

DOI: 10.7652/xjtuxb201303005

动态可调主元分析的多元自相关质量控制方法

刁广州, 赵丽萍, 要义勇

(西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 为解决在复杂产品制造过程中由多元质量数据自相关引起的大量虚发报警问题, 以提高产品制造过程中监测的准确性, 提出了一种动态可调的主元分析(DRPCA)方法。通过对主元分析方法引入折息因子, 构建了多个参数可调的动态主元分析(PCA)算法。利用实验数据计算各变量的特征值和贡献率, 来确定主元个数, 降低多元自相关过程的计算复杂度, 消除数据间的自相关。根据计算的各变量的每个主元负荷值来确定主导变量, 结合多变量控制图和主导变量控制图, 对多元自相关制造过程进行了实时监测。研究表明: DRPCA 方法不仅能够消除数据间的自相关, 减少制造过程中的虚发报警, 而且可以准确地检测出制造过程中的异常变量。

关键词: 主元分析方法; 多元自相关; 折息因子; 主导变量

中图分类号: TH166 **文献标志码:** A **文章编号:** 0253-987X(2013)03-0024-06

The Dynamic Regulated Principal Component Analysis for Multivariate Autocorrelation Process Quality Control Method

DIAO Guangzhou, ZHAO Liping, YAO Yiyong

(State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: To solve the fault alarm problems from multivariate quality data autocorrelation in the product manufacturing process, the dynamic regulated principal component analysis (DRPCA) method is proposed. The dynamic PCA algorithm of multiple adjustable parameters is constructed by introducing the discount factors. The principal component number is determined by calculating the cumulative contribution and the characteristic value of variables via experimental data. The autocorrelation among data is eliminated to decrease the computational complexity in autocorrelation process. The main variables are found according to the load values by the variables with the principal component. The multiple variable chart and single value control chart are adopted to real-time monitor of the manufacturing process, which enables to eliminate the autocorrelation among data and reduce the false alarms, and to find out the abnormal variables in manufacturing process accurately.

Keywords: dynamic regulated principal component analysis; multivariate autocorrelation; discount factor; dominant variables

随着经济的发展, 现代制造环境呈现出与以往不同的变化特点, 特别是在机械、化工、制药等连续型生产过程中已经实现了整个过程的自动化控制。

由于产品在整个制造过程中受到不同因素的影响, 使得每个质量数据的测量值与上一时刻的测量值相关^[1-2], 因此这种现象被称为制造过程的质量数据自

收稿日期: 2012-06-12。 作者简介: 刁广州(1986—), 男, 博士生; 赵丽萍(通信作者), 女, 教授, 博士生导师。 基金项目: 国家自然科学基金资助项目(51275399)。

网络出版时间: 2012-12-23

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20121223.1637.001.html>

相关。特别是近年来测量技术和采集技术的不断发展,高频数据采集越来越普遍,导致制造过程数据的自相关越发明显。当采集的过程数据存在自相关时,由于以观测值服从独立同分布为假设的传统控制方法忽略了数据间的自相关作用,因此过程质量不能得到有效控制,甚至还会给质量控制工作带来误导^[3],从而影响了正常生产的进行。

目前,国内外已出现了一些多元自相关过程的质量控制方法,例如杨穆尔等人分析了多元自相关过程的残差 T^2 控制图^[4],并基于残差思想提出了向量自回归(VAR)控制图。田海晶等人以神经网络^[5]为基础,建立了自相关质量预测模型,将计算的残差值采用 Hotelling T^2 控制图进行监控,并结合 MYT(Mason Young-Tracy)分解法进行了故障诊断。Chen 等人提出了多元 Cuscore 质量控制图^[6],以监测多元自相关过程的均值变量。

本文通过引入折息因子,构建了一种动态可调的主元分析(DRPCA)方法。该方法能够降低质量数据间的计算复杂度,消除数据间的自相关。根据各变量主元的负荷值来确定异常的主导变量,结合多变量控制图和主导变量单值控制图,对制造过程实时监控,从而提高了多元自相关过程质量控制图的准确性,为现代制造过程提供了一种有效、准确、多变量自相关的质量监控方法。

1 动态可调主元分析方法

1.1 多元自相关制造过程分析

设某个产品的制造过程有 d 个变量,用数据集可表示为 $X = [X_1, X_2, \dots, X_d]$ 。由于相邻变量之间存在着影响关系,所以引入关系集合

$$R = [R_1, R_2, \dots, R_d]$$

$$R_i = \begin{cases} X_1 \\ (X_i, X_{i-1}), & i = 2, 3, \dots, d \end{cases} \quad (1)$$

式中: R_i 表示 X_i 与 X_{i-1} 之间的关系集合。

由于制造过程中自相关的存在,所以采集的数据之间存在序列相关的关系,对于 X_i ,其 j 时刻的数据 X_{ij} 受到 $(j-1)$ 时刻数据 $X_{i(j-1)}$ 的影响,因此

$$X_{ij} - \mu_i = \varphi_i(X_{i(j-1)} - \mu_i) + \varepsilon \\ i = 1, 2, \dots, d; j = 2, 3, \dots, N \quad (2)$$

式中: N 为 X_i 的样本数; φ_i 为 X_i 的自相关系数; μ_i 为 X_i 的均值; ε 为白噪声干扰值, $\varepsilon \in (0, N)$ 。

由以上分析可知, X_i 在 j 时刻的数值不仅在时间序列上受到 $X_{i(j-1)}$ 的影响,而且受到 X_{i-1} 的影响,因此由式(1)、式(2)可得


$$X_{ij} = \begin{cases} f(X_{i(j-1)}), & i = 1; j = 2, 3, \dots, N \\ f(X_{i-1})f(X_{i(j-1)}), & i = 2, 3, \dots, d \end{cases} \quad (3)$$

由于产品的制造过程往往是批量的重复性生产,因此采集的数据也需按批次统计,这样可能会造成采集的数据成为 3 维数据集,使得数据间的非线性特性越来越明显,数据间的自相关计算也越来越复杂。

1.2 动态可调主元分析方法

采用主元分析(PCA)^[7-8]法对数据矩阵进行分析,将矩阵的信息重新组合,从中提取较少的综合变量,且能够最多地概括原数据矩阵的信息。本文提出的 DRPCA 方法可将解决观测数据的非线性特性与采用 PCA 解决系统动态性能的优点相结合,通过引入折息因子,构建出多个可调参数的动态 PCA 算法,并利用多向核函数方法对数据空间模型进行求解。

DRPCA 方法是利用 PCA 将三维数据集划分为批量和变量数据块 $X(I, J_K)$,其中 J_K 为 J 个变量的 K 个采样点,划分后形成一个新的二维数据集,采用滑动窗口技术^[9-10]将二维数据集再划分为一系列子数据空间(见图 1)。



(a)数据集 (b)数据降维 (c)数据转换
I:批量数;J:变量数;K:采样点数;b:窗口步长;u:窗口长度

图1 制造过程数据分析

划分后的子数据空间为

$$X = \{X_u(I, J), X_{u+b}(I, J), \dots, X_{u+(n-1)b}(I, J)\} \quad (4)$$

式中: $X_u(I, J)$ 表示第 I 批次、 J 变量的采样点在第 1 个窗口上的数据集; $X_{u+b}(I, J)$ 为按照 b 移动后得到的第 2 个窗口上的数据集; n 为窗口个数; $X_{u+(n-1)b}(I, J)$ 表示在第 n 个窗口上的数据集。从图 1b 中可以看出,新的数据长度存在差异,为了弥补这一缺点,引入折息因子,设 u, b 按照步长将数据重新分组后加入滑动窗口(如图 1c)。采用加权系数对不同时刻的数据加入不同置信度,以增强算法的时变跟踪能力。折息因子为

$$\left. \begin{aligned} T_k &= v(t)T_{k-1}, & 1 < k \leq L \\ T_L &= w(L) \end{aligned} \right\} \quad (5)$$

式中: L 为滑动窗口的移动步数; $v(t)$ 为 t 时刻的时变因子, $0 < v(t) \leq 1$; $w(L)$ 为加权系数; T_k 为第 k 步的折息因子; T_L 为滑动窗口最后一步移动的折息因子, 与 $w(L)$ 相等。由式(5)可得出的第 k 步的动态折息因子与加权系数、时变因子的数学关系为

$$T_k = \left[\prod_{t=k+1}^L v(t) \right] w(L) \quad (6)$$

从式(6)中可以看出, 不同 k 的折息因子 T_k 随 k 的变化而变化, 具有形式多变、可调性强等优点, 因此具有更大的灵活性和适应性。

引入折息因子后, 改进的 PCA 算法的子数据空间模型为

$$\begin{aligned} X_u(I', J) &= X_u(I, J) T_k \\ Y_u(J, I') &= X_u(I', J) \mathbf{P} \end{aligned} \quad (7)$$

$$\mathbf{P} = \begin{bmatrix} a_{11} & 0 & 0 & \cdots & 0 \\ a_{21} & a_{22} & 0 & \cdots & 0 \\ \vdots & \vdots & & a_{ii} & 0 \\ a_{j1} & a_{j2} & \cdots & a_{ji} & a_{j'j'} \end{bmatrix} \quad (8)$$

式中: Y_u 为采集数据转换后的集合; $\mathbf{P}$ 为引入折息因子后的子数据空间转换矩阵; $X_u(I', J)$ 为 $X_u(I, J)$ 引入折息因子得到的数据集合; I' 为子数据空间样本个数。对数据进行标准化处理, 即对数据进行均值归一化, 利用式(8)的转换矩阵将原输入空间映射到一个高维的特征空间 $t_N (t_N \in \mathbf{R}^s)$ 进行主元分析, 其中 N 为采样样本数, s 为测量变量的维数, 满足 $F(\phi: \mathbf{R}^s \rightarrow F)$ 。由原空间中的向量 $\mathbf{x} \in X_u(I', J)$, 以及在特征空间中的映射向量 $\mathbf{x}' = (x'_1, \dots, x'_p)$ 表示在映射函数 $\phi(\mathbf{x})$ 上的投影, 并满足

$$\begin{aligned} \mathbf{x}' &= v_r \phi(\mathbf{x}) = \sum_{e=1}^m a_e^r \phi(x_e) \phi(\mathbf{x}) = \\ &\sum_{e=1}^m a_e^r K(x_e, \mathbf{x}), \quad r = 1, \dots, p \end{aligned} \quad (9)$$

式中: v_r 为主元变量; a_e^r 为第 r 个特征值对应的第 e 个元素; p 为特征值个数; $K(x_e, \mathbf{x})$ 为在特征空间引入点积的核函数, $K(x_e, \mathbf{x}) = \langle \phi(x_e), \phi(\mathbf{x}) \rangle$, 用于避免直接计算引起的非线性映射。

采用累计方差分数法对主元个数进行计算, 累计方差分数法是通过计算前 h 个变量的累积方差来确定主元个数, 累积贡献率为

$$C_p = \left(\sum_{i=1}^h x'_i / \sum_{i=1}^p x'_i \right); \quad 1 \leq h \leq p \quad (10)$$

根据计算的各变量的主元负荷值来确定影响质量的主导变量。

2 多元自相关过程的监测

由 DRPCA 方法建立新的测量样本矩阵 $\mathbf{Y}$, 采用均方预测误差 (SPE) 统计量^[11] 和 Hotelling T^2 统计量 (简称 T^2 统计量) 对多元质量控制图的控制限进行调整。SPE 统计量通过分析新的测量数据的残差进行检测, 它表示此时刻的测量值相对主元模型的偏离程度, 是模型外部数据变化的一种测度。统计量计算值为

$$Q = \mathbf{e}_n^T \mathbf{e}_n \quad (11)$$

式中: $\mathbf{e}_n$ 为残差矢量。对于新的测量样本, T^2 的统计量为

$$T^2 = \mathbf{Y} \mathbf{P}_A \lambda^{-1} \mathbf{P}_A^T \mathbf{Y}^T \quad (12)$$

式中: $\mathbf{P}_A$ 为 $\mathbf{Y}$ 的协方差矩阵; λ 为协方差矩阵的特征值。

根据残差判定准则, 在正常情况下, SPE 统计量与 T^2 统计量应满足

$$Q < \theta_1 \left[\frac{Ch_0(2\theta_2)^{1/2}}{\theta_1} + 1 + \frac{\theta_2 h_0(h_0 - 1)}{\theta_1} \right]^{1/h_0} \quad (13)$$

$$T_2 < \frac{l(m-1)}{m-l} z \quad (14)$$

式中: $\theta_i = \sum_{j=i+1}^m \lambda_j$, $i=1, 2, 3$; $h_0 = 1 - \frac{2\theta_1\theta_3}{\theta_2^2}$; C 为正态分布置信度为 $(1-\alpha)\%$ 的统计置信极限, 其中 α 为置信检验水平; m 为样本个数; l 为所保留的主元个数; z 为 F 分布的临界值。

定义多元自相关质量控制图 (见图 2) 的异常判




图 2 基于 DRPCA 方法的多元自相关质量控制框图

定规则为

$$(\sigma > T_2) \cup (\sigma > Q) \tag{15}$$

式中: σ 为样本均方差。根据计算的 T^2 和 SPE 统计量值来确定控制图的控制上限,利用多元控制图对过程变量进行实时监测。

3 实例分析

以某汽车净化器生产线的涂覆过程为例,将 DRPCA 方法与传统的质量控制方法的监控效果进行了对比,涂覆过程是在真空条件下进行的,需要控制的参数有压强、搅拌温度、浆液质量分数、涂覆温度、浆液质量以及 pH 值等。从该生产线采集 2 个批次、共 30 组的实验数据如表 1 所示。

表 1 涂覆过程的变量数据

批 次	序 号	浆液质量 分数/%	压强 /Pa	搅拌温 度/℃	pH	浆液质 量/kg	涂覆温 度/℃
I	1	30.62	4 412	41.9	1.96	9.93	40.2
	2	31.85	3 955	42.8	2.22	9.09	40.7
	3	30.86	3 896	41.4	2.02	9.04	39.2
	4	30.37	3 961	41.5	2.11	8.46	40.3
	5	31.81	3 938	41.3	1.97	8.98	39.0
	6	31.96	3 852	41.3	2.14	9.25	39.7
	7	30.88	4 176	42.7	2.00	9.36	39.3
	8	30.22	4 182	42.2	2.16	8.79	40.5
	9	30.52	4 030	42.1	2.17	8.73	40.7
	10	30.82	3 823	41.3	2.19	9.98	39.1
	11	31.19	3 893	42.7	2.08	10.20	39.6
	12	30.52	3 941	42.2	1.93	9.77	39.8
	13	31.21	4 128	41.7	1.99	9.83	40.5
	14	31.42	3 802	42.0	2.26	9.59	40.0
	15	30.44	3 817	41.8	1.96	8.20	40.0
II	16	30.23	3 867	41.2	2.23	10.00	39.6
	17	30.59	4 059	41.5	2.12	8.67	39.1
	18	30.64	4 092	41.2	2.30	9.36	39.4
	19	30.85	4 059	41.4	1.93	8.27	39.4
	20	31.02	3 980	41.5	2.08	9.44	40.9
	21	30.17	4 018	41.8	1.94	8.21	39.5
	22	30.53	3 918	41.1	2.28	9.31	40.1
	23	31.60	4 097	42.8	1.90	8.99	40.5
	24	30.06	3 875	42.9	2.21	9.56	40.4
	25	31.86	4 074	42.0	2.23	9.43	39.2
	26	31.46	3 873	42.0	2.25	9.81	39.7
	27	30.98	3 947	41.7	1.93	9.78	39.1
	28	31.16	4 050	42.8	2.06	8.67	39.8
	29	30.47	4 112	41.7	2.00	9.40	40.0
	30	30.92	3 832	41.2	2.22	8.40	40.3

用 PCA 方法将三维集合 $X(2,6,15)$ 转换为二维数据 $X(6,30)$,并采用滑动窗口将 $X(6,30)$ 划分为一系列子数据空间,得到

$$X = \{X_u(6,5), X_{u+b}(6,5), \cdots, X_{u+25b}(6,5)\}$$
$$u = 5, \quad b = 1, \quad w(26) = 0.45$$

$$T_k = 0.45 \left[\prod_{t=k+1}^L v(t) \right]$$

根据仿真结果可确定时变因子的取值范围为 $0.92 < v(t) < 0.98$,取 $v(t) = 0.95$,折息因子的取值见图 3。




图 3 折息因子

根据式(10)计算主元累积贡献率,并对主元因子进行分析,以确定主元特征值(见表 2)。

表 2 涂覆过程的主元因子及累积贡献率

主 元 数	主元特 征值	主元因子 分析式	C _p /%
1	1.517 1	0.134X ₁ +0.043X ₂ −0.074X ₃ − 1.058X ₄ +0.096X ₅ +0.152X ₆	25.3
2	1.363 4	−0.264X ₁ −0.088X ₂ +0.052X ₃ + 0.094X ₄ −0.027X ₅ −1.764X ₆	48.0
3	1.077 3	−0.014X ₁ −0.102X ₂ +1.028X ₃ + 0.077X ₄ +0.048X ₅ −0.269X ₆	66.0
4	0.958 9	−0.058X ₁ −1.049X ₂ +0.099X ₃ + 0.044X ₄ +0.092X ₅ −0.368X ₆	90.3
5	0.841 8	−0.079X ₁ +0.094X ₂ −0.048X ₃ + 0.098X ₄ −1.037X ₅ +0.077X ₆	96.1
6	0.241 4	−0.824X ₁ −0.027X ₂ +1.028X ₃ + 0.096X ₄ −0.060X ₅ −1.456X ₆	99.8

由表 2 可以看出,主元 1~4 的 C_p 为 90.3%,由此可以解释 90%以上的变量数据的变化过程。采用 C_p 的主元选取原则,选取的主元数为 4,计算各变量的相对主元负荷值如表 3 所示。

表 3 涂覆过程各变量的主元负荷参数

负荷参数	主元 1	主元 2	主元 3	主元 4
浆液质量分数/%	0.294	0.382	0.449	0.442
pH	0.374	0.488	0.334	0.501
压强/Pa	0.632	0.646	0.782	0.665
搅拌温度/°C	0.264	0.063	0.741	0.198
浆液质量/kg	0.110	0.683	0.108	0.528
涂覆温度/°C	0.540	0.237	0.304	0.408

根据表 1 中的数据,分别计算平方预测误差的 SPE 统计量 U_1 ,以及 Hotelling T^2 统计量 U_2 ,计算相应的 $\alpha = 95\%$,控制图上限的 $U_1 = 17.6, U_2 = 18.2$ 。利用 T^2 控制图和主导因素的单变量控制图,对净化器的涂覆过程进行实时监测,取某时间段的 30 个监测点为监控对象,将传统质量控制方法与采用 DRPCA 方法对净化器涂覆过程的监控效果进行对比,由式(15)判断涂覆过程中是否出现了异常。图 4、图 5 分别为传统质量控制方法与本文提出的 DRPCA 方法的监控效果。




图 4 传统方法的监控效果




图 5 DRPCA 方法的监控效果

从图 4 的监控效果中可以看出,传统方法是忽略了数据间的自相关后确定的控制上限(16.7),因此在该涂覆过程中的第 5、7、14 s 时出现了超差,但

根据实际净化器的涂覆生产过程,只在第 5 s 时出现超差,而第 7、14 s 时则是正常的。图 5 为本文提出的 DRPCA 方法的监控效果,可以看出,在第 5 s 时出现了超差,表明该方法能够准确地检测出涂覆过程的异常,并消除了虚发报警,明显降低了涂覆过程的误报率。

根据主导变量单值控制图,对主导变量-压强进行监测(见图 6)。从图 6 可以看出,主导变量-压强




图 6 主导变量-压强的单值控制图

在 5 s 时出现了超差,根据涂覆结果,检验出该时刻生产的净化器是不合格的,从而验证了本文提出的主导变量确定方法的有效性。

4 结 论

(1)根据滑动窗口技术,本文通过引入折息因子,提出了 DRPCA 的质量控制方法。该方法通过转换数据样本的组合形式,有效地降低了自相关过程的计算复杂度,消除了数据间的自相关,提高了质量控制图的监测能力。

(2)对于 DRPCA 方法建立的新样本,采用 SPE 统计量和 T^2 统计量来确定质量控制图的控制限,并结合主元负荷值确定主导变量,利用多元控制图和主导变量单值控制图监测制造过程,从而减少了虚发报警,及时确定制造过程中的异常因素。

(3)以汽车净化器的涂覆过程为例,通过分析计算,确定控制图的上限及主导变量,并对涂覆过程进行实时监测。结果表明,该方法明显降低了自相关过程的虚发报警,能够准确确定汽车净化器涂覆过程中的异常问题,从而减少了制造过程中异常检查的时间。

本文提出的 DRPCA 方法能够有效地避免自相关过程中所产生的虚发报警现象,同时结合表 3 中各变量的主元负荷参数,可以准确地确定出制造过程中出现的异常因素。

参考文献:

- [1] ISSAM B K, CLAUS W, MOHAMED L. Support vector regression control charts for multivariate nonlinear autocorrelated processes [J]. *Chemometrics and Intelligent Laboratory Systems*, 2010, 103(1): 76-81.
- [2] JESSREY E J, XIA P. The quality control chart for monitoring multivariate autocorrelated processes [J]. *Computational Statistics & Data Analysis*, 2007, 51(8): 3862-3870.
- [3] SEOUNG B K, WEERAWA J, SUN K P. Data mining model-based control charts for multivariate autocorrelated processes [J]. *Expert Systems with Applications*, 2012, 39(2): 2073-2081.
- [4] 杨穆尔, 孙静. 多元自相关过程的 VAR 控制图 [J]. *数理统计与管理*, 2008, 27(2): 403-406.
YANG Mu'er, SUN Jing. A VAR control scheme for multivariate autocorrelated observations [J]. *Application of Statistics and Management*, 2008, 27(2): 403-406.
- [5] 田海晶, 潘尔顺. 自相关过程的多变量统计过程监控 [J]. *上海交通大学学报*, 2008, 42(3): 496-499.
TIAN Haijing, PAN Ershun. Multivariate statistical process control for autocorrelated process [J]. *Journal of Shanghai Jiao Tong University*, 2008, 42(3): 496-499.
- [6] CHEN S H, NEMBHARD H B. Multivariate Cuscore control charts for monitoring the mean vector in autocorrelated processes [J]. *IIE Transactions*, 2011, 43(4): 291-307.
- [7] DING S, ZHANG P, DING E, et al. On the application of PCA technique to fault diagnosis [J]. *Tsinghua Science and Technology*, 2010, 15(2): 138-144.
- [8] 王华忠, 俞金寿. 基于核函数 PCA 的非线性过程实时监控方法 [J]. *华东理工大学学报*, 2005, 31(6): 783-824.
WANG Huazhong, YU Jinshou. On-line monitoring of nonlinear processes based on kernel principal component analysis [J]. *Journal of East China University of Science and Technology*, 2005, 31(6): 783-824.
- [9] LIU Xueqin, UWE K, TIM L. Moving window kernel PCA for adaptive monitoring of nonlinear processes [J]. *Chemometrics and Intelligent Laboratory Systems*, 2009, 96(2): 132-143.
- [10] 郭小萍, 陆宁云, 高福荣, 等. 间歇过程滑动窗口子时段建模和在线监测 [J]. *控制与决策*, 2005, 20(9): 1034-1037.
GUO Xiaoping, LU Ningyun, GAO Furong, et al. Sub-stage PCA modeling and on-line monitoring with moving windows for batch processes [J]. *Control and Decision*, 2005, 20(9): 1034-1037.
- [11] 冯雄峰, 阳宪惠, 徐用懋. 多元统计过程控制方法的平方预测误差分析 [J]. *清华大学学报: 自然科学版*, 1999, 39(7): 41-45.
FENG Xiongfeng, YANG Xianhui, XU Yongmao. Squared prediction error analysis of multivariate statistical process control [J]. *Tsinghua University: Science & Technology*, 1999, 39(7): 41-45.

[本刊相关文献链接]

- 吴君, 张荻, 马丹丹, 张明辉, 谢永慧. 利用三维接触有限元法的透平叶片枞树型叶根轮缘优化. 2012, 46(5): 25-31.
- 尚万峰, 赵升吨. 伺服压力机加工工艺的 Bezier 模型及其优化研究. 2012, 46(3): 31-35.
- 郝元宏, 韩静, 齐春. 一种新的浮选泡沫图像识别方法. 2011, 45(4): 104-108.
- 杜锦华, 梁得亮. 波能直驱互感耦合式开关磁阻发电机的最佳效率跟踪控制. 2012, 46(4): 52-57.
- 支强, 蔡远利. 动能杀伤器侧窗定向机制分析及建模. 2012, 46(1): 91-96.
- 赵鹏, 姚敏立, 沈晓卫, 胡友涛. 非奇异快速终端滑模液位跟踪控制. 2011, 45(12): 39-44.
- 邵伟, 郭俊杰, 周阿维. 应用在线整定广义最小方差多项式权值的测头控制方法. 2011, 45(4): 100-103.
- 张洋, 别朝红. 一种无速度传感器的双馈风力发电机滞环矢量控制策略. 2010, 44(6): 109-113.
- 武利龙, 陈斌. 气泡堆积法生成局部加密非结构化网格. 2009, 43(9): 19-22.
- 方素平, 夏晓华, 肖燕, 郭瑞. 一种线阵相机镜头畸变的标定方法. 2013, 47(1): 11-14.
- 胡国伟, 别朝红. 一种适用于配电网重构的动态调整策略. 2012, 46(12): 78-84.
- 杨攀, 桂小林, 田丰, 王刚. 一种高效的用于话题检测的关键词元聚类方法. 2012, 46(10): 24-28.
- 张进华, 李婷, 王孙安, 李小虎. 可变视场下的火灾探测算法. 2012, 46(10): 29-35.
- 陈明, 胡安, 刘宾礼. 绝缘栅双极型晶体管失效机理与寿命预测模型分析. 2012, 46(10): 65-71.
- 何英杰, 刘进军, 王兆安, 邹云屏. 三电平有源电力滤波器谐波电流跟踪无差控制方法. 2009, 43(8): 90-94.
- 袁敞, 刘进军, 王晓钰, 李晶, 王兆安. 一种新型串联型有源电力滤波器无谐波检测控制方法. 2009, 43(2): 86-89.
- 张国亮, 王捷, 刘宏. 大范围视觉伺服方法在空间机器人上的应用. 2009, 43(1): 85-89.

(编辑 管咏梅)