

基于粒子群算法的模糊控制在倒立摆中的应用

曹晓燕^{1,2}, 于立萍³, 姚文韬⁴

(1. 中国海洋大学 信息科学与工程学院, 山东 青岛 266102;

2. 武汉第二船舶设计院, 湖北 武汉 430064;

3. 山东科技大学 信息与电气工程学院, 山东 青岛 266510;

4. 清华大学 智能技术与系统国家重点实验室, 北京 100084)

摘要:粒子群算法是一种仿生进化算法,源于对鸟群觅食行为的模拟,由于其计算简单、快速,被广泛应用。但是,基本粒子群算法在求解的过程中存在着全局搜索能力和局部求精能力两个性能指标之间的矛盾,算法容易陷入局部极值,进化后期的收敛速度慢。针对上述问题,提出了基于混沌变异算子的粒子群算法,可以使粒子摆脱局部极值,继续优化,加快收敛速度。将基于混沌变异的粒子群算法与模糊算法相结合,用于控制倒立摆系统的平衡。仿真实验表明,混沌变异粒子群算法优化了倒立摆系统模糊控制器的设计,改善了控制效果。

关键词:粒子群;混沌;模糊控制;倒立摆

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2008)06-0151-05

Particle Swarm Optimization in Fuzzy Control of an Inverted Pendulum

CAO Xiao-yan^{1,2}, YU Li-ping³, YAO Wen-tao⁴

(1. College of Information Science and Engineering, Ocean University of China, Qingdao 266102, China;

2. The Second Ship and Design Institute of Wuhan, Wuhan 430064, China;

3. College of Information & Electrical Engineering, Shandong University of Science and Technology, Qingdao 266510, China;

4. State Key Lab. of Intelligence Technology and System, Tsinghua University, Beijing 100084, China)

Abstract: Particle swarm optimization (PSO) is a kind of bionic evolutionary algorithm and it is inspired by the swarms of birds in nature. Original PSO has contradictions between two performance indicators: global search capabilities and local refining capacity. Moreover, it usually converges to a local optimum with slow converging speed in the late stage of evolutionary. A PSO with chaotic mutation is proposed to accelerate the particles to jump out the local extremum. Combining it with fuzzy logic algorithm is applied to control an inverted pendulum. Simulation demonstrates the effectiveness of the PSO with chaotic mutation, which optimizes fuzzy control and improves the performance of control.

Key words: PSO; chaos; fuzzy control; inverted pendulum

0 引言

由 Kennedy 和 Eberhart 于 1995 年提出的粒子群优化算法(Particle Swarm Optimization, PSO^[1])是一种自组织的群体优化算法,它源于对鸟群和鱼群觅食行为的模拟。PSO 算法作为一种并行的优化算法,具有计算简单、收敛性良好等优点,在非线性、多峰值连续空间优化问题、神经网络训练等领域中均取得了良好

的效果^[2]。

同遗传算法等群体优化算法相似,基本粒子群算法在求解的过程中存在着全局搜索能力和局部求精能力两个性能指标之间的矛盾:一方面,为了搜索到全局最优解,最大限度地保持群体的多样性,这样必然会使局部求精的能力下降;另一方面,提高局部求精能力,往往使算法求得局部最优解而不是全局最优解。

针对上述问题,提出了基于混沌变异算子的粒子群算法,在基本粒子群算法的基础上,结合遗传算法中的变异算子来增强算法的全局搜索能力和局部求精能力。把基于混沌变异的粒子群算法应用到倒立摆系统中,倒立摆系统作为智能控制算法的理想平台,具有高

收稿日期:2007-09-02

作者简介:曹晓燕(1981-),女,山东烟台人,硕士研究生,研究方向为智能控制和视频监控、计算机应用;于立萍,博士,副教授,研究方向为移动机器人及遥操作、智能控制和计算机视觉。

阶次、不稳定、多变量、非线性和强耦合特性,是一个绝对不稳定系统,对它的研究具有很强的理论和实践意义。通过仿真实验,验证了该算法的有效性和可靠性。

1 基于混沌变异的粒子群算法

1.1 粒子群算法的基本原理

粒子群算法是一种仿生进化算法,具有群体和适配度这两种概念。群体中的粒子个体代表问题的一个可行解,每个粒子具有速度与位置两个描述量,位置坐标对应的目标函数值可以作为该粒子的适配度。粒子群算法首先初始化一群随机粒子,然后通过迭代找到最优解。在每次迭代的过程中,粒子通过追踪两个“极值”位置来更新自己的位置:一个是粒子本身的历史最优解 pBest;另一个是目前种群的最优解,即全局极值位置 gBest。粒子按照式(1)和(2)迭代更新其速度和位置^[1]:

$$\begin{aligned} v_{i,j}^{t+1} &= v_{i,j}^t + c_1 * \text{rand} * (pBest_{i,j}^t - x_{i,j}^t) + \\ &c_2 * \text{rand} * (gBest_j^t - x_{i,j}^t) \\ x_{i,j}^{t+1} &= x_{i,j}^t + v_{i,j}^{t+1}; i = 1, 2, \dots, m; j = 1, 2, \dots, n \end{aligned} \quad (1)$$

$$(2)$$

假设 n 维搜索空间,粒子群数为 m , $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,n})$ 和 $v_i = (v_{i,1}, v_{i,2}, \dots, v_{i,n})$ 分别表示粒子的位置和速度信息。 $pBest_{i,j}$ 是粒子 i 历史最优解的第 j 维坐标; $gBest_j$ 是种群当前最优位置的第 j 维坐标; rand 是服从 $U(0,1)$ 分布的随机数;学习因子 c_1 和 c_2 为非负常数,取 $c_1 = 2.8, c_2 = 1.3$ ^[3]。更新过程中,粒子的位置坐标将限制在搜索空间范围内。

Shi^[4] 等人通过对式(1)添加动量惯性系数 ω ,使之随着迭代次数的增加而递减,使算法在迭代初期可以具有广泛的全局搜索能力,而在迭代的后期则具有较强的局部搜索能力,修改后的方程如式(3)所示:

$$v_{i,j}^{t+1} = \omega * v_{i,j}^t + c_1 * \text{rand} * (pBest_{i,j}^t - x_{i,j}^t) + c_2 * \text{rand} * (gBest_j^t - x_{i,j}^t) \quad (3)$$

Clerc^[5] 对式(2)添加了一个速度约束因子 K ,用于提高粒子群算法的性能:

$$x_{i,j}^{t+1} = x_{i,j}^t + K * v_{i,j}^{t+1} \quad (4)$$

其中,

$$K = \frac{2}{2 - c - \sqrt{c^2 - 4 * c}}, c = c_1 + c_2 \quad (5)$$

基于式(3)和(4)的粒子群算法也称之为基本粒子群算法。虽然通过引入惯性系数 ω 和速度约束因子 K ,可以在一定程度上兼顾搜索的全局性和求解的精确性,但是,对于许多复杂的非线性问题,尤其是多峰极值问题的求解,基本粒子群算法很容易陷入局部极

值点,为了使粒子能够更容易跳出局部极小点,达到较高的收敛精度,提出了基于混沌变异的粒子群算法。

1.2 基于混沌变异的粒子群算法

混沌是自然界广泛存在的一种非线性现象,具有较强的随机性、遍历性和初值敏感性^[6],被广泛地应用于随机优化。文中使用的混沌映射 Logistic 迭代方程为:

$$\begin{aligned} \beta_j^{t+1} &= \mu * \beta_j^t * (1 - \beta_j^t), t = 1, 2, \dots \\ \beta_j &\in (0, 1), \beta_j \neq 0.25, 0.5, 0.75 \end{aligned} \quad (6)$$

利用混沌自身的遍历性,可以很好地实现局部搜索。

在对解空间的搜索过程中,根据变异概率在种群中选择一定数目的粒子,对其历史最优个体 pBest 进行混沌变异,变异空间随着迭代次数的增加而逐渐缩小。混沌变异的迭代伪代码如下:

$$\begin{aligned} x_{-new} &= pBest \\ \text{随机生成 } \beta_j &\in (0, 1), \beta_j \neq 0.25, 0.5, 0.75; \\ \text{For } t = 1: \text{混沌迭代次数} \\ \beta_j^{t+1} &= \mu * \beta_j^t * (1 - \beta_j^t) \end{aligned}$$

计算变异尺度:

$$x_c = x_{j,\min} + \beta_j^{t+1} (x_{j,\max} - x_{j,\min}) \quad (7)$$

变异得到新的位置信息:

$$x_{-new_j^{t+1}} = (1 - \alpha_g) * x_{-new_j^t} + \alpha_g * x_c \quad (8)$$

其中比例因子 $\alpha_g = 1 - (\frac{k-1}{k})^d$ 决定变异搜索的空间。 k 是粒子群的进化代数, d 可取常量。

If(x_{-new} 的适配值 > pBest 的适配值)

pBest = x_{-new} ;

Break;

Endif

Endfor

为了使粒子群能够有效地摆脱局部极值,尽快得收敛到全局最优解,可以按照式(8)对粒子的局部极值进行混沌变异,由比例因子 α_g 的定义可以看出,变量的搜索空间随着迭代代数的增加而逐渐缩小。这样,在初期,有利于在广阔的范围内搜索到全局最优解,在后期,可以在局部极值的周围进行细致的搜索,提高收敛精度。下面将以倒立摆为研究对象来验证算法的有效性。

2 倒立摆系统

倒立摆系统作为研究控制理论的一种典型的实验装置,具有成本低廉、结构简单、物理参数和结构易于调整的优点,然而倒立摆系统本身所具有的高阶次、不稳定、多变量、非线性和强耦合特性,是一个绝对不稳

设计如下的编码规则:

* 模糊变量的隶属度函数仍然保持全交叠,因此,只需要优化各个隶属度函数的中心即可,不必优化宽度;编码并不直接描述各隶属度函数的中心,而是描述到各隶属度函数中心初始值的偏差;偏差范围小于等于原隶属度函数中心距离的一半。

* 模糊变量的隶属度函数关于零点对称,因此,只要优化一半的隶属度函数即可。

* 共需要优化 7 个参数(θ 的隶属度函数 2 个, $\dot{\theta}$ 的隶属度函数 2 个, u 的隶属度函数 2 个, 量化因子 1 个)。

按照上面的规则,编码如表 3 所示。

表 3 粒子向量编码规则

| 变量 | 隶属度函数中心 | | | | | 取值范围 |
|----------------|-------------------|--------------------|---|-------------------|------------------|-------------------|
| θ | $-\frac{\pi}{3}$ | $-\frac{\pi}{6}$ | 0 | $\frac{\pi}{6}$ | $\frac{\pi}{3}$ | $\frac{\pi}{12}$ |
| $\dot{\theta}$ | $-\frac{5\pi}{9}$ | $-\frac{5\pi}{18}$ | 0 | $\frac{5\pi}{18}$ | $\frac{5\pi}{9}$ | $\frac{5\pi}{36}$ |
| u | -8 | -4 | 0 | 4 | 8 | 2 |

本例中种群大小为 30, 最大迭代次数为 50, 混沌变异概率为 0.01, 学习因子 $c_1 = 2.8$, $c_2 = 1.3$, 惯性系数 ω 初始值为 1, 每次迭代按照 $\omega = \omega * 0.95$ 递减, 速度约束因子 $K = 0.72984$ 。

4.2 定义适配度

适配度函数是粒子群算法中的一个重要概念, 适配函数设计是否合适直接影响到粒子群算法的优化结果。本例中使用 ITEA 积分性能指标, 如式(10)所示:

$$J(\text{ITEA}) = \int_0^{\infty} t |e(t)| dt = \min \quad (10)$$

这种目标函数用于控制参数优化, 能够综合评价控制系统的动态和静态性能, 如响应快、调节时间短、超调量很小以及稳态误差也很小等。文中使用 θ 的变化作为目标函数, 即 $e(t) = \theta(t)$, 并且将适配函数取为 J 的倒数, 即: $f(x) = 1/J(\text{ITEA})$ 。

4.3 仿真实验

本例中粒子群算法总共迭代 50 次, 最大适配值 222.9758, 平均适配值 222.975779, 最大适配值和平均适配值随迭代次数变化的曲线如图 3 所示。

优化后的隶属度函数如图 4 所示, 优化后的量化因子 $\text{Gain} = 10$ 。对使用混沌变异粒子群算法进行参数优化后的系统进行仿真, 结果如图 5 所示。

从图 5 所示的比较图中可以看出, 经优化后的控制效果要大大优于优化前的控制效果, 倒立摆系统在大约 2s 之后就进入稳定状态。以上实验证明了利用

基于混沌变异的粒子群算法实现模糊控制器的优化是可行的, 通过参数的寻优, 能够很好地改进系统的动态响应。

5 结束语

针对基本 PSO 算法存在的不足, 引入了基于混沌的变异算子, 按照一定的变异概率对粒子的局部极值进行扰动, 加速粒子跳出局部极值点, 而继续优化, 提高了算法的收敛速度和收敛精度。同时将基于混沌变异的粒子群算法与模糊控制相结合实现了倒立摆系统的控制, 仿真实验表明了算法的有效性。

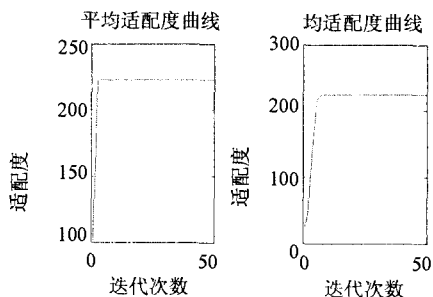
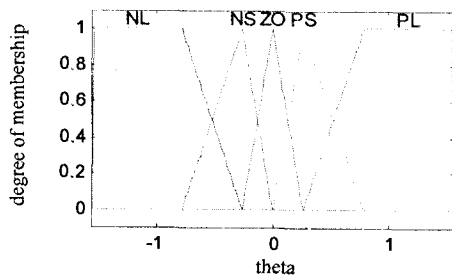
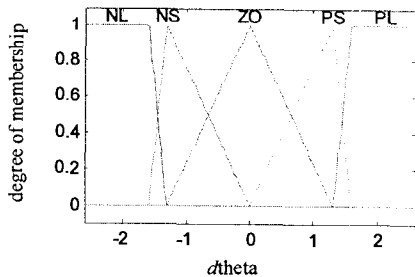


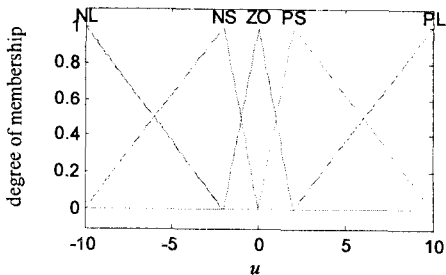
图 3 最大适配值和平均适配值迭代变化曲线



(a) 优化后的 θ 的隶属度函数



(b) 优化后的 $d\theta$ 的隶属度函数



(c) 优化后的 u 的隶属度函数

图 4 优化后的隶属度函数

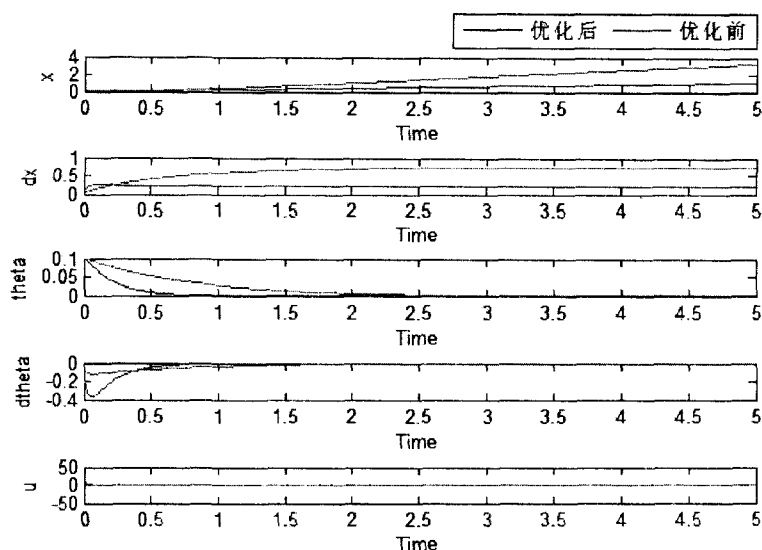


图5 优化前后倒立摆系统仿真图

参考文献:

- [1] Kennedy J, Eberhart R. Particle swarm optimization[C]// Proc. of the IEEE Conf. on Neural Networks, IV. Perth: IEEE Press, 1995:1942-1948.
- [2] Peng X, Venayagamoorthy G K, Corzine K A. Combined training of recurrent neural networks with particles swarm op-

- timization and backpropagation algorithms for impedance identification [C] // Proc. of the IEEE Swarm Intelligence Symposium (SIS 2007). Honolulu, HI: IEEE Press, 2007:9-15.
- [3] Carlisle A, Dozier G. An off-the-shelf PSO [C] // Proc. of the Workshop on Particle Swarm Optimization. Indiana, USA: IEEE Press, 2001:1-6.
- [4] Shi Y, Eberhart R. A modified particle swarm optimizer [C] // Evolutionary Computation Proc. of the IEEE World Congress on Computational Intelligence. New York: IEEE Press, 1998:69-73.
- [5] Clerc M. The swarm and the queen: Towards a deterministic and adaptive particle swarm optimization[C]//Proc. of the ICEC. Washington: IEEE Press, 1999:1951-1957.
- [6] Kennedy M P. Three Steps to Chaos - Part I: Evolution[J]. IEEE Transactions on Circuits and System - I: Fundamental Theory and Applications, 1993, 40(10): 640-656.
- [7] 洪旭. 倒立摆系统模糊控制算法研究[D]. 西安: 西安电子科技大学, 2005.

(上接第150页)

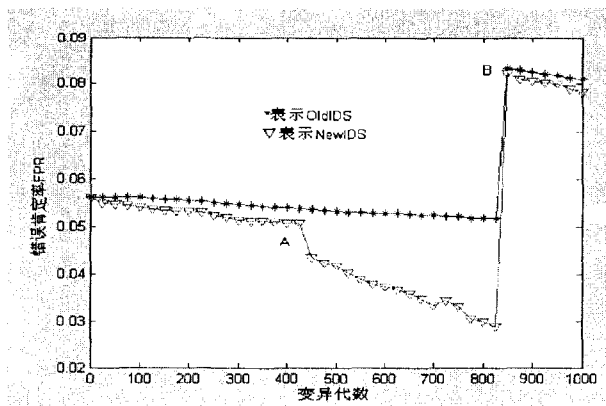


图2 系统FPR对比图

4 结束语

根据生物系统的免疫记忆原理,由免疫检测器集中的成熟检测器生成记忆检测器,形成了记忆检测器为主的多层次检测器集合。实验证明有很好的检测率和学习能力,并能降低错误的肯定率,而对记忆检测器变异,进一步提升检测效率、增强自适应性和降低伪肯定率,然后再借鉴 Cache 中的替换算法给出记忆检测器的淘汰策略,使整个系统的性能进一步优化。但实验中的一些参数的设定对结果影响很大,下一步的工

作是研究实验参数的影响程度。以提高入侵检测系统的自适应性和有效性。

参考文献:

- [1] Forrest S, Perelson A S, Allen L, et al. Self - Nonself discrimination in a computer[C]// In Proceedings of IEEE Symposium on Research in Security and Privacy. Oakland, CA: [s. n.], 1994:202-212.
- [2] Kim J, Bentley P J. Towards an artificial immune system for network intrusion detection: An investigation of clonal selection with a negative selection operator[C]//Kim J H, Zhang B T, Fogel G, et al (Eds.). in The Congress on Evolutionary Computation (CEC - 2001). Seoul, Korea: [s. n.], 2001: 1244-1252.
- [3] Michaud S R, Lamont G B, Zydallis J B, et al. Protein Structure Prediction with Immunological EA Computation[C]//In: Proceeding of Genetic and Evolutionary Computation Conference (GECCO - 2001). San Francisco, California: Morgan Kaufmann, 2001:1367-1374.
- [4] 李涛. 计算机免疫学[M]. 北京: 电子工业出版社, 2004.
- [5] Haines J W, Lippmann R P, Fried D J, et al. DARPA intrusion detection system evaluation: Design and procedures [R]. Technical Report 1062. Lexington: MIT Lincoln Laboratory, 1999.