的性能波动。而 MM 机制由于其贪婪匹配的局限性,难以在异构资源争用激烈的环境下实现全局协同,其社会福利始终低于 ARAPVS。实验结果定量地证明了所提机制在动态时隙序列中具有极高的决策效率与系统价值保障能力。




图 7 不同场景下各算法社会福利随迭代轮次的收敛性对比




图 8 算法执行时间随任务数量与节点规模变化的对比分析

计算效率。图 8 评估了 ARAPVS 的收敛效率。随着 N 的增加,由于协调复杂度的提升,执行时间有所增长,但对 M 的变化不敏感。这主要得益于系统架构层面的控制面与数据面分离设计:由于 CSC 仅需通过信令通道处理基于轻量级元数据的拍卖模型,而无需感知和处理庞大的同步数据载荷,从而极大缓解了中心节点的算力与通信压力。这验证了 KM 匹配策略能够在大规模网络中确保快速收敛。与需要大量训练时间的 DDPG 相比,ARAPVS 作为一种在线机制,能够更快速地适应网络环境的动态变化。

平均累积陈旧度(AoI)。为了量化物理-虚拟同步的质量,我们评估了系统的平均累积陈旧度。较低的陈旧度意味着数字孪生模型能够更实时地反映物理实体的状态变化。如图 9 所示,ARAPVS 凭借其反向拍卖机制中的广义成本优化逻辑,通过 KM 算法实现了任务与资源的全局最优匹配,在所有场景中均保持最低的 AoI。相比之下,RA




图9 不同算法与任务规模下的平均累积陈旧度对比热图

与 GA 完全忽视了数据新鲜度对同步质量的影响,导致 AoI 极高。MM 机制由于其双向拍卖中的舍弃规则导致资源分配冗余,而 DDPG 受限于训练波动,二者的同步稳定性与性能均不及基于反向拍卖的 ARAPVS 机制。

5 相关工作

近年来,数字孪生技术与边缘计算的融合推动了动态系统优化研究。例如,曹等人^[16]构建了数字孪生辅助的车载边缘计算系统,通过孪生模型映射车辆动态行为以优化任务卸载;李等人^[17]为边缘计算场景设计了数字孪生架构,借助孪生模型提升无人机集群的任务分配效率。然而,这些研究仅聚焦于任务卸载策略的设计,将数字孪生单纯作为调度过程的辅助工具,却忽略了实时物理-虚拟同步机制的构建^[18]。这导致数字孪生模型在动态场景下的精度难以保障,进而削弱了系统决策的可靠性^[19]。而这正是本文的核心研究动机:通过设计基于反向拍卖的资源分配机制,在数字孪生辅助的边缘计算网络中实现稳定的实时物理-虚拟同步,从而提升数字孪生模型精度与系统决策的可靠性^[20]。

事实上,在数字孪生辅助边缘计算系统中,物理-虚拟同步问题可转化为“同步效率-资源成本”协同优化的任务,鉴于边缘节点的个体合理性和自私性,在没有奖励的情况下,很难主动完成感知任务。因此,需引入激励机制以促使车辆完成感知任务,例如博弈论、拍卖理论等,而反向拍卖则是其中一种可行的方法^[21]。现有拍卖类机制可分为双向拍卖与单向拍卖两类,均存在明显局限。在双向拍卖研究中,Sun 等^[22]提出 BDA 与 DPDA 两种动态定价策略,通过建立移动设备(MD)与边缘节点的匹配模

型实现资源分配,但该方法仅关注“任务-资源”的基础供需匹配,未将物理-虚拟同步的核心指标纳入拍卖约束;Jiao 等人^[23]设计了面向区块链网络的云/雾计算拍卖机制,依托价格杠杆调节资源供需,却未考虑数字孪生场景下同步误差与资源分配量的耦合关系,导致同步质量难以保障。Peng 等人^[24]虽提出区块链辅助的协同卸载拍卖,通过多智能体强化学习优化任务分配,但仍以“卸载效率”为核心目标,未将物理-虚拟双向状态更新的资源需求纳入竞价评估框架^[25]。

单向拍卖(尤其是反向拍卖)因“买方主导、卖方竞价”的特性,更契合云服务中心(CSC)主导的物理-虚拟同步资源调度场景,但其现有应用仍存在场景适配性不足的问题^[26]。在边缘计算领域,Zhou 等人^[27]提出反向拍卖驱动下的 RACORAM 机制,通过约束梯度下降分配(CGDAM)与贪心随机获胜者选择(GWBSM)优化 CSC 成本,同时基于 VCG 规则保障边缘节点的个体理性,但该机制聚焦传统计算卸载任务,未将物理-虚拟同步的动态需求转化为资源分配约束,无法直接适配数字孪生场景;Lu 等人^[28]提出拍卖驱动的聚类联邦学习机制,虽通过反向拍卖激励边缘节点参与模型训练,却未涉及物理-虚拟同步的双向资源协同需求。在车辆感知场景中,Liu 等人^[29]提出 Hector 方法,将车辆轨迹映射为时空约束,通过反向拍卖激励车辆绕行以扩大感知覆盖,但未考虑数字孪生中车辆物理状态与虚拟模型的实时同步需求;Gao 等人^[30]针对车辆感知的非确定性设计反向拍卖模型,引入数据质量评估优化获胜者选择,却未关联虚拟模型更新的算力需求;Chen 等人^[31]构建时效性优先的反向拍卖机制,通过子模块最大化提升请求者效用,仍局限于单向感知任务,未覆盖物理-虚拟双向同步的资源调度需求。

相比之下,本文将“同步性能-资源成本-社会福利”的协同优化融入数字孪生辅助边缘计算网络(DTEN)的资源分配过程,提出基于反向拍卖的 ARAPVS 机制。

该机制通过云服务中心(CSC)的集中式调度,综合考虑三方面核心需求:一是系统收益最大化,二是实时物理-虚拟同步需求,三是异构边缘资源限制,这一设计显著超越了现有研究仅聚焦任务卸载策略或采用“随机分配”“贪心算力优先”等简化分配模型的局限^[32]。

现有研究多将数字孪生作为调度辅助工具,未

建立同步需求与资源分配的深度关联;而本文深入挖掘物理-虚拟同步与资源分配的内在耦合关系,通过反向拍卖的全局任务-资源匹配与 VCG 定价的激励相容性,既确保数字孪生模型的实时精度,又提升系统在动态场景下的适应性。

为清晰呈现本文工作与现有研究的差异,表 3 从核心优化目标、同步需求考量、机制特性(真实性/个体理性)、资源约束适配四个维度进行总结。

表 3 ARAPVS 与现有机制的核心特性对比

文献来源	核心特性				
	数字孪生应用	物理-虚拟同步	资源联合分配	公平性	个体理性
[1]	✓	×	✓	×	×
[2]	✓	✓	×	×	×
[3]	✓	×	×	×	×
[10]	×	×	×	✓	✓
[15]	×	×	×	×	×
[16]	×	×	✓	✓	✓
[19]	×	×	×	✓	×
[22]	×	×	✓	✓	✓
[23]	×	×	×	✓	✓
[24]	×	×	✓	✓	×
ARAPVS	✓	✓	✓	✓	✓

注:数字孪生应用:是否用数字孪生辅助资源分配;物理-虚拟同步:是否将物理-虚拟状态同步作为核心目标;资源联合分配:是否同时优化算力与通信资源;个体理性:是否保障边缘节点收益非负。

6 结束语

本文提出了一种面向数字孪生辅助边缘计算网络的基于集中式反向拍卖的物理-虚拟同步资源分配联合决策机制(ARAPVS)。为实现该目标,首先将决策问题建模为一个紧耦合的多维联合决策优化任务,联合优化同步对-边缘节点匹配、计算-通信资源分配与物理-虚拟状态同步,在满足同步时延约束的前提下最小化边缘节点总成本。

接着,设计了 ARAPVS 机制:遵循逻辑集中控制与数据分布传输的分离设计原则,通过轻量级信令授权与分布式高速链路直连,有效解决了中心化调度在边缘数字孪生场景下的通信瓶颈难题。随后,采用集中式反向拍卖全局筛选“低成本且同步适配性高”的边缘节点;引入 VCG 定价规则保障激励相容性;利用匈牙利-库恩(KM)匹配算法实现同步任务与边缘资源束的权重化匹配;通过反向拍卖的全局调度逻辑优化资源分配结果,避免局部最优。此外,从理论上严格证明了所提机制的个体理性、真实性与计算效率,实验结果验证了 ARAPVS 在实

时同步精度与边缘节点成本控制方面的有效性。

局限性与未来工作:ARAPVS 当前以“单边缘节点承接单个同步任务”为主要匹配模式,限制了同步任务在多边缘节点间的并行处理能力,导致资源利用效率存在提升空间。此外,虽然目前控制面与数据面分离设计有效规避了同步数据的瓶颈,但在超大规模异构场景下,CSC 的信令处理压力仍然有待进一步通过分布式协议优化。未来将探索同步任务的并行分解机制,支持任务在多个边缘节点间拆分执行,进一步提升系统的动态适应性与资源利用率。

参 考 文 献

- [1] Zhou Z, Jia Z, Liao H, et al. Secure and latency-aware digital twin assisted resource scheduling for 5G edge computing-enabled distribution grids. *IEEE Transactions on Industrial Informatics*, 2022,18(7):4933-4943
- [2] Xu M, Niyato D, Zhang H, et al. EPViSA: Efficient auction design for real-time physical-virtual synchronization in the human-centric metaverse. *IEEE Journal on Selected Areas in Communications*, 2024,42(3):694-709
- [3] Li B, Xie W, Ye Y, et al. FlexEdge: digital twin-enabled task offloading for UAV-aided vehicular edge computing. *IEEE Transactions on Vehicular Technology*, 2023,72(8):11086-11091
- [4] Nandakumar K. Capride learning: Confidential and private decentralized learning based on encryption-friendly distillation loss//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada, 2023: 8084-8092
- [5] Qian Y, Ma L. Parameter-efficient federated learning for edge computing with end devices resource limitation//*Proceedings of the 4th International Conference on Industrial Artificial Intelligence*. Shenyang, China, 2022:1-5
- [6] Wuerkaixi A, Cui S, Zhang J, et al. Accurate forgetting for heterogeneous federated continual learning. *arXiv preprint arXiv:2502.14205*, 2025
- [7] Qi D, Zhao H, Li S. Better generative replay for continual federated learning. *arXiv preprint arXiv:2302.13001*, 2023
- [8] Shenaj D, Toldo M, Rigon A, et al. Asynchronous federated continual learning//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada, 2023:5055-5063
- [9] Xu Y, Wang J, Ma L, et al. Two-stage learning brain storm optimizer//*Proceedings of the International Conference on Intelligent Computing*. Bari, Italy, 2020:28-40
- [10] Ma L, Wang X, Wang X, et al. TCDA: truthful combinatorial double auctions for mobile edge computing in industrial Internet of Things. *IEEE Transactions on Mobile Computing*, 2022,21(11):4125-4138

- [11] Zhou Y, Kang H D, Zhang T, et al. Multiple residual quantization of pruning//Proceedings of the International Conference on Data Mining and Big Data. Beijing, China, 2022:209-219
- [12] Qiu W, Chen Y, Huang C, et al. FlexEdge: digital twin-enabled task offloading for UAV-aided vehicular edge computing. *IEEE Transactions on Vehicular Technology*, 2023, 72 (8):11086-11091
- [13] Ma L B, Chang F R, Zhang H X, et al. Large-scale global coevolutionary optimization algorithm based on formal concept analysis. *Chinese Journal of Computers*, 2021, 44 (7): 1310-1325(in Chinese)
(马连博, 常凤荣, 张恒熙等. 基于形式概念分析的大规模全局协同进化优化算法. *计算机学报*, 2021, 44 (7):1310-1325)
- [14] Kiani A, Ansari N. Toward hierarchical mobile edge computing: An auction-based profit maximization approach. *IEEE Internet of Things Journal*, 2017, 4 (6):2082-2091
- [15] Hu R, Gong Y. Trading data for learning: Incentive mechanism for on-device federated learning//Proceedings of the IEEE Global Communications Conference (GLOBECOM). Taipei, China, 2020:1-6
- [16] Daniel C, Gregory M, Swann P, et al. Random graph generation for scheduling simulations//Proceedings of the 3rd International ICST Conference on Simulation Tools and Techniques. Torremolinos, Spain, 2010:1-10
- [17] Liu Y, Chang S, Liu Y, et al. FairFed: Improving fairness and efficiency of contribution evaluation in federated learning via cooperative Shapley value//Proceedings of the IEEE INFOCOM 2024-IEEE Conference on Computer Communications. Vancouver, Canada, 2024:621-630
- [18] Tian C, Zheng M, Lin C W, et al. Heterogeneous window transformer for image denoising. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2024, 54 (9): 5601-5612
- [19] Kapoor A, Kumar D. Federated learning for urban sensing systems: A comprehensive survey on attacks, defences, incentive mechanisms, and applications. *IEEE Communications Surveys & Tutorials*, 2024, 26 (3):1820-1845
- [20] Li N, He M R, Ma L B. Research status and progress of evolutionary deep learning. *Information and Control*, 2024, 53 (2):129-153 (in Chinese)
(李楠, 贺美蕊, 马连博. 进化深度学习的研究现状与进展. *信息与控制*, 2024, 53 (2):129-153)
- [21] Sim R H L, Zhang Y, Chan M C, et al. Collaborative machine learning with incentive-aware model rewards//Proceedings of the 37th International Conference on Machine Learning. Vienna, Austria, 2020: 8927-8936
- [22] Hu S, Li G. Dynamic request scheduling optimization in mobile edge computing for IoT applications. *IEEE Internet of Things Journal*, 2020, 7 (2):1426-1437
- [23] Kang J, Xiong Z, Niyato D, et al. Incentive mechanism for reliable federated learning: A joint optimization approach to combining reputation and contract theory. *IEEE Internet of Things Journal*, 2019, 6 (6):10700-10714
- [24] Jiao Y, Wang P, Niyato D, et al. Auction mechanisms in cloud/fog computing resource allocation for public blockchain networks. *IEEE Transactions on Parallel and Distributed Systems*, 2019, 30 (9):1975-1989
- [25] Nguyen D C, Ding M, Pathirana P N, et al. Cooperative task offloading and block mining in blockchain-based edge computing with multi-agent deep reinforcement learning. *IEEE Transactions on Mobile Computing*, 2021, 22 (4):2021-2037
- [26] Sarikaya Y, Ercetin O. Motivating workers in federated learning: A stackelberg game perspective. *IEEE Networking Letters*, 2019, 2 (1):23-27
- [27] Zhou H, Wu T, Chen X, et al. Reverse auction-based computation offloading and resource allocation in mobile cloud-edge computing. *IEEE Transactions on Mobile Computing*, 2023, 22 (10):6144-6159
- [28] Lu R, Zhang W, Wang Y, et al. Auction-based cluster federated learning in mobile edge computing systems. *IEEE Transactions on Parallel and Distributed Systems*, 2023, 34 (4):1145-1158
- [29] Liu J, Guo S, Liu K, et al. Resource provision and allocation based on microeconomic theory in mobile edge computing. *IEEE Transactions on Services Computing*, 2022, 15 (3): 1512-1525
- [30] Zhan Y, Li P, Qu Z, et al. A learning-based incentive mechanism for federated learning. *IEEE Internet of Things Journal*, 2020, 7 (7):6360-6368
- [31] Chen S, Liu X, Zhang Z. Timeliness-prioritized reverse auction mechanism for one-way sensing tasks: Maximizing requester utility via submodular optimization. *IEEE Internet of Things Journal*, 2023, 11 (8):15678-15690
- [32] Gao Y, Li L, Wang H. Reverse auction model for vehicle perception with uncertainty: Optimizing winner selection via data quality assessment. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25 (3):2245-2256



CUI Ru-Yun, M. S. candidate. Her main research interests include digital twins and edge computing.

ZHOU Yue-E, Ph. D. candidate. Her main research interests include edge computing and model compression.

MA Lian-Bo, Ph. D. , professor, Ph. D. supervisor. His research interests include computational

intelligence, edge computing and federated learning.

HUANG Min, Ph. D. , professor, Ph. D. supervisor. Her research interests include industrial internet, supply chain and intelligent optimization.

WANG Xing-Wei, Ph. D. , professor, Ph. D. supervisor. His research interests include computer networks, cloud computing and artificial intelligence.

Background

Real-time physical-virtual synchronization is a critical enabler for edge digital twin networks (DTEN), facilitating efficient collaboration between physical devices and virtual replicas. This task involves inherently coupled decisions: synchronization pair matching, resource allocation, and task offloading. These must simultaneously account for heterogeneous resource capacities and stringent local constraints, making the optimization problem computationally intractable in large-scale deployments.

However, existing studies often treat DT as an auxiliary tool, failing to establish a deep connection between synchronization quality and resource management. They lack systematic solutions for tightly coupled joint optimization and fail to balance synchronization timeliness (i. e. , information freshness) with resource consumption. To bridge this gap, this paper proposes ARAPVS, a centralized reverse auction-based mechanism. Unlike traditional cost-minimization approaches, ARAPVS aims to maximize system social welfare by introducing a digital twin state staleness model to quantify synchronization quality. It employs the Kuhn-Munkres (KM) algorithm with an opportunity cost strategy to solve the minimum weight perfect matching problem and integrates the Vickrey-Clarke-Groves (VCG) pricing rule to ensure individual rationality and incentive compatibility.

To address these gaps, this paper proposes ARAPVS, a

reverse auction-based joint decision-making mechanism for physical-virtual synchronization resource allocation. ARAPVS adopts a centralized scheduling framework led by the Cloud Service Center (CSC), integrates the Vickrey-Clarke-Groves (VCG) payment rule to ensure truthfulness and individual rationality, and uses the Kuhn-Munkres (KM) algorithm to achieve minimum weight perfect matching between synchronization tasks and edge resource bundles. The mechanism effectively minimizes the total cost of edge nodes while satisfying latency and communication constraints, achieving stable and real-time physical-virtual synchronization.

This work was supported by the National Natural Science Foundation of China (No. 62472079), which focuses on cloud supervision and governance in in ter-cloud computing, promoting its deep application. Our research team has made remarkable achievements in edge computing, federated learning, and resource scheduling, publishing numerous papers in top-tier international journals such as IEEE TON, IEEE TMC, and IEEE TSC, with several selected as ESI Highly Cited Papers. This paper contributes to the key technical breakthrough of real-time physical-virtual synchronization in DTEN, providing an efficient resource allocation and incentive solution that advances the practical application of the supported national projects.