

DOI: 10.19650/j.cnki.cjsi.J1905096

一种用于故障分类与预测的多任务特征共享神经网络*

王震, 黄如意, 李霖蒲, 李巍华

(华南理工大学机械与汽车工程学院 广州 510640)

摘要:智能故障诊断与预测技术在工业实际中得到了广泛地应用,但仍存在以下局限性:1)将不同退化程度的同类型故障作为多种不同的故障模式进行分类识别,脱离了工程应用的实际;2)基于特定数据训练的诊断模型工况泛化能力差。针对上述问题,提出一种多任务特征共享神经网络,并将其应用于轴承的智能故障诊断与预测。首先,利用卷积神经网络(CNN)构建自适应特征提取器,从原始振动信号中提取深层次特征;其次,同时建立分类与预测的多任务特征共享诊断模型,实现故障类型分类以及故障尺寸预测。最后,通过凯斯西储大学轴承数据集验证了所提方法。试验结果表明:所提方法不但能同时实现对故障类型的分类以及故障尺寸的预测,而且具有较强的工况泛化能力。

关键词:智能故障诊断;多任务学习;特征共享;卷积神经网络;长短时记忆网络

中图分类号: TH165.3 TP206.3 **文献标识码:** A **国家标准学科分类代码:** 520.20

Multi-task feature sharing neural network used for fault diagnosis and prognosis

Wang Zhen, Huang Ruyi, Li Jipu, Li Weihua

(School of Mechanical & Automotive Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: Intelligent diagnosis and prognosis techniques have been widely applied in modern industrial practice. However, there still exist same limitations as follows: 1) the techniques take the identical type faults with different degradation degree as different individual fault patterns for classification and identification, which is unreasonable in practical industry application; 2) the diagnosis model based on the training with specific data lacks generalization ability under varying working conditions. Aiming at above mentioned problems, a multi-task feature sharing neural network is proposed and applied to the intelligent diagnosis and prognosis of bearings. Firstly, the CNN is used to construct an adaptive feature extractor, which extracts deep features from raw vibration signals. Secondly, a multi-task feature sharing diagnosis model is constructed for classification and prediction, and the fault classification and fault size prediction are realized. Finally, the proposed method is verified with the benchmark bearing dataset from Case Western Reserve University (CWRU). The experiment results show that the proposed method not only can realize the task of fault type classification and fault size prediction, but also possess strong generalization ability.

Keywords: intelligent fault diagnosis; multi-task learning; feature sharing; convolutional neural network (CNN); long short-term memory network (LSTM)

0 引言

长期运行于高负荷、高转速和高作业率状态下的机械设备,极易出现疲劳失效,进而导致设备停机,甚至导致重大安全事故和巨大的经济损失^[1-3]。因此,智能故障

诊断与预测性维护技术已经成为了工业界和学术界的研究热点^[4]。

近年来,基于深度学习和数据驱动的智能诊断方法在工业实际中得到了较为广泛地应用^[5-7]。余博等^[8]提出一种深度卷积变分自编码网络(deep convolution variational autoencoder network, DCVAEN),将频谱数据作为输入,并

应用于离心泵的故障诊断。Janssens 等^[9]基于卷积神经网络(CNN)和快速傅里叶变换(fast fourier transformation, FFT),实现了对滚动轴承的智能诊断。Zhang 等^[10]提出了一种新型卷积神经网络(deep convolutional neural networks with wide first-layer kernels, WDCNN),并应用于变负载工况下的轴承故障诊断。侯文擎等^[11]提出了基于堆叠降噪自编码网络(stacked denoising auto encoder, SDAE)的诊断算法,通过粒子群算法(particle swarm optimization, PSO)进行参数优化。Shao 等^[12]提出一种新型自编码网络,通过人工鱼群算法(artificial fish swarm algorithm, AFSA)进行参数优化,在滚子轴承的故障诊断上取得了较好的效果。Lei 等^[13]利用无监督学习提取深层特征,再结合深度神经网络进行故障诊断。Shao 等人^[14]提出一种新型卷积深度置信网络(convolutional deep belief network, CDBN),并在电动机轴承故障诊断中取得了较好的效果。Zhang 等^[15]提取了滚动轴承振动信号的多个时频统计特征,输入支持向量机(support vector machine, SVM)进行故障诊断。Jia 等^[16]提出了基于FFT和深度神经网络(deep neural network, DNN)的诊断算法。曲建岭等^[17]提出了一种“端到端”的自适应一维卷积神经网络,并应用于滚动轴承故障诊断。

上述智能诊断方法虽然取得了一定的成果,但仍存在以下局限性:1)将不同退化程度的同类型故障视作多种不同的故障模式,利用分类的方法来识别退化程度。而在实际工业环境中,评价设备退化程度的参量多为连续变化的物理量,例如滚动轴承的点蚀故障尺寸。以分类的方法来进行设备退化评估不符合工业实际情况;2)传统的针对特定工况训练的模型,在工况(如转速和载荷)发生变化时,诊断算法的工况泛化能力较差。而实际工业生产中,难以收集所有工况的数据以供模型训练;3)现有方法多限于诊断特定任务,如设备故障分类或性能退化预测,无法同时实现多种任务的诊断和预测。

针对上述问题,本文提出一种基于CNN和长短时记忆网络的多任务特征共享神经网络(multi-task feature sharing neural network, MFSNN),并将其应用于滚动轴承的智能故障诊断和预测。网络具有多任务特征共享的特点,采用多任务联合训练,可同时实现故障分类任务和故障退化程度预测任务,具有良好的工况泛化能力。首先,构建基于CNN的自适应特征提取器,从原始振动信号中提取包含有多任务间共享知识的通用特征。然后,同时建立多任务模型:分类模型和预测模型。不同的任务模型从通用特征中进一步提取得到更深层的特定特征,从而同时实现基于Softmax分类器的故障分类和基于长短时记忆网络的故障尺寸预测。最后,通过美国凯斯西储大学的轴承数据集对所提方法进行了验证。试验结果表明:本文方法不但能同时实现对故障类型的分类识别和故障尺寸的预测,而且具有较强的工况泛化能力。

1 理论基础

1.1 CNN

CNN是一种深度前馈神经网络,其卷积层和池化层能够从输入数据中提取平移不变性特征,并利用反向传播算法对网络中的权重参数逐层优化,已广泛应用于图像识别^[18]、语音识别^[19]等领域。

卷积层是对上一层的输出特征,通过卷积操作和非线性激活生成新的特征表示。不同尺寸的卷积核 $W \in \mathfrak{R}^{m \times n}$ 与输入特征表示 $Z \in \mathfrak{R}^{M \times N}$ 卷积形成新的特征表示 $V \in \mathfrak{R}^{(M-m+1) \times (N-n+1)}$ 。公式可表述为:

$$V = W * Z = \sum_{u=1}^m \sum_{v=1}^n w_{uv} x_{i+u-1, j+v-1} \quad (1)$$

此时得到的特征表示 V 是对输入表示 Z 的高层表示,包含有 Z 的局部特征信息,添加偏置后经非线性激活得到输出特征表示,其数学模型为:

$$Z^l = \sigma(W^l * Z^{l-1} + b^l) \quad (2)$$

式中: Z^l 为第 l 层的输出, Z^{l-1} 为第 $l-1$ 层的输出, b^l 为待优化的偏置,卷积核 W^l 为待学习的权重向量, σ 为非线性激活函数。

池化层对卷积层输出的特征进行选择,得到更为抽象的特征,同时减少了特征维度。常用的池化方式为最大值池化,即提取特定区域内的最大值,其数学模型为:

$$Z_{m,n}^d = \max_{i \in \mathfrak{R}_{m,n}^d} \{x_i\} \quad (3)$$

式中: x_i 为区域 $\mathfrak{R}_{m,n}^d$ 内的神经元激活后的值。

以一维CNN为例,将一维时间序列作为输入,其工作原理如图1所示。




图1 一维CNN

Fig.1 One-dimensional CNN

1.2 长短时记忆网络

长短时记忆网络是一种基于门控的循环神经网络(recurrent neural network, RNN),其解决了简单循环神经网络的梯度消失和梯度爆炸问题。与前馈神经网络不

同,长短时记忆网络当前的输出不仅依赖于当前的输入,也与历史输出有关。由于具有对历史信息的记忆功能,长短时记忆网络能较好地处理长时间序列,并已广泛应用于机器翻译、文本预测等领域。

长短时记忆网络由多个记忆单元构成。单个记忆单元由输入门、遗忘门、输出门组成,并引入细胞状态(cell state)进行内部循环信息传递,结构如图 2 所示。其前向传播过程的数学模型为:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \tag{4}$$

$$h_t = o_t \cdot \tanh(C_t) \tag{5}$$

式中: C_t 为当前状态, C_{t-1} 为上一单元的状态, h_t 为当前外部状态, \tilde{C}_t 为单元内部的候选状态。 i_t, o_t 和 f_t 分别为输入门、输出门和遗忘门的状态,可以表示为:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{6}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{7}$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{8}$$

式中: x_t 为当前的输入; h_{t-1} 为上一时刻的外部状态; σ 为非线性激活函数。




图 2 LSTM 单元

Fig.2 LSTM cell

在每个 LSTM 单元中,输入门、遗忘门和输出门共同影响单元的状态,动态地调整单元所记忆的信息。

1.3 多任务特征共享神经网络 (MFSNN)

基于上述理论基础,提出一种多任务特征共享神经网络。网络由输入层、特征提取器、分类模型和预测模型构成,网络结构和诊断流程如图 3 所示。

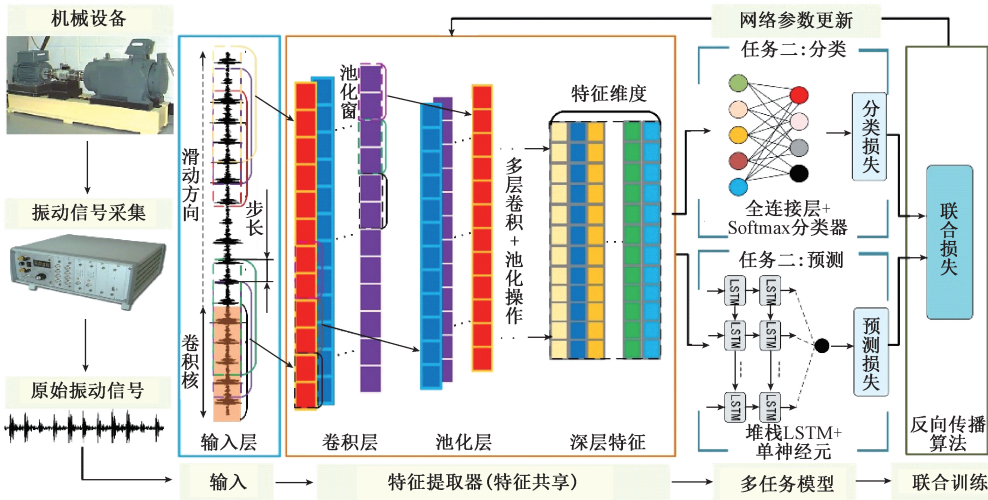


图 3 MFSNN

Fig.3 MFSNN

1) 通过数据采集系统获取机械设备各运行工况下的原始振动信号,并将其划分为训练集和测试集;

2) 搭建基于一维 CNN 的特征提取器,特征提取器能够从原始振动信号中提取深层的特征,实现自适应的特征提取,避免了人为提取特征的不确定性及对专业知识的依赖性;

3) 将提取到的深层特征共享至不同的任务模型,并计算相应的分类损失和预测损失;

4) 由步骤 3) 中的分类损失和预测损失组成联合损失,通过联合训练,最小化联合损失,从而同时实现基于

Softmax 分类器的故障分类和基于长短时记忆网络的故障尺寸预测。

大部分智能诊断算法限于单一特定任务,例如设备故障分类或性能退化预测。然而,设备的故障类型和性能退化趋势往往存在一定的相关关系,即故障类别特征与故障退化特征之间存在一定的共享知识。本文引入多任务特征共享机制,通过多任务联合训练,多个任务共同从原始输入中学习共享知识,共同优化诊断模型的性能,确保模型不过拟合至单个任务,从而提升模型的泛化能力。通过有监督学习,特征提取器提取包含有共享知识

的通用特征。然后,不同的任务模型对通用特征做进一步学习,提取得到更深层的特定特征,从而实现多任务特征共享的智能故障诊断。

本文采用有监督的多任务联合训练,损失函数为各个任务损失函数的线性加权,即联合损失函数,其数学表达式为:

$$L = \sum_{m=1}^M \lambda_m L_m \quad (9)$$

式中: M 为任务数量,本文取值为2; L_m 为第 m 个任务的损失函数; λ_m 为第 m 个任务的权重。

故障类型分类任务的损失函数为交叉熵损失函数(cross entropy loss),其表达式为:

$$L_{\text{classification}} = -\frac{1}{N} \left[\sum_{n=1}^N \sum_{k=1}^K 1\{y^n = k\} \log(\hat{y}_k^n) \right] \quad (10)$$

式中: N 和 K 分别表示样本数及类别数; y^n 表示第 n 个样本的真实类别; \hat{y}_k^n 表示第 n 个样本对应的第 k 个输出神经元的激活值; $1\{*\}$ 是指示性函数,“ $*$ ”代表的表达式为真时返回1,否则返回0。

故障程度预测任务的损失函数为均方误差损失函数(mean square error, MSE),其表达式为:

$$L_{\text{regression}} = \frac{1}{N} \sum_{n=1}^N (y_{\text{true}}^n - y_{\text{pred}}^n)^2 \quad (11)$$

式中: N 表示样本数; y_{true}^n 表示第 n 个样本的真实故障尺寸; y_{pred}^n 表示第 n 个样本的神经元预测值。

2 实验

2.1 实验数据集

为验证诊断算法的准确性和泛化能力,利用美国凯斯西储大学的滚动轴承数据集进行实验验证。该数据集共包括4种不同的负载和转速组合,即包含4种不同的工况。实验利用电火花加工分别在轴承内圈、外圈和滚动体上制造了不同尺寸(0.007 in, 0.014 in, 0.021 in, 1 in = 25.4 mm)的单点损伤。然后用安装在驱动端和风扇端的加速度传感器采集振动加速度信号。本文选取了采样频率为12 kHz的驱动端加速度数据,共包括3种不同工况,如表1所示。

表1 试验工况

Table 1 Testing conditions

工况	载荷/hp	转速/(r·min ⁻¹)
A	1	1772
B	2	1750
C	3	1730

号中截取一定长度的数据段来构成单个训练样本。同时,为保留样本间的时间连续性,相邻2个样本首尾重合。综合考虑样本长度和样本量对实验结果的影响,选取每个样本的长度为2 048个点,相邻2个样本的首尾重合率为25%。具体数据集构成和样本数量如表2所示。每个样本即为定长的加速度时域振动信号,其时域波形如图4所示。图4(a)和(b)为同工况下故障尺寸为0.177 8 mm的内圈和滚珠故障样本,图4(c)和(d)为同工况下故障尺寸为0.533 4 mm的内圈和滚珠故障样本。对比(a)和(b)或(c)和(d)可知,在相同故障程度下,不同故障模式的原始时域信号的波形幅值和包络均有较大的差异;对比(a)和(c)或(b)和(d)可知,在相同故障模式下,不同故障程度的原始时域信号的波形幅值和包络也存在明显差异,故障程度增大时,振动信号的振幅也明显增加。多任务特征共享神经网络可从大量原始时域信号中学习深层特征和不同任务间的共享知识,从而实现故障类型分类和故障尺寸预测。

表2 实验样本组成

Table 2 Composition of experiment samples

轴承状态	样本量	故障类别标签	故障尺寸/mm
正常	900	0	0.000 0
	240	1	0.177 8
滚珠故障	240	1	0.355 6
	240	1	0.533 4
内圈故障	240	2	0.177 8
	240	2	0.355 6
	240	2	0.533 4
外圈故障	240	3	0.177 8
	240	3	0.355 6
总计	3 060		

为合理评价诊断算法的准确性,本文利用分类准确率来评价故障类型的分类准确率,用均方根误差(root mean square error, RMSE)来评价故障尺寸的预测误差,其数学表达式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y_{\text{true}}^n - y_{\text{pred}}^n)^2} \quad (12)$$

式中: N 表示样本数; y_{true}^n 表示第 n 个样本的真实故障尺寸; y_{pred}^n 表示第 n 个样本的神经元预测值。

2.2 MFSNN 模型参数

本文利用深度学习框架 Keras 构建模型,训练优化器为 Adam,学习率设置为 0.001,联合损失函数由式(9)~(11)得到,具体表达式为:

为确保有足够的样本量来训练网络,本文由原始信




图 4 原始振动加速度信号

Fig.4 Raw vibration acceleration signals

$$L = \lambda_1 L_1 + \lambda_2 L_2 \tag{13}$$

式中: L_1 和 L_2 分别为故障类型分类任务和故障尺寸预测任务的损失函数; λ_1 和 λ_2 为对应任务的权重, 根据训练取得的效果, 本文取 $\lambda_1 = 0.3$ 和 $\lambda_2 = 1.0$ 。

批量(batch size)和迭代次数(epochs)是 2 个重要的训练超参, 对模型的收敛速度和训练精度有较大影响。为选择最优的超参组合, 现将 A 工况的数据集随机打乱, 按 7:3 划分训练集和测试集, 再进行训练。观察在不同超参组合下, 模型在测试集上的分类准确率和 RMSE, 从而选择出最优的批量和迭代次数, 结果如图 5 所示。

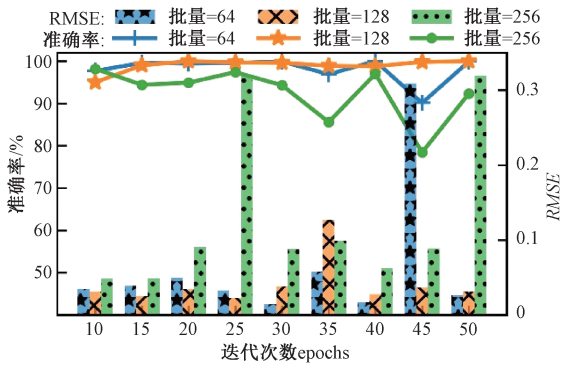


图 5 批量大小和迭代次数的选择

Fig.5 Selection of batch size and epochs

经分析可得, 当批量为 64 和 256 时, 网络不稳定。当批量为 128, 迭代次数大于 20 时, 准确率稳定在 99% 左右, RMSE 存在一定的波动。对深度学习模型而言, 迭代次数增加的同时, 模型训练所需时间也在增加。因此, 本文选择迭代次数为 20, 批量为 128, 在保证网络收敛到最优的同时, 减少训练模型所需的时间。

2.3 MFSNN 模型准确性验证


为验证模型的诊断与预测准确性, 将数据集以 7:3 划分为训练集和测试集, 以交叉验证的方式, 分别在 A、

B、C 3 种不同工况下验证 MFSNN 模型在诊断与预测方面的准确性, 实验结果见表 3, 效果如图 6 所示。

表 3 不同工况下的诊断结果


Table 3 Diagnosis results under different working conditions

工况	准确率/%	RMSE
A	100	0.017 5
B	100	0.011 7
C	100	0.008 2
平均	100	0.012 5




(a) A 工况诊断结果

(a) The diagnosis result for working condition A



(b) B 工况诊断结果

(b) The diagnosis result for working condition B



(c) C工况诊断结果
(c) The diagnosis result for working condition C

图6 模型交叉验证的诊断结果

Fig.6 Diagnosis results of model cross-validation

由表3和图6可以发现,在不同工况下,模型对故障类型的识别准确率均达到了100%;对故障尺寸的预测也达到较高的精度,3种工况下RMSE的平均值为0.0125。实验结果表明,所提方法实现了故障类型的分类和故障尺寸的预测,并且取得了较高的准确度。

2.4 MFSNN模型工况泛化能力验证

本节通过2个实验案例,并使用交叉验证的方法来验证MFSNN模型的工况泛化能力。同时,选择多种现有智能诊断算法进行对比,所选对比方法包括:

1)文献[16]提出的DNN诊断算法,先对各个样本进行快速傅里叶变换,再将频谱数据作为模型的输入,实现对轴承的故障类型分类。

2)文献[10]提出的WDCNN诊断算法,此方法将原始振动信号作为模型的输入,实现故障分类。

3)文献[15]使用的传统诊断算法SVM,先对原始时域信号提取均值、方差、重心频率等18项时频统计特征,再将统计特征作为输入,实现故障分类。

对比方法均只针对故障模式分类这一单一任务,无法实现故障尺寸预测。为合理论证MFSNN模型在工况泛化时的故障类型分类准确率和故障尺寸预测误差,通过对比方法的分类器改为回归模型,重新训练得到故障尺寸预测模型,并用未知工况测试和验证。

实验案例1):

本实验案例,采用留一交叉验证法来划分训练集和测试集,即选择其中某一种工况的数据为测试集,其他工况的数据为训练集。将训练集输入MFSNN模型,并通过多任务联合训练,得到诊断模型。最后,用测试集数据来测试模型。实验结果如图7、8和表4所示。表中的“AB→C”表示诊断模型用A和B2种工况的数据集进行训练,用工况C的数据集进行测试和验证。


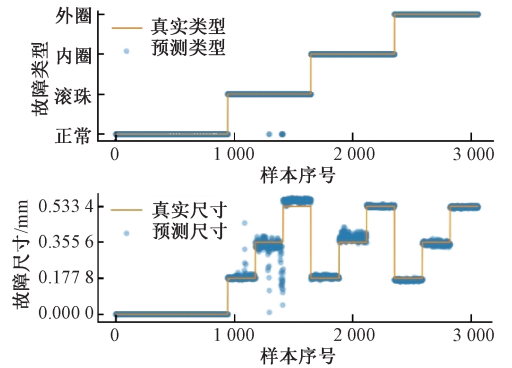
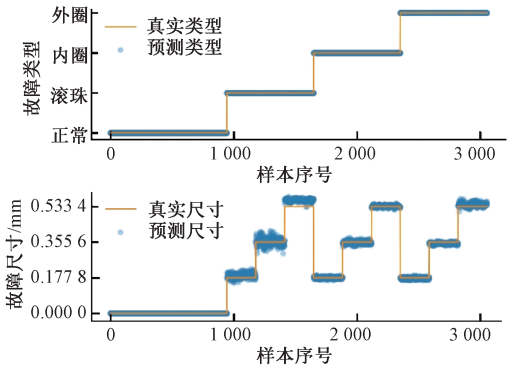


图7 案例1)实验结果对比

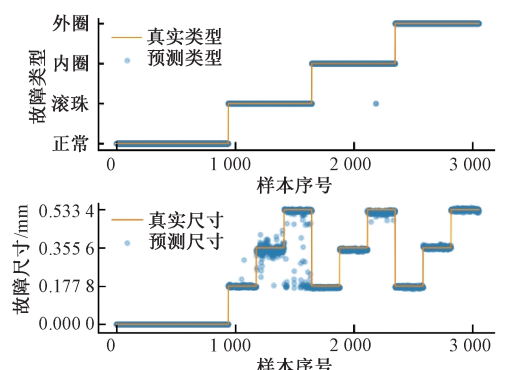
Fig.7 Experiment result comparison for case 1



(a) AB→C工况泛化结果
(a) The generalization result for working conditions AB→C



(b) AC→B工况泛化结果
(b) The generalization result for working conditions AC→B



(c) BC→A工况泛化结果
(c) The generalization result for working conditions BC→A

图8 MFSNN模型工况泛化能力实验结果

Fig.8 Experiment results of the generalization ability of MFSNN model for different working conditions

表 4 案例 1) 实验结果
Table 4 Testing result for case 1

实验组别	本文		DNN		WDCNN		SVM	
	准确率/%	RMSE	准确率/%	RMSE	准确率/%	RMSE	准确率/%	RMSE
AB→C	99.74	0.022 7	99.96	0.089 0	99.48	0.033 8	89.48	0.078 9
AC→B	100	0.012 9	99.84	0.080 0	99.96	0.030 9	99.11	0.069 1
BC→A	99.93	0.040 9	99.38	0.079 9	99.47	0.062 9	97.08	0.094 2
平均	99.89	0.025 5	99.72	0.082 9	99.64	0.042 5	95.22	0.080 7

实验案例 2):

为进一步验证 MFSNN 模型的泛化能力,本实验案例只选取某一种工况的数据来训练模型,其他工况的数据来测试和验证模型。实验结果如图 9 和表 5 所示,表中的“ $A \rightarrow B$ ”表示模型用工况 A 的数据集进行训练,用工况 B 的数据集进行测试和验证。

通过对比和分析 2 个实验案例,可得出以下结论:

1) 所提 MFSNN 模型,采用多任务联合训练,可同时实现故障类型分类和故障尺寸预测多种任务;而对比方法需分别训练故障模式分类和故障尺寸预测两个单任务模型,无法同时实现故障类型分类和故障尺寸预测。

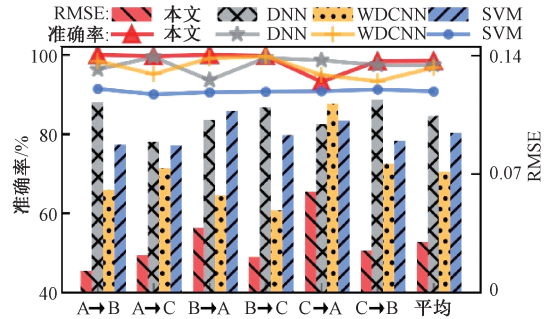


图 9 案例 2) 实验结果对比

Fig.9 Experiment result comparison for case 2

表 5 案例 2) 实验结果
Table 5 Testing result for case 2

实验组别	本文		DNN		WDCNN		SVM	
	准确率/%	RMSE	准确率/%	RMSE	准确率/%	RMSE	准确率/%	RMSE
A→B	100	0.012 8	96.32	0.112 4	98.41	0.060 7	91.40	0.087 2
A→C	99.64	0.022 0	99.47	0.089 1	95.16	0.073 3	90.01	0.087 1
B→A	100	0.038 1	93.61	0.101 9	99.13	0.057 2	90.58	0.107 1
B→C	99.72	0.020 9	99.20	0.109 3	99.62	0.048 5	90.74	0.092 8
C→A	93.16	0.059 6	98.63	0.099 4	94.97	0.111 4	90.83	0.101 5
C→B	98.40	0.024 8	97.41	0.113 9	93.32	0.076 1	91.22	0.089 7
平均	98.49	0.029 7	97.44	0.108 9	96.76	0.071 2	90.79	0.098 4

2) 在 2 个不同的工况泛化实验案例中, MFSNN 模型的故障类型识别的平均准确率分别为 99.89%、98.49%, 优于 DNN、WDCNN 和 SVM 3 种对比方法; 故障尺寸预测平均均方根误差 RMSE 分别为 0.025 5、0.029 7, 也优于对比方法。

3) 案例 2) 用一种工况的数据训练模型, 其所用到的有标签数据量仅为案例 1) 的 50%。对比两实验案例可发现: 相比案例 1), 案例 2) 中 MFSNN 的故障类型识别的平均准确率仅降低了 1.4%, 故障尺寸预测平均均方根误差 RMSE 仅增加了 0.004 2; 而 DNN、WDCNN 和 SVM 3 种对比方法的故障类型识别准确率分别降低了 2.28%、2.88%、4.76%, 故障尺寸预测平均均方根误差

RMSE 分别增加了 0.026 0、0.028 7、0.017 7。即本文方法在降低对有标签数据需求的同时, 保证了较好的精度和工况泛化能力。

4) 本文方法可添加更多任务分支, 有望实现更多样的诊断任务。关于本文方法的拓展性和迁移性的研究, 可以作为未来探索和拓展的研究方向, 进一步拓展和优化 MFSNN 模型的实际应用场景。

综上所述, 实验结果表明: 本文方法同时实现了轴承故障类型的分类识别和故障尺寸的回归预测, 且整体的诊断准确性和泛化能力优于多种对比的智能诊断方法, 具有较高的实际应用价值。

3 结 论

本文提出了一种任务特征共享神经网络,引入了多任务学习和特征共享机制,从原始振动信号中提取含有多任务共享知识的通用特征,同时实现了滚动轴承故障类型分类和故障尺寸预测。在两个不同的工况泛化实验案例中,本文方法的故障类型识别平均准确率分别为99.89%、98.49%,优于DNN、WDCCN和SVM3种对比方法;故障尺寸预测平均均方根误差RMSE分别为0.0255、0.0297,也优于对比方法,具有较好的诊断与预测准确性和工况泛化能力。本文方法使用原始信号作为输入,诊断精度和工况泛化能力均优于以频谱数据作为输入的DNN和以时频统计特征作为输入的SVM,避免了人为提取特征,增强了诊断的智能性。

参考文献

- [1] 年夫顺.关于故障预测与健康管理的几点认识[J].仪器仪表学报,2018,39(8):1-14.
NIAN F SH. Viewpoints about the prognostic and health management [J]. Chinese Journal of Scientific Instrument, 2018,39(8):1-14.
- [2] 辛玉,李舜酩,王金瑞,等.基于迭代经验小波变换的齿轮故障诊断方法[J].仪器仪表学报,2018,39(11):79-86.
XIN Y, LI SH M, WANG J R, et al. Gear fault diagnosis method based on iterative empirical wavelet transform[J]. Chinese Journal of Scientific Instrument, 2018,39(11):79-86.
- [3] GHODS A, LEE H H. Probabilistic frequency-domain discrete wavelet transform for better detection of bearing faults in induction motors[J]. Neurocomputing, 2016, 188:206-216.
- [4] 赵光权,葛强强,刘小勇,等.基于DBN的故障特征提取及诊断方法研究[J].仪器仪表学报,2016,37(9):1946-1953.
ZHAO G Q, GE Q Q, LIU X Y, et al. Fault feature extraction and diagnosis method based on deep belief network [J]. Chinese Journal of Scientific Instrument, 2016, 37 (9): 1946-1953.
- [5] 温江涛,闫常弘,孙洁娣,等.基于压缩采集与深度学习的轴承故障诊断方法[J].仪器仪表学报,2018,39(1):171-179.
WEN J T, YAN CH H, SUN J D, et al. Bearing fault diagnosis method based on compressed acquisition and deep learning [J]. Chinese Journal of Scientific Instrument, 2018, 39(1): 171-179.
- [6] ZHAO R, YAN R Q, CHEN ZH H, et al. Deep learning and its applications to machine health monitoring [J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [7] 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 Y G, JIA F, ZHOU X, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21):49-56.
- [8] 余博,田福庆,梁伟阁.基于深度卷积变分自编码网络的故障诊断方法[J].仪器仪表学报,2018,39(10):27-35.
SHE B, TIAN F Q, LIANG W G. Fault diagnosis based on a deep convolution variational autoencoder network[J]. Chinese Journal of Scientific Instrument, 2018, 39(10): 27-35.
- [9] JANSSENS O, SLAVKOVIKJ V, VERVISCH B, et al. Convolutional Neural Network Based Fault Detection for Rotating Machinery[J]. Journal of Sound and Vibration, 2016,377:331-345.
- [10] ZHANG W, PENG G L, LI CH H, 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.
- [11] 侯文擎,叶鸣,李巍华.基于改进堆叠降噪自编码的滚动轴承故障分类[J].机械工程学报,2018,54(7):87-96.
HOU W Q, YE M, LI W H. Rolling element bearing fault classification using improved stacked de-noising auto-encoders [J]. Journal of Mechanical Engineering, 2018, 54 (7): 87-96.
- [12] SHAO H D, JIANG H K, ZHAO H W, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis [J]. Mechanical Systems and Signal Processing, 2017, 95:187-204.
- [13] LEI Y, JIA F, LIN J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data[J]. IEEE Transactions on Industrial Electronics, 2016, 63(5):3137-3147.
- [14] SHAO H D, JIANG H K, ZHANG H ZH, et al. Electric locomotive bearing fault diagnosis using novel

convolutional deep belief network[J]. IEEE Transactions on Industrial Electronics, 2018, 65(3):2727-2736.

- [15] ZHANG X L, WANG B J, CHEN X F. Intelligent fault diagnosis of roller bearings with multivariable ensemble-based incremental support vector machine [J]. Knowledge-Based Systems, 2015, 89: 56-85.
- [16] JIA F, LEI Y G, LIN J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems and Signal Processing, 2016, 72-73:303-315.
- [17] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.
- [18] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521:436-444.
- [19] ABDEL-HAMID O, MOHAMED A R, JIANG H, et al. Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition[C]. 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2012:4277-4280.

作者简介



王震, 2018年于中南大学获得学士学位, 现为华南理工大学硕士研究生, 主要研究方向为智能故障诊断、深度学习理论及应用。

E-mail: maybingbox@163.com

Wang Zhen received his B. Sc. degree in 2018 from Central South University; now, he is a master student in South China University of Technology. His main research interest includes intelligent fault diagnosis, deep learning theory and application.



李巍华(通信作者), 分别在1995年和1998年于太原理工大学获得学士学位和硕士学位, 2003年于华中科技大学获得博士学位, 现为华南理工大学教授, 主要研究方向为智能故障诊断与预测。

E-mail: whlee@scut.edu.cn

Li Weihua (Corresponding author) received his B. Sc. and M. Sc. degrees both from Taiyuan University of Technology in 1995 and 1998, respectively, and received his Ph. D. degree from Huazhong University of Science and Technology in 2003. Now, he is a professor in South China University of Technology. His main research interest includes intelligent fault diagnosis and prognosis.