

基于注意力和线性层融合的 动态图卷积交通量预测模型

尉辉¹, 肖洪波^{2,3}, 邹北骥², 奎晓燕², 肖捡花³, 和佳聚³, 合尼古力¹

1. 新疆交通职业技术学院人工智能工程学院, 新疆 乌鲁木齐 831401;

2. 中南大学计算机学院, 湖南 长沙 410012;

3. 怀化学院计算机与人工智能学院(软件学院), 湖南 怀化 418000

摘要

交通量的精准预测是优化路网运行效率、缓解城市交通拥堵的关键。针对传统模型依赖预定义静态图结构、难以捕捉动态时空相关性以及单一时间尺度建模难以全面提取多尺度特征的问题, 提出了双重动态自适应时空建模框架。该框架在时间维度采用动态时间特征提取多头注意力机制, 自适应调整时序权重以捕捉关键动态特征; 在空间维度设计动态图卷积网络, 通过自注意力机制实时生成邻接矩阵, 以表征节点间动态空间依赖关系, 从而实现时空双重动态协同建模。此外, 该框架引入可学习的线性融合层, 自适应整合多时间尺度预测结果, 协同优化局部与全局特征表达。在真实道路数据集上的实验表明, 该框架显著优于基线模型, 验证了其优越的时空特征捕捉与预测性能。

关键词

交通量预测; 动态时间特征提取多头注意力机制; 动态图卷积; 线性层融合

中图分类号: TP399

文献标志码: A

doi: 10.11959/j.issn.2096-0271.2026015

Dynamic graph convolutional traffic flow prediction model based on attention and linear layer fusion

Wei Hui¹, Xiao Hongbo^{2,3}, Zou Beiji², Kui Xiaoyan², Xiao Jianhua³, He Jiaju³, He Niguli¹

1. School of Artificial Intelligence Engineering, Xinjiang Communications Polytechnic University, Urumqi 831401, China

2. School of Computer Science and Engineering, Central South University, Changsha 410012, China

3. School of Computer and Artificial Intelligence (School of Software), Huaihua College, Huaihua 418000, China

Abstract

Accurate traffic volume prediction is crucial for optimizing the operational efficiency of road networks and alleviating urban traffic congestion. Traditional models rely on predefined static graph structures, making it difficult to capture dynamic spatiotemporal correlations, and single-time-scale modeling struggles to comprehensively extract multi-scale features. To address these issues, a dual dynamic adaptive spatiotemporal modeling framework is proposed. In the temporal dimension, this framework employs a dynamic time feature extraction multi-head attention mechanism to adaptively adjust temporal weights to capture key dynamic features. In the spatial dimension, it designs a dynamic graph convolutional network that generates an adjacency matrix in real-time through a self-attention mechanism to

represent dynamic spatial dependencies between nodes, thus achieving spatiotemporal dual dynamic collaborative modeling. Furthermore, this framework introduces a learnable linear fusion layer to adaptively integrate multi-time-scale prediction results and collaboratively optimize local and global feature representations. Experiments on real road datasets demonstrate that this framework significantly outperforms the baseline model, validating its superior spatiotemporal feature capture and prediction performance.

Key words

traffic volume prediction, dynamic time feature extraction with multi head attention mechanism, dynamic graph convolution, linear layer fusion

0 引言

随着城市化进程加速,智能交通系统成为智慧城市建设的核心基础设施。交通量预测是智能交通系统的关键,它通过分析历史交通量数据来预测未来交通量^[1]。精准的交通量预测对缓解城市交通拥堵、减少交通事故、提高出行效率至关重要^[2]。

早期交通量预测主要采用传统的统计学方法,如历史平均法(historical average, HA)^[3]、自回归积分滑动平均(autoregressive integrated moving average, ARIMA)模型^[4]、向量自回归(vector autoregression, VAR)模型^[5]。这些模型通常只能处理线性、稳定的数据,难以建模非线性关系,因此在实际场景中表现不佳。为了突破传统统计学方法的局限性,研究者引入了机器学习方法,如支持向量回归(support vector regression, SVR)^[6]、 K 近邻(k -nearest neighbor, KNN)算法^[7]等。这类方法能建模非线性数据,但严重依赖特征工程,需要人工设计时空特征,因此难以有效提取交通流数据复杂的时空特征。近年来,深度学习方法快速发展,如长短期记忆(long short term memory, LSTM)网络^[8]、循环神经网络(recurrent neural network,

RNN)^[9]以及图神经网络(graph neural network, GNN)^[10]等方法被应用到交通量预测中。其中,LSTM网络、RNN能够通过门控机制有效捕捉交通流数据的短期时序依赖关系,GNN则通过显式建模非欧氏路网拓扑,有效捕捉交通流数据的空间相关性。与统计学方法和机器学习方法相比,深度学习方法能够挖掘出交通流数据的更多特性和复杂结构,具有较强的空间或时间依赖性捕获能力,预测性能显著优于传统的统计学和机器学习方法。然而,这些方法仍然无法同时建模交通流数据的时空特征。因此,研究者们引入了能同时捕捉交通流数据时空相关性的深度学习方法,如时空图卷积网络(spatial-temporal graph convolutional network, STGCN)^[11]、扩散卷积递归神经网络(diffusion convolutional recurrent neural network, DCRNN)^[12],这些方法能同时捕捉交通流数据的时空相关性,进一步提升模型的预测性能。但其仍然依赖预定义的静态邻接矩阵,导致对交通系统中动态时空相关性的建模能力不足。总而言之,现有研究仍面临以下挑战。

首先,交通流数据的时间相关性存在显著的动态变化特性。不同交通模式(如早晚高峰、工作日、节假日)会相互耦合且非线性变化,交通量随时间呈现复杂的周期性变化。然而,现有模型大多数采用

固定时序建模,如传统傅里叶变换仅能捕捉固定周期,但高峰交通量会因节假日、突发事件等发生相位偏移,导致固定时序模型难以有效捕捉交通量动态变化的时间相关性。其次,交通道路网络中不同节点之间的相互影响程度也会随交通状态实时地动态变化。现有模型(如STGCN、DCRNN等)采用静态邻接矩阵表征空间关联,而静态邻接矩阵无法表达状态依赖的空间关联。如早晚高峰时,高速路出口对主干道路的影响权重为0.8,平时这个权重则降至0.3,但是静态图卷积仍然按照固定权重计算,导致交通量预测出现偏差。因此,现有静态模型难以有效捕捉交通量的动态空间相关性。最后,对同一时间点的交通量预测,单步预测容易受到交通量突变干扰且存在不同时间尺度敏感性偏差。然而,现有大部分研究忽略了这一因素对交通量预测模型性能的影响。

为解决上述挑战,笔者提出一种新的交通量预测模型。具体地,本文的主要贡献如下。

(1) 笔者创新性地提出双重动态自适应时空建模框架:首先,设计动态时间特征提取多头注意力机制,通过动态权重修正策略自适应调整关注权重,聚焦关键时变特征,弥补了传统注意力对时序动态性建模不足的缺陷;其次,构建了自适应动态图卷积网络,依据实时交通状态演化生成动态邻接矩阵,突破了静态图结构难以刻画空间关系动态演化的瓶颈。该框架实现了时空维度双重动态特性的协同建模,显著提升了动态时空特征的表征能力。

(2) 笔者创新性地引入可学习的线性融合层,将不同时间步长的特征线性组合,通过权重参数自动学习,动态调整不同时间尺度特征对最终交通量预测结果的贡献度,捕捉局部细节和全局特征,显著增强

模型对复杂时间交通模式的刻画能力。

(3) 笔者在PEMS03、PEMS04、PEMS07、PEMS08共4个数据集上进行了大量性能评估实验。实验结果表明,所提框架显著优于其他基线模型,预测性能最佳。

1 相关工作

交通量预测作为智能交通系统的关键技术支撑,近年来持续吸引国内外学者开展系统性研究^[13]。早期研究多采用传统的统计学方法^[14]。HA、ARIMA模型和VAR模型就是其中较经典的模型。Williams等^[15]首次引入ARIMA模型来预测交通量。Zivot等^[16]提出利用VAR进行模型分析、建模时间序列数据。尽管这类模型实现简单,建模线性、平稳数据时具有优势,但交通流数据大多呈现非线性、动态变化的特征,因此在实际场景中这类模型表现不佳。

为突破传统统计学方法的局限,机器学习方法逐渐被应用到交通量预测中,经典算法包括KNN、SVR、支持向量机(support vector machine, SVM)等。Zhang等^[17]提出一种KNN方法,用于城市高速公路短期交通量预测。Castro-Neto等^[18]提出一种在线SVR,用于预测典型和非典型条件下的短期高速公路交通量。Yang等^[19]提出利用SVM来预测交通量。这些模型通过非线性建模,能够自动提取交通流数据中的高维、非线性特征,在特定场景中表现良好。然而,机器学习方法难以同时建模复杂的时空相关性,导致预测性能不理想^[20]。

近年来,深度学习方法迅速发展,被广泛应用到交通量预测中。Li等^[12]引入DCRNN,使用图上的双向随机游走来捕

获空间依赖性,使用具有调度采样的编码器-解码器架构来捕获时间相关性。Yu等^[11]提出STGCN,其通过建模多尺度交通网络来全面捕捉交通流数据的时空相关性。Guo等^[21]提出一种新的基于注意力的时空图卷积网络(attention based spatial-temporal graph convolutional network, ASTGCN),其利用时空注意力机制来捕捉交通流数据的动态时空相关性,应用时空图卷积来捕捉空间模式。Song等^[22]提出时空同步图卷积网络(spatial-temporal synchronous graph convolutional network, STSGCN),该模型开发了时空同步建模机制来捕捉交通流数据复杂的局部时空相关性。Wu等^[23]提出一种用于时空图建模的图神经网络架构Graph WaveNet,其通过开发自适应依赖矩阵并通过节点嵌套来精准捕捉隐藏的空间依赖性。Liu等^[24]提出一种具有空间注意力机制的图卷积网络来捕捉道路网络的空间关系,采用门控循环单元和Transformer编码结构对交通状态时间序列进行局部和全局重构。Zhu等^[25]提出时空记忆异构图卷积网络,通过构建一个时空保留网络来捕捉交通流数据长期动态时空相关性。He等^[26]提出时空3D多尺度扩展密集网络,其使用3D多尺度扩展卷积网络同时捕获近程和远程的相关性。Du等^[27]提出一种基于时空注意力和图卷积学习框架的多尺度增强的交通量预测模型,该模型引入了时空依赖特征增强模块和具有空间注意力机制的交通网络拓扑特征增强矩阵。Gan等^[28]提出一种广义动态时空图卷积网络,该模型构建了一个基于学习的广义动态图结构,并将其与图扩散相结合,从而全面捕捉交通流数据局部和全局时空依赖关系。He等^[29]提出一种用于交通量预测的时空图模型,该模型开发了一种整合

了空间注意力的改进图卷积神经网络来提取空间特征,引入了一种整合了时间注意力的长短期记忆网络来捕捉时间相关性。Byeon等^[30]提出一种用于交通量预测的全局感知时空网络模型,该模型主要应用时空注意力机制来捕捉时空相关性。尽管这些模型取得了一些成果,但这些深度学习方法时空动态建模能力不足,难以有效捕捉交通流数据的动态时空依赖性^[31]。

因此,笔者提出一种基于注意力机制和线性层融合的动态图卷积交通量预测模型,创新性地构建动态时间特征提取多头注意力机制,捕捉动态变化的时间相关性;同时引入动态图卷积神经网络捕捉交通流数据动态变化的空间相关性,并通过线性层融合不同时间步长尺度的结果,提升模型预测性能。

2 问题定义

本研究的核心任务是交通量时空预测,笔者对交通道路网络时空图定义如式(1)所示。

$$g_t=(v, b, f_t) \quad (1)$$

其中, v 表示所有节点集合, N 表示节点数量, $N=|v|$; b 表示所有边的集合, M 表示边的数量, $M=|b|$; f 表示时间为 t 时,所有节点的特征值。

笔者旨在通过过去 T 时间片的数据来预测未来长度为 h 的时间片数据,过去 T 时间片的数据描述如式(2)所示。

$$G_T=\{g_{T-h}, \dots, g_{T-1}, g_T\} \quad (2)$$

本研究中交通量预测的目标是通过 G_T 来预测后面长度为 h 的时间片数据,如式(3)所示。

$$Y = \{g_{T+1}, g_{T+2}, \dots, g_{T+h}\} \quad (3)$$

3 研究方法

笔者结合混合位置编码、动态时间特征提取多头注意力机制、动态图卷积神经网络、线性层融合方法，提出了一种新的交通量预测模型。该模型的核心创新是构建了一种双重动态自适应时空建模框架，通过动态时间特征提取多头注意力机制和自适应动态图卷积网络实现了时空维度双重动态特征的协同建模，显著提升了模型对动态时空特征的代表能力。模型架构如图1所示。图1中，Input_1是初始采集的真实数据即原数据，Input_2是该模型运行出的预测结果和上一轮输入的原始数据的整合。模型将上一轮所有输入数据和新生成的数据拼接到一起，作为本次解码器的输入数据再次输入模型。 L 是编码器及解码器层数，num_for_predic=4表示预测步长为4。

由图1可知，所提模型主要包含4个模块。第一个模块是混合位置编码，融合时

间和空间维度的位置表征，帮助多头注意力机制基于不同位置特征自适应分配权重。第二个模块是动态时间特征提取模块，利用多头注意力机制来捕捉交通量的动态时间相关性。第三个模块是动态空间特征提取模块，利用动态图卷积神经网络捕捉节点间的空间动态。第四个模块是线性层融合模块，融合不同时间尺度的预测结果，进行最终的交通量预测。

3.1 混合位置编码

混合位置编码结合传统绝对位置编码与可学习的相对位置信息，能够更全面地表征序列时空特征。该方法的核心在于能够同时利用绝对位置编码提供的基础坐标框架，以及自学习编码捕获的灵活上下文依赖关系。在多头注意力机制中，这种融合的代表使模型不仅能够感知元素的绝对时空顺序，还能根据具体任务动态调整位置间的交互权重，从而在视频分析、时空序列预测等任务中基于时空双重线索自适应地分配注意力，有效提升对复杂位置关系的建模能力。

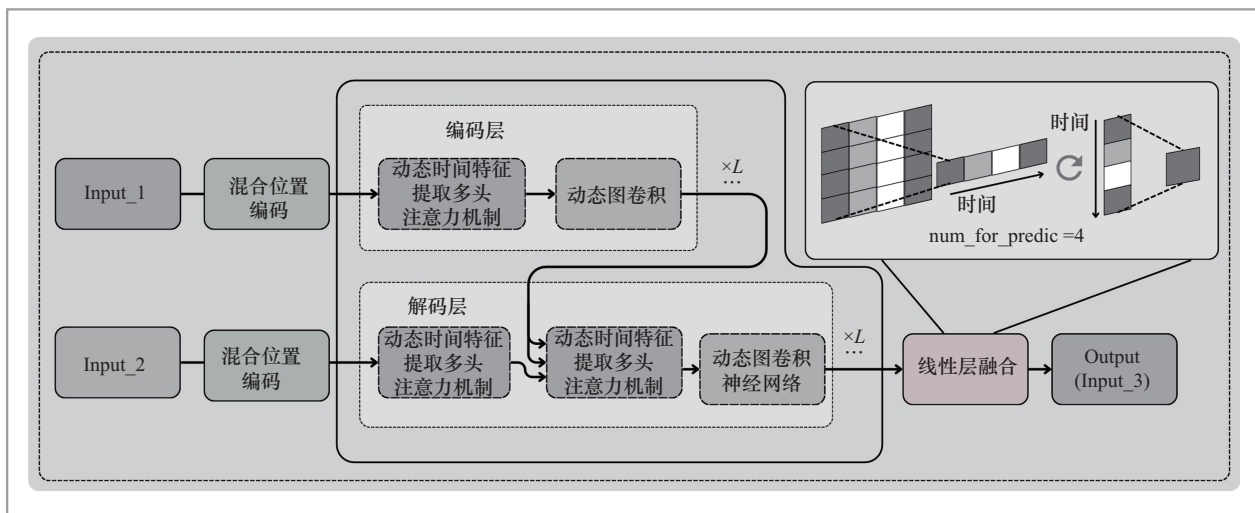


图1 模型架构

具体而言,对于输入序列中的第*i*个位置,其绝对位置编码通常采用正弦和余弦函数生成。

$$PE_{(i,2k)} = \sin\left(\frac{i}{10000^{2k/d}}\right), PE_{(i,2k+1)} = \cos\left(\frac{i}{10000^{2k/d}}\right) \quad (4)$$

其中,*d*为嵌入维度,*k*为维度索引。与此同时,自学习位置编码是一个随机初始化并通过训练优化的参数矩阵 $P \in R^{L \times d}$,其中,*L*为序列最大长度。最终的混合位置表征 H_i 通常通过简单的加性融合得到。

$$H_i = PE_i + P_i \quad (5)$$

这种设计使模型能够融合固定位置与自适应上下文信息,相比单一编码方式,能显著增强模型在长序列或多维度数据中的表现。

3.2 动态时间特征提取多头注意力机制

动态时间特征提取多头注意力机制的核心在于自适应地捕捉输入交通流数据序列中不同时间点之间的动态依赖关系,并动态调整对关键时间信息的关注程度。如图2所示,该机制首先将输入序列映射到多个并行的子空间(称为“头”)。在每个子空间中,其独立计算注意力权重,衡量序列中不同时间点之间的相关性如式(5)所示。这些权重本质上是自适应的,能够动态突出重要时刻的信息并抑制噪声。最后,所有子空间的计算结果被拼接并整合,融合了从不同“视角”学习到的丰富上下文信息,从而更全面地捕捉时间动态特征。

首先,将输入序列的查询(*Q*)、键(*K*)、值(*V*)通过多组线性投影矩阵,拆分到多个子空间(头)中。

$$Q_i = XW_i^Q, K_i = XW_i^K, V_i = XW_i^V (i=1, 2, \dots, h) \quad (6)$$




图2 动态时间特征提取多头注意力机制的原理

其中, W_i^Q, W_i^K, W_i^V 是第*i*头的投影矩阵,*h*是多头注意力机制头的数量,*X*是节点特征矩阵。

其次,在每个子空间中独立计算注意力权重。

$$\text{Attention}_i(Q_i, K_i, V_i) = \text{Softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (7)$$

其中,*d_k*是键向量*K*的维度。此操作通过Softmax函数对相似度进行归一化,计算每个键向量的权重,然后将权重乘以值向量,最后执行加权求和,得到注意力的输出。

3.3 动态图卷积神经网络

动态图卷积神经网络是一种能自适应调整图结构的图神经网络。其核心思想是通过数据驱动实时生成自适应邻接矩阵,捕捉交通流数据中复杂的动态空间依赖关系。笔者在经典动态图卷积思想的基础上,创新性地提出双重动态自适应时空建模框架,旨在实现时空维度动态特征的协同深度建模。因此,在空间维度,笔者构建自适应动态图卷积网络。其核心在于摒弃了预定义或静态学习的邻接矩阵,设计了一个深度动态图生成模块。该模块直接依据模型学习到的蕴含丰富时空上下文信息的

隐层状态（而不仅是原始输入或简单变换），实时推断节点间的动态关联强度，生成更精准地反映当前交通态势演化的动态邻接矩阵。这显著提升了模型捕捉复杂、时变空间依赖关系（如因拥堵传播、事件影响而实时改变的空间交互）的能力。动态图卷积神经网络的原理如图3所示，其关键步骤如下。

(1) 节点特征变换

节点特征矩阵（ N 为节点数， d 为特征维度）通过线性变换生成查询向量和键向量。

$$Q = XW_Q, K = XW_K \quad (8)$$

其中， X 为节点特征矩阵， $X \in R^{N \times d}$ ； W_Q 、 W_K 为可学习参数， $W_Q, W_K \in R^{d \times s}$ 。

(2) 关联度计算

本文通过点积计算不同节点间的关联程度，并引入缩放因子。

$$\text{Attention} = \frac{QK^T}{\sqrt{s}} \quad (9)$$

其中， s 为缩放因子。

(3) 邻接矩阵生成与归一化

对计算所得关联度矩阵进行归一化处理，得到动态邻接矩阵。

$$A = \text{Softmax}(\text{AttentionScores}) \quad (10)$$

最终得到动态邻接矩阵 A ，其反映当前输入下节点间的实时关联程度，实现了邻接矩阵的自适应学习与动态更新。

3.4 线性层融合

线性层融合原理如图4所示。线性层融合的输入源于预测模型在目标时间点前 m 个不同预测步上的隐层特征表示，这些特征被表示为 (H_1, H_2, \dots, H_m) 。其中， $H_i \in R^{1 \times d}$ ，代表第 i 个预测步对应的特征向

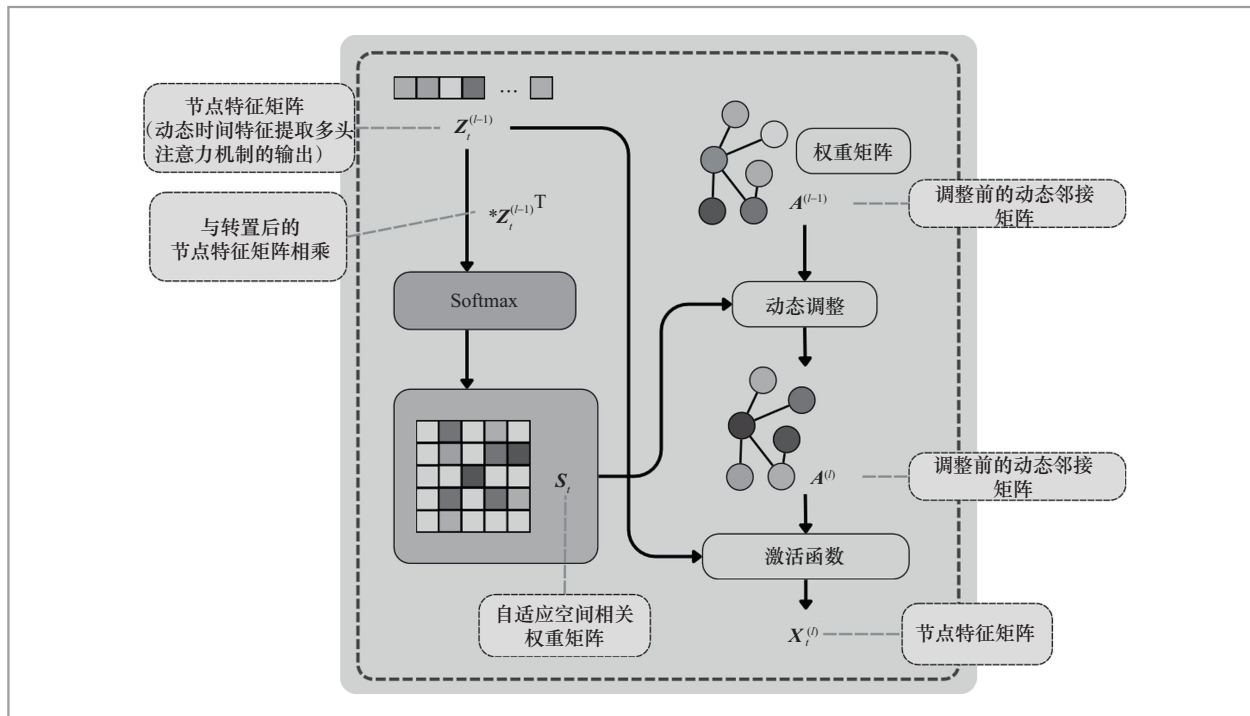


图3 动态图卷积神经网络的原理

量, d 为特征维度, h 为融合的特征数量。以 $m=12$ 为例。 t 时刻前 12 个时刻都产生了隐层特征表示, 那么 t 时刻就包含了 12 个隐层特征表示, 即在 t 时刻隐层特征序列为 $(H_1, H_2, \dots, H_{12})$ 。对 t 时刻的隐层特征序列进行算术平均聚合法, 得到最终的预测结果。

线性层融合的核心操作首先是将这些处于不同语义空间的特征 (H_1, H_2, \dots, H_m) 通过独立的线性投影对齐到统一的语义空间。

$$\hat{H}_i = W_i H_i + b_p, i \in \{1, 2, \dots, m\} \quad (11)$$

其中, $W_i \in R^{d \times d}$ 、 $b_i \in R^d$ 分别是第 i 个特征的投影矩阵和偏置向量, 是可学习的参数。 $\hat{H}_i \in R^d$ 是对齐后的特征。然后, 将对齐后的特征 $(\hat{H}_1, \hat{H}_2, \dots, \hat{H}_m)$ 沿特征维度进行拼接。

$$\hat{H} = \text{Concat}(\hat{H}_1, \hat{H}_2, \dots, \hat{H}_m) \in R^{m \times d} \quad (12)$$

最后, 通过一个全连接层 (可视为加权融合) 将拼接后的高维特征映射到最终的预测输出空间。

$$Y = W_f \hat{H} + b_f \quad (13)$$

其中, $W_f \in R^{d_{out} \times (m \times d)}$ 、 $b_f \in R^{d_{out}}$ 是最终融合层的权重矩阵和偏置向量, 也是可学习的参数。 d_{out} 是预测目标的维度, 如一维流量值。

4 实验结果和分析

4.1 数据集

本文采用美国加利福尼亚州高速公路测评系统 (performance measurement system, PeMS), 该系统每隔 30 s 实时收集一次数据, 原始的交通流数据被聚合




图4 线性层融合原理

为 5 min 的粒度^[32]。笔者分别从 4 个地区构建 PeMS03、PeMS04、PeMS07、PeMS08 数据集作为实验数据集。

4.2 性能评估指标

笔者采用 3 个误差衡量指标评估模型预测性能, 定义如下。

(1) 平均绝对误差 (mean absolute error, MAE)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (14)$$

(2) 均方根误差 (root mean square error, RMSE)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2} \quad (15)$$

(3) 平均绝对百分比误差 (mean absolute percentage error, MAPE)

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{f_i - y_i}{y_i} \right| \quad (16)$$

其中, f_i 表示模型预测的交通量, y_i 表示实际的交通量, n 为测试样本的数量, y 、 f

分别表示 y_i 和 f_i 的集合。

4.3 模型参数设置

为了研究主要超参数如模型维度 dim_n 、编码器及解码器层数 L 、多头注意力头数 h_num ，对模型预测性能的影响。笔者通过实验来确定最佳模型维度 dim_n 、编码器及解码器层数 L 、多头注意力头数 h_num 。模型预测误差随超参数变化的实验结果如图5所示。

由图5可知，模型维度 $\text{dim}_n=64$ 时，模型整体预测误差最小，确定最佳模型维度为64；编码器及解码器层数 $L=4$ 时，模型的预测误差整体最小，因此将最佳编码器及解码器层数确定为4；当多头注意力头数 $h_num=8$ 时，模型整体预测误差最

小，增大或者减少多头注意力头数都会导致模型预测误差增大，适当的多头注意力头数能提升模型的预测性能，因此选定最佳多头注意力头数为8。

4.4 基线方法

为评估模型预测性能，笔者选择了10个基线方法来进行对比实验。

- HA^[3]：根据历史交通量的平均值来预测未来交通量。
- SVR^[6]：一种基于支持向量机的回归分析模型。
- LSTM网络^[8]：一种特殊的递归神经网络变体。
- STGCN^[12]：时空图卷积神经网络模型。

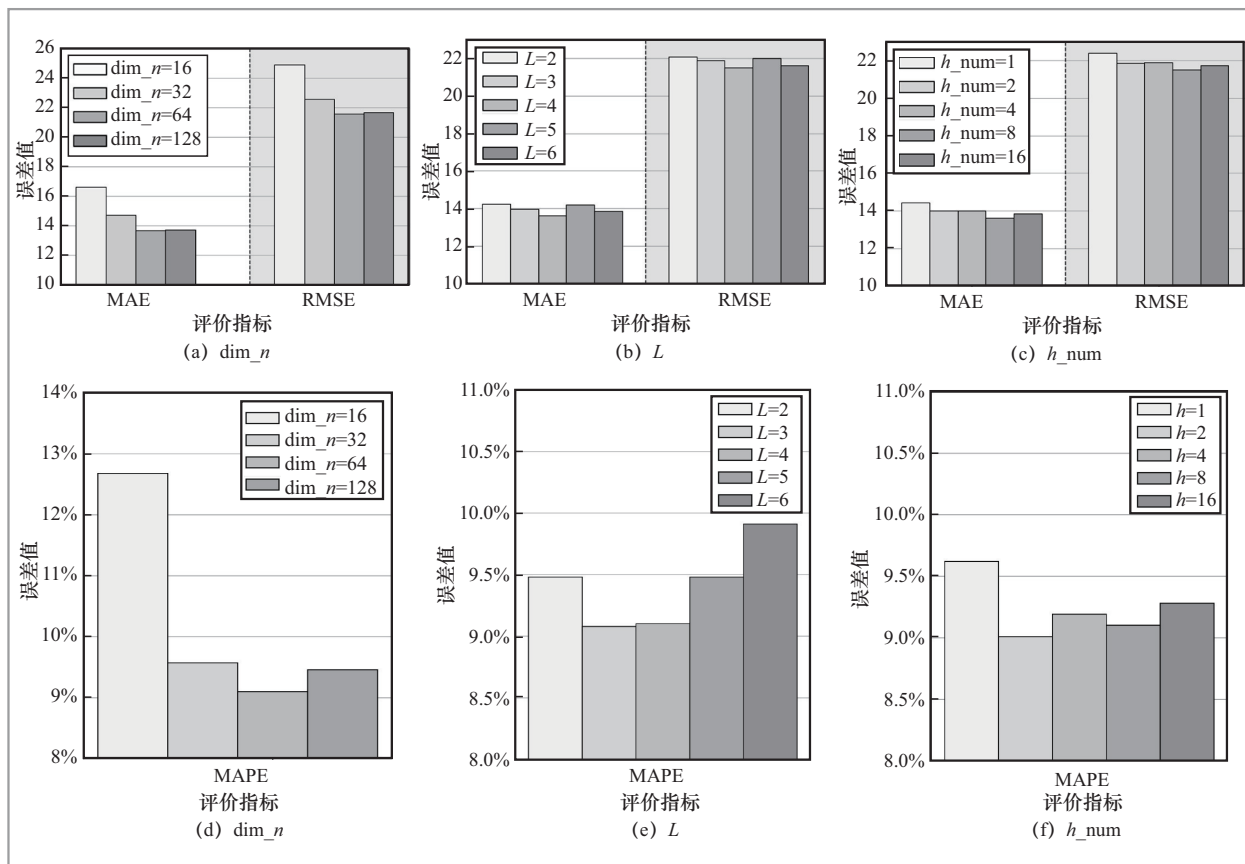


图5 模型最佳超参数分析

- DCRNN^[11]: 引入了扩散卷积递归神经网络, 是一种经典的用于交通量预测的深度学习框架。

- Graph-WavaNet^[25]: 由时空层和输出层组成的图神经网络架构。

- STSGCN^[22]: 时空同步图卷积网络模型。

- ASTGCN^[21]: 基于注意力机制的时空图卷积神经网络模型。

- H²STGCN (homophily-heterophily spatial-temporal graph convolution network)^[33]: 利用同质性和异质性组件来捕捉交通流数据中复杂的时空关系。

- PDFormer^[34]: 结合了注意力机制和Transformer架构, 弥补了传统卷积或循环结构在长期依赖捕捉上的缺陷。

4.5 基线实验结果和分析

笔者在 PeMS03、PeMS04、PeMS07

和PeMS08数据集上, 对所提模型及10个基线模型进行性能评估对比实验。10个基线模型(包括HA、SVR、LSTM网络、STGCN、DCRNN、Graph-WavaNet、STSGCN、ASTGCN、H²STGCN和PDFormer)以及所提出的模型在4个数据集上的平均预测误差见表1。

由表1可知, 与10个基线方法相比, 所提模型在4个数据集上的平均MAE、RMSE、MAPE最小, 预测性能最佳。传统时间序列分析模型(SVR、HA、LSTM)在4个数据集上的平均MAE、RMSE、MAPE偏大, 表现不佳。这是因为这些方法建模非线性交通流数据的能力有限, 且仅考虑时间相关性, 忽略了节点之间的空间相关性。与传统时间序列分析模型相比, 基于GCN的深度学习模型(如STGCN、DCRNN、Graph-WavaNet以及STSGCN)在4个数据集上的平均预测误差较小。这是因为深度学习模型同时考

表1 各模型在4个数据集上的平均预测误差

数据集	评估指标	各模型在4个数据集上的平均预测误差										
		SVR	HA	LSTM	STGCN	DCRNN	Graph-WaveNet	STSGCN	ASTGCN	H ² STGCN	PDFormer	所提模型
PeMS03	MAE	29.00	22.06	22.26	20.69	18.26	19.90	18.60	17.53	14.77	21.57	13.32
	RMSE	44.67	31.25	33.32	35.42	29.69	32.43	31.11	29.51	24.00	34.07	22.42
	MAPE	20.06%	18.38%	28.49%	20.94%	18.03%	19.07%	22.58%	17.41%	21.38%	27.69%	13.39%
PeMS04	MAE	36.25	27.89	27.06	22.53	23.11	25.28	23.60	20.89	18.81	18.33	17.70
	RMSE	54.22	39.32	40.81	35.29	35.80	38.90	36.11	33.07	30.74	29.95	28.59
	MAPE	15.88%	18.40%	21.77%	16.83%	15.91%	18.75%	17.16%	14.28%	12.84%	12.25%	11.76%
PeMS07	MAE	42.77	32.30	30.28	27.02	23.41	26.63	25.19	26.34	26.70	19.79	18.77
	RMSE	62.91	45.85	44.69	42.81	35.81	39.43	39.15	39.17	42.68	32.85	29.93
	MAPE	15.15%	13.92%	13.96%	12.30%	10.02%	12.93%	13.01%	11.85%	11.73%	8.36%	8.51%
PeMS08	MAE	30.05	22.88	22.55	18.81	18.40	18.94	19.10	18.37	15.00	14.04	13.63
	RMSE	44.95	32.09	33.94	28.13	28.23	30.71	28.62	28.16	24.30	23.51	21.53
	MAPE	16.00%	13.23%	17.33%	12.90%	11.49%	12.27%	13.98%	11.70%	9.74%	9.30%	9.10%

虑了时空相关性，能处理高维、非线性交通流数据，进一步提升了模型预测性能。在此，还需要指出的是，STSGCN在PeMS03数据集上的MAPE较高而MAE较低，这主要是因为该数据集中存在少量低流量时段样本。这些样本的真实值极小，使预测误差在计算MAPE时被显著放大，从而贡献了近一半的MAPE总误差。相比之下，MAE指标受此类极端点的影响较小。基于注意力机制的GCN模型（如ASTGCN），预测性能显著优于基于GCN的深度学习模型。因为传统基于GCN的模型使用静态邻接矩阵建模时空依赖关系，时空卷积层层数增多时，会出现过平滑现象，其模型会对距离相同的节点赋予相同权值，导致模型空域相关性建模能力有限。H²STGCN和PDFormer模型的预测性能整体上又优于上述深度学习模型，因为它们能同时捕捉交通流数据的时空相关性。而且H²STGCN独特的分层结构能有效解决深层GCN的过平滑问题，PDFormer结合了Transformer架构和注意力机制，能弥补传统卷积或循环结构在长期依赖捕

捉上的缺陷，因此二者预测性能均较好。

与所提模型相比，ASTGCN、H²STGCN以及PDFormer的预测性能较差。ASTGCN虽引入时空注意力机制，但仍采用静态邻接矩阵建模空间相关性，因此难以捕捉动态空间依赖。H²STGCN依赖静态分层图结构，无法适应动态突变。PDFormer虽采用注意力机制和Transformer架构，但因固定位置编码与静态权重融合机制，其在动态时空特征提取方面存在局限性。相比之下，所提模型利用动态时间特征提取多头注意力机制提取动态时间相关性，动态图卷积网络捕捉动态空间相关性。这种高效的动态时空特征提取机制显著提升了模型预测性能。

为对比模型在不同时间步长上的预测性能，本文在4个数据集上以5 min为时间步长进行评估，实验结果如图6~图9所示。

从图6~图9可以清晰地看出，所提模型在4个数据集上的整体预测误差均最小，预测性能最佳。随着时间步长增加，各模型的预测误差整体上都呈增长趋势。HA、




图6 各个模型在PeMS03数据集上的预测误差




图7 各个模型在PeMS04数据集上的预测误差

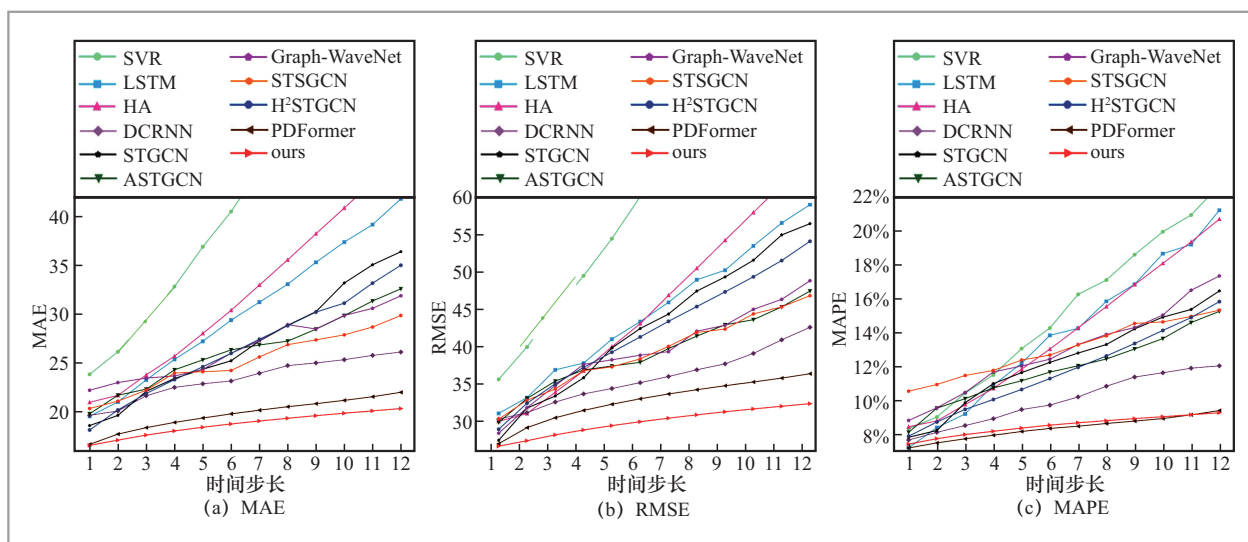


图8 各个模型在PeMS07数据集上的预测误差

SVR、LSTM 随时间推移，预测误差增大较明显。这是因为这类模型仅能提取时间特征，缺乏捕捉空间特征的能力，因此预测精确度尤其是长期预测的精确度远低于其他时空建模方法。DCRNN 采用扩散卷积和门控循环单元（gated recurrent unit, GRU）捕捉交通数据的时空相关性，其预测性能优于 HA、SVR 和 LSTM 模型。

STGCN 利用 GCN 提取空间特征、利用一维卷积神经网络提取时间特征，但其受卷积核大小的限制，无法有效处理长期信息。因此 STGCN 的长期预测性能不及基于注意力机制的时空模型，如 ASTGCN。ASTGCN 不仅能有效捕捉交通数据的时空相关性，而且注意力机制的引入能帮助其提取全局信息，因此预测性能有所提升。

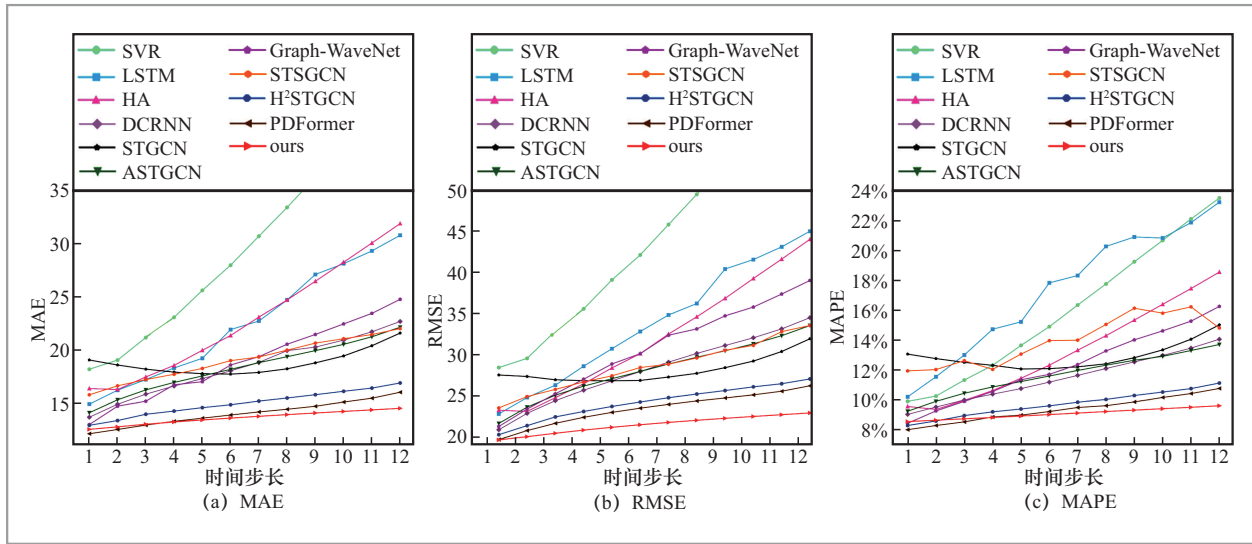


图9 各个模型在PeMS08数据集上的预测误差

然而ASTGCN仍依赖预定义的静态邻接矩阵来建模空间依赖关系，因此难以有效捕捉动态变化的空间相关性。H²STGCN和PDFormer的预测性能随时间推移下降的速度较慢，短期和长期预测均表现良好。

4.6 消融实验结果和分析

为评估模型中各模块的有效性，笔者在4个数据集上进行了消融实验。4种消融实验变体模型设置如下。

- W/O LinLayer：去除线性层融合。
- W/O TTPAM：用普通多头注意力替代动态时间特征提取多头注意力机制。
- W/O SpaAM：去除动态图卷积网络中的自注意机制。
- W/O PosEmb：去除混合位置编码。

消融实验的平均预测误差如图10~图13所示。

模型基于12个时间步长，在4个数据集上进行消融实验的预测误差如图14~图17所示。

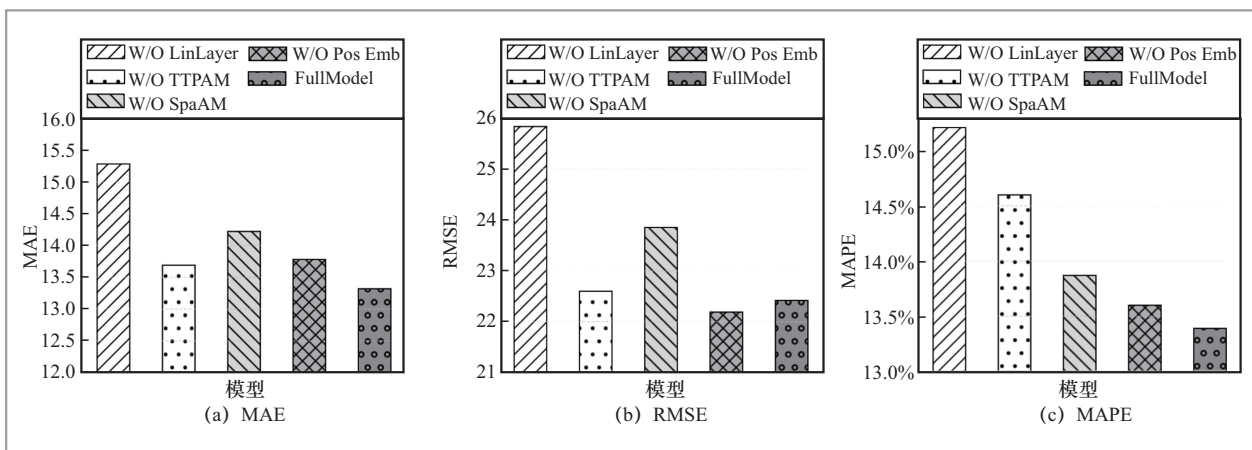


图10 在PeMS03数据集上进行消融实验的平均预测误差

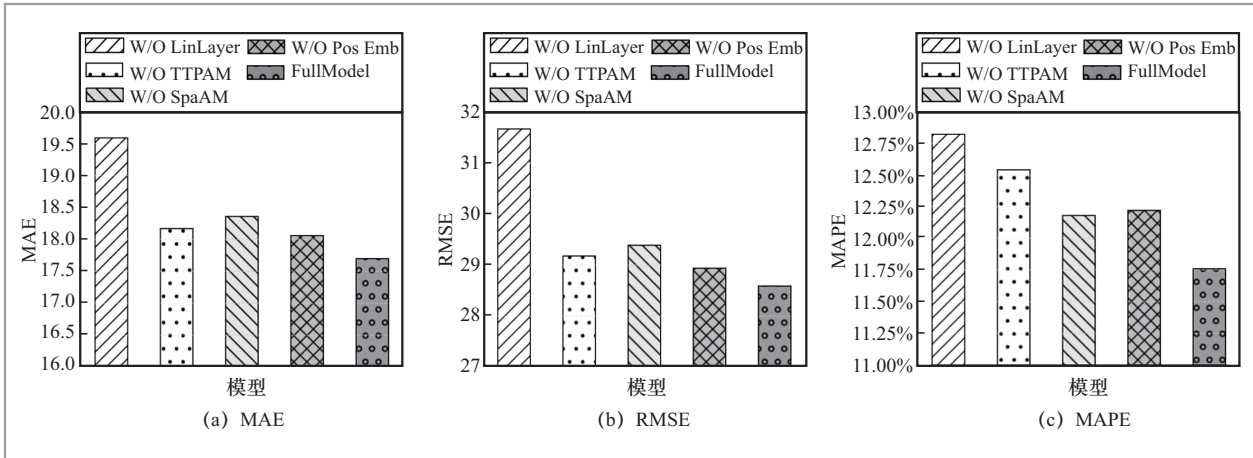


图11 在PeMS04数据集上进行消融实验的平均预测误差

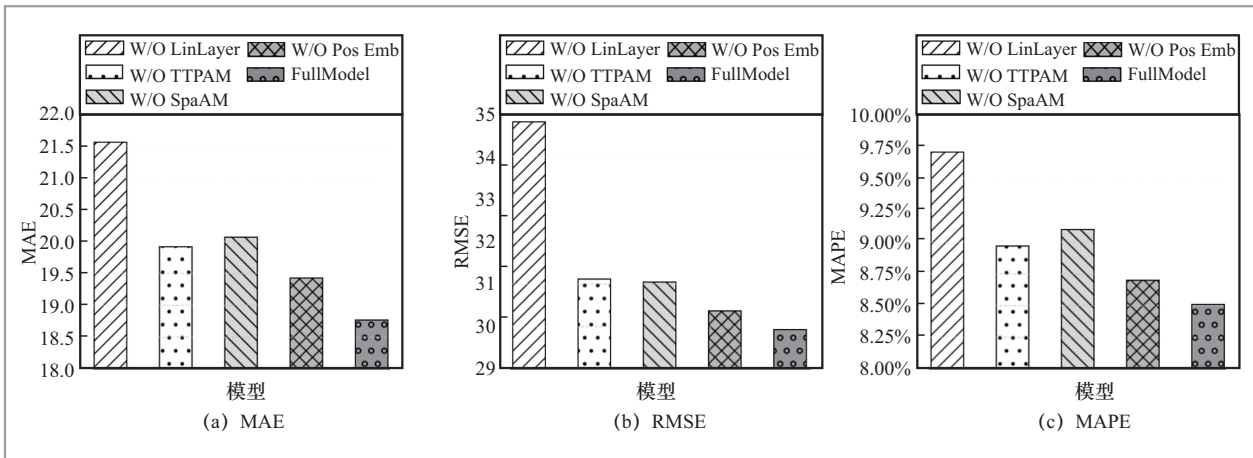


图12 在PeMS07数据集上进行消融实验的平均预测误差

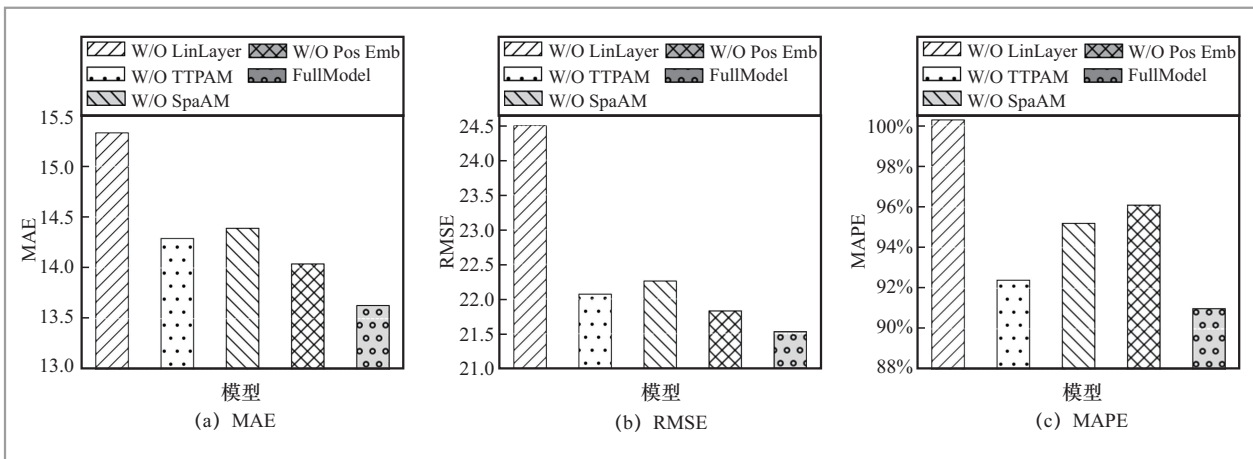


图13 在PEMS08数据集上进行消融实验的平均预测误差

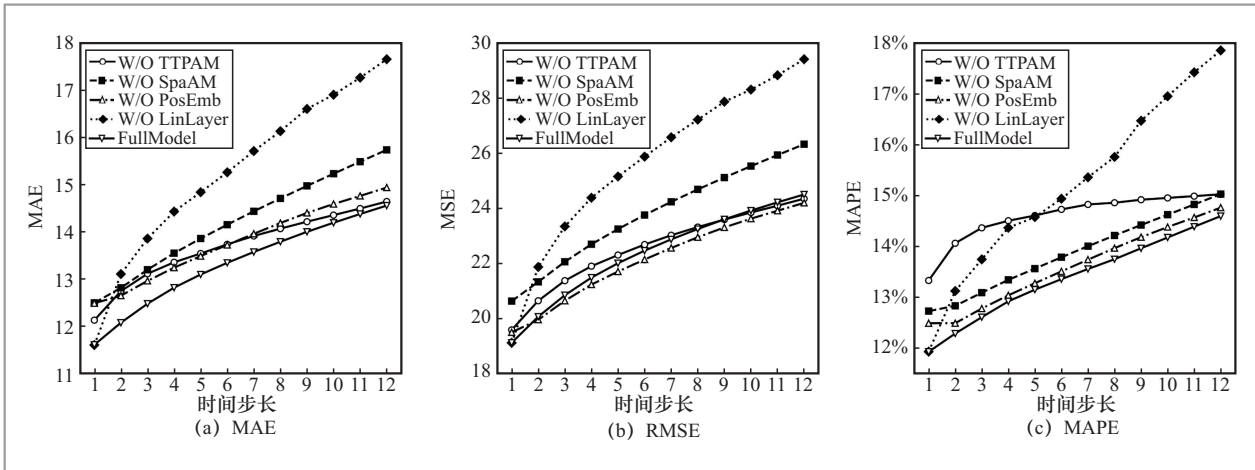


图14 不同时间步长下在PeMS03数据集上进行消融实验的预测误差

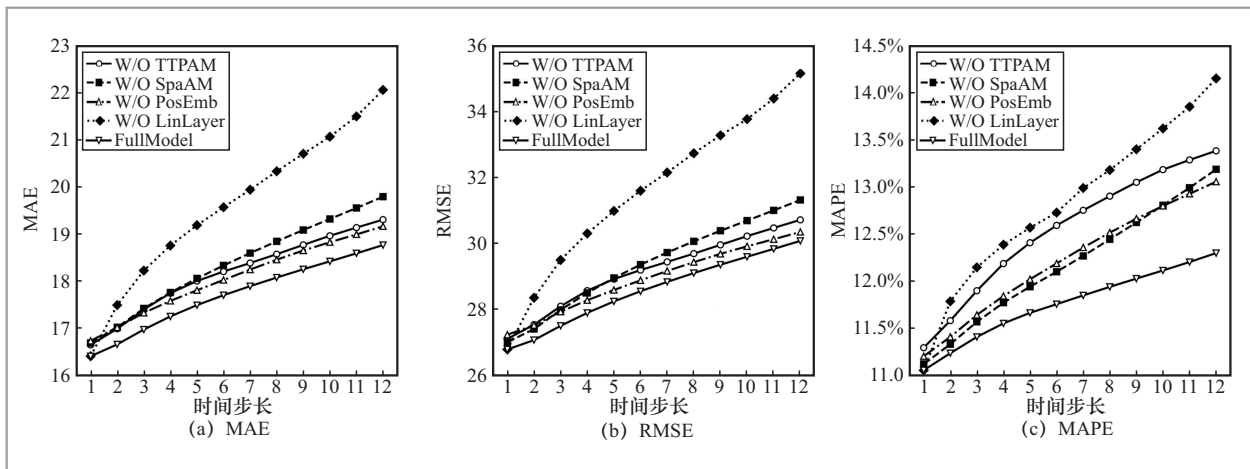


图15 不同时间步长下在PeMS04数据集上进行消融实验的预测误差




图16 不同时间步长下在PeMS07数据集上进行消融实验的预测误差

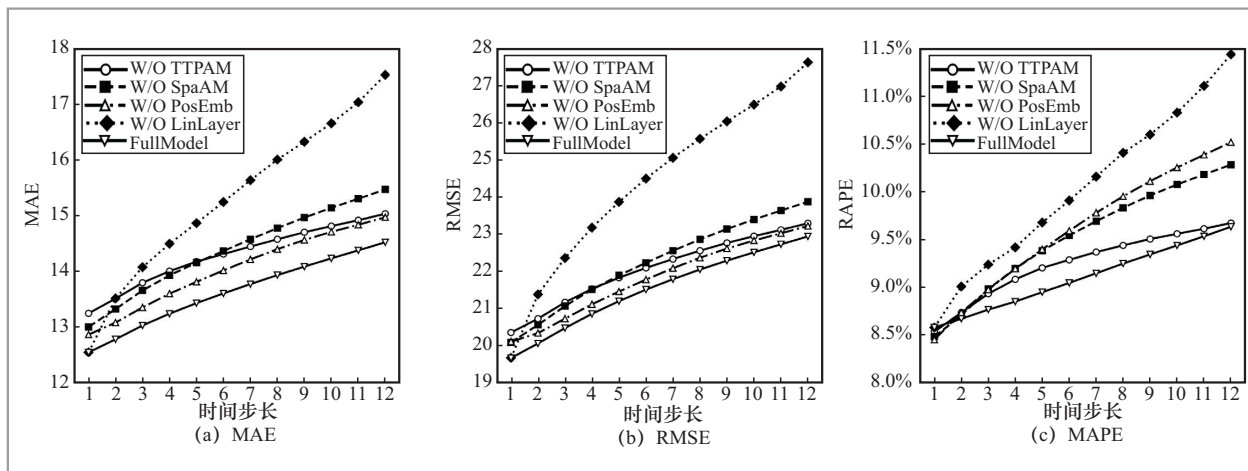


图17 不同时间步长下在PeMS08数据集上进行消融实验的预测误差

由图14~图17可知,在不同时间步长上各个变体模型在4个数据集上进行消融实验的平均预测误差发生了显著变化。其中W/O TTPAM的平均预测误差增大,说明动态时间特征提取多头注意力机制比普通多头注意力机制能更有效地提取动态时间特征,提升模型性能。W/O SpaAM的平均预测误差增大明显,模型性能下降较快,说明自注意力机制对动态图卷积提取空间动态具有积极作用。W/O PosEmb模型相比所提模型,预测误差显著增大,模型性能下降幅度较大,说明混合位置编码对提升模型性能具有重要作用。此外,与所提模型相比,W/O LinLayer的平均预测误差随时间步长的增大而显著增大,且增长幅度最大,说明线性层融合对提升模型性能贡献最大。综上所述,所提模型中的各个模块对提升模型的预测性能都有积极的作用,都具备有效性。

5 结束语

为了应对交通量预测中动态时空特征

建模与多尺度时间特征融合的挑战,笔者提出了一种基于注意力机制与线性层融合的动态图卷积交通量预测模型。该模型创新性地构建了一种双重动态自适应时空建模框架,该框架开发了动态时间特征提取多头注意力机制,利用并行化注意力头与动态权重修正策略自适应捕捉时序动态相关性;设计了自适应动态图卷积网络,通过自注意力机制生成动态邻接矩阵精准刻画空间关联的实时演化。这种双重动态自适应时空建模框架突破了传统静态建模的局限性。此外,本文进一步引入了可学习的线性层融合模块,自动学习多尺度时间特征的组合权重以增强复杂模式刻画能力。在PeMS03、PeMS04、PeMS07和PeMS08数据集上的性能评估实验结果充分证明,所提模型显著优于其他较先进的基线模型,整体上预测性能最佳。

参考文献:

- [1] Cao S Q, Wu L B, Zhang R, et al. A spatiotemporal multiscale graph convolutional network for traffic flow predic-

- tion[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(8): 8705–8718.
- [2] Zhang X D, Chen X W, Tang H N, et al. AdpSTGCN: Adaptive spatial-temporal graph convolutional network for traffic forecasting[J]. *Knowledge-Based Systems*, 2024, 301: 112295.
- [3] Stephanedes Y J, Michalopoulos P G, Plum R A. Improved estimation of traffic flow for real-time control (discussion and closure)[J]. *Transportation Research Record*, 1981, 95: 28–39.
- [4] Pan B, Demiryurek U, Shahabi C. Utilizing real-world transportation data for accurate traffic prediction[C]//*Proceedings of the 2012 IEEE 12th International Conference on Data Mining*. Piscataway: IEEE Press, 2013: 595–604.
- [5] Chandra S R, Al-Deek H. Predictions of freeway traffic speeds and volumes using vector autoregressive models[J]. *Journal of Intelligent Transportation Systems*, 2009, 13(2): 53–72.
- [6] Wu C H, Ho J M, Lee D T. Travel-time prediction with support vector regression[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2004, 5(4): 276–281.
- [7] Liu Z, Qin X, Huang W, et al. Effect of time intervals on K-nearest neighbors model for short-term traffic flow prediction[J]. *Promet – Traffic&Transportation*, 2019, 31(2): 129–139.
- [8] Bi J, Zhang X, Yuan H T, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM[J]. *IEEE Transactions on Automation Science and Engineering*, 2022, 19(3): 1869–1879.
- [9] Connor J T, Martin R D, Atlas L E. Recurrent neural networks and robust time series prediction[J]. *IEEE Transactions on Neural Networks*, 1994, 5(2): 240–254.
- [10] Kong L B, Yang H C, Li W G, et al. Traffexplainer: a framework toward GNN-based interpretable traffic prediction[J]. *IEEE Transactions on Artificial Intelligence*, 2025, 6(3): 559–573.
- [11] Han H Y, Zhang M D, Hou M, et al. STGCN: a spatial-temporal aware graph learning method for POI recommendation[C]//*Proceedings of the 2020 IEEE International Conference on Data Mining (ICDM)*. Piscataway: IEEE Press, 2021: 1052–1057.
- [12] Li Y G, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting [EB]. *arXiv preprint*, 2017, arXiv: 1707.01926.
- [13] Zuo C Q, Zhang X, Zhao G, et al. PCR: a parallel convolution residual network for traffic flow prediction[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2025, 9(4): 3072–3083.
- [14] Chen L Q, Zhao Q L, Li G H, et al. A sparse cross attention-based graph convolution network with auxiliary information awareness for traffic flow prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(3): 3210–3222.
- [15] Williams B M, Hoel L A. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: theoretical basis and empirical results[J]. *Journal of Transportation Engineering*, 2003, 129(6): 664–672.
- [16] Zivot E, Wang J H. Vector autoregressive models for multivariate time series [M]//*Modeling Financial Time Series*

- with S-PLUS. New York: Springer, 2006: 385–429.
- [17] Zhang L, Liu Q C, Yang W C, et al. An improved K-nearest neighbor model for short-term traffic flow prediction[J]. *Procedia – Social and Behavioral Sciences*, 2013, 96: 653–662.
- [18] Castro-Neto M, Jeong Y S, Jeong M K, et al. Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions[J]. *Expert Systems with Applications*, 2009, 36(3): 6164–6173.
- [19] Yang Y N, Lu H P. Short-term traffic flow combined forecasting model based on SVM[C]//*Proceedings of the 2010 International Conference on Computational and Information Sciences*. Piscataway: IEEE Press, 2011: 262–265.
- [20] Hu J, Zheng T C, Peng L L, et al. LightST: a simplifying spatio-temporal graph neural network for traffic flow forecasting[J]. *IEEE Transactions on Big Data*, 2025, 11(5): 2517–2528.
- [21] 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 Thirty-Third AAAI Conference on Artificial Intelligence and Thirty-First Innovative Applications of Artificial Intelligence Conference and Ninth AAAI Symposium on Educational Advances in Artificial Intelligence*. New York: ACM, 2019: 922–929.
- [22] 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*. Canada: AAAI, 2020, 34(1): 914–921.
- [23] Wu Z H, Pan S R, Long G D, et al. Graph WaveNet for deep spatial-temporal graph modeling[EB]. arXiv preprint, 2019, arXiv: 1906.00121.
- [24] Liu Z, Ding F, Dai Y Q, et al. Spatial-temporal graph convolution network model with traffic fundamental diagram information informed for network traffic flow prediction[J]. *Expert Systems with Applications*, 2024, 249: 123543.
- [25] Zhu W, Long B C, Xiao J L. Spatial-temporal retentive heterogeneous graph convolutional network for traffic flow prediction[C]//*Proceedings of the 2024 International Joint Conference on Neural Networks (IJCNN)*. Piscataway: IEEE Press, 2024: 1–8.
- [26] He R, Zhang C J, Xiao Y P, et al. Deep spatio-temporal 3D dilated dense neural network for traffic flow prediction[J]. *Expert Systems with Applications*, 2024, 237: 121394.
- [27] Du S D, Yang T, Teng F, et al. Multi-scale feature enhanced spatio-temporal learning for traffic flow forecasting[J]. *Knowledge-Based Systems*, 2024, 294: 111787.
- [28] Gan R, An B C, Li L H, et al. A freeway traffic flow prediction model based on a generalized dynamic spatio-temporal graph convolutional network[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(10): 13682–13693.
- [29] He G J, Huang W, Zhu Y T, et al. Adaptive spatial-temporal dependence graph convolution neural network for traffic flow prediction[J]. *Expert Systems with Applications*, 2025, 281: 127564.
- [30] Byeon H, Khalaf M I, Quraishi A, et al.

Spatiotemporal network for accurate traffic flow prediction in intelligent transportation systems using generative AI[J]. IEEE Transactions on Intelligent Transportation Systems, 2025.

[31] Fofanah A J, Chen D, Wen L, et al. CHAMFormer: dual heterogeneous three-stages coupling and multivariate feature-aware learning network for traffic flow forecasting[J]. Expert Systems with Applications, 2025, 266: 126085.

[32] Chen C, Petty K, Skabardonis A, et al. Freeway performance measurement

system: mining loop detector data[J]. Transportation Research Record: Journal of the Transportation Research Board, 2001, 1748(1): 96-102.

[33] Chen Y X, Huo J Y, Lin F R, et al. Beyond homophily in spatial-temporal traffic flow forecasting[J]. Neural Networks, 2025, 183: 106950.

[34] Shin Y, Yoon Y. PGCN: progressive graph convolutional networks for spatial-temporal traffic forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(7): 7633-7644.

作者简介



尉辉 (1981-), 男, 新疆交通职业技术学院人工智能工程学院副教授, 主要研究方向为网络技术、智能交通。



肖洪波 (1991-), 男, 中南大学计算机学院博士生, 主要研究方向为时空数据挖掘、智能交通。



邹北骥 (1961-), 男, 博士, 中南大学计算机学院教授, 主要研究方向为医学图像处理、医学大数据分析。



奎晓燕 (1980-), 女, 博士, 中南大学计算机学院教授, 主要研究方向为医疗大数据、医疗人工智能。



肖捡花 (1992-), 女, 博士, 怀化学院计算机与人工智能学院 (软件学院) 副教授, 主要研究方向为智能交通、深度学习。



和佳聚 (2003-), 男, 怀化学院计算机与人工智能学院 (软件学院) 本科生, 主要研究方向为智能交通、深度学习。



合尼古力 (1976-), 女, 新疆交通职业技术学院人工智能工程学院教授, 主要研究方向为智能交通技术及应用。

收稿日期: 2025-11-06

通信作者: 肖洪波, hbxiao@csu.edu.cn; 肖捡花, xiaojianhua@hnu.edu.cn

基金项目: 国家自然科学基金项目 (No.62202198, No.U22A2034, No.62177047); 湘江实验室重点项目 (No.23XJ02005); 湖南省自然科学基金项目 (No.2024JJ7372); 湖南省教育厅科学研究重点项目 (No.24A0550, No.24A0018); 湖南省教育厅教学改革项目 (No.202401001340, No.202502001316); 湖南省科技厅重点研发计划 (No.2024JK2135); 湖南省普通高等学校科技创新团队支持项目“武陵山片区智慧农业信息处理与控制技术” (No.ZNKZD2024-3); 新疆维吾尔自治区自然科学基金项目 (No.2024D01A52); 中南大学前沿交叉项目 (No.2023QYJC020)

Foundation Items: The National Natural Science Foundation of China (No.62202198, No.U22A2034, No.62177047), Key Project of Xiangjiang Laboratory (No.23XJ02005), The Natural Science Foundation of Hunan Province (No.2024JJ7372), Key Scientific Research Projects of Hunan Provincial Department of Education (No.24A0550, No.24A0018), The Teaching Reform Project of Hunan Provincial Department of Education (No.202401001340, No.202502001316), The Key Research and Development Plan of Hunan Provincial Department of Science and Technology (No.2024JK2135), The Science and Technology Innovation Team Support Project for Ordinary Higher Education Institutions in Hunan Province “Wuling Mountain Area Smart Agriculture Intommation Processing and Control Technology” (No.ZNKZD2024-3), The Natural Science Foundation of Xinjiang Uygur Autonomous Region (No.2024D01A52), Frontier Cross Project of Central South University (No.2023QYJC020)