

DOI: 10.19650/j.cnki.cjsi.J1904903

基于时间迁移模型的旋转机械实时故障诊断*

沈飞¹, 陈超¹, 徐佳文¹, 严如强^{1,2}

(1 东南大学仪器科学与工程学院 南京 210096; 2 西安交通大学机械工程学院 西安 710049)

摘要:提出一种时间迁移模型,以提升旋转机械工况发生变化时的实时故障诊断性能,其由历史数据构成源领域、当前数据构成目标领域。首先,根据变工况规则确定模型的数据领域,并提取其时域特征向量构成五维空间。其次,将源和目标领域通过最大方差投影(MVP)和流形正则化投影(MRP)分别映射至二维子空间,并利用最小均值差异(MMD)准则缩短两者距离。最后,在投影空间中利用BP神经网络和支持向量机(SVM)分类器对源领域建立分类模型,并应用至目标领域,并通过筛选源领域样本以更新诊断模型。齿轮传动系统试验结果表明,时间迁移能够解决工况发生变化时的实时机械故障诊断问题,相比传统迁移成分分析(TCA)模型能提升诊断性能,故为其工程应用提供有价值的技术手段。

关键词:实时故障诊断;时间迁移;最大方差投影;流形正则化投影;最小均值差异

中图分类号: TH165+.3 TP18 **文献标识码:** A **国家标准学科分类代码:** 510.40

Time transfer model based rotating machine real-time fault diagnosis

Shen Fei¹, Chen Chao¹, Xu Jiawen¹, Yan Ruqiang^{1,2}

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China; 2. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A new time transfer model is proposed to enhance the real-time fault diagnosis performance of rotating machine when the working condition change occurs. Here the source domain is composed of historical data and the target domain is composed of current measurement data. Firstly, the data domains of the model are determined according to the varying working condition rules, and their time-domain feature vectors are extracted to construct the five-dimension spaces. Secondly, the source and target domains are mapped into a two-dimension sub-space using the maximum variance projection (MVP) and the manifold regularization projection (MRP), respectively. Meanwhile, the minimum mean difference (MMD) criterion is used to minimize the distance between source domain and target domain in two-dimension space. Finally, in the projection space, the BP neural network and support vector machine (SVM) classifiers are adopted to build the classification models of the source domain, which are applied in target domain. Also, the diagnostic model is updated through selecting the samples in source domains. Experiments on the gear drive-train system were conducted, the experiment results prove that the time transfer model can solve the real-time mechanical fault diagnosis problem when the working condition change occurs. Compared with traditional transfer component analysis (TCA) model, the proposed time transfer model can improve the diagnostic performance, the proposed model provides a valuable technical solution for the engineering application of mechanical fault diagnosis.

Keywords: real-time fault diagnosis; time transfer; maximum variance projection; manifold regularization projection; minimum mean difference

0 引 言

齿轮、轴承等旋转部件对于机械设备的长期稳定运行至关重要,但设备运行过程中可能受到不确定工况和恶劣环境的影响,使旋转部件承受不可预估的瞬时损伤,并加剧恶化趋势^[1-3]。针对不确定工况条件下的机械实时故障诊断问题,以数据为基础的模型普遍存在如下矛盾:由于变工况影响,历史数据与当前数据特性不一致,无法直接用于实时故障诊断;数据特性一致前提下,若等待当前数据采集足够,则模型响应时间过慢,无法满足实时诊断的要求。为解决故障诊断的实时性问题,相关学者普遍采用如下 3 个策略:1) 通过改变设备测量手段,将不易实时测量的机械振动量转化为易于实时测量的光电位移量^[4],声学量^[5]等信号,但后者引入了更多的环境噪声干扰,且本质上未解决变工况诊断问题;2) 通过改进现有的智能算法,加速故障诊断实施过程,如杨青等^[6]提出的基于小波和最小二乘法支持向量机 (least squares support vector machines, LSSVM) 的实时故障诊断方法采用了递推算法,节省了存储空间和运算时间,同时增强了模型适应性;又如洪涛等^[7]提出了快速支持向量机 (fast support vector machine, Fast SVM) 算法以应用于涡轮泵实时故障检测,但该类算法需要依赖对获取数据集的先验知识,即人为有针对性地删减模型无效迭代过程,通用性较弱;3) 通过改进或融合现有智能算法,减少故障诊断实施过程对数据量的依赖程度,如西安交通大学李凌均等^[8]设计的机械故障单值分类模型只需正常运行时的数据信号,无需故障数据,但该模型仅能区分健康和非健康两种状态,无法进一步判别何种故障;又如北京交通大学武哲等^[9]将布置在轴承座的关键位置的多个加速度传感器数据进行融合以缩短采集时间,提升诊断精度和实时性,但模型对所有通道数据同等看待,实际上过多地融合了无效通道的数据。

为解决旋转机械部件的实时故障诊断问题,本文在上述策略之外提出了时间迁移的新思路。迁移学习 (transfer learning, TL) 的基本原理是寻找和利用相似的源领域数据以帮助目标领域数据的建模,其在情感分类^[10]、手势识别^[11]和人脸识别^[12]等领域取得了进展。所提模型将历史振动数据视为源领域数据,将当前振动数据视为目标领域数据以实施时间迁移。其有益效果在于:1) 能够利用历史工况数据中的有用信息,克服变工况的影响;2) 仅利用少量当前时刻数据,既满足实时性诊断要求,又节省建模资源;3) 随着时间推移,源领域数据和目标领域数据能不断迭代更新,领域样本间可相互转化,模型细节将在以下各节介绍。

1 时间迁移基本问题

1.1 基本假设

迁移学习的数学描述如下^[13-15]:给定 D_s, T_s, D_t 和 T_t , 迁移学习在于利用 $\{D_s, T_s\}$ 上训练的分类器 $c_s(\cdot)$, 建立 $\{D_t, T_t\}$ 上的分类模型 $c_t(\cdot)$, 其中 D_s 为源领域、 D_t 为目标领域、 T_s 为源任务、 T_t 为目标任务, 且 $D_s \neq D_t$ 或 $T_s \neq T_t$ 。

旋转机械故障诊断中,由于转速和负载等工况的变化,使得历史振动数据特性与当前数据特性可能不一致。针对该不一致性,以“电机-齿轮传动系统”为例,时间迁移基本问题如图 1 所示,其利用大量历史数据构成 $\{D_s, T_s\}$, 少量当前时刻数据构成 $\{D_t, T_t\}$, 而后将源领域模型迁移至目标领域。随着时间的推移,将新采集的样本纳入目标领域,原目标领域样本纳入源领域,以维持诊断模型的不断更新。

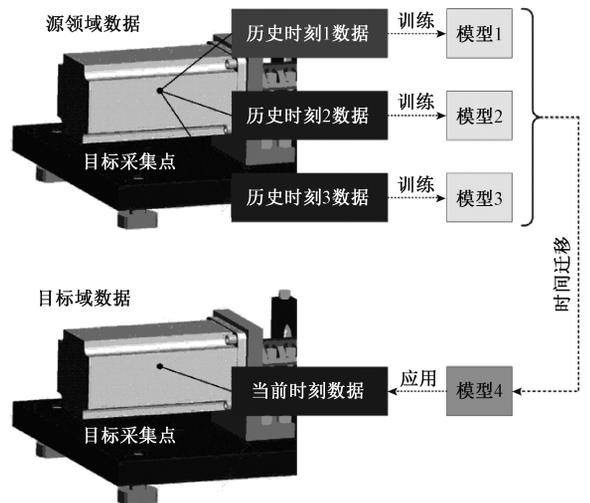


图 1 基本时间迁移问题

Fig.1 The basic time transfer problem

1.2 时间迁移目标和源领域的确定

1) 选择目标领域

时间迁移故障诊断模型中,由于故障裂纹随时间增长,且工况随时间而变,则目标数据选用当前时刻数据,假设目标通道存在一系列振动数据 $x_i = \{x_{i0}, x_{i1}, \dots, x_{ik}\}_i$, 其中 $x_{i0} \sim x_{ik}$ 为采集振动数据点, t_0 为历史最早采集时刻, t_k 为最新采集时刻, 下标 i 为通道编号, 则时间迁移模型目标领域的确定遵循如下规则:

(1) 从 x_{ik} 向前选取一定长度的数据量作为目标领域, 所选区间工况变化不超过全局的 10%;

(2) 所选区间至少包含一个设备运行周期;

(3)规则1与规则2冲突时,即包含数据点少于一个设备运行周期,则按规则2补全,且判定为劣质样本;

(4)若满足规则1时,区间包含数据点超过10个设备运行周期,则判定为优质数据样本,可直接实施非迁移训练。

2) 选择源领域

时间迁移故障诊断模型中,源领域根据目标领域而选取,其遵循如下规则:

(1)若目标领域区间为 $X' = \{x_{in}, \dots, x_{ik}\}$,从 x_{in} 向前选取一定长度的数据量作为源领域,所选区间工况变化不超过全局的30%;

(2)所选区间至少包含10~ n 个设备运行周期, n 为目标领域包含的设备周期;

(3)规则1与规则2冲突时,按规则2补全10~ n 个设备运行周期,且判定为劣质源数据样本。

1.3 时间迁移整体模型

1) 单周期旋转机械故障诊断模型

以齿轮传动系统为例,单周期旋转机械故障诊断模型如图2所示,包括如下步骤:(1)确定迁移的源领域和目标领域,即根据2.2节的规则实施领域选择;(2)时域信号特征提取,分别对源领域和目标领域时域信号实施特征提取,特征包括波形指标、偏态指标、峭度指标、裕度指标和脉冲指标;(3)迁移投影,将源领域和目标领域通过迁移投影映射至公共子空间,并使两者在子空间内的差异性最小;(4)源领域故障分类,根据源领域子空间特征与标签建立分类模型,包括支持向量机(support vector machine, SVM)^[16]和BP神经网络^[17]分类器;(5)将目标领域测试数据代入该分类器,对齿轮传动系统实时故障识别。

2) 时间迁移故障诊断模型实时更新

时间迁移故障诊断模型的实时更新流程如图3所示,其遵循如下4个规则:

(1)实时更新过程中,当目标领域采集少量当前振动数据后,即执行一次单周期旋转机械故障诊断模型,输出一次目标领域诊断结果,并更新源领域和目标领域;

(2)SVM和BP神经网络两个分类器同时对样本实施判定,若两者分类结果相同,则属于有效样本,否则属于无效样本;

(3)原有效源领域样本保留,原无效源领域样本舍弃,新有效目标领域样本加入源领域,作为下一时刻的训练源领域样本;

(4)源领域训练池满时(即刚好同时满足实时性和诊断精度)时,每加入一个新源领域样本,则剔除最早时刻源领域样本。

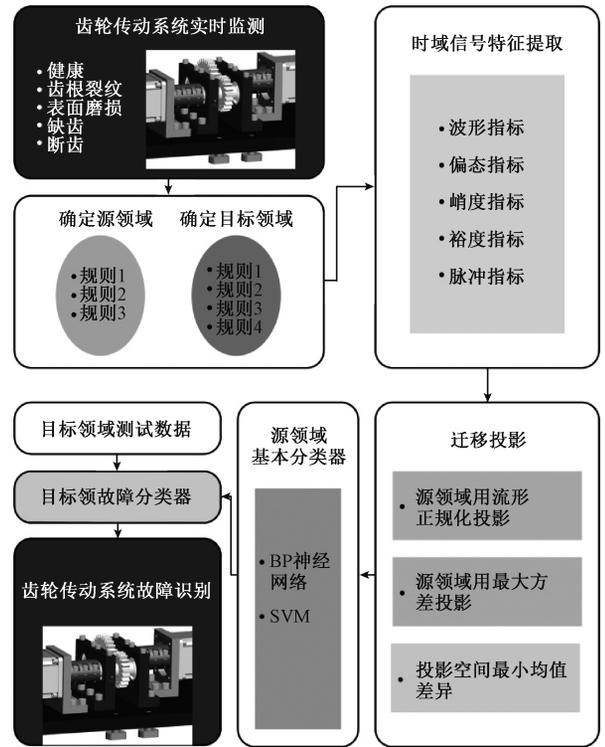


图2 单周期旋转机械故障诊断模型

Fig.2 Single cycle fault diagnosis model of rotating machine

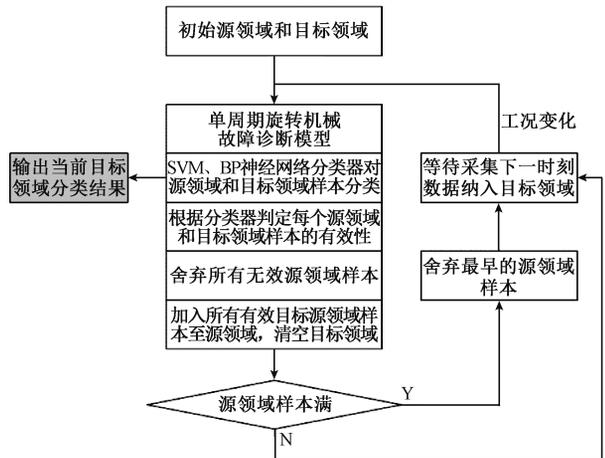


图3 故障诊断模型实时更新流程

Fig.3 Real-time update process of fault diagnosis model

2 时间迁移模型相关算法

2.1 时域信号特征提取

工况变化条件下,时域特征发生显著变化,且过多特征量将降低模型实时性能,故模型从波形指标、偏态指标、峭度指标、裕度指标和脉冲指标5个方面提取,时域特征量如表1所示。为消除各指标之间的量纲影响,对

各指标进行量化处理。

$$f'_i = \frac{f_i - \min(F)}{\max(F) - \min(F)} \quad (1)$$

式中: f_i 为第 i 个原特征量; f'_i 为第 i 个量化特征量; F 为全特征集。

表 1 提取的时域特征量

Table 1 Extracted time domain features

特征指标	数学公式	特征含义
波形指标	$S_f = X_{rms} / \bar{X} $	表征波形特性的量化值
偏态指标	$P_t = \frac{1}{N} \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}}$	表征振动幅值概率密度不对称性的量化值
峭度指标	$K_v = \beta / X_{rms}$	表征偏离正态分布程度的量化值
裕度指标	$L = X_{max} / X_r$	表征信号稳定性的量化值
脉冲指标	$I_f = X_{max} / \bar{X} $	表征信号脉冲能量量化值

注: X_{rms} 为均方根, $|\bar{X}|$ 为均值绝对值, $\beta = \frac{1}{N} \sum_{i=1}^{N-1} x_i^4$ 为信号峭度, X_{max} 为信号峰值; $X_r = \left[\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right]^2$ 为方根幅值。

2.2 时间迁移投影

1) 相关投影算法

1) 流形正则化投影 (manifold regularization projection, MRP)

其目的是使得投影后低维空间 $\mathbf{Y} = \{y_i\}$ 的邻域结构特征与投影前高维空间 $\mathbf{X} = \{x_i\}$ 的邻域结构特征一致^[18-19], 即 \mathbf{X} 空间中距离较近的样本集在 \mathbf{Y} 空间内距离仍较近, \mathbf{X} 空间中距离较远的样本在 \mathbf{Y} 空间内距离仍较远, 其目标函数为:

$$\min \frac{1}{2} \sum_{ij} [(y_i - y_j)^2 S^{ij}] \quad (2)$$

其中, S^{ij} 为低维空间样本 y_i 和 y_j 之间的距离权重。

$$S^{ij} = \begin{cases} \exp[-\|x_i - x_j\|^2 / t] & \|x_i - x_j\|^2 < \varepsilon \\ 0 & \text{others} \end{cases} \quad (3)$$

式中: x_i, x_j 为高维空间中与 y_i, y_j 相对应的样本, ε 为局部邻域半径。当 x_i 与 x_j 相邻时, S^{ij} 较大, 超过局部邻域半径范围时, 权重为 0, 据此简化式(2), 得到:

$$\min_V \text{Tr}[\mathbf{V}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{V}] \quad (4)$$

式中: \mathbf{V} 为 5×2 维投影矩阵; $\mathbf{L} = \mathbf{D} - \mathbf{S}$ 为拉普拉斯矩阵; \mathbf{D} 为对角矩阵; 其对角线值 $D^j = \sum_{i=1}^n S^{ij}$; n 为高维空间 \mathbf{X} 中样本数; $\text{Tr}[\cdot]$ 为求迹函数。

2) 最大方差投影 (maximum variance projection, MVP)

其目的是使得投影后低维空间 $\mathbf{Y} = \{y_i\}$ 的样本方差

最大, 从而提高样本分辨率^[20-21], 其目标函数为:

$$\max_V \text{Tr}[\mathbf{V}^T \mathbf{X} \mathbf{X}^T \mathbf{V}] \quad (5)$$

其中, \mathbf{V} 为 5×2 维投影矩阵; $\text{Tr}[\cdot]$ 为求迹函数。

2) 构建投影模型

时间迁移模型中, 源领域和目标领域主要差异在于由变工况导致的信号特性边缘分布^[22-23], 故前者用流形正则化投影以维持子空间数据结构不变, 后者用最大方差投影以增大子空间数据分辨率, 且用最小均值差异 (minimum mean difference, MMD) 以拉近两者在子空间内距离, 投影模型流程如图 4 所示, 其目标函数如下:

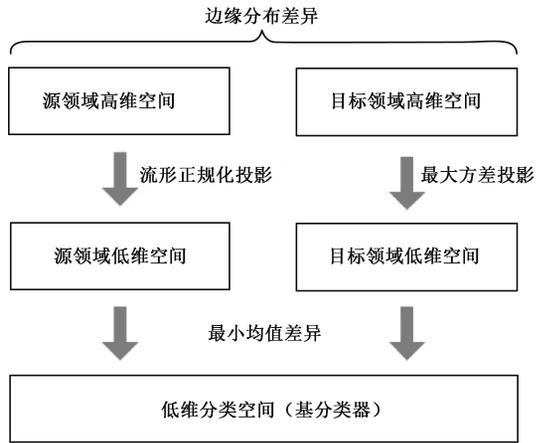


图 4 时间迁移投影模型流程

Fig.4 The flow chart of the time transfer-based projection model

$$\max_V \frac{\text{Tr}[\mathbf{V}^T \mathbf{X}'^t (\mathbf{X}'^t)^T \mathbf{V}]}{\lambda_1 \text{Tr}[\mathbf{V}^T \mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T \mathbf{V}] + \lambda_2 \text{Tr}[\mathbf{V}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{V}]} \quad (6)$$

其中, 分子项 $\text{Tr}[\mathbf{V}^T \mathbf{X}'^t (\mathbf{X}'^t)^T \mathbf{V}]$ 表示将 \mathbf{X}'^t 通过最大方差投影至低维空间, 分母项 $\lambda_1 \text{Tr}[\mathbf{V}^T \mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T \mathbf{V}]$ 表示将 \mathbf{X}^s 通过流形正则化投影至低维空间, 分母项 $\lambda_2 \text{Tr}[\mathbf{V}^T \mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{V}]$ 项表示在映射子空间内最小均值差异; λ_1, λ_2 分别表示投影权重, $\mathbf{X} = [\mathbf{X}^s, \mathbf{X}^t]$, 上标 s 和 t 分别代表源领域和目标领域, \mathbf{M} 为均值差异矩阵, 其元素定义如下:

$$M_{ij} = \begin{cases} 1 / (n_s)^2 & x_i, x_j \in \mathbf{X}^s \\ 1 / (n_t)^2 & x_i, x_j \in \mathbf{X}^t \\ -1 / n_s n_t & \text{others} \end{cases} \quad (7)$$

为求投影矩阵 \mathbf{V} , 式(6)中的最大化问题转化为:

$$\max_V \text{Tr}[\mathbf{V}^T \mathbf{X}'^t (\mathbf{X}'^t)^T \mathbf{V}]$$

$$\text{s.t. } \text{Tr}\{\mathbf{V}^T [\lambda_1 \mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \lambda_2 \mathbf{X} \mathbf{M} \mathbf{X}^T] \mathbf{V}\} = \bar{\omega} \quad (8)$$

引入拉格朗日乘子 τ , 得:

$$J(\mathbf{V}, \tau) = \text{Tr}[\mathbf{V}^T \mathbf{X}'^t (\mathbf{X}'^t)^T \mathbf{V}] - \tau \text{Tr}\{\mathbf{V}^T [\lambda_1 \mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \lambda_2 \mathbf{X} \mathbf{M} \mathbf{X}^T] \mathbf{V}\} + \bar{\omega} \quad (9)$$

令 $J(\mathbf{V}, \tau)$ 对 \mathbf{V} 的偏导数为 0, 得:

$$X^t (X^t)^T V - \{\tau [\lambda_1 X^t L^s (X^s)^T + \lambda_2 X M X^T] V\} = 0 \quad (10)$$

即:

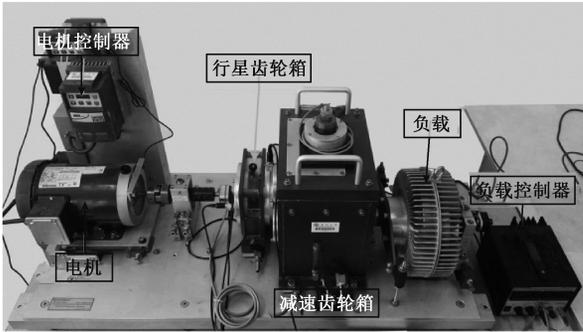
$$[\lambda_1 X^t L^s (X^s)^T + \lambda_2 X M X^T]^{-1} [X^t (X^t)^T] V = \tau V \quad (11)$$

据此求解投影矩阵 V 即可。

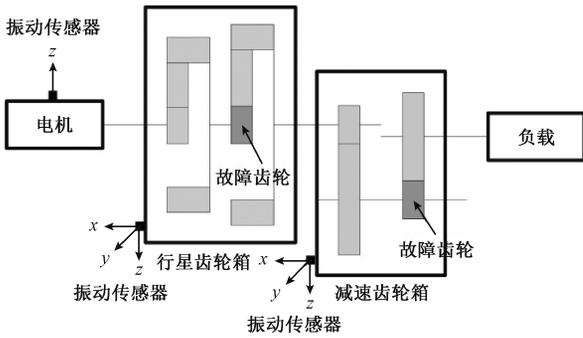
3 实验研究与性能分析

3.1 实验系统与数据集

时间迁移试验所用数据来自 Spectra Quest 振动试验系统,如图 5 所示,其由电机控制器,驱动电机,行星齿轮箱,减速齿轮箱和负载控制器组成。7 个通道分别采集行星齿轮箱,减速齿轮箱的 xyz 三轴和电机 z 轴方向上的振动。试验中,故障发生于减速齿轮箱和行星齿轮箱的次级传动齿轮,故障类型包括:健康 (C1)、齿根裂纹 (C2)、表面磨损 (C3)、缺齿 (C4) 和断齿 (C5) 5 类,其中 C3 又包含轻度磨损 (C3-1)、中度磨损 (C3-2) 和重度磨损 (C3-3) 3 类。



(a) The photo of the system



(b) The structure of the system

图 5 Spectra Quest 振动试验系统

Fig.5 Spectra Quest vibration test system

3.2 领域选取试验及性能分析

领域选取的试验条件如下:1)故障类型:C1;2)工况

条件:变转速曲线如图 6 所示;3)采集通道:行星齿轮箱 xyz 和减速齿轮箱 xyz 。减速齿轮箱 x 方向的领域选取结果如图 7 所示。

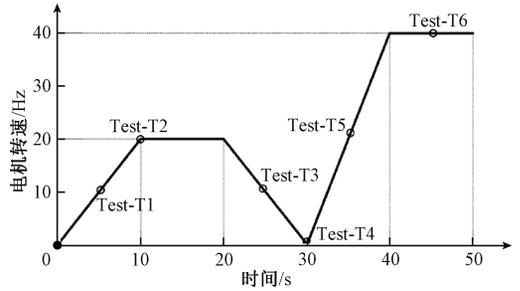


图 6 变转速曲线

Fig.6 Variable rotation speed curve

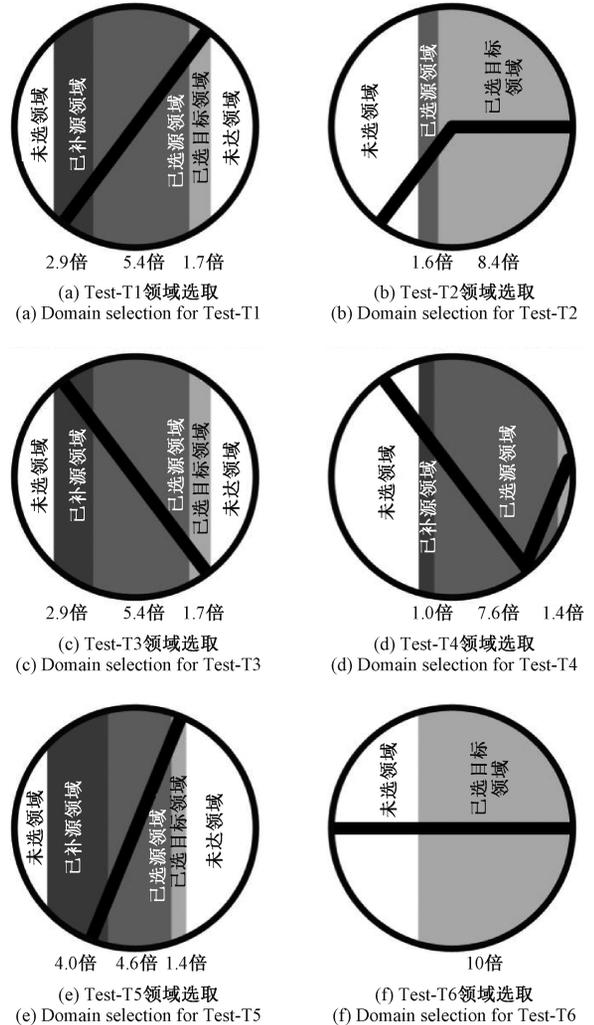


图 7 减速齿轮箱 x 方向领域选取

Fig.7 The domain selection in the x direction of the speed reducing gear box

以 Test-T1 为例,其目标领域、已选源领域和已补源

领域的数据长度分别 1.7 倍、5.4 倍和 2.9 倍的设备运行周期,则其样本质量 Q 计算如下:

$$Q = R_1 + \gamma_2 R_2 + \gamma_3 R_3 \quad (12)$$

式中: R_1 、 R_2 和 R_3 分别为目标领域、已选源领域和已补源领域占总数据量的比值; γ_2 和 γ_3 分别为后两者相对于目标领域的质量权重。据此计算各采集通道的 6 个试验点 Q 值,如表 2 所示。由图 7 和表 2 可得到如下结论:1) 比较单通道领域,其质量顺序为:Test-T6 > Test-T2 > Test-T4 > Test-T1 = Test-T3 > Test-T5,说明时间迁移领域选取过程中,目标领域工况变化越小,可选样本数据量越充足,领域样本质量越高。工况不发生变化时(如 Test-T6),所选样本均为目标领域样本,此时直接使用分类器分类;2) 比较减速齿轮箱和行星齿轮箱,变工况条件下,前者数据质量($\bar{Q} = 8.31$) 优于后者($\bar{Q} = 8.02$),原因是时域变化对重量小、结构复杂的行星齿轮箱振动特性影响更大;3) 比较轴向(x) 和垂直于轴向(y & z),变工况条件下,前者数据质量($\bar{Q} = 8.30$) 优于后者($\bar{Q} = 8.02$),因此时频变化对轴向振动影响更小。

表 2 实时试验点的 Q 值($\gamma_2 = 0.8, \gamma_3 = 0.6$)

Table 2 The Q values in real time test points($\gamma_2 = 0.8, \gamma_3 = 0.6$)

试验	Test-T1	Test-T2	Test-T3	Test-T4	Test-T5	Test-T6
行 x	7.39	9.22	7.39	7.70	7.12	10
行 y	7.19	8.96	7.19	7.48	6.93	10
行 z	7.19	8.96	7.19	7.48	6.93	10
减 x	7.76	9.68	7.76	8.08	7.48	10
减 y	7.32	9.13	7.32	7.62	7.06	10
减 z	7.32	9.13	7.32	7.62	7.06	10

3.3 时域信号特征提取试验及性能分析

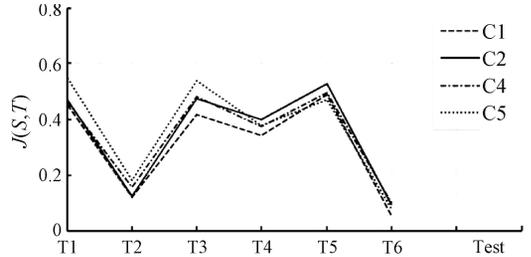
特征提取试验条件如下:1) 特征提取对象及样本比例:根据图 7 (Test-T1 ~ Test-T6); 2) 故障类别: C1 ~ C5; 3) 采集通道: 减速齿轮箱 x 轴; 4) 特征向量样本数: 一个设备运行周期 30 条样本,共 300 条。试验利用杰卡德距离来计算源领域和目标领域的样本差异性,定义如下:

$$J(S, T) = \frac{|S \cup T| - |S \cap T|}{|S \cup T|} \quad (13)$$

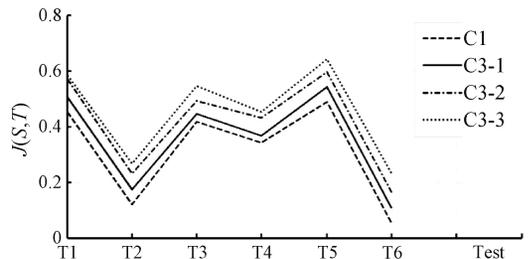
式中: S 为源领域样本空间; T 为目标领域样本空间; $|S \cap T|$ 代表两空间中交集元素的个数(即任意来自 S 空间和 T 空间两特征向量余弦距离小于 30%); $|S \cup T|$ 代表两空间中并集元素的个数(即样本总数); $0 \leq J(S, T) \leq 1$, $J(S, T)$ 值越大,两者差异性越明显。

据此,不同故障类型下的 $J(S, T)$ 如图 8 所示,可以得到如下结论:1) 当故障类型为健康(C1)时,源领域与目标领域样本差异度最小,且 $J(S, T)$ 与试验点 Q 值呈

近似反比,相关系数-0.993 2; 2) 加入频域故障的特征样本,其差异度改变不明显(8.59%),加入时域故障的特征样本,其差异性随故障严重程度增大而增大,相比健康齿轮,轻度、中度、重度磨损的差异性分别达 11.78%、25.74% 和 28.68%,因此实施时间迁移算法存在必要。



(a) 频域故障特性样本差异度
(a) The difference for frequency domain fault feature samples



(b) 时域故障特性样本差异度
(b) The difference for time domain fault feature samples

图 8 不同故障类型下的 $J(S, T)$

Fig.8 $J(S, T)$ under different kinds of fault types

3.4 迁移故障诊断试验及性能分析

故障诊断试验条件如下:1) 实施对象及样本比例:根据图 7 (Test-T1 ~ Test-T6); 2) 故障类别: 第 I 组: C1、C2、C3-2、C4、C5, 第 II 组: C1、C3-1、C3-2、C3-3; 3) 采集通道: 减速齿轮箱 x 轴; 4) 特征向量样本数: 一个设备运行周期 30 条样本,共 300 条。

以 Test-T1 和 Test-T2 为例, C1、C2、C4 故障类别的投影空间样本分布图分别如图 9 所示,其中图 9(a) 和 (c) 分别给出两者经流形正则化/最大方差投影后的样本分布图,图 9(b) 和 (d) 分别给出两者经最小均值差异后的样本分布图,并列其投影矩阵 V 。对比 Test-T1 的流形正则化/最大方差投影子空间样本和引入最小均值差异投影子空间样本,前者源和目标领域同一故障类别距离(如源领域 C1 类和目标领域 C1 类)大于目标领域不同故障类别间距离(如目标领域 C1 类和目标领域 C2 类),此时子空间内分类器易发生误诊断,而后者源和目标领域同一故障类别距离较小,源和目标领域可采用同一类别划分平面,能够提升诊断效果。对比 Test-T1 和 Test-T2 试验投影子空间样本分布图,前者源领域和目标领域中心距离大于后者,故源领域的选取应尽量接近目标领域特性,高质量的样本其投影效果更好。

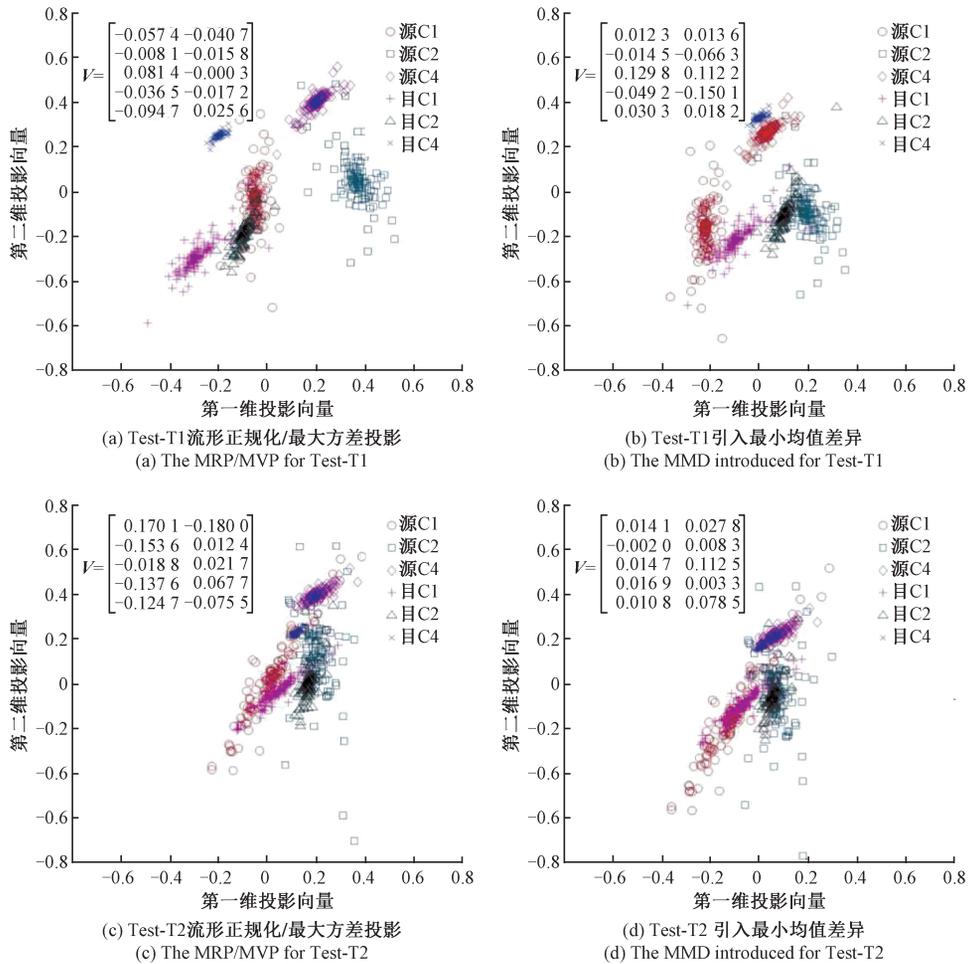


图9 投影子空间样本分布图

Fig.9 Sample distribution in projection sub-spaces

同时,时间迁移中分类器的第 I 组和第 II 组故障类别的全局诊断精度分别如表 3 和 4 所示,两组中 Test-T1 试验的故障诊断细节分别如表 5 和 6 所示。对比 Test-T1 至 Test-T6,目标领域样本数据量所占比例越高,其平均分类精度越高,如 Test-T6 中不含源数据样本,其第 I 组和第 II 组分类精度达 98.67%和 97.33%,而 Test-T5 中源和目标领域数据样本比例为 8.6 : 1.4,其第 I 组和第 II 组分类精度仅为 94.75%和 92.26%,较前者低 4.5%。对比第 I 组(故障类别识别)和第 II 组(故障严重性识别)试验,可见时间迁移模型应用于前者的效果优于后者,其原因是迁移投影思想在削弱源和目标领域差异的同时,一定程度上也削弱了同一故障类型中不同故障严重程度间的差异(如 C3-1 和 C3-2, C3-2 和 C3-3),使其误判增加,但总体精度仍较高。观察表 5 和 6 中的误分类细节,表 5 误判样本较为分散(如 C5 故障误判现象同时发生于 C1、C3-2 和 C4 类别),表 6 误判样本较为集中(如 C3-3 故障误判现象均发生于 C3-2 类别),即说明了迁移投影在缩短源和目标领域差异的同时可能会缩短特定故障类

型的差异。

表 3 时间迁移第 I 组故障类别诊断精度

Table 3 The diagnostic accuracies for the fault classes in group I with time transfer classifier

试验	目标样本	诊断精度/%					平均
		C1	C2	C3-2	C4	C5	
Test-T1	51 * 5	96.08	98.04	94.12	94.12	92.16	94.90
Test-T2	252 * 5	99.21	98.41	96.82	97.22	98.41	98.01
Test-T3	51 * 5	92.16	94.12	98.04	94.12	96.08	94.90
Test-T4	42 * 5	88.10	92.85	95.23	90.47	90.47	91.42
Test-T5	42 * 5	97.61	92.85	95.23	92.85	95.23	94.75
Test-T6	300 * 5	99.00	99.33	98.33	98.00	98.67	98.67

最后,为观察时间迁移模型的性能提升能力,模型框架中的 BP 神经网络和 SVM 分类器分别用迁移成分分析(transfer component analysis, TCA)^[24],最小二乘支持向量机(least squares support vector machines, LSSVM)^[25],

表 4 时间迁移第 II 组故障类别诊断精度

Table 4 The diagnostic accuracies for the fault classes in group II with time transfer classifier

试验	目标 样本	诊断精度/%				
		C1	C3-1	C3-2	C3-3	平均
Test-T1	51 * 4	96.08	92.16	90.19	92.16	92.65
Test-T2	252 * 4	98.41	97.22	95.63	96.83	97.02
Test-T3	51 * 4	98.03	94.12	92.16	90.19	93.63
Test-T4	42 * 4	90.47	95.23	88.10	92.85	91.66
Test-T5	42 * 4	97.61	88.10	88.10	95.23	92.26
Test-T6	300 * 4	98.33	98.67	96.66	95.66	97.33

表 5 第 I 组故障类别 Test-T1 诊断精度细节

Table 5 Diagnostic accuracy details for fault class Test-T1 in group I

类别	故障				
	C1	C2	C3-2	C4	C5
R1	49		3		1
R2		50		1	
R3	1		48		1
R4	1	1		48	2
R5				2	47
诊断精度/%	96.08	98.04	94.12	94.12	92.16

表 6 第 II 组故障类别 Test-T1 诊断精度细节

Table 6 Diagnostic accuracy details for fault class Test-T1 in group II

类别	故障			
	C1	C3-1	C3-2	C3-3
R1	49			
R2	2	47	5	
R3		4	46	4
R4				47
诊断精度/%	96.08	92.16	90.19	92.16

域适应机(domain adaptation machine, DAM)^[26]和域选择机(domain selection machine, DSM)^[27]代替,其中试验条件如下:1)实施对象及样本比例:Test-T1(8.3:1.7);2)故障类别:C1、C2、C3-2、C4、C5;3)采集通道:减速齿轮箱 x 轴;4)特征向量样本数:一个设备运行周期 30 条样本,共 300 条,不同模型的故障诊断精度比较结果如表 7 所示。可以看出,虽然 4 种不同分类器内核的诊断精度差异较小,但在 BP/SVM 内核下,迁移投影性能提升为 14.68% 和 8.14%,大于其他所选基分类器的提升效果,

同时 BP/SVM 核迁移投影算法耗时最短,有助于提升算法执行速度,在考虑实时故障诊断前提下,所提方法具有较高的性价比。

表 7 不同模型的故障诊断精度比较

Table 7 The fault diagnosis accuracy comparison for different models

模型	诊断精度%	模型	诊断精度%	性能提升%
迁移投影(BP/SVM 核)	94.90	BP	80.22	14.68
		SVM	86.76	8.14
迁移投影(TCA 核)	95.17	TCA	93.18	1.99
迁移投影(DAM 核)	94.98	DAM	92.30	2.68
迁移投影(核 DSM)	95.03	DSM	93.45	1.58

3.5 迁移模型实时性评估试验

迁移模型实时性评估试验条件如下:1)周期处理数据长度:10 倍周期(9 倍源领域+1 倍的目标领域);2)周期样本数量:300 条(270 条源领域样本+30 条目标领域样本);3)处理器与执行配置:Inter(R) Core(TM) i5-4210U CPU @ 1.70 ~ 2.40 GHz,内存 4 G, MATLAB R2018b,得到模型算法平均执行时间如表 8 所示,从而可得完整执行单时间迁移模型周期的平均耗时为 1.16 s,1 min 可执行 52 次周期,基本满足实时诊断。

表 8 模型平均执行时间

Table 8 Average execution time of the models

步骤	执行过程	执行时间
I	目标领域选取	<0.001 s
II	源领域选取	<0.001 s
III	特征提取	300 样本平均 0.134 s
IV	迁移投影	高质量源领域样本(以 Test-T6 为例)迭代 12 次,平均 0.180 s;低质量源领域样本(以 Test-T5 为例)迭代 36 次,平均 0.431 s;
		高质量源领域样本(以 Test-T6 为例)迭代 22 次,平均 0.426 s;低质量源领域样本(以 Test-T5 为例)迭代 26 次,平均 0.519 s;
V	BP/SVM 故障诊断决策输出	
VI	准备下一执行周期	平均 0.248 s

同时,利用所提迁移模型对图 6 所示的 50 s 采集周期变转速曲线实时诊断,其中时间迁移模型执行 44 次,变转速实时诊断精度曲线如图 10 所示。为便于比较,图 10 亦绘制了 SVM 的非迁移诊断算法精度曲线,其执行 58 次,迁移成分分析(TCA)迁移诊断算法精度曲线,其执行 9 次。图 10 中:对比两个迁移模型和 SVM,当源

领域和目标领域差距较大时(30~40 s),前者仍能保持较高的诊断精度,而后者精度急剧下降至约60%,故证明了迁移理论的优势;对比TCA和时间迁移算法,虽然两者诊断精度不相伯仲,但由于前者矩阵维数过高,且所需目标领域数据量约为所提方法的5倍,使得单次算法执行周期过长,50 s内仅能执行9个周期,丢帧现象严重,当设备工况发生急剧变化时,TCA无法实时跟踪,故证明了时间迁移投影模型的优势。

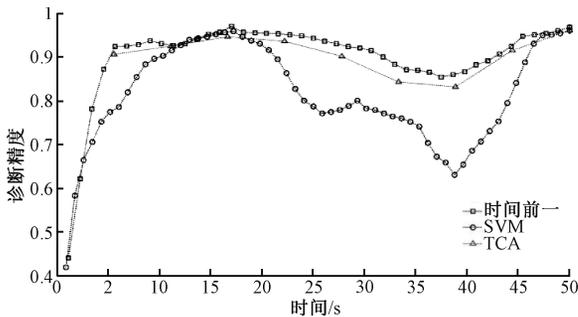


图10 变转速曲线诊断精度

Fig.10 The diagnostic accuracies of variable rotation speed curves

4 结 论

本文提出一种时间迁移模型,以提升旋转机械工况发生变化时的实时故障诊断性能。其中,领域选取试验表明,目标领域工况变化越小,可选样本数据量越充足,领域样本质量越高。时域特征提取试验表明,当故障类型为健康时,源领域与目标领域样本差异度最小,若加入频域故障的特征样本,其差异度改变不明显,若加入时域故障的特征样本,其差异性随故障严重程度增大而增大。时间迁移故障诊断试验表明,迁移投影在缩短源和目标领域差异的同时可能会缩短特定故障类型的差异,根据不同样本质量其综合诊断精度在92.26%~98.67%之间。相比SVM,该模型能提升诊断精度,相比TCA,该模型能提升故障诊断的实时性,相比其它复杂分类器内核,在不影响诊断精度前提下执行速度更快。总体而言,时间迁移能很好地解决旋转故障诊断的实时性问题,克服实时诊断中当前数据量不足的问题,为其工程应用提供有价值的技术手段。

参考文献

[1] 温江涛, 闫常弘, 孙洁娣, 等. 基于压缩采集与深度学习的轴承故障诊断方法[J]. 仪器仪表学报, 2018(1):171-179.

WEN J T, YAN CH H, SUN J T, et al. Bearing fault diagnosis method based on compression acquisition and

deep learning [J]. Chinese Journal of Scientific Instrument, 2018(1):171-179.

[2] CUI L, WANG J, LEE S. Matching pursuit of an adaptive impulse dictionary for bearing fault diagnosis[J]. Journal of Sound and Vibration, 2014, 333(10):2840-2862.

[3] CUI L, HUANG J, ZHANG F, et al. HVSRMS localization formula and localization law: Localization diagnosis of a ball bearing outer ring fault [J]. Mechanical Systems and Signal Processing, 2019, 120: 608-629.

[4] 于海洋, 赵新杰, 张龙. 频率辅助信号结合EMD的旋转机械故障诊断[J]. 半导体光电, 2017, 38(2): 271-277.

YU H X, ZHAO X J, ZHANG L. Rotating machinery fault diagnosis using frequency auxiliary signal and EMD [J]. Semiconductor Optoelectronics, 2017, 38(2): 271-277.

[5] 鲁文波, 蒋伟康, 潘思伟, 等. 基于近场声全息声像图纹理特征的机械故障诊断方法[J]. 振动工程学报, 2013, 26(4):617-623.

LU W B, JIANG W K, PAN S W, et al. Mechanical fault diagnosis based on texture features of acoustic images by near-field acoustic holography [J]. Journal of Vibration Engineering, 2013, 26(4):617-623.

[6] 杨青, 田枫, 王大志, 等. 基于提升小波和递推LSSVM的实时故障诊断方法[J]. 仪器仪表学报, 2011, 32(3):596-602.

YANG Q, TIAN F, WANG D ZH, et al. Real-time fault diagnosis approach based on lifting wavelet and recursive LSSVM [J]. Chinese Journal of Scientific Instrument, 2011, 32(3):596-602.

[7] 洪涛, 黄志奇, 杨畅. 涡轮泵实时故障检测的快速支持向量机算法[J]. 仪器仪表学报, 2012, 33(8): 1786-1792.

HONG T, HUANG ZH Q, YANG CH. Fast support vector machine algorithm for turbopump real-time fault detection[J]. Chinese Journal of Scientific Instrument, 2012, 33(8):1786-1792.

[8] 李凌均, 张周锁, 何正嘉. 基于支持向量数据描述的机械故障诊断研究[J]. 西安交通大学学报, 2003, 37(9):910-913.

LI L J, ZHANG ZH S, HE ZH J. Research of mechanical system fault diagnosis based on support vector data

- description [J]. *Journal of Xi'an Jiaotong University*, 2003, 37(9):910-913.
- [9] 武哲, 杨绍普, 刘永强. 基于多元经验模态分解的旋转机械早期故障诊断方法[J]. *仪器仪表学报*, 2016, 37(2):241-248.
- WU Z, YANG SH P, LIU Y Q, Rotating machinery early fault diagnosis method based on multivariate empirical mode decomposition [J], *Chinese Journal of Scientific Instrument*, 2016, 37(2):241-248.
- [10] PAN S J, QIANG Y. A survey on transfer learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10):1345-1359.
- [11] GOUSSIES N A, UBALDE S, MEJAIL M. Transfer learning decision forests for gesture recognition [J]. *Journal of Machine Learning Research*, 2017, 15(1):3667-3690.
- [12] 余化鹏, 张朋, 朱进. 基于深度迁移学习的人脸识别方法研究[J]. *成都大学学报(自然科学版)*, 2017, 36(2):151-156.
- YU H P, ZHANG P, ZHU J. Study on face recognition method based on deep transfer learning [J]. *Journal of Chengdu University (Natural Science)*, 2017, 36(2):151-156.
- [13] DUAN L X, TSANG I W, XU D. Domain transfer multiple kernel learning [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(3):465-479.
- [14] LU W, LIANG B, CHENG Y, et al. Deep model based domain adaptation for fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3):2296-2305.
- [15] 谢骏遥, 王金江, 赵锐, 等. 迁移因子分析在齿轮箱变工况故障诊断中的应用[J]. *电子测量与仪器学报*, 2016, 30(4):534-541.
- XIE J Y, WANG J J, ZHAO R, et al. Application of transfer factor analysis in gearbox fault diagnosis under various working condition [J]. *Journal of Electronic Measurement and Instrumentation*, 2016, 30(4):534-541.
- [16] CHERKASSKY V, MA Y. Practical selection of SVM parameters and noise estimation for SVM regression. [J]. *Neural Networks*, 2004, 17(1):113-126.
- [17] 孙文珺, 邵思羽, 严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. *机械工程学报*, 2016, 52(9):65-71.
- SUN W J, SHAO S Y, YAN R Q, Induction motor fault diagnosis based on deep neural network of sparse auto-encoder [J]. *Journal of Mechanical Engineering*, 2016, 52(9):65-71.
- [18] 陈伟杰, 邵元海, 李春娜, 等. 基于流形正则化的半监督投影双子支持向量机[J]. *模式识别与人工智能*, 2016, 29(2):97-107.
- CHEN W J, SHAO Y H, LI CH N, et al. Semi-supervised projection twin support vector machine via manifold regularization [J]. *Pattern Recognition and Artificial Intelligence*, 2016, 29(2):97-107.
- [19] 王萍, 王迪, 冯伟. 基于流形正则化的在线半监督极限学习机[J]. *上海交通大学学报*, 2015, 49(8):1153-1158.
- WANG P, WANG D, FENG W. Online semi-supervised extreme learning machine based on manifold regularization [J]. *Journal of Shanghai Jiaotong University*, 2015, 49(8):1153-1158.
- [20] 朱燕, 陈熙. 核最大方差差分嵌入在生物特征提取中的应用[J]. *计算机工程与应用*, 2014, 50(8):183-187.
- ZHU Y, CHEN X. Kernel maximum variance difference based embedding approach with application to biometric feature extraction [J], *Computer Engineering and Applications*, 2014, 50(8):183-187.
- [21] 谢英红, 吴成东. 基于投影群和协方差流形双重建模的目标跟踪[J]. *仪器仪表学报*, 2014, 35(2):374-379.
- XIE Y H, WU CH D. Object tracking with dual modeling based on projection group and covariance manifold [J]. *Chinese Journal of Scientific Instrument*, 2014, 35(2):374-379.
- [22] EYIÖKUR F I, YAMAN D, EKENEL H K. Domain adaptation for ear recognition using deep convolutional neural networks [J]. *Iet Biometrics*, 2018, 7(3):199-206.
- [23] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis [J]. *IEEE Transactions on Neural Networks*, 2011, 22(2):199-210.
- [24] MATASCI G, VOLPI M, KANEVSKI M, et al. Semisupervised transfer component analysis for domain adaptation in remote sensing image classification [J].

IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(7):3550-3564.

- [25] DENG W, YAO R, ZHAO H, et al. A novel intelligent diagnosis method using optimal LS-SVM with improved PSO algorithm [J]. Soft Computing, 2017, 23(7): 2445-2462.
- [26] DUAN L, XU D, TSANG I W. Domain adaptation from multiple sources: a domain-dependent regularization approach[J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(3):504-518.
- [27] DUAN L, XU D, CHANG S F. Exploiting web images for event recognition in consumer videos: A multiple source domain adaptation approach [C]. Computer Vision and Pattern Recognition (CVPR), IEEE, 2012.

作者简介



严如强(通信作者),1997年和2002年分别于中国科学技术大学获得学士学位和硕士学位,2007年于美国马萨诸塞大学阿默斯特分校获得博士学位,现为西安交通大学教授、博士生导师,主要研究方向为机械系统状态监测与故障诊断,信号处理,无线传感网络。

E-mail: ruqiang@ seu.edu.cn

Yan Ruqiang (Corresponding author) received his B. Sc. and M.Eng. degrees both from University of Science and Technology of China in 1997 and 2002, respectively, and received his Ph. D. degree in 2007 from University of Massachusetts, Amherst. Now, he is a professor and Ph. D. supervisor in Xi'an Jiaotong University. His main research interests include mechanical system condition monitoring and fault diagnosis, signal processing, and wireless sensor networks.



沈飞,2014年和2016年于东南大学获得学士学位和硕士学位,现为东南大学仪器科学与工程学院博士研究生,主要研究方向为机械故障诊断。

E-mail: sfseu0311@163.com

Shen Fei received his B. Sc. and M. Sc. degrees both from Southeast University in 2014 and 2016, respectively. Now, he is pursuing his Ph. D. degree in School of Instrument Science and Engineering, Southeast University. His main research interests include mechanical fault diagnosis.