

文章编号: 1001-0920(2009)12-1841-05

基于杂合机制的免疫遗传算法在动态问题中的应用

刘黎黎, 汪定伟

(东北大学 信息科学与工程学院, 沈阳 110004)

摘要: 针对遗传算法在求解动态问题时存在多样性缺失, 无法快速响应环境变化的问题, 提出一种基于杂合子机制的免疫遗传算法. 该算法借鉴免疫系统中多样性与记忆机理, 从保持等位基因多样性出发, 在免疫变异中引入杂合映射机制, 使种群能够探索更大的解空间. 同时, 通过引入记忆策略, 使算法迅速跟踪最优解变化轨迹. 该方法在动态 0-1 优化问题的求解中取得了较好的效果.

关键词: 动态优化; 免疫遗传算法; 杂合映射; 记忆策略

中图分类号: TP18 **文献标识码:** A

Heterozygosis-based immune genetic algorithm for dynamic optimization problems

LIU Li-li, WANG Ding-wei

(College of Information Science and Engineering, Northeastern University, Shenyang 110004, China. Correspondent: LIU Li-li, E-mail: liulili1202@gmail.com)

Abstract: In order to prevent the diversity loss and enhance the adaptation capacity for genetic algorithm in dynamic environments, a heterozygosis-based immune genetic algorithm is proposed for solving dynamic problem. Inspired by the diversification and memory mechanisms in the immune system, for the purpose of maintaining diversity of allies, a heterozygosis-based mapping operator is introduced in the process of immune mutation, which helps individuals to explore the search space comprehensively. Meanwhile, a memory-based scheme is introduced to speed up the reaction to the moving optima. The proposed algorithm is applied to the dynamic 0-1 optimization problems with promising results.

Key words: Dynamic optimization; Immune genetic algorithms; Heterozygosis-based mapping; Memory-based scheme

1 引言

动态优化问题在现实生活与工程实际中具有广泛的应用背景. 如在生产调度问题中, 原材料质量的变化、新工件的随时到达以及机器发生故障等^[1], 在车辆调度中, 路径代价的改变、顾客需求增减等^[2], 都给问题的求解带来了复杂性.

遗传算法(GA)作为一种适应性的全局搜索算法, 已应用于大量静态问题中, 并取得了满意的效果. 相比之下, 动态环境中的 GA 不仅需要快速而准确地找到最优解, 而且还需要连续地跟踪最优解的变化轨迹^[2], 这就给传统 GA 带来了挑战. GA 在求解动态问题时面临的最大难点是: 随着迭代次数的增加, 种群会趋于收敛, 在新环境下, 多样性缺失会

削弱算法的探索能力. 因此, 如何在利用有价值的历史信息同时, 有效地增加种群多样性, 增强种群在动态环境下的适应能力, 已成为应用 GA 求解动态问题的一个研究热点^[3,4]. 其中, Yang^[5]提出了一种原对偶映射方法(PDGA), 使低适应值个体有机会探索当前环境下更好的区域, 并在此基础上引入了记忆策略. 实验证明, 这种结合多样性和记忆机制的方法有助于种群更好地适应动态环境.

以生物免疫机理为基础的人工免疫系统为智能优化方法提供了新的思路^[6,7], 免疫系统具有抗体多样性和自我调节能力. 本文将免疫调节中的多样性与记忆机制引入遗传算法, 提出一种新的基于杂合子机制的免疫遗传算法(HIGA). 一方面, 借鉴遗

收稿日期: 2008-11-25; **修回日期:** 2009-02-15.

基金项目: 国家自然科学基金项目(70931001, 70771021); 国家自然科学基金创新群体项目(60821063); 教育部博士点基金项目(200801450008).

作者简介: 刘黎黎(1980—), 女, 长春人, 助教, 博士生, 从事动态进化计算的研究; 汪定伟(1948—), 男, 江西彭泽人, 教授, 博士生导师, 从事建模与优化、生产计划与调度等研究.

传学中复合杂合子的作用机理,使等位基因按位值映射为不同的基因值,增强种群多样性;另一方面,提取在记忆中对当前环境有价值的信息,使种群更快地适应动态环境,迅速跟踪最优解变化轨迹,节省计算资源.该算法在动态 0-1 优化问题中取得了较好的效果.

2 基于杂合机制的免疫遗传算法

2.1 免疫系统借鉴原理

自然界中,生物体通过免疫系统自适应地识别、记忆,以排除外部侵入的抗原性异物,维护体内环境的稳定.免疫系统的两个重要特征是^[8,9]:免疫调节功能和记忆功能.免疫调节功能:免疫系统是自适应系统,通过细胞的克隆增殖作用产生多类型抗体,以适应不同环境;记忆功能:抗原初次侵入生物体内,系统产生记忆细胞,当相似类型的抗原再次侵入时,记忆细胞被重新激活,以促进免疫应答的效率.

这样,可以将外界环境中不断产生的抗原对应于变化的问题,抗体对应于问题的可行解,而抗原对应于函数目标,求解目标即在动态环境下快速找到与当前抗原最佳匹配的抗体(即新环境下的最优解或满意解).

2.2 算法设计

算法总体思想是:为了增强种群在动态环境中的探索力度,在克隆操作中引入基于杂合机制的映射策略,防止种群整体进化信息的停滞;为使个体更快地响应动态环境,在探测到环境变化时,重新激活有价值的记忆信息,对与当前环境最匹配的记忆个体进行克隆变异,在扩大搜索空间的同时兼顾寻优速度,使种群更快地跟踪环境变化.

2.2.1 杂合映射算子

遗传学中,杂和子缺失是导致生物多样性减少的因素之一.复合杂合子是指等位基因进行不同方式突变的染色体,而这种等位基因突变相异的趋势可导致种群多样性的增强.相对地,在遗传算法进化后期,基因模式相似,种群多样性减少,表现为单一的基因位值占据了该基因位的绝大多数位置,个体的趋同将导致整个种群在动态环境中的探索能力下降.

双概率原对偶遗传算法(DPPDGA)将种群中某一基因位上,数目相对较少的基因位值定义为该基因位的弱势基因位值(反之为强势基因位值),依据杂合子机理,通过对该数目进行适应性调整来控制两个突变的概率.本文将该方法引入个体的克隆变异运算中,从而根据环境的反馈信息调节种群多样性.

这里,设在 t 代种群中以概率 p_d 选择个体进行

克隆, $p_k^{inf}(t)$ 和 $p_k^{sup}(t)$ 分别表示该基因位值为弱势与强势的映射概率,映射示例如图 1 所示.

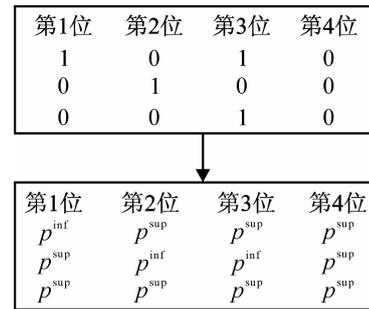


图 1 基于杂合子机制映射实例

下面将 $p_k^{inf}(t)$ 和 $p_k^{sup}(t)$ 计算过程简述如下.

设种群大小为 NP , 编码长度为 L , $I_k(t)$ 表示 t 代种群中第 k 基因位弱势基因位值期望数目, $\gamma_k(t)$ 和 $\eta_k(t)$ 分别表示非克隆个体和克隆个体中第 k 基因位值为弱势基因位值的数目,则有

$$I_k(t) = \gamma_k(t) + \eta_k(t) + (N_c - \eta_k(t)) \times p_k^{sup}(t) - \eta_k(t) \times p_k^{inf}(t). \quad (1)$$

取 $ND \leq NP/2$, 由 $p_k^{sup}(t) \in [0, 1]$, 有

$$0 \leq \frac{I_k(t) - \gamma_k(t) - \eta_k(t) + \eta_k(t) \times p_k^{inf}(t)}{N_c - \eta_k(t)} \leq 1. \quad (2)$$

对上式分两种情况讨论:

1) $N_c = \eta_k(t)$, $p_k^{sup}(t) = p_k^{inf}(t) = 0$. 原染色体的基因位均被弱势基因位值占据,对偶算子不参与运算.

2) $N_c > \eta_k$ 时:

① $\eta_k(t) = 0$, 原染色体第 k 位上无弱势基因,有

$$p_k^{sup}(t) = \frac{I_k(t) - \gamma_k(t)}{ND}. \quad (3)$$

② $\eta_k(t) > 0$ 时,有

$$\frac{\gamma_k(t) + \eta_k(t) - I_k(t)}{\eta_k(t)} \leq p_k^{inf}(t) \leq \frac{ND + \gamma_k(t) - I_k(t)}{\eta_k(t)}. \quad (4)$$

可求得该不等式的边界成立条件为

$$\gamma_k(t) \leq \eta_k(t) \leq \gamma_k(t) + N_c. \quad (5)$$

由式(1)有 $\gamma_k(t) + \eta_k(t) < I_k(t)$. 由上式可取

$$p_k^{inf}(t) = \min\left(\frac{ND + \gamma_k(t) - I_k(t)}{\eta_k(t)}, 1\right) \times \epsilon, \quad (6)$$

其中 $\epsilon \in (0, 1)$. 反之,

$$p_k^{inf}(t) = p_k^{sup}(t) = 0.$$

为了增强算法在较好区域的开发性能,提高寻优速度, $I_k(t)$ 随进化代数的增加应逐渐减小,为此,引入如下弱势基因数目调整因子:

$$\mu(t) = \cos(\pi \times t^2 / 2 \times T^2). \quad (7)$$

其中: t 为当前进化代数, T 为动态环境变化周期. 当

$T = 100$ 时, $\mu(t)$ 的形状如图 2 所示.

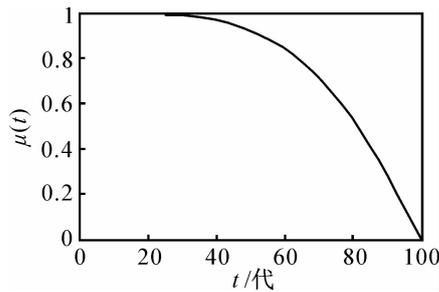


图 2 $T = 100$ 时, $\mu(t)$ 随代数 t 变化曲线

由图 2 可见, 进化初期 $\mu(t)$ 的下降速度较慢, 可以保证进化前期种群的多样性, 扩大寻优范围; 而后期的下降速度较快, 以增强进化后期算法的开发能力.

结合式(5), 按照下式对弱势基因位值的数目进行适应性调整:

$$I_k(t) = \begin{cases} NP/2, & t = 0; \\ \max(1, \min(\mu(t) \times I^{-1}(k), & (8) \\ N_c + \eta_k(t)), \eta_k(t)), & t > 0. \end{cases}$$

2.2.2 记忆策略

环境变化后, 为使种群在当前较好区域搜索, 引入记忆策略. 基于记忆方法的 3 要素如下:

1) 记忆存储. 一般来说, 记忆种群中存储的个体在历史环境中应具有较好的适应能力, 这里取某代种群中最好解作为记忆个体. 记忆个体与相应的最优值成对地记录下来, 并将后者作为提取该个体的依据.

2) 记忆更新. 所利用的记忆信息应能反映种群历史进化情况, 也应及时反馈当前状态. 这里取更新时段间隔 $t_M = t_c + \text{Rand}(5, 10)$, t_c 为环境变化的代数. 用当前最优解替代记忆种群中最差个体以完成记忆种群更新, 使存储信息可以在某种程度上及时跟踪环境变化.

3) 记忆利用. 当探测到环境变化后, 与当前环境最匹配的个体(根据之前存储的最优值提取)被激活, 进行基于杂合机制的克隆变异运算, 得到 N_m 个新个体, 替换掉种群中较差的等数目个体.

综上, 动态环境中的 HIGA 设计如下:

Step1: 初始化操作. 设定种群大小 NP , 最大代数 NG , 计时器 $t := 0$, 随机产生初始种群 $P(0)$ 和记忆个体 $M(0)$.

Step2: 若满足终止条件, 则转 Step8; 否则, 执行 Step3 ~ Step7.

Step3: 评价 $P(t)$ 中的个体和 $M(t)$.

Step4: 检测种群平均最优值是否减小. 若减小, 则说明环境变化, 执行 Step5 和 Step6.

Step5: 记忆利用.

Step6: 更新记忆.

Step7: 以克隆概率 p_d 选择个体, 按照式(8)进行克隆变异.

Step8: 输出结果.

3 仿真结果与分析

3.1 动态测试函数

选取在静态问题中常用的两个测试函数: Royal Road 函数和欺骗函数, 采用异或(XOR)^[11]方法构造动态测试环境. 两个静态函数及构造方法简述如下.

3.1.1 Royal Road 函数

在一个长度为 64 位包含有 8 个连续的 8 位 Building Blocks 的位串上, 函数的适值计算如下:

$$f(x) = \sum_{i=1}^8 c_i \cdot \delta_i(x). \quad (9)$$

其中: $c_i = 8$, $\delta_i(x) = \{1, \text{如果 } x \in S; 0, \text{否则}\}$. 该 Royal Road 函数的最优值为 64.

3.1.2 欺骗函数

对于 3 阶模式(完全)欺骗问题, 编码空间中 $\{0, 1\}^3$ 元素的适应值如下:

$$\begin{aligned} f(000) &= 28, & f(001) &= 26, \\ f(010) &= 22, & f(011) &= 0, \\ f(100) &= 14, & f(101) &= 0, \\ f(110) &= 0, & f(111) &= 30. \end{aligned}$$

可见, 该静态问题的最优值为 300.

3.1.3 动态环境构造方法

XOR 方法可简述为: 随机产生或者以某种控制方式产生一个模板 T , 然后对目标串 X 进行“异或”(XOR)运算, 这里用“ \oplus ”表示(比如, $0 \oplus 0 = 0$, $1 \oplus 0 = 1$, $1 \oplus 1 = 0$). 在模板 T 中若某一位值为 1, 则位运算时, 目标串 X 对应的位会发生变化(从 0 变成 1, 或者从 1 变成 0); 而值为 0 时, X 中的对应位将保持不变. 因此 T 所包含的值为 1 的位与模板长度比值可看成是环境变化强度大小, 用 ρ 表示.

假设在第 t 代环境发生变化, 则在 $(t+1)$ 代个体 X 评价方法如下:

$$f(X, t+1) = f(X \oplus T, t). \quad (10)$$

这里, 振荡周期 τ 被依次设为 10, 50, 100 和 200, 分别表示环境变化发生在算法的早期、中期及后期收敛阶段. ρ 值依次被设为 0.1, 0.5, 0.7 和 0.9, 分别表示环境变化强度很小到适中直至强烈.

3.2 实验设置

在上述动态环境下, 对 HIGA 算法进行测试, 并根据文献[11]的参数设置数据和与标准遗传算法(SGA), PDGA 进行比较. 种群大小 $NP = 100$, 采用轮盘赌选择和精英保留策略. 对于 HIGA, 克隆概率

$p_d = 0.8$, 记忆种群规模 $M = 0.1 \times NP = 10$, 替代个体数 $N_m = 10$. 其他两种算法采用单节点交叉, 交叉率 $p_c = 0.6$; 位变异, 变异率 $p_m = 0.001$. 每个实例运行 50 次, 取平均值.

3.3 实验结果与分析

图 3, 图 4 分别是 3 种算法最优解平均值的比较结果. 采用自由度为 98, 显著性水平 0.05 的 t 检验方法^[12], 相应的统计结果如表 1, 表 2 所示. 表中, 用“+”, “~”和“-”分别表示算法 1 显著优于、基本等于和明显劣于算法 2.

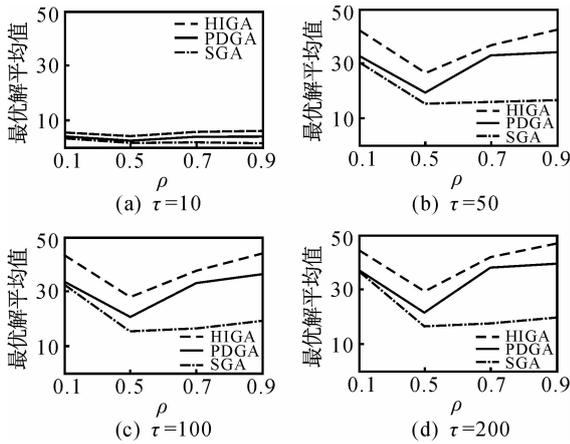


图 3 Royal Road 函数中的最优解平均值

表 1 Royal Road 函数中算法 t -检验结果

ρ	0.1				0.5				0.7				0.9				
	τ	10	50	100	200	10	50	100	200	10	50	100	200	10	50	100	200
HIGA-SGA	~	+	+	+	~	+	+	+	+	+	+	+	+	+	+	+	+
HIGA-PDGA	~	+	+	+	~	+	+	+	+	~	+	+	+	~	+	+	+

表 2 欺骗函数中算法 t -检验结果

ρ	0.1				0.5				0.7				0.9				
	τ	10	50	10	50	10	50	10	50	10	50	100	200	10	50	100	200
HIGA-SGA	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+	+
HIGA-PDGA	+	+	+	+	+	+	+	+	+	+	+	+	+	~	+	+	+

法中 SGA 表现最差, 这进一步说明了动态环境中引入多样性和记忆机制的重要性.

为了更好地比较算法对最优解的跟踪能力, 进一步引入累积平均最优解 p^* 作为算法性能的评估指标. p^* 的计算公式为^[13]

$$p^*(T) = \frac{1}{T} \sum_{i=1}^T e_i^*, \quad T = 1, 2, \dots, NG, \quad (12)$$

其中 e_i^* 是到第 i 次估值为止所获得的最好解.

图 5 是在动态欺骗函数中 $\rho = 0.5$ 时算法的累积平均最优值曲线. 由图 5 可得如下结论: 1) HIGA 比其他两种算法具有更快和更稳定的寻优速度, 在环境变化时能尽快适应环境变化, 这进一步证实了算法的有效性; 2) HIGA 的优势在振荡周期较小时体现

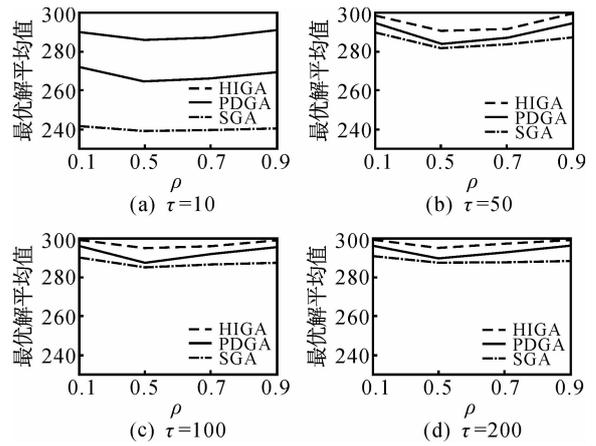


图 4 欺骗函数中的最优解平均值

由表 1, 表 2 和图 3, 图 4 可得如下结论: 1) HIGA 在各种测试环境下的动态性能均普遍优于其他两种算法, 这说明本文采用的基于免疫系统的记忆与多样性机制是有效的, 尤其在环境变化较小或适中 ($\rho = 0.1$ 和 $\rho = 0.5$) 时, 这种优势体现得更为明显. 这主要是由于当环境变化不是很剧烈时, 历史记忆信息对相似环境下的寻优更有指导意义. 2) HIGA 的性能比 PDGA 好, 这说明基于杂合机制的映射方法能够有效增强种群多样性, 扩大搜索空间. 一般来讲, 一个发散的种群更能适应动态环境. 3) 在 3 种算

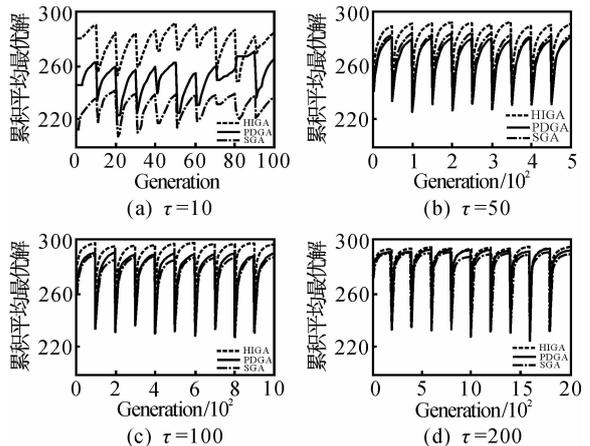


图 5 欺骗函数中 $\rho = 0.5$ 时的动态性能曲线

更为明显,这是因为所采用的记忆机制可以在环境变化后较快地产生适合当前环境的个体,增强寻优效率;3) 算法性能与动态参数设置有较大关系。

4 结 论

对动态环境下进化算法的研究具有十分重要的实际意义. 为了增强遗传算法求解动态问题的性能, 本文提出了基于杂合机制的免疫遗传算法. 该算法的优势主要体现在两个方面: 1) 将基于杂合机制的映射方法引入克隆变异中, 可使种群获得更好的多样性, 通过当前环境反馈信息适应性地调整基因位值, 可使种群更好地跟踪最优点变化轨迹; 2) 记忆策略将以往有价值的信息以上述克隆方式进行改进, 在提高算法寻优速度的同时兼顾了多样性要求, 提高了算法的鲁棒性. 本研究为动态 0-1 优化问题的求解提供了一种有效的方法。

参考文献 (References)

- [1] Branke J. Evolutionary optimization in dynamic environments [M]. Boston: Kluwer Academic Publishers, 2002.
- [2] 王洪峰, 汪定伟, 杨圣祥. 动态环境中的进化算法[J]. 控制与决策, 2007, 22(2): 127-131.
(Wang H F, Wang D W, Yang S X. Evolutionary algorithm in dynamic environment [J]. Control and Decision, 2007, 22(2): 127-131.)
- [3] Branke J, Kaubler T, Schmidt C. A multi-population approach to dynamic optimization problems [C]. Adaptive Computing in Design and Manufacturing. Heidelberg: Springer, 2000.
- [4] Branke J. Memory enhanced evolutionary algorithms for changing optimization problems[C]. Proc of IEEE Int Congress on Evolutionary Computation. Piscataway: IEEE Service Center, 1999: 1875-1882.
- [5] Yang S. Non-stationary problem optimization using the primal-dual genetic algorithm [C]. Proc of the 2003 Congress on Evolutionary Computing. Canberra, 2003, (3): 2246-2253.
- [6] Gaspar A, Collard P. From GAs to artificial immune systems: Improving adaptation in time dependent optimization [C]. Proc of the 1999 Congress on Evolutionary Computing. Washington DC, 1999, (3): 1859-1866.
- [7] Gaspar A, Collard P. Two models of immunization for time dependent optimization[C]. Proc of the 2000 IEEE Int Conf on SMC. Washington DC, 2000: 189-196.
- [8] Simoes A, Costa E. An immune system-based genetic algorithm to deal with dynamic environments: Diversity and memory [C]. Proc of the 6th Int Conf on Neural Networks and Genetic Algorithms. Hong Kong, 2003: 168-174.
- [9] Simoes A, Costa E. Improving the genetic algorithm's performance when using transformation[C]. Proc of the 6th Int Conf on Neural Networks and Genetic Algorithms. Hong Kong, 2003: 175-181.
- [10] Yang S, Yao X. Experimental study on population-based incremental learning algorithms for dynamic optimization problems [J]. Soft Computing, 2005, 9 (11): 815-834.
- [11] Yang S. Non-stationary problem optimization using the primal-dual genetic algorithm [C]. Proc of the 2003 Congress on Evolutionary Computing. Canberra, 2003, (3): 2246-2253.
- [12] Liu L L, Wang D W, Ip W H. A permutation-based dual genetic algorithm for dynamic optimization problems[J]. Soft Computing, 2008, 13(7): 725-738.
- [5] Chen W H, Ballance D J, Gawthrop P J. Optimal control of nonlinear systems: A predictive control approach[J]. Automatica, 2003, 39(4): 633-641.
- [6] Chen W H. Analytic predictive controllers for nonlinear systems with ill-defined relative degree[J]. IEE Proc: Control Theory and Applications, 2001, 148(1): 9-15.
- [7] Chen W H. Predictive control of general nonlinear systems using approximation[J]. IEE Proc: Control Theory and Applications, 2004, 151(2): 137-144.
- [8] Chen W H. Closed-form nonlinear MPC for multivariable nonlinear systems with different relative degree[C]. Proc of the American Control Conf. Denver: IEEE Press, 2003: 4887-4892.
- [9] Chen W H, Ballance D J. On a switching control scheme for nonlinear system with ill-defined relative degree[J]. Systems and Control Letters, 2002, 47(2): 159-166.
- [10] 张国银, 杨智, 谭洪舟. 一类非线性系统非切换解析模型预测控制方法研究[J]. 自动化学报, 2008, 34(9): 1147-1156.
(Zhang G Y, Yang Z, Tan H Z. Research on no-switch analytic nonlinear model predictive control method for a class of nonlinear systems[J]. Acta Automatica Sinica, 2008, 34(9): 1147-1156.)

(上接第 1840 页)