

基于粒子群优化的 约束广义预测控制实现方法

金建平

(常州机电职业技术学院, 江苏 常州 213164)

摘要: 用微粒群优化算法解决存在约束的广义预测控制的优化问题, 并给出了基于微粒群优化算法的广义预测控制算法的实现方法。将该算法应用到工业过程对象中进行测试, 仿真结果表明了算法的有效性和高效性, 获得了良好的控制效果。

关键词: 广义预测控制; 遗传算法; 优化; 约束

中图分类号: TP273+.1

文献标识码: B

文章编号: 1674-7720(2010)18-0080-03

Application of constrained generalized predictive controller based on particle swarm optimization algorithm

JIN Jian Ping

(Changzhou Institute of Mechatronic Technology, Changzhou 213164, China)

Abstract: Investigation is made in this paper of using particle swarm optimization algorithm to optimize the performance index of generalized predictive control. An algorithm for generalized predictive control using particle swarm optimization algorithm is given. The ability of the algorithm is tested with industrial process control and the results of the simulation show the validity and better optimization performance, and the algorithm gets good performance.

Key words: generalized predictive control; genetic algorithm; optimization; constraint

广义预测控制已经在工业过程中得到广泛应用。在广义预测控制中, 如果被控过程是线性无约束的, 并且目标函数是二次型的形式, 则可求得一个解析的线性控制器, 但是实际工业过程中存在着各种约束, 这会使得求解控制量的滚动优化问题变得复杂, 通常需求解一个有约束的二次规划或非凸规划, 而传统的通过迭代求解二次规划和非凸规划方法计算量非常大, 另外非凸规划的求解对初始条件也非常敏感, 这些会影响到广义预测控制的性能。为了解决此问题, 本文将粒子群优化算法应用到广义预测控制中, 解决广义预测控制的局限性。

1 广义预测控制算法

广义预测控制算法是一种先进的控制算法, 它广泛应用在电力、炼油、化工和造纸等工业领域, 是一种源于实际工业过程的高级控制算法, 是预测控制中最具代表性的算法之一^[1-4], 随着对广义预测控制研究的不断深入, 其理论和算法也逐步得到了完善。在广义预测控制算法中, 用受控自回归积分滑动平均(CARMA)模型描述

一个具有非平稳噪声的实际过程可表示为:

$$A(z^{-1})y(t) = B(z^{-1})u(t-1) + \frac{C(z^{-1})\zeta(t)}{\Delta} \quad (1)$$

其中, $u(t)$ 和 $y(t)$ 为过程输入和输出, $\zeta(t)$ 为一个不相关的白噪声序列, $\Delta = 1 - z^{-1}$ 为差分算子, $A(z^{-1})$ 、 $B(z^{-1})$ 、 $C(z^{-1})$ 为后移算子 z^{-1} 的多项式。即:

$$A(z^{-1}) = a_0 + a_1 z^{-1} + \dots + a_n z^{-n} \quad (2)$$

$$B(z^{-1}) = b_0 + b_1 z^{-1} + \dots + b_n z^{-n} \quad (3)$$

$$C(z^{-1}) = c_0 + c_1 z^{-1} + \dots + c_n z^{-n} \quad (4)$$

对于单输入单输出(SISO)系统, 假设 $C(z^{-1}) = 1$, 则从 t 时刻起, 第 j 步后的预测输出值可表示为:

$$\hat{y}(t+j) = E_j(z^{-1})B(z^{-1})\Delta y(t+j) + F_j(z^{-1})y(t) \quad (5)$$

式(5)中, E_j 和 F_j 可以通过求解丢番图方程得到, 即

$$1 = E_j(z^{-1})A\Delta + z^{-1}F_j(z^{-1}) \quad (6)$$

式(6)中, $E_j(z^{-1})$ 和 $F_j(z^{-1})$ 是由 $A(z^{-1})$ 和预测长度 j 唯一确定的多项式, 即

技术与方法 Technique and Method

$$E_j(z^{-1})=e_{j,0}+e_{j,1}z^{-1}+\dots+e_{j,j-1}z^{-(j-1)} \quad (7)$$

$$F_j(z^{-1})=f_{j,0}+f_{j,1}z^{-1}+f_{j,n}z^{-n} \quad (8)$$

令多项式 $G_j(z^{-1})=E_j(z^{-1})B(z^{-1})$, 整理后可得:

$$G_j(z^{-1})=\frac{(1-z^{-j}F_j)B(z^{-1})}{A(z^{-1})\Delta} \quad (9)$$

$G_j(z^{-1})$ 中前 j 项的系数正是对象阶跃响应前 j 项的采样值, 记为 g_1, g_2, \dots, g_j , 将 $G_j(z^{-1})$ 展开为:

$$G_j(z^{-1})=g_{j,0}+g_{j,1}z^{-1}+\dots+g_{j,j-1}z^{-(j-1)}+\dots \quad (10)$$

则有 $g_{j,i}=g_{i+1}(i < j)$ 。因此, 广义预测控制预测模型可以写成:

$$\hat{y}(t+j)=G_j(z^{-1})\Delta u(t+j-1)+F_j(z^{-1})y(t) \quad (11)$$

即

$$\hat{Y}=GU+F \quad (12)$$

式(12)中:

$$\hat{Y}=[\hat{y}(t+1|t), \dots, \hat{y}(t+N|t)]^T \quad (13)$$

$$U=[\Delta u(t), \dots, \Delta u(t+N_u-1)]^T \quad (14)$$

$$F=[f_1(t), f_2(t), \dots, f_N(t)]^T \quad (15)$$

$$G=\begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & & \\ \vdots & & \ddots & \\ \vdots & & & g_1 \\ \vdots & \vdots & & \\ g_N & \dots & g_{N-N_u+1} & \dots \end{bmatrix}_{N \times N_u} \quad (16)$$

通过长时间段预测, 广义预测控制用多步预测优化代替一步预测优化, 并且优化时域随着时间的推移而推移, 具有多步预测并实施滚动优化的机制, 使得系统存在时滞估计误差或时滞变化时具有较好的鲁棒性。在 t 时刻的优化性能指标表示为:

$$\min J(t)=E\left\{\left[\hat{y}(t+j)-w(t+j)\right]^2+\sum_{j=1}^{N_u} \lambda\left[\Delta u(t+j-1)\right]^2\right\} \quad (17)$$

式(17)中: N 为预测时域, N_u 为控制时域, 将上式极小化后得到其最优解:

$$U=(G^T G+\lambda I)^{-1} G^T(W-F) \quad (18)$$

最优控制量为:

$$u(t)=u(t-1)+g^T(W-F) \quad (19)$$

式(19)中, $W=[w(t+1), \dots, w(t+N)]^T$; g^T 为矩阵 $(G^T G+\lambda I)^{-1} G^T$ 的第 1 行。

式(19)中, 如果控制量存在约束情况, 则需求解带有约束的二次规划, 约束非线性的存在会导致优化成为一个非凸规划, 非凸规划的求解对初始条件非常敏感, 会在局部最优解处收敛, 无法保证求得的是全局最优解, 本文尝试用微粒群优化(PSO)算法来解决这一局限性。

2 PSO 算法及其改进

2.1 基本 PSO 算法原理

由 Kennedy 和 Eberhart 提出的 PSO 算法^[5-7]来源于对简单社会的模拟, 最初设想是模拟对鸟群觅食的过程,

后来发现 PSO 算法是一种很好的优化工具。PSO 算法与其他进化算法相类似, 也是将寻优的参数组合成群体, 通过对环境的适应度来将群体中的个体向更好的区域移动。与其他进化算法不同, 在描述个体时, 将其看成是 D 维寻优搜索空间的一个没有体积的微粒(点)^[8-10], 结合微粒的历史最佳位置和群体历史中最优微粒的最佳位置信息, 按追随最优微粒的原理, 以一定的速度向目标值逼近。

设第 i 个微粒的位置为 $X_i=(x_{i1}, x_{i2}, \dots, x_{id})$, 其速度为 $V_i=(v_{i1}, v_{i2}, \dots, v_{id})$ 。该微粒所经历的历史最好位置记为 $P_i=(p_{i1}, p_{i2}, \dots, p_{id})$, 也称为 P_{best} , 记全体所有微粒经过的最好位置为 $P_g=(g_{i1}, g_{i2}, \dots, g_{id})$, 也称为 $P_{g_{best}}$ 。按追随当前最优微粒的原理, 对第 t 代的第 i 个微粒, PSO 算法根据方程(20)和方程(21)计算第 $t+1$ 代的第 j 维的速度和位置^[10-11]。

$$v_{ij}^{t+1}=wv_{ij}^t+c_1r_1^t(p_{ij}^t-x_{ij}^t)+c_2r_2^t(g_{ij}^t-x_{ij}^t) \quad (20)$$

$$x_{ij}^{t+1}=x_{ij}^t+v_{ij}^{t+1} \quad (21)$$

式中, w 为惯性权重, 它使微粒保持运动惯性, 使其具有扩展搜索空间的趋势, 有助于新区域的搜索; r_1^t, r_2^t 为 $[0, 1]$ 的随机数; c_1 和 c_2 为加速度常数, 表示将每个微粒推向 P_{best} 和 $P_{g_{best}}$ 的统计加速度权重, 两者均为正值。

此外, 微粒的速度 v_i 被一个最大速度所限制。如果当前对微粒的加速导致它在某维的速度 v_{ij} 超过该维的最大速度 $v_{max,j}$, 则该维的速度被限制为最大速度 $v_{max,j}$, 使得粒子不至于因为飞行速度过高而跳过可能的优化解。

2.2 PSO 算法的改进

通过对式(20)和式(21)分析发现, 如果粒子群的历史最优粒子位置 $P_{g_{best}}$ 在较长时间内没有发生变化, 在粒子群体快接近 $P_{g_{best}}$ 时, 其速度更新将主要由历史速度决定, 于是速度将越来越低, 粒子群呈现出强烈的“趋同性”, 表现在式中的第二项和第三项接近于 0。这种“趋同性”加快了算法的搜索速度, 但是却减弱了群体开拓新的搜索空间的能力。如果该最优位置为一局部最优, 则算法很容易陷入局部最优, 发生早熟现象。通过粒子群优化算法的搜索机理分析发现, 无论是早熟收敛还是全局收敛, 微粒群中的粒子都会出现“聚集”现象。针对这个问题, 本文对 PSO 算法作了以下改进: 在微粒群从第 t 代向第 $t+1$ 代“飞翔”时, 粒子除追随个体极值 P_{best} 和全局极值 $P_{g_{best}}$ 外, 还追随从微粒群中随机选取的某个粒子的个体极值 P_n , 据此改进思想, 式(20)也可表示为:

$$v_{ij}^{t+1}=wv_{ij}^t+c_1r_1^t(p_{ij}^t-x_{ij}^t)+c_2r_2^t(g_{ij}^t-x_{ij}^t)+c_3r_3^t(q_{ij}^t-x_{ij}^t) \quad (22)$$

式(22)中, c_1 为非负常数, 一般取 0.5; r_3^t 为 $[0, 1]$ 的随机数, 根据仿真实验, r_3^t 的取值范围在 0~0.5 之间时能获得较好的效果; q_{ij} 是随机选取粒子的位置。在粒子的飞翔迭代公式中增加 P_n 后, 由 P_{best} 、 $P_{g_{best}}$ 和 P_n 三者共同向下

技术与方法 Technique and Method

一代提供信息,使粒子获得的信息量增大,从而可能更快地找到最优解。同时 P_n 的权重系数很小,相当于扰动信息,增加了粒子的多样性,避免算法过早收敛。式(21)和式(22)组成后称之为改进的 PSO 算法(MPSO)。

2.3 算法设计

引入了约束的广义预测控制问题,实际上就是一个非线性优化问题,利用 PSO 算法对其进行处理的基本思想是:首先通过选择合适的适应度函数,将有约束广义预测控制性能指标优化的极小值问题转化为 PSO 算法优化的极大值问题;然后通过空间限定法引入约束,经迭代计算后最终得到满足约束的最优控制量求解。

基于 MPSO 算法的广义预测控制结构如图 1 所示,预测模型采用式(12)的形式,MPSO 算法通过优化性能指标 $J(t)$ 输出控制量进行控制。

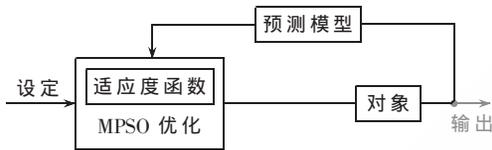


图 1 基于 MPSO 算法的控制结构

对优化性能指标进行变换得到适应度函数为:

$$f = \frac{1}{1+J(t)} \quad (23)$$

式中, $J(t)$ 可以是式(18)的形式,也可以是满足控制性能要求的其他形式,通过这种变换将 GPC 优化的极小值问题转化为 MPSO 算法优化的极大值问题,并使 MPSO 算法的适应度函数值都在区间 $[0, 1]$ 中变化。

3 仿真实例

热交换器是工业生产所需要的一种换热装置,结构如图 2 所示,图中, T_1 、 T_2 、 T_3 、 T_4 、 T_5 均为温度控制器, F_1 、 F_2 、 F_3 均为测量流量的控制器, P_1 为测量压力的控制器。系统中包括 2 个输入管,即 1 个热水管和 1 个冷水管,对应控制其流量的阀门为 V_1 、 V_2 。另外还有 1 个 15 kW 的隔热式加热水箱。水箱中的温度通过冷水管中的流量

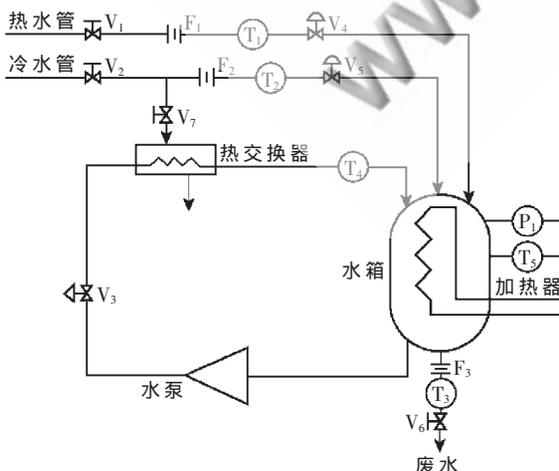


图 2 热交换器结构示意图

来控制,而水箱中的水又经过 1 个离心泵,通过阀门 V_3 来控制,输送回热交换器中。这其中包括很多闭环控制系统,被测量有温度、流量、压力等,本文选择的闭环系统为热交换器中循环水的温度控制,对温度控制回路的扰动主要有蒸汽压力、水流速度和进水温度。本文选取的闭环控制为图 2 中的 T_4 - V_3 环节。

选取系统控制量 $u(t)$ 为阀门 V_3 的位置,系统的输出 $y(t)$ 为从热交换器到水箱的温度 T_1 ,通过模型辨识,可以得到该系统的一阶时滞的传递函数模型,表达式为:

$$G(s) = \frac{0.119}{1+18s} e^{-20s} \quad (24)$$

设采样时间 $T=4s$,将上式离散化后得:

$$G(z^{-1}) = \frac{0.119(1-a)z^{-1}}{1-az^{-1}} z^{-d} \quad (25)$$

式(25)中, $a=e^{-\frac{20}{T}}$, $d=5$ 。仿真过程中选取预测步长为 10,控制步长为 2。从仿真结果可以看出,用 PSO 算法可以得到良好的控制效果。

本文尝试用微利群优化算法来解决该非线性优化问题,从仿真结果来看,该算法具有良好的鲁棒性和跟踪性能,取得了满意的控制效果,表明将粒子群优化算法应用到广义预测控制中是可行和有效的。

参考文献

- [1] MENDES J, KENNEDY J, NEVES J. Watch the neighbor or how the swarm can learn from its environment[C]. Proc. Of the IEEE Swarm Intelligence Symposium. Indiana: IEEE Press, 2003: 88-94.
- [2] CLARKE D W. Generalized predictive control-part I[J]. Automatica, 1987, 23(2): 137-148.
- [3] CLARKE D W. Generalized predictive control-part II extensions and interpretations[J]. Automatica, 1987, 23(2): 149-160.
- [4] 王伟. 广义预测控制理论及其应用[M]. 北京: 科学出版社, 1998.
- [5] KENNEDY J, EBERHART R. Particle swarm optimization[C]. Proc. IEEE Int. Conf. on Neural Networks. Perth: IEEE Press, 1995: 1942-1948.
- [6] SHI Yu Hui, EBERHART R. A modified particle swarm optimizer[C]. Proc. IEEE Int. Conf. on Evolutionary Computation. Anchorage: IEEE Press, 1997: 303-308.
- [7] ZHANG L P, YU H J, HU S X. A new approach to improve particle swarm optimization[C]. Proc. Of the Genetic and Evolutionary Computation Conf. Chicago: IEEE Press, 2003: 134-142.
- [8] MILLONAS M M. Swarms phase transition and collective intelligence[M]. MA: Addison Wesley, 1994.
- [9] SHI Y, EBERHART R C. Fuzzy adaptive particle swarm optimization[C]. Proc. Of the IEEE Congress on Evolutionary

computation.Seoul,Korea:IEEE Press, 2001 : 101-106.

- [10] RATNAWEERA A, HALGAMUGE SK, WATSON C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficient[C]. IEEE Trans. Evolutionary

computation. IEEE Press, 2004 : 240-255.

(收稿日期: 2010-04-18)

作者简介:

金建平,男,1980年生,硕士研究生,主要研究方向:智能优化和电力系统监控等。

