DOI: 10.3901/JME.2019.03.073

基于残差网络的 RV 减速器故障诊断*

汪久根 柯梁亮

(浙江大学机械工程学院 杭州 310058)

摘要: 为了提升对 RV 减速器的故障诊断的准确率,采用残差网络诊断 RV 减速器的故障。通过振动试验台测得 RV 减速器 4 种故障模式与正常模式下的振动信号,由此构造训练和测试数据集,并对训练集进行数据增强处理。然后将截取的一维信号样本预处理转换为二维信号样本,输入残差网络进行训练和 5 折交叉验证。接着通过残差网络的分类准确率与 DNN、LeNet、10 层 CNN 等模型的准确率进行比较,结果表明残差网络优于传统方法,对 RV 减速器故障的分类准确率达到 98.11%。进一步采用了西储大学轴承数据集对模型的泛用性进行验证。最终,通过 LDA(线性判别分析)对残差网络平均池化层的输出进行降维,分析了散点图与 RV 减速器故障类型之间的关系。

关键词: RV 减速器; 残差网络; 故障诊断; 振动信号; 深度学习

中图分类号: TH132

Fault Diagnosis for RV Reducer Based on Residual Network

WANG Jiugen KE Liangliang

(School of Mechanical Engineering, Zhejiang University, Hangzhou 310058)

Abstract: In order to improve the accuracy of the fault diagnosis of the RV reducer, a residual network is used to diagnose the faults of the RV reducer. The vibration signals of four kinds of fault mode and normal mode of the RV reducer are measured through the vibration test bench, the training and test data sets are constructed with those signals, and the data of the training set was augmented. After that, with data preprocessing, one-dimensional signal samples are converted into two-dimensional signal samples and are imported in the residual network for training and 5-folds cross validation. Then, the classification accuracy of the residual network is compared with that of DNN, LeNet and 10 layers CNN. The results show that the residual network is better than the traditional methods, the classification accuracy for the RV reducer reaches 98.11%. Furthermore, the western reserve university's bearing data set is used to verify the universality of the new model. Finally, LDA(Linear Discriminant Analysis) is used to reduce the dimension of the output of the average pooled layer of the residual network, and the relationship between the scattergram and the fault type of the RV reducer was studied.

Key words: RV reducer; residual network; fault diagnosis; vibration signal; deep learning

0 前言

在“中国制造 2025”的概念背景下,工业机器人产业存在着巨大的发展空间。国家发改委所发布的《机器人产业发展规划(2016-2020)》表明,机器人产业整体的发展规划在千亿级别。在机器人部件中, RV 减速器是核心部件,相关的研究中^[1],主要是关于受力分析^[2]、动力学建模^[3]、试验装置^[4]等方面,故障诊断方面的研究较少。

加速度振动信号包含了机械设备的故障信息,

是进行故障诊断的常用对象。众多学者结合机器学习算法与加速度振动信号的特征,提出了不同的故障诊断方法与思路。胥永刚等^[5]将双树复小波变换与 SVM 结合,在四种轴承故障的识别中获得了较好的效果。ROCCHETTA 等^[6]使用贝叶斯模型实现了机械零件的裂纹的检测。申中杰等^[7]将 SVM 应用于轴承的寿命预测。近年来,深度学习的出现为故障诊断提供了新的方法。雷亚国等^[8]基于深度学习理论对机械的状态监测方法进行了研究。TAMILSELVAN 等^[9]将深度信念网络应用于机械设备的故障检测当中。ALI 等^[10]使用经验模态分解和人工神经网络,对轴承的故障诊断进行了研究。CHEN 等^[11]将卷积神经网络应用于齿轮箱故障的识别,在其数据集上获得了平均 96.8% 的识别准确度。

* 国家高技术研究发展计划(863 计划, 2015AA043002)、国家自然科学基金(51375436)和浙江省重大科技专项(2017C01047)资助项目。20180516 收到初稿, 20180917 收到修改稿

WEN 等^[12]提出了将信号分段堆叠的信号预处理方法,并与卷积网络结合应用于多个开源的故障信号数据库的识别,取得了较好的效果。残差网络由 HE 等^[13]在 2015 年提出,在图像识别、分类上取得了较传统 CNN 更为优秀的效果^[14]。ZHAO 等^[15]将小波包变换与残差网络应用在了行星齿轮减速器的故障模式识别当中。以上研究中,大部分研究采用的是浅层学习模型,深层模型的应用较少。

为了进一步提高对 RV 减速器不同故障的分类准确率,本文对 RV 减速器振动测试试验台测得的 4 类 RV 减速器故障信号和正常信号进行分析,讨论了信号预处理的方法,并采用残差网络对 RV 减速器的故障信号进行分类。最后对残差网络的分类结果进行了对比与分析。

1 残差网络模型

残差网络主要优点有:① 解决了深层网络模型反向传播时梯度消散的问题,降低了训练深层模型的难度;② 加快了实际训练的过程中模型的收敛速度;③ 去除了全连接层,降低了参数数量。本文所使用的残差网络模型如图 1 所示。

图 1 残差网络模型

网络中包含了 2 个卷积层和 4 个残差块,每个残差块又包含 2 个卷积层,共 10 个卷积层。由于数据集本身存在误差,过深的网络可能引起误差的放大,造成训练效果下降,因此,需要对网络深度加以控制,选择合适层数的残差网络。

1.1 激活函数

Relu 函数是常用的激活函数之一,其公式为

$$\text{Relu}(x) = \max(0, x) \quad (1)$$

Softmax 函数用于多分类的输出,函数形式为

$$S_i = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2)$$

式中, S_i 表示输入为第 i 类样本的概率; x_i 表示残差网络对应第 i 类样本的输出值,选取使得 S_i 为最大值的 i 作为分类结果。

1.2 卷积层

卷积层实现了数据传递过程中的稀疏交互和参数共享,降低了模型的参数数量。卷积层中包含了 4 个参数,从左到右依次为卷积核行数、列数、单次移动步长和卷积核的数量。对于二维输入数据 X ,设步长为 1,卷积层的卷积过程可以表示为

$$\text{Conv}(x)_{i,j} = \sum_m \sum_n X_{i-m,j-n} K_{m,n} \quad (3)$$

式中, X 表示输入矩阵; K 表示卷积核; m, n 表示卷积核的行列值,具体计算过程如图 2 所示。

图 2 卷积计算过程图

1.3 残差块

1.3.1 残差块结构

残差块的结构如图 3 所示,包含了两个卷积层与一个 ShortCut 连接。右半部分图中 n 的值由具体网络结构而定。本文采用残差网络模型中,4 个残差块中卷积层的参数各不相同,具体参数如表 1 所示。

图 3 一般残差块和需要张量匹配的残差块

表 1 残差块参数

残差块	卷积层参数	
	Conv1	Conv2
Block1	Conv(3,3,1,64)	Conv(3,3,1,64)
Block2	Conv(3,3,1,64)	Conv(3,3,2,64)
Block3	Conv(3,3,1,128)	Conv(3,3,1,128)
Block4	Conv(3,3,1,256)	Conv(3,3,1,256)

残差块中卷积核的大小均为 3，主要区别在于步长与卷积核数量。第二个残差块通过步长为 2 的卷积核进一步将输入数据的边长减小一半，减小了模型训练过程的计算量。同时，由于 Block2 中步长为 2 的卷积层使得输出的张量维数会与输入的张量维数不同，无法直接相加。因此，在 Block2 中的 Shortcut 部分需要加入一个步长为 2 的卷积核对输出进行处理，使得两个张量的维数能够匹配。

1.3.2 ShortCut 连接

每个残差块中包含了一个 ShortCut 连接，表示在残差块的实际输出为卷积层输出加上残差块的输入。ShortCut 使卷积层学习得到的函数由 $F(x)$ 变为 $H(x)=F(x)+x$ 。这保证了在反向传播的过程中，对 $H(x)$ 计算得到的梯度不会趋向于 0。

1.4 残差网络训练

1.4.1 超参数

残差网络的超参数包括学习率、训练批量大小、训练次数等，在网络模型确定之后，超参数的调整对模型的最终结果存在着重要影响。一般的训练过程中，学习率是影响最大的超参数。学习率越大，收敛越快，但是结果越不稳定。本文中的模型先采用 0.000 1 的学习率预训练 20 个迭代步，然后增大至 0.001 训练，之后在模型的分类准确度较高时减小为 0.000 1，直至模型的误差收敛。用较小的学习率进行预训练能够防止模型中由于训练开始时损失数值过大引起的节点权值后续更新困难等问题。

此外，批量的大小也较为重要。较小的批量使得参数更新较快，但容易使模型难以收敛；较大的批量更容易使模型收敛，但参数更新缓慢。本文中的残差网络模型在 256 的批量下已能够达到较好的结果，与 512 等更大的批量相差不大；而当批量减小为 128 或更小时，模型训练结果会有较大的波动，因此选择批量为 256。

1.4.2 损失函数

交叉熵是常用的一种损失函数，公式为

$$H(x) = -\sum_{i=1}^N p_i(x) \lg(q_i(x)) \quad (4)$$

式中， N 为类型数量； x 表示一个输入样本； $p_i(x)$ 与 $q_i(x)$ 分别表示输入样本属于第 i 类类型的实际概率与模型预测概率。当需要对单元进行 L2 正则化时，可添加正则化项，此时公式变为

$$H(x) = -\sum_{i=1}^N p_i(x) \lg(q_i(x)) + \lambda \sum_{j=1}^M \|\omega_j\| \quad (5)$$

式中， M 为正则化部分的参数数量； ω 为参与正则化的参数项； λ 为正则化系数，决定了正则化的程

度。L2 正则化限制了参数值的大小，能够防止过拟合。试验过程中选取了 0、0.000 01、0.000 1 作为正则化系数，但是对于文中残差网络模型的识别准确率影响十分微小，故后续均取 0 进行计算。

1.5 LDA 降维

LDA(线性判别分析)降维主要依据不同类别的样本在空间中分布的类内散度与类间散度，目的在于将不用类别的数据尽可能的分开。高维度下的 LDA 函数为

$$J(W) = \frac{W^T S_b W}{W^T S_w W} \quad (6)$$

式中， S_b 表示类间散度， S_w 表示类内散度，通过迭代改变权值 W 的值使得 $J(W)$ 最大化，最终使得数据能够在给定维度下以最分散的形式表示。

2 振动信号测试

2.1 系统结构

振动信号测试系统中，各元器件型号对应如表 2，整体结构图如图 4 所示。试验台通过伺服电动机驱动 RV 减速器转动，由磁粉制动器加载，输出转速、扭矩分别由角度编码器、扭矩传感器测得。该系统属于功率开放式结构，结构简单、控制精度高，适合 RV 减速器的振动信号测试。

表 2 加速度振动试验台元器件表

编号	名称	型号
1	磁粉制动器	CZ-50
2	扭矩传感器	JN338-AE
3	角度编码器	BCE94BK30
4	RV 减速器	SHPR-20E
5	伺服电动机	SGM7A-15AFA61

图 4 RV 减速器加速度振动信号测试系统

本文中的各项试验条件如表 3 所示。伺服电机的转速取恒定值，多种负载工况。

表 3 工况参数表

参数	数值
电动机转速/(r/min)	400
减速器负载/(N·m)	0,20,40,60,80,100,120
采样频率/Hz	2 000

2.2 传感器安装

试验中所采用的传感器为贴片式加速度传感器, 型号为 1C102, 灵敏度 $20 \text{ mV}/(\text{m/s}^2)$, 有效频率范围 $0 \sim 1000 \text{ Hz}$, 量程 $0 \sim 100 \text{ m/s}^2$ 。传感器通过胶水贴附于 RV 减速器上较为平坦的表面, 具体的安装位置如图 5, 分别测量水平径向、水平轴向、垂直径向三个方向的振动。考虑试验台结构, 本文选用水平轴向的振动信号进行故障诊断。

图 5 加速度传感器安装位置

2.3 振动信号的预处理

2.3.1 信号归一化

为了增加模型的可靠性, 需要对输入信号进行归一化处理, 具体公式为

$$y = \frac{x - \bar{x}}{\max(x) - \min(x)} \quad (7)$$

式中, x 表示信号的原始值; y 表示归一化后的值。

2.3.2 数据集增强

如图 6 所示, 当步长小于单个样本的信号长度时, 样本之间存在重叠部分, 固定长度的信号能够提取更多的样本; 当步长与数据长度相同时, 即无数据集增强效果。本文中对步长取 170。

图 6 信号样本截取示意图

2.3.3 信号维数转换

由于 RV 减速器的加速度振动信号是一位序列, 不利于残差网络的计算, 因此需要将一维信号转换成二维信号, 优化残差网络的计算。

如图 7 所示, 本文中采用原始样本信号逐行堆叠的方式进行信号的维度转换, 矩阵第一行包含原样本信号中的第 1 至第 n 个数据, 第二行包含第 $n+1$

至第 $2n$ 个数据。将 1 024 长度的样本信号转换为 32×32 、 16×64 等不同行列数的二维信号。

图 7 维度转换示意图

2.4 故障模式

由于试验条件有限, 试验中共选择了 4 种故障信号与正常信号, 一共 5 种类型的信号, 如表 4 所示。4 类故障情况中, 标签为 3、4 的两类信号为复合故障信号。复合故障信号较 1、2 类的故障更难识别, 对故障诊断模型要求更高。各故障对应的零件表面点蚀坑图片如图 8 所示, 每类故障信号包含了表 3 中所列的不同负载工况。

表 4 RV 减速器故障表

标签号	RV 减速器状况
0	无故障
1	行星齿轮点蚀
2	摆线轮点蚀
3	行星轮点蚀+针销点蚀
4	摆线轮点蚀+针销点蚀

图 8 RV 减速器摆线轮、行星齿轮、针销点蚀故障图

正常信号的时域图如图 9 所示, 可以观察到 RV 减速器的非线性。由于 RV 减速器中的结构较为复杂, 内部零件较多, 简单的通过信号的时域、频域特征较难对 RV 进行有效的诊断。

图 9 正常 RV 减速器加速度振动信号

3 结果讨论

3.1 分类准确率

对于采集到的振动信号，在每种工况中截取 600 个样本信号，选取 80%作为训练集，20%作为测试集，然后对训练集进行数据增强。最终，训练集包含 100 800 个训练样本，测试集包含 4 200 个测试样本。每个样本包含 1 024 个数据点，堆叠为 32×32 的二维样本。在完成数据集的构建后，通过 GTX1070Ti 显卡训练残差网络，每 200 个迭代步计算一次测试集准确度。其分类准确度曲线图如图 10，误差曲线图如图 11 所示。在以 0.001 的学习率训练 6 000 步后将学习率更改为 0.000 1，残差网络的分类准确度与损失均达到收敛。

图 10 残差网络分类准确率图

图 11 残差网络分类损失图

进一步地对残差网络进行 5 折交叉验证，并重复 3 次，结果如表 5 所示。训练集的准确度能够收敛到 100%，可以判断模型不存在欠拟合。表中全部测试集的准确度平均值为 98.11%，模型的泛化能力较好，因此认为模型不存在过拟合。

表 5 残差网络 5 折交叉验证(%)

数据集		1	2	3	4	5
一	训练	100	100	100	100	100
	测试	98.59	97.85	98.06	97.85	98.26
二	训练	100	99.61	100	100	100
	测试	98.43	97.83	98.06	97.93	98.36
三	训练	100	100	100	100	100
	测试	98.47	97.76	98.13	97.90	98.17

3.2 不同行列数的影响

在进行信号的维度转换时，考虑对信号采取不同的堆叠方式会影响到残差网络卷积层内部的计算，因此需要对维数转换形成的不同行列数的二维信号进行分类结果的对比，分析堆叠方式对模型训练结果的影响。结果如表 6 所示，在同样的数据集下，将 32×32 的输入矩阵更改为 64×16 或者 128×8 的矩阵时，残差网络的分类准确率进一步上升到 99.12%。结果表明不同的堆叠方式会对残差网络模型预测的准确率造成较大的影响。当行数小于列数时，模型的分类准确率会随着两者的差距增大而明显下降；当行数大于列数时，模型的分类准确率能够稳定在一个较高水平。在模型的构建过程中，行列数的变化也可以当作一种模型优化方法使用。

表 6 不同行数的样本分类准确率(%)

行数	列数	分类准确率			
		一	二	三	平均值
8	128	91.77	92.11	91.67	91.85
16	64	94.19	94.46	94.27	94.31
32	32	98.12	98.12	98.09	98.11
64	16	99.27	99.19	98.89	99.12
128	8	99.29	99.19	99.10	99.19

3.3 泛用性验证

残差网络模型对于 RV 减速器故障能够达到一个较高的分类准确率，但模型可能存在一定的局限性。为了验证本文中的残差网络模型的泛用性，采用公开的西储大学轴承数据库，选取多类轴承故障信号进行识别，数据集处理方式与 RV 减速器故障信号的处理方式相同。

表 7 轴承故障表

标签号	故障类型
0	无故障
1	内圈故障
2	外圈故障
3	滚动体故障

表8 轴承故障分类准确率表(%)

数据集	1	2	3	4	5
训练集	100	100	100	99.61	100
测试集	99.63	99.42	99.55	99.31	99.55

根据5折交叉验证的结果,可知残差网络模型在滚动轴承数据集上也能够达到99.49%的平均分类准确率。这论证了残差网络模型具有一定的泛用性,同样的网络模型对于不同对象、不同类型的振动信号均能够进行识别与分类。

3.4 效果对比

为了验证残差网络的在RV减速器故障诊断当中相对传统模型的优势,采用传统的故障诊断方法对RV减速器信号进行故障模式识别,对比不同方法的分类准确度。由于SVM(支持向量机)需要特征工程支持,非本文研究重点,且简单验证了其配合小波包变换时的分类效果较差,准确率均在50%以下,故不再进一步进行交叉验证。对DNN(深度神经网络)、LeNet(卷积神经网络)以及去除了ShortCut连接后的10层CNN模型进行5折交叉验证,重复3次,分类准确率如表9所示。DNN包含了三个隐含层,一个输入层和一个输出层,在本文RV减速器故障数据集上的表现较差,分类准确率在70%以下,而传统的CNN模型LeNet的分类准确率平均值为86.50%。相较于传统的神经网络模型DNN,深度学习模型更能够有效地对RV减速器故障信号进行识别和分类。与浅层模型LeNet相比,10层CNN作为深层模型具有更强的识别能力。进一步将残差网络与10层CNN的分类准确率进行对比,残差网络的分类准确率整体上有了2%~3%的提高,说明了残差网络中的ShortCut结构的有一定的优越性,能够提升网络的识别能力。

表9 LeNet、DNN 分类准确率表(%)

模型	1	2	3	4	5
10层CNN	95.35	96.26	96.19	95.33	96.16
一 LeNet	85.03	87.10	87.05	86.21	86.69
DNN	59.87	65.35	63.54	61.52	63.18
10层CNN	95.56	95.88	95.56	94.62	96.24
二 LeNet	84.34	86.92	87.55	85.91	87.17
DNN	59.42	65.38	63.91	62.00	63.64
10层CNN	95.06	96.14	95.02	95.23	95.91
三 LeNet	84.92	86.97	87.80	86.49	87.35
DNN	58.48	65.20	64.14	61.47	62.80

4 LDA 降维分析

在本文的残差网络中,平均池化层的输出可以

看作为残差网络提取到的特征,维数为256维。由于其维数大于3,需要对数据进行降维处理。由于存在5类样本,降维至二维空间可能会使得样本之间存在重叠,因此需要通过LDA降维将原始数据维数降低至三维,在空间中可视化。

图12~14依次是残差网络模型迭代了0、4500、8000步之后对平均池化层的输出进行LDA降维后的三维散点图。散点图中的坐标轴无实际意义,因此用系数1、2、3分别作为三个坐标的名称。

图12 迭代步数0时的平均池化层输出

图13 迭代步数4500时的平均池化层输出

散点图中,不同形状的数据点分别代表了5类RV减速器振动信号。初始状态,由于模型内部参数的随机初始化,5类数据点分布杂乱,此时模型不具有特征提取能力。在训练4500个迭代步后,结合图13,此时模型的分类准确率在90%附近,相同类型的数据点开始聚集,且不同类型的数据点逐渐分离,但仍然存在一定数量的数据点相互混杂。在迭代8000步后,残差网络的分类准确度和损失均达到收敛,不同故障类型的数据点在3维空间中的

图 14 迭代步数 8000 时的平均池化层输出

达到了一个较好的分布, 相互之间的混杂较少, 各类型之间可以观察到明显的交界位置。

从散点图的变化过程也可以进一步分析不同故障之间的关联性。结合故障类型表 4, 类型为 0、1、2 即代表无故障、行星轮点蚀、摆线轮点蚀的 3 类数据点相对于类型 3、4 两类复合故障的数据点分散较快, 在迭代 4 500 步后, 0、1 两类整体上已经分散开。在迭代 8 000 步之后, 非复合故障类型的数据点相互之间的距离更远, 说明复合故障的特征较普通故障更难提取。结合表 10, 复合故障类型部分有更多的分类错误, 如 1、3 与 3、4 这两部分。2、4 两类虽均包含了摆线轮故障, 但可能由于该故障比较容易识别, 因此错分类错误较少。0、1 两类存在分类错误可能由于试验台结构导致行星轮处受到试验台本身振动的影响, 掺杂了噪声, 从而产生了错误的分类。整体上, 通过图表可以认为复合故障更难诊断, 与实际状况吻合。

表 10 残差网络测试集分类结果

		预测类型				
		0	1	2	3	4
实际 类型	0	695	5	0	0	0
	1	2	686	0	8	4
	2	0	1	697	1	1
	3	3	11	1	681	4
	4	1	1	0	3	695

5 结论

(1) 通过残差网络对 RV 减速器加速度振动信号进行了故障诊断, 仅对数据进行归一化处理和维数转换, 省略了特征工程环节, 简化了故障诊断的流程。

(2) 通过数据增强优化训练集, 提升了残差网络的分类性能, 选择的参数使得残差网络对 5 类 RV 减速器故障信号的分类准确率达到 98.11%。

(3) 通过改变二维信号样本的行列数, 讨论了堆叠方式的改变对残差网络的分类准确率的影响, 并进一步优化了残差网络的分类效果。

(4) 通过 LDA 将残差网络内部平均池化层的 256 维的输出降至 3 维, 绘制的散点图反映了残差网络本身的特征提取能力。此外, 进一步根据散点图的分布和变化过程讨论了散点图与 RV 减速器故障类型的联系。

参 考 文 献

- [1] 张小丽, 陈雪峰, 李兵, 等. 机械重大装备寿命预测综述[J]. 机械工程学报, 2011, 47(11): 100-116.
ZHANG Xiaoli, CHEN Xuefeng, LI Bing, et al. Review of life prediction for mechanical major equipments[J]. Journal of Mechanical Engineering, 2011, 47(11): 100-116.
- [2] 何卫东, 李力行, 徐永贤, 等. 高精度 RV 传动的受力分析及传动效率[J]. 机械工程学报, 1996, 32(4): 104-110.
HE Weidong, LI Lixing, XU Yongxian, et al. Analysis on the forces and efficiency of RV transmission for high precision[J]. Chinese Journal of Mechanical Engineering, 2011, 32(4): 104-110.
- [3] 张大卫, 王刚, 黄田, 等. RV 减速机动力学建模与结构参数分析[J]. 机械工程学报, 2001, 37(1): 69-74.
ZHANG Dawei, WANG Gang, HUANG Tian, et al. Dynamic formulation of RV reducer and analysis of structural parameters[J]. Chinese Journal of Mechanical Engineering, 2001, 37(1): 69-74.
- [4] 陈李果, 彭鹏, 汪久根, 等. RV 减速器试验装置研制及测试分析[J]. 机械传动, 2017(11): 92-96.
CHEN Liguang, PENG Peng, WANG Jiugen, et al. Development and test analysis of RV reducer experimental rig[J]. Journal of Mechanical Transmission, 2017(11): 92-96.
- [5] 胥永刚, 孟志鹏, 陆明. 基于双树复小波包变换和 SVM 的滚动轴承故障诊断方法[J]. 航空动力学报, 2014, 29(1): 67-73.
XU Yonggang, MENG Zhipeng, LU Ming. Fault diagnosis method of rolling bearing based on dual-tree complex wavelet packet transform and SVM[J]. Journal of Aerospace Power, 2014, 29(1): 67-73.
- [6] ROCCHETTA R, BROGGI M, HUCHET Q, et al. On-line Bayesian model updating for structural health monitoring[J]. Mechanical Systems & Signal Processing,

- 2018, 103: 174-195.
- [7] 申中杰, 陈雪峰, 何正嘉, 等. 基于相对特征和多变量支持向量机的滚动轴承剩余寿命预测[J]. 机械工程学报, 2013, 49(2): 183-189.
- SHEN Zhongjie, CHEN Xuefeng, HE Zhengjia, et al. Remaining life predictions of rolling bearing based on relative features and multivariable support vector machine[J]. Journal of Mechanical Engineering, 2013, 49(2): 183-189.
- [8] 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 Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [9] TAMILSELVAN P, WANG P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115(7): 124-135.
- [10] ALI J B, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals[J]. Applied Acoustics, 2015, 89(3): 16-27.
- [11] CHEN Z Q, LI C, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J]. Shock & Vibration, 2015, 2015(2): 1-10.
- [12] WEN L, LI X, GAO L, et al. A new convolutional neural network based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2017, PP(99): 1-1.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[J]. Computer Vision and Pattern Recognition, 2015: 770-7.
- [14] IAN G, YOSHUA B, AARON C. Deep learning[M]. Cambridge: The MIT Press, 2016.
- [15] ZHAO M, KANG M, TANG B, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes[J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
-
- 作者简介: 汪久根, 男, 1963 年出生, 博士, 教授, 博士研究生导师。主要研究方向为摩擦学与仿生设计。
E-mail: me_jg@zju.edu.cn
柯梁亮(通信作者), 男, 1995 年出生, 硕士研究生。主要研究方向为 RV 减速器故障诊断和寿命预测。
E-mail: 2691047652@qq.com