

基于时空图神经网络的城市公交客流预测方法

杨文欣¹, 黄政祥¹, 肖盟¹, 罗思^{1,2}, 钟志康^{1,2}, 贺丹^{1,2}

(1. 中车时代电动汽车股份有限公司, 湖南 株洲 412007; 2. 长沙中车智驭新能源科技有限公司, 长沙 410083)

摘要:在城市公交客流预测中,传统方法难以同时有效捕捉空间动态变化与时间长期依赖之间的耦合关系。为获得更准确的预测结果,本文提出一种基于时空图神经网络的 GraphTST 模型。该模型融合了全局上下文嵌入机制、自适应动态图卷积编码器,以及基于 Patch 的 Transformer 时序模块。在真实公交数据集上的实验结果显示,GraphTST 模型在多步预测任务中的平均绝对误差和均方根误差分别比 Informer 模型降低 16% 和约 19%,表明该模型在预测精度与鲁棒性方面具有显著优势。

关键词:客流预测; 时空图神经网络; 动态图卷积; Transformer

中图分类号:U469.1⁺4; TP391 文献标志码:A DOI:10.15917/j.cnki.1006-3331.2026.03.006

Urban Bus Passenger Flow Prediction Method Based on Spatio-temporal Graph Neural Network

YANG Wenxin¹, HUANG Zhengxiang¹, XIAO Meng¹, LUO Si^{1,2}, ZHONG Zhikang^{1,2}, HE Dan^{1,2}

(1. CRRC Electric Vehicle Co., Ltd., Zhuzhou 412007, China;

2. CRRC Intelligent Control and New Energy Technology Co., Ltd., Changsha 410083, China)

Abstract: In urban bus passenger flow prediction, traditional methods struggle to simultaneously capture the coupling between dynamic spatial variations and long-term temporal dependencies. To achieve more accurate prediction results, this paper proposes a GraphTST model based on a spatio-temporal graph neural network. The model integrates a global context embedding mechanism, an adaptive dynamic graph convolutional encoder, and a Patch-based Transformer temporal module. Experimental results on real bus datasets show that the GraphTST model reduces the mean absolute error and root mean square error in multi-step prediction tasks by 16% and above 19%, respectively compared to the Informer model, demonstrating that the proposed model has significant advantages in prediction accuracy and robustness.

Key words: passenger flow prediction; spatio-temporal graph neural network; dynamic graph convolution; Transformer

公共交通系统的高效运行依赖于准确的客流预测,而准确的预测结果是实施车辆调度、运力配置和动态班次调整的基础。这些措施不仅提升了运营效率、缩短了乘客候车时间、提高了出行便利性,也有助于缓解城市交通拥堵^[1]。

然而,公交客流具有复杂的时空变化特征,其运行过程受多种因素综合影响。除常规时段(如日常高峰期、节假日)外,天气状况、重大活动及突发事件等外部变量,也会显著改变客流分布,使站点间的空间依赖关系呈现高度动态化。传统预测方法(如自回归积分滑动平均模型、长短期记忆网络、卷积神经网络)

既难以有效捕捉上述空间依赖关系,也无法同时处理长序列依赖与动态图拓扑结构,导致预测精度有限^[2]。

时空图神经网络(Spatio-Temporal Graph Neural Network, ST-GNN)能同时建模交通网络的空间拓扑关系与时间动态演变规律,因此成为智慧交通领域的研究前沿。目前,该方法已在公交客流预测场景中开始了试点探索,但暂未实现大规模行业应用。然而,目前多数具备部署潜力的方法仍依赖静态邻接矩阵,难以刻画路网状态、交通事件的实时动态影响^[3-4]。这一局限主要源于动态图技术在实际应用中面临计

收稿日期:2025-08-12。

第一作者:杨文欣(1996—),女,硕士,工程师,主要从事智慧公交平台研发相关工作。E-mail:yangwenxin_cy@crrecg.cc。

算效率低、数据依赖强、泛化能力弱等多重挑战。

为解决上述问题,本文提出一种面向公交客流预测任务的新型时空图神经网络,即图时间序列变换器(Graph Time Series Transformer, GraphTST)。

1 GraphTST 模型核心创新点

GraphTST 模型通过以下 4 个核心创新点有效地模拟了复杂的时空依赖关系。

1) 全局上下文嵌入机制。在现有的 ST-GNN 框架中嵌入全局上下文,融合整个网络的时间特征、外部环境变量(如天气、节假日)、系统级趋势(如全市范围内的高峰、天气引起的全网波动),从而提高模型的感知能力。

2) 自适应动态图编码器。设计自适应动态图编码器,利用最新客流数据实时更新站点邻接矩阵,动态捕捉交通状况(如道路拥堵)对空间关系的影响,从而提升空间建模的灵活性与准确性。

3) 基于序列块(Patch)的 Transformer 时间模块。GraphTST 采用 Patch 分段建模策略,在降低计算复杂度的同时,有效捕捉了长期时间依赖关系,克服了传统迭代网络在长序列中的梯度消失问题,提高了超长时间序列的处理效率。

4) 系统实验和性能验证。利用真实城市公交数据集进行的对比实验表明,GraphTST 模型的预测精度明显高于传统高级模型。即使在客流快速变化的场景下,GraphTST 模型依旧表现出优异的鲁棒性与适应性,从而为智能公交系统的动态优化提供了有力的技术工具。

2 客流数据集描述

本文使用的客流数据集来自某城市的实际公交网络,数据集基本信息如下:

1) 数据量。原始数据集包含约 500 万条公交乘车记录。

2) 时间范围。数据的时间范围为 2024 年 1 月 1 日至 2024 年 12 月 31 日。为确保模型在不同季节的通用性,训练和测试均包含全年数据。

3) 数据频率。安装在公交车车辆前后门的客流量仪器自动采集数据并上传到公交调度系统,系统据此对车辆在各站点的上下车人数进行记录。每条记录采集的是公交车停靠时的即时数据,该数据能够反

映乘客的实时上下车情况。

4) 数据字段。每条记录包含以下字段:时间戳(如“2024-01-20 08:37:52”)、公交线路 ID、公交站点 ID、客流量、天气信息(如晴、雨、雪等)、交通状况(如畅通、缓行、拥堵等)、节假日标识。

3 GraphTST 模型

3.1 模型架构

GraphTST 模型的整体架构处理步骤如下:

1) 输入预处理。首先向模型输入形状为 (B, T, S) 的三维张量,其中 B 为批量大小, T 为历史时间步数, S 为站点数量。输入数据需经过一系列处理步骤,具体步骤如下:①维度转置:将张量的维度从 (B, T, S) 调整为 (B, S, T) ,即将站点数量 S 置于时间维度 T 之前。此步骤旨在将每个站点视为一个独立特征,使其格式符合时空图卷积网络对节点特征输入的要求^[5]。②序列边缘填充:为避免在卷积操作中丢失序列两端的信息,使用一维复制填充法在调整后张量的时间维度 T 上进行边缘值填充。③序列分块:将填充后的长序列沿时间维度分割为一系列连续的、重叠或非重叠的序列块。每个 Patch 包含固定数量的时间步,此步骤将数据转换为更适合 Transformer 架构处理的块序列格式。④输出重塑:将分块后的数据重塑为 (B, M, P, C) 的四维张量,其中 M 为 Patch 的数量, P 为每个 Patch 的时间步长, C 为特征通道数(此处 $C=S$,即站点数量)。该四维张量将作为深度特征提取网络的直接输入。

2) 多头注意力-Conv2d 编码器。该编码器由多个模块顺序堆叠而成,其模块结构设计如下:①多头注意力层:负责建模不同 Patch 之间的长程依赖关系,有效捕捉全局上下文信息。②二维卷积层(Conv2d):接收多头注意力的输出,在局部邻域内进行空间卷积,以聚合短程特征并细化局部表示。③层归一化(LayerNorm):对特征进行标准化,以稳定训练过程。④正则化与激活:采用 Dropout 抑制过拟合,并采用激活函数(如 ReLU/GELU)引入非线性。通过这种从全局到局部的层次化设计,编码器得以同时捕获长程依赖与局部时空关系。

3) 位置与预嵌入。在 GraphTST 模型中,位置编码将顺序信息引入时间序列,以便更好地理解时间序列数据的时间特性。在此基础上,自适应位置编码允

许模型捕捉时间步长之间的相对关系。此外,预嵌入层将每个站点的初始客流信息与位置编码相结合,使模型能够识别不同时间和地点的公交客流模式。上述结合提高了模型对动态非平稳数据建模的能力。

4) 全局嵌入。为捕捉系统级的时空模式, GraphTST 先对外部变量(如日内时刻、周内日期、天气、节假日)进行编码,然后将编码融合为一个统一的全局上下文向量。上述外部变量有助于模型捕捉宏观周期性变化(如早晚高峰)和微观扰动(如突发事件、天气变化)。随后,模型将全局上下文向量与局部站点特征相结合,可提高模型对不同层次交通波动的理解能力,使模型在不同情况下作出更准确的预测。

5) 动态图卷积编码。在动态图卷积编码中,模型根据当前时间步观测到的客流数据,动态更新公交站点之间的空间邻接矩阵。这种动态更新确保站点间的连通性与实际交通状况相匹配。图卷积利用更新后的邻接矩阵捕捉站点间的空间依赖关系,进而使模型能够根据实时交通环境动态调整站点间的依赖关系。

6) Patch-based Transformer 时序模块与输出投影。其时序模块的处理流程如下:①序列分块与聚合:将每个节点的长时间序列分割为多个等长的 Patch,并通过多头注意力机制对其进行聚合,旨在以较低计算成本捕获长期时序依赖。②特征处理与扁平化:将聚合后的特征依次经线性层和丢弃层处理,并进行扁平化操作。③输出映射:将扁平化后的特征映射为包含未来多步预测结果的输出张量。该张量可直接作为下游调度模型的输入,以支持智能排班任务。

3.2 问题表述

设 $G=(V, \mathcal{E})$ 为城市公交网络图,其中每个节点对应一个公交站点($v_i \in V$),每条边 e_{ij} 为站点 i 和 j 之间的物理或服务连接($e_{ij} \in \mathcal{E}$)。设 X 为历史客流矩阵($X \in \mathbf{R}^{T \times N}$),其中 $\mathbf{R}^{T \times N}$ 表示一个 T 行 N 列的实数矩阵。目标是预测未来 H 个时间步的客流 $Y \in \mathbf{R}^{H \times N}$ 。其中 $\mathbf{R}^{H \times N}$ 表示一个 H 行 N 列的实数矩阵,每一行对应一个未来时间步,每一列对应一个公交站点,矩阵中的每个元素表示该站点在该时间步的预测客流量。为此,建立如式(1)所示的映射函数。

$$f:(X, A, E) \mapsto Y \quad (1)$$

式中: A 为动态邻接矩阵($A \in \mathbf{R}^{N \times N}$, 当需要显式表示

时间依赖性时写作 A_t);其中 $\mathbf{R}^{N \times N}$ 表示一个 N 行 N 列的实数矩阵,每个元素 a_{ij} 表示站点 i 与站点 j 之间的关联强度(例如动态邻接权重)。该矩阵用于描述站点之间的空间依赖关系; E 为外部上下文特征向量(如天气、特殊事件、时段等)。

不同于传统单变量或固定窗口多变量时间序列模型,本文将 X 视为定义在 G 上的多变量时空信号。当交通状态变化(如拥堵或临时改道)导致连通关系演化时, A_t 能更真实地反映站点间的动态交互。

为了同时捕获公交网络的静态拓扑特征与时变交互作用,本文提出的 GraphTST 模型基于动态图结构,捕捉公交网络的时空依赖关系,进而更准确地预测未来客流量 Y ,为后续排班优化与运营决策提供可靠依据。

3.3 全局上下文嵌入

GraphTST 在每个时间步 t 引入一条全局嵌入向量 $g_t \in \mathbf{R}^d$,其中 $\mathbf{R}^d$ 为 d 维实数向量空间。该向量由外部协变量(如时段、天气、节假日等)通过前馈网络 Φ 编码得到,用于向所有节点注入宏观影响,从而在整个公交网络范围内捕获时段、星期、节假日、天气状况等全局上下文信息。

设 $z_t \in \mathbf{R}^p$ 为时间步 t 的全局协变量向量,其中 $\mathbf{R}^p$ 为 p 维实列向量空间。将该向量输入前馈神经网络 $\Phi: \mathbf{R}^p \rightarrow \mathbf{R}^d$,其中 Φ 由一个或多个全连接层及非线性激活函数组成。得到的致密表示如式(2)所示。

$$g_t = \Phi(z_t) \quad (2)$$

将 g_t 广播到所有节点,并与节点 v_i 在时间步 t 的局部隐藏表示 $h_t^{(i)} \in \mathbf{R}^{d_h}$ 进行融合(其中 $\mathbf{R}^{d_h}$ 表示隐藏维度为 d_h 的实向量空间),由此产生新的节点特征 $\tilde{h}_t^{(i)}$,如式(3)所示。

$$\tilde{h}_t^{(i)} = \text{Fuse}(h_t^{(i)}, g_t), \forall i \in \{1, \dots, N\} \quad (3)$$

式中: $\text{Fuse}(\cdot, \cdot)$ 为融合算子,可采用串联、逐元素相加、可学习的仿射组合中的任意一种。

上述广播融合机制能够在注入全局行为模式的同时保留节点的局部差异,从而显著提升时空图预测的效果。本文将 one-hot 时间特征输入多层感知机,得到全局嵌入向量 g_t ;然后在图卷积编码之前,将 g_t 拼接到每个节点的输入特征中,从而实现全局与局部信息的统一建模。

3.4 动态邻接图编码器

为刻画公交站点之间的空间依赖关系,本文在

GraphTST 中引入图编码器, 该编码器以随时间变化的 A_t 为引导 ($A_t \in \mathbf{R}^{N \times N}$), 对节点级输入特征进行卷积处理。时间步 t 的输入特征由历史客流特征与全局嵌入拼接而成, 记为 H_t ($H_t \in \mathbf{R}^{N \times d}$, 其中 $\mathbf{R}^{N \times d}$ 表示一个 N 行 d 列的实数矩阵), 具体构造如式(4)所示。

$$H_t = [X_t \parallel g_t \mathbf{1}^T] \quad (4)$$

式中: X_t 为节点历史特征矩阵 ($X_t \in \mathbf{R}^{N \times d_x}$); g_t 为全局嵌入向量 ($g_t \in \mathbf{R}^{d_g}$, 其中 $\mathbf{R}^{N \times d_x}$ 表示一个 N 行 d_x 列的实数矩阵), 其中, $\mathbf{R}^{d_g}$ 为 d_g 维实数向量空间; $\mathbf{1} \in \mathbf{R}^N$ 为全 1 向量, 用于将 g_t 广播到所有节点。

不同于传统 GNN 依赖静态邻接矩阵, GraphTST 中的邻接矩阵 A_t 可随时动态更新, 以反映需求模式和网络状况的变化。本文将 A_t 视为节点近期观测的函数, 可通过相似度函数 $\psi(\cdot, \cdot)$ 计算, 其中 ψ 可基于客流相关系数、动态连通性或含交通信息的辅助图等方式定义, $[A_t]_{ij}$ 的具体计算如式(5)所示。

$$[A_t]_{ij} = \psi(\mathbf{x}_t^{(i)}, \mathbf{x}_t^{(j)}) \quad (5)$$

式中: $[A_t]_{ij}$ 为时间步 t 下站点 i 与站点 j 之间的权重关系; $\mathbf{x}_t^{(i)}$ 为节点 i 的最新特征向量; $\mathbf{x}_t^{(j)}$ 为节点 j 的最新特征向量。

为综合利用静态与动态空间先验, 在执行图卷积时使用有效邻接矩阵 $\tilde{A}_t$, 其公式如式(6)所示。

$$\tilde{A}_t = \alpha A_{\text{static}} + (1 - \alpha) A_t \quad (6)$$

式中: A_{static} 为静态基线邻接(由物理距离或线路拓扑关系构建); α 为可学习或预设的融合系数, 其取值范围为 $[0, 1]$ 。

图编码器由一层或多层图卷积组成(例如扩散卷积或谱域卷积)。单层图卷积的输出 Z_t 如式(7)所示。

$$Z_t = \sigma(\tilde{A}_t H_t W) \quad (7)$$

式中: W 为可学习权重矩阵 ($W \in \mathbf{R}^{d \times d'}$ 其中 $\mathbf{R}^{d \times d'}$ 表示一个 d 行 d' 列的实数矩阵); $\sigma(\cdot)$ 为非线性激活函数; Z_t 为时间步 t 的空间感知节点嵌入 ($Z_t \in \mathbf{R}^{N \times d'}$, 其中 $\mathbf{R}^{N \times d'}$ 表示一个 N 行 d' 列的实数矩阵)。

本文提出的模型通过堆叠多层图卷积块, 捕获公交站点之间的高阶空间关系; 同时引入动态邻接矩阵, 使模型能够根据临时加班或线路调整引起的局部邻域结构变化进行动态调整, 从而保证所得空间表征的鲁棒性。该设计的核心优势在于借鉴了 Graph-

WaveNet^[6] 的自适应图卷积思想, 即通过学习动态邻接矩阵突破静态拓扑连接的局限, 进而刻画图中节点间复杂、动态的依赖关系。

3.5 基于 Patch 的 Transformer 时间模块

在时间维度建模上, GraphTST 采用受 PatchTST^[7] 启发的分块 Transformer 编码器, 具体处理步骤如下: ① 将每个节点的空间编码特征序列作为输入; ② 将特征序列转换为适合 Transformer 处理的 Token 序列, 采用长度为 L 的滑动窗口将序列划分为重叠的 Patch, 每个 Patch 对应一个短时序子序列; ③ 通过线性映射将每个 Patch 映射为一个 Token。

这种以 Patch 为最小计算单元的做法, 既能保留 Token 内部的局部时序模式, 又能显著压缩序列长度, 从而降低长时预测的计算开销。

为避免多变量间的干扰并提升长期预测性能, 本模型采用通道独立的建模方式: 所有节点的时间序列共享同一组 Transformer 权重, 但在输入和编码过程中彼此保持独立。节点间的空间信息交互完全依赖于前述的图融合阶段, 而不再在时间编码器内部进行。该设计使得模型能在复杂的图结构与长历史序列的建模需求之间取得良好平衡。

在 Transformer 编码器内部, 标准的多头自注意力层和前馈网络层依次作用于 Patch Token 序列。为注入全局上下文信息, 本文在序列首部添加一个可学习的“Graph Token”, 该 Token 初始化为全局嵌入 g_t , 并在自注意力机制下与所有 Patch Token 交互。其作用类似于双向编码器表示变换模型中的 CLS Token, 用以聚合节点完整历史的时间信息。编码完成后, 按以下步骤恢复时间序列并进行预测: ① 将各节点的 Patch 表征通过线性投影及重叠求和方式, 还原为连续的时间序列; ② 将还原后的序列输入一层线性输出映射, 得到各节点未来 H 个时间步的客流预测值。

整套设计使模型既能高效利用长历史数据, 又能在保持计算效率的前提下捕获全局与局部的时序依赖。

4 实验结果及分析

本文通过在真实公交车数据集上进行实验, 验证了 GraphTST 模型在公交车客流预测中的有效性与优越性。实验重点评估了模型的预测精度、效率及鲁棒性, 并与多个现有基准模型进行了比较。结果表明,

GraphTST 在处理复杂时空数据方面具备优越性。

4.1 基准模型对比

为了评估 GraphTST 模型的性能,本文选择以下几种基准模型进行对比。

1) CNN-1D。在每个节点上独立应用一维时序卷积(无空间组件),通过对历史客流数据进行卷积操作,捕捉时间序列中的局部时序特征,但该机制无法有效建模长距离时序依赖^[8]。

2) Transformer。在每个节点的历史序列上应用原生 Transformer 编码器(不使用 Patch 划分),采用标准自注意力机制建模长时间序列的依赖关系^[9],但该机制存在计算冗余、长序列运行效率偏低的问题。

3) Informer。该机制采用 ProbSparse 注意力机制,相较于标准自注意力,能够在长序列预测中保持高性能;特别是在处理大规模复杂交通数据时,该机制能更精确地捕捉时间序列之间的依赖关系^[10]。

所有模型均在相同的数据划分上调参并训练。其中,GraphTST 使用与基线相同的输入协变量,其超参数(如隐藏维度和层数)通过验证集选择。表 1 为 GraphTST 与上述 3 种基准模型的性能比较。

表 1 GraphTST 与基准模型的性能比较

模型	MAE	RMSE
CNN-1D	6.8	8.9
Transformer	6.1	8.3
Informer	5.0	7.2
GraphTST	4.2	5.8

由表 1 可知,在 105 步超前预测任务中,GraphTST 的平均绝对误差(Mean Absolute Error, MAE)为 4.2,均方根误差(Root Mean Square Error, RMSE)为 5.8。与次优的 Informer 模型相比,GraphTST 的 MAE 和 RMSE 分别降低了 16% 和约 19%。这一结果表明,GraphTST 能更充分地捕获公交客流在时间与空间上的动态变化规律,从而为城市公交运营管理提供更准确、更可靠的决策支持。

4.2 消融实验

消融实验通过移除 GraphTST 模型的某些组件来评估各模块对模型性能的贡献,从而验证各模块的必要性与有效性。具体设置如下:① 移除全局上下文嵌入模块(仅保留空间和时间模块);② 移除动态图编码器(使用固定邻接矩阵);③ 同时移除全局嵌入

和动态图编码器(模型仅使用静态图结构和传统时间序列处理方法)。

表 2 为消融实验的测试结果,列出了不同设置下 GraphTST 模型的 MAE 值和 RMSE 值。

表 2 GraphTST 模型各组件的消融实验

模型	MAE	RMSE
GraphTST	4.2	5.8
GraphTST(移除全局上下文嵌入模块)	4.8	6.5
GraphTST(移除动态图编码器)	5.0	6.8
GraphTST(移除全局嵌入和动态图编码器)	5.5	7.3

由表 2 可知,当移除全局嵌入向量后,GraphTST 难以捕捉高需求时段的系统性模式,导致 MAE 和 RMSE 明显上升;当移除动态图编码器后,GraphTST 无法及时适应突发性客流变化,整体性能也出现显著下降。消融实验结果进一步证实了全局上下文与自适应空间编码的重要性。

4.3 结果讨论

1) 模型优势。GraphTST 能够准确捕捉客流波动(尤其在高峰期和低谷期),预测误差显著小于各基准模型。这得益于 Patch 的注意力机制:通过降低计算复杂度,模型能够高效处理超长序列,从而提升了对长期依赖关系的建模能力。

2) 局限性。尽管 GraphTST 取得了较好的预测性能,但仍存在以下局限性:① 计算开销较大。动态图学习模块会引入额外计算开销,在处理超大规模网络或对实时性要求极高的场景时,易导致较高的计算延迟,难以满足实时性要求。② 依赖外部数据的完整性与准确性。模型性能在一定程度上依赖于外部特征(如天气、事件)的质量。当数据缺失或质量不佳时,其鲁棒性可能受到影响。③ 泛化能力有待验证。当前工作主要验证了模型在特定城市公交网络上的有效性,其在不同规模、不同运营模式交通网络上的泛化能力,仍需通过更广泛的跨域实验进行验证。

5 结束语

本文提出的用于短期公交客流预测的时空图神经网络模型 GraphTST,解决了现有方法难以捕捉复杂时间模式和动态空间依赖关系的问题。GraphTST 是一种全局上下文嵌入式动态图卷积编码器,这种建

(下转第 57 页)

车主发电机批量烧损机理: 直接原因为主发电机长期高负载运行导致热积累与绝缘劣化; 根本原因在于供电系统中 DC/DC 变换器与主发电机输出电压不匹配, 导致并联负载失衡。为此, 提出将 DC/DC 输出电压优化至 27.4 V 的方案, 从根源上解决负载不均问题。经实车验证, 该方案可靠有效, 已纳入标准化设计并应用于后续车型, 显著提升了供电系统稳定性与寿命, 为同类车型设计优化及故障预防提供了重要参考。

参考文献:

- [1] 严程健, 夏靖武, 杨兆银. 混合动力城市客车交流发电模块的改进设计[J]. 客车技术与研究, 2014, 36(1): 30-33.
- [2] 杨万里, 徐小兵, 范鹏飞, 等. 浅谈纯电动客车动力电池系统安全技术[J]. 客车技术与研究, 2020, 42(4): 39-41.
- [3] 安藤裕隆, 刘丽杰. HC85 系列车混合动力系统优化及环境负荷降低效果[J]. 国外铁道机车与动车, 2025(4): 21-

24.

- [4] 马富强, 强强, 杨军, 等. 发电机组并机控制器故障分析及解决方案[J]. 内燃机与配件, 2025(13): 80-82.
- [5] 亢超星, 庞强, 赵倩. 内燃机车柴油机扭振对同步发电机可靠性的影响[J]. 电机技术, 2025(3): 6-9.
- [6] 陈龙, 丛培鹏, 曾云峰, 等. 低恒速工况下主发电机励磁涌流控制方法研究[J]. 自动化仪表, 2025, 46(6): 87-91.
- [7] 魏延辉, 高朝晖, 王爽, 等. 基于参数辨识的航空无刷交流发电机仿真模型的建立[J]. 航空科学技术, 2025, 36(2): 83-90.
- [8] 石耀民. 油电增程式混合动力客车发动机转速异常问题研究[J]. 城市公共交通, 2024(10): 34-40.
- [9] 刘永豹. 涡轮增压发动机高速旋转状态失衡振动故障诊断系统[J]. 计算机测量与控制, 2024, 32(10): 9-16.
- [10] 周付明, 刘武强, 杨小强, 等. 基于精细化改进多尺度快速样本熵的旋转机械故障诊断方法研究[J]. 机械强度, 2023, 45(1): 1-8.

(上接第 44 页)

模技术结合了基于 Patch 的 Transformer 时序模块, 可学习整个网络的时间模式并动态更新站点之间的空间关系, 从而更真实地描述公共交通网络的变化特征。通过预测时间模式和动态依赖关系的变化来预测公交客流。基于真实交通网络数据的实验结果表明, GraphTST 在预测准确性方面优于传统的主流基准模型(如 CNN-1D、Transformer、Informer)。消融实验验证了每个模块设计的合理性, 并进一步证明了全局特征嵌入和动态图结构在提高预测效果方面的重要作用。未来, 可引入实时天气状况、交通状况、特殊事件等外部因素, 实现多源信息的集成建模, 以推动 GraphTST 的实际应用(如在线公交调度系统), 从而提升公交运营的智能性与准确性。

参考文献:

- [1] 2024 年交通运输行业发展统计公报[R]. 2024. https://xxgk.mot.gov.cn/jigou/zhghs/202506/t20250610_4170228.html.
- [2] 张宇希. 基于 LSTM 模型的城市公交客流预测研究[D]. 沈阳: 沈阳大学, 2024: 32-56.
- [3] 张鹏祯. 基于机器学习的公交客流预测方法研究[D]. 北京: 北京邮电大学, 2023: 30-47.
- [4] 赵彬. 基于 GCN-LSTM 的短时公交客流预测模型研究

[D]. 广州: 广东工业大学, 2022: 26-35.

- [5] 王宇阳. 基于时空图卷积的城市公交站点客流预测研究[D]. 长沙: 长沙理工大学, 2022: 29-44.
- [6] Wu Zonghan, Pan Shirui, Long Guodong, et al. Graph WaveNet for deep spatial-temporal graph modeling[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence (IJCAI-19). Macao: International Joint Conferences on Artificial Intelligence, 2019: 1907-1913.
- [7] Nie Yuqi, Nguyen N H, Sinthong P, et al. A time series is worth 64 words: long-term forecasting with transformers[C]//The Eleventh International Conference on Learning Representations, 2023: 1-24. <https://www.alphaxiv.org/abs/2211.14730>.
- [8] Liu Guojin, Yin Zhenzhi, Jia Yunjian, et al. Passenger flow estimation based on convolutional neural network in public transportation system[J]. Knowledge-Based Systems, 2017(123): 102-115.
- [9] Yue Min, Ma Shuxin. LSTM-based transformer for transfer passenger flow forecasting between transportation integrated hubs in urban agglomeration[J]. Applied Sciences, 2023, 13(1): 637.
- [10] Li Dekui, Du Shubo, Hou Yuru. Long-term passenger flow forecasting for rail transit based on complex networks and informer[J]. Sensors, 2024, 24(21): 6894.