DOI:10.3969/j.issn.1001-4551.2023.11.013

基于改进层次极差熵和 WOA-ELM 的滚动轴承故障识别*

李娜娜1,万 中2

(1. 西安交通大学城市学院 机械工程系,陕西 西安 710018;2. 西安昆仑工业集团有限公司,陕西 西安 710043)

摘要:由于传统的多尺度熵特征提取方法无法提取信号的高频故障特征,造成特征的提取不够完整,故障识别准确率也较低。为此,提出了一种基于改进层次极差熵(IHRE)和鲸鱼算法(WOA)优化极限学习机(ELM)的滚动轴承故障诊断策略。首先,基于改进的层次分析和极差熵,提出了可以同时分析滚动轴承振动信号低频和高频成分的 IHRE 时间序列复杂性测量方法,并将其用于提取滚动轴承振动信号的深层次故障特征;然后,采用鲸鱼算法对极限学习机的核心参数进行了优化,构建了网络结构最优的鲸鱼算法——极限学习机(WOA-ELM)分类器;最后,将所构建的 IHRE 故障特征输入至 WOA-ELM 分类器,进行了故障分类,对滚动轴承进行了故障识别;基于滚动轴承的实验数据进行了算法的有效性分析,并从多个维度进行了对比,进行了算法优越性分析。研究结果表明:IHRE 方法的故障识别准确率最高,达到了 100%,而多次实验的平均识别准确率也达到了 99.82%,优于改进层次样本熵、层次极差熵和多尺度极差熵方法;在分类时间和分类准确率方面,WOA-ELM 分类模型要优于 PSO-ELM 和 GA-ELM 分类器。该结果证明,基于 IHRE 和 WOA-ELM 的故障诊断策略能够快速且有效地识别滚动轴承的故障类型,具有应用的潜力。

文章编号:1001-4551(2023)11-1752-08

Rolling bearing fault identification based on improved hierarchical range entropy and WOA-ELM

LI Nana¹, WAN Zhong²

(1. Department of Mechanical Engineering, Xi'an Jiaotong University City College, Xi'an 710018, China;2. Xi'an Kunlun Industrial Group Corporation, Xi'an 710043, China)

Abstract: The traditional multi-scale entropy feature extraction method cannot extract the high-frequency fault features of the signal, hence the feature extraction is not complete enough, and the accuracy of fault identification is also low. Therefore, a fault diagnosis strategy of rolling bearing based on improved hierarchical extreme range entropy (IHRE) and whale algorithm (WOA) and optimized extreme learning machine (ELM) was proposed. Firstly, based on the improved hierarchical analysis and range entropy, a time series complexity measurement method called IHRE was proposed, which could simultaneously analyze the low frequency and high frequency components of the rolling bearing vibration signals, and was used to extract the deep fault characteristics of the rolling bearing vibration signals. Then, the WOA was used to optimize the key parameters of the ELM, and the whale algorithm-extreme learning machine (WOA-ELM) classifier with the best network structure was built. Finally, the constructed IHRE fault features were input to WOA-ELM classifier for classification, and fault identification of rolling bearings was completed. Based on rolling bearing experiment data, the effectiveness of the algorithm was analyzed and compared from multiple dimensions, and the superiority of the algorithm was analyzed. The results show that the IHRE method has the highest accuracy of fault identification, reaching 100%, and the average recognition accuracy of multiple experiments has also reached 99. 82%, which is superior to the improved hierarchical sample entropy, hierarchical range entropy and multi-scale range entropy methods. WOA-ELM classification model outperforms PSO-ELM and GA-ELM classifiers in terms of classification time and accuracy, proving

收稿日期:2023-03-13

基金项目:陕西省教育厅科学研究项目(19JK0496)

作者简介:李娜娜(1984-),女,陕西韩城人,硕士,副教授,主要从事机械设计及制造方面的研究。E-mail:s7w638qh@163.com

that the fault diagnosis strategy based on IHRE and WOA-ELM can quickly and effectively identify the fault types of rolling bearings, and has application potential.

Key words: improved hierarchical range entropy(IHRE); whale optimization algorithm optimized extreme learning machine(WOA-ELM); rolling bearing; fault diagnosis

0 引 言

滚动轴承的健康状况直接影响整个旋转机械设备 的性能和可靠性。一旦轴承出现故障,轻则会降低产 品的加工质量或加剧设备的振动噪声,重则造成严重 的安全事故。因此,研究滚动轴承的故障诊断策略具 有积极的工程价值^[12]。

在真实的机械系统中,由于存在摩擦、阻尼、冲击 等多种因素的影响,使得滚动轴承振动信号中的故障 信息是相互耦合的。基于熵的特征提取指标(例如, 近似熵、样本熵、模糊熵和排列熵等),因为其能够有 效处理非线性数据,而被广泛应用于旋转机械的故障 诊断中^[3]。

李卫民等人^[4]采用近似熵来表征异步电机的故 障状态,利用支持向量机的识别结果验证了近似熵的 有效性;但近似熵对短序列的分析精度较低。邹龙庆 等人^[5]提出了基于局部均值分解和样本熵的故障诊 断方法,结果验证了样本熵的性能优于近似熵;但样本 熵基于阶跃函数进行定义,无法考虑数据的模糊特性。 ZHANG Xiao-yuan 等人^[6]采用排列熵检测并诊断滚动 轴承的故障状态,结果表明,排列熵不仅可以用于准确 地筛选出健康轴承,而且能够有效识别故障轴承;但排 列熵忽略了信号中的幅值信息^[7]。随后,OMIDVAR-NIA A 等人^[8]对样本熵进行了改进,提出了极差熵 (range entropy,RE),并基于多种故障信号,对 RE 方 法的优越性(与样本熵和近似熵进行对比)进行了验 证;但 RE 方法只用于进行信号的单尺度分析,忽略了 其他尺度的信息。

为将 RE 方法扩展至多尺度分析,李富国等人^{[9]2} 基于粗粒化处理,提出了多尺度极差熵(multiscale range entropy,MRE),并将其用于滚动轴承的故障诊 断,结果证明了 MRE 方法的有效性;但 MRE 方法的粗 粒化处理存在较大缺陷,遗漏了其它尺度上的故障信 息。随后,ZHENG Li-kang 等人^[10]提出了改进多尺度 极差熵,证实了改进粗粒化处理的优势;但基于粗粒化 处理的多尺度分析无法用于提取信号的高频特征,遗 漏了大量的故障信息。为此,周杰等人^[11]采用层次分 析对信号进行了处理,结合 RE 方法提出了层次极差 熵(hierarchical range entropy, HRE),通过滚动轴承的 故障诊断,结果证明了 HRE 方法明显优于 MRE 方法; 但 HRE 方法的层次处理不够精细,遗漏了部分故障 信息。

针对上述问题,笔者基于改进的层次分析对时间 序列进行处理,提出一种改进层次极差熵算法,以同步 提取信号中低频和高频的故障特征;在此基础上,结合 鲸鱼算法优化的极限学习机模型,提出一种基于 IHRE 和 WOA-ELM 的滚动轴承故障诊断策略。

首先,使用 IHRE 方法提取滚动轴承振动信号的 故障信息,构建故障特征向量;然后,随机抽取部分特 征向量对 WOA-ELM 分类器进行训练;最后,将剩余的 测试样本输入至训练好的分类器中,进行滚动轴承故 障的识别。

1 改进层次极差熵

1.1 极差熵算法

极差熵是在样本熵的基础上改进得到的,而样本 熵是通过求解重构 m 维相空间中 2 个状态向量 Z_i^m 和 Z_j^m 之间的切比雪夫距离,以此来得到 B_i^m 的条件 概率^[12]。

RE 方法的理论如下:

1) 对于信号 $\{x_i, i = 1, 2, \dots, N\}$, 从其原始排序中 挑出 m 个样本点, 构建了一个新的序列 $Z_i^{m,i}$, 即得到相 空间如下:

$$\begin{cases} \mathbf{Z}_{i}^{m,t} = \{x_{i}, x_{i+t}, x_{i+2t}, \cdots, x_{i+(m-1)t}\} \\ i = 1, 2, \cdots, N - (m-1)t \end{cases}$$
(1)

式中:m 为嵌入维数;t 为时间延迟,一般为1; $\mathbf{Z}_{i}^{m,t}$ 为m 维相空间的状态向量。

当 t = 1 时,原始信号则被分割为 m 个序列 \mathbf{Z}_{i}^{m} ,表示如下:

$$\begin{cases} \mathbf{Z}_{i}^{m} = \{x_{i}, x_{i+1}, x_{i+2}, \cdots, x_{i+m-1}\} \\ i = 1, 2, \cdots, N - m + 1 \end{cases}$$
(2)

2)根据熵与信号自相似度之间的关系,由自相似 度估计中的极差分析概念构造新的估计距离的模型, 称之为 *d_r*(**Z**^{*m*}_{*i*},**Z**^{*m*}_{*i*}),表示如下:

$$\begin{cases} d_{r}(\mathbf{Z}_{i}^{m}, \mathbf{Z}_{j}^{m}) = \frac{\max_{k} |x_{i+k} - x_{j+k}| - \min_{k} |x_{i+k} - x_{j+k}|}{\max_{k} |x_{i+k} - x_{j+k}| + \min_{k} |x_{i+k} - x_{j+k}|} \\ k = 0, 1, 2, \cdots, m - 1 \end{cases}$$
(3)

3)将 RE 进行标准差处理,生成 B^{m,r},表示如下:

$$\begin{cases} \boldsymbol{B}_{i}^{m,r} = \sum_{j}^{N-m} \boldsymbol{\Psi}(r - d_{r}(\boldsymbol{Z}_{i}^{m}, \boldsymbol{Z}_{j}^{m})) \\ j = 1, 2, \cdots, N - m, j \neq i \end{cases}$$
(4)

式中:r为相似容差; $\Psi($)为 Heaviside 函数。 其中:

$$\Psi(r-d_r(\mathbf{Z}_i^m,\mathbf{Z}_j^m)) = \begin{cases} 0 & r-d_r(\mathbf{Z}_i^m,\mathbf{Z}_j^m) < 0\\ 1 & r-d_r(\mathbf{Z}_i^m,\mathbf{Z}_j^m) \ge 0 \end{cases}$$
(5)

4) 将每个 **B**^{*m*}_{*i*}(*r*) 相加并取平均,则生成 **B**^{*m*,*r*}_{*i*},表示 如下:

$$\boldsymbol{B}_{m}^{r} = \frac{1}{N-m} \sum_{i=1}^{N-m} \boldsymbol{B}_{i}^{m,r}$$
(6)

5) 令 *m* = *m* + 1, 重复执行上述步骤, 则可以生成 *B*'_{*m*+1}。与样本熵类似, RE 方法定义如下:

$$RE = -\ln \frac{\boldsymbol{B}_{m+1}^{r}}{\boldsymbol{B}_{m}^{r}}$$
(7)

1.2 层次极差熵算法

多尺度极差熵方法虽然能够对信号进行多尺度分析,但根据 WANG Xian-zhi 等人^[13]的研究,粗粒化处理的固有缺陷导致其只能分析信号的低频特征信息, 而忽视了信号的高频特征。

为此,笔者通过借鉴层次分析的优势,提出了 HRE 方法。该方法不仅能对信号进行多尺度分析,而 且能够同时提取信号低频和高频的特征。

给定振动信号 $X = \{x_1, x_2, \dots, x_N\}$,其中, $N = 2^n$ ($n = 1, 2, \dots$),则 HRE 定义如下:

1) 定义一个平均算术符 Q_0 如下:

$$(\boldsymbol{Q}_0(\boldsymbol{X}))_j = \frac{x(2j-1) + x(2j)}{2}, j = 1, 2, \cdots, 2^{n-1}(8)$$

长度为 2^{n-1} 的信号 $Q_0(X)$ 表示原信号 X 经过单 次层次分解后的平均分量;

2) 定义一个差分算术符 Q₁ 如下:

$$(\boldsymbol{Q}_1(\boldsymbol{X}))_j = \frac{x(2j-1) - x(2j)}{2}, j = 1, 2, \cdots, 2^{n-1}(9)$$

长度为 2^{n-1} 的信号 $Q_1(X)$ 表示原信号 **X** 经过单次层次分解后的差值分量。原信号 **X** 能够通过 Q_0 (*X*)和 $Q_1(X)$ 表示如下:

$$x_{2j-1} = (\boldsymbol{Q}_0(\boldsymbol{X}))_j + (\boldsymbol{Q}_1(\boldsymbol{X}))_j, x_{2j} = (\boldsymbol{Q}_0(\boldsymbol{X}))_j - (\boldsymbol{Q}_1(\boldsymbol{X}))_j$$
(10)

据此,信号 Q₀(X)和 Q₁(X)组成了对信号 X 进行 多次层次分析的第二层。算术符 Q_j(j=0/j=1)可定 义为一个矩阵:

$$\begin{aligned} \boldsymbol{Q}_{j} &= \\ \begin{pmatrix} \frac{1}{2} & \frac{(-1)^{j}}{2} & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & \frac{1}{2} & \frac{(-1)^{j}}{2} & \cdots & 0 & 0 \\ 0 & 0 & 0 & 0 & \cdots & \frac{1}{2} & \frac{(-1)^{j}}{2} \\ \end{pmatrix}_{2^{n-1} \times 2^{n}} \end{aligned}$$

$$(11)$$

算术符 Q_i 的矩阵形式由信号 X 的长度所决定。 为了表征 X 的多层次分析,算术符将被重复利用;

3)令 e 为整数,且 0 $\leq e \leq 2^{n} - 1$;令 $L_{i}(i = 1, 2, \dots, n)$ 等于 0 或 1。对于给定的 e,存在唯一向量组 [$L_{1}, L_{2}, \dots, L_{n}$],使得:

$$e = \sum_{i=1}^{n} L_i 2^{n-i}$$
 (12)

4)信号 X 第 n +1 层的第 e +1 个层次节点定义如下:

 $X_{n,e} = Q_{L_n} \cdot Q_{L_{n-1}} \cdot \cdots \cdot Q_{L_1}(X)$ (13) 式中: Q_L 为 X_{0,0} 到 X_{n,e} 的第 *i* 次层次分割。

若第i次层次分割为平均计算,则 $Q_{L_i} = Q_0$,即 $L_i = 0;$ 若第i次层次分割为差分计算,则 $Q_{L_i} = Q_1$,即 $L_i = 1;$

5) 计算每个节点 *X_{n,e}* 的极差熵, 即得到了原信号 *X* 的 HRE, 定义为:

$$HRE(\boldsymbol{X}, m, r, k) = RE(\boldsymbol{X}_{n, e}, m, r)$$
(14)

1.3 改进层次极差熵算法

虽然 HRE 方法实现了从低频和高频两个频段来 表征信号的复杂性,但其与 MRE 方法类似,所采用的 层次分割不够精细,导致随着分解层数的增加,层次分 量 *X_{n,e}*的长度显著减小,降低了复杂性的测量精度。 为此,笔者借鉴柏世兵等人^[14]提出的改进层次分割处 理,结合极差熵,提出了改进层次极差熵。

其原理如下:

1) 对于信号 { x_1, x_2, \dots, x_N }, 定义平均算术符 $Q_0(x)$ 和差分算术符 $Q_1(x)$ 如下:

$$Q_0(x) = \frac{x_i + x_{i+1}}{2}, i = 1, 2, \dots, N-1,$$
$$Q_1(x) = \frac{x_i - x_{i+1}}{2}, i = 1, 2, \dots, N-1$$
(15)

式中:N为信号的数据长度,为大于1的正整数,其避免了传统层次分析必须要求数据长度 $N=2^n$ 的缺陷; $Q_0(x)$ 为信号的低频信息; $Q_1(x)$ 为信号的高频信息;

2)当分解层数为k,h=0或1时,算术符 Q_{h}^{k} 的矩 阵形式定义如下:

$$\boldsymbol{Q}_{h}^{k} = \begin{bmatrix} \frac{1}{2} & \underbrace{0 \cdots 0}_{2^{k-1}-1} & \underbrace{(-1)^{n}}{2} & 0 & \cdots & 0 & 0 \\ 0 & \frac{1}{2} & \underbrace{0 \cdots 0}_{2^{k-1}-1} & \underbrace{(-1)^{h}}{2} & \cdots & 0 & 0 \\ \cdots & & & & \\ 0 & 0 & 0 & 0 & \cdots & \frac{1}{2} & \underbrace{0 \cdots 0}_{2^{k-1}-1} \end{bmatrix}$$

3)为了完成信号的层次分析,需重复利用步骤 2) 中的算术符。对于分解层数 $k \in N^+$,建立长度为 k 的 向量 $s_m = [s_1, s_2, \dots, s_k]$,则整数 e 可以定义如下:

$$e = \sum_{m=1}^{k} 2^{k-m} \boldsymbol{s}_m$$

 $s_m \in \{0,1\}, m = 1, 2, \dots, k$ (19) 式中: s_m 为第 m 层的平均算术符 Q_0 或差分算术 符 Q_1 :

4) 基于向量 $s_m = [s_1, s_2, \dots, s_k]$, 定义信号 x_i 的层 次分量如下:

$$\boldsymbol{X}_{k,e} = \boldsymbol{Q}_{s_k}^k \cdot \boldsymbol{Q}_{s_{k-1}}^{k-1} \cdots \boldsymbol{Q}_{s_1}^1 \cdot \boldsymbol{x} \tag{20}$$

式中: $X_{k,e}$ 为信号 x 第 k 层的节点 e 上的层次分量;

5) 计算每个节点 *X_{k,e}* 的极差熵, 即实现了信号的 IHRE 分析目的, 定义如下:

 IHRE(x,m,r,k) = RE($X_{k,e},m,r$)
 (21)

 以 k = 2 为例,对应的层次分解和改进层次分解过

 程如图 1 所示。



图1 2 层的层次和改进层次分解过程

Fig. 1 2-layer original hierarchical and improved hierarchical decomposition process

综合上述分析可知:改进的层次分析弥补了多尺 度分析只考虑信号低频分量而忽略高频分量中故障信 息的缺陷;同时,相较于传统的层次分析,改进的层次 分析缓解了传统层次分析方法存在的"随着层次层数 增加,统计可靠性降低"的缺陷。

1.4 鲸鱼算法优化极限学习机

极限学习机是一种单隐层神经网络,其具有学习 速度快、泛化性能好的优点。但其输入权重和隐含层 阈值会严重影响模型的稳定性和可靠性,干扰分类识 别的准确率^[15]。

为此,笔者采用鲸鱼算法(WOA)对极限学习机

 $\begin{array}{c} 0\\ 0\\ (18)\\ (-1)^{h} \end{array}$

(ELM)的输入权重和隐含层阈值进行优化^[16]。

WOA 算法是 MIRJALILI S 等人^[17] 通过模拟座头 鲸的捕食行为而开发的一种智能算法,其具有操作简 单、参数少等优点。

WOA 优化 ELM 的具体步骤如下:

1)初始化 ELM 的输入权重和隐含层阈值,并将其 作为 WOA 中鲸鱼个体的起始坐标;

2)求解种群中全部个体的适应度值,搜索到最优 的鲸鱼个体,并存储目前最优个体的坐标;

3)若未达到最大迭代次数,则更新鲸鱼个体与猎物之间的方位,并进入下次迭代;

4)当符合条件时,保留当前最优鲸鱼个体坐标, 其坐标即对应 ELM 的最优参数。

2 基于 IHRE 的故障诊断策略

2.1 仿真实验

在 IHRE 方法中,需要设置 4 个参数(即信号数据 长度 N,嵌入维数 m,相似容差 r 和分解层数 k)。

基于李富国等人^{[9]4}的研究,笔者将参数设置为 m = 2, r = 0.2;参考 SONG En-zhe 等人^[18]的研究,将分 解层数设置为 k = 3。

白噪声和 1/f 噪声是 2 种典型的随机噪声,两者 的差异在于白噪声的复杂性随着频率的增加而减小, 1/f 噪声在全频段都具有较大的复杂度。因此,笔者 通过对这两种噪声信号进行分析,以检测算法的有 效性。

笔者以数据长度为1024、2048、4096的白噪声和 1/f噪声为对象,首先研究数据长度对 IHRE 算法性能 的影响,并将其与 HRE, MRE 进行比较,3种方法的参 数保持相同,而 MRE 的尺度因子设置为8。

3种方法的分析结果如图2所示。

由图 2 可以发现:1) 对于不同长度的两种噪声, 其 IHRE 曲线基本重合,且能够较明显地区分两种噪 声,说明样本长度对 IHRE 的影响较小,因此,笔者设 置 *N* = 2 048;2) 对比图 2(a)、图 2(b) 和图 2(c) 可以 发现,在分析同一长度的噪声信号时,IHRE 的熵值曲



图 2 不同长度 *N* 下 IHRE, HRE 和 MRE 对两种噪声 的分析结果

Fig. 2 Analysis results of IHRE, HRE and MRE for two kinds of noise at different lengths N

线具有最小的标准差,证明改进的层次分析方法在分 析稳定性方面优于层次分析和粗粒化分析;3)IHRE 在分析噪声信号时,1/f噪声的熵曲线一直呈现波动, 这表明1/f噪声在高频时也具有较大的复杂度(与理 论一致);而1/f噪声的MRE曲线呈现下降的趋势,表 明1/f噪声的复杂度随着尺度的增加而减小(与理论 不一致),验证了IHRE 方法的有效性。

2.2 故障诊断策略

为了证明基于 IHRE 方法在分析非线性数据中的有效性和优越性,笔者提出了一种基于 IHRE 和 WOA-ELM 的滚动轴承故障诊断策略。该策略的详细步骤如下:

1) 假定有 *m* 种不同的滚动轴承故障数据,将其等 分为 *n* 个样本,对全部样本进行 IHRE 故障特征提取, 选择 8 个尺度的 IHRE 值作为故障特征向量;

2)从不同工况样本的特征向量中随机抽取 j 个样 本构造训练集,其余构造测试集;

3) 对基于 WOA-ELM 构建的多类别分类器进行训练,得到参数最优的分类模型;

4) 对测试数据进行分类, 根据分类器的输出标签 来判断滚动轴承的健康状态。

3 实验验证

3.1 数据集介绍

笔者采用东南大学数据集进行基于 IHRE 和 WOA-ELM 的滚动轴承故障诊断算法的性能分析。该数据集由齿轮箱数据集和滚动轴承数据集组成。

笔者采用动力传动系统模拟器进行数据集的采 集。实验装置如图3所示。



图 3 实验装置 Fig. 3 experimental device

该装置的主要结构包含电动机、制动器、控制器模 块和行星齿轮箱、平行齿轮箱。笔者利用布置在驱动 电机、行星齿轮箱和平行齿轮箱表面的振动传感器,以 5 120 Hz 的频率收集振动信号,模拟器的转速和负载 配置分别为 20 Hz/0 V 和 30 Hz/2 V,笔者选择 30 Hz/ 2 V下的滚动轴承数据进行实验,该数据包含 5 种不同 的工况,分为 1 种健康状态和 4 种故障状态。

滚动轴承故障数据集的描述如表1所示。

笔者将每种故障类型的数据选择 60 组长度为 2 048的样本(其中,20 组样本用于构建训练集,剩余 40 组样本作为测试集)。因此,总共有 100 个训练样 本,200 个测试样本。

表1 滚动轴承故障数据集描述

Table 1	Rolling	bearing	failure	data	set	description
---------	---------	---------	---------	------	-----	-------------

故障描述	缩写	训练/测试样 本数量	分类 标签
正常的轴承	F1	20/40	1
滚动体存在裂纹	F2	20/40	2
内圈存在裂纹	F3	20/40	3
外圈存在裂纹	F4	20/40	4
内圈和外圈存在裂纹	F5	20/40	5

3.2 实验分析

为了获得能够反映滚动轴承故障本质的故障特征,笔者利用 IHRE 方法对振动信号进行分析,所提取的故障特征如图 4 所示。



由图 4 可以发现: IHRE 对样本有一定的区分效 果,在部分尺度上能够较好地区分故障,但仍然需要进 一步验证其性能。

为了评估上述模型的性能,并分析滚动轴承样本的损伤状态、完成故障的识别,笔者将基于 IHRE 方法 提取的故障特征输入至 WOA-ELM 分类器进行识别。

首先,笔者采用 100 组样本对 WOA-ELM 分类器 进行训练,获得参数最优的分类器;随后将 200 组样本 输入至训练完备的分类器,进行测试,以识别故障类 型。其中,WOA 的种群规模设置为 20,迭代次数设置 为 100。

IHRE 方法的 WOA-ELM 识别结果如图 5 所示。

随后,为了进一步评估 IHRE 方法的优越性,笔者 将由改进层次样本熵(improved hierarchical sample entropy,IHSE)、HRE 和 MRE 提取的故障特征,分别输 入至 WOA-ELM 分类器,进行故障类别的识别,并统计 了各个方法在特征提取中所耗费的时间。

4种方法的详细故障识别结果如表2所示。



图 5 IHRE 方法的 WOA-ELM 混淆矩阵

Fig. 5 WOA-ELM confusion matrix for IHRE method

表 2 4 种故障诊断方法的详细识别结果

 Table 2
 Detailed identification results of four fault diagnosis methods

故障诊断方法	识别准确率/%	特征提取时间/s
IHRE + WOA-ELM	100	681.41
IHSE + WOA-ELM	97	376.08
MRE + WOA-ELM	61.5	99.55
HRE + WOA-ELM	70	70.25

结合图 5 和表 2 可以发现: IHRE + WOE-ELM 方 法的识别准确率为 100%, 能够准确地识别滚动轴承 的故障类型。

横向来看,基于 RE 的特征提取方法(IHRE)优于 基于 SE 的特征提取方法(IHSE),这表明 RE 方法的 性能优于 SE,这与已有的结论一致。

从纵向来看,改进的层次分析优于传统的层次分 析,而传统的层次分析优于粗粒化处理,这与之前的理 论分析一致(这是因为层次分析考虑了信号的高频特 征信息,在特征提取上较粗粒处理更加全面。而改进 的层次分析由于采用滑动的平均处理,相较于传统的 层次分析更加精细,因此 IHRE 的准确率更优)。

最后,从效率方面来看,IHRE 方法的效率最差, 需要 681.41 s 来提取故障特征;HRE 方法的效率最 高,只需要 70.25 s,但由于 IHRE 方法的识别准确率最 高,因此,综合来看 IHRE 是有效的。

随后,为了验证4种方法在实际工况下的抗干扰 性能,笔者在相同条件下重复进行50次分类实验,以 观察4种方法的平均分类准确率。

采用4种方法分别进行50次实验,所得到的结果 如表3所示。

从表3可以发现:IHRE 方法的平均准确率达到了 99.82%,高于其他4种方法,证明了 IHRE 方法具有 极强的稳定性,能够保证每次的分类结果都是可靠的; IHSE 方法的平均识别准确率也达到了 97.99%,也具

表3 4 种方法 50 次实验的详细结果

Table 3 Detailed results of 50 experiments with four methods

一七次	诊断准确率/%			
刀伍	最大	最小	平均	
IHRE	100	99.5	99.82	
IHSE	99.5	94.5	97.99	
MRE	60	48.5	52.93	
HRE	71.5	56.5	66.13	

有很强的故障诊断性能,但其最小准确率只有94.5%, 证明其性能不是非常稳定,容易出现错误识别的结果; HRE 和 MRE 的识别结果非常差,平均识别准确率只有 66.13%和52.93%,无法保证故障的准确识别,因此可 以说明 HRE 和 MRE 方法不适用于该数据的故障识别。

总体而言, IHRE 和 IHSE 方法都具有优异的性能, 而 IHRE 方法在稳定性方面略优于 IHSE。

为了进一步验证 IHRE 和 IHSE 方法的性能,笔者 将不同数量的故障特征依次输入至 WOA-ELM 分类器 中进行故障识别,得到了不同特征数量时的分类准确 率结果,如图 6 所示。





从图 6 可以发现: IHRE 准确率曲线一直在 IHSE 曲线的上方,证明在输入不同数量的特征时, IHRE 的 准确率均高于 IHSE 方法;在输入第 5 个特征时, IHRE 方法已经能够取得 100% 的识别准确率,这证明 IHRE 方法可以在仅需少量特征的情况下准确识别滚动轴承 的故障,故 IHRE 优于 IHSE 方法。

最后,为了验证 WOA-ELM 的性能,笔者利用粒子 群优化的极限学习机(particle swarm optimization extreme learning machine, PSO-ELM)、蝙蝠算法优化的 极限学习机(bat algorithm-extreme learning machine, BA-ELM)和遗传算法优化的极限学习机(genetic algorithm-extreme learning machine, GA-ELM)进行对 比,将 IHRE 故障特征输入至这4种分类器进行识别, 并统计分类的时间,得到不同分类器的故障识别结果, 如表4所示。

表4 不同分类器的故障识别结果

Table 4 Fault identification results of different classifiers

分类模型	分类准确率/%	分类时间/s
WOA-ELM	100	0.63
PSO-ELM	99.5	0.65
BA-ELM	100	0.73
GA-ELM	99	0.97

由表4可以发现:WOA-ELM和BA-ELM都实现了100%的分类准确率,但WOA-ELM的效率更高;同时,PSO-ELM和GA-ELM的准确率均低于WOA-ELM分类器,且分类时间也多于WOA-ELM。

由此可见,WOA-ELM 不仅具有较好的泛化性,而 且还具有较高的分类效率。

4 结束语

由于传统的多尺度熵特征提取方法无法提取信号 的高频故障特征,造成特征提取不够完整,故障识别准 确率也较低。为此,笔者提出了一种基于 IHRE 和 WOA-ELM 的滚动轴承故障诊断策略,并利用东南大 学滚动轴承数据进行了实验和分析,验证了该故障诊 断策略的有效性和优越性。

研究结论如下:

1) IHRE 方法避免了 MRE 方法无法分析信号高频分量的缺陷,同时优化了 HRE 方法依赖数据长度的问题,其分析更加全面和充分,更适合于提取滚动轴承的故障特征;

2) 与常见的 GA-ELM、PSO-ELM 和 BA-ELM 相比, WOA-ELM 分类器在识别精度和效率方面更具有优势;

3) 在故障诊断实验中, IHRE + WOA-ELM 的故障 诊断方法取得了 100% 的识别准确率和 99.82% 的平 均准确率,均优于对应的 3 种对比方法;同时, IHRE 方 法仅需 5 个特征即可实现故障的准确识别,性能优于 IHSE 方法。

在后续的工作中,笔者将针对极差熵的快速计算 开展研究,以进一步提高 IHRE 的特征提取效率。

参考文献(References):

[1] 袁建明,刘 宇,胡志辉,等. 基于 InMPE 和 MFO-SVM 的 变负载滚动轴承故障诊断[J]. 机电工程,2023,40(8): 1185-1193.
YUAN Jian-ming, LIU Yu, HU Zhi-hui, et al. Fault diagnosis of rolling bearings experiencing variable loads based on InMPE and MFO-SVM[J]. Journal of Mechanical

& Electrical Engineering, 2023, 40(8):1185-1193.

- [2] 郑近德,陈 焱,童靳于,等.精细广义复合多元多尺度反向散布熵及其在滚动轴承故障诊断中的应用[J].中国机械工程,2023,34(11):1315-1325.
 ZHENG Jin-de, CHEN Yan, TONG Jin-yu, et al. Refined generalized composite multi-variate multi-scale reverse dispersion entropy and its application in rolling bearing fault diagnosis [J]. China Mechanical Engineering, 2023, 34
- (11):1315-1325.
 [3] LI Yong-bo, WANG Xian-zhi, LIU Zhen-bao, et al. The entropy algorithm and its variants in the fault diagnosis of rotating machinery: a review [J]. IEEE. Access, 2018, 6 (11):66723-66741.
- [4] 李卫民,马继召,雷晓柱.基于近似熵与支持向量机的异步电机故障诊断研究[J].机床与液压,2021,49(5):173-176,155.

LI Wei-min, MA Ji-zhao, LEI Xiao-zhu. Research on fault diagnosis for asynchronous motor based on approximate entropy and support vector machine [J]. Machine Tool & Hydraulics,2021,49(5):173-176,155.

[5] 邹龙庆,陈桂娟,邢俊杰,等.基于 LMD 样本熵与 SVM 的 往复压缩机故障诊断方法[J].噪声与振动控制,2014,34 (6):174-177.

ZOU Long-qing, CHEN Gui-juan, XING Jun-jie, et al. Fault diagnosis method based on LMD sample entropy and SVM for reciprocating compressors [J]. Noise and Vibration Control, 2014, 34(6):174-177.

- [6] ZHANG Xiao-yuan, LIANG Yi-tao, ZHOU Jian-zhong, et al. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM[J]. Measurement, 2015, 69(6):164-179.
- [7] 姜万录,赵亚鹏,张淑清,等.精细复合多尺度波动散布熵 在液压泵故障诊断中的应用[J].振动与冲击,2022,41
 (8):7-16.

JIANG Wan-lu, ZHAO Ya-peng, ZHANG Shu-qing, et al. Application of refined composite multiscale fluctuation dispersion entropy in hydraulic pumps fault diagnosis [J]. Journal of Vibration and Shock, 2022, 41(8):7-16.

- [8] OMIDVARNIA A, MESBAH M, PEDERSEN M, et al. Range entropy: a bridge between signal complexity and selfsimilarity[J]. Entropy, 2018, 20(12):962.
- [9] 李富国,王俊元,武增荣,等.基于 MRE 与特征类的轴承 故障诊断方法[J].制造技术与机床,2022,71(6):50-54.
 LI Fu-guo, WANG Jun-yuan, WU Zeng-rong, et al. Bearing fault diagnosis method based on MRE and eigen class[J]. Manufacturing Technology & Machine Tool,2022, 71(6):50-54.
- ZHENG Li-kang, HE Ye, CHEN Xiao-an. Research on a fault diagnosis method for rolling bearing based on improved multiscale range entropy and hierarchical prototype [J].
 Measurement Science and Technology, 2021, 32

(9):095003.

- [11] 周 杰.基于 CYCBD 与 HRE 的滚动轴承故障智能诊断 方法研究[D].太原:中北大学机械工程学院,2020.
 ZHOU Jie. Research on Intelligent Fault Diagnosis Method of Rolling Bearing Based on CYCBD and HRE [D].
 Taiyuan: North University of China, School of Mechanical Engineering,2020.
- [12] 章 涛,陈勇旗,廖紫洋,等. 一种北方苍鹰参数优化的 VMD-MRE 轴承故障诊断方法[J/OL]. 机械科学与技术:1-8[2023-05-24]. https://doi.org/10.13433/j. cnki. 1003-8728.20230226.
 ZHANG Tao, CHEN Yong-qi, LIAO Zi-yang, et al. A VMD-MRE bearing fault diagnosis method for Northern Goshawk parameter optimization [J/OL]. Mechanical Science and Technology for Aerospace Engineering: 1-8 [2023-05-24]. https://doi.org/10.13433/j. cnki. 1003-8728.20230226.
- [13] WANG Xian-zhi, SI Shu-bin, LI Yong-bo. Hierarchical diversity entropy for the early fault diagnosis of rolling bearing [J]. Nonlinear Dynamics, 2022, 108 (2): 1447-1462.
- [14] 柏世兵,林金亮,杨玉华.改进层次全局模糊熵和 MCFS 在滚动轴承损伤识别中的应用[J/OL].机电工程:1-9
 [2023-03-10]. http://kns. cnki. net/kcms/detail/33.
 1088. TH. 20230210.1104.002. html
 BAI Shi-bing, LIN Jin-liang, YANG Yu-hua. Application of improved hierarchical global fuzzy entropy and MCFS in damage identification of rolling bearing [J]. Journal of Mechanical & Electrical Engineering: 1-9 [2023-03-10].
 http://kns. cnki. net/kcms/detail/33. 1088. TH.
 20230210.1104.002. html
- [15] 张玉学,潘宏侠.基于 LMD 近似熵和 PSO-ELM 的齿轮 箱故障诊断[J]. 机械传动,2017,41(8):109-113.
 ZHANG Yu-xue, PAN Hong-xia. Gearbox fault diagnosis based on LMD approximate entropy and PSO-ELM [J].
 Journal of Mechanical Transmission, 2017, 41 (8): 109-113.
- [16] 何坤敏,王 霄,杨 靖,等.基于 RF 特征优选和 WOA-ELM 的风电齿轮箱故障诊断[J].电子测量技术,2023,46(5):57-64.
 HE Kun-min, WANG Xiao, YANG Jing, et al. Fault diagnosis of wind turbine gearbox based on RF feature optimization and WOA-ELM[J]. Electronic measurement technology,2023,46(5):57-64.
- [17] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95 (1): 51-67.
- [18] SONG En-zhe, KE Yun, YAO Chong, et al. Fault diagnosis method for high-pressure common rail injector based on IFOA-VMD and hierarchical dispersion entropy [J]. Entropy,2019,21(10):923.

本文引用格式:

李娜娜,万 中. 基于改进层次极差熵和 WOA-ELM 的滚动轴承故障识别[J]. 机电工程,2023,40(11):1752-1759.

LI Nana, WAN Zhong. Rolling bearing fault identification based on improved hierarchical range entropy and WOA-ELM[J]. Journal of Mechanical & Electrical Engineering, 2023,40(11):1752-1759. 《机电工程》杂志:http://www.meem.com.cn