

# 基于双通道时空融合的图神经网络交通流预测

张震<sup>1</sup>, 李卓<sup>1</sup>, 刘博<sup>2</sup>, 马继骏<sup>3</sup>, 孔令涛<sup>3</sup>, 王子昂<sup>3</sup>

(1. 郑州大学 电气与信息工程学院, 河南 郑州 450001; 2. 郑州大学 河南先进技术研究院, 河南 郑州 450001; 3. 河南省交通运输厅, 河南 郑州 450016)

**摘要:** 针对现有交通流预测方法未能充分捕获异质时序特征以及在建模动态空间依赖性时难以准确捕捉其时变特性等问题, 提出了一种基于双通道时空融合机制的图神经网络模型(DC-STGNN)。在时间维度上, 设计基于离散小波变换的解耦层, 将交通序列分解为低频与高频分量, 并分别采用频域增强模块与多尺度扩张因果卷积进行建模, 精准捕捉异构时序特征; 设计时间门控机制, 根据交通动态变化调节长期趋势和短期扰动之间的权重, 实现更具针对性的时间特征提取, 提升模型对不同时间尺度的适应能力。在空间维度上, 融合多阶扩散图卷积与多头图注意力机制进行建模, 分别提取交通网络中的静态结构特征和动态空间依赖性, 有效刻画了复杂交通网络中动态空间交互模式; 设计空间门控机制, 自适应地融合静态与动态图信息, 有效增强模型对复杂空间结构的建模能力。最后在真实的交通数据集 PEMS-04、PEMS-08、PEMS-BAY 和 METR-LA 上分别进行了 15、30 和 60 min 的交通流量预测实验。实验结果表明: DC-STGNN 相较于多个基线模型, 在 MAE、RMSE 和 MAPE 3 项预测指标上基本保持最优, 表现出更高预测精度与长期稳定性。

**关键词:** 交通流预测; 频域注意力机制; 离散小波变换; 多阶图卷积; 多头图注意力

**中图分类号:** TP391 **文献标志码:** A **doi:** 10.13705/j.issn.1671-6833.2026.02.004

交通流预测是智能交通系统(ITS)的关键技术之一, 其核心任务是基于历史交通信息, 预测未来时段的交通状态。准确的交通流预测不仅有助于缓解道路拥堵, 还能为交通调度和应急管理提供决策支持。

早期的研究主要以知识驱动方法为主, 如排队论<sup>[1]</sup>, 该方法通过描述交通系统中的排队机制来模拟车辆的流动特征, 然而在现实交通网络中, 其表达能力受到较大限制。随着计算能力的提升和数据规模的扩大, 数据驱动方法逐渐成为研究热点, 如自回归积分滑动平均(ARIMA)<sup>[2]</sup>和卡尔曼滤波(Kalman filter)<sup>[3]</sup>等方法, 这类方法可建模交通时序的线性特征, 适用于短期预测任务。

当前主流模型主要聚焦于时间、空间两个维度。时间维度上, 循环神经网络(RNN)<sup>[4]</sup>及其改进版本, 如长短期记忆网络(LSTM)<sup>[5]</sup>和门控循环单元(GRU)<sup>[6]</sup>, 有效解决了梯度消失问题。空间维度上, 研究者利用卷积神经网络(CNN)提取空间特

征<sup>[7]</sup>。但由于道路网络具有非欧几里得拓扑结构, 难以有效对节点间的空间依赖关系进行建模。为了解决这个问题, 图神经网络(GNN)<sup>[8]</sup>逐渐应用于交通预测任务, 以更好地建模道路网络的空间关系。由于交通路网具备天然的图结构, 如图注意力网络(GAT)<sup>[9]</sup>和图卷积网络(GCN)<sup>[10]</sup>等方法, 能够直接对节点之间的连接关系进行建模, 从而提取有效的空间特征。在此基础上, 研究人员进一步将时间建模方法与图结构结合, 如 STGCN<sup>[11]</sup>和 DCRNN<sup>[12]</sup>等, 实现了对交通流中时空特征的联合建模。此后, 研究持续深化, 部分工作引入新的图建模机制以提升对复杂依赖关系的建模能力, 如 MGHCN<sup>[13]</sup>利用超图卷积机制, 将传统图中边关系映射为超图节点, 从而实现潜在的时空依赖建模; STSF-GACN<sup>[14]</sup>采用 Wasserstein 距离构建时空相似性矩阵, 从而实现自适应邻接矩阵优化; ASTAM<sup>[15]</sup>通过多尺度时间分段建模, 增强了对复杂时空依赖的感知能力。

尽管现有模型在时空特征提取方面取得了一定

收稿日期: 2026-01-20; 修订日期: 2026-03-29

基金项目: 河南省重点研发专项(231111211600); 河南省交通运输厅科技项目(2019G3)

作者简介: 张震(1966—), 男, 河南郑州人, 郑州大学教授, 博士, 博士生导师, 主要从事计算机视觉、交通流量预测的研究, E-mail: zhangzhen66@126.com。

进展,但在现实交通场景中仍面临一些挑战。在时间维度上,多数方法采用单一架构处理所有时序模式,难以区分长期趋势与短期扰动。例如,早晚高峰的周期性波动与交通事故引发的剧烈变化。因此,当采用单一建模方式对这两种时序特征进行处理时,信息相互干扰,影响预测精度。在空间维度上,大多数方法采用了静态图或自适应图进行建模,这些方法难以应对道路网络中不断变化的动态依赖关系。综上所述,如何有效区分异质时间特征、动态感知空间结构演变,是目前交通流量预测研究需要解决的关键问题。

相较于上述模型的不足,本文提出了一种基于双通道时空融合的图神经网络模型(traffic flow prediction based on a dual-channel spatio-temporal graph neural network, DC-STGNN),该模型在时间维度上,摒弃了传统的统一建模结构,通过解耦长期趋势和短期扰动,分别建模异质时序特征;在空间维度上,利用交通状态与时空特征生成动态图,结合自适应图机制,同时建模静态和动态的空间关系。

## 1 交通流量预测问题定义

### 1.1 交通网络

在智能交通系统中,道路网络通常可以建立一个图结构模型,记作  $G=(V,E,A)$ ,其中  $V$  表示道路网络中的节点集合,  $|V|=N$  表示节点数量(如路口或传感器位置);  $E$  为边的集合,表示节点之间的交通连接关系;邻接矩阵  $A \in \mathbf{R}^{N \times N}$  表示节点之间的连接关系,反映道路之间的空间结构特征。

### 1.2 交通序列

在图结构的基础上,不同时刻的交通状态可通过

图上信号表征。具体而言,在时间步  $t$ , 整个交通网络的状态被表示为图信号  $X_t \in \mathbf{R}^{N \times F}$ , 其中  $N$  代表节点数量,对应交通网络里的一个个路网节点;  $F$  为每个节点的特征维度数,涵盖速度、流量、密度等交通参数。这些特征共同刻画了该时刻的交通状况。

### 1.3 交通流预测

交通流预测指根据历史观测到的交通流数据,预测未来一段时间内的交通状态。通常,模型以过去  $T$  个连续时间步的图信号序列作为输入,表示为  $X=[X_{(t-T+1)}, \dots, X_{(t)}] \in \mathbf{R}^{T \times N \times F}$ , 通过学习一个预测函数  $F$ , 预测未来  $T'$  个连续时间步内的交通图信号序列,表示为  $\hat{Y}=[\hat{X}_{(t+1)}, \dots, \hat{X}_{(t+T')}] \in \mathbf{R}^{T' \times N \times F}$ 。综上所述,整个预测过程可以表示为

$$\hat{Y} = F(X, A) \tag{1}$$

式中:  $X$  表示输入的图信号;  $\hat{Y}$  表示模型预测的图信号;  $A$  表示交通网络的邻接矩阵。

## 2 模型设计

### 2.1 模型简介

DC-STGNN 的整体框架如图 1 所示。核心由 3 个模块组成:解耦层(decoupling layer, DL)、异质时间建模器(heterogeneous temporal learner, HTL)和多阶动态空间建模器(multi-order dynamic spatial learner, MDSL)。解耦层利用离散小波变换(DWT)对交通序列进行频域分解,以识别并建模不同时间尺度下的异质时间特征;HTL 针对解耦得到的异质时间特征,分别建模高、低频序列;MDSL 模块用于捕捉交通状态的动态属性和内在特性。各模块的具体细节将在下文展开介绍。

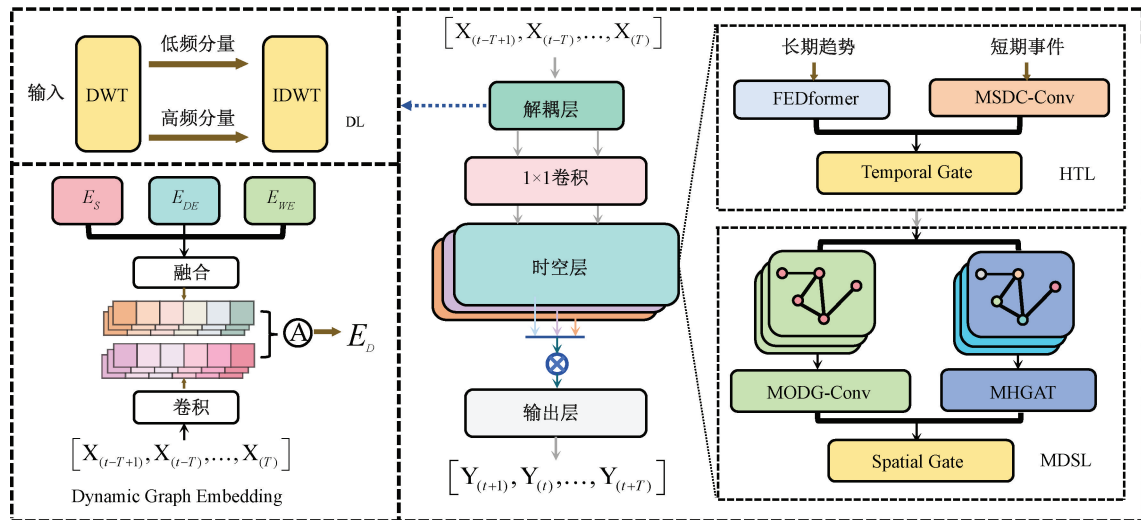


图 1 模型框架

Figure 1 model framework

## 2.2 解耦层

解耦层利用 DWT 将输入的交通序列分解为不同的频率分量。低频分量表征交通状态中的长期趋势(例如早晚高峰),高频分量反映短期波动(例如交通事故或极端天气)。

具体来说,采用图 2 所示的双层 DWT 架构。在每一层中,信号依次通过低通滤波器  $l$  和高通滤波器  $h$  进行卷积与下采样处理,从而逐级提取频率成分。首次分解得到低频子序列  $\mathbf{X}^l(1)$  和高频子序列  $\mathbf{X}^h(1)$ ;接着对  $\mathbf{X}^l(1)$  进行二次分解,得到更深层的低频分量  $\mathbf{X}^l(2)$  与高频分量  $\mathbf{X}^h(2)$ 。




图 2 双层离散小波变换结构示意图

Figure 2 A schema of two-level discrete wavelet transform

此后,利用逆离散小波变换(IDWT)将分解后的各频域分量重构回时间域,得到保持原始维度的序列。为降低模型复杂度和计算开销,将所有高频分量通过线性变换统一映射到一个高维表示空间中。最终,长期趋势特征与短期扰动特征的公式分别为

$$\mathbf{X}_l = \mathbf{W} \tilde{\mathbf{X}}^l(2) + b^l; \quad (2)$$

$$\mathbf{X}_h = \mathbf{W}_{h_1} \tilde{\mathbf{X}}^h(1) + \mathbf{W}_{h_2} \tilde{\mathbf{X}}^h(2) + b^h. \quad (3)$$

式中:  $\tilde{\mathbf{X}}^l(2)$ 、 $\tilde{\mathbf{X}}^h(2)$  和  $\tilde{\mathbf{X}}^h(1)$  分别为对应分量的 IDWT 重构序列;  $\mathbf{W} \in \mathbf{R}^{F \times D}$ ,  $b \in \mathbf{R}^D$  为线性变换中的可学习参数,分别表示权重矩阵与偏置项。

## 2.3 异质时间建模器 (HTL)

在交通时间序列中,低频分量代表长期趋势,其特点是变化缓慢、稳定性强,且当时间跨度较大时,这些长期趋势仍保持较强相关性;高频分量代表短期事件,如交通事故等,其变化较低频分量更剧烈,具有明显的局部性和波动性。针对这种时间异质性,本文设计了一个双通道时间建模结构,即异质时间建模器 (HTL)。HTL 可分别对长期趋势与短期波动进行建模,有效从异质时间特征中提取互补信息以提升整体模型对长期复杂交通的建模能力。

### 2.3.1 频域增强模块 (FEDformer)

本文在趋势建模通道中引入了频域增强解耦网络 (FEDformer)<sup>[16]</sup>,从频域角度对低频趋势成分建模,提升长期依赖建模能力。趋势通道输入记为  $\mathbf{X}_l \in \mathbf{R}^{T \times N \times D}$ ,其中  $T$  为时间步数,  $N$  为节点数,  $D$  为

特征维度。

FEDformer 首先对输入序列进行快速傅里叶变换 (FFT),并利用随机模式选择策略仅保留少量关键频率模式,得到<sup>[16]</sup>:

$$F(\mathbf{Z}) = \text{Select}(F(\mathbf{X}_l)) \cdot R. \quad (4)$$

式中:  $F$  表示傅里叶变换;  $R \in \mathbf{C}^{M \times D \times D}$  是可学习的频域卷积核,  $M \ll T$  表示所选频率模式数量。随后,对频域建模结果进行零填充,并通过逆傅里叶变换还原至时间域,得到趋势建模输出<sup>[16]</sup>:

$$\mathbf{Z}_{\text{FED}} = F^{-1}(\text{Padding}(F(\mathbf{Z}))) \in \mathbf{R}^{T \times N \times D}. \quad (5)$$

该输出  $\mathbf{Z}_{\text{FED}}$  表示模型在趋势通道下对长期演化模式的建模结果,将作为后续时间融合模块的重要输入。

相较于传统时间卷积或注意力机制, FEDformer 采用的频域表示与随机模式选择机制,不仅能捕捉时序中的全局结构,还具有线性计算复杂度,显著提升了模型对长时间序列建模的效率及精度。

### 2.3.2 多尺度扩张因果卷积 (MSDC-Conv)

交通序列中的事件通常呈现短时突变特性,其动态特征集中于连续时段内,具有显著局部性和高频性<sup>[17]</sup>。为有效提取短时扰动特征,本文在事件建模通道中引入多尺度扩张因果卷积 (multi-scale dilated causal convolution, MSDC-Conv),旨在从不同时间尺度上建立交通事件的瞬时响应模型。该结构通过并行设置多个扩张因子,在不增加卷积核的前提下扩展感受野,从而在多个时间范围内捕获高频信息,提升对复杂扰动的表征能力。设输入序列为

$$\mathbf{X}_h \in \mathbf{R}^{T \times N \times D}. \quad (6)$$

式中:  $T$  为时间步数;  $N$  为节点数量;  $D$  为特征维度。为获取不同时间尺度下的特征响应,模型采用多个扩张因子  $\{d_1, d_2, \dots, d_m\}$  并行建模,将各尺度卷积结果在通道维度聚合,得到最终输出:

$$\mathbf{Z}_{\text{msconv}} = \text{Aggregate} \{ \mathbf{X}_h *_{\tau, d_i} f_i \}_{i=1}^m. \quad (7)$$

式中:  $\mathbf{Z}_{\text{msconv}} \in \mathbf{R}^{T \times N \times D}$ ;  $\text{Aggregate}(\cdot)$  表示特征聚合操作;  $*_{\tau, d}$  表示扩张因果卷积。

该多尺度设计能够在多个感知范围内刻画交通事件的时序演化过程,有助于提升模型对短期扰动的表达能力和预测精度。

### 2.3.3 时间门控 (temporal gate)

在交通状态的演化过程中,长期趋势与短期事件的影响程度在不同时间段可能存在显著差异。例如,在高峰拥堵时段短期事件往往起主导作用,而在平稳运行时段则更多受到长期趋势的主导。为此,本文设计了时间门控机制,以实现趋势分量和事件分量的动态加权融合,从而自适应提取对当前时

刻最具代表性的时间特征。

该机制以趋势通道的输出  $\mathbf{Z}_{\text{FED}} \in \mathbf{R}^{T \times N \times D}$  与事件通道的输出  $\mathbf{Z}_{\text{msconv}} \in \mathbf{R}^{T \times N \times D}$  为输入,通过门控权重自适应调节两者的影响程度,其计算过程如下:

$$\mathbf{G} = \sigma(\mathbf{Z}_{\text{msconv}} \mathbf{W}_e + \mathbf{Z}_{\text{FED}} \mathbf{W}_i + b); \quad (8)$$

$$\mathbf{Z}_T = \mathbf{G} \odot \mathbf{Z}_{\text{msconv}} + (1 - \mathbf{G}) \odot \mathbf{Z}_{\text{FED}}. \quad (9)$$

式中:  $\mathbf{G} \in \mathbf{R}^{T \times N \times D}$  表示门控权重;  $\sigma(\cdot)$  为 Sigmoid 激活函数;  $\mathbf{W}_e, \mathbf{W}_i \in \mathbf{R}^{D \times D}, b \in \mathbf{R}^D$  为可学习参数;  $\odot$  表示逐元素乘法 (Hadamard 乘积);  $\mathbf{Z}_T \in \mathbf{R}^{T \times N \times D}$  为时间建模模块最终融合输出。

该门控机制能够根据不同时间片的上下文动态调整趋势与事件之间的权重,有效提升模型在不同交通状态下的时间建模能力。

## 2.4 多阶动态空间建模器 (MDSL)

交通网络既具有稳定的拓扑结构,还具有动态变化的空间依赖关系。为了充分捕捉这种多层次、时变性的空间相关性,本文设计了 MDSL。该模块融合了静态图与动态图结构,结合多阶扩散机制与多头注意力机制,从而在多个尺度上捕捉交通网络中的空间交互模式,提升模型对复杂空间依赖的建模能力。

### 2.4.1 静态图建模

从长期视角看,交通网络的拓扑结构相对稳定。本文于节点嵌入生成静态邻接图,用于表示交通网络的固有结构属性。

具体而言,本文为每个节点学习两个嵌入矩阵  $\mathbf{E}_1, \mathbf{E}_2 \in \mathbf{R}^{N \times \varphi}$  其中,  $N$  表示节点数;  $\varphi$  表示嵌入维度,这两个矩阵在模型初始化阶段由随机初方式生成,并在端到端训练过程中通过反向传播算法不断优化,具备良好的可训练性和自适应性。该过程不依赖于外部先验知识或现有图结构,完全数据驱动方式完成。随后,将两个嵌入矩阵进行点积运算,并进行 ReLU 激活与 Softmax 归一化处理,得到静态图邻接矩阵<sup>[18]</sup>:

$$\mathbf{A}_s = \text{softmax}(\text{ReLU}(\mathbf{E}_1 \mathbf{E}_2^T)). \quad (10)$$

式中:  $\text{ReLU}(\cdot)$  激活函数用于抑制弱相关性;  $\text{softmax}(\cdot)$  用于归一化邻接权重。

在得到静态图  $\mathbf{A}_s$  后,我们引入多阶扩散图卷积 (Multi-order Diffusion Graph Convolution, MODG-Conv)。通过聚合  $K$  阶扩散特征,得到静态图空间建模输出为:

$$\mathbf{Z}_{\text{DGCN}} = \text{Concat}[\mathbf{Z}^{(1)}, \mathbf{Z}^{(2)}, \dots, \mathbf{Z}^{(K)}]. \quad (11)$$

与传统图卷积方法仅关注一阶邻接特征不同,MODG-Conv 采用多阶扩散机制,具有更强的结构建模能力。可有效捕捉远距离节点间依赖关系,从而

增强模型对交通网络全局结构的理解,特别适用于建模长期稳定的交通模式。

### 2.4.2 动态图建模

为了建模交通网络中随时间演化的空间依赖关系,本文提出了一种数据驱动的动态图生成方法,用于刻画时变的节点交互结构(图 1 中左下角“Dynamic Graph Embedding”)。该模块负责生成每个时间步下的动态图邻接矩阵。

具体而言,以当前时刻的节点输入特征  $\mathbf{X}_t$  为基础,结合可学习的空间与时间嵌入  $\mathbf{E}_{\text{ST}} \in \mathbf{R}^{N \times D}$ ,生成每个节点在该时刻下的动态表示<sup>[19]</sup>:

$$\mathbf{E}_d = \tanh(\mathbf{W}_d \mathbf{X}_t \odot \mathbf{E}_{\text{ST}}). \quad (12)$$

式中:  $\mathbf{W}_d \in \mathbf{R}^{D \times d}$  是可学习的线性映射矩阵;  $\odot$  表示逐元素乘法;  $\mathbf{E}_{\text{ST}} = \mathbf{E}_s \odot (\mathbf{E}_w \odot \mathbf{E}_D)$ , 其中  $\mathbf{E}_s, \mathbf{E}_w, \mathbf{E}_D \in \mathbf{R}^{N \times D}$  分别表示空间嵌入、周周期嵌入和日周期嵌入,均为可训练参数。

接着用嵌入间的相似性得分作为连接强度,并通过非线性变换与归一化构造邻接矩阵<sup>[18]</sup>:

$$\mathbf{A}_d = \text{softmax}(\text{ReLU}(\mathbf{E}_d \mathbf{E}_d^T)). \quad (13)$$

式中:  $\mathbf{A}_d \in \mathbf{R}^{N \times N}$  表示当前时间步下生成的动态图邻接矩阵,刻画了时刻  $t$  下节点间的动态相关性。该构图方法无需预定义拓扑,可自适应反映节点关系的动态变化,在突发事件或流量波动下尤为有效。已有研究如 Graph WaveNet<sup>[18]</sup>,也采用了类似思路,验证了该方法在实际应用中的有效性。

在此基础上,本文引入多头图注意力机制 (multi-head graph attention network, MH-GAT)。该机制结合动态图邻接矩阵所反映的时变结构,在多个注意力子空间中并行计算节点间的依赖关系,并对邻居特征进行加权聚合。

设动态图邻接矩阵为  $\mathbf{A}_d^i \in \mathbf{R}^{N \times N}$ , 节点特征为  $\mathbf{X} \in \mathbf{R}^{N \times F}$  则第  $c$  个注意力头的输出为<sup>[19]</sup>

$$\mathbf{Z}_i^{(c)} = \sigma \left( \sum_{j \in \mathcal{J}_d^c(i)} \alpha_{ij}^{(c)} \mathbf{W}^{(h)} \mathbf{X}_j \right). \quad (14)$$

式中:  $\alpha_{ij}^{(h)}$  为第  $c$  个子空间中节点  $i$  与节点  $j$  的注意力权重;  $\mathbf{W}^{(c)}$  为该头的线性变换参数;  $\sigma(\cdot)$  为激活函数。最终,所有注意力头的输出通过拼接操作得到融合表示<sup>[19]</sup>:

$$\mathbf{Z}_{\text{GAT}}(i) = \parallel_{h=1}^H \mathbf{Z}_i^{(c)}(i). \quad (15)$$

该空间特征将输入后续的空间门控机制,与静态图通道提取的特征进行融合。

与静态图建模相比,动态图可根据不同时间步的输入状态与时间嵌入自适应地生成空间连接,更具灵活性。尤其在突发事件或流量波动下,结合 MH-GAT 的动态图建模能够从多个子空间刻画节点

间的动态耦合,更准确地反映交通网络的非平稳性。综上,MODG-Conv和MH-GAT分别从静态与动态层面建模空间依赖,最后通过空间门控融合有效提升了建模精度和对复杂结构变化的适应性。

### 2.4.3 空间门控(spatial gate)

在分别获得了静态图通道的多阶扩散特征  $\mathbf{Z}_{\text{DGCN}} \in \mathbf{R}^{T \times N \times D}$  与动态图通道的多头图注意力特征  $\mathbf{Z}_{\text{GAT}} \in \mathbf{R}^{T \times N \times D}$  之后,本文引入空间门控单元自适应融合两类信息,在保留静态结构稳定性的同时,更好地响应交通图结构的动态变化。

具体地,空间融合输出定义如下:

$$\mathbf{Z}_S = \mathbf{G} \odot \mathbf{Z}_{\text{DGCN}} + (1 - \mathbf{G}) \odot \mathbf{Z}_{\text{GAT}}. \quad (16)$$

式中: $\odot$ 表示逐元素乘法。

门控权重  $\mathbf{G}$  由以下公式计算:

$$\mathbf{G} = \sigma(\mathbf{Z}_{\text{DGCN}} \mathbf{W}_{\text{dg}} + \mathbf{Z}_{\text{GAT}} \mathbf{W}_{\text{ga}} + b). \quad (17)$$

式中: $\mathbf{W}_{\text{dg}}, \mathbf{W}_{\text{ga}} \in \mathbf{R}^{D \times D}$  和  $b \in \mathbf{R}^D$  为可学习参数; $\sigma(\cdot)$  为 Sigmoid 激活函数。

通过该门控机制,模型可以根据具体的输入特征自适应调整静态和动态空间信息的融合比例,有效提升时变复杂结构下的建模能力。

## 2.5 输出层

模型采用堆叠式时空融合结构,通过联合多个时空建模单元,逐层提取复杂的交通依赖特征。为了提升模型的信息保持能力与训练稳定性,引入了残差连接机制,以实现历史信息的深度传递。

最终的时空融合输出由时间建模模块输出  $\mathbf{Z}_T$  与空间建模模块输出  $\mathbf{Z}_S$  相加获得,即  $\mathbf{Z}_{\text{out}} = \mathbf{Z}_T + \mathbf{Z}_S$ 。为了实现多步交通预测,本文设计了一个前馈全连接输出层,直接将融合特征映射到预测结果:

$$\hat{\mathbf{Y}} = \text{FC}_{\text{out}}(\mathbf{Z}_{\text{out}}). \quad (19)$$

式中: $\hat{\mathbf{Y}} \in \mathbf{R}^{T \times N \times D'}$  为最终预测结果, $D'$  为输出特征维度,通常对应预测的未来时间步数; $\text{FC}_{\text{out}}(\cdot)$  表示全连接层。

训练过程中采用 MAE 作为优化目标,其定义如下:

$$\mathcal{L} = \frac{1}{T \times N \times D'} \sum_{t=1}^T \sum_{n=1}^N \sum_{d=1}^{D'} |\hat{Y}_{t,n,d} - Y_{t,n,d}|. \quad (20)$$

式中: $\mathcal{L}$  表示 MAE 损失函数; $\hat{Y}_{t,n,d}$  表示第  $t$  个时间步、节点  $n$ 、维度  $d$  的预测值; $Y_{t,n,d}$  为对应的真实值。

## 3 实验

### 3.1 数据集

本文在 4 个公开的交通数据集上进行了实验,

包括 PEMS-04、PEMS-08、PEMS-BAY、METR-LA 数据集。PEMS-04 与 PEMS-BAY 覆盖美国旧金山湾区,分别包含 307 和 325 个探测器;PEMS-08 采集自美国加州圣贝纳迪诺地区,包含 170 个环形探测器;METR-LA 采集自美国洛杉矶市,共有 207 个探测器。各数据集采样频率均为每 5 min 一次。

数据集的详细信息如表 1 所示,其中“S”表示交通速度,“F”表示交通流量,“O”表示道路占用率。

表 1 数据集详细信息

Table 1 Dataset details

数据集	节点数	样本数	采样间隔/min	数据类型
PEMS-04	307	16 992	5	S,F,O
PEMS-08	170	17 856	5	S,F,O
METR-LA	207	34 272	5	F
PEMS-BAY	325	52 116	5	S

### 3.2 实验设置

本文采用 3 种常用的性能评估指标:平均绝对误差(MAE)、均方根误差(RMSE)以及平均绝对百分比误差(MAPE)。实验前我们对原始数据进行了以下预处理操作:首先,针对部分传感器的缺失数据,采用线性插值的方法进行填补,数据采用标准化 MIN-MAX 将各节点的数据归一化至  $[0, 1]$  区间。

以下为模型训练过程中具体设置:所有实验基于 PyTorch2.0.1 和 CUDA11.8 框架完成。主要依赖库包括 numpy、scipy 和 PyWavelets 等。批量大小为 64,初始学习率为 0.001,优化器采用 Adam。最大训练迭代轮数为 100,并使用输入序列离散小波变换分解为高、低频子序列,分解层数设为 2。低频通道采用 FEDformer 提取长期趋势特征,高频通道采用多尺度扩张因果卷积提取短期扰动特征,卷积核大小设置为 2。静态图采用多阶扩散图卷积,扩散阶数  $K$  为 2。动态图部分结合时空嵌入生成动态邻接图,并通过多头图注意力机制提取动态空间关系,其中注意力头数设为 4,每个头的嵌入维度为 16,总嵌入维度为 64。

数据集按 7:1:2 的比例划分训练集、验证集和测试集。实验基于 PyTorch 框架的本地环境中完成,实验平台配置为 RTX 3080TI (12 GB) 与 13th Gen Intel(R) Core(TM) i5-13490F 处理器。

### 3.3 基准模型

为验证本文所提模型的有效性,本文选取经典统计预测方法 HA<sup>[20]</sup>、纯卷积架构模型 STGCN<sup>[11]</sup>、扩散图卷积模型 DCRNN<sup>[12]</sup>、自适应图结构模型 GWNEN<sup>[18]</sup> 与 AGCRN<sup>[22]</sup>、渐进图卷积模型 PGCN<sup>[21]</sup>

等经典及先进方法作为基准,开展对比实验。

### 3.4 模型复杂度分析

设置序列长度为  $T$ , 交通网络节点数为  $N$ , 节点特征维度为  $d$ , 注意力头数为  $H$ , 扩张卷积感受野大小为  $r$ , 扩散阶数为  $K$ 。

首先 DWT 及其逆变换 IDWT 均可利用快速算法实现,时间复杂度为  $O(T)$ , 对整体计算开销贡献较小。在 HTL 模块中, FEDformer 模块进行频域建模,计算复杂度为  $O(T \log T)$ , 相较于传统的 Transformer, FEDformer 在长序列处理上更为高效;高频分量通过多尺度扩张因果卷积提取短期扰动,计算复杂度为  $O(rTd)$ , 其中感受野大小  $r$  通常较小,保证了计算效率。在 MDSL 模块中,多阶扩散图卷积计算复杂度为  $O(KNd^2)$ , 其中扩散阶数  $K$  通常为小整数;多头图注意力机制复杂度为  $O(Nd^2 + Nkd)$ , 其中  $k$  为节点的平均邻居数,远小于节点总数  $N$ 。

综合来看, DC-STGNN 计算高效、整体复杂度低,模块设计兼顾计算性能和表达能力。

### 3.5 模型性能对比分析

表 2 展示了本文模型与基准模型在 4 个数据集上对未来 15 min、30 min 和 60 min 的预测性能。传统方法 HA 在所有指标上表现最差,难以有效建模处理交通数据的复杂时空依赖。STGCN 和 DCRNN 等方法虽能精度有所提升,但在长期预测任务中易产生误差累积,且在部分数据集上泛化能力不足。GWNET、PGCN 和 AGCRN 等模型引入扩张卷积、自适应图结构或可学习建图机制,在部分场景中展现出优势,但整体表现仍不够稳定,预测精度波动较大。

相比之下,本文模型的预测结果至少在两个指标上最优,在多个数据集的不同时间尺度下均取得领先。选取其中具有代表性的结果进行量化分析,在 PEMS-08 数据集上,30 min 预测任务的

表 2 不同模型预测性能对比

Table 2 Performance comparison of different models

数据集	模型	15 min			30 min			60 min		
		MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
PEMS-04	HA	31.58	52.39	33.78	31.58	52.39	33.78	31.58	52.39	33.78
	STGCN	18.78	29.93	13.33	19.70	31.38	13.94	21.55	33.88	13.92
	DCRNN	18.79	29.65	13.16	20.05	31.51	14.08	20.19	31.64	14.24
	GWNET	18.17	28.98	13.14	19.18	30.54	13.72	21.04	33.14	15.12
	PGCN	18.02	28.85	12.96	19.02	30.35	13.68	20.76	32.70	14.96
	AGCRN	19.11	31.40	<b>12.65</b>	19.84	32.71	<b>13.10</b>	21.46	35.38	14.08
	本文模型	<b>17.69</b>	<b>28.45</b>	12.69	<b>18.34</b>	<b>29.88</b>	13.46	<b>19.99</b>	<b>31.42</b>	<b>13.98</b>
PEMS-08	HA	34.86	59.24	27.88	34.86	59.24	27.88	34.86	59.24	27.88
	STGCN	14.55	22.72	9.38	15.62	24.55	9.84	17.86	27.56	11.14
	DCRNN	14.21	22.19	9.19	15.18	24.01	9.79	16.97	26.90	10.94
	GWNET	13.68	21.61	8.80	14.65	23.43	9.39	16.42	26.25	10.75
	PGCN	13.44	21.53	8.84	14.25	23.12	9.42	15.54	25.31	<b>10.28</b>
	AGCRN	14.78	23.27	9.49	15.77	25.01	10.17	17.52	27.69	11.25
	本文模型	<b>12.81</b>	<b>21.03</b>	<b>8.44</b>	<b>13.54</b>	<b>22.60</b>	<b>9.13</b>	<b>14.62</b>	<b>24.56</b>	10.30
METR-LA	HA	4.15	7.77	12.90	4.15	7.77	12.90	4.15	7.77	12.90
	STGCN	2.88	5.74	7.62	3.47	7.24	9.57	4.59	9.40	12.70
	DCRNN	2.70	5.25	6.94	3.10	6.36	8.48	3.58	7.60	10.39
	GWNET et	2.69	5.15	6.90	3.07	6.22	8.37	3.53	7.37	10.01
	PGCN	2.69	5.14	6.86	3.08	6.19	8.29	3.54	7.35	9.89
	AGCRN	2.85	5.52	7.59	3.23	6.51	9.02	3.61	7.47	10.51
	本文模型	<b>2.63</b>	<b>4.97</b>	<b>6.69</b>	<b>3.02</b>	<b>6.12</b>	<b>8.09</b>	<b>3.38</b>	<b>7.10</b>	<b>9.77</b>
PEMS-BAY	HA	2.88	5.59	6.80	2.88	5.59	6.80	2.88	5.59	6.80
	STGCN	1.36	2.96	2.90	1.81	4.27	4.17	2.49	5.69	5.79
	DCRNN	1.31	2.78	2.74	1.65	3.78	3.70	1.96	4.61	4.64
	GWNET et	1.39	3.00	2.91	1.83	4.22	4.14	2.35	5.42	5.80
	PGCN	1.31	<b>2.74</b>	2.73	<b>1.63</b>	3.68	3.66	1.93	4.43	4.62
	AGCRN	1.37	2.89	2.95	1.70	3.88	3.90	1.97	4.61	4.70
	本文模型	<b>1.30</b>	<b>2.74</b>	<b>2.71</b>	1.64	<b>3.67</b>	<b>3.65</b>	<b>1.91</b>	<b>4.38</b>	<b>4.49</b>

$MAE$  从最优基线 (PGCN) 的 14.25 降至 13.54, 下降约 4.98%;  $RMSE$  降低了约 2.25%,  $MAPE$  下降了 3.08%。在 PEMS-04 数据集的 60 min 预测任务中, 本文模型在  $MAE$  和  $RMSE$  上分别从最优基线 (DCRNN) 的 20.19 和 31.64 降至 19.99 和 31.42。

模型性能提升主要是其在结构设计上具有两方面创新, 一方面引入了基于离散小波变换的解耦机制, 将时间序列分解为长期趋势与短期扰动两个分支, 分别通过 FEDformer 和多尺度扩张因果卷积建模, 增强了模型对异质时间特征的刻画能力; 另一方面, 模型融合了多阶扩散图卷积和多头图注意力机制, 分别从静态拓扑和动态状态角度建模空间依赖, 实现了对稳定结构与时变关联的捕捉。

表 3 模型在 METR-LA 和 PEMS-BAY 数据集上的消融实验结果

Table 3 Ablation experimental results of the model on the METR-LA and PEMS-BAY datasets

数据集	模型	30 min			60 min		
		$MAE$	$RMSE$	$MAPE/\%$	$MAE$	$RMSE$	$MAPE/\%$
PEMS-BAY	w/o 解耦层	1.68	3.74	3.76	1.98	4.47	4.60
	w/o FEDformer	1.92	4.42	4.25	2.32	4.99	5.23
	w/o MSDC-Conv	1.83	3.91	4.07	2.26	4.72	4.95
	w/o MODG-Conv	1.76	3.75	3.81	2.11	4.66	4.70
	w/o MHGAT	1.82	3.99	3.89	2.15	4.74	4.76
	本文模型	1.63	3.67	3.66	1.91	4.38	4.49
METR-LA	w/o 解耦层	3.14	6.31	8.25	3.22	7.39	10.10
	w/o FEDformer	3.46	7.12	8.95	3.96	8.27	11.09
	w/o MSDC-Conv	3.20	6.18	8.45	3.59	7.19	10.28
	w/o MODG-Conv	3.21	6.20	8.41	3.62	7.21	10.25
	w/o MH-GAT	3.15	6.17	8.28	3.51	7.17	9.99
	本文模型	3.02	6.12	8.09	3.38	7.10	9.77

### 3.7 敏感性实验

为了进一步评估模型在动态图空间建模中的灵敏性, 本文针对多头图注意力机制中注意力头数 (Head Number) 这一关键超参数进行了敏感性分析。多头注意力机制通过在不同的子空间中并行建模节点之间的依赖关系, 能够有效提升模型对复杂空间结构的表达能力。然而, 过多的注意力头可能引入冗余信息, 增加计算负担, 导致训练不稳定。本实验在 METR-LA 与 PEMS-08 数据集上, 以 30 min 预测任务为基准, 在保持其他超参数不变的条件下, 分别设置注意力头数量为 1, 2, 4 与 8, 并评估其在  $MAE$ 、 $RMSE$  和  $MAPE$  3 项指标下的表现, 实验结果如图 3 和图 4 所示。

当注意力头数为 4 时, 模型性能最佳, 但数据变化趋势不稳定, 这表明多头机制的引入对动态图空

### 3.6 消融实验

为进一步验证所提模型中各关键模块的有效性, 本文在 METR-LA 和 PEMS-BAY 两个典型交通数据集上设计了消融实验, 探讨各子模块对整体性能贡献。具体设置如下:

w/o 解耦层: 移除解耦层模块; w/o FEDformer: 移除 FEDformer 模块; w/o MSDC-Conv: 移除 MSDC-Conv 模块; w/o MODG-Conv: 移除 MODG-Conv 模块; w/o MH-GAT: 移除 MH-GAT 模块。

表 3 展示了消融实验中各模型变体在 30, 60 min 的对比预测结果, 除去被消融的模块外, 其余设置与原模型完全一致。实验结果表明, 原模型的性能显著优于其他变体模型, 移除任一模块均会导致性能下降, 验证了模块设计的合理性与有效性。

间建模有一定影响, 但头数设置需要结合实际数据调整, 因此本文在实验中将头数设置为 4, 以获得模型的最佳性能。

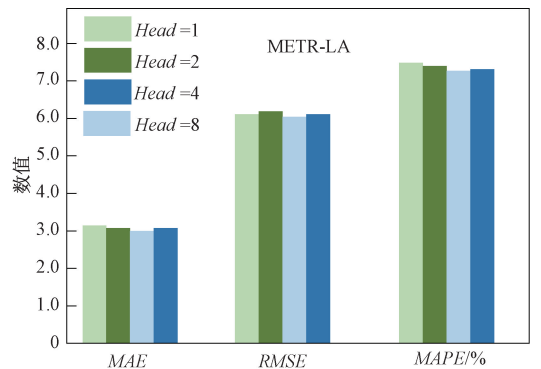


图 3 在 METR-LA 上注意力头数对预测性能的影响  
Figure 3 Impact of attention head number on prediction performance for METR-LA

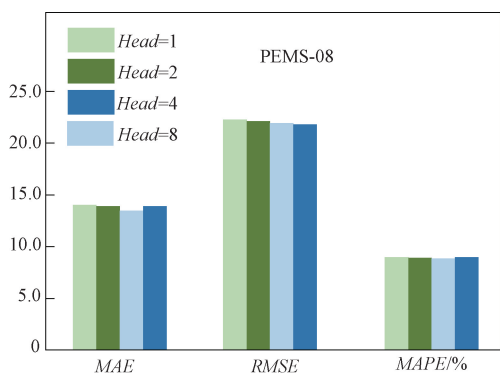


图4 在 PEMS-08 上注意力头数对预测性能的影响

Figure 4 Impact of attention head number on prediction performance for PEMS-08

### 3 结论

本文针对交通流预测中异质时间特征难以建模、空间依赖动态变化难以刻画等问题,提出了一种融合频域解耦机制与动态图建模的双通道时空融合机制的图神经网络模型。在时间建模方面,引入离散小波变换,将交通序列划分为长期趋势与短期扰动,并分别采用频域增强模块处理与多尺度扩张因果卷积建模,提升了模型对异质时间特征的提取能力。在空间建模方面,构建了多阶动态空间结构表征,一方面利用节点嵌入构建静态图,捕捉稳定的拓扑关系,另一方面结合历史状态生成动态图,通过多头图注意力机制,自适应地提取空间特征,提升对复杂空间关系的建模能力。同时引入时间门控与空间门控机制,对多通道特征进行动态加权调节,进一步加强了时空建模的能力。实验结果表明,相较于当前主流模型,本文所提出的 DC-STGNN 在 4 个真实交通数据集上均取得了显著的性能提升,在不同时间尺度的任务中表现稳定,在中长期预测任务中优势更加明显。从频域解耦机制与动态图建模两个角度入手,有助于提升模型对交通流中复杂时空特征的提取能力。本文研究为异质交通模式的长期预测任务提供了一种有效的建模思路。

### 参考文献:

[1] Cascetta E. Transportation systems engineering: theory and methods[M]. Boston: Springer, 2001.

[2] Liu Boyi, Tang Xiangyan, Cheng Jieren, et al. Traffic flow combination forecasting method based on improved LSTM and ARIMA[J]. International Journal of Embedded Systems, 2020, 12(1): 22.

[3] Cai Lingru, Zhang Zhanchang, Yang Junjie, et al. A noise-immune Kalman filter for short-term traffic flow forecasting[J]. Physica A: Statistical Mechanics and its

Applications, 2019, 536: 122601.

[4] Ma Dongfang, Song Xiang, Li Pu. Daily traffic flow forecasting through a contextual convolutional recurrent neural network modeling inter- and intra-day traffic patterns [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(5): 2627-2636.

[5] Han Xu, Gong Shicai. LST-GCN: long short-term memory embedded graph convolution network for traffic flow forecasting[J]. Electronics, 2022, 11(14): 2230.

[6] Yang Yanqun, Lin Jie, Zheng Yubin. Short-time traffic forecasting in tourist service areas based on a CNN and GRU neural network [J]. Applied Sciences, 2022, 12(18): 9114.

[7] Han Lingyi, Zheng Kan, Zhao Long, et al. Short-term traffic prediction based on DeepCluster in large-scale road networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(12): 12301-12313.

[8] Wang Shun, Zhang Yong, Hu Yongli, et al. Knowledge fusion enhanced graph neural network for traffic flow prediction[J]. Physica A: Statistical Mechanics and its Applications, 2023, 623: 128842.

[9] Zhang Yunuo, Wang Xiaoling, Yu Jia, et al. Adaboosting graph attention recurrent network: a deep learning framework for traffic speed forecasting in dynamic transportation networks with spatial-temporal dependencies [J]. Engineering Applications of Artificial Intelligence, 2024, 127: 107297.

[10] Xu Yi, Han Liangzhe, Zhu Tongyu, et al. Generic Dynamic Graph Convolutional Network for traffic flow forecasting[J]. Information Fusion, 2023, 100: 101946.

[11] Yu Bing, Yin Haoteng, Zhu Zhanxing. Spatio-temporal graph convolutional networks: a deep learning framework for traffic forecasting[C]//Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence. Sweden: AAAI, 2018: 3634-3640.

[12] Li Yaguang, Yu R, Shahabi C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[PP/OL]. V1. ArXiv9(2017-07-06)[2025-06-19]. <https://doi.org/10.48550/arXiv.1707.01926>.

[13] Fan Xuanxuan, Qi Kaiyuan, Wu Dong, et al. MGHCN: multi-graph structures and hypergraph convolutional networks for traffic flow prediction[J]. Alexandria Engineering Journal, 2025, 111: 221-237.

[14] Wang Bin, Long Zhendan, Sheng Jinfang, et al. Spatial-Temporal Similarity Fusion Graph Adversarial Convolutional Networks for traffic flow forecasting[J]. Journal of the Franklin Institute, 2024, 361(17): 107299.

[15] Alsehaimi B, Alzamzami O, Alowidi N, et al. An adaptive spatio-temporal traffic flow prediction using self-atten-

- tion and multi-graph networks [J]. *Sensors*, 2025, 25 (1): 282.
- [16] Zhou Tian, Ma Ziqing, Wen Qingsong, et al. FEDformer: frequency enhanced decomposed transformer for long-term series forecasting [C] // International Conference on Machine Learning. Baltimore: PMLR, 2022.
- [17] Xu Xing, Mao Hao, Zhao Yun, et al. An urban traffic flow fusion network based on a causal spatiotemporal graph convolution network [J]. *Applied Sciences*, 2022, 12(14): 7010.
- [18] Wu Zonghan, Pan Shirui, Long Guodong, et al. Graph WaveNet for deep spatial-temporal graph modeling [PP/OL]. V1. arXiv (2019-05-31) [2025-12-06]. <https://doi.org/10.48550/arXiv.1906.00121>.
- [19] Li Yujie, Shao Zezhi, Xu Yongjun, et al. Dynamic frequency domain graph convolutional network for traffic forecasting [C] // Proceedings of the ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway: IEEE, 2024: 5245-5249.
- [20] Li Yaguang, Shahabi C. A brief overview of machine learning methods for short-term traffic forecasting and future directions [J]. *SIGSPATIAL Special*, 2018, 10(1): 3-9.
- [21] Shin Y, Yoon Y. PGCN: progressive graph convolutional networks for spatial-temporal traffic forecasting [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(7): 7633-7644.
- [22] Bai Lei, Bai Lei, Yao Lina, et al. Adaptive graph convolutional recurrent network for traffic forecasting [C] // Proceedings of the 34th International Conference on Neural Information Processing Systems. New York: ACM, 2020: 17804-17815.

## Traffic Flow Prediction Based on a Dual-channel Spatio-temporal Graph Neural Network

ZHANG Zhen<sup>1</sup>, LI Zhuo<sup>1</sup>, LIU Bo<sup>2</sup>, MA Jj<sup>3</sup>, KONG Lt<sup>3</sup>, WANG Za<sup>3</sup>

(1. School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, China; 2. School of Henan Institute of Advanced Technology, Zhengzhou University, Zhengzhou 450001, China; 3. Henan Provincial Department of transportation, Zhengzhou 450016, China)

**Abstract:** To overcome the limitations of existing traffic flow forecasting methods, which often fail to adequately capture heterogeneous temporal patterns and struggle to accurately model the time-varying characteristics of dynamic spatial dependencies, this study proposes a Dual-Channel Spatio-Temporal Graph Neural Network (DC-STGNN). In the temporal dimension, a decoupling layer based on discrete wavelet transform is designed to decompose traffic sequences into low-frequency and high-frequency components. The low-frequency components are modeled using a frequency-enhanced module, while the high-frequency components were captured through multi-scale dilated causal convolution, enabling precise modeling of heterogeneous temporal patterns. In addition, a temporal gating mechanism is introduced to dynamically balance the contributions of long-term trends and short-term fluctuations according to traffic variations, thereby achieving more targeted temporal feature extraction and improving adaptability across different time scales. In the spatial dimension, multi-order diffusion graph convolution and multi-head graph attention are integrated to separately extract static structural features and dynamic spatial dependencies of the traffic network, effectively capturing the evolving spatial interaction patterns in complex traffic systems. Furthermore, a spatial gating mechanism was developed to adaptively fuse static and dynamic graph information, enhancing the model's capability in representing complex spatial structures. Extensive experiments on real-world traffic datasets--PEMS-04, PEMS-08, PEMS-BAY, and METR-LA--for 15-, 30-, and 60-minute traffic flow prediction tasks show that DC-STGNN achieves higher prediction accuracy and better long-term stability compared to the best-performing baseline models.

**Keywords:** traffic flow forecasting; frequency-enhanced mechanism; discrete wavelet transform; multi-order graph convolution; spatio-temporal graph neural network