

基于迁移学习的轴承故障诊断

傅锦涛^{1,1,2}, 张弓^{1,2}, 张树忠^{1,2}

(1. 福建理工大学 机械与汽车工程学院, 福建 福州 350118;

2. 广州先进技术研究所 前瞻科学与技术研究中心, 广东 广州 511458)

摘要: 提出一种基于多核最大均值差异的一维卷积迁移学习方法。利用一维卷积网络直接从原始振动信号中提取故障特征信息; 应用对抗策略迁移技术辅助网络提取两个域之间的共同特征; 以多核最大均值差异作为评价源域和目标域的距离指标, 实现域不变特征提取并在凯斯西储大学轴承数据集的4种工况下进行迁移学习。研究表明, 相比于传统方法, 该文所提方法在故障分类精度上提高了6%, 具有良好的应用前景。

关键词: 轴承故障; 迁移学习; 多核最大均值差异; 故障诊断

中图分类号: TH18; TH133.33 **文献标志码:** A

文章编号: 2097-3853(2024)04-0393-08

Bearing fault diagnosis of cross-working grinding mill based on transfer learning

FU Jintao¹, ZHANG Gong^{1,2}, ZHANG Shuzhong^{1,2}

(1. School of Mechanical and Automotive Engineering, Fujian University of Technology, Fuzhou 350118, China;

2. Frontier Science and Technology Research Center, Guangzhou Institute of Advanced Technology, Guangzhou 511458, China)

Abstract: A one-dimensional convolution transfer learning method based on multi-core maximum mean difference is proposed. Firstly, one-dimensional convolutional networks are utilized to directly extract fault feature information from the original vibration signals. Secondly, an adversarial strategy migration technique is employed to assist the network in extracting common features between the two domains. Finally, the multi-core maximum mean difference is used to evaluate the distance between the source domain and target domain, enabling extraction of domain invariant features and facilitating transfer learning under four working conditions of the bearing dataset from Case Western Reserve University. Compared with traditional methods, the proposed approach can enhance fault classification accuracy by 6%, which has a good application prospect.

Keywords: bearing fault; transfer learning; multi-core maximum mean difference; fault diagnosis

据统计, 旋转机械设备故障的30%由轴承故障引起, 其中90%的滚动轴承故障与内圈或外圈缺陷有关^[1]。若滚动轴衰退化, 可能导致产品无法达到标准, 增加成本并停机。因此, 必须早期有效诊断轴承故障, 以降低损失、优化维护计划并确保设备安全可靠运行^[2]。

近年来, 深度学习在故障诊断域取得了显著进展。Zhang等^[3]系统介绍了深度学习在轴承故

障诊断中的方法, 并与传统的机器学习方法进行对比。Huang等^[4]利用CNN-LSTM模型通过LSTM层捕捉时间延迟信息, 提升故障诊断预测精度。Zhu等^[5]利用多个高斯核计算域损失, 该方法有效地增强了模型的鲁棒性, 使其能够完成跨工况诊断。

综上, 实际工况的不同, 数据特征也不一样, 因此建立不同工况下的复杂故障诊断模型非常必要。

收稿日期: 2024-01-16

基金项目: 福建省智能加工技术及装备重点实验室开放基金(KF-01-22005); 福建省2022年中央引导地方科技发展资金项目(2022L3014)

第一作者简介: 傅锦涛(1998—), 男, 浙江绍兴人, 硕士研究生, 研究方向: 故障诊断。

通信作者: 张树忠(1980—), 男, 福建周宁人, 教授, 博士, 研究方向: 机电液产品的系统研发、故障诊断、智能控制技术等。

本文提出一种基于一维卷积神经网络(1D convolutional neural network, 1D-CNN)的迁移学习方法,用于解决跨工况下的轴承故障诊断问题。

1 方案设计

采用一种基于特定工况获得的带标签数据进行训练的故障诊断方法。该方法可以用于识别其他工况下未标记的轴承健康状况,实现不同工况下诊断故障的能力。

1.1 一维卷积迁移神经网络模型的搭建

如图 1 所示,提出了基于多核最大均值差异的一维卷积迁移神经网络(1D convolutional neural

network-multiple kernel maximum mean discrepancy-convolutional transfer neural network, 1D-MKMMDC-TNN)模型,用于优化源域和目标域之间的距离。模型包括轴承状态识别和域自适应两个模块。轴承状态识别模块采用 1D-CNN,包括特征提取器和健康状况分类器。特征提取器学习轴承的故障特征,健康状况分类器准确识别轴承的健康状况。自适应域模块由两部分组成:域鉴别器和分布差异度量模块。该模块连接到特征提取器,有助于 1D-CNN 学习域不变特征。这样,在不同的数据域中,模型能有效诊断故障。

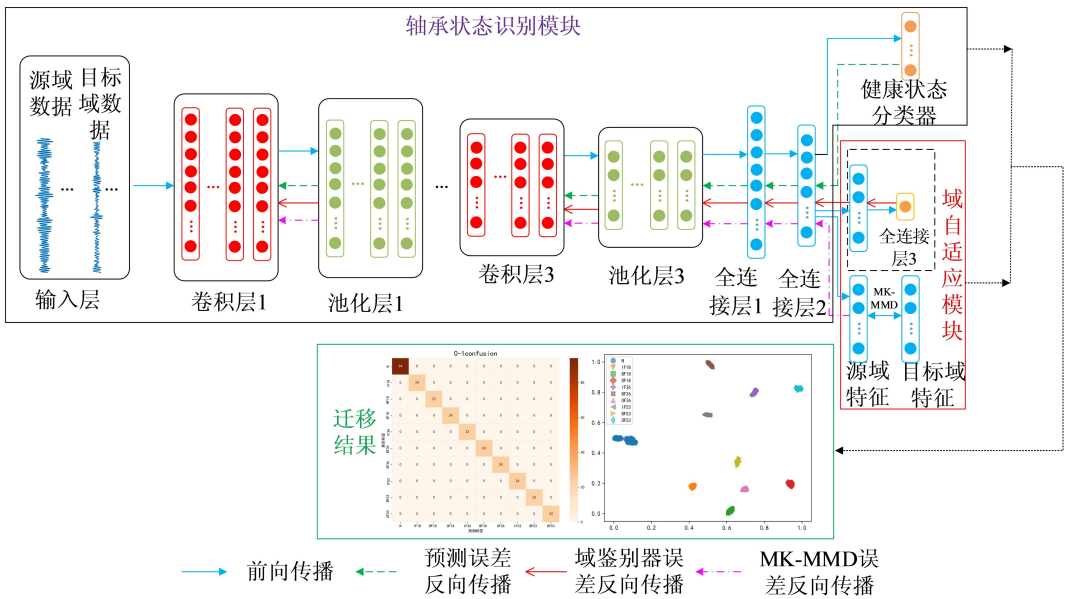


图 1 一维卷积迁移学习模型

Fig.1 One-dimensional convolutional transfer learning model

1.1.1 轴承状态识别

轴承状态识别模块由 10 层 1D-CNN 实现,包括 1 个输入层、3 个卷积层、3 个池化层、2 个全连接层和 1 个输出层。输入层接收长度为 L 的输入振动信号,随后将其传递至卷积层。在卷积层中,卷积核与输入数据进行卷积操作,以便学习有关特征信息。具体如式(1)所示^[6]。

$$c_i = \text{ReLU} \left(\sum_{m=1}^n w_c * s_{i-j+1,i}^m + b_c \right) \quad (1)$$

式中, $*$ 为一维卷积算子; w_c 为卷积核; b_c 为卷积核相应的偏置; n 为卷积核个数; c_i 为卷积层的第 i 个输出点; $\text{ReLU}(\cdot)$ 为一个激活函数; s 为输入数据。

每个卷积层连接到一个池化层,池化层对卷

积特征降维采样操作,以减少卷积特征的维数并增加平移不变性。本文采用最大池化函数,返回子区域内的最大值为:

$$\text{pooling}_{\max}(x) = \max_{i \in R(x)} (x_i) \quad (2)$$

式中, $R(x)$ 为 x 对应的子区域; x_i 为第 i 个元素的子区域。

输入的振动信号经过 3 次卷积和池化运算后,得到 3 个池化层的特征表示。将这些池化层的特征送入第一个全连接层进行压平处理。全连接层 2 的输出通过 ReLU 激活函数计算得到。

$$f_2 = \text{ReLU}(m_s \mathbf{w} + \mathbf{b}) \quad (3)$$

式中, m_s 为上一个全连接层的值; \mathbf{w} 为权重矩阵; \mathbf{b} 为偏置向量。

基于全连接层2的输出 f_2 ,在健康识别模块的输出层中使用softmax回归来估计机器的健康状况。

$$y = \frac{1}{\sum_{i=1}^K \exp((\mathbf{w}_i)^T f_2 + \mathbf{b})} \begin{bmatrix} \exp((\mathbf{w}_1)^T f_2 + \mathbf{b}) \\ \exp((\mathbf{w}_2)^T f_2 + \mathbf{b}) \\ \exp((\mathbf{w}_k)^T f_2 + \mathbf{b}) \end{bmatrix} \quad (4)$$

式中, \mathbf{w}_i 为连接到第 i 个输出神经元的权重矩阵; K 为健康状况类别。

1.1.2 域自适应

域自适应模块分为域分类器和域分布差异度量两部分。域分类器由全连接层3和域判别器输出层组成,其中全连接层的计算如式(3),在域分布差异度量中,源域特征和目标域特征符合不同概率分布,分别为 $P(f_2^{(Y)})$ 和 $P(f_2^{(M)})$ 。源域特征和目标域特征之间的距离由最大均值差异(maximum mean discrepancy, MMD)计算。

$$\text{MMD}(f_2^{(Y)}, f_2^{(M)}) = \left\| \frac{1}{N_S \sum_{i=1}^{N_S} \psi(f_{2i}^{(Y)})} - \frac{1}{N_T \sum_{j=1}^{N_T} \psi(f_{2j}^{(M)})} \right\|_H^2 \quad (5)$$

式中, $\|\cdot\|_H^2$ 为再生核希尔伯特空间; N_S 和 N_T 分别为源域和目标域的样本数; $\psi(f_{2i}^{(Y)})$ 和 $\psi(f_{2j}^{(M)})$ 分别为源域和目标域的特征映射函数。为简化计算, $\psi(\cdot)$ 使用核技巧,具体如式(6)。

$$\kappa(f_{2i}^{(Y)}, f_{2j}^{(M)}) = [\psi(f_{2i}^{(Y)}), \psi(f_{2j}^{(M)})] \quad (6)$$

式中, $[a, b]$ 为内积算子; $\kappa(a, b)$ 为与 $\psi(\cdot)$ 相关联的特征核。根据文献[7],不同的核函数选择会影响MMD测试的效果。因此,采用多核最大均值差异(multiple kernel maximum mean discrepancy, MKMMD)方法,结合多种不同的核函数,以提高其有效性。

1.2 优化目标

1.2.1 减少源域数据集上健康分类错误

为确保在故障诊断任务中有高精度表现,1D-MKMMD-CTNN模型专注于准确识别轴承的健康状态,并致力于学习那些跨不同域依然保持一致性的关键特征。这一目标通过模型内部的一维卷积迁移学习网络实现,该网络包含了专门设计用于识别轴承健康状态的模块。因此,1D-MKMMD-CTNN的核心优化目标旨在最小化源域数据中的健康分类误差,以此提升模型在处理目标域数据时的准确度和可靠性。这种优化策略尤其适用于

处理包含多个轴承状态类别的复杂数据集,使模型能够有效应对各种不同的故障情况。

通过这种方法,1D-MKMMD-CTNN不仅能够源域中实现高效准确的故障检测,还能通过迁移学习机制,抓取未见过的目标域轴承状态特征。这样的策略确保了模型在面对新的挑战时,能够无缝适应,维持其故障诊断的准确性,展现出卓越的跨域泛化能力。此外,通过不断优化和调整模型的目标函数,1D-MKMMD-CTNN能够在不同的应用场景中保持高性能。对于包含 k 个轴承状态类别的数据集,其目标函数 L_c 可定义为:

$$L_c = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^n I[\gamma_i = k] \log \frac{\exp((\mathbf{w}_j)^T f_2 + \mathbf{b})}{\sum_{i=1}^k \exp((\mathbf{w}_i)^T f_2 + \mathbf{b})} \right] \quad (7)$$

式中, m 为训练样本的批量大小; γ_i 为故障类别; $I[\cdot]$ 为指标函数。

1.2.2 最大化两域数据集上的域分类误差

图1展示了域分类器与特征提取器的连接。根据域自适应理论[8]的核心原则,如果一个经过精心设计的域分类器难以区分来自源域和目标域的特征,那么可以认为这些特征具有跨域的普适性,即它们是域不变的。这种观点为1D-MKMMD-CTNN模型提供了第二个重要的优化方向:在源域和目标域数据上最大化域分类误差,从而强化模型的域自适应能力。

具体来说,域分类损失的定义为模型优化过程中的关键指标,它指导模型学习到能够在不同域间通用的特征。通过这种方式,1D-MKMMD-CTNN不仅能够识别并适应在源域数据上显现的特征,还能够灵活调整,以适应目标域中可能存在的任何分布变化,确保模型在新环境中仍能保持高效的诊断性能。域分类损失 L_d 定义为[9]:

$$L_d = \frac{1}{m} \sum_{i=1}^m (g_i \log d(x_i) + (1 - g_i) \log(1 - d(x_i))) \quad (8)$$

式中, g_i 为源域标签; $d(x_i)$ 为第 i 个样本的输出域。在训练阶段,训练数据集由 m_s 个源域数据样本和 m_t 个目标域数据样本构成。因此,式(8)可改写为:

$$L_d = \frac{1}{m_s} \sum_{i=1}^{m_s} L_d(f_{2i}^{(Y)}) + \frac{1}{m_t} \sum_{j=1}^{m_t} L_d(f_{2j}^{(M)}) \quad (9)$$

式中, $f_{2i}^{(Y)}$ 和 $f_{2j}^{(M)}$ 分别为源域数据和目标域数据中

学习到的高级特征。

1.2.3 最小化两域数据集之间的 MKMMD 距离

在 1D-MKMMD-CTNN 中,全连接层的输出连接到健康状况分类器的高级特征。这意味着高阶特征直接影响了传输故障诊断的有效性^[10]。为确保模型能在源域和目标域之间有效迁移,必须仔细处理和减少由不同对抗网络学习到的特征间的分布差异。

为精确计算不同域之间高阶学习特征的分布差异,采用 MKMMD 核函数。MKMMD 是一种强大的统计工具,能够有效量化并最小化源域和目标域数据特征分布之间的差异。通过优化这一度量,1D-MKMMD-CTNN 能够学习到更具代表性的、跨域通用的特征,进而提升其在未知目标域上的故障诊断性能。本节使用了多核最大均值差异核函数 \hat{D} ,其实际计算过程为:

$$\hat{D} = \frac{1}{n_1^2} \sum_{i=1}^{n_m} \sum_{j=1}^{n_m} k(f_{2i}^{(Y)}, f_{2j}^{(Y)}) + \frac{1}{n_1^2} \sum_{i=1}^{n_m} \sum_{j=1}^{n_m} k(f_{2i}^{(M)}, f_{2j}^{(M)}) \quad (10)$$

式中, n_m 为源域样本数量; n_1 为目标域样本数量。

结合前 3 个优化目标,将优化对象改写为:

$$L = L_c - \lambda L_d + \mu \hat{D} \quad (11)$$

式中, λ 和 μ 决定了域自适应的强度。

1.3 优化器的选择

深度学习中优化的过程如图 2 所示。将经过预处理的数据输入到一个已经搭建好的模型中。该模型会根据其初始的参数配置,对输入的数据进行处理,产生一个输出结果。将输出结果与一个预先定义的目标结果做比较,计算出一个损失值(或称为损失函数),以梯度下降的方法最小化这个损失函数。

在实际训练中,由于模型参数量过大,使用梯度下降算法非常耗时。通常使用随机梯度下降算法(stochastic gradient descent, SGD)。SGD 算法的核心是随机选择小规模样本来近似轨迹梯度,而不是针对所有的样本,因此该算法明显地降低了计算量^[11]。Adam 算法是一种结合 RMSProp 算法改进的自适应学习率优化算法。图 3 为 Adam 和 SGD 优化器在训练时获得的损失值和精度曲线,从图中可以看出,Adam 优化器的损失值比较低,在大约 20 次迭代时已经接近于 0,因此 Adam 优化器与 SGD 优化器相比,可以给模型带

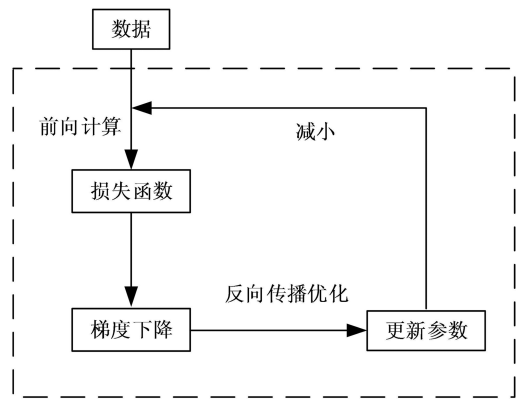


图 2 深度学习的优化过程

Fig.2 Deep learning optimization process

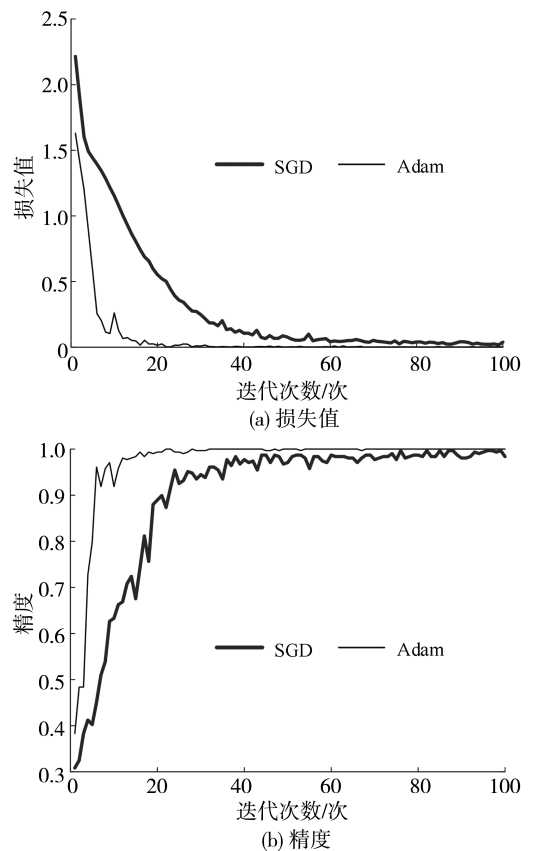


图 3 Adam 优化器和 SGD 优化器的精度与损失值

Fig.3 Accuracy and loss values of Adam optimizer and SGD optimizer

来更高的训练精度。

2 试验验证与结果对比

2.1 实验数据集介绍

简化后的凯斯西储大学轴承实验台^[12]如图 4 所示。电动机轴支撑着被测试的轴承并通过电火花加工引入了单点故障。经过加工的故障轴承

被重新装入测试电机中,分别在 0、0.75、1.50 和 2.25 kW 的负载条件下,使用 16 通道数据记录仪采集振动加速度信号。




图 4 凯斯西储大学轴承实验台^[12]

Fig.4 Bearing test bench of Case Western Reserve University^[12]

针对轴承数据集中的 4 种轴承状态(N 为正常轴承、IF 为内圈故障、OF 为外圈故障、BF 为滚动体故障),有 3 种不同的损伤直径(18、36、54 表示损伤直径大小为 0.18、0.36 和 0.54 mm)。轴承数据集要做十分类处理,其结果如表 1 所示。

数据集中包含 4 种负载下的工况,为方便表示迁移任务,将 0 kW 下的工况(源域)迁移到 0.75 kW 下的工况(目标域),用 0→1 来表示,12 种迁移任务如表 2 所示。

表 1 数据集的十分类

Tab.1 10 classes of data sets

分类	I	II	III	IV	V	VI	VII	VIII	IX	X
故障类型	N	IF18	OF18	BF18	IF36	OF36	BF36	IF54	BF54	OF54

表 2 迁移任务

Tab.2 Transfer Task

迁移任务	表示	迁移任务	表示
0 kW 迁移到 0.75 kW	0→1	0.75 kW 迁移到 0 kW	1→0
0 kW 迁移到 1.50 kW	0→2	0.75 kW 迁移到 1.50 kW	1→2
0 kW 迁移到 2.25 kW	0→3	0.75 kW 迁移到 2.25 kW	1→3
1.50 kW 迁移到 0 kW	2→0	2.25 kW 迁移到 0 kW	3→0
1.50 kW 迁移到 0.75 kW	2→1	2.25 kW 迁移到 0.75 kW	3→1
1.50 kW 迁移到 2.25 kW	2→3	2.25 kW 迁移到 1.50 kW	3→2

2.2 关键参数设置

将每个工况下的内圈、外圈、滚动体故障与正常轴承数据合并,并随机分成训练集和测试集,比例为 8:2,选用 Adam 优化器,学习率为 0.001,批量大小为 128。

2.3 试验结果分析与讨论

2.3.1 对比模型介绍

对比的模型包括:基于多核最大均值差异的一维卷积神经网络(multiple kernel maximum mean discrepancy-convolutional neural network, MKMMD-CNN);基于对抗策略迁移学习的一维卷积神经网络(adversarial-convolutional neural network, AD-CNN);传统的一维卷积神经网络(1D-CNN);最后是本文提出的引入多核最大均值差异核函数(multiple kernel maximum mean discrepancy,

MKMMD)两域距离优化的一维迁移卷积神经网络(1D-MKMMD-CTNN)共 4 种模型。

2.3.2 实验结果分析

4 种模型均完成了 12 组迁移任务,每种迁移策略重复实验 5 次,总计试验 240 次。4 种模型在 12 组迁移任务下的分类精度如表 3 和图 5。

表 3 迁移策略测试结果

Tab.3 Migration strategy test results

迁移策略	1D-CNN	MKMMD-CNN	AD-CNN	本文所提方法
0→1	96.96	96.74	99.34	99.74
0→2	97.88	98.53	99.85	99.94
0→3	87.93	94.15	99.19	99.85
1→0	98.54	89.77	98.96	99.31
1→2	99.42	99.92	98.61	99.95
1→3	94.55	99.16	99.16	99.76
2→0	90.34	92.66	95.54	99.42
2→1	95.96	98.73	98.48	99.01
2→3	95.53	99.90	99.79	99.99
3→0	84.41	96.71	95.13	98.19
3→1	87.67	97.77	97.81	98.70
3→2	90.69	99.77	99.72	100.00

从表 3 和图 5 可以看出,本文提出的 1D-MKMMMD-CTNN 方法,在故障诊断精度方面明显优于前几种模型。

组迁移策略的最终精度波动不大,相比于前述 3 种模型,该方法具有最佳的故障分类性能。




图 5 12 组迁移策略诊断精度 (单位: %)

Fig.5 Diagnostic accuracy of 12 groups of migration strategies (unit: %)

(1) 本文所提方法的故障类型分类精度基本保持在 99% 左右,有几组甚至达到 100%, 并且 12

(2) 仅用一维卷积神经网络模型进行跨工况中故障分类的平均精度为 93.47%, 比本文设计的模型相差约 6%, 再次证明了本文所提出模型精度的准确性。

(3) MKMMD-CNN 模型由于缺乏对抗策略, 相较于本文方法, 无法完全保证所提取的轴承故障特征是源域和目标域中共享的, 因此该模型的故障类型分类精度较低。

(4) 基于对抗策略的一维迁移卷积神经网络模型, 由于缺少 MKMMD 策略, 无法拉近源域和目标域特征分布的距离, 因此, 该模型的故障类型分类精度也要比本文提出的模型分类精度略低。

为了更全面比较这 4 种模型的迁移效果, 引入 KPCA 降维可视化 t-SNE, 展示迁移策略 (以 1.50 kW 迁移到 0 kW 工况为例) 下的故障类型分类结果, 如图 6 所示。图中横、纵坐标 x, y 分别表示特征 1 和特征 2。

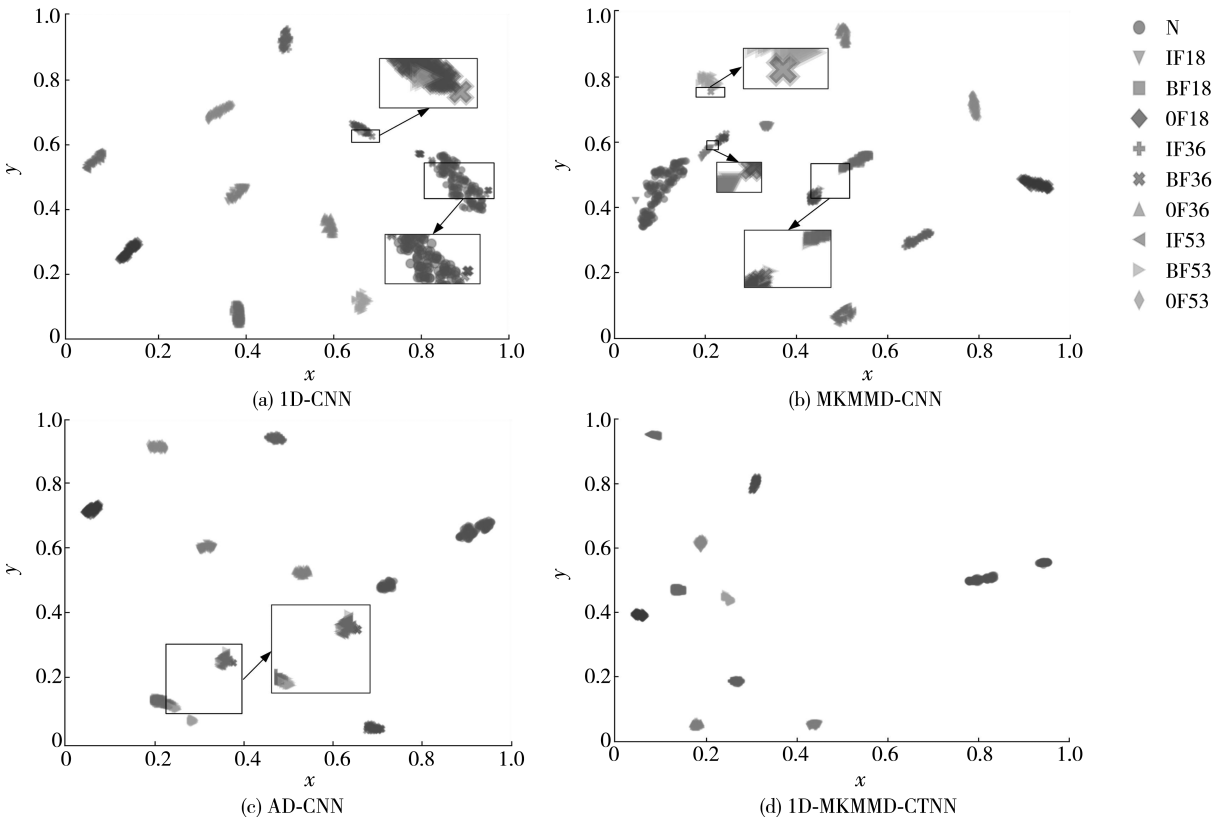


图 6 4 种模型可视化结果

Fig.6 Visualization results of 4 models

从图 6 可见, 3 种模型在得到的分类结果中均产生了部分重叠, 说明这 3 种模型存在将特征

错误地提取成其他故障类型特征的问题。

从图 7(a) 可看出,1D-CNN 模型在对编号为 IX 的轴承故障分类中,错误地将 6 个数据分类到编号 III 中,4 个数据错误地分类到 VI 中。在对编

号为 IV 的轴承故障分类中,将 5 个数据错误地分类到编号为 IX 中。一共有 15 个数据出现分类错误,是 4 种模型中分类精度最差的。

真实标签	I	II	III	IV	V	VI	VII	VIII	IX	X
I	47	0	0	0	0	0	0	0	0	0
II	0	23	0	0	0	0	0	0	0	0
III	0	0	24	0	0	0	0	0	0	0
IV	0	0	0	24	0	0	0	0	0	0
V	0	0	0	0	24	0	0	0	0	0
VI	0	0	0	0	0	19	0	0	5	0
VII	0	0	0	0	0	0	23	0	0	0
VIII	0	0	0	0	0	0	0	24	0	0
IX	0	0	6	0	0	4	0	0	14	0
X	0	0	0	0	0	0	0	0	0	24
	I	II	III	IV	V	VI	VII	VIII	IX	X

(a) 1D-CNN

真实标签	I	II	III	IV	V	VI	VII	VIII	IX	X
I	47	0	0	0	0	0	0	0	0	0
II	0	23	0	0	0	0	0	0	0	0
III	0	0	24	0	0	0	0	0	0	0
IV	0	0	0	24	0	0	0	0	0	0
V	0	0	0	0	24	0	0	0	0	0
VI	11	0	0	0	0	13	0	0	0	0
VII	0	0	0	0	0	0	23	0	0	0
VIII	0	0	0	0	0	0	0	24	0	0
IX	0	0	0	0	0	3	0	0	21	0
X	0	0	0	0	0	0	0	0	0	24
	I	II	III	IV	V	VI	VII	VIII	IX	X

(b) MKMMD-CNN

真实标签	I	II	III	IV	V	VI	VII	VIII	IX	X
I	47	0	0	0	0	0	0	0	0	0
II	0	23	0	0	0	0	0	0	0	0
III	0	0	24	0	0	0	0	0	0	0
IV	0	0	0	24	0	0	0	0	0	0
V	0	0	0	0	24	0	0	0	0	0
VI	0	0	0	0	0	21	0	3	0	0
VII	0	0	0	0	0	0	23	0	0	0
VIII	0	0	0	0	0	0	0	24	0	0
IX	0	0	3	0	0	0	0	0	21	0
X	0	0	0	0	0	0	0	0	0	24
	I	II	III	IV	V	VI	VII	VIII	IX	X

(c) AD-CNN

真实标签	I	II	III	IV	V	VI	VII	VIII	IX	X
I	47	0	0	0	0	0	0	0	0	0
II	0	23	0	0	0	0	0	0	0	0
III	0	0	24	0	0	0	0	0	0	0
IV	0	0	0	24	0	0	0	0	0	0
V	0	0	0	0	24	0	0	0	0	0
VI	0	0	0	0	0	24	0	0	0	0
VII	0	0	0	0	0	0	23	0	0	0
VIII	0	0	0	0	0	0	0	24	0	0
IX	0	0	0	0	0	2	0	0	22	0
X	0	0	0	0	0	0	0	0	0	24
	I	II	III	IV	V	VI	VII	VIII	IX	X

(d) 1D-MKMMD-CTNN

图 7 4 种模型混淆矩阵结果

Fig.7 Confusion matrix results of 4 models

从图 7(b) 可看出, MKMMD-CNN 模型在对编号为 IX 的轴承故障分类中,错误地将 11 个数据分类到编号 I 中。在对编号为 IX 的轴承故障分类中,将 3 个数据错误地分类到编号 VI 中。

从图 7(c) 可看出, AD-CNN 模型在对编号为 VI 的轴承故障分类中,错误地将 3 个数据分类到编号 VIII 中。在对编号为 IX 的轴承故障分类中,将 3 个数据错误地分类到编号为 III 中。

相比之下,本文提出的 1D-MKMMD-CTNN 模型表现较出色,如图 7(d) 所示,只有在对编号为 IX 的轴承故障分类中,错误地将 2 个数据分类到编号 VI 中。相比较前面 3 种模型出现错误分类的个数较少,能够准确地将十种轴承故障进行分类。

3 结论

1) 基于一维卷积的迁移学习神经网络模型无需对采集到的信号进行预处理,可直接输入信号以实现轴承故障的实时监测,满足工程实际需求。

2) 所设计的基于迁移学习的智能轴承故障分类方法克服了传统跨工况轴承故障分类中标记样本不足的问题,同时在分类精度上优于传统跨工况深度学习,如 2.25 kW 工况迁移到 0 kW 工况下,分类精度提高了 15%。

3) 通过结合对抗策略迁移和度量源域与目标域分布差异,显著提高了不同工况下的故障分类精度。该方法在凯斯西储大学轴承数据集的 4

种不同工况下进行了 12 组迁移策略的验证,结果 6%,表明了该方法的有效性。
显示故障分类的平均精度较传统方法可提高约

参考文献:

- [1] SUN Y J, WANG J, WANG X H. Fault diagnosis of mechanical equipment in high energy consumption industries in China: a review[J]. *Mechanical Systems and Signal Processing*, 2023, 186: 109833.
- [2] LI Z X, LI J M, DING W M, et al. A sparsity-enhanced periodic OGS model for weak feature extraction of rolling bearing faults[J]. *Mechanical Systems and Signal Processing*, 2022, 169: 108733.
- [3] ZHANG S, ZHANG S B, WANG B N, et al. Deep learning algorithms for bearing fault diagnostics—a comprehensive review [J]. *IEEE Access*, 2020, 8: 29857–29881.
- [4] HUANG T, ZHANG Q, TANG X A, et al. A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems[J]. *Artificial Intelligence Review*, 2022, 55(2): 1289–1315.
- [5] ZHU J, CHEN N, SHEN C Q. A new deep transfer learning method for bearing fault diagnosis under different working conditions[J]. *IEEE Sensors Journal*, 2020, 20(15): 8394–8402.
- [6] CAO Z J, MA L J, LONG M S, et al. Partial adversarial domain adaptation[M] // *Computer Vision-ECCV 2018*. Cham: Springer International Publishing, 2018: 139–155.
- [7] GRETTON A, SRIPERUMBUDUR B, SEJDINOVIC D, et al. Optimal kernel choice for large-scale two-sample tests[C] // *Proceedings of the 25th International Conference on Neural Information Processing Systems-Volume I*. Lake Tahoe, Nevada: ACM, 2012: 1205–1213.
- [8] BEN-DAVID S, BLITZER J, CRAMMER K, et al. A theory of learning from different domains[J]. *Machine Learning*, 2010, 79(1): 151–175.
- [9] CAO X C, WANG Y, CHEN B Q, et al. Domain-adaptive intelligence for fault diagnosis based on deep transfer learning from scientific test rigs to industrial applications[J]. *Neural Computing and Applications*, 2021, 33(9): 4483–4499.
- [10] CHOUDHARY A, MIAN T, FATIMA S. Convolutional neural network based bearing fault diagnosis of rotating machine using thermal images[J]. *Measurement*, 2021, 176: 109196.
- [11] 王功鹏, 段萌, 牛常勇. 基于卷积神经网络的随机梯度下降算法[J]. *计算机工程与设计*, 2018, 39(2): 441–445, 462.
- [12] 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: 100–131.

(责任编辑: 陈雯)

(上接第 386 页)

- [7] 马月, 吕永刚, 温友超, 等. 海上光伏电站基础结构的综述[J]. *科技与创新*, 2023(20): 92–95.
- [8] 曾胜财, 兰祥武. 海上渔排离网型光伏电站设计与应用[J]. *海峡科学*, 2023(10): 39–42, 69.
- [9] 熊礼俭. 风力发电新技术与发电工程设计、运行、维护及标准规范实用手册[M]. 北京: 中国科技文化出版社, 2005.
- [10] 陈恒安, 管霖, 卢操, 等. 新能源发电为主电源的独立微网多目标优化调度模型和算法[J]. *电网技术*, 2020, 44(2): 664–674.
- [11] 毛晓明, 陈深, 吴杰康, 等. 分时电价机制下含蓄电池微网的优化调度[J]. *电网技术*, 2015, 39(5): 1192–1197.
- [12] JAIN H, DEB K. An evolutionary many-objective optimization algorithm using reference-point based nondominated sorting approach, part II: handling constraints and extending to an adaptive approach[J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(4): 602–622.
- [13] 陶思钰, 黄民翔. 基于 NSGA-II 算法的并网型微网多目标调度[J]. *华东电力*, 2013, 41(8): 1678–1682.
- [14] ZHAO W T, WANG Z S, SONG W H, et al. Multi-objective optimal operation of microgrid based on NSGA-III algorithm [C] // *2022 IEEE/IAS Industrial and Commercial Power System Asia (I&CPS Asia)*. Shanghai: IEEE, 2022: 877–881.

(责任编辑: 方素华)