

改进麻雀搜索算法优化 BP 神经网络的短时交通流预测

王 坤, 李昕光*, 詹 郡, 吕 桐

(青岛理工大学 机械与汽车工程学院, 青岛 266525)

摘 要:针对 BP 神经网络预测短时交通流量过于依赖初始参数的问题, 提出一种基于改进麻雀搜索算法 (ISSA) 来优化 BP 神经网络的短时交通流预测模型 (ISSA-BP)。针对标准麻雀搜索算法 (SSA) 易收敛于原点, 容易陷入局部最优等问题, 对麻雀群体中的发现者和部分加入者的位置更新公式分别进行改进, 改进后的发现者将基于搜索维度的大小和当前最优值的位置来进行全局搜索, 部分加入者将根据其与最优位置之间的距离来进行全局搜索。通过实验对 BP, PSO-BP, SSA-BP, ISSA-BP 4 种短时交通流预测模型的预测效果进行对比分析, 结果显示, ISSA-BP 短时交通流预测模型的误差最小, ISSA-BP 模型相较 BP 模型在 MAE 评价指标上的预测精度提升了 48.85%, 有着更好的预测精度。

关键词:短时交通流预测; 算法优化; 改进麻雀搜索算法; BP 神经网络; 基准测试函数

中图分类号: U491.1⁺4 **文献标志码:** A **文章编号:** 1673-4602(2024)01-0126-08

The Improvement of sparrow search algorithm and the optimization of BP neural network for short term traffic flow prediction

WANG Shen, LI Xinguang*, ZHAN Jun, LÜ Tong

(School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: The short-term traffic flow prediction by BP neural network is too dependent on the initial parameters. In order to solve this problem and optimize the BP neural network, a short-term traffic flow prediction model (ISSA-BP) is proposed based on the improved sparrow search algorithm (ISSA). Since the standard sparrow search algorithm (SSA) is easy to converge at the origin and fall into local optimum, the position update formulas of the discoverers and of some joiners in the sparrow group are improved respectively. The improved discoverers will perform a global search based on the size of the search dimension and the position of the current optimal value, and some joiners will perform a global search according to the distance between the optimal position and themselves. The prediction effects of four short-term traffic flow prediction models, BP, PSO-BP, SSA-BP and ISSA-BP, are compared and analyzed through experiments. The results show that the error of ISSA-BP short-term traffic flow prediction model is the smallest, and the prediction accuracy of ISSA-BP model is much better, 48.85% higher than that of BP model in terms of MAE evaluation indicators.

收稿日期: 2022-10-06

基金项目: 山东省自然科学基金面上项目 (ZR2020MG017); 青岛市哲学社会科学规划项目 (QDSKL2101167)

作者简介: 王 坤 (1998-), 男, 河南焦作人。硕士, 研究方向为智能交通。E-mail: wxs7536@126.com。

* 通信作者: 李昕光 (1978-), 女, 山东茌平人。博士, 副教授, 主要从事智能交通与低碳交通研究。E-mail: tutulxg@126.com。

Key words: short-term traffic flow prediction; algorithm optimization; improved sparrow search algorithm; BP neural network; benchmark function

在城市不可能无限增加车道的情况下,交通控制和交通诱导成为缓解交通拥堵的最好方法。良好的交通控制和交通诱导需要精准的短时交通流预测作为支撑^[1]。由于交通流的不确定性和突发性,传统的线性模型不能对交通流进行很好地预测。BP 神经网络通过其较强的输入到输出的映射功能、自学习和自适应能力,可以对具有非线性变化的交通流进行很好地预测。但传统 BP 神经网络的预测结果对初始参数的选取具有极高的依赖性,不当的初始参数选取会导致程序陷入局部最优或收敛过慢^[2-4]。

近年来,各种群智能优化算法凭借搜索能力强、收敛速度快、结果不依赖初始参数选取等特点,在神经网络的优化上得到广泛应用。例如通过粒子群算法来优化 BP 神经网络模型,从而提高 BP 神经网络短时交通流预测模型的预测精度^[5-7]。但粒子群算法收敛速度慢,寻优能力较弱。2020 年提出的麻雀搜索算法(Sparrow Search Algorithm,SSA)相较于粒子群算法,具有参数少,结构简单,收敛快等特点,获得了较广泛应用。李雅丽等^[8]针对最近几年来较为典型的几个群智能算法,利用 22 个测试函数,从算法的精度、收敛速度和预测结果的稳定性等方面对算法进行了对比,对比结果显示麻雀搜索算法的性能远超其他算法;刘丽娜等^[9]用改进麻雀搜索算法来求解作业车间调度问题,获得了更好的最小值、平均值和寻优成功率;ZHANG 等^[10]用改进麻雀搜索算法设计了移动机器人的仿生路径规划;JIANG 等^[11]利用改进麻雀搜索算法来解决现有算法求解飞行器轨迹优化问题时收敛精度低、易陷入局部优化的问题。

本文提出一种基于改进麻雀搜索算法(Improving Sparrow Search Algorithm,ISSA)优化 BP 神经网络的短时交通流预测模型(ISSA-BP),针对标准麻雀搜索算法易收敛于原点的问题,对标准麻雀搜索算法中发现者和加入者的位置更新公式进行部分改进,改善标准麻雀搜索算法的全局探索能力,降低计算复杂度。利用改进麻雀搜索算法优化 BP 神经网络的权值,使 BP 神经网络预测模型的收敛速度更快,精度更高。

1 改进麻雀搜索算法

麻雀搜索算法和粒子群算法都是根据鸟类的种群觅食行为提出的。2020 年提出的新型的麻雀搜索算法不仅考虑到了鸟类的觅食行为,还考虑到了针对捕食者的反捕食和种群中鸟类之间的夺食行为^[12],同其他智能群体优化算法相比较,麻雀搜索算法的初始参数更少,收敛速度更快^[13]。

1.1 标准麻雀搜索算法

在 SSA 中,假设有 N 只麻雀在 D 维搜索空间中觅食,则将第 i 只麻雀在搜索空间中的位置坐标设置为 $X_i = [x_{i1}, x_{i2}, \dots, x_{id}]$, x_{id} 表示第 i 只麻雀在 d 维度中位置的。 D 维空间中每一只麻雀的位置都是目标函数的一个解,将麻雀在空间中的位置代入目标函数会得到解的值,按照解的大小对麻雀种群进行排序,排序靠前的麻雀作为发现者,将优先获取食物,并为加入者提供觅食方向。发现者的位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp[-i/(\alpha \cdot T_m)] & \text{if } R_2 < S \\ X_{i,j}^t + Q \cdot \mathbf{O} & \text{if } R_2 \geq S \end{cases} \quad (1)$$

式中: $X_{i,j}^t$ 为第 i 只麻雀在第 t 次迭代时在第 j 维度上的坐标; α 为取值范围 $[0, 1]$ 的随机数; T_m 为常数,表示最大循环次数; R_2 为取值范围 $[0, 1]$ 的随机数,表示警戒值; S 为取值范围 $[0.5, 1]$ 的随机数,表示安全阈值; Q 为服从正态分布的随机数; \mathbf{O} 为元素均为 1 的矩阵,矩阵形状为 $1 \times d$ 。

在式(1)中,当 $R_2 < S$ 时,表示麻雀种群没有发现捕食者,麻雀种群进行正常的觅食行为;当 $R_2 \geq S$,表示麻雀种群发现周围存在捕食者,所有麻雀停止觅食,进行反捕食行为,并飞往其他地方进行觅食。排序靠后的麻雀作为加入者,加入者中靠前的部分会依靠发现者提供的方向进行觅食,加入者中靠后的部分会因为获取不到食物而选择向更远的地方觅食,加入者的位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp[(X_w^t - X_{i,j}^t)/i^2] & \text{if } i > v/2 \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t-1}| \cdot \mathbf{A}^+ \cdot \mathbf{O} & \text{if } i \leq v/2 \end{cases} \quad (2)$$

式中: X_p^{t+1} 为第 $t+1$ 次迭代的全局最优位置; X_w^t 表示第 t 次迭代的全局最差的位置; A^+ 是矩阵, 由 A 矩阵计算得来, 计算公式为 $A^+ = A^T(AA^T)^{-1}$, 其中矩阵 A 的形状为 $1 \times d$ 。当 $i > v/2$ 时 (v 为麻雀编号), 表示这部分加入者的位置较差, 无法获得发现者标记的食物, 从而选择向更远的地方觅食; 其余位置较好的加入者则快速飞向最优位置附近觅食。

在麻雀种群中约有 10%~20% 的麻雀负责警戒, 这些麻雀会根据自己的判断来确定是否有危险, 这部分警戒麻雀的位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_b^t + \beta \cdot |X_{i,j}^t - X_b^t| & \text{if } f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_w^t|}{(f_i - f_w) + \epsilon} \right) & \text{if } f_i = f_g \end{cases} \quad (3)$$

式中: X_b^t 为全局最优位置; β 服从以 0 为均值, 1 为方差的正态分布, 用来控制步长; K 为取值范围 $[-1, 1]$ 的随机数; f_i 为当前麻雀个体所代表解的值; f_g 为当前全局最优解的值; f_w 为当前全局最差解的值; ϵ 是为了避免运算错误而设置的不影响计算的很小的常数。

在式(3)中, 当 $f_i > f_g$ 时, 表示该麻雀不在种群中心, 需要往中心靠拢; 当 $f_i = f_g$ 时, 表示种群中心的麻雀需要向其他麻雀靠拢。

1.2 麻雀搜索算法的缺陷

在式(1)中, 当 $R_2 < S$ 时, $\exp[-i/(\alpha \cdot T_m)]$ 指数函数由于指数为负数所以取值范围为 $(0, 1)$, 且当 i 的值靠近 1 时, 函数值的分布靠近 1 且不超过 1。随着 i 逐渐增大, 函数的取值范围会逐渐缩小, 但函数值的分布也逐渐均匀。当 $i = 1000$ 时, 函数值的分布范围约为 $(0, 0.4)$, 构建 $f(x) = \exp[-x/(\alpha \cdot T_m)]$ 函数并将结果制作为散点图, 散点分布图如图 1 所示。由于在公式(1)中, 当 $R_2 < S$ 时, $X_{i,j}^{t+1}$ 只能在 $(0, X_{i,j}^t)$ 取值, 所以随着迭代的增加, $X_{i,j}^{t+1}$ 会逐渐向原点收敛。在公式(2)中, 当 $i > v/2$ 时, 由于 i^2 是个较大的值, 故指数函数的值会聚集在 1 附近, 又因为 Q 是一个服从正态分布的随机数, 所以 $X_{i,j}^{t+1}$ 的取值会随着迭代逐渐向原点收敛。




图 1 迭代散点分布

利用 3 个测试函数对原算法的缺陷进行验证。对带入 3 个测试函数的原算法选择相同的参数: 维度为 2、麻雀数为 10、循环次数为 100、测试次数为 50。具体测试函数和测试结果的平均值如表 1 所示。

表 1 测试函数参数和测试结果

测试函数	搜索空间	函数最小值	平均值
$f(x) = x^2 + y^2$	$[-100, 100]$	0	$3.273\ 70 \times 10^{-6}$
$f(x) = (x - 25)^2 + (y - 25)^2$	$[-75, 125]$	0	0.065 057 3
$f(x) = (x - 50)^2 + (y - 50)^2$	$[-50, 150]$	0	0.132 344

由表 1 可知, 随着最优值的位置距离原点越远, 测试结果的平均值越大, 因此标准的 SSA 算法对于最优解越靠近原点的函数, 寻优的效果越好。但 BP 神经网络的最优值所对应的权值和阈值未必靠近原点, 所以需要对标准 SSA 算法进行改进。

1.3 麻雀搜索算法的改进

保留标准麻雀搜索算法的收敛和反捕食公式不变, 对易收敛于原点的位置更新公式进行部分改进。受粒子群算法^[14-15]中粒子会根据最优粒子的位置和自身最优位置进行搜索这一行为的启发, 将位置更新

公式分别改为以自身为中心的搜索模式和以全局最优位置为中心的搜索模式,在增加搜索多样性的同时避免麻雀在探索过程中向原点收敛,同时也降低了计算的复杂度,提高程序的运行效率。因此,改进式(1)中当 $R_2 < S$ 时的位置更新公式和式(2)中当 $i > v/2$ 时的位置更新公式,改进后的 2 个位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + \left(a \cdot L \cdot r \cdot \frac{i}{P_m}\right) \cdot \mathbf{A} & \text{if } R_2 < S \\ X_{i,j}^t + \mathbf{Q} \cdot \mathbf{O} & \text{if } R_2 \geq S \end{cases} \quad (4)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + \mathbf{Q} \times (X_{i,j}^t - X_b^t) & \text{if } i > v/2 \\ X_P^{t+1} + |X_{i,j}^t - X_P^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{O} & \text{if } i \leq v/2 \end{cases} \quad (5)$$

式中: L 为搜索空间的长度; r 为随机数,取值范围为 $[-1, 1]$; P_m 为常数,表示发现者的数量; a 为搜索因子。

a 的值从 0.2 非线性缩减至约 0.03,其计算公式为

$$a = 0.2 - 0.1 \times [\exp(t/T_m) - 1] \quad (6)$$

式(6)中利用以自然数为底数的指数函数在 $[0, 1]$ 的取值范围内的函数值先缓慢增加后快速增加的特点,令搜索因子 a 在迭代初期能以较大的值缓慢缩小,提高发现者在自身附近的搜索范围;迭代后期搜索因子 a 的值以较快的速度缩小为较小值,提高自身的收敛速度。

以式(4)中的粒子搜索范围构建 $f(x) = a \times L \times r \times (x/P_m)$ 函数并将结果制作作为散点图,其中, $a = 0.2, L = 200, P_m = 30$ 。表示为迭代初期按适应度值排序的麻雀个体的搜索范围。将所构建函数的计算结果制作作为散点图,散点分布图如图 2 所示。

从图 2 中可以看出种群中的麻雀个体随着适应度的逐渐降低搜索范围会逐渐变大。迭代后期的散点由于 a 的缩小更加收敛,变化幅度将会更小。使得麻雀种群前期有较大的搜索空间,后期有较快的收敛速度。

为了使算法在迭代前期具有较高的全局搜索范围,迭代后期具有较快的局部收敛速度,令跟随发现者觅食与不跟随发现者觅食的加入者的比例系数随迭代次数指数衰减,计算公式为

$$H = b + b \cdot c^t \quad (7)$$

式中: H 为加入者中不随发现者觅食的比例系数; b 为常数,取值为 0.35; c^t 为衰减因子,根据最大迭代次数和所需衰减到的大小进行设置,取值为 0.999。




图 2 麻雀散点分布

2 改进算法的测试

2.1 测试函数

为测试改进麻雀搜索算法的性能,选取 4 个国际通用的基准测试函数($f_1 \sim f_4$)^[16]对 ISSA 进行仿真测试,同时对这 4 个测试函数的最优值位置进行偏移从而衍生出($f_5 \sim f_8$)4 个偏移函数,其中 f_1, f_5 仅有 1 个极值,其余函数均有多个极值。8 个测试函数的参数值如表 2 所示。

2.2 算法测试

利用上述 8 个测试函数对 ISSA, SSA 和 PSO 进行测试,为保证算法的公平性及准确性,给 3 种算法设置相同的参数。种群中的个体数均为 30,搜索空间的维度均为 30,最大迭代次数均为 1000,每个函数独立运行 50 次,分别记录每次测试的最优值位置与实际最优值位置之间距离的标准差,计算公式为

表 2 8 个测试函数的参数值

函数名	函数表达式	维度	搜索区间	最小值及坐标
Sphere	$f_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	$f(x_1, \dots, x_n) = f(0, \dots, 0) = 0$
Griewank	$f_2(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-100, 100]$	$f(x_1, \dots, x_n) = f(0, \dots, 0) = 0$
Rastrigin	$f_3(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi \cdot x_i) + 10]$	30	$[-100, 100]$	$f(x_1, \dots, x_n) = f(0, \dots, 0) = 0$
Ackley	$f_4(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi \cdot x_i)\right] + 22.71282$	30	$[-100, 100]$	$f(x_1, \dots, x_n) = f(0, \dots, 0) = 0$
Sphere (偏移)	$f_5(x) = \sum_{i=1}^n (x_i - 50)^2$	30	$[-50, 150]$	$f(x_1, \dots, x_n) = f(50, \dots, 50) = 0$
Griewank (偏移)	$f_6(x) = \frac{1}{4000} \sum_{i=1}^n (x_i - 50)^2 - \prod_{i=1}^n \cos\left[\frac{(x_i - 50)^2}{\sqrt{i}}\right] + 1$	30	$[-50, 150]$	$f(x_1, \dots, x_n) = f(50, \dots, 50) = 0$
Rastrigin (偏移)	$f_7(x) = \sum_{i=1}^n [(x_i - 50)^2 - 10\cos[2\pi \cdot (x_i - 50)]] + 10$	30	$[-50, 150]$	$f(x_1, \dots, x_n) = f(50, \dots, 50) = 0$
Ackley (偏移)	$f_8(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - 50)^2}\right) - \exp\left\{\frac{1}{n} \sum_{i=1}^n \cos[2\pi \cdot (x_i - 50)]\right\} + 22.71282$	30	$[-50, 150]$	$f(x_1, \dots, x_n) = f(50, \dots, 50) = 0$

$$f(x) = \frac{1}{z} \sum_{i=1}^z |x_i - \hat{x}_i| \tag{8}$$

式中： z 为运行次数； i 为第 i 次运行； x_i 为第 i 次运行的最优值位置； \hat{x}_i 为实际最优值位置。

计算 3 种算法在 8 种测试函数中的最优值位置与实际最优值之间距离的平均值和标准差，用以比较算法的搜索精度和稳定性。PSO, SSA, ISSA 算法对 8 个测试函数的测试结果(小数点后保留 2 位有效数字)如表 3 所示。

表 3 不同模型对于 8 个测试函数的误差

函数	PSO		SSA		ISSA	
	均值	标准差	均值	标准差	均值	标准差
f_1	697.17	685.38	0.09	0.36	1.91	6.12
f_2	759.24	694.21	0.30	0.26	22.69	135.46
f_3	676.21	610.59	0.21	0.40	11.66	17.57
f_4	8614.86	2630.71	0.24	1.17	1396.01	1283.23
f_5	832.66	738.42	6.39	2.27	0.75	0.91
f_6	1043.85	900.14	248.81	745.58	3.24	2.07
f_7	797.68	735.68	136.68	481.40	7.88	3.10
f_8	9200.61	2065.94	2213.04	745.48	1485.96	962.22

由表 3 可知,SSA 和 ISSA 在 8 个函数上的寻优效果均好于 PSO 算法;SSA 算法在 $f_1 \sim f_4$ 函数(函数最优解在每个维度上均为 0)寻优好于 ISSA,这是由于 SSA 算法会收敛于原点;在 $f_5 \sim f_8$ 函数(函数最优解在每个维度上的值均为 50)上 ISSA 寻优效果好于 SSA,并且 ISSA 在 (f_1, f_5) 、 (f_2, f_6) 、 $(f_3,$

f_7)、 (f_4, f_8) 这 4 组对比函数上寻优效果接近,而 SSA 在这 4 组对比函数上的寻优效果相差很大,所以 ISSA 相比较于 SSA 算法有着更好的普遍适应性,更适合用于解决实际问题。

3 短时交通流模型构建与实验测试

3.1 构建模型

针对 BP 神经网络在非线性预测中的优缺点,用改进麻雀搜索算法的最优解作为 BP 神经网络的初始权值,结合交通流特性构建基于改进麻雀搜索算法优化 BP 神经网络(ISSA-BP)的短时交通流预测模型。

1) 利用 python 语言和 Tensorflow 深度学习框架设计神经网络层数,确定输入层、隐藏层以及输出层的节点个数和每层的激活函数,搭建 BP 神经网络模型。

2) 搭建改进麻雀搜索算法模型,确定麻雀种群的适度值函数。用第 1)步中构建的 BP 神经网络期望值与预测值之差的绝对值之和作为麻雀的适度值函数来构建 ISSA 算法模型。

3) 通过迭代来寻找到最优适度值。输出其所对应的位置作为最优解,将输出的最优解作为 BP 神经网络的权值和阈值。将 BP 神经网络代入训练集进行训练,当训练精度达到要求或达到最大迭代次数后,输入测试集,并输出最终测试结果与真实值之间的误差。

3.2 模型评价

为了对短时交通流预测模型的精度进行判定,采用平均绝对百分误差(MAPE)、平均绝对值误差(MAE)和均方误差(MSE)进行误差分析^[17-19],公式如下:

$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100\% \quad (9)$$

$$E_{MAE} = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (10)$$

$$E_{MSE} = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (11)$$

式中: E_{MAPE} 、 E_{MAE} 、 E_{MSE} 分别为平均绝对百分误差值、平均绝对值误差值、均方误差值。

3.3 实验测试

模型的输入为 3,输出为 1。BP 神经网络以及 PSO-BP,SSA-BP,ISSA-BP 模型的 BP 神经网络部分采用相同的网络结构,模型的输入层输入节点个数为 3;隐藏层为 2 层,每层的节点个数均为 10;输出层的节点个数为 1;激活函数采用 Sigmoid 函数。

为了评价 ISSA-BP 模型的性能,采用西安市区某道路断面 18 d 交通流量数据^[20]进行实验测试。该道路断面的交通流量数据以 15 min 为间隔,从 7:30 开始到 11:30 截止,每天 16 组数据,共 288 组数据。首先对数据进行预处理,删除数据集中的异常值并利用牛顿插值公式进行填充。数据集中的交通流数据只有每天的 16 个数据为连续数据,每天 16 个交通流数据除去作为特征输入的 3 个数据,每天可制作 13 组训练数据。为了使模型达到充分训练,将前 17 d 的数据制作为训练集,共 221 组训练数据;最后一天的数据制作为测试集,共 13 组测试数据。将训练集和测试集数据分别输入 BP,PSO-BP,SSA-BP,ISSA-BP 神经网络模型进行短时交通流的预测,比较各个模型的预测输出。4 种短时交通流预测模型的真实值曲线和预测值曲线如图 3—图 6 所示。

从图 3—图 6 中可以看出,ISSA-BP 模型相较于其他 3 个模型的预测值曲线更贴合真实值曲线。基于 BP 和 SSA-BP 的短时交通流预测结果前半部分小于真实值,后半部分大于真实值,二者的预测结果均不能很好地表现出交通流的变化趋势;基于 PSO-BP 和 ISSA-BP 的短时交通流预测结果在真实值上下波动,二者的预测结果均能较好地表现出交通流的变化趋势,但基于 PSO-BP 的预测值曲线与真实值曲线之间的差值波动较大,预测的交通流量与真实值之间的误差较大;基于 ISSA-BP 模型的预测值曲线相较于 PSO-BP 的预测值曲线更贴合真实值曲线,能够更好地满足交通流变化的预测。

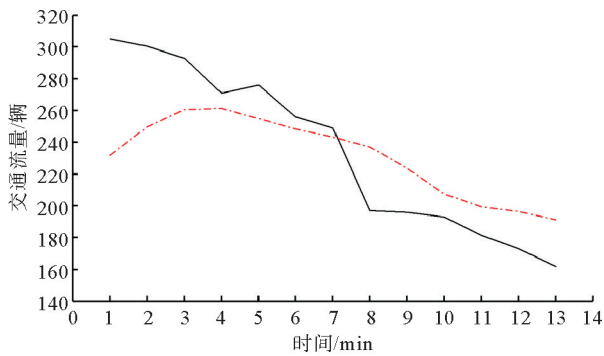


图3 BP交通流预测
— 真实值; - - - 预测值

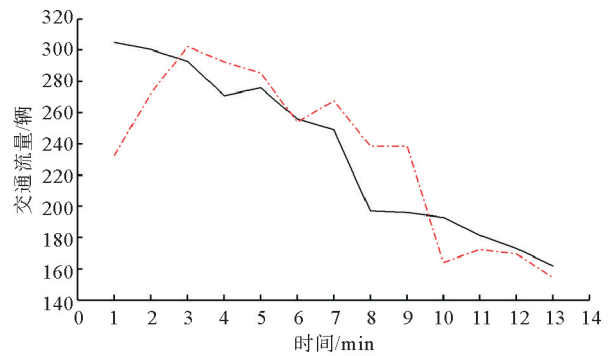


图4 PSO-BP交通流预测
— 真实值; - - - 预测值




图5 SSA-BP交通流预测
— 真实值; - - - 预测值

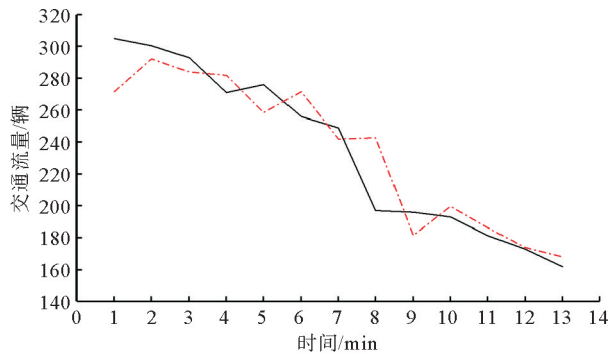


图6 ISSA-BP交通流预测
— 真实值; - - - 预测值

为更科学直观地判断4种交通流预测模型的预测效果,利用3.2部分所选择的3种误差评价指标对4种模型的交通流量预测结果进行对比分析,对比结果如表4所示。由表4可知,基于ISSA-BP的短时交通流预测模型相较于其他3个预测模型,其预测结果在3种误差分析中均表现最好。从MAPE评价指标的对比结果来看,ISSA-BP模型的预测精度比BP模型高49.17%,比PSO-BP模型高38.47%,比SSA-BP神经网络模型高40.64%;从MAE评价指标的对比结果来看,ISSA-BP模型的预测精度比BP模型高48.85%,比PSO-BP模型高38.71%,比SSA-BP神经网络模型高40.99%;从MSE评价指标的对比结果来看,ISSA-BP模型的预测精度比BP模型高68.34%,比PSO-BP模型高61.84%,比SSA-BP神经网络模型高63.36%。说明ISSA-BP在短时交通流预测方面具有更好的预测精度。

表4 4种预测模型的误差

误差评价指标	BP	PSO-BP	SSA-BP	ISSA-BP
MAPE	11.68	9.64	10.00	5.93
MAE	27.15	22.66	23.53	13.89
MSE	1068.43	886.39	923.00	338.23

4 结论

针对标准麻雀搜索算法易收敛于原点和局部最优值的缺陷,对麻雀群体中的发现者和部分加入者的位置更新公式进行改进,使其不再轻易收敛于原点,并增强麻雀种群前期的全局搜索能力使其不易陷入局部最优。应用4个国际通用的基准测试函数和4个偏移测试函数对ISSA的性能进行了验证,结果显示ISSA在8个测试函数上的表现均优于PSO,在最优值不在原点的偏移测试函数上的表现优于SSA。ISSA比PSO的测试表现更好,比SSA拥有更好的普遍适应性。用改进的麻雀搜索算法得到的最优解作为

BP 神经网络的初始权值,构建了 ISSA-BP 短时交通流预测模型。通过实验测试对 SSA 模型、PSO 模型和 BP 神经网络模型进行了对比分析,结果显示 ISSA-BP 模型的误差最小,预测精度最高。下一步考虑应用该算法对多种因素以及特殊因素影响下的短时交通流量进行预测。

参考文献(References):

- [1] 杨文,贾学锋,马清. 基于周期相似性和 LSSVM 的交通流量多步预测[J]. 青岛理工大学学报,2013,34(2):86-91.
YANG Wen, JIA Xuefeng, MA Qing. Multi-step prediction of traffic flow based on cycle similarity and least squares support vector machines[J]. Journal of Qingdao Technological University, 2013, 34(2): 86-91.
- [2] 曹洁,沈钧珥,张红,等. 基于小波和多维重构的 BP 神经网络交通流短时预测[J]. 计算机应用与软件,2018,35(12):61-65.
CAO Jie, SHEN Juner, ZHANG Hong, et al. Short-term traffic flow forecasting based on BP neural network with wavelet and multidimensional reconstruction[J]. Computer Applications and Software, 2018, 35(12): 61-65.
- [3] 孔繁辉,李健. 深度信念网络优化 BP 神经网络的交通流预测模型[J]. 管理评论,2020,32(3):300-306.
KONG Fanhui, LI Jian. Traffic flow prediction model based on deep belief network optimized BP neural network[J]. Management Review, 2020, 32(3): 300-306.
- [4] 曾庆山,全书鹏,靳志强. 融合 BP 神经网络与 ARIMA 的短时交通流预测[J]. 郑州大学学报(工学版),2011,32(4):60-63.
ZENG Qingshan, QUAN Shupeng, JIN Zhiqiang. Short-term traffic flow's forecasting by fusing BP neural network and ARIMA[J]. Journal of Zhengzhou University(Engineering Science), 2011, 32(4): 60-63.
- [5] 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.
LI Song, LIU Lijun, ZHAI Man. Prediction for short-term traffic flow based on modified PSO optimized BP neural network[J]. Systems Engineering-Theory & Practice, 2012, 32(9): 2045-2049.
- [6] 马秋芳. 改进 PSO 优化的 BP 神经网络短时交通流预测[J]. 计算机仿真,2019,36(4):94-98.
MA Qiufang. BP neural network short-term traffic flow prediction based on improved particle swarm optimization[J]. Computer Simulation, 2019, 36(4): 94-98.
- [7] 张军,王远强,朱新山. 改进 PSO 优化神经网络的短时交通流预测[J]. 计算机工程与应用,2017,53(14):227-231.
ZHANG Jun, WANG Yuanqiang, ZHU Xinshan. Short-term prediction of traffic flow based on neural network optimized improved particle swarm optimization[J]. Computer Engineering and Applications, 2017, 53(14): 227-231.
- [8] 李雅丽,王淑琴,陈倩茹,等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用,2020,56(22):1-12.
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms[J]. Computer Engineering and Applications, 2020, 56(22): 1-12.
- [9] 刘丽娜,南新元,石跃飞. 改进麻雀搜索算法求解作业车间调度问题[J]. 计算机应用研究,2021,38(12):3634-3639.
LIU Lina, NAN Xinyuan, SHI Yuefei. Improved sparrow search algorithm for solving Job-Shop scheduling problem[J]. Application Research of Computers, 2021, 38(12): 3634-3639.
- [10] ZHANG Z, HE R, YANG K. A bioinspired path planning approach for mobile robots based on improved sparrow search algorithm[J]. Advances in Manufacturing, 2021: 1-17.
- [11] JIANG Z, GE J, XU Q, et al. Fast trajectory optimization for gliding reentry vehicle based on improved sparrow search algorithm[J]. Journal of Physics: Conference Series, 2021, 1986(1): 012114.
- [12] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [13] 唐延强,李成海,宋亚飞,等. 自适应变异麻雀搜索优化算法[J]. 北京航空航天大学学报,2023,49(3):681-692.
TANG Yanqiang, LI Chenghai, SONG Yafei, et al. Adaptive mutation sparrow search optimization algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 681-692.
- [14] 沈永增,闫纪如,王伟. 基于混沌粒子群优化小波神经网络的短时交通流预测[J]. 计算机应用与软件,2014,31(6):84-86.
SHEN Yongzeng, YAN Jiru, WANG Wei. Short-time traffic flow forecasting based on WNN optimised by CPOS[J]. Computer Applications and Software, 2014, 31(6): 84-86.
- [15] 邴其春,龚勃文,林赐云,等. 基于粒子群优化投影寻踪回归模型的短时交通流预测[J]. 中南大学学报(自然科学版),2016,47(12):4277-4282.
BING Qichun, GONG Bowen, LIN Ciyun, et al. Short-term traffic flow prediction method based on particle swarm optimization projection pursuit regression model[J]. Journal of Central South University(Science and Technology), 2016, 47(12): 4277-4282.
- [16] SONG H M, SULAIMAN M H, MOHAMED M R. An application of grey wolf optimizer for solving combined economic emission dispatch problems[J]. International Review on Modelling and Simulations, 2014, 7(5): 838-844.