

控制与决策

Control and Decision

基于MMD的故障可诊断性定量评价方法

秦玉峰, 史贤俊

引用本文:

秦玉峰, 史贤俊. 基于MMD的故障可诊断性定量评价方法[J]. *控制与决策*, 2023, 38(10): 2925–2933.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.2201>

您可能感兴趣的其他文章

Articles you may be interested in

[基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation–entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

[基于Fisher Score与最大信息系数的齿轮箱故障特征选择方法](#)

Fault feature selection method of gearbox based on Fisher Score and maximum information coefficient

控制与决策. 2021, 36(9): 2234–2240 <https://doi.org/10.13195/j.kzyjc.2019.1770>

[高超声速飞行器间歇故障改进自适应容错控制](#)

Improved adaptive fault–tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

[基于不变网络模型和故障注入的分布式信息系统故障溯源方法](#)

Fault source location algorithm for distributed information system based on invariant network and fault injection

控制与决策. 2020, 35(11): 2723–2732 <https://doi.org/10.13195/j.kzyjc.2019.0214>

基于MMD的故障可诊断性定量评价方法

秦玉峰[†], 史贤俊

(海军航空大学 岸防兵学院, 山东 烟台 264001)

摘要: 提出一种基于最大均值差异 (maximum mean discrepancy, MMD) 的故障可诊断性定量评价方法. 该方法无需构建任何系统模型, 通过度量不同故障模式下测量数据之间的距离定量评价故障可诊断性, 适用于结构复杂、不易于建模且能够获取测量数据的复杂系统. 首先, 将测量数据通过特征核映射到可再生核希尔伯特空间 (reproducing kernel Hilbert space, RKHS) 中, 以 MMD 作为多元分布距离度量指标, 将故障可诊断性定量评价问题转换为多元分布在 RKHS 中的距离度量问题; 然后, 利用数学推导分析测量噪声强度对故障可诊断性评价结果的影响; 最后, 通过仿真实例验证所提出方法的有效性.

关键词: 故障可诊断性; 定量评价; 最大均值差异; 可再生核希尔伯特空间; 多元分布

中图分类号: TP277 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.2201

引用格式: 秦玉峰, 史贤俊. 基于MMD的故障可诊断性定量评价方法[J]. 控制与决策, 2023, 38(10): 2925-2933.

Quantitative evaluation approach of fault diagnosability based on maximum mean discrepancy

QIN Yu-feng[†], SHI Xian-jun

(College of Coastal Defense Force, Naval Aviation University, Yantai 264001, China)

Abstract: This paper proposes a method of quantitative evaluation of fault diagnosability based on maximum mean discrepancy (MMD). The method evaluates the fault diagnosability quantitatively by measuring the distance between measurement data under different fault conditions without building any system model. It is suitable for the system with complex structures that are difficult to build models and obtain measurement data. Firstly, the measurement data is mapped to the reproducing kernel Hilbert space (RKHS) through the characteristic kernel. The MMD is taken as the distance measure of multivariate distributions, and the fault diagnosability quantitative evaluation is transformed into the distance measurement of multivariate distributions in the RKHS. Then, the influence of measurement noise intensity on the result of fault diagnosability evaluation is analyzed by mathematical derivation. Finally, the validity of the proposed method is verified by simulation analysis.

Keywords: fault diagnosability; quantitative evaluation; maximum mean discrepancy; reproducing kernel Hilbert space; multivariate distribution

0 引言

随着系统结构功能日益复杂, 对系统运行质量和安全性的要求越来越高. 近年来, 国内外学者针对故障诊断技术开展了深入研究^[1-3], 故障可诊断性作为故障诊断的基础逐渐受到重视. 故障可诊断性主要包括故障可检测性和故障可隔离性^[4]. 作为系统的一种重要设计特性, 故障可诊断性从根本上反映了系统诊断故障的能力^[5], 因此对系统故障可诊断性进行研究具有重要的实际意义.

故障可诊断性研究主要包括可诊断性评价和可

诊断性设计两部分, 前者是可诊断性设计的基础和前提^[6]. 可诊断性评价是指度量系统检测和隔离故障能力的过程, 可以得到系统在当前资源配置下诊断故障的难易程度. 对于可诊断性较低或不可诊断的故障, 仅通过改进故障诊断算法并不能有效提高故障诊断效果, 这时便需要对系统中的测试点进行优化配置, 以获取更多的故障信息, 或提高所获取故障信息的质量. 由此可见, 可诊断性评价可以指导故障诊断算法的开发以及测试点的优化配置, 将提高故障诊断能力的工作融入到系统设计阶段. 可诊断性评价结

收稿日期: 2021-12-20; 录用日期: 2022-05-17.

[†]通讯作者. E-mail: Hy_qyf082@163.com.

*本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

果可以是定性的,也可以是定量的:定性评价确定故障是否能够被检测或隔离,定量评价衡量检测或隔离故障的难度^[7].可诊断性定性评价主要通过建立系统的多信号流图^[8]、有向图^[9-10]等定性模型,通过分析故障与测试信息的相关关系,从而得到故障可诊断性判据.定性模型从宏观的角度描述系统,能够体现故障相关关系和传播关系,但是定性评价只能评价故障是否能够被检测或隔离,无法给出故障检测或隔离的难度,因此应用范围受限.可诊断性定量评价目前主要包括两种方法.一种是基于主元分析的评价方法.Dunia等^[11]将测量空间划分为模型子空间和故障子空间,两个子空间之间的差异越大则故障的可检测性越高;Yue等^[12]通过分析故障检测指标SPE与 T^2 是否能够超出相应的控制限来确定故障的可检测性;Mnassri等^[13-14]在主元分析框架中对故障可检测性概念进行扩展和推广,提出了适用于任何具有二次型形式的故障检测指标的可检测性判据.另一种是基于多元分布相似度的评价方法,这也是目前最广泛使用的可诊断性定量评价方法.Eriksson等^[15-16]基于线性时间窗口模型提出了一种基于K-L散度的可诊断性评价方法,该方法以K-L散度作为多元分布差异的度量指标,通过度量多元分布的差异程度对可诊断性进行量化评价;Fu等^[17-20]针对系统及故障的多种不同描述形式,对基于K-L散度的可诊断性评价方法进行了应用推广;蒋栋年等^[21-22]通过稀疏核密度估计得到残差数据的概率密度函数,然后通过计算两种故障下残差概率密度函数的K-L散度量故障的可诊断性;Zhao等^[23]基于K-L散度对二维系统的故障可诊断性评价方法进行了研究;与K-L散度类似,文献^[6,24]利用巴氏系数衡量多元分布差异性,而后进行可诊断性定量评价.然而,目前对于可诊断性定量评价方法的研究存在以下不足:

1) 大多数研究都是基于解析模型进行可诊断性定量评价,但是解析模型无法反映出系统中的全部细节.另外,考虑到系统运行过程中的各种不确定性,想要建立精确的解析模型非常困难.

2) 上述文献中度量多元分布差异的方法,如K-L散度或巴氏系数等,实际上并不是度量距离,其不满足距离定义中的对称性,因此评价结果中故障 f_i 与 f_j 的可隔离性和故障 f_j 与 f_i 的可隔离性并不相同,含义不明确.

3) 当两个多元分布没有重叠时,若利用上述方法度量两个多元分布的差异,则巴氏系数为0,K-L散度的结果是没有意义的.

作为一种核学习方法,MMD被最先提出用于解决双样本的检测问题,判断两个分布是否相同.目前,MMD已广泛用于机器学习和统计学领域,如:Long等^[25]将MMD纳入DNN,构造了一个适应性正则化的子空间迁移学习框架;Jia等^[26]提出了一种新的基于MMD的异常检测器,用于评估所研究的数据或所提取的特征集是否适用于故障预测和健康管理任务;Li等^[27]为解决利用无标签数据进行滚动轴承故障诊断的问题,提出了一种基于MMD的深度迁移学习方法.在衡量分布之间的差异时,MMD相比K-L散度和巴氏系数的优点在于:MMD是一种度量距离,满足正定性、对称性和三角不等式;另外,即使两个分布没有重叠或者重叠非常少,MMD仍然能够反映出分布之间的差异.

综上所述,为了弥补现有方法的不足,本文提出一种基于MMD的故障可诊断性定量评价新方法.该方法通过度量不同故障模式下测量数据之间的距离对可诊断性进行定量评价.主要贡献包括:

1) 不需要建立系统模型即可对系统中的故障可诊断性进行评价,适用于结构复杂不易于建模、能够获取测量数据的复杂系统;

2) 评价结果满足距离定义中的对称性,实际意义更加清晰;

3) 不要求多元分布必须存在重叠部分,适用范围更广且结果更加准确.

1 基于MMD的可诊断性定量评价

1.1 问题描述

描述一个随机变量最直接的方法是给出其概率密度函数,但是对于一些复杂高维随机变量,直接给出其分布函数非常困难,此时可以用随机变量的矩对其进行描述,例如均值(一阶中心矩)、方差(二阶中心矩)等.但是,仅根据均值和方差相同并不能说明两个随机变量服从同一分布,需要利用更高阶的矩对随机变量进行描述.MMD的基本思想是计算随机变量的任意阶矩,若两个随机变量的任意阶矩均相同,则这两个随机变量所服从的分布是一致的,此时两个分布之间的距离为0;若两个分布不相同,则用相差最大的矩度量两个分布之间的距离.

考虑到系统在不同故障模式下获取到的测量数据可能不同,可根据测量数据之间的距离大小判断故障可诊断性的强弱:若发生故障 f_i 时的测量数据与正常情况下的测量数据之间距离较大,则故障 f_i 的可检测性较强;若发生故障 f_i 时的测量数据与发生故障 f_j 时的测量数据之间距离较大,则故障 f_i 与 f_j 的

可隔离性较强.

基于以上分析, 可以基于 MMD 的相关理论, 将故障可诊断性定量评价问题转换为不同故障模式下测量数据分布的距离度量问题, 下面介绍具体实现方法.

1.2 具体方法

假设系统中共有 d 个测试, 组成集合 $\Phi = \{t_1, t_2, \dots, t_d\}$, 实际进行故障诊断时共有 $2^d - 1$ 种可能选用的测试组合, 记所有测试组合构成集合 $\hat{T} = \{T_1, T_2, \dots, T_{2^d-1}\}$, 其中 $T_i \subseteq \Phi$ 表示第 i 种测试组合, $1 \leq i \leq 2^d - 1$. 记无故障模式为 f_0 , 在第 λ 种测试组合 T_λ 下, 系统发生故障 f_i 时的测量数据为 $X_\lambda = [x_1^\lambda, \dots, x_{n_1}^\lambda] \in \mathbf{R}^{m_\lambda \times n_1}$, 发生故障 f_j 时所获取的测量数据为 $Y_\lambda = [y_1^\lambda, \dots, y_{n_2}^\lambda] \in \mathbf{R}^{m_\lambda \times n_2}$, 其中 m_λ 为第 λ 种测试组合 T_λ 中测试的数量.

记 \mathcal{H} 为一个具有内积 $\langle \cdot, \cdot \rangle_{\mathcal{H}}$ 和相关范数 $\|\cdot\|_{\mathcal{H}}$ 运算 (定义 \mathcal{H} 上的范数运算为 $\|h\|_{\mathcal{H}} = \langle h, h \rangle_{\mathcal{H}}^{1/2}$) 的可分希尔伯特空间. 假设 $x_1^\lambda, \dots, x_{n_1}^\lambda, y_1^\lambda, \dots, y_{n_2}^\lambda$ 分别为独立同分布随机变量样本, 且满足 $X_\lambda \sim P_\lambda, Y_\lambda \sim Q_\lambda, P_\lambda, Q_\lambda$ 为未知多元分布, 则分布 P_λ 和 Q_λ 在 \mathcal{H} 上的距离^[28] 可表示为

$$\Delta(P_\lambda, Q_\lambda) = \sup_{f \in \mathcal{F}} |E_{X_\lambda \sim P_\lambda} f(X_\lambda) - E_{Y_\lambda \sim Q_\lambda} f(Y_\lambda)|. \quad (1)$$

其中: \mathcal{F} 为 \mathcal{H} 上的一类实值函数, E 为期望. 称 $\Delta(P_\lambda, Q_\lambda)$ 为 P_λ 与 Q_λ 之间的 MMD. 为便于描述, 记两组数据之间的 MMD: $\Delta(X_\lambda, Y_\lambda)$ 与两组数据所服从分布之间的 MMD: $\Delta(P_\lambda, Q_\lambda)$ 是等价的. 式 (1) 定义了两个概率分布之间的伪距离度量. 对于 $\forall P, Q, R$, 一个伪距离度量 $\Delta(\cdot, \cdot)$ 应满足以下条件^[29]:

- 1) $\Delta(P, P) = 0$;
- 2) $\Delta(P, Q) = \Delta(Q, P)$;
- 3) $\Delta(P, R) \leq \Delta(P, Q) + \Delta(Q, R)$.

\mathcal{F} 的选择需要满足两个要求:

1) 式 (1) 必须能够度量分布之间的距离, 即 $\Delta(P_\lambda, Q_\lambda)$ 需要满足

$$\Delta(P_\lambda, Q_\lambda) = 0 \Leftrightarrow P_\lambda = Q_\lambda. \quad (2)$$

2) \mathcal{F} 应为 \mathcal{H} 的一个子集使得 $\Delta(P_\lambda, Q_\lambda)$ 是有限的.

为选取合适的 \mathcal{F} 满足上述要求, 进行如下定义.

定义 1 设 k 为正定核函数, 则对于 $\forall x_1, x_2, \dots, x_n \in \mathcal{H}, \forall \alpha_1, \alpha_2, \dots, \alpha_n$, 均有

$$\sum_{i,j=1}^n \alpha_i \alpha_j k(x_i, x_j) \geq 0, \quad (3)$$

当且仅当 $\alpha_1 = \dots = \alpha_n = 0$ 时等号成立.

设 \mathcal{X} 为非空数据集, $\phi(x) = k(x, \cdot)$, 则 \mathcal{H} 中存在唯一的实值函数 Hilbert 空间 $H(k)$, 满足:

- 1) $\forall x \in \mathcal{X}, \phi(x) \in H(k)$;
- 2) $\forall f \in \mathcal{H}, \forall x \in \mathcal{X}, \langle f, \phi(x) \rangle_{H(k)} = f(x)$.

称 $H(k)$ 为核函数 k 的 RKHS.

定义 2 令 $\mathcal{B}(k) = \{f \in H(k) | \|f\|_{H(k)} \leq 1\}$ 表示 $H(k)$ 上的单位球, 设 \mathcal{F} 与 k 满足 $\mathcal{F} = \mathcal{B}(k)$, 如果 k 能够使得 $\Delta(P, Q) = 0 \Leftrightarrow P = Q$ 成立, 则称 k 为特征核.

常见的特征核包括: 高斯核 $k(x, y) = \exp\left(-\frac{\|x-y\|^2}{2\sigma^2}\right)$, 指数核 $k(x, y) = \exp\left(-\frac{\|x-y\|}{2\sigma^2}\right)$, 拉普拉斯核 $k(x, y) = \exp\left(-\frac{\|x-y\|}{\sigma}\right)$, 柯西核 $k(x, y) = \frac{1}{\|x-y\|^2/\sigma+1}$ 等, 其中核参数 $\sigma > 0$.

定义 3 设分布 P 满足 $E_{X \sim P}(\sqrt{k(X, X)}) < \infty$, 则存在 $\mu_P = E_{X \sim P}[\phi(X)] \in H(k)$, 使得对于 $\forall f \in H(k)$, 均有

$$\begin{aligned} Ef(X) &= \int_{\mathcal{X}} p(dX) f(X) = \\ &= \int_{\mathcal{X}} p(dX) \langle \phi(X), f \rangle_{H(k)} = \\ &= \int_{\mathcal{X}} \langle p(dX) \phi(X), f \rangle_{H(k)} = \langle \mu_P, f \rangle_{H(k)}, \end{aligned} \quad (4)$$

其中 μ_P 为 P 在 $H(k)$ 中的核均值嵌入.

由上述定义可知, 取 $\mathcal{F} = \mathcal{B}(k)$, k 为特征核即可使 \mathcal{F} 满足前文所提要求. 此时式 (1) 可表示为

$$\begin{aligned} \Delta(P_\lambda, Q_\lambda) &= \\ &= \sup_{f \in H(k), \|f\|_{H(k)} \leq 1} |E_{X_\lambda \sim P_\lambda} f(X_\lambda) - E_{Y_\lambda \sim Q_\lambda} f(Y_\lambda)| = \\ &= \sup_{f \in H(k), \|f\|_{H(k)} \leq 1} |\langle \mu_{P_\lambda}, f \rangle_{H(k)} - \langle \mu_{Q_\lambda}, f \rangle_{H(k)}| = \\ &= \sup_{f \in H(k), \|f\|_{H(k)} \leq 1} |\langle \mu_{P_\lambda} - \mu_{Q_\lambda}, f \rangle_{H(k)}|. \end{aligned} \quad (5)$$

根据内积性质, 有

$$\begin{aligned} |\langle \mu_{P_\lambda} - \mu_{Q_\lambda}, f \rangle_{H(k)}| &\leq \\ \|\mu_{P_\lambda} - \mu_{Q_\lambda}\|_{H(k)} \|f\|_{H(k)} &\leq \\ \|\mu_{P_\lambda} - \mu_{Q_\lambda}\|_{H(k)}. \end{aligned} \quad (6)$$

此时 $\Delta(P_\lambda, Q_\lambda)$ 可以表示 P_λ 和 Q_λ 在 RKHS 上核均值嵌入之间的差异, 即

$$\begin{aligned} \Delta(P_\lambda, Q_\lambda) &= \\ &= \sup_{f \in H(k), \|f\|_{H(k)} \leq 1} |\langle \mu_{P_\lambda} - \mu_{Q_\lambda}, f \rangle_{H(k)}| = \\ &= \|\mu_{P_\lambda} - \mu_{Q_\lambda}\|_{H(k)}. \end{aligned} \quad (7)$$

图 1 给出了核均值嵌入框架示意图. 分布被映射为 RKHS 中的一个点, 两个分布间的距离可以通过内积进行计算.




图1 核均值嵌入框架

由于 μ 无法直接计算, 考虑到样本均值是期望的无偏估计, 利用样本均值进行替代计算. $\Delta(P_\lambda, Q_\lambda)$ 的大小取决于 $H(k)$ 中 $\phi(X_\lambda)$ 与 $\phi(Y_\lambda)$ 平均值之间的差异, 有

$$\begin{aligned} \Delta(P_\lambda, Q_\lambda)^2 &= \\ \|\mu_{P_\lambda} - \mu_{Q_\lambda}\|_{H(k)}^2 &= \\ \left\| \frac{1}{n_1} \sum_{i=1}^{n_1} \phi(x_i^\lambda) - \frac{1}{n_2} \sum_{j=1}^{n_2} \phi(y_j^\lambda) \right\|_{H(k)}^2 &= \\ \frac{1}{n_1^2} \sum_{i,j=1}^{n_1} \langle \phi(x_i^\lambda), \phi(x_j^\lambda) \rangle + \frac{1}{n_2^2} \sum_{i,j=1}^{n_2} \langle \phi(y_i^\lambda), \phi(y_j^\lambda) \rangle - & \\ \frac{2}{n_1 n_2} \sum_{i,j=1}^{n_1, n_2} \langle \phi(x_i^\lambda), \phi(y_j^\lambda) \rangle. & \end{aligned} \quad (8)$$

根据 $H(k)$ 的可再生性可得

$$\begin{aligned} \langle \phi(x_i^\lambda), \phi(x_j^\lambda) \rangle_{H(k)} &= \\ \langle \phi(x_i^\lambda), k(x_j^\lambda, \cdot) \rangle_{H(k)} &= k(x_i^\lambda, x_j^\lambda). \end{aligned} \quad (9)$$

由此可得

$$\begin{aligned} \Delta(P_\lambda, Q_\lambda)^2 &= \\ \frac{1}{n_1^2} \sum_{i,j=1}^{n_1} k(x_i^\lambda, x_j^\lambda) + \frac{1}{n_2^2} \sum_{i,j=1}^{n_2} k(y_i^\lambda, y_j^\lambda) - & \\ \frac{2}{n_1 n_2} \sum_{i,j=1}^{n_1, n_2} k(x_i^\lambda, y_j^\lambda). & \end{aligned} \quad (10)$$

故障诊断性能与选取的测试相关, 由于故障可以由任意测试组合进行诊断, 本文将所有测试组合的 MMD 最大值作为故障可诊断性评价结果. 根据以上分析可以得到故障可诊断性评价公式为

$$D(f_i, f_j) = \max\{\Delta(P_\lambda, Q_\lambda)\}. \quad (11)$$

其中: $i, j = 0, 1, \dots, i \neq j, \lambda = 1, 2, \dots, 2^d - 1$. $D(f_i, f_0)$ 为故障 f_i 的可检测性, 数值越大表明故障 f_i 的可检测性越高, 故障 f_i 越容易被检测, $D(f_i, f_0) = 0$ 表示故障 f_i 是不可检测的. $D(f_i, f_j)$ 表示 f_i 与 f_j 的可隔离性, 数值越大表明故障 f_i 与故障 f_j 的可隔离性越高, 故障 f_i 与故障 f_j 越容易被隔离, $D(f_i, f_j) = 0$ 表示故障 f_i 与故障 f_j 是不可隔离的. 由于故障 f_i 不存在与自身的可隔离性, 不考虑 $D(f_i, f_j) (i = j)$ 的情况.

2 测量噪声对可诊断性的影响

由上一节分析可知, 测量数据是基于 MMD 进行故障可诊断性评价的基础. 然而, 由于在现实测量过程中不可避免地受到噪声干扰等因素的影响, 从而难以准确地获得所需的测量数据. 当测量数据存在误差时, 很容易造成可诊断性评价结果产生偏差, 进一步造成可诊断性设计的失误. 因此有必要分析测量噪声对故障可诊断性的影响, 这也是面向应用的故障可诊断性定量评价需要解决的关键问题之一.

当数据量足够大时, 假设测量数据服从正态分布. 为了简化计算, 提出如下定理.

定理1 若 k 为高斯核, X, Y 分别服从 l 维正态分布 $X \sim N(\mu_1, \Sigma_1)$ 和 $Y \sim N(\mu_2, \Sigma_2)$, 则 X 与 Y 的 MMD 为

$$\begin{aligned} \Delta(X, Y)^2 &= \\ |I_l + 4\sigma\Sigma_1|^{-1/2} + |I_l + 4\sigma\Sigma_2|^{-1/2} - & \\ 2|I_l + 2\sigma\Sigma|^{-1/2} \exp[-\sigma(\mu_1 - \mu_2)^T(I_l + & \\ 2\sigma\Sigma)^{-1}(\mu_1 - \mu_2)]. & \end{aligned} \quad (12)$$

其中: I_l 为 l 维单位阵, $\Sigma = \Sigma_1 + \Sigma_2$.

证明过程略^[30].

假设在测量过程中存在均值为 0、方差为 Σ^* 的高斯噪声. 与不考虑噪声时的测量数据 X, Y 相比, 添加了测量噪声后的数据 X^*, Y^* 方差会增大. 记 $\Sigma_1^* = \Sigma_1 + \Sigma^*, \Sigma_2^* = \Sigma_2 + \Sigma^*, X^* \sim N(\mu_1, \Sigma_1^*), Y^* \sim N(\mu_2, \Sigma_2^*), \text{tr}(\cdot)$ 为矩阵的迹. 利用 $\text{tr}(\Sigma^*)$ 表示噪声强度, $\text{tr}(\Sigma^*)$ 越大表示噪声的强度越高. 由式 (12) 可以得到 $\Delta(X^*, Y^*)$ 与 $\text{tr}(\Sigma^*)$ 之间的变化关系如图 2 所示.




图2 $\Delta(X^*, Y^*)$ 与 $\text{tr}(\Sigma^*)$ 的变化关系

由式 (12) 和图 2 可知, 当 $\text{tr}(\Sigma^*)$ 逐渐增大时, $\Delta(X^*, Y^*)$ 是单调递减的, 即测量噪声会降低故障的可诊断性, 并且噪声强度越大故障的可诊断性越低.

3 仿真分析

对某型开关电源系统进行故障可诊断性分析. 该开关电源采用 PWM 开关控制方式, 将 220 V 50 Hz 交流电转换成可控的恒流源供给负载从而实现电能的转换. 系统中所有电阻的容差为 5%, 电容的容差

为10%, 测试 t_1 、 t_4 为电流信号检测, t_2 、 t_3 为电压信号检测. 限于篇幅, 选取系统中部分关键元件的故障模式进行分析, 如表1所示.

表1 故障模式表

故障编号	故障元件	故障类型
f_0	—	无故障
f_1	Q_1	开路
f_2	U_3	短路
f_3	R_{11}	开路
f_4	R_{18}	短路
f_5	C_{10}	短路
f_6	R_6	开路

系统中有4个测试, 故共有15种测试组合, 即 $\hat{T} = \{T_1, T_2, \dots, T_{15}\}$, \hat{T} 中元素如表2所示.

表2 测试组合表

测试组合编号	测试组合	测试组合编号	测试组合
T_1	$\{t_4\}$	T_9	$\{t_1, t_4\}$
T_2	$\{t_3\}$	T_{10}	$\{t_1, t_3\}$
T_3	$\{t_3, t_4\}$	T_{11}	$\{t_1, t_3, t_4\}$
T_4	$\{t_2\}$	T_{12}	$\{t_1, t_2\}$
T_5	$\{t_2, t_4\}$	T_{13}	$\{t_1, t_2, t_4\}$
T_6	$\{t_2, t_3\}$	T_{14}	$\{t_1, t_2, t_3\}$
T_7	$\{t_2, t_3, t_4\}$	T_{15}	$\{t_1, t_2, t_3, t_4\}$
T_8	$\{t_1\}$		

3.1 可诊断性评价结果分析


假设测试信号存在0均值高斯噪声, 信噪比 $SNR = 20 \text{ dB}$, 均匀采集0~5 ms时间内的测量数据. 取 k 为高斯核, 核参数 $\sigma = 1$. 以故障 f_1 为例, 首先分析故障 f_1 的可检测性. 无故障发生时和发生故障 f_1 时的测量信号如图3所示. 在使用测试 $t_1 \sim t_4$ 的条件下, 计算在无故障发生时测量数据 X 和发生故障 f_1 时测量数据 Y^1 的MMD所组成的集合为

$$\{0.0053, 0.9864, 0.9814, 0.0800, 0.0796, 0.6384, 0.6352, 0.0525, 0.0525, 0.9815, 0.9766, 0.0861, 0.0856, 0.6352, 0.6319\}.$$


由计算结果可知, 集合中第2个元素0.9864为最大值, 即选用测试组合 $T_2 : \{t_3\}$ 进行检测时 X 和 Y^1 具有最大的MMD, 故障 f_1 的可检测性为 $D(f_1, f_0) = 0.9864$.

分析故障 f_1 和故障 f_2 的可隔离性. 发生故障 f_2 时的测量信号数据如图4所示.

计算发生故障 f_1 时测量数据 Y^1 和发生故障 f_2



(a) 无故障时的测量信号



(b) 发生故障 f_1 时的测量信号

图3 无故障发生时和发生故障 f_1 时的测量信号




图4 发生故障 f_2 时的测量信号

时测量数据 Y^2 的MMD所组成的集合为

$$\{0.0015, 0.0011, 0.0018, 0.9946, 0.9901, 0.9898, 0.9853, 0.0149, 0.0148, 0.0148, 0.0148, 0.9895, 0.9850, 0.9848, 0.9803\}.$$

由计算结果可知, 集合中第4个元素0.9946为最大

值,即选用测试组合 $T_4 : \{t_2\}$ 进行检测时 Y^1 和 Y^2 具有最大的MMD,故障 f_1 与故障 f_2 的可隔离性为 $D(f_1, f_2) = 0.9946$. 其余故障的可检测性和可隔离性分析过程类似,此处不再赘述.

给出该系统故障可诊断性评价结果如表3所示. 由表3可知,故障 f_2 的可检测性最高,其余故障可检测性比较接近,这是因为: t_3 设置在系统输出端,当发生 $f_1 \sim f_6$ 中任一故障时, t_3 的输出均为0,与正常情况相比,测试 t_3 的差异较为明显. 对于故障 f_2 ,除 t_3 外,测试 t_2 的差异也比较明显,此时采用 $T_6 : \{t_2, t_3\}$

测量数据之间能够取到MMD的最大值1.0304;对于其余故障,除 t_3 外其他测试差异都不明显,故采用 $T_2 : \{t_3\}$ 时测量数据之间能够取到MMD的最大值,因此除故障 f_2 外其余故障的可检测性非常接近. 故障 f_4 与 f_5 的可隔离性最低: $D(f_4, f_5) = 0.0189$,表明发生故障 f_4 和 f_5 时,测试 $t_1 \sim t_4$ 的测量数据基本相同,利用测试 $t_1 \sim t_4$ 隔离故障 f_4 与 f_5 是比较困难的. 此外,由式(10)和表3可知:对于任意两个故障 f_i 和 f_j ,其可隔离性评价结果是对称的,即 $D(f_i, f_j) = D(f_j, f_i)$.

表3 基于MMD的可诊断性评价结果

	f_0	f_1	f_2	f_3	f_4	f_5	f_6
f_1	0.9864	*	0.9946	0.8271	0.8739	0.8810	0.9144
f_2	1.0304	0.9946	*	0.4491	0.3431	0.3290	0.0865
f_3	0.9867	0.8271	0.4491	*	0.2450	0.2442	0.3960
f_4	0.9865	0.8739	0.3431	0.2450	*	0.0189	0.2978
f_5	0.9864	0.8810	0.3290	0.2442	0.0189	*	0.2848
f_6	0.9863	0.9144	0.0865	0.3960	0.2978	0.2848	*

为验证本文方法对系统故障可诊断性评价结果的正确性,采用t-SNE算法^[31]将测量数据投影至2维空间进行可视化,根据数据的聚类程度对所提出方法进行验证. 考虑到 $D(f_1, f_2) > D(f_3, f_4) > D(f_4, f_5)$, 分别以故障 f_1 与 f_2 、 f_3 与 f_4 、 f_4 与 f_5 为例进行实验,其中每类故障的测试信号采集50个样本,仿真结果如图5所示.

由图5可见:对于故障 f_1 与 f_2 ,同一类别的测量数据全部分布在同一区域内,且两类数据之间间隔较大,可以明显区分出两类故障;对于故障 f_3 与 f_4 ,同一类别的测量数据仅有部分分布在同一区域内,并且两类测量数据所在区域存在重叠;对于故障 f_4 与 f_5 ,两类测量数据所在区域基本上完全重合,数据可区分性差,难以区分两类故障. 上述结果与故障可诊断性评价结果一致,可以表明所提出方法的可诊断性评价结果是正确的. 另外,对于故障可诊断性较低的故障,可以考虑对系统进行基于故障可诊断性的优化设计,通过增设测试或改变所设测试的位置等方法来提高测试数据的差异程度,进而提高实际的故障诊断效果.

为表明本文方法的优点,将基于本文方法与基于K-L散度方法^[21-22]的故障可诊断性评价结果进行对比. 可以得到,基于K-L散度方法所得故障可隔离性结果是不对称的,即 $D(f_i, f_j) \neq D(f_j, f_i)$. 例如,故障 f_1 与 f_2 的可隔离性为 $D(f_1, f_2) = 3.3886e3$, f_2 与 f_1 之间的可隔离性为 $D(f_2, f_1) = 3.9652$;故障 f_1 与 f_3 之间的可隔离性为 $D(f_1, f_3) = 2.8316$, f_3 与 f_1




图5 数据可视化结果

之间的可隔离性为 $D(f_3, f_1) = 384.0589$. 由于 K-L 散度本身非对称的性质, 出现 $D(f_1, f_2) > D(f_1, f_3)$ 而 $D(f_2, f_1) < D(f_3, f_1)$ 的情况, 此时无法判断隔离故障 f_1 与 f_2 的难度是否大于隔离故障 f_1 与 f_3 的难度. MMD 作为一种度量距离, 满足对称性条件, 因此基于本文方法所得到的故障可诊断性评价结果是对称的, 能够明确隔离各个故障的难易程度.

3.2 核函数影响分析

3.2.1 特征核

由式 (10) 可知, 故障可诊断性评价结果除了与测量数据自身有关, 还与所选取的特征核有关. 为分析所选取的特征核对故障可诊断性评价结果的影响, 分别选取特征核为指数核、拉普拉斯核和柯西核可对诊断性进行定量评价, 核参数 $\sigma = 1$. 因为不同特征核的具体形式不同, 当选用不同的特征核时, 所得到的可诊断性评价结果具体数值存在差异, 所以基于不同特征核得到的可诊断性评价结果之间不具有可比性. 但是, 特征核的变化不会改变故障可诊断性强弱的基本特性. 例如: 在所有评价结果中, 故障 f_2 的可检测性最高、故障 f_4 与 f_5 的可隔离性最低的结论没有发生改变. 就这方面而言, 选取不同特征核所得到的可诊断性评价结果是一致的.

3.2.2 核参数

由于本文选用的是高斯核, 为分析核参数 σ 对故障可诊断性评价结果的影响, 依次将 σ 设置为 $\sigma = 1, 5, 10, 15, 20$, SNR 为 20 dB. 当发生故障 f_1 时, 各测试组合在不同 σ 取值下 $\Delta(X, Y^1)$ 的计算结果如图 6 所示.




图 6 各测试组合在不同 σ 取值下 $\Delta(X, Y^1)$ 的计算结果

图 6 中横坐标为测试组合, 纵坐标为无故障发生时测量数据 X 和发生故障 f_1 时测量数据 Y^1 的 MMD, 不同 σ 取值情况下各测试组合的 MMD 最大值用红色圆圈进行标记. 令

$$\Delta_{ij}(X, Y^1) = |\Delta(X_i, Y_i^1) - \Delta(X_j, Y_j^1)|.$$

由图 6 可知, σ 取值对故障可诊断性评价结果的数值存在影响: σ 取值越大, $D(f_1, f_0)$ 和 $\Delta_{ij}(X, Y^1)$

数值越小. 以 $\Delta_{26}(X, Y^1)$ 为例, $D(f_1, f_0)$ 和 $\Delta_{26}(X, Y^1)$ 在不同 σ 取值下的变化趋势如图 7 所示.




图 7 σ 对故障 f_1 可检测性评价结果的影响

由图 7 可知, $\Delta_{26}(X, Y^1)$ 随着 σ 增大而减小, 表明 σ 的增大降低了 $\Delta_{ij}(X, Y^1)$ 对数据变化的敏感性. 因此, 为了使 $\Delta(X, Y)$ 能够充分反应数据之间的差异, σ 的取值不宜过大. 另外, 在 σ 所有取值情况中, $\Delta(X, Y^1)$ 都是在选用测试组合 $T_2 : \{t_3\}$ 时取得最大值, 表明 σ 取值变化虽然改变了可诊断性评价结果的数值, 但不会改变确定可诊断性评价结果时所选用的测试组合, 表明了故障可诊断性是系统的一种固有属性. σ 对其余故障的可诊断性影响分析结果与图 6 和图 7 类似, 此处不再赘述.

3.3 测量噪声影响分析

为验证测量噪声强度对故障可诊断性的影响, 分别将信噪比设置为 $\text{SNR} = -10, -5, 0, \dots, 30$ dB. 不同 SNR 对故障 f_1 可诊断性评价结果的影响如图 8 所示.




图 8 SNR 对故障 f_1 可诊断性评价结果的影响

由图 8 可见, 随着测量噪声强度逐渐减小, 故障可诊断性的指标逐渐增大, 表明测量噪声强度越小诊断故障的难度越低. 并且当 $\text{SNR} \leq 15$ dB 时, 可诊断性指标增长趋势较快; 当 $\text{SNR} > 15$ dB 时, 可诊断性指标增长趋势较慢. 因此可以认为当 $\text{SNR} > 15$ dB

时,测量噪声对可诊断性的影响较小. 测量噪声强度对其余故障可诊断性影响的分析结果与图8类似,此处不再赘述.

4 结论

本文提出了一种基于MMD的故障可诊断性定量评价新方法,具体如下:

1) 将故障可诊断性定量评价问题转化为多元分布的距离度量问题,通过度量测量数据之间的距离对故障可诊断性进行定量评价.

2) 以MMD为指标度量多元分布之间的距离,分析了基于MMD进行故障可诊断性定量评价的基本原理,在此基础上通过数学推导研究了测量噪声对故障可诊断性的影响,并得到相关结论:测量噪声强度越大,故障的可诊断性越低.

3) 通过仿真实例验证了所提出方法的有效性,并分析了不同的核参数和信噪比对可诊断性评价结果的影响.

可诊断性评价是可诊断性设计的基础,如何利用可诊断性评价结果指导可诊断性优化设计是后续工作的研究重点.

参考文献(References)

- [1] Song Y, Li Y B, Jia L, et al. Retraining strategy-based domain adaption network for intelligent fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(9): 6163-6171.
- [2] Dey S, Perez H E, Moura S J. Robust fault detection of a class of uncertain linear parabolic PDEs[J]. Automatica, 2019, 107: 502-510.
- [3] Yin X, Chen J, Li Z J, et al. Robust fault diagnosis of stochastic discrete event systems[J]. IEEE Transactions on Automatic Control, 2019, 64(10): 4237-4244.
- [4] IEEE Trialuse standard for test ability and diagnosability characteristics and metrics[S]. 2004.
- [5] 王大轶, 符方舟, 刘成瑞, 等. 控制系统可诊断性的内涵与研究综述[J]. 自动化学报, 2018, 44(9): 1537-1553.
(Wang D Y, Fu F Z, Liu C R, et al. Connotation and research status of diagnosability of control systems: A review[J]. Acta Automatica Sinica, 2018, 44(9): 1537-1553.)
- [6] 李文博, 王大轶, 刘成瑞. 有干扰的控制系统故障可诊断性量化评估[J]. 控制理论与应用, 2015, 32(6): 744-752.
(Li W B, Wang D Y, Liu C R. Quantitative fault diagnosis ability evaluation for control systems with disturbances[J]. Control Theory & Applications, 2015, 32(6): 744-752.)
- [7] Wang D Y, Fu F Z, Li W B, et al. A review of the diagnosability of control systems with applications to spacecraft[J]. Annual Reviews in Control, 2020, 49: 212-229.
- [8] 王振西, 刘成瑞, 张强, 等. 基于多信号流图和改进BHS-树的陀螺可诊断性研究[J]. 空间控制技术与应用, 2012, 38(4): 1-5.
(Wang Z X, Liu C R, Zhang Q, et al. Gyro's diagnosability method based on multi-signal flow graph and improved BHS-tree[J]. Aerospace Control and Application, 2012, 38(4): 1-5.)
- [9] 刘文静, 李文博, 张秀云, 等. 基于图论的深空探测航天器故障可诊断性评价[J]. 控制理论与应用, 2019, 36(12): 2074-2084.
(Liu W J, Li W B, Zhang X Y, et al. Fault diagnosability evaluation of deep space exploration spacecraft based on graph theory[J]. Control Theory & Applications, 2019, 36(12): 2074-2084.)
- [10] Liu J, Hua Y Z, Li Q D, et al. Fault diagnosability qualitative analysis of spacecraft based on temporal fault signature matrix[C]. IEEE Chinese Guidance, Navigation and Control Conference. Nanjing, 2016: 1496-1500.
- [11] Dunia R, Joe Qin S. Subspace approach to multi dimensional fault identification and reconstruction[J]. AIChE Journal, 1998, 44(8): 1813-1831.
- [12] Yue H H, Qin S J. Reconstruction-based fault identification using a combined index[J]. Industrial & Engineering Chemistry Research, 2001, 40(20): 4403-4414.
- [13] Mnassri B, Adel E M E, Ouladsine M. Unified sufficient conditions for PCA-based fault detectability and isolability[J]. IFAC Proceedings Volumes, 2012, 45(20): 421-426.
- [14] Mnassri B, El Adel E M, Ouladsine M. Generalization and analysis of sufficient conditions for PCA-based fault detectability and isolability[J]. Annual Reviews in Control, 2013, 37(1): 154-162.
- [15] Eriksson D, Krysander M, Frisk E. Quantitative fault diagnosability performance of linear dynamic descriptor models[C]. Proceedings of the 22nd International Workshop on Principles of Diagnosis. Murnau, 2011: 1-8.
- [16] Eriksson D, Krysander M, Frisk E. Quantitative stochastic fault diagnosability analysis[C]. Proceedings of the 50th IEEE Conference on Decision and Control and European Control Conference. Orlando, 2011: 1563-1569.
- [17] Fu F Z, Wang D Y, Li L L, et al. Datadriven method for the quantitative fault diagnosability analysis of dynamic

- systems[J]. IET Control Theory & Applications, 2019, 13(8): 1197-1203.
- [18] Fu F Z, Xue T, Wu Z G, et al. A fault diagnosability evaluation method for dynamic systems without distribution knowledge[J]. IEEE Transactions on Cybernetics, 2022, 52(6): 5113-5123.
- [19] Fu F Z, Wang D Y. A method for quantitative fault diagnosability analysis of systems with probabilistic sensor faults[J]. International Journal of Control, Automation and Systems, 2019, 17(8): 2159-2164.
- [20] Fu F Z, Wang D Y, Li W B, et al. Data-driven fault identifiability analysis for discrete-time dynamic systems[J]. International Journal of Systems Science, 2020, 51(2): 404-412.
- [21] 蒋栋年, 李炜, 王君, 等. 基于故障可诊断性量化评价的传感器优化配置方法研究[J]. 自动化学报, 2018, 44(6): 1128-1137.
(Jiang D N, Li W, Wang J, et al. Research on sensor optimal placement method using quantitative evaluation of fault diagnosability[J]. Acta Automatica Sinica, 2018, 44(6): 1128-1137.)
- [22] 蒋栋年, 李炜, 王君. 非线性系统故障可诊断性量化评价及诊断方法[J]. 华中科技大学学报: 自然科学版, 2016, 44(12): 102-108.
(Jiang D N, Li W, Wang J. Fault diagnosability quantitative evaluation and method of fault diagnosis for nonlinear system[J]. Journal of Huazhong University of Science and Technology: Natural Science Edition, 2016, 44(12): 102-108.)
- [23] Zhao D, Ahn C K, Paszke W, et al. Fault diagnosability analysis of two-dimensional linear discrete systems[J]. IEEE Transactions on Automatic Control, 2021, 66(2): 826-832.
- [24] 符方舟, 王大轶, 李文博. 复杂动态系统的实际非完全失效故障的可诊断性评估[J]. 自动化学报, 2017, 43(11): 1941-1949.
(Fu F Z, Wang D Y, Li W B. Quantitative evaluation of actual LOE fault diagnosability for dynamic systems[J]. Acta Automatica Sinica, 2017, 43(11): 1941-1949.)
- [25] Long M S, Wang J M, Ding G G, et al. Adaptation regularization: A general framework for transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2014, 26(5): 1076-1089.
- [26] Jia X D, Zhao M, Di Y, et al. Assessment of data suitability for machine prognosis using maximum mean discrepancy[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5872-5881.
- [27] Li X Q, Jiang H K, Wang R X, et al. Rolling bearing fault diagnosis using optimal ensemble deep transfer network[J]. Knowledge-Based Systems, 2021, 213: 106695.
- [28] Gretton A, Borgwardt K M, Rasch M J, et al. A kernel twosample test[J]. Journal of Machine Learning Research, 2012, 13: 723-773.
- [29] Kellner J, Celisse A. A onesample test for normality with kernel methods[J]. Bernoulli, 2015, 25(3): 1816-1837.
- [30] Wand M P, Jones M C. Kernel Smoothing[M]. New York: Chapman & Hall, 1994: 24-25.
- [31] Laurens V D M, Geoffrey H. Visualizing data using tSNE[J]. Journal of Machine Learning Research, 2008, 9: 2579-2605.

作者简介

秦玉峰(1995—), 男, 博士生, 从事故障可诊断性设计的研究, E-mail: Hy_qyf082@163.com;

史贤俊(1968—), 男, 教授, 博士生导师, 从事飞行器故障诊断、测试性设计等研究, E-mail: sxjaa@sina.com.