

动态交通流量预测的时空注意力图卷积网络

邹正标^{1,2}, 刘毅志^{1,2*}, 廖祝华^{1,2}, 赵肄江^{1,2}

(1.湖南科技大学计算机科学与工程学院, 湖南湘潭 411201; 2.湖南科技大学服务计算与软件服务新技术湖南省重点实验室, 湖南湘潭 411201)

摘要:针对现有交通流预测方法大多忽略时空耦合相关性、时空变化性以及外部特征对预测结果准确性的影响,提出一种动态交通流量预测的时空注意力图卷积网络(attention-based spatio-temporal graph convolutional network, ATST-GCN)模型。提出基于注意力的双向门控循环单元结构,从动态空间序列中提取时间相关性;构建带残差链接的多层图注意力网络(graph attention network, GAT)卷积模块,深入挖掘动态空间相关性;融合时变特征与时常特征,充分利用外部静态特征的共同作用。采用PeMS数据集对交通流量预测的准确度进行验证,试验结果表明:本研究方法能够有效提高交通流量预测精度,优于现有的多数先进方法。在PeMS08和PeMS03数据集上,本研究方法相对STSGCN模型分别提高13.44%和10.96%,相对T-GCN模型分别提高21.41%和21.32%,相对STGCN模型分别提高8.04%和6.55%,相对DMSTGCN模型分别提高3.23%和2.80%,相对Trendformer模型分别提高2.29%和2.00%。

关键词:智能交通系统;交通流量预测;注意力机制;时空相关性;图卷积网络

中图分类号:U121 **文献标志码:**A

引用格式:邹正标,刘毅志,廖祝华,等.动态交通流量预测的时空注意力图卷积网络[J].山东大学学报(工学版),2024,54(5):50-61.

ZOU Zhengbiao, LIU Yizhi, LIAO Zhuhua, et al. Attention-based spatio-temporal graph convolutional network for dynamic traffic flow prediction[J]. Journal of Shandong University (Engineering Science), 2024, 54(5):50-61.

Attention-based spatio-temporal graph convolutional network for dynamic traffic flow prediction

ZOU Zhengbiao^{1,2}, LIU Yizhi^{1,2*}, LIAO Zhuhua^{1,2}, ZHAO Yijiang^{1,2}

(1.School of Computer Science and Engineering, Hunan University of Science and Technology, Xiangtan 411201, Hunan, China; 2. Hunan Provincial Key Laboratory of New Technologies in Service Computing and Software Services, Hunan University of Science and Technology, Xiangtan 411201, Hunan, China)

Abstract: Most existing methods ignored the impact of spatio-temporal coupling correlation, spatio-temporal variability, and external features on the accuracy of prediction results. In response to the above problems, this paper proposed a spatio-temporal attention graph convolution network model (attention-based spatio-temporal graph convolutional network, ATST-GCN) for dynamic traffic flow prediction. An attention-based bidirectional GRU structure was proposed to extract temporal correlation from dynamic spatial sequences. A multi-layer GAT (graph attention network, GAT) convolution module with residual connection was constructed to deeply extract the dynamic spatial correlation. Time-varying features and constant features were integrated to make full use of the joint effect of external static and dynamic features. The PeMS dataset was used for verification of the accuracy of traffic flow prediction using PeMs dataset. The experiment results showed that the method proposed in this paper could effectively improve the accuracy of traffic flow prediction and was better than most existing advanced methods. On the PeMS08 and PeMS03 datasets, the method of this study improved 13.44% and 10.96% relative to the STSGCN model, 21.41% and 21.32% relative to the T-GCN model, 8.04% and 6.55% relative to the STGCN model, 3.23% and 2.80% relative to the DMSTGCN model, 2.29% and 2.00% respectively relative to the Trendformer model.

Keywords: intelligent transportation system; traffic flow prediction; attention mechanism; spatio-temporal correlation; graph convolutional network

收稿日期:2023-10-17

基金项目:国家自然科学基金面上资助项目(41871320);湖南省重点研发计划资助项目(2023sk2081)

第一作者简介:邹正标(1998—),男,湖南岳阳人,硕士研究生,主要研究方向为智能交通。E-mail:zb_zou@sina.cn

*通信作者简介:刘毅志(1973—),男,湖南衡阳人,副教授,硕士生导师,博士,主要研究方向为多媒体内容分析与检索、时空数据挖掘、智慧城市、智慧医疗。E-mail:yizhi_liu@sina.cn

0 引言

为提高交通预测的准确性和效率,研究人员在过去的几十年中提出了许多方法和技术。这些方法包括基于统计模型的方法,如差分整合移动平均自回归 (autoregressive integrated moving average, ARIMA) 模型^[1]、支持向量回归 (support vector regression, SVR) 模型^[2];基于机器学习的方法,如神经网络 (neural network, NN)^[3]、支持向量机 (support vector machine, SVM)^[4]、决策树^[5];基于深度学习的方法,如卷积神经网络 (convolutional neural network, CNN)^[6]、循环神经网络 (recurrent neural network, RNN)^[7]。这些方法充分利用历史交通数据和其他相关信息建立预测模型,并通过训练和优化模型提高预测的准确性和鲁棒性。

过去的研究往往分别提取交通流的时间相关性与空间相关性,再融合成特征。这种方法忽略了交通流的时间与空间相关性之间的相互影响,未能将交通流的时空相关性作为一个整体考虑^[8]。例如,考虑某一时刻发生了一起重大交通事故,导致某一条道路的交通流量急剧增加。这个信息可能会在提取空间相关性模型中捕捉到,但在提取时间相关性模型中却未考虑,这是因为以往部分方法未能有效利用相邻路段的空间信息。为了综合捕获交通流的时空相关性,本研究采用图卷积网络对不同时间片的空间依赖关系进行动态建模,并构建一个基于注意力机制的双向门控循环单元 (gated recurrent unit, GRU) 结构,用于从动态的空间依赖关系序列中提取时间依赖性。通过考虑最近几个小时、前几天以及前几周的时间步长的信息,以获取最近、每日前后和每周前后的时间特征。

以往的研究在对交通流的空间相关性进行建模时,通常将不同道路之间的空间相关性视为静态不变的,实际上道路之间的空间相关性往往会随时间推移而不断变化^[9]。由于不同时间段的交通模式存在显著差异,这种变化通常难以充分追踪。以往方法在计算道路拓扑图的空间相关性之后就一直沿用,忽略了交通模式的动态演变^[10-11]。例如,在早晚(上下班高峰)和正午、深夜时段(休息期间),办公室和居民区的空间相关性可能呈现出不同的态势,上下班高峰时段的空间相关性可能大于休息时段。为了解决上述问题,本研究在图卷积网络的基础上,引入注意力机制实现对交通流预测在不同时间片的空间依赖关系进行动态建模,从而更

好地挖掘交通流数据中变化的空间相关性信息。

交通流量与速度之间呈现二元平衡关系,即这两个变量相互作用,相互影响,形成一种相对稳定的关联。因此,在进行交通流量预测时,有必要纳入速度信息,以全面平衡二者之间的关系。研究结果还表明,一些外部特征能够有效提升预测精度^[12-14],然而,以往的交通流预测工作较少考虑这些外部特征(如天气、道路类型、兴趣点 (point of interest, POI) 信息等)对预测结果的影响^[15-17]。针对这些问题,本研究设计1个融合模块,旨在整合时变特征(如交通流量、速度和天气信息等)和时常特征(如年平均交通流量、道路类型、POI 信息等),以全面考虑不同类型特征对交通流预测的综合影响。

相较于过去在交通流预测领域的其他研究,本研究同时考虑时空相关性、动态空间相关性和外部特征的应用,在针对中长期交通流预测中表现更加稳定,填补了在该领域未能同时考虑时空相关性、动态空间相关性和外部特征综合应用的空白。

1 相关工作

1.1 相关方法介绍

1.1.1 传统方法

传统的统计模型方法计算复杂度较低,操作相对简单,依赖线性假设,不能反映交通流量的非线性特征。传统的机器学习方法结构简单、具备一定的数据拟合能力,但依赖于手工设计,对数据质量要求高。

文献[1]将历史平均 (history average, HA) 模型应用于交通流量预测,使用历史时段的平均交通流量作为预测值。HA 模型不需要提前做出任何假设,且计算简单快速,但是该方法只能对静态交通流量进行预测,忽略了当前交通模式变化的影响,而且还不能很好地拟合时间特征,通常预测精度较低。文献[18]使用 ARIMA 模型进行交通流量预测,首先将海量的非平稳的交通流量数据转变为平稳的交通流量数据,然后进行模型参数估计,最后将处理后的数据输入模型得到最终的预测结果。

1.1.2 基于循环神经网络的方法

文献[19]探讨了长短时记忆 (long short-term memory, LSTM) 网络在短期交通流量预测中的应用,发现该模型适用于捕获交通数据的长期时间依赖关系;文献[20]提出一种混合深度学习网络模型,减少了网络学习过程中交通流量的分布不均衡和过拟合问题的影响;文献[21]对初始的 LSTM 网

络模型进行改进,使模型计算过程都包含卷积操作,该模型能更好地捕获交通流量中的时空相关性;文献[22]使用算数平均滤波对 LSTM 网络模型进行改进,解决了预测模型受噪声数据影响的问题。这些方法都利用 LSTM 网络模型提取时间序列特征,适用于长期预测任务,然而 LSTM 网络模型需要学习的参数多,训练时间长,并且在计算过程中容易产生累计误差。

GRU 是 LSTM 网络的一种效果很好的变体,比 LSTM 网络的结构更加简单,效果也更好^[23-24]。GRU 可以解决 RNN 网络中的长依赖问题,而且参数较少,训练速度更快,能够降低过拟合的风险。文献[25]使用 LSTM 和 GRU 神经网络方法预测短期交通流量,试验表明基于 RNN 的深度学习方法的性能优于 ARIMA 模型。

双向循环神经网络 (bidirectional recurrent neural network, Bi-RNN) 是一种具有前向和后向 2 个方向的循环连接神经网络结构^[26],它在处理序列数据时能够同时考虑过去和未来的上下文信息,从而提供更全面的序列建模能力。RNN 在处理序列数据时只能利用过去的信息进行预测,这可能导致模型对于未来信息无法准确捕捉^[27]。为了解决这个问题,Bi-RNN 引入一个额外的逆向循环层,使网络能够同时向前和向后传播信息。这样,网络能够在每个时间步骤上同时考虑过去和未来的上下文信息。文献[28]提出一种结合 K -最近邻算法 (K -nearest neighbor, KNN) 和双向长短期记忆 (bidirectional long short-term memory, Bi-LSTM) 模型预测短期交通流的时空特征的方法;文献[29]提出一个基于卷积神经网络和双向长短期记忆模型的多步预测模型,将交通数据的空间特征作为 Bi-LSTM 模型的输入,提取交通数据的时间序列特征;文献[30]提出一种基于双向门控循环单元法的交通流预测,采用双向门控循环单元 (bidirectional gated recurrent unit, Bi-GRU) 模型进行交通流预测。但是这些模型只从时间相关性层面对交通流数据进行预测,没有考虑交通流数据的空间相关性,而且未考虑不同历史时段的交通流数据对当前时刻交通流预测的重要性不同。

1.1.3 基于卷积神经网络的方法

基于卷积神经网络的方法在交通流预测中能够有效捕获交通数据中的时空特征,尤其适用于需要考虑路段之间的关系和交通流随时间变化而变化的任务。文献[31]提出一种基于门控卷积的时空交通流预测模型,利用图卷积网络 (graph

convolutional networks, GCN) 结合 GRU 捕获交通流数据的时空特征;文献[32]提出一种时空组合图卷积神经网络,构建自适应时空组合图并提出时空组合图卷积,有效揭示交通流量数据动态和复杂的时空相关性;文献[33]提出一种时空轻量级图 GRU 网络,利用记忆增强注意和门控机制有效捕获交通网络的局部和全局时空关系;文献[34]提出时空同步图卷积网络,通过精心设计的时空同步建模机制,有效捕获复杂的局部时空相关性;文献[35]提出一种时间图卷积网络模型,将 GCN 和 GRU 结合用于长期交通流量预测任务;文献[36]提出时空图卷积网络模型,通过图卷积学习路网的空间信息,并利用一维卷积学习时间维度上的交通流量变化。但是卷积神经网络只考虑用固定的路网拓扑结构构建图网络,缺少对动态变化的路网拓扑结构的关注。

动态图卷积用于处理动态或时变的图数据,它的主要特点是能够适应图数据中节点之间的连接关系在不同时间或情境下的变化。文献[37]提出一种时空融合图神经网络模型,对不同时间段构建的空间和时间图进行融合运算,能够有效学习交通流量隐藏的时空相关性;文献[38]提出一种采用注意力编解码器架构的图形多注意网络模型,可以预测路网中不同地点以及不同时间尺度的交通流量;文献[39]提出一种动态和多面时空图卷积网络,提出一个新的框架解决具有多面数据的交通速度预测问题;文献[40]提出一个时空动态循环图卷积框架,以解决具有多面数据的交通速度预测问题;文献[41]提出一种基于动态时空卷积网络的车道级交通流预测模型,该模型采用动态图卷积网络,利用扩张因果卷积与门控机制构成的门控时间卷积网络提取交通流序列的时间动态特征;文献[42]构建了考虑时空相似性的动态图卷积神经网络,以多时间尺度下的数据输入张量表达交通流数据的时间相似性。基于动态图卷积网络的方法在交通流预测中具有潜力,尤其适用于需要考虑时空关系的任务。

1.1.4 基于注意力机制的方法

注意力机制应用在语音识别、机器翻译、图像识别等领域^[43],交通流预测需要考虑时空数据之间的复杂关联,注意力机制可以用来捕获不同时空位置之间的相关性,允许模型更好地建模这些关联。文献[11]提出一种新的序列到序列时空注意力深度学习框架处理城市交通流建模任务,可以自适应地学习与城市交通流相关的多通道、多变量时空序列数据中的时空依赖性和非线性相关性特征;文献

[44]提出一种时空注意力图卷积网络,该网络采用编码器-解码器框架,其中 k 阶切比雪夫图卷积网络用于提取交通网络的空间相关性,同时将历史时间步长和与预测时间段间隔相同的周交通数据堆叠作为输入,更好地捕获时间和周期性;文献[45]在基于时空特征的交通流量预测模型的基础上引入注意力机制,同时在预测时引入堆叠自动编码器

(stacked autoencoder, SAE) 机制降低模型的复杂度;文献[46]提出一种结合了卷积神经网络、门循环单元、多任务学习和时分离注意机制的短期交通流预测方法。

1.2 现有模型比较

表1和表2分别展示了最近几年最新的针对短期和中长期交通流预测模型的信息。

表1 短期交通流预测模型介绍表

Table 1 Introduction of short-term traffic flow prediction models

| 文献序号 | 模型名称 | 时间相关性 | 静态空间相关性 | 动态空间相关性 | 外部特征利用 | 数据集 |
|------|-----------------|----------|---------|---------|-----------------|-------------|
| [28] | KNN-BILSTM | 双向 LSTM | KNN | 无 | 无 | 英国高速 |
| [29] | CNN-BILSTM | 双向 LSTM | CNN | 无 | 无 | 加州高速 |
| [30] | Bi-GRU | 双向 GRU | 无 | 无 | 无 | 郑州高速 |
| [31] | GC-STTFPM | GRU | GCN | 无 | 无 | 洛杉矶公路 |
| [33] | STLGRU | 门控机制 | GCN | 注意力机制 | 无 | 加州高速、洛杉矶公路 |
| [46] | AST-MTL-CNN-GRU | GRU | CNN | 注意力机制 | 无 | 泉州大道、加州高速 |
| [47] | GLSNN | LTSM、GRU | GCN | 无 | 无 | 纽约传感器、纽约出租车 |
| [48] | LSTM | LSTM | 无 | 无 | 工作日、节假日、早晚高峰、天气 | 明尼苏达大学数据 |

表2 中长期交通流预测模型介绍表

Table 2 Introduction of medium and long-term traffic flow prediction models

| 文献序号 | 模型名称 | 时间相关性 | 静态空间相关性 | 动态空间相关性 | 外部特征利用 | 数据集 |
|------|----------------|------------------------|------------------------|-------------|-----------|------------|
| [10] | STG-CRNN | 门控扩展因果卷积 | 双向游走的图卷积 | 路网动态相关性邻接矩阵 | 路网相似性度量数据 | 洛杉矶公路、加州高速 |
| [25] | LSTM NN、GRU NN | LSTM、GRU | 无 | 无 | 无 | 加州高速 |
| [44] | STAGCN | 切比雪夫图卷积 | Encoder-Decoder | 注意力机制 | 无 | 加州高速 |
| [49] | STGCA | GCN | GCN | 注意力机制 | 无 | 加州高速 |
| [50] | STANN | Encoder-Decoder、卷积 GRU | Encoder-Decoder、卷积 GRU | 注意力机制 | 无 | 墨尔本街道 |

在针对短期交通流预测的模型中,文献[28-29]采用了双向 LSTM,文献[30]采用了双向 GRU,与仅使用单向 LSTM 和 GRU 的文献[31,46-48]相比,这些方法能更好地捕捉时间序列数据之间的前后关系,然而,它们并没有充分考虑交通流的动态空间相关性。文献[33,46]既考虑了时间相关性,又考虑了动态空间相关性,相较于其他只考虑静态空间相关性的模型,它们能够捕捉交通流中动态变化的空间依赖关系,然而,它们未考虑如天气等外部特征的利用。

在针对中长期交通流预测的模型中,文献[25]并未考虑动态空间相关性。文献[10,44,49-50]同时考虑了动态空间相关性的提取,但未考虑外部特征的应用。文献[10,50]考虑了时空相关性、动态空间相关性和外部特征的应用,但外部特征考虑不够全面。

相较于上述模型的不足之处,本研究提出的时空注意力图卷积网络(attention-based spatio-temporal graph convolutional network, ATST-GCN)模型同时考虑了时空相关性、动态空间相关性和外部特征的应用,在针对中长期交通流预测中表现更加稳定,填补了在该领域未能同时考虑时空相关性、动态空间相关性和外部特征综合应用的空白。

2 交通流预测问题定义

为了更好地定义交通流量预测任务,本研究定义了以下相关概念。

2.1 道路属性

本研究选取2个道路相关属性,分别是 POI 功能相似度和动态时间规整(dynamic time warping, DTW)算法相似度。

(1) POI 功能相似度

具有相似功能的城市地区的道路通常具有相似的交通模式,而使用道路周围区域的 POI 类型和数量能够描述这些分布在不同位置的区域之间的功能相似程度。

(2) DTW 算法相似度

具有相似交通模式的道路在空间上不一定很接近,通过 DTW 算法测量每条道路间的历史交通状况模式的相似性,衡量道路间的相关性。

2.2 K 跳邻接矩阵

K 跳邻接矩阵表示图中节点之间的关系,K 代表节点之间的距离。在一个图中,节点可以直接相连(距离为 1),或者通过一定数量的中间节点相连(距离为 K)。K 跳邻接矩阵通常用于 GCN 中,用来捕获节点之间的信息传递路径。本研究将具有 N 个路段的道路网络建模为有向图 $G=(S,A)$,其中 S 表示路段集合,对于每个路段 $i \in S$,其 K 跳邻居定义为 $Hop_i(K)$,公式为:

$$Hop_i(K) = \{j \in S \mid d(i,j) \leq K\}, \quad (1)$$

式中 $d(i,j)$ 表示在路段 i 和路段 j 之间移动所需的最小步数。

K 跳邻域矩阵 A^K 构造公式为:

$$A^K = Ci(A^K + I) = \begin{cases} 1, & j \in Hop_i(K) \text{ 或 } i=j \\ 0, & \text{其他} \end{cases}, \quad (2)$$

式中, $Ci(\cdot)$ 是通过将矩阵中每个非零元素转换为 1 的函数, A^K 是没有自连接的 K 跳邻域矩阵,添加单位矩阵 I 表示自连接。

2.3 问题定义

根据上述定义,本研究将交通流量预测任务定义如下。

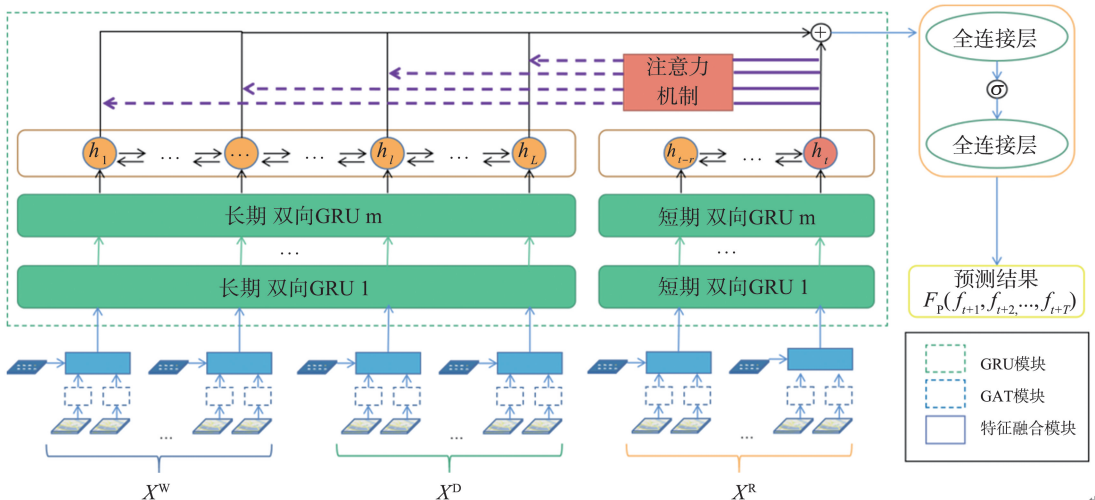
将时间步 t 下路段 i 的平均速度和流量分别定义为 $V_{i,t}$ 和 $F_{i,t}$,将时间步长 t 的同一时刻的路网天气观测定义为 W_t 。交通流量预测是一个典型的时间序列预测任务,即利用过去 M 个时间步长的信息预测在时间步长 t+P 时各路段的交通流量,公式表示为:

$$F_{t+P} = \operatorname{argmax}_{F_{t+P}} P_r(F_{t+P} \mid V_t, \dots, V_{t-M}, F_t, \dots, F_{t-M}, W_t, \dots, W_{t-M}, R, A^K), \quad (3)$$

式中, F_{t+P} 是时间步 t+P 时预测的路段流量的集合, V_t 是时间步 t 时观测到的路段速度的集合, F_t 是时间步 t 时观测到的段流量的集合, R 是道路属性, $P_r(\cdot \mid \cdot)$ 是条件概率函数。

3 模型结构

本研究提出一种基于注意力的时空注意力图卷积网络(ATST-GCN)模型用于动态交通流量预测,模型的整体模块如图 1 所示。图 1(a) 展示了所提出的基于注意力的双向 GRU 模块结构。本研究沿着时间轴构建了 3 种类型的时间序列 X^R 、 X^D 和 X^W , 分别从前 r 个时间步长,前 d 天和前 w 周的数据中收集相应信息,时间序列构造如图 1(b) 所示。近期时间序列由当前时间步之前的 r 个时间步样本组成,它可能对未来交通流量有最重要的影响;日时间序列由当前时间步在过去 d 天中同一时间步的前后 r 个时间样本组成,用于给交通数据的日周期建模;周时间序列由当前时间步在过去 w 周中同一天的同一时间步的前后 r 个时间步样本组成,这种类型的时间序列旨在提取每周的周期特征,例如,每周一类似的交通模式。



(a) 双层GRU模块图

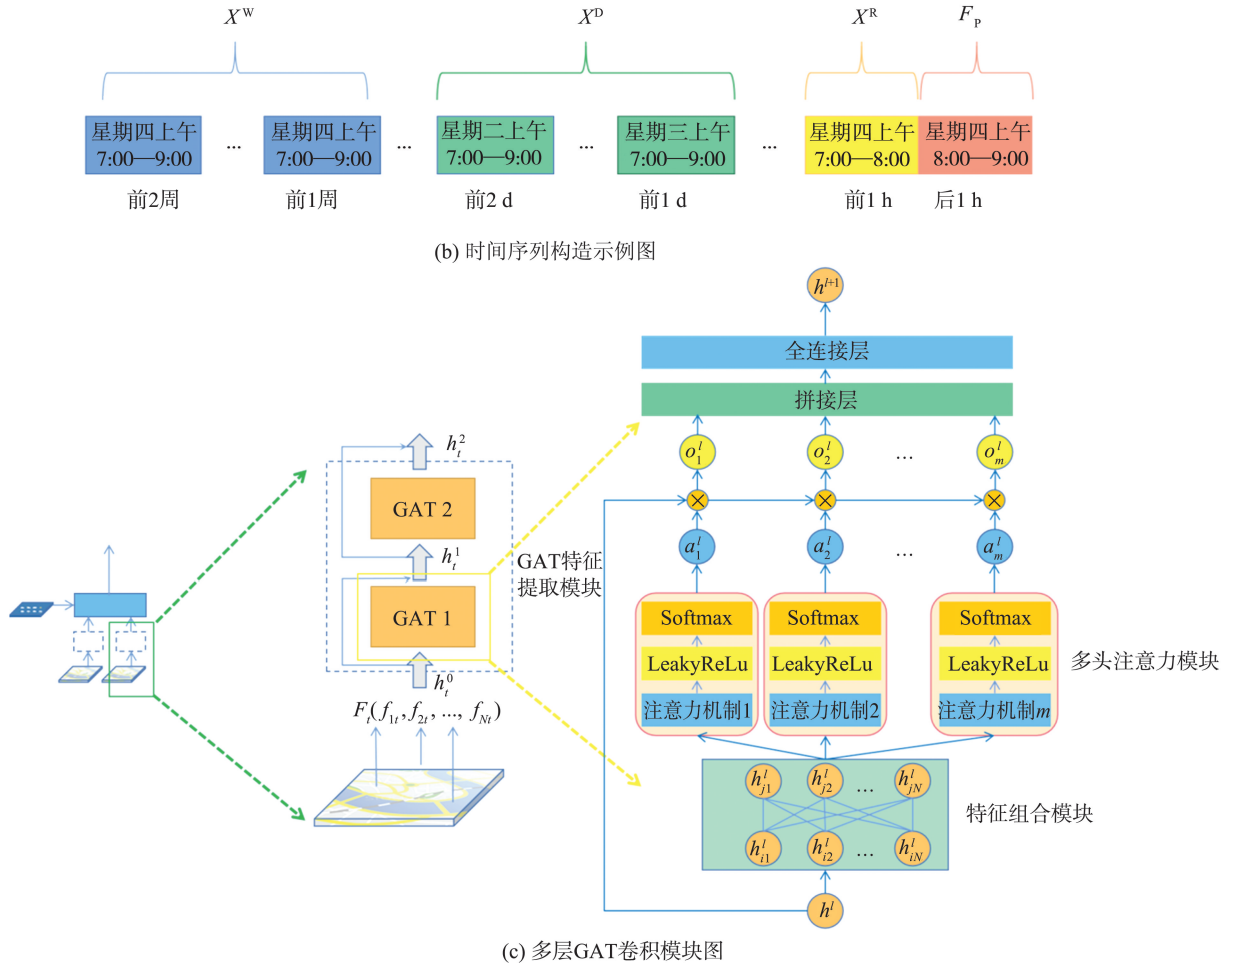


图1 ATST-GCN 模型整体模块示意图

Fig.1 Schematic diagram of ATST-GCN model

3.1 带残差链接的多层图注意力网络 (graph attention network, GAT) 卷积模块

以前基于 GCN 的模型假设空间依赖性是不变的,道路拓扑图中的空间依赖性只计算一次并一直使用,并忽略了动态变化的交通模式。为了解决这个问题,本研究采用 GAT,假设邻居段对中心段的贡献不是预先确定的,GAT 通过采用注意力机制学习 GCN 在不同路段特征两两组合时的相对权重。在 GAT 中,从特征 h_i^l 到更高层特征 h_i^{l+1} 的转换公式为:

$$e_{ij}^l = \text{LeakyReLU}(a_{ij}^l(h_i^l | h_j^l)), \quad (4)$$

$$a_{ij}^l = \frac{\exp(e_{ij}^l)}{\sum_{k=1}^N \exp(e_{ik}^l)}, \quad (5)$$

$$o_i^l = \sum_{k=1}^N a_{ik}^l h_k^l, \quad (6)$$

$$h_i^{l+1} = \sigma(W_i^l o_i^l + b_i^l), \quad (7)$$

式中, $\text{LeakyReLU}(\cdot)$ 是非线性激活函数, e_{ij}^l 是特征 h_i^l 和特征 h_j^l 的组合向量经过多头注意力模块打分

后的分数向量, a_{ij}^l 是给特征 h_i^l 和特征 h_j^l 的组合向量进行打分的注意力向量, o_i^l 是特征 h_i^l 的输出向量, $\sigma(\cdot)$ 是 Sigmoid 激活函数, W_i^l 和 b_i^l 是对 o_i^l 进行变换的系数和偏置项。

本研究采用多头注意机制,使模型能够从多个表示子空间中共同学习注意分数,如图 1(c) 所示,多个独立注意机制同时执行 GAT 卷积操作,然后将它们的特征连接起来,以产生输出特征表示,每个 GAT 特征提取模块由 2 个 GAT 组成。对于每个时间步 t ,第 1 层的输入是一组流量 $F_t = \{f_{1t}, f_{2t}, \dots, f_{Nt}\}$, $f_{it} \in \mathbb{R}^F$, 或者一组速度 $V_t = \{v_{1t}, v_{2t}, \dots, v_{Nt}\}$, $v_{it} \in \mathbb{R}^F$, 这些值将作为初始特征 $h_t^0 = \{h_{1t}^0, h_{2t}^0, \dots, h_{Nt}^0\}$, $h_{it}^0 \in \mathbb{R}^F$, 并输入第 1 层 GAT; 第 1 层 GAT 生成一组新的高阶特征 $h_t^1 = \{h_{1t}^1, h_{2t}^1, \dots, h_{Nt}^1\}$, $h_{it}^1 \in \mathbb{R}^{F'}$, 将来自不同注意力头的输出特征连接起来,作为第 2 层 GAT 的输入; 第 2 层 GAT 生成一组新的高阶特征 $h_t^2 = \{h_{1t}^2, h_{2t}^2, \dots, h_{Nt}^2\}$, $h_{it}^2 \in \mathbb{R}^{F''}$, 将来自不同注意力头的输出特征连接起来,作为不同节点的流量在时间步 t 下的空间特征表示 $h_{f,t}^2$ 。

堆叠多层 GAT 时可能导致梯度消失的问题,使得模型失去对于低阶特征的捕获能力,为了解决梯度消失的问题,同时提升模型共同捕获低阶特征和高阶特征的能力,在第 1 层和第 2 层 GAT 的输出中引入了残差连接。

3.2 特征融合模块

流量和速度之间存在二元平衡关系,因此有必要在流量预测中包含速度信息。为了同时获取对于低阶特征和高阶特征表示,引入了残差连接。在获得速度的空间特征表示 $h_{v,t}^2$ 后,本研究添加一个门控结构调节所获得的速度信息。流量和速度的空间特征融合后的空间特征表示

$$h_t^c = (h_{f,t}^2 \odot \sigma(h_{v,t}^2)) \quad (8)$$

天气现象对交通流相关参数有显著影响,如速度、流量等。本研究选取的天气信息包含了 5 个维度信息(时刻、天气、气温、风向、风力),在特征融合模块中选取对应 t 时刻的天气信息 W_t ,通过一维卷积 $\text{Conv1D}(\cdot)$ 将天气信息处理成与融合后的空间特征 h_t^c 维度一致的天气特征 W_t ,构建公式为:

$$W_t = \text{Conv1D}(W_t) \quad (9)$$

此外,本研究还包括了 2 个与道路属性相关的静态特征,即 POI 信息和节点 DTW 相似度信息。在每个时间步 t ,路网范围内的天气特征 W_t 、道路属性特征 R 和融合后的空间特征 h_t^c ,通过拼接函数 $\text{concat}(\cdot)$ 一同连接为 X_t ,将 X_t 用作基于注意力的双向 GRU 模块的输入, X_t 的计算公式为:

$$X_t = \text{concat}(h_t^c, W_t, R) \quad (10)$$

整个特征融合模块如图 2 所示,其中 t 时刻的速度、流量、天气分别表示为 V_t 、 F_t 、 W_t 。

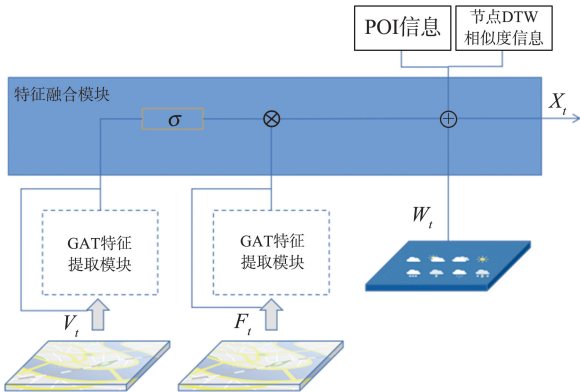


图 2 特征融合模块示意图

Fig. 2 Schematic diagram of feature fusion module

3.3 基于注意力的双向 GRU 模块

长期特征在不同时间步长下的重要性可能各不相同,因此本研究将双向 GRU 分为长期和短期 2 种,分别对不同时间周期的流量空间特征进行时间

特征提取。将特征融合模块提取的空间特征输入多层堆叠的双向 GRU 中,以获取高阶交通流量的时空相关性表示。使用近期时间序列 X^R 作为短期双向 GRU 的输入,使用日时间序列 X^D 和每周周时间序列 X^W 沿时间轴连接为 X^L ,作为长期双向 GRU 的输入。将双向 GRU 的输出结果连接起来,并使用注意力机制捕捉它们的动态重要性,GRU 模块输出的计算公式为:

$$h_i^s = \text{GRU}_s(X_i^R), \quad (11)$$

$$h_i^l = \text{GRU}_l(X_i^L), \quad (12)$$

$$h^l = \text{Attention}(h_i^s, [h_1^l, \dots, h_i^l, \dots, h_L^l]), \quad (13)$$

$$h^p = \text{concat}(h_i^s, h^l), \quad (14)$$

式中, $\text{GRU}_s(\cdot)$ 代表短期 GRU, $\text{GRU}_l(\cdot)$ 代表长期 GRU, $\text{Attention}(\cdot)$ 代表注意力机制, h_i^s 代表第 i 个短期 GRU 单元的特征向量, h_i^l 代表第 i 个长期 GRU 单元的特征向量, h^l 代表通过注意力机制对全部长期 GRU 单元的特征向量进行筛选后的输出向量, h^p 表示将第 t 个短期 GRU 单元的特征向量 h_i^s 和 h^l 拼接后得到的预测向量。

通过在输出层用 \tanh 激活函数对预测值进行处理后,最终的预测结果计算公式为:

$$F^p = W_2[\tanh(W_1 h^p + b_1)] + b_2, \quad (15)$$

式中, F^p 是最终的流量预测值, W_1 、 W_2 、 b_1 、 b_2 分别为输出层 2 个全连接层的变换系数和偏置项。

4 试验

4.1 数据集介绍

选用美国加州高速路网 PeMS 交通数据集^[51], 试验用到其中的 PeMS08 和 PeMS03 数据集,数据集介绍如表 3 所示。

表 3 PeMS 数据集介绍表
Table 3 Introduction of PeMS dataset

| 数据集 | 时间 | 地点 | 节点数/个 | 数据量/条 | 数据属性 |
|--------|---------------|-----------|-------|-----------|------------|
| PeMS08 | 2016 年 7—8 月 | 美国加州第 8 区 | 170 | 3 035 520 | 速度、占有率、车流量 |
| PeMS03 | 2018 年 9—11 月 | 美国加州第 3 区 | 358 | 9 382 464 | 速度、占有率、车流量 |

4.2 预处理

(1) 对原始数据集缺省值进行数据清洗。查找原数据集中不完整的记录信息,通过填补邻近时间片内交通流数据的平均值进行填充,具体填充计算公式为:

$$x_t = \frac{1}{2P} \sum_{j=1}^P (x_{t-j} + x_{t+j}), \quad (16)$$

式中, x_i 为待填充数据, P 为选取的前后邻近数据的条数。

(2) 计算 K 跳邻接矩阵。计算全部探测器之间的 1 跳邻接矩阵, 再根据查找 1 跳邻接矩阵各个探测器节点间的间接相邻关系, 进而计算全部探测器之间的 2, ..., K 跳邻接矩阵。

(3) 计算 POI 功能图矩阵。根据各个探测器节点对应的经纬度等位置信息, 查找对应经纬度坐标下周围半径 500 m 以内的 POI 信息, 进行整理并分为 8 种类型, 根据 POI 功能图的计算方式得到对应的 POI 功能图矩阵。

(4) 计算 DTW 相似度矩阵。将数据集中第 1 个月内每周各个时间片的交通流平均数据通过 DTW 算法计算各个节点间的 DTW 相似度, 得到对应的 DTW 相似度矩阵。

(5) 对输入数据进行归一化处理。将原始数据调整为 $-1 \sim 1$, 再选取放大倍数 F , 将数据调整至 $0 \sim 2F$, 具体计算公式为:

$$x_i = F \left[1 + \frac{x_i - \frac{1}{N_i} \sum_{t=1}^{N_i} x_t}{\frac{1}{N_i} \sum_{t=1}^{N_i} (x_t - \frac{1}{N_i} \sum_{t=1}^{N_i} x_t)^2} \right], \quad (17)$$

式中 N_i 为当前属性的总记录数。

4.3 试验配置

本研究试验训练集占总数据的 70%, 测试集占总数据的 20%, 验证集占总数据的 10%。模型训练时采用 Adams 优化器, 学习速率设置为 0.001, 损失函数为均方误差 (mean square error, MSE), 训练 100 个周期。设置双向 GRU 的层数为 1, 长期双向 GRU 的输入序列为前 1、2 周和前 1、2 d 同一时刻 t 前后 1 h 的交通流空间特征, 短期双向 GRU 的输入序列为待预测时刻 t 前 1 h 的交通流空间特征, 双向隐藏单元数设置为 128 个, 批处理大小为 64。所有使用单向、双向的 LSTM 和 GRU 的基线方法都遵循上述设置。所用的处理器为 AMD Ryzen 7 PRO 4750U with Radeon Graphics 1.70 GHz, 试验所用到的环境为 Tensorflow 2.5.0 和 Python 3.7.0。

4.4 基线方法和评估指标

为了验证所提出的 ATST-GCN 模型的有效性, 将所提出的模型与 HA 模型^[11]、ARIMA 模型^[1]、时空同步图卷积网络 (spatial-temporal synchronous graph convolutional networks, STSGCN)^[34]、时间图卷积网络 (temporal graph convolutional network, T-GCN)^[35]、时空图卷积网络 (spatial-temporal graph convolutional network, STGCN)^[36]、动态和多面时空

图卷积网络 (dynamic and multi-faceted spatio-temporal graph convolutional network, DMST-GCN)^[39] 等经典和深度学习模型进行了比较。

本试验选用的评估指标有均方根误差 (root mean square error, RMSE) R 、平均绝对误差 (mean absolute error, MAE) M 。

4.5 试验结果与分析

4.5.1 消融试验

为了进一步提高所提出模型的预测精度, 本研究还添加了输出激活函数、GAT 层残差连接、DTW 相似度信息、POI 信息共 4 个模块。为了验证这些模块的有效性, 本研究分别在 PeMS08、PeMS03 两个数据集上设置了消融试验, 并将采样间隔设置为 15 min, 预测未来 60 min 的交通流量, 试验结果如表 4、5 所示。

表 4 PeMS08 数据集消融试验结果
Table 4 Experimental results on PeMS08 dataset

| 模块组合 | | | | R | M |
|--------|-----------|---------|--------|-----------------|-----------------|
| 输出激活函数 | GAT 层残差连接 | DTW 相似度 | POI 信息 | | |
| | ✓ | ✓ | ✓ | 34.170 9 | 22.861 2 |
| ✓ | | ✓ | ✓ | 33.895 6 | 22.777 3 |
| ✓ | ✓ | | ✓ | 33.672 2 | 22.474 9 |
| ✓ | ✓ | ✓ | | 33.755 6 | 22.590 2 |
| ✓ | ✓ | ✓ | ✓ | 33.521 6 | 22.234 2 |

表 5 PeMS03 数据集消融试验结果
Table 5 Experimental results on PeMS03 dataset

| 模块组合 | | | | R | M |
|--------|-----------|---------|--------|-----------------|-----------------|
| 输出激活函数 | GAT 层残差连接 | DTW 相似度 | POI 信息 | | |
| | ✓ | ✓ | ✓ | 26.832 1 | 18.452 4 |
| ✓ | | ✓ | ✓ | 26.211 3 | 18.115 5 |
| ✓ | ✓ | | ✓ | 25.601 6 | 17.718 0 |
| ✓ | ✓ | ✓ | | 25.812 3 | 17.901 4 |
| ✓ | ✓ | ✓ | ✓ | 25.285 4 | 17.499 9 |

由表 4、5 可以看出, 在输出层用 tanh 激活函数对预测值进行处理后, 准确度得到了提升, 说明该模块使得模型对数据变化的敏感程度变强, 从而更容易拟合预测的真实值; 在 GAT 特征提取模块中加入残差连接后, 模型预测的性能提高, 说明加入残差连接后能有效改善多层堆叠的卷积网络梯度消失的问题。在特征融合模块加入 DTW 相似度信息后, 模型预测的误差降低, 说明 DTW 相似度信息能有效捕捉远距离节点间的交通流空间相关性, 弥补仅根据邻接矩阵获取近距离道路节点间的交通流空间相关性的不足; POI 信息对于提

升交通流数据的预测准确度也有一定的作用,说明不同种类的特征融合会对预测结果产生增益。

4.5.2 对比试验

基于统计模型和机器学习的方法只关注交通流数据的时间特征,而基于深度学习的方法同时关注时间和空间特征,为了验证后者相比较前者在交通流量预测上的优越性,设置了 HA、ARIMA 模型和 STSGCN、T-GCN、STGCN、DMSTGCN 模型的对比试验。在基于深度学习的方法中,基于注意力机制的方法捕捉交通流数据的时空相关性更有优势,

如对比试验中的 ATST-GCN 模型,相对于传统单向 RNN、Bi-RNN 能同时考虑过去和未来的上下文信息,具有更强大的序列建模能力,GRU 相较 LSTM 的结构更加简单而且效果也很好。为了说明 Bi-RNN 和 GRU 的优势,分别设置单向、双向 LSTM 和 GRU 共 4 组对照组,分别用于 ATST-GCN 模型中对交通流数据的时间相关性提取。本研究将采样间隔设置为 15 min,预测未来 15、30、45 min 以及 60 min 的交通流量,对 PeMS08、PeMS03 数据集设置了如表 6、7 所示的对照试验。

表 6 PeMS08 数据集对比试验结果
Table 6 Experimental results on PeMS08 dataset

| 类别 | 方法 | 15 min | | 30 min | | 45 min | | 60 min | |
|----------------|-------------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | | R | M | R | M | R | M | R | M |
| 基于统计模型和机器学习的方法 | HA ^[18] | 42.474 8 | 29.723 0 | 45.669 0 | 32.862 6 | 48.632 4 | 35.574 6 | 50.963 2 | 38.086 5 |
| | ARIMA ^[1] | 40.290 0 | 28.124 5 | 44.248 3 | 30.774 1 | 46.423 1 | 33.373 2 | 47.976 8 | 34.996 6 |
| 基于深度学习的方法 | STSGCN ^[34] | 34.331 8 | 24.075 3 | 35.492 4 | 25.842 9 | 36.900 3 | 26.909 3 | 38.725 6 | 28.194 2 |
| | T-GCN ^[35] | 35.302 3 | 26.033 9 | 37.659 1 | 27.462 0 | 39.879 7 | 29.242 0 | 42.651 7 | 31.106 4 |
| | STGCN ^[36] | 34.009 0 | 23.200 0 | 34.936 1 | 23.931 0 | 35.586 0 | 24.693 0 | 36.453 0 | 25.656 0 |
| | DMSTGCN ^[39] | 33.174 6 | 22.067 4 | 33.679 0 | 22.957 9 | 34.214 0 | 23.239 9 | 34.641 4 | 23.617 8 |
| 基于注意力机制的方法 | ATST-GCN (单向 LSTM) | 34.034 0 | 22.753 2 | 34.363 7 | 22.892 8 | 34.632 9 | 23.112 3 | 34.901 8 | 23.435 5 |
| | ATST-GCN (双向 LSTM) | 33.191 2 | 22.015 1 | 33.512 7 | 22.150 2 | 33.775 3 | 22.362 5 | 34.074 4 | 22.451 5 |
| | ATST-GCN (单向 GRU) | 33.629 6 | 22.305 9 | 33.955 4 | 22.442 8 | 34.221 4 | 22.657 9 | 34.618 4 | 22.748 4 |
| | ATST-GCN (双向 GRU) | 32.680 8 | 21.676 5 | 32.997 4 | 21.809 5 | 33.255 9 | 22.018 6 | 33.521 6 | 22.234 2 |

表 7 PeMS03 数据集对比试验结果
Table 7 Experimental results on PeMS03 dataset

| 类别 | 方法 | 15 min | | 30 min | | 45 min | | 60 min | |
|----------------|-------------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | | R | M | R | M | R | M | R | M |
| 基于统计模型和机器学习的方法 | HA ^[18] | 32.038 8 | 23.394 1 | 34.448 2 | 25.865 2 | 36.683 5 | 27.999 8 | 38.441 6 | 29.976 8 |
| | ARIMA ^[1] | 29.330 6 | 21.358 0 | 32.212 2 | 23.370 1 | 33.795 4 | 25.343 9 | 34.926 5 | 26.576 7 |
| 基于深度学习的方法 | STSGCN ^[34] | 25.896 5 | 18.949 0 | 26.772 0 | 20.340 2 | 27.834 0 | 21.179 5 | 29.210 8 | 22.190 8 |
| | T-GCN ^[35] | 26.628 6 | 20.490 5 | 28.406 3 | 21.614 6 | 30.081 3 | 23.015 5 | 32.137 9 | 24.482 9 |
| | STGCN ^[36] | 25.653 0 | 18.260 1 | 26.352 4 | 18.835 4 | 26.842 6 | 19.435 2 | 27.496 6 | 20.193 1 |
| | DMSTGCN ^[39] | 25.023 7 | 17.368 6 | 25.404 1 | 18.069 5 | 25.807 7 | 18.291 4 | 26.130 1 | 18.589 0 |
| 基于注意力机制的方法 | ATST-GCN (单向 LSTM) | 25.671 9 | 17.991 1 | 25.920 6 | 18.172 0 | 26.123 7 | 18.346 2 | 26.326 5 | 18.502 8 |
| | ATST-GCN (双向 LSTM) | 25.036 2 | 17.327 4 | 25.278 7 | 17.433 8 | 25.476 8 | 17.590 8 | 25.702 4 | 17.670 9 |
| | ATST-GCN (单向 GRU) | 25.366 8 | 17.556 3 | 25.612 6 | 17.664 1 | 25.813 2 | 17.833 4 | 26.012 7 | 18.004 6 |
| | ATST-GCN (双向 GRU) | 24.651 2 | 17.060 9 | 24.890 0 | 17.165 6 | 25.084 9 | 17.330 2 | 25.285 4 | 17.499 9 |

由表 6、7 可以看出,同时使用 Bi-RNN 和 GRU 的 ATST-GCN 模型取得了最佳性能,说明 GRU 较 LSTM 网络的效果更好,而且相比单向 GRU,双向 GRU 能更好地捕获时间序列数据间前后的相互影

响,能有效防止神经网络模型的误差积累。在面对更复杂的时空预测问题时,针对时间序列问题的 HA 和 ARIMA 等传统模型难以处理时间序列的不稳定性。STSGCN、T-GCN、STGCN、DMSTGCN

虽然综合考虑了时空特征,但忽视了动态变化的时空相关性。相比其他基线模型,ATST-GCN模型通过将时空相关性和空间相关性作为整体进行建模,并引入多头注意力机制,使得模型更好地捕捉变化的时空相关性,从而提高预测的准确度。

通过以上分析,可以认为本研究提出的动态交通流量预测的时空注意力图卷积网络模型可以有效地提取交通网络中的时空特征。相比其他基线模型,ATST-GCN模型对中长期(45、60 min)交通流量的预测效果更加稳定。

5 结束语

本研究提出一种动态交通流量预测的时空注意力图卷积网络模型(ATST-GCN),并成功应用于交通流量的预测。ATST-GCN采用基于注意力的双向GRU结构,用于提取动态的空间相关性序列中的时间相关性;采用基于注意力机制的图卷积网络,用于挖掘交通流数据中变化的空间相关性;采用融合模块,用于充分融合不同种类特征的影响。本研究使用PeMS数据集进行验证,在大规模真实数据集上的试验表明,与一些现有先进方法相比,本研究提出的方法能够有效建模道路空间的时空相关性,提高交通流预测的精度。在未来,将考虑进一步扩展本研究的框架,以应用于更广泛的交通时空预测任务。

参考文献:

- [1] LIU Jing, GUAN Wei. A summary of traffic flow forecasting methods [J]. Journal of Highway Transportation Research Development, 2004, 21(3): 82-85.
- [2] 孙德山.支持向量机分类与回归方法研究[D].长沙:中南大学,2004.
SUN Deshan. The researches on support vector machine classification and regression methods[D]. Changsha: Central South University, 2004.
- [3] 初连禹,杨兆升.基于神经网络的实时交通流量模糊预测[J].中国公路学报,1998(增刊1):78-82.
CHU Lianyu, YANG Zhaosheng. Real-time traffic volume prediction based on fuzzy neural network [J]. China Journal of Highway and Transport, 1998 (Suppl. 1): 78-82.
- [4] 杨兆升,王媛,管青.基于支持向量机方法的短时交通流量预测方法[J].吉林大学学报(工学版),2006,36(6):881-884.
YANG Zhaosheng, WANG Yuan, GUAN Qing. Short-term traffic flow prediction method based on SVM [J]. Journal of Jilin University (Engineering and Technology Edition), 2006, 36(6): 881-884.
- [5] 薛红军,陈广交,李鑫民,等.基于决策树理论的交通流参数短时预测[J].交通信息与安全,2016,34(3):64-71.
XUE Hongjun, CHEN Guangjiao, LI Xinmin, et al. A short-term forecasting of traffic flow parameters based on decision tree theory [J]. Journal of Transport Information and Safety, 2016, 34(3): 64-71.
- [6] 赵天信.基于卷积神经网络的交通流预测方法研究[D].兰州:兰州理工大学,2023.
ZHAO Tianxin. Research on traffic flow prediction method based on convolution neural network [D]. Lanzhou: Lanzhou University of Technology, 2023.
- [7] 王媛源.基于循环神经网络的区域性交通流预测研究与系统实现[D].石河子:石河子大学,2023.
WANG Yuanyuan. Research and system implementation of urban regional traffic flow prediction based on cyclic neural network [D]. Shihezi: Shihezi University, 2023.
- [8] 李朝阳,李琳,陶晓辉.面向动态交通流预测的双流图卷积网络[J].计算机科学与探索,2022,16(2):384-394.
LI Chaoyang, LI Lin, TAO Xiaohui. Two-stream graph convolutional neural network for dynamic traffic flow forecasting [J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(2): 384-394.
- [9] DIAO Z L, WANG X, ZHANG D F, et al. Dynamic spatial-temporal graph convolutional neural networks for traffic forecasting [C] // Proceedings of the AAAI Conference, Honolulu, USA: AAAI, 2019: 890-897.
- [10] 谷振宇,陈聪,郑家佳,等.基于时空图卷积循环神经网络的交通流预测[J].控制与决策,2021,37(3):645-653.
GU Zhenyu, CHEN Cong, ZHENG Jiajia, et al. Traffic flow prediction based on STG-CRNN [J]. Control and Decision, 2021, 37(3): 645-653.
- [11] 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.
DU Shengdong, LI Tianrui, YANG Yan, et al. A sequence-to-sequence spatial-temporal attention learning model for urban traffic flow prediction [J]. Journal of Computer Research and Development, 2020, 57(8): 1715-1728.
- [12] TANNER J C. Effect of weather on traffic flow [J]. Nature, 1952, 169(4290): 107.
- [13] KOCKELMAN K M. Changes in flow-density relationship due to environmental, vehicle, and driver characteristics [J]. Transportation Research Record,

- 1998, 1644(1): 47-56.
- [14] HRANAC R, STERZIN E, KRECHMER D, et al. Empirical studies on traffic flow in inclement weather [R]. USA: Federal Highway Administration, 2006.
- [15] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI, 2019, 33(1): 922-929.
- [16] YAO H X, TANG X F, WEI H, et al. Revisiting spatial-temporal similarity: a deep learning framework for traffic prediction[C]// Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI, 2019, 33(1): 5668-5675.
- [17] 闫旭, 范晓亮, 郑传潘, 等. 基于图卷积神经网络的都市交通态势预测算法[J]. 浙江大学学报(工学版), 2020, 54(6): 1147-1155.
YAN Xu, FAN Xiaoliang, ZHENG Chuanpan, et al. Urban traffic flow prediction algorithm based on graph convolutional neural networks [J]. Journal of Zhejiang University (Engineering Science), 2020, 54(6): 1147-1155.
- [18] HAMED M M, AL-MASAEID H R, SAID Z M B. Short-term prediction of traffic volume in urban arterials [J]. Journal of Transportation Engineering, 1995, 121(3): 249-254.
- [19] SHAO H, SOONG B H. Traffic flow prediction with long short-term memory networks (LSTMS) [C]//In Proceedings of 2016 IEEE Region 10 Conference (TENCON). Singapore: IEEE, 2016: 2986-2989.
- [20] QU Z, LI H, LI Z, et al. Short-term traffic flow forecasting method with M-B-LSTM hybrid network[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 23(1): 225-235.
- [21] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[J]. Advances in Neural Information Processing Systems, 2015, 28: 802-810.
- [22] 刘铭, 鱼昕. 基于改进 LSTM 算法的短时交通流量预测[J]. 桂林理工大学学报, 2021, 41(2): 409-414.
LIU Ming, YU Xin. Short-term traffic flow prediction based on MVF-LSTM algorithm[J]. Journal of Guilin University of Technology, 2021, 41(2): 409-414.
- [23] DEY R, SALEM F M. Gate-variants of gated recurrent unit (gru) neural networks [C]//Proceedings of 2017 IEEE 60th International Midwest Symposium on Circuits and Systems (MWSCAS). Boston, USA: IEEE, 2017: 1597-1600.
- [24] MOGHAR A, HAMICHE M. Stock market prediction using LSTM recurrent neural network [J]. Procedia Computer Science, 2020, 170: 1168-1173.
- [25] FU R, ZHANG Z, LI L. Using LSTM and GRU neural network methods for traffic flow prediction [C]//2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC). Wuhan, China: IEEE, 2016: 324-328.
- [26] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.
- [27] SU Y, ZHAO Y J, NIU C H, et al. Robust anomaly detection for multivariate time series through stochastic recurrent neural network [C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax, Canada: ACM, 2019: 2828-2837.
- [28] ZHUANG W Q, CAO Y B. Short-term traffic flow prediction based on a k -nearest neighbor and bidirectional long short-term memory model [J]. Applied Sciences, 2023, 13(4): 2681.
- [29] ZHUANG W Q, CAO Y B. Short-term traffic flow prediction based on CNN-BILSTM with multicomponent information [J]. Applied Sciences, 2022, 12(17): 8714.
- [30] WANG S Y, SHAO C F, ZHANG J, et al. Traffic flow prediction using bi-directional gated recurrent unit method [J]. Urban Informatics, 2022, 1(1): 16.
- [31] 徐丽, 符祥远, 李浩然. 基于门控卷积的时空交通流预测模型[J]. 计算机应用, 2023, 43(9): 2760-2765.
XU Li, FU Xiangyuan, LI Haoran. Spatial-temporal traffic flow prediction model based on gated convolution [J]. Journal of Computer Applications, 2023, 43(9): 2760-2765.
- [32] 范晓亮, 彭朝鹏, 郑传潘, 等. 面向大规模交通网络的时空关联挖掘方法[J]. 清华大学学报(自然科学版), 2023, 63(9): 1317-1325.
FAN Xiaoliang, PENG Zhaopeng, ZHENG Chuanpan, et al. Spatio-temporal correlation mining method for large-scale traffic networks [J]. Journal of Tsinghua University (Science and Technology), 2023, 63(9): 1317-1325.
- [33] BHAUMIK K K, NILOY F F, MAHMUD S, et al. STLGRU: spatio-temporal lightweight graph GRU for traffic flow prediction [EB/OL]. (2022-12-08) [2023-12-20]. <https://arxiv.org/abs/2212.04548>.
- [34] 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]//Proceedings of the AAAI Conference on Artificial Intelligence. New York, USA: AAAI, 2020, 34(1): 914-921.

- [35] 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*, 2019, 21(9): 3848-3858.
- [36] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting [EB/OL]. (2017-09-14) [2023-12-20]. <https://arxiv.org/abs/1709.04875>.
- [37] LI M Z, ZHU Z X. Spatial-temporal fusion graph neural networks for traffic flow forecasting [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. Vancouver, Canada: AAAI, 2021, 35(5): 4189-4196.
- [38] ZHENG C P, FAN X L, WANG C, et al. Gman: a graph multi-attention network for traffic prediction [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. New York, USA: AAAI, 2020, 34(1): 1234-1241.
- [39] HAN L Z, DU B W, SUN L L, et al. Dynamic and multi-faceted spatio-temporal deep learning for traffic speed forecasting [C]// *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*. Singapore: [s.n.], 2021: 547-555.
- [40] 刘志, 陈洋, 周涵林, 等. 基于时空动态循环图卷积网络的交通流预测 [J]. *浙江工业大学学报*, 2023, 51(3): 282-288.
LIU Zhi, CHEN Yang, ZHOU Hanlin, et al. Traffic flow prediction based on spatiotemporal dynamic recurrent graph convolutional framework [J]. *Journal of Zhejiang University of Technology*, 2023, 51(3): 282-288.
- [41] 江辉, 张阳, 杨书敏, 等. 基于动态时空卷积网络的车道级交通流预测 [J/OL]. *武汉理工大学学报(交通科学与工程版)*. (2023-07-04) [2023-12-20]. <http://kns.cnki.net/kcms/detail/42.1824.U.20230704.1417.062.html>.
JIANG Hui, ZHANG Yang, YANG Shumin, et al. Lane-level traffic flow prediction based on dynamic spatio-temporal convolution network [J/OL]. *Journal of Wuhan University of Technology (Transportation Science & Engineering)*. (2023-07-04) [2023-12-20]. <http://kns.cnki.net/kcms/detail/42.1824.U.20230704.1417.062.html>.
- [42] 谷振宇, 陈聪, 郑家佳, 等. 考虑时空相似性的动态图卷积神经网络交通流预测 [J]. *控制与决策*, 2023, 38(12): 3399-3408.
GU Zhenyu, CHEN Cong, ZHENG Jiajia, et al. Traffic flow prediction based on STS-DGCN [J]. *Control and Decision*, 2023, 38(12): 3399-3408.
- [43] BURCHI M, VIELZEUF V. Efficient conformer: progressive downsampling and grouped attention for automatic speech recognition [C]// *2021 IEEE Automatic Speech Recognition and Understanding Workshop (ASRU)*. Cartagena, Colombia: IEEE, 2021: 8-15.
- [44] 李志鹏. 时空注意力图卷积网络的交通流量预测研究 [J]. *智能计算机与应用*, 2022, 12(11): 253-257.
LI Zhijuan. Research on traffic flow prediction of spatio-temporal attention graph convolutional networks [J]. *Intelligent Computer and Applications*, 2022, 12(11): 253-257.
- [45] 李小妍. 基于图神经网络的交通流量预测 [D]. 成都: 电子科技大学, 2020.
LI Xiaoyan. Traffic forecasting based on graph neural network [D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [46] YANG Z J, WANG C. Short-term traffic flow prediction based on AST-MTL-CNN-GRU [J]. *IET Intelligent Transport Systems*, 2023, 17(11): 2205-2220.
- [47] CAI B H, WANG Y H, HUANG C, et al. GLSNN network: a multi-scale spatiotemporal prediction model for urban traffic flow [J]. *Sensors*, 2022, 22(22): 8880.
- [48] CHEN X. Research on short-term traffic flow forecasting model based on LSTM [J]. *World Scientific Research Journal*, 2020, 6(5): 191-200.
- [49] 刘建松, 康雁, 李浩, 等. 面向交通流量预测的时空 Graph-CoordAttention 网络 [J]. *计算机科学*, 2023, 50(增刊1): 568-574.
LIU Jiansong, KANG Yan, LI Hao, et al. Spatial-temporal Graph-CoordAttention network for traffic forecasting [J]. *Computer Science*, 2023, 50(Suppl.1): 568-574.
- [50] DO L N N, VU H L, VO B Q, et al. An effective spatial-temporal attention based neural network for traffic flow prediction [J]. *Transportation Research Part C: Emerging Technologies*, 2019, 108: 12-28.
- [51] CHEN C, PETTY K, SKABARDONIS A, et al. Freeway performance measurement system: mining loop detector data [J]. *Transportation Research Record*, 2001, 1748(1): 96-102.

(编辑:郭少华)