

基于多时空图融合与动态注意力的交通流预测

翟志鹏, 曹阳, 沈琴琴*, 施全

(南通大学交通与土木工程学院, 江苏 南通 226019)

摘要: 精准的交通流预测是实现智能交通系统的关键前提, 对加强系统的仿真和控制、提高管理者的决策等方面具有重要意义。针对大多数现有的图卷积网络(GCN)模型忽略交通流数据的动态时空变化、对节点信息使用不足导致时空相关性提取不充分的问题, 提出一种基于多时空图融合与动态注意力的交通流预测模型。首先, 以不同的卷积单元提取交通流数据中多时域状态下的时间特征; 然后, 构建多时空图体现节点在空间分布中的动态变化趋势和异质性, 并结合 GCN 提取空间特征; 最后, 利用多头自注意力机制分别对时空特征进行分析与融合, 输出预测结果。在两个实际的公共数据集 PeMS04 和 PeMS08 上进行实验分析, 并与基于注意力的时空图卷积网络(ASTGCN)、多视角的时空 Transformer 网络(MVSTT)和动态时空感知图神经网络(DSTAGNN)等基于时空图卷积网络的基准模型对比, 结果表明所提模型在平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和均方根误差(RMSE)指标上分别平均降低了 7.10%、7.22% 和 6.47%, 具有较强的适应性和鲁棒性。

关键词: 智能交通系统; 交通流预测; 时空特征; 图卷积网络; 多头自注意力机制

中图分类号: TP18

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0069439

Traffic Flow Prediction Based on Multiple Spatio-Temporal Graph Fusion and Dynamic Attention

ZHAI Zhipeng, CAO Yang, SHEN Qinqin*, SHI Quan

(School of Transportation and Civil Engineering, Nantong University, Nantong 226019, Jiangsu, China)

【Abstract】 Accurate traffic flow prediction is a key prerequisite for realizing intelligent transportation systems, and is of great significance for strengthening system simulation and control and improving the decision-making of managers. To address the problem of most existing Graph Convolutional Network (GCN) models ignoring the dynamic spatial and temporal variations in traffic data and insufficiently employing node information, which leads to insufficient extraction of spatial and temporal correlations, a traffic flow prediction model based on multiple spatio-temporal graph fusion and dynamic attention is proposed. First, the temporal characteristics of traffic flow data in multi-temporal states are extracted by different convolutional cells. The next step involves constructing a multiple spatio-temporal graph to capture the dynamic trend and heterogeneity of nodes in spatial distribution, followed by extracting spatial characteristics through the integration of GCN. Finally, the spatial and temporal characteristics are analyzed and fused using the multi-head self-attention mechanism to output prediction results. Experimental analyses are performed on two public datasets, PeMS04 and PeMS08, and compared with the Attention Based Spatial-Temporal Graph Convolutional Network (ASTGCN), Multiview Spatial-Temporal Transformer Network (MVSTT), Dynamic Spatial-Temporal Aware Graph Neural Network (DSTAGNN) and other benchmark models that utilize spatio-temporal graph convolution. The results show that the Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and Root Mean Square Error (RMSE) of the proposed model are reduced by 7.10%, 7.22%, and 6.47%, respectively, demonstrating the proposed model's strong adaptability and robustness.

【Key words】 intelligent transportation system; traffic flow prediction; spatio-temporal characteristics; Graph Convolution Network (GCN); multi-head self-attention mechanism

0 引言

随着汽车保有量的不断增长,城市道路拥堵频发,给城市在安全、环境等方面带来巨大的压力,严

重阻碍了城市的高质量发展。智能交通系统作为构建智慧城市的关键组件,是缓解交通拥堵的有效手段,而精准的交通流预测是实现智能交通系统的关键前提,对监测城市交通运行状态、安全和提高应急

收稿日期: 2024-02-28 修回日期: 2024-05-19

基金项目: 国家自然科学基金面上项目(61771265);江苏高校“青蓝工程”项目;南通市科技计划项目(JC2021198)。

通信作者 E-mail: * shenqq@ntu.edu.cn

响应能力等方面具有十分重要的研究意义^[1]。

城市交通数据依赖传感器节点收集到的历史信息,信息的收集与数据分析技术的进步,为交通流预测领域的研究提供了有力的技术支持。经大量的研究分析与实践探索,统计学方法、机器学习和深度学习均已被成功应用到交通流预测中^[2]。然而,统计学方法仅对线性问题有良好的分析结果,对交通流数据呈现的非线性特征性能表现不佳。 k -最近邻(k -NN)、差分自回归移动平均(ARIMA)、支持向量回归等机器学习方法^[3]在处理高维数据、提取数据非线性特征方面有一定的优势,但由于过于依赖时间关联因素而忽略交通流数据复杂的时空特征,导致精度较低。

相比传统的机器学习模型,深度学习模型在提取数据的非线性特征以及时空特征方面具有明显的优势^[4-5]。循环神经网络^[6](RNN)及其变体[如长短期记忆网络(LSTM)^[7]和门控循环单元(GRU)^[8]等]被用于深层次挖掘交通流数据的时间特征,取得了良好的预测结果。由于交通路网具有复杂的空间相关性,某一路段上的交通状态必定受到其邻近路段的影响,因此在图像处理领域中取得巨大成功的卷积神经网络(CNN)^[9]被引入到交通流预测领域,以增强模型对空间特征的挖掘能力。研究表明,虽然 CNN 能有效聚合邻近信息,但对空间特征的挖掘均基于欧氏空间下的网格数据,对处理非欧氏空间下的数据特征存在明显的局限性。

为提高对非欧氏空间下数据复杂拓扑结构中空间特征的挖掘能力,研究者将图卷积网络(GCN)^[10-11]引入到交通流预测中,并结合基于时间序列的深度学习模型提出了一系列时空特征融合的交通流预测模型。文献^[12]分别利用 GCN 和 GRU 提取交通流数据的空间特征和时间特征,提出了时间图卷积网络交通流预测模型。文献^[13]将交通流数据划分为不同的时间窗口以提取周相关、日相关和邻近相关的数据,在 GCN 模块中采用高阶切比雪夫多项式,提出了多时空图卷积网络交通流预测模型。然而,在这些工作中,GCN 模块通常采用静态的邻接矩阵描述路网空间结构,在训练过程中固化了路网的分布,无法表现节点呈现出的空间动态变化趋势。为此,一方面,可采用相关性分析方法构建更加符合实际的模糊邻接矩阵^[14]、添加可学习的权重张量^[15]、根据自适应学习算法^[16]等获取节点之间的关联信息;另一方面,可将 GCN 与图学习算法^[17]、注意力机制^[18]等相结合,构建新的

时空图卷积网络获取节点的特定模式,提取交通流数据中的时空动态关系^[19]。同时,为摆脱 GCN 模型对预定义图的过度依赖,一些研究专注于构建新的图结构信息,例如:基于高斯核函数融合由向量空间嵌入生成的相似性图和距离图,构建动态相关性图^[20];根据路网空间结构的内在动态信息,生成基于数据驱动策略的动态时空感知图^[21];通过图嵌入方法对路段空间位置信息进行编码,构建自适应邻接图^[22];根据路网节点间的距离度量、相似性度量等多属性特征构建基于时空相似性的动态图^[23];根据流量特征、距离特征和天气特征构建节点相关性图^[24]。上述方法不再只利用预定义图建模空间信息,而是将静态图和动态图紧密结合,构建具有多种属性的特征图,强化模型对复杂的时空关联特征和空间动态变化趋势的挖掘能力。

由于动态图更能表现交通路网中节点的时空动态性,基于动态图的多时空图卷积网络已成为目前研究的主要方向之一。但是,现有的大多数模型只考虑了节点的空间相似性,如距离相似性和邻域相似性,这不足以表示具有时空属性的节点之间的相关性。同时,根据不同算法生成的融合图,图内每一个节点均蕴含着不同的时空信息,如何将不同图中节点对应的同时实现多图时空融合仍具有极大的挑战性。此外,多时空深度学习模型受到数据源的限制,对长时的时空特征提取不够充分。时间和空间相关性是动态关联的,时空信息的精细融合可以揭示更为复杂的时空关联。因此,深入挖掘交通特征中的潜在的时空特征对提高预测精度和鲁棒性至关重要。

针对上述问题,本文提出一种基于多时空图融合与动态注意力的交通流预测模型,从时间、空间及时空融合 3 个层面分析交通流数据的特征。首先,通过不同的卷积单元捕获交通流信息的全局和局部关联性,利用自注意力机制分析多时域状态下的细粒度时间特征;然后,构建 4 种代表不同属性的特征图体现节点在空间分布中的异质性,结合空间嵌入方法实现多时空图融合,使用 GCN 和自注意力机制提取交通流数据的全局空间特征;最后,融合时空特征,完成交通信息的全局分析与交互,实现更加精准的预测。在不同数据集上的验证结果表明,所提模型的预测精度在多种评价指标上均优于对比的基于 GCN 的基线模型。

1 问题定义

本文将道路网络表示为一个拓扑图 $G = (V,$

E, A), 其中, V 表示道路网络 G 内节点的集合, E 表示节点之间连通性的边的集合, $A \in \mathbb{R}^{N \times N}$ 表示图 G 的邻接矩阵。任意时间步 i 处的交通状态可表示为图信号矩阵 $X_i \in \mathbb{R}^{D \times N}$, 其中, D 是交通属性特征(如交通流量、速度、占有率等)的数量, N 是传感器的个数。

交通流预测的目标是根据 T 个历史时间步的交通流量 $X_{(t-T+1):t} \in \mathbb{R}^{D \times T \times N}$, 学习道路网络 G 上

的映射函数 $\mathcal{F}(\cdot)$, 预测 P 个未来时间步的交通流量 $X_{(t+1):(t+P)} \in \mathbb{R}^{D \times P \times N}$:

$$X_{(t+1):(t+P)} = \mathcal{F}(X_{(t-T+1):t}; G) \quad (1)$$

2 方法

本文提出一种基于多时空图融合与动态注意力的交通流预测模型, 根据特征属性的差异, 实现对时空、时间和空间特征的分析, 模型框架如图 1 所示。




图 1 模型框架

Fig.1 Model framework

图卷积循环单元(GCRU)组合了 GCN 和 RNN 的特点, 其利用节点之间的拓扑结构和时序关系, 共同完成对每个节点时空特征的挖掘: 在时间组件中, 为加强对多时域状态下时间特征的分析, 构建长时和短时门控卷积单元, 并串联多头自注意力机制细粒度挖掘交通流数据中的长时和短时特征; 在空间组件中, 构建 4 种不同的结构图,

每一张图均代表了节点在不同空间模式下的结构关系, 为其赋予可学习的权重张量, 动态分析图与图之间的全局关系, 并结合节点嵌入信息实现多时空图融合, 同时辅以 GCN 和多头自注意力机制提取节点的空间特征; 在时空融合组件中, 将时间组件和空间组件的输出作为输入, 以多头自注意力机制融合时间和空间特征, 通过卷积层映射得

到最后的预测结果。

2.1 GCRU

GCRU 将 GCN 和 RNN 组合,根据节点间的拓扑结构关系和时序数据,对随时间变化的时空特征进行挖掘。GCRU 为每个节点赋予一个隐藏状态,并在隐藏状态中保持相同的拓扑结构,根据当前时

间步和上一时间步的状态信息,对图中的每个节点聚合其邻居节点的特征以更新当前节点的隐藏状态,挖掘数据中的时序关系和演变过程,共同考虑节点间的时空关系。同时,GCRU 逐节点提取数据特征,实现对分布于不同时间步中的周期性特征的挖掘。GCRU 的框架如图 2 所示。




图 2 GCRU 框架

Fig. 2 GCRU framework

对于给定的输入信息 $\mathbf{X} \in \mathbb{R}^{N \times T \times H}$ (其中 H 表示嵌入维度),GCRU 的计算公式如下:

$$\begin{aligned} z_t &= \sigma(\Theta_{z*G}(\mathbf{X}_t \parallel \mathbf{h}_{t-1})\mathbf{W}_z + \mathbf{b}_z) \\ r_t &= \sigma(\Theta_{r*G}(\mathbf{X}_t \parallel \mathbf{h}_{t-1})\mathbf{W}_r + \mathbf{b}_r) \\ \tilde{\mathbf{h}}_t &= \varphi(\Theta_{h*G}(\mathbf{X}_t \parallel r_t \odot \mathbf{h}_{t-1})\mathbf{W}_h + \mathbf{b}_h) \\ \mathbf{h}_t &= z_t \odot \mathbf{h}_{t-1} + (1 - z_t) \odot \tilde{\mathbf{h}}_t \end{aligned} \quad (2)$$

式中: Θ_{z*G} 、 Θ_{r*G} 和 Θ_{h*G} 分别表示不同门内的图卷积运算; $\mathbf{W}_z$ 、 $\mathbf{W}_r$ 、 $\mathbf{W}_h$ 、 $\mathbf{b}_z$ 、 $\mathbf{b}_r$ 和 $\mathbf{b}_h$ 是可学习的参数; $\sigma(\cdot)$ 和 $\varphi(\cdot)$ 分别表示 Sigmoid 和 Tanh 激活函数; $\odot$ 为 Hadamard 乘积; $[\mathbf{X}_t, \mathbf{h}_{t-1}]$ 和 $\mathbf{h}_t$ 分别表示第 t 个时间步的输入和输出。

2.2 时间组件

2.2.1 长短时门控卷积单元

在实际交通路网中,某一区域的车流信息会受到其他区域的影响,节点间时序数据的相似性会随着时域模式的变化而变化,相邻时域内的节点数据相关性强,而间接相邻的节点数据相关性弱。为提取在不同时域模式下区域节点间的影响关系,搭建了长时门控卷积和短时门控卷积单元,以不同的卷积核大小捕捉长期和短期的时间关联特征。

1) 长时门控卷积单元(L-卷积层)。

L-卷积层使用大小为 $(T, 1)$ 的卷积核,根据时间序列长度 $(T=12)$ 展开卷积操作,提取完整的时间序列特征,输出结果为 $\mathbf{X}_{TL} \in \mathbb{R}^{N \times \mu}$ (其中 μ 表示中间矢量维度),计算公式为:

$$\begin{aligned} \mathbf{X}_{TL} &= \\ &\varphi(\text{Conv}_1(\mathbf{X}_G) + a) \odot \sigma(\text{Conv}_2(\mathbf{X}_G) + b) \end{aligned} \quad (3)$$

式中: $\mathbf{X}_G \in \mathbb{R}^{N \times T \times H}$ 是图卷积循环单元的输出;

$\text{Conv}_1(\cdot)$ 和 $\text{Conv}_2(\cdot)$ 是长时卷积运算; a 和 b 是可学习的偏置参数。

2) 短时门控卷积单元(S-卷积层)。

S-卷积层使用大小为 $(4, 1)$ 的卷积核,细粒度提取短时序的特征,输出结果为 $\mathbf{X}_{TS} \in \mathbb{R}^{N \times \mu}$,计算公式为:

$$\begin{aligned} \mathbf{X}_{TS} &= \\ &\varphi(\text{Conv}_3(\mathbf{X}_G) + c) \odot \sigma(\text{Conv}_4(\mathbf{X}_G) + d) \end{aligned} \quad (4)$$

式中: $\text{Conv}_3(\cdot)$ 和 $\text{Conv}_4(\cdot)$ 是短时卷积运算; c 和 d 是可学习的偏置参数。

2.2.2 多头自注意力单元

交通节点间的信息关联错综复杂,不同节点的特征随着时空关系的延伸发生变化。为了加强对节点全局关联特征的挖掘能力,在门控卷积单元后串联多头自注意力单元,这样不仅能深层次挖掘不同时间尺度上数据周期性特征的动态分析,如天周期和周周期特征的变化。

对于多头自注意力机制,假设给定输入为 $\mathbf{X}_q$ 、 $\mathbf{X}_k$ 和 $\mathbf{X}_v$,采用线性映射获得序列 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$:

$$\begin{aligned} \mathbf{Q} &= \mathbf{X}_q \mathbf{W}_q \\ \mathbf{K} &= \mathbf{X}_k \mathbf{W}_k \\ \mathbf{V} &= \mathbf{X}_v \mathbf{W}_v \end{aligned} \quad (5)$$

式中: $\mathbf{W}_q$ 、 $\mathbf{W}_k$ 、 $\mathbf{W}_v \in \mathbb{R}^{H \times H}$ 为线性变换的权重参数。

基于 $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 和缩放因子 d ,计算第 i 个注意力头 head_i :

$$\text{head}_i = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (6)$$

再使用多头注意力单元连接 n 个头的注意力特征,并行计算注意力函数:

$$\text{MHA}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_n) \mathbf{W}_m \quad (7)$$

式中: $\text{MHA}(\cdot)$ 是多头注意力函数; Concat 是连接注意力特征的连接操作; $\mathbf{W}_m \in \mathbb{R}^{H \times H}$ 是用于整合多头注意力分数并进行降维的学习参数。

为全局和局部特征构建多头自注意力层、全连接层以及残差和归一化层,学习高维度下的时间依赖关系,得到 $\mathbf{X}_{\text{TL}}^m, \mathbf{X}_{\text{TS}}^m \in \mathbb{R}^{N \times T \times H}$:

$$\mathbf{X}_{\text{TL}}^m = F((\text{MHA}(\mathbf{X}_{\text{TL}}, \mathbf{X}_{\text{TL}}, \mathbf{X}_{\text{TL}})) \mathbf{W}_\alpha) \quad (8)$$

$$\mathbf{X}_{\text{TS}}^m = F((\text{MHA}(\mathbf{X}_{\text{TS}}, \mathbf{X}_{\text{TS}}, \mathbf{X}_{\text{TS}})) \mathbf{W}_\beta) \quad (9)$$

式中: $\mathbf{X}_{\text{TL}}^m$ 和 $\mathbf{X}_{\text{TS}}^m$ 为长时和短时门控卷积单元的输出; $\mathbf{W}_\alpha, \mathbf{W}_\beta \in \mathbb{R}^{H \times H}$ 分别为自注意力层权重参数; $F(\cdot)$ 为残差和归一化层映射。

2.2.3 门控融合单元

构建门控融合单元有效整合不同时间域状态下的属性特征,将长时和短时特征融合,计算公式为:

$$g = \sigma(\mathbf{W}_t(\mathbf{X}_{\text{TL}}^m) + \mathbf{W}_s(\mathbf{X}_{\text{TS}}^m)) \quad (10)$$

$$\mathbf{X}_J = g \cdot \mathbf{X}_{\text{TS}}^m + (1 - g) \cdot \mathbf{X}_{\text{TL}}^m \quad (11)$$

式中: $\mathbf{W}_t, \mathbf{W}_s \in \mathbb{R}^{H \times H}$ 分别是两个输入分量的权重参数; g 表示门控值; $\mathbf{X}_J \in \mathbb{R}^{N \times T \times H}$ 是门控融合单元的输出。

2.3 空间组件

交通流信息中充斥着复杂多变的时空依赖关系,仅通过预定义的邻接图难以体现交通节点的空间动态性,因此,构建不同的特征图反映节点在不同空间模式下的分布特点,使用可训练的权重张量对齐空间与时间的依赖关系,并引入空间和图注意力机制计算位于不同图中节点间的相关性,生成动态融合图。

2.3.1 特征图定义

模型定义 4 种结构图^[25],分别为距离图 $\mathbf{G}^D$ 、邻接图 $\mathbf{G}^N$ 、功能图 $\mathbf{G}^F$ 和时间模式相似图 $\mathbf{G}^M$ 。图与矩阵对应关系定义为:

$$\begin{cases} \mathbf{G}^D = \{\mathbf{V}, \mathbf{E}, \mathbf{A}^D \in \mathbb{R}^{N \times N}\} \\ \mathbf{G}^N = \{\mathbf{V}, \mathbf{E}, \mathbf{A}^N \in \mathbb{R}^{N \times N}\} \\ \mathbf{G}^F = \{\mathbf{V}, \mathbf{E}, \mathbf{A}^F \in \mathbb{R}^{N \times N}\} \\ \mathbf{G}^M = \{\mathbf{V}, \mathbf{E}, \mathbf{A}^M \in \mathbb{R}^{N \times N}\} \end{cases} \quad (12)$$

式中: $\mathbf{A}^D, \mathbf{A}^N, \mathbf{A}^F, \mathbf{A}^M$ 分别代表距离矩阵、邻接矩阵、功能矩阵和时间模式相似矩阵。

距离矩阵 $\mathbf{A}^D$ 的元素用阈值高斯核函数定义为:

$$\mathbf{A}_{ij}^D = \begin{cases} \exp\left(-\frac{d_{ij}^2}{\tau^2}\right), & i \neq j \text{ and } \exp\left(-\frac{d_{ij}^2}{\tau^2}\right) \geq \epsilon \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

式中: d_{ij} 是节点 v_i 和 v_j 之间的直线欧几里得距离,反映实际空间中节点间的最短直线距离; τ^2 是距离的方差,采用 ϵ 和 τ^2 控制 $\mathbf{A}^D$ 的稀疏性和分布。

邻接矩阵 $\mathbf{A}^N$ 的元素定义为:

$$\mathbf{A}_{ij}^N = f(x) = \begin{cases} 1, & v_i \text{ 和 } v_j \text{ 相连} \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

利用 Pearson 相关性提出功能图提取全局上下文函数相似度的系数,以 K 表示函数的总数,节点 v_i 的函数向量表示为 $\mathbf{F}_i = \{f_{i,1}, f_{i,2}, \dots, f_{i,k}, \dots, f_{i,K}\}$ 。根据 Pearson 相关系数将功能矩阵 $\mathbf{A}^F$ 的元素定义为:

$$\mathbf{A}_{ij}^F = \begin{cases} \frac{\sum_{k=1}^K (f_{i,k} - \bar{\mathbf{F}}_i)(f_{j,k} - \bar{\mathbf{F}}_j)}{\sqrt{\sum_{k=1}^K (f_{i,k} - \bar{\mathbf{F}}_i)^2 \sum_{k=1}^K (f_{j,k} - \bar{\mathbf{F}}_j)^2}}, & i \neq j \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

对于节点 v_i ,用于训练的时间序列数据的向量描述为 $\mathbf{T}_i = \{t_{i,1}, t_{i,2}, \dots, t_{i,p}, \dots, t_{i,P}\}$,其中, P 为时间序列长度, $t_{i,p}$ 是节点 v_i 在时间步 p 处的时间序列数据值。根据余弦相似度将时间模式相似矩阵 $\mathbf{A}^M$ 的元素定义为:

$$\mathbf{A}_{ij}^M = \begin{cases} \frac{\sum_{p=1}^P (t_{i,p} - \bar{\mathbf{T}}_i)(t_{j,p} - \bar{\mathbf{T}}_j)}{\sqrt{\sum_{p=1}^P (t_{i,p} - \bar{\mathbf{T}}_i)^2 \sum_{p=1}^P (t_{j,p} - \bar{\mathbf{T}}_j)^2}}, & i \neq j \\ 0, & \text{otherwise} \end{cases} \quad (16)$$

2.3.2 多时空图融合的构建方法

图融合方法是构建动态图的关键,每一种结构图都是交通环境变化的映射。融合方法对交通属性的各项比重产生直接影响,而简单的加权合并无法满足对空间属性的比重分配。因此,使用空间嵌入方法得到 $\mathbf{M}_{\text{SE}} \in \mathbb{R}^{N \times N}$ 以保存图的结构信息,使用图嵌入方法为不同图进行编码,表示不同图中的节点关系,构建可训练的权值张量 $\mathbf{T}^{(i)} \in \mathbb{R}^{|G| \times N \times N}$ 对应图中的每个节点,再根据全连接网络将图转化为向量得到多图嵌入矩阵 $\mathbf{M}_{\text{GE}}^{(i)} \in \mathbb{R}^{N \times N}$,其中, (i) 表示任意图。为了得到多图之间的顶点表示,将空间

嵌入和多图嵌入融合为多图的节点表示(即图空间嵌入),再利用空间注意力和图注意力自适应提取节

点之间的相关性,最后加权求和得到多时空融合图 $G^* = \{V, E, A^* \in \mathbb{R}^{H \times H}\}$, 如图 3 所示。




图 3 多时空融合图的构建

Fig. 3 Construction of multi-spatial-temporal fusion graph

2.3.3 空间特征分析

交通流特征具有明显的空间依赖关系,相邻节点或非相邻节点均会对目标节点产生影响,因此,对节点在空间上的强弱相关性分析对挖掘交通流数据的演变趋势有重要意义。

将动态融合图 G^* 和交通流数据作为空间组件的输入,提取交通流数据的空间相关性。

首先,使用 GCN 在空间维度上聚合邻近节点的值更新目标节点,并构建多层 GCN 扩大感受野,传播和聚合空间信息中相距较远的节点特征,得到 $X_S^c \in \mathbb{R}^{N \times T \times H}$ 。单个 GCN 操作计算公式为:

$$X_C = \phi(\hat{D}^{-\frac{1}{2}} \hat{A}^* \hat{D}^{-\frac{1}{2}} X \Theta) \quad (17)$$

式中: $\hat{A}^* = A^* + I$ 为添加自连接的图矩阵; $\hat{D}$ 为 $\hat{A}^*$ 的度矩阵; Θ 代表卷积核; $\phi(\cdot)$ 为 ReLU 激活函数。

其次,构建空间多头自注意力单元,以 X_S^c 作为输入,动态学习节点和边之间的潜在依赖关系,对交通节点特征进行更强的相关性分析。 $X_S \in \mathbb{R}^{N \times T \times H}$ 表示空间组件的输出,计算公式为:

$$X_S = F((MHA(X_S^c, X_S^c, X_S^c)) W_S) \quad (18)$$

式中: $W_S \in \mathbb{R}^{H \times H}$ 为可学习的权重参数。

2.4 时空融合组件

时间组件和空间组件的输出分别为 $X_J \in \mathbb{R}^{N \times T \times H}$ 和 $X_S \in \mathbb{R}^{N \times T \times H}$, 两种模式在交通流中各自占据一定比重,结合节点和边之间复杂的时空依赖关系,构建一个基于多头自注意力机制的融合层,利用空间和时间组件之间的对应关系灵活分配权重,计算公式为:

$$X_{ST} = MHA(Q, K, V) \quad (19)$$

$$Q = X_S W_q, K = X_J W_k, V = X_J W_v$$

式中: $X_{ST} \in \mathbb{R}^{N \times T \times H}$ 表示时空融合组件的输出; $W_q, W_k, W_v \in \mathbb{R}^{H \times H}$ 为线性变换的权重参数。

3 实验

3.1 数据集

采用公开的交通流数据集 PeMS04 和 PeMS08^[26] 来评估本文提出的模型性能,详细信息如表 1 所示。

表 1 数据集详细信息

Table 1 Dataset details

数据集	节点数/个	边数/条	步长总数/步	时间间隔/min
PeMS04	307	340	16 992	5
PeMS08	170	295	17 856	5

数据集源自美国加州的不同区域,在时间、地点和规模上均存在一定差异,每个传感器以 5 min 为一个时间间隔,每天包含 288 条数据记录,每条记录共包含 3 个数据特征,分别为交通流量、平均车速和路面占有率。

以 6:2:2 的比例将数据集划为训练集、验证集和测试集。每组数据均通过滑动窗口的形式,利用前 12 个时间步长(60 min)的交通流数据预测未来 12 个时间步长的数据。同时,对每一个特征数据都进行归一化处理:

$$\hat{X} = \frac{X - \text{mean}(X)}{\text{std}(X)} \quad (20)$$

式中: $\text{mean}(X)$ 为全部交通流数据的平均值; $\text{std}(X)$ 为全部交通流数据的标准差。

3.2 评价指标

本文采用 3 个评价指标来评估本文模型的有效性,分别是平均绝对误差(MAE, e_{MAE})、平均绝对百分比误差(MAPE, r_{MAPE})和均方根误差(RMSE, e_{RMSE}):

$$e_{MAE} = \frac{1}{L} \sum_{i=1}^L |Y_i - Y'_i| \quad (21)$$

$$r_{\text{MAPE}} = \frac{1}{L} \sum_{i=1}^L \left| \frac{Y_i - Y'_i}{Y_i} \right| \times 100\% \quad (22)$$

$$e_{\text{RMSE}} = \sqrt{\frac{1}{L} \sum_{i=1}^L (Y_i - Y'_i)^2} \quad (23)$$

式中: Y_i 和 Y'_i 分别表示交通车流量的真实值和预测值。评价指标数值越小,表示模型的预测效果越好。

3.3 基线模型及模型参数

为评估本文所提模型的性能,选取以下基线模型进行对比:

1) 基于统计方法的 ARIMA 模型;

2) 基于机器学习方法的 FC-LSTM 和 GRU-ED 网络模型;

3) 深度学习模型,包括结合 GCN 和注意力机制的 ASTGCN 模型、融合了图卷积和 RNN 的 AGCRN 模型、基于 Transformer 结构搭建双图空间学习的 MVSTT^[27] 模型、结合自注意力机制构建时空感知图的 DSTAGNN 模型。

本文模型基于深度学习框架 PyTorch 开发。训练过程中,学习率设置为 0.000 1,每次批处理训练的样本数(Batch size)设置为 8,迭代次数(Epoch)统一设置为 100,其他超参数设置如表 2 所示。

表 2 模型参数设置

Table 2 Model parameter settings

参数	取值
嵌入维度/维	64
注意力头数/个	4
长时门控卷积核大小	12×1
短时门控卷积核大小	4×1
预测层卷积核大小	1×1

3.4 实验结果分析

3.4.1 基线模型对比实验

为了验证模型性能的优越性,将本文所构建的模型与上述基线模型进行对比。所选基线模型的参

数设置均与本文模型实验参数对照,并在测试集上以 12 个时间步进行验证,利用 MAE、MAPE 和 RMSE 比较模型的输出结果,实验结果如表 3 所示,加粗表示最优值,下同。

表 3 模型在不同数据集上的结果对比

Table 3 Comparison of model results on different datasets

Model	PeMS04			PeMS08		
	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE
ARIMA	33.73	24.18	48.80	31.09	22.73	44.32
FC-LSTM	26.77	18.23	40.65	23.09	14.99	35.17
GRU-ED	23.68	16.44	39.27	22.00	13.33	36.23
ASTGCN	21.79	14.16	34.28	18.90	11.44	29.34
AGCRN	19.82	13.15	32.40	17.03	10.65	26.95
MVSTT	19.54	13.40	31.55	15.86	11.70	25.11
DSTAGNN	19.38	12.93	31.50	15.81	10.20	25.04
Ours	18.88	12.74	30.39	15.44	10.08	24.57

由表 3 可以看出,在所有评价指标上,本文模型的预测精度均优于其他基线模型。以 RMSE 和 PeMS04 数据集为例,相比 ASTGCN 提高 11.35%,相比 AGCRN 提高 6.2%,相比 MVSTT 提高 3.68%,相比 DSTAGNN 提高 3.52%。ASTGCN 添加了更为复杂的空间和时间注意力机制以提取动态的时空相关性,挖掘空间依赖关系时只依赖于预定义的静态邻接图,忽略了空间结构中潜在的动态依赖关系;AGCRN 利用图卷积中的节点可学习嵌入挖掘隐藏的空间依赖性,但在扩展感受野的同时不能堆叠时空层;MVSTT 虽能在不同视角下细粒度分析时域的演化,构建双图空间学习模块挖掘静态和动态空间图的依赖关系,但仅对静态图加以分析而忽略了其他结构图在空间上的演化影响;DSTAGNN 通过节点间的概率分布属性表示节点的动态空间依赖性,利用 Wasserstein 距离构建时空感知图取代传统的预定义的静态邻接图。

图 4 和图 5 分别展示了在不同数据集下以 12 个




图 4 不同模型在 PeMS04 上的性能比较

Fig.4 Performance comparison of different models on PeMS04

时间步(60 min)为统计范围,模型的预测精度指标(MAE 和 RMSE)随着时间步长增长的变化趋势




图 5 不同模型在 PeMS08 上的性能比较

Fig.5 Performance comparison of different models on PeMS08

3.4.2 消融实验对比

为验证模型中各组件的有效性,构建模型变体对比组件缺失的情况:

- 1)-MG: 移除动态融合图组件,用静态邻接图代替;
- 2)-SR: 移除短时门控卷积单元;
- 3)-LR: 移除长时门控卷积单元。

实验结果如表 4 所示。可以看出:变体的误差变大,表明模型中相关组件的影响程度更大;动态融合图能为模型在空间结构上提供更多的节点分布信息;长时和短时门控卷积单元能提取更多的时间序列特征;多头自注意力单元则关注数据的全局特征分析。

此外,还给出了本文模型随超参数变化的实验




图 6 不同超参数在数据集上的预测效果对比

Fig.6 Comparison of prediction effects on datasets with different hyperparameters

3.4.3 模型性能实验对比

在基线模型中选择两个最优的模型 MVSTT、DSTAGNN 与本文所提模型在数据集 PeMS08 上进行性能对比,各个模型每轮 Epoch 平均训练时

间、推理时间及显存占用如表 5 所示。


结果表明,本文模型的预测精度在不同时间步下均优于其他基线模型,且精度变化趋势稳定。

结果,包括短时门控卷积单元的大小和注意力头的数量。实验结果如图 6 所示。可以看出:短时门控卷积单元的大小对预测结果影响较大,而注意力头的数量变化影响相对较小。根据对比结果选择最佳的参数配置为:短时门控卷积单元大小为 4×1 ,注意力头的数量为 4 个。

表 4 消融实验结果

Table 4 Results of ablation experiment

变体	PeMS04			PeMS08		
	MAE	MAPE/%	RMSE	MAE	MAPE/%	RMSE
-MG	19.43	12.85	31.04	15.76	10.24	25.15
-SR	18.98	12.79	30.49	15.53	10.20	24.95
-LR	19.10	12.97	30.71	15.54	11.13	24.64
Ours	18.88	12.74	30.39	15.44	10.08	24.57



间、推理时间及显存占用如表 5 所示。

由表 5 可以看出,所提模型与 MVSTT 相比计算速度有所下降,但预测精度有明显提高,与 DSTAGNN 相比计算速度和预测精度均有一定提

升,进一步证明了所提模型综合性能的优异性。

表 5 模型性能对比

Table 5 Comparison of model performance

模型	每轮 Epoch 平均 训练时间/s	每轮 Epoch 平均 推理时间/s	显存占用/ MB
MVSTT	221	19	4 021
DSTAGNN	267	28	4 587
Ours	252	26	4 232

3.4.4 预测结果可视化

将归一化处理后的交通流数据作为模型的输入进行训练,使用验证集作为评测数据,图 7 给出了本文模型在数据集 PeMS08 中 3 号传感器预测车流量和真实车流量(均为每 5 min 车流量)的差异曲线。由图 7 可以看出,基于真实值的曲线在低峰时段分布具有规律性,在高峰时段分布无规律,而模型的预测曲线较好地符合这一分布趋势,说明该模型对不同分布下的数据均有较强的学习能力,进一步验证了模型的有效性。




图 7 模型预测数据拟合对比图

Fig.7 Model prediction data fitting comparison chart

4 结束语

为了有效应对交通路网中由传感器节点的动态变化延伸出的对时空特征提取不充分的问题,本文提出一种基于多时空图融合与动态注意力的交通流预测模型。使用不同的卷积单元和多头自注意力机制分别提取交通流数据的全局和局部特征,细粒度分析多时域状态下的时间特征;同时,为增强模型对节点空间特征的挖掘能力及解决数据中存在的空间异质性问题,构建 4 种不同的特征图并结合空间嵌入方法生成动态融合图,根据 GCN 和多头自注意力机制提取交通流数据的全局空间特征。在公开数据集 PeMS04 和 PeMS08 上进行对比实验,结果表明该模型预测精度均优于其他基线模型。后续将重

点对多特征输入问题进行研究,增强模型在交通路网中的鲁棒性,进一步提高模型的预测精度。

参考文献

- [1] 曲栩,甘锐,安博成,等. 基于广义时空图卷积网络的交通群体运动态势预测[J]. 交通运输工程学报, 2022, 22(3): 79-88.
QU X, GAN R, AN B C, et al. Prediction of traffic swarm movement situation based on generalized spatio-temporal graph convolution network [J]. Journal of Traffic and Transportation Engineering, 2022, 22 (3): 79-88. (in Chinese)
- [2] MEDINA-SALGADO B, SÁNCHEZ-DELACRUZ E, POZOS-PARRA P, et al. Urban traffic flow prediction techniques: a review [J]. Sustainable Computing: Informatics and Systems, 2022, 35: 100739.
- [3] 姚俊峰,何瑞,史童童,等. 基于机器学习的交通流预测方法综述[J]. 交通运输工程学报, 2023, 23(3): 44-67.
YAO J F, HE R, SHI T T, et al. Review on machine learning-based traffic flow prediction methods[J]. Journal of Traffic and Transportation Engineering, 2023, 23(3): 44-67. (in Chinese)
- [4] ZHENG G, CHAI W K, DUANMU J L, et al. Hybrid deep learning models for traffic prediction in large-scale road networks[J]. Information Fusion, 2023, 92: 93-114.
- [5] ZHANG X, GONG Y S, ZHANG C Q, et al. Spatio-temporal fusion and contrastive learning for urban flow prediction [J]. Knowledge-Based Systems, 2023, 282: 111104.
- [6] 李松江,祝绍淞,杨华民,等. 基于时空相关性多任务神经网络的交通预测[J]. 计算机应用与软件, 2021, 38(9): 286-292.
LI S J, ZHU S S, YANG H M, et al. Traffic prediction based on spatiotemporal correlation multitask neural network [J]. Computer Applications and Software, 2021, 38 (9): 286-292. (in Chinese)
- [7] 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.
- [8] SHU W N, CAI K, XIONG N N. A short-term traffic flow prediction model based on an improved gate recurrent unit neural network [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(9): 16654-16665.
- [9] 徐丽,符祥远,李浩然. 基于门控卷积的时空交通流预测模型[J]. 计算机应用, 2023, 43(9): 2760-2765.
XU L, FU X Y, LI H R. Spatial-temporal traffic flow prediction model based on gated convolution[J]. Journal of Computer Applications, 2023, 43 (9): 2760-2765. (in Chinese)
- [10] RAHMANI S, BAGHBANI A, BOUGUILA N, et al. Graph neural networks for intelligent transportation systems: a survey [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 8846-8885.
- [11] 刘俊奇,涂文轩,祝恩. 图卷积神经网络综述[J]. 计算机工程与科学, 2023, 45(8): 1472-1481.
LIU J Q, TU W X, ZHU E. Survey on graph convolutional neural network[J]. Computer Engineering & Science, 2023, 45(8): 1472-1481. (in Chinese)
- [12] 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.
- [13] 戴俊明,曹阳,沈琴琴,等. 基于多时空图卷积网络的交通

- 流预测[J]. 计算机应用研究, 2022, 39(3): 780-784.
DAI J M, CAO Y, SHEN Q Q, et al. Traffic flow prediction based on multi-spatial-temporal graph convolutional network [J]. Application Research of Computers, 2022, 39(3): 780-784. (in Chinese)
- [14] 冯思芸, 施振佳, 曹阳. 基于全局时空特性的城市路网交通速度预测模型[J]. 计算机工程, 2022, 48(5): 112-117.
FENG S Y, SHI Z Q, CAO Y. Urban road network traffic speed prediction model based on global spatio-temporal characteristics [J]. Computer Engineering, 2022, 48(5): 112-117. (in Chinese)
- [15] BAI L, YAO L, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting [J]. Advances in Neural Information Processing Systems, 2020, 33: 17804-17815.
- [16] CHEN Z J, LU Z, CHEN Q S, et al. Spatial-temporal short-term traffic flow prediction model based on dynamical learning graph convolution mechanism [J]. Information Sciences, 2022, 611: 522-539.
- [17] ZHANG W, ZHU F H, LV Y S, et al. AdapGL: an adaptive graph learning algorithm for traffic prediction based on spatiotemporal neural networks [J]. Transportation Research Part C: Emerging Technologies, 2022, 139: 103659.
- [18] GUO S, LIN Y, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[C]//Proceedings of the 33th AAAI Conference on Artificial Intelligence. Honolulu, USA: AAAI Press, 2019: 922-929.
- [19] 葛宇然, 付强. 基于时空联合学习的城市交通流短时预测模型[J]. 计算机工程, 2023, 49(1): 270-278.
GE Y R, FU Q. Short-time prediction model for urban traffic flow based on joint spatio-temporal learning [J]. Computer Engineering, 2023, 49(1): 270-278. (in Chinese)
- [20] ZHANG W Y, ZHU K, ZHANG S, et al. Dynamic graph convolutional networks based on spatiotemporal data embedding for traffic flow forecasting[J]. Knowledge-Based Systems, 2022, 250: 109028.
- [21] LAN S, MA Y, HUANG W, et al. DSTAGNN: dynamic spatial-temporal aware graph neural network for traffic flow forecasting [C] // Proceedings of the 39th International Conference on Machine Learning. San Diego, USA: ACM Press, 2022: 11906-11917.
- [22] 尹恒, 张凡, 李天瑞. 基于多邻接图与多头注意力机制的短期交通流量预测[J]. 计算机科学, 2023, 50(4): 40-46.
YIN H, ZHANG F, LI T R. Short-time traffic flow forecasting based on multi-adjacent graph and multi-head attention mechanism [J]. Computer Science, 2023, 50(4): 40-46. (in Chinese)
- [23] 谷振宇, 陈聪, 郑家佳, 等. 考虑时空相似性的动态图卷积神经网络交通流预测[J]. 控制与决策, 2023, 38(12): 399-3408.
GU Z Y, CHEN C, ZHENG J J, et al. Traffic flow prediction based on dynamic graph convolution neural network considering spatio-temporal similarity [J]. Control and Decision, 2023, 38(12): 399-3408. (in Chinese)
- [24] BAO Y X, SHEN Q Q, CAO Y, et al. PLU-MCN: perturbation learning enhanced U-shaped multi-graph convolutional network for traffic flow prediction [J]. Information Fusion, 2024, 104: 102213.
- [25] SHAO W, JIN Z, WANG S, et al. Long-term spatio-temporal forecasting via dynamic multiple-graph attention[C]//Proceedings of the 31st International Joint Conference on Artificial Intelligence. Vienna, Austria: Morgan Kaufmann Press, 2022: 2225-2232.
- [26] Caltrans performance measurement system[EB/OL]. [2024-02-25]. <http://pems.dot.ca.gov/>.
- [27] PU B, LIU J, KANG Y, et al. MVSTT: a multiview spatial-temporal transformer network for traffic-flow forecasting [J]. IEEE Transactions on Cybernetics, 2024, 54(3): 1582-1595.

编辑 金胡考