2026 年 第 26 卷 第 29 期
2026, 26(29): 12803-07
科 学 技 术 与 工 程
Science Technology and Engineering
ISSN 1671-1815
CN 11-4688/T

DOI:10.12404/j.issn.1671-1815.2507676
引用格式:王启明, 白继根, 冯斯特, 等. 基于卡口数据的高速公路交通流预测[J]. 科学技术与工程, 2026, 26(29): 12803-12809.
Wang Qiming, Bai Jigen, Feng Site, et al. Highway traffic flow prediction based on checkpoint data[J]. Science Technology and Engineering, 2026, 26(29): 12803-12809.

# 基于卡口数据的高速公路交通流预测

王启明[1], 白继根[1], 冯斯特[2], 马登云[3], 张全营[1], 李世发[3], 赵建东[2*]
(1. 北京云星宇交通科技股份有限公司, 北京 100070; 2. 北京交通大学交通运输学院, 北京 100044;
3. 河北省公安厅交管总队高速专班, 石家庄 050052)

**摘 要** 为提高高速公路交通流预测精度,结合 S-G 滤波器、双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)、门控循环单元(gated recurrent unit, GRU)等方法,提出了基于 S-G 滤波器的 BiLSTM-GRU 组合模型进行高速公路短时交通流预测。首先,该组合模型使用 S-G 滤波器合理去除数据中的噪声和异常波动,解决模型难以捕捉高速交通流量波动性较大的问题;其次,使用 BiLSTM,根据其双向优势捕捉交通流数据的长期依赖关系与时间模式;再次,利用 GRU 的自动学习特征,高效提取与转换 BiLSTM 的输出特征并输出预测值;最后,采用平均绝对误差(mean absolute error, MAE)、均方误差(mean square error, MSE)与平均绝对百分比误差(mean absolute percentage error, MAPE)对预测结果进行评价分析。实例分析选取京哈高速天津界(唐山段)104 km 主线卡口沈阳方向交通流数据,对组合模型预测性能进行分析,结果表明:基于 S-G 滤波器的 BiLSTM-GRU 组合模型相比传统单一模型及其他组合模型,MSE 改善了 0.75 ~ 51.28、MAE 改善了 0.14 ~ 3.82、MAPE 改善了 0.95% ~ 20.84%。可见,基于 S-G 滤波器的 BiLSTM-GRU 组合模型能够合理去除数据中的噪声和异常波动,提高高速公路短时交通流预测精度,为高速公路交通流管控提供理论依据。

**关键词** 智能交通; 组合预测; S-G 滤波器; 双向长短时记忆网络; 门控循环单元; 短时交通流预测
**中图法分类号** U491.1; **文献标志码** A

# Highway Traffic Flow Prediction Based on Checkpoint Data

WANG Qi-ming[1], BAI Ji-gen[1], FENG Si-te[2], MA Deng-yun[3], ZHANG Quan-ying[1],
LI Shi-fa[3], ZHAO Jian-dong[2*]
(1. Beijing Yunxingyu Traffic Technology Ltd., Beijing 100070, China; 2. School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044, China; 3. Hebei Provincial Public Security Department Traffic Control Corps High Speed Class, Shijiazhuang 050052, China)

[**Abstract**] In order to improve the prediction accuracy of expressway traffic flow, combined with S-G filter, bidirectional long short-term memory(BiLSTM), gated recurrent unit(GRU) and other methods, a BiLSTM-GRU combined model based on S-G filter was proposed to predict the short-term traffic flow of expressways. First, the S-G filter was employed to reasonably remove noise and abnormal fluctuations from the data, addressing the issue of models struggling to capture the high volatility of traffic flow. Second, BiLSTM was utilized to leverage its bidirectional advantage in capturing long-term dependencies and temporal patterns in traffic flow data. Third, GRU was employed to automatically learn features, efficiently extracting and transforming the output features of BiLSTM to produce predicted values. Finally, the mean absolute error (MAE), mean square error (MSE), and mean absolute percentage error (MAPE) were used to evaluate and analyze the prediction results. The case analysis selects the traffic flow data of the 104 km main line bayonet Shenyang direction of the Beijing-Harbin Expressway in Tianjin (Tangshan section), and analyzes the prediction performance of the combined model. The results show that the BiLSTM-GRU combined model based on S-G filter improves MSE by 0.75 to 51.28, MAE by 0.14 to 3.82, and MAPE by 0.95% to 20.84% compared with the traditional single model and other combined models. It can be seen that the BiLSTM-GRU combined model based on S-G filter can reasonably remove noise and abnormal fluctuations in the data, improve the prediction accuracy of short-term traffic flow on expressways, and provide a theoretical basis for traffic flow control on expressways.

[**Keywords**] intelligent transport; combined prediction; S-G filter; bidirectional long short-term memory network; gated recurrent unit; short-term traffic flow prediction

**收稿日期**: 2025-11-05 **修订日期**: 2026-04-21
**基金项目**: 国家自然科学基金面上项目(72371019);北京云星宇交通科技股份有限公司 2024 年度科研项目(X9224147)
**第一作者**: 王启明(1975—),男,汉族,江西安福人,硕士,高级工程师。研究方向:智能交通。E-mail:wangqiming@yunxingyu.com。
*通信作者: 赵建东(1975—),男,汉族,山西忻州人,博士,教授。研究方向:智能交通系统。E-mail:zhaojd@bjtu.edu.cn。

随着人们出行需求的提高,全国汽车保有量逐年上升,截至2024年年底,全国机动车保有量已达到4.53亿辆。近年来,城市内与城市间的交通拥堵现象日益严重,在高速出行高峰期间,容易造成交通事故,增加出行延误,缓解交通拥堵现象成为亟须解决的难题,而交通流预测能够基于历史数据学习进行合理预测,为交通流量管控提供科学的理论依据与数据依据。因此,交通流预测技术已成为城市交通与智慧交通研究的重要内容。

交通流预测技术主要分为短期、中期、长期预测三种,目前应用较多,且预测精度较高的为短期预测。早期学者主要采用参数与非参数模型进行交通流预测,最早由 Voort 等[1]使用自回归积分滑动平均模型进行交通流预测;Okutani 等[2]将卡尔曼滤波模型应用到交通预测领域,但以上方法预测效果较差。参数模型法是一种简单快捷的预测方法,通过结合历史数据、时间变化趋势进行预测,但其对波动性大、影响因素多的交通流预测效果较差;非参数模型法主要包含非参数回归、$K$ 最近邻算法等方法,能够对复杂交通流进行预测,但耗时长,准确性低。

为进一步提高预测精度,研究学者开始采用机器学习与深度学习方法进行预测,并通过合理方式将方法组合。传统机器学习主要包含 $K$ 近邻算法、支持向量机等,传统机器学习算法能够结合历史数据进行学习训练,预测较复杂的交通流,但仍难以精准预测大规模交通流量。深度学习主要包含卷积神经网络、循环神经网络、图神经网络与众多改进方法,通过合理构建神经网络结构,精准预测交通流量,但单一的算法难以解决流量的波动性、干扰因素等问题,因此,学者提出组合算法,将两种或两种以上的模型组合,进一步提高预测精度。

其中长短期记忆(long short-term memory, LSTM)神经网络与门控循环单元(gated recurrent unit, GRU)神经网络,通过改进循环神经网络(recurrent neural network,RNN)得到的深度学习方法受到广泛应用。Wang 等[3]将 CNN 与 LSTM 组合,并设置了3个特定特征的替代时空数据;程刚等[4]采用粒子群算法(particle swarm optimization,PSO)对长短期记忆网络模型(LSTM)进行改进,进一步提高预测效果;为进一步处理历史数据,庞学丽等[5]构建 VMD-ISSA-LSTM 组合模型对原始流数据进行分解处理,再通过 ISSA 优化 LSTM 预测交通流量;汤泽慧等[6]将 CNN、LSTM 与注意力机制组合,捕捉交通流数据特征,并使用注意力机制分配 LSTM 隐含层权重,进一步提高交通流预测精度;张召悦等[7]采用 ARMA 模型进行初始预测,AE 模型优化数据进行自适应压缩,最后通过 LSTM 模型修正初始预测结果;叶宝林等[8]发现双向长短时记忆网络(bidirectional long short-term memory,BiLSTM)较单一 LSTM 预测效果更佳,能够更好地获取数据相关性信息。因此,面对交通流量波动与 LSTM 的局限性,Li 等[9]提出融合注意力机制的双向长短期记忆模型(ATT-BiLSTM),以处理时间序列数据中的前向和后向依赖关系,并集成了注意力机制,进一步提高了交通流预测精度;史博等[10]为解决超参数设置问题,采用贝叶斯优化算法结合 LSTM 构建组合模型,取得良好预测效果;郝椿淋等[11]结合时间卷积网络(temporal convolutional network,TCN)与引入自注意力机制的 BiGRU 更全面获取交通流数据中的时间相关性,并取得较好的预测效果;考虑到 BiLSTM与 GRU 模型的优势,周睿等[12]将经验模态分解与长短期记忆模型结合进行交通流量预测,进一步提高预测精度;Ma 等[13]结合变分模态分解(variational mode decomposition,VMD)、双向长短时记忆网络(BiLSTM)和门控循环单元(GRU)的混合模型进行短时交通流预测,并验证其在短时交通流预测中的有效性。

综上所述,机器学习与深度学习方法的组合使用已经极大提高了交通流短期预测精度,且 LSTM 与 GRU 模型及双向模型的应用广泛,但目前对于两者的结合使用仍较少,高速公路流量的波动性较大,需要结合合理的数据处理方法与深度学习方法,目前的研究能够较好运用深度学习方法进行预测,但对数据的波动性处理研究尚且不足,为更好地分析与预测交通流量,现考虑高速公路交通流量数据波动性问题以及与深度学习模型结合使用的问题,提出基于 S-G 滤波器的 BiLSTM-GRU 模型,以提高高速公路交通流量预测精度,为高速公路交通流量管控提供数据与理论支撑。

## 1 基于 S-G 滤波器的 BiLSTM-GRU 组合模型

### 1.1 Savitzky-Golay 滤波器

Savitzky-Golay 滤波器(S-G 滤波器)方法相对简单快速,能够在时域内基于局域多项式最小二乘法进行拟合,以降低运算负担。该方法可以确保在与原信号形状与宽度保持一致的情况下,保留相对极大值、极小值并滤除原信号的噪声。因此,该方法能够广泛应用于数据流的平滑除噪处理。其主要原理是通过设置窗口宽度与多项式阶数,能够在不同场景下对低频成分进行拟合,进而平滑处理高

频成分。

S-G 滤波器主要有以下流程:①设置窗口宽度;②设置多项式阶数;③计算拟合系数。

在给定数据场景中,假设横坐标呈现均匀间距 $\Delta x$ ,对于每个点 $x_i$ ,选取其附近固定数量的点拟合构建多项式,多项式在 $x_i$ 处的取值定义为对应拟合光滑值 $g_i(g_i \in G)$。设定 $x_i$ 左侧有 $n_1$ 个点,右侧有 $n_r$ 个点,构建的多项式 $p_i(x)$ ,其是在最小二乘准则下,对包含 $x_i$ 在内的 $n_1 + n_r + 1$ 个点在最小二乘意义下拟合得到的, $k = n_1 + n_r$ ,因此它满足条件为

$$g_i = \sum_{j=0}^{k} b_j \frac{x^2 - x_i}{\Delta x} j \tag{1}$$

为使 $p_i(x)$ 拟合效果达到最优,实测数据为 $y$ ,必须定义 $b_j$ ,即

$$\min \sum_{j=i-n_l}^{i+n_r} [p_i(x_j) - y_j]^2 \tag{2}$$

定义矩阵为

$$\boldsymbol{A} = \begin{pmatrix} -n_1^k & \cdots & -n_1 & \cdots & 1 \\ \vdots & & & & \\ 0 & \cdots & 0 & \cdots & 1 \\ \vdots & & & & \\ n_r^k & \cdots & n_r & \cdots & 1 \end{pmatrix} \in \mathbf{R}^{n_r+n_l+1} \tag{3}$$

$$\boldsymbol{B} = \begin{bmatrix} b_k \\ \vdots \\ b_1 \\ b_0 \end{bmatrix} \in \mathbf{R}^{k+1} \tag{4}$$

$$\boldsymbol{Y} = \begin{bmatrix} y_{j-n_i} \\ \vdots \\ y_j \\ y_{j+n_r} \end{bmatrix} \in \mathbf{R}^{n_1+n_r+1} \tag{5}$$

由以上矩阵可得

$$\min \sum_{j=i-n_I}^{i+n_r} [p_i(x_j) - y_j]^2 = \min \| \boldsymbol{AB} - \boldsymbol{Y} \| \tag{6}$$

当式(6)达到最优时, $\boldsymbol{AB} = \boldsymbol{Y}$ ,即

$$\boldsymbol{A}^{\mathrm{T}}\boldsymbol{AB} = \boldsymbol{A}^{\mathrm{T}}\boldsymbol{Y} \tag{7}$$

由于 $\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A}$ 为正定矩阵可逆,因此

$$\boldsymbol{B} = (\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A})^{-1}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{Y} \tag{8}$$

因此可得

$$\boldsymbol{Y}_{\text{estimate}} = \boldsymbol{A}(\boldsymbol{A}^{\mathrm{T}}\boldsymbol{A})^{-1}\boldsymbol{A}^{\mathrm{T}}\boldsymbol{Y} \tag{9}$$

### 1.2　BiLSTM

长短时记忆网络(LSTM)基于循环神经网络(RNN)进行改进。RNN 模型在分析长时间序列时,可能会存储邻近时刻的信息,导致较长时刻信息丢失,容易发生梯度消失、爆炸问题,为优化信息传递流程,避免梯度消失现象,LSTM 引入细胞状态与输入、输出、遗忘门结构,并将 RNN 原有的隐含层修改为记忆块,使得信息能够较好地传递,有利于分析长时间序列,处理长期依赖关系[14]。以下为计算过程。

遗忘门:

$$\boldsymbol{f}_t = \sigma(\boldsymbol{W}_f[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_f) \tag{10}$$

输入门:

$$\boldsymbol{i}_t = \sigma(\boldsymbol{W}_i[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_i) \tag{11}$$

$$\tilde{\boldsymbol{C}}_t = \tanh(\boldsymbol{W}_c[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_c) \tag{12}$$

更新细胞状态(细胞状态 $\boldsymbol{C}_t$ 由遗忘门与输入门输出,通过加权更新):

$$\boldsymbol{C}_t = \boldsymbol{f}_t * \boldsymbol{C}_{t-1} + \boldsymbol{i}_t * \tilde{\boldsymbol{C}}_t \tag{13}$$

输出门:

$$\boldsymbol{o}_t = \sigma(\boldsymbol{W}_o[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_o) \tag{14}$$

$$\boldsymbol{h}_t = \boldsymbol{o}_t * \tanh(\boldsymbol{C}_t) \tag{15}$$

式中:$\sigma$ 为激活函数; $\boldsymbol{W}_f$ 、$\boldsymbol{W}_i$ 、$\boldsymbol{W}_c$ 为权重矩阵; $[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t]$ 为前隐藏状态与当前输入组合; $\boldsymbol{i}_t$ 为输入门 $t$ 时的激活值; $\tilde{\boldsymbol{C}}_t$ 为记忆细胞在 $t$ 时刻的更新状态; $\boldsymbol{h}_t = \boldsymbol{o}_t * \tanh(\boldsymbol{C}_t)$ 为输出门 $t$ 时的激活值; $\boldsymbol{h}_t$ 为 $t$ 时的隐藏状态; $\boldsymbol{W}_o$ 为权重矩阵; $\boldsymbol{b}_f$ 、$\boldsymbol{b}_i$ 、$\boldsymbol{b}_o$ 为偏置项; * 表示逐元素相乘(哈达玛积)。

双向长短期记忆网络(BiLSTM)是长短期记忆网络(LSTM)的一种扩展形式。其通过前向与后向 LSTM 单元组合而成,在处理时间序列数据的过程中,BiLSTM 通过并行两个方向相反的 LSTM 以实现信息的双向捕捉,使得模型能够同步整合序列中当前位置的历史与未来信息,突破传统单向 LSTM 仅能依赖历史信息进行推断的局限,并在时间序列预测中展现出更佳性能。

### 1.3　GRU

门控循环单元(GRU)是长短期记忆网络(LSTM)的变体形式,在保留循环神经网络(RNN)固有优势的基础上,增加了自动学习特征、能够对长距离独立信息进行有效建模的能力。通过简化网络结构,仅保留更新门和重置门以提升运算效率,因此相较于 LSTM 更简洁有效。

重置门:

$$\boldsymbol{r}_t = \sigma(\boldsymbol{W}_r[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_r) \tag{16}$$

根据权重,确定候选隐藏层状态信息 $\hat{\boldsymbol{h}}_t$ :

$$\hat{h}_t = \tanh(\boldsymbol{W}[\boldsymbol{r}_t\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}) \tag{17}$$

更新门:

$$z_t = \sigma(\boldsymbol{W}_z[\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_z) \tag{18}$$

根据获得的权重,计算当前隐藏层状态信息:

$$\boldsymbol{h}_t = (1 - z_t)\boldsymbol{h}_{t-1} + z_t\hat{\boldsymbol{h}}_t \tag{19}$$

输出:

$$\boldsymbol{y}_t = \sigma(\boldsymbol{W}_o\boldsymbol{h}_t + \boldsymbol{b}_o) \tag{20}$$

式中:$\boldsymbol{r}_t$、$z_t$ 为重置门、更新门状态;$\sigma$ 为激活函数;$\boldsymbol{W}_r$、$\boldsymbol{W}_z$、$\boldsymbol{W}_o$ 为权重矩阵;$[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]$ 为前隐藏状态与当前输入组合,$\boldsymbol{h}_t$ 为 $t$ 时的隐藏状态,为权重矩阵;$\boldsymbol{b}_r$、$\boldsymbol{b}_z$、$\boldsymbol{b}_o$ 为系数向量;$\boldsymbol{x}_t$、$\boldsymbol{y}_t$ 为输入、输出量。

### 1.4 模型构建

由于高速公路卡口检测数据缺失与异常值较多,采用历史两周同期均值进行数据缺失值与异常值的修正,并选取京哈高速天津界(唐山段)104 km 主线卡口沈阳方向 7 d 的数据进行分析,如图 1 所示,高速公路交通流量存在一定规律的趋势与高峰时段,但其交通流量波动性较大,模型难以进行学习预测。

针对高速交通流波动性较大问题,采用 S-G 滤波器对交通流量数据进行平滑,窗口宽度设置为 11,多项式阶数设置为 2,平滑后的 1 d 数据对比图如图 2 所示,可以发现 S-G 滤波器方法相对简单,能够合理去除数据中的噪声和异常波动,既保留了原数据的趋势,也能够保留相对极大值、极小值并滤除原信号的噪声,解决模型难以捕捉高速交通流量波动性较大的问题,因此选用 S-G 滤波器作为组合模型的方法之一。

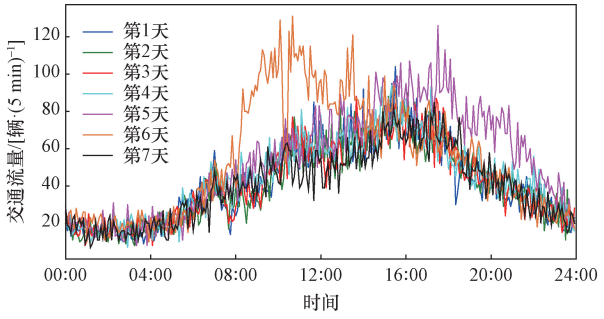


图 1 高速公路 586 卡口 7 d 数据对比

Fig. 1 Comparison of 7-day data of 586 checkpoint of expressway

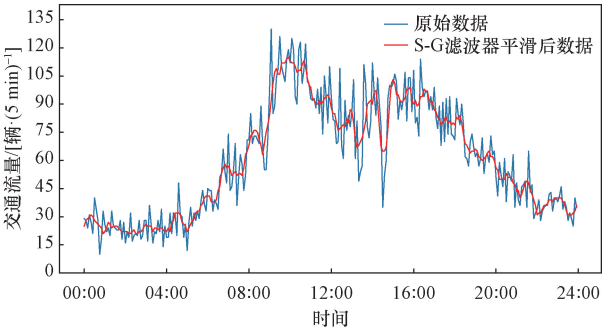


图 2 S-G 滤波器平滑前后数据对比

Fig. 2 Comparison of data before and after S-G filter smoothing

在对交通流量数据进行平滑后,可见数据波动性降低,可将平滑后的数据输入模型进行训练、预测。由于 BiLSTM 能够通过并行两个方向相反的 LSTM 以实现信息的双向捕捉,使得模型能够同步整合序列中当前位置的历史与未来信息,突破传统单向 LSTM 仅能依赖历史信息进行推断的局限,通过 BiLSTM 捕捉数据中的长期依赖关系,并学习交通流量中的时间模式。GRU 在保留循环神经网络固有优势的基础上,增加了自动学习特征、能够对长距离独立信息进行有效建模的能力。通过简化网络结构,仅保留更新门和重置门以提升运算效率,在 BiLSTM 捕捉数据中的长期依赖关系、学习交通流量中的时间模式并输出数据后,由 GRU 进一步处理 BiLSTM 输出,高效地处理这些复杂特征,进行特征提取与转换,最终输出预测值。

基于 S-G 滤波器的 BiLSTM-GRU 组合模型步骤如图 3 所示,具体流程如下。

**步骤 1** 获取交通流原始数据,依据阈值法识别缺失或异常的交通流数据,根据短时交通流数据之间的时间相关性,采用同期历史均值法进行修正。

**步骤 2** 将处理好的交通流量数据使用 S-G 滤波器进行平滑,去除数据中噪声与异常波动,窗口宽度设置为 11,多项式阶数设置为 2。

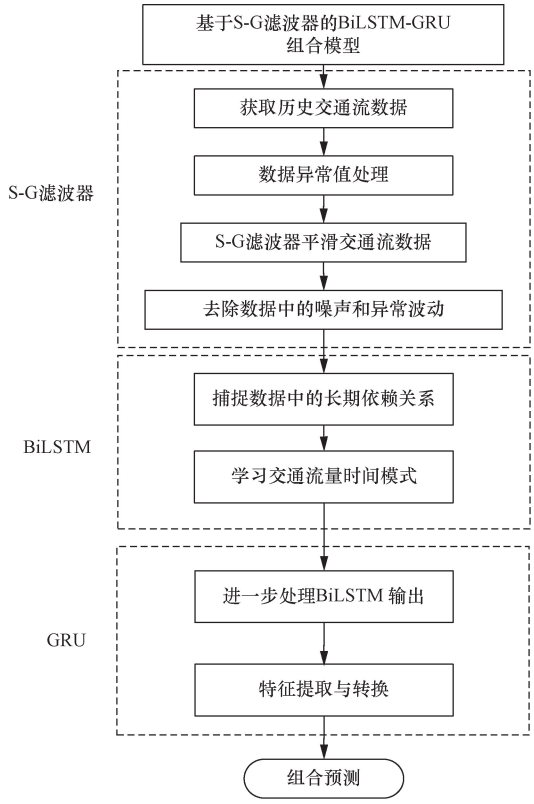


图 3 组合预测模型功能架构图

Fig. 3 Function architecture diagram of hybrid prediction model

**步骤 3**　将平滑后的交通流量数据输入BiLSTM中,通过双向 LSTM 实现信息的双向捕捉,获取数据中的长期依赖关系,学习交通流量时间模式。

**步骤 4**　将 BiLSTM 输出输入 GRU,进一步处理 BiLSTM 输出,高效处理复杂特征,进行特征提取与转换,最终输出预测值。

## 2　预测误差指标

为检验该组合模型的性能,采用平均绝对误差(MAE)、均方误差(MSE)与平均绝对百分比误差(MAPE)对预测结果进行分析评价。

平均绝对误差:

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i-y_i| \tag{21}$$

均方误差:

$$\mathrm{MSE}=\frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i-y_i|^2 \tag{22}$$

平均绝对百分比误差:

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i-y_i}{y_i}\right|\times 100\% \tag{23}$$

式中:$\hat{y}_i$ 为交通流量预测值;$y_i$ 为真实值;$n$ 为样本个数。

## 3　实例分析

### 3.1　数据来源

实例数据来源于河北高速交警卡口数据系统,为京哈高速天津界(唐山段)104 km 主线卡口沈阳方向,由道路卡口采集的过车数据,经去重、异常值修正后得到的交通流数据。数据获取区间为 2024 年 6 月 1—30 日,获取形式为过车信息,经处理去重与异常值处理计算得出卡口每 5 min 的交通流量,每日 288 条交通流量数据,共 30 d 交通流量数据,将前 29 d 作为训练集,最后 1 d 作为测试集。

### 3.2　组合模型参数设置

组合模型参数设置如下时,预测效果最优。S-G 滤波器设置窗口宽度为 11,多项式阶数设置为 2,可在滤除噪声的同时,保留预测所需的关键时间特征,其中,窗口宽度代表 S-G 滤波器拟合时选取的邻域数据点数量,由于偶数数量无中心锚点需插值处理,容易导致数据失真,因此优先选择奇数为 3、5、7、9、11 等,研究内容为 5 min 粒度交通流数据,窗口通常设 11,以对应覆盖 11×5=55 min 的交通流数据,以滤除随机噪声,同时保留小时级短期趋势,该时间尺度既能够捕捉 5 min 粒度下交通流的短期连续趋势,如早晚高峰的流量上升与下降,且不会因窗口过宽导致局部波动特征被模糊,也不会因窗口过窄导致降噪不充分,无法滤除数据中的随机噪声;多项式阶数设置为 2,由于 1 阶多项式的线性拟合无法捕捉交通流的非线性趋势,会丢失关键的非线性时间特征;大于等于 3 阶多项式会过度拟合数据,将噪声当作有效特征拟合,导致平滑后的数据失真,会降低预测精度;2 阶多项式二次拟合能够有效拟合交通流的非线性趋势,同时避免过度拟合,适合实时或高频更新的交通数据处理场景,保证计算效率。

BiLSTM 模型输入维度设置为 1,对应输入的交通流量单特征;隐藏层维度设置为 128,为每个 LSTM 单元的隐藏状态维度,128 属于中等维度,能够捕捉交通流量的周期性、趋势性等,且不会因维度过高导致过拟合、计算成本激增;层数设置为 2,第一层捕捉局部时间依赖,第二层进一步提取高阶特征;由于启用双向 LSTM,故输出特征维度为 256。

GRU 模型输入维度设置为 256,用于接收 BiLSTM的双向输出作为输入;隐藏层维度设置为 128,与 BiLSTM 的隐藏层维度保持一致,可避免特征维度突变导致的信息损失,且 GRU 能够通过门控机制对输入进行筛选和压缩,保留关键特征,同时简化计算;层数设置为 2,通过两层 GRU 进一步强化对长周期依赖的捕捉;作用于 GRU 的层间 dropout 设置为 0.3,防止层间特征共线性,降低过拟合风险,且仅当层数 > 1 时有效;GRU 输出后设置 dropout 正则化,其中 dropout = 0.3,用于对 GRU 的输出特征进行随机失活,防止过拟合。

组合模型训练相关超参数中,批大小设置为 64,学习率设置为 0.001,使用 Adam 优化器,训练轮次设置为 150,并采用早停策略,设置 patience = 15。

### 3.3　预测结果分析

基于 S-G 滤波器的 BiLSTM-GRU 组合模型预测结果与 S-G 滤波器平滑处理后实际流量对比如图 4 所示,可见预测效果较好,且预测残差值基本在 ±10 以内,综上可以说明预测的有效性。

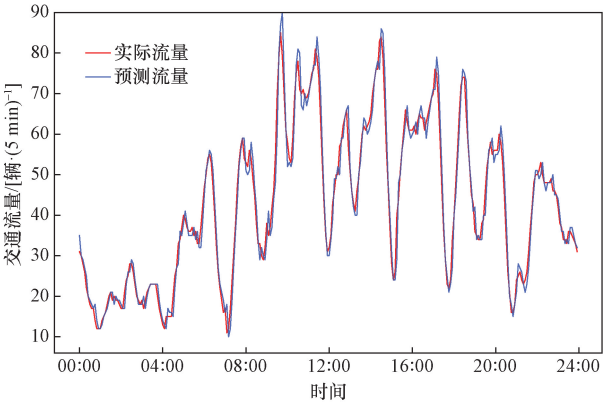


图 4　组合模型预测结果

Fig. 4　Prediction results of the mixed model

为进一步验证组合模型的有效性与优势,选取了如表1所示的基础方法,并采用相关方法进行组合预测以验证预测模型组合的有效性。为保证预测结果对比公平性,在同一设备上进行模型训练与预测。数据均采用京哈高速天津界(唐山段)104 km主线卡口沈阳方向,由道路卡口采集的2024年6月1—30日的交通流数据,前29 d为训练集,最后1 d为测试集。对于LSTM、GRU、BiLSTM等神经网络类对比模型,其结构参数与训练超参数与S-G滤波器-BiLSTM-GRU组合模型一致,统一设置相同输入维度、隐藏层维度128、训练批大小64、Adam优化器、学习率0.001等关键参数。对于STL、VMD等含数据处理方法的对比模型,其处理参数参考交通流预测领域成熟研究选取适配5 min粒度数据的最优值;ARIMA模型通过ADF平稳性检验、自相关分析确定最优阶数。所有对比模型均处于自身性能最优的参数状态,确保模型预测结果差异仅由结构合理性与方法适配性决定。预测结果评价采用均方误差(MSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)三种指标。对比结果如表1所示。

综上分析,参数模型ARIMA虽然预测复杂度低,但易受数据不平稳、非线性的影响,在复杂场景下,尤其是数据波动性较大场景下预测效果较差;单一神经网络模型LSTM、GRU算法,虽能在一定程度上进行简单时序数据预测,但存在单独使用时误差较大、精度不足、难以处理复杂场景数据的缺点。S-G滤波器-BiLSTM-GRU组合模型结合了数据处理方法与预测模型的优势,首先通过S-G滤波器合理去除数据中的噪声和异常波动,在保留原数据的趋势基础上,保留相对极大、极小值,解决模型难以捕捉高速交通流量波动性较大的问题,接着采用BiLSTM与GRU进行预测,BiLSTM双向捕捉数据中的长期依赖关系,并学习交通流量中的时间模式,GRU自动学习特征,能够对长距离独立信息进行有效建模,通过BiLSTM捕捉数据中的长期依赖关系,学习交通流量中的时间模式输出数据后,高效地处理这些复杂特征,进行特征提取与转换,最终输出预测值。

**表1 各模型预测性能对比**

**Table 1 Comparison of prediction performance of each model**

| 模型名称 | MSE/[辆$^2$·(5 min)$^{-2}$] | MAE/[辆·(5 min)$^{-1}$] | MAPE/% |
|---|---|---|---|
| LSTM | 60.96 | 6.14 | 26.96 |
| GRU | 56.38 | 5.90 | 24.83 |
| ARIMA | 53.64 | 5.81 | 18.00 |
| STL-BiLSTM | 58.86 | 6.12 | 19.74 |
| STL-BiGRU | 52.96 | 5.78 | 18.49 |
| STL-LSTM | 58.40 | 6.06 | 19.10 |
| STL-GRU | 52.40 | 5.67 | 17.50 |
| STL-GRU-Transformer | 53.07 | 5.76 | 17.23 |
| STL-ARIMA-LSTM | 55.99 | 5.92 | 17.43 |
| STL-ARIMA-GRU | 55.37 | 5.89 | 17.42 |
| VMD-BiLSTM-BiGRU | 34.15 | 4.72 | 15.86 |
| VMD-BiLSTM-GRU | 33.98 | 4.71 | 15.38 |
| VMD-BiLSTM-GRU(S-G平滑数据) | 10.43 | 2.46 | 7.07 |
| S-G滤波器-BiLSTM-GRU | 9.68 | 2.32 | 6.12 |

S-G滤波器-BiLSTM-GRU组合模型的预测性能相较传统单一模型与其他多种组合模型均较好,所提出的组合模型预测误差更低。S-G滤波器-BiLSTM-GRU模型的MSE相比传统单一模型及其他组合模型改善了0.75~51.28、MAE改善了0.14~3.82、MAPE改善了0.95%~20.84%,具体原因是S-G滤波器方法相较其他数据处理方法,不仅能够合理对数据进行平滑,而且能有效保留关键信息,BiLSTM与GRU预测模型相较单一的LSTM或GRU能够更全面地捕捉数据特征,提升预测稳定性与准确性,将不同方法进行组合替换,验证了不同组合模型的预测结果会受到数据处理方法和基础模型性能的影响,S-G滤波器-BiLSTM-GRU组合模型相较LSTM、GRU、ARIMA、STL系列组合模型、VMD系列组合模型预测误差更低,证明了S-G滤波器-BiLSTM-GRU组合模型各组成部分的有效性,且该组合预测模型具有可行性与优势性。

## 4 结论

为进一步提高高速公路交通流预测精度,便于高速公路交通流管控,提出将S-G滤波器、双向长短期记忆网络与门控循环单元结合为组合模型,并基于京哈高速天津界(唐山段)卡口数据进行验证,得出如下主要结论。

(1)该组合模型相较传统模型,S-G滤波器能够去除数据中的噪声和异常波动,不仅能够保留原数据的趋势,还能保留原数据中的相对极大、极小值,解决传统模型难以捕捉高速交通流量波动性较大的问题,减少了交通流时间序列数据的非平稳性特征对预测精度的干扰,使得数据预处理效能得到实质性提升,双向长短期记忆网络在组合模型中能够利用其双向优势,捕捉交通流量数据长期依赖关系与时间模式,门控循环单元通过自动学习特征,高效提取转换BiLSTM输出特征,最终输出预测值。

(2)通过实例验证并与多种模型进行对比,证明该组合模型的可行性与优势。S-G滤波器-BiLSTM-GRU组合模型应用于高速公路短时交通流

预测时,其预测精度较好,能够满足高速公路短时交通流预测精度与管控的要求,为高速公路短时交通流预测提供理论与数据支持。

(3)但在实际场景应用中,交通流量预测会受到天气、节假日等情况的影响,后续的研究还需要对数据进行多尺度的分解与预测,进一步提高预测模型精度与泛化能力,为高速公路交通流量管控提供更优的理论与数据支撑。

## 参 考 文 献


[1] Voort M V D, Dougherty M, Watson S. Combining Kohonen maps with ARIMA time series models to forecast traffic flow[J]. Transportation Research Part C: Emerging Technologies, 1996, 4(5): 307-318.

[2] 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.

[3] Wang J D, Susanto C O N. Traffic flow prediction with heterogenous data using a hybrid CNN-LSTM model[J]. Computers, Materials & Continua, 2023, 76(3): 3097-3112.

[4] 程刚, 郭航宇, 朱弘昊. 基于 PSO-LSTM 的拉萨市短时交通流预测[J]. 道路交通管理, 2024(7): 54-57.
Cheng Gang, Guo Hangyu, Zhu Honghao. Short-term traffic flow prediction in Lhasa based on PSO-LSTM[J]. Road Traffic Management, 2024(7): 54-57.

[5] 庞学丽, 宋坤, 姚红云, 等. 基于 VMD-ISSA-LSTM 的短时交通流预测研究[J]. 现代电子技术, 2024, 47(8): 31-36.
Pang Xueli, Song Kun, Yao Hongyun, et al. Research on short-term traffic flow prediction based on VMD-ISSA-LSTM[J]. Modern Electronics Technique, 2024, 47(8): 31-36.

[6] 汤泽慧, 赵丹, 王晟由. 基于 CNN-LSTM-AM 的短时交通流量预测[J]. 科学技术与工程, 2024, 24(31): 13562-13567.
Tang Zehui, Zhao Dan, Wang Shengyou. Study on short-term traffic flow prediction based on CNN-LSTM-AM[J]. Science Technology and Engineering, 2024, 24(31): 13562-13567.

[7] 张召悦, 张红波. 基于 ARMA-AE-LSTM 模型的进场交通流预测方法[J]. 科学技术与工程, 2024, 24(27): 11919-11927.
Zhang Zhaoyue, Zhang Hongbo. Approach traffic flow prediction method based on ARMA-AE-LSTM model[J]. Science Technology and Engineering, 2024, 24(27): 11919-11927.

[8] 叶宝林, 戴本岙, 张鸣剑, 等. 基于图卷积网络的交通流预测方法综述[J]. 南京信息工程大学学报, 2024, 16(3): 291-310.
Ye Baolin, Dai Benao, Zhang Mingjian, et al. Review of traffic flow prediction methods based on graph convolution network[J]. Journal of Nanjing University of Information Science and Technology, 2024, 16(3): 291-310.

[9] Li Z, Xu H, Gao X, et al. Fusion attention mechanism bidirectional LSTM for short-term traffic flow prediction[J]. Journal of Intelligent Transportation Systems, 2024, 28(4): 511-524.

[10] 史博, 宋锋, 李轶群, 等. 基于交通流预测的高速公路收费站车道开闭配置[J]. 科学技术与工程, 2023, 23(30): 13157-13164.
Shi Bo, Song Feng, Li Yiqun, et al. Lane opening and closing configuration of expressway toll station based on traffic flow prediction[J]. Science Technology and Engineering, 2023, 23(30): 13157-13164.

[11] 郝椿淋, 张剑. 基于自注意力机制 TCN-BiGRU 的交通流预测[J]. 电子测量技术, 2024, 47(8): 61-68.
Hao Chunlin, Zhang Jian. Traffic flow prediction based on self-attention mechanism TCN-BiGRU[J]. Electronic Measurement Technology, 2024, 47(8): 61-68.

[12] 周睿, 邱爽, 孟双杰, 等. 基于差分处理的 EMD-LSTM 短时空中交通流量预测[J]. 科学技术与工程, 2025, 25(2): 842-849.
Zhou Rui, Qiu Shuang, Meng Shuangjie, et al. Short-term prediction of air traffic flow based on EMD-LSTM of differential processing[J]. Science Technology and Engineering, 2025, 25(2): 842-849.

[13] Ma C, Hu Y, Xu X. Hybrid deep learning model with VMD-BiLSTM-GRU networks for short-term traffic flow prediction[J]. Data Science and Management, 2025, 8(3): 257-269.

[14] 陆由付, 孔维麟, 田垚, 等. 基于 SSA-CNN-BiLSTM 组合模型的短时交通流量预测[J]. 交通运输研究, 2024, 10(1): 18-27.
Lu Youfu, Kong Weilin, Tian Yao, et al. Short-term traffic flow prediction based on SSA-CNN-BiLSTM combination model[J]. Transport Research, 2024, 10(1): 18-27.