

鉴别流形敏感的跨模态轴承故障诊断方法

朱彦敏^{1,3}, 苏树智^{2,3}

1. 安徽理工大学机电工程学院, 安徽淮南 232001

2. 安徽理工大学计算机科学与工程学院, 安徽淮南 232001

3. 合肥综合性国家科学中心大健康研究院 职业医学与健康联合研究中心(安徽理工大学), 安徽淮南 232001

摘要:目的 在实际应用中采集的原始多模态故障数据通常是包含大量噪声和冗余信息的非线性数据, 如何从不同故障模态中提取有效的非线性故障特征仍是一个挑战性的问题。方法 提出了一种鉴别流形敏感的跨模态故障诊断方法, 在该方法中首先借助相关分析理论在跨模态故障空间中构建了不同模态间的相关系数, 并通过理论推导获得了相关系数的等价优化模型, 然后利用局部近邻图构建了鉴别流形敏感散布, 进而通过最大化不同模态间的相关性和最小化鉴别流形敏感散布, 形成了鉴别流形敏感的跨模态故障诊断模型, 并且在理论上推导出了该优化模型的解析解, 从而能够从不同模态的故障数据中学习强鉴别力的非线性故障特征。结果 在德国帕德博恩轴承数据集和多模态轴承故障数据集上设计了针对性实验, 实验结果显示在少量故障样本用于训练时即可获得良好的诊断准确性。结论 提出的方法是一种有效的跨模态故障诊断方法。

关键词:故障诊断; 跨模态故障特征抽取; 鉴别流形结构

中图分类号: TP277 **文献标识码:** A **doi:** 10.16055/j.issn.1672-058X.2024.0003.015

Discriminant Manifold Sensitivity Cross-Modal Bearing Fault Diagnosis Method

ZHU Yanmin^{1,3}, SU Shuzhi^{2,3}

1. School of Mechanical and Electrical Engineering, Anhui University of Science & Technology, Anhui Huainan 232001, China

2. School of Computer Science and Engineering, Anhui University of Science & Technology, Anhui Huainan 232001, China

3. Joint Research Center for Occupational Medicine and Health of Institute, Health and Medicine, Hefei Comprehensive National Science Center, Anhui University of Science & Technology, Anhui Huainan 232001, China

Abstract: Objective Raw multi-modal fault data collected in practical applications is usually nonlinear data containing a large amount of noise and redundant information. How to extract effective nonlinear fault features from different fault modalities is still a challenging problem. **Methods** A discriminant manifold sensitivity cross-modal fault diagnosis method was proposed. In the method, the correlation coefficient between different modalities was first constructed in the cross-

收稿日期: 2023-10-18 **修回日期:** 2023-11-18 **文章编号:** 1672-058X(2024)03-0113-06

基金项目: 国家自然科学基金面上项目(52374155和61806006); 安徽省自然科学基金(面上项目)(2308085MF218); 安徽省高等学校自然科学研究项目(重大项目)(2022AH040113); 安徽省高校中青年教师培养行动项目(YQZD2023035); 淮南市指导性科技计划项目(2023142和2023147); 安徽理工大学青年基金(重点项目)(QNZD202202); 安徽理工大学医学专项培育项目(重大项目)(YZ2023H2A007); 合肥综合性国家科学中心大健康研究院职业医学与健康联合研究中心项目(OMH-2023-05和OMH-2023-24)。

作者简介: 朱彦敏(1987—), 女, 博士研究生, 讲师, 从事多模态故障诊断研究。

通讯作者: 苏树智(1987—), 男, 博士研究生, 副教授, 从事多模态模式识别研究。Email: sushuzhi@foxmail.com.

引用格式: 朱彦敏, 苏树智. 鉴别流形敏感的跨模态轴承故障诊断方法[J]. 重庆工商大学学报(自然科学版), 2024, 41(3): 113—118.

ZHU Yanmin, SU Shuzhi. Discriminant manifold sensitivity cross-modal bearing fault diagnosis method[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(3): 113—118.

modal fault space using correlation analysis theory, and the equivalent optimization model of the correlation coefficient was obtained by theoretical derivation. Then, the discriminant manifold sensitivity scatter was constructed by using local neighborhood graphs, and a discriminant manifold sensitivity cross-modal fault diagnosis model was constructed by maximizing the correlation between different modalities and minimizing the discriminant manifold sensitivity scatter. The analytical solutions of the optimization model were derived theoretically, so that nonlinear fault features with well discriminant power can be obtained from fault data of different modalities. **Results** Targeted experiments were designed on the Germany Paderborn bearing dataset and the multi-modal bearing fault dataset. The experimental results showed that good diagnosis accuracy can be achieved with a small number of training fault samples. **Conclusion** The proposed method is an effective cross-modal fault diagnosis method.

Keywords: fault diagnosis; cross-modal fault feature extraction; discriminant manifold structure

1 引言

轴承故障诊断是机械安全生产的重要环节,一般可分为基于模型的轴承故障诊断方法^[1]和基于数据驱动的轴承故障诊断方法^[2]。基于模型的轴承故障诊断方法需要针对实际场景构建精确的物理或数学模型,然而由于实际环境和故障机理的高复杂性,往往难以实现精准模型的构建。随着传感器和存储设备的发展,在实际生产中能够采集和存储大量的设备监测数据,并且基于数据驱动的轴承故障诊断方法具有信息提取能力强、环境泛化能力好、设计需求低等优点,该类方法是目前轴承故障诊断主流方法^[3]。

常见的数据驱动式轴承故障诊断方法有主成分分析^[4]、线性鉴别分析^[5]、近邻保持投影^[6]、流形学习^[7]等方法。然而该类方法主要处理单模态数据,难以有效从不同模态中同时提取有效的故障特征。典型相关分析(Canonincal Correlation Analysis, CCA)^[8]是一种多变量统计方法,能够同时从两种模态中学习相关特征,在一定程度上能够视为主成分分析和偏最小二乘^[9]的方法扩展。然而 CCA 是一种无监督方法,无法利用类标签等鉴别信息进一步改善学习特征的分类性能,为此,鉴别多典型相关分析(Discriminative Canoncial Correlation Analysis, DMCCA)^[10]方法构建了基于类标签的跨模态相关分析矩阵,并以此为基础学习了鉴别相关投影方向,从而实现了不同模态间鉴别相关特征的同时抽取。从模态内鉴别散布的角度出发,标签多典型相关分析(Labeled Multiple Canoncial Correlation Analysis, LMCCA)^[11]方法约束了子空间中类内样本的聚集性,从而形成了标签敏感的跨模态子空间学习模型,该模型能够将类标签信息有效嵌入低维子空间,并且大量

实验结果验证了该方法的有效性。

在实际生产中采集的跨模态故障数据通常属于带有大量噪声的非线性数据^[12],然而上述方法均属于线性特征学习方法难以掌握跨模态非线性故障数据中的几何结构,进而影响抽取特征的鉴别力。为此,分布跨模态特征学习^[13]方法利用不同近邻样本间的几何分布关系来约束低维空间的非线性结构,从而改善非线性结构失真带来的弱鉴别力问题。另外,局部保持典型相关分析(Locality Preserving Canoncial Correlation Analysis, LPPCCA)^[8]方法将局部结构信息嵌入典型相关分析的理论框架,形成了模态间的局部相关优化模型,已解决两个模态间非线性相关缺失的问题,并利用全局核技术进一步增强了低维特征间的流形可分性,但是该方法缺失了跨模态鉴别结构的约束。

如何从带有大量噪声和冗余信息的跨模态故障数据中提取有效的非线性故障特征仍然是一项具有挑战性的工作,为此,本文以空间学习理论为基础,在跨模态故障空间中构建了不同模态间的相关系数,通过理论推导进一步给出了该相关系数的等价优化模型,并进一步提出基于局部近邻图的鉴别流形散布,该散布能够有效约束故障特征的内在流形结构。然后通过最大化不同模态间的相关性和最小化鉴别流形散布,构建鉴别流形敏感的跨模态故障诊断优化模型,并且在理论上推导出该优化模型的解析解,进而形成鉴别流形敏感的跨模态故障诊断(Discriminant Manifold Sensitivity Cross-modal Fault Diagnosis, DMSCFD)方法,该方法能够从不同模态的故障数据中学习强鉴别力的非线性故障特征。为了验证提出方法的有效性,在德国帕德博恩多模态故障数据集和多模态轴承故障数据

集上设计了针对性实验,实验结果显示 DMSCFD 方法是一种有效的跨模态故障诊断方法。

2 模型的构建

假设 $X = [x_1, x_2, \dots, x_n] \in R^{d_x \times n}$ 和 $Y = [y_1, y_2, \dots, y_n] \in R^{d_y \times n}$ 为两个不同模态的故障样本集,其中 d_x 和 d_y 分别为故障样本集 X 和 Y 的样本维数, n 为样本数量, x_i 为 X 中第 i ($i=1, 2, \dots, n$) 个故障样本, y_i 为 Y 中第 i 个故障样本。 $\alpha \in R^{d_x \times 1}$ 和 $\beta \in R^{d_y \times 1}$ 分别为 X 和 Y 对应的空间投影方向。利用空间投影方向能够将 X 与 Y 投影到跨模态故障空间,进而获得投影后的故障特征,即 $\alpha^T X = [\alpha^T x_1, \alpha^T x_2, \dots, \alpha^T x_n]$ 和 $\beta^T Y = [\beta^T y_1, \beta^T y_2, \dots, \beta^T y_n]$ 。

为了约束不同模态间故障特征的内在一致性,本文首先借助相关分析理论^[14],在跨模态故障一致空间中构建了 X 和 Y 的相关系数:

$$\rho(\alpha^T X, \beta^T Y) = \frac{\text{Cov}(\alpha^T X, \beta^T Y)}{\sqrt{\text{Cov}(\alpha^T X, \alpha^T X)} \sqrt{\text{Cov}(\beta^T Y, \beta^T Y)}} \quad (1)$$

其中, $\text{Cov}(\alpha^T X, \beta^T Y) = \frac{1}{n} \sum_{i=1}^n (\alpha^T x_i - \alpha^T \bar{x}) (\beta^T y_i - \beta^T \bar{y})$ 为 $\alpha^T X$ 与 $\beta^T Y$ 的协方差。在 $\text{Cov}(\alpha^T X, \beta^T Y)$ 中 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ 为 X 的故障样本均值, $\text{Cov}(\alpha^T X, \alpha^T X)$ 和 $\text{Cov}(\beta^T Y, \beta^T Y)$ 的定义与 $\text{Cov}(\alpha^T X, \beta^T Y)$ 的定义相同。

在跨模态故障空间中最大化相关系数能够尽量保留不同模态间的一致信息^[15],为此,利用式(1)构建了空间投影方向 α 和 β 的目标优化模型:

$$\max_{\alpha, \beta} \rho(\alpha^T X, \beta^T Y) = \frac{\alpha^T H_{xy} \beta}{\sqrt{\alpha^T H_{xx} \alpha} \sqrt{\beta^T H_{yy} \beta}} \quad (2)$$

其中, $H_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})^T$, $H_{xx} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T$, $H_{yy} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(y_i - \bar{y})^T$ 。

对于空间投影方向 α 和 β ,相关系数 $\rho(\alpha^T X, \beta^T Y)$ 具有尺度不变性^[16],因此,能够将式(2)等价转化为带有约束的极值优化问题:

$$\begin{aligned} \max_{\alpha, \beta} \quad & \alpha^T H_{xy} \beta \\ \text{s. t.} \quad & \alpha^T H_{xx} \alpha = 1, \beta^T H_{yy} \beta = 1 \end{aligned} \quad (3)$$

上述极值优化问题是基于样本均值的表达形式,

难以嵌入样本间的关系约束信息,为此本文对 H_{xy} 进行了下列等价推导:

$$\begin{aligned} H_{xy} &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})^T = \\ & \frac{1}{n} \sum_{i=1}^n x_i y_i^T - \left(\frac{1}{n} \sum_{i=1}^n x_i \right) \bar{y}^T - \bar{x} \left(\frac{1}{n} \sum_{i=1}^n y_i^T \right) + \\ & \frac{1}{n} \sum_{i=1}^n \bar{x} \bar{y}^T = \frac{1}{n} \sum_{i=1}^n x_i y_i^T - \bar{x} \bar{y}^T = \\ & \frac{1}{n} \sum_{i=1}^n x_i y_i^T - \frac{1}{n^2} \sum_{i=1}^n x_i \sum_{j=1}^n y_j^T = \\ & \frac{1}{2n^2} \sum_{i=1}^n \sum_{j=1}^n (x_i y_i^T - x_i y_j^T - x_j y_i^T + x_j y_j^T) = \\ & \frac{1}{2n^2} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)(y_i - y_j)^T \quad (4) \end{aligned}$$

类似 H_{xy} 的等价推导, H_{xx} 和 H_{yy} 同样能够等推导出为

$$H_{xx} = \frac{1}{2n^2} \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)(x_i - x_j)^T \quad (5)$$

$$H_{yy} = \frac{1}{2n^2} \sum_{i=1}^n \sum_{j=1}^n (y_i - y_j)(y_i - y_j)^T \quad (6)$$

极值优化问题具有常量不变性^[17],即目标函数乘以任意非零正数,不改变其优化结果。因此,进一步根据式(5)、式(6)、式(7)中的等价推导,式(4)能够转化为下列等价优化模型:

$$\begin{aligned} \max_{\alpha, \beta} \quad & \alpha^T \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)(y_i - y_j)^T \beta \\ \text{s. t.} \quad & \alpha^T \sum_{i=1}^n \sum_{j=1}^n (x_i - x_j)(y_i - y_j)^T \alpha = 1 \\ & \beta^T \sum_{i=1}^n \sum_{j=1}^n (y_i - y_j)(y_i - y_j)^T \beta = 1 \quad (7) \end{aligned}$$

原始跨模态故障数据通常是包含大量噪声和冗余信息的非线性数据,为了能够在学习的跨模态故障空间中嵌入非线性的鉴别流形结构,本文进一步构建了故障样本集 X 的局部近邻图,其中该图的近邻权重矩阵 $W^x \in R^{n \times n}$ 的计算公式如下:

$$w_{ij}^x = \begin{cases} e^{-\frac{\|x_i - x_j\|}{2\sigma^2}}, & \text{if } x_j \in \text{Nei}_k(x_i) \\ 0, & \text{otherwise} \end{cases} \quad (8)$$

其中, w_{ij}^x 为 W^x 中的第 (i, j) 个元素, $\text{Nei}_k(x_i)$ 表示在 X 中与 x_i 在同一类内的前 k 个近邻样本的集合, σ 为高斯参数。

在式(8)的基础上,利用局部近邻图构建了故障样本集 X 的鉴别流形散布 \tilde{R}_{xx} :

$$\tilde{R}_{xx} = \alpha^T \sum_{i=1}^n w_{ij}^x (x_i - x_j) (x_i - x_j)^T \alpha = \alpha^T R_{xx} \alpha \quad (9)$$

其中, $R_{xx} = \sum_{i=1}^n w_{ij}^x (x_i - x_j) (x_i - x_j)^T$ 。类似于鉴别流形散布 \tilde{R}_{xx} 的构建,故障样本集 Y 的鉴别流形散布 \tilde{R}_{yy} 可以构建为

$$\tilde{R}_{yy} = \beta^T \sum_{i=1}^n w_{ij}^y (y_i - y_j) (y_i - y_j)^T \beta = \beta^T R_{yy} \beta \quad (10)$$

其中, $R_{yy} = \sum_{i=1}^n w_{ij}^y (y_i - y_j) (y_i - y_j)^T$ 。在式(11)中 w_{ij}^y 是 Y 近邻权重矩阵 $W^y \in R^{n \times n}$ 的第 (i, j) 个元素, w_{ij}^y 的计算公式如下:

$$w_{ij}^y = \begin{cases} e^{-\frac{\|y_i - y_j\|}{2\sigma^2}}, & \text{if } y_j \in \text{Nei}_k(y_i) \\ 0, & \text{otherwise} \end{cases} \quad (11)$$

其中, $\text{Nei}_k(y_i)$ 有与 $\text{Nei}_k(x_i)$ 类似的定义。

通过最大化不同模态间的相关性和最小化鉴别流形散布,能够在保留不同模态间一致信息的前提下尽量将流形鉴别结构嵌入学习的模态故障空间,从而形成鉴别流形敏感的跨模态故障诊断模型,即:

$$\begin{aligned} \max_{\alpha, \beta} \quad & \alpha^T F_{xy} \beta \\ \text{s. t.} \quad & \alpha^T R_{xx} \alpha = 1, \beta^T R_{yy} \beta = 1 \end{aligned} \quad (12)$$

3 模型的优化求解

为了求解式(12)中模型优化目标(即空间投影方向 α 和 β 的解析解,首先构建式(12)的拉格朗日乘子函数 $L(\alpha, \beta)$:

$$L(\alpha, \beta) = \alpha^T F_{xy} \beta - \frac{\lambda_1}{2} (\alpha^T R_{xx} \alpha - 1) - \frac{\lambda_2}{2} (\beta^T R_{yy} \beta - 1) \quad (13)$$

其中, $\frac{\lambda_1}{2}$ 和 $\frac{\lambda_2}{2}$ 为拉格朗日乘子。然后将 $L(\alpha, \beta)$ 对 α 求

偏导,并将 $\frac{\partial L(\alpha, \beta)}{\partial \alpha}$ 设为 0 可得:

$$\frac{\partial L(\alpha, \beta)}{\partial \alpha} = F_{xy} \beta - \lambda_1 R_{xx} \alpha = 0 \quad (14)$$

$L(\alpha, \beta)$ 对 β 求偏导,并将 $\frac{\partial L(\alpha, \beta)}{\partial \beta}$ 设为 0 可得:

$$\frac{\partial L(\alpha, \beta)}{\partial \beta} = F_{yx} \alpha - \lambda_2 R_{yy} \beta = 0 \quad (15)$$

其中, F_{yx} 是 F_{xy} 的转置矩阵,即 $F_{yx} = F_{xy}^T$ 。

式(14)和式(15)分别左乘 α^T 和 β^T ,并且根据 $\alpha^T R_{xx} \alpha = 1$ 和 $\beta^T R_{yy} \beta = 1$ 可得:

$$\alpha^T F_{xy} \beta = \lambda_1 \quad (16)$$

$$\beta^T F_{yx} \alpha = \lambda_2 \quad (17)$$

由于 $\alpha^T F_{xy} \beta = (\alpha^T F_{xy} \beta)^T = \beta^T F_{yx} \alpha$,可知 $\lambda_1 = \lambda_2$ 。令 $\lambda = \lambda_1 = \lambda_2$,式(14)和式(15)可等价表示为

$$F_{xy} \beta = \lambda R_{xx} \alpha \quad (18)$$

$$F_{yx} \alpha = \lambda R_{yy} \beta \quad (19)$$

通过对式(18)和式(19)进一步推导可得:

$$R_{xx}^{-1} F_{xy} R_{yy}^{-1} F_{yx} \alpha = \lambda^2 \alpha \quad (20)$$

通过上述等价推导,将式(12)中空间投影方向 α 的极值优化问题转化为了式(20)的特征值分解问题。空间投影方向 α 的优化解为 $R_{xx}^{-1} F_{xy} R_{yy}^{-1} F_{yx}$ 的前 d 个最大特征值对应的特征向量,即 $\{\alpha_i\}_{i=1}^d$,然后即可直接获得故障数据集 X 对应的空间投影矩阵 $A = [\alpha_1, \alpha_2, \dots, \alpha_d] \in R^{d \times d}$,利用空间投影运算^[8]可以将 X 投影到跨模态故障空间,进而获得 X 的故障特征 $A^T X$,即 $A^T X = [A^T x_1, A^T x_2, \dots, A^T x_n] \in R^{d \times n}$ 。

类似空间投影方向 α 的优化求解,利用类似的等价推导,同样能够通过计算 $R_{yy}^{-1} F_{yx} R_{xx}^{-1} F_{xy}$ 的特征值和特征向量,来获得故障数据集 Y 对应的空间投影矩阵 $B = [\beta_1, \beta_2, \dots, \beta_d] \in R^{d \times d}$,利用空间投影运算可以将 Y 投影进入跨模态故障空间,进而获得 Y 的故障特征 $B^T Y$,即 $B^T Y = [B^T y_1, B^T y_2, \dots, B^T y_n] \in R^{d \times n}$ 。借助串行融合策略^[8],即可获得故障特征 $A^T X$ 和 $B^T Y$ 的跨模态融合故障特征 $Z = A^T X + B^T Y$ 。

当获得新的跨模态故障数据 $\{x_{\text{new}}, y_{\text{new}}\}$ 时,利用空间投影矩阵 A 和 B 能够直接获得对应的跨模态融合故障特征 $Z_{\text{new}} = A^T x_{\text{new}} + B^T y_{\text{new}}$,最后利用支持向量机分类器即可获得最终的跨模态故障诊断结果。

4 实验与分析

为了验证方法的有效性,本文在德国帕德博恩轴承数据集^[18]和多模态轴承故障诊断实验平台采集的多模态轴承故障数据集上设计了针对性实验。德国帕德博恩轴承数据集的轴承故障共计四种,分别是内圈故障、外圈故障、无故障,以及内圈和外圈的混合故障,每种故障采集了振动数据和电流数据这两种模态数据,

利用故障采样和预处理方法^[19]获得了 1 000 个故障样本,每类 250 个故障样本。多模态轴承故障诊断实验平台由伺服电机、伺服驱动器、轴承等组成,该平台的轴承包含无故障、内圈故障、滚子故障、外圈故障四种类型的故障,每种故障采集了振动数据和位移数据这两种模态数据,利用同样的故障采样和预处理方法从每类故障中获得了 280 个故障样本,共计 1 120 个故障样本。在实验中本文与 LMCCA、DMCCA、LPCCA、CCA 进行了对比分析,并且在所有的实验中统一使用支持向量机分类器。

在德国帕德博恩轴承数据集的实验中从每类故障随机选择 $t(t=3,4,5,6)$ 个故障样本用于训练,剩余故障样本作为测试样本,并且该样本随机实验执行 10 次,在表 1 中给出了 10 次样本随机实验的平均准确率。CCA 是一种无监督线性故障诊断方法,没有考虑非线性故障样本间的流形结构,在表 1 中也拥有较低的诊断准确率。LPCCA 借助图理论将非线性结构嵌入故障特征,然而由于故障样本中包含大量的噪声信息和冗余信息,会造成非线性结构的失真,这种失真的结构直接嵌入故障特征将会弱化故障特征的鉴别力,从表 1 可以看出,基于非线性结构的 LPCCA 拥有比 CCA 更低的诊断准确率。LMCCA 和 DMCCA 属于监督特征学习方法,利用类标签的内在鉴别力,能够有效改善故障特征的类分离性,拥有比 CCA 和 LPCCA 更好的故障诊断准确性。本文提出的 DMSCFD 方法在相关分析理论基础上构建了鉴别流形敏感的跨模态故障诊断模型,该模型不仅能够掌握非线性故障样本中隐含的流形结构,而且能够利用鉴别信息形成鉴别流形敏感散布,有效改善了非线性结构失真的问题,在表 1 中 DMSCFD 同样获得了最高的诊断准确性。

表 1 德国帕德博恩轴承数据集上故障诊断的准确率

Table 1 Accuracy of fault diagnosis on the Germany Paderborn bearing dataset

方法	3Train	4Train	5Train	6Train
DMSCFD	91.90	96.79	98.12	99.10
LMCCA	90.25	95.96	97.91	98.84
DMCCA	84.92	92.92	94.33	95.56
LPCCA	75.34	81.59	79.49	83.72
CCA	76.61	86.64	87.15	90.80

在多模态轴承故障数据集上,每类故障中随机选择 t (t 是从 3 到 20,间隔为 1) 个故障样本用于训练,剩余故障样本作为测试样本,并且执行十次该样本随机实验,在图 1 中展示了十次样本随机实验的平均诊断准确率随每类样本数量增加的变化图。从图 1 中可以看出随着训练样本数量的增加,所有方法基本呈现递增趋势,并且在多模态轴承故障数据集上所有对比方法诊断准确率的相对高低与在德国帕德博恩轴承数据集上的实验结果基本一致,DMSCFD 方法仍然拥有最高的诊断准确率,这在一定程度上也显示了 DMSCFD 方法在不同故障诊断数据中具有较好的鲁棒性。

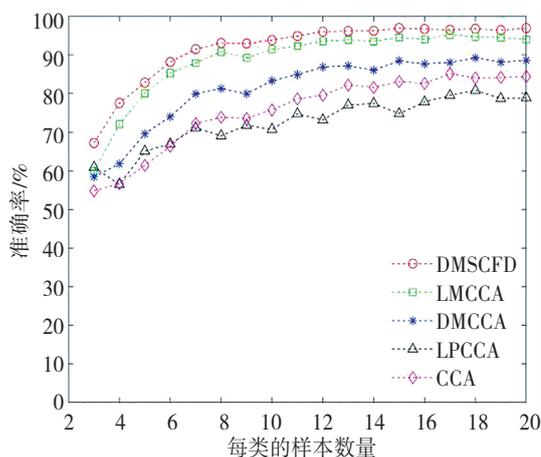


图 1 多模态轴承故障数据集上诊断准确率随每类样本数量增加的变化

Fig. 1 Changes of the diagnosis accuracy with the increase of training samples per class on the multi-modal bearing fault dataset

5 结 论

本文在相关分析理论的基础上构建了跨模态故障空间的相关系数,并通过理论推导获得了基于该相关系数的等价优化模型,进一步构建了能够更好掌握非线性故障样本间流形结构的鉴别流形敏感散布,并形成了鉴别流形敏感的跨模态故障诊断模型,该模型在最大化跨模态相关性的基础上约束了鉴别流形结构,有效增强了故障特征的类分离性,并且在理论上推导出了该模型的解析解,从而形成了 DMSCFD 方法,在两种轴承故障数据集中设计了针对性实验,实验结果显示了 DMSCFD 方法的有效性。

参考文献(References):

- [1] TANG L, TIAN H, HUANG H, et al. A survey of mechanical fault diagnosis based on audio signal analysis[J]. *Measurement*, 2023: 113294.
- [2] JIANG X, LI X, WANG Q, et al. Multi-sensor data fusion-enabled semi-supervised optimal temperature-guided PCL framework for machinery fault diagnosis [J]. *Information Fusion*, 2024, 101: 102005.
- [3] 郑近德, 陈焱, 童靳于, 等. 精细广义复合多元多尺度反向散布熵及其在滚动轴承故障诊断中的应用[J]. *中国机械工程*, 2023, 34(11): 1315—1325.
- ZHENG Jin-de, CHEN Yan, TONG Jin-yu, et al. RGCMvMRDE and its applications in rolling bearing fault diagnosis[J]. *China Mechanical Engineering*, 2023, 34 (11): 1315—1325.
- [4] BHARADIYA J P. A tutorial on principal component analysis for dimensionality reduction in machine learning [J]. *International Journal of Innovative Science and Research Technology*, 2023, 8(5): 2028—2032.
- [5] YAN R, SHANG Z, XU H, et al. Wavelet transform for rotary machine fault diagnosis: 10 years revisited [J]. *Mechanical Systems and Signal Processing*, 2023, 200: 110545.
- [6] ZHANG N, XU Y, ZHU Q X, et al. Novel regularization double preserving integrated with neighborhood locality projections for fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2023(2): 75—84.
- [7] ZHOU J, ZHANG Q, ZENG S, et al. Latent linear discriminant analysis for feature extraction via isometric structural learning [J]. *Pattern Recognition*, 2024, 149: 110218.
- [8] YANG X, LIU W, LIU W, et al. A survey on canonical correlation analysis[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 33(6): 2349—2368.
- [9] KRISHNAN A, WILLIAMS L J, MCINTOSH A R, et al. Partial least squares (PLS) methods for neuroimaging: a tutorial and review [J]. *Neuroimage*, 2011, 56 (2): 455—475.
- [10] GAO L, QI L, CHEN E, et al. Discriminative multiple canonical correlation analysis for information fusion [J]. *IEEE Transactions on Image Processing*, 2018, 27 (4): 1951—1965.
- [11] GAO L, ZHANG R, QI L, et al. The labeled multiple canonical correlation analysis for information fusion[J]. *IEEE Transactions on Multimedia*, 2019, 21(2): 375—387.
- [12] DUBEY R, SHARMA R R, UPADHYAY A, et al. Automated variational non-linear chirp mode decomposition for bearing fault diagnosis [J]. *IEEE Transactions on Industrial Informatics*, 2023(4): 91—98.
- [13] CHEN Z, CAO Y, DING S X, et al. A distributed canonical correlation analysis -based fault detection method for plant-wide process monitoring [J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(5): 2710—2720.
- [14] AMOROSI L, PADELLINI T, PUERTO J, et al. A mathematical programming approach to sparse canonical correlation analysis [J]. *Expert Systems with Applications*, 2024, 237: 121293.
- [15] ANNOYE H, BERETTA A, HEUCHENNE C. Statistical matching using kernel canonical correlation analysis and super-organizing map [J]. *Expert Systems with Applications*, 2024, 246: 123134.
- [16] WONG C M, WANG Z, WANG B, et al. Enhancing detection of multi-frequency modulated SSVEP using phase difference constrained canonical correlation analysis [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31(7): 1343—1352.
- [17] 苏树智, 张志鹏. 基于超图相关距离判别投影的轴承故障诊断方法[J]. *振动与冲击*, 2023, 42(23): 103—111.
- SU Shu-zhi, ZHANG Zhi-peng. Bearing fault diagnosis method based on HCDDP [J]. *Journal of Vibration and Shock*, 2023, 42(23): 103—111.
- [18] LI F, WANG L, WANG D, et al. An adaptive multiscale fully convolutional network for bearing fault diagnosis under noisy environments [J]. *Measurement*, 2023, 216: 112993.
- [19] SU S, ZHANG M, ZHU Y, et al. Elastic subspace diagnosis via graph-balanced discriminant projection [J]. *Measurement*, 2024, 225: 114039.