

基于核正交流形角不相似度的非线性动态过程监测方法

卢春红[†], 文万志

(南通大学 计算机科学与技术学院, 江苏 南通 226019)

摘要: 针对过程的非线性和动态特性, 提出一种基于核正交流形角不相似度的监测方法. 利用两个流形子空间正交向量求取内积矩阵的奇异值, 构建基于核正交流形角的不相似度指标, 量化评估标准集和测试集的流形子空间的统计量关系. 首先, 在多流形投影方法的基础上, 利用非线性函数将原始过程数据投影到特征空间; 其次, 引入 Gram-Schmidt 方法正交化投影向量, 形成流形子空间的基向量; 再次, 对两个流形子空间的内积进行特征值分解, 获得核正交流形角, 构建不相似度监测模型, 该监测指标融合角度和距离度量, 能够更好地触发故障警报; 最后, 通过在 TE 过程上的仿真实验验证了所提出算法的优越性.

关键词: 非线性动态过程监测; 核正交流形投影; 正交向量; 不相似度指标; 故障检测

中图分类号: TP277

文献标志码: A

Kernel orthogonal manifold angle based dissimilarity for nonlinear dynamic process monitoring

LU Chun-hong[†], WEN Wan-zhi

(College of Computer Science and Technology, Nantong University, Nantong 226019, China)

Abstract: For process with nonlinear and dynamic features, a kernel orthogonal manifold angle based dissimilarity is developed to quantitatively evaluate the statistical relationship between the manifold subspaces of normal benchmark and test data sets. The kernel orthogonal manifold angle based dissimilarity index is derived from the singular values of the inner-product matrix calculated by the orthogonal vectors in the two manifold subspaces. Firstly, the historical process data is mapped into feature space by using the nonlinear function based on multi-manifold. Then, the projection vectors are orthogonalized by using Gram-Schmidt method, and base vectors of the manifold subspace are constructed. Furthermore, the kernel orthogonal manifold angle with singular value decomposition(SVD) of the inner-product of two manifold subspaces, and the dissimilarity monitoring model are got. Angle and distance measures are combined into the monitoring index to trigger fault alarm with better sensitivity. The simulation experiment on the TE process demonstrates the superiority of the proposed method.

Keywords: nonlinear dynamic process monitoring; kernel orthogonal manifold projection; orthogonal vector; dissimilarity index; fault detection

0 引言

随着工业过程系统的复杂化和规模化, 需要建立有效的监测模型以确保过程安全、提高产品质量和增加经济效益, 其中数据驱动的多元统计过程监测(MSPM)方法受到了学者的广泛关注^[1]. 主元分析(PCA)作为典型的MSPM方法, 将过程数据映射到低维特征子空间和残差子空间, 提取原始数据空间的主元信息, 之后在两个子空间分别构建反映数

据变化的统计指标实现在线监测^[2]. 为了处理非线性过程数据, Lee等^[3]提出了核主元分析(KPCA)方法, 利用核技巧有效提取了非线性主元, 避免了复杂的非线性变换函数的计算. 然而, 这些静态的模型忽略了过程的时变动态特性. 为此, Ku等^[4]提出了动态PCA(DPCA)处理这一问题, 通过引入时标变量, 扩展数据矩阵, 构建时变行为模型, 但是大量的变量增加了模型结构的复杂度.

收稿日期: 2017-04-11; 修回日期: 2017-08-05.

基金项目: 国家自然科学基金项目(61602267); 南通市科技应用项目(MS12016036); 江苏省高校自然科学基金项目(17KJB530008).

责任编辑: 姜斌.

作者简介: 卢春红(1982-), 女, 讲师, 博士, 从事数据驱动的过程监测的研究; 文万志(1982-), 男, 博士, 从事数据挖掘、过程建模的研究.

[†]通讯作者. E-mail: sharon0510@126.com

这些基于PCA的监测方法主要提取了高维数据中的方差信息,表征了原始数据空间的全局结构特征而忽略了局部结构特征. He等^[5]提出的局部保持投影(LPP)方法,因特征提取能够保持局部结构,被应用于间歇过程^[6]和非线性过程^[7],取得了较好的监测效果. 然而,由于未考虑过程数据的全局结构,LPP方法的监测性能受到了影响. 全局结构描述了原始数据的外部形状,而局部结构表征了数据的内在结构,因此,建模时需要同时考虑全局和局部结构信息. Zhang等^[8]提出了全局-局部结构分析的监测模型,取得了比PCA和LPP方法更优越的监测结果; Yu^[9]提出了基于局部和全局PCA的统计过程监测模型; Wang等^[10]利用平滑参数整合PCA和LPP的目标函数,提出局部保持PCA(LPPCA)算法进行故障检测. 这些方法都是以不同的方式叠加PCA与LPP的优化函数. Tong等^[11]基于流形学习技术的邻域嵌入思想,提出了多流形投影的降维算法,同时保留全局和局部结构,获得了较满意的监测性能. 随后,他们提出了基于基函数正交约束下的改进方法^[12]. 该方法没有利用过程模式分析动态时变过程,而这些模式可以改善监测性能^[13]. 基于PCA的模式匹配方法通过识别动态时序数据集之间的相似模式,实施过程监测^[14]. 然而,基于主元子空间的相似度角仅反映了数据全局的欧氏结构特征.

本文针对非线性动态过程,从模式匹配角度提出基于核正交流形角的不相似度监测方法,通过将近邻流形同时嵌入到非线性数据的全局和局部结构空间,获取表征原始空间全局和局部结构特征的低维核潜隐空间;为了更好地表征数据形态,利用正交约束计算核正交潜变量,再利用滑动窗计算每对基准和测试数据集的核潜隐向量之间的核正交流形角,结合核潜隐空间的距离比例因子,设计不相似度指标实现非线性动态过程的监测.

1 基于KPCA不相似度的过程监测

Johannesmeyer等^[15]通过比较基准和测试数据集的主元,计算不同主元之间的相似度因子识别出故障. 基于角度度量的不相似度方法,从模式匹配角度比较基准和测试数据集的潜隐子空间和提取隐变量之间的关系,刻画未知数据集和已知数据集之间的相似度进行过程监测.

给定包含 n 个变量和 m 个样本的两类数据集: $\mathbf{X}_M \in \mathbf{R}^{m \times m}$, $\mathbf{X}_B \in \mathbf{R}^{n \times m}$, \mathbf{X}_B 为正常基准集, \mathbf{X}_M 为测试集. 利用数据集 \mathbf{X}_B 和 \mathbf{X}_M 建立KPCA模型,分别获得两类核主元(KPC)集. 假设 $\varphi(\cdot)$ 为非线性映射函数,将原始数据变换到特征空间. KPCA可以通过求解下列特征值问题得到:

$$\lambda v = \frac{1}{n} \sum_{i=1}^n \varphi(x_i)^\top \varphi(x_i) v, \quad (1)$$

其中 $v = \sum_{i=1}^n \alpha_i \varphi(x_i)$, v 为特征值 λ 对应的特征向量, α_i 为每个特征样本的系数.

定义核矩阵 $\kappa_{ij} = \langle \varphi(x_i), \varphi(x_j) \rangle$,采用高斯核函数,均值中心化的核矩阵可以表示为

$$\bar{\kappa} = \kappa - E_n \kappa - \kappa E_n + E_n \kappa E_n, \quad (2)$$

其中矩阵 E_n 的元素为 $1/n$. 因此,式(1)可以进一步转化为

$$\lambda \alpha = \frac{1}{n} \bar{\kappa} \alpha. \quad (3)$$

假设当前测试样本为 x_q ,则其在特征空间内对应的得分向量可以表示为

$$t_q = \sum_{i=1}^n \alpha_i \bar{\kappa}_q. \quad (4)$$

根据累计方差贡献率达90%以上,选取 l 个核主元.

T^2 统计监测指标表示为

$$T_q^2 = t_q^\top \Lambda^{-1} t_q, \quad (5)$$

其中 Λ 为映射后训练样本的协方差矩阵. 根据KPCA模型,两类数据集 \mathbf{X}_B 和 \mathbf{X}_M 选取前 l 个主元,分别获得核主元集 \mathbf{P}^B 和 \mathbf{P}^M ,则每对核主元之间的几何角可以表示为

$$\cos \theta_i = \frac{(p_i^B)^\top (p_i^M)^\top}{\|p_i^B\|_2 \|p_i^M\|_2}, \quad (6)$$

其中 θ_i 为第 i 对主元 p_i^B 与 p_i^M 的夹角. 构建基于夹角的不相似度指标为

$$D_{\text{KPCA}}^\theta = \frac{1}{l} \sum_{i=1}^l (1 - \cos^2 \theta_i). \quad (7)$$

若每对核主元有相似的几何方向,则它们的幅值不同. 通过比较核主元空间的距离,反映主元空间的幅值变化,有

$$D_{\text{KPCA}}^{\text{dist}} = (T^M)^2 / (T^B)^2, \quad (8)$$

其中 $(T^B)^2$ 和 $(T^M)^2$ 分别是两个核主元空间 T^2 监测统计量的均值. 因此,结合核主元空间的距离因子,构建基于夹角的不相似度指标为

$$D_{\text{KPCA}} = D_{\text{KPCA}}^\theta \cdot D_{\text{KPCA}}^{\text{dist}}. \quad (9)$$

利用核密度估计(KDE)方法可以获取该监测指标的控制限.

2 基于核流形角的不相似度方法

2.1 核多流形投影

给定数据集 $\mathbf{X} = [x_1, x_2, \dots, x_n]^\top$,其中 $x_i \in \mathbf{R}^m$ 是 m 维的数据样本. 核多流形投影方法是寻找合适的投影矩阵 $\mathbf{P} = [p_1, p_2, \dots, p_d]$,使非线性数据投影至低维的特征子空间 $\mathbf{Y} = [y_1, y_2, \dots, y_n]^\top$, $y_i = \mathbf{p}^\top \varphi(x_i) \in \mathbf{R}^d$ ($d \ll m$, φ 为非线性映射函数), \mathbf{Y}

尽可能地表征 \mathbf{X} 的特征. 基于多流形投影的算法思路^[11], 分别给出局部结构保持和全局结构保持的优化目标函数为

$$\begin{aligned} J_L(\mathbf{w}) = & \min \frac{1}{2} \sum_{i,j=1}^n (\mathbf{w}^T \varphi(x_i) - \mathbf{w}^T \varphi(x_j))^2 G_{ij} = \\ & \min \mathbf{w}^T \varphi(\mathbf{X})(\mathbf{D} - \mathbf{G})\varphi(\mathbf{X})^T \mathbf{w} = \\ & \min \mathbf{w}^T \varphi(\mathbf{X})\mathbf{L}\varphi(\mathbf{X})^T \mathbf{w}, \end{aligned} \quad (10)$$

$$\begin{aligned} J_G(\mathbf{v}) = & \max \sum_{i=1}^n \mathbf{v}^T (\varphi(x_i) - \varphi(\bar{x}_i))(\varphi(x_i) - \varphi(\bar{x}_i))^T \mathbf{v} = \\ & \max \mathbf{v}^T (\varphi(\mathbf{X}) - \varphi(\bar{\mathbf{X}}_i))^T (\varphi(\mathbf{X}) - \varphi(\bar{\mathbf{X}}_i)) \mathbf{v} = \\ & \max \mathbf{v}^T \bar{\varphi}(\mathbf{X})^T \bar{\varphi}(\mathbf{X}) \mathbf{v}. \end{aligned} \quad (11)$$

其中: $\mathbf{L} = \mathbf{D} - \mathbf{G}$ 称为 Laplacian 矩阵, 对角阵 \mathbf{D} 的元素 $D_{ii} = \sum_j G_{ij}$, \mathbf{G} 为近邻样本之间的相似度矩阵 (σ 为调整 \mathbf{G} 的参数), $G_{ij} = \exp(-\|x_i - x_j\|^2)$; $\bar{\mathbf{X}}_i = [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n]^T$ 为局部均值矩阵, 定义 x_i 的近邻集 $N(x_i, x_j)$ 的均值向量为

$$\bar{x}_i = \frac{1}{n_i} \sum_{x_j \in N(x_i, x_j)} x_j, \quad i = 1, 2, \dots, n, \quad (12)$$

n_i 为近邻集中元素的个数.

令 $\mathbf{w} = \varphi(\mathbf{X})\alpha$, $\mathbf{v} = \bar{\varphi}(\mathbf{X})\alpha$, 则式 (10) 和 (11) 可以表示为

$$J_L(\alpha) = \min \alpha^T \kappa \mathbf{L} \kappa \alpha, \quad (13)$$

$$J_G(\alpha) = \max \alpha^T \bar{\kappa} \bar{\kappa} \alpha. \quad (14)$$

非线性多流形投影的目标函数为

$$J_{\text{KMMP}}(\alpha) = \min \frac{\alpha^T \kappa \mathbf{L} \kappa \alpha}{\alpha^T \bar{\kappa} \bar{\kappa} \alpha}. \quad (15)$$

最优系数向量 α 通过求解广义特征向量问题获得:

$$\kappa \mathbf{L} \kappa \alpha = \lambda \bar{\kappa} \bar{\kappa} \alpha. \quad (16)$$

则投影矩阵 \mathbf{P} 可以表示为

$$\mathbf{P} = [\varphi(\mathbf{X})\alpha_1, \varphi(\mathbf{X})\alpha_2, \dots, \varphi(\mathbf{X})\alpha_n]. \quad (17)$$

其列向量可以张成流形子空间^[16].

2.2 核正交流形投影 (KOMP)

由于 \mathbf{P} 的列向量非正交, 本文中利用核 Gram-Schmidt 正交化向量获得流形子空间的一系列单位正交向量, 这里正交向量的数量等于 \mathbf{P} 的列秩 d . 首先对向量进行正交化, 再进行正则化处理, 具体过程如下:

- 1) 令 $K = \varphi(\mathbf{X})^T \varphi(\mathbf{X})$, $\beta_1 = \alpha_1$;
- 2) 计算 $\beta_N = \alpha_n - \sum_{i=1}^{n-1} \frac{\alpha_n^T \kappa \beta_i}{\beta_i^T \kappa \beta_i} \beta_i$, $n = 2, \dots, d$;
- 3) 计算权重向量 $\gamma_i = \frac{\beta_i}{\sqrt{\beta_i^T \kappa \beta_i}}$, $i = 1, 2, \dots, d$;
- 4) 流形子空间的基向量 $\zeta_i = \varphi(\mathbf{X})\gamma_i$, $i = 1, 2,$

\dots, d .

测试样本 x_q , 则其在特征空间内对应的得分向量可以表示为

$$\mathbf{t}_q = \sum_{i=1}^d \zeta_i \kappa_q. \quad (18)$$

T^2 统计监测指标表示为

$$T_q^2 = \mathbf{t}_q^T \Lambda^{-1} \mathbf{t}_q. \quad (19)$$

核流形子空间可以由基向量张成:

$$S_1 = \text{span}[\varphi(\mathbf{X})\gamma_1, \varphi(\mathbf{X})\gamma_2, \dots, \varphi(\mathbf{X})\gamma_d]. \quad (20)$$

给定两个非线性数据集 $\varphi(\mathbf{X})$ 和 $\varphi(\mathbf{Y})$, 则它们对应的核流形子空间可以计算为

$$S_1 = \text{span}[\varphi(\mathbf{X})\gamma_1, \varphi(\mathbf{X})\gamma_2, \dots, \varphi(\mathbf{X})\gamma_d],$$

$$S_2 = \text{span}[\varphi(\mathbf{Y})\delta_1, \varphi(\mathbf{Y})\delta_2, \dots, \varphi(\mathbf{Y})\delta_d], \quad (21)$$

其中 γ_i 和 δ_i 分别是子空间 S_1 和 S_2 的权重向量.

令 \mathbf{M}_{ij} 为两个子空间基向量的内积, 有

$$\mathbf{M}_{ij} = \gamma_i^T \varphi(\mathbf{X})^T \varphi(\mathbf{Y}) \delta_j. \quad (22)$$

令 $\mathbf{A} = [\gamma_1, \gamma_2, \dots, \gamma_d]$, $\mathbf{B} = [\delta_1, \delta_2, \dots, \delta_d]$, 核矩阵 $\tilde{\kappa} = \varphi(\mathbf{X})^T \varphi(\mathbf{X})$, 则内积矩阵表示为

$$\mathbf{M} = \mathbf{A}^T \tilde{\kappa} \mathbf{B}. \quad (23)$$

将 \mathbf{M} 进行奇异值分解 (SVD), 得到

$$\mathbf{M} = \mathbf{U} \Lambda \mathbf{V}^T, \quad (24)$$

其中 $\Lambda = \text{diag}(\eta_1, \eta_2, \dots, \eta_d)$, $\eta_1, \eta_2, \dots, \eta_d$ 是按照降序排列的奇异值. 因此, 有

$$\cos \theta_i = \eta_i, \quad (25)$$

θ_i 为核流形角, 其表征两个流形子空间的相似度.

两个流形子空间的角度不相似度指标为

$$D_{\text{KOMA}}^\theta = \frac{1}{d} \sum_{i=1}^d (1 - \cos^2 \theta_i). \quad (26)$$

2.3 基于核正交流形角不相似度的过程监测

两个核流形子空间的角度可以度量基准集和测试集之间的不相似度. 给定基准集 $\mathbf{X}_b \in \mathbf{R}^{n \times w}$ 和测试集 $\mathbf{X}_q \in \mathbf{R}^{n \times r}$, 两类数据集都包含 n 个变量, 整个测试集含有 r 个样本, 动态过程监测下的测试集按照滑动窗宽 w 向前滑动. 首先, 利用基准集构建核正交流形投影 (KOMP) 模型, 获得核流形投影子空间; 同时, 测试集上利用滑动窗获得一系列子集的流形子空间 $S_q^{(1)}, S_q^{(2)}, \dots, S_q^{(r)}$. 然后, 结合子空间的距离度量, 构建基于核正交流形角 (KOMA) 不相似度的监测指标 D_{KOMA} , 用于评估基准和测试流形子空间的不相似度, 有

$$D_{\text{KOMA}}(i) = \frac{T_m^2(i)}{T_q^2} \cdot D_{\text{KOMA}}^\lambda, \quad (27)$$

其中*i*为测试集的第*i*个滑动窗. 该指标值越大, 说明测试集潜在的模式与基准集的差异越显著, 代表该测试操作越接近于异常操作.

通过计算, 获得一系列滑动窗下的不相似度指标值, 再利用KDE方法估计出异常操作检测的控制限. 如果不相似度监测指标超过控制限, 则触发故障警报; 否则, 认为是正常操作.

2.4 TE过程仿真研究

TE过程是模拟现实工业过程中的正常数据和21种不同故障数据的仿真平台, 已在过程监测中得到了大量的应用, 详细的介绍可参见文献[17], 文中选取了33个过程连续测量变量, 仿真数据集源于 <http://web.mit.edu/braatzgroup/links.html>.

离线建模阶段, 利用正常工况下的300个样本作为基准集建立KPCA不相似度和核正交流形角(KOMA)不相似度的过程监测模型, 表1描述了测试场景中所涉及到的6种故障. 3种混有不同故障类型的过程场景用作对比这两种监测方法的结果, 场景如表2所示, 每种场景中均包含了正常和不同的故障操作.

表1 故障列表

故障	描述
F_1	进料A损失阶跃
F_2	冷凝器冷却水入口温度阶跃
F_3	冷凝器冷却水入口温度随机变化
F_4	A/C进料比阶跃
F_5	进料C入口压力损失阶跃
F_6	冷凝器冷却水阀粘住

表2 TE过程的3种测试场景


场景	测试场景
场景1	正常操作: 1 st ~ 300 th 样本 F_1 : 301 st ~ 800 th 样本
场景2	正常操作: 1 st ~ 200 th 样本 F_2 : 201 st ~ 400 th 样本 正常操作: 401 st ~ 600 th 样本 F_3 : 601 st ~ 800 th 样本
场景3	正常操作: 1 st ~ 100 th 样本 F_4 : 101 st ~ 300 th 样本 正常操作: 301 st ~ 400 th 样本 F_5 : 401 st ~ 500 th 样本 正常操作: 501 st ~ 600 th 样本 F_6 : 601 st ~ 800 th 样本

文中, 滑动窗宽设为25, 控制限的置信度设为95%, 近邻阶数*k*为10, 近邻调节参数 σ 设为100, 高斯核函数的核宽可通过交叉验证确定. 故障检测率和误报率两个度量指标用于表征所提出的KOMA不相似度方法和KPCA不相似度方法在TE过程中的监测结果, 平均值如表3所示.


表3 TE过程3种场景的故障检测率和误报率 %

场景编号	故障检测率		误报率	
	KPCA	KOMA	KPCA	KOMA
1	92.7	96.2	7.6	5.0
2	89.2	93.6	10.1	7.5
3	86.3	90.5	12.2	9.4

第1种测试场景下两种不相似度监测统计量的时序图分别如图1(a)和图1(b)所示. 与KPCA不相似度方法相比, 所提KOMA方法增加了3.5%的检测率, 并且误报率也稍低一些.




(a) KPCA不相似度方法




(b) KOMA不相似度方法

图1 第1种场景下的过程监测结果

第2种场景下两种方法的监测结果分别如图2(a)和图2(b)所示. 可以发现, KOMA不相似度监测



(a) KPCA不相似度方法



(b) KOMA不相似度方法

图2 第2种场景下的过程监测结果

方法产生了较高的故障检测率,达到了93.6%,而KPCA不相似度监测方法获得了89.2%的检测率.同时,KOMA方法得到的7.5%的误报率,低于KPCA方法的10.1%误报率.从时序图上可观测到,KPCA不相似度方法在故障发生时监测时延较大,主要由于该方法未及时抓取过程的时序动态变化操作.而且,KPCA方法主要提取了全局结构特征,获取了过程中较大的变化,忽视了局部结构特征,使得投影子空间不能充分反映过程特性.所提出的KOMA方法获得了较小的时延监测结果,能够敏感地触发故障警报.

第3种测试场景包含了3类故障,两种监测统计量的趋势图如图3(a)和图3(b)所示.可观测到KPCA不相似度方法获得了86.3%的故障监测率,低于KOMA方法,较多的故障样本未被检测出,且由于较多的正常样本被误报,获得了较高的误报率.KOMA不相似度方法由于嵌入近邻流形到全局和局部结构中,较好地保持了数据本身的结构形态,构建的不相似度指标能够及时检测过程的动态变化情况,在该场景中获得了较低的误报率,并能够有效地检测出过程故障.

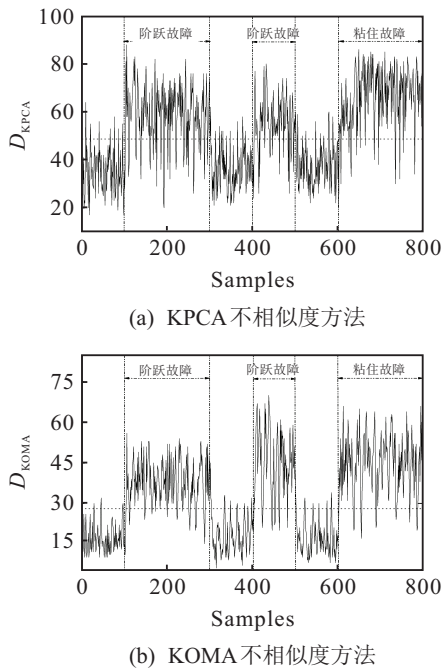


图3 第3种场景下的过程监测结果

为了进一步验证KOMA不相似度方法的可行性,与传统的PCA方法、文献[10]中的LPPCA方法、KPCA不相似度方法进行比较分析,这4种方法对所列6种故障的监测结果列于表4.前两种方法利用 T^2 和SPE的合成统计量^[18]进行监测,仿真中采集1000个正常样本作为训练集,6种故障各采集1000个样本作为测试集,其中前400个样本为正常数据,后600个样本为故障数据.

表4 故障列表

故障	PCA	LPPCA	KPCA	KOMA
F_1	88.9	93.7	92.2	96.0
F_2	82.4	90.6	91.4	94.3
F_3	86.5	89.8	92.0	95.3
F_4	83.1	91.2	90.4	93.8
F_5	88.4	92.8	91.1	93.2
F_6	86.0	90.5	89.3	93.6
Average	85.9	91.4	91.1	94.4

从平均检测率来看:相比于PCA方法,LPPCA和KPCA不相似度方法均取得了更好的监测效果,主要是因为LPPCA方法利用了全局和局部过程信息,而KPCA不相似度方法抓取了过程模式之间的非线性关系;KOMA不相似度方法检测出最多的故障,故障检测率稍优于LPPCA和KPCA不相似度方法;KOMA方法提取了更多的数据结构信息,更好地保持了过程数据的流形特征,改善了监测性能.

3 结论

本文针对KPCA不相似度方法中未考虑过程数据的局部结构特征,在多流形投影方法的基础上,提出了一种基于核正交流形角不相似度的非线性动态过程监测方法.利用Gram-Schmidt方法正交化投影向量,保持了数据本质形态,并对两个流形子空间内积进行SVD分解,构建两个子空间的不相似度指标.在TE过程上的仿真研究充分说明了,KOMA不相似度监测方法优于KPCA不相似度方法.

参考文献(References)

- [1] 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.
- [2] 童楚东, 史旭华, 蓝艇. 正交信号校正的自回归模型及其在动态过程监测中的应用[J]. 控制与决策, 2016, 31(8): 1505-1508. (Tong C D, Shi X H, Lan T. Orthogonal signal correction based auto-regression model with application to dynamic process monitoring[J]. Control and Decision, 2016, 31(8): 1505-1508.)
- [3] Lee J M, Yoo C K, Choi S W, et al. Nonlinear process monitoring using kernel principal component analysis[J]. Chemical Engineering Science, 2004, 59(1): 223-234.
- [4] Ku W, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1): 179-196.
- [5] He X F, Niyogi P. Locality preserving projection[C]. Proc of 17th Annual Conf on Neural Information Processing Systems. Cambridge: MIT Press, 2003: 585-591.
- [6] Hu K, Yuan J. Multivariate statistical process control based on multiway locality preserving projections[J]. J of Process Control, 2008, 18(7): 797-807.

- [7] Shao J D, Rong G, Lee J M. Generalized orthogonal locality preserving projections for nonlinear fault detection and diagnosis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2009, 96(1): 75-83.
- [8] Zhang M G, Ge Z, Song Z, et al. Global-local structure analysis model and its application for fault detection and identification[J]. *Industrial & Engineering Chemistry Research*, 2011, 50(11): 6837-6848.
- [9] Yu J. Local and global principal component analysis for process monitoring[J]. *J of Process Control*, 2012, 22(7): 1358-1373.
- [10] 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.
(Wang J, Feng J, Han Z Y. Locally preserving PCA method based on manifold learning and its application in fault detection[J]. *Control and Decision*, 2013, 28(5): 683-687.)
- [11] Tong C, Yan X. Statistical process monitoring based on a multi-manifold projection algorithm[J]. *Chemometrics and Intelligent Laboratory Systems*, 2014, 130: 20-28.
- [12] Tong C D, Shi X H, Lan T. Statistical process monitoring based on orthogonal multi-manifold projections and a novel variable contribution analysis[J]. *ISA Trans*, 2016, 65: 407-417.
- [13] Singhal A, Seborg D E. Pattern matching in historical batch data using PCA[J]. *IEEE Control Systems*, 2002, 22(5): 53-63.
- [14] Ge Z, Song Z. Process monitoring based on independent analysis-principal component analysis(ICA-PCA) and similarity factors[J]. *Industrial & Engineering Chemistry Research*, 2007, 46(7): 2054-2063.
- [15] Johannesmeyer M C, Singhal A, Seborg D E. Pattern matching in historical data[J]. *AIChE J*, 2002, 48: 2022-2038.
- [16] Wang R P, Shan S, Chen X, et al. Manifold- manifold distance and its application to face recognition with image sets[J]. *IEEE Trans on Image Processing*, 2012, 21(10): 4466-4479.
- [17] Downs J J, Vogel E F. A plant-wide industrial process control problem[J]. *Computers & Chemical Engineering*, 1993, 17: 245-255.
- [18] Yue H H, Qin S J. Reconstruction-based fault identification using a combined index[J]. *Industrial & Engineering Chemistry Research*, 2001, 40(20): 4403-4414.

(责任编辑: 齐 霖)

第31届中国控制与决策会议(2019CCDC)征文通知

第31届中国控制与决策会议(2019CCDC)将于2019年6月3日~5日在中国南昌举行。会议由东北大学和中国自动化学会信息物理系统控制与决策专业委员会主办,华东交通大学承办。

第31届中国控制与决策会议论文集中的英文论文将进入IEEE XploreData Base,被EI检索。

第31届中国控制与决策会议将涉及理论与应用两方面,主要涵盖系统、控制与决策相关课题。征文范围如下:

控制理论与工程: 智能控制、计算与优化;故障诊断与自愈控制;模式识别与深度学习;信息物理系统的分析与控制;信号处理与信息融合;最优控制与最优化;复杂系统与复杂网络;线性系统理论与应用;系统辨识与参数估计;非线性系统理论与应用;混杂系统与离散事件系统;空间飞行器控制;随机系统;分布参数系统控制;网络集群与网络化控制;多智能体系统与协同控制;传感器网络与物联网;鲁棒控制;过程控制与预测控制;专家系统、模糊系统与模糊控制;运动控制;控制工程教育;数据驱动控制;纳米自动化与装配;自适应控制与学习控制;变结构控制;先进传感技术与仪器仪表;控制系统信息安全;生物系统的建模、控制与仿真;无人系统自动控制;微机电系统。

决策理论与系统: 决策理论与方法;生产计划与调度;管控一体化;管理信息系统与企业信息化;供应链与物流的管理;知识工程与数据挖掘;大数据与知识自动化;经济控制论与社会经济系统;对策论与社会网络;智能制造与工业智能;电动车辆与智能交通;新能源管理与控制系统节能技术;智能电网。

机器人系统: 机器人控制;移动机器人;微机器人与微操作;工业机器人;图像处理与机器人视觉;多足机器人系统;搜寻、援救与野外机器人;机器人传感与数据融合;医用机器人与生物机器人;空间与水下机器人;遥控机器人。

会议程序委员会热情欢迎业内专家以会议为平台,针对国际控制与决策领域前沿热点方向、科研学者普遍关心的话题,组织“邀请分会”、“特别专题”、“专家论坛”、“高峰论坛”等学术研讨活动,会议将提供优质的平台服务。拟组织者请在2018年10月31日前与大会秘书处(secretary_ccdc@ise.neu.edu.cn)联系并提交组织建议书。

会议投稿者请于2018年10月31日前提交全文。请登录<http://www.ccdc.neu.edu.cn>网址了解具体的相关事宜并投稿。同时也可以通过E-mail向大会秘书处(secretary_ccdc@ise.neu.edu.cn)咨询。

中国控制与决策会议秘书处