

基于改进域对抗网络的齿轮箱跨工况故障诊断^{*}贾宝惠¹ 苏家成¹ 高 源²

(1. 中国民航大学交通科学与工程学院 天津 300300; 2. 中国民航大学安全科学与工程学院 天津 300300)

摘 要: 针对不同工况下采集的齿轮箱振动数据特征分布不一致和噪声成分影响迁移效果的问题,本文提出了一种结合注意力机制的域对抗迁移网络的深度迁移学习故障诊断方法。首先,将带标签的振动信号和未带标签的振动信号通过固定长度的数据分割方法构建成数据集;其次,为减少噪声样本带来的负迁移影响,采用卷积注意力模块(CBAM)以及判别损失项辅助特征提取器提取具有区分度的特征,加强分类决策边界;最后,为解决数据特征分布不一致的问题,采用多核最大均值差异(MK-MMD)对齐源域和目标域的全局分布,并利用对抗机制对齐两域的子领域分布。在公开的变工况齿轮箱故障数据集上进行试验验证,结果表明,所提方法的平均识别准确率达到 96.25%以上,并与其他诊断方法的对比分析,验证了所提方法的有效性和优越性。

关键词: 判别损失项;卷积注意力模块;域对抗迁移网络;迁移学习;故障诊断

中图分类号: TH17;TN0 **文献标识码:** A **国家标准学科分类代码:** 460

Gearbox fault diagnosis across different operating conditions
based on improved domain-adversarial networkJia Baohui¹ Su Jiacheng¹ Gao Yuan²

(1. School of Transportation Science and Engineering, Civil Aviation University of China, Tianjin 300300, China;

2. School of Safety Science and Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: To address the issues of inconsistent feature distributions and the influence of noise components on the transfer effect in gearbox vibration data collected under different operating conditions, this paper proposes a deep transfer learning fault diagnosis method that integrates an attention mechanism with domain adversarial transfer networks. First, labeled and unlabeled vibration signals are constructed into datasets using a fixed-length data segmentation method. Second, to reduce the negative transfer impact caused by noisy samples, a convolutional block attention module (CBAM) and a discriminative loss term are used to assist the feature extractor in extracting discriminative features and enhancing the classification decision boundary. Finally, to solve the problem of inconsistent data feature distributions, a multi-kernel maximum mean discrepancy (MK-MMD) is employed to align the global distributions of the source and target domains, and an adversarial mechanism is used to align the subdomain distributions between the two domains. Experimental validation on a publicly available variable-condition gearbox fault dataset demonstrates that the proposed method achieves an average recognition accuracy of over 96.25%. A comparison with other diagnostic methods further validates the effectiveness and superiority of the proposed approach.

Keywords: discriminative loss; convolutional block attention module; domain-adversarial neural network; transfer learning; fault diagnosis

0 引 言

齿轮箱是旋转机械的核心部件,在精密仪器、航空航天及汽车制造等领域中发挥关键作用。随着齿轮箱向复杂化和高可靠性方向发展,准确、高效的故障诊断是保障可靠性

和经济性的前提^[1-2]。传统故障诊断方法一般以信号处理和人工进行特征提取为主要手段。然而,由于齿轮箱动力学特性复杂、故障形式多样以及振动信号存在非线性和高噪声,故障诊断技术在齿轮箱的应用面临挑战^[3-4]。

近年来,基于深度学习的方法在智能故障诊断上取得

收稿日期:2024-11-27

^{*} 基金项目:国家自然科学基金委员会-中国民用航空局联合研究基金(U2033209)、中央高校基本科研业务费(KJZ53420240023)项目资助

了显著成果,但大部分方法基于训练集和测试集数据分布一致的假设。然而,在实际工业场景中,由于齿轮箱转速、负载及传感器监测部位的差异,训练和测试数据之间往往存在显著的分布差异,导致模型性能下降^[5-8]。迁移学习近年来成为人工智能领域的突破性研究方向,致力于将源域中学到的知识应用于与目标域相关的任务^[9-10]。相关研究中,现有的齿轮箱跨工况故障诊断方法主要集中在特征对齐和域自适应方面。Xu 等^[11]提出了一种通过特征变换矩阵将源域和目标域的特征映射到公共空间的跨域迁移学习方法,并结合传递分量分析技术缓解目标域数据稀缺性的问题。Zhang 等^[12]则提出了类子域自适应网络,通过优化源域和目标域之间的特征对齐,进一步提升了模型的迁移能力。此外,Guo 等^[13]提出了基于深度卷积迁移学习网络的方法,而 Jiao 等^[14]则提出了残差联合适应对抗网络模型,这些方法通过自动学习特征来提升跨工况故障诊断的准确性和效率。

域对抗网络(domain-adversarial neural network, DANN),这是一种经典的域适应故障诊断方法。DANN 的基本思想是通过对抗训练使源域和目标域的特征分布对齐,从而提升模型在目标域上的性能。尽管 DANN 模型在多种迁移学习任务中取得了显著效果,但其仍存在一些局限性:DANN 主要通过全局域对齐来应对源域与目标域数据分布的不一致性。然而,在实际应用中,跨工况的数据不仅在全局分布上存在差异,还可能在子域特征上有显著变化,这将影响模型的精度和泛化能力。

为了克服上述问题,徐嘉杰等^[15]引入了 Wasserstein 距离对 DANN 进行改进,从而提升了轴承故障诊断中的迁移学习效果。王健等^[16]则结合 DANN 与宽卷积核卷积神经网络提出了一种新的网络故障诊断模型,进一步改善了模型性能。然而,尽管这些改进方法在一定程度上缓解了 DANN 的缺陷,但现有的迁移学习方法在工业应用中仍面临若干挑战:一方面,多数方法仅关注对齐全局域分布,未充分重视子域的对齐,无法充分整合相同故障类型的子域特征,从而影响模型精度。另一方面,噪声样本在迁移过程中被视为同等重要,其产生了负迁移的影响,从而导致决策边界模糊。

因此,本文引入 DANN 模型进行齿轮箱跨工况故障诊断,并做出如下改进:1)利用 Swin Transformer 和卷积注意力模块(convolutional block attention module, CBAM)实现关键特征提取和样本的动态加权,抑制含噪样本表达;2)通过判别性损失函数增强类内聚合性和类间分离性,加强决策边界;3)利用域对抗网络的对抗机制,通过联合损失函数实现全局和子领域的分布对齐。本文在 PHM2009 工业齿轮箱数据集上进行了实验验证,结果表明,该方法在多种工况迁移任务中显著提高了诊断精度,解决了因数据分布差异导致的故障识别难题,进一步验证了模型的有效性和优越性。

1 理论基础

1.1 领域自适应

域适应(domain adaptation, DA)是迁移学习的一个重要分支领域,它的核心思想是通过源域和目标域数据进行对齐,减少域间分布差异,从而使得在源域上训练的模型能够在目标域中有效应用^[17]。域适应方法又根据目标域是否具有标签又分为有监督域适应和无监督域适应。因为无监督域适应更符合工业情况下获得带标签数据困难的实际背景,所以本文选择进行无监督域适应下的齿轮箱故障诊断研究。

无监督域适应通常给定有标签的源域数据集 $D_s = \{(x_i, y_i)\}_{i=1}^{N_s}$ 和无标签的目标域数据集 $D_t = \{(x_j)\}_{j=1}^{N_t}$, 源域和目标域的联合概率分布往往不同,即 $P_s(X) \neq P_t(X)$ 。无监督域适应要求能够建立一个可以对齐源域和目标域分布差异的模型,实现模型在目标域上也有泛化能力,提高模型的实际应用性能。目前在域适应研究中,往往注重于源域和目标域整体的分布对齐,但无论是源域或目标域,其子域分布都不同,忽视子域分布问题往往会造成域混叠现象。

最大均值差异(maximum mean discrepancy, MMD)是在域适应中一种衡量两个概率分布 p 和 q 差异的统计量^[18]。它在域适应中常被用来度量源域和目标域之间的分布差异,并通过最小化这种差异来帮助模型进行全局域适应,学习领域不变的特征。其计算公式为:

$$MMD^2(p, q) = \left\| \frac{1}{m} \sum_{i=1}^m \phi(x_i) - \frac{1}{n} \sum_{j=1}^n \phi(y_j) \right\|_H^2 \quad (1)$$

式中: $\phi(\cdot)$ 是将样本映射到再生核希尔伯特空间 H 中的特征映射。

多核最大均值差异(multi-kernel maximum mean discrepancy, MK-MMD)基于简单的 MMD 发展而成。MMD 是源域和目标域使用一个相同的核函数 $k(\cdot, \cdot)$ 嵌入到一个再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS)中,然后通过衡量两者的均值嵌入的差异来判定它们的分布是否相同。设均值嵌入分别为 $\phi(p)$, $\phi(q)$, MMD 中构造最大化 MMD 损失,在弱分布假设前提下,通过优化可达到最优传递概率,但不利于在应用中进行泛化。MK-MMD 中提出将同一个样本集嵌入多个核函数,形成单个损失。与 MMD 类似,对于两种概率分布 p 和 q , MK-MMD 定义为 p 和 q 在再生核希尔伯特空间中均值嵌入之间的距离,其数学表达式为:

$$L_{MK-MMD} = d_k^2(p, Q) = \|E_p[\phi(x^p)] - E_q[\phi(x^q)]\|_{\mathcal{H}_k}^2 \quad (2)$$

式中:均值 E_p 视为 $q(x)=0$ 时,分布的特征均值。

与普通单核的 $k(\cdot, \cdot)$ 形式的特征嵌入 $\phi(x^p) = \phi(x^q)$, 在这里设置为多个不同的核函数,如式(3)所示。

$$K = \sum_{i=1}^m \beta_i k_i, \sum \beta_i = 1, \beta_i > 0, \forall i \quad (3)$$

式中: β_i 表示权重, 对其增加的权重选择适当的多核合适结构。

1.2 域对抗神经网络 DANN

领域对抗神经网络 (domain-adversarial neural network, DANN) 是一种基于对抗性思想来进行域适应的迁移学习方法。DANN 主要由特征提取器、领域判别器和标签分类器组成。DANN 网络的损失主要由分类损失 L_g 和领域分类损失 L_d 构成:

$$L_g = \log \frac{1}{G_y[G_f(x)]_{y_i}} \quad (4)$$

$$L_d = d_i \log \frac{1}{G_d[G_f(x_i)]} + (1 - d_i) \log \frac{1}{G_d[G_f(x_i)]} \quad (5)$$

式中: $G_f(x_i)$ 为样本经特征提取器得到的特征表示; $G_y[\cdot]$ 和 $G_d[\cdot]$ 分别为标签分类器和领域判别器得到的分类结果; d_i 为领域的标签。

1.3 特征提取器

本文引入 Swin-transformer^[19] 架构作为提出的跨工况故障诊断迁移学习模型的特征提取模块。相比于残差网络 Resnet34 等卷积网络, Swin-transformer 在特征提取能力上能够在不同层次上提取细粒度到粗粒度的特征, 获得全局域不变特征, 在域适应的场景下, 其多尺度特征提取和全局特征重用能力能够在源域和目标域分布差异较大时, 帮助模型更好地实现领域特征对齐。特征提取模块由 Patch Partition 层、Linear Embedding 层和 Swin Transformer Block 模块组成。故障特征图进入特征提取模块后, 首先会在 Patch Partition 层被划分成固定大小的特征块并被展平成特征向量, 然后由 Linear Embedding 层进行线性变化, 使得输入特征可以被 Transformer Block 模块处理, 特征提取器的具体结构如图 1 所示, 其中将层叠 4 个 Swin Transformer Block 模块。




图 1 Swin-transformer 特征提取器

Fig. 1 Swin-Transformer feature extractor

在数据预处理阶段, 预先挖掘出故障信号中深层次故障特征对后续输入至特征提取网络进行特征提取至关重要。相比于直接使用原始故障信号作为输入, 时频谱图能够显著增强故障信号中频率特征的可区分性和抑制干扰噪声频率成分, 因此本文选取短时傅里叶变换 (short time

Fourier transform, STFT) 进行样本的时频谱图转换, 其公式为:

$$STFT_x(t, f) = \int_{-\infty}^{+\infty} x(t) g(t - \tau) e^{-j2\pi f \tau} d\tau \quad (6)$$

式中: $g(t - \tau)$ 为窗函数, $STFT_x(t, f)$ 为短时傅里叶变换的结果。

1.4 卷积注意力模块

卷积注意力模块 (CBAM) 是一种轻量级、可嵌入的注意力模块, 通过结合通道和空间注意力机制来增强特征, 旨在强调有用特征和抑制无用特征来提升神经网络的特征表示能力^[20]。通过使用 CBAM 对样本进行权重计算, 可以实现对样本特征的自适应加权, 抑制含噪特征在迁移时可能带来的负面影响, 从而提高模型迁移能力。CBAM 注意力模块具体实现方法如图 2 所示。




图 2 卷积注意力模块

Fig. 2 Convolutional block attention module

1) 通道注意力模块

通道注意力模块通过全局池化来捕捉特征图在通道维度上的重要性。具体步骤为:

(1) 全局池化:

$$F_{avg} = GAP(F), F_{max} = GMP(F) \quad (7)$$

(2) 共享全连接层:

$$M_{avg} = MLP(F_{avg}), M_{max} = MLP(F_{max}) \quad (8)$$

共享网络的结构为:

$$MLP(\cdot) = W_1 ReLU(W_0(\cdot)) \quad (9)$$

$$W_0 \in R^{c_r \times c}, W_1 \in R^{c \times \frac{c}{r}}$$

其中, r 是压缩率, 通常为 16。

(3) 融合:

$$M_{channel} = \sigma(M_{avg} + M_{max}) \quad (10)$$

其中, σ 表示 Sigmoid 激活函数。

(4) 重加权:

$$F_{channel} = M_{channel} \otimes F \quad (11)$$

2) 空间注意力模块

空间注意力模块通过对特征图在空间维度上的重要性

进行建模。具体步骤为:

(1)池化操作:

$$F_{\text{spatial}}^{\text{avg}} = \text{AvgPool}(F_{\text{channel}}) \quad (12)$$

$$F_{\text{spatial}}^{\text{max}} = \text{MaxPool}(F_{\text{channel}})$$

(2)特征融合:

$$F_{\text{concat}} = [F_{\text{spatial}}^{\text{avg}}; F_{\text{spatial}}^{\text{max}}] \quad (13)$$

(3)卷积操作:对连接后的特征图进行一次卷积操作,生成一个单通道的空间注意力图。

(4)重加权:将输入特征图的每个像素点与对应的空间注意力值相乘,实现空间注意力的重加权。

1.5 判别性损失

为获得更清晰的决策边界,加强对齐域特征分布效果,本文引入了一种判别损失计算模块。判别损失模块是为了通过优化源域特征的分布,使其在类别内部具有更高的一致性,而在类别之间具有更大的分散性。这种特征区分度的提升可以进一步促进目标域数据对齐后的特征区分效果。判别性损失函数的数学表达式为:

$$L_c = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s(\cos(\theta_{y_i}) - m)}}{\sum_{j=1}^C e^{s(\cos(\theta_j) - \delta_j)}} \quad (14)$$

式中: N 和 C 分别为样本数和类别数; θ_{y_i} 为样本 i 与类别中心的角; m 为间隔参数,用于增强类间分离; s 为尺度参数; δ_j 为类别偏置参数。

1.6 GoogleNet 分类器

GoogleNet^[21] 通过使用 Inception 块在保证性能的前提下,减少参数数量的同时提升了识别精度,避免了加深网络层数导致的训练困难问题。考虑到实际工业场景下,齿轮箱数据集样本量少的特点,为了精简参数数量和加快训练速度,本文在 GoogleNet 分类器上,做了以下改进:

1) 将 Inception 块中的卷积核进行优化,组合使用 1×1 卷积和 3×3 卷积,先采用 1×1 卷积减少通道数,然后使用 3×3 的卷积进行处理,减少模型参数以适应小规模数据集,同时显著降低训练时间。

2) 引入 TReLU 激活函数,结合可训练参数 α 和 β 增强激活函数对不同数据分布的适应能力,加快收敛速度。TReLU 激活函数的公式为:

$$\begin{aligned} TReLU(x) &= e^{\alpha} ReLU(x) + \beta \\ ReLU(x) &= \max(0, x) \end{aligned} \quad (15)$$

式中: x 为神经元的输入值; e 为自然常数。

2 齿轮箱故障诊断模型

2.1 改进 DANN 迁移学习模型

本文提出的齿轮箱故障诊断迁移模型具体结构如图 3 所示。相较于传统的 DANN 模型,本文主要对其特征提取模块、标签分类器、域对齐器进行了改进,并加入了 CBAM 模块和判别损失项,在图 3 中以红色虚线区域标注。

本文提出的改进域对抗迁移网络模型的总体优化目

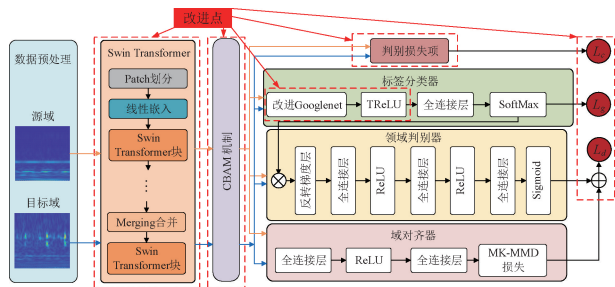


图 3 齿轮箱故障诊断迁移模型架构

Fig. 3 The architecture of gearbox fault diagnosis transfer learning model

标为:

$$\begin{cases} \max_{F, G} -L_c + \lambda_1 L_d - \lambda_2 L_g - L_{MK-MMD} \\ \min_D L_d \end{cases} \quad (16)$$

式中: F 为特征提取器, G 为标签分类器, D 为领域判别器。 λ_1 和 λ_2 为权重系数。模型通过最大化 L_g 、 L_c 和 L_{MK-MMD} 来更新优化标签分类器和特征提取器的参数,以及通过最小化 L_d 更新优化领域判别器参数。

2.2 故障诊断流程

在数据预处理阶段,对采集到的齿轮箱振动信号进行预处理。通过使用 STFT 方法将振动信号样本转换为时频图,并按照无监督学习的范式,将数据集划分为带标签信息的源域数据集和无标签信息的目标域数据集,并将一部分目标域数据集作为测试集。将源域数据和目标域数据输入至 Swin Transformer 特征提取器和 CBAM 模块中,提取深层次的故障特征表示;随后,进行判别性特征损失项计算,这些特征会被传递至域对抗网络中,用于分别计算 L_c 、 L_d 、 L_g 和 L_{MK-MMD} ,联合损失函数项会在对抗训练时,增强模型的决策边界和域对齐效果;在模型收敛后,使用训练好的模型对无标签的目标域数据进行故障诊断。故障诊断流程如图 4 所示。

3 实验

3.1 实验数据集选取

为验证本文提出的基于迁移学习的跨工况齿轮箱故障诊断方法的有效性,实验选用 PHM2009 数据挑战赛提供的工业齿轮箱数据集进行分析^[22]。该齿轮箱由输入轴、空转轴、输出轴及两对齿轮副组成,其结构如图 5 所示。实验中模拟了 8 种故障模式,并在 35、40、45 和 50 Hz 4 种转速工况下进行测试。齿轮箱输入轴端安装了加速度传感器,用于采集振动信号,每种工况下采样 4 s,采样频率为 66.67 kHz。

3.2 数据预处理和实验设置

为模拟齿轮箱在高速与低速之间运行的实际工况,基于 PHM2009 数据集设计了 12 种迁移任务。将 35、40、45、50 Hz 的转速工况分别表示为 0、1、2、3,从而构建 12 个迁

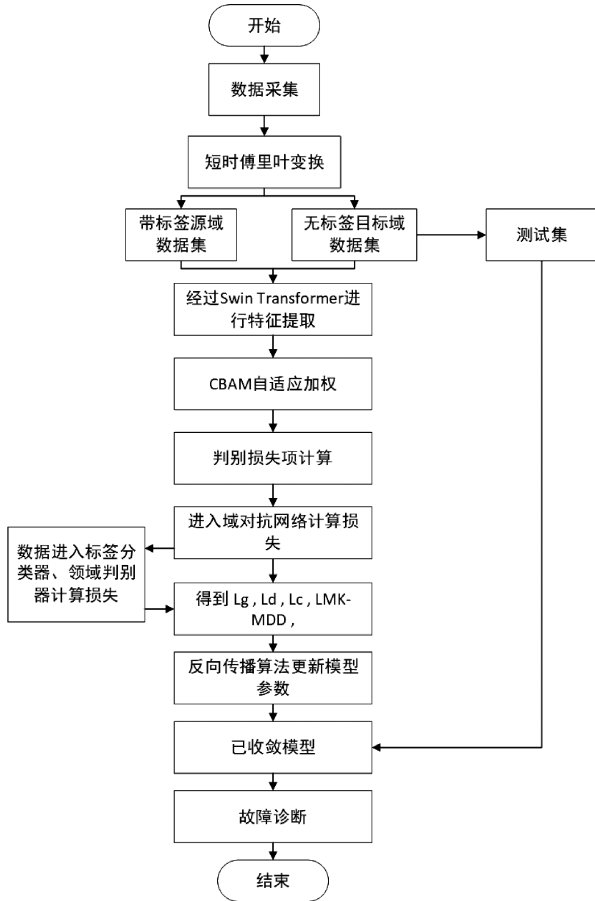


图4 本文提出的迁移学习故障诊断流程

Fig. 4 Fault diagnosis based on proposed transfer learning model

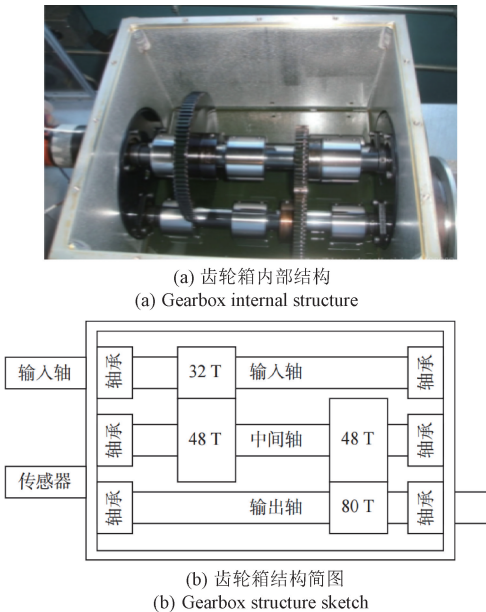


图5 PHM2009数据集对应的齿轮箱结构

Fig. 5 Gearbox structure corresponding to the PHM2009 dataset

移任务:0-1、0-2、0-3、1-0、1-2、1-3、2-0、2-1、2-3、3-0、3-1 和

3-2。例如,任务 0-1 表示源域数据来自 35 Hz 工况,目标域数据来自 40 Hz 工况。

为了突出全局故障特征,将振动信号转换为时频图作为模型输入。在每种工况的不同故障模式下,振动信号按照每 1 024 个采样点划分为一个样本,每种故障模式包含 100 个样本。图 6 展示了同一工况,不同故障模式下生成的时频图像。

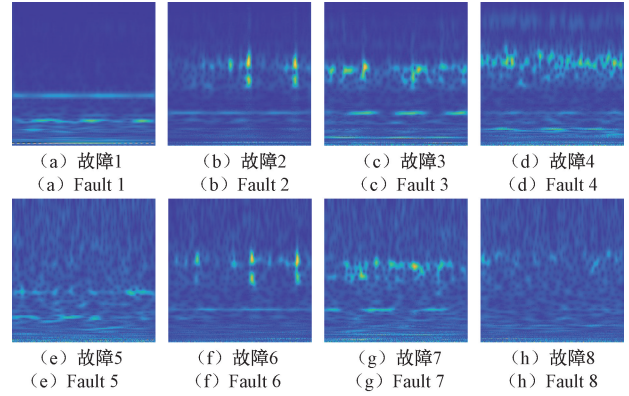


图6 不同故障模式下的齿轮箱时频图

Fig. 6 Time-frequency plots of the gearbox under different fault modes

在迁移任务的训练中,BatchSize 设置为 16,采用 Adam 优化器,初始学习率为 0.01,每次以 0.000 5 衰减,训练迭代 50 次,通过反向传播优化模型参数。

3.3 迁移诊断实验结果对比分析

1) 迁移诊断效果对比实验

为验证本文提出模型在齿轮箱故障迁移诊断中的有效性,基于 PHM2009 故障数据集,将本文模型与以下 4 种方法进行对比:深度域混淆网络(deep domain confusion, DDC)^[23]、深度自适应网络(deep adaptation networks, DAN)^[24]、深度子域自适应网络(deep subdomain adaptive networks, DSAN)^[25]以及域对抗网络(domain-adversarial neural network, DANN)^[26]。其中,DDC 模型通过单核 MMD 对齐源域和目标域的边缘分布,以实现跨域适应;DAN 则在 DANN 的基础上,在多个层次上引入了多核 MMD 进行域对齐,以更好地解决源域和目标域之间的分布差异问题;DSAN 则进一步细化了子域对齐,优化了域适应效果,以应对不同子域特征差异;DANN 则通过对抗训练机制对源域和目标域进行域适应,解决了源域和目标域在特征分布上的不一致问题。DDC、DAN、DSAN 和 DANN 是目前在跨域学习领域广泛应用的模型,能够代表域适应领域中的经典方法。

为了直观展示本文提出的迁移故障诊断模型在迁移任务中的分类性能,本文通过计算多分类混淆矩阵,对齿轮箱变工况下的迁移诊断任务进行分析。混淆矩阵能够以矩阵的形式直接显示所有故障类型间的真实标签与模型预测标签之间的关系。其中,矩阵的纵轴表示真实标签,矩阵的横

轴表示预测标签,主对角线上的值为各故障类型被正确分类的数量,其余值表示被误分类为其他故障类型的数量。以迁移任务 0-1 为例,本文提出的模型与 DDC、DAN、DSAN 和 DANN 的混淆矩阵结果如图 7 所示。

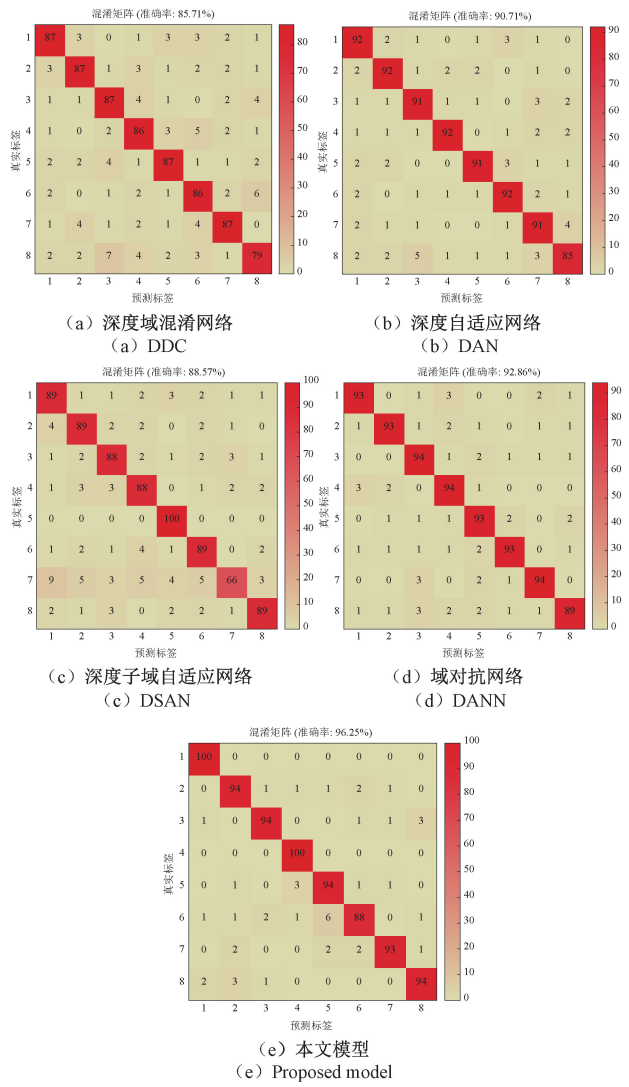


图 7 迁移任务 0-1 中不同迁移学习故障诊断混淆矩阵
Fig. 7 Confusion matrices of fault diagnosis with different transfer learning tasks in task 0-1

从图中可以看出,本文提出的模型分类准确率达到 96.25%,显著优于其他方法(85.71%、90.71%、88.57%和 92.86%)。主对角线值较高,表明对各故障类型的分类效果更加准确,部分类别(如 1、4 和 7)分类率达到 100%。此外,非主对角线上的误分类比例显著减少,体现了模型对噪声和分布差异的强适应性。

以上所有迁移学习方法在每个迁移任务中都将进行十次实验,取 10 次实验平均准确率为最终准确率。为确保对比实验的可靠性,所有网络中的特征提取模块均采用与本文方法一致的特征提取块,且均采用相同的实验设备、

BatchSize 与学习率衰减策略等相关参数。通过在 PHM2009 齿轮箱数据集上实验,得到 5 种迁移方法在 12 种迁移任务中的故障诊断准确率如表 1 所示。

表 1 PHM2009 齿轮箱迁移诊断准确率结果

Table 1 Transfer diagnosis accuracy results for the PHM2009 gearbox dataset

迁移任务	DDC	DAN	DSAN	DANN	本文模型
0-1	85.71	90.71	88.57	92.86	96.25
0-2	91.25	81.25	90.50	92.63	95.38
0-3	88.13	96.5	94.375	93.75	94.13
1-0	74.25	92.5	89.75	91.38	98.63
1-2	84.00	89.13	87.63	90.13	95.25
1-3	80.63	94.25	92.50	93.63	97.00
2-0	76.25	88.13	85.50	89.25	94.88
2-1	79.63	91.25	89.38	90.75	96.25
2-3	82.38	94.50	93.13	95.00	97.50
3-0	77.38	95.13	91.625	92.88	96.38
3-1	80.25	92.38	90.5	93.25	95.75
3-2	84.25	96.13	94.88	95.38	98.25
平均	82.01	91.82	90.70	92.57	96.30

从表 1 中可以看出,本文提出的模型在所有迁移任务中均表现出最优的分类准确率,平均值达到 96.30%,显著优于对比方法 DDC(82.01%)、DAN(91.82%)、DSAN(90.70%)和 DANN(92.57%)。尤其在任务 1-0 和 2-3 中,本文模型分别取得 98.63%和 97.50%的准确率,说明在实际工业场景下,面对不同工况条件带来的数据分布差异和噪声干扰问题,本文模型能够有效地适应目标域的数据分布变化,克服了数据分布不一致所带来的负面影响。

2) 结果可视化分析

通过对结果进行可视化可以直观地比较本文模型和对比模型在源域和目标域的对齐效果。t 分布领域嵌入法(t-distributed stochastic neighbor embedding, t-SNE)是常见的可视化方法之一,使用 t-SNE 对迁移任务 0-1 中各个模型所提取的特征进行可视化,不同模型的可视化结果如图 8 所示,其中不同颜色和符号分别表示齿轮箱的不同故障模式,实心符号和空心符号分别代表源域数据和目标域数据。

从图 8 中可以看出,本文提出的迁移故障诊断模型得到了较好的分布对齐效果,特征簇紧凑且可区分度较高。不同的故障特征在二维坐标中有明显的区分度,而相同故障特征则在二维坐标中聚集在一起。源域与目标域各个子类特征分布较为吻合,相同类别源域与目标域特征分布对齐效果较好,不同类别特征之间的分类边界明显,未出现子域混叠的现象。相比之下,其他方法在特征分布上仍存在一定混杂,特征区分度较低。

由图 8 可知,本文提出的迁移故障诊断模型在分布对齐上表现优异,特征簇紧凑且区分度高。不同故障特征在二维空间中明显分离,相同故障特征聚集在一起,且源域与目标域子类特征分布高度吻合,分类决策边界清晰,无子域




图 8 T-SNE 可视化 PHM2009 齿轮箱数据集的 0-1 任务

Fig. 8 T-SNE visualization of the PHM2009 gearbox dataset for Task 0-1

混叠现象。相比之下,其他方法特征分布存在混杂,区分度较低。

3) 消融实验

为验证判别性特征和改进 DANN 等模块的有效性,本文对提出的迁移学习故障诊断模型进行了消融实验。以模型 DANN 为基础,本文主要的改进有:Swin Transformer、判别性特征、CBAM 以及改进的 Googlenet 4 处。基于基准模型 DANN(实验 1)逐步改进,设计了 8 组实验,结果如表 2 所示。

表 2 消融实验结果

Table 2 Ablation experiment results					
实验	Swin Transformer	判别性损失	CBAM	改进 Googlenet	准确率/%
1	—	—	—	—	80.24
2	✓	—	—	—	82.23
3	—	✓	—	—	81.15
4	—	—	✓	—	80.89
5	—	—	—	✓	86.78
6	✓	✓	—	—	93.55
7	✓	✓	✓	—	94.31
8	✓	✓	✓	✓	97.50

实验结果显示,不同模块的引入对模型性能有显著影响。实验 2 中加入 Swin Transformer 后,准确率提升至 82.23%,验证了其在特征提取方面的有效性;实验 3 引入判别性损失,准确率提升至 81.15%,表明该模块能增强模型的分类能力;实验 4 中加入 CBAM 模块,准确率提升至 80.89%,通过特征加权机制进一步优化了模型精度;实验 6 中结合 Swin Transformer 和改进 Googlenet,准确率达到 93.55%,显示两者在特征提取和结构优化上的协同效果;实验 8 综合引入所有模块后,准确率达到最高值 97.50%,相比基础模型提升 17.26%,表明本文模型能够显著提升

迁移任务中的故障分类性能,且效果优于单一改进方案。

4) 源域样本大小影响

在实际工业场景下,不仅要面对数据分布不同而导致的模型精度差的问题,还面临着故障数据标注困难的问题,这造成了带标签的数据非常稀缺,因此本实验将探讨源域数据集的样本数量大小对本文模型性能的影响。

首先,设置不同大小的源域数据集,选取样本数量分别为实验一中样本数量的 10%~100%,间隔 10%,使用这些不同数量的样本进行模型训练,并保持目标域数据集比例和模型结构一致。图 9 直观说明了在不同数量比例下,模型在迁移任务 0-1 的诊断识别率。

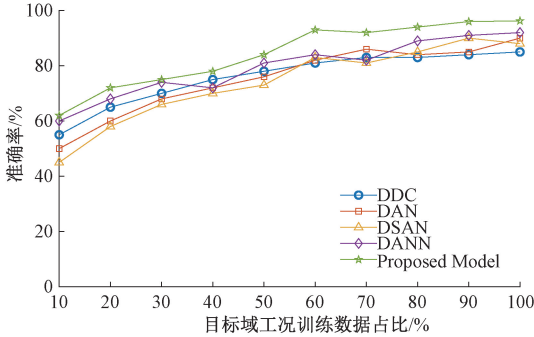


图 9 不同源域样本数据量下迁移诊断准确率变化
Fig. 9 Variation of transfer diagnosis accuracy with different source domain sample sizes

从图 9 中可以看出,当样本数量比例为 100% 时,诊断准确率最高为 96.25%,这说明如果能获得足量的带标签数据,模型就可以获得更好的迁移效果。当样本数量比例降低时,模型的诊断识别率逐渐降低,但相比于其他模型,本文模型在 60% 比例数据集上仍然可以获得 92.50% 的准确率,均高于其他模型的识别率。本实验表明了本文模型在使用有限数量的带标签数据进行训练时,模型仍能够充分挖掘源域的潜在信息,实现较好的迁移效果,仍可以对齿轮箱不同故障类型进行有效地诊断识别,更符合实际工业场景下的应用情形。

4 结 论

本文提出了一种结合注意力机制的改进域对抗迁移网络的齿轮箱故障诊断方法,以解决不同工况下齿轮箱振动数据特征分布不一致及噪声干扰难以去除的问题。通过 Swin Transformer 进行全局特征提取,引入卷积注意力模块(CBAM)、判别损失项增强特征的自适应表达能力和提升特征的区别性,同时结合改进的对抗学习模型进一步优化迁移过程,成功地实现了特征的区别性提取与源域和目标域的分布对齐。在公开的变工况齿轮箱故障数据集上的实验验证表明,所提方法的平均识别准确率达到 96.30%,并在对比分析中显示出其优越性和可靠性。

尽管所提出的方法在齿轮箱故障诊断方面取得了不错

的效果,但在更复杂、多变的工况下仍存在进步空间。此外,模型的大量的超参数也对设备的性能提出了高要求。因此,未来的研究将围绕提高模型的自适应性及轻量化研究展开,以实现更广泛的故障诊断应用。

参考文献

[1] 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 Y G, YANG B, DU ZH J, et al. Deep transfer diagnosis method for mechanical equipment faults under big data[J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.

[2] 郭海科,赵小强. 采用动态校准与联合分布对齐的旋转机械跨工况故障诊断[J]. 仪器仪表学报, 2024, 45(8): 32-44.
GUO H K, ZHAO X Q. Rotating machinery fault diagnosis across working conditions using dynamic calibration and joint distribution alignment[J]. Chinese Journal of Scientific Instrument, 2024, 45(8): 32-44.

[3] 文成林,吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报, 2020, 42(1): 234-248.
WEN CH L, LYU F Y. Review of fault diagnosis methods based on deep learning [J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248.

[4] 陈仁祥,杨星,胡小林,等. 深度置信网络迁移学习的行星齿轮箱故障诊断方法[J]. 振动与冲击, 2021, 40(1): 127-133.
CHEN R X, YANG X, HU X L, et al. Planetary gearbox fault diagnosis method based on deep belief network and transfer learning [J]. Vibration and Shock, 2021, 40(1): 127-133.

[5] 石明宽,丁传仓,王锐,等. 面向变工况下工业流数据故障诊断的持续迁移学习系统[J]. 仪器仪表学报, 2024, 45(4): 10-16.
SHI M K, DING CH C, WANG R, et al. Continuous transfer learning system for fault diagnosis of industrial stream data under variable operating conditions [J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 10-16.

[6] 李剑君,李昂,王勇飞,等. 变工况条件下三相异步电机匝间短路故障诊断[J]. 国外电子测量技术, 2024, 43(3): 162-167.
LI J J, LI ANG, WANG Y F, et al. Diagnosis of interturn short circuit fault in three-phase asynchronous motor under variable operating conditions [J]. Foreign Electronic Measurement Technology, 2024, 43(3): 162-167.

[7] 路飞宇,佟庆彬,姜学东,等. 一种基于条件度量迁移学习的机械故障诊断可解释方法[J]. 仪器仪表学报, 2024, 45(7): 250-262.
LU F Y, TONG Q B, JIANG X D, et al. Interpretable method for mechanical fault diagnosis based on condition metric transfer learning[J]. Chinese Journal

- of Scientific Instrument, 2024, 45(7): 250-262.
- [8] 蔡改贫, 肖文聪, 黄耀锋. 领域对抗与分类差异的变工况球磨机负荷识别[J]. 电子测量与仪器学报, 2023, 37(12): 67-75.
- CAI G P, XIAO W C, HUANG Y F. Load identification of ball mill under off-design conditions based on domain confrontation and classification difference[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12): 67-75.
- [9] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究[J]. 电子测量与仪器学报, 2023, 37(7): 205-212.
- WANG L, HE K, LI Z SH, et al. Transfer learning based on BiLSTM-Attention research on fault identification methods for variable operating conditions[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7): 205-212.
- [10] 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. Rapid fault diagnosis of rolling bearings based on transfer learning and deep residual networks[J]. Vibration and Shock, 2022, 41(3): 154-164.
- [11] 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.
- [12] ZHANG L, LI H, CUI J, et al. Class subdomain adaptation network for bearing fault diagnosis under variable working conditions[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-17.
- [13] GUO L, LEI Y G, XING S B, 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.
- [14] JIAO J Y, ZHAO M, LIN J, et al. Residual joint adaptation adversarial network for intelligent transfer fault diagnosis [J]. Mechanical Systems and Signal Processing, 2020, 145: 106962.
- [15] 徐嘉杰, 沈艳霞. 基于改进 DANN 迁移学习的轴承寿命预测方法[J]. 化工自动化及仪表, 2023, 50(4): 493-499, 594.
- XU J J, SHEN Y X. Bearing life prediction method based on improved DANN transfer learning [J]. Chemical Engineering Automation & Instrumentation, 2023, 50(4): 493-499, 594.
- [16] 王健, 郭娜, 杨建伟, 等. 基于改进 DANN 和注意力机制的轴箱故障诊断方法[J]. 机床与液压, 2024, 52(16): 194-199.
- WANG J, WU N, YANG J W, et al. Fault diagnosis method for axle boxes based on improved DANN and attention mechanism[J]. Machine Tool & Hydraulics, 2024, 52(16): 194-199.
- [17] 李晶晶, 孟利超, 张可, 等. 领域自适应研究综述[J]. 计算机工程, 2021, 47(6): 1-13.
- LI J J, MENG L CH, ZHANG K, et al. Review of domain adaptation research [J]. Computer Engineering, 2021, 47(6): 1-13.
- [18] 吴佳敏, 王发令, 邹鹤敏, 等. 基于深度卷积迁移学习的机车齿轮箱故障诊断[J]. 机械设计与研究, 2023, 39(5): 82-88.
- WU J M, WANG F L, ZOU H M, et al. Fault diagnosis of locomotive gearboxes based on deep convolutional transfer learning [J]. Journal of Mechanical Design and Research, 2023, 39(5): 82-88.
- [19] 王国桢, 卢国杰, 王桂棠. 无人化起重装卸的目标物实例分割模型研究 [J]. 电子测量技术, 2023, 46(18): 139-146.
- WANG G ZH, LU G J, WANG G T. Instance segmentation model of uncertain object in unmanned lifting and handling scenarios [J]. Electronic Measurement Technology, 2023, 46(18): 139-146.
- [20] 张瑞博, 李凌均. 基于注意力机制与 Inception-ResNet 的轴承故障诊断方法 [J]. 电子测量技术, 2023, 46(21): 107-113.
- ZHANG R B, LI L J. Bearing fault diagnosis method based on attention mechanism and Inception-ResNet [J]. Electronic Measurement Technology, 2023, 46(21): 107-113.
- [21] 杨魏华, 阮爱国, 黄国勇. 基于预训练 GoogleNet 模型和迁移学习的齿轮箱故障检测方法[J]. 机电工程, 2024, 41(2): 262-270.
- YANG W H, RUAN AI G, HUANG G Y. Fault detection of gearboxes based on pre-trained GoogleNet model and transfer learning [J]. Mechanical & Electrical Engineering, 2024, 41(2): 262-270.
- [22] ZHANG X, XU Q, JIANG H, et al. Application of deep neural network in gearbox compound fault diagnosis[J]. Energies, 2023, 16: 4164.
- [23] TZENC E, HOFFMAN J, ZHANG N, et al. Deep domain confusion: Maximizing for domain invariance [J]. Computer Science, 2014. DOI: 10.48550/arXiv:1412.3474.
- [24] LI C, ZHANG S, QIN Y, et al. A systematic review of deep transfer learning for machinery fault diagnosis[J]. Neurocomputing, 2020, 407: 121-135.
- [25] ZHU Y CH, ZHUANG F ZH, WANG J D, et al. Deep subdomain adaptive networks for image classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(4): 1713-1722.
- [26] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. Journal of Machine Learning Research, 2017, 17(1): 2096-2030.

作者简介

贾宝惠, 硕士, 教授, 博士生导师, 主要研究方向为维修与适航技术、健康管理。

E-mail: jiabaohui@sina.com

苏家成(通信作者), 硕士, 主要研究方向为信号处理、故障诊断。

E-mail: 837368380@qq.com