

# 基于动态建模与重构的列车轴承故障检测和定位

刘强<sup>1</sup> 方彤<sup>1</sup> 董一凝<sup>2</sup> 秦泗钊<sup>3</sup>

**摘要** 列车运行时轴承故障的检测与定位对于列车运行安全与健康维护至关重要. 现有的轴承故障报警系统主要是基于单一轴温变量的规则诊断, 报警不及时. 针对上述问题, 本文结合运行于相似环境和速度的同车多轴轴温的相关性及轴温动态性, 提出了一种数据驱动的基于多轴轴温动态潜结构的列车轴承故障检测与定位方法. 首先, 提出基于动态内在典型相关分析 (Dynamic-inner canonical correlation analysis, DiCCA) 的列车多轴轴温动态潜结构建模方法; 其次, 利用所建立的模型, 提出基于 DiCCA 综合指标的列车轴承故障检测方法; 在此基础上, 提出基于 DiCCA 多向重构的列车轴承故障定位方法. 利用某列车实际运行时的轴温数据进行验证, 结果表明了所提方法的有效性.

**关键词** 故障检测, 故障定位, 动态潜结构建模, 多方向重构

**引用格式** 刘强, 方彤, 董一凝, 秦泗钊. 基于动态建模与重构的列车轴承故障检测和定位. 自动化学报, 2019, 45(12): 2233-2241

**DOI** 10.16383/j.aas.c190247

## Dynamic Modeling and Reconstruction Based Fault Detection and Location of Train Bearings

LIU Qiang<sup>1</sup> FANG Tong<sup>1</sup> DONG Yi-Ning<sup>2</sup> QIN S. Joe<sup>3</sup>

**Abstract** The effective fault detection and diagnosis is necessary for operation safety and maintenance of the trains. The existing bearing alarm system normally applies rule-based method that cannot detect the fault into account before the bearing is heavily damaged. In this paper, taking the correlation and dynamic relation of multi-bearing temperatures, a data-driven dynamic latent structure based train bearing fault detection and diagnosis method is proposed. Firstly, a dynamic-inner canonical correlation analysis (DiCCA) based dynamic latent structure method is applied to extract the cross and auto dynamic relations within multi-dimensional bearing temperatures of the train. Secondly, a DiCCA based combined index is defined for fault detection of dynamic system and applied to detect the operational abnormality of the bearings. Thirdly, a DiCCA based multi-directional reconstruction method is proposed to locate the faulty bearing. Finally, application results using bearing temperature data collected from the practical operation of a train demonstrate the effectiveness of the proposed method.

**Key words** Fault detection, fault location, dynamic latent structure modeling, multi-directional reconstruction

**Citation** Liu Qiang, Fang Tong, Dong Yi-Ning, Qin S. Joe. Dynamic modeling and reconstruction based fault detection and location of train bearings. *Acta Automatica Sinica*, 2019, 45(12): 2233-2241

列车运行时的轴承故障是可能导致铁路降速停车、引起线路晚点与瘫痪, 甚至导致人员伤亡的重

大安全隐患. 该故障的及时检测与准确定位是保障列车运行安全与设备健康维护的关键. 现有的列车轴承状态监控系统通常是基于单个轴温变量是否超限的规则来诊断故障轴承<sup>[1]</sup>. 如法国高速列车 TGV、德国城际列车 ICE、我国的动力分散型动车组 (和谐号、复兴号) 以及动力集中型动车组 (韶山系列等). 该类系统针对单一变量的诊断, 通常会在轴承损坏较为严重导致轴温过高超限时才能报警, 不能捕捉到初期的异常变化.

在列车轴承故障诊断研究方面, 利用实验采集的轴承振动信号, 学者提出基于线性预测滤波、倒谱预白化处理<sup>[2]</sup> 等信号增强算法的列车轴承故障诊断方法. 此外, 基于小波包、傅里叶变换、希尔伯特-黄变换、经验模态分解<sup>[3-7]</sup> 等时频谱分析与分类方

收稿日期 2019-03-25 录用日期 2019-07-17

Manuscript received March 25, 2019; accepted July 17, 2019

国家自然科学基金 (61490704, 61991401, 61673097, 61573022), 中央高校基本科研业务费 (N180802004, N160801001) 资助

Supported by National Natural Science Foundation of China (61490704, 61991401, 61673097, 61573022) and Fundamental Research Funds for the Central Universities (N180802004, N160801001)

本文责任编辑 阳春华

Recommended by Associate Editor YANG Chun-Hua

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. 美国斯坦福大学 斯坦福 94305-2004, 美国 3. 美国南加州大学 洛杉矶 90089, 美国

1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, China

2. Stanford University, Stanford CA 94305-2004, USA 3. Viterbi School of Engineering, University of Southern California, Los Angeles CA 90089, USA

法(模糊分类, 随机森林, 支持向量机等)也广泛应用于轴承振动信号分析及轴承状态的评估<sup>[8-10]</sup>. 列车牵引系统中, 齿轮箱扭转振动对扭矩与定子电流有着直接影响. 对此学者提出一种基于扭转振动信号评估的故障诊断方法<sup>[11]</sup>. 然而, 上述基于振动信号的诊断方法需要在列车上对每个待监控的轴承附加振动传感器, 带来高昂的额外成本、且对传感器的可靠性要求高; 另外, 该类方法对计算和通信资源要求高, 限制了其应用.

近年来, 基于多元统计的过程监控方法 (Multivariate statistical process monitoring, MSPM) 通过如主成分分析 (Principal component analysis, PCA)、偏最小二乘 (Partial least squares, PLS) 等潜结构建模方法由历史正常运行数据提取多维变量间的相关性, 通过其非期望变化来诊断异常, 已成功应用于化工、冶金等工程领域<sup>[12-16]</sup>. 在基于数据潜结构的列车运行故障诊断方面, 利用列车信息控制系统采集到多维强相关的运行数据, 近年也取得了一些研究进展. 如, 对于列车牵引传动系统, 文献 [17] 将核主成分分析与随机森林结合提出基于潜结构特征分类的列车牵引变压器故障诊断方法; 为实现列车制动系统传感器故障的检测与分离, 文献 [18] 提出多元统计监控与贡献图、平滑技术相结合的列车制动系统故障诊断方法.

对于列车运行时的轴承状态而言, 现有车载轴温报警系统采集的多轴轴承温度直接表征了轴承状态, 且具有动态相关关系, 可利用其非期望变化进行轴承故障诊断. 一方面, 在相似的运行环境、运行速度与负载状态下, 列车各轴承温度表现为较强的互相关性; 另一方面, 随着列车运行, 各轴轴温受牵引力等多个潜在因素的累积作用产生变化, 具有明显动态性. 但传统的 PCA 一类静态建模方法无法提取数据间的动态关系. 近几年学者提出动态的建模方法, 如动态 PCA (Dynamic PCA, DPCA)<sup>[19]</sup>. 该方法在连续样本组成的扩展矩阵上进行 PCA, 但扩展矩阵提取的潜变量含义难以解释.

最近, 学者提出了基于动态潜结构的动态系统建模与故障检测方法<sup>[20-22]</sup>, 如动态内在典型相关分析 (Dynamic-inner canonical correlation analysis, DiCCA) 和动态内在主成分分析 (Dynamic-inner PCA, DiPCA). DiPCA 和 DiCCA 分别基于投影后最大化方差、相关系数来提取具有动态性的潜变量, 具有一致的内外模型目标<sup>[20]</sup>, 提取动态潜变量后, 再利用 PCA 方法对不具动态性的残差监控, 从而实现基于动态潜结构的动态系统故障检测. 然而, 从故障检测的角度, 现有方法的动态部分和静态部

分无需分为四个子空间.

针对上述问题, 本文分别将动态变化和静态变化部分的潜在变化和残差合并为综合指标, 提出基于综合指标的动态系统故障检测方法. 在此基础上, 将基于 DiCCA 的故障检测方法与列车运行的多轴轴承数据的空间相关性和动态相关性相结合, 提出基于 DiCCA 综合指标的列车运行轴承故障检测方法. 为实现故障定位, 将 DiCCA 模型与多方向重构贡献图 (Multi-directional reconstructions based contributions, MRBC) 相结合<sup>[23-24]</sup>, 提出了一种基于 DiCCA 多方向重构的列车轴承故障定位方法.

## 1 基于轴温动态潜结构的列车轴承故障检测与定位方法

列车轴温受复杂多变环境等位置因素影响, 机理复杂, 难以采用基于模型的方法<sup>[25]</sup>. 本节结合列车多轴运行于相似环境、速度与负载下引入的空间相关性和时间相关性, 研究数据驱动的动态潜结构建模方法, 以及在此基础上的轴承故障检测与定位方法.

### 1.1 基于 DiCCA 的列车多轴轴温动态潜结构建模

设  $\mathbf{x}_k \in \mathbf{R}^m$  为列车  $m$  个轴在  $k$  时刻的轴温样本,  $\mathbf{t}_k$  为样本  $\mathbf{x}_k$  映射到低维度的潜变量, 即多轴轴温受环境等潜在影响的动态特征信息

$$\mathbf{t}_k = \mathbf{x}_k^T \mathbf{w} \quad (1)$$

其中,  $\mathbf{w}$  为映射方向.

设轴温样本  $\mathbf{X} = [\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_{s+N}]^T$ , 其中,  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{s+N}$  为  $s+N$  个采样时刻的轴温样本. 为提取轴温的动态特征, 选取窗口长度为  $N$ , 对轴温样本  $\mathbf{X}$  进行滑窗操作, 得到  $s+1$  个轴温样本块  $\mathbf{X}_i$ , 前  $s$  块  $\mathbf{X}_i$  组成扩展矩阵  $\mathbf{Z}_s$ , 如式 (2) 所示.

$$\begin{aligned} \mathbf{X}_i &= [\mathbf{x}_i \ \mathbf{x}_{i+1} \ \dots \ \mathbf{x}_{N+i-1}]^T, \quad i = 1, 2, \dots, s+1 \\ \mathbf{Z}_s &= [\mathbf{X}_s \ \mathbf{X}_{s-1} \ \dots \ \mathbf{X}_1] \end{aligned} \quad (2)$$

基于 DiCCA 的建模目标<sup>[19]</sup> 可表达为

$$\max_{\mathbf{w}, \beta} J = \mathbf{w}^T \mathbf{X}_{s+1}^T \mathbf{Z}_s (\beta \otimes \mathbf{w}) \quad (3)$$

其中,  $s$  表示动态结构阶次,  $\beta = [\beta_1 \ \dots \ \beta_{s-1} \ \beta_s]^T$  为自回归系数矩阵,  $\|\mathbf{X}_{s+1} \mathbf{w}\| = 1, \|\mathbf{Z}_s (\beta \otimes \mathbf{w})\| = 1, \beta \otimes \mathbf{w}$  为克罗内克积. 即寻找方向  $\mathbf{w}$ , 使得轴温潜变量  $\mathbf{t}_k$  与其预测值  $\hat{\mathbf{t}}_k$  的相关性最大, 因而  $\mathbf{t}_k$  提取了轴温样本  $\mathbf{x}_k$  中具有动态性的信息.

$\mathbf{t}_k$  可由一个自回归模型表达为

$$\mathbf{t}_k = \beta_1 \mathbf{t}_{k-1} + \dots + \beta_{s-1} \mathbf{t}_{k-s+1} + \beta_s \mathbf{t}_{k-s} + \mathbf{v}_k \quad (4)$$

$\mathbf{t}_k$  的预测值可表达为

$$\hat{\mathbf{t}}_k = \beta_1 \mathbf{t}_{k-1} + \cdots + \beta_{s-1} \mathbf{t}_{k-s-1} + \beta_s \mathbf{t}_{k-s} \quad (5)$$

结合上述分析, DiCCA 模型可表达为

$$\begin{cases} \mathbf{t}_k = \hat{\mathbf{t}}_k + \mathbf{v}_k = \sum_{i=1}^s \beta_i \mathbf{t}_{k-i} + \mathbf{v}_k \\ \mathbf{x}_k = \mathbf{P} \hat{\mathbf{t}}_k + \mathbf{e}_k \end{cases} \quad (6)$$

DiCCA 算法步骤见附录 A. DiCCA 的两个模型参数 (动态结构阶次  $s$  和动态潜变量个数  $l$ ) 可按照文献 [22] 中的参数选择方法来确定.

## 1.2 基于 DiCCA 的列车轴承故障检测方法

经 DiCCA 建模, 轴温数据所处的原始变量空间分为动态主元空间与静态残差空间. 从式 (6) 可知,  $\hat{\mathbf{t}}_k$  与  $\mathbf{e}_k$  分别处于动态主元空间与静态残差空间.

基于所建立模型, 对轴温  $\mathbf{x}_k$  的监控应关注动态主元空间与静态残差空间, 即  $\hat{\mathbf{t}}_k$  与  $\mathbf{e}_k$ . 提取具有动态性的潜变量  $\mathbf{t}_k$  后, 残差  $\mathbf{e}_k$  还可能含有较大的静态相关变化, 需对其进行 PCA 分解的基础上进行故障检测. 由于  $\hat{\mathbf{t}}_k$  是动态甚至是不稳定的, 直接对  $\hat{\mathbf{t}}_k$  的监控易发生误报 [22]. 而  $\mathbf{v}_k$  关注轴温的动态结构变化, 如图 1 所示,  $C_{ii}$  表示  $\mathbf{v}_k$  中第  $i$  个变量的自相关系数, 结果显示,  $\mathbf{v}_k$  中不存在明显动态性, 因此对  $\hat{\mathbf{t}}_k$  的监控可通过监控  $\mathbf{v}_k$  来完成, 即对  $\mathbf{v}_k$  进行 PCA 建模监控.

对于  $k$  时刻的样本可分解为

$$\begin{cases} \mathbf{t}_k = \hat{\mathbf{t}}_k + \mathbf{v}_k = \sum_{i=1}^s \beta_i \mathbf{t}_{k-i} + \mathbf{P}_v \mathbf{t}_{v,k} + \mathbf{r}_{v,k} \\ \mathbf{x}_k = \mathbf{P} \hat{\mathbf{t}}_k + \mathbf{e}_k = \mathbf{P} \hat{\mathbf{t}}_k + \mathbf{P}_s \mathbf{t}_{s,k} + \mathbf{r}_{s,k} \end{cases} \quad (7)$$

其中,  $\mathbf{P}_v$  与  $\mathbf{P}_s$  分别为  $\mathbf{v}_k$  与  $\mathbf{e}_k$  进行 PCA 建模后的负载矩阵;  $\mathbf{t}_{v,k}$  与  $\mathbf{t}_{s,k}$  分别为  $\mathbf{v}_k$  与  $\mathbf{e}_k$  的主元得分;  $\mathbf{r}_{v,k}$  与  $\mathbf{r}_{s,k}$  分别为  $\mathbf{v}_k$  与  $\mathbf{e}_k$  的残差.

基于上述 DiCCA 模型的潜结构空间划分, 建

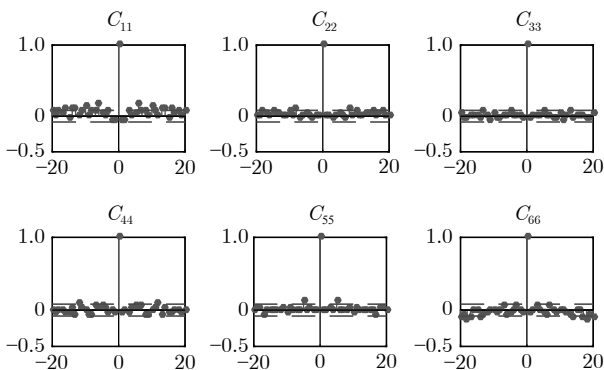


图 1 列车轴温 DiCCA 模型中  $\mathbf{v}_k$  的自相关系数

Fig. 1 Autocorrelation coefficient of  $\mathbf{v}_k$  in the DiCCA model of train bearings

立如式 (8) 所示的两个综合指标来监控列车轴承状态. 其中, 综合指标  $\varphi_s$  用于监控轴温间的静态关系, 综合指标  $\varphi_v$  用于监控轴温的动态结构变化.

$$\begin{aligned} \varphi_v &= \mathbf{v}_k^T \Phi_v \mathbf{v}_k \\ \varphi_s &= \mathbf{e}_k^T \Phi_s \mathbf{e}_k \end{aligned} \quad (8)$$

其中,  $\Phi_v = (\mathbf{I} - \mathbf{P}_v \mathbf{P}_v^T) / \delta_v^2 + (\mathbf{P}_v \Lambda_v^{-1} \mathbf{P}_v^T) / \chi_v^2$ ,  $\Phi_s = (\mathbf{I} - \mathbf{P}_s \mathbf{P}_s^T) / \delta_s^2 + (\mathbf{P}_s \Lambda_s^{-1} \mathbf{P}_s^T) / \chi_s^2$ ,  $\mathbf{I}$  为单位矩阵,  $\chi_v^2$ ,  $\delta_v^2$  为  $\mathbf{v}_k$  的 Hotelling  $T^2$  统计量 ( $T^2$  指标) 与平方预测误差统计量 (SPE 指标) 控制限,  $\chi_s^2$ ,  $\delta_s^2$  分别为  $\mathbf{e}_k$  的  $T^2$  指标与 SPE 指标控制限; 设训练样本数为  $n$ , 由训练样本建立的 DiCCA 模型可得:  $\mathbf{V} = [\mathbf{v}_1 \mathbf{v}_2 \cdots \mathbf{v}_n]^T$ ,  $\mathbf{E} = [\mathbf{e}_1 \mathbf{e}_2 \cdots \mathbf{e}_n]^T$  以及  $\mathbf{T}_v = [\mathbf{t}_{v,1} \mathbf{t}_{v,2} \cdots \mathbf{t}_{v,n}]^T$ ,  $\mathbf{T}_s = [\mathbf{t}_{s,1} \mathbf{t}_{s,2} \cdots \mathbf{t}_{s,n}]^T$ ,  $\Lambda_v$  为  $\mathbf{T}_v$  的协方差矩阵,  $\Lambda_s$  为  $\mathbf{T}_s$  的协方差矩阵;  $\mathbf{t}_s$  与  $\mathbf{v}$  分别为动态和静态部分潜变量, 为了检测其异常变化, 对这两部分分别定义  $T^2$  指标、SPE 指标以及综合指标. 上述统计指标的控制限是在假设潜变量和噪声高斯分布的前提下, 根据统计指标服从卡方分布来近似估计 [26]. 本文按照式 (9) 根据综合指标  $\varphi_v$  和  $\varphi_s$  是否超过各自的控制限  $\delta_{cv}^2$  和  $\delta_{cs}^2$  来检测故障

$$\varphi_v > \delta_{cv}^2 \text{ 或 } \varphi_s > \delta_{cs}^2 \quad (9)$$

其中, 控制限按照文献 [27] 计算  $\delta_{cv}^2 = g_v \chi_v^2$ ,  $\delta_{cs}^2 = g_s \chi_s^2$ ,  $g_v = \text{tr}(\mathbf{S}_v \Phi_v)^2 / \text{tr}(\mathbf{S}_v \Phi_v)$ ,  $g_s = \text{tr}(\mathbf{S}_s \Phi_s)^2 / \text{tr}(\mathbf{S}_s \Phi_s)$ ,  $\mathbf{S}_v$  为  $\mathbf{V}$  的协方差矩阵,  $\mathbf{S}_s$  为  $\mathbf{E}$  的协方差矩阵.

## 1.3 基于 MRBC 的列车轴承故障定位方法

DiCCA 检测指标  $\varphi_v$  或  $\varphi_s$  超出控制限后, 需进一步定位故障轴承, 及时维护检修. 本节提出一种基于 DiCCA 模型的 MRBC 列车轴承故障定位方法.

针对轴温动态结构异常以及轴温间的静态关系异常, 分别从动态结构和静态关系两方面诊断故障原因变量. 基于重构的思想是根据沿着预先设定的故障方向重构, 根据统计指标恢复正常的程度来识别故障变量. 本文中分别基于检测指标  $\varphi_s$ ,  $\varphi_v$  对  $\mathbf{e}_k$ ,  $\mathbf{v}_k$  沿各轴承变量方向重构, 并根据各轴承的重构贡献的相对大小确定故障轴承变量. 假设第  $i$  个轴承为故障轴承, 则  $\mathbf{e}_k$  沿第  $j$  个轴承变量的重构向量可表达为

$$\mathbf{e}_k^r = \mathbf{e}_k - \Xi_j \mathbf{f}_{s,j} \quad (10)$$

其中,  $\Xi_j = [0 \ 0 \cdots 1 \cdots 0]^T \in \mathbf{R}^m$  为第  $j$  个轴承变量方向, 即第  $j$  个元素为 1 且其余元素为 0 的向量,  $\mathbf{f}_{s,j}$  为  $\Xi_j$  方向故障的大小,  $\mathbf{e}_k^r$  为  $\mathbf{e}_k$  沿该方向的重构向量.

对于指标  $\varphi_s$ , 重构后的  $\varphi_s$  可表达为

$$\varphi_s(e_k^r) = \left\| \Phi_s^{\frac{1}{2}}(e_k - \Xi_i f_{s,j}) \right\|^2 \quad (11)$$

其中,  $\Phi_s = (I - P_s P_s^T)/\delta_s^2 + (P_s \Lambda_s^{-1} P_s^T)/\chi_s^2$ .

各轴承方向的故障幅度  $f_{s,j} = \arg \min \varphi_s(e_k^r)$  可由  $\frac{d\varphi_s(e_k^r)}{df_{s,j}} = 0$ , 即  $-2(e_k^r - \Xi_j f_{s,j})^T \Phi_s \Xi_j = 0$ , 解得故障幅度  $f_{s,j} = (\Xi_j^T \Phi_s \Xi_j)^{-1} \Xi_j^T \Phi_s e_k$ .

因此, 对于指标  $\varphi_s$  各轴承的重构贡献为

$$RBC_{\Xi_j}^{\varphi_s} = \left\| \Phi_s^{\frac{1}{2}} \Xi_j f_{s,j} \right\|^2 \quad (12)$$

对于指标  $\varphi_v$ , 由于  $v_k$  各变量方向均包含多个轴承的温度信息, 对  $v_k$  重构无法分别求得各个轴承对故障的贡献. 故应对  $v_k$  在原始变量空间的投影  $v_{x,k} = R^T v_k$  进行多方向重构, 其中,  $R = (W(P^T W)^{-1})^T$ . 与  $f_{s,j}$  求解方法类似,  $\frac{d\varphi_v(v_{x,k}^r)}{df_{v,j}} = 0$ , 即  $-2(v_{x,k} - \Xi_j f_{v,j})^T \Phi_v \Xi_j = 0$ , 解得故障幅度  $f_{v,j} = (\Xi_j^T \Phi_v \Xi_j)^{-1} \Xi_j^T \Phi_v v_{x,k}$ . 其中,  $\Phi_v = (I - P_v P_v^T)/\delta_v^2 + (P_v \Lambda_v^{-1} P_v^T)/\chi_v^2$ .

综上, 基于  $\varphi_s, \varphi_v$  的多方向重构贡献可分别表达为

$$\begin{aligned} RBC_{\Xi}^{\varphi_s} &= e_k \Phi_s \Xi (\Xi^T \Phi_s \Xi)^{-1} \Xi^T \Phi_s e_k \\ RBC_{\Xi}^{\varphi_v} &= v_{x,k} \Phi_v \Xi (\Xi^T \Phi_v \Xi)^{-1} \Xi^T \Phi_v v_{x,k} \end{aligned} \quad (13)$$

其中,  $\Phi_{vv} = R^T \Phi_v R$ .

多方向重构的 DiCCA 列车轴承故障定位方法归纳如下 (由于  $\varphi_s, \varphi_v$  的重构过程类似, 为描述简便, 描述过程中统一用  $\varphi$ ).

**步骤 1.** DiCCA 监控. 若  $\varphi \leq \varphi_{lim}$  ( $\varphi_{lim}$  为  $\varphi$  的控制限), 重复步骤 1, 否则进行步骤 2.

**步骤 2.** 初始化故障方向阵  $\Xi$  为空矩阵, 故障方

向量数  $l = 0$ .

**步骤 3.** 依次将剩余  $m - l$  个轴承变量方向  $\Xi_j$  插入当前故障方向阵, 计算  $RBC_{\Xi_{jj}}^{\varphi}$ . 其中,  $\Xi_{jj} = [\Xi, \Xi_j]$ ,  $j = 1 : m - l$ .

**步骤 4.** 将步骤 3 中  $RBC_{\Xi_{jj}}^{\varphi}$  最大的轴承变量方向  $\Xi_j$  加入故障方向阵, 即  $\Xi = [\Xi, \Xi_j]$ ,  $l = l + 1$ . 其中,  $\Xi_j = \arg \max RBC_{\Xi_{jj}}^{\varphi}$ .

**步骤 5.** 计算  $\varphi_{rec} = \varphi - RBC_{\Xi}^{\varphi}$ . 若  $\varphi_{rec} \geq \varphi_{lim}$ , 返回步骤 2, 否则, 根据当前故障方向阵  $\Xi$ , 定位故障轴承. 计算候选集  $l$  个故障轴承的贡献, 画出基于对应指标的 MRBC 贡献图.

DiCCA 的两个检测指标  $\varphi_s, \varphi_v$  超出控制限后, MRBC 方法迭代寻找当前具有最大故障贡献的轴承, 将该轴承加入故障变量候选集, 并沿当前具有最大 RBC 贡献的轴承方向进行重构, 直到  $\varphi_s, \varphi_v$  降至控制限以下, 候选集轴承变量即为故障变量.

列车轴承故障检测及定位流程如图 2 所示.

## 2 应用验证

列车轴温数据采样周期为 1 s, 采集自 36 个温度传感器, 用于监控列车轴承的工作状态. 其中包括 4 个轴承 (每个轴承包括 7 个测量位置: 大 (小) 齿轮箱电机侧、大 (小) 齿轮箱车轮侧、电机定子、电机传动端和电机非传动端) 与 8 个轴箱温度. 基于规则的各传感器位置预警限和报警限, 如表 1 所示. 采用列车正常运行的轴温数据训练 DiCCA 模型, 按前文所述方法确定动态阶次和潜变量个数为  $s = 3$  和  $l = 6$ .

### 2.1 列车轴承故障检测结果分析

在本小节中, 将列车异常轴温数据用于故障检

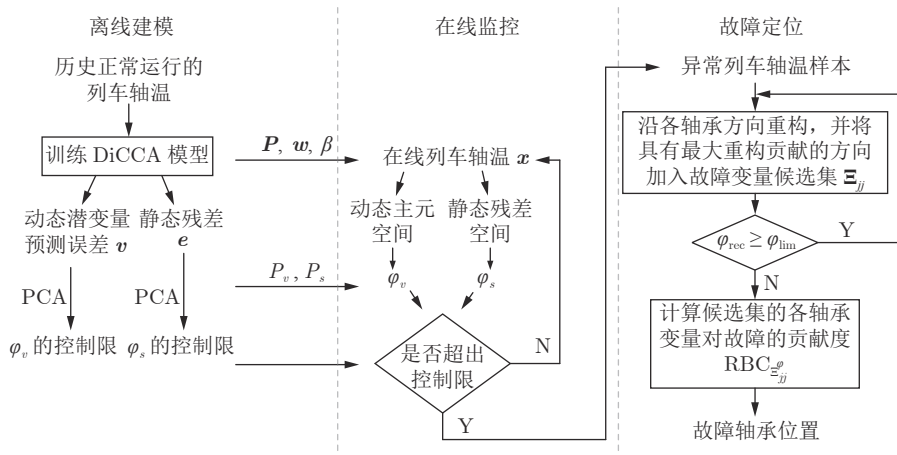


图 2 列车轴承故障检测及定位流程

Fig. 2 The process of fault detection and locating for train bearings

表 1 基于规则的列车轴温预警及报警限  
Table 1 Rule-based warning and alarm limits of train bearings

传感器位置	预警限(°C)	报警限(°C)
轴箱	100	120
齿轮箱	110	130
电机定子	160	180
电机传动端	110	130
电机非传动端	90	110

测方法的比较, 其中包括 5 个案例(案例 1: 电机定子故障, 案例 2: 电机非传动端故障, 案例 3: 齿轮箱故障, 案例 4: 轴箱故障, 案例 5: 电机传动端故障). 结合案例 1, 将 DiCCA 与列车系统诊断规则方法的故障检测结果进行对比, 如图 3(a) 和图 3(b) 所示, 电机定子在 7 300 样本时刻左右已发生非期望变化, 但由于轴温尚未超出预设的报警限, 现有列车轴承报警系统在第 9 000 样本时刻左右, 即故障较为严重时才根据轴温超限报警. 由图 3(b) 所示的本文所提方法诊断结果, 检测指标  $\varphi_s$  由第 7 324 个样本点开始超出控制限, 诊断出静态残差子空间的异常, 多轴轴温间的静态相关关系产生了异常变化; 随后轴温产生大幅波动, 轴温数据的动态结构也产生异常变化, 由表征轴温的动态主元空间的  $\varphi_v$  指标超限有效检测出该类异常. 相比于列车系统诊断规则, 所提方法提前近 30 分钟检测出电机定子初期的异常变化.

结合案例 1~5, 将 DiCCA 与 PCA、DPCA 方法的故障检测结果进行对比, 检测结果如图 4~8 所示, 并整理结果至表 2. 例如案例 1 中, DiCCA 在第 7 324 个样本点处检测到异常, DPCA 在第 8 235 个样本点处检测到异常, PCA 在第 8 982 个样本点处检测到异常. 经现场确认, 检测结果与实际发生的故障情况一致, 且 DiCCA 比 DPCA 和 PCA 报警时间提前. 另外, 选取不同的动态阶次和潜变量个数时, 诊断结果变化不大, 表明了所提方法对于参数变化的鲁棒性.








图 4 案例 1 的故障检测结果

Fig. 4 Fault detection result of Case 1



(a) 列车系统诊断规则检测结果

(a) Fault detection result of the rule-based method of the train system



(b) DiCCA 检测结果

(b) Fault detection result of DiCCA

图 3 DiCCA 与列车系统诊断规则检测结果对比

Fig. 3 Fault detection result comparison of DiCCA and the rule-based method of the train system

## 2.2 列车轴承故障定位结果分析

选取案例 3 和案例 4 部分样本作为测试. 其中, 案例 3 为齿轮箱故障, 故障位置为 3 轴大齿轮箱车轮侧(变量 33). 表 2 结果显示, DiCCA 于第 11 027 个样本点检测到异常. 选取样本点 11 027 前后共 200 个样本, 运用本文提出的基于 DiCCA 的 MR-BC 故障定位方法, 计算样本各轴承变量的贡献(即




图 5 案例 2 的故障检测结果

Fig. 5 Fault detection result of Case 2




图 6 案例 3 的故障检测结果

Fig. 6 Fault detection result of Case 3




图 7 案例 4 的故障检测结果

Fig. 7 Fault detection result of Case 4




图 8 案例 5 的故障检测结果

Fig. 8 Fault detection result of Case 5

第 11 001~11 200 样本点). 图 9(a) 和图 10 结果显示, 在基于  $\varphi_s, \varphi_v$  的 MRBC 贡献图中, 变量 33 贡献很大, 图 9(b) 对基于  $\varphi_s$  的 MRBC 贡献图在样本点 11 027 处进行了展开, 成功确定故障位置为 3 轴大齿轮箱车轮侧 (变量 33).

案例 4 为轴箱故障, 故障位置为 3 位轴箱 (变

量 5), 期间 1 轴电机定子 (变量 17) 间断性地存在传感器故障. 取样本点 57 301~57 500 共 200 个样本, 运用本文提出的基于 MRBC 的故障定位方法, 结果如图 11 和图 12 所示, 3 位轴箱 (变量 5) 与 1 轴电机定子 (变量 17) 贡献较高, 均成功定位, 验证了本文提出的列车轴承故障定位方法的有效性.

表 2 各方法的轴承故障检测结果对比  
Table 2 Result comparison among fault detection methods

故障案例	开始检测到异常的样本点			
	规则方法	PCA	DPCA	DiCCA
电机定子	9 000	8 982	8 235	7 324
电机非传动端	35 930	35 010	35 008	35 007
齿轮箱	19 340	11 042	11 039	11 027
轴箱	7 406	6 821	6 820	6 770
电机传动端	14 200	8 340	8 321	8 292





图 9 案例 3 基于  $\varphi_s$  的 MRBC 贡献图  
Fig. 9  $\varphi_s$  based MRBC plot of Case 3

### 3 结束语

结合列车运行轴承故障诊断需求, 本文提出了一种基于动态潜结构建模与重构的列车轴承故障检测与定位方法, 所提出的方法成功地检测并定位了列车的故障轴承。另外, 本文提出的方法与 DPCA、PCA 以及传统基于规则的轴承故障检测方法相比具有提前报警的优势。

在列车工作环境变化、维护正常运行工况变化时易发生误报警, 需要结合维护信息与新采数据对基于历史数据建立的轴温模型进行更新, 下一步将




图 10 案例 3 基于  $\varphi_v$  的 MRBC 贡献图  
Fig. 10  $\varphi_v$  based MRBC plot of Case 3




图 11 案例 4 基于  $\varphi_s$  的 MRBC 贡献图  
Fig. 11  $\varphi_s$  based MRBC plot of Case 4




图 12 案例 4 基于  $\varphi_v$  的 MRBC 贡献图  
Fig. 12  $\varphi_v$  based MRBC plot of Case 4

深入研究自适应的列车轴温数据建模方法, 通过轴温动态潜结构模型的切换或迭代更新来适应正常的列车运行工况变化。

### 附录 A 动态内在典型相关分析<sup>[21]</sup>

1) 归一化  $\mathbf{X}$  为零均值和单位方差, 初始化  $\mathbf{w}$  为随机单

位向量.

2) 求解  $\mathbf{w}, \beta$ , 迭代执行至  $\mathbf{t}$  收敛.

$$\mathbf{t} = \mathbf{X}\mathbf{w}, \quad \mathbf{t} := \mathbf{t}/\|\mathbf{t}\|$$

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

$$\mathbf{t}_i = [\mathbf{t}_i \ \mathbf{t}_{i+1} \ \cdots \ \mathbf{t}_{N+i-1}]^T, \quad i = 1, 2, \cdots, s+1$$

$$\mathbf{T}_{ss} = [\mathbf{t}_s \ \cdots \ \mathbf{t}_1]$$

$$\beta := \beta / (\mathbf{t}_{s+1}^T \mathbf{T}_{ss} \beta)^{0.5}$$

$$\mathbf{X}_\beta = \sum_{i=1}^s \beta_i \mathbf{X}_{s-i+1}^T$$

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

3) 计算  $\mathbf{X}$  的残差.  $\mathbf{p} = \mathbf{X}^T \mathbf{t} / \mathbf{t}^T \mathbf{t}$

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

4) 返回步骤 2), 继续对  $\mathbf{X}$  的残差进行相同的迭代, 提取潜变量, 直至提取了  $l$  个潜变量.  $l$  个潜变量的负载向量  $\mathbf{p}$  组成负载矩阵  $\mathbf{P} = [\mathbf{p}_1 \ \mathbf{p}_2 \ \cdots \ \mathbf{p}_l]$ , 对应的负载向量  $\mathbf{w}$  组成负载矩阵  $\mathbf{W} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_l]$ .

## References

- Jia Hua-Qiang, Li Li-Jun. Thinking on improving the manufacturing level and operation quality of high speed train EMU in China. *Chinese Railways*, 2014, (1): 30–33 (贾华强, 李利军. 提高我国高铁动车组装备制造水平和运行品质的思考. 中国铁路, 2014, (1): 30–33)
- Borghesani P, Pennacchi P, Randall R B, Sawalhi N, Ricci R. Application of cepstrum pre-whitening for the diagnosis of bearing faults under variable speed conditions. *Mechanical Systems and Signal Processing*, 2013, **36**(2): 370–384
- Nikolaou N G, Antoniadis I A. Rolling element bearing fault diagnosis using wavelet packets. *NDT & E International*, 2002, **35**(3): 197–205
- Elbouchikhi E, Choqueuse V, Amirat Y, Benbouzid M E H, Turri S. An efficient Hilbert-Huang transform-based bearing faults detection in induction machines. *IEEE Transactions on Energy Conversion*, 2017, **32**(2): 401–413
- Rai V K, Mohanty A R. Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert-Huang transform. *Mechanical Systems and Signal Processing*, 2007, **21**(6): 2607–2615
- Van M, Kang H, Shin K. Rolling element bearing fault diagnosis based on non-local means de-noising and empirical mode decomposition. *IET Science, Measurement and Technology*, 2014, **8**(6): 571–578
- Lu S L, He Q B, Hu F, Kong F R. Sequential multiscale noise tuning stochastic resonance for train bearing fault diagnosis in an embedded system. *IEEE Transactions on Instrumentation and Measurement*, 2014, **63**(1): 106–116
- Soualhi A, Medjaher K, Zerhouni N. K A. Bearing health monitoring based on Hilbert-Huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, 2015, **64**(1): 52–62
- Wang Z W, Zhang Q H, Xiong J B, Xiao M, Sun G X, He J. Fault diagnosis of a rolling bearing using wavelet packet denoising and random forests. *IEEE Sensors Journal*, 2017, **17**(17): 5581–5588
- Lou X S, Loparo K A. Bearing fault diagnosis based on wavelet transform and fuzzy inference. *Mechanical Systems and Signal Processing*, 2004, **18**(5): 1077–1795
- Henao H, Kia S, and Capolino G. Torsional vibration assessment and gear-fault diagnosis in railway traction system. *IEEE Transactions on Industrial Electronics*, 2011, **58**(5): 1707–1717
- Qin S J. Survey on data-driven industrial process monitoring and diagnosis. *Annual Reviews in Control*, 2012, **36**(2): 220–234
- Jia R X, W J, Zhou J L. Fault diagnosis of industrial process based on the optimal parametric  $t$ -distributed stochastic neighbor embedding. *Science China Information Sciences*, 2019.
- 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*, 2019, DOI: 10.16383/j.aas.c180089 (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, 2019, DOI: 10.16383/j.aas.c180089)
- 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)
- Guo H Y, Cao D P, Chen H, Lv C, Wang H J, Yang S Q. Vehicle dynamic state estimation: state of the art schemes and perspectives. *IEEE/CAA Journal of Automatica Sinica*, 2018, **5**(2): 418–431
- Dai C X, Liu Z G, Hu K T, Huang K. Fault diagnosis approach of traction transformers in high-speed railway combining kernel principal component analysis with random forest. *IET Electrical Systems in Transportation*, 2016, **6**(3): 202–206
- Ji H Q, He X, Shang J, Zhou D H. Incipient fault detection with smoothing techniques in statistical process monitoring. *Control Engineering Practice*, 2017, **62**: 11–21
- 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
- Dong Y N, Qin S J. Dynamic latent variable analytics for process operations and control. *Computers and Chemical Engineering*, 2018, **114**: 69–80
- Dong Y N, Qin S J. Dynamic-Inner canonical correlation and causality analysis for high dimensional time series data. *IFAC-PapersOnLine*, 2018, **51**(18): 476–481
- Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring. *Journal of Process Control*, 2018, **67**: 1–11
- Johan A W, Stephen P G, Age K S. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and Intelligent Laboratory Systems*, 2000, **51**(1): 95–114
- Li G, Qin S J, Chai T Y. Multi-directional reconstruction based contributions for root-cause diagnosis of dynamic processes. In: Proceedings of the 2014 American Control Conference, Portland, OR, USA: IEEE, 2014. 3500–3505
- Zhou Dong-Hua, Ji Hong-Quan, He Xiao. Fault diagnosis technology for high speed train information control system. *Acta Automatica Sinica*, 2018, **44**(7): 1153–1164 (周东华, 纪洪泉, 何潇. 高速列车信息控制系统的故障诊断技术. 自动化学报, 2018, **44**(7): 1153–1164)
- Yue H H, Qin S J. Reconstruction-based fault identification using a combined index. *Industrial and Engineering Chemistry Re-*



*search*, 2001, **40**(20): 4403–4414

- 27 Box, G. Some theorems on quadratic forms applied in the study of analysis of variance problems, I. Effect of inequality of variance in the one-way classification. *Ann. Math. Stat.*, 1954, **25**: 290–302



**刘 强** 东北大学教授. 主要研究方向为大数据建模、过程监控与故障诊断. 曾获辽宁省优秀博士学位论文奖, 中国自动化学会优秀博士学位论文提名奖. 本文通信作者.

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


(**LIU Qiang** Professor at Northeastern University. His research interest covers big data modeling, statistical process monitoring, and fault diagnosis. Prof. Liu was the recipient of the Excellent Doctoral Dissertation of the Liaoning Province of China. He was also the recipient of the Excellent Doctoral Dissertation Nomination Award of Automation Society by the Automation Society of China. Corresponding author of this paper.)



**方 彤** 东北大学硕士研究生. 主要研究方向为统计过程监控与故障诊断. E-mail: 1770520@stu.neu.edu.cn

(**FANG Tong** Master student at Northeastern University. His research interest covers statistical process monitoring and fault diagnosis.)

is.)



**董一凝** 美国斯坦福大学博士后学者. 2011年毕业于清华大学电子工程系获学士学位. 2016年获美国南加州大学电子工程博士学位. 主要研究方向为过程数据分析, 潜变量模型, 统计过程监控和故障诊断.

E-mail: yiningdo@stanford.edu

(**DONG Yi-Ning** Postdoctoral scholar in electrical engineering at Stanford University, USA. She received her bachelor degree in electrical engineering from Tsinghua University, China in 2011, and her Ph.D. degree in electrical engineering from University of Southern California, USA in 2016. Her research interest covers process data analytics, latent variable models, statistical process monitoring and fault diagnosis.)



**秦泗钊** 美国南加州大学教授. IEEE Fellow, IFAC Fellow, AIChE Fellow. 主要研究方向为统计过程监控, 故障诊断, 模型预测控制, 系统辨识, 建筑能源优化与控制性能监控.

E-mail: sqin@usc.edu

(**QIN S. Joe** Professor at the University of Southern California, USA. He is a IEEE Fellow, IFAC Fellow and AIChE Fellow. His research interest covers statistical process monitoring, fault diagnosis, model predictive control, system identification, building energy optimization, and control performance monitoring.)