

基于细菌觅食行为的分布估计算法 在预测控制中的应用

王雪松^{1,2},程玉虎¹,郝名林¹

(1.中国矿业大学信息与电气工程学院,江苏徐州 221116; 2.中国科学院自动化研究所,北京 100190)

摘要: 为增强分布估计算法(EDA)的局部优化能力,将细菌的觅食(BF)行为,即细菌的趋化性运动引入到分布估计算法中,提出一种基于细菌觅食行为的分布估计算法 BF-EDA.通过 8 个 Benchmark 函数来测试算法性能,并与常规 EDA、粒子群优化(PSO)和 HPSO-TVAC 算法进行实验比较,结果表明 BF-EDA 算法在优化解的质量和收敛速度方面具有较好的性能.进一步,为克服传统的基于梯度信息优化方法的缺点,将 BF-EDA 应用于预测控制的非线性滚动优化阶段,以优化求解被控系统的最优控制序列.曲线跟踪实验结果表明,基于 BF-EDA 的预测控制算法具有良好的控制品质.

关键词: 分布估计算法; 细菌觅食; 预测控制; 滚动优化

中图分类号: TP273 **文献标识码:** A **文章编号:** 0372-2112 (2010) 02-0333-07

Estimation of Distribution Algorithm Based on Bacterial Foraging and Its Application in Predictive Control

WANG Xue-song^{1,2}, CHENG Yu-hu¹, HAO Ming-lin¹

(1. School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China;

2. Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

Abstract: In order to enhance the local optimization capability of estimation of distribution algorithm (EDA), bacterial foraging behavior, also called chemotactic behavior, was introduced into EDA to construct a novel estimation of distribution algorithm based on bacterial foraging (BF-EDA). The BF-EDA was validated using eight benchmark functions. The experimental results show that, compared with traditional EDA, particle swarm optimization (PSO) and HPSO-TVAC algorithms, the BF-EDA performs well in terms of quality of the optimal solution and speed of convergence. The BF-EDA was further applied to a nonlinear rolling optimization phase of predictive control to obtain a series of optimal control variables, which can overcome the disadvantages of traditional optimization methods based on gradient information. Experimental studies concerning curve tracking illustrate that the proposed predictive control strategy based on BF-EDA has excellent control performance.

Key words: estimation of distribution algorithm; bacterial foraging; predictive control; rolling optimization

1 引言

预测控制是直接从工业过程中产生的一类基于模型的控制算法,具有较强的鲁棒性和抗干扰能力^[1].在预测控制中,每个控制周期需要求取一次使得性能指标函数最优化的控制量,即滚动优化.正如 Brisk 在第 12 届 IFAC 大会上所指出的那样,预测控制最主要的特征是在线滚动优化^[2].然而,由于被控对象的非线性,以及预测控制所要求的对未来输出的预测性,往往导致性能

指标函数比较复杂,难以求取控制量的解析解,故控制量的求取问题实际转化为了非线性规划问题.为求解该非线性规划问题,常用的方法为序列二次规划法.但该方法依赖于模型的梯度信息,其适用范围局限在性能指标函数存在导数的情况.近年来,随着遗传算法(genetic algorithm, GA)^[3]、粒子群优化(particle swarm optimization, PSO)^[4]、蚁群算法(ant colony algorithm, ACA)^[5]和人工免疫(artificial immune, AI)^[6]等智能优化方法的发展,如何将这方法应用于预测控制的滚动优化阶段已逐渐成

为研究的热点.

GA、PSO、ACA 和 AI 等优化方法均是基于对种群中的各个个体进行遗传操作(交叉、变异等)来实现群体的进化的,是对生物进化“微观”层面上的数学建模,具有较好的局部优化能力,但全局搜索能力较差.最近几年,在进化计算领域兴起了一类新型的优化算法,称为分布估计算法(estimation of distribution algorithm, EDA),并迅速成为进化计算领域的研究热点和解决工程问题的有效方法^[7].分布估计算法提出了一种全新的进化模式,是统计学习理论与随机优化算法的结合.与传统进化算法不同,EDA 是基于对整个群体建立数学模型,直接描述整个群体的进化趋势,是对生物进化“宏观”层面上的数学建模,具有良好的全局搜索能力,但局部搜索能力差.

由 Passino 提出的细菌觅食(bacterial foraging, BF)理论是基于一个假设,细菌通过涌动和翻滚两种趋化性运动寻找并获得食物,以在单位时间内最大化所获得的能量为目标^[8].根据觅食理论,自然选择通常会淘汰觅食能力差的个体,而留下具有良好觅食策略的个体的基因,因为这些个体在繁殖方面有更大的优势(它们获得了足够的食物来进行繁殖行为).每一代都进行这样的自然选择,那么很多代之后,较差的觅食策略或者被淘汰掉或者进行重整而演化成良好的策略.可以看出,细菌觅食的行为机制侧重于局部搜索,而 EDA 是一种全局搜索算法,两者结合可充分利用各自的优点,能够做到算法探索与利用的有效均衡.为此,为了增强 EDA 在较好解邻域内精确搜索最优解的能力,将细菌觅食行为引入到 EDA 方法中,提出一种基于细菌觅食行为的改进分布估计算法 BF-EDA,并将其应用于预测控制的滚动优化阶段.

2 基于改进分布估计算法的预测控制

如图 1 所示,与经典预测控制相同,基于改进分布估计算法的神经网络预测控制系统同样具有预测模型、滚动优化、反馈校正 3 个基本特征,不同之处仅在于由 Elman 网络预测模型取代了经典的预测模型,用基于细菌觅食行为的分布估计算法取代传统的基于梯度信

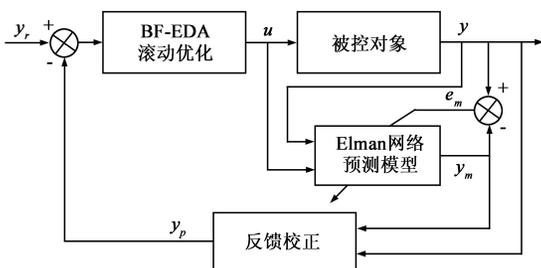


图1 基于改进分布估计算法的预测控制结构

息的优化方法.图中, y_r 、 y 、 y_m 和 y_p 分别为系统设定值、系统输出、Elman 网络预测模型输出和修正预测输出, u 为控制信号.

2.1 预测模型

预测控制是一种基于模型的控制算法,这一模型称为预测模型.预测模型的作用是根据系统的历史信息 and 未来的输入,预测系统未来的输出.预测模型只强调模型的预测功能,而不注重模型的形式,因而,阶跃响应、脉冲响应和神经网络等非参数化模型也可以用来描述预测模型.其中,神经网络建模对被控系统模型无特殊要求,它只需由一组输入输出数据提取信息即可.Elman 网络在 BP 网络的基础上,加入内部反馈信号,利用内部状态反馈来描述系统的非线性动力学行为,从而提高了学习速度,适合于动态系统的实时辨识.为此,本文采用 Elman 网络来对非线性系统进行实时在线辨识.

为了建立动态系统的预测模型,必须将时间的因素引入 Elman 网络中.在此将实际系统输入和输出的各次滞后作为网络的输入,则 Elman 网络的单步预测模型可以表示为:

$$y_m(t+1) = \text{NNP}[y(t), y(t-1), \dots, y(t+1-N); u(t), u(t-1), \dots, u(t+1-M); W] \quad (1)$$

式中, $y(t)$ 和 $u(t)$ 分别为时刻 t 时的系统输出以及控制输入, N 和 M 是输出和输入的滞后时间, $N \geq M$, W 为 Elman 网络的权值.

将上述 Elman 网络输出的单步预测值反馈给网络作为输入用于下一步的预测,利用式(1)进行递推,从而得到未来一段时期的预测值:

$$y_m(t+k) = \text{NNP}[y_m(t+k-1), \dots, y_m(t+k-N); u(t+k-1), \dots, u(t+k-M); W] \quad (2)$$

式中, $k=1, 2, \dots, p$, p 为预测时域, $u(t), u(t+1), \dots, u(t+p-1)$ 为未来控制序列.

2.2 反馈校正模型

由于上述神经网络预测模型不可避免地要与实际系统存在误差,而且随着时间的累积,这些误差将变得越来越大,因此必须通过反馈来修正模型.在神经网络预测控制算法中,每一步都要检测系统实际输出,并与模型输出比较构成误差信息,然后以此误差信息对神经网络模型进行学习和修正.这一过程可以在线进行,也可以离线进行.为满足控制系统实时性的要求,此处采用误差信息对未来的输出预测值进行在线修正:

$$y_p(t+k) = y_m(t+k) + h[y(t) - y_m(t)] \quad (3)$$

式中, h 为误差修正系数.由于该系数是对不确定因素造成的误差进行补偿,故 h 的选择难以用精确的数学

模型表达,一般采用经验试凑法,经多次仿真研究得到一个合适的值。

2.3 基于改进分布估计算法的滚动优化

预测控制是一种以优化确定控制策略的算法,它以一个确定的性能指标来确定未来的控制量 $u(t), u(t+1), \dots, u(t+q-1)$, q 为控制时域. 这一性能指标一般取为,系统从某一采样时刻起未来有限时间段内的输出对期望输出的跟踪能力,随着时间的推移不断向前滚动. 另一方面,考虑到实际系统中不允许输出的控制量太大或变化过于剧烈,因而将控制量也作为性能指标的一部分. 因此,系统 t 时刻的性能指标为:

$$J_o = \frac{1}{2} \sum_{k=1}^p [y_r(t+k) - y_p(t+k)]^2 + \frac{1}{2} \sum_{m=1}^q \lambda_m u^2(t+m-1) \quad (4)$$

式中, p 和 q 分别为预测和控制时域,通常规定 $p \geq q \geq 1$, λ_m 为加权系数. 控制的目标是,确定未来的 q 个控制量使系统的性能指标最优,即使 J_o 最小.

分布估计算法是基于概率统计的随机搜索算法,它与其它进化算法的不同是,它不用交叉变异方式产生下一代样本,而是对上一代样本进行统计分析并建立概率模型,进而利用概率模型产生下一代样本,如此反复进行,实现群体的进化. 细菌觅食行为,即细菌的趋化性运动,是由细胞表面的鞭毛推动的,有两种基本动作:涌动推动细菌向前方远动(鞭毛反时针旋转扭成一股,束高速旋转推动细胞平滑移动);原地翻滚,随机确定细菌涌动的方向(鞭毛顺时针旋转,束分散或松开导致细胞原地翻滚,当束重新形成时细胞体改变方向并开始下一个涌动)^[8]. 在分布估计算法中引入细菌觅食行为,提出一种基于细菌觅食行为的改进分布估计算法,并将其应用于优化求解被控系统的最优控制序列,算法步骤描述如下:

第一步,初始化种群. 假设解空间为细菌所在的环境,在环境中随机生成 NP 个独立的细菌,并使其均匀分布,细菌所在的位置坐标表示各独立的解,如 $U_{j,c}^i = (u_{j,t,c}, u_{j,t+1,c}, \dots, u_{j,t+q-1,c})$, q 为需要优化的控制量的个数,即解空间的维数, $i = 1, 2, \dots, NP$, $j = 1, 2, \dots, N_c$, $G = 1, 2, \dots, G_{\max}$. N_c 为细菌最大趋化步数, G_{\max} 为最大进化代数. $U_{j,c}^i$ 表示第 i 个细菌,在第 G 代中,第 j 个趋化步在解空间中的位置. 细菌的初始化位置采用实数编码,每个坐标由下式生成:

$$U_{j,1}^i = low + rand \times (high - low) \quad (5)$$

式中, $high$ 和 low 分别为解空间的上、下限值,即控制量的幅值约束, $rand$ 为在 $[0, 1]$ 区间内取值的随机数.

第二步,对细菌的位置进行评价,即由式(4)计算待优化函数的值 $J(i, j, G) = J_o(U_{j,c}^i)$. 按如下步骤实

现:

(1) 将 $U_{j,c}^i = (u_{j,t,c}, u_{j,t+1,c}, \dots, u_{j,t+q-1,c})$ 送 Elman 网络预测模型(2),求得被控对象输出的预测值 $Y_m = (y_m(t+1), y_m(t+2), \dots, y_m(t+p))$;

(2) 对基于模型的预测进行反馈校正,由式(3)可得 $Y_p = (y_p(t+1), y_p(t+2), \dots, y_p(t+p))$;

(3) 由式(4)计算适应度函数值 $J(i, j, G) = J_o(U_{j,c}^i)$.

第三步,趋化步 for $j = 1: N_c$, 对每个细菌 i 的趋化步按如下步骤实现:

(1) 翻滚:产生一个随机的向量 $\Theta(i) \in R^q$,以确定细菌涌动的方向,向量 $\Theta(i)$ 的每一个元素为区间 $[-1, 1]$ 内的随机数;

(2) 涌动:令 $U_{j+1,c}^i = U_{j,c}^i + \frac{C(i)\Theta(i)}{\sqrt{\Theta^T(i)\Theta(i)}}$ 为细菌涌动一次后的位置,其中 $C(i)$ 表示第 i 个细菌一次涌动的距离,即趋化步长;

趋化步长对细菌觅食算法的性能影响较大,此处采用自适应步长以加快算法的收敛. 在进化的初期,需要一个较大的步长,以便在较大的空间内搜索解,然后在进化的过程中逐渐减小趋化步长,使其在较好解的周围进一步搜索最优解. 根据菌群中细菌的位置信息来确定步长:

$$C(i) = \frac{\max_i(U_{j,c}^i) - \min_i(U_{j,c}^i)}{DIV} \quad (6)$$

式中, $\max_i(U_{j,c}^i)$ 和 $\min_i(U_{j,c}^i)$ 分别为菌群中的细菌在环境中坐标位置的上、下限值, DIV 为常数.

另外,为防止陷入局部极小点,在一次进化过程中,如细菌连续多次未到达一个符合要求的更好位置,即 $0 < \frac{J(i, j, G) - J(i, j+1, G)}{J(i, j, G)} < \delta$ (δ 为给定精度),则适当增大趋化步长,此时取:

$$C(i) = \min(\|high - low\| 15, 10C(i)) \quad (7)$$

(3) 计算 $J(i, j+1, G) = J_o(U_{j+1,c}^i)$, 并与细菌涌动前的位置相比较,看是否到达一个更好的位置. 如果细菌涌动一次后,到达一个更好的位置,则保持上次方向再涌动一次,直到到达一个较差的位置或达到规定的最大涌动次数 N_s . 为简化计算,只让一半细菌再次涌动.

第四步,产生下一次迭代的细菌群. 结束 N_c 个趋化步后,根据每个细菌的健康状况 $J(i)_{health} = \sum_{j=1}^{N_c} J(i, j, G)$ ($J(i)_{health}$ 值越大,表明细菌健康状况越差),选择 $NP/2$ 个健康状况较好的细菌,对它们的位置信息进行统计分析,建立高斯概率模型^[9]. 应用分布估计算法根据概率模型,生成 NP 个新的细菌,然后进入下一次迭代.

第五步,检查是否满足迭代终止条件,若满足则停止迭代,否则转第二步.

由式(4)知,在很多时候,预测控制性能指标函数的优化目标是难以达到 0 的,从而造成 BF-EDA 优化算法在已经获得最优值的情况下还会一直不断地继续寻优直到算法达到最大迭代次数才能终止,白白浪费了大量的时间,使得 BF-EDA 优化算法不能应用于实时控制系统.因此,可以考虑在 BF-EDA 算法中引入稳定精度 ϵ 和最大稳定连续迭代次数 G_{con} 这两个参数来判断算法是否已获得最优值,进而决定是否应终止迭代.这样就能节省大量时间,提高预测控制的实时性.也就是说,考虑到系统控制的实时性,在设定一个最大进化代

数 G_{max} 的同时,如果当连续 G_{con} 代细菌的最优适应值稳定在精度 ϵ 时,同样停止迭代.

3 实验与分析

3.1 Benchmark 函数实验

为了考查 BF-EDA 算法的性能,并与常规 EDA、PSO^[10]和 HPSO-TVAC^[11]算法进行比较,选择 8 个常用的 Benchmark 函数进行数值实验,这些函数被广泛用于评价优化算法的性能.其中,前 4 个函数为单模态函数,具有单一极小点,后 4 个函数为多模态函数,具有多个局部极小点.函数描述、维数、取值范围和理论极值见表 1.

表 1 测试函数

函数	维数 D	取值范围	理论极值
$f_1(x) = \sum_{i=0}^{D-1} x_i^2$	100	$x_i \in [-5.12, 5.12]$	0
$f_2(x) = \sum_{i=0}^{D-1} x_i + \prod_{i=0}^{D-1} x_i $	100	$x_i \in [-10, 10]$	0
$f_3(x) = (\sum_{i=0}^{D-1} (i+1)x_i^4) + rand[0,1]$	100	$x_i \in [-1.28, 1.28]$	0
$f_4 = \max(x_i), \quad 0 \leq i < D$	100	$x_i \in [-100, 100]$	0
$f_5(x) = \sum_{i=0}^{D-1} (x_i^2 - 10\cos(2\pi x_i) + 10)$	100	$x_i \in [-5.12, 5.12]$	0
$f_6(x) = \frac{1}{4000} (\sum_{i=0}^{D-1} x_i^2) + \prod_{i=0}^{D-1} \cos(\frac{x_i}{\sqrt{i+1}}) - 1$	100	$x_i \in [-600, 600]$	0
$f_7 = \sum_{i=0}^{D-1} -x_i \sin(\sqrt{ x_i })$	100	$x_i \in [-500, 500]$	$-4.1898E+4$
$f_8 = -20\exp(-0.2\sqrt{\frac{1}{D}\sum_{i=0}^{D-1} x_i^2}) - \exp(\frac{1}{D}\sum_{i=0}^{D-1} \cos(2\pi x_i)) + 20 + e$	100	$x_i \in [-32, 32]$	0

为保证算法的可比性,4 种算法取相同的进化代数与种群规模,即 $G_{max} = 1500$, $NP = 200$. PSO 中^[10], 粒子群规模 $swarmsize = 100$, 惯性权重 $w = 0.6$, 学习因子 $c_1 = 1.8$, $c_2 = 1.8$. HPSO-TVAC 中^[11], $swarmsize = 100$, $w = 0$, $c_1 = 2.5 - (2.5 - 0.5)\frac{G}{G_{max}}$, $c_2 = (2.5 - 0.5)\frac{G}{G_{max}} + 0.5$. BF-EDA 中最大趋化步数 $N_c = 5$, 最大涌动次数 $N_s = 5$, 给定精度 $\delta = 10^{-3}$, $DIV = 15$.

采用如下 3 种性能指标测试算法性能^[12]: (1) 固定进化代数内算法平均最优结果. 虽然此时所得结果可能不靠近最优结果, 仅仅是局部最优点附近一个适应度较小点, 但此性能指标能在一定程度上反映出算法的收敛速度. 本文取此固定进化代数为 500. (2) 到达确定阈值的平均进化代数. 此性能指标也是算法进化速度测试指标, 但不同于上述指标, 此时可能意味着算法已经靠近了全局最优位置. 本文中函数 f_1 、 f_2 、 f_6 和 f_8 的阈值取为 $E - 8$, 函数 f_3 的阈值为 0.015, 函数 f_4 的阈值为 0.5, 函数 f_5 的阈值为 15.0, 函数 f_7 的阈值为 -31314 . 当运行代数达到 5000 代而仍未满足学习误差精

度时则认为算法已陷于局部最优解. (3) 达标率. 通过计算算法到达预设阈值的次数占规定进化总次数的比例, 测试算法的可靠性.

考虑性能指标 1, 表 2 给出了 500 代内 4 种算法优化上述测试函数 30 次所得平均优化结果. 由表 2 可以看出, 对于函数 f_1 、 f_2 、 f_6 和 f_8 , EF-EDA 能在 500 代之内得到满意结果; 对于函数 f_2 , BF-EDA 所得结果略劣于 EDA, 但是明显优于 PSO 和 HPSO-TVAC. 因此, 考虑全部优化函数, EF-EDA 能在规定进化代数内得到较为理想的优化结果, 甚至得到满意解.

表 2 500 代内 4 种算法所得平均优化结果

函数	BF-EDA	EDA	PSO	HPSO-TVAC
f_1	2.1393E-23	8.6649E-23	0.21027	1.4481
f_2	5.6812E-10	5.1107E-10	13.7397	18.2540
f_3	1.2857E-02	3.9863E-02	0.4291	2.7002
f_4	0.2188	20.5502	30.3179	30.2217
f_5	14.9253	19.7405	2.7701E+02	143.6644
f_6	0	0	1.4833	6.1721
f_7	-3.1305E+04	-2.2204E+04	-2.4313E+04	-2.2769E+04
f_8	1.5339E-11	2.1496E-10	3.5342	10.5900

表 3 最大进化代数下 4 种算法所得最优解的平均值与方差

函数	BF-EDA		EDA		PSO		HPSO-TVAC	
	平均值	方差	平均值	方差	平均值	方差	平均值	方差
f_1	0	0	0	0	4.3811E-06	3.7942E-11	2.0619E-07	1.4976E-14
f_2	0	0	0	0	5.0407	1.4968E+02	0.0036	1.1695E-06
f_3	1.1958E-02	1.0073E-06	3.7421E-02	3.4628E-05	1.2222E-01	5.7125E-04	0.9444	6.8028E-02
f_4	0.0987	0.0043	20.5502	19.9611	23.5177	1.3073	21.3304	6.2932
f_5	14.9253	8.7134	19.7405	5.8785	2.4796E+02	1.3611E+03	98.9214	2.5272E+02
f_6	0	0	0	0	3.0875E-02	2.9526E-03	4.8804E-05	5.5264E-10
f_7	-3.1314E+04	1.3232E+06	-2.2204E+04	1.4476E+06	-2.4508E+04	2.0447E+06	-2.8513E+04	1.9964E+06
f_8	7.79963E-15	0	6.0896E-12	7.3384E-22	1.4971	4.9071E-01	5.3837	0.8836

表 4 不同算法所得优化结果的达标率及平均进化代数

函数	BF-EDA		EDA		PSO		HPSO-TVAC	
	达标率	平均进化代数	达标率	平均进化代数	达标率	平均进化代数	达标率	平均进化代数
f_1	100%	209	100%	215	100%	2085	100%	2932
f_2	100%	448	100%	446	40%	4305	100%	4135
f_3	100%	268	0	/	0	/	0	/
f_4	100%	350	0	/	0	/	0	/
f_5	45%	392	0	/	0	/	0	/
f_6	100%	257	100%	273	66%	2540	87%	3582
f_7	57%	441	0	/	0	/	0	/
f_8	100%	389	100%	394	0	/	0	/

表 3 给出了最大进化代数下各算法 30 次独立实验所得最优解的平均值与方差.由表 3 出示的数据可以看出,BF-EDA 所得结果要明显优于 PSO 和 HPSO-TVAC;另外,BF-EDA 在 8 个测试函数上得到的均值和方差均不大于 EDA(函数 f_5 的方差除外),这是由于在 EDA 中引入了 BF,增强了 EDA 的局部搜索最优解能力的缘故.

表 4 给出了不同算法的达标率及平均进化代数.对于较为简单的单模态函数 f_1 ,4 种算法的达标率均为 100%,但 PSO 和 HPSO-TVAC 的平均进化代数要明显多于 EDA 和 BF-EDA.由表 2、3 和 4 可知,对于函数 f_1 、 f_2 、 f_6 和 f_8 ,BF-EDA 和 EDA 在所得平均优化结果、最优解、达标率和平均进化代数方面结果较为相近.但是,对于函数 f_3 、 f_4 、 f_5 和 f_7 ,EDA、PSO 和 HPSO-TVAC 的达标率均为 0,表明这 3 种算法在进化后期陷入了局部收敛.可见对于所有 8 个测试函数,BF-EDA 所得结果有较高的可靠性.

通过上述分析可知,除函数 f_5 和 f_7 外,BF-EDA 所得结果能以 100% 的达标率得到非常可靠的满意结果,而

$$y(t) = \begin{cases} \frac{0.5y(t-1)y(t-2)}{1+y(t-1)^2+y(t-2)^2} + 0.3\cos(0.5(y(t-1)+y(t-2))) + 1.2u(t-1) + \varepsilon(t), & t \leq 150 \\ \frac{0.1y(t-1)y(t-2)}{1+0.8[y(t-1)^2+y(t-2)^2]} + 0.5\cos(0.5(y(t-1)+y(t-2))) + 1.6u(t-1) + \varepsilon(t), & t > 150 \end{cases} \quad (9)$$

式中, $\varepsilon(t)$ 为随机噪声,幅值最大为给定波形幅值的 1%.控制量 $u(t)$ 的取值范围为:

$$u(t) = \begin{cases} -1.3, & u(t) \leq -1.3 \\ 1.3, & u(t) \geq -1.3 \end{cases} \quad (10)$$

由式(5)和(10)可知,BF-EDA 解空间的上、下限值 high 和 low 分别为 1.3 和 -1.3.

且所需进化代数也比较少.因此,总体来说,BF-EDA 在进化结果质量及收敛速度上要优于其它 3 种算法.

3.2 预测控制的曲线跟踪

由式(4)计算最优控制量时需要优化多个控制量,它的计算是个复杂的过程,无法满足系统控制的实时性要求.为简化计算,只考虑 t 时刻控制量的大小 $u(t)$,而其它步 $u(t+1), \dots, u(t+q-1)$ 则保持不变.到下一时刻 $(t+1)$ 时,将重新计算控制量.以上过程不断反复进行,并随时间向前递推.此时,系统的性能指标为:

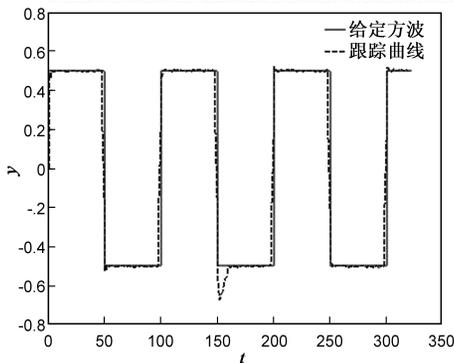
$$J_o = \frac{1}{2} \sum_{k=1}^p [y(t+k) - y_p(t+k)]^2 + \frac{1}{2} \lambda_m u(t)^2 \quad (8)$$

为验证本文所提预测控制算法的性能,采用本文提出的预测控制方法研究非线性函数对象式(9)对幅值为 $[-0.5, 0.5]$ 的方波和正弦波的曲线跟踪能力.当被控对象在 $t=150$ 步时,参数发生变化,具体变化情况如下:

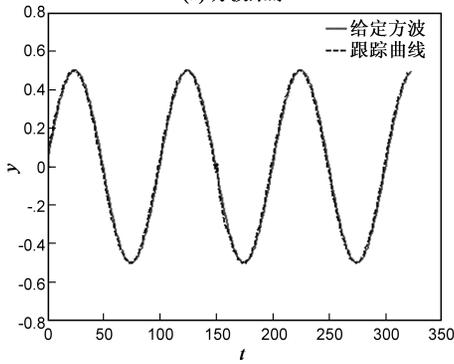
曲线跟踪实验中,取 Elman 网络预测模型的输入为 $y(t-1), y(t-2), u(t-1), u(t-2)$, 输出为 $y(t)$. 预测控制算法的参数设置为:预测时域 $p=3$,控制时域 $q=1$,加权系数 $\lambda_m=1/500$,BF-EDA 滚动优化算法的最大进化代数 $G_{\max}=150$,种群规模 $NP=60$,最大趋化步

数 $N_c = 2$, 最大涌动次数 $N_s = 5$, $\varepsilon = 10^{-4}$, $G_{con} = 10$, $\delta = 10^{-3}$, $DIV = 20$.

图 2 给出了被控对象的曲线跟踪实验结果. 结果表明, 本文所提预测控制算法具有良好的控制品质, 能适应被控对象参数的变化, 具有一定的鲁棒性和自适应能力. 另外, 在方波和正弦波的跟踪仿真过程中, 本文所提预测控制算法每时间步控制量优化计算的平均耗时分别为 0.5124 秒和 2.2867 秒. 可以看出, 若将该预测控制方法用于实时性要求不是太高, 如水箱液位控制、锅炉高温过热器的过热汽温控制、化工过程和化学反应的 pH 值控制等生产过程控制还是可行的. 但是, 对于机电类快变过程的快速跟踪控制问题, 如机器人、火炮或雷达的目标跟踪等, 该方法往往难以在线实时控制. 因此, 寻找一种算法简单、控制迅速有效的预测控制方法也是作者的后续研究内容, 如可根据具体控制对象, 在工况变化不大的情况下, 采取间断性地在线模型辨识, 可满足实时性更高的系统.



(a) 方波跟踪



(b) 正弦波跟踪

图2 曲线跟踪实验

4 结论

充分利用了分布估计算法的全局搜索性能及细菌觅食行为机制的局部优化能力, 提出一种基于细菌觅食行为的改进分布估计算法 BF-EDA, 并将其应用于预测控制的滚动优化阶段, 以优化求解被控系统的最优控制序列. Benchmark 函数实验结果验证了 BF-EDA 算

法在优化解的质量方面的优越性. 曲线跟踪实验结果表明, 基于 BF-EDA 的预测控制算法具有良好的跟踪性能、自适应和抗干扰能力. 为增强分布估计算法的优化性能及其在非线性预测控制中的实用性做出了有益的探索, 同时, 对于算法的稳定性、收敛性和诸多参数的选择等问题还有待于做进一步的研究.

参考文献:

- [1] Wang Xuesong, Cheng Yuhu, Sun Wei. Multi-step predictive control with TDBP method for pneumatic position servo system [J]. Transactions of the Institute of Measurement and Control, 2006, 28(1): 53 - 68.
- [2] 余世明, 杜维. 目标规划法在预测控制滚动优化及在线辨识中的应用[J]. 自动化学报, 2002, 28(6): 995 - 1000.
Yu Shi-ming, Du Wei. Applications of goal programming in receding-horizon optimization and online identification of predictive control [J]. Acta Automatica Sinica, 2002, 28(6): 995 - 1000. (in Chinese)
- [3] Yuzgec U, Y. Becerikli, M. Turker. Nonlinear predictive control of a drying process using genetic algorithms [J]. ISA Transactions, 2006, 45(4): 589 - 602.
- [4] Song Ying, Chen Zengqiang, Yuan Zhuzhi. New chaotic PSO-based neural network predictive control for nonlinear process [J]. IEEE Transactions on Neural Networks, 2007, 18(2): 595 - 600.
- [5] Sandou G, Oлару S. Ant colony and genetic algorithm for constrained predictive control of power systems [J]. Lecture Notes in Computer Science, 2007: 4416: 501 - 514.
- [6] 朱红霞, 沈炯, 丁轲轲. 单元机组负荷非线性预测控制及其仿真研究 [J]. 中国电机工程学报, 2006, 26(23): 72 - 77.
Zhu Hong-xia, Shen Jiong, Ding Ke-ke. Nonlinear predictive control on the load system of a thermal power unit and its simulation study [J]. Proceedings of the CSEE, 2006, 26(23): 72 - 77. (in Chinese)
- [7] 周雅兰, 王甲海, 印鉴. 一种基于分布估计的离散粒子群优化算法 [J]. 电子学报, 2008, 36(6): 1242 - 1248.
Zhou Ya-lan, Wang Jia-hai, Yin Jian. A discrete particle swarm optimization algorithm based on estimation of distribution [J]. Acta Electronic Sinica, 2008, 36(6): 1242 - 1248. (in Chinese)
- [8] Passino K M. Biomimicry of bacterial foraging for distributed optimization and control [J]. IEEE Control Systems Magazine, 2002, 22(3): 52 - 67.
- [9] Tsutsui S, Pelikan M, Goldberg D E. Probabilistic model-building genetic algorithms using marginal histograms in continuous domain [A]. Proceedings of the International Conference on Knowledge Based Intelligent Information Engineering Systems and Allied Technology [C]. Amsterdam, Netherlands: IOS

Press, 2001. 112 – 121.

- [10] Kennedy J, Eberhart R C. Swarm intelligence[M]. Morgan, Kaufmann Publishers, 2001.
- [11] Ratnaweera A, Halgamuge K S. Selforganizing hierarchical particle swarm optimizer with time-varying acceleration coefficients[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 240 – 254.
- [12] Mathew S, Terence S. Breeding swarms: a GA/PSO hybrid [A]. Proceedings of Genetic and Evolutionary Computation [C]. New York: ACM Press. 2005. 161 – 168.

作者简介:



王雪松 女, 1974 年生于安徽泗县, 2002 年获中国矿业大学控制理论与控制工程专业博士学位, 2002 年至 2004 年于北京理工大学控制科学与工程博士后流动站从事博士后工作, 现为中国矿业大学信息与电气工程学院副教授. 主要研究方向为机器学习、复杂系统优化与控制、生物信息学等.

E-mail: wangxuesongcumt@163.com



程玉虎 男, 1973 年生于安徽淮南, 2005 年获中国科学院自动化研究所控制理论与控制工程专业博士学位, 现为中国矿业大学信息与电气工程学院副教授. 主要研究方向为机器学习和智能系统等. E-mail: chengyuhu@163.com



郝名林 男, 1985 年生于江苏淮安, 2006 年获中国矿业大学学士学位, 现为中国矿业大学控制理论与控制工程专业硕士研究生, 研究方向为智能优化理论与应用.