

基于时序注意力与交互动态图卷积的交通流预测^①



姚佳禹, 徐文进, 杨洪宁, 杜珍珍

(青岛科技大学 信息科学技术学院, 青岛 266061)
通信作者: 徐文进, E-mail: 15954263549@163.com

摘要: 交通流预测是智能交通管理和缓解拥堵的重要任务. 传统预测方法主要依赖统计方法, 难以捕捉交通流中复杂的时空相关性. 近年来, 图神经网络 (GNN) 作为一种强有力的工具, 在建模和预测交通流方面取得了显著进展. 然而, 现有的基于 GNN 的方法在捕捉交通流的动态时空相关性及其隐性交互关系上存在一定的局限性, 影响了模型的预测精度. 本文提出了一种基于时序注意力和交互动态图卷积网络 (TAIDGCN) 的方法, 通过时序注意力层 (TAL) 和扩张时序卷积层 (DTCN) 捕捉动态时间相关性, 采用交互式动态图卷积网络 (IDGCN) 捕捉空间相关性, 并结合多组分结构进一步提升模型的时空建模能力. 具体来说, TAL 和 DTCN 在时间维度上提取近期、日周期和周周期的时间特征, 改善了中期和长期的时空预测能力, 而 IDGCN 通过交互学习机制捕捉交通流中的动态空间关系. 在两个真实世界的开放高速公路数据集上对模型进行验证, 结果表明, 所提 TAIDGCN 模型能够有效提取动态时空信息, 且预测精度超过当前 10 个基准模型, 证明了该方法在交通流预测任务中的优越性和应用潜力.

关键词: 交通流量预测; 智能交通系统; 时空相关性; 注意力机制; 图神经网络

引用格式: 姚佳禹, 徐文进, 杨洪宁, 杜珍珍. 基于时序注意力与交互动态图卷积的交通流预测. 计算机系统应用, 2025, 34(9): 141-150. <http://www.c-s-a.org.cn/1003-3254/9956.html>

Traffic Flow Prediction Based on Temporal Attention and Interactive Dynamic Graph Convolution

YAO Jia-Yu, XU Wen-Jin, YANG Hong-Ning, DU Zhen-Zhen

(College of Information Science and Technology, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract: Traffic flow prediction is an important task for intelligent transportation systems and congestion mitigation. Traditional methods mainly rely on statistical approaches, which fail to capture the complex spatiotemporal correlations within traffic flow. In recent years, graph neural networks (GNN) have shown remarkable performance in modeling and predicting traffic flow. However, existing GNN-based methods face limitations in capturing the dynamic spatiotemporal dependencies and latent interactive relationships, which hinders prediction accuracy. To address this issue, a novel method named temporal attention and interactive dynamic graph convolutional network (TAIDGCN) is proposed. Dynamic temporal dependencies are captured using a temporal attention layer (TAL) and a dilated temporal convolution layer (DTCN), while spatial dependencies are modeled through an interactive dynamic graph convolution network (IDGCN). A multi-component structure is further integrated to enhance the overall spatiotemporal modeling capability. Specifically, TAL and DTCN extract temporal features from recent patterns, daily cycles, and weekly cycles, thus improving mid- and long-term spatiotemporal prediction accuracy. Meanwhile, IDGCN leverages an interactive learning mechanism to capture dynamic spatial relationships in traffic flow. The proposed model is validated on two real-world open highway datasets. Experimental results demonstrate that TAIDGCN effectively captures dynamic spatiotemporal information and

① 收稿时间: 2025-02-12; 修改时间: 2025-03-14; 采用时间: 2025-03-31; csa 在线出版时间: 2025-07-25
CNKI 网络首发时间: 2025-07-28

outperforms ten benchmark models in prediction accuracy, highlighting its superiority and potential for traffic flow prediction applications.

Key words: traffic flow prediction; intelligent transportation system (ITS); spatiotemporal correlation; attention mechanism; graph neural network (GNN)

随着全球城市化加速,城市人口和机动车数量激增导致交通流量大幅增加,带来了交通拥堵、事故频发和环境污染等问题,严重影响出行体验,并造成巨大的经济损失^[1].为应对这些挑战,许多城市积极建设智能交通系统(ITS),其中交通流量预测作为核心功能之一,可以提供实时流量数据和趋势预测,优化交通管理,如信号灯调度、动态诱导和应急响应^[2].精准的预测还支持共享出行、智能导航和自动驾驶等技术的发展,帮助管理部门缓解交通压力并提升出行体验^[3].

现有的交通流量预测方法主要分为传统统计模型、机器学习方法和深度学习方法.传统统计模型如ARIMA^[4]依赖时间序列的线性特征,难以处理非线性数据.LSTM^[5]可以捕捉长期时间依赖性,但空间特征建模不足.CNN^[6]擅长提取空间特征,但难以建模复杂交通网络.GCN^[7]捕捉节点关系,但对动态时间变化处理有限.时空图卷积网络(STGCN)^[8]和图注意力网络(GAT)^[9]结合了时间、空间建模和注意力机制,但往往无法充分利用交通流中的动态时空相关性及隐性交互关系,导致在长时间跨度或实时预测中表现不佳.

为了解决这些问题,本文提出了一种基于时序注意力和交互动态图卷积网络(TAIDGCN)的交通流预测方法.该方法通过集成时序注意力机制和动态图卷积来捕捉交通流中的时空依赖关系.具体而言,时序注意力层(TAL)和扩张时序卷积网络(DTCN)用于捕捉动态时间相关性,而交互式动态图卷积网络(IDGCN)用于建模空间相关性.通过这几个组件的结合,模型能够关注近期、日周期和周周期的交通流模式,从而改善中期和长期的预测能力.

TAIDGCN模型采用了多组分结构,使其能够学习不同的时序模式,如近期交通趋势、日常周期和周周期.这种结构帮助模型更好地捕捉动态交通模式.此外, IDGCN中的交互学习机制增强了模型在捕捉路段间动态空间关系方面的能力,这对交通流预测至关重要.

本文在两个真实世界的开放高速公路数据集上对所提TAIDGCN模型进行评估.结果表明,TAIDGCN

模型优于10个现有的基准模型,证明了该方法能够有效提取动态时空信息,并具有较强的实际应用潜力.

本文的主要贡献如下.

(1) 提出TAIDGCN模型,用于捕捉交通流预测中的动态时空相关性.

(2) 引入了时序注意力层(TAL)和扩张时序卷积网络(DTCN)来增强时间预测能力,同时使用交互式动态图卷积网络(IDGCN)来建模空间关系.

(3) 在真实世界数据集上的广泛实验表明,所提模型优于现有方法,具有更高的预测精度.

1 相关工作

1.1 传统方法和统计模型

交通流量预测的相关工作可以大致分为传统方法和基于深度学习的方法.早期研究多集中在统计模型和传统机器学习模型上,这些方法通常基于线性假设,并依赖于手工设计的特征.例如,历史平均(HA)方法通过计算历史数据的平均值来预测交通流量,虽然简单但在应对复杂交通变化时表现有限.ARIMA模型是时间序列分析中常用的统计方法,通过自回归和移动平均机制来建模交通流.然而,这类方法通常假设时间序列是平稳的,难以捕捉交通流中的非线性变化和复杂时空依赖.此外,卡尔曼滤波和支持向量回归(SVR)^[10]也被应用于交通流量预测,但它们同样难以处理大规模和复杂的时空数据,尤其是在存在非线性和动态变化的情况下.

1.2 基于深度学习的方法

随着数据规模的增大和计算能力的提升,深度学习逐渐成为交通流预测的主流方法.循环神经网络(RNN)及其变体,如长短期记忆网络(LSTM)和门控循环单元(GRU)^[11],被广泛用于处理时间序列数据,尤其适合捕捉长期依赖关系.LSTM通过引入记忆门机制,解决了标准RNN在长时间依赖上的梯度消失问题,因此在处理交通流量的时序依赖性时表现良好.相比之下,GRU的结构更为简单,计算开销更低,因此在

实时交通流量预测中具有优势. 然而, RNN 和 LSTM 等模型往往只能处理时间维度上的依赖关系, 无法充分建模交通网络中节点之间的空间依赖.

为了更好地捕捉交通网络中的空间关系, 卷积神经网络 (CNN) 被引入用于提取交通数据中的空间特征. 时序卷积网络 (TCN)^[12]通过在时间维度上进行卷积操作代替传统的递归结构, 极大地提高了计算效率. 然而, TCN 在处理空间依赖时存在局限, 因此在应对交通流预测时并不理想. 为了解决这一问题, 时空卷积网络 (STGCN)^[8]结合了图卷积网络 (GCN) 和时序卷积网络, 能够同时建模交通网络中的空间和时间依赖. GCN 主要处理交通网络中的非欧几里得空间结构, 而时序卷积网络则专注于时间维度的特征提取, 二者结合能够更全面地捕捉交通流的时空特征^[13].

1.3 基于图神经网络的交通流预测方法

除了 STGCN, 基于图神经网络 (GNN) 的其他模型也被广泛应用于交通流预测中. 例如, 扩散卷积递归神经网络 (DCRNN)^[14]通过将交通网络建模为有向图, 利用扩散过程模拟节点间的信息传播, 再结合 GRU 进行时序特征提取. 这种方法能够捕捉交通流中的复杂空间依赖, 并处理时序数据. 此外, 图波网络 (Graph WaveNet)^[15]也是一种重要的 GNN 变体, 它通过将图卷积与扩散卷积结合, 用于建模动态图结构, 并能有效应对非线性交通流模式.

自注意力机制在交通流预测中也取得了重要进展. 例如, ASTGCN^[16]引入了自适应的时空注意力机制, 可以动态调整不同时间步和空间节点的权重, 从而更灵活地建模复杂的交通模式. GMAN^[17]进一步利用了多头注意力机制, 在图卷积网络的基础上引入时空注意力模块, 显著提升了交通流预测的准确性和鲁棒性.

1.4 多图卷积网络 (MGCN) 及外部因素的应用

多图卷积网络 (MGCN)^[18]通过从不同尺度提取空间特征, 有效提升了交通流预测模型的表现. MGCN 能够在多个图结构上进行卷积操作, 从而捕捉交通网络中不同尺度的依赖关系. 这类模型尤其适用于复杂路网环境下的交通预测.

近年来, 研究人员关注外部因素 (如天气、节假日、突发事件等) 对交通流预测的影响. 例如, ST-MetaNet^[3]通过自适应融合外部因素提高预测精度. 这些方法依赖额外数据, 存在采集成本高、适用性受限的问题. 此外, 外部因素的动态变化较难建模, 影响预测稳定性.

因此, 部分研究选择仅依赖交通流自身的时空模式, 利用图卷积网络、注意力机制等方法提升预测性能, 从而避免对外部数据的依赖, 在多个数据集上表现良好.

针对当前研究的不足, 本文提出了 TAIDGCN 模型, 具体模型设计将在第 2 节进行介绍.

2 时序注意力和交互动态图卷积网络

本文提出的 TAIDGCN 模型通过结合时序注意力层 (TAL)、扩张时序卷积层 (DTCN) 和交互式动态图卷积网络 (IDGCN) 来捕捉交通流量的时空依赖性. 模型分为 3 个独立的分支, 分别建模近期、每日和每周周期的时空特征. 在每个分支中, TAL 首先提取时间特征; DTCN 进一步捕捉时间相关性; IDGCN 则建模空间依赖性和节点间的动态交互关系. 最后, 通过融合操作融合各分支的特征, 生成最终的预测结果. 图 1 展示了模型的整体架构.

2.1 问题定义

在本文中, 交通流量预测任务被视作一种时间序列预测问题, 其目标是利用交通网络的结构信息和历史观测数据来预测未来的交通流量. 具体来说, 交通网络可以表示为一个图 $G = (V, E, A)$. 其中, V 表示节点集合, 即监测节点或传感器的位置集合; E 表示边的集合, 描述节点之间的连接关系; $A \in \mathbb{R}^{N \times N}$ 为邻接矩阵, 包含节点之间的连接权重或距离信息.

在 T 时刻, 每个监测节点会生成一个特征值向量, 因此整个网络的观测数据可以表示为图信号矩阵. $X_G \in \mathbb{R}^{N \times F}$. 其中, N 是节点数量, F 是特征维度. 假设有 i 个历史时间间隔, 每个时间 T 有一个特征矩阵 X_T , 组成历史序列 $H = \{X_{T-i+1}, X_{T-i+2}, \dots, X_T\}$. 基于此历史数据序列, 目标是预测未来 T' 个时间步的交通流量, 即未来序列 $P = \{X_{T+1}, X_{T+2}, \dots, X_{T+T'}\}$. 总之, 这个问题可以形式化为一个映射关系:

$$f: \{X_{T-i+1}, X_{T-i+2}, \dots, X_T\} \rightarrow \{X_{T+1}, X_{T+2}, \dots, X_{T+T'}\} \quad (1)$$

其中, f 是从历史交通流量数据到未来流量数据的预测函数.

2.2 多组件结构

在本文的多组件结构中, 为了捕获不同时间周期的交通流量变化特征, 我们将输入数据划分为近期、每日和每周这 3 个时间尺度, 每个时间尺度分别代表

不同时间模式. 假设 T_0 、 T_p 和 q 分别表示当前时间、预测窗口大小和每天的样本数量, T_h 、 T_d 和 T_w 分别作

为最近, 每日和每周的时间分量输入, 这3个时间模式表示如下^[16].

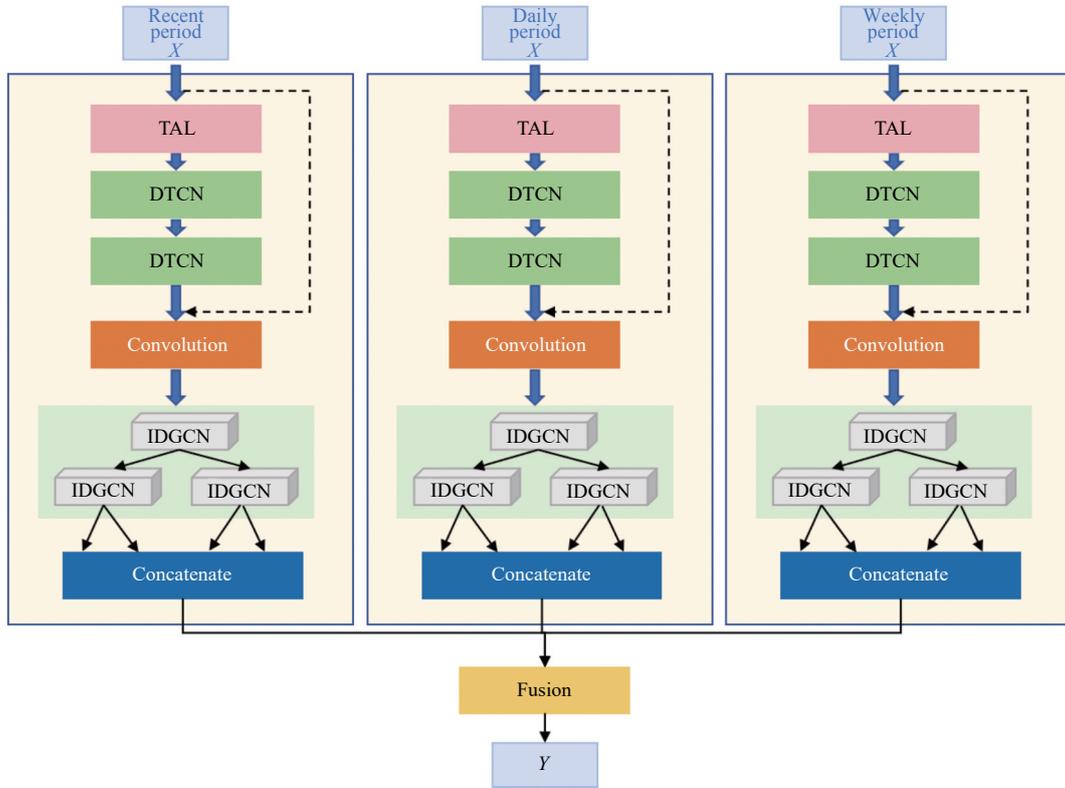


图1 TAIDGCN 的总体架构

(1) 近期周期: 该周期表示靠近预测时间点的历史数据, 用 $X_h = (X_{T_0-T_h+1}, X_{T_0-T_h+2}, \dots, X_{T_0}) \in \mathbb{R}^{N \times F \times T_h}$ 表示. 因为交通流量在短时间内的波动往往具有先兆性, 因此近期数据段对预测具有重要作用.

(2) 每日周期: 该周期表示前一天与预测时间相同时段的数据, 用 $X_d = (X_{T_0-q+1}, X_{T_0-q+2}, \dots, X_{T_0-q+T_p}) \in \mathbb{R}^{N \times F \times T_d}$ 表示. 由于交通流量每天在某些时间段 (如早高峰和晚高峰) 具有类似的模式, 选择前一天的同一时间段可以帮助捕捉每日的流量特征.

(3) 每周周期: 该周期表示前一一周的相同时段的历史数据, 用 $X_w = (X_{T_0-7 \times q+1}, X_{T_0-7 \times q+2}, \dots, X_{T_0-7 \times q+T_p}) \in \mathbb{R}^{N \times F \times T_w}$ 表示. 通常, 交通流量的周模式与特定工作日的变化密切相关, 例如上周五的交通流量与本周五较为相似, 因此使用每周周期的数据可以捕捉一周内的规律性变化特征.

多组件结构在交通流量预测中能够有效捕捉不同时间尺度上的变化特征. 通过分别引入近期、每日和每周周期, 模型可以捕捉短期内的突发波动、日常模

式的重复规律以及周周期的特定特征. 这种结构利用了交通流量的多重周期性, 提高了模型的预测准确性和稳定性. 此外, 多组件结构增强了模型的适应性, 使其能够应对不同类型的时间变化和异常情况.

2.3 时序注意力层

交通流量在时间维度上呈现出显著的动态相关性, 尤其是在预测任务中, 不同时间步之间的关联性对准确建模未来趋势至关重要. 传统的卷积方法往往局限于捕获短期的局部依赖性, 难以充分挖掘长时间范围内的复杂变化规律. 为此, 本研究通过注意力模型来衡量一个时间步相对于另一个时间步的重要程度. 此外, 该模型能够根据输入数据的特点, 自适应地为不同时间步分配权重, 从而动态捕获时间相关性. 在此过程中, 不仅有效提取了动态时间特征, 还显著降低了噪声的干扰^[19]. 我们将总交通流量、平均速度和平均占用率这3个类别的数据整合后输入到注意力层, 通过数据融合提取更加可靠的注意力权重, 这些权重随后用于对交通流量数据进行处理.

$$E = V_e \times \sigma \left((X_h)^T U_1 \right) U_2 (U_3 X_h) + b_e \quad (2)$$

$$E'_{i,j} = \text{Softmax}(E_{i,j}) = \frac{\exp(E_{i,j})}{\sum_{j=1}^T \exp(E_{i,j})} \quad (3)$$

其中, $V_e, b_e \in \mathbb{R}^{T \times T}$, $U_1 \in \mathbb{R}^N$, $U_2 \in \mathbb{R}^{F \times N}$, $U_3 \in \mathbb{R}^F$ 是需要学习的参数. $X_h = (X_1, X_2, \dots, X_T) \in \mathbb{R}^{N \times F \times T}$ 是输入数据. E 表示每一时刻的注意力分数, 这些分数根据输入数据的不同而变化. $E_{i,j}$ 的值表达了时间 i 和时间 j 之间的相关性, 并通过 Softmax 函数进行归一化, 以确保每个时间点的权重之和为 1. 我们将时序注意力矩阵直接应用于输入数据, 以动态调整输入信息, 即:

$$\hat{X}_h = (\hat{X}_1, \hat{X}_2, \dots, \hat{X}_T) = (X_1, X_2, \dots, X_T) E' \in \mathbb{R}^{N \times F \times T} \quad (4)$$

2.4 扩张时序卷积层

在时序注意力层提取动态时空相关性后, 扩张时序卷积 (DTCN) 用于进一步建模时间特征, 通过扩大感受野捕获更深层次的时间依赖关系. DTCN 结合了扩张卷积和门控机制^[19], 具备在长时间序列建模中的显著优势. 扩张时序卷积层的结构如图 2 所示.

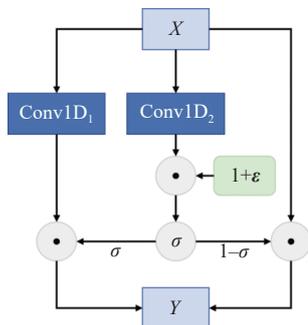


图 2 扩张时序卷积层的结构

扩张卷积通过在卷积操作中引入扩张率 (dilation rate), 能够在不增加计算量的情况下显著扩展感受野, 使其覆盖更长的时间范围, 从而更适合处理长时间依赖特性, 其内部操作过程如图 3 所示. 然而, 为了避免“网格效应 (grid effect)”导致的信息丢失和不连续性, DTCN 中堆叠的卷积层采用了不同的扩张率. 在该模型中, 第 1 层的扩张率设置为 2, 第 2 层的扩张率设置为 1, 这种设计能够确保所有时间步都能参与卷积计算, 保证了时间信息的完整性.

DTCN 的门控机制通过 Sigmoid 函数动态调节信息流动, 突出关键信息, 同时抑制冗余信息. 与时序注意力机制的结合使得模型在捕获复杂的时间相关性时更加高效, 同时也减少了噪声的干扰. 为了缓解网络加

深时的梯度消失问题, 该模型还引入了残差结构, 确保时间特征能够更稳定地传递.

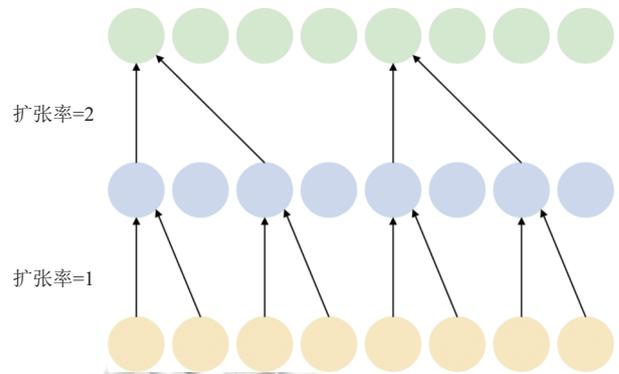


图 3 扩张卷积的过程

此外, 本研究在 DTCN 中引入了一种正则化机制 DropPath^[20], 通过随机扰动的方式对门控机制进行微调, 从而进一步提升模型的鲁棒性和灵活性. 这种方法通过引入一个随机分布的张量 ϵ 对门控部分的输出进行扰动, 其中, $\epsilon \in [-0.1, 0.1]$. 这一设计不仅增加了模型训练的随机性, 还有效防止了深层网络过拟合的现象, 使得模型能够更好地适应复杂的交通流量数据.

2.5 交互式动态图卷积网络

对于大多数时间序列数据, 由于其趋势性和接近性特征, 即使经过交错下采样, 子序列仍能保留原始序列的大部分信息. 同一路段交通数据在降采样后生成的两个子序列, 依然保持了原序列的时间趋势和周期性模式. 因此为了充分捕捉交通流量中短期、日周期和周周期的复杂时空依赖关系, 该模块采用了一种交互式学习机制. 该机制通过动态生成邻接矩阵, 将时间特征融入空间建模, 实现时空特征的深度交互与动态融合, 从而提升预测性能.

交互式动态图卷积 (IDGCN) 模块旨在捕获交通网络中节点之间的动态空间相关性并建模其交互特性. 具体而言, 交通流量数据首先通过卷积模块提取基础特征. 为实现多分辨率的特征建模和扩展感受野, 输入序列按照时间维度划分为奇数索引和偶数索引的两个子序列, 这些子序列随后被输入到 IDGCN 模块中进行动态空间相关性的建模. IDGCN 模块能够探索道路网络中潜在的节点连接, 以捕获隐含的空间依赖关系. 同时, 基于输入交通数据, IDGCN 动态模拟节点之间随时间变化的关联性, 从而更全面地建模交通流量的复杂动态模式.

首先, 我们将输入序列在时间维度上划分为两个

子序列: 奇数索引子序列 X_{odd} 和偶数索引子序列 X_{even} . 这些子序列输入动态图卷积网络 (DGCN) 中, DGCN 基于交通数据构建交互图, 用于捕获节点之间的动态空间相关性. DGCN 最初由 Liu 等人^[21] 提出, 用于建模节点间的空间异质性. 本文采用交互学习机制 (IDGCN), 使得输出子序列 X' 被重新组合为与原始输入序列长度一致的特征序列, 并用于最终的特征预测. 输入序列的分割与交互特征提取的具体过程如下:

$$X_{\text{even}}, X_{\text{odd}} = \text{Split}(X) \quad (5)$$

$$X' = \text{IDGCN}(X_{\text{even}}, X_{\text{odd}}) \quad (6)$$

其中, $\text{Split}(\cdot)$ 表示将输入序列在时间维度上划分为两个子序列, X' 是 IDGCN 的输出.

2.5.1 动态图卷积模块

动态图卷积模块包括融合图卷积和图生成两个部分. 首先, 基于输入特征和先验的图拓扑信息, 通过扩散图卷积生成学习图 A_{learn} . 学习图不仅整合了实际地理拓扑的先验信息, 还反映了交通网络的基础结构特性. 随后, 利用节点嵌入生成自适应图结构 A_{ada} , 该自适应图能够动态捕获节点之间的交互关系.

接着, 将学习图 A_{learn} 和自适应图 A_{ada} 融合, 生成动态图结构 A_{dyn} . 通过引入可学习参数 α , 模型可以动态调整两种图的重要性权重, 从而实现空间关系的自适应建模. 最终, 扩散图卷积作用于动态图 A_{dyn} , 以捕获节点之间的动态全局空间相关性. 具体公式如下:

$$A_{\text{learn}} = \text{DGCN}(\text{diffusion}(X')) \quad (7)$$

$$A_{\text{ada}} = \text{Softmax}(\text{ReLU}(E_1 E_2^T)) \quad (8)$$

$$A_{\text{dyn}} = \alpha A_{\text{learn}} + (1 - \alpha) A_{\text{ada}} \quad (9)$$

其中, E_1, E_2 表示节点嵌入参数, 维度设置为 10, Softmax 和 ReLU 为激活函数.

2.6 多组件融合

在交通流量预测中, 不同地点可能受不同时间模式的影响. 例如, 某些地区的周一早高峰的流量模式可能与上周一的相似, 而另一些地区则可能需要考虑更多的日周期和周周期的因素. 这些地点的预测需要灵活地结合不同时间尺度的影响. 然而, 也有一些时段, 交通流量并未呈现出明显的周期性趋势, 这时需要结合邻近时段的数据. 因此, 针对这些复杂情况, 我们使用张量来定义融合矩阵 \tilde{W} , 该矩阵能够自适应地从数据中学习各个时间周期组件的权重, 从而实现更加精

准的预测. 我们将融合过程定义如下:

$$\tilde{W} = (W_h, W_d, W_w) \quad (10)$$

$$\hat{Y} = \tilde{W}(\hat{Y}_h, \hat{Y}_d, \hat{Y}_w)^T = W_h \odot \hat{Y}_h + W_d \odot \hat{Y}_d + W_w \odot \hat{Y}_w \quad (11)$$

其中, \odot 表示 Hadamard 乘积; $\tilde{W} \in \mathbb{R}^{3N \times T}$ 是由 3 部分组成的参数融合矩阵; $W_h, W_d, W_w \in \mathbb{R}^{N \times T}$, 其中 N 表示节点数, T 表示预测的时间步数. 通过这种方式, 模型能够根据数据自适应地学习各组件的权重, 动态调整不同位置和时间的预测权重.

3 实验分析

3.1 数据集

为验证本文模型方法, 我们使用了两个来自加利福尼亚的高速公路交通数据集, 分别为 PeMSD4 和 PeMSD8^[22]. 这些数据通过加利福尼亚交通监测系统 (PeMS) 每 30 s 采集一次, 并且每 5 min 进行一次汇总, 全天共获得 288 个数据点. 这两个数据集都包含 3 项主要的交通指标: 总流量、平均速度和平均占用率. 具体的信息可以参考表 1.

表 1 PeMSD4 和 PeMSD8 数据集详细信息

数据集	节点数	边数	时间步数	时间范围
PeMSD4	307	340	16 992	2018/01/01–2018/02/28
PeMSD8	170	295	17 856	2016/07/01–2016/08/31

为了避免冗余探测器的干扰, 我们确保相邻探测器之间的距离大于 5.6 km, 并剔除了部分重复数据. 在处理缺失数据时, 采用线性插值方法填补空缺. 所有数据在预处理时进行了归一化操作, 使得数据值限制在 $[0, 1]$ 范围内, 并确保数据集的均值为 0. 实验中将节点随机划分为训练集、验证集和测试集, 比例为 6:2:2, 与基准实验设置相同.

3.2 实验设置

TAIDGCN 模型是基于 PyTorch 构建的, 并使用配备 24 GB RAM 的 NVIDIA GeForce RTX 3090 GPU 进行训练. 为了评估模型的性能, 将 DGCN 的扩张率分别设置为 2 和 1, 并且叠加了两层 DGCN. 我们设定的预测窗口大小为 $T_p = 12$, 即模型基于前一小时的数据预测未来 12 个时间步的交通流量. 通常, 历史数据越长, 能够涵盖的时间周期越精细, 从而提高预测的准确度. 然而, 为了保证实验的公平性, 并确保能够准确对比不同模型的预测能力, 我们在所有模型中保持相同的历史数据和预测跨度. 具体而言, 实验使用了 12 个

时间点的数据: $T_h = 12$, $T_d = 12$, $T_w = 12$. 在训练阶段, 采用 Adam 优化器, 并设置学习率为 0.001, 批处理大小设置为 64. 为全面评估模型性能, 使用了包括平均绝对误差 (MAE) 和均方根误差 (RMSE) 在内的评估指标. 每个指标的计算如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{T_i} - Y_{P_i}| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{T_i} - Y_{P_i})^2} \quad (13)$$

其中, N 是节点数量, Y_P 是预测值, Y_T 是真实值. 误差值越小, 模型性能越好. 这些评估指标为模型性能提供了全面的评估, 综合考虑了预测误差的大小、百分比以及预测值的平方误差.

3.3 基准模型

将 TAIDGCN 与 10 种基线方法进行比较, 具体如下.

(1) HA: 历史平均法利用历史数据的平均值来预测未来的数据.

(2) VAR: 向量自回归是一种时间序列模型, 用于捕捉交通序列的时间相关性.

(3) ARIMA^[4]: 这是用于时间序列数据分析预测的最经典方法之一.

(4) LSTM^[5]: 长短期记忆网络是一种神经网络模型, 能够有效捕捉时间序列中的长期依赖关系.

(5) GRU^[11]: 门控循环单元是一种特殊类型的 RNN 模型, 通过引入更新门和重置门机制, 有效捕捉长时间序列中的依赖关系.

(6) DCRNN^[14]: 扩散卷积递归神经网络使用扩散卷积网络学习空间信息, 并使用序列到序列模型捕捉时间信息.

(7) ASTGCN^[16]: 基于注意力的时空图卷积网络采用时空注意力机制, 有效捕捉动态的时空相关性.

(8) STSGCN^[23]: 时空同步图卷积网络使用 GCN 模型以同步方式建模时空相关性.

(9) Graph WaveNet^[15]: 使用图卷积网络和扩张因果卷积网络来捕捉交通道路网络的时空依赖关系.

(10) GMAN^[17]: 图多头注意力网络结合了图卷积网络和多头注意力机制, 通过同时学习时空依赖关系来提高复杂时空数据的预测精度.

3.4 实验结果

我们将 TAIDGCN 模型与 10 个基准方法进行对

比, 使用 PeMSD4 和 PeMSD8 数据集来预测未来一个小时的交通流, 表 2 总结了下一个小时交通流预测性能的平均结果. 通过分析实验结果, 我们可以得出以下结论: (1) 所提出的 TAIDGCN 模型在预测精度方面明显优于传统方法 (如 HA、VAR 和 ARIMA) 以及仅专注于时间维度的 LSTM、GRU, 相比于其他基准模型 (如 ASTGCN、STSGCN、Graph WaveNet 和 GMAN), TAIDGCN 在 PeMSD4 和 PeMSD8 数据集上表现出显著的优势, 突显了注意力机制和图卷积网络在捕捉交通流量时空依赖性中的有效性. (2) TAIDGCN 结合了时序注意力层、扩张时序卷积层和交互式动态图卷积网络, 通过这 3 个模块的有机协作, 提升了对交通流量数据的时空建模能力. TAL 模块有效地捕捉了时序相关性, DTCN 通过扩张卷积进一步建模时间特征, 而 IDGCN 则专注于空间依赖关系的建模, 从而实现了更精确的交通流量预测. 总体而言, 与其他基线模型相比, 所提方法在 PeMSD4 和 PeMSD8 数据集上均表现出更好的性能.

表 2 不同模型在 PeMSD4 和 PeMSD8 数据集上的平均性能比较

模型	PeMSD4		PeMSD8	
	MAE	RMSE	MAE	RMSE
HA	35.89	53.41	29.26	43.59
VAR	34.31	51.17	21.37	30.54
ARIMA	32.71	59.84	23.99	43.88
LSTM	30.39	44.60	23.17	36.48
GRU	29.69	43.74	22.15	35.43
DCRNN	25.34	37.26	19.09	29.74
ASTGCN	24.15	36.12	16.77	26.35
STSGCN	23.38	34.54	17.63	27.38
Graph WaveNet	23.01	33.34	15.99	24.73
GMAN	22.23	31.93	15.57	24.01
TAIDGCN (Ours)	22.06	31.49	15.19	23.63

图 4 和图 5 展示了不同方法在预测时段延长情况下的预测性能变化趋势. 总体而言, 随着预测时段的延长, 预测难度加大, 预测误差也不可避免地增加. 可以看出, 对于短期预测, 仅依赖时间相关性的方法 (如 HA、VAR、ARIMA、LSTM 和 GRU) 能够取得较为理想的结果. 然而这些方法的性能会随着预测时段的延长而显著下降, 导致预测精度大幅降低. 相较之下, 深度学习方法尽管在预测时段延长时同样会出现误差增加的情况, 但其整体预测性能依然优于传统方法. TAIDGCN 模型在所有预测时段中均表现出最佳预测精度, 进一步验证了其在捕捉复杂时空相关性方面的优越性.

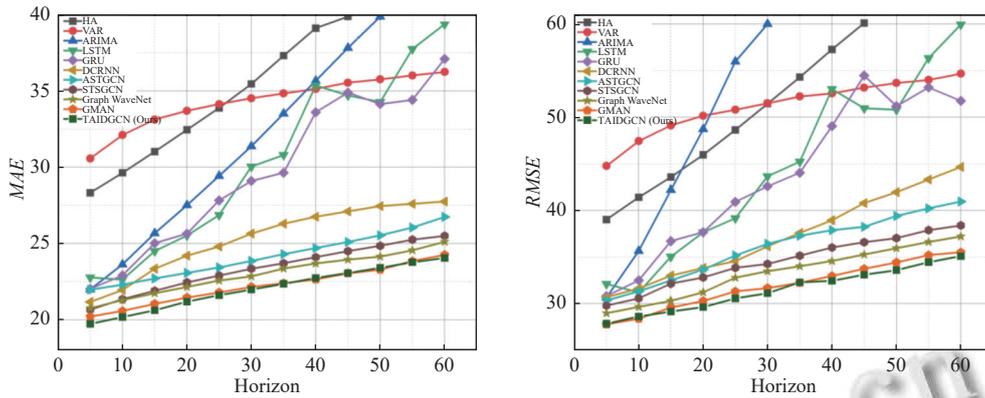


图4 随预测时段延长,不同方法在 PeMSD4 数据集上的预测性能变化

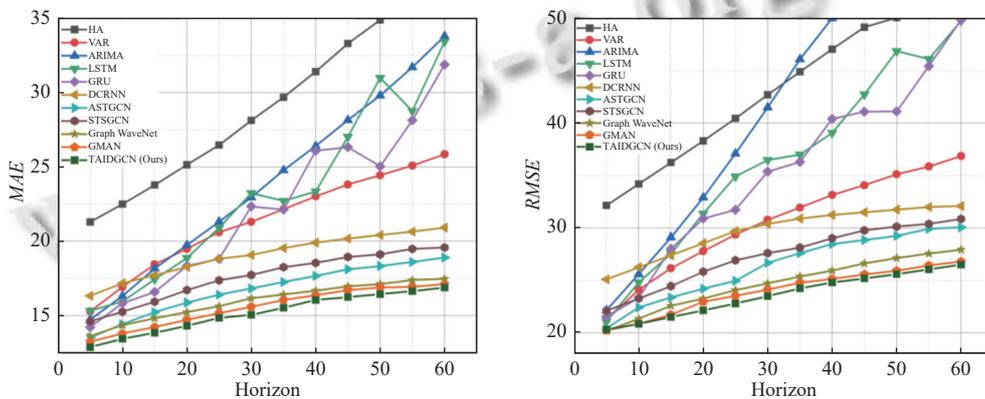


图5 随预测时段延长,不同方法在 PeMSD8 数据集上的预测性能变化

3.5 消融实验

为了评估 TAIDGCN 模型中各组成部分的贡献,在 PeMSD4 和 PeMSD8 数据集上进行了消融研究.我们设计了 3 个 TAIDGCN 变体,具体如下.

(1) w/o DropPath: 未在 DTCN 中添加 DropPath 机制.

(2) w/o DGCN: 将 DGCN 替换为常规的扩散 GCN,且 GCN 的输入邻接矩阵为预先定义的初始邻接矩阵.

(3) w/o Interaction: 在 IDGCN 中使用分段子序列机制,但不进行交互学习.

图 6 总结了消融研究的平均结果,证明了所提方法的合理性和有效性.

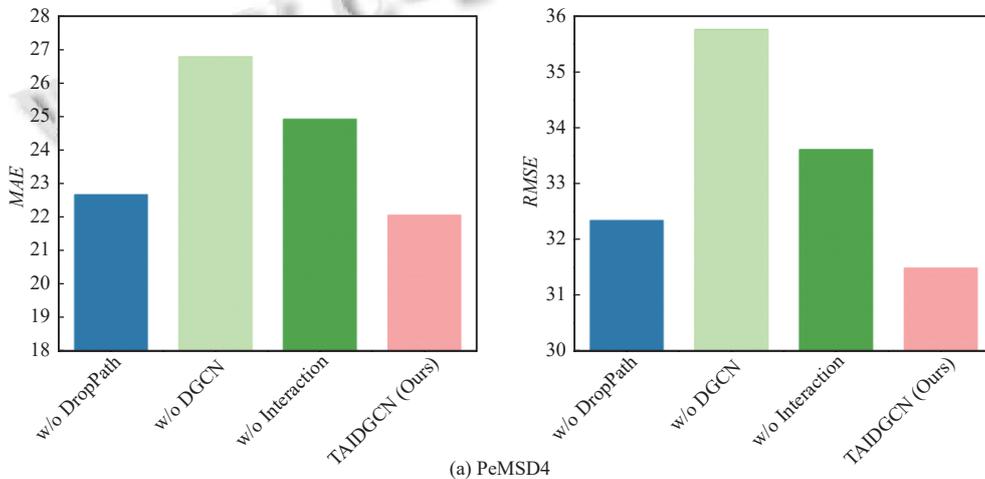


图6 TAIDGCN 的消融研究预测性能

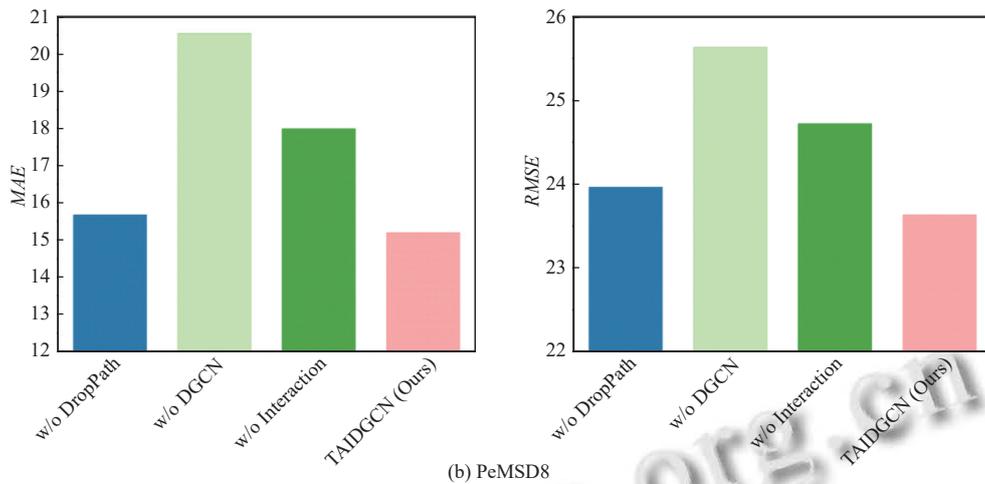


图6 TAIDGCN的消融研究预测性能(续)

消融实验结果表明, TAIDGCN 模型的各项组成部分对模型性能的提升至关重要, 其中, DGCN 和交互学习结构是对模型影响最大的组成部分. 接下来, 进一步探讨这些关键模块如何为模型带来优势. 移除 DGCN 模块后, 模型在两个数据集上的 MAE 和 RMSE 均显著上升, 表明 DGCN 在捕捉复杂动态空间相关性中的核心作用. 交互学习机制同样对模型性能起到重要贡献, 移除后空间建模能力显著下降, 进一步证明了该机制在动态邻接矩阵生成及深度空间关系学习中的优势. 此外, DropPath 在抑制过拟合和提升模型泛化能力方面表现尤为突出, 尽管在较小规模的 PeMSD8 数据集上效果有限, 但在更复杂的 PeMSD4 数据集上显著提升了预测性能. 完整模型 TAIDGCN 的表现最优, 验证了 TAL、DTCN 和 IDGCN 模块设计的合理性与协同性.

3.6 计算时间

为进一步分析模型的计算效率, 对不同模型的计算时间进行了测试, 重点评估每轮训练时间 (s) 和推理时间 (s). 选择 PeMSD4 数据集作为测试数据集, 并对比 TAIDGCN 与多个基线模型的计算性能, 结果见表 3.

表3 PeMSD4 数据集上不同模型的计算时间

模型	每轮训练时间 (s)	推理时间 (s)
DCRNN	100.96	16.67
ASTGCN	50.61	9.40
STSGCN	57.55	14.39
Graph WaveNet	48.81	6.87
GMAN	68.40	7.98
TAIDGCN (Ours)	73.86	10.56

从表 3 可以看出, DCRNN 计算复杂度最高, 每轮训练时间 100.96 s, 推理时间 16.67 s, 主要由于其循环神经网络结构限制了并行计算. Graph WaveNet 计算效率最高, 每轮训练时间 48.81 s, 推理时间 6.87 s, 得益于

自适应图卷积和扩张卷积. GMAN 每轮训练时间 68.40 s, 推理时间 7.98 s, 相较于 Graph WaveNet 计算开销更大, 但仍低于 DCRNN, 说明其基于注意力机制的建模方式提升了一定的计算效率. STSGCN 每轮训练时间 57.55 s, 推理时间 14.39 s, 表明其时空同步学习方式在推理阶段带来了额外的计算开销.

相比之下, TAIDGCN 在计算复杂度和预测精度之间取得了一定的平衡. 其每轮训练时间为 73.86 s, 推理时间 10.56 s, 尽管计算复杂度高于 GMAN, 但仍比 DCRNN 低 26.8%, 推理时间减少 36.7%, 表明 TAIDGCN 在提升预测性能的同时, 计算开销仍处于合理范围内. 这表明, 尽管 TAIDGCN 采用了交互动态图卷积以及多尺度时空建模方法, 计算量有所增加, 但整体计算效率仍然可接受.

4 结论与展望

本文提出的 TAIDGCN 模型有效解决了交通流量预测中的时空依赖性问题, 通过集成时序注意力机制 (TAL)、扩张时序卷积网络 (DTCN) 和交互式动态图卷积网络 (IDGCN), 显著提高了交通流量预测的准确性. 通过实验验证, TAIDGCN 在两个真实世界高速公路数据集上超过了多个基准模型, 证明了其在捕捉复杂时空模式和动态空间关系方面的优越性. 消融实验进一步表明, 模型中各组件, 包括 DGCN 和交互学习机制, 对性能提升起关键作用. 然而, 由于 TAIDGCN 采用了更复杂的模型架构, 其计算复杂度相较于部分基线模型有所增加, 训练和推理时间高于 GMAN, 但仍明显低于 DCRNN, 表明其计算开销仍在可接受范围内. 此外, 本文的多组分结构能够有效融合不同时间尺度的特征, 增强了模型的适应性和泛化能力. 总体而言,

TAIDGCN 为智能交通系统中的交通流预测提供了一个解决方案,具有广泛的应用前景和实际价值。

未来的研究可以进一步优化模型结构,以降低计算复杂度,并提升在大规模交通网络上的适用性。同时,考虑到交通流数据的实时性,提高训练和推理效率,实现高效的实时预测也是重要方向。

本研究主要关注基于交通流自身的时空特征建模,而不依赖外部因素,尽管已有研究尝试结合天气、重大事件等信息来提升预测精度。未来可在保持时空建模能力的基础上,探索外部因素的融合,以增强模型在复杂环境下的适应性。

此外,本研究已通过消融实验分析了时序注意力、扩张时序卷积和交互式动态图卷积对模型性能的贡献,未来可进一步优化这些模块,提升其在不同交通模式下的适应性,如改进注意力机制以更精准地捕捉动态特征,或结合自适应图学习增强对不规则交通网络的建模能力。同时,结合强化学习等自适应优化技术,对模型进行动态调节,以提升其在复杂交通环境下的鲁棒性和泛化能力。

参考文献

- 1 Yang BL, Sun SL, Li JY, *et al.* Traffic flow prediction using LSTM with feature enhancement. *Neurocomputing*, 2019, 332: 320–327. [doi: 10.1016/j.neucom.2018.12.016]
- 2 Jiang RH, Yin D, Wang ZN, *et al.* DL-Traff: Survey and benchmark of deep learning models for urban traffic prediction. arXiv:2108.09091v1, 2021.
- 3 Pan ZY, Liang YX, Wang WF, *et al.* Urban traffic prediction from spatio-temporal data using deep meta learning. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage: ACM, 2019. 1720–1730.
- 4 Williams BM, Hoel LA. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results. *Journal of Transportation Engineering*, 2003, 129(6): 664–672. [doi: 10.1061/(ASCE)0733-947X(2003)129:6(664)]
- 5 Ma XL, Tao ZM, Wang YH, *et al.* Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 2015, 54: 187–197. [doi: 10.1016/j.trc.2015.03.014]
- 6 Geng X, Li YG, Wang LY, *et al.* Spatiotemporal multi-graph convolution network for ride-hailing demand forecasting. *Proceedings of the 33rd AAAI Conference on Artificial Intelligence*. Honolulu: AAAI, 2019. 3656–3663.
- 7 Bruna J, Zaremba W, Szlam A, *et al.* Spectral networks and locally connected networks on graphs. arXiv:1312.6203, 2013.
- 8 Yu B, Yin HT, Zhu ZX. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting. arXiv:1709.04875, 2017.
- 9 Velickovic P, Cucurull G, Casanova A, *et al.* Graph attention networks. arXiv:1710.10903, 2017.
- 10 Jeong YS, Byon YJ, Castro-Neto MM, *et al.* Supervised weighting-online learning algorithm for short-term traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(4): 1700–1707. [doi: 10.1109/TITS.2013.2267735]
- 11 Fu R, Zhang Z, Li L. Using LSTM and GRU neural network methods for traffic flow prediction. *Proceedings of the 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*. Wuhan: IEEE, 2016. 324–328.
- 12 Bai SJ, Kolter JZ, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. arXiv:1803.01271, 2018.
- 13 Zhao L, Song YJ, Zhang C, *et al.* T-GCN: A temporal graph convolutional network for traffic prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(9): 3848–3858. [doi: 10.1109/TITS.2019.2935152]
- 14 Li YG, Yu R, Shahabi C, *et al.* Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. arXiv:1707.01926, 2017.
- 15 Wu ZH, Pan SR, Long GD, *et al.* Graph WaveNet for deep spatial-temporal graph modeling. arXiv:1906.00121, 2019.
- 16 Guo SN, Lin YF, Feng N, *et al.* Attention based spatial-temporal graph convolutional networks for traffic flow forecasting. *Proceedings of the 33rd AAAI Conference on Artificial Intelligence*. Honolulu: AAAI, 2019. 922–929.
- 17 Zheng CP, Fan XL, Wang C, *et al.* GMAN: A graph multi-attention network for traffic prediction. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York: AAAI, 2020. 1234–1241.
- 18 Lv MQ, Hong ZX, Chen L, *et al.* Temporal multi-graph convolutional network for traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(6): 3337–3348. [doi: 10.1109/TITS.2020.2983763]
- 19 Wang Y, Jing CF, Xu SS, *et al.* Attention based spatiotemporal graph attention networks for traffic flow forecasting. *Information Sciences*, 2022, 607: 869–883. [doi: 10.1016/j.ins.2022.05.127]
- 20 Larsson G, Maire M, Shakhnarovich G. Fractalnet: Ultra-deep neural networks without residuals. arXiv:1605.07648, 2016.
- 21 Liu AY, Zhang YY. Spatial-temporal interactive dynamic graph convolution network for traffic forecasting. arXiv:2205.08689, 2022.
- 22 Jiang WW, Luo JY. Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications*, 2022, 207: 117921. [doi: 10.1016/j.eswa.2022.117921]
- 23 Song C, Lin YF, Guo SN, *et al.* Spatial-temporal synchronous graph convolutional networks: A new framework for spatial-temporal network data forecasting. *Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York: AAAI, 2020. 914–921.

(校对责编:王欣欣)