DOI: 10.3901/JME.2020.01.030

噪声干扰下的 RV 减速器故障诊断*

彭 鹏 柯梁亮 汪久根
(浙江大学机械工程学院 杭州 310027)

摘要: 在实际工况下, 旋转矢量(Rotate vector, RV)减速器的振动信号往往掺杂噪声。被噪声污染后的振动信号给 RV 减速器的故障诊断带来挑战。为此, 提出一种噪声干扰下的卷积神经网络模型(Anti-noise network, ANNet)以实现 RV 减速器的故障模式识别。该模型首先将一维振动信号通过信号堆叠的方式转化成二维灰度图像, 然后采用 Dropout 操作直接对原始输入信号进行随机干扰, 并同时利用多个不同尺度的卷积核对输入信号的不同特征进行自动提取和融合。进一步将 ANNet 算法与其他算法进行了对比分析, 结果表明在不同强度的噪声干扰下, ANNet 算法相比于其他算法具有更强的抗噪干扰能力; 尤其是在强噪干扰环境下, ANNet 模型的诊断准确率比现有算法高出 10%~20%。最后探讨和解释了模型的特殊结构设计以及模型具备抗噪能力的原因。

关键词: RV 减速器; 噪声干扰; 输入 Dropout; 多尺度卷积核; 故障诊断

中图分类号: TH132

Fault Diagnosis of RV Reducer with Noise Interference

PENG Peng KE Liangliang WANG Jiugen

(School of Mechanical Engineering, Zhejiang University, Hangzhou 310027)

Abstract: The vibration signal of rotate vector (RV) reducer is often covered with noise, which poses challenges to the fault diagnosis of RV reducer. To this end, a novel model of convolution neural network (Anti-noise network, ANNet) is proposed to achieve the fault mode identification of RV reducers under noise interference. The one-dimensional vibration signal is first converted into a two-dimensional gray image with the method of signal stacking, and then the dropout operation is utilized to directly interfere with the original input signal. Additionally, different sizes of kernels are applied to extract and fuse the different features of the input signal. Furthermore, the proposed method is compared with other algorithms. The results demonstrate that the proposed algorithm has a stronger anti-noise performance than that of others. Particularly, under the condition of intense noise (3 dB), the accuracy of the model is 10%-20% higher than the existing approaches. Finally, the special structural design of the proposed model and the reason for anti-noise performance of the model are discussed and explained.

Key words: RV reducer; random noise; Dropout of input signal; multi-scale kernels; fault diagnosis

0 前言

随着“中国制造 2025 计划”的提出, 工业机器人产业得到加速发展。作为工业机器人三大核心部件之一的减速器也再次迎来了新的发展机遇。目前工业机器人中所使用的减速器主要分为谐波减速器和 RV 减速器。相比于谐波减速器, RV 减速器具有刚度大、承载能力大、以及结构紧凑等优点, 且有替代谐波减速器的趋势, 因而 RV 减速器一直是众多学者研究的热点对象^[1-2]。但目前的研究中很少涉

及 RV 减速器失效模式的诊断。

在现有的故障诊断方法中, 基于振动信号对 RV 减速器进行故障诊断是可行方法之一^[3]。利用振动信号进行故障诊断的方法可分为传统的机器学习诊断方法^[4-5]和当前流行的深度学习诊断方法^[6]两种。研究表明, 深度学习诊断方法相对于传统的机器学习诊断算法能够避免繁琐的手工特征设计操作, 在样本数据量足够多的条件下, 深度学习方法相比于传统机械学习方法具有较大优势^[6]。常见用于机械设备健康状态监测的深度学习方法有深层神经网络(Deep neural network, DNN)、自编码器(Autoencoders, AE)、长短期记忆网络(Long short-term memory, LSTM)以及卷积神经网络(Convolutional neural network, CNN)等^[7-11]。其中卷积神经网络发

* 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。20190226 收到初稿, 20190807 收到修改稿

展最为迅速,许多学者借鉴 LeNet^[12]、AlexNet^[13]、VGGNet^[14]、GoogLeNet^[15]以及 ResNet^[16]等卷积神经网络模型的设计经验成功的解决了多种机械设备的故障诊断问题。WEN 等^[17]借鉴了经典的 LeNet 网络设计经验,并结合信号转换方法实现了对轴承故障的分类。ZHAO 等^[18]利用了 ResNet 中的模块结构并结合小波变换实现了对风电齿轮箱的故障诊断。但实际工况下随机噪声会污染振动信号,给故障识别带来挑战^[19]。为考虑实际工况下的噪声干扰, PAN 等^[20]提出 LiftingNet 来实现对轴承故障的诊断。ZHANG 等^[21]提出一种简单有效的训练干扰卷积神经网络模型(Convolution neural networks with training interference, TICNN)来识别含有噪声的轴承故障信号。然而, TICNN 中不同大小的卷积核对最终的诊断结果影响较大。

考虑到 RV 减速器振动信号中存在随机噪声的干扰以及现有卷积神经网络算法的一些不足,本文提出一种抗噪声干扰的 RV 减速器故障诊断算法(ANNet)。ANNet 利用 Dropout 操作对输入信号进行随机干扰,然后采用多尺度卷积核模块实现对干扰信号的多尺度特征学习与特征融合。文章后续的内容组织如下:第一节中将详细介绍本文算法的实现过程;在第二节中,描述了本文的实验过程以及本文算法与其他算法相对比的结果;第三节详细解释了 ANNet 具备抗噪能力的原因;第四节给出了本文的结论。

1 ANNet 模型

1.1 信号堆叠

为了利用 RV 减速器多个维度的信号特征,本文首先利用信号堆叠方法^[17]将一维振动信号转换为二维灰度图像。信号堆叠的方式如图 1 所示。图 1 中,每一个序列 a_i 中包含 m 个数据点,将 n 个这样的序列按顺序依次堆叠即可形成大小为 $m \times n$ 二维图像。在本文中 m 和 n 都取 32,即构成一个 32×32 大小的灰度图像。

图 1 一维振动信号转二维图像信号

1.2 输入信号 Dropout

Dropout 技术的原理是:按照一定的概率随机将某些神经元置零,以破坏同层神经元之间的相互作用。该技术常用于卷积神经网络的全连接层中,以提高网络的泛化能力,抑制网络过拟合^[22]。

当机器人处于恶劣工况下时, RV 减速器中的振动信号往往掺杂着随机噪声,这种随机噪声可以看成是对纯净振动信号的一种随机干扰。与文献[8]和文献[21]中所使用的 Dropout 操作不同,本文提出的 Dropout 操作直接应用于输入信号层,而不是全连接层或者卷积层。其具体实现过程如下

$$\begin{aligned} X' &= X \cdot R \\ (r_{i,j} &\sim \text{Bernoulli}(p)) \\ p &\sim \text{Uniform}(l, 0.9) \\ l &= 0.1 + (0.9 - 0.1) * s/S \end{aligned} \quad (1)$$

式中 X ——原始输入振动信号;

X' ——Dropout 操作之后的输出振动信号;

R ——一个只含有元素 10 和 1 的矩阵,各个元素的取值服从概率为 p 的伯努利分布;

p ——服从均匀分布 $U(0.1 \sim 0.9)$ 的变量;

l ——均匀分布的下限值;

s ——当前迭代次数;

S ——模型总迭代次数,在本文中取迭代次数为 30 000 次。

1.3 模块结构

在卷积神经网络中,卷积核的作用是自动提取信号特征。但不同的卷积核对模型最终的输出结果有较大的影响,一般需要根据经验选择合适大小的卷积核。另一方面, RV 减速器中零件众多,产生的故障信号频率成分复杂。为了降低人为选取卷积核的经验要求,本文在同一网络层中设置了不同大小的卷积核以组成一个模块,并将这些卷积核卷积之后的结果进行堆叠以实现特征融合。其具体实现方式如图 2b 所示。从图 2b 中可知,本文在每一个模块中同时设置了大小为 15×15 、 7×7 和 3×3 的三种卷积核。每种卷积核的卷积结果经过批归一化(Batch normalization, BN)操作和非线性校正单元(Rectified linear unit, ReLU)激活后再进行堆叠得到模块的输出。其中涉及的卷积操作、BN 操作以及 ReLU 操作可分别通过文献[12]、[13]和[23]获取相关计算公式,本文不再赘述。

图 2 本文模型结构示意图

设输入信号经过模块结构中的卷积操作、BN操作和 ReLU 操作后得到的输出特征图分别为 Re_1 、 Re_2 和 Re_3 。则最终的 Block 输出为

$$Re = \text{concat}(Re_1, Re_2, Re_3) \quad (2)$$

其中,concat 为张量连接操作,即保持三维张量 Re_1 、 Re_2 和 Re_3 的长度和宽度不变,在深度方向上依次进行拼接; Re 表示最终的 Block 输出。

在本模型中一共设置了 5 个模块,并在最后一层模块的输出结果上采取平均池化操作。整个模型的结构图如图 2a 所示。表 1 列出了本模型的详细参

表 1 模型参数

网络层	输出张量
Input signal	32×32×1
Dropout1	32×32×1
模块 1	32×32×48 (16×3)
模块 2	32×32×96 (32×3)
模块 3	32×32×192 (64×3)
模块 4	32×32×384 (128×3)
模块 5	32×32×768 (256×3)
均值池化	1×1×768
Dropout2	1×1×768
全连接	5

数。其中模块 1 中参数 16×3 表示模块 1 中三种卷积核卷积后的输出特征图深度都为 16,后续模块结构中的参数以此类推。模块结构中所有的卷积核采取全零填充、步长为 1 的方式对输入特征图进行卷积操作。此外,在本模型中初始学习率设置为 0.001,并采取线性递减的方式降低;每一次训练的批次样本数为 16 个;均值池化层中的池化核选择为 32×32;Dropout2 中的丢弃率设置为 0.5;整个模型的权值不采取任何正则化措施。

2 试验与方法对比

2.1 试验台与故障模式

本文中涉及的 RV 减速器试验台如图 3 所示。在本试验中,电机转速设置为 400 r/min,磁粉制动器的负载设置为 40 N·m,振动传感器的采样频率设置为 2 kHz。本文选取轴向方向,即图 3 所示的 z 轴方向采集振动信号。

图 3 RV 减速器试验台

本试验中,一共设置 5 种模式,即 4 种故障模式与一种正常模式。4 种故障模式分别为:行星轮故障、摆线轮故障、行星轮与针销复合故障以及摆线轮与针销复合故障。相比于单一类型故障诊断,复合故障识别更具挑战性。各种故障模式如图 4 所示。

图 4 不同故障模式

对上述 5 种模式下的振动信号进行采集,并按照第 2 节中介绍的信号堆叠方法生成二维图像样本。表 2 列出了本试验中各种故障模式和噪声水平

下的样本数量。与文献[21]的处理方式相同, 本文涉及到的噪声测试数据集为在原始信号样本上添加不同分贝的高斯白噪声而构成的样本集。其中 None 表示原始振动信号, 不添加任何噪声。在表 2 中, 测试样本中噪声分贝值越大, 表示噪声能量相对于原始振动信号的能量越小, 此时噪声信号对振动信号干扰较弱。值得注意的是, 在模型训练阶段, 输入信号是通过 Dropout 操作被随机干扰的, 而不是通过加入白噪声干扰的。在模型测试阶段, 输入信号是通过加入白噪声的方式而被干扰的, 而 Dropout 操作不在测试阶段对输入信号进行干扰。

表 2 试验样本数量

训练 样本	测试 样本 1	测试 样本 2	测试 样本 3	测试 样本 4	测试 样本 5	测试 样本 6
None	None	15 dB	12 dB	9 dB	6 dB	3dB
4500×5	500×5	500×5	500×5	500×5	500×5	500×5

2.2 方法对比

为了对比分析本文提出模型的优势, 本文将与卷积神经网络算法^[17](Convolutional neural networks, CNN)、残差网络算法(Residual network, ResNet)^[18]、以及训练干扰卷积神经网络算法(TICNN)^[21]进行对比分析。为了算法对比的公平性, 所有参与对比的算法所利用的输入信号均为原始振动信号转换过的二维图像信号, 不经过其他变换, 且不同模型的层数都设置为相同大小。考虑到本文试验样本的尺寸大小, 将文献[21]提出 TICNN 模型的卷积核改为二维卷积核使其适用于本文的输入信号。多数研究已经表明, 在样本数目足够多的条件下, 深度卷积神经网络模型比传统的机器学习算法在故障分类中具有较大优势^[17], 因此本文不再与传统机器学习算法, 如支持向量机等, 进行对比。各种模型在不同噪声干扰下的测试准确率如图 5 所示。每一种噪声条件下的样本都进行了 20 次的试验, 最终取测试的平均值作为最终模型的测试准确率。

图 5 各种模型在不同噪声水平测试集上的准确率

从图 5 中可以看出, 随着噪声水平的提高, 各个模型在测试集上的准确率都存在不同程度的下降。文献[17]提出的 CNN 算法在弱噪声(>9 dB)干扰的测试样本中识别率最低, 但在强噪声(<6 dB)干扰的测试样本中识别率高于残差网络算法。一种可能的解释是, 文献[17]提出的卷积神经网络模型属于经典的卷积神经网络模型, 其特征学习能力比残差网络的特征学习能力较弱。因此当噪声较弱时, 原始振动信号的特征被噪声破坏的程度较低, 此时 ResNet^[18]强大的特征学习能力发挥出作用, 取得比 CNN 更高的准确率。而当噪声较强时, 原始的振动信号特征被噪声破坏的程度较高。因此, ResNet^[18]在原始振动信号中学习到的某些关键特征也有可能被噪声破坏掉, ResNet^[18]可能过度拟合了原始振动信号数据。因此, 此时的 ResNet^[18]相对于 CNN 算法不再具备优势。

相比于 ResNet 和 CNN, TICNN 在不同噪声水平下的测试准确率都较高。这是因为 TICNN 算法在第一层卷积核操作中加入了 Dropout 操作, 对模型学习到的第一层特征形成了一定的干扰, 使得模型能够具备一定的抗干扰能力。

相比于其他算法, 本文提出的 ANNet 在不同噪声水平的测试集上表现最佳。特别是在 3 dB 的强噪声干扰下, ANNet 相对于 ResNet 能够提高将近 20% 的准确率, 相比于 TICNN 也能提高 10% 左右的准确率。这是因为本文算法 ANNet 直接对原始输入信号进行了随机 Dropout。此外, ANNet 还采取了不同尺度的卷积核同时提取振动信号的多尺度特征。而 TICNN 算法是对第一层卷积核进行 Dropout, 而不是对输入信号进行 Dropout, 因此 TICNN 算法中利用的还是原始的振动信号。此外, TICNN 算法在同一层的网络中只采用了一种卷积核。因此, TICNN 对于振动信号的多种尺度的特征学习较难。

3 模型结构解释

从第 2 节不同模型对比的结果可知, 本文提出的 ANNet 具备更强的抗噪能力。本节将进一步尝试解释为何 ANNet 中的特殊设计能够使得 ANNet 具备较高的抗噪性。ANNet 中的特殊设计包括对输入信号进行 Dropout 操作以及同时采用多种卷积核提取和融合振动信号特征。

3.1 输入信号 Dropout

被噪声信号污染的 RV 减速器振动信号可以看成是噪声信号对原始振动信号的一种干扰, 而且这种干扰具有较强的随机性。在本文算法中, 输入信

号先经过了 Dropout 操作, 而 Dropout 操作最大的一个特点就是随机性。Dropout 随机将某些输入信号点进行置零可是看成是对原始信号进行了随机干扰, 其效果相当于对输入信号添加了椒盐噪声。当模型学习的样本是这种被随机干扰过后的样本后, 模型的抗干扰性也会有所提高。为了更为直观理解这一点, 图 6 对原始振动信号以及不同概率下进行 Dropout 操作输出的图像进行了可视化。为了获取更好的可视化效果, 将原始振动信号进行归一化操作。从图 6 中可以看出, Dropout 操作对输入信号进行了随机干扰, 而且当概率 p 越小时, 原始的振动信号被随机干扰的程度越大。

对输入信号进行 Dropout 操作的第二个作用就是大大丰富训练样本的数量, 因为即使是同一个样本, 再次被输入模型时, 由于 Dropout 随机将信号点置零的操作, 造成输出结果很难保持一致。因此, ANNet 学习的样本数量相比于其他模型是要多得多的, 在足够多的样本中, 学习到有用的信号特征的概率是较大的。这正体现了目前深度学习模型需要大数据进行驱动的特点。

ANNet 中 Dropout 操作的第三个作用是破坏了原始信号的局部结构特征, 强制模型学习其他更为有用的细节特征或者样本的整体特征。这从图 6 中被破坏掉的输入样本中可以得到体现。同时也需要注意的是, 对输入信号进行 dropout 操作会丢失大量的原始振动信号特征, 因此模型需要经过多次迭代才能收敛。

ANNet 中 Dropout 操作与无监督学习方法中的去噪编码器有类似之处。即, 都是对输入信号进行随机干扰。研究表明, 对输入信号进行干扰, 可以让去噪编码器学习到更为鲁棒的特征。与去噪编码器相同, 本文对输入信号进行 Dropout 操作也可以让模型学到更为鲁棒的特征。不同于去噪自编码器, ANNet 中没有对受损的输入信号进行重建, 而是直接对受损信号进行特征提取和分类。

图 6 原始振动信号以及不同概率下 Dropout 操作的输出信号图像

为了进一步验证 Dropout 操作在模型抗噪性能上的作用, 本文进行了对比试验, 即保持 ANNet 的其他部分不变, 不对输入信号进行 Dropout 操作与 ANNet 原有算法进行比较。对比结果如图 7 所示,

可见对输入信号进行 Dropout 操作可以在很大程度上提高模型的抗噪能力, 在 3 dB 的强噪干扰下可以提高 10% 左右。

图 7 对输入信号是否采取 Dropout 操作识别准确率对比

3.2 多尺度卷积核

研究表明, 卷积核的大小对故障的识别率是有影响的^[18]。因为不同大小的卷积核对输入信号的感受范围是不一样的, 因此不同的卷积核处理的振动信号特征也是不一样的。这一点在文献[21]中也得到了体现。但该文献[21]以及其他的故障诊断算法^[17-18]中还是在同一层网络结构中使用相同尺度的卷积核。而 ANNet 在同一层的网络中同时使用了三种不同大小的卷积核, 这样做的好处主要有两点。第一, 既然不同的卷积核对最终的识别结果有影响, 当采用单一的卷积核时, 势必要根据经验选取最合适的卷积核进行模型设计。而本文在同一层中同时使用多种卷积核, 降低了人为选择卷积核的经验要求。第二点, 正如文献[21]提到的一样, 不同的卷积核能够提取不同的信号特征。ANNet 在同一层网络中使用不同大小的卷积核就是为了从缺失部分信息的样本中提取多尺度的特征。同时 ANNet 对不同卷积核卷积的结果进行了堆叠相加, 这使得提取到的不同特征能够被很好的融合在一起。此外, RV 减速器中零件众多, 产生的振动信号频率成分也纷繁复杂, 采取多尺度卷积核的方式更有利于提取 RV 减速器产生的故障信号特征。

为了验证不同尺度的卷积核能提升模型的抗噪效果, 本文再一次进行对比试验。即保持 ANNet 其他部分不变, 将 Block 中所有的卷积核统一设计为 3×3 、 7×7 以及 15×15 大小。图 8 给出了对比分析结果。从图 8 中可知, 在 6 dB 以下强噪环境下, 7×7 的卷积核抗噪性最差。而 3×3 与 15×15 的卷积核则相对较好。这是因为在强噪环境下, 原始信号被干扰的程度增加, 此时的输入信号的某些特征在一些较小局部范围内被干扰的概率较小, 因此 3×3

的卷积核在强噪环境下表现比 7×7 的卷积核要好。另一方面, 虽然信号某些局部特征被破坏掉, 但样本还保留着部分整体特征, 因此此时 15×15 的卷积核也比 7×7 的卷积核效果要好。从一定程度上, 这又刚好体现了第 3.1 节中提到的对输入信号进行 Dropout 操作的第三个作用, 即, 对输入进行 Dropout 操作, 强制模型学习样本其他更为有用的细节特征以及样本整体特征。而 ANNet 使用多尺度的卷积核, 最终识别的效果都优于上述每种单一尺度卷积核取得的效果。一个可能的原因是, 由于噪声的随机性, 噪声对原始信号不同尺度范围都是具有破坏能力的, 采用单一尺度的卷积核会丢失某些其他样本特征, 因此使用多尺度的卷积核相比于单尺度的卷积核具有更好的抗噪性。

图 8 多尺度卷积核与单尺度卷积核对比

结合图 7 和图 8 以及上述的对比分析可知, ANNet 具有抗噪能力的原因是结合了 Dropout 操作以及多尺度卷积核模块的共同结果。Dropout 操作对输入信号进行随机干扰, 这种随机性与噪声相似, 因为实际工况中的噪声也是随机对真实的信号干扰的。同时, 多尺度卷积核能够借助于多尺度特征提取和特征融合能力从被干扰的不完整信号中学习更为有用的样本特征。

不同的机械设备产生的振动信号在很大程度上是不一样的, 因此后续的工作可以通过实验获取更多设备的故障信号, 从而对模型的泛用性进行测试。同时, 不同工况, 例如转速和载荷对 RV 减速器振动信号的识别也存在很大影响, 因此如何在变工况下实现对 RV 减速器的故障识别也是后续工作的一个重点。

4 结论

提出了一种抗噪干扰的 RV 减速器故障识别算法(ANNet)。ANNet 利用原始的振动信号同时实现

了随机干扰样本、特征学习以及故障诊断三大功能。与当前盛行的其他深度学习算法对比发现, ANNet 具备更强的抗噪能力。

ANNet 具备较高的抗噪性是 Dropout 操作和多尺度卷积核模块共同作用的结果。Dropout 操作实现对输入信号的随机干扰, 而多尺度卷积核模块则利用其多尺度特征学习能力从被干扰的样本中学习对故障诊断有用的特征。

对输入振动信号进行 Dropout 操作有三个作用: 第一, 可以对输入样本随机干扰, 提高模型的抗干扰能力; 第二, 可以大大丰富样本数量, 增大 ANNet 学习有用特征的概率; 第三, 破坏样本的局部结构特征, 强迫模型学习其他更为有用的细节特征或者样本的整体特征。

采取多尺度卷积核具有两大优势。其一, 降低人为选择合适的卷积核的经验要求; 其二, 充分利用不同卷积核不同尺度特征的提取能力, 同时融合这些提取的特征, 使得模型既能利用样本全局特征又不丢失其他有用的细节特征。

参 考 文 献

- [1] 何卫东, 李力行, 李欣. 机器人用高精度 RV 减速器摆线轮的优化新齿形[J]. 机械工程学报, 2000, 36(3): 51-55.
HE Weidong, LI Lixing, LI Xin. New optimized tooth-profile of cycloidal gear of high precision RV reducer used in robot[J]. Chinese Journal of Mechanical Engineering, 2000, 36(3): 51-55.
- [2] ZHANG Zhenhua, WANG Jiaxu, ZHOU Guangwu, et al. Analysis of mixed lubrication of RV reducer turning arm roller bearing[J]. Industrial Lubrication & Tribology, 2017(3): 161-171.
- [3] 彭鹏, 陈李果, 汪久根, 等. 机械磨损的检测技术综述[J]. 润滑与密封, 2018(1): 115-124.
PENG Peng, CHEN Liguang, WANG Jiugen, et al. A review on detection technology of mechanical wear[J]. Lubrication Engineering, 2018(1): 115-124.
- [4] WIDODO A, YANG B. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.
- [5] BAGHERI B, AHMADI H, LABBAFI R. Application of data mining and feature extraction on intelligent fault diagnosis by artificial neural network and k-nearest neighbor[C]//International Conference on Electrical Machines, 2010: 1-7.
- [6] 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.
- [7] JIA Feng, LEI Yaguo, LIN Jing, 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.
- [8] 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 Wenjun, SHAO Siyu, YAN Ruqiang. Induction motor fault diagnosis based on deep neural network of sparse auto-encoder[J]. Journal of Mechanical Engineering, 2016, 52(9): 65-71.
- [9] GAN Meng, WANG Cong, ZHU Chang'an. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings[J]. Mechanical Systems and Signal Processing, 2016, 72: 92-104.
- [10] LU Chen, WANG Zhenya, QIN Weili, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130: 377-388.
- [11] MA Meng, SUN Chuang, CHEN Xuefeng. Deep coupling autoencoder for fault diagnosis with multimodal sensory data[J]. IEEE Transactions on Industrial Informatics, 2018: 1137-1145.
- [12] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in neural information processing systems, 2012: 1097-1105.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [R]. arXiv preprint arXiv: 1409.1556, 2014.
- [15] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//Proceedings of the IEEE conference on computer vision and pattern recognition, 2015: 1-9.
- [16] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition, 2016: 770-778.
- [17] WEN Long, LI Xinyu, GAO Liang, et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5990-5998.
- [18] ZHAO Minghang, KANG M, TANG Baoping, 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.
- [19] LI Weihua, ZHANG Shaohui, RAKHEJA S. Feature denoising and nearest-farthest distance preserving projection for machine fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2016, 12(1): 393-404.
- [20] PAN Jun, ZI Yanyang, CHEN Jinglong, et al. LiftingNet: A novel deep learning network with layerwise feature learning from noisy mechanical data for fault classification[J]. IEEE Transactions on Industrial Electronics, 2018, 65(6): 4973-4982.
- [21] ZHANG Wei, LI Chuanhao, PENG Gaoliang, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. Mechanical Systems and Signal Processing, 2018, 100: 439-453.
- [22] SRIVASTAVA N, HINTON G, 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.
- [23] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[R]. arXiv preprint arXiv: 1502.03167, 2015.

作者简介: 彭鹏, 男, 1994 年出生, 博士研究生。主要研究方向为磨损检测技术和故障诊断算法。

E-mail: 1498714385@qq.com

柯梁亮, 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

汪久根(通信作者), 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