

DOI: 10.19650/j.cnki.cjsi.J1905038

谱质心迁移在变工况轴承故障诊断的应用 *

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:轴承故障诊断普遍存在需建立不同模型以适应变工况的问题,故提出一种谱质心迁移学习模型,通过将源工况领域迁移至目标工况领域减少后者的建模代价,并增强模型通用性。首先计算两工况领域间频谱相似度(FSSM)并排序选择近距离源工况领域为初始训练集。其次在迭代过程中剔除与训练集谱质心均值距离较远的样本,并加入同数量目标工况领域无标签样本,直至两者谱质心均值距离一致,模型故障类别取决于支持向量机(SVM)和逻辑回归(LR)基分类器的输出。Spectra Quest齿轮传动系统试验结果表明,转速负载发生变化时,该模型诊断性能优于非迁移模型,且能够根据替换样本数、精度、频谱相似度、耗时等指标评估源工况领域质量,因此具有解决变工况轴承故障诊断问题的潜在价值。

关键词:谱质心;迁移学习;轴承故障诊断;频谱相似度

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

Application of spectral centroid transfer inbearing fault diagnosis under varying working conditions

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: There is a limitation existing in classical bearing fault diagnosis that it is required to build different target models to fit varying working conditions. This paper proposes a spectral centroid transfer learning model, which transfers the source working condition domain to target working condition domain; the modeling cost for target working condition domain is reduced and the universality of bearing fault diagnosis model is enhanced. Firstly, the frequency spectrum similarity measure (FSSM) value between the two working conditions domains is calculated and the source working condition domain with near distance is sorted and selected as the initial training set. Then, during iteration process, the samples whose spectral centroid mean distances are relatively far from that of the training set are removed, and the same quantity of label less samples from target working condition domain are added to training set. The iteration finishes when the spectral centroid mean distances of both the working conditions domains are equal. Here the fault categories are determined by the outputs of two sub-classifiers: The support vector machine (SVM) and the logistic regression (LR) based sub-classifiers. The experiment results on Spectra Quest geared drive train show that the diagnostic performance of the proposed model is significantly better than that of non-transfer model when the rotation speed or load changes. Meanwhile, some indexes, including the number of replaced samples, the diagnostic accuracy, the FSSM index and the time consumption can be utilized to evaluate the quality of the source working condition domain. Thus, the proposed model possesses a potential value in solving bearing fault diagnosis issue under varying working conditions.

Keywords: spectral centroid; transfer learning; bearing fault diagnosis; frequency spectrum similarity measure

0 引言

轴承作为机械传动系统的关键部件之一,其性能对整个系统保持长期稳定运行起着决定性作用,而不确定的工况因素则会对其寿命产生影响^[1]。相关学者已运用大量技术手段以解决变工况条件下旋转轴承故障诊断的问题,手段之一为结合多种故障诊断模型,以达到将各方法优势互补的目的,李军等^[2]结合经验模态分解(empirical mode decomposition, EMD)和互信息法以有效剔除虚假分量,从而突显故障信号特征;姜战伟等^[3]结合参数优化变分模态分解(parameter optimized variational mode decomposition, POVMD)和包络阶次谱以寻求适应变工况滚动轴承模型。其他学者则采用另一手段,倾力改进单一算法以匹配变工况条件提升诊断性能,如支持向量机^[4](support vector machine, SVM)和神经网络^[5]算法等;Lu 等^[6]改进构建了一种全波信号增强随机共振模型;张锐戈等^[7]分析了滚动轴承振动加速度信号双谱特征,两者均能实现变载荷、变转速环境的滚动轴承故障诊断。但是目前大部分变工况轴承诊断模型仍受限于 2 个条件^[8]:1) 模型需要建立在已知的变工况条件下,不确定的工况将使模型难有成效;2) 需要建立不同的模型以适应不同的工况,面对新工况需重新建模,资源消耗较大。

为克服上述局限性,大多研究者采用提升变工况建模效率的途径以优化资源利用,熊邦书等^[9]将周期能量特征和优化的局域均值分解(local mean decomposition, LMD)特征结合以缩短变工况神经网络训练时间,但方法仍需重新建模,故复杂度较高。本文受迁移学习^[10-12]研究启发,将开辟另一途径解决变工况建模问题:利用谱质心迁移将源工况领域模型经过迁移训练后直接应用至目标工况领域模型,最终降低训练成本,节省建模资源。

1 变工况领域适应性

1.1 变工况迁移基本模型

所构建的变工况迁移基本模型如图 1 所示,其将源工况领域经过迁移训练后直接应用至目标工况领域模型,其中前者可来自建好的多个模型,后者来自需要应用的场景模型,源工况领域和目标工况领域的数据或分布特征具有差异。非迁移故障诊断模型仅利用目标工况领域数据建立目标诊断模型,而迁移故障诊断模型则可在目标工况领域数据量较少时加入源工况领域数据集,以帮助前者建模以提升故障诊断性能。变工况迁移基本模型能够实施有如下 2 个前提:1) 源工况领域与目标工况领域特性较为接近,有能力迁移至目标工况领域,故需要提前实施领域适应性判别以选取源工况领域;2) 目标工

况领域数据量不足,应用非迁移故障诊断模型难以达到符合要求的效果。

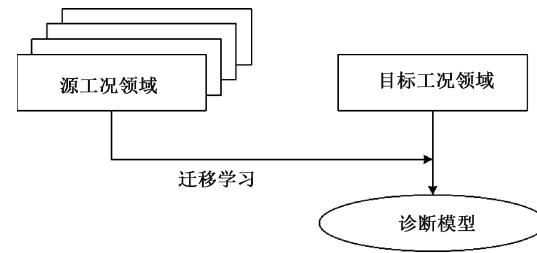


图 1 变工况迁移基本模型

Fig.1 Basic transfer model for variable working conditions

1.2 变工况对领域适应性的影响

为描述变工况对领域适应性的影响,对一般轴承系统受力分析,沿轴承周围的载荷分布 $q(t)$ 呈各向异性,表示如下^[13]:

$$q(t) = q_{\max} \left[1 - \frac{2x_m}{2x_m - c_d} (1 - \cos(2\pi f_{ir} t)) \right]^n$$

$$\varphi_{\max} = \arccos[c_d / 2x_m] \quad (1)$$

式中: x_m 为最大形变; c_d 为径向间隙; f_{ir} 为轴承转动频率; φ_{\max} 为负载区域的最大边界角。由式(1)可以看出,载荷的周期性特征与转速有关,其载荷分布角度与最大形变或径向负载有关。

实际工业环境中,由于人员操作和环境因素的不确定性,轴承系统的转速和径向负载无法提前预知,工况变化具有不确定性,前者主要导致载荷分布的频域差异性,后者导致其时域差异性。图 2 所示为变工况周期性故障冲击的领域差异性仿真,可见其对故障冲击的特定频谱有显著影响,故特定频谱指标能表征其领域适应性。

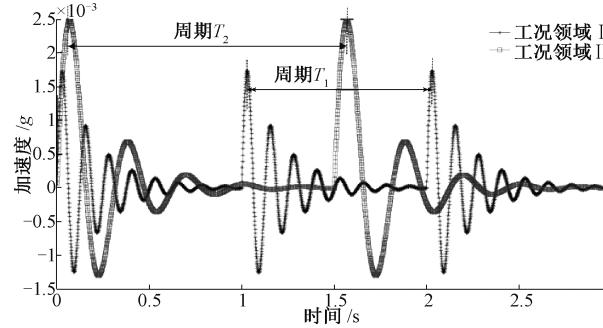


图 2 变工况周期性故障冲击的领域差异性

Fig.2 The domain differences of periodic fault shock under varying working conditions

1.3 领域适应性及源工况领域选择

为提升后续迁移性能,事先需对源工况领域和目标工况领域实施相似度计算,只有领域适应性足够强的源

工况领域模型才被考虑迁移,否则会产生负迁移^[14],领域适应性计算流程如图 3 所示。

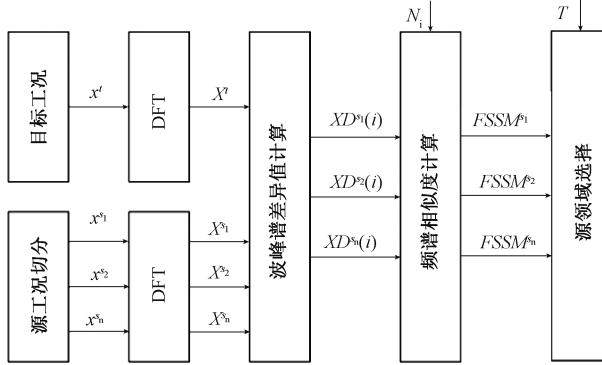


图 3 领域适应性计算流程

Fig.3 Computational flowchart of domain adaptation

首先,对于源工况领域一维振动信号 \mathbf{x}^s , 切分成等长小窗口信号,在每个窗口内,其工况可视为一致。

$$\mathbf{x}^s = [\mathbf{x}^{s_1}, \mathbf{x}^{s_2}, \dots, \mathbf{x}^{s_n}] \quad (2)$$

其次,对目标工况领域振动信号 \mathbf{x}^t 和每个窗口的源工况领域振动信号,利用离散傅里叶变换^[15](discrete fourier transform, DFT)分别提取其频域信息,如下:

$$\mathbf{X}(k) = \sum_{n=0}^{N-1} \mathbf{x}(n) e^{-j\frac{2\pi}{N}nk} \quad (3)$$

$$|\mathbf{X}(k)| = \sqrt{R^2(k) + I^2(k)} \quad (4)$$

式中: $\mathbf{x}(n)$ 为时域信号; $\mathbf{X}(k)$ 为频域信号; $|\mathbf{X}(k)|$ 为幅度谱; $R(k)$ 为 $\mathbf{X}(k)$ 的实部; $I(k)$ 为 $\mathbf{X}(k)$ 的虚部。

考虑到 \mathbf{x}^s 和 \mathbf{x}^t 间差异性,本文借助低频分量的幅度谱以计算领域适应性,设 \mathbf{X}' 为目标工况领域的频谱, \mathbf{X}^s 为第 n 个源工况领域的频谱,则第 i 个波峰的频谱差异为:

$$XD^s(i) = |\mathbf{X}'(i) - \mathbf{X}^s(i)| \quad (5)$$

由于轴承系统振动有用信号主要分布在低频域,DFT 频谱随频率升高而急剧降低,故计算频谱相似度时,高频分量的贡献低于低频分量,最终得到 \mathbf{x}^s 和 \mathbf{x}^t 间频谱相似度^[16] $FSSM(s_n, t)$ 为:

$$FSSM(s_n, t) = \sum_{i=0}^{N_i} \frac{|\mathbf{X}'(i) - \mathbf{X}^s(i)|}{|\mathbf{X}'(i)| + |\mathbf{X}^s(i)|} \quad (6)$$

其中, $FSSM(s_n, t)$ 值越小, 源工况领域 s_n 和目标工况领域 t 之间的相似度越高, \mathbf{X}' 的领域适应性越强; N_i 为选取的波峰数, N_i 越大计算耗时越长,因此可采用频率能量累积函数来分析前 N_i 次频谱能量占总能量的比率,以确定最优 N_i , 计算如下。

$$P(N_i) = \frac{\sum_{i=0}^{N_i} |MS_i(i)|}{\sum_{i=0}^N |MS_i(i)|} \times 100\% \quad (7)$$

式中: N 为总波峰数; $P(N_i) > 99\%$ 时, N_i 被选取。

2 谱质心迁移学习模型

2.1 谱质心及其频率加权

根据谱质心定义,设信号频率范围为 $f_1 \sim f_2$,则离散傅里叶频谱的质心 f_{sc} 计算公式^[17]为:

$$f_{sc} = \frac{\sum_{f_i=f_1}^{f_i=f_2} f_i S(f_i)}{\sum_{f_i=f_1}^{f_i=f_2} S(f_i)} \quad (8)$$

式(8)表明, f_{sc} 指各频率与该点能量分布概率值的乘积和,其表征能量重心。谱质心特征具有良好的鲁棒性,其几乎不受背景噪声的影响,因此已被成功应用于如语音识别^[18]、噪声识别^[19]等领域。而轴承振动信号中,有效频率中心在特定故障的低频段集中,故不同工况下定义的谱质心差异性不明显,为便于分析,本文采用式(9)所示的频率加权的谱质心公式,其相比式(8)区分性更强。

$$f'_{sc} = \frac{\sum_{f_i=f_1}^{f_i=f_2} f_i S(f_i)}{\sum_{f_i=f_1}^{f_i=f_2} S(f_i)} \quad (9)$$

2.2 谱质心迁移思想

现有的迁移学习模型主要包括 4 类:1) 基于样本权重迁移模型^[20];2) 基于特征映射的迁移模型^[21-22];3) 基于半监督的迁移模型^[23-24];4) 基于神经网络的迁移模型^[25-26]等。本文所提的谱质心迁移学习属于第一类,其主要思想是在源工况领域中调整样本权重或剔除劣质样本以增强目标工况领域的匹配性,其方法流程如图 4 所示。

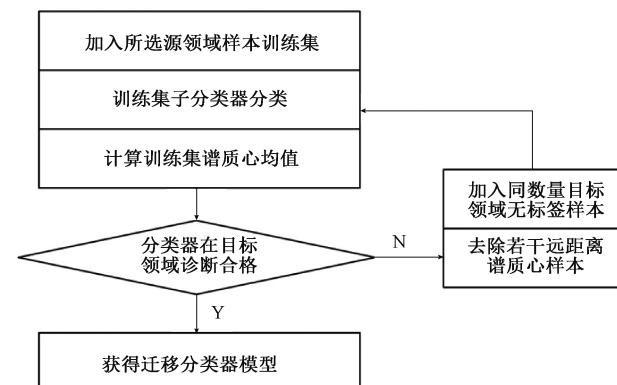


图 4 谱质心迁移流程

Fig.4 Flow chart of spectral centroid transfer strategy

该流程表明,谱质心迁移思想主要利用目标工况领域未标注的数据更新训练集,使其和目标工况领域逐渐

靠近。初始化时,训练集为所选源工况领域有标签样本。迭代过程中,首先去除分类器中谱质心距离测试集中心较远的样本,并向集中加入可信度高且靠近中心的无标签目标领域样本,直至分类器谱质心均值与目标工况领域一致,完成迁移。

2.3 训练集和测试集

该迁移模型中,训练集和测试集分别定义如下。

1) 训练数据集: $\mathbf{T} = \{(\mathbf{c}_1^s, l_1^s), (\mathbf{c}_2^s, l_2^s), \dots, (\mathbf{c}_n^s, l_n^s)\}$, 其中样本 $\mathbf{c}_j^s = \{c_1, c_2, \dots, c_{N_s}\}$, l_j^s 为 \mathbf{c}_j^s 的故障类别, s 表示源工况领域, $1 \sim n$ 为样本编号, $c_1 \sim c_{N_s}$ 为前 N_s 波峰频谱能量。

2) 测试数据集: $\mathbf{S} = \{\mathbf{c}_1^t, \mathbf{c}_2^t, \dots, \mathbf{c}_m^t\}$, t 表示目标工况领域, $1 \sim m$ 为样本编号。

选取样本数 n 和 m 时需充分评估,若 n 过大,则即使 m 全部加入,训练集中仍有大量劣质样本存在,若 n 过小,则可能导致源工况被目标工况领域样本全部替换,两者均失去迁移学习价值。

2.4 谱质心迁移算法

根据图 4 的谱质心迁移流程,算法核心在于保证迭代过程中加入的目标工况领域样本标签的可靠性,故采用逻辑回归^[27](logistic regression, LR) 和 SVM 2 子分类器协同分类,前者通过采用 Logistic 函数将自变量映射到不同的分类标签上,属于局部分类,而后者通过计算输出最优超平面以划分不同类别,属于全局分类,将两者同时引入到谱质心迁移模型的目的在于从局部和全局角度有效判定引入样本的同类性和剔除样本的异类性,谱质心迁移算法的步骤如下。

1) 初始化训练数据集: $\mathbf{T}_0 = \{\mathbf{c}_1^s, \mathbf{c}_2^s, \dots, \mathbf{c}_n^s\}$, 其中样本 $\mathbf{c}_j^s = \{c_1, c_2, \dots, c_{N_s}\}$, s 表示源工况领域, $1 \sim n$ 为样本编号, $c_1 \sim c_{N_s}$ 为前 N_s 波峰频谱能量。

2) 对有标签的训练集 \mathbf{T}_r 采用逻辑回归和支持向量机算法,得到 2 个分类器 C_r^L 和 C_r^S ,并计算其在测试集 $\mathbf{S} = \{\mathbf{c}_1^t, \mathbf{c}_2^t, \dots, \mathbf{c}_m^t\}$ 上的结果, t 表示目标工况领域, $1 \sim m$ 为样本编号。

3) 计算 \mathbf{T}_r 中所有标注样本的谱质心和训练集的谱质心均值,剔除 k 个距离谱质心均值较远的样本,距离公式为:

$$\mathbf{D}(i) = \sqrt{\sum_{i=1}^n [f'_{sc}(\mathbf{T}_r(i)) - f'_{sc}(\mathbf{T}_r)]^2} \quad (10)$$

式中: $f'_{sc}(\mathbf{T}_r(i))$ 为第 i 标注样本的谱质心; $f'_{sc}(\mathbf{T}_r)$ 为训练集的谱质心均值。

4) 样本剔除: 第 r 次迭代时对训练集中所有样本的 $\mathbf{D}(i)$ 值进行排序,选择排列距离最远的 k/l 个样本剔除出训练样本集。

5) 样本加入: 针对每种故障类型 $1 \sim l$, 从目标领域数据集中平均选择 k/l 个样本加入各自训练集,选取时故

障类型 $1 \sim l$ 由逻辑回归和支持向量机 2 子分类器同时确定,输出一致时则该样本被选取,不一致时该样本被放弃,重新选取,直至样本更新数量达到 k/l , l 为故障类别数, k 为选取的总样本数。

6) 分类器在目标领域诊断存在 2 个合格条件,达到其一即结束迭代。

(1) 精度达标,2 个分类器 C_r^L 和 C_r^S ,其对目标领域所有样本诊断结果重合率 Rc 超过设定阈值 Rc^t , Rc 计算如下:

$$Rc = \frac{mc}{m} \times 100\% \quad (11)$$

式中: mc 为分类器 C_r^L 和 C_r^S 对同一样本输出分类结果相同的目标领域样本数, m 为当前迭代中目标领域总样本数, 阈值 Rc^t 初始设定为 90%, 且扫描 80% ~ 99% 范围, 其取决于精度和可接受算法时间的平衡值。

(2) 精度未达标但加入的目标样本足够影响训练集输出结果,即若目标领域谱质心均值与训练集谱质心均值差异小于 1%, 计算如下:

$$\frac{\left[\frac{1}{n} \sum_{i=1}^n \mathbf{D}_s^r(i) - \frac{1}{m} \sum_{i=1}^m \mathbf{D}_t^r(i) \right]}{\frac{1}{m} \sum_{i=1}^m \mathbf{D}_t^r(i)} < 0.01 \quad (12)$$

式中: \mathbf{D}_s^r 代表第 r 次迭代的训练领域; \mathbf{D}_t^r 代表第 r 次迭代的目标领域。2 个合格条件均不满足时 $r = r + 1$, 转回步骤 2) 继续下一次迭代。

7) 结束迭代,输出 C_r^L 和 C_r^S 的表决分类结果:

$$R_j = \begin{cases} R_j(C_r^L), R_j(C_r^S) = R_j(C_r^S) \\ R_j(C_r^L), A_j(C_r^L) > A_j(C_r^S) \\ R_j(C_r^S), A_j(C_r^L) < A_j(C_r^S) \end{cases} \quad (13)$$

式中: $R_j(C_r^L)$ 和 $R_j(C_r^S)$ 为 2 个分类器在第 j 个目标工况领域样本分类结果; $A_j(C_r^L)$ 和 $A_j(C_r^S)$ 为 2 个分类器第 j 个目标领域临近区域内源工况领域的分类精度。

2.5 谱质心迁移性能评估指标

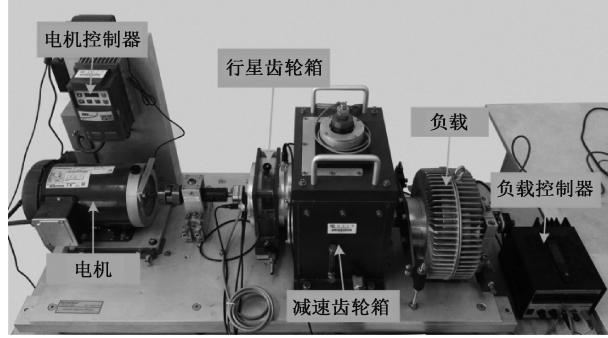
对于谱质心迁移算法的性能评估,本文主要采用如下指标,1) 源工况领域被替换样本数 N_m , 表示训练数据集 T 被测试数据集 S 替换的样本个数, $0 \leq N_m \leq n$, N_m 越大则领域适应性越差; 2) 迭代次数, 迭代次数越多则源工况领域适应性越差; 3) 迭代过程中训练集和测试集的谱质心距离, 其能够表征未被替换的训练集样本质量, 将在试验部分阐述。

3 实验研究与性能分析

3.1 实验系统与数据集

如图 5 所示, 谱质心迁移试验所用轴承数据来自 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等部分组成,608A11振动传感器分别安装在行星齿轮箱,减速齿轮箱的三轴方向上,故障轴承设定在减速齿轮箱的第二级传动轴或行星齿轮箱的第二级行星轴上,轴承故障类型及其试验条件如表1所示。1)就系统代表性而言,该系统包含电机、一级行星齿轮箱、二级减速齿轮箱以及负载等子系统,为通用齿轮箱传动模型,能代表大部分实际的机械传动系统;2)就算法适用性而言,系统包含多转速、多负载、多采集位置及多故障点,可实施不同工况间的迁移以评估所提故障诊断算法的性能。



(a) 系统实物
(a) The photo of the system

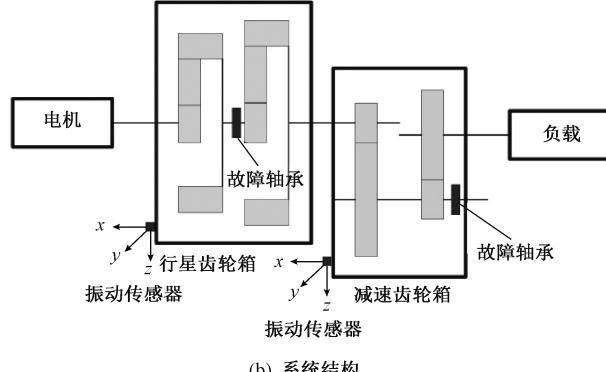


图5 Spectra Quest 齿轮传动系统

Fig.5 Spectra Questgeared drivetrain

表1 轴承故障类型及其试验条件

Table 1 The bearing fault types and its test conditions

轴承故障	内圈磨损 (C1)	外圈磨损 (C2)	滚珠磨损 (C3)	内外磨损 (C4)	健康轴承 (C5)
转速控制	20 Hz (D1)	30 Hz (D2)	40 Hz (D3)	50 Hz (D4)	-
负载扭矩	0 N·m (E1)	3.657 N·m (E2)	7.315 N·m (E3)	10.97 N·m (E4)	14.63 N·m (E5)
故障轴承	行星齿轮箱 (F1)	减速齿轮箱 (F2)	-		

3.2 领域适应性试验

1) 试验设定

领域差异性试验中,对于目标工况领域采用表1的如下工况: $T_1 = \{D_2, E_2, F_2\}$, 其含义为转速 30 Hz, 负载扭矩 7.315 N·m 工况条件下的减速箱轴承故障; 源工况领域采用如下 8 种工况: $S_1 = \{D_1, E_2, F_2\}$, $S_2 = \{D_3, E_2, F_2\}$, $S_3 = \{D_4, E_2, F_2\}$, $S_4 = \{D_2, E_1, F_2\}$, $S_5 = \{D_2, E_3, F_2\}$, $S_6 = \{D_2, E_4, F_2\}$, $S_7 = \{D_2, E_5, F_2\}$, $S_8 = \{D_2, E_2, F_1\}$, 即每种源工况领域改变目标工况领域 3 个条件之一。

2) 试验结果与分析

图6所示为 $N_i = 5$ 时的 T_1 以及 $S_1 \sim S_8$ 的归一化实-虚部二维频谱图(故障类别均为外圈磨损),其中横坐标为归一化的实部幅值,纵坐标为归一化的虚部幅值。图6可见,变转速条件下(S_1, S_2 和 S_3),源工况领域的二维频谱的峰值数量与目标工况领域具有显著差异; 变负载条件下(S_4, S_5, S_6 和 S_7),源工况领域和目标工况领域的二维频谱噪声具有差异; 变对象条件下(S_8),两者的二维频谱其峰值数量和噪声均有差异。表2所示为 $N_i = 5$ 时,8 种源工况领域与目标工况领域 T_1 的 FSSM 值,其进一步表明变工况对提取特征的影响排序为: 变负载<变转速<变对象,即变负载影响相对最小,同时可知在同一影响因素下,源工况领域越远离目标工况领域时,其 FSSM 值越大,对表2排序后,选用 S_4 源工况领域作为训练集初始样本。

表2 源工况领域与目标工况领域 T_1 间 FSSM 指标

Table 2 FSSM indices between source working condition domains and target working condition domain T_1

领域	FSSM	领域	FSSM
$S_1 \sim T_1$	0.788 2	$S_5 \sim T_1$	0.578 4
$S_2 \sim T_1$	0.691 1	$S_6 \sim T_1$	0.589 5
$S_3 \sim T_1$	1.342 5	$S_7 \sim T_1$	0.663 0
$S_4 \sim T_1$	0.337 6	$S_8 \sim T_1$	2.772 1

为确定峰值数量 N_i ,表3所示为 S_4 数据集中 5 种故障类型(C1~C5)的频谱能量大于 99% 的频率位置及相应值,由表3可知,当轴承发生故障时,频率能量向低频域集中,而健康轴承在高频能量较为分散,故根据 C5 选取最优波峰数 $N_i=11$ 。

表3 频谱能量大于 99% 的频率位置及能量值

Table 3 The frequency position and its spectrum energy for the frequency with spectrum energy greater than 99%

故障类型	C1	C2	C3	C4	C5
N_i	8	6	7	7	11
$P(N_i)/\%$	99.21	99.07	99.26	99.18	99.04

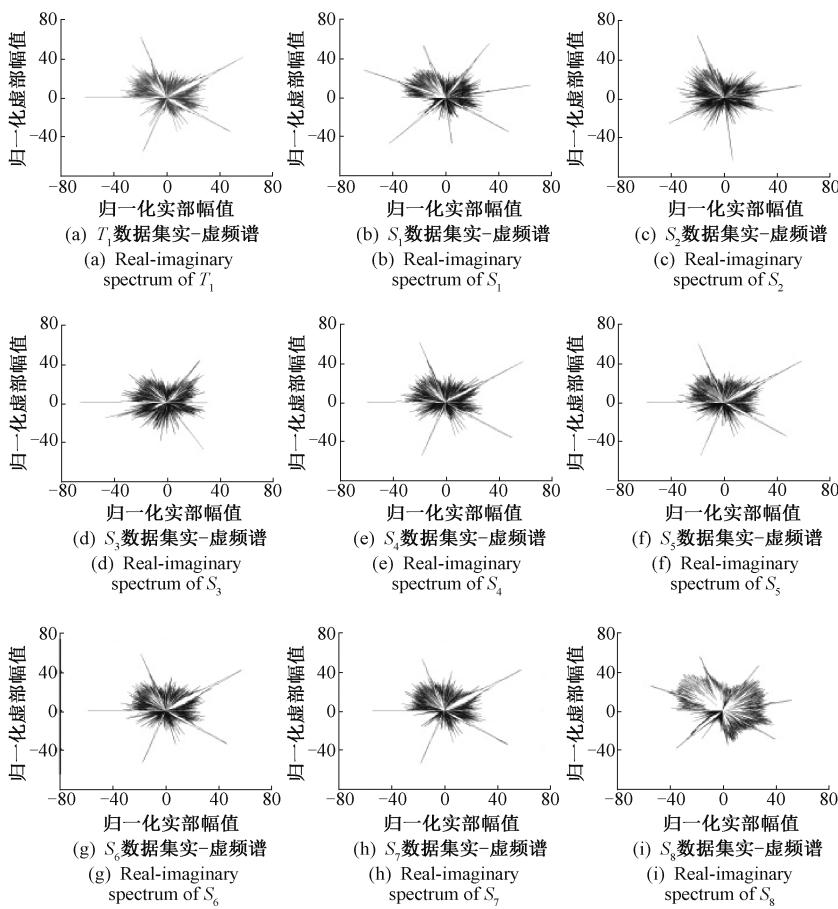


图 6 九种工况领域归一化实-虚频谱

Fig.6 Normalized real-imaginary spectrum diagrams for nine working condition domains

相比变转速、变负载而言,诊断对象的变化使得迁移的不确定性增加,故试验增加一条目标工况领域: $T_2 = \{D_2, E_2, F_1\}$,其源工况领域采用如下8种工况: $S_0 = \{D_1, E_2, F_1\}$, $S_{10} = \{D_3, E_2, F_1\}$, $S_{11} = \{D_4, E_2, F_1\}$, $S_{12} = \{D_2, E_1, F_1\}$, $S_{13} = \{D_2, E_3, F_1\}$, $S_{14} = \{D_2, E_4, F_1\}$, $S_{15} = \{D_2, E_5, F_1\}$, $S_{16} = \{D_2, E_2, F_2\}$ 。表4所示为 $N_i = 5$ 时,8种源工况领域与目标工况领域 T_2 的 FSSM 值,与表2相比(0.970 3),表4的平均 FSSM 值偏大(1.088 3),证明针对减速齿轮箱对象的迁移学习易于针对行星齿轮箱对象的迁移学习,这是由于前者结构更为简单且更具通用性,同时对表4实施排序,可选用 S_{12} 源工况领域作为训练集初始样本,与表2中的 S_4 源工况领域一致。

表 4 源工况领域与目标工况领域 T_2 间 FSSM 指标Table 4 FSSM indices between source working condition domains and target working condition domain T_2

领域	FSSM	领域	FSSM
$S_8 \sim T_2$	0.948 3	$S_{13} \sim T_2$	0.709 2
$S_{10} \sim T_2$	0.821 7	$S_{14} \sim T_2$	0.790 3
$S_{11} \sim T_2$	1.488 0	$S_{15} \sim T_2$	0.862 5
$S_{12} \sim T_2$	0.479 4	$S_{16} \sim T_2$	2.606 8

3.3 谱质心迁移故障诊断试验

1) 试验设定

谱质心迁移故障诊断主要试验如下:1) 单一变工况性能试验,其试验数据集选用为目标工况领域 $T = \{D_2, E_2, F_2\}$,无标签样本数量 50,源工况领域 $S_2 = \{D_3, E_2, F_2\}$ 和 $S_4 = \{D_2, E_1, F_2\}$,有标签样本数量 200;2) 复杂变工况性能试验,其试验数据集选用图 7 所示的变转速曲线,图中采用“滑动窗口”选取目标工况领域和源工况领域,前者为当前实时数据集,后者为最接近当前时刻的历史数据集;3) 性能评估试验,其主要利用几类性能评估指标对所提方法迁移性能实施评估,同时与 SVM、K 最近邻(K-nearest neighbor, KNN)以及 TrAdaBoost 算法诊断性能进行比较,其中 SVM 和 KNN 中仅采用 50 个目标工况领域样本直接分类,TrAdaBoost 算法的源工况领域有标签样本数量为 200。

2) 试验结果与分析

(1) 单一变工况性能试验

单一变工况性能试验中,源工况领域和目标工况领域均为单一领域,表 5 所示为源工况样本数量为 200 时变转速和变负载故障诊断试验结果,表中精确率 $Pr(C_i)$

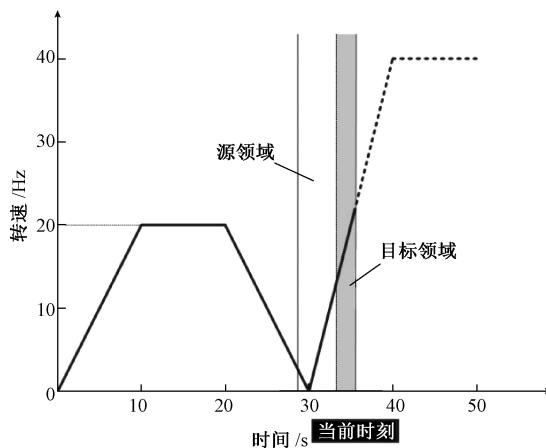


图7 变转速曲线及其领域选择

Fig.7 The variable rotation speed curve and its domain selection

和查全率 $Re(C_i)$ 计算如下:

$$Pr(C_i) = \frac{C_i \text{类中分类正确样本数}}{\text{所有 } C_i \text{类样本总数}} \times 100\%$$

$$Re(C_i) = \frac{C_i \text{类中分类正确样本数}}{\text{被分为 } C_i \text{类样本总数}} \times 100\% \quad (14)$$

由表 5 可以得到如下结论,1) 通过对比 $S_2 \sim T_1$ 和 $S_4 \sim T_1$ 谱质心迁移结果,可见后者的诊断性能优于前者,符合变负载源领域 FSSM 值更小的预期判断;2) 2 项试验中,组合故障的识别率(92.00%、93.78%)低于其他故障类别,证明方法对内外磨损故障比较敏感,更适用于单故障诊断,诊断组合故障性能较弱;3) $S_2 \sim T_1$ 试验的迭代次数 48, $S_4 \sim T_1$ 试验迭代次数 26, 可见变负载能够改变时域信号噪声特征,但对谱质心的影响较小,故方法更适用于环境因素变化的诊断。

表5 变工况谱质心迁移故障诊断结果

Table 5 Fault diagnosis results with spectral centroid transfer under varying working condition (%)

故障类别	$S_2 \sim T_1$		$S_4 \sim T_1$	
	Pr	Re	Pr	Re
C1	93.13	99.02	98.12	98.33
C2	95.56	99.04	95.80	96.21
C3	97.69	92.41	96.05	93.42
C4	92.00	89.13	93.78	90.40
C5	99.23	94.52	98.99	93.33
总体	95.53	94.82	96.55	94.34

作为比较,针对目标工况 T_1 和 T_2 , 表 6 和 7 分别给出了 SVM、KNN 以及 TrAdaBoost 方法在相同条件下的试验结果,在 T_1 试验中,相比 SVM、KNN 等仅利用目标工

况领域数据,引入源工况领域样本能提升 18.85% 综合诊断精度。在 T_2 试验中,SVM、KNN 性能与 T_1 试验相近,这是由于两者均未采用迁移思想,而从 TrAdaBoost 和所提谱质心迁移结果来看,针对减速齿轮箱对象的迁移学习精度(95.31%)高于针对行星齿轮箱的精度(92.57%),进一步证实了 3.2 节中对前者迁移易于后者的初步判断。

表6 T_1 变工况诊断结果比较

Table 6 Comparison of diagnosis results in varying working condition for T_1 (%)

诊断方法	$S_2 \sim T_1$		$S_4 \sim T_1$	
	Pr	Re	Pr	Re
SVM	80.13	76.01	84.52	89.70
KNN	77.99	74.42	80.62	79.44
TrAdaBoost	94.01	95.16	96.77	93.12
所提方法	95.53	94.82	96.55	94.34

表7 T_2 变工况诊断结果比较

Table 7 Comparison of diagnosis results in varying working condition for T_2 (%)

诊断方法	$S_{10} \sim T_2$		$S_{12} \sim T_2$	
	Pr	Re	Pr	Re
SVM	79.83	77.08	83.95	90.12
KNN	79.02	75.33	81.17	80.20
TrAdaBoost	91.45	94.68	92.01	92.76
所提方法	89.17	93.74	93.08	94.28

为进一步比较现有迁移模型(TrAdaBoost 算法)和所提模型的性能,针对目标工况 T_1 ,表 8 所示为前者在相同条件下的诊断细节,对比表 5 可以得到如下结论,1)就诊断性能而言,虽然所提方法与现有模型在总体精度上相近(仅提升 0.54%),但就不同类别(C1~C5)而言,现有模型的每类单独分类精度取决于已知标签目标样本的质量,试验中设定 C2 类别已知标签目标样本质量较高(即接近总体训练集特性),C3 类别已知标签目标样本质量较低(即远离总体训练集特性),最终 C2 类别具有较高单独分类精度(98.17%),C3 具有较低单独分类精度(91.47%),因此具有人为选择性,而所提模型虽然对内外磨损故障比较敏感,更适用于单故障诊断,诊断组合故障性能较弱,但其单独分类精度取决于故障类型本身,无人为选择性;2)就模型实用性而言,现有模型利用部分已知标签的目标数据,故实用性不及所提方法。

表8 TrAdaBoost的 T_1 变工况迁移故障诊断细节Table 8 Fault diagnosis details of TrAdaBoost transfer model in varying working condition for T_1 (%)

故障类别	$S_2 \sim T_1$		$S_4 \sim T_1$	
	P_r	Re	P_r	Re
C1	93.46	96.07	95.99	94.05
C2	98.17	97.89	99.21	97.42
C3	90.39	91.92	95.14	88.44
C4	93.15	94.84	96.99	92.22
C5	94.88	95.08	96.52	93.47
总体	94.01	95.16	96.77	93.12

(2) 复杂变工况性能试验

复杂变工况性能试验中,针对谱质心迁移,变转速曲线采用如图7所示的变转速曲线和“滑动窗口”法选取源工况领域和目标工况领域,其中前者样本数量为250,后者样本数量为50,针对SVM,训练域样本数量为300,得到2条50 s变转速滑动诊断精度曲线如图8所示。由图8可见,无论是迁移模型还是非迁移模型,当选择窗滑动至转速变化率较快处时(38 s),此时源工况领域与目标工况领域差异性较大,得到的诊断性能较低(迁移正确率86.73%);当选择窗滑动至转速变化率较快处时(18、48 s),此时源工况领域与目标工况领域特性一致,得到的诊断性能较高(迁移正确率97.71%、98.66%)。对比谱质心迁移和支持向量机模型,可看出源工况领域与目标工况领域差异性较小时,两者精度较高且性能接近,而源工况领域与目标工况领域差异性较大时,前者诊断性能显著高于后者,证明了迁移学习在变工况故障诊断的应用优势。

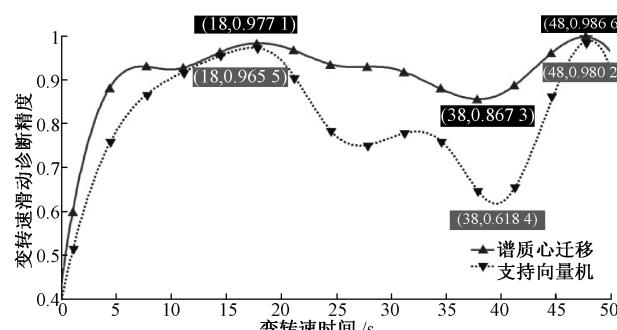


图8 变转速滑动诊断精度曲线

Fig.8 The sliding diagnostic accuracy curve for variable rotation speed

(3) 性能评估试验

首先,针对 $S_2 \sim T_1$ 的单一变工况性能试验,当源工况和目标工况样本数量均为200,即可供替代的目标样本足够时,表9所示为3个评估指标随迭代次数的变化

情况,包括源领域被替换样本数 N_m ,迭代过程中的诊断精度 A_e ,源领域与目标领域的频谱相似度FSSM以及算法耗时 t 。由表9可见, $S_2 \sim T_1$ 试验的总迭代次数48次,迭代前30次时,被替换的源工况领域样本数量达到44,诊断性能也迅速从82.45%提升至94.88%,若进一步迭代,替换数量则越来越少,精度提升也较为缓慢,但算法时间消耗呈线性增长,故需要根据不同的源工况领域数据集选择合适的迭代次数,若源工况领域相似度较小,则被替换样本数量越多,迁移性能越弱,耗时越长,谱质心迁移的价值越小。

表9 $S_2 \sim T_1$ 迭代过程的评估指标Table 9 Evaluation index table in $S_2 \sim T_1$ iteration process

迭代次数	10	20	30	40	48
N_m	23	34	44	52	55
$A_e/%$	82.45	90.27	94.88	95.32	95.53
FSSM	0.6911	0.5846	0.5623	0.5619	0.5601
t/s	3.71	7.42	11.13	14.84	18.55

其次,针对 $S_2 \sim T_1$ 单一变工况性能试验,在目标工况样本数量为50时,调整源工况领域样本数量为50~250,绘制源工况领域样本数量与诊断精度曲线如图9所示,针对 S_2 和 T_1 这2个特定数据集,当源工况领域样本数量小于125时,目标领域样本足够替换,大于125时,即使用50个目标工况样本全部替换,也无法替换源工况领域中全部劣质样本,因此当源工况领域样本较大(250)时,诊断性能显著降低(正确率76.1%),故实际应用中若源工况领域特性未知,则参考3倍于目标工况样本数量选取源工况样本数量。

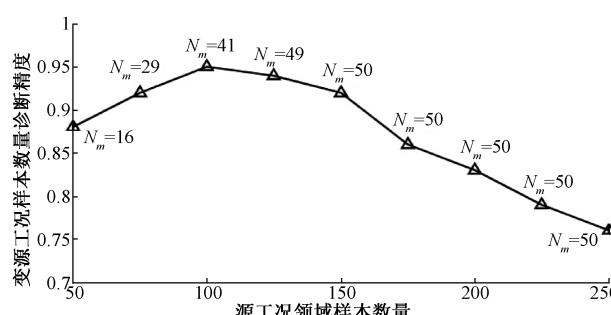


图9 源工况领域样本数与诊断精度曲线

Fig.9 The curve of diagnostic accuracy vs. the number of source domain samples

4 结 论

本文提出一种谱质心迁移学习在变工况轴承故障诊

断的应用模型,以增强轴承转速和负载发生变化时诊断模型的通用性。通过计算源工况领域与目标工况领域之间的频谱相似度,得出变负载的影响低于变转速的影响的结论。同时诊断结果证明,相比 SVM 和 KNN 等非迁移模型而言。采用谱质心迁移将源工况领域迁移至目标工况领域能够提升 18.85% 诊断精度,故更能适应变工况环境。模型评估表明,需根据不同的选择源工况领域数据集及其样本数量,若源工况领域相似度较小,迁移性能越弱,耗时越长,谱质心迁移的价值越小。总体而言,谱质心迁移模型很好地解决了变工况轴承故障诊断的领域适应性问题,为故障诊断的工程应用提供了有价值的技术手段。

参考文献

- [1] 胥永刚,孟志鹏,赵国亮.基于双树复小波变换的轴承复合故障诊断研[J].仪器仪表学报,2014,35(2):447-452.
XU Y G, MENG ZH P, ZHAO G L. Study on compound fault diagnosis of rolling bearing based on dual-tree complex wavelet transform [J]. Chinese Journal of Scientific Instrument, 2014, 35(2):447-452.
- [2] 李军,李佳,张世义,等.采用 EEMD 算法与互信息法的机械故障诊断方法[J].华侨大学学报(自然版),2018,2018(1):7-13.
LI J, LI J, ZHANG SH Y, et al. Mechanical fault diagnosis method using EEMD algorithm and mutual information method [J]. Journal of Huaqiao University (Natural Science), 2018, 2018(1):7-13.
- [3] 姜伟,郑近德,潘海洋,等.POVMD 与包络阶次谱的变工况滚动轴承故障诊断[J].振动、测试与诊断,2017,2017(3):609-616.
JIANG ZH W, ZHENG J D, PAN H Y, et al. Fault diagnosis under variable conditions based on parameter optimized variational mode decomposition and envelope order spectrum[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 2017(3):609-616.
- [4] ISLAM M M, KIM J, KHAN S A, et al. Reliable bearing fault diagnosis using Bayesian inference-based multi-class support vector machines [J]. Journal of the Acoustical Society of America, 2017, 141(2):EL89.
- [5] PAHON E, STEINER N Y, JEMEI S, et al. Solid oxide fuel cell fault diagnosis and ageing estimation based on wavelet transform approach [J]. International Journal of Hydrogen Energy, 2016, 41(31):13678-13687.
- [6] 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.
- [7] 张锐戈,李劲.滚动轴承双谱特征提取及变工况故障诊断[J].武汉轻工大学学报,2017,36(2):57-66.
ZHANG R G, LI J. Fault diagnosis of variety operation conditions for rolling element bearings based on bispectrum feature extraction [J]. Journal of Wuhan Polytechnic University, 2017, 36(2):57-66.
- [8] 陈超,沈飞,严如强.改进 LSSVM 迁移学习方法的轴承故障诊断[J].仪器仪表学报,2017,38(1):33-40.
CHEN CH, SHEN F, YAN R Q. Enhanced least squares support vector machine-based transfer learning strategy for bearing fault diagnosis[J]. Chinese Journal of Scientific Instrument, 2017, 38(1):33-40.
- [9] 熊邦书,李龙,李新民,等.周期能量与优化 LMD 结合的轴承故障诊断方法[J].振动、测试与诊断,2016,36(2):372-377.
XIONG B SH, LI L, LI X M, et al. Combination between periodical energy and optimized LMD for bearing fault diagnosis [J]. Journal of Vibration, Measurement & Diagnosis, 2016, 36(2):372-377.
- [10] YANG L, ZHANG J. Automatic transfer learning for short text mining [J]. Eurasip Journal on Wireless Communications & Networking, 2017, 2017(1):42.
- [11] ZHOU G, ZENG Z, HUANG J X, et al. Transfer learning for cross-lingual sentiment classification with weakly shared deep neural networks [J]. 2016, 2016(1):245-254.
- [12] 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.
- [13] WHILE M F. Rolling element bearing vibration transfer characteristics: Effect of stiffness[J]. Journal of Applied Mechanics, 1979, 46(3):677-684.
- [14] 吴伊萍.机器学习中的负迁移探讨[J].赤峰学院学报(自然科学版),2010,26(8):39-42.
WU Y P. Discuss with negative transfer in machine learning [J]. Journal of Chifeng University (Natural Science), 2010, 26(8):39-42.
- [15] 杨旭霞,张毅,张鹏.基于 FFT 分析振动信号的机械故障诊断[J].山西电子技术,2015(2):6-7.
YANG X X, ZAHNG Y, ZHANG P. The mechanical fault diagnosis of vibration signal based on FFT analysis[J]. Shanxi Electronic Technology, 2015 (2): 6-7.
- [16] 姜礼平,李冬雷,季傲.基于兰氏距离的改进冲突证据合成方法[J].海军工程大学学报,2016,28(6):1-4.
JIANG L P, LI D L, JI AO. Improved conflicting

- evidence combination method based on lance williams distance[J]. Journal of Naval University of Engineering, 2016, 28(6):1-4.
- [17] 曾金芳, 滕召胜. 谱质心在电力谐波分析中的应用[J]. 中国电机工程学报, 2013, 33(31):73-80.
- ZENG J F, TENG ZH SH. Spectral centroid applications on power harmonic analysis [J]. Proceedings of the CSEE, 2013, 33(31):73-80.
- [18] GAJIC B, PALIWAL K K. Robust speech recognition in noisy environments based on subband spectral centroid histograms[J]. IEEE Transactions on Audio Speech & Language Processing, 2006, 14(2):600-608.
- [19] 李军杰, 马建仓, 柏会宁, 等. 基于谱质心直方图-SVM 的滚动轴承故障诊断[J]. 噪声与振动控制, 2014, 34(5):187-191.
- LI J J, MA J C, BAI H N, et al. Fault diagnosis of rolling bearings based on spectral centroid histograms-SVM [J]. Noise and Vibration Control, 2014, 34 (5) : 187-191.
- [20] 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 CH, YAN R Q. Application of SVD and transfer learning strategy on motorfault diagnosis [J]. Journal of Vibration Engineering, 2017, 30 (1) : 118-126.
- [21] HUSSAIN S F, BASHIR S. Co-clustering of multi-view datasets[J]. Knowledge & Information Systems, 2016, 47(3):1-26.
- [22] CHENG M, WU G, WAN H, et al. Exploiting correlation subspace to predict heterogeneous cross-project defects [J]. International Journal of Software Engineering & Knowledge Engineering, 2017, 26 (9) : 1571-1580.
- [23] YANG L, HANNEKE S, CARBONELL J. A theory of transfer learning with applications to active learning[J]. Machine Learning, 2013, 90(2):161-189.
- [24] DENG Z, CHOI K S, JIANG Y, et al. Generalized hidden-mapping ridge regression, knowledge-leveraged inductive transfer learning for neural networks, fuzzy systems and kernel methods. [J]. IEEE Transactions on Cybernetics, 2014, 44(12):2585.
- [25] 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.
- [26] 王文朋, 毛文涛, 何建樑, 等. 基于深度迁移学习的烟雾识别方法 [J]. 计算机应用, 2017, 37 (11) : 3176-3181.
- WANG W P, MAO W T, HE J L, et al. Smoke recognition based on deep transfer learning[J]. Journal of Computer Applications, 2017, 37 (11) :3176-3181.
- [27] 毛林, 陆全华, 程涛. 基于高维数据的集成逻辑回归分类算法的研究与应用[J]. 科技通报, 2013 (12) : 64-66.
- MAO L, LU Q H, CHENG T. The research and application of ensemble logistic regression classification algorithm based on high dimensional data[J]. Bulletin of Science and Technology, 2013 (12) :64-66.

作者简介



沈飞, 分别在 2014 年和 2016 年于东南大学获得学士学位和硕士学位, 现为东南大学博士研究生, 主要研究方向为机械系统故障诊断。

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 a Ph. D. candidate in Southeast University. His main research interest is mechanical system fault diagnosis.



严如强(通信作者), 分别在 1997 年和 2002 年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. Sc. degrees both from University of Science and Technology of China in 1997 and 2002, and Ph. D. degree from University of Massachusetts, Amherst, USA in 2007, respectively. 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 network.