

基于改进残差网络的风电轴承故障迁移诊断方法

邓林峰, 王琦, 郑玉巧

(兰州理工大学机电工程学院, 甘肃 兰州 730050)

摘要: 针对风电轴承故障源域数据和目标域数据特征分布不同而导致的故障诊断精度偏低问题, 提出一种利用改进残差神经网络进行风电轴承故障迁移诊断的方法。该方法将卷积核和池化核设定为与一维振动信号卷积运算相适应的尺寸, 从振动信号直接提取轴承的故障特征; 在一维残差网络中同时使用批量归一化和实例归一化, 进一步增强模型的特征提取能力; 在模型训练阶段, 通过源域数据和目标域数据的多核最大均值差异构建新的损失函数, 以提高模型在不同分布数据集上的迁移学习及分类能力。利用故障轴承实验数据对方法的有效性进行验证, 结果显示, 即使受到轴承变转速运行工况和故障振动信号含噪声干扰成分的双重影响, 该方法仍然可提取出轴承故障的重要特征, 并实现不同工况轴承故障的迁移诊断和准确分类, 这对于发展复杂环境下的旋转机械智能故障诊断技术具有参考价值。

关键词: 故障诊断; 风电轴承; 振动信号; 卷积神经网络; 残差网络

中图分类号: TH165⁺.3; TP183 **文献标志码:** A **文章编号:** 1004-4523(2024)02-0356-09

DOI: 10.16385/j.cnki.issn.1004-4523.2024.02.018

引言

轴承是风电机组传动系统的关键部件, 承受着风机转动部件的重量, 并支承这些部件进行旋转将风能转化为电能, 其健康状况对风电机组的性能、稳定性和使用寿命会产生巨大影响^[1-3]。因此, 对风电轴承故障进行监测与诊断, 是保障风电机组安全高效运行的重要措施。轴承振动信号中包含着轴承故障信息, 通过对其进行分析处理可识别轴承的健康状况。然而随着风电设备的监测数据量与日俱增, 传统故障诊断方法已无法适应大数据故障诊断分析的发展需求^[4]。

近年来, 基于大数据深度学习的模式识别方法在机械故障诊断领域快速发展^[5]。其中, 卷积神经网络 (Convolutional Neural Network, CNN) 具有局部计算、权值共享和端对端等特点, 表现出优异的故障诊断性能^[6-7]。但是, 这些方法有效的前提是基于两个基本假设^[8]: 1) 有大量的标记数据可用; 2) 训练集和测试集独立且服从同一分布。然而, 在工程现场, 风电机组运行环境复杂, 存在多种引起风电机组运行状态发生变化的因素, 使得风电轴承出现故障时采集到的振动信号往往具有明显的非平稳特

性^[9]。在这种状况下, 从部分振动信号提取的故障特征值将发生偏离, 导致故障训练样本和测试样本的分布特性存在一定差异^[10-11], 从而影响深度学习模型在测试集上的泛化性能, 致使故障诊断结果的准确性较低, 难以满足轴承故障监测的实际需求。

针对上述问题, Guo 等^[12]利用重采样技术和自适应随机共振滤波技术, 实现强噪声干扰下风力发电机轴承故障的高效自动诊断。董绍江等^[13]联合奇异值分解和经验模态分解对故障信号进行处理, 并在 CNN 池化层引入注意力机制增强模型的特征提取能力, 实现了强噪声环境下轴承故障的准确诊断。Ren 等^[14]将变分模态分解、多尺度排列熵和特征迁移学习方法相结合, 对变工况下的风机齿轮箱轴承故障具有较高的分类准确率。Zhu 等^[15]提出了一种迁移学习的 CNN 模型, 将服从不同分布的两组数据的多核最大均值差异作为训练 CNN 的约束条件, 可有效识别不同负载下轴承的故障类别。Zhang 等^[16-17]针对风电机组轴承、齿轮的故障信号和诊断模型的特点, 采用数模联动策略进行数据形式的变换与模型结构的改进, 建立了可靠有效的风电轴承、齿轮的故障迁移诊断方法。Liang 等^[18]提出基于子域自适应深度可变形残差网络的无监督风机轴承故障诊断方法, 实现了变转速轴承故障的有效诊断。

收稿日期: 2023-01-26; 修订日期: 2023-03-26

基金项目: 国家自然科学基金资助项目 (62241308); 甘肃省技术创新引导计划-科技专员专项资助项目 (22CX8GA130)。

虽然上述方法针对噪声或负载变化工况下的轴承复杂故障诊断有一定效果,但模型的特征提取能力和迁移学习能力还有进一步提升的空间。

综上所述,本文提出一种利用残差神经网络的风电轴承故障迁移诊断方法。通过对残差网络的卷积运算进行一维化处理并加入批量归一化和实例归一化,以增强残差网络的特征提取能力;在模型训练阶段,利用不同分布特性的数据建立基于多核最大均值差异的新损失函数,用于提高模型在不同分布数据集上的迁移学习及数据分类能力。在此基础上,利用滚动轴承故障实验数据对该方法的性能进行验证和对比分析,证实其对风电轴承复杂故障进行迁移诊断的有效性。

1 理论基础

1.1 残差网络

为解决神经网络在训练过程中出现的梯度消失和梯度爆炸问题,He等^[19]提出了残差神经网络(Residual Network, ResNet)。ResNet本质上是由多个残差块堆叠而成的,残差块在普通CNN的基础上使用跳跃连接,达到使网络学习残差的目的。残差块结构如图1所示,图1(a)和(b)分别表示输入与残差映射输出特征维度相同和不同时的残差块。

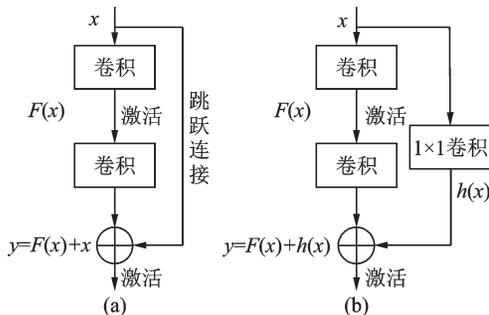


图1 残差块结构

Fig. 1 Structure of residual block

由图1可见,残差块输出 y 为输入 x 和残差映射输出 $F(x)$ 的叠加值,其中 $F(x)$ 是对 x 进行卷积和激活运算所得,其具体计算过程如下式所示:

$$x' = \sum_{i=1}^c \mathbf{w} * x + b \quad (1)$$

式中 x 表示残差块的输入; c 表示通道数量; \mathbf{w} 表示卷积核的权重矩阵; b 表示偏置项;*表示进行卷积运算; x' 表示卷积运算的结果。

$$y' = f(x') = \max\{0, x'\} \quad (2)$$

式中 x' 为式(1)卷积运算得到的输出特征图; y' 为 x' 经过ReLU激活处理后的输出值。

需要注意的是,当输入 x 和残差映射输出 $F(x)$ 的通道数量不同时,则需要如图1(a)的跳跃连接的基础上,通过使用 1×1 卷积运算保证它们的特征维度相同,如图1(b)所示。

1.2 批量归一化和实例归一化

批量归一化(Batch Normalization, BN)操作类似于一种标准化操作,在CNN中添加BN层的目的是减少内部协变量转移,从而提高网络性能。其计算过程为:

$$\begin{cases} \mu_B = \frac{1}{N} \sum_{i=1}^N x_i \\ \sigma_B^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu_B)^2 \\ \hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \\ y_i = \gamma \hat{x}_i + \beta \end{cases} \quad (3)$$

式中 μ_B 表示样本均值; σ_B^2 表示样本方差; N 表示样本批尺寸; \hat{x}_i 表示卷积核的原始输出特征图 x_i 经标准化处理后的数据; y_i 表示 \hat{x}_i 的批量归一化处理结果; ϵ 表示常值向量; γ 和 β 分别表示尺度因子和移动因子的两个可学习参数。

实例归一化(Instance Normalization, IN)的运算过程与BN相似,不同之处在于:BN是通过计算每批次样本的均值 μ_B 和方差 σ_B^2 实现归一化,而IN则是通过计算每个通道的均值 μ_i 和方差 σ_i^2 实现归一化;对于一维信号而言,则是通过计算单个样本信号所有数据点的均值 μ_i 和方差 σ_i^2 进行实例归一化,因此IN的结果不受批尺寸的影响。

1.3 多核最大均值差异

在机器学习方法中,度量准则必不可少。最大均值差异(Maximum Mean Discrepancy, MMD)^[20]是迁移学习方法尤其是域适应中常用的度量准则之一,其主要用来度量两组不同但相关数据在再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS)中的分布距离,是一种核学习方法。假设存在两组服从不同分布的数据 $X = \{x_1, x_2, \dots, x_n\}$ 和 $Y = \{y_1, y_2, \dots, y_m\}$,则 X 和 Y 的MMD计算式为:

$$MMD(X, Y) = \left\| \frac{1}{n} \sum_{i=1}^n \varphi(x_i) - \frac{1}{m} \sum_{j=1}^m \varphi(y_j) \right\|_H^2 \quad (4)$$

式中 $\|\cdot\|_H$ 表示RKHS中的分布距离; $\varphi(\cdot)$ 为映射函数,用于把原变量映射到RKHS。

将式(4)的平方展开后,RKHS中的内积就可以转换为核函数,即

$$MMD(X, Y) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n k(x_i, x_j) - \frac{2}{nm} \sum_{i=1}^n \sum_{j=1}^m k(x_i, y_j) + \frac{1}{m^2} \sum_{i=1}^m \sum_{j=1}^m k(y_i, y_j) \quad (5)$$

式中 n 为源域样本的数量; m 为目标域样本的数量; $k(\cdot, \cdot)$ 为核函数。

高斯核函数可以将原始特征映射到无穷维的高维特征空间^[20], 因此, 本研究使用高斯核函数计算 MMD , 即式(5)中的核函数为:

$$k(u, v) = e^{-\frac{\|u-v\|^2}{2h^2}} \quad (6)$$

式中 h 为核参数, 可控制函数的径向作用范围。

由式(6)可知, 核参数 h 越大, 高斯核函数的值就越分散, 其函数图像就会越平坦, 两个样本之间的欧式距离对高斯核函数的值影响较小, 使得分类模型的学习能力有限, 数据的分类训练准确率较低; 反之, 函数值就越集中, 函数图像就会越尖锐, 高斯核函数对两点之间的欧式距离就会很敏感, 使分类模型对源域数据过分拟合, 而对目标域数据的预测效果较差。显而易见, 参数 h 的选择很关键, 会对 MMD 的计算结果产生一定影响。为解决该问题, Gretton 等提出多核最大均值差异 (Multiple Kernel MMD, MK-MMD)^[21], 其在计算 MMD 时, 通过同时使用多个核函数来避免核参数选择不当所带来的计算误差。因此, MK-MMD 将传统核参数的选择问题转换为多个核函数的凸优化问题^[21], 如下式所示:

$$K \triangleq \left\{ k = \sum_{i=1}^{N_k} \beta_u k_u; \sum_{i=1}^{N_k} \beta_u = 1, \beta_u \geq 0, \forall u \right\} \quad (7)$$

式中 K 表示 N_k 个高斯核函数集的凸组合; k_u 表示第 u 个核; $\{\beta_u\}$ 表示不同核函数的权重参数集。

2 风电轴承故障迁移诊断方法

2.1 改进的一维残差网络模型

He 等^[19] 提出残差网络的初衷是用于解决复杂图像的识别问题, 因此其卷积核及其卷积运算都是针对二维图像设计和计算的。为使残差网络适合处理轴承一维振动信号, 需对其进行改进, 具体改进措施如下:

1) 采集的轴承一维振动信号为一维时间序列, 为适应其结构特性, 所构建的残差网络模型的全层卷积核和池化核均适用于一维信号的一维卷积运算。

2) 模型的第一层采用大尺寸卷积核, 目的是为了增大感受野, 一次获取更多的数据点并为网络后续层提供有用信息。同时, 对于含噪振动信号而言,

大卷积核可以更好地抑制高频噪声^[22]。

3) 为了增强模型的特征提取能力, 在图 1 所示的残差块中同时使用 BN 和 IN 两种归一化方法, 具体操作如图 2 所示。

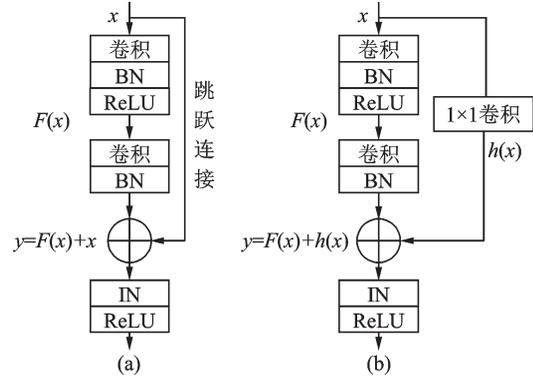


图 2 改进后的残差块
Fig. 2 Improved residual block

从图 2 中可见, 改进残差块是在图 1 所示残差块的基础上先对残差映射部分的第一个卷积层输出依次进行 BN 和激活操作; 然后, 对第二个卷积层的输出进行 BN 操作; 最后, 对残差块的输出 y 依次进行 IN 和激活操作。此外, 需注意的是, 当残差块的输入 x 和残差映射的输出 $F(x)$ 具有相同特征维度时, 使用图 2(a) 所示的残差块, 反之使用图 2(b) 所示的残差块。综上所述, 最终所构建的一维残差神经网络模型结构如图 3 所示。

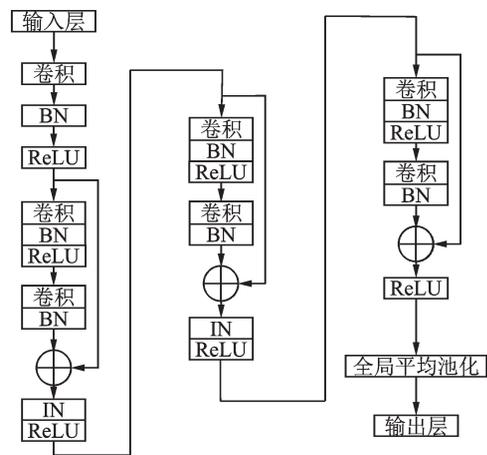


图 3 一维残差神经网络模型结构
Fig. 3 Structure of one-dimensional residual neural network model

从图 3 中可见, 改进后的一维残差神经网络模型主要由 1 个卷积层、3 个残差块以及 1 个全局平均池化层构成。其中, 前 2 个残差块为图 2 所示改进后的完整残差块, 而第 3 个残差块仅有 BN 层无 IN 层。

2.2 模型的训练方法

在构建好一维残差神经网络模型后,还需要对其进行训练才可用于实际一维信号的模式分类。首先以原始一维振动信号作为输入,前向传播并逐层完成信号特征的自动提取;然后利用全局平均池化操作对所提取的特征进行全局空间整合,并通过Softmax函数进行分类;最后以交叉熵度量Softmax函数的输出概率分布和信号类别概率分布间的差异,并将其作为损失函数。交叉熵的计算公式为:

$$l_c = -\sum_x p(x) \ln q(x) \quad (8)$$

式中 $p(x)$ 表示样本 x 的分类的真实概率; $q(x)$ 表示观测到的样本 x 实际分类结果的概率。

为增强模型在不同分布特性数据集上的迁移学习和推广泛化能力,将数据集的MK-MMD引入到交叉熵损失函数上,即

$$l = l_c + \lambda_1 M_{K1}(D_s, D_t) + \lambda_2 M_{K2}(D_s, D_t) \quad (9)$$

式中 l 表示训练一维残差网络模型的损失函数; l_c 表示交叉熵损失函数; D_s 和 D_t 分别表示存在分布差异的源域和目标域故障数据; $M_{K1}(D_s, D_t)$ 和 $M_{K2}(D_s, D_t)$ 分别表示 D_s 和 D_t 在图3所示一维残差网络模型的第3个残差块和全局平均池化层的多核最大均值差异; λ_1 和 λ_2 分别为用于控制 $M_{K1}(D_s, D_t)$ 和 $M_{K2}(D_s, D_t)$ 的权重。

为提高模型的性能,本研究通过联合使用5个高斯核函数计算 D_s 和 D_t 的MK-MMD值,其中5个高斯核函数的核参数 h 分别设置为1, 2, 4, 8和 $16^{[23]}$ 。

完成损失函数的计算后,再通过反向传播分别计算损失函数关于模型各层权值和偏置的导数,最后使用优化算法更新模型的权值和偏置。迭代循环上述过程,直到损失函数值达到最小。综上,改进的一维残差神经网络模型的训练过程如图4所示。

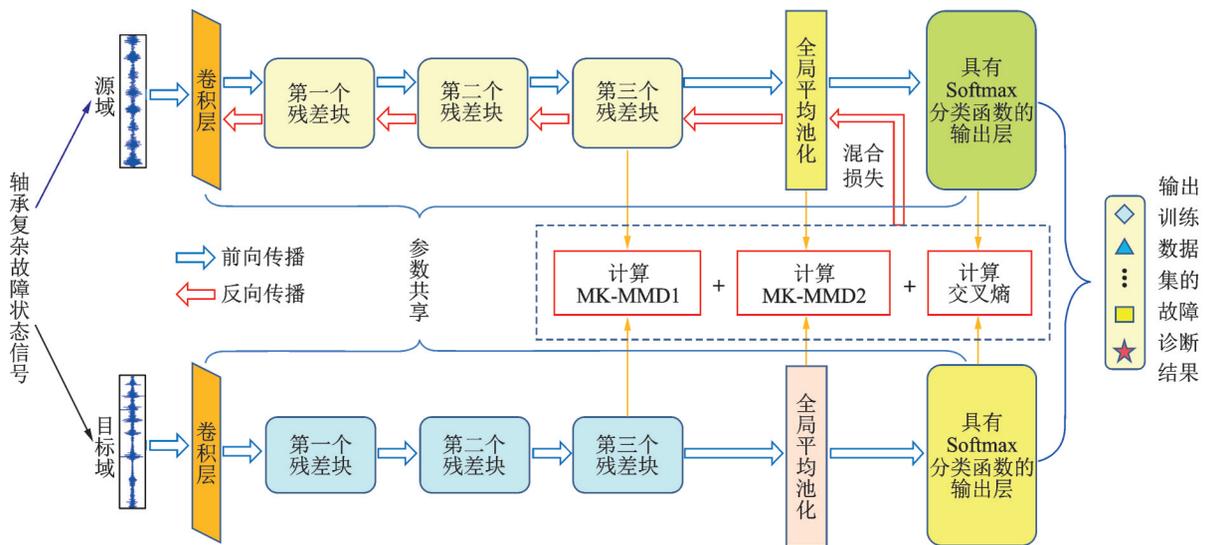


图4 模型的训练过程

Fig. 4 Training process of the model

从图4中可见,结合轴承复杂故障信号训练一维残差网络的过程为:将服从不同分布的源域数据 D_s 和目标域数据 D_t 共同输入模型进行前向传播;然后,分别计算 $M_{K1}(D_s, D_t)$ 和 $M_{K2}(D_s, D_t)$ 的值,通过式(9)计算模型的损失函数 l 的值,并将其进行反向传播,以更新模型参数使损失函数 l 达到最小,从而完成模型训练;最后,分别输出源域和目标域数据的分类结果。

2.3 风电轴承故障迁移诊断流程

针对风电轴承故障振动特征分布不同的特点,基于改进的一维残差神经网络模型及其训练过程,设计复杂工况下的风电轴承故障迁移诊断方法,该

方法主要分为三个环节:1) 数据集准备;2) 模型训练;3) 模型测试。其具体实施步骤如下:

步骤1 将采集到的轴承故障振动信号分为源域和目标域,并对源域数据进行故障状态标记,目标域数据不标记;其中,目标域数据进一步划分为训练数据子集和测试数据子集,将训练数据子集与源域数据合并构成完整的训练数据集。

步骤2 建立适应轴承故障振动信号的改进一维残差神经网络,并对网络参数进行初始化。

步骤3 将训练数据集输入网络模型,并逐层进行前向传播,获得不同层上输出的故障特征。

步骤4 利用一维残差神经网络第3个残差块和平均池化层的输出特征图计算相应的MK-MMD

值以及输出层的交叉熵,进而得到模型的损失函数值,并将该值进行反向传播,以更新模型每层的权重和偏置,使模型的下一轮次训练损失值减小。

步骤 5 若满足训练终止条件,训练过程结束;若不满足,则返回步骤 3 继续循环迭代。

步骤 6 将轴承信号的测试数据子集输入训练好的网络模型,对其进行故障分类与识别,实现复杂工况下的风电轴承故障迁移诊断。

与上述步骤对应的流程如图 5 所示。

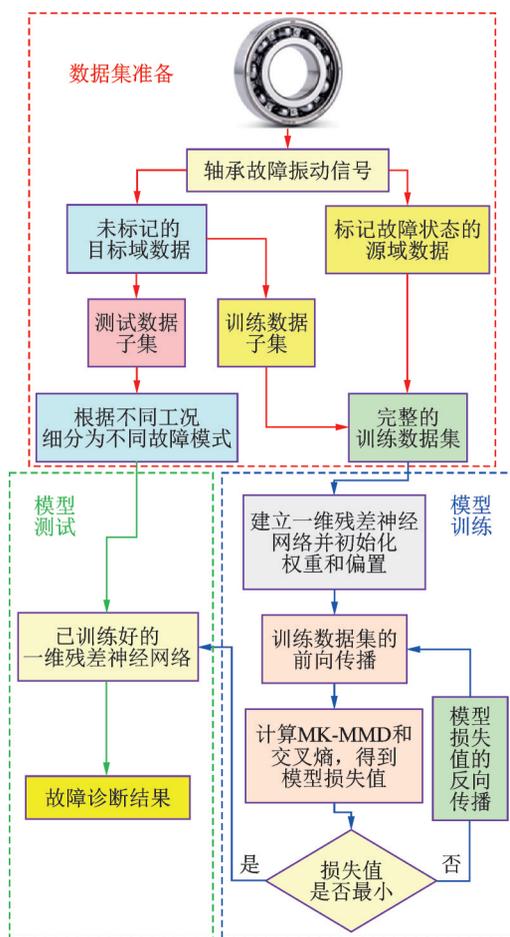


图 5 轴承故障迁移诊断流程图

Fig. 5 Flowchart of the bearing fault transfer diagnosis

3 方法的实验验证

3.1 公开的实验数据简介

实验数据选用美国凯斯西储大学轴承数据中心的滚动轴承故障数据集^[5]。轴承型号为 SKF6205 深沟球轴承,其运行状态包括正常(N)、内圈故障(IF)、外圈故障(OF)和滚动体故障(BF)共 4 种类型,且每类故障都包含了 0.1778, 0.3556 和 0.5334 mm 三种故障直径,因此每一转速下可形成 10 种运行状态。

本研究选用驱动端轴承数据,因原始数据样本有限,采用重叠采样^[22]的方式处理原始数据,使每个样本数据点为 2048。由于具有 4 种转速,按不同转速将原始数据划分为 4 个数据集,具体信息如表 1 所示。

表 1 实验数据集

Tab. 1 Experiment datasets

数据集	训练样本数	测试样本数	转速/(r·min ⁻¹)
A	10×800	10×200	1797
B	10×800	10×200	1772
C	10×800	10×200	1750
D	10×800	10×200	1730

3.2 模型参数

残差神经网络模型用于具体的分类任务时,选择恰当的参数可有效发挥模型的性能。因此,通过预训练方式,得到第 2 节所建立一维残差神经网络模型的参数,具体参数如表 2 所示。

表 2 模型参数

Tab. 2 Parameters of the model

网络层	具体参数	输出维度	其他参数
输入层	—	2048×1	
卷积层	16×64×8	256×16	
残差块 1	16×1×1 32×3×1	256×32	批尺寸:16 优化器:Adadelta
残差块 2	32×1×1 64×3×1	256×64	
残差块 3	64×1×1 128×3×1	256×128	
池化层	—	128×1	
输出层	10	10×1	

3.3 实验结果对比及分析

为说明本文方法的优势,将其与 ResNet 和 DAN^[24]方法进行对比分析,其中 ResNet 与本研究构建的网络模型相比,其前两个残差块只使用 BN 操作。3 种方法对轴承故障的分类准确率如图 6 所示。

图 6(a), (b), (c) 和 (d) 分别表示在测试数据中加入信噪比为 -4, -2, 2 和 4 dB 高斯白噪声后的故障诊断结果。从图 6 中可见,在同时受到噪声污染和轴承转速变化影响的情况下,ResNet 的故障识别准确率最低;DAN 的故障识别率略高于 ResNet,因为 DAN 方法同时进行故障特征提取和减小源域与目标域数据分布差异操作,但该方法却未能消除

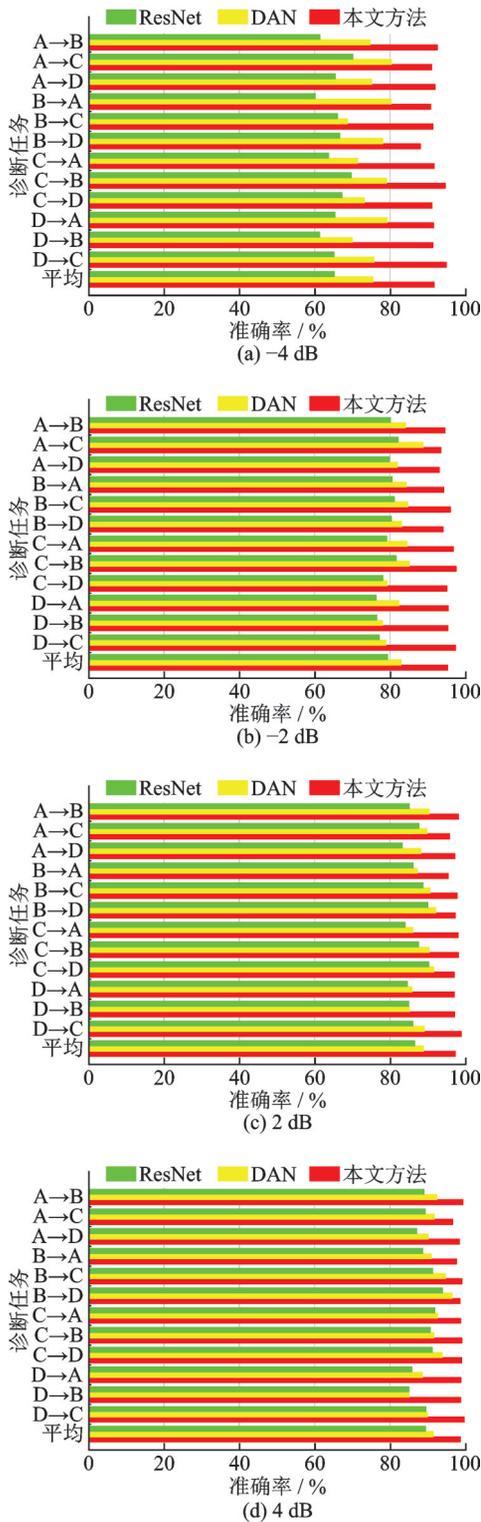


图 6 3 种方法的故障诊断准确率

Fig.6 Fault diagnosis accuracies of the three different methods

噪声干扰所带来的影响。相比之下,本文方法在同时受到噪声和转速变化影响下可以达到很高的故障识别率,当信噪比为-4 dB时,平均准确率相较于ResNet和DAN方法分别高出了26.7%和16.4%;信噪比为4 dB时其平均准确率高达99.2%。由此说明,本研究方法可实现复杂工况下的轴承故障迁移诊断,并具有较高的准确率。

3.4 轴承故障实例分析

为进一步验证本研究方法的实用性,将该方法用于图7所示的HZXT-DS-001型双跨转子轴承系统综合故障模拟实验台的轴承故障识别。



图 7 HZXT-DS-001 型实验台

Fig.7 HZXT-DS-001 experiment rig

实验台的轴承型号为NSK6038深沟球轴承,在轴承上设置的故障形式如图8所示。

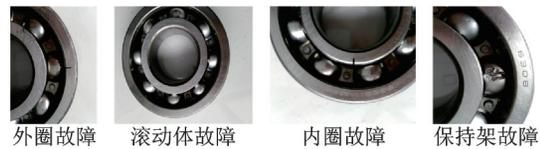


图 8 轴承故障的 4 种形式

Fig.8 Four different fault forms of the bearing

轴承设置了4种转速,信号采样频率为8 kHz。为使用与3.2节表2中相同的模型参数,使每个样本的采样点数为2048。同样,按轴承转速不同,本实验共准备了4个数据集,其具体信息如表3所示。

表 3 实验数据集

Tab.3 Experiment datasets

数据集	训练样本数	测试样本数	转速/(r·min ⁻¹)
A	5×600	5×200	2600
B	5×600	5×200	2800
C	5×600	5×200	3000
D	5×600	5×200	3200

本实验中轴承故障不区分严重程度,故只有5种运行状态,即每个数据集均包含5种状态,因此需将模型输出向量长度设置为5。仍然与ResNet和DAN方法进行诊断性能的对比分析,结果如图9所示。

从图9中可见,在原始故障数据中加入不同信噪比的高斯白噪声的情况下,ResNet和DAN方法的准确率明显低于本研究方法的准确率,且信噪比越低,其他两种方法的故障诊断准确率与本研究方法的故障诊断准确率的差距越大;对于任何一种信噪比,本研究方法的故障识别准确率都超过了90%。由此说明,在轴承故障信号受到严重噪声污染的情况下,本研究方法仍可有效解决变转速下的轴承故障诊断问题,其故障识别准确率明显高于其

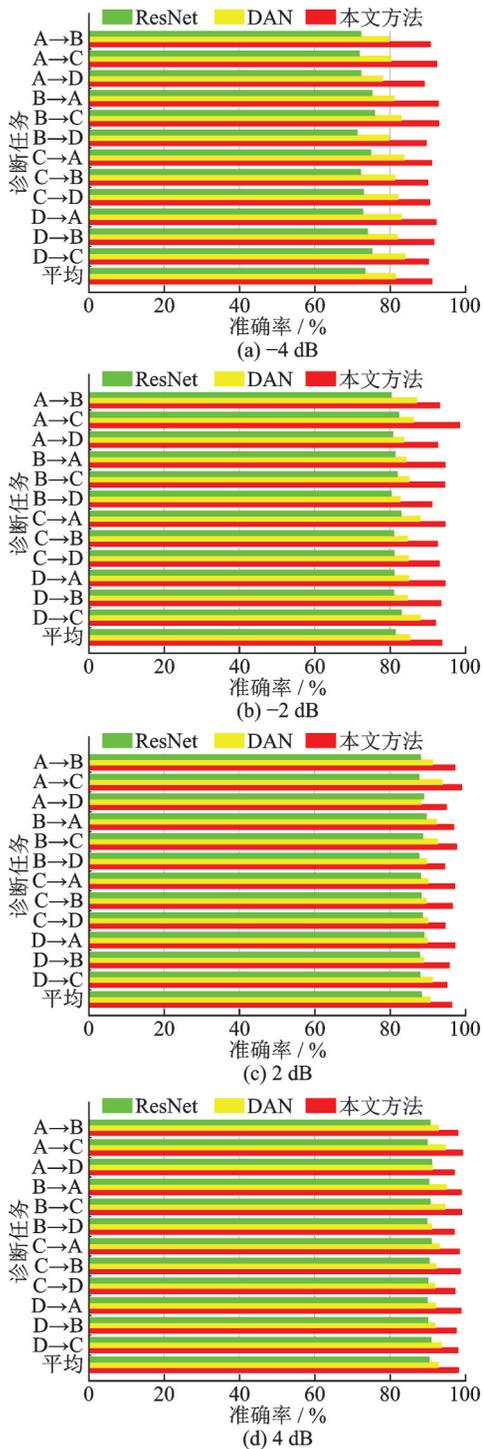


图9 3种方法的性能对比

Fig.9 Performance comparison of the three different methods

他两种方法,表现出了较好的故障迁移诊断能力和抗噪性能。因此,本研究方法在复杂工况下轴承故障诊断应用中的有效性和广泛适用性得到证实。

4 结论

风电轴承故障诊断技术可为风电装备的安全运行提供保障。针对风电轴承故障数据不同分布特性

而导致的故障诊断精度偏低问题,提出一种利用改进残差神经网络的风电轴承故障迁移诊断方法。通过处理轴承故障实验数据以及与其他典型故障诊断方法的比较分析,对该方法的性能进行了验证。获得的主要结论如下:

(1) 本研究提出的一维残差神经网络模型由于对卷积运算进行了一维化处理,可直接将轴承故障原始一维振动信号作为网络的输入数据,无需对一维振动信号进行人工特征提取;通过在模型的前两层残差块中同时使用批量归一化和实例归一化,能够有效降低噪声对模型性能的影响;利用源域特征和目标域特征之间的最大均值差异建立模型的损失函数,可提高模型在目标域数据上的分类性能。

(2) 与其他两种故障诊断方法进行实验和对比分析,结果表明在噪声污染和轴承转速变化同时存在的情况下,本研究方法依然可以有效实现滚动轴承复杂故障的迁移诊断,其故障诊断准确率较ResNet和DAN方法更高,且准确率达到90%以上,说明本研究方法不仅可以实现复杂工况下轴承故障的迁移诊断,而且具有较好的抗噪性能。

(3) 在实验验证阶段,本研究考虑的情况是轴承在不同转速之间的故障迁移诊断任务,且所建模型在固定参数下表现出良好的故障迁移诊断能力,而对于模型在不同参数下的诊断效果并未考虑。下一步将尝试对不同参数下模型的鲁棒性进行研究,揭示模型参数对模型识别结果的影响机制,并建立适合于处理风电轴承振动信号的一维深度卷积神经网络模型,发展复杂工况下风电装备的智能故障诊断方法与技术。

参考文献:

- [1] Wang Jinjiang, Liang Yuanyuan, Zheng Yinghao, et al. An integrated fault diagnosis and prognosis approach for predictive maintenance of wind turbine bearing with limited samples[J]. *Renewable Energy*, 2020, 145: 642-650.
- [2] Liu Zepeng, Zhang Long. A review of failure modes, condition monitoring and fault diagnosis methods for large-scale wind turbine bearings[J]. *Measurement*, 2020, 149: 107002.
- [3] Ma Zhipeng, Zhao Ming, Luo Mourui, et al. An integrated monitoring scheme for wind turbine main bearing using acoustic emission[J]. *Signal Processing*, 2023, 205: 108867.
- [4] Stetco A, Dinmohammadi F, Zhao X, et al. Machine

- learning methods for wind turbine condition monitoring: a review[J]. *Renewable Energy*, 2019, 133: 620-635.
- [5] 姚齐水, 别帅帅, 余江鸿, 等. 一种结合改进 Inception V2 模块和 CBAM 的轴承故障诊断方法[J]. *振动工程学报*, 2022, 35(4): 949-957.
- Yao Qishui, Bie Shuashuai, Yu Jianghong, et al. A bearing fault diagnosis method combining improved inception V2 module and CBAM[J]. *Journal of Vibration Engineering*, 2022, 35(4): 949-957.
- [6] Xu Zifei, Mei Xuan, Wang Xinyu, et al. Fault diagnosis of wind turbine bearing using a multi-scale convolutional neural network with bidirectional long short term memory and weighted majority voting for multi-sensors [J]. *Renewable Energy*, 2022, 182: 615-626.
- [7] 韩特, 刘超, 沈长青, 等. 深度嵌入度量学习的机械跨工况故障识别方法[J]. *振动工程学报*, 2023, 36(2): 565-573.
- Han Te, Liu Chao, Shen Changqing, et al. Deep embedding metric learning for machinery fault identification across different working conditions[J]. *Journal of Vibration Engineering*, 2023, 36(2): 565-573.
- [8] Lei Yaguo, Yang Bin, Jiang Xinwei, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap[J]. *Mechanical Systems and Signal Processing*, 2020, 138: 106587.
- [9] Gomez J L, Khelif I, Bourdon A, et al. Angular modeling of a rotating machine in non-stationary conditions: application to monitoring bearing defects of wind turbines with instantaneous angular speed[J]. *Mechanism and Machine Theory*, 2019, 136: 27-51.
- [10] Zhao Zhibin, Zhang Qiyang, Yu Xiaolei, et al. Applications of unsupervised deep transfer learning to intelligent fault diagnosis: a survey and comparative study[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3525828.
- [11] Su Hao, Yang Xin, Xiang Ling, et al. A novel method based on deep transfer unsupervised learning network for bearing fault diagnosis under variable working condition of unequal quantity[J]. *Knowledge-Based Systems*, 2022, 242: 108381.
- [12] Guo Jun, Lu Siliang, Zhai Chao, et al. Automatic bearing fault diagnosis of permanent magnet synchronous generators in wind turbines subjected to noise interference[J]. *Measurement Science and Technology*, 2018, 29(2): 025002.
- [13] 董绍江, 裴雪武, 吴文亮, 等. 基于多层降噪技术及改进卷积神经网络的滚动轴承故障诊断方法[J]. *机械工程学报*, 2021, 57(1): 148-156.
- Dong Shaojiang, Pei Xuewu, Wu Wenliang, et al. Rolling bearing fault diagnosis method based on multilayer noise reduction technology and improved convolutional neural network[J]. *Journal of Mechanical Engineering*, 2021, 57(1): 148-156.
- [14] Ren He, Liu Wenyi, Shan Mengchen, et al. A new wind turbine health condition monitoring method based on VMD-MPE and feature-based transfer learning[J]. *Measurement*, 2019, 148: 106906.
- [15] Zhu Jun, Chen Nan, Shen Changqing. A new deep transfer learning method for bearing fault diagnosis under different working conditions[J]. *IEEE Sensors Journal*, 2020, 20(15): 8394-8402.
- [16] Zhang Yan, Liu Wenyi, Wang Xin, et al. A novel wind turbine fault diagnosis method based on compressed sensing and DTL-CNN[J]. *Renewable Energy*, 2022, 194: 249-258.
- [17] Zhang Yan, Liu Wenyi, Gu Heng, et al. A novel wind turbine fault diagnosis based on deep transfer learning of improved residual network and multi-target data[J]. *Measurement Science and Technology*, 2022, 33(9): 095007.
- [18] Liang Pengfei, Wang Bin, Jiang Guoqian, et al. Unsupervised fault diagnosis of wind turbine bearing via a deep residual deformable convolution network based on subdomain adaptation under time-varying speeds[J]. *Engineering Applications of Artificial Intelligence*, 2023, 118: 105656.
- [19] He Kaiming, Zhang Xiangyu, Ren Shaoqing, et al. Deep residual learning for image recognition[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, N. V., USA, 2016: 770-778.
- [20] Gong Lihua, Xiang Lingzhi, Liu Sihang, et al. Born machine model based on matrix product state quantum circuit[J]. *Physica A: Statistical Mechanics and its Applications*, 2022, 593: 126907.
- [21] Che Changchang, Wang Huawei, Ni Xiaomei, et al. Domain adaptive deep belief network for rolling bearing fault diagnosis[J]. *Computers & Industrial Engineering*, 2020, 143: 106427.
- [22] Zhang Wei, Li Chuanhao, 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 and Signal Processing*, 2018, 100: 439-453.
- [23] Li Xiang, Zhang Wei, Ding Qian. Cross-domain fault diagnosis of rolling element bearings using deep generative neural networks[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(7): 5525-5534.
- [24] Long Mingsheng, Cao Yue, Cao Zhangjie, et al. Transferable representation learning with deep adaptation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 41(12): 3071-3085.

A fault transfer diagnosis method for wind turbine bearings based on improved residual neural networks

DENG Lin-feng, WANG Qi, ZHENG Yu-qiao

(School of Mechanical and Electrical Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: To address the low accuracy in diagnosing faults in wind turbine bearings caused by the different characteristic distribution of the source domain data and the target domain data, a fault transfer diagnosis method using improved residual neural networks is proposed. The convolution kernel and pooling kernel are set to a size suitable for the convolution operation of one-dimensional signals, allowing for direct extraction of fault features from the bearing vibration signals; Both batch normalization and case normalization are used in the one-dimensional residual network to further enhance the feature extraction ability of the model; In the model training stage, a new loss function is constructed based on the multiple kernel maximum mean discrepancy between the source domain data and the target domain data to improve the transfer learning and classification ability of the model. The effectiveness of the method is verified by conducting the experimental data of the faulty bearings. The results show that the proposed method can effectively extract the important features of bearing faults and achieve the transfer diagnosis and accurate classification of the bearing faults. This holds true even under varying speed operation conditions and when the bearing fault vibration signals are disturbed by some noise components. Therefore, this work provides a useful strategy in developing intelligent fault diagnosis technology of rotating machinery under complex working conditions.

Key words: fault diagnosis; wind turbine bearing; vibration signal; convolutional neural network; residual neural network

作者简介: 邓林峰(1984—),男,博士,副教授。E-mail: denglinfeng2002@163.com。