

## 改进粒子群算法优化 BP 神经网络的短时交通流预测

李 松<sup>1</sup>, 刘力军<sup>2</sup>, 翟 曼<sup>1</sup>

(1. 河北大学 管理学院, 保定 071002; 2. 河北经贸大学 工商管理学院, 石家庄 050061)

**摘 要** 为提高 BP 神经网络预测模型的预测准确性, 提出了一种基于改进粒子群算法优化 BP 神经网络的预测方法. 引入自适应变异算子对陷入局部最优的粒子进行变异, 改进了粒子群算法的寻优性能, 利用改进粒子群算法优化 BP 神经网络的权值和阈值, 然后训练 BP 神经网络预测模型求得最优解. 将该预测方法应用到实测交通流的时间序列进行有效性验证, 结果表明了该方法对短时交通流具有更好的非线性拟合能力和更高的预测准确性.

**关键词** 交通流预测; BP 神经网络; 粒子群算法; 变异算子

## Prediction for short-term traffic flow based on modified PSO optimized BP neural network

LI Song<sup>1</sup>, LIU Li-jun<sup>2</sup>, ZHAI Man<sup>1</sup>

(1. School of Management, Hebei University, Baoding 071002, China;

2. School of Business Administration, Hebei University of Economics and Business, Shijiazhuang 050061, China)

**Abstract** In order to improve forecasting model accuracy of BP neural network, an improved prediction method of optimized BP neural network based on modified particle swarm optimization algorithm (PSO) was proposed. In this modified PSO algorithm, an adaptive mutation operator was proposed in PSO to change positions of the particles which plunged in the local optimization. The modified PSO was used to optimize the weights and thresholds of BP neural network, and then BP neural network was trained to search for the optimal solution. The availability of the modified prediction method was proved by predicting the time series of real traffic flow. The computer simulations have shown that the nonlinear fitting and accuracy of the modified prediction methods are better than other prediction methods.

**Keywords** traffic flow prediction; BP neural network; swarm optimization algorithm (PSO); mutation operator

### 1 引言

实时准确的交通流预测是交通控制和交通诱导的前提和关键, 其研究一直是智能交通系统的研究热点. 多年来, 专家和学者们建立了很多预测模型和方法, 如历史平均法、时间序列法、Kalman 滤波法、回归分析法等等<sup>[1]</sup>. 这些方法理论基础较成熟, 应用也较多. 但这些传统的预测方法大都是基于数理统计的方法, 共同特点是先建立数据序列的主观模型, 然后根据主观模型进行计算和预测, 预测精度不能满足实际的要求, 加之不具备自适应和自学习的能力, 预测系统的鲁棒性没有保障. 近年来许多学者对城市交通流系统的非线性特性进行了深入研究<sup>[2-3]</sup>, 建立了多种考虑交通流非线性的交通流预测模型, 如 BP 神经网络模型<sup>[4-5]</sup>、RBF 神经网络模型<sup>[6]</sup>、Volterra 滤波器自适应预测模型<sup>[7-8]</sup>等. 其中, BP 神经网络模型是比较成功的预测模型. 但该模型有两个明显的缺点: 一是容易陷入局部极小值; 二是收敛速度慢. 为克服上述缺点, 本文采用改进粒子群优化算法 (particle swarm optimization, PSO) 优化的 BP 神经网络预测模型, 应用于短时交通流

**收稿日期:** 2010-06-21

**资助项目:** 国家自然科学基金 (50478088); 河北省自然科学基金 (E2012201002); 河北省高等学校人文社会科学研究重点项目 (SKZD2011106)

**作者简介:** 李松 (1965-), 男, 哈尔滨人, 博士, 教授, 研究方向: 交通系统工程, 智能交通控制等; 刘力军 (1970-), 男, 河北石家庄人, 博士, 副教授, 研究方向: 交通系统工程, 智能交通控制等; 翟曼 (1983-), 女, 河北石家庄人, 硕士研究生, 研究方向: 混沌预测理论.

预测.

## 2 BP 神经网络预测模型

时间序列预测的实质是一个动力学系统的逆问题, 即通过动力系统的状态来重构该系统的动力学模型  $F(\cdot)$ , 即:

$$F(X_i) = x_{i+T} (T > 0) \quad (1)$$

式中,  $T$  为前向预测步长.

构造一个非线性函数  $f(\cdot)$  去逼近  $F(\cdot)$  的方法有很多, BP 神经网络就是一种构造时间序列非线性预测模型  $F(\cdot)$  的很好方法.

若一个非线性离散动力系统的输入为  $X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})^T$ , 输出为  $y_i = x_{i+1}$ , 选择典型的三层 BP 神经网络, 由于用 BP 神经网络来预测时间序列, 神经网络输入层的神经元数等于时间序列重构相空间的嵌入维数  $m$  时, 预测效果比较好<sup>[9]</sup>, 故取 BP 神经网络的输入个数为  $m$ 、隐层为  $p$ 、输出个数为 1, 则 BP 神经网络完成映射  $f: R^m \rightarrow R^1$ , 其隐层各节点的输入为

$$S_j = \sum_{i=1}^m w_{ij} x_i - \theta_j, \quad j = 1, 2, \dots, p \quad (2)$$

式中,  $w_{ij}$  为输入层至隐层的连接权值;  $\theta_j$  为隐层节点的阈值.

BP 神经网络转移函数采用 Sigmoid 函数  $f(x) = 1/(1 + e^{-x})$ , 则隐层节点的输出为

$$b_j = \frac{1}{1 + \exp(-\sum_{i=1}^m w_{ij} x_i + \theta_j)}, \quad j = 1, 2, \dots, p \quad (3)$$

同理, 输出层节点的输入、输出分别为:

$$L = \sum_{j=1}^p v_j b_j - \gamma \quad (4)$$

$$x_{i+1} = \frac{1}{1 + \exp(-\sum_{j=1}^p v_j b_j + \gamma)} \quad (5)$$

式中,  $v_j$  为隐层至输出层的连接权值;  $\gamma$  为输出层的阈值.

BP 神经网络的连接权重  $w_{ij}$ 、 $v_j$  和阈值  $\theta_j$ 、 $\gamma$  可以通过 BP 神经网络训练求得, 故  $x_{i+1}$  是可预测的. 式 (5) 即为 BP 神经网络的预测模型.

BP 神经网络在开始训练前将各层的连接权值及阈值随机初始化为  $[0, 1]$  之间的值, 这种未经优化的随机初始化往往会使 BP 神经网络的收敛速度慢, 且容易使最终结果为非最优解. 采用改进的粒子群优化算法可以对初始权值以及阈值分布进行优化, 优化的初始权值和阈值能使 BP 神经网络具有更高的精度.

## 3 对 PSO 算法的改进

粒子群优化算法<sup>[10]</sup> 是 Kennedy 和 Eberhart 在 1995 年受人工生命研究结果的启发, 通过模拟鸟群觅食过程中的迁徙和群聚行为而提出的一种基于群体智能的全局随机搜索算法. 在该算法中, 每个优化问题的候选解都是搜索空间中一个粒子 (particle) 的状态, 每个粒子都对应一个由目标函数决定的适应度值 (fitness value), 粒子的速度决定了它们飞翔的方向和距离. 粒子根据自身及同伴的飞行经验进行动态调整, 即粒子自身所找到的最优解和整个种群当前找到的最优解. 如此在解空间中不断搜索, 直至满足要求为止.

### 3.1 基本 PSO 算法

设在一个  $S$  维的搜索空间中, 由  $n$  个粒子组成的种群  $W = (W_1, W_2, \dots, W_n)$ , 其中第  $i$  个粒子表示为一个  $S$  维的向量  $W_i = (w_{i1}, w_{i2}, \dots, w_{iS})^T$ , 代表第  $i$  个粒子在  $S$  维搜索空间中的位置, 表示一个问题的潜在解. 根据目标函数可计算出每个粒子位置  $W_i$  对应的适应度值. 第  $i$  个粒子的速度记为  $V_i = (V_{i1}, V_{i2}, \dots, V_{iS})^T$ , 其个体极值记为  $P_i = (P_{i1}, P_{i2}, \dots, P_{iS})^T$ , 种群全局的极值记为  $P_g = (P_{g1}, P_{g2}, \dots, P_{gS})^T$ .

在每一次迭代过程中, 粒子通过个体极值和全局极值更新自身的速度和位置, 更新模型为

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - W_{id}^k) + c_2 r_2 (P_{gd}^k - W_{id}^k) \quad (6)$$

$$W_{id}^{k+1} = W_{id}^k + V_{id}^{k+1} \quad (7)$$

式中,  $\omega$  为惯性权重;  $d = 1, 2, \dots, S$ ;  $i = 1, 2, \dots, n$ ;  $k$  为当前迭代次数;  $V_{id}$  为粒子的速度;  $c_1$  和  $c_2$  为非负常数, 称为加速因子;  $r_1$  和  $r_2$  为分布于  $[0, 1]$  之间的随机数.

### 3.2 对 PSO 算法的改进

由于 PSO 中粒子向自身历史最佳位置和邻域或群体历史最佳位置聚集, 形成粒子种群的快速趋同效应, 容易出现陷入局部极值、早熟收敛或停滞现象<sup>[11]</sup>. 为了克服上述不足, 本文借鉴遗传算法中的变异思想, 在 PSO 算法中引入自适应变异算子, 即对某些变量以一定的概率重新初始化. 变异操作拓展了在迭代中不断缩小的种群搜索空间, 使粒子能够跳出先前搜索到的最优位置, 在更大的空间中开展搜索, 同时保持了种群多样性, 提高算法寻优找到更优值的可能性. 下面结合预测算法介绍具体操作.

## 4 改进 PSO 算法优化 BP 神经网络预测算法

改进 PSO 算法优化 BP 神经网络预测算法基本步骤如下.

**Step 1** 初始化参数, 包括种群规模、迭代次数、学习因子以及位置和速度取值的限定区间. 其中, 粒子和速度初始化对粒子位置和粒子速度赋予随机值.

**Step 2** 根据时间序列输入输出参数个数构建 BP 神经网络拓扑结构, 随机生成一个种群粒子  $W_i = (w_{i1}, w_{i2}, \dots, w_{iS})^T$ ,  $i = 1, 2, \dots, n$ , 代表 BP 神经网络的初始值, 其中

$$S = RS_1 + S_1S_2 + S_1 + S_2 \quad (8)$$

式中,  $R$ 、 $S_1$  和  $S_2$  分别为 BP 神经网络输入层结点数、隐层结点数和输出层结点数.

**Step 3** 确定粒子的评价函数. 给定一个 BP 神经网络进化参数, 将 Step 2 中得到的粒子  $W_i$  对 BP 神经网络权值和阈值进行赋值, 输入训练样本进行神经网络训练, 达到设定的精度得到一个网络训练输出值  $\hat{y}_i$ . 则种群  $W$  中个体  $W_i$  的适应度值  $fit_i$  定义为

$$fit_i = \sum_{j=1}^{M-1} (\hat{y}_j - y_j)^2, \quad i = 1, 2, \dots, n \quad (9)$$

式中,  $\hat{y}_j$  为训练输出值;  $y_j$  为训练输出期望值;  $M$  为重构相空间中相点数;  $n$  为种群规模.

**Step 4** 根据输入输出样本计算每个粒子位置  $W_i$  对应的适应度值, 根据初始粒子适应度值确定个体极值和群体极值, 并将每个粒子的最好位置作为其历史最佳位置.

**Step 5** 在每一次迭代过程中, 根据式 (6) 和式 (7) 通过个体极值和全局极值更新粒子自身的速度和位置; 引入简单自适应变异算子, 在粒子每次更新之后以一定概率重新初始化粒子; 计算新粒子适应度值, 根据新种群粒子适应度值更新粒子个体极值和群体极值.

**Step 6** 满足最大迭代次数后, 将改进粒子群算法得到的最优粒子对 BP 神经网络连接权值和阈值进行赋值, BP 神经网络预测模型经训练后, 时间序列预测最优解输出.

## 5 改进 PSO 算法优化 BP 神经网络预测算法

### 5.1 仿真条件

为了说明本文算法的有效性, 在 Matlab2009b 环境下, 采用 Matlab 语言编写算法计算程序, 并应用 Matlab 神经网络工具箱构建了 3 种预测模型, 分别是: 改进 PSO 算法优化 BP 神经网络预测模型 (MPSOBP 模型)、PSO 算法优化 BP 神经网络预测模型 (PSOBP 模型) 和一般的 BP 神经网络预测模型 (BP 模型). 对于同一实测交通流时间序列, 进行交通量预测对比实验.

实验中的交通流时间序列数据按式 (10) 处理成均值为 0、振幅为 1 的归一化时间序列, 并对归一化时间序列进行相空间重构.

$$y_i = \frac{x_i - \frac{1}{n} \sum_{i=1}^n x_i}{\max(x_i) - \min(x_i)} \quad (10)$$

式中,  $\{x_i\}$  为原时间序列;  $\{y_i\}$  为归一化的时间序列.

实验的误差评价体系采用绝对误差  $err$ 、平均绝对误差  $MAE$  和相对误差  $perr$ , 即

$$err = x_i - \hat{x}_i \quad (11)$$

$$MAE = \frac{1}{N_p} \sum_{i=1}^{N_p} |x_i - \hat{x}_i| \quad (12)$$

$$perr = \frac{\sum_{i=1}^{N_p} (x_i - \hat{x}_i)^2}{\sum_{n=1}^{N_p} x_i^2} \quad (13)$$

式中,  $x_i$  和  $\hat{x}_i$  分别为真实值和预测值;  $N_p$  为预测样本数.

实验采用  $m-2m+1-1$  三层 BP 神经网络结构,  $m$  为交通流时间序列的相空间重构嵌入维数取 5; BP 神经网络参数设置为: 训练次数取 100, 训练目标取  $1.0e-005$ , 学习率取 0.01; 粒子群算法参数设置为: 种群规模取 30, 进化代数取 100 次, 加速因子取  $c_1 = c_2 = 1.49445$ , 自适应变异算子变异概率取  $P_m = 0.01-0.05$ , 粒子位置和速度取值区间分别为  $[-5, 5]$  和  $[-1, 1]$ .

## 5.2 实测交通流时间序列的实证分析

仿真实验中的短时交通流数据来自北京四环路交通检测器数据, 每 5 分钟记录一次数据, 共产生 1302 个数据.

取该交通流时间序列前 1200 个数据为训练样本, 后 102 个数据为预测检验样本. 为测试预测方法的准确性, 取不同数量的训练样本进行实验. 图 1、图 2 和图 3 分别给出了 3 种预测模型在训练样本为 1200、预测样本为 30 时的预测结果, 表 1 给出了 3 种预测模型在不同数量训练样本条件下 30 个预测样本的预测平均绝对误差 MAE 和相对误差  $perr$ .




图 1 BP 神经网络模型预测结果




图 2 PSOBP 神经网络模型预测结果




图 3 MPSOBP 神经网络模型预测结果

从图 1、图 2 和图 3 可以看出, 3 种预测模型的预测结果都能够很好地反映交通流量变化的趋势和规律, 说明这 3 种预测模型都能较好地满足短时交通流量预测的要求.

从表 1 可以看出, 当训练样本为 800 时, 由于 PSO 算法形成粒子种群的快速趋同效应, 神经网络陷入局部极值, 因此 PSOBP 模型出现了预测精度低于 BP 模型的情况. 而采用文中加入自适应变异算子的 PSO 算法优化的 MPSOBP 模型, 由于避免了 PSO 中粒子向自身历史最佳位置或群体历史最佳位置聚集而形成的种群快速趋同效应, 其预测精度全部高于 PSOBP 模型和 BP 模型, 说明 MPSOBP 预测模型对实测交通流的预测是有效的.

表 1 实测交通流时间序列不同训练样本的预测误差

训练样本数	1200	1000	800	600	400	
预测样本数	30	30	30	30	30	
MAE	BP 模型	24.1353	25.5804	34.2720	31.1454	37.6787
	PSOBP 模型	25.4632	26.5499	29.0602	30.5280	33.0644
	MPSOBP 模型	22.7096	23.5779	26.2551	23.4968	28.1463
perr	BP 模型	0.0150	0.0158	0.0365	0.0263	0.0364
	PSOBP 模型	0.0144	0.0158	0.0216	0.0258	0.0305
	MPSOBP 模型	0.0134	0.0136	0.0164	0.0130	0.0204

从表 1 还可以看出, 训练样本越少, MPSOBP 模型的预测精度比 PSOBP 模型和 BP 模型提高得越多, 这对短时交通流实现小样本预测具有重要意义.

## 6 结束语

针对 BP 神经网络预测存在局部极小缺陷和收敛速度慢的问题, 在 PSO 算法中引入自适应变异算子, 提出了一种基于改进 PSO 算法优化 BP 神经网络的时间序列预测方法. 将其应用于微观实测交通流预测, 并与 PSOBP 预测模型和 BP 模型进行了比较. 结果表明: 该方法大大降低了 BP 神经网络预测模型陷入局部极小值的可能、提高了模型收敛速度. 相对于 PSOBP 预测模型和 BP 预测模型, 该方法对实测交通流具有更好的非线性拟合能力和更高的预测精度.

## 参考文献

- [1] 贺国光, 李宇, 马寿峰. 基于数学模型的短时交通流预测方法探讨 [J]. 系统工程理论与实践, 2000, 20(12): 51-56.  
He G G, Li Y, Ma S F. Discussion on short-term traffic flow forecasting methods based on mathematical models[J]. Systems Engineering — Theory & Practice, 2000, 20(12): 51-56.
- [2] 王东山, 贺国光. 交通混沌研究综述与展望 [J]. 土木工程学报, 2003(1): 68-73.  
Wang D S, He G G. Summary and prospects of the study on traffic chaos[J]. China Civil Engineering Journal, 2003(1): 68-73.
- [3] 李松, 贺国光, 张杰. 车头间距与高速公路交通流混沌 [J]. 西南交通大学学报, 2007, 42(3): 304-308.  
Li S, He G G, Zhang J. Relationship between distance headway and chaos in traffic flow on expressway[J]. Journal of Southwest Jiaotong University, 2007, 42(3): 304-308.
- [4] 董超俊, 刘智勇. 多层混沌神经网络及其在交通量预测中的应用 [J]. 系统仿真学报, 2007, 19(19): 4450-4453.  
Dong C J, Liu Z Y. Multi-layer neural network Involving chaos neurons and Its application to traffic-flow prediction[J]. Journal of System Simulation, 2007, 19(19): 4450-4453.
- [5] 吴昊. 交通流理论中的混沌特性识别及预测研究 [D]. 西安: 长安大学, 2010.  
Wu H. Based on traffic flow and chaos theory of traffic flow chaos identification and prediction research[D]. Xi'an: Chang'an University, 2010.
- [6] 张玉梅, 曲仕茹, 温凯歌. 基于混沌和 RBF 神经网络的短时交通流量预测 [J]. 系统工程, 2007, 25(11): 30-34.  
Zhang Y M, Qu S R, Wen K G. A short-term traffic flow forecasting method based on chaos and RBF neural network[J]. Systems Engineering, 2007, 25(11): 30-34.
- [7] 李松, 刘力军, 郭海玲. 短时交通流混沌预测方法的比较 [J]. 系统工程, 2009, 27(9): 60-64.  
Li S, Liu L J, Guo H L. Comparative of the predictive method of chaos in short-term traffic flow[J]. Systems Engineering, 2009, 27(9): 60-64.
- [8] 张玉梅, 曲仕茹. 基于混沌的交通流量 Volterra 自适应预测模型 [J]. 计算机应用研究, 2010, 27(12): 4486-4488.  
Zhang Y M, Qu S R. Adaptive Volterra prediction model for traffic flow based on chaos[J]. Application Research of Computers, 2010, 27(12): 4486-4488.
- [9] 臧洌. 人工神经网络在混沌观测时序数据处理中的应用 [J]. 数据采集与处理, 2001, 16(4): 98-101.  
Zang L. Application of neural network to analysis and treatment of chaotic observation time series[J]. Journal of Data Acquisition & Processing, 2001, 16(4): 98-101.
- [10] Kennedy J, Eberhart R C. Particle swarm optimization[C]// Proceedings of the 4th IEEE International Conference on Neural Networks, Piscataway: IEEE Service Center, 1995, 4: 1942-1948.
- [11] Ling S H, Iu H, Leung F H F, et al. Improved hybrid particle swarm optimized wavelet neural network for modeling the development of fluid dispensing for electronic packaging[J]. IEEE Transactions on Industrial Electronics, 2008, 55(9): 3447-3460.