

基于多尺度动态时空卷积网络的交通流速度预测

赵星, 陈娴

(河海大学土木与交通学院, 江苏 南京 210024)

摘要: 准确可靠的交通流速度对提升交通管理效率、缓解交通拥堵具有重要意义。为实现交通流速度的准确预测, 深入挖掘复杂的动态时空关系, 提出了一种基于多尺度动态时空卷积网络的交通流速度预测模型 (multi-scale dynamic spatio-temporal convolutional network, MDSTCN)。首先, 在图卷积神经网络基础上, 构建自适应的静态空间邻接矩阵, 引入注意力机制捕捉交通流的方向性和动态交互, 挖掘复杂的动态空间关系; 其次, 采用多尺度膨胀卷积结构捕捉时间局部特征与长期趋势; 最后, 基于真实数据集对模型进行训练和测试, 设计了多种实验对比。结果表明, 提出的 MDSTCN 对比最佳基线模型 Graph WaveNet, RMSE、MAE、MAPE 平均相对下降了 5.91%、7.51%、8.59%; 15、30、60 min 的预测误差的波动幅度最小, 突出其在长期预测任务中的良好适应性和稳定性。

关键词: 交通流速度预测; 动态图; 多尺度膨胀卷积

中图分类号: U491

文献标志码: A

Traffic Speed Prediction Based on Multi-scale Dynamic Spatio-temporal Convolutional Network

Zhao Xing, Chen Xian

(College of Civil and Transportation Engineering, Hohai University, Nanjing 210024, China)

Abstract: Accurate and reliable traffic speed prediction is crucial for enhancing traffic management efficiency and alleviating traffic congestion. To improve the traffic speed prediction accuracy and capture complex dynamic spatio-temporal dependencies in traffic data, this study proposes a traffic speed prediction model based on the multi-scale dynamic spatio-temporal convolutional network (MDSTCN). Firstly, an adaptive static spatial adjacency matrix is constructed based on the graph convolutional network, and attention mechanism is introduced to capture the directional dependencies and dynamic interactions of traffic flow, thereby uncovering the intricate dynamic spatial relationships. Secondly, a multi-scale causal dilated convolutional structure is adopted to extract temporal correlations encompassing both local patterns and long-term trends. Finally, the model is trained and tested on a real-world dataset, with a variety of comparative experiments designed. The results show that compared with the best baseline model Graph WaveNet, the proposed MDSTCN model achieves average relative reductions of 5.91% in RMSE, 7.51% in MAE, and 8.59% in MAPE. Furthermore, the prediction error fluctuation across 15/30/60-minute time horizons is minimal, highlighting its good adaptability and stability in long-term prediction tasks.

Key words: Traffic speed prediction; dynamic graph; Multi-scale dilated convolution

现有城市道路无法与日益增长的交通需求相匹配, 导致交通拥堵呈现高发常态化, 影响居民的日常出行的同时, 给城市交通管理带来了巨大的挑战, 制约城市发展。交通流速度作为反映城市交通状况的关键

投稿日期: 2025-05-15

基金项目: 江苏省自然科学基金项目 (BK20211203)

指标,是智能交通系统的重要组成部分,交通流速度预测的准确性对于提升交通管理效率、优化资源配置、缓解交通拥堵具有重要意义。然而,交通数据的复杂时空依赖性在时间和空间上呈现出动态变化和不确定性^[1],交通状态预测精度不仅受到历史数据、节假日等时间维度因素影响,不同地理位置、交通设施、路段拥堵的传播等空间维度因素也会引起交通流状态变化。因此,有必要从交通数据的时空特性出发,构建高效精准的交通流速度预测模型,为未来城市道路管理规划和出行者决策提供参考依据。

早期基于统计理论和机器学习的预测方法,如历史平均模型(HA)^[2]、自回归移动平均(ARIM)^[3]、贝叶斯网络^[4]、支持向量机(SVM)^[5]以及K最近邻(KNN)^[6]等方法,在捕捉非线性的突变特征和海量数据的处理中存在局限性。近年来,深度学习模型在交通流速度预测中取得了显著进展。递归神经网络(Recurrent Neural Network, RNN)^[7]因其捕捉时变规律的有效性被广泛使用,为缓解RNN梯度消失和爆炸问题^[8],其他学者使用变体长短期记忆网络(Long Short-Term Memory, LSTM)^[9]、门控递归单元(Gated Recurrent Unit, GRU)^[10]以引入记忆机制和门控机制学习具有较长时间跨度的时间序列。然而,这些模型忽略了交通流数据的空间结构特征,卷积神经网络(Convolutional Neural Networks, CNN)和图神经网络(Graph Neural Networks, GNN)因而被引入交通流速度预测中^[11],以充分利用交通网络中的空间信息。其中,CNN对网格化后的交通网络进行空间特征提取,忽略不同道路的连接关系,而GNN利用图在非欧式空间数据进行卷积操作^[12],更适合复杂的交通网络拓扑结构。通过混合架构堆叠空间模块和时间模块,空间优先结构的GCN-LSTM模型^[13]、时间优先结构的T-GCN模型^[14]能够实现时空特征的渐进提取。然而现有模型在捕捉路段数据的动态时空依赖关系上仍然存在挑战。

对于图结构而言,预定义的图结构大多由欧几里得距离或路段的连接情况决定,然而交通流还受到一些隐含因素影响,如道路特征、兴趣点分布、交通转向控制等,这使得预定义的图结构难以准确表达路段间的空间关系。为此,多种图结构的自适应生成算法被提出,DCRNN模型^[15]通过图结构上的随机游走捕获交通数据的空间关联性,ETGCN模型^[16]利用注意力机制融合多种图结构,GAT模型^[17]采用注意力机制表示目标节点和相邻节点的相关性。但这些模型仍然基于静态图结构描述交通数据的时空特性,忽略了不同节点的关联性随时间的动态变化。这种静态假设难以刻画交通网络中空间关联的实时变化,尤其在交通流速度因交通事件而发生剧烈波动时,路段间的相关性可能发生显著改变^[18]。如图1所示,在凌晨2-6点与日间8-14点两路段的相关性明显发生变化。即使是自适应的邻接矩阵,若在不同时间窗保持不变,也不能捕捉图结构在时间维度的动态变化。




图1 相邻路段空间依赖性可视化

Fig.1 Visualization of spatial dependencies among adjacent road segments

传统基于RNN的递归架构因其序列依赖性,计算过程严格依照时间步顺序进行,当前时间步的输出依赖于前一时间步的结果,导致计算效率低,训练和推理阶段耗时长。而CNN在二维图像的处理可以拓展到时间维度的因果卷积,通过卷积核的滑动捕捉局部和长期的时间依赖关系^{[19][20]}。时间卷积网络(TCN)

[21]使用因果卷积进行交通预测, 能够实现对数据的高效并行处理。为了有效捕捉序列的长期依赖关系, TCN 通过叠加多层膨胀卷积网络以扩大感受野, 并使用残差连接防止网络退化。然而为了有效覆盖整个时序序列并捕捉复杂的依赖关系, TCN 通常需要堆叠多层形成深层网络进行特征提取, 大幅增加了网络的复杂性和模型训练难度。

为了有效表达交通数据中的复杂时空关系, 提升交通流速度预测精度, 本文从捕捉路段节点的动态时空特性出发, 提出一种基于多尺度动态时空卷积网络的交通流速度预测模型 (Multi-scale Dynamic Spatio-temporal Convolutional Network, MDSTCN)。在预定义邻接矩阵的基础上, 通过节点嵌入的自适应邻接矩阵优化图结构, 捕捉全局静态空间关系, 同时引入空间注意力机制提取局部动态空间特征, 捕捉交通流速度波动的时滞性和方向性。进一步地, 为了有效融合不同空间特征信息, 设计了一种精细化的门控结构以自适应调控各组件的权重, 从而实现对复杂空间特征的精准整合与优化表达。其次, 本文提出了一种多尺度时间卷积方法, 通过调整膨胀率能灵活地学习不同尺度的时间特征, 挖掘时间序列中的全局和局部特征关系。最后, 本文在真实数据集上进行测试, 验证了模型捕捉交通流速度的时空特征的有效性。

1 交通流速度预测模型构建

本文提出基于多尺度动态时空卷积网络的交通流速度预测模型 (MDSTCN), 旨在通过动态融合时空特征, 捕捉交通数据中的复杂依赖关系。如图 2 所示, MDSTCN 模型主体由两个时空卷积层堆叠而成, 通过残差连接方式保留原始输入特征, 避免网络的信息衰减。其中, 每个时空卷积层由静态空间特征融合模块、多尺度时间卷积模块构成, 首先通过静态空间特征融合模块挖掘交通数据的静态与动态空间关联, 生成融合空间特征矩阵, 随后将该特征矩阵传递至多尺度时间卷积模块学习时间依赖关系。在静态空间特征融合模块中, 预定义和自适应生成的图结构通过图卷积网络提取静态空间特征, 而注意力机制则用于响应交通流空间关系的动态变化, 最后使用门控机制对静态和动态的空间特征进行融合。多尺度时间卷积模块采取不同膨胀率的因果卷积, 并行提取不同时间尺度的依赖关系, 捕捉交通序列的短期波动和长期趋势。该架构能够有效处理交通流数据中的时空动态复杂性, 为交通流速度预测提供精确的建模基础。

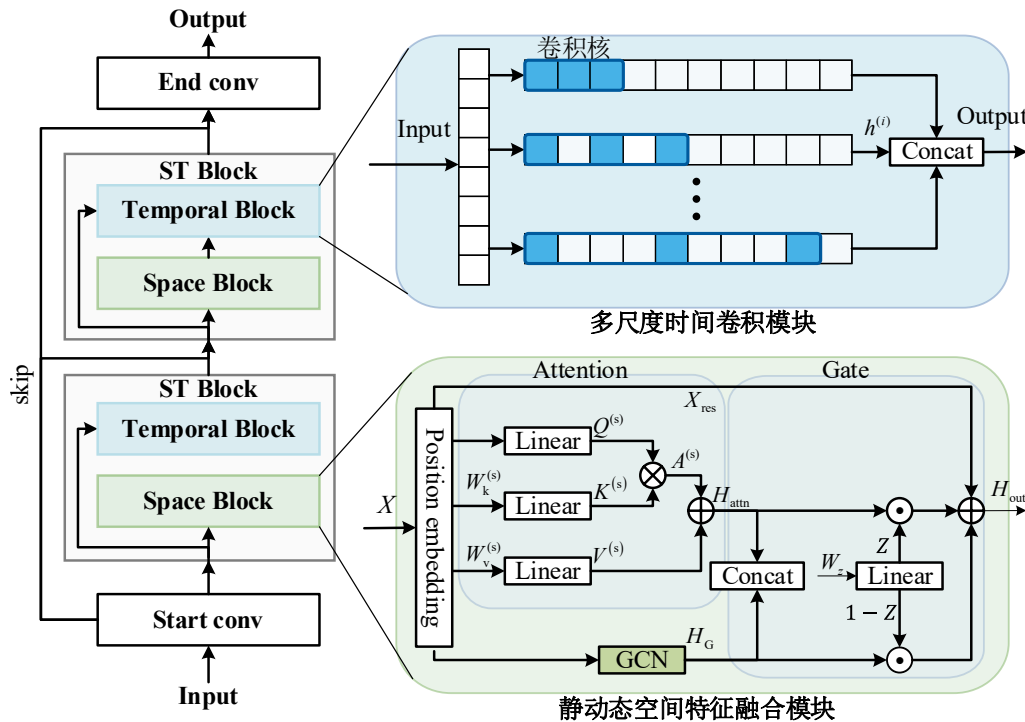


图 2 预测模型整体结构

Fig.2 Overall structure of the prediction model

1.1 问题描述

本文中的交通流速度预测问题可以描述为：给定历史时间窗口长度为 T_h 的 N 个路段的 F 维交通流特征矩阵 $X = [X_{t-T_h+1}, X_{t-T_h+2}, \dots, X_t]$ ， $X \in \mathbb{R}^{T_h \times N \times F}$ ，以及路网图结构 $G = (V, E, A)$ ， $A \in \mathbb{R}^{N \times N}$ ，预测未来 T_p 个时刻的交通流速度 $\hat{V} = [\hat{V}_{t+1}, \hat{V}_{t+2}, \dots, \hat{V}_{t+T_p}]$ ， $\hat{V} \in \mathbb{R}^{T_p \times N}$ 。模型表达式如下，其中 f 为预测模型。

$$\hat{V} = f(X, G) \quad (1)$$

其中， t 时刻交通流数据 $X_t = [X_t(1), X_t(2), \dots, X_t(N)]$ 储存路段历史交通流数据特征， $X_t \in \mathbb{R}^{N \times F}$ ，在本研究中只考虑历史交通流速度即特征维度 $F=1$ ，未来 t' 时刻的交通流速度 $\hat{V}_{t'} = [\hat{V}_{t'}(1), \hat{V}_{t'}(2), \dots, \hat{V}_{t'}(N)]$ 。 $G = (V, E, A)$ 储存图结构信息，节点 V 代表路段，边 E 代表路段之间的连接关系， A 是基于实际路段连通情况构建的静态邻接矩阵。

1.2 静动态空间特征融合模块

为刻画交通流的空间关联性，在图卷积基础上，本文通过自适应邻接矩阵从交通流特征中学习道路的拓扑连接关系，以可训练的路网隐式依赖挖掘全局静态空间特征。随后引入注意力机制，实时感知各路段交通流间的动态交互。最后设计了精细化的门控结构，依据当前状态自适应分配门控权重以融合静态动态空间特征，使图卷积的稳定性与注意力的灵活性互为补充，从而捕捉交通流复杂的空间特征。

1.2.1 静态自适应图卷积

交通网络作为典型图拓扑结构，相较于传统卷积神经网络，图神经网络(Graph Neural Networks, GNN) 能利用图表示处理非欧氏空间数据，使卷积操作更适用于交通数据结构。GCN 通过定义图数据的卷积操作，聚合邻居节点特征以更新当前节点特征表示，实现了节点间信息传递。

GCN 的输入主要包含表示图结构的邻接矩阵和节点特征矩阵，邻接矩阵用于表示图中节点之间的连接关系，特征矩阵表示每个节点的特征向量。GCN 通过邻居聚合和特征传播两个关键步骤实现图上的卷积操作。图结构数据 $G = (V, E, A)$ ，其中 V 表示节点集合， E 表示节点间边的集合， A 为邻接矩阵，通过元素 A_{ij} 表示图中节点 i 和节点 j 的连接强度， $A \in \mathbb{R}^{N \times N}$ 。则节点特征矩阵根据式 (2) 更新：

$$H^{(l+1)} = f(H^{(l)}, A) = \sigma \left(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (2)$$

其中， $H^{(l)}$ 表示第 l 层的特征矩阵， \hat{A} 表示归一化后的邻接矩阵， $W^{(l)}$ 表示第 l 层的权重矩阵， σ 表示激活函数， D 为邻接矩阵 A 的度矩阵。

然而，交通系统中的空间依赖具有动态性和方向性，在交通流中，上游路段对下游路段的影响强度通常高于逆向影响。DCRNN 模型使用了扩散卷积层，对于静态邻接矩阵通过有限的 K 步迭代方法模拟信号的前向和后向传播扩散现象。另外，在交通系统中，邻接矩阵反应了真实的道路连通性，但由于数据的不充分性和交通网络的隐式依赖，预定义的图结构无法精准呈现路段的关联关系^[22]。因此本文使用自适应邻接矩阵，在模型训练中挖掘网络的隐式特征，避免原始邻接矩阵因为遗漏或是错误连接而造成的信息损失。

$$H_G = \sum_{k=0}^K (P_f^{(k)} X W_{k1} + P_b^{(k)} X W_{k2} + \tilde{A}_{\text{apt}}^{(k)} X W_{k3}) \quad (3)$$

其中， $P_f^{(k)}$ 、 $P_b^{(k)}$ 分别为前向和后向转移矩阵， $P_f^{(k)} = A / \text{rowsum}(A)$ ， $P_b^{(k)} = A^T / \text{rowsum}(A^T)$ ， A 为静态邻接矩阵， $A \in \mathbb{R}^{N \times N}$ ， $\tilde{A}_{\text{apt}}^{(k)}$ 为自适应邻接矩阵， X 为输入节点特征， W_{k1}, W_{k2}, W_{k3} 为第 k 层的权重矩阵。

自适应邻接矩阵根据节点嵌入方法,由可学习化参数 E_1, E_2 生成, $E_1, E_2 \in R^{N \times d_{\text{emb}}}$, d_{emb} 为节点嵌入维度, a_{ij} 表示源节点 i 和目标节点 j 的连接权重。交通数据中的空间依赖关系是单向的,因此通过 $E_1 E_2^T - E_2 E_1^T$ 捕捉非对称方向的依赖关系。

$$\tilde{A}_{\text{apt}}^{(k)} = I + \text{softmax}\left(\text{ReLU}\left(E_1 E_2^T - E_2 E_1^T\right)\right) \quad (4)$$

其中, E_1, E_2 分别表示将路段映射为源节点的特征嵌入矩阵和目标节点的特征嵌入矩阵。 ReLU 激活函数消除弱连接并保证邻接矩阵非负, softmax 函数对自适应邻接矩阵进行归一化处理。加入单位矩阵 I 保证最终得到的邻接矩阵对角线为1,实现自环。

1.2.2 动态空间注意力机制

注意力机制具有显著的优点,能够动态捕捉节点之间的相关性,且可以根据输入数据的变化实时调整权重。在交通预测中,注意力机制已被广泛应用于交通网络中复杂的时空依赖关系建模^[23],可以更好地捕捉交通流量在不同路段之间的转移模式,尤其是在短距离和局部范围内。

为了克服邻接矩阵在动态关联性建模上的局限性,本文引入注意力机制,动态捕捉当前时间窗内的节点相关性,具体而言即通过计算目标路段特征与邻接路段特征的相似度,生成动态注意力权重矩阵。通过这种方式,模型能够实时响应交通网络中的动态变化,例如交通事故或突发拥堵,从而提高交通预测的准确性和鲁棒性。多头注意力机制为节点分配可训练的权重,能够自动聚焦于关键信息。通过不同权重矩阵,输入的特征矩阵 X 被投射到高维潜在子空间:查询矩阵 $Q^{(s)}$ 、键矩阵 $K^{(s)}$ 、值矩阵 $V^{(s)}$ 。

$$Q^{(s)} = XW_q^{(s)} \quad (5)$$

$$K^{(s)} = XW_k^{(s)} \quad (6)$$

$$V^{(s)} = XW_v^{(s)} \quad (7)$$

其中, $Q^{(s)}, K^{(s)}, V^{(s)} \in R^{T_h \times N \times F}$, $W_q^{(s)}, W_k^{(s)}, W_v^{(s)}$ 为可学习的投影矩阵, $W_q^{(s)}, W_k^{(s)}, W_v^{(s)} \in R^{F \times F}$ 。

节点间的动态依赖关系使用点积计算,最后通过加权组合输出结果。

$$A^{(s)} = \text{softmax}\left(Q^{(s)}(K^{(s)})^T / \sqrt{d_A^{(s)}}\right) \quad (8)$$

$$H_{\text{attn}} = A^{(s)}V^{(s)} \quad (9)$$

其中, $A^{(s)}$ 表示注意力权重矩阵, $A^{(s)} \in R^{N \times N}$,其元素 $a_{ij}^{(s)}$ 表示节点 i 对节点 j 的动态关联强度,权重值 $a_{ij}^{(s)}$ 越大表明当前时段节点 i 对节点 j 的交通状态影响越大。最后将每个节点特征动态更新为全局节点的加权组合 $H_{\text{attn}} \in R^{T_h \times N \times F}$ 。

1.2.3 门控特征融合策略

门控机制(Gating Mechanism)是一种在神经网络中用于控制信息流动的关键技术,在交通预测中被广泛应用LSTM及其变体GRU。门的本质为一种激活函数,产生一个介于0和1之间的值来表达允许信息通过的比例,其中0表示完全遗忘,1表示完全保留。由此门控机制可以过滤无用信息,有效保留关键信息并减少计算冗余。同时门控机制允许模型对不同输入进行动态调整,增强模型泛化能力。

通过简单门控机制融合图卷积和空间注意力层学习到的空间特征 H_G, H_{attn} ,门控系数 g 和 $1-g$ 分别决定图卷积和注意力层保留信息的比例。该门控机制的实现如下所示:

$$g = \sigma\left(f_s(H_{\text{attn}}) + f_g(H_G)\right) \quad (10)$$

$$H = g \cdot H_{\text{attn}} + (1-g) \cdot H_G \quad (11)$$

其中, f_s 和 f_G 分别对 H_{attn}, H_G 进行独立线性变换, 将其映射为相同维度的特征向量。随后经过 sigmoid 激活函数生成门控系数 g , 用于对 H_{attn}, H_G 进行加权平均, 从而实现局部和全局空间特征的融合。

但是简单的门控机制难以适应路网复杂场景, 因此本文设计了一种精细化的门控机制, 通过动态调整融合权重, 能有效融合基于图卷积的拓扑特征和基于注意力机制的动态关联特征。公式如下所示:

$$Z = \sigma(W_z [H_{\text{attn}}, H_G] + b_z) \quad (12)$$

$$H_{\text{fuse}} = Z \odot H_{\text{attn}} + (1 - Z) \odot H_G + X_{\text{res}} \quad (13)$$

其中, 通过拼接空间注意力的输出 H_{attn} 和图卷积的结果 H_G , 捕捉两个模块输出的交互关系, 并独立为每个特征维度分配权重, 使用 sigmoid 将门控权重 Z 映射到 $[0, 1]$, $Z \in R^{T_h \times N \times F}$, $W_z \in R^{2F \times F}$ 。 \odot 表示逐元素相乘, X_{res} 是跳跃连接保留的原始输入特征。

该门控机制通过拼接操作获取联合特征, 使用门控权重对图卷积和注意力模块输出进行加权求和, 并保留残差, 实现了更精细化的特征融合。模型不仅能够融合图卷积模块和注意力机制提取的特征, 还能通过残差连接有效保留原始输入信息, 提高模型的特征表达能力和鲁棒性。门控权重 Z 可以实现动态调整, 在不同的交通场景中平衡图卷积和注意力机制的贡献, 根据交通状态的变化自适应地选择性依赖静态拓扑特征或动态关联特征。例如, 在高峰时段, 交通流的动态关联性更强, 模型会更多地依赖空间注意力机制; 而在平峰时段, 静态拓扑特征则更具代表性。

最后对融合后的特征进行归一化和非线性处理, 进一步提升特征质量和模型性能:

$$H_{\text{out}} = \text{LayerNorm}(\text{ReLU}(H_{\text{fuse}})) \quad (14)$$

通过 LayerNorm 归一化操作, 模型能够稳定训练过程, 减少梯度爆炸和消失问题; 而 ReLU 激活函数则为模型引入非线性特性, 使其能够更好地捕捉交通流数据中的复杂模式。

1.3 多尺度时间卷积模块

在时间序列预测中, 因果卷积不同时间步的输出相对独立, 可以实现并行计算以同时处理整个序列, 相较于 RNN 的递归结构能够显著提升效率^[24]。膨胀卷积通过在卷积核中插入间隔以扩大感受野, 能更好捕捉时间序列中的上下文信息。卷积核中相邻元素的间隔由膨胀率 d 决定, 传统的 1D 卷积可以看作是 $d=1$ 的膨胀卷积。对于输入历史时间窗口长度为 T_h 的交通流特征数据 $X = [X_0, X_1, \dots, X_{T_h}]$, 给定宽度为 M 的卷积核 $K_{\text{conv}} = [k_1, k_2, \dots, k_M]$ 和膨胀率 d , 膨胀因果卷积可表征为 $t-(M-1) \times d$ 至 t 时间步特征的加权组合, 公式如下所示:

$$h_t' = (K_{\text{conv}} *_{d} X)_t = \sum_{m=0}^{M-1} k_m X_{t-m \times d} \quad (15)$$

其中, $K_{\text{conv}} *_{d} X$ 代表膨胀率为 d 的膨胀卷积, h_t' 是卷积后 t 时间步的输出值, k_m 是卷积核 K_{conv} 在位置 m 的权重, $X_{t-m \times d}$ 是第 $t-m \times d$ 个时间步的输入特征。

多尺度并行的卷积在 CNN 提取图像特征中得到广泛应用, 并证明了其捕捉不同尺度特征的能力^[25]。多尺度时间卷积模块采用了多分支并行的浅层结构, 能够灵活调整卷积核的感受野。不同的时间尺度可能包含不同的模式和趋势, 使用不同膨胀率的膨胀卷积核, 不仅可以减小局部噪声对特征提取的影响, 还能够充分挖掘时间序列中的时间特征, 提升模型的表达能力, 同时降低网络的深度, 提高运行效率。

对于输入特征 $X \in R^{T_h \times N \times F}$, 保证卷积核 $K_{\text{conv}} = [k_1, k_2, \dots, k_M]$, $K_{\text{conv}} \in R^{M \times F \times C_{\text{out}}}$ 的大小不变, 通过一组膨胀率 $D = [d_1, d_2, \dots, d_n]$ 来实现多尺度时间特征提取。

$$h^{(i)} = K *_{d_i} X \quad (16)$$

$$H_T = \text{concat}(w_i \cdot h^{(i)} | i = 1, 2, \dots, n) \quad (17)$$

其中, h^i 是膨胀率 d_i 的膨胀卷积的输出, $h^{(i)} \in R^{T_h \times N \times C_{out}}$, 共有 n 个卷积分支, 为保证多尺度时间卷积模块输入输出的特征维度不变, $C_{out} = \frac{F}{n}$, w_i 是可学习参数, $w_i \in R$, 表示第 i 个卷积分支的权重, 用于调整不同分支在时间特征提取中的重要性, 以实现多尺度时间特征的加权融合。最后将不同卷积分支的输出拼接形成多尺度时间特征矩阵 H_T , $H_T \in R^{T_h \times N \times F}$ 。

2 实验

2.1 数据概况与特征分析

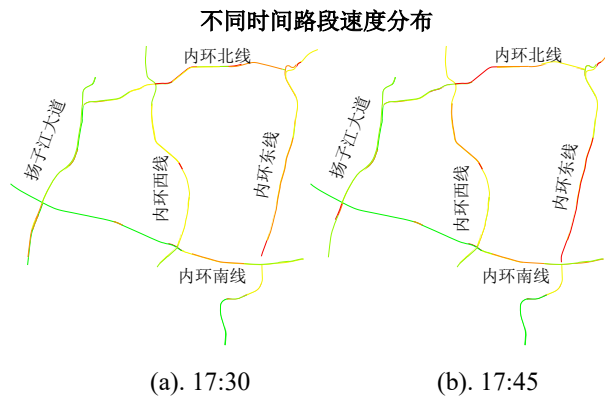
2.1.1 数据集

本文主要以高德地图南京市内环快速路的真实交通数据集为研究对象, 进行交通流速度预测研究。该数据集包含 2022 年 7 月 1 日至 2022 年 12 月 31 日的交通数据, 数据采样间隔为 5 min, 包含 73 条路段, 共 3 868 416 条数据。首先对数据预处理, 由线性插值填补缺失数据, 依照 7:1:2 的比例分别构建训练集、验证集和测试集, 其次通过归一化将原始的交通流速度数据映射到[-1,1]中。本文使用滑动窗口法, 将连续的时间序列数据切分为多个固定长度的子序列, 将其作为模型的输入序列和标签。其中滑窗大小为历史时间步长+预测时间步长。

2.1.2 交通流速度时空特性分析

交通流时间特性和空间特性相互影响, 同一路段的速度不仅受到历史时刻速度的影响, 也会受到邻近路段前序时刻速度的影响。为了分析交通流速度的时空相关性, 本文选取晚高峰部分时段(17:30-18:30)进行研究, 在该时段内交通流速度波动剧烈, 易于分析交通流速度波动的传播过程。

待研究路段在不同时刻的交通流速度变化如图 3 所示, 可明显观测到各路段交通流速度的时空变化: 由于交通需求增加, 17:30 内环北线、南线与东线的部分路段速度下降, 形成局部初始扰动; 随着时间推移, 扰动引发的速度波动逐渐向周围路段传播, 内环西线与扬子江大道的速度相继出现大幅下降; 约 1 h 后部分路段如内环南线、西线的速度逐步回升, 然而内环北线和东线等核心过境通道因持续超载, 仍维持低速状态。基于上述交通流的时空演变规律, 采用 1 h 时间窗的历史数据可有效覆盖交通流从初始扰动形成、交通流速度波动传播到局部状态恢复的过程, 既能保证模型捕捉交通流速度未来时段的变化趋势, 又能避免过长序列引入的噪声干扰, 为交通流速度预测模型提供具有时效性的输入信息, 提升对未来时段交通状态的预测精度。



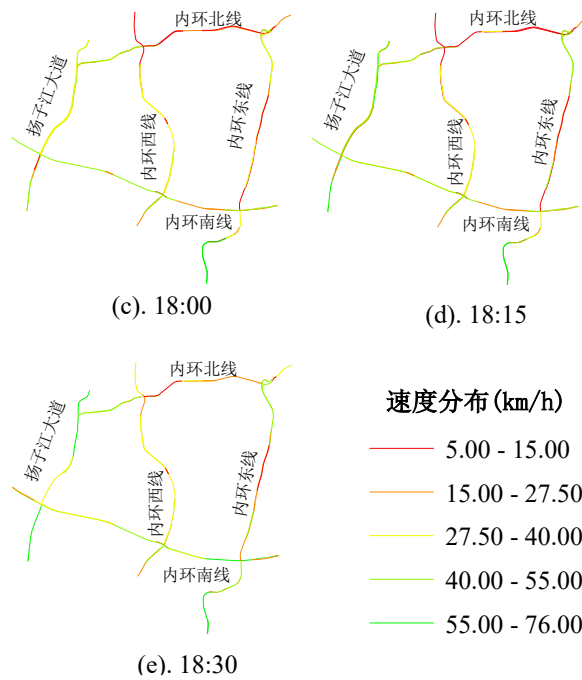


图3 南京市内环快速路速度时空演变趋势

Fig.3 The spatio-temporal evolution trend of traffic speed on the Nanjing Inner Ring Expressway

进一步分析交通流速度传播的时间延迟现象。以内环西线自南向北方向的相邻路段B、C为研究对象，其空间位置关系如图4所示，根据高德地图的实测数据，两路段的直线距离约为2 km，高峰时段的预估通过行程时间约13 min。对比两路段在高峰时段的速度变化情况如图5所示，可明显观测到路段B的交通流速度下降滞后于路段C。晚高峰时段，路段C的交通流速度急剧下降并于18:10达到局部最小值，而路段B的交通流速度局部最小值呈现约15 min的传播时滞。该时滞与两路段的行程时间高度吻合，验证了交通流状态变化的时滞性。若忽略这种空间传递的滞后性，可能导致模型对速度变化趋势的误判，进而影响交通流速度的预测准确性。因此，需要建立考虑路段空间关联性的动态网络模型，准确刻画路段拓扑关系及时空传播机制，以提升交通流速度的预测准确度。另外，图5同时展示了由本文模型 MDSTCN 对路段B、C未来5 min的交通流速度预测结果，两路段的预测速度与实际速度的波动趋势一致，说明模型能够描述交通流速度波动传播的时间延迟现象。



图4 内环快速路部分路段空间关系

Fig.4 Spatial relationship between some sections of the Inner Ring Expressway

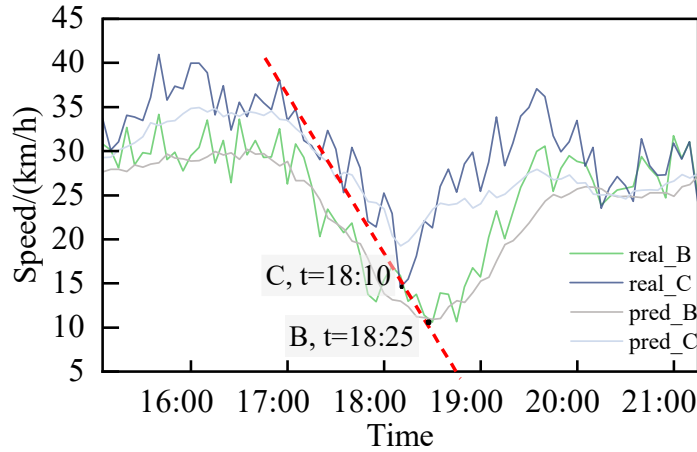


图5 相邻路段的拥堵传播时间滞后现象

Fig.5 Spatio-temporal lag phenomenon in congestion propagation between adjacent road segments

2.2 对比实验

为了验证本文建立预测模型的有效性，选取现阶段广泛使用的多种研究模型 LSTM^[9]、T-GCN^[14]、DCRNN^[15]、STGCN^[26]、ASTGCN^[27]、Graph WaveNet^[28]作为对照。

实验在 NVIDIA 1660 Ti GPU 的环境中进行，基于 PyTorch 2.5.1 框架搭建模型并进行训练。模型输入历史时间步长为 12，即使用历史 60 min 的交通流速度，分别预测未来 15 min、30 min、60 min 的交通流速度。在实验中，通过 Adam Optimizer 进行参数更新，其中学习率 learning rate=0.002，模型训练轮数 epoch=50，批大小 batch_size=64，交通网络的路段数为 73。

在交通预测中，通过对比模型预测结果与实际交通流速度数据，使用 MAE、RMSE、MAPE 来计算预测误差、综合评估预测模型性能，有助于判断模型是否能够有效捕捉交通流速度的变化趋势和特征。平均绝对误差（MAE）是预测值与实际值之间差异的绝对值的平均值，均方根误差（RMSE）计算预测值与真实值之差的平方和的平方根，平均百分比误差（MAPE）用于衡量预测精度，以百分比形式表达预测误差，具有良好的解释性。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (20)$$

其中， n 为样本个数， y_i 为第 i 个样本的真实值， \hat{y}_i 为第 i 个样本的预测值。

2.3 实验结果及分析

本文基于交通流速度数据集探究了多种预测模型在短时（15 min）、中期（30 min）以及长期（60 min）时间尺度下的预测性能，得到测试集的预测结果如表 1 所示。图 6 展示了不同模型的预测性能随时间尺度增加的变化趋势。与其他经典模型相比，本文提出的模型 MDSTCN 在各时间尺度下均实现了最佳预测性能，尤其在长期预测任务中具有显著优势。

1) 空间图结构的有效性：在短时预测中，单纯依赖时间特征的模型 LSTM 的预测精度明显低于考虑空间因素的模型。T-GCN 和 DCRNN 在循环神经网络 RNN 架构的基础上引入图结构，分别通过 GCN 和扩散卷积捕捉空间结构信息，显著提高了短时预测的性能，RMSE 分别下降了 0.68 和 0.51。然而，随着预测时间跨度的增加，在中长期预测中 T-GCN 的性能提升幅度逐渐减小。另外，DCRNN 采取递归多步预测

方法, 导致误差随预测时长逐步累积, 这一现象在长期预测中表现尤为明显, 其 RMSE 甚至比 LSTM 高出 0.40, 这说明直接多步预测在长期预测中能够更好应对误差累积问题, 保持相对稳定的预测性能。

2) 动态图建模的有效性: ASTGCN 模型通过注意力机制捕捉时空图的动态变化, 在 STGCN 模型的基础上大幅提升了预测性能, 尤其是长期预测任务中优势突出。本文提出的模型相比 Graph WaveNet 的自适应邻接矩阵, 进一步引入注意力机制以捕捉空间特征的动态变化, 在 RMSE、MAE 和 MAPE 评价指标上平均相对降低了 5.91%、7.51% 和 8.59%, 验证了节点嵌入自适应图结构与注意力机制结合, 能够有效建模图结构的动态变化。

3) 膨胀卷积在时间特征提取中的有效性: STGCN 使用的纯卷积结构针对短时预测的性能略低于 T-GCN, 且在中长期预测中的表现更差, 60 min 预测中 STGCN 的 RMSE 指标甚至比 LSTM 高出 0.17, 这表明单纯的一维卷积结构在时间特征提取的有效性不及 RNN 架构。而 Graph WaveNet 模型通过堆叠膨胀卷积层, 显著扩大了感受野, 有效增强了对时间依赖性的建模能力, 在短期和中长期预测任务中均表现优异。本文模型采用多尺度膨胀卷积结构, 尽管在 15 min 短时预测任务中相比 Graph WaveNet 模型的性能提升幅度有限, RMSE 仅相对降低 2.09%; 但在中长期预测中展现出更高的稳定性, 在 60 min 预测任务中, 本文模型的 RMSE、MAE 和 MAPE 指标对比 Graph WaveNet 分别实现了 10.83%、12.67% 和 16.33% 的相对降低。另外, 在 15 min、30 min、60 min 预测任务中, 本文模型的 RMSE 仅上升了 1.00, 说明模型在捕捉中长期速度变化趋势的优势。

表 1 不同模型预测性能对比

Tab.1 Comparison of prediction performance on different models

模型	RMSE			MAE			MAPE/%		
	15 min	30 min	60 min	15 min	30 min	60 min	15 min	30 min	60 min
LSTM	5.57	5.95	6.94	3.85	4.07	4.65	9.98	10.81	13.12
T-GCN	4.89	5.46	6.53	3.36	3.69	4.36	8.39	9.47	11.79
DCRNN	5.06	5.99	7.34	3.32	3.85	4.65	8.31	10.27	13.45
STGCN	4.95	5.80	7.11	3.38	3.87	4.64	8.48	10.18	13.00
ASTGCN	4.82	5.43	6.60	3.19	3.50	4.18	7.84	9.04	11.28
Graph WaveNet	4.79	5.37	6.38	3.16	3.51	4.19	7.65	8.80	11.01
Our model	4.69	5.11	5.69	3.06	3.28	3.66	7.45	8.20	9.21

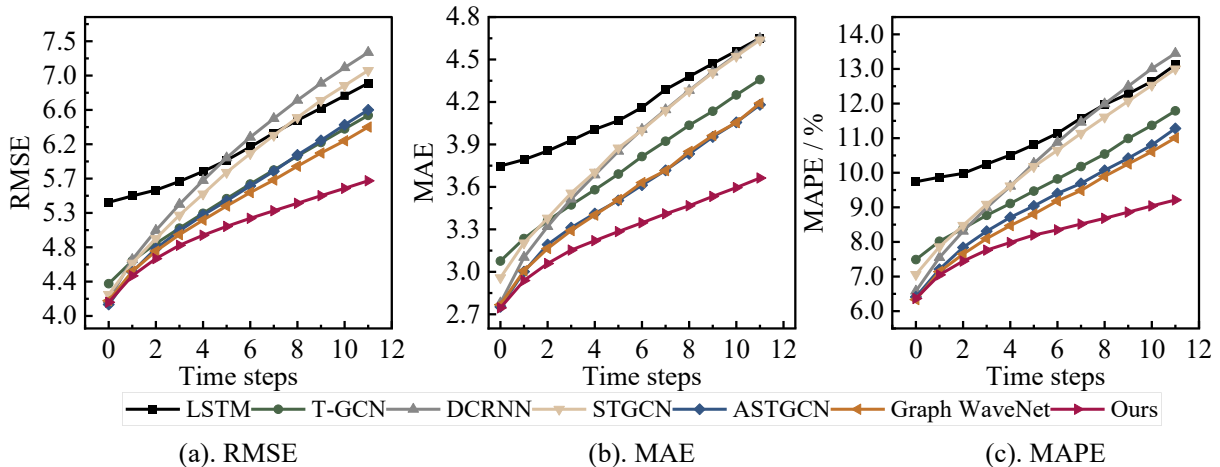


图 6 各模型随预测时间尺度增加的性能变化趋势

Fig.6 Trends of prediction performance in different models with increasing prediction horizons

为进一步评估不同模型在各时间步的预测性能, 以某一日的预测结果为例进行可视化, ASTGCN、DCRNN、Graph WaveNet 和本文模型 MDSTCN 与真实值对比情况如图 7 所示。对于 ASTGCN、DCRNN 模型, 随预测步长的变化, 预测的速度值出现了明显的滞后现象, 表明其预测误差随预测时间范围增加出

现了显著增长。相比而言，本文提出的模型能更好地对动态时空变化和长期时间依赖关系进行建模，这对交通流速度预测的精度提升有显著促进作用，尤其在长期预测方面具有更好的适应性。




图 7 ASTGCN、DCRNN、Graph WaveNet、MDSTCN 单日交通流速度预测可视化

Fig.7 Visualization of one-day traffic speed prediction obtained by ASTGCN, DCRNN, Graph WaveNet and MDSTCN

2.4 消融实验

为了系统性地验证各组件的有效性和差异化影响，进一步分析模型的精度提升和长期预测的有效性来源，本文以 MDSTCN 为基准模型设计了 5 种变体模型进行对比分析：MDSTCN-gcn（去除图卷积）、MDSTCN-adj（去除自适应邻接矩阵）、MDSTCN-attn（去除注意力机制）、MDSTCN-gate（动态门控机制替换为简单门控机制，如公式(10-11)）、MDSTCN-space（空间特征提取模块替换为线性卷积），实验结果如表 2 所示。分析各变体模型的预测效果，凸显了空间特征提取模块在捕捉复杂时空依赖中的必要性，尤其是注意力机制对中长期预测精度的提升作用显著。

1) 空间特征的必要性。MDSTCN-space 模型的结果在各指标的表现最差，且与 MDSTCN 模型的差距较大，尤其在 60 min 预测中其 RMSE 较基准模型 MDSTCN 上升了 0.98。这表明空间特征对预测性能的提升效果随预测步长增加，验证了在速度预测尤其是长期预测任务中考虑复杂时空依赖的重要性。

2) 静态空间特征对预测能力的提升。缺失自适应邻接矩阵的 MDSTCN-adj 模型在预测中与 MDSTCN 模型的表现接近，说明通过自适应矩阵重构静态空间关系对于速度预测的稳定具有有限作用。而去掉图卷积后的 MDSTCN-gcn 模型则在各预测任务中误差均有较明显上升，在 15 min、30 min、60 min 预测任务中，其 RMSE 相较基线模型分别上升 0.05, 0.10, 0.12，说明了图卷积捕捉空间拓扑关系的能力。

3) 注意力机制的短期过拟合风险与长期预测增益。去除注意力机制后的 MDSTCN-attn 模型在短时预测（15 min）中的 RMSE 甚至略低于 MDSTCN 模型，说明注意力机制可能无法提升模型的短时预测效果，

引入注意力机制反而导致模型结构更加复杂,增加过拟合风险。然而,注意力机制能够显著提升模型长期预测的性能。在 60min 预测任务中,相较于 MDSTCN 而言,MDSTCN-attn 模型的 RMSE、MAE 和 MAPE 指标相对增加了 3.51%、4.37%、7.49%,这表明空间特征的动态变化在长期预测中的重要性,同时该结果也与注意力机制在交通预测邻域的主流研究结论相吻合^[22]。

4) 特征融合的耦合重要性。简化门控机制的 MDSTCN-gate 模型的预测性能与基线模型相比出现明显下降,其预测误差 RMSE 在 15 min、30 min、60 min 预测任务中分别增加 0.03、0.08、0.18,表明在空间特征捕捉过程中,需要重点关注图卷积和注意力机制结果之间的耦合关系。简单的门控机制难以综合静态图卷积和动态注意力机制的优点,而通过设计精细化的门控结构,可以充分发挥图卷积和注意力机制的各自优势,从而更充分地挖掘空间特征。

表 2 MDSTCN 消融实验结果

Tab.2 Ablation study results of MDSTCN

模型	RMSE			MAE			MAPE/%		
	15 min	30 min	60 min	15 min	30 min	60 min	15 min	30 min	60 min
MDSTCN	4.69	5.11	5.69	3.06	3.28	3.66	7.45	8.20	9.21
MDSTCN-gcn	4.74	5.21	5.81	3.11	3.39	3.81	7.68	8.63	9.77
MDSTCN-adj	4.69	5.14	5.75	3.07	3.33	3.71	7.52	8.38	9.47
MDSTCN-attn	4.67	5.14	5.89	3.05	3.32	3.82	7.47	8.41	9.90
MDSTCN-gate	4.72	5.19	5.87	3.10	3.39	3.82	7.51	8.38	9.67
MDSTCN-space	5.01	5.74	6.67	3.27	3.71	4.31	8.03	9.58	11.86

此外,为了探究不同膨胀率组合对模型预测性能的影响,本文设计了多种膨胀率组合进行对比实验,结果如表 3 所示。鉴于模型的输入时间序列步长仅为 12,较小的膨胀率已足以覆盖输入序列的时间特征,且能够避免因膨胀率过大而导致的细节丢失问题,因此本文不对其他更大膨胀率组合进行额外分析。

对比单一膨胀率实验的结果,可发现较大的膨胀率虽然在短时预测的表现较差,但在长期预测中,模型 RMSE 下降明显。其主要原因可能在于不同膨胀率对时间序列的差异化解析:较小的膨胀率通过强化局部特征提取能力,能更精准地刻画近期数据中的瞬时波动,而较大的膨胀率则能够扩大感受野的范围,捕捉到长期的趋势。因此不同的膨胀率组合能够综合优点,实现短时和中长期预测的性能提升。

进而对比不同膨胀率组合的预测结果,可以发现[1,2]和[1,1,1]组合的模型预测性能最佳。在短时预测中两者的性能较为接近,然而中长期预测中[1,2]组合的预测效果优于[1,1,1],这表明膨胀卷积在长期预测中的有效性。[1,1,1]组合在短期预测中能实现较好预测的原因在于多分支的复用结构捕捉时间序列不同特征的有效性^[29]。因此本文选取膨胀率组合[1,2]为最优组合,在 15 min、30 min、60 min 预测任务中,其 RMSE 对比传统膨胀率为 1 的 1D 卷积分别下降了 0.23、0.38、0.62,验证了多尺度膨胀卷积通过扩大感受野,能够有效捕捉交通流在时间维度上的多种波动模式。此外,对比[1,3]与[1,2]组合的结果进一步论证了较大的膨胀率确实忽略了序列中重要细节,从而导致了性能的下降。可见,不同的膨胀率组合会对模型的预测性能造成显著影响,因此在进行预测任务时,需要重点关注膨胀率组合的选取,以优化模型的预测性能。

表 3 不同膨胀率组合实验结果

Tab.3 Prediction results of different dilation rate combinations

膨胀率组合	RMSE			MAE			MAPE/%		
	15 min	30 min	60 min	15 min	30 min	60 min	15 min	30 min	60 min
[1]	4.92	5.49	6.31	3.37	3.72	4.26	7.92	8.89	10.24
[2]	4.93	5.44	6.14	3.36	3.66	4.11	7.97	8.86	10.13
[3]	4.99	5.47	6.04	3.48	3.52	4.02	8.41	9.31	10.27
[1,1,1]	4.89	5.41	6.15	3.32	3.64	4.14	7.85	8.81	10.13

[1, 2]	4.69	5.11	5.69	3.06	3.28	3.66	7.49	8.29	9.32
[1, 3]	4.86	5.41	6.05	3.28	3.62	4.05	7.80	8.75	10.13
[1, 1, 1]	4.73	5.19	5.77	3.06	3.31	3.67	7.48	8.28	9.31
[1, 2, 3]	4.88	5.40	6.08	3.28	3.57	4.02	7.86	8.78	10.06

2.5 模型空间特征提取结果分析

交通流速度传播的时延现象会导致下游路段交通速度的滞后响应，这种时空耦合效应使得速度预测需同时考虑空间关联性与时间延迟特性。

为验证自适应邻接矩阵对道路网络空间关联性的特征提取能力，以路段 C 为例，其自适应邻接矩阵构建结果如图 8 所示。实验结果表明，该模型成功识别了路段 B 与路段 C 的静态拓扑关联关系，验证了静态拓扑编码模块的有效性。需要特别指出的是，尽管路段 C 与路段 D 存在物理邻接关系，但由于其交通流速度呈现显著差异（如图 9 所示），导致动态相关系数仅为 0.10。这一现象表明，模型并未简单依赖空间物理邻接关系，而是通过融合交通流的特征实现了静态空间关系的重构。




图 8 路段 C 及其邻接路段自适应邻接矩阵的空间关联性结果

Fig.8 Result of spatial correlations via adaptive adjacency matrix for road segment C


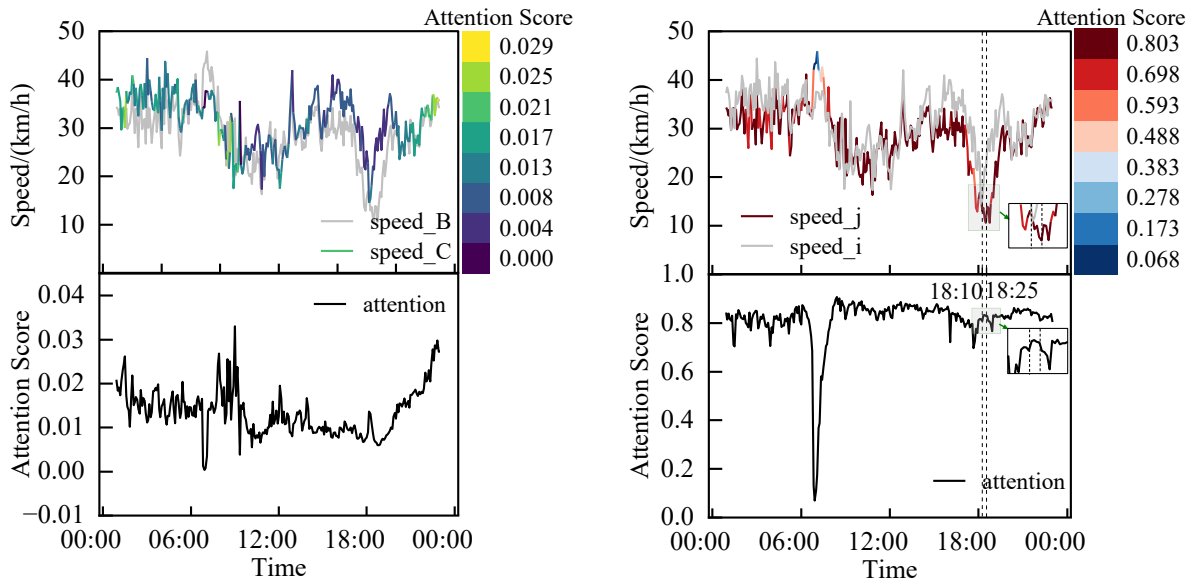


图 9 路段 C 及其邻接路段交通流速度时间演变分析

Fig.9 Dynamic correlation analysis of traffic flow speed for road segment C and its adjoining segments

基于注意力机制的动态空间建模方面，本文选取路段 B、C 进行实证分析，图 10 展示了路段 B、C 的双向注意力权重随时间的变化情况。图 10(a)、(b)的结果显示路段 B、C 间的注意力权重存在显著的方向性依赖。路段 B 至 C 方向的注意力权重显著低于路段 C 至 B 方向，在晚高峰时段（17:00-19:00）路段 B-C 方向的注意力权重均值仅为 0.01，而路段 C-B 的反向权重高达 0.8，说明路段 C 的交通流状态对路段 B 具有显著影响。这一现象与交通波传播理论相吻合，路段 C 的交通流速度下降导致的局部拥堵会向上游路段

B 传播, 验证了模型对于交通流波动传播方向性的有效捕捉。进一步分析可发现, 当两路段的速度曲线变化趋势接近时, 如 08:00-10:00、21:00-24:00 时段, 双向注意力权重均有所提升, 这表明模型不仅能够识别方向性依赖, 还能实时感知路段间交通状态的动态交互。此外, 从图 10(b)中可观察到晚高峰时段内, 下游路段 C 至上游路段 B 的注意力权重在 18:10-18:25 时段内处于较高水平, 恰好对应路段 C 的速度达到局部最小值至路段 B 速度下降至低点的 15 min 速度波动传播时滞, 说明注意力机制能够捕捉速度波动在两路段的传播方向和传播延迟。



(a) 路段 B 至 C 方向的注意力权重 (C 为目标路段) (b) 路段 C 至 B 方向的注意力权重 (B 为目标路段)

图 10 路段 B、C 双向注意力权重时序动态可视化结果

Fig.10 Visualization of temporal dynamics comparison of bidirectional attention weights for road segments B and C

相较于传统的基于拓扑结构的时空建模方法, 本文提出的自适应邻接矩阵与注意力机制的混合架构, 一方面能够通过自适应邻接矩阵的静态模块保证基础拓扑结构的稳定性, 另一方面基于注意力机制的动态组件能够增强模型对于交通流波动传播的适应性。通过静态与动态空间关系的协同学习, 模型在全局空间结构的基础上, 实现了对交通流动态交互的特征提取, 为交通流速度的准确预测提供了可靠的空间关联分析基础。

3 结论

本文提出了一种基于时空建模的多尺度动态图预测模型 MSTGCN, 在自适应邻接矩阵构建的静态拓扑连接的基础上, 引入空间注意力机制对动态时空依赖进行深入挖掘, 并结合多尺度膨胀卷积有效捕捉序列中的时间特征, 从而提升模型对复杂时空数据的建模能力。实验结果表明, 本文模型能够精准捕捉交通流速度变化的趋势, 并展现出良好的预测性能。主要结论如下:

1) 空间特征提取中, 在图卷积基础上采用自适应邻接矩阵学习的静态道路连接特征, 在考虑交通流特征的基础上能够准确识别路段间的拓扑关联关系, 在 15、30、60 min 中预测任务中使用自适应邻接矩阵的图卷积结构 RMSE 分别降低 0.05, 0.10, 0.12; 注意力机制能够有效表达交通数据中的动态空间关系和交通状态的时空演变规律, 捕捉交通流的方向性和动态性, 显著提升模型在中长期预测的性能, 在 60 min 预测中注意力机制实现了 RMSE 0.20 的降低; 同时基于精细化的门控机制设计, 结合静态图卷积与动态注意力机制两者的优势, 充分挖掘交通流的复杂时空依赖, 对比简单门控结构其预测误差 RMSE 在 15、30、60 min 预测任务中分别下降 0.03、0.08、0.18。

2) 多分支的膨胀卷积能够在浅层网络中捕捉关键的时间关联, 提升了模型的灵活性和稳定性。不同膨

胀率能够有效提取时间序列的不同特征,选取合适的膨胀率组合能够兼具局部特征与长期趋势的捕捉能力,从而实现短时和中长期预测的性能提升。本文选取的最佳膨胀率组合[1, 2]相比膨胀率为1的1D卷积,在15、30、60 min 预测任务中, RMSE 分别降低了0.23、0.38、0.62,这表明多尺度膨胀卷积在捕捉交通流时间特征的有效性,通过并行结构同时保留局部细节和全局趋势,尤其对长期预测的性能提升最为显著。

3) 对比最佳基准模型 Graph WaveNet, MSTGCN 模型的 RMSE、MAE、MAPE 指标平均相对降低了5.91%、7.51%、8.59%,验证了模型的有效性;60 min 预测任务中, MSTGCN 模型 RMSE、MAE 和 MAPE 指标对比 Graph WaveNet 相对降低了10.83%、12.67%和16.33%,突出其在长期预测中的优势。

本文主要聚焦于15、30、60 min 的预测任务,未来可进一步拓展至更长时间的预测,如3、6 h 的预测性能分析。此外,本文仅使用了基础的交通数据,当前模型虽能通过历史序列捕捉交通流的周期性规律,但真实的交通流速度极易受到外界因素的干扰,降雨等恶劣天气因素会改变驾驶行为如跟车间距和行车速度选择等,进而引发车流速度的短时波动,而大型活动或是节假日等因素可能导致交通流的剧烈变化,打破交通流速度的历史周期性规律。因此在后续工作中可考虑逐步引入外部因素,如天气特征、特殊交通事件等,以探究增强信息表达对模型预测性能的提升效果。

参考文献:

- [1] Wang S, Cao J, Philip S Y. Deep learning for spatio-temporal data mining: A survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 34(8): 3681-3700.
- [2] Smith B L, Demetsky M J. Traffic flow forecasting: comparison of modeling approaches[J]. Journal of Transportation Engineering, 1997, 123(4): 261-266.
- [3] 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.
- [4] Sun S, Zhang C, Yu G. A bayesian network approach to traffic flow forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(1): 124-132.
- [5] Wang J, Shi Q. Short-term traffic speed forecasting hybrid model based on chaos-wavelet analysis-support vector machine theory[J]. Transportation Research Part C: Emerging Technologies, 2013, 27: 219-232.
- [6] Li L, Qu X, Zhang J, et al. Traffic speed prediction for intelligent transportation system based on a deep feature fusion model[J]. Journal of Intelligent Transportation Systems, 2019, 23(6): 605-616.
- [7] Lingras P, Sharma S, Zhong M. Prediction of recreational travel using genetically designed regression and time-delay neural network models[J]. Transportation Research Record, 2002, 1805(1): 16-24.
- [8] Fan J, Zhang K, Huang Y, et al. Parallel spatio-temporal attention-based TCN for multivariate time series prediction[J]. Neural Computing and Applications, 2023, 35(18): 13109-13118.
- [9] Tian Y, Pan L. Predicting short-term traffic flow by long short-term memory recurrent neural network [C]//2015 IEEE International Conference on Smart City/SocialCom/SustainCom (SmartCity). IEEE Computer Society, 2015: 153-158.
- [10] Hussain B, Afzal M K, Ahmad S, et al. Intelligent traffic flow prediction using optimized GRU model[J]. IEEE Access, 2021, 9: 100736-100746.
- [11] Ke R, Li W, Cui Z, et al. Two-stream multi-channel convolutional neural network for multi-lane traffic speed prediction considering traffic volume impact[J]. Transportation Research Record, 2020, 2674(4): 459-470.324-328.
- [12] 王竟成, 张勇, 胡永利, 等. 基于图卷积网络的交通预测综述[J]. 北京工业大学学报, 2021, 47(8): 954-970.
WANG J, ZHANG Y, HU Y, et al. Survey on graph convolutional neural network-based traffic prediction[J]. Journal of Beijing University of Technology, 2021, 47(08): 954-970.
- [13] 陈华伟, 邵毅明, 敖谷昌, 等. 面向在线地图的 GCN-LSTM 神经网络速度预测[J]. 交通运输工程学报, 2021, 21(4): 183-196.
CHEN H W, SHAO Y M, AO G C, et al. Speed prediction by online map-based GCN-LSTM neural network[J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 183-196.
- [14] Zhao L, Song Y, 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.
- [15] Li Y, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting[C]//International

- Conference on Learning Representations. 2018.
- [16] Zhang Z, Li Y, Song H, et al. Multiple dynamic graph based traffic speed prediction method[J]. Neurocomputing, 2021, 461: 109-117.
- [17] Wang Y, Jing C, Xu S, et al. Attention based spatiotemporal graph attention networks for traffic flow forecasting[J]. Information Sciences, 2022, 607: 869-883.
- [18] Wang Z, Ding D, Liang X. TYRE: A dynamic graph model for traffic prediction[J]. Expert Systems with Applications, 2023, 215: 119311.
- [19] Zhang R, Sun F, Song Z, et al. Short - term traffic flow forecasting model based on GA - TCN[J]. Journal of Advanced Transportation, 2021, 2021(1): 1338607.
- [20] Akhtar M, Moridpour S. A review of traffic congestion prediction using artificial intelligence[J]. Journal of Advanced Transportation, 2021, 2021(1): 8878011.
- [21] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(4): 640-651.
- [22] 肖琳, 陈洪超, 邹复民. 基于多头注意力时空图神经网络的交通流预测[J]. 重庆交通大学学报(自然科学版), 2024, 43(09): 78-85.
XIAO L, CHEN H C, ZOU F M. Traffic flow prediction based on multi-head attention spatiotemporal graph neural network[J]. Journal of Chongqing Jiaotong University(Natural Science), 2024, 43(9): 78-85.
- [23] Zhang Z, Li Y, Song H, et al. Multiple dynamic graph based traffic speed prediction method[J]. Neurocomputing, 2021, 461: 109-117.
- [24] 崔建勋, 要甲, 赵泊媛. 基于深度学习的短期交通流预测方法综述[J]. 交通运输工程学报, 2024, 24(2): 50-64.
CUI J X, YAO J, ZHAO B Y. Review on short-term traffic flow prediction methods based on deep learning[J]. Journal of Traffic and Transportation Engineering, 2024, 24(2): 50-64.
- [25] 李晓晗, 刘石坚, 刘建华, 等. 基于多尺度和双源运动感知的车辆检测方法[J]. 华东交通大学学报, 2024, 41(4): 64-72.
LI X H, LIU S J, LIU J H, et al. Study on multi-scale feature and dual-source motion perception for vehicle detection[J]. Journal of East China Jiaotong University, 2024, 41(4): 64-72.
- [26] Yu B, Yin H, Zhu Z. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. International Joint Conferences on Artificial Intelligence Organization, 2018: 3634-3640.
- [27] Guo S, Lin Y, Feng N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//Proceedings of the AAAI conference on artificial intelligence. 2019, 33(01): 922-929.
- [28] Wu Z, Pan S, Long G, et al. Graph WaveNet for Deep Spatial-Temporal Graph Modeling[C]//28th International Joint Conference on Artificial Intelligence (IJCAI-19). International Joint Conference on Artificial Intelligence (IJCAI), 2019.
- [29] 许新征, 李杉. 基于特征膨胀卷积模块的轻量化技术研究[J]. 电子学报, 2023, 51(2): 355-364.
XU X Z, LI S. Research of Lightweight Convolution Neural Network Based on Feature Expansion Convolution[J]. Acta Electronica Sinica, 2023, 51(2): 355-364.



通信作者: 赵星(1986—), 女, 副教授, 硕士生导师, 研究方向为应急疏散交通管理。E-mail: zhaoxing@hhu.edu.cn。