



基于遗传算法的非高斯系统随机分布控制

摘要

传统的控制理论并未考虑工业过程中的一些不确定因素,而这些不确定因素在生产过程中对系统的能源损耗和精度都有很大的影响.为了解决上述问题,本文研究一种基于数据的非高斯随机分布系统优化控制策略,该策略采用核密度估计(KDE)方法完全基于输出数据估计输出概率密度函数(PDF),根据控制目标建立性能指标函数,采用遗传算法优化性能指标函数,实现输出PDF对目标PDF的跟踪.以磨矿系统为模型进行仿真,采用PDF表征粒度分布(PSD).仿真结果表明,基于遗传算法的非高斯随机分布最优控制算法能有效地实现随机分布控制系统的控制目标,为实际工业生产提供参考.

关键词

非高斯系统;核密度估计;概率密度函数;遗传算法

中图分类号 TP13

文献标志码 A

收稿日期 2018-11-21

资助项目 国家自然科学基金(61320106010, 61573190, 61571014)

作者简介

洪越,女,硕士生.hongyuejiangsu@163.com
殷利平(通信作者),女,博士,副教授,研究方向为随机控制、鲁棒控制、故障检测与诊断.lpyin@nuist.edu.cn

0 引言

工业技术的不断发展一方面使得生产率快速提高,社会不断进步,另一方面工业过程中的不确定因素也使得工业控制越来越复杂,传统的控制理论在很多情况下已经不符合现代工业的发展要求.近几十年来,在控制理论界中有很多面向随机系统的随机控制和随机估计方面的研究^[1-2],其研究成果已经广泛地应用于诸多工业领域,如最小方差控制,它属于随机最优控制的一种特殊情形,具有求解和实现简便的优点.对于线性高斯系统,可以采用最小方差控制等方法^[3-4],但是当系统含有非高斯变量时,使用均值和方差不能完全描述系统的特征,这些方法便不适用.有鉴于此,以PDF(概率密度函数)为控制对象的非高斯随机分布系统控制理论逐渐成为随机控制研究领域的一个新分支^[5-6].尽管非高斯随机分布系统控制理论研究意义重大,但是开展非高斯随机分布系统的理论研究是相当复杂的.

在随机分布控制系统中,控制的目标是实现输出的PDF跟踪目标PDF^[7-10],在基于泛函算子模型的随机分布控制系统中,基于数据采用KDE(核密度估计)方法估计PDF具有很多优越性^[4].采用KDE估计输出的PDF,根据控制目标建立性能指标函数,并将控制目标转化为性能指标函数优化的控制方法能够大大简化算法程序,并且即使当建模发生误差,由于该算法基于数据特征,因此也不会很敏感.在以往优化性能指标函数时,往往采用的是梯度算法.梯度算法的计算过程复杂,当需要优化的指标函数复杂或者系统本身就很复杂时,算法过程中的求导和泰勒展开比较困难,且计算量大耗时长.因此,在实际应用中寻找到对模型要求低、计算量小,能找到全局最优解的算法是很关键的.现代智能算法大多来源于生物智能或者物理现象,虽然在理论上还不完善也不能确保找到解的最优性,但是它符合非高斯随机分布系统的优化要求,即对模型要求低、搜索全局化、鲁棒性强且高效.

遗传算法最早由美国的Holland教授提出,它来源于20世纪60年代自然与人工自适应系统研究的一种模拟生物的遗传和进化来解决最优化的搜索启发式算法^[11].遗传算法具有较强的灵活性,能够通过稍加调整以适应实际待解决问题.遗传算法由于其特殊的搜索特性,对优化问题没有太多的数学要求,且具有有效地进行概率意义的全局搜索的能力.作为一种智能算法,在工业生产中遗传算法可以用

¹ 南京信息工程大学 自动化学院, 南京, 210044

来优化性能指标函数,通过种群个体的遗传操作、交叉操作和变异操作不断更新优化种群,最终找到最优解,即最优控制输入。

本文根据随机分布相关控制理论,基于数据采用 KDE 估计输出 PDF,并建立性能指标函数,采用遗传算法对性能指标函数进行优化,找到最优控制。以磨矿系统为例进行仿真实验,以证明所提方法的有效性。

1 系统模型

本文考虑一个工业上的模型——磨矿系统模型,该模型的控制目标是:在每一个时刻,系统输出 PSD(粒度分布)跟踪一个目标 PSD。本文用 PDF 表征 PSD,二者可视为等价。选矿是矿产品生产过程中最重要的环节,而磨矿又是选矿中动力和金属材料消耗最大的一个阶段^[12]。磨矿回路是一个非常复杂的非线性系统,为了提高资源利用率,提高矿料研磨后的磨矿作业指标是一项富有挑战性但是非常有意义的任务。

图 1 所示为磨矿结构回路,考虑较为普遍的湿磨情况,在工作过程中研磨机和蓄液池都需不断加入水。其中水力旋流器的作用是在离心力和重力的作用下使质量大的矿物颗粒与质量小的矿物颗粒分离,质量大的成为底流矿料通过沉沙口再次进入研磨机,质量小的随溢流排出。同时新添矿料通过进料器添加到研磨机内,研磨后的矿物颗粒通过排矿口进入蓄液池,蓄液池的悬浮液由水泵抽入水力旋流器^[13]。

设磨矿系统模型为

$$\begin{cases} x_{k+1} = f(x_k, u_k, \omega_k), \\ y_k = h(x_k, u_k, v_k), \end{cases} \quad (1)$$

其中 k 表示的是系统生产过程的采样时刻, u_k 是控制输入序列,即磨矿机新添矿料量, y_k 是受控输出序列,即磨矿系统输出的随机粒度, x_k 是系统的状态序列,即磨矿系统磨矿浓度, ω_k 和 v_k 是非高斯随机输入序列,即磨矿过程中不确定因素引起的输入。

在采样时刻 k , 将系统 (1) 的输出 PDF 记为

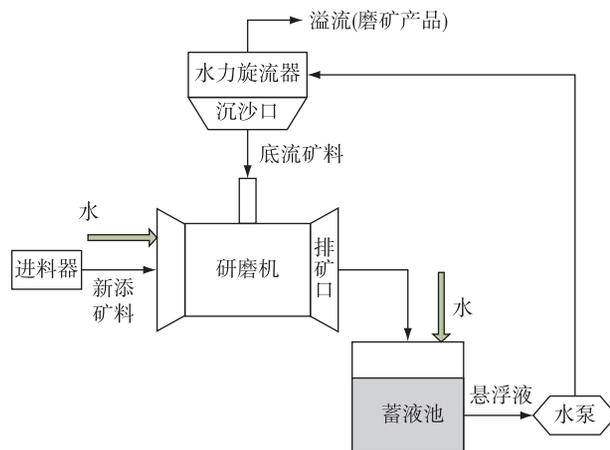


图 1 磨矿结构回路

Fig. 1 Schematic diagram of mineral grinding circuit

γ_{y_k} , 目标 PDF 由矿料性质和后续选择方法决定, 记为 γ_d , 即磨矿产品的 PSD^[14-15] 设定值。在每个采样时刻 k , 将系统输出的 L 个溢流产品粒度 $\{y_{ki}\} (i = 1, 2, \dots, L)$ 作为样本, 采用 KDE 的方法得到系统输出的 PDF, 即 γ_{y_k} , 根据控制目标建立性能指标函数, 使用遗传算法优化性能指标函数得到最优控制 u_k , 使得输出 PDF 跟踪目标 PDF。

磨矿系统的算法结构如图 2 所示。

2 基于 KDE 的粒度 PDF 估算

KDE 是一种非参数估计, 不需要先验知识和任何概率分布形式的假设, 单纯地从数据出发研究样本的分布特征, 适合于求取每一采样时刻 k 流溢产品粒度的 PDF。根据 KDE 原理, $\gamma_{y_k}(\tau)$ 的核密度估计^[16-17] 为

$$\hat{\gamma}(\tau) = \frac{1}{Lh} \sum_{i=1}^L K\left(\frac{\tau - y_{ki}}{h}\right), \quad (2)$$

其中 τ 表示为统计学中肯德尔相关系数的值, L 为样本容量, h 为带宽, 起平滑系数的作用, $K(\cdot)$ 为核函数, 通常选择镜像对称的单峰函数, 此处为高斯核函数:

$$K\left(\frac{\tau - y_{ki}}{h}\right) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\tau - y_{ki})^2}{2h^2}}. \quad (3)$$

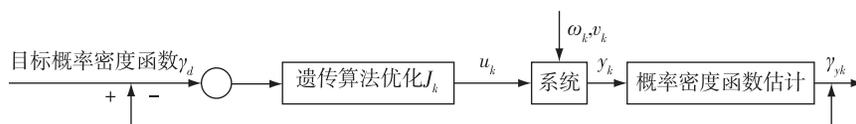


图 2 算法流程

Fig. 2 Flow chart of mineral grinding algorithm

当 $L \rightarrow \infty, h \rightarrow 0$ 时 $\hat{\gamma}_{y_k}(\tau) \rightarrow \gamma_{y_k}(\tau)$. 带宽是 KDE 的关键问题, 此处根据 Silvermann 提出的基于平衡偏差和方差的经验法则 (ROT)^[17] 选择, 即:

$$h = 1.06\sigma L^{-1/5}, \quad (4)$$

其中 σ 为样本的标准差.

3 性能指标建立

本文跟踪的目标是一个给定的 PDF $\gamma_d(\tau)$, 控制目标是设计控制律, 使输出的条件 PDF $\gamma_{y_k}(\tau | x_k, u_k)$ 满足:

$$\gamma_{y_k}(\tau | x_k, u_k) \rightarrow \gamma_d(\tau), k \rightarrow +\infty. \quad (5)$$

基于泛函算子模型的随机分布控制理论, 涉及到的性能指标函数^[18-20]一般可以写成:

$$J_k = Q_k \delta(\gamma_{y_k}, \gamma_d) + \frac{1}{2} R_k u_k^2. \quad (6)$$

式(6)中第1项是统计特性, 表示输出 PDF 与目标 PDF 之间的距离, 可以用积分表示为

$$\delta(\gamma_{y_k}, \gamma_d) = \int_a^b (\hat{\gamma}_{y_k}(\tau) - \gamma_d(\tau))^2 \tau. \quad (7)$$

第2项为 u_k 的能力约束项. 性能指标函数表达式中 Q_k, R_k 为权系数.

4 基于遗传算法的最优控制策略

待优化的性能指标函数(6), 第1项和第2项都与 u_k 有关, 且第1项比较复杂. 由于遗传算法操作简单并具有全局性, 所以可以使用遗传算法进行优化. 此时, 控制目标转化为寻找在每一个时刻 k, u_k^* 使得 J_k 最小, 即:

$$u_k^* = \arg_{u_k} \min J_k(u_k | x_k), \quad k=0, 1, \dots. \quad (8)$$

基本遗传算法由选择算子、交叉算子和变异算子组成, 在遗传算法中优化的目标函数即为适应度函数. 选择算子中使用比例的方法来计算个体遗传下去的概率, 所以要求所有个体的适应度必须不为负. 在遗传算法中, 个体适应度越大被遗传到下一代的概率越大, 个体适应度越小被遗传到下一代的概率越小. 本文中所需优化的性能指标函数 J_k 为优化的目标函数即遗传算法中的适应度函数, J_k 不为负, 但是优化的目标为求最小值, 即所求目标函数为最小, 使用下式方法进行转换^[21-22]:

$$J_k^*(X) = \begin{cases} C_{\max} - J_k(X), & J_k(X) < C_{\max}, \\ 0, & J_k(X) \geq C_{\max}, \end{cases} \quad (9)$$

式中 C_{\max} 是相对较大的数, 选取方法有: 1) 预先选择一个较大的数; 2) 进化到当前代为止最大的目标函

数的值; 3) 最近几代群体中的最大目标函数值.

基于遗传算法的非线性非高斯系统的 PDF 跟踪控制算法的详细步骤可总结如下:

1) 初始化磨矿系统(1)的随机状态变量 x_0 和输入控制 u_0 .

2) 设采样时刻 $k=0$.

3) 用遗传算法优化 k 时刻的性能指标函数, 得到最优控制 u_k^* :

①种群个体记为 $p_k^i(i)$ ($i=1, 2, 3, \dots, I$), 即本文中的控制输入 u_k , 初始化种群个体 $p_k^1(i)$, 用式(6)和式(9)计算 $p_k^1(i)$ 的适应度函数 $J_k^{*1}(i)$, 记适应度最大个体为全局最优记为 u_1^* ;

②令 $t=2$;

③用式(6)和式(9)计算 $p_k^t(i)$ 的适应度函数 $J_k^{*t}(i)$;

④将 $p_k^t(i)$ 进行选择运算, 通过轮盘算法将群体的个体进行配对选择, 作为下一代的父代和母代;

⑤为了进行交叉运算, 将种群个体进行二进制编码操作;

⑥将进行完二进制编码操作后的 $\text{bin}p_k^t(i)$ 进行交叉计算;

⑦将完成交叉计算的 $\text{bin}p_k^t(i)$ 进行变异操作;

⑧将进行完变异操作的 $\text{bin}p_k^t(i)$ 进行解码操作, $t=t+1$, 得到新种群 $p_k^{t+1}(i)$;

⑨若 $t>T$ 进入4) 否则进入③.

4) 计算新种群的适应度函数值, 记使得适应度函数最大的个体为 u_k^* , 将 u_k^* 作用于系统(1), $k=k+1$, 转进入3).

该算法可以用图3表示.

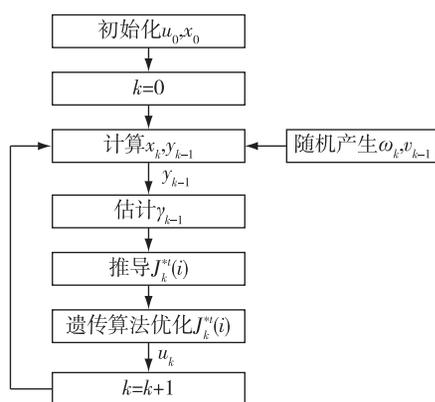


图3 算法流程

Fig. 3 Flow chart of genetic-based algorithm

5 仿真

下面将以模型(10)为例,详细阐述怎样采用遗传算法优化性能指标函数,以实现磨矿粒度 PDF 的跟踪控制:

$$\begin{cases} x_{k+1} = \sin(x_k) + \frac{1}{9}u_k - 0.5\sqrt{\omega_k}, \\ v_k = x_k^3 + u_k + \sqrt{v_k}, \end{cases} \quad (10)$$

其中, ω_k 的 PDF 为

$$\gamma_\omega(x) = \begin{cases} -48(x^2 - x + \frac{3}{16}), & x \in [0.25, 0.75], \\ 0, & x \in (-\infty, 0.25) \cup (0.75, +\infty), \end{cases} \quad (11)$$

v_k 的 PDF 为

$$\gamma_v(x) = \begin{cases} \frac{-6(x - 0.25)}{\sqrt{x}}, & x \in [0, 0.25], \\ 0, & x \in (-\infty, 0) \cup (0.25, +\infty). \end{cases} \quad (12)$$

设磨矿产品的 PSD 指标为高斯分布 $N(1, 0.252)$, 即跟踪目标的 PDF 为

$$\varphi(x) = \frac{1}{0.25\sqrt{2\pi}} \exp\left\{-\frac{(x-1)^2}{2 \times 0.25^2}\right\}. \quad (13)$$

在仿真中设定的初始条件为 $x_0 = -0.1, u_0 = 0.1$, 权系数取为 $Q_k = 15, R_k = 0.1$. 通过多次测试, 在遗传算法中种群的个体个数为 30, 迭代的次数 $T = 10$, 杂交率 = 0.7, 选择率 = 0.5, 变异率 = 0.1. 本仿真中采用式(9)的方法, 取 $C_{\max} = 30$, 即:

$$J_k^*(X) = \begin{cases} 30 - J_k(X), & J_k(X) < 30, \\ 0, & J_k(X) \geq 30. \end{cases} \quad (14)$$

在实际仿真过程中, 首次仿真时由于系统初始状态未稳定和遗传算法的原理特性, $p'_k(i)$ 在 0.1 处陷入局部最优, 使得适应度函数收敛于 13.06. 为了避免遗传算法过早收敛, 采用了将在一定范围内随机产生 5 个新个体代替更新种群前 5 个个体的方法. 调整过的算法在 $k=4$ 之后, 适应度函数收敛于 30, 输出 PDF 对目标 PDF 实现了跟踪. 图 4 是在每一个采样时刻 k , 系统最佳的新添矿料量, 即控制输入 u_k . 图 5 为适应度函数变化曲线, 由图 5 可以看出当 $k=4$ 之后, 适应度函数趋近于 30 (即性能指标函数趋近 0), 只在小范围内波动. 图 6 是 $k=0, 1, 20$ 的输出 PDF 和目标 PDF 曲线, 由图 6 可以看出 $k=0, 1$ 时的 PDF 与目标 PDF 差别很大, 但 $k=20$ 时的 PDF 与目标 PDF 很接近. 图 7 给出了输出 PDF 随时间变化的三维图以展示系统的跟踪过程. 图 8 为系统输出

PDF 与目标 PDF 的差随时间变化的三维图, 由图 8 可以看出在 $k=4$ 之后差异非常小, 说明输出 PDF 对目标 PDF 实现了跟踪, 本文采用的基于数据和遗传算法的控制算法是有效的.

与遗传算法相似, 粒子群算法也是属于进化优化算法的一种, 它源于对鸟群捕食行为的研究. 对于粒子群算法系统初始化仍为一组随机解, 以适应度函数为评价标准, 在算法中将每个优化问题的解看作是一个粒子, 通过粒子速度的改变找到粒子最优位置即系统最优解. 在粒子群优化算法中粒子位置的更新与速度的更新都具有良好的导向性, 因此粒子群对空间中的最优解有很强的逼近能力, 且收敛速度快, 但是这种导向性很容易导致该算法出现陷入局部最优解的情况, 全局搜索能力弱. 于是在复杂的工业问题中, 遗传算法相比于粒子群算法更具实际应用的适应能力.

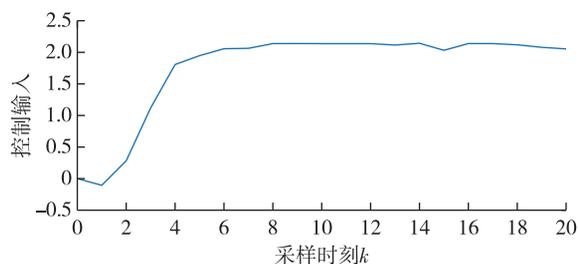


图 4 控制输入序列

Fig. 4 Control input sequence

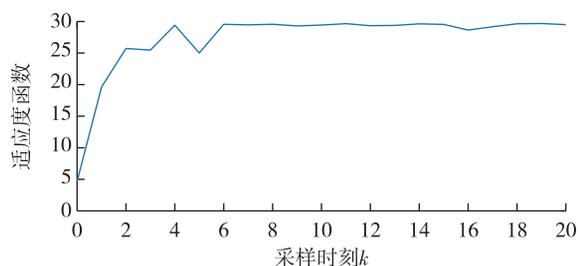


图 5 适应度函数

Fig. 5 Fitness function

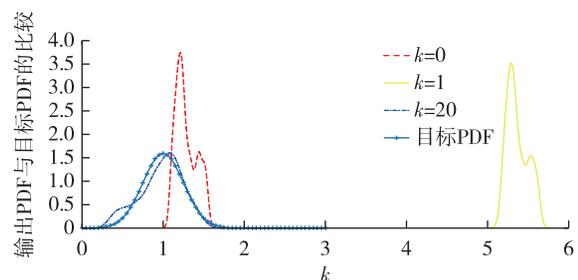


图 6 输出 PDF 和目标 PDF 的比较

Fig. 6 Comparison between output PDF and target PDF

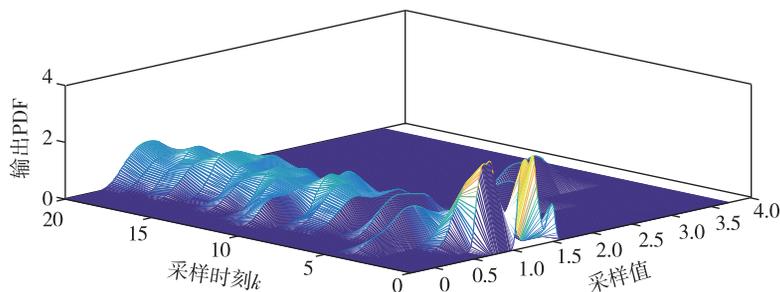


图7 输出 PDF(三维图)

Fig. 7 The 3D output PDF

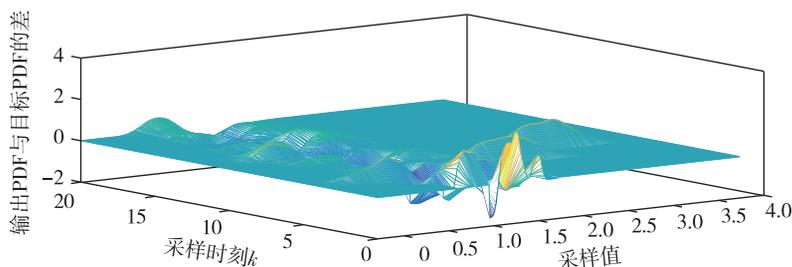


图8 输出 PDF 与目标 PDF 的差(三维图)

Fig. 8 Difference between output PDF and target PDF

6 结论

本文以磨矿系统为例,将适当调整后的遗传算法应用于 PDF 的控制算法中,通过调整每一采样时刻的磨矿机新添矿料量,控制系统的输出.首先在每一采样时刻 k ,用 KDE 估计磨矿产品粒度的 PDF,然后根据控制目标基于输出 PDF 和目标 PDF 的误差建立性能指标函数,最后用调整后的遗传算法优化性能指标函数,实现最优控制.仿真结果表明,在实际应用中,遗传算法进行小的调整后就能够适应模型的要求,实现随机分布控制系统的控制目标.

参考文献

References

- [1] Murray R M, Astrom K J, Boyd S P, et al. Future directions in control in an information-rich world [J]. IEEE Control Systems, 2003, 23(2): 20-33
- [2] 殷利平,周丽,张敏.多维非高斯系统最小熵控制[J].南京信息工程大学学报(自然科学版), 2012, 4(6): 545-549
YIN Liping, ZHOU Li, ZHANG Min. Minimum entropy control for multivariate non-Gaussian system [J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2012, 4 (6): 545-549
- [3] Freudenberg J S, Middleton R H, Braslavsky J H. Minimum variance control over a Gaussian communication channel [J]. IEEE Transactions on Automatic Control, 2011, 56(8): 1751-1765
- [4] Yin L P, Zhang H Y, Guo L. Data driven output joint probability density function control for multivariate nonlinear non-Gaussian systems [J]. IET Control Theory & Applications, 2015, 9(18): 2697-2703
- [5] Guo L, Wang H. Stochastic distribution control system design [M]. London: Springer London, 2010. DOI: 10.1007/978-1-84996-030-4
- [6] Yin L P, Guo L. Joint stochastic distribution tracking control for multivariate descriptor systems with non-Gaussian variables [J]. International Journal of Systems Science, 2012, 43(1): 192-200
- [7] Wang H, Borairi M, Roberts J C, et al. Modelling of a paper making process via genetic neural networks and first principle approaches [J]. Proc of the IEEE International Conference on Intelligent Processing Systems, 1997, 1: 584-588
- [8] Yao L N, Li L F, Lei C H. Active fault tolerant control for nonlinear non-Gaussian singular stochastic distribution systems [C] // Industrial Electronics and Applications. IEEE, 2016: 450-455
- [9] Guo L, Yin L P, Wang H. Robust PDF control with guaranteed stability for non-linear stochastic systems under modelling errors [J]. IET Control Theory & Applications, 2009, 3(5): 575-582
- [10] Borairi M, Wang H, Roberts J C. Dynamic modelling of a paper making process based on bilinear system modelling and genetic neural networks [C] // UKACC International Conference on Control, 1998: 1277-1282
- [11] 马永杰,云文霞.遗传算法研究进展[J].计算机应用

- 研究,2012,29(4):1201-1206,1210
 MA Yongjie, YUN Wenxia. Research progress of genetic algorithm[J]. Application Research of Computers, 2012, 29(4):1201-1206, 1210
- [12] 周平,丁进良,赵大勇,等.实现粒度指标的磨矿过程智能优化控制系统[J].控制工程,2006,13(4):334-337
 ZHOU Ping, DING Jinliang, ZHAO Dayong, et al. Intelligent optimizing control system of grinding process for particle size index[J]. Control Engineering of China, 2006, 13(4):334-337
- [13] Sun X B, Ding J L, Chai T Y, et al. Neural networks based probability density function control for stochastic systems [M]//Sun X B, Ding J L, Chai T Y, et al. eds. Recent Advances in Intelligent Control Systems. London: Springer London, 2009: 125-148. DOI: 10.1007/978-1-84882-548-2_6
- [14] 郭宏亮.自动化浮选系统中泡沫分离岭的研究[J].计算机仿真,2013,30(2):422-425
 GUO Hongliang. Research on foam separation ridge in automation flotation system[J]. Computer Simulation, 2013, 30(2):422-425
- [15] 李胜荣.结晶学与矿物学[M].北京:地质出版社,2008
 LI Shengrong. Crystallography and mineralogy [M]. Beijing: Geological Publishing House, 2008
- [16] Yin L P, Zhang H Y, Li Z, et al. KDE based output PDF control for nonlinear non-Gaussian systems using PSO algorithm [C] // IEEE Control Conference, 2014: 5351-5356
- [17] Parzen E. On estimation of a probability density function and mode [J]. The Annals of Mathematical Statistics, 1962, 33(3):1065-1076
- [18] Guo L, Wang H. Minimum entropy filtering for multivariate stochastic systems with non-Gaussian noises [J]. IEEE Transactions on Automatic Control, 2006, 51(4):695-700
- [19] Yin L P, Guo L. Fault isolation for multivariate nonlinear non-Gaussian systems using generalized entropy optimization principle [J]. Automatica, 2009, 45(11):2612-2619
- [20] Guo L, Yin L P, Wang H, et al. Entropy optimization filtering for fault isolation of nonlinear non-Gaussian stochastic systems [J]. IEEE Transactions on Automatic Control, 2009, 54(4):804-810
- [21] 王银年.遗传算法的研究与应用:基于3PM交叉算子的退火遗传算法及应用研究[D].无锡:江南大学,2009
 WANG Yinnian. Research and application of genetic algorithm; annealing genetic algorithm based on 3PM intersection operator and its application research [D]. Wuxi: Jiangnan University, 2009
- [22] 吴启迪.自然计算导论[M].上海:上海科学技术出版社,2010
 WU Qidi. Introduction to natural calculation [M]. Shanghai: Shanghai Science and Technology Press, 2010

Genetic algorithm-based stochastic distribution control for non-Gaussian systems

HONG Yue¹ YIN Liping¹

¹ School of Information and Control, Nanjing University of Information Science and Technology, Nanjing 210044

Abstract Traditional control theory does not consider some uncertain factors in the industrial process, which has a significant impact on energy loss and system accuracy in production process. This paper considers the data-based optimization control strategies for non-Gaussian stochastic systems. Kernel density estimation was used to estimate the output probability density functions (PDFs) on the basis of collected output data. Firstly, the performance index function was established based on the control objectives. Secondly, the performance index function was optimized by a genetic algorithm. The simulation takes the grinding system as a model and uses PDFs to characterize the particle size distribution. Simulation results show that the genetic algorithm-based stochastic distribution control for non-Gaussian systems can effectively achieve the control target of the stochastically distributed control system and provides reference for practical industrial production.

Key words non-Gaussian system; kernel density estimation (KDE); probability density function; genetic algorithm