DOI: 10.3901/JME.2021.15.105

基于 FNER 性能退化指标及 IDRSN 的滚动轴承寿命状态识别方法*

董绍江^{1,2} 裴雪武¹ 汤宝平³ 田科位¹ 朱朋¹ 李洋¹ 赵兴新⁴

- (1. 重庆交通大学机电与车辆工程学院 重庆 400074;
2. 磁悬技术与磁浮列车教育部重点实验室 成都 610031;
3. 重庆大学机械传动国家重点实验室 重庆 400044;
4. 重庆长江轴承股份有限公司 重庆 401336)

摘要: 针对滚动轴承退化性能难以评估、寿命状态难以识别的问题, 提出一种基于特征噪声能量比(Feature-to-noise energy ratio, FNER)指标及改进深度残差收缩网络(Improved deep residual shrinkage network, IDRSN)的滚动轴承寿命状态识别新方法。首先, 将全寿命轴承信号进行希尔伯特(Hilbert)变换和快速傅里叶变换(Fast fourier transform, FFT)得到包络谱, 根据故障特征频率及其倍频计算包络谱幅值的特征能量比(Feature energy ratio, FER); 然后, 根据自相关函数(Autocorrelation function, AF)得到包络信号的总能量, 将故障特征能量和噪声能量的比值作为轴承性能退化指标, 之后按照 FNER 指标曲线划分轴承寿命状态和实现样本标注化; 随后, 使用标注化样本训练引入了密集连接网络的 IDRSN 得到轴承寿命状态识别模型。为了提高抗干扰能力, 将 DropBlock 层引入第一个大型卷积内核, 在全局平均池化之前引入 Dropout 技术。最后, 运用两个滚动轴承全寿命周期数据集验证 FNER 指标和 IDRSN 模型的实用性和有效性, 结果表明所提方法能更准确地实现滚动轴承寿命状态识别。

关键词: 特征噪声能量比; 滚动轴承性能退化评估; 早期故障检测; 改进深度残差收缩网络; 寿命状态识别

中图分类号: TH17; TN911

Recognition of Rolling Bearing Life Status Based on FNER Performance Degradation Indicator and IDRSN

DONG Shaojiang^{1, 2} PEI Xuwu¹ TANG Baoping³ TIAN Kewei¹ ZHU Peng¹
LI Yang¹ ZHAO Xingxin⁴

- (1. School of Mechantronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074;
2. Key Laboratory of Magnetic Suspension Technology and Maglev Vehicle, Ministry of Education, Chengdu 610031;
3. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044;
4. Chongqing Changjiang Bearing Co., Ltd, Chongqing 401336)

Abstract: Aiming at the difficulty in evaluating the degradation performance of rolling bearing and identifying bearing running state, a new method based on feature-to-noise energy ratio (FNER) indicator and improved deep residual shrinkage network (IDRSN) model is proposed. Firstly, Hilbert transform and fast fourier transform (FFT) are used to obtain the envelope spectrum of bearing run-to-failure test signal and the fault feature energy of the envelope spectrum amplitude is calculated. The feature energy ratio of the envelope spectrum amplitude is calculated according to the fault characteristic frequency and its frequency multiplication. Subsequently, the total energy of the signal is obtained according to the autocorrelation function (AF). After that, the ratio of the fault

* 国家自然科学基金(51775072), 重庆市科技创新领军人才支持计划(CSTCCCXLJRC201920)和重庆市高校创新研究群体(CXQT20019)资助项目。20201010 收到初稿, 20210315 收到修改稿

feature energy and the noise energy is used as the bearing performance degradation indicator. Moreover, the bearing running state is divided according to FNER indicator and tagged bearing samples realized. Then, tagged samples are used to train the IDRSN which introduces the densely connected network to obtain the bearing running state recognition model. In order to improve the anti-interference ability, the DropBlock layer is introduced into the first large convolution kernel and the Dropout technique is introduced before the global average pooling layer (GPA). Finally, two life cycle data sets of rolling bearings are used to verify the practicability and validity of FNER indicator and IDRSN model. The results show that the proposed method can more accurately identify the life state of rolling bearings.

Key words: feature-to-noise energy ratio; rolling bearing performance degradation assessment; early fault detection; improved deep residual shrinkage network; life state recognition

0 前言

滚动轴承是机械系统中关键零部件之一,而且还是其中常见的故障单元。轴承在运行过程中经常承受高负荷和严酷条件,在这种工作条件下,轴承上的缺陷往往会逐渐发展。在工业实践中,对收集到的轴承振动信号进行分析可以判断轴承是否异常^[1]。但滚动轴承早期故障时振动信号微弱,容易被强干扰信号覆盖,难以识别^[2]。因此,研究噪声环境下的滚动轴承寿命状态识别方法显得非常重要,进而采取有效的措施可以避免故障的持续恶化。

滚动轴承寿命状态识别的本质是模式识别,其关键在于如何构建合适的轴承性能退化指标和如何建立有效的轴承寿命状态识别模型^[3]。过去,学者们提出了基于时域、频域和时频域的振动信号分析方法来实现滚动轴承退化起始点的检测,进而实现轴承的早期故障诊断。ZHENG 等^[4]提出基于复合多尺度模糊熵的滚动轴承早期故障检测方法。文献[5]表明基于简单的时域统计特征很难建立阈值来区分轴承的健康和故障状况。JACEK 等^[6]提出子带频谱波峰因数和子带频谱脉冲因数完成了轴承的性能退化评估。YU 等^[7]从振动信号中提取时域、频域和时频域特征来表示轴承的性能状态。ZHOU 等^[8]提出基于提升小波包符号熵和支持向量数据描述的轴承性能评估方法。ALI 等^[9]结合经验模态分解得到的内禀模态函数能量熵和时频域特征用于检测轴承早期故障。然而,这些指标要么对早期轴承缺陷不够敏感,检测效果不佳;要么在轴承运行初期表现不稳定,造成虚报警。希尔伯特包络分析是用于幅度解调的信号处理技术,包络信号可以视为谐波和噪声分量两部分的总和^[10]。文献[10]验证了包络谐波噪声比(Envelope harmonic-to-noise ratio, EHNR)是检测周期脉冲的有效方法。EHNR 利用自相关函数检测由于轴承故障而产生的脉冲的周期性,能很好

地计算包络信号中谐波能量和噪声能量。但是,对于被噪声污染的信号,在定位由于轴承故障引起的周期性冲击时,自相关的精度会降低^[11],从而导致检测到的故障起始点相较于轴承的实际故障起始点滞后。

当滚动轴承发生故障时,不同故障类型的理论故障频率可以根据被测轴承的特性计算得到。此时,故障特征频率及其倍频将同时出现在包络谱中,且幅值相对比较突出。因此,本文将包络谱幅值提取为原始特征,通过定位频域中的周期性脉冲并计算故障特征频率及倍频处的幅值能量和占包络谱幅值总能量的比值得到特征能量比(Feature energy ratio, FER)^[12],应用自相关函数计算包络信号的总能量,提出特征噪声能量比(Feature-to-noise energy ratio, FNER)轴承性能退化指标,并将其用于评估轴承的性能退化过程,最终实现轴承早期故障检测。

目前,基于数据驱动的轴承寿命状态识别模型不断被提出。ALI 等^[9]应用人工神经网络对七种不同轴承状态进行了表征和分类。ZHANG 等^[13]将特征输入到长短时记忆递归神经网络中实现了轴承运行状态的识别。这些模型在轴承寿命状态识别方面取得了不错的效果,但是都没有考虑轴承服役环境中的噪声干扰问题,难以保证精度。

综上,本文提出一种基于特征噪声能量比(FNER)指标及改进深度残差收缩网络(Improved deep residual shrinkage network, IDRSN)的滚动轴承寿命状态识别新方法。该方法首先将 FNER 指标用于评估轴承全寿命周期数据的性能退化过程,不仅避免了轴承运行初期的误报警问题,还能较早地检测出轴承退化过程的起始点;其次,采用自相关奇异值分解(Autocorrelation function singular value decomposition, AF-SVD)和 Hilbert 变换的包络谱分析验证检测结果的正确性,并且实现了轴承早期故障诊断;然后, IDRSN 用于识别根据 FNER 曲线划分的全寿命周期寿命状态样本集。最后,通过实验

室数据验证了本文所提方法的实用性和有效性。

1 提出的轴承寿命状态识别方法

1.1 FNER 轴承性能退化指标

Hilbert 变换可以提取时域信号的包络频谱, 具有可以解调调制信号的功能。设任意时间序列 $x(t)$ 有 n 个数据样本, 每个样本有 m 个采样数据。对信号 $x(t)$ 做 Hilbert 变换, 即

$$\tilde{x}(t) = H\{x(t)\} = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (1)$$

式中, $\tilde{x}(t)$ 为变换后的时间序列。然后, 对 $\tilde{x}(t)$ 计算包络并去除包络信号的直流分量, 即

$$e(t) = \sqrt{\tilde{x}^2(t) + x^2(t)} \quad (2)$$

$$\hat{e}(t) = e(t) - \bar{e}(t) \quad (3)$$

式中, $e(t)$ 为包络处理后的信号; $\bar{e}(t)$ 为包络信号的均值; $\hat{e}(t)$ 为去除包络信号直流分量的新包络信号。通过对新包络信号进行快速傅里叶变换(FFT), 可以使信号的故障特征频率及倍频在包络谱中清晰地显现出来, 且幅值相对比较突出。

$$e(k) = \frac{1}{N} \sum_{n=0}^{N-1} e(t) \exp(-j\pi n t / N) \quad (4)$$

$$|F(u, v)| = [R^2(u, v) + I^2(u, v)]^{1/2} \quad (5)$$

式中, $R(u, v)$ 和 $I(u, v)$ 分别表示 FFT 的实部和虚部。

基于以上原因, 本文计算特征能量比(FER)来评价故障频率成分在整个包络谱中的表现, 即故障成分占信号成分的比重大小。特征能量比(FER)反映包络谱中前 p 个故障特征频率占整个频谱总能量的比重大小, 文中取 $p=3$ 。

$$FER = \frac{E}{E^*} \quad (6)$$

式中, E 为信号包络解调后的频谱序列的前 3 倍频处的幅值能量和, E^* 为包络谱幅值总能量。计算新包络信号的自相关函数(Autocorrelation function, AF)可以得到包络信号总能量 $r_x(0)$ [10]。

$$r_x(\tau) = \int_{-\infty}^{+\infty} \hat{e}(t) \hat{e}(t + \tau) d\tau \quad (7)$$

式中, τ 为自相关函数的时间滞后量。将 $r_x(0)$ 与 FER 相结合得到特征能量和噪声能量大小。将特征能量和噪声能量的比值定义为特征噪声能量比(FNER)。它的大小不仅可以表征故障强弱, 还可以充分反映故障引起的周期性冲击。同时避免传统特征对复杂

运行条件下评估结果的影响, 是一种评估轴承退化性能和检测滚动轴承早期故障的新指标。

根据包络信号总能量 $r_x(0)$ 和 FER 计算包络信号中故障特征能量和噪声能量。则 FNER 定义如下

$$FNER = \frac{FER \cdot r_x(0)}{r_x(0) - FER \cdot r_x(0)} \quad (8)$$

1.2 基于 FNER 的性能退化评估和早期故障检测

1.2.1 设置健康阈值

计算出轴承全寿命样本数据的 FNER 值后, 将 FNER 指标用于评估滚动轴承的性能退化。在实际应用中, 找到轴承初始故障起始点至关重要, 另外需要设置适当的健康阈值来区分轴承的健康状况与异常状况。本文设置的健康阈值遵守高斯分布的 4σ 准则 [14]。超出这个区间的数据则为异常点, 根据健康阈值判断轴承是否进入退化期, 找出退化的起始点实现轴承早期故障检测。

1.2.2 AF-SVD 和 Hilbert 包络解调验证检测结果

根据 FNER 曲线和阈值确定早期故障起始位置之后, 采用合适的方法验证结论的正确性是必不可少的。轴承早期故障振动信号微弱, 容易被强噪声覆盖, 本文利用 AF-SVD 对信号降噪, 并结合 Hilbert 包络解调方法验证检测结果的正确性。

对于一个含噪声的一维轴承振动信号, 无法对其直接进行 SVD, 因此选择对其进行相空间重构。

延时步长 τ 和嵌入维数 m 的选择直接影响到相空间的重构质量。时间延迟 τ 的计算方法很多, 本文采用自相关函数法计算时间延迟 τ 。根据式(4)计算原时间序列的自相关函数, τ 取使得 AF 小于某个域值(本文取 0.1)的最小 τ 值。当 Hankel 矩阵的维数取 $m = N/(1 + \tau)$ 时, SVD 算法会有较好的降噪效果 [15], N 为信号的采样数据个数。关于有效奇异值 λ 的选择, 本文根据奇异值分布曲线确定降噪阶次。

1.3 基于 IDRSN 模型的轴承寿命状态识别算法

针对卷积神经网络和现有浅层智能诊断算法的不足, ZHAO 等 [16] 提出的深度残差收缩网络(Deep residual shrinkage network, DRSN)是基于深度残差网络(Deep residual network, DResNet)和挤压激励网络结构(Squeeze-and-excitation network, SENet)的新型改进。它将软阈值化作为非线性层引入到增加了 SENet 结构的 ResNet 网络结构之中, 其本质是将 SENet 中各个特征通道的加权替换成了各个特征通道的软阈值化, 从而提高深度残差网络在含噪声数据或复杂数据上的特征学习效果, 最终得到更优的模型。本文提出了一种改进深度残差网络(IDRSN)模型用于轴承的状态识别, 如图 1 所示。

图 1 改进的深度残差收缩网络模型

由图 1 可知, IDRSN 主要由输入层、卷积层、DropBlock 层、改进残差收缩模块(Improved residual shrinkage module, IRSM)层、全局平均池化(Global average pooling, GAP)^[16]和状态识别层组成。该方法采用多个 IRSM 作为特征提取器, 采用密集连接网络代替两个传统的卷积隐层, 目的是加深网络的同时促进特征之间的相互融合。批量归一化(Batch normalization, BN)是嵌入在深度神经网络内部层与层之间的一种运算。同时引入泄露修正线性单元(LReLU)^[17]代替修正线性单元(ReLU)增强模型对轴承故障的识别能力。为提高模型的抗噪音能力和降低模型的过拟合风险, 将 DropBlock 层^[18]引入第一大卷积层、Dropout 技巧^[19]引入到 GAP 之前。首先将标签化一维信号集作为输入; 然后信号依次经过第一大卷积层、DropBlock 层、IRSM、Dropout、GPA; 最终通过 Softmax 输出状态类别。“端到端”的算法结构具有更好的可操作性和通用性。

1.3.1 改进的残差收缩模块

(1) 残差收缩模块的基本原理。

残差收缩模块是在残差模块的第二个卷积层之后添加了分支 SENet 结构, 生成了对应通道的权重。深度残差收缩网络模型的一部分如图 2 所示。

图 2 残差收缩模块结构图

在残差收缩网络中, 阈值是可以通过注意力机制根据样本自身情况、自动调整的。

$$y = \begin{cases} x - \tau & x > \tau \\ 0 & -\tau \leq x \leq \tau \\ x + \tau & x < -\tau \end{cases} \quad (9)$$

式中, x 是输入特征, y 是输出特征, τ 是阈

值, 即正参数。输入信号为一维特征, 特征在经过隐层 1 后并通过 ReLU 函数得到隐层 2 的输入。在隐藏层 2 构建两个网络路径。一个对输入特征图内的所有元素取绝对值, 然后经过全局均值池化并求平均得到 X 。另一个 SENet 子网络用来学习得到一组在 0 到 1 区间的值。在 SENet 子网络中, 首先经过 GAP 得到的新特征作为两个全连接网络的输入, 经过 SENet 网络结构得到一组区间在 0 到 1 之间的值。将该组数值和 X 相乘得到一组阈值向量, 通过式(9)对隐藏层 2 的输出特征实现噪声滤除。最后加上残差项从而得到新的输出特征, 在多个首尾相连的残差收缩模块中完成特征的自动提取。

(2) 改进的残差收缩模块结构。

DenseNet 主要由多个 Dense block(DB)组成^[20]。DB 可以是修正线性单元、卷积、池化等操作的组合, 使得每一层的输入来自前面所有层的输出。在 IRSM 中, 用 DenseNet 替换残差收缩模块中的两个卷积隐层, 将 LReLU 作为激活函数, 如图 3 所示。

图 3 改进的残差收缩模块结构图

1.4 轴承的寿命状态识别过程

本文所提轴承寿命状态识别的过程分两部分: 轴承性能退化评估和轴承寿命状态识别, 如图 4 所示。

图 4 提出的轴承寿命状态识别模型

具体性能评估和状态识别过程的说明如下。

(1) 使用式(1)对轴承全寿命数据进行希尔伯特变换和去除直流分量得到包络信号。根据式(7)计算包络信号的自相关函数, 由自相关函数的特性得到包络信号的总能量。

(2) 计算包络信号的快速傅里叶变换得到包络光谱, 并提取其幅值作为原始特征。另外, 根据轴承的特性计算故障特征频率, 根据包络谱找出故障特征频率及倍频对应的幅值。根据式(6)计算 FER, 由式(8)得到 FNER 性能退化指标。

(3) 设置合适的健康阈值区分轴承的健康状态与异常状况, 根据 FNER 曲线实现轴承性能退化评估。在找到轴承初始故障的起始点位置之后, 运用 AF-SVD 和 Hilbert 包络解调方法进行结果验证。

(4) 根据轴承性能退化曲线划分轴承运行状态。基于重叠采样方法^[21]制作寿命状态数据集。基于 Python-Tensorflow 在 Windows10 中搭建和训练 IDRSN 模型。将测试集输入到训练好的 IDRSN 模型中最终实现轴承的寿命状态识别。

2 试验验证

本节中, 选择两个全寿命周期数据集验证所提方法的有效性, 并与其他方法进行比较。运用 FNER 方法实现了轴承早期故障检测和性能退化评估, IDRSN 模型用于识别噪声环境下的轴承寿命状态。

2.1 全寿命周期数据集来源

试验一: 数据是辛辛那提大学智能维护系统中心的滚动轴承全寿命数据集。本文选择了 3 次试验采集到的轴承全寿命数据。根据被试轴承特性计算出滚动轴承内、外圈理论故障特征频率分别为 296.9 Hz、236.4 Hz。

试验二: 数据是 XJTU-SY 滚动轴承全寿命数据集^[22]。试验共设计了 3 类工况, 每类工况下有 5 个轴承, 本文选取 5 个不同的轴承验证方法的有效性。因载荷施加在水平方向, 该方向的振动信号包含更多的退化信息, 故选取水平方向振动信号作为分析。根据被测轴承的特性计算得到 Bearing2-1、Bearing3-3 的内圈理论故障特征频率分别为 184.4 Hz、196.68 Hz; Bearing1-2、Bearing2-4、Bearing2-5 的外圈理论故障特征频率分别为 107.91 Hz、115.62 Hz、115.62 Hz。

2.2 基于 FNER 和 IDRSN 的轴承寿命状态识别

本小节选用试验一中第 2 次试验的轴承数据, 实现对所提 FNER 指标和 IDRSN 识别模型的验证。

2.2.1 FNER 性能退化指标的分析

根据轴承全寿命数据样本计算 FNER 值, 得到的曲线图如图 5 所示, 图 5 的局部放大如图 6 所示。

图 5 试验 2 中轴承 1 全寿命样本的 FNER 曲线图

图 6 图 5 中轴承 1 全寿命样本的 FNER 曲线局部放大

从图 5 中可以明显识别出轴承 1 从运行到失效的不同阶段。前 500 个样本的 FNER 处于相对稳定状态, 因此选择前 500 个样本计算健康阈值, 大小为 0.007 46, 如图 5、6 中所示。在 5 320 min(第 533 个样本)时, FNER 等于 0.023 04, 趋势明显增加, 这表明初始故障开始发生, 此时的故障特征往往被强噪声掩盖。7 010 min 后, FNER 增加趋势更加明显, 表明滚动轴承在故障发展阶段运行, 这一阶段故障的尺寸会加深加大, 故障特征也变得更加明显。但也会由于连续的接触磨损使故障部位变平滑出现“自愈”的假象, 因此 FNER 的幅值出现先升高后降低的现象。8 230 min 后, 轴承故障缺陷增长加快, FNER 幅值剧烈振荡, 工作的可靠性显著降低, 轴承濒临失效。9 110 min 后, 轴承完全不能可靠工作, 甚至会对整个机械系统造成严重危害。综上, 轴承 1 的性能退化分为五个阶段: 正常期为 0~5 320 min, 轻度退化期为 5 320~7 010 min, 中度退化期为 7 010~8 230 min, 严重退化期为 8 230~9 110 min 以及失效期为 9 110 min 到结束。

2.2.2 基于 AF-SVD 和 Hilbert 包络解调的 FNER 评估结果的正确性验证

由以上分析可知, 轴承的初始故障发生在第 5 320 min(第 533 个样本)。为了验证评估结果的正确性, 采用 AF-SVD 和 Hilbert 包络解调的包络谱分析

方法分析第 700、534、533 和 332 个样本。解调结果如图 7 所示。

图 7 AF-SVD 和 Hilbert 方法处理得到的四个样本包络谱

从图 7a~7c 可以看出, 在 231 Hz 的频率处有一个明显的频谱峰值, 该峰值接近 236.4 Hz 的故障特征频率。而且存在明显的谐波频率特性。此外, 图 7d 所示的第 532 个样本的包络光谱在接近理论故障特征频率处没有明显的频谱峰, 本文未展示的 5 320 min 之前的样本显示相同的结果。因此可以推断出外圈的初始故障发生在第 5 320 min, 分析验证了评估结果的正确性。

2.2.3 FNER 与其他性能退化指标的分析与比较

本小节均选用试验一的第 2 次试验中轴承 1 的全寿命周期数据进行评估分析和比较。

(1) 使用 EHNR 方法的评估结果。

图 8 示出了采用包络谐波噪声比(EHNR)方法评估全寿命周期数据得到的性能退化曲线图。

图 8 第 2 次实验中轴承 1 全寿命样本的 EHNR 曲线图

从图 8 中可以看出, EHNR 方法识别的轴承退化起始点为第 543 个样本, 比本文所提 FNER 方法的识别结果晚了 10 个样本(100 min)。虽然 EHNR 方法在正常期没有出现虚警点, 但明显可以看出, EHNR 幅值在轴承运行前期不够平稳, 整体振荡明显。

(2) 使用 RMS 方法的评估结果。

图 9 示出了采用均方根(Root mean square, RMS)

方法评估全寿命周期数据得到的性能退化曲线图。

图 9 第 2 次试验中轴承 1 全寿命样本的 RMS 曲线图

从图 9 可以看出, RMS 值表示轴承在第 533 个样本开始退化。但是在 6 980 min 之前 RMS 振幅的增加趋势并不明显, 这表明正常阶段和轻微故障阶段的 RMS 差异不明显。值得注意的是, 第 513 样本的 RMS 值大于阈值, 考虑此位置可能为轴承初始故障点, 故采用 AF-SVD 和 Hilbert 包络谱分析方法第 513 个样本, 图 10 中的解调结果显示, 第 513 个样本的包络谱在接近外圈理论故障频率的频率处没有明显的频谱峰, 所以说明该样本为误报警样本。

图 10 第 2 次试验中轴承 1 第 513 个样本的包络解调结果

(3) 使用 Kurtosis 方法的评估结果。

图 11 示出了采用 Kurtosis 方法评估全寿命周期数据得到的性能退化曲线图。从图 11 可以看出, Kurtosis 方法识别的退化起始点为第 648 个样本, 与 EHNR 方法和 FNER 方法相比分别落后 105、115 个样本(1 050 min、1 150 min)。另外, 由于 Kurtosis 是用于描述波形的脉冲特性的参数, Kurtosis 趋势不稳定。轴承运行在第 40 分钟时的 Kurtosis 值大于阈值, 出现误报警现象。并且在轴承故障的发展阶段, Kurtosis 值甚至低于阈值。

图 11 第 2 次试验中轴承 1 全寿命样本的 Kurtosis 曲线图

结合以上分析和表 1 可以看出在轴承轻度退化

期时,常用的 RMS 和 Kurtosis 对初始故障不敏感,并且存在误报警。EHNR 值在运行初期极不稳定,虽然不会发生误报警,但是检测结果却比本文方法晚 100 min。FEEMD-EHNR 方法^[14]将检测结果提前为第 5 340 min,但检测结果仍比本文方法晚 20 min。经过对比发现,FNER 方法在评估第 2 次实验中轴承 1 时没有出现虚报警,且早期故障检测结果比 Kurtosis、RMS、EHNR 和 FEEMD-EHNR 方法都早。说明 FNER 指标对初始故障的敏感性更高,适合滚动轴承在线运行检测和早期故障诊断。

表 1 五种方法的早期退化点检测结果对比

指标方法	故障起点时间/min	误报警数目
Kurtosis	6 470	1
RMS	5 320	1
EHNR	5 420	0
FEEMD-EHNR	5 340	0
FHNR	5 320	0

2.2.4 所提 IDRSN 寿命状态识别模型的性能验证

本节将通过试验验证 IDRSN 具有较强抗噪性能。根据第 2.2.1 节和第 2.2.2 节的分析,文中将轴承寿命状态划分为 5 类,每类都可以认为是一种寿命状态阶段。图 12 是根据 FNER 曲线划分的五个寿命状态。

图 12 第 2 次试验中轴承 1 的五种寿命状态数据集的划分

从图 12 可知,根据试验一中第 2 次试验的全寿命数据获得的寿命状态数据集包含五种运行状态,分别为正常期、轻度退化期、中度退化期、严重退化期以及失效期。每个样本包含 2 048 个数据点,将每次采集到的 20 480 个数据点切分成 30 个样本。每个状态对应的样本数依次为 4 440、5 070、3 360、2 640 和 2 190。为提高结果的可靠性,采用 5 折交叉验证,选取 80%作为训练集,20%作为测试集。最终,将 14 400 个训练样本输入到 IDRSN 中训练,3 600 个测试样本进行状态识别,试验重复五次。

(1) IDRSN 模型的架构设计和参数确定。

本文所提的 IDRSN 识别模型共建立 19 层模型,包括 3 个卷积层、1 个 Dropblock 层、12 个 IRSM, 1 个 Dropout 层、1 个 GAP, 1 个 Softmax 层。其中每个 IRSM 包含 1 个 DenseNet, 由 7 个卷积层和 1

个池化层组成。在 IDRSN 模型训练中采用 Adam 自适应学习率优化算法,采用 LReLU 激活函数,Mini-batch 为 36,循环迭代轮数 6 000 轮,Dropout 为 0.8。本文的模型的具体参数设置如表 2 所示。

表 2 IDRSN 识别模型的参数设置

结构名称	参数	输出大小	保留率
Conv1	(1,64,8,16)	16×256	—
Dropblock	—	16×256	0.75~1.0
Block1	$\begin{bmatrix} (1,1,1,32) \times 1 \\ (1,4,1,128) \times 2 \\ (1,1,1,32) \times 1 \end{bmatrix} \times 4$	32×256	—
Conv2	(1,4,2,64)	64×128	—
Block2	$\begin{bmatrix} (1,1,1,64) \times 1 \\ (1,4,1,256) \times 2 \\ (1,1,1,64) \times 1 \end{bmatrix} \times 4$	64×128	—
Conv3	(1,4,2,128)	128×64	—
Block3	$\begin{bmatrix} (1,1,1,128) \times 1 \\ (1,4,1,512) \times 2 \\ (1,1,1,128) \times 1 \end{bmatrix} \times 4$	128×64	—
Dropout	—	—	0.8
GAP	—	8 192	—
Softmax	—	5/18	—

表 2 中第一层卷积内核大小为 1×64 ,步长为 1×8 ,其中第一卷积层选用的宽卷积核能够削弱高频信号对提取特征时的影响^[19]。每个 Block 包含 4 个残差收缩块,例如 Block1 的 $\begin{bmatrix} (1,1,1,32) \times 1 \\ (1,4,1,128) \times 2 \end{bmatrix}$ 中参数 (1,1,1,32)表示第一个卷积层卷积核的大小为 1×1 ,步长为 1,通道数为 32;参数(1,4,1,128)代表第二个卷积层卷积核的大小为 1×4 ,步长为 1,通道数为 128。 $\begin{bmatrix} (1,4,1,32) \times 2 \\ (1,4,1,128) \times 1 \end{bmatrix}$ 中参数 32 和 128 表示第一、二个卷积层卷积核的通道数。 $\begin{bmatrix} (1,1,1,32) \times 1 \\ (1,2,1,32) \times 1 \end{bmatrix}$ 中参数 (1,1,1,32) 表示第一个卷积层卷积核的大小为 1×1 ,步长为 1,通道数为 32;(1,2,1,32)表示最大池化层的核大小为 1×2 ,步长为 1,通道数为 32。

(2) 改进部分的抗干扰能力验证。

本小节将通过试验验证提出的 FNER 性能退化

指标结合 IDRSN 模型具有较强的抗噪性能,将采用不同的试验方案验证改进部分在噪声环境下的优越性。对比试验控制了三个变量,包括主模型,Dropblock 层设置,DenseNet 设置。首先,主要模型包括 IDRSN、传统 DResNet 和传统 DRSN,三者的结构参数相同,见表 2;然后,是否在第一大卷积层中加入 Dropblock 层;最后一个变量是否引入 DenseNet 代替 DRSN 中两个传统的卷积隐层。不同模型的变量设置如表 3 所示。

表 3 不同模型的变量设置

模型	IRSM	DenseNet	Dropblock 层
A	是	是	是
B	是	是	否
C	否	否	是
D	否	否	否

表 3 中模型 A 表示 IDRSN,模型 A 和 B 用于验证 Dropblocks 层的优势;模型 A 和 C 用于验证 DenseNet 在残差收缩模块中的优势;模型 D 表示传统 DRSN;模型 E 表示传统 DResNet。试验模拟了工业噪声对测试样本的影响,即在测试样本中加入 SNR=0~10 dB 的白高斯噪声。在测试集上的测试结果如表 4 所示,表中结果是 5 折交叉验证的平均值。

表 4 五个模型的识别正确率(%)

数据集	SNR/dB					
	0	2	4	6	8	10
A	85.20	94.29	96.65	97.62	98.05	98.48
B	82.49	92.62	96.34	97.41	97.95	98.42
C	79.04	93.16	97.02	97.70	98.41	98.71
D	70.85	89.21	95.70	97.56	98.20	98.52
E	64.61	83.49	92.56	95.92	97.10	97.67

从表 4 可知,对试验一中的数据集中的数据集进行训练和测试时,五个模型在 SNR=0 dB 高噪声环境中的平均识别正确率从模型 E~A 呈递增状。相比之下,模型 A 的平均识别正确率最高,达到了 85.20%,分别比模型 B、C、D、E 高出 2.71%、6.16%、14.35%、20.59%。无论在何种噪声环境中,A 模型的识别正确率始终高于其他 4 个模型。由于篇幅原因,本文未展示五个模型在 I~V 测试时的正确率,在 SNR=0~10 dB 环境中模型 E~A 的识别率逐渐递增。

将模型 D 与模型 E 相比,在 SNR=0 dB 高噪声环境下,模型 D 的正确率比模型 E 高出 1.88%~9.08%;结果表明,对于轴承信号,传统 DRSN 比

传统 DResNet 对故障特征更为敏感,得到的模型在噪声环境中的表现更加良好。将模型 B、C 与模型 D 相比,模型 A 分别比模型 B、C 相比。模型 C 比模型 D 高出 2.98%~16.79%、模型 A 分别比模型 B 高出 0.26%~4.89%。结果表明,将 Dropblocks 层引入到第一大卷积核中可以增加模型的抗干扰能力。模型 B 比模型 D 高出 8.28%~20.67%、模型 A 比模型 C 高出 0.83%~8.40%。结果表明,DenseNet 替换 DRSN 中的两个卷积隐层可以提高模型的细节特征提取能力。随着 SNR 的增大,所有模型的识别正确率都提高,在 SNR=10 dB 环境中,趋近 100%的准确率。综上,试验有效地验证了 IDRSN 模型的实用性和有效性,验证了改进部分的优越性,所提 IDRSN 模型在噪声环境下的抗干扰能力。

2.3 基于 FNER 和 IDRSN 方法的泛化性能验证

本小节选用试验二和试验一中余下的数据集,

实现对 FNER 指标和 IDRSN 方法的泛化性能验证。

2.3.1 基于 FNER 指标的早期故障检测结果

(1) 试验一中两次试验的轴承 3 的性能退化评估。

根据试验一的第 1 次试验中轴承 3 和第 3 次试验中轴承 3 的全寿命数据计算 FNER,得到的性能退化曲线如图 13 和图 14 所示。根据图 13、14 评估两个轴承的性能退化过程,并实现早期故障诊断。

图 13 试验 1 中轴承 3 的 FNER 性能退化评估曲线

图 14 试验 3 中轴承 3 的 FNER 性能退化评估曲线

从图 13 和图 14 可以看出两个轴承从运行到失效的全过程。通过计算健康阈值确定实验 1 中轴承 3 的退化起始点为第 1 824 个样本,实验 3 中轴承 3 的退化起始点为第 6 071 个样本,且未出现误报警,可以很好地检测轴承的运行状态。

(2) 试验二中五次试验的 5 个轴承的性能退化评估。

图 15 给出了 5 个轴承 Bearing2-1、1-2、3-3、2-4 和 2-5 的 FNER 性能退化曲线。从图 15a、b、c、

d 和 e 可以明显地看出 5 个轴承从运行到失效的全过程。通过计算健康阈值可以确定轴承 Bearing2-1、Bearing1-2、Bearing3-3、Bearing2-4、Bearing2-5 的退化起始点分别为第 453、32、340、31、121 个样本, 且未出现误报警现象。

图 15 试验二中 5 个轴承的 FNER 性能退化评估曲线

2.3.2 IDRSN 状态识别模型的泛化性

本小节将通过试验验证 IDRSN 具有较强泛化性能。根据 2.3.1(2)的分析, 文中按照轴承退化阶段分别将轴承 Bearing2-1、Bearing1-2、Bearing3-3、Bearing2-4、Bearing2-5 划分为 2、5、2、2、7 种寿命状态阶段, 轴承的寿命状态数据集由 5 个轴承 18 种状态组合而成。Bearing2-1 的正常、故障状态为第 416~453、454~491 个样本; Bearing1-2 的五种状态分别为第 1~31、32~62、63~93、94~124、125~161 个样本; Bearing3-3 的正常、故障状态为

第 310~340、341~371 个样本; Bearing2-4 的正常、故障状态为第 1~31、32~42 个样本; Bearing2-5 的七种状态分别为第 84~120、121~157、158~194、195~231、232~268、269~305、306~339 个样本。将每次采集到的 32 768 个数据点样本按照重叠采样获得 40 个标签化样本, 每个样本含有 2 048 个数据点。采用 5 折交叉验证, 选取 80%作为训练集, 20%作为测试集, 最终, 将 19 104 个训练样本输入到 IDRSN 中训练, 4 776 个测试样本进行状态识别, 并在测试样本中加入 SNR=0~10 dB 的白高斯噪声, 试验重复五次。识别结果如表 5 所示。

表 5 不同噪声环境下 IDRSN 模型的识别正确率(%)

五折数据集	SNR/dB					
	0	2	4	6	8	10
I	82.71	90.78	94.52	96.07	97.05	97.44
II	81.22	88.62	93.01	95.38	96.12	96.67
III	87.81	93.27	94.88	96.03	97.06	97.54
IV	80.69	90.14	94.46	96.05	96.18	96.85
V	83.90	91.44	94.61	95.97	96.90	97.35
AVG	83.27	90.85	94.30	95.90	96.66	97.17

由表 5 可知, 在 SNR=0 dB 噪声环境中进行样本测试, IDRSN 的识别正确率均在 80%以上, 且平均识别正确率达 83.27%。随着 SNR 的增加, 样本中含有的噪声越少, IDRSN 的识别正确率上升。当 SNR=10 dB 时, IDRSN 的平均识别正确率达 97.17%, 验证了 IDRSN 在噪声环境下的泛化能力。

2.3.3 特征分布的可视化

本小节选用 t-随机邻近嵌入算法将所有卷积层、IRSM、全连接层的特征表达降为二维分布, 通过对 IDRSN 训练过程的可视化展示模型特征提取过程。由于篇幅原因, 图 16 给出了训练好的模型 A, 通过 t-随机邻近嵌入方法提取的测试样本的特征分布可视化图, 识别正确率为 99.28%。随着 IDRSN 模型网络层数的增加, 每一层的特征可分割性不断增强, 最终实现特征的有效分类。说明了深度结构的必要性, 所提方法有很好的寿命状态识别能力。

图 16 测试样本的特征分布图

3 结 论

(1) 本文提出了一种新的解决噪声环境下难以实现滚动轴承寿命状态识别的方法。FNER 指标用于评估轴承的性能退化状态; IDRSN 模型用于识别轴承的寿命状态; AF-SVD 和 Hilbert 包络解调方法用于验证评估结果的正确性, 实现早期故障诊断。

(2) 选用辛辛那提轴承数据集进行试验验证, 试验结果表明, 与 Kurtosis、RMS、EHNH 和 FEEMD-EHNH 等方法相比, 所提出的 FNER 指标对初始故障更为敏感, 评估结果在第 5 320 分钟时开始退化, 结果均早于其他方法且无误报警问题。采用 AF-SVD 和 Hilbert 包络解调方法验证了结果的正确性, 实现了早期故障诊断。IDRSN 模型将 Dropblocks 层引入到第一大卷积核中增强模型的抗干扰能力。DenseNet 替换 DRSN 中的两个卷积隐层, 同时 LReLU 作为激活函数, 提高模型的细节特征提取能力。在 SNR=0~10 db 环境中识别 5 类寿命状态时, 平均识别正确率为 95.10%, 均高于其他模型。

(3) 通过泛化性试验表明, 对辛辛那提和 XJTU-SY 两个轴承数据集, FNER 指标均可实现轴承的性能退化评估。对 XJTU-SY 中 5 个轴承组成的 18 类寿命状态数据集, 在 SNR=10db 环境中的平均识别正确率为 97.17%。综上, IDRSN 模型可以很好地实现轴承实验数据寿命状态识别。

参 考 文 献

- [1] WU Dengyun, WANG Jianwen, WANG Hong, et al. An automatic bearing fault diagnosis method based on characteristics frequency ratio[J]. *Sensors*, 2020, 20(5): 15-27.
- [2] WANG Hengdi, DENG Sier, YANG Jianxi, et al. Parameter-adaptive VMD method based on BAS optimization algorithm for incipient bearing fault diagnosis[J]. *Mathematical Problems in Engineering*, 2020, 2020: 5659618.
- [3] DONG Shaojiang, WU Wenliang, HE Kun, et al. Rolling bearing performance degradation assessment based on improved convolutional neural network with anti-interference[J]. *Measurement*, 2020, 151: 107219.
- [4] ZHENG Jinde, PAN Haiyang, CHENG Junsheng. Rolling bearing fault detection and diagnosis based on composite multiscale fuzzy entropy and ensemble support vector machines[J]. *Mechanical Systems and Signal Processing*, 2017, 85: 746-759.
- [5] ZIMROZ R, BARTELMU W, BARSZCZ T, et al. Diagnostics of bearings in presence of strong operating conditions non stationarity-a procedure of load dependent features processing with application to wind turbine bearings[J]. *Mechanical Systems and Signal Processing*, 2014, 46(1): 16-27.
- [6] JACEK D. Diagnosing of rolling-element bearings using amplitude level-based decomposition of machine vibration signal[J]. *Measurement*, 2018, 126: 143-155.
- [7] YU Jianbo. Bearing performance degradation assessment using locality preserving projections[J]. *Expert Systems with Applications*, 2011, 38(6): 7440-7450.
- [8] ZHOU Jianmin, GUO Huijuan, ZHANG Long, et al. Bearing performance degradation assessment using lifting wavelet packet symbolic entropy and SVDD[J]. *Shock and Vibration*, 2016, 2016: 1-10.
- [9] 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: 16-27.
- [10] XU Xiaoqiang, ZHAO Ming, LIN Jing, et al. Envelope harmonic-to-noise ratio for periodic impulses detection and its application to bearing diagnosis[J]. *Measurement*, 2016, 91: 385-397.
- [11] SACHAN S, SHUKLA S, SINGH S K. Two level de-noising algorithm for early detection of bearing fault using wavelet transform and zero frequency filter[J]. *Tribology International*, 2020, 143: 106088.
- [12] 程珩, 励文艳, 权龙, 等. 基于 VMD-MDE 和 ELM 的柱塞泵微弱故障诊断[J]. *振动.测试与诊断*, 2020, 40(4): 635-642, 818.
CHENG Heng, LI Wenyan, QUAN Long, et al. Diagnosis of weak fault of plunger pump based on VMD-MDE and ELM[J]. *Vibration. Test and Diagnosis*, 2020, 40(4): 635-642, 818.
- [13] ZHANG Bin, ZHANG Shaohui, LI Weihua. Bearing performance degradation assessment using long short-term memory recurrent network[J]. *Computers in Industry*, 2019, 106: 14-29.
- [14] CHEGINI S N, MANJILI M J H, BAGHERI A. New fault diagnosis approaches for detecting the bearing slight degradation[J]. *Meccanica*, 2020, 55(1): 261-286.
- [15] PANG Bin, HE Yuling, TANG Guiji, et al. Rolling bearing fault diagnosis based on optimal notch filter and

- enhanced singular value decomposition[J]. *Entropy*, 2018, 20(7): 482.
- [16] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual shrinkage networks for fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(7): 4681-4690.
- [17] LIEW S S, KHALIL-HANI M, BAKHTERI R. Bounded activation functions for enhanced training stability of deep neural networks on visual pattern recognition problems[J]. *Neurocomputing*, 2016, 216(5): 718-734.
- [18] GHIASI G, LIN T Y, QUOC V L. DropBlock: A regularization method for convolutional networks[C]// *Neural Information Processing Systems Conference*, Montreal: NIPS. 2018.
- [19] 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.
- [20] HUANG Gao, LIU Zhang, MAATEN L V D, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 2261-2269.
- [21] XU Kun, LI Shunming, WANG Jinrui, et al. A novel adaptive and fast deep convolutional neural network for bearing fault diagnosis under different working conditions[J]. *Proceedings of the Institution of Mechanical Engineers. Part D: Journal of Automobile Engineering*, 2019, 234(4): 1167-1182.
- [22] 雷亚国, 韩天宇, 王彪, 等. XJTU-SY 滚动轴承加速寿命试验数据集解读[J]. *机械工程学报*, 2019, 55(16): 1-6.
- LEI Yaguo, HAN Tianyu, WANG Biao, et al. XJTU-SY rolling bearing accelerated life test data set interpretation[J]. *Journal of Mechanical Engineering*, 2019, 55(16): 1-6.

作者简介: 董绍江, 男, 1982 年出生, 博士, 教授, 博士研究生导师。
主要研究方向为机械故障诊断和机电一体化技术。

E-mail: dongshaojiang100@163.com

裴雪武(通信作者), 男, 1995 年出生。主要研究方向为机械故障诊断。

E-mail: 398721763@qq.com