

基于LSTM的5G-TSN时钟同步误差预测

刘青俊¹, 王然¹, 黄震宁², 郝洁¹, 滕艺丹³, 吴强⁴

(1. 南京航空航天大学计算机科学与技术学院, 江苏 南京 211106; 2. 中国移动通信集团有限公司研究院, 北京 100032;
3. 深圳职业技术大学人工智能学院, 广东 深圳 518055; 4. 浙江大学计算机科学与技术学院, 浙江 杭州 310027)

摘要: 5G与时间敏感网络(time-sensitive networking, TSN)融合架构被视为工业4.0的核心使能技术, 5G-TSN端到端确定性传输依赖高精度的时钟同步。然而, 5G与TSN之间存在时钟异构性, 特别是基站与TSN时间转换设备间的时钟频率偏移传递性, 使得系统级同步误差呈现时变非线性特征, 现有研究缺乏有效的同步误差动态监测与预测机制。针对此问题, 建立了5G-TSN时钟同步模型, 并提出基于长短期记忆(long short-term memory, LSTM)的时钟同步误差预测机制。LSTM具备建模长期时序依赖的能力, 在结构上适应时钟误差的累计性与动态变化特征, 能够有效预测趋势并识别潜在的同步异常, 为同步补偿提供前馈调控支撑, 提升同步可靠性。仿真实验结果表明, 在典型工业场景仿真数据集上, 该方法的决定系数 R^2 达0.951, 在均方误差等评价指标上优于反向传播神经网络、递归神经网络、门控循环单元和基于自注意力机制的Transformer模型, 为构建高精度、可调控的亚微秒级5G-TSN融合同步系统提供了理论支撑。

关键词: 5G-TSN; 时钟同步; 时钟同步误差预测; LSTM

中图分类号: TP393

文献标志码: A

DOI:10.11959/j.issn.2096-109x.2026004

5G-TSN clock synchronization error prediction based on long short-term memory

Liu Qingjun¹, Wang Ran¹, Huang Zhenning², Hao Jie¹, Teng Yidan³, Wu Qiang⁴

1. College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China
2. Research Institute of China Mobile Communications Group Co., Ltd., Beijing 100032, China
3. School of Artificial Intelligence, Shenzhen Polytechnic University, Shenzhen 518055, China
4. College of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China

Abstract: The integrated architecture of the fifth-generation mobile communication technology (5G) and time-sensitive networking (TSN) is widely regarded as a core enabling technology for Industry 4.0. End-to-end deterministic transmission in 5G-TSN relies on high-precision clock synchronization. However, due to the clock heterogeneity between 5G and TSN, particularly the transferability of clock frequency offsets between base stations and TSN time conversion devices, system-level synchronization errors exhibit time-varying nonlinear characteristics. Current research lacks effective mechanisms for dynamic monitoring and prediction of synchronization errors. To address this issue, a 5G-TSN clock synchronization model was established, and a clock synchronization error prediction mechanism based on long short-term memory (LSTM) was proposed. LSTM's ability to model long-term temporal

收稿日期: 2025-06-23; 修回日期: 2025-12-11

通信作者: 王然, wangran@nuaa.edu.cn

基金项目: 国家自然科学基金(No.62171218); 江苏省前沿技术研发项目(No.BF2024067)

Foundation Items: The National Natural Science Foundation of China (No.62171218), Frontier Technologies R&D Program of Jiangsu under Grant (No. BF2024067)

dependencies aligns well with the cumulative and dynamic nature of clock errors, enabling it to predict trends and identify potential synchronization anomalies effectively. This provides feed forward control support for synchronization compensation and enhances reliability. Simulation experiment results show that on a typical industrial scene simulation dataset, the determination coefficient R^2 of this method reaches 0.951, and it outperforms backpropagation neural networks, recurrent neural networks, gated recurrent units, and Transformer models based on self-attention mechanisms in terms of evaluation metrics such as mean squared error. This work provides theoretical support for constructing high-precision, adjustable sub-microsecond 5G-TSN integrated synchronization systems.

Keywords: 5G-TSN, clock synchronization, clock synchronization error prediction, LSTM

0 引言

随着工业4.0的提出,信息与数据在工业制造和信息通信技术中的作用日益凸显,推动工业体系向更智能、柔性与高效的方向发展^[1]。网络作为数据传输的主要载体,在工业领域中发挥着至关重要的作用。工业4.0的发展对工业控制领域网络的通用性和扩展性提出了更高的要求。传统的工业控制网络虽在保障高可靠性方面表现出色,但由于其采用“尽力而为”的传输机制,受限于固定的拓扑结构及有限的带宽,难以满足新一代工业场景对确定性通信的严格需求。为应对上述挑战,5G与时间敏感网络(time-sensitive networking, TSN)的深度融合被视为支撑工业4.0发展的关键解决方案之一^[2]。

TSN是一种基于以太网技术演进而来的确定性通信技术,旨在提升传统工业网络在带宽、时延与扩展性方面的性能。自2012年IEEE 802.1工作组正式启动TSN标准化工作以来,TSN凭借低时延、低抖动、低丢包率和高可靠性等优势,逐步成为满足工业领域实时通信需求的重要基础设施,同时保持了与传统以太网的良好兼容性^[3]。与此同时,5G的快速发展为工业控制注入了新动能。得益于大带宽、广覆盖、低时延和高可靠的无线通信能力,5G在支持远程分布式工业场景、提升系统灵活性及降低部署成本方面展现出显著优势^[4]。尤其是在制造业对个性化和定制化需求日益增长的背景下,5G与TSN的融合能够实现端到端的确定性连接,为工业自动化提供关键支撑。5G-TSN在智能制造、智能电网、智能网联汽车等领域均具有广泛的应用前景。例如,在自动化机械制造领域中,机械臂、机床的控制算法可以部署在云端,而执行单元(如传感

器等)部署在车间,通过无线网络实现指令的执行和状态的反馈。5G与TSN的融合不仅为工业现场设备的灵活部署与系统扩展提供了便利,还构建了满足高实时性、高可靠性要求的统一通信基座,为工业自动化的全面互联和智能化升级奠定了坚实基础。然而,自动驾驶、机械臂协同控制等工业场景也对5G-TSN时钟同步的精度提出了更高的要求。

为提升5G与TSN的确定性传输能力,第三代合作伙伴计划(3rd generation partnership project, 3GPP)在5G标准Release16和Release17中引入了对TSN的支持机制^[5]。如图1所示,3GPP将5G系统(5G system, 5GS)视为TSN中的一个桥接节点,并在控制面与用户面分别定义了TSN应用功能(time-sensitive networking application function, TSN-AF)、网络侧TSN转换器(network-side TSN translator, NW-TT)和设备侧TSN转换器(device-side TSN translator, DS-TT)^[6],以实现TSN与5G的互联互通。其中,NW-TT负责5G核心网与TSN的时钟协同,实时监测核心网侧的5G时钟与TSN时钟之间的偏差,利用频率补偿机制调整时钟参数;DS-TT负责UE侧无线时钟与TSN时钟的映射与转换。Release16规定,在垂直工业场景下,5G-TSN时钟同步的绝对精度为 $\pm 1.5 \mu\text{s}$ 。然而,5G与TSN在物理层技术、数据链路层协议及上层控制机制等方面均存在本质差异,二者的异构性使得实现确定性互操作面临诸多挑战,其中核心的问题就是如何实现高精度时钟同步,因为时钟同步是保障确定性传输的基础^[7]。TSN通常采用有线传输方式,信道特性稳定、时延波动小、可控性高。而5G网络则基于无线空口进行传输,受信道时变特性与终端设




图1 5G-TSN架构

备(UE)移动性的影响,时延不确定性显著增加,严重影响同步精度^[8]。在集成架构中,DS-TT与NW-TT须同时支持TSN的高精度同步机制与5G网络的时钟管理机制,但二者分属不同的时钟域,且时钟信息传递方式不一致,从而增加了同步的复杂度。

在同步过程中,5G的无线特性容易引入不可预知的误差,从而导致DS-TT与NW-TT获取的5G主时钟频率发生偏移,进而降低系统整体的同步性能。特别是在自动驾驶车辆协同、智能机械臂协作、远程医疗等工业垂直场景中,用户对时钟同步精度和响应时间的要求极高,时钟偏移或时延均可能严重影响业务的执行。因此,如何在异构时钟域下实现高精度、低抖动的5G-TSN时钟同步机制,已成为当前亟须攻克的关键技术问题。

在3GPP Release16和Release17中,5G-TSN的时钟同步依赖误差补偿方法来实现,即根据报文反馈的时延信息进行时钟补偿。该方法须针对5G空口的时延波动频繁更新补偿系数,动态适应性有待提高。当5G网络内部发生不确定的时钟扰动导致同步偏差时,系统只能在后续的时钟周期被动调整,难以及时响应,易造成时钟同步调控滞后。然而,在5G-TSN时钟同步过程中,误差序列通常表现出明显的周期性趋势,即围绕长期稳定趋势产生规律性的波动与振荡,而非沿单一方向的线性演化。这种特性要求同步误差预测任务不仅能够捕捉局部短时变化,还需建模长期依赖与周期结构。LSTM作为递归神经网络

(RNN)的改进版本,引入了门控机制(包括输入门、遗忘门和输出门)与记忆单元结构,使网络能够自动判断历史信息的保留、更新或遗忘,从而有效维持对长期依赖特征的建模能力。LSTM恰好契合5G-TSN时钟同步误差序列的核心特点,即时间跨度长、周期性强、误差波动非线性复杂。此外,LSTM的状态转移结构天然适合处理时钟误差的积累性与突发性特征,能够动态感知误差趋势的变化过程,并对可能的偏移波动进行平滑建模,提升对同步异常点的识别能力。因此,本文提出一种基于LSTM的5G-TSN时钟同步误差预测机制,旨在同步过程中动态捕捉误差演化趋势,为时钟同步的前馈调控和故障预防提供有效的预测支持。

本文的主要贡献如下。

1) 将5G和TSN作为独立时钟域,充分考虑5G时钟内部DS-TT、NW-TT及UE移动带来的不确定性因素,建立5G-TSN时钟同步信息传递过程的仿真模型,并对其同步行为进行系统建模与模拟分析。

2) 针对5G-TSN时钟同步过程的周期性和误差特性,设计了一种基于LSTM的同步误差预测方法。该方法能够有效捕捉误差序列的时序依赖特征,实现对下一时刻同步误差的精准预测,从而为同步偏差的提前调节与误差抑制提供数据支撑与策略依据。

3) 通过实验对所提模型的预测性能进行了定量评估,结果表明,本文所提的基于LSTM的预测机制在拟合和预测同步误差趋势方面表

现优异，显著优于对比模型。本文模型在均方误差（mean squared error, MSE）及决定系数 R^2 等指标上均取得更好的结果，有效验证了该机制的预测可靠性与实用性，为提升5G-TSN系统整体的时钟同步精度提供了理论与实践支持。

1 研究现状与问题分析

1.1 5G-TSN时钟同步

目前，关于5G-TSN时钟同步的研究已取得较多进展。3GPP在Release16和Release17中规定了5G-TSN的集成架构，并定义了与时钟同步相关的组件功能^[9]。朱瑾瑜等^[10]对TSN与5G融合部署的需求和网络架构进行了深入探讨。Muslim等^[11]基于OMNeT++网络仿真器搭建了5G-TSN时钟同步模型，并分析了5G基站和UE的上下行链路时延对同步精度的影响。李晓辉等^[12]针对下一代基站与用户端之间的无线同步信号检测问题，提出一种可以提高同步信号检测成功率的算法，通过优化无线同步信号的物理检测过程，实现高精度5G-TSN时间同步。Song等^[13]将5GS视为白盒，通过获取每个5G网元的时钟频率偏移并进行累计计算，结合统计得到的时间同步报文在5G系统中的驻留时间，实现了较精确的5G传输时延估计。Chai等^[14]提出一种基于数据报文中转的跨域时间同步方法，利用算法估计时间同步报文在5G系统中的驻留时间，并通过仿真验证了所估计的驻留时间对同步性能的改善效果。Striffler等^[15]重点分析了5G系统内部时钟频率偏移和相位偏移对5G-TSN端到端同步精度的影响。Wei等^[16]基于现场可编程门阵列（FPGA）+ARM软硬件协同设计平台提出一种时钟同步增强方法，通过优化5G-TSN端到端链路时延，从而提高同步精度。朱海龙等^[17]基于OMNeT++网络仿真平台，在IEEE 802.1 AS协议中优化了5G-TSN在5GS中的驻留时延测量机制，从而降低了端到端同步误差。

上述研究大致可以分为3类：第一类基于网络仿真平台对5G-TSN进行建模分析，探讨影响同步精度的关键因素并提出初步的优化机制；第二类聚焦于5G系统内部，通过提升信号检测精

度、优化波束管理方式等提高5G同步的可靠性，进而间接改善端到端的同步性能；第三类围绕NW-TT和DS-TT等5G-TSN关键组件的频率偏差信息，考虑5G系统内部的同步不确定性，定量分析5G-TSN端到端同步的影响因素并提出相应的优化策略。尽管已有研究在同步机制建模、影响因素分析和局部优化等方面取得了一定成果，但目前仍普遍缺乏针对同步误差的预测与监管机制。考虑到5G无线传输本身具有较高的不确定性，这给时钟同步的确定性带来了重大挑战，尤其是在5G与TSN协同运行的异构网络环境中。因此，开展面向5G-TSN的时钟同步误差预测机制研究，具有重要的理论价值和实践意义。

1.2 时间序列预测

本文涉及的5G-TSN时钟同步误差预测问题，本质上属于时间序列预测任务。当前主流的时序预测方法可以划分为3类，即传统统计方法、机器学习方法和深度学习方法。自回归积分移动平均模型和指数平滑法是时态数据预测中常用的传统统计方法，这类方法依赖时间序列的历史数据及平稳性假设，适用于线性、波动较小的数据场景，但在处理高频抖动或长周期非平稳序列时，预测性能较差^[18]。机器学习方法（如支持向量机、K近邻等）能够映射输入数据和输出数据之间的非线性特征，并直接从历史数据中构建特征，而无须关注系统内部机制^[19]。但这类方法对数据间潜在的时序相关性挖掘不足，在建模复杂时序模式时能力有限。深度学习方法通过增加神经元的隐藏层数来增强非线性特征提取能力，反向传播神经网络（back propagation neural network, BPNN）和递归神经网络是其中常见的时序预测模型^[20]。RNN利用其循环结构捕捉时间序列中的上下文关联信息，在短期时序预测任务中表现良好。但在建模长期依赖关系时，RNN易出现梯度爆炸或梯度消失问题，导致其处理长序列数据时预测性能不稳定。为弥补这一缺陷，LSTM被提出。作为RNN的改进版本^[21]，LSTM通过引入门控结构调节信息流的输入与记忆保留机制，并利用记忆单元维持时间依赖性，有效缓解了梯度爆炸或消失问题，提升了模型捕捉长周

期、强波动时序数据的能力。门控循环单元 (gated recurrent unit, GRU) 则是 LSTM 的轻量级变体。此外, 基于自注意力机制的 Transformer 模型^[22]也被应用于复杂时序预测任务, 其引入了位置编码用来解析时序序列中的依赖关系和季节性变化规律。然而, Transformer 模型对训练数据集的规模要求较高, 训练收敛耗时较长, 在小样本数据集上的泛化能力容易受限。

5G-TSN 时钟同步误差具有周期性与波动性特征, LSTM 在建模复杂动态序列方面的独特优势, 使其在该领域具备显著应用潜力。然而, 目前尚缺乏将 LSTM 应用于 5G-TSN 时钟同步误差预测的研究。为此, 本文提出基于 LSTM 的误差预测机制, 以期为实现高精度、高可靠的 5G-TSN 时钟同步提供新的解决思路。

2 5G-TSN 时钟同步模型

5G-TSN 时钟同步模型包含 5G-TSN 时钟同步信息传递模型和 5G-TSN 时钟同步误差模型, 其整体框架如图 2 所示。

在 5G-TSN 融合时钟系统中, 5GS 作为 TSN 的一个桥接节点, 负责转发广义精确时间协议 (generalized precision time protocol, gPTP) 的同

步报文。NW-TT 和 DS-TT 设备均支持 IEEE 802.1AS 协议, 可以对经 5G 网络传输的 gPTP 报文进行时间戳解析和时钟补偿处理, 具体过程如图 2 所示, 其中, T_{si} 为入口时间戳 (timestamp ingress), 当 gPTP 报文进入 5G 系统 (由 NW TT, 网络侧 TSN 转换器) 时, 基于 5G 内部时钟记录的进站时间, 标记报文进入 5G “逻辑网桥” 的时刻; T_{se} 为出口时间戳 (timestamp egress), 当 gPTP 报文离开 5G 系统 (由 DS TT, 设备侧 TSN 转换器) 时, 基于 5G 内部时钟记录的出站时间, 标记报文离开 5G “逻辑网桥” 的时刻。

该融合系统包含两个独立的时钟域, 即 TSN 时钟域和 5G 时钟域。其中, TSN 主时钟 (TSN-Master) 作为全局时间基准源, 其行为建模如式(1)所示。

$$T_{MC}(t) = t \quad (1)$$

其中, t 表示理想状态下的真实时间。在 TSN 时钟域内, TSN 从时钟 (TSN-Slave) 以 TSN-Master 为基准进行同步, TSN-Slave 建模如式(2)所示。

$$T_i(t) = \alpha_i t + \beta_i, i = 0, 1, 2, \dots, N \quad (2)$$

其中, α_i 和 β_i 分别表示 TSN-Slave 的频率偏移和相位偏移。5G 系统内部也存在独立的主时钟源 (定义为 5GS), 该时钟可以通过基站与外部的高




图2 5G-TSN 时钟同步模型

精度时钟源（如北斗卫星授时系统）进行同步。5GS同步TSN-Master的过程如式(3)所示。

$$T_{5G}(t) = \alpha_{5G}t + \beta_{5G} \quad (3)$$

其中， α_{5G} 和 β_{5G} 分别表示5G主时钟的频率偏移和相位偏移。5G系统通过协议数据单元（protocol data unit, PDU）会话转发gPTP时间同步消息，即在5G网络内部不对gPTP报文中的时间戳进行解码与转换，仅需借助5G系统边界的转换设备（NW-TT和DS-TT）记录的时间戳，计算报文出入5G系统的时间差 $T_{sc} - T_{si}$ 。

如图2所示，时钟同步过程始于TSN-Master向NW-TT发送同步报文（Sync报文）和同步跟随报文（Follow_up报文），并分别记录发送时间戳 $T_{MC(t_{11})}$ 和 $T_{MC(t_{12})}$ 。NW-TT接收到报文后分别记录时间戳 $T_{5G(t_{11'})}$ 和 $T_{5G(t_{12'})}$ ，根据式(4)和式(5)可以计算出NW-TT相对于TSN-Master的时钟频率比 r_{5G} 。

$$\begin{cases} T_{5G(t_{11'})} = \alpha_{5G}T_{MC(t_{11})} + \beta_{5G} \\ T_{5G(t_{12'})} = \alpha_{5G}T_{MC(t_{12})} + \beta_{5G} \end{cases} \quad (4)$$

$$r_{5G} = \frac{T_{5G(t_{12'})} - T_{5G(t_{11'})}}{T_{MC(t_{12})} - T_{MC(t_{11})}} \quad (5)$$

随后，NW-TT向TSN-Master发送链路时延请求报文Pdelay_Req，并记录时间戳 $T_{5G(t_{21})}$ ，TSN-Master接收到报文后记录时间戳 $T_{MC(t_{21'})}$ ，并在时间戳 $T_{MC(t_{22})}$ 回复链路时延请求响应报文Pdelay_Resp（此报文携带TSN-Master接收到Pdelay_Req报文的时间），NW-TT记录接收到Pdelay_Resp报文的时间戳 $T_{5G(t_{22'})}$ 。基于上述时间戳，TSN-Master和NW-TT之间的链路时延 d_1 可以通过式(6)和式(7)计算得到。

$$\begin{cases} T_{MC(t_{21'})} = T_{5G(t_{21})} + d_1 \\ T_{MC(t_{22})} = T_{5G(t_{22'})} - d_1 \end{cases} \quad (6)$$

$$d_1 = \frac{1}{r_{5G}} \left((T_{5G(t_{22'})} - T_{5G(t_{21})}) - (T_{MC(t_{22})} - T_{MC(t_{21'})}) \right) \quad (7)$$

同理，在DS-TT和TSN-Slave侧，TSN-Slave与5GS之间的时钟频率比 $\frac{r_{SC}}{r_{5G}}$ 和链路时延 d_2 可以通过式(8)和式(9)计算得到。

$$\frac{r_{SC}}{r_{5G}} = \frac{T_{SC(t_{32'})} - T_{SC(t_{31'})}}{T_{5G(t_{32})} - T_{5G(t_{31})}} \quad (8)$$

$$d_2 = \frac{\frac{r_{5G}}{r_{SC}} \left((T_{SC(t_{42'})} - T_{SC(t_{41'})}) - (T_{5G(t_{42})} - T_{5G(t_{41'})}) \right)}{2} \quad (9)$$

通过上述过程，5GS的NW-TT与DS-TT、TSN-Slave均记录了自身与TSN-Master的相关时钟信息，从而完成一次完整的5G-TSN跨域时钟同步。具体而言，TSN-Master向5GS发送同步报文并记录时间戳 $T_{MC(t_1)}$ ，NW-TT接收该报文后记录时间戳 $T_{5G(t_2)}$ 。随后NW-TT将时间戳 $T_{MC(t_1)}$ 和 $T_{5G(t_2)}$ 、时钟频率比 r_{5G} 、链路时延 d_1 等信息传递至DS-TT。DS-TT接收消息后，向TSN-Slave发送同步报文，并记录发送时间戳 $T_{5G(t_3)}$ 。TSN-Slave接收该报文后，记录时间戳 $T_{SC(t_4)}$ 。基于上述数据，TSN-Slave可以推导自身相对于TSN-Master的时钟频率比和相位偏移，并对本地时钟进行校准。最终，TSN-Master与TSN-Slave完成一次跨5G系统同步，总时延如式(10)所示。

$$\begin{cases} T_{SC(t_4)} - T_{MC(t_1)} = D + d \\ d = d_1 + \frac{d_2}{r_{SC}} \\ D = \frac{T_{5G(t_3)} - T_{5G(t_2)}}{r_{5G}} \end{cases} \quad (10)$$

其中， d 表示TSN主从时钟与5G系统之间的总链路时延， D 表示TSN时钟在5G系统内部驻留的时延。基于这些数据，TSN-Slave与TSN-Master之间的相位偏移 CF_{sync} 可以通过式(11)计算得出。

$$CF_{sync} = T_{SC(t_4)} - r_{SC}(d + D + T_{MC(t_1)}) \quad (11)$$

其中， r_{SC} 表示TSN-Slave相对于TSN-Master的时钟频率。TSN-Slave据此调整本地时钟，实现与TSN主时钟的同步。

然而，上述同步过程基于理想假设，未考虑实际5G-TSN时钟同步场景中存在的多种干扰因素。

首先，上述过程默认5G的主时钟（5GS）与NW-TT、DS-TT是保持同步的，即 $r_{5G} = r_{NW} = r_{DS}$ ，其中 r_{5G} 、 r_{NW} 、 r_{DS} 分别为5G时钟，

NW-TT 的时钟, DS-TT 的时钟分别相当于 TSN 主时钟的时钟频率比。但实际上, 由于 5G 网络基于无线传输, NW-TT 与 DS-TT 在实际部署中常存在频率偏差。 r_{SC} 可以通过式(12)计算得到。

$$r_{SC} = R_{SC-DS} \times r_{DS} \quad (12)$$

其中, R_{SC-DS} 表示 TSN-Slave 与 DS-TT 相较于 TSN-Master 的时钟频率累计比。在理想情况下, r_{NW} 与 r_{5G} 是相等的, 但实际存在偏差, 该偏差 (T_{err1}) 可以通过式(13)量化。

$$T_{err1} = |R_{DS-NW} - 1| \times R_{SC-DS} \times r_{NW} \times (D + d) \quad (13)$$

其中, R_{DS-NW} 表示 NW-TT 和 DS-TT 之间的时钟频率累计比。由式(13)可知 T_{err1} 与 NW-TT 和 TSN-Master 的频率累计比呈线性相关。

其次, 尽管 5G 与 TSN 为独立时钟域, 但在实际部署中, NW-TT 与 DS-TT 需要同时支持并处理 TSN 与 5G 的时钟同步协议, 易产生时钟域耦合效应, 该效应须作为独立误差项 (T_{err2}) 纳入考量。

此外, 5G 网络的同步可靠性低于 TSN, 尤其是在 5G 基站 (gNB) 与 UE 之间的空口传输过程中, 容易引入时延波动和同步误差; 同时, 5G 系统内部还可能存在硬件漂移、调度抖动等不确定性问题。将这部分误差记为 T_{err3} 。

综合上述实际影响因素, TSN-Slave 经 5G 网络传输后与 TSN-Master 的同步误差可以建模为式(14)。

$$CF_{sync} = T_{SC}(t_4) - r_{SC}(d + D + T_{MC}(t_1)) + E_{5G-TSN} \quad (14)$$

其中, E_{5G-TSN} 包含时钟频率偏移误差 T_{err1} 、时钟域耦合效应偏差 T_{err2} 和 5G 系统中的不确定误差 T_{err3} 。后续仿真将基于上述建模逻辑对同步行为进行精确模拟, 以评估实际系统中 5G-TSN 时钟同步精度的动态特性。

3 基于 LSTM 的 5G-TSN 时钟同步误差预测机制

5G-TSN 时钟同步过程遵循 IEEE 802.1AS 协议, 具有明显的周期性特征。同步操作在固定周期内重复执行, 由此产生的同步精度误差也呈现周期性波动特征。在复杂网络环境中, 还可能伴随突发性干扰误差。针对这一特性构建 5G-TSN 时钟同步误差预测机制, 对提升系统整体的时钟

同步精度与可靠性具有重要意义。

LSTM 作为 RNN 的改进模型, 引入了门控机制与记忆单元 (包含输入门、遗忘门和输出门)。该模型能够自适应判断历史信息的保留、更新与丢弃策略, 从而对具有长期依赖特征的时间序列数据具备良好的拟合能力。5G-TSN 时钟同步误差序列具有时间跨度广、周期性强、误差波动高度非线性且复杂的典型特征, 因此 LSTM 与 5G-TSN 时钟同步的误差序列关键特性具有高度适配性。此外, LSTM 具备状态转移结构, 能够有效处理时钟误差的累计性与动态变化特征。

综上所述, 本文提出一种基于 LSTM 的 5G-TSN 时钟同步误差预测机制, 为实现同步误差的高精度预测与动态调控提供可行路径, 进而为 5G-TSN 的高可靠、低时延服务提供关键支撑。

3.1 LSTM 模型的原理

LSTM 模型中, 前向计算、反向传播与参数优化共同构成了模型的训练机制。LSTM 将 RNN 中的神经细胞替换为 LSTM 记忆细胞单元, 这一设计赋予其捕捉长期依赖信息的能力。其前向计算过程可以用式(15)~式(19)描述。

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (15)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (16)$$

$$c_t = f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (17)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o) \quad (18)$$

$$h_t = o_t \tanh(c_t) \quad (19)$$

其中, W 和 b 分别表示对应的权重系数矩阵和偏置项, $\tanh$ 表示激活函数, i_t 为输入门, f_t 为遗忘门, c_t 为记忆细胞门, o_t 为输出门, h_t 为隐藏状态。LSTM 模型的训练采用类似于经典的反向传播算法, 具体流程如下: 首先, 按照上述公式计算各 LSTM 记忆细胞的输出值; 然后, 沿时间与网络层次两个方向反向传播, 计算每个记忆细胞单元的误差项; 接着, 基于所得误差项计算各权重参数的梯度; 最后, 采用梯度优化算法对权重参数进行迭代更新。

3.2 基于 LSTM 的 5G-TSN 时钟同步误差预测框架

如图 3 所示, 本文构建的预测框架主要包括输入层、隐藏层、网络训练、输出层和预测分析




图3 基于LSTM的5G-TSN时钟同步误差预测框架

5个部分。首先，基于前文建立的5G-TSN时钟同步模型，结合IEEE 802.1AS时钟同步协议，定义初始同步误差序列并构建同步仿真数据集 $E = \{\text{error}_1, \text{error}_2, \dots, \text{error}_n\}$ 。其中 error_i 表示第 i 个时刻TSN-Slave相较于TSN-Master的时钟同步误差， n 表示总采样时刻数。

随后，对原始误差进行预处理，包括数据清洗、数据归一化和数据集划分3个环节。将数据集划分为训练集 E_{tr} 和测试集 E_{te} 。采用 z -score 标准化方法对数据进行归一化处理，标准化后的训练集如式(20)所示。

$$E'_{\text{tr}} = \{\text{error}'_1, \text{error}'_2, \dots, \text{error}'_m\} \quad (20)$$

该标准化序列将作为LSTM模型的输入特征，用于预测未来时刻的同步误差。

在网络训练阶段，为适配LSTM隐藏层的时序处理机制，需要设置合理的间隔窗口长度 L 。将输入序列按窗口分割后，得到式(21)和式(22)所示的模型输入，对应的理论输出如式(23)和式(24)所示。

$$X = \{X_1, X_2, \dots, X_L\} \quad (21)$$

$$X_p = \{\text{error}'_p, \text{error}'_{p+1}, \dots, \text{error}'_{m-L+p}\} \quad (22)$$

$$Y = \{Y_1, Y_2, \dots, Y_L\} \quad (23)$$

$$Y_p = \{\text{error}'_{p+1}, \text{error}'_{p+2}, \dots, \text{error}'_{m-L+p}\} \quad (24)$$

之后将输入数据 X 送入隐藏层，该隐藏层由多个按时间顺序连接的同构LSTM细胞组成， X 经隐藏层运算后的输出如式(25)和式(26)所示。

$$P = \{P_1, P_2, \dots, P_L\} \quad (25)$$

$$P_p = \text{LSTM}_{\text{forward}}(X_p, C_{p-1}, H_{p-1}) \quad (26)$$

其中， $\text{LSTM}_{\text{forward}}$ 表示LSTM细胞的前向计算， C_{p-1} 和 H_{p-1} 分别表示前一个LSTM细胞的记忆状态和输出。本文选用均方误差作为损失函数，训练过程的损失函数定义如式(27)所示。

$$\text{loss} = \sum_{i=1}^{L(m-L)} (p_i - y_i)^2 / [L(m-L)] \quad (27)$$

以损失函数最小化为优化目标，设定网络初始化的随机种子 seed 、学习率 η 和训练步数 steps ，并采用Adam优化器迭代更新网络权重，最终获得训练完成的预测模型，记为 LSTM^* 。

模型训练完成后进入预测阶段。预测采用迭代方式进行。首先，将理论输出 Y 的最后一行数据 Y_f 作为起始输入。

$$Y_f = \{\text{error}'_{m-L+1}, \text{error}'_{m-L+2}, \dots, \text{error}'_m\} \quad (28)$$

将 Y_f 输入隐藏层计算得到下一时刻的预测输出 Y_{f+1} ，如式(29)和式(30)所示。

$$P_f = \text{LSTM}^*(Y_f) = \{p_{m-L+2}, p_{m-L+3}, \dots, p_{m+1}\} \quad (29)$$

$$Y_{f+1} = \{\text{error}'_{m-L+2}, \text{error}'_{m-L+3}, \dots, \text{error}'_{m+1}\} \quad (30)$$

随后，将 Y_{f+1} 输入 LSTM^* ，则 $m+2$ 时刻的预测值为 p_{m+2} ，依此类推得到预测序列 P_0 ，如式(31)所示。

$$P_0 = \{p_{m+1}, p_{m+2}, \dots, p_n\} \quad (31)$$

最后，对预测序列 P_0 进行反归一化处理，恢复为实际的误差量级，处理过程如式(32)所示。

$$P_{\text{te}} = \text{de}_{\text{score}}(P_0) = \{p_{m+1}^*, p_{m+2}^*, \dots, p_n^*\} \quad (32)$$

综上所述，将输入数据 X 的每一行依次输入模型，可以得到与训练集 E_{tr} 对应的拟合序列 P_{tr} ，通过计算 P_{tr} 与 E_{tr} 、 E_{te} 与 P_{te} 的偏差，结合平均绝对误差 (mean absolute error, MAE)、均方误差和均方根误差 (root mean squared error, RMSE) 等指标，可以定量评估模型的拟合精度和预测能力，从而验证所提机制的有效性。

4 实验及结果分析

4.1 5G-TSN 时钟同步仿真环境

在典型的工业应用场景（如机械臂远程协作）中，系统对时钟同步精度、网络传输时延及可靠性均提出了极高要求。本文基于 3GPP 规定的时钟同步协议，结合第 3 节提出的 5G-TSN 时钟同步误差预测机制，模拟了机械臂远程协同作业场景，并搭建了仿真实验环境以获取用于模型训练与验证的数据集。仿真运行的硬件平台为 13th Gen Intel Core i5-13400F 处理器与 NVIDIA GeForce RTX 4060 Ti 显卡，软件环境为 Windows 11 操作系统，编程语言主要使用 Python 3.9。

仿真实施流程如下：首先，基于 IEEE 802.1AS 中定义的 TSN 时钟节点，模拟 gPTP 信息的周期性传递行为，并采集 gPTP 时钟信息在 TSN 主从节点和 5G 网络中的时间戳数据。然后，基于时钟补偿机制计算出各节点间的链路时延和时钟频率等关键参数。为验证仿真模型的有效性，将本文构建的仿真模型的测试结果与 3GPP Release 16 和 Release 17 中规定的数值 ($1.5 \mu\text{s}$) 进行对比，结果显示本文所提模型端到端的时延在 $1 \mu\text{s}$ 左右，满足亚微秒级时钟同步需求，证

明所构建的时钟仿真模型适配 5G-TSN 典型工业场景，采集的仿真数据可用于后续误差预测分析。


在 5G 网络中，时钟同步精度受多项参数影响，其中子载波间隔 (subcarrier spacing, SCS) 和子载波配置参数 (Numberology u) 尤为关键。系统所需的时间同步精度与 SCS 正相关，SCS 值越大，对时钟同步的精度要求越高。本文设定 5G 的 SCS 为 15 kHz，对应的时钟同步精度为 $\pm 1.5 \mu\text{s}$ 。gPTP 同步周期设定为 0.125 s，链路时延测量间隔为 1 s，Sync 报文驻留时间为 100 μs ，Pdelay 报文响应时间为 100 μs ，同时限定 TSN-Master 时钟抖动不超过 2 ns，端到端链路传输时延设为 100~900 ns。为更贴近实际的部署环境，仿真中还引入了 5G 网络参数，主要包括：5G 无线传输可靠性设为 99%，以模拟可能的丢包与中断；5G 系统噪声服从高斯分布 $n(t) \sim N(0, \sigma^2)$ ，其中 σ 为噪声方差，可以通过参数调节模拟不同信道条件下的扰动情况， α 设为 0.2A (A 为信号幅度)。5G-TSG 时钟同步仿真参数见表 1。

表 1 5G-TSN 时钟同步仿真参数


网络参数	参数值
SCS	15 kHz
时间同步精度	$\pm 1.5 \mu\text{s}$
链路时延测量间隔	1 s
Sync 报文驻留时间	100 μs
Pdelay 报文响应时间	100 μs
TSN-Master 时钟抖动	不超过 2 ns
端到端链路传输时延	100~900 ns
5G Numerology	0
5G 无线传输可靠性	99%
5G 系统噪声	$n(t) \sim N(0, \sigma^2)$ ，标准差为 0.2A

基于上述仿真配置，本文对 0~100 s 内的时钟同步过程进行了模拟。图 4 展示了 TSN-Slave 与 TSN-Master 之间的链路时延和时钟频率比变化情况，图 5 展示了 5G-TSN 中的时钟同步误差演化曲线（在 100 s 的仿真过程中共采样 1 000 次）。从图 5 可以看出，5G-TSN 时钟同步误差具有周期性波动与突发性扰动特征。这说明误差序列中包含高频扰动成分与低频趋势成分，具有典型的复杂

时间序列特征。为提升模型的训练效果和泛化能力,本文对原始仿真数据进行了增强处理,通过丰富训练样本,强化模型对不同误差模式的适配能力。增强后的数据集按8:2的比例划分,其中80%用于LSTM模型训练,20%用于模型预测性能评估。



(a) 时钟频率比变化情况



(b) 链路时延变化情况

图4 链路时延和时钟频率比变化情况




图5 5G-TSN时钟同步误差演化曲线

4.2 对比模型与指标

为验证所提的基于LSTM的时钟同步误差预测模型的有效性,本文选取了BPNN、RNN和GRU 3种典型的时间序列预测模型,以及基于自注意力机制的Transformer模型进行对比实验。本文采用均方误差、均方根误差、平均绝对误差、平均绝对百分比误差(mean absolute percentage error, MAPE)、对称平均绝对百分比

误差(symmetric mean absolute percentage error, SMAPE)和决定系数 R^2 等经典指标评估预测模型的性能。

4.3 模型参数设置

基于表1所列参数构建的5G-TSN时钟同步仿真数据集,本文开展了同步误差预测实验。

在构建LSTM模型时,本文引入了网格搜索验证流程,通过遍历不同神经元数量与时间窗口长度的组合,以MSE值为核心评价依据进行对比验证,最终确定时间窗口长度 L 为12。

LSTM模型参数配置见表2,LSTM网络包含3个隐藏层。为防止模型过拟合,本文引入了早停机制,若验证集的loss在20个训练轮次内无性能提升,则提前终止训练过程。

表2 LSTM模型参数配置

模型参数	参数值
学习率	0.001
训练集:测试集	8:2
批大小	32
优化器	Adam
激活函数	ReLU
训练轮次	200轮
每层LSTM神经元个数	200个
全连接层神经元个数	50个

为确保对比实验的公平性,BPNN、RNN与GRU 3种模型均采用与LSTM模型相同的参数配置。Transformer模型参数,结合其结构特性进行针对性设置,具体如下:采用6层编码器堆叠结构,每层编码器配置8头多头注意力机制,每个注意力头的维度为128;输入层嵌入正弦余弦位置编码。

4.4 实验结果

实验结果如表3~表4、图6~图8所示。从表3和图6可以看出,LSTM和4种对比模型在训练集上,均能较好地拟合出5G-TSN时钟同步误差随时间的变化趋势,但是LSTM模型的预测误差更小、精度更高,在各项评价指标上表现优越。具体而言,LSTM在所有评价指标上优于4种对比模型。尤其是在MSE方面,BPNN、RNN、GRU及Transformer模型的数值处于300~337之间,LSTM模型的MSE值为262.26(相较其他模型下降较多);在RMSE和MAE方面,LSTM表现略优于其他模型;在MAPE和SMAPE方面,与其他4种模型相

比, LSTM提升范围分别为9.4%~29.80%、10.50%~32.20%; 在 R^2 方面, 训练集所有模型均超过0.95, 其中LSTM的 R^2 值(0.973)最高, 表明所有模型在训练集上均具备良好的拟合能力, 而LSTM在模型可解释性与拟合能力方面具有领先优势。

表3 各模型在训练集上的实验结果

预测模型	指标					
	MSE	RMSE	MAE	MAPE	SMAPE	R^2
BPNN	307.19	17.527	12.143	173.90%	173.40%	0.968
RNN	300.96	17.348	12.557	180.80%	179.70%	0.969
GRU	305.98	17.492	12.065	172.30%	171.70%	0.968
Transformer	336.43	18.342	13.782	192.70%	193.40%	0.965
LSTM	262.26	16.194	11.227	162.90%	161.20%	0.973

表4 各模型在测试集上的实验结果

预测模型	指标					
	MSE	RMSE	MAE	MAPE	SMAPE	R^2
BPNN	456.394	21.363	14.723	179.40%	180.10%	0.933
RNN	379.329	19.476	14.317	175.10%	174.80%	0.944
GRU	418.981	20.469	14.713	178.80%	179.20%	0.938
Transformer	765.740	27.672	21.012	251.60%	255.50%	0.887
LSTM	348.401	18.665	13.584	165.10%	165.20%	0.951

然而, 在测试集上的拟合能力更能反映预测模型的泛化能力。从表4和图6可以看出, 所有模型在测试集上仍然展现出较好的预测能力, 其中LSTM在整体指标上仍明显优于其他模型, 表明所有模型均能较好地刻画出5G-TSN时钟同步




图6 训练集和测试集的拟合指标

误差随时间的变化规律。具体而言,在MSE方面,LSTM为348.4,显著低于BPNN、GRU和Transformer;RNN的MSE为379.33,虽相较BPNN与GRU误差更小,但仍不及LSTM。在RMSE、MAE、MAPE和SMAPE方面,LSTM同样保持领先,但与训练集相比优势略有收窄。在 R^2 方面,LSTM是唯一在测试集上仍超过0.95的模型,验证了LSTM模型具有更强的泛化能力与拟合稳定性。

综上所述,相较于BPNN、RNN及GRU,基于LSTM的5G-TSN时钟同步误差预测机制在训练集和测试集上均表现出更高的预测精度与鲁棒性,能够有效监测和预测时钟同步误差的变化趋势。此外,尽管Transformer凭借复杂的位置编码与注意力机制常被视为更先进的模型,但在本任务的小样本数据集下,其各项指标均劣于BPNN、RNN、GRU及LSTM,且训练收敛时间显著更长,难以满足工业场景对实时性与高效性的要求。

LSTM不仅在整体趋势预测上表现优异,在同步误差较大的关键时间点(即潜在故障时刻)的识别与捕捉方面同样展现出较强能力。如图7所示,在训练集的第1 645~1 648个采样区间,5G-TSN同步误差集中在1 000 ns附近,已接近3GPP规定的同步精度临界值(1 μ s),提示该时段可能存在同步异常风险。进一步观察可见,在第1 646和1 647个采样点上,LSTM的预测值最接近实际值,显示出其对潜在故障时刻的精准识别能力。在测试集上也呈现类似规律,如图8所示,在第12~14个采样区间,同步误差同样逼近1 000 ns,LSTM在该区间的预测误差最小,表现出更强的故障趋势感知能力。类似现象在第246~248、372~374等采样区间同样存在。




图7 训练集的拟合情况




图8 测试集的拟合情况

此外,为更全面地评估模型在贴近工业复杂干扰环境下的性能,在利用表1所列参数构建的5G-TSN时钟同步仿真环境基础上,本文设计了非高斯与非平稳噪声条件下的鲁棒性测试。训练阶段仍采用高斯白噪声 $n(t) \sim N(0, \sigma^2)$ ($\sigma = 0.2A$),测试阶段引入脉冲噪声、混合噪声和突发噪声,3类噪声的仿真描述和参数配置如下。

1) 脉冲噪声:以概率 p_{imp} 在误差序列中注入幅值为 $A_{\text{imp}} \times \sigma$ 的脉冲干扰,用于模拟工业现场偶发的强干扰。

2) 混合噪声:在高斯噪声基础上叠加脉冲噪声,模拟常规噪声与偶发干扰共存的场景,参数配置为 $\sigma = 0.01A$ 、 $p_{\text{imp}} = 0.001$ 、 $A_{\text{imp}} = 0.1\sigma$ 。

3) 突发噪声:采用马尔可夫模型生成连续 L_{burst} 个采样点的高幅度干扰,本实验设置 $L_{\text{burst}} = 1$ 、 $A_{\text{imp}} = 0.1\sigma$,用于模拟工业系统中设备切换、瞬态冲击等引起的短时干扰。

该实验保持LSTM网络结构、超参数、训练集数据分布不变,仅改变测试集噪声类型与强度,并记录LSTM模型在不同噪声条件下的MSE、 R^2 及相对于基线高斯噪声的MSE变化率,具体见表5。

表5 LSTM模型在不同噪声环境下的性能

噪声类型	噪声参数	MSE	R^2	MSE变化率
高斯	$\sigma=0.2A$	348.401	0.951	0
脉冲	$p_{\text{imp}}=0.001, A_{\text{imp}}=0.1\sigma$	347.314	0.945	-0.312%
混合	$\sigma=0.01A, p_{\text{imp}}=0.001, A_{\text{imp}}=0.1\sigma$	377.346	0.940	8.308%
突发	$L_{\text{burst}}=1, A_{\text{burst}}=0.1\sigma$	352.585	0.944	1.201%

由表5可知,在3类干扰噪声环境下,LSTM模型的MSE与 R^2 均未出现显著波动,仍能较精

准地完成误差预测任务,表现出良好的抗干扰鲁棒性。

综上所述,在构建的 5G-TSN 时钟同步仿真环境下,基于 LSTM 的误差预测机制不仅能够精准刻画同步误差的整体变化趋势,还能够有效识别和捕捉同步异常时刻,为实际部署中的时钟同步监测、故障预警及精准调控提供可靠支持。此外,该模型能够对不同时间点的同步精度差异进行预判,从而为业务流的优先级调度与网络资源动态分配提供时序依据,在保障时延敏感业务需求的同时,提高网络资源利用效率与整体系统的可靠性。

5 结束语

5G-TSN 融合网络被视为支撑工业 4.0 发展的有效解决方案,而高精度的 5G-TSN 时钟同步是保障无线与有线网络业务确定性传输的基础。由于 5G 与 TSN 属于异构网络,二者在时钟信息传递机制、协议栈及同步路径上存在显著差异,加之 5G 无线传输本身的不确定性,实现高精度同步面临严峻挑战。现有研究缺乏对 5G-TSN 时钟同步误差动态演变的有效监测与预测机制。为此,本文提出一种基于 LSTM 的 5G-TSN 时钟同步误差预测机制,旨在实现对误差演化趋势及异常时刻的有效感知与提前调控。

本文基于 3GPP 提出的架构准则,将 5G 与 TSN 建模为两个独立的时钟域,综合考虑 DS-TT、NW-TT 与 5GS 的频率偏差,以及 5G 内部 UE 设备移动等不确定因素,构建了面向实际场景的 5G-TSN 时钟同步仿真模型,并模拟了 gPTP 报文在融合网络中的传输与时钟补偿过程。

本文提出了基于 LSTM 的 5G-TSN 时钟同步误差预测机制,该机制涵盖数据采集、模型构建与预测应用 3 层架构。通过建模误差序列的周期性与趋势性特征,实现对下一时刻误差的准确预测,为时钟同步的提前校准与误差规避提供依据。实验结果表明, LSTM 模型的预测精度在 MAE、MAPE、MSE、RMSE、SMAPE 和 R^2 等指标上均优于对比模型,验证了所提机制在预测精度与泛化能力方面的优势,为提升 5G-TSN 时钟同步性能提供了有效的技术支撑。

除整体趋势预测外, LSTM 模型对同步过程中的异常或潜在故障时刻也展现出良好的识别与预警能力。此外,时钟同步精度可作为业务调度的关键约束,依托预测机制对各时刻同步精度进行动态评估,可辅助实现智能调度决策:在同步精度较高时段优先保障时延敏感业务(如机械臂协同),在同步精度较低时段则调度带宽或吞吐量敏感型业务(如高清视频传输)。该机制不仅有助于提升同步系统的稳定性,也为网络资源优化分配提供了决策依据。

未来将探索将该预测机制融入垂直行业场景下的业务调度系统,构建面向时钟驱动的业务感知型调度优化框架,实现从同步精度预测到资源优化控制的全链路协同。同时,将研究 LSTM 预测与同步补偿算法的联合优化,增强系统的控制韧性。此外,也将对模型在硬件加速与边缘部署等方面的工程化路径进行探索,从而提升其实用价值。

参考文献:

- [1] Rikalovic A, Suzic N, Bajic B, et al. Industry 4.0 implementation challenges and opportunities: a technological perspective[J]. IEEE Systems Journal, 2022, 16(2): 2797-2810.
- [2] 5G Alliance for Connected Industries and Automation. 5G for connected industries and automation(second edition)[EB]. 2025.
- [3] Lo Bello L, Steiner W. A perspective on IEEE time-sensitive networking for industrial communication and automation systems[J]. Proceedings of the IEEE, 2019, 107(6): 1094-1120.
- [4] Wu H. Ten reflections on 5G[J]. ZTE communications, 2020, 18(1): 1-4.
- [5] 3GPP. System architecture for the 5G system (5GS): 3GPP TS 23.501 version 16.10.0[S]. 2020.
- [6] Acia G. Integration of 5G with time-sensitive networking for industrial communications[R]. 2021.
- [7] 3GPP. System architecture for the 5G system: 3GPP TS 23.501 V15.3.0[S]. 2018.
- [8] Jiang X, Luvisotto M, Pang Z, et al. Reliable minimum cycle time of 5G NR based on data-driven channel characterization[J]. IEEE Transactions on Industrial Informatics, 2021, 17(11): 7401-7411.
- [9] Au E. A short update on 3GPP release 16 and release 17 standards[J]. IEEE Vehicular Technology Magazine, 2020, 15(2): 160-160.
- [10] 朱瑾瑜, 张恒升, 陈洁. TSN 与 5G 融合部署的需求和网络架构演进[J]. 中兴通讯技术, 2021, 27(6): 47-52.

Zhu J Y, Zhang H S, Chen J, et al. Requirements and network architecture evolution of integrated TSN and 5G deployments[J]. ZTE

Communications, 2021, 27(6): 47-52.

- [11] Muslim A B, TöNjes R, Bauschert T. Synchronizing TSN devices via 802.1 AS over 5G networks[J]. Electronics, 2024, 13(4): 768.
- [12] 李晓辉, 王先文, 樊韬, 等. 5G-TSN系统下的高精度时间同步[J]. 系统工程与电子技术, 2023, 45(2):559-565.
Li X H, Wang X W, Fan T, et al. High-precision time synchronization in 5G-TSN systems[J]. Systems Engineering & Electronics, 2023, 45(2):559-565.
- [13] Song J, Kubomi M, Zhao J, et al. Time synchronization performance analysis considering the frequency offset inside 5G-TSN network[C]//Proceedings of the 2021 17th International Symposium on Wireless Communication Systems. Piscataway: IEEE Press, 2021: 1-6.
- [14] Chai Z C, Liu W, Li M, et al. Cross domain clock synchronization based on data packet relay in 5G-TSN integrated network[C]//Proceedings of the 2021 IEEE 4th International Conference on Electronics and Communication Engineering (ICECE). Piscataway: IEEE Press, 2022: 141-145.
- [15] Striffler T, Schotten H D. The 5G transparent clock: synchronization errors in integrated 5G-TSN industrial networks[C]//Proceedings of the 2021 IEEE 19th International Conference on Industrial Informatics (INDIN). Piscataway: IEEE Press, 2021: 1-6.
- [16] Wei X H, Wei X Z, Luo Z Q, et al. An enhanced IEEE1588 clock synchronization for link delays based on a system-on-chip platform[J]. International Journal of Electronics and Telecommunications, 2021: 289-294.
- [17] 朱海龙, 严园园, 张华宇. 基于驻留时间补偿的5G-TSN系统高精度时间同步方法[J]. 北京邮电大学学报, 2023, 46(6): 89-94.
Zhu H L, Yan Y Y, Zhang H Y, et al. High-precision time synchronization method for 5G-TSN systems based on dwell time compensation [J]. Journal of Beijing University of Posts and Telecommunications, 2023, 46(6): 89-94.
- [18] Wang J Q, Du Y, Wang J. LSTM based long-term energy consumption prediction with periodicity[J]. Energy, 2020, 197: 117197.
- [19] Pano-Azucena A D, Tlelo-Cuautle E, Tan S X D. Prediction of chaotic time series by using ANNs, ANFIS and SVMs[C]//Proceedings of the 2018 7th International Conference on Modern Circuits and Systems Technologies (MOCAST). Piscataway: IEEE Press, 2018: 1-4.
- [20] Aishwarya D C, Babu C N. Prediction of time series data using GA-BPNN based hybrid ANN model[C]//Proceedings of the 2017 IEEE 7th International Advance Computing Conference (IACC). Piscataway: IEEE Press, 2017: 848-853.
- [21] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [22] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. 2017: 5998-6008.

[作者简介]



刘青俊 (2001-), 男, 山西大同人, 南京航空航天大学硕士生, 主要研究方向为确定性网络、工业互联网。



王然 (1989-), 男, 黑龙江哈尔滨人, 南京航空航天大学副教授、博士生导师, 主要研究方向为云计算、工业互联网、人工智能应用等。



黄震宁 (1988-), 男, 安徽枞阳人, 中国移动通信集团有限公司研究院高级工程师, 主要研究方向为5G/6G网络演进、工业互联网、能力开放、智能化、确定性网络等。



郝洁 (1988-), 女, 安徽亳州人, 南京航空航天大学副教授、硕士生导师, 主要研究方向为无线传感、无线通信等。



滕艺丹 (1987-), 女, 吉林吉林人, 深圳职业技术大学讲师, 主要研究方向为图像处理、增强现实与虚拟现实技术应用。



吴强 (1973-), 男, 新疆伊宁人, 浙江大学教授、博士生导师, 主要研究方向为未来网络、工业互联网、空天地一体化网络等。