

基于深度迁移自编码器的变工况下滚动轴承故障诊断方法

苏靖涵¹, 张潇²

(1. 南开大学 电子信息与光学工程学院, 天津 300350;
2. 徐州医科大学 医学信息与工程学院, 江苏 徐州 221008)

摘要: 在实际工业场景下的轴承故障诊断, 存在轴承故障样本不足, 训练样本与实际信号样本存在分布差异的问题; 文章提出一种新的基于深度迁移自编码器的故障诊断方法 FS-DTAE, 应用于不同工况下的轴承故障诊断; 该方法首先采用小波包变换进行信号处理与特征提取; 其次, 采用提出的基于朴素贝叶斯与域间差异的特征选取 (FSBD) 方法对统计特征进行评估, 选取更有利于跨域故障诊断和迁移学习的特征; 然后, 利用源域特征数据训练深度自编码器, 将训练得到的模型参数迁移至目标域, 再利用目标域正常状态样本对深度迁移自编码器模型进行微调, 微调后的模型用于目标域无标签特征数据的故障分类; 最后, 基于 CWRU 轴承故障数据开展不同工况下故障诊断实验, 结果表明, 所提出的 FS-DTAE 方法能够有效提高不同工况下的故障诊断准确率。

关键词: 故障诊断; 自编码器; 迁移学习; 特征选取; 变工况

Bearings Fault Diagnosis Method Based on Deep Transfer Auto-encoder Under Variable Working Conditions

SU Jinghan¹, ZHANG Xiao²

(1. College of Electric Information and Optical Engineering, Nankai University, Tianjin 300350, China;
2. College of Medical Information and Engineering, Xuzhou Medical University, Xuzhou 221004, China)

Abstract: Bearing fault diagnosis in the actual industrial scene, there are some problems, such as the lack of bearing fault samples, and the distribution difference between the training samples and the actual signal samples. A new fault diagnosis method based on deep transfer auto-encoder is proposed in this paper, which is applied to the fault diagnosis of bearings under different working conditions. Firstly, wavelet packet transform is used for signal processing and feature extraction; Secondly, the proposed feature selection method based on Naive Bayes and difference between domains (FSBD) is used to evaluate the statistical features and select the features that are more conducive to cross-domain fault diagnosis and transfer learning; the source domain feature data is used to train the deep auto-encoder, and parameters of the trained model are migrated to the target domain. Then, the normal state samples of the target domain are used to fine-tune the deep transfer auto-encoder model, and the fine-tuned model is used for fault classification of the target domain unlabeled feature data. Finally, based on the CWRU bearing fault data, fault diagnosis experiments under different working conditions are performed. The results show that the proposed FS-DTAE method can effectively improve the fault diagnosis accuracy under different working conditions.

Keywords: fault diagnosis; auto-encoder; transfer learning; features selection; variable working conditions

0 引言

在现代工业领域中, 旋转机械设备的运行状态将直接影响工业生产的进程和效率, 而作为其核心部件之一的滚动轴承发生故障将直接影响设备的安全运行, 因此, 滚动轴承的故障诊断研究对保障工业机械设备安全稳定运行具有重要意义^[1-3]。

随着传感器技术、工业互联网、数据挖掘和机器学习的快速发展, 基于人工智能数据驱动的故障诊断方法逐渐

成为研究热点^[1]。近年来, 深度学习理论作为研究热点, 由于深度学习模型具备强大的特征提取能力, 能够克服浅层学习模型的缺陷, 进而在机械故障诊断领域获得了越来越多的关注^[2-5]。然而, 面对实际工业场景下的故障诊断, 存在如下问题^[1,3,6]: (1) 由于机械设备运行工况复杂多变, 导致故障诊断模型的训练样本与实际运行过程中的轴承振动信号样本存在分布差异, 而传统的深度故障诊断模型大多假设训练样本与测试样本是相同分布。(2) 实际工况下的轴承故障样本不足。机械设备中正常状态的轴承在不同工

收稿日期: 2021-05-05; 修回日期: 2021-06-15。

基金项目: 国家重点研发计划项目(2020YFB1711500)。

作者简介: 苏靖涵(1992-), 男, 江苏徐州人, 硕士研究生, 主要从事故障诊断方向的研究。

引用格式: 苏靖涵, 张潇. 基于深度迁移自编码器的变工况下滚动轴承故障诊断方法[J]. 计算机测量与控制, 2021, 29(7): 85-90, 99.

况下运行的监测数据易获取,但若想获取不同工况下的故障数据,代价巨大。

针对上述问题,迁移学习方法在近年来逐渐获得研究者的关注,迁移学习旨在利用已有领域(源域)的知识解决不同但相关领域(目标域)的问题,包括基于样本、基于特征、基于关系和基于模型的 4 种迁移方法^[2-5]。文献 [1] 提出了一种深度在线迁移的故障诊断方法,通过建立 CNN-ISVM 预训练模型并保存参数,使在线处理新增目标数据时,无需重新训练,实验表明所提出方法能够较好实现变负载下的滚动轴承多状态在线故障分类。文献 [3] 针对轴承监测数据严重缺乏的问题,提出一种用于不同机械设备间轴承故障诊断的深度迁移自编码器模型,采用可缩放指数型线性单元作为自编码器的激活函数,修正代价函数来降低重构误差,最后采用不同设备中的轴承开展实验,验证了所提出方法的有效性与适应性。文献 [6] 利用稀疏自编码器构建深度迁移学习模型,用于不同载荷工况下的轴承故障诊断。文献 [7] 针对不同设备,提出了一种增强深度自编码器用于跨域故障诊断,实验分析表明,所提出的方法能够表现出更优的故障诊断性能。然而,上述文献中的故障诊断方法关注于深度模型的迁移,而未考虑特征间分布差异和判别性能对深度模型迁移后的故障分类影响。对此,本文提出一种新的变工况下滚动轴承故障诊断框架,首先,利用小波包变换(WPT, wavelet packet transform)处理原始信号,进行统计特征提取,构建源域和目标域特征样本;其次,利用源域带标签样本与目标域正常状态样本,综合考虑特征的判别性能和域间分布差异,选取更有利于跨域故障诊断的特征构建源域特征子集;然后,利用源域特征子集训练深度自编码器(DAE, deep auto encoder),将模型参数直接迁移至目标域,在微调阶段,利用源域带标签特征样本与目标域正常状态特征样本进行迁移学习,获得深度迁移模型;最后,诊断模型对目标域无标签特征样本进行识别分类,输出故障诊断结果。

1 基于朴素贝叶斯与域间差异的特征选取

1.1 朴素贝叶斯算法

朴素贝叶斯算法是一种基于贝叶斯定理的数据分类方法,其通过贝叶斯公式对已有样本数据的类别进行判别^[9]。贝叶斯公式如下:

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (1)$$

式中, $P(A | B)$ 表示 A 在 B 条件下的后验概率; $P(B | A)$ 表示 B 在 A 条件下的后验概率; $P(A)$ 和 $P(B)$ 均为先验概率; 朴素贝叶斯算法分类的原理是将事件的先验概率和后验概率相联系,并利用先验信息预测事件的后验概率。

假设有训练样本为 $X = \{x_1, x_2, \dots, x_n\}$, 每个样本对应的类别为 $y(x_i) \in C$, 其中 $SSTD(k) = \sum_{i=1}^M SSTD_i^k$ 为类别集合, $T = \{t_1, t_2, \dots, t_n\}$ 为测试样本。则测试样本 T 类别为 $WSDR(k) = \frac{WV(k)}{SSTD(k)}$ 的后验概率为:

$$P(c_j | t_1, t_2, \dots, t_n) = \frac{P(t_1, t_2, \dots, t_n | c_j)P(c_j)}{P(t_1, t_2, \dots, t_n)} \quad (2)$$

式中, $P(t_1, t_2, \dots, t_n | c_j)$ 为故障类型 $a_i \in R^m$ 的条件概率; 式中 $P(c_j)$ 为 $R^d (d < m)$ 的先验概率。根据得到的样本 T 归属各类别的后验概率, 概率大的类别即为最终类别。注意, 朴素贝叶斯假设各属性变量间相互独立, 因此, 式 (1) 中的可以变换为:

$$P(c_j | t_1, t_2, \dots, t_n) = \frac{P(c_j) \prod_{i=1}^n (P(t_i | c_j))}{P(t_1, t_2, \dots, t_n)} \quad (3)$$

1.2 最大均值差异

在基于特征的迁移学习中, 最大均值差异 (Maximum mean discrepancy, MMD) 被常应用于度量不同域数据间分布差异^[2,10]。给定源域特征样本 X_S 与目标域特征样本 X_T , 有 $P_T(X_T) \neq P_S(X_S)$, 则两个域间的边缘分布差异有:

$$MMD(X_S, X_T) = \left\| \frac{1}{n_S} \sum_{x_i \in X_S} \varphi(x_i) - \frac{1}{n_T} \sum_{x_j \in X_T} \varphi(x_j) \right\|_H^2 \quad (4)$$

式中, φ 为再生核 Hilbert 空间 H 中的非线性映射函数, n_S 与 n_T 分别为源域与目标域的样本数。

1.3 基于朴素贝叶斯与域间差异的特征选取 (FSBD)

从原始特征集中选取更有利于跨域故障诊断的特征用于深度模型的训练和迁移, 本文提出基于朴素贝叶斯与域间差异的特征选取方法 (FSBD), FSBD 从两方面角度评价特征, 特征的判别性能和特征在不同域间的分布差异。我们认为, 判别性能高且在不同域间的分布差异小的特征更有利于跨域故障诊断和深度模型的迁移。

给定工况 1 下的带标签轴承特征样本作为源域 X_S , 工况 2 下的正常状态特征样本和无标签故障特征样本作为目标域 X_T 。源域与目标域样本中均包含 M 种故障类型 (包括正常状态), 每种故障类型有 N 个样本, 每个样本有 K 种特征。本节中, 对于特征判别性能的评估, 利用朴素贝叶斯算法对源域中每种特征样本进行分类, 得到的分类精度作为表征特征判别性能的指标。对于特征在不同域间分布差异的度量, 利用 MMD 度量源域和目标域中正常状态下的特征样本的边缘分布差异。最后, 基于朴素贝叶斯算法的分类精度和特征的 MMD 值, 构建新的特征选取指标 FSI。FSBD 的具体步骤如下:

1) 特征判别性能评价。给定 X_S 中的原始特征集, $[X_S^1, X_S^2, \dots, X_S^K]$, 其中 $X_S^k, k \in [1, K]$ 如下所示:

$$X_S^k = \begin{bmatrix} S_{11}^k & S_{12}^k & \dots & S_{1N}^k \\ S_{21}^k & S_{22}^k & \dots & S_{2N}^k \\ \vdots & \vdots & \vdots & \vdots \\ S_{M1}^k & S_{M2}^k & \dots & S_{MN}^k \end{bmatrix} \quad (5)$$

式中, $S_{ij}^k, i \in [1, M], j \in [1, N]$ 表示第 i 种故障状态下的第 j 个信号样本的第 k 种特征。利用朴素贝叶斯算法对源域 K 种特征数据进行分类, 得到分类精度序列 ACC 如下所示:

$$ACC = \{acc(1), acc(2), \dots, acc(K)\} \quad (6)$$

2) 特征在不同域间的分布差异度量。给定 X_T 中的原

始特征集, $[X_T^1, X_T^2, \dots, X_T^K]$, 其中 $X_T^k, k \in [1, K]$ 如下所示:

$$\mathbf{X}_T = \begin{bmatrix} T_{11}^k & T_{12}^k & \dots & T_{1N}^k \\ T_{21}^k & T_{22}^k & \dots & T_{2N}^k \\ \vdots & \vdots & \vdots & \vdots \\ T_{M1}^k & T_{M2}^k & \dots & T_{MN}^k \end{bmatrix} \quad (7)$$

式中, $T_{ij}^k, i \in [1, M], j \in [1, N]$ 表示第 i 种故障状态下的第 j 个信号样本的第 k 种特征。基于源域和目标域中正常状态下特征样本 X_S^{normal} 和 X_T^{normal} 计算各特征在源域和目标域之间的 MMD , 得到域间差异序列 DD 如下所示:

$$DD = \{MMD(1), MMD(2), \dots, MMD(K)\} \quad (8)$$

3) 构建新的特征选取指标 FSI 。基于前两步骤获得的分类精度序列 ACC 和域间差异序列 DD , 构建新的特征选取指标 FSI , 表达式如下:

$$FSI(k) = \frac{ACC(k)}{MMD(k)} \quad (9)$$

对于 K 种特征, 可得到 FSI 序列如下:

$$FSI = \{FSI(1), FSI(2), \dots, FSI(K)\} \quad (10)$$

本文认为, 特征的 ACC 值越大, 其用于分类的判别性能越好, 特征在不同域间分布差异 MMD 越小, 则其域适应能力越强。因此, 当 FSI 值越大, 则对应的特征更有利于跨域故障诊断和深度模型迁移。最后, 将 FSI 序列根据数值大小降序排列, 选取前 d 个数值对应的特征用于后续的深度模型训练和迁移。

2 深度迁移自编码器

2.1 堆叠自编码器

自编码器 (Auto encoder, AE)^[8] 是一种无监督学习的神经网络, 它能够从无标签数据集中学习提取出深层特征。AE 包括编码和解码两个过程, 自编码器的结构可分为三层, 输入层、隐含层和输出层^[10], 其结构如图 1 所示。

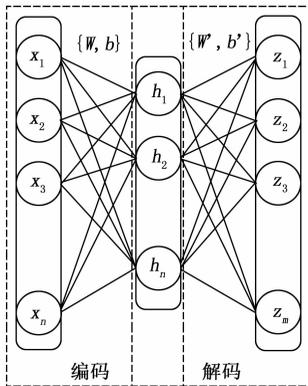


图 1 一个自编码器的结构

在编码过程, 输入层数据 $\{x_1, x_2, \dots, x_m\}$ 通过激活函数 $\varphi_{act}(\cdot)$ 映射到隐含层 $\{h_1, h_2, \dots, h_n\}$, 映射关系如下所示:

$$h = \varphi_{act}(\mathbf{W} \cdot \mathbf{x} + \mathbf{b}) \quad (11)$$

其中, $\mathbf{W} \in \mathbf{R}^{n \times m}$ 为编码权重矩阵, $\mathbf{b} \in \mathbf{R}^n$ 为偏置向量。

在解码过程, 隐藏层数据 $\{h_1, h_2, \dots, h_n\}$ 通过激活函数 $\varphi_{act}(\cdot)$ 映射到输出层 $\{z_1, z_2, \dots, z_m\}$, 映射关系如下所示:

$$\mathbf{z} = \varphi_{act}(\mathbf{W}' \cdot \mathbf{h} + \mathbf{b}') \quad (12)$$

其中, $\mathbf{W}' \in \mathbf{R}^{m \times n}$ 为解码权重矩阵, $\mathbf{b}' \in \mathbf{R}^m$ 为偏置向量。AE 的参数通过最小化重构误差为优化目标, 训练获得, 其重构误差如下所示:

$$J_{AE}(\theta) = \frac{1}{N} \sum_{i=1}^N \left(\frac{1}{2} \|x_i - z_i\|^2 \right) \quad (13)$$

其中, $\theta = \{\mathbf{W}, \mathbf{b}, \mathbf{W}', \mathbf{b}'\}$ 为自编码器参数。

深度自编码器的构建, 本文是将多个 AE 叠加在一起, 即堆叠自编码器 (stacked auto encoders, SAE), 将每个 AE 经编码后的隐含层作为下一级 AE 的输入层, 最后一级 AE 的隐含层作为输出的深度特征, 最后输入分类器。上述深度自编码器的训练有两个阶段:

1) 无监督预训练。利用训练集样本进行各层 AE 训练, 获得深度自编码器的参数。

2) 对深度自编码器网络的整体进行有监督微调。

2.2 深度迁移自编码器

为实现跨域故障诊断, 本文在深度自编码器的基础上, 构建深度迁移自编码器, 具体过程如下:

1) 设置 AE 模型的激活函数, 本文采用 SELU 函数作为激活函数; 设置深度自编码器的结构层数, 每层节点数。

2) 利用源域无标签特征数据训练深度自编码器模型, 获得每一层的编码权重参数和偏置参数。

3) 将利用源域数据训练得到的深度自编码器模型的结构层数, 节点层数, 编码权重参数以及偏置参数迁移至目标域的模型, 作为针对目标域数据的深度自编码器初始参数。

4) 利用 softmax 分类器构建分类层, 连接在深度自编码器的最后一层, 再利用目标域中正常状态下特征数据对连接了分类层的深度自编码器进行 Fine-tuning 微调。

5) 获得深度迁移自编码器模型, 可用于目标域无标签特征数据的分类。

3 故障诊断框架

本文基于信号处理, 提出的基于朴素贝叶斯与域间差异的特征选取方法和深度迁移自编码器, 提出一种新的应用于变工况下轴承故障诊断框架 FS-DTAE, 如图 2 所示。该框架主要包括 3 个步骤: 信号处理与特征提取, 特征选取和深度迁移学习。具体描述如下:

1) 信号处理与特征提取。本文利用 WPT 对采集到的轴承振动信号进行分解, 结合统计参数, 提取统计特征作为原始特征集。

2) 特征选取。为从高维原始特征集中选取有利于跨域故障诊断和深度迁移学习的特征, 基于源域有标签特征数据和目标域正常状态数据, 利用提出的特征选取方法 FS-BD, 对原始特征集中各特征进行判别性能与域间差异的度量, 提出新的量化指标 FSI 。基于降序排列的 FSI 序列, 选取特征构建子集, 用于后续的深度模型训练与迁移。

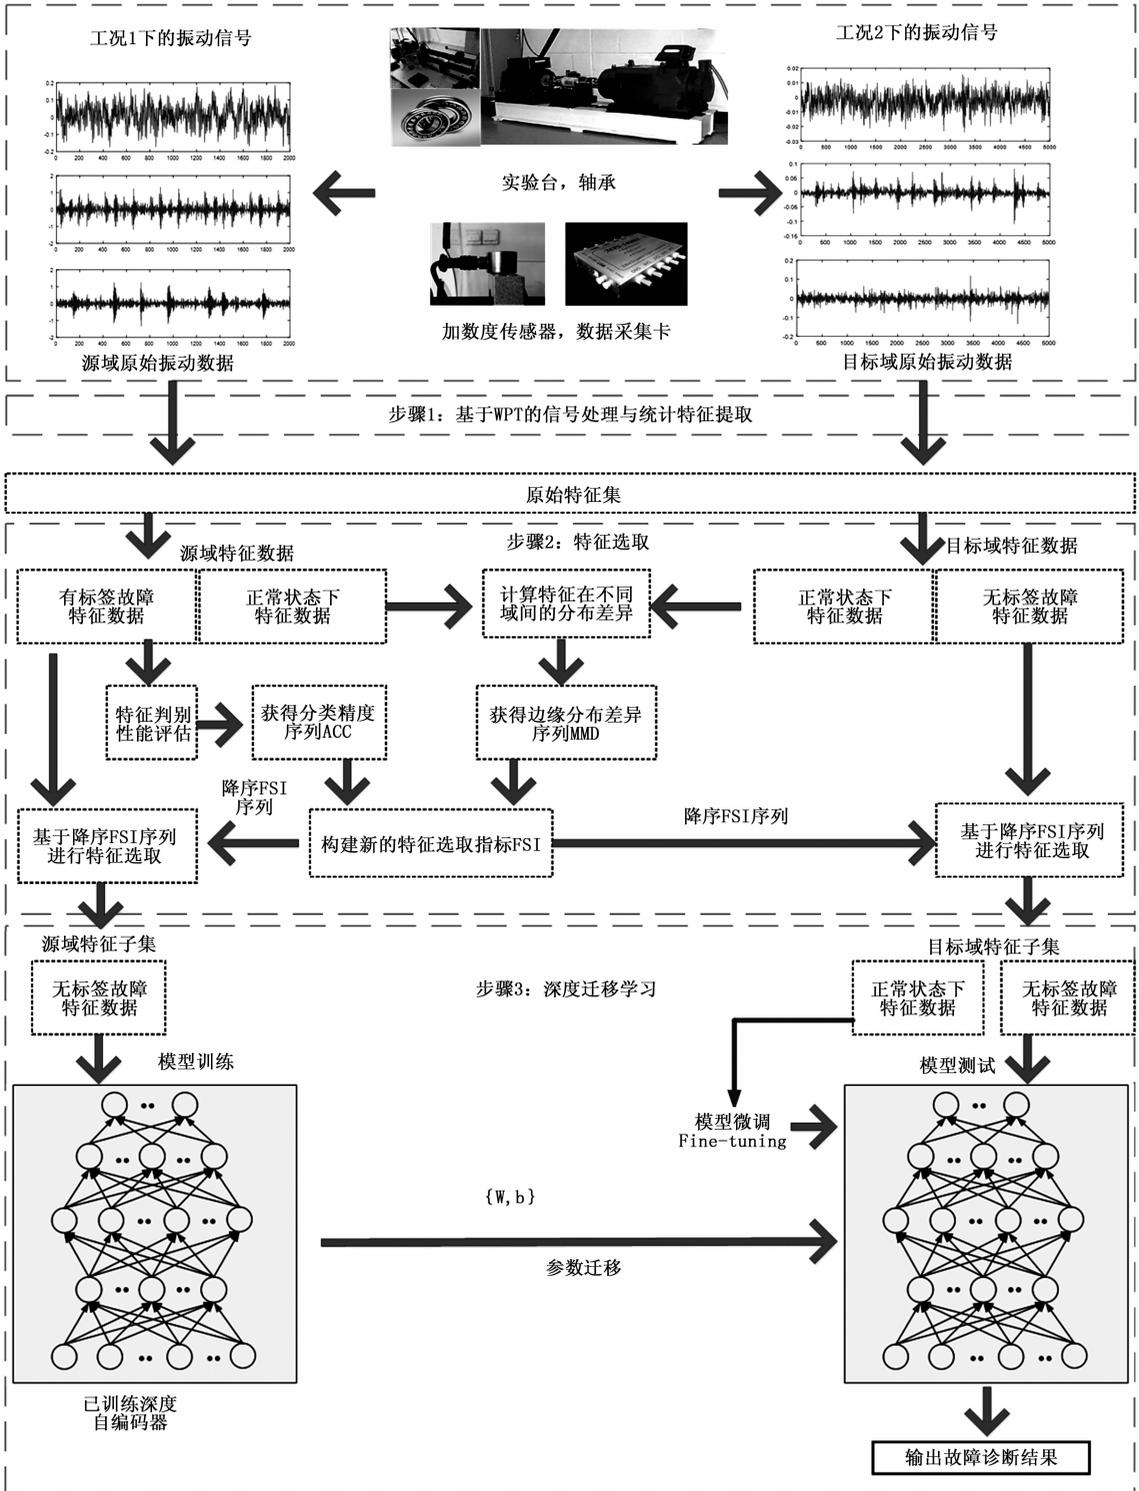


图 2 基于深度迁移自编码器的变工况下轴承故障诊断框架 FS-DTAE

3) 深度迁移学习。在第二步基础上，获得源域和目标域特征子集。首先，利用源域无标签特征子集数据作为训练样本，训练深度自编码器；其次，将源域训练得到的深度自编码器参数迁移至目标域，作为目标域深度自编码器模型的初始化参数。最后，利用源域和目标域中正常状态的特征数据对目标域深度自编码器进行 Fine-tuning 微调。

最后，目标域无标签特征数据测试深度迁移自编码器的故障诊断性能。

4 实验验证

为验证本文所提出的变工况下轴承故障诊断框架 FS-DTAE 的有效性 with 适应性，采用美国凯斯西储大学 (CW-

RU) 的轴承振动数据开展不同工况下故障诊断实验验证。

4.1 实验设置与任务

本文使用的 CWRU 轴承数据采集自图 3 所示的故障模拟试验台, 该数据集广泛的被研究人员用于开展轴承故障诊断研究。该试验台轴承有三类故障, 内圈缺陷, 外圈缺陷以及滚动体缺陷, 缺陷的尺寸包括 0.007 英寸、0.014 英寸、0.021 英寸和 0.028 英寸。振动数据集中包含 4 种不同运行状态下的振动数据, 分别为 0 hp、1 hp、2hp 和 3 hp 电机负载情况下。基于该数据集, 本文设置 2 个跨域故障诊断任务, 任务 1 中, 2 hp 和 3 hp 下的故障数据分别作为源域和目标域; 任务 2 中, 2 hp 和 3 hp 下的故障数据分别作为目标域和源域。两个任务的实验数据具体如表 1 所示。任务 1 和 2 中, 源域和目标域数据均包含 12 种轴承故障样本, 对应的类别标签为 1—12, 其中源域中样本数为 240, 目标域中样本数为 480。每个样本包含 2 000 个采样数据点。

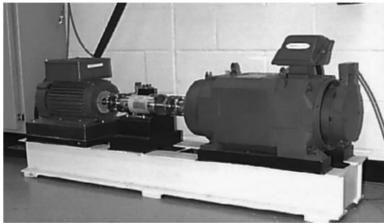


图 3 CWRU 的轴承故障实验台

表 1 CWRU 轴承振动数据集

故障类型	缺陷尺寸/ 英寸	任务 1		任务 2		类别
		源域: 2hp	目标域: 3hp	源域: 3hp	目标域: 2hp	
健康状态	0	20	40	20	40	1
滚动体 故障	0.007	20	40	20	40	2
	0.014	20	40	20	40	3
	0.021	20	40	20	40	4
	0.028	20	40	20	40	5
内圈故障	0.007	20	40	20	40	6
	0.014	20	40	20	40	7
	0.021	20	40	20	40	8
	0.028	20	40	20	40	9
外圈故障	0.007	20	40	20	40	10
	0.014	20	40	20	40	11
	0.021	20	40	20	40	12
样本数量		240	480	240	480	

4.2 实验结果分析

根据本文提出的 FS-DTAE 故障诊断框架, 首先, 利用 WPT 对轴承振动信号进行四层分解 (母小波为 “demj”), 基于第四层的 16 个终端节点的单支重构信号 (16 个信号), 和重构信号的 16 个 Hilbert 包络谱, 计算 11 种统计参数^[5,11-13] (极差, 平均值, 标准差, 峰度, 能量, 能量熵, 偏度, 波峰因子, 脉冲因子, 形状因子和纬度因子)。因此, 共计算得到 352 个统计特征, 构建原始特征集 (Raw

feature set, RFS)。

在原始特征集基础上, 运用本文提出的 FSBD 方法, 评价各特征的判别性能和不同域间差异, 获取特征选取的量化指标 FSI, 图 4 所示为 352 个特征值的 FSI 值。根据得到的 FSI 值序列, 进行降序排列, 选取序列中前 d 个 FSI 值对应的统计特征构建特征子集, 再进行深度自编码器训练和模型迁移。本文基于从源域选取的特征用于深度自编码器训练, 设置隐含层 4 个, 每层节点个数分别为 400, 200, 100 和 50, 分类层为 softmax 分类器。

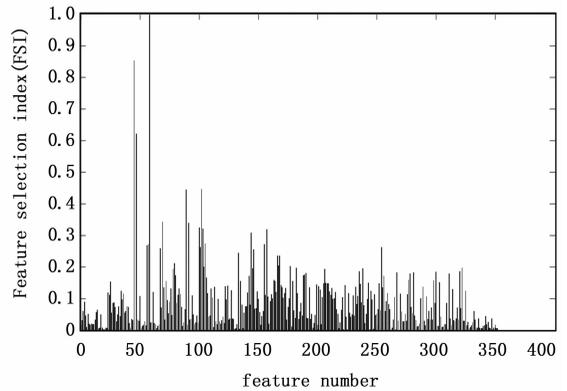


图 4 352 个统计特征的 FSI 值

为进一步验证本文所提出框架的优越性, 选取一些经典和常用迁移学习的故障诊断方法进行实验对比。经典方法包括 SVM, KNN, CNN 和 DBN, 常用迁移学习方法包括 TCA 和 JDA^[14-16]。基于上述方法, 构建对比故障诊断模型, 如表 2 所示。举例说明, RFS-SVM 模型表示源域的特征数据全部作为 SVM 的输入, 进行故障诊断模型的训练, 再利用训练好的模型对目标域进行故障分类; RFS-TCA/JDA 模型表示源域和目标域无标签特征数据经 TCA/JDA 处理后, 再输入 SVM 分类器进行模型训练, 训练好的模型再对目标域特征数据进行故障分类^[17-20]。RFS-FSBD-TCA/JDA 模型则是在 RFS-TCA/JDA 模型基础上引入本文所提出的特征选取方法, 特征选取后构建的特征子集再进行 TCA/JDA 处理。

表 2 对比故障诊断模型

序号	模型	序号	模型
1	RFS-SVM	6	RFS-TCA
2	RFS-KNN	7	RFS-JDA
3	RFS-CNN	8	RFS-FSBD-TCA
4	RFS-DBN	9	RFS-FSBD-JDA
5	RFS-SAE	10	FS-DTAE

基于表 2 中所示的对比模型, 进行表 1 中所示的故障诊断任务 1 和 2, 对应的故障诊断结果如表 3 和图 5 所示。图 5 所示为表 2 中各故障诊断模型的实验结果对比, 表 3 所示为所提出的 FS-DTAE 模型, RFS-FSBD-TCA 和 RFS-FSBD-JDA 模型在不同的特征选取数时的故障诊断结果。

表 3 轴承故障诊断结果

特征选取数 d	任务 1 的故障诊断准确率 /%			任务 2 的故障诊断准确率 /%		
	FS-DTAE	RFS-FSBD-TCA	RFS-FSBD-JDA	FS-DTAE	RFS-FSBD-TCA	RFS-FSBD-JDA
	40	86.87	80.83	82.71	89.38	89.17
60	95.83	83.33	91.46	96.46	92.50	92.71
80	99.38	92.29	92.71	98.96	93.13	94.79
100	99.58	95.21	95.83	100.00	96.46	97.92
120	99.79	94.58	97.71	99.17	95.63	96.67
140	99.79	94.38	98.13	99.38	95.21	96.88
160	97.50	92.08	96.04	99.79	95.00	95.83
180	97.92	92.29	96.25	98.75	94.79	95.63
200	95.83	90.42	95.21	98.33	94.58	95.42
220	92.50	90.83	94.79	97.71	94.17	95.00
240	92.08	88.75	95.00	96.25	92.71	94.58
260	91.46	89.17	92.50	95.83	92.50	93.13
280	88.75	88.96	90.63	92.08	90.83	93.33
300	82.50	86.88	90.42	90.42	88.75	92.29
320	83.13	85.83	88.96	89.17	88.33	88.96
340	85.63	85.67	87.00	88.96	88.13	88.13
352	85.42	85.00	86.00	88.33	86.88	86.87

图 5 所示的实验结果对比表明本文所提出的故障诊断模型在不同工况下的故障诊断性能最优，任务 1 和任务 2 的故障诊断精度最高分别可达 99.79% 和 100%，高于其他对比模型的最大故障诊断精度。对比模型中，将本文提出的特征选取方法 FSBD 与迁移学习方法结合起来，能够明显提高故障诊断精度，RFS-FSBD-TCA 和 RFS-FSBD-JDA 两个模型在任务 1 中所取得的最大故障诊断精度分别为 95.21% 和 98.13%，在任务 2 中，最大故障诊断精度可达 98.13% 和 97.92%。表明，FSBD 方法所选取出的特征更有利于跨域故障诊断和迁移学习过程，进而提高模型的故障诊断性能。

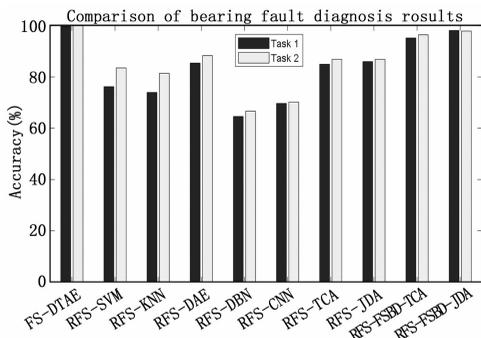


图 5 不同故障诊断模型的实验结果对比

表 3 所示的故障诊断结果表明本文提出的特征选取方法 FSBD 在选取合适的特征数时，能够明显提高故障诊断准确率，对于 FS-DTAE 模型，任务 1 中，根据降序 FSI 序列选取前 120 个特征用于后续模型训练和迁移，能够

取得最大的故障诊断准确率；任务 2 中，选取前 100 个特征可达到 100% 的诊断准确率。FSBD 与迁移学习方法 TCA 和 JDA 结合起来构建的故障诊断模型，基于降序 FSI 序列选取一定数量的特征，能够提升模型的故障诊断性能。

5 结束语

本文在信号处理与统计特征提取，特征选取和深度自编码器基础上，提出了一种新的基于深度迁移自编码器的轴承故障诊断模型 FS-DTAE，旨在提高在不同工况下的轴承故障诊断准确率。利用 CWRU 轴承故障数据开展不同工况下的故障诊断实验，实验结果表明：

1) 本文所提出的 FS-DTAE 模型与设置的对比模型相比，取得的故障诊断准确率最高，验证了该模型在不同工况下故障诊断的有效性和优越性。

2) 本文提出的特征选取方法 FSBD 能够明显提高迁移故障诊断模型的诊断准确率。基于原始特征的降序 FSI 序列，分别选取前 120 个和 100 个特征时，可使 FS-DTAE 模型在任务 1 和 2 的故障诊断结果分别达到 99.79% 和 100%。

3) 本文提出的 FSBD 方法与其他迁移学习方法结合，同样能够明显提高故障诊断准确率，表明该方法所选取出的特征更有利于跨域故障诊断和迁移学习。

综合实验结果分析，本文所提出的 FSBD 方法能够提升故障诊断模型的性能，使构建的深度迁移模型达到理想的故障诊断准确率。

参考文献：

- [1] 康守强, 刘旺辉, 王玉静, 等. 基于深度在线迁移的变负载下滚动轴承故障诊断方法 [J/OL]. 控制与决策: 1-10 [2021-06-12]. <https://doi.org/10.13195/j.kzyjc.2020.1686>.
- [2] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法 [J]. 机械工程学报, 2019, 55 (7): 1-8.
- [3] 邵海东, 张笑阳, 程军圣, 等. 基于提升深度迁移自动编码器的轴承智能故障诊断 [J]. 机械工程学报, 2020, 56 (9): 84-90.
- [4] 丁恩杰, 俞啸, 廖玉波, 等. 基于物联网的矿山机械设备状态智能感知与诊断 [J]. 煤炭学报, 2020, 45 (6): 2308-2319.
- [5] 俞啸, 范春阳, 董飞, 等. 基于 EMD 与深度信念网络的滚动轴承故障特征分析与诊断方法 [J]. 机械传动, 2018, 42 (6): 157-163.
- [6] LIU D, CHENG W, WEN W. Intelligent cross-condition fault recognition of rolling bearings based on normalized resampled characteristic power and self-organizing map [J]. Mechanical Systems and Signal Processing, 2021, 153: 107462.
- [7] 季旭峰, 邓亚飞, 杜世昌, 等. 基于深度迁移学习的轴承故障分析 [J]. 机械设计与研究, 2021, 37 (1): 106-110.
- [8] HE Z, SHAO H, JING L, et al. Transfer fault diagnosis of bearing installed in different machines using enhanced deep auto-encoder [J]. Measurement, 2019, 152: 1-13.

(下转第 99 页)