

基于混合自注意力孪生网络的小样本轴承故障诊断

谢乃鹏¹, 周 凤², 熊 伟¹

(1. 贵州大学 公共大数据国家重点实验室, 贵阳 550025;

2. 贵州大学 计算机科学与技术学院, 贵阳 550025)

摘要: 针对小样本条件下传统应用于滚动轴承故障诊断的深度学习算法诊断精度不高, 泛化性差的问题; 提出了一种基于混合自注意力机制和孪生网络的小样本轴承故障诊断算法; 基于孪生神经网络结构, 构造相同类别和不同类别的轴承样本对输入孪生网络, 借助一维卷积单元提取样本的特征, 然后采用位置自注意力机制和通道自注意力机制进行矩阵融合构建混合自注意力模块, 提取更具判别性的特征信息, 距离度量阶段以自适应的网络度量方式来代替常用的欧式距离度量, 并且引入全局均值池化来减少网络参数; 实验结果表明该方法在每类故障样本数量为 9、15、30 的准确率为 88.2%、94.7%、96.2%, 对比其他方法, 文章所提算法在小样本条件下的诊断准确率更高, 并且拥有更好的泛化性能。

关键词: 滚动轴承; 孪生神经网络; 故障诊断; 自注意力机制; 混合自注意力

Fault Diagnosis of Small Sample Bearing Based on Hybrid Self-Attention and Twin Network

XIE Naipeng¹, ZHOU Feng², XIONG Wei¹

(1. State Key Laboratory of Public Big Data, Guizhou University, Guiyang 550025, China;

2. College of Computer Science & Technology, Guizhou University, Guiyang 550025, China)

Abstract: Aiming at the problems of poor diagnostic accuracy and poor generalization of traditional deep learning algorithms applied in rolling bearing fault diagnosis under small sample conditions, a small-sample bearing fault diagnosis algorithm based on the hybrid self-attention mechanism and twin network is proposed. Based on the twin neural network structure, this paper constructs an input twin network for bearing samples of same and different categories, and extracts the features of samples with the help of one-dimensional convolutional unit, and then, the position self attention mechanism and channel self-attention mechanism are used for matrix fusion to construct the hybrid self-attention module, which extracts more discriminative feature information. In the distance metric stage, an adaptive network metric is used instead of commonly used Euclidean distance metric, and global mean pooling is introduced to reduce network parameters. Experimental results show that the accuracy of the proposed method is 88.2%, 94.7%, and 96.2% for the fault samples of 9, 15, and 30 in each category. Compared with other methods, the proposed algorithm has high diagnostic accuracy for small samples and better generalization performance.

Keywords: rolling bearing; twin neural network; fault diagnosis; self-attention mechanism; hybrid self-attention

收稿日期:2023-11-26; 修回日期:2024-01-14。

基金项目:贵州省科技计划项目([2022]ZD001)。

作者简介:谢乃鹏(1998-),男,硕士研究生。

通讯作者:周 凤(1976-),女,硕士,副教授。

引用格式:谢乃鹏,周 凤,熊 伟. 基于混合自注意力孪生网络的小样本轴承故障诊断[J]. 计算机测量与控制, 2025, 33(2): 1-8, 36.

0 引言

滚动轴承被广泛应用于工业生产、航空航天、制造业等多个领域^[1]。机械设备的日常工作与轴承的健康状态息息相关,一旦轴承发生故障将直接影响整个设备的正常工作,轻则造成经济损失,重则造成安全事故。因此,准确地诊断出滚动轴承的故障状态对于机械设备的健康检测和安全使用具有重要意义^[2]。

早期的故障诊断技术主要是通过传统的信号分析方法提取出故障信号的特征频率,通过特征频率来确定故障类型。常见的方法有经验模态分解^[3]、小波变换^[4]、奇异值分解^[5]等。在实际工业场景中,设备复杂的运行状况使得信号处理难度大大增加,这类方法需要依靠扎实的专家经验以及大量信号处理知识才能准确地诊断出故障状态。深度学习是人工智能领域的一个重大突破,其通过建立深层结构模型,无需依赖专业的信号处理手段和专家经验,能够直接从时域或频域信号中自适应地提取故障特征,提供了端到端的故障诊断模式,近年来已被广泛应用于故障诊断领域^[6]。文献[7]在第一卷积层中使用大卷积核的一维卷积网络用于滚动轴承的故障诊断,具有良好的抗噪能力。文献[8]提出了一种基于卷积神经网络的轴承数据特征表示方法,提高轴承数据的鲁棒性和显著性。文献[9]提出了深度残差收缩网络,以提升高噪声振动信号的特征学习能力,实现较高的故障诊断精度。虽然这些方法在故障诊断上有所成效,但建立模型时需要反复学习大量的训练样本特征,不断优化网络参数才能得到较好的故障诊断效果。然而,现实中由于各种客观条件,导致轴承故障数据缺乏,很难收集到足够的样本来训练模型^[10]。

对于小样本问题^[11],专家学者主要通过数据增强、迁移学习和度量学习^[12]来进行研究。文献[13]提出一种基于阶次跟踪核心假设的数据增强算法,利用重采样技术模拟不同转速和工作载荷下的数据,在小样本工作条件迁移场景中,得到了更佳的表现。此外,文献[14-16]采用迁移学习方法,先将模型放在源域数据中进行学习,然后将从源域中学习到的知识迁移到目标域,通过这个方法,能够有效解决数据不充足的问题,文献[17]在原型网络中引入了混合自注意力机制,在样本不充足的情况下实现风电齿轮箱高精度故障诊断。上述方法虽然取得了一定的成果,但仍存在一些局限。比如迁移学习方法需要大量的源域数据进行知识学习,故障诊断性能依赖于目标域和源域的分布和迁移方法;数据增强方法有可能破坏原始数据的结构,导致诊断结果过拟合或者引入噪声数据;而度量学习在嵌入空间中进行简单的距离度量,在面对复杂场景时,故障诊断准确率也不高。

孪生网络^[18]由于其独特的网络结构,能够对同类样本的相似性与非同类样本间的差异性特征进行学习,因而可以在数据有限的情况下获得较强的泛化能力。文献[19]提出了一种基于深度卷积神经网络和孪生神经网络模型的故障诊断方法,通过利用相同或不同类别的样本进行学习来实现有限数据轴承故障诊断,其模型的性能在多组实验中超过了基线模型。文献[20]等提出了一种新的基于有限训练样本的故障诊断的孪生网络模型,在孪生网络模型中引入了残差块来进行小样本学习,进一步提高了孪生网络在不同工作负载和噪声环境下故障诊断的准确性。虽然孪生网络在轴承故障诊断领域获得成功的应用,但是还处于起步阶段,有待进一步深入研究。

孪生网络和关系网络^[21]都是度量学习的经典模型,孪生网络所提取的特征向量之间的距离度量通常采用线性度量函数或者预先固定好的度量函数,如欧氏距离、余弦距离,但此类固定距离度量函数过度依赖特征提取网络学习到的特征嵌入空间质量。而关系网络模型则是通过构建神经网络来计算两个样本之间的距离从而分析匹配程度,可以看成提供了一个可学习的非线性分类器用于判断关系,面对新任务时其泛化性能更好。因此,本文将孪生神经网络作为故障诊断的基本网络框架,结合关系网络的优势,同时引入混合自注意力机制(HSA, hybrid self-attention),提出了一种混合自注意力孪生网络模型的轴承故障诊断方法。先通过使用一维卷积单元和 HAS 级联组成特征提取网络,并提取到更具判别性的特征;然后通过神经网络度量样本特征向量,将其与特征提取网络联合训练,使模型自适应地根据输入样本的特征调整度量方式,进而提高模型故障诊断的泛化能力和准确率。

1 孪生网络与混合自注意力机制

1.1 孪生神经网络

孪生神经网络使用两个权值共享的特征提取网络同时接收两个输入样本,特征提取网络通常可由卷积神经网络^[22]、循环神经网络等组成。特征提取网络会分别提取出样本的特征向量,然后对特征向量进行距离度量,通过最小化相同类别之间 $loss$, 最大化不同类别 $loss$ 进行迭代训练得到一个可以判断两个物体是否相似的模型。其结构如图 1 所示。

两个子网络分别接收两个输入 x_1 与 x_2 , 提取得到它们的特征向量 $G_w(x_1)$ 和 $G_w(x_2)$, w 为两个特征提取网络的共享参数。然后通过距离度量方式计算两个输出向量的距离 $d(x_1, x_2)$, 最后输出相似度 E_w 。当两个样本属于相同类别时,相似度趋近于 1; 当两个样本属于不同类别时,相似度趋近于 0。




图 1 孪生神经网络结构

孪生网络输入的样本对包含来自相同或不同类别的两个样本。对于 n 个类别的分类任务, 每个类别有 m 个训练样本。相同类别的样本对数量为:

$$nA_m^2 = n \times m \times (m - 1) \quad (1)$$

不同类别的样本对数量为:

$$A_n^2 C_m^1 C_m^1 = n \times (n - 1) \times m \times m \quad (2)$$

采用样本对这种策略可以显著增加用于训练模型的数据量, 并有效减少对样本的依赖。

1.2 混合自注意力机制

自注意力机制是一种特殊的注意力机制, 其关注输入序列内部的依赖关系, 减少了外部信息的干扰, 通过特征的内部相关性来获得更好的特征表示。本文引入了自注意力机制, 以提高轴承振动信号的特征利用率, 并基于位置自注意力和通道自注意力进行矩阵融合构建混合自注意力模块 (HSA), 利用输入项之间的相互关系, 自行决定分配输入项权重大小。以提高滚动轴承振动信号的特征利用率, 最佳地捕捉信号特征的内部相关性。HAS 结构如图 2 所示。

在位置自注意力 (PSA, positional self-attention) 模块中, 首先通过 3 个不同的卷积层得到 3 个 $M \times L$ 的特征图 B, C, D 。其中 M 表示通道数, L 表示特征图长度。随后将 B 的转置矩阵 B^* 与 C 相乘, 通过应用 SoftMax 层进行归一化处理, 得到 $L \times L$ 权重矩阵 S :

$$s_{ji} = \frac{\exp(B_i^* \cdot C_j)}{\sum_{i=1}^L \exp(B_i^* \cdot C_j)} \quad (3)$$

其中: s_{ji} 表示位置 i 和 j 上的特征点之间的相关性。

然后将特征图 D 和权重矩阵 S 的转置相乘, 得到 PSA 矩阵。最后, PSA 的输出 E 是 PSA 矩阵和原始特征矩阵的加权和。具体计算如下:

$$E_i = \alpha \sum_{i=1}^L (S_{ji} \cdot D_i) + A_j \quad (4)$$

其中: α 表示分配给 PSA 矩阵的权重, 初始值为 0, 然后逐渐学习到更多的权重。 PSA 矩阵中具有较高相似性的位置彼此将会获得更高的权重, 使得模型关注具有




图 2 HSA 结构

更相似特征的位置信息, 从而提取具有更多故障特征的信息。

对于通道自注意力 (CSA, channel self-attention) 模块, 首先对特征图及其转置矩阵进行矩阵乘法, 随后, 通过应用 SoftMax 层进行归一化处理, 得到通道权重矩阵 X :

$$x_{ji} = \frac{\exp(A_j \cdot A_i^*)}{\sum_{i=1}^M \exp(A_j \cdot A_i^*)} \quad (5)$$

其中: x_{ji} 表示着第 i 个通道对第 j 个通道的影响。随后, 将权重矩阵和输入 A 相乘得到 CSA 矩阵。最后, 将 CSA 矩阵和输入 A 相加后, CSA 模块的最终输出结果如下:

$$E_j = \beta \sum_{i=1}^L (x_{ji} \cdot A_i) + A_j \quad (6)$$

其中: β 表示分配给 CSA 矩阵的权重, 初始值为 0, 然后逐渐学习到更多的权重。特别地, 具有较高相似度的通道将在 CSA 矩阵中具有较高的权重。该策略通过对通道的依赖性进行建模, 有助于提高特征识别。

2 本文算法

2.1 算法框架

本文以孪生网络为主干模型, 根据轴承振动数据的特点, 重新设计了特征提取和距离度量部分, 提高滚动轴承的故障诊断准确率。算法框架如图 3 所示。

其中: x_i 和 x_j 为相同类别或不同类别的输入样本对, x_k 为待测样本; S_A, S_B, S_C 和 S_D 为测试集中某一个类别所有样本的集合; R_A, R_B, R_C 和 R_D 为距离度量模块输出的 x_k 与 S_A, S_B, S_C 和 S_D 之间的相似度, A, B, C 和 D 为不同类别的标签。在训练过程中从训练集中随机选取相同或者不同类别的样本对模型进行训




图3 本文算法框架

练, 通过将得到的相似度值代入损失函数来更新参数, 等模型训练完成后, 选取模型性能最优的参数用于故障诊断。在测试过程中将训练样本中各个类别的样本输入到已训练好的模型中, 得到每个类别特征集合, 然后将 x_k 输入到特征提取网络得到 x_k 的特征向量后, 分别将 x_k 的特征向量和各个类别的特征向量拼接后输入到距离度量模块得到 x_k 与每个类别的相似度, 通过比较选择相似度最高的类别作为 x_k 的分类类别。

2.2 特征提取模块

本文搭建的特征提取模块由两个结构和参数完全相同的特征提取网络组成。具体结构如图4所示。




图4 特征提取网络结构

为防止参数过多, 特征提取网络采用四层卷积来提取特征向量。首先使用一个卷积核大小为 64×1 的大核

卷积来提取样本的全局特征, 然后分别使用大小为 3×1 的卷积核来对特征进行细化, 获得更好的局部特征表示。在每次卷积操作过后, 均采用 ReLu 激活函数来提高模型的非线性变换, 并且使用批量归一化 (BN) 操作来提升网络的收敛速度。为了提高模型的特征提取能力, 提取到更具判别性的特征信息, 在每次 max pooling 操作过后加入一个 HAS 模块突出故障特征信息。最后使用 flatten 层将提取到的特征输出至具有 100 个神经元的全连接层后输出得到特征向量。

2.3 距离度量模块

距离度量模块的作用主要是映射特征向量之间的关系。当两个样本相同时, 输出值应该为 1, 当两个样本不不同时, 输出值应该为 0。标准的孪生网络通常采用欧式距离作为度量函数, 但此类固定距离度量函数需要嵌入特征提取模块并将样本特征准确地提取至目标子空间, 过度依赖特征提取网络的特征提取效果, 在面对轴承故障数据工况变化时, 仍然得不到较高的准确率, 因此本文参考关系网络样本的度量方式, 使用神经网络结构替换孪生网络固定距离的度量方式, 通过训练神经网络, 让模型能够灵活地度量不同工况下的特征向量。距离度量模块结构如图5所示。




图5 距离度量模块

将特征提取模块输出的特征向量拼接后输入至距离度量模块后, 距离度量模块首先通过两个卷积层对其进行处理, 然后使用全局均值池化 (GAP, global average pooling) 代替多层全连接减少模型参数, 缓解过拟合问题。最后经过全连接层后利用 Sigmoid 激活函数把相似度值变换到 $[0, 1]$ 中, 相似度的计算方式为:

$$R_{i,j} = g\{c[f(X_i), f(X_j)]\} \quad (7)$$

其中: $R_{i,j}$ 为输入样本 X_i 和 X_j 的相似度, $g()$ 为距离度量模块的输出, $f()$ 为特征提取网络的输出, c 为样本输出特征的拼接。

为同时满足孪生网络中特征提取模块和距离度量模块的约束条件, 定义损失函数为:

$$L_{\text{loss}} = y(1 - R)^2 + \sigma(1 - y)(0 - R)^2 \quad (8)$$

其中: y 表示样本的相似度标签, 样本相同时取值为 1, 不同取 0。 σ 为惩罚系数, 用来调节模型训练性能, 当损失函数偏差较大时, 通过 σ 来调节模型的参数更新过程。

3 实验与分析

3.1 实验设置

本文使用 CWUR 的滚动轴承数据集对所提方法在

小样本下的有效性进行了验证, 并进一步使用 PU 数据集验证模型的泛化性能。

本文实验使用 i7-10700 CPU@ 2.90 GHz、16 GB 内存的计算机来进行训练和测试。使用 TensorFlow 框架搭建模型。在实验中采用默认设置的 Adam 优化器优化更新参数, Batch-size 为 32。本文模型的参数设置如表 1 所示, 其中, 卷积层: (卷积核尺寸, 卷积步长, 卷积核数量, padding 策略), 池化层: (池化窗口大小, 池化步长, padding 策略)。全连接层参数表示神经元数量。

表 1 模型参数设置

网络	网络结构	主要参数	输出尺寸
特征提取网络	输入层	—	2 048×2
	卷积层	(64×1,16×1,16,same)	128×16
	最大池化层	(2×1,2×1,valid)	64×16
	HSA	—	64×16
	卷积层	(3×1,1×1,32,same)	64×32
	最大池化层	(2×1,2×1,valid)	32×32
	HSA	—	32×32
	卷积层	(3×1,1×1,64,same)	32×64
	最大池化层	(2×1,2×1,valid)	16×64
	HSA	—	16×64
	卷积层	(3×1,1×1,64,same)	16×64
	最大池化层	(2×1,2×1,valid)	8×64
	HSA	—	8×64
	全连接层	100	1×100
距离度量网络	输入层	—	100×2
	卷积层	(3×1,2×1,64,same)	50×64
	卷积层	(3×1,2×1,64,same)	25×64
	全局均值池化	—	1×64
	全连接层	64	1×64

3.2 CWUR 数据集验证

3.2.1 CWUR 数据集介绍

CWRU 数据集是世界公认的轴承故障诊断标准数据集。我们选择 CWRU 轴承数据集集中的 12 k 驱动端轴承故障数据作为原始实验数据。本文每个样本都是从两个振动信号中提取的, 电机转速为 1 730 rpm, 通过大

小为 2 048 个点的滑动窗口以 80 个点的移位步长滑动来生成样本。轴承故障位置有 3 种类型: 内圈故障、滚珠故障以及外圈故障。每个故障类型有 3 种故障直径: 分别为 0.007、0.014 和 0.021 英寸, 包括健康状态, 总共有 10 类故障类型。实验数据集如表 2 所示。为了研究所提方法在有限数据下故障诊断的性能, 从每种故障类别样本中分别随机挑选了 6、9、15、30、50 个样本构造了 5 种训练集。

3.2.2 实验及分析

实验选取未改进的孪生网络、CNN、宽卷积神经网络 (WDCNN)、ISNN^[23]、多尺度深度卷积神经网络 (MS-DCNN)、LSTM-CNN、DBN 和 AE 作为对比方法。为了消除实验结果的随机性, 我们将算法训练和测试实验重复 5 次, 然后取准确率平均值。各种方法在测试集的准确率如表 3 所示。

由表 3 可知, 对于具有 60 个样本的训练集 A, CNN 的准确率最低, 不到 50%, 孪生网络准确率仅有 66.3%, DBN 和 AE 两种方法的准确率也只有 70% 左右, LSTM-CNN 和 WDCNN 方法准确率为 75.0% 左右, ISNN 的表现较好, 准确率达到 80.3%, 而本文提出的方法在仅有 60 个样本时也可以达到 84.8%, 远高于其他几种方法。对于具有 90 个样本的训练集 B, 所有方法的准确率有所提高, 其中 CNN 的准确率提升最大, 达到 54.9%, 但仍小于其他方法。本文所提方法准确率为 88.2%, 仍高于其他方法。随着样本数量的增加, 每种方法的准确率都在提升, 当样本数量增加到 500 (训练集 E) 时, 各种方法都能得到较高的准确率, 除了 CNN 方法只有 85.4% 以外, 其他方法都达到了 90% 以上, MS-DCNN 和 LSTM-CNN 两种算法的准确率分别为 93.4% 和 94.7%, WDCNN 和 ISNN 的准确率分别为 95.0% 和 96.1%, 已经非常接近本文所提方法 97.5%, 这些性能比较表明, 当使用有限的数据集进行训练时, 本文提出的方法仍然能够较好地提取故障特征进行故障诊断, 达到较高的诊断准确率, 具有更好的性能, 并且随着训练样本数量的增多, 模型的训练

表 2 实验数据集

故障类型	正常	滚动体故障			内圈故障			外圈故障		
故障直径	0	0.007	0.014	0.021	0.007	0.014	0.021	0.007	0.014	0.021
故障标签	0	1	2	3	4	5	6	7	8	9
训练集 A	6	6	6	6	6	6	6	6	6	6
训练集 B	9	9	9	9	9	9	9	9	9	9
训练集 C	15	15	15	15	15	15	15	15	15	15
训练集 D	30	30	30	30	30	30	30	30	30	30
训练集 E	50	50	50	50	50	50	50	50	50	50
测试集	50	50	50	50	50	50	50	50	50	50

表 3 各种方法在测试集上的准确率 %

训练集	A	B	C	D	E
CNN	45.2	54.9	68.7	75.0	85.4
AE	69.4	75.1	81.5	84.4	90.7
MS-DCNN	73.4	76.3	79.0	87.2	93.4
LSTM-CNN	76.1	80.6	83.1	89.5	94.6
DBN	72.8	74.7	79.6	86.2	91.4
孪生网络	66.3	70.7	74.2	82.9	90.2
WDCNN	74.7	78.4	87.9	90.8	95.0
ISNN	80.3	84.7	88.4	92.7	96.1
本文方法	84.8	88.2	94.7	96.2	97.5

结果逐渐趋于稳定，模型的故障诊断准确率不断提高。本文所提的方法性能仍略高于其他方法。

为了直观地理解所提方法对原始信号的特征提取过程，使用 T-SNE 降维的方法对提取的特征进行可视化。相同类别的样本更好地聚集在一起，不同类别样本之间也有较大间隔，区分明显，说明了所提方法能够提取有效特征，从而实现小样本条件下的故障诊断。

为了观察所提方法对每类轴承故障的识别情况，以每类 15 个训练样本（训练集 C）为例，绘制了 CNN、DBN、LSTM-CNN 和所提方法在测试集 1 上诊断结果

的混淆矩阵，如图 7 所示。其中横坐标表示预测的故障类型标签，纵坐标表示真实故障类型标签，主对角线为预测正确的样本数，每类共有 50 个测试样本。

从图 6 可知，在每类故障有 15 个训练样本的情况下，3 种对比方法均产生了不少错分情况，故障诊断效果较差，而本文方法则明显好于对比方法。具体来说，从图 6（a）可以看出，用 CNN 进行诊断时，每个类别均有较多的错分的情况，特别是故障标签为 6 的故障类型，错分样本个数达到了一半。图 6（b）和（c）表明 DBN 和 LSTM-CNN 的效果好于 CNN 方法，对大部分故障类别都能正确分类 40 个左右。相比之下，从图 6（d）可以看出，本文方法能显著改善各类故障的错分情况，除了 2 类和 3 类被错分较多，其余故障类型均有 45 个以上的样本被正确识别。以上分析表明，在训练样本较少的情况下，几种对比方法均难以对轴承故障进行有效诊断，而本文方法能够有效提升故障诊断效果，实现小样本情况下的轴承故障诊断。

3.3 PU 数据集验证

3.3.1 PU 数据集介绍

PU 轴承数据集由德国帕德博恩大学提供，用于数据驱动的轴承故障诊断。数据集使用 32 个 6 203 型轴




图 6 不同方法在训练集 C 上诊断结果的混淆矩阵

承, 包括 12 个人工损坏轴承, 14 个经加速寿命试验得到的自然故障轴承, 以及 6 个健康轴承。为了进一步所提方法在轴承故障方面的泛化能力, 我们从 32 个类中选择 13 个代表性类, 即使用 1 个健康轴承、8 个人工损伤轴承和 5 个自然故障轴承的数据来进行研究, 并使用数据集上两种不同转速下 (900 rpm、1 500 rpm) 的实验数据来进行验证。数据包括人工模拟故障数据、健康轴承数据和自然故障数据, 表 4 列出了这些选定类的完整信息。本文使用大小为 2 048 个点的滑动窗口以 80 个点的移位步长滑动来生成样本, 在两种转速下每个类别采样 20 样本, 按照 7 : 3 将数据划分为训练集和测试集。实验选取未改进的孪生网络以及 CRWU 数据集中表现较好的 WDCNN、LSTM-CNN 和 ISNN 方法进行比较验证所提方法的泛化性能。

表 4 人工故障及实际故障轴承数据

名称	故障位置	故障原因	严重等级
KA01	OR	electrical discharge	1
KA03	OR	electric engraver	2
KA05	OR	electric engraver	1
KA07	OR	Drilling	1
KA08	OR	Drilling	2
KI01	IR	electrical discharge	1
KI03	IR	electric engraver	1
KI05	IR	electric engraver	2
K001	Healthy	—	0
KA04	OR	fatigue; pitting	1
KB23	OR+IR	fatigue; pitting	2
KB27	OR+IR	Indentations	1
KI04	IR	fatigue; pitting	1

3.3.2 实验及分析

实验结果表 5 所示。900 rpm→900 rpm 表示采用 900 rpm 转速下的轴承故障数据作为训练集, 900 rpm 转速下的故障数据作为测试集。

表 5 不同方法在数据集上的准确率 %

模型	900 rpm→ 900 rpm	900 rpm→ 1 500 rpm	1 500 rpm→ 1 500 rpm	1 500 rpm→ 900 rpm
LSTM-CNN	84.6	81.9	81.4	79.8
WDCNN	87.1	85.6	83.9	82.7
ISNN	89.9	88.1	86.2	83.9
孪生网络	82.7	81.4	81.5	78.5
本文方法	94.5	92.7	92.8	89.4

从实验结果可以看出, 当训练集和测试集工况没有变化时, 所有方法的准确率都达到了 80% 以上。孪生网络、LSTM-CNN 和 WDCNN 方法诊断精度都较低, 表现较好的 ISNN 方法也只有 89.9% 和 86.2 的准

确率, 而本文方法准确率有 94.5% 和 92.8%, 性能高于其他方法, 在训练集和测试集工况变化时, 其他方法诊断性能变得更差, 尤其是 LSTM-CNN 和孪生网络, 在 1 500 rpm→900 rpm 情况下准确率已经低于 80%, 而表现较好的 WDCNN 和 ISNN 也只有 83.9% 和 82.7%, 而本文方法准确率达到 89.4%, 高于其他方法, 效果最好。在 1 500 rpm→900 rpm 的实验中, 孪生网络和 LSTM-CNN 准确率较低, 仅有 81.9% 和 81.4%, ISNN 和 WDCNN 的准确率为 88.1% 和 85.6%, 而本文方法诊断精度为 92.7%, 准确率仍然较高, 相比其他方法准确率下降幅度也较少, 仅下降 1.8 个百分点。通过以上分析, 本文方法相比其他方法, 表现出了良好的泛化性能, 能够有效实现跨工况轴承故障的有效分类。

3.4 消融实验

为了验证所提方法中 HAS 模块和使用神经网络度量相似性对小样本条件下故障诊断的影响程度。我们在 CWRU 轴承数据集上自然轴承故障诊断实验下进行消融实验, 模型由 60、150 和 300 个训练样本的有限数据进行训练。相似性度量基准为孪生网络常用的欧氏距离。基准特征提取网络为未级联 HAS 的 CNN 网络。消融实验结果如表 6 所示。

表 6 消融实验

模型	60	150	300
CNN+欧式距离(Baseline)/%	66.3	74.2	82.9
CNN+神经网络/%	70.6	79.7	85.5
CNN+HAS+欧式距离/%	78.2	88.1	90.3
CNN+HAS+神经网络(本文方法)/%	84.8	94.7	96.2

从实验结果可以看出两个模块都能提高分类准确率。仅在特征提取网络级联 HSA 模块后, 60、150 和 300 个样本情况下准确率均有 10 个百分点左右的提升了; 仅使用神经网络代替欧式距离以后, 60、150 和 200 个样本情况下准确率分别提升了 4.3、5.5、2.6 个百分点, 提升相对于前者较小, 因为相似性度量准确性较依赖于特征提取网络映射的特征向量质量。同时加入两个模块后在 60、150 和 300 个样本情况下准确率都得到了较大提升, 最高的达到了 20 个百分点。相比基准模型, 这两个模块的加入能够明显提高故障诊断的准确率, 有效地实现小样本下的轴承故障诊断。

为了更加直观地分析所加模块的性能, 我们绘制出了模型训练过程中训练迭代测试准确度曲线, 如图 7 所示。

从图 7 可以看出, 在迭代次数较少时, 本文方法便能有效提取故障特征, 得到较好的故障诊断效果, 而单独加入 HAS 或者神经网络对准确率的提升都不大, 随




图 7 不同模块的迭代过程对准确率的影响

随着迭代次数的增加, 本文方法能够得到更高的准确率, 略高于单独加入 HAS 或者神经网络, 远高于 Baseline。通过以上分析可以得出, 同时使用 HAS 和神经网络改进孪生网络能够有效提升模型故障诊断的性能, 得到较好的故障诊断效果, 实现有限故障数据下的轴承故障诊断。

4 结束语

针对小样本条件下传统应用于滚动轴承故障诊断的深度学习算法特征提取不充分以及在变工况下诊断精度不高, 泛化性差的问题。本文基于孪生网络模型, 通过引入自注意力机制, 利用 CNN 和 HAS 级联加强特征提取, 使用神经网络构成的相似性度量模块度量相似性, 增强模型的泛化性能, 实现小样本条件下滚动轴承故障诊断算法模型, 实验结果表明, 该模型在训练样本较少的情况下, 仍能有较高的诊断准确率, 性能优于 CNN、DBN 和 LSTM-CNN 等方法, 并且当测试数据工况变化时也能表现出更好泛化性。但是由于引入 HAS 机制导致参数和运算量增加, 训练时间更长, 在未来的工作中, 将进一步提高模型诊断准确率和优化模型结构, 减少模型训练时间。

参考文献:

- [1] RAI A, UPADHYAY S. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings [J]. Tribology International, 2016, 96: 289 - 306.
- [2] 沈保明, 陈保家, 赵春华, 等. 深度学习在机械设备故障预测与健康管理的综述 [J]. 机床与液压, 2021, 49 (19): 162 - 171.
- [3] YUAN J, JIANG H, ZHAO Q, et al. Dual-mode noise-reconstructed EMD for weak feature extraction and fault diagnosis of rotating machinery [J]. IEEE Access, 2019, 7:

173541 - 173548.

- [4] WANG Y, LI Q, ZHOU F, et al. A new method with Hilbert transform and slip-SVD-based noise-suppression algorithm for noisy power quality monitoring [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 68 (4): 987 - 1001.
- [5] WANG H, XU J, YAN R, et al. A new intelligent bearing fault diagnosis method using SDP representation and SE-CNN [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69 (5): 2377 - 2389.
- [6] 张雪英, 栾忠权, 刘秀丽. 基于深度学习的滚动轴承故障诊断研究综述 [J]. 设备管理与维修, 2017 (18): 130 - 133.
- [7] ZHANG W, PENG G, LI C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals [J]. Sensors, 2017, 17 (2): 425 - 466.
- [8] LU C, WANG Z, ZHOU B, et al. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification [J]. Advanced Engineering Informatics, 2017, 32: 139 - 151.
- [9] MINGHANG Z, SHISHENG Z, XUYUN F, et al. Deep residual shrinkage networks for fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (7): 4681 - 4690.
- [10] 司伟伟, 岑健, 伍银波, 等. 小样本轴承故障诊断研究综述 [J]. 计算机工程与应用, 2023, 59 (6): 45 - 56.
- [11] LI F, ROB F, PIETRO P. One-shot learning of object categories. [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (4): 594 - 611.
- [12] 李新叶, 龙慎鹏, 朱婧. 基于深度神经网络的少样本学习综述 [J]. 计算机应用研究, 2020, 37 (8): 2241 - 2247.
- [13] HU T H, TANG T, LIN R L, et al. A simple data augmentation algorithm and a self-adaptive convolutional architecture for few-shot fault diagnosis under different working conditions [J]. Measurement, 2020, 156: 107539.
- [14] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究 [J]. 西安交通大学学报, 2021, 55 (10): 30 - 37.
- [15] 张根保, 李浩, 冉琰, 等. 一种用于轴承故障诊断的迁移学习模型 [J]. 吉林大学学报 (工学版), 2020, 50 (5): 1617 - 1626.
- [16] LI X, HU Y, LI M, et al. Fault diagnostics between different type of components: a transfer learning approach [J]. Applied Soft Computing Journal, 2020, 86: 105950.

(下转第 36 页)