



数据驱动的高速列车轴承多模态运行监控与故障诊断

刘强^{1*}, 詹志强¹, 王硕¹, 刘英翔², 方彤¹

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. Viterbi School of Engineering, University of Southern California, Los Angeles 90089, USA

* 通信作者. E-mail: liuq@mail.neu.edu.cn

收稿日期: 2019-10-18; 修回日期: 2020-01-14; 接受日期: 2020-01-24; 网络出版日期: 2020-04-13

国家自然科学基金 (批准号: 61490704, 61673097, 61991401)、辽宁省“兴辽英才计划” (批准号: XLYC1907049) 和教育部基本科研业务费 (批准号: N180802004, N160801001) 资助项目

摘要 高速列车多个轴承动态运行于相似环境造成轴承温度具有空间和时间相关性, 可利用轴温相关关系的非期望变化进行轴承故障诊断; 但传统的单一模态建模与监控方法未考虑在不同区间运行的列车其轴承温度具有各异的动态特征, 难以建模上述关系, 易造成误诊断. 针对上述问题, 本文研究综合利用高速列车轴温监测系统采集的同一列车多轴轴温数据, 以及列车控制系统和轴承故障报警系统中的列车运行轨迹数据, 提出数据驱动的列车轴承多模态运行监控与故障诊断方法. 首先, 针对列车通讯异常和传感器故障造成的缺失点和离群点问题, 提出线性插值和动态主元搜索相结合的列车轴温数据预处理方法; 接下来, 依据不同运行区间内轴承温度变化相似性的聚类结果识别出同一列车的不同运行模态, 并结合其与故障报警地理信息所提取的运行区间之间的相关性, 提出基于列车运行轨迹的运行模态识别方法; 在此基础上, 提出多模态动态内在典型相关分析 (multi-modal dynamic inner canonical correlation analysis, M-DiCCA) 列车轴承多模态建模与运行监控方法; 其后, 提出基于动态时间规整的轴承故障原因诊断方法; 最后, 采用实际列车运行的轴温数据进行实验验证, 结果表明了所提方法的有效性.

关键词 动态数据建模, 动态时间规整, 故障诊断, 多模态建模

1 引言

高速列车轴承是保障列车安全运行的关键设备^[1]. 在列车高速运行过程中, 轴承长期处于交变应力组合作用下易发生点蚀、剥落和熔化等故障. 轴承一旦出现故障并迅速恶化, 会危及列车的运行安全^[2], 对高速列车轴承进行有效监控和故障诊断是保障其运行安全的必要途径^[3].

引用格式: 刘强, 詹志强, 王硕, 等. 数据驱动的高速列车轴承多模态运行监控与故障诊断. 中国科学: 信息科学, 2020, 50: 527-539, doi: 10.1360/SSI-2019-0232
Liu Q, Zhan Z Q, Wang S, et al. Data-driven multimodal operation monitoring and fault diagnosis of high-speed train bearings (in Chinese). Sci Sin Inform, 2020, 50: 527-539, doi: 10.1360/SSI-2019-0232

现有的列车轴承故障检测主要是基于振动信号的方法和基于温度信号的方法。基于振动信号的方法是对信号放大和滤波后, 计算振动频率或幅值, 再通过时域分析及频域分析进行故障检测^[4], 例如, 文献 [5] 提出了基于振动加速度的轴箱及转向架故障检测方法。然而, 振动异常容易被来自齿轮传动系统、轮轨间相互作用和车身的机械振动引起的背景噪声所掩盖, 而且通常需要额外安装振动传感器, 限制了其应用^[6]。基于温度信号的方法通常是根据单一轴承的温度是否超过预设定的阈值进行规则诊断的, 例如, 英国国家铁路网安装了 200 余套轴箱温度传感器来检测轴承故障^[7]。上述方法都是基于单一变量的轴承状态监控, 通常在故障严重时才能检测, 难以发现故障初期异常。

数据驱动的潜结构方法, 如主元分析法 (principal component analysis, PCA)^[8~14] 以及偏最小二乘法 (partial least squares, PLS)^[15], 根据多变量间相关关系的非期望变化进行故障检测和诊断, 已成功应用于半导体和钢铁制造等行业。上述方法为建立多轴轴温数据潜结构关系, 在此基础上进行列车运行时的轴承状态监控提供了可行的思路。例如, 文献 [16] 根据高速列车动态运行时各轴运行于相似的运行环境引入不同轴承温度间的空间相关性, 造成列车运行时各轴轴温具有动态相关关系, 提出基于动态内在典型相关分析 (dynamic inner canonical correlation analysis, DiCCA) 的多轴轴温数据动态潜结构建模与运行监控方法。采用文献 [17, 18] 所提出的动态内在典型相关分析方法依据动态性依次提取各个动态潜变量, 在此基础上定义相应的统计指标实现轴承运行监控, 并提出基于多向重构的故障定位方法。然而, 上述方法是单一模态建模与监控, 未考虑列车的多模态运行特点, 易发生误报警。

列车运行于不同地理环境下包括坡道、曲线、直线和隧道等, 不同轴温之间的相互关系发生改变, 且轴温分布随运行区间变化, 具有多模态特点。目前已有一些根据工业过程的多模态运行特点提出的多模态数据建模与运行监控方法。主要是根据先验知识或根据过程数据本身相关关系等的变化来划分多阶段, 并在此基础上进行多模态建模与运行监控^[19, 20]。比如, 文献 [21] 针对间歇过程不同生产阶段的过程变量相关关系及分布的显著不同, 提出对各阶段采用多向主元分析单独建模的多模态数据建模方法, 在此基础上提出相应的多模态运行监控方法^[22], 并成功应用于工业硫化催化裂化。但上述方法仅能监控稳定的模态, 难以监控模态间的过渡过程; 针对该问题, 文献 [23] 通过对相邻两稳定模态之间的负载矩阵加权来进行过渡模态的监控。但是现有的多模态数据建模及运行监控方法主要基于稳定模态数据间静态关系, 未考虑变量间的动态关系, 难以应用于多模态动态运行的高速列车轴承运行监控; 另一方面, 现有方法的模态划分未有效利用列车运行于不同地理环境下, 列车控制系统和维护系统记录的列车运行模态相关的运行轨迹等更全面的信息。

本文研究数据驱动的列车多模态运行监控与故障诊断方法, 主要贡献如下。(1) 将长时段历史轴温数据中包含的缺失点和离群点数据看作稀疏点, 提出线性插值与动态主元搜索相结合的异常数据重构方法; (2) 结合列控系统的运行轨迹信息和轴温监控系统的轴温数据, 在对轴温数据聚类分析和列车故障运行位置提取运行区间信息的基础上, 提出基于列车运行轨迹的运行模态识别方法; (3) 结合高速列车多模态动态运行特点, 提出多模态动态内在典型相关分析 (multi-modal dynamic inner canonical correlation analysis, M-DiCCA) 建模和运行监控方法, 以及在此基础上的故障原因诊断方法。

2 数据驱动的列车轴承多模态动态潜结构建模与运行监控

2.1 高速列车轴承温度数据预处理

高速列车的车载轴温监控系统通过轴温主机采集轴承温度数据, 再通过网络系统传送到地面存

储. 然而, 采集到的轴温数据常存在缺陷. 例如, 列车通过隧道等区域时常发生通讯异常造成部分时段的多个轴承温度数据缺失. 另外, 接线不良、电磁干扰等造成的温度传感器故障会带来某轴温变量数据的瞬时异常, 从而引入离群点. 数据驱动的潜结构方法需要利用正常数据, 少量的异常点会引入大的建模误差, 并影响故障诊断的准确性, 从而需要进行数据预处理.

首先, 假设列车历史运行采集的轴承温度数据阵 $\mathbf{X} \in \mathbb{R}^{N \times m}$ (其中 N 为样本数, m 为轴承变量数), 数据缺失时间为 $t \in [t_s, t_o]$ (t_s 为数据缺失开始时间, t_o 为数据缺失结束时间) 的轴温采样值为空, 针对列车通过隧道等区域时发生通讯异常会造成该时刻列车的多个轴温变量缺失, 从而无法利用该时刻其他轴温来估计缺失轴温的问题, 采用文献 [24] 的线性插值法取缺失数据的前后部分数据进行缺失值插补, 得到数据阵 \mathbf{X}_s .

接下来, 针对 \mathbf{X}_s 中可能含有离群点的问题, 结合轴温数据动态性, 以及长时间尺度将离群点看做稀疏点, 采用动态主元搜索方法进行离群点重构 [25]. 该方法首先结合动态主元分析方法通过变量延迟扩展来提取变量间动态关系的思想 [26], 将 \mathbf{X}_s 根据延迟时间 d 按式 (1) 得到延迟数据阵 \mathbf{X}_d :

$$\mathbf{X}_d = \begin{bmatrix} \mathbf{X}_s^T(1:N-d+1, 1:m) \\ \mathbf{X}_s^T(2:N-d+2, 1:m) \\ \dots \\ \mathbf{X}_s^T(d:N, 1:m) \end{bmatrix}^T, \quad (1)$$

其中参数 d 表征系统的动态阶次, 本文采用残差平方和法确定 [27].

在此基础上, 将 \mathbf{X}_d 按式 $\mathbf{X}_d = \mathbf{L} + \mathbf{S}$ 分解, 其中 \mathbf{L} 为低秩数据阵, \mathbf{S} 为稀疏离群点数据. 采用主元搜索方法利用 L_1 范数和凸优化来求解 $\|\mathbf{L}\|_* + \lambda\|\mathbf{S}\|_1$ 最小的优化问题 [28], 得到重构后的轴温数据.

2.2 基于列车轴承变量聚类和维护数据的多模态运行知识发现

列车运行时轴承的不同运行模态主要体现在各轴温变量间相关关系的变化. 考虑轴承温度与运行区间和速度的潜在相关性, 首先依据列车速度的加速、降速、匀速运行模式, 将运行于不同区间和不同速度模式下的历史轴承数据划分为若干样本集. 在此基础上, 采用动态时间规整 (dynamic time wrapping, DTW) 方法对不同运行区间和不同运行速度模式下的各轴温变量进行聚类分析 [29], 利用该结果进行运行模态划分. 具体实现方法是: 将某运行区间某时段的各个轴温温度变量的样本子集作为一条时间序列, 采用式 (2) 的动态时间规整距离衡量各轴温变量的时间序列之间的相似性.

$$d_{h,c} = \text{DTW}(\mathbf{x}_h(\text{zone}, \text{section}), \mathbf{x}_c(\text{zone}, \text{section})), \quad h, c \in \{1, 2, \dots, m\}, \quad (2)$$

其中 $\text{DTW}(\cdot)$ 表示求解两个时间序列的动态时间规整距离, $\mathbf{x}_h(\text{zone}, \text{section})$ 和 $\mathbf{x}_c(\text{zone}, \text{section})$ 分别表示轴承 h 和 c 在运行区间 zone 和 section 时段的轴温时间序列.

采用算法 A1 —— K- 均值聚类算法对各轴承变量聚类, 最佳聚类数目参数由组内平方误差和来确定. 由第 4 节的历史轴承温度数据的变量聚类结果可以看出, 运行模态受加速、减速、匀速变化影响较小, 且相邻两天列车运行于不同区间时轴承变量聚类结果不同. 如图 1 所示, 由 2018 年 1 月某车次速度变化曲线提取列车运行于不同区间的速度模式 (1 月 14 日、1 月 16 日和 1 月 18 日具有相同的速度模式, 1 月 15 日和 1 月 17 日具有相同的速度模式). 图 2 给出不同速度模式下列车各个运行阶段的各轴温变量的聚类分析结果, 从图中可以看出, 列车在不同区间的运行模态下, 不同轴温数据间的




图 1 (网络版彩图) 某车次多天速度变化曲线

Figure 1 (Color online) Operation speed curve of a train during a number of days

潜结构关系发生改变. 通过对轴承变量聚类结果和列车运行区间联合分析, 可以看出多轴轴温相关关系的模态变化与列车运行区间有关. 为此, 可以根据列车运行轨迹进行轴承温度多模态运行监控. 根据当前列车运行轨迹与历史运行轨迹的动态时间规整距离的大小, 判定与历史运行模态的相似度, 实现运行模态识别; 在此基础上, 进行 2.3 和 2.4 小节的多模态动态潜结构建模与运行监控.

2.3 列车轴承温度多模态动态潜结构建模

列车运行时动态变化的各轴轴温具有相似性, 引入时空相关性. 为此, 建立多轴轴温的动态潜结构模型, 提取运行环境和列车速度变化等带来的轴温共有变化和各轴承温度的特有变化. 利用 2.2 小节的多模态划分结果, 提取列车不同运行模态下的历史轴承温度数据, 再分别采用算法 A2 —— 动态内在典型相关分析算法建立各模态下的动态潜结构模型^[17], 具体说明如下.

设某运行模态下, 标准化预处理后的轴温样本如下:

$$\mathbf{X}^M = [\mathbf{x}_1^M \mathbf{x}_2^M \cdots \mathbf{x}_{s+N}^M]^T, \quad (3)$$

其中 $M = \{0, 1, 2, \dots, M_s\}$ 表示运行模态, $M = 0$ 时表示维护停运, M_s 为运行模态数, $\mathbf{x}_1^M, \mathbf{x}_2^M, \dots, \mathbf{x}_{s+N}^M$ 分别为 $s + N$ 个采样时刻的轴温样本.

利用 \mathbf{X}^M 提取轴温的动态特征, 选取窗口长度 N 对轴温样本 \mathbf{x}^M 进行滑窗操作, 得到 $s + 1$ 个轴温样本块 \mathbf{X}_i^M , 前 s 块 \mathbf{X}_i^M 组成扩展矩阵 \mathbf{Z}_s^M , 如下所示:

$$\begin{aligned} \mathbf{X}_i^M &= [\mathbf{x}_i^M \mathbf{x}_{i+1}^M \cdots \mathbf{x}_{N+i-1}^M]^T, \quad i = 1, 2, \dots, s + 1, \\ \mathbf{Z}_s^M &= [\mathbf{X}_s^M \mathbf{X}_{s-1}^M \cdots \mathbf{X}_1^M]. \end{aligned} \quad (4)$$

对各运行模态, DiCCA 的建模目标可表达为

$$\max_{\omega, \beta} J = \omega^T (\mathbf{X}_{s+1}^M)^T \mathbf{Z}_s^M (\beta \otimes \omega), \quad (5)$$

其中 s 表示动态结构阶次, $\beta = [\beta_1 \cdots \beta_{s-1} \beta_s]^T$, $\|\mathbf{X}_{s+1}^M\| = 1$, $\|\mathbf{Z}_s^M (\beta \otimes \omega)\| = 1$, ω 为映射方向, \otimes 为克罗内克 (Kronecker) 积. 即寻找方向 ω , 使得轴温潜变量 $\mathbf{t}_k = \mathbf{x}_k^T \omega$ 与其预测值 $\hat{\mathbf{t}}_k$ 的相关性最大.

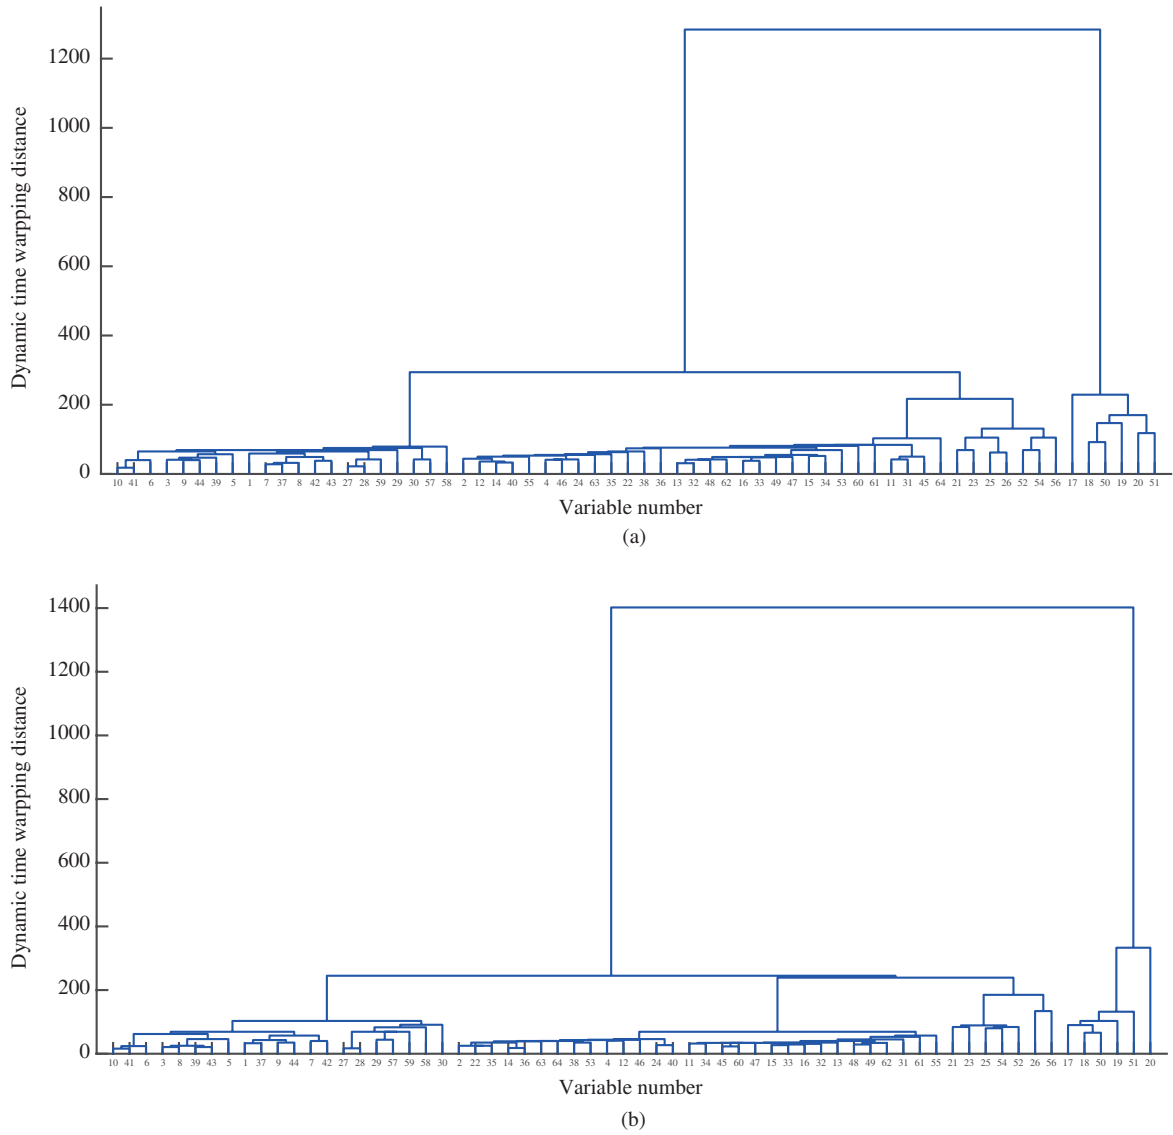


图 2 (网络版彩图) 不同运行区间的轴承变量聚类结果图. (a) 模式 1; (b) 模式 2
 Figure 2 (Color online) Clustering results for different operational modes. (a) Mode 1; (b) mode 2

DiCCA 模型可表达为

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

其中 \mathbf{t}_k 为多轴轴温映射到低维度的潜变量, 表示多轴轴温受环境、车速等影响的动态变化, \mathbf{P}_v^M 与 \mathbf{P}_s^M 分别为 \mathbf{v}_k 与 \mathbf{e}_k 进行 PCA 分解后的负载矩阵, $\mathbf{r}_{v,k}$ 与 $\mathbf{r}_{s,k}$ 分别为 \mathbf{v}_k 与 \mathbf{e}_k 的残差. DiCCA 的两个模型参数、动态结构阶次 s 和动态潜变量个数 l 可按文献 [30] 中的方法来确定.

2.4 基于多模态动态潜结构的列车轴承运行监控

2.4.1 列车运行模式匹配

首先, 利用动态时间规整距离来计算列车当前运行轨迹与历史运行轨迹的相似性, 识别其运行模式. 下面给出具体算法说明. 假设列车从发车开始, 根据预先设定长度的动态时间窗口的运行轨迹为 R_{new} , 计算其与对应时刻的各运行模式历史运行轨迹 R_M 的相似度 $\text{DTW}(R_{\text{new}}, R_M)$, 识别规则如下:

如果 $\min\{\text{DTW}(R_{\text{new}}, R_M)\} > \lambda_{\min}$, λ_{\min} 为根据经验确定的阈值, 则 $M = 0$, 采用新采集的轴温数据建立新模式的轴温动态潜结构模型, $M_s = M_s + 1$.

否则 $M = \text{argmin}\{\text{DTW}(R_{\text{new}}, R_M)\}$.

2.4.2 列车多模态运行监控

为实现多模式监控, 分别建立各运行模式的轴承运行监控指标. 利用 2.3 小节中如式 (6) 所建立的模型, 按式 (8) 所示检测动态变化综合指标 φ_v^M 和静态变化综合指标 φ_s^M , 根据 φ_v^M 和 φ_s^M 两个统计指标是否超过各自的控制限 $\delta_{M,cv}^2$ 和 $\delta_{M,cs}^2$, 判定在该运行模式下轴承是否发生故障^[17]:

$$\begin{aligned} \varphi_v^M &= \frac{Q_v}{\delta_v^2} + \frac{T_v^2}{\chi_v^2} = \mathbf{v}^T \Phi_v^M \mathbf{v} > \delta_{M,cv}^2, \\ \text{或 } \varphi_s^M &= \frac{Q_r}{\delta_r^2} + \frac{T_r^2}{\chi_r^2} = \mathbf{e}^T \Phi_s^M \mathbf{e} > \delta_{M,cs}^2, \end{aligned} \quad (7)$$

$$\begin{aligned} \Phi_v^M &= (\mathbf{I} - \mathbf{P}_v^M (\mathbf{P}_v^M)^T) / \delta_v^2 + \mathbf{P}_v^M (\Lambda_v^M)^{-1} (\mathbf{P}_v^M)^T / \chi_v^2, \\ \Phi_s^M &= (\mathbf{I} - \mathbf{P}_s^M (\mathbf{P}_s^M)^T) / \delta_r^2 + \mathbf{P}_s^M (\Lambda_s^M)^{-1} (\mathbf{P}_s^M)^T / \chi_r^2, \end{aligned} \quad (8)$$

其中 \mathbf{I} 为单位阵, δ_v^2 和 χ_v^2 分别为 \mathbf{v} 的 SPE 指标和 T^2 指标控制限, δ_r^2 和 χ_r^2 分别为 \mathbf{e} 的 SPE 指标和 T^2 指标控制限, $\delta_{M,cv}^2$ 和 $\delta_{M,cs}^2$ 分别为动态变化综合指标 φ_v^M 和静态变化综合指标 φ_s^M 的控制限, 综合指标控制限的计算方法参见文献 [31].

3 基于重构贡献与动态时间规整的列车轴承故障原因诊断

检测到轴承异常后, 进一步进行故障定位和原因诊断. 首先, 基于 M-DiCCA 模型, 分别计算沿候选故障变量集方向 Ξ 重构的动态内在典型相关分析的动态综合指标的重构贡献 $RBC_{\Xi}^{\varphi_v}$ 和静态综合指标的重构贡献 $RBC_{\Xi}^{\varphi_s}$, 如式 (9). 再按照文献 [16, 31, 32] 的多向重构方法, 根据各个轴承变量方向的重构贡献的大小定位受故障影响的轴承.

$$\begin{aligned} RBC_{\Xi}^{\varphi_s} &= \mathbf{e}_k \Phi_s \Xi (\Xi^T \Phi_s \Xi)^+ \Xi^T \Phi_s \mathbf{e}_k, \\ RBC_{\Xi}^{\varphi_v} &= \mathbf{v}_{x,k} \Phi_{vv} \Xi (\Xi^T \Phi_{vv} \Xi)^+ \Xi^T \Phi_{vv} \mathbf{v}_{x,k}, \end{aligned} \quad (9)$$

其中 $\mathbf{R} = (\mathbf{W}((\mathbf{P}_v^M)^T \mathbf{W})^{-1})^T$, $\Phi_{vv} = \mathbf{R}^T \Phi_v \mathbf{R}$, $\mathbf{v}_{x,k} = \mathbf{R}^T \mathbf{v}_k$, $\Xi_j = [0 \ 0 \ \dots \ 1 \ \dots \ 0]^T \in \mathbb{R}^m$ 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, Ξ 为多个候选故障轴承变量的方向向量组成的矩阵.

定位故障轴承后, 利用该轴承特有变化趋势的相似性, 诊断故障原因. 首先, 对故障发生时段的原始故障变量去除由速度和环境变化引入的变化; 其后, 根据待诊断案例与历史故障之间由动态时间规整距离定义的相似性来进行故障原因识别.

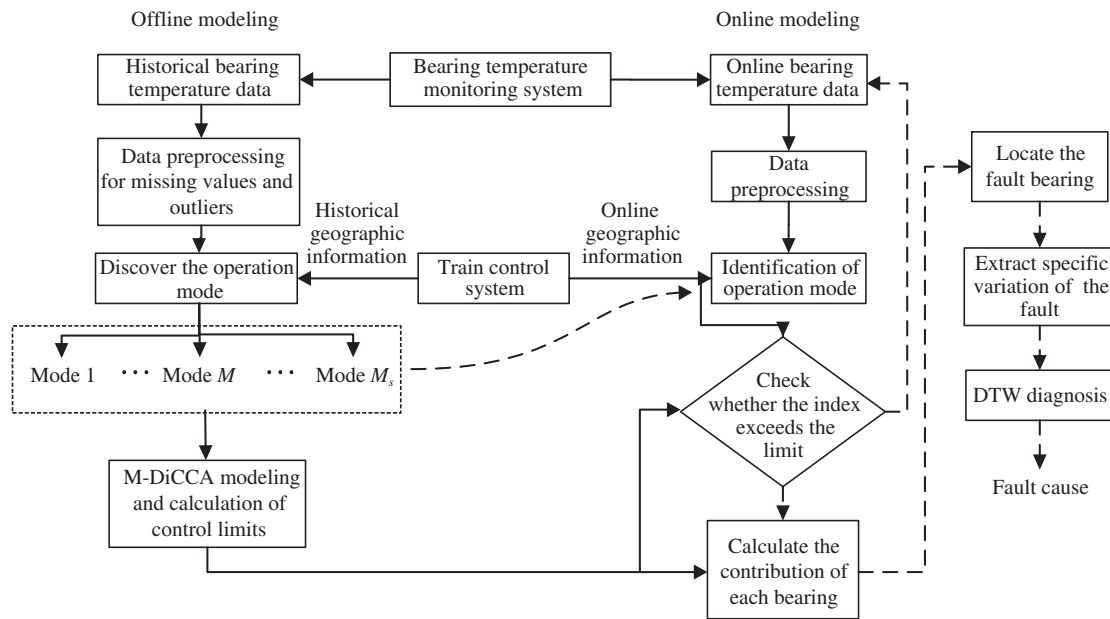


图 3 高速列车轴承多模态运行监控与故障诊断流程图

Figure 3 Flow chart of multi-mode operation monitoring and fault diagnosis for the high-speed train bearings

假设历史已发故障案例由 $\{C_j\}$ ($j = 1, 2, \dots, N_a; N_a$ 为历史故障数) 表示. 对于新发故障的数据特征变化曲线 C_{new} , 计算其与 C_j 的动态时间规整距离, 在此基础上根据如下规则进行故障原因识别:

如果 $DTW(C_{new}, C_j) > \gamma$, 其中 γ 为根据经验设定的阈值, 则 C_{new} 作为新的故障类加入 $\{C_j, j = 1, 2, \dots, N_a\}$, $N_a = N_a + 1$.

本文所提出的高速列车轴承多模态运行监控与故障诊断的整体流程如图 3 所示.

4 实验验证

采用 2018 年 1 月某列车轴温监测系统采集的温度数据以及列控系统采集的地理位置信息, 进行本文所提方法的实验验证. 变量数 $m = 64$, 建模样本选择 1 月 12 日 ~1 月 16 日车辆启动后和入库前的轴温数据, 测试数据包括单天的正常运行数据和某次含有故障的数据.

对含有缺失值和离群点的轴温数据重构. 如图 4 所示, 缺失值填补后的数据保持原有数据相关关系; 如图 5 所示, 离群点重构为正常值.

接下来, 利用历史正常轴承温度数据对轴承变量进行聚类, 以同一颜色描述轴承变量属于同一类, 结果详见图 6, 可见列车在不同运行区间的各轴承聚类划分了两个模态. 在此基础上, 进行基于列车运行轨迹的多模态运行监控, 结果如图 7 和 8 所示. 其中, 图 7 是单一模态的运行监控图, 可以看出正常运行时静态指标 φ_s 超出控制限的误报警. 结合列车控制系统提供的列车地理位置信息, 基于多模态模型对列车轴承进行状态监控, 结果如图 8 所示, 有效降低了误报. 对于含有某故障的轴承数据, 采用本文方法有效检测到 79 样本时刻附近的轴承异常, 如图 9 所示. 由图 9 可以看出, 故障主要影响动态综合指标, 采用图 10(b) 所示的动态综合指标多向重构贡献诊断出 25 号轴承故障. 本次故障案例的原始温度曲线图如图 11 所示, 从该图中可以看出所提方法诊断出故障轴承的早期异常 (见变量 25), 与经现场验证的实际故障情况相符. 此后, 计算异常轴承与故障模式库中的故障参考样本间动态时间规

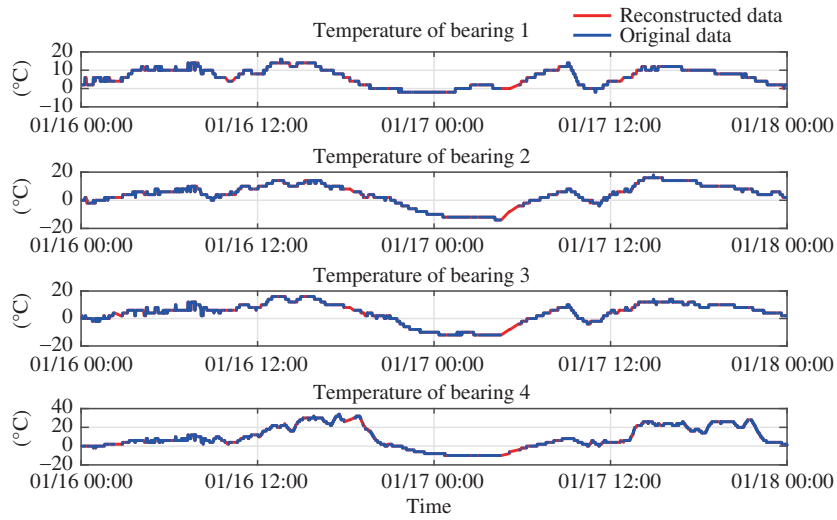


图 4 (网络版彩图) 缺失值插补结果

Figure 4 (Color online) Results of filling missing values




图 5 (网络版彩图) 离群点轴温数据重构. (a) 重构前; (b) 重构后

Figure 5 (Color online) Reconstruction results of outliers of bearing temperatures. (a) Before reconstruction; (b) after reconstruction

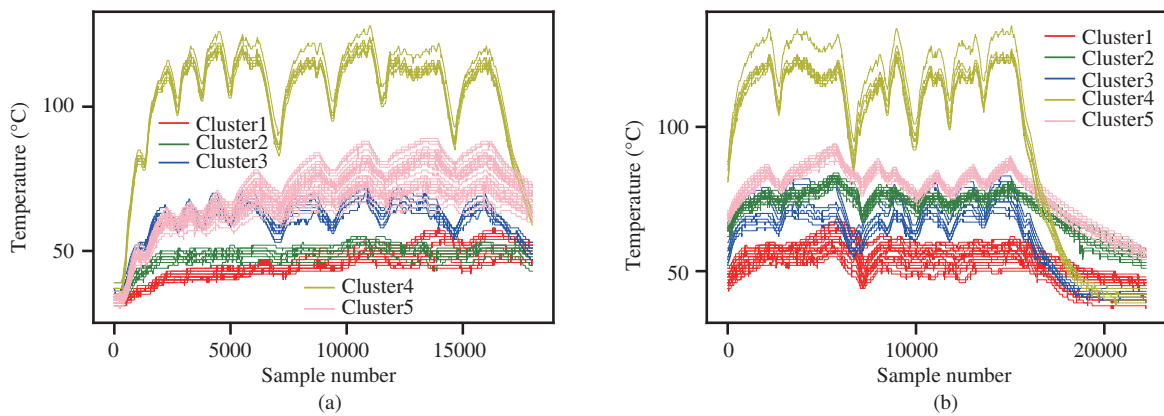


图 6 (网络版彩图) 轴承变量聚类结果. (a) 模式 1; (b) 模式 2

Figure 6 (Color online) Clustering results of bearing variables. (a) Mode 1; (b) Mode 2




图 7 (网络版彩图) 正常运行时单一模态运行监控结果
Figure 7 (Color online) Single modal monitoring results using normal data




图 8 (网络版彩图) 正常运行时多模态运行监控结果
Figure 8 (Color online) Multi-modal monitoring results using normal data

整距离. 取距离最小的为轴承故障原因. 本故障案例与故障模式库中的 3 类故障之间 (即电机定子故障, 电机传动端故障和电机非传动端故障) 的动态时间规整距离分别为 370589, 137070 和 1059, 识别出故障类型 3, 即电机非传动端故障, 与现场确认的原因一致.

5 结束语

结合多模态动态运行的列车多轴轴温的时空相关性, 本文提出了一种数据驱动的基于多模态动态




图 9 (网络版彩图) 故障运行时多模态运行监控结果

Figure 9 (Color online) Monitoring results using the data collected from faulty operation




图 10 (网络版彩图) 轴承变量贡献图. (a) 静态指标; (b) 动态指标

Figure 10 (Color online) Contribution of bearing variables for statistical index. (a) Static index; (b) dynamic index

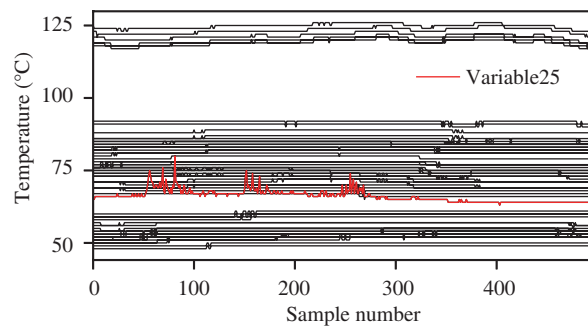


图 11 (网络版彩图) 故障发生早期实际轴温曲线

Figure 11 (Color online) Bearing temperatures for the incipient faults

潜结构的列车轴承运行监控与故障诊断方法. 本文方法有效降低了采用单一模态模型的列车运行轴承异常监控的误报率, 并且成功诊断出故障原因. 下一步将研究去除速度和环境温度影响的轴承状态监控与故障诊断方法.

参考文献

- 1 Randall R B. Vibration-based condition monitoring: industrial, aerospace and automotive applications. *Mech Mach Sci*, 2011, 3: 431–477
- 2 Yi C, Lin J, Zhang W, et al. Faults diagnostics of railway axle bearings based on IMF's confidence index algorithm for ensemble EMD. *Sensors*, 2015, 15: 10991–11011
- 3 Henaio H, Kia S H, Capolino G A. Torsional-vibration assessment and gear-fault diagnosis in railway traction system. *IEEE Trans Ind Electron*, 2011, 58: 1707–1717
- 4 Sha M Y, Liu L G. Summary of bearing fault diagnosis technology based on vibration signal. *Bearing*, 2015, 9: 59–63 [沙美好, 刘利国. 基于振动信号的轴承故障诊断技术综述. *轴承*, 2015, 9: 59–63]
- 5 Yi C, Liu L, Lin J, et al. Quantizing the health state of railway axle bearing via signal-to-noise ratio defined by EEMD and SVD. In: *Proceedings of 2018 IEEE International Conference on Prognostics and Health Management (ICPHM)*, Seattle, 2018. 1–7
- 6 Cheng Y, Wang Z, Zhang W. A novel condition-monitoring method for axle-box bearings of high-speed trains using temperature sensor signals. *IEEE Sensors J*, 2019, 19: 205–213
- 7 Li J, Li M, Zhang J. Rolling bearing fault diagnosis based on time-delayed feedback monostable stochastic resonance and adaptive minimum entropy deconvolution. *J Sound Vib*, 2017, 401: 139–151
- 8 Harkat M F, Mourot G, Ragot J. Sensor failure detection of air quality monitoring network. *IFAC Proc Vol*, 2000, 33: 529–534
- 9 Kourtis T, Macgregor J F. Process analysis, monitoring and diagnosis, using multivariate projection methods. *Chemometrics Intell Lab Syst*, 1995, 28: 3–21
- 10 Kourtis T, Macgregor J F. Recent developments in multivariate SPC methods for monitoring and diagnosing process and product performance. *J Qual Tech*, 1996, 4: 409–428
- 11 Wang X, Kruger U, Irwin G W, et al. Nonlinear PCA with the local approach for diesel engine fault detection and diagnosis. *IEEE Trans Contr Syst Technol*, 2008, 16: 122–129
- 12 Hamadache M, Lee D. Improving signal-to-noise ratio (SNR) for inchoate fault detection based on principal component analysis (PCA). In: *Proceedings of the 14th International Conference on Control, Automation and Systems (ICCAS 2014)*, 2014
- 13 Garcia-Alvarez D, Fuente M J, Sainz G I. Fault detection and isolation in transient states using principal component analysis. *J Process Control*, 2012, 22: 551–563
- 14 Benaicha A, Mourot G, Benothman K, et al. Determination of principal component analysis models for sensor fault detection and isolation. *Int J Control Autom Syst*, 2013, 11: 296–305
- 15 MacGregor J F, Jaeckle C, Kiparissides C, et al. Process monitoring and diagnosis by multiblock PLS methods. *AIChE J*, 1994, 40: 826–838
- 16 Liu Q, Fang T, Dong Y N, et al. Dynamic modeling and reconstruction based fault detection and diagnosis of train bearings. *Acta Autom Sin*, 2019, 45: 2233–2241 [刘强, 方彤, 董一凝, 等. 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: 2233–2241]
- 17 Dong Y N, Qin S J. Dynamic-inner canonical correlation and causality analysis for high dimensional time series data. *IFAC-PapersOnLine*, 2018, 51: 476–481
- 18 Dong Y N, Qin S J. Dynamic latent variable analytics for process operations and control. *Comput Chem Eng*, 2018, 114: 69–80
- 19 Hartigan J A, Wong M A. A K-means clustering algorithm. *Appl Stat*, 2013, 28: 100–108
- 20 Karypis G, Han E H, Kumar V. Chameleon: hierarchical clustering using dynamic modeling. *Computer*, 1999, 32: 68–75
- 21 Zhao S J, Zhang J, Xu Y M. Monitoring of processes with multiple operating modes through multiple principle component analysis models. *Ind Eng Chem Res*, 2004, 43: 7025–7035

- 22 Zhao C H, Wang F L, Lu N Y, et al. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes. *J Process Control*, 2007, 17: 728–741
- 23 Yao Y, Gao F R. Phase and transition based batch process modeling and online monitoring. *J Process Control*, 2009, 19: 816–826
- 24 Pang X S. The methods of comparison of missing data processing. *Stat Dec*, 2010, 2010: 152–155
- 25 Deshpande A, Dong Y N, Li G, et al. Data processing framework for data cleansing. US Patent, US20160179599A1, 2016-06-23
- 26 Ku W, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis. *Chemomet Intell Lab Syst*, 1995, 30: 179–196
- 27 Lennart L. *System Identification: Theory for the User*. Upper Saddle River: PTR Prentice Hall, 1999. 9–11
- 28 Candés E J, Li X, Ma Y, et al. Robust principal component analysis? *J ACM*, 2011, 58: 1–37
- 29 Berndt D J, Clifford J. Using dynamic time warping to find patterns in time series. In: *Proceedings of KDD Workshop*, 1994. 359–370
- 30 Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring. *J Process Control*, 2018, 67: 1–11
- 31 Yue H, Qin S J. Reconstruction-based fault identification using a combined index. *Ind Eng Chem Res*, 2001, 40: 4403–4414
- 32 Li G, Qin S J, Chai T, et al. Multi-directional reconstruction based contributions for root-cause diagnosis of dynamic processes. In: *Proceedings of American Control Conference*, 2014. 3500–3505

附录 A

算法 A1 K-均值聚类算法^[26]

- (1) 给定大小为 n 的数据集 \mathbf{X} , 令 $q = 1$, 随机选取 h 个初始的聚类中心 $\mathbf{Y}_c(q)$, $c = 1, 2, \dots, h$.
 - (2) 计算每个数据对象与聚类中心 $\mathbf{Y}_c(q)$ 的动态时间规整距离 $\text{DTW}(\mathbf{x}_a, \mathbf{Y}_c(q))$, $a = 1, 2, \dots, n$; $c = 1, 2, \dots, h$. 如果满足 $\text{DTW}(\mathbf{x}_a, \mathbf{Y}_c(q)) = \min\{\text{DTW}(\mathbf{x}_a, \mathbf{Y}_c(q))\}$, 则 $\mathbf{x}_a \in C_h$.
 - (3) 重新计算 h 个新的聚类中心, $\mathbf{Y}_c(q+1) = \frac{1}{n_c} \sum_{a=1}^{n_c} \mathbf{x}_a^c$, 即取聚类中所有元素各自维度的平均.
 - (4) 根据下式判断迭代是否结束, 如果 $\|\mathbf{Y}_c(q+1) - \mathbf{Y}_c(q)\|^2 > \lambda$, 则 $q = q + 1$, 返回步骤 (2) 继续迭代, 否则算法结束.
-

算法 A2 动态内在典型相关分析算法^[17]

- (1) 归一化 \mathbf{X} 为零均值和单位方差, 初始化 $\boldsymbol{\omega}$ 为随机单位向量.
 - (2) 求解 $\boldsymbol{\omega}, \boldsymbol{\beta}$, 迭代步骤 (2) 直至 t 收敛.

$$\mathbf{t} = \mathbf{X}\boldsymbol{\omega}, \mathbf{t} = \mathbf{t}/\|\mathbf{t}\|,$$

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

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

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

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

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

$$\boldsymbol{\omega} = (\mathbf{X}_{s+1}^T \mathbf{X}_{s+1} + \mathbf{X}_\beta^T \mathbf{X}_\beta)^+ (\mathbf{X}_{s+1}^T \sum_{i=1}^s \beta_i \mathbf{t}_{s-i+1} + \mathbf{X}_\beta^T \mathbf{t}_{s+1}).$$
 - (3) 计算 \mathbf{X} 的残差.

$$\mathbf{X} := \mathbf{X} - \mathbf{t}\mathbf{p}^T; \mathbf{p} = \mathbf{X}^T \mathbf{t}/\mathbf{t}^T \mathbf{t}.$$
 - (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 $\boldsymbol{\omega}$ 组成负载矩阵 $\mathbf{W} = [\boldsymbol{\omega}_1 \boldsymbol{\omega}_2 \cdots \boldsymbol{\omega}_l]$.
-

Data-driven multimodal operation monitoring and fault diagnosis of high-speed train bearings

Qiang LIU^{1*}, Zhiqiang ZHAN¹, Shuo WANG¹, Yingxiang LIU² & Tong FANG¹

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

2. *Viterbi School of Engineering, University of Southern California, Los Angeles 90089, USA*

* Corresponding author. E-mail: liuq@mail.neu.edu.cn

Abstract The multiple bearings of high-speed trains operate in a similar condition that correlates the bearings' temperatures dynamically. This allows for detecting bearing abnormalities and diagnosing the faults according to unexpected changes in the dynamic relations. Traditional single-modal modeling methods do not consider the different dynamic characteristics while the train is in different operating zones. This leads to difficulty with modeling the relationship using a single model, resulting in false alarms. To solve the above problems, the bearing temperature data collected by the bearing temperature monitoring system, the location information of the historical bearing fault alarms collected by the train control system, and the maintenance data are incorporated to identify the operation modes. In this paper, a novel data-driven multimodal bearing operation monitoring and fault diagnosis method is proposed for high-speed trains. First, to manage the outliers and missing values caused by train network communication disconnection and sensor faults, a preprocessing method, which combines linear-filling and a dynamic principal component pursuit, is proposed to reconstruct the contaminated data of the bearing temperatures. Second, the train location information-based operation mode identification method is proposed according to the fact that the clustering results of multiple bearing temperature correlations match well with the operating zone, extracted from the location information of historical faults. Third, a multimodal dynamic inner canonical correlation analysis (M-DiCCA) modeling method and the corresponding operation monitoring method for the train bearings are proposed. Subsequently, a dynamic time warping (DTW)-based fault diagnosis method is proposed. Finally, the application results by using the bearing temperature data collected from practical train operations demonstrate the effectiveness of the proposed methods.

Keywords dynamic data modeling, dynamic time warping, fault diagnosis, multimodal modeling



Qiang LIU was born in 1980. He is a professor at Northeastern University, China. His research interests are centered on machine learning and fault diagnosis of complex systems.



Zhiqiang ZHAN was born in 1996. He is a master's student at Northeastern University, China. His research interests include statistical process monitoring and machine learning.



Shuo WANG was born in 1994. He is a master's student at Northeastern University, China. His research interests include statistical process monitoring of complex systems.



Yingxiang LIU was born in 1994. He is a Ph.D. candidate at the University of Southern California, USA. His research interests include machine learning, statistical process monitoring, and fault diagnosis of complex systems.