

DOI:10.19651/j.cnki.emt.2313330

基于特征选择的时空融合交通流预测^{*}

李昕光¹ 王坤² 曲大义¹

(1. 青岛理工大学机械与汽车工程学院 青岛 266525; 2. 青岛理工大学土木工程学院 青岛 266525)

摘要: 针对目前交通流预测模型在提取数据特征时容易忽略工作日和休息日交通流变化趋势存在差异的不足,提出一种基于特征选择的时空融合交通流预测模型 STTF-XGB。该模型从数据和模型两个层面提高模型对数据特征的提取。首先,利用皮尔逊相关系数计算数据间的相关性,并根据相关性的大小将数据集重新划分为工作日和休息日数据集。其次,采用能够体现全局关系的邻接矩阵结合自注意力机制构建图自注意力机制,提取路网数据的全局空间特征,并结合自注意力机制构建“三明治”结构的时空特征提取模块,基于 Transformer 模型构建时空融合模型 STTF。然后,在 STTF 模型末端,利用 XGBoost 模型筛选多头注意力机制提取的特征,构建 STTF-XGB 模型。最后,在英国高速公路交通流数据集上对模型进行实验,结果表明:STTF-XGB 在中短期的预测中较时空融合预测模型 GCN-BiLSTM 和 GAT-BiLSTM 在预测精度上提升约 5%~10%,且预测误差波动范围最小,能够有效用于交通流预测。

关键词: 智慧交通;特征选择;数据划分;时空融合;XGBoost 模型

中图分类号: U491.14 文献标识码: A 国家标准学科分类代码: 510.0823

Spatiotemporal fusion traffic flow prediction based on feature selection

Li Xinguang¹ Wang Shen² Qu Dayi¹

(1. School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266525, China;

2. School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: To address the shortcomings of the current traffic flow prediction model in extracting data features that easily ignore the differences in traffic flow trends between weekdays and rest days, a feature selection-based spatio-temporal fusion traffic flow prediction model STTF-XGB is proposed. The model improves the extraction of data features by the model from both data and model levels. First, Pearson correlation coefficient is used to calculate the correlation between data, and the data set is reclassified into weekday and rest day data sets according to the magnitude of the correlation. Secondly, the global spatial features of the road network data are extracted by using the adjacency matrix which can reflect the global relationship and the self-attention mechanism to build a graph self-attention mechanism, and the spatio-temporal feature extraction module with a "sandwich" structure is built based on the Transformer model to build a spatio-temporal fusion model STTF. Then, at the end of the STTF model, the XGBoost model is used to filter the features extracted by the multi-head attention mechanism to build the STTF-XGB model. Finally, the model was experimented on the UK freeway traffic flow dataset, and the results show that STTF-XGB can be effectively used for traffic flow prediction with about 5%~10% improvement in prediction accuracy over the GCN-BiLSTM and GAT-BiLSTM model in the short and medium term, and the prediction error fluctuation range is minimal.

Keywords: intelligent transportation; feature selection; data segmentation; spatio-temporal fusion; XGBoost model

0 引言

智慧交通系统离不开实时准确的交通流预测数据^[1],循环神经网络(recurrent neural network, RNN)和卷积神经网络(convolutional neural network, CNN)^[2-3]作为深度

学习的经典模型被广泛用于交通流预测。近年来 Transformer 凭借自注意力机制更好的数据深层特征提取能力,在交通流预测方面取得了优秀的效果。王宁^[4]基于 RNN 单向模型对时间依赖关系建模的不足,提出一种基于自注意力的 Transformer 交通流预测模型,通过实验证明

收稿日期:2023-04-10

* 基金项目:国家自然科学基金(52272311)、山东省自然科学基金面上项目(ZR2020MG017)资助

了该方法在交通流量预测上的有效性和准确性。但在复杂的交通路网中,观测点的交通流量不仅与历史数据存在时间上的关联,也与路网中的其他观测点之间存在空间关联。

将图神经网络与循环神经网络、卷积神经网络结合起来提取路网数据的时空特征成为交通流预测研究中的热门,并取得了不错的成果。Han 等^[5]通过图卷积网络(graph convolutional networks,GCN)学习拓扑来捕获空间相关性,通过将长短时记忆网络(long short-term memory,LSTM)嵌入到GCN网络的训练过程来捕获时间相关性,改进了原有时空交通流预测中循环神经网络和图神经网络相结合的传统方法,能够更好地捕捉交通流中存在的时空特征。贺文武等^[6]提出一种基于递增式丢边的轻量时空图卷积神经网络模型,采用“三明治”式结构构建时空卷积模块,同时引入递增式丢边策略避免节点交通流信息特征失效,提高了预测精度。汪鸣等^[7]使用图卷积网络和变体 Transformer 分别捕获数据中的时间和空间依赖性,并通过门控融合机制将两者提取到的特征进行融合,提出了一个多时间尺度时空图网络模型,并通过实验验证了模型的有效性。

上述研究对基于时空融合的交通流预测具有重要参考价值,但仍存在部分的改进空间。现有研究中鲜有考虑工作日和休息日交通流变化趋势不同对预测结果的影响。另外,大部分模型提取空间特征时只注重了相邻节点对目标节点的影响,忽略了全局空间特征。同时,在利用多头注意力机制的模型中,没有对提取的多个特征进行筛选,增加了预测时的计算复杂度和预测难度。针对上述问题,本文提出一种基于特征选择的时空融合交通流预测模型,利用邻接矩阵与掩码矩阵的相似性将自注意力机制与图神经网络相结合,构建图自注意力机制来提取路网数据的全局空间特征,并将其引入 Transformer 模型,以“三明治”结构提取数据的时空特征,构建了时空 Transformer 的交通流融合预测模型(spatio-temporal transformer,STTF)。在 STTF 模型的末端,利用极端梯度提升算法(eXtreme gradient boosting,XGBoost)筛选重要特征^[8],构建 STTF-XGB 模型,提高模型的预测效率和精度。

1 数据划分处理

1.1 数据介绍

实验数据集为英国希恩罗机场附近的 M4 和 M25 公路的部分观测点组成的路网数据,共选取 8 个观测点数据。其中观测点 1、3、4、5 为 M4 公路上的观测点,各观测点代号依次为 2268B、2302B、2308B 和 2305B; 观测点 2、6、7、8 为 M25 公路上的观测点,各观测点代号依次为 4959B、4941A、4926K 和 4919A。观测点 4 和观测点 7 的数据为支路并入主路的数据,其余观测点的数据均为主路的数据。各观测点之间的关系为: 观测点 1 位于观测点 2、3、6 的下游; 观测点 3 位于观测点 4、5 的下游; 观测点 6 位于观测点

7、8 的下游。数据集中 8 个观测点数据均为 2018 年 4~6 月份的交通流数据,以 15 分钟为间隔,共 91 天 69888 个数据。将数据集中 6 月份最后一周数据作为可视化数据,其余数据按照 8:2 的比例划分训练集和测试集。各观测点的位置如图 1 所示。



图 1 观测点位置

1.2 数据相关性分析

交通流数据的周期性变化在工作日和休息日之间存在不同,为了提高模型对交通流特征的提取效率,通过皮尔逊相关系数对交通流数据进行相关性分析,并根据数据相关性重新划分数据集。皮尔逊相关系数^[9]计算公式如下:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中: r 为相关性系数; x 和 y 为两个序列, x 和 y 分别为 x 序列和 y 序列的平均值; n 为序列长度。

皮尔逊相关系数的含义为: 在 0.8~1.0 之间为极强相关,在 0.6~0.8 之间为强相关,在 0.4~0.6 之间为一般相关,在 0.2~0.4 之间为弱相关,在 0.0~0.2 之间为极弱相关或无相关。系数大于 0 为正相关,小于 0 为负相关,等于 0 为不相关。以目标观测点的数据为例,计算数据集中 91 天数据之间的相关性,并制作如图 2 所示的热力图。

从图 2 中可知,热力图的主体部分由 5×5 和 2×2 的红色正方形交错组成,剩余部分的颜色多表现为浅色和蓝色。从热力值上看,红色部分属于极强相关,浅色和浅蓝色部分属于强相关,蓝色部分属于一般相关。从热力图的整体分布来看,91 天的数据在整体上符合一周连续 5 天工作日和 2 天休息日的周期性规律,工作日和休息日数据之间的相关性较低,因此对交通流数据采取休息日和工作日分开预测。

将数据集按照 5 天工作日和 2 天休息日的方式划分为工作日数据和休息日数据两个数据集,重新划分后的两个数据集中,数据之间的相关性如图 3 和 4 热力图所示。从图 3 中可以看出,第 1、26、41 这 3 天的数据与其他工作日的数据呈现一般相关关系,其他工作日数据之间均表现为

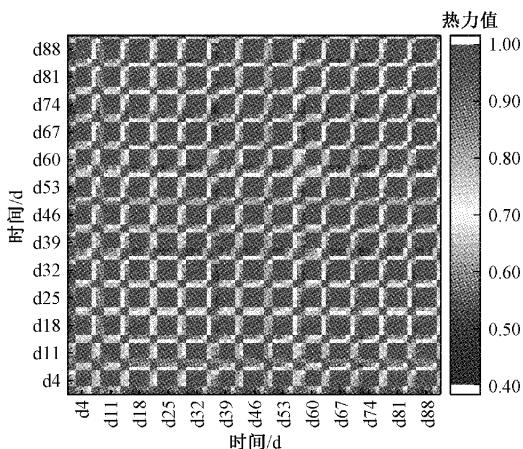


图 2 原数据集的相关性

极强相关。第 1、26、41 分别为 2018 年的 4 月 2 号、5 月 7 日和 5 月 28 日,这 3 天分别为复活节、五月初银行假日和春季银行假期,均为英国的法定节假日,且 4 月~6 月仅有这 3 天法定节假日,所以这 3 天应属于休息日。从图 4 中可以看出,整个休息日数据之间均呈现极强相关。

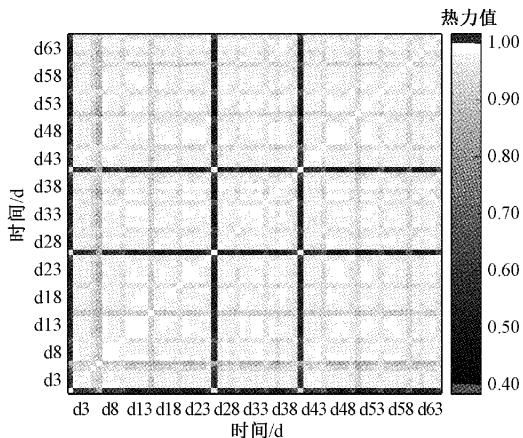


图 3 工作日数据间的相关性灰度映射图

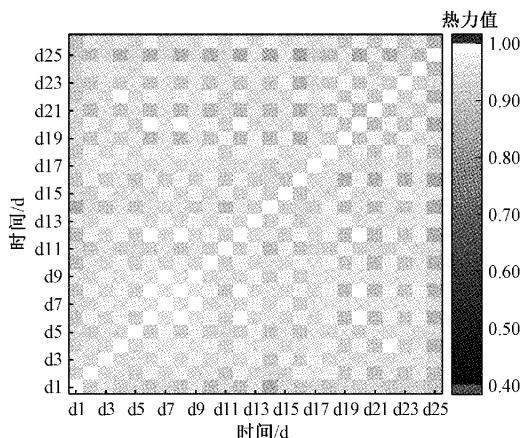


图 4 休息日数据间的相关性灰度映射图

将工作日中第 1、26、41 这 3 天数据划分为休息日数

据,计算重新划分后的工休日和休息日数据间的相关性,并制作成图 5 和 6 所示的散点图,从图 5 中可以看出,工休日数据间的相关性系数小球大部分分布于 0.95 左右;从图 6 中可以看出,休息日数据间的相关性系数小球大部分分布于 0.9~1 之间。工休日数据之间和休息日数据均呈现极强相关,故按照重新划分后的数据集作为工休日和休息日数据集。

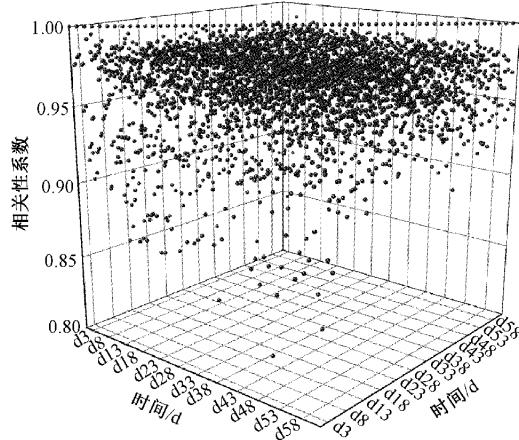


图 5 工作日数据间的相关性系数散点图

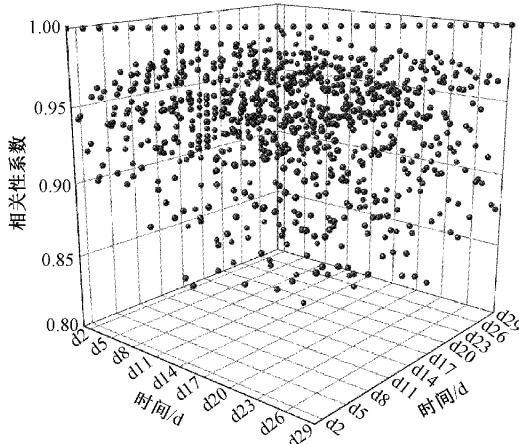


图 6 休息日数据间的相关性系数散点图

2 时空融合模型构建

本文提出一种基于特征选择的时空融合预测模型 STTF-XGB,该模型主要包含两个模块:1)STTF 时空融合模块,该模块利用自注意力机制提取时间特征、图自注意力机制提取空间特征;2)XGBoost 特征选择模块,该模块利用 XGBoost 模型对 STTF 模型提取的多头特征进行筛选,选出重要特征。

2.1 自注意力机制

由于 Transformer 提取特征的方式是通过词向量之间的点积来计算各词向量之间的关系,完全不依赖外界,故被称为自注意力机制。为了深度提取数据特征,将若干个相

同的自注意力模块叠加组成特征提取模块，在编码端和解码端采用相同的特征提取模块来充分挖掘词向量之间的关系。每个自注意力模块均由注意力层和残差前馈神经网络组成。为了防止过拟合，在注意力层采用多头的方式，即多头注意力机制，从不同方向提取数据特征。单个 attention 可以用以下形式表示：

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}(\mathbf{Q}\mathbf{K}^T / \sqrt{d_k})\mathbf{V} \quad (2)$$

式中：Attention($\mathbf{Q}, \mathbf{K}, \mathbf{V}$)表示 attention 层的输出； $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别代表查询向量矩阵、键向量矩阵和值向量矩阵。

$\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 矩阵分别是由词向量与 3 个权重矩阵相乘所得。多头注意力机制则是由若干个 attention 拼接而成。根据矩阵相乘的特性，通过线性转换，每个注意力头只负责最终输出序列中一个子空间，而且互相独立。多个子空间，可以让模型去关注不同的信息，从而避免过拟合。在编码端，除第一层输入为编码端的输入与权重矩阵相乘所得，其余层的 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 向量矩阵均用上一层的输出代替；在解码端除第一层的 \mathbf{Q} 向量矩阵为解码端的输入与权重矩阵相乘所得，其余层的 \mathbf{Q} 向量矩阵均为上一层的输出，每一层的 \mathbf{K}, \mathbf{V} 矩阵均为编码端的输出。

2.2 图自注意力

在交通系统中，由于交通路网的空间结构和交通流的有向性，道路的交通流量不仅在时间周期上满足一定的变化规律，也与道路上游的交通流量存在关联。由于交通路网中存在明显上下游关系，所以有向图更能够准确的表达路网的拓扑结构。

将数据集中 8 个观测点之间的相关性制作成图 7 热力图，将路网节点之间的上下游关系制作成图 8 有向图。从图 7 中可以看出，目标观测点 1 与观测点 2、3、4、5 之间均为极强相关，且相关性较为接近，从观测点 6 开始，观测点 6、7、8 与观测点 1 的相关性逐步减弱。从图 8 的路网关系图中可以看出，观测点 1 处于最下游；观测点 2、3、6 为观测点 1 的相邻节点，处于中游；观测点 4、5、7、8 与目标观测点不相邻，处于最上游。结合图 7，观测点 1 与相邻节点 6 的相关性不如观测点 1 与不相邻节点 4 和 5 之间的相关性，所以单纯计算相邻节点对目标节点的影响存在一定的局限性。

从特征提取的本质上来看，经典的空间特征提取模型 GCN 与 GAT 都是将邻居节点的特征聚合到中心节点上，利用图上局部静止的信息来学习新的节点特征表达，不同的是 GCN 利用了拉普拉斯矩阵，GAT 利用了 attention 系数，但两者都不能直接学习路网的整体空间特征。

从交通路网的现实意义中来看，GCN 和 GAT 对相邻节点之间的特征提取可以理解为多个上游支路汇入目标道路车辆的占比，即某个时间段内某条上游支路中汇入目标道路流量的比例。但从范围更广的路网结构中看，如图 8 中的观测点 1、3、4，三者处于同一上下游链中，即观测点 4 是观测点 3 的上游，观测点 3 是观测点 1 的上游。从空间

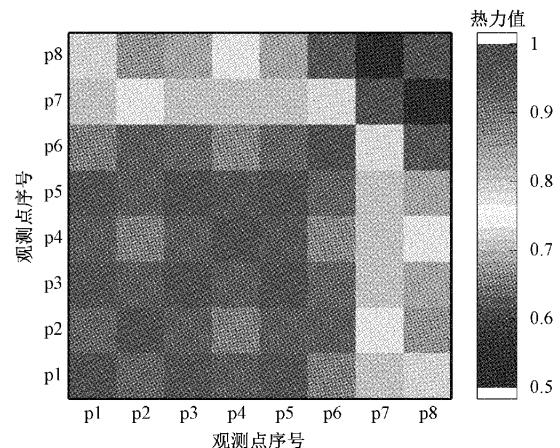


图 7 8 个观测点之间的相关性系数热力图

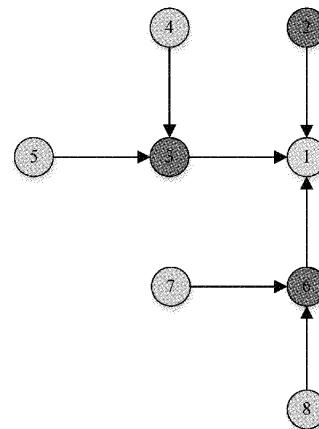


图 8 路网关系有向图

上看，观测点 4 的交通流量会通过观测点 3 作用于观测点 1，从时间上看，观测点 4、3、1 交通流量中的某部分是相同的，即观测点 1 中的某部分流量是下一时刻在路网其他位置的存储，所以将与目标节点不相邻但存在上下游关系的节点纳入空间特征的提取具有一定的意义。因此，本文提出能够提取整个空间特征的图自注意力机制，利用全局关系的邻接矩阵结合自注意力机制中的掩码矩阵，从而将图论与自注意力机制结合，提取空间特征。

2.3 STTF 模型框架

为了充分提取路网数据的时间特征与空间特征，对标准 Transformer 进行改进。在注意力层，采用自注意力机制提取路网数据的时间特征；采用图自注意力机制提取路网数据的空间特征，图自注意力机制相较于经典的 GAT 和 GCN 空间特征提取模型，能够更好的提取路网的整体空间特征。自注意力和图自注意力机制分别从时间和空间方面提取全局特征，两者结合能够充分提取整个路网数据的特征。在时空特征提取模块的结构方面，采用时间—空间—时间的“三明治”结构^[10]，并通过矩阵转置的方式，置换时间序列数据与空间结构数据的位置。时空提取模块框架如图 9 所示。

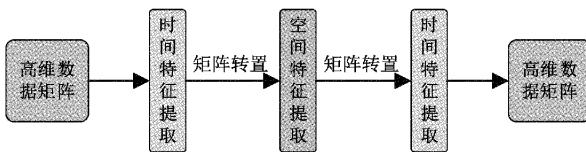


图 9 时空提取模块框架

2.4 基于 XGBoost 的特征选择

由于 STTF 模型中的注意力层采用的是多头注意力, 多头注意力在注意到数据的不同特征时, 也关注了不重要的特征, 从而增加了计算复杂度。为了提高计算效率, 减少无关特征对预测结果的影响, 采用 XGBoost 特征选择算法对提取的特征进行筛选, 构建 STTF-XGB 模型。

XGBoost 是基于提升树的集成学习模型, 相较于梯度提升树(GBDT), XGBoost 对目标函数进行二次泰勒展开, 能够让梯度收敛的更快。梯度提升算法可以使提升树被创建后, 相对直接地得到每个特征的重要性得分, 重要性分数衡量了特征在构建提升决策树中的价值。在整个模型中, 构建决策树时被用的越多的特征, 它的重要性就相对越高。

特征重要性是通过对数据集中的每个特征进行计算, 并进行排序得到, 在单个决策树中通过每个特征分裂点改进性能度量的量来计算特征重要性, 由节点负责加权和记录次数。简单来说, 一个特征对分裂点改进性能度量越大(越靠近根节点), 权值越大; 被越多提升树所选择, 特征越重要。性能度量可以是选择分裂节点的 Gain 纯度, 也可以是其他度量函数。最终将一个特征在所有提升树中的结果进行加权求和后进行平均, 得到重要性得分。

为提高模型的预测速度, 使用 XGBoost 对训练好的 SFFT 模型进行特征选择。将训练集数据重新输入训练好的模型, 将输出的时空特征输入 XGBoost 模型, 输出特征的重要性排序; 按照排序结果将重要性最小的若干个特征去除, 并将新的特征进行线性映射。经过 XGBoost 特征筛选后的模型, 相较于未经过筛选的模型, 预测时间更短, 预测精度更高。STTF-XGB 模型结构如图 10 所示。

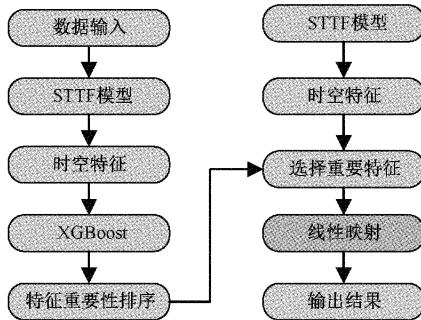


图 10 STTF-XGB 模型结构

3 实验与结果分析

3.1 模型评价指标

为了对交通流预测模型的预测精度进行判定, 采用平

均绝对百分误差(MAPE), 平均绝对值误差(MAE)和均方根误差(MSE)进行误差分析^[11 12], 公式如下:

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (3)$$

$$E_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (4)$$

式中: E_{MAE} , E_{RMSE} 分别为平均绝对值误差值和均方误差值; x_i 和 \hat{x}_i 分别为交通流量的真实值和预测值; n 为样本数量。

3.2 基准模型介绍和参数设置

本文的基准模型主要分为时间序列预测模型和时空融合预测模型。时间序列预测基准模型为差分整合移动平均自回归模型^[13] (autoregressive integrated moving average model, ARIMA)、XGBoost、双向长短时记忆神经网络(bi-directional long short-term memory, BiLSTM)和 Transformer; 时空融合预测基准模型为 GCN-BiLSTM^[14] (graph convolutional networks) 和 GAT-BiLSTM^[15] (graph attention network)。

各模型的关键参数为: ARIMA 模型差的分次数 d 设置为 2、自回归项 p 设置为 2、移动平均项数 q 设置为 1; XGBoost 模型使用树的模型作为弱学习器, 树的最大深度为 20; BiLSTM 模型的损失函数为 MSE 损失函数, 最大迭代次数设置为 200 次, 学习率设置为 0.000 1; Transformer 模型的损失函数为交叉熵损失函数, 最大迭代次数设置为 30 次, 学习率设置为 0.000 1; GCN-BiLSTM 和 GAT-BiLSTM 模型分别采用 GCN 和 GAT 提取空间特征, 均采用 BiLSTM 提取时间特征。

3.3 模型测试

将数据带入 7 种模型进行测试后, 各模型的评价指标如表 1 所示。从不同预测步长上对 7 种模型的预测结果进行对比, 由表 1 可知, 7 种模型预测结果的 MAE 值均随着输出步长的增加预测精度降低。在同一预测步长下对不同模型进行对比, GCN-BiLSTM、GAT-BiLSTM 和 STTF-XGB 模型预测结果的 MAE 和 RMSE 值, 相较于另外 4 种模型更好, 因此引入空间特征的模型比单一时间序列的模型预测精度更高。从整体上来看, 在输出步长为 1、3、5 时, STTF-XGB 模型的预测精度最高, ARIMA 的整体预测精度最低; 在输出步长为 7、9 时, GAT-BiLSTM 模型的预测精度最高, ARIMA 的整体预测精度最低。因此, STTF-XGB 在短中期预测中具有较高的优势。

3.4 预测结果可视化

为进一步展示模型预测效果, 对数据集中 6 月份最后一周数据进行预测, 并计算各模型预测结果与真实值之间的差值, 对各模型的预测误差进行统计, 制作如图 11 所示的箱型图。从图 11 中可以看出, STTF-XGB 的误差波动最小, 均值最接近 0, 但中位线较低; ARIMA、BiLSTM 和 Transformer 模型的预测结果存在异常值; GAT-BiLSTM

表 1 不同模型的预测结果

模型	$t=1$		$t=3$		$t=5$		$t=7$		$t=9$	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
ARIMA	14.81	17.88	33.26	48.85	47.58	68.37	87.77	113.67	113.69	135.73
XGBoost	10.20	14.56	11.68	16.91	13.95	20.30	17.75	27.07	24.90	36.89
BiLSTM	9.20	14.55	10.66	17.23	11.95	17.87	15.24	22.52	21.61	33.62
Transformer	8.94	13.80	9.95	15.46	11.73	19.16	17.55	22.94	24.92	34.49
GCN-BiLSTM	7.28	10.76	8.41	12.97	9.80	14.63	12.86	18.33	19.17	29.27
GAT-BiLSTM	7.18	10.37	8.17	12.75	9.74	15.14	12.44	18.12	18.61	27.18
STTF-XGB	6.85	9.01	7.91	12.01	9.33	13.52	13.10	20.75	20.83	32.11

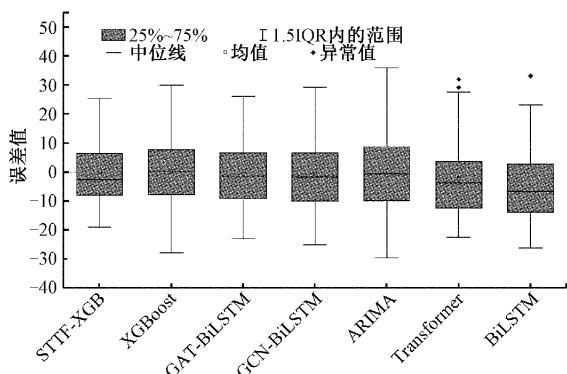


图 11 各模型误差箱型图

模型的误差波动略好于 GCN-BiLSTM 模型,3 种时空融合模型的稳定性均好于时间序列模型。从整体上可以看出,STTF-XGB 的误差波动最小,预测效果最稳定,与真实值最为接近,所以 STTF-XGB 的模型预测效果最好。

3.5 消融实验

为进一步验证数据划分为工作日数据和休息日数据对预测精度的提升,利用预测效果最好的 STTF-XGB 模型设计消融实验,消融实验中模型的输出步长设置为 1、3、5。STTF-XGB-0 实验的数据为原始数据集,STTF-XGB-1 实验的数据集为划分为工作日和休息日的数据集。消融实验的测试结果如表 2 所示。

表 2 消融实验的预测结果

模型	评价指标	$t=1$	$t=3$	$t=5$
STTF-XGB-0	MAE	9.11	11.38	13.68
	RMSE	13.82	15.10	18.15
STTF-XGB-1	MAE	6.85	7.91	9.33
	RMSE	9.01	12.01	13.52

从表 2 中可以看出,使用划分为工作日和休息日数据的 STTF-XGB-1 实验的预测结果,相较于使用原始数据集的 STTF-XGB-0 实验的预测结果,在 MAE 和 RMSE 误差评价指标上提升约 20%~30% 左右,说明划分工作日和休息日数据对模型预测精度具有较大提升。

4 结 论

本文将图神经网络与自注意力机制相结合构建了图自注意力机制,结合 Transformer 模型,通过自注意力机制提取数据的时间特征、图自注意力机制提取数据的空间特征,构建结构为时间—空间—时间的“三明治”时空特征提取模块,提出了时空 Transformer 交通流预测模型 STTF。针对多头注意力提取的多个特征,考虑到非重要特征会影响模型预测效率和预测精度的问题,利用 XGBoost 对 STTF 模型的输出特征进行选择,剔除不重要的特征,构建了 STTF-XGB 模型。针对工作日和休息日交通流数据变化趋势的不同,通过皮尔逊相关性系数对交通流数据集按照工作日和休息日进行划分,提高数据的周期稳定性,并通过消融实验证明了数据按照周期性划分能够有效提高模型的预测精度。

通过实际数据对模型预测效果进行检验,实验结果证明当预测区间在 15~75 min 时,STTF-XGB 模型的预测结果相较于 XGBoost、BiLSTM 和 Transformer 等时间序列预测模型在预测精度上提升约 20%~30%;相较于时空融合预测模型 GCN-BiLSTM 和 GAT-BiLSTM 在预测精度上提升约 5%~10%,STTF-XGB 模型具有较高的预测精度。消融实验结果表明,相较于使用原始数据集的预测结果,经过数据划分的 STTF-XGB-1 实验在 MAE 和 RMSE 误差评价指标上提升约 20%~30%,验证了数据划分对模型预测精度具有提升作用。由于模型在中短期预测中具有优势,且可一次性进行中短期交通流预测,在实际应用中,中期预测能够满足交通管理者的交通规划需求,短期预测能够满足交通控制需求。中期规划可减轻短时间的交通控制的管理压力,更好的缓解交通拥堵。

参考文献

- [1] 殷礼胜,魏帅康,孙双晨,等.基于 FEEMD-SAPSO-BiLSTM 组合模型的短时交通流预测[J].电子测量与仪器学报,2021,35(10):72-81.
- [2] 殷礼胜,孙双晨,魏帅康,等.基于自适应 VMD-Attention-BiLSTM 的交通流组合预测模型[J].电子测量与仪器学报,2021,35(7):130-139.

- [3] 霍嘉男,成卫,李冰. 基于多特征数据融合的城市道路行程速度预测[J]. 深圳大学学报(理工版),2023,40(2):195-202.
- [4] 王宁. 基于自注意力机制的交通流量预测研究[D]. 南昌:南昌大学, 2019:14-18.
- [5] HAN X, GONG S. LST-GCN: Long short-term memory embedded graph convolution network for traffic flow forecasting [J]. Electronics, 2022, 11(14): 2230.
- [6] 贺文武,裴博彧,毛国君,等. 基于轻量时空图卷积模型的路网交通流预测[J]. 铁道科学与工程学报, 2022,19(9):2552-2562.
- [7] 汪鸣,彭舰,黄飞虎. 基于多时间尺度时空图网络的交通流量预测模型[J]. 计算机科学, 2022, 49(8): 40-48.
- [8] 焦朋朋,安玉,白紫秀,等. 基于 XGBoost 的短时交通流预测研究[J]. 重庆交通大学学报(自然科学版), 2022,41(8):17-23,66.
- [9] 邹耀斌,齐慧康,孙水发. 皮尔逊相关性最大化导向的自动阈值分割方法[J]. 电子测量技术, 2023, 46(17):109-117.
- [10] RASAIZADI A, SEYEDABRISHAMI S. Stacking ensemble learning process to predict rural road traffic flow [J]. Journal of Advanced Transportation, 2022;3198636.
- [11] 屈展,赵鑫,屈伸. 引入果蝇优化算法的最小二乘支持向量机交通流量预测[J]. 电子测量技术, 2018, 41(16):18-22.
- [12] 张文胜,郝汝奇,朱冀军,等. 基于改进灰狼算法优化 BP 神经网络的短时交通流预测模型[J]. 交通运输系统工程与信息, 2020, 20(2):196-203.
- [13] 周金治,刘艺涵,吴斌. 基于 ARIMA 与 GGA 算法的 ETL 任务调度机制研究[J/OL]. 控制工程,1-8[2022-10-29].
- [14] 张阳,胡月,陈德旺,等. 基于 GCN-BiLSTM 的短时交通流预测模型[J]. 武汉理工大学学报(交通科学与工程版),2023,47(5):802-806.
- [15] 殷礼胜,吴洋洋. 基于改进 VMD-GAT-GRU 的交通流量组合预测模型[J]. 电子测量与仪器学报, 2022, 36(7):62-72.

作者简介

李昕光(通信作者),博士,副教授,主要研究方向为智能交通。

E-mail:xinguangli@qut.edu.cn