

DOI:10.3969/j.issn.1001-4551.2022.08.002

基于模型采样和领域对抗神经网络的 轴承故障诊断方法*

高 晗¹, 毛 阆^{2,3}, 韦荣阳¹, 张建中⁴, 黄立荣⁴, 杨 健¹

(1. 浙江大学 化工机械研究所, 浙江 杭州 310027; 2. 浙江大学 平衡建筑研究中心, 浙江 杭州 310028;
3. 浙江大学 建筑设计研究院有限公司, 浙江 杭州 310028; 4. 杭州元创新型材料科技有限公司, 浙江 杭州 311500)

摘要:为了适应不同产品的不同加工要求,轴承需要工作于不同的工况下,但是工况的变化会造成数据分布差异,从而导致轴承故障诊断模型的性能下降,同时目前也缺少针对无标签情况下实现故障类别均衡采样的方法,为此,提出了一种基于模型采样(MBS)和领域对抗神经网络(DANN)的轴承故障诊断方法。首先,使用基于模型采样(MBS)的方法,将预训练模型输出的类别概率分布作为采样依据,克服了在无标签目标工况下实现类别均衡采样的困难;然后,结合领域对抗神经网络(DANN),设计了将特征从目标工况迁移到源工况的网络结构;最后,在故障模拟实验数据上,建立了高精度的变工况轴承故障诊断模型,并将采用该方法所获结果与采用多种对照方法所获结果进行了对比分析,以验证该方法在变工况轴承故障诊断上的有效性和优越性。研究表明:在模拟实验中,采用基于 MBS-DANN 的方法可达到 98.41% 的平均诊断准确率,相比随机采样法提高超过 10%;这说明无标签样本类别均衡采样具有重要意义,也可验证基于 MBS-DANN 的方法在变工况轴承故障诊断上的有效性和优越性。

关键词:定厚辊轴承;无标签采样法;类别均衡采样;特征迁移学习;模型采样;领域对抗神经网络

中图分类号:TH133.3; TP277

文献标识码:A

文章编号:1001-4551(2022)08-1024-07

Fault diagnosis method for bearings based on MBS-DANN

GAO Han¹, MAO Tian^{2,3}, WEI Rong-yang¹, ZHANG Jian-zhong⁴, HUANG Li-rong⁴, YANG Jian¹

(1. Institute of Process Equipment, Zhejiang University, Hangzhou 310027, China;

2. Center for Balance Architecture, Zhejiang University, Hangzhou 310028, China; 3. Architectural Design & Research Institute of Zhejiang University Co., Ltd., Hangzhou 310028, China; 4. Hangzhou Yuanchuang New Materials Sci-Tech Co., Ltd., Hangzhou 311500, China)

Abstract: In order to meet the changing processing requirements of products, bearings need to work in different working conditions. Aiming at the problems of the performance limitation of bearing fault diagnosis model due to data distribution difference caused by variation of working conditions, to the same time, there was currency a lack of methods to achieve balanced sampling of fault categories in the absence of labels, a bearing fault diagnosis method based on model-based sampling (MBS) and domain adversarial neural network (DANN) was proposed. Firstly, model-based sampling (MBS) was used to take the classification probability distribution of the output of the pre-training model as the sampling basis, which overcame the difficulty of realizing the classification equilibrium sampling under the target condition of unlabeled samples. Then, combining with domain adversarial neural network (DANN), a network structure was designed to transfer features from target to source conditions. Finally, a high-precision bearing fault diagnosis model under variable working conditions was realized based on the fault simulation experimental data, and the results were compared with those of several control methods, to verify the effectiveness and superiority of the method in variable condition bearing fault diagnosis. The research results show that the average diagnostic accuracy of the proposed method is 98.41% in the simulation experiment, which is more than 10% higher than that of the random sampling method; which

收稿日期:2022-03-03

基金项目:国家重点研发计划资助项目(2021YFB2601603);国家自然科学基金资助项目(52075487);浙江省科技计划资助项目(2022C01219)

作者简介:高晗(1997-),男,云南临沧人,硕士研究生,主要从事设备智能故障诊断方面的研究。E-mail:yngaohan@zju.edu.cn

通信联系人:杨健,男,博士,博士生导师。E-mail:zdhjkz@zju.edu.cn

can reveal the importance of class equalization sampling for unlabeled samples, and also verify the effectiveness and superiority of the proposed method in bearing fault diagnosis under variable conditions.

Key words: fixed thickness roller bearing; unlabeled sampling method; classification equilibrium sampling; feature transfer learning; model-based sampling(MBS); domain adversarial neural network (DANN)

0 引 言

轴承是高速旋转机械的核心工作部件,设备出现的故障有很大比例来源于轴承的磨损^[1]。

目前,高速旋转机械被应用于各行各业,例如在建筑材料制造行业中用于板材定厚加工的双辊式砂光机。

建筑节能装饰一体化板的关键加工装备—双辊式砂光机通过定厚辊的高速旋转,带动砂带加工出厚度均匀的板材。定厚辊的深沟球轴承在高速旋转下容易磨损,使定厚辊振幅逐渐加剧,造成砂带与工作台的相对距离不断变化,导致板材加工不均匀,严重影响板材质量。因此,在轴承损伤出现的早期对其进行故障诊断具有重要意义。

虽然故障发生时可能会伴随较为明显的异常数据,但在故障早期,无法直接通过观察数据变化来判断设备健康状态,需要对数据进行处理分析,然后才能得出结果。

2006年“深度学习”的概念被提出后^[2],得益于硬件计算能力的提升,针对深度学习的研究得到了高速发展;因其对数据的分析处理能力,深度学习逐渐在轴承故障诊断领域取得了许多成果^[3]。

袁建虎等人^[4]将振动信号变换后得到的时频灰度图作为二维卷积神经网络的输入,利用卷积神经网络的图像处理能力,识别出了对应的轴承健康状态,从而实现了故障诊断的目的。QIAN Wei-wei等人^[5]提出了一种自适应堆叠卷积神经网络,建立了小样本训练集下的轴承故障分类模型。PAN Hong-hu等人^[6]将一维卷积神经网络和长短期记忆网络(long short-term memory, LSTM)结合在一起,提出了一种新的轴承故障诊断方法,通过卷积神经网络进行了特征处理,再由 LSTM 作为分类器,输出故障类型。

以上方法取得了一定效果,但为满足客户的需求,设备需切换多种工作模式,双辊式砂光机为了加工不同表面要求的板材,需要更换不同粗糙度的砂带。加工时,不同砂带对轴作用的扭矩发生了变化,轴的负载功率也随之变化,而轴承在不同工况中运行时的振动信号存在数据分布差异,模型的变工况诊断准确率并不理想。

迁移学习^[7]是深度学习中提升模型泛化性的重

要研究分支,其原理是将源领域或任务(即源工况)上学到的知识或模型,通过某种迁移方法应用到不同但相关的领域或问题中,以提升目标领域或任务(即目标工况)的模型性能。

迁移方法通常分为样本、模型、特征、关系迁移等方法^[8],这些方法都需要使用目标工况的样本。其中,特征迁移学习仅需要无故障标签的样本,数据获取成本更低,也更容易应用实现。

特征迁移法适用于源工况和目标工况任务一致而振动信号数据分布不一致的情况;其研究内容是:将目标工况与源工况的数据映射到一个共同的特征空间中,使两个工况的数据在新的特征空间中近似为同一分布,以消除工况间的差异,之后利用有故障标签的源工况样本训练出模型,并对无标签的目标工况样本进行更准确地诊断分类。

寻找相似分布特征空间,本质上是减少两个分布之间的差异,例如:将两个分布的多核最大平均差异(multikerner-maximum mean discrepancy, MK-MMD)^[9]引入模型损失函数中进行训练;使用领域对抗神经网络(domain-adversarial neural network, DANN),并借鉴了生成对抗网络(generative adversarial networks, GAN)^[10]的生成器和判别器的对抗训练博弈策略,把生成器替换为特征提取器,在博弈中逐渐消除两个分布之间的差异。

在深度学习模型训练过程中,故障类别不均衡的训练样本会严重影响模型的表现效果,难以学习到少数类的特征表示^[11]。为了确保迁移模型的训练效果,选择的训练样本数量应该遵循故障类别同等比例的原则。因此,针对源工况和目标工况的采样方法至关重要。因为工程应用中无法直接判断目标工况下无故障标签样本的故障类别,所以对迁移学习方法在工程中的应用提出了新的挑战。许多研究轴承故障诊断的迁移学习方法的论文^[9,12,13]在进行实验验证时,直接采用了故障类别等比例数量的目标工况样本,但并未对采样方法做出说明。

针对以上变工况轴承故障诊断的特征迁移学习方法在工程应用中的不足,笔者提出一种能在无标签样本条件下实现均衡采样的方法,并结合 DANN 框架设计神经网络结构以建立诊断模型,最后在故障模拟实

验数据的基础上设置对照方法,对比验证所提出方法的有效性和优越性。

1 基于 MBS 的无标签采样法

笔者提出的基于模型采样(MBS)的采样方法流程如图 1 所示。

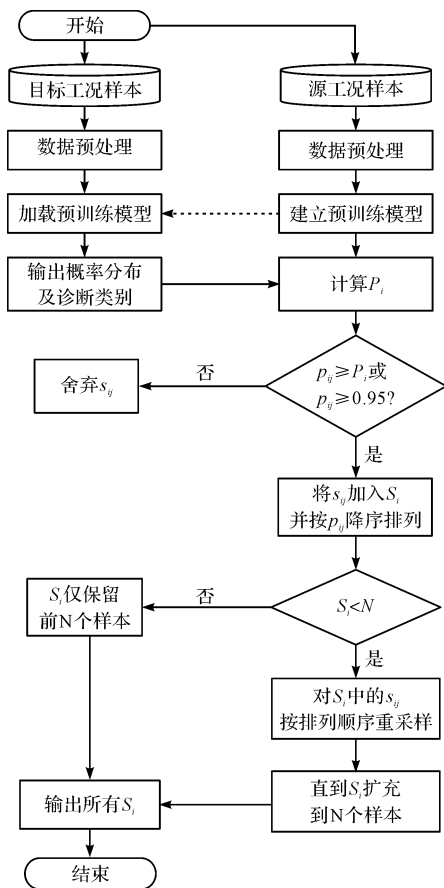


图 1 MBS 采样法流程

S_{ij} —被诊断为 i 类别的样本 j ; P_{ij} —样本 S_{ij} 的 i 类别概率; P_i —被诊断为 i 类别的所有样本的 i 类别概率的平均值; S_i — i 类别的输出采样样本集合; N —每一类故障按等比例原则需要采样的样本理想数量

MBS 方法用于在特征迁移前对目标工况的无故障标签样本进行采样,以采集与故障类别等比例数量的样本。

在采样前,需要先建立预训练模型,预训练模型不考虑目标工况样本,仅使用带故障标签的源工况样本进行训练,但目标工况的采样效果依赖于模型在目标工况的泛化性能,因此,对预训练模型的网络结构设计十分重要,输出层必须为 SoftMax 层,以满足输出为各类别故障概率分布的要求,概率最高的类别即为模型诊断类别。

当通过类别数量和训练样本总数量确认了每一类别故障的样本理想数量后,MBS 采样法可从大量无故障标签的目标工况样本中进行采样,具体可概括为 3 个环节:

(1) 将所有样本输入到预训练模型中,记录每个样本由 SoftMax 层输出的概率分布,并为其打上最高概率对应的类别标签;

(2) 根据每个类别在对应标签样本中的平均概率过滤低概率样本,以排除可能混淆在该类别的其他类别样本;设置的 0.95 阈值是为了在过滤过程中,防止某些在预训练模型中表现很好的类别故障样本被过滤,保留每个类别样本的多样性;

(3) 重采样环节是为了在某些类别样本采样数量达不到理想数量时仍实现数据类别均衡,保障最终诊断模型的表现效果。

2 基于 DANN 的特征迁移学习

笔者设计的 DANN 由 3 个网络构成,分别是特征提取网络 F、工况判别网络 D、故障判别网络 C。

特征提取网络 F 可将源工况和目标工况映射到相似分布的特征空间,工况判别网络 D 可判别经特征映射后的样本来自哪一个工况,故障判别网络 C 可判别经特征映射后的样本来自哪一类别故障。

DANN 网络的框架及训练过程如图 2 所示。

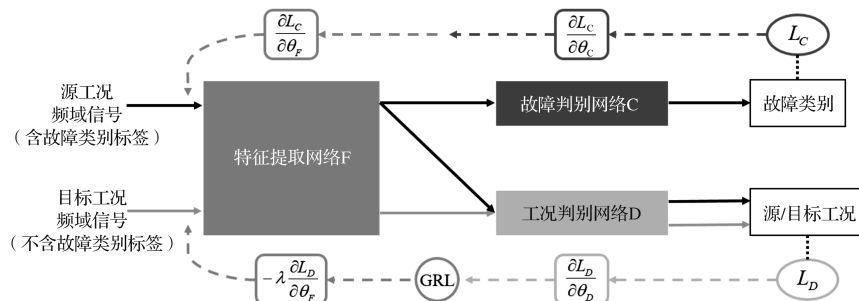


图 2 DANN 结构及训练过程示意图

从图 2 中可以看到:3 个网络同时进行训练,使 F 和 D 同时不断增强,直到 D 的精度稳定在 50% 左右,即认为 F 映射的特征空间不再含有不同工况间的差

异,目标工况和源工况在特征空间中属于同一分布;此外,F 在训练过程中也需要考虑到诊断效果。

DANN 在训练过程中分为两个完整的网络:F 与

C 构成源工况的故障诊断网络,输入带标签的源工况样本,反向传播时对 F 和 C 都进行参数调整;F 与 D 构成了源工况和目标工况的工况判别对抗网络,输入无标签的目标工况和源工况样本,反向传播调整 D 的参数以提高工况的判别准确率,值得一提的是,在调整 F 的参数时需要引入梯度翻转层(gradient reversal layer,GRL)^[14],反向强化 F 的特征提取能力,以骗过 D 的工况判别能力,从而实现对抗训练。

C、D、F 这 3 个神经网络的参数更新过程分别如下:

$$\theta_C \leftarrow \theta_C - \mu \frac{\partial L_C}{\partial \theta_C} \quad (1)$$

$$\theta_D \leftarrow \theta_D - \mu \frac{\partial L_D}{\partial \theta_D} \quad (2)$$

$$\theta_F \leftarrow \theta_F - \mu \left(\frac{\partial L_C}{\partial \theta_F} - \lambda \frac{\partial L_D}{\partial \theta_F} \right) \quad (3)$$

式(1~3)中: $\theta_C, \theta_D, \theta_F$ —C, D, F 的网络参数; L_C, L_D —C, D 的损失函数; μ —学习率; λ —梯度翻转因子。

3 实验及结果分析

3.1 实验数据集介绍

由于定厚辊轴承上并未布置振动信号采集及通信等设备,短期内难以获得故障类别丰富的振动数据。同时,因少量类别故障诊断的任务过于简单,而无法体现出 MBS-DANN 方法的优越性(相较于其他深度学习方法)。

轴承作为旋转机械的通用部件,在实验条件下,改变轴承所受负载,以此来模拟双辊式砂光机的不同工况,仍能达到对笔者所提出的方法进行验证的目的。

笔者选用故障类别丰富,且轴承类型同为深沟球轴承的美国凯斯西储大学轴承数据中心的电机驱动端测试轴承^[15],以此来研究所提出的基于 MBS-DANN 的轴承故障诊断方法。

笔者以负载 1 hp(马力)工况作为源工况,以负载 0 hp、2 hp、3 hp 作为目标工况,并分别用各工况(包含正常状态在内)的 14 个不同故障类型、程度及位置的故障振动信号数据作为诊断模型的实验样本,来验证该方法的有效性和优越性。

笔者对各类别故障的定义及标签如表 1 所示。

在轴承故障模拟实验中,笔者通过对轴承进行电火花加工,人为制造深度 0.279 4 mm 但直径不同(例:0.177 8 mm、0.355 6 mm、0.533 4 mm)的滚珠、内圈、外圈损伤。作为不同故障类别,对于在运行中相对于

表 1 轴承故障类别的定义及标签

序号	故障代码	故障类型	故障程度/mm	故障位置	标签
1	NO	正常	—	—	0
2	007BF	滚珠	0.177 8	—	1
3	007IF	内圈	0.177 8	—	2
4	007OF@3	外圈	0.177 8	3 点	3
5	007OF@6	外圈	0.177 8	6 点	4
6	007OF@12	外圈	0.177 8	12 点	5
7	014BF	滚珠	0.355 6	—	6
8	014IF	内圈	0.355 6	—	7
9	014OF@6	外圈	0.355 6	6 点	8
10	021BF	滚珠	0.533 4	—	9
11	021IF	内圈	0.533 4	—	10
12	021OF@3	外圈	0.533 4	3 点	11
13	021OF@6	外圈	0.533 4	6 点	12
14	021OF@12	外圈	0.533 4	12 点	13

基座属于静止的外圈,其故障中还包含 3 点钟、6 点钟、12 点钟方向的位置信息。

笔者将每个工况下每个故障类别的样本切割为长度 1 024 个数据点、混叠 512 个点的 200 个样本,即每个工况下含有 2 800 个样本。

为了消除不同样本初始相位的不同,以及信号混叠的影响,笔者使用快速傅里叶变换,将原始的时域振动信号转换为频域振动信号的 512 个数据点,作为模型输入。

3.2 实验步骤

该研究设计的验证实验步骤流程如图 3 所示。

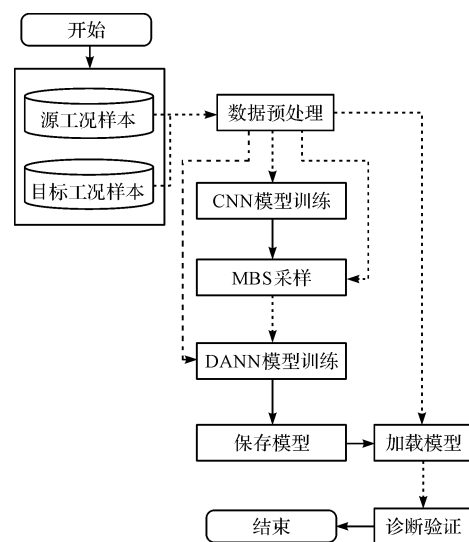


图 3 实验步骤

图 3 中,实线表示步骤流转,两种不同的虚线分别表示源工况和目标工况样本的数据流。MBS 的预训练模型选择卷积神经网络(convolutional neural net-

works, CNN)。

首先,笔者使用带故障标签的源工况样本训练 CNN 模型;之后,通过 MBS 对无故障标签的目标工况样本进行采样,并将采样样本与源工况样本用于训练 DANN 模型;最后,使用模型对目标工况样本进行诊断,以验证方法的有效性和优越性。

CNN 的网络结构及超参数配置如表 2 所示。

表 2 CNN 网络结构及超参数配置

序号	网络层	输出维度	核尺寸	步长	卷积核/神经元个数	激活函数
1	输入层	(None,512,1)	—	—	512	—
2	卷积层 1	(None,512,4)	5	1	4	ReLU
3	平均池化层 1	(None,256,4)	2	2	—	—
4	卷积层 2	(None,256,4)	5	1	4	ReLU
5	平均池化层 2	(None,128,4)	2	2	—	—
6	拉直层	(None,512)	—	—	—	—
7	全连接层 1	(None,20)	—	—	20	tanh
8	全连接层 2	(None,14)	—	—	14	Softmax

表 3 DANN 网络结构及超参数配置

	序号	网络层	输出维度	核尺寸	步长	卷积核/神经元个数	激活函数
特征提取 网络 F	1	输入层	(None,512,1)	—	—	512	—
	2	卷积层 1	(None,512,4)	5	1	4	ReLU
	3	平均池化层 1	(None,256,4)	2	2	—	—
	4	卷积层 2	(None,256,4)	5	1	4	ReLU
	5	平均池化层 2	(None,128,4)	2	2	—	—
	6	拉直层	(None,512)	—	—	—	—
	7	全连接层 1	(None,20)	—	—	20	tanh
故障判别 网络 C	8	全连接层 2	(None,14)	—	—	14	Softmax
工况判别 网络 D	9	全连接层 3	(None,50)	—	—	50	ReLU
	10	全连接层 4	(None,2)	—	—	2	Softmax

3.3 实验结果分析

CNN 模型表现出了较为不错的泛化能力,平均准确率达到 96.9%,这为后续的 MBS 采样奠定了良好的基础。其中,在 2 hp 工况下泛化性最佳,准确率达到 99.5%;在 0 hp 工况下的准确率为 94.39%,主要存在将不同程度的滚珠故障混淆的问题;在 3 hp 工况下的准确率为 96.82%,主要存在将不同程度的内圈故障混淆的问题,说明 CNN 模型在不同程度故障识别上的泛化性仍存在不足。

由于 0 hp 和 3 hp 工况还存在一定的上升空间,因此,笔者选择 0 hp 和 3 hp 工况的样本数据,验证 MBS-DANN 模型的有效性和优越性。

此处以 0 hp 工况为例说明 MBS 的采样结果。MBS 方法在重采样前采集到的各诊断类别样本数量,如图 4 所示。

图 4 中,出现类别不均衡情况的原因是:0 hp 工况下使用的样本为每个类别同等数量 200 个样本,共 2 800 个样本,正好满足故障类别等比例的样本数量要

DANN 的网络结构及超参数配置如表 3 所示。

在 CNN 模型中,笔者用交叉熵作为损失函数,用 Adam 作为优化器,以 64 个样本为一个 batch,进行模型的批训练,共训练迭代 100 次;

笔者在 DANN 模型中,用交叉熵作为 C 和 D 的损失函数,用 SGDM 作为优化器,以 128 个样本为一个 batch,进行模型的批训练,共训练迭代 500 次。




图 4 0 hp-MBS 重采样前的各诊断类别样本数量

求(在工程应用中几乎不可能出现同等数量的样本情况,此处是为了便于对比),最为理想的情况下无需重采样,MBS 即可采样得到每个类别 200 个样本,也就说明 CNN 模型对 0 hp 工况下的故障诊断准确率已经达到了 100%,无需再进行迁移学习。

但如前文所述,CNN 模型在 0 hp 的表现效果还有进一步优化空间,因此该现象是正常的。

继续完成重采样, MBS 方法最终采样到的样本的实际类别样本数量, 如图 5 所示。




图 5 0 hp-MBS 采样样本的实际类别样本数量

MBS 方法最后的重采样是为了弥补基于模型采样的不足。经过重采样后, 每个类别理论上(即 CNN 模型诊断的类别)都达到了 200 个样本。

从图 5 中可看出: 仅在 9 号故障中有 4 个 6 号故障样本混入, 采样的准确率达到 99.86%, 保障了类别均衡。其在一定程度上验证了 MBS 采样法的有效性。

同样, 笔者以 0 hp 工况为例说明 DANN 的训练过程。工况判别准确率变化曲线如图 6 所示。




图 6 0 hp-工况判别准确率变化曲线

从图 6 可以看到: 工况的判别准确率经过 500 次迭代后, 逐渐稳定在 50% 振荡, D 已经无法分辨出经 F 映射后的特征来自于哪一工况, 从而实现了从目标工况到源工况的特征迁移。

0 hp 工况在 DANN 模型上表现的故障诊断混淆矩阵, 如图 7 所示。

由图 7 可知: 不同程度故障混淆的情况得到了较大改善, 整体准确率提升到 98.43%。此外, 3 hp 工况下的整体准确率也提升到 98.39%, 验证了 MBS-DANN 方法的有效性。

3.4 对比实验及分析

为了验证 MBS-DANN 模型在变工况轴承故障早

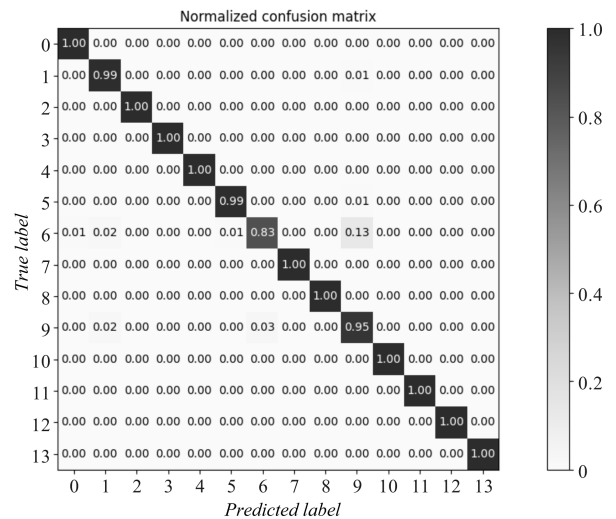


图 7 0 hp-DANN 模型故障诊断混淆矩阵

期诊断问题中的有效性和优越性, 笔者设了 4 个对照方法: (1) 未迁移的模型(即 CNN 模型); (2) 同样使用无标签目标工况样本进行深度学习的卷积自编码器(convolution auto-encoder, CAE)^[16]与 MBS 采样法结合; (3) 基于理想采样法的 DANN 模型; (4) 基于随机采样法的 DANN 模型^[17]。

其中, 理想采样是指采样的最理想情况, 即每个类别同等数量采样 200 个样本; 随机采样是指不对目标工况下的无标签样本进行任何先验判断, 而直接采样。

随机采样的各类别样本数量如图 8 所示。




图 8 随机采样的各类别样本数量

笔者采用的随机采样模拟方法是先随机生成各故障类别的采样比例, 之后根据样本总数量(共计 2 800 个), 从对应类别样本中随机采样相应数量的样本。由于在该实验中, 每个类别样本只有 200 个, 因此, 超过 200 个的类别采用随机重采样的方式补齐样本数量。

不同对照方法与 MBS-DANN 的模型跨工况轴承故障早期诊断准确率对比结果, 如表 4 所示。

表 4 不同对照方法与 MBS-DANN 的诊断准确率对比

	1 hp→0 hp	1 hp→3 hp	AVG
MBS-DANN	98.43%	98.39%	98.41%
MBS-CAE	96.18%	94.43%	95.31%
随机采样-DANN	96.39%	79.57%	87.98%
理想采样-DANN	99.61%	98.86%	99.24%
CNN	94.39%	96.82%	95.61%

由表 4 可知:

相较于 MBS-CAE 模型,实验结果验证了 DANN 模型的优越性;相较于随机采样和理想采样的 DANN 模型,理想采样法表现效果最佳,说明了采样对特征迁移法的重要性,随机采样法与 MBS 采用法的准确率差距也验证了 MBS 采样法的有效性;相较于未迁移的 CNN 模型,平均准确率提升了 2.8%,验证了 MBS-DANN 模型的有效性和优越性。

4 结束语

针对传统深度学习方法在变工况下的轴承故障诊断准确率较低,以及特征迁移学习方法在工程应用中无标签样本采样方法缺失的问题,笔者提出了一种基于 MBS-DANN 的轴承故障诊断方法,即采用基于预训练 CNN 模型的 MBS 方法,保障了采样样本数量的类别均衡,将 DANN 作为神经网络框架,并在轴承故障模拟实验数据上,进行了多种方法的实验对比分析。

研究结果表明:

(1)在理想采样法和随机采样法下,实验数据分别达到 99.4%、87.98% 的平均准确率,证明了建模前无标签样本类别均衡采样方法的重要性;

(2)MBS 方法克服了在无标签目标工况下,实现类别均衡采样的困难;相比随机采样法,MBS 方法平均准确率提高了超过 10%,而仅比理想采样法低不到 1%,充分验证了 MBS 方法的有效性;

(3)MBS 方法与 DANN 网络结合,达到了 98.41% 的诊断平均准确率,在对比实验中,仅次于理论采样-DANN,充分验证了 MBS-DANN 方法的优越性。

由于时间和条件有限,仍有工作可在后续的研究中进行开展:笔者仅在模拟实验条件下进行了该方法的验证,后续可针对实际应用场景对该方法进行验证和进一步优化;除了工况会影响振动信号数据分布,轴承的润滑、温升等情况也会导致数据分布差异,后续笔

者拟将该方法在更多场景中进行验证及应用。

参考文献 (References):

- [1] RAI A, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings [J]. *Tribology International*, 2016, 96 (1): 289-306.
- [2] 朱兴统. 旋转机械智能故障诊断方法的研究[D]. 广州: 广东工业大学自动化学院, 2020.
- [3] HINTON G E, OSINDERO S, TEH Y W. A Fast learning Algorithm for deep belief nets [J]. *Neural Computation*, 2014, 18(7): 1527-1554.
- [4] 袁建虎, 韩涛, 唐建, 等. 基于小波时频图和 CNN 的滚动轴承智能故障诊断方法 [J]. *机械设计与研究*, 2017, 33(2): 93-97.
- [5] QIAN Wei-wei, LI Shun-ming, WANG Jin-rui, et al. An intelligent fault diagnosis framework for raw vibration signals: adaptive overlapping convolutional neural network [J]. *Measurement and Technology*, 2018, 29(9): 095009.
- [6] PAN Hong-hu, HE Xing-xi, TANG Sai, et al. An improved bearing fault diagnosis method using one-dimensional CNN and LSTM [J]. *Journal of Mechanical Engineering*, 2018, 64(7-8): 443-453.
- [7] PAN S J, YANG Qiang. A Survey on transfer learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [8] WEISS K, KHOSHGOFTAAR T M, WANG D D. A survey of transfer learning [J]. *Journal of Big Data*, 2016, 3(1): 1-40.
- [9] 黄凯. 基于无监督深度迁移学习的轴承故障诊断 [J]. *电子技术与软件工程*, 2021(16): 218-220.
- [10] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: an overview [J]. *IEEE Signal Processing Magazine*, 2018, 35(1): 53-65.
- [11] 曹思钰. 基于卷积神经网络的数据不平衡故障诊断方法研究 [D]. 武汉: 华中科技大学机械科学与工程学院, 2020.
- [12] 刘嘉濛, 郑凡帆, 梁丽冰, 等. 基于领域对抗网络的轴承故障诊断方法研究 [J]. *机电工程*, 2020, 37(3): 227-233.
- [13] 杨健, 李立新, 廖晨茜, 等. 面向滚动轴承故障诊断的改进对抗迁移学习算法研究 [J]. *中国测试*, 2021, 47(9): 15-19, 40.
- [14] GANIN Y, LEMPITSKY V. Unsupervised Domain Adaptation by Backpropagation [C]. *International Conference on Machine Learning*. PMLR, 2015.
- [15] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study [J]. *Mechanical Systems and Signal Processing*, 2015, 64(1): 100-131.
- [16] 周文宣, 刘洋, 邓敏强, 等. 基于 CAE 和 CNN 的变工况下滚动轴承智能故障诊断研究 [J]. *动力工程学报*, 2022, 42(1): 43-48.
- [17] 郑煜, 王凯, 杨利红. 滚动轴承早期故障优化自适应随机共振诊断法 [J]. *轻工机械*, 2020, 38(2): 74-76, 83.

[编辑: 雷敏]

本文引用格式:

高晗, 毛阔, 韦荣阳, 等. 基于模型采样和领域对抗神经网络的轴承故障诊断方法 [J]. *机电工程*, 2022, 39(8): 1024-1030.

GAO Han, Mao Tian, WEI Rong-yang, et al. Fault diagnosis method for bearings based on MBS-DANN [J]. *Journal of Mechanical & Electrical Engineering*, 2022, 39(8): 1024-1030.

《机电工程》杂志: <http://www.meem.com.cn>