

基于 MMDFE-DA 的滚动轴承故障诊断方法*

雷子豪¹, 温广瑞^{1,2}, 周桥¹, 董书志¹, 黄鑫¹, 周浩轩¹

(1. 西安交通大学机械工程学院 西安, 710049) (2. 新疆大学机械工程学院 乌鲁木齐, 830047)

摘要 针对变工况条件下轴承训练数据集和测试数据集存在分布差异, 导致智能诊断模型泛化能力不足, 且需针对不同任务分别建模问题, 提出一种基于多尺度混合域特征提取(multi-scale mixed domain feature extraction, 简称 MMDFE)和领域自适应(domain adaptation, 简称 DA)的滚动轴承智能故障诊断方法。首先, 引入变分模态分解提取多尺度混合域特征, 构建完备的特征空间; 其次, 通过随机森林算法实现特征的降维和优选, 消除冗余信息; 然后, 应用优选后的特征结合流形嵌入式分布对齐方法实现不同领域数据的分布对齐及跨域诊断; 最后, 采用不同工况下的数据集进行验证, 并与传统的智能诊断方法和迁移学习方法进行对比, 结果表明, 所提方法可以准确有效实现跨域诊断。

关键词 故障诊断; 滚动轴承; 领域自适应; 随机森林; 多尺度混合域特征

中图分类号 TH17; TP18

引言

轴承作为旋转机械中的关键部件, 恶劣的工作条件易使轴承发生故障。为了避免重大经济损失和灾难性故障, 研究先进的智能故障诊断算法具有重要意义^[1], 基于振动信号的信号分解和特征提取是研究的重点。目前, 在信号处理方法的基础上进行时域、频域和时频域统计参数的提取研究取得了一定成果^[2]。但是, 当机械系统具有耦合组件且暴露在强烈背景噪声的复杂环境中时, 系统通常会出现非线性行为。熵作为一种复杂性指标, 在故障诊断和时间序列分析中得到了广泛应用^[3]。

变分模式分解(variational mode decomposition, 简称 VMD)作为一种自适应分解方法^[4], 可以将信号非递归地分解成多个正交的本征模态函数, 在滚动轴承的信号处理和特征提取中起着重要作用。学者们对其进行改进和优化, 成功应用于故障诊断领域^[5]。Dibaj 等^[6]提出一种结合 VMD 和卷积神经网络(convolutional neural networks, 简称 CNN)的故障诊断方法, 在复合故障诊断中取得了一定效果。局部均值分解(local mean decomposition, 简称 LMD)作为一种自适应信号处理方法, 可对复杂的非平稳信号进行分解。吴东升等^[7]提出一种基于

VMD-LMD-CNN 的集合型故障诊断方法。上述方法忽略了特征的物理意义以及可解释性。随机森林(random forests, 简称 RF)作为一种新的机器学习算法, 具有建模参数少、泛化性能强等优点, 能根据特征重要性指标对分类性能进行评估, 被广泛应用到工程领域中。

尽管智能故障诊断方法取得了较大成功, 但都基于一个假设: 有足够的带标签数据训练智能诊断模型。在工程实际中, 上述假设往往得不到满足。迁移学习为解决以上问题提供了一种思路^[8]。与此相关的方法有测地线流式核(geodesic flow kernel, 简称 GFK)^[9]、迁移联合匹配(transfer joint matching, 简称 TJM)^[10]、迁移成分分析(transfer component analysis, 简称 TCA)^[11]、联合分布分析(joint distribution adaptation, 简称 JDA)^[12]以及流形嵌入式分布对齐(manifold embedded distribution alignment, 简称 MEDA)^[13]等。随着人工智能的发展, 深度迁移学习在计算机视觉领域取得了一些成果, 如动态对抗自适应网络(dynamic adversarial adaptation network, 简称 DAAN)^[14]。Guo 等^[15]将领域自适应模块引入到深度学习中, 可有效学习可迁移的特征。Wen 等^[16]利用稀疏自编码器提取不同工况下的轴承频谱特征, 使用最大均值差异(maximum

* 国家重点研发计划资助项目(2020YFB1710002); 国家自然科学基金资助项目(51775409); 装备预研共用技术和领域基金资助项目(6140004030116JW08001)

收稿日期: 2020-09-10; 修回日期: 2021-08-04

mean discrepancy,简称MMD)学习可迁移的特征分布。然而,与深度迁移模型相比,使用浅层迁移模型更容易理解从原始特征空间向目标域中的转换和知识迁移的过程,减小了训练样本的数量,避免深度网络的训练和参数调优。

笔者提出了一种基于多尺度混合域特征的领域自适应方法。利用VMD方法提取滚动轴承的多尺度混合域特征,充分表征了滚动轴承的内部信息。基于随机森林算法实现特征选择并排序。结合流形嵌入式分布对齐的领域自适应方法,实现不同工况下滚动轴承的跨域故障诊断。

1 基本原理

1.1 特征提取

为充分表征轴承的振动信号,从时域、频域、时频域和复杂度等中提取特征集。通过统计方法分别提取了15个时域特征,包括平均值、均方值、方差、标准差、方根幅值、平均幅值、均方幅值、峰值、峰峰值、波形指标、峰值指标、脉冲指标、裕度指标、偏斜度和峭度。在频域,提取了12个频域特征参数^[17]和7个功率谱参数^[18]。振动信号各频率成分的功率发生变化时,功率谱的能量分布和重心位置也会发生改变。均方频率(mean square frequency,简称MSF)、重心频率(barycenter frequency,简称FC)以及频率方差(frequency variance,简称VF)的表达式为

$$\text{MSF} = \frac{\int_0^{\pi} f^2 S(\omega) d\omega}{\int_0^{\pi} S(\omega) d\omega} \quad (1)$$

$$\text{FC} = \frac{\int_0^{\pi} \omega S(\omega) d\omega}{\int_0^{\pi} S(\omega) d\omega} \quad (2)$$

$$\text{VF} = \text{MSF} - \text{FC}^2 \quad (3)$$

其中: $S(\omega)$ 为信号的功率谱; ω 为信号的角频率。

在时频域提取了信号的8维小波包能量谱特征^[19],即

$$E_j = \sum_{k=1}^M |\omega_j(k)|^2 \quad (4)$$

其中: $\omega_j(k)$ 为对振动信号使用小波包分解后各个节点的重构信号。

复杂性测度主要对信号本身的分布特征和复杂程度进行分析,熵作为一种复杂性度量,广泛用于时

间序列分析。当机械系统发生故障时,导致系统具有非线性特性,从而增加系统响应的复杂性,而熵测度恰恰适合量化这种动态变化,从而达到区分不同系统状态的目的。笔者在此基础上进一步提取了排列熵^[20]、近似熵^[21]、样本熵^[22]和模糊熵^[23]4个复杂性测度指标。

1.2 变分模态分解

VMD将信号分成一系列具有稀疏特性的本征模态函数(intrinsic mode functions,简称IMF),其本质相当于将维纳滤波器概括为具有窄带特性的自适应频带。因此,VMD分解信号可以看作是一个约束变分问题,通过搜索约束变分模型的最优解来实现信号的自适应分解。约束变分模型为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_k u_k = f \end{cases} \quad (5)$$

其中: u_k 为分解后的各个IMF; ω_k 为IMF的中心频率。

为了更有效地解决约束变分难题,该方法引入了拉格朗日乘法算子 λ 和二次惩罚参数 α 。因此,约束变分问题可以重新整理为

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right)^* u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \end{aligned} \quad (6)$$

其中: $f(t)$ 为原始信号。

式(6)可通过交替方向乘子算法来解决,将原问题等价转换为IMF和对应的中心频率 ω_k 的交替更新。

$$\begin{cases} \hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} = \frac{\int_0^{\infty} \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^{\infty} |\hat{u}_k(\omega)|^2 d\omega} \end{cases} \quad (7)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (8)$$

当IMF和中心频率更新时,根据式(8),拉格朗日乘法算子也随之更新。

重复执行更新过程,直到满足等式(5)的收敛标准为止。

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon \quad (9)$$

其中: ϵ 取值为 1×10^{-6} 。

1.3 随机森林

随机森林算法采用集成学习中套袋法的思想,将多个决策分类器进行组合,借助套袋法增加样本空间,进而建立多个分类回归树(classification and regression trees,简称 CART)作为决策树。每个决策树会对样本进行分类,最后将每个决策树的结果进行集成,模型的输出使用投票法进行表决,从而得出最终结论。图 1 为随机森林算法示意图。

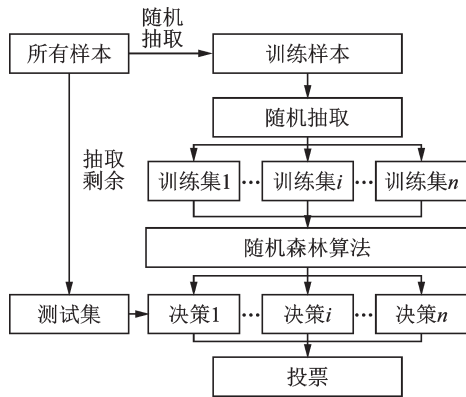


图 1 随机森林算法示意图

Fig.1 Schematic diagram of the random forest algorithm

在随机森林算法中有 2 个特征重要性指标,分别是 Gini 指标下降量和袋外错误率(out-of-bag error,简称 OOB)的误分率增加量(mean decrease accuracy,简称 MDA)。通过随机改变某特征值来测试 CART 树的 OOB 误差,使用 2 次测试 OOB 误差的平均值来表征特征的重要程度,其误差差值下降越多,说明该特征越重要。

$$J(X^j) = \frac{1}{N} \sum_{i=1}^N (e_i^j - e_i) \quad (10)$$

其中: e_i 和 e_i^j 分别为改变某特征值前后的 OOB 误差。

1.4 流形嵌入式分布对齐

流形嵌入式分布对齐是一种自适应分布适配方法,该方法首先通过流形特征变换将原始特征空间的特征映射到 Grassmann 流形空间中,以此降低领域之间的数据漂移;其次,通过引入自适应因子来动态衡量边缘分布和条件分布的相对重要性;最后,通过结构风险最小化(structural risk minimization,简

称 SRM)原则学习分类器。MEDA 概念图如图 2 所示。




图 2 MEDA 概念图

Fig.2 A conceptual diagram of MEDA

假设 $g(\cdot)$ 为流形特征变换的函数,最终域不变的分分类器 f 可以表示为

$$f = \arg \min l(f(g(x_i)), y_i) + \eta \|f\|_K^2 + \sum_{i=1}^n H_K \quad (11)$$

$$\lambda \overline{D}_f(D_s, D_t) + \rho R_f(D_s, D_t)$$

其中: $\|f\|_K^2$ 为 f 的平方范数; \overline{D}_f 为动态对齐方式; R_f 为利用拉普拉斯正则化的流形最近点的相似几何特性; η, λ, ρ 为正归化参数。

在进行流形特征映射时首先将子空间嵌入到流形 G 中,则原始特征的 d 维子空间可以认为是流形 G 上对应的点。令 $S_s = \Phi(0)$ 以及 $S_t = \Phi(1)$, 然后找到一条从 $\Phi(0)$ 到 $\Phi(1)$ 的测地线,将原始特征空间映射到流形特征空间中。

$$\langle z_i, z_j \rangle = \int_0^1 (\Phi(t)^T x_i)^T (\Phi(t)^T x_j) dt = x_i^T G x_j \quad (12)$$

通过 $z = \sqrt{G} x$,将原始特征空间的特征映射到流形空间。引入自适应因子来衡量边缘分布和条件分布的重要性,表示为

$$\overline{D}_f(D_s, D_t) = (1 - \mu) D_f(P_s, P_t) + \mu \sum_{c=1}^C D_f^{(c)}(Q_s, Q_t) \quad (13)$$

其中: μ 为自适应因子; $c \in \{1, 2, \dots, C\}$ 代表类别; $D_f(P_s, P_t)$ 表示适配边缘分布; $D_f^{(c)}(Q_s, Q_t)$ 表示适配条件分布。

借助 MMD 计算分布差异,自适应分布适配可以表示为

$$\overline{D}_f(D_s, D_t) = (1 - \mu) \|E[f(z_s)] - E[f(z_t)]\|_{H_K}^2 + \mu \sum_{c=1}^C \|E[f(z_s^{(c)})] - E[f(z_t^{(c)})]\|_{H_K}^2 \quad (14)$$

采用 A-distance 估计不同分布的距离。对于边

缘分布差异,计算源域、目标域之间的 A-distance, 记为 A_M 。对于条件分布差异,首先将目标域聚为 C 类,其次计算源域和目标域中来自同一个类别的数据的 A-distance,取其均值记为 A_c ,则自适应因子可以表示为

$$\hat{\mu} \approx A_M / (A_M + \sum_{c=1}^C A_c) \quad (15)$$

最后,基于结构风险最小化原则在流形变换后的特征空间上学习分类器即可。

2 基于 MMDFE-DA 的故障诊断方法

为了提高滚动轴承在多变工况下的故障诊断精度,提出了一种基于多尺度混合域特征提取和领域自适应的滚动轴承智能诊断算法框架,图 3 为所提方法流程图。该流程图主要包括:①多尺度混合域特征的提取;②特征选择并排序;③领域自适应。具体步骤如下:

1) 采用加速度传感器采集滚动轴承在不同工况下的原始振动信号,分别构建源域和目标域样本集。

2) 使用 VMD 对信号进行分解,对原始信号和分解后各阶的 IMFs 分别进行时域、频域、时频域、复杂度等特征指标的提取,构建可以表征信号状态信息和内在属性完备的多尺度混合域特征集,随后对特征集进行归一化处理。

3) 构建 RF 模型,使用 OOB 误差计算特征向量的重要性,并根据上述各个特征的重要程度进行排序和优选,实现特征降维,消除冗余信息。

4) 将经过步骤 3 优选后的特征首先进行流形特征变换,以此减小不同领域间的数据漂移。通过自

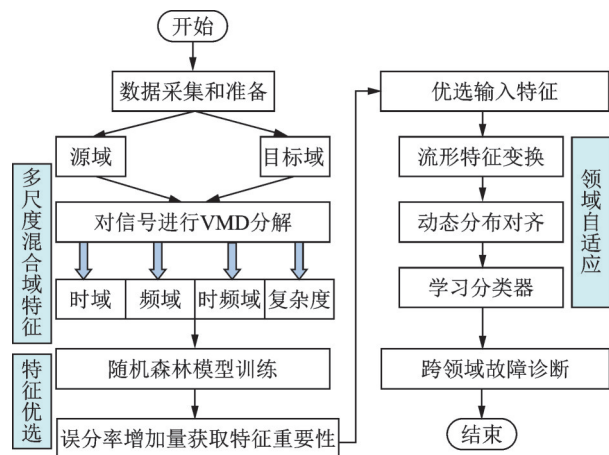


图 3 所提方法流程图

Fig.3 Flowchart for the proposed method

适应适配源域样本和目标域样本的边缘分布和条件分布,运用结构风险最小化原则学习分类器,即可实现不同工况下的滚动轴承跨域诊断。

3 实验验证及分析

为研究所提方法的泛化能力和优越性,使用西安交通大学的风力涡轮机传动系统诊断模拟平台采集不同负载下的轴承振动数据,并与传统的智能诊断方法以及传统迁移学习算法进行比较,以显示所提方法的有效性和优越性。

3.1 数据描述

风力涡轮机传动系统故障诊断模拟平台如图 4 所示,主要由电机、电机控制器、轴承座、齿轮箱以及磁粉制动器组成。图 5 为实验轴承的 3 种故障情况,分别为内圈故障、外圈故障以及滚动体故障。其中,内圈和外圈故障采用的是激光烧灼,损伤深度约为 0.2 mm,损伤直径约为 2 mm。考虑到激光烧灼会对滚动体造成二次热处理,同时滚动体体积较小,因此采用砂轮机磨削预置故障。

实验中由于负载的变化可以通过改变电流加以控制,因此电流分别设置为:0,0.4,0.8 以及 1.2 A,分别模拟不同程度的负载。直流电机的转速为 2 kr/min。振动信号由 BK 加速度计收集,灵敏度为 10.23 mV/g。振动信号采集卡使用 DT9837,采样数为 20 480,采样频率为 20 480 Hz。




图 4 风力涡轮机传动系统故障诊断模拟平台

Fig.4 Wind turbine drive train fault diagnosis simulator



图 5 实验轴承的 3 种故障情况

Fig.5 Three fault conditions of the experimental bearing

以实验台上采集到的转速为 2 kr/min 时的 4 个不同负载下的振动信号作为分析数据集(A, B, C, D), 每个数据集分别包括正常状态(normal state, 简称 NS)、内圈故障(inner race fault, 简称 IF)、外圈故障(outer race fault, 简称 OF)以及滚动体故障(ball fault, 简称 BF)样本共 400 个。其中, 每类样本 100 个, 每个样本有 2 400 个采样点。实验台变负载数据集如表 1 所示。根据表 1, 设置 12 个迁移学习的任务, 即 $A \rightarrow B, A \rightarrow C, A \rightarrow D, B \rightarrow A, B \rightarrow C, B \rightarrow D, C \rightarrow A, C \rightarrow B, C \rightarrow D, D \rightarrow A, D \rightarrow B$ 和 $D \rightarrow C$ 。数据集 A, B, C, D 分别为提供诊断知识的源域和目标域。4 种工况下滚动轴承的原始振动信号如图 6 所示。

表 1 实验台变负载数据集

Tab.1 Variable load datasets of test bench

数据集	轴承类型	故障类型	标签	样本数量	工况
A	ER-16K	NS	1	4×100	负载 0 (2 kr/min)
		IF	2		
		OF	3		
		BF	4		
B	ER-16K	NF	1	4×100	负载 1 (2 kr/min)
		IF	2		
		OF	3		
		BF	4		
C	ER-16K	NF	1	4×100	负载 2 (2 kr/min)
		IF	2		
		OF	3		
		BF	4		
D	ER-16K	NF	1	4×100	负载 3 (2 kr/min)
		IF	2		
		OF	3		
		BF	4		

3.2 实验结果与分析

将所提的方法应用于实验室的变负载数据集中。从原始振动信号中提取包括时域、频域、时频域和复杂度特征在内的特征集。使用 VMD 分解原始振动信号, 经 VMD 分解后的原始信号和各阶 IMF 的波形和频谱如图 7 所示。其中, VMD 的参数设置采用经验值, 选择包含对研究有用信息的前 6 个 IMF, 并从这 6 个 IMF 中分别提取混合域特征集, 形成多尺度混合域特征集, 并对特征集进行归一化。

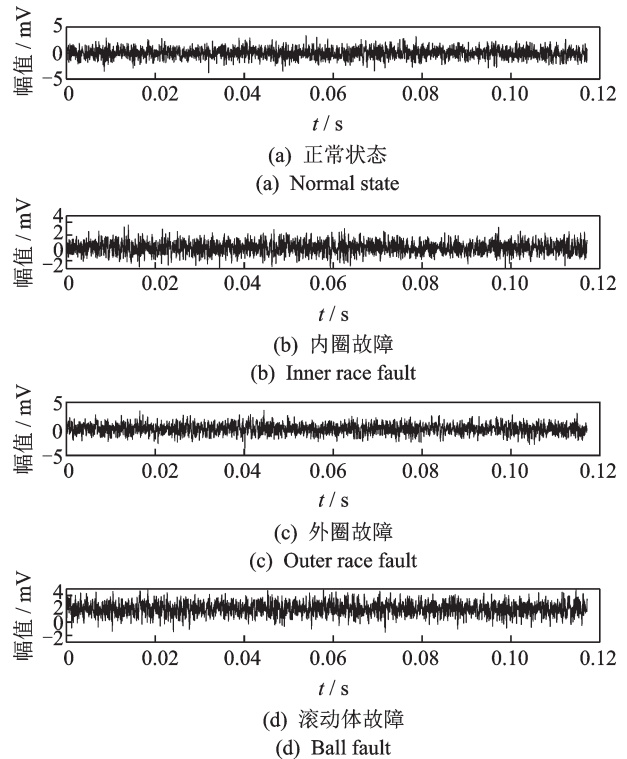
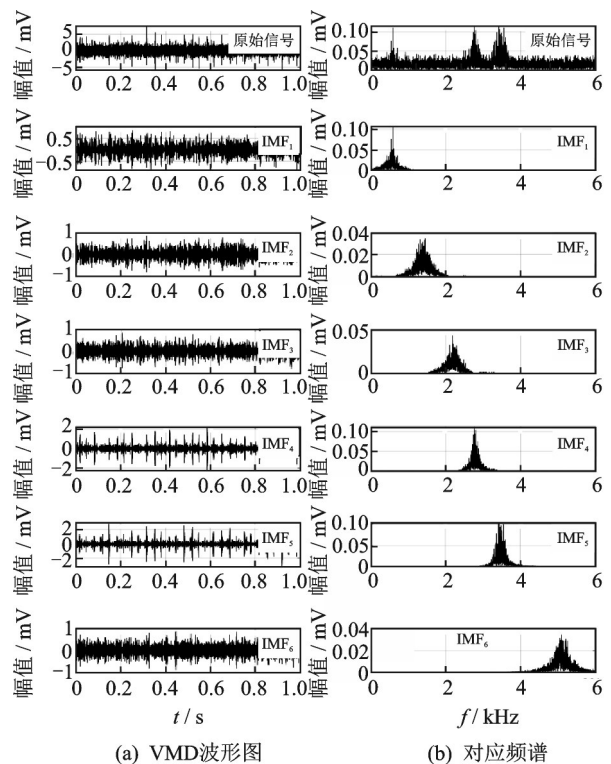


图 6 4 种工况下滚动轴承的原始振动信号

Fig.6 The raw vibration signal of rolling bearing in four working conditions



(a) Time domain waveforms of VMD (b) Corresponding spectrum

图 7 VMD 结果

Fig.7 Results of VMD

使用 RF 训练模型, 通过 OOB 误差对多尺度混合域的特征重要性进行排序。由于篇幅限制, 根据

特征重要性排序的前 15 维特征直方图如图 8 所示。可以发现,具有高贡献的特征主要集中在原始信号和前三阶的 IMF。由于出色的非线性特征提取能力和良好的抗噪声能力,近似熵和样本熵已成为主要的敏感特征。此外,时域的均方根值、波形指标,频域的功率谱密度特征参数、频谱特征参数以及时频域的小波尺度能量都在不同程度上有所贡献。这表明笔者提出的多尺度混合域特征提取器可以提取完备的特征集。




图 8 根据特征重要性排序的前 15 维特征直方图

Fig.8 Sorted histogram according to the importance of top 15 dimensions features

为了确定在 RF 优选后待输入的特征维数,按照特征重要程度逐渐增加特征维数并输入到 SVM 中进行识别,在 12 个迁移数据集上进行测试,取各准确率的平均值。随着输入特征维数的增加,平均识别率逐渐升高。当输入前 34 维特征时,平均识别率达到 74.11%,之后随着输入维数的继续增加,识别率均有所降低,但也稳定在 72.5% 左右。分析其原因,可能是添加了重要性低的特征后,特征集存在冗余和干扰,并产生了负迁移。因此,确定最优的特征子集为前 34 维特征。

针对变负载数据集使用 MEDA 方法进行跨领域的故障诊断。对于每个样本,获取上述方法所提的优选特征(34 维),对其进行流形特征变换(10 维),以期减小源域和目标域之间的领域差异。通过自适应分布对齐以及简单分类器 K 最近邻(K-nearest neighbor,简称 K-NN)的学习,其中 $k=1$,最终实现跨领域故障诊断。

以任务 $B \rightarrow C$ 为例,所提方法的准确率为 96.5%。所提方法在数据集 B 上的混淆矩阵如图 9 所示。可见,所提方法能够正确地将正常、内圈故障、外圈故障进行分类,其中滚动体故障存在少数错分的情况。为了更直观地理解迁移学习的过程,引

入了 t 分布随机近邻嵌入(t-distributed stochastic neighbor embedding,简称 t-SNE)^[24]算法。该算法可以降低特征的维数,直接绘制特征分布。图 10 为领域自适应在数据集 B(源域)和数据集 C(目标域)上的可视化结果。由图 10(a)发现,尽管同一工况下不同类型的故障样本之间能够很好地区分,但不

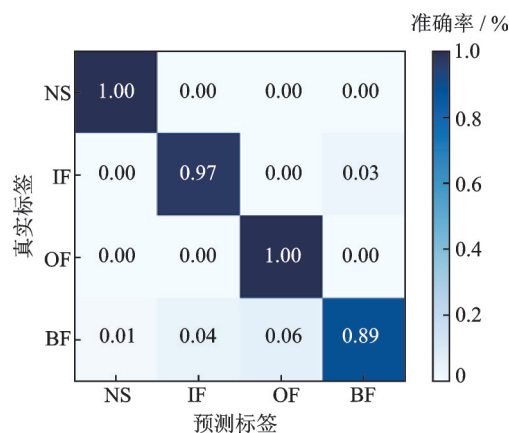




图 9 所提方法在数据集 B 上的混淆矩阵

Fig.9 Confusion matrix of proposed method on dataset B



(a) 领域自适应之前

(a) Before domain adaptation



(b) 领域自适应之后

(b) After domain adaptation

图 10 领域自适应在数据集 B(源域)和数据集 C(目标域)上的可视化结果

Fig.10 Visualization result of cross process domain adaptation on dataset B (source domain) and dataset C (target domain)

同工况下同种类型的故障不能有效区分。通过领域自适应之后,不同工况下同一类型的故障样本的分布越来越接近,如图10(b)所示。将所提方法在数据集的12种变负载工况下进行验证,表2为变负载数据集下各种方法的准确率。可以发现,所提方法在10种任务下均取得了最优成绩,在12种任务中平均准确率最高,标准差最低,该结果进一步证明了所提方法的优越性。

表2 变负载数据集下的准确率
Tab.2 Accuracy under variable load datasets %

任务	SVM	TCA	GFK	JDA	TJM	所提方法
A→B	72.75	71.50	60.50	77.25	82.50	89.00
A→C	71.00	63.50	65.75	68.25	74.75	71.25
A→D	78.75	65.75	72.50	69.50	76.50	87.00
B→A	67.75	71.75	63.75	80.75	73.75	92.25
B→C	91.50	92.75	90.50	94.50	95.50	96.50
B→D	89.00	91.75	85.00	93.50	96.50	96.75
C→A	54.25	67.00	56.25	75.25	74.00	91.50
C→B	93.50	94.75	95.00	94.25	96.50	96.75
C→D	94.00	94.50	92.50	93.50	94.75	97.25
D→A	35.75	53.50	34.75	51.75	54.50	79.75
D→B	67.00	85.00	73.50	86.50	89.50	94.00
D→C	94.50	91.50	91.25	91.25	94.00	91.00
均值	74.11	78.60	73.44	81.35	83.56	90.25
标准差	0.172 8	0.139 9	0.175 2	0.129 2	0.126 1	0.750 6
排序	5	4	6	3	2	1

4 结 论

1) 提出了一种多尺度混合域特征提取器。特征提取器集成了先进的信号处理方法,可以更完整地表征信号,能够在复杂环境中发挥强大的非线性提取能力。

2) 提出了一种基于随机森林的特征优化器,不仅减小了特征维数,消除了冗余信息,还给出了特征的重要性程度,可了解不同特征对诊断和识别的贡献,从而选择敏感的特征子集进行诊断。

3) 引入一种基于流形嵌入分布对齐的领域自适应方法,以解决轴承在不同工况下的跨领域诊断难题。通过提出的框架设计及变负载实验,证明了与传统的智能诊断方法和迁移学习方法相比,该方法的有效性和优越性。


4) 所提出方法是根据经验确定VMD算法的关

键参数,未来可通过群体智能优化算法求解最优参数。此外,该方法还可以应用于齿轮箱、转子、电动机和液压设备的故障诊断。

参 考 文 献

- [1] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5):94-104. (in Chinese)
- [2] YAN X, JIA M. A novel optimized SVM classification algorithm with multi-domain feature and its application to fault diagnosis of rolling bearing[J]. Neurocomputing, 2018, 313:47-64.
- [3] YAN R, LIU Y, GAO R X. Permutation entropy: a nonlinear statistical measure for status characterization of rotary machines[J]. Mechanical Systems and Signal Processing, 2012, 29:474-484.
- [4] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [5] 张西宁,张雯雯,周融通,等. 基于多维缩放和随机森林的轴承故障诊断方法[J]. 西安交通大学学报, 2019, 53(8):1-7.
ZHANG Xining, ZHANG Wenwen, ZHOU Rong-tong, et al. Bearing fault diagnosis method based on multiple dimensional scaling and random forest[J]. Journal of Xi'an Jiaotong University, 2019, 53(8):1-7. (in Chinese)
- [6] DIBAJ A, ETTEFAGH M M, HASSANNEJAD R, et al. A hybrid fine-tuned VMD and CNN scheme for untrained compound fault diagnosis of rotating machinery with unequal-severity faults [J]. Expert Systems with Applications, 2021, 167: 114094.
- [7] 吴东升,杨青,张继云,等. 基于VMD-LMD-CNN的集合型故障诊断方法[J]. 轴承, 2020(10):57-63.
WU Dongsheng, YANG Qing, ZHANG Jiyun, et al. Ensemble fault diagnosis method based on VMD-LMD-CNN[J]. Bearing, 2020(10):57-63. (in Chinese)
- [8] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [9] GONG B, SHI Y, SHA F, et al. Geodesic flow kernel for unsupervised domain adaptation [C] //2012 IEEE Conference on Computer Vision and Pattern

- Recognition. Washington, D. C.: IEEE Computer Society, 2012: 2066-2073.
- [10] LONG M, WANG J, DING G, et al. Transfer joint matching for unsupervised domain adaptation[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Washington, D. C.: IEEE Computer Society, 2014: 1410-1417.
- [11] 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.
- [12] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation [C] //2013 IEEE International Conference on Computer Vision. Washington, D. C.: IEEE Computer Society, 2013: 2200-2207.
- [13] WANG J, FENG W, CHEN Y, et al. Visual domain adaptation with manifold embedded distribution alignment[C]//Proceedings of the 26th ACM International Conference on Multimedia. [S.l.]: Association for Computing Machinery, 2018:402-410.
- [14] YU C, WANG J, CHEN Y, et al. Transfer learning with dynamic adversarial adaptation network[C]//2019 19th IEEE International Conference on Data Mining. Washington, D. C.: IEEE Computer Society, 2019: 778-786.
- [15] GUO L, LEI Y, XING S, et al. Deep convolutional transfer learning network: a new method for intelligent fault diagnosis of machines with unlabeled data [J]. IEEE Transactions on Industrial Electronics, 2019, 66(9): 7316-7325.
- [16] WEN L, GAO L, LI X. A new deep transfer learning based on sparse auto-encoder for fault diagnosis [J]. IEEE Transactions on Systems Man Cybernetics-Systems, 2019, 49(1): 136-144.
- [17] 雷亚国, 何正嘉, 訾艳阳. 基于混合智能新模型的故障诊断[J]. 机械工程学报, 2008, 44(7): 112-117.
LEI Yaguo, HE Zhengjia, ZI Yanyang. Fault diagnosis based on novel hybrid intelligent model [J]. Chinese Journal of Mechanical Engineering, 2008, 44(7): 112-117. (in Chinese)
- [18] 王冬云, 张文志, 张建刚. 小波包能量谱在滚动轴承故障诊断中的应用[J]. 轴承, 2010(11): 32-36.
WANG Dongyun, ZHANG Wenzhi, ZHANG Jianguang. Application of wavelet packet energy spectrum in rolling bearing fault diagnosis[J]. Bearing, 2010(11): 32-36. (in Chinese)
- [19] CHEN P, TANIGUCHI M, TOYOTA T, et al. Fault diagnosis method for machinery in unsteady operating condition by instantaneous power spectrum and genetic programming[J]. Mechanical Systems and Signal Processing, 2005, 19(1): 175-194.
- [20] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series[J]. Physical Review Letters, 2002, 88(17): 174102.
- [21] PINCUS S M. Approximate entropy as a measure of system-complexity[J]. Proceedings of the National Academy of Sciences of the United States of America, 1991, 88(6): 2297-2301.
- [22] LABATE D, la FORESTA F, MORABITO G, et al. Entropic measures of eeg complexity in alzheimer's disease through a multivariate multiscale approach [J]. IEEE Sensors Journal, 2013, 13(9): 3284-3292.
- [23] CHEN W, WANG Z, XIE H, et al. Characterization of surface EMG signal based on fuzzy entropy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2007, 15(2): 266-272.
- [24] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008(9): 2579-2605.



第一作者简介:雷子豪,男,1995年11月生,博士生。主要研究方向为深度学习、迁移学习、机械状态监测、智能故障诊断和预测等。

E-mail: zihao_lei@163.com

通信作者简介:温广瑞,男,1976年7月生,博士、教授。主要研究方向为机械运行状态故障诊断及性能维护、现场动平衡理论及方法、远程及现场监测与系统开发。

E-mail: grwen@mail.xjtu.edu.cn