

面向高速公路流量预测的自适应时空图卷积循环神经网络

阮鸿柱¹, 王金宝¹, 杜梦辉²

(1.云南省综合交通发展中心, 云南 昆明 650031;

2.北京交通大学, 北京 100044)

✉ qtzrhz@163.com; 583454013@qq.com; 21140020@bjtu.edu.cn



摘要:为更全面地建模交通数据中的空间相关性,实现更准确地预测高速公路流量,提出一种自适应时空图卷积循环神经网络。利用扩散图卷积和自适应邻接矩阵整合成的自适应图卷积网络建模交通数据中的空间相关性,采用门控循环单元学习交通数据中的时间相关性,实现多时间步车流量预测。基于桂林市高速公路网真实交通数据集的实验结果表明,相比于用于对比的最优方法,该方法的三个误差评价指标,即平均绝对误差、均方根误差、平均绝对百分比误差分别降低了约17.6%、18.6%和10.8%,优于用于对比的方法,该方法可以更准确地预测高速公路的流量。

关键词:智能交通;流量预测;自适应图卷积网络;时空相关性

中图分类号:TP391.4 **文献标志码:**A

Adaptive Spatio-Temporal Graph Convolutional Recurrent Neural Network for Expressway Traffic Flow Prediction

RUAN Hongzhu¹, WANG Jinbao¹, DU Menghui²

(1.Yunnan Transportation Development Center, Kunming 650031, China;

2.Beijing Jiaotong University, Beijing 100044, China)

✉ qtzrhz@163.com; 583454013@qq.com; 21140020@bjtu.edu.cn

Abstract: In order to more comprehensively model the spatial correlation in traffic data and achieve more accurate expressway traffic flow prediction, this paper proposes an adaptive spatio-temporal graph convolutional recurrent neural network. The adaptive graph convolutional network which is integrated by the diffusion graph convolution and the adaptive adjacent matrix is used to model the spatial correlation in traffic data. Gated recurrent unit is adopted to learn the temporal correlation in traffic data, and the multi-time step traffic flow prediction is realized. The experimental results based on the real traffic dataset of Guilin expressway network show that, compared with other optimal methods used for comparison, the three error evaluation indicators of the method, namely, the average absolute error, the root mean square error, and the mean absolute percentage error, have decreased by about 17.6%, 18.6%, and 10.8% respectively, which is superior to methods for comparison. Therefore, this method can achieve more accurate expressway traffic flow prediction.

Key words: intelligent transportation; flow prediction; adaptive graph convolution network; spatio-temporal correlation

0 引言(Introduction)

准确的高速公路流量预测对提升智能交通系统的安全性、稳定性和效率至关重要。受多种复杂因素的影响,例如道路拓扑结构、可见度、降水量等,交通数据中存在复杂的时空相关

性^[1-3]。基于图卷积神经网络的深度学习方法可以建模交通数据中的动态时空相关性,但是这些方法需要根据距离等特征预先定义邻接关系图建模空间相关性^[4-8]。本文通过对桂林市路网数据集集中的流量数据进行分析发现,根据有限先验知识构建

的邻接关系图难以反映完整的空间相关性^[9-10]。基于此,本文基于数据驱动的方式生成自适应邻接矩阵,在此基础上设计了一个自适应图卷积网络,以便更全面地捕获交通数据中的空间相关性。

为更好地捕获具有较大时间跨度的交通数据间的依赖性,采用门控循环单元建模时间相关性,将其与自适应图卷积网络整合成具有编码器-解码器结构的自适应时空图卷积循环神经网络(ASTGCRN)实现准确地预测多时间步流量。

1 流量数据特性分析 (Analysis of flow data features)

高速公路网承载各种交通工具的运行,其流量的变化与人们的生活出行紧密相关,表现出一定的时空分布规律,分析这种规律是对交通流量进行有效预测的前提与基础。本文对桂林高速公路网的流量变化做以下分析:(1)相邻节点流量变化趋势相近,但数据尺度可能会有差异。如图1所示,“粟家6-灵川西3”和“马面立交2-桂林南3”断面在邻接图中具有邻接关系,它们的断面流量分布的整体趋势相近,但平均值与峰值水平相差较大。在很多工作中,研究对象选取的是普通的城区道路,采样点的密度很大,并且采样点之间的距离很短,所以相邻的节点流量数值相近、变化更平缓;但是,本文选取的高速公路的断面总是伴随互通与收费站出现,采样点之间的距离相隔较远且稀疏,流量变化与节点所处地段密切相关,所以流量变化会随着总车流量的整体变化而表现出趋势上的相似性,但也会因进出高速车流量的不同,导致不同采样点在数据尺度上存在差异性。(2)路网中距离相隔较远的两个节点也可能表现出较强的相关性。如图1中“粟家6-灵川西3”与“兴桂路起点1-兴安城南5”断面虽然没有邻接关系,但是都处于同一方向的高速路线上,其流量变化也表现出相似的趋势。由于先验知识有限,因此根据距离等特征预先定义邻接关系图难以捕获交通数据中完整的空间相关性。




图1 断面流量变化趋势图
Fig.1 Traffic flow trend chart of sections

为解决以上问题,本文使用自适应图卷积网络学习路网交通数据中的空间相关性,将其与门控循环单元整合,用于学习交通数据中复杂的时空相关性,进而实现准确的流量预测。

2 自适应时空图卷积循环神经网络 (Adaptive spatio-temporal graph convolutional recurrent neural network)

本文提出面向高速公路流量预测的自适应时空图卷积循环神经网络,如图2所示。以多个时间步的图信号矩阵为输入,利用自适应图卷积捕获路网交通数据中的空间相关性,利用门控循环单元捕获数据中的时间相关性,将编码后的节点嵌入表示输入门控循环单元构成的解码器,预测多个时间步的交通流量。




图2 自适应时空图卷积循环神经网络

Fig.2 Adaptive spatio-temporal graph convolutional recurrent neural network

2.1 输入层

将经过数据预处理得到路网 G 中所有节点在各个时间步的特征作为输入,具体输入特征构造方式如下:在第 t 个时间间隔内,观测到高速公路路网 G 上的图信号用矩阵 $\mathbf{X}_t = (\mathbf{x}_{t,1}, \mathbf{x}_{t,2}, \dots, \mathbf{x}_{t,N})^T \in \mathbb{R}^{N \times C}$ 表示,其中 N 表示节点数量, $\mathbf{x}_{t,v} = (x_{t,v}^{\text{upper}}, x_{t,v}^{\text{lower}}, x_{t,v}^{\text{flow}}, x_{t,v}^{\text{prec}}, x_{t,v}^{\text{vis}}, x_{t,v}^{\text{weekday}}, x_{t,v}^{\text{ts}}) \in \mathbb{R}^{1 \times C}$ 表示第 t 个时间间隔内节点 v 的 C 个观测量的取值。其中, $x_{t,v}^{\text{upper}}$ 为该时间间隔内节点上游路段车速, $x_{t,v}^{\text{lower}}$ 为该时间间隔内节点下游路段车速, $x_{t,v}^{\text{flow}}$ 为该时间间隔内节点流量值, $x_{t,v}^{\text{prec}}$ 为该时间段内节点处平均降水量, $x_{t,v}^{\text{vis}}$ 为该时间段内节点处可见度, $x_{t,v}^{\text{weekday}}$ 为该时间段对应的周中日期数量, $x_{t,v}^{\text{ts}}$ 为该时间段对应的时间片。将每个时间步的图信号矩阵通过全连接层映射为矩阵 $\mathbf{Y}_t \in \mathbb{R}^{N \times d_h}$, d_h 为节点嵌入表示的维度。

2.2 自适应图卷积网络

图卷积网络(Graph Convolutional Network, GCN)是一种用于处理非欧式结构数据的神经网络。现实中的高速公路路网是不规则的,可以视作非欧式结构,并且可以使用图卷积网络处理高速公路路网数据,捕获不同检测点交通数据的空间相关性,提升交通数据预测的精度。图卷积运算可以用一阶切比雪夫多项式展开实现很好的逼近,并且可以推广到高维图卷积:

$$\mathbf{Z}_t = \tilde{\mathbf{A}} \mathbf{Y}_t \mathbf{W} \quad (1)$$

其中, $\tilde{\mathbf{A}} \in \mathbb{R}^{N \times N}$ 为标准化后的邻接矩阵, $\mathbf{Y}_t \in \mathbb{R}^{N \times d_h}$ 和 $\mathbf{Z}_t \in \mathbb{R}^{N \times d_h}$ 分别为第 t 个时间间隔内图卷积网络的输入和输出, $\mathbf{W} \in \mathbb{R}^{d_h \times d_h}$ 为映射矩阵。

在图卷积网络的基础上,扩散图卷积层已被证明其在时空数据建模中更有效。为表示 K 个有限步的图信号扩散过程,扩散图卷积层可表示为

$$\mathbf{Z}_t = \sum_{k=0}^K \mathbf{P}^k \mathbf{Y}_t \mathbf{W}_k \quad (2)$$

其中, $\mathbf{P}^k$ 表示转移矩阵的幂级数,对于无向图, $\mathbf{P} = \tilde{\mathbf{A}} / \text{rowsum}(\tilde{\mathbf{A}})$, $\text{rowsum}(\tilde{\mathbf{A}})$ 表示对矩阵 $\tilde{\mathbf{A}}$ 逐行进行元素求和,得到与 $\tilde{\mathbf{A}}$ 行数相同的向量。在本文研究的高速公路流量预测问题中,以检测点为节点构成的图是有向的,因此图信号得到的扩散过程是有向的,分为前向和后向扩散。前向转移矩阵可定义为 $\mathbf{P}_f = \tilde{\mathbf{A}} / \text{rowsum}(\tilde{\mathbf{A}})$, 后向转移矩阵 $\mathbf{P}_b = \tilde{\mathbf{A}}^T / \text{rowsum}(\tilde{\mathbf{A}}^T)$, 为同时建模图信号的前向和后向扩散过程,可通过对前向和后向转移矩阵求和表示扩散图卷积层:

$$\mathbf{Z}_t = \sum_{k=0}^K (\mathbf{P}_f^k \mathbf{Y}_t \mathbf{W}_{k1} + \mathbf{P}_b^k \mathbf{Y}_t \mathbf{W}_{k2}) \quad (3)$$

扩散图卷积网络需要根据相似度或距离预先定义邻接关系矩阵,用于捕获交通数据的空间相关性,由于先验知识有限,因此预定义图中具有邻接关系的节点在流量变化规律上可能并没有明显的相关性;预定义图中不具有邻接关系的节点在流量变化规律上可能具有明显的相关性^[10]。为此,本文将扩散图卷积层与自适应邻接矩阵相结合,以便全面且自适应地捕获交通数据的空间相关性。自适应邻接矩阵的构造方法如下:为所有节点随机初始化两个可学习的节点嵌入表示矩阵 $\mathbf{E}_1$ 和 $\mathbf{E}_2 \in \mathbb{R}^{N \times d_e}$, 其中 d_e 为嵌入表示的维度。自适应邻接矩阵 $\tilde{\mathbf{A}}_{\text{adp}}$ 定义为

$$\tilde{\mathbf{A}}_{\text{adp}} = \text{SoftMax}(\text{ReLU}(\mathbf{E}_1 \mathbf{E}_2^T)) \quad (4)$$

其中, $\mathbf{E}_1$ 表示原始节点的嵌入表示, $\mathbf{E}_2$ 表示目标节点的嵌入表示。通过 $\mathbf{E}_1$ 与 $\mathbf{E}_2$ 的乘积,可以得到原始节点和目标节点的空间相关性权重。利用 ReLU 激活函数过滤掉相关性较弱的连接关系。SoftMax 函数用于标准化自适应邻接矩阵。因此,标准化后的自适应邻接矩阵可以看作是潜在图信号扩散过程中的转移矩阵。通过将扩散图卷积层与自适应邻接矩阵相结合,本文使用如下自适应图卷积层,以数据驱动的方式学习路网交通数据的空间相关性:

$$\mathbf{Z}_t = \sum_{k=0}^K (\mathbf{P}_f^k \mathbf{Y}_t \mathbf{W}_{k1} + \mathbf{P}_b^k \mathbf{Y}_t \mathbf{W}_{k2} + \tilde{\mathbf{A}}_{\text{adp}} \mathbf{Y}_t \mathbf{W}_{k3}) \quad (5)$$

2.3 自适应时空图卷积循环神经网络

为实现准确的流量预测,除了学习不同位置交通数据的空间相关性,还需要捕获交通数据中的时间相关性。因此,本文将自适应图卷积网络与门控循环神经网络整合,以捕获数据中的时空相关性。在得到第 t 个时间间隔内聚合路网空间相关性的节点嵌入表示 $\mathbf{Z}_t \in \mathbb{R}^{N \times d_h}$ 后,将其作为门控循环单元在第 t 步的输入,门控循环单元中重置门的计算公式定义为

$$\mathbf{r}_t = \sigma(\mathbf{Z}_t \mathbf{W}_r + \mathbf{h}_{t-1} \mathbf{U}_r + \mathbf{b}_r) \quad (6)$$

门控循环单元中更新门的计算公式定义为

$$\mathbf{z}_t = \sigma(\mathbf{Z}_t \mathbf{W}_z + \mathbf{h}_{t-1} \mathbf{U}_z + \mathbf{b}_z) \quad (7)$$

第 t 步的候选隐藏状态 $\hat{\mathbf{h}}_t$ 的计算为

$$\hat{\mathbf{h}}_t = \tanh(\mathbf{Z}_t \mathbf{W}_{zh} + (\mathbf{r}_t \odot \mathbf{h}_{t-1}) \mathbf{W}_{hh} + \mathbf{b}_z) \quad (8)$$

时间步 t 的隐藏状态 $\mathbf{h}_t$ 的计算基于当前时间步的更新门 $\mathbf{z}_t$ 组合上一时间步的隐藏状态 $\mathbf{h}_{t-1}$ 和当前时间步的候选隐藏状态 $\hat{\mathbf{h}}_t$:

$$\mathbf{h}_t = \mathbf{z}_t \odot \mathbf{h}_{t-1} + (1 - \mathbf{z}_t) \odot \hat{\mathbf{h}}_t \quad (9)$$

在输入最后一个时间步 T_h 的图信号矩阵后,得到对时空数据编码后的隐藏状态 $\mathbf{h}_{T_h} \in \mathbb{R}^{N \times d_h}$, 将其输入由门控循环神经构成的解码器,逐步输出未来 T_p 个时间步的流量矩阵 $\mathbf{F} = (\mathbf{f}_{t+1}, \mathbf{f}_{t+2}, \dots, \mathbf{f}_{t+T_p}) \in \mathbb{R}^{N \times T_p}$ 。

2.4 模型训练

模型训练的损失函数使用均方误差函数,优化算法选用 Adam 算法,Adam 算法是一种基于动量思想的自适应随机梯度下降算法,在迭代前计算梯度的两阶动量并计算滑动平均值,并用于更新参数。

3 实验与结果(Experiments and results)

实验使用桂林市路网区域的交通数据,共有 36 个节点,从 2022 年 1 月 1 日到 2 月 28 日共 59 天,以 1 h 为单位聚合每个节点的流量。按 6:2:2 的比例划分训练集、验证集和测试集,使用训练集的均值和标准差对所有数据进行归一化,输入时间步 T_h 设置为 8,预测时间步 T_p 设置为 8。

3.1 评价指标

为验证本文提出模型的预测性能,研究人员选取了回归任务常使用的平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Squared Error, RMSE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)。

3.2 基准线模型

选取以下基准线模型与本文提出的模型进行对比:(1)HA:历史平均模型,即对每一个节点都以前 T_h 个时间步流量的平均值作为下一时间步的预测值;(2)GCN^[11]:标准图卷积神经网络,使用谱域中对角化的线性算子替代经典卷积算子实现卷积操作;(3)RNN^[12]:循环神经网络,能很好地挖掘数据中的时序信息与语义信息,这里使用门控循环单元(GRU)作为编码器和解码器;(4)GMAN^[4]:图多注意网络,借助自注意力机制实现了空间与时间维度的注意力模块,多个时空注意力模块堆叠组成编码器与解码器;(5)AGCRN^[10]:自适应图卷积循环神经网络,使用数据自适应图和自适应图卷积循环神经网络模块,为每个节点都学习了一个特定的参数空间,挖掘流量序列中不同的模式。

3.3 参数设置

模型扩散图卷积的扩散维度设置为 2,自适应图卷积模块的嵌入维度设置为 10,堆叠的图卷积模块数设置为 2,图卷积隐藏维度设置为 64,门控循环神经网络层数设置为 2,循环单元隐藏状态的维度设置为 64,解码器中的全连接层数设置为 1,训练时,小批量大小设置为 8,初始学习率设置为 0.001,早停步数设置为 10。

3.4 实验结果分析

按上述使用不同的方法在相同场景下进行预测,结果如表1所示。

表1 不同方法实验结果比较

Tab.1 Comparison of experimental results of different methods

模型	MAE	RMSE	MAPE/%
HA	138.79	168.59	80.70
GCN	111.68	152.15	62.98
RNN	61.41	81.51	28.99
GMAN	97.18	130.59	67.42
AGCRN	57.97	83.88	24.28
ASTGCRN	47.79	66.38	21.66

从表1中看出,效果最差的是历史平均模型(HA),其次是仅使用了图邻接关系的GCN,擅长捕获节点间特征相关性的GMAN在训练过程中产生了过拟合,最终结果也只是稍好于GCN,原因是节点间数据尺度的差异导致了过拟合。RNN仅关注数据中的时序信息,却在本任务中表现出色,说明高速公路数据具有较强的周期性,在门控神经循环网络中嵌入了自适应图卷积的AGCRN表现则好于RNN,这也证明节点间存在空间相关性,并且自适应图卷积能在一定程度上解决不同位置流量数据尺度不同的问题,而ASTGCRN一方面通过扩散卷积学习节点与更高阶邻接节点间的相关性,通过自适应图卷积学习不同尺度数据间的相关性,很好地捕捉到了空间相关性,另一方面使用基于门控循环神经网络的编码器和解码器捕获数据中的时间相关性,效果优于其他最优基准线模型,平均绝对误差、均方根误差、平均绝对百分比误差分别降低了约17.6%、18.6%和10.8%。

为了更全面地分析本文提出方法(ASTGCRN)的优势,对各模型在“蒙村互通3-阳朔高田5”断面从某年2月24日23时到2月25日23时时间区段的交通流量预测值和真实值(truth)进行可视化(如图3所示)。从图3中可以看出,各个基准线模型基本保持了与真实值相似的变化趋势,但在数值水平上相差较大。从中也能直观地看到RNN、AGCRN和ASTGCRN要优于其他三个模型,而在车流量整体水平的预测上ASTGCRN优于RNN。当车流量值在短时间内发生较大波动时,如2月25日15时到2月25日17时时间区段,ASTGCRN的预测效果优于AGCRN。









图3 各模型在“蒙村互通3-阳朔高田5”断面上的交通流量预测结果

Fig. 3 Traffic flow prediction results of each model on the "Mengcun Hutong 3-Yangshuo Gaotian 5" section

3.5 消融实验分析

为进一步分析模型中各个组件的作用,设计了原模型 ASTGCRN 的三个变体进行消融实验,将这三个变体与 ASTGCRN 进行比较,变体的描述如下。

ASTGCRN_wo_diff:在 ASTGCRN 的基础上,去掉扩散图卷积模块,考查模型是否学习到了高阶邻接信息。

ASTGCRN_wo_adap:在 ASTGCRN 的基础上,去掉自适应图卷积模块,考查模型是否克服了不同节点交通数据的尺度差异性,并学习到了更全面的空间相关性。

ASTGCRN_wo_GRU:在 ASTGCRN 的基础上,使用全连接层替代以门控循环单元为基础的编解码器。

消融实验的结果如表 2 所示,在去掉扩散图卷积模块 (ASTGCRN_wo_diff)后,模型的预测准确性要稍好于去掉之前,而去掉自适应图卷积模块 (ASTGCRN_wo_adap)后模型预测准确性显著降低,证明自适应图卷积很好地捕获到了交通数据中的空间相关性,而扩散图卷积在本实验中的作用并不大,在高阶邻居节点的信息得到融合的情况下,预定义图结构的信息可能对空间相关性的学习产生了干扰,使得扩散图卷积没能充分发挥作用。在去掉以门控循环单元为基础的编解码器 (ASTGCRN_wo_GRU)后,模型预测准确性大幅下降,这证明门控循环单元对于学习数据在时间维度的变化规律是非常重要的。

表2 消融实验结果

Tab.2 Results of the ablation experiment

模型	MAE	RMSE	MAPE/%
ASTGCRN_wo_diff	45.97	63.97	21.19
ASTGCRN_wo_adap	54.31	74.65	26.99
ASTGCRN_wo_GRU	60.66	81.58	33.70
ASTGCRN	47.79	66.38	21.66

4 结论 (Conclusion)

本文通过分析桂林路网中高速公路流量的时空分布,针对其分布特性提出了一种自适应时空图卷积循环神经网络模型,该模型基于自适应图卷积网络解决了根据有限先验知识构建的邻接关系图难以反映交通数据中完整空间相关性的问题,并结合门控循环单元捕获了交通数据中复杂的时空相关性。将本文所提模型同其他常用的预测方法在桂林市高速公路网真实的交通数据集上进行了实验,实验结果表明本文所提模型的预测效果最优,并通过消融实验说明了提出方法的有效性。但是,该方法依然存在一些优化空间,例如可以考虑其他因素,如节假日、交通事故对车流量的影响,合理地量化这些因素可以作为优化模型的方向。

参考文献 (References)

[1] 汪鸣,彭舰,黄飞虎. 基于多时间尺度时空网络的交通流量预测模型[J]. 计算机科学,2022,49(8):40-48.
[2] 宋瑞蓉,王斌君,全鑫,等. 融合多维时空特征的交通流量预测模型[J]. 科学技术与工程,2021,21(31):13439-13446.

[3] 褚鹏宇,刘澜,尹俊淞,等. 融合时空信息的短时交通流预测[J]. 计算机工程与应用,2016,52(12):246-250.
[4] ZHENG C P,FAN X L,WANG C,et al. GMAN:a graph multi-attention network for traffic prediction[C]//ROSSI F. Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park,CA:AAAI,2020,34(1):1234-1241.
[5] GUO S N,LIN Y F,WAN H Y,et al. Learning dynamics and heterogeneity of spatial-temporal graph data for traffic forecasting[J]. IEEE Transactions on Knowledge and Data Engineering,2022,34(11):5415-5428.
[6] BAI J D,ZHU J W,SONG Y J,et al. A3T-GCN:attention temporal graph convolutional network for traffic forecasting[J]. ISPRS International Journal of Geo-Information, 2021,10(7):485.
[7] GUO S N,LIN Y F,FENG N,et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//CONITZER V. Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park:AAAI, 2019,33(1):922-929.
[8] SONG C,LIN Y F,GUO S N,et al. Spatial-temporal synchronous graph convolutional networks:a new framework for spatial-temporal network data forecasting[C]//ROSSI F. Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park,CA:AAAI,2020,34(1):914-921.
[9] LIU F,WANG J Y,TANG X,et al. Adaptive graph convolutional network for PolSAR image classification[J]. IEEE Transactions on Geoscience and Remote Sensing,2022,60: 1-14.
[10] BAI L,YAO L N,LI C,et al. Adaptive graph convolutional recurrent network for traffic forecasting[DB/OL]. (2020-10-22)[2021-10-05]. <https://arxiv.org/abs/2007.02842>.
[11] ZHAO L,SONG Y J,ZHANG C,et al. T-GCN:a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems,2020,21(9):3848-3858.
[12] DAI G W,MA C X,XU X C. Short-term traffic flow prediction method for urban road sections based on space-time analysis and GRU [J]. IEEE Access, 2019, 7: 143025-143035.

作者简介:

阮鸿柱(1993-),男,硕士,高级工程师。研究领域:智慧高速,交通信息工程。
王金宝(1973-),男,本科,正高级工程师。研究领域:智慧交通。
杜梦辉(1999-),男,硕士生。研究领域:智慧交通。