

基于数据驱动的故障诊断技术研究现状及展望

张 妮¹ 车立志² 吴小进¹

(潍坊学院信息与控制工程学院 潍坊 261061)¹ (青岛出入境检验检疫局 青岛 266555)²

摘 要 对基于数据驱动的过程故障诊断方法进行了总结和划分,其中包含多元统计方法、机器学习方法、流形学习方法等。将各类基于数据驱动的故障诊断方法的原理、研究进展及其在工业过程中的应用进行了描述和分析,最后指出这一领域中需要进一步解决的问题以及近期的研究热点。

关键词 数据驱动方法,故障诊断,多元统计方法

中图分类号 TP277 文献标识码 A

Present Situation and Prospect of Data-driven Based Fault Diagnosis Technique

ZHANG Ni¹ CHE Li-zhi² WU Xiao-jin¹

(College of Information and Control Engineering, Weifang University, Weifang 261061, China)¹

(Huangdao Entry-Exit Inspection and Quarantine Bureau, Qingdao 266555, China)²

Abstract Fault diagnosis methods based on data-driven were summarized and divided, which include multivariate statistical methods, machine learning, manifold learning and so on. The principle, research progress and different methods application were analyzed and described. The problems needed to solve and recent research hotspots were addressed finally.

Keywords Data-driven method, Fault diagnosis, Multivariate statistical methods

1 引言

故障诊断技术对于保障现代化工业过程安全高效地运行具有极其重要的研究意义。随着生产智能化和分布式控制系统的广泛应用,大量数据被采集并存储,如何从观测数据中挖掘出有用资源,去掉冗余信息,进而指导生产实践是学术界和工业界亟需解决的问题。基于数据驱动的故障诊断方法从历史数据出发,不需要精确的数学模型,在故障诊断领域得到了广泛的应用^[1-4]。本文将基于数据驱动的故障诊断方法分为多元统计方法、机器学习方法、流形学习方法等,并对其进行描述和总结。

基于数据驱动的故障诊断方法通过对工业过程数据进行采集并加以分析,监督生产过程的运行状况,检测过程的故障信息,诊断故障原因,分离故障变量,从而使生产系统处于最佳运行状态。

2 基于数据驱动的故障诊断方法

2.1 多元统计方法

多元统计的故障诊断方法通过分析输入、输出数据来建立多元统计模型,将大量过程变量通过多元统计方法投影映射到含有少数隐变量的低维空间,进一步构造统计量来对工业过程进行监控,如果某一统计量超出控制限便可能发生故障。标准的多元统计方法在推导过程中做了如下假定:线性

过程、变量自身不存在时间序列相关性,过程参数不随时间变化,变量服从高斯正态分布等;然而实际工业过程均存在不同程度的偏离建模假设,容易造成监控出现漏报、误报问题。以下首先对多元统计分析方法在故障诊断领域的相关研究进行总结。

2.1.1 主元分析法

主元分析法(PCA)通过正交变换对采样矩阵或采样协方差矩阵进行分解,把相关的多维变量通过线性组合转化成不相关的主元变量。PCA 是目前应用最广的数据降维和特征提取方法之一。

PCA 是一种线性变换方法,无法提取数据的非线性特征。通过对原始数据进行非线性映射可以提取非线性主元,然而非线性映射不易获得。目前非线性特征提取方法主要有以下 3 类:主元曲线方法^[5]、自组织神经网络的非线性 PCA 方法^[6]、基于核函数的主元分析法(KPCA)。KPCA 算法不需要复杂的优化和迭代过程,得到了广泛的应用和推广^[7]。文献[8]针对非线性过程中较大的时延和复杂的相关性特性,提出高灵敏度局部 KPCA 算法来实现早期故障预测。Yan 将非线性数据分段线性化后分段运用 PCA 方法实现过程监控。近年来,Yu 提出了基于非线性高斯 BF 网络的故障诊断技术^[10],同时建立了基于非线性相关测量的非参数 PCA 模型^[11]。

如果数据采样速率较高,变量就不能满足时间上的相互

本文受国家自然科学基金(60974025),山东省自然科学基金(ZR2015PE025),潍坊学院博士科研基金(2015BS08)资助。

张 妮(1983—),女,博士,讲师,主要研究方向为故障检测与故障诊断、机器学习与模式识别,E-mail:117zhangni@163.com;车立志(1983—),男,硕士,主要研究方向为故障诊断技术研究,E-mail:chelizhi330@163.com;吴小进(1985—),男,博士,讲师,主要研究方向为图像处理,E-mail:wfuwxj@163.com。

独立,为消除过程动态影响,增加采样间隔是最简单的方法,然而其忽视了变量之间的动态关系。Ku 考虑了滞后阶次的影响,在增广矩阵的基础上建模,得到时间相关的动态 PCA (DPCA)^[12]。Yan 运用 DPCA 和动态独立元分析法(DICA)分别提取过程数据的动态特征^[13]。文献[8]运用贝叶斯信息准则获取过程变量的时延。

过程时变时,过程监控模型保持不变容易导致误报警。递归 KPCA 更新模型可以解决这一问题,然而随着新的采样点的增加,核矩阵规模变大,造成计算和存储的灾难。Kruger^[14]针对复杂非线性时变系统提出记忆存储滑动窗口 KPCA(MWKPCA),自适应地更新特征空间的数据均值和方差。文献[15]运用可变窗口自适应 KPCA 实现非稳态时变过程监控。在建模数据样本较少以及参数时变时,Jeng 采用递归和滑动窗口 PCA 更新 PCA 模型及统计量控制限,减少了算法的计算量^[16]。文献[17]提出自适应 KPCA 监控统计量,采用多变量指数滑动平均预测过程均值的变化,之后通过均值漂移估计联合提取的主元构造自适应监控统计量。经典的 PCA 监控模型是时不变的,且对提取的主元缺乏合理的物理解释,针对这类问题,文献[18]通过对 PCA 算法添加稀疏约束,运用自适应稀疏 PCA 方法来提取主元。

工业过程通常会发生工作点切换,从而过程存在多个稳定的运行工况。对多模态工业过程的监控方法主要有不同模态整体建模、多模型建模、自适应建模、鲁棒建模方法^[19]。高斯混合模型是近年来常用的一种多模型监测方法,文献[20]运用高斯混合模型结合最优主元实现多模态过程故障诊断, Yang 运用混合概率 PCA 实现多个模态的过程监控^[21]。

实际工业过程一般包含多个子系统以及操作区域,需要对其分块实施故障检测,一致 PCA、层次 PCA 和多块 PCA 是目前此类问题的故障诊断方法^[22-24]。

此外,对间歇过程的故障诊断主要集中于复合 PCA 方法^[25]。以上数据的提取和压缩都是同一尺度上实现的,文献[26]运用小波变换结合 PCA 方法实现多尺度过程信息提取,同时针对数据的非高斯分布问题,指出核密度估计是解决此类问题的主要方法。Yan 指出过程存在独立变量和相关变量,独立变量和相关变量的监控应分别展开,运用支持向量数据描述(SVDD)结合 KPCA 分别监控独立变量空间和相关变量空间^[27]。

检测到故障发生之后需要进一步确定故障发生的原因,工业过程主要采取以下方法解决过程故障诊断问题:基于多元统计的变量贡献率图方法、基于机器学习的方法、基于聚类的方法。变量贡献率图是目前采用最为普遍的多元统计故障诊断方法,该方法采用 T^2 和 Q 贡献率图确定故障变量^[28]。Alcala 总结了基于贡献率图的故障诊断方法,如全分解贡献、偏分解贡献、对角贡献、基于重构的贡献和基于角度的贡献等^[3]。实时数据与故障数据库的相似度匹配亦可以实现故障诊断。

2.1.2 规范变量分析

规范变量分析(CVA)也称为典型变量分析,可以获取过去向量集的最优线性变换,变换后的向量互不相关且与未来向量集的相关度最大,CVA 提取最佳预测能力的低维典型变量,并构造统计量 T^2 , T^2_0 , Q 来监控过程变化。CVA 在解决变量之间相关性的同时解决了变量自身的时序相关性^[29]。

Lee 运用 CVA 算法提取数据信息,并用其构造监控统计

量以分别对状态空间和噪声空间进行监控,同时提出有效的变量重构故障识别算法^[30];邓将核函数与 CVA 相结合,解决了变量之间的非线性相关问题,同时提出基于鲁棒 CVA 的故障诊断方法^[31]。批处理中的两维 DPCA 可能出现大量的滞后变量,从而导致贡献率图不符;Gao 通过 CVA 辨识得到状态空间模型,通过状态变量取代滞后变量得到了清晰的贡献率图^[32]。

2.1.3 独立元分析

近年来,独立主元分析(ICA)方法广泛应用于多变量非高斯过程监控中。ICA 是一种基于信号高阶统计特性的分析方法,可以提取相互独立的独立元变量^[33]。

Lee 将 ICA 引入到工业过程故障诊断中,采用核密度估计获得监控量的控制限;Yoo 运用多向 ICA 解决了批过程故障诊断问题^[34]。局部离群因子法(Lof)是最近发展的基于密度的离群点估计方法,文献[35]运用 Lof 估计监控统计量,用 ICA 结合 Lof 提高了故障诊断的鲁棒性。Stefatos 考虑了变量空间相关和时间序列相关,提出了 DICA 诊断故障的贡献率图法^[36]。Fan 基于动态增广矩阵和非线性贡献率提出核动态 ICA 故障检测方法,解决了非线性非高斯动态过程故障诊断^[37]。Su 提出基于 ICA-稀疏 Autoencoder 的非线性过程监控方法^[38]。文献[39]运用有监督的局部多层感知器结合 ICA 实现过程故障检测与诊断,提高了神经网络的分类性能。Deng 提出动态贝叶斯 ICA 算法来监控多模态非高斯动态过程^[40]。

2.1.4 费舍尔判别分析

与 PCA 方法相比,费舍尔判别分析(FDA)在故障的分类上更有优势,其基本思想是选取一组线性变换,在满足最小化故障类内离散度、最大化类间离散度准则的同时对建模数据进行排列,投影到低维空间,从而实现最优分离。

Yan 运用 FDA 结合自组织映射实现故障可视化识别^[41]。针对故障分类时需要标签数据从而使得计算耗时的问题,Ge 提出半监督 KFDD 方法来实现故障分类^[42]。文献[43]针对大型复杂系统的干扰噪声、过程的非高斯性和非线性问题,运用联合 FDA 方法解决此类问题。

2.1.5 偏最小二乘法

实际生产过程中,人们往往关心导致过程质量变化的故障,偏最小二乘法(PLS)利用质量变量来引导过程变量样本空间的分解,得到投影空间。投影空间反映了过程变量与质量变量相关的变化。

Kresta 最早将 PLS 方法用于工业过程监控^[44],文献[45]运用动态 PLS 进行在线过程监控,消除了变量自身的序列相关性^[45]。Zhao 建立 PLS 模型来处理间歇过程多阶段问题^[46]。针对多变量多尺度的动态过程, Lee 提出联合 PLS 和小波分解的多尺度 PLS 算法^[47]。针对不等长多相批过程, Zhao 采用统计分析和在线监控方法进行处理^[48]。Yu 针对过程的多模态和模态内的非线性问题,结合推理方法建立非线性核高斯混合模型,以实现故障检测和故障诊断^[49]。Yin 改进传统的 PLS 算法,将可测量变量分解成性能相关和不相关两部分,实现包含离群点和遗失点的过程故障诊断^[50-51]。Zhang 提出基于正交分解的改进 DKPLS 过程监控算法,建立测量值和质量指标之间的动态关系,同时建立基于知识挖掘的大尺度过程监控方法,基于综合子空间分解能够发现模态之间的相关性^[52-53]。

2.2 机器学习

基于机器学习的故障诊断方法以诊断正确率为学习目标,一般包含两部分:1)选取正常建模数据集进行训练;2)测试数据用于在线故障诊断分类。

2.2.1 神经网络

神经网络在故障诊断中的研究集中在以下几个方面:从模式识别的角度做分类器;与其它方法相结合;作为非线性组合器。面对一个问题时,首先要分析神经网络求解问题的性质,然后依据问题的特点确定网络模型,最后通过对网络进行训练和仿真来验证网络的性能是否满足要求。

Verron 采用条件高斯神经网络进行故障诊断,可以对新故障进行识别^[54]。文献^[55]依靠代价误差函数和停止准则训练得到最少神经元,使得网络的训练和测试过程较为快速,分类结果相对精确。针对过程的非高斯特性,Yu 提出基于自组织映射的故障诊断技术^[56]。Ge 运用线性动态系统这一典型的动态贝叶斯网络模型,有效地处理过程数据的动态性和不确定性^[57]。

神经网络故障诊断虽然有其独特的优越性,但也存在一些缺陷:训练样本获取困难;忽视了专家的经验知识;网络权值的表达方式不易理解。

2.2.2 支持向量机

支持向量机(SVM)是 Vapnik 提出的一种机器学习方法^[58],它基于结构风险最小化(SRM)原理,克服了过学习以及陷入局部最小值的问题。与神经网络相比,支持向量机更适用于小样本数据^[59]。

支持向量机针对两类问题而被提出,不能直接用于多值问题分类。针对这一问题,目前存在两种多值分类方法:1)将两类 SVM 扩展为多类分类 SVM;2)用多个两类分类 SVM 组成多类分类器。

Wu 联合模糊理论、小波理论以及鲁棒损失函数构造了新的的小波 SVM 故障分类器^[60]。Ge 运用基于支持向量数据描述(SVDD)的批过程监控,在数据不满足高斯分布时亦能有效地进行故障检测^[61]。针对系统的多模态和非线性结构,Khediri 结合核均值聚类 and SVDD 分离不同的非线性过程模态,并对每一模态使用不同的 SVDD 模型进行故障诊断的研究^[62]。Liu 提出基于小波 SVM 的故障诊断方法^[63];文献^[64]运用改进的二进制树 SVM 进行多故障分类,可以更为有效地获取每个 SVM 的特性,提高了诊断速率和诊断精度。Yin 总结了 SVM 故障诊断的研究及发展进展,并指出相比于人工神经网络和专家系统,SVM 在小样本泛化性能上表现出很大的优势^[65]。

2.3 流形学习

高维观测空间中的点由少数独立变量共同作用张成流形,如果能有效地展开观测空间卷曲的流形,即可对该数据集进行降维。

目前,流形学习方法在故障诊断领域应用较少,主要是运用流形学习算法进行故障特征提取以及信号降噪。Deng^[66]将 KPCA 结合局部结构分析更为有效地挖掘了数据的结构信息。为了挖掘高维数据中潜在的几何结构,Ge 运用非监督维数降低技术-非局部结构约束近邻保持嵌入,建立基于全局信息的双目标优化函数对过程数据进行特征信息提取^[67]。文献^[68]提出结构保持流形映射算法以实现故障诊断,可以有效地保存原始数据的全局和局部几何结构信息。

目前流形学习应用还处于初级阶段,其研究大部分仅局限于合成数据集和实验基准数据集,其面临的许多问题需要进一步研究并解决:高维原始空间和低维子流形空间非线性映射关系的近似、充分和分布均匀的采样数据、算法对噪声和参数变化都比较敏感等。

2.4 粗糙集

粗糙集理论在 20 世纪 80 年代提出,是一种处理模糊和不确定性问题的新的数学工具。粗糙集不需要数据集之外的先验信息便可以对数据进行特征提取。粗糙集用于故障诊断表现在以下几个方面:利用粗糙集进行故障特征提取;利用粗糙集简化故障特征,减小输入维数;与其它方法相结合用于故障诊断。

Zhou 采用粗糙集理论对统计特征向量进行离散化,从而获得关键特征和诊断规则^[69]。在故障诊断中,故障及其征兆不能一一对应,存在很多交叠的故障模式,Zhang 对粗糙集进行改进后结合支持向量多类分类器来解决此类问题^[70]。

2.5 信号处理

运用信号处理方法可以提取与故障相关的信号的时域或频域特征用于故障诊断。

谱分析法通过傅里叶变换等将复杂信号分解为有限或无限个频谱的分量之和,然后求各个分量的功率谱图,判断故障类型及故障源。文献^[69]将故障信号的沃尔什光谱的统计特性组成特征向量。谱分析是一种时域分析法且只适用于平稳信号的分析。而小波变换是一种非平稳信号的时频域分析法^[71],其故障诊断机理包括两个方面:通过对小波变换系数模极大值的检测来实现对信号奇异性的检测;利用小波变换对信号进行多尺度多分辨率分析以提取信号在不同尺度的特征,进而用于故障诊断。小波分解不能对信号的高频部分进行再分解,而小波包可以对信号在全部频带内进行正交分解。针对信号的非稳态、非线性以及时变性特点,将经验模式分解(EMD)、局部均值分解(LMD)、短时傅里叶变换以及 Winger-Ville 分布等方法用于故障诊断领域有效地解决了此类问题^[72-74]。

此外,信息融合技术能够将多元信息合成,从而得出更为精确的信息。多传感器的信息融合技术应用于故障诊断时,每个传感器基于检测统计量,对被诊断的对象做出是否有故障发生的推断;而融合中心则基于一定的准则进行融合处理,最终得出是否存在故障的决策,提高了故障诊断精度^[75-77]。

结束语 基于数据驱动的故障诊断技术发展至今已经建立了较为完整的理论体系,并且在工业生产中进行了初步的探索应用,其研究空间相对比较宽广。然而仍旧存在很多问题有待进一步研究和改进。

(1)高质量数据的获取问题。工业过程中的采集数据往往受到不同噪声的影响,使得故障检测和诊断的可靠性大大降低,因此如何得到高质量的数据(如对实际数据进行噪声和离群点去除)是该领域一个值得重视的问题。

(2)对故障的辨识和分离仍是研究的难点,故障诊断是消除故障的关键,相比于故障检测,故障诊断需要更多的知识和经验。纯数据方法缺乏模型信息,未能充分体现模型的拓扑结构,诊断故障原因比较困难。如何运用基于定性的知识和定量的数据实现故障诊断,如何结合先验知识对不可认知故障进行识别并具有学习能力,这些仍是需要解决的问题。

(3)多故障特别是并发故障研究是需要解决的问题。

目前针对单一故障诊断的研究较多,而在实际过程中不可避免地存在多故障同时发生或者一个故障发生的同时引发其它故障出现,单个故障模式特征无法应用到复合故障的建模以及分析中,此外针对并发故障诊断的研究才刚刚起步。

(4)实际生产过程中故障检测和诊断的通用性。故障检测及诊断方法都有其适用的条件:高斯分布、线性系统、稳态过程以及大延时等;但实际过程中不可能对本身的特性完全了解,因此需要能解决多种问题共存的过程监控以及诊断,即集成算法的研究。

(5)鲁棒性故障诊断的研究。基于数据的鲁棒故障诊断研究较少,故障诊断的鲁棒性问题研究仍是一个亟需解决的难题。

随着科技的不断发展和进步,基于数据的故障诊断方法将会不断完善并推广,该领域还有一些研究方向需要进一步探索。

(1)将现有算法与数学方法结合以提高过程故障检测的实时性、灵敏性和准确性;寻找新的基于数据的故障识别工具,进一步改善故障诊断的效果。

(2)多数故障检测方法是监督方法,由于缺乏先验知识导致故障诊断能力不高,如何利用先验知识建立有监督的监控策略,将故障检测和故障诊断作为整体进行解决是一个很有意义的课题。此外,将数据驱动的方法与基于模型的方法进一步融合补充亦是故障诊断领域的一个研究方向。

(3)数据的预处理和自适应算法的运用需要进一步的研究。故障诊断不仅需要选择建模方法,而且需要选择适合诊断模型的过程进行监控。在实际生产中,由于人为的调整、设备性能的变化以及过程变化导致稳定状态值发生变化,因此单一模式不再适用,自适应算法需要进一步的研究。

(4)故障预报即早期故障检测的研究对于实际生产过程的实时监控具有重要的应用价值。对于缓慢变化的故障,在它失控之前,过程变化的趋势已经非常明显,故障预报可以在故障发生的早期状态进行报警,从而显著提高监控性能。

(5)实际应用的迫切需求。理论研究和实践应用相互结合,将基于数据驱动的故障诊断算法用于服务工业过程是学术界和工业界协同发展的目标。

参 考 文 献

[1] VENKATASUBRAMANIAN V, RENGASWAMY R, KAVURI SURYAN, et al. A Review of Process Fault Detection and Diagnosis Part III: Process History based Methods[J]. Computers and Chemical Engineering, 2003, 27(3): 327-346.

[2] 刘强, 柴天佑, 秦泗钊, 等. 基于数据和知识的工业过程监视及故障诊断综述[J]. 控制与决策, 2010, 25(6): 801-807.

[3] ALCALA CARLOS F, JOE Q S. Analysis and Generalization of Fault Diagnosis Methods for Process Monitoring[J]. Journal of Process Control, 2011, 21(3): 322-330.

[4] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.

[5] HASTIE T, STUETZLE W. Principal Curves[J]. Journal of the American Statistical Association, 1989, 84(4): 502-516.

[6] KRAMER MARK A. Nonlinear Principal Component Analysis using Auto-associative Neural Networks[J]. Aiche Journal, 1991, 37(2): 233-243.

[7] 邓晓刚, 田学民. 一种基于 KPCA 的非线性故障诊断方法[J]. 山东大学学报(工学版), 2005, 35(3): 103-106.

[8] XU Y, LIU Y, ZHU Q X. Multivariate Time Delay Analysis based Local KPCA Fault Prognosis Approach for Nonlinear Processes[J]. Chinese Journal of Chemical Engineering, 2016, 24(10): 1413-1422.

[9] YAN A M, KERSCHEN G, DE BOE P, et al. Structural Damage Diagnosis Under Changing Environmental Conditions Part II: Local PCA for Nonlinear Analysis[J]. Mechanical System Signal Process, 2005, 19(4): 865-880.

[10] YU H Y, KHAN F, GARANIYA V. Nonlinear Gaussian Belief Network based Fault Diagnosis for Industrial Processes[J]. Journal of Process Control, 2015, 35(c): 178-120.

[11] YU H Y, KHAN F, GARANIYA V. A Sparse PCA for Nonlinear Fault Diagnosis and Robust Feature Discovery of Industrial Processes[J]. AIChE Journal, 2016, 62(5): 1494-1513.

[12] KU W F, STORER R, GEORGAKIS C. Disturbance Detection and Isolation by Dynamic Principal Component Analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1): 179-196.

[13] HUANG J, YAN X F. Dynamic Process Fault Detection and Diagnosis based on Dynamic Principal Component Analysis, Dynamic Independent Component Analysis and Bayesian inference[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 148: 115-127.

[14] LIU X Q, KRUGER U. Moving Window Kernel PCA for Adaptive Monitoring of Nonlinear Processes[J]. Chemometrics and Intelligent Laboratory Systems, 2009, 96(2): 132-143.

[15] KHEDIRI ISSAM B, LIMAM M, WEIHS C. Variable Window Adaptive Kernel Principal Component Analysis for Nonlinear Nonstationary Process Monitoring[J]. Computers & Industrial Engineering, 2011, 61(3): 437-446.

[16] JENG J C. Adaptive Process Monitoring using Efficient Recursive PCA and Moving Window PCA Algorithms[J]. Journal of the Taiwan Institute of Chemical Engineers, 2010, 41(4): 475-481.

[17] CHENG C Y, HSU C C, CHEN M C. Adaptive Kernel Principal Component Analysis (KPCA) for Monitoring Small Disturbances of Nonlinear Processes[J]. Industrial & Engineering Chemistry Research, 2010, 49(5): 2254-2262.

[18] LIU K L, FEI Z S, YUE B X, et al. Adaptive Sparse Principal Component Analysis for Enhanced Process Monitoring and Fault Isolation[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 146: 426-436.

[19] 谭帅, 常玉清, 王福利, 等. 基于 GMM 的多模态过程模式识别与过程监测[J]. 控制与决策, 2015, 30(1): 53-58.

[20] JIANG Q C, HUANG B, YAN X F. GMM and Optimal Principal Components-based Bayesian Method for Multimode Fault Diagnosis[J]. Computers & Chemical Engineering, 2016, 84: 338-349.

[21] YANG Y W, MA Y X, SONG B, et al. An Aligned Mixture Probabilistic Principal Component Analysis for Fault Detection of Multimode Chemical Processes[J]. Chinese Journal of Chemical Engineering, 2015, 23(8): 1357-1363.

[22] GE Z Q, SONG Z H. Two-level Multiblock Statistical Monitoring for Plant-wide Processes[J]. Korean Journal of Chemical Engineering, 2009, 26(6): 1467-1475.

[23] LIU K L, JIN X, FEI Z S, et al. Adaptive Partitioning PCA Model for Improving Fault Detection and Isolation[J]. Chinese Journal of Chemical Engineering, 2015, 23(6): 981-991.

- [24] WANG G Z, LIU J C, LI Y, et al. Fault Diagnosis of Chemical Processes based on Partitioning PCA and Variable Reasoning Strategy[J]. Chinese Journal of Chemical Engineering, 2016, 2016, 24(7): 869-880.
- [25] YIN S, DING S X, ABANDAN S A, et al. Data-driven Monitoring for Stochastic Systems and Its Application on Batch Process[J]. International Journal of Systems Science, 2013, 44(7): 1366-1376.
- [26] YANG Y H, LI X L, LIU X Z, et al. Wavelet Kernel Entropy Component Analysis with Application to Industrial Process Monitoring[J]. Neurocomputing, 2015, 147(1): 395-402.
- [27] HUANG J, YAN X F. Related and Independent Variable Fault Detection based on KPCA and SVDD[J]. Journal of Process Control, 2016, 39: 88-99.
- [28] ZHAO C H, GAO F R. Fault Subspace Selection Approach Combined With Analysis of Relative Changes for Reconstruction Modeling and Multifault Diagnosis[J]. IEEE Transactions on Control Systems Technology, 2015, 24(3): 928-939.
- [29] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-16.
- [30] LE C, CHOI S W, LEE I B. Variable Reconstruction and Sensor Fault Identification using Canonical Variate Analysis[J]. Journal of Process Control, 2006, 16(7): 747-761.
- [31] 邓晓刚, 田学民. 基于鲁棒规范变量分析的故障诊断方法[J]. 控制与决策, 2008, 23(4): 415-419.
- [32] YAO Y, GAO F R. Subspace Identification for Two-dimensional Dynamic Batch Process Statistical Monitoring[J]. Chemical Engineering Science, 2008, 63(13): 3411-3418.
- [33] 陈国金, 梁军, 钱积新. 独立元分析方法(ICA)及其在化工过程监控和故障诊断中的应用[J]. 化工学报, 2003, 54(10): 1474-1477.
- [34] YOO C K, LEE J M, VANROLLEGHEM P A, et al. On-line Monitoring of Batch Processes using Multiway Independent Component Analysis[J]. Chemometrics and Intelligent Laboratory Systems, 2004, 71(2): 151-163.
- [35] LEE J, KANG B, KANG S H. Integrating Independent Component Analysis and Local Outlier Factor for Plant-wide Process Monitoring[J]. Journal of Process Control, 2011, 21(7): 1011-1021.
- [36] GEORGE S, BEN H A. Dynamic Independent Component Analysis Approach for Fault Detection and Diagnosis[J]. Expert Systems with Applications, 2010, 37(12): 8606-8617.
- [37] FAN J C, WANG Y Q. Fault Detection and Diagnosis of Non-linear Non-Gaussian Dynamic Processes using Kernel Dynamic Independent Component Analysis[J]. Information Sciences, 2014, 259(3): 369-379.
- [38] LUO L, SU H Y, BAN L. Independent Component Analysis-based Sparse Autoencoder in the Application of Fault Diagnosis[J]. Intelligent Control & Automation, 2015, 52(1): 1378-1382.
- [39] RAD M A A, YAZDAN PANAHI M J. Designing Supervised Local Neural Network Classifiers based on EM Clustering for Fault Diagnosis of Tennessee Eastman Process[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 146: 149-157.
- [40] XU Y, DENG X G. Fault Detection of Multimode Non-Gaussian Dynamic Process using Dynamic Bayesian Independent Component Analysis[J]. Neurocomputing, 2016, 200(c): 70-79.
- [41] CHEN X Y, YAN X F. Fault Diagnosis in Chemical Process based on Self-organizing Map Integrated with Fisher Discriminant Analysis[J]. Chinese Journal of Chemical Engineering, 2013, 21(4): 382-387.
- [42] GE Z Q, ZHONG S Y, ZHANG Y W. Semi-supervised Kernel Learning for FDA Model and Its Application for Fault Classification in Industrial Processes[J]. IEEE Transactions on Industrial Informatics, 2016, 12(4): 1551-1563.
- [43] FENG J, WANG J, ZHANG H G, et al. Fault Diagnosis Method of Joint Fisher Discriminant Analysis based on the Local and Global Manifold Learning and Its Kernel Version[J]. IEEE Transactions on Automation Science and Engineering, 2016, 13(1): 122-133.
- [44] KRESTA K J V, MACGREGOR J F, MARLIN M T E. Multivariate Statistical Monitoring of Process Operating Performance[J]. Canadian Journal of Chemical Engineering, 1991, 69(1): 35-47.
- [45] TIINA K, MAURI S, SIRKKA-LIISA J J. An Online Application of Dynamic PLS to a Dearomatization Process[J]. Computers and Chemical Engineering, 2004, 28(12): 2611-2619.
- [46] ZHAO S J, ZHANG J, XU Y M. Performance Monitoring of Processes with Multiple Operating Modes Through Multiple PLS Models[J]. Journal of Process Control, 2006, 16(7): 763-772.
- [47] LEE H W, LEE M W, JONG M P. Multi-scale Extension of PLS Algorithm for Advanced on-line Process Monitoring[J]. Chemometrics and Intelligent Laboratory Systems, 2009, 98(2): 201-212.
- [48] ZHAO C H, MO S Y, GAO F R. Statistical Analysis and Online Monitoring for Handling Multiphase Batch Processes with Varying Durations[J]. Journal of Process Control, 2011, 21(6): 817-829.
- [49] YU J. A Nonlinear Kernel Gaussian Mixture Model based Inferential Monitoring Approach for Fault Detection and Diagnosis of Chemical Processes[J]. Chemical Engineering Science, 2012, 68(1): 506-519.
- [50] YIN S, WANG G, YANG X. Robust PLS Approach for KPI-related Prediction and Diagnosis against Outliers and Missing Data[J]. International Journal of Systems Science, 2014, 45(7): 1375-1382.
- [51] YIN S, ZHU X P, KAYNAK O. Improved PLS Focused on Key-Performance-Indicator-Related Fault Diagnosis[J]. IEEE Transactions on Industrial Electronics, 2015, 62(3): 1651-1658.
- [52] JIA Q L, ZHANG Y W. Quality-related Fault Detection Approach based on Dynamic Kernel Partial Least Squares[J]. Chemical Engineering Research and Design, 2016, 106: 242-252.
- [53] ZHANG Y W, FA Y P, YANG N. Fault Diagnosis of Multimode Processes based on Similarities[J]. IEEE Transactions on Industrial Electronics, 2016, 63(4): 2606-2614.
- [54] SYLVAIN V, TEODOR T, ABDESSAMAD K. Fault Diagnosis of Industrial Systems by Conditional Gaussian Network Including a Distance Rejection Criterion[J]. Engineering Applications of Artificial Intelligence, 2010, 23(7): 1229-1235.
- [55] BARAKAT M, DURAUX F, LEFEBVRE D, et al. Self Adaptive Growing Neural Network Classifier for Faults Detection and Diagnosis[J]. Neurocomputing, 2011, 74(18): 3865-3876.
- [56] YU H Y, KHAN F, GARANIYA V, et al. Self-Organizing Map based Fault Diagnosis Technique for Non-Gaussian Processes

- [J]. Industrial & Engineering Chemistry Research, 2014, 53(21):8831-8843.
- [57] GE Z Q, CHEN X R. Supervised Linear Dynamic System Model for Quality Related Fault Detection in Dynamic Processes[J]. Journal of Process Control, 2016, 44:224-235.
- [58] VAPNIK V, GOLOWICH S, SMOLA A. Support Vector Method for Function Approximation, Regression Estimation, and Signal Processing[J]. Advances in Neural Information Processing Systems, 1996, 9:281-287.
- [59] 马笑潇, 黄席樾, 柴毅. 基于 SVM 的二叉树多类分类算法及其在故障诊断中的应用[J]. 控制与决策, 2003, 18(3):272-284.
- [60] WU Q, LAW R. Complex System Fault Diagnosis based on a Fuzzy Robust Wavelet Support Vector Classifier and an Adaptive Gaussian Particle Swarm Optimization [J]. Information Sciences, 2010, 23(1):4514-4528.
- [61] GE Z Q, GAO F R, SONG Z H. Batch Process Monitoring based on Support Vector Data Description Method [J]. Journal of Process Control, 2011, 21(6):949-959.
- [62] KHEDIRI I B, WEIHS C, LIMAM M. Kernel k-means Clustering based Local Support Vector Domain Description Fault Detection of Multimodal Processes[J]. Expert Systems with Applications, 2012, 39(2):2166-2171.
- [63] LIU Z W, CAO H R, CHEN X F, et al. Multi-fault Classification based on Wavelet SVM with PSO Algorithm to Analyze Vibration Signals from Rolling Element Bearings[J]. Neurocomputing, 2013, 99(1):399-410.
- [64] WANG A N, SHA M, LIU L M, et al. A New Process Industry Fault Diagnosis Algorithm based on Ensemble Improved Binary-Tree SVM[J]. Chinese Journal of Electronics, 2015, 24(2):258-262.
- [65] YIN Z Y, HOU J N. Recent Advances on SVM based Fault Diagnosis and Process Monitoring in Complicated Industrial Processes[J]. Neurocomputing, 2016, 174(PB):643-650.
- [66] DENG X G, TIAN X M, CHEN S. Modified Kernel Principal Component Analysis based on Local Structure Analysis and Its Application to Nonlinear Process Fault Diagnosis[J]. Chemometrics and Intelligent Laboratory Systems, 2013, 127(16):195-209.
- [67] MIAO A M, GE Z Q, SONG Z H, et al. Nonlocal Structure Constrained Neighborhood Preserving Embedding Model and Its Application for Fault Detection[J]. Chemometrics and Intelligent Laboratory Systems, 2015, 142:184-196.
- [68] 王健, 冯健, 韩志艳. 基于流形学习的局部保持 PCA 算法在故障检测中的应用[J]. 控制与决策, 2013, 28(5):683-687.
- [69] XIANG X Q, ZHOU J Z, LI C S, et al. Fault Diagnosis based on Walsh Transform and Rough Sets[J]. Electric Power Systems Research, 2009, 23(4):1314-1326.
- [70] ZHANG X Y, ZHOU J Z, GUO J, et al. Vibrant Fault Diagnosis for Hydroelectric Generator Units with a New Combination of Rough Sets and Support Vector Machine[J]. Expert Systems with Applications, 2012, 39(3):2621-2628.
- [71] 叶昊, 王桂增, 方崇智. 小波变换在故障检测中的应用[J]. 自动化学报, 1997, 23(6):736-741.
- [72] LEI Y G, LIN J, HE Z J, et al. A Review on Empirical Mode Decomposition in Fault Diagnosis of Rotating Machinery [J]. Mechanical Systems and Signal Processing, 2013, 35(1/2):108-126.
- [73] TIAN Y, MA J, LU C, et al. Rolling Bearing Fault Diagnosis Under Variable Conditions Using LMD-SVD and Extreme Learning Machine[J]. Mechanism and Machine Theory, 2015, 90:175-186.
- [74] YAN R Q, GAO R X, CHEN X F. Wavelets for Fault Diagnosis of Rotary Machines: A Review with Applications[J]. Signal Processing, 2014, 96(5):1-15.
- [75] 王耀南, 李树涛. 多传感器信息融合及其应用综述[J]. 控制与决策, 2001, 16(5):518-522.
- [76] 朱大奇, 刘永安. 故障诊断的信息融合方法[J]. 控制与决策, 2007, 22(12):1321-1328.
- [77] ZHANG F Y, GE Z Q. Decision Fusion Systems for Fault Detection and Identification in Industrial Processes [J]. Journal of Process Control, 2015, 31:45-54.

(上接第 6 页)

- [91] 马厦飞, 连珪. “海马”号 4500 米级 ROV 系统研发历程[J]. 船舶与海洋工程, 2015, 31(1):9-12.
- [92] 高艳波, 李慧青. 深海高技术发展现状及趋势[J]. 海洋技术, 2010, 29(3):119-124.
- [93] DWYER T F. Telepsychiatry: psychiatric consultation by interactive television[J]. American Journal of Psychiatry, 1973, 130(8):865-869.
- [94] SINGH R, JEONG B, RENAMBOTET L. TeraVision: a distributed, scalable, high resolution graphics streaming system [C] // 2004 IEEE International Conference on Cluster Computing. IEEE, 2004:391-400.
- [95] JEONG B. Collaborative Visualization Architecture in Scalable Adaptive Graphics Environment [C] // IBM Visualization and Graphics Student Symposium, TJ Watson Research Hawthorne and Yorktown, 2007.
- [96] FRIESEN J A, TARMAN T D. Remote high-performance visualization and collaboration[J]. IEEE Computer Graphics and Applications, 2000, 20(4):45-49.
- [97] YHAKUR, BAX J S, HOLDSWORTH D W, et al. Design and performance evaluation of a remote catheter navigation system [J]. IEEE Transactions on Biomedical Engineering, 2009, 56(7):1901-1908.
- [98] 刘浩. 导管机器人系统的建立及其关键技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2010.
- [99] 李显凌. 用于微创介入手术的导管导向机器人研究[D]. 哈尔滨: 哈尔滨工业大学, 2009.
- [100] RAHMAN S M M, IKEURA R, NOBE M, et al. Control of a power assist robot for lifting objects based on human operator's perception of object weight [C] // The 18th IEEE International Symposium on Robot and Human Interactive Communication, 2009(RO-MAN 2009). IEEE, 2009:84-90.
- [101] WATANABE T, YOSHIKAWA T. Grasping optimization using a required external force set[J]. IEEE Transactions on Automation Science and Engineering, 2007, 4(1):52-66.
- [102] SHELTON J N, CHIU G T C, PIZLO Z. Exponentially segmented positioning of a single link mechanism: A control algorithm that satisfies Fitts' Law [C] // American Control Conference, 2007(ACC'07). IEEE, 2007:5983-5988.
- [103] 熊友军. 基于增强现实的遥操作关键技术研究[D]. 武汉: 华中科技大学, 2005.