

改进WOA优化LSTM神经网络的短时交通流预测*

曾蓉, 黄德启[†], 魏霞, 赵恒辉
(新疆大学 电气工程学院, 新疆 乌鲁木齐 830017)

摘要: 针对城市交通中交叉路口短时交通流预测问题, 本文提出了一种IWOA-LSTM模型, 该模型是在传统的WOA算法基础上, 对初始种群进行tent混沌初始化, 同时将线性递减的收敛因子改进为非线性的方式, 再将改进后的IWOA算法与LSTM神经网络模型结合, 所得到的IWOA-LSTM模型提高了对交通流预测的精度. 本文选取了8个基准测试函数对IWOA算法进行性能测试和仿真实验, 验证了改进的IWOA算法在收敛速度以及精度上的优势. 最后将IWOA-LSTM模型的预测结果和PSO-LSTM模型的预测结果分别与实际交通流量进行对比, 得出IWOA-LSTM算法误差更小的结论.

关键词: 交通流预测; IWOA-LSTM; tent混沌; 收敛因子

DOI: 10.13568/j.cnki.651094.651316.2021.03.05.0001

中图分类号: U491.14; TP18 **文献标识码:** A **文章编号:** 2096-7675(2022)02-0242-07

引文格式: 曾蓉, 黄德启, 魏霞, 赵恒辉. 改进WOA优化LSTM神经网络的短时交通流预测[J]. 新疆大学学报(自然科学版)(中英文), 2022, 39(2): 242-248.

英文引文格式: ZENG Rong, HUANG Deqi, WEI Xia, ZHAO Henghui. Short-term traffic flow forecast based on modified WOA optimized LSTM neural network[J]. Journal of Xinjiang University(Natural Science Edition in Chinese and English), 2022, 39(2): 242-248.

Short-term Traffic Flow Forecast Based on Modified WOA Optimized LSTM Neural Network

ZENG Rong, HUANG Deqi, WEI Xia, ZHAO Henghui

(School of Electrical Engineering, Xinjiang University, Urumqi Xinjiang 830017, China)

Abstract: Aiming at the problem of short-term traffic flow prediction at intersections in urban traffic, this paper proposes an IWOA-LSTM model, which is based on the traditional WOA algorithm and initializes the initial population with tent chaos. At the same time, the linearly decreasing convergence factor is improved into a non-linear way, and the improved IWOA algorithm is combined with the LSTM neural network model. The resulting IWOA-LSTM model improves the accuracy of traffic flow prediction. This paper selects 8 benchmark test functions to perform performance testing and simulation experiments on the IWOA algorithm, which verifies the advantages of the improved IWOA algorithm in convergence speed and accuracy. The prediction results of the IWOA-LSTM model and the PSO-LSTM model are compared with the actual traffic flow respectively, and the conclusion that the IWOA-LSTM algorithm has a smaller error is obtained.

Key words: traffic flow prediction; IWOA-LSTM; tent chaos; convergence factor

0 引言

随着社会的不断发展, 私家车的增多, 交通量的急剧增加使得城市道路拥堵问题日益严重, 实时准确的交通预测至关重要. 受道路环境和人为因素的影响, 城市道路交通系统是一个复杂系统, 人们的出行方式、上下班高峰期、天气状况、节假日等多种因素都以非线性的关系相互作用影响着交通流量^[1-2]. 因此交通流的预测一直以来都是交通领域的研究热点和难点.

* 收稿日期: 2021-03-05

基金项目: 国家自然科学基金(51468062).

作者简介: 曾蓉(1994-), 女, 硕士生, 从事交通流预测与智能交通系统的研究.

[†] 通讯作者: 黄德启(1972-), 男, 博士, 副教授, 从事智能交通系统的研究, E-mail: dqhuang88@qq.com.

近年来,深度学习模型因其对复杂非线性关系的建模能力,在交通状态预测等诸多研究领域受到学者们的关注.张阳等^[3]针对短时交通流的特点,构建了IWPA-LSTM模型,利用改进的小波包对时间序列进行精细分解,将重构的子序列输入模型进行预测,在小样本的情况下具有更高的实用性;王祥雪等^[4]构建了LSTM-RNN的城市快速路短时交通流预测模型,该算法针对交通流的时空关联性预测精度高,兼顾了实时性和实用性;罗向龙等^[5]分析了交通流序列的内部规律特性和时空相关性,构建了KNN-LSTM预测模型,使用K最近邻(KNN)算法筛选出检测站点并以该站点交通流序列构造数据集,最后输入LSTM模型进行预测,取得了较好的效果;满春涛等^[6]考虑上下游的时空相关性,利用LSTM模型分析了不同输入配置对预测精度的影响,有效提高了短时交通流的预测精度.本文在针对交通流的时空特性基础上,通过对高峰期的交通流进行分析,选择在时空关联性有较高优势的LSTM神经网络作为预测模型,提出了一种基于改进鲸鱼算法的长短时城市交叉路口交通流量预测模型.

1 模型建立

1.1 LSTM神经网络

深度学习是Hinton等提出的一种机器学习.RNN(时间递归神经网络)及LSTM因其特殊的记忆能力在处理时间序列问题上很受欢迎^[7].相比RNN,LSTM在较长的序列中有更好的表现,主要是解决长序列训练过程中的梯度消失和梯度爆炸等问题.如图1所示,LSTM引入了细胞状态来记忆信息,并增加了3种门(输入门,遗忘门,输出门)结构来实现信息的保护和控制^[8].其主要公式表示如下:

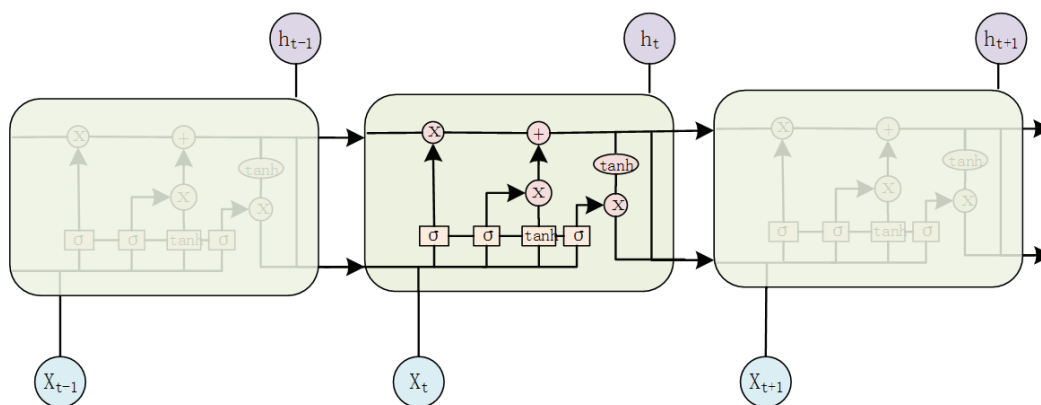


图 1 LSTM神经网络

输入门:

$$i_t = \sigma(W_i \cdot [h_{t-1}, X_t] + b_i) \tag{1}$$

遗忘门:

$$f_t = \sigma(W_f \cdot [h_{t-1}, X_t] + b_f) \tag{2}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, X_t] + b_c) \tag{3}$$

输出门:

$$O_t = \sigma(W_o \cdot [h_{t-1}, X_t] + b_o) \tag{4}$$

两种记忆,长记忆:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{5}$$

短记忆:

$$h_t = O_t * \tanh(C_t) \tag{6}$$

式中: X, h 分别为LSTM的输入向量和输出向量; f 表示遗忘门、 i 表示输入门、 O 表示输出门; C 是LSTM神经网络的单元状态; σ, \tanh 分别为sigmoid, tanh的激活函数; W 和 b 分别表示权重和偏差矩阵.

1.2 WOA算法

鲸鱼优化算法(WOA)是由Mirjalili等提出的一种新算法. 世界上最大的须鲸之一是座头鲸, 座头鲸最有趣的就是他们的气泡网觅食方法. 其基本原理分为三个阶段: 包围猎物、泡网攻击、搜寻猎物^[9-10]. 算法的基本公式如下:

(1) 包围猎物

$$\vec{D} = \left| \vec{C} \cdot \vec{X}^*(t) - \vec{X}(t) \right| \quad (7)$$

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D} \quad (8)$$

$$\vec{A} = 2\vec{a} \cdot rand - \vec{a} \quad (9)$$

$$\vec{C} = 2 \cdot rand \quad (10)$$

$$a = (2 - 2t/T_{\max}) \quad (11)$$

式中: $\vec{X}^*(t)$, $\vec{X}(t)$ 分别表示猎物位置和当前鲸鱼的位置; $\vec{A} \cdot \vec{D}$, t 分别为包围步长和当前迭代次数; T_{\max} 表示最大迭代次数; $rand$ 表示[0,1]之间的随机数, \vec{a} 表示收敛因子, 随着迭代次数的增加从2线性递减到0.

(2) 泡网攻击

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot (\cos 2\pi l) + \vec{X}^*(t) \quad (12)$$

式中: \vec{D}' 表示第*i*只鲸鱼和当前最优位置之间的距离; b 是用来限定对数螺旋形式的常量系数; l 表示[-1,1]之间的随机数.

(3) 搜寻猎物

$$\vec{D} = \left| \vec{C} \cdot \vec{X}_{rand}(t) - \vec{X}(t) \right| \quad (13)$$

$$\vec{X}(t+1) = \vec{X}_{rand}(t) - \vec{A} \cdot \vec{D} \quad (14)$$

式中: $\vec{X}_{rand}(t)$ 表示随机选取鲸鱼的位置向量.

1.3 IWOA算法

1.3.1 IWOA算法的改进

由于传统的WOA算法易陷入局部最优、寻优精度低且收敛速度慢的缺陷, 因此本文提出了改进的WOA算法, 利用混沌对种群进行初始化可保证初始种群的多样性^[11]. tent混沌映射结构简单, 用其对当前最优个体进行变异生成新的个体, 能较快地搜索到全局最优解. 其表达式为:

$$X_{n+1} = \begin{cases} X_n/q, & 0 < X_n \leq q \\ (1-X_n)/(1-q), & q < X_n < 1 \end{cases} \quad (15)$$

式中: 参数 $X_n \in (0, 1)$, $q \in (0, 1)$.

在实际的鲸鱼群体中, 前期搜索空间大, 需要快速搜索; 后期需要精细搜索, 距离猎物较近时, 步长过大容易过早陷入局部最优. 标准的鲸鱼算法收敛因子由2线性递减到0, 但线性递减的收敛因子不能很好地区分全局搜索和局部搜索. 所以本文对传统鲸鱼算法中收敛因子*a*的递减形式做了改进, 将线性递减方式改为非线性递减方式, 改进公式如下:

$$a = 2 \cdot [1 - \cos(t/T_{\max})^2] \cdot (\pi/2) \quad (16)$$

$$a2 = (-1) \cdot [1 - \cos(t/T_{\max})^2] \cdot (\pi/2) \quad (17)$$

1.3.2 IWOA算法性能测试及仿真实验

选取8个基准测试函数对改进的鲸鱼优化算法(IWOA)性能进行仿真测试, 基准测试函数如表1所示.

为了更好地分析本文提出的IWOA算法的收敛性, 将IWOA算法与WOA、PSO、GWO三种算法的收敛曲线进行仿真对比, 仿真结果如图2所示.

表 1 基准测试函数

函数	维数	搜索区间	最优值
$F_1(x) = \sum_{i=1}^n X_i^2$	1 000	[-100,100]	0
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n X_i $	1 000	[-10,10]	0
$F_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	1 000	[-100,100]	0
$F_4(x) = \sum_{i=1}^{n-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	1 000	[-30,30]	0
$F_5(x) = \sum_{i=1}^n x_i + 0.5 ^2$	1 000	[-100,100]	0
$F_6(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$	1 000	[-32,32]	0
$F_7(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos \left(\frac{x_i}{\sqrt{i}} \right) + 1$	1 000	[-600,600]	0
$F_8(x) = \frac{\pi}{\Omega} \left(10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + \dots + \sum_{i=1}^{n-1} (y_n - 1)^2 + \sum_{i=1}^n u(x_i, 10, 100, 4) \right)$	1 000	[-50,50]	0

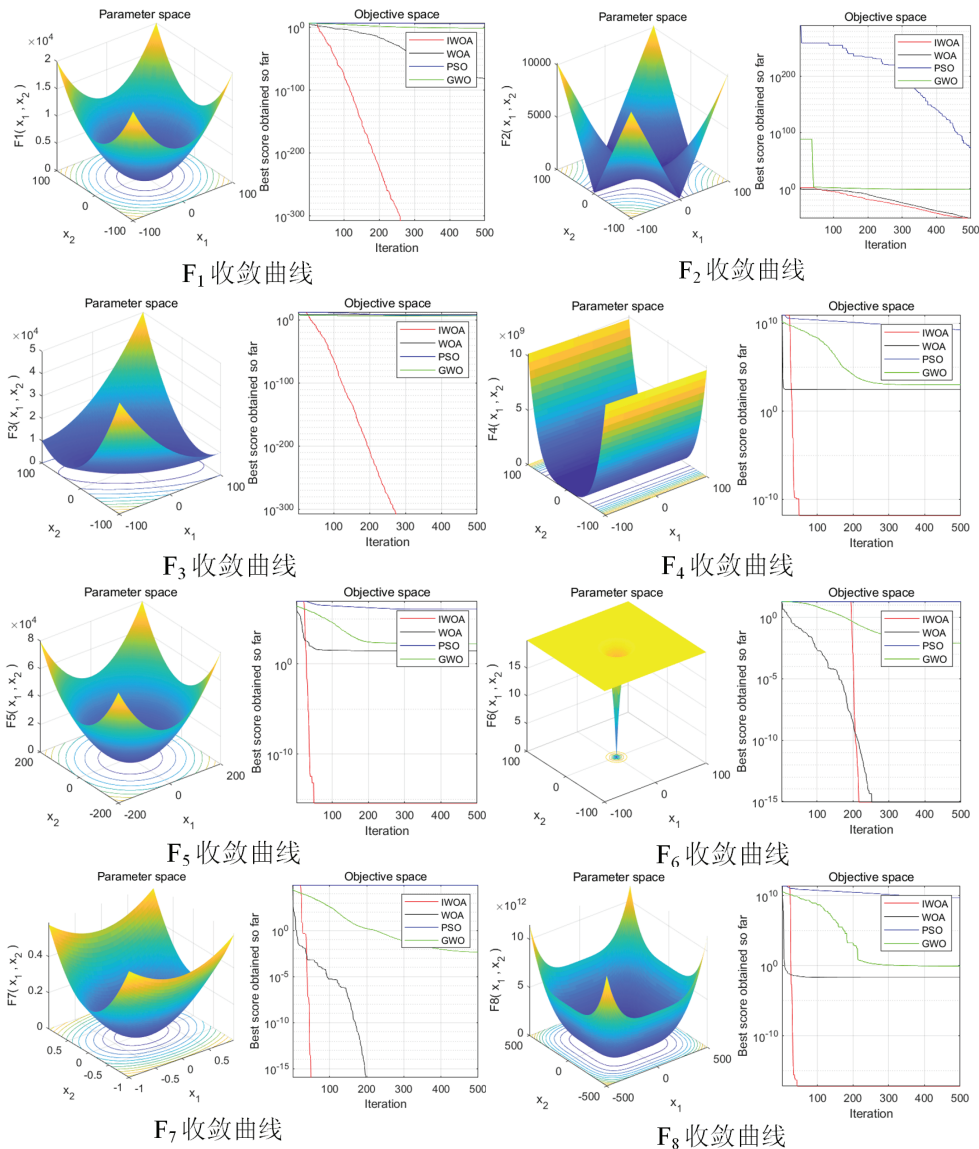


图 2 测试函数图和收敛曲线图

图2为函数的三维空间图和收敛曲线图,根据收敛曲线可以看出,在收敛速度上,本文改进的鲸鱼优化算法较PSO、WOA、GWO更快,且收敛精度也较其他三种算法更高.改进的WOA在测试函数上均取得了较好的寻优效果,故本文利用改进的鲸鱼算法模型对LSTM神经网络进行优化预测高峰期交通流量.

1.4 IWOA-LSTM模型

交通流作为一种时间序列,其受到多方面因素的影响,具有复杂的不稳定性、非线性等特点^[12].LSTM神经网络在处理时间序列分析的问题中具有明显的优势,为了准确地预测交通流,本文以LSTM模型为基础,构建针对交通流数据的预测模型.LSTM模型中某些超参数的值控制着网络结构,为了使模型网络结构与交通流特征相匹配,将传统的WOA进行了改进,构建了IWOA-LSTM预测模型并在MATLAB开发环境下搭建模型和训练.IWOA-LSTM预测模型的流程如图3所示.

算法的基本步骤如下:

步骤1:实验数据分为训练集和测试集.

步骤2:把LSTM模型中时间窗口大小、批处理大小、神经网络隐藏层单元数目作为优化对象,初始化IWOA算法.

步骤3:计算每个个体的适应度值.以各鲸鱼对应参数构建LSTM神经网络模型,通过训练数据进行训练,测试数据进行预测,将预测结果的平均绝对百分比误差作为各鲸鱼的适应度值.

步骤4:根据鲸鱼的适应度值确定全局最优位置和局部最优位置.

步骤5:根据WOA算法式(9)、(10)更新A和C,根据IWOA算法式(16)、(17)计算a的值.

步骤6:判断p和|A|的大小,若 $p < 0.5$,根据WOA算法的式(12)对鲸鱼的位置进行更新;若 $|A| < 1$,根据式(8)更新鲸鱼位置,否则根据式(14)更新鲸鱼位置.

步骤7:判断终止条件.若满足终止条件,则输出最优解;否则,返回步骤3.

步骤8:用最优参数构建LSTM神经网络模型并进行预测.

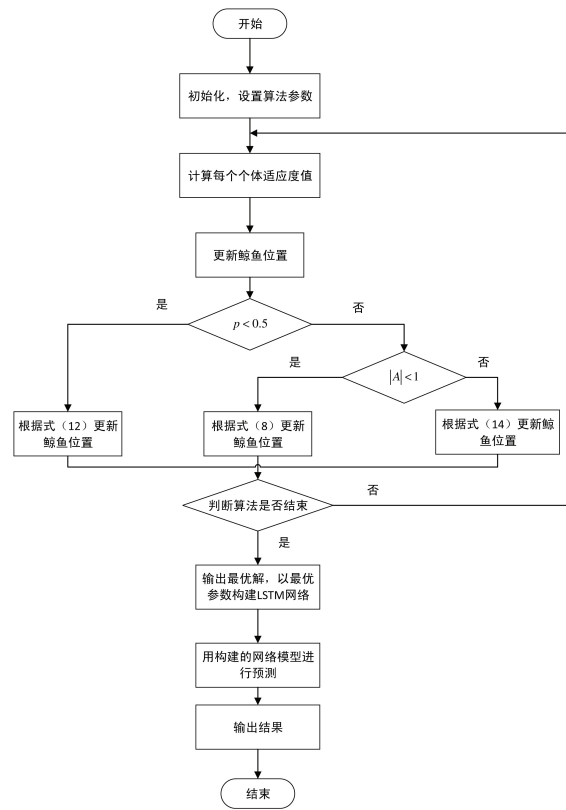


图 3 IWOA-LSTM网络流程图

2 实验及结论分析

2.1 实验数据

实验选取美国加州PeMs数据库开放的交通流数据,交叉路口如图4所示.本实验选取2020年3月1日到3月31日一个月的车流量数据,该道路有三条车道,交通流数据包括每条车道一个月的交通流量,车流量的时间间隔为5分钟,因此每天的交通流量序列一共有288个样本,一个月共有8 928个样本.通过分析交通流的特性,每天中午和夜间车流量较小,而早晚上下班高峰期的车流量较大,所以提取每天早晚高峰期各两个小时(早上7:00-9:00,下午17:30-19:30)的车流量,将前80%的交通流数据作为训练集,后20%作为测试集进行流量预测.

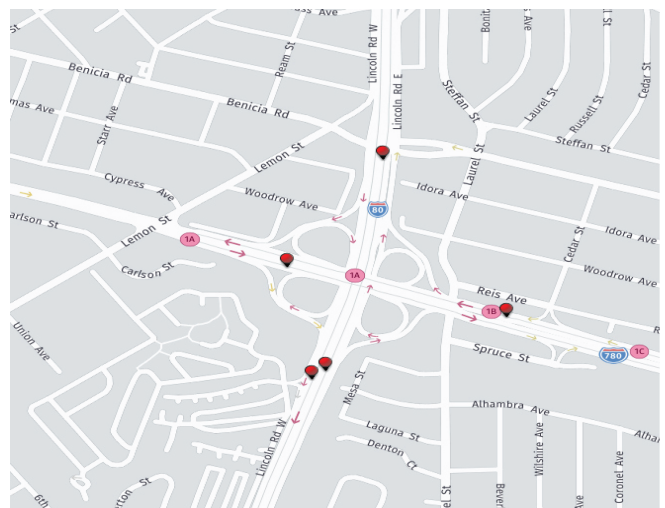


图 4 城市交叉路口图

2.2 基于LSTM的神经网络模型的车流量预测

2.2.1 模型建立及参数选择

本文将PSO-LSTM作为交通流预测的对比模型,各模型参数设定为:LSTM模型的最大训练周期数设为1,分块尺寸为50,初始学习速率为0.001;同时设置PSO模型和IWOA模型的种群数量均为30,迭代次数为500.为了使模型的训练效果更好,需要使用改进的WOA和PSO来选择合适的时间步长、网络层数、各层节点数等,利用优化后的LSTM神经网络去预测交通流量^[13].

2.2.2 模型评估

采用均方根误差(Root Mean-Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)分别作为交通流预测的评价指标^[14].公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |X(i) - \bar{X}(i)| \tag{18}$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{X(i) - \bar{X}(i)}{X(i)} \right| \times 100\% \tag{19}$$

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (x(j) - \bar{X}(i))^2} \tag{20}$$

式中: $X(i)$ 为实际交通流量; $\bar{X}(i)$ 为预测交通流量的结果; n 为数据样本容量.

2.2.3 实验结果

通过对数据的分析,由于城市内部车流量有较强的时间性,在每天高峰期时间段的车流量比较多,而在其他时间段的车流量较少,因此,该模型提取了每天早晚高峰期各两个小时的交通流进行预测.仿真结果如图5所示.图5中绿色实线为实际车流量,红色虚线为PSO-LSTM预测车流量,蓝色双虚线为本文方法预测的车流量.两种模型的误差对比如图6所示.可以看出IWOA-LSTM的预测曲线比PSO-LSTM的曲线对实际交通流量的拟合度更高,IWOA-LSTM的误差波动在一定范围内也相对较小,相较于实际交通流本文算法更接近真实值.

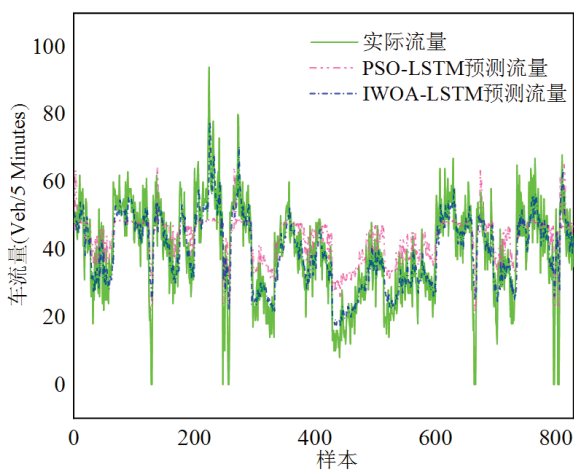


图 5 两种模型预测结果与实际交通流量对比图

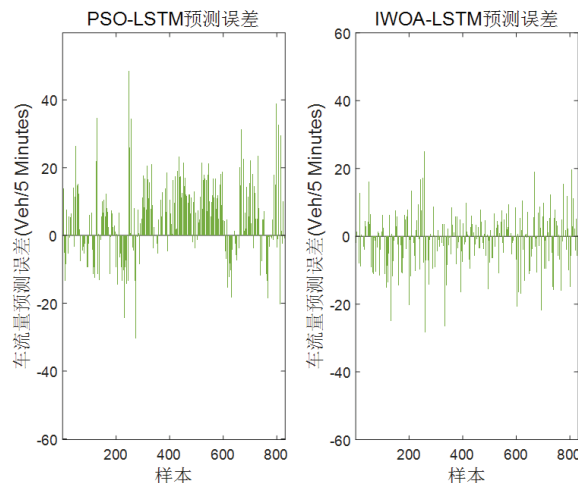


图 6 两种模型误差对比图

表 2 模型预测精度对比

预测模型	RMSE	MAE	MAPE
PSO-LSTM	12.206 7	9.726 2	0.331 0
IWOA-LSTM	8.528 4	6.344 5	0.172 98

模型的预测精度评价指标如表2所示. IWOA-LSTM预测模型RMSE、MAE、MAPE分别为8.528 4、6.344 5、

0.172 98, PSO-LSTM预测模型 $RMSE$ 、 MAE 、 $MAPE$ 分别为12.206 7、9.726 2、0.331 0, 基于IWOA-LSTM的交通流预测误差小于PSO-LSTM模型, 本文预测模型的平均绝对误差百分比相比PSO-LSTM模型降低了15.8%。由此可见, 本文所采用的预测模型误差更小, 预测精度更接近于真实的交通流值。

3 结束语

本文基于混沌算法对WOA模型的初始种群进行优化, 并对鲸鱼算法中的收敛因子进行了改进, 针对交通流量预测准确度不高的问题, 提出了基于IWOA-LSTM模型的城市交叉路口车流量预测模型, 该模型能够快速准确的学习传统时间序列预测算法所不能发现的路口时空相关性, 且拥有较长的记忆功能, 可以对城市交叉路口的车流量进行有效预测。通过与其他模型对比, 发现该模型对城市交叉路口的车流量预测相较于PSO-LSTM而言有较好的预测效果, 预测结果与实际交通流量拟合度更好, 验证了该方法对于城市交叉路口车流量预测的有效性。本文只是针对单个交叉路口的交通流进行建模预测, 具有一定的局限性。在未来的研究中, 可以比较分析城市交通流的时空特性, 结合各个关联路口的相关特性进行区域交通流的预测, 从而实现整个区域交通流的预测。

参考文献:

- [1] LYU Y S, DUAN Y J, KANG W W, et al. Traffic flow prediction with big data: a deep learning approach[J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(2): 865-873.
- [2] 杨文忠, 张志豪, 柴亚闯, 等. 基于GBRT模型的交通事故预测[J]. 新疆大学学报(自然科学版)(中英文), 2020, 37(1): 36-43.
- [3] 张阳, 杨书敏, 辛东嵘, 等. 改进小波包与长短时记忆组合模型的短时交通流预测[J]. 交通运输系统工程与信息, 2020, 20(2): 204-210.
- [4] 王祥雪, 许伦辉. 基于深度学习的短时交通流预测研究[J]. 交通运输系统工程与信息, 2018, 18(1): 81-88.
- [5] 罗向龙, 李丹阳, 杨彧, 等. 基于KNN-LSTM的短时交通流预测[J]. 北京工业大学学报, 2018, 44(12): 1521-1527.
- [6] 满春涛, 康丹青. 考虑上下游的LSTM短时交通流量预测[J]. 哈尔滨理工大学学报, 2019, 24(5): 101-107.
- [7] 尹邵龙, 赵亚楠. 深度学习在城市交通流预测中的实践研究[J]. 现代电子技术, 2015, 38(15): 158-162.
- [8] 宋刚, 张云峰, 包芳勋, 等. 基于粒子群优化LSTM的股票预测模型[J]. 北京航空航天大学学报, 2019, 45(12): 2533-2542.
- [9] 张永, 陈锋. 一种改进的鲸鱼优化算法[J]. 计算机工程, 2018, 44(3): 208-219.
- [10] 何庆, 魏康园, 徐钦帅. 求解函数优化问题的改进鲸鱼优化算法[J]. 微电子学与计算机, 2019, 36(4): 72-77.
- [11] 宋健, 王聪, 张宏立. 基于云模型的混合粒子群算法的统一混沌系统时变参数辨识[J]. 新疆大学学报(自然科学版)(中英文), 2020, 37(3): 407-414.
- [12] JIN F, ZHAO B C. Short-term traffic flow prediction based on road network topology[J]. Journal of Beijing Institute of Technology, 2019, 28(3): 383-388.
- [13] 李高盛, 彭玲, 李祥, 等. 基于LSTM的城市公交车站短时客流量预测研究[J]. 公路交通科技, 2019, 36(2): 128-135.
- [14] LI R M, HUANG Y F, WANG J. Long-term traffic volume prediction based on K-means gaussian interval type-2 fuzzy sets[J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(6): 1344-1351.

责任编辑: 赵新科