DOI: 10.3901/JME.2019.07.065

利用 FCKT 以及深度自编码神经网络的 滚动轴承故障智能诊断*

杨 蕊 李宏坤 王朝阁 郝佰田
(大连理工大学机械工程学院 大连 116024)

摘要: 实时、快速、批量地对振动信号进行处理成为故障诊断领域的未来发展趋势,但是可能会带来数据维数灾难问题。针对在样本较大情况下深度学习运行时间较长,以及层与层之间节点数的减少使得故障识别准确率降低问题,提出首先计算原始时域信号的频谱在不同偏移点数下的相关峭度值(FCKT)作为新的样本数据,并结合深度自编码神经网络实现轴承的智能故障分类。新样本相对于原始样本,实现了数据的维数约减,缩短了样本集的分析时间。同时,在保持各样本数据原有信息的基础上,使得样本之间差异性更突出。另外,该方法在避免深度学习算法层与层之间的权值根据经验设定的同时,解决了通过逐层减少隐含层节点数来提高计算效率时带来的分类识别准确率降低的问题。最后,通过试验数据对比分析验证了算法的有效性。

关键词: 不同偏移点数相关峭度值(FCKT); 深度自编码器; 智能故障分类

中图分类号: TH113

Intelligent Fault Detection for Rolling Element Bearing Based on FCKT and Deep Auto-coding Neural Network

YANG Rui LI Hongkun WANG Chaohe HAO Baitian
(School of Mechanical Engineering, Dalian University of Technology, Dalian 116024)

Abstract: Real-time, fast, and batch processing of vibration signals have become a future development trend in the field of fault diagnosis. However, it may lead to data dimensional disasters. In view of the fact that the long running time and the low fault identification accuracy of deep learning algorithm under the condition of large sample. The frequency spectrum correlation Kurtosis of original time domain signal is calculated under different iteration periods (FCKT) as new samples data and use the deep auto-coding neural network is used to realize the intelligent fault classification of planetary gearbox. Compared with the original samples, the new samples reduce the data dimension and shorten the analysis time. At the same time, the differences between the samples are more prominent based on the original information of each sample data. In addition, the method solves the problems that the weight parameters between layers of deep learning algorithm are set according to experience and the classification accuracy is reduced by reducing the number of hidden nodes layer by layer to improve the calculation efficiency. Finally, the validity of the algorithm is verified by comparison of experimental data.

Key words: correlation Kurtosis for different iteration periods (FCKT); deep auto-coding; intelligent fault classification

0 前言

当前,随着工业的发展和社会需求量的增大,加工过程中的机械设备朝着高速、高效、高精方向发展^[1]。实时的状态监测已经取代定期维修方式成为保障设备健康运行的关键环节。设备的实时监测

与诊断采用规模较大的设备群,每个设备需要在多个测点位置进行数据采集,每个测点采集到的数据长度由于采样率的提高而增大,从设备起始到寿命终止的过程中数据采集时间长,产生的数据量较大。这时,对单个数据进行单独分析将消耗大量的人力物力。在当前情况下,难以对其进行逐条分析。因此,当前设备监测周期的缩短以及海量数据的产生使得传统的基于信号处理的故障诊断方法不再实用。故障诊断领域迫切需要一种能实时地、快速地、

* 国家自然科学基金资助项目(51175057)。20180528 收到初稿,20181108 收到修改稿

批量地对采集数据进行高效处理的智能分类和状态监测系统,并吸引了研究者广泛的关注。

HINTON 等^[2]在 2006 年首次提出了深度学习概念,开启了人工神经网络在语音识别、图像处理等过程中的应用,其在机器学习领域也受到了越来越广泛的关注。这一概念的提出受到大脑神经网络的启发,类似于大脑处理视觉听觉系统输入输出的信息的过程。深度学习过程可以实现高维数据降维以及数据重构。高维数据经过自编码中间层神经网络,可以挖掘原始输入数据中的有用信息。为了提高网络分解结果精度,每个中间层自编码器的权值通过梯度下降进行微调。

在机械故障诊断领域,已经有很多研究者致力于自编码深层神经网络的研究。例如,TAO 等^[3]采用一个基于堆栈的自编码器和 Softmax 回归的深度神经网络算法来对轴承故障进行诊断。FENG 等^[4]提出采用深层的 ANNs 来对多种状态下的轴承和行星齿轮箱数据进行识别。该方法克服了传统浅层 ANNs 结构的不足并提高了识别准确率。2015 年,雷亚国等采用振动信号频域特征作为深度学习方法的训练样本集,完成大数据的信息挖掘,高效、准确地识别出机械的运行状态^[1],随后,受无监督特征学习的启发,提出对数据进行两阶段学习来实现数据的智能诊断^[5]。第一阶段采用系数滤波方法对振动数据直接进行特征学习。然后,将学习到的特征输入到 softmax 回归模型中进行运行状态分类识别。2017 年,SHAO 等^[6]提出了一种名为集成深度自动编码器的智能故障诊断方法。根据不同的特征采用不同的激活函数作为隐藏函数来设计一系列的自动编码器,实现无监督自动编码。选取识别准确性大于设定阈值的深度自动编码器并计算满足要求的自动编码器在每次试验中的权值,从而计算样本所属类别的占比程度,经过多次试验验证了改进模型相比于传统分类方法的优越性。

当前,在降噪编码以及 Dropout 正则化方法的帮助下,SUN 等^[7]将局部干扰加到稀疏自编码的输入数据中来增强特征表示的鲁棒性。然后将自编码学习到的特征输入到分类器来识别感应电动机的故障。同时,采用 Dropout 正则化方法来消除训练过程中的过匹配。从其结果可以看出基于自编码的 DNN 算法在机械故障识别领域的有效性。然而,他们主要是通过自编码来作为降维技术,也就是每一个隐含层节点数都少于输入样本数,以便在输入数据量大的情况下进行故障诊断。2017 年,陈仁祥等^[8-9]将稀疏项限制和加噪编码融入到自编码网络中,提高自编码网络的非监督自动提取损伤特征的学习能

力以及鲁棒性。随后,将自编码网络堆栈并添加有监督微调操作,实现损伤程度的智能分类与诊断。

AHMED 等^[10]首先采用压缩感知将原始数据压缩,然后将压缩后的数据输入基于稀疏自编码的无监督深层神经网络进行特征学习。最后,故障分类分为两个阶段。第一阶段是基于堆栈自编码器的预训练分类和 Softmax 回归层。第二阶段是基于反向传播算法的重训练分类形成的微调阶段。该种算法虽然能实现数据维数的约减,但是在压缩感知过程中,其所得的稀疏表示系数受到字典的影响。字典越完备,其稀疏系数越能准确重构原信号。但是,其字典维数越大可能导致在数据压缩过程中计算效率很低。甚至数据压缩后整体的数据分类过程的计算量要大于直接对原始数据进行分类的计算量。

尽管深度学习算法可以避免传统的信号处理方法需要先验知识等问题。但是为了提高识别率,需要大量的具有代表性地标数据作为训练样本。不同型号、不用严重程度以及不同故障状态下的轴承数据都必须存在,这会使得训练数据量巨大,从而导致算法效率降低。文献[11]提出通过隐含层节点逐层递减的方法来实现数据维数约减,但是,这可能使得分类准确度降低。也许可以通过提取原始信号中的敏感特征,然后采用自编码算法来达到数据维数约减以及分类准确度的提高。传统的维数约减技术有核主成分分析^[12]。主要是通过提取多个时域、频域或时频域中占主导地位的少数特征量。

通过对比分析,发现相关峭度在表征冲击特征的同时可以提取信号周期变化特性,对于区分不同状态下的信号特征非常有效。MCDONALD 等^[13]采用最大相关峭度解卷积进行齿轮箱故障探测,该方法能提取连续冲击信号,避免单个冲击信号的影响。之后,CHEN 等^[14]提出了一种改进的相关峭度方法来对共振频带进行解调,将新的参数和小波滤波以及粒子群算法相结合可以准确提取轴承故障特征频率。另外,FENG 等^[15]采用最大相关峭度解卷积和谱峭度来寻找故障频带并对微弱故障进行诊断。但是最大相关峭度解卷积算法的结果受到迭代周期和滤波器长度选择的影响。然而,并没有太多文献涉及相关参数的选择。CHEN 等^[16]给出了一种滤波器长度和偏移阶次的选择标准。然后,TANG 等^[17]提出采用粒子群优化算法选择滤波器迭代周期和长度。但是对于离散数据分析,该算法容易陷入局部最优。到目前为止,仍然没有一个固定的标准来对滤波器参数进行选择。相对于时域周期特性,频域中边频带的等间隔特性更有利于采用相关峭度值来选择最优解调频带^[14]。

针对当前存在的数据维数灾难以及在样本较大情况下深度学习算法运行时间较长, 以及在同一状态下不同故障发生早期以及外界噪声较大情况下采集到的振动信号特征较为接近使得故障诊断准确率降低的问题。本文提出采用基于不同偏移点数下的频域相关峭度(FCKT)以及深度自编码方法来对轴承运行状态进行智能分类。不同偏移点数下的频域相关峭度可以表征信号中不同点之间的特征关系, 抑制噪声干扰以及避免单个幅值较大点的影响。将原始信号的 FCKT 作为新的样本数据, 可以消除振动信号中随机成分的干扰, 提高系统的鲁棒性。在增强样本自身特征的基础上缩短了各样本的数据长度, 同时提高了算法的识别准确度和运行效率。

1 基本理论

1.1 FCKT

相关峭度是在峭度的基础上提出的, 其表征的是相关系数的峭度值。相关峭度值的大小反映了周期冲击特征的强弱。它计算的是相关系数偏移 m 个周期后的峭度值。该指标对于存在多周期冲击特征的信号更加的敏感。其表达式见式(1)

$$CK_M(T) = \frac{\sum_{n=1}^N \left(\prod_{m=0}^M x_{n-mT} \right)^2}{\left(\sum_{n=1}^N x_n^2 \right)^{M+1}} \quad (1)$$

式中, CK 是相关峭度值, T 是偏移点数, M 是偏移次数, x 是被分析的信号, N 是信号长度且 $n=1, 2, \dots, N$ 。FCKT 是计算在不同偏移点数下的频域相关峭度值。其表达式如下式所示

$$y = \int_{-\infty}^{+\infty} x(t) \exp(-i\omega t) dt \quad (2)$$

$$FCKT_M(T) = \frac{\sum_{n=1}^N \left(\prod_{m=0}^M y_{n-mT} \right)^2}{\left(\sum_{n=1}^N y_n^2 \right)^{M+1}} \quad (3)$$

式中, y 是傅里叶变换系数。FCKT_M 是频域信号偏移 M 个周期的相关峭度值。首先, 对原始信号进行傅里叶变换, 得到一系列的傅里叶变换系数作为原始信号的频域信号, 如式(2)所示。在计算 FCKT 的过程中, T 和 M 是未知的, 将偏移点数 T 看成变量, M 定义为某个确定的量。计算一系列 T 对应的相关峭度值作为新的样本来训练深度自编码神经网络, 如式(3)所示。原始信号长度为 N , 而计算所得的 FCKT 的长度为 T 定义域内的长度。 T 的取值范围

是小于 N 的正整数值。很明显地, 所得的新的样本维数一定小于原始信号的维数。

1.2 深度神经网络

作为机器学习中一个重要的分支, 神经网络经历了从单层到多层的过程, 也就是其发展历程从感知器逐渐过渡到深度学习。经典的神经网络包括有三个层次, 输入层、隐含层以及输出层。其结构示意图见图 1。

图 1 神经网络结构示意图

在神经网络构建过程中, 输入层和输出层单元个数是固定的, 隐含层单元个数是需要自己定义的。整个神经网络的输出结果主要与输入层和隐含层以及隐含层和输出层之间的权值有关。而权值在网络中也非确定性的, 需要在运行过程中对其进行训练。将上述模型简化为一般的计算模型(图 2)。

图 2 神经网络结构简图及其参数化模型

假定输入层各节点为 x_1, x_2, x_3 , 中间层各节点为 $a_i^{(l)}$, 表示的是第 l 层的第 i 个节点的激活值, 也即输出值。 $w_{ij}^{(l)}$ 表示的是第 l 层第 j 个节点与第 $l+1$ 层第 i 个节点之间的连接参数权值大小。 $b_i^{(l)}$ 表示第 l 层第 i 个节点的偏置项。在神经网络传递信息的过程中, 通过相邻层之间的权值将许多个单一神经元联结在一起, 第 l 层神经元的输出是 $l+1$ 层神经元的输入。依据上图可以得出以下关系式

$$\begin{cases} a_1^{(2)} = f_1(w_{11}^{(1)}x_1 + w_{12}^{(1)}x_2 + w_{13}^{(1)}x_3 + b_1^{(1)}) \\ a_2^{(2)} = f_1(w_{21}^{(1)}x_1 + w_{22}^{(1)}x_2 + w_{23}^{(1)}x_3 + b_2^{(1)}) \\ a_3^{(2)} = f_1(w_{31}^{(1)}x_1 + w_{32}^{(1)}x_2 + w_{33}^{(1)}x_3 + b_3^{(1)}) \end{cases} \quad (4)$$

$$\begin{cases} a_1^{(3)} = f_2(w_{11}^{(2)}a_1^{(2)} + w_{12}^{(2)}a_2^{(2)} + b_1^{(2)}) \\ a_2^{(3)} = f_2(w_{21}^{(1)}a_1^{(2)} + w_{22}^{(1)}a_2^{(2)} + b_2^{(2)}) \end{cases} \quad (5)$$

当输入层节点个数为 n 时, 将上述函数写成一般表达式

$$a_i^l = f\left(\sum_{j=1}^n w_{i,j}^{(l-1)} a_j^{l-1} + b_i^{(l-1)}\right) \quad (6)$$

式中, f 是激活函数。上述过程也称为编码过程, 反映的是原始信号内部的特征信息。最后一层隐含层输出的是原始信号最高级的特征。整个网络的分类结果和模型中参数的选择有关, 本文将采用堆栈自编码器对权值矩阵进行无监督学习。堆栈自编码器由一个输入层和多个隐含层组成。其结构图如图 3 所示。

图 3 深度自编码框架图

单层神经网络只适用于线性数据分类, 而轴承故障数据是非线性数据, 多层神经网络也即深度学习方法是较好的选择。以两层自编码器为例进行说明。堆栈自编码器是由多层稀疏自映射神经网络组成。自编码器的输入层和自映射神经网络的第一层隐含层组成第一个自编码器, 自编码器第一层的输入层和自神经网络的第二个隐含层组成第二个自编码器, 以此类推, 直到将最高层自编码器的输入层输入到分类器完成网络测试。隐含层向量也就是图 3 所示的编码过程中的输出矩阵。自编码器在组合的过程中没有自映射神经网络各层的重构输出层。

1.3 无监督自编码器

自编码器是为了无监督地训练特征参数, 使得输入值在压缩过程中尽量做到损失最小。它包括编码和解码两部分, 其编码过程如式(6)所示。解码过

程可以根据下式

$$z = g_{\theta'}(a) = s(W^T a + B^T) \quad \theta' = \{W^T, B^T\} \quad (7)$$

式中, z , a , θ 表示输出层输出, 隐含层输出以及自映射神经网络的连接参数。 $s(\cdot)$ 表示重构函数, 其目的是为了使输出层输出尽可能等于输入数据。在自编码器构建的过程中使得每层输出值代表输入数据中最重要的信息。也即重构的数据特征都和去除的信息无关。如人类大脑一样, 获得的外界信息只能刺激特定的某部分神经元活动, 而其他神经元受到抑制。在神经网络中, 对自编码输出值加上 L_1 规则约束将使得每次输入尽量稀疏。在前向传播过程中的激活函数为 sigmoid 函数, 其输出结果为 0 或 1。稀疏约束表示式可以表示为

$$\rho_l = \frac{1}{m} \sum_{i=1}^m [a_i^l] \quad (8)$$

式中, a_i^l 和 m 分别表示第 l 个隐含层的激励以及输入节点的个数, ρ_l 是第 l 个隐含层的平均激励。假定 ρ 表示稀释系数并将其定义为接近于 0 的常数, 采用 KL 散度来测量 ρ 和 ρ_l 之间的不同, KL 散度随着两者之间不同程度的增大而单调递增。在无监督学习过程中, ρ_l 明显偏离 ρ , 因此增加了一个额外的惩罚项来优化目标函数。

$$KL(\rho // \rho_l) = \rho \lg \frac{\rho}{\rho_l} + (1 - \rho) \lg \frac{1 - \rho}{1 - \rho_l} \quad (9)$$

为了使得重构误差达到最小化, 对于单个的自编码器, 其误差损失函数可以如下式所示

$$C(\omega, b; x, a) = \frac{1}{2} \|z - x\|^2 = \frac{1}{2} \|g_{\theta'}(a) - x\|^2 \quad (10)$$

式中, $C(\omega, b; x, a)$ 是平方误差损失函数的一半。在该基础上, 假定神经网络的输入层有 m 个样本, L 层神经网络结构的所有损耗函数如下式所示

$$\begin{aligned} C(\omega, b) = & \left[\frac{1}{m} \sum_{i=1}^m C(\omega, b; x^{(i)}, a^{(i)}) \right] + \\ & \beta \sum_{j=1}^s KL(\rho // \rho_l) + \frac{\lambda}{2} \sum_{l=1}^{L-1} \sum_{i=1}^{n+1} \sum_{j=1}^n (w_{i,j}^{(l)})^2 = \\ & \left[\frac{1}{m} \left(\frac{1}{2} \|g_{\theta'}(a^{(j)}) - x^{(j)}\|^2 \right) \right] + \\ & \beta \left(\rho \lg \frac{\rho}{\rho_l} + (1 - \rho) \lg \frac{1 - \rho}{1 - \rho_l} \right) + \\ & \frac{\lambda}{2} \sum_{l=1}^{L-1} \sum_{i=1}^{n+1} \sum_{j=1}^n (w_{i,j}^{(l)})^2 \end{aligned} \quad (11)$$

$C(\omega, b)$ 是平方和误差的平均值, λ 是正则化项, 通过减小权值的大小来防止过拟合的出现。 β

决定着稀疏表示过程所占的稀疏比重。 $w_{i,j}^{(l)}$ 表示的是第 l 层第 j 个节点与第 $l+1$ 层第 i 个节点之间的连接参数权值大小的综合表达式。 n 表示第 l 层神经网络的神经元个数。依次训练每个自编码器并使用平均和误差作为评估指标来搜索最优参数值，相比随机初始化具有更好的局部最小值，该种网络自寻优功能适用于不同网络，适用性较强。

图 4 算法框架图

2 试验验证

采用内蒙古科技大学的试验台采集振动数据并对本文所提算法进行验证，如图 5 所示。试验台是由一个 2 级行星齿轮箱，一个由滚动轴承或套筒轴承支撑的 2 级平行轴齿轮箱，1 个轴承负载和 1 个可编程的磁力制动器组成。其中，电动机转速变化范围为 0~5 000 r/min。变速驱动电动机直接和扭矩传感器与编码器相连，紧接着连接第 1 级行星齿轮箱的太阳轮，第 1 级行星齿轮箱的行星架作为输出轴连接第 2 级行星齿轮箱的输入轴太阳轮，随后第 2 级行星齿轮箱的行星架连接平行轴齿轮箱，从而带动整个系统进行工作。分别采集健康状态、第一级行星轮外圈故障、第一级行星轮内圈故障以及第一级行星轮滚针故障四种状态下的振动信号进行分析，采样频率设为 15 360 Hz，电动机转速为 2 100 r/min(表 1)。

图 5 试验台实物图

表 1 试验工况描述

类别	故障位置	训练样本/测试样本大小
1	无	270/50
2	内圈	270/50
3	滚针	270/50
4	外圈	270/50

首先，计算不同运行状态下振动信号的原时域波形、频域波形、时域信号在不同偏移点数下的相关峭度值(TCKT)以及频域信号在不同偏移点数下的相关峭度值(FCKT)，如图 6 所示，图 6a~6d 中各子图自上而下依次为正常状态、行星轮轴承内圈故障、行星轮轴承外圈故障、行星轮轴承滚动体故障。从图中可以看出，内圈故障以及外圈故障在不同状态下的时域波形、频域波形以及 TCKT 波形非常接近，而两者的 FCKT 波形差异性最大。故本文提出将采集到的数据的频域信号在不同周期下的相关峭度值(FCKT)作为样本进行分析。

(a) 不同状态下原时域信号波形图

(b) 不同状态下原频域信号波形图

图6 各不同状态下的波形图

依据相关峭度计算公式可得, 计算结果受到偏移点数 T 以及偏移次数 M 的影响。在本文中, 将 T 作为一个自变量, 而偏移次数定义为固定值时计算所得的 FCKT 作为样本数值。为了更进一步得到最优的 M 值以使得样本分类精确度达到最大, 设定偏移点数的变化范围为 1~784, 偏移次数为 1~10 时原振动信号的 TCKT 值以及 FCKT 值, 并将其输入到自编码神经网络进行分析, 得出各偏移次数对应的识别准确率, 如图 7 所示。从图中可以看出, 当偏移次数为 1 时, 两种指标样本对应的识别准确率最高。随着偏移次数的增大, 识别准确率呈现相对下降趋势。且 TCKT 值作为新样本时的识别准确率相对于 FCKT 值较低。因此, 在后续分析中, 将原

始信号的 FCKT 作为新的样本, 并将偏移次数设为 1。为了进一步研究偏移点数的取值范围对识别率的影响, 将最大偏移点数为研究目标, 分别从 10 开始每隔 10 个偏移点进行一次识别率计算, 直到最大偏移点数达到 700 为止, 如图 8 所示。可以看出, 随着最大偏移点数取值范围的增大, 识别准确率呈增长趋势, 且当最大偏移点数取为 140 时, 识别准确率达到 100%, 但是稳定性较差。当最大偏移点数达到 340 时, 识别准确率达到 100% 且呈现相对稳定趋势。

图7 同一样本在不同偏移次数下的 FCKT 与 TCKT 指标的识别精确率

图8 偏移点数取值范围对准确率的影响

依据上文所述, 计算原始信号在偏移次数为 1, 偏移点数为 1~340 时的 FCKT 值, 并将其输入到自编码深度神经网络中进行分析。采用两层自编码器, 经过多次尝试, 得出在第一层自编码器节点数为 200, 第二层自编码器为 100, 且每层自编码器参数偏移更新次数为 100 时, 识别率就可以达到 100%。同样采用上述各参数设置, 并计算分别以原始时域信号、原始频域信号、原始时域信号的 TCKT 值作为样本输入到自编码深度神经网络计算其识别准确率。通过对比分析图 9 各曲线, 可以看出频域指标的识别准确率要高于时域指标。为了进一步说明本文所提方法的有效性, 以原始振动信号的均值、均

方根值、方差、峭度值、最小值、最大值、峰峰值作为样本集进行分析。其故障诊断率如图 10 所示。从图中可以看出, 计算准确率约为 86.875%, 标准差为 4.204 9, 算法稳定性较差。可以看出, FCKT 指标作为样本时的识别准确率最高且最为稳定。

图 9 各数据指标作为样本的识别准确率对比图

图 10 多指标作为样本的识别准确率图

表 2 各方法的平均识别准确率

方法	平均诊断准确率(%)	准确率的标准差
时域+ DAE	83.541 7	3.254 3
多指标+DAE	88.291 7	3.770 4
TCKT+DAE	74.416 7	1.871 2
频域+ DAE	98.500 0	1.471 0
FCKT+DAE	100.000 0	0

在堆栈自编码过程中, 为了实现数据维数降维, 有研究者提出采用隐含层节点数逐层减少的方法。为了说明其逐层节点递减过程对识别准确率带来的影响。以原始振动信号为分析样本, 本文设定第一层隐含层节点数为 200, 并计算了第二隐含层节点数从 200 开始, 每减少 10 个节点数对应的精确度, 直到第二层节点数减少为 40 为止。从图 11 可以看出, 准确度随第二隐含层节点数的减少而降低。

上文已经验证了本文所提参数指标在识别准确率方面的提升。为了更进一步说明所提方法对于提高算法效率方面的贡献。直接采用深度自编码算法对采集到的振动信号进行分析, 分析过程中的训练样本数为 270, 测试样本数为 50, 每个样本的数据

图 11 第二隐含层节点数和精确度的关系

长度是 1 572, 运行次数为 20, 计算运行时间的平均数得到每次运行时间约为 355.188 s。然后采用本文所提的算法对同一组样本进行分析, 首先计算每个样本数据偏移点数为 1~400 范围内的相关峭度值, 其运行 20 次后得到的平均运行时间为 190.66 s, 运行时间减少了 46.32%, 如图 12 所示。可以看出, 对数据计算 FCKT 后再进行深度自编码智能分类可以大大缩减运行时间。

图 12 算法运行时间对比

3 结论

采用 FCKT 以及深度自编码神经网络可以实现行星齿轮箱运行状态的自动快速智能分类。解决了深度自编码器通过逐层减少隐含层节点数来提高运行速度而导致的识别准确率降低问题。通过计算原始振动信号频域在不同偏移点数下的相关峭度值作为新的数据样本进行分类识别, 能挖掘原始样本在不同周期点之间的关系, 增强样本之间的差异性。在提高分类准确率的同时减少了分析数据维数, 提高了分类速率。

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 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.
- [2] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [3] TAO S, ZHANG T, YANG J, et al. Bearing fault diagnosis method based on stacked autoencoder and softmax regression[C]// Proceedings of the Control Conference, 2015: 6331-6335.
- [4] JIA F, LEI Y, 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 & Signal Processing, 2016, 72: 303-315.
- [5] 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.
- [6] SHAO H D, JIANG H K, LIN Y, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders[J]. Mechanical Systems and Signal Processing, 2018, 102: 278-297.
- [7] SUN W, SHAO S, ZHAO R, et al. A sparse auto-encoder-based deep neural network approach for induction motor faults classification[J]. Measurement, 2016, 89: 171-188.
- [8] 陈仁祥, 杨星, 杨黎霞, 等. 栈式稀疏加噪自编码深度神经网络的滚动轴承损伤程度诊断[J]. 振动与冲击, 2017, 36(21): 125-131.
- CHEN Renxiang, YANG Xing, YANG Lixia, et al. Fault severity diagnosis method for rolling bearings based on a stacked sparse denoising auto-encoder[J]. Shock and Vibration, 2017, 36(21): 125-131.
- [9] CHEN R, CHEN S, HE M, et al. Rolling bearing fault severity identification using deep sparse auto-encoder network with noise added sample expansion[J]. Journal of Risk & Reliability, 2017, 231(6): 666-679.
- [10] AHMED H O A, WONG M L D, NANDI A K. Intelligent condition monitoring method for bearing faults from highly compressed measurements using sparse over-complete features[J]. Mechanical Systems & Signal Processing, 2018, 99: 459-477.
- [11] CHEN L, WANG Z Y, QIN W L, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. Signal Processing, 2017, 130: 377-388.
- [12] SCHOLKOPF B, SMOLAA, MULLER K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299-1319.
- [13] MCDONALD G L, ZHAO Q, ZUO M J. Maximum correlated Kurtosis deconvolution and application on gear tooth chip fault detection[J]. Mechanical Systems & Signal Processing, 2012, 33(1): 237-255.
- [14] CHEN X, ZHANG B, FENG F, et al. Optimal resonant band demodulation based on an improved correlated Kurtosis and its application in bearing fault diagnosis[J]. Sensors, 2017, 17(2): 360-379.
- [15] FENG J, LEI Y, SHAN H, et al. Early fault diagnosis of bearings using an improved spectral Kurtosis by maximum correlated Kurtosis deconvolution[J]. Sensors, 2015, 15(11): 29363-29377.
- [16] ZHOU H, CHEN J, DONG G. Application of maximum correlated Kurtosis deconvolution on rolling element bearing fault diagnosis[M]. London: Springer International Publishing, 2015.
- [17] TANG G, WANG X, HE Y. Diagnosis of compound faults of rolling bearings through adaptive maximum correlated kurtosis deconvolution[J]. Journal of Mechanical Science and Technology, 2016, 30(1): 43-54.

作者简介: 杨蕊, 女, 1990 年出生, 博士研究生。主要研究方向为机械设备微弱故障特征提取、智能故障诊断。

E-mail: yr90223@mail.dlut.edu.cn

李宏坤(通信作者), 男, 1974 年出生, 教授, 博士研究生导师。主要研究方向为机械设备动态分析与故障诊断, 信号处理。

E-mail: lihk@dlut.edu.cn