

# 数据领域选择与空间迁移在齿轮箱故障诊断中的应用

沈 飞<sup>1</sup>, 陈 超<sup>1</sup>, 徐佳文<sup>1</sup>, 严如强<sup>1,2</sup>

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

**摘要:** 提出一种空间迁移新思路, 以提升齿轮箱故障诊断性能, 其由辅助振动数据构成源领域、目标振动数据构成目标领域, 迁移学习(Transfer learning, TL)将前者分类模型应用至后者, 以克服短时间内目标振动数据不足的问题。根据频带选择独立成分分析(Band selective independent component analysis, BS-ICA)规则选择迁移模型的数据领域, 并提取其时域特征构成五维空间。利用均衡密度投影(Equilibrium density projection, MDP)将源领域和目标领域同时映射至二维投影空间, 并最小化领域均值差异以拉近两者在低维空间内的距离。在投影空间内, 利用逻辑回归(Logistic regression, LR)和支持向量机(Support vector machine, SVM)基分类器对映射样本实施分类。同时通过剔除低质量源领域样本, 加入新采集样本以维持模型更新。利用 Spectra Quest 齿轮传动系统, 对比迁移成分分析(Transfer composition analysis, TCA)、领域适应机(Domain selection machine, DSM)等传统 TL 模型, 所提方法不但能提高工况快速变化时的诊断精度, 同时能加快诊断速度, 具有实际的工程应用价值。

**关键词:** 故障诊断; 齿轮箱; 空间迁移; 频带选择独立成分分析; 均衡密度投影

**中图分类号:** TH165<sup>+</sup>.3; TH132.41 **文献标志码:** A **文章编号:** 1004-4523(2021)02-0389-13

**DOI:** 10.16385/j.cnki.issn.1004-4523.2021.02.020

## 引 言

当前针对复杂齿轮传动系统的故障诊断模型普遍存在如下两个局限性<sup>[1-3]</sup>: 1) 由于机械设备功能和结构的互不相同, 其所包含的齿轮部件也千差万别, 不同齿轮组装方式、齿轮结构及传动轴长度等因素均可能导致齿轮传动系统各部件的输出特性(如振动和噪声)存在差异, 因此某一局部建立的故障诊断模型无法直接应用至另一局部, 可移植性较差; 2) 由于齿轮箱工况变化等原因使得部分数据无法利用, 从而导致齿轮故障诊断模型难以满足实时性, 其在所需建模数据量多、执行周期长的齿轮箱故障诊断策略中尤为明显。

为提高齿轮故障诊断模型可移植性, 相关学者提出了一些解决方案: 1) 将齿轮箱传动系统模块化、功能分割和重组, 如张玉<sup>[4]</sup>、王文利等<sup>[5]</sup>对齿轮箱各主要部件(齿轮、轴承、轴和箱体)的故障振动形式和信号特征分别预先建档, 诊断应用时再重组各子模块, 以适应不同型号齿轮箱的状态监测与故障诊断, 但该类方法以用户熟悉箱体内部结构为前提; 2) 自适应调整算法参数以提升齿轮箱故障诊断的可扩展

性, 如自适应总体平均经验模式分解模型<sup>[6]</sup>和自适应优化品质因子的共振稀疏分解模型<sup>[7]</sup>, 尤其是时培明等<sup>[8]</sup>设计的基于深度学习特征提取和粒子群支持向量机的中速轴大齿轮故障识别模型, 其能够针对不同振动信号自适应提取频谱特征, 但该类方法普遍复杂度较高; 3) 诊断过程中辅助推理技术对复杂齿轮传统结构实施判定, 如梅杰等<sup>[9]</sup>将专家系统与神经网络结合, 构建专家系统的知识库和推理机, 能有效实现多级行星齿轮的故障诊断。

为提高齿轮故障诊断模型实时性, 相关学者也提出了一些解决方案: 1) 通过改变设备测量手段, 将不易实时输入测量系统的振动信号转化为易于实时测量的瞬态声信号<sup>[10]</sup>, 但后者加入了更多的环境噪声干扰; 2) 通过改进现有的智能诊断算法, 加速算法实施过程, 如杨青等<sup>[11]</sup>提出的最小二乘支持向量机(Least square support vector machine, LSSVM)实时故障诊断模型采用了递推算法, 节省了存储空间和运算时间, 并增强了模型适应性; 又如张少敏等<sup>[12]</sup>结合 Storm 实时流数据处理和 Spark 内存批处理技术为大数据下的在线风电机组实时故障诊断提供了可能, 但该类算法普遍需要依赖数据集的先验知识; 3) 利用传感器数据融合或数据通道分解等方法减少

对齿轮数据量的依赖程度,如毛瑞卿等<sup>[13]</sup>采用多传感器决策层融合技术,构造D-S证据理论识别框架,建立基于统计自组织映射神经网络的齿轮故障诊断模型。又如王建国等<sup>[14]</sup>对齿轮振动信号进行VMD分解并融合前4个模态的排列熵和能量,实际上将数据扩展成4倍。利用小波包分解<sup>[15]</sup>、经验模态分解<sup>[16]</sup>等手段也可实施数据扩展,但该类模型可能会出现融合过多冗余信息,或数据过度利用等情形。

本文在上述策略之外提出了“空间迁移”的新思路。迁移学习的基本原理是指寻找和利用相似的源领域数据以帮助目标领域数据的分类,并已在文本分析<sup>[17]</sup>、图像处理<sup>[18]</sup>和电机故障诊断<sup>[19]</sup>等领域取得了进展。所提模型将辅助振动数据视为源领域,将目标振动数据视为目标领域,以实施空间迁移,主要贡献在于:(1)首次定义“空间迁移”的概念,利用辅助振动数据中的有用信息,帮助目标振动数据进行诊断,增强模型适应性;(2)设计基于频带选择独立成分分析规则的信号分离方法,快速地确定源领域和目标领域;(3)设计均衡密度投影准则将迁移学习中的源领域空间和目标领域空间映射至新空间,并最小化领域均值差异以拉近两者在低维空间内的距离;(4)设计数据更新规则,逐步减少模型对源领域振动数据的依赖,实时更新,节省建模资源,提高诊断速度。

## 1 “空间迁移”及其齿轮箱故障诊断模型

### 1.1 “空间迁移”思路

基本迁移学习的数学描述如下<sup>[20]</sup>: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 $c_s$ ,建立 $\{D_t, T_t\}$ 上的分类模型 $c_t$ ,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 $T_s \neq T_t$ 。

据此,“空间迁移”的总体思路如下:复杂齿轮传动系统中,不同传感器采集振动数据各不相同,且由于实际齿轮故障位置无法预知,不同传感器拾取的齿轮故障的响应也不一致,若对所有传感器数据同等对待将增加齿轮系统故障的误诊率,且可能存在实际故障位置附近传感器分布不足的情形。针对该情形,本文定义了“空间迁移”的概念,如图1所示。若故障发生于齿轮箱A内部,则由齿轮箱B和C传感器振动数据构成源领域,并建立分类模型,由齿轮箱A传感器振动数据构成目标领域,并将前者迁移至后者,形成在复杂齿轮传动系统不同空间上的模

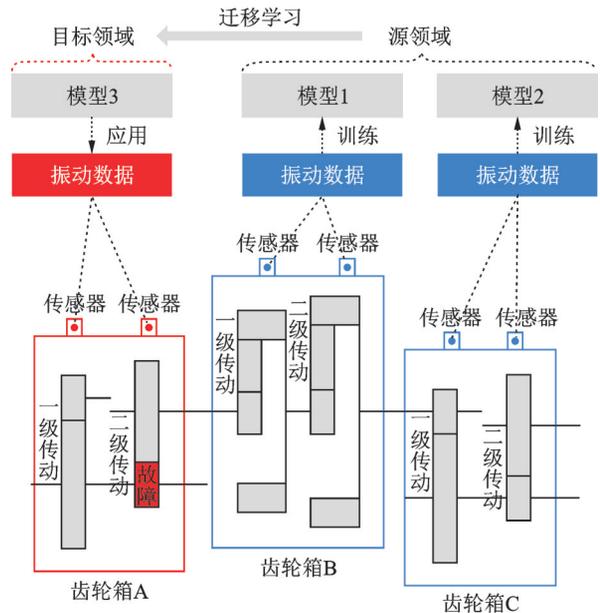


图1 “空间迁移”思路

Fig. 1 The space transfer learning strategy

型迁移。同时,随着时间的推移,通过剔除低质量源领域样本,并加入新的采集样本以维持诊断模型的持续更新,若更新过程中齿轮箱B和C上的传感器采集的数据质量持续低于齿轮箱A上的传感器采集的数据质量时,源领域由齿轮箱A上的传感器采集的历史数据替代,此时“空间迁移”思路转化为“时间迁移”思路,即利用由齿轮箱A历史传感器振动数据构成源领域,由齿轮箱A当前传感器振动数据构成目标领域,直至齿轮箱B和C高质量传感器振动数据出现。

为进一步阐明“空间迁移”的诊断有效性,图2比较了仅利用 $D_t$ 和同时利用 $D_s$ 和 $D_t$ 的实时诊断过程,若假设两者所需数据量和模型执行速度一致,前者仅利用目标领域数据,故单次处理周期较长,且受限于 $D_t$ 的质量,而后者由于引入了源领域数据,其

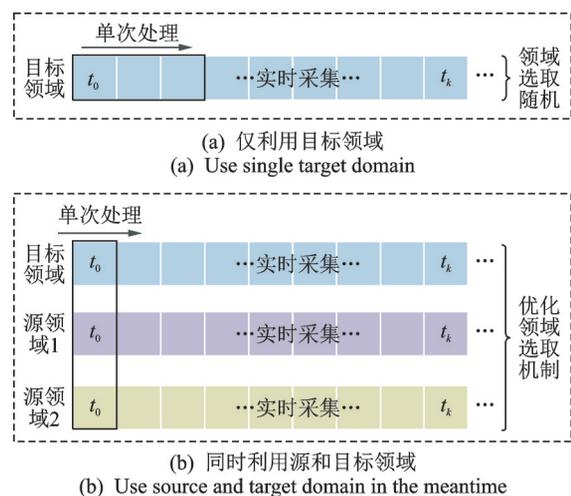


图2 “空间迁移”的诊断有效性

Fig. 2 Diagnostic effectiveness of space transfer learning

更新速度几倍于前者,将有效提升诊断实时性。相比而言,后者的另一优势在于,仅利用  $D_i$  时传感器选取是随机的,可能与故障关联性不强,而“空间迁移”通过优化领域选取机制,确保  $D_i$  与故障呈最强相关性,故具有更强的齿轮箱故障诊断能力。

### 1.2 齿轮箱故障诊断模型基本框架

根据“空间迁移”思路,提出齿轮箱故障诊断模型基本框架,如图 3 所示,包括如下步骤:A)数据领域选择机制:利用 BS-ICA 确定域类型,同时利用工况变化确定域长度;B)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,包括波形指标、偏态指标、峭度指标、裕度指标和脉冲指标等;C)迁移学习投影:利用均衡密度投影将源领域和目标领域映射至低维空间,并通过最小化领域均值差异以拉近两者在低维空间内的距离;D)低维空间分类:根据源领域子空间特征与标签建立分类模型,包括逻辑回归<sup>[21]</sup>和支持向量机<sup>[22]</sup>基分类器,并代入目标领域数据以实施故障识别;E)模型更新:对源领域和目标领域数据进行更新以实现持续诊断过程。



图 3 齿轮箱故障诊断模型框架

Fig. 3 The framework of gearbox fault diagnosis model

### 1.3 故障特征提取及基本分类器

#### 1.3.1 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,故齿轮箱故障诊断模型从波形指标( $S_f = X_{rms}/|\bar{X}|$ )、偏态指标( $P_t = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{\sqrt{N \sum_{i=1}^N x_i^2}}$ )、峭度指标( $K_v = \beta/X_{rms}$ )、裕度指标( $L = X_{max}/X_r$ )和脉冲指标( $I_f = X_{max}/|\bar{X}|$ )

五个方面提取,其中  $X_{rms}$  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。为消除各指标之间的量纲影响,对各特征进行量化处理

$$f_j(i) = \frac{f_j(i) - \min(f_j)}{\max(f_j) - \min(f_j)}, \quad i \in [1, n], j \in [1, 5] \quad (1)$$

式中  $f_j(i)$  为第  $i$  个样本的第  $j$  个特征量,  $n$  为样本数量。实施批量化处理时,样本数量  $n$  取 5% 工况变化数据集总样本和定值 50 中较小值,且  $\max(f_j)$  和  $\min(f_j)$  选取时剔除异常值。

#### 1.3.2 逻辑回归分类器

基于逻辑回归(LR)分类器的齿轮箱故障诊断模型如图 4 所示,其包括训练阶段和测试阶段。

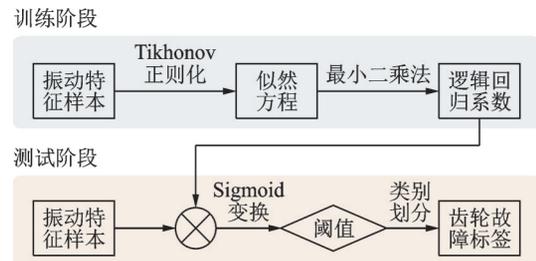


图 4 基于逻辑回归的齿轮箱故障诊断模型

Fig. 4 LR-based gearbox fault diagnosis model

**训练阶段:**首先通过逻辑斯方程建立训练特征矩阵  $F^t = \{f_i^t\}$  与故障类型向量  $Y^t = \{y_i^t\}$  之间的关系模型,其中  $i \in [1, n_t]$ ,  $n_t$  为训练样本数量,上标  $t$  代表训练集,方程如下

$$\begin{cases} y_i^t = \mu(f_i^t, \beta) \\ \mu(f_i^t, \beta) = \frac{\exp(\beta^T f_i^t)}{1 + \exp(\beta^T f_i^t)} \end{cases} \quad (2)$$

式中  $y_i^t$  为第  $i$  个特征向量  $f_i^t$  的分类标签;  $\mu'$  为预测概率函数;  $\beta = [\beta_0, \beta_1, \beta_2, \dots, \beta_5]$  为逻辑回归系数向量,特征维数为 6(第 0 维为常量,第 1-5 维为特征向量相乘系数)。其次利用似然函数表示逻辑回归的损失函数,并计算其最大似然方程如下

$$\ln L(F^t, Y^t, \beta) = \sum_{i=1}^{n_t} y_i^t \ln [\mu(f_i^t, \beta)] + [\max(Y^t) - y_i^t] \ln [\max(Y^t) - \mu(f_i^t, \beta)] \quad (3)$$

对  $\ln L(F^t, Y^t, \beta)$  利用 Tikhonov 算法正则化后,使用最小二乘法迭代计算,逐步得到最优的逻辑回归系数,过程如下

$$\beta_{i+1} = (F'^T U F')^{-1} F'^T U z, \\ z_j = \beta_i^T f_i^t + \frac{y_i^t - \mu_j^t}{\mu_j^t (\max(Y') - \mu_j^t)} \quad (4)$$

式中  $\beta_i$  和  $\beta_{i+1}$  分别为第  $i$  和第  $i+1$  次迭代时的逻辑回归系数;  $U$  为对角项是  $\mu_j^t (\max(Y') - \mu_j^t)$  的对角权重矩阵; 向量  $z$  由元素为  $z_j$  的中间变量组成, 用以更新输出分类值  $\mu_j$  和误差  $|y_i^t - \mu_j^t|$ 。

**测试阶段:** 首先输入测试特征矩阵  $F^s = \{f_i^s\}$ ,  $i \in [1, n_s]$ , 其中  $n_s$  为测试样本数量, 上标  $s$  代表测试集, 将测试特征与逻辑回归系数作加乘运算, 表达式为

$$\mathbf{A} = \beta_0 + \beta_1 f_{i1}^s + \dots + \beta_4 f_{i4}^s + \beta_5 f_{i5}^s \quad (5)$$

式中  $\mathbf{A}$  为加乘运算结果, 对  $\mathbf{A}$  进行 Sigmoid 变换, 得

$$\mu_i^s = \mu^s(f_i^s, \beta) = \frac{\exp(\mathbf{A})}{1 + \exp(\mathbf{A})} \quad (6)$$

式中  $\mu_i^s$  为逻辑回归(LR)分类器对测试特征向量  $F^s$  的输出齿轮故障标签。

### 1.3.3 多值支持向量机分类器

基本的支持向量机(SVM)是二值分类器, 为解决齿轮箱故障诊断模型的多值问题<sup>[23]</sup>, 引入类间相对分离度, 其目的是先将易于区分的类分离, 再实现不易区分的类分离。假设 SVM 二值分类器将训练特征矩阵  $F'$  和测试特征矩阵  $F^s$  映射到特征空间  $H$ 。首先, 计算该特征空间中齿轮故障类型的分离度  $\mathcal{R}_{ij}^H$

$$\mathcal{R}_{ij}^H = \frac{d^H(m_i, m_j)}{\sigma_i^H + \sigma_j^H} \quad (7)$$

式中  $m_i$  和  $m_j$  分别为第  $i$  类故障和第  $j$  类故障的类中心;  $d^H(\cdot)$  为在特征空间  $H$  内的距离函数;  $\sigma_i^H$  和  $\sigma_j^H$  分别为第  $i$  类故障和第  $j$  类故障的类方差, 并对第  $i$  类故障与其他  $K-1$  故障的分离度进行降序排列:  $\mathcal{R}_{i1}^H \geq \mathcal{R}_{i2}^H \geq \dots \geq \mathcal{R}_{i(K-1)}^H$ , 其中  $K$  代表总故障类别数。设  $k$  的初始值为 1, 并逐一增加至  $K$  (故障类别总数), 迭代过程中需构造二值分类器 SVM $_k$  的第  $k$  次训练集  $F_k^t = \Sigma_1^t + \Sigma_2^t$ :

$$\Sigma_1^t = \{(f_{ik}^t, +1)\}, \\ \Sigma_2^t = \{(\mathcal{F}_{ik}^t, -1) | \mathcal{F}_{ik}^t \in F^t - \{f_{ik}^t\}\} \quad (8)$$

式中  $\mathcal{F}_{ik}^t$  代表  $F^t$  中非  $f_{ik}^t$  的样本, 二值分类完成后, 训练特征矩阵  $F^t$  剔除  $F_k^t$  的部分作为下一次迭代的训练集, 直至实现  $K$  次迭代

$$F_{k+1}^t = F_k^t - \{f_{ik}^t\} \quad (9)$$

利用特征矩阵  $F^t$  训练得到多值 SVM 后, 将特征矩阵  $F^s$  代入模型计算, 得到其输出齿轮故障标签。

逻辑回归的优势在于可适用于连续性和类别性自变量, 能够在大量数据集时发挥作用, 而支持向

量机的识别效果取决于其支持向量的分布, 故能够在小样本数据集时发挥作用, 两者组合可提升基本模式识别能力。

## 2 数据领域选择及空间迁移模型

### 2.1 数据领域选择机制

基于“空间迁移”的齿轮箱故障诊断模型中, 由于振动特性取决于采集位置、与故障齿轮的距离、齿轮传动结构和噪声干扰等因素, 分离信号成分不满足相互独立条件, 传统 ICA 方法不再适用, 故采用频带选择独立成分分析(BS-ICA)<sup>[24]</sup>方法预先对信号分离以确定域类型, 设多个传感器振动数据为

$$x(t) = [x_1(t), x_2(t), \dots, x_p(t)]^T \quad (10)$$

式中 下标  $1-p$  为传感器编号。

BS-ICA 的基本模型为

$$\hat{s}(t) = \mathbf{W} [h(t)x(t)] \quad (11)$$

式中  $h(t) = [h_1(t), h_2(t), \dots, h_p(t)]$  由  $p$  个相同滤波器组成, 以提取  $x(t)$  中的独立分量;  $\hat{s}(t)$  为未知分离信号  $s(t) = [s_1(t), s_2(t), \dots, s_q(t)]^T$  的估计,  $q$  为分离信号数;  $\mathbf{W}$  为解混矩阵, 其目的在于得到自适应的最优输出  $\{h(t), \mathbf{W}\}$ 。算法过程中, 为使  $\hat{s}(t)$  之间独立性最强, 构建互信息指标<sup>[25]</sup>

$$I[\hat{s}] = \sum_{i=1}^q H(\hat{s}_i) - H(\hat{s}) \quad (12)$$

式中  $H(x) = -\sum p(x_i) \lg p(x_i)$  为定义熵函数;  $I[\hat{s}]$  为非负值, 且当元素完全独立时,  $I[\hat{s}] = 0$ 。FastICA 算法<sup>[26]</sup>迭代过程中, 通过构建最小目标函数  $\min_{h(t), \mathbf{W}} I[\hat{s}]$  以估计滤波器  $h(t)$  和解混矩阵  $\mathbf{W}$ 。

**求滤波器系数:** 设  $h(\hat{s}) = [h_0, h_1, h_2, \dots, h_l]$  为有限脉冲响应传递函数,  $l$  为滤波器阶数, 式(12)对  $h_k$  求偏导得:

$$\frac{\partial E n(\hat{s}_i)}{\partial h(l)} = -E \left\{ \frac{\rho_s^t(\hat{s}_i)}{\rho_s(\hat{s}_i)} \frac{\partial \hat{s}_i}{\partial h(l)} \right\} = \\ -E \left\{ \psi_{\hat{s}_i}(\hat{s}_i) \sum_{j=1}^n \frac{\partial \hat{s}_i}{\partial z_j} \cdot \frac{\partial z_j}{\partial h(l)} \right\} = \\ -E_t \left\{ \psi_{\hat{s}_i}(t) \sum_{j=1}^n \omega_{i,j} x_j(t-l) \right\} = \\ -E_t \left\{ \psi_{\hat{s}_i}^T(t) \mathbf{W} x(t-l) \right\} \quad (13)$$

$$\frac{\partial E n(\hat{s})}{\partial h(l)} = -E \left\{ \sum_{i=1}^n \frac{\partial \lg \rho_s(\hat{s}(t))}{\partial \hat{s}_i} \cdot \frac{\partial \hat{s}_i}{\partial h(l)} \right\} = \\ -\sum_{i=1}^n E \left\{ \frac{\partial \lg \rho_s(\hat{s}(t))}{\partial \hat{s}_i(t)} \sum_{j=1}^n \omega_{i,j} x_j(t-l) \right\} = \\ -E_t \left\{ \varphi_s^T(t) \mathbf{W} x(t-l) \right\} \quad (14)$$

式中  $\omega_{i,j}$  为矩阵  $W$  的第  $(i,j)$  个元素;  $\rho(\cdot)$  为边缘概率分布;  $\psi_s(t)$  为边际得分函数<sup>[27]</sup>;  $\varphi_s(t)$  为联合得分函数<sup>[28]</sup>;  $z = [z_1, z_2, \dots, z_n]^T$ ;  $z_i(t) = h * x_i(t)$  为卷积运算中间值。据此,  $I[\hat{s}]$  对  $h(l)$  的偏导可为

$$\frac{\partial I[\hat{s}]}{\partial h(l)} = E\{[\varphi_s^T(t) - \psi_s^T(t)]Wx(t-l)\} \quad (15)$$

当且仅当  $\hat{s}$  中元素相互独立时,  $\partial I[\hat{s}]/\partial h(l)$  值为 0, 最终滤波器  $h(t)$  的估计值可由式(15)通过梯度下降法求得。

**求解混矩阵:** 式(12)对  $W$  求偏导得

$$\partial I[\hat{s}]/\partial W = -[W^T]^{-1} - E\{\psi_s(\hat{s})z^T\} \quad (16)$$

式中  $z^T = [z_1, z_2, \dots, z_n]^T$ ,  $z_i(t) = h(t) * x_i(t)$ , 该式右边乘以  $W^T W$ , 进一步可得

$$\Delta W \propto (I + E[\psi_s(\hat{s})\hat{s}^T])W \quad (17)$$

FastICA 迭代过程中, 为确保  $\hat{s}_i$  方差呈收敛特性, 用  $1 - E(\hat{s}_i^2)$  替代矩阵  $I + E\{\psi_s(\hat{s})\hat{s}^T\}$  对角线上的元素

$$\Delta W \propto W - \text{diag}\{E(\hat{s}_1^2), E(\hat{s}_2^2), \dots, E(\hat{s}_p^2)\} + E[\psi_s(\hat{s})\hat{s}^T]W - \text{diag}\{E[\psi_s(\hat{s})\hat{s}^T]\}W \quad (18)$$

最终, 解混矩阵  $W$  的估计值可由式(18)通过 GD 求得。

**确定域类型:** 通过观察  $\hat{s}(t)$  分离信号矩阵, 对其包含故障成分信号实施傅里叶变换, 根据先验已知故障频率由强至弱排序  $\hat{s}(t)$  相应频段。通过  $W_{ij}$  逆矩阵, 将包含故障频率段的分离信号映射至原传感器并排序, 取相关性最强的传感器采集数据, 确定目标领域, 次强的若干传感器采集数据确定为源领域。

## 2.2 空间迁移投影机制

### 2.2.1 均衡密度投影

均衡密度投影(MDP)的目的是针对高维空间  $X = \{x_i\}$  样本分布不均匀情形, 使得投影后低维空间  $Y = \{y_{ij}\}$  的密度趋于均匀, 从而调整空间样本条件分布<sup>[29]</sup>。首先, 在  $X$  空间中寻找距离每个数据点最近的  $k$  个近邻点组成局部近邻, 并计算数据点的局部权重矩阵  $\Omega$ , 其定义误差函数

$$\min \epsilon(\Omega) = \sum_{i=1}^n \left\| x_i - \sum_{j=1}^k \Omega_{ij} x_j \right\|^2 \quad (19)$$

式中  $x_j (j=1, 2, \dots, k)$  为  $x_i$  的  $k$  个邻近点;  $\Omega_{ij}$  为  $x_i$  和  $x_j$  之间的权重,  $\Omega_i = [\Omega_{i1}, \Omega_{i2}, \dots, \Omega_{ik}]$  为第  $i$  数据点的权重矩阵。

其次, 计算每个样本点样本密度信息, 并调整  $\Omega_i$

$$\begin{aligned} \alpha_i^* &= \max \|x_i - x_j\|^2, \\ \alpha_i &= 1 - \alpha_i^* / \sum_{j=1}^k \|x_i - x_j\|^2, \\ \Omega^* &= [\Omega_1, \dots, \Omega_n][\alpha_1, \dots, \alpha_n]^T, \\ \sum_{j=1}^k \Omega_{ij} \alpha_i &= 1 \end{aligned} \quad (20)$$

最后, 构造目标函数并求解投影矩阵, 如下

$$\begin{aligned} \min \sum_{i=1}^n \left\| x_i - \sum_{j=1}^k \Omega_{ij} x_j \right\|^2 = \\ \min \text{Tr}[V^T X N X^T V] \end{aligned} \quad (21)$$

式中  $N = (I - \Omega^*)^T (I - \Omega^*)$  为均衡密度转移矩阵,  $V$  为投影矩阵。

### 2.2.2 构建迁移投影模型

迁移投影模型中, 源领域和目标领域的信号特性条件分布存在差异, 故利用均衡密度投影将源领域和目标领域投影至低维空间, 同时最小化领域均值差异以拉近两者在低维空间内的距离, 其目标函数如下

$$\begin{aligned} \min \{ \text{Tr}[V^T X^s N^s (X^s)^T V] + \\ \lambda_1 \text{Tr}[V^T X^s N^s (X^s)^T V] + \\ \lambda_2 \text{Tr}[V^T X M X^T V] \} \end{aligned} \quad (22)$$

式中 第一项表示将  $X^s$  通过均衡密度投影至低维空间, 第二项表示将  $X^t$  通过均衡密度投影至低维空间, 第三项表示最小化领域均值差异以拉近两者在低维空间内的距离;  $\lambda_1, \lambda_2$  表示投影权重,  $X = [X^s, X^t]$ , 上标  $s$  和  $t$  分别代表源领域和目标领域,  $M$  为均值差异矩阵, 其元素定义如下

$$M_{ij} = \begin{cases} 1/(n_s)^2, & x_i, x_j \in X^s \\ 1/(n_t)^2, & x_i, x_j \in X^t \\ -1/(n_s n_t), & \text{其余} \end{cases} \quad (23)$$

为求得投影矩阵  $V$ , 引入拉格朗日乘子  $\tau$ , 得

$$\begin{aligned} J(V, \tau) = \text{Tr}[V^T X^s N^s (X^s)^T V] + \\ \tau \text{Tr}\{V^T [\lambda_1 X^s N^s (X^s)^T + \\ \lambda_2 X M X^T] V\} - \bar{\omega} \end{aligned} \quad (24)$$

对式(24)求偏导, 并令其为 0, 得

$$\begin{aligned} X^s N^s (X^s)^T V + \tau \lambda_1 X^s N^s (X^s)^T V + \\ \tau \lambda_2 X M X^T V = 0 \end{aligned} \quad (25)$$

即

$$\begin{aligned} [\lambda_1 X^s N^s (X^s)^T + \lambda_2 X M X^T]^{-1} \cdot \\ [X^s N^s (X^s)^T] V = -\tau V \end{aligned} \quad (26)$$

最终, 对式(26)利用奇异值分解求投影矩阵  $V$ , 即能得到符合要求的低维空间  $Y = XV$ 。

### 2.2.3 模型领域更新

齿轮箱故障诊断模型更新流程如图5所示,包括:(1)更新过程中,当目标领域采集一定量数据后,执行一次BS-ICA+迁移学习投影模型,并输出一诊断结果;(2)LR和SVM两个基分类器同时对样本实施判定,若分类结果相同,则属于有效样本,否则为无效样本;(3)源领域中有效样本保留,无效样本舍弃,所有领域中有效样本加入源领域,作为下一时刻的训练样本;(4)训练池累加至样本满时(即满足数据更新速度),每补充一个源领域样本,则剔除最早时刻的样本。齿轮箱故障诊断模型更新的有益效果在于:能够剔除源领域中的劣质样本,保留优质样本,随着高质量样本的加入,逐步提升模型质量,一旦目标通道优质样本量足够或工况稳定,则无需其他通道样本,模型自动转化为非迁移模型,增强模型适应性。

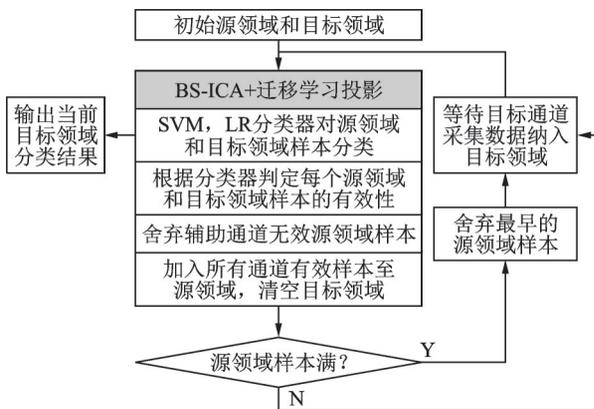


图5 齿轮箱故障诊断模型更新流程图

Fig. 5 Domain update flow for gearbox fault diagnosis

## 3 实验研究与性能分析

### 3.1 实验系统与数据集

试验所用数据来自如图6所示的Spectra Quest齿轮传动系统。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。七个传感器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(normal condition, NC)、齿根裂纹(root crack fault, RCF)、表面磨损(surface wear fault, SWF)、缺齿(miss tooth fault, MTF)和断齿(chipped tooth fault, CTF)五类,其中SWF又包含轻度磨损(SWF-L)、中度磨损(SWF-M)和重度磨损(SWF-H)三类。

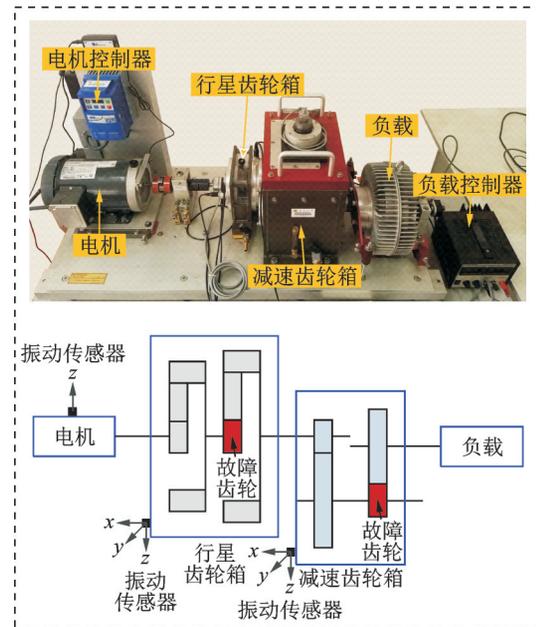


图6 Spectra Quest 齿轮传动系统

Fig. 6 The Spectra Quest gear drive system

### 3.2 数据领域选择试验

#### 3.2.1 领域长度确定

试验过程中,利用齿轮箱试验系统的工况变化以确定源领域和目标领域的域长度,将按照如下规则:A,从当前时刻向前选取一定长度的数据量作为领域长度,目标领域区间内工况变化不超过近10个设备运行周期工况变化的10%,源领域区间内工况变化不超过近10个设备运行周期工况变化的30%,且选取的信号长度至少包含一个设备运行周期,其中设备运行周期指齿轮箱输出轴旋转一圈所经历的时长。B,工况变化越快,选取域长度越短,源领域数越多,每个领域的选取长度越短。所有领域信号长度总和至少为10个设备运行周期。在工况变化一定时,目标领域数据长度选取越长,其包含的低质量样本越多,降低模型故障诊断性能;源领域数据长度选取越长,则可利用的高质量样本越多,在有利的数据选取条件下,能够提升模型诊断性能。

#### 3.2.2 BS-ICA 相关试验

数据领域选择试验条件如下:1)电机转速:30 Hz;2)采集通道:电机 $z$ 方向观测通道、减速齿轮箱 $z$ 方向观测通道和行星齿轮箱 $z$ 方向观测通道;3)故障类型:NC, SWF-M和MTF;4)滤波器阶数:5;5)根据Spectra Quest齿轮传动系统传动比<sup>[30]</sup>,一级行星齿轮传动比1/6,二级行星齿轮传动比7/32,一级减速齿轮传动比29/100,二级减速齿轮传动比2/5,若电机频率为30 Hz,则行星齿轮箱计算主频为5与140 Hz,减速齿轮箱计算主频为31.72与11.42 Hz;6)分离信号数:3。试验列表如表1所示。

表 1 数据领域选择试验列表

Tab. 1 Tests for data domain selection

| 试验      | 行星齿轮箱齿轮    | 减速齿轮箱齿轮    |
|---------|------------|------------|
| Test-S1 | NC:健康      | NC:健康      |
| Test-S2 | SWF-M:中度磨损 | NC:健康      |
| Test-S3 | MTF:缺齿     | NC:健康      |
| Test-S4 | NC:健康      | SWF-M:中度磨损 |
| Test-S5 | NC:健康      | MTF:缺齿     |

图 7(a-e)分别绘制了 Test-S1 至 Test-S5 模型求解过程中的相关参数。通过观察其解混矩阵和滤波器系数,可得到如下结论:1)对比健康齿轮系统(Test-S1)和含故障齿轮系统(Test-S2 至 Test-S5),前者滤波器系数明显小于后者,说明含有故障的系统各传感器信号关联性更强,健康齿轮系统信号较

为独立;2)对比 Test-S3 和 Test-S5 的  $W$  矩阵,当 MTF 故障发生于行星齿轮箱齿轮时,其  $z$  方向观测通道分量得到显著增强,其余通道分量较弱,故该通道选定为目标领域,同理当 MTF 故障发生在减速齿轮箱齿轮时,准确判定减速齿轮箱  $z$  方向观测通道为目标领域;3)观察试验过程中有限脉冲响应传递系数  $[h_0, h_1, h_2, h_3, h_4, h_5]$ ,健康传动系统的脉冲旁瓣抖动最小(-0.0127 至 0.0150),缺齿故障的脉冲旁瓣抖动最大(-0.1048 至 0.1667),故前者可进一步减少滤波器阶数以降低训练成本,而后可增加阶数以提升滤波性能;4)同时观察五种试验集的解混矩阵首元素跟踪曲线和首阶滤波器系数跟踪曲线,均能在较短时间内达到一个稳态常量值(400 次迭代平均执行时间为 1.2 s),故满足实时性。

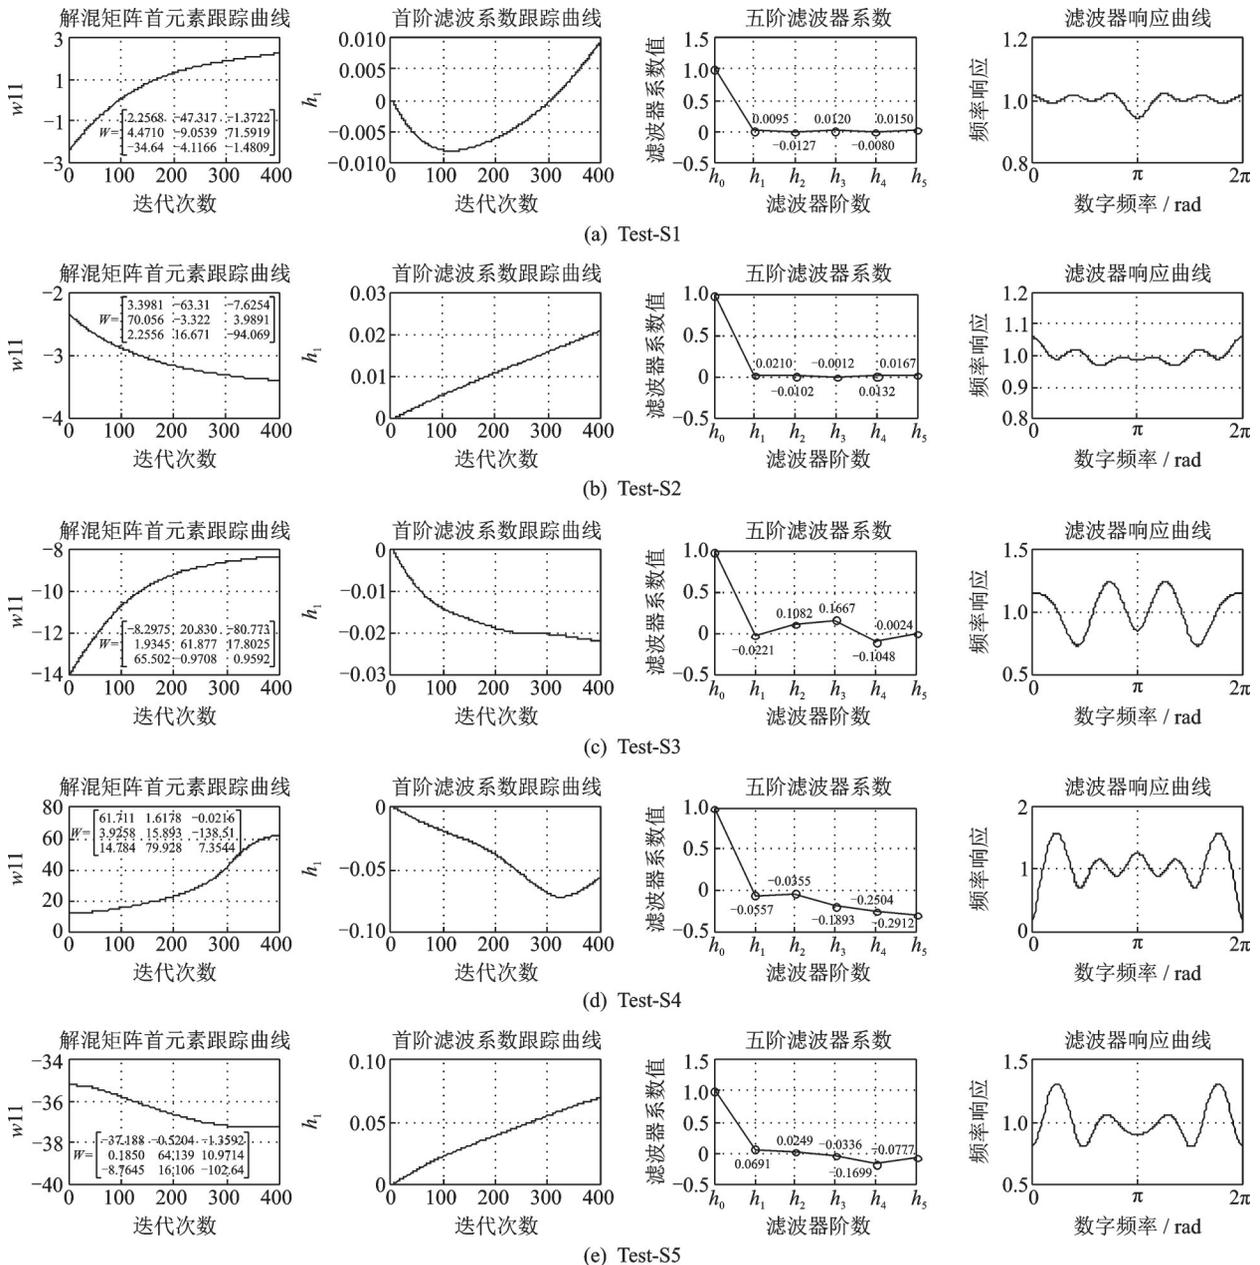


图 7 Test-S1-Test-S5 中解混矩阵和滤波器系数

Fig. 7 The de-mixing matrices and filter coefficients of Test-S1-Test-S5

以 Test-S3 为例,图 8 给出原始时域信号及其振动分离成分,对比两者可见,分离信号成分 I 主要表征电机运行频率,分离信号成分 II 主要表征齿轮故障成分振动,可观察到 140 Hz 故障频率,分离信号成分 III 主要表征振动噪声,Test-S3 的解混矩阵及其逆矩阵如下:

$$W = \begin{bmatrix} -8.30 & 20.83 & -80.77 \\ 1.93 & 61.88 & 17.80 \\ 65.50 & -0.97 & 0.96 \end{bmatrix}$$

$$W^{-1} = \begin{bmatrix} 0.22 & 0.17 & 15.29 \\ 3.32 & 15.04 & -0.02 \\ -11.55 & 3.86 & -1.58 \end{bmatrix} \times 10^{-3}$$

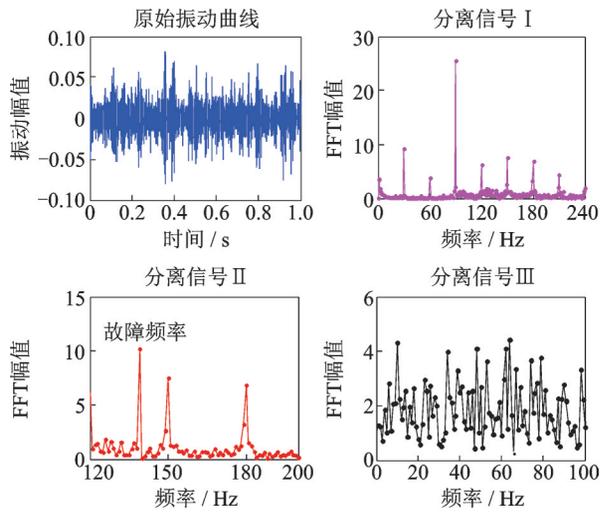


图 8 Test-S3 原始时域信号及其振动分离成分

Fig. 8 The original signals and separated signals of Test-S3

可计算三者对分离信号成分 II 的相关性排序为:行星齿轮箱  $z$  轴 > 减速齿轮箱  $z$  轴 > 电机  $z$  轴,故判定行星齿轮箱  $z$  轴为齿轮箱故障诊断模型的目标领域,减速齿轮箱  $z$  轴通道为齿轮箱故障诊断模型的源领域。

### 3.3 时域信号特征提取试验

时域信号特征提取的试验条件如下:1)故障类别:NC,SWF-M 和 CTF;2)采集通道:行星齿轮箱  $z$  轴和减速齿轮箱  $z$  轴;3)设备转速:20,30 和 40 Hz;4)领域选取:当故障发生于行星齿轮箱齿轮时,行星齿轮箱  $z$  轴通道为目标领域,减速齿轮箱  $z$  轴通道为源领域,当故障发生于减速齿轮箱齿轮时,减速齿轮箱  $z$  轴通道为目标领域,行星齿轮箱  $z$  轴通道为源领域。试验利用杰卡德距离  $J(D_s, D_t)^{[31]}$  计算领域样本间的差异性,其定义如下

$$J(D_s, D_t) = \frac{|D_s \cup D_t| - |D_s \cap D_t|}{|D_s \cup D_t|} \quad (27)$$

式中  $D_s$  为源领域样本空间,  $D_t$  为目标领域样本空

间,  $|D_s \cap D_t|$  代表两空间中交集元素的个数,  $|D_s \cup D_t|$  代表两空间中并集元素的个数(即样本总数),  $0 \leq J(D_s, D_t) \leq 1$ ,  $J(D_s, D_t)$  值越大,两者差异性越明显。

图 9(a)-(c) 分别绘制 NC, SWF-M 和 CTF 故障类别特征向量,图中可得:1)健康齿轮传动系统中,由于不含故障,斜对角上预判减速齿轮箱内故障的源领域和预判行星齿轮箱内故障的目标领域特征一致,横向来源和目标领域间存在差异性,特征  $[f_1, f_2]$  差异较大,特征  $[f_3, f_4, f_5]$  差异较小,两者  $J(D_s, D_t)$  值为 0.2433;2)磨损故障齿轮传动系统中,磨损发生于行星齿轮箱内时特征  $[f_2]$  明显高于其发生于减速齿轮箱内,两者  $J(D_s, D_t)$  值为 0.4667;3)断齿故障齿轮传动系统中,断齿发生于行星齿轮箱内时,其特征分辨率高于断齿发生于减速齿轮箱内,两者  $J(D_s, D_t)$  值为 0.5800;4)比较 NC, SWF-M 和 CTF 故障类型的特征值,健康和磨损故障在  $[f_1, f_2, f_5]$  特征上具有区分性,健康和断齿故障在  $[f_3, f_4]$  特征上具有区分性;5)比较 20, 30 和 40 Hz 转速,虽然其特征向量存在差异,但总体变化趋势保持一致,20 与 30 Hz 特征向量间相关系数 0.99, 30 与 40 Hz 特征向量间相关系数 0.98,故恒定转速前提下,不同转速对空间迁移特征趋势影响较小。

### 3.4 齿轮箱故障诊断试验

齿轮箱故障诊断主要试验条件如表 2 所示,其余试验条件为:1)故障类别:第 I 组:NC, RCF, SWF-M, MTF, CTF;第 II 组:NC, SWF-L, SWF-M, SWF-H。2)设备转速:30 Hz。3)样本数量:目标领域样本数 60,源领域样本数 240,共 300 条。

以 Test-S6 和 Test-S7 为例,图 10(a) 和 (b) 分别绘制 NC, CTF 故障类别的投影低维空间样本分布图,并列出其投影矩阵  $V$ 。由图 10 可见,经均衡密度投影后,同一类别内样本分散性较为均衡,且类别间区分性较明显,但由于源领域样本间信号特性差异较大,故其在子空间内的投影存在变形现象,而目标领域投影空间无变形现象。其次,行星齿轮箱的投影变形较减速齿轮箱更明显,这是由于前者振动数据特征相对复杂,后者相对简单。最后,引入最小均值差异后,源领域和目标领域健康齿轮数据集、源领域和目标领域缺齿故障齿轮数据集均能够较好重合,以基分类器的分类,且可看出 Test-S7 比 Test-S6 投影空间重合效果更佳,故诊断性能更高。

同时,表 3 和 4 分别给出模型故障类别及故障严重性的诊断精度。由表 3 和 4 计算可得:1)行星齿轮箱作为源领域、减速齿轮箱作为目标领域(Test-S6, Test-S8, Test-S10 & Test-S12)的综合诊断精度为

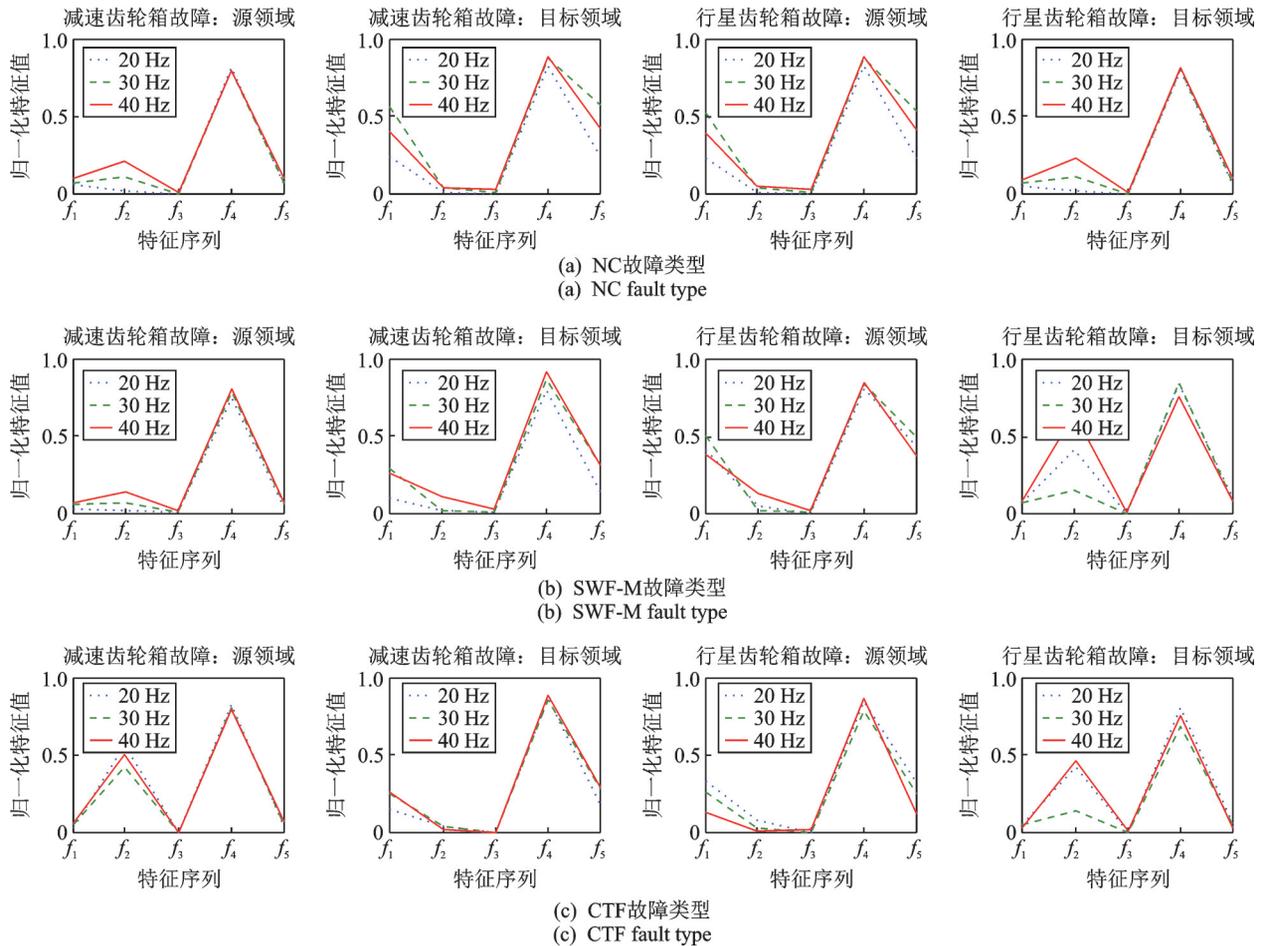


图 9 NC,SWF-M和CTF故障类别特征向量

Fig. 9 The feature vectors of NC, SWF-M and CTF fault types

表 2 齿轮箱故障诊断试验条件

Tab. 2 Experimental conditions of gearbox fault diagnosis

| 试验       | 源领域               | 目标领域              |
|----------|-------------------|-------------------|
| Test-S6  | 行星齿轮箱 z 轴(第 I 组)  | 减速齿轮箱 z 轴(第 I 组)  |
| Test-S7  | 减速齿轮箱 z 轴(第 I 组)  | 行星齿轮箱 z 轴(第 I 组)  |
| Test-S8  | 行星齿轮箱 x 轴(第 I 组)  | 减速齿轮箱 x 轴(第 I 组)  |
| Test-S9  | 减速齿轮箱 x 轴(第 I 组)  | 行星齿轮箱 x 轴(第 I 组)  |
| Test-S10 | 行星齿轮箱 z 轴(第 II 组) | 减速齿轮箱 z 轴(第 II 组) |
| Test-S11 | 减速齿轮箱 z 轴(第 II 组) | 行星齿轮箱 z 轴(第 II 组) |
| Test-S12 | 行星齿轮箱 x 轴(第 II 组) | 减速齿轮箱 x 轴(第 II 组) |
| Test-S13 | 减速齿轮箱 x 轴(第 II 组) | 行星齿轮箱 x 轴(第 II 组) |

92.94%, 而调换领域后 (Test-S7, Test-S9, Test-S11 & Test-S13) 其综合诊断精度为 95.23%, 即空间迁移中结构相对简单的减速齿轮箱更适合辅助结构相对复杂的行星齿轮箱诊断; 2) z 轴相互迁移的综合精度 (94.19%) 略高于 x 轴相互迁移 (93.98%), 其说明垂直于转轴方向的振动更能表征故障特征, 尤其是缺齿、断齿等与频率有关的故障; 3) 观察故障类别识别 (第 I 组) 和故障严重性识别 (第 II 组) 的差异, 可发现在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

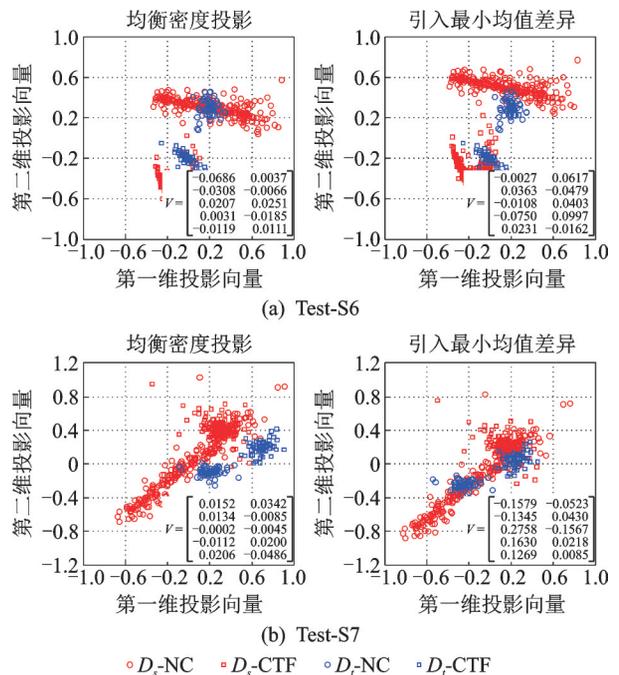


图 10 NC,CTF 故障类别的投影低维空间样本分布图

Fig. 10 Projection maps in low dimensional space of NC and CTF faults

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 SWF-1 和 SWF-2, SWF-2 和

表3 齿轮箱故障类别诊断精度

Tab. 3 Diagnostic accuracies of gearbox fault types

| 试验      | 目标<br>样本 | 诊断精度/% |       |       |       |       |       |
|---------|----------|--------|-------|-------|-------|-------|-------|
|         |          | NC     | RCF   | SWF-M | MTF   | CTF   | 平均    |
| Test-S6 | 60×5     | 95.00  | 88.33 | 95.00 | 93.33 | 96.67 | 93.67 |
| Test-S7 | 60×5     | 93.33  | 95.00 | 95.00 | 98.33 | 98.33 | 96.00 |
| Test-S8 | 60×5     | 95.00  | 96.67 | 88.33 | 90.00 | 93.33 | 92.67 |
| Test-S9 | 60×5     | 100    | 96.67 | 90.00 | 93.33 | 96.67 | 95.33 |

表4 齿轮箱故障严重性诊断精度

Tab. 4 Diagnostic accuracies of gearbox fault severities

| 试验       | 目标<br>样本 | 诊断精度/% |       |       |       |       |
|----------|----------|--------|-------|-------|-------|-------|
|          |          | NC     | SWF-L | SWF-M | SWF-H | 平均    |
| Test-S10 | 60×4     | 93.33  | 90.00 | 90.00 | 95.00 | 92.08 |
| Test-S11 | 60×4     | 93.33  | 95.00 | 93.33 | 98.33 | 95.00 |
| Test-S12 | 60×4     | 90.00  | 96.67 | 90.00 | 96.67 | 93.34 |
| Test-S13 | 60×4     | 98.33  | 88.33 | 96.67 | 95.00 | 94.58 |

SWF-3),使其误判增加,但总体精度损失仅0.67%,仍可接受,故模型提升了齿轮故障诊断的适用性。

### 3.5 齿轮箱故障诊断模型实时评估试验

利用图6所示的Spectra Quest齿轮传动系统对

表5 齿轮箱故障诊断模型样本选取条件

Tab. 5 Sample selection conditions for gearbox fault diagnosis

| 模型   | 样本选取条件   |
|------|--|
| LR   | 1)周期处理数据长度:10倍周期(来自减速齿轮箱z轴);2)周期样本数量:300条  |
| SVM  | 1)周期处理数据长度:10倍周期(来自减速齿轮箱z轴);2)周期样本数量:300条  |
| TCA  | 1)周期处理数据长度:12倍周期(源领域来自减速齿轮箱x,y轴和行星齿轮箱x,y,z轴,目标领域来自减速齿轮箱z轴);2)周期样本数量:360条(含源领域300条,目标领域60条) |
| DSM  | 1)周期处理数据长度:12倍周期(源领域来自减速齿轮箱x,y轴和行星齿轮箱x,y,z轴,目标领域来自减速齿轮箱z轴);2)周期样本数量:360条(含源领域300条,目标领域60条) |
| 空间迁移 | 1)周期处理数据长度:遵循领域选择规则;2)周期样本数量=所选周期数×30  |

注:1个周期代表齿轮箱输出轴运行一圈所经历的时长

据此,表6列出各模型在50s周期内的执行次数、周期平均用时以及等待采集与总时间之比等实时信息,图12绘制各模型的10-50s内综合诊断精度曲线。由表7可以看出,由于LR和SVM模型中目标通道所需的数据量5倍于迁移模型,低采样率下,算法执行次数取决于采集时长;高采样率下,算法执行次数取决于算法执行时间,两者的周期平均用时均为2.08s。而在TCA,DSM和空间迁移模型中,由于目标通道所需的数据量较少,模型实时性完全取决于算法执行速度,且由于传统迁移算法复杂度较高,空间迁移模型的执行速度约为其4倍,故提升了诊断实时性。图12中,对比迁移和非迁移模型,当工况变化较大时(30-40s时间段内),计算两者的总体诊断精度,前者较后者高18.64%,证明了迁移

空间迁移模型进行实时性评估,并与迁移成分分析<sup>[32]</sup>、领域选择机<sup>[33]</sup>、支持向量机、逻辑回归四个模型作比较,模型共性试验条件为:1)故障类别:NC,RCF,SWF-M,MTF,CTF;2)故障位置:减速齿轮箱齿轮;3)变转速曲线:如图11所示,根据传动比关系,若电机转速为 $v$ ,则行星齿轮箱故障轮转速为 $v/6$ ,减速齿轮箱故障齿轮转速为 $203v/19200$ ;4)采集通道:减速齿轮箱 $x,y,z$ 轴和行星齿轮箱 $x,y,z$ 轴,模型样本选取条件如表5所示。

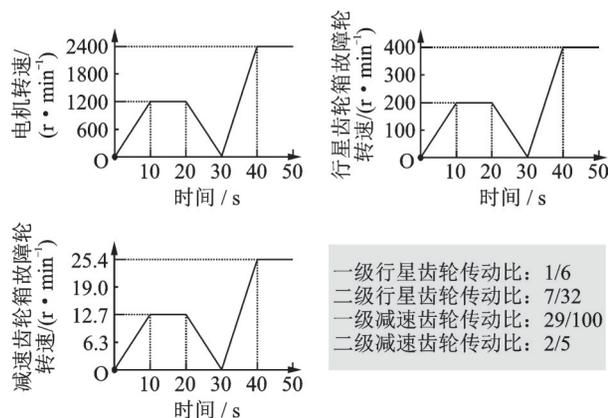


图11 齿轮传动系统变转速曲线

Fig. 11 Varying rotating speed curves of gear drive system

策略的优势;对比空间迁移和其余两迁移模型,虽然前者总体模型精度仅比后者高0.67%,但由于其执行速度快,当设转速发生急剧变化时,所利用的数据集特性更接近当前时刻,此时精度差异值为1.67%,

表6 各模型在50s周期内的执行结果

Tab. 6 Implementation results of models during 50 s cycles

|      | 执行次数/<br>次 | 周期平均<br>用时/s | 等待采集与<br>总时间之比/% |
|------|------------|--------------|------------------|
| LR   | 24         | 2.08         | 64               |
| SVM  | 24         | 2.08         | 23               |
| TCA  | 9          | 5.55         | 0                |
| DSM  | 15         | 3.33         | 0                |
| 空间迁移 | 40         | 1.25         | 0                |

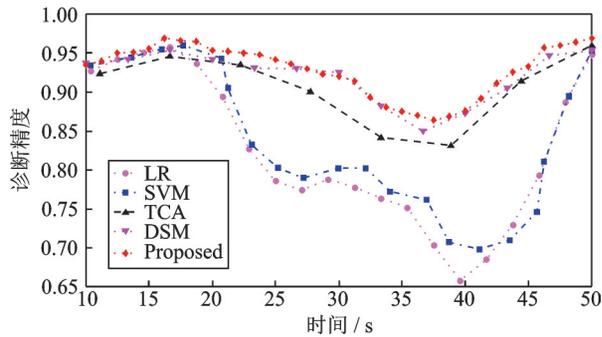


图12 10-50 s内实时诊断精度曲线

Fig. 12 Real-time diagnostic accuracy curves from 10 s to 50 s

证明了空间迁移的优势。

最后,分别用TCA核,LSSVM核和DSM核分别替换原LR/SVM核,以比较空间迁移模型的性能,其中试验条件如下:1)故障类别:NC,RCF,SWF-M,MTF,CTF;2)故障齿轮:减速齿轮箱;3)设备转速:30 Hz;4)源领域及样本数量:行星齿轮箱 $z$ 轴240条;5)目标领域:减速齿轮箱 $z$ 轴60条。不同核的空间迁移模型故障诊断性能比较如表7所示。由表7可以看出,使用LR/SVM内核下,其诊断精度提升9.82%,大于其他所选基分类器的提升效果,同时LR/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,基于LR/SVM核的空间迁移模型具有较高的性价比。

表7 不同核的空间迁移模型故障诊断性能比较

Tab. 7 The comparison of fault diagnosis performance of space transfer models with different kernels

| 空间迁移模型  | 诊断精度          | 诊断耗时          |
|---------|---------------|---------------|
| LR/SVM核 | 比SVM提升9.82%   | 比SVM多6.33%    |
| TCA核    | 比TCA提升3.21%   | 比TCA多10.54%   |
| LSSVM核  | 比LSSVM提升5.78% | 比LSSVM多20.40% |
| DSM核    | 比DSM提升1.68%   | 比DSM多33.15%   |

## 4 结论

提出一种基于数据领域选择与空间迁移的齿轮箱故障诊断模型,以提升复杂齿轮传动系统故障诊断的适应性和实时性。数据领域选取试验表明,含有故障的系统各传感器间信号关联性更强,健康齿轮系统信号较为独立。时域特征提取试验表明,健康和磨损故障在 $[f_1, f_2, f_3]$ 特征上具有区分性,健康和断齿故障在 $[f_3, f_4]$ 特征上具有区分性,且特征趋势与转速无关。故障诊断试验表明,迁移学习模型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,且结构简单的齿轮系统更适合辅助结构复杂系统的诊断,故障类别诊断综合诊断精度为94.42%,故障严重性综合诊断精度为93.75%。相比TCA,DSM等传统迁移学习算法,模型既能提高工况快速变化时的诊断精度,又能加快诊断速度,具有实际的工程应用价值。

## 参考文献:

- [1] 郭远晶,魏燕定,金晓航,等. 频谱密度函数相似性比较的齿轮箱故障诊断[J]. 振动工程学报, 2018, 31(1):157-164.  
Guo Y J, Wei Y D, Jin X H, et al. Gearbox fault diagnosis using similarity comparison of frequency spectrum density function[J]. Journal of Vibration Engineering, 2018, 31(1):157-164.
- [2] Cui L L, Huang J F, Zhang F B, 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(1): 608-629.
- [3] 郑近德,潘海洋,杨树宝,等. 广义变分模态分解方法及其在变工况齿轮故障诊断中的应用[J]. 振动工程学报, 2017, 30(3):502-509.  
Zheng J D, Pan H Y, Yang S B, et al. Generalized variational mode decomposition and its applications to gearbox fault diagnosis under variable conditions[J]. Journal of Vibration Engineering, 2017, 30(3): 502-509.
- [4] 张玉. 基于振动信号分析的齿轮箱故障诊断[J]. 仪器仪表与分析监测, 2011, 1(1):20-24.  
Zhang Y. Diagnosis for the failure of gearbox based on analysis of vibration signal[J]. Instrumentation and Analysis Monitoring, 2011, 1(1):20-24.
- [5] 王文利,黄世琦,谢志江,等. 一种齿轮箱信号分析与故障诊断系统[J]. 重庆大学学报(自然科学版), 1999, 22(4):45-48.  
Wang W L, Huang S Q, Xie Z J, et al. Signal analysis and fault diagnosis system of gearbox [J]. Journal of Chongqing University (Natural Science Edition), 1999, 22(4):45-48.
- [6] 雷亚国,孔德同,李乃鹏,等. 自适应总体平均经验模式分解及其在行星齿轮箱故障检测中的应用[J]. 机械工程学报, 2014, 50(3):64-70.  
Lei Y G, Kong D T, Li N P, et al. Adaptive ensemble empirical mode decomposition and its application to fault detection of planetary gearboxes[J]. Journal of Mechanical Engineering, 2014, 50(3):64-70.
- [7] 黄文涛,付强,窦宏印. 基于自适应优化品质因子的共振稀疏分解方法及其在行星齿轮箱复合故障诊断中的应用[J]. 机械工程学报, 2016, 52(15):44-51.

- Huang W T, Fu Q, Dou H Y. Resonance-based sparse signal decomposition based on the quality factors optimization and its application of composite fault diagnosis to planetary gearbox [J]. *Journal of Mechanical Engineering*, 2016, 52(15):44-51.
- [8] 时培明, 梁凯, 赵娜, 等. 基于深度学习特征提取和粒子群支持向量机状态识别的齿轮智能故障诊断[J]. *中国机械工程*, 2017, 28(09):1056-1061.  
Shi P M, Liang K, Zhao N, et al. Intelligent fault diagnosis for gears based on deep learning feature extraction and particle swarm optimization SVM state identification [J]. *China Mechanical Engineering*, 2017, 28(09):1056-1061.
- [9] 梅杰, 陈定方, 李文锋, 等. 基于神经网络的多级行星齿轮箱故障诊断专家系统[J]. *中国工程机械学报*, 2011, 9(1):117-121.  
Mei J, Chen D F, Li W F, et al. Fault diagnosis expert system for multilevel planetary gear boxes based on neural networks [J]. *Chinese Journal of Construction Machinery*, 2011, 9(1):117-121.
- [10] 田昊, 唐力伟, 陈红, 等. 基于瞬态声与阶次倒谱的齿轮箱故障诊断[J]. *振动、测试与诊断*, 2009, 29(2):137-140.  
Tian H, Tang L W, Chen H, et al. Fault diagnosis of gearbox by using transient acoustic signal and order cepstrum [J]. *Journal of Vibration, Measurement & Diagnosis*, 2009, 29(2):137-140.
- [11] 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 Z, 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.
- [12] 张少敏, 毛冬, 王保义. 大数据处理技术在风电机组齿轮箱故障诊断与预警中的应用[J]. *电力系统自动化*, 2016, 40(14):129-134.  
Zhang S M, Mao D, Wang B Y. Application of big data processing technology in fault diagnosis and early warning of wind turbine gearbox [J]. *Power System Automation*, 2016, 40(14):129-134.
- [13] 毛瑞卿, 马西良, 程刚, 等. 基于多传感器信息融合的齿轮故障识别方法[J]. *矿山机械*, 2015, 1(11):125-130.  
Mao R Q, Ma X L, Chen G, et al. Gear fault identification method based on multi-sensor information fusion [J]. *Mining and Processing Equipment*, 2015, 1(11):125-130.
- [14] 王建国, 陈帅, 张超. 基于VMD与多特征融合的齿轮故障诊断方法[J]. *机械传动*, 2017, 1(3):165-170.  
Wang J G, Chen S, Zhang C. Gear fault diagnosis method based on VMD and multi-feature fusion [J]. *Mechanical transmission*, 2017, 1(3):165-170.
- [15] Sharma S, Tiwari S K, Singh S. Diagnosis of gear tooth fault in a bevel gearbox using discrete wavelet transform and autoregressive modeling [J]. *Life Cycle Reliability & Safety Engineering*, 2018;1-12.
- [16] 彭延峰, 程军圣, 杨宇. ACROA优化的自适应最稀疏窄带分解方法[J]. *振动工程学报*, 2016, 29(6):1127-1133.  
Peng Y F, Chen J S, Yang Y. Adaptive sparsest narrow-band decomposition method optimized by ACROA [J]. *Journal of Vibration Engineering*, 2016, 29(6):1127-1133.
- [17] Weiss K, Khoshgoftaar T M, Wang D D. A survey of transfer learning [J]. *Journal of Big Data*, 2016, 3(1):9.
- [18] HAN Dongmei, LIU Qigang, FAN Weigu. A new image classification method using CNN transfer learning and web data augmentation [J]. *Expert Systems with Applications*, 2018, 95(1):43-56.
- [19] 沈飞, 陈超, 严如强. 奇异值分解与迁移学习在电机故障诊断中的应用[J]. *振动工程学报*, 2017, 30(1):118-126.  
Shen F, Chen C, Yan R Q. Application of SVD and transfer learning strategy on motor fault diagnosis [J]. *Journal of Vibration Engineering*, 2017, 30(1):118-126.
- [20] 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.
- [21] Xu E L, Qian X, Liu T, et al. Detection of cooperative interactions in logistic regression models [J]. *IEEE Transactions on Signal Processing*, 2017, 65(7):1765-1780.
- [22] 赵海洋, 徐敏强, 王金东. 改进二叉树支持向量机及其故障诊断方法研究[J]. *振动工程学报*, 2013, 26(5):764-770.  
Zhao H Y, Xu M Q, Wang J D. An improved binary tree SVM and application for fault diagnosis [J]. *Journal of Vibration Engineering*, 2013, 26(5):764-770.
- [23] 王保建, 张小丽, 傅杨奥, 等. 优化支持向量机及其在智能故障诊断中的应用[J]. *振动、测试与诊断*, 2017, 37(3):547-552.  
Wang B J, Zhang X L, Fu Y A X, et al. Optimization of support vector machine and its application in intelligent fault diagnosis [J]. *Journal of Vibration, Measurement & Diagnosis*, 2017, 37(3):547-552.
- [24] 陈建国, 王珍, 李宏坤. SDICA方法在单通道信号故障分类中的研究[J]. *振动、测试与诊断*, 2017, 37(37):256-260.

- Chen J G, Wang Z, Li H S. Study of fault classification for single channel signal based on SDICA[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(37): 256-260.
- [25] 蒋爱华,周璞,章艺,等.相空间重构延迟时间互信息改进算法研究[J].振动与冲击,2015,34(2): 79-84.
- Jiang A H, Zhou P, Zhang Y, et al. Improved mutual information algorithm for phase space reconstruction [J]. Journal of Vibration and Shock, 2015, 34(2): 79-84.
- [26] Yuan L, Zhou Z H, Yuan Y C, et al. An improved FastICA method for fetal ECG extraction. [J]. Computational & Mathematical Methods in Medicine, 2018, 2018(10):7061456.
- [27] 刘淳,金洪飞,潘慧峰.使用边际似然函数识别变结构模型[J].统计研究,2010,27(11):88-94.
- Liu C, Jin H F, Pan H F. Identifying structural breaks by marginal likelihood [J]. Statistical Research, 2010, 27(11):88-94.
- [28] Kim E K. The effect of gluteus medius strengthening on the knee joint function score and pain in meniscal surgery patients [J]. Journal of Physical Therapy Science, 2016, 28(10):2751-2753.
- [29] Joshi L K, Mukhopadhyay A, Preis F, et al. Exact time dependence of causal correlations and nonequilibrium density matrices in holographic systems [J]. Physical Review D, 2017, 96(10):106006.
- [30] Shao S Y, Stephen M A, Yan R Q, et al. Highly-accurate machine fault diagnosis using deep transfer learning [J]. IEEE Transactions on Industrial Informatics, 2018, 15(4):18579911.
- [31] Zhou C, Wieser A. Modified Jaccard index analysis and adaptive feature selection for location fingerprinting with limited computational complexity [J]. Journal of Location Based Services, 2019, 13(2): 128-157.
- [32] 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.
- [33] Lu W, Liang B, Yu C, et al. Deep model based domain adaptation for fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2017, 64(3): 2296-2305.

## Application of data domain selection and space transfer on gearbox fault diagnosis

SHEN Fei<sup>1</sup>, CHEN Chao<sup>1</sup>, XU Jia-wen<sup>1</sup>, YAN Ru-qiang<sup>1,2</sup>

(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:** To improve the performance of gearbox fault diagnosis, a space transfer strategy is proposed. Here the source domains are composed by multiple auxiliary channels and the target domain is composed by single target channel. With transfer learning (TL), the fault diagnosis models in the former can be applied in the latter to overcome the problem of lacking target data. Firstly, the domains are selected according to the band selective independent component analysis (BS-ICA) rule and the original five-dimension spaces are constructed by extracting their time-domain features. Secondly, the source and target domains are mapped to a public two-dimensional space using the equilibrium density projection (EDP). Meanwhile, the minimum mean difference strategy is used to minimize the difference between two projection spaces. Finally, the logistic regression (LR) and support vector machine (SVM) classifiers are both carried out for sample classification. Also, the diagnostic model can be updated by removing low-quality samples while adding high-quality samples in source domains. Based on the Spectra Quest's gear drive system, the performance between proposed method and classical transfer strategies including transfer composition analysis (TCA) and domain selection machine (DSM) are compared, which indicates that the former has higher diagnostic accuracy as well as faster running speed when facing with rapid change of working conditions, thus possessing high value in application of engineering.

**Key words:** fault diagnosis; gearbox; space transfer; band selective independent component analysis; equilibrium density projection

作者简介:沈飞(1991-),男,电话:15651680110;E-mail:sfseu0311@163.com

通讯作者:严如强(1975-),男,教授。电话:13584054760;E-mail:ruqiang@seu.edu.cn