

## 基于自适应时空网络的 SDN 流量预测模型

刘月<sup>1</sup>,张慧<sup>2</sup>,蔡安亮<sup>1</sup>,沈建华<sup>1\*</sup>

(1.南京邮电大学 通信与信息工程学院,南京 210003;2.深圳赛柏特通信技术有限公司,广东 深圳 518000)

**摘要:**为了提高软件定义网络(SDN)流量预测的准确率,提出了一种基于自适应时空网络的 SDN 流量预测模型。该模型通过采用自适应图卷积神经网络来捕捉 SDN 流量的空间相关性,利用门控循环单元来捕捉时间上的变化趋势,并针对 SDN 流量的高度动态特性引入了自回归模块。实验结果表明,所提出的 SDN 流量预测方法相比现有的基线模型能够识别出更多的流量特征,同时表现出更优的预测性能。

**关键词:**软件定义网络;流量预测;自适应图卷积网络;门控循环;时空相关性

**中图分类号:**TN91 **文献标志码:**A **文章编号:**1002-5561(2024)06-0034-06

**DOI:**10.13921/j.cnki.issn1002-5561.2024.06.007

开放科学(资源服务)标识码(OSID):



## SDN traffic prediction model based on adaptive spatiotemporal network

LIU Yue<sup>1</sup>, ZHANG Hui<sup>2</sup>, CAI Anliang<sup>1</sup>, SHEN Jianhua<sup>1</sup>

(1. School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. CypressTel SHENZHEN Communication Technology Company, Shenzhen Guangdong 518000, China)

**Abstract:** To improve the accuracy of software defined networking (SDN) traffic prediction, an SDN traffic prediction model based on an adaptive spatiotemporal network is proposed. This model captures the spatial correlation of SDN traffic by using an adaptive graph convolutional neural network, captures temporal variation trends through gated recurrent units, and introduces an autoregressive module in response to the highly dynamic nature of SDN traffic. The experimental results show that the proposed SDN traffic prediction method can identify more traffic features compared to existing baseline models and demonstrates superior prediction performance.

**Key words:** software defined network, traffic prediction, adaptive graph convolutional network, gated recurrent, spatiotemporal correlation

## 0 引言

网络流量预测在网络管理中至关重要,旨在通过对历史数据的分析预测未来流量模式,帮助优化资源分配并及时发现异常,从而提升网络性能<sup>[1]</sup>。流量矩阵(TM)作为描述网络流量信息的主要方式,记录了一定时间内所有节点间流量<sup>[2]</sup>。但在传统网络架构中,TM 预

测面临诸多挑战,如设备只能获取局部信息、流量信息基于估算而非直接测量导致的不准确等<sup>[3]</sup>。

软件定义网络(SDN)架构通过分离控制平面与数据平面,实现了网络的集中控制和直接编程,克服了上述问题。SDN 允许高效收集包括节点间通信模式和流量负载在内的详细流量信息,提高了 TM 预测的准确性。

TM 预测方法大致分为线性和非线性两类。常用的线性方法如差分自回归移动平均模型(ARIMA)<sup>[4]</sup>和向量自回归模型(VAR)<sup>[5]</sup>在处理网络流量时效果不佳,因为网络流量的时间序列变化具有明显的非线性特征。为此,研究者开发了更高精度的非线性模型,比如支持向量回归(SVR)、深度信念网络(DBN)、循环神经网络(RNN)及其变体长短期记忆网络(LSTM)和门控循环单元(GRU)等<sup>[6-13]</sup>,但这些模型往往只考虑时间相

收稿日期:2024-01-19。

基金项目:国家自然科学基金项目(批准号:62301284)资助。

作者简介:刘月(1999—),女,江苏扬州人,硕士研究生,现就读于南京邮电大学通信与信息工程学院电子信息专业。主要研究方向是将深度学习技术运用于软件定义网络的流量预测,参与了南京邮电大学横向科研课题“新一代智能 SD-WAN 体系架构及其关键技术”研发。



\* 通信作者:沈建华(1972—),男,工学博士,教授,主要研究方向为高速率大容量光纤通信系统、智能光网络等。

关性,忽略了网络流量受拓扑结构影响的特点。因此,有研究将卷积神经网络应用于图结构数据,利用图卷积网络(GCN)捕捉空间相关性,并将其与GRU结合,以增强TM预测能力<sup>[14-19]</sup>。不过,这种方法需要预定义邻接图来反映空间关系,而在SDN中,由于拓扑结构复杂且流量高度动态,这种方法可能不够准确<sup>[20]</sup>。

鉴于此,本文提出一种基于自适应时空网络(ASTNet)的SDN流量预测模型(下文简称ASTNet模型)。该模型基于自适应图卷积网络学习TM中潜在的空间相关性,并结合GRU来学习时间相关性。两者整合成自适应图卷积循环神经网络(AGCRNN),并在流量剧烈变化时引入自回归(AR)模块,以提高局部突发性流量的预测精度。

## 1 ASTNet模型及工作原理

### 1.1 问题描述

SDN中的交换机、路由器等设备,以及它们之间的连接关系可以被视为一个图结构,其中节点表示网络设备,边表示设备之间的连接,因此SDN拓扑图 $G=(V, E)$ ,  $V$ 表示拓扑中的节点集合,  $V=\{v_1, v_2, \dots, v_N\}$ ,  $N$ 表示拓扑中的节点数,  $E$ 表示拓扑中的链路集合;  $A$ 表示拓扑图 $G$ 的邻接矩阵,  $A \in R^{N \times N}$ ,  $R$ 表示实数集,其中 $A_{v_i, v_j}$ 表示节点 $v_i$ 和 $v_j$ 是否存在连接关系,  $A_{v_i, v_j} \in \{0, 1\}$ , 值为0表示不存在连接, 值为1表示存在连接; 将SDN中的流量矩阵 $X$ 作为节点的特征,  $X_t$ 表示时刻 $t$ 节点的流量矩阵,  $X_t \in R^{N \times N}$ 。

基于拓扑图 $G$ 和 $n$ 个历史时刻的流量矩阵 $X$ , SDN流量预测问题可以理解学习一个函数 $f$ 以预测未来 $T$ 个时刻的流量矩阵,表达式如下:

$$[X_{t+1}, \dots, X_{t+T}] = f[G, (X_{t-n}, \dots, X_{t-1}, X_t)] \quad (1)$$

### 1.2 数据预处理

数据集在用于模型训练之前需要进行预处理,包括数据归一化、数据集分割和样本生成。

1)数据归一化。由于流量数据的数量级差异较大,为了使数据特征具有相同的度量尺度,本文首先对流量数据取对数,然后除以数据中的最大值来进行归一化处理。

2)数据集分割。将数据集按照一定比例划分为训练集、验证集和测试集。

3)样本生成。通过滑动窗口的方法来生成预测模型的样本。每个样本由两部分组成:第一部分为输入

的 $n$ 个流量序列,第二部分为未来 $T$ 个流量矩阵作为预测的真实值。流量数据记为一个时间序列 $(X_1, X_2, \dots, X_s)$ ,其中 $s$ 是整个采样周期内的最大时隙。从流量序列的起始位置开始,按照设定的窗口大小,在时间序列上滑动窗口。每次滑动窗口时,取出窗口内 $n+T$ 个数据作为一个样本。

### 1.3 模型设计

ASTNet模型包含2个模块:AGCRNN模块和AR模块。ASTNet模型框架如图1所示。通过引入AGCRNN模块来学习流量数据中的时空非线性特征,并利用AR模块来捕捉流量数据中的线性特征,最终将这两部分特征融合,以生成更准确的预测结果。其中,AGCRNN模块进一步细分为自适应图卷积模块和GRU模块,前者用于捕捉流量数据的空间相关性,后者则专注于时间相关性的提取。




图1 ASTNet模型架构

#### 1.3.1 自适应图卷积模块

SDN可以通过图结构表示,因此可以利用GCN来捕捉SDN流量数据的空间相关性。为了处理图结构的数据,GCN采用了一种基于谱方法的卷积定理。该定理通过将傅里叶变换应用于图信号,实现信号从节点域到傅里叶域的映射,并在傅里叶域中定义图卷积运算。在GCN中,每一次卷积操作都会计算节点及其相邻节点特征的加权平均值,并将结果作为该节点的新表示。一层图卷积模型示意图如图2所示,其中橙色节点表示待卷积操作的节点,绿色节点表示与之相邻的节点,蓝色节点表示与之不相邻的节点。这种节点更新过程通过图的邻接矩阵来实现。通过聚合邻居信息,模型能够更好地理解目标节点与其周围节点之间的关联关系,从而提取出更丰富的特征表示。一个基于分层传播规则的 $l$ 层GCN,其层与层之间的传播方式可以表示为




图2 一层图卷积模型示意图

$$X^{(t+1)} = h \left[ \hat{D}^{-\frac{1}{2}} (A + I_N) \hat{D}^{-\frac{1}{2}} X^{(t)} W^{(l)} \right] \quad (2)$$

其中,  $\hat{A} = A + I_N$ ,  $I_N$  是一个  $N$  维的单位矩阵,  $\hat{D}$  为度矩阵,  $\hat{D}_{ii} = \sum_j \hat{A}_{ij}$ ;  $W^{(l)}$  是  $l$  层的权重矩阵;  $h(\cdot)$  表示非线性激活函数, 如 ReLU 函数。

考虑到 SDN 中的拓扑结构通常是动态变化的, 尤其是在面对设备连接和拓扑结构调整时, 预先定义的邻接矩阵可能无法适应这种动态性。此外, 预定义的邻接矩阵需要基于先验知识来确定节点间的连接关系, 而简单的邻接关系往往难以准确描述 SDN 中节点之间复杂的交互模式。相比之下, 自适应邻接矩阵能够在模型学习过程中自动调整节点间的权重, 从而更好地应对 SDN 的动态特性和复杂性。因此, 本文采用自适应邻接矩阵  $\hat{A}_a$  来增强对空间相关性的表示能力。首先, 随机初始化 2 个分别表示源节点和目标节点的嵌入矩阵  $E_1, E_2$ , 且  $E_1, E_2 \in R^{N_{se} \times e}$ ,  $e$  是嵌入表示的维度, 然后将  $E_1$  和  $E_2^T$  相乘得到源节点和目标节点之间的空间依赖权值, 自适应邻接矩阵  $\hat{A}_a$  表示为

$$\hat{A}_a = \text{SoftMax} \left[ \text{ReLU} (E_1 E_2^T) \right] \quad (3)$$

其中, ReLU 激活函数用来限制较小的权重, SoftMax 函数用来进行归一化操作。在训练过程中, 节点嵌入矩阵的参数通过梯度下降进行更新。通过  $E_1$  和  $E_2^T$  的迭代

训练代替经过定义和计算的  $\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}}$ , 则自适应图卷积模块的输出可表示为

$$X^{(t+1)} = h \left[ \text{SoftMax} \left[ \text{ReLU} (E_1 E_2^T) \right] X^{(t)} W^{(l)} \right] \quad (4)$$

### 1.3.2 GRU 模块

网络流量不仅受网络拓扑结构的影响, 还受到时间动态变化的影响。LSTM 和 GRU 广泛应用于时间序

列数据的处理中, 两者都使用门控机制来保留序列中的重要信息。然而, 与 LSTM 内部包含 3 个门(输入门、遗忘门和输出门)不同, GRU 仅包含 2 个门: 重置门和更新门。因此, GRU 的结构更为精简, 参数量更少, 训练速度更快。基于这些优点, 本文选择 GRU 模型来捕捉流量数据的时间相关性。GRU 结构图如图 3 所示。




图3 GRU 结构图

GRU 原理如下: 时刻  $t$  的流量矩阵  $X_t$  经一层自适应图卷积模块得到的输出  $X'_t$  作为 GRU 模块的输入, 与  $t-1$  时刻的隐藏层  $h_{t-1}$  结合, 经过计算得到时刻  $t$  的隐藏层输出  $h_t$ 。

相关参数定义如式(5)所示。

$$\begin{cases} u_t = \sigma(W_u [X'_t, h_{t-1}] + b_u) \\ r_t = \sigma(W_r [X'_t, h_{t-1}] + b_r) \\ c_t = \tanh(W_c [X'_t, (r_t h_{t-1})] + b_c) \\ h_t = u_t h_{t-1} + (1 - u_t) c_t \end{cases} \quad (5)$$

其中,  $u_t$  是更新门, 用来确定前一时刻的流量信息影响当前时刻的流量信息的程度, 值越小说明前一时刻的流量信息对当前时刻的流量信息的影响越小;  $r_t$  是重置门, 用来确定前一时刻的网络流量信息被忽略的程度, 值越小说明前一时刻网络流量信息被忽略得越多;  $c_t$  用来存储当前时刻  $t$  的流量信息,  $W$  和  $b$  表示训练过程中的权重和偏差,  $\sigma$  表示激活函数。

### 1.3.3 AR 模块

由于其高度动态性, SDN 流量数据中存在局部极值变化的情况。为提高预测精度, 本文引入 AR 模块来捕获 SDN 流量中的线性特征, 并采用经典的 AR 模型对线性部分进行预测。线性模块的预测结果可表示为

$$\hat{Y}_t = \sum_{i=1}^q W_i^L X_{t-i}^L + b_L \quad (6)$$

其中,  $q$  为 AR 阶数,  $W_i^L$  和  $b_L$  为 AR 模型的参数。将

AGCRNN 得到的预测结果记为  $\hat{Y}_t^N$ , 最终的预测结果由非线性部分和线性部分构成, 如式(7)所示。

$$\hat{Y}_t = a_t^N \hat{Y}_t^N + a_t^L \hat{Y}_t^L \quad (7)$$

其中,  $a_t^N$  和  $a_t^L$  表示需要学习的权重,  $Y_t$  为真实值,  $\hat{Y}_t$  表示预测值。

### 1.3.4 损失函数

损失函数是优化算法的核心, 用于计算每次迭代的误差, 指导模型参数的更新, 使模型的预测尽量接近实际值, 同时能判断模型是否收敛。为防止过拟合, 本文在模型中加入 L2 正则化项, 即在损失函数中添加模型参数的平方和作为正则化项。损失函数公式如下:

$$J = |Y_t - \hat{Y}_t| + \lambda \sum_{i=1}^k W_i^2 \quad (8)$$

其中,  $\lambda$  为 L2 正则化项系数,  $k$  为模型中所有权重参数的数量。

## 2 实验设计与验证

### 2.1 数据集描述

为了验证 ASTNet 模型的有效性, 本文实验采用真实网络 GEANT 数据集<sup>[21]</sup>。GEANT 网络拓扑由 23 个对端节点和 38 条链路组成, 其网络拓扑如图 4 所示。完整的数据集统计了 4 个月内的流量数据, 采样间隔为 15 min, 共得到 10 773 个样本。




图 4 GEANT 网络的拓扑结构

### 2.2 评价指标

模型评价指标是用来度量模型性能的工具。在本次实验中, 本文采用了均方根误差(RMSE)、平均绝对误差(MAE)和平均绝对百分比误差(MAPE)这 3 种评价指标来评估真实流量与预测流量之间的差异, 其表达式分别如式(9)、式(10)、式(11)所示。这 3 个指标的数值越小, 表示预测效果越好。

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

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

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i} \times 100\% \quad (11)$$

### 2.3 基线模型

本文选取 4 种基线模型(ARIMA、SVR、GRU、图卷积和门控循环单元的模型(GCGRU))与 ASTNet 模型进行性能对比。

### 2.4 超参数设置

在本实验中, 数据集按照 6:2:2 的比例被划分为训练集、验证集和测试集。模型输入的历史时间步为 5, 用于预测未来 1、2、3 个时间步的网络流量。实验设置的学习率为 0.001, 训练轮数(epoch)为 300, 批次大小(batch size)为 64, L2 正则化项系数  $\lambda$  设为 0.5, 优化器采用 Adam 算法, RNN 单元的隐藏状态维度设置为 64。为了防止过拟合并提高模型的泛化能力, 本文设置了早停策略, 即当验证损失在连续 20 个 epoch 内没有改善时停止训练。所有基线模型均遵循其文献中所报告的最佳参数配置。


## 3 实验结果与分析

本文提出的 ASTNet 模型与不同基线模型在  $T$  为 1、2、3 个时间步上的预测性能对比如表 1 所示。可以看出, ASTNet 模型的综合误差最低, 获得了最佳的预测效果, 证明了 ASTNet 模型在网络流量预测方面具有优越的能力。相比之下, ARIMA 模型的表现最不理想, 这主要是因为 ARIMA 模型本质上只能捕捉线性特征, 而 SDN 流量则表现出较强的非线性特性。SVR 这种传统的机器学习方法也表现一般, 其原因在于 SVR 的性能高度依赖于手动调整的超参数及预定义的特征集。GRU 模型能够自适应地学习时间序列中的长短期依赖关系, 从而显著提高了预测精度, 但该模型仅考虑了时间特征, 忽略了空间特征的影响。与此相对, GCGRU 模型同时考虑了时间特征和空间特征, 因此相较于其它基线模型展现出了更优的预测性能。


本文将表 1 中 GRU、GCGRU 和 ASTNet 这 3 种模型的预测性能进行了可视化处理, 结果如图 5 所示。以 RMSE 指标为例, 相较于 GRU 模型, ASTNet 模型的 RMSE 在 3 个时间步上分别减少了 18.87%、17.58% 和 16.27%, 这表明 ASTNet 模型能够更有效地提取时

表 1 GEANT 数据集上各模型预测性能对比


| 模型     | RMSE     |          |          | MAE      |          |          | MAPE     |          |          |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
|        | $T=1$    | $T=2$    | $T=3$    | $T=1$    | $T=2$    | $T=3$    | $T=1$    | $T=2$    | $T=3$    |
| ARIMA  | 0.328 11 | 0.328 12 | 0.328 19 | 0.238 35 | 0.238 35 | 0.238 37 | 11.743 5 | 11.749 2 | 11.756 8 |
| SVR    | 0.092 35 | 0.092 44 | 0.092 48 | 0.074 81 | 0.074 92 | 0.075 21 | 9.812 2  | 9.883 4  | 10.024 5 |
| GRU    | 0.020 19 | 0.021 61 | 0.023 79 | 0.015 02 | 0.016 81 | 0.018 34 | 1.889 3  | 2.017 8  | 2.259 9  |
| GCGRU  | 0.017 94 | 0.019 32 | 0.021 46 | 0.012 47 | 0.014 43 | 0.016 25 | 1.546 1  | 1.728 8  | 2.013 4  |
| ASTNet | 0.016 38 | 0.017 81 | 0.019 92 | 0.011 02 | 0.013 21 | 0.015 06 | 1.361 9  | 1.582 9  | 1.896 1  |



(a) RMSE 指标对比



(b) MAE 指标对比




(c) MAPE 指标对比


图 5 不同模型在性能指标上的对比

间特征。此外,与GCGRU模型相比,ASTNet模型的RMSE在3个时间步长上分别减少了8.7%、7.82%和7.18%,这说明ASTNet模型在提取网络流量数据的空间特征方面比GCGRU模型更为有效,从而提高了预测精度。


为了更直观地比较ASTNet模型与GRU模型、GCGRU模型在预测性能上的差异,本文从数据集GEANT中截取了400个时间步的流量序列数据进行可视化分析。预测结果如图6所示。可以看出,在遭遇突发流量时,虽然GRU模型和GCGRU模型能够大致预测到流量的突增,但它们在预测流量的具体幅度上存在较大的误差。相比之下,ASTNet模型的表现则更为出色,它在整个预测周期内均展现出了更好的拟合效果,特别是在捕捉流量变化的细节上更为准确。



(a) GRU 预测结果



(b) GCGRU 预测结果



(c) ASTNet 预测结果

图 6  $T=1$  时,不同模型预测结果对比

## 4 结束语

本文针对 SDN 流量预测问题,提出了一种基于 ASTNet 的 SDN 流量预测模型。该模型在实现自适应空间特征提取和预测突发流量方面具有良好的效果。将该模型应用于公开数据集 GEANT 上,并与传统经典模型进行了比较。实验结果表明:相比其它模型,ASTNet 模型在整体流量和局部突发流量的预测准确度均有所提高。在未来的工作中,本文将尝试引入与 SDN 流量相关的其它特征,比如链路带宽、抖动、时延等,也可以尝试结合自注意力机制等方法进一步提高模型的预测性能。

## 参考文献:

- [1] VINAYAKUMAR R, SOMAN K P, POORNACHANDRAN P. Applying deep learning approaches for network traffic prediction[C]//IEEE. Proceedings of 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI). Manipal: IEEE, 2017: 2353–2358.
- [2] TUNE P, ROUGHAN M, HADDADI H, et al. Internet traffic matrices: A primer[J]. Recent Advances in Networking, 2013, 1: 1–56.
- [3] KREUTZ D, RAMOS F M V, VERISSIMO P E, et al. Software-defined networking: a comprehensive survey[J]. Proceedings of the IEEE, 2014, 103(1): 14–76.
- [4] MOAYEDI H Z, MASNADI-SHIRAZI M A. Arima model for network traffic prediction and anomaly detection[C]//IEEE. Proceedings of 2008 international symposium on information technology. Kuala Lumpur: IEEE, 2008, 4: 1–6.
- [5] STOCK J H, WATSON M W. Vector autoregressions[J]. Journal of Economic perspectives, 2001, 15(4): 101–115.
- [6] BERMOLLEN P, ROSSI D. Support vector regression for link load prediction[J]. Computer Networks, 2009, 53(2): 191–201.
- [7] NIE L, JIANG D, GUO L, et al. Traffic matrix prediction and estimation

刘月,张慧,蔡安亮,等:基于自适应时空网络的 SDN 流量预测模型

- based on deep learning for data center networks[C]//IEEE. Proceedings of 2016 IEEE Globecom Workshops (GC Wkshps). Washington: IEEE, 2016: 1–6.
- [8] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization[EB/OL]. (2014–09–08) [2024–01–19]. <https://www.semanticscholar.org/paper/Recurrent-Neural-Network-Regularization-Zaremba-Sutskever/f264e8b33c0d49a692a6ce2c4bcb28588aeb7d97>.
  - [9] GRAVES A. Supervised sequence labelling with recurrent neural networks. studies in computational intelligence[M]. Berlin: Springer, 2012.
  - [10] AZZOUNI A, PUJOLLE G. NeuTM: a neural network-based framework for traffic matrix prediction in SDN[C]//IEEE. Proceedings of NOMS 2018-2018 IEEE/IFIP Network Operations and Management Symposium. Taipei: IEEE, 2018: 1–5.
  - [11] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014–12–11) [2024–01–19]. <https://arxiv.org/abs/1412.3555>.
  - [12] LE D H, TRAN H A, SOUHI S, et al. An ai-based traffic matrix prediction solution for software-defined network[C]//IEEE. Proceedings of ICC 2021-IEEE International Conference on Communications. Virtual/Montreal: IEEE, 2021: 1–6.
  - [13] RAMAKRISHNAN N, SONI T. Network traffic prediction using recurrent neural networks[C]//IEEE. Proceedings of 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). Orlando: IEEE, 2018: 187–193.
  - [14] KIPF T N, WELLMING M. Semi-supervised classification with graph convolutional networks[EB/OL]. [2024–01–19]. [https://xueshu.baidu.com/usercenter/paper/show?paperid=4bbac8399145c63d7eb85f702ad5f11&site=xueshu\\_se](https://xueshu.baidu.com/usercenter/paper/show?paperid=4bbac8399145c63d7eb85f702ad5f11&site=xueshu_se).
  - [15] WU Z, PAN S, CHEN F, et al. A comprehensive survey on graph neural networks[J]. IEEE transactions on neural networks and learning systems, 2020, 32(1): 4–24.
  - [16] 宋元隆,吕光宏,王桂芝,等.基于图卷积神经网络的 SDN 网络流量预测[J]. 计算机科学, 2021, 48(6A): 392–397.
  - [17] ZHAO L, SONG Y, ZHANG C, et al. T-gcn: a temporal graph convolutional network for traffic prediction[J]. IEEE transactions on intelligent transportation systems, 2019, 21(9): 3848–3858.
  - [18] ZHU J, WANG Q, TAO C, et al. AST-GCN: attribute-augmented spatiotemporal graph convolutional network for traffic forecasting[J]. IEEE Access, 2021, 9: 35973–35983.
  - [19] GUI Y, WANG D, GUAN L, et al. Optical network traffic prediction based on graph convolutional neural networks[C]//IEEE. Proceedings of 2020 Opto-Electronics and Communications Conference (OECC). Taipei: IEEE, 2020: 1–3.
  - [20] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks[C]//ACM. Proceedings of The 41st international ACM SIGIR conference on research & development in information retrieval. Ann Arbor: ACM, 2018: 95–104.
  - [21] UHLIG S, QUOTIN B, LEPROPRE J, et al. Providing public intradomain traffic matrices to the research community[J]. ACM SIGCOMM Computer Communication Review, 2006, 36(1): 83–86.