

数据驱动高速列车动态牵引系统的故障诊断

姜斌^{1,2*}, 陈宏田^{1,3}, 易辉⁴, 陆宁云^{1,2}

1. 南京航空航天大学自动化学院, 南京 211106, 中国

2. 南京航空航天大学江苏省物联网与控制技术重点实验室, 南京 211106, 中国

3. Department of Chemical and Materials Engineering, University of Alberta, Edmonton T6G 1H9, Canada

4. 南京工业大学电气工程与控制科学学院, 南京 211816, 中国

* 通信作者. E-mail: binjiang@nuaa.edu.cn

收稿日期: 2019-10-07; 修回日期: 2019-11-30; 接受日期: 2019-12-07; 网络出版日期: 2020-04-03

国家自然科学基金(批准号: 61490703, 61922042)资助项目

摘要 牵引系统为高速列车的重要组成部分, 其可靠性对列车安全运行至关重要。本文利用牵引系统传感器数据, 提出了一种最优的数据驱动故障检测与诊断(fault detection and diagnosis, FDD)方法, 用于解决动态牵引系统的故障诊断问题。首先, 基于传感器数据构建系统模型, 用于描述牵引系统动态。然后, 通过相关性与子系统辨识技术, 定义残差生成器以及故障检测统计量。而后根据改进的支持向量机(support vector machine, SVM), 研究了最优的数据驱动故障诊断问题。最后, 通过中车株洲电力机车研究所有限公司的高速列车实验平台, 验证了所提出方法的合理性与有效性。

关键词 高速列车, 牵引系统, 数据驱动, 故障诊断

1 引言

自 1964 年日本“新干线”诞生, 高速列车凭借快速、舒适、准时等特点, 在过去 50 多年取得了长足发展^[1]。仅在 2018 年, 中国高速列车运送旅客达 20.7 亿人次, 每天在轨运行的列车约 5 千至 7 千辆。牵引系统作为高速列车的“心脏”, 对列车安全运行起到至关重要的影响。然而高速列车牵引系统故障时有发生, 故快速、准确、在线地检测与诊断列车牵引系统故障具有重要意义, 目前已成为智能交通领域的挑战难题之一^[2~7]。

依据 2017 年中国国家铁路局发布的“铁路动车组运用维修规程”¹⁾, 根据高速列车运行时间与历程, 其(含牵引系统)检修共分为 5 个等级, 其中 1 级日检与 2 级月检主要为人工日常检查, 3, 4, 5 级侧重于对列车进行维修。此类故障诊断与检修策略的缺点可归结为: (1) 可靠性低, 难以发现微小故障;

1) http://www.nra.gov.cn/jgjf/flfg/gfxwj/fbsj/2017-/201803/t20180302_52968.shtml

引用格式: 姜斌, 陈宏田, 易辉, 等. 数据驱动高速列车动态牵引系统的故障诊断. 中国科学: 信息科学, 2020, 50: 496–510, doi: 10.1360/SSI-2019-0220
Jiang B, Chen H T, Yi H, et al. Data-driven fault diagnosis for dynamic traction systems in high-speed trains (in Chinese). Sci Sin Inform, 2020, 50: 496–510, doi: 10.1360/SSI-2019-0220

(2) 效率低下, 最长可导致一个月的故障检测延时; (3) 成本高, 耗费巨大人力物力。除此之外, 列车配备了故障保护设备与安全监控装置, 用于实时检测幅值较大的故障^[8]。然而, 此类控制限的方法可靠性低, 不能满足现有列车组高安全性的需求^[7]。

鉴于上述因素, 很多学者针对高速列车牵引系统的实时故障检测与诊断 (fault detection and diagnosis, FDD) 问题, 分别从理论与应用角度开展了广泛研究^[9~16]。目前, 现有的高速列车 FDD 方法可分为 3 类^[5]: 基于模型的方法, 基于信号分析的方法和基于数据驱动的方法。

在列车牵引系统的物理/数学模型已知的情况下, 基于模型的 FDD 方法可以通过设计残差生成器与评价函数, 完成实时的高速列车 FDD 任务。文献 [10] 提出了一种全维观测器, 用于诊断速度传感器与扭矩传递系统的故障。基于牵引系统数学模型, 文献 [17] 设计了一种故障检测滤波器, 可以有效地消除由于间歇性故障所带来的影响。利用混合逻辑动态模型和残差生成器, 文献 [18] 给出了一类简洁观测器, 可以快速诊断牵引系统的绝缘栅双极型晶体管开路故障。文献 [14] 根据牵引系统的精确数学模型, 设计了一类鲁棒的故障检测与隔离方法, 可以有效地检测传感器故障并且可以实现故障信号的辨识。

基于信号分析的方法主要利用牵引系统信号所蕴含的时域、频域、时频域特征等重要信息, 直接完成 FDD 任务。尤其对于高速列车旋转设备的机械故障, 此类方法具有绝对优势。目前, 该类方法辅助于人工检修, 被广泛应用于牵引系统的 FDD 问题。如文献 [19] 根据正常与故障情况下牵引系统信号在时域的差异, 提出了实时的绝缘栅双极型晶体管开路故障检测与隔离方案。文献 [20] 利用离散傅里叶 (Fourier) 变换技术提取频域信息, 进而设计了一种用于诊断齿轮磨损故障的策略。为了有效地检测牵引逆变器中绝缘栅双极型晶体管的开路故障, 文献 [21] 结合熵与小波变换技术提取信号中的时频域信息, 从而达成牵引系统 FDD 的目的。

由于数据驱动 FDD 方法具有易实现性、良好可移植性等优点, 在近十年被广泛用于牵引系统的 FDD 研究^[5, 22]。如文献 [15] 采用非线性主元分析与随机森林方法, 研究了列车牵引逆变器故障诊断问题。针对信号的非高斯 (non-Gaussian) 特性, 文献 [11] 基于牵引系统信号间的相关性, 提出了基于典型相关分析 (canonical correlation analysis, CCA) 的牵引系统故障检测方法。文献 [6, 12] 基于主元分析, 设计了用于牵引系统的微小 FDD 方案。

上述方法中, 基于信号分析与基于数据驱动的 FDD 方法常要求高速列车牵引系统运行在某个工作点, 以满足这些方法的应用前提。此外, 基于模型的方法需要事先进行复杂的牵引系统建模, 由于运行机理复杂且很难考虑外部不确定性, 故在线 FDD 应用目前仍较难实现。文献 [5] 指出, 对于数据驱动的牵引系统 FDD 任务而言, 第 1 个难点在于如何处理牵引系统的动态问题来保证可以达到实时的 FDD 目的; 第 2 个难点在于, 牵引系统各个部件发生故障的概率不同, 导致离线的故障数据集大小不同, 从而出现诊断偏好问题。

由于外部环境变化与不同任务需求, 高速列车常处于动态的运行状态^[8], 很难保证列车长时间工作在某个恒定的平衡点。如文献 [23] 通过高速列车的运行速度与所在位置, 描述了牵引系统的动态性能。据目前可参阅文献, 现有数据驱动的高速列车 FDD 研究 (如文献 [9, 11, 12]) 往往要求牵引系统处于某静态工作点。故仅根据所收集的离线数据, 如何处理高速列车牵引系统的动态性能进而实现 FDD 任务, 是目前的一大难点。此外, 高速列车由不同类型的机械、电子等器件组成。这些器件具有不尽相同的使用寿命、工作机理、物理结构, 导致其发生故障的概率不同^[8]。文献 [4] 对牵引系统不同的故障类型、故障位置进行了阐述与总结。例如, 根据列车牵引系统故障发生的时间 (或周期), 一些故障可被定义为间歇故障。该类非永久性的间歇故障出现时间短, 可自行消失, 且可反复出现^[3]。与常见故障 (如电容故障、传感器故障等^[24]) 相比, 此类故障的样本集极小, 且很难被收集, 这将使得故障样本出

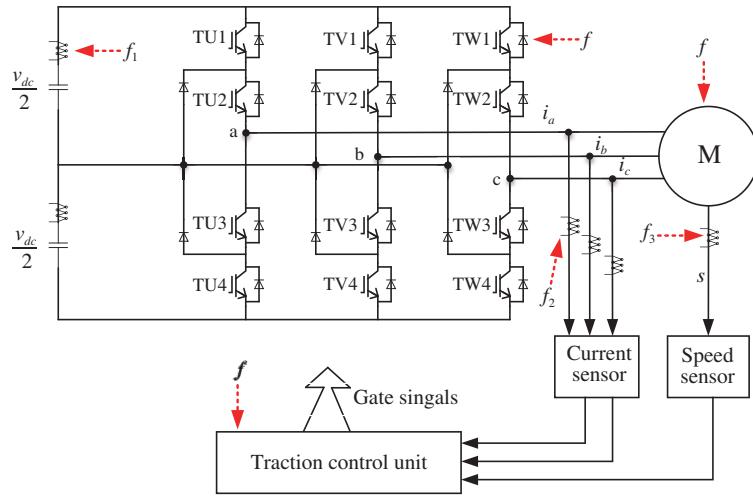


图 1 (网络版彩图) CRH2 型高速列车牵引系统原理图

Figure 1 (Color online) Schematic diagram of traction systems in CRH2-type high-speed trains

现不平衡问题。若直接采用传统的 FDD 方法进行故障诊断, 将出现诊断偏好问题^[25] 进而降低 FDD 性能。如何基于不均衡的故障样本数据集进行有效的 FDD, 是实际任务的另一个难题。据目前可参阅文献, 对于所述高速列车牵引系统 FDD 挑战, 上述研究仍是空白。

为此, 本文提出了最优的牵引系统 FDD 方案, 同时考虑了牵引系统动态问题与样本不均衡问题。本文所设计方法的创新点在于: (1) 与以往数据驱动方法相比, 所提出的故障检测算法可以充分利用牵引系统可测数据不同时刻间的相关性, 设计适用于动态工况的故障检测残差, 且具有提升的故障检测性能。(2) 与传统支持向量机 (support vector machine, SVM) 相比, 所设计基于改进 SVM 的故障诊断算法可以通过考虑故障样本总体风险问题, 实现牵引系统故障样本不均衡情况下的最优诊断性能。最后根据中车株洲电力机车研究所有限公司 (以下简称中车株洲所) 的 dSPACE 平台, 论证所设计 FDD 方法的有效性。

2 预备知识与问题陈述

本节首先介绍了高速列车牵引系统的结构, 而后根据传感器采集的数据进行建模, 最后基于构建的动态数据模型, 引出本文所要实现的最优故障诊断性能目标。

2.1 牵引系统

牵引系统是高速列车的核心部件, 为整个列车运行提供充足动力源^[7]。以 CRH2 型高速列车的牵引系统为例, 其主要包含牵引变压器、三电平牵引逆变器、牵引电机、牵引控制单元、滤波器等^[8]。该类牵引系统采用电压空间矢量脉宽调制策略, 其(从中间环节至牵引电机)原理图如图 1 所示。

为了实时控制列车和监控列车运行状态, 牵引系统中安装有不同类型的传感器, 如电压传感器、电流传感器、速度传感器和温度传感器等^[26]。如图 1 所示, 列车牵引系统的不同电气元器件可能发生故障。可根据发生故障的器件或位置将其分为^[27] 变流器故障、电机故障、控制单元故障、传感器故障等。

2.2 数据建模

根据列车牵引系统运行机理, 其离散的系统模型可表示为

$$\begin{aligned} x(k+1) &= Ax(t) + Bu(t) + F_1f_1(k) + w(k), \\ y(k) &= Cx(t) + Du(k) + F_2f_2(k) + v(k), \end{aligned} \quad (1)$$

其中 A, B, C, D, F_1, F_2 为已知适维矩阵; $x \in \mathbb{R}^{m_n}$ 为系统状态; $u \in \mathbb{R}^{m_l}$ 为系统输入; $y \in \mathbb{R}^{m_m}$ 为系统输出; $f_1 \in \mathbb{R}^{m_n}$ 与 $f_2 \in \mathbb{R}^{m_m}$ 为故障; $w \in \mathbb{R}^{m_n}$ 与 $v \in \mathbb{R}^{m_m}$ 为独立同分布的高斯白噪声, 且满足

$$\begin{aligned} \text{var} \begin{bmatrix} w(k) \\ v(k) \end{bmatrix} &= \begin{bmatrix} \Sigma_{ww} & \Sigma_{wv} \\ \Sigma_{wv}^T & \Sigma_{vv} \end{bmatrix} \sigma_{i,j}, \\ \mathbb{E}[w(k)] &= 0, \quad \mathbb{E}[v(k)] = 0, \end{aligned} \quad (2)$$

其中 $\sigma_{i,j}$ 为 Kronecker 算子, 即当 $i = j$ 时 $\sigma_{i,j} = 1$, 其他情况下 $\sigma_{i,j} = 0$.

对于式(1)所描述的列车牵引系统, 实际可测/可知的信号为系统输入 u 与系统输出 y . 考虑间隔 s 与 N , 则可定义堆栈矩阵 $U_{k,s}$ 与 $Y_{k,s}$ 为

$$\begin{aligned} U_{k,s} &= [U_{k-s}^T \cdots U_k^T]^T = [u_s(k) \cdots u_s(k+N-1)] \in \mathbb{R}^{(s+1)m_l \times N}, \\ Y_{k,s} &= [Y_{k-s}^T \cdots Y_k^T]^T = [y_s(k) \cdots y_s(k+N-1)] \in \mathbb{R}^{(s+1)m_m \times N}, \end{aligned} \quad (3)$$

其中

$$\begin{aligned} U_s &= [u(k) \cdots u(k+N-1)] \in \mathbb{R}^{m_l \times N}, \\ u_s(k) &= [u^T(k-s) \cdots u^T(k)]^T \in \mathbb{R}^{(s+1)m_l}, \\ Y_s &= [y(k) \cdots y(k+N-1)]^T \in \mathbb{R}^{m_m \times N}, \\ y_s(k) &= [y^T(k-s) \cdots y^T(k)] \in \mathbb{R}^{(s+1)m_m}. \end{aligned} \quad (4)$$

当牵引系统(1)无故障情况下, 可根据式(3)与(4)得到

$$Y_{k,s} = \Gamma_s X_{k-s} + H_{u,s} U_{k,s} + H_{w,s} W_{k,s} + V_{k,s}, \quad (5)$$

其中

$$\begin{aligned} \Gamma_s &= [C^T \cdots (A^s)^T C^T] \in \mathbb{R}^{(s+1)m_m \times m_n}, \\ H_{u,s} &= \begin{bmatrix} D & 0 & \cdots & 0 \\ CB & D & 0 & \vdots \\ \vdots & \vdots & D & 0 \\ CA^{s-1}B & \cdots & CB & D \end{bmatrix} \in \mathbb{R}^{(s+1)m_m \times (s+1)m_l}, \\ H_{w,s} &= \begin{bmatrix} D & 0 & \cdots & 0 \\ C & D & 0 & \vdots \\ \vdots & \vdots & 0 & 0 \\ CA^{s-1} & \cdots & C & D \end{bmatrix} \in \mathbb{R}^{(s+1)m_m \times (s+1)m_n}, \end{aligned} \quad (6)$$

且 $W_{k,s} = [w_s(k) \cdots w_s(k+N-1)] \in \mathbb{R}^{(s+1)m_n \times N}$, $V_{k,s} = [v_s(k) \cdots v_s(k+N-1)] \in \mathbb{R}^{(s+1)m_m \times N}$, $w_s(k) = [w^T(k-s) \cdots w^T(k)]^T \in \mathbb{R}^{(s+1)m_n}$, $v_s(k) = [v^T(k-s) \cdots v^T(k)]^T \in \mathbb{R}^{(s+1)m_m}$.

模型 (5) 即为牵引系统的输入输出数据模型, 充分考虑了牵引系统的运行动态.

2.3 问题陈述及本文目标

虽然模型 (5) 隐含牵引系统的输入输出关系, 但在实际应用中只有数据矩阵 $U_{k,s}$ 与 $Y_{k,s}$ 已知. 另外, 由于列车牵引系统中各类元器件具有不同的寿命周期, 导致不同故障发生的概率不同, 将使得收集的离线故障数据 (训练样本) 出现不均衡问题. 这将使得某些机器学习方法如 SVM 在进行故障诊断时, 出现偏好问题而导致诊断精度不尽人意.

因此, 基于上述问题, 本文将实现的目标如下:

- (1) 根据已知的数据矩阵 $U_{k,s}$ 与 $Y_{k,s}$, 实现数据驱动的残差设计, 用于牵引系统的故障检测问题.
- (2) 基于得到的残差, 通过构建可变的惩罚因子, 设计对牵引系统故障样本量不均衡问题具有鲁棒性的故障诊断方法, 且可实现最优的故障诊断性能.

3 最优故障诊断方法

本节首先根据输入输出数据, 定义了基于数据形式的残差; 而后根据残差信号, 设计了具有可变惩罚因子的 SVM 诊断策略; 最后通过数学分析阐述方法的最优性能.

3.1 数据驱动故障检测

为了利用数据模型 (5) 以及已知数据矩阵 $U_{k,s}$ 与 $Y_{k,s}$ 进行牵引系统故障检测, 首先给出以下定义 1.

定义1 ([28]) 当系统 (1) 无故障无噪声时, 如果对于任意 u_s 和 $x(0)$,

$$r(k) = \mathcal{M}[u_s^T(k) \ y_s^T(k)]^T = 0 \quad (7)$$

成立, 则矩阵 \mathcal{M} 为数据驱动实现的稳定核代表.

根据定义 1 可知, 需要设计合适的 \mathcal{M} 使得式 (7) 成立, 从而得到残差信号 $r(k)$ 并进一步用于牵引系统的故障检测.

定义 $e(k) = y(k) - \hat{y}(k)$, 根据卡尔曼 (Kalman) 滤波技术, 式 (5) 可等价地表示为 [29]

$$(I - H_{y,s}^K) Y_{k,s} = E_{k,s} + \Gamma_s^K \hat{X}_{k-s} + H_{u,s}^K U_{k,s}, \quad (8)$$

其中

$$\begin{aligned}\Gamma_s^K &= [C^T \cdots (A_K^s)^T C^T], \\ H_{u,s}^K &= \begin{bmatrix} D & 0 & \cdots & 0 \\ CB_K & D & 0 & \vdots \\ \vdots & \vdots & D & 0 \\ CA_K^{s-1}B_K & \cdots & CB_K & D \end{bmatrix}, \\ H_{y,s}^T &= \begin{bmatrix} 0 & 0 & \cdots & 0 \\ CK & 0 & 0 & \vdots \\ \vdots & \vdots & 0 & 0 \\ CA_K^{s-1}K & \cdots & CK & 0 \end{bmatrix},\end{aligned}\tag{9}$$

$$A_K = A - KC,$$

$$B_K = B - KC,$$

且 $E_{k,s}$ 与式 (3) 中的数据矩阵定义具有相同形式, K 为卡尔曼滤波增益矩阵.

由于时间间隔 s 较大时 $A_K^s \approx 0$, 则式 (8) 的向量形式可表示为

$$(I - H_{y,s}^K) y_f = e_f + [\Gamma_s^K \Pi_u \ \Gamma_s^K \Pi_y \ H_{u,s}^K] \begin{bmatrix} u_p(k) \\ y_p(k) \\ u_f(k) \end{bmatrix},\tag{10}$$

其中下标 p 与 f 分别代表 k 时刻前与 k 时刻后; Π_u 与 Π_y 为由 A_K, B_K, B 组成的矩阵. 则矩阵 \mathcal{M} 可进一步定义为

$$\mathcal{M} = [\Gamma_s^K \Pi_u \ \Gamma_s^K \Pi_y \ H_{u,s}^K \ (H_{y,s}^K - I)].\tag{11}$$

对于输入输出数据 U_p, U_f, Y_p, Y_f , 则有

$$\frac{1}{N-1} \begin{bmatrix} \begin{bmatrix} U_p \\ Y_p \\ U_f \end{bmatrix} [U_p^T \ Y_p^T \ U_f^T] \begin{bmatrix} U_p \\ Y_p \\ U_f \end{bmatrix} Y_f^T \\ * \quad \quad \quad Y_f Y_f^T \end{bmatrix} = \begin{bmatrix} \Sigma_{pp} & \Sigma_{pf} \\ * & \Sigma_{ff} \end{bmatrix}.\tag{12}$$

对 $\Sigma_{pp}^{-1/2} \Sigma_{pf} \Sigma_{ff}^{-1/2}$ 进行以下奇异值分解:

$$\Sigma_{pp}^{-1/2} \Sigma_{pf} \Sigma_{ff}^{1/2} = P \Lambda R^T, \quad \Lambda = \begin{bmatrix} \Lambda_l & 0 \\ 0 & 0 \end{bmatrix}.\tag{13}$$

而后可通过以下定义:

$$\begin{aligned}J \Lambda_l &= \Sigma_{pp}^{-1/2} P(:, 1:l) \Lambda_l = [\Gamma_s^K \Pi_u \ \Gamma_s^K \Pi_y \ H_{u,s}^K]^T, \\ L &= \Sigma_{ff}^{-1/2} R(:, 1:l) = (I - H_{y,s}^K)^T,\end{aligned}\tag{14}$$

得到用于故障检测的矩阵 \mathcal{M} .

故用于检测牵引系统故障的残差信号可定义为

$$r(k) = L^T y_f(k) - \Lambda_l J^T [u_p^T(k) \ y_p^T(k) \ u_f^T(k)]^T. \quad (15)$$

当牵引系统在健康运行的状况下, $r_n(k)$ 满足

$$r_n(k) \sim \mathcal{N}(0, I - \Lambda_l^2), \quad (16)$$

且

$$J(r_n(k)) = r_n(k)^T (I - \Lambda_l^2)^{-1} r_n(k) \sim \chi^2(l). \quad (17)$$

令故障误报率为 α , 则 T^2 统计量的阈值可设定为

$$J_{\text{th}} = \chi_{\alpha}^2(l). \quad (18)$$

与文献 [30] 不同之处为, 本节所设计的方法主要基于奇异值分解, 辨识牵引系统的稳定核代表矩阵. 根据所辨识的矩阵 \mathcal{M} , 设计用于动态系统故障检测的残差.

3.2 数据驱动故障诊断

假设牵引系统离线数据包含 \mathcal{T} 种故障, 即 \mathcal{F}_τ , 其中 $\tau = 1, \dots, \mathcal{T}$. 当故障通过式 (17) 中的 T^2 统计量成功检测后, 可依据式 (15) 标记相应的残差信号为 $\mathcal{S} = \{(r_1, l_1), \dots, (r_{N_\tau}, l_\tau), \dots, (r_{N_f}, l_\mathcal{T})\}$, 且 $N_f = N_1 + \dots + N_\mathcal{T}$ 为故障样本的总个数, N_τ 为故障 \mathcal{F}_τ 的样本数. 对于上述多类故障诊断问题, 可将其标签表示为

$$l_\tau = \begin{cases} 1, & \text{if } r \in \mathcal{F}_1 = \{1, \dots, N_1\}, \\ \vdots \\ \mathcal{T}, & \text{if } r \in \mathcal{F}_\mathcal{T} = \{N_1 + \dots + N_{\mathcal{T}-1} + 1, \dots, N_f\}. \end{cases} \quad (19)$$

本文采用一对多法 (one-versus-rest) 的方式, 考虑式 (19) 中的故障样本不均衡问题. 即令所有非 1 的标签为 -1 , 定义以下目标函数寻找最优的故障分类超平面:

$$\begin{aligned} & \min \frac{1}{2} \|\omega\|^2 + C_1 \sum_{i=1}^{N_1} \xi_i + C_2 \sum_{i=N_1+1}^{N_f} \xi_i \\ & \text{s.t. } l_\tau(\omega^T r + b) \geq 1 - \xi_i, \\ & \quad \xi_i \geq 0, \\ & \quad C_1 = C_2(N_f - N_1)/N_1, \end{aligned} \quad (20)$$

其中 ω 和 b 分别为故障诊断超平面的权重与偏置; C_1, C_2 为惩罚因子; ξ_i 为松弛变量, 且 $i = 1, \dots, N_f$.

根据故障样本数, 优化目标 (20) 对不同类型的数据增加了对惩罚因子的约束, 以期通过每类故障样本总体风险尽可能相同, 实现最优的故障诊断效果. 在式 (20) 中, C_2 为非第一类故障样本的惩罚因子.

对于上述目标函数, 本文的求解过程归纳如下.

Step 1. 定义权重向量 $m = [m_1 \cdots m_{N_f}]^T \in \mathbb{R}^{N_f}$. 首先, 设定初始化参数 $C_1 = C_2 = 100$, $m = 1/N_f[1 \cdots 1]^T$. 根据传统 SVM 方法, 得到诊断结果.

Step 2. 根据分类误差生成新超平面:

$$\varepsilon = \sum_{i=1}^{N_f} \frac{\operatorname{sgn}|(\omega^T r + b) - l_\tau|}{2}. \quad (21)$$

当 $\varepsilon = 0$ 或 ε 小于可容忍的误判率时, m 向量不做修改. 否则需根据下式 (22) 更新加权向量, 即

$$m_i^{\text{new}} = \begin{cases} m_i^{\text{old}} \sqrt{\varepsilon/(1-\varepsilon)}, & \text{当 } \operatorname{sgn}|(\omega^T r + b) - l_\tau| = 0, \\ m_i^{\text{old}} \sqrt{(1-\varepsilon)/\varepsilon}, & \text{当 } \operatorname{sgn}|(\omega^T r + b) - l_\tau| \neq 0, \end{cases} \quad (22)$$

其中 $i = 1, \dots, N_f$. 则可得新残差信号为 $\mathcal{S}^{\text{new}} = \{(m_1 r_1, l_1), \dots, (m_{N_\tau} r_{N_\tau}, l_\tau), \dots, (m_{N_f} r_{N_f}, l_\tau)\}$. 结合给定 C_1, C_2 得到新的超平面, 并定义为 $(\omega^{\text{new}})^T r + b^{\text{new}}$.

Step 3. 得到新的超平面后, 需要在此基础上调整惩罚因子, 使得满足优化目标 (20) 中相关惩罚因子的约束条件. 关于惩罚因子的更新法则为

$$\begin{aligned} C_1 &= \frac{\epsilon c_i}{A} \|\omega^{\text{new}}\|^2, \quad i = 1, \dots, N_1, \\ C_2 &= \frac{\epsilon c_i}{B} \|\omega^{\text{new}}\|^2, \quad i = N_1 + 1, \dots, N_f, \end{aligned} \quad (23)$$

其中,

$$\begin{aligned} c_i &= \begin{cases} 1/N_1, & \text{如果 } r \text{ 在超平面上,} \\ m_i, & \text{其他情况,} \end{cases} \\ A &= \sum_{i=1}^{N_1} c_i \max(1 - (\omega^{\text{new}})^T r - b), \\ B &= \sum_{i=N_1+1}^{N_f} c_i \max(1 + (\omega^{\text{new}})^T r + b). \end{aligned} \quad (24)$$

Step 4. 更新参数 m, C_1, C_2 , 通过求解 (20) 得到优化的超平面, 用于后续的 FDD 问题.

3.3 最优性能分析

本小节将从相关性与损失风险两个角度, 讨论所设计 FDD 方案的最优性能.

注释1 通过考虑不同时刻数据间的相关性得到式 (11) 中 \mathcal{M} 矩阵, 从而保证了最优的故障检测性能.

当牵引系统存在噪声与故障 (如式 (1) 所示) 时, 可得到残差信号为

$$r_\tau(k) = e_s(k) + H_{F_1,s} f_{1,s}(k) + H_{F_2,s} f_{2,s}(k), \quad (25)$$

其中矩阵 $H_{F_1,s}$ 与 $H_{F_2,s}$ 可依据式 (6) 或 (9) 得到. 在式 (25) 中, e_s 的波动主要源于随机的噪声, 而 $H_{F_1,s} f_{1,s}(k) + H_{F_2,s} f_{2,s}(k)$ 的变化主要源于系统存在的故障. 假设牵引系统只发生故障 $f_{1,s}$, 则上式可简化为 $r_\tau(k) = e_s(k) + H_{F_1,s} f_{1,s}(k)$. 由于本文所设计的方法充分考虑了系统的动态性能, 故在同一工作模式/工况下, 牵引系统输入 u 的变化不会对式 (25) 中的残差信号造成影响.

采用 T^2 统计量, 则有

$$\begin{aligned} T^2(r_\tau(k)) &= e_s(k)^T(I - \Lambda_l^2)^{-1}e_s(k) \\ &+ (H_{F_1,s}f_{1,s}(k) + H_{F_2,s}f_{2,s}(k))^T(I - \Lambda_l^2)^{-1}(H_{F_1,s}f_{1,s}(k) + H_{F_2,s}f_{2,s}(k)). \end{aligned} \quad (26)$$

式 (12)~(14) 通过奇异值分解, 使得 Λ_l 最大从而保证式 (26) 对故障具有最好的检测性能.

注释2 式 (20) 关于惩罚因子的约束, 可以保证当样本不均衡时, 每类样本总体风险尽可能相同, 从而实现最优的故障诊断效果.

式 (23) 给出了惩罚因子的更新法则, 根据式 (20) 关于惩罚因子的约束条件, 可得

$$\frac{(N_f - N_1) \sum_{i=1}^{N_1} \xi_i}{N_1 \sum_{i=N_1+1}^{N_f} \xi_i} = 1, \quad (27)$$

因此, 本文方法可以通过调节风险损失, 有效地抑制样本不均衡问题.

本文所设计的改进 SVM 是属于多分类 (类别大于 2) 范畴, 在考虑样本不均衡问题的基础上进行自动调整用于故障诊断的最优超平面, 实现更好的诊断性能. 值得注意的是: (1) 当自动调节过大时, 可通过对式 (23) 的变化率进行限定, 以避免由于调节过大而导致性能波动剧烈; (2) 最优超平面的自我调整率与诊断误差呈负相关, 故当故障诊断精度较低时, 算法具有较大的调整以期实现更好的学习能力; (3) 所设计方法可以根据诊断结果, 实现分类器泛化性能和学习性能之间的折中.

4 实验验证

本节首先在中车株洲所的实验平台上进行故障注入, 而后论证本文所提出的 FDD 方法.

4.1 故障注入及实现流程

高速列车牵引系统的故障注入采用硬件在环的方式, 其源于文献 [27] 的设计. 在如图 2 所示的 CRH2 型高速列车牵引系统平台上, 从 350 s 之后注入以下 4 种故障:

- (1) A 相电流传感器故障, 其幅值为 $f_1 = 10$ A.
- (2) 由 4% 转子断条和 20% 气隙偏心组成的复合故障 f_2 .
- (3) 中间电压的上桥臂电压传感器故障, 幅值为 $f_3 = 25$ V.
- (4) 速度传感器渐变故障 f_4 , 其幅值为 $f_4 = [5 + 0.5(t - 350)]$ rad/min.

由于上述 4 种故障发生的概率不同, 例如复合故障 f_2 发生的概率远远低于其他故障, 故离线情况下收集的故障数据集存在差异. 本文考虑 4 种故障样本量的比例为 5:1:3:5.

根据图 2 中的实验平台以及列车牵引系统实际安装传感器位置, 定义两桥臂电压与三相电流的测量值为系统输入矩阵 U , 电磁转矩与车速的测量值为系统输出数据 Y , 且设定时间间隔 $N = 5000, s = 5$. 其离线的 \mathcal{M} 辨识与故障检测阈值步骤如算法 1 所示.

对于离线的故障数据集, 需要通过故障检测得到的残差信号进行最优超平面的选择, 从而实现对多种故障的特征提取, 其离线步骤如算法 2 所示.

基于离线算法 1 所定义的统计量与算法 2 所得到的故障特征, 所设计的在线 FDD 过程如算法 3 所示.

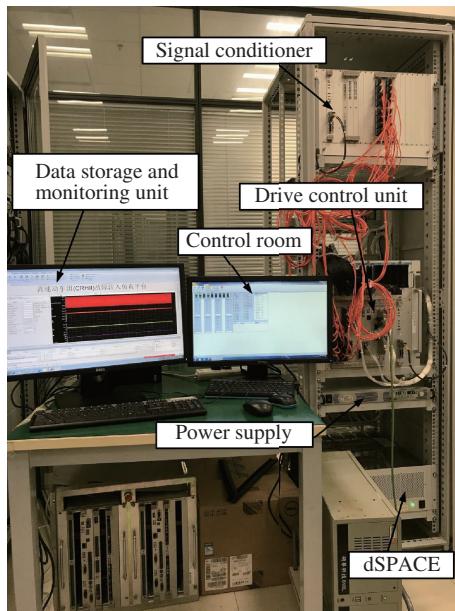


图 2 (网络版彩图) 高速列车牵引系统故障注入与诊断实验平台

Figure 2 (Color online) Platform of fault injection and diagnosis for traction systems of high-speed trains

算法 1 离线辨识算法

- 1: 根据给定的 N, s , 得到输入矩阵 U 与输出矩阵 Y ;
- 2: 通过式 (14), 得到 M 矩阵;
- 3: 依据式 (15), 定义数据驱动的残差信号 $r(k)$;
- 4: 通过式 (17) 定义统计量, 并根据式 (18) 得到用于故障检测的阈值.

算法 2 离线故障特征提取算法

- 1: 对于 T 种故障数据, 通过式 (15) 得到所有类型故障的残差信号;
- 2: 采用一对多法, 定义故障诊断的目标函数 (20);
- 3: 根据诊断误差, 更新权重向量 m ;
- 4: 通过式 (23) 得到新的惩罚因子;
- 5: 生成新的故障诊断超平面.

算法 3 在线 FDD 算法

- 1: 读取在线数据 u 和 y ;
- 2: 根据式 (15) 得到当前时刻残差;
- 3: 依据式 (17) 中的统计量, 进行故障检测. 当系统无故障时, 返回第 1 步; 否则继续执行算法;
- 4: 以报警的残差作为算法 2 得到分类器的输入, 输出故障类型, 并返回第 1 步.

4.2 故障检测实验结果

采用第 3.1 小节设计的动态数据驱动故障检测方法, 对所注入的 4 种故障检测结果如图 3 所示, 其中蓝色实线为 T^2 统计量, 红色虚线为故障检测阈值.

当 350 s 注入电流传感器故障 f_1 时, T^2 超出阈值可以实现零漏报的故障检测结果.

对于 350 s 注入的电机复合故障 f_2 , T^2 在阈值附近出现较多波动, 主要是由于此类故障对牵引系

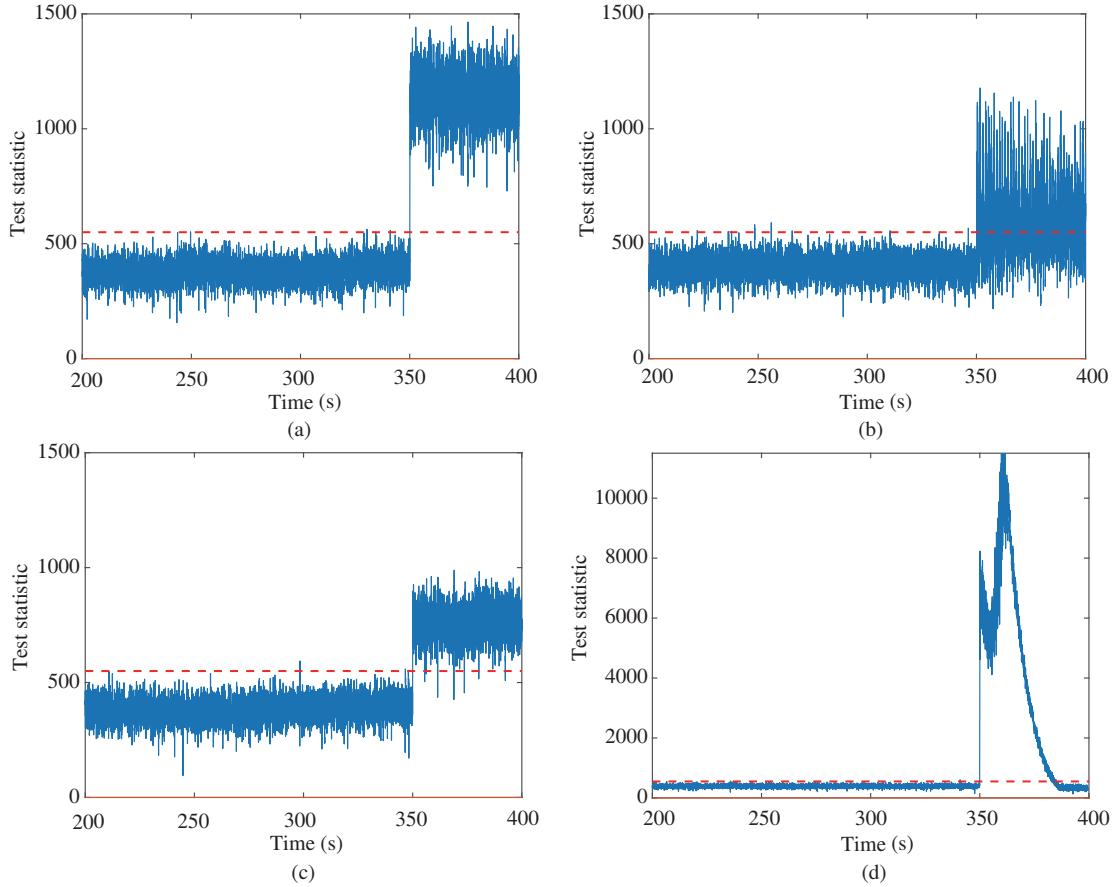


图 3 (网络版彩图) 对 4 种故障检测结果. (a) 故障 f_1 , 故障检测率为 100%, 故障误报率为 0.3%; (b) 故障 f_2 , 故障检测率为 59.69%, 故障误报率为 0.92%; (c) 故障 f_3 , 故障检测率为 99.46%, 故障误报率为 0.77%; (d) 故障 f_4 , 故障检测率为 71.5%, 故障误报率为 0.23%

Figure 3 (Color online) Detection results for 4 types of faults. (a) Fault f_1 : fault detection ratio is 100%, and false alarm ratio is 0.3%; (b) fault f_2 : fault detection ratio is 59.69%, and false alarm ratio is 0.92%; (c) fault f_3 : fault detection ratio is 99.46%, and false alarm ratio is 0.77%; (d) fault f_4 : fault detection ratio is 71.5%, and false alarm ratio is 0.23%

统整体性能影响较低造成的结果. 由于统计量具有一定上升趋势, 且大多数已超出阈值, 故也能完成对该类故障的检测任务.

当 350 s 注入电压传感器故障 f_3 时, T^2 瞬间超出阈值可以实现对此类故障的检测任务. 且从实验结果看, 具有很好的检测性能.

当速度传感器发生故障, 使得传感器值与真实值产生差异, 从而导致牵引系统的控制器进行较大程度的调节. 如图 3(d) 所示, 统计量出现较大波动. 对于此类故障, 所提出算法仍能实现较好的检测性能.

需要特别指出, 本文考虑了高速列车牵引系统的动态性能. 从图 3 的实验结果可以看出, 正常情况下故障检测的统计量与噪声有关, 与系统动态特性无关. 主要原因为, 本文所设计的方法可以通过输入输出数据不同时刻的相关性, 来抵消动态特性对残差信号以及统计量所带来的影响, 从而实现高速列车动态牵引系统的故障检测任务.

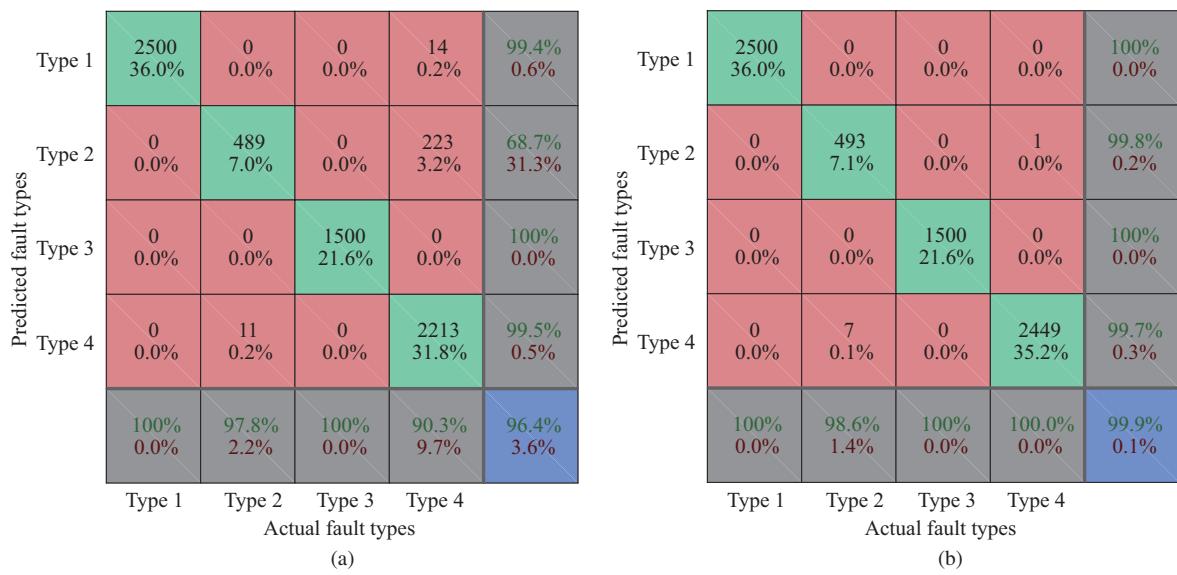


图 4 (网络版彩图) 传统 SVM (a) 和本文改进 SVM (b) 诊断结果

Figure 4 (Color online) Diagnosis results using (a) traditional SVM and (b) the proposed modified SVM

4.3 故障诊断实验结果

基于上述的故障检测结果, 将其残差信号作为故障诊断输入, 对注入的 4 种故障进行实时诊断。为了突显本文所设计诊断方法对故障样本不均衡问题的优势, 故与传统 SVM 进行了比较, 其实验结果(即混淆矩阵)如图 4 所示。在图 4 中, 混淆矩阵的绿色部分给出了故障样本被正确诊断的数量和所占数据比例, 可以反映出各类故障样本的不均衡问题; 红棕色部分呈现了故障误判的样本个数与比率; 灰色部分为该类样本故障诊断的正确率与误判率; 蓝色部分为所有类型故障的诊断正确率与误判率。

在离线情况下, 训练诊断分类器的不同故障样本量差异, 使得学习到的分类超平面出现偏移而影响诊断性能。如图 4(a) 所示, 采用传统的 SVM 方法对检测步骤中得到的残差信号进行诊断, 其总体误判率为 4%; 且从具体的结果可以看出, 最大样本量的 f_4 与最小样本量的 f_2 具有最差诊断性能。

根据图 4(a) 得到的诊断误差, 本文所设计的改进 SVM 自举地生成惩罚因子, 以期通过使得不同故障间的总体风险损失相同, 得到更为满意的诊断分类器。在初始惩罚因子均为 100 的情况下, 本文通过调整 3 次惩罚因子得到最新的超平面, 其对 4 类故障的诊断结果如图 4(b) 所示。对 4 类故障的总体诊断正确率为 99.9%, 相对于传统 SVM 具有更加满意的诊断精度。

5 结论

本文从数据驱动的角度, 研究了高速列车牵引系统最优故障诊断问题。首先提取牵引系统数据间的相关性, 定义数据驱动形式的残差用于监控动态牵引系统的运行状态; 由于牵引系统不同元器件发生故障的概率不同, 进一步提出了最优的故障诊断策略, 用于自适应调整支持向量机产生的超平面从而提高诊断精度; 最后, 所设计方法的有效性在中车株洲所的测试平台进行了验证。本文工作不但为数据驱动动态高速列车的故障诊断问题提出了有效的可选方案, 同时也为后续研究高速列车数据驱动的故障容错控制与寿命预测等挑战提供了有价值的参考。

参考文献

- 1 Givoni M. Development and impact of the modern high-speed train: a review. *Transp Rev*, 2006, 26: 593–611
- 2 Liu Q, Kong D, Qin S J, et al. Map-reduce decentralized PCA for big data monitoring and diagnosis of faults in high-speed train bearings. *IFAC-PapersOnLine*, 2018, 51: 144–149
- 3 Zhou D H, Ji H Q, He X. Fault diagnosis techniques for the information control system of high-speed trains. *Acta Automat Sin*, 2018, 44: 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: 1153–1164]
- 4 Yang C C, Yang C, Peng T, et al. A fault-injection strategy for traction drive control systems. *IEEE Trans Ind Electron*, 2017, 64: 5719–5727
- 5 Chen H T, Jiang B. A review of fault detection and diagnosis for the traction system in high-speed trains. *IEEE Trans Intell Transp Syst*, 2020, 21: 450–465
- 6 Chen H T, Jiang B, Chen W, et al. Data-driven detection and diagnosis of incipient faults in electrical drives of high-speed trains. *IEEE Trans Ind Electron*, 2019, 66: 4716–4725
- 7 Jiang B, Wu Y K, Lu N Y, et al. Review of fault diagnosis and prognosis techniques for high-speed railway traction system. *Control Decision*, 2018, 33: 841–855 [姜斌, 吴云凯, 陆宁云, 等. 高速列车牵引系统故障诊断与预测技术综述. 控制与决策, 2018, 33: 841–855]
- 8 Zhang S G. CRH₂-type Electric Multiple Units. Beijing: China Railway Publishing House, 2008. 146–150 [张曙光. CRH₂型动车组. 北京: 中国铁道出版社, 2008. 146–150]
- 9 Zhou D, Ji H Q, He X, et al. Fault detection and isolation of the brake cylinder system for electric multiple units. *IEEE Trans Contr Syst Technol*, 2018, 26: 1744–1757
- 10 Guzinski J, Abu-Rub H, Diguet M, et al. Speed and load torque observer application in high-speed train electric drive. *IEEE Trans Ind Electron*, 2010, 57: 565–574
- 11 Chen Z W, Ding S X, Peng T, et al. Fault detection for non-Gaussian processes using generalized canonical correlation analysis and randomized algorithms. *IEEE Trans Ind Electron*, 2018, 65: 1559–1567
- 12 Chen H T, Jiang B, Lu N Y, et al. Deep PCA based real-time incipient fault detection and diagnosis methodology for electrical drive in high-speed trains. *IEEE Trans Veh Technol*, 2018, 67: 4819–4830
- 13 Lv Y S, Chen Y Y, Li L, et al. Generative adversarial networks for parallel transportation systems. *IEEE Intell Transp Syst Mag*, 2018, 10: 4–10
- 14 Youssef A B, El Khil S K, Slama-Belkhodja I. State observer-based sensor fault detection and isolation, and fault tolerant control of a single-phase PWM rectifier for electric railway traction. *IEEE Trans Power Electron*, 2013, 28: 5842–5853
- 15 Dai C X, Liu Z G, Hu K T, et al. Fault diagnosis approach of traction transformers in high-speed railway combining kernel principal component analysis with random forest. *IET Elect Syst Transp*, 2016, 45: 202–206
- 16 Zhou D, Qiu H, Yang S, et al. Submodule voltage similarity-based open-circuit fault diagnosis for modular multilevel converters. *IEEE Trans Power Electron*, 2019, 34: 8008–8016
- 17 Bennett S M, Patton R J, Daley S. Sensor fault-tolerant control of a rail traction drive. *Control Eng Practice*, 1999, 7: 217–225
- 18 Gou B, Ge X L, Wang S L, et al. An open-switch fault diagnosis method for single-phase PWM rectifier using a model-based approach in high-speed railway electrical traction drive system. *IEEE Trans Power Electron*, 2016, 31: 3816–3826
- 19 Estima J O, Cardoso A J M. A new algorithm for real-time multiple open-circuit fault diagnosis in voltage-fed PWM motor drives by the reference current errors. *IEEE Trans Ind Electron*, 2013, 60: 3496–3505
- 20 Henao 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
- 21 Hu K T, Liu Z G, Lin S S. Wavelet entropy-based traction inverter open switch fault diagnosis in high-speed railways. *Entropy*, 2016, 18: 78
- 22 Jiang Y C, Yin S. Recursive total principle component regression based fault detection and its application to vehicular cyber-physical systems. *IEEE Trans Ind Inf*, 2018, 14: 1415–1423
- 23 Dong H R, Ning B, Cai B G, et al. Automatic train control system development and simulation for high-speed railways. *IEEE Circ Syst Mag*, 2010, 10: 6–18

- 24 Yang C, Gui W H, Chen Z W, et al. Voltage difference residual-based open-circuit fault diagnosis approach for three-level converters in electric traction systems. *IEEE Trans Power Electron*, 2020, 35: 3012–3028
- 25 Chen Y Y, Lv Y S, Wang F Y. Traffic flow imputation using parallel data and generative adversarial networks. *IEEE Trans Intell Transp Syst*, 2019. doi: 10.1109/TITS.2019.2910295
- 26 Feng J H, Xu J F, Liao W, et al. Review on the traction system sensor technology of a rail transit train. *Sensors*, 2017, 17: 1356
- 27 Yang X Y, Yang C H, Peng T, et al. Hardware-in-the-loop fault injection for traction control system. *IEEE J Emerg Sel Top Power Electron*, 2018, 6: 696–706
- 28 Ding S X, Yang Y, Zhang Y, et al. Data-driven realizations of kernel and image representations and their application to fault detection and control system design. *Automatica*, 2014, 50: 2615–2623
- 29 Qin S J. An overview of subspace identification. *Comput Chem Eng*, 2006, 30: 1502–1513
- 30 Chen Z W, Ding S X, Zhang K, et al. Canonical correlation analysis-based fault detection methods with application to alumina evaporation process. *Control Eng Practice*, 2016, 46: 51–58

Data-driven fault diagnosis for dynamic traction systems in high-speed trains

Bin JIANG^{1,2*}, Hongtian CHEN^{1,3}, Hui YI⁴ & Ningyun LU^{1,2}

1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

2. Jiangsu Key Laboratory of Internet of Things and Control Technologies, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;

3. Department of Chemical and Materials Engineering, University of Alberta, Edmonton T6G 1H9, Canada;

4. College of Electrical Engineering and Control Science, Nanjing Tech University, Nanjing 211816, China

* Corresponding author. E-mail: binjiang@nuaa.edu.cn

Abstract Traction systems are an important aspect of high-speed trains, and their reliable operation is crucial. With data available from trains, this paper proposes an optimal fault detection and diagnosis (FDD) strategy for dynamic traction systems. Based on the established dynamic model, using sensor measurements, a correlation-aided subspace identification technique is proposed to formulate residual signals and corresponding test statistics for fault detection. Then, a modified support vector machine (SVM) is designed for optimally solving the diagnosis bias caused by the difference in the apparent probabilities of multiple fault scenarios. The feasibility and effectiveness of the proposed optical FDD performance are illustrated in the CRRC experimental platforms.

Keywords high-speed trains, traction systems, data-driven, fault detection and diagnosis, FDD



Bin JIANG was born in 1966. He obtained his Ph.D. degree in automatic control from Northeastern University, Shenyang, China, in 1995. He has been a postdoctoral fellow, research fellow, and visiting professor in Singapore, France, USA, and Canada, respectively. Currently, he is a chair professor of Cheung Kong Scholar Program in the Ministry of Education and the vice president at Nanjing University of Aeronautics and Astronautics. His research interests include fault diagnosis and fault tolerant control, and their applications in aircraft, satellites, and high-speed trains.



Hui YI was born in 1984. He received the B.E. degree and the Ph.D. degree from the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics in 2005 and 2012, respectively. In 2012, he joined the College of Electrical Engineering and Control Science, Nanjing Tech University, as a lecturer, where he is currently an associate professor. His research interests include fault diagnosis, health monitoring, and artificial intelligence.



Hongtian CHEN was born in 1989. He received the B.S. and M.S. degrees from the School of Electrical and Automation Engineering at Nanjing Normal University, China, in 2012 and 2015, respectively; and the Ph.D. degree from the College of Automation Engineering at Nanjing University of Aeronautics and Astronautics, in 2019. Now, he is a postdoctoral fellow with the Department of Chemical and Materials Engineering, University of Alberta, Canada. His research interests include process monitoring and fault diagnosis, data mining and analytics, machine learning, and quantum computation, as well as their applications in high-speed trains, new energy systems, and industrial processes.



Ningyun LU was born in 1978. She received her Ph.D. degree from Northeastern University, Shenyang, China, in 2004. From 2002 to 2005, she worked as a research associate and postdoctoral fellow at Hong Kong University of Science and Technology. Currently, she is a full professor at the College of Automation Engineering at Nanjing University of Aeronautics and Astronautics, Nanjing, China. Her research interests include data-driven fault prognosis, data-driven diagnosis, health management techniques, and their applications to various industrial processes.