

# 基于改进粒子群优化算法的灰色神经网络的铁路货运量预测

雷 斌\*, 陶海龙, 徐晓光

(兰州交通大学 机电技术研究所, 兰州 730070)

(\* 通信作者电子邮箱 leibin@mail.lzjtu.cn)

**摘 要:**针对现有铁路货运量预测方法的不足,提出基于改进粒子群优化算法的灰色神经网络(IPSO-GNN)的铁路货运量预测方法,通过 IPSO 对常规灰色神经网络(GNN)的白化参数进行优化,改善了 GNN 的不足,保证了预测精度;同时利用灰色关联分析法,计算了铁路货运量和影响因素间的关联度,以最主要的 6 个关联因素,建立了基于 IPSO-GNN 的铁路货运量预测模型。仿真实验结果表明,在铁路货运量预测中此模型预测精度优于常规 GNN 及其他预测方法,说明此预测方法有效可行。

**关键词:**铁路货运量预测;粒子群优化算法;灰色神经网络;灰色关联分析;BP 神经网络;Elman 神经网络

**中图分类号:** TP18 **文献标志码:** A

## Railway freight volume prediction based on grey neural network with improved particle swarm optimization

LEI Bin\*, TAO Hai-long, XU Xiao-guang

(Institute of Mechanical and Electrical Technology, Lanzhou Jiaotong University, Lanzhou Gansu 730070, China)

**Abstract:** Concerning the shortcomings of the methods which forecast railway freight volume, the paper proposed Grey Neural Network (GNN) based on the Improved Particle Swarm Optimization algorithm (IPSO-GNN). To make up for the shortfall of the conventional GNN and guarantee the prediction accuracy, it optimized the GNN whitening parameters through the IPSO. And it computed the railway freight volume and the correlation degree of influential factors. It built a railway freight volume model based on IPSO-GNN with six relating factors. The simulation results show that the prediction method is effective and feasible. The prediction precision of the given model in the railway freight volume forecast is better than those of the conventional GNN prediction method and other prediction methods.

**Key words:** railway freight volume prediction; Particle Swarm Optimization (PSO) algorithm; Grey Neural Network (GNN); grey relation analysis; BP neural network; Elman neural network

## 0 引言

铁路货运量作为货运市场体系中的重要统计指标,为铁路运输所占的货运市场份额提供了重要的依据。因此,预测货运量发展趋势是制定铁路货物运输营销战略的前提和基础,对铁路货运组织的实施具有重要作用<sup>[1]</sup>。但铁路货运是一个复杂的社会经济系统,受社会、经济、自然等多种因素的综合影响,且各因素的作用机制通常不能或无法用精确的数学语言来准确描述,因此铁路货运量预测属于复杂的非线性系统问题,这就导致其预测建模的困难性与多样性<sup>[2]</sup>。目前国内学者已利用灰色系统理论<sup>[2-4]</sup>、分形理论<sup>[5-6]</sup>、粗糙集(Rough Set)理论<sup>[7]</sup>、支持向量机模型(Support Vector Machine, SVM)<sup>[8]</sup>、人工神经网络<sup>[9-11]</sup>等方法对铁路货运量进行预测。

受环境因素、突发事件的影响,铁路货运量具有很强的波动性,因此使灰色系统理论、分形理论、Rough Set 理论在短期货运量预测中的预测精度往往不高,另外 SVM 模型因主要参数(核函数  $\sigma$  及惩罚因子  $c$ )选取的困难性影响了其实用性。而基于神经网络和灰色模型的灰色神经网络(Grey Neural Network, GNN),结合了神经网络非线性拟合能力强及灰色模型计算量小、少样本情况下精度较高的特点,这就在不同程

度上克服了上述不足。但由于 GNN 权值和阈值随机初始化,导致了网络易陷入局部最优,而且每次预测结果不同,且偏差较大。

粒子群优化(Particle Swarm Optimization, PSO)算法是基于群体智能理论的优化算法,算法概念非常简单,具有好的鲁棒性及非常好的全局搜索能力,利用 PSO 优化 GNN 的参数可以改善上述不足。针对标准 PSO 容易陷入局部极小点且过早收敛的问题,本文采用一种改进的 PSO 算法(IPSO),该算法能够较好地调整全局与局部搜索能力之间的平衡;并将其应用于 GNN 的参数优化。仿真结果表明基于 IPSO-GNN 方法的预测精度优于常规 GNN 及其他智能预测方法,更加适合于铁路货运量预测。

## 1 基于 IPSO-GNN 预测模型

### 1.1 PSO 算法及算法改进

PSO 算法是 Kennedy 等<sup>[12]</sup>受鸟群觅食行为的启发后于 1995 年提出来的,是基于群体智能理论的优化算法,通过鸟之间的集体协作使群体达到最优的过程。为更好地控制算法的开发和探索能力,Shi 等<sup>[13]</sup>引入惯性权重  $w$  形成了标准版本。标准 PSO 算法首先初始化为一组随机粒子(随机解),然后通过跟踪当前最优的粒子来搜索最优解。假设  $d$  维搜索空

收稿日期:2012-04-11;修回日期:2012-05-22。 基金项目:甘肃省自然科学基金资助项目(1014RJZA042)。

作者简介:雷斌(1978-),男,甘肃会宁人,讲师,硕士,CCF 会员,主要研究方向:物流运输装备监控及信息化、自动化立体仓库监控管理系统、物流信息系统;陶海龙(1981-),男,甘肃兰州人,硕士,主要研究方向:物流运输装备监控及信息化、物流信息系统;徐晓光(1987-),男,河北石家庄人,硕士研究生,主要研究方向:物流运输装备监控及信息化、物流信息系统。

间中,有  $m$  个粒子组成一个群体,第  $i$  个粒子的位置和速度分别为  $X^i = (x_{i,1}, x_{i,2}, \dots, x_{i,d})$  和  $V^i = (v_{i,1}, v_{i,2}, \dots, v_{i,d})$ ,在每一次迭代中,粒子通过跟踪两个最优解来更新自己,第一个就是粒子本身所找到的最优解——个体极值  $pbest$ ,  $P^i = (p_{i,1}, p_{i,2}, \dots, p_{i,d})$ ;另一个是整个种群目前找到的最优解——全局最优解  $gbest$ 。在找到这两个最优解时,粒子根据如下公式来更新自己的速度和位置。

$$v_{i,j}(t+1) = w \times v_{i,j}(t) + c_1 \times r_1 \times [p_{i,j} - x_{i,j}(t)] + c_2 \times r_2 \times [p_{g,j} - x_{i,j}(t)] \quad (1)$$

$$x_{i,j}(t+1) = x_{i,j}(t) + v_{i,j}(t+1) \quad (2)$$

其中:  $j = 1, 2, \dots, d; i = 1, 2, \dots, m; w$  为惯性权重,  $c_1$  和  $c_2$  为正的学习因子,  $r_1$  和  $r_2$  为  $[0, 1]$  的随机数。

在标准 PSO 算法中,惯性权重  $w$  是可调整的重要参数,其作用是有效控制算法的收敛和探索能力,较大的  $w$  使算法具有较强的全局搜索能力,而较小的  $w$  则更有利于局部搜索。针对参数  $w$  的设置,近年来学者们提出了许多变化方法,其中以 Shi 等的线性递减权值策略(LDW-PSO)<sup>[14]</sup> 应用最为广泛。即:

$$w = w_{\max} - (w_{\max} - w_{\min}) \times t/t_{\max} \quad (3)$$

其中:  $w_{\max}$ 、 $w_{\min}$  分别为表示  $w$  的最大值和最小值,  $t$  表示当前迭代步数,  $t_{\max}$  表示最大迭代步数,但其存在一些问题。首先,如果在运行初期探测到较优点,则希望能迅速收敛于最优点,而  $w$  的线性递减减缓了算法的收敛速度;其次,在算法的运行后期,随着  $w$  的减小,导致全局搜索能力下降,多样性减弱,容易陷入局部最优<sup>[6]</sup>。为克服其不足,本文采用一种改进的非线性权值递减算法,使 PSO 算法能较好地调整全局与局部搜索能力之间的平衡。惯性权值  $w$  的计算公式为:

$$w = w_{\max} + (w_{\max} - w_{\min}) \times \tan((t/t_{\max}) \times (\pi/4)) \quad (4)$$

另外,为了使 PSO 算法在迭代过程中能拓展不断缩小的种群搜索空间,使粒子能够跳出先前搜索到得最优位置,在更大的空间进行搜索,保持种群多样性。借鉴遗传算法的变异思想,在 PSO 算法中引入变异操作,即在粒子每次更新之后,以一定概率初始化粒子。

为测试其有效性,以 2 个经典函数来验证其收敛性能。

F0:

$$f(x) = \sum_{i=1}^n x_i^2; -100 < x_i < 100 \quad (5)$$

F1:

$$f(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10); -5.12 < x_i < 5.12 \quad (6)$$

其中:F0 为 Sphere 函数,单峰,在  $x_i = 0$  时达到极小值 0;F1 为 Rastrigin 函数,多峰,当  $x_i = 0$  达到全局最小值 0。

在测试中,粒子群的粒子数量设为 40,维数分别为 10 和 20,  $c_1$ 、 $c_2$  都设为 2.05,循环次数均为 1000。标准 PSO 的  $w$  为 0.65;IPSO 和 LDW-PSO 的  $w_{\max}$ 、 $w_{\min}$  分别为 0.9、0.4;最大限制速度  $v_{\max} = 1$ 。用上述 2 个测试函数来测试每个算法各 30 次,得到不同 PSO 算法下的测试函数结果如表 1 所示。

表 1 测试结果

函数	维数	标准 PSO	LDW-PSO	IPSO
F0	10	5.5729E-07	2.0040E-10	3.0700E-12
	20	0.0312	0.0014	7.2161E-07
F1	10	11.2232	9.9098	5.1147
	20	28.6038	25.7021	15.6411

从表 1 可以看出,对于 F0、F1,当维数分别为 10 和 20 时,IPSO 算法结果均优于标准 PSO 和 LDW-PSO 的算法结果。由

此可见,IPSO 算法具有较好的调整全局搜索和局部搜索能力。

## 1.2 灰色神经网络

GNN 的思路是将灰色模型(Grey Model, GM)的白化方程映射到一个 BP 网络中,对网络进行训练,当网络收敛时从训练好的网络中提取出相应的连接权值系数,计算相应的系数  $a$  和  $b_i (i = 1, 2, \dots, n-1)$  从而得到一个白化的微分方程,进而利用此微分方程对系统进行数据预测<sup>[15]</sup>。其过程可描述为如下:

设  $n$  个参数的灰色神经网络模型的微分方程为:

$$\frac{dy_1}{dt} + ay_1 = b_1y_2 + b_2y_3 + \dots + b_{n-1}y_n \quad (7)$$

其中:  $y_2, y_3, \dots, y_n$  为系统的输入参数;  $y_1$  为系统输出参数;  $a, b_1, \dots, b_{n-1}$  为微分方程系数。其时间响应式为

$$z(t) = \left( y_1(0) - \frac{b_1}{a}y_2(t) - \frac{b_2}{a}y_3(t) - \dots - \frac{b_{n-1}}{a}y_n(t) \right) e^{-at} + \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \dots + \frac{b_{n-1}}{a}y_n(t) \quad (8)$$

令  $d = \frac{b_1}{a}y_2(t) + \frac{b_2}{a}y_3(t) + \dots + \frac{b_{n-1}}{a}y_n(t)$ , 则式(8)可转化为:

$$z(t) = \left( (y_1(0) - d) - y_1(0) \frac{1}{1 + e^{-at}} + 2d \frac{1}{1 + e^{-at}} \right) (1 + e^{-at}) \quad (9)$$

将式(9)映射到 BP 神经网络中,得网络拓扑结构如图 1 所示。其中:  $t$  为输入参数序号;  $y_2(t), \dots, y_n(t)$  为网络输入参数;  $w_{11}, w_{21}, w_{22}, \dots, w_{2n}, w_{31}, w_{32}, w_{3n}; \theta$  为阈值;  $y_1$  为网络输出值; LA、LB、LC、LD 分别表示灰色神经网络的四层。令  $2b_1/a = u_1, 2b_2/a = u_2, \dots, 2b_{n-1}/a = u_{n-1}$ , 则网络的初始权值可以表示为:  $w_{11} = a, w_{21} = -y_1(0), w_{22} = u_1, w_{23} = u_2, \dots, w_{2n} = u_{n-1}, w_{31} = w_{32} = \dots = w_{3n} = 1 + e^{-at}$ , LD 层中输出节点的阈值为  $\theta = (1 - e^{-at})(d - y_1(0))$ 。




图 1 灰色神经网络拓扑结构

GNN 学习流程采用 BP 算法,由输入信号的正向传播和误差的反向传播两个过程组成,其具体过程如下:

- 1) 根据训练数据特征初始化网络结构。初始化参数  $a, b$ , 并根据  $a, b$  值计算  $u$ 。
- 2) 根据网络权值定义计算  $w_{11}, w_{21}, w_{22}, \dots, w_{2n}, w_{31}, w_{32}, w_{3n}$ 。
- 3) 对每一个输入序列  $(t, y(t))$ ,  $t = 1, 2, 3, \dots, N$ , 计算每层输出。

LA 层:  $a = w_{11}t$ ;

LB 层:  $b = f(w_{11}t) = \frac{1}{1 + e^{-w_{11}t}}$ ;

LC 层:  $c_1 = bw_{21}, c_2 = y_2(t)bw_{22}, c_3 = y_3(t)bw_{23}, \dots, c_n = y_n(t)bw_{2n}$ ;

LD 层:  $d = w_{31}c_1 + w_{32}c_2 + \dots + w_{3n}c_n - \theta_{y1}$ 。

- 4) 计算网络预测输出与期望输出的误差,并根据误差调

整权值和阈值。

LD 层误差:

$$\delta = d - y_1(t);$$

LC 层误差:

$$\begin{cases} \delta_1 = \delta(1 + e^{-w_{11}t}) \\ \delta_2 = \delta(1 + e^{-w_{11}t}) \\ \vdots \\ \delta_n = \delta(1 + e^{-w_{11}t}) \end{cases}$$

LB 层误差:

$$\delta_{n+1} = \frac{1}{1 + e^{-w_{11}t}} \left( 1 - \frac{1}{1 + e^{-w_{11}t}} \right) (w_{21}\delta_1 + w_{22}\delta_2 + \cdots + w_{2n}\delta_n)$$

根据预测误差调整权值。

调整 LB 到 LC 的连接权值:

$$\begin{cases} w_{21} = -y_1(0) \\ w_{22} = w_{22} - u_1\delta_2b \\ \vdots \\ w_{2n} = w_{2n} - u_{n-1}\delta_nb \end{cases}$$

调整 LA 到 LB 的连接权值:

$$w_{11} = w_{11} + at\delta_{n+1};$$

调整阈值:

$$\theta = (1 + e^{-w_{11}t}) \left( \frac{w_{22}}{2}y_2(t) + \frac{w_{23}}{2}y_3(t) + \cdots + \frac{w_{2n}}{2}y_n(t) - y_1(0) \right)$$

5) 判断训练是否结束,若否,返回3)。

### 1.3 基于 IPSO-GNN 预测模型

IPSO-GNN 算法是采用 IPSO 算法优化 GNN 的  $a, b_1, \dots, b_{n-1}$  等  $n$  个白化参数,以训练样本的个体对应的 GNN 预测误差作为个体的适应值,算法结束时能够寻找到全局最优值;在此基础上以最优值作为 GNN 初始权值和阈值对网络进行训练,进而达到网络的训练目标。其过程可描述如下:

1) 初始化,设定粒子群的维数  $D$ 。因 GNN 的初始权值与阈值由  $a, b_1, \dots, b_{n-1}$  等  $n$  个参数确定,则粒子群的维数  $D$  为:

$$D = n \quad (10)$$

2) 设置粒子群的适应值函数,本文选用以训练样本的个体对应的 GNN 预测误差作为个体适应度值函数,如式(11)所示。因 GNN 的输出神经元只有 1 个,因此可简化为式(12)。

$$E = \sum_{s=1}^p \sum_{i=1}^k |y_i - o_i| \quad (11)$$

$$E = \sum_{s=1}^p |y_s - o_s| \quad (12)$$

其中: $k$  为网络的输出节点数,显然  $k = 1$ ;  $s$  为训练样本; $y_i$  为 GNN 第  $i$  个节点的期望输出; $o_i$  为 GNN 的第  $i$  个节点的实际输出; $y_s$  为 GNN 训练中第  $s$  个样本对应的期望输出; $o_s$  为 GNN 训练中第  $s$  个样本对应的实际输出。

3) 利用 IPSO 算法优化 GNN 的  $a, b_1, \dots, b_{n-1}$  等  $n$  个参数,并将优化后最优参数作为 GNN 的初始权值和阈值代入网络进行训练,根据 GNN 训练算法进行调节权值和阈值,直至网络的误差(或迭代次数)指标达到预定值。

## 2 铁路货运量影响因素的选择

铁路运输涉及到诸多外部和内部因素,为提高铁路货运量的预测精度,需要对这些因素进行分析。若引入过多的影响因素,因各影响因素之间的相关性使预测结果不准确;而选取过少的影响因素则不能全面地反映铁路运量发展的趋势。所以要合理地选择影响因素,使其能全面反映对铁路货运量的影响,又使所选取因素不相互包含而具有明显的相关性。而灰色系统理论中的灰色关联法,可在不完全信息中对要分析的各因素,通过一定的数据处理,在随机的因素序列间找到它们之间的关联性,从而找出主要影响因素<sup>[16]</sup>。

表2收集了1999—2008年我国铁路货运量( $P_0$ )及其影响因素数据,其中影响铁路货运量因素由铁路货物周转量( $P_1$ )、水路与公路货运量之和( $P_2$ )、国内生产总值( $P_3$ )、第一产业( $P_4$ )、第二产业( $P_5$ )、第三产业( $P_6$ )、进出口贸易总额( $P_7$ )、铁路行业就业人员( $P_8$ )、全国铁路营业里程( $P_9$ )这9个元素组成。为确定各因素对货运量的影响大小,本文通过灰色关联分析法确定铁路货运量及影响因素之间的关系,从而选取主要影响因素。

表2 1999~2008年铁路货运量及其影响因素

序号	年	$P_0$ /万 t	$P_1$ /(亿 t·km)	$P_2$ /万 t	$P_3$ /亿元	$P_4$ /亿元	$P_5$ /亿元	$P_6$ /亿元	$P_7$ /亿元	$P_8$ /万人	$P_9$ /万 km
1	1999	167 554	12 910.32	180 464.30	89 677.05	14 770.03	41 033.58	33 873.40	29 896.20	185.20	6.74
2	2000	178 581	13 770.52	192 351.50	99 214.55	14 944.72	45 555.88	38 714.00	39 273.20	187.10	6.87
3	2001	193 189	14 694.11	207 883.10	109 655.17	15 781.27	49 512.29	44 361.60	42 183.60	178.90	7.01
4	2002	204 955	15 658.45	220 614.40	120 332.69	16 537.02	53 896.77	49 898.90	51 378.20	175.80	7.19
5	2003	224 248	17 246.74	241 494.70	135 822.76	17 381.72	62 436.31	56 004.70	70 483.50	172.80	7.3
6	2004	249 017	19 288.82	268 305.80	159 878.34	21 412.73	73 904.31	64 561.30	95 539.10	169.90	7.44
7	2005	269 296	20 726.04	290 022.00	183 217.40	22 420.00	87 364.60	73 432.90	116 921.80	166.60	7.54
8	2006	288 224	21 954.43	310 178.41	211 923.50	24 040.00	103 162.00	84 721.40	140 971.40	165.30	7.71
9	2007	314 237	23 797.07	338 034.00	257 305.60	28 627.00	124 799.00	103 879.60	166 740.20	174.10	7.8
10	2008	330 058	25 106.39	355 460.42	300 670.00	34 000.00	146 183.40	120 486.60	179 921.50	173.30	7.97
关联度			0.977 4	0.999 1	0.684 4	0.833 4	0.650 5	0.687 7	0.527 9	0.582 9	0.670 1

注:数据来自国家统计局网站。

### 2.1 确定参考数列与比较数列

以表1中铁路货运量为参考数列,记  $X_0 = \{x_0(k)\}$ ,  $k = 1, 2, \dots, 10$ ;以表1中9个影响因素作为标记数列,记为  $X_i = \{x_i(k)\}$ ,  $i = 1, 2, \dots, 9$ 。

### 2.2 无量纲化

本文对数据采用均值化处理,即对每一个数列的所有数

据均用该列数据的平均值去除,得到一个新数列  $x_j'$ :

$$\bar{x}_j = \frac{1}{n} \sum_{k=1}^n x_j(k) \quad (13)$$

$$x_j'(k) = x_j(k) / \bar{x}_j \quad (14)$$

### 2.3 关联系数与关联度

参考数列  $X_0$  与比较数列  $X_i$  的关联系数  $\zeta_i(k)$  有式(5):



$$\zeta_i(k) = \frac{\min_k \min_i |x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_i \max_k |x_0(k) - x_i(k)|} \quad (15)$$

其中: $\rho$ 为分辨系数, $\rho \in [0,1]$ , $\rho$ 越小,分辨率越高,一般取 0.5。

参考数列  $X_0$  与比较数列  $X_i$  的关联度为:

$$r_i = \frac{1}{n} \sum_{k=1}^n \zeta_i(k) \quad (16)$$

通过上述计算得到铁路货运量与影响因素的关联度值,数据见表 1,则影响铁路货运量各影响因素的主次顺序依次为  $P_2, P_1, P_4, P_6, P_3, P_9, P_5, P_8, P_7$ 。本文选用主次排序中的前 6 个因素作为主要因素预测铁路货运量。

### 3 IPSO-GNN 模型的应用

#### 3.1 数据处理

为使数据处理方便,防止净输入绝对值过大引起的神经元输出饱和现象,加快训练网络的收敛性。需对货运量及影响因素按式(12)进行归一化处理,将其转化为  $[0,1]$  的数。

$$x_i' = (x_i - n)/(m - n) \quad (17)$$

其中: $x_i'$ 为归一化后值; $x_i$ 为原值; $n$ 为  $x_i$  中最小值的 0.7 倍; $m$ 为  $x_i$  中最大值的 1.3 倍。

#### 3.2 建立基于 IPSO-GNN 预测模型

将表 2 中 1999—2005 年的数据作为网络训练数据,2006—2008 年的数据为测试数据,采用 Matlab 7.5 分别建立 GNN 和 IPSO-GNN 模型,并与 BP 网络,Elman 网络进行比较分析。网络参数确定:由于本文中输入数据为 6 维,输出为 1 维,故 GNN 的结构为 1-1-7-1,设定训练迭代次数 200;由 GNN 结构可得 IPSO-GNN 模型中粒子群维数  $D = 7$ ,其余参数分别为粒子数为 20, $c_1, c_2$  都为 2, $w_{\max}, w_{\min}$  分别为 0.9、0.4,最大限制速度  $v_{\max} = 5$ ,迭代次数为 100;另外 BP 网络,Elman 网络的隐层神经元数都为 13。

#### 3.3 仿真结果

应用训练数据对网络进行训练,分别采用各预测模型对检测样本进行预测,预测结果如表 4 所示,同时图 2 对 GNN 和 IPSO-GNN 训练误差曲线进行了对比,各预测模型的预测结果对比如图 3 所示。

表 3 仿真结果

序号	年度	实际货运量	GNN		IPSO-GNN		BP NN		Elman NN	
			预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%	预测值	相对误差/%
1	2006	0.548 2	0.520 7	5.02	0.527 9	3.70	0.506 7	7.57	0.513 7	6.30
2	2007	0.631 7	0.582 7	7.75	0.603 3	4.50	0.567 2	10.21	0.564 6	10.62
3	2008	0.682 4	0.652 7	4.35	0.692 5	-1.48	0.533 2	21.87	0.604 8	11.37
平均值				5.71		2.24		13.21		9.43




图 2 GNN 和 IPSO-GNN 模型训练误差曲线对比




图 3 各模型预测结果对比(货运量为实际值)

从表 4 中可知,GNN 模型的平均相对误差为 5.71%,BP NN 模型的平均相对误差为 13.21%,Elman NN 模型的平均相对误差为 9.43%,可见在小样本预测的问题上,GNN 要优于 BP 网络和 Elman 网络;同时,IPSO-GNN 模型的平均相对误差为 2.24%。另外由图 3 可得,IPSO-GNN 模型预测结果

均优于其他模型,其预测结果最接近于实际货运量值,可见 IPSO-GNN 模型预测精度高,可满足铁路货运量预测要求。

### 4 结语

惯性权重  $w$  对 PSO 算法的收敛速度和精度有较大影响,因此本文对其进行了改进,并且加入遗传变异算子,以使该算法能较好地调整全局和局部搜索能力之间的平衡,并将其应用于优化 GNN 的白化参数  $a, b_1, \dots, b_{n-1}$  来改善 GNN 的不足。另外利用灰色关联分析法,计算了铁路货运量及其影响因素间的关联度,然后选用最主要的 6 个关联因素,建立了基于 IPSO-GNN 铁路货运量预测模型。仿真结果表明,基于 IPSO-GNN 预测模型精度均高于 GNN、BP 网络以及 Elman 网络等方法,说明此预测方法有效可行。

#### 参考文献:

- [1] 黄勇,徐景昊.关于铁路货运量预测研究[J].铁道运输与经济,2010,32(4):86-89.
- [2] 林晓言,陈有孝.基于灰色—马尔可夫链改进方法的铁路货运量预测研究[J].铁道学报,2005,27(3):15-19.
- [3] 张诚,周湘峰.基于灰色预测—马尔可夫链—定性分析的铁路货运量预测[J].铁道学报,2007,29(5):15-21.
- [4] 谢建文,张元标,王志伟.基于无偏灰色模糊马尔可夫链的铁路货运量预测研究[J].铁道学报,2009,31(1):1-7.
- [5] 李红启,刘凯.基于分形理论的铁路货运量分析[J].铁道学报,2003,25(3):19-23.
- [6] 朱子虎,吴华稳,翁振松,等.基于分形理论的铁路客货运量预测[J].铁道运输与经济,2011,33(7):80-84.
- [7] 李红启,刘凯.基于 Rough Set 理论的铁路货运量预测[J].铁道学报,2004,26(3):1-7.

(下转第 2962 页)

度航向传感器时,选择精度相对较低的计程仪,也能满足导航精度设计要求。

表1 CEP半径 $r$ 与 $\sigma_x/\sigma_y$ 的关系

$\sigma_x/\sigma_y$	CEP半径 $r$
0.1	$0.6820\sigma_y$
0.2	$0.7059\sigma_y$
0.3	$0.7499\sigma_y$
0.4	$0.8079\sigma_y$
0.5	$0.8704\sigma_y$
0.6	$0.9336\sigma_y$
0.7	$0.9962\sigma_y$
0.8	$1.0577\sigma_y$
0.9	$1.1181\sigma_y$
1.0	$1.1774\sigma_y$

### 3 实验结果

某水下机器人导航系统中航向传感器航向角设置误差为 $0.20^\circ$ ,漂移误差为 $0.005^\circ/\text{h}$ 。多普勒计程仪测速系数误差为航速的 $0.3\%$ ,机械安装要求安装偏角不大于 $0.3^\circ$ 。水下机器人平均航速为 $1\text{ m/s}$ ,航行时间 $2\text{ h}$ 。根据上文分析,可以得到:

$$e_{H_1} = 0.35\% D$$

$$e_{H_2} = 0.52\% D$$

$$e_{H_3} = 0.009\% D$$

$$e_{L_1} \approx 0$$

$$e_{L_3} \approx 0$$

$$e_{L_3} \approx 0$$

$$e_{L_4} \approx 0.3\% D$$

其中 $D$ 表示航程。横向和纵向偏差各项误差互不相关,设各个误差传播系数为1,因此水下机器人导航系统合成的横向偏差均方差为:

$$\sigma_x = \sqrt{e_{H_1}^2 + e_{H_2}^2 + e_{H_3}^2} \approx 0.63\% D$$

合成的纵向偏差均方差为:

$$e_L = \sqrt{e_{L_1}^2 + e_{L_2}^2 + e_{L_3}^2 + e_{L_4}^2} \approx 0.3\% D$$

经过计算,圆概率偏差为:

$$r = 0.53\% D$$

水下机器人经过湖上实验,航行距离 $5000\text{ m}$ 。起航前用GPS接收到的经纬度数据作为初始位置,之后水下机器人下潜到一定深度进行定深航行,航行结束后机器人浮出水面,接收GPS信号得到结束点的经纬度数据。将机器人自己推算的位置与GPS接收机得到的位置进行比较,位置偏差为 $24\text{ m}$ ,实验结果表明导航误差为 $0.5\% D$ ,同航程下的闭环航路实验导航

误差几乎等于零,这与分析结果接近,表明本文提出的水下机器人导航误差分析以及圆概率偏差计算方法是有效的。

### 4 结语

CEP已经普遍用于评定水下机器人导航技术指标。在进行水下机器人研制工作前,往往需要对导航技术指标进行预报以确定导航系统是否满足任务需求。本文给出一种用于水下机器人设计前预报CEP的有效方法。分析了水下机器人组合导航系统的误差源,给出了各个误差表达式,并建立了用于求解CEP的迭代方程,采用牛顿下山法确定CEP,数值结果表明当横向与纵向误差之比在 $0 \sim 0.7$ 时,CEP半径 $r$ 不会大于两者之中的大者。实际实验结果与预报结果相符,说明本文介绍的方法是有效的,可以在多种水下机器人或水下机器人系统的设计研制过程中广泛应用。

#### 参考文献:

- [1] ARULAMPALAM S, MASKELL S, GORDON N, *et al.* A tutorial on particle filters for on-line nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing, 2002, 50(2): 174-188.
- [2] VIKÉ S, JOUFFROY J. Diffusion-based outlier rejection for underwater navigation[EB/OL]. [2012-03-01]. <http://ieeexplore.ieee.org/iel5/10918/34367/01639890.pdf>.
- [3] 冯子龙,刘健,刘开周. AUV自主导航航位推算算法的研究[J]. 机器人, 2005, 27(2): 168-172.
- [4] 李硕,曾俊宝,王越超. 自治/遥控水下机器人北冰洋下导航[J]. 机器人, 2011, 33(4): 509-512.
- [5] 杨放琼,谭青,彭高明. 基于信息融合地图的水下位置估计[J]. 计算机工程与应用, 2008, 44(18): 200-203.
- [6] McEWEN R, THOMAS H, WEBER D, *et al.* Performance of an AUV navigation system at Arctic latitudes[J]. IEEE Transactions on Oceanic Engineering, 2005, 30(2): 443-454.
- [7] NEIL H K, CHADWELL C D, ZIMMERMAN R. Absolute positioning of an autonomous underwater vehicle using GPS and acoustic measurements[J]. IEEE Journal of Oceanic Engineering, 2005, 30(1): 153-164.
- [8] 吴东坡,肖金友. 小子样条件下弹头落点 CEP 计算方法[J]. 现代防御技术, 2002, 30(3): 91-95.
- [9] 金忠. 圆概率偏差的测定与检验[J]. 南京理工大学学报, 1995, 19(2): 135-138.
- [10] SHNIDMAN D A. Efficient computation of the Circular Error Probability (CEP) Integral[J]. IEEE Transactions on Automatic Control, 1995, 40(8): 1472-1474.

(上接第2951页)

- [8] 王治. 基于遗传算法一支持向量机的铁路货运量预测[J]. 计算机仿真, 2012, 27(12): 320-322.
- [9] 赵闯,刘凯,李电生. 基于广义回归神经网络的货运量预测[J]. 铁道学报, 2004, 26(1): 12-15.
- [10] 刘志杰,季令,叶玉玲,等. 基于径向基神经网络的铁路货运量预测[J]. 铁道学报, 2006, 28(5): 1-5.
- [11] 郭玉华,陈治亚,冯芬玲,等. 基于经济周期的铁路货运量神经网络预测研究[J]. 铁道学报, 2010, 32(5): 1-6.
- [12] KENNEDY J, EBERHART R C. Particle swarm optimization[C]// Proceedings of IEEE International Conference on Neural Networks. Piscataway, NJ: IEEE Press, 1995: 1942-1948.
- [13] SHI Y, EBERHART R. A modified particle swarm optimization [C]// Proceedings of the IEEE International Conference of Evolutionary Computation. Anchorage: IEEE, 1998: 69-73.
- [14] SHI Y, EBERHART R. A modified particle swarm optimization [C]. Proceedings of the IEEE Congress on Evolutionary Computation. Piscataway, NJ: IEEE Press, 1998.
- [15] 周志刚,郭科,陈丽红. 时序数据预测的灰色神经网络技术[J]. 统计与决策, 2007, (1): 128-129.
- [16] 邓聚龙. 灰色系统基本方法[M]. 武汉: 华中理工大学出版社, 1996: 82-82.