

# 基于 IPSO 的模糊神经网络优化及交通流量预测

金成均<sup>1</sup> 常桂然<sup>1</sup> 程 维<sup>2</sup> 姜慧研<sup>2</sup>

(东北大学信息科学与工程学院 沈阳 110819)<sup>1</sup> (东北大学软件学院 沈阳 110819)<sup>2</sup>

**摘要** 在基于模糊神经网络的交通流量预测中,神经网络的各节点参数优化是最关键的。采用粒子群算法优化模糊神经网络的参数。针对粒子群算法易于陷入局部最优的缺点,提出一种改进的粒子群优化算法,并将改进的算法用于路口交通流量预测。仿真结果表明,该算法的收敛速度和预测精度优于传统粒子群算法、BP 算法,提高了交通流量预测的精度和速度。

**关键词** 模糊神经网络,粒子群优化,交通流量预测

中图分类号 TP183 文献标识码 A

## Fuzzy Neural Networks Based on IPSO for Traffic Flow Prediction

JIN Cheng-jun<sup>1</sup> CHANG Gui-ran<sup>1</sup> CHENG Wei<sup>2</sup> JIANG Hui-yan<sup>2</sup>

(School of Information Science and Engineering, Northeastern University, Shenyang 110819, China)<sup>1</sup>

(Software College, Northeastern University, Shenyang 110819, China)<sup>2</sup>

**Abstract** In a traffic flow prediction based fuzzy neural network, the optimization of the parameters of the nodes is very critical. An improved particle swarm optimization method was used to optimize the fuzzy neural network parameters to improve the precision and speed of vehicle prediction by fuzzy neural networks. Simulation results show that the accuracy of method is faster and accuracy is more accurate than PSO and BP algorithm, and the fuzzy neural network prediction model based on IPSO is an effective method for traffic flow prediction.

**Keywords** Fuzzy neural network, Particle swarm optimization, Traffic flow prediction

## 1 引言

交通流量预测本身的非线性和复杂性、不确定性,使得无模型方法受到广泛重视。近年来出现了一些精度更高的无模型预测方法,其中把模糊神经网络(Fuzzy Neural Network, FNN)应用于交通流量的预测取得了较好的结果<sup>[2]</sup>。模糊神经网络结合了模糊系统的逻辑推理能力以及神经网络的自学习能力,使其既具备强大的结构性知识表达能力,又具备自身参数调整优化的能力。

在模糊神经网络结构确定的情况下,如何确定网络中各节点的参数,即网络的学习算法,是目前交通流量预测模型研究的热点之一。模糊神经网络的学习算法通常采用误差反向传播算法(Error Back-propagation, BP)<sup>[6]</sup>。但是由于 BP 算法固有的局限性使得 FNN 的学习过程很容易陷入局部极小点,并且如果解的周围平坦,会使学习过程变得相当缓慢,严重影响了模糊神经网络的在线应用。

近年来,有些文献将粒子群算法引入到神经网络的学习过程中,得到了较好的结果<sup>[2-6]</sup>。粒子群算法(Particle Swarm Optimization, PSO)属于进化算法的一种,与遗传算法相似,通过迭代寻找最优解。但是它比遗传算法规则更为简单,通过追踪当前搜索到的最优值来寻找全局最优。粒子群算法虽

然有很多优点,但同样存在算法精度较低、易发散等缺点,尤其是在优化过程中容易陷入局部最优点,导致算法“早熟”现象。

因此,本文提出了一种改进的粒子群算法,即采用抛物线对粒子群算法的惯性权值和学习因子进行调整,提高种群多样性以避免“早熟”现象。仿真结果表明,采用这种方法进行交通流量预测,可以得到较好的实时预测结果。

## 2 模糊神经网络与粒子群算法

### 2.1 模糊神经网络

模糊神经网络(FNN)是模糊理论和神经网络相结合的非线性人工智能系统<sup>[2,3]</sup>。目前,模糊系统与神经网络有多种融合方式。本文研究基于 T-S 模型而建立的模糊神经网络, T-S 模型利用神经网络实现模糊控制,即基于神经网络结构的模糊控制。T-S 模型的特点是规则的前件采用模糊量形式,后件采用精确量线性集结的形式<sup>[4]</sup>。T-S 模糊神经网络的第  $j$  条规则可以写成:

if  $x_1$  is  $A_1^j, x_2$  is  $A_2^j, \dots, x_n$  is  $A_n^j$  then  $y_j = a_0^j + a_1^j x_1 + a_2^j x_2 + \dots + a_n^j x_n$ , 其中  $x_i$  为第  $i$  个输入变量,  $i=1, 2, \dots, n$ ,  $n$  为输入变量的个数;  $A_i^j$  为第  $i$  个输入变量的第  $j$  个模糊集,  $j=1, 2, \dots, m$ ;  $y_j$  为第  $j$  条规则的输出,为模糊规则线性参数。

到稿日期:2011-12-10 返修日期:2012-04-04 本文受国家自然科学基金项目(60903159),中央高校基本科研业务费专项资金项目(N100604012)资助。

金成均(1971—),男,博士生,主要研究方向为嵌入式系统、智能交通, E-mail: cxjcn@163.com。

$$\mu(x) = e^{-\frac{(x-c)^2}{2\delta^2}} \quad (1)$$

式(1)为高斯隶属函数,其中  $c, \delta$  为实数参数。神经网络的输出见式(2):

$$Y = \sum \omega_j y_j$$

$$\omega_j = \frac{\mu_j}{\sum \mu_k} \quad (2)$$

式中,  $\mu_j$  为模糊集的隶属函数值。有 2 个输入和 4 条模糊规则的 T-S 模糊神经网络的结构如图 1 所示。由图 1 可知, T-S 模糊神经网络由数据输入层(第一层)、模糊化层或隶属度计算层(第二层)、模糊处理层(第三层)、每条条件计算层(第四层)及输出层(第五层)组成。




图 1 T-S 模糊神经网络的结构图

FNN 的优化过程就是对神经网络的参数进行训练的过程。

## 2.2 粒子群算法

粒子群算法 PSO 基于群体和适应度的概念,来源于对具有社会性组织群体的研究<sup>[1-9]</sup>。在粒子群算法中,每个优化问题的解都被看作是搜索空间中的一只鸟,也就是粒子。所有的粒子都根据适应度函数计算出一个适应值,同时每个粒子还有一个速度,这两个值决定它们飞翔的方向和距离。这样,粒子们就会追随当前的最优粒子在解空间中进行搜索。

设:

$X_i = (x_{i1}, x_{i2}, \dots, x_{in})$  为粒子  $i$  的当前位置;  $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$  为粒子  $i$  的当前飞行速度;  $P_i = (p_{i1}, p_{i2}, \dots, p_{in})$  为粒子  $i$  所经历过的最好位置,称为个体最好位置;  $P_g = (p_{g1}, p_{g2}, \dots, p_{gn})$  为所有粒子经历过的最好位置,称为全局最好位置。

PSO 算法的进化方程为:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 (p_{ij} - x_{ij}(t)) + c_2 r_2 (p_{gj} - x_{ij}(t)) \quad (3)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (4)$$

式中,  $\omega$  为惯性权重,  $c_1, c_2$  为学习因子,  $r_1, r_2$  为两个相互独立的均匀分布的  $(0, 1)$  间的随机数。

基于粒子群算法的模糊神经网络优化的基本流程如下:

首先随机产生初始的粒子群,给每个粒子都赋予一个随机位置和速度。每个粒子是由模糊神经网络的各个参数(前件参数和后件线性参数)构成的,即每个粒子代表一个特定的 FNN 结构。每个粒子的维数由模糊神经网络中需要训练的参数个数决定。其次,评价每个粒子的适应度值。根据适应度值最大原则来确定每个粒子的  $P_i$  和粒子群的  $P_g$ 。然后再根据 PSO 算法的进化方程,计算每个粒子的飞行速度,从而产生新的粒子位置。如此循环,直到适应度值达到要求,或者达到最大迭代次数。整个算法结束后,就会得到一个可以用

于预测的模糊神经网络。

## 3 粒子群算法的改进

粒子群算法结构简单,运行速度较快。在寻优过程中,如果某个粒子找到一个局部最优值,其它粒子将迅速向其移动,这样就会陷入局部最优值,从而失去找到全局最优解的机会,发生“早熟”现象。近年来国内外的许多研究者针对这些缺点做了大量的工作,并提出了各种改进的 PSO 算法<sup>[1-7]</sup>。

### 3.1 惯性权重和学习因子的改进

粒子群算法中存在比较重要的几个参数:惯性权重  $\omega$ 、学习因子  $c_1$  和  $c_2$ 。

惯性权重  $\omega$  的取值对算法性能有影响。由于固定惯性权重  $\omega$  往往无法获得好的效果,因此在搜索过程中其随迭代代数对参数进行调整。较大的  $\omega$  值有利于跳出局部最优值,而较小的  $\omega$  值有利于算法收敛。近年来国内外的研究者针对这些缺点做了大量的工作,并提出了各种改进的 PSO 算法。一种经典的方法是线性递减权重(LDIW)的方法<sup>[1,2,8]</sup>:

$$\omega = (\omega_{start} - \omega_{end}) \frac{iter_{max} - iter}{iter_{max}} + \omega_{end} \quad (5)$$

式中,  $\omega_{start}$  和  $\omega_{end}$  分别为惯性权重的初始值和最终值,  $iter_{max}$  和  $iter$  分别为算法的最大迭代次数和当前迭代代数。

根据文献[6],凹函数递减策略优于线性策略,而线性策略优于凸函数策略。

因此,为了在全局搜索和局部搜索之间取得较好的平衡,本文采用抛物线对权重加以改进。本文利用抛物线的特点,在初始阶段的下降速度大于线性递减权重,而随着迭代次数的增加,下降速度逐渐减慢。

$$\omega = \omega_{start} + (\omega_{end} - \omega_{start}) \left( \frac{2 \times iter}{iter_{max}} \right) + (\omega_{start} - \omega_{end}) \left( \frac{iter}{iter_{max}} \right)^2 \quad (6)$$

以式(6)构造的惯性因子,初期具有最大值,迭代的最后一步达到最小值,中间迭代周期是非线性减小的,目的是在迭代的早期加大惯性权重的递减速度以使算法更快地进入局部搜索,均衡全局和局部搜寻能力。

PSO 算法中,学习因子  $c_1$  和  $c_2$  分别控制“认知”部分和“社会”部分对粒子速度的影响。合适的  $c_1$  和  $c_2$  可以加快收敛且不易陷入局部最优。一般来说,在 PSO 算法中,总是希望个体在初始阶段能够在整个寻优空间进行搜索,而在结束阶段希望能够提高算法的收敛速度和精度,以有效地寻找到全局最优解。

在迭代过程中,本文动态地改变  $c_1$  和  $c_2$  的值,使得在算法的初始阶段具有大的“认知”部分(大的  $c_1$ )和小的“社会”部分(小的  $c_2$ ),以利于算法在整个寻优空间进行搜索。而在算法后期,应该有小“认知”部分(小的  $c_1$ )和大的“社会”部分(大的  $c_2$ ),以更利于算法收敛于全局最优解,提高算法的收敛速度和精度。为此,取  $c_1$  和  $c_2$  分别如下:

$$c_1 = c_{1start} + (c_{1end} - c_{1start}) \left( \frac{2 \times iter}{iter_{max}} \right) + (c_{1start} - c_{1end}) \left( \frac{iter}{iter_{max}} \right)^2$$

$$c_2 = c_{2end} + (c_{2start} - c_{2end}) \left( \frac{2 \times iter}{iter_{max}} \right) + (c_{2end} - c_{2start}) \left( \frac{iter}{iter_{max}} \right)^2 \quad (7)$$

式中,  $c_{1start}$  和  $c_{1end}$  ( $1 \leq c_{1end} < c_{1start} \leq 2$ ) 分别为学习因子  $c_1$  的初始值和最终值;  $c_{2start}$  和  $c_{2end}$  ( $0.5 \leq c_{2end} < c_{2start} \leq 1$ ) 分别为学

习因子  $c_2$  的初始值和最终值。

### 3.2 保持种群多样性

随着种群的不断进化,粒子之间的差异越来越小,而粒子的位置决定着粒子的适应度大小。因此,根据种群中所有粒子的适应度的整体变化可以判断种群的状态。PSO 算法运行若干代之后,所有的粒子都会趋近于  $P_g$ 。如果当前的  $P_g$  是一个局部最优点,那么一旦所有粒子都收敛于这一点之后,这些粒子就很难跳出这个局部最优点,从而无法得到正确的结果。造成这种现象的原因之一,是 PSO 算法中粒子的多样性迅速消失。为了降低陷入局部最优点的机会,始终保持粒子具有一定的多样性,从而引入遗传算法的交叉算子。当算法运算过程中  $P_g$  连续  $k$  代无变化时,说明此时算法出现停滞,且种群多样性较差。

有些研究者<sup>[7-9]</sup>提出了用遗传算法的“变异”和“交叉”运算来增强种群多样性的 GA-PSO。虽然这些研究工作已经给出了提高粒子群算法的全局搜索能力的方法,但是它们很难在提高搜索速度和保持种群多样性之间达到平衡。

变异运算只是产生新个体的辅助方法,决定了遗传算法的局部搜索能力;而交叉运算决定了遗传算法的全局搜索能力,因此,本文采用遗传算法中的交叉运算来产生新的粒子群。

$$\begin{aligned} X_k &= PX_i + (1-P)X_j \\ V_k &= PV_i + (1-P)V_j \end{aligned} \quad (8)$$

式中,  $X$ 、 $V$  分别为粒子的位置和速度,  $P$  为交叉率:

$$P = \begin{cases} 2/3 \cdot (f_{\max} - f_c) / (f_{\max} - \bar{f}), & f_c \geq \bar{f} \\ 2/3, & f_c < \bar{f} \end{cases} \quad (9)$$

式中,  $f_c$  为交叉的两个粒子中较大的适应值,  $f_{\max}$ 、 $\bar{f}$  分别为粒子群的最大适应值和平均适应值。

### 3.3 模糊神经网络的优化过程

设粒子群的种群规模为  $M$ 。基于 IPSO 算法的模糊神经网络的优化过程如下:

- 步骤 1 根据初始约束条件,初始化粒子群。
- 步骤 2 根据预先定义的训练样本,计算网络的输出。
- 步骤 3 评价每个粒子的适应值。

$$f(X_i) = \frac{1}{1 + Err(X_i)} \quad (10)$$

$$Err(X_i) = \frac{1}{2} \sum_{k=1}^N (T_k(X_i) - Y_k(X_i))^2$$

式中,  $Y_k(X_i)$  为网络的实际输出;  $T_k(X_i)$  为期望输出;  $f(X_i)$  为适应函数,适应度值表示神经网络的误差,误差越小则表明粒子在搜索中的性能越好。

步骤 4 根据粒子的适应值,选择  $P_i$  和  $P_g$ 。

步骤 5 如果  $P_g$  连续进化  $K$  次未有变化,则继续执行步骤 6,否则转步骤 7。

步骤 6 从原有粒子中随机选择  $M/2$  个粒子,根据式(8)、式(9)进行交叉,得到  $M/2$  个新的粒子。

步骤 7 根据式(3)、式(4)、式(6)、式(7),更新粒子的位置和速度。

步骤 8 若 PSO 的训练误差大于  $Err$ ,转步骤 2。

步骤 9 在 IPSO 全局寻优的基础上,运行 BP 算法,进行局部细致搜索。BP 算法有学习速度慢的缺点,但是该算法有比 PSO 算法在解点附近快速、精确收敛的特点<sup>[6]</sup>。因此,本文在 PSO 算法的后阶段中加入 BP 算法,以提高优化算法的

收敛性。

步骤 10 判断终止条件是否满足,若满足,则算法结束,否则转步骤 9。

## 4 实验结果

为了验证基于本算法的模糊神经网络应用于交通车辆预测的有效性,分别使用 LDIW-PSO、GA-PSO、PSO+BP、本文算法对模糊神经网络进行训练,对交通车辆预测结果进行了比较。

实验环境为 Intel Core2 Dual 2.5GHz, 1GB RAM, 使用 Visual C++ 6.0 和 Matlab 7.0。实验数据来源于文献<sup>[7]</sup>, 采样时间  $T=2\text{min}$  (2 分钟的流量), 数据采集长度为 7。2min 内的数据(218 个)为  $x(t-1)$ ,  $x(t)$  为输入,  $x(t+l)$  为输出(共 216 个输入输出对)。前 196 对数据用于对网络的训练,后 20 对数据用于测试。为了简化实验,利用 2 个输入和 4 条规则的模糊神经网络(需要训练的参数共 20 个,隶属函数的参数 8 个,模糊规则线性参数 12 个)进行车辆预测。

### 4.1 模糊神经网络的学习

本文用 180 个样本数据对模糊神经网络进行训练。实验参数设置为:种群个数 40,  $P_g$  的无变化迭代次数  $K=5$ , BP 算法的学习率  $\beta=0.01$ , PSO 算法的终止条件为迭代次数大于 300 或者误差  $Err$  为 0.255。

图 2 为本文算法和其他算法的训练过程比较。从图 2 可以直观地看出:本文的算法在出现停滞(迭代次数 50,就是说,  $P_g$  若干代无变化时)时,能及时跳出局部极值点,在解空间的其他范围内进行搜索,具有较强的全局搜索能力和较快的收敛速度。而 LDIW-PSO 算法一旦收敛于某个极值点(在图 2 中迭代次数 130 以后)后就很难跳出这个极值点,最终只能收敛于该点。




图 2 本文算法与其他算法的训练误差曲线

算法的初始阶段(迭代次数 100 以前), GA-PSO 算法的收敛速度比其他算法(LDIW-PSO 算法、PSO+BP 算法)快,在算法后期,算法的精度和速度不如其他算法(本文算法和 PSO+BP 算法),不适合 FNN 的实时学习。由图 2 可以看出,相比于 LDIW-PSO 算法、GA-PSO 算法, PSO+BP 算法具有较好的收敛性,但其收敛速度和正确性不如本文算法。

从表 1 可以看出,本算法的平均学习时间为 200ms,比其他算法更快,其有利于实时学习。

表 1 FNN 学习时间结果对比

算法	平均迭代次数	平均学习时间(ms)
LDIW-PSO	300 以上	730 以上
GA-PSO	300 以上	500 以上
PSO+BP	300	460
本文算法	250	200

(下转第 230 页)

and neighborhood systems[M]. Rough Sets and Knowledge Discovery, 1998;107-121

- [3] Lin T Y. Granular computing on binary relations II: rough set representations and belief functions [M]. Rough Sets and Knowledge Discovery, 1998;122-140
- [4] Lin T Y. Granular computing: practices, theories, and future directions[M]. Encyclopedia on Complexity of Systems Science, 2009;4339-4355
- [5] Yao Y Y. Stratified rough sets and granular computing[C]// Proceedings of the 18th International Conference of the North American Fuzzy Information Processing Society. 1999;800-804
- [6] Yao Y Y. Granular computing: basic issues and possible solutions[C]// Proceedings of the 5th Joint conference on Information Sciences. Atlantic, USA, 2000;186-189
- [7] Yao Y Y, Yao J T. Granular computing as a basis for consistent

classification problems[C]// Proceedings of PAKDD'02 workshop on Foundations of Data Mining. CIICM, Taiwan, 2002; 101-106

- [8] 刘清, 刘群. 粒及粒计算在逻辑推理中的应用[J]. 计算机研究与发展, 2004, 41(4): 546-551
- [9] 张文修, 徐伟华. 基于粒计算的认知模型[J]. 工程数学学报, 2007, 24(6): 957-971
- [10] 王国胤, 张清华. 不同知识粒度下粗糙集的不确定性研究[J]. 计算机学报, 2008, 31(9): 1588-1598
- [11] 胡军, 王国胤. 覆盖粒度空间的层次模型[J]. 南京大学学报: 自然科学版, 2008, 44(5): 551-558
- [12] 张清华, 王国胤, 刘显全. 分层递阶的模糊商空间结构分析[J]. 模式识别与人工智能, 2008, 21(5): 627-634
- [13] 苗夺谦, 王国胤, 刘清, 等. 粒计算: 过去、现在与展望[M]. 北京: 科学出版社, 2007

(上接第 192 页)

## 4.2 交通车辆预测

本文用训练好的 FNN 进行车辆预测, 并对预测结果进行分析。以某一个城市的公路某一段交通流量实测数据<sup>[10]</sup>为例, 进行预测仿真实验。将 216 个输入输出对中的后 20 对数据作为预测仿真数据。一般情况下, 可利用平均绝对误差率(MAPE)来评价网络的性能优劣。因此, 为了评价算法的正确度, 将平均绝对误差率作为评价指数。

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (11)$$

式中,  $n$  为样本数据数,  $y_t$  和  $\hat{y}_t$  分别为实际值和预测值。

表 2 FNN 的车辆预测精度(平均绝对误差率)

实际车辆 (pcu/h)	本文方法		LDIW-PSO 方法		GA-PSO 方法		PSO+BP 方法	
	预测 结果	相对 误差	预测 结果	相对 误差	预测 结果	相对 误差	预测 结果	相对 误差
6025	5363	0.110	5245	0.129	5145	0.146	4820	0.200
5135	5007	0.025	5109	0.005	5005	0.025	5176	0.008
4945	4812	0.027	4517	0.087	4795	0.030	4906	0.008
4425	4632	0.047	4183	0.055	4589	0.037	4635	0.047
4802	4585	0.045	3677	0.234	4575	0.047	4435	0.076
5880	4581	0.221	3886	0.339	4501	0.235	4476	0.239
6105	4742	0.223	4574	0.251	4753	0.221	4868	0.203
5883	5197	0.117	4945	0.159	5225	0.112	5013	0.148
5490	4913	0.105	4895	0.108	5890	0.073	5107	0.070
4820	5017	0.041	4654	0.034	4654	0.034	5071	0.052
4507	4720	0.047	4150	0.079	4250	0.057	4605	0.022
4812	4584	0.047	3559	0.260	5310	0.103	4428	0.080
4905	4586	0.065	3868	0.211	5868	0.196	4482	0.086
5475	4609	0.158	4062	0.258	4559	0.167	4562	0.167
5918	4684	0.209	4406	0.255	4660	0.213	4895	0.173
6224	4940	0.206	4757	0.236	7547	0.213	4991	0.198
5879	5221	0.112	5012	0.147	5012	0.147	4982	0.153
5722	4907	0.142	4923	0.140	4910	0.142	5128	0.104
5609	5082	0.094	4763	0.151	4985	0.111	5089	0.093
5485	5326	0.029	4920	0.103	4985	0.048	5226	0.047
平均绝对误差率		0.104		0.162		0.118		0.109

车辆预测仿真结果如表 2 所列。由表 2 可以看出, 基于更新粒子群算法的 FNN 的交通流量预测方法具有较高的准确性。采用本文算法的 FNN 的车辆预测平均绝对误差率为 0.104, LDIW-PSO 算法、GA-PSO 算法、PSO+BP 算法的平

均绝对误差率分别为 0.162、0.118、0.109。

**结束语** 本文针对车辆预测问题, 提出了一种基于 IPSO 的模糊神经网络的交通车辆预测方法。本文对 PSO 算法进行了两个方面的改进, 即改进了 PSO 算法的惯性权重、学习因子且增强了种群多样性; 其次在 IPSO 中加入了一个 BP 算法。试验结果表明了, 本文的算法有效解决了 PSO 算法的“早熟”现象, 充分利用了 PSO 算法的全局搜索能力, 进一步提高了模糊神经网络的训练效率和车辆预测结果。

## 参考文献

- [1] Shi Y, Eberhart R C. A modified particle swarm optimizer. Proceedings of the IEEE Congress on Evolutionary Computation [C]// Piscataway: IEEE Press. 1998; 303-308
- [2] 于万霞, 杜太行, 于越. 基于粒子群的模糊神经网络交通量预测[J]. 微计算机信息, 2008, 24(4): 232-233
- [3] 刘坤, 谭营, 何新贵. 基于粒子群优化的过程神经网络学习算法[J]. 北京大学学报: 自然科学版, 2011, 47(2): 238-244
- [4] 李秀英, 韩志刚. 基于粒子群算法优化的 T-S 型模糊神经网络控制器[J]. 黑龙江大学自然科学学报, 2010, 27(4): 272-276
- [5] 陈贵敏, 贾建援, 韩琪. 粒子群优化算法的惯性权值递减策略研究[J]. 西安交通大学学报, 2006, 40(1): 53-56
- [6] 李雄军, 罗建旭, 黄娟. 基于 PSO 和 BP 复合算法的模糊神经网络控制器[J]. 自动化与仪器仪表, 2010(2): 1-3
- [7] Li Lin-yi, Li De-ren. Fuzzy entropy image segmentation based on particle swarm optimization[J]. Progress in Natural Science, 2008, 18(9): 1167-1171
- [8] 朱红求, 阳春华, 桂卫华. 一种带混沌变异的粒子群优化算法[J]. 计算机科学, 2010, 37(3): 215-217
- [9] 刘衍民, 牛奔, 赵庆祯. 基于交叉和变异的多目标粒子群算法[J]. 计算机应用, 2011, 31(1): 82-84, 117
- [10] Abdulhai B, Porwal H, Recker W. Short-term freeway traffic flow prediction using genetically-optimized time-delay-based neural networks [R]. Institute of Transportation Studies, University of California, Berkeley, 1999