

控制与决策

Control and Decision

基于分层分块DLPPCA-SVM的复杂工业过程监测与故障诊断方法

姚远, 佟佳蓉, 高军, 王姝, 宋圣军

引用本文:

姚远, 佟佳蓉, 高军, 王姝, 宋圣军. 基于分层分块DLPPCA-SVM的复杂工业过程监测与故障诊断方法[J]. *控制与决策*, 2022, 37(5): 1402-1408.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1614>

您可能感兴趣的其他文章

Articles you may be interested in

[基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808-814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999-3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

[标签Petri网的路径信息在故障诊断中的应用](#)

Application of path information of labeled Petri nets in fault diagnosis

控制与决策. 2021, 36(2): 325-334 <https://doi.org/10.13195/j.kzyjc.2019.0698>

[基于批次图像化的卷积自编码故障监测方法](#)

Fault detection of batch image-based convolutional autoencoder

控制与决策. 2021, 36(6): 1361-1367 <https://doi.org/10.13195/j.kzyjc.2019.1342>

[基于自适应混合核典型变量分析的工业过程质量相关故障检测](#)

Quality-related fault detection for industrial processes based on adaptive mixed kernel canonical variable analysis

控制与决策. 2021, 36(4): 801-807 <https://doi.org/10.13195/j.kzyjc.2020.0690>

基于分层分块 DLPPCA-SVM 的复杂工业过程 监测与故障诊断方法

姚远^{1†}, 佟佳蓉², 高军³, 王姝², 宋圣军⁴

(1. 国网辽宁省电力有限公司 电力科学研究院, 沈阳 110006; 2. 东北大学 信息科学与工程学院, 沈阳 110004; 3. 东软集团股份有限公司, 沈阳 110179; 4. 国网辽宁省电力有限公司, 沈阳 110006)

摘要: 针对工业过程动态性及非线性强等特点, 提出一种基于动态局部保持主成分分析的过程监测方法. 该方法通过构造扩展矩阵来解决动态过程中各采样点间相关性强的问题, 并将局部保持投影(LPP)与主成分分析(PCA)相结合从而实现提取流形结构的最大方差信息. 在此基础上, 针对复杂工业过程变量复杂多变、呈不同特性的特点, 提出基于分层分块 DLPPCA-SVM(dynamic locality preserving principal component analysis-support vector machine, DLPPCA-SVM)的过程监测及故障诊断方法, 该方法针对不同特性的子块分别采用 DLPPCA 和 PCA 进行建模, 并利用支持向量机进行故障诊断. 将该方法用于田纳西-伊斯曼(TE)化工过程和发电机组的在线监测和故障诊断, 仿真结果验证了所提出方法的有效性.

关键词: 发电机组; 流形学习; DLPPCA; 在线监测; 故障诊断; 支持向量机

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1614

开放科学(资源服务)标识码(OSID):



引用格式: 姚远, 佟佳蓉, 高军, 等. 基于分层分块 DLPPCA-SVM 的复杂工业过程监测与故障诊断方法[J]. 控制与决策, 2022, 37(5): 1402-1408.

Monitoring and fault diagnosis method of complex industrial process based on DLPPCA-SVM

YAO Yuan^{1†}, TONG Jia-rong², GAO Jun³, WANG Shu², SONG Sheng-jun⁴

(1. State Grid Liaoning Electric Power Research Institute, Shenyang 110006, China; 2. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 3. Neusoft Corporation, Shenyang 110179, China; 4. State Grid Liaoning Electric Power, Shenyang 110006, China)

Abstract: This paper proposes a process monitoring method based on dynamic local keeping principal component analysis to solve the problem of strong correlation between sampling points in a dynamic process by constructing extended matrixes. Locality preserving projections(LPP) and principal component analysis(PCA) are combined to maximize the overall variance while keeping the local structure unchanged. On this basis, a process monitoring and fault diagnosis method based on the layered and block DLPPCA-SVM (dynamic locality preserving principal component analysis-support vector machine) is proposed for complex industrial processes with different characteristics. DLPPCA and PCA are used to model the sub blocks with different characteristics, and the support vector machine is used for fault diagnosis. The method is applied to the on-line monitoring and fault diagnosis of the TE process and generator set. The simulation results verify the effectiveness of the proposed method.

Keywords: generator set; manifold learning; DLPPCA; online monitoring; fault diagnosis; support vector machine

0 引言

对工业过程进行准确的故障监测与诊断在实际生产中具有重要的意义. 基于数据驱动的方法^[1]适用于难以确立精确数学模型的复杂工业过程. 主成分分析法(principal component analysis, PCA)^[2-3]是一

种典型的数据驱动方法, 但对非线性数据表现较差, 不能保持非线性数据间的局部特征. 局部保持投影(locality preserving projections, LPP)^[4-5]是一种流形学习方法(manifold learning)^[6-7], 可从高维采样数据中恢复低维流形结构, 并较好地保持数据局部结构, 对

收稿日期: 2020-11-22; 录用日期: 2021-02-10.

基金项目: 国家重点研发计划项目(2017YFB0902100).

[†]通讯作者. E-mail: yaoyuan_shenyang@163.com.

非线性数据有着更佳的效果. 但LPP可能导致样本空间中距离较远的样本点在投影后发生重叠. 目前, 已有文献将LPP与PCA结合使用^[8-9], 但以上方法均基于过程变量独立且满足高斯分布的假设前提, 而实际复杂工业过程中的过程变量常具有自相关、互相关等特点. 因此, 本文提出一种基于动态局部保持主成分分析法(dynamic locality preserving principal component analysis, DLPPCA)的过程监测方法. 该方法不但通过构造扩展矩阵来解决动态过程中各采样点间相关性强的问题, 而且将LPP与PCA相结合, 先通过LPP提取出数据的流形信息, 再使用PCA实现相关性去除, 从而提取最大方差信息.

分层分块思想也是近年来逐渐得到推广和使用的方法^[10-11]: 将一个完整生产过程划分为若干个有意义的块, 再对每个块单独建模. 但由于对每个块都采用相同的建模方法, 而实际上各个工序存在差异, 导致每个子块变量之间的相关关系、数据分布等都不相同, 所适合的建模方法未必相同.

在前人的研究基础上, 本文对分层分块方法进行了改进, 结合支持向量机^[12-13]提出一种基于分块DLPPCA-SVM的故障诊断方法. 其基本思想是: 利用分块思想, 在离线建模的过程中根据各个子系统的特性将系统划分为不同的子块^[14], 线性特性强的子块采用PCA进行过程监测, 非线性和动态特性强的子块采用DLPPCA方法进行过程监测. 再将各子块特征提取后的得分矩阵结合在一起作为顶层监控数据, 对顶层监控数据采用PCA或DLPPCA的方法进行统计量监测, 在监测到统计量超出控制限后, 通过SVM分类器进行故障诊断, 得到具体的故障原因. 本文使用田纳西-伊斯曼(Tennessee-Eastman, TE)^[15]化工过程故障数据和电厂实际生产数据分别进行仿真实验, 以表明本文所提出算法的有效性和正确性.

1 DLPPCA算法

LPP算法作为一种流形学习方法可以从高维采样数据中恢复低维流形结构, 并较好地保持数据局部结构, 对非线性数据也有更佳的效果, 但可能会导致样本空间中距离较远的样本点在投影后发生重叠. 而PCA算法虽然不能保持非线性数据间的局部特征, 但可以实现去除相关性, 提取最大方差信息, 将两者相结合可以实现互补. 而且实际生产过程往往具有明显的动态性, 即当前采样点的数据往往与相邻的过去采样点数据密切相关. 因此, 本文结合LPP与PCA算法并进行动态拓展, 提出DLPPCA算法: 首先通过构造扩展矩阵, 将相邻的采样点关联起来, 从而

解决各采样点间相关性强的问题; 然后将LPP与PCA相结合, 从而实现提取流形结构的最大方差信息.

先对样本集进行标准化处理, 得到 $X = [x_1, x_2, \dots, x_n] \in R^{m \times n}$; 再确定动态步数 l , 此处动态步数的取值根据经验选取, 不宜过大, 一般取 $l = 1, 2$, 在本文中取 $l = 1$. 从而构造扩展矩阵 $X^* \in R^{m(l+1) \times (n-l)}$ 如下:

$$X^* = [X(1), X(2), \dots, X(n-l)], \quad (1)$$

其中 $X(i)$ 为将采样点向后平移 i 时刻后的数据矩阵, 即

$$X(i) = [x_{i-l}^T, x_{i-l+1}^T, \dots, x_i^T]^T. \quad (2)$$

由式(1)和(2), 得到动态扩展矩阵 X^* 且 $X^* \in R^{m(l+1) \times (n-l)}$. 求解下式的广义特征值:

$$X^* L X^{*T} \alpha = \lambda X^* D X^{*T} \alpha, \quad (3)$$

取最小的 k 个特征值构成投影矩阵 A , 从而得到投影后的低维矩阵 $Y^* = A^T X^*$. 求解 Y^* 的协方差矩阵

$$\Sigma = \text{cov}(Y^*) = \frac{Y^* (Y^*)^T}{n-l-1}, \quad (4)$$

对求得的协方差矩阵进行特征值分解, 有

$$\Sigma p_i = \lambda^* p_i. \quad (5)$$

取最大的 d 个特征值所对应的特征向量得到矩阵 P . 通过

$$Y = P^T Y^*, \quad (6)$$

得到经过DLPPCA算法特征提取后的低维矩阵 Y , 该矩阵又称得分矩阵.

对于新检测样本, 首先对其进行标准化, 再应用DLPPCA算法对得到的得分矩阵 Y 求解统计量.

T^2 统计量为

$$T^2 = y^{*T} P A^{-1} P^T y^*. \quad (7)$$

其中: $y^{*(k \times 1)} \in Y^*$, A 是由最大的 d 个 λ^* 所组成的对角矩阵.

T^2 统计量服从F分布, 因此 T^2 所对应的控制限为

$$T_\alpha^2 = \frac{k((n-l)^2 - 1)}{(n-l)(n-k)} F_\alpha(k, n-l-k). \quad (8)$$

SPE统计量为

$$\text{SPE} = (y^*)^T (I - P P^T) y^*. \quad (9)$$

SPE所对应的控制限为

$$\text{SPE}_\alpha = \theta_1 \left[\frac{c_\alpha h_0 \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}}. \quad (10)$$

其中

$$\theta_r = \sum_{j=k+1}^m \lambda_j^*, \quad r = 1, 2, 3; \quad (11)$$

$$h_0 = 1 - \frac{2\theta_1\theta_3}{3\theta_2^2}; \quad (12)$$

$1 - \alpha$ 代表置信度,本文取0.99.

2 基于分层分块DLPPCA-SVM的过程监测和故障诊断方法

对大型复杂系统整体进行过程监测时,如果各子系统间相关关系匹配异常,则故障诊断困难甚至出现误诊的情况;而且由于系统中过程变量间的相关关系不同,有些存在较强的线性关系,有些存在较强的非线性关系,如果不加以区分而使用一种方法对整体进行监测,则会导致最终结果不够准确.为了解决上述问题,本文采用分层分块的思想^[14],利用系统历史数据计算阈值^[16]并结合系统机理,将工业过程划分为多个子块,并判断各子系统内变量间的相关关系,对于动态性强的、呈非线性的子块选择DLPPCA方法,对于动态性弱的、呈线性的子块选择PCA方法.对各子块也采用相应的方法进行特征提取.假设该工业过程划分为 S 个子块: m 个子块使用PCA方法,其得分矩阵为 Y_1, Y_2, \dots, Y_m ; n 个子块使用DLPPCA方法,其得分矩阵为 $Y_{m+1}, Y_{m+2}, \dots, Y_{m+n}$.

将各子系统的得分矩阵组合到一起,作为顶层监测数据,即 $\tilde{X} = [Y_1, Y_2, \dots, Y_m, Y_{m+1}, Y_{m+2}, \dots, Y_{m+n}]^T$.

最后,根据顶层数据各个维度间的相关关系,选择基于PCA或DLPPCA的过程监测方法对顶层进行监测,并利用历史故障数据训练各子块的SVM分类器.图1为PCA-DLPPCA方法的示意图.

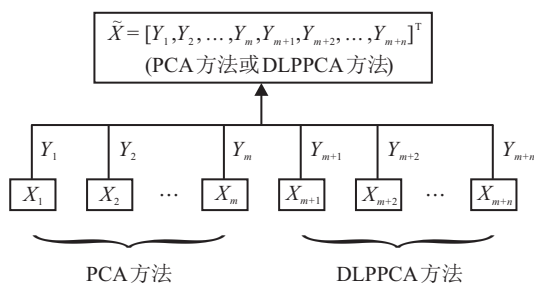


图1 PCA-DLPPCA方法基本思想示意图

在在线监测过程中,当底层统计量和顶层统计量超限时,通过SVM进行诊断,可得到明确的故障类型.算法步骤如下.

离线建模阶段:

step 1: 收集系统历史数据,对各子块进行分析,决定各子块使用的方法.动态性强、呈非线性的子块使用DLPPCA方法,动态性弱、呈线性的子块使用PCA

方法.

step 2: 对正常工况数据进行标准化处理,得到 $X = [x_1, x_2, \dots, x_n] \in R^{m \times n}$,分别使用PCA和DLPPCA对其进行处理,保存各子块的得分矩阵 Y_1, Y_2, \dots, Y_m 和 $Y_{m+1}, Y_{m+2}, \dots, Y_{m+n}$,以及各子块所对应的 T^2 和SPE控制限.

step 3: 收集各子块历史故障数据进行标准化处理,并使用该子块的方法进行特征提取,保存得到的得分矩阵.

step 4: 将step 2中得到的各子块得分矩阵进行组合,得到顶层监测数据 $\tilde{X} = [Y_1, Y_2, \dots, Y_m, Y_{m+1}, Y_{m+2}, \dots, Y_{m+n}]^T$,并对顶层监测数据进行分析,选择合适的监测方法,计算顶层数据的 \tilde{T}^2 和 \tilde{SPE} 统计量.

step 5: 利用step 3中求得的故障数据得分矩阵分别训练各子块的SVM分类器,通过交叉验证实现多分类.

在线监测部分:

step 6: 获得在线监测数据,并对数据进行标准化处理,得到 x_{new} .采用各子块所对应的方法进行特征提取.使用PCA方法计算得到得分矩阵 $y_{new1}, y_{new2}, \dots, y_{newm}$ 以及 $T_P^2SPE_P$ 统计量.使用DLPPCA方法计算得到得分矩阵 $y_{newm+1}, y_{newm+2}, \dots, y_{newm+n}$ 以及 $T_D^2SPE_D$ 统计量.

step 7: 利用step 6中的得分矩阵组合得到顶层监测数据 $\tilde{x}_{new} = [y_{new1}, \dots, y_{newm}, y_{newm+1}, \dots, y_{newm+n}]^T$,并使用step 4中确定的方法计算在线顶层监测数据的 \tilde{T}_{new}^2 和 \tilde{SPE}_{new} 统计量.

step 8: 在在线检测中,若顶层数据和底层子块均未出现超限,则系统正常;若底层子块超出控制限,则利用step 4训练得到的SVM分类器对故障子块进行诊断,得到明确的故障类型;若仅顶层数据存在超限,而底层子块均在控制限以下,则子块间出现故障或不匹配.

3 仿真验证

3.1 TE过程仿真验证DLPPCA

TE过程^[15]数据是对Eastman化学公司的实际工艺流程进行修改后得到的,该数据集共包含21组故障数据和1组正常数据,每组数据包含训练数据和测试数据.训练数据共480个采样点,测试数据共960个采样点,其中测试数据均在第161个采样点处开始加入故障因素^[17].首先以故障A5为例,该故障为冷凝器冷却水入口温度阶跃变化故障,在大约第350个采样点时出水口温度回落到正常范围内,但入水口温度

故障仍然存在. 当使用PCA进行监测时如图2所示.




图2 故障A5采用PCA方法的统计量监测

由图2可见, 出水口温度回落到正常范围后尽管故障仍然存在, 但统计量已经降到了控制限以下. 但是, 当使用DLPPCA对故障A5进行过程监测时, 当出

水口温度回归正常范围后仍能准确地监测出故障, 结果如图3所示.




图3 故障A5采用DLPPCA方法的统计量监测

以表格形式给出部分TE故障使用PCA和DLPPCA监测的误报率和漏报率, 如表1所示.

表1 PCA和DLPPCA误报率和漏报率对比 %

故障	PCA				DLPPCA			
	SPE漏报率	SPE误报率	T ² 漏报率	T ² 误报率	SPE漏报率	SPE误报率	T ² 漏报率	T ² 误报率
A1	0.38	5.66	0.88	0.00	0.25	0.63	0.13	2.01
A2	1.63	3.77	1.75	0.00	1.88	3.14	1.50	0.87
A4	0.38	1.89	92.50	0.00	43.80	2.52	27.28	0.67
A6	0.13	3.14	1.38	0.00	0.00	0.00	0.00	0.61
A8	2.50	3.77	3.25	0.00	4.51	5.03	2.00	0.32
A10	68.38	1.26	74.00	0.00	15.02	1.26	9.89	16.35
A12	5.13	3.14	2.00	0.00	0.50	1.26	0.13	0.42
A13	4.88	1.89	6.38	0.63	4.76	1.26	3.13	0.21
A14	0.13	3.14	4.00	0.00	0.00	3.77	0.13	0.64
A16	72.00	1.89	0.92	0.63	18.02	2.52	10.14	20.36
A17	6.25	3.77	26.00	0.00	5.01	2.52	5.13	6.42
A18	9.63	5.03	11.38	0.00	9.14	1.89	5.76	5.79
A20	49.38	4.40	74.00	0.00	19.27	2.52	13.27	27.04

由表1可以看出: 对于部分故障, DLPPCA表现出优越性; 而另一部分故障, PCA与DLPPCA监测结果不相上下, 不存在DLPPCA劣于PCA的情况, 从而验证了DLPPCA方法的可行性和准确性.

3.2 发电机组过程仿真验证分层分块DLPPCA-SVM

本节仿真实验中, 使用来自某电厂2×660MW发电机组的相关数据. 选择汽动给水泵系统、高压加

热器系统和过热蒸汽及其减温水系统这3个子系统作为3个底层子块. 首先, 根据阈值^[16]计算各变量间的相关关系并进行实际验证, 确定各子块所使用的底层建模方法: 汽动给水泵系统使用PCA, 其余两系统使用DLPPCA方法; 然后, 取各子系统稳态工况下的1000组数据, 其中600组数据作为训练数据集, 400组作为测试数据集; 最后, 利用各子块所对应的方法进行离线建模, 并求得顶层数据, 对顶层数据进行与子

块相同的分析,选择DLPPCA方法进行建模.

在离线建模后使用故障数据集并训练SVM分类器. 本文共使用6类故障: 故障1: 高压加热器系统的一段抽汽压力从第200个采样点开始逐渐增大的故障; 故障2: 高压加热器系统的1号水位从第200个采样点开始逐渐下降的故障; 故障3: 汽动给水泵系统的小机转速从第200个采样点开始逐渐增大并在第400个采样点回落为正常值的故障; 故障4: 汽动给水泵系统的给水压力从第200个采样点开始出现扰动的故障; 故障5: 过热蒸汽及其减温水系统的过热器左侧一级减温器前温度从第200个采样点开始逐渐增大并在第300个采样点时回落为正常值的故障; 故障6: 过热蒸汽及其减温水系统的省煤器左侧出口给水压力从第200个采样点开始出现扰动故障.

以故障5为例验证本文方法的应用效果. 当该故障发生时,故障发生子块的统计量监测结果如图4所示.




图4 过热蒸汽及其减温水系统子块采用DLPPCA方法的统计量监测

由图4可以看出,当故障5发生时故障所在子块的统计量立刻超出控制限,并在第300个采样点后回落到控制限以下,与实际故障情况相符. 而其他两个子块统计量则基本处在控制限以下,如图5和图6所示.

当故障5发生时,顶层统计量监测情况如图7所示. 可见,当故障子系统发生异常情况,顶层统计量立即超限并监测出故障,当故障消失后又回落到控制限以下,基本与底层故障子块过程监测趋势相符.




图5 汽动给水泵系统子块采用PCA方法的统计量监测

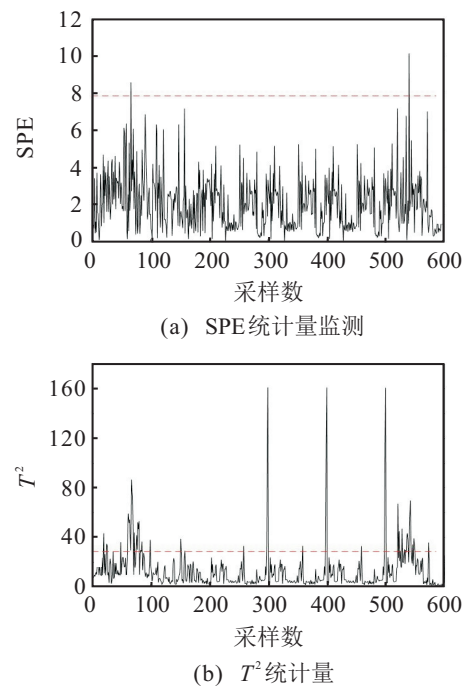


图6 高压加热器系统子块采用DLPPCA方法的统计量监测

在监测到故障后,选取故障子块内第200~第300个采样点使用该子块的SVM分类器进行故障诊断. 当前故障标记类别为5, 正常工况数据标记为0, 结果如图8所示. 从图8中可以看出,诊断效果明显,所选取的100个采样点都能被准确地诊断为故障5, 准确率达到100%.

本文中的故障诊断采用的分类器训练数据是经过各子块所对应方法处理后的训练数据, 诊断准确率




图7 顶层数据的统计量监测




图8 SVM故障诊断结果

优于未经处理直接训练分类器. 6种故障诊断准确率对比情况如表2所示.

表2 SVM和DLPPCA-SVM、PCA-SVM准确率对比 %

故障	SVM 准确率	DLPPCA-SVM 准确率	PCA-SVM 准确率
故障1	97.03	100.00	99.00
故障2	96.03	100.00	100.00
故障3	99.50	100.00	100.00
故障4	97.03	99.71	100.00
故障5	83.54	100.00	97.13
故障6	92.08	100.00	98.02

从表2中可以得到两类对比的结果: 1) 对于使用DLPPCA建模的子块, DLPPCA-SVM比PCA-SVM的准确率更高; 而对于PCA建模的子块, 尽管对目前故障而言两种建模方法准确率几乎相同, 但考虑到该子块本身的特性, 仍然使用PCA进行建模更为适宜. 由此可以表明, 对于不同子块使用不同方法建模的做法具有必要性. 2) 不管是PCA-SVM, 还是DLPPCA-

SVM, 其诊断准确率相较于单独使用SVM的情况都有所提升. 这说明对数据使用子块所对应方法处理后再训练SVM确实可以提高诊断准确性, 从而表明本文所提出方法具有可行性.

通过以上仿真实验和对比, 说明基于分层分块DLPPCA-SVM的方法能够更加准确地建模, 在应用于实际系统异常情况时, 能够及时监测到系统异常情况并诊断出故障类型, 具有很好的应用效果

4 结论

本文提出了基于分层分块DLPPCA-SVM的过程监测与故障诊断方法, 将系统划分为不同的子块, 并通过计算阈值与机理分析相结合的方式分析各子块的内在关系特性, 分别采用PCA和DLPPCA进行底层建模(其中DLPPCA对于动态性能强的非线性数据具有很好的效果), 从而得到各子块的得分矩阵, 再通过组合得分矩阵获得顶层数据, 并使用同样的分析思路, 选择适合顶层数据的建模方法. 在此基础上, 结合支持向量机进行故障诊断. 通过TE过程数据的仿真实验验证了本文所提出方法的有效性和准确性. 将该方法应用于发电机组的过程监测和故障诊断, 仿真结果进一步表明了该方法能够进行有效的过程监测和准确的故障诊断.

参考文献(References)

- [1] 李哈, 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): 1-9.
(Li H, Xiao D Y. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.)
- [2] Wold S, Esbensen K, Geladi P. Principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1987, 2(1/2/3): 37-52.
- [3] Zhao H M, Zheng J J, Xu J J, et al. Fault diagnosis method based on principal component analysis and broad learning system[J]. IEEE Access, 2019, 7: 99263-99272.
- [4] He X, Niyogi P. Locality preserving projections[J]. Advances in Neural Information Processing Systems, 2004, 16(16): 153-160.
- [5] Du H S, Li G D, Wang S, et al. Discriminant locality preserving projections based on L_2 , p-norm for image feature extraction and recognition[J]. Journal of Visual Communication and Image Representation, 2019, 58: 166-177.
- [6] Cayton L. Algorithms for manifold learning[R]. San Diego: University of California at San Diego, 2005: 1-17.
- [7] Huang H, Shi G Y, He H B, et al. Dimensionality reduction of hyperspectral imagery based on spatial-spectral manifold learning[J]. IEEE Transactions on Cybernetics, 2020, 50(6): 2604-2616.
- [8] 张晓涛, 唐力伟, 王平, 等. 基于半监督PCA-LPP流形

学习算法的故障降维辨识[J]. 中南大学学报: 自然科学版, 2016, 47(5): 1559-1564.
 (Zhang X T, Tang L W, Wang P, et al. Fault identification and dimensionality reduction method based on semi-supervised PCA-LPP manifold learning algorithm[J]. Journal of Central South University: Science and Technology, 2016, 47(5): 1559-1564.)

[9] 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.)

[10] 许仪勋, 陆拯, 郭志忠. 基于遗传算法的电力系统分层信息故障诊断方法[J]. 继电器, 2000, 28(10): 15-18.
 (Xu Y X, Lu Z, Guo Z Z. Layered information fault diagnosis based on genetic algorithm[J]. Relay, 2000, 28(10): 15-18.)

[11] Pooranam N, Nithya M, Praveen Kumar D, et al. A study on optimization algorithm (OA) in machine learning and hierarchical information[J]. Journal of Computational and Theoretical Nanoscience, 2020, 17(4): 1733-1736.

[12] Noble W S. What is a support vector machine?[J]. Nature Biotechnology, 2006, 24(12): 1565-1567.

[13] Cervantes J, Garcia-Lamont F, Rodríguez-Mazahua L, et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends[J]. Neurocomputing, 2020, 408: 189-215.

[14] 张淑美. 基于数据驱动的复杂多模态过程模态识别及过程监测研究[D]. 沈阳: 东北大学, 2016.

(Zhang S M. Mode identification and process monitoring for complex multimode processes based on data-driven methods[D]. Shenyang: Northeastern University, 2016.)

[15] Downs J J, Vogel E F. A plant-wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, 17(3): 245-255.

[16] 崔琳琳. 基于HPCA-PPA的电厂发电机组故障诊断方法研究[D]. 沈阳: 东北大学, 2019.
 (Cui L L. Research on fault diagnosis method for power generator sets based on HPCA-PPA[D]. Shenyang: Northeastern University, 2019.)

[17] Ge Z Q, Song Z H. Process monitoring based on independent component analysis/principal component analysis (ICAPCA) and similarity factors[J]. Industrial & Engineering Chemistry Research, 2007, 46(7): 2054-2063.

作者简介

姚远(1979-), 男, 高级工程师, 硕士, 从事火电机组先进控制技术研究, E-mail: yaoyuan_shenyang@163.com;
 佟佳蓉(1995-), 女, 硕士, 从事故障诊断与预测的研究, E-mail: jzyzxw@163.com;
 高军(1971-), 男, 工程师, 从事电气自动化的研究, E-mail: gaojun@neusoft.com;
 王姝(1979-), 女, 副教授, 博士, 从事复杂工业过程监测、故障诊断与预测等研究, E-mail:wangshu@ise.neu.edu.cn;
 宋圣军(1975-), 男, 高级工程师, 硕士, 从事火电机组先进控制技术研究, E-mail: rzs_ssj@126.com.

(责任编辑: 李君玲)

下 期 要 目

柔性触觉传感技术及其在医疗康复机器人的应用 程 龙, 等

轮足复合移动机器人运动规划发展现状及关键技术分析 郭 非, 等

基于多约束条件的机器人抓取策略学习方法 崔 涛, 等

基于改进生物激励神经网络算法的多移动机器人协同变电站巡检作业 陈南凯, 等

指数型犹豫模糊熵在多属性决策中的应用 王拥兵, 等

基于公共特有子空间提取的工业设备多模式运行过程故障检测方法 何雨辰, 等

两个具有耦合时滞的分数阶复杂网络的延迟投影同步与参数辨识 杨 心, 等

离散输入受限系统的增益调度事件触发和自触发控制 张 凯, 等

基于统一资源编码的成像卫星联合任务规划算法框架 张佳唯, 等

考虑时延的智能网联汽车混合交通流稳定性分析 姚志洪, 等

基于W-DenseNet的减压阀不平衡样本故障诊断模型 张 洪, 等