

DOI: 10.13382/j.jemi.B2508401

面向 TSN-5G 异构网络的端到端传输调度方法研究^{*}

李翠翠^{1,2,3} 金 曦⁴ 夏长清^{2,3} 段 勇¹ 许 驰^{2,3} 孙乙铭^{2,3}

(1. 沈阳工业大学信息科学与工程学院 沈阳 110870; 2. 机器人国家重点实验室 沈阳 110016;

3. 中国科学院沈阳自动化研究所 沈阳 110016; 4. 东北大学 沈阳 110169)

摘 要:随着全球数字化转型的深入发展,工业物联网对网络通信的传输时延、可靠性、广覆盖方面提出了严苛的要求。而时间敏感网络(TSN)以其确定性的低时延传输特性,与5G的广覆盖优势形成互补,二者深度融合构建的TSN-5G异构网络成为满足工业物联网实时通信需求的前沿方案。但目前缺少对该方案的传输资源细粒度使用的优化方法,导致有限资源没有得到充分利用,进而影响端到端传输的成功率。为此,在TSN与5G融合的工业网络架构的基础上,设计了一种基于双Q学习的鲸鱼优化方法,该方法通过双深度Q网络(DDQN)动态优化鲸鱼优化方法的“搜索”或者“包围”的执行动作选择,可以加快方法的寻优过程,且能够有效避免鲸鱼优化方法陷入局部最优。在性能对比方面,该方法也展现出显著优势,与传统的鲸鱼优化方法和遗传方法相比,其调度成功率的提升范围在6.1%~74%。因此,通过DDQN与鲸鱼优化方法的结合可以很好的解决TSN-5G网络的细粒度资源分配难题。

关键词:TSN-5G异构网络;双Q学习;鲸鱼优化方法;调度成功率

中图分类号:TN915 **文献标识码:**A **国家标准学科分类代码:**520.10

Research on end-to-end transmission scheduling method for TSN-5G heterogeneous networks

Li Cuicui^{1,2,3} Jin Xi⁴ Xia Changqing^{2,3} Duan Yong¹ Xu Chi^{2,3} Sun Yiming^{2,3}

(1. School of Information Science and Engineering, Shenyang University of Technology, Shenyang 110870, China; 2. State Key Laboratory of Robotics, Shenyang 110016, China; 3. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China; 4. Northeastern University, Shenyang 110169, China)

Abstract: With the in-depth development of global digital transformation, industrial IoT has put stringent requirements on the transmission delay, reliability, and wide coverage of network communication. TSN, with its deterministic low-delay transmission characteristics, complements the wide coverage advantage of 5G. The TSN-5G heterogeneous network, formed by the deep integration of the two, has become a cutting-edge solution to meet the real-time communication needs of industrial IoT. However, currently there is a lack of optimization methods for fine-grained use of transmission resources in this solution, resulting in the underutilization of limited resources, which in turn affects the success rate of end-to-end transmission. Therefore, based on the TSN and 5G fusion industrial network architecture, this paper designs a whale optimization algorithm based on dual Q-learning. The algorithm uses DDQN to dynamically optimize the execution action selection of “search” or “encirclement” in the whale optimization algorithm, which can accelerate the optimization process and effectively avoid the whale optimization algorithm falling into local optimum. In terms of performance comparison, the algorithm also shows significant advantages. Compared with the traditional whale optimization algorithm and genetic algorithm, The improvement of scheduling success rate ranges from 6.1% to 74%. Thus, the combination of DDQN and whale optimization algorithm can effectively solve the fine-grained resource allocation problem in TSN-5G networks.

Keywords: TSN-5G heterogeneous network; double Q-learning; whale optimization algorithm; scheduling success rate

收稿日期:2025-05-22 Received Date: 2025-05-22

^{*} 基金项目:国家自然科学基金(62133014,62303449)、中国高校产学研创新基金(2025ZX012)、辽宁省科学技术计划重点研发项目(2024JH2/102400070)、中国科学院沈阳自动化研究所基础研究计划(2023JC1K09)项目资助

0 引言

在工业 4.0 浪潮的推动下,工业物联网(industrial internet of things, IIoT)正迅速崛起,已成为学术界与工业界竞相研究和应用的热点领域^[1]。随着 IIoT 和工业 4.0 的快速发展,大量工业仪表和工业设备通过有线和无线网络接入工业系统,电子测量、工业自动化、工业机器人等领域对数据传输的实时性和可靠性提出了更高的要求^[2]。然而,传统以太网采用的“尽力而为”(best effort, BE)传输机制难以满足工业自动化等场景对实时性的严格要求。为此,IEEE 802.1 任务组制定了时间敏感网络(time-sensitive networking, TSN)^[3]技术标准,它基于以太网提供确定性、实时性和可靠性传输^[4-5],并通过引入时间敏感整形器(time-aware shaper, TAS)、循环排队和转发(cyclic queuing and forwarding, CQF)^[6]等机制,显著提升了网络的确定性传输能力。在网络运行过程中,TSN 通过 IEEE 802.1AS 协议实现全网设备的高精度时钟同步。随后,集中式网络配置(centralized network configuration, CNC)^[7]依据预定义的调度策略传输数据流。与此同时,5G 网络中的超可靠低延迟通信(ultra-reliable low-latency communications, URLLC)技术通过极高的可靠性以及低至毫秒级的延迟保障,为工业自动化^[8]提供了无线解决方案,并且支持 5G 和 TSN 的集成^[9]。这种集成显著提升了工业网络的灵活性和可扩展性,并将确定性网络的覆盖范围从有线域扩展至无线域^[10],为工业互联网的发展开辟了新的可能性。Ginthor 等^[11]在 TAS 机制的基础上,提出了一种基于窗口的资源分配方法,该方法考虑了大尺度衰落对无线 TSN 调度的影响,通过优化调度策略提高了 TSN-5G 网络的可扩展性。Liu 等^[12]提出一种综合考虑 TSN 和 5G 网络资源的联合资源分配方法,该方法通过智能选择 5G 中的配置授权来影响 TSN 网络中流量的注入时间,从而缓解队列溢出问题。Yang 等^[13]在 5G-TSN 融合网络中提出了两步法来解决资源分配问题,并根据 TSN 和流的特点分别制定了优先级度量,用以实现低时延通信。Wang 等^[14]通过融合方法调度 TSN 的注入时隙并假设 5G 网桥上的传输时延为常量,从而解决 TSN 流量调度问题。

上述方法通过优化调度策略提升了网络性能和效率,但并未考虑 5G 时频资源的细粒度使用,导致传输可靠性降低,限制了与 TSN 协同优化的效果。而且,目前关于 TSN-5G 混合网络的研究多聚焦于架构设计与性能评估^[15-16],但对于保障网络中时间敏感型应用的确定性低延迟传输至关重要的端到端流量调度问题,尚未得到充分解决。现有的精确方法,例如基于数学规划的方法,虽能解决小规模调度问题,却因计算复杂度高而难以应

用于大规模场景。因此已有学者采用启发式方法解决大规模的调度问题,常用的启发式方法包括粒子群优化方法^[17]、蚁群优化方法^[18]、蛭螂优化方法^[19]、遗传方法(genetic algorithm, GA)^[20]、鲸鱼优化方法(whale optimization algorithm, WOA)^[21]等。但启发式方法虽适用于大规模问题,却常陷入局部最优。此外,针对 TSN-5G 异构网络的资源分配问题,已有研究涉及接入选择^[22-23]、可见光通信上行链路^[24]、网络数字孪生^[25]等方面,为本文提供了有益参考。为解决该问题,本文提出了一种结合强化学习与鲸鱼优化方法两者优势的新方法,在解决 TSN-5G 网络大规模端到端流量细粒度调度问题的同时,突破问题的局部最优限制,寻找全局最优解。

在 TSN 和 5G 的异构网络环境中,本文不仅考虑了 TSN 的注入时隙,还进一步细化了 5G 的时间和频率因素,从而能够更细粒度地优化调度策略。基于 TSN-5G 网络架构,本文深入研究了大规模流量调度问题。提出了一种基于双 Q 学习的鲸鱼优化方法(double Q-learning base whale optimization algorithm, DQWOA),该方法通过 WOA 进行解搜索,并引入双 Q 学习机制辅助 WOA 调整动作,有效避免陷入局部最优,显著提升了搜索效率。与其他方法相比,本文提出的 DQWOA 方法在调度成功率上显著提升,验证了其在解决 TSN-5G 网络中确定性低延迟传输问题的有效性。

1 系统模型

1.1 TSN-5G 网络架构

TSN-5G 网络架构如图 1 所示,由 5G 系统和 TSN 系统组成。5G 系统作为流量转发桥梁,通过设备侧和网络侧 TSN 转换器实现与 TSN 之间的互联互通^[26]。

网络采用完全集中的管理架构,集中式用户配置(centralized user configuration, CUC))负责接收终端设备的通信请求并将其转发至 CNC。CNC 依据从 CUC 获取的网络拓扑和流量数据执行调度算法。为各流分配资源并相应更新网络配置,随后经 CUC 将调度结果下发至各终端设备。

1.2 TSN-5G 网络中的流量调度

本文 TSN-5G 网络由如下关键组件构成:一组工业物联网终端系统 $M = \{M_1, M_2, \dots\}$ 、一组 TSN 网桥 $N = \{N_1, N_2, \dots\}$ 和 5G 系统的逻辑桥 N_{5G} 。此外, Q_{TSN} 用于表示 TSN 网桥的队列容量,用于支撑不同流量负载下的网络性能。在 TSN-5G 的异构网络中,每个时间触发(time-triggered, TT)流被定义为:

$$f_i = \{start_i, end_i, path_i, period_i, etc_i, size_i, slot_i, time_i, frequency_i\} \quad (1)$$




图1 TSN-5G 网络架构

Fig. 1 Architecture diagram of TSN-5G network

在信息交互的网络中,数据的传输从一个源节点出发,最终到达一个目的节点,其中 $start_i$ 和 end_i 分别表示源节点和目的地节点。从源节点 $start_i$ 向节点 end_i 发送数据的路径,记作 $path_i$, 路径是一个有序的节点序列。例如,对于一个 TT 流的路径,可以将其表示为:

$$path_i = \{M_1, N_1, N_2, N_{5G}, M_4\} \quad (2)$$

另外,TT 流的传输具有严格的周期性,用 $period_i$ 表示 TT 流的周期,即数据包按照固定的时间间隔发送。同时,TT 流还对端到端延迟有严格要求, ete_i 表示所需的端到端延迟,即数据从源节点发出到到达目的节点的最大允许时间。 $size_i$ 表示流 f_i 的大小, $slot_i$ 表示流 f_i 在 TSN 的注入时隙, $time_i$ 和 $frequency_i$ 表示流 f_i 在 5G 上所需的时频资源。本文采用 CQF 的传输机制, CQF 是一种基于时隙的流量调度机制,为 TSN 中的周期性流量提供确定性的延迟保证。 CQF 通过将时间划分为一系列等长的时隙,并在每个时隙中处理特定的数据传输任务,从而实现流量的精确调度。传输规则如图 2 所示,数据传输过程是由源节点 M_1 按照预定的周期发送数据包,数据包首先到达 TSN 网桥节点 N_1 , 并将数据包放入循环队列中,等待下一个可用的时隙 $slot_i$, 并检查循环队列中的数据包,确保数据包的大小不超过当前时隙下 N_1 节点剩余的队列容量,并将准备好的数据包转发到下一个 TSN 网桥节点 N_2 , 每次发送到下一个节点时,时隙 $slot_i$ 就增加 1, 表示数据包在下一个时隙被发送到了下一个节点。 N_2 节点重复 N_1 节点的过程,直到数据包到达 5G 系统逻辑桥 N_{5G} 。当数据包到达 N_{5G} 节点时,根据调度方案为数据包分配 5G 网络的时频资源,此时时隙为 $slot_i + 3$, 数据包所占用的时频资源的起始坐标是 $(time_i, frequency_i)$, 时频资源的范围分别是 T 和 F 。最后数据包在时隙 $slot_i + 4$ 到达目的节点 M_2 。

在通信系统中,不同的 TT 流各自拥有独特的传输周期。为了确保所有 TT 流能够完整且有序地进行传输,必须找到一个共同的周期,使得所有 TT 流的传输都能够精准地协调一致。这个共同的周期,即所有 TT 流周期的最




图2 传输规则

Fig. 2 Transmission rules

小公倍数,被定义为“超周期”。其计算方式如下:

$$HP = lcm\{period_1, period_2, \dots, period_n\} \quad (3)$$

1.3 TSN-5G 网络中的流量调度

CNC 上的流量调度方法,为每个 TT 流分配合适的 TSN 注入时隙、5G 时频资源,从而最大化成功调度的流数量。这一优化问题可以表示为:

$$\max \sum_{i=1}^n P_{succ}(f_i) \quad (4)$$

其中, $P_{succ}(f_i) = 1$ 表示流 f_i 被调度成功,反之 $P_{succ}(f_i) = 0$ 表示流 f_i 被调度失败。为了确保异构网络中通信的确定性与可靠性,定义了以下关键约束条件。

1) 注入时隙约束

为了确保网络通信的确定性和可靠性,在下一个超周期开始之前,当前超周期中的所有帧必须被其目的节点成功接收;否则,网络将无法保证帧的确定性传输。因此,每个流的最后一个帧必须在超周期结束前准确到达其目的节点。 $slot_i$ 是流 f_i 的注入时隙,则注入时隙需满足的约束可以表示为:

$$0 \leq slot_i + \left(\frac{HP}{period_i} - 1\right) \times period_i + ete_i < HP \quad (5)$$

2) 时频范围约束

每个流 f_i 的时间维度和频率维度需满足如下约束条件。

(1) 时间维度约束:

$$0 \leq time_i < T \quad (6)$$

(2) 频率维度约束:

$$0 \leq \text{frequency}_i < F \quad (7)$$

式中: F 表示 5G 的频率范围; T 表示一个 TSN 时隙中包含的 5G 时隙数量。每个流的时频资源必须在该范围内,则可以确保每个 TT 流的时频资源被合理分配。

3) 时频面积约束

流的时频资源是一个二维矩阵。在调度过程中,必须确保任意两个流 f_i 和 f_j 所占用的时频资源不能重叠。公式表示如下:

$$S_i \cap S_j = \emptyset \quad (8)$$

式中: S_i 是流 f_i 在时隙 $slot_i$ 下所占用的时频资源,可以表示为 time_i 乘 frequency_i 的面积放置在 5G 中的占用位置,包括位置信息 ($slot_i + p_i - 1, x_i, y_i$) 和长宽信息 ($\text{time}_i, \text{frequency}_i$),其中 p_i 表示 5G 在 f_i 的第 p_i 跳。

2 方法设计

提出了一种基于双 Q 学习的鲸鱼优化方法,用于解决 TSN-5G 网络中的大规模流量调度问题。该方法结合了强化学习中的双 Q 学习机制与鲸鱼优化方法的核心优势,一方面通过引入双 Q 学习来减少过高估计的问题,从而提升决策的准确性和稳定性;另一方面,借助 WOA 方法模拟座头鲸捕食行为的特性,DQWOA 能够有效增强种群多样性,加速全局搜索能力,并提高方法的收敛速度。

2.1 适应值函数方法

本文的目标是最大化成功调度流的数量,因此,适应值函数可以表示为:

$$g(x) = \frac{P_{succ}}{P_{total}} \quad (9)$$

式中: P_{succ} 是成功调度的 TT 流的数量; P_{total} 是所有 TT 流的数量。适应值函数 $g(x)$ 可以根据方法 1 来计算。方法输入是流的集合 K ,包括调度流 f_i 、时隙 $slot_i$ 、流的时频的二维矩阵 S_i ,以及链路 L 在时隙 t 时的队列容量 Q_i^L ,输出是 TT 流的调度成功率 $g(x)$ 。

2.2 基于双 Q 学习的鲸鱼优化方法

DQWOA 巧妙地融合了深度强化学习中的双 Q 网络机制,通过动态调整搜索策略,显著提升了方法在复杂网络环境中的适应性,从而更好地应对 TSN-5G 网络中资源分配的复杂性。

1) 面向传输调度的 WOA

首先初始化种群,在搜索空间中随机产生 N 只鲸鱼个体组成初始种群,每只鲸鱼代表一个 TT 流集合的调度方案,包括每个 TT 流的注入时隙以及对应的时频资源。第 i 只鲸鱼在 d 维空间中的位置可表示为 $X_i = (x_i^1, x_i^2,$

方法 1 适应值函数方法

输入: $K = \{f_i, slot_i, S_i\}$, 队列容量 Q_i^L

输出: 流的调度成功率 $g(x)$

初始化 $Q_{TSN}, P_{failed} = 0$

For 每一个流 $f_i \in F$ 执行:

For 每一个链路 $l \in path_i$ 执行:

If $Q_i^L < size_i$ or $S_i \cap S_j \neq \emptyset (\forall j \in [0, i))$ then

$P_{failed} = P_{failed} + 1$

跳出当前循环

Else

$Q_{slot_i}^L = Q_i^L - size_i$

$slot_i + 1$

End if

End for

End for

返回 $g(x) = (P_{total} - P_{failed}) / P_{total}$

$\dots, x_i^d), i = 1, 2, \dots, N$ 。 d 表示 TT 流调度方案中需要优化的变量维度,由于本文每个流所需要优化的变量包括 TSN 的注入时隙和 5G 的时频资源,因此在整个 TT 流的调度方案中 $d=3$ 乘流的数量。假设当前群体中的最优位置为猎物,群体中其他鲸鱼个体均向最优个体移动,并使用方法 1 计算每个个体的适应值,并记录最优个体及位置。WOA 包括 3 种动作,分别是“包围”、“攻击”和“搜索”。“包围”是模拟鲸鱼围绕当前最优解进行搜索的行为,属于局部搜索,通过逐渐缩小包围圈细化当前最优解附近的解空间;“攻击”是模拟座头鲸的气泡网捕食行为,通过螺旋路径逐渐接近猎物,属于局部搜索,主要用于在当前最优解附近进行更精细的搜索,进一步优化解的质量;“搜索”是随机选择一只鲸鱼个体作为目标,进行全局搜索,这种行为有助于方法跳出局部最优解,探索更广阔的解空间。

为了更好地适应调度问题,本文方法的设计策略是在迭代初期,WOA 将优先执行“搜索”或“包围”动作。其中,“包围”动作主要用于 TSN 注入时隙的调度。 $X_{best}(t)$ 为猎物位置; A 和 C 为系数向量。“包围”动作的公式如下:

$$X(t+1) = X_{best}(t) - A \times D' \quad (10)$$

$$D' = |C \times X_{best}(t) - X(t)| \quad (11)$$

随着迭代的推进,鲸鱼群体的行为策略逐渐发生变化,越来越多的个体开始执行“攻击”动作。此时,“攻击”动作专注于 5G 时频进行调度。其中,参数 b 是用于限制螺旋形状的常数,而 l 是在 $[-1, 1]$ 区间的随机数。“攻击”动作的公式如下:

$$X(t+1) = D' \times e^{bl} \times \cos(2\pi l) + X_{best}(t) \quad (12)$$

$$D' = |X_{best}(t) - X(t)| \quad (13)$$

2) 基于 DDQN 的 WOA

为提升 WOA 性能,将 DDQN 动态优化引入到 WOA

的“搜索”或者“包围”的执行动作选择中。因为 WOA 在执行“搜索”或者“包围”动作的过程中可能会过早收敛到局部最优,尤其是在复杂的优化问题中。而且 WOA 的动作选择通常是基于固定的策略,缺乏根据环境动态调整的能力,为了克服 WOA 的局限性,引入了 DDQN, DDQN 能够感知当前解的状态,通过学习状态-动作价值函数,为 WOA 的每只鲸鱼提供最优的行为选择,从而提高优化效率和效果。

在数学上,本文的问题可以被建模为马尔可夫决策过程,其被表示为 3 元组 $\langle S, A, R \rangle$, 其中 S 是状态集合, A 是动作集合, 并且 R 是即时奖励。在每次迭代中, 智能体接收状态 s , 并基于当前状态 s 和当前策略 $\pi_i(a|s)$ 采取动作 a 。然后, 环境执行动作 a , 并提供即时奖励 r 。本文的状态、动作和奖励设计如下。

(1) 状态空间

WOA 当前解的调度参数作为 DDQN 的输入状态。

$$State = \{ (slot_1, time_1, frequency_1), (slot_2, time_2, frequency_2), \dots \} \quad (14)$$

(2) 动作空间

鲸鱼群的动作选择对于引导搜索过程和提升方法效率至关重要。这些动作决定了鲸鱼的移动方向, 从而影响整个种群的搜索行为。在每次迭代中, 根据当前的搜索状态和环境反馈, 需要动态调整鲸鱼的动作。动作的选择包括“包围”和“搜索”两种策略, 可以表示为:

$$Action = \{ encircle: 0, search: 1 \} \quad (15)$$

若接收到的动作信号是 0, 则鲸鱼执行“包围”动作; 若为 1, 则执行“搜索”动作。其中, “搜索”动作的公式如下:

$$X(t+1) = X(rand) - A \times D \quad (16)$$

$$D = |C \times X(rand) - X| \quad (17)$$

(3) 奖励空间

本文的目标是最大限度地提高 TT 流的调度成功率, 而适应值函数是用于衡量每次迭代后解的质量。因此, 奖励函数与全局最佳适应值相关, 可以通过如下公式计算:

$$r_t = \frac{|g_{best}(t) - g_{best}(t+1)|}{|g_{best}(t)|} \quad (18)$$

式中: $g_{best}(t)$ 是第 t 次迭代中的全局最佳适应值, 而 $g_{best}(t+1)$ 是第 $t+1$ 迭代中的全局最佳适应值。由于 Q 学习通常使用一个 Q 网络来选择动作和计算目标 Q 值, 这可能导致 Q 值的过估计。为了避免这种高估, 本文采用了双 Q 学习方法来动态调整动作的选择。双 Q 学习方法使用两个 Q 表, 即 Q_{eval} 和 Q_{target} , 以近似最大预期动作值。其中一个 Q 表用另一个 Q 表的值更新下一个状态。两个 Q 表的更新方式可以表示为:

$$Q_{eval}(s, a) = Q_{eval}(s, a) + \alpha [r + \gamma Q_{target}(s', \argmax_a Q_{eval}(s', a)) - Q_{eval}(s, a)] \quad (19)$$

$$Q_{target}(s, a) = Q_{target}(s, a) + \alpha [r + \gamma Q_{eval}(s', \argmax_a Q_{target}(s', a)) - Q_{target}(s, a)] \quad (20)$$

式中: $Q_{eval}(s, a)$ 是在当前状态 s 下采取动作 a 的 Q 值; r 是状态 s 下采取动作 a 后获得的即时奖励; $\alpha \in [0, 1]$ 是学习率; $\gamma \in [0, 1]$ 是折扣率。对于每个时间步, 首先利用评估网络 Q_{eval} 来选择下一个状态 s' 下的最优动作 a' , 通过计算 $\argmax_a Q_{eval}(s', a)$ 实现; 接着使用目标网络 Q_{target} 来估计这个最优动作 a' 在下一个状态 s' 下的 Q 值。这种更新机制确保了评估网络和目标网络交替使用, 从而有效避免了 Q 值的过估计问题。

在本文中, 双 Q 学习方法在训练阶段采用了 ε - 贪婪策略来平衡探索与利用。随着学习的不断深入, ε 值会通过 ε - 衰减策略逐渐降低, 这意味着智能体将越来越倾向于利用已学到的知识而非探索新的可能性。这种策略安排使得智能体能够在初期广泛地探索环境, 而在后期则更加专注于优化其策略。

在大多数情况下, 智能体会根据评估网络 Q_{eval} 的预测, 选择当前状态下 Q 值最高的动作。这种做法有助于智能体利用已有的信息来做出最优决策, 从而提升学习效率。通过这种方式, 智能体在保持一定探索度的同时, 逐步提升其对环境的利用能力, 以期达到更高效的学习效果。

3) TSN-5G 网络流量调度方法

在 DQWOA 框架中, 首先初始生成所有鲸鱼个体, 种群大小为 N , 鲸鱼个体初始位置 $X(i)$ ($i = 1, 2, \dots, N$), 随后根据方法 1 计算每只个体的适应值, 并更新全局最佳适应值。当未达到最大迭代次数 T_{max} 时, 如果随机函数产生的数小于阈值, 则利用 DDQN 辅助 WOA 选择执行“搜索”或者“包围”动作: 如果动作等于 0, 则利用“包围”公式更新种群位置; 如果动作等于 1, 则利用“搜索”公式更新种群位置。否则利用“攻击”公式更新种群位置, 方法如图 3 所示。最后计算更新后的解决方案的适应值, 如果找到更好的解决方案, 则更新最佳解决方案, 直到迭代完成。其中阈值公式如下:

$$threshold = initial_threshold \times (1 - \frac{T}{T_{max}}) \quad (21)$$

式中: $threshold$ 表示阈值; $initial_threshold$ 表示初始阈值, 初始阈值设置为 0.9; T 表示当前迭代次数; T_{max} 表示最大迭代次数。阈值是一个随着迭代次数的增加线性递减的函数, 以此使其在迭代前期能更大概率的利用 DDQN 帮助选择最优的执行动作, 随着迭代次数的增加, 阈值会慢慢减小, 此时就会更多执行“攻击”动作。

方法 2 的时间复杂度可以估计为:

$$O(T_{max} \times (N \times (3 \times Num_{flows} + 3 \times Num_{flows}) + 3 \times Num_{flows}) + O(n^3)) + O(n^2) \quad (22)$$

式中: $T_{\max}$ 表示方法 2 中最外循环中的迭代次数; N 表示种群中鲸鱼个体的数量; Num_{flows} 表示流的数量。由于搜索的参数有 3 个, 所以每个解的维度是 3 乘流的数量 N_{flows} , $O(n^3)$ 是计算适应值的时间复杂度, $O(n^2)$ 是更新 DDQN 智能体的时间复杂度。因此, 方法 2 的时间复杂度是 $O(n^3)$ 。

方法 2 应用于 TT 流的 DQWOA 方法

输入: $K = \{f_i, slot_i, S_i\}$, 队列容量 Q_i^t

输出: 最佳解决方案及其适应值

参数初始化: 种群大小 N , 鲸鱼个体的初始位置 $X(i) (i = 1, 2, \dots, N)$

根据方法 1 计算每只鲸鱼的适应值

更新全局最优解

While($t < T_{\max}$)

For 种群中的每一只鲸鱼 do:

If 随机数 $<$ 线性递减阈值

获取当前解决方案的状态

使用 DDQN 智能体选择动作

If action == 0 then

使用式 (10) 更新种群位置

Else action == 1 then

使用式 (16) 更新种群位置

Else

使用式 (12) 更新种群位置

End for

计算更新后的解决方案的适应值

如果找到更好的解决方案, 则更新最佳解决方案

使用收集的经验更新 DDQN 智能体

End while




图 3 DQWOA 框架

Fig. 3 DQWOA algorithm framework

3 实验分析

将对 DQWOA 的有效性进行评估, 对比的方法包括 GA、时隙与时频同时调度的鲸鱼优化方法 (simultaneous scheduling whale optimization algorithm, SSWOA) 和时隙与时频分开调度的鲸鱼优化方法 (decoupled scheduling whale optimization algorithm, DSWOA)。其中, SSWOA 方法是指无论 WOA 执行哪个动作, 在调度 TSN 注入时隙的同时也进行 5G 时频的调度; 而 DSWOA 是将 TSN 注入时隙与 5G 的时频分开调度, 在执行“包围”动作时进行

TSN 注入时隙的调度, 在执行“攻击”动作时进行 5G 时频的调度。主要评估的指标包括调度成功率、执行时间和收敛性。

3.1 仿真设置

模拟了 4 种 TSN-5G 工业网络拓扑进行实验, 如表 1 所示。网络拓扑如图 4 所示。实验中随机生成了 TT 流, 其中终端节点 M 的集合对应源节点和目的节点。每个 TT 流的周期从周期集 1 和周期集 2 中随机选择, TT 流的大小在 100~1 000 B 之间随机变化, 每个 TSN 网桥的队列容量均设置为 15 000 bytes, 5G 上的时频设置为 24 (5G) 时隙×288 信道。详细的 TT 流参数设置如表 2 所示。实验对比不同算法的调度成功率、执行时间和收敛性的评估指标, 如表 3 所示, 在调度 1 000 个流时各算法的调度成功率、执行时间及收敛迭代位置均得到明确呈现、可以看出, DQWOA 取得了最高的调度成功率, 显著优于 SSWOA、DSWOA 和 GA 算法。由于双 Q 学习机制在策略评估与更新过程中引入了额外的计算开销, 所以 DQWOA 的执行时间相对较长。在收敛性方面, DQWOA 仅经 40 次迭代即趋于稳定, 收敛速度明显快于 SSWOA、DSWOA 及 GA 算法。

表 1 网络拓扑信息

Table 1 Network topologies information

网络拓扑	TSN 桥	5G 系统桥	发送设备	接收设备
拓扑 1	4	1	2	3
拓扑 2	4	1	4	3
拓扑 3	4	1	8	3
拓扑 4	4	1	16	3




图 4 网络拓扑图

Fig. 4 Network topology diagram

3.2 仿真结果

深入探讨 DQWOA、SSWOA、DSWOA 和 GA 方法的性能表现。对于所有方法, 将最大迭代数设为 30, 种群大小设置为 10。对于 DQWOA, 将学习率 α 设置为 0.001, 折扣因子 γ 设置为 0.95。在所有的鲸鱼优化方法中, 将控制搜索范围的参数 a 设置为 2, 控制螺旋行为的

参数 b 设置为 0.5。遗传方法的交叉率和变异率分别设置为 0.8 和 0.1。

表 2 TT 流的信息及相关网络参数

Table 2 TT traffic information and related network parameters

参数	值
TT 流的源节点	$M = \{M_1, M_2, M_3, \dots\}$
TT 流的目的节点	$M = \{M_1, M_2, M_3, \dots\}$
TT 流的 TSN 网桥	$N = \{N_1, N_2, N_3, \dots\}$
TT 流的大小/bytes	100~1 000
周期集 1	{10,20,40} 个 TSN 时隙
周期集 2	{5,10,20} 个 TSN 时隙
TSN 网桥的队列容量/bytes	15 000
	{1,2,4(5G)时隙}×1 信道
每个流所占用的 5G 时频资源	{1,2(5G)时隙}×2 信道
	1(5G)时隙×4 信道
5G 系统的时频资源	24(5G)时隙×288 信道

表 3 不同算法各性能指标比较

Table 3 Comparison of various performance metrics of different algorithms

算法	调度成功率/%	执行时间/s	收敛迭代位置
DQWOA	60.2	35.0	40
SSWOA	54.0	5.7	80
DSWOA	56.6	5.6	80
GA	28.7	23.0	90

1) 调度成功率分析

在实验中评估了 TSN-5G 网络中 TT 流量调度成功率方面的方法性能。

(1) 调度成功率与流的数量的关系分析

基于网络拓扑 1,测试不同方法在不同数量的流下的调度成功率,如图 5 所示。实验表明,随着 TT 流的数量增加,流的调度成功率呈下降趋势,这是因为网络资源是有限的,虽然调度成功的流的数量有所上升,但成功调度流的数量的增加仍小于增加的流的数量,所以呈现下降趋势。

当不同方法对比时,可以看出 DSWOA 方法的调度成功率高于 SSWOA 方法的调度成功率,这说明将 TSN 注入时隙与 5G 时频分别调度的方法会更加有效。因此将 DSWOA 与双 Q 方法相结合在理论上会进一步优化对 TT 流的调度,从实验结果可以明显看出,DQWOA 方法的调度成功率明显优于其他方法,在调度 2 000 个流时,DQWOA 的调度成功率为 56.25%,相比 SSWOA、DSWOA 和 GA 分别提升了 3.4%、2.3%和 41.6%。

(2) 调度成功率与网络规模的关系分析

实验测试了选自周期集 1 的 1 000 个 TT 流在不同方法不同网络拓扑下的调度成功率,如图 6 所示。可以




图 5 不同方法在不同数量的流时调度成功率的比较

Fig. 5 Comparison of the scheduling success rates for different algorithms with varying numbers of flows

明显看出随着网络规模的扩大所有方法的调度成功率都呈现上升趋势。这是因为网络规模的增加提升了网络资源,因此可以容纳更多的流,从而提升了 TT 流的调度成功率。当不同方法对比时,可以明显看出 DQWOA 的调度成功率始终优于 SSWOA、DSWOA 和 GA 方法。这一结果表明,相较于其他方法 DQWOA 拥有更好的探索能力,并在不同网络规模下具有更强的适应性和资源优化能力。




图 6 不同网络拓扑下调度成功率的比较

Fig. 6 Comparison of the scheduling success ratios in various network topologies

(3) 调度成功率与周期集的关系分析

实验首先对比了在利用 DQWOA 方法进行调度时,不同数量的流在不同周期集下的调度成功率,如图 7 所示。当调度相同数量的流时,在周期集 1 下流的调度成功率始终高于周期集 2 下流的调度成功率,这是因为两个周期集下时隙数量的差异,周期集 1 中包含 40 个 TSN 时隙,而周期集 2 中包含 20 个 TSN 时隙,更多的时隙可以使 TT 流在超周期之内拥有更多的资源,因此其调度成功率偏高。

除此之外,还进一步研究了利用 DQWOA 方法调度




图 7 DQWOA 在不同周期集合下调度成功率的比较
Fig. 7 Comparison of scheduling success rates of DQWOA under different period sets

1 000 个流在不同网络拓扑下的调度成功率,如图 8 所示。尽管在不同的网络拓扑下,周期集 1 下流的调度成功率仍然高于周期集 2 下流的调度成功率,这也表明了周期集的优化可以提升 TT 流的调度性能。




图 8 DQWOA 在不同周期集合及不同网络拓扑下调度成功率的比较
Fig. 8 Comparison of scheduling success rates of DQWOA under different period sets and various network topologies

2) 执行时间分析

实验比较 500 个 TT 流在不同网络拓扑、不同方法、不同周期集下的平均执行时间,如图 9 所示。图 9 中实线表示周期集 1 中不同方法的执行时间,虚线则表示周期集 2 中不同方法的执行时间。其中 DQWOA 是平均到 30 次迭代后的执行时间。可以看出,随着网络规模的增加,所有方法的执行时间都有不同程度的增加。其中 DQWOA 为了获得更好的优化性能,融合了 DDQN 和 DSWOA 方法,所以执行时间较长。

此外,实验结果还显示不同方法在不同周期集下的执行时间表现不一。有些方法在周期集 1 中的执行时间比周期集 2 长,而有些则相反。这种现象的原因可能与周期集的特性有关。在 DQWOA 方法中,周期集 1 比周期集 2 需要更多的执行时间,是因为在调度相同数量的 TT 流时,随着超周期内时隙数量的减少,TT 流的调度变得更加困难。为了获得高质量的解,需要增加解空间的搜索,这自然会导致执行时间的增加。在 GA、SSWOA、




图 9 不同方法在不同周期集及不同网络拓扑下的执行时间的比较
Fig. 9 Comparison of execution time of different algorithms under different period sets and various network topologies

DSWOA 方法中,周期集 1 的执行时间小于周期集 2 是因为随着超周期内时隙的增加,解空间也随之增加,这同样导致执行时间的增加。

3) 方法收敛性对比分析

实验通过展现不同方法的平均适应值来体现方法的收敛性。实验中对比了不同方法迭代 100 次调度 500 个 TT 流的平均适应值,如图 10 所示。DQWOA 方法在 4 种网络拓扑下的收敛速度都快于其他方法,因为其在更少的迭代次数便趋于稳定,体现了其解质量上的优势。因此实验结果表明,DQWOA 在收敛速度和求解质量两个维度均优于 SSWOA、DSWOA 和 GA,体现了方法的鲁棒性。

3.3 实验系统验证

仿真实验虽验证了各算法在理想网络环境下的调度成功率、执行时间及收敛性,但未考虑 5G 实际传输过程中因外界电磁干扰、信道衰落等复杂因素导致的时频资源丢包问题,而该问题直接影响工业物联网数据传输的可靠性,是工程应用中必须解决的关键挑战。为进一步验证算法在真实 5G 传输场景下的性能,基于 5G 开源平台搭建了实际实验系统,开展针对性验证实验,核心目标是通过真实丢包数据评估 DQWOA 及对比算法的抗丢包能力,确保算法的工程实用性。

实验系统硬件配置严格遵循工业级标准与 3GPP 协议规范,其中 5G 基站测采用 USRP B210 软件无线电设备作为射频前端,该设备支持宽频段信号收发与灵活的软件定义配置,通过高速接口连接至主机服务器。主机服务器配置为 AMD Ryzen 7 9700X CPU、64 GB DDR5 内存及 NVIDIA RTX 3090 GPU,确保满足 5G 信号处理、时频资源调度及数据日志存储的高性能需求;基站软件基于 OpenAirInterface 开源框架构建,运行于 Ubuntu 22.04 操作系统,工作频段配置为 n78,符合工业 5G 主流应用




图 10 不同方法在收敛性方面的比较

Fig. 10 Comparison between the different algorithms in terms of the convergence

频段要求。用户终端 Quectel RM520N-CN 工业级 5G 模块,该模块支持 5G NR 独立组网与非独立组网双模工作,具备低功耗、高可靠性特点,可无缝对接工业物联网终端设备与 TSN 转换器,实现 TSN 数据流与 5G 网络的互联互通。

实验过程中,首先在 5G 系统的全部时频资源上持续发送测试数据包,记录每个时频资源点的传输状态,生成 5G 丢包日志文件。日志文件中明确标记了各时频点的丢包情况,若某时频点因外界干扰、信道质量恶化等因素导致测试数据包丢失,则标记为丢包时频点;反之则标记为可靠时频点,为后续算法验证提供真实的丢包场景数据支撑。接着将前文仿真实验中使用的 TT 流参数直接应用于本实验,确保实验条件与仿真场景的一致性,便于对比分析。对于每一个经算法分配时频资源的数据包,查询 5G 丢包日志文件,若算法分配的时频资源点与日志中的丢包时频点重合,则判定该数据包传输丢失。

实验结果如图 11 所示,从实验结果可以看出,所有算法的丢包率均随 TT 流数量的增加呈上升趋势。这是因为随着流数量增多,网络时频资源竞争加剧,各算法分配到可靠时频点的概率降低,更多数据包被分配至日志中的丢包时频点,导致丢包率上升。而 DQWOA 算法的丢包率在所有流数量场景下均显著低于其他对比算法,




图 11 不同方法在真实系统下丢包率的比较

Fig. 11 Comparison of packet loss rates of different algorithms in real systems

这一优势源于 DQWOA 的细粒度资源分配策略与双 Q 学习机制,一方面,算法同时优化 TSN 注入时隙与 5G 时频资源,能够更精准地匹配可靠时频资源;另一方面,双 Q 学习机制有效避免了算法陷入局部最优,提升了对全局可靠时频资源的探索能力,从而减少了数据包与丢包时频点的重合概率。对比 SSWOA 与 DSWOA 可知,

DSWOA 的丢包率低于 SSWOA,进一步验证了 TSN 注入时隙与 5G 时频分开调度策略的合理性,能够更有针对性地优化时频资源分配,降低与丢包时频点的冲突风险。而 GA 算法由于缺乏高效的全局搜索能力,资源分配的随机性较强,导致其丢包率最高。

综上,实验系统验证结果表明,即使在真实 5G 传输存在丢包干扰的场景下,DQWOA 算法依然能够通过优化的资源分配策略降低数据丢包率,展现出优于对比算法的抗干扰能力与传输可靠性,为其在工业物联网实际场景中的应用提供了有力支撑。

4 结 论

本文结合双 Q 学习和鲸鱼优化算来解决 TSN-5G 异构网络中的端到端流量调度问题。基于 TSN 与 5G 融合的工业网络架构,设计了一种基于双 Q 学习的鲸鱼优化方法。该方法通过模拟鲸鱼的捕食行为来搜索调度解,并引入双 Q 学习帮助调整动作,避免陷入局部最优,显著提升了搜索效率。大量的仿真结果表明,DQWOA 在 TT 流的调度成功率上优于其他方法,包括遗传方法、时隙与时频同时调度的鲸鱼优化方法和时隙与时频分开调度的鲸鱼优化方法。实验结果验证了 DQWOA 在解决 TSN-5G 网络中确定性低延迟传输问题的有效性。

参考文献

- [1] WÓJCICKI K, BIEGAŃSKA M, PALIWODA B, et al. Internet of things in industry: Research profiling, application, challenges and opportunities—A review [J]. *Energies*, 2022, 15: 1806.
- [2] YU K, GIDLUND M, ÅKERBERG J, et al. Reliable RSS-based routing protocol for industrial wireless sensor networks [C]. *Conference of the IEEE Industrial Electronics Society*. IEEE, 2012: 3231-3237.
- [3] NASRALLAH A, THYAGATURU A S, ALHARBI Z, et al. Ultra-low latency (ULL) networks: The IEEE TSN and IETF DetNet standards and related 5G ULL research [J]. *IEEE Communications Surveys & Tutorials*, 2018, 21(1): 88-145.
- [4] ZHANG T, DENG Q, GUAN N, et al. Queue assignment for fixed-priority real-time flows in time-sensitive networks: Hardness and algorithm [J]. *Journal of Systems Architecture*, 2021, 116: 102141.
- [5] DAI X, ZHAO S, JIANG Y, et al. Fixed-priority scheduling and controller co-design for time-sensitive networks [C]. *2020 IEEE/ACM International Conference On Computer Aided Design*, 2020.
- [6] WU Y, PAN W, CHEN Z, et al. Optimized mapping and hybrid transmission integrating TAS and CQF in TSN [C]. *2024 8th International Conference on Communication and Information Systems (ICCIS)*, 2024: 82-88.
- [7] ALSENWI M, TRAN N H, BENNIS M, et al. Intelligent resource slicing for eMBB and URLLC coexistence in 5G and beyond: A deep reinforcement learning based approach [J]. *IEEE Transactions on Wireless Communications*, 2021, 20(7): 4585-4600.
- [8] BAIRAGI A K, MUNIR M S, ALSENWI M, et al. Coexistence mechanism between eMBB and uRLLC in 5G wireless networks [J]. *IEEE Transactions on Communications*, 2021, 69(3): 1736-1749.
- [9] LI M, CHEN C, HUA C, et al. A learning-based pre-allocation scheme for low-latency access in industrial wireless networks [J]. *IEEE Transaction on Wireless Communications*, 2019, 19(1): 650-664.
- [10] PRADOS-GARZON J, TALEB T, BAGAA M. LEARNET: Reinforcement learning based flow scheduling for asynchronous deterministic networks [C]. *2020 IEEE International Conference on Communications (ICC)*. Dublin, Ireland: IEEE, 2020: 1-6. ; 1-6.
- [11] GINTHOER D, GUILLAUME R, SCHUENGEL M, SCHOTTEN H D. Robust end-to-end schedules for wireless time-sensitive networks under correlated large-scale fading [C]. *2021 17th IEEE International Conference on Factory Communication Systems (WFCS)*. Linz, Austria: IEEE, 2021: 115-122.
- [12] LIU H, LI M, GU F, et al. End-to-end flow scheduling optimization for industrial 5G and TSN integrated networks [C]. *GLOBECOM 2024-2024 IEEE Global Communications Conference*. 2024: 1797-1802.
- [13] YANG J, YU G. Traffic scheduling for 5G-TSN integrated systems [C]. *2022 International Symposium on Wireless Communication Systems (ISWCS)*. IEEE, 2022: 1-6.
- [14] WANG X, YAO H, MAI T, et al. Reinforcement learning-based particle swarm optimization for end-to-end traffic scheduling in TSN-5G networks [J]. *IEEE/ACM Transactions on Networking*, 2023, 31(6): 3254-3268.
- [15] SEIJO O, ITURBE X, VAL I. Tackling the challenges of the integration of wired and wireless TSN with a technology proof-of-concept [J]. *IEEE Transactions on Industrial Informatics*, 2021, 18(10): 7361-7372.
- [16] LARRAÑAGA A, LUCAS-ESTAN M C, MARTINEZ I, et al. 5G configured grant scheduling for 5G-TSN integration for the support of industry 4.0 [C]. *2023 18th Wireless On-Demand Network Systems and Services Conference (WONS)*. IEEE, 2023: 72-79.

[17] 冯宇君, 王忠庆, 刘藤子, 等. 基于粒子群算法的高铁站台导向标识的研究及优化 [J]. 电子测量技术, 2021, 44(14): 169-172.
FENG Y J, WANG ZH Q, LIU T Z, et al. Research and optimization of high-speed railway station platform guide signs based on particle swarm optimization algorithm [J]. Electronic Measurement Technology, 2021, 44 (14): 169-172.

[18] 王宏健, 鄂鑫, 张凯, 等. 改进蚁群算法解决 UUV 集群任务规划问题 [J]. 仪器仪表学报, 2022, 43(9): 238-254.
WANG H J, E X, ZHANG K, et al. Improved ant colony algorithm for UUV cluster task planning [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 238-254.

[19] 潘志远, 卜凡亮. 基于蜣螂算法优化的 DV-Hop 定位算法 [J]. 电子测量与仪器学报, 2023, 37(7): 33-41.
PAN ZH Y, BU F L. DV-Hop location algorithm optimized by dung beetle algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 33-41.

[20] 汤洪, 徐旺. 基于改进遗传算法的资源优化调度方法 [J]. 现代电子技术, 2024, 47(9): 169-172.
TANG H, XU W. A resource optimization scheduling method based on improved genetic algorithm [J]. Modern Electronic Technology, 2024, 47(9): 169-172.

[21] 李仕华, 吕世宁, 张广辉, 等. 基于 WOA 算法的串级模糊 PID 吊车控制 [J]. 国外电子测量技术, 2023, 42(12): 86-93.
LI SH H, LYU SH N, ZHANG G H, et al. A hierarchical fuzzy PID crane control based on WOA algorithm [J]. Foreign Electronic Measurement Technology, 2023, 42(12): 86-93.

[22] 张慧颖, 梁士达, 李月月, 等. 基于象限分割的迟滞软切换 VLC-WiFi 接入选择算法 [J]. 电子测量技术, 2024, 47(1): 63-70.
ZHANG H Y, LIANG SH D, LI Y Y, et al. Hysteresis soft handover access selection algorithm for VLC-WiFi based on quadrant segmentation [J]. Electronic Measurement Technology, 2024, 47(1): 63-70.

[23] 王诗, 严洁, 蓝浩, 等. 用户决策在异构认知网络接入中的算法研究 [J]. 电子测量与仪器学报, 2024, 38(10): 224-234.
WANG SH, YAN J, LAN H, et al. Algorithm research on user decision in heterogeneous cognitive network access [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 224-234.

[24] 梁静远, 葛亚航, 柯熙政. 可见光通信上行链路研究进展 [J]. 电子测量与仪器学报, 2024, 38(12): 1-11.
LIANG J Y, GE Y H, KE X ZH. Research progress of uplink in visible light communication [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 1-11.

[25] 杨海俊, 汪滢, 常诚, 等. 基于大模型与仪器仿真的网络数字孪生系统构建 [J]. 仪器仪表学报, 2025, 46(10): 52-62.
YANG H J, WANG Y, CHANG CH, et al. Construction of network digital twin system based on large model and instrument simulation [J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 52-62.

[26] ROST P, KOLDING T. Performance of integrated 3GPP 5G and IEEE TSN networks [J]. IEEE Communications Standards Magazine, 2022, 6: 51-56.

作者简介



李翠翠, 现为沈阳工业大学硕士研究生, 同中国科学院沈阳自动化研究所进行联培, 主要研究方向为工业网络、资源配置优化。
E-mail: licuicui@sia.cn

Li Cuicui is now a M. Sc. candidate at Shenyang University of Technology and is jointly trained at the Shenyang Institute of Automation, Chinese Academy of Sciences. Her main research interests include industrial networks and resource allocation optimization.



金曦(通信作者), 2013 年于东北大学获得博士学位, 现为东北大学教授, 主要研究方向为 5G、实时调度、人工智能。
E-mail: jinxi@neu.edu.cn

Jin Xi (Corresponding author) received her Ph. D. degree from Northeastern University in 2013. She is now a professor at Northeastern University. Her main research interests include 5G, real-time scheduling, and artificial intelligence.



夏长清, 2015 年于东北大学获得博士学位, 现为中国科学院沈阳自动化研究所研究员, 主要研究方向智能边缘计算、网络-算力协同调度、AI 智能体。
E-mail: xiachangqing@sia.cn

Xia Changqing received his Ph. D. degree from Northeastern University in 2015. He is now a professor at the Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interests include intelligent edge computing, network-computing synergy scheduling, and AI agents.



段勇, 于 2007 年在东北大学获得博士学位, 现为沈阳工业大学教授, 主要研究方向为机器学习, 计算机视觉等。

E-mail: duanyong0607@sut.edu.cn

Duan Yong received his Ph. D. degree from Northeastern University in 2007. He is now a professor at Shenyang University of Technology. His main research interests include machine learning, computer vision, etc.



许驰, 2017 年于中国科学院大学获得博士学位, 现为中国科学院沈阳自动化研究所研究员, 主要研究方向工业互联网、工业物联网、工业控制系统。

E-mail: xuchi@sia.cn

Xu Chi received his Ph. D. degree from

the University of Chinese Academy of Sciences in 2017. He is now a professor at the Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interests include industrial internet, industrial Internet of Things, and industrial control systems.



孙乙铭, 2021 年于哈尔滨工业大学获得博士学位, 现为中国科学院沈阳自动化研究所副研究员, 主要研究方向网络化控制、数据驱动控制、具身智能。

E-mail: sunyiming@sia.cn

Sun Yiming received his Ph. D. degree from Harbin Institute of Technology in 2021. He is now an associate professor at the Shenyang Institute of Automation, Chinese Academy of Sciences. His main research interests include networked control, data-driven control, and embodied intelligence.