

混合策略改进 WOA-BiLSTM 的快速路 出口匝道车速预测

何庆龄, 裴玉龙, 侯琳, 刘静, 潘胜

(东北林业大学 土木与交通学院, 哈尔滨 150040)

摘要: 针对现有元启发式算法在优化神经网络预测车速过程中收敛速度慢和误差大的问题, 提出了基于改进鲸鱼优化算法优化双向长短期记忆网络(IWOA-BiLSTM)的快速路出口匝道车速预测方法。首先, 采用 Circle 混沌映射取代鲸鱼优化算法中随机产生的初始种群, 增加种群的多样性并提高质量。其次, 使用精英反向学习策略, 提高种群个体择优位置的多样性, 降低算法陷入局部最优和过早收敛的风险。最后, 采用余弦函数改变自适应收敛因子和引入惯性权重的策略, 在保留鲸鱼优化算法优点的前提下, 平衡算法的全局搜索和局部开发能力。仿真结果表明: 与现有元启发式算法和车速预测模型相比, IWOA 算法在寻优求解精度、收敛速度和预测精度等方面均有明显提升。

关键词: 交通运输规划与管理; 出口匝道; 车速预测; 鲸鱼优化算法; 混合策略; 双向长短时神经网络

中图分类号: U491 文献标志码: A 文章编号: 1671-5497(2025)06-2038-12

DOI: 10.13229/j.cnki.jdxbgxb.20230940

Hybrid strategy improves WOA-BiLSTM speed prediction of expressway exit ramp

HE Qing-ling, PEI Yu-long, HOU Lin, LIU Jing, PAN Sheng

(College of Civil Engineering and Transportation, Northeast Forestry University, Harbin 150040, China)

Abstract: Aiming at the problem that the existing meta-heuristic algorithm has slow convergence speed and large error in the process of optimizing the neural network to predict vehicle speed, a vehicle speed prediction method for expressway off-ramp based on IWOA-BiLSTM was proposed. Firstly, the Circle chaotic map was used to replace the randomly generated initial population in the whale optimization algorithm to increase the diversity and quality of the population. Secondly, the elite opposition-based learning strategy was used to improve the diversity of the individual's preferred position and reduce the risk of the algorithm falling into local optimum and premature convergence. Finally, the cosine function was used to change the adaptive convergence factor and introduce the inertia weight strategy. On the premise of retaining the advantages of the whale optimization algorithm, the global search and local development

收稿日期: 2023-09-05.

基金项目: 国家重点研发计划项目(2018YFB1600902); 国家自然科学基金项目(71771047).

作者简介: 何庆龄(1994-), 男, 讲师, 博士. 研究方向: 智能优化算法, 交通规划. E-mail: qinglinghe@yeah.net

通信作者: 裴玉龙(1961-), 男, 教授, 博士. 研究方向: 交通规划. E-mail: peiyulong@nefu.edu.cn

capabilities of the algorithm were balanced. The simulation results show that, compared with the existing meta-heuristic algorithm and vehicle speed prediction model, the IWOA algorithm has significantly improved in terms of optimization accuracy, convergence rate and prediction accuracy.

Key words: transportation planning and management; exit ramp; speed prediction; whale optimization algorithm(WOA); hybrid strategy; bidirectional long short-term memory(BiLSTM)

0 引言

快速路出口匝道作为连接主干路的关键枢纽,是车辆合流、分流和交织运行的汇集区域,该区域内车辆加减速、换道和跟驰^[1]等风险行为易导致交通紊乱及事故^[2]。速度控制不当是诱发交通紊乱和事故的主要致因。如何根据出口匝道车速运行规律,确定回归预测特征参数,构建精准的车速预测模型,是实现交通运行状况合理预判,制定交通诱导与控制策略的关键,其对提升道路管控水平,缓解交通拥堵和降低事故发生风险具有重要意义。

现有车速预测方法可分为数理统计参数模型和深度学习模型。数理统计参数模型包括多元线性回归、差分整合移动平均自回归和卡尔曼滤波等^[3]。上述模型只能根据充足的历史数据拟合车速与影响因素间的线性关系,对车速预测的动态复杂性和非线性考虑不足,易导致拟合回归分析中对某些影响因素的不可预测性,降低模型预测精度和泛化能力。

随着信息技术和计算机数据处理能力的提升,深度学习凭借其对于深层次动态复杂数据的表达能力和非线性时空分布规律的有效捕捉,从而实现数据输入与输出间复杂关联的描述,以及更高的模型预测精度和鲁棒性,已被广泛应用于车速预测研究^[4]。神经网络模型^[5]、基于灰度共生矩阵和负指数加权组合的快速路车速预测方法相较于多元线性回归和卡尔曼滤波具有更高的预测精度^[6]。基于空间向量自回归的车速预测模型,通过考虑车速时空分布特征,相较于差分整合移动平均自回归和历史平均等数理统计参数模型具有预测精度较高的优势^[7]。

基于浅层神经网络结构的车速预测方法,虽然其预测精度优于数理统计参数模型,但由于其仅能提取车速数据中基本的非线性关联特征,难以深度挖掘表征交通流数据的时空关联特征和演化规律。循环神经网络和门控循环单元等深度神经网络

更适合车速预测这种非线性动态复杂的系统^[4]。结合卷积神经网络和长短期记忆网络的深度学习模型(Convolutional neural network-long short term memory network, CNN-LSTM)^[8]、基于模糊规则的鲸鱼优化双向长短时神经网络(Bidirectional long short-term memory, LSTM)^[9]、鲸鱼优化Bi-LSTM^[10],以及基于自适应噪声完全集成经验模式分解和LSTM的车速组合预测模型^[11],因其不仅有效解决了数据样本训练过程中因内部梯度受时间步长影响导致梯度爆炸和消失的长程依赖问题^[12],也避免了LSTM过分依靠经验得到超参数,导致模型预测精度和泛化能力不足的问题。

现有研究主要通过数理统计和深度学习方法探析车速的时空分布特征并对其进行预测,忽视了驾驶行为出现频数对车速预测的影响,以及现有元启发式算法存在易陷入局部最优和收敛不足的问题。无免费午餐(No free lunch, NFL)定理表明:没有任何一种元启发式算法拥有解决所有复杂工程应用优化问题的能力^[13]。因此,本文以快速路出口匝道驾驶行为轨迹数据相关性分析为基础,采用Circle混沌映射、精英反向学习、余弦函数改变自适应收敛因子和引入惯性权重等混合策略改进鲸鱼优化算法,构建了基于改进鲸鱼优化算法优化双向长短期记忆网络(Improved whale optimization algorithm for optimizing bidirectional long short term memory networks, IWOA-BiLSTM)的快速路出口匝道车速预测模型,避免了现有模型忽视驾驶行为出现频数对车速预测的影响,以及现有元启发式算法易陷入局部最优和收敛不足,导致LSTM超参数寻优求精精度不足和运行时间较长造成车速预测应用研究的局限性。

1 数据来源统计和影响因素甄选

1.1 数据来源统计

本文数据采用同济大学TJRD TS公开的上海北横通道出口匝道车辆轨迹数据,该数据集

数据类型包括交通运行状态和驾驶行为等数据。本文采用 Python 3.10 中的 pandas 数据库读取 Excel 数据,并通过分组函数 groupby 对驾驶行为出现频数进行分类统计,分别整理得到 5、15 和 30 min 等不同时间粒度对应的数据样本为 1 344、448 和 224 条。

1.2 影响因素甄选

为深入探析驾驶行为、交通流量与平均车速的影响关系,并将其纳入快速路出口匝道车速预测数据集中。本文采用二元定距变量相关分析中的 Pearson 相关系数探讨出口匝道车速影响因素间的相关程度,结果如表 1 所示。

表 1 平均车速影响因素相关程度

Table1 Correlation degree of influencing factors of average speed

	交通流量	平均车速	正常驾驶	强行换道	频繁换道	缓速行驶	近距离跟驰	急加减速
交通流量	交通流量	***	***	***	***	***	***	***
平均车速	0.17	平均车速	***	***	***	***	***	***
正常驾驶	0.52	0.63	正常驾驶	***	***	***	***	***
强行换道	-0.49	-0.56	-0.78	强行换道	***	***	***	***
频繁换道	0.18	0.30	0.22	-0.26	频繁换道	***	***	**
缓速行驶	-0.49	-0.62	-0.84	0.64	-0.41	缓速行驶	***	
近距离跟驰	-0.22	-0.27	-0.32	0.37	-0.13	0.24	近距离跟驰	***
急加减速	-0.092	-0.14	-0.16	0.19	-0.097	0.081	0.13	急加减速

注:**表示显著性水平小于等于 0.01;***表示表示显著性水平小于等于 0.001

由表 1 可知,驾驶行为、交通流量与平均车速均具显著相关性。其中正常驾驶和缓速行驶与平均车速的相关系数大于 0.6,属于强相关;强行换道与平均车速的相关系数大于 0.4,属于中度相关;其他影响因素中,频繁换道与平均车速相关性最大,其次为近距离跟驰、交通流量和急加减速。现有研究认为当影响变量间相关系数大于 0.7、0.85 或者 0.95 时,即认为两变量间相关性较高,需删除其中一个变量^[14]。由表 1 可知,本文所选影响变量间相关系数 $|\rho_{X,Y}| < 0.85$,其相关性大小均在阈值范围内,故将驾驶行为和交通流量等甄选为车速预测影响因素。

2 鲸鱼优化算法

2.1 环绕猎物

鲸鱼优化算法是 Mirjalili 等^[15]于 2016 年提出的一种包括环绕猎物、螺旋气泡网攻击和随机搜索等数学模型的一种元启发式算法。环绕猎物是指由于数据样本中最优位置不确定,故该数学模型假定当前适应度最高样本的位置为目标位置,并将其作为其他样本更新自身位置的参考:

$$\vec{D} = |C \cdot \vec{X}^*(t) - \vec{X}(t)| \quad (1)$$

$$\vec{X}(t+1) = \vec{X}^*(t) - A \cdot \vec{D} \quad (2)$$

式中: \vec{D} 为鲸鱼个体与猎物的距离向量; t 为当前迭代次数; \vec{X}^* 为最佳个体的位置向量; \vec{X} 为位置

向量;系数变量 A 和 C 的计算公式如下。

$$A = 2a \cdot r_1 - a \quad (3)$$

$$C = 2r_2 \quad (4)$$

式中: a 为随着迭代开始从 2 衰减到 0 的系数; r_1 和 r_2 为 $[0, 1]$ 之间的随机变量。

2.2 螺旋气泡网攻击

螺旋气泡网攻击主要是通过螺旋更新位置和收缩环绕机制模拟实现其他样本位置更新到最优样本位置距离的过程,鉴于螺旋更新位置和收缩环绕机制同时发生在螺旋气泡网攻击过程中,故该数学模型假定其各自发生的概率为 50%,公式为:

$$\vec{X}(t+1) = \begin{cases} \vec{X}^*(t) - A \cdot \vec{D}, & p < 0.5 \\ \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t), & (5) \\ p \geq 0.5 \end{cases}$$

式中: b 为螺旋位置形状的常量; l 为 $[-1, 1]$ 之间的随机数; p 为 $[-1, 1]$ 之间的随机数。

2.3 随机搜索

随机搜索机制主要是根据数据样本之间的位置进行随机搜索,该数学模型假定当 $A > 1$ 时,其根据数据样本的特征随机更新样本个体位置,以增强其全局搜索能力,公式为:

$$\vec{D} = |C \cdot \vec{X}_{\text{rand}} - X| \quad (6)$$

$$\vec{X}(t+1) = \vec{X}_{\text{rand}} - A \cdot \vec{D} \quad (7)$$

式中: \vec{X}_{rand} 为从当前群体中随机选择的个体。

3 改进鲸鱼优化 BiLSTM

3.1 混沌序列初始化

随机均匀分布的初始种群有助于扩展算法的搜索空间,提高算法的收敛速度和求解精度^[16]。由于未有任何先验条件可供使用,鲸鱼优化算法在搜索空间内随机生成的初始化种群,易导致算法个体位置分布不均匀,搜索空间较小。因混沌算法具有非线性、随机性和遍历性等特点,采用 Circle 映射产生初始化种群,相较于随机生成的种群,有助于提高 WOA 种群个体位置在求解空间分布的均匀性和种群遍历性,并将其可行解线性的转化到混沌变量优化空间,可有效降低算法易陷入局部最优状态的风险,进而提高其寻优求解效率。

$$x_{i+1} = \text{mod}(x_i + 0.2 - (0.5/2\pi) \sin(2\pi x_i), 1) \quad (8)$$

3.2 精英反向学习

精英反向学习^[17]是针对反向学习存在生成的反向解相对于当前搜索空间更难搜索到全局最优值的问题而提出的改进策略,该策略假设当前种群中一般个体对应的自身极值点为精英个体 $X_{i,j}^e = (X_{i,1}^e, X_{i,2}^e, \dots, X_{i,d}^e) (i = 1, 2, 3, \dots, d)$, 其反向解 $\overline{X}_{i,j}^e = (\overline{X}_{i,1}^e, \overline{X}_{i,2}^e, \dots, \overline{X}_{i,d}^e)$ 可表示为:

$$\overline{X}_{i,j}^e = K \times (\alpha_j + \beta_j) - X_{i,j}^e \quad (9)$$

式中: K 为在 $(0, 1)$ 上的动态系数; $X_{i,j}^e \in [\alpha_j, \beta_j]$, $\alpha_j = \min(X_{i,j})$, $\beta_j = \max(X_{i,j})$; α_j 和 β_j 为动态边界,其弥补了固定边界难以保存搜索经验的不足,使精英反向解可在狭窄的搜索空间中进行定位,有利于提高算法的收敛性能,若其操作使 $X_{i,j}^e$ 越过边界成为非可行解,则可根据式(10)随机生成的方法进行重置:

$$\overline{X}_{i,j}^e = \text{rand}(\alpha_j, \beta_j) \quad (10)$$

3.3 改进收敛因子及惯性权重

基于群思想的元启发式算法需平衡全局搜索和局部开发的关系,若不能平衡好两者的关系,易导致算法过早收敛陷入局部最优或收敛缓慢等问题。全局搜索意味着种群在广大的搜索空间进行搜寻,其搜索步长及空间相对较大,可降低算法陷入局部最优的概率。局部开发则要求种群在局部空间内进行精细化搜索,从而避免因搜索步长较大错失理论最优解。鲸鱼优化算法作为群思想元启发式算法的一种,如何平衡全局搜索和局部开发亦是至关重要的。由式(2)(5)和(7)可知,鲸

鱼优化算法的性能很大程度上依赖于 A 的取值,由式(3)可知收敛因子 a 的变化决定了 A 的取值。

鉴于鲸鱼优化算法中收敛因子呈线性递减,未能较好平衡全局搜索和局部开发间的关系,本文结合余弦函数特性,将收敛因子公式改进为:

$$a = 2 - 2 \cos\left(\frac{\pi \cdot t}{2 \cdot t_{\max}}\right) \quad (11)$$

式中: t_{\max} 为最大迭代次数。

鉴于鲸鱼优化算法不断更新领导者位置,易导致算法陷入局部最优的问题,本文通过引入惯性权重对鲸鱼位置进行更新,以期提高鲸鱼优化算法跳出局部最优的概率。改进后的鲸鱼位置更新公式为:

$$\vec{X}(t+1) = \varphi \vec{X}^*(t) - A \cdot \vec{D}, |A| < 1, p < 0.5 \quad (12)$$

$$\vec{X}(t+1) = \varphi \vec{X}_{\text{rand}} - A \cdot \vec{D}, |A| \geq 1, p < 0.5 \quad (13)$$

$$\vec{X}(t+1) = \vec{D}^t \cdot e^{bt} \cdot \cos(2\pi t) + \varphi \vec{X}^*(t), p \geq 0.5 \quad (14)$$

式中: φ 为惯性权重。

$$\varphi(t+1) = \varphi_{\max} - (\varphi_{\max} - \varphi_{\min}) \cdot \cos\left(\frac{t}{t_{\max}} \pi\right) \quad (15)$$

3.4 双向长短时神经网络

BiLSTM 网络由若干个时序相反、相互独立的前后向 LSTM 组成,其创新之处在于该网络中引入了未来时刻的数据样本信息对当前时刻的影响,综合考虑了数据样本前后两个方向的特征影响,可更充分地提取数据样本的时间特征^[18]。BiLSTM 网络通过前后正反向计算,分别得到两个方向的输出 \vec{h}_t 和 \overleftarrow{h}_t , 将两者结合后输入全连接层,可得到最终的时间序列预测值^[19]。BiLSTM 网络数学模型为:

$$\vec{h}_t = g_1([x_t, h_{t-1}] \cdot \vec{w} + b_h) \quad (16)$$

$$\overleftarrow{h}_t = g_1([x_t, h_{t-1}] \cdot \overleftarrow{w} + b_{\overleftarrow{h}}) \quad (17)$$

$$y_t = g_2(\vec{w} \vec{h}_t + \overleftarrow{w} \overleftarrow{h}_t + b_y) \quad (18)$$

式中: \vec{w} 和 b_h 为正向 LSTM 网络的权重矩阵和偏置向量; \overleftarrow{w} 和 $b_{\overleftarrow{h}}$ 为反向 LSTM 网络的权重矩阵和偏置向量; g_1, g_2 分别为激活函数 Sigmoid、ReLU。

3.5 IWOA-BiLSTM 预测流程

综合上述改进策略,本文所提的 IWOA-BiLSTM 车速预测流程如图 1 所示,步骤如下所示。

(1) 根据实验仿真效果和运行时间对比分析

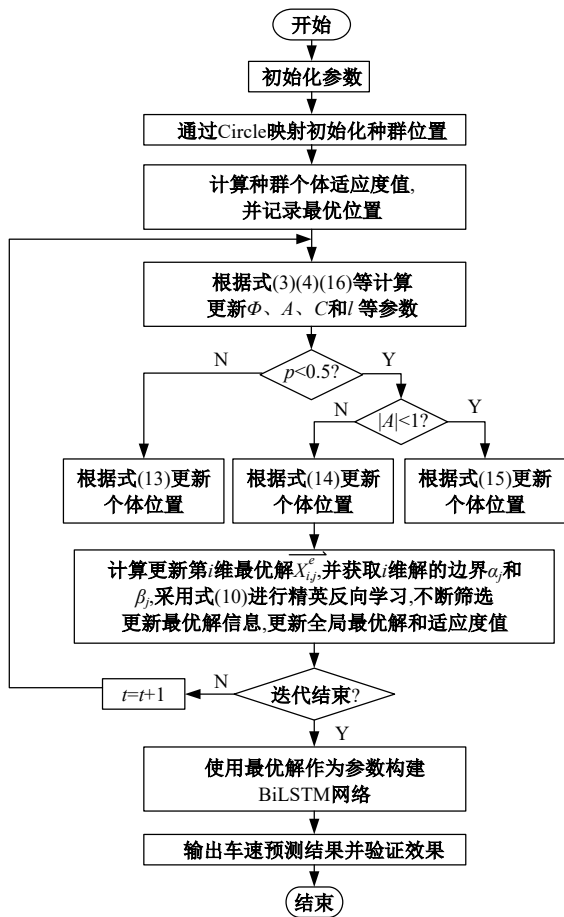


图 1 IWOA-BiLSTM 车速预测流程

Fig. 1 IWOA-BiLSTM speed prediction process

结果,将种群规模设置为 30,最大迭代次数为 40。

(2)按照 Circle 映射生成初始化种群。

(3)计算种群中个体的适应度值并记录最优位置 $\vec{X}(t)$ 。

(4)按照式(15)更新参数 φ ,同时更新 a 、 A 、 C 和 l 等参数。

(5)比较 $|A|$ 大小,以及随机生成的 p 值与 0.5 的大小后,选择相应的位置更新公式。若 $p < 0.5$ 且 $|A| < 1$,则按照式(12)更新当前个体位置;若 $p < 0.5$ 且 $|A| \geq 1$,则按照式(14)随机搜索猎物;若 $p \geq 0.5$,则按照式(14)更新当前位置。

(6)根据式(9)对当前维度解进行精英反向学习后与其他维度值组成新的可行解,并根据目标函数适应度值对其进行评价。若该解优于之前的解,则保留精英反向学习的新解;反之,保留之前解的信息。采用该方式将各维度的解更新完毕。

(7)判断算法是否达到最大迭代次数,若达到,则停止迭代计算,并输出最优个体位置和适应度值;若未达到,重复执行步骤(4)~(6)。

(8)输出 IWOA 算法全局最优解,并将其作为最优参数构建 BiLSTM 网络。

(9)使用 IWOA-BiLSTM 网络模型进行快速路口匝道车速预测,并进行效果验证。

4 数值仿真及预测结果

4.1 数值仿真结果

为验证本文所提混合改进策略对鲸鱼优化算法的有效性和鲁棒性,选取 12 个典型基准测试函数进行数值仿真实验,并将 30 次数值仿真结果与 WOA、灰狼优化算法 (Grey wolf optimizer, GWO)、粒子群优化算法 (Particle swarm optimization, PSO) 和遗传算法 (Genetic algorithm, GA) 进行综合对比分析。数值仿真实验中将各算法的种群个数设置为 30,最大迭代次数设置为 500。12 个典型基准测试函数中, $f_1 \sim f_4$ 为高维单模态基准测试函数, $f_5 \sim f_8$ 为高维多模态基准测试函数, $f_9 \sim f_{12}$ 为固定维数复合模态基准测试函数。各基准测试函数数值仿真结果平均值和标准差如表 2 所示。

单模态基准测试函数作为只有唯一全局最优解的测试函数,主要用于评估检测元启发式算法的开发能力。根据表 1 可知,在 f_1 、 f_2 、 f_3 和 f_4 等测试函数中,所有统计结果均优于其他元启发式算法,因此, IWOA 具有较强的开发能力。多模态基准测试函数相较于单模态基准测试函数,具有随着函数维度增加,包含许多局部最优解的特性。该特性对评估检测元启发式算法的探索能力具有较好的效果。由 f_5 、 f_7 和 f_8 等测试函数的统计结果可知, IWOA 相较于 WOA、GWO、PSO 和 GA 具有较强的探索能力。这主要是由于精英反向学习有效避免了算法陷入局部最优解,提高了可行解逼近全局最优解的概率。复合模态基准测试函数由于其组成较为复杂,在所属区间中存在多个局部极小值,常用于测试算法平衡全局搜索和局部开发关系的能力。因为只有元启发式算法在探索和开发之间取得适当的平衡,才能有效克服陷入局部最优的问题。根据 f_9 、 f_{10} 、 f_{11} 和 f_{12} 等测试函数统计结果可知, IWOA 相较于 WOA、GWO、PSO 和 GA 具有良好的全局搜索和局部开发平衡能力。 IWOA 算法良好的平衡性能主要得益于余弦函数对收敛因子的改进,以及使用惯性权重对鲸鱼优化算法位置更新的原因。

为进一步分析 IWOA 数值仿真结果的分布

表 2 基准测试函数仿真结果

Table 2 Benchmarking functions simulation results

测试函数	指标	IWOA	WOA	GWO	PSO	GA
f_1	平均值	2.6E-72	1.1E-50	1.0E-16	1.6E+01	3.9E+01
	标准差	1.4E-71	4.7E-50	6.6E-17	7.1E+00	6.7E+00
f_2	平均值	3.0E-05	6.2E-01	4.3E+04	1.0E+04	3.8E+04
	标准差	9.4E-05	2.3E+00	1.8E+04	6.5E+03	8.5E+03
f_3	平均值	2.1E-23	4.8E+01	8.2E-07	9.5E+00	6.8E+01
	标准差	9.1E-23	3.1E+01	9.5E-07	2.9E+00	8.6E+00
f_4	平均值	7.4E-05	4.1E-01	7.0E-01	3.3E+02	9.5E+03
	标准差	1.1E-04	2.6E-01	3.4E-01	1.5E+02	5.7E+03
f_5	平均值	-1.2E+04	-1.0E+04	-6.0E+03	-6.8E+03	-2.1E+03
	标准差	1.1E+03	1.9E+03	6.8E+02	1.1E+03	4.1E+02
f_6	平均值	1.9E-15	0.0E+00	2.7E+00	2.0E+02	2.6E+02
	标准差	1.0E-14	0.0E+00	2.9E+00	2.9E+01	3.3E+01
f_7	平均值	0.0E+00	1.5E-02	5.0E-03	4.4E+00	1.1E+02
	标准差	0.0E+00	4.6E-02	1.0E-02	1.4E+00	6.7E+01
f_8	平均值	4.7E-03	2.7E-02	4.6E-02	5.8E+00	8.4E+00
	标准差	2.5E-02	2.7E-02	2.5E-02	2.5E+00	4.2E+00
f_9	平均值	6.5E-04	4.3E-03	6.4E-03	1.2E-02	8.7E-03
	标准差	4.2E-04	1.2E-02	9.9E-03	9.2E-03	9.9E-03
f_{10}	平均值	-3.3E+00	-3.2E+00	-2.6E+00	-3.1E+00	-1.6E+00
	标准差	7.0E-02	1.3E-01	7.9E-01	1.7E-01	5.0E-01
f_{11}	平均值	-9.6E+00	-7.5E+00	-8.3E+00	-8.0E+00	-2.2E+00
	标准差	1.6E+00	3.1E+00	2.5E+00	2.5E+00	8.0E-01
f_{12}	平均值	-1.0E+01	-1.0E+01	-8.7E+00	-6.7E+00	-2.4E+00
	标准差	9.9E-01	2.1E+00	2.9E+00	3.0E+00	9.2E-01

特性,本文根据各算法独立运行 30 次求解基准测试函数的结果绘制箱式统计图,见图 2。图 2 中,每个框中的中心标记为算法求解基准测试函数的中位数,框的底部和顶部边缘表示一等分点和三等分点,符号“+”表示不在箱内的坏值。由箱式统计图中位数和坏值的对比结果可知,IWOA 具有求解质量更高,坏值较少的优势,且其求解结果分布更为集中,具有良好的鲁棒性。

4.2 收敛曲线分析

基准测试函数收敛曲线可直观体现各元启发式算法的收敛速度和求解精度,并可清晰展现元启发式算法克服局部最优的能力。12 个基准测试函数的收敛曲线见图 3,其中横轴代表迭代次数,纵轴代表测试函数独立运行 30 次后的平均适应度值。

由基准测试函数 f_3 、 f_6 和 f_7 的收敛曲线可知,在迭代前期 φ 值较大,种群迅速向最优个体的中心位置集聚,收敛速度较快。算法在迭代 300 次左右后,收敛曲线出现拐点,随着迭代次数增加,算法进行精英反向学习的概率变大,函数适应度

值迅速下降。根据基准测试函数 f_9 和 f_{12} 的收敛曲线可知,IWOA 在迭代 200 次左右就可达到其他对比算法的求解精度,此后由于精英反向学习和惯性权重因子的扰动作用,促使算法可有效跳出局部空间继续搜索最优解。

从 f_4 、 f_5 和 f_8 的收敛曲线可知,IWOA 在迭代过程中相较于其他算法多次出现拐点,表明通过余弦函数改进鲸鱼优化算法的自适应收敛因子,可更好地平衡全局搜索和局部开发间的关系,提高算法的收敛速度和求解精度。基准测试函数 f_{10} 的收敛曲线表明:IWOA 在迭代 100 次之前就能收敛到最优精度,证明在探索阶段的改进策略有效提高了鲸鱼优化算法的收敛速度。从 f_2 的收敛曲线可知,IWOA 在迭代初期的适应度值就优于其他对比算法,表明使用 Circle 映射初始化后的种群质量更高,在一定程度上提高了算法的全局搜索能力。通过基准测试函数 f_1 和 f_{11} 的收敛曲线可知,IWOA 相较于其他对比算法均具有较高的收敛速度和求解精度。

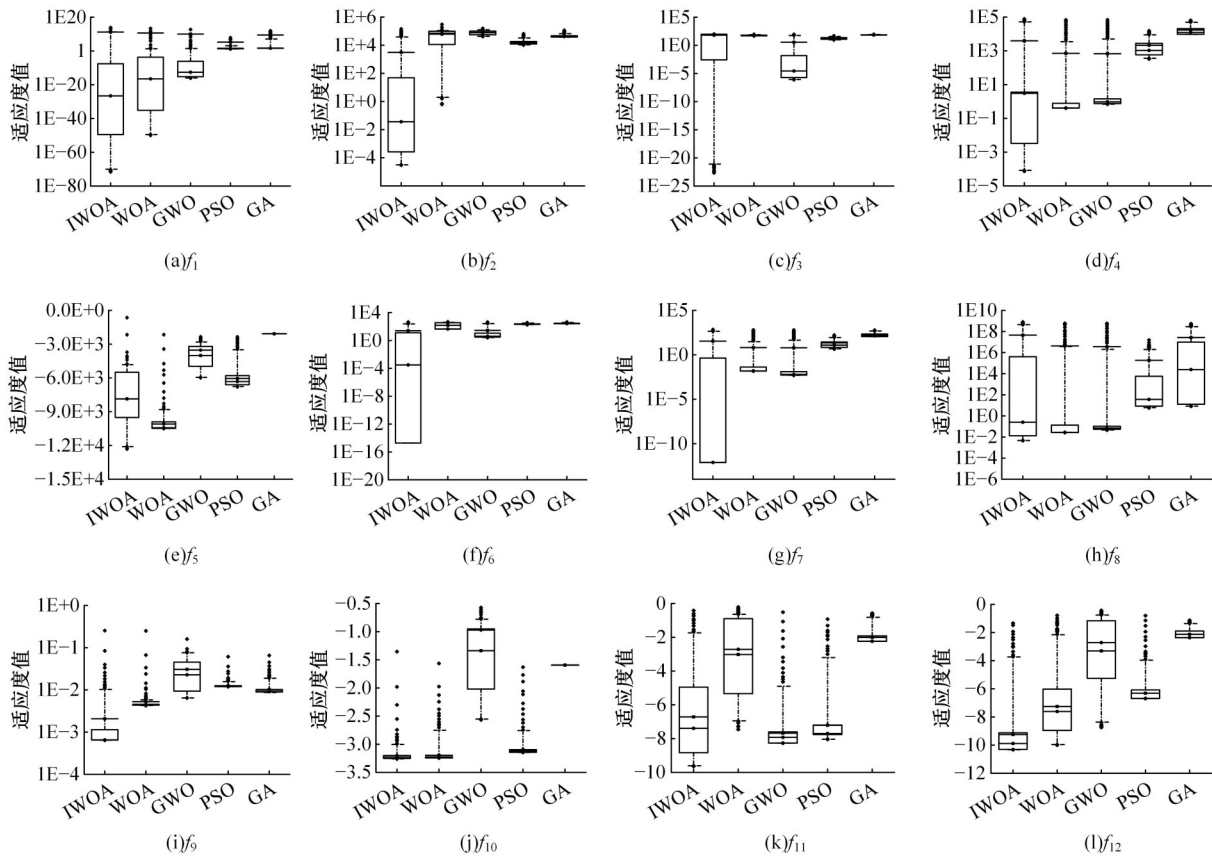


图 2 基准测试函数仿真结果统计

Fig. 2 Benchmarking functions simulation results statistics

4.3 算法时间复杂度与排名分析

对IWOA算法的时间复杂度进行分析,假定参数初始化(种群规模为 N ,空间维度为 d)执行时间为 t_1 ,产生随机分布的时间为 t_2 ,计算得到适应度函数所需时间为 $f(d)$,可得到鲸鱼优化算法初始阶段的时间复杂度为:

$$O(t_1 + N(dt_2 + f(d))) = O(d + f(d)) \quad (20)$$

设鲸鱼种群中所有个体在每一维度位置更新所需时间相同,都为 t_3 ,迭代后比较优劣和选择最优位置更新时间分别为 t_4 和 t_5 ,则鲸鱼优化算法在寻优阶段的时间复杂度为:

$$O(N(dt_3 + f(d) + t_4) + t_5) = O(d + f(d)) \quad (21)$$

因此,鲸鱼优化算法求解每代最优可行解的时间总复杂度为:

$$T(d) = O(d + f(d)) + O(d + f(d)) = O(d + f(d)) \quad (22)$$

在改进算法中,初始化阶段时间复杂度与鲸鱼优化算法基本一致。假设在寻优阶段鲸鱼个体位置更新时间为 e_1 ,精英反向学习更新鲸鱼最优

个体位置时间为 e_2 ,鲸鱼最优个体择优比较时间为 e_3 ,余弦函数改进自适应收敛因子和惯性权重更新鲸鱼个体位置时间为 e_4 ,则该阶段IWOA时间复杂度为:

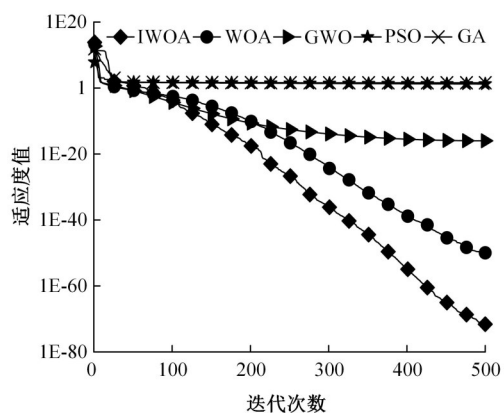
$$O(N(de_1 + f(d) + t_4) + t_5 + N(e_2 + e_4) + e_3) = O(d + f(d)) \quad (23)$$

因此,IWOA算法求解每代最优可行解的时间总复杂度为:

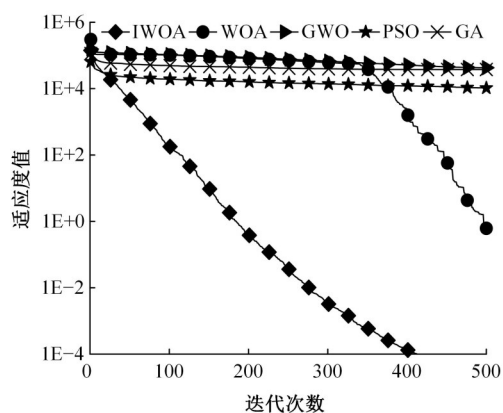
$$T(d) = O(d + f(d)) + O(d + f(d)) = O(d + f(d)) \quad (24)$$

综上,IWOA算法与WOA算法在时间复杂度上基本一致。为直观对比分析两种算法的时间复杂度,本文将12个基准测试函数分别用IWOA和WOA在同一平台单独运行30次,并将基准测试函数按照维度进行分类后,计算对应30次数值仿真实验的平均耗时,数值仿真实验平均耗时如表3所示。


由表3可知,IWOA在求解单峰基准测试函数方面与原算法时间基本一致,在求解多峰和复合基准测试函数方面并未增加算法的时间复杂




(a) f_1




(b) f_2



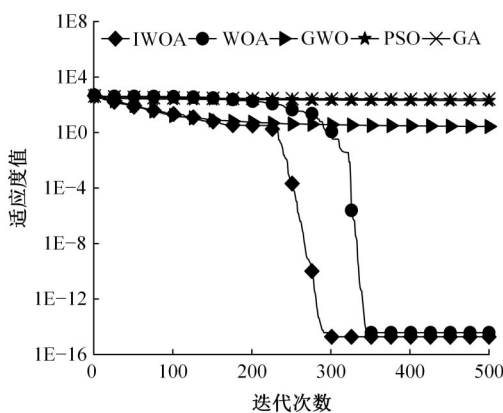
(c) f_3




(d) f_4




(e) f_5



(f) f_6



(g) f_7



(h) f_8

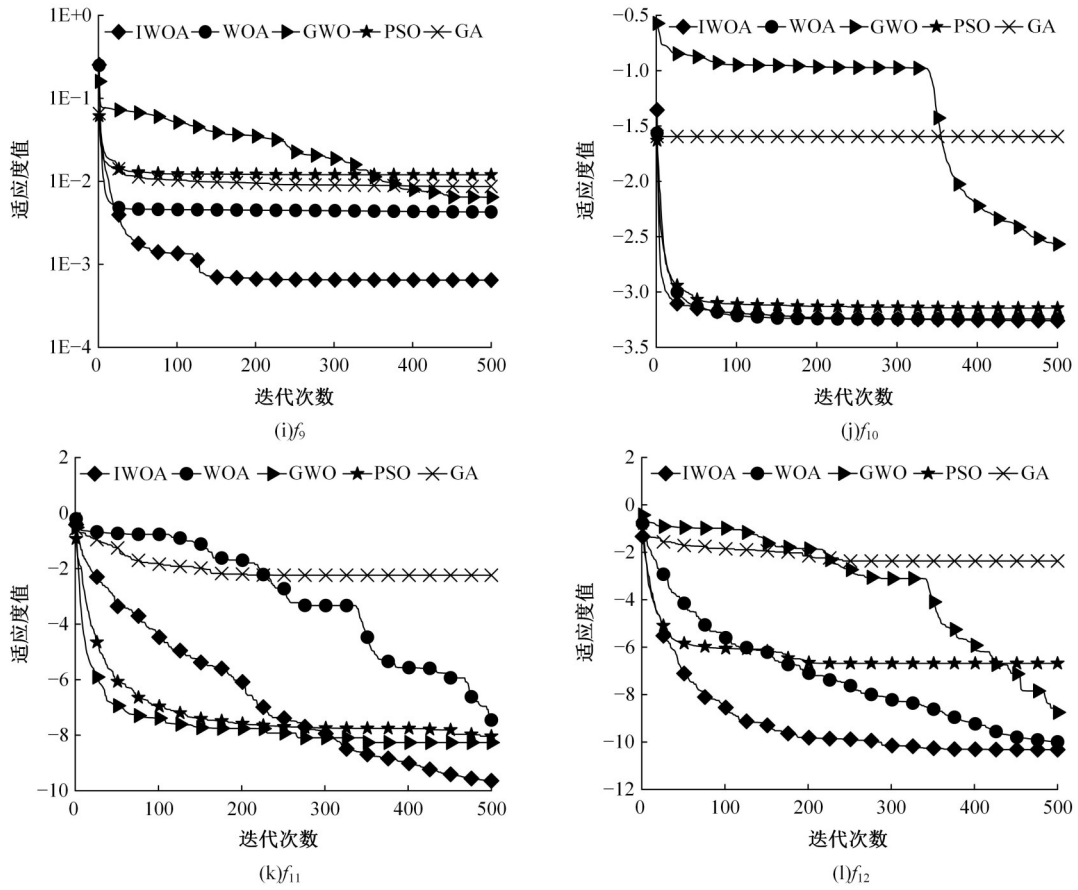


图 3 基准测试函数收敛曲线

Fig. 3 Benchmark function convergence curve

表 3 IWOA 和 WOA 的平均耗时对比

Table 3 Comparison of the average time consumption of IWOA and WOA

函数	平均耗时		WOA 与 IWOA 平均耗时的百分比/%
	WOA	IWOA	
单峰基准测试函数	1.570	1.828	116.43
多峰基准测试函数	1.977	1.905	96.36
复合基准测试函数	1.701	1.694	99.59
平均值	1.749	1.809	103.41

度,而且通过混合改进策略提高了算法的收敛度和寻优求解精度。

鉴于所有算法的定量分析都是基于 12 个基准测试函数的平均绝对误差 (Mean absolute error, MAE), 通过对算法数值仿真测试结果进行排序, 可有效验证算法的性能指标。表 4 为基准测试函数的 MAE 排序, 其公式为:

$$MAE = \sum_{i=1}^{N_f} |m_i - o_i| / N_f \quad (25)$$

式中: m_i 为算法求解结果的平均值; o_i 为每个基准测试函数的理论值; N_f 为基准测试函数的总数。

由表 4 可知, IWOA 的 MAE 排名为第 1, 相较

表 4 算法 MAE 排名

Table 4 Algorithm MAE ranking

算法	MAE	排名
IWOA	2.13E+01	1
WOA	1.78E+02	2
PSO	1.40E+03	3
GWO	4.10E+03	4
GA	4.85E+03	5

于其他对比算法, IWOA 表现出最小的 MAE 值, 从而再次证明了混合改进策略的有效性。

4.4 出口匝道车速预测结果分析

本文将预处理后的快速路出口匝道车速测数据集按照 6:2:2 分为训练集、验证集和测试集, 其中训练集是为得到出口匝道车速预测模型的拟合回归函数, 验证集用以调整确定出口匝道车速预测拟合回归函数的参数, 测试集用以验证预测模型的有效性。根据实验仿真效果和运行时间对比分析结果, 将 IWOA 算法种群规模参数 POP 设置为 30, 种群最大迭代次数 MAX 设置为 40, 变量取值范围下限 LB 设置为 $[1e-3, 10, 1e-4]$, 变量取值

范围上限 UB 设置为 $[1e-2, 50, 1e-1]$, 变量维数 dim 设置为 3。将处理后的快速路出口匝道车速预测数据集作为 IWOA-BiLSTM 的样本输入, 运用 IWOA 算法寻优确定预测模型的拟合回归参数, 并获得出口匝道车速预测值。为评价快速路出口匝道车速预测结果的准确度, 本文采用拟合

回归分析实际值与预测值的线性相关性, 结果如图 4 所示。由图 4 可知, 不同时间粒度下出口匝道实际值与预测值具有较强的线性相关性, 斜率分别为 0.826 4、0.823 4 和 0.821 2, R^2 分别为 0.917 3、0.956 2 和 0.996 1, 即实际值和预测值相差较小, 拟合模型具有较高精度。




图 4 实际值与预测值相关性

Fig. 4 Correlation between actual value and predicted value

4.5 预测结果对比分析

本文将现有预测模型中元启发式算法种群规模均设置为 30, 最大迭代次数均设置为 40, 以确保算法寻优过程中参数的一致性。将快速路出口

匝道车速预测数据集作为 IWOA-BiLSTM 和现有预测模型的输入, 可得到出口匝道不同时间粒度下的车速预测结果, 各预测模型误差统计结果如图 5 所示。




图 5 误差对比分析

Fig. 5 Error comparison analysis

由图 5 可知, IWOA-BiLSTM 预测结果误差统计值均低于现有预测模型, 值得注意的是, 出口匝道车速预测结果误差与时间粒度成反比, 主要原因是, 随着时间粒度的增加, 出口匝道车速数据相对平稳, 随机性和波动性较小。

表 5 为不同时间粒度下各模型预测性能指标对比。由表 5 可知, IWOA-BiLSTM 对快速路出口匝道不同时间粒度下车速预测结果的 MAE、均方根差 (Root mean square error, RMSE) 和平均绝对百分比误差 (Mean absolute percentage error,

MAPE) 的均值分别为 4.6%、4.8% 和 7.4%, 相较于 WOA-BiLSTM 分别降低了 2.3%、2.3% 和 3.9%; 相较于 PSO-ELMAN 分别降低了 2.7%、2.7% 和 4.6%; 相较于 GA-BP 分别降低了 3.2%、2.9% 和 5.2%; 相较于 LSTM 分别降低了 3.1%、2.9% 和 5.2%; 相较于 SVM 分别降低了 3.8%、3.9% 和 6.4%。值得注意的是, 所有模型的 MAPE 与时间粒度成反比, 但是 IWOA-BiLSTM 的变化幅度最小, 表明其鲁棒性和适用性较好。

表 5 不同时间粒度下各模型预测性能指标对比

Table 5 Comparison of the prediction performance indexes of each model under different time granularity

类别	5 min			15 min			30 min		
	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%	MAE	RMSE	MAPE/%
IWOA-BiLSTM	4.7	5.0	7.5	4.6	4.8	7.4	4.5	4.6	7.2
WOA-BiLSTM	7.0	7.2	11.5	6.9	7.2	11.3	6.8	6.8	11.0
PSO-ELMAN	7.7	7.8	12.5	7.2	7.3	11.7	7.1	7.3	11.6
GA-BP	8.4	8.3	13.5	7.7	7.5	12.4	7.3	7.3	11.8
LSTM	7.8	7.9	12.8	7.6	7.9	12.5	7.6	7.4	12.3
SVM	8.9	9.2	14.6	8.3	8.9	13.7	7.9	8.0	12.9

5 结束语

本文采用混合策略改进鲸鱼优化算法,并对比分析了12个基准测试函数的数值仿真结果与收敛特性,结果表明:IWOA在求解精度、收敛速度和跳出局部最优能力等方面相较于WOA、GWO、PSO和GA等算法具有更为出色的寻优求解性能。使用IWOA对BiLSTM进行超参数寻优并构建训练了基于IWOA-BiLSTM的快速路出口匝道车速预测模型,该模型相较于现有预测模型具有较高的精度,且模型鲁棒性和适用性较强。未来研究需通过考虑改变鲸鱼优化算法的寻优机理和结构,以及融合其他元启发式算法的优点,提出性能更佳并可有效提高BiLSTM预测精度和适用性的优化算法和车速预测模型。

参考文献:

- [1] Hou L, Pei Y, He Q. A car following model in the context of heterogeneous traffic flow involving multi-lane following behavior[J]. *Physica A: Statistical Mechanics and its Applications*, 2023, 632: No. 129307.
- [2] 朱洁玉, 马艳丽. 合流区域多车交互风险实时评估方法[J]. *吉林大学学报: 工学版*, 2022, 52(7): 1574-1581.
Zhu Jie-yu, Ma Yan-li. Real-time assessment method of multi-vehicle interaction risk in confluence area[J]. *Journal of Jilin University (Engineering Edition)*, 2022, 52(7): 1574-1581.
- [3] Boukerche A, Wang J. Machine learning-based traffic prediction models for intelligent transportation systems[J]. *Computer Networks*, 2020, 181: No. 107530.
- [4] Tedjopurnomo D A, Bao Z, Zheng B, et al. A survey on modern deep neural network for traffic prediction: trends, methods and challenges[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2020, 34(4): 1544-1561.
- [5] Lee S, Lee Y I, Cho B. Short-term travel speed prediction models in car navigation systems[J]. *Journal of Advanced Transportation*, 2006, 40(2): 122-139.
- [6] Zhang Z, Wang Y, Chen P, et al. Probe data-driven travel time forecasting for urban expressways by matching similar spatiotemporal traffic patterns[J]. *Transportation Research Part C: Emerging Technologies*, 2017, 85: 476-493.
- [7] Chen P, Ding C, Lu G, et al. Short-term traffic states forecasting considering spatial-temporal impact on an urban expressway[J]. *Transportation Research Record*, 2016, 2594(1): 61-72.
- [8] Tang K, Chen S, Cao Y, et al. Short-Term travel speed prediction for urban expressways: hybrid convolutional neural network models[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 23(3): 1829-1840.
- [9] George S, Santra A K. An improved long short-term memory networks with Takagi-Sugeno fuzzy for traffic speed prediction considering abnormal traffic situation[J]. *Computational Intelligence*, 2020, 36(3): 964-993.
- [10] Manne S, Lydia E L, Pustokhina I V, et al. An intelligent energy management and traffic predictive model for autonomous vehicle systems[J]. *Soft Computing*, 2021, 25(18): 11941-11951.
- [11] Jia X, Zhou W, Yang H, et al. Short-term traffic travel time forecasting using ensemble approach based on long short-term memory networks[J]. *IET Intelligent Transport Systems*, 2023, 17: 1262-1273.
- [12] Shuai C, Wang W C, Xu G, et al. Short-term traffic flow prediction of expressway considering spatial influences[J]. *Journal of Transportation Engineering, Part A: Systems*, 2022, 148(6): No. 04022026.
- [13] Wolpert D H, Macready W G. No free lunch theorems for optimization[J]. *IEEE Transactions on Evolutionary Computation*, 1997, 1(1): 67-82.

- [14] Yuan J, Abdel-Aty M, Gong Y, et al. Real-time crash risk prediction using long short-term memory recurrent neural network[J]. Transportation research record, 2019, 2673(4): 314-326.
- [15] Mirjalili S, Lewis A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [16] Kaur G, Arora S. Chaotic whale optimization algorithm[J]. Journal of Computational Design and Engineering, 2018, 5(3): 275-284.
- [17] Seif Z, Ahmadi M B. An opposition-based algorithm for function optimization[J]. Engineering Applications of Artificial Intelligence, 2015, 37: 293-306.
- [18] 刘嫣然, 孟庆瑜, 郭洪艳, 等. 图注意力模式下融合高精地图的周车轨迹预测[J]. 吉林大学学报: 工学版, 2023, 53(3): 792-801.
- [19] Liu Yan-ran, Meng Qing-yu, Guo Hong-yan, et al. Cycle car trajectory prediction with high-precision map fusion under the attention mode of map[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(3): 792-801.
- [19] 张兵, 周丹丹, 孙健. 基于双向长短期记忆网络的公交到站时间预测模型[J]. 交通运输系统工程与信息, 2023, 23(2): 148-160.
- Zhang Bing, Zhou Dan-dan, Sun Jian, et al. Bus arrival time prediction model based on bidirectional long short-term memory network[J]. Transportation System Engineering and Information, 2023, 23(2): 148-160.