

文章编号: 1001-0920(2011)10-1581-05

## 遗传算法优化BP神经网络的短时交通流混沌预测

李松<sup>1</sup>, 刘力军<sup>2</sup>, 解永乐<sup>1</sup>

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

**摘要:** 为了提高BP神经网络预测模型对混沌时间序列的预测准确性, 提出了一种基于遗传算法优化BP神经网络的改进混沌时间序列预测方法. 利用遗传算法优化BP神经网络的权值和阈值, 然后训练BP神经网络预测模型以求得最优解, 并将该预测方法应用到几个典型混沌时间序列和实测短时交通流时间序列进行有效性验证. 仿真结果表明, 该方法对典型混沌时间序列和短时交通流具有较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; 混沌理论; BP神经网络; 遗传算法

**中图分类号:** U491.1

**文献标识码:** A

## Chaotic prediction for short-term traffic flow of optimized BP neural network based on genetic algorithm

LI Song<sup>1</sup>, LIU Li-jun<sup>2</sup>, XIE Yong-le<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. Correspondent: LI Song, E-mail: lees3432@163.com)

**Abstract:** In order to improve the prediction accuracy of BP neural network model for chaotic time series, a prediction method for chaotic time series of optimized BP neural network based on genetic algorithm(GA) is presented. The GA is used to optimize the weights and thresholds of BP neural network, and the BP neural network is trained to search for the optimal solution. The efficiency of the proposed prediction method is tested by the simulation of several typical nonlinear systems and time series of real traffic flow. The simulation results show that the proposed method has better fitting ability and higher accuracy.

**Key words:** traffic flow prediction; chaotic theory; BP neural network; genetic algorithm

### 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. 城市交通流系统具有明显的混沌特征, 其短时交通流采样数据即为典型的混沌时间序列, 在此基础上进行预测的基本思想就是构造一个非线性映射来近似地还原原系统, 这一非线性映射即为要建立的预测模型. 神经网络是一个具有高度非线性的动力学系统, 它具有强大的非线性拟合能力, 可以寻找一种非线性函数来逼近嵌入空间吸引子轨迹状态的映射关系, 使其在混沌时间序列预测方面有特定的优势. 许多学者在这一领域进行了深入研究, 建立了多种交通流预测模型, 如BP神经网络模型<sup>[1]</sup>、RBF神经网络模型<sup>[2]</sup>以及Volterra滤波器自适应预测模型<sup>[3]</sup>. 其

中BP神经网络模型是应用最广泛的预测模型, 但该模型有两个明显的缺点: 一是易陷入局部极小值; 二是收敛速度慢. 克服上述缺点的一种方法是采用遗传算法(GA)优化的BP神经网络预测模型. 文献[4-5]单纯地利用GA来优化BP神经网络预测模型, 在其预测算法中, 不仅没有考虑短时交通流的混沌特性, 而且BP神经网络预测算法也存在缺陷.

本文从非线性混沌时间序列角度出发, 将BP神经网络和GA有机融合, 提出了一种基于GA优化BP神经网络的改进混沌时间序列预测算法. 该算法利用GA来弥补BP神经网络连接权值和阈值选择上的随机性缺陷, 不仅能发挥BP神经网络泛化的映射能力, 而且使BP神经网络具有较快的收敛性以及较强的学习能力. 利用该算法对3个典型混沌时间序列和

收稿日期: 2010-06-28; 修回日期: 2010-09-20.

基金项目: 国家自然科学基金项目(50478088); 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, 教授, 博士, 从事交通系统工程、智能交通控制等研究; 刘力军(1970-), 男, 副教授, 博士, 从事交通系统工程、智能交通控制等研究.

短时交通流时间序列进行了建模和预测分析, 结果表明该方法对于典型混沌时间序列和短时交通流具有较好的非线性拟合能力和较高的预测精度.

## 2 混沌时间序列的 BP 神经网络预测算法

相空间重构理论是混沌时间序列预测的基础. Packard 等人<sup>[6-7]</sup>提出用延迟坐标法对混沌时间序列  $x_1, x_2, \dots, x_n$  进行相空间重构, 则在状态空间中重构的某一点状态矢量可以表示为

$$X_i = (x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau})^T, \quad (1)$$

$$i = 1, 2, \dots, M.$$

其中:  $M = n - (m - 1)\tau$  为重构相空间中相点的个数,  $\tau$  为延迟时间,  $m$  为嵌入维数.

典型的 3 层 BP 神经网络预测混沌时间序列, 其输入层神经元数为  $m$  时的预测效果较好<sup>[8]</sup>, 选择其隐层神经元数为  $p$ , 输出层神经元数为 1, 则 BP 神经网络完成映射  $f: R^m \rightarrow R^1$ , 其数学表达式为

$$x_{i+1} = f(X_i) = \frac{1}{1 + \exp\left(-\sum_{j=1}^p v_j b_j + \gamma\right)}. \quad (2)$$

其中:  $v_j$  为隐层至输出层的连接权值,  $\gamma$  为输出层的阈值,  $b_j$  为隐层节点的输出. BP 神经网络转移函数采用 Sigmoid 函数  $f(x) = 1/(1 + e^{-x})$ , 则有

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

$$j = 1, 2, \dots, p.$$

其中:  $w_{ij}$  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 (2) 即为 BP 神经网络的混沌时间序列预测模型, 用 BP 神经网络来预测混沌时间序列, 其隐层神经元数  $p$  一般可取经验值  $2m + 1$ .

## 3 GA 优化 BP 神经网络的混沌时间序列的预测算法

### 3.1 基本思路

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变慢, 且容易使最终结果为非最优解. 作为一种全局优化随机搜索算法, GA 通过遗传算子模拟遗传过程中出现的复制、交叉和变异等现象, 对种群个体逐代择优, 从而最终获得最优个体. 采用 GA 对 BP 神经网络的初始权值和阈值分布进行优化, 通过选择、交叉和变异操作找到 BP 神经网络的最优初始权值和阈值, 将 GA 得到的最优个体对 BP 神经网络初始权值和阈值进行赋

值, 然后利用 BP 神经网络预测模型进行局部寻优, 从而得到具有全局最优解的 BP 神经网络预测值. 下面结合预测算法介绍具体操作.

### 3.2 GA 优化 BP 神经网络预测算法

算法基本步骤如下:

**Step 1:** 设种群规模为  $P$ . 随机生成  $P$  个个体的初始种群  $W = (W_1, W_2, \dots, W_p)^T$ , 给定一个数据选定范围, 采用线性插值函数生成种群中个体  $W_i$  的一个实数向量  $w_1, w_2, \dots, w_S$  作为 GA 的一个染色体. 为了得到高精度权值和阈值, 采用实数编码方法.

**Step 2:** 确定个体的评价函数. 给定一个 BP 神经网络进化参数, 将 Step 1 中得到的染色体对 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网络训练输出值, 以训练误差平方和作为种群  $W$  中个体  $W_i$  的适应度.

**Step 3:** 采用轮盘赌法选择算子, 即基于适应度比例的选择策略对每一代种群中的染色体进行选择. 选择概率为

$$p_i = f_i / \sum_{i=1}^P f_i, \quad i = 1, 2, \dots, P. \quad (4)$$

其中:  $f_i$  为适应度值倒数,  $P$  为种群规模.

**Step 4:** 由于个体采用实数编码, 交叉操作方法采用实数交叉法. 第  $k$  个基因  $w_k$  和第  $l$  个基因  $w_l$  在  $j$  位的交叉操作分别为

$$w_{kj} = w_{kj}(1 - b) + w_{lj}b, \quad (5)$$

$$w_{lj} = w_{lj}(1 - b) + w_{kj}b,$$

其中  $b$  为  $[0,1]$  间的随机数.

**Step 5:** 变异操作. 选取第  $i$  个个体的第  $j$  个基因进行变异操作, 即

$$w_{ij} = \begin{cases} w_{ij} + (w_{ij} - w_{\max})f(g), & r \geq 0.5; \\ w_{ij} + (w_{\min} - w_{ij})f(g), & r < 0.5. \end{cases} \quad (6)$$

$$f(g) = r_2(1 - g/G_{\max}). \quad (7)$$

其中:  $w_{\max}$  和  $w_{\min}$  分别为基因  $w_{ij}$  取值的上下界,  $r$  为  $[0,1]$  间的随机数,  $r_2$  为一个随机数,  $g$  为当前迭代次数,  $G_{\max}$  为最大进化代数.

**Step 6:** 将 GA 得到的最优个体分解为 BP 神经网络的连接权值和阈值, 以此作为 BP 神经网络预测模型的初始权值和阈值, BP 神经网络预测模型经训练后, 输出混沌时间序列预测最优解.

## 4 仿真实验

### 4.1 仿真条件

为了说明本文算法的有效性, 在 Matlab 2009 b 环境下, 采用 Matlab 语言编写算法程序, 并应用 Matlab 神经网络工具箱构建 2 种预测模型: 1) 一般的 BP 神

神经网络混沌时间序列预测模型 (BP 模型); 2) 采用 GA 优化一般 BP 神经网络的改进混沌时间序列预测模型 (GABP 模型). 应用上述 2 种预测模型分别对 3 种典型非线性系统的混沌时间序列 (Logistic, Henon, Lorenz) 进行数据预测对比实验, 对实测交通流时间序列进行交通量预测对比实验.

实验中的时间序列数据按下式处理成均值为 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:

$$y_i = \frac{x_i - \frac{1}{n} \sum_{i=1}^n x_i}{\max(x_i) - \min(x_i)}. \quad (8)$$

其中:  $\{x_i\}$  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

$$\text{err} = x_i - \hat{x}_i, \quad (9)$$

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

$$\text{perr} = \frac{\sum_{i=1}^{N_p} (x_i - \hat{x}_i)^2}{\sum_{n=1}^{N_p} x_i^2}. \quad (11)$$

其中:  $x_i$  和  $\hat{x}_i$  分别为真实值和预测值,  $N_p$  为预测样本数. BP 神经网络采用  $m - 2m + 1 - 1$  的典型 3 层结构, 其节点传递函数采用对数型 S 函数 logsig 和线性函数 purelin, 训练函数采用 L-M 优化算法 trainlm, 具体参数设置为: 训练次数取 100, 训练目标取 0.000 01, 学习率取 0.01. GA 参数设置为: 种群规模取 10, 进化代数取 100 次, 交叉概率取 0.4, 变异概率取 0.2.

### 4.2 3 种典型混沌时间序列预测

3 种典型非线性系统混沌时间序列的表达式、参数、积分时间步长、嵌入维数  $m$  和时间延迟  $\tau$  见表 1.

表 1 3 种典型非线性系统

非线性系统	表达式	参数	步长 $m/\tau$
Logistic	$x_{i+1} = \mu x_i (1 - x_i)$	$\mu = 4.0$	1 2/6
Henon	$\begin{cases} x_{i+1} = 1 - ax_i^2 + y_i \\ y_{i+1} = bx_i \end{cases}$	$\begin{cases} a = 1.4 \\ b = 0.3 \end{cases}$	1 2/1
Lorenz	$\begin{cases} \dot{x} = \sigma(y - x) \\ \dot{y} = (r - z)x - y \\ \dot{z} = xy - bz \end{cases}$	$\begin{cases} \sigma = 16 \\ r = 45.92 \\ b = 4 \end{cases}$	0.01 3/10

实验中, Logistic 和 Henon 映射按设定初始值直接迭代; Lorenz 映射用四阶 Runge-Kutta 算法积分, 时间序列取  $x$  分量. 时间序列舍去前面 7 000 点过渡点, 取后 2 000 点数据作为实验数据.

取混沌时间序列的前 1 500 个数据为训练样本,

后 500 个数据为预测检验样本. 为了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 3 分别给出了训练样本为 1 500, 预测样本为 200 时的预测结果, “\*” 分别表示 BP 预测值和 GABP 预测值, “·” 表示真实值. 表 2 给出了 2 种预测模型在不同数

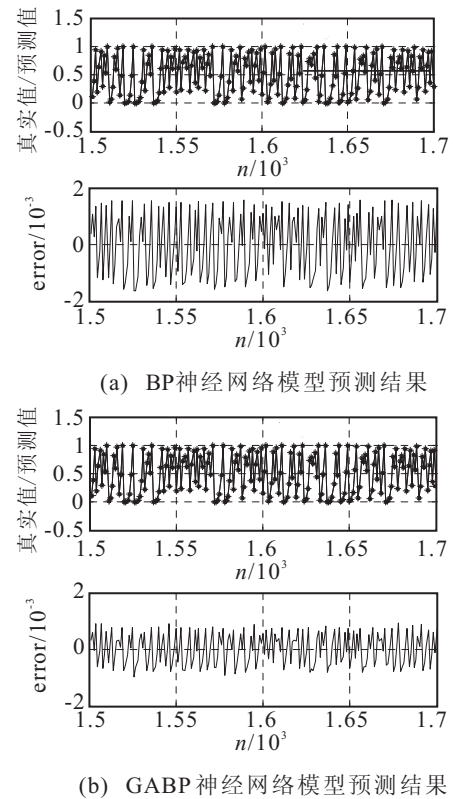


图 1 Logistic 混沌序列预测结果

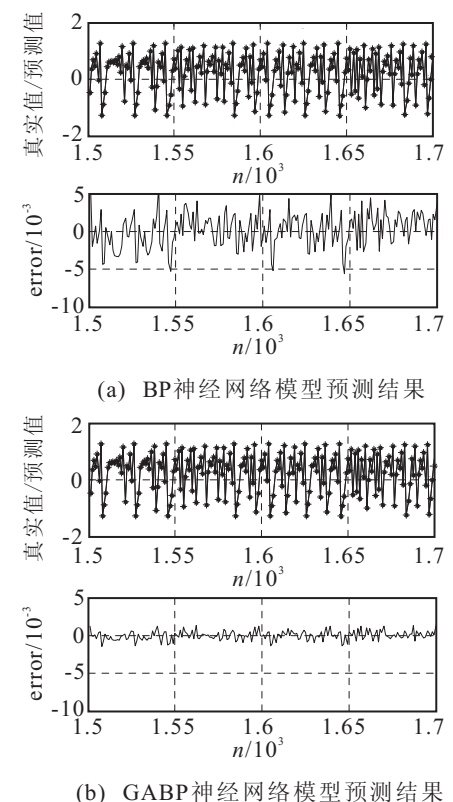


图 2 Henon 混沌序列预测结果




图 3 Lorenz 混沌序列预测结果

量训练样本条件下 200 个预测样本的预测平均绝对误差 MAE 和相对误差 perr. 从图 1~图 3 和表 2 可以看出, 对于 3 种典型非线性混沌时间序列, GABP 预测模型的非线性拟合能力和预测精度在不同训练样本下均远远高于 BP 模型, 这说明 GABP 预测算法对于典型混沌时间序列的预测是有效的. 从表 2 还可以看出, 对于不同的混沌时间序列, GABP 模型的预测精度不同; 同一混沌时间序列, 训练样本数量不同, GABP 模型的预测精度也不同. 这说明 GABP 模型和 BP 模型一样, 其预测效果不仅与训练样本数量有关, 还与混沌时间序列本身有关.

### 4.3 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 min 记录一次数据, 共产生 1302 个数据. 采用文献 [9] 中计算最大 Lyapunov 指数的改进算法, 计算得该交通流时间序列的延迟时间  $\tau$  为 2, 嵌入维数  $m$  为 5, 最大 Lyapunov 指数为 0.0143,

说明该交通流时间序列为混沌时间序列.

实验取变异概率为 0.05, 其他参数不变. 取交通流序列前 1200 个数据为训练样本, 后 102 个数据为预测检验样本, 用 GABP 模型和 BP 模型对其进行预测. 图 4 给出了训练样本为 1200, 预测样本为 30 的预测结果, “\*” 分别表示 BP 预测值和 GABP 预测值, “.” 表示真实值. 表 3 给出了 2 种预测模型在不同数量训练样本条件下 30 个预测样本的平均绝对误差 MAE 相对误差 perr. 从图 4 和表 3 可以看出, 2 种预测模型的预测结果均能较好地反映交通流量变化的趋势和规律, 经过优化的 GABP 模型预测精度稳定, 不受训练样本数量影响, 且 GABP 模型的预测精度高于 BP 模型, 这说明 GABP 预测模型对于实测短时交通流时间序列的预测是有效的. 从表 3 还可以看出, 训练样本越少, GABP 预测模型的预测精度比 BP 预测模型提高的越多, 这一特点对短时交通流实现小数据量样本的混沌预测和混沌控制具有重要意义.

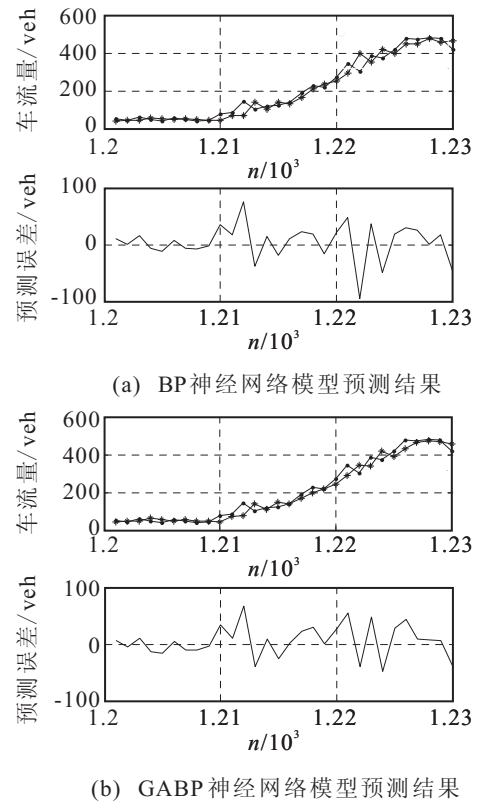


图 4 实测交通流混沌序列预测结果

表 2 3 种典型混沌时间序列不同数量训练样本的预测误差

系统	Logistic			Henon			Lorenz			
	训练样本数	1500	1000	500	1500	1000	500	1500	1000	500
MAE	BP	9.538e-04	9.651e-04	9.932e-04	0.0017	0.0019	0.0018	0.1170	0.0868	0.1128
	GABP	4.919e-04	9.829e-05	1.448e-04	3.560e-04	8.243e-04	4.627e-04	0.0508	0.0298	0.0475
Perr	BP	3.084e-06	3.309e-06	3.490e-06	8.047e-06	9.196e-06	8.426e-06	1.484e-04	7.922e-05	1.387e-04
	GABP	8.253e-07	3.166e-08	8.385e-08	3.214e-07	1.617e-06	5.979e-07	3.971e-05	1.086e-05	4.077e-05

表 3 实测交通流混沌时间序列不同训练样本预测误差

训练样本数		1200	1000	800	600	400
MAE	BP	24.135	25.580	34.272	31.145	37.679
	GABP	22.486	23.474	23.629	22.963	24.864
Prec	BP	0.0150	0.0158	0.0365	0.0263	0.0364
	GABP	0.0120	0.0136	0.0171	0.0139	0.0142

尽管 GABP 模型对于短时交通流时间序列的预测精度比 BP 预测模型有较大的提高, 但相对于典型混沌时间序列预测, GABP 模型预测精度的提升幅度还是较小, 这说明城市交通流系统具有更高的复杂性, 提高短时交通流的预测准确性不仅要从预测方法上考虑, 还要从多角度考虑。

## 5 结 论

针对 BP 神经网络存在局部极小缺陷和收敛速度慢的问题, 提出了一种基于 GA 优化 BP 神经网络的改进混沌时间序列预测模型, 将其应用于 3 种典型非线性混沌系统和实测交通流系统的预测, 并与 BP 神经网络预测模型的预测精度进行了比较. 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 BP 神经网络预测模型, 该模型对于典型混沌时间序列和短时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(References)

- [1] 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(10): 101-104.  
(Dong C J, Liu Z Y. Multi-layer neural network involving chaos neurons and its application to traffic-flow prediction[J]. J of System Simulation, 2007, 19(10): 101-104.)
- [2] 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.)

- [3] 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 study on chaotic prediction methods in short-term traffic flow[J]. Systems Engineering, 2009, 27(9): 60-64.)
- [4] 任雪莲, 陈晓芬, 马骏. 遗传-神经网络在交通流预测中的应用[J]. 交通科技与经济, 2009, 54(4): 10-12.  
(Ren X L, Chen X F, Ma J. Genetic algorithms and BP neural networks used in traffic flow forecasting[J]. Technology and Economy in Areas of Communications, 2009, 54(4): 10-12.)
- [5] 陈文, 庞琳娜. GABP 神经网络在交通流预测中的应用研究[J]. 微计算机信息, 2009, 26(14): 245-247.  
(Chen W, Pang L N. The research of the application of GABP neural network in traffic flow prediction[J]. Microcomputer Information, 2009, 26(14): 245-247.)
- [6] Takens F. Detecting strange attractors in turbulence[J]. Lecture Notes in Mathematics, 1981, 898: 361-381.
- [7] Packard N H, Crutchfield J P, Farmer J D, et al. Shaw Geometry from a time series [J]. Physical Review Letters, 1980, 45(9): 712-716.
- [8] 王洪元, 史国栋. 人工神经网络技术及其应用[M]. 北京: 中国石化出版社, 2002: 34-36.  
(Wang H Y, Shi G D. Artificial neural networks and its applications[M]. Beijing: China Petrochemical Press, 2002: 34-36.)
- [9] 李松, 贺国光. 基于最大 Lyapunov 指数改进算法的交通流混沌判别[J]. 武汉理工大学学报, 2006(5): 747-750.  
(Li S, He G G. Identification of chaos in the traffic flow based on the improved largest Lyapunov exponents algorithm[J]. J of Wuhan University of Technology, 2006, 30(5): 747-750.)
- [10] Alin A S, Christian Ott, Udo Frses, et al. Cartesian impedance control of redundant robots: Recent results with the DLR-light-weight-arms[C]. Proc of 2003 IEEE Int Conf on Robotics and Automation. Taipei, 2003: 3704-3709.
- [11] 熊根良, 刘伊威, 黄剑斌, 等. 基于 DSP/FPGA 的反步法阻抗控制柔性关节机械臂[J]. 控制与决策, 2009, 24(8): 1137-1142.  
(Xiong G L, Liu Y W, Huang J B, et al. Backstepping impedance control flexible joint manipulators using DSP/FPGA structure[J]. Control and Decision, 2009, 24(8): 1137-1142.)
- [12] 叶正茂, 赵慧, 张尚盈, 等. 基于位置内环的柔顺力控制的研究[J]. 控制与决策, 2006, 21(6): 651-655.  
(Ye Z M, Zhao H, Zhang S Y, et al. On compliant force control based on inner position loop[J]. Control and Decision, 2006, 21(6): 651-655.)
- [13] 王斌锐, 周唯逸, 许宏. 智能气动肌肉的静态驱动特性研究[J]. 农业机械学报, 2009, 40(3): 208-212.  
(Wang B R, Zhou W Y, Xu H. Static actuating characteristics of intelligent pneumatic muscle[J]. Trans of the Chinese Society for Agricultural Machinery, 2009, 40(3): 208-212.)

(上接第 1580 页)