

DOI: 10.7652/xjtuxb201703021

多变量轨迹分析的过程故障检测方法

沈非凡, 宋执环, 葛志强

(浙江大学工业控制技术国家重点实验室, 310027, 杭州)

摘要: 为了解决实际工业过程中的多变量动态过程监测问题,提出了一种基于多变量轨迹分析和主元分析的在线故障检测方法。通过构造过程轨迹向量实现了多变量动态信息的提取,结合主元分析算法对模型进行了改进,利用改进模型充分分析了过程数据的变化特征,同时将关键变量的轨迹趋势图作为参考实现了离线建模和在线故障检测。与传统的基于轨迹分析的方法相比,所提方法克服了变量个数限制,解决了统计量难以设计的问题,提取了过程动态特性,实现了更为可靠的动态过程监测。通过某企业合成氨生产中转化单元的实例验证表明,所提方法在处理多变量动态过程的故障检测问题上效果良好。

关键词: 故障检测;多变量轨迹分析;主元分析;合成氨生产

中图分类号: TP277 **文献标志码:** A **文章编号:** 0253-987X(2017)03-0122-07

Fault Detection Based on Multivariate Trajectory Analysis

SHEN Feifan, SONG Zhihuan, GE Zhiqiang

(State Key Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027, China)

Abstract: To solve dynamic problems in industrial multivariable process monitoring, a novel fault detection method is proposed to describe process trajectories combining multivariate trajectory analysis with principal component analysis. The trajectory vectors are constructed to extract information in multivariate dynamic process, and then principal component analysis algorithm is adopted to develop the model and analyze the variation features of process data. The trajectory tendency charts of several critical variables involved with data variations are plotted, and offline modeling and online fault detection are finally realized. Compared with the traditional methods based on trajectory analysis, the proposed method breaks the limitation of variable number and solves the difficulty in developing monitoring statistics to better extract characters in process dynamics and more reliable dynamic process monitoring. A practical case of synthetic ammonia conversion unit verifies the effectiveness of the proposed method.

Keywords: fault detection; multivariate trajectory analysis; principal component analysis; synthetic ammonia production

过程监测与故障诊断对于工业过程的平稳运行起着重要的作用。由于现代工业过程的复杂性,精确的数学模型往往难以建立,因此基于数据驱动的

过程监测方法近年来被广泛应用于实际过程中^[1-3],其中最为常用的是以主元分析(PCA)以及偏最小二乘法(PLS)为代表的多变量统计过程控制(MSPC)

收稿日期: 2016-08-17。 作者简介: 沈非凡(1989—),男,博士生;宋执环(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(61573308);高等学校博士学科点专项科研基金资助项目(20130101110138)。

网络出版时间: 2016-12-07

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20161207.1604.006.html>

方法^[4-6]。然而,这些方法往往基于变量分布以及相关性的简单假设,难以处理实际过程中数据非线性以及动态性等问题^[7-9]。过程轨迹分析是用于描述过程进程以及状态变化的一种方法,即选取部分关键变量描绘其在整个过程(运行时间和变量空间内)中的变化趋势,实现控制、监测、优化等多种目标^[10]。目前,常用的轨迹分析方法需要将变量的变化趋势投影到二维或三维的空间中,其难以处理多变量情况下的高维问题^[11]。针对多变量轨迹分析的难点,本文提出了一种基于轨迹向量的过程监测方法,其利用过程数据的特性,通过差分计算和归一化处理,利用轨迹向量代替原始数据样本,实现过程的离线建模和在线监测。

1 过程轨迹分析及监测

轨迹分析的主要作用是将整个过程的变化趋势通过几个关键变量在选定的分析空间中描绘出来,并根据实际任务的需求进行进一步计算和处理^[12]。

当前利用过程轨迹进行过程监测的主要步骤包括以下3个阶段。

(1)变量选取和计算平均轨迹。根据实际需求选择关键变量,计算这些变量在整个历史运行时段和分析空间内的平均轨迹。从过程监测的角度出发,现代工业过程的变量可分为操作变量和测量变量两大类,其中测量变量包含过程变量和少量可被测得的质量变量。通常情况下,质量变量以及与质量密切相关的重要过程变量更适合作为关键变量,用于轨迹分析和后续监控。在分析空间时,时间作为一个特殊变量,并没有被引入空间内的计算中,其优点是能够解决采样间隔不等长及数据缺失等与时间标签相关的问题。

(2)轨迹可视化与离线建模。根据得出的过程关键变量平均轨迹绘制出二维或三维的轨迹趋势图;根据历史数据特性,通过轨迹趋势图设定并计算离线监测模型下的轨迹可接受范围,即基于变量轨迹的控制限。

(3)在线监测及诊断。提取过程实时在线样本中已选定了关键变量信息,并在当前时刻绘制出对应的变量轨迹。随后,判断当前轨迹是否超出离线模型设定的控制限。若未超出控制限,则继续获取下一个在线样本并进行后续计算;若已超出控制限,则进入故障诊断阶段,寻找引起异常的变量及根本原因。

该方法挖掘了过程数据的变化趋势,将过程的

动态性通过较为简单的方法直接提取,对于处理数据特性较为复杂的动态过程有良好的效果。然而,在处理变量数较多的大数据问题上,过程轨迹可视化的实现十分困难,而在处理平稳过程时难以对过程开始及结束的时间点进行定位,所以离线建模难度很大。

2 轨迹向量构造

为了更好地处理多变量轨迹分析问题,本文引入了一种全新的轨迹向量描述和构造方法,用于表示大部分过程变量在运行过程中各个时段的变化趋势,并利用轨迹向量进一步实现离线建模和在线故障检测^[13]。

如图1所示,虚线表示变量在该时段内的变化,实线表示综合计算两个变量变化得出的变量轨迹。由于图1b中变量2的变化程度较大,使得其综合变量轨迹与图1a完全不同;图1c中变量1和变量2的变化均较大,然而经综合计算后的变量轨迹变化方向与图1a保持一致。从轨迹分析的角度来看,图1a和图1c反映的是过程运行过程中的相似轨迹,有同样的动态变化趋势。在后续建模计算中,由于两者轨迹变化的长度不一致,所以需要将相似轨迹进行归一化处理才能提取出有效信息,并利用轨迹向量实现故障检测。




图1 变量轨迹在分析空间中的表示

为了解决过程轨迹归一化的问题,本文提出了一种包含归一化步骤的过程轨迹向量计算方法。在离线建模阶段,首先提取历史数据 $\mathbf{X} \in \mathbf{R}^{M \times N}$ 的轨迹信息,其中 M 代表历史总采样样本数, N 代表变量总数。设定一个轨迹计算的步长 s ,对历史数据每个样本以该固定步长进行差分计算

$$t_{m,n} = \|x_{m,n} - x_{m-s,n}\| \quad (1)$$

式中: $t_{m,n}$ 为差分计算后得到的值; m, n 分别代表当

前样本和变量标签; $x_{m,n}$ 为当前样本变量的值。由当前样本标签 m 下所有的差分计算结果集合, 可以得到未归一化的轨迹向量

$$\bar{\mathbf{x}}_m = [t_{m,1}, t_{m,2}, \dots, t_{m,N}] \quad (2)$$

为了实现轨迹向量的归一化, 将向量中的每个元素除以该向量的模长, 计算出轨迹向量每个变量元素在单位模长下的变化幅度

$$\hat{\mathbf{x}}_m = \left[\frac{t_{m,1}}{\|\bar{\mathbf{x}}_m\|}, \frac{t_{m,2}}{\|\bar{\mathbf{x}}_m\|}, \dots, \frac{t_{m,N}}{\|\bar{\mathbf{x}}_m\|} \right] \quad (3)$$

归一化计算得到的轨迹向量 $\hat{\mathbf{x}}_m$ 提取了过程中所选变量在运行时间内的变化趋势信息, 并能直接用于后续的离线建模。该算法的优点是计算所得的轨迹向量直接包含过程变量的动态特征, 轨迹的归一化计算也使得监测模型的建模对时间标签和数据完整性的要求更低。

3 基于轨迹向量的过程监测

3.1 变量选取

在实际生产过程中, 传感器采集到的变量有多种类型, 其中部分变量不适合用于过程监测模型的建模。这些变量主要包括生产过程积累量、包含大量缺失值的变量以及过程运行中基本保持不变的变量。与现有基于轨迹分析方法的区别在于, 本文提出的方法是通过选取适合用于建模的大部分过程变量进行进一步的分析和计算的, 不再受到关键变量数的限制。

3.2 计算轨迹向量

对变量选择步骤完成之后得到的历史数据集 $\mathbf{X} \in \mathbf{R}^{M \times N}$ 进行轨迹向量构造。根据样本数量规模, 选择合适的轨迹向量计算步长 s , 得到历史轨迹向量集 $\hat{\mathbf{X}} \in \mathbf{R}^{(M-s) \times N}$ 。

为了避免时间区间内前后样本的相似度过高, 引起轨迹向量的构造被噪声等无关信息覆盖, 差分计算的步长不宜选择得过小。在动态过程监测的实际应用中, 需要满足步长区间内的前后样本存在一定的差异性, 这样通过轨迹向量的差分计算能较好地提取过程数据的局部动态特征。

3.3 建立离线监测模型

PCA 作为一种传统的多元统计算法, 被广泛应用于过程监测领域中^[14]。选取一段采样得到的包含 m 个采样点数和 n 个测量变量的过程数据 $\mathbf{X} \in \mathbf{R}^{m \times n}$, 利用 PCA 建立的统计分析模型表示如下^[15]

$$\mathbf{X} = \mathbf{TP}^T + \tilde{\mathbf{TP}}^T = \mathbf{TP}^T + \mathbf{E} \quad (4a)$$

$$T^2 = \mathbf{t}^T \mathbf{A}^{-1} \mathbf{t} \leq \frac{k(m^2 - k)}{m(m - k)} F_\alpha(k, m - k) \quad (4b)$$

$$\mathbf{Q} = \mathbf{ee}^T = \mathbf{x}(\mathbf{I} - \mathbf{PP}^T)\mathbf{x}^T \leq \mathbf{Q}_\alpha \quad (4c)$$

式中: k 表示主元个数; $\mathbf{T} \in \mathbf{R}^{m \times k}$ 、 $\mathbf{P} \in \mathbf{R}^{n \times k}$ 分别表示主元空间得分矩阵和载荷矩阵; $\tilde{\mathbf{T}} \in \mathbf{R}^{m \times (n-k)}$ 、 $\tilde{\mathbf{P}} \in \mathbf{R}^{n \times (n-k)}$ 分别表示残差空间得分矩阵和载荷矩阵; $\mathbf{E} \in \mathbf{R}^{m \times n}$ 为残差矩阵; $\mathbf{t}^{1 \times k}$ 为监测主元空间的 Hotelling T^2 统计量中主元空间得分矩阵的行向量; $\mathbf{A}$ 为包含坐标转换后方差信息的对角矩阵; $F_\alpha(k, m - k)$ 表示 F 分布的 α 置信限; $\mathbf{e}^{1 \times n}$ 为监测残差空间的平方预测误差 (SPE) 统计量中残差矩阵 $\mathbf{E}$ 的行向量; $\mathbf{x}^{1 \times n}$ 为原始数据矩阵 $\mathbf{X}$ 的行向量; $\mathbf{Q}_\alpha$ 表示残差统计量的 α 置信限。通常情况下, 置信限设置为 99% 时可以满足大部分过程监测的实际需求。

传统的 PCA 算法基于过程数据高斯分布以及变量线性相关的假设, 因此在实际复杂工业过程中的监测效果并不理想。本文利用包含过程变化信息的轨迹向量矩阵 $\hat{\mathbf{X}} \in \mathbf{R}^{(M-s) \times N}$ 代替原有的数据矩阵, 再利用 PCA 算法建立离线统计模型。该模型用样本的相对变化趋势代替原来的空间绝对位置进行建模, 能够以相似的运算效率处理复杂的动态过程, 由此提高了故障检测的泛用性和可靠性。

与此同时, 引入轨迹分析中的部分策略, 选取少量的过程关键变量绘制轨迹趋势图, 并作为监测模型的补充。通过对历史数据的分析, 在离线阶段绘制出包含历史数据信息的过程轨迹, 以此作为正常工况下的参考轨迹。在在线监测阶段, 当前在线数据的轨迹可作为故障检测和诊断的补充。

3.4 进行在线监测

在在线监测阶段, 通过获取到的当前样本数据计算离线模型设定步长下的当前样本轨迹向量

$$\hat{\mathbf{x}}_c = [t_{c,1}/\|\bar{\mathbf{x}}_c\|, t_{c,2}/\|\bar{\mathbf{x}}_c\|, \dots, t_{c,n}/\|\bar{\mathbf{x}}_c\|]$$

$$\bar{\mathbf{x}}_c = [t_{c,1}, t_{c,2}, \dots, t_{c,N}]$$

$$t_{c,n} = \|x_{c,n} - x_{c-s,n}\| \quad (5)$$

利用当前时刻的轨迹向量通过建立的离线 PCA 模型计算统计量。若当前轨迹在主元空间和残差空间的统计量超出了控制限, 则表示当前轨迹偏离了历史轨迹, 而过程很可能产生了异常或者故障, 应进入后续的故障诊断步骤; 若统计量的值均未超过设定的控制限, 则表示当前轨迹正常, 而过程仍处于正常工况, 应等待下一个在线样本的采集和计算。

作为统计监测模型的补充, 通过对在线阶段样本的收集, 绘制出离线模型中已选定变量的在线轨迹趋势图。利用该轨迹图, 通过对当前在线轨迹与整个运行过程中的离线历史轨迹的比较, 来判定当前轨迹是否已偏离正常工况下的轨迹。针对统计量

超限不明显或者没有连续超限的情况,利用轨迹图可辅助诊断故障是否发生。

整个故障诊断的流程主要包含离线建模和在线实时监测两部分,如图 2 所示。在最终决策阶段,当轨迹 PCA 模型的 T^2 统计量或 SPE 统计量超限时,故障检测模型将通过报警来提示故障已经发生,实现基于数学模型的定量监测,而工作人员可以通过实时的关键变量轨迹趋势图进行可视化监控,并作为轨迹 PCA 模型的定性补充。当故障警报产生且实时轨迹出现较大偏离时,可以判定故障已经发生;当故障警报产生而实时轨迹保持正常时,可能产生了误报现象,工作人员需要结合实际经验进行进一步诊断;当未发生故障警报而实时轨迹发生较为明显的偏离时,可能产生了漏报或者检测延迟现象,需要搜寻引起轨迹异常的根源,找出发生异常的关键变量进行更为及时的故障检测和诊断。




图 2 基于过程轨迹分析的故障检测流程图

4 应用实例

为了验证本文方法在实际工业过程中的可行性,利用某企业合成氨流程中的一个单元实例进行了测试。该单元是合成氨生产过程中的转化单元,在转化流程中烃类和蒸汽依次经过预转化炉和一段炉、通过催化剂进行一次反应,生成氨合成所需组分的原料气;通过一次反应后剩余的甲烷等原料经过二段炉与空气及催化剂进行二次反应,生成部分原料气。转化单元反应装置及流程如图 3 所示。

将转化单元在 2015 年 1 月至 3 月的采样数据矩阵 $\mathbf{X} \in \mathbf{R}^{129\,601 \times 67}$ 作为历史数据,其中包含 129 601 个采样样本及 67 个变量。部分变量由于其数据特性,不适合用于监测模型的建模,因此在历史数据矩阵中首先剔除这些变量。在 67 个变量中,剔除了 19 个不适合用于建模的变量,其中主要包括:生产




图 3 合成氨转化单元流程图

过程累积量,如一段炉回收燃气总量;在过程中基本不变的量,如锅炉给水流量;包含大量缺失值的变量或者开关变量,如氩气含量。

首先选取第 55 001 至第 57 000 个样本进行测试,该时间段是转化单元空闲状态和运行状态间的过渡阶段,变量在这一阶段内变化幅度较大,有较强的动态特性。

在 2 000 个样本中随机选取 500 个样本作为建模样本,将其余 1 500 个过渡阶段样本及 1 500 个正常工况下随机抽取的样本作为测试样本。由于正常工况下的数据特性与过渡阶段差异较大,因此从正常工况下抽取的随机样本在该实例中可被视为故障样本进行测试。进入一段炉的天然气流量及二段炉入口的工艺空气流量将作为过程关键变量,由此绘制对应的轨迹趋势图,作为故障检测的参考和补充。

利用基于轨迹向量的 PCA 模型和传统 PCA 模型分别对以上数据进行建模和测试,两个 PCA 模型统计量的置信度均设为 99%。在实例中,当轨迹向量的计算步长分别设置为 5 和 10 个采样间隔时,故障检测的效果基本保持一致;当步长小于 5 时,故障检测的效果受到了一定的影响。这是由于当步长设置过小时,前后样本差异性过小,导致轨迹向量无法较好地提取样本动态信息。以步长为 10 个采样间隔为例(下同),在正常过渡阶段数据下的统计监测结果和轨迹趋势图分别如图 4、5 所示。

其于轨迹向量的 PCA 和传统 PCA 模型的误报率分别为 0 和 1.8%。从正常样本的监测结果看,轨迹趋势图中在线样本与离线样本的轨迹基本吻合,且两种方法的误报率均较低,该实例下的测试效果均令人满意。

对随机抽取的 1 500 个故障样本进行测试,两种方法的统计监测效果及轨迹趋势图分别如图 6、7




图 4 过渡阶段正常样本监测结果




图 5 过渡阶段正常样本轨迹趋势图




图 6 过渡阶段故障样本监测结果




图 7 过渡阶段故障样本轨迹趋势图

果看,传统 PCA 算法无法检测出异常的在线数据。这是由于过渡阶段的数据往往包含了前后工况的数据特征,这就导致了利用空间绝对位置进行分析的传统 PCA 模型无法检测到故障样本的不同特征;反之,对样本进行空间相对位置分析的基于轨迹向量的方法则可以在一定程度上检测出数据的异常。同时,由于处于过渡阶段的正常建模样本有较强的动态性,基于轨迹分析的方法可以更好地提取数据动态特性,所以在故障检测中有更好的效果。轨迹趋势图也展示了在线样本的轨迹与建模样本难以吻合,表明故障已经发生。

针对较为平稳的稳态工况进行了测试。选择第 65 001 至第 67 000 个样本作为正常工况下的数据,并随机抽取其中的 1 000 个样本作为离线建模样本。将建模样本之后的 20 000 个稳态工况下的样本作为正常情况下的测试数据,同时将前一工况下的第 51 001 至第 53 000 个样本作为故障数据,用两种方法进行效果对比。轨迹向量的计算步长设为 10,两个 PCA 模型统计量的置信度均设为 99%。在正常工况下的监测结果和轨迹趋势图如图 8、9 所示。




图 8 稳定工况下正常样本监测结果




图 9 稳定工况下正常样本轨迹趋势图

所示。

基于轨迹向量的 PCA 和传统 PCA 模型的故障检出率分别为 0 和 28.5%。从故障样本的监测结

基于轨迹向量的 PCA 和传统 PCA 模型的误报率分别为 40.2%和 2.94%。从正常样本的监测结

果看,传统 PCA 在工况后段的误报率极高,而基于轨迹向量的方法保持了较低的误报率。这是由于在后段工况部分变量受外部环境的影响产生了漂移,导致统计量逐渐超出了控制限,事实上受测过程依然处于正常运行的状态。从轨迹趋势图的角度进行分析,得出在线样本与离线样本的轨迹基本吻合,可以认为受测过程仍处于正常工况。

将故障数据引入后进行测试,结果如图 10、11 所示。




图 10 稳定工况下故障样本监测结果




图 11 稳定工况下故障样本轨迹趋势图

基于轨迹向量的 PCA 和传统 PCA 模型的故障检出率分别为 100% 和 99.2%。从监测结果看,两种方法的统计量均有明显的超限现象,都能很好地检测出故障。针对更为明显的故障,传统 PCA 模型可以检测到故障样本在空间中绝对位置发生异常;基于轨迹分析的统计方法及对应的轨迹趋势图同样能通过捕捉变量趋势异常变化检测出故障。

从上述两个不同操作阶段的实例测试结果看,基于轨迹向量的方法有更好的适应性,无论在数据特性较为复杂的过渡阶段还是在数据特性较为稳定的工况下,均有较好的故障检测效果,而传统方法在复杂工况下的监测效果并不满意。

5 结 论

本文基于轨迹分析方法在过程监测中的应用背景,提出了一种以轨迹向量构造为主的过程故障检测方法。该方法考虑了变量在空间内的相对位置信息,提取了过程运行中变量的变化轨迹,并代替原始样本用于离线建模。将轨迹向量与 PCA 模型结合并进行改进,同时将关键变量轨迹图作为故障检测的参考,使得故障检测的可靠性得以提高。实验结果表明,与仅利用原始样本进行建模的传统 PCA 模型相比,本文方法对复杂动态过程的在线故障检测效果更好,适合实际工业过程中的监测应用。

本文方法的优点主要包括:克服了传统基于轨迹的监测方法中关键变量数受限制的问题,实现了多变量轨迹分析和故障检测;通过将轨迹向量和 PCA 模型结合,解决了复杂数据轨迹分析监测中统计量难以设计的问题;与传统方法相比,能更好地提取过程动态特性,对动态过程监测有更好的效果。但是,针对其他过程的通用性和有效性仍有待检验。

参考文献:

- [1] QIN S J. Survey on data-driven industrial process monitoring and diagnosis [J]. Annual Reviews in Control, 2012, 36(2): 220-234.
- [2] TONG C, EL-FARRA N H, PALAZOGLU A, et al. Fault detection and isolation in hybrid process systems using a combined data-driven and observer-design methodology [J]. AIChE Journal, 2014, 60(8): 2805-2814.
- [3] GE Z, SONG Z, GAO F. Review of recent research on data-based process monitoring [J]. Industrial & Engineering Chemistry Research, 2013, 52(10): 3543-3562.
- [4] GE Z, SONG Z. Semiconductor manufacturing process monitoring based on adaptive substatistical PCA [J]. IEEE Transactions on Semiconductor Manufacturing, 2010, 23(1): 99-108.
- [5] NOMIKOS P, MACGREGOR J F. Monitoring batch processes using multiway principal component analysis [J]. AIChE Journal, 1994, 40(8): 1361-1375.
- [6] NOMIKOS P, MACGREGOR J F. Multi-way partial least squares in monitoring batch processes [J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1): 97-108.
- [7] WEN Q, GE Z, SONG Z. Data-based linear Gaussian state-space model for dynamic process monitoring [J].

- AICHE Journal, 2012, 58(12): 3763-3776.
- [8] CHOI S W, MORRIS J, LEE I B. Dynamic model-based batch process monitoring [J]. Chemical Engineering Science, 2008, 63(3): 622-636.
- [9] YU J. Multiway discrete hidden Markov model-based approach for dynamic batch process monitoring and fault classification [J]. AICHE Journal, 2012, 58(9): 2714-2725.
- [10] BOGOMOLOV A. Multivariate process trajectories: capture, resolution and analysis [J]. Chemometrics and Intelligent Laboratory Systems, 2011, 108(1): 49-63.
- [11] CIMANDER C, MANDENIUS C F. Bioprocess control from a multivariate process trajectory [J]. Bioprocess and Biosystems Engineering, 2004, 26(6): 401-411.
- [12] WAN J, MARJANOVIC O, LENNOX B. Trajectory tracking of batch product quality using intermittent measurements and moving window estimation [C]// UKACC International Conference on Control. Piscataway, NJ, USA: IEEE, 2012: 115-128.
- [13] SHEN F, GE Z, SONG Z. Multivariate trajectory-based local monitoring method for multiphase batch processes [J]. Industrial & Engineering Chemistry Research, 2015, 54(4): 1313-1325.
- [14] 蒋少华, 桂卫华, 阳春华, 等. 基于核主元分析与多支持向量机的监控诊断方法及其应用 [J]. 中南大学学报(自然科学版), 2009, 40(5): 1323-1328.
- JIANG Shaohua, GUI Weihua, YANG Chunhua, et al. Method based on kernel principal component analysis and support vector machine and its application [J]. Journal of Central South University (Science and Technology), 2009, 40(5): 1323-1328.
- [15] 王海清, 宋执环, 李平. 改进 PCA 及其在过程监测与故障诊断中的应用 [J]. 化工学报, 2001, 52(6): 471-475.
- WANG Haiqing, SONG Zhihuan, LI Ping. Improved PCA with application to process monitoring and fault diagnosis [J]. Journal of Chemical Industry and Engineering, 2001, 52(6): 471-475.

(编辑 苗凌 葛赵青)

(上接第 71 页)

- [9] BARTHLOTT W, NEINHUIS C. Purity of the sacred lotus, or escape from contamination in biological surfaces [J]. Planta, 1997, 202(1): 1-8.
- [10] DU ROURE O, SAEZ A, BUGUIN A, et al. Force mapping in epithelial cell migration [J]. Proceedings of the National Academy of Sciences of the United States of America, 2005, 102(7): 2390-2395.
- [11] EVANS B A, SHIELDS A R, CARROLL R L, et al. Magnetically actuated nanorod arrays as biomimetic cilia [J]. Nano Letters, 2007, 7(5): 1428-1434.
- [12] ROCA-CUSACHS P, RICO F, MARTINEZ E, et al. Stability of microfabricated high aspect ratio structures in poly (dimethylsiloxane) [J]. Langmuir, 2005, 21(12): 5542-5548.
- [13] GLASSMAKER N J, JAGOTA A, HUI C Y, et al. Design of biomimetic fibrillar interfaces: 1 Making contact [J]. Journal of The Royal Society Interface, 2004, 1(1): 23-33.
- [14] NISHINO T, MEGURO M, NAKAMAE K, et al. The lowest surface free energy based on-CF₃ alignment [J]. Langmuir, 1999, 15(13): 4321-4323.
- 201701022]
- 李锁斌, 陈天宁, 奚延辉, 等. 声子晶体板中低频完全禁带形成机理研究. 2016, 50(12): 51-57. [doi:10.7652/xjtuxb201612009]
- 王玉玺, 黄国策, 李伟, 等. 非均匀广义对角加载稳健波束形成算法. 2016, 50(8): 64-69. [doi:10.7652/xjtuxb201608011]
- 郭仁飞, 庄健, 于德弘. 用于三维形貌定量测量的调制电流式扫描离子电导显微镜. 2016, 50(7): 83-88. [doi:10.7652/xjtuxb201607013]
- 高美明, 洪军, 甄宜超. 机床多体系统空间刚度场约束下的加工误差预测. 2016, 50(6): 90-96. [doi:10.7652/xjtuxb201606014]
- 张瑶, 张鸿, 李梁, 等. 时钟数据恢复电路中的线性相位插值器. 2016, 50(2): 48-54. [doi:10.7652/xjtuxb201602009]
- 张东伟, 郭英, 齐子森, 等. 采用空间极化时频分布的跳频信号多参数联合估计算法. 2015, 49(8): 17-23. [doi:10.7652/xjtuxb201508004]
- 吴杰, 冯祖仁, 刘恒, 等. 水下目标多元声传感阵列网络定位方法. 2015, 49(4): 40-45. [doi:10.7652/xjtuxb201504007]
- 胡克用, 胥芳, 艾青林, 等. 适用于光伏多峰功率跟踪的改进型粒子群优化算法. 2015, 49(4): 140-148. [doi:10.7652/xjtuxb201504023]
- 李博, 冯松, 毛军红. 在线图像可视铁谱 LED 阵列反射光源设计与实现. 2014, 48(10): 29-34. [doi:10.7652/xjtuxb201410005]

[本刊相关文献链接]

龚茹雪, 赵宗亚, 黄洪恩, 等. 双面微电极阵列芯片力电特性的有限元仿真. 2017, 51(1): 141-146. [doi:10.7652/xjtuxb

(编辑 赵炜 杜秀杰)