

## 基于带内网络遥测数据的流量预测与负载均衡

张旭<sup>1,2,3</sup>, 赵晨熙<sup>1,2</sup>, 冯川<sup>1,2,3</sup>, 文婷<sup>1,2</sup>, 刘炜<sup>1,2</sup>, 郭磊<sup>1,2</sup>

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 重庆邮电大学智能通信与网络安全研究院, 重庆 400065;  
3. 重庆邮电大学大数据智能计算重点实验室, 重庆 400065)

**摘要:** 为了解决网络运维与管理中海量遥测数据分析的挑战, 设计了一个网络控制自动化系统。整体原则遵循“监控-分析-控制”的架构。在监控模块中, 通过 SRv6-INTO 算法进行遥测数据采集编排。同时为缓解控制平面负载, 在数据平面开发了数据处理器, 对遥测数据进行初步处理。分析模块采用长短期记忆网络与注意力机制相结合的方法对遥测数据进行流量预测。控制模块基于分析模块的预测结果, 通过 SRv6 技术实现业务流的动态路径调整。仿真结果表明, 所提模型在预测精度上优于其他方法, 并成功实现了拥塞避免。

**关键词:** 带内网络遥测; 网络控制自动化; 流量预测; 负载均衡

**中图分类号:** TP393.06; TP183

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2025142

## Traffic prediction and load balancing based on in-band network telemetry data

ZHANG Xu<sup>1,2,3</sup>, ZHAO Chenxi<sup>1,2</sup>, FENG Chuan<sup>1,2,3</sup>, WEN Ting<sup>1,2</sup>, LIU Wei<sup>1,2</sup>, GUO Lei<sup>1,2</sup>

1. School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China  
2. Institute of Intelligent Communications and Network Security, Chongqing University of Posts and Telecommunications, Chongqing 400065, China  
3. Key Laboratory of Big Data Intelligent Computing, Chongqing University of Posts and Telecommunications, Chongqing 400065, China

**Abstract:** To address the challenges of massive telemetry data analysis in network operation and management, a network control automation system was designed. The overall architecture followed the “monitor-analyze-control” principle. The SRv6-INTO algorithm was used in the monitoring module for telemetry data collection and orchestration. To alleviate the load on the control plane, a data processor was developed in the data plane to perform preliminary processing of the telemetry data. The analysis module employed a combination of long short-term memory networks and attention mechanisms for traffic forecasting based on the telemetry data. The control module dynamically adjusted service flow paths using SRv6 technology, based on the prediction results from the analysis module. Simulation results show that the proposed model outperforms other methods in prediction accuracy and successfully achieves congestion avoidance.

**Keywords:** in-band network telemetry, network control automation, traffic prediction, load balancing

### 0 引言

随着网络规模的扩大和业务类型的日益丰富, 传统的人工网络管理方式已难以满足日益提高的网

络性能和灵活性需求。如何高效处理和深入分析收集的海量遥测数据, 并从中获取有价值的网络状态信息成为一个亟待解决的关键问题。传统的数据分

收稿日期: 2025-07-01; 修回日期: 2025-08-10

通信作者: 冯川, fengc@cqupt.edu.cn

基金项目: 国家自然科学基金资助项目(No.62201105, No.62331017); 重庆市教育委员会科学技术研究基金资助项目(No. KJQN202400621); 重庆市自然科学基金资助项目(No.CSTB2025NSCQ-GPX1283)

**Foundation Items:** The National Natural Science Foundation of China (No.62201105, No.62331017), The Chongqing Municipal Education Commission (No.KJQN202400621), The Natural Science Foundation of Chongqing (No.CSTB2025NSCQ-GPX1283)

析方法主要基于统计学模型, 如自回归移动平均模型 (ARIMA, autoregressive integrated moving average model)、向量自回归模型等, 但这些方法难以有效捕捉网络流量的非线性特征和长期依赖关系, 也无法充分利用遥测数据中丰富的网络状态信息。为此, 众多学者开始探索深度学习解决方案。长短期记忆 (LSTM, long short-term memory) 网络凭借其独特的门控机制, 在时序数据处理方面展现出显著优势。然而, 单纯的 LSTM 模型在处理复杂网络流量时仍有局限, 难以兼顾不同时间段的局部和全局特征, 对突发流量的预测准确度不理想, 且存在长期预测误差累积的问题。为了解决这些问题, 不少学者提出将注意力 (Attention) 机制引入 LSTM 模型。注意力机制能够自适应地为不同时间步和不同路径段的特征分配权重, 从而有效避免 LSTM 模型因长期预测误差累积的问题<sup>[1-2]</sup>。

与此同时, 带内网络遥测 (INT, in-band network telemetry) 作为一种创新的网络监控方法, 通过在数据包中携带遥测指令, 使其能够在传输过程中自动采集网络设备的状态信息, 如队列深度、链路利用率等关键指标<sup>[3]</sup>。与传统网络监控方法相比, INT 通过数据平面直接收集信息, 不需要控制平面干预, 不仅能准确反映网络实际运行状态, 还可以获取细粒度的逐跳信息<sup>[4]</sup>。更重要的是, 它支持可编程, 具备强大的灵活性和扩展性, 为基于深度学习的分析方法提供更为精准和丰富的输入数据, 从而提升预测的准确性和稳定性。

随着网络规模和复杂性的不断增加, 如何高效分析遥测数据并实现网络状态的全面评估, 成为当前亟待解决的重要问题。虽然已有大量文献对带内网络遥测编排问题进行了深入研究<sup>[5-8]</sup>, 但少有文献探讨基于编排所采集的遥测数据分析的问题, 基于以上背景, 本文重点研究基于带内网络遥测数据的流量预测与负载均衡问题, 主要研究工作如下。

1) 针对网络运维与管理中海量遥测数据分析的挑战, 为了实现网络控制自动化, 本文提出了一种“监控-分析-控制”一体化网络自动化系统架构。

2) 在监控模块中, 利用文献[9]中提出的 SRv6-INTO 算法编排业务流并收集遥测数据, 同时为了减轻控制平面分析数据负载过重, 在数据平面开发了数据处理器, 对采集到的遥测数据做初步预处理。在分析模块中, 结合 LSTM 网络和注意力机制

对采集到的遥测数据进行分析。同时为了提高模型的性能, 通过控制变量的方法确定模型的超参数设置。在控制模块中, 设计了能够依据应用层需求智能路径调控机制, 通过 SRv6 技术调整业务流的路径以减轻交换机或链路负载, 实现负载均衡。

3) 在 Cost239 网络拓扑中进行了仿真分析, 仿真结果表明, 所提模型的均方根误差 (RMSE, root mean square error) 和平均绝对误差 (MAE, mean absolute error) 均低于其他基准模型, 同时在链路利用率、链路时延以及交换机队列深度的预测效果方面也优于基准模型, 并且根据流量预测的结果实现了负载均衡的功能。

## 1 相关工作

### 1.1 网络分析

随着海量遥测数据的持续采集与上传, 如何高效分析这些数据并准确评估网络运行状态, 成为众多学者关注的研究重点之一。文献[10]提出了一种基于 INT 和深度学习的自动化快速网络异常检测系统——INT-detector。首先, 构建了一个基于 INT 的遥测原型, 能够通过获取设备的逐跳状态实现精细化监控。然后, 利用生成对抗主动学习方法, 减少了对人工干预的依赖, 能够在大规模数据情况下自动检测异常。为了提高检测准确性, 采用低通滤波进行数据预处理, 消除了短期流量波动引起的瞬时抖动。文献[11]针对 INT 在数据包丢失监测方面的不足, 提出了数据包丢失监测系统, 设计了一种基于交替标记的丢包检测和定位机制, 通过标记遥测数据包来实现对丢包事件的精准识别。接着, 提出了一个基于生成对抗网络的丢失数据恢复方法, 该方法能够从不完整的遥测数据中恢复丢失的数据。文献[12]提出了一种基于熵驱动的自适应 INT 技术, 通过引入状态处理能力到可编程数据平面交换机, 实现了遥测数据的智能采集。该技术基于数据的信息含量进行本地决策, 既保证了监控精度, 又显著降低了带宽开销。此外, 通过与带外监控的有效结合, 该技术能够准确检测和定位网络异常。文献[13]提出了一种基于 INT 和递归神经网络的网络异常检测系统, 能够实时检测恶意网络攻击。文献[14]提出了一种基于 INT 技术的自动化分布式拒绝服务 (DDoS, distributed denial of service) 检测方法。该方法通过机器学习对 INT 数据进行分析, 成功实现

了对DDoS攻击的实时检测与识别。然而,尽管该方法在实时检测和识别方面取得了显著成效,仍然面临如何精确识别攻击路径和优化防御策略的问题。为了解决这一问题,文献[15]提出了一种基于时空图卷积网络(ST-GCN, spatial-temporal graph convolutional network)的方法,利用INT收集细粒度的网络状态信息,并通过ST-GCN模型捕捉网络状态的时序和空间特征,从而能够更准确地检测攻击路径。文献[16]提出了一种基于P4编程和INT技术的智能网络架构,旨在通过自动化学习和优化决策来支持网络拥塞控制。该架构通过INT技术实时获取网络状态信息,并结合机器学习算法,使系统能够自动学习并优化网络控制策略,从而减少人工干预,提升网络的灵活性和自适应能力。

尽管上述研究在网络状态监控、异常检测和攻击识别方面取得了显著成果,但它们大多集中于实时检测和分析当前网络状态,而针对如何利用网络状态信息进行流量预测的研究相对较少。

## 1.2 流量预测

流量预测不仅能够帮助优化网络资源分配和提升网络性能,还能为网络故障预警、流量调度等应用提供基础。因此,如何将网络状态应用于流量预测,成为当前网络监控领域中的一个重要研究方向。文献[17]利用LSTM模型对收集到的遥测数据进行了分析,从而实现了网络流量的预测。文献[18]为了避免大量遥测数据上传导致控制器负载过高,在数据平面采用多项式拟合算法(如一阶、二阶和三阶多项式拟合)作为预测算法,通过历史数据来预测设备的状态。只有当实际数据与预测数据之间的差值超过预定阈值时,才会上传真实的遥测数据,否则仅上传一个小的通知标志。这种方式有效降低了带宽开销,并减轻了控制器的负担。文献[19]提出了一种基于粒子群优化(PSO, particle swarm optimization)和LightGBM的网络流量预测模型,该模型通过PSO LightGBM的参数,使每个网络流量可以适应不同的流量特性。与传统的深度学习模型相比,该模型结构更加简单,同时在准确性和效率上表现更好。

综上所述,现有研究大多只局限于对网络状态数据进行分析 and 流量预测,但是没有将预测结果运用于实际网络调控。因此,本文将基于遥测数据进行流量预测,并结合SRv6技术实现网络负载均衡。

## 2 系统架构

### 2.1 总体架构

网络控制自动化系统设计如图1所示,该系统设计遵循“监控-分析-控制”的基本框架,运行流程如下。在控制器中,首先通过文献[9]设计的SRv6-INTO应用作为监控模块,通过将SRv6-INTO算法的输出下发到数据平面,从而实现高收益的带内网络遥测编排。同时,为了降低控制平面的开销,本文将一部分数据处理卸载到数据平面,通过数据处理器进行初步处理。当收集到遥测数据后,数据处理器首先进行数据预处理,然后进行基于差值过滤的数据去重,最后将数据存储到数据库以便后续分析,并上传至控制器的分析模块。分析模块通过将LSTM网络和注意力(LSTM-Attention)机制相结合对遥测数据进行分析,从而实现流量预测。随后,流量预测的结果会反馈给控制模块,此时控制模块则会通过SRv6技术对业务流进行灵活路由,从而有效避免网络拥塞。以图1中数据平面中的一条业务流为例,SRv6-INTO算法编排了其遥测路径为S1—S2—S4—S6,并在交换机S2、S4和S6处采集遥测数据。通过分析模块进行流量预测,发现S4—S6链路可能出现拥塞。此时,控制模块将业务流的遥测路径从S1—S2—S4—S6调整为S1—S2—S4—S5—S6,从而成功避免了链路拥塞。数据处理器具体功能包括将交换机内部数据转换为链路状态信息、基于差值过滤的数据去重和对遥测数据缺失进行补充。

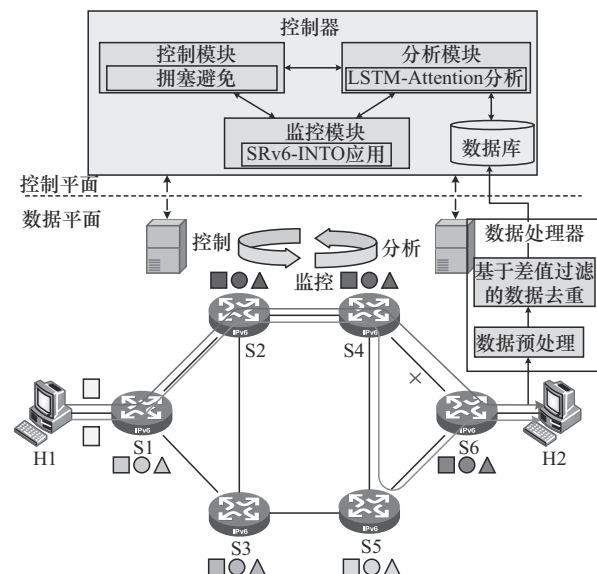


图1 网络控制自动化系统设计

表 1 给出了本文需要进行数据分析的遥测数据种类, 并详细介绍了其反映链路和交换机状态的各项指标。

表 1 遥测数据种类

遥测数据	反映状态说明
队列深度	队列深度越大说明交换机负载越高
链路利用率	链路利用率高说明存在链路拥塞
链路时延	链路时延异常增加表明链路可能存在问题
时间戳	用于记录采集遥测数据的时间
交换机 ID	用于记录遥测数据所属的交换机

由于 SRv6-INTO 算法采集到的遥测数据属于交换机的遥测数据, 因此需要进一步计算才能得到链路遥测数据, 它们的计算方式如式(1)和式(2)所示。

#### 1) 链路时延

$$\text{链路时延} = \text{入队时间戳} - \text{出队时间戳} \quad (1)$$

式(1)用于计算链路上传输的数据包时延。

#### 2) 链路利用率

$$\text{链路利用率} = \frac{\text{通过链路字节数} \times 8}{\text{链路时延} \times \text{链路带宽}} \quad (2)$$

式(2)用于计算链路利用率。

在实际网络环境中, 链路和交换机状态参数(如队列深度、链路时延、链路利用率等)通常呈现出较强的时间连续性, 短期内不会出现剧烈波动。基于这一特点, 本节在数据平面设计了差值过滤方法对原始遥测数据进行初步筛选。具体来说, 当相邻 2 次采集的遥测数据变化幅度小于预设阈值时, 可以仅保留其中一条记录, 从而有效降低数据存储和传输开销。此外, 由于 SRv6-INTO 算法采用选择性数据采集, 即并非对所有遥测数据进行采集, 因此在某些时间点可能存在数据缺失的情况。为了保证后续分析模块预测的准确性, 需要对这些缺失的数据进行相应的填补处理。因此, 本节设计了遥测数据预处理算法实现对遥测数据的预处理, 并将其应用在数据处理器, 如算法 1 所示。

#### 算法 1 遥测数据预处理

输入  $S_T, N_T$

输出  $\tilde{S}_T, \tilde{N}_T$

- 1) for  $t \in T$  do
- 2) if  $D(S_t - S_{t-1}) || D(N_t - N_{t-1})$  do
- 3) if  $J(S_t) || J(N_t)$  do

- 4) 采用前向补充的方式对  $S_T$  和  $N_T$  进行缺失值处理
- 5) end if
- 6) 更新遥测数据至数据库
- 7) end if
- 8) end for

算法 1 的输入为 SRv6-INTO 算法采集到的遥测数据集  $S_T$  和  $N_T$ , 其中  $S_T = \{q_v\}_{v=1}^{|V|}$ , 表示  $T$  时间步所收集交换机的队列深度, 而  $N_T = \{(u_l, d_l)\}_{l=1}^{|L|}$ , 表示  $T$  时间步收集的链路利用率和链路时延。算法 1 的输出为遥测数据预处理后的集合  $\tilde{S}_T$  和  $\tilde{N}_T$ 。首先在算法的第 1 行遍历所有的时间步, 第 2 行中  $D(S_t - S_{t-1})$  和  $D(N_t - N_{t-1})$  是判断交换机和链路在  $t$  和  $t-1$  时刻的遥测数据的差值是否超过所设定的阈值。当 2 个时间步之间的遥测数据差值超过前一时刻数据的 5% 时, 则认为该差值超过阈值。若超过则在算法的第 3 行通过  $J(S_t)$  和  $J(N_t)$  来判断交换机和链路在  $t$  时刻的遥测数据是否有缺失项, 若有缺失, 则在算法的第 4 行通过前向补充的方式。例如, 若某一时间步缺失链路时延数据, 则用前一时间步的链路时延数据进行填充。最后在算法的第 6 行将遥测数据更新至数据库。

## 2.2 分析模块

在传统的 LSTM 模型中, 网络依赖于一个固定大小的隐藏状态来表示输入序列的所有信息。虽然 LSTM 模型能够捕捉长期依赖关系, 但在不同时间步的遥测数据中, 模型可能无法有效地识别哪些时刻对当前预测更为关键。因此, 本节结合注意力机制, 使模型能够根据每个时间步的重要性动态地调整输入权重。

图 2 给出了 LSTM-Attention 模型架构原理, 由 4 个关键组件构成。输入序列用于接收经过预处理的遥测数据序列, 通常包括交换机队列深度、链路时延、链路利用率等时序数据。LSTM 隐藏层通过其特殊的门控结构和记忆单元, 有效捕捉遥测数据中的时序依赖关系。而 Attention 层的作用则是对 LSTM 隐藏层输出和输入序列的时序特征进行加权, 赋予不同时间步不同的权重, 使模型能够聚焦于对预测结果最为重要的时间步。通过这种方式, Attention 机制帮助模型识别出关键的时间点, 如交换机或链路负载过重的时刻, 从而提升预测的准确性。经过 LSTM 隐藏层和 Attention 机制处理后, 模

型得到了多个时间步的加权特征,全连接层通过对这些加权特征进行进一步处理和组合,最终生成交换机和链路状态的预测值。如式(3)所示,LSTM模型通过点积计算当前时刻和历史时刻之间的相似度得分,然后对得分进行缩放,以平衡不同时间步对当前预测的影响。

$$e_{ii} = \frac{h_i^T h_i + x_i^T x_i}{\sqrt{d}} \quad (3)$$

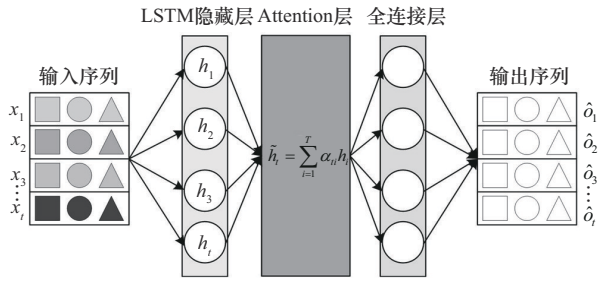


图2 LSTM-Attention模型架构原理

式(3)用于计算不同时间步下隐藏层状态的相似度同时包括不同时间步输入之间的相似度,其中, $d$ 表示隐藏层状态的维度, $x_t = [\tilde{S}_t, \tilde{N}_t]$ 。

$$\alpha_{ii} = \frac{\exp(e_{ii})}{\sum_{j=1}^T \exp(e_{ij})} \quad (4)$$

式(4)用于将相似度得分进行归一化处理,将它们转换为注意力权重,确定不同时间步的遥测数据对当前预测的重要性程度。

$$\tilde{h}_t = \sum_{i=1}^T \alpha_{ii} h_i \quad (5)$$

式(5)用来计算更新后时间步 $t$ 的隐藏层状态 $\tilde{h}_t$ ,结合了注意力权重和当前隐藏层状态 $h_t$ ,生成新的隐藏层状态。

基于LSTM-Attention分析模块的具体步骤如下。

**步骤1** 遥测数据归一化处理。由于原始采集的遥测数据是交换机内部的原始状态信息,这些数据尚未直接反映网络链路的关键性能指标,需要通过算法1对遥测数据进行预处理后,上传至控制器。对遥测数据归一化处理后将不同尺度和范围的数据转换到一个统一的标准尺度,对于预处理后的遥测数据集 $\tilde{S}_T$ 和 $\tilde{N}_T$ ,通过式(6)和式(7)对交换机队列深度和链路时延进行归一化处理。由于链路利用率本身已经在 $[0,1]$ 内,因此不需要进行归一化处理。

$$\tilde{q}_v = \frac{q_v - q_{v_{\min}}}{q_{v_{\max}} - q_{v_{\min}}} \quad (6)$$

其中, $q_v$ 表示交换机 $v$ 的队列深度, $q_{v_{\max}}$ 和 $q_{v_{\min}}$ 分别表示遥测数据集中交换机 $v$ 的最大队列深度和最小队列深度。

$$\tilde{d}_l = \frac{d_l - d_{l_{\min}}}{d_{l_{\max}} - d_{l_{\min}}} \quad (7)$$

其中, $d_l$ 表示链路 $l$ 的时延, $d_{l_{\max}}$ 和 $d_{l_{\min}}$ 分别表示遥测数据集中链路 $l$ 的最大时延和最小时延。假设训练数据序列长度为 $N$ ,输入窗口长度为 $m$ 以及预测步长为 $l$ 。

**步骤2** 将训练集根据训练数据序列长度划分为 $P = (x_1, x_2, \dots, x_N)$ 。

**步骤3** 构建训练集的输入值和预测值,可以表示为

$$V = (K_1, x_{m+l}; K_2, x_{m+l+1}; \dots; K_{N-m-l+1}, x_N) \quad (8)$$

其中, $K_1$ 为第一组输入的遥测数据值, $x_{m+l}$ 是根据 $K_1$ 预测第 $m+l$ 时刻的遥测数据值, $K_1 = (x_1, x_2, \dots, x_m)$ 。同理, $K_{N-m-l+1}$ 为最后一组输入的遥测数据值, $x_N$ 为最后一组的预测值, $K_{N-m-l+1} = (x_{N-m-l+1}, x_{N-m-l+2}, \dots, x_{N-l})$ 。

**步骤4** 根据步骤3中构建的训练集的输入值和预测值对模型进行训练。

**步骤5** 模型训练完成后,利用训练好的模型在验证集上预测遥测数据值。

## 2.3 控制模块

为了实现网络控制自动化,本节在控制平面中设计了控制模块。该模块以LSTM-Attention流量预测结果为基础,利用SRv6技术编排业务流路径。通过识别即将可能发生堵塞的链路以及即将达到处理瓶颈的交换机,控制器能够灵活下发流表从而及时调整业务流路径,有效避免链路堵塞和避开处理负载过高的交换机。本节提出了一种针对应用层需求按需调整路径的方案。若应用层需要减缓交换机的处理负载,则为业务流规划交换机负载较轻的路径进行传输。若应用层需要缓解链路带宽总开销,则为业务流规划链路利用率较低的传输路径。控制模块的堵塞避免步骤如下。

**步骤1** 控制器根据每个业务流的源节点和目的节点通过最短路径优先(SPF, shortest path first)算法计算其最短路径。

**步骤 2** 判断业务流的当前的路径是否经过即将拥塞的链路或到达负载瓶颈的交换机。若经过则进行步骤 3，反之执行步骤 6。

**步骤 3** 将预测即将拥塞的链路或达到负载瓶颈的交换机从拓扑图中暂时移除。

**步骤 4** 在修改后的拓扑图上，根据应用层需求选择合适的路径优化策略：若应用层需要减缓交换机处理负载，则使用交换机负载作为路径权重，寻找总权重最小的路径；若应用层需要缓解链路带宽总开销，则使用链路利用率作为路径权重，寻找总权重最小的路径。

**步骤 5** 通过 SRv6 技术构建路径编排策略，生成对应的路径段列表。

**步骤 6** 控制器根据计算出的路径下发流表，指示业务流按照路径进行传输。

同时为了方便指示业务流的路径，本节对 SRv6 数据包结构中的分段路由头部 (SRH, segment routing header) 的 Segment List 字段进行了专门设计。该字段由 128 bit 的 IPv6 地址组成，本节设计其具体格式为  $200x:db8:dead::y$ ，其中  $x$  和  $y$  分别代表某个交换机的 ID 和端口号。具体来说，若 SRv6 数据包结构中的 SRH 内有 4 个 Segment List 字段，分别为  $2001:db8:dead::1$ 、 $2002:db8:dead::4$ 、 $2004:db8:dead::4$  和  $2006:db8:dead::3$ ，则表示该数据包将依次经过 ID 为 1、2、4 和 6 的交换机，并从这些交换机的 1 号、4 号、4 号和 3 号端口转发出去，从而实现了数据包转发路径的精确控制与灵活转发。

为了更清楚地说明拥塞避免的过程，用一个例子来详细说明，如图 3 所示。从主机 H1 发送一个数据包至 H2，当数据包到达连接 H1 的交换机 S1 时，S1 随即通过与控制器相连的链路发送 Packet-In 信息，通过 SPF 算法为业务流计算最短路径，路径为 S1—S2—S4—S6。LSTM-Attention 模型预测 S4-S6 链路可能发生拥塞。为此，控制器重新计算备选路径，得到 2 条可选路径：S1—S2—S5—S6 和 S1—S3—S5—S6。其中路径 S1—S2—S5—S6 交换机负载较低，路径 S1—S3—S5—S6 链路负载更低。若应用层需要减轻交换机处理负载，控制器将选择交换机负载较低的路径 S1—S2—S5—S6，并通过 SRv6 技术向业务流嵌入链路的段标识符 (SID, segment identifier)，然后下发流表，引导业务流沿新路径传输。若应用层需要缓解链路带宽开

销，控制器则选择链路负载更低的路径 S1—S3—S5—S6，同样通过 SRv6 技术完成路径重构和流表下发，有效降低链路负载。




图 3 拥塞避免

### 3 仿真分析

#### 3.1 仿真设置

##### 1) 数据集准备

本文基于具有 11 个节点和 23 条链路的 Cost239 网络拓扑，通过文献[9]所提 SRv6-INTO 算法来采集遥测数据。Cost239 网络拓扑如图 4 所示。假设每个节点内有 10 种遥测数据类型，分别为交换机 ID、入端口号、出端口号、解析状态、数据包长度、队列时延、入队深度、出队深度、入口时间戳和出口时间戳。




图 4 Cost239 网络拓扑

在遥测数据采集过程中,本文采用主机随机生成业务流的方法,通过随机选择源节点和目的节点保证流量的随机性和网络覆盖性。业务流的传输路径则基于 SPF 算法精确计算,模拟真实网络中的路由选择机制。随机生成的业务流、Cost239 网络拓扑结构以及各节点内的遥测数据集合,将作为 SRv6-INTO 算法的输入。控制器接收 SRv6-INTO 算法的输出后,将相应的流表下发至数据平面,当业务流经过对应节点后进行遥测数据采集,最终获得原始遥测数据集。同时为了造成流量拥塞的现象,本文将在不同时刻在节点 4 和节点 8 集中生成大流量和长持续时间的业务流,一共采集了 1 000 个时间点的数据作为模型的输入。

## 2) 模型参数设置

为了评估所提 LSTM-Attention 模型的性能,本文采用 RMSE 和 MAE 这 2 种指标对流量预测结果进行定量分析,计算方式分别如式(9)和式(10)所示。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{o}_i - o_i)^2} \quad (9)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{o}_i - o_i| \quad (10)$$

其中,  $\hat{o}_i$  表示预测值,  $o_i$  表示真实值,且  $\hat{o}_i$  和  $o_i$  都是一个三元组,包括当前时刻的交换机队列深度、链路时延和链路利用率。具体来说,预测值  $\hat{o}_i = (\hat{q}_i, \hat{u}_i, \hat{d}_i)$ , 其中,  $\hat{q}_i$  表示预测的归一化队列深度,  $\hat{u}_i$  表示预测的归一化链路利用率,  $\hat{d}_i$  表示预测的归一化链路时延,同理,真实值  $o_i = (\tilde{q}_i, \tilde{u}_i, \tilde{d}_i)$ 。

在预测过程中, LSTM-Attention 模型的超参数配置对模型性能好坏具有一定影响。超参数包括输入窗口大小、批量大小、训练次数、隐藏层数、隐藏层神经元数量和学习率。为了确定最优参数组合,本文采用控制变量法进行超参数选择。在每次实验中仅调整一个目标参数,其他参数不变,从而观察每个超参数对模型性能的影响。评估过程中主要以 RMSE 作为核心指标,反映预测值与真实值之间的偏差程度。同时本文将收集到的遥测数据集合按照 6:4 的比例分为训练集和验证集,用来评估本文模型与其他模型相比的预测准确性。最终确定了本文模型的最优超参数配置,这些参数选择如表 2 所示。

表 2 LSTM-Attention 参数选择

参数	数值
输入窗口大小	6
批量大小	240
训练次数	150
隐藏层数	3
隐藏层神经元数量	128
学习率	0.01

## 3.2 仿真结果

为了评估本文提出的 LSTM-Attention 模型的预测性能,本节选取 ARIMA、RNN (recurrent neural network)、GRU (gated recurrent unit) 和 LSTM 这 4 种经典模型作为对比模型。本节选用表 2 中确定的超参数作为模型的参数设置。同时为了确保实验的准确性,RNN、GRU 和 LSTM 也将使用相同的参数设置。而对于 ARIMA 模型则是使用网格搜索方法自动选择最优的参数组合,最终确定 ARIMA(2,1,2) 作为最佳模型配置,以确保 ARIMA 模型能够达到最佳预测性能。不同预测模型的性能评估结果如表 3 所示。结果显示,与 ARIMA、RNN、GRU 和 LSTM 模型相比,LSTM-Attention 模型的 MAE 指标分别低 73.2%、41.3%、24.2% 和 18.3%, RMSE 指标分别低了 70.6%、38.2%、22.4% 和 17.2%。

表 3 不同预测模型的性能评估结果

模型	MAE	RMSE
ARIMA	0.068 53	0.087 42
RNN	0.031 28	0.041 63
GRU	0.024 21	0.033 15
LSTM	0.022 47	0.031 06
LSTM-Attention	0.018 36	0.025 71

图 5 和图 6 分别展示了对比模型以及本文模型对链路 16 的链路带宽利用率预测值与真实值对比。从图 5(a) 可以看到, ARIMA 模型在数据点 100~150 尖锐波动中, ARIMA 模型的预测曲线明显高于真实值,无法捕捉到这些突变特征。这是因为遥测数据之间包含复杂的时间依赖关系,而 ARIMA 是一种线性统计模型,主要基于历史数据的自回归和移动平均特性进行预测,无法有效捕获非线性的复杂模

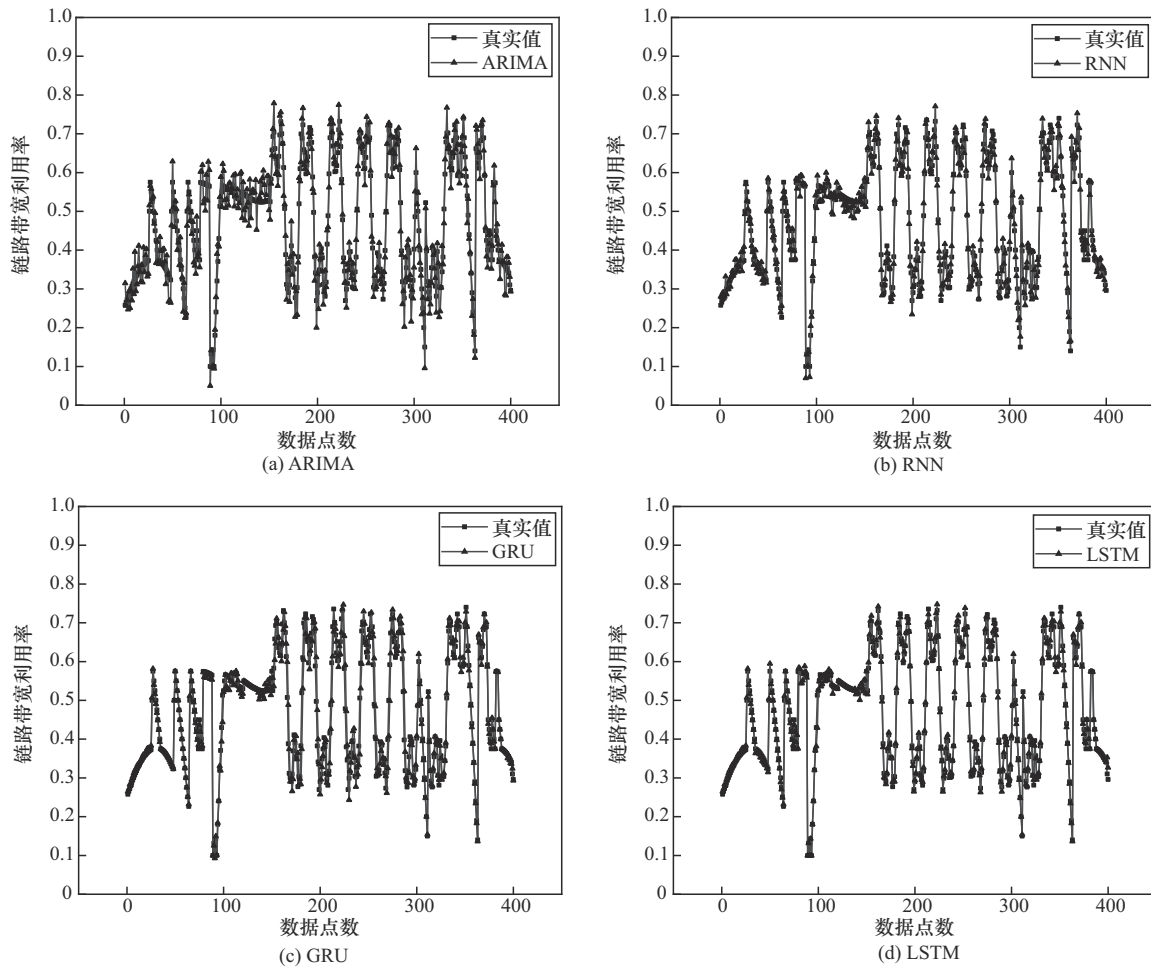


图5 不同模型链路带宽利用率预测结果

式，特别是在网络流量突变时刻。图5(b)~图5(d)分别展示了RNN、GRU和LSTM模型对链路16的链路带宽利用率预测结果。这3种模型相比ARIMA模型在捕捉波动变化上有显著改善，特别是在数据点200~250的高频波动中，预测曲线能更好地跟随真实值的变化趋势。但是，这些模型在连续的尖锐波峰波谷处仍然存在不同程度的预测偏差。尤其是在数据点230、280和350附近的极值处。这是因为RNN、GRU和LSTM模型虽然设计了不同的门控结构来保留历史信息，但它们都依赖于时序的单向传递，每个时间步的输出都受限于前一时间步传递过来的状态信息。在这个过程中，早期的关键特征会随着序列长度的增加而逐渐衰减。虽然LSTM模型通过设计记忆单元试图解决长期依赖问题，但在实际的遥测数据处理中，当需要参考更早时刻遥测数据信息时，这种单向传递机制还是无法有效地保持远距离的信息关联。




图6 LSTM-Attention模型链路带宽利用率预测结果

相比之下，图6展示的LSTM-Attention模型表现出更好的性能。通过注意力机制，本文模型能够在整个历史序列中建立关联，不受时间步距离的限制。

图7和图8分别展示了对比模型以及本文模

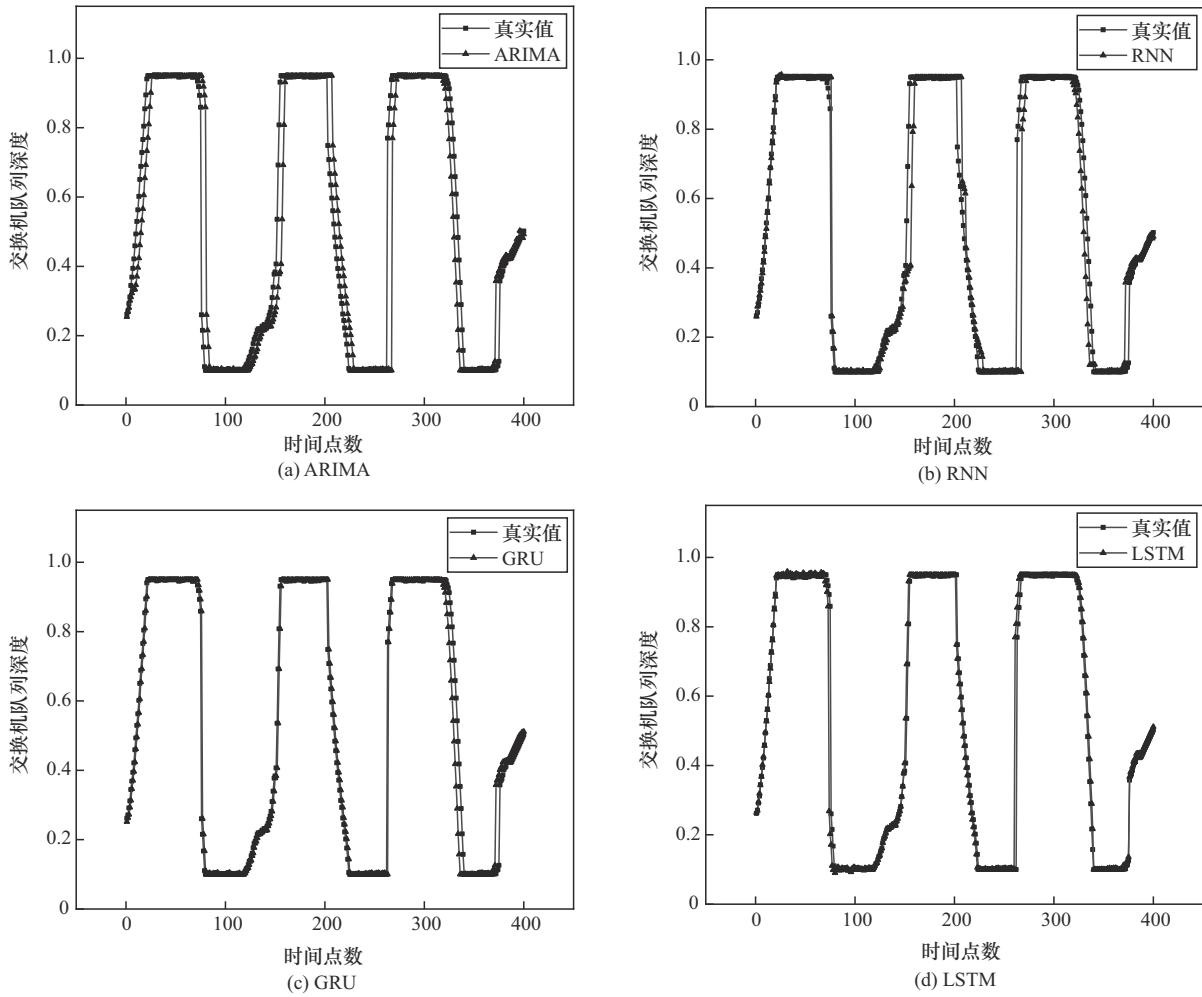


图7 不同模型交换机队列深度预测结果

型对节点4的交换机队列深度预测值与真实值对比。可以看出,节点4的交换机队列深度在不同时刻出现了突变,这是因为本文为了造成链路拥塞情况会随机在节点4和节点8注入大流量。与其他4种对比模型相比,本文模型的预测值与真实值几乎完全重合。这是因为传统模型在处理复杂遥测数据动态变化时往往存在滞后和不准确的问题。引入注意力机制后,LSTM模型能更好地聚焦遥测数据中的关键信息,动态调整不同时间步的权重。

图9和图10分别展示了对比模型以及本文模型对链路16的链路时延预测值与真实值对比。可以看出,图9和图10链路时延的变化趋势和图5和图6中的链路利用率的变化趋势大体一致,这是因为链路利用率的增加会导致链路时延的增加。同时,可以看到本文模型的预测值相较于其他4种对比模型,更接近真实值。




图8 LSTM-Attention模型交换机队列深度预测结果

图11验证了控制模块的拥塞避免功能,源节点1到目的节点7的业务流(2001:db8:dead::1-2007:db8:dead:4)通过最短路径优先算法计算出其路径为1—3—7。当分析模块监测到节点3至节点7

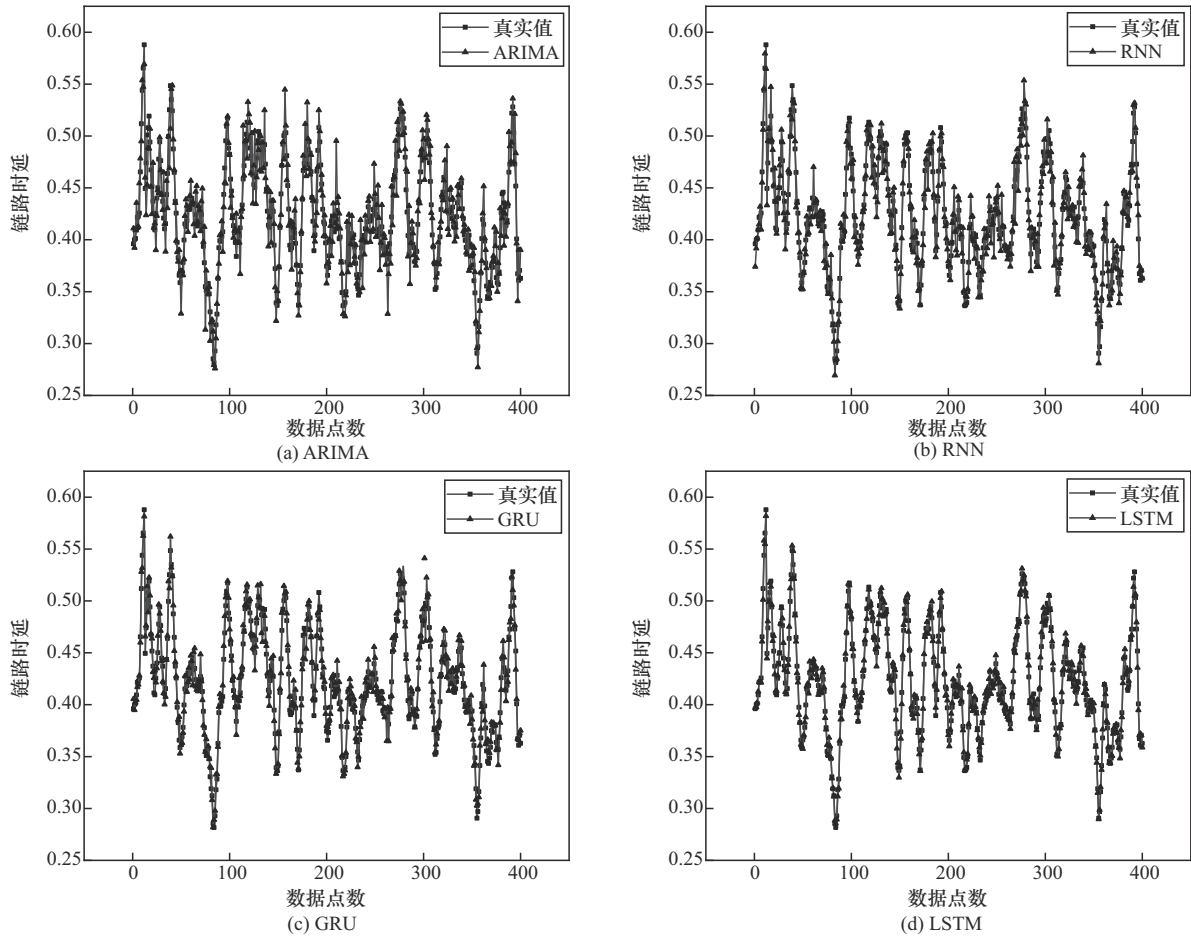


图9 不同模型链路时延预测结果

(链路8)可能存在拥塞时,控制器使用SRv6技术重新规划业务流的传输路径。图11为规划路径后的业务流信息,同样是从节点1到节点7,此时数据包为SRv6数据包,其路径为1—4—3—2—7。路径调整不仅避开了潜在的拥塞链路,还确保了数据传输的高效性和可靠性。




图10 LSTM-Attention模型链路时延预测结果



图11 拥塞避免功能验证

## 4 结束语

本文提出了一种网络控制自动化系统,旨在实现网络的智能化管理。该系统由 3 个关键模块组成:监控模块、分析模块和控制模块。监控模块利用本文所提算法进行遥测数据采集。分析模块部分则是将 LSTM 网络和 Attention 机制相结合对遥测数据进行分析预测。控制模块根据预测结果以及应用层需求利用 SRv6 技术规划业务流的路径,从而实现减轻链路和交换机负载的功能。同时为减轻控制平面压力,本文在数据平面开发了数据处理器,将部分数据处理功能卸载到数据平面。通过差值过滤和缺失值填补,实现了对遥测数据的预处理。在仿真实验中,相较于 ARIMA、RNN、GRU 和传统 LSTM 等基准模型,本文模型的 MAE 指标最高降低了 73.2%, RMSE 指标最高降低了 70.6%。最后验证了控制模块中拥塞避免的功能。

### 参考文献:

- [1] WEN X Y, LI W B. Time series prediction based on LSTM-attention-LSTM model[J]. *IEEE Access*, 2023, 11: 48322-48331.
- [2] WU J, QIU T F, TANG H, et al. Network traffic prediction based on a CNN-LSTM with attention mechanism[C]//*Proceedings of the 2022 7th International Conference on Computational Intelligence and Applications (ICCIA)*. Piscataway: IEEE Press, 2022: 205-209.
- [3] WANG Z H, JIANG D D, MUMTAZ S. Network-wide data collection based on in-band network telemetry for digital twin networks[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(1): 86-101.
- [4] KARAAGAC A, POORTER E D, HOEBEKE J. In-band network telemetry in industrial wireless sensor networks[J]. *IEEE Transactions on Network and Service Management*, 2020, 17(1): 517-531.
- [5] CASTRO A G, LORENZON A F, ROSSI F D, et al. Near-optimal probing planning for in-band network telemetry[J]. *IEEE Communications Letters*, 2021, 25(5): 1630-1634.
- [6] PAN T, LIN X C, SONG H Y, et al. INT-probe: lightweight in-band network-wide telemetry with stationary probes[C]//*Proceedings of the 2021 IEEE 41st International Conference on Distributed Computing Systems (ICDCS)*. Piscataway: IEEE Press, 2021: 898-909.
- [7] JI M T, SU C W, YAN Y T, et al. INTView: adaptive planner for in-band network telemetry without detours[C]//*Proceedings of the ICC 2023-IEEE International Conference on Communications*. Piscataway: IEEE Press, 2023: 5490-5495.
- [8] LI F L, YUAN Q C, PAN T, et al. MTU-adaptive in-band network-wide telemetry[J]. *IEEE/ACM Transactions on Networking*, 2024, 32(3): 2315-2330.
- [9] LIU W, ZHANG X, FENG C, et al. Segment routing based in-band network telemetry in IPv6 over optical networks[C]//*Proceedings of the 2024 2nd International Conference on Mobile Internet, Cloud Computing and Information Security (MICCIS)*. Piscataway: IEEE Press, 2024: 125-129.
- [10] ZHANG Y, PAN T, ZHENG Y, et al. Automating rapid network anomaly detection with in-band network telemetry[J]. *IEEE Networking Letters*, 2022, 4(1): 39-42.
- [11] TAN L Z, SU W, ZHANG W, et al. A packet loss monitoring system for in-band network telemetry: detection, localization, diagnosis and recovery[J]. *IEEE Transactions on Network and Service Management*, 2021, 18(4): 4151-4168.
- [12] XU Z C, TANG S F, ZHU Z Q. Entropy-driven adaptive INT and its applications in network automation of IP-over-EONs[J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2022, 28(4): 3700313.
- [13] NAM S, LIM J, YOO J H, et al. Network anomaly detection based on in-band network telemetry with RNN[C]//*Proceedings of the 2020 IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia)*. Piscataway: IEEE Press, 2020: 1-4.
- [14] SAHIN H, BEZERRA J, BRITO I, et al. Leveraging in-band network telemetry for automated DDoS detection in production programmable networks: the AmLight use case[C]//*Proceedings of the SC24-W: Workshops of the International Conference for High Performance Computing, Networking, Storage and Analysis*. Piscataway: IEEE Press, 2024: 793-802.
- [15] CAO Y Y, JIANG H, DENG Y C, et al. Detecting and mitigating DDoS attacks in SDN using spatial-temporal graph convolutional network[J]. *IEEE Transactions on Dependable and Secure Computing*, 2022, 19(6): 3855-3872.
- [16] YAO H P, MAI T L, XU X B, et al. NetworkAI: an intelligent network architecture for self-learning control strategies in software defined networks[J]. *IEEE Internet of Things Journal*, 2018, 5(6): 4319-4327.
- [17] 唐绍飞. 基于带内遥测的自适应网络监控技术研究[D]. 安徽: 中国科学技术大学, 2022.  
TANG S F. Research on adaptive network monitoring technology based on in-band telemetry[D]. Anhui: University of Science and Technology of China, 2022.
- [18] SONG E G, PAN T, JIA C H, et al. INT-filter: mitigating data collection overhead for high-resolution in-band network telemetry[C]//*Proceedings of the GLOBECOM 2020-2020 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2020: 1-6.
- [19] LI F, NIE W, LAM K Y, et al. Network traffic prediction using PSO-lightGBM-TM[C]//*Proceedings of the IEEE INFOCOM 2024-IEEE Conference on Computer Communications Workshops (INFOCOM WKSHPs)*. Piscataway: IEEE Press, 2024: 1-6.

[作者简介]



张旭 (1992-), 男, 辽宁沈阳人, 博士, 重庆邮电大学副教授、博士生导师, 主要研究方向为软件定义网络、光网络、算力网络。



文婷 (2002-), 女, 湖南益阳人, 重庆邮电大学硕士生, 主要研究方向为软件定义网络。



赵晨熙 (2001-), 男, 山西运城人, 重庆邮电大学硕士生, 主要研究方向为软件定义网络、弹性光网络。



刘炜 (2001-), 男, 江西上饶人, 重庆邮电大学硕士生, 主要研究方向为软件定义网络、算力网络。



冯川 (1991-), 女, 辽宁辽阳人, 博士, 重庆邮电大学讲师, 主要研究方向为软件定义网络、算力网络、任务卸载。



郭磊 (1980-), 男, 四川眉山人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为光网络、无线通信网络。