文章编号:1673-0291(2026)04-0191-10 **DOI**:10.11860/j.issn.1673-0291.20250180

基于多因素融合时空图卷积网络的交通流量预测

栗 剑[1],解冬东[1,2],王婷婷[3],魏晓军[3],姬明曦[4]
(1.山东高速集团有限公司,济南 250098;2.长安大学 信息工程学院,西安 710064;3.山东高速信息集团有限公司,济南 250100;4.山东山科数字经济研究院有限公司,济南 250000)

摘 要:针对城市路网交通流量难以精准预测的现实问题,提出一种基于多因素融合时空图卷积网络(Multi-factor Fusion Spatio-temporal Graph Convolutional Network, MFSGCN)的交通流量预测模型,将长期趋势、短期瞬态、周期性与时变外部因素在统一的空间图卷积框架中融合.首先,MFSGCN利用图卷积神经网络(Graph Convolutional Networks, GCN)有效捕捉交通网络中的时空依赖关系,实现空间维度上的建模;其次,MFSGCN融合动态邻接矩阵,自适应学习随时间变化的交通网络动态特征;再次,MFSGCN基于多头自注意力机制融合长期特征、短期特征、周期性特征与时变特征,有效捕捉高影响阶段的交通流量变化;最后,在METR-LA、PEMS-BAY和PEMS04数据集上进行广泛实验,验证MFSGCN的有效性和合理性.研究结果表明:MFSGCN的均方根误差(Root Mean Square Error,RMSE)和平均绝对误差(Mean Absolute Error,MAE)指标明显优于时空Transformer网络(Spatial-temporal Transformer Network,STN)、双重动态时空图卷积网络(Dual Dynamic Spatial-temporal Graph Convolution Network,DDSGCN)、域对抗图神经网络(Domain Adversarial Graph Neural Network,DAGNN)等对比模型,在15 min的预测任务中,RMSE指标结果误差最高降低了1.11,60 min长时间预测任务中,RMSE指标结果降低了1.6.研究成果可以为城市交通管理与交通信号优化提供参考.

关键词:城市交通;流量预测;图卷积;动态邻接矩阵;深度学习
中图分类号:U491;TP302.7 **文献标志码**:A

Traffic flow prediction based on multi-factor fusion spatiotemporal graph convolutional network

Li Jian[1], *Xie Dongdong*[1,2], *Wang Tingting*[3], *Wei Xiaojun*[3], *Ji Mingxi*[4]
(1.Shandong Hi-Speed Group Co., Ltd., Jinan 250098, China; 2.School of Information Engineering, Chang'an University, Xi'an 710064, China; 3.Shandong Hi-Speed Information Group Co., Ltd., Jinan 250100, China; 4.Shandong Shanke Digital Economy Research Institute Co., Ltd., Jinan 250000, China)

Abstract: To improve the accuracy of traffic flow prediction for urban road networks, this study proposes a Multi-Factor Fusion Spatiotemporal Graph Convolutional Network (MFSGCN). The model integrates long-term trends, short-term transients, periodic patterns, and time-varying external factors within a unified spatial graph convolution framework. First, MFSGCN employs a Graph Convolu-

收稿日期:2025-11-03;**修回日期**:2026-04-07
基金项目:国家重点研发计划(2024YFF0908100);山东省重点研发计划(2023CXPT035)
Foundation items: National Key R&D Program of China (2024YFF0908100); Key R&D Program of Shandong Province(2023CXPT035)
第一作者:栗剑(1983—),男,山东济南人,高级工程师,硕士.研究方向为交通信息工程及控制、大数据与人工智能. **email**:lijian1@sdhsg.com.
通信作者:姬明曦(1992—),女,宁夏中卫人,高级工程师,硕士. **email**:mingxiji@126.com.

引用格式:栗剑,解冬东,王婷婷,等.基于多因素融合时空图卷积网络的交通流量预测[J].北京交通大学学报,2026,50(4):191-200.
Li Jian, Xie Dongdong, Wang Tingting, et al.Traffic flow prediction based on multi-factor fusion spatiotemporal graph convolutional network[J].Journal of Beijing Jiaotong University, 2026, 50(4): 191-200.(in Chinese)

tional Network (GCN) to effectively capture spatiotemporal dependencies in the traffic network and model spatial relationships. Second, it incorporates a dynamic adjacency matrix to adaptively learn the time-varying characteristics of the traffic network. Third, it uses a multi-head self-attention mechanism to fuse long-term, short-term, periodic, and time-varying features, thereby effectively capturing traffic flow variations during periods of substantial external influence. Finally, extensive experiments on the METR-LA, PEMS-BAY, and PEMS04 datasets verify the effectiveness and validity of MFSGCN. The results show that MFSGCN outperforms benchmark models, including the Spatial-Temporal Transformer Network (STN), Dual Dynamic Spatial-temporal Graph Convolution Network (DDSGCN), and Domain Adversarial Graph Neural Network (DAGNN), in terms of Root Mean Square Error (RMSE) and Mean Absolute Error (MAE). For the 15-min prediction task, MFSGCN reduces RMSE by up to 1.11; for the 60-min long-horizon prediction task, it reduces RMSE by up to 1.6. These findings can inform urban traffic management and traffic signal optimization.

Keywords: urban traffic; traffic flow prediction; graph convolution; dynamic adjacency matrix; deep learning

随着全球城市化进程的加快,城市交通系统的负荷不断增加,交通拥堵问题日益严重,对城市经济和居民日常生活造成巨大影响.智能交通系统(Intelligent Transportation Systems, ITS)作为推动交通运输质量变革、效率变革、动力变革的重要途径,能够有效缓解交通压力、优化交通管理.精准的交通流量预测[1]能够帮助城市管理者合理安排交通资源、优化信号灯设置以及及时响应交通突发状况,提高整体交通效率和出行体验,因此成为ITS中的关键研究方向.

在交通流量预测的早期研究中,传统方法主要依赖基于统计学或机器学习的模型[2].随着深度学习的兴起,研究者们基于卷积神经网络(Convolutional Neural Network, CNN)[3]和循环神经网络(Recurrent Neural Network,RNN)[4]在交通流量预测领域做了大量工作.文献[5]将复杂的地理空间数据转换为图像形式,并利用CNN处理交通网络的复杂依赖关系.文献[6]提出一种特征增强的长短期记忆网络(Long Short-Term Memory,LSTM)模型,通过捕捉交通流中的时间依赖性,并整合高影响值与当前时间步,显著提高了模型的泛化能力与预测性能.文献[7]基于双向LSTM捕捉时间依赖性,结合过去与未来的时序数据,通过粒子群优化模型参数,取得了较好的预测结果.随着交通网络结构的复杂化,基于CNN和RNN的方法在捕捉非欧式空间关系时表现出一定的局限性,在处理长时间序列时存在显著的计算瓶颈,随着序列长度的增加,模型容易出现梯度消失或梯度爆炸问题.

图卷积神经网络(Graph Convolutional Networks, GCN)能够有效处理非欧式空间中的不规则图结构,在交通网络的拓扑建模中展现出显著优势,已成为交通流量预测领域的关键技术,并受到广泛关注[8-9].文献[10]结合GCN与LSTM提出一种时空图卷积网络模型,用于捕捉网络中节点的动态时空特征,克服了CNN和传统RNN在捕捉非欧式空间结构上的局限,提高了交通流量预测的准确性.文献[11]结合GCN与LSTM,从异构的时空数据中提取复杂的时空依赖关系,既有效处理了交通流量,还提高了交通事故预测的准确率.然而,LSTM在处理长时间序列时存在计算瓶颈,模型的时序捕捉能力有限.Transformer基于自注意力机制,可以有效捕捉序列中的长时依赖,还具备并行处理序列数据的能力.为解决现有方法在捕捉时空依赖性方面的不足,近年来研究者们将Transformer与GCN结合[12]实现精准建模交通网络中的拓扑结构,在交通流量预测中取得了良好的成效.文献[13]结合Transformer与GCN,在有效捕捉交通网络的复杂空间拓扑关系的同时,还处理了长时间序列中的全局依赖性.近期,文献[14]提出的时空图Transformer将图拓扑编码与时空注意力机制结合,强调了图卷积与Transformer在交通预测中协同建模空间-时间依赖的重要性,在真实交通流量数据集上取得了优异的预测性能.文献[15]提出了一种融合动态多图卷积与Transformer的时空预测模型,在同时捕捉长短期时间相关性与复杂空间关系方面表现优异,显著提升了长短期预测精度.文献[16]构建了一个多尺度时空图神经网络,通过多时间尺度的特征分解与统一编码模块,有效提取不同时间尺度下

的交通流模式,提升了交通流量预测的泛化能力.文献[17]提出了面向语义感知的图 Transformer 架构,通过引入路网语义信息引导 Transformer 中的空间注意力机制,提高了对道路拓扑语义特征及时变空间依赖的建模精度.

尽管目前的交通流量预测模型已具有良好的应用性能,但在处理复杂时空依赖和动态特征融合方面仍存在不足,模型的泛化能力有限.此外,现有模型整合外部因素的方式较为简单,没有充分考虑非周期性因素的影响.鉴于此,针对交通流量周期性变化难以刻画、事故或信号灯放行等引起的突发流量难以捕捉的问题,提出了多因素融合时空图卷积网络(Multi-factor Fusion Spatio-temporal Graph Convolutional Network, MFSGCN),将长期趋势、短期瞬态、周期性与时变外部因素纳入统一建模框架,结合 GCN 的空间特征提取优势与 Transformer 的时序处理能力,实现了复杂时空依赖关系的精确建模,提升交通流量预测的准确性与泛化能力.

1　问题定义

假设交通网络包含 N 个节点,每个节点代表不同的传感器,在 T 时间步长下记录流量数据,利用给定的时间序列数据,预测未来时间步的交通流量,并通过融合长期特征、短期特征、周期性特征、时变特征等提升预测精度,相关定义如下:

设交通流量数据 $\boldsymbol{X}=[X_1, X_2, \cdots, X_T]$,其中 $X_i \in \mathbb{R}^{N\times F}$,表示时间步 i 的交通流量数据,F 表示每个节点的特征维度.预测目标为 $\boldsymbol{Y}=[Y_{T+1}, Y_{T+2}, \cdots, Y_{T+P}]$,其中 $Y_i \in \mathbb{R}^{N\times F}$,表示未来 P 时间步的交通流量.

为了提升模型的预测能力,引入长期特征、短期特征、周期性特征、时变特征,其中长期特征 $\boldsymbol{L}=[L_1, L_2, \cdots, L_T]$,$L_i \in \mathbb{R}^{N\times F}$,反映长时间段内的流量变化;短期特征 $\boldsymbol{S}=[S_1, S_2, \cdots, S_T]$,$S_i \in \mathbb{R}^{N\times F}$,反映短期内的流量波动;周期性特征 $\boldsymbol{C}=[C_1, C_2, \cdots, C_T]$,$C_i \in \mathbb{R}^{N\times F}$,反映周期性的流量波动;时变特征 $\boldsymbol{E}=[E_1, E_2, \cdots, E_T]$,$E_i \in \mathbb{R}^{N\times F}$,反映节假日、天气突变等外部因素的流量波动.

交通流量预测问题可以描述为一个时空序列建模问题:在给定的历史交通流量数据的基础上,预测未来多个时间步的交通流量.MFSGCN 基于交通流量数据 $\boldsymbol{X}$、长期特征 $\boldsymbol{L}$、短期特征 $\boldsymbol{S}$、周期性特征 $\boldsymbol{C}$ 和时变特征 $\boldsymbol{E}$ 联合建模,来预测未来时间步内的交通流量,表达式为

$$[Y_{T+1}, Y_{T+2}, \cdots, Y_{T+P}]=f(\boldsymbol{X}, (\boldsymbol{L}, \boldsymbol{S}), \boldsymbol{C}, \boldsymbol{E}) \quad (1)$$

2　方法模型

为了精准预测城市路网交通流量,进而缓解交通拥堵、优化交通资源配置及提升交通管理效率,结合 GCN 和 Transformer 架构,提出一种基于多因素融合时空图卷积网络 MFSGCN,充分考虑节假日、天气突变等外部因素对交通流量的影响,可有效捕捉交通网络中的复杂时空依赖关系.

2.1　MFSGCN 整体结构

MFSGCN 模型综合考虑了长期趋势、短期瞬态、周期性与时变外部因素对交通流量的影响,在统一的空间图卷积框架中进行融合,整体架构如图 1 所示.由图 1 可知:MFSGCN 是一个基于 GCN 与 Transformer 的多因素融合时空图网络,GraphWaveNet 模块包括利用 WaveNet[18] 进行时间卷积和利用 GCN 在空间维度上传递拓扑信息;通过长短期特征提取模块、周期特征提取模块和时变特征提取模块实现对交通流量预测的精准建模;利用多头自注意力机制将长期特征、短期特征、周期性特征和时变特征进行融合,自适应调节不同因素对交通流量的影响,使模型能够对未来交通流量进行更精准的预测,在面对复杂的时空依赖关系时,展现了较强的预测能力.

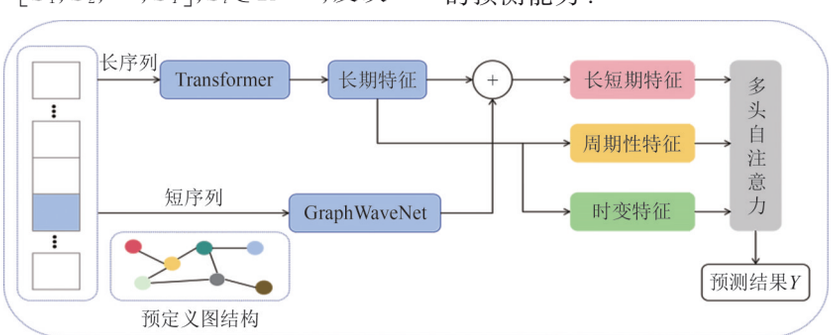


图 1　MFSGCN 模型结构图

Fig.1　Architecture of the MFSGCN model

2.2　长短期特征提取

在交通流量预测中，短期时序主要反映突发变化和局部动态，而长期时序则蕴含周期性模式与稳定趋势．因此，依据数据集采样频率及交通时序规律，可以将输入时序划分为短序列与长序列，并分别用于短期动态与长期规律的特征学习．MFSGCN模型通过结合空洞卷积和图卷积，分别从长期和短期时间尺度上提取流量特征，确保其能够有效应对交通流量的高频波动和低频趋势，其中长短期特征提取模块如图2所示．

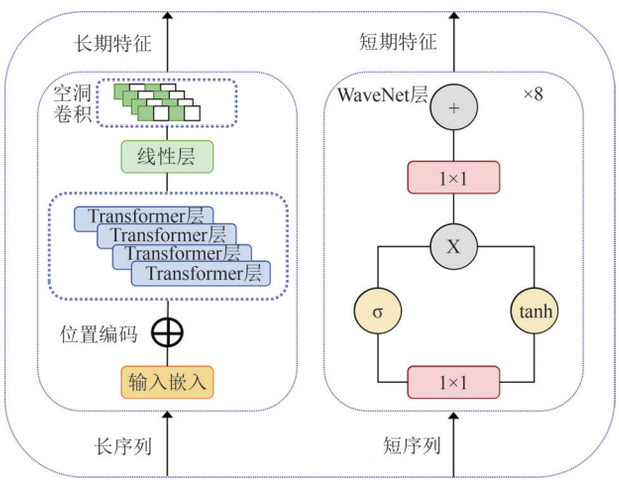


图2　长短期特征提取模块

Fig.2　Long-term and short-term feature extraction module

短序列采用长度为12的最近时段数据，对应1小时的流量记录，能够捕获高频、快速响应的短期波动．长序列采用长度为4 032的连续历史序列，对应两周数据，用于建模交通流量的长期趋势与周期性结构．

长序列经过Transformer编码器后，进一步采用多层空洞卷积网络，通过逐层递增的扩张率来捕捉更大范围内的依赖关系．给定输入流量数据$X\in\mathbb{R}^{C_{in}\times N\times F}$，时间步$t$处的长期特征$L(t)$提取方式为

$$L(t)=\sum_{c=1}^{C_{in}}\sum_{n=1}^{N}\sum_{m=-M}^{M}W_l(c,n,m)\cdot X(c,n,t-m)\quad(2)$$

式中：C_{in}是输入通道数；$W_l(c,n,m)$表示第l层中通道c、节点n和时间偏移m的卷积核权重；$X(c,n,t-m)$是时间步$t-m$处的输入流量数据；M表示卷积核的大小．通过对不同时间尺度上的信息进行卷积，MFSGCN能够从长序列中提取趋势性变化．这种机制使模型能够更好地捕捉流量中的低频长期变化，确保其在长时间跨度内的预测效果．

短期特征$S(t)$通过堆叠WaveNet层的扩张因果卷积单元实现，其主要目的是在时间维度上捕捉节点的短期波动，同时保留用于后续空间聚合的节点级表示．给定最近时间步的交通流量数据$X_{t-S_l+1:t}$，短期特征的提取方式为

$$S(t)=\mathrm{WaveNet}(X_{t-S_l+1:t})\quad(3)$$

式中：S_l为短期特征S的长度；$S(t)$是WaveNet层堆叠后提取的短期时序特征，使MFSGCN能够准确捕捉交通流量在最近时间窗口内的快速波动与局部时序依赖．

为进一步提升预测精度，长短期特征提取模块对长期特征$L(t)$和短期特征$S(t)$进行线性融合，得到长短期特征融合H_{fused}为

$$H_{\mathrm{fused}}=\boldsymbol{W}_{\mathrm{f}}\cdot[L(t)\oplus S(t)]+b_{\mathrm{f}}\quad(4)$$

式中：$\boldsymbol{W}_{\mathrm{f}}$为融合权重矩阵；$b_{\mathrm{f}}$为计算长短期特征融合的偏置项；$\oplus$表示沿通道维度进行拼接．通过融合长期特征与短期特征，MFSGCN在面对不同时间尺度的流量变化时，能够同时捕捉短期和长期的交通流量变化趋势．

2.3　周期性特征提取

为了捕捉交通流量中的日周期和周周期特征，MFSGCN模型通过周期性特征提取模块捕捉交通流量中的周期性波动，其模块结构如图3所示．

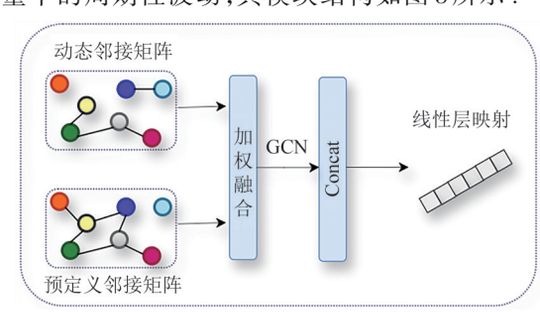


图3　周期性特征提取模块

Fig.3　Periodic feature extraction module

该模块通过结合长期特征$L(t)$与空洞卷积模块来实现．对于任意的时间步t，通过前一周的流量$X_{\mathrm{w}}t$和前一天的流量$X_{\mathrm{d}}t$来提取周周期的周期性特征$S_{\mathrm{w}}(t)$和日周期的周期性特征$S_{\mathrm{d}}(t)$，计算式分别为

$$S_{\mathrm{w}}(t)=\sum_{j=1}^{K}\alpha_j\cdot\left(\sum_{m=-M}^{M}w_{\mathrm{w}}(m)\cdot X_{\mathrm{w}}(t-m)\right)\quad(5)$$

$$S_{\mathrm{d}}(t)=\sum_{j=1}^{K}\alpha_j\cdot\left(\sum_{m=-M}^{M}w_{\mathrm{d}}(m)\cdot X_{\mathrm{d}}(t-m)\right)\quad(6)$$

式中：K表示所考虑的动态邻接关系数量；j表示动态邻接矩阵的索引；$w_{\mathrm{w}}(m)$和$w_{\mathrm{d}}(m)$分别表示周周期和日周期的卷积核权重；α_j表示为动态邻接矩阵的权重．通过多层感知机（Multi-Layer Perceptron，MLP）拼接周周期特征和日周期特征得到最终的周

期性特征,计算式为

$$C(t)=\mathrm{MLP}\left(S_{\mathrm{w}}(t)\oplus S_{\mathrm{d}}(t)\oplus L(t)\right) \tag{7}$$

2.4　时变特征提取

时变特征主要捕捉交通流量中不具周期性、但具有显著时间波动性的外部影响因素,如节假日、天气突变、大型活动、道路施工等.这些因素往往导致交通流量在短期内偏离历史规律,传统周期性和短期特征难以有效建模,因此需要引入显式的时变特征提取模块.MFSGCN通过时变特征提取模块处理该问题.时变特征提取模块基于一维卷积进行特征提取,对于任意的时间步t,时变特征$E(t)$的计算式为

$$E(t)=W_{\mathrm{h}}\cdot H(t)+b'_{\mathrm{h}} \tag{8}$$

$$H(t)=\sigma\left(\sum_{m=-M}^{M}w_{\mathrm{h}}(m)\cdot H(t-m)+b_{\mathrm{h}}\right) \tag{9}$$

式中:σ表示ReLU激活函数;$w_{\mathrm{h}}(m)$为卷积核权重;b_{h}为计算$H(t)$的偏置项;W_{h}和b'_{h}为全连接层的权重和计算时变特征的偏置项.

2.5　多头注意力特征融合

为了充分挖掘短期特征、长期趋势特征、周期性特征以及时变特征之间的相互关系,MFSGCN使用多头注意力机制进行特征融合,将长期、短期、周期与时变4类特征共同用于构建注意力机制的查询、键和值,使不同因素共同决定空间-时间依赖的表示,在不同的特征维度上并行计算不同的注意力权重,从而更好地捕捉复杂的时空依赖关系和多特征之间的交互.对于给定长短期特征H_{fused}、周期性特征$C(t)$和时变特征$E(t)$,将其统一记为$\mathcal{H}=\{H_{\mathrm{fused}},C(t),E(t)\}$,经过线性映射生成多头注意力的查询、键、值,通过多头注意力机制中的Concat特征融合函数、softmax激活函数获取最终融合的综合特征表示F_{fusion},其计算式为

$$F_{\mathrm{fusion}}=\boldsymbol{W}^{\mathrm{O}}\cdot\mathrm{Concat}\left(\mathrm{softmax}\left(\frac{QK^{\mathrm{T}}}{\sqrt{d}}+B_T\right)V\right) \tag{10}$$

$$\begin{cases}Q=\sum\limits_{f\in\mathcal{H}}H_f W_f^{\mathrm{Q}}\\ K=\sum\limits_{f\in\mathcal{H}}H_f W_f^{\mathrm{K}}\\ V=\sum\limits_{f\in\mathcal{H}}H_f W_f^{\mathrm{V}}\\ B_T=\phi(H_T)\end{cases} \tag{11}$$

式中:$\boldsymbol{W}^{\mathrm{O}}$为线性映射矩阵.通过设置多个注意力头,模型能够并行计算不同特征之间的相关性,避免单一注意力头可能造成依赖关系错失,并增强模型的表达能力,使得模型能够更全面地理解交通流量的时空变化,从而提升对未来流量的预测准确性.

2.6　损失函数

为仅对有效数据进行误差计算,进而确保模型在面对不完整数据时仍能保持较高的预测精度,MFSGCN采用掩码平均绝对误差(Masked Mean Absolute Error, Masked MAE)作为模型的损失函数,损失函数Loss的计算式为

$$\mathrm{Loss}=\frac{\sum\limits_{i=1}^{\mathrm{num}}\mathrm{Mask}_i\cdot|Y_i-\hat{Y}_i|}{\sum\limits_{i=1}^{\mathrm{num}}\mathrm{Mask}_i} \tag{12}$$

式中:Mask_i为第i个样本的掩码指示值,用来表述该样本是否为有效数据;Y_i为第i个样本的真实值;$\hat{Y}_i$为第i个样本的模型预测值;num为样本数量.基于掩码机制,MFSGCN在面对不完整数据时能够专注于对有效信息的学习,从而提高其在不同数据完整性条件下的预测能力.

3　实验

使用NVIDIA RTX 4090 GPU进行模型的训练与测试,训练周期为100,以确保模型在大规模数据集上的充分训练与稳定收敛.将MFSGCN模型在3个交通流量数据集上进行验证,包括METR-LA[18]、PEMS-BAY[19]和PEMS04[20]数据集,数据集详细信息如下.

METR-LA:洛杉矶地区的交通流量数据集,包含2012年3月至2012年6月的交通流量信息,涵盖207个传感器的数据.

PEMS-BAY:加州湾区的交通流量数据集,包含2017年1月1日至2017年5月31日的交通流量信息,涵盖325个传感器的数据.

PEMS04:加利福尼亚州的交通流量数据集,包含2018年1月至2018年2月的交通流量信息,涵盖29条高速公路上的307个传感器数据.

在实验中,对于METR-LA与PEMS-BAY数据集,按照7:2:1的比例划分训练集、验证集和测试集;对于PEMS04数据集,按照6:2:2的比例进行划分.训练集用于模型参数学习,验证集用于超参数调节与早停策略选择,测试集仅用于最终性能评估.

模型在训练、验证与测试阶段均采用一致的输入构造方式.对预测的任意时间步t,短期输入序列用于刻画近期交通流量的动态变化,长期输入序列用于建模交通流量的长期趋势与周期性结构,二者均来自预测时刻之前的历史观测数据.长期序列不直接作为逐时间步预测输入,而是以压缩后的趋势与周期为表示形式参与特征融合,从而提升模型对

复杂时空依赖的建模能力.

为了全面评估模型的预测性能,实验采用均方根误差(Root Mean Square Error,RMSE)、平均绝对误差(Mean Absolute Error,MAE)、平均绝对百分比误差(Mean Absolute Percentage Error,MAPE)3种常用的评价指标进行评估.对MFSGCN模型通过统一处理缺失数据,确保评估的一致性,并与其他基线模型进行公平比较.采用的METR-LA、PEMS-BAY与PEMS04数据集的原始交通流量数据采样间隔均为5 min.在此基础上,将未来连续多个时间步的预测结果进行组合,以实现不同时间跨度的预测任务.15 min、30 min和60 min的预测分别对应未来3、6和12个5 min时间步的交通流量预测.

3.1 对比试验

在公开数据集(METR-LA、PEMS-BAY、PEMS04)中验证MFSGCN模型的RMSE、MAE和MAPE性能,并与现有的交通流量预测模型进行对比,包括DSTET[21]、STN[22]、MTGNN[23]、DDSGCN[24]、STID[25]和DAGNN[26](选取的6个模型均为交通预测领域常用或具有代表性的工作,覆盖Transformer、动态图结构学习、图学习+卷积时序建模、双动态时空图卷积、跨城市迁移学习等多种技术路线).同时,对比模型均在METR-LA、PEMS-BAY、PEMS04等公开基准上进行验证,并提供论文可查证的结果与/或公开实现,具备较好的可复现性与对比公平性.

将METR-LA按7∶2∶1划分训练集、验证集和测试集,从测试集中选取典型传感器节点Sensor node 91和Sensor node 196,截取前6 000个时间步开展分析,对比连续时间段内的交通流量预测值与真实观测值,结果如图4所示.图4中:曲线出现的不连续区间并非模型预测中断,而是由于原始数据中存在缺失值(无有效观测)所致;在这些时刻,真实值无法提供可靠参考,因此图中对应位置留空以保持可视化的客观性.同时,在定量评价指标计算时亦遵循常用做法,对缺失值进行掩码处理,仅在有效观测位置统计RMSE、MAE与MAPE,以保证实验结果的公平性与可复现性.

由图4可知:MFSGCN在整体趋势建模方面能够较好地贴合真实交通流量变化,预测曲线在大多数时间段内与真实值保持一致,即MFSGCN模型具备稳定的长期预测能力;在交通流量相对平稳的时段,模型能够准确捕捉流量的周期性波动,预测结果平滑且误差较小;在交通流量出现突变或剧烈波动的时段(如流量骤降或异常低谷),MFSGCN仍

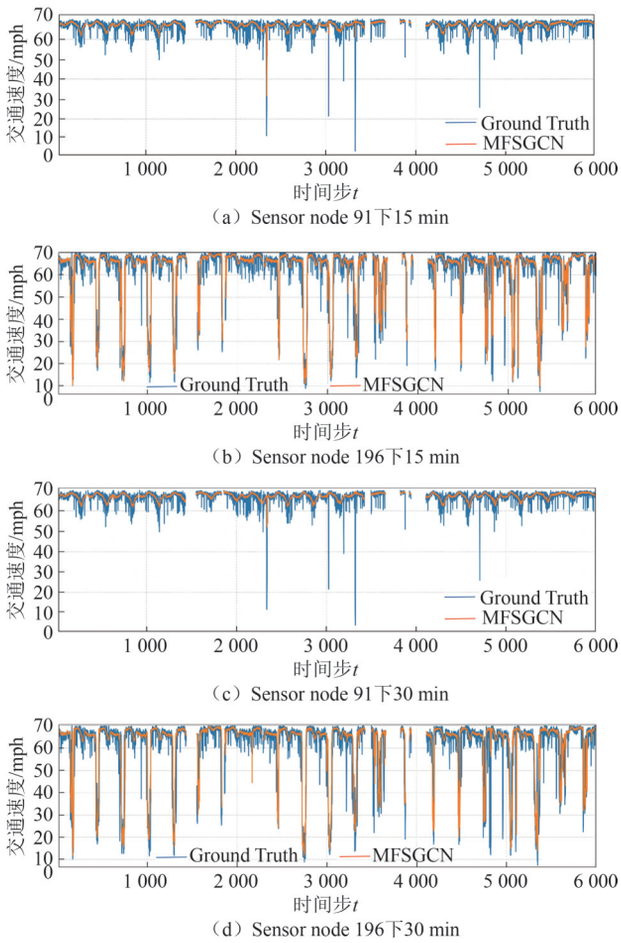


图4 METR-LA数据集上预测结果与真实值对比图

Fig.4 Comparison between predicted and observed traffic flows on the METR-LA dataset

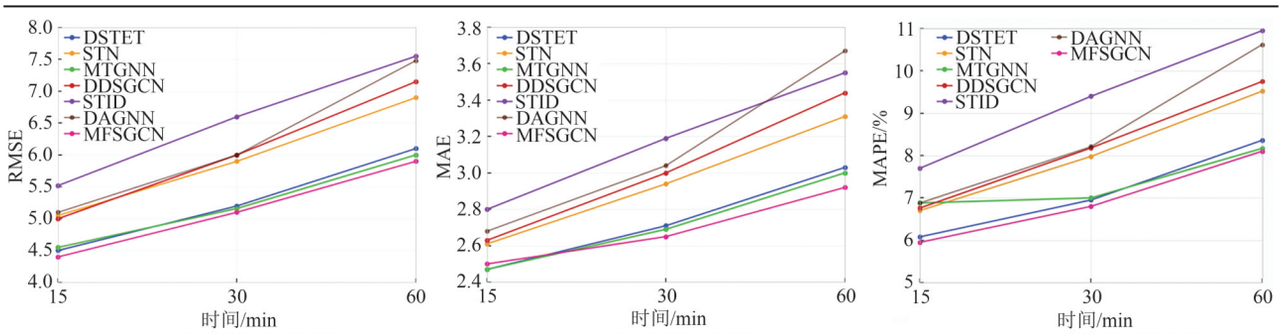
能较好地跟随真实值变化趋势,虽然在极端变化点附近存在一定偏差,但整体预测误差显著受控,未出现明显的滞后或发散现象,表明MFSGCN在复杂交通状态下仍具备较强的鲁棒性,对突发变化具有一定的响应能力.

现有模型的实验结果来源于LSTTN[1]、DSTET[21]和STN[22]中的数据,对于实验中使用到的数据集,METR-LA与PEMS-BAY均严格按照7∶2∶1划分训练集、验证集和测试集,PEMS04按照6∶2∶2划分训练集、验证集和测试集,对比实验结果如表1所示,可视化对比结果分别如图5、图6和图7所示.由表1可知:在15 min、30 min和60 min预测任务中,MFSGCN模型在各个时间步长上的误差均显著低于对比模型;各对比模型在应对复杂的交通流量变化时,预测值与实际值之间的差距较大,并且在多个数据集上泛化能力不足.MFSGCN模型通过融合图卷积网络和Transformer的优势,利用多头注意力机制和动态邻接矩阵,实现了精准的交通流

表 1　在 METR-LA、PEMS-BAY 和 PEMS04 数据集上的预测性能比较

Tab.1　Comparison of prediction performance on METR-LA, PEMS-BAY and PEMS04 datasets

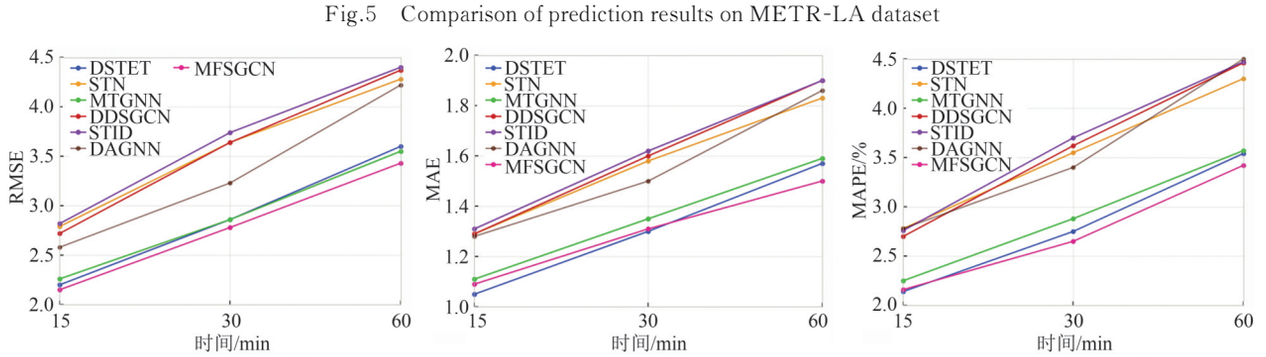
数据集	模型	15 min 条件			30 min 条件			60 min 条件		
		RMSE ↓	MAE ↓	MAPE ↓ /%	RMSE ↓	MAE ↓	MAPE ↓ /%	RMSE ↓	MAE ↓	MAPE ↓ /%
METR-LA	DSTET	4.52	**2.46**	6.05	5.22	2.71	6.95	6.08	3.03	8.30
	STN	5.05	2.62	6.72	5.94	2.94	7.98	6.88	3.31	9.54
	MTGNN	4.55	2.46	6.87	5.19	2.69	7.00	6.01	3.00	8.14
	DDSGCN	5.01	2.64	6.76	6.02	3.00	8.12	7.13	3.44	9.74
	STID	5.53	2.80	7.70	6.60	3.18	9.40	7.54	3.55	10.95
	DAGNN	5.03	2.67	6.85	6.00	3.03	8.16	7.49	3.67	10.55
	MFSGCN	**4.42**	2.49	**5.96**	**5.13**	**2.65**	**6.83**	**5.94**	**2.93**	**8.08**
PEMS-BAY	DSTET	2.17	**1.06**	**2.13**	2.85	**1.29**	2.74	3.60	1.57	3.54
	STN	2.78	1.29	2.74	3.63	1.58	3.55	4.27	1.83	4.30
	MTGNN	2.21	1.11	2.25	2.85	1.34	2.86	3.55	1.59	3.58
	DDSGCN	2.71	1.29	2.69	3.64	1.60	3.62	4.37	1.89	4.46
	STID	2.81	1.30	2.73	3.72	1.62	3.68	4.40	1.89	4.47
	DAGNN	2.58	1.28	2.75	3.22	1.49	3.38	4.21	1.86	4.50
	MFSGCN	**2.13**	1.09	2.15	**2.79**	1.30	**2.66**	**3.42**	**1.50**	**3.41**
PEMS04	DSTET	**27.38**	16.90	11.59	28.66	17.68	12.44	29.77	18.48	12.71
	STN	29.31	17.73	11.83	—	—	—	—	—	—
	MTGNN	27.97	17.41	12.75	28.92	17.97	13.31	30.23	18.73	13.81
	DDSGCN	28.38	17.69	12.34	29.54	18.51	12.70	30.69	19.51	13.46
	STID	28.48	17.51	12.00	29.86	18.29	12.46	31.79	19.58	13.38
	DAGNN	29.68	19.13	13.85	32.02	20.53	14.31	38.87	23.63	15.55
	MFSGCN	27.60	**16.45**	**11.30**	**28.62**	**17.55**	**12.05**	**29.62**	**18.33**	**12.23**



（a）RMSE结果对比情况　（b）MAE结果对比情况　（c）MAPE结果对比情况

图 5　METR-LA 数据集上的预测结果对比图

Fig.5　Comparison of prediction results on METR-LA dataset



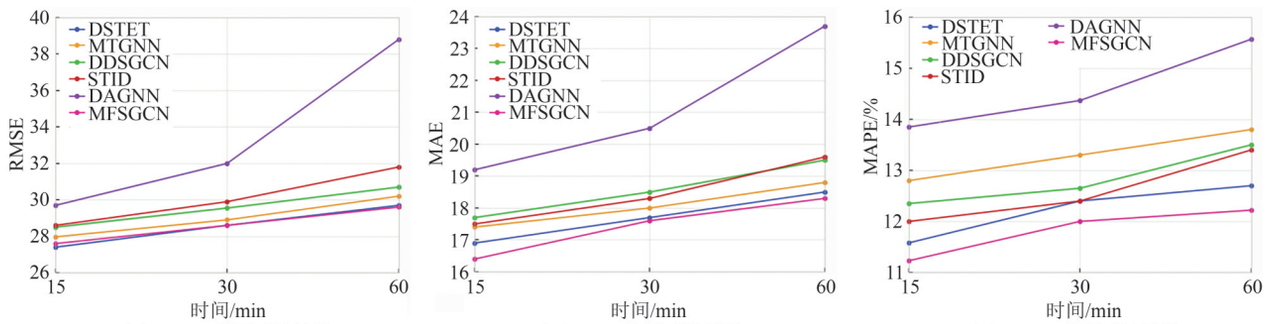
（a）RMSE结果对比情况　（b）MAE结果对比情况　（c）MAPE结果对比情况

图 6　PEMS-BAY 数据集上的预测结果对比图

Fig.6　Comparison of prediction results on PEMS-BAY dataset

量预测,并且具有较强的泛化能力,MFSGCN 模型的参数量约为 1.26 M,在 METR-LA 数据集上单样本前向计算量约为 58.1 GFLOPs.

为评估 MFSGCN 模型的训练效率,对比分析



（a）RMSE结果对比情况 （b）MAE结果对比情况 （c）MAPE结果对比情况

图7 PEMS04数据集上的预测结果对比图

Fig.7 Comparison of prediction results on PEMS04 dataset

了MFSGCN与LSTTN等基线模型在训练一个epoch时的时长与模型参数量.为确保计算环境的一致性和公平性,实验均在NVIDIA RTX A6000 GPU上进行,现有模型的实验数据均来源于LSTTN[1].表2列出了MFSGCN与其他基线模型的参数量及训练时长的对比数据.

表2 模型参数及训练时间对比

Tab.2 Comparison of model parameter counts and training times

模型名	参数量/M	训练时间/(s/epoch)
Graph WaveNet[27]	0.99	19.6
MTGNN[23]	1.61	22.3
DSTET[21]	0.72	48.2
LSTTN[1]	2.19	611.6
MFSGCN	1.26	507.3

由表2可知:MFSGCN的训练时长为507.3 s/epoch,与LSTTN的611.6 s/epoch相较,MFSGCN在计算效率上表现较好;MFSGCN的参数量(1.26 M)较LSTTN(2.19 M)更少,但仍能够在相同硬件设备上高效运行;MFSGCN训练时采用批次大小为16的输入序列,GPU显存占用约为20 526 MB,在保持良好预测性能的同时,具有较高的训练效率.通过这些对比,可以看出MFSGCN模型的设计在模型复杂度与训练效率之间找到了较好的平衡,能够在大型交通流量预测任务中实现高效的计算性能.

3.2 消融试验

为进一步验证MFSGCN模型中各个模块在交通流量预测中的性能,在METR-LA数据集上进行消融实验,并对完整模型和去除各模块后的模型在不同时间步长上的性能进行比较,时间步长设置为15、30、60 min,消融实验模型配置为:① 完整模型(MFSGCN),包含短期特征、长期特征、周期性特征和时变特征的完整模型;② w/o周期性特征(w/o CM),去除周期性特征提取模块,仅保留短期、长期和时变特征;③ w/o时变特征(w/o EM),去除时变特征提取模块,仅保留短期、长期和周期性特征;④ w/o长短期特征(w/o LT),去除长期特征提取模块,仅保留短期、周期性和时变特征.

为了评估不同模型配置的性能,采用RMSE、MAE、MAPE 3个指标进行对比,实验结果如表3所示.

表3 消融实验

Tab.3 Ablation experiments

模型配置	时间步长/min	RMSE↓	MAE↓	MAPE↓/%
MFSGCN	15	**4.42**	**2.49**	**5.96**
w/o CM	15	4.78	2.59	6.42
w/o EM	15	4.69	2.55	6.31
w/o LT	15	4.80	2.61	6.50
MFSGCN	30	**5.13**	**2.65**	**6.83**
w/o CM	30	5.45	2.84	7.30
w/o EM	30	5.38	2.80	7.15
w/o LT	30	5.53	2.89	7.40
MFSGCN	60	**5.94**	**2.93**	**8.08**
w/o CM	60	6.25	3.15	8.60
w/o EM	60	6.20	3.10	8.45
w/o LT	60	6.34	3.20	8.75

由表3可知:去除MFSGCN模型中任何一个模块都会导致模型的整体预测性能下降,尤其是在长时间步长的预测中;周期性特征和时变特征对于捕捉交通流量中的规律性和特殊变化具有重要作用;长期特征则对理解整体流量趋势至关重要.

4 结论

1)提出了一种基于时空图卷积网络的交通流量预测模型(MFSGCN),基于GCN和Transformer架构综合考虑了长短期趋势、周期性因素和事故、红绿灯放行等多种因素对交通流量的影响,能够有效捕捉交通网络中的时空依赖关系.

2)MFSGCN融合动态邻接矩阵,并通过多头

注意力融合分配不同的权重,实现了对交通流量的精准预测.

3) 由 METR-LA、PEMS-BAY 和 PEMS04 公开数据集上的实验可知,MFSGCN 在 RMSE、MAE 和 MAPE 等指标上总体优于 DSTET、STN、MTGNN 等 6 大对比模型,其中在 15 min 预测任务中,RMSE 最大降低 1.11;在 60 min 长时预测任务中,RMSE 最大降低 1.6,表明该模型在短时与长时交通流量预测任务中均具有较好的预测性能和泛化能力.

未来工作将进一步引入天气、气温等外部因素,构建天气特征处理模块,以提升模型在复杂环境下的适应性.

参考文献(References):

[1] Luo Q Y, He S L, Han X, et al. LSTTN: A Long-Short Term Transformer-based spatiotemporal neural network for traffic flow forecasting[J]. Knowledge-Based Systems, 2024, 293: 111637.

[2] Dell'Acqua P, Bellotti F, Berta R, et al. Time-aware multivariate nearest neighbor regression methods for traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(6): 3393－3402.

[3] Tu Y, Lin S K, Qiao J Z, et al. Deep traffic congestion prediction model based on road segment grouping[J]. Applied Intelligence, 2021, 51(11): 8519－8541.

[4] 王思超, 汤颖. 结合自相关注意力动态卷积的交通预测网络[J]. 小型微型计算机系统, 2024, 45(6): 1418－1425.
Wang Sichao, Tang Ying. Auto-correlation attention and dynamics convolution based spatial-temporal networks for traffic forecasting[J]. Journal of Chinese Computer Systems, 2024, 45(6): 1418－1425. (in Chinese)

[5] Jiang W W, Zhang L. Geospatial data to images: a deep-learning framework for traffic forecasting[J]. Tsinghua Science and Technology, 2019, 24(1): 52－64.

[6] Yang B L, Sun S L, Li J Y, et al. Traffic flow prediction using LSTM with feature enhancement[J]. Neurocomputing, 2019, 332: 320－327.

[7] Bharti, Redhu P, Kumar K. Short-term traffic flow prediction based on optimized deep learning neural network: PSO-Bi-LSTM[J]. Physica A: Statistical Mechanics and its Applications, 2023, 625: 129001.

[8] 郭健, 郑皎凌, 乔少杰, 等. 基于深度时序聚类的城市卡口短时交通流量预测[J]. 计算机应用研究, 2025, 42(2): 371－380.
Guo Jian, Zheng Jiaoling, Qiao Shaojie, et al. Short-term traffic flow prediction of city intersection based on deep temporal clustering[J]. Application Research of Computers, 2025, 42(2): 371－380. (in Chinese)

[9] 王佳昊, 黎文斌, 郭仕尧, 等. 基于全局时空图卷积神经网络的城市交通流量预测[J]. 计算机科学, 2024, 51(增 2): 534－542.
Wang Jiahao, Li Wenbin, Guo Shiyao, et al. Urban traffic flow prediction based on global spatiotemporal graph convolutional neural network[J]. Computer Science, 2024, 51(S2): 534－542. (in Chinese)

[10] Chen J Y, Wang X K, Xu X H. Gc-lstm: graph convolution embedded LSTM for dynamic network link prediction[J]. Applied Intelligence, 2022, 52(7): 7513－7528.

[11] Yuan Z N, Zhou X, Yang T B. Hetero-ConvLSTM: A deep learning approach to traffic accident prediction on heterogeneous spatio-temporal data[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, 2018: 984－992.

[12] Wen Y J, Li Z H, Wang X Y, et al. Traffic demand prediction based on spatial-temporal guided multi graph Sandwich-Transformer[J]. Information Sciences, 2023, 643: 119269.

[13] Geng Z L, Xu J, Wu R S, et al. STGAFormer: Spatial-temporal Gated Attention Transformer based Graph Neural Network for traffic flow forecasting[J]. Information Fusion, 2024, 105: 102228.

[14] Wang Z C, Hu Y, Zhong R R, et al. St-Graphormer: Spatio-temporal graph transformer for end-to-end traffic forecasting[J]. The Journal of Supercomputing, 2025, 81(8): 896.

[15] Zhang J, Yang Y M, Wu X H, et al. Spatio-temporal transformer and graph convolutional networks based traffic flow prediction[J]. Scientific Reports, 2025, 15: 24299.

[16] CHEN H, HUANG J, LU Y, et al. Multi-scale spatio-temporal graph neural network for urban traffic flow prediction[J]. Scientific Reports, 2025, 15: 26732.

[17] Dong P P, Zhang X N. ST-GTrans: Spatio-temporal graph transformer with road network semantic awareness for traffic flow prediction[J]. Neural Networks, 2025, 190: 107623.

[18] Van Den Oord A, Dieleman S, Zen H G, et al. WaveNet: A generative model for raw audio[C]// Proceedings of the 9th ISCA Speech Synthesis Workshop. Sunnyvale, 2016:1－15.

[19] Li Y, Yu R, Shahaibi C, et al. Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting[C]//6th International Conference on Learning Representations (Poster). Canada, 2018:1－16.

[20] Guo S N, Lin Y F, Feng N, et al. Attention based

spatial-temporal graph convolutional networks for traffic flow forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 922－929.

[21] Sun W, Cheng R Z, Jiao Y Q, et al. Transformer network with decoupled spatial-temporal embedding for traffic flow forecasting[J]. Applied Intelligence, 2023, 53(24): 30148－30168.

[22] Ma J, Zhao J, Hou Y. Spatial-temporal transformer networks for traffic flow forecasting using a pre-trained language model[J]. Sensors, 2024, 24(17): 5502.

[23] Wu Z H, Pan S R, Long G D, et al. Connecting the dots: multivariate time series forecasting with graph neural networks [C]//Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Virtual, 2020: 753－763.

[24] Sun Y F, Jiang X H, Hu Y L, et al. Dual dynamic spatial-temporal graph convolution network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 23680－23693.

[25] Yu B, Yin H T, Zhu Z X. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Stockholm, 2018: 3634－3640.

[26] Ouyang X C, Yang Y, Zhang Y L, et al. Domain adversarial graph neural network with cross-city graph structure learning for traffic prediction[J]. Knowledge-Based Systems, 2023, 278: 110885.

[27] Wu Z H, Pan S R, Long G D, et al. Graph WaveNet for deep spatial-temporal graph modeling[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. Macao, 2019: 1907－1913.