

文章编号: 1005-0523(2026)03-00013-09



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预测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并深入挖掘复杂的动态时空关系, 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(MDSTCN)。首先, 在图卷积神经网络基础上, 构建自适应静态空间邻接矩阵, 并引入注意力机制捕捉交通流的方向性和动态交互, 以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变化趋势; 最后, 基于真实数据集完成模型训练与测试, 并设计多种对比实验。结果表明, 与最佳基线模型 Graph WaveNet 相比, MDSTCN 的 E_{RMS} , E_{MA} 和 E_{MAP} 均有所下降; 其在 15, 30 min 和 60 min 预测时间尺度上的误差波动幅度最小, 凸显了模型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; 动态图卷积网络; 多尺度膨胀卷积

中图分类号: U491

文献标志码: A

本文引用格式: 赵星, 陈娴. 基于多尺度动态时空卷积网络的交通流速度预测[J]. 华东交通大学学报, 2026, 43(3): 13-21.

Traffic Speed Prediction Based on a 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 traffic speed prediction accuracy and capture complex dynamic spatio-temporal dependencies in traffic data, this study proposes a traffic speed prediction model based on a multi-scale dynamic spatio-temporal convolutional network (MDSTCN). First, an adaptive static spatial adjacency matrix is constructed based on graph convolutional network (GCN), and an attention mechanism is introduced to capture the directional dependencies and dynamic interactions of traffic flow, thereby uncovering intricate dynamic spatial relationships. Second, a multi-scale dilated convolution structure is adopted to extract local temporal features and long-term variation trends. Finally, the model is trained and tested on a real-world dataset, and various comparative experiments are conducted. The results show that, compared with the best baseline model (Graph WaveNet) the proposed MDSTCN achieves lower E_{RMS} , E_{MA} , and E_{MAP} . Furthermore, the fluctuation range of prediction errors across the 15, 30 min, and 60 min horizons are the smallest, highlighting its good adaptability and stability in long-term prediction tasks.

Key words: traffic speed prediction; dynamic graph convolutional network; multi-scale dilated convolution

Citation format: ZHAO X, CHEN X. Traffic speed prediction based on a multi-scale dynamic spatio-temporal

收稿日期: 2025-05-15

基金项目: 江苏省自然科学基金项目(BK20211203)

convolutional network[J]. Journal of East China Jiaotong University, 2026, 43(3): 13-21.

交通流速度作为反映城市交通状况的关键指标,其预测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维度上呈现出动态变化和不稳定性^[1],交通状态预测精度既受历史数据、节假日等时间维度因素的影响,也受地理位置、交通设施条件、路段拥堵传播等空间维度因素的制约。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。

早期基于统计理论和机器学习的预测方法(如HA、ARIMA、SVM、KNN等),在捕捉非线性突变特征和处理海量数据方面存在局限性^[2-5]。近年来,深度学习模型在交通流速度预测领域取得了显著进展。循环神经网络(RNN)及其变体长短期记忆网络(LSTM)和门控循环单元(GRU)通过记忆和门控机制能够学习较长时间跨度的时序特征^[6-9],有效捕捉时变规律。然而,传统RNN架构具有序列依赖性,计算效率低。时间卷积网络(TCN)使用因果卷积通过多层膨胀卷积扩大感受野,实现时间维度的高效并行处理^[10-11]。但为覆盖时间序列,TCN需堆叠形成深层网络,大幅增加了模型复杂性与训练难度。

为了充分挖掘交通流数据中的空间信息,学者们引入卷积神经网络(CNN)和图神经网络(GNN)等图处理方法^[12]。相比于CNN网格化处理交通网络的方式,GNN在非欧式空间数据上进行卷积操作,更适用于复杂交通网络拓扑结构。通过混合架构堆叠空间模块和时间模块,GCN-LSTM、T-GCN等混合模型实现了时空特征的渐进提取^[13-15],但在捕捉路段数据的动态时空依赖关系方面仍面临挑战。

对于图结构而言,预定义的图结构仅基于路段的连接情况构建,忽略了道路特征、兴趣点分布、交通转向控制等隐含因素影响,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^[16]通过图结构上的随机游走捕获交通数据的空间关联性,ETGCN^[17]利用注意力机制融合多种图结构,GAT^[18]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,忽略了不同节点关联性随时间的动态变化——尤其交通流速度因交通事件剧烈波动时,路段相关性可能发生显著改变^[19]。即使是自适应邻接矩阵,若在不同时间窗内保持不变,也无法捕捉图结构在时间维度上的动态变化。

针对上述不足,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(MDSTCN)。在预定义邻接矩阵的基础上,通过节点嵌入生成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,为实现不同空间特征信息的有效融合,设计了精细化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,提出多尺度时间卷积方法,通过调整膨胀率灵活学习不同尺度的时间特征,挖掘时间序列中的全局与局部特征关系。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时空特征的有效性。

1 交通流速度预测模型构建

本文提出的MDSTCN模型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。模型主体由两个时空卷积层堆叠而成,采用残差连接方式保留原始输入特征,避免网络信息衰减。每个时空卷积层由静态空间特征融合模块和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GCN提取静态空间特征,注意力机制用于响应交通流空间关系的动态变化,并通过门控机制融合静态与动态空间特征。多尺度时间卷积模块采用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。

1.1 问题描述

本文将交通流速度预测问题定义为: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 $X=[X_{t-T_h+1}, X_{t-T_h+2}, \dots, X_t]$, $X \in \mathbf{R}^{T_h \times N \times F}$, 以及路网图结构 $G=(V, E, A)$, $A \in \mathbf{R}^{N \times N}$, 预测未来 T_p 个时间的交通流速度 $\hat{V}=[\hat{V}_{t+1}, \hat{V}_{t+2}, \dots, \hat{V}_{t+T_p}]$, $\hat{V} \in \mathbf{R}^{T_p \times N}$ 。模型表达式如下

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

式中: f 为预测模型; t 时间交通流数据 $X_t=[X_t(1), X_t(2), \dots, X_t(N)]$ 储存路段历史交通流数据特征, $X_t \in \mathbf{R}^{N \times F}$; 本研究只考虑历史交通流速度, 即特征维度 $F=1$; 未来 t' 时间的交通流速度 $\hat{V}_{t'}=[\hat{V}_{t'}(1), \hat{V}_{t'}(2), \dots, \hat{V}_{t'}(N)]$; $G=(V, E, A)$ 储存图结构信息, V 为路段, E 为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 静态动态空间特征融合模块

为刻画交通流的空间关联性, 本文在图卷积基础上, 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, 利用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; 最后设计精细化门控结构, 依据当前状态自适应分配门控权重以融合静态与动态空间特征, 使图卷积的稳定性与注意力机制的灵活性互为补充。

1.2.1 静态自适应图卷积

交通网络作为典型的图拓扑结构, GNN 能利用图表示处理非欧氏空间数据, 通过聚合邻居节点特征以更新当前节点特征表示, 实现节点间信息传递。

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。节点特征矩阵根据式(2)更新

$$\begin{aligned} H^{(l+1)} &= f(H^{(l)}, A) \\ &= \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}) \end{aligned} \quad (2)$$

式中: $H^{(l)}$ 为第 l 层的特征矩阵; $\hat{A}$ 为带自环的邻接矩阵; $W^{(l)}$ 为第 l 层的权重矩阵; σ 为激活函数; $\hat{D}$ 为邻接矩阵 $\hat{A}$ 的度矩阵。

交通系统中的空间依赖具有动态性和方向

性。DCRNN 模型使用扩散卷积层, 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。此外, 由于数据的不充分性和交通网络的隐式依赖, 预定义图结构无法精准呈现路段的关联关系^[20]。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遗漏或错误连接造成的信息损失。表达式为

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

式中: H_G 为扩散卷积后得到的特征矩阵; $P_f^{(k)}$, $P_b^{(k)}$ 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, $A \in \mathbf{R}^{N \times N}$, $\tilde{A}_{apt}^{(k)}$ 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参数 E_1 , E_2 生成, $E_1, E_2 \in \mathbf{R}^{N \times d_{emb}}$, d_{emb} 为节点嵌入维度, a_{ij} 为源节点 i 和目标节点 j 的连接权重。交通数据中的空间依赖关系具有方向性, 通过 $E_1 E_2^T - E_2 E_1^T$ 捕捉非对称方向的依赖关系。表达式为

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

式中: E_1 , E_2 分别为将路段映射为源节点和目标节点的特征嵌入矩阵; $\text{ReLU}(\cdot)$ 消除弱连接并保证邻接矩阵非负; $\text{Softmax}(\cdot)$ 对自适应邻接矩阵进行归一化元素处理; 加入以单位矩阵 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

注意力机制能够动态捕捉节点间的相关性, 并可根据输入数据的变化实时调整权重。为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。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。由此, 模型能够实时响应交通网络中的动态变化, 提高预测的准确性和鲁棒性。通过不同权重矩阵, 输入特征矩阵 X 被映射到高维潜在子空间, 得到查询矩阵 $Q^{(s)}$, 键矩阵 $K^{(s)}$, 值矩阵 $V^{(s)}$ 。表达式为

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

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

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

式中: $Q^{(s)}$, $K^{(s)}$, $V^{(s)} \in \mathbf{R}^{T_h \times N \times F}$; $W_q^{(s)}$, $W_k^{(s)}$, $W_v^{(s)}$ 均

为可学习的投影矩阵; $\mathbf{W}_q^{(s)}$, $\mathbf{W}_k^{(s)}$, $\mathbf{W}_v^{(s)} \in \mathbf{R}^{F \times F}$ 。

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。

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

$$\mathbf{H}_{\text{attn}} = \mathbf{A}^{(s)} \mathbf{V}^{(s)} \quad (9)$$

式中: $\mathbf{A}^{(s)} \in \mathbf{R}^{N \times N}$ 为注意力权重矩阵,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; $d^{(s)}$ 为查询矩阵 $\mathbf{Q}^{(s)}$ 最后一维的特征维度。最后将每个节点特征动态更新为全局节点的加权组合 $\mathbf{H}_{\text{attn}} \in \mathbf{R}^{T_h \times N \times F}$ 。

1.2.3 门控特征融合策略

简单门控机制难以适应复杂路网场景,因此本文设计了精细化门控机制。该机制通过动态调整融合权重,能够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。门控权重 $\mathbf{Z}$ 能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)。表达式为

$$\mathbf{Z} = \sigma(\mathbf{W}_z[\mathbf{H}_{\text{attn}}, \mathbf{H}_G] + \mathbf{b}_z) \quad (10)$$

$$\mathbf{H}_{\text{fuse}} = \mathbf{Z} \odot \mathbf{H}_{\text{attn}} + (1 - \mathbf{Z}) \odot \mathbf{H}_G + \mathbf{X}_{\text{res}} \quad (11)$$

式中:通过拼接空间注意力的输出 $\mathbf{H}_{\text{attn}}$ 和图卷积的结果 $\mathbf{H}_G$,捕捉两个模块输出的交互关系;并通过可训练权重矩阵 $\mathbf{W}_z$ 和偏置向量 $\mathbf{b}_z$ 独立为每个特征维度分配权重,使用 Sigmoid 将门控权重 $\mathbf{Z} \in \mathbf{R}^{T_h \times N \times F}$ 映射到 $[0, 1]$,得到最后的融合特征 $\mathbf{H}_{\text{fuse}}$; $\odot$ 表示逐元素相乘; $\mathbf{X}_{\text{res}}$ 为跳跃连接保留的原始输入特征。

最后,对融合后的特征进行归一化和非线性处理,得到最终的空间特征矩阵 $\mathbf{H}_{\text{out}}$,进一步提升特征质量和模型性能

$$\mathbf{H}_{\text{out}} = \text{LayerNorm}(\text{ReLU}(\mathbf{H}_{\text{fuse}})) \quad (12)$$

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,因果卷积各时间步的输出相对独立,可实现并行计算,相较于 RNN 的循环结

构能够显著提升效率。膨胀卷积在卷积核中插入间隔以扩大感受野,能更好地捕捉上下文信息。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 $\mathbf{X} = [\mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_{T_h}]$,给定宽度为 M 的卷积核 $\mathbf{K}_{\text{conv}} = [k_1, k_2, \dots, k_M]$ 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。表达式为

$$\mathbf{h}'_t = (\mathbf{K}_{\text{conv}} *_{d} \mathbf{X})_t = \sum_{m=0}^{M-1} k_m \mathbf{X}_{t-m \times d} \quad (13)$$

式中: $\mathbf{K}_{\text{conv}} *_{d} \mathbf{X}$ 代表膨胀率为 d 的膨胀卷积积; $\mathbf{h}'_t$ 是卷积后 t 时间步的输出特征; k_m 是卷积核 $\mathbf{K}_{\text{conv}}$ 在位置 m 的权重; $\mathbf{X}_{t-m \times d}$ 是第 $t-m \times d$ 个时间步的输入特征。

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,同时降低网络深度,提高运行效率。

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

$$\mathbf{h}^{(i)} = \mathbf{K} *_{d_i} \mathbf{X} \quad (14)$$

$$\mathbf{H}_T = \text{Concat}(\mathbf{w}_i \cdot \mathbf{h}^{(i)} | i = 1, 2, \dots, n) \quad (15)$$

式中: $\mathbf{h}^{(i)} \in \mathbf{R}^{T_h \times N \times C_{\text{out}}}$ 为膨胀率 d_i 膨胀卷积输出,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, $C_{\text{out}} = F/n$; $\mathbf{w}_i \in \mathbf{R}$ 是可学习参数,为第 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;将不同卷积分支的输出拼接形成多尺度时间特征矩阵 $\mathbf{H}_T \in \mathbf{R}^{T_h \times N \times F}$ 。

2 实验与结果分析

2.1 数据概况与特征分析

2.1.1 数据集

本文采用高德地图南京市内环快速路的真实交通数据集。数据集采集时间为 2022 年 7 月 1 日至 2022 年 12 月 31 日,采样间隔为 5 min,涵盖 73 条路段,共 3 868 416 条数据。实验使用滑动窗口法构建

输入序列与标签。

2.1.2 交通流速度时空特性分析

为了剖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)路网交通流速度变化规律进行分析。随着时间推移,内环西线的初始局部拥堵扰动引发了速度波动的向外传播。基于此演变规律,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、波动传播到局部状态恢复的过程。

进一步分析交通流速度传播的时间延迟现象,以直线距离约为2 km的相邻路段B和C为例,高峰时段的预估通行时间约为13 min,对比两路段在高峰时段的速度变化情况,如图1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滞后约15 min。该时滞与两路段的通行时间相吻合,验证了交通流状态变化的时滞性,也凸显了MDSTCN模型刻画速度波动时延特征的准确性。




图1 相邻路段的拥堵传播时间滞后现象

Fig. 1 Spatio-temporal lag phenomenon in congestion propagation between adjacent road segments

2.2 对比实验

本文选取 LSTM、T-GCN、DCRNN、STGCN、ASTGCN 和 Graph WaveNet 等主流基线模型进行对比验证。

使用平均绝对误差(MAE, E_{MA})、均方根误差(RMSE, E_{RMS})和平均绝对百分比误差(MAPE, E_{MAP})作为评价指标,综合评估预测模型性能,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。表达式为

$$E_{MA} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (16)$$

$$E_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (17)$$

$$E_{MAP} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (18)$$

式中: 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 实验结果分析

各模型在短时(15 min)、中期(30 min)及长期(60 min)时间尺度下的预测性能,测试集的预测结果如表1及图2所示。本文提出的MDSTCN模型在各时间尺度下均取得了最佳预测性能,尤其在长期预测任务中优势显著。

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,其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,分别通过图卷积网络(GCN)和扩散卷积捕捉空间结构信息,显著提高了短时预测性能。

2) 动态图建模的有效性:ASTGCN与本文的MDSTCN在长期预测任务中优势突出。相比

表1 不同模型预测性能对比

Tab.1 Comparison of prediction performance among different models

模型	E_{RMS}			E_{MA}			$E_{MAP} / \%$		
	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
MDSTCN	4.69	5.11	5.69	3.06	3.28	3.66	7.45	8.20	9.21




图2 各模型随预测时间尺度增加的性能变化趋势

Fig. 2 Trends in the prediction performance of different models with increasing prediction horizons

Graph WaveNet的自适应邻接矩阵,MDSTCN各项误差指标均有所降低,表明节点嵌入自适应图结构与注意力机制相结合,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在中长期预测中的表现差,在60 min预测中,STGCN的 E_{RMS} 指标甚至比LSTM高出0.17。MDSTCN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,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 E_{RMS} 、 E_{MA} 、 E_{MAP} 指标相比Graph WaveNet均有所降低。此外,在15,30,60 min预测任务中,本文模型也凸显了其在捕捉中长期速度变化趋势方面的优势。

为进一步评估不同模型在各时间步上的预测性能,本文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与真实值的对比如图3所示。随着预测步长的增加,ASTGCN和DCRNN模型预测的速度值出现了明显的滞后现象。相比之下,本文提出的模型能够更好地对动态时空变化和长期时间依赖关系进行建模,显著提升交通流速度预测精度。

2.4 消融实验

为系统评估MDSTCN各组件的贡献度,本文设计了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(将动态门控机制替换为简单门控机制),以及MDSTCN-space(将空间特征提取模块替换为线性

卷积)。实验结果如表2所示。

1) 空间特征的必要性。在60 min预测任务中,MDSTCN-space模型的 E_{RMS} 较基准模型MDSTCN上升了0.98。证实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) 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 E_{RMS} 甚至略低于MDSTCN模型,说明注意力机制在短时预测中可能无法提升模型效果,反而会因模型结构复杂而增加过拟合风险。然而,注意力机制能够显著提升模型的长期预测性能。这表明动态空间特征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领域的主流研究结论相吻合。

3) 特征融合的耦合重要性。采用简化门控机制的MDSTCN-gate模型,其预测性能较基准模型明显下降。这表明,在空间特征捕捉过程中,需要重点关注图卷积与注意力机制结果之间的耦合关系。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各自的优势,更充分地挖掘空间特征。

2.5 模型空间特征提取结果分析

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,本文以路段C为例,分析其邻接路段相关系数与交通流速度变化的关系,如图4所示。路段C与路段B的相关系数为0.66,表明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




图3 ASTGCN,DCRNN,Graph WaveNet和MDSTCN 单日交通流速度预测可视化

Fig. 3 Visualization of one-day traffic speed prediction obtained by ASTGCN,DCRNN,Graph WaveNet and MDSTCN

表2 MDSTCN消融实验结果

Tab.2 Ablation study results of MDSTCN

模型	E_{RMS}			E_{MA}			$E_{MAP}/\%$		
	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

系,但由于其交通流速度呈现显著差异,导致动态相关系数仅为0.10。这表明,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特征实现了静态空间关系的重构。

在基于注意力机制的动态空间建模方面,选取路段B、C进行实证分析。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。晚高峰期间,

路段C对路段B的反向权重高达0.80,而正向权重仅为0.01。该现象与交通波传播理论相吻合,验证了MDSTCN模型对交通流波动传播方向性的有效捕捉。进一步分析发现,当两路段的速度曲线变化趋势接近时,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。




图4 路段C及其邻接路段交通流速度时间演变分析

Fig. 4 Dynamic correlation analysis of traffic flow speed for road segment C and its adjoining segments

3 结论

1) 在空间特征提取中,基于图卷积并采用自适应邻接矩阵学习静态道路连接特征,能够准确识别路段间的拓扑关联关系;在长期预测任务中,采用自适应邻接矩阵的图卷积结构的 E_{RMS} 均有所降低。注意力机制能够有效表征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中的性能;在60 min预测中,注意力机制使 E_{RMS} 降低0.20。同时,基于精细化门控机制设计,结合静态图卷积与动态注意力机制的优势,能够充分挖掘交通流的复杂时空依赖;与简单门控结构相比,其预测误差 E_{RMS} 在15,30,60 min预测任务中均有所下降。

2) 多分支膨胀卷积能够在浅层网络中捕捉关键的时间关联,提升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性能的提升。

3) 与最佳基准模型Graph WaveNet相比,MDSTCN模型的 E_{RMS} 、 E_{MA} 、 E_{MAP} 均有所降低,验证了模型的有效性;在60 min预测任务中,MDSTCN模型的 E_{RMS} 、 E_{MA} 、 E_{MAP} 较Graph WaveNet明显降低,突出了其在长期预测中的优势。

参考文献:

[1] WANG S Z, CAO J N, YU P S. 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 L, ZHANG C S, YU G Q. A Bayesian network approach to traffic flow forecasting[J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(1): 124-132.
[5] LI L C, 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.
[6] LINGRAS P, SHARMA S, ZHONG M. Prediction of recreational travel using genetically designed regression and time-delay neural network models[J]. Transportation Research Record: Journal of the Transportation Research Board, 2002, 1805(1): 16-24.
[7] FAN J, ZHANG K, HUANG Y P, et al. Parallel spatio-temporal attention-based TCN for multivariate time series prediction[J]. Neural Computing and Applications, 2023, 35(18): 13109-13118.
[8] MA C X, DAI G W, ZHOU J B. Short-term traffic flow prediction for urban road sections based on time series analysis and LSTM-BiLSTM method[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(6): 5615-5624.
[9] HUSSAIN B, AFZAL M K, AHMAD S, et al. Intelligent traffic flow prediction using optimized GRU model[J]. IEEE Access, 2021, 9: 100736-100746.
[10] ZHANG R J, SUN F, SONG Z W, et al. Short-term traffic flow forecasting model based on GA-TCN[J]. Journal of Advanced Transportation, 2021, 2021(1): 1338607.
[11] AKHTAR M, MORIDPOUR S. A review of traffic congestion prediction using artificial intelligence[J]. Journal of Advanced Transportation, 2021, 2021(1): 8878011.
[12] KE R M, LI W, CUI Z Y, et al. Two-stream multi-channel convolutional neural network for multi-lane traffic speed prediction considering traffic volume impact[J]. Transportation Research Record: Journal of the Transportation Research Board, 2020, 2674(4): 459-470.
[13] 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 C, ZHANG Y, HU Y L, et al. Survey on graph convolutional neural network-based traffic prediction[J]. Journal of Beijing University of Technology, 2021, 47(8):

- 954-970.
- [14] 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.
- [15] ZHAO L, SONG Y J, ZHANG C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.
- [16] MALLICK T, BALAPRAKASH P, RASK E, et al. Graph-partitioning-based diffusion convolutional recurrent neural network for large-scale traffic forecasting[J]. Transportation Research Record: Journal of the Transportation Research Board, 2020, 2674(9): 473-488.
- [17] ZHANG Z K, LI Y D, SONG H F, et al. Multiple dynamic graph based traffic speed prediction method[J]. Neurocomputing, 2021, 461: 109-117.
- [18] WANG Y, JING C F, XU S S, et al. Attention-based spatiotemporal graph attention networks for traffic flow forecasting[J]. Information Sciences, 2022, 607: 869-883.
- [19] WANG Z H, DING D, LIANG X. TYRE: a dynamic graph model for traffic prediction[J]. Expert Systems with Applications, 2023, 215: 119311.
- [20] 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(9): 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.



通信作者:赵星(1986—),女,副教授,博士,硕士生导师,研究方向为交通控制与管理。E-mail:zhaoxing@hhu.edu.cn。

(责任编辑:熊玲玲)