

DOI: 10.13382/j.jemi.B2104102

一种轴承故障诊断的多任务深度学习方法*

赵志宏^{1,2} 李乐豪² 李 晴²

(1. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室 石家庄 050043;

2. 石家庄铁道大学信息科学与技术学院 石家庄 050043)

摘要:提出一种基于多任务深度学习的故障诊断方法,将故障诊断任务分为故障分类和损伤程度识别。共享层采用卷积神经网络提取监测振动信号中蕴含的故障特征信息,两个子任务模块使用门控循环单元从共享层的输出中进一步提取特征,进行故障分类和损伤程度识别。在多任务深度学习方法中两个子任务模块可以通过共享层相互影响,提高模型的特征提取能力,获得更好的故障诊断性能。在轴承数据集上进行故障诊断实验,同时与故障分类单任务模型和损伤程度识别单任务模型进行对比,以检验多任务深度学习方法的故障诊断性能,实验结果显示多任务深度学习模型在测试集上两个任务同时正确的准确率为99.79%。为进一步验证多任务深度学习方法的特征提取能力,在测试集中添加不同程度的高斯噪声进行故障诊断实验,在较强噪声情况下,多任务深度学习模型的准确率明显高于单任务深度学习模型。研究表明,多任务深度学习模型与单任务深度学习模型相比故障诊断准确率更高,同时抗噪性能更好,具有一定的实用价值。

关键词: 轴承;多任务深度学习;卷积神经网络;门控循环单元;故障诊断

中图分类号: TN06;TP277 **文献标识码:** A **国家标准学科分类代码:** 460.1520

Multi-task deep learning method for bearing fault diagnosis

Zhao Zhihong^{1,2} Li Lehao² Li Qing²

(1. State Key Laboratory of Mechanical Behavior in Traffic Engineering Structure and System Safety, Shijiazhuang Railway Institute, Shijiazhuang 050043, China; 2. School of Computation and Informatics, Shijiazhuang Railway Institute, Shijiazhuang 050043, China)

Abstract: A fault diagnosis method based on multi-task deep learning is proposed, which classifies fault diagnosis tasks into fault classification and defect severity recognition. The shared layer uses convolution neural network to extract fault characteristic information contained in monitoring vibration signal, and the two subtask modules use gated recurrent unit to classify fault and recognize defect severity respectively. In multi-task deep learning method, the two subtask modules can interact with each other through the shared layers to promote the feature extraction ability of the model and make the whole model have better fault diagnosis performance. Fault diagnosis experiments are carried out on bearing dataset and compared with fault classification single-task model and defect severity identification single-task model to verify the fault diagnosis performance of multi-task deep learning method. The experimental results show that the accuracy of the multi-task deep learning model is 99.79% for both tasks on the test set. In order to further verify the feature extraction capability of the multi-task deep learning method, different degrees of Gaussian noise were added to the test set for fault diagnosis experiment. Under the condition of strong noise, the accuracy of the multi-task deep learning model was significantly higher than that of the single-task deep learning model. The research results show that the multi-task deep learning model can diagnose fault more accurately and has better denoising than the single-task deep learning model, which has certain practical value.

Keywords: bearing; multi-task deep learning; convolutional neural network; gated recurrent unit; fault diagnosis

0 引言

滚动轴承是机械设备中最为重要的零部件之一,旋转机械设备中总故障的 30% 是滚动轴承故障,对其展开健康检测十分必要。在轴承健康状态监测系统运行中,传感器会采集到海量蕴含轴承健康信息的大数据^[1]。如何利用这些大数据进行准确、高效的故障诊断是一个重要的研究课题。

Hinton 等^[2-3]于 2006 年提出了深度学习概念并为深度神经网络的训练提供了方法,近年来深度学习技术发展迅速,在计算机视觉和自然语言处理领域尤为突出。由于深度学习方法无需手工特征提取,具有较强的特征自提取能力,因此深度学习方法逐渐成为了故障诊断领域的研究热点。

孙文珺等^[4]将稀疏自编码器与 Dropout 方法相结合,使得学习到的模型具有较强的鲁棒性,在感应电机的故障诊断上取得了较好的效果。侯文擎等^[5]提出一种改进的堆叠降噪自编码器诊断方法,利用粒子群算法进行网络超参数自适应选择,在仿真信号和变转速工况实测信号下的实验中均取得较高的诊断准确率。唐波等^[6]提出一种基于一维深度卷积的轴承故障诊断方法,在多故障、变负载的情况下取得了较高的准确率。宫文峰等^[7]提出一种使用全卷积神经网络(CNN)和支持向量机(SVM)的电机轴承微小故障诊断方法,在不同负载下具有良好的迁移泛化能力。周兴康等^[8]提出一种基于深度一维残差卷积自编码器的齿轮箱故障诊断方法,不需要大量有标签数据就能够对齿轮箱故障进行诊断,具有一定的实用价值。吴春志等^[9]提出一种一维深度卷积神经网络的齿轮箱故障诊断模型,具有较强的特征提取能力,故障诊断准确率高于传统方法。咎涛等^[10]提出一种多输入层的深度卷积神经网络模型,在输入振动信号的同时将谱分析数据在模型的其他位置输入,和传统卷积神经网络模型相比收敛速度更快准确率更高。周齐才等^[11]提出基于改进的堆叠式循环神经网络的轴承故障诊断模型,利用深度学习模型极强的非线性拟合能力以及门控循环单元(gated recurrent neural network, GRU)特有的沿时间通道传播的特点,对轴承故障进行了有效的诊断。王太勇等^[12]提出一种基于注意力机制和双向长短期记忆网络的故障诊断方法,故障诊断的准确率高达 99% 以上,并且在变工况的情况下也可以取得了较高的故障诊断准确率。

以上故障诊断方法都属于单任务深度学习故障诊断方法。随着深度学习的发展,很多专家学者将多任务学习思想^[13]应用于深度学习模型的设计,例如目标检测领域的 Faster R-CNN^[14]就是一个多任务深度学习模型,其

物体识别任务和候选框定位任务共用一个特征提取网络,使得目标检测精度和效率都得到提升。另外,在人脸识别^[15]、文本分割^[16]和自然语言理解^[17]等领域多任务深度学习也有很多应用,均取得了很好的效果。本文基于多任务深度学习思想,将故障诊断任务划分为故障分类和损伤程度识别两个子任务,利用多任务学习不同任务之间的相互影响,使模型获得更好的性能。本文多任务深度学习模型的共享层使用卷积神经网络,各个子任务模块使用门控循环单元进一步提取特征,在公开的轴承振动信号数据集上和单任务深度学习模型进行对比实验,实验结果表明多任务深度学习方法可以获得更好的故障诊断准确率,并且在噪声环境下具有更好的鲁棒性。

1 理论基础

1.1 多任务深度学习

多任务深度学习是将复杂的任务划分为多个相互关联的子任务,与单任务深度学习各个模型相互独立不同,多任务深度学习模型可以通过参数共享的方式提升模型的泛化能力,使各个子任务的性能得到提升^[18]。多任务深度学习常用的参数共享方式可以分为软参数共享和硬参数共享,软参数共享通过对多个单任务深度学习模型的网络层施加约束使得模型中部分网络层的参数相似;硬参数共享则直接共用部分网络层,使得部分网络层参数一致。多任务深度学习有效的原因主要有^[19]隐层表示能力更强,通过同时学习服务于多个任务的特征可以获得一个相较于单任务深度学习模型更一般的表示;窃听机制(Eavesdropping),一个较难学习的任务可以获得另一个容易学习任务的辅助;正则化,引入规约偏置来改进模型,抑制了过拟合。

1.2 卷积神经网络

卷积神经网络模型通常由卷积层、池化层和全连接层组成。卷积神经网络学到的模式具有平移不变性,特征出现在输入数据的特定位置,经过卷积,输出的特征也将出现在特定位置。同时卷积神经网络学到的模式还具有空间层次结构,后一层卷积可以学习前一层卷积提取到的特征组成的模式,通过卷积层的堆叠,网络可以提取到越来越抽象,越来越复杂的特征。

本文设计的卷积神经网络包括卷积层、批规范化层、Dropout 层。卷积层的计算如下:

$$\mathbf{x}_i^l = f(\mathbf{W}_i^l * \mathbf{X}^{l-1} + \mathbf{b}_i^l) \quad (1)$$

式中: * 代表卷积运算; f 代表激活函数; \mathbf{W}_i^l 代表第 l 层的第 i 个卷积核的权重矩阵; \mathbf{X}^{l-1} 代表上一层的输出,即 $l-1$ 层的输出; \mathbf{x}_i^l 代表 l 层输出的第 i 个特征; \mathbf{b}_i^l 代表第 l 层的第 i 个卷积核的偏置项。

采用 SELU 作为卷积层的激活函数。SELU 的运算公式如下:

$$\text{SELU} = \begin{cases} \lambda x, x > 0 \\ \lambda \alpha e^x - \alpha, x \leq 0 \end{cases} \quad (2)$$

式中: $\lambda = 1.050\ 700\ 98$, $\alpha = 1.673\ 263\ 24$ 。SELU 激活函数克服了 ReLU 激活函数将所有负值置零和 Sigmoid 激活函数不利于梯度反向传播的缺点^[20-21]。SELU 允许一定范围的负值存在,可以很好地解决特征丢失和梯度消失的问题,并且求导运算速度快,可以提升深度学习模型的性能^[22]。

批规范化层^[23]可以对输入进行白化预处理:

$$\tilde{\mathbf{x}} = \frac{\mathbf{x} - E(\mathbf{x})}{\sqrt{\text{Var}(\mathbf{x}) + \varepsilon}} \quad (3)$$

式中: $E(\mathbf{x})$ 表示一个批次输入 \mathbf{x} 的平均值; $\text{Var}(\mathbf{x})$ 代表该批次数据的标准差, ε 代表极小的整数用来避免分母为 0。使得该层神经元的输出既不过分的大也不过分的小,均值为 0,标准差为 $1 + \varepsilon$ 。为了改善标准化后的偏移量的丢失,引入“比例及平移(scalar and shift)”操作:

$$\mathbf{y} = \lambda \tilde{\mathbf{x}} + \beta \quad (4)$$

Dropout 层在网络的训练过程中随机丢弃两个层之间一定比例的神经元^[24]。通过设置 Dropout 层可以使得模型获得更好的泛化性能,避免过拟合现象。

1.3 门控循环单元

门控循环单元^[25]相较于传统循环神经网络可以更好地捕捉时间序列中时间距离较长的依赖关系。门控循环单元有两个门——重置门和更新门。重置门决定先前的隐藏状态单元是否被忽略,更新门控制当前隐藏状态单元是否需要被新的隐藏状态单元更新。门控循环单元与长短期记忆网络相比,由 3 个门减少到了两个门,在保证了一定的性能的同时,减少了训练的参数,使得训练网络所需的时间减少。门控循环单元的结构如图 1 所示,图中 z_t 和 r_t 分别为更新门和重置门, h_t 为隐藏层输出, σ 为 Sigmoid 激活函数, h_t 的计算方式如下:

$$z_t = \sigma(\mathbf{W}^{(z)}\mathbf{x}_t + \mathbf{U}^{(z)}\mathbf{h}_{t-1}) \quad (5)$$

$$r_t = \sigma(\mathbf{W}^{(r)}\mathbf{x}_t + \mathbf{U}^{(r)}\mathbf{h}_{t-1}) \quad (6)$$

$$\tilde{\mathbf{h}}_t = \tanh(r_t \circ \mathbf{U}\mathbf{h}_{t-1} + \mathbf{W}\mathbf{x}_t) \quad (7)$$

$$\mathbf{h}_t = (1 - z_t) \circ \tilde{\mathbf{h}}_t + z_t \circ \mathbf{h}_{t-1} \quad (8)$$

式中: $\tilde{\mathbf{h}}_t$ 为输入 \mathbf{x}_t 和过去隐藏状态单元的输出 $\tilde{\mathbf{h}}_{t-1}$ 汇总; $\mathbf{W}^{(z)}$ 、 $\mathbf{U}^{(z)}$ 、 $\mathbf{W}^{(r)}$ 、 $\mathbf{U}^{(r)}$ 、 \mathbf{W} 和 \mathbf{U} 为可训练参数矩阵。在门控循环的网络中可以设置输入 \mathbf{x}_t 的 Dropout 和过去隐藏状态单元 \mathbf{h}_t 的 Dropout (Recurrent_Dropout) 来优化模型,避免过拟合。




图 1 门控循环单元网络结构

Fig. 1 Structure of GRU

2 多任务深度学习模型

本文提出一种结合卷积神经网络和门控循环单元的多任务深度学习模型,采用硬参数共享方式。共享层由卷积神经网络组成,负责提取蕴含故障类别和损伤程度信息的特征,然后将这个特征分别送入两个由门控循环单元组成的子任务模块中进一步提取故障类别和损伤程度的特征,并进行分类。轴承故障诊断的多任务深度学习模型如图 2 所示,共享层采用卷积神经网络进行数据降维和特征提取。虽然通过池化操作可以降低维度,但是同时会损失大量有用信息,不利于之后的子任务模块进一步提取对应的特征,因此本文通过在卷积层中设置较大的卷积核和较长的步长来减少数据的维度。使用 Dropout 避免过拟合,使用 SELU 激活函数和批规范化来提高模型的拟合能力和收敛速度。

两个子任务模块分别为故障分类模块和损伤程度识别模块。子任务模块采用门控循环单元来进一步提取特征,门控循环单元相较于全连接神经网络、卷积神经网络可以更好地提取时序特征,相较于传统的循环神经网络解决了长距离依赖问题,与长短期记忆网络相比又减少了参数量和计算量,所以选用门控循环单元作为子任务模块的特征提取网络。同时为进一步防止过拟合在门控循环单元中设置 Dropout 和 Recurrent_Dropout。损失函数由两个任务的损失相加得到,模型损失 L 为:

$$L = \mu L_{\text{fault}} + \lambda L_{\text{defect}} \quad (9)$$

$$L_{\text{fault}} = \sum_{i=1}^N F^{(i)} \log \hat{F}^{(i)} + (1 - F^{(i)}) \log(1 - \hat{F}^{(i)}) \quad (10)$$

$$L_{\text{defect}} = \sum_{i=1}^M D^{(i)} \log \hat{D}^{(i)} + (1 - D^{(i)}) \log(1 - \hat{D}^{(i)}) \quad (11)$$

式中: F_{fault} 为故障分类任务的损失函数; F_{defect} 为损伤程度识别任务的损失函数; μ 和 λ 为两个损失函数的权重,本文 $\mu = 1$, $\lambda = 0.6$; N 和 M 分别为故障类别数和损伤程度类别数,本文 $N = 4$, $M = 4$; $F^{(i)}$ 为样本是第 i 类故障类

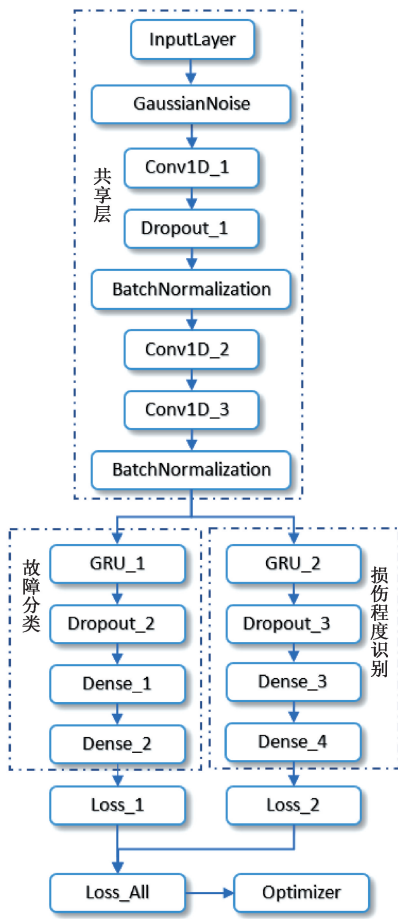


图 2 多任务深度学习模型

Fig. 2 Multi-task deep learning model

别的概率； $\hat{F}^{(i)}$ 为多任务深度学习模型预测样本是第 i 类故障类别的概率； $D^{(i)}$ 为样本是第 i 类损伤程度类别的概率； $\hat{D}^{(i)}$ 为多任务深度学习模型预测样本是第 i 类损伤程度的概率。

训练中使用 Adam 优化器进行优化,学习率设置为 0.001,网络参数的具体设置如表 1 所示。

3 实验研究

3.1 数据集

1) 数据来源

采用凯斯西储大学 (CWRU) 滚动轴承数据集^[26] 来验证多任务深度学习方法的故障诊断性能,该数据集被广泛应用于轴承故障诊断研究。该数据集来自图 3 的轴承故障试验台,从左到右依次为电机、转矩传感器和功率计。数据集包含 0、1、2 和 3 hp 四种负载下的内圈故障、外圈故障和滚动体故障上的单点故障,每种故障包含 0.177 8、0.355 6 和 0.533 4 mm 的 3 种损伤程度,同时数

据集也包含了 4 种负载下正常状态的轴承振动信号。振动信号通过 16 通道的 DAT 记录器以 12 kHz 的采样频率采集。

表 1 网络参数设置

Table 1 The parameters of network structure

网络层名称	参数	输出特征大小
InputLayer	无	2 000×1
GaussianNoise	均值=0,标准差=0.3	2 000×1
Conv1D_1	卷积核=30×1×65,步长=15, 激活函数=SELU	134×30
Dropout_1	0.2	134×30
Conv1d_2	卷积核=30×30×6,步长=1, 激活函数=SELU	134×30
Conv1d_3	卷积核=24×30×65,步长=8, 激活函数=SELU	17×24
GRU_1	输出维度=256,Dropout=0.2,	256
GRU_2	Recurrent_Dropout=0.2	256
Dropout_2	0.5	256
Dropout_3		256
Dense_1	单元数=50,激活函数=ReLU	50
Dense_3		50
Dense_2	单元数=4,激活函数=Softmax	4
Dense_4		4




图 3 试验台

Fig. 3 Experiment rig

2) 数据增强和数据划分

采用滑动窗口取样,使得训练网络所需的数据集中包含尽可能多的相位初值,以提升模型的泛化能力,避免过拟合。从原始信号的起始点开始采集,每个样本采集 2 000 个采样点,窗口向后移动 28 个采样点采集下一个样本,以获得更多样本。

对原始数据进行滑动窗口采样后,按照负载不同进行划分,构建出数据集 A、B、C、D 和 E,其中 E 包含了 4 种不同负载的信号,数据集划分如表 2 所示。数据集 A、B、C、D 和 E 的样本总数分别为 20 000、20 000、20 000、20 000 和 72 000。数据集中的样本根据表 3 和 4 制作故障类别和损伤程度标签。数据集 A、B、C 和 D 中故障分类为正常、滚动体故障、内圈故障和外圈故障的样本数分别为 2 000、6 000、6 000 和 6 000。数据集 E 中故障分类

为正常、滚动体故障、内圈故障和外圈故障的样本数分别为 7 200、21 600、21 600 和 21 600。数据集 A、B、C 和 D 中损伤程度为 0、0.177 8、0.355 6 和 0.533 4 mm 故障的样本数分别为 2 000、6 000、6 000 和 6 000。数据集 E 中损伤程度为 0、0.177 8、0.355 6 和 0.533 4 mm 故障的样本数分别为 7 200、21 600、21 600 和 21 600。

3.2 实验分析

1) 多任务深度学习故障诊断实验

本实验的硬件环境为 Intel i7-9750 H、NVIDIA

GTX1650 和 16 G 内存,软件环境为 Python3.6、TensorFlow-gpu1.14.0 和 Keras2.2.4,模型的输入层大小为 2 000×1, batch_size 为 120,迭代训练 150 次。使用多任务深度学习模型在数据集 A、B、C、D 和 E 上进行实验,在各个数据集上的实验结果如表 5 所示,可以看出多任务深度学习模型的故障诊断性能比较好,可以 100% 准确识别单一负载数据集的故障类别和损伤程度,并且多次训练和测试均可以保持 100% 的准确率,在混合负载的数据集上 E 上也取得了 99.79% 的准确率。

表 2 数据集划分

Table 2 Segmentation of data set

数据集	正常 0	滚动体			内圈			外圈			负载/hp	
		0.177 8	0.355 6	0.533 4	0.177 8	0.355 6	0.533 4	0.177 8	0.355 6	0.533 4		
A	训练集	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	0
	验证集	400	400	400	400	400	400	400	400	400	400	
	测试集	200	200	200	200	200	200	200	200	200	200	
B	训练集	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1
	验证集	400	400	400	400	400	400	400	400	400	400	
	测试集	200	200	200	200	200	200	200	200	200	200	
C	训练集	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	2
	验证集	400	400	400	400	400	400	400	400	400	400	
	测试集	200	200	200	200	200	200	200	200	200	200	
D	训练集	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	1 400	3
	验证集	400	400	400	400	400	400	400	400	400	400	
	测试集	200	200	200	200	200	200	200	200	200	200	
E	训练集	5 040	5 040	5 040	5 040	5 040	5 040	5 040	5 040	5 040	5 040	混合
	验证集	1 440	1 440	1 440	1 440	1 440	1 440	1 440	1 440	1 440	1 440	
	测试集	720	720	720	720	720	720	720	720	720	720	

表 3 故障类别的标记类型

Table 3 Tag types of fault classification

故障类别	标记类型
正常	0
外圈故障	1
内圈故障	2
滚动体故障	3

表 4 损伤程度的标记类型

Table 4 Tag types of defect severity

损伤程度	标记类型
0 mm	0
0.177 8 mm	1
0.355 6 mm	2
0.533 4 mm	3

表 5 多任务故障诊断准确率

Table 5 Accuracy of multi-task fault diagnosis (%)

	A	B	C	D	E
故障分类	100	100	100	100	99.83
损伤程度识别	100	100	100	100	99.94
同时正确	100	100	100	100	99.79

多任务深度学习模型在数据集 E 验证集上的准确率曲线和损失曲线分别如图 4(a) 和 (b) 所示,从准确率曲线可以看出,收敛速度较快,在 50 代之前故障分类和损伤程度识别的准确率已经达到 98% 以上,在 100 代之后故障分类和损伤程度识别的准确率达到一个较高水平。从损失曲线可以看出故障分类损失的波动大于损伤程度识别损失的波动。

2) 与单任务深度学习模型对比

为验证参数共享可以提高故障诊断准确率,分别构建故障分类单任务深度学习模型 (fault classification single-task deep learning model, FCSM) 和损伤程度识别单任务深度学习模型 (defect severity recognition single-task deep learning model, DSRSM) 与多任务深度学习模型进行对比试验。两个单任务深度学习模型的网络结构如图 5 所示, FCSM 和 DSRSM 均由共享层、门控循环单元、Dropout 和全连接层组成,网络层设计和超参数与多任务深度学习模型一致。训练 FCSM 和 DSRSM 使用的数据与训练多任务深度学习模型相同,单一负载数据集 A、B 和 C 中训练集的数量为 14 000,验证集的数量为 4 000,测试集数量为 2 000;混合负载的数据集 D 中训练集的数量为 504 000,验证集的数量为 14 400,测试集的数量为

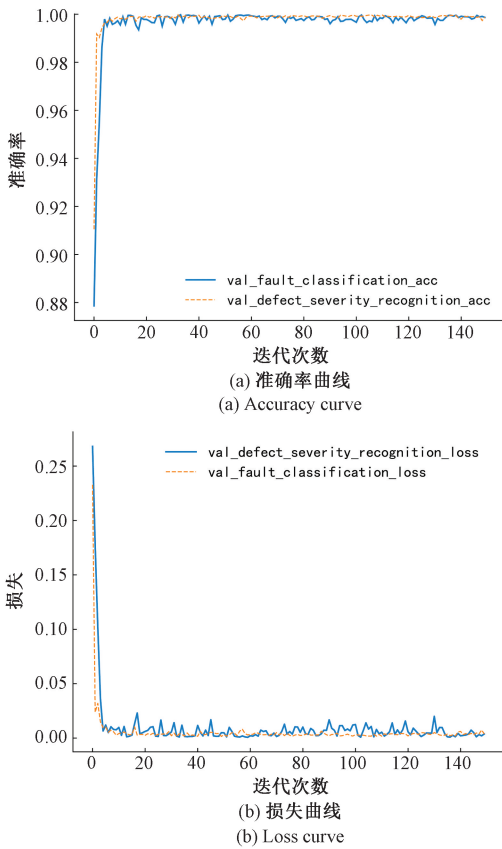


图 4 准确率和损失曲线

Fig. 4 Accuracy and loss curve

7 200,并根据任务不同分别打上故障类别和损伤程度的标签。分别在数据集 A、B、C、D 和 E 上进行实验,实验结果如表 6 所示。

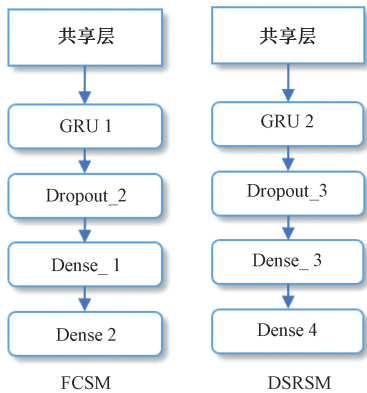


图 5 单任务深度学习模型

Fig. 5 Single-task deep learning model

对比表 5 和 6 得出多任务深度学习模型相较于 FCSM 和 DSRSM 有如下特点:在单一负载的数据集 A、B、C 和 D 上两种方法均可以取得 100%的准确率;但是对于分类难度增大的数据集 E 时,多任务深度学习模型两个

任务同时正确的准确率相较于单任务深度学习模型提高了 0.82%。同时多任务深度学习方法只需训练一个模型,所需要训练的参数相对较少,训练速度更快。

表 6 单任务模型的准确率

Table 6 Accuracy of single task models (%)

模型	A	B	C	D	E
FCSM	100	100	100	100	99.35
DSRSM	100	100	100	100	99.61
同时正确	100	100	100	100	98.97

3) 抗噪实验

为进一步验证多任务深度学习模型具有更好的特征提取能力,在混合负载的数据集 E 上进行抗噪能力实验。使用不添加噪声的训练集训练多任务深度学习模型、FCSM 和 DSRSM,在添加不同程度噪声的测试集中测试故障诊断能力。

在数据集 E 的测试集中添加不同程度的噪声,构建信噪比为 6、8、10、15、20 dB 的测试集。其中信噪比 SNR 的计算公式为:

$$SNR = 10\lg(P_s/P_n) \tag{12}$$

式中: P_s 表示原始信号的有效功率; P_n 表示噪声的有效功率。

不同程度噪声下的多任务深度学习模型、FCSM 和 DSRSM 准确率如表 7 所示,从表 7 可以看到,在较高信噪比的情况下,多任务深度学习模型相比两个单任务深度学习模型的提升不明显。但是在较低信噪比的情况下,多任务深度学习模型的抗噪性能更强,不仅故障分类和损伤程度识别的准确率高于单任务深度学习模型,而且同时正确的准确率也高于单任务深度学习模型。其中在信噪比为 6 dB 的情况下,多任务深度学习模型的故障分类准确率、故障程度识别准确率和同时正确的准确率分别为 97.42%、97.14%和 95.31%,比单任务深度学习模型分别提高了 25.77%、7.08%和 8.91%。验证了多任务深度学习模型相较于单任务深度学习模型提取到的故障特征更好,鲁棒性更强。

表 7 不同程度噪声下的准确率

Table 7 Recognition accuracy under different levels of noise (%)

	单任务模型		两个单任务			多任务模型	
	FCSM	DSRSM	模型同时正确	故障分类	损伤程度识别	同时正确	
6 dB	71.65	90.06	86.40	97.42	97.14	95.31	
8 dB	99.42	99.26	98.68	99.49	99.82	99.31	
10 dB	99.89	99.42	99.30	99.72	99.86	99.58	
15 dB	99.63	99.49	99.11	99.47	99.89	99.39	
20 dB	99.13	99.22	98.36	99.50	99.81	99.31	

4 结 论

本文提出一种故障诊断的多任务深度学习模型,将故障诊断任务分为故障分类任务和损伤程度识别任务,并与单任务深度学习模型进行对比实验,结果表明多任务深度学习模型获得了更高的准确率和更好的鲁棒性。

多任务深度学习模型在故障分类和损伤程度识别任务中都取得了较高的故障诊断准确率。在轴承故障诊断的多任务深度学习模型中,故障分类任务和损伤程度识别任务两个任务通过共享层相互影响,提高了轴承故障特征提取能力。多任务深度学习故障诊断方法与单任务相比抗噪能力更强,在较强噪声的情况下多任务深度学习模型的准确率可以提高 10% 以上。

本文方法的不足之处为训练模型所需的样本数较多,训练时间较长,进一步工作需要简化模型,缩短训练时间,提高网络的诊断速度。

参考文献

- [1] 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.
- [2] HINTON G E, OSINDERO S, THE Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18 (7): 1527-1554.
- [3] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-7.
- [4] 孙文珺,邵思羽,严如强. 基于稀疏自动编码深度神经网络的感应电动机故障诊断[J]. 机械工程学报, 2016, 52(9):65-71.
- SUN W J, SHAO S Y, YAN R Q. Induction motor fault diagnosis based on deep neural network of sparse auto-encoder [J]. Journal of Mechanical Engineering, 2016, 52(9): 65-71.
- [5] 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.
- [6] 唐波,陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.
- TANG B, CHEN SH SH. Method of bearing fault diagnosis based on deep convolutional neural network [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3): 88-93.
- [7] 宫文峰,陈辉,张美玲,等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1):195-205.
- GONG W F, CHEN H, ZHANG M L, et al. Intelligent diagnosis method for incipient fault of motor bearing based on deep learning [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 195-205.
- [8] 周兴康,余建波. 基于深度一维残差卷积自编码网络的齿轮箱故障诊断[J]. 机械工程学报, 2020, 56(7): 96-108.
- ZHOU X K, YU J B. Gearbox fault diagnosis based on one-dimension residual convolutional auto-encoder [J]. Journal of Mechanical Engineering, 2020, 56 (7): 96-108.
- [9] 吴春志,江鹏程,冯辅周,等. 基于一维卷积神经网络的齿轮箱故障诊断[J]. 振动与冲击, 2018, 37(22): 51-56.
- WU CH ZH, JIANG P CH, FENG F ZH, et al. Faults diagnosis method for gearboxes based on a 1-D convolutional neural network [J]. Journal of Vibration and Shock, 2018, 37(22): 51-56.
- [10] 咎涛,王辉,刘智豪,等. 基于多输入层卷积神经网络的滚动轴承故障诊断模型[J]. 振动与冲击, 2020, 39(12):142-149.
- ZAN T, WANG H, LIU Z H, et al. A fault diagnosis model for rolling bearings based on a multi-input layer convolutional neural network [J]. Journal of Vibration and Shock, 2020, 39(12): 142-149.
- [11] 周奇才,沈鹤鸿,赵炯,等. 基于改进堆叠式循环神经网络的轴承故障诊断[J]. 同济大学学报(自然科学版), 2019, 47(10):1500-1507.
- ZHOU Q C, SHEN H H, ZHAO J. Bearing fault diagnosis based on improved stacked recurrent neural network [J]. Journal of Tongji University (Natural Science), 2019, 47(10): 1500-1507.
- [12] 王太勇,王廷虎,王鹏,等. 基于注意力机制 BiLSTM 的设备智能故障诊断方法[J]. 天津大学学报(自然科学与工程技术版), 2020, 53(6):601-608.
- WANG T Y, WANG T H, WANG P, et al. An intelligent fault diagnosis method based on attention-based Bidirectional LSTM network [J]. Journal of Tianjin University (Science and Technology), 2020, 53 (6): 601-608.

- [13] CARUANA R. Multitask learning [J]. Machine Learning, 1997, 28(1):41-75.
- [14] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6):1137-1149.
- [15] WANG Z, HE K, FU Y, et al. Multi-task deep neural network for joint face recognition and facial attribute prediction [C]. Proceedings of the 2017 ACM on International Conference on Multimedia Retrieval, 2017: 365-374.
- [16] WU B, WEI B, LIU J, et al. Faceted text segmentation via multitask learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, DOI:10.1109/TNNLS.2020.3015996.
- [17] LIU X, HE P, CHEN W, et al. Multi-task deep neural networks for natural language understanding [C]. Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, 2019: 4487-4496.
- [18] ZHANG Y, YANG Q. An overview of multi-task learning [J]. National Science Review, 2018, 5(1): 30-43.
- [19] RUDER S. An overview of multi-task learning in deep neural networks [DB/OL]. [2021-2-3]. <https://arxiv.org/abs/2011.02888v1>.
- [20] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines [C]. Proceedings of the 27th International Conference on Machine Learning (ICML-10), 2010: 807-814.
- [21] LU L, SHIN Y, SU Y, et al. Dying ReLU and initialization: Theory and numerical examples [DB/OL]. <https://export.arxiv.org/abs/1903.06733>.
- [22] 邵海东, 张笑阳, 程军圣, 等. 基于提升深度迁移自动编码器的轴承智能故障诊断[J]. 机械工程学报, 2020, 56(9):84-90.
- SHAO D H, ZHANG X Y, CHENG SH J. Intelligent fault diagnosis of bearing using enhanced deep transfer auto-encoder [J]. Journal of Mechanical Engineering, 2020, 56(9):84-90.
- [23] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]. Proceedings of the 32nd International Conference on Machine Learning, 2015: 448-456.
- [24] SRIVASTAVA N, HINTON G E, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15(1):1929-1958.
- [25] WANG Y, LIAO W, CHANG Y. Gated recurrent unit network-based short-term Photovoltaic forecasting [J]. Energies, 2018, 11(8):1-14.
- [26] 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, 64-65:100-131.

作者简介



赵志宏(通信作者), 1998年于河北师范大学获得学士学位, 2003年于河北大学获得硕士学位, 2012年于北京交通大学获得博士学位, 现为石家庄铁道大学教授, 主要研究方向为机械故障诊断、机器学习、信号处理、动力学分析。

E-mail: hb_zhaozhihong@126.com

Zhao Zhihong (Corresponding author) received his B. Sc. degree in 1998 from Hebei Normal University, M. Sc. degree in 2003 from Hebei University, and Ph. D. degree in 2012 from Beijing Jiaotong University. Now he is a professor at Shijiazhuang Tiedao University. His main research interests include diagnosis of mechanical equipment, machine learning, signal processing and dynamics analysis.