

# 基于多时间粒度时空图网络的蜂窝网络流量预测

张德杨<sup>1</sup>, 任佳玺<sup>2</sup>

(1. 河南省科学技术情报中心, 河南 郑州 450003;

2. 郑州轻工业大学, 河南 郑州 450000)

**摘要:**蜂窝网络流量预测对于运营商提高网络服务质量、降低能耗、优化资源配置具有重要意义。针对当前蜂窝网络流量预测方法无法同时提取多时间粒度序列特征和空间特征的问题,提出一种基于多时间粒度时空图神经网络的蜂窝网络流量预测方法。该方法首先将基站历史数据建模为多个时间粒度的时序数据,并使用一维卷积网络提取每个序列的特征,然后使用图注意力网络对多时间粒度的特征进行聚合得到单一基站的数据特征,最后将多个基站的特征进行空间聚合,并使用全连接层将每个基站聚合后的特征映射为预测结果。实验选择公开数据集 Telecom Italia 验证该方法的有效性,使用 RMSE 和  $R^2$  作为预测结果的评价指标,与当前已有方法相比该方法可取得最好的预测结果。论文最后分析了不同时间粒度序列对最终预测结果的影响,结果表明时间粒度位于 40 分钟至 1.5 小时之间的序列对提高模型预测效果的贡献最大。

**关键词:**流量预测;多时间粒度;图注意力网络;空间聚合;一维卷积网络

中图分类号:TP18;TN929.53

文献标识码:A

文章编号:1673-629X(2024)10-0024-07

doi:10.20165/j.cnki.ISSN1673-629X.2024.0191

## Cellular Network Traffic Prediction Based on Spatio-temporal Graph Network with Multiple Temporal Granularity

ZHANG De-yang<sup>1</sup>, REN Jia-xi<sup>2</sup>

(1. The Scientific & Technological Information Center of Henan, Zhengzhou 450003, China;

2. Zhengzhou University of Light Industry, Zhengzhou 450000, China)

**Abstract:** Cellular network traffic prediction is of great significance for operators to improve network service quality, reduce energy consumption, and optimize resource allocation. A cellular network traffic forecasting approach based on a multi-time granularity spatio-temporal graph neural network is proposed to address the problem that current cellular network traffic forecasting methods cannot extract multi-time granularity sequence features and spatial features effectively. The historical traffic data of the base station is modeled as time series of multiple time granularities, and the one-dimensional convolutional network is applied to extract the features of each sequence. Then the graph attention network is employed to aggregate the features of multi-time granularities to obtain the embedding of a single base station. Finally, the embeddings of multiple base stations are spatially aggregated, and the final prediction result for each base station is obtained via a fully connected network. The public dataset Telecom Italia is used to verify the effectiveness of the proposed method, and RMSE and  $R^2$  are used as evaluation indicators for the prediction results. The proposed method can achieve the best prediction results compared with the current existing methods. Finally we analyze the influence of different time granularity sequences on the final prediction results. The results show that sequences with time granularity between 40 minutes and 1.5 hours make the greatest contribution to improving the model prediction effect.

**Key words:** traffic prediction; multi-temporal granularity; graph attention network; spatial aggregation; 1D convolutional network

## 0 引言

蜂窝网络是当前社会的重要通信网络,它通过基站向覆盖范围内的终端用户提供呼叫、消息和数据服

务。随着通信技术的发展,蜂窝网络从 1970 年的第一代通信网络发展到今天的第五代通信网络,网络的通信能力有了大幅提升。伴随着网络通信能力的提升,

收稿日期:2024-02-29

修回日期:2024-07-02

基金项目:河南省重点研发与推广专项(212102210096)

作者简介:张德杨(1979-),男,硕士,高级工程师,通讯作者,研究方向为计算机科学与技术、网络数据分析、网络流量预测;任佳玺(1999-),女,硕士研究生,研究方向为图神经网络、网络流量预测。

基站对于硬件设施及能耗的需求也在不断增长。从通信技术上说,基站的功率提升可以提供更强的通信信号和数据处理能力,从而可以为更多用户提供高质量的通话和互联网服务,反之基站功率降低则可降低网络的服务质量,甚至出现网络拥塞。根据网络流量情况动态调整基站的发射功率,对于网络运营商降低运营成本具有重要意义<sup>[1]</sup>。但是,网络流量是一个动态变化的过程,根据实时检测到的网络流量调整基站功率往往具有滞后性,这种滞后性会导致严重的用户体验下降和资源浪费。因此,能够根据历史网络流量数据预测未来一段时间内的网络流量,并提前调整基站运营策略,对于提高网络服务质量、降低能耗、优化资源配置具有重要意义<sup>[2-3]</sup>。

目前,面向蜂窝网络的流量预测技术已经有多年的发展历史,但由于历史流量数据中存在复杂的时空关联模式,准确地预测网络流量仍面临非常大的挑战。在过去十几年中,蜂窝网络流量预测方法可分为统计方法、传统机器学习方法、深度学习方法三类。目前已有很多统计方法,其中,Xu 等人<sup>[4]</sup>提出的 ARIMA 是一种常用的时间序列分析方法,使用自回归分量、差分分量和移动平均分量的加权线性组合构建 ARIMA 模型,并使用贝叶斯准则提升网络流量预测效果。Clemente 等人<sup>[5]</sup>使用 Holt-Winters 指数平滑策略进行未来流量的预测。Perveen 等人<sup>[6]</sup>使用蒙特卡洛粒子滤波算法,通过估计观测变量的后验概率密度进行流量需求的预测。与其它两类方法相比,统计方法模型参数量少、可解释性好,但由于此类方法对于非线性关系的建模能力有限,其预测准确度较低。

由于统计类方法无法有效处理时序数据中的非线性关联关系,许多研究使用机器学习方法进行网络流量的预测。Yamada 等人<sup>[7]</sup>使用随机森林(Random Forest, RF)预测网络流量,并根据预测结果动态调整网络带宽。Xia 等人<sup>[8]</sup>将 RF 和 LightGBM(Light Gradient Boosting Machine)应用于移动网络流量预测,该方法使用 RF 过滤冗余特征并使用 LightGBM 训练预测模型。Sun 等人<sup>[9]</sup>提出一种网络流量特征提取方法,并使用高斯过程进行流量预测。机器学习类方法存在的主要问题是预测准确度依赖于人工提取的数据特征,而人工提取特征时往往无法提取深层隐藏特征。

随着深度学习技术在图像<sup>[10]</sup>、自然语言处理<sup>[11-12]</sup>领域的广泛应用,越来越多的研究者将深度学习应用于流量预测问题<sup>[13-14]</sup>。常用的深度学习的方法包括深度置信网络<sup>[15]</sup>、LSTM<sup>[16]</sup>、CNN<sup>[17]</sup>等,此类方法通过端到端的网络结构实现历史流量数据到未来流量的映射,但此类方法无法实现时序数据的空间关联关系,特

别是基站间数据流量的关联关系。图神经网络是近几年出现的用于建模非欧关系的深度学习模型,它非常适合建模多基站间的流量关联问题<sup>[18-19]</sup>。Lin 等人<sup>[20]</sup>首先使用多图卷积神经网络提取基站间的空间关联,然后使用 LSTM 预测基站流量。Lin 等人<sup>[21]</sup>使用两个图注意力网络进行流量预测,第一个网络用于建模基站间的时空关联关系,第二个提高模型预测效率。Wang 等人<sup>[22]</sup>提出了一种基于时间序列相似性的图注意力网络,用于时空蜂窝流量预测。Zhang 等人<sup>[23]</sup>首先使用卷积操作提取基站间空间关联,然后使用 LSTM 提取时序数据。Zhao 等人<sup>[24]</sup>首先提出一种基于多表示图卷积、历史关联嵌入和时间属性嵌入的网络流量特征提取方法,然后使用门控时间卷积网络预测网络流量。

综上所述,基于时空神经网络的流量预测技术是当前的发展趋势,但当前研究仍无法同时处理多时间粒度历史数据的时空关联,该领域的预测准确度也有待进一步提高。针对以上问题,本文提出一种基于多时间粒度时空图神经网络的蜂窝网络流量预测方法。该方法首先使用线性卷积提取单一时间粒度的历史数据特征,然后使用图注意力网络建模多个时间粒度特征间的关联关系,最后使用空间特征聚合模块建模多基站间的空间关联。与已有方法相比,该方法可同时建模单基站多时间粒度间的关联性和多基站间的空间关联性。使用公开数据集对提出的方法进行验证,实验结果表明该方法可取得最好的预测效果。

## 1 方法概述

本节首先介绍提出的模型框架,然后分别介绍方法的线性卷积、时间特征聚合和空间特征聚合三个子模块。

### 1.1 模型框架

该文使用基站历史流量数据预测未来一段时间内的基站流量。为了在预测过程中考虑不同时间粒度的时序关联性,首先定义时间粒度递增集  $\delta = \{\delta_1, \delta_2, \dots, \delta_k\}$ , 粒度表示时序数据中每个时刻流量的时间跨度。不失一般性,定义  $\delta_1 = 1$  为最小时间粒度,即基站提供的原始时序数据的时间粒度,且对  $\forall i > 1$  有  $\delta_i$  是  $\delta_1$  的整数倍。假设需要预测的基站数量为  $N$ , 基站  $n$  在时间粒度  $\delta_i$  下的历史流量数据用  $\mathbf{x}_n^{\delta_i} = \{x_{n1}^{\delta_i}, x_{n2}^{\delta_i}, \dots, x_{nl_i}^{\delta_i}\}$  表示,其中  $x_{nt}^{\delta_i}$  表示时刻  $t$  的流量,  $l_i$  为时间粒度  $\delta_i$  的序列长度。对于不同的预测任务,  $x$  可以为通话数量、短信数量、网络连接流量等。在此定义下,该文的流量预测任务可描述为:给定  $N$  个基站历史数据  $\mathbf{x}^{\delta_i}$ , 预测时间粒度  $\delta_i$  下未来流量  $\mathbf{x}_{l_i+1}^{\delta_i}$ 。使用的预测模型如图 1 所示。

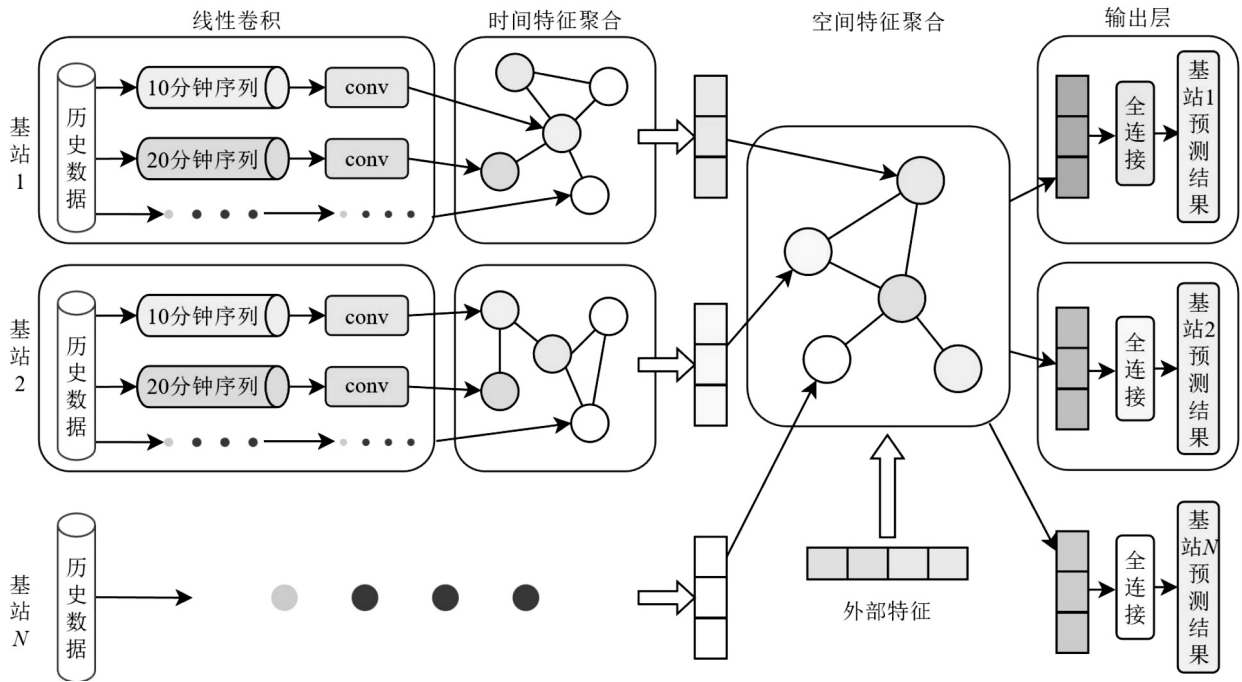


图 1 模型框架

如图 1 所示,该模型包括四部分:线性卷积、时间特征聚合、空间特征聚合和输出层。模型输入为基站提供过去一段时间的流量数据,线性卷积层首先将输入的数据合成为不同时间粒度的时序数据。对于每一个时间粒度,使用线性卷积提取序列表征。同一个基站的不同时序数据的表征作为时间特征聚合的输入。在时间特征聚合网络中,每一个时序代表一个图节点,不同粒度时序数据间的关系为图的边。经过时间特征聚合后,每一个基站的样本输出一个一维特征,该特征作为空间特征聚合的输入。在空间特征聚合中,每一个基站代表一个节点,基站间的流量关系作为图的边。经过空间聚合对不同基站表征进行融合后,每个基站输出的特征经过一个全连接层映射为该基站的预测结果。预测结果为未来一段时间内的流量。

### 1.2 线性卷积

线性卷积包括两步,第一步将输入的历史流量数据合成为不同时间粒度的序列,第二步对不同时间序列做线性卷积。根据 1.1 节中的定义,基站  $n$  的输入序列为  $\mathbf{x}_n^{\delta_i}$ ,对于  $\forall i > 1$  时  $\mathbf{x}_n^{\delta_i}$  可使用  $\mathbf{x}_n^{\delta_{i-1}}$  合成得到,时间粒度  $\delta_i$  在  $t$  时刻的流量如公式 1 所示。

$$\mathbf{x}_n^{\delta_i} = \sum_{j=1}^{\delta_i} \mathbf{x}_n^{\delta_{i-1}(l_i - (l_i - t + 1)\delta_i + j)} \quad (1)$$

其中,  $l_1$  和  $l_i$  分别为输入序列长度和粒度  $\delta_i$  的序列长度。从公式可以看出,在时间粒度为  $\delta_i$  的序列中,每时刻的流量为最小粒度序列中  $\delta_i$  个时刻流量之和。执行完公式 1 后,可得到粒度为  $\delta_i$  的时序数据  $\mathbf{x}_n^{\delta_i}$ ,基站  $n$  的所有序列记为  $\mathbf{x}_n$ 。下一步对不同粒度的时序数据进行线性卷积,以提取序列在时间维度的特征。

线性卷积包括  $p$  层的卷积池化操作,基站  $n$  第  $j$  层的输入记为  $\xi_{n(j-1)}^{\delta_i}$ ,且  $\xi_{n0}^{\delta_i} = \mathbf{x}_n^{\delta_i}$ 。第  $j$  层卷积操作使用  $n_j^i$  个卷积核,其维度为  $n_j^i \times n_j^{i-1}$ 。卷积过程中,通过计算卷积核与输入数据的算术运算得到卷积值。第  $j$  层卷积结果中第  $e$  行  $f$  列的计算方法如公式 2 所示。

$$(\text{tmp}_{nj}^{\delta_i})_e^f = \sum_{b=e}^{e+n_j^i} \sum_{d=1}^{n_j^{i-1}} (\xi_{n(j-1)}^{\delta_i})_b^d (c_j^{\delta_i})_{b-e+1}^d \quad (2)$$

其中,  $(\xi_{n(j-1)}^{\delta_i})_b^d$  为基站  $n$  第  $j$  层卷积中第  $b$  行  $d$  列的值,  $c_j^{\delta_i}$  为对时间粒度  $\delta_i$  的序列卷积时第  $j$  层第  $f$  个卷积核。模型构建过程中,卷积核使用随机值初始化,并在模型训练过程中使用梯度下降方法更新得到最优值。为了降低模型复杂度,对卷积后的序列做最大池化,如公式 3 所示。

$$(\xi_{nj}^{\delta_i})_e^f = \max[(\text{tmp}_{nj}^{\delta_i})_{2e-1}^f, (\text{tmp}_{nj}^{\delta_i})_{2e}^f] \quad (3)$$

其中,  $\max$  为取最大值。经过以上两步后,第  $j$  层的输出记为  $\xi_{nj}^{\delta_i}$ ,其维度为  $l_j \times n_j^i$ 。经过  $p$  层卷积池化操作后,得到基站  $n$  在该时间粒度序列的  $m$  维特征,记为  $\mathbf{o}_n^{\delta_i}$ ,所有时间粒度的特征作为时间特征聚合的输入。

### 1.3 时间特征聚合

蜂窝网络未来的流量与多个时间粒度的历史数据相关。时间特征聚合模块的目的是对不同时间粒度序列的特征进行聚合,以在预测过程中融合多时间粒度时序数据的影响。本节使用图注意力网络对多时间粒度序列进行建模。基站  $n$  的图使用  $G = \{\mathbf{V}_n, \mathbf{A}_n\}$  表示,其中  $\mathbf{V}_n$  为顶点集,  $\mathbf{A}_n$  为边集。在本问题中,  $\mathbf{V}_n$  表示由  $\mathbf{o}_n^{\delta_i}$  组成的特征集,  $\mathbf{A}_n = (a_{nij})_{k \times k}$  表示由不同时间粒度间关系组成的邻接矩阵。图注意力网络结构如图 2 所示。




图 2 图注意力网络

使用图注意力网络进行特征聚合之前,首先要使用注意力机制计算不同时间粒度间的关联权重。时间粒度  $\delta_i$  和  $\delta_j$  之间的权重计算方法如公式 4 和公式 5 所示。

$$a_{nij}^{\text{imp}} = \text{LeakyReLU}(\alpha^T [\mathbf{W}_g \delta_i^{\delta_i} \parallel \mathbf{W}_g \delta_j^{\delta_j}]) \quad (4)$$

$$a_{nij} = \frac{\exp(a_{nij}^{\text{imp}})}{\sum_{q=1}^k \exp(a_{niq}^{\text{imp}})} \quad (5)$$

其中,  $\alpha \in \mathbb{R}^{2m_1}$  和  $\mathbf{W}_g \in \mathbb{R}^{m_1 \times m_1}$  为模型参数,需要在训练过程中根据梯度下降自动更新,  $\parallel$  为向量连接操作,公式 4 计算权重初值,公式 5 对计算的权重做归一化。计算完权重后,图注意力网络的特征聚合方法如公式 6 所示。

$$\hat{\delta}_n^{\delta_i} = \sum_{j=1}^k a_{nij} \mathbf{W}_g \delta_j^{\delta_i} \quad (6)$$

由公式 6 可以看出,聚合后的特征为所有时间粒度特征的加权和。为了增加模型的鲁棒性,使用多头注意力机制计算多次聚合的平均值,如公式 7 所示。

$$\bar{\delta}_n^{\delta_i} = \sigma \left( \frac{1}{L} \sum_{l=1}^L \hat{\delta}_n^{\delta_i} \right) \quad (7)$$

其中,  $L$  为使用的注意力的数量。将所有时间粒度的特征相连后可得到基站  $n$  时间聚合的输出,如公式 8 所示。

$$\mathbf{o}_n^{\delta_i} = \parallel_{j=1}^k \bar{\delta}_n^{\delta_j} \quad (8)$$

其中,  $\mathbf{o}_n^{\delta_i} \in \mathbb{R}^{m_2}$  为经过时间图聚合后基站  $n$  的特征,且  $m_2 = Lm_1$ ,所有基站的特征用  $\mathbf{o}'$  表示,该矩阵作为空间图聚合的输入。

#### 1.4 空间特征聚合

根据当前的研究<sup>[25-26]</sup>,某地区内基站的流量往往与其邻近基站相关,空间特征聚合的目的是在基站特征中融合其它基站的影响。空间特征聚合如公式 9 所示。

$$\mathbf{o}_n^{\sim} = \sigma(\mathbf{W}_{sn}^T \mathbf{o}') \quad (9)$$

其中,  $\mathbf{o}_n^{\sim} \in \mathbb{R}^{m_2}$  为基站  $n$  经过空间聚合后的特征,  $\sigma$  为激活函数,  $\mathbf{W}_{sn} \in \mathbb{R}^N$  为基站  $n$  的权重向量,该向量需要在模型训练过程中使用梯度下降计算得到最优值。如公式 9 所示,特征的空间聚合实际上计算了多个相关基站特征的加权和。由于在空间范围内基站数量较

多,且距离较远的基站间流量关联性较小,为了降低模型的复杂度,在进行空间特征聚合时只考虑距离较近的基站。为了实现这个目的,将  $\mathbf{W}_{sn}$  设置为稀疏向量,即当基站  $i$  与基站  $n$  距离超过一个预定参数  $d$  时,  $\mathbf{W}_{sn}$  中的第  $i$  个元素设置为 0。

执行完公式 9 后,  $\mathbf{o}_n^{\sim}$  为基站  $n$  经过空间聚合后历史流量的特征,然而未来的基站流量除了与历史数据有关,也与一些外部因素如天气相关。该文在空间聚合特征中添加外部特征  $\mathbf{o}_w$ ,以提高预测准确度。两个特征相连后,经过一个全连接层将基站  $n$  的特征映射为模型的输出,如公式 10 所示。

$$\hat{y} = \mathbf{W}_o(\mathbf{o}_n^{\sim} \parallel \mathbf{o}_w) + \mathbf{b} \quad (10)$$

其中,  $\hat{y}$  为模型输出的预测值,  $\mathbf{W}_o$  和  $\mathbf{b}$  为模型可训练参数。

## 2 实验验证

### 2.1 数据集描述

本节使用 Telecom Italia 数据集验证该方法的有效性,该数据集由欧洲一家大型电话服务提供商提供,最初用于大数据竞赛<sup>[27]</sup>。数据集提供了 2013 年 11 月 01 日至 2014 年 01 月 01 日之间意大利米兰市三种蜂窝数据,包括短信服务,呼叫服务和互联网流量数据,数据的时间粒度为 10 分钟。在原始数据集中,米兰市被划分为  $100 \times 100$  的方格,方格的大小约为 0.235 公里,每个方格用一个 1 至 10 000 之间的数字编号。原始数据集由方格 ID、时间戳、短信接收、短信发送、电话接入、电话呼出和互联网流量几个字段组成。

由于原始数据集中区域较多,遵循文献<sup>[27]</sup>中的思路,选取市区中心  $20 \times 20$  的方格作为模型的输入,每一个方格代表一个基站。对每一个基站数据,使用步长为 1 小时的滑动窗口将时序数据划分成预测样本,将每个样本之后 1 小时内的基站数据作为样本的标签。对于每一个样本,使用公式 1 合成不同时间粒度的序列,每一个时间粒度对应的序列如表 1 所示。

表 1 时间粒度划分

编号	时间粒度 $\delta$	序列长度 $l$	总跨度
1	10 分钟	12	2 小时
2	20 分钟	9	3 小时
3	30 分钟	10	5 小时
4	40 分钟	9	6 小时
5	1 小时	10	10 小时
6	1.5 小时	10	15 小时
7	2 小时	12	24 小时

除了原始流量数据,相关研究<sup>[26]</sup>中还提供了该段

时间内的节假日和气候数据,其中气候数据包括天气、温度、风速等。该文在空间聚合特征中添加这两类特征,以提高预测准确度。

## 2.2 实验设计

考虑短信和通话两个预测任务,样本标签为未来一小时内短信和通话数量。最后一周的样本作为测试集,其它时间的样本作为训练集。实验使用 PyTorch 深度学习框架进行模型构建和训练,最优模型所使用的训练参数如表 2 所示。

表 2 模型参数

参数名称	参数值
batch size	32
优化器	Adam
学习率	0.005
Dropout rate	0.2
迭代次数	100
损失函数	MSE

表中损失函数为均方误差 (MSE),其计算方法如公式 11 所示。

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (11)$$

其中,  $\hat{y}_i$  为样本预测结果,  $y_i$  为真实标签。模型训练完成后,对测试样本进行预测,使用均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 和  $R^2$  评价模型的预测效果,其计算方法如公式 12 ~ 14 所示。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (12)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (13)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (14)$$

其中,  $\bar{y}_i$  为样本预测结果的平均值。对于指标 RMSE, 值越小预测效果越好。对于指标 MAPE, 其值为大于等于 0 的实数, 该值越小, 相应的预测效果越好。对于  $R^2$ , 其值为 0 ~ 1 之间的实数, 其值越大预测效果越好。

为了验证该方法的有效性, 实验选择 ARIMA<sup>[4]</sup>、LSTM<sup>[16]</sup>、MGCN<sup>[20]</sup>、MRSTGCN<sup>[24]</sup>、ST-FCCNet<sup>[26]</sup>、MST-DenseNet<sup>[28]</sup> 等几种经典的蜂窝流量预测方法进行对比。对比方法使用的数据包括短信接收、短信发送、电话接入、电话呼出和互联网流量, 以及节假日和气候数据。ARIMA 和 LSTM 以单基站 1 小时时间粒度的归一化数据作为输入。LSTM 使用两层隐藏层, 隐藏层节点数设置为 128, 序列长度设置为 10。MGCN 以所有基站的 1 小时时间粒度数据作为输入,

首先使用基站距离、区域相似性、历史数据相关性构建多个图结构, 然后对每一时刻的数据图做空间特征融合, 最后使用时序模型输出每个基站最终的预测结果。MRSTGCN 使用时间间隔为 1 小时、1 天和 1 周的历史序列提取历史关联和时间属性特征。ST-FCCNet 以 1 小时和 24 小时时间粒度作为输入, 对于时序中的每一时刻, 将空间多个基站的特征执行连接操作后输入全连接层以捕获基站间的空间依赖。与文中方法相比, 没有考虑空间聚合时不同基站特征权重。MST-DenseNet 以单基站多个时间粒度数据作为输入, 选取的时间粒度数据包括 1 小时、1 天、1 周和 1 个月。对每个时间粒度, 使用 2 个卷积层和 2 全连接层提取时序特征, 最后将多个时间粒度特征融合后输出得到预测结果。与文中方法相比, 使用的时间粒度数量少且没考虑基站的空间依赖。

## 2.3 实验结果

本节介绍不同预测方法在短信数量和通话数量两个预测任务上的实验结果, 两个预测任务的对比结果如表 3 和表 4 所示, 其中 T-GAT 为文中方法。

表 3 短信任务预测结果

方法	RMSE	MAPE/%	$R^2$
ARIMA <sup>[4]</sup>	113.1	22.2	0.878
LSTM <sup>[16]</sup>	95.6	19.8	0.922
MGCN <sup>[20]</sup>	68.4	15.8	0.970
MRSTGCN <sup>[24]</sup>	72.7	15.9	0.967
ST-FCCNet <sup>[26]</sup>	80.3	17.7	0.963
MST-DenseNet <sup>[28]</sup>	78.9	17.0	0.944
T-GAT	64.7	15.1	0.978

表 4 通话任务预测结果

方法	RMSE	MAPE/%	$R^2$
ARIMA <sup>[4]</sup>	82.6	19.3	0.895
LSTM <sup>[16]</sup>	74.4	16.9	0.929
MGCN <sup>[20]</sup>	55.7	14.2	0.966
MRSTGCN <sup>[24]</sup>	58.1	14.8	0.960
ST-FCCNet <sup>[26]</sup>	49.9	13.5	0.968
MST-DenseNet <sup>[28]</sup>	65.5	15.5	0.939
T-GAT	47.4	13.1	0.976

从表中可以看出, 在所有预测方法中, 文中方法取得了最好的预测效果。对于短信预测任务, 当前最好的预测方法为 MGCN, 三个预测指标的值分别为 68.4, 15.8% 和 0.970, 文中方法的三个指标值分别为 64.7, 15.1% 和 0.978, 分别降低了 5.4%, 4.4% 和 0.8%。对于通话预测任务, 表现最好的方法为 ST-FCCNet, 文中方法分别降低了 5.0%, 3.0% 和 0.8%。ARIMA 和 LSTM 预测效果较差, 主要原因为两个方法

只使用单一时间粒度和单基站数据进行预测,没有考虑多时间粒度和基站的空间关联性。MRSTGCN 考虑了当前流量序列与历史流量序列的时间关联性,并同时考虑了基站的空间关联性,这两个特性使得预测效果明显提高。但该方法没有使用数据集的外部特征且没有挖掘不同时间粒度序列间的关联,所以其预测结果比 MGCN 和 ST-FCCNet 差。在剩余的三种已有方法中, MST-DenseNet 考虑了三个不同时间粒度的关联性,但没有考虑空间关联性,其预测效果好于 LSTM,但仍然差于其它方法。ST-FCCNet、MGCN 同时考虑了多个时间粒度序列关系和基站空间位置的关系,因此这两类方法表现较好。但是这两个方法在考虑时间粒度关联时,只对不同时间粒度的特征进行拼接,并没考虑特征权重,所以两类方法表现较文中方法差。

### 2.4 模型参数影响

文中方法的优势在于既考虑了不同时间粒度间的关联权重也考虑了基站的空间关联性。本节进一步分析两类关联对最终结果的影响。本节首先去除模型中

的时间聚合模块,使用单一时间粒度获取预测结果。

图 3 中画出了在两个预测任务上不同时间粒度的 RMSE 预测结果。从图中可以看出,当时间粒度编号为 4 至 6,即时间粒度为 40 分钟至 1.5 小时,单时间粒度序列的预测效果较好。为了进一步分析不同时间粒度的组合对预测结果的影响,修改原模型中时间特征聚合模块中时间粒度的数量,并将方法命名为 T-GAT- $i$ ,其中  $i$  表示选择的时间粒度数量。对于每个方法,挑选  $i$  个表现最好的时间粒度序列构建时间特征聚合模块,并得到最终的预测结果。除此之外,为了分析空间关联性的影响,本节还在原模型中去除空间聚合模块,将方法命名为 T-GAT-s。

图 4 画出了不同方法在两类预测任务上的预测结果。观察 T-GAT-s 的结果可以发现,该方法表现比 T-GAT 差,这说明空间特征聚合模块可以有效提高预测准确率。观察不同时间粒度方法的预测结果可发现,随时间粒度数量的增多,预测误差先有明显下降,然后趋于平缓。这说明融合多个时间粒度的特征可提高预测效果。




图 3 不同时间粒度序列的预测结果




图 4 不同时间粒度数量的预测结果

## 3 结束语

网络流量预测是蜂窝网络运营过程中面临的重要问题,准确的流量预测可帮助网络运营商合理配置网络资源、降低运营成本。针对当前流量预测方法中无

法融合多时间粒度序列特征的问题,提出一种融合多时间粒度特征的时空图模型。该方法使用一维卷积提取单序列特征,使用图注意力网络建模多时间粒度序列间的关联,使用公开数据集验证了方法的有效性。基站流量预测是一个复杂的时空关联预测问题,该文

在进行空间特征聚合时只考虑了邻近基站之间的关联,如何挖掘更深层次的空间关联性是未来的研究方向。另外,基站的流量不仅与历史流量相关,还与天气、周边商业分布等众多外部因素相关。该文只使用了天气和节假日数据,挖掘流量与其它外部因素的关联性也是一个重要的研究方向。

#### 参考文献:

- [1] 谭惠文. 异构蜂窝网络中流量预测及延时卸载激励机制关键技术研究[D]. 武汉:湖北工业大学,2021.
- [2] 刘悦,王芳. 基于优化组合核极限学习机的网络流量预测[J]. 计算机技术与发展,2016,26(6):73-77.
- [3] JIANG W. Cellular traffic prediction with machine learning: a survey[J]. *Expert Systems with Applications*,2022,201:117163.
- [4] XU F,LIN Y,HUANG J,et al. Big data driven mobile traffic understanding and forecasting: a time series approach[J]. *IEEE Transactions on Services Computing*,2016,9(5):796-805.
- [5] CLEMENTE D,SOARES G,FERNANDES D,et al. Traffic forecast in mobile networks; classification system using machine learning[C]//2019 IEEE 90th vehicular technology conference (VTC2019-Fall). Hawaii:IEEE,2019:45-49.
- [6] PERVEEN A,ABOZARIBA R,PATWARY M,et al. Dynamic traffic forecasting and fuzzy-based optimized admission control in federated 5G-open RAN networks[J]. *Neural Computing and Applications*,2023,35(33):23841-23859.
- [7] YAMADA Y,SHINKUMA R,SATO T,et al. Feature-selection based data prioritization in mobile traffic prediction using machine learning[C]//2018 IEEE global communications conference (GLOBECOM). Abu Dhabi:IEEE,2018:1-6.
- [8] XIA H,WEI X,GAO Y,et al. Traffic prediction based on ensemble machine learning strategies with bagging and lightgbm[C]//2019 IEEE international conference on communications workshops (ICC Workshops). Shanghai:IEEE,2019:1-6.
- [9] SUN S C,GUO W. Forecasting wireless demand with extreme values using feature embedding in gaussian processes[C]//2021 IEEE 93rd vehicular technology conference (VTC2021-Spring). Helsinki:IEEE,2021:1-6.
- [10] ZHANG X,DEMIRIS Y. Visible and infrared image fusion using deep learning[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*,2023,45(8):10535-10554.
- [11] BENAVIDES-ASTUDILLO E,FUERTE W,SANCHEZ-GORDON S,et al. A phishing-attack-detection model using natural language processing and deep learning[J]. *Applied Sciences*,2023,13(9):5275.
- [12] 安俊秀,蒋思畅. 面向自然语言处理的词向量模型研究综述[J]. 计算机技术与发展,2023,33(12):17-22.
- [13] 王跃文. 基于深度学习的无线蜂窝网络流量预测研究[D]. 徐州:中国矿业大学,2021.
- [14] 冯培坤,刘杰,伍卫国,等. 一种基于并联组合模型预测站点流量的策略[J]. 计算机技术与发展,2020,30(9):1-6.
- [15] SELVAMANJU E,SHALINI V B. Archimedes optimization algorithm with deep belief network based mobile network traffic prediction for 5G cellular networks[C]//2022 4th international conference on smart systems and inventive technology (ICSSIT). Tirunelveli:IEEE,2022:370-376.
- [16] 陈雄,王海晨. 基于ISSA-LSTM模型的短时交通流预测[J]. 计算机技术与发展,2023,33(4):198-204.
- [17] GAO Y,ZHANG M,CHEN J,et al. Accurate load prediction algorithms assisted with machine learning for network traffic[C]//2021 international wireless communications and mobile computing (IWCMC). Harbin:IEEE,2021:1683-1688.
- [18] 梁栋天. 基于空时特性的基站流量分析与预测研究[D]. 北京:北京邮电大学,2021.
- [19] 郭心语,马漫曦,周忠龙,等. 基于空时图卷积神经网络的移动蜂窝网络流量预测[J]. 科海故事博览,2023(17):25-27.
- [20] LIN J,CHEN Y,ZHENG H,et al. A data-driven base station sleeping strategy based on traffic prediction[J]. *IEEE Transactions on Network Science and Engineering*,2021,8(3):2326-2341.
- [21] LIN C Y,SU H T,TUNG S L,et al. Multivariate and propagation graph attention network for spatial-temporal prediction with outdoor cellular traffic[C]//Proceedings of the 30th ACM international conference on information & knowledge management. New York:ACM,2021:3248-3252.
- [22] WANG Z,HU J,MIN G,et al. Spatial-temporal cellular traffic prediction for 5G and beyond: a graph neural networks-based approach[J]. *IEEE Transactions on Industrial Informatics*,2022,19(4):5722-5731.
- [23] ZHENG H,LIN F,FENG X,et al. A hybrid deep learning model with attention-based conv-LSTM networks for short-term traffic flow prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*,2020,22(11):6910-6920.
- [24] 赵斌男. 基于GCN的网络流量预测子系统的设计与实现[D]. 北京:北京邮电大学,2023.
- [25] 李莉,吴润泽,包正睿,等. 可重构分层感知网络流量预测算法[J]. 计算机技术与发展,2018,28(5):197-200.
- [26] 黄冬宜,杨兵,吴子豪,等. 用于全市蜂窝流量预测的时空全连接卷积网络[J]. 计算机工程与应用,2021,57(9):168-175.
- [27] BARLACCHI G,DE NADAI M,LARCHER R,et al. A multi-source dataset of urban life in the city of Milan and the Province of Trentino[J]. *Scientific Data*,2015,2(1):1-15.
- [28] 马冀,林尚静,李月颖,等. 多源跨域数据融合的无线网络流量预测[J]. 计算机科学,2022,49(S2):893-899.