DOI: 10.3901/JME.2021.21.096

基于增强迁移卷积神经网络的机械智能故障诊断*

陈祝云 钟 琪 黄如意 廖奕校 李霁蒲 李巍华
(华南理工大学机械与汽车工程学院 广州 510640)

摘要: 现有的基于深度迁移学习的智能诊断方法通常对源域和目标域特征对齐来减少两者分布差异, 没有考虑源域类别决策边界对目标域特征匹配的影响, 针对此不足, 提出了一种增强迁移卷积神经网络(Enhanced transfer convolutional neural network, ETCNN)来改进机械设备在变工况下的诊断精度和泛化能力。为充分利用标签信息和提取高维特征, 构建卷积神经网络和两个独立的分类器对源域数据分别训练, 用于检测远离决策边界的目标域样本。为有效减少不同决策边界处样本的误匹配, 进一步构建分类损失函数和分类器判别损失函数, 并引入对抗训练策略, 最大两个分类器的分类差异, 同时最小化源域与目标域特征分布差异, 实现目标域样本与源域样本自适应匹配, 从而有效改进故障的分类性能。在滚动轴承数据集上对所提方法进行充分评估, 并与其他三种深度迁移学习方法: 域适配网络(Domain adaptive network, DAN), 多层域适配网络(Multi-layer DAN, MLDAN), 以及深度对抗卷积神经网络(Deep adversarial convolutional neural network, DACNN)进行充分比较, 结果表明, 所提方法不仅具有良好的分类能力和泛化能力, 同时明显优于其他方法。

关键词: 机械设备; 故障诊断; 迁移学习; 增强迁移卷积神经网络

中图分类号: TG156

Intelligent Fault Diagnosis for Machinery Based on Enhanced Transfer Convolutional Neural Network

CHEN Zhuyun ZHONG Qi HUANG Ruyi LIAO Yixiao LI Jipu LI Weihua
(School of Mechanical & Automotive Engineering, South China University of Technology, Guangzhou 510640)

Abstract: Existing intelligent fault diagnosis methods based on deep transfer learning techniques usually align the features of source domain and target domain to reduce distribution discrepancy, ignoring the influences of category decision boundary on target domain samples. Therefore, an enhanced transfer convolutional neural network (ETCNN) is proposed to improve the diagnostic accuracy and generalization ability of mechanical equipment under variable operation conditions. To make full use of the label information and extract high-dimensional features, convolutional neural network with two independent classifiers is separately trained on the source domain data to detect target domain samples away from the decision boundary. To effectively reduce the mismatch of samples at different decision boundaries, a classification loss function and a classifier discriminative loss function are constructed. Furthermore, an adversarial training strategy is introduced to adaptively match samples across domains and improve the classification performance by maximizing the classification differences between the two classifiers while minimizing the differences in feature distributions. The proposed method is fully evaluated on the rolling bearing data set and compared with the other three diagnosis methods including domain adaptive network (DAN), multi-layer DAN (MLDAN) and deep adversarial convolutional neural network (DACNN). The results show that the proposed method not only presents good classification and generalization performance, but also significantly outperforms other methods.

Key words: mechanical equipment; fault diagnosis; transfer learning; enhanced transfer convolutional neural network

0 前言

旋转机械广泛应用在航空航天、汽车制造、轨

道交通和风力发电等国计民生的重要工程领域, 在国民经济生产中具有举足轻重的作用^[1]。开展机械设备的状态监测与诊断, 对可能发生的故障进行检测、诊断和预测, 以“防患于未然”, 对保证机械的可靠、连续和稳定运行, 减少经济损失和运行成本以及避免重大事故发生, 具有十分重要的现实需求

* 国家重点研发计划(2018YFB1702400)和国家自然科学基金(51875208, 51475170)资助项目。20201201 收到初稿, 20210325 收到修改稿

和实际意义^[2]。

基于数据驱动的诊断方法不需建立复杂部件或系统的动力学模型, 通过利用大量历史数据建立和优化模型, 可获得良好结果, 因而非常适用于复杂机械的智能故障诊断^[3]。目前基于数据驱动的故障诊断方法通常可分为基于传统机器学习的智能诊断方法、基于深度学习的智能诊断方法和基于迁移学习的智能诊断方法。

传统机器学习方法通常基于浅层网络结构, 限制了其高维特征学习能力。深度学习方法由于其强大的自动特征学习能力在故障诊断领域已取得较大的成功^[4-6]。但其良好的分类性能通常受限于以下两个基本假设^[7]: ① 测试数据与训练数据需满足独立同分布; ② 待诊断任务有充足的标签故障样本。

迁移学习放宽了传统机器学习/深度学习中测试数据和训练数据须服从独立同分布的约束。在迁移学习中, 源域任务与目标域任务的特征空间分布不需一致, 能够在彼此不同但相关的两个域间挖掘领域不变的本质结构和特征, 使得标注数据等有监督信息可在领域间实现迁移和复用^[8]。在故障诊断领域, 一些学者采用时频域特征和迁移成分分析^[9]、奇异值分解和 TrAdaBoost 迁移算法^[10]以及神经网络辅助训练分类器^[11]等传统方法开展了一些迁移学习智能诊断方法研究。此外, 将深度神经网络和迁移学习技术相结合, 研究基于特征表示的深度迁移学习方法, 在解决小样本学习和域偏移等诊断问题上也有了较多的探索和应用^[12]。例如在解决小样本学习方面, 邵海东等^[13]提出了一种提升深度迁移自编码网络诊断模型, 借助于其他设备的辅助数据预训练网络, 采用一个训练样本进行参数调优, 改进了小样本下的轴承诊断精度。SHAO 等^[14]利用在 ImageNet 上预训练的 AlexNet 模型, 采用时频图对网络高层进行调优, 在小样本下改进了齿轮和轴承的诊断精度。CHEN 等^[15]提出了一种可迁移的深度卷积神经网络, 采用微调策略, 实现了不同设备下的知识迁移和小样本诊断。然而, 上述基于参数迁移的学习方案通常需要假定目标域数据有少量标签样本, 限制了该方法更广阔的应用。

另一种是基于域适配的迁移学习方案, 通过构建度量函数减少源域和目标域数据的分布差异^[16]。例如 LU 等^[17]提出了一种深度神经网络诊断模型, 采用自编码网络和最大均值差异(Maximum mean discrepancy, MMD)减少源域和目标域样本在高维特征空间上的分布差异, 从而改进故障诊断的域适配能力。WEN 等^[18]构建了一种深度域适配网络诊断

模型, 采用源域和目标域的自相关频谱特征输入稀疏自编码, 并嵌入 MMD 损失函数来联合训练, 改进了电机的故障诊断性能。雷亚国等^[19]开发了一种深度迁移学习诊断模型, 通过集成深度残差网络与领域适配正则项约束, 可有效的诊断不同机械设备间的同种故障类型。ZHANG 等^[20]将卷积神经网络和 MMD 结合, 提出深度适配卷积神经网络诊断模型, 可有效诊断电机轴承故障。WANG 等^[21]提出了一种深度迁移学习诊断模型, 结合残差网络、多尺度特征提取器及伪标签构造条件最大均值差异技术对每类样本进行域适配, 可有效诊断不同载荷下的轴承故障。HAN 等^[22]提出一种深度对抗卷积神经网络诊断模型, 通过引入梯度反转层, 执行对抗训练, 改进了不同载荷下的风机故障诊断精度。YANG 等^[23]提出了一种特征迁移神经网络, 通过引入多层特征适配和伪标签学习, 实现了不同设备的知识迁移和诊断。LI 等^[24]提出了一种多层域适配卷积神经网络, 采用多个高斯核函数, 通过对深度卷积神经网络不同层的特征分别进行域适配, 并构建损失函数联合训练, 有效改进了诊断网络对迁移任务的分类能力。ZHU 等^[25]提出了一种深度迁移学习卷积神经网络, 网络在底层采用共享的特征提取器, 在全连接层构建多层 MMD 域适配, 来改进不同载荷下的轴承分类性能。

图1 不同的深度迁移学习方案

然而, 上述大多数深度迁移网络诊断方法, 如图 1a 所示, 通常采用深度神经网络作为特征提取器对输入信号提取高维特征, 采用度量函数如 MMD 或域判别器等, 对提取的深度特征进行适配, 实现源域和目标域特征对齐。但网络并没考虑源域类别决策边界对目标域特征匹配的影响, 因而域适配阶段, 特征提取器仍可能学习到处于决策边界处的特征。针对在决策边界上的一些目标域样本, 如图中标注的紫色圆圈所示, 在源域数据上学习到的类别决策边界对这些样本容易产生误分类, 从而限制了网络的诊断性能。

因而, 如图 1b 所示, 提出一种增强迁移卷积神经网络 (Enhanced transfer convolutional neural network, ETCNN) 诊断方案, 构建两个独立的分类器对源域数据学习两个独立的决策边界, 针对决策边界处的样本, 对两个分类器的预测结果进行度量。域适配阶段, 最小特征分布差异同时最大分类器差异, 减少网络学习的特征落入到决策边界附近, 从而有效提高故障识别精度和泛化能力。论文的主要贡献包括以下几点。

(1) 考虑目标域样本与源域类别决策边界的关系, 构建具有卷积神经网络结构和独立分类器的诊断模型, 采用源域数据分别进行训练, 可利用源域标签信息学习不同的决策边界, 实现对决策边界外的目标域样本的有效检测。

(2) 在域适配阶段, 通过引入分类损失函数、分类器判别损失函数, 采用对抗训练技术, 最大两个分类器的分类差异, 同时最小化源域与目标域特征分布差异, 使网络可利用源域类别信息减少目标域样本的误匹配, 改进网络的诊断性能。

(3) 通过滚动轴承故障诊断试验, 在六种迁移任务上, 验证了所提方法具有良好的诊断能力和泛化性能, 同时优于其他比较方法。

1 增强迁移卷积神经网络诊断方案

1.1 网络结构描述

所提的增强迁移卷积神经网络诊断框架如图 2 所示。网络结构由特征提取器 G_f 和两个独立的分类器 C 构成。特征提取器 G_f 通过堆叠多个一维卷积层、批次归一化层和最大池化层组成, 可直接对一维的原始输入信号进行处理。而分类器则由一个全连接层和 Softmax 层构成, 负责对高层特征进行处理, 学习输入数据的分类决策边界。

图 2 增强迁移卷积神经网络故障诊断框架

网络结构的具体参数如图 3 所示。网络输入数据为一维振动信号, 第一个卷积层采用较大的卷积核进行滑窗和卷积操作, 卷积核尺寸为 64×1 , 步幅为 16, 卷积核的数量设置为 20, 以增强网络特征学习和抗噪性能。接下来三个卷积层的卷积核数目分别设置为 20、40 和 40, 卷积核尺寸为 3×1 , 步幅为 2, 以提高网络对细节特征的学习能力。此外, 在每一卷积层, 嵌入批次归一化层以及最大池化层, 池化大小为 2×1 , 步幅为 2, 从而使得池化后输出的特征图尺寸减小一半, 降低网络的复杂度。在分类器结构上, 每个分类器 C_1 和 C_2 都具有一个全连接层, 节点数设置为 500, 并在最终的输出层, 采用 Softmax 函数执行最终的分类输出任务。

图 3 所提方法的网络结构参数

1.2 网络参数优化

所提方法利用特征提取器 G_f 从原始数据输入中直接提取高维特征, 采用监督训练方法对源域样本分别训练两个独立的分类器 C_1 和 C_2 , 对源域样本进行正确分类。由于不同分类器学习的决策边界对目标域样本的预测具有差异性, 构造两个分类器的判别损失, 对这种差异性进行度量。基于生成对抗网络的学习思想^[26], 将文中构建的特征提取器 G_f 当作生成对抗网络的生成器, 将构建的两个分类器 C_1 和 C_2 当作生成对抗网络的判别器, 采用对抗训练技术, 一方面固定特征提取器 G_f , 最大化两个分类器的分类差异, 以使得域决策边界内的样本能尽可能分类, 在源域边界外的目标域样本更好的检测。另一方面, 固定分类器 C_1 和 C_2 的参数, 最小化源域与目标域特征之间的差异, 训练特征提取器 G_f , 使得目标域样本更接近于源域样本, 实现源域和目标域特征对齐。通过特征提取器和分类器形成一种

对抗机制，获取优化的网络模型。所提方法考虑源域类别判别边界对目标域样本的影响，利用两个独立的分类器作为判别器，可有效将不同域之间的特征对齐，具体学习过程包括以下三步。

步骤一：监督训练特征提取器 G_f 和分类器 C 。源域数据集 $\{X_s, Y_s\}$ 由原始数据 X_s 及其对应标签 Y_s 组成，而目标域数据 $\{X_t\}$ 由不带标记的目标域数据 X_t 构成。将源域数据 X_s 输入特征提取器 G_f 中，得到数据的高维特征，并进一步输入到两个分类器 C_1 和 C_2 中，两个分类器分别将源域数据准确分为 K 类 (K 为源域类别数)，分类器采用 Softmax 函数作为输出获得类别的概率分布。分类损失函数为

$$L_{cls}(X_s, Y_s) = -E_{(x_s, y_s) \sim (X_s, Y_s)} \sum_{k=1}^K \mathbb{1}_{[k=y_s]} \lg p(y|x_s) \quad (1)$$

式中， $p(y|x_s)$ 对应分类器对源域样本的概率输出。采用传统的监督学习算法，利用最小化交叉熵损失训练特征提取器 G_f 和对应的两个分类器 C_1 和 C_2 ，对网络特征提取器和分类器参数进行优化

$$\min_{G_f, C_1, C_2} L_{cls}(X_s, Y_s) \quad (2)$$

步骤二：构建分类器判别损失函数。由于分类器 C_1 和 C_2 初始化参数不同，采用源域数据同时训练网络时，可获得两个具有不同判别特性的分类器。由于两个分类器学习到不同的决策边界，对同一个目标域样本，两个分类器可能获得不同的分类结果，因而网络进一步引入分类器判别损失函数，即

$$L_{dis}(X_t) = E_{x_t \sim X_t} [d(p_1(y|x_t), p_2(y|x_t))] \quad (3)$$

式中， $p_1(y|x_t)$ 和 $p_2(y|x_t)$ 分别为分类器 C_1 和 C_2 的概率输出；通过 L_{dis} 对两个分类器获得的概率输出计算散度 $d(p_1(y|x_t), p_2(y|x_t))$ 来测量目标样本数据的差异。

在本研究中，利用两个分类器的概率输出之差的绝对值作为度量函数，度量两个分类器的输出差异^[27]。计算公式如下

$$d(p_1, p_2) = \frac{1}{K} \sum_{k=1}^K |p_{1k} - p_{2k}| \quad (4)$$

式中， d 为度量函数，利用 L_1 距离计算； p_{1k} 和 p_{2k} 为两个分类器对第 K 类的概率输出。

步骤三：对抗训练特征提取器 G_f 和分类器 C 。在前面的网络分类中，由于两个分类器 C_1 和 C_2 的决策边界只在源域数据上进行训练，当源域和待测的目标域数据分布不一致时，两个分类器都不能很好地对目标域样本进行分类。在域适配阶段，为对

特征提取器和分类器进行有效训练，减少两个域的数据分布差异，引入对抗训练思想，采用交替迭代的方式来对网络参数进行更新。一方面，固定特征提取器 G_f ，训练两个分类器 C_1 和 C_2 。采用标签源域数据优化分类器的分类性能，同时最大化分类器的分类差异，使两个分类器可更好地检测出位于源域边界之外的目标域样本。通过对分类器判别损失函数引入负数，网络通过最小化分类损失函数和分类器判别损失函数，对分类器参数进行更新

$$\min_{C_1, C_2} L_{cls}(X_s, Y_s) - L_{dis}(X_t) \quad (5)$$

上述优化后的分类器能对不同决策边界外的目标域样本进行检测，但无法减少源域和目标域数据的分布差异，因而，进一步固定分类器 C_1 和 C_2 的参数，训练特征提取器 G_f ，使得目标域的样本与源域样本之间的分布差异尽可能小，从而实现对源域与目标域数据的分布匹配，网络的优化函数，计算公式如下

$$\min_{G_f} L_{dis}(X_t) \quad (6)$$

在训练过程中，先执行步骤一，监督训练特征提取器和分类器，达到一定预迭代次数，然后执行步骤三，进行对抗训练，重复步骤一和步骤三的训练过程，直至获得优化的诊断网络，并用于对目标域数据进行故障诊断。

1.3 网络诊断流程

所提 ETCNN 方案的流程图如图 4 所示，其最终的诊断流程可归纳如下。

(1) 从机械设备中获取不同运行工况下的机械设备振动数据，构建标签源域和无标签目标域数据，并将数据进一步划分成训练和测试数据。

(2) 构建特征提取器、两个独立分类器，并进一步构建对应的分类损失函数和分类器判别损失函数。

(3) 将源域训练数据输入到特征提取器和两个独立的分类器，基于步骤一，采用交叉熵损失函数，利用反向传播算法，对特征提取器和分类参数进行有监督训练。

(4) 输入源域和目标域训练数据，基于步骤三中的式(5)采用对抗训练策略，固定特征提取器，采用训练数据优化分类器，同时最大化分类器的判别损失函数，更新分类器参数。

(5) 利用训练数据，基于步骤三中的式(6)，固定两个分类器参数，最小化判别损失函数，优化特征提取器参数，使源域和目标域数据尽可能匹配。

(6) 重复步骤(3)~(5), 直到达到给定的迭代次数, 此时输出优化的诊断模型。

(7) 利用目标域测试数据输入到训练好的诊断模型中测试, 两个分类器输出概率值, 通过求和平均后, 输出不同运行工况下的诊断结果。

图 4 所提 ETCNN 方案的流程图

2 故障诊断试验与算法验证

2.1 数据描述

为评估所提方法的性能, 采集相关的不同工况下的轴承数据集进行验证。数据集采自旋转机械滚动轴承故障试验平台, 如图 5 所示。

图 5 滚动轴承试验平台

在该试验平台中, 输出轴承由皮带轮通过加载

电机进行驱动, 故障轴承安装在输出轴上, 并在输出轴承座上安装加速度传感器, 以 12 000 Hz 的采样频率采集机械振动信号。试验台分别运行在 800 r/min、1 100 r/min 和 1 400 r/min 的轴转速下, 以模拟不同的运行工况。针对轴承的故障类型, 总共设置了 3 种轴承健康状态用于分类: 正常状态, 内圈故障(通过线切割加工引入 0.5 mm 和 2.0 mm 等缺陷)和外圈故障(通过线切割加工引入 0.5 mm 和 2.0 mm 缺陷), 具体数据集描述如表 1 所示。

表 1 滚动轴承不同健康状态描述

转速/(r/min)	健康状态	缺陷尺寸/mm	标签
800 & 1 100 & 1 400	正常状态	0	1
800 & 1 100 & 1 400	内圈故障	0.5 和 2.0	2
800 & 1 100 & 1 400	外圈故障	0.5 和 2.0	3

为构建迁移任务, 将三种转速下采集的三种不同健康状态的轴承数据用于试验评估。考虑到轴承的内圈和外圈故障特征频率, 截取的样本长度需至少包含故障频率的一个周期, 因而从原始信号中截取 2 048 个数据点形成一个样本。在每个运行转速下, 正常状态有 300 个样本, 而内圈故障(包含两种不同缺陷)和外圈故障(包含两种不同缺陷)分别有 600 个样本, 因而三种健康状态共有 1 500 个样本, 并以 50% 的比例划分为训练和测试数据。

为执行域适配, 首先设计 A→B 和 A→C 两种迁移任务。以第一个迁移任务即 A→B 为例, A 代表源域任务, 数据采集自 800 r/min 的运行工况, 而 B 代表目标域任务, 数据采集自 1 100 r/min 的运行工况。构建的增强迁移卷积神经网络致力于只采用源域标签训练数据 and 无标签的目标域训练数据, 执行对抗训练和知识迁移, 并在测试阶段, 用无标签目标域的测试集验证网络的分类能力。在每个试验中, 随机选择任务的一半样本用于训练, 而其余样本用于测试。此外, 通过将源域和目标域诊断任务进行互换, 采用交叉验证, 设计了另外四种迁移任务: B→A、B→C、C→A 和 C→B, 从而可对算法进行综合评估, 具体的迁移任务如表 2 所示。

表 2 轴承数据集构建的六种迁移任务

迁移任务	源域转速/(r/min)	目标域转速/(r/min)	标签源域样本	无标签目标域样本
A→B	800	1 100	1 500	1 500
A→C	800	1 400	1 500	1 500
B→A	1 100	800	1 500	1 500
B→C	1 100	1 400	1 500	1 500
C→A	1 400	800	1 500	1 500
C→B	1 400	1 100	1 500	1 500

2.2 相关方法描述

在六个迁移任务上使用了三种经典的深度迁移学习算法进行比较。

(1) 域适配网络(Domain adaptive network, DAN)。DAN 是 ZHANG 等^[20]提出的方法, 用于滚动轴承故障诊断。网络采用卷积神经网络提取源域和目标域的高维特征, 并采用 MMD 方法来度量源域和目标域的特征差异, 网络通过反向传播算法实现目标域自适应迁移。

(2) 多层域适配网络(Multi-layer DAN, MLDAN)。MLDAN 是 YANG 等^[23]和 LI 等^[24]采用的深度迁移学习方法, MLDAN 在 DAN 的基础上, 进一步采用了多层域适配技术, 综合利用卷积神经网络的底层和高层特征进行联合域适配, 从而更好地实现特征匹配。

(3) 深度对抗卷积神经网络(Deep adversarial convolutional neural network, DACNN)。DACNN 是 HAN 等^[22]提出的方法。网络包含特征提取器、标签预测器和域分类器。特征提取器和标签预测器由 CNN 提取特征。在对抗训练中, 域分类器引入梯度反转层, 采用随机梯度下降法实现网络参数优化。

在比较的诊断方法中, DAN 引入经典的最大均值差异度量函数, 是最早与深度神经网络结合执行深度迁移学习的方法之一。MLDAN 进一步将 DAN 的单层域适配拓展到多层域适配。DACNN 采用对抗训练技术对源域和目标域执行域适配, 在不同领域获得了广泛的应用。因而, 三种方法可从不同方面与所提方法进行充分比较。

在四种深度迁移学习方法中, 有一些核心参数, 比如卷积神经网络的结构、学习率、损失函数、批次、优化算法、迭代次数等对网络的分类性能具有重要的影响, 为尽量保证比较的客观性, 对所有比较的方法, 我们采用了与所提 ETCNN 相同的卷积神经网络结构, 即在 DAN、MLDAN、DACNN 三种比较方法中, 都具有与所提方法相同的堆叠多个卷积和池化层结构的特征提取器和具有全连接层和 Softmax 层结构的分类器; 同时都采用了相同的学习率(设置为 0.01), 优化器(Adam)、批次(设置为 50)、分类损失函数(采用交叉熵损失函数)以及迭代次数(设置为 300), 并且所有比较的方法和所提方法, 都采用原始数据输入, 用测试数据测试, 重复五次试验, 以提供综合评价。所有方法都在 Intel Xeon E5-262v3(2.4 GHz), 64G RAM, TITAN X 图形处理上, 采用 PyTorch 深度学习框架进行运算。

2.3 结果与讨论

(1) 不同迁移任务上的结果比较。

诊断结果如表 3 所示, 可观察到, 在六个诊断任务上, 四种深度迁移学习诊断方法都提供了较好的分类结果。在比较的方法中, DACNN 取得了最小的平均分类精度(91.46%), DAN 的平均分类精度为 92.01%, 而 MLDAN 的平均分类精度为 92.67%, 取得了比 DAN 稍微更好的结果, 表明多层域适配方案通过综合利用不同层的特征, 可改进网络的迁移学习能力。而所提 ETCNN 的平均分类精度为 94.29%, 相比其他三种比较方法, 在每个迁移任务上, 都平均提高了至少 2%。

此外, 对单个迁移任务进行分析, 可发现, 几种比较方法在一些任务: C→A 和 C→B 上取得了与所提 ETCNN 一致好的分类性能(在分类精度和标准差上都很有竞争力), 但是在其他几个迁移任务上, 比如 A→C 上, DACNN 只取得了 87.52%的分类精度, DAN 和 MLDAN 分别取得了 91.09%和 92.33%, 而 ETCNN 为 96.09%, 比其他方法精度更高。同时, 在不同的迁移任务上, ETCNN 也具有更好的分类稳定性和分类精度。表明所提方法通过利用决策边界信息, 能够更有效地减少不同域之间的分布差异, 获得更好的域适配能力和分类性能。

表 3 各方法在轴承数据集上的分类结果

迁移任务	DAN	MLDAN	DACNN	ETCNN
A→B	94.40±0.89	94.74±2.70	94.11±2.31	98.40±0.58
A→C	91.09±2.94	92.33±4.57	87.52±2.27	96.09±2.27
B→A	93.09±1.30	93.01±3.03	92.91±2.78	95.84±0.47
B→C	94.01±4.56	95.56±4.69	95.12±2.01	97.83±1.16
C→A	84.89±3.82	85.12±2.52	84.15±3.69	85.96±3.28
C→B	94.55±1.67	95.25±2.96	94.95±1.82	95.41±2.11
平均值	92.01	92.67	91.46	94.92

(2) 不同方法的泛化性分析。

在实际的工业生产中, 机械设备通常运行在可变工作条件下, 从设备采集的数据本身包含了一定的背景噪声干扰。为模拟在实际环境中, 采集的测试数据可能包含的额外背景噪声, 在测试阶段, 借鉴相关方案^[28-30], 对原始测试数据添加一定水平的高斯白噪声, 以验证算法的泛化性。首先采用训练数据训练网络, 然后对每个测试样本都添加了零均值高斯白噪声, 其信噪比(Signal-to-noise ratio, SNR)为 4 dB。并将加噪后的测试数据分别输入到 DAN、MLDAN、DACNN 和所提 ETCNN 中, 进行迁移任务诊断, 以进一步比较不同方法的泛化能力。

五次平均后的诊断结果(包括均值和标准差)如图 6 所示。从结果可看出, 由于目标域测试数据添加了额外的高斯白噪声, 相比原始未加噪数据结果, 所有方法的诊断精度都有比较大的下降, 这是因为尽管深度迁移诊断网络可有效减少不同域分布差异, 然而原始振动信号经过进一步加噪后, 包含在信号中的相关判别信息很容易被噪声干扰并覆盖, 不仅导致判别信息变得微弱, 同时加大了源域和目标数据的分布差异, 因此, 增加了深度迁移学习方法对迁移任务的诊断难度。

此外, 在比较的三种方法中, DAN 和 MLDAN 获得了比较高的结果, 它们的平均分类精度分别为 79.62% 和 80.43%。而 DACNN 的分类能力相对较差, 其平均精度只有 72.92%, 并且不同迁移任务诊断精度波动较大, 如在 $A \rightarrow B$ 和 $A \rightarrow C$ 中, 其分类精度均有较大程度的下降。而所提方法的平均分类精度为 82.51%, 在四种方法中获得更高的分类精度, 同时在不同迁移任务上具有较小的标准差。以上分析表明, 所提 ETCNN 能够抵御额外噪声的影响, 呈现更好的分类和泛化性能。

图 6 不同方法在加噪数据下泛化性分析

(3) 预选代数对分类性能的影响。

在所提 ETCNN 中, 步骤一的预选代数是一个很重要的参数。为研究预选代数对网络分类性能的影响, 以迁移任务 $A \rightarrow B$ 为例, 预选代数从 {1, 2, 3, 4, 5, 6, 7} 中递增选择, 每次试验重复五次, 最终结果取平均值和标准差综合评估。

从图 7 可看出, 当预选代数为 1 时, 分类精度为 96.51%, 当取值在 3~7 时, 分类精度整体变化较小, 表明网络对上述取值不太敏感。考虑分类性能和训练时间, 预选代数设置为 4。

(4) 可视化分析。

为对网络学习的特征进行分析和, 采用 t-SNE 技术^[31]对不同方法学习的特征进行可视化。以 $A \rightarrow B$ 为例, 提取 DAN、MLDAN、DACNN 及所提

ETCNN 在全连接层的输出特征, 分别进行降维可视化。不同方法的聚类性能如图 8 所示。其中“S”表示源域数据, “T”表示目标域数据。例如“S-1”代表源域类别 1, 而“T-1”代表目标域类别 1。

图 7 预选代数对分类性能的影响

从图 8 可看到, 在单一源域任务上(S-1、S-2 和 S-3), 四种方法在监督学习任务中都有很强的特征学习能力: 相同健康状态能很好聚类, 不同健康状态也能明显区分。然而综合考虑源域和目标域的聚类性, 在 DAN 和 MLDAN 中, 以类别 2 为例, 来自源域和目标域的样本尽管属于同种类别, 却分散在不同区域, 具有较少的样本重叠, 表明两种方法在该类别上域适配能力的局限性。DACNN 在该任务上, 比其他两种比较方法表现更好, 来自源域和目标域的样本大部分都能够很好重合, 但同时也有较多的样本分散在类别 1 和类别 3 中。对比的, 所提 ETCNN 明显获得更好的结果。

图 8 特征可视化分析

此外, 所提 ETCNN, 在目标域测试样本中, 有少量属于类别 2 的样本(外圈故障: T-2)和类别 1 的样本(正常状态: T-1)相互混叠在一起, 表明这些

样本存在较大相似性, 所提方法并不能很好将其区分, 因而这些样本将容易被误分类。对其中一次测试结果采用混淆矩阵进行分析, 如图 9 所示, 所提方法有少量样本(3.5%)预测为类别 1, 但实际属于类别 2, 同时也有少量样本被预测为类别 2 和类别 3, 但实际分别属于类别 3 和类别 2, 因而在最终诊断结果中, 所提方案没达到 100% 的诊断精度, 这与表 3 的结果一致: 所提方法在该任务下平均分类精度为 98.40%。然而, 对比其他几种深度迁移学习诊断结果, 所提方案仍获得了更好的分类结果, 验证了其更优的域适配能力。

图 9 混淆矩阵

3 结论

提出了一种 ETCNN 诊断方法, 通过考虑源域和目标域的数据分布差异以及决策边界信息, 所提方法能自适应实现不同域之间的特征匹配, 解决机械设备在变工况故障诊断存在的域偏移问题。论文的主要结论如下所述。

(1) 采用特征提取器和两个独立的分类器可有效建立目标域样本与域源域类别决策边界的关系, 改进分类器对目标域样本的检测能力。

(2) 引入分类损失函数、分类器判别损失函数和对抗训练策略到诊断网络, 综合利用了决策边界和域分布信息, 减少了两域之间的数据分布差异, 增强了诊断网络域适配能力。

(3) 试验结果表明, 与其他三种深度迁移学习方法相比, 所提方法呈现了更好的特征学习能力, 尤其是在加噪数据下, 所提方法具有更强的故障分类和泛化性能。

参 考 文 献

- [1] 陈雪峰, 訾艳阳. 智能运维与健康诊断[M]. 北京: 机械工业出版社, 2018.
CHEN Xuefeng, ZI Yanyang. Intelligent maintenance and

health management [J]. Beijing: China Machine Press, 2018.

- [2] 王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
WANG Guobiao, HE Zhengjia, CHEN Xuefeng, et al. Basic research on machinery fault diagnosis—what is the prescription[J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.
- [3] 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.
- [4] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [5] 李川, 张绍辉, JOSE V. 基于次优网络深度学习的 3D 打印机故障诊断[J]. 机械工程学报, 2019, 55(7): 73-80.
LI Chuan, ZHANG Shaohui, JOSÉ V. Fault diagnosis for 3d printers using suboptimal networked deep learning, Journal of Mechanical Engineering, 2019, 55(7): 73-80.
- [6] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9-18.
HU Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks[J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18.
- [7] LONG Mingsheng, CAO Yue, WANG Jianmin, et al. Learning transferable features with deep adaptation networks[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning, July 6-11, Lille, France, 2015: 97-105.
- [8] PAN S, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 22(10): 1345-1359.
- [9] 沈飞, 陈超, 严如强. 奇异值分解与迁移学习在电机故障诊断中的应用[J]. 振动工程学报, 2017, 30(1):

- 118-126.
- SHEN Fei, CHEN Chao, YAN Ruqiang. Application of SVD and transfer learning strategy on motor fault diagnosis[J]. *Journal of Vibration Engineering*, 2017, 30(1): 118-126.
- [10] XIE Junyao, ZHANG Laibin, DUAN Lixiang, et al. On cross-domain feature fusion in gearbox fault diagnosis under various operating conditions based on transfer component analysis[C]//*Proceeding of International Conference on Prognostics and Health Management*, June 20-22, Ottawa, Canada, 2016: 1-6.
- [11] ZHANG Ran, TAO Hongyang, WU Lifeng, et al. Transfer learning with neural networks for bearing fault diagnosis in changing working conditions[J]. *IEEE Access*, 2017, 5: 14347-14357.
- [12] YAN Ruqiang, SHEN Fei, SUN Chuang, et al. Knowledge transfer for rotary machine fault diagnosis[J]. *IEEE Sensors Journal*, 2019, 20(15): 8374-8393.
- [13] 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.
- SHAO Haidong, ZHANG Xiaoyang, CHENG Junsheng, et al. Fault diagnosis of bearing using enhanced deep transfer auto-encoder[J]. *Journal of Mechanical Engineering*, 2020, 56(9): 84-90.
- [14] SHAO Shiyu, MCALEER S, YAN Ruqiang, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(4): 2446-2455.
- [15] CHEN Zhuyun, KONSTANTINOS G, LI Weihua. Intelligent fault diagnosis for rotary machinery using transferable convolutional neural network[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 339-349.
- [16] GANI Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. *Journal of Machine Learning Research* 2017, 17(1): 2096-2030.
- [17] LU Weining, LIANG Bin, CHENG Yu, et al. Deep model based domain adaptation for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2016, 64(3): 2296-2305.
- [18] WEN Long, GAO Liang, LI Xingyu. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2017, 49(1): 136-144.
- [19] 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.
- LEI Yaguo, YANG Bin, DU Zhaojun, et al. Deep transfer diagnosis method for machinery in big data era[J]. *Journal of Mechanical Engineering*, 2019, 55(7): 1-8.
- [20] ZHANG Bo, LI Wei, TONG Zhe, et al. Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks[J]. *IEEE Access*, 2018, 6: 66367-66384.
- [21] WANG Xu, SHEN Changqing, XIA Min, et al. Multi-scale deep intra-class transfer learning for bearing fault diagnosis[J]. *Reliability Engineering & System Safety*, 2020, 202: 107050-107056.
- [22] HAN Te, LIU Chao, YANG Wenguang, et al. A novel adversarial learning framework in deep convolutional neural network for intelligent diagnosis of mechanical faults[J]. *Knowledge-Based Systems*, 2019, 165: 474-487.
- [23] YANG Bin, LEI Yaguo, JIA Feng, et al. An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings[J]. *Mechanical Systems & Signal Processing*, 2019, 122: 692-706.
- [24] LI Xiang, ZHANG Wei, DING Qian. Multi-layer domain adaptation method for rolling bearing fault diagnosis[J]. *Signal Processing*, 2019, 157: 180-197.
- [25] ZHU Jun, CHEN Nan, SHENG Changqing, et al. A new deep transfer learning method for bearing fault diagnosis under different working conditions[J], *IEEE Sensors Journal*, 2019, 20(15): 8394-8402.
- [26] GOODFELLOW I, POUGET J, MIRZA M, et al. Generative adversarial networks[C]//*Annual Conference on Neural Information Processing Systems*, December 8-13, Montreal, Canada, 2014: 2672-2680.
- [27] SAITO K, WATANABE K, USHIKU Y, et al. Maximum classifier discrepancy for unsupervised domain adaptation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, June 18-23, Utah, USA, 2018: 3723-3732.
- [28] ZHANG Wei, LI Chuanghao, PENG Gaoliang, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. *Mechanical Systems & Signal Processing*, 2017, 100: 439-453.

- [29] PAN Jun, ZI Yanyang, CHEN Jinglong, et al. LiftingNet: a novel deep learning network with layerwise feature learning from noisy mechanical data for fault classification[J]. IEEE Transactions on Industrial Electronics, 2017, 65(6): 4973-4982.
- [30] HUANG Wenyi, CHENG Junsheng, YU Yang, et al. An improved deep convolutional neural network with multi-scale information for bearing fault diagnosis[J]. Neurocomputing, 2019, 359: 77-92.
- [31] MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.

作者简介: 陈祝云, 男, 1990 年出生, 博士后。主要研究方向为机械信号处理、基于深度学习和迁移学习的设备故障诊断与预示。

E-mail: mezychen@scut.edu.cn

李巍华(通信作者), 男, 1973 年出生, 博士, 教授, 博士研究生导师。主要研究方向为智能驾驶环境感知、设备智能维护、故障预测与健康管理以及车辆 NVH 性能测试与诊断。

E-mail: whlee@scut.edu.cn