

自适应神经网络交通流预测的 混沌麻雀优化方法

王敬月^{1,2}, 楼俊钢^{1,2}

(1. 湖州师范学院 湖州长三角智慧交通研究院, 浙江 湖州 313000;

2. 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江 湖州 313000)

摘要:群体优化神经网络模型可以以任意精度逼近各种复杂函数,在各类非线性预测问题包括交通流预测中得到了很好的应用. 鉴于其局部寻优能力强、收敛速度快等特点,采用麻雀算法来优化自适应神经网络交通流预测模型的参数,并在麻雀算法中引入混沌映射,以增加其搜索的遍历均匀性和随机性,从而优化其全局寻优性能. 多个实际交通流数据集的实验结果表明,相比常用的群体优化神经网络模型,优化后的自适应神经网络交通流预测模型的平均预测准确度提升 0.52%~4.01%.

关键词:智能交通;麻雀算法;Tent 映射;参数优化;交通流预测

中图分类号:U491

文献标志码:A

文章编号:1009-1734(2022)10-0000-08

交通流预测模型是智能交通领域最热门的研究方向之一. 实时准确的交通流预测可以针对路面交通状况制定相应的管理方案,以有效缓解道路交通拥堵,提高出行效率,降低交通事故的发生几率等^[1]. 目前,国内外研究者已提出大量的交通流预测模型,包括非参数回归模型^[2]、K 近邻模型^[3-4]、混沌理论模型^[5]、神经网络模型(Artificial Neural Network, ANN)^[6]和深度学习模型^[7]等.

ANNs 模型是最常用的交通流预测方法之一,其具有很强的非线性映射能力和柔性的网络结构,通过对网络层数、神经元个数等的设定,以任意精度逼近各类非线性问题. 因此,ANNs 被广泛用于软件失效预测、电力负荷预测等非线性预测问题^[8-9]. 群优化算法^[10-11]是通过模拟生物界群体行为特征而得出的一种新兴元启发式算法,其结构简洁,擅长并行处理. 将群优化算法融入各类 ANNs,可以极大地提升其预测效果^[12-13]. Vlahogianni 等提出基于遗传算法(Genetic Algorithm, GA)的多层 ANN 结构优化策略,该策略有助于精确描述交通流数据,指导 ANN 的结构选择^[14]. Chan 等运用多尺度分析交通流参数,并结合 Levenberg-Marquardt 算法和指数平滑的混合 ANN 来优化多尺度系数^[15]. Ghadami 等提出一种无系统模型,该模型仅使用预警指标和分叉方法预测环形道路的拥堵状态^[16]. Peng 等针对静态混合城市的交通网络结构和基于历史交通流站点间的动态时空关系,建模新的时空关联动态预测图结构^[17]. 李松等针对混沌时间序列,提出使用 GA 优化误差反向传播神经网络(Back Propagation Neural Networks, BPNN)预测交通流,使预测值较好地拟合实际值,从而提高预测准确性^[18]. 寇飞采用自适应人工鱼群算法改进 BP 参数,较好地体现了预测过程交通流变化的特性^[19].

麻雀搜索算法(Sparrow Search Algorithm, SSA)是由 Xue 等^[20]于 2020 年提出的,它是一种新型群体智能优化算法,其主要思想是根据麻雀种群觅食及反捕食等一系列行为,选取具有最优适应度值的麻雀. 该算法在收敛速度和精度等方面优于粒子群算法(Particle Swarm Optimization, PSO)和引力搜索等群体智能优化算法. 本文引入 Tent 混沌映射^[21]来增加 SSA 的遍历均匀性和随机性,提出混沌麻雀算法(Chaos Sparrow Search Algorithm, CSSA),以提高 SSA 的全局寻优能力;利用 CSSA 优化 BP 神经网络

收稿日期:2021-04-28

基金项目:国家自然科学基金项目(61772199);浙江省自然科学基金项目(LR20F020002).

通信作者:楼俊钢,博士,教授,研究方向:机器学习与智能信息处理. E-mail:ljg@zjhu.edu.cn.

交通流预测模型的参数,建立 CSSA-BPNN 交通流预测模型,并将其应用于国内 3 个不同城市的真实交通数据集,以验证该模型的有效性.

1 CSSA 算法

1.1 SSA 算法

麻雀种群分为生产者、跟随者和侦察者.生产者具有较好的觅食技能,且负责引领其他麻雀觅食;跟随者主要跟随一只麻雀觅食且监视争夺食物;侦察者负责在危险时发出信号,使所有麻雀进行位置移动以躲避危险.种群麻雀适应度值可用以下矩阵表示:

$$F_x = \begin{bmatrix} f([X_{1,1} & X_{1,2} & \cdots & X_{1,d}]) \\ f([X_{2,1} & X_{2,2} & \cdots & X_{2,d}]) \\ \cdots & \cdots & \cdots & \cdots \\ f([X_{n,1} & X_{n,2} & \cdots & X_{n,d}]) \end{bmatrix}, \quad (1)$$

其中, n 为麻雀数量, d 为待优化变量维数.

在种群迭代过程中,生产者的位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp(\frac{-i}{\partial \cdot \text{item}_{\max}}), & R_2 < ST, \\ X_{i,j}^t + QL, & R_2 \geq ST, \end{cases} \quad (2)$$

其中, t 为当前迭代值, j 为 1 到 d 之间的维数, $X_{i,j}^t$ 为第 i 只麻雀在迭代 t 时第 j 维的值, $\text{item}_{\max}$ 为迭代次数最多的数, $R_2 \in [0,1]$, $ST \in [0.5,1.0]$ 分别为报警值和安全阈值, Q 为服从正态分布的随机数, L 为元素全为 1 的 $1 \times d$ 的矩阵.如果 $R_2 < ST$,则麻雀种群是安全的,反之则表示一些麻雀发现捕食者,种群中的所有麻雀须转移到安全区域.

跟随者会时刻监控生产者,一旦发现生产者具有更好的食物,它们就会去争夺,如果赢了,则获得食物,否则继续监控.跟随者的位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{j^2}\right), & i > n/2, \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| \cdot A^+ \cdot L, & \text{otherwise}, \end{cases} \quad (3)$$

其中: X_p 为生产者所占据的最佳位置; X_{worst} 为当前最差位置; A 为元素被随机分配 1 和 -1 的 $1 \times d$ 矩阵, $A^+ = A^T(AA^T) - 1$.当 $i > n/2$ 时,第 i 个跟随者由于饥饿,因此其适应度值较差.

在危险时,麻雀的位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g, \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \epsilon}\right), & f_i = f_g, \end{cases} \quad (4)$$

其中: X_{best} 为当前最佳位置; β 是一个均值为 0、方差为 1 的正态分布; $K \in [-1,1]$ 为一个随机数; f_i 为目前麻雀的适应度值; f_g 和 f_w 分别为当前麻雀的最佳和最差适应度值; ϵ 为避免零分区误差的最小常数; $f_i > f_g$ 表示麻雀在群体的边缘; $f_i = f_g$ 表示处于种群中间的麻雀意识到危险,需要靠近其他麻雀; K 为麻雀移动方向,为步长控制系数.

1.2 Tent 混沌映射

为避免算法过早收敛而加快迭代速度,可使用混沌系统初始化种群.混沌是指在一个确定性系统中存在的貌似随机的不规则运动,其行为表现为不确定性、不可重复和不可预测的混沌现象. logistic 映射和 Tent 映射是当前应用较广的离散混沌映射系统.研究表明, Tent 映射比 Logistic 映射具有更优的遍历均匀性和收敛速度^[22].因此,本文采用 Tent 混沌映射初始化种群. Tent 混沌映射的表达式如下:

$$Z_{i+1} = \begin{cases} 2Z_i, & 0 \leq Z \leq \frac{1}{2}, \\ 2(1-Z_i), & \frac{1}{2} < Z \leq 1. \end{cases} \quad (5)$$

其在可行域中先随机产生初值 Z_0 , 迭代直到达到最大次数, 最终产生 Z 序列。

1.3 CSSA 算法

CSSA 算法流程见图 1. 其具体步骤如下:

Step1: 构建 BP 神经网络模型, 初始化网络参数;

Step2: 初始化麻雀算法的各项参数, 如空间维数、麻雀规模、迭代次数、种群上下边界、生产者数量等;

Step3: 采用 Tent 混沌映射初始化种群, 加入混沌扰动, 使种群尽可能地均匀分布;

Step4: 计算种群中麻雀的适应度值;

Step5: 在 1 到迭代次数之间, 根据适应度值对种群进行排序;

Step6: 生产者的位置更新、跟随者的位置更新、在危险时麻雀的位置更新;

Step7: 先进行个体最优更新, 再进行群体最优更新;

Step8: 将上述步骤得到的最优适应度值和全局最优位置赋予 BP 神经网络模型, 以优化其权值和阈值, 从而进行预测。




图 1 CSSA 算法流程图

Fig. 1 CSSA algorithm flow

CSSA 算法主要部分的伪代码见表 1.

表 1 CSSA 算法主要部分的伪代码

Tab. 1 Pseudocode for the main part of the CSSA algorithm

输入: 待优化的变量 X	15. END
输出: 最优位置 $zbest$, 最优适应度值 $fitnesszbest$	16. FOR $i = (pNum + 1)$ to $sizepop$ by 1
1. 初始化参数: 空间维数 dim 、迭代次数 $Maxgen$ 、麻雀规模 $sizepop$ 、 种群上边界 $popmin$ 、种群下边界 $popmax$	17. 跟随者的位置更新
2. FOR $i = 1$ to $sizepop$ by 1	18. END
3. 计算种群中每个麻雀的位置	19. FOR $j = 1$ to $length(b)$ by 1
4. END	20. 在危险时, 麻雀群体的位置更新
5. FOR $i = 1$ to dim by 1	21. END
6. 加入混沌扰动种群位置	22. FOR $j = 1, 2, \dots, sizepop$ do
7. END	23. IF $fitness(j) < fitnessgbest(j)$ THEN
8. FOR $i = 1$ to $sizepop$ by 1	24. 个体最优适应度值的更新
9. 计算适应度值	25. END
10. END	26. IF $fitness(j) < fitnesszbest$ THEN
11. FOR $t = 1$ to $maxgen$	27. 群体最优适应度值的更新
12. 根据适应度值对麻雀进行排序	28. END
13. FOR $i = 1$ to $pNum$ by 1	29. END
14. 生产者的位置更新	30. END

2 基于 CSSA - BPNN 的交通流预测模型

基于 CSSA - BPNN 的交通流预测模型如图 2 所示. 该模型采用 3 层 BP 神经网络: 输入层取 4、隐藏层取 8、输出层取 1. 模型的输入包括车间距(m)、车速(m/s)、车道数(n)、车密度(veh/km), 输出为下一时间段的交通流量.




图 2 基于 CSSA - BPNN 的交通流预测模型

Fig. 2 Traffic flow forecasting model based on CSSA - BPNN

3 实验分析

3.1 模型实验

实验数据集来自: 上海市中心近陕西路西侧延安高架路段, 时间为 2020 年 2 月 1 日 14:10 - 17:10, 天气下雪; 北京市北四环近中关村路段, 时间为 2020 年 11 月 3 日 08:30 - 11:00, 天气晴; 西安南二环长安立交路段, 时间为 2020 年 8 月 4 日 11:25 - 18:15, 天气晴. 采集路面数据信息的记录时间间隔为 0.8 s.

在实验中, 种群最大迭代次数为 100 次, 学习率为 0.1, 目标值为 0.000 01, 麻雀种群规模为 100, 种群边界值为 $[-5, 5]$. 首先将遗传算法结合 BP (GA - BP)、粒子群算法结合 BP (PSO - BP)、麻雀算法结合 BP (SSA - BP)、Logistic 映射优化 SSA 结合 BP (Logistic Sparrow Search Algorithm, LSSA - BP)、CSSA - BP 5 种模型分别输入训练集数据进行网络训练, 并在训练完成后将其输入测试集数据进行预测.

图 3 为 5 种模型分别使用 3 组数据集进行实验的结果, x 轴为预测次数, y 轴为预测值与实际值之间的误差百分值. 误差百分值越小, 说明预测值越接近实际值, 交通流预测效果越好.




图 3 5 种模型在 3 组数据集上的预测误差对比图

Fig. 3 Comparison plot of prediction errors of 5 models on 3 datasets

图 3(a)为使用第 1 组数据集进行的实验.第 1 组数据集有 1 868 组数据,选取前 1 400 组作为训练集,后 468 组作为测试集.根据预测第 125~140 次的实验结果误差对比,可以看出,CSSA-BP 模型比其他 4 种模型的预测误差更接近 0,预测效果更好.图 3(b)为使用第 2 组数据集进行的实验,第 2 组数据集有 4 552 组数据,选取前 3 500 组作为训练集,后 1 052 组作为测试集.根据预测第 145~165 次的实验结果误差对比,可以看出,CSSA-BP 模型比其他 4 种模型的预测误差更稳定.图 3(c)为使用第 3 组数据集进行的实验,第 3 组数据集有 2 830 组数据,选取前 2 200 组作为训练集,后 630 组作为测试集.根据预测第 135~145 次的实验结果误差对比,可以看出,CSSA-BP 模型的预测过程更稳定,预测误差变化幅度更小.由此可见,本文提出的 CSSA-BP 交通流预测模型的预测误差最小,其预测值更接近实际值,预测精度最高,效果最优.

图 4 为 5 种模型在 3 组数据集上的网络迭代次数对比图, x 轴为预测模型的迭代次数, y 轴为模型迭代结束时所达到的最小均方误差(MSE).迭代次数越小,说明模型的预测速度越快,MSE 值越小,精度越高.




图 4 5 种模型在 3 组数据集上的网络迭代次数对比图

Fig. 4 Comparison chart of the number of network iterations on 3 datasets of 5 models

图 4(a)为 5 种模型在第 1 组数据集上的训练结果.从 0 开始进行第 1 次训练,可以看出,CSSA-BP 网络迭代 7 次结束,SSA-BP 网络迭代 8 次结束,GA-BP 网络迭代 10 次结束,PSO-BP 网络迭代 10 次结束,LSSA-BP 网络迭代 7 次结束.图 4(b)为 5 种模型在第 2 组数据集上的训练结果.从 0 开始进行第 1 次训练,可以看出,CSSA-BP 网络迭代 6 次结束,SSA-BP 网络迭代 10 次结束,GA-BP 网络迭代 8 次结束,PSO-BP 网络迭代 10 次结束,LSSA-BP 迭代 11 次结束.图 4(c)为 5 种模型在第 3 组数据集上的训练结果.从 0 开始进行第 1 次训练,可以看出,CSSA-BP 网络迭代 9 次结束,SSA-BP 网络迭代 13 次结束,GA-BP 网络迭代 12 次结束,PSO-BP 网络迭代 9 次结束,LSSA-BP 网络迭代 12 次结束.5 种模型在 3 组数据集上的预测均方误差(MSE)随着迭代次数的增加而逐渐减小,其中 CSSA-BP 模型的 MSE 最小.经综合分析发现,CSSA-BP 模型相比其他 4 种模型,其收敛速度更快.

3.2 模型评价

选用 RMSE、MAE、MAPE 和预测准确率为评价指标,其计算公式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |y_{pred} - y_{true}|^2}, \quad (6)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{pred} - y_{true}| \quad (7)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_{pred} - y_{true}|}{y_{true}}, \quad (8)$$

$$\text{预测准确率}(\%) = (1 - MAPE) \times 100\%, \quad (9)$$

其中, y_{pred} 为预测值, y_{true} 为实际值, N 为预测次数.

BP 神经网络权值和阈值是随机产生的,且群体优化算法的全局寻优效果不一,所以需要对这 5 种模型分别使用 3 组数据集进行 10 次实验,以计算最优值 F_1 、最差值 F_2 、平均值 F_3 。表 2 结果表明,在 3 组数据集的实验中,CSSA-BP 模型的 MAE、RMSE、MAPE 均值均比 GA-BP、PSO-BP、SSA-BP、LSSA-BP 模型小。而评估指标 MAE、RMSE、MAPE 值越小,说明模型预测交通流的测试值与实际值拟合度越高,其预测精度越高。因此,CSSA-BP 模型的误差分布离散程度更小,误差更小,预测效果更好。

表 2 5 种模型的误差评价指标值

Tab. 2 Error evaluation index values of five models

模型	评价结果	MAE			RMSE			MAPE		
		1	2	3	1	2	3	1	2	3
GA-BP	F_1	7.349	6.194	13.962	17.249	10.953	26.479	0.015	0.008	0.013
	F_2	18.485	15.213	19.594	21.919	29.447	53.974	0.046	0.032	0.264
	F_3	13.786	11.306	15.233	26.514	24.783	28.192	0.031	0.016	0.050
PSO-BP	F_1	7.069	6.875	8.905	14.075	16.398	12.975	0.025	0.007	0.009
	F_2	14.144	10.290	15.424	33.011	19.829	27.615	0.059	0.044	0.751
	F_3	13.506	11.922	15.396	34.357	22.918	29.103	0.037	0.017	0.115
SSA-BP	F_1	7.912	5.848	10.069	10.938	10.225	17.957	0.015	0.006	0.012
	F_2	13.853	16.175	11.409	25.329	27.301	20.370	0.091	0.015	0.113
	F_3	12.523	10.300	11.739	20.253	18.677	20.447	0.034	0.011	0.034
LSSA-BP	F_1	8.755	5.232	13.739	19.939	7.053	23.342	0.018	0.005	0.016
	F_2	13.295	12.221	14.063	77.110	24.082	24.655	0.082	0.033	0.044
	F_3	12.163	8.896	11.935	26.211	18.246	20.276	0.033	0.013	0.030
CSSA-BP	F_1	5.952	4.468	8.162	13.433	8.846	11.504	0.014	0.005	0.008
	F_2	8.243	12.074	9.299	13.632	19.808	17.905	0.036	0.011	0.075
	F_3	8.685	7.954	9.606	15.551	13.959	17.985	0.028	0.008	0.025

表 3 为在 3 组数据集实验中,CSSA-BP 模型的 4 项评价指标相对其他 4 种模型的变化率。从表 3 可以看出,CSSA-BP 的平均绝对误差(MAE)比 GA-BP 降低 34.5%,比 PSO-BP 降低 35.4%,比 SSA-BP 降低 23.8%,比 LSSA-BP 降低 19.5%;CSSA-BP 的均方根误差(RMSE)比 GA-BP 降低了 40.3%,比 PSO-BP 降低了 44%,比 SSA-BP 降低 20.1%,比 LSSA-BP 降低 25%;CSSA-BP 的平均绝对百分比误差(MAPE)比 GA-BP 降低 36.5%,比 PSO-BP 降低 51.8%,比 SSA-BP 降低 23.7%,比 LSSA-BP 降低 23.3%。CSSA-BP 模型相对其他 4 种模型的平均预测准确率比 GA-BP 提升 1.25%,比 PSO-BP 提升 4.01%,比 SSA-BP 提升 0.62%,比 LSSA-BP 提升 0.52%。由此可以看出,CSSA-BP 模型预测交通流的测试值与实际值的拟合度更高,误差更小,整体的预测效果更优。

表 3 CSSA-BP 相对其他 4 种模型的评价指标变化率(%)

Tab. 3 CSSA-BP compares the evaluation index change rate of the four models (%)

模型	数据集	MAE	RMSE	MAPE	预测准确率提高百分值/%
GA-BP	1	37	41.3	9.6	0.31
	2	29.6	43.6	50	0.81
	3	36.9	36.2	50	2.63
	均值	34.5	40.3	36.5	1.25
PSO-BP	1	35.6	54.7	24.3	0.94
	2	33.2	39.1	52.9	0.92
	3	37.6	38.2	78.2	10.17
	均值	35.4	44	51.8	4.01

表 3(续)

模型	数据集	MAE	RMSE	MAPE	预测准确率提高百分值/%
SSA - BP	1	30.6	23.2	17.6	0.62
	2	22.7	25.2	27.2	0.3
	3	18.1	12	26.4	0.93
	均值	23.8	20.1	23.7	0.62
LSSA - BP	1	28.5	40.6	15.1	0.52
	2	10.5	23.4	38.4	0.51
	3	19.5	11.2	16.6	0.52
	均值	19.5	25	23.3	0.52

4 结 语

本文在 3 组真实交通流数据集上对 5 种模型进行预测,结果表明,CSSA - BP 模型相比 GA - BP、PSO - BP、SSA - BP、LSSA - BP⁴,其预测精确度更高,迭代速度更快.虽然 3 组数据集的采集时间、天气状况不一,但实验结果未受到影响.从总体看,CSSA - BPNN 模型结构精简,预测效果较优,具有实际应用价值.未来的研究将进一步考虑加入空间因素.此外,某一条道路车流量也会受邻近道路车流量的影响而发生变化,若排除天气、时间和空间因素,模型将能更精准地预测道路车流量.

参考文献:

- [1] 郭戈,许阳光,徐涛,等.网联共享车路协同智能交通系统综述[J].控制与决策,2019,34(11):2 375 - 2 389.
- [2] MA D F,SHENG B W,JIN S,et al. Fuzzy hybrid framework with dynamic weights for short - term traffic flow prediction by mining spatio - temporal correlations[J]. IET Intelligent Transport Systems,2020,14(2):73 - 81.
- [3] ZHENG Z D,SU D C. Short - term traffic volume forecasting: A k - nearest neighbor approach enhanced by constrained linearly sewing principle component algorithm[J]. Transportation Research Part C:Emerging Technologies,2014,43:143 - 157.
- [4] XIA D W,WANG B F,LI H Q,et al. A distributed spatial - temporal weighted model on MapReduce for short - term traffic flow forecasting[J]. Neurocomputing,2016,179:246 - 263.
- [5] CHENG A Y,JIANG X,LI Y F,et al. Multiple sources and multiple measures based traffic flow prediction using the chaos theory and support vector regression method[J]. Physica A:Statistical Mechanics and its Applications,2017,466:422 - 434.
- [6] PAMULA T. Impact of data loss for prediction of traffic flow on an urban road using neural networks[J]. IEEE Transactions on Intelligent Transportation Systems,2018,20(3):1 000 - 1 009.
- [7] ZHANG D G,WANG J X,FAN H R,et al. New method of traffic flow forecasting based on quantum particle swarm optimization strategy for intelligent transportation system[J]. International Journal of Communication Systems,2021,34(1):e4647.1 - e4647.20.
- [8] VALLERO G,RENGA D,MEO M,et al. RAN energy efficiency and failure rate through ANN traffic predictions processing[J]. Computer Communications,2022,183:51 - 63.
- [9] NEERAJ N,MATHEW J,AGARWAL M,et al. Long short - term memory - singular spectrum analysis - based model for electric load forecasting[J]. Electrical Engineering,2021,103(2):1 067 - 1 082.
- [10] 姜天华,邓冠龙,朱惠琦. 离散猫群优化算法求解带交货期的 FJSP 问题[J]. 控制与决策,2020,35(1):161 - 168.
- [11] 张娜,赵泽丹,包晓安,等. 基于改进的 Tent 混沌万有引力搜索算法[J]. 控制与决策,2020,35(4):893 - 900.
- [12] WU Y K,TAN H C,QIN L Q,et al. A hybrid deep learning based traffic flow prediction method and its understanding[J]. Transportation Research Part C:Emerging Technologies,2018,90:166 - 180.

- [13] LIU Q C, WANG B C, ZHU Y Q. Short-term traffic speed forecasting based on attention convolutional neural network for arterials[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(11): 999-1016.
- [14] VLAHOIANNI E I, KARLAFTIS M G, GOLIAS J C. Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach[J]. Transportation Research Part C: Emerging Technologies, 2005, 13(3): 211-234.
- [15] CHAN K Y, DILLON T S, SINGH J, et al. Neural-network-based models for short-term traffic flow forecasting using a hybrid exponential smoothing and Levenberg-Marquardt algorithm[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 13(2): 644-654.
- [16] GHADAMI A, EPUREANU B I. Forecasting the onset of traffic congestions on circular roads[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22(2): 1196-1205.
- [17] PENG H, WANG H F, DU B W, et al. Spatial temporal incidence dynamic graph neural networks for traffic flow forecasting[J]. Information Sciences, 2020, 521: 277-290.
- [18] 李松, 刘力军, 翟曼. 改进粒子群算法优化 BP 神经网络的短时交通流预测[J]. 系统工程理论与实践, 2012, 32(9): 2045-2049.
- [19] 寇飞. 自适应人工鱼群算法 BP 循环神经网络短时交通流预测研究[D]. 北京: 北京交通大学, 2018: 38-41.
- [20] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems and Control Engineering, 2020, 8(1): 22-34.
- [21] JANG Y, SULLIVAN B, LUDWIG C, et al. EPIC-Tent: An Egocentric Video Dataset for Camping Tent Assembly [C]//ICCV Workshops, 2019: 4461-4469.
- [22] 单梁, 强浩, 李军, 等. 基于 Tent 映射的混沌优化算法[J]. 控制与决策, 2005, 20(2): 179-182.

Optimizing Neural Network Based on Chaotic Sparrow for Traffic Flow Forecasting

WANG Jingyue^{1,2}, LOU Jungang^{1,2}

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China;
2. Zhejiang Province Key Laboratory of Smart Management & Application
of Modern Agricultural Resources, Huzhou 313000, China)

Abstract: The swarm optimization neural network model can approximate various complex functions with arbitrary accuracy, and has been well applied in various nonlinear prediction problems including traffic flow prediction. In view of its strong local optimization ability and fast convergence speed, the sparrow algorithm is used to optimize the parameters of the adaptive neural network traffic flow prediction model; chaotic mapping is introduced in the sparrow algorithm to increase the uniformity and randomness of the search traversal, thereby optimizing the overall situation. Optimal performance. Experimental results on multiple actual traffic flow data sets show that the method proposed in this paper improves the average prediction accuracy by 0.52%~4.01% compared with the commonly used swarm intelligence optimization neural network method.

Keywords: intelligent transportation system; sparrow algorithm; tent mapping; parameter optimization; traffic flow forecasting

[责任编辑 高俊娥]