

# 基于改进灰狼算法优化BP神经网络的 短时交通流预测模型

张文胜<sup>1,2</sup>, 郝孜奇<sup>1</sup>, 朱冀军<sup>3</sup>, 杜甜添<sup>4</sup>, 郝会民<sup>5</sup>

(1. 石家庄铁道大学 交通运输学院, 石家庄 050043; 2. 河北省交通安全与控制重点实验室, 石家庄 050043; 3. 河北省交通规划设计院, 石家庄 050011; 4. 天津轨道交通运营集团有限公司, 天津 300222; 5. 石家庄市勘察测绘设计研究院, 石家庄 050011)

**摘要:** 准确的短时交通流预测是交通控制和交通诱导的依据. 提出一种基于改进灰狼算法(TGWO)优化BP神经网络的短时交通流预测模型(TGWO-BP), 有效提高短时交通流预测精度. 针对标准灰狼算法(GWO)收敛速度慢, 容易陷入局部极值的问题, 提出一种自适应递减的收敛因子, 使灰狼算法区分全局搜索和局部搜索; 改进灰狼个体的位置更新公式, 引入惯性权重, 调节惯性权重大小使灰狼算法具有跳出局部极值的能力; 对比分析TGWO-BP、GWO-BP、PSO-BP、BP这4种短时交通流预测模型, 结果显示, TGWO-BP的短时交通流预测模型误差为10.03%, 达到较好的预测精度.

**关键词:** 智能交通; 短时交通流预测; 改进灰狼算法(TGWO); BP神经网络; 收敛因子; 惯性权重

## BP Neural Network Model for Short-time Traffic Flow Forecasting Based on Transformed Grey Wolf Optimizer Algorithm

ZHANG Wen-sheng<sup>1,2</sup>, HAO Zi-qi<sup>1</sup>, ZHU Ji-jun<sup>3</sup>, DU Tian-tian<sup>4</sup>, HAO Hui-min<sup>5</sup>

(1. School of Traffic and Transportation, Shijiazhuang Tiedao University, Shijiazhuang 050043, China; 2. Traffic Safety and Control Laboratory of Hebei Province, Shijiazhuang 050043, China; 3. Hebei Provincial Communications Planning and Design Institute, Shijiazhuang 050011, China; 4. Tianjin Rail Transit Operation Group Co. Ltd, Tianjin 300222, China; 5. Shijiazhuang Transportation Management Office, Shijiazhuang 050011, China)

**Abstract:** Accurate short-time traffic flow forecasting is the basis of traffic control and traffic induction. In this paper, a short time traffic flow forecasting model (TGWO- BP) is proposed based on transformed grey wolf optimizer algorithm (TGWO) and BP neural network, which can effectively improve the accuracy of short-time traffic flow forecast. Firstly, due to the drawbacks that the standard gray wolf algorithm converges slowly and tends to fall into the local extremum, an adaptive decreasing convergence factor is proposed, so that the grey wolf algorithm can distinguish the global search from the local search. Secondly, the position renewal formula of the gray wolf individual is improved by introducing the inertial weight. By adjusting the size of the inertial weight, the grey wolf algorithm has the ability to jump out of the local extremum. Finally, four short-time traffic flow forecasting models of TGWO-BP, GWO-BP, PSO-BP and BP are constructed, and the results show that the error of

收稿日期: 2019-11-14

修回日期: 2019-12-19

录用日期: 2020-01-07

基金项目: 河北省科技计划重点项目/Science and Technology Plan Project of Hebei Province (18390324D); 石家庄市科技计划项目/ Science and Technology Project of Shijiazhuang(181130034A, 191260411A).

作者简介: 张文胜(1971-), 男, 宁夏隆德人, 教授, 博士.

\*通信作者: dtthy1219@163.com

the short-time traffic flow forecasting model of TGWO-BP is 10.03%, and the accuracy of the prediction is better.

**Keywords:** intelligent transportation; short-time traffic flow forecast; transformed grey wolf optimizer algorithm (TGWO); BP neural network; convergence factor; inertial weight

## 0 引言

准确、实时的短时交通流预测是交通控制及交通诱导的重要保障. 由于交通流变化趋势具有非线性和不确定性, 人工神经网络凭借其良好的非线性收敛能力, 可以更加准确学习短时交通流中的不确定性, 但神经网络存在收敛速度慢, 容易陷入局部极值的缺点. 为此, Fabio Moretti<sup>[1]</sup>等用统计方法优化人工神经网络, 提出了一种基于神经网络的混合模型对短时交通流进行预测, 预测结果较优, 但人工神经网络的阈值为确定值, 降低了预测精度. Chai Yanhong<sup>[2]</sup>等将小波分析和 BP (Back Propagation) 神经网络进行结合, 使用小波函数进行初始数据的去除噪声处理, 将处理后的数据用 BP 神经网络进行训练, 使用梯度下降法进行神经网络参数调整, 提高了预测结果的精度, 但降低了收敛速度. 近年来, 各种元启发式算法凭借其收敛速度快, 精度高的特点, 广泛应用于神经网络的优化. Mirjalili<sup>[3]</sup>提出一种新的元启发式算法——灰狼算法 (Grey Wolf Optimizer, GWO), 较其他元启发式算法具有调整参数少、便于理解、收敛速度快的优点, 但灰狼算法依然存在对多峰函数求解时收敛速度慢, 容易陷入局部最优解的缺点. 石峰等<sup>[4]</sup>利用灰狼算法对空气质量检验样本进行实时监控训练, 避免了神经网络过拟合现象的发生, 但该算法具有后期收敛速度慢的缺点. 傅蔚阳<sup>[5]</sup>等使灰狼个体移动方向满足反向学习策略, 改善了算法的寻优范围, 但降低了算法的收敛速度.

本文提出一种基于改进灰狼算法 (Transformed Grey Wolf Optimizer, TGWO) 优化 BP 神经网络 (TGWO-BP) 的短时交通流预测模型, 对标准灰狼算法中的收敛因子和位置更新公式进行改进, 改善标准灰狼算法的寻优能力和收敛特性. 利用改进灰狼算法对 BP 神经网络的权值和阈值进行寻优, 使 BP 神经网络的收敛速度更快, 精度更高.

## 1 改进的灰狼算法

### 1.1 灰狼算法

在灰狼群体中, 灰狼个体按照社会关系严格划分为  $\alpha$ 、 $\beta$ 、 $\delta$ 、 $\omega$  这 4 个等级, 如图 1 所示. 其中,  $\alpha$  狼为头狼,  $\beta$  狼为协助者,  $\delta$  狼服从  $\alpha$ 、 $\beta$  的命令, 并指挥没有自主决策能力的  $\omega$  狼. 在狩猎过程中, 灰狼在  $\alpha$  狼的带领下, 有组织地对猎物包围, 进而攻击<sup>[6]</sup>.

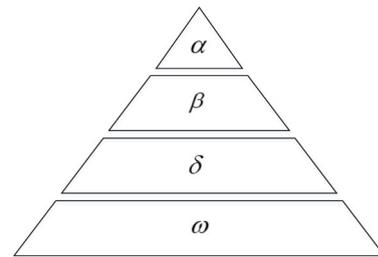


图 1 灰狼社会等级划分

Fig. 1 Grey wolf social hierarchy

在数学模型中, 每只灰狼个体代表种群中一个候选解, 将种群中的最优解称为  $\alpha$ , 次优解称为  $\beta$ , 第三优解称为  $\delta$ , 其余候选解统称为  $\omega$ . 灰狼算法的每次迭代, 将  $\alpha$ 、 $\beta$  和  $\delta$  作为前三优解, 判断猎物位置, 指挥  $\omega$  在猎物周围随机更新, 向猎物不断逼近.

假设灰狼种群规模为  $N$ , 搜索空间为  $D$  维, 第  $i$  只灰狼的位置为  $X_i = (X_i^{(1)}, X_i^{(2)}, \dots, X_i^{(D)})$ , 则狼群的行为公式如下.

(1) 包围行为.

灰狼在发现猎物后将其包围, 包围的公式为

$$D = |C \cdot X_p(t) - X(t)| \quad (1)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (2)$$

式中:  $D$  为灰狼个体和猎物之间的距离;  $t$  为当前迭代次数;  $X_p(t)$  为猎物在  $t$  次迭代的位置向量;  $X(t)$  为灰狼个体在  $t$  次迭代的位置向量;  $A$  和  $C$  为系数向量, 计算公式为

$$A = 2a(r_1 - 1) \quad (3)$$

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

式中:  $r_1, r_2$  为标量在  $[0, 1]$  之间的随机向量;  $a$  为

收敛因子,  $a$  的值从2线性递减至0, 计算公式为

$$a = 2 - 2 \cdot \frac{t}{t_{\max}} \quad (5)$$

式中:  $t_{\max}$  为最大迭代次数.

包围行为中, 改变  $A$  和  $C$  的值可实现灰狼对猎物的搜索, 通过  $r_1, r_2$  的随机设定, 灰狼可以搜索到猎物周围的  $n$  个方向<sup>[6]</sup>.  $|A|$  表示  $A$  值的大小, 由式(2)可知, 当  $|A| > 1$  时, 灰狼下一步迭代将从当前位置远离猎物, 即候选解趋向由猎物向外发散, 以进行全局搜索, 搜索其他潜在最优解; 当  $|A| < 1$  时, 灰狼个体的下一位置将处于当前位置和猎物之间, 即候选解趋向于向猎物集聚, 以进行局部搜索, 逼近最优解.

## (2) 捕猎行为.

灰狼将猎物包围后由头狼  $\alpha$  指导,  $\beta$  和  $\delta$  协助, 进行捕猎行为. 猎捕行为中, 灰狼由  $\alpha, \beta, \delta$  带领, 逐渐靠近猎物.  $\alpha, \beta, \delta$  的位置更新公式分别为

$$D_\alpha = |C_1 X_\alpha(t) - X(t)| \quad (6)$$

$$D_\beta = |C_2 X_\beta(t) - X(t)| \quad (7)$$

$$D_\delta = |C_3 X_\delta(t) - X(t)| \quad (8)$$

$$X_1(t+1) = X_\alpha(t) - A_1 D_\alpha \quad (9)$$

$$X_2(t+1) = X_\beta(t) - A_2 D_\beta \quad (10)$$

$$X_3(t+1) = X_\delta(t) - A_3 D_\delta \quad (11)$$

$$X(t+1) = \frac{X_1(t+1) + X_2(t+1) + X_3(t+1)}{3} \quad (12)$$

式中:  $A_1$  和  $C_1, A_2$  和  $C_2, A_3$  和  $C_3$  分别表示  $\alpha, \beta, \delta$  的系数向量;  $X_\alpha(t), X_\beta(t), X_\delta(t)$  分别表示  $\alpha, \beta, \delta$  相对猎物的位置向量;  $X_1(t+1), X_2(t+1), X_3(t+1)$  分别表示  $\alpha, \beta, \delta$  灰狼个体在  $(t+1)$  次迭代时的位置向量.

灰狼通过式(6)~式(12)不断调整猎捕方向和与猎物的距离, 多次迭代后, 捕获猎物. 此时头狼  $\alpha$  所在位置和适应度, 即为最优解.

灰狼算法的收敛因子是呈线性递减的. 在实际应用中: 函数在算法初期, 需要较大的搜索范围; 在迭代后期, 则需要较小的搜索范围, 使局部搜索更加精细. 线性递减的收敛因子不能满足灰狼算法的自适应搜索, 算法收敛速度较慢, 容易陷入局部极值. 标准灰狼算法中的步长更新公式假

定猎物位置不变, 而实际问题中, 猎物位置是在不断移动的, 固定的猎物位置导致算法资源浪费, 不容易收敛到极值.

## 1.2 灰狼算法的改进

分别将标准灰狼算法的收敛因子和步长更新公式进行改进, 改善灰狼算法收敛速度和搜索特性.

### (1) 自适应收敛因子.

标准灰狼算法开发能力依赖于  $A$  的取值,  $A$  的取值又依赖于收敛因子  $a$  的变化, 在标准灰狼算法中, Mirjalili<sup>[9]</sup>规定收敛因子由2线性递减至0. Sasmita<sup>[7]</sup>证明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. 在实际灰狼群体中, 前期搜索空间较大, 需要快速搜索; 后期距离猎物较近, 步长过大容易漏掉搜索空间, 过早地陷入局部最优解, 需要精细搜索.

依据 Sigmoid 函数前期下降快, 后期下降慢的特点, 提出一种基于 Sigmoid 函数的收敛因子计算公式.

$$a = a_{\max} - \left[ 1 + \exp\left(-\frac{t}{t_{\max}}\right) \right]^{-1} \quad (13)$$

式中:  $a_{\max}$  为收敛因子设定的最大值.

基于 Sigmoid 函数重新定义了收敛因子的变化率, 使收敛因子的值随迭代次数的增加, 呈非线性减小.  $a$  在迭代初期, 减小较快, 搜索范围较大, 在进行全局搜索时, 可以更迅速地发现多个潜在极值; 随着迭代次数的增加,  $a$  减小较慢, 在进行局部搜索时, 较小的步长可以防止算法漏掉函数的极值点.

### (2) 步长更新公式.

在粒子群优化算法<sup>[8]</sup> (Particle Swarm Optimization, PSO) 中, 采用经典的线性递减权重策略, 通过引入动态惯性因子  $\theta$ , 平衡了算法进行全局和局部搜索的能力.

$$\theta(t+1) = \theta_{\min} + \frac{(\theta_{\max} - \theta_{\min})(t_{\max} - t)}{t_{\max}} \quad (14)$$

式中:  $\theta$  为惯性权重;  $\theta_{\max}$  表示惯性权重的最大值, 一般取0.9;  $\theta_{\min}$  表示惯性权重的最小值, 一般取0.4.

受其启发, 本文提出一种基于惯性权重的灰狼位置更新公式, 赋予灰狼跳出局部极值的能力.

$$X(t+1) = \varphi X_p(t) - AD \quad (15)$$

$$\varphi(t+1) = \varphi_{\max} - (\varphi_{\max} - \varphi_{\min}) \cdot \frac{t}{t_{\max}} \quad (16)$$

式中:  $\varphi$  为惯性权重;  $\varphi_{\max}$  表示惯性权重的最大值, 一般取0.9;  $\varphi_{\min}$  表示惯性权重的最小值, 一般取0.4.

在新的步长更新公式中, 惯性权重是线性递减的. 当惯性权重设置较大时, 可以降低算法陷入局部极值的风险; 当惯性权重设置较小时, 可以提高算法的搜索精度, 减少不必要的迭代过程, 提高算法计算效率.

## 2 改进算法性能测试及仿真实验

### 2.1 测试函数

为测试改进灰狼算法的性能, 选取文献[9]中8个国际通用的标准测试函数对TGWO进行仿真测试, 8个测试函数如表1所示. 函数分为3类,  $f_1 \sim f_4$  为单峰函数,  $f_5 \sim f_7$  为多峰函数,  $f_8$  为固定维度多峰函数. 测试函数涵盖了多个类型, 测试结果具有指导作用.

表 1 8个测试函数表

Table 1 Eight test function tables

函数名	维数	函数表达式	搜索区间	最小值
Sphere	30	$f_1(x) = \sum_{i=1}^n x_i^2$	[-100, 100]	0
Schwefel2.22	30	$f_2(x) = \sum_{i=1}^n  x_i  + \prod_{i=1}^n  x_i $	[-10, 10]	0
Schwefel1.2	30	$f_3(x) = \sum_{i=1}^n \left( \sum_{j=1}^i x_j \right)^2$	[-100, 100]	0
Schwefel2.21	30	$f_4(x) = \max\{ x_i , 1 \leq x_i \leq n\}$	[-100, 100]	0
Rastrigin	30	$f_5(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	[-5.12, 5.12]	0
Griewank	30	$f_6(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	[-600, 600]	0
Ackley	30	$f_7 = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right] + 20 + e$	[-32, 32]	0
Hartman	3	$f_8 = \sum_{i=1}^4 c_i \exp\left[-\sum_{j=1}^3 a_{ij}(x_j - p_j)^2\right]$	[0, 1]	-3.86

### 2.2 改进灰狼算法TGWO与GWO和PSO算法的比较

利用本文提出的改进灰狼算法对上述8个测试函数进行求解, 与标准GWO、PSO进行比较. 为保证算法的公平性及准确性, 3种算法的参数取值

一致. 设种群规模为30, 最大迭代次数为500, 每个函数独立运行30次, 分别记录每次的最优值. 计算3种函数运行30次的最优解的平均值和标准差, 用以测试算法的搜索精度和稳定性. PSO、GWO、TGWO算法对8个基准函数的测试结果如表2所示.

表 2 3种算法对测试函数的寻优结果

Table 2 Optimization results of three algorithms on test functions

函数	PSO		GWO		TGWO	
	均值	标准差	均值	标准差	均值	标准差
$f_1$	$1.54 \times 10^{-4}$	$1.76 \times 10^{-4}$	$2.11 \times 10^{-27}$	$3.30 \times 10^{-27}$	<b><math>3.13 \times 10^{-76}</math></b>	<b><math>3.62 \times 10^{-76}</math></b>
$f_2$	$4.64 \times 10^{-2}$	$6.05 \times 10^{-2}$	$7.41 \times 10^{-17}$	$5.46 \times 10^{-17}$	<b><math>2.67 \times 10^{-41}</math></b>	<b><math>3.16 \times 10^{-41}</math></b>
$f_3$	1.13	6.12	$2.37 \times 10^{-5}$	$2.98 \times 10^{-5}$	<b><math>2.08 \times 10^{-39}</math></b>	<b><math>3.30 \times 10^{-39}</math></b>
$f_4$	1.01	0.22	$7.29 \times 10^{-7}$	$4.38 \times 10^{-7}$	<b><math>2.56 \times 10^{-29}</math></b>	<b><math>4.34 \times 10^{-29}</math></b>
$f_5$	64.09	21.46	3.72	3.18	<b>0</b>	<b>0</b>
$f_6$	0.37	0.53	$1.01 \times 10^{-13}$	$1.42 \times 10^{-14}$	<b><math>4.44 \times 10^{-15}</math></b>	<b>0</b>
$f_7$	$9.47 \times 10^{-3}$	$5.49 \times 10^{-3}$	$2.56 \times 10^{-3}$	$6.28 \times 10^{-3}$	<b>0</b>	<b>0</b>
$f_8$	-3.86	<b>0</b>	-3.86	$1.50 \times 10^{-3}$	<b>-3.86</b>	<b><math>8.61 \times 10^{-4}</math></b>

表2中,将8个函数在算法中的最优值用粗体标出,8个测试函数中TGWO都可以收敛到极值处(当收敛进度达到 $1 \times 10^{-10}$ 时认为算法收敛).与PSO对比可知,GWO和TGWO在收敛精度上有很大提高;与传统GWO相比,TGWO收敛结果更加准确.

表2中,只能观察到TGWO寻找到8个测试函数的最优值比GWO和PSO寻找到的最优值更加准确,不能准确分析TGWO的收敛速度.为了分析TGWO的收敛性,图2给出8种算法的收敛曲线对比图.

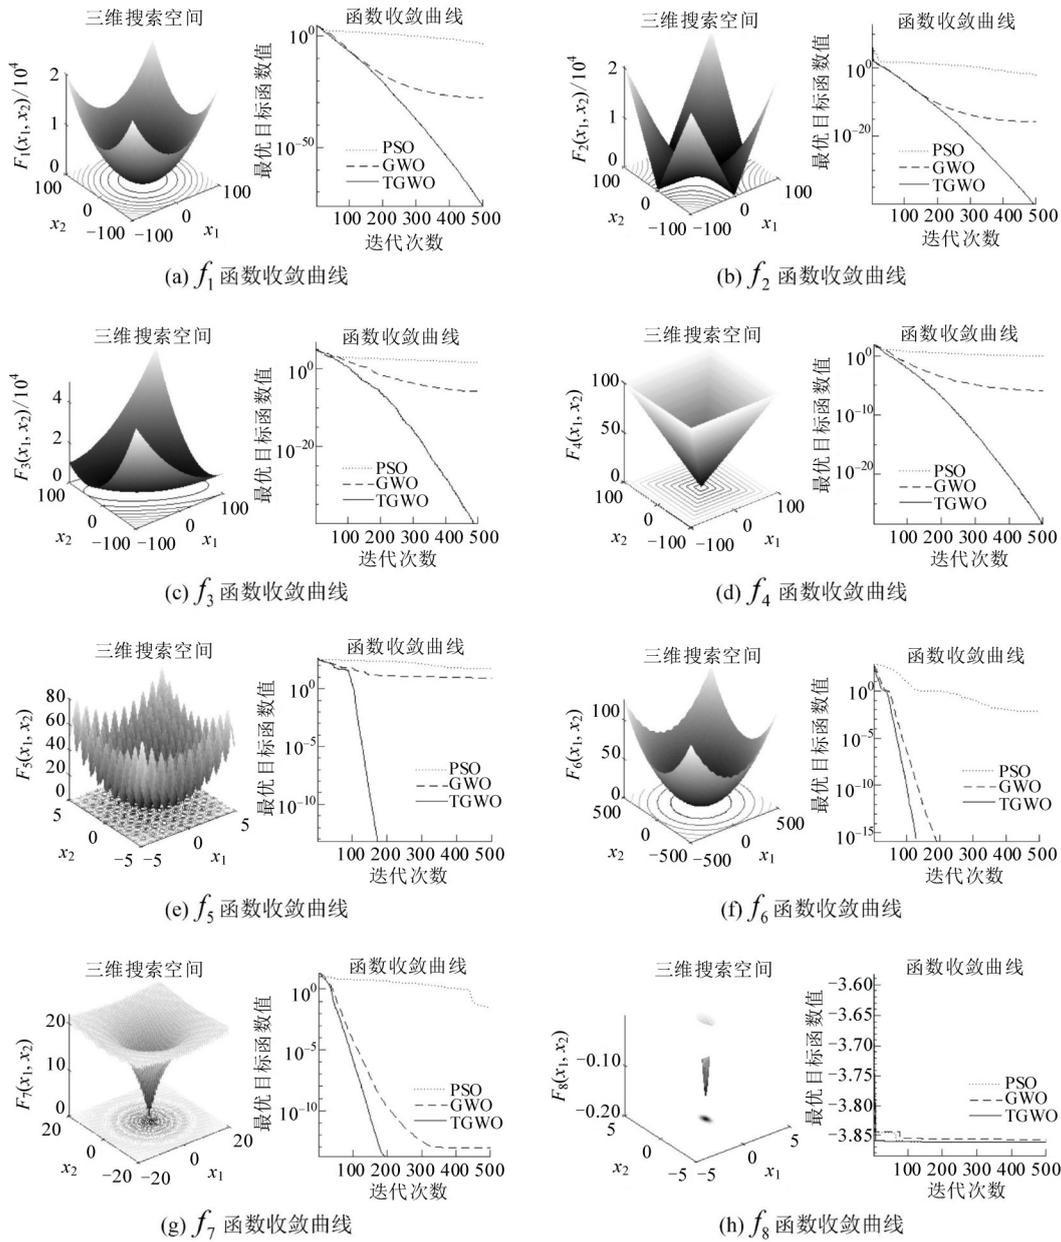


图2 8个测试函数的函数图和收敛曲线对比图

Fig. 2 Comparison diagram of function diagram and convergence curve of eight test functions

图2各分图:左图为测试函数的三维搜索空间分布图, $x_1$ 和 $x_2$ 分别为函数搜索区间, $F(x_1, x_2)$ 表示函数值的大小;右图为智能算法对函数求极值时的收敛曲线,横轴表示迭代次数,纵轴是最优值.

可以看到:对于单峰函数 $f_1 \sim f_4$ ,改进的灰狼

算法收敛速度大幅度增加,收敛精度在标准灰狼算法的3倍以上;对于多峰函数 $f_5$ 和 $f_7$ ,改进的灰狼算法精度可以收敛到0,标准差为0;对于固定维度多峰函数 $f_8$ ,改进的灰狼算法收敛到其最小值-3.68.由此可见,TGWO在测试函数上收敛速度

较PSO和GWO更快,精度更高.

### 3 短时交通流预测模型构建与实例分析

#### 3.1 TGWO-BP模型的构建

在短时交通流的预测中,BP神经网络具有接近任何非线性函数的能力,本文构建了基于改进灰狼算法优化BP神经网络(TGWO-BP)的短时交通流预测模型.利用改进的灰狼算法寻找到两个最优值,作为BP神经网络的初始权值和阈值,利用优化后的BP神经网络进行短时交通流的训练和预测,提高传统BP神经网络模型的预测精度.

(1) 初始化灰狼种群,确定BP神经网络参数.选择符合实际数据的BP神经网络输入层、隐含层、输出层,以及各层的激活函数.

(2) 确定灰狼种群的适应度函数.用初始化后的灰狼参数构建BP神经网络,将BP神经网络期望值和预测值相差的绝对值之和作为灰狼的适应度函数,公式为

$$f(x) = \sum_{e=1}^n |\hat{x}_e - x_e| \quad (17)$$

式中: $n$ 为网络输出节点数; $\hat{x}_e$ 和 $x_e$ 分别为网络的预测输出和期望输出.

(3) 将适应度函数值视为灰狼群体中的猎物位置,利用TGWO,寻找到最优函数值.输出函数的两个最优解,将输出的两个最优解分别赋为BP神经网络的权值和阈值.对BP神经网络进行训练,达到训练精度要求后,输入预测数据,输出最

终预测结果.

#### 3.2 模型评价指标

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(Mean Absolute Percent Error, MAPE)进行误差分析.

$$E_{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100\% \quad (18)$$

式中: $E_{MAPE}$ 为平均绝对百分误差值; $\hat{x}_i$ 、 $x_i$ 分别为交通流的预测值、实测值; $N$ 为预测的总时间长度.

#### 3.3 交通流预测实例分析

实验数据为2017年3月7日~4月20日贵阳市白云区00:00-23:55的车流量数据,时间间隔为5 min.利用Matlab 2017a进行编程分析,对数据进行预处理,包括冗余数据的删除与错误数据的修改、小波去噪、相空间重构与归一化处理.将数据集利用BP\_Adaboost强分类器进行分类设计.

将预处理后的数据分别输入本文构建的TGWO-BP、GWO-BP、PSO-BP、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.为保证对比结果的公平性,各模型参数保持一致.BP神经网络训练次数为100,精确度为0.000 1,学习率为0.01;灰狼算法(GWO)和改进灰狼算法(TGWO)种群数量为30,迭代次数为500,维度为41;粒子群算法(PSO)种群数量为30,迭代次数为500.每种模型独立运行50次,取平均值作为最终预测结果.4种模型预测短时交通流的期望输出和预测输出结果如图3~图6所示.

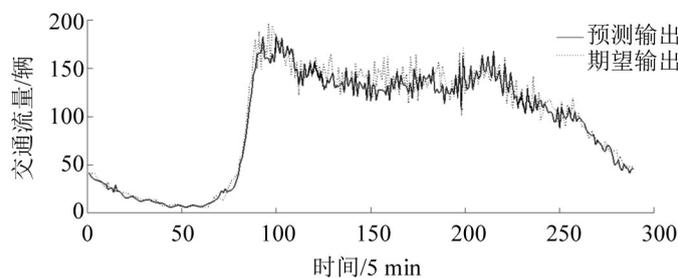


图3 基于TGWO-BP的短时交通流预测模型

Fig. 3 Short-term traffic flow based on TGWO-BP

图3中,基于TGWO-BP的短时交通流预测结果较为精确,预测输出与期望输出变化范围基本一致,相比于其他3种预测模型,预测输出与期望输出间的误差更小,可以较准确地描述短时交通流的变化趋势.图4中,基于GWO-BP的短时交通

流预测结果可以大致满足交通流的变化趋势,但是随着时间的增长,后期误差较大,预测输出的值偏低.图5中,基于PSO-BP的短时交通流预测结果误差较大,在时间轴[100, 200]内,预测输出值的趋势平缓,波动幅度小;在时间轴250左右,预测输出普

遍偏高,明显偏离期望输出.图6中,基于BP的短时交通流预测结果不能满足交通流的变化趋势,

在大部分时间范围内,预测输出均低于期望输出,不能很好地拟合期望输出.

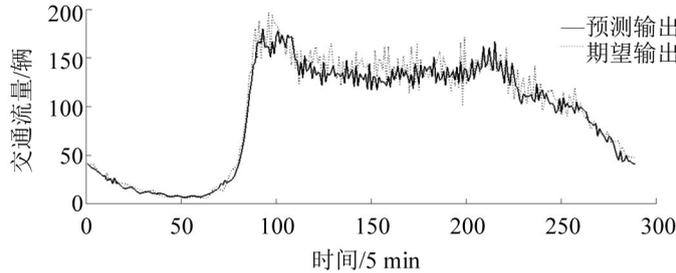


图4 基于GWO-BP的短时交通流预测模型

Fig. 4 Short-term traffic flow based on GWO-BP

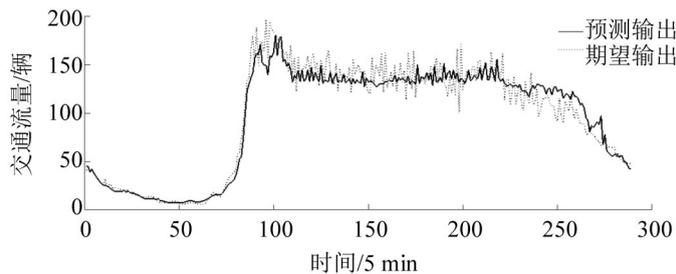


图5 基于PSO-BP的短时交通流预测模型

Fig. 5 Short-term traffic flow based on PSO-BP

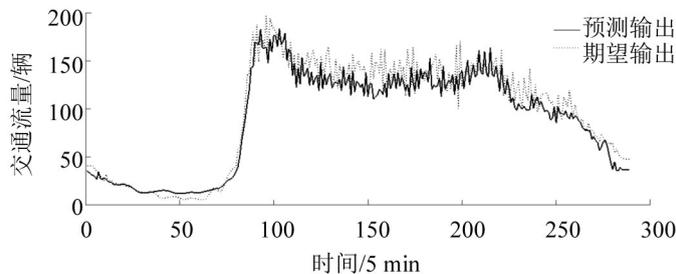


图6 基于BP的短时交通流预测模型

Fig. 6 Short-term traffic flow based on BP

为更直观地判断4种预测模型的预测结果,利用平均绝对百分误差(MAPE)对4种预测模型进行对比分析,MAPE的值取短时交通流预测模型独立运行50次之后的平均值,如表3所示.

表3 4种预测模型的平均绝对百分误差值

Table 3 MAPE of four forecast models

预测模型	TGWO-BP	GWO-BP	PSO-BP	BP
MAPE/%	10.03	11.25	13.94	14.36

由表3可知,基于TGWO-BP的短时交通流预测误差值小于GWO-BP、PSO-BP和BP神经网络模型,预测精度比GWO-BP高出1.22%,比PSO-BP高出3.91%,比BP神经网络模型高出4.33%,说明TGWO-BP在短时交通流预测方面具有更高的

精度.

## 4 结论

本文针对标准灰狼算法收敛速度慢,不易区分全局搜索和局部搜索,以及容易陷入局部极值的问题,基于Sigmoid函数改进了灰狼算法的收敛因子,使其具有自适应递减的能力,提高算法搜索速度,引入惯性权重改进狼群的位置更新公式,使灰狼自动更新搜索步长,不容易陷入局部极值.

通过求解8个基准测试函数进行了TGWO的验证,结果证明,TGWO较GWO和PSO具有更高的精度和更快的收敛速度.利用改进的灰狼算法优化BP神经网络的权值和阈值,构建了基于

TGWO-BP的短时交通流预测模型,通过与GWO-BP、PSO-BP和BP神经网络模型进行对比实验,发现TGWO-BP预测误差为10.03%,具有更高的预测精度,可以满足短时交通流预测的准确性和实时性的要求,具有良好的应用前景.

#### 参考文献:

- [1] MORETTI F, PIZZUTI S, ANNUNZIATO M, et al. Urban traffic flow forecasting through statistical and neural network bagging ensemble hybrid modeling[J]. *Neurocomputing*, 2015, 167(C): 3-7.
- [2] CHAI Y, HUANG D, ZHAO L. A short-term traffic flow prediction method based on wavelet analysis and neural network[C]//2016 Chinese Control and Decision Conference(CCDC), Yinchuan, IEEE, 2016: 7030-1034.
- [3] MIRJALILI S M. Lewis a grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69(3): 46-61.
- [4] 石峰, 楼文高, 张博. 基于灰狼群智能最优化的神经网络PM<sub>2.5</sub>浓度预测[J]. *计算机应用*, 2017, 37(10): 2854-2860. [SHI F, LOU W G, ZHANG B. Neural network model for PM<sub>2.5</sub> concentration prediction by grey wolf optimizer algorithm[J]. *Journal of Computer Applications*, 2017, 37(10): 2854-2860.]
- [5] 傅蔚阳, 刘以安, 薛松. 基于灰狼算法与小波神经网络的目标威胁评估[J]. *浙江大学学报(工学版)*, 2018, 52(4): 680-686. [FU W Y, LIU Y A, XUE S. Target threat assessment using grey wolf optimization and wavelet neural network[J]. *Journal of Zhejiang University (Engineering Science)*, 2018, 52(4): 680-686.]
- [6] HEIDARI A A, PAHLAVANI P. An efficient modified grey wolf optimizer with lévy flight for optimization tasks [J]. *Applied Soft Computing*, 2017(60): 115-134.
- [7] PADHY S, PANDA S, MAHAPATRA S. A modified GWO technique based cascade PI- PD controller for AGC of power systems in presence of plug in electric vehicles[J]. *Engineering Science and Technology*, 2017, 20(2): 427-442.
- [8] 黄益绍, 韩磊. 基于改进极限学习机的公交站点短时客流预测方法[J]. *交通运输系统工程与信息*, 2019, 19(4): 115-123. [HUANG Y S, HAN L. Short-term passenger flow prediction method on bus stop based on improved extreme learning machine[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2019, 19(4): 115-123.]
- [9] SONG H, SULAIMAN M, MOHAMED M. An application of grey wolf optimizer for solving combined economic emission dispatch problems[J]. *International Review on Modeling and Simulation*, 2014, 7(5): 838-844.