

# 图智能AI技术在基站流量预测中的探索与实验

## Exploration and Experiment of Graph Intelligence AI Technology in Base Station Traffic Prediction


李永<sup>1</sup>, 刘博<sup>2</sup>, 汪悦<sup>3</sup>, 王鑫<sup>3</sup>, 程新洲<sup>3</sup> (1. 北京工业大学, 北京 100124; 2. 新西兰梅西大学, 新西兰; 3. 中国联通研究院, 北京 100176)

Li Yong<sup>1</sup>, Liu Bo<sup>2</sup>, Wang Yue<sup>3</sup>, Wang Xin<sup>3</sup>, Cheng Xinzhou<sup>2</sup> (1. Beijing University of Technology, Beijing 100124, China; 2. Massey University, New Zealand; 3. China Unicom Research Institute, Beijing 100176, China)

### 摘要:

5G网络以其高速率、广泛连接和低时延为新技术领域提供支持,但面临着严峻的能耗问题。研究了AI技术在提升基站能效方面的应用,提出了基于图神经网络的流量预测方法,考虑了流量数据的空间关联和时间依赖性。该方法结合图卷积网络和时序卷积模块,优化了基站流量分布,显著提升了流量预测准确性。准确的流量预测能够为基站关停策略提供科学依据,从而有效降低能耗,提升能源效率,减少成本,促进可持续发展。

### 关键词:

5G基站; 节能; 流量预测; 人工智能; 图神经网络  
doi: 10.12045/j.issn.1007-3043.2024.09.007  
文章编号: 1007-3043(2024)09-0038-06  
中图分类号: TN929.5  
文献标识码: A  
开放科学(资源服务)标识码(OSID): 

### Abstract:

5G network provides support for new technology fields with its high speed, extensive connectivity, and low latency, but it faces a severe challenge in terms of energy consumption. It explores the application of AI technology in enhancing the energy efficiency of base stations, and proposes a traffic prediction method based on Graph Neural Networks that takes into account the spatial correlation and temporal dependency of traffic data. The method combines graph convolutional networks and 1-D convolution modules to optimize the distribution of base station traffic, which significantly improves the accuracy of traffic prediction. Accurate traffic prediction can provide scientific basis for base station shutdown strategies, which effectively reduce energy consumption, improve energy efficiency, reduce costs, and promote sustainable development.

### Keywords:

5G base station; Energy saving; Traffic prediction; Artificial intelligence; Graph neural network

引用格式: 李永, 刘博, 汪悦, 等. 图智能AI技术在基站流量预测中的探索与实验[J]. 邮电设计技术, 2024(9): 38-43.

## 1 概述

由于5G毫米波基站在更高频段运行,其覆盖范围比3.5 GHz频段基站更小,同时毫米波基站的功放效率可能低于传统基站,这意味着它们的功耗也更大。另一方面,5G基站与4G相比具有更大的带宽,每个基站的发射功率可能是4G的多倍,导致单站整体功耗大幅增加。此外,AI内生也将是5G网络的一项重要特

征,5G基站未来还将承载更多的AI计算任务,通过基站侧的边缘计算能力对各类AI应用进行推理运算,将进一步增加5G基站的能耗。

因此,对无线基站的能耗管控至关重要,有效的能耗管控不仅能够降低运营成本,减少对环境的负面影响,而且将成为未来无线网络建设的关键策略。目前,行业内主要采用人工智能算法来对基站流量进行预测,对于流量较少的基站进行动态关停、调整,以此来节约基站的能耗。然而对5G无线基站的关停时段必须要进行精准合理的预测和规划,以避免部分基站

收稿日期: 2024-08-01

关停后造成通信服务的中断和用户体验的下降。

5G网络建设初期可能会存在基站异构组网的情况,网络结构趋于复杂化,业务场景趋于差异化,客户需求也趋于多样化。而目前针对无线网络基站的传统机器学习流量预测方法主要侧重于单个基站的预测,忽视了基站与基站之间的连接关系,这将导致对5G无线基站的能耗关停模型预测的准确性不高,从而严重限制了基站节能策略的有效实施。

而图智能AI技术在无线基站资源编排调度中将体现出重要价值:一是图结构化数据可以呈现出对象之间复杂关系的重要性,精确描述5G异构无线基站之间的关系;二是图智能人工智能算法在复杂网络环境下展现出比传统机器学习更为卓越的决策能力,智能推断挖掘复杂无线网络拓扑中的隐藏信息和关联关系;三是电信行业拥有通信网络拓扑和人机物交互拓扑这2种天然的图结构,应用图智能AI技术可以建立无线基站的网络资源拓扑模型,进而优化无线基站的资源配置和调度,实现网络资源、用户感知和能耗的最优编排,为基站动态关停节能提供高效、智能的决策支持。本文采用图神经网络技术赋能无线通信网络基站资源动态调度,可以进一步提高5G异构混合无线基站流量预测的准确性,更精确地分析和优化基站的时空流量分布,成为5G+AI的全新演进方向。

## 2 基于传统机器学习的基站流量预测方法

如果采用传统的机器学习AI方法,需基于基站的历史流量数据及工参数据预测单基站的周期性流量变化。为了更好地对基于图智能AI技术优势进行对比论证,本文首先利用传统的时序预测方法,例如:ARIMA、VARMLP、LGBM等模型对基站的未来流量进行智能预测,由此对流量小的5G基站进行动态关停以实现小区基站的能耗动态管控。

可以采用加权平均、指数平滑、线性回归等统计学方法来建立单变量时序预测,例如采用ARIMA model、Prophet model等算法,通过基站流量时序图得出无线基站小区流量的日周期性,进而动态关停基站实现能耗节能。ARIMA model、Prophet model属于单变量时序预测,其受限于时间序列的平稳分布,且不能捕获多元变量之间的非线性关系,在预测精度上不尽如人意。因此可以引入多变量AI模型进行时序预测,多变量时序预测又可以分为2类,一类是监督学习算法,包括XGBoost、LightGBM、RandomForest等树模

型算法,这些算法由于无法明确建模变量之间的潜在空间依赖关系,因此多变量时序预测算法还可以采用深度学习算法来提升基站流量的预测精度,例如VARMLP采用了全连接神经网络,其预测精度与ARIMA算法相比有了一定的提升,但是对于有地理位置关联关系的基站预测场景来说,VARMLP也有一定的局限性,这是因为VARMLP无法提取空间特征,其无线基站的流量预测能力被严重限制。因此,在此基础上引入卷积神经网络来捕获基站之间的地理关联信息,如LSTNet和TPA-LSTM算法可以对邻居节点进行时序关系的预测,LSTNet和TPA-LSTM算法由于可以捕获非线性的多变量关系,因此其预测精准度与其他算法相比有了明显提升,但是LSTNet和TPA-LSTM算法仍然无法明确地建模成对多变量之间的依赖关系。

## 3 基于图智能AI技术的基站流量预测方法

传统的深度学习方法在提取欧氏空间数据特征方面取得了不错的效果,但是在处理非欧式空间数据上的效果不佳,其中最主要的原因就是对图结构数据的应用。这是因为图是不规则的,不具备平移不变性,每个图都有一个大小可变的无序节点,每个节点又都可能有不同数量的相邻节点,从而不能利用卷积等操作来提取相同的结构信息。由此衍生了图神经网络,图神经网络=图结构数据+神经网络,就是将卷积网络、循环网络和深度自动编码器等算法思想构建成用于处理图数据的神经网络结构。

图神经网络可以划分为如下五大类别。

a) 图卷积网络(Graph Convolution Networks, GCN)<sup>[5]</sup>,将卷积运算从传统数据推广到图数据,核心思想是学习一个函数映射,图中的目标节点通过该映射可以聚合它自己的特征与它的邻居特征来生成节点新表示。

b) 图注意力网络(Graph Attention Networks),在聚合邻居特征信息时融入注意力机制,自适应学习不同邻居节点的权重。

c) 图自动编码器(Graph Autoencoders),它是一种图嵌入方法,核心思想是利用神经网络结构对图上节点特征进行降维。

d) 图生成网络(Graph Generative Networks),通过利用循环网络、卷积网络等技术学习现有图隐藏表示,从而生成具有所需属性的新图。

e) 图时空网络<sup>[6]</sup> (Graph Spatial-temporal Networks), 同时捕捉时空图的时空相关性, 将图卷积神经网络 (GCN) 与循环神经网络 (RNN) 及其变体网络结构融合, 充分挖掘节点之间的时空依赖关系。

本次针对小区流量时序预测任务主要采用学术界比较认可的时空图神经网络算法 GCN, 图 1 所示为 GCN 的基本计算原理。图卷积 GC 模块整合节点及邻居节点信息, 包含 2 个 mix-hop 传播层, 每个 mix-hop

包含信息传播和信息选择 2 个模块, 分别处理单个节点的 inflow 信息和 outflow 信息, 最终将 2 个信息相加输出; 时序卷积 TC 模块提取时间依赖特征, 采用膨胀卷积和 inception 层。膨胀卷积解决长期依赖问题; inception 层增加卷积宽度, 增加感受视野; 跳跃连接层主要作用是对信息进行规范化, 使输入到输出层的序列长度相同; 输出层包括 2 个 1×1 的卷积层, 输出指定维度值。

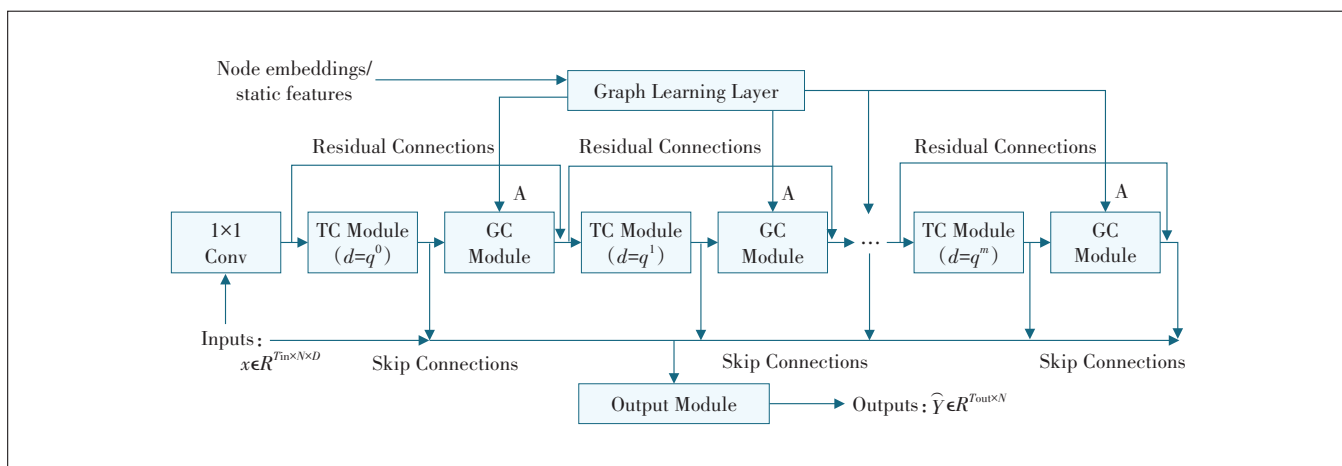


图 1 GCN 模型运算原理

为了更好地适应无线通信网络的场景, 本文在 GCN 基本模型的基础上对 GCN 模型结构及自适应学习邻接矩阵的方法上做了部分优化调整, 补全了基于地理位置信息的基站拓扑结构, 构建图卷积 GC 模块提取基站流量的空间特征, 构建时序卷积 TC 模块提取基站流量的时间特征, 充分提取基站流量的时空特征, 最后通过全连接层得到预测结果。

图 2 所示为本文所提模型的结构示意。本文从基站的工参数据获取各个基站的经纬度数据, 通过高斯核函数计算基站结点间的邻接矩阵。高斯核函数也称为径向基函数, 可以将有限维数据映射到高维空间, 定义如下:

$$k(x, x') = e^{-\frac{\|x - x'\|^2}{2\sigma^2}} \quad (1)$$

计算两两基站间的高斯核值, 为了保持邻接矩阵的稀疏性, 取上限阈值 0.1, 大于阈值的邻接值为 0。将得到的邻接矩阵输入到图卷积网络中。

2017 年, 图卷积网络被提出用于解决图结构的数据。GCN 设计了一种从图数据中提取特征的方法, 可以用于解决节点分类、图分类、边预测等问题。对于一张图  $G$ , 有节点  $V$  和边  $E$ ,  $G=(V, E)$ , 邻接矩阵  $A$ 。每层的计算公式如下:

$$H^{(l+1)} = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{\frac{1}{2}} H^{(l)} W^{(l)}) \quad (2)$$

其中,  $H$  为层, 上标是层数,  $W$  为层与层之间的权值矩阵。 $\hat{A} = A + I$ ,  $I$  为单位矩阵。 $\hat{D}$  为  $\hat{A}$  的度数矩阵,  $\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{\frac{1}{2}}$  是对  $A$  做了一个对称的归一化。

本文构建的基站拓扑结构中, 图卷积网络处理每




图 2 本文模型结构



个时刻的节点特征,并利用一维卷积<sup>[7]</sup>操作提取不同时刻间的时序信息。与二维卷积在宽度和高度2个方向进行滑动窗口操作不同,一维卷积值在宽度单方向上进行滑动窗口并相乘求和。二维卷积操作一般用于处理图像问题,而一维卷积则用于时序特征提取。最后,通过全连接层预测各个基站的流量值。

## 4 实验验证

本章将介绍本文实验所采用的数据集、模型参数、实验所用的评价指标及实验结果。

### 4.1 数据集

为了提升基站流量运营的图AI模型的泛化性,本文将在图AI算法模型实施过程中引入不同地理、用户密度和业务类型环境下的数据。图AI模型泛化能力可以衡量模型能否将从一个数据集学到的知识并应用到新的、未见过的数据上的重要指标,对于基站流量预测模型来说,具备强大的泛化能力意味着能够在多样化的网络环境中提供准确的预测,从而实现有效的能耗管理。多环境测试对于验证模型的实用性和可靠性至关重要。不同的地理环境、用户行为和业务模式将对基站流量产生显著影响。例如,城市中心的商业区可能在工作日的白天出现流量高峰,而居民区则可能在晚上和周末出现流量高峰。此外,不同地区的文化和生活习惯也会导致流量模式的差异。

本文所采用的数据为某市某区的流量数据,为了全面提升图AI模型的泛化能力,本文引入如表1所示的几类典型的网络环境数据。

表1 网络环境数据

数据来源	特点
城市中心商业区	高用户密度,多样化的业务需求
城市郊区	用户密度较低,流量模式可能更受居住模式影响
居民区	可能在特定时间(如晚上和周末)出现流量高峰
工业区	可能存在周期性的流量需求,与工作班次相关
乡村地区	用户分布稀疏,业务类型可能较为单一

通过对某年4月到9月所采集到的流量进行分析,发现基站流量通常以一天(24h)为周期。故本文采用24h预测12h流量的预测方式。总共3205个样本,按照8:1:1的比例切分为训练集、验证集和测试集,样本数量分别为2564、321和320个。基于训练集的最大最小值对整个数据集进行min-max归一化处理。数据标准化中最典型的的就是数据的归一化处理,

即将数据统一映射到[0,1]区间上,转换函数如下:

$$x^* = \frac{x - \min}{\max - \min} \quad (3)$$

### 4.2 实验参数

本文提出的流量预测模型所涉及到的实验环境参数如表2所示,采用的模型参数如表3所示。

表2 实验环境参数

操作系统	参数
CPU	Intel(R) Core(TM) i7-10870H
GPU	NVIDIA GeForce RTX 3060
内存	32G
Python	3.6.5
Pytorch	1.8.0+cu111

表3 模型参数

batch size	4
epoch	50
learning rate	0.001
dropout	0.3
weight decay rate	0.0001
clip	5
gen层数	2

本文每一代训练(epoch)计算一次验证集的误差值,如果误差值不再下降,则训练停止。取验证集最低误差的模型参数在测试集上做预测。

### 4.3 评价指标

本文实验采用3种评价指标:MAE、RMSE<sup>[8]</sup>和WMAPE。

平均绝对误差(Mean Absolute Error, MAE)的计算如式(4)所示。当预测值与真实值完全吻合时为0,误差越大,MAE值越大。

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (4)$$

其中, $A_i$ 、 $F_i$ 分别为 $t$ 时刻的真实值和预测值。 $n$ 为样本个数。

均方根误差(Root Mean Square Error, RMSE)的计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2} \quad (5)$$

由于本文流量数据大多接近0,无法计算MAPE,故采用加权平均绝对误差百分比值(Weighted Mean Absolute Percentage Error, WMAPE)作为评价指标。

WMAPE的计算公式如下:

$$WMAPE = \frac{\sum_{t=1}^n |A_t - F_t|}{\sum_{t=1}^n A_t} \quad (6)$$

#### 4.4 实验结果

本文的实验结果如表4所示,表4给出了不同预测时间段的MAE、RMSE和WMAPE指标。随着所预测时间段的增加,3种指标数值呈逐渐增加的趋势,说明预测误差随着时间段的增加而增加。并随机抽取某一节点(基站),画出预测图(见图3)。在图3中,蓝色的点表示真实值,红色的代表预测值,模型为24h的数据预测12h,从图3可以看出,本文模型的预测结果较为接近真实值。

表4 不同预测时间段下的实验结果

时间/h	MAE/%	RMSE/%	WMAPE/%
3	13.19	35.0	34.67
6	13.70	36.17	36.00
12	14.38	36.83	38.21

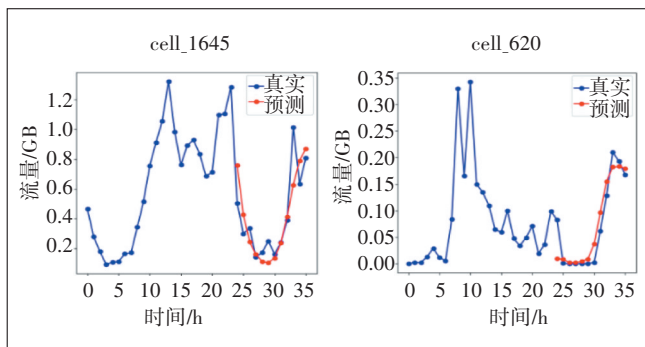


图3 随机选择基站所预测流量与真实流量对比

本文提出的流量预测方法结合基站关停策略,通过对预测流量数据的分析和合理规划,可以有效减少基站能耗。具体的节能量取决于基站的能耗模型、关停时间段和关停基站数量等因素。通过优化关停策略,不仅能够准确估算节能量,降低基站运营成本,减少环境影响,还能提高能源利用效率。因此,合理的流量预测和基站关停策略是实现基站节能的关键。

表5所示为3种流量预测方式的对比结果。跟ARIMA和LightGBM方法相比,本文所采用的图神经网络方式取得了最低的流量预测误差值。MAE、RMSE和WMAPE 3种指标均最优,从而验证了本文所提流量预测方法的性能。

在实施基站智能节能运营策略时,笔者建议除了需要对基站的上下行流量进行预测外,还需要综合考

表5 基站流量预测模型的对比结果

模型	MAE/%	RMSE/%	WMAPE/%
ARIMA	15.04	46.69	52.33
LightGBM	13.58	43.01	45.58
GCN	14.38	36.83	38.21

量当前基站的总业务流量和总的连接用户数。通过统计分析发现模拟基站的小区连接用户数也基本具备和业务流量相同的周期特性,可使用和流量预测相同的模型对未来12h的基站用户数进行预测,结果如表6和图4所示。从表6和图4可以看出,本文所采用的图神经网络方式与MA、LGBM模型相比,对基站用户数的预测的效果最优,且提升效果显著,WMAPE达到28.37%。

表6 基站用户数量预测模型的对比结果

模型	MAE/%	RMSE/%	WMAPE/%
ARIMA	4.044 2	9.387 6	30.26
LightGBM	4.009 2	7.951 2	19.01
GCN	6.011 3	10.019 0	28.37

5G基站的典型功耗为3500W,单个基站一年的能耗约为30.66MWh,根据本文提出的基于图神经网络的流量预测方法,结合实际的基站运行数据,预计整体至少可以节约10%~20%的能耗,通过预测流量低峰期,并相应地调整基站运行状态,单基站每年可以节约6MWh的能耗,具有显著的经济和环境效益。

## 5 结束语

随着通信技术的飞速发展,5G网络作为当前和未来通信的主流技术,正面临着日益严峻的能耗挑战。5G基站以其高速率、大容量、低时延的特性,支撑着智慧城市、工业自动化、虚拟现实等众多应用,但同时也带来了更高的能耗需求。有效的能耗管理对于降低运营成本、减轻环境影响、并确保5G网络的可持续发展至关重要。针对5G基站的能耗管理,传统机器学习方法在预测基站能耗和关停策略时可能存在准确性低的问题。为此,本文提出了一种基于图神经网络(GCN)的流量预测方法,该方法通过分析基站之间的空间关联和时间依赖性,显著提高了流量预测的准确性。改进的GCN算法不仅能够捕捉基站间的复杂关系,还能够预测流量模式,从而为基站的动态关停提供科学依据。在实施5G基站的智能节能策略时,除了

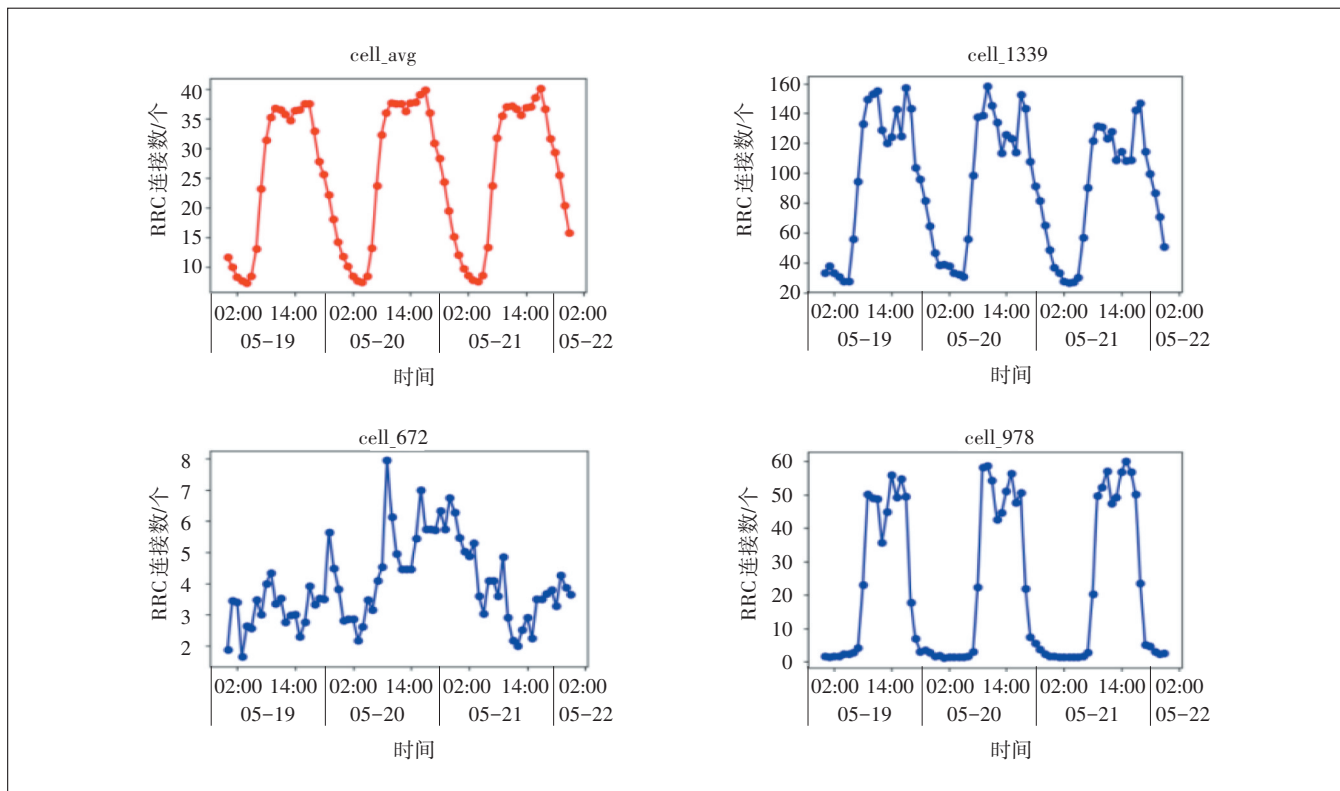


图4 小区RRC连接平均数时序走势预测

考虑基站的流量数据外,还需要综合考量基站的总业务流量、连接用户数以及不同时间段的网络使用模式。这种综合考量可以进一步提升节能策略的有效性,确保在满足用户服务质量的前提下,实现能源的最优利用。

本文的研究结果表明,采用图神经网络技术不仅能够提高5G基站流量预测的准确性,还能够为5G网络与人工智能(AI)技术的融合提供新的思路。通过智能化的流量管理和基站关停策略,5G网络能够更加高效地运行,同时为环境保护做出贡献。随着5G技术的不断演进和AI技术的日益成熟,预计这种结合了先进技术的节能策略将在未来的通信网络管理中发挥更加重要的作用。

#### 参考文献:

[1] JIANG W, HAN B, HABIBI M A, et al. The road towards 6G: a comprehensive survey [J]. IEEE Open Journal of The Communications Society, 2021(2):334-366.  
[2] WANG H, HUANG M, ZHAO Z Z, et al. Base station wake-up strategy in cellular networks with hybrid energy supplies for 6G networks in an IoT environment [J]. IEEE Internet of things journal, 2021, 8(7):5230-5239.

[3] 麻秀范, 孟祥玉, 朱秋萍, 等. 计及通信负载的5G基站储能调控策略[J]. 电工技术学报, 2022, 37(11):2878-2887.  
[4] 曾博, 穆宏伟, 董厚琦, 等. 考虑5G基站低碳赋能的主动配电网优化运行[J]. 上海交通大学学报, 2022, 56(3):279-292.  
[5] ZHANG S, TONG H H, XU J J, et al. Graph convolutional networks: a comprehensive review [J]. Computational Social Networks, 2019, 6(1):11.  
[6] 冯宁, 郭晨楠, 宋超, 等. 面向交通流量预测的多组件时空图卷积网络[J]. 软件学报, 2019, 30(3):759-769.  
[7] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7):134-143.  
[8] WILLMOTT C J, MATSUURA K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance [J]. Climate Research, 2005, 30(1):79-82.

#### 作者简介:

李永, 毕业于北京理工大学, 副教授, 博士, 主要研究领域为智能计算芯片及系统应用; 刘博, 毕业于北京理工大学, 研究员, 博士, 主要从事人工智能、图像识别等领域的研究工作; 汪悦, 毕业于北京邮电大学, 博士, 主要从事图智能AI技术以及多模态大模型领域的研究工作; 王鑫, 毕业于英国约克大学, 中国科协青托人才, 硕士, 主要从事图智能AI技术以及绿色低碳算力领域的研究工作; 程新洲, 教授级高级工程师, 主要从事通信大数据分析 & 架构等研究工作。