

基于滑模控制的改进差分进化算法^①

刘珑龙, 于盛楠, 高存臣

(中国海洋大学 数学科学学院, 青岛 266100)

通讯作者: 于盛楠, E-mail: yushengnan@stu.ouc.edu.cn

摘要: 针对机器人轨迹规划问题, 提出了一种基于滑模控制的改进差分进化 (IDE) 算法. 以运行时间和能量损耗为目标函数. 利用种群中最好个体和平均水平个体的差分引导变异方向, 利用种群中最好个体替换最差个体, 加快收敛速度. 取消变异因子和交叉因子, 降低人工干预, 增强了模型稳定性. 利用保形分段三次 Hermite 插值代替三次样条插值, 防止拟合过冲, 降低了抖振. 基于给出的状态空间方程, 设计了滑模控制律, 通过李亚普诺夫函数方法证明了系统的稳定性. 仿真实验和结果分析表明, 改进的算法有较强的搜索能力, 加快了收敛速度, 降低了运动轨迹的抖振.

关键词: 滑模控制; 轨迹规划; 差分进化算法

引用格式: 刘珑龙, 于盛楠, 高存臣. 基于滑模控制的改进差分进化算法. 计算机系统应用, 2018, 27(12): 156-162. <http://www.c-s-a.org.cn/1003-3254/6680.html>

Improved Method of Difference Evolution Algorithm Based on Sliding Mode Control

LIU Long-Long, YU Sheng-Nan, GAO Cun-Chen

(School of Mathematical Sciences, Ocean University of China, Qingdao 266100, China)

Abstract: For the robot trajectory planning problem, an improved Differential Evolution (DE) algorithm based on sliding mode control is proposed. The operation time and energy consumption is taken as the objective function. The direction of variation is guided by the difference between the best individuals and the average individuals in the population. Using the best individuals to replace the worst individuals in the population, the rate of convergence is accelerated. Removal of mutation factor and cross factor reduces manual intervention and enhances the stability of the model. Using piecewise Hermite interpolation of order 3 instead of spline interpolation of order 3 to prevent fitting overshoot and reduce chattering. Based on the system state space equation, a sliding mode control law was designed and stability is proved by using a Lyapunov function. Simulation experiments and the analysis of results are demonstrated that the improved algorithm not only has strong search ability but also accelerate the convergence rate and reduce the chattering effect in the trajectory planning of the system states.

Key words: sliding mode control; trajectory planning; differential evolution algorithm

在机器人轨迹规划的过程中会产生震荡, 造成额外能量消耗. 而在定点运动中, 不同的运动轨迹会造成不同程度的抖振. 如何设计机器人的最优轨迹优化问题受到了工业界和学术界的广泛关注. 传统的机器人

轨迹规划多以运行时间指标为目标, 采用 B 样条插值对一系列离散路径点拟合^[1], 在边界层出现稳态跟踪误差, 运动平稳性较差. 近几年, 杨国军等^[2]对简单遗传算法进行了改进, 将模糊原理应用于遗传算法, 提出了一

① 收稿时间: 2018-05-10; 修改时间: 2018-06-04; 采用时间: 2018-06-14; csa 在线出版时间: 2018-12-03

种基于模糊遗传算法的机械手时间最优轨迹规划方案。王宪等^[3]提出基于改进蚁群算法的机器人轨迹规划,引入带方向信息的全局启发因子来提高最优路径的搜索效率。甘亚辉等^[4]采用遗传算法综合考虑各机器人沿轨迹运动的安全性,运动代价以及运动约束,获得了单个机器人规划最优的运动轨迹。付荣等提出了关节空间基于粒子群优化^[5]和自适应遗传算法^[6]的时间最优 3-5-3 多项式插值轨迹规划算法,解决了由于多项式插值轨迹规划具有阶次高,没有凸包性质的缺点,难以应用传统优化方法进行优化的问题。王学琨等^[7]针对六自由度关节型解耦机械臂在抓取目标物体过程中出现的不稳定性、快速性以及最大速度约束的问题,提出了一种利用 DE 算法优化的时间最优 3-5-3 多项式插值机械臂轨迹规划算法。余阳^[8],赫建立等^[9]采用高次均匀 B 样条插值,提出了基于遗传算法的轨迹规划方案,该方案比较理想地兼顾了工业机器人工作效率与轨迹的平稳性。刘一扬等^[10]改进了遗传算法的机器人运动轨迹跟踪控制,在机器人运动轨迹滑模面设计一个跟踪误差的积分补偿器,缓解了运动轨迹跟踪控制在边界层出现稳态跟踪误差。邓飙等^[11]使用五次 B 样条插值规划轨迹,引入了罚函数处理约束条件,利用非支配排序遗传算法 (NSGA-II) 对轨迹进行多目标优化,选择了最为平滑且时间最优的解作为最终解。殷凤健等^[12]利用三次样条插值和自适应遗传算法对运动轨迹进行了时间最短优化,并利用罚函数解决了系统运动的约束问题。对于固定时间顶点的最优轨迹规划问题的目标函数,求得了使得整个运动过程消耗最小的能量函数。梁延德等^[13]在每两个相邻的目标点之间构造分段数为 7 的三次样条函数,证明了此时的插值函数有能力描述时间最短的轨迹问题,并用 BFGS 方法进行了优化计算。

对于机器人可行轨迹的规划问题,上述算法往往仅在以总时间为指标的目标函数上加上其他项,或者增大拟合多项式的次数,增大样条函数的次数上进行了改进。但是人工参与设置的参数过多,模型不稳定以及拟合过冲导致运动轨迹震荡的情况还未引起学者的足够重视。

本文针对种群优化算法中人工参数设置过多,模型训练过程不稳定以及拟合过冲导致运动轨迹震荡的情况,提出了一种基于滑模控制的改进差分进化 (IDE) 算法。该算法在变异阶段之前增加筛选阶段,求

出了当前群体的目标函数值最优 (适应度值最小) 的个体、适应度值最大的个体和所有个体的平均水平。在变异阶段,取消了变异因子,采用适应度值最小的个体和平均水平的个体提高种群中每一个个体的水平,用适应度值最小的个体替换适应度值最大的个体,加快收敛速度。取消了交叉阶段,减少了交叉因子的两个参数。在插值方面,采用了保形分段三次 Hermite 插值,降低了插值函数光滑性的要求,避免了模型不稳定以及拟合过冲导致运动轨迹震荡的情况。通过仿真实验和结果分析表明,本文给出的改进差分进化算法与传统方法相比,该方法具有明显的优势。

1 差分进化算法

1.1 差分进化算法的内容

差分进化算法是基于群体智能理论的优化算法,通过群体中个体间的合作与竞争更新群体,最终通过迭代更新,逼近最优解,因此可用于智能化优化搜索。标准差分进化算法是根据父代个体间的差分矢量进行变异,交叉和贪婪选择更新个体。其基本思想是从某一随机产生的初始群体开始,通过把种群中任意两个个体的向量差加权后乘上变异因子与第三个个体求和来产生新个体,然后将新个体与当代种群中某个预先决定的个体相比较,如果新个体的适应度值优于与之相比较的个体的适应度值,则在下一代中就用新个体取代旧个体,否则旧个体仍保存下来,通过不断地迭代运算,保留优良个体,淘汰劣质个体,引导搜索过程向最优解逼近。

在优化设计中,差分进化算法与传统的优化方法相比,具有以下主要特点:

(1) 差分进化算法从一个群体 (即多个点) 而不是从一个点开始搜索,这是它能以较大的概率找到整体最优解的主要原因。

(2) 差分进化算法的进化准则是基于适应性信息的,无须借助其他辅助性信息 (如要求函数可导或连续),大大地扩展了其应用范围。

(3) 差分进化算法具有内在的并行性,这使得它非常适用于大规模并行分布计算,减小时间成本开销。

(4) 差分进化算法采用概率转移规则,不需要确定性的规则。

但是标准的差分进化算法也存在以下问题:

(1) 变异阶段随机选取 3 个个体进行差分,然后加

权求和求出新个体,进行贪婪选择后,二选一保留原始个体或者用新个体替代原始个体.利用随机选取的个体进行更新,没有充分利用种群中表现最好的个体和种群总体的信息,收敛的速度和稳定性有待提高.

(2) 为了增大种群多样性,采用变异因子和交叉因子或者随迭代代数变化的自适应变异因子和交叉因子,在增大种群多样性,避免陷入局部最优的同时引入了需要人工干预的两个参数的取值范围.人工干预参数的引入,使得调参对于结果的影响很大,这不利于算法的应用和推广.

1.2 改进差分进化算法的内容基本流程

标准差分进化算法是基于实数编码的进化算法,整体结构上与其他进化算法类似,由变异,交叉和选择三个基本操作构成.改进的差分进化算法取消了交叉操作,主要包括以下几个步骤:

(1) 生成初始群体

在 n 维空间里,随机产生满足约束条件的 M 个个体作为初始种群,第 i ($i = 1, 2, \dots, M$)个个体表示如下:

$$x_{ij}(0) = r(x_{ij}^U - x_{ij}^L) + x_{ij}^L \quad (1)$$

其中, $j = 1, 2, \dots, n$, x_{ij}^U 和 x_{ij}^L 分别是第 i 个个体第 j 个维度的上界和下界; $r = r_{ij}(0, 1)$ 是 $[0, 1]$ 之间的随机数; $D+1$ 为每个样本固定点的数目.

(2) 筛选操作

计算所有个体的适应度值,对所有个体按照适应度值进行排序,求出最大、最小适应度值的个体和所有个体的平均值

$$x_{\text{best}}(t) = \{x_{ij} | \min(f(x_{i1}, x_{i2}, \dots, x_{in}))\} \quad (2)$$

$$x_{\text{bad}}(t) = \{x_{ij} | \max(f(x_{i1}, x_{i2}, \dots, x_{in}))\} \quad (3)$$

其中, $i = 1, 2, \dots, M$.

$$x_{\text{mean}}(t) = \text{mean}(x_1, x_2, \dots, x_n) \quad (4)$$

其中, $x_j, j = 1, 2, \dots, n$ 为 M 维的列向量, t 为代数. $x_{\text{best}}(t)$ 为当前代中种群中最好的个体; $x_{\text{bad}}(t)$ 为当前代中种群中最差的个体; $x_{\text{mean}}(t)$ 为当前种群中所有个体的平均值; $x_{bj}(t) - x_{\text{mean}}(t)$ 为差分向量.

(3) 变异操作

对所有个体进行的变异操作为:

$$x_{ij}(t+1) = x_{ij}(t) + \text{rand}((x_{\text{best}}(t) - x_{\text{mean}}(t))) \quad (5)$$

对表现最差个体的操作为:

$$x_{\text{bad}}(t+1) = x_{\text{best}}(t) \quad (6)$$

其中, $x_{ij}(t)$ 为上一代对应的个体, rand 为 $[-1, 1]$ 之间的随机数; $x_{\text{best}}(t)$ 为当前代中种群中最好的个体; $x_{\text{mean}}(t)$ 为当前种群中所有个体的平均值; $x_{bj}(t) - x_{\text{mean}}(t)$ 为差分向量.最后用种群中最好的个体代替种群中最差的个体.由于式(5)借鉴了当前种群中最好的个体信息,因而可加快收敛速度.由于每次用表现最好的个体替换表现最差的个体,每次迭代之后,种群的平均水平得到较大的提高.随着迭代次数的增多,种群中最好的个体和平均水平的个体的差分逐渐减小,种群的进化逐渐由粗放搜索转化到细化搜索.

(4) 选择操作

为确定 $x_{ij}(t)$ 是否成为下一代成员,首先判断其是否超过阈值,采用公式(7)进行更新,然后采用评价函数 $f(x_{i1}, x_{i2}, \dots, x_{in}), i = 1, 2, \dots, M$ 进行比较:

$$x_{ij}(t+1) = \begin{cases} \frac{1}{2}(x_{ij}^L + x_{\text{best},j}), x_{ij}(t) < x_{ij}^L \\ \frac{1}{2}(x_{ij}^U + x_{\text{best},j}), x_{ij}(t) > x_{ij}^U \end{cases} \quad (7)$$

$$F_{\text{next}} = f(x_{i1}(t+1), \dots, x_{in}(t+1))$$

$$F_{\text{now}} = f(x_{i1}(t), \dots, x_{in}(t))$$

$$x_j(t+1) = \begin{cases} x_j(t+1), F_{\text{next}} < F_{\text{now}} \\ x_j(t), F_{\text{next}} > F_{\text{now}} \end{cases} \quad (8)$$

其中, $x_j, j = 1, 2, \dots, n$ 为 M 维列向量.反复执行步骤(2)~(4)操作,直至达到最大迭代代数 T .

1.3 标准差分进化算法的参数设置

对于标准差分进化算法而言,为了取得理想的结果,需要对差分进化算法的各个参数进行合理的设置.针对不同的优化问题,参数的设置往往也不同.另外,为了使差分进化算法的收敛速度得到提高,学者们针对差分算法的核心部分,变异向量的构造形式提出了多种扩展形式,以适应更广泛的优化问题.

(1) 变异因子 F

变异因子 F 是控制种群多样性和收敛性的重要参数.一般在 $[0, 2]$ 之间取值.变异因子 F 值较小时,群体的差异度减小,进化过程不会跳出局部极值,导致种群过早收敛.变异因子 F 值较大时,虽然容易跳出局部极值,但是收敛速度会减慢.一般可选在 $F = 0.3 \sim 0.6$.

(2) 交叉因子 cr

群体的交叉因子 cr 一般在 $[0, 1]$ 之间选择,比较好的选择应在 0.3 左右, cr 取值偏大,收敛速度会加快,但

易发生早熟现象.

(3) 群体规模 M

群体所含个体数量 M 一般介于 $5D$ 和 $10D$ 之间 (D 为问题的维度), M 越大, 种群多样性越强, 获得最优解概率越大, 但是计算时间更长, 一般取 20~50.

(4) 最大迭代代数 T

最大迭代代数 T 一般作为进化过程的终止条件. 迭代次数越大, 最优解越精确, 但是计算的时间会越长, 需要根据具体问题设定.

以上四个参数对差分进化算法的求解结果和求解效率都有很大的影响, 因此要合理设定这些参数才能获得较好的效果.

1.4 改进差分进化算法的参数设置

对于改进的差分进化算法仅需设定种群规模 M 和最大迭代代数 T 两个参数, 减少了人工干预, 有利于模型的应用和推广.

对于机器人轨迹规划中最优轨迹规划的滑模控制问题, 为了将改进 DE 与标准 DE 进行对比, 此处的种群规模 M 和最大迭代次数 T 的设置与标准 DE 中相同.

2 基于最优轨迹规划的滑模控制

在控制系统的轨迹规划中, 为了使实际上生成的轨迹平滑, 在保持理想轨迹接近参考轨迹的同时, 还应确保系统在运动过程中消耗的总能量尽可能小, 可采用保形分段三次 Hermite 函数插值, 并结合改进的差分进化方法来进行轨迹规划.

2.1 轨迹规划算法与相关定理

考虑机械转动的二阶线性系统

$$I\ddot{\theta} + b\dot{\theta} = \tau + d \quad (9)$$

其中, θ 为角度, I 为转动惯量, b 为粘性系数, τ 为控制输入, d 为加在控制输入上的扰动, $|d| \leq \eta_2$.

通过差分进化方法, 沿着参考路径进行最优规划, 从而保证系统运动在不偏离参考路径的基础上, 采用滑模控制方法, 实现对最优轨迹的跟踪, 使整个运动过程中消耗的能量最小.

引理 1. 对 $V: [0, +\infty) \in \mathbf{R}$, 不等式方程

$$\dot{V} \leq -\alpha V + f, \forall t \geq t_0 \geq 0$$

的解为:

$$V(t) \leq e^{-\alpha(t-t_0)} V(t_0) + \int_{t_0}^t e^{-\alpha(t-\tau)} f(\tau) d\tau$$

其中, α 为任意常数^[14].

2.2 最优轨迹的设计

不失一般性, 最优轨迹可在定点运动-摆线运动轨迹的基础上进行优化. 摆线运动的表达式如下:

$$\theta_r = (\theta_d - \theta_0) \left[\frac{t}{T} - \frac{1}{2\pi} \sin\left(\frac{2\pi t}{T}\right) \right] + \theta_0 \quad (10)$$

其中, T 是摆线周期; θ_0 和 θ_d 分别是初始角度和目标角度. 由于差分进化算法是一种离散型算法, 因此需要对连续型的参考轨迹式 (10) 进行等时间采样, 采样时间间隔为 $\frac{T}{2n}$, 可得离散化参考轨迹为:

$$\theta_r = \bar{\theta}_{r,0}, \bar{\theta}_{r,1}, \dots, \bar{\theta}_{r,2n-1}, \bar{\theta}_{r,2n} \quad (11)$$

其中, $\bar{\theta}_{r,j}$ 表示在时刻 $t = \frac{j}{2n}T$ 对于 θ_r 的采样值 ($j = 0, 1, \dots, 2n$); $\bar{\theta}_r$ 是离散的参考轨迹. 定义 $\Delta\bar{\theta}_j(k)$ 为参考轨迹的偏差 ($j = 1, 2, \dots, n-1$), k 表示差分进化算法中的第 k 次迭代, 即得:

$$\bar{\theta}_{opj}(k) = \bar{\theta}_{r,j} + \Delta\bar{\theta}_j(k) \quad (12)$$

其中, $\bar{\theta}_{opj}(k)$ 表示在时刻 $t = \frac{j}{2n}T$ 由差分进化算法第 k 次迭代得到的关节角的修正角度.

2.3 最优轨迹的优化

最优轨迹能够通过优化与参考轨迹的偏差来间接得到. 假设系统达到稳定的最大允许时间为 $t = 3T_E$, 根据能量守恒定理, 用非保守力做功来表示系统在运动过程中消耗的总能量, 目标函数为:

$$J = \omega \int_0^{3T_E} |\tau\dot{\theta}| dt + (1-\omega) \int_0^{3T_E} s(t) dt \quad (13)$$

其中, ω 为权值, $\omega \in (0, 1)$; τ 为控制输入信号; $s(t) = s_d(t) = (\theta - \theta_r)$ 为实际跟踪轨迹 θ 与理想轨迹 θ_r 的距离.

通过采用差分进化算法, 优化轨迹式 (11), 使目标函数值最小, 从而获得最优轨迹. 标准差分进化算法的设定参数如下: 最大迭代次数 G , 种群规模 M , 变异因子 F , 交叉因子 cr . 经过差分进化算法可得到一组最优偏差, 进而得到最优的离散轨迹如下:

$$\bar{\theta}_{op} = [\bar{\theta}_{op,0}, \bar{\theta}_{op,1}, \dots, \bar{\theta}_{op,2n-1}, \bar{\theta}_{op,2n}] \quad (14)$$

为了获得连续型的最优轨迹, 采用保形分段三次 Hermite 插值进行轨迹规划, 即用保形分段三次 Hermite 插值的方法对离散轨迹进行插值的边界条件如下:

$$\theta_{op,0} = \bar{\theta}_{op,0} = \theta_0$$

$$\theta_{op,T} = \bar{\theta}_{op,2n} = \theta_d$$

$$\dot{\bar{\theta}}_{op}(0) = \dot{\bar{\theta}}_{op,0} = \dot{\theta}_0 = 0$$

$$\dot{\bar{\theta}}_{op}(T) = \dot{\bar{\theta}}_{op,2n} = \dot{\theta}_d = 0$$

插值节点为:

$$\theta_{op}(t_j) = \bar{\theta}_{op,j}, t_j = \frac{j}{2n} T_E, j = 1, 2, \dots, 2n - 1$$

将插值得到的连续函数 $\theta_{op}(k)$ 作为关节的最优轨迹. 定义跟踪误差为 $e = \theta_{op} - \theta$, 设计滑模函数为:

$$s = \dot{e} + ce \tag{15}$$

其中, $c > 0$ 为常数, 则

$$\begin{aligned} \dot{s} &= \ddot{e} + c\dot{e} = \ddot{\theta}_{op} - \ddot{\theta} + c\dot{e} \\ &= \ddot{\theta}_{op} - \frac{1}{I}(\tau + d - b\dot{\theta}) + c\dot{e} \end{aligned} \tag{16}$$

设计滑模控制律为:

$$\tau = b\dot{\theta} + \eta_2 \text{sgn}(s) + I(c\dot{e} + \ddot{\theta}_{op} + \eta_1 s) \tag{17}$$

其中, $\eta_1 > 0$.

定义 Lyapunov 函数为 $V = \frac{1}{2}s^2$, 则

$$\begin{aligned} \dot{V} &= -\eta_1 s^2 - \frac{s}{I}(d + \eta_2 \text{sgn}(s)) \\ &\leq -2\eta_1 V \leq 0 \end{aligned} \tag{18}$$

根据引理 1 中的不等式求解引理^[15], 解得

$$V(t) \leq V(0)e^{-\eta_1 t} \tag{19}$$

可见, $s(t)$ 为指数收敛, 收敛速度取决于 η_1 .

3 仿真实例

考虑简单的被控对象

$$I\ddot{\theta} + b\dot{\theta} = \tau + d$$

其中, $I = \frac{1}{133}$, $b = \frac{25}{133}$, $d = \text{sint}$, 采样时间为 $ts = 0.001$, 采用 Z 变换进行离散化. 仿真实验中, 最大允许时间为 $3T_E$, 摆线周期 $T_E = 1$, 在摆线周期内, 取采样点数的一半, 即 $n = 500$, 则采样时间为 $ts = \frac{T_E}{2n} = 0.001$. 采样采用保形分段三次 hermite 插值方法, 插值点选取 4 个点, 即通过插值点的优化来初始化路径. 具体方法为: 插值点横坐标固定取第 200, 第 400, 第 600 和第 800 个点, 纵坐标取初始点和终止点之间的 4 个随机值, 第 i 个样本($i = 1, 2, \dots, Size$)第 j 个插值点($j = 1, 2, 3, 4$)的值取

$$\theta_{op,ij} = r(\theta_d - \theta_0) + \theta_0$$

其中, r 为 $0 \sim 1$ 之间的随机值.

采用改进的差分进化算法设计最优轨迹 θ_{op} , 取权值 $\omega = 0.5$, 种群规模 $M = 30$. 分别通过 DE 和 IDE 不断优化 4 个插值点的纵坐标, 直到达到满意的优化指标或最大迭代代数为止, 这里设定最大迭代代数 $T = 90$. 跟踪指令为 $\theta_d = 0.5$, 采用 (15) 中的滑模控制律, 取 $c = 30$, $\eta_1 = 300$, 为了降低抖振, 采用饱和函数代替符号函数, 取 $\Delta = 0.05$, $\eta_2 = 1.01$.

4 结果分析

2010 年 Weber 设计了对缩放因子 F 进行了适应性的调整^[16]分布式 DE 算法 (FACPDE). 2012 年文献^[17]提出了对 F 和 C 进行动态调整的分布式 DE 算法 (DDE-PTS). 将标准 DE, IDE, FACPDE, DDE-PTS 与滑模控制相结合, 得到仿真结果如图 1~图 3 所示. 图 1 为 DE 与 IDE 控制输入信号图, 图 2 为 DE FACPDE, DDE-PTS 与 IDE 控制输入信号图. 图 1 和图 2 显示了 IDE 相比 DE, FACPDE 和 DDE-PTS 对于消除抖振的效果更佳显著. 标准差分进化算法由于采用了三次样条插值, 要求曲线存在二阶连续偏导, 更加平滑; 由于要解决的问题中存在二阶导数, 改进 DE 采用保形分段三次 Hermite 插值, 对于二阶导数仅要求存在, 弱化了条件, 防止了拟合过冲, 使用范围更广. FACPDE, DDE-PTS 由于人工参数设置的影响, 导致收敛过程中信号的不稳定性. 从图 3 的适应度函数曲线和图 4 的目标函数优化的最优轨迹效果图中, 可以看出, 足够长时间后, DE、FACPDE、DDE-PTS 和 IDE 均可逼近最优解且 IDE 优化最优轨迹求出最优解的速度比 DE, FACPDE 和 DDE-PTS 更快. IDE 由于在变异阶段充分利用了群体中最优个体的信息和种群的平均水平, 收敛速度有了很大的提升. 此外, IDE 去掉了变异因子和交叉因子, 仅需设置种群数目和最大迭代次数两个参数, 减少了人为参与, 算法的稳定性得到很大程度的提高, 有利于算法的使用和推广. 上述结果验证了 IDE 算法在轨迹规划方面的合理性和有效性.

5 结论

本文研究了机器人的轨迹规划问题, 并提出了基于滑模控制的 IDE 算法. 该算法在变异阶段充分利用了种群中表现最好的个体和种群中所有个体的信息,

利用表现最好的个体的信息与平均水平的个体的差分引领种群迭代更新的方向, 利用表现最好的个体替换表现最差的个体, 加快了收敛速度. 取消了变异阶段的变异因子和交叉阶段, 去掉了变异因子和交叉因子两个人工调整的参数, 增强了模型的稳定性, 有利于模型发推广应用. 在拟合阶段采用采用保形分段三次 Hermite 插值, 避免了拟合过冲, 降低了插值函数光滑性的要求, 增大了算法的使用范围.

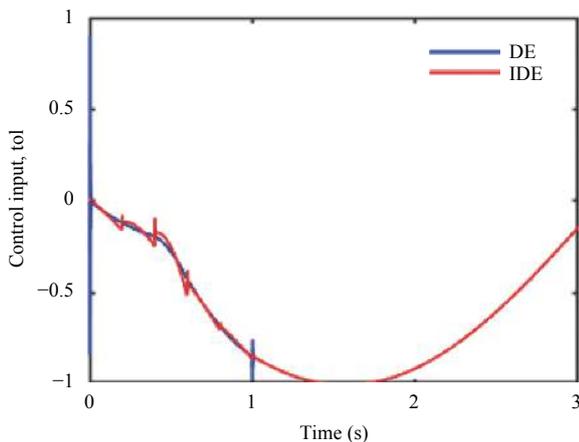


图1 DE 与 IDE 控制输入信号图

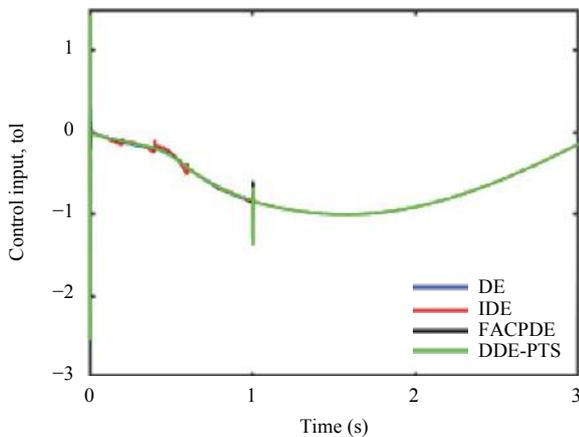


图2 DE,FACPDE,DDE-PTS 与 IDE 控制输入信号图

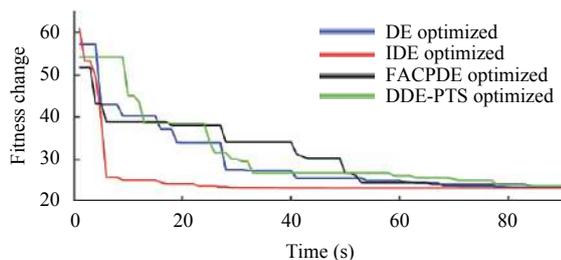


图3 适应度函数曲线

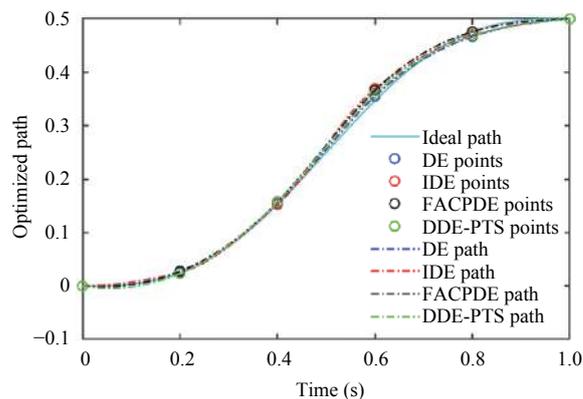


图4 最优轨迹效果图

本文工作表明, 所提出的基于滑模控制的 IDE 算法对于机器人的定点运动-摆线运动轨迹的轨迹规划是有效的, 未来将继续关注 IDE 算法在其他生产领域的应用研究.

参考文献

- 1 钱东海, 谭伟, 赵锡芳. 基于 B 样条路径的机器人时间最优轨迹规划. 上海交通大学学报, 1998, 32(12): 29-33.
- 2 杨国军, 崔平远. 机械手时间最优轨迹规划方法研究. 中国机械工程, 2002, (20): 1715-1717. [doi: 10.3321/j.issn:1004-132X.2002.20.002]
- 3 王宪, 杨国梁. 基于改进蚁群算法的机器人轨迹规划. 计算机系统应用, 2010, 19(11): 79-82. [doi: 10.3969/j.issn.1003-3254.2010.11.018]
- 4 甘亚辉, 戴先中. 基于遗传算法的多机器人系统最优轨迹规划. 控制理论与应用, 2010, 27(9): 1245-1252.
- 5 付荣, 居鹤华. 基于粒子群优化的时间最优机械臂轨迹规划算法. 信息与控制, 2011, 40(6): 802-808.
- 6 居鹤华, 付荣. 基于 GA 的时间最优机械臂轨迹规划算法. 控制工程, 2012, 19(3): 472-477. [doi: 10.3969/j.issn.1671-7848.2012.03.026]
- 7 王学琨, 李刚, 周东凯, 等. 基于 DE 的时间最优 6-DOF 机械臂轨迹规划算法. 计算机仿真, 2015, 32(8): 332-337. [doi: 10.3969/j.issn.1006-9348.2015.08.072]
- 8 余阳, 林明, 林永才. 基于混合遗传算法的工业机器人最优轨迹规划. 计算机工程与设计, 2012, 33(4): 1574-1580. [doi: 10.3969/j.issn.1000-7024.2012.04.063]
- 9 赫建立, 朱龙英, 成磊, 等. 基于遗传算法的 6-DOF 机器人最优时间轨迹规划. 机械传动, 2015, 39(9): 41-45.
- 10 刘一扬, 刘明明. 基于改进遗传算法的机器人运动轨迹跟踪控制. 机械传动, 2016, 40(3): 39-42, 61.
- 11 邓飙, 张潇, 龙勇, 等. 基于五次 B 样条的起竖装置时间最优轨迹规划. 组合机床与自动化加工技术, 2016, (6):

- 21–25.
- 12 殷凤健, 梁庆华, 程旭, 等. 基于时间最优的机械臂关节空间轨迹规划算法. 机械设计与研究, 2017, 33(5): 12–15.
- 13 梁延德, 李瑞峰, 张红哲, 等. 基于时间最优的PTP轨迹规划问题. 计算机工程与设计, 2017, 38(1): 231–237.
- 14 Das S, Konar A, Chakraborty UK. Two improved differential evolution schemes for faster global search. Proceedings of the 7th Annual Conference on Genetic and Evolutionary Computation. Washington DC, USA. 2005. 991–998.
- 15 Ioannou P, Sun J, Ioannou P A. Robust adaptive controls. Ioannou P, Sun J. Robust adaptive control. Prentice Hall PTR, 2013. 333–335.
- 16 Weber M, Tirronen V, Neri F. Scale factor inheritance mechanism in distributed differential evolution. Soft Computing, 2010, 14(11): 1187–1207. [doi: [10.1007/s00500-009-0510-5](https://doi.org/10.1007/s00500-009-0510-5)]
- 17 Saadi HA, Chouinard JY, Guessoum A. Distributed differential evolution algorithm for PAPR reduction of OFDM signals. Proceedings of the 11th International Conference on Information Science, Signal Processing and Their Applications. Montreal, QC, Canada. 2012. 567–572.

WWW.C-S-A.ORG.CN

WWW.C-S-A.ORG.CN