

面向交通流预测的全局-局部时空感知模型

潘理虎¹, 尹佳莉¹, 张睿¹, 谢斌红¹, 张林梁²

(1. 太原科技大学计算机科学与技术学院, 山西 太原 030024; 2. 山西省智慧交通研究院有限公司, 山西 太原 030036)

摘要: 交通流预测方法是智能交通系统的重要基础,但现有方法在准确捕获交通数据的时空相关性上仍有不足。为挖掘道路网络的复杂时空相关性,提高预测性能,提出一种考虑全局-局部时空感知的时空图注意力网络模型 GL-STAGGN。首先对输入数据进行时空位置嵌入来表征交通流的时空异质性,以增强时空数据的特征表示,其次利用全局-局部时间感知的多头自注意力同步挖掘全局与局部空间范围内的时间动态相关性;然后引入图注意力网络和基于注意力机制的动态图卷积网络分别聚合局部节点特征和动态调整空间相关性强度,以深度捕捉全局与局部空间相关性的内在关联;最后采用编码器-解码器架构将时空组件融合以构成 GL-STAGGN 模型。在现实世界的高速公路交通数据集 PEMS04 和 PEMS08 上的实验结果表明,相比未考虑全局-局部时空关系和忽略空间异质性的先进方法 DSTAGNN, GL-STAGGN 的平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)平均降低了 2.8%、2.3%和 3.3%,优于大多数现有基线模型,可更好地为智能交通系统提供支持。

关键词: 交通流预测;时空相关性;编码器-解码器;注意力机制;动态图卷积网络

源代码链接: <https://github.com/April-jiali/GL-STAGGN2.8>

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0069550

Global-Local Spatiotemporal Perception Model for Traffic Flow Prediction

PAN Lihu¹, YIN Jiali¹, ZHANG Rui¹, XIE Binhong¹, ZHANG Linliang²

(1. College of Computer Science and Technology, Taiyuan University of Science and Technology, Taiyuan 030024, Shanxi, China;

2. Shanxi Intelligent Transportation Institute Co., Ltd., Taiyuan 030036, Shanxi, China)

【Abstract】 Traffic flow prediction is crucial for intelligent transportation systems; however, the existing methods cannot accurately capture the temporal and spatial correlation of traffic data. To further explore the complex spatiotemporal correlation of road networks and improve prediction performance, a spatiotemporal graph attention network GL-STAGGN model considering global-local spatiotemporal perception is proposed. First, the spatiotemporal heterogeneity of traffic flow is represented by embedding the spatiotemporal location of the input data to enhance the feature representation of spatiotemporal data; subsequently, global-local time-aware multi-head self-attention synchronization is used to mine the global and local spatiotemporal dynamic correlation. Second, a graph attention network and a dynamic graph convolutional network based on the attention mechanism are introduced to aggregate local node features and dynamically adjust the spatial correlation intensity for capturing the internal correlation between global and local spatial correlations in depth. Finally, the GL-STAGGN model is constructed using an encoder-decoder architecture to fuse the spatiotemporal components. Experimental results on real-world highway traffic datasets, PEMS04 and PEMS08, show that compared with the advanced method DSTAGNN, which does not consider the global-local spatiotemporal relationship and spatial heterogeneity, the average Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE) decreased by 2.8%, 2.3%, and 3.3%, respectively. Furthermore, GL-STAGGN performs better than most existing baseline models in terms of supporting intelligent transportation systems.

【Key words】 traffic flow prediction; spatio-temporal correlation; encoder-decoder; attention mechanism; dynamic graph convolution network

0 引言

随着交通出行需求的快速增长,交通拥堵等相

关问题日益严重。许多国家都在大力发展智能交通系统(ITS),ITS已成为现代智慧城市不可或缺的一部分^[1]。准确的交通流预测作为智能交通系统和交

基金项目: 山西省基础研究项目(202203021221145);山西省研究生联合培养示范基地项目(2022JD11)。

作者简介: 潘理虎(CCF 高级会员),男,教授、博士,主研方向为人工智能、领域软件工程;尹佳莉,硕士研究生;张睿(CCF 高级会员),副教授、博士;谢斌红(CCF 会员),教授;张林梁,高级工程师、博士。

收稿日期: 2024-03-13

修回日期: 2024-06-04

E-mail: panlh@tyust. du. cn

通信息服务的重要基础,对调整交通调度和制定合理交通控制策略具有重大意义,有益于降低交通安全风险,使人们能够更好地安排日常出行。

交通流预测旨通过观测到的历史交通数据来预测未来的交通状态变化^[2]。早期的交通流预测问题采用传统的统计方法,包括差分自回归移动平均 (ARIMA) 模型^[3]、向量自回归 (VAR)^[4]、卡尔曼滤波器^[5]等。但是,它们无法处理非平稳和非线性的时间序列,难以捕获时空数据的复杂非线性关系。传统的机器学习模型如支持向量回归 (SVR)^[6] 和 k 近邻 (k -NN)^[7] 提供了比线性模型更好的结果,但其性能需要更精细的特征工程,并不能充分挖掘复杂时空依赖。交通数据的本质是非结构化的时空数据。而图神经网络 (GNN) 对非结构化时空数据的空间关系捕获能力更为卓越,因此在空间建模中更受研究者的青睐。作为典型代表的时空图卷积网络 (STGCN)^[8] 利用卷积操作捕获时间关系,通过图卷积网络 (GCN) 捕获空间关系。LI 等^[9] 提出基于门控循环单元 (GRU) 的扩散卷积递归神经网络 (DCRNN) 方法,它利用双向随机游走的扩散 GCN 提取时空相关性。然而,这些方法对于时间依赖性的提取存有局限。GUO 等^[10] 和 ZHENG 等^[11] 从注意力机制的角度出发深度挖掘时间依赖性,结合 CNN 和 GCN 综合捕获时空相关性。文献^[12] 提出时空同步图卷积网络 (STSGCN) 在利用卷积运算的同时,捕获局部空间和时间相关性。文献^[13] 提出时空融合图神经网络 (STFGNN),将时间与空间模块融合为时空图来捕获时空相关性。文献^[14] 从动态图卷积的角度出发,通过时空注意力融合的方法来构建模型。文献^[15] 提出动态时空感知图神经网络 (DSTAGNN),利用动态时空感知图代替传统的图卷积方法所使用的预定义静态图,从动态图的角度来考虑流量预测。这些模型虽已取得了成功,但在准确捕获非线性时空相关性以及提高模型预测性能上仍存在进一步改进和提升的空间。

由于交通数据是具有复杂时间相关性和动态空间相关性的时空数据^[16],它们不仅随时间的推移而发生改变,还与空间位置有关^[17]。在时间维度上,交通数据表现出特定的周期性和趋势性,这些特性存在全局与局部范围的差异;在空间维度上,道路网络上的交通流呈现错综复杂的情况,交通数据的动态空间相关性也呈现多种多样的特征。局部路段的交通状况会对周围路段产生一定的影响,例如交通事故、临时施工等。而整体运作的协调,会使各局部路段保持畅通。此外,在交通状况的动态变化中存

在隐性的时空异质性,不同时间的不同空间位置可能具有不同的交通流特征和交通模式^[18]。这种异质性可能由城市结构、道路类型、周围环境等因素而产生。例如在同一时间段内,城市中心商务区的早高峰与郊区的居民区附近则表现出截然不同的流量模式。然而,上述方法在交通流预测领域主要借助图卷积与注意力机制来聚焦于局部时空特征的捕捉,或者运用动态图理论以取代静态图来深化时空特征的挖掘。尽管这些技术在特定应用中显现成效,但它们在模型构建时,未能充分整合全局时空关联与时空异质性的作用。这导致当前模型在描绘交通数据复杂时空依赖性时,视角相对单一,未能全面把握其深层次的非线性关系,从而限制了预测性能的进一步优化。因此,本文的研究同时考虑时空相关性的全局与局部范围变化对流量预测的影响,以及在仅有道路网络结构可用的情况下有效学习时空异质性来提高模型预测性能与精度。

针对上述问题,本文提出了一种全局-局部时空感知的交通流预测模型 GL-STAGGN。该模型通过全面挖掘复杂时空数据的动态依赖,以有效捕捉全局与局部范围的时空相关性。同时,通过时空位置嵌入的方法来表征时空异质性以提高模型预测性能。GL-STAGGN 基于编码器-解码器架构,首先利用编码技术对时空异质性进行嵌入表示。然后利用双分支的时间感知注意力模块来挖掘全局-局部时间相关性。最后利用全局-局部空间感知模块来捕捉全局-局部空间相关性。

本文的主要贡献如下:

1) 提出了一种新颖的基于编码器-解码器架构的时空感知模型 GL-STAGGN。该模型通过嵌入时空异质性和全面捕捉交通流量数据的全局与局部时空相关性的方法,提高交通流预测的性能与精度。

2) 设计了一个双分支的时间感知多头自注意力模块,同步地对全局和局部空间范围内的时间动态相关性进行建模。进一步设计了全局-局部空间感知模块,该模块利用图注意力网络 (GAT) 和空间动态图卷积网络 (DGCN) 的优势逐步对时空图结构的局部与全局信息进行建模。此外,应用时间位置嵌入方法和 GCN 层分别获取时间与空间位置嵌入,以增强模型对时空异质性结构的感知。

3) 在现实世界的高速公路交通数据集上进行了实验,并评估了与 9 个基线方法相比的性能,GL-STAGGN 在实现准确交通流预测方面优于大多数现有的基线方法。

1 相关工作

1.1 交通流预测

交通流预测作为智慧城市交通系统的核心问题,已吸引了研究人员的广泛关注。起初研究人员依赖诸如自回归差分移动平均(ARIMA)^[3]以及向量自回归(VAR)^[4]等传统时间序列统计分析方法,这些方法的核心在于揭示基于时间序列之间数据间的线性关联。然而,由于交通流动态的复杂性和非线性特质,此类模型在预测效能上显得力有未逮。为突破线性框架的限制,机器学习算法逐渐被引入到交通流预测中,如支持向量回归(SVR)^[6]和 k NN^[7]。因其能处理非线性关系而脱颖而出,这些算法显著提升了预测的准确性。但它们需要精心设计的特征工程,耗时又耗力。近年来,随着深度学习技术的兴起,其在自动化特征提取方面的卓越能力为交通流预测领域注入了新的活力^[19],催生了一系列创新研究。研究者将循环神经网络(RNN)及其变体^[20-23](如 LSTM 和 GRU)引入到交通预测中,它们擅长捕捉交通数据的时间序列模式。MA 等^[24]提出的 LSTM 模型和 CUI 等^[25]提出的双向 LSTM 结构,分别在交通速度预测和双向时间依赖性捕捉上展现了潜力。尽管如此,RNN 在处理长序列时存在局限,促使研究者们探索基于时间序列的卷积神经网络(CNN)方法,如时间卷积神经网络(TCN)^[26-27],以改进时间依赖性的建模。然而,纯粹的时间序列方法忽视了交通数据的空间维度。为弥补这一缺陷,部分研究开始利用 CNN 以揭示空间相关性。比如,DCRNN^[9]利用扩散卷积挖掘空间依赖性,ST-ResNet^[28]则针对城市行人流量预测采用了 CNN。值得注意的是,交通数据本质上属于非欧氏类型,而基于 CNN 的模型只能应用于标准网格数据^[29-30]。

1.2 时空图神经网络

图神经网络(GNN)因其在处理非欧几里得数据结构上的特点,特别是在解析时空数据中错综复杂的空间关系方面表现出色,已成为交通预测研究领域不可或缺的关键技术^[31-32]。在这一前沿领域中,STGCN^[8]的出现标志着一个重大突破,它将 GCN 应用于剖析空间特征之间复杂且微妙的相互关联,为后续基于图神经网络的交通预测研究奠定了坚实基础。后来,ASTGCN^[10]通过在 GCN 框架中引入注意力机制,显著增强了模型对时空特征细微差别的辨识能力,从而更精确地把握交通数据的时空特性。Graph WaveNet^[33]则将自适应图结构

与图卷积相结合,成功地提取了更为精细的空间特征。STSGCN^[12]则运用滑动窗口技术,有效地捕捉了局部时空图的动态变化,特别适用于解析短周期内的时空模式。STFGNN^[13]作为一种时空融合图神经网络,引入了时空融合图模块,并与一维卷积模块并行工作,以实现时空信息的全面捕捉。DSTAGNN^[14]模型则通过动态时空感知图取代静态图卷积,突破了固定图结构的局限,增强了模型的灵活性和适应性。与此同时,较多研究^[34-36]探讨了空间图动态性的重要性,通过革新图构建策略,强调了适应交通网络实时变化对于提升预测精度的必要性,凸显了模型设计中灵活性与动态适应性的价值。然而,这些方法在揭示和利用交通网络内在的动态关联时忽视了时空图固有的静态特征(即空间异质性),以及仅仅是对时空局部相关信息捕捉的片面性。鉴于此,本文提出的 GL-STAGGN 模型在充分挖掘动态时空相关性的同时也纳入了时空异质性对交通流预测影响的研究,并同时考虑对时空相关性特征的局部动态变化和全局范围影响的有效挖掘,以提高模型对交通流预测的性能与精度。

2 问题定义

本文将交通路网结构表示为无向图 $G = (V, E, \mathbf{A})$, 其中, $V = \{v_1, v_2, \dots, v_N\}$ 是路网中 N 个监测器节点的集合, E 是一组边的集合, $\mathbf{A} = [a_{ij}] \in \mathbb{R}^{N \times N}$ 是路网 G 的邻接矩阵, 表示边的连接关系。

交通信号矩阵 $\mathbf{X}_t \in \mathbb{R}^{N \times C}$ 表示交通路网 G 在 t 时刻的观测值, 其中 C 是交通流的维度。将路网中 T 时间片上所有节点的流量张量表示为 $\mathbf{X} = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_N) \in \mathbb{R}^{T \times N \times C}$ 。

交通流预测的目标是结合先验知识, 利用历史观测数据预测未来交通系统的交通流。可以定义为: 从过去 T 步的时间序列中学习映射函数 f 来预测未来 T' 步的交通流, 如式(1)所示:

$$\begin{aligned} & [\mathbf{X}_{t-T+1}, \mathbf{X}_{t-T+2}, \dots, \mathbf{X}_t] \xrightarrow{f} \\ & [\mathbf{X}_{t+1}, \mathbf{X}_{t+2}, \dots, \mathbf{X}_{t+T'}; G] \end{aligned} \quad (1)$$

3 全局-局部时空感知交通流预测模型

GL-STAGGN 模型由数据输入层、时空编码器-解码器层和线性预测层构成, 如图 1 所示(彩色效果见《计算机工程》官网 HTML 版, 下同)。时空编码器中由 L 层相同的编码器层堆叠而成, 每层都包含全局-局部时间感知的多头自注意力模块、全

局-局部空间感知模块和残差连接及层归一化 3 个基本组件,全局-局部时间感知的多头自注意力块旨在全局和局部空间范围下的时间维度对交通数据的动态变化进行建模。全局-局部空间感知模块则是利用图注意力网络聚合空间图的局部节点特征,利用空间动态 GCN 捕获交通数据的全局空间动态相关性。残差连接和层归一化是为了有效缓解梯度消

失和提高模型鲁棒性。时空解码器的整体架构与时空编码器基本一致,而全局-局部时间感知块中的局部分支使用因果卷积^[25]操作获取键矩阵 $\mathbf{K}$ 。这用来捕获编码器输出序列的相关性,并防止模型在编码器输出序列中获取未来位置信息。本文将模型的输入数据表示为 $\mathbf{X} = (\mathbf{X}_{t-T+1}, \mathbf{X}_{t-T+2}, \dots, \mathbf{X}_t) \in \mathbb{R}^{N \times D_{\text{model}} \times T}$,以自回归生成的方式输出预测序列。




图 1 基于编码器-解码器架构的 GL-STAGGN 模型

Fig.1 GL-STAGGN model based on encoder-decoder architecture

3.1 时空位置嵌入

时间序列存在顺序性的问题,对时间相关性建模时顺序信息也尤为重要,时间最近的观测数据通常相关性更强。为此,本文引入了 Transformer^[37]的时间位置嵌入方法,使得附近的元素拥有相对应的位置嵌入信息而得到更准确的预测。计算公式如下:

$$\mathbf{P}_T^{\text{PE}}(p, 2d) = \sin(p/10\,000^{2d/D_{\text{model}}}) \quad (2)$$

$$\mathbf{P}_T^{\text{PE}}(p, 2d+1) = \cos(p/10\,000^{2d/D_{\text{model}}}) \quad (3)$$

式中: p 是时间序列的位置索引; d 是维度; 所得时间位置嵌入表示为 $\mathbf{P}_T^{\text{PE}} \in \mathbb{R}^{T \times D_{\text{model}}}$ 。

为了在保留图结构信息的同时,明确地对空间异质性进行建模,本文利用空间位置嵌入方法来增强模型对空间结构的感知能力。首先,通过为图中的每个节点分配一个额外的嵌入向量来生成初始的空间位置嵌入 $\mathbf{P}_S^{\text{PE}} \in \mathbb{R}^{N \times D_{\text{model}}}$,再应用 GCN 层进行拉普拉斯平滑操作^[38],以获得空间位置嵌入 $\mathbf{P}_S^{\text{PE}}$ 。时间位置嵌入 $\mathbf{P}_T^{\text{PE}}$ 和空间位置嵌入 $\mathbf{P}_S^{\text{PE}}$ 将与原始输入数据 $\mathbf{X}$ 融合,得到具有时间顺序信息和隐含空间异质性信息的输入数据 $\mathbf{X}_{\text{ST}} \in \mathbb{R}^{N \times T \times D_{\text{model}}}$,该矩阵的内部元素由 T 个时间片上 N 个节点的流量张量

组成。

3.2 全局-局部时间感知多头自注意力

时间维度的相关性在整个空间范围内和局部空间范围内的表现有所不同。为了挖掘交通数据的复杂时间相关性,本文引入多头自注意力机制^[39]的方法来建模全局和局部空间范围内的时间相关性。它允许模型在处理输入序列时同时关注不同表示子空间的信息内容。这对建模全局和局部时间相关性非常有利。

图 2 所示为全局-局部时间感知的多头自注意力模块。它的输入为 $\mathbf{X}_{\text{ST}} \in \mathbb{R}^{N \times T \times D_{\text{model}}}$,在原始输入数据中融合了时空位置嵌入,以便于后续更充分地挖掘时空依赖信息。模块将注意力的头数分割后采用双分支的架构,分别对全局时间相关性和局部时间相关性进行同步捕捉。在全局分支中,考虑到全局上下文信息,本文使用 1D 卷积分别提取查询矩阵 $\mathbf{Q}$ 、键矩阵 $\mathbf{K}$ 和值矩阵 $\mathbf{V}$,使其产生全局感受野,然后通过注意力机制捕获低频全局时间相关性。在局部分支中,通过因果卷积提取 $\mathbf{Q}$,1D 卷积提取 $\mathbf{K}$ 后进行点积运算得到具有局部上下文感知的权重矩阵,最后和线性变换得到的 $\mathbf{V}$ 相乘获得局部感知的注意力结果。将全局与局部注意力进行拼接,通

过线性变换得到最终注意力结果。在形式上如式(4)~式(10)所示:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{D_{\text{model}}}}\right)\mathbf{V} \quad (4)$$

$$h_i^{\text{head}} = \text{Attention}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (5)$$

$$M_{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \sum_{i=1}^h h_i^{\text{head}} \mathbf{W}^o \quad (6)$$

$$M_{\text{global}}^{\text{MSA}}, M_{\text{local}}^{\text{MSA}} = \text{Split}(M_{\text{MSA}}(\ast)) \quad (7)$$

$$M_{\text{global}}^{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \bigoplus (g_1^{\text{thead}}, g_2^{\text{thead}}, \dots, g_i^{\text{thead}}) \mathbf{W}_g^o \quad (8)$$

$$M_{\text{local}}^{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \bigoplus (l_1^{\text{thead}}, l_2^{\text{thead}}, \dots, l_i^{\text{thead}}) \mathbf{W}_l^o \quad (9)$$

$$M_{\text{gl}}^{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = M_{\text{global}}^{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) \bigoplus M_{\text{local}}^{\text{MSA}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) \quad (10)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别是查询、键和值矩阵, 这些矩阵的元素组成为 T 个时间片上 N 个节点的流量张量; D_{model} 是模型维度大小; h 是注意力的头数; $\mathbf{W}^o$ 是总的投影矩阵; $\mathbf{W}_i^Q, \mathbf{W}_i^K, \mathbf{W}_i^V$ 是 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 的投影矩阵; $M_{\text{MSA}}(\ast)$ 是多头自注意力方程; i 是全局注意力的头数, j 是局部注意力的头数, $(i+j)=h$ 是总的注意力头数; $\mathbf{W}_g^o, \mathbf{W}_l^o$ 分别是全局注意力和局部注意力的投影矩阵; $\bigoplus$ 表示连接操作。最后得到一个具有全局与局部时间相关性特征的序列表示 $\mathbf{M} = (\mathbf{M}_{t-T+1}, \mathbf{M}_{t-T+2}, \dots, \mathbf{M}_t) \in \mathbb{R}^{N \times T \times D_{\text{model}}}$, 该矩阵由模型维度为 D_{model} 的 T 个时间片上 N 个节点的流量张量组成。




图2 全局-局部时间感知多头自注意力

Fig.2 Global-local time perception multi-head self-attention

3.3 全局-局部空间感知结构

3.3.1 局部图注意力网络

本文使用图注意力网络(GAT)来挖掘道路网络节点间的局部空间关系。GAT使用自注意力机制为每个邻居节点分配不同的权重^[40], 允许模型学

习每个邻居节点的重要性, 完全独立于图结构。此外, GAT能在一定程度上缓解图卷积中信息丢失的问题, 使得模型在建模局部相关性时也能保留全局信息。首先将全局-局部时间感知的多头注意力模块的输出 $\mathbf{M} \in \mathbb{R}^{N \times T \times D_{\text{model}}}$ 作为 GAT 的输入, 在已具备充分时空相关性特征的情况下继续对空间相关性进行挖掘。GAT 为每个节点及其邻居节点计算注意力权重, 通过 LeakyReLU 激活函数对注意力权重进行非线性处理, 再使用 Softmax 对 e_{ij} 归一化得到每条边的注意力权重 a_{ij} , 然后对邻接节点的特征进行加权求和, 得到节点 i 的聚合信息, 计算公式如下:

$$e_{ij} = \text{LeakyReLU}(\bar{\mathbf{a}}^T [\mathbf{W}\mathbf{x}_i \parallel \mathbf{W}\mathbf{x}_j]) \quad (11)$$

$$a_{ij} = \text{Softmax}(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in N_i} \exp(e_{ik})} \quad (12)$$

$$\mathbf{G}_i = \sigma\left(\sum_{j \in N_i} a_{ij} \mathbf{W}\mathbf{x}_j\right) \quad (13)$$

式中: e_{ij} 表示节点 i 和节点 j 之间的注意力分数; $\bar{\mathbf{a}}^T$ 是映射函数; $\mathbf{W}$ 是可学习参数; $\parallel$ 表示连接操作; σ 是激活函数。最后得到一组聚合后具有时间相关性和局部空间相关性信息的节点表示 $\mathbf{G}_t = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\} \in \mathbb{R}^{N \times D_{\text{model}}}$, 其中的组成元素为每个节点的信息。需要注意的是, 为了不增加模型的计算成本, 本文使用单层 GAT 对局部空间相关性进行捕捉。

3.3.2 全局空间动态图卷积

尽管 GAT 模块有效地捕获了高频局部邻居节点的信息, 但它没有足够的能力来处理低频全局信息。为此, 本文进一步引入基于 GCN 的动态图卷积网络(DGCN)^[41] 以充分捕捉全局空间相关性, 如图3所示。图注意力模块的输出 $\mathbf{G}_t \in \mathbb{R}^{N \times D_{\text{model}}}$ 作为空间 DGCN 的输入, 此时的 $\mathbf{G}_t$ 已融合了时间相关依赖和局部空间相关性信息。首先通过式(14)得到全局空间相关的注意力权重矩阵 $\mathbf{S}_{\text{gt}} \in \mathbb{R}^{N \times N}$ 。然后对 $\mathbf{S}_{\text{gt}}$ 进行自适应缩放, 再通过 Hadamard 乘积运算来调整静态的归一化邻接矩阵 $\mathbf{A}_{\text{dj}}$ 。最后将其与 $\mathbf{G}_t$ 通过图卷积运算得到动态图卷积的输出结果。计算公式如下:

$$\mathbf{S}_{\text{gt}} = \text{Softmax}\left(\frac{\mathbf{G}_t \mathbf{G}_t^T}{\sqrt{D_{\text{model}}}}\right) \quad (14)$$

$$D_{\text{DGCN}}(\mathbf{G}_t) = \sigma((\mathbf{A}_{\text{dj}} \odot \mathbf{S}_{\text{gt}}) \mathbf{G}_t \mathbf{W}) \quad (15)$$

式中: $\odot$ 表示 Hadamard 乘积; σ 是激活函数。动态图卷积块根据保留全局信息的输出 $\mathbf{G}_t$ 不同变化的

相关矩阵来聚合全局空间信息。最终得到融合全局与局部时空信息的输出 $\mathbf{X}_{gl} = (\mathbf{X}_{t-T+1}, \mathbf{X}_{t-T+2}, \dots, \mathbf{X}_t) \in \mathbb{R}^{N \times D_{model} \times T}$ 。这不仅考虑了交通流数据的空间异质性和时间非线性,还整合了全局视角下的长期趋势与周期性模式,以及局部视角下的瞬时事件和局部交互,进而提高预测精度。




图3 空间 DGCN
Fig.3 Spatial DGCN

表 1 数据集汇总

Table 1 Dataset summary

数据集	时间范围	节点数/个	边数/条	时间步/个	时间间隔/min
PEMS04	2018-01-01—2018-02-28	307	340	16 992	5
PEMS08	2016-07-01—2016-08-31	170	295	17 856	5

为与基线方法保持一致且公平比较,实验中使用的两个数据集按时间顺序划分为训练集(60%)、验证集(20%)和测试集(20%),并使用过去 12 个连续的时间步预测未来 12 个时间步(未来 1 h)的交通流量。此外,当数据集中存在缺失数据点时,采用线性插值来恢复缺失数据,然后应用最大-最小标准化方法将所有数据映射到 $[-1, 1]$ 范围,并将归一化后的数据输入 GL-STAGGN 模型。

4.2 基线模型与评价指标

4.2.1 基线模型

1) HA^[42]: 历史平均值使用历史数据的加权平均值作为未来值的预测。

2) VAR^[4]: 向量自回归是时间序列预测的另一种传统方法。

3) DCRNN^[9]: 扩散卷积循环神经网络遵循编码器-解码器结构,采用扩散图卷积网络和 GRU 相结合的方式进行交通流预测。

4) STGCN^[8]: 第一次利用卷积操作捕获时间关系,利用 GCN 捕获空间关系。

5) ASTGCN^[10]: 将注意力机制引入交通流预

4 实验

本文在两个高速公路交通流量数据集上进行了 GL-STAGGN 模型与基线模型的性能评估及对比分析,并对 GL-STAGGN 进行了消融实验、超参数分析以及时间成本分析。

4.1 数据集与预处理

本文使用两个真实流量数据集 PEMS04 和 PEMS08 验证 GL-STAGGN 的性能。表 1 中列出了两个数据集的详细信息。

PEMS04 和 PEMS08 是有关美国加利福尼亚州所有主要市区的高速公路交通流量数据集,由加州交通局的绩效测量系统(PEMS)收集。它们记录交通流量、速度、车道占用率和有关传感器站的地理位置等信息,且原始交通流量数据 30 s 实时收集一次,并按 5 min 的时间步长聚合。PEMS04 包含旧金山湾区 307 个传感器收集的交通数据,其时段为 2018 年 1 月 1 日至 2 月 28 日。PeMS08 包含圣贝纳迪诺 170 个传感器收集的交通数据,其时段为 2016 年 7 月 1 日至 8 月 31 日。

测,设计了空间注意力和时间注意力机制来建模空间和时间动态以构建时空图卷积网络。

6) Graph WaveNet^[33]: Graph WaveNet 将图卷积与时间卷积相结合,以捕获时空依赖性。

7) STSGCN^[12]: 一种新型时空同步图卷积网络,利用卷积运算来同时捕获局部空间和时间相关性。

8) STFGNN^[13]: 提出一种将时间和空间模块融合的时间图以进行流量预测。

9) DSTAGNN^[15]: 一种新的动态时空感知图代替传统的图卷积方法所使用的预定义静态图,从动态图的角度来考虑流量预测。

4.2.2 评价指标

实验中使用流量预测的平均绝对误差(MAE, E_{MAE})、均方根误差(RMSE, E_{RMSE})和平均绝对百分比误差(MAPE, E_{MAPE}) 3 个常用指标^[27]来评估模型性能。

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

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

$$E_{\text{MAPE}}(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (18)$$

式中: N 为样本数量; $\hat{y}_i$ 为预测值; y_i 为真实值。

4.3 实验设置

GL-STAGGN 模型基于 PyTorch2.0 框架和 Python3.8 实现,所有实验均在具有 10 GB 显存的 NVIDIA GeForce RTX 3080 * 2 的 GPU 上进行。模型训练时使用 HuberLoss 损失函数、Adam 优化器来优化模型,模型维度为 64,学习率为 0.001,注意力总头数 $h=8$,全局与局部分支的头数分割比为 1:1, GL-STAGGN 模型在两个数据集上的其他设置如表 2 所示。

表 2 GL-STAGNN 模型在两个数据集上的设置

Table 2 Settings of the GL-STAGNN model on two datasets

数据集	编码器层数 L	解码器层数 L'	卷积核大小 k
PEMS04	3	3	3
PEMS08	4	4	3

表 3 GL-STAGNN 模型与 9 个基线模型在 PEMS04 和 PEMS08 数据集上的性能比较

Table 3 Performance comparison of GL-STAGNN model and nine baseline models on PEMS04 and PEMS08 datasets

模型	PEMS04			PEMS08		
	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
HA ^[42]	36.76	54.14	21.83	29.52	44.03	16.59
VAR ^[4]	24.54	38.61	17.24	19.19	29.81	13.10
DCRNN ^[9]	23.65	37.12	16.05	18.22	18.29	11.56
STGCN ^[8]	21.16	34.89	13.83	17.50	27.09	11.29
Graph WaveNet ^[33]	24.89	39.66	17.29	18.28	30.05	12.15
ASTGCN ^[10]	22.93	35.22	16.56	18.25	28.06	11.64
STSGCN ^[12]	21.19	33.65	13.90	17.13	26.80	10.96
STFGCN ^[13]	20.48	32.51	16.77	16.94	26.25	10.60
DSTAGNN ^[15]	19.30	31.46	12.70	15.67	24.77	9.94
GL-STAGGN(ours)	19.05	30.99	12.43	15.00	24.01	9.60

从表 3 可以看出,传统模型 HA 和 VAR 只能处理平稳和线性的交通数据,对复杂的时空交通数据处理能力非常有限。DCRNN 是一种基于 RNN 的经典交通流预测方法,由于 RNN 捕获长期时间相关性的能力远低于注意力机制,因此本文的模型 GL-STAGGN 与其相比有着很大的提升。STGCN 作为时空 GCN 模型的典型代表,它同时考虑了时间和空间相关性的影响,具有更好的预测精度。Graph WaveNet、STSGCN 和 STFGCN 使用一维 CNN 在时间维度上捕捉时间相关性。由于这两种模型所使用的卷积核感受野较小,难以捕捉到长期时间信息。因此,它们也很难在长期预测上做出更准确的预测。此外,引入注意力机制的模型 ASTGCN 在时间维度和空间维度上分别使用了注意力卷积的方法,并获得了良好的性能。因为注意力机制可以灵活地捕捉长期时间相关性。本文的模

型 GL-STAGGN 也同样利用注意力机制,其长期预测性能比 ASTGCN 有更大优势。DSTGNN 考虑了空间图的动态相关性,使用动态图代替了大多数图卷积方法所使用的静态图,在性能上有良好的表现。但可能忽略了空间异质性,这在一定程度上限制了其预测性能。

4.4 性能比较分析

为验证 GL-STAGGN 模型的优越性能,在两个真实交通流数据的测试集上开展了性能对比实验。表 3 显示了 GL-STAGGN 与基线模型对未来 1 h 的平均预测结果,“_”表示次优性能,粗体表示最优性能。在考虑全局和局部时空相关性以及空间异质性的情况下, GL-STAGGN 在大多数情况下以及在这两个流量数据集上的表现都优于所有基线模型。GL-STAGGN 在 PEMS04 和 PEMS08 上的性能都有明显的提升。在 PEMS04 中, GL-STAGGN 在 MAE、RMSE 和 MAPE 指标上分别比先进模型 DSTAGNN 降低了 1.3%、1.49% 和 2.13%。在 PEMS08 中, GL-STAGGN 在 MAE、RMSE 和 MAPE 指标上分别比最先进的模型 DSTAGNN 降低了 4.28%、3.07% 和 3.42%。

型 GL-STAGGN 也同样利用注意力机制,其长期预测性能比 ASTGCN 有更大优势。DSTGNN 考虑了空间图的动态相关性,使用动态图代替了大多数图卷积方法所使用的静态图,在性能上有良好的表现。但可能忽略了空间异质性,这在一定程度上限制了其预测性能。

本文的 GL-STAGGN 模型综合考虑了全局与局部时空相关性以及空间异质性,将静态空间特征明确嵌入到原始输入数据,利用一种新的全局-局部时间感知注意力沿时间维度对全局与局部时间相关性进行建模,利用图注意力以及动态图卷积的方法沿空间维度对全局与局部空间相关性进行建模。最终 GL-STAGGN 表现出了最佳预测性能。

4.5 消融分析

本文在 PEMS08 数据集上进一步评估 GL-STAGGN 中不同组件对模型性能的有效性。本文

设计的 7 种 GL-STAGGN 变体模型如下:

1) w/o TE: 在输入数据部分去除时间位置嵌入, 以研究对序列顺序信息建模的优势。

2) w/o SE: 在输入数据部分去除空间位置嵌入, 以研究对交通网络拓扑结构固有的静态空间特性建模的优势。

3) w/o Tr-Att: 用传统多头自注意力模块代替全局-局部时间感知的多头自注意力模块, 以研究在预测时考虑全局和局部时间动态变化的有效性。

4) w/o G-Att: 在全局-局部时间感知的多头自注意力模块中去除全局分支, 仅保留局部分支, 以研究局部分支对模型预测的影响。

5) w/o L-Att: 在全局-局部时间感知的多头自注意力模块中去除局部分支, 仅保留全局分支, 以研究全局分支对模型预测的影响。

6) w/o GAT: 在 GL-STAGGN 的基础上去除图注意力模块, 以研究局部节点特征聚合对模型预测的有效性。

7) w/o DGCN: 利用普通 GCN 代替动态 DGCN, 以研究动态获取全局空间相关性对模型预测的有效性。

除上述差异外, 所有变体与 GL-STAGGN 都具有相同的设置。不同变体的预测平均结果和 12 个时间步预测结果如图 4、图 5 所示。可以观察到空间位置嵌入对模型的重要性, 说明了考虑空间异质性更有助于模型预测。在去除时间位置嵌入后, 变体性能恶化严重, 表明时间位置嵌入的顺序信息对 GL-STAGGN 仍是一个较为重要的组件。消融实验结果表明, 本文提出的全局-局部时间感知块对提高模型性能具有优越性, 且在仅使用全局分支或仅使用局部分支的情况下, 变体性能并不具有优势。将传统多头自注意力替换全局-局部时间感知块后的变体, 其性能比 GL-STAGGN 差得多。这表明同时考虑全局和局部空间范围内时间变化的影响更有助于捕捉时间动态变化特征以提高模型预测精度。此外, 本文还对去除 GAT 模块和使用简单 GCN 代替动态 GCN 的两个变体进行了实验评估。图 4 和图 5 均表明, 这两个变体在平均性能和随时间步增长的预测性能上都比 GL-STAGGN 要低。这也证明了本文使用 GAT 捕捉空间图的局部节点特征和从全局空间角度使用动态 GCN 灵活地调整空间相关性强度对整体模型预测的有效性。




图 4 GL-STAGGN 的成分分析

Fig.4 Composition analysis of GL-STAGGN




图 5 GL-STAGGN 在预测 12 个时间步上的成分分析

Fig.5 Component analysis of GL-STAGGN in predicting 12 time steps

4.6 参数配置的影响

为进一步探究超参数设置以及残差连接和层归一化对模型性能的影响,本文使用不同的网络配置在 PEMS08 数据集上进行一系列实验。由于模型采用重复堆叠的编码器-解码器架构来捕获特征,在注意力模块中采用多头的方式,因此与模型结构有关的超参数是编解码器层数 L 、注意力头数 h ,还有模型自身的维度 D_{model} 。如图 6 所示,模型维度 D_{model} 从 $\{16, 32, 64, 128\}$ 中搜索,层数 L 从 $\{2, 3, 4, 5\}$ 中

搜索,头数 h 从 $\{2, 4, 8, 16\}$ 中搜索, GL-STAGGN 的性能并没有随着模型维度、编解码器层数以及注意力头数的增加而持续提高,当这些超参数都增加到特定值时, GL-STAGGN 的性能也趋于稳定。当模型维度 $D_{\text{model}}=64$ 、编解码器层数 $L=4$ 、注意力头数 $h=8$ 时, GL-STAGGN 的性能最佳。此外,如果模型只有残差连接或只有层归一化时,很难训练且损失不收敛。当模型既有残差连接又有层归一化时可产生最佳性能。




图 6 不同网络配置对模型性能的影响

Fig.6 Impact of different network configurations on model performance

4.7 时间成本分析

在全局-局部时间感知的多头自注意力模块中,每个节点的多头自注意力操作和卷积操作的计算复杂度分别为 $O(kT^2D_{\text{model}})$ 和 $O(T^2D_{\text{model}})$ 。对于每个时间步,空间动态 GCN 块中的 GCN 操作的计算复杂度为 $O(ND_{\text{model}})$,空间注意力操作的计算复杂度为 $O(N^2D_{\text{model}})$ 。此外,在 PEMS08 和 PEMS04 数据集上使用 NVIDIA GeForce RTX 3080 * 2 的 GPU 对 GL-STAGGN 进行训练,随着样本点数量批次的增加, GL-STAGGN 的训练时间也在线性增长。PEMS08 数据集的批次大小为 16,每个批次的训练时间大约需要 0.25 s。PEMS04 数据集的批次大小为 4,每个批次的训练时间大约需要 0.12 s。

在预测阶段, GL-STAGGN 能通过自回归生成在 0.3 s 内处理批次样本大小为 16 的数据,进行未来 12 个时间步的预测。

5 结束语

本文提出一种新颖的时空图神经网络模型 GL-STAGGN,该模型基于编码器-解码器架构设计,专注于全局与局部的时空感知特性以及空间异质性的捕捉。GL-STAGGN 通过时空位置嵌入聚合交通流的空间异质性,以增强时空数据的特征表示,进而通过全局-局部时间感知的多头自注意力块,和具有图注意力网络及动态图卷积网络的全局-局部空间感知结构对时空数据的嵌入表示进行递进式地学

习。最后利用结合注意力机制的动态图卷积方法进行特征聚合,以深度挖掘交通数据的复杂时空相关性和空间异质性。在两个真实世界的公共交通数据集上的实验结果表明,同时捕捉全局-局部时空相关性和空间异质性对准确预测交通流具有重要作用。GL-STAGGN 较先进的基线模型具有优越的预测性能,能为交通管理工作提供更好的支持。GL-STAGGN 模型还存有一些潜在的缺陷需要进一步改进:首先,GL-STAGGN 缺乏对现实世界数据固有的不确定性的学习,如何有效融合这种不确定性到时空感知学习中是一大挑战;其次,模型的鲁棒性可能受益于纳入更多外部影响因素,比如气象条件、节假日效应等,这些因素在实际交通流动预测中扮演着不可忽视的角色;最后,如何减少该模型算法的自身局限性,提升模型在不同场景下的泛化能力。未来通过这些改进,有望进一步优化 GL-STAGGN 的预测性能,拓宽其在智能交通系统中的应用范围。

参考文献

- [1] 周玮, 闵卫东. 面向交通场景的强鲁棒性场景图生成网络[J]. 计算机工程, 2025, 51(9): 231-241.
ZHOU W, MIN W D. Robust scene graph generation network for traffic scenes[J]. Computer Engineering, 2025, 51(9): 231-241. (in Chinese)
- [2] JIN G Y, LIANG Y X, FANG Y C, et al. Spatio-temporal graph neural networks for predictive learning in urban computing: a survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 36(10): 5388-5408.
- [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] ZIVOT E, WANG J. Vector autoregressive models for multivariate time series[M]. Berlin, Germany: Springer, 2006.
- [5] OKUTANI I, STEPHANEDES Y J. Dynamic prediction of traffic volume through Kalman filtering theory[J]. Transportation Research Part B: Methodological, 1984, 18(1): 1-11.
- [6] WU C H, HO J M, LEE D T. Travel-time prediction with support vector regression[J]. IEEE Transactions on Intelligent Transportation Systems, 2004, 5(4): 276-281.
- [7] VAN L J W C, VAN H C. Short-term traffic and travel time prediction models[J]. Artificial Intelligence Applications to Critical Transportation Issues, 2012, 22(1): 22-41.
- [8] YU B, YIN H T, ZHU Z X. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1709.04875>.
- [9] LI Y G, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1707.01926>.
- [10] GUO S N, LIN Y F, FENG N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting[J]. Artificial Intelligence, 2019, 33(1): 922-929.
- [11] ZHENG C P, FAN X L, WANG C, et al. GMAN: a graph multi-attention network for traffic prediction[J]. Artificial Intelligence, 2020, 34(1): 1234-1241.
- [12] SONG C, LIN Y F, GUO S N, et al. Spatial-temporal synchronous graph convolutional networks: a new framework for spatial-temporal network data forecasting[J]. Artificial Intelligence, 2020, 34(1): 914-921.
- [13] LI M Z, ZHU Z X. Spatial-temporal fusion graph neural networks for traffic flow forecasting[J]. Artificial Intelligence, 2021, 35(5): 4189-4196.
- [14] LAN S Y, MA Y T, HUANG W, et al. DSTAGNN: dynamic spatial-temporal aware graph neural network for traffic flow forecasting[C]//Proceedings of International Conference on Machine Learning. Washington D. C., USA: IEEE Press, 2022: 11906-11917.
- [15] LUO X L, ZHU C J, ZHANG D T, et al. Dynamic graph convolution network with spatio-temporal attention fusion for traffic flow prediction[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/2310.08328>.
- [16] 周楚昊, 林培群. 基于多通道 Transformer 的交通量预测方法[J]. 计算机应用研究, 2023, 40(2): 435-439.
ZHOU C H, LIN P Q. Traffic flow prediction method based on multi-channel Transformer[J]. Application Research of Computers, 2023, 40(2): 435-439. (in Chinese)
- [17] XU X, ZHANG L, LIU B L, et al. Transport-hub-aware spatial-temporal adaptive graph Transformer for traffic flow prediction[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/2310.08328>.
- [18] LIU A Y, ZHANG Y Y. Spatial-temporal interactive dynamic graph convolution network for traffic forecasting[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/2205.08689>.
- [19] FU R, ZHANG Z, LI L. Using LSTM and GRU neural network methods for traffic flow prediction[C]//Proceedings of the 31st Youth Academic Annual Conference of Chinese Association of Automation. Wuhan, China: [s. n.], 2016: 324-328.
- [20] CHO K, MERRIENBOER B V, GÜLÇEHRE Ç, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1406.1078>.
- [21] CUI Z Y, KER M, PU Z Y, et al. Stacked bidirectional and unidirectional LSTM recurrent neural network for forecasting network-wide traffic state with missing values[J]. Transportation Research Part C: Emerging Technologies, 2020, 118: 102674.
- [22] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015, 54: 187-197.
- [23] 倪庆剑, 彭文强, 张志政, 等. 基于信息增强传输的时空图神经网络交通流预测[J]. 计算机研究与发展, 2022, 59(2): 282-293.
- [24] NI Q J, PENG W Q, ZHANG Z Z, et al. Spatial-temporal graph neural network for traffic flow prediction based on information enhanced transmission[J]. Journal of Computer Research and Development, 2022, 59(2): 282-293. (in Chinese)
- [25] CUI Z, KE R, PU Z, et al. Deep bidirectional and unidirectional LSTM recurrent neural network for network-wide traffic speed prediction[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1801.02143>.
- [26] VAN DEN OORD A, DIELEMAN S, ZEN H, et al. WaveNet: a generative model for raw audio[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1609.03499>.
- [27] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1803.01271>.

- [27] ZHANG J B, ZHENG Y, QI D K. Deep spatio-temporal residual networks for citywide crowd flows prediction [J]. Artificial Intelligence, 2017, 31(1): 332-343.
- [28] YAO H X, TANG X F, WEI H, et al. Revisiting spatial-temporal similarity: a deep learning framework for traffic prediction [J]. Artificial Intelligence, 2019, 33(1): 5668-5675.
- [29] HUANG R, HUANG C, LIU Y, et al. LSGCN: long short-term traffic prediction with graph convolutional networks [C] // Proceedings of the IJCAI'20. Washington D. C., USA: IEEE Press, 2020: 2355-2361.
- [30] ZHAO Y J, LIN Y F, WEN H M, et al. Spatial-temporal position-aware graph convolution networks for traffic flow forecasting [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 24(8): 8650-8666.
- [31] CIRSTEAN R G, YANG B, GUO C J, et al. Towards spatio-temporal aware traffic time series forecasting [C] // Proceedings of the 38th IEEE International Conference on Data Engineering. Washington D. C., USA: IEEE Press, 2022: 2900-2913.
- [32] LIU H Y, ZHU C J, ZHANG D T, et al. Attention-based spatial-temporal graph convolutional recurrent networks for traffic forecasting [M]. Berlin, Germany: Springer, 2023.
- [33] WU Z, PAN S, LONG G, et al. Graph wavenet for deep spatial-temporal graph modeling [EB/OL]. [2024-02-10]. <https://arxiv.org/pdf/1906.00121>.
- [34] 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.
- [35] KONG J L, FAN X M, ZUO M, et al. ADCT-Net: adaptive traffic forecasting neural network via dual-graphic cross-fused transformer [J]. Information Fusion, 2024, 103: 102122.
- [36] BUI K N, CHO J, YI H. Spatial-temporal graph neural network for traffic forecasting: an overview and open research issues [J]. Applied Intelligence, 2022, 52(3): 2763-2774.
- [37] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of Advances in Neural Information Processing Systems. Cambridge, USA: MIT Press, 2017: 303-315.
- [38] BELKIN M, NIYOGI P. Laplacian eigenmaps and spectral techniques for embedding and clustering [C] // Proceedings of Advances in Neural Information Processing Systems. Cambridge, USA: MIT Press, 2002: 585-592.
- [39] WANG K F, AN J, ZHOU M C, et al. Minority-weighted graph neural network for imbalanced node classification in social networks of Internet of people [J]. IEEE Internet of Things Journal, 2022, 10(1): 330-340.
- [40] YE Y Q, XIAO Y, ZHOU Y X, et al. Dynamic multi-graph neural network for traffic flow prediction incorporating traffic accidents [J]. Expert Systems with Applications, 2023, 234: 121101.
- [41] GUO S N, LIN Y F, WAN H Y, et al. Learning dynamics and heterogeneity of spatial-temporal graph data for traffic forecasting [J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(11): 5415-5428.
- [42] STEPHANEDES Y, MICHALOPOULOS P, PLUM R. Comparative performance evaluation of demand and prediction algorithms [J]. Traffic Engineering & Control, 1981, 22(32): 443-452.

文字编辑 索书志
栏目编辑 宋 圆