

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2023.0166

基于多层域适应的无标签数据故障诊断方法

王进花^{1,*}, 刘瑞¹, 曹洁^{1,2}

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 甘肃省制造信息工程研究中心, 兰州 730050)

摘 要: 在工业生产中, 由于源域数据和目标域数据分布有差异且有标签的故障数据量较少, 以至于现有的域适应轴承故障诊断方法大多精度不高。基于此, 提出多层域适应神经网络(MDANN)故障诊断方法, 用于无标签数据的滚动轴承故障诊断。使用小波包分解与重构(WPT)对原始振动信号进行处理, 以降低信号冗余并避免关键信号特征遗失; 利用多核最大均值差异(MK-MMD)算法对输入特征值进行差异计算, 并通过反向传播更新多层域适应神经网络的参数, 使其能够提取域不变特征; 为保证无标签目标域数据可以正常参与网络训练, 使用最大概率标签作为真实标签的伪标签策略, 解决目标域无标签数据无法训练问题, 增强模型可靠诊断知识的获取。采用2个公开数据集CWRU和PU进行验证。实验结果表明: 所提方法与常见的域适应方法对比具有更高的诊断精度, 说明该方法能够有效地学习可迁移特征, 拟合2个数据集之间的数据分布差异。

关 键 词: 滚动轴承; 故障诊断; 迁移学习; 多层域适应; 伪标签策略

中图分类号: TP277; TD453

文献标志码: A

文章编号: 1001-5965(2025)04-1185-10

近年来, 随着机器学习的蓬勃发展, 基于深度学习的故障诊断逐渐用于工业领域并取得了良好的效果^[1-4]。但是, 深度学习具有一定的局限性, 如要求训练集和测试集必须具有相同的特征分布、标注数据必须充足等。在实际的工业生产中, 由于滚动轴承的转速、负荷、扭矩等工作状态多变, 这使得原始的振动信号具有不同的特征分布并且部分工况数据采集困难, 无法满足以上2个要求。

迁移学习方法被认为是解决上述问题的有效方法之一, 其放宽了以上2个前提条件, 近年来被用于解决数据缺失状况下的故障诊断问题。Ma等^[5]构建了基于AlexNet卷积网络的故障诊断迁移学习模型, 并引用了一种新的数据处理方式频率切片小波变换(frequency slicing wavelet transform, FSWT), 用于一维振动信息转换成二维图像, 解决模型搭建时间久、诊断精度低的问题。Wu等^[6]通过在训练

过程中加入额外的噪声干扰来增强故障诊断模型对于工作条件改变的适应性问题。刘飞等^[7]将残差网络和迁移学习相结合进行迁移学习故障诊断模型搭建, 进行滚动轴承快速故障诊断, 极大地缩短了诊断时间。Zou等^[8]基于小波包分解与重构(wavelet packet transformation, WPT)的思想进行数据转换, 并利用t-sne研究不同工况下迁移学习的可行性, 总结了不同工况下轴承故障诊断的技术细节。上述文献利用参数迁移的方法来完成轴承的故障诊断, 在保证高精度的同时也降低了模型的训练时间。然而对于一些机器来讲, 很难采集到带标记的故障数据。主要原因在于机器从正常运行到故障需要漫长地退化过程, 人为很难捕捉到故障时机, 即使某个机器发生故障后, 也会立马进行替换或修理, 避免机器损坏带来经济损失。

为解决无标记数据的训练问题, Zhao等^[9]通过

收稿日期: 2023-04-06; 录用日期: 2023-06-09; 网络出版时间: 2023-06-29 11:39

网络出版地址: link.cnki.net/urlid/11.2625.V.20230628.1442.003

基金项目: 国家重点研发计划(2020YFB1713600); 国家自然科学基金(62063020); 甘肃省自然科学基金(20JR5RA463)

*通信作者. E-mail: wjh0615@lut.edu.cn

引用格式: 王进花, 刘瑞, 曹洁. 基于多层域适应的无标签数据故障诊断方法[J]. 北京航空航天大学学报, 2025, 51(4): 1185-1194.

WANG J H, LIU R, CAO J. Unlabeled data fault diagnosis method based on multi-domain adaptation[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(4): 1185-1194 (in Chinese).

添加软阈值构建深度收缩残差网络提取噪声冗余下的轴承振动数据的特征信息,对输入特征进行边缘分布约束完成故障诊断。Shao 等^[10]通过多核最大均值差异 (multi-kernel maximum mean discrepancy, MK-MMD) 距离度量方式减小源域和目标域之间的特征分布差异,提高模型在目标域中的分类精度。Xu 等^[4]提出联合均值差异匹配算法建立公共子空间,从而完成对工业过程的故障诊断。上述文献基于一个基本假设即目标域数据充足,但实际工业生产中,数据实用性不强,导致目标域数据不足以训练出高精度模型。因此,本文提出一种基于多层域适应结合伪标签策略的轴承故障诊断方法。该方法通过模型迭代收集源域和目标域数据的可迁移特征,达到对无标签目标域数据的健康状况识别目的。

本文的创新点为:①将小波包分解与重构算法与轴承故障诊断相结合,在数据处理层面对原始振动信号进行特征优化,既避免信号冗余又保证减少特征遗失;②构建多层域适应神经网络 (multi-dimain adaptation neural network, MDANN) 模型,利用源域的诊断知识来识别无标签的目标域样本,跨域边缘分布差异小、类间距离小,能够学习到可迁移特征;③提出多层域适应和伪标签相结合的特征迁移策略,前者逐层减小了源域和目标域学习到的数据可转移特征之间的分布差异,后者利用概率统计思想,取最大概率作为样本标签,解决目标域无标签数据的训练问题。

1 问题描述

本文旨在基于特征迁移思想建立一个轴承故障诊断模型,但源域和目标域的轴承数据来自于不同的数据集,因此,这些数据的特征分布存在严重差异^[4,11]。如果直接使用卷积神经网络 (convolutional neural networks, CNN) 模型学习到的源域特征用于目标域数据的诊断,诊断精度无法保证^[12],如图 1(a) 所示。为解决该问题,在模型搭建的过程中添加一个新的模块,即域自适应模块。通过该模块使得模型可以学习源域数据和目标域数据的可迁移特征,从而实现源域数据提供的诊断知识能够正确识别目标域的样本,如图 1(b) 所示。

使用 D^s 表示源域,使用 D^t 表示目标域。若源域的样本空间 $\chi^s \in D^s$,目标域的样本空间 $\chi^t \in D^t$,那么分别从源域和目标域获取的样本数据则可以表示为 $x^s \in \chi^s$ 和 $x^t \in \chi^t$ 。设定标签空间 $y = \{1, 2, \dots, k\}$,共 k 种健康状况,且源域的健康状况包含目标域的健康状况,即 $y^t \subseteq y^s \subseteq y$ 。同时假设源域和目标域的边




图 1 域适应
Fig. 1 Domain adaptation

缘概率分布分别为 $P(x^s)$ 和 $Q(x^t)$ 。本文主要目的是利用从源域数据中获取诊断知识,对无标签的目标域进行准确诊断,即使用源域 $D^s = \{\chi^s, P(x^s)\}$ 的 m 个带标签样本数据 $\chi^s = \{x_i^s, y_i^s\}_i^m$ 提供充足的各类健康状况信息,对目标域 $D^t = \{\chi^t, P(x^t)\}$ 的 n 个不带标签的样本数据 $\chi^t = \{x_j^t\}_{j=1}^n$ 进行故障状态识别。本文所搭建的模型由数据处理、特征提取、域自适应和故障分类 4 部分组成。在数据处理过程中,利用包分解与重构方法对原始振动信息进行再加工。其中,源域数据包含所有的故障类型且标记清晰,提供诊断知识。目标域样本缺少标记,利用源域的诊断知识进行分类。在特征提取方面,将源域数据和目标域数据同时放入搭建的网络中,通过网络迭代从而提取域不变特征。域自适应模块是指利用 MK-MMD 计算 3 层全连接层后输出特征的差异值,并通过反向传播缩小差异,从而获取可迁移特征。最后,对传入分类器的样本特征进行分类。

2 方法介绍

2.1 小波包分解与重构

深度学习模型通常使用反向传播算法来学习特征,利用多层神经网络逐层提取数据的高层次特征。该方法可以在大数据集上取得很好的效果,但如果数据集较小或存在噪声影响时,深度学习模型容易过拟合,导致泛化能力不足。因此,引入 WPT 算法去除冗余信息和噪声干扰,生成更加稳健的特征表示。

小波包分解与重构提供一种更加精细的信号分析方法,从而将时频平面划分得更细致,同时引入了最优基选择的概念。

在频带经过多层次的划分后,根据被分析信号的特征,自适应地选取最佳基函数与信号相匹配。

从函数理论的角度来看,小波包分解是将信号投影到小波包基函数生成的空间中。从信号处理的角度来看,其是让信号通过系列中心频率不同但带宽相同的滤波器,细化信号的高频部分、抑制噪声并提高信号的分析能力。

设 $x(n)$ 为一段振动信号, $p_i^j(n)$ 表示第 j 层上的第 i 个小波包, 其包系数为 C_i^j 。在进行分解和重构的过程中, 通过计算出小波包节点的 j 相对能量 R_{EWP}^j 和熵 E_{WPN}^j 评估最优子结构, 对相关小波包进行筛选。WPT 的过程如下:

$$\begin{cases} p_j^{2^{i-1}} = \sum_{k=1}^k h(k-2)p_{j-1}^i(n) \\ p_j^{2^i} = \sum_{k=1}^k g(k-2l)p_{j-1}^i(n) \end{cases} \quad (1)$$

$$p_j^i(t) = \sum_{k=1}^k h(l-2k)p_{j+1}^{2^{i-1}} + \sum_{k=1}^k g(l-2k)p_{j+1}^{2^i} \quad (2)$$

式中: $h(\cdot)$ 为低通滤波器; $g(\cdot)$ 为高通滤波器; k, l 为分解层数。小波包筛选依据如下:

$$E_{\text{WPN}}^j(i) = - \sum_{j=1}^K P_i^j \log_2(P_i^j) \quad (3)$$

$$R_{\text{EWP}}^j(i) = \frac{\sum_{j=1}^K (C_i^j)^2}{\sum_{m=1}^N \sum_{j=1}^K (C_m^j)^2} \quad (4)$$

式中: N 为小波包节点总数; K 为每个小波包节点的小波包系数总数。

2.2 多核最大均值差异

MK-MMD 是基于单核最大均值差异的一种改进方法。其将数据分布 x, y 通过核函数 $\varphi(\cdot)$ 映射到希尔伯特空间 H 上, 筛选多个核进行线性组合构成最优的核:

$$d_k^2(x, y) \triangleq \|E_x[\phi(x^s)] - E_y[\phi(x^t)]\|_{H_k}^2 \quad (5)$$

m 个核一起定义的特有核可以被表示为

$$K \triangleq \{k = \sum_{u=1}^m \beta_u k_u : \sum_{u=1}^m \beta_u = 1, \beta_u \geq 0, \forall u\} \quad (6)$$

MK-MMD 的损失值可以表示为: $d = \sum_{l=l_1}^{l_3} d_k^2(D_s^l, D_t^l)$ 。最终通过最小化损失函数来减少网络学习到的可迁移特征的分布差异, 可以表示为

$$\min_{\theta} \sum_{l=l_1}^{l_3} d_k^2(D_s^l, D_t^l) \quad (7)$$

式中: $l \subseteq \{l_1, l_2, l_3\}$; θ 表示全连接层 F1、F2、F3 的参数集。

2.3 伪标签策略

基于多层域适应策略, 可以减小学习到的可迁移特征的分布差异。而由于目标域数据没有标签导致最后一层全连接层参数无法进行训练。为解决

决模型无法训练问题, 引入伪标签学习策略。

伪标签策略的核心思想就是将预测概率最大的标签作为真实标签, 并通过网络迭代训练使得伪标签无限接近真实标签。其生成包括样本标签概率预测和伪标签的转换 2 个步骤。其中, 最后一层的 softmax 函数会计算出样本标签的概率分布, 根据该概率分布, 将其转换为该样本最终的标签。具体计算式为

$$y^s = \{1, 2, \dots, k\} \quad (8)$$

$$y_i^t = \begin{cases} \max\{y^s, y_i^t\} \\ 0 \end{cases} \quad (9)$$

式中: y_i^t 为目标域第 i 个样本的伪标签。

由于源域和目标域样本都用于训练共享 CNN 参数, 那么伪标签的学习目标优化可表示为

$$\min_{\theta} = \frac{1}{m} \sum_{i=1}^m J(y_i^s, F) + \lambda \frac{1}{n} \sum_{j=1}^n J(y_j^t, F) \quad (10)$$

式中: m 和 n 分别为源域和目标域样本的数量; $J(\cdot)$ 为交叉熵损失函数; y_i^s 为源域中第 i 个样本的真实标签; F 为域共享参数; λ 为权衡参数; θ 为域共享 CNN 的参数集。

3 本文方法

3.1 基本网络架构

模型的基本网络架构由输入层、卷积层、池化层及全连接层 4 部分组成, 网络结构如图 2 所示, 网络中具体参数信息如表 1 所示。

输入层是由 2 个长度为 N 的振动信号组成, 每 2 048 个样本点构成一个数据样本。其中, 源域数据集的样本有标签, 目标域数据集样本无标签。

卷积层进行一维卷积运算^[13]。假设卷积核的大小为 $w_c \in \mathbf{R}^{H \times D}$, 第 i 个被切割的样本点表示为 $x_{j-m+1:j}^i \in \mathbf{R}^{H \times D}$, b_c 为相应的偏置, 那么一次卷积操作可以描述为

$$c_j = R_{\text{elu}} \left(\sum_{i=1}^n x_{j-m+1:j}^i w_c + b_c \right) \quad (11)$$

池化层位于卷积层之后, 用于降低卷积池化的维数, 减少网络训练参数从而有效克服过拟合问题^[14]。本文采用最大池化策略, 若池化的最大范围为 m , 池化的向量记为 $\mathbf{x}_j$, 池化后的结果记为 $\mathbf{l}_j$ 。一次池化操作可描述为

$$\mathbf{l}_j = \max\{\mathbf{x}_{j:m:j(m+1)}\} \quad (12)$$

原始信号经过 4 次卷积和池化操作后, 利用全连接层将输入的域不变特征映射为一维向量^[15]。假设输入的域不变特征在全连接层 F1 前, 则记为




图 2 本文方法网络结构

Fig. 2 Network structure of the proposed method

表 1 网络参数详解			
Table 1 Detailed explanation of network parameters			
网络层	网络参数	激活函数	输出尺寸
输入层			2 048×1
卷积层C1	3×1×20	非线性映射Relu	2 046×20
卷积层C2	3×20×20	非线性映射Relu	1 020×20
卷积层C3	3×20×20	非线性映射Relu	508×20
卷积层C4	3×20×20	非线性映射Relu	252×20
池化层P1~P6	2×1		
全连接层F1			5 040×1
全连接层F2	5 040×256		256×1
全连接层F3	256×5	分类函数SoftMax	5×1

$\mathbf{x}_i^{F0,D}$, D 表示一维 CNN。那么输入到 F2 层的域不变特征则可由式(13)推导:

$$\mathbf{x}_i^{F1,D} = \sigma_t(\mathbf{w}^{F1} \mathbf{x}_i^{F1,D} + \mathbf{b}^{F1}) \tag{13}$$

经过 3 次全连接操作后, 进行最终的特征分类^[16-17]。由分类函数 softmax 来预测样本 $\mathbf{x}_i^s$ 和 $\mathbf{x}_i^t$ 的标签, F3 层输出的样本标签概率分布可以用式(14)和式(15)推导:

$$\mathbf{I}_i^{F3,D} = [P(y_i^D = 1|\mathbf{x}_i^{F2,D})P(y_i^D = 2|\mathbf{x}_i^{F2,D})\cdots P(y_i^D = k|\mathbf{x}_i^{F2,D})] \tag{14}$$

$$P(y_i^D = i|\mathbf{x}_i^{F2,D}) = \frac{\exp((\mathbf{w}_j^{F3})^T \mathbf{x}_i^{F2,D} + \mathbf{b}^{F3})}{\sum_{j=1}^n \exp((\mathbf{w}_j^{F3})^T \mathbf{x}_i^{F2,D} + \mathbf{b}^{F3})} \tag{15}$$

式中: $\mathbf{w}_j^{F3}$ 和 $\mathbf{b}^{F3}$ 为 F3 层的权重和偏置; $\mathbf{I}_i^{F3,D} = [\mathbf{I}_i^{F3,s}, \mathbf{I}_i^{F3,t}]$ 为数据样本的标签概率分布。

3.2 网络的训练过程

本文提出的 MDANN 模型通过联合最小化 3 个

正则化项来进行训练: ①源域样本的预测标签与真实标签之间的误差; ②目标域数据训练使用伪标签所带来的损失; ③跨域数据学习到的域不变特征的多层 MK-MMD 值。结合 3 个优化目标, 该网络的损失函数定义为

$$L = L_c + \lambda L_p + \mu d_k^2 \tag{16}$$

式中: λ 、 μ 为权衡参数, 根据训练结果动态调整。

在训练过程中, 使用随机梯度下降(stochastic gradient descent, SGD)^[18-19] 算法根据损失函数值进行参数优化。设 θ_c 为健康状况分类器的参数, 那么式(16)中的损失函数可以改写为

$$L(\theta_f^*, \theta_c^*, \theta_p^*) = \min_{\theta_f, \theta_c, \theta_p} L_c(\theta_f, \theta_c) + \lambda L_p(\theta_p) + \mu d_k^2(\theta_f) \tag{17}$$

由随机梯度算法和式(15), 参数 θ_f 、 θ_c 、 θ_p 将会按照如下规则更新:

$$\theta_f \leftarrow \theta_f - \varepsilon \left(\frac{\partial L_c}{\partial \theta_f} - \lambda \frac{\partial L_d}{\partial \theta_f} + \mu \frac{\partial d_k^2}{\partial \theta_f} \right) \tag{18}$$

$$\theta_c \leftarrow \theta_c - \varepsilon \frac{\partial L_c}{\partial \theta_c} \tag{19}$$

$$\theta_p \leftarrow \theta_p - \varepsilon \frac{\partial L_p}{\partial \theta_p} \tag{20}$$

式中: ε 为学习率, 在本文中为 0.000 1。

4 实验验证

为证明本文方法的有效性, 使用公开数据集设计实验进行相关验证。当网络的损失值不再下降或训练次数达到 3 000 时, 保存网络参数, 使用无标签的目标域数据进行测试。由于该网络模型从目

标域中学习到的特征分布与源域样本相似, 因此, 分类器可以正确地对目标域中的未标记样本进行分类。具体训练过程如图 3 所示。




图 3 网络训练流程
Fig. 3 Network training flow

4.1 滚动轴承数据集

CWRU 轴承数据集来自于 SKF 公司型号 6205-2RS 的滚动轴承实验平台的数据采集, 如图 4 所示。本文选择了内圈直径为 0.18 mm 和 0.36 mm, 外圈直径为 0.18 mm 和 0.36 mm 及正常状态 5 种健康类型滚动轴承来做故障诊断检测^[19-20]。





图 4 CWRU 滚动轴承实验平台
Fig. 4 CWRU rolling bearing test platform

PU 轴承数据集是由型号为 6203 的滚动轴承实验平台进行数据采集而成。如图 5 所示, 本文使用其中的电加工放点实验产生的人工故障数据。选取内圈故障 1、故障 2, 外圈故障 1、故障 2, 健康状态 5 种滚动轴承进行健康状况识别。

参与训练和测试的数据集的基本情况如表 2 所示。



1.电机; 2.扭矩测量单元; 3.轴承测量单元; 4.飞轮; 5.负载电机。

图 5 PU 滚动轴承实验平台
Fig. 5 PU rolling bearing test platform

表 2 数据集的基本情况 Table 2 Basic information of datasets			
数据集	转速/(r·min ⁻¹)	负载/N	训练集/测试集 (故障样本数)
数据集A(CWRU)	1 700	1 470	1 500/500
数据集B (PU)	1 500	1 000	1 500/500

4.2 权衡参数的确定

为有效提高 MDANN 的特征提取效果, 需要对模型的损失函数做充分的研究。而参数 λ 、 μ 作为损失函数的一部分, 对模型的特征提取能力有着重要的影响。因此, 对参数选择的研究非常必要。

分类精度与学习到的 F2 层全连接层的可迁移特征密切相关。通过计算 F2 层输出特征的 MMD 损失值来评估 MDANN 模型选择不同参数的特征迁移效果, 进而衡量参数选择的优劣。动态参数 λ 和 μ 分别从数据集合 {0,0.05,0.1,0.3,0.5,1} 及 {0.01,0.05,0.1,0.15,0.2,0.25,0.3,0.35} 中取得, 最终实验取 10 次训练的平均值。实验结果如图 6 所示, 其中, x 轴表示 μ 值, y 轴表示对应的 MMD 损失值, 不同颜色的折线表示参数 λ 的取值。

由图 6 可知, 当权衡参数 μ 小于 0.15 时, MMD 损失值明显较大, 说明学习到的可迁移特征适应能力弱。一旦将权衡参数 λ 设置为较大的值, 如大于 0.1, 则跨域差异也难以校正。因此, 选定最终的结果: λ 为 0.05, μ 为 0.15。




图 6 不同实验参数的诊断结果
Fig. 6 Diagnosis results of different experimental parameters

4.3 不同数据处理对诊断精度的影响

为验证不同数据处理方法对模型诊断精度的影响,采用数据集 A、B 进行实验。实验中将 WPT、短时傅里叶变换(short time Fourier transform, FFT)、连续小波变换(continuous wavelet transform, CWT)及不做任何处理 4 种数据处理方法进行对比。迁移任务 A->B 数据集和 B->A。在实验过程中,所有方法均调整至最优的参数,并取 10 次结果的平均值作为最终的结果,具体诊断效果如表 3 所示。

由表 3 可知:①在 A->B 和 B->A 迁移任务中,对原始振动数据进行数据处理比不进行数据处理所得的诊断精度要高,说明数据处理对于故障诊断的必要性;②使用 CWT 和 FFT 可以完成故障诊断,精度在 73% 左右,效果并不理想;③使用 WPT 进行数据的拆分并组合的方式可以达到最优的诊断效果,在 A->B 和 B->A 的迁移任务中,均达到最优诊断效果,诊断精度分别为 82.14% 和 80.37%,说明本文方法的优越性。

为进一步了解不同参数的分类细节,在进行 A->B 训练任务时绘制了轴承分类的混淆矩阵,如图 7

表 3 不同数据处理方法的诊断精度

Table 3 Diagnosis accuracy of different data processing methods			
数据处理方法	输入特征	迁移任务	诊断精度/%
不做处理	2 048×1	A->B	62.23
FFT	2 048×1	A->B	71.48
CWT	2 014×1	A->B	73.65
WPT	2 048×1	A->B	82.14
不做处理	2 048×1	B->A	54.21
FFT	2 048×1	B->A	75.47
CWT	2 014×1	B->A	71.56
WPT	2 048×1	B->A	80.37

所示。图中,坐标轴上的 5 个参数代表轴承的 5 种健康状态,对角线上的所有数据识别正确的样本数目占总样本数据的百分比。由图 7 可知:①正常状态的轴承基本都能被识别出来;②内圈故障 1 的诊断效果较差,但易于内圈故障 2 的诊断混淆,这可能与 2 个数据集之间的数据特征有关;③4 种方法均取到了 60% 以上的诊断精度,使用 WPT 方法时达到了最优的分类效果,诊断精度为 82.14%。




图 7 轴承分类的混淆矩阵

Fig. 7 Confusion matrix for bearing classification

4.4 多层域适应对诊断精度的影响

为验证不同层数的域适应算法对诊断精度的影响, 将 MK-MMD 算法分别加在第 1 层全连接层后, 第 1 层、第 2 层全连接层后, 第 1 层、第 2 层、第 3 层全连接层后及不添加 4 种情况做对比。具体故障诊断效果如表 4 所示。

表 4 多层域适应对诊断精度的影响

Table 4 Effect of multi-domain adaptation on diagnosis accuracy

处理策略	训练时间/s	训练任务	诊断精度/%
不添加MK-MMD	93	A->B	37.21
F1处添加MK-MMD	108	A->B	71.32
F1,F2处添加MK-MMD	124	A->B	77.56
F1,F2,F3处添加MK-MMD	147	A->B	82.94
不添加MK-MMD	89	B->A	41.83
F1处添加MK-MMD	97	B->A	75.89
F1,F2处添加MK-MMD	123	B->A	79.87
F1,F2,F3处添加MK-MMD	148	B->A	83.21

由表 4 可知: ①在相同的训练任务下, 随着 MK-MMD 算法逐层加入, 训练时间也随之增多。每多一层加入 MK-MMD 算法来计算输出特征的差异值, 训练时间就会增多 15 s 左右; ②MK-MMD 算法的不断加入使得模型域适应能力明显增强, 分类任务完成的更加出色; ③当所有全连接层都加入 MK-MMD 算法后, 分类效果达到最优, 在 A->B 和 B->A 的迁移任务中, 诊断精度分别为 82.94% 和 83.21%。

通过 t-分布领域嵌入(t-distributed stochastic neighbor embedding, t-SNE)算法, 可以将上述算法全连接层处提取出来的故障特征降维至二维平面, 并以散点图的形式呈现,从而可以对不同算法分类结果进行更为直观的展示。在 A->B 迁移任务下, 4 种不同处理策略提取的特征可视化结果如图 8 所示。

由图 8 可知: ①未加入域适应算法分类效果极差, 各个故障类别之间的界限不够明显, 不同类别之间的特征相互堆叠, 诊断精度只有 37.21%; ②在全连接层处加入 MK-MMD 算法时, 模型的域适应能力得到增强, 可以有效提取 2 个数据集之间的公共特征, 诊断精度明显提高, 为 71.32%; ③随着逐层在全连接处添加域适应算法 MMD 时, 不同类别之间几乎没有特征堆叠, 诊断精度逐步提高。

4.5 不同方法诊断精度对比

为验本文方法的优越性, 将该方法与常见的域适应算法进行对比实验。本文选取迁移成分分析(transfer component analysis, TCA)^[21]、深度域混淆(deep domain confusion, DDC)^[22] 网络、深度自适应




图 8 不同处理策略对于诊断精度影响的 t-SNE 可视化
Fig. 8 t-SNE visualization of effects of different processing strategies on diagnosis accuracy

网络 (deep adaptation network, DAN)^[23]、与域适应神经网络 (domain adaptive neural network, DANN)^[24] 4 种迁移学习网络及不添加域适应模块的 MDANN。其中, TCA 主张最小化源域 s 的概率分布 $P(\phi(X^s))$ 和目标域 t 的概率分布 $Q(\phi(X^t))$ 之间的距离; DDC 的核心理念在于使用 MMD 度量全连接层的第 2 层处的特征差异; DAN 的主要思想是使用 MK-MMD 度量多个全连接层的差异, 并以相加的方式处理计算结果; DANN 是 MDANN 的简化版本, 只进行域混淆, 没有做差异度量。DAN 的网络输入是一维数据, DDC、DANN 的输入是经过小波变换处理后的二维数据。本次的迁移任务是 A->B 和 B->A。在实验过程中, 所有模型均调整至最优的参数, 并取 10 次实验结果的平均值作为最后的结果, 具体诊断效果如表 5 所示。

表 5 不同模型的精度

Table 5 Accuracy of different models

网络模型	是否域适应	迁移任务	输入特征	诊断精度/%
TCA	否	A->B	2 048×1	47.12
DDC	是	A->B	224×224×3	74.32
DAN	是	A->B	2 048×1	76.86
DANN	是	A->B	224×224×3	77.58
MANN	否	A->B	2 048×1	32.15
MDANN	是	A->B	2 048×1	84.17
TCA	否	B->A	2 048×1	28.21
DDC	是	B->A	224×224×3	65.36
DAN	是	B->A	2 048×1	74.21
DANN	是	B->A	224×224×3	75.36
MANN	否	B->A	2 048×1	36.58
MDANN	是	B->A	2 048×1	82.15

由表 5 可知: ①具备域适应的模型能够有效学习到可迁移特征,使得完成迁移任务的效果远远优于未具备域适应功能的网络模型; ②仅通过度量输出特征的差异值或仅通过加入域鉴别器进行域混淆虽然可以完成迁移任务,但效果并不理想,诊断精度均在 60%~75% 之间; ③MDANN 在迁移任务 A->B 和 B->A 中均表现优异,诊断精度分别为 84.17% 和 82.15%,在 6 个网络模型中排名第 1。

对 A->B 迁移任务进行 t-SNE 可视化,如图 9 所示。由图 9 可知: ①TCA、MDANN(未添加域适应模型)各个故障类别之间的界限不够明显,不同类别之间的特征相互堆叠,导致诊断精度不断下降; ②DCC、DAN、DANN 部分故障类型堆叠较多,导致模型识别困难,诊断性能不理想; ③MDANN 模型的散点分布图在 6 个迁移模型中的故障重叠最少,使得故障分辨简单,可以达到最好的分类结果,也进一步说明了该模型在故障诊断领域的优越性。




图 9 不同模型的 t-SNE 图

Fig. 9 t-SNE diagrams of different models

5 结 论

本文提出一种基于多层域适应的滚动轴承故障诊断方法,用于解决无标签的故障数据不足的问题,结论如下:

- 1) 鉴于 FFT 缺乏时间对频率的定位, CWT 数据量大,数据具有冗余性的问题,利用 WPT 对原始轴承数据进行重构,优化原始数据的特征表示,使得网络可以提取深度特征;
 - 2) 针对源域数据和目标域数据分布有差异的问题,对全连接层进行多层域适应,使用 MK-MMD 来度量差异,并使用叠加或相乘方式验证 2 种策略的优异性;
 - 3) 针对目标域没有标签导致最后一个全连接层无法进行训练,使用伪标签策略来解决模型无法训练的问题,从而提高了模型的域适应能力。
- 未来将对模型内部特征提取层做出优化,从而更好的提取可迁移特征。同时,将本文方法嵌入到单片机内,设计出一套具有实时诊断能力的嵌入式平台,应用于工业故障诊断领域。

参考文献 (References)

[1] YU X, LIANG Z T, WANG Y J, et al. A wavelet packet transform-based deep feature transfer learning method for bearing fault diagnosis under different working conditions[J]. Measurement, 2022, 201: 111597.

[2] HU Q, SI X S, QIN A S, et al. Balanced adaptation regularization based transfer learning for unsupervised cross-domain fault diagnosis[J]. IEEE Sensors Journal, 2022, 22(12): 12139-12151.

[3] 赵小强, 张青青, 陈鹏, 等. 基于 PSO-BFA 和改进 Alexnet 的滚动轴承故障诊断方法[J]. 振动与冲击, 2020, 39(7): 21-28.

ZHAO X Q, ZHANG Q Q, CHEN P, et al. Rolling bearing fault diagnosis method based on improved Alexnet and PSO-BFA[J]. Journal of Vibration and Shock, 2020, 39(7): 21-28(in Chinese).

[4] XU W, WAN Y, ZUO T Y, et al. Transfer learning based data feature transfer for fault diagnosis[J]. IEEE Access, 2020, 8: 76120-76129.

[5] MA P, ZHANG H L, FAN W H, et al. A novel bearing fault diagnosis method based on 2D image representation and transfer learning-convolutional neural network[J]. Measurement Science and Technology, 2019, 30(5): 055402.

[6] WU Z H, JIANG H K, ZHAO K, et al. An adaptive deep transfer learning method for bearing fault diagnosis[J]. Measurement, 2020, 151: 107227.

[7] 刘飞, 陈仁文, 邢凯玲, 等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法[J]. 振动与冲击, 2022, 41(3): 154-164.

LIU F, CHEN R W, XING K L, et al. Fast fault diagnosis algorithm for rolling bearing based on transfer learning and deep residual network[J]. Journal of Vibration and Shock, 2022, 41(3): 154-164(in Chinese).

[8] ZOU Y S, LIU Y Z, DENG J L, et al. A novel transfer learning method for bearing fault diagnosis under different working conditions[J]. Measurement, 2021, 171: 108767.

[9] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage

networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4681-4690.

[10] SHAO J J, HUANG Z W, ZHU J M. Transfer learning method based on adversarial domain adaption for bearing fault diagnosis[J]. IEEE Access, 2020, 8: 119421-119430.

[11] LI B, TANG B P, DENG L, et al. Joint attention feature transfer network for gearbox fault diagnosis with imbalanced data[J]. Mechanical Systems and Signal Processing, 2022, 176: 109146.

[12] 张根保, 李浩, 冉琰, 等. 一种用于轴承故障诊断的迁移学习模型[J]. 吉林大学学报 (工学版), 2020, 50(5): 1617-1626.

ZHANG G B, LI H, RAN Y, et al. A transfer learning model for bearing fault diagnosis[J]. Journal of Jilin University (Engineering and Technology Edition), 2020, 50(5): 1617-1626(in Chinese).

[13] LIU M K, TRAN M Q, WENG P Y. Fusion of vibration and current signatures for the fault diagnosis of induction machines[J]. Shock and Vibration, 2019, 2019(1): 7176482.

[14] JIE H J, WANDA P. RunPool: a dynamic pooling layer for convolution neural network[J]. International Journal of Computational Intelligence Systems, 2020, 13(1): 66-76.

[15] YANG Z N, WANG X Y, YANG R. Transfer learning based rolling bearing fault diagnosis[C]//Proceedings of the IEEE 10th Data Driven Control and Learning Systems Conference. Piscataway: IEEE Press, 2021: 354-359.

[16] 徐冰冰, 岑科廷, 黄俊杰, 等. 图卷积神经网络综述[J]. 计算机学报, 2020, 43(5): 755-780.

XU B B, CEN K T, HUANG J J, et al. A survey on graph convolutional neural network[J]. Chinese Journal of Computers, 2020, 43(5): 755-780(in Chinese).

[17] SHABBEER BASHA S H, DUBEY S R, PULABAIGARI V, et al. Impact of fully connected layers on performance of convolutional neural networks for image classification[J]. Neurocomputing, 2020, 378: 112-119.

[18] 史加荣, 王丹, 尚凡华, 等. 随机梯度下降算法研究进展[J]. 自动化学报, 2021, 47(9): 2103-2119.

SHI J R, WANG D, SHANG F H, et al. Research advances on stochastic gradient descent algorithms[J]. Acta Automatica Sinica, 2021, 47(9): 2103-2119(in Chinese).

[19] CAO X Y, LAI L F. Distributed gradient descent algorithm robust to an arbitrary number of Byzantine attackers[J]. IEEE Transactions on Signal Processing, 2019, 67(22): 5850-5864.

[20] ACHARYA U R, YANTI R, ZHENG J W, et al. Automated diagnosis of epilepsy using CWT, HOS and texture parameters[J]. International Journal of Neural Systems, 2013, 23(3): 1350009.

[21] SHEN J X, SONG D, MA T C, et al. Blade crack detection based on domain adaptation and autoencoder of multidimensional vibro-acoustic feature fusion[J]. Structural Health Monitoring, 2023, 22(5): 3498-3513.

[22] ZHANG W P, ZHANG P, HE X H, et al. Convolutional neural network based two-layer transfer learning for bearing fault diagnosis[J]. IEEE Access, 2022, 10: 109779-109794.

[23] LONG M S, ZHU H, WANG J M, et al. Deep transfer learning with joint adaptation networks[C]//Proceedings of the 34th International Conference on Machine Learning. New York: ACM, 2017: 2208-2217.

[24] WANG Q, MICHAU G, FINK O. Domain adaptive transfer learning for fault diagnosis[C]//Proceedings of the Prognostics and System Health Management Conference. Piscataway: IEEE Press, 2019: 279-285.

Unlabeled data fault diagnosis method based on multi-domain adaptation

WANG Jinhua^{1,*}, LIU Rui¹, CAO Jie^{1,2}

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. Gansu Manufacturing Information Engineering Research Center, Lanzhou 730050, China)

Abstract: in industrial production, due to the difference in the distribution of source domain data and target domain data and the small amount of labeled fault data, the accuracy of domain adaptation-based bearing fault diagnosis algorithms proposed in the past is generally not high. In view of this, the multi-domain adaptation neural network (MDANN) fault diagnosis method was proposed in this paper, which was used for rolling bearing fault diagnosis without labeled data. Firstly, the original vibration signal was processed by using wavelet packet transformation (WPT) to reduce signal redundancy and avoid the loss of key signal features. Secondly, the multi-kernel maximum mean discrepancy (MK-MMD) algorithm was used to calculate the difference of input eigenvalues, and the network parameters of MDANN were updated by backpropagation so that the network can extract domain invariant features. Finally, in order to ensure that unlabeled target domain data can participate in network training normally, the maximum probability label was used as a pseudo-label strategy of the real label to solve the problem that unlabeled target domain data cannot be trained and enhance the acquisition of reliable diagnosis knowledge of the model. Two publicly available datasets, CWRU and PU, were used for validation. The experimental results show that the proposed method has higher diagnosis accuracy compared with common domain adaptation methods, which further shows that the method can effectively learn the transferable features and fit the discrepancy in data distribution between the two datasets.

Keywords: rolling bearing; fault diagnosis; transfer learning; multi-domain adaptation; pseudo-label strategy

Received: 2023-04-06; **Accepted:** 2023-06-09; **Published Online:** 2023-06-29 11:39
URL: link.cnki.net/urlid/11.2625.V.20230628.1442.003
Foundation items: National Key Research and Development Program of China (2020YFB1713600); National Natural Science Foundation of China (62063020); Natural Science Foundation of Gansu Province (20JR5RA463)
*** Corresponding author.** E-mail: wjh0615@lut.edu.cn