

肖玉怡, 郭小燕. 基于变分模态分解和优化后长短期记忆网络的短期交通流预测[J]. 智能计算机与应用, 2025, 15(12): 100-106. DOI: 10.20169/j.issn.2095-2163.24032203

基于变分模态分解和优化后长短期记忆网络的短期交通流预测

肖玉怡¹, 郭小燕²

(1 甘肃农业大学 理学院, 兰州 730070; 2 甘肃农业大学 信息科学技术学院, 兰州 730070)

摘要: 为了提升高速公路短期交通流预测的准确性, 为实时交通管理提供科学依据, 并优化道路智能交通系统, 本文提出使用变分模态分解对数据进行处理, 并结合基于鲸鱼优化算法优化后的长短期记忆网络模型的短时交通流预测方法。首先, 采用VMD降低原始交通流数据的非线性和非平稳性; 其次, 使用鲸鱼优化算法对LSTM模型的参数进行优化, 构建基于VMD-WOA-LSTM的短时交通流预测模型; 最后, 利用美国加州湾区高速公路传感器收集的交通流数据对所提方法的性能进行评价, 并与LSTM、EMD-LSTM、EEMD-LSTM、VMD-LSTM等模型对比。实验表明: VMD-WOA-LSTM模型能够更好地拟合交通流序列变化趋势, 具有更高的预测精度, 能够有效地进行短时交通流预测。

关键词: 智能交通; 短期交通流预测; 变分模态分解; 鲸鱼优化算法; 长短期记忆网络

中图分类号: U491.14; TP183 文献标志码: A 文章编号: 2095-2163(2025)12-0100-07

Short-term traffic flow prediction based on VMD-WOA-LSTM

XIAO Yuyi¹, GUO Xiaoyan²

(1 College of Science, Gansu Agricultural University, Lanzhou 730070, China;

2 College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: In order to improve the accuracy of highway short-term traffic flow forecast, it provides scientific basis for real-time traffic management. In this paper, a short-term traffic flow prediction method is proposed by using variational mode decomposition to process the data and combining with the long short-term memory neural network model optimized by whale optimization algorithm. Firstly, VMD is used to reduce the influence of the nonlinear and non-stationarity of the original traffic flow data on the prediction results. Secondly, whale optimization algorithm is used to optimize the parameters of the LSTM model, then a prediction model based on VMD-WOA-LSTM is constructed. Finally, the performance of the proposed method was evaluated by using the traffic flow data collected by highway sensors in the Bay Area of California, USA. Compared with LSTM, EMD-LSTM, EEMD-LSTM, VMD-LSTM and other models, the experiment shows that: VMD-WOA-LSTM model can better fit the changing trend of traffic flow sequence, has higher prediction accuracy, and can effectively forecast short-term traffic flow.

Key words: ITS; short-term traffic forecast; variational modal decomposition; whale optimization algorithm; long short-term memory network

0 引言

短期交通流预测在先进智能交通系统(ITS)中起着至关重要的作用^[1]。与中长期预测相比, 短区间更容易产生数据的波动, 因此准确的短期预测仍然是一个具有挑战性的课题, 目前短期预测模型主要分为参数模型、非参数模型和混合模型。

参数模型一般基于统计理论, 需要保证时间序列处于平稳状态。典型的参数模型如卡尔曼滤波, 在处理有噪声干扰的交通流方面表现优异^[2]; 灰色预测模型在样本数较少时也能达到较高的预测精度^[3]; 自回归积分移动平均模型采用差分将交通流转化为平稳序列^[4]。KUMAR等^[5]提出季节性自回归综合移动平均模型, 在自回归积分移动平均模型

基金项目: 国家自然科学基金(32360437); 甘肃农业大学青年导师基金(QAU-QDFC-2021-19)。

作者简介: 肖玉怡(1998—), 女, 硕士, 主要研究方向: 大数据分析。Email: 1926439557@qq.com。

通信作者: 郭小燕(1976—), 女, 博士, 教授, 主要研究方向: 大数据分析。

收稿日期: 2024-03-22

基础上引入季节因子,提高了交通流周期性特征的提取能力,在短期交通流预测中更为实用。然而,由于参数模型适用于线性数据,在处理非线性和大规模交通流方面效果不理想,无法满足短期交通流预测的时效性^[6]。

非参数模型具有较强的非线性拟合能力和自学习机制,在处理复杂交通流时具有优势。梯度增强决策树因其灵活性和可移植性在交通流预测中得到了广泛的应用^[7]。支持向量机由于具有较强的非线性收敛性能,可以有效地解决高维特征的回归问题^[8]。人工神经网络因其框架灵活、学习能力强,逐渐成为交通流预测的主要方法^[9]。循环神经网络(RNN)及其变体门控循环单元(GRU)和长短期记忆网络(LSTM)等深度学习方法在短期交通流预测中被广泛采用。

混合模型通过模型的合理组合可以克服单一模型的缺陷,因此成为短期交通预测中应用最广泛的方法^[10]。在数据采集过程中,交通数据经常受到天气状况、检测器状态等外生因素的干扰。因此,采集到的原始数据通常含有大量的噪声,会降低模型的性能^[11]。交通流的分解可以减少噪声的影响,提高预测精度^[12]。HAMAD 等^[13]将经验模态分解(EMD)与神经网络相结合,在真实环路检测器数据中预测短期行进速度;JIANG 等^[14]将集合经验模态分解(EEMD)与灰色支持向量机相结合,提出了适合短期预测的混合模型;朱永强等^[15]构建了互补集合经验模态分解(CEEMD)与最小二乘支持向量机(LSSVM)相结合的预测模型,使用 CEEMD 进行模态分解,通过对美国加利福尼亚的某高速公路交通数据进行预测的结果表明,此模型的平均相对误差为 6.51%,与其他模型相比拥有更好的预测结果;吴玲玲等^[16]提出一种 EMD 与差分进化算法优化反向传播神经网络(DE-BPNN)相结合的交通流预测模型,并利用实测交通数据进行实例验证,结果表明使用 EMD 分解后的模型预测精度更高;沈富鑫等^[17]提出一种 CEEMD 与 GRU 结合的交通预测模型,并利用上海市南北高架快速路实测交通数据进行验证,结果表明模型预测精度平均提升了 25.8%;邴其春等^[18]提出了一种将变分模态分解(VMD)与 LSTM 相结合的短时交通流预测方法,并利用上海南北高架快速路感应线圈数据进行分析验证,预测结果表明采用变分模态分解后的预测结果更为精确,相比于反向传播神经网络(BPNN)、LSTM、EMD-LSTM、EEMD-LSTM 等模型的预测结

果,在平均绝对误差(MAE)方面分别优化了 35.5%、28.25%、21.1%、13%。

以上分解方法取得了较好的预测效果,但 EMD 和其改进算法存在端点效应及模态混叠等一系列问题,因此本文采用 VMD 对原始数据进行模态分解,并将分解出的分量送入 LSTM 模型中进行短期交通流预测,以提升模型的短期交通流预测性能;为进一步提升模型的预测效果,采用鲸鱼优化算法(WOA)来优化 LSTM 模型的相关参数,建立 VMD-WOA-LSTM 短期交通流预测模型,并将该模型与 LSTM 模型、EMD-LSTM 模型、EEMD-LSTM 模型、VMD-LSTM 模型对比,结果表明本文模型的预测效果更好,并实验证明了模型的有效性。

1 理论基础

1.1 VMD 算法

VMD 算法是一种先进的时频信号分解算法^[19]。具体步骤可以表示为:

(1) 对 $u_k(t)$ 进行希尔伯特变换,得到单侧谱:

$$\hat{u}_k(t) = \int_0^t \delta(t-\tau) * u_k(\tau) d\tau \quad (1)$$

其中, $\delta(t)$ 为狄拉克分布函数, $*$ 为卷积运算。

(2) 变换后 $u_k(t)$ 乘以指数混合解调中心频率 $e^{-j\omega_k t}$, 将频谱转移至基带:

$$\left\{ \left[\delta(t) + \frac{j}{\pi t} \right] * u_k(t) \right\} \cdot e^{-j\omega_k t} \quad (2)$$

(3) 约束变分模型:

$$\begin{aligned} & \min_{\{u_k, \omega_k\}} \left\{ \sum_k \left\| \partial_t \left\{ \hat{u}_k(t) + \frac{j}{\pi t} \int_0^t \delta(t-\tau) * u_k(\tau) d\tau \right\} \cdot e^{-j\omega_k t} \right\|_2^2 \right\} \\ & \text{s. t. } \sum_k u_k = f \end{aligned} \quad (3)$$

其中, ∂_t 是求偏导数, k 是分量的个数。

(4) 引入第二惩罚因子 α 和拉格朗日乘子 λ , 将约束变分模型转化为无约束变分模型:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left\{ \hat{u}_k(t) + \frac{j}{\pi t} \int_0^t \delta(t-\tau) * u_k(\tau) d\tau \right\} \cdot e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (4)$$

(5) 使用交替方向乘法对 $u_k(t)$ 、 ω_k 及 λ 进行更新,更新公式如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^n(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_n^k)^2} \quad (5)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (6)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau(\hat{u}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (7)$$

其中, $\hat{f}(\omega)$ 、 $\hat{u}_k^n(\omega)$ 、 $\hat{\lambda}(\omega)$ 是 $f(\omega)$ 、 $u_k^n(\omega)$ 、 $\lambda(\omega)$ 傅里叶变换的结果; ω 是频率; n 是迭代次数; τ 是拉格朗日乘子的更新参数。

(6) 重复(5)直到满足收敛精度为止,从中得到 k 个窄带分量。迭代终止条件:

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (8)$$

1.2 WOA 优化算法

鲸鱼优化算法(WOA)是一种种群优化算法^[20]。其寻优过程如下:

(1) 猎物包围:寻优过程即座头鲸更新位置的过程,如下式所示,座头鲸的最终位置代表了搜索空间中的最优个体。

$$\mathbf{D} = |\mathbf{C} \cdot \mathbf{X}^*(t) - \mathbf{X}(t)| \quad (9)$$

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) - \mathbf{A} \cdot \mathbf{D} \quad (10)$$

其中, \mathbf{D} 表示座头鲸和猎物的距离; \mathbf{X}^* 为当前位置最优解; \mathbf{X} 为当前的位置; \mathbf{A} 和 \mathbf{C} 控制座头鲸的游动方式; t 为迭代次数。 \mathbf{A} 和 \mathbf{C} 计算公式如下:

$$\mathbf{A} = 2\mathbf{a} \cdot \mathbf{r} - \mathbf{a} \quad (11)$$

$$\mathbf{C} = 2 \cdot \mathbf{r} \quad (12)$$

其中, \mathbf{r} 为 $[0,1]$ 中的随机向量; T_{\max} 是最大迭代次数; \mathbf{a} 为控制参数。

\mathbf{a} 为控制参数:

$$\mathbf{a} = 2 - 2t/T_{\max} \quad (13)$$

(2) 泡泡网攻击:主要包括两种攻击行为,一个是收缩包围机制,另一种是螺旋更新位置,其数学模型如下式:

$$\mathbf{D}_1 = |\mathbf{X}^*(t) - \mathbf{X}(t)| \quad (14)$$

$$\mathbf{X}(t+1) = \mathbf{D}_1 \cdot e^{bl} \cdot \cos(2\pi l) + \mathbf{X}^*(t) \quad (15)$$

其中, \mathbf{D}_1 是座头鲸到猎物的距离; b 是常数; l 是 $[-1,1]$ 间的随机数。

(3) 猎物搜索:当 $|\mathbf{A}| \geq 1$ 时,随机选取某鲸鱼

来更新其位置,其数学模型如下式:

$$\mathbf{D}_{\text{rand}} = |\mathbf{C} \cdot \mathbf{X}_{\text{rand}} - \mathbf{X}(t)| \quad (16)$$

$$\mathbf{X}(t+1) = \mathbf{X}_{\text{rand}} - \mathbf{A} \cdot \mathbf{D}_{\text{rand}} \quad (17)$$

其中, \mathbf{X}_{rand} 为某鲸鱼的位置向量, \mathbf{D}_{rand} 表示某鲸鱼到座头鲸的距离。

1.3 LSTM 模型

LSTM 模型适合处理具有一定时间间隔的数据序列^[21]。本文采用 LSTM 进行短期交通流预测, LSTM 模型主要包括 4 个部分:记忆单元、遗忘门、输入门和输出门, LSTM 模型的网络结构如图 1 所示。

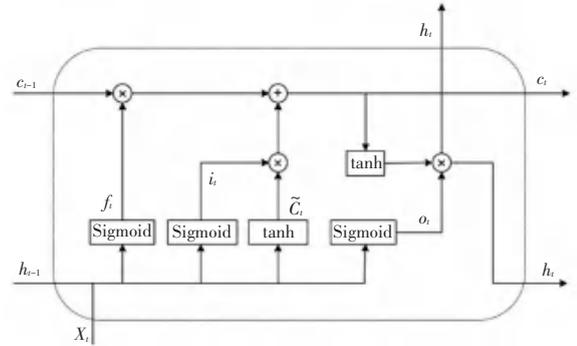


图 1 LSTM 网络结构

Fig. 1 LSTM network structure

记忆单元是整个 LSTM 模型的核心部件,用于存储过去信息的单元状态,记忆单元在时刻 t 的输出如下式:

$$\tilde{C}_t = \tanh(\mathbf{W}_c \cdot [h_{t-1}, \mathbf{X}_t] + b_c) \quad (18)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (19)$$

其中, \mathbf{X}_t 表示当前时刻的输入, C_{t-1} 是对 C_t 的更新。

遗忘门可以确定细胞状态中哪部分信息需要被删除,其输出如下式:

$$f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, \mathbf{X}_t] + b_f) \quad (20)$$

其中, Sigmoid(σ) 是激活函数; f_t 是遗忘门最终的输出值; b_f 是遗忘门的偏置值; \mathbf{W}_f 是遗忘门的加权矩阵。

输入门决定哪些信息可以进入单元状态,在 tanh 层创建候选值向量生成候选记忆,其中新信息则会被添加到单元状态中,以补充丢失的属性信息。另外,输入门更新存储在细胞状态中的信息,在 t 时刻的输出计算如下式:

$$i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, \mathbf{X}_t] + b_i) \quad (21)$$

输出门的结果可以通过 3 个主要部分来确定:前一刻的输入信息、在单元状态更新后存储的信息

以及最后一刻的输出信息。 t 时刻的输出如下式:

$$o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, \mathbf{X}_t] + b_o) \quad (22)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (23)$$

2 模型建立

2.1 基于 VMD-WOA-LSTM 的短时交通流预测模型

由于交通事故、天气情况等多种因素的影响,交通流时间序列表现出一定程度上的非线性和非平稳性,本文结合 VMD 算法较好的自适应性,将 VMD 算法与 LSTM 模型相结合,并利用 WOA 对 LSTM 模型的参数进行优化,构建 VMD-WOA-LSTM 短期交通流预测模型。使用 VMD 分解原始交通流数据,得到 K 个本征模态函数(IMF)分量,将训练集分量输入到 LSTM 模型中进行训练,由于 LSTM 模型的相关参数对预测结果影响较大,使用试凑法进行参数设置存在低效、主观的问题,因此本文采用 WOA 算法对 LSTM 模型的隐藏层节点数、训练次数及学习率这 3 个参数进行优化,以提升模型的预测精度,模型预测流程如图 2 所示,其中 WOA-LSTM 模型优化流程如图 3 所示。

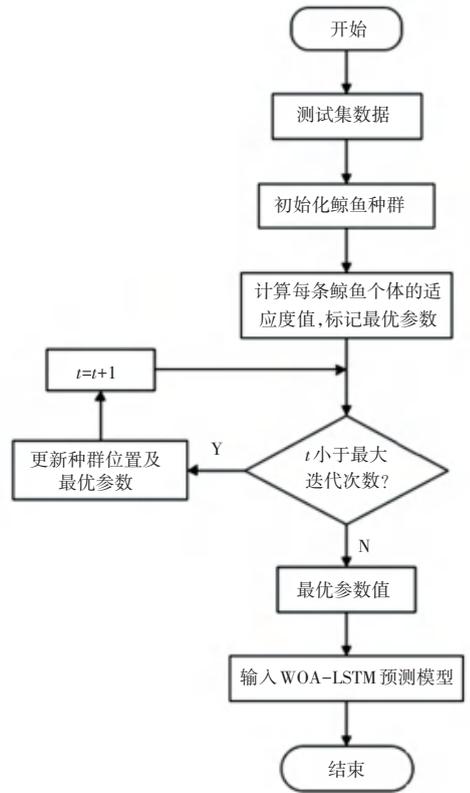


图 3 WOA-LSTM 模型优化流程

Fig. 3 WOA-LSTM model optimization process

模型预测步骤如下:

步骤 1 数据分解。使用 VMD 将序列分解为多个 IMF 分量;

步骤 2 标准化。为了保证数据集落在 $[0, 1]$ 的范围内,提高 LSTM 模型的收敛性,对数据集进行归一化处理;

步骤 3 参数优化。采用 WOA 算法对模型的参数进行优化,得到每个分解序列的最合适的参数组合;

步骤 4 预测和反归一化。使用超参数优化的 LSTM 模型对各 IMF 进行预测,并对结果进行反归一化,得到真实预测值;

步骤 5 叠加求和。将各 IMF 的预测结果叠加重构,即可得到交通流序列的最终预测结果;

步骤 6 预测性能分析。将交通流预测值与交通流实际值进行比较,评价模型的预测性能。

2.2 模型评价指标

选用平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)和拟合优度 R^2 作为本文模型预测效果的评估指标,公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (24)$$

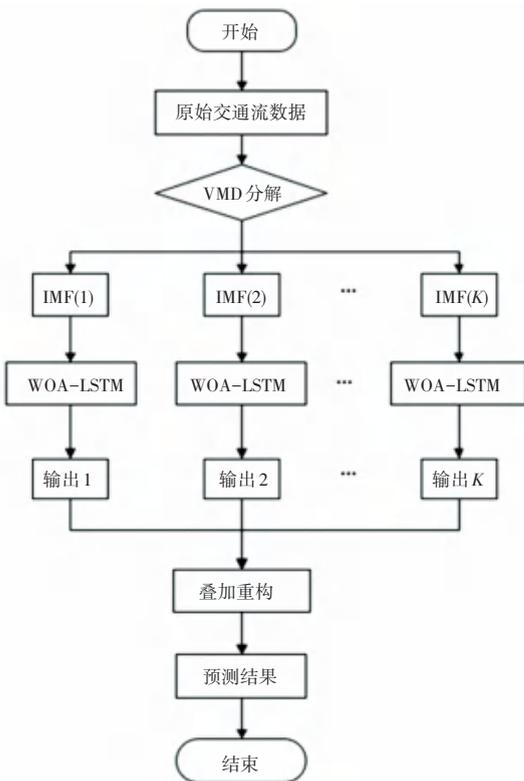


图 2 模型预测流程

Fig. 2 Model prediction process

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (25)$$

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (26)$$

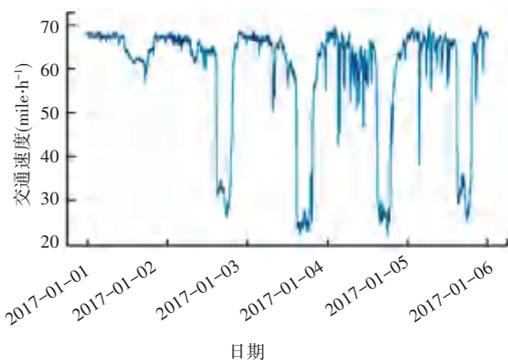
$$R^2 = 1 - \left(\sum_{i=1}^n (\hat{y}_i - y_i)^2 / \sum_{i=1}^n (\bar{y}_i - y_i)^2 \right) \quad (27)$$

其中: y_i 表示实际值, \hat{y}_i 表示预测值。

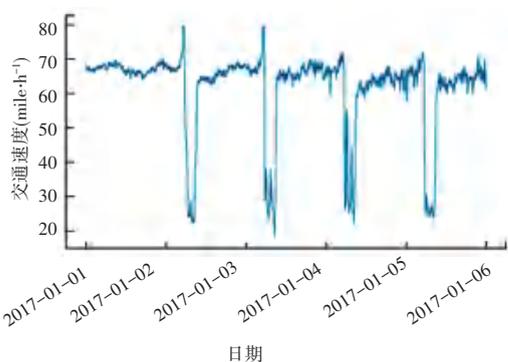
3 实例分析

3.1 模态分解

本文选用的交通流速度数据来源于美国加州湾区高速路片区上某两个传感器实时采集的数据,数据收集时间段为2017年1月1日至1月5日,采样间隔为5 min(两组数据在后文简称序列1、序列2)。序列1最大速度为70.4 mile/h,最小速度为22 mile/h,共1440条数据;序列2最大速度为79.6 mile/h,最小速度为18.1 mile/h,共1440条数据。序列1、序列2的原始交通流速度数据如图4所示。



(a) 序列1



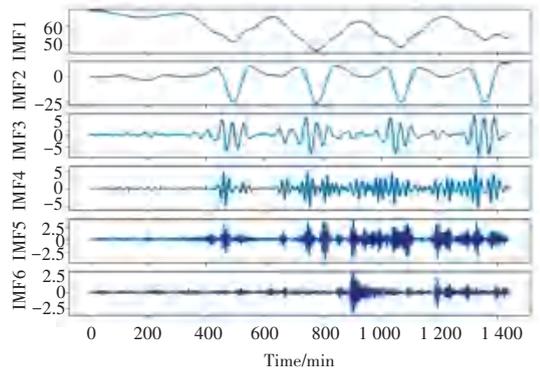
(b) 序列2

图4 各序列原始交通数据

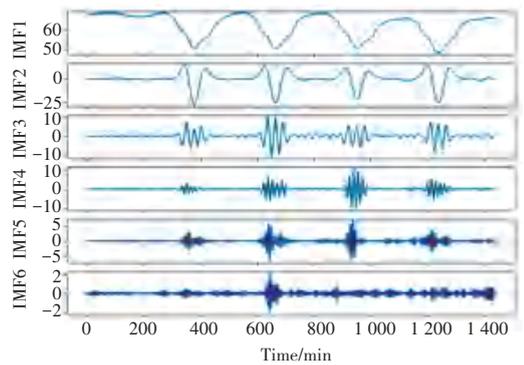
Fig. 4 Original traffic data of each sequence

在2个序列中各选取60%作为训练集,20%作为验证集,20%作为测试集。首先使用VMD对其进行分解,多次实验表明,序列1、序列2均在 $K=6$ 时

有最佳预测效果。两个序列模态分解结果分别如图5所示。从图5可以看出,IMF1、IMF2是趋势分量,反映了交通流速度的长期变化趋势,IMF3、IMF4为波动分量,反映了交通流速度数据的周期性趋势,IMF5、IMF6为随机分量,反映了交通流速度数据的随机影响。



(a) 序列1



(b) 序列2

图5 各序列VMD分量

Fig. 5 VMD components of each sequence

3.2 模型训练

为验证本文模型的有效性,选取LSTM、EMD-LSTM、CEEMDAN-LSTM与VMD-LSTM这4种模型进行比对。这4个模型的训练次数、隐藏层节点数、学习率分别都设定为100、128、0.001。本文模型使用WOA对每个分量的LSTM模型的训练次数、隐藏层节点数与学习率进行寻优,其中前两个参数的寻优范围为10~200,学习率寻优范围为0.001~0.01。通过WOA算法训练得到的各序列分量预测参数见表1。

参数优化后,将测试集数据输入到参数优化后的模型中进行预测,然后将各个分量预测结果进行叠加,得到最终的交通流预测值。

3.3 实验结果与分析

本文模型与LSTM、EMD-LSTM、EEMD-LSTM及VMD-LSTM模型的预测结果见表2。

表 1 各序列分量预测参数

Table 1 Prediction parameters of each sequence component

序列 1				序列 2			
分量	隐藏层节点数	训练次数	学习率	分量	隐藏层节点数	训练次数	学习率
IMF1	91	174	0.001 9	IMF1	71	200	0.003 8
IMF2	188	141	0.003 7	IMF2	78	137	0.004 4
IMF3	134	91	0.002 8	IMF3	190	168	0.008 0
IMF4	116	192	0.001 4	IMF4	18	182	0.006 7
IMF5	46	98	0.004 9	IMF5	168	163	0.007 3
IMF6	161	132	0.003 9	IMF6	52	146	0.006 2

表 2 模型预测结果

Table 2 Model prediction results

序列 1											
5 min				15 min				30 min			
MAE	RMSE	MAPE/%	R ²	MAE	RMSE	MAPE/%	R ²	MAE	RMSE	MAPE/%	R ²
1.825	3.736	3.485	0.925	2.989	5.761	5.980	0.823	4.258	7.648	9.089	0.688
1.751	2.815	3.109	0.957	2.472	3.652	4.565	0.927	2.805	4.012	5.129	0.909
0.902	1.795	1.423	0.983	1.466	2.493	2.350	0.966	2.187	3.499	3.610	0.932
0.641	0.797	1.240	0.996	0.904	1.162	1.755	0.992	1.519	1.938	3.051	0.978
0.362	0.512	0.761	0.999	0.629	0.852	1.205	0.996	1.105	1.431	2.132	0.988
序列 2											
5 min				15 min				30 min			
MAE	RMSE	MAPE/%	R ²	MAE	RMSE	MAPE/%	R ²	MAE	RMSE	MAPE/%	R ²
1.641	2.330	3.579	0.968	3.281	5.493	7.935	0.824	4.861	9.425	12.304	0.483
1.078	1.578	2.099	0.986	1.719	2.437	3.247	0.966	2.635	3.757	5.031	0.919
0.782	1.024	1.578	0.994	1.337	1.823	2.622	0.981	2.006	2.884	4.093	0.952
0.655	0.787	1.290	0.996	0.798	1.029	1.679	0.994	1.216	1.741	2.726	0.981
0.473	0.578	0.882	0.998	0.717	0.902	1.366	0.995	1.060	1.439	2.269	0.987

由表 2 可知,对于 5 min 速度预测任务,VMD-WOA-LSTM 模型与 LSTM 模型相比,MAE 降低了约 80.16%,MAPE 降低了约 78.16%,准确率提升了约 8.0%;与 EMD-LSTM 模型相比,MAE 降低了约 79.33%,MAPE 降低了 75.52%,准确率提升了约 4.4%;与 EEMD-LSTM 模型相比,VMD-WOA-LSTM 模型的 RMSE 降低了约 71.48%,MAPE 降低了约 46.52%,准确率提升了约 1.6%;与 VMD-LSTM 模型相比,VMD-WOA-LSTM 模型的 RMSE 降低了约 35.76%,MAPE 降低了约 38.63%,准确率提升了约 0.3%。对于 30 min 速度预测任务,VMD-WOA-LSTM 模型的 RMSE 比 LSTM 模型降低了约 81.29%,MAPE 降低了约 76.54%,准确率提升了约 43.6%;VMD-WOA-LSTM 模型的 RMSE 比 EMD-

LSTM 模型降低了约 58.43%,MAPE 降低了约 58.43%,准确率提升了约 8.7%;与 EEMD-LSTM 模型相比,VMD-WOA-LSTM 模型的 MAE 降低了约 49.47%,MAPE 降低了约 40.94%,准确率提升了约 6.0%;与 VMD-LSTM 模型相比,VMD-WOA-LSTM 模型的 MAE 降低了约 27.25%,MAPE 降低了约 30.12%,准确率提升了约 1.0%。这说明与 LSTM、EMD-LSTM、EEMD-LSTM 及 VMD-LSTM 等模型相比,VMD-WOA-LSTM 模型有着更低的预测误差和更高的预测精度,可以应用于交通流预测。

将 VMD-WOA-LSTM 模型在测试集上的预测可视化结果如图 6 所示。

从图 6 中可以看出本文模型的拟合效果很好,证明可以将本文模型应用到实际交通流预测中。

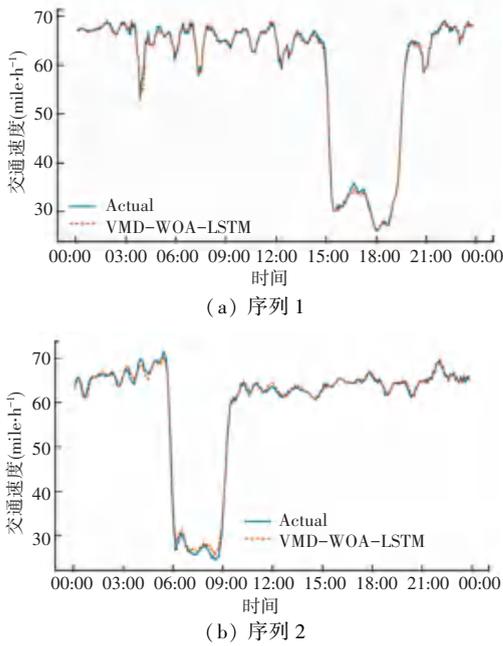


图6 各序列预测可视化结果

Fig. 6 Visualization results of each sequence prediction

4 结束语

本文提出了一种基于VMD与经过鲸鱼优化算法优化参数后的LSTM模型相结合的短期交通流预测方法,通过对原始交通流数据进行分解以及使用WOA算法对LSTM模型参数进行寻优来提高模型的预测精度。本文主要结论如下:

(1)使用VMD对原始数据进行分解,提升了LSTM模型的预测精度;

(2)采用WOA优化LSTM的隐藏层节点数、训练次数与学习率等超参数,能够更好提升LSTM模型的性能;

(3)通过对交通流实测数据预测的结果表明,本文模型预测精度明显高于LSTM、EMD-LSTM、EEMD-LSTM与VMD-LSTM等模型,验证了该模型应用于交通流预测的优越性和可行性。

VMD-WOA-LSTM模型有非常好的预测效果,但其仅考虑到了LSTM模型的超参数优化,忽略了VMD分解中的参数优化情况,所以在之后的研究中可以考虑优化VMD的相关参数。此次研究收集的数据仅是高速公路上的交通流数据,没有对城市道路上的交通流数据进行研究,而城市道路上的交通流更为复杂,未来可以考虑收集城市道路上的交通流数据并对其进行预测。

参考文献

[1] ZHAO Z, CHEN W, WU X, et al. LSTM network: A deep learning approach for short-term traffic forecast [J]. IET

Intelligent Transport Systems, 2017, 11(2): 68-75.

[2] 聂佩林, 余志, 何兆成. 基于约束卡尔曼滤波的短时交通流量组合预测模型[J]. 交通运输工程学报, 2008, 8(5): 86-90.

[3] DUAN H, XIAO X. A Multimode dynamic short-term traffic flow grey prediction model of high-dimension tensors [J]. Complexity, 2019, 2019: 9162163. DOI:1.1155/2019/9162163

[4] DONG M K, CHEN C, HUANG M H, et al. Joint network traffic forecast with ARIMA models and chaotic models based on wavelet analysis[J]. Applied Mechanics and Materials, 2011, 55: 743-746.

[5] KUMAR S V, VANAJAKSHI L. Short-term traffic flow prediction using seasonal ARIMA model with limited input data [J]. European Transport Research Review, 2015, 7(3): 1-9.

[6] KUMAR S V. Traffic flow prediction using kalman filtering technique[J]. Procedia Engineering, 2017, 187: 582-587.

[7] YANG S, WU J, DU Y, et al. Ensemble learning for short-term traffic prediction based on gradient boosting machine[J]. Journal of Sensors, 2017, 2017: 7074143.

[8] 蒋晓峰, 许论辉, 朱悦. 基于SVM短时交通流量预测[J]. 广西师范大学学报(自然科学版), 2012, 30(4): 13-17.

[9] ZHENG W, LEE D H, SHI Q. Short-term freeway traffic flow prediction: Bayesian combined neural network approach [J]. Journal of Transportation Engineering, 2006, 132(2): 114-121.

[10] PENG Y, XIANG W. Short-term traffic volume prediction using GA-BP based on wavelet denoising and phase space reconstruction [J]. Physica A: Statistical Mechanics and Its Applications, 2020, 549: 123913.

[11] CAI L, LEI M, ZHANG S, et al. A noise-immune LSTM network for short-term traffic flow forecasting [J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2020, 30(2): 1-11.

[12] CHEN X, LU J, ZHAO J, et al. Traffic flow prediction at varied time scales via ensemble empirical mode decomposition and artificial neural network [J]. Sustainability, 2020, 12(9): 3678.

[13] HAMAD K, SHOURIJEH M T, LEE E, et al. Near-term travel speed prediction utilizing Hilbert-Huang transform [J]. Computer-Aided Civil and Infrastructure Engineering, 2009, 24(8): 551-576.

[14] JIANG X, ZHANG L, CHEN X M. Short-term forecasting of high-speed rail demand: A hybrid approach combining ensemble empirical mode decomposition and gray support vector machine with real-world applications in China [J]. Transportation Research Part C: Emerging Technologies, 2014, 44: 110-127.

[15] 朱永强, 王小凡. 基于互补型集成经验模态分解和遗传最小二乘支持向量机的交通流量预测模型[J]. 科学技术与工程, 2020, 20(17): 7088-7092.

[16] 吴玲玲, 尹莉莉, 任其亮. 一种EMD和DE-BPNN组合优化的短时交通流预测方法[J]. 重庆理工大学学报(自然科学), 2021, 35(12): 155-163.

[17] 沈富鑫, 郇其春, 张伟健, 等. 基于CEEMD-GRU组合模型的快速路短时交通流预测[J]. 河北科技大学学报, 2021, 42(5): 454-461.

[18] 郇其春, 张伟健, 沈富鑫, 等. 基于变分模态分解和LSTM的短时交通流预测[J]. 重庆理工大学学报(自然科学版), 2023, 37(5): 169-177.

[19] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.

[20] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.

[21] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.