

# EEMD + BiGRU 组合模型在短时交通流量预测中的应用\*

张玺君, 郝俊

(兰州理工大学 计算机与通信学院, 甘肃 兰州 730050)

**摘要:**针对城市交通流随机波动性强、数据中含噪声多导致预测精度下降的问题,提出一种基于集合经验模态分解(ensemble empirical mode decomposition, EEMD)和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的组合交通流量预测模型,有效地提升了短时交通流预测的精度。模型利用 EEMD 算法对原始数据进行分解,根据分解所得的本征模函数(intrinsic mode function, IMF)分量绘制噪声能量图谱,去除分量中的噪声,并将去噪后的 IMF 分量作为 BiGRU 网络的输入进行训练,再将训练所得的结果进行重构相加,得到最终的预测结果。实验结果表明,未舍弃含有噪声的 IMF 分量进行重构的预测结果,相比于参考文献中提出的 EMD + LSTM 模型、LSTM 模型和 EEMD + LSTM 模型,其平均绝对百分误差分别优化了 42.36%、61.82% 和 30.95%;舍弃含有噪声的 IMF 分量后进行重构的预测结果,其平均绝对百分误差相比于将全部 IMF 分量进行重构优化了 56.62%。

**关键词:**智能交通;交通时序数据;集合经验模态分解;双向门控循环单元;交通流预测

中图分类号:U491 文献标志码:A 开放科学(资源服务)标识码(OSID):  
文章编号:1001-2486(2023)02-073-08



听语音  
与作者  
互动  
聊科研

## Application of EEMD + BiGRU combination model in short-term traffic flow prediction

ZHANG Xijun, HAO Jun

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** Aiming at the problems of high random fluctuation of urban traffic flow and high noise in data, which leads to the decline of prediction accuracy, a combined traffic flow prediction model based on EEMD (ensemble empirical mode decomposition) and BiGRU (bidirectional gated recurrent unit) was proposed, which can effectively improve the accuracy of short-term traffic flow prediction. EEMD algorithm was used to decompose the original data, and the noise energy map was drawn according to the IMF (intrinsic mode function) component to remove the noise in the component. The denoised IMF components were trained as the input of BiGRU network. And the results of training were reconstructed and added to obtain the final prediction result. The experimental results show that, compared with the EMD + LSTM model, LSTM model and EEMD + LSTM model proposed in references, the mean absolute percentage errors are improved by 42.36%, 61.82% and 30.95% when the IMF components containing noise are not abandoned during reconstruction; after abandoning the IMF component containing noise, the mean absolute percentage error is improved by 56.62% compared with the reconstruction of all IMF components.

**Keywords:** intelligent traffic; traffic time series data; ensemble empirical mode decomposition; bidirectional gated recurrent unit; traffic flow prediction

短时交通流量预测是智能交通系统(intelligent traffic system, ITS)的一个重要内容,使用深度学习技术对城市路网的短时交通流预测进行研究具有重要的意义,主要表现在以下几个方面:

1)短时交通流量预测反映了未来一段时间内的交通流量变化趋势,交通管理部门可根据预测情况及时调整路口红绿灯时长,并合理分配人

力对不同拥堵地段进行交通诱导;

2)短时交通流量预测可以为交通参与者推荐最佳线路,出行者也可以根据未来一段时间的交通流量预测情况及时调整出行计划,避免因交通拥堵耽误行程;

3)能够极大地提高城市交通的智能化以及人们的出行效率。

\* 收稿日期:2021-04-22

基金项目:国家自然科学基金资助项目(62162040, 61966023);甘肃省高等学校创新基金资助项目(2021A-028);甘肃省科技计划资助项目(21ZD4GA028)

作者简介:张玺君(1980—),男,甘肃临洮人,副教授,博士,硕士生导师, E-mail: zhangxijun198079@sina.com

李磊等<sup>[1]</sup>使用卷积神经网络(convolutional neural networks, CNN)提取交通流数据的空间特征,再使用长短期记忆网络(long short-term memory, LSTM)提取数据的时间依赖特征,达到对交通流进行预测的目的。姚思佳等<sup>[2]</sup>提出了一种优化的误差反馈循环卷积神经网络模型,该模型在预测精度、构建效率及鲁棒性上均得到有效提高。王博文等<sup>[3]</sup>提出一种基于编码器-解码器(encoder-decoder, ED)框架的 LSTM 模型,能够有效地对交通流序列的多步及单因素、多因素进行预测。张维等<sup>[4]</sup>提出了一种基于多元因素的双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)高速公路交通流预测模型,该模型在高速公路短期交通流预测中的适用性更强、精确度更高。王庆荣等<sup>[5]</sup>将天气、节假日等外部因素融入模型中,使用 LSTM 网络与注意力机制进行预测。谷振宇等<sup>[6]</sup>建立了一种基于图卷积控循环单元(graph convolutional recurrent neural network, GCRNN)的交通流预测模型,取得了较好的预测结果。

此外,由于交通流时间序列具有非线性、非平稳性的特点,若不对原始交通数据进行数据预处理,则会对预测精度产生较大的影响。

戴邵武等<sup>[7]</sup>使用经验模态分解(empirical mode decomposition, EMD)算法对数据进行预处理,在此基础上使用了 LSTM 搭建预测模型。王志建等<sup>[8]</sup>在使用 EMD 对数据进行预处理的基础上,引入门控循环单元(gate recurrent unit, GRU)对模型进行训练。连义平<sup>[9]</sup>使用 EMD 算法对数据进行分解,并通过最小二乘支持向量机(least squares support vector machine, LSSVM)训练组合模型。Mei 等<sup>[10]</sup>采用了 EMD 算法对数据进行预处理,将遗传算法的交叉和变异因素引进粒子群算法来选择 SVM 的最优参数,从而得到了最优的模型。

文献[7-10]中采用的 EMD 方法,虽然能够对数据进行一定的去噪,但是会出现模态混叠的问题,即不能将高频分量与低频分量完全分离,使分解所得的结果失去具体的物理意义。因此,本文采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)对数据进行预处理,并对处理所得的分量进行能量分析,剔除数据中的噪声;文献[1,3,5]中采用的 LSTM 网络是解决时间序列预测问题的经典方法,但由于交通流数据具有时间相关性,为考虑前后车流量对交通流

的影响,同时为加快实验进程,采用 BiGRU 来提取时间特征。

## 1 集合经验模态分解

EEMD<sup>[11]</sup>是对 EMD 的一种改进。EMD<sup>[12]</sup>可以对非平稳、非线性的时间序列进行平稳化处理,并且不需要预先设置任何参数,将时间序列  $T(t)$  输入后便可分解为  $N$  个本征模函数(intrinsic mode function, IMF)分量  $I_n(t)$  和残余分量  $R(t)$ ,即

$$T(t) = \sum_{n=1}^N I_n(t) + R(t) \quad (1)$$

式中: $I_n(t)$ 为时间序列  $T(t)$  的第  $n$  个 IMF 分量,  $n=1, 2, \dots, N$ ;  $N$  为所有 IMF 分量的数目; $t$  是该序列的时间尺度。

一般情况下,IMF 分量要满足两个条件<sup>[13]</sup>:

- 1) IMF 分量的极大值点与极小值点的总数与该分量过零点的个数相同或者相差不超过一个;
- 2) 在任意的时刻,IMF 分量的局部上、下包络线平均值为 0。

EEMD 算法<sup>[13]</sup>通过在原始序列中添加白噪声,将其进行多次平均后,白噪声可以相互抵消,此时极值点可近似看作是均匀分布的,由此,消除了模态混叠的问题。EEMD 的分解过程如下:

**步骤 1:**向原始时间序列  $T(t)$  添加白噪声  $W_1(t)$ ,得到一个新的时间序列  $P(t)$ 。

$$P(t) = T(t) + W_1(t) \quad (2)$$

**步骤 2:**找出时间序列  $P(t)$  的局部极大值点、极小值点,并绘制上、下包络线,求得平均值曲线  $V_1(t)$ ,从时间序列  $P(t)$  中去除  $V_1(t)$ ,得到第一个分量  $H_1(t)$ 。

$$H_1(t) = P(t) - V_1(t) \quad (3)$$

**步骤 3:**判断  $H_1(t)$  是否满足 IMF 分量条件。若满足,则向原时间序列  $T(t)$  添加不同的噪声序列  $W_i(t)$  ( $i=1, 2, \dots, N$ ),重复步骤 1~2,获得  $N$  个 IMF 分量记为  $H_i(t)$  ( $i=1, 2, \dots, N$ );若不满足,则重复步骤 2。

**步骤 4:**为了消除多次添加的白噪声信号对实际 IMF 分量的影响,将上述得到的  $N$  个  $H_i(t)$  ( $i=1, 2, \dots, N$ ) 进行整体的平均运算,则得到第一个 IMF 分量,记为  $\bar{I}_1(t)$ 。

$$\bar{I}_1(t) = \frac{1}{N} \sum_{i=1}^N H_i(t) \quad (4)$$

**步骤 5:**将  $\bar{I}_1(t)$  从原始时间序列  $T(t)$  中分离出来,得到第一个残差序列  $\bar{R}_1(t)$ 。

$$\bar{R}_1(t) = T(t) - \bar{I}_1(t) \quad (5)$$

步骤 6: 设  $\bar{R}_1(t)$  为时间序列  $T(t)$ , 反复进行步骤 1~5 共  $N$  次, 直到算法对剩余分量无法建模为止。

## 2 双向门控循环单元

GRU<sup>[14]</sup> 是较 LSTM 结构更加简单的一种神经网络。传统的 LSTM 通过三个门结构——输入门、遗忘门、输出门来控制输出, 而 GRU 网络只有两个门——更新门  $U(t)$ 、重置门  $N(t)$ , 具体结构如图 1 所示。该神经网络在训练时收敛速度较 LSTM 更快, 并且其效果更好, 所以也是当前非常流行的一种网络结构。

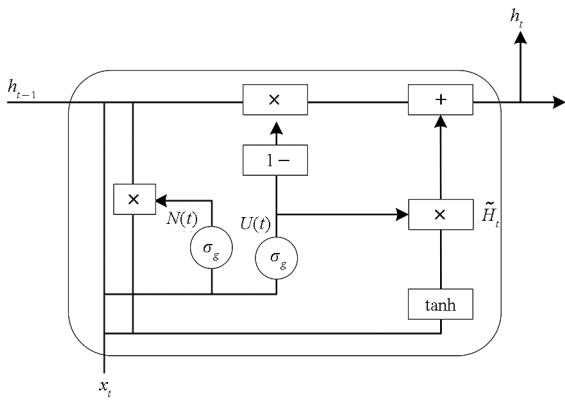


图 1 GRU 网络结构

Fig. 1 Network structure of GRU

双向门控循环单元 (bidirectional GRU, BiGRU) 结合了双向 RNN 和 GRU 的优点, 如图 2 所示, 其由一个前向 GRU 隐藏层和一个后向 GRU 隐藏层组成, 并且这两个隐藏层都与输出层相连接, 将前向和后向的信息同时传递给输出层。BiGRU 的输出为:

$$Y(t) = H_Y \cdot [h_t^{(F)}, h_t^{(B)}] + b_Y \quad (6)$$

式中:  $h_t^{(F)}$ 、 $h_t^{(B)}$  为前向、后向隐藏层的输出;  $H_Y$  为权值矩阵,  $b_Y$  为偏置项。

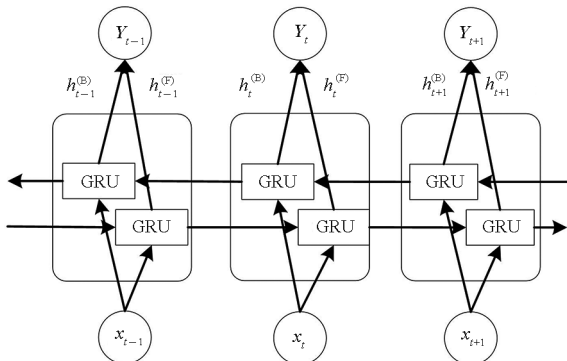


图 2 BiGRU 网络结构

Fig. 2 Network structure of BiGRU

## 3 EEMD + BiGRU 组合预测模型

### 3.1 模型结构

基于 EEMD + BiGRU 的组合预测模型的主要思想为: 利用 EEMD 算法对数据进行预处理, 得到若干 IMF 分量和趋势分量 Res; 绘制噪声能量图谱对 IMF 进行分析, 去除含有噪声的分量; 分别对剩余 IMF 使用 BiGRU 网络进行预测; 最后将预测结果加和重构, 实现短时交通流的预测。模型在  $t$  时刻的预测流程如图 3 所示。

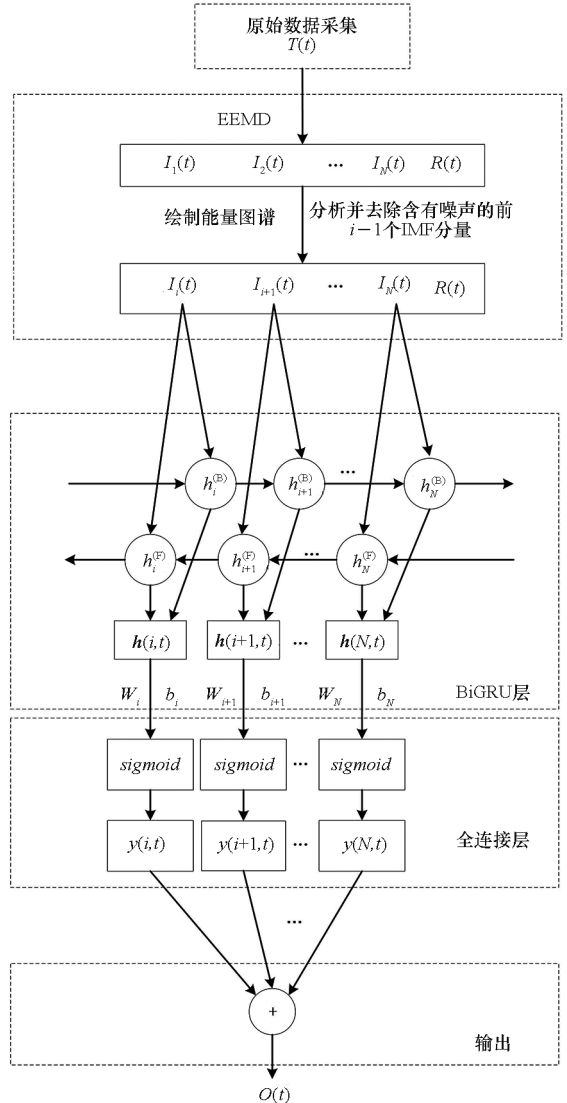


图 3 组合预测模型

Fig. 3 Combined prediction model

模型预测的具体过程描述如下:

- 1) 输入原始时间序列  $T(t)$ 。
- 2) 使用 EEMD 算法将  $T(t)$  分解为  $N$  个 IMF 序列  $I_m(t)$  ( $m=1, 2, \dots, N$ ) 和一个残差序列  $R(t)$ 。
- 3) 计算 IMF 序列能量值并绘制噪声能量图谱。

4) 根据最小能量准则剔除含有噪声的 IMF 分量。

5) 将去除噪声后的 IMF 序列输入 BiGRU 网络中进行时间特征提取, 在  $t$  时刻, 第  $m$  个 IMF 的输出为:

$$\mathbf{h}(m, t) = [h_i^{(F)}, h_i^{(B)}] \quad (7)$$

式中,  $\mathbf{h}(m, t)$  为  $t$  时刻第  $m$  个 IMF 通过 BiGRU 网络后的输出结果。

6) 将 BiGRU 网络的输出通过全连接层计算预测结果, 在  $t$  时刻第  $m$  个 IMF 的输出为:

$$y(m, t) = \text{sigmoid}[\mathbf{h}(m, t) \cdot \mathbf{W}_i + b_i] \quad (8)$$

式中:  $y(m, t)$  为  $t$  时刻第  $m$  个 IMF 通过全连接层后的输出,  $\mathbf{W}_i$  为 BiGRU 网络层到全连接层的权值矩阵,  $b_i$  为偏置项。

7) 输出  $t$  时刻的预测结果:

$$O(t) = \sum_{m=1}^N y(m, t) \quad (9)$$

### 3.2 损失函数

该模型以均方误差 (mean square error, MSE) 为优化目标, 目标函数为:

$$T_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (k_i - \hat{k}_i)^2 \quad (10)$$

式中,  $T_{\text{MSE}}$  为均方误差,  $\hat{k}_i$  为预测值,  $k_i$  为实际值,  $n$  为训练数据的个数。

更新权值、阈值的传统方法为梯度下降法, 在使用此种方法时很难选出一个合适的学习速率, 若学习率过高, 则迭代结果会越过局部极小值从而影响模型的收敛速度; 若学习率过低, 则模型的收敛速度过慢, 还易引起梯度发散的问题。因此, 在训练模型时, 采用自适应时刻估计方法 Adam 对模型的权值和阈值进行更新。Adam 算法能够计算每个参数的自适应学习速率, 其收敛速度更快, 学习的效果更佳, 从而使得参数的更新达到最优效果。

## 4 实验分析

### 4.1 实验数据与评价指标

实验采用美国明尼苏达州三个城市道路 2018 年 12 月的数据, 为方便实验, 本文使用 DetExtractorV3.5 对原始数据集进行数据抽取, 抽取后的数据时间间隔为 5 min, 数据样本为 2 949 条, 如图 4 所示, 将前 2 674 条数据作为训练集, 后 275 条作为测试集。

为了对模型的性能进行评估, 选择均方根误




图 4 数据样本

Fig. 4 Data sample

差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和平均绝对百分误差 (mean absolute percentage error, MAPE) 来评估模型的准确性, 三者的值越小, 模型的准确度越高。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{k}_i - k_i)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{k}_i - k_i| \quad (12)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{k}_i - k_i}{k_i} \right| \quad (13)$$

式中,  $n$  为预测样本的数量。

### 4.2 模型实施

实验环境为 ThinkPad 计算机 (Inter(R) Core (TM) i5 - 6200U CPU @ 2.30 GHz 2.40 GHz), 以 Keras 神经网络为基础框架, 在 Python3.6.5 中搭建神经网络并进行训练。组合模型的参数设置如下: 训练次数为 100 次, 每一个批大小为 1, BiGRU 隐藏层的神经元个数为 100; 为了避免过拟合的问题, 在全连接层和 BiGRU 层之间加入 Dropout, 在训练模型时随机删除 20% 神经元<sup>[13]</sup>。模型的网络结构如图 5 所示。

### 4.3 EEMD 分解结果

对数据进行 EEMD 分解后, 得到了 10 个 IMF 分量和一个 Res 趋势项, 如图 6 所示。由图可见, 图中 IMF1、IMF2、IMF3、IMF4、IMF5 频率较高, 为高频分量; IMF6、IMF7、IMF8、IMF9、IMF10、Res 分量频率较低, 为低频分量。

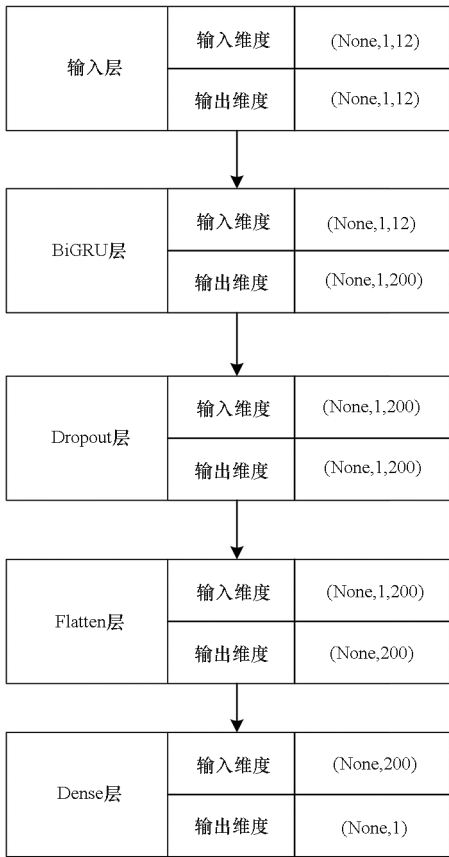












图5 网络结构


Fig.5 Network structure





(j) IMF10 分量

(j) IMF10 component



(k) Res 分量

(k) Res component

图 6 EEMD 分解

Fig. 6 EEMD decomposition

## 4.4 结果分析

### 4.4.1 参数分析

为探究采取不同的时间步长对模型预测准确性的影响,实验分别选择了用 5 min、15 min、30 min、45 min、60 min 来预测 5 min 的数据。实验结果如图 7 所示。




图 7 不同步长预测结果

Fig. 7 The predicted results of different step length

由以上实验结果可以看出,组合模型的最佳输入步长为 12,即用 60 min 的数据预测 5 min 的数据。

### 4.4.2 未去除 IMF 分量噪声的实验结果

选择模型 LSTM、GRU、BiGRU、EMD + LSTM、EMD + GRU、EEMD + LSTM、EEMD + GRU、EMD + BiGRU 与本文的 EEMD + BiGRU 进行对比。所有模型的超参数设置与 4.2 节描述相同,

用 1 h 的数据预测 5 min 的数据,故输入时间步长为 12。表 1 为不同模型的精度比较。

表 1 模型比较

Tab. 1 Model comparison

模型	性能评价指标		
	RMSE	MAE	MAPE/%
LSTM <sup>[15]</sup>	17.40	12.30	14.43
GRU	16.41	11.92	14.64
BiGRU	17.00	12.23	14.69
EMD + LSTM <sup>[12]</sup>	9.14	7.13	9.56
EMD + GRU	8.35	6.38	7.95
EMD + BiGRU	9.40	7.49	9.70
EEMD + LSTM <sup>[16]</sup>	7.53	6.24	7.98
EEMD + GRU	5.72	4.43	5.59
EEMD + BiGRU	5.07	3.96	5.51

从表 1 中可以看出,LSTM、GRU、BiGRU 三种单一模型的预测精度无明显区别,而在使用 EMD 算法对原始数据进行分解后,MAPE 较单一模型分别优化了 33.75%、45.70%、33.97%;使用 EEMD 算法对数据进行分解后,与 EMD + GRU、EMD + BiGRU 算法相比,MAPE 又分别优化了 29.69%、43.20%。本文所提模型与文献[12]提出的 EMD + LSTM 预测模型相比,MAPE 优化了 42.36%;与文献[15]提出的 LSTM 模型相比,MAPE 优化了 61.82%;与文献[16]提出的 EEMD + LSTM 相比,MAPE 优化了 30.95%。

### 4.4.3 去除 IMF 中噪声分量的实验结果

马鑫等<sup>[17]</sup>认为,根据最小能量准则,在含有噪声的信号中,噪声频段较高,当出现可用信号时,会打破 IMF 分量能量递减的规律,此时会产生一个局部的能量极小点,在该极小点之后,有用信号将代替噪声成为各 IMF 分量的能量主导。IMF 分量的能量为:

$$E_m = \sum_{i=1}^P [I_m(i)]^2 \quad (14)$$

式中: $E_m$  表示第  $m$  个 IMF 分量的能量值, $I_m(i)$  表示第  $m$  个 IMF 分量中的第  $i$  个数据。

根据式(14),得到各 IMF 的平方根能量值如图 8 所示。由图 8 可以看出,IMF1 到 IMF2 能量逐渐减小,并在 IMF2 达到最小,从 IMF3 开始能量逐渐增加,故选择 IMF2 作为噪声与信号的分界点,将 IMF3 之前的 IMF 分量舍弃。本文做了对比试验,如表 2 所示。






图 8 IMF 能量图

Fig. 8 IMF energy diagram

表 2 去除不同 IMF 后预测精度比较

Tab. 2 Prediction accuracy comparison after abandoning different IMF

模型	性能评价指标		
	RMSE	MAE	MAPE/%
EEMD + BiGRU	5.07	3.96	5.51
EEMD + BiGRU (去除 IMF1)	3.59	2.87	4.92
EEMD + BiGRU (去除 IMF1、IMF2)	2.21	1.72	2.39

由表 2 可见,舍弃 IMF1、IMF2 后,将预测结果进行重构,预测精度达到了最佳,相比于将全部结果进行重构,其 MAPE 优化了 56.62%。

#### 4.4.4 多步长预测结果

为验证本文 EEMD + BiGRU 模型在不同步长下预测的精确度,使用 1 h 的数据分别预测 15 min 后、30 min 后、45 min 后以及 1 h 后的数据,实验结果如表 3 所示。

表 3 多步长预测

Tab. 3 Multi-step prediction

步长	性能评价指标		
	RMSE	MAE	MAPE/%
15 min	3.59	2.62	3.72
30 min	7.91	5.82	8.30
45 min	12.76	9.57	13.12
1 h	18.69	13.30	16.94

由表 3 中数据可知,随着预测步长的增加,预测精度在逐渐下降。根据网络结构,本文使用的

BiGRU 网络中每一个 BiGRU 单元的状态会传递到下一个单元进行乘法、加法运算。当预测的时间步长增大时,意味着整个网络的运算时间会增加,同时也需要进行很多次的乘法、加法运算,从而导致有用的历史信息在逐渐减少,预测的精确度也在逐渐下降。

因此,本文所提模型在中长期预测问题上还有待改进。

#### 4.4.5 分时段预测结果

为验证所提模型在不同场景下的预测效果,本文将实验中的周末数据与工作日数据进行了分析。实验结果如表 4 所示。

表 4 不同场景下实验结果

Tab. 4 Experimental results under different scenarios

模型	MAPE/%	
	工作日	周末
EEMD + BiGRU	2.35	1.91
LSTM <sup>[15]</sup>	14.44	14.55
EMD + LSTM <sup>[12]</sup>	11.30	10.54
EEMD + LSTM <sup>[16]</sup>	5.33	4.06

由表 4 可得,在工作日与周末时段,本文所提模型相比于参考模型 LSTM, MAPE 分别优化了 83.73%、86.88%,相比于参考模型 EMD + LSTM, MAPE 分别优化了 79.20%、81.88%;相比于参考模型 EEMD + LSTM, MAPE 分别优化了 55.91%、52.96%。

## 5 结论

本文提出了 EEMD + BiGRU 组合模型对交通流进行短时预测。模型使用 EEMD 算法对数据进行分解,根据最小能量准则剔除噪声,利用 BiGRU 网络对数据的时间特征进行提取,实现了短时交通流量的预测。实验结果表明,EEMD + BiGRU 组合模型预测的精度较其他单一模型或 EMD 组合模型的预测精度有明显的提升,且在去除含有噪声的 IMF 分量后,模型的预测精度有进一步的提升。该模型的构建与预测的精度,满足了未来智能交通系统下短时交通流预测精确性的需求。

## 参考文献 (References)

[1] 李磊,张青苗,赵军辉,等. 基于改进 CNN-LSTM 组合模型的分时段短时交通流预测[J]. 应用科学学报, 2021, 39(2): 185 - 198.

- LI L, ZHANG Q M, ZHAO J H, et al. Short-term traffic flow prediction method of different periods based on improved CNN-LSTM[J]. Journal of Applied Sciences, 2021, 39(2): 185 - 198. (in Chinese)
- [2] 姚思佳, 桂智明, 郭黎敏. 基于改进 eRCNN 的局部路网交通流预测[J]. 计算机与现代化, 2021(7): 49 - 53, 64.
- YAO S J, GUI Z M, GUO L M. Local road network traffic flow prediction based on improved eRCNN[J]. Computer and Modernization, 2021(7): 49 - 53, 64. (in Chinese)
- [3] 王博文, 王景升, 王统一, 等. 基于长短时记忆网络的 Encoder-Decoder 多步交通流预测模型[J]. 重庆大学学报, 2021, 44(11): 71 - 80.
- WANG B W, WANG J S, WANG T Y, et al. Encoder-Decoder multi-step traffic flow prediction model based on long short-time memory network [J]. Journal of Chongqing University, 2021, 44(11): 71 - 80. (in Chinese)
- [4] 张维, 袁绍欣, 陶建军, 等. 基于多元因素的 Bi-LSTM 高速公路交通流预测[J]. 计算机系统应用, 2021, 30(6): 184 - 190.
- ZHANG W, YUAN S X, TAO J J, et al. Bi-LSTM expressway traffic flow prediction based on multiple factor data[J]. Computer Systems & Applications, 2021, 30(6): 184 - 190. (in Chinese)
- [5] 王庆荣, 田可可, 朱昌锋, 等. 融合多因素的短时交通流预测研究[J]. 计算机工程与应用, 2022, 58(21): 309 - 316.
- WANG Q R, TIAN K K, ZHU C F, et al. Short term traffic flow prediction based on multi-factors [J]. Computer Engineering and Applications, 2022, 58(21): 309 - 316. (in Chinese)
- [6] 谷振宇, 陈聪, 郑家佳, 等. 基于时空图卷积循环神经网络的交通流预测[J]. 控制与决策, 2022, 37(3): 645 - 653.
- GU Z Y, CHEN C, ZHENG J J, et al. Traffic flow prediction based on STG-CRNN [J]. Control and Decision, 2022, 37(3): 645 - 653. (in Chinese)
- [7] 戴邵武, 陈强强, 刘志豪, 等. 基于 EMD-LSTM 的时间序列预测方法[J]. 深圳大学学报理工版, 2020, 37(3): 265 - 270.
- DAI S W, CHEN Q Q, LIU Z H, et al. Time series prediction based on EMD-LSTM model [J]. Journal of Shenzhen University Science and Engineering, 2020, 37(3): 265 - 270. (in Chinese)
- [8] 王志建, 张炜健, 刘士杰. 基于 EMD-GRU 循环神经网络的转向交通流量组合预测[J]. 工业控制计算机, 2020, 33(12): 73 - 76.
- WANG Z J, ZHANG W J, LIU S J. Combined forecasting of turning traffic flow based on EMD-GRU recurrent neural network[J]. Industrial Control Computer, 2020, 33(12): 73 - 76. (in Chinese)
- [9] 连义平. 基于 EMD 和 LSSVM 组合模型的交通流量预测[J]. 电子设计工程, 2019, 27(11): 47 - 50, 55.
- LIAN Y P. Traffic flow forecast based on EMD and LSSVM combination model [J]. Electronic Design Engineering, 2019, 27(11): 47 - 50, 55. (in Chinese)
- [10] MEI D, YAN Q, GAO L N, et al. A short-term traffic flow prediction model based on EMD and GPSO-SVM [C]// Proceedings of IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference, 2017: 2554 - 2558.
- [11] 殷礼胜, 唐圣期, 李胜, 等. 基于 EEMD-IPSO-LSSVM 的交通流组合预测模型[J]. 电子测量与仪器学报, 2019, 33(12): 126 - 133.
- YIN L S, TANG S Q, LI S, et al. Combined model based on EEMD-IPSO-LSSVM for short-term flow traffic prediction[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 126 - 133. (in Chinese)
- [12] 张晓晗, 冯爱民. 基于经验模态分解和长短期记忆神经网络的短期交通流量预测[J]. 计算机应用, 2021, 41(1): 225 - 230.
- ZHANG X H, FENG A M. Short-term traffic flow prediction based on empirical mode decomposition and long short-term memory neural network [J]. Journal of Computer Applications, 2021, 41(1): 225 - 230. (in Chinese)
- [13] 陆文琦, 芮一康, 冉斌, 等. 智能网联环境下基于混合深度学习的交通流预测模型[J]. 交通运输系统工程与信息, 2020, 20(3): 47 - 53.
- LU W Q, RUI Y K, RAN B, et al. Traffic flow prediction based on hybrid deep learning under connected and automated vehicle environment [J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(3): 47 - 53. (in Chinese)
- [14] 桂智明, 李壮壮, 郭黎敏. 基于 ACGRU 模型的短时交通流预测[J]. 计算机工程与应用, 2020, 56(21): 260 - 265.
- GUI Z M, LI Z Z, GUO L M. Short-term traffic flow prediction based on ACGRU model [J]. Computer Engineering and Applications, 2020, 56(21): 260 - 265. (in Chinese)
- [15] 曹博, 高茂庭. 基于 LSTM 的短时交通流预测研究[J]. 现代计算机(专业版), 2018(25): 3 - 7.
- CAO B, GAO M T. Research on the short-term traffic flow prediction based on LSTM [J]. Modern Computer, 2018(25): 3 - 7. (in Chinese)
- [16] CHEN X Q, CHEN H X, YANG Y S, et al. Traffic flow prediction by an ensemble framework with data denoising and deep learning model[J]. Physica A: Statistical Mechanics and Its Applications, 2021, 565: 125574.
- [17] 马鑫, 郝亚南. 经验模态分解去噪方法研究[J]. 科技视界, 2018(23): 72 - 73.
- MA X, HAO Y N. Research on empirical decomposition denoising method [J]. Science & Technology Vision, 2018(23): 72 - 73. (in Chinese)