

基于图卷积神经网络的无线基站 流量预测研究

Research on Wireless Base Station Traffic Forecasting Based on Graph Convolutional Networks

郭超,陈佳,汪悦(中国联通研究院,北京 100048)
Guo Chao,Chen Jia,Wang Yue(China Unicom Research Institute,Beijing 100048,China)

摘要:

采用图神经网络方法对无线网络基站进行流量预测,首先基于基站地理距离构建预定义网络拓扑图,其次利用GCN提取基站之间的空间依赖关系,然后将结果输入到门控循环单元GRU提取基站之间的时间依赖关系,最后通过全连接层对基站未来多个时刻的流量做出精确预测。利用中国联通某市基站数据进行模型验证,实验结果表明,该模型相对于其他主流预测模型进一步降低了预测误差,模型预测准确率大幅度提升。

关键词:

图神经网络;流量预测;卷积神经网络;门控循环单元

doi:10.12045/j.issn.1007-3043.2023.06.007

文章编号:1007-3043(2023)06-0036-05

中图分类号:TP391

文献标识码:A

开放科学(资源服务)标识码(OSID):



Abstract:

It uses graph neural network method for traffic prediction of wireless network base stations. Firstly, a predefined network topology map is constructed based on the geographic distance of the base station. Secondly, GCN is used to capture spatial dependence between the base stations, and the results are input to the gated recurrent unit to capture temporal dependence between the base stations. Finally, accurate predictions are made for the future traffic of the base stations at multiple times through the fully connected layer. The model is validated using data from a base station of China Unicom in a certain city. Experiments demonstrate that GCN+GRU model can reduce prediction errors compared to other mainstream prediction models, and the model's prediction accuracy is significantly improved.

Keywords:

Graph neural networks; Traffic forecasting; Convolutional neural networks; Gate recurrent unit

引用格式:郭超,陈佳,汪悦. 基于图卷积神经网络的无线基站流量预测研究[J]. 邮电设计技术,2023(6):36-40.

1 研究背景

为支撑无线网络基站 License 资源动态调配及基站智能节能场景,需要对无线基站未来多个时刻流量做出精准预测,根据预测的结果可以提前部署进行网络资源优化、设备降耗节能以及精准运维。而当前对无线网络基站的通信流量预测主要是单个节点预测,很少考虑节点与节点之间的连接关系,模型的预测准确度不高,严重制约智能化运营策略的实施效能。随着人工智能技术在通信领域的应用愈加广泛,可表示

为节点之间复杂关系的拓扑图结构数据要素价值愈发凸显,加上通信网络设备之间天然的拓扑连接结构,图神经网络算法在复杂网络场景下可表现出更优的决策能力,大幅度提高网络智能运营效能。

2 研究综述

2.1 多变量时序预测方法

当前对无线网络基站流量预测主要为孤岛式节点流量预测,即从单个节点的时间序列数据出发,根据目标节点的历史数据,建立每个节点当前特征与之前特征随时间变化的函数,主要分为2种类型。一种是线性预测模型,常用的有移动平均模型MA、自回归

收稿日期:2023-04-02

模型AR、自回归移动平均ARIMA及其相关改进模型,这类模型的优点是较为简单,可解释性强,缺点是无法进行多变量预测。另外一种是非线性预测模型。随着人工智能技术的发展,出现了基于特征工程的机器学习算法,常见的有逻辑回归、LightGBM等梯度提升模型,这类算法在线性模型的基础上提高了模型的复杂度,模型准确率也有一定幅度提升,同时也衍生了一些基于数据驱动的深度预测模型,常见的有循环神经网络(RNN)及其改进模型LSTM等,通常模型可解释性差,需要大量的训练数据且训练耗时。

以上模型均只考虑了多变量时序数据的时间依赖特征,没有考虑变量与变量之间的邻接关系,模型预测准确性有待提升。针对无线网络基站流量预测任务,考虑到用户无线网络信号连接的基站会随着位移的改变发生切换,一定程度上可以认为基站与邻居基站之间存在某种强连接关系,因此本文引入了构建基站邻接关系的图神经网络预测方法。

2.2 图神经网络(GNN)

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表现不佳,其中最主要的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,每个节点又都可能不同数量的相邻节点,导致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用于处理图数据的神经网络结构。

图神经网络可以划分为五大类别,分别是:图卷积网络(Graph Convolution Networks, GCN),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的新表示;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;图自动编码器(Graph Autoencoders),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;图生成网络(Graph Generative Networks),通过循环网络、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;图时空网络(Graph Spatial-temporal Networks),可同时捕捉时空图的时空相关性,将GCN与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。

3 时空图神经网络算法模型

本文以无线基站为节点进行建模分析,提出了GCN与门控循环单元(GRU)组合的时空图神经网络预测模型GCN+GRU。首先根据基站地理位置构建预定义网络拓扑图,并加入自适应学习方法对网络拓扑进行优化补全,完善基站之间潜在邻居连接关系,其次利用图卷积来提取基站之间的空间依赖关系,聚合目标节点以及邻居节点信息,然后将具有空间特征的数据输入到GRU网络中,提取无线基站网络流量的时间特征,最后通过全连接层得到预测结果。模型整体架构及建模步骤如图1所示。




图1 模型整体架构及建模步骤

3.1 数据采集及预处理

a) 基站位置数据。以基站为目标节点,采集基站经纬度地理位置数据用于构建预定义网络拓扑图。

b) 基站特征数据。采集基站不同时刻网络流量 f_i 和平均连接用户数 u_i ,同时考虑到小区流量数据走势的日周期性,增加一列时刻特征维度 t_i ,则无线基站特征矩阵 $X=(f_i, u_i, t_i) \in R^{N \times P \times 3}$ (N 为节点数量, P 为节点属性特征数量,也是历史时间序列的长度,3为通道数),其中 $t_i = \frac{i}{24}$ ($i = 0, 2, 3 \dots 23$)。

c) 数据预处理。首先按照一般的统计方法对小区流量数据进行数据清洗(去重、去异常值、线性差值

补全), 然后运用Z-score方法对数据进行标准化。公式为 $x'_t = \frac{x_t - \mu}{\sigma}$, 其中 x_t 为 t 时刻原始流量值, μ 为均值, σ 为标准差。

3.2 训练集、验证集、测试集划分

将归一化后的小区流量数据和时刻特征数据进行训练集、验证集、测试集划分, 分割比例分别为7:1:2。

3.3 构建预定义拓扑图及自适应学习优化补全

a) 基于基站地理位置数据, 计算小区的地理距离, 设定距离阈值为2 km, 小于等于阈值则认为基站存在连接关系, 构建预定义网络拓扑图, 抽取对称的邻接矩阵 A_0 , 有连接关系的位置元素为1, 其余为0。

b) 加入自适应学习, 从时序数据中自适应地捕获变量之间隐藏的空间关系, 优化补全预定义图结构, E_1 和 E_2 是随机初始化的2个节点的embedding。

$$A_{\text{adp}} = \text{softMax} \left[\text{Relu} \left(E_1 E_2^T \right) \right] \quad (1)$$

$$A = A_{\text{adp}} + A_0 \quad (2)$$

3.4 时空图神经网络预测模型

3.4.1 构造 1×1 卷积层

首先利用 1×1 卷积层对基站输入特征数据 $X \in R^{N \times P \times 3}$ 进行降维处理, 卷积核维度为 $1 \times 1 \times 3$, 卷积核个数为1, 基站输出特征 $X' \in R^{N \times P}$, N 为基站节点数量, P 为历史时间序列长度。

3.4.2 GCN提取空间依赖特征

利用GCN模型从拓扑图中提取空间依赖特征, 聚合目标节点和邻居节点特征信息。给定一个无向图的邻接矩阵 A 和特征矩阵 X , GCN模型通过在傅里叶域中构造一个过滤器, 作用在图节点上, 通过一阶邻域捕获节点之间的空间特征, 叠加多个卷积层可以捕获多阶邻域节点特征, 传播公式如下:

$$H^{l+1} = \sigma \left(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^l W^l \right) \quad (3)$$

其中, $\tilde{A} = A + I$ (I 为单位矩阵), $\tilde{D}$ 为 $\tilde{A}$ 的度矩阵, H 是每一层的特征矩阵, σ 是非线性激活函数。

大量实验表明, 使用2层或者3层图卷积已经可以得到很好的结果了, 且随着网络深度的加深会造成过度平滑和计算复杂的问题, 所以本文选择2层GCN模型捕获空间依赖关系, 可以表示为式(4)。

$$f(A, X) = \sigma \left[\hat{A} \times \text{ReLU} \left(\hat{A} X W^0 \right) \times W^1 \right] \quad (4)$$

其中, $\hat{A} = \tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2}$, X 为输入特征矩阵且 $X \in R^{N \times P}$ (N 为节点数量, P 为节点属性特征的数量, 也是历史时间序列的长度), $W^0 \in R^{P \times H}$, $W^1 \in R^{H \times T}$, H 为

隐藏神经元个数, T 为预测长度。

3.4.3 GRU提取时间依赖特征

GRU网络是另一种基于门控制的循环神经网络, 是LSTM网络的变体, 同样可以解决RNN网络中的长期依赖问题。GRU网络中没有LSTM网络中的内部、外部状态划分, 而是通过直接在当前网络状态 h_t 和上一时刻的网络状态 h_{t-1} 之间添加一个线性的依赖关系解决梯度消失和梯度爆炸的问题。GRU的网络结构比LSTM简单, 只有2个门(更新门和重置门), 参数较少, 训练能力较快。因此本文选择利用GRU网络从基站流量数据中提取时间相关性, 其结构如图2所示。




图2 GRU网络框架图

图2中 h_{t-1} 表示 $t-1$ 时刻的隐藏状态, x_t 表示 t 时刻无线基站流量信息, r_t 和 z_t 分别表示重置门(红色框)和更新门(蓝色框), 重置门控制前一状态信息传入候选状态 $\tilde{h}_t$ 的比例, 更新门控制前一状态信息传入新状态 h_t 中的比例。总结来说, GRU网络通过获取 $t-1$ 时刻的隐藏状态与当前时刻基站的流量信息得到 t 时刻的基站流量信息。

3.4.4 时空图卷积模块

将上述GCN和GRU网络组合形成时空图卷积模块, 同时提取无线基站流量数据的空间和时间依赖特征。图3为时空图卷积模块的具体结构, 模块的计算过程如下, 其中 $f(A, x_t)$ 为前面介绍的卷积过程, 即式(4), w 和 b 为训练过程每一步骤的权重和偏移量, 其他标识含义同上述GRU模块。

$$r_t = \sigma \left\{ w_r \left[f(A, x_t), h_{t-1} \right] + b_r \right\} \quad (5)$$

$$z_t = \sigma \left\{ w_z \left[f(A, x_t), h_{t-1} \right] + b_z \right\} \quad (6)$$

$$\tilde{h}_t = \tanh \left\{ w_h \left[f(A, x_t), r_t \times h_{t-1} \right] + b_h \right\} \quad (7)$$

$$h_t = z_t \times h_{t-1} + (1 - z_t) \times \tilde{h}_t \quad (8)$$




图3 时空图卷积模块结构

3.5 全连接层

将提取完时空特征的数据输入一个全连接层,神经元个数为 T , T 为数据预测长度。

3.6 模型评价指标

针对网络流量预测任务,本文采用平均绝对误差(Mean Absolute Error, MAE)、加权平均绝对误差百分比(Weighted Mean Absolute Percentage Error, WMAPE)、均方误差(Mean Square Error, MSE)和根均方误差(Root Mean Square Error, RMSE)评价指标,其中重点关注WMAPE,预测误差百分比更能直观反映模型的优劣。

a) MAE:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (9)$$

b) WMAPE,在MAPE的基础上得来:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \quad (10)$$

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

c) MSE:

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

d) RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (13)$$

4 实证分析

基于某市部分基站数据进行模型验证,提取了2022年6月—9月基站的地理位置数据和流量特征数据,经过数据清洗及建模分析,共有2 136个基站。

基于基站地理位置数据,按照第3.3节中的方法构建预定义网络拓扑图,抽取对称邻接矩阵 A , $A=(2\ 136, 2\ 136)$ 。基站流量特征数据方面,以预测基站下行流量为目标,首先对流量特征数据进行滑窗操作,然后按照7:1:2的比例划分为训练集、验证集与测试集, $input_size=24$ [节点属性特征数量,即式(4)中的

$P=24$], $output_size=12$ (预测基站未来12个时刻的下行流量,即 $T=12$)。

为检验模型预测效果,构建了ARIMA、LightGBM等传统时序预测方法作为baseline models,3个算法模型预测效果及评价结果如图4所示。

首先从单个基站预测效果来对比,图4是从2 136个基站中随机抽取的9个基站预测效果图,红色是基站真实下行流量数据 y_true ,共36个时刻数据,绿色是ARIMA模型预测数据,蓝色是LightGBM模型预测数据,黄色是时空图神经网络预测数据,3个模型都是根据前24个时刻的流量数据预测未来12个时刻的流量。通过预测效果图可以直观地看出,对于大部分基站来说时空图神经网络算法预测的效果明显优于另外2个baseline models,只有少部分基站预测效果基本持平。

其次分析模型的整体评价结果,表1是不同算法模型的评价结果对比,主要比较各模型的WMAPE指标(相对误差百分比概念最为客观合理,数值越小越好)。时空图神经网络算法的预测效果表现最佳,当Horizon=12时(预测长度为12),预测误差WMAPE=31.07%,效果提升12.68%(预测误差由LightGBM的35.58%下降到31.07%),预测结果显著优于另外2个模型。

为了验证时空图神经网络算法模型预测效果的稳定性,本文将预测长度提高。当Horizon=24时,模型预测效果依然表现最佳,预测误差WMAPE=33.8%,且和另外2个模型对比,效果提升幅度也有所扩大,效果提升13.16%(预测误差由LightGBM的38.92%下降到33.8%),由此可以看出时空图神经网络算法稳定性也较高。

5 结论及展望

5.1 主要结论

基于基站地理位置构建了预定义网络拓扑图,利用图卷积+GRU充分提取了潜在的时空关联,对无线网络基站流量进行了多步预测,预测误差显著降低,预测准确率大幅度提升。由此可见,引入邻居特征、提取空间依赖关系的图神经网络预测方法对基站流量预测有很好的应用效果。

5.2 未来展望

通过基站地理距离抽取了静态无向预定义网络拓扑图,构建了对称的邻接矩阵,这样做有利于权值




图4 不同算法模型预测效果

表1 不同算法模型评价结果对比

Datasets	Models	MAE	WMAPE/%	MSE	RMSE
Downlink_flow (预测长度 Horizon=12)	ARIMA	1.504 0	52.33	7.284 2	2.698 9
	LGBM	1.358 0	35.58	5.298 1	2.301 8
	GCN+GRU	1.264 7	31.07	4.978 4	2.231 2
Downlink_flow (预测长度 Horizon=24)	ARIMA	1.534 2	55.20	7.314 7	2.704 5
	LGBM	1.382 6	38.92	5.437 8	2.331 9
	GCN+GRU	1.332 9	33.80	5.158 4	2.271 2

共享、参数共享,减少模型参数个数及训练时间,但是考虑到基站与基站之间实际的切换关系,边与边的权重可能不太一样,因此可能没有充分利用边的信息,导致模型预测效果有一定程度损失。未来可考虑引入 Attention 机制,采取图注意力网模型(GAT),为目标基站不同的邻居节点分配不同的权重,继续进行模型预测效果研究。

参考文献:

[1] 王菁,文晓东,王春枝. 基于动态扩散卷积交互图神经网络的网络

流量预测[J]. 计算机应用研究,2023,40(1):97-101.

- [2] 郑友康,王红蕾. 基于深度学习的短时道路交通流量预测研究[J]. 软件,2020,41(5):72-74.
- [3] WU Z H, PAN S R, CHEN F W, et al. A comprehensive survey on graph neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(1): 4-24.
- [4] 杜圣东,李天瑞,杨燕,等. 一种基于序列到序列时空注意力学习的交通流预测模型[J]. 计算机研究与发展, 2020, 57(8): 1715-1728.
- [5] 金仲明. 基于时空图神经网络的交通预测[J]. 软件和集成电路, 2019(7):36-37.
- [6] 朱虹锦,颜文勇. 基于图神经网络的城市交通流量预测[J]. 电脑知识与技术, 2021, 17(2):154-155, 160.

作者简介:

郭超,毕业于北京工业大学,工程师,硕士,主要从事网络智能运营AI算法、图智能技术应用研究工作;陈佳,毕业于北京邮电大学,工程师,硕士,主要从事前端技术开发、网络AI算法、图智能技术应用研究工作;汪悦,毕业于北京邮电大学,工程师,博士,主要从事用户智慧运营AI算法、图智能技术应用研究工作。