

基于多级动态主元分析的电熔镁炉异常工况诊断

刘强¹ 孔德志¹ 郎自强²

摘要 电熔镁熔炼过程中的异常工况(如半熔化工况)直接影响产品质量、威胁人员和生产安全,有必要及时诊断。但与异常直接相关的超高温熔池温度($>2850^{\circ}\text{C}$)难以利用温度传感器检测,目前现场主要依靠工人在定期巡检时人眼观察炉壁来诊断,工作强度大、安全度低、诊断不及时。针对上述问题,本文提出一种炉体动态图像驱动的电熔镁炉异常工况实时诊断方法。结合电熔镁炉熔炼各区域温度分布的空间特征、正常工况下熔炼温度变化和水雾扰动引入的图像时序特征、以及异常工况下温度异常区域持续发亮扩大的特征,在对炉体动态图像进行空间多级划分的基础上,提出了一种多级动态主元分析(Multi-level dynamic principal component analysis, MLDPCA)动态图像分块建模方法。在此基础上,提出基于MLDPCA的逐级诊断方法与基于贡献图的异常定位方法。最后,采用某电熔镁生产现场的实际图像进行方法验证,结果表明了所提方法的有效性。

关键词 电熔镁炉, 异常工况诊断, 多级动态主元分析, 时序图像建模

引用格式 刘强, 孔德志, 郎自强. 基于多级动态主元分析的电熔镁炉异常工况诊断. 自动化学报, 2021, 47(11): 2570–2577

DOI 10.16383/j.aas.c190313

Multi-level Dynamic Principal Component Analysis for Abnormality Diagnosis of Fused Magnesia Furnaces

LIU Qiang¹ KONG De-Zhi¹ LANG Zi-Qiang²

Abstract The abnormalities during the melting process of fused magnesia furnace (FMF) such as semimolten situation may significantly affect the product quality, the safety of personnel and manufacturing process. The abnormal condition diagnosis deserves more attentions. However, the ultra-high temperature within the melting zone of the FMF is not measurable, that makes the diagnosis of FMF abnormality be difficult. The practitioners can only perform occasional visual inspections which often fail to detect the abnormalities in time. In order to resolve this challenge, this paper proposes a novel dynamic image analysis based real-time abnormality diagnosis method for the FMF. The proposed method exploits the spatial and temporal characteristics of temperature fluctuation in FMF in normal condition as well as the partial glowing of the furnace wall and continuous expanding of the glowing area in abnormal conditions. In order to extract these spatial and temporal features from the dynamic images, a new multi-level dynamic principal component analysis (MLDPCA) algorithm is developed. A hierarchical monitoring method is then proposed to perform the abnormality diagnosis and locate the abnormality by using the MLDPCA based contribution plot. The application result on a practical FMF using the collected field images has demonstrated the effectiveness of the proposed method.

Key words Fused magnesia furnace, abnormality diagnosis, multilevel dynamic principal component analysis, dynamic image modeling

Citation Liu Qiang, Kong De-Zhi, Lang Zi-Qiang. Multi-level dynamic principal component analysis for abnormality diagnosis of fused magnesia furnaces. *Acta Automatica Sinica*, 2021, 47(11): 2570–2577

收稿日期 2019-04-22 录用日期 2019-07-30

Manuscript received April 22, 2019; accepted July 30, 2019
国家自然科学基金(61991401, U20A20189, 61673097, 61833004),
兴辽英才计划项目(XLYC1907049, XLYC1808001), 中央高校基
本科研业务费(N180802004)资助

Supported by National Natural Science Foundation of China
(61991401, U20A20189, 61673097, 61833004), LiaoNing Revitalization
Talents Program (XLYC1907049, XLYC1808001), the Fundamental Research Funds for the Central Universities
(N180802004)

本文责任编辑 杨浩

Recommended by Associate Editor YANG Hao

1. 东北大学流程工业综合自动化国家重点实验室 沈阳 110819
中国 2. 英国谢菲尔德大学自动控制和系统工程系 谢菲尔德市
S1 3JD 英国

1. State Key Laboratory of Synthetical Automation for Process

电熔镁炉是生产电熔镁砂(主要成分是氧化镁)晶体的核心装备。电熔镁砂具有结构紧密、熔点高、抗氧化性好、耐腐蚀性强等优良特性,是广泛应用于航空、军事、冶金等领域的重要战略物资^[1-2]。电熔镁生产工艺是将主要成分为碳酸镁的菱镁矿石加热到 2850°C 以上,使其熔炼为氧化镁产品和二氧化碳气体。由于菱镁矿石成分波动大、矿物组成复杂,熔炼时易发生半熔化、排气异常、过加热等异常 Industries, Northeastern University, Shenyang 110819, China
2. Department of Automatic Control and Systems Engineering,
University of Sheffield, Sheffield S1 3JD, UK

工况, 引起熔炼温度及分布异常, 直接影响产品质量和生产安全^[3-6], 有必要及时诊断.

由于与运行工况直接相关的熔炼温度高达2850 °C以上, 无法由常规温度传感器测量, 目前主要是通过工人定期巡检时观察炉壁状态来诊断. 但是人工巡检实时性差且容易误检、漏检. 此外, 由于现场生产环境恶劣(高温、强光等), 不利于工人长期工作. 为此, 有学者提出基于熔炼电流的电熔镁炉异常工况诊断方法, 主要是通过历史故障数据提取异常工况特征, 再基于上述特征来诊断异常工况. 比如, 文献[5]提出一种基于规则的电熔镁炉异常工况诊断方法, 利用镁炉运行时的熔炼电流数据建立专家诊断规则库, 但规则提取和维护困难. 而且, 电熔镁炉电极移动及熔炼过程中电弧放电过程中的强不确定性会导致电流无规律的波动, 影响诊断精度.

相比较过程数据而言, 熔炼图像更直观地反映了熔炼过程中熔池内的工况. 近两年学者提出了基于图像的电熔镁炉异常工况诊断方法. 比如, 文献[7]提出基于炉体图像相关系数的半熔化工况诊断方法, 但该方法未有效利用图像的时序特征, 对于熔炼时的水雾引入的扰动较为敏感; 文献[8-9]提出基于深度学习的异常工况诊断方法, 但模型训练需要大量带有标签的异常工况数据, 诊断结果强依赖于标签的准确性, 而实际生产中往往难以获取标签数据, 限制了该类方法的应用.

相比于异常工况数据而言, 电熔镁生产的正常工况数据更容易获取. 近年来, 数据驱动的异常工况诊断通常利用正常工况数据, 采用如主元分析(Principal component analysis, PCA)^[10-13]等方法获取过程变量间的潜结构关系和正常变化的范围, 再通过其非期望变化来诊断异常, 已在化工、钢铁、半导体加工等过程中得到成功应用.

对于电熔镁熔炼过程而言, 局部空间特性和温度惯性会引入时空动态性, 传统的PCA方法只能提取静态变化, 使得基于PCA的异常工况诊断方法易发生误报与漏报^[14-15]. 针对此问题, 学者提出了提取动态关系的动态潜结构建模方法以及在此基础上的异常工况诊断方法. 比如, 文献[16-19]提出采用时滞偏移技术来提取多维变量间的动态关系的动态主元分析方法; 文献[20-21]利用自回归算法提取潜变量, 然后建立一个向量自回归内部模型来提取变量间的动态关系; 文献[22]提出动态内在主元分析(Dynamic inner principal component analysis, DiPCA)方法直接从多维时间序列中根据动态性强弱依次提取动态潜变量, 在此基础上建立相应的监控指标来实现异常工况诊断. 上述方法为利用

电熔镁炉动态图像提取熔炼过程的动态特征进行异常工况诊断提供了新思路.

本文面向半熔化这类与熔炼温度直接相关的异常工况的诊断问题, 研究利用熔炼过程炉壁时序图像提取各区域的时空特征的方法. 主要贡献是结合文献[23]所提出的分块建模和逐级诊断思路, 提出电熔镁炉时序图像逐级建模与异常工况诊断方法. 该方法结合镁炉熔炼图像的空间特征以及温度惯性和水雾扰动的时序特征将炉壁时序图像分为整体、子块、列三级. 在此基础上, 将熔炼过程分级特征与DiPCA算法相结合提出一种多级动态主元分析(Multi-level dynamic principal component analysis, MLDPCA)算法来提取炉壁动态图像局部子块区域的图像空间特征, 再通过对建立的MLDPCA模型定义区域的监控指标及整个炉况的综合指标, 实现异常工况的逐级诊断. 当检测到异常工况后, 将MLDPCA模型与贡献图^[24]相结合, 提出基于MLDPCA贡献图的电熔镁炉熔炼异常定位方法.

1 电熔镁炉运行工况描述与特征分析

1.1 电熔镁生产过程描述与异常工况描述

1) 电熔镁生产过程描述

电熔镁生产是通过三相交流电熔镁炉(简称电熔镁炉)将主要成分为碳酸镁的菱镁矿石加工的轻烧镁粉加热到2850 °C以上使之分解为氧化镁熔液和二氧化碳气体, 再将氧化镁熔液冷却结晶去除杂质后得到高纯度的氧化镁晶体^[2, 5]. 图1为电熔镁生产的工艺图^[2], 利用三相电极供电与镁粉原料之间形成电弧使原料加热熔化, 分为起炉、加热熔炼、冷却、粉碎、分拣等工序, 其中加热熔炼为主要工序. 其主要熔炼过程是周期性地加料、加热熔化和排气.

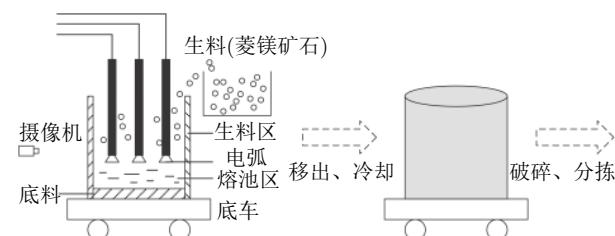


图1 电熔镁生产过程

Fig. 1 Fused magnesia manufacturing processes

2) 电熔镁炉异常工况描述

由于原料大小和成分波动, 造成熔炼时三相电极之间电阻的突变, 易引起熔炼温度及分布的异常, 发生半熔化、排气异常、过烧等异常工况. 该类异常的发生和发展伴随着熔池温度及分布的非期望动态

变化。熔池温度及分布动态变化引起炉壁图像时空特征变化，为利用其进行电熔镁炉异常工况诊断提供了新的思路。

1.2 电熔镁炉运行工况的图像特征分析

电熔镁炉炉体为圆柱体，炉口为排气区，炉中部主要为熔炼区，炉底和边部主要为保护层区，不同区域的温度分布不同，采集到的各区域图像具有相对独立的空间特征。同时，各区域熔炼温度变化受物质和能量约束，为各区域的图像引入时间相关性。然而，熔炼时对炉壁喷洒水冷却降温，会带来大量白色的水雾，对上述时空相关性带来强干扰。比如，炉壁上方漂浮的水雾，在炉口火焰的照射下，水雾亮度较高，但由于水雾存在时间短且不断产生，造成局部区域时序图像的亮度波动，如图2(a)所示。

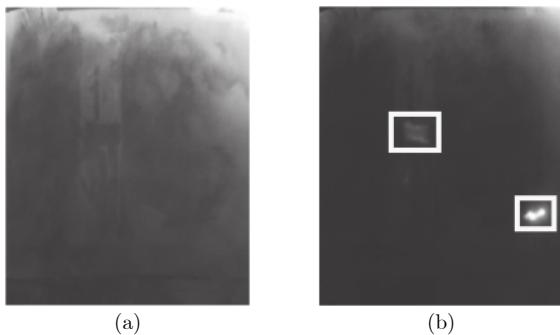


图2 (a) 正常工况图像; (b) 半熔化工况图像

Fig.2 (a) Image of normal situation; (b) Image of semimolten situation

与熔炼温度相关的异常工况发生时，时序图像会偏离上述时空相关性。比如，半熔化异常工况发生时，熔池温度异常升高且区域不断扩大。炉壁图像在自然闪烁的同时逐渐变红发亮，且发亮区域不断扩大，如图2(b)所示。相对于位置不规则变化的水雾，半熔化区域在空间上较固定。为此，可利用正常工况下的时序图像的时空特征的非期望变化来诊断异常工况。结合镁炉不同熔炼区域空间特征相对独立，可对电熔镁炉熔炼图像分块处理，提取熔炼区域时序图像的时空特征动态潜结构，在此基础上，实现异常工况的逐级诊断与定位。

2 基于多级动态主元分析的电熔镁炉异常工况诊断方法

2.1 时序图像预处理

电熔镁炉异常工况相关的熔炼温度主要与图像

亮度有关。为此，利用式(1)将原始RGB图像转化为灰度图像^[25]。

$$\mathbf{M}_n = \mathbf{V}_n^R \times 0.299 + \mathbf{V}_n^G \times 0.587 + \mathbf{V}_n^B \times 0.144 \quad (1)$$

其中， $n = 1, 2, \dots, N$, N 为图像的帧数， $\mathbf{V}_n^R, \mathbf{V}_n^G, \mathbf{V}_n^B$ 分别表示第 n 帧原始时序图像的R, G, B三个通道的亮度。

熔炼过程中，炉口的火焰会不规则跳动导致亮度不断变化，拍摄出的时序图像忽明忽暗，不利于时序图像的特征提取。因此，对上述灰度图像按式(2)进行归一化^[26]：

$$\begin{aligned} \hat{\mathbf{M}}_n &= \frac{\sigma(\mathbf{M}^s)}{\sigma(\mathbf{M}_n)} (\mathbf{M}_n - \bar{\mathbf{M}}_n) + \mathbf{M}^s \\ \mathbf{M}^s &= \frac{1}{N_1} \sum_{i=1}^{N_1} \mathbf{M}_i \end{aligned} \quad (2)$$

其中， $\hat{\mathbf{M}}_n$ 为经过灰度归一化后第 n 帧图像， $\sigma(\cdot)$ 表示求取标准差， $\bar{\mathbf{M}}$ 表示对 \mathbf{M} 取均值， \mathbf{M}^s 表示参考图像， N_1 为参考图像的帧数，根据火焰闪烁频率来确定。

2.2 时序图像多级动态主元分析建模

正常工况下，镁炉熔炼温度随时间变化引入炉壁图像的时序特征。描述上述特征的时序图像序列包含空间上两个维度以及时间维度共计三个维度。不同熔炼区域（如炉口与炉底）的图像具有各异的时空特征，若直接将二维单帧图像拉直变换转化为一维数据，进而将三维时序图像序列转化为二维数据进行动态建模，会忽略各区域内图像各像素点间的空间约束，难以有效提取各熔炼区域内各异的动态变化；另一方面，准确反应熔炼运行工况的高分辨率图像对应超大规模的变量个数（ $> 90,000$ ），若将超大规模变量直接拉直为一维进行建模，建模算法内的矩阵乘积等运算会因变量维数过大超过计算机内存限制，导致建模算法难以计算实现。因此，本文通过分块将每个位置的每帧图像的每一时刻组合来描述工况特征，提出了一种多级动态主元分析建模方法。为提取上述特征，首先将时序图像序列分为3级数据，如图3所示。

第1级数据为每帧完整的时序图像 \mathbf{X}_n ：

$$\mathbf{X}_n = \hat{\mathbf{M}}_n, \quad n = 1, 2, \dots, N$$

针对电熔镁熔炼过程分为 B 个区域，将每帧图像 \mathbf{X}_n 根据熔炼过程知识分成的 B 个块，作为第2级数据：

$$\mathbf{X}_n = [\mathbf{X}_{1,n} \ \mathbf{X}_{2,n} \ \dots \ \mathbf{X}_{B,n}]$$

然后为提取动态性，将每个块对应相同的列提取出

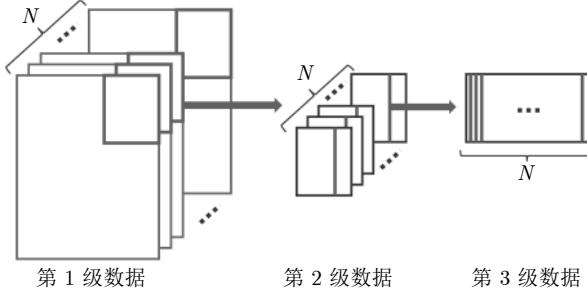


图 3 时序图像序列分级结构

Fig. 3 Hierarchical structure of time series image

来组合为 $\mathbf{X}_{b,m}$, 作为第 3 级数据:

$$\mathbf{X}_{b,m} = [\mathbf{X}_{b,m,1} \ \mathbf{X}_{b,m,2} \cdots \ \mathbf{X}_{b,m,N}], \quad b = 1, 2, \dots, B$$

其中, m 为对应子块的第 m 列, $m = 1, 2, \dots, M$, M 为单帧图像的列数, $\mathbf{X}_{b,m,n}$ 为时序图像序列的第 n 帧图像的第 b 块中的第 m 列. 根据 $\mathbf{X}_{b,m}$ 可以得到如下矩阵:

$$\begin{aligned} \mathbf{X}_{b,m,i} &= [\mathbf{x}_{b,m,i} \ \mathbf{x}_{b,m,i+1} \ \cdots \ \mathbf{x}_{b,m,N+i-1}]^T \\ \mathbf{Z}_{b,m,s} &= [\mathbf{X}_{b,m,1} \ \mathbf{X}_{b,m,2} \cdots \ \mathbf{X}_{b,m,s}] \end{aligned} \quad (3)$$

其中, $i = 1, 2, \dots, s+1$.

可以得到第 3 级数据动态建模目标^[22]:

$$\begin{aligned} \max_{\mathbf{w}_{b,m}, \boldsymbol{\beta}_{b,m}} \quad & \mathbf{w}_{b,m}^T \mathbf{X}_{b,m,s+1}^T \mathbf{Z}_{b,m,s} (\boldsymbol{\beta}_{b,m} \otimes \mathbf{w}_{b,m}) \\ \text{s.t.} \quad & \|\mathbf{w}_{b,m}\| = 1, \|\boldsymbol{\beta}_{b,m}\| = 1 \end{aligned} \quad (4)$$

其中, s 为模型的动态阶次, $\mathbf{w}_{b,m}$ 为权重向量且 $\|\mathbf{w}_{b,m}\| = 1$, $\boldsymbol{\beta}_{b,m} = [\beta_{b,m,1} \ \beta_{b,m,2} \ \cdots \ \beta_{b,m,s}]^T$ 为通过前 s 时刻的动态潜变量预测 k 时刻动态潜变量 $\mathbf{t}_{b,m,k}$ 的系数, $(\boldsymbol{\beta}_{b,m} \otimes \mathbf{w}_{b,m})$ 为求取 $\boldsymbol{\beta}_{b,m}$ 和 $\mathbf{w}_{b,m}$ 的克罗内克积.

采用附录 A 的动态内在主元分析 (Dynamic inner PCA, DiPCA) 算法, 建立第 3 级数据的动态潜结构模型:

$$\mathbf{X}_{b,m,s+1} = \hat{\mathbf{T}}_{b,m,s+1} \mathbf{P}_{b,m,v}^T + \mathbf{T}_{b,m,r} \mathbf{P}_{b,m,r}^T + \mathbf{E}_{b,m,r} \quad (5)$$

其中, $\hat{\mathbf{T}}_{b,m,s+1} \mathbf{P}_{b,m,v}^T$ 为动态主成分, $\mathbf{T}_{b,m,r} \mathbf{P}_{b,m,r}^T$ 为静态主成分, $\mathbf{E}_{b,m,r}$ 为静态残差. 通过多级动态建模, 在高维时序图像序列中提取出低维的静态潜变量 $\mathbf{T}_{b,m,r}$ 和动态潜变量 $\hat{\mathbf{T}}_{b,m,s+1}$ 分别描述熔炼温度分布的静态变化和动态变化.

2.3 基于 MLDPCA 的异常工况逐级诊断

传统的过程监控通常利用平方预测误差 (Squared prediction error, SPE) 和 Hotelling's T^2 两个指标检测空间相关性的异常变化. 为了有效检测各熔炼区域温度分布非期望的动态变化, 本文建立 MLDPCA 的动态潜变量监控指标和静态潜变量的监控

指标.

第 k 时刻的动态得分 $\mathbf{t}_{b,m,v,k}$, 动态残差 $\mathbf{v}_{b,m,v,k}$, 静态得分 $\mathbf{t}_{b,m,r,k}$ 和静态残差 $\mathbf{e}_{b,m,r,k}$ 可由以下式(6)计算,

$$\begin{aligned} \mathbf{t}_{b,m,v,k} &= \mathbf{R}_{b,m,v}^T \mathbf{x}_{b,m,v,k} \\ \mathbf{v}_{b,m,v,k} &= \mathbf{t}_{b,m,v,k} - \hat{\mathbf{t}}_{b,m,v,k} \\ \hat{\mathbf{t}}_{b,m,v,k} &= \sum_{i=1}^s \Theta_{b,m,v,i}^T \mathbf{t}_{b,m,v,k-i} \\ \mathbf{e}_{b,m,k} &= \mathbf{x}_{b,m,v,k} - \mathbf{P}_{b,m,v} \hat{\mathbf{t}}_{b,m,v,k} \\ \mathbf{t}_{b,m,r,k} &= \mathbf{P}_{b,m,r}^T \mathbf{e}_{b,m,k} \\ \mathbf{e}_{b,m,r,k} &= (\mathbf{I} - \mathbf{P}_{b,m,r} \mathbf{P}_{b,m,r}^T) \mathbf{e}_{b,m,k} \end{aligned} \quad (6)$$

其中, $\mathbf{R}_{b,m,v} = \mathbf{W}_{b,m} (\mathbf{P}_{b,m,v}^T \mathbf{W}_{b,m})^{-1}$, $\hat{\mathbf{t}}_{b,m,v,k}$ 为 $\mathbf{t}_{b,m,v,k}$ 的预测, 由前 s 个时刻预测得到, $\Theta_{b,m,v}$ 为关于 $\mathbf{T}_{b,m,v}$ 的向量自回归模型的系数, $\mathbf{W}_{b,m}$, $\mathbf{P}_{b,m,v}$ 和 $\mathbf{P}_{b,m,r}$ 分别为权重向量矩阵、动态负载矩阵和静态负载矩阵, 按附录 A 中方法计算求得.

对于动态部分, 定义第 3 级数据的监控指标:

$$\begin{aligned} T_{b,m,v,k}^2 &= \mathbf{v}_{b,m,v,k}^T \mathbf{P}_{b,m,v} \Lambda_{b,m,v}^{-1} \mathbf{P}_{b,m,v}^T \mathbf{v}_{b,m,v,k} \\ SPE_{b,m,v,k} &= \mathbf{v}_{b,m,v,k}^T (\mathbf{I} - \mathbf{P}_{b,m,v} \mathbf{P}_{b,m,v}^T) \mathbf{v}_{b,m,v,k} \end{aligned} \quad (7)$$

其中, $\Lambda_{b,m,v} = \frac{1}{N-1} \mathbf{V}_{b,m,v}^T \mathbf{V}_{b,m,v}$, $\mathbf{V}_{b,m,v}$ 为第 b 块数据的动态残差矩阵, 可由式(6)求得, \mathbf{I} 为单位矩阵.

对于静态部分, 定义第 3 级数据的监控指标:

$$\begin{aligned} T_{b,m,r,k}^2 &= \mathbf{e}_{b,m,r,k}^T \mathbf{P}_{b,m,r} \Lambda_{b,m,r}^{-1} \mathbf{P}_{b,m,r}^T \mathbf{e}_{b,m,r,k} \\ SPE_{b,m,r,k} &= \mathbf{e}_{b,m,r,k}^T (\mathbf{I} - \mathbf{P}_{b,m,r} \mathbf{P}_{b,m,r}^T) \mathbf{e}_{b,m,r,k} \end{aligned} \quad (8)$$

其中, $\Lambda_{b,m,r} = \frac{1}{N-1} \mathbf{T}_{b,m,r}^T \mathbf{T}_{b,m,r}$, $\mathbf{T}_{b,m,r}$ 为第 b 块的静态得分矩阵, 可由附录 A 中的方法计算得出.

为了监控局部熔炼区域温度分布异常及其随时间的非期望变化, 将以上指标通过下式建立综合指标:

$$\varphi_{b,m,k} = \frac{T_{b,m,v,k}^2}{\tau_{b,m,v}^2} + \frac{SPE_{b,m,v,k}}{\delta_{b,m,v}^2} + \frac{T_{b,m,r,k}^2}{\tau_{b,m,r}^2} + \frac{SPE_{b,m,r,k}}{\delta_{b,m,r}^2} \quad (9)$$

其中, $\tau_{b,m,v}^2$ 、 $\delta_{b,m,v}^2$ 、 $\tau_{b,m,r}^2$ 和 $\delta_{b,m,r}^2$ 分别为 $T_{b,m,v}^2$ 、 $SPE_{b,m,v}$ 、 $T_{b,m,r}^2$ 和 $SPE_{b,m,r}$ 的控制限. 各控制限可由式(10)求得:

$$cl = g \chi_{h;\alpha}^2 \quad (10)$$

其中, cl 为各监控指标的控制限, $g = \frac{v}{2\mu}$, $h = \frac{2\mu^2}{v}$, μ 为相应监控指标的均值, v 为监控指标的方差. χ^2 表示卡方分布.

对于第 2 级数据, 其监控指标为:

$$\varphi_{b,k} = \frac{\varphi_{b,1,k}}{\varsigma_{b,1}} + \frac{\varphi_{b,2,k}}{\varsigma_{b,2}} + \cdots + \frac{\varphi_{b,M,k}}{\varsigma_{b,M}} \quad (11)$$

其中, $\varsigma_{b,m}$ 为 $\varphi_{b,m,k}$ 的控制限, 可由式 (10) 求得.

对于整个镁炉时序图像的监控指标:

$$\varphi_k = \frac{\varphi_{1,k}}{\varsigma_1} + \frac{\varphi_{2,k}}{\varsigma_2} + \cdots + \frac{\varphi_{B,k}}{\varsigma_B} \quad (12)$$

其中, ς_b 为 $\varphi_{b,k}$ 的控制限, 可由式 (10) 求得, 同时根据式 (10) 可求出第 3 级监控指标 φ_k 的控制限 ς .

正常工况下存在水雾等干扰, 采用综合指标诊断可减小水雾等干扰对分级指标诊断带来的误报, 提高诊断算法的鲁棒性.

基于 MLDPCA 进行异常工况诊断的流程如图 4 所示, 步骤总结如下: 首先利用历史正常工况数据建立 MLDPCA 模型, 再采用建立的模型计算实时图像的各级监控指标, 在此基础上进行集散监控. 然后对综合指标进行监控, 当检测到异常工况发生时, 首先由第 2 级监控指标定位到异常工况发生的块 b , $b = 1, 2, \dots, B$, 然后通过式 (13) 计算该块每个像素点的贡献^[24]:

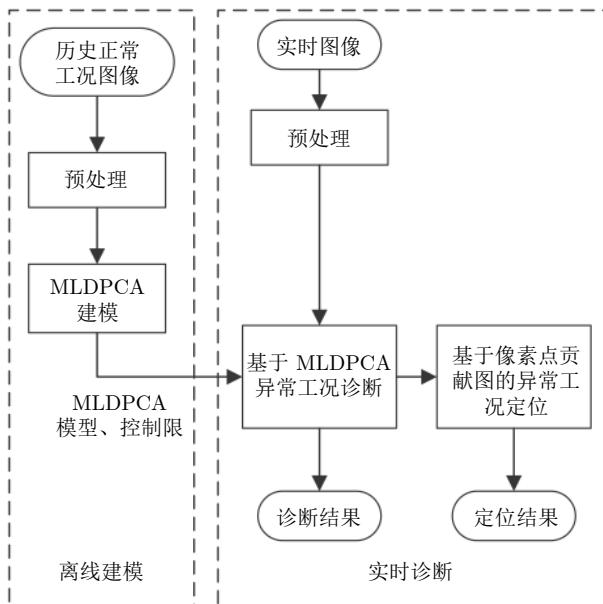


图 4 基于 MLDPCA 的异常工况诊断流程图

Fig. 4 Flow chart of MLDPCA based abnormal situation diagnosis

$$Cont_{b,i}^{\varphi} = (\boldsymbol{\xi}_i^T \boldsymbol{\Phi}_{b,i}^{\frac{1}{2}} \mathbf{x}_{b,i})^2 \quad (13)$$

其中, $\boldsymbol{\Phi}_{b,i} = \frac{\tilde{\mathbf{C}}_{b,i}}{\delta_{b,i}^2} + \frac{\mathbf{D}_{b,i}}{\tau_{b,i}^2}$, $\tilde{\mathbf{C}}_{b,i} = \mathbf{I} - \mathbf{P}_{b,i} \mathbf{P}_{b,i}^T$, $\mathbf{D}_{b,i} = \mathbf{P}_{b,i}^T \Lambda^{-1} \mathbf{P}_{b,i}$, $\Lambda = \mathbf{T}_{b,i}^T \mathbf{T}_{b,i}$, $\boldsymbol{\xi}_i$ 表示单位矩阵 \mathbf{I} 的第 i 列. 求取到各个像素点的贡献后, 将各个点的贡献按从大到小的顺序排列为 $Cont_{b,j}, j = j_1, j_2, \dots, j_M$.

$$CP = \frac{\sum_{j=j_1}^{j_A} Cont_{b,j}}{\sum_{i=1}^M Cont_{b,i}} \quad (14)$$

通过式 (14) 计算贡献最大的前 A 个像素点的累计贡献率 CP , 其中, 异常点个数 A 的取值由累计贡献率达到阈值 ct 来确定, 本文中根据经验将 ct 取值为 35 %, M 为该块像素点的总数. 将贡献较大的前 A 个像素点取值为 1, 其余的像素点取值为 0, 将取值为 1 的点可视化为白色, 将取值为 0 的点可视化为黑色, 得到各个像素点的贡献图, 根据贡献图, 定位到异常工况发生的位置.

3 实验验证

本节结合实际的电熔镁炉熔炼过程, 从电熔镁炉半熔化异常工况诊断的准确性与实时性两个方面对第 2 节所提出的异常工况诊断方法进行验证. 从电熔镁炉熔炼现场采集到图像序列, 采样率为 30 帧/秒, 其分辨率为 $385 \times 315 \times 800$, 其中前两个维度分别为空间维度的水平方向与垂直方向, 第三个维度为时间维度(即动态图像的帧数). 将前 300 帧作为训练集, 第 301 ~ 800 帧作为测试集. 图 5 为本文方法与多级 PCA 方法的诊断结果对比, 其下半部分为上半部分方框中放大后的结果, 由图 5 (a) 可以看出 540 帧开始, 综合监控指标开始超过控制限, 可以诊断此时发生了异常工况. 检测到半熔化异常工况发生后, 利用每个子块的监控指标定位异常工况区域, 图 6 分别为每个子块的监控指标变化图, 可以看出第 9 个子块在 540 帧左右监控指标上升, 诊断发生了半熔化工况; 同时, 第 5 个子块在 700 帧左右监控指标上升, 可以判断在第 700 帧时发生了第 2 个半熔化工况. 第 6 子块在后期也发生了监控指标上升情况, 是由第 9 个子块处的半熔化区域后期范围扩大引起.

分别计算第 540 帧时第 9 块和第 700 帧时第 5 块每个像素的贡献, 由于发生半熔化工况的像素有多个, 因此计算每个像素点的贡献率, 将累计贡献率超过 35 % 的像素点标记为白色, 其余像素点标记为黑色, 可视化如图 7 所示, 图中白色区域为诊断出半熔化工况发生位置. 通过图 7 (a) 可以诊断出在 540 帧时第 9 子块上方发生了半熔化异常工况, 图 7 (b) 在 700 帧时第 5 子块左上方发生异常. 图 8 为电熔镁炉第 540 帧和第 700 帧图像(编号从左到右, 从上到下依次为 1 ~ 9), 通过与图 7 对比, 本文方法能够及时诊断半熔化工况发生的位置. 图 8 (b) 第 5 子块左上角处半熔化工况发生位置刚好处于炉

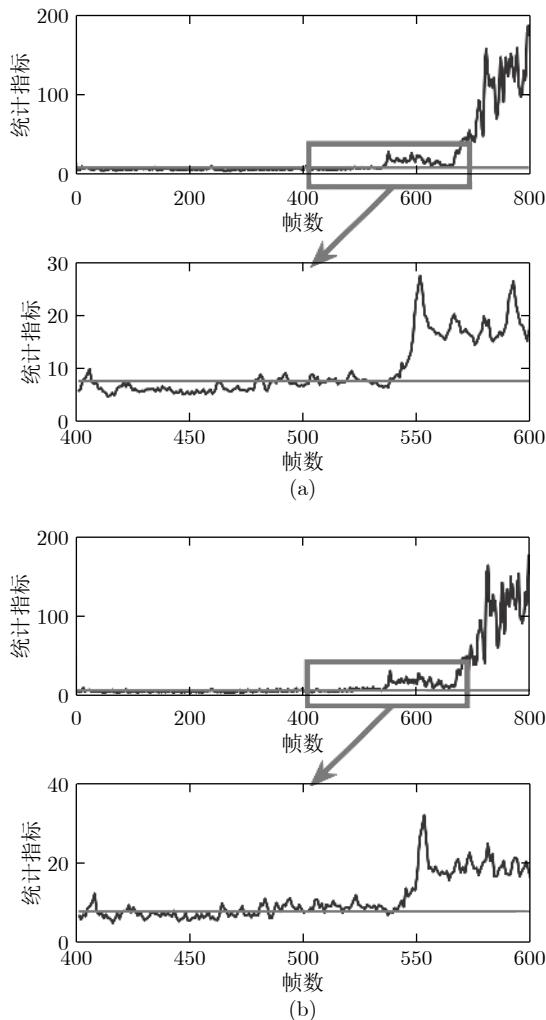


图 5 (a) MLDPCA 诊断结果; (b) 多级 PCA 诊断结果
Fig.5 (a) Diagnosis result of MLDPCA; (b) Diagnosis result of MLPCA

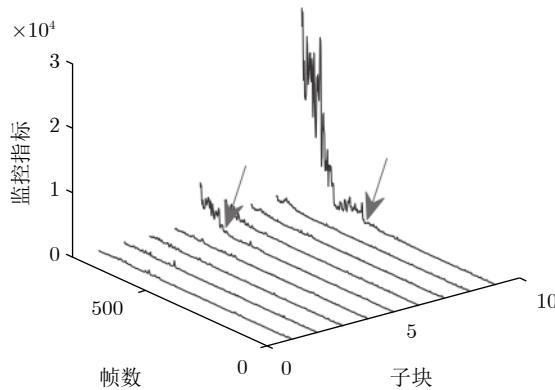


图 6 每个子块的监控指标
Fig.6 Monitoring index for each sub-block

壁正常工况的白斑附近, 肉眼辨别困难, 若由人工巡检易漏报。

图 5 (b) 为多级 PCA 诊断结果。可以看出由多

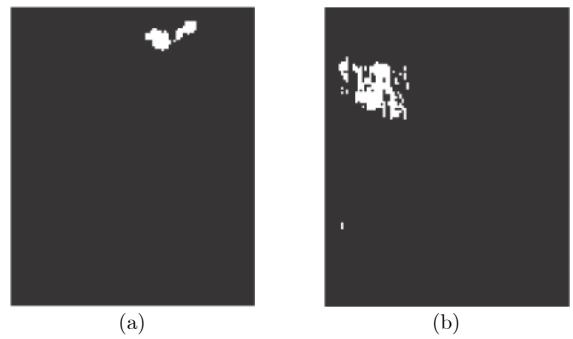


图 7 (a) 第 540 帧时第 9 块贡献图; (b) 第 700 帧时第 5 块贡献图
Fig.7 (a) Contribution plot in 9th block at 540th; (b) Contribution plot in 5th block at 700th

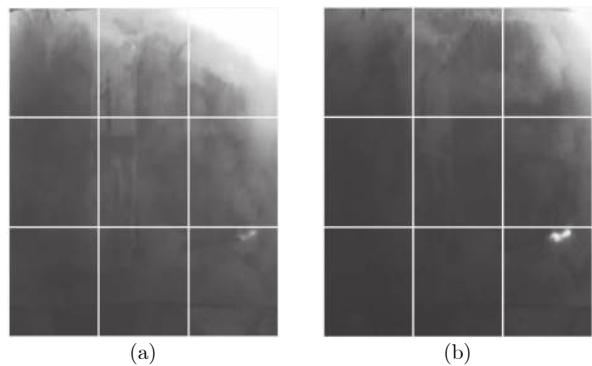


图 8 (a) 第 540 帧时炉壁图像; (b) 第 700 帧时炉壁图像
Fig.8 (a) Image at 540th frame; (b) Image at 700th frame

级 PCA 方法求出的监控指标在控制限附近存在较大的波动, 相比于本文方法更容易误报。经过分析可知由于存在高频噪声特性的水雾干扰, 而静态的 PCA 在计算时无法提取时序图像的时间特性, 因此会将水雾干扰情况计算到监控指标中。为减少误报率, 改进监控性能, 本文利用时间延迟窗进行诊断^[27], 即当连续 d 个样本的综合指标超限(即 $[\varphi_k \sim \varphi_{k+d}] > \varsigma$)时诊断出异常, 其中, ς 为监控指标控制限, 可由式(10)求得, d 为延迟窗大小, 本文取值为 6。表 1 给出了采用时间延迟窗和未采用时间延迟窗条件下, 本文方法与多级 PCA 方法的误报率。由该表可以看出, 未采用时间延迟窗时, 本文方法相比多级 PCA 方法而言误报率降低了约 5 倍, 为 7.63%; 而采用时间延迟窗后, 使本文方法的误报率降至 0.1%, 满足了实际应用的要求。

本文方法在硬件配置为 i7-3770, 3.40 GHz 的 4 核 CPU, 内存为 8 GB 的计算机上进行实验与验证。由于本文采用动态阶次为 3 的 DPCA 建模, 滞后 3 帧(0.10 秒), 采用大小为 6 帧的时间延迟方法滞后 6 帧(约 0.20 秒), 二者带来计算滞后时间 9

表 1 电熔镁炉半熔化工况诊断误报率
Table 1 False positive rates of semimolten for FMF

诊断方法	误报率(不加时间延迟诊断)	误报率(加时间延迟诊断)
多级 PCA	35.17 %	8.69 %
本文方法	7.63 %	0.1 %

帧(约 0.30 秒), 该滞后时间与 MLDPCA 诊断算法的计算时间之和为在线诊断的时间. 表 2 分别列出了本文方法与多级 PCA 方法的离线建模时间与在线诊断时间. 可以看出, 本文方法建模时间长于多级 PCA 方法, 诊断时间相近, 均约为 0.9 秒, 满足了诊断的实时性要求, 虽然本文方法建模时间较长, 但可提前离线训练完成.

表 2 建模时间与诊断时间
Table 2 Cost time of modeling and online diagnosis

诊断方法	建模时间(秒)	诊断时间(秒)
多级 PCA	54.95	0.87
本文方法	145.14	0.94

4 结语

针对电熔镁熔炼过程图像的时空特性, 本文提出一种基于多级动态主元分析的异常工况诊断方法. 相比人工巡检, 可在异常发展前前提前预报. 相比较静态 PCA 算法, 所提方法能够更好地克服现场水雾干扰的影响, 降低误报率, 提高了诊断精度. 下一步拟研究镁炉炉壁图像与炉口火焰图像和熔炼的电流相融合的异常工况诊断方法.

附录 A: 动态内在主元分析 (Dynamic inner Principal Component Analysis, DiPCA) 算法^[22]

1) 归一化 \mathbf{X} 为零均值和单位方差, 初始化 \mathbf{w} 为一个随机的单位向量.

$$\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \cdots \ \mathbf{x}_{K+s}]^T$$

令

$$\mathbf{X}_i = [\mathbf{x}_i \ \mathbf{x}_{i+1} \ \cdots \ \mathbf{x}_{K+i-1}]^T$$

其中, $i = 1, 2, \dots, s+1$, K 为建模数据的样本个数, s 为模型的动力阶次.

2) 提取动态潜变量. 迭代下列步骤直到收敛, $\mathbf{t} = \mathbf{X}\mathbf{w}$, 其中, $\mathbf{t}_i = \mathbf{X}_i\mathbf{w}$

$$\boldsymbol{\beta} = [\mathbf{t}_1 \ \mathbf{t}_2 \ \cdots \ \mathbf{t}_s]^T \mathbf{t}_{s+1}$$

$$\mathbf{w} = \sum_{i=1}^s \boldsymbol{\beta}_i (\mathbf{X}_{s+1}^T \mathbf{t}_i + \mathbf{X}_i^T \mathbf{t}_{s+1})$$

$$\mathbf{w} := \frac{\mathbf{w}}{\|\mathbf{w}\|}$$

$$\boldsymbol{\beta} := \frac{\boldsymbol{\beta}}{\|\boldsymbol{\beta}\|}$$

3) 计算残差:

$$\mathbf{X} := \mathbf{X} - \mathbf{t}\mathbf{p}^T; \mathbf{p} = \frac{\mathbf{X}^T \mathbf{t}}{\mathbf{t}^T \mathbf{t}}$$

4) 返回步骤 2), 提取下一个潜变量, 直到 l 个潜变量都被提取出来.

5) 动态建模. 建立一个向量自回归模型, 将 \mathbf{T}_{s+1} 与 $\mathbf{T}_1, \mathbf{T}_2, \dots, \mathbf{T}_s$ 之间的动态关系表示如下:

$$\mathbf{T}_{s+1} = \mathbf{T}_1 \Theta_s + \mathbf{T}_2 \Theta_{s-1} + \cdots + \mathbf{T}_s \Theta_1 + \mathbf{V} = \bar{\mathbf{T}}_s \Theta + \mathbf{V}$$

其中, $\bar{\mathbf{T}} = [\mathbf{T}_1 \ \mathbf{T}_2 \ \cdots \ \mathbf{T}_s]$, $\Theta = [\Theta_s \ \Theta_{s-1} \ \cdots \ \Theta_1]$, 由最小二乘法得到 Θ 的估计值 $\hat{\Theta} = (\bar{\mathbf{T}}_s^T \bar{\mathbf{T}}_s)^{-1} \bar{\mathbf{T}}_s^T \mathbf{T}_{s+1}$, 从而得到 \mathbf{T}_{s+1} 的预测值 $\hat{\mathbf{T}}_{s+1} = \bar{\mathbf{T}}_s \hat{\Theta}$.

6) 预测误差静态建模. 对预测误差矩阵 \mathbf{E}_{s+1} 执行 PCA 算法:

$$\mathbf{E}_{s+1} = \mathbf{X}_{s+1} - \hat{\mathbf{T}}_{s+1} \mathbf{P}^T = \mathbf{T}_r \mathbf{P}_r^T + \mathbf{E}_r$$

References

- 1 Luo Xian-Ping, Li Jian-Kang, Xu Hui, Wang Jin-Qing, Lu Deng-Qing, Zhang Xian. Preparation and melting process of fused magnesia. *Journal of Salt and Chemical Industry*, 2016, **45**(8): 8–13
(罗仙平, 李建康, 徐徽, 王金庆, 逯登琴, 张贤. 电熔镁砂制备工艺及熔炼过程. 盐业与化工, 2016, **45**(8): 8–13)
- 2 Wu Zhi-Wei, Chai Tian-You, Wu Yong-Jian. A hybrid prediction model of energy consumption per ton for fused magnesia. *Acta Automatica Sinica*, 2013, **39**(12): 2002–2011
(吴志伟, 柴天佑, 吴永建. 电熔镁砂产品单吨能耗混合预报模型. 自动化学报, 2013, **39**(12): 2002–2011)
- 3 Zhang X, Xue D F, Xu D L, Feng X Q, Wang J Y. Growth of large MgO single crystals by an arc-fusion method. *Journal of Crystal Growth*, 2005, **280**(6): 234–238
- 4 Zhang X, Xue D F, Wang J Y, Feng X Q. Improved growth technology of large MgO single crystals. *Journal of Crystal Growth*, 2006, **292**(7): 505–509
- 5 Wu Z W, Wu Y J, Chai T Y, Sun J. Data-driven abnormal condition identification and self-healing control system for fused magnesium furnace. *IEEE Transactions on Industrial Electronics*, 2015, **62**(3): 1703–1715
- 6 Chai T Y, Wu Z W, Wang H. A CPS based optimal operational control system for fused magnesium furnace. In: Proceedings of the 20th world Congress of the International Federation of Automatic Control. Toulouse, France: IFAC, 2013. **50**(1): 14992–14999
- 7 Kong De-Zhi, Liu Qiang, Lang Zhi-Qiang. Dynamic correlation based semi-melting condition diagnosis for fused magnesia furnaces. In: Proceedings of the 2018 Chinese Process Control Conference. Shenyang, China, 2018
(孔德志, 刘强, 郎志强. 基于图像动态相关度的电熔镁炉半熔化异常工况诊断, 中国过程控制会议, 沈阳, 中国, 2018)
- 8 Lu Shao-Wen, Wang Ke-Dong, Wu Zhi-Wei, Li Peng- Qi, Guo Zhang. Online detection of semi-molten of fused magnesium furnace based on deep convolutional neural network. *Control and*

- Decision*, 2017, **23**(9): 1–8
(卢绍文, 王克栋, 吴志伟, 李鹏琦, 郭章. 基于深度卷积网络的电熔镁炉欠烧工况在线识别. 控制与决策, 2017, **23**(9): 1–8)
- 9 Wu Gao-Chang, Liu Qiang, Chai Tian-You, Qin S Joe. Abnormal condition diagnosis based on deep learning of image sequences for fused magnesium furnaces. *Acta Automatica Sinica*, 2019, **45**(8): 1475–1485
(吴高昌, 刘强, 柴天佑, 秦泗钊. 基于时序图像深度学习的电熔镁炉异常工况诊断. 自动化学报, 2019, **45**(8): 1475–1485)
- 10 Qin S J. Data-driven fault detection and diagnosis for complex industrial processes. In: Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes. Barcelona, Spain: IFAC, 2009. **42**(8): 1115–1125
- 11 Ji Hong-Quan, He Xiao, Zhou Dong-Hua. Fault detection techniques based on multivariate statistical analysis. *Journal of Shanghai Jiao Tong University*, 2015, **49**(6): 842–848
(纪洪泉, 何潇, 周东华. 基于多元统计分析的故障检测方法. 上海交通大学学报, 2015, **49**(6): 842–848)
- 12 Liu Qiang, Chai Tian-You, Qin S Joe, Zhao Li-Jie. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process. *Control and Decision*, 2010, **25**(6): 801–807
(刘强, 柴天佑, 秦泗钊, 赵立杰. 基于数据和知识的工业过程监视及故障诊断综述. 控制与决策, 2010, **25**(6): 801–807)
- 13 Jia Bao-Zhu, Jia Zhi-Tao, Yu Pei-Wen. Data-driven vessel smart fault diagnosis method. *Control Engineering of China*, 2019, **26**(10): 1892–1898
(贾宝柱, 贾志涛, 余培文. 数据驱动的船舶智能故障诊断方法. 控制工程, 2019, **26**(10): 1892–1898)
- 14 Chen Xiao-Lu, Wang Rui-Xuan, Wang Jing, Zhou Jing-Lin. Industrial process monitoring and fault diagnosis based on hybrid discriminant analysis. *Acta Automatica Sinica*, 2020, **46**(8): 1600–1614
(陈晓露, 王瑞璇, 王晶, 周靖林. 基于混合型判别分析的工业过程监控及故障诊断. 自动化学报, 2020, **46**(8): 1600–1614)
- 15 Jia R X, Wang J, Zhou J L. Fault diagnosis of industrial process based on the optimal parametric t-distributed stochastic neighbor embedding. *Science China Information Sciences*, 2021, **64**: 159204
- 16 Ku W, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis. *Chemometrics and Intelligent Laboratory Systems*, 1995, **30**(1): 179–196
- 17 Chen J, Liu K C. On-line batch process monitoring using dynamic PCA and dynamic PLS models. *Chemical Engineering Science*, 2002, **57**(1): 63–75
- 18 Lu N, Yao Y, Gao F, Wang F. Two-dimensional dynamic PCA for batch process monitoring. *AIChE Journal*, 2005, **51**(12): 3300–3304
- 19 Lin W, Qian Y, Li X. Nonlinear dynamic principal component analysis for on-line process monitoring and diagnosis. *Computers and Chemical Engineering*, 2000, **24**(2): 423–429
- 20 Li G, Liu B, Qin S J, Zhou D H. Dynamic latent variable modeling for statistical process monitoring. In: Proceedings of the 18th World Congress The International Federation of Automatic Control. Milano, Italy: IFAC, 2011. **44**(1): 12886–12891
- 21 Li G, Qin S J, Zhou D H. A new method of dynamic latent-variable modeling for process monitoring. *IEEE Transactions on Industrial Electronics*, 2014, **61**(11): 6438–6448
- 22 Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring. *Journal of Process Control*, 2018, **67**(7): 1–11
- 23 Liu Q, Qin S J, Chai T Y. Decentralized fault diagnosis of continuous annealing processes based on multilevel PCA. *IEEE Transactions on Automation Science and Engineering*, 2013, **10**(3): 687–698
- 24 Alcalá F, Qin S J. Reconstruction-based contribution for process monitoring. *Automatica*, 2009, **7**(45): 1593–1600
- 25 Gonzalez R C, Woods R E. Digital image processing. Englewood: Prentice Hall, 2002. 282–348
- 26 Reinhard E, Ashikmin M, Gooch B, Shirley P. Color transfer between images. *IEEE Computer Graphics & Applications*, 2001, **21**(5): 34–41
- 27 Izadi I, Shah S L, Shook D S, Kondaveeti S R, Chen T W. A framework for optimal design of alarm systems. In: Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes. Barcelona, Spain: IFAC, 2009. **42**(8): 651–656



刘强 东北大学教授. 主要研究方向为数据驱动的建模, 过程监控与故障诊断. 本文通信作者.

E-mail: liuq@mail.neu.edu.cn

(LIU Qiang) Professor at Northeastern University, China. His research interest covers data driven modeling, statistical process monitoring, fault diagnosis of complex industrial processes. Corresponding author of this paper.)



孔德志 东北大学流程工业综合自动化国家重点实验室硕士研究生. 主要研究方向为数据驱动建模与故障诊断.

E-mail: 1770563@stu.neu.edu.cn

(KONG De-Zhi) Master student at the State Key Laboratory of Synthetical Automation for process Industries, Northeastern University. His research interest covers data-driven modeling and fault diagnosis.)



郎自强 英国谢菲尔德大学自动控制与系统工程系教授. 主要研究方向为非线性系统建模、分析、设计和信号处理理论及工程应用.

E-mail: z.lang@sheffield.ac.uk

(LANG Zi-Qiang) Chair professor of Complex Systems Analysis and Design in the Department of Automatic Control and Systems Engineering at the University of Sheffield, UK. His research interest covers nonlinear system modelling, analysis, design and signal processing as well as their engineering applications.)