

基于数据驱动残差评价策略的故障检测方法

蒋栋年, 李 炜[†]

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 兰州理工大学
甘肃省工业过程先进控制重点实验室, 兰州 730050)

摘 要: 提出一种基于残差评价策略的故障检测方法, 在仅有系统残差数据的基础上, 不依赖于系统解析模型进行故障检测, 为基于数据驱动方法进行复杂系统的故障检测提供了新的理论依据. 为了提高系统故障检测的准确性, 在分析故障检测漏报率和误报率的基础上, 对故障检测阈值进行优化设计, 并通过对车辆电源系统可能发生的励磁系统故障进行故障检测, 验证了所提出方法的准确性和有效性.

关键词: 故障检测; 数据驱动; K-L 散度; 残差评价

中图分类号: TP277 **文献标志码:** A

Fault detection method based on data-driven residual evaluation strategy

JIANG Dong-nian, LI Wei[†]

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: This paper proposes a fault detection method based on the residual evaluation strategy. On the basis of the system residual error data only, do not rely on the system analytical model for fault detection, a new theoretical basis is provided for fault detection based on the data-driven method for the complex system. In order to improve the accuracy of the system fault detection, the fault detection threshold is optimally designed on the basis of fault miss alarm ratio and false alarm ratio. And by detecting the possible failure of the excitation system in the vehicle power system, the accuracy and effectiveness of the proposed method is verified.

Keywords: fault detection; data-driven; Kullback-Leibler divergence; residual evaluation

0 引 言

伴随着现代工程技术的迅速发展, 系统规模不断扩大, 集成化和复杂化程度日益增强. 此类系统一旦发生事故, 不仅会造成巨大的经济损失, 甚至会带来灾难性后果, 这对系统的安全性和可靠性提出了巨大挑战^[1]. 因此, 如何切实有效地提高现代系统的故障诊断准确率, 降低事故风险, 成为亟待解决的关键性问题.

残差是指由被观测数据构成的函数与这些函数的期望值之差, 是故障诊断的基础. 获取残差的方法有多种, 仅以是否依赖系统模型分类, 可分为基于系统数学模型和基于数据驱动的方法. 然而无论使用哪种方式获取残差, 都要求残差携带系统故障信息, 反应故障征兆. 通过系统残差进行故障检测的过程,

本质就是残差的评价过程. 文献[2-3]提出了基于模型故障诊断中残差生成的一般形式和利用残差进行故障诊断的基本思想, 并在此基础上研究了线性系统的故障诊断问题; 文献[4]针对移动机器人系统在线故障诊断难、状态估计计算量大的问题, 设计了一组基于非线性系统的平行粒子滤波器, 通过评价故障前后残差概率密度函数的对数似然函数, 实现了非线性复杂系统的故障诊断.

理论上讲, 当系统未发生故障时, 系统残差为零; 发生故障时, 残差数据则会偏离零值. 然而, 实际工程中, 由于噪声、扰动、未建模动态等内外不确定因素的影响, 即使在系统正常运行时, 残差通常也会偏离零值. 而且许多系统在正常运行时, 由于多种运行模式之间的切换, 会使得各种不确定因素的影响

收稿日期: 2016-06-04; 修回日期: 2016-08-27.

基金项目: 国家自然科学基金项目(61364011); 甘肃省青年自然科学基金项目(1506RJYA108); 甘肃省先进控制重点实验室开放基金项目(XJK201505).

作者简介: 蒋栋年(1984-), 男, 博士生, 从事故障诊断与容错控制的研究; 李炜(1963-), 女, 教授, 博士生导师, 从事工业过程先进控制和安全性等研究.

[†]通讯作者. E-mail: dreamjdn@126.com

放大化,以致于残差特性体现出一种非平稳特征.而对这类系统,传统基于统计的静态概率分布方法^[5-8]以及基于范数的固定阈值方法^[9-12]在运用中便会遭遇瓶颈.一种可行的方法是利用定量或定性的先验知识,借助于自适应阈值的设计,从而得到不固定阈值来应对系统中由时变的不确定性、扰动及运行模式切换带来对故障检测的困难^[13-14].文献^[15-16]以广义似然比检验为理论基础,通过对似然函数的优化实现了数据驱动的故障检测,然而其并未涉及自适应阈值的设计.

本文以 Kullback-Leibler (K-L) 散度方法为基础,借助数据驱动技术,通过对具有多模式运行系统的非平稳残差过程的分类评价进行故障检测.首先采用模式适配度方法确定无故障时系统残差概率密度函数的分类数,并以此为前提运用 K -均值方法对残差数据进行聚类;进而借助 K-L 散度方法,在线计算系统实时数据与离线数据残差概率密度函数的距离差异度,从而实现了对系统故障的有效诊断.

1 多模式运行系统的故障检测方法描述

系统的故障信息通常隐含于残差之中,通过观测并分析残差信息便可检测系统的运行状态.然而,不同系统的残差分布具有差异性,即使是同一系统,不同运行模式下,由于操作模式的转换,其输入量和输出量的异同表现也会使得残差的分布呈现一种非平稳特征,这对于传统通过残差评价进行故障诊断的方法无疑是挑战.

为了应对多模式运行系统残差数据的非平稳特性,基于数据驱动技术进行残差评价进而实现故障检测,比基于模型的故障检测方法更具优势.通过系统无故障时采集的历史离线残差数据进行模式聚类,并与在线数据进行相似度和差异度计算分析,从而实现了对多模式运行系统的故障检测.

考虑某一多模式运行的系统在无故障时采集的残差数据样本集合为 $D = \{r_1, r_2, \dots, r_{N_D}\}$, 其中 N_D 为样本数量.运行模式的切换使得 D 中的残差数据随时间变化时,统计特性也随之变化,且难以统一在一种概率分布之下.因此,为了对不同运行模式下的残差数据进行分类,首先将集合 D 分割为若干残差样本子集

$$R_k = \{r_{k-n}, r_{k-n+1}, \dots, r_k\}, \quad (1)$$

其中 n 为残差子集中的样本数,且 $n < N_D$.对于分割后所有的残差样本子集,有

$$T = \{R_1, R_2, \dots, R_{N_T}\}. \quad (2)$$

由此可得: $N_T = N_D/n$, R_k 可通过式(1)得到.假定 R_k 包含的残差样本源于同一种系统运行模式,实际中,只要使得 n 值的选取小于某一系统运行模式的运行时间,而大于任意两种运行模式的转换时间即可实现这一目标.因此,对于集合 T 中的任意残差集合 $R_k \subset T, k = 1, 2, \dots, N_T$, 在系统未发生故障时,其均属于某一特定的系统运行模式.而同一运行模式下,若将系统残差数据假定为一个平稳过程,则在该模式下 R_k 中的残差数据拥有相同的概率密度函数.

然而,根据以上分析,虽然 $R_k \subset T, k = 1, 2, \dots, N_T$ 属于某一种特定运行模式,并不代表系统拥有 N_T 种运行模式,因为存在不同残差集合属于同一种运行模式的可能性.换言之,若系统有 K 种运行模式,满足 $K < N_T$, 对残差集合 T 针对概率密度函数进行分类,集合 T 应该分为 K 类.也就是说,可通过一定的技术手段对集合 T 中的 $R_k (k = 1, 2, \dots, N_T)$ 进行优化聚类,其结果为真实的系统运行模式数 K .对 R_k 的优化聚类方法将在 2.4 节中介绍,这里假定系统已经进行了聚类,聚类后的系统运行模式数为 K .在不同的运行模式下,可将系统参数化表示为

$$\theta = \{\theta_1, \theta_2, \dots, \theta_K\}, \quad (3)$$

其中 $\theta_i (i = 1, 2, \dots, K)$ 为在第 i 种运行模式下系统的参数化表示.鉴于在同一运行模式下的残差数据有相同的概率密度函数,在无故障情况下,对每一种运行模式下的残差,应用核密度估计方法进行概率密度函数估计,可得

$$p(\theta^{\text{NF}}) = \{p(\theta_1^{\text{NF}}), p(\theta_2^{\text{NF}}), \dots, p(\theta_K^{\text{NF}})\}, \quad (4)$$

其中 $p(\theta_i^{\text{NF}}) (i = 1, 2, \dots, K)$ 为在第 i 种无故障运行模式下残差的概率密度函数估计.

为了对系统进行在线故障检测,需要采集实时运行的残差数据

$$R'_k = \{r_{k-m}, r_{k-m+1}, \dots, r_k\}, \quad (5)$$

其中 m 为实时运行的数据窗长度.

系统运行过程中,由于存在多种运行模式,确定当前系统运行状态所处模式又会面临困难.为了应对此问题又不失一般性,这里做出两个假设:

- 1) 假设系统当前的运行模式为未知;
- 2) 假设当前系统的运行模式属于某一具体模式的概率亦未知.

为了将 R'_k 与 R_k 进行比较,同时保证采集的数据来源于同一系统运行模式,进而确定系统是否发生故障,需满足

$$m \leq \min(n_{\theta_1}, n_{\theta_2}, \dots, n_{\theta_K}), \quad (6)$$

其中 n_{θ_k} 为进行残差聚类后属于某一系统运行模式的残差样本数量. 基于此,对在线采集的残差数据 R'_k 进行核密度估计,可得其概率密度函数为 $p(\theta_m)$.

可见,针对多模式系统,虽然其残差特性呈现非平稳特性,但可以通过对残差离线历史进行分类、聚类,并通过核密度估计分析其统计特性. 当系统处于在线运行时,在对在线数据统计分析的基础上分析与离线统计特性的差异度和相似度,从而实现对系统进行故障检测的目的.

2 基于数据驱动方法的故障检测

2.1 Kullback-Leibler (K-L) 散度

为了对运行的系统进行故障检测,一种有效的方法是通过将在线残差概率密度函数 $p(\theta_m)$ 与离线求得的残差概率密度函数 $p(\theta^{NF})$ 进行比较,从而实现基于残差数据驱动的故障检测. 若两种概率函数差异度超过阈值,则可判定系统发生故障,反之则认为系统处于正常运行状态.

借助于距离差异度(如 K-L 散度^[17]),可衡量系统正常与发生不同故障时多元分布的相似度和差异度,进而通过测量发生故障时的距离差异度实现对系统故障的检测. 为了应用 K-L 散度方法进行系统的故障检测,下面引出 K-L 散度的定义.

针对随机变量 x ,对于两种连续概率密度函数 $f(x)$ 和 $g(x)$,K-L 距离定义为

$$I(f||g) = \int f(x) \log \frac{f(x)}{g(x)} dx. \quad (7)$$

通过式(7)可以给出概率密度函数 $f(x)$ 和 $g(x)$ 的 K-L 散度定义为

$$\text{KLD}(f, g) = I(f||g) + I(g||f). \quad (8)$$

K-L 散度用来衡量两个过程概率分布的差别,物理意义其实是二者夹角的度量. 因此,它的值越大,表明两个过程之间的差别越大;反之,则差别越小. 当两类概率分布完全相同时,值为0. 具有如下特性:

$$\begin{cases} \text{KLD}(f, g) = 0, & f = g; \\ \text{KLD}(f, g) \geq 0, & \text{else.} \end{cases} \quad (9)$$

然而,若随机变量 x 服从正态分布特性,即假设 $f(x) \sim N(\mu_1, \sigma_1^2)$, $g(x) \sim N(\mu_2, \sigma_2^2)$,则由于正态分布外观的相似性,使得计算所得的 K-L 散度较小,难以对两种概率分布实现分类. 因此,本文引入一种针对正态分布的 K-L 散度计算方法^[18-19]:

$$\text{KLD}(f, g) = \frac{1}{2} \left[\frac{\sigma_2^2}{\sigma_1^2} + \frac{\sigma_1^2}{\sigma_2^2} + (\mu_1 - \mu_2)^2 \left(\frac{1}{\sigma_1^2} + \frac{1}{\sigma_2^2} \right) - 2 \right]. \quad (10)$$

式(10)中,通过引入正态分布中的均值和方差,可以有效地进行正态分布 K-L 散度的计算,并在针对小故障的检测中具有更小的漏报率和误报率.

2.2 基于 K-L 散度的故障检测

考虑使用 K-L 散度方法,通过下式计算正常运行与发生故障时残差分布的距离差异度,从而进行故障检测:

$$\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF})) > \delta_{th}. \quad (11)$$

其中: δ_{th} 为故障检测阈值; m 为在线运行的数据窗长度,并满足式(6); K 为无故障时的系统运行模式数; $p(\theta_m)$ 为在线残差数据的概率密度函数; $p(\theta_i^{NF})(i = 1, 2, \dots, K)$ 为在第 i 种无故障运行模式下,残差数据的概率密度函数.

当在线数据窗长度为 m 时,对所采集的残差数据运用核密度估计方法估计其概率密度函数 $p(\theta_m)$,并借助于 K-L 散度方法,计算其与无故障时 K 种残差概率密度函数的距离差异度,若所得的最小值较大,即超过阈值 δ_{th} ,则说明当前所采集残差数据的概率密度不符合系统正常运行时的任意一种运行模式,可视为故障信息;反之,若所得的最小值较小,即不超过阈值 δ_{th} ,则说明当前所采集残差数据的概率密度符合系统正常运行时的某一种运行模式,当前系统运行正常.

依据上述判定方式,虽可运用离线时所采集的系统正常运行数据来检测在线运行时系统是否发生故障,但在运用无故障时的残差数据进行 $p(\theta^{NF})$ 计算时,仍面临着残差数据为非平稳过程且系统的运行模式未知等困难.

为了确定无故障时系统的运行模式,需要解决两个关键问题:

- 1) 确定系统运行模式数 K ;
- 2) 在已知系统运行模式数 K 的情况下,对残差数据进行 K 总数的聚类.

下面通过设计一种自学习方法确定系统运行模式数 K ,并进一步通过引入 K -均值聚类实现残差数据分类.

2.3 基于自学习方法的 K 值确定

为了通过数据驱动的方法,使用残差数据集 T 对系统进行描述,这里定义一种描述数据模型匹配程度的度量指标模式适配度. 即使用残差数据 T 对系统的运行模式 θ 进行匹配评价的定量描述,并将其记为 $V(T, \theta)$.

当给定 $V(T, \theta)$ 时,通过残差数据的分布规律可以求解系统的运行模式数 K

$$K^* = \arg \max[V(T, \theta)]. \quad (12)$$

可见,求解式(12)的关键是求得对系统进行适当定量描述的模式适配度函数 $V(T, \theta)$. 接下来选用一种统计方法对其求取.

设离散随机变量 r 为残差的随机采样,其值域为 $X = \{x_1, x_2, \dots, x_M\}$,则针对具体给定的系统运行模式 $\theta_i (i = 1, 2, \dots, K), r = x_j$ 的概率分布为

$$p(r_j|\theta_i) = p(r = x_j|\theta_i) = \theta_{ij}. \quad (13)$$

其中: $j = 1, 2, \dots, M$; 由于当前系统运行模式的总数未知,设 $i > 0$,且满足

$$\begin{aligned} \sum_{j=1}^M \theta_{ij} &= 1, \theta_{ij} \geq 0, \\ i &= 1, 2, \dots, K, j = 1, 2, \dots, M. \end{aligned} \quad (14)$$

若考虑有 N 个残差的随机采样 r_1, r_2, \dots, r_N , 则其联合概率分布函数为 $p(r_1, r_2, \dots, r_N|\theta)$, 假设 r_1, r_2, \dots, r_N 满足独立同分布特性.

定义 c_j 为残差样本 r_1, r_2, \dots, r_N 中大小等于 x_j 的样本数量,即

$$c_j = \{r_k \in \{r_1, r_2, \dots, r_N\} | r_k = x_j, x_j \in X\}. \quad (15)$$

由式(15)可知 $\sum_{j=1}^M c_j = N$. 考虑到随机残差样本 r_1, r_2, \dots, r_N 的独立同分布特性,可得残差样本的似然函数为

$$L(\theta|r) = \prod_{i=1}^N p(r_i|\theta). \quad (16)$$

结合式(13)和(15),可将式(16)转化为

$$L(\theta|r) = \prod_{i=1}^N p(r_i|\theta) = \prod_{i=1}^N \theta_{ij}^{c_j}. \quad (17)$$

其中: $i = 1, 2, \dots, K, j = 1, 2, \dots, M$. 假定系统有 K 种运行模式,考虑对数似然函数

$$l(\theta|r) = \log[L(\theta|r)] = \sum_{j=1}^M c_j \log \left[\sum_{i=1}^K \theta_{ij} \right]. \quad (18)$$

在未对系统运行模式数进行优化时,其数目为 N_T ,优化以后的数目为 K ,可见 $K < N_T$,则在系统运行模式数未知时,有

$$l(\theta|r) = \log[L(\theta|r)] = \sum_{K=1}^{N_T} \sum_{j=1}^M c_j \log \left[\sum_{i=1}^K \theta_{ij} \right]. \quad (19)$$

计算最大对数似然函数

$$\begin{aligned} \hat{l}(\theta|r) &= \max_{i=1,2,\dots,K} l(\theta|r) = \\ &= \max_{i=1,2,\dots,K} \sum_{K=1}^{N_T} \sum_{j=1}^M c_j \log \left[\sum_{i=1}^K \theta_{ij} \right] = \end{aligned}$$

$$\begin{aligned} &= \sum_{K=1}^{N_T} \max_{i=1,2,\dots,K} \sum_{j=1}^M c_j \log \left[\sum_{i=1}^K \theta_{ij} \right] = \\ &= \sum_{K=1}^{N_T} \max_{i=1,2,\dots,K} \sum_{j=1}^M c_j \log \theta_{ij}. \end{aligned} \quad (20)$$

根据最大似然函数的量化表述,可将 $\hat{l}(\theta|r)$ 定义为系统的模式适配度^[16]

$$\begin{aligned} V(T, \theta) &= \hat{l}(\theta|r) = \\ &= \sum_{K=1}^{N_T} \max_{i=1,2,\dots,K} \sum_{j=1}^M c_j \log \left[\sum_{i=1}^K \theta_{ij} \right]. \end{aligned} \quad (21)$$

在知道模式适配度 $V(T, \theta)$ 的情况下,依据式(12)可求得 K 值,即确定了系统的运行模式数.

2.4 残差的聚类

在确定了系统运行模式数 K 后,即已知残差类别数目的情况下,运用残差聚类方法进行残差数据分类.

对于残差集合 $R_k, R_k \subset T, k = 1, 2, \dots, N_T$, 由于其均来源于同一系统的运行模式,概率密度函数集合可描述为

$$\psi = \{p_{\theta_1}, p_{\theta_2}, \dots, p_{\theta_{N_T}}\}. \quad (22)$$

由第2.3节可知,残差样本集合通过模式适配度学习,最终确定有 K 种运行模式,也就是说,残差集合 $T = \{R_1, R_2, \dots, R_{N_T}\}$ 若通过聚类,则其聚类数目为 K ,设聚类后样本集合为 P_1, P_2, \dots, P_K .

已知残差样本集合和聚类数目 K 的情况下, K -均值聚类是一种针对残差数据分类行之有效的方法. 采用如下的 K -均值聚类算法进行残差概率密度聚类.

算法1 残差概率密度聚类算法.

输入:数据集 $\psi = \{p_{\theta_1}, p_{\theta_2}, \dots, p_{\theta_{N_T}}\}$, 聚类数目为 K ;

输出: K 个类簇 $C_j, j = 1, 2, \dots, K$.

Step 1: 令 $i = 1$, 对集合 ψ 中的残差概率密度函数值,等间隔选取 K 个数据点作为 K 个类簇的初始簇中心 $p_{\theta_j^*} (j = 1, 2, \dots, K)$.

Step 2: 计算每个数据点与这 K 个簇中心的距离 $\text{KLD}(p_{\theta_k}, p_{\theta_j^*})$, 如果满足

$$D^*(i) = \min_P \sum_{i=1}^K \sum_{\theta_k \in P_i} \text{KLD}(p_{\theta_k}, p_{\theta_j^*}), \quad (23)$$

则 $p_{\theta_k} \in C_j$.

Step 3: 计算 k 个新的聚类中心

$$p_{\theta_j^*} = \frac{1}{|P_j|} \sum_{p_{\theta_k} \in P_j} p_{\theta_k}, j = 1, 2, \dots, K. \quad (24)$$

Step 4: 判断. 若 $|D^*(i+1) - D^*(i)| < \varepsilon$, ε 为预先选定的充分小量, 则停止; 否则, $i = i+1$, 返回 Step 2.

通过模式适配度优化系统的运行模式数 K , 在已知系统残差概率密度聚类数 K 的基础上, 借助于 K -均值聚类方法, 可求得系统的运行模式数和每种运行模式下残差的概率密度函数, 从而运用式(11)即可在不依赖于系统模型的情况下, 对系统可能发生的故障进行检测.

3 基于故障误报率和漏报率的阈值优化

残差的计算是能否准确地实现故障检测的基础, 故障诊断误报率和漏报率是评价诊断方法的基本指标, 而适当阈值的选取则是能否实现故障可靠诊断的保障. 因此, 本文通过引入一种基于故障误报率和漏报率的阈值优化方法, 实现故障检测阈值的优化选取.

3.1 误报率与漏报率计算

由于动态系统不可避免的存在内外部不确定性因素, 使得残差势必会在一定范围内产生波动, 进而导致故障诊断过程中的误报和漏报. 如何通过优化阈值并改善之, 有必要从误报率和漏报率的计算分析入手.

选取假设检验, 原假设 H_0 为系统无故障, 备择假设 H_1 为系统发生故障, 则动态系统故障误报率和漏报率可由下式表示^[20]:

$$P_{FA} = P\left(\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF})) > J | H_0\right), \quad (25)$$

$$P_{MA} = P\left(\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF})) \leq J | H_1\right). \quad (26)$$

为了求得故障误报和漏报的概率, 在 2.2 节故障检测方法下, 需要知道 K-L 散度 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 的概率密度函数. 为便于计算, 假设 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 服从正态分布, 对 K-L 散度的一组数据进行 Lilliefors 假设检验, 可得显著性水平为 0.06, 说明 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 确实服从正态分布.

用 KLm 表示 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 的正态分布均值, 蒙特卡洛估计误差 σ_{MC}^2 作为正态分布的方差, 即 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF})) \sim N(\text{KLm}, \sigma_{MC}^2)$. 可得 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 的概率密度函数为

$$f_j(x) = \frac{1}{\sigma_{MC}\sqrt{2\pi}} e^{-\frac{(x-\text{KLm})^2}{2\sigma_{MC}^2}}, \quad j = 0, 1. \quad (27)$$

若系统无故障即假设 H_0 为真, 则概率密度函数

为 f_0 , 均值 $\text{KLm} = \text{KLm}_0$, 方差 $\sigma_{MC} = \sigma_{MC0}$; 当系统发生故障即假设 H_1 为真时, 概率密度函数为 f_1 , 均值 $\text{KLm} = \text{KLm}_1$, 方差 $\sigma_{MC} = \sigma_{MC1}$.

根据式(27), 故障误报率和故障漏报率可通过下式得到:

$$P_{FA} = 1 - \int_{-\infty}^h f_0(x) dx, \quad (28)$$

$$P_{MA} = \int_{-\infty}^h f_1(x) dx. \quad (29)$$

为了求取概率密度函数 $f(x)$ 的分布函数, 使用如下的误差函数:

$$\text{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt. \quad (30)$$

由此可近似求得概率密度函数 $f(x)$ 的分布函数为

$$F(x) = \frac{1}{2} + \frac{1}{2} \text{erf}\left(\frac{x - \text{KLm}}{\sigma_{MC}\sqrt{2}}\right). \quad (31)$$

根据文献[17], 故障误报率和漏报率的计算公式如下:

$$P_{FA} = 1 - 0.5 \times \left(1 + \text{erf}\left(\frac{h - \text{KLm}_0}{\sigma_{MC0}\sqrt{2}}\right)\right), \quad (32)$$

$$P_{MA} = 0.5 \times \left(1 + \text{erf}\left(\frac{h - \text{KLm}_1}{\sigma_{MC1}\sqrt{2}}\right)\right). \quad (33)$$

3.2 阈值的优化选取

由式(32)和(33)可知, 故障误报率和漏报率的求取与 K-L 散度的阈值 δ_{th} 选取密切相关. 阈值 δ_{th} 增大, 故障误报率减小, 但故障漏报率增大; 而阈值 δ_{th} 减小, 则故障误报率增大, 故障漏报率减小. 因此, 设计合适的阈值 δ_{th} 很有必要.

根据 $\min_{i=1,2,\dots,K} \text{KLD}(p(\theta_m), p(\theta_i^{NF}))$ 的波动规律, 充分考虑正态分布中均值和方差的运用, 阈值 δ_{th} 可以通过式 $\delta_{th} = \text{KLm}_0 + \alpha \times \sigma_{MC0}$ 进行确定, 其中 α 为阈值因子. 对阈值因子 α 的选取直接影响阈值的大小, 进而影响故障诊断过程中的漏报率和误报率. 因此, 参照文献[20]中阈值因子的优化算法, 定义函数 $\text{COST} = P_{FA} + P_{MA}$, 并运用梯度下降算法对 α 进行优化选取. 其优化算法如下.

算法2 梯度下降优化算法.

```

设定初始值  $\alpha = \alpha_0$ 
while  $\Delta\alpha < \text{Tol}$  and  $n_{\text{iter}} < n_{\text{max}}$  do
1)  $\Delta\alpha := -\nabla\text{COST}(\alpha)$  (梯度);
2) 选取步长:  $\varphi$ ;
3) 更新:  $\alpha_{k+1} = \alpha_k + \varphi\Delta\alpha$ ;
end while
    
```

其中: n_{iter} 为优化算法中迭代的当前步数, n_{max} 为算法未收敛情况下的最大运行步数, Tol 为能够接受的最大梯度变化值, 符号 ∇ 为梯度下降函数.

4 仿真分析

4.1 仿真对象描述

这里以120kW的某军用车电源为仿真对象,其核心组成是柴油发电机组,结构如图1所示.在野外作战条件下,车辆电源不仅是现代武器装备主要的能量来源,也为连队日常用电提供了安全可靠的生活保障.主要包括:汽车底盘、降噪箱体、120kW柴油发电机组及其控制系统等.柴油机为康明斯NT855-

GA、电子调速器为美国Cummins、同步发电机为斯坦福UCI274F、电压调节器为MX321的励磁控制系统.各模块之间的关系如图2所示.图2中:向量 U 为发电机 d 轴和 q 轴电压, I 为发电机 d 轴和 q 轴电流, U_f 为励磁电压, P_m 为发电机机械功率, n 为发电机转速,发电机的额定输出电压为400V.由于系统所带负载的差异性,使得励磁电压产生差异,从而导致系统输出电压出现偏差.电压允许偏差在额定电压的-10%~+7%内.

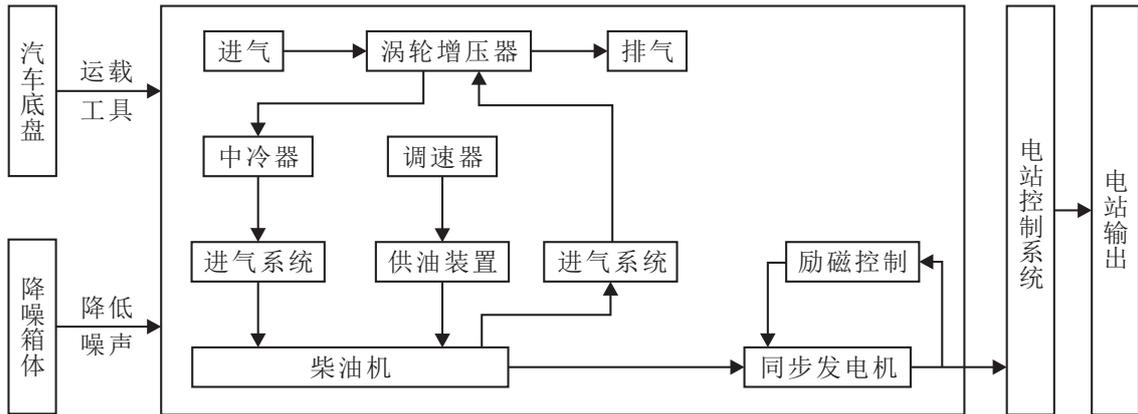


图1 车辆电源系统结构

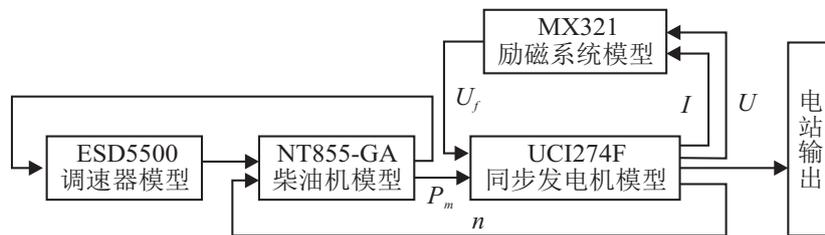


图2 车辆电源模块关系

图3所示为发电机在正常运行时,由于系统带载不同导致系统处在不同运行模式下时的输出电压残差曲线,所带负载分别为线性负载、线性与非线性混合负载以及非线性负载.

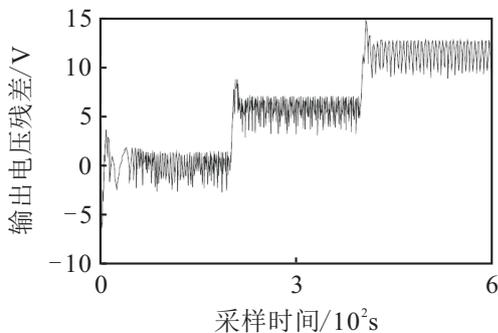


图3 输出电压残差数据曲线

4.2 残差特性分析

虽然利用系统正常运行时的历史离线数据可以获得残差特性曲线,但系统的运行模式数尚为未知,

采用2.3节给出的方法,通过求取系统模式适配度来确定系统运行模式数 K ,其求取过程曲线如图4所示.

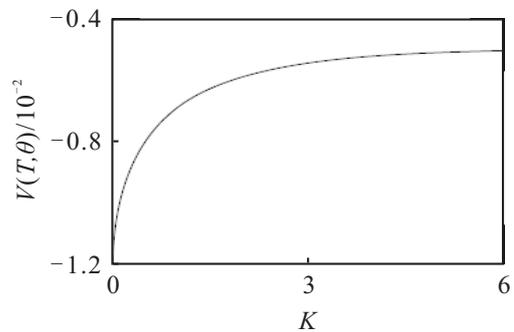


图4 根据模式适配度训练K值

从图4可以看出,在 $K = 3$ 时, $V(T, \theta)$ 趋于最大值且变化趋于平缓,因此确定 $K = 3$,即系统的运行模式数为3.从车辆电源系统的输出电压残差曲线图3也可看出,残差曲线明显具有3段特征,说明文中所述确定系统运行模式数的方法是可行的.

对于如图3所示具有非平稳过程的残差数据,在已确定残差聚类数目 $K = 3$ 的情况下,运用第2.4节所述的 K -均值聚类算法对残差数据进行聚类,聚类结果如图5所示。

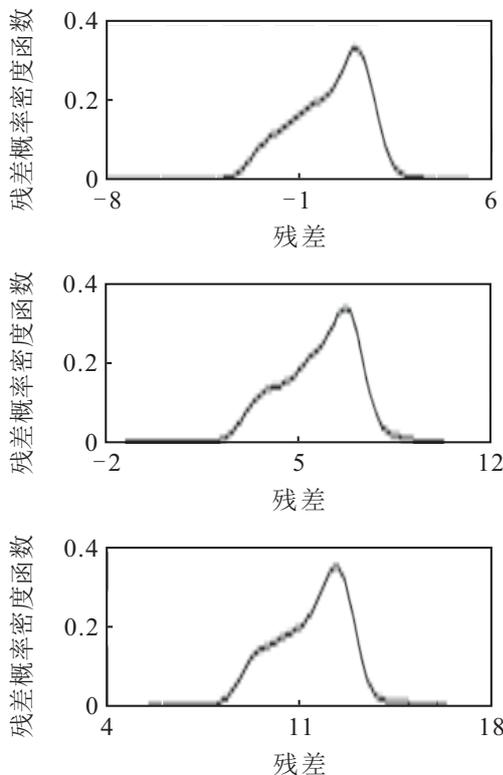


图5 残差概率密度曲线

图5为对3类残差数据进行聚类后的3段概率密度曲线。可以看出,图5中的3类概率密度曲线除所处横轴的位置外,外观上具有很大的相似性,以致在对其两两直接计算K-L散度时,所得K-L散度值偏小而难以实现分类。但是,若借助于高斯分布的K-L散度计算方法式(10),则由于3种概率密度均值和方差明显的差异性,可以显著改善分类效果。

4.3 故障检测

经过对车辆电源系统运行的历史数据进行分析,系统运行中一种常见的故障是,由于励磁模块在户外高温环境下长时间运行所致的微机芯片、电子元器件的分歧水平老化,进而导致励磁电压异常,主要表现在系统输出电压的稳态值超出额定电压范围。为了便于分析,本文假设励磁电压发生乘性故障 $\delta \in [1.1 \ 1.5]$,即 $U_f = \delta \cdot U_f$ 时,故障发生在采样时刻200,在线采集输出电压残差数据如图6所示。

取最大运行步数 $n_{max} = 100$,步长 $\varphi = 0.1$, $Tol = 0.1$,运用3.2节所述的优化算法,优化选取当前故障模式下的阈值因子为 $\alpha = 2.5$,即可得到故障诊断阈值为2.8。选取在线数据的数据窗长度为20,进而运用式(11)对车辆电源励磁系统进行故障检测,故

障检测曲线如图7所示。

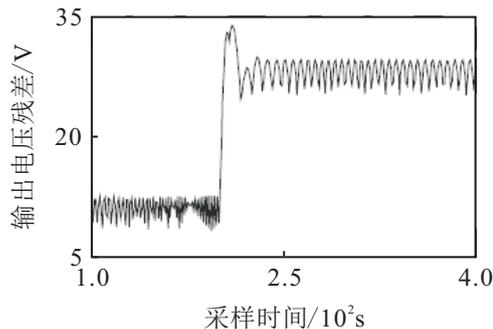


图6 在线残差数据曲线

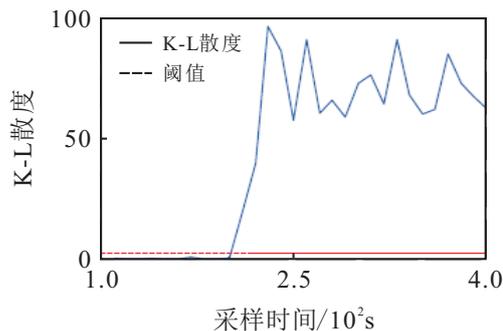


图7 励磁系统故障检测

由图7可知,当电源车辆处于在线运行状态时,通过在线采集输出电压的残差数据,并与离线残差数据进行比对,借助于文中提出的故障检测方法可以有效地实现对励磁系统故障的检测。

5 结论

残差作为故障诊断的基础,通过对其进行评价可以在不依赖系统模型的基础上对复杂系统进行故障的检测和隔离。然而,由于系统在运行过程中存在不同的运行模式,及系统可能受到扰动、噪声等内外不确定因素的影响,使得残差的统计特性为一种非平稳过程,为通过残差评价进行有效的故障诊断带来了挑战。因此,本文针对具有非平稳特征的残差数据提出了一种基于数据驱动残差评价的故障检测方法。首先通过对残差数据分类,保证分类后每一片段中的残差数据为平稳过程;其次对分类后的残差数据进行聚类,优化出系统的运行模式数;最后通过计算在线残差数据和离线残差数据概率密度函数的K-L散度,达到对系统故障进行在线故障检测的目的,并采用军用车辆电源系统验证了所提出方法的有效性。

参考文献(References)

[1] 周东华,刘洋,何潇. 闭环系统故障诊断技术综述[J]. 自动化学报, 2013, 39(11): 1933-1943.
(Zhou D H, Liu Y, He X. Review on fault diagnosis techniques for closed-loop systems[J]. Acta Automatica Sinica. 2013, 39(11): 1933-1943.)
[2] Patton R J, Uppal F J, Simani S, et al. Robust FDI

- applied to thruster faults of a satellite system[J]. *Control Engineering Practice*, 2010, 18(9): 1093-1109.
- [3] Patton R J, Frank P M, Clark R N. Issues of fault diagnosis for dynamic systems[M]. Berlin: Springer-Verlag, 2000.
- [4] Michal Z. Online fault detection of a mobile robot with a parallelized particle filter[J]. *Neurocomputing*, 2014, 126(3): 151-165.
- [5] Svard C, Nyberg M, Frisk E. Realizability constrained selection of residual generators for fault diagnosis with an automotive engine application[J]. *IEEE Trans on Systems, Man, and Cybernetics: Systems*, 2013, 43(6): 1354-1369.
- [6] Heyns T, Godsill S J, Villiers J P de, et al. Statistical gear health analysis which is robust to fluctuating loads and operating speeds[J]. *Mechanical System and Signal Process*, 2012, 27(1): 651-666.
- [7] Michele C, Piero B, Pietro T, et al. Interacting multiple-models, state augmented particle filtering for fault diagnostics[J]. *Probabilistic Engineering Mechanics*, 2015, 40: 12-24.
- [8] 蒋栋年, 李炜. 基于自适应阈值的粒子滤波非线性系统故障诊断方法研究[J]. *北京航空航天大学学报*, 2016, 42(10): 2099-2106.
(Jiang D N, Li W. Research on fault diagnosis of particle filter nonlinear systems based on adaptive threshold method[J]. *J of Beijing University of Aeronautics and Astronautics*, 2016, 42(10): 2099-2106.)
- [9] Chakraborty S, Keller E, Ray A, et al. Detection and estimation of demagnetization faults in permanent magnet synchronous motors[J]. *Electric Power Systems Research*, 2013, 96: 225-236.
- [10] Li W, Zhu Z, Ding S X. Fault detection design of networked control systems[J]. *IET Control Theory Applications*, 2011, 5(12): 1439-1449.
- [11] Al-Salami I M, Chabir K, Sauter D, et al. Adaptive thresholding for fault detection in networked control systems[C]. *Proc of the IEEE Int Conf on Control Applications*. Yokohama: IEEE, 2010: 446-451.
- [12] Zhong H, Ye H, Ding H X, et al. Observer-based fast rate fault detection for a class of multirate sampled-data systems[J]. *IEEE Trans on Automatic Control*, 2007, 52(3): 520-525.
- [13] Braun S, Feldman M. Decomposition of non-stationary signals into varying time scales: Some aspects of the EMD and HVD methods[J]. *Mechanical Systems and Signal Processing*, 2011, 25(7): 2608-2630.
- [14] Poulimenos A G, Fassois S D. Parametric time-domain methods for non-stationary random vibration modelling and analysis-a critical survey and comparison[J]. *Mechanical Systems and Signal Processing*, 2006, 20(4): 763-816.
- [15] Svärd C. Methods for automated design of fault detection and isolation systems with automotive applications[J]. *Teknik Och Teknologier*, 2012, 4(2): 978-985.
- [16] Carl Svärd, Mattias Nyberg, Erik Frisk, et al. Data-driven and adaptive statistical residual evaluation for fault detection with an automotive application[J]. *Mechanical Systems and Signal Processing*, 2014, 45(1): 170-192.
- [17] Abdulrahman Y, Claude D, Demba D. An optimal fault detection threshold for early detection using Kullback-Leibler Divergence for unknown distribution data[J]. *Signal Processing*, 2016, 120: 226-279.
- [18] Jinane H, Claude D, Demba D. Incipient fault detection and diagnosis based on Kullback-Leibler divergence using principal component analysis: Part I[J]. *Signal Processing*, 2014, 94: 278-287.
- [19] Jinane H, Claude D, Demba D. Incipient fault detection and diagnosis based on Kullback-Leibler divergence using principal component analysis: Part II[J]. *Signal Processing*, 2015, 10: 334-344.
- [20] Bartys M, Patton R, Syfert M, et al. Introduction to the Damadics actuator FDI benchmark study[J]. *Control Engineering Practice*, 2006, 14(6): 577-596.

(责任编辑: 齐 霁)