

基于小样本学习的滚动轴承故障检测

曹莹莹, 郇战, 陈震, 陈瑛

(常州大学微电子与控制工程学院, 常州 213000)

摘要: 轴承故障类型复杂, 并且在不同工况下每种故障类型都很难获得足够的训练样本。因此, 本文提出一种基于深度神经网络的小样本学习分类算法, 引入第1层具有宽卷积核网络(Convolutional neural network with training interference, TICNN)作为孪生网络的子网络用于提取特征, 减少工业环境噪声影响。孪生网络是一种常用于小样本学习的结构, 通过输入相同或不同类别的样本对进行训练, 学习不同属性样本与特征之间的映射关系, 并采用相似度进行度量。测试样本通过寻找最近邻的类别来实现分类。在标准凯斯西储大学轴承故障诊断基准数据集上的实验结果表明, 在数据有限的情况下, 本文模型在故障诊断中表现出更好的效果。当使用最少的训练数据在不同的噪声环境中进行测试时, 本文小样本学习模型的性能超过了具有合理噪声水平的基线模型, 故障诊断准确率达到94.41%。当在具有新故障类型或新工作条件的测试集上进行评估时, 本文模型仍然有效。

关键词: 滚动轴承故障分类; 小样本学习; 孪生网络; 有限样本; 卷积神经网络

中图分类号: TP391 **文献标志码:** A

Rolling Bearing Fault Detection Based on Few-Shot Learning

CAO Yingying, HUAN Zhan, CHEN Zhen, CHEN Ying

(School of Microelectronics and Control Engineering, Changzhou University, Changzhou 213000, China)

Abstract: Bearing fault types are complex, and it is difficult to obtain enough training samples for each fault type under different working conditions. Convolutional neural network with training interference (TICNN) with wide convolutional kernel is introduced as the subnetwork of the Siamese network used to extract features, reducing the impact of industrial environment noise. Siamese network is a structure commonly used for few-shot learning. By inputting the same or different categories of samples for training, the mapping relationship between different attribute samples and features is learned, and the similarity between samples is used as measure index. The test sample is classified by finding the class of the nearest neighbor. Experimental results on the standard Case Western Reserve University (CWRU) bearing fault diagnosis benchmark dataset show that, in the case of limited data, the proposed model shows better results in fault diagnosis. The performance of the proposed few shot learning model exceeds the baseline model with a reasonable noise level when testing with the least training data in different noise environments, and the accuracy of fault diagnosis reaches 94.41%. When evaluating on test sets with new fault types or new working conditions, the proposed model also performs well.

Key words: rolling bearing fault classification; few-shot learning; Siamese network; limited sample; convolutional neural network

引言

滚动轴承作为工业设备中最常用的部件之一,其故障诊断分类是滚动轴承性能状况评估和维护的关键问题。为了解决传统的滚动轴承故障诊断方法多依赖于人工经验和感觉,效率较低,而且容易出现误判等问题,人们开始将机器学习技术引入滚动轴承故障诊断领域,通过对大量的轴承振动信号进行处理和分析,实现对轴承的故障诊断和分类。

目前,滚动轴承故障诊断分类现状主要包括以下3个方面。首先,各国研究机构和企业已经开始开展滚动轴承故障诊断分类的研究和应用,如美国斯坦福大学机械工程系、德国西门子、日本NTN等,并且取得了一定的研究成果和应用实践。其次,目前机器学习技术在滚动轴承故障诊断分类领域中得到了广泛的应用,如支持向量机、神经网络和深度学习等。刘飞等^[1]提出了一种基于迁移学习与深度残差(Transfer learning residual network, TL-ResNet)网络的快速故障诊断算法,提高了模型的训练速度和故障诊断准确率,并具有良好的泛化性能。贾峰等^[2]针对目标域中额外故障样本对滚动轴承故障诊断精度的影响问题,提出了采用深度迁移学习与自适应加权的轴承故障诊断方法。李秋婷等^[3]提出了基于卷积注意力(Convolutional block attention module, CBAM)和残差网络(Residual network, ResNet)的滚动轴承故障诊断CAR(CBAM and ResNet)模型,以及基于Transformer的滚动轴承故障诊断模型,有效识别滚动轴承的故障。Yu等^[4]提出了一种基于经验模态分解(Empirical mode decomposition, EMD)能量熵和神经网络的滚动轴承故障诊断方法,EMD与神经网络的结合为滚动轴承故障的智能诊断提供了有用的工具。Chen等^[5]提出了一种基于循环谱相干(Cyclic spectral coherence, CSCoh)二维图表示和卷积神经网络(Convolutional neural network, CNN)的故障诊断方法。这些技术对大量数据学习和训练,能够对轴承不同故障类型进行准确的分类诊断。此外,滚动轴承故障诊断分类还涉及多种处理和分析技术,如振动信号分析、频域分析、小波分析^[6]和时频分析^[7]等;还有一些非线性动力分析方法,如样本熵^[8]、模糊熵^[9]和排列熵^[10]等。这些技术能够从不同角度对滚动轴承的故障进行分析,提高诊断的准确性和可靠性。然而,当前滚动轴承故障诊断分类还面临着一些问题和挑战,如数据的采集和处理难度大、信号复杂多变和分类精度低等。因此,如何提高滚动轴承故障诊断分类的准确性和效率,仍然是当前研究和应用中需要解决的问题。

由于轴承样本数据有限,而传统方法需要较多样本数据。因此,本文提出一种基于小样本学习框架的滚动轴承故障诊断分类方法,通过对轴承振动信号进行处理和分析,实现对轴承的故障诊断和分类,并探讨该方法在实际应用中的优势和局限性。

1 相关工作

1.1 小样本学习

小样本学习^[11-13]是近几年兴起的一个研究领域,顾名思义,就是通过少量的样本训练出较好的模型。传统深度神经网络提取复杂数据和学习高级特征的能力已经被证明,但这种学习方式需要大量训练数据,效率很低,而小样本学习旨在解决这些问题。

在小样本学习中,包括支持集(Support set)和查询集(Query)。根据类别数量和样本数量的不同,支持集被定义为 K -way N -shot 支持集。这里, K -way 表示支持集中存在 K 个类别, N -shot 表示每个类别中存在 N 个样本。小样本分类的准确率也会受支持集类别数和样本数的影响。样本数不变,类别数量的增加会导致分类准确率降低;而当类别数量不变,样本数增加时,分类准确率会随之提高。需要说

明的是,支持集只是用来在预测分类时提供额外的信息,这样可以帮助模型识别出原本不属于训练集中的数据。因此支持集和训练集是不相等的,训练集需要的是一个非常大的数据集,其中每一类别都包含非常多的样本数,当训练集足够大就可以训练一个神经网络。而支持集却很小,每一类别只包含一个或几个样本数,不足以训练神经网络。

1.2 孪生网络

孪生网络就是判断两张图片相似程度的深度神经网络。其使用同一个深度神经网络对两段输入信号分别提取特征,得到2个向量,通过相似度函数对2个向量进行距离度量,从而判断2段输入信号的相似程度。孪生网络的网络结构如图1所示。孪生网络由2个结构相同、共享权值的子网络构成。孪生网络的2个输入端分别接收两段振动信号 X_1 、 X_2 。其中 X_1 经过网络 $F_w(X)$ 将其转化为向量 $F_w(X_1)$; X_2 经过网络 $F_w(X)$ 将其转化为向量 $F_w(X_2)$ 。经过两个子网络输出的2个向量又经过距离度量计算得到两个输出向量的距离 D_T ,孪生网络损失函数为

$$L(T, (Y, X_1, X_2)) = \frac{1}{2N} \sum_{n=1}^N Y D_T^2 + (1 - Y) \max(m - D_T, 0)^2 \quad (1)$$

式中: $D_T(X_1, X_2) = \|X_1 - X_2\|_2 = \left(\sum_{i=1}^n (X_1^i - X_2^i)^2 \right)^{\frac{1}{2}}$ 为振动信号 X_1 、 X_2 的距离,其中 i 为第 i 个 mini-batch; N 为样本数; T 为 TICNN 网络; Y 表示输入的样本对是否相似。

当 Y 等于1,即样本相似,此时损失函数为

$$L_S = \frac{1}{2N} \sum_{n=1}^N Y D_T^2 \quad (2)$$

当 Y 等于0,即样本不相似,此时损失函数为

$$L_D = \frac{1}{2N} \sum_{n=1}^N (1 - Y) \max(m - D_T, 0)^2 \quad (3)$$

式中 m 为超参数,控制样本对的距离。具体含义为:当输入样本对距离小于 m 时, L 大于0需要继续训练;当距离大于 m 时, L 为0,训练完毕。 m 一般设定为 $(0,1)$ 的任意数值,本文 m 取经验值0.5,可以得到最佳的分类效果和收敛速度。

2 基于宽卷积核网络的小样本学习

2.1 小样本学习策略

首先,小样本是基于One-shot的多次使用。小样本学习的一般策略就是通过相同或者不同的样本对训练模型,输出的结果为样本对相似的概率。小样本学习的性能通过 K -way N -shot测试来衡量。

在One-shot K -way测试中,设 \hat{x} 为一个分类故障状态的测试样本, S 为支持集,包含 K 个样本振动信号,并且每个标签都含有不同的标签 y ,则支持集表达式为

$$S = \{(x_1, y_1), (x_2, y_2), \dots, (x_K, y_K)\} \quad (4)$$

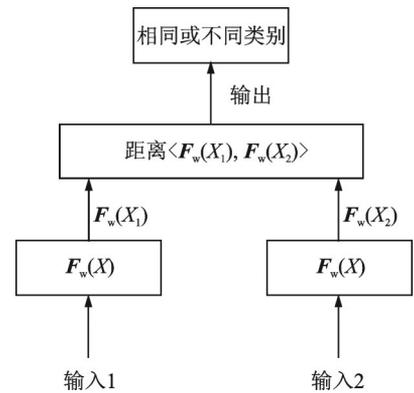


图1 孪生网络结构图

Fig.1 Structure of Siamese network

测试样本 \hat{x} 与支持集中样本相似的概率为

$$P(x_1^i, x_2^i) = \text{sigm}(\text{FC}(D_T^2(x_1^i, x_2^i))) \quad (5)$$

式中 FC 为全连接层。

然后,根据支持集中最相似的样本对测试样本进行分类,如式(6)所示。支持集中与 \hat{x} 求得最大 P 值的 x_c 的类别即为测试样本 \hat{x} 的分类状态,选择出与测试样本最相似的样本当做分类结果。

$$C(\hat{x}, S) = \arg_c \max(P(\hat{x}, x_c)) \quad x_c \in S \quad (6)$$

式中下标 c 表示验证集。

在 N -shot K -way 中,给模型 1 个由 K 个不同类组成的支持集 S ,每个类都有 N 个振动信号样本 (S_1, S_2, \dots, S_N) ,模型分别按照式(6)依次测试样本与支持集中每个类别样本的相似度,再通过式(7)将 K 个类别中 N 个样本计算出的 P 值进行求和,取最大值确定 \hat{x} 是属于支持集中的哪一类。即重复 5 次 One-shot,将每次得到的概率通过式(7)求和,计算得到相同标签最大的概率和,最终模型通过计算确定测试样本属于支持集中哪个类别。

$$C(\hat{x}, (S_1, S_2, \dots, S_N)) = \arg_c \max \left(\sum_{n=1}^N P(\hat{x}, x_{cn}) \right) \quad x_{cn} \in S_n \quad (7)$$

式中 x_{cn} 为验证集中的样本。图 2 是以小样本为框架,加入孪生网络的流程图。使用美国凯斯西储大学(CWRU)原始数据,模型训练时从训练集中抽取相同或不同类别的振动信号样本作为训练样本对输入模型,经过神经网络提取样本特征得到特征向量,经过式(1)度量样本对距离,通过优化器对模型的参数优化,生成以小样本学习为框架的滚动轴承故障诊断模型。

2.2 宽卷积核网络

前文提到孪生网络就是使用权值共享的两个深度学习网络对输入的样本对进行相似度概率的距离计算,从而判断样本对是否属于同一类。由于工业环境中高频噪声比较多,第 1 层为小核的卷积网络极易容易受到影响,因此本文设计了一种第 1 层为宽卷积核提取特征的宽卷积核网络(Convolutional neural network with training interference, TICNN)。用于轴承故障诊断的小样本学习模型就是一个基于 TICNN^[14]的孪生神经网络^[15]。

为了减少工业环境噪声影响,将第 1 层设置成 64×1 的大卷积核,这样也可以更好地提取短时特征。其余 5 层均使用 3×1 的小卷积核,由于卷积核参数少,更利于模型加深网络,同时还可以抑制过拟合。另外,在每层卷积层之后均加入了批量归一化(Batch normalization, BN)的处理,然后进行一个 2×1 的最大值池化。6 次卷积操作除了第 6 层每一层都有零补。基于 TICNN 模型的具体参数如表 1 所示。TICNN 的结构如图 3 中 A 所示,在网络使用第 1 层大卷积之前先对卷积核进行 1 个 Dropout 操作,这对于 TICNN 模型是第 1 种干扰,主要目的是提供 TICNN 训练时不完整的信号,从而达到强化模型应对信号不足甚至缺失时对轴承故障诊断的能力。

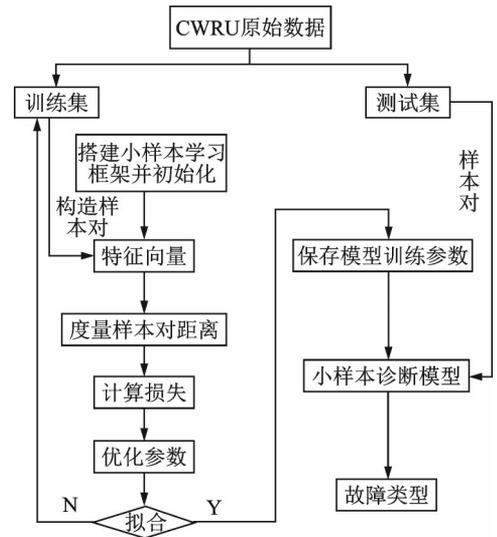


图 2 基于孪生网络的小样本学习流程图

Fig.2 Few-shot learning flow chart based on Siamese network

表1 基于 TICNN 的小样本学习模型参数
Table 1 Parameters of few-shot learning model based on TICNN

No.	Layer type	Kernel size/stride	Kernel number	Output size	Padding
1	Convolution 1	$64 \times 1 / 16 \times 1$	16	256×16	Same
2	Pooling 1	$2 \times 1 / 2 \times 1$	16	128×16	Valid
3	Convolution 2	$3 \times 1 / 1 \times 1$	32	128×32	Same
4	Pooling 1	$2 \times 1 / 2 \times 1$	32	64×32	Valid
5	Convolution 3	$3 \times 1 / 1 \times 1$	64	64×32	Same
6	Pooling 1	$2 \times 1 / 2 \times 1$	64	32×64	Valid
7	Convolution 4	$3 \times 1 / 1 \times 1$	64	32×64	Same
8	Pooling 1	$2 \times 1 / 2 \times 1$	64	16×64	Valid
9	Convolution 5	$3 \times 1 / 1 \times 1$	64	16×64	Same
10	Pooling 1	$2 \times 1 / 2 \times 1$	64	8×64	Valid
11	Convolution 6	$3 \times 1 / 1 \times 1$	64	6×64	Same
12	Pooling 1	$2 \times 1 / 2 \times 1$	64	3×64	Valid
13	Softmax	10	1	10	—

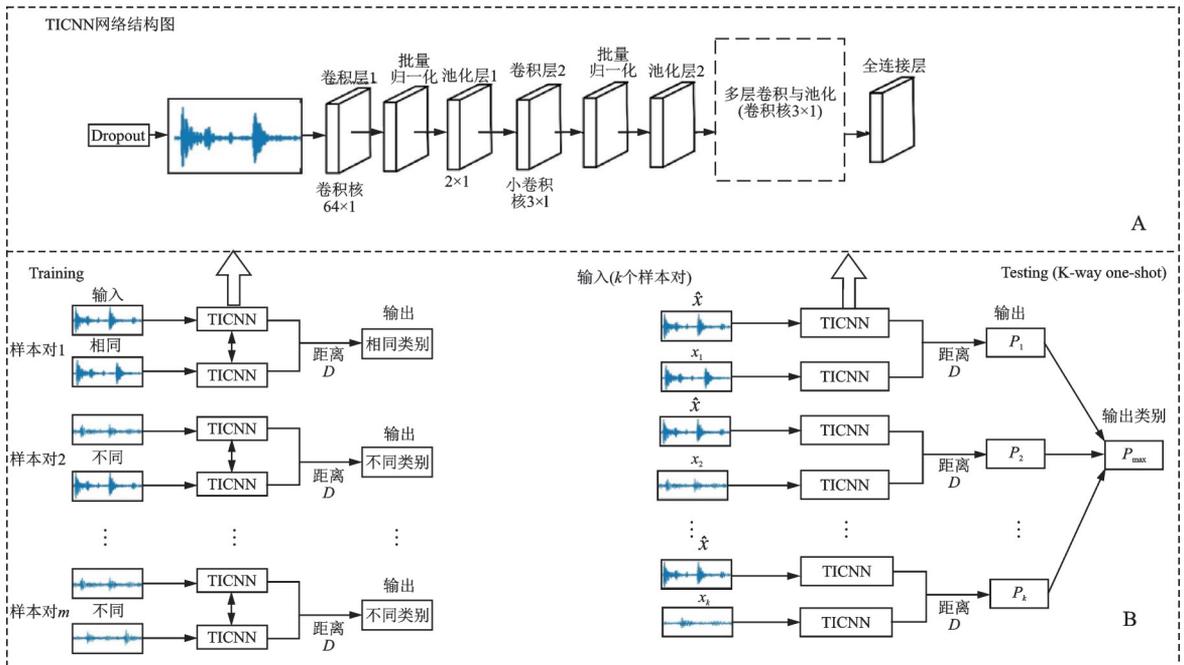


图3 基于 TICNN 的小样本学习的诊断模型

Fig.3 Diagnosis model of few-shot learning based on TICNN

2.3 模型的训练与测试

小样本学习诊断模型如图3中B所示。输入的样本对是由2段相同或者不同类别的振动信号组成。经过以 TICNN 为子网络的孪生网络计算相似度并且输出两者概率距离 P , 经过式(1)计算损失, 再通过

优化器为参数进行优化更新。 K -way N -shot本质就是对 K -way One-shot进行了 n 次操作。1次One-shot的操作得先从训练数据中随机选择数据当做支持集,通过模型从支持集中按照式(6)选择出与测试样本最相似的样本当做分类结果。 K -way N -shot的测试见式(7),也就是 N 次One-shot,此时支持集是由包含 K 个类别,每个类别中有 N 个样本的数据集组成。测试时,本文选择Five-shot,重复5次One-shot,将每次得到的概率通过式(7)求和,计算得到相同标签最大的概率和,最终模型通过计算确定测试样本属于支持集中哪个类别。

3 实 验

3.1 数据集及故障数据

为了验证小样本学习算法在有限轴承数据中性能,本文选用CWRU轴承数据集^[16-17]中的轴承故障数据作为原始实验数据,CWRU数据集测试试验台如图4所示。故障数据按照采样位置分为风扇端和驱动端,按照采样频率分为48 kHz和12 kHz。本文实验选择的是12 kHz采样频率下的驱动端轴承故障数据,如表2所示。按照工况不同分为A、B、C、D四种数据集,其中A、B、C分别代表1、2、3马力的工况,D代表它们的集合。每种采样频率下的轴承故障数据

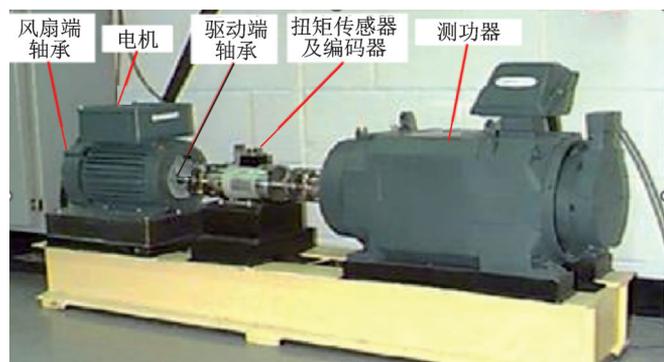


图4 CWRU数据测试实验台

Fig.4 Test bench of CWRU data

按照故障位置不同可以分为内圈、外圈以及滚动体故障3种。每种故障位置又可以按照故障内径分成0.007、0.014、0.028 in(1 in=2.54 cm)3种类别。加上正常故障一共可以得到10种不同类型故障标签。

表2 从CWRU数据集中选取的故障数据

Table 2 Fault data selected from CWRU dataset

故障参数及数据集		正常	滚动体			内圈			外圈		
故障内径/in		0	0.007	0.014	0.021	0.007	0.014	0.021	0.007	0.014	0.021
故障标签		1	2	3	4	5	6	7	8	9	10
数据集 A	训练样本	660	660	660	660	660	660	660	660	660	660
	测试样本	25	25	25	25	25	25	25	25	25	25
数据集 B	训练样本	660	660	660	660	660	660	660	660	660	660
	测试样本	25	25	25	25	25	25	25	25	25	25
数据集 C	训练样本	660	660	660	660	660	660	660	660	660	660
	测试样本	25	25	25	25	25	25	25	25	25	25
数据集 D	训练样本	1 980	1 980	1 980	1 980	1 980	1 980	1 980	1 980	1 980	1 980
	测试样本	75	75	75	75	75	75	75	75	75	75

在实验中,使用一半的振动信号来生成训练样本,其余的用于生成测试样本。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训练样本。测试样本是由相同大小的滑动窗口在没有重叠的情况下滑动生成的。数据集A、B和C分别处于不同的工况下,3个数据集每个数据集都包含660个训练样本和25个测试样本。数据集D处于3种工作条件下,包含1 980个训练样本和75个测试样本。

3.2 训练样本数量对模型性能的影响

本实验的目的主要是评估样本数量对每个训练模型性能的影响,同时也是为了解决有限数据故障诊断中的挑战:由于在工业系统领域方面不允许因为一些突发状况而导致故障,尤其是一些重要零件和重要系统的故障。为了降低工业系统因为轴承损坏进入故障状态,并且测试在本文模型中不同的样本对于性能的影响,本文将数据集D中的测试数据集设置为测试集,并从整个数据集D中的训练样本中分别随机选择60、90、120、200、300、600、900、1 500、6 000个样本,进行了一系列比较实验。对比的方法主要包括:随机森林(Random forest, RF)、支持向量机(Support vector machines, SVM)和基于CNN改进的WDCNN方法^[18]。对于每个训练集,使用整个训练集训练SVM以及RF,并通过多次实验比较,为SVM算法搜索了合适的参数。其他方法使用60%的样本作为训练集,其余40%样本作为验证集,评估了样本数量对每个训练模型性能的影响。对于每个训练集大小,重复样本选择过程5次,生成5个不同的训练集,以处理随机选择的小训练集的偏差。对于每个这样的随机训练样本集,本文将算法训练和测试实验重复4次,以应对算法的随机性。对于每一系列的实验,总共重复了10次,实验结果如图5所示。通过比较,很明显可以看出本文方法比传统机器学习性能优异。4种方法的识别准确率如表3所示。可以看出,当样本数量为90时,本文TICNN-Five-shot的准确率为94.17%,远远高于RF的28.79%以及SVM的46.56%,同时相比较于WDCNN,准确率也提高了3%左右。当样本数量为60、90、120时也都表现得较好,这表明当使用有限的数据集进行训练时,小样本学习算法具有更好的性能;而且,随着样本数量的增加,4种方法的准确率都在稳步上升。此外,当样本数量达到1 500和6 000时,本文方法测试准确率分别达到了99.24%和99.63%。

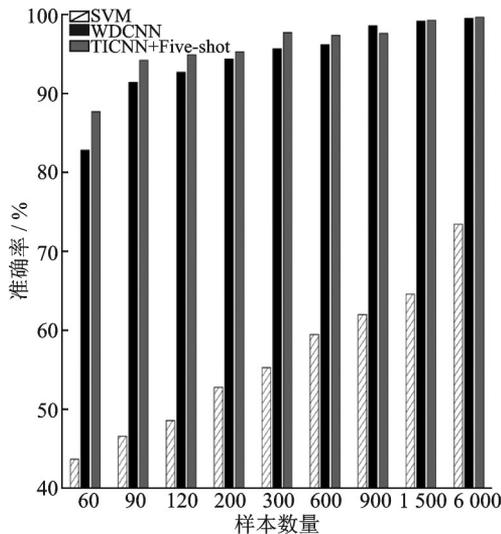


图5 不同样本数量的结果对比

Fig.5 Comparison of results of different sample sizes

表3 不同样本数量的准确率对比

Table 3 Comparison of accuracy of different sample sizes

样本数	RF	SVM	WDCNN	TICNN+Five-shot
60	25.81	43.63	82.80	87.66
90	28.79	46.56	91.37	94.17
120	30.98	48.56	92.66	94.88
200	36.19	52.75	94.32	95.25
300	40.23	55.25	95.65	97.68
600	47.00	59.44	96.14	97.32
900	51.07	61.97	98.55	97.57
1 500	55.84	64.56	99.13	99.24
6 000	72.95	73.41	99.46	99.63

3.3 噪声环境下的模型性能

当工业系统的工作条件非常复杂,并根据生产要求发生多次变化时,收集和标记足够的训练样本是不现实的,所以选择在实验中加入噪声来测试本文方法在噪声环境影响下的性能。

信噪比定义为

$$\text{SNR} = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (8)$$

式中: P 为功率; P_{signal} 为信号的功率; P_{noise} 为噪声的功率。

本实验依然选择CWRU的原始振动数据对模型进行训练,在测试样本中添加 $-4\sim 10$ dB的高斯噪声进行测试。实验结果如表4所示。从表4可以看出,本文模型不仅在信噪比较高时取得高的准确率,在信噪比较低时,本文模型性能依然表现不错。

表4 不同SNR下的准确率对比

Table 4 Comparison of accuracy at different SNRs

样本数量	SNR/dB							
	-4	-2	0	2	4	6	8	10
60	37.54	51.68	65.33	76.90	82.02	84.5	84.67	86.29
90	30.17	45.25	65.65	80.29	86.96	90.94	91.94	93.10
120	35.25	56.04	76.69	86.21	91.30	92.33	93.53	93.41
200	31.97	47.49	67.78	84.28	93.30	95.81	96.77	97.09
300	31.30	49.94	67.22	81.45	89.30	92.68	93.77	94.78
600	38.58	50.16	63.17	80.61	90.85	95.01	96.80	97.17
900	36.28	43.11	60.34	75.09	88.98	95.0	96.56	97.38
1 500	37.83	54.66	69.99	81.36	93.75	97.33	98.18	98.50
6 000	47.29	59.77	71.95	87.19	96.60	98.86	99.27	99.50

将本文模型的抗噪性能与传统的DNN和SVM方法进行比较,实验结果如图6所示。由图6可以看出,当信噪比很低时,本文模型相比较于DNN和SVM方法准确率更高;在信噪比逐渐变大的过程中,本文模型也更快达到稳定。

3.4 出现新故障类别下的模型性能

由于在实际应用中,工作情况和故障类别通常都是不平衡的,因此本实验重点放在不平衡的故障类别,即出现新故障类别时模型的性能。使用传统神经网络的方法需要在出现新故障类别时重新训练,而对于本文提出的小样本学习,只需要给出少量的新故障类别样本就能完成对新类别的诊断。本文采用的是从数据集A抽取数据进行训练,再在数据集C中进行测试。从所有类别训练TIC-NN模型,从30%随机新类别训练小样本模型到数据集D中的所有可见类别。将每个这样的实验重复5次,以处理算法的随机性。实验结果如图7所示,在仅仅使用90个样本的情况下,本文模型正确率达到了94.17%。另外,当新类别数达到30%时,对比WDCNN,本文模型准确率提高到了72.41%,提升了8%;新类别数为20%时,本文模型准确率提高了1.8%。由此可见,小样本模型在应

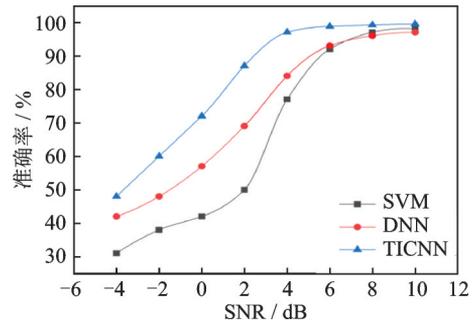


图6 不同方法的抗噪性能

Fig.6 Anti-noise performance of different methods

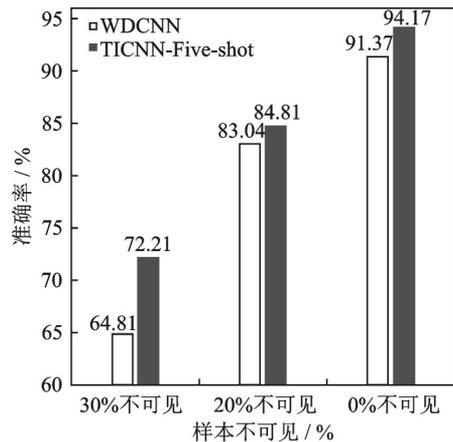


图7 在样本不可见类别下的准确率对比

Fig.7 Comparison of accuracy under category invisibility

对新类别出现时性能仍然较好。

4 结束语

为了解决滚动轴承样本数量有限的问题,本文提出了一种以小样本学习为框架,并搭配孪生网络的模型。由于工业环境受噪声影响严重,提出使用第1层为宽卷积核的 TICNN 神经网络为孪生网络的子网络,通过相同的3个 TICNN 网络对输入的振动信号样本对的特征进行距离度量,从而进行相似度判断。在 CWRU 数据集上进行了相关实验,通过与神经网络 WDCNN 模型以及传统机器学习方法的对比实验结果显示,当样本量较少,在噪声环境下以及测试集中出现新的故障类别的情况下,本文模型都表现出优异的性能。

参考文献:

- [1] 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 Fei, CHEN Renwen, XING Kailing, et al. Fast fault diagnosis algorithm for rolling bearings based on transfer learning and depth residual network[J]. Vibration and Shock, 2022, 41(3): 154-164.
- [2] 贾峰,李世豪,沈建军,等.采用深度迁移学习与自适应加权的滚动轴承故障诊断[J].西安交通大学学报,2022,56(8):1-10.
JIA Feng, LI Shihao, SHEN Jianjun, et al. Fault diagnosis of rolling bearing based on deep migration learning and adaptive weighting [J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 1-10.
- [3] 李秋婷,王秀青,解飞,等.基于注意力机制的滚动轴承故障诊断方法研究[J].轴承,2023(10):84-92.
LI Qiuting, WANG Xiuqing, XIE Fei, et al. Research on fault diagnosis method of rolling bearing based on attention mechanism[J]. Bearing, 2023(10): 84-92.
- [4] YU Y, JUNSHENG C. A roller bearing fault diagnosis method based on EMD energy entropy and ANN[J]. Journal of Sound and Vibration, 2006, 294(1/2): 269-277.
- [5] CHEN Z, MAURICIO A, LI W, et al. A deep learning method for bearing fault diagnosis based on cyclic spectral coherence and convolutional neural networks[J]. Mechanical Systems and Signal Processing, 2020, 140: 106683.
- [6] 赵志宏,杨绍普.基于小波包变换与样本熵的滚动轴承故障诊断[J].振动、测试与诊断,2012,32(4):640-644.
ZHAO Zhihong, YANG Shaopu. Roller bearing fault diagnosis based on wavelet packet transform and sample entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4): 640-644.
- [7] 刘佳敏,赵知劲,曹越飞,等.基于时频分析的多跳频信号盲检测[J].信号处理,2021,37(5):763-771.
LIU Jiamin, ZHAO Zhijin, CAO Yuefei, et al. Blind detection of multi-frequency hopping signals based on time-frequency analysis[J]. Journal of Signal Processing, 2021, 37(5): 763-771.
- [8] 何志坚,周志雄.基于 ELMD 的样本熵及 Boosting-SVM 的滚动轴承故障诊断[J].振动与冲击,2016,35(18):190-195.
HE Zhijian, ZHOU Zhixiong. Fault diagnosis of roller bearings based on ELMD sample entropy and Boosting-SVM[J]. Journal of Vibration and Shock, 2016, 35(18): 190-195.
- [9] 刘慧,谢洪波,和卫星,等.基于模糊熵的脑电睡眠分期特征提取与分类[J].数据采集与处理,2010,25(4):484-489.
LIU Hui, XIE Hongbo, HE Weixing, et al. Characterization and classification of EEG sleep stage based on fuzzy entropy[J]. Journal of Data Acquisition and Processing, 2010, 25(4): 484-489.
- [10] PINCUS S M. Approximate entropy as a measure of system complexity[J]. Proceedings of the National Academy of Sciences, 1991, 88(6): 2297-2301.
- [11] DAEHWAN L, JONGPIL J. Few-shot learning-based light-weight WDCNN model for bearing fault diagnosis in siamese network[J]. Sensors, 2023. DOI: 10.3390/s23146310.
- [12] TONG W, CHANGZHENG C, XINGJUN D, et al. A novel method of production line bearing fault diagnosis based on 2D image and cross-domain few-shot learning[J]. Applied Sciences, 2023, 13(3): 1809-1809.
- [13] ZHANG Ziling. Bearing fault diagnosis based on small sample learning of maml-triplet[J]. Applied Sciences, 2022, 12(21): 10723-

10723.

- [14] 张伟, 彭高亮. 基于卷积神经网络的轴承故障诊断算法研究[J]. 哈尔滨工业大学, 2018(2): 30-35.
ZHANG Wei, PENG Gaoliang. Research on bearing fault diagnosis algorithm based on convolutional neural network[J]. Journal of Harbin Institute of Technology, 2018(2): 30-35.
- [15] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]//Proceedings of ICML Deep Learn. [S.l.]: ICML, 2015: 1-30.
- [16] LOU X, LOPARO K A. Bearing fault diagnosis based on wavelet transform and fuzzy inference[J]. Mechanical Systems and Signal Processing, 2004, 18(5): 1077-1095.
- [17] 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(8): 100-131.
- [18] ZHANG Ansi, LI Shaobo, CUI Yuxin, et al. Limited data rolling bearing fault diagnosis with few-shot learning[J]. IEEE Access 2019, 7: 1-10.

作者简介:

曹莹莹(2000-), 女, 硕士研究生, 研究方向: 工业物联网和机器学习。



郇战(1969-), 通信作者, 男, 教授, 研究方向: 物联网和智能控制技术, E-mail: hzh@cczu.edu.cn.



陈震(1998-), 男, 硕士研究生, 研究方向: 工业物联网和机器学习, E-mail: s21060858003@smail.cczu.edu.cn.



陈瑛(1987-), 女, 博士, 研究方向: 数据挖掘、机器学习和智能控制技术。

(编辑: 刘彦东)