

# 自动编码器与典型相关分析方法联合驱动的 工业过程质量监测

董 洁, 孙瑞琪, 彭开香<sup>†</sup>, 唐 鹏

(北京科技大学 自动化学院, 北京 100083; 工业过程知识自动化教育部重点实验, 北京 100083)

**摘要:** 本文将自动编码器(AE)特征提取方法和典型相关分析方法(CCA)有机结合, 提出了一种联合驱动的质量监测模型及其质量相关的故障检测方法. 首先, 利用AE算法对输入样本进行无监督自动学习和重构, 实现数据的特征提取和降维; 其次, 利用CCA算法实现特征与质量变量关联最大化, 建立质量变量与特征变量的关系模型; 根据监测模型的潜结构投影, 构建 $T^2$ 统计量和SPE统计量及其相应控制限. 将提出的方法用于分析带钢热连轧过程现场实际数据, 结果表明, 基于自动编码器-典型相关分析方法(AE-CCA)的质量监测方法能够准确的检测出故障, 并且检测效果优于传统的核典型相关分析(KCCA)算法.

**关键词:** 故障诊断; 质量监测; 典型相关分析方法(CCA); 自动编码器-典型相关分析方法(AE-CCA); 带钢热连轧

**引用格式:** 董洁, 孙瑞琪, 彭开香, 等. 自动编码器与典型相关分析方法联合驱动的工业过程质量监测. 控制理论与应用, 2019, 36(9): 1493 – 1500

DOI: 10.7641/CTA.2019.80554

## Industrial process quality monitoring method and application joint-driven by automatic encoder and canonical correlation analysis method

DONG Jie, SUN Rui-qi, PENG Kai-xiang<sup>†</sup>, TANG Peng

(School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China;  
Key Laboratory of Knowledge Automation for Industrial Processes of Ministry of Education, Beijing 100083, China)

**Abstract:** In this paper, the feature extraction method of automatic encoder (AE) and canonical correlation analysis method (CCA) are organically combined, and a joint-driven quality monitoring model and quality-related fault detection method are proposed. Firstly, AE algorithm is used to automatically learn and reconstruct the input samples to complete the feature extraction and dimensionality reduction of the data. Secondly, CCA algorithm is used to maximize the correlation between the feature and the quality variables to establish the monitoring model of quality variables and characteristics. According to the latent structure projection of the monitoring model,  $T^2$  statistics and SPE statistics and their control limits are constructed. The proposed method was applied to the actual data of hot strip mill process (HSMP). The result shows that the quality monitoring method based on AE-CCA can detect faults accurately, and the effect of detection is significantly better than that of traditional kernel canonical correlation analysis (KCCA) algorithm.

**Key words:** fault diagnosis; quality monitoring; canonical correlation analysis method(CCA); automatic encoder-canonical correlation analysis method(AE-CCA); hot strip mill process(HSMP)

**Citation:** DONG Jie, SUN Ruiqi, PENG Kaixiang, et al. Industrial process quality monitoring method and application joint-driven by automatic encoder and canonical correlation analysis method. *Control Theory & Applications*, 2019, 36(9): 1493 – 1500

收稿日期: 2018-07-25; 录用日期: 2019-01-21.

<sup>†</sup>通信作者. E-mail: kaixiang@ustb.edu.cn; Tel.: +86 10-62333084.

本文责任编辑: 张化光.

国家自然科学基金项目(61473033, 61773053, 61873024), 国家重点研发计划项目(2017YFB0306403), 北京科技大学基本科研业务费项目(FRF-GF-17-A4, FRF-BD-18-002A)资助.

Supported by the National Natural Science Foundation of China (61473033, 61773053, 61873024), the National Key R&D Program of China (2017YFB0306403) and the Fundamental Research Funds for the China Central Universities of USTB (FRF-GF-17-A4, FRF-BD-18-002A).

### 1 引言

随着生产企业的规模化发展以及对产品质量的要求不断提高,工业过程变得日益复杂,传统的控制方法遇到了诸多问题,过程发生故障的可能性和危害程度也随之增加.所以,建立有效的监控系统,快速检测和识别各种类型的潜在异常和故障,最大限度地抑制性能下降和避免危险情况发生就显得至关重要.采用合适的故障检测与诊断方法,来保证复杂工业系统的安全运行以及稳定的产品质量,已经成为过程监控的首要任务<sup>[1]</sup>.

目前研究中基于模型的故障诊断方法已经趋于成熟,这类方法需要已知清晰的物理模型或建立近似模型,利用残差发生器产生残差信号,通过残差评估并通过决策函数判断故障的发生;基于经验知识的方法适用于不易建立机理模型、传感器不充足的“信息缺乏”系统,但其中需要很多复杂高深的专业知识以及长期积累的经验并且不易操作<sup>[2-5]</sup>.随着自动化仪器仪表在生产过程中的广泛应用,大量的过程数据被采集存储下来,使得基于数据驱动的故障诊断方法成为当今过程监控领域的主流技术,其中20世纪90年代提出的多元统计过程监控(multivariate statistical process monitoring, MSPM)技术已经受到了学术界和工业生产领域的高度重视,包括主元分析、偏最小二乘、规范变量分析、Fisher判别分析等多元投影降维方法,都是利用特征统计量判断过程异常<sup>[6]</sup>.

基于机器学习的故障诊断方法通过训练数据建立故障识别和分类的映射,然后将训练好的模型用于新观测的数据来判断是否异常.支持向量机(support vector machines, SVM)和人工神经网络是两种典型的机器学习方法.基于SVM的故障诊断方法将诊断问题看成样本分类的问题,根据历史数据训练出分类器,将数据空间划分成不同的区域,然后将测试数据投影至划分好的空间,根据所在区域判断其对应的运行状态<sup>[7]</sup>.基于人工神经网络的故障诊断方法利用数据样本训练神经网络,获得最佳拟合模型,设置输出模式,然后将测试数据输入到训练好的模型中,通过前向计算得到网络的输出,即样本对应的故障模式.但在实际应用中,基于统计规律的浅层学习方法的问题逐渐暴露出来:学习能力不强,只能提取初级特征.在计算机硬件技术迅速发展的背景下,深度学习模型诞生.深度学习网络是含有多隐含层的人工神经网络,通过组合低层特征形成更加抽象的高层特征表示,具有良好的特征学习能力<sup>[8]</sup>.深度学习非线性表达能力强,判别能力好,已经在图像识别、手势识别、语音识别、医疗识别肿瘤细胞等领域取得了突破性进展,目前深度神经网络也逐渐应用到过程监控和机械设备的故障诊断等领域.

特征提取是故障诊断技术的关键步骤,不同的特征表示、提取与选择过程将导致故障诊断效果截然不同,本文提出自动编码器-典型相关分析方法(automatic

encoder-canonical correlation analysis method, AE-CCA)联合驱动算法提取有效数据特征,通过最大化特征变量与质量变量的相关性,建立了质量相关的故障检测模型,并与基于KCCA的故障检测方法进行实验对比,利用带钢热连轧生产过程实际数据,验证了本文提出的AE-CCA算法的有效性.

### 2 基于AE的特征提取

自动编码器(automatic encoder, AE)是一种对称的3层无监督神经网络,分为输入层、隐含层(编码层)和输出层(解码层),结构如图1所示,该网络隐含层对输入数据编码,输出层重构输入,然后重构误差反向传播调整网络参数,使得隐含层学习到输入的特征,获得最佳的数据表达,从而整个网络拥有无监督自动学习的能力<sup>[9]</sup>.




图1 自动编码器示意图  
Fig. 1 Diagram of AE

AE算法真正关心的不是输出(解码),而是中间的编码,或者说是从输入到编码的映射.对 $x_i (i = 1, \dots, n)$ 降维(编码)得到的 $y_j (j = 1, \dots, m) (m < n)$ ,如果重构(解码)后得到的系统输出 $\hat{x}_i$ 还能复原输入 $x_i$ ,则说明编码 $y_i$ 已经承载了原始数据的重要因素,即提取出了原信息的主要特征,如图2所示.




图2 特征提取示意图

Fig. 2 Diagram of feature extraction

将给定数据  $X \in \mathbb{R}^n$  输入到网络中, 从输入层到隐含层是编码过程, 经过线性变化和 Sigmoid 激活函数的作用下, 编码器将数据  $X$  压缩表示为  $Y \in \mathbb{R}^m (m < n)$ .

$$Y = s_f(WX + b), \quad (1)$$

$$s_f(x) = 1/(1 + e^{-x}), \quad (2)$$

其中:  $X$  和  $Y$  是  $n$  维和  $m$  维向量,  $W$  是  $m \times n$  维权重矩阵,  $b$  是  $m$  维偏置矩阵,  $s_f$  为 Sigmoid 激活函数.

经过从隐含层到输出层的解码过程, 解码器将降维数据  $Y$  变换为重构数据  $\hat{X} \in \mathbb{R}^n$ , 如下所示:

$$\hat{X} = s_g(W^*Y + b^*), \quad (3)$$

其中:  $W^*$  是  $n \times m$  维权重矩阵,  $W^*$  通常取  $W^T$ ,  $b^*$  是一个  $n$  维偏置矩阵,  $s_g$  为解码器激活函数, 通常取 Sigmoid 函数或恒等函数, 则 AE 参数表示为  $\theta = \{W, W^*, b, b^*\}$ .

输出层的输出  $\hat{X}$  可以看作是对输入  $X$  的一个估计, AE 算法就是通过使  $\hat{X}$  尽可能接近  $X$  来训练网络参数  $\theta$ . 其中  $\hat{X}$  与  $X$  的接近程度用重构误差函数  $L(x_i, \hat{x}_i)$  来描述. 当  $s_g$  为恒等函数时:

$$L(x_i, \hat{x}_i) = \|x_i - \hat{x}_i\|^2. \quad (4)$$

当  $s_g$  为 Sigmoid 函数时,

$$L(x_i, \hat{x}_i) = -\sum_{i=1}^n [x_i \ln(\hat{x}_i) + (1 - x_i) \ln(1 - \hat{x}_i)]. \quad (5)$$

训练样本集  $S = \{x_i\}_{i=1}^n$  的整体损失函数为

$$J_{AE}(\theta) = \sum_{x_i \in S} L(x_i, \hat{x}_i). \quad (6)$$

为了避免出现权重过大而造成过拟合的现象, 设置一个权重衰减项:

$$D = \frac{1}{2} \|W\|_2^2. \quad (7)$$

由式(6)与式(7)可得目标函数为

$$J = \frac{1}{2n} \sum_{i=1}^n L(x_i, \hat{x}_i) + \lambda D, \quad (8)$$

其中系数  $\lambda$  初始值为 0, 如果训练模型出现过拟合现象, 多次测试, 取得合适的  $\lambda$  值.

通过表 1 所示的梯度下降法对 AE 的损失函数作最小化处理.

表 1 梯度下降法

Table 1 Gradient descent

- |  |
|--|
| 1) 初始化参数: $\Delta\theta = 0$ ;   |
| 2) 梯度算法计算: $\Delta\theta = \Delta\theta + \nabla \frac{\partial J}{\partial \theta}$ ; |
| 3) 更新参数: $\theta = \theta - \alpha [(\frac{1}{n} \Delta\theta) + \lambda \theta]$ .    |

因此, AE 算法在每个迭代过程中, 用式(9)更新权

重矩阵:

$$W \leftarrow W - l \times \frac{\partial J}{\partial W}, \quad (9)$$

其中:  $l$  为学习率;  $b$  和  $b^*$  采用相同的方式更新, 当一个完整的 AE 网络训练完成后, 就能够得到网络参数  $\theta = \{w, w^*, b, b^*\}$  和数据特征, 利用学到的特征进行后续的操作.

### 3 AE-CCA 的质量监测模型与故障检测

#### 3.1 CCA 算法基本思想

典型相关分析 (canonical correlation analysis method, CCA) 是由 Hotelling 于 1935 年提出的研究两组变量相关性的一种统计方法<sup>[10]</sup>. 为了研究两组变量  $X^T = (x_1 \ x_2 \ \dots \ x_p)$  与  $Y^T = (y_1 \ y_2 \ \dots \ y_q)$  的相关性, 新定义两组变量  $U = A^T X = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_p x_p$  和  $V = B^T Y = \beta_1 y_1 + \beta_2 y_2 + \dots + \beta_q y_q$  为两组原变量的一个线性组合, 可以将问题转化为通过研究  $U$  和  $V$  这两个变量的相关性来确定原来两组变量之间的相关关系.

Pearson 相关性系数  $\rho$  是用来衡量变量的相关性, 输出范围为  $-1$  到  $1$ ,  $0$  代表无相关, 负值代表负相关, 正值代表正相关, 公式如下:

$$\rho(X, Y) = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sigma_X \sigma_Y} = \frac{E[(X - \mu_X)(Y - \mu_Y)]}{\sqrt{\sum_{i=1}^n (X_i - \mu_X)^2} \sqrt{\sum_{i=1}^n (Y_i - \mu_Y)^2}}. \quad (10)$$

将两组变量合并成一个  $n \times (p+q)$  维的数据矩阵, 记为  $Z = [X_{n \times p}, Y_{n \times q}]_{n \times (p+q)}$ .

$Z$  的协方差矩阵与其相关系数矩阵相等, 记为  $R = \begin{bmatrix} R_{11} & R_{12} \\ R_{21} & R_{22} \end{bmatrix}$ , 其中:  $R_{11} = \text{cov}(X, X)$ ,  $R_{22} = \text{cov}(Y, Y)$ ,  $R_{12} = R_{21}^T = \text{cov}(X, Y)$ . 要使  $U$  与  $V$  两者相关程度达到最大, 即  $\rho(U, V)$  达到最大, 关键问题是求出  $A$  与  $B$ , 其中:  $A^T = (\alpha_1 \ \alpha_2 \ \dots \ \alpha_p)$ ,  $B^T = (\beta_1 \ \beta_2 \ \dots \ \beta_q)$ .

显然,  $U$  与  $V$  的均值为 0, 方差分别是  $\text{var}(U) = A^T R_{11} A$  和  $\text{var}(V) = B^T R_{22} B$ ,  $\text{cov}(U, V) = A^T R_{12} B$  是协方差, 所以  $U$  与  $V$  的相关系数为

$$\rho(U, V) = \frac{A^T R_{12} B}{\sqrt{A^T R_{11} A} \sqrt{B^T R_{22} B}}. \quad (11)$$

CCA 算法就可以转化成优化问题的解:

$$J = \max(\rho) = \max(A^T R_{12} B), \quad (12)$$

其中  $A^T R_{11} A = B^T R_{22} B = 1$  是约束条件.

应用奇异值分解法 SVD 优化函数:

假设  $A = R_{11}^{-1/2} u$ ,  $B = R_{22}^{-1/2} v$ , 代入优化函数的约束条件为

$$\begin{cases} A^T R_{11} A = u^T R_{11}^{-1/2} R_{11} R_{11}^{-1/2} u = 1, \\ B^T R_{22} B = v^T R_{22}^{-1/2} R_{22} R_{22}^{-1/2} v = 1, \end{cases} \quad (13)$$

可得  $u^T u = 1, v^T v = 1$ .

优化目标转换成

$$J = \max_{u,v} u^T R_{11}^{-1/2} R_{12} R_{22}^{-1/2} v, \quad (14)$$

其中  $u^T u = 1, v^T v = 1$  是约束条件.

定义矩阵  $\gamma$  作为相关性评估矩阵:

$$\gamma = R_{11}^{-1/2} R_{12} R_{22}^{-1/2}. \quad (15)$$

将  $u$  和  $v$  视为矩阵  $\gamma$  的某一奇异值对应的左右奇异向量,  $\text{rank}(\gamma) = \kappa$ , 对  $\gamma$  进行SVD分解:

$$\gamma = \Gamma \Lambda \Delta^T, \quad (16)$$

其中:

$$\begin{aligned} \Gamma &= (\gamma_1, \dots, \gamma_s), \quad \Delta = (\delta_1, \dots, \delta_m), \\ \Lambda &= \begin{pmatrix} \Lambda_\kappa & 0 \\ 0 & 0 \end{pmatrix}, \quad \Lambda_\kappa = \text{diag}\{\lambda_1, \dots, \lambda_\kappa\}. \end{aligned}$$

显然,

$$\max(u^T R_{11}^{-1/2} R_{12} R_{22}^{-1/2} v) = \max(u^T \Gamma \Lambda \Delta^T v). \quad (17)$$

由于  $\Gamma$  和  $\Delta$  为正交阵, 则  $u^T \Gamma$  和  $\Delta^T v$  可以得到一个标量值为1, 其余标量值为0的两个向量. 那么  $u^T \cdot R_{11}^{-1/2} R_{12} R_{22}^{-1/2} v$  的最大值就是奇异值的最大值, 利用其对应的左右奇异向量可以求出系数

$$A = R_{11}^{-1/2} \Gamma(:, 1 : \kappa), \quad B = R_{22}^{-1/2} \Delta(:, 1 : \kappa).$$

### 3.2 基于AE-CCA的质量监测模型

设  $U \in \mathbb{R}^{n \times l}$  和  $Y \in \mathbb{R}^{n \times m}$  分别是过程中测量得到的输入和输出向量, 并且服从正态分布:

$$\begin{cases} U \sim N(\mu_u, \Sigma_u), \\ Y \sim N(\mu_y, \Sigma_y). \end{cases} \quad (18)$$

均值标准化的输入输出向量可以表示为

$$\begin{cases} U_0 = U - \mu_u, \\ Y_0 = Y - \mu_y, \end{cases} \quad (19)$$

其中  $U_0 \in \mathbb{R}^{n \times l}$  和  $Y_0 \in \mathbb{R}^{n \times m}$ .

一般输入  $U_0$  的维数较高, 所以先用AE算法对  $U_0$  提取特征降维. 构造输入层、隐含层和输出层节点数分别为  $h_1 \sim h_3$  的AE网络, 其中  $h_1 = h_3$  为输入数据的维数  $l$ , 隐含层  $h_2$  的个数可以参考以下公式:

$$\begin{cases} h_2 \leq \sqrt{h_1 + h_3} + a, \\ h_2 \approx \log_2 h_1, \end{cases} \quad (20)$$

其中  $a \in (1, 10)$ . 式(20)可以确定隐含层节点数量的大致范围, 再通过仿真查看误差数值和曲线效果, 最终

确定隐含层节点数.

将标准化数据  $U_0$  输入AE网络, 赋予网络权值初值, 用得到的误差反向调节网络权值, 训练后获得合适的网络参数  $\theta = \{W, W^*, b, b^*\}$ , 使得误差低于0.1, 隐含层输出特征:

$$U_s = s_f(WU_0^T + b) \in \mathbb{R}^{n \times s}, \quad s < l. \quad (21)$$

则AE-CCA算法的关键问题为求解

$$J = \max_{J_s, L_s} J_s^T \Sigma_{U_s, Y} L_s, \quad (22)$$

其中:  $J_s^T \Sigma_{U_s} J_s = L_s^T \Sigma_Y L_s = 1$  是约束条件,  $\Sigma_{U_s, Y} = \text{cov}(U_s, Y)$ ,  $\Sigma_{U_s} = \text{cov}(U_s, U_s)$ ,  $\Sigma_Y = \text{cov}(Y, Y)$ . 计算特征与质量变量的协方差:

$$\begin{cases} \Sigma_{U_s} \approx \frac{1}{n-1} \sum_{i=1}^n (u_i - \mu_u)(u_i - \mu_u)^T, \\ \Sigma_Y \approx \frac{1}{n-1} \sum_{i=1}^n (y_i - \mu_y)(y_i - \mu_y)^T, \\ \Sigma_{U_s, Y} \approx \frac{1}{n-1} \sum_{i=1}^n (u_i - \mu_u)(y_i - \mu_y)^T, \end{cases} \quad (23)$$

其中  $\mu_u$  和  $\mu_y$  分别为  $U_s$  和  $Y$  的均值.

$\gamma$  作为输入输出的相关性评估依据:

$$\gamma = \Sigma_{U_s}^{-1/2} \Sigma_{U_s, Y} \Sigma_Y^{-1/2}. \quad (24)$$

对  $\gamma$  进行SVD分解, 得到

$$J_s = \Sigma_{U_s}^{-1/2} \Gamma(:, 1 : \kappa), \quad L_s = \Sigma_Y^{-1/2} \Delta(:, 1 : \kappa),$$

构造新的典型相关变量为  $\Phi_u = J_s^T u_s$  和  $\Phi_y = L_s^T y$ , 建立AE-CCA的质量监测模型, 描述输入输出的稳定关系

$$\Phi_y(k) = \Phi_u(k) + v(k), \quad (25)$$

其中  $v(k)$  表示与  $\Phi_y(k)$  有着微弱相关噪声项.

按下式定义残差向量<sup>[11]</sup>:

$$r(k) = \Phi_y(k) - \Lambda_\kappa \Phi_u(k). \quad (26)$$

构造如下形式的两个统计量  $T^2$  和  $Q$  用于过程监测:

$T^2$  统计量用于检测发生在输入子空间且与输出相关的那部分故障, 构造  $T^2$  统计量如下:

$$T^2(k) = U_s^T J_s J_s^T U_s \leq J_{th, T^2}, \quad (27)$$

其中  $J_{th, T^2}$  表示  $T^2$  统计量的控制限, 其数据样本服从  $F$  分布, 表达式为

$$J_{th, T^2} = \frac{\kappa(N^2 - \kappa)}{N(N - \kappa)} F_{1-\alpha}(\kappa, N - \kappa), \quad (28)$$

其中:  $F_{1-\alpha}(\kappa, N - \kappa)$  表示带有  $\kappa$  和  $N - \kappa$  个自由度, 置信度为  $1 - \alpha$  的  $F$  分布的临界值. 正常生产工况时,  $T^2$  统计量处于控制限内, 如果  $T^2 > J_{th, T^2}$ , 则表示系

统有故障发生。

$Q$  统计量用于检测发生在输出子空间且与输入相关的那部分故障, 构造的  $Q$  统计量如下:

$$Q(k) = r^T(k)(1 - \Lambda_\kappa^2)^{-1}r(k) \leq J_{th,Q}, \quad (29)$$

其中:  $J_{th,Q}$  表示  $Q$  统计量的控制限; 正常情况下,  $Q$  统计量处于控制限内, 如果  $Q > J_{th,Q}$  时, 表示系统有故障发生, 控制限  $J_{th,Q}$  为

$$J_{th,Q} = g\chi_{1-\alpha}^2(k). \quad (30)$$

自由度为  $h$ , 其中:  $g = S/2\mu$ ,  $h = 2\mu^2/S$ ,  $S$  与  $\mu$  可以用下式计算:

$$\mu = \frac{1}{N} \sum_{k=1}^N Q_{train}(k), \quad (31)$$

$$S = \frac{1}{N-1} \sum_{k=1}^N (Q_{train}(k) - \mu)^2. \quad (32)$$

基于 AE-CCA 质量相关的故障检测流程框架如图 3 所示, 算法步骤总结在表 2 中。

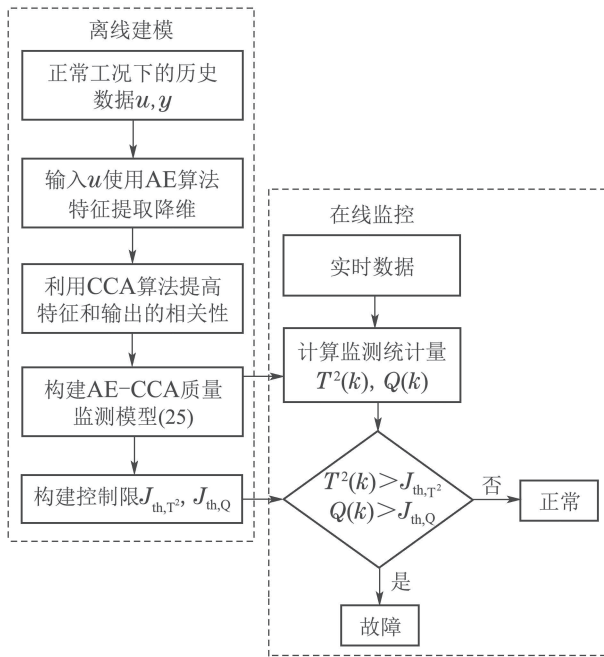


图 3 基于 AE-CCA 质量相关的故障检测图  
Fig. 3 Quality related fault detection diagram based on AE-CCA

表 2 基于 AE-CCA 的故障检测方案

Table 2 Fault detection scheme based on AE-CCA

- 1) 标准化过程数据的  $u_0, y_0$ ;
- 2) 构造并输入数据训练 AE 网络, 隐含层输出特征;
- 3) 计算相关性矩阵  $\gamma$ , 并作 SVD 分解  $\Sigma_u^{-1/2} \Sigma_{uy} \Sigma_y^{-1/2} = \Gamma \Lambda \Delta^T$ , 得到特征矩阵  $\Lambda_\kappa = \text{diag}\{\lambda_1, \dots, \lambda_\kappa\}$ ;
- 4) 构造新变量  
 $J_s = \Sigma_u^{-1/2} \Gamma(:, 1 : \kappa)$ ,  $L_s = \Sigma_y^{-1/2} \Delta(:, 1 : \kappa)$ ;
- 5) 构造  $T^2$  和  $Q$  统计量, 确定控制限。

### 4 带钢热连轧过程的仿真分析

带钢热连轧是钢铁生产流程的关键工序, 现代带钢热连轧过程主要包含加热炉、粗轧机组、传送带和飞剪、精轧机组、层流冷却装置、卷取机、输出辊道等装置<sup>[12]</sup>, 如图 4 所示。

热连轧工艺流程可以描述为: 装钢机将连铸坯装入步进式加热炉内进行加热(加热后连铸坯出炉温度一般在  $800 \sim 1200^\circ\text{C}$  之间); 加热好的板坯经过高压水除鳞处理后送入粗轧机组(板坯厚度在  $200 \text{ mm}$  左右)轧制  $3 \sim 5$  道次, 再经过保温、飞剪、高压水除鳞等工序送入精轧机组; 精轧机组一般由六至七架轧机组成, 机架间设有活套装置, 并设有液压 AGC 自动厚度控制系统, 用于保证带钢厚度精度及板形要求; 精轧后通过层流冷却系统进行加速冷却控制, 最后卷取成钢卷<sup>[13]</sup>。

实际生产过程最关心的就是产品质量和生产效率, 因此带钢热连轧产品质量的在线监测与故障诊断具有很重要的现实意义。整个热轧过程影响产品质量的因素有产品厚度、宽度、板形和温度历程等, 过程中一旦发生故障, 仅靠延迟滞后的反馈控制策略很难保证产品质量<sup>[14]</sup>。所以本文对精轧阶段进行过程监测研究, 重点研究出口厚度这一关键因素, 利用热连轧现场(辽宁鞍钢集团有限公司  $1700 \text{ mm}$  带钢热连轧生产线)采集的大量能够反映生产过程的数据, 考虑生产过程的“厚度质量变量”及影响质量的“关键过程变量”以此来实现过程厚度质量监测, 相关变量的详细情况如表 3 所示。




图 4 带钢热连轧生产流程图  
Fig. 4 HSMP flow chart

表3 精轧监测过程变量的选取

Table 3 Selection of process variables for finishing rolling monitoring

变量编号	类别	描述	单位
1-7	测量变量	第 <i>i</i> 机架的平均辊缝, $i = 1, \dots, 7$	mm
8-14	测量变量	第 <i>i</i> 机架的轧制力, $i = 1, \dots, 7$	MN
15-20	测量变量	第 <i>i</i> 机架的弯辊力, $i = 2, \dots, 7$	MN
21	质量变量	精轧出口厚度	mm

为了测试本文提出的AE-CCA联合驱动的质量监测算法, 利用MATLAB对带钢热连轧过程的3000组历史数据进行离线训练, 建立质量监测模型, 再分别利用3000组不同故障的实时数据进行故障检测, 实现在线监控的目的。

仿真验证选取了3个典型故障, 如表4所示, 故障1是第5个机架测量弯辊力的传感器出现故障, 测量值发生阶跃跳变. 故障发生时, 变量 $x_{18}$ 的测量值突然变大, 随着AGC对后面两个机架的反馈调节, 第6个和第7个机架的弯辊力的值也会发生变化. 但是这种故障只会引起带钢板形的变化, 对钢板出口厚度的影响较小, 这种故障是质量不相关的, 不会被质量监测模型检测到. 故障2是第2和第3个机架之间控制冷却水阀的执行器发生故障, 这种故障在精轧过程是偶然发生的. 故障发生时, 直接影响第3个机架及后面机架的轧制力, 由于本身机架AGC的作用, 辊缝发生变化, 直接影响产品质量. 故障3是第4机架液压压下辊缝控制系统失效, 这种故障发生时, 直接影响第4机架辊缝采样值 $x_4$ , 第4机架的总轧制力的采样值 $x_{11}$ 也受到影响, 后面机架的辊缝轧制力都会发生改变, 进而影响最后的出口厚度。

表4 热连轧故障说明

Table 4 Hot rolling fault description

故障描述	发生时间	类型
第5机架的弯辊力测量传感器故障	第10 s	质量不相关
第2和第3机架之间的冷却水阀出现故障	第10 s	质量相关
第4机架液压压下辊缝控制系统失效	第20 s	质量相关

为了验证AE-CCA算法的有效性和优越性, 选择同样用于处理非线性数据的KCCA算法进行对比测试. KCCA算法选择合适的核函数将数据样本非线性映射到高维特征空间, 描述过程数据与质量数据之间的非线性关系, 然后在特征空间利用线性CCA算法继续建模<sup>[15]</sup>.

对比图5-6应用KCCA和AE-CCA两种算法对故障1的检测结果, 出现故障1后在控制器的调解下, 不

影响质量变量,  $T^2$ 统计量不会超过控制限, 另一方面 $Q$ 统计量超过了控制限, 表明这种故障影响了过程变量, 所以应该视为质量无关的故障, 两种算法的检测结果良好。




图5 故障1基于KCCA的故障检测结果

Fig. 5 Fault 1 detection results based on KCCA




图6 故障1基于AE-CCA的故障检测结果

Fig. 6 Fault 1 detection results based on AE-CCA

对比图7-8应用两种算法对故障2的检测结果, 故障2是质量相关的故障,  $T^2$ 统计量和 $Q$ 统计量都超过了控制限, 应用传统的KCCA算法建模得到的故障检测结果存在较高的误报率, 故障2是过程进行到第10 s发生, 持续15 s, 到25 s后恢复正常, 即从1000个采样点开始发生故障, 对比之下, 应用AE-CCA算法的检测效果更好, 能够及时的检测出故障, 并且误报率低。





图7 故障2基于KCCA的故障检测结果  
Fig. 7 Fault 2 detection results based on KCCA





图8 故障2基于AE-CCA的故障检测结果

Fig. 8 Fault 2 detection results based on AE-CCA




图9 故障3基于KCCA的故障检测结果

Fig. 9 Fault 3 detection results based on KCCA





图10 故障3基于AE-CCA的故障检测结果

Fig. 10 Fault 3 detection results based on AE-CCA

对比图9-10应用两种算法对故障3的检测结果, 故障3也是质量相关的故障,  $T^2$ 统计量和 $Q$ 统计量都超过了控制限, 传统的KCCA算法建模也可以得到很好的检测结果, 故障3是过程进行到第20 s发生, 一直持续, 即从2000个采样点开始发生故障, 对比之下, 应用AE-CCA算法的检测效果更好, 能够及时的检测出故障, 并且误报率低。



从表5中AE-CCA和KCCA两种算法的检测率和误报率对比情况来看, 针对带钢热连轧生产过程中的3种故障, 故障检测率基本相似, 但故障误报率大不相同, AE-CCA算法故障误报率更低, 更直观的看出AE-CCA算法检测结果更好。

表5 两种方法故障检测率和误报率对比结果

Table 5 Comparison of failure detection rate and false alarm rate between the two methods

故障	故障1		故障2		故障3	
	检测率	误报率	检测率	误报率	检测率	误报率
AE-CCA	0.987	0.043	0.967	0.033	0.99	0.112
KCCA	0.985	0.157	0.989	0.207	0.926	0.0395

### 5 结论

本文提出一种基于AE-CCA的质量相关的过程监测方法, 该方法通过特征学习实现了数据降维, 然后构建特征变量与质量变量之间的关系模型, 同时设计相应的统计量和控制限监测质量指标的波动情况. 将AE-CCA算法应用到带钢热连轧过程的现场实际数据分析, 选取两个热连轧过程常见的故障进行仿真研

究,结果表明,AE-CCA算法能够及时的检测出故障,算法有效,并与KCCA算法进行了检测效果对比,可以看出AE-CCA算法应用于过程监控效果更佳。

### 参考文献:

- [1] WANG Guozhu, LIU Jianchang, LI Yuan, et al. Fault diagnosis of industrial processes based on weighted  $k$ -nearest neighbor reconstruction analysis. *Control Theory & Applications*, 2015, 32(7): 873 – 880. (王国柱, 刘建昌, 李元, 等. 加权 $k$ 最近邻重构分析的工业过程故障诊断. 控制理论与应用, 2015, 32(7): 873 – 880.)
- [2] QIN S J. Survey on data-driven industrial process monitoring and diagnosis. *Annual Reviews in Control*, 2012, 36(2): 220 – 234.
- [3] GAO Z, CECATI C, DING S X. A survey of fault diagnosis and fault-tolerant techniques-part I: fault diagnosis with model-based and signal-based approaches. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757 – 3767.
- [4] YIN S, LI X, GAO H, et al. Data-based techniques focused on modern industry: an overview. *IEEE Transactions on Industrial Electronics*, 2015, 62(1): 657 – 667.
- [5] ZHOU D H, HU Y Y. Fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2009, 35(6): 748 – 758.
- [6] QIN S J, ZHENG Y. Quality-relevant and process-relevant fault monitoring with concurrent projection to latent structures. *AIChE Journal*, 2013, 59(2): 496 – 504.
- [7] WANG Jianjian, HE Feng, WU Zixuan, et al. Construction of Pad'e32 smooth support vector machine model and its application. *Control Theory & Applications*, 2018, 35(9): 1302 – 1310. (王建建, 何枫, 吴子轩, 等. Pad'e32光滑支持向量机模型的构造及其应用. 控制理论与应用, 2018, 35(9): 1302 – 1310.)
- [8] SHAO H, JIANG H, ZHANG H, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network. *IEEE Transactions on Industrial Electronics*, 2018, 65(3): 2727 – 2736.
- [9] LIU Y, FENG X, ZHOU Z. Multimodal video classification with stacked contractive autoencoders. *Signal Processing*, 2016, 120: 761 – 766.
- [10] AKAHO S. A kernel method for canonical correlation analysis. *ArXiv Preprint Cs/0609071*, 2006.
- [11] CHEN Z, ZHANG K, DING S X, et al. Improved canonical correlation analysis-based fault detection methods for industrial processes. *Journal of Process Control*, 2016, 41: 26 – 34.
- [12] MA L, DONG J, PENG K, et al. A novel data-based quality-related fault diagnosis scheme for fault detection and root cause diagnosis with application to hot strip mill process. *Control Engineering Practice*, 2017, 67: 43 – 51.
- [13] PENG K, ZHANG K, YOU B, et al. Quality-relevant fault monitoring based on efficient projection to latent structures with application to hot strip mill process. *IET Control Theory and Applications*, 2015, 9(7): 1135 – 1145.
- [14] ZHANG K, DONG J, PENG K. A novel dynamic non-Gaussian approach for quality-related fault diagnosis with application to the hot strip mill process. *Journal of the Franklin Institute*, 2017, 354(2): 702 – 721.
- [15] ZHU Q, LIU Q, QIN S J. Quality-relevant fault detection of nonlinear processes based on kernel concurrent canonical correlation analysis. *2017 American Control Conference (ACC)*. Seattle, WA, USA: IEEE, 2017: 5404 – 5409.

### 作者简介:

**董洁** 教授, 博士生导师, 目前研究方向为复杂系统建模与控制、复杂工业系统的故障诊断与一体化控制, E-mail: dongjie@ies.ustb.edu.cn;

**孙瑞琪** 硕士研究生, 目前研究方向为复杂工业系统质量相关的故障诊断, E-mail: 15510626728@126.com;

**彭开香** 教授, 博士生导师, 目前研究方向为复杂工业系统故障诊断与容错控制, E-mail: kaixiang@ustb.edu.cn;

**唐鹏** 博士研究生, 目前研究方向为复杂工业系统故障诊断, E-mail: gnepgnat@163.com.