

基于改进果蝇算法优化 WKELM 的医疗滚动轴承故障诊断技术研究

何 成¹, 刘长春², 吴 涛², 武 洋², 徐 颖², 陈 童³

(1. 上海第二工业大学 智能制造与控制工程学院, 上海 201209;

2. 上海第二工业大学 环境与材料工程学院, 上海 201209; 3. 上海市第一人民医院, 上海 200080)

摘要: 针对传统小波核极限学习机 (Extreme Learning Machine, ELM) 应用于医疗滚动轴承故障诊断中识别精度不高且训练速度慢的一系列问题的出现, 并针对性的想出一种更好地对滚动转轴发生的故障进行识别的办法, 通过对小波核极限学习机算法进行改进的方法; 该方法运用改进果蝇算法 (LGMS-Fruit-flying Optimization Algorithm, LGMS-FOA) 优化小波核极限学习机中的正则化系数和小波核函数中的参数; 采用的方法是变分模态分解 (Variational Mode Decomposition, VMD), 通过这种方法能够对滚动轴承的故障信号分解为含有故障信息的各模态分量从而提取到故障特征; 通过与其他三种算法的实验结果对比证明, 基于 LGMS-FOA-WKELM 的滚动轴承故障诊断方法的识别精度更高且训练时间更短。

关键词: 医疗滚动轴承; 故障诊断; VMD 分解; LGMS-FOA-WKELM 算法

Rolling Bearings Fault diagnosis research based on WKELM Optimized by Improved FOA Algorithm

He Cheng¹, Liu Changchun², Wu Tao², Wu Yang², Xu Ying², Chen Tong³

(1. Shanghai Polytechnic University, Shanghai 201209, China;

2. Shanghai Polytechnic University, Shanghai 201209, China; 3. Shanghai General Hospital, Shanghai 200080, China)

Abstract: The regularization coefficient and the parameters in the wavelet kernel function of the rolling bearing fault diagnosis based on the extreme learning machine will affect the classification effect of WKELM. A fault identification method based on improved FOA algorithm to optimize WKELM parameters is proposed. The method uses VMD to decompose the fault signal of the rolling bearing to obtain the modal components containing the fault information, and uses SVD to obtain each modal singular value as the feature vector. The LGMS improved FOA algorithm was introduced to optimize the relevant parameters of WKELM, and the optimal rolling bearing fault diagnosis classifier was constructed. The experimental comparison results show that the LGMS-FOA-WKELM method not only has high recognition accuracy, but also has shorter training time and stronger stability.

Keywords: medical rolling bearing; fault diagnosis; VMD decomposition; LGMS-FOA-WKELM algorithm

0 引言

现代医疗行业都配有相当数量的精密滚动轴承部件。随着医疗水平的不断提高, 医疗器械的复杂性越来越高, 系统越复杂, 故障的概率就越高。如果医疗器械出现故障并停止维护, 则会影响到患者, 甚至导致严重的医疗事故。在医疗行业中, 呼吸机、心脏血泵等均含有轴承, 在长期的工作中会磨损、老化, 如果不及时诊断出轴承故障会影响患者的治疗过程, 更有可能引起严重的医疗事故。为了解决这些问题, 生命支持仪器需要对关键部件进行实时监控, 及早发现故障, 合理制定维护计划^[1-2]。

传统的基于极限学习机 (Extreme Learning Machine, ELM) 的滚动轴承故障诊断方法是随机选择极限学习机中

的正则化系数, 这会对极限学习机的分类精度产生很大的负面影响, 使得分类精度会有所降低, 因此提出 LGMS-FOA (a linear generation mechanism of candidate solution-LGMS) 算法来优化 WKELM 参数的滚动轴承故障诊断方法^[3-5]。在故障特征提取方面, 小波包变换、经验模态分解等方法已被广泛应用于故障特征提取中, 但该方法会造成数据冗余, 进而增加了 ELM 的训练时间, 虽然其自适应能力强, 但是存在着模态混叠的缺陷, 因此, 在滚动轴承故障特征提取过程中, 合适的故障特征提取方法极为重要, 本文通过运用两种途径来获得故障的特征信息, 而且这些故障特征信息都是具有多维的特征信息, 这两种途径分别叫做变分模态分解 (variational mode decomposition, VMD) 和奇异值方法 (singular value decomposition, SVD)^[6]。

1 变分模态分解的方法与核极限学习机原理的运用

1.1 通过运用变分模态分解的办法提取滚动轴承相关特征
对于变分模态分解, 其最基本的含义就是通过一种新

收稿日期:2019-01-17; 修回日期:2019-03-18。

基金项目:上海第二工业大学研究生项目基金(EGD18YJ0003)。

作者简介:何 成(1976-),男,江苏盐城人,博士研究生,副教授,主要从事故障诊断与寿命预测方向的研究。

信号采用估计的办法, 进而优化了受约束函数, 在这个方法中, 其关键性作用的就是能够构造并求解出变分相关的问题。变分问题的构造有如下几步^[7]:

1) 对所得到的各个模态函数 $\mu_k(t)$ 运用 Hilbert 矩阵进行变换;

2) 利用前面变换得出的解析信号进行分析, 并得到与之相关的单边频谱;

3) 通过对上一步中每一个解析信号的中心频率进行估计并混合, 从而方便将每一种模态的频谱能够调制接近于基带;

4) 对上述过程中的每个模式的解析信号进行调制过后, 并估计其宽带;

最后得出相关的受约束的变分问题的数学函数表达式为:

$$\begin{cases} \min_{\{\mu_k\}, \{\omega_k\}} \sum_{k=1}^K \left\| \delta(t) \left[\left(\delta(t) + \frac{j}{\pi t} \right) \mu_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ s. t. \sum_{k=1}^K \mu_k = f \end{cases} \quad (1)$$

在表达式中: K 表示是函数个数, 其中函数即本征模态函数, $\delta(t)$ 表示为相应的脉冲函数, ω_k 表示是中心频率值, μ_k 是模态函数表达式, $\mu_k(t)$ 是第 K 个 IMF 分量的表达式。

1.2 小波核极限学习机

行泛化的能力就更强, 它的输出目标是 minimized 输出权值和最小化输出误差。根据在优化理论中, KKT (Karush-Kuhn-Tucker) 条件是非线性规划最佳解的必要条件。KKT 条件将 Lagrange 乘数法 (Lagrange multipliers) 中的等式约束优化问题推广至不等式约束, 得到的目标函数为^[8]:

$$\min L_{ELM} = \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \gamma_i^2 - \sum_{i=1}^N \alpha_i (h(x_i)\beta - t_i + \gamma_i) \quad (2)$$

式中, 输出权值用 β 来表示, 训练样本用 χ_i 来表示, 目标输出值用 t_i 来表示, $h(x_i)$ 在函数中表示处于隐藏层中的核映射, C 在函数中表示为正则化系数, γ_i 在函数中表示为对对象的训练误差, α_i 在函数中则表示为 Lagrange 算子。

极限学习机的输出函数可以用下式来表示^[9]:

$$f(x) = h(x)\beta = h(x)H^T \left(\frac{I}{C} + HH^T \right)^{-1} T \quad (3)$$

在函数表达式中: 用 I 表示是一个单位矩阵, H 表示是在阴层的一个矩阵, 且是用于输出的矩阵, T 则表示是输出层的一个矩阵。

为了能够更进一步让极限学习机对分类能力得到提升, 对极限学习机引入核函数, 其矩阵的具体表达式为^[10]:

$$HH^T(i, j) = h(x_i) \times h(x_j) = K(x_i, x_j) \quad (4)$$

式中, $K(x_i, x_j)$ 表示核函数, $i, j \in (1, 2, \dots, N)$ 。

因此, 核极限学习机的输出函数表达式为:

$$f(x) = h(x)H^T \left(\frac{I}{C} + HH^T \right)^{-1} T = \begin{bmatrix} K(x, x_1) \\ \dots \\ K(x, x_N) \end{bmatrix} \left(\frac{I}{C} + \Omega \right)^{-1} T$$

极限学习机的核函数选用 Morlet 小波函数, 其具体的数学表达式为:

$$K(x, x') = \cos \left[a \frac{\|x_i - x'_i\|}{b} \right] \exp \left[-\frac{\|x_i - x'_i\|^2}{c} \right] \quad (6)$$

式中, a 为系数因子, b 为尺度因子, c 为平移因子。

2 FOA 算法的优化改进

2.1 FOA 算法分析

2.1.1 FOA 算法原理

FOA 是一种基于果蝇的食物发现行为来寻找全局优化的新方法。果蝇在视觉和嗅觉方面优于其他物种 (如图 1 所示)。果蝇的食物发现过程有两个步骤: 首先, 它通过使用嗅觉器官闻到食物来源并向该方向飞行; 然后, 在它接近食物位置后, 它还可以利用其敏感的视觉来寻找食物和果蝇的植绒位置并向该方向飞行^[11-12]。图 1 显示了果蝇群的食物发现迭代过程。

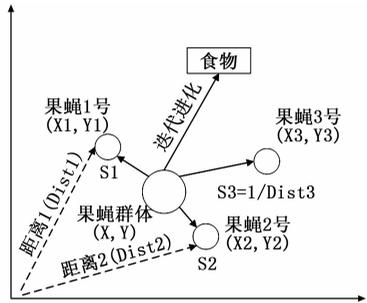


图 1 果蝇群寻找食物的迭代过程

基于果蝇群的食物发现特征, FOA 的整个过程描述如下。

步骤 1: 在 FOA 算法中, 对最大迭代次数、总群大小、对果蝇的位置范围、还有果蝇随机进行飞行的方向和飞行的距离等主要参数进行初始化;

步骤 2: 候选解决方案的非线性生成机制。

步骤 2.1: 最初的果蝇群位置如下:

$$\begin{aligned} x_{axis} &= \text{rand}(LR) \\ y_{axis} &= \text{rand}(LR) \end{aligned} \quad (7)$$

步骤 2.2: 单个果蝇使用嗅觉器官得出随机方向和距离, 以便找到食物:

$$\begin{aligned} x_i &= x_{axis} + \text{rand}(FR) \\ y_i &= y_{axis} + \text{rand}(FR) \end{aligned} \quad (8)$$

步骤 2.3: 计算食物位置到原点的距离:

$$Dist_i = \sqrt{x_i^2 + y_i^2} \quad (9)$$

步骤 2.4: 计算气味浓度判断值 S_i :

$$S_i = \frac{1}{Dist_i} = \frac{1}{\sqrt{(x_{axis} + \text{rand}(FR))^2 + (y_{axis} + \text{rand}(FR))^2}} \quad (10)$$

公式 (10) 称为 NGMS。

步骤 3: 通过输入气味浓度判断权值 S_i 到气味浓度判断方程来计算出每一个果蝇所处的位置所对应的气味浓度, 并定义为 $Smell_i$;

$$Smell_i = objective\ function(S_i) \quad (11)$$

步骤4: 找出果蝇群中具有最大气味浓度的果蝇:

$$[Smell\ best\ best\ index] = \max(Smell) \quad (12)$$

步骤5: 得到最大浓度值和 x , y 坐标。然后, 果蝇群通过视觉飞向该位置:

$$\begin{aligned} Smell\ best &= best\ smell, \\ x_{axis} &= x(best\ index), \\ y_{axis} &= y(best\ index) \end{aligned} \quad (13)$$

步骤6: 输入迭代优化并重复步骤2~5, 当气味浓度达到最大值或者迭代次数达到设定的最大迭代次数时, 循环停止。

2.1.2 FOA 算法存在的不足

1) 当域中存在负数时, FOA 无法解决优化问题, 因为在式(10)中 $S_i > 0$;

2) 当 x_{axis} 和 y_{axis} 的值固定时, 式(10)中的 S_i 不遵循均匀分布。由于 S_i 不遵循均匀分布, 因此无法在域中统一生成解; 也就是说, NGMS 不允许在域中统一执行搜索, 因此果蝇群失去了搜索全局优化的能力。这就是为什么 FOA 无法有效地解决复杂的优化问题;

3) 在式(10)中, 当 x 轴和 y 轴的值较大且 FR 的范围较小时, FR 的变化对 value 的值几乎没有影响; 因此 S_i 很容易陷入局部最优值;

2.2 LGMS-FOA 算法的参数优化

2.2.1 LGMS-FOA 算法步骤

为了克服上述缺点, 将 NGMS 替换为候选解(缩写为 LGMS)的新线性生成机制, 并提出基于 LGMS 的改进 FOA(缩写为 LGMS-FOA)。LGMS-FOA 的步骤如下。

步骤1: 进行初始化参数的操作。LGMS 的参数包含数量规模 ($sizepop'$)、搜索系数 (n)、初始权值 (ω_0) 以及权重系数 (α)。

步骤2: 候选解的线性生成机制:

步骤2.1: 最初的果蝇群位置:

$$x_{axis}' = n * rand(domain\ of\ definition) \quad (14)$$

步骤2.2: 给出随机方向和距离, 以便找到单个果蝇的食物:

$$\begin{aligned} x'_i &= x_{axis}' + \omega * rand(domain\ of\ definition) \\ \omega &= \omega_0 * \alpha^{gen} \end{aligned} \quad (15)$$

步骤2.3: 让气味浓度判断值 S'_i 等于 x'_i :

$$S'_i = x'_i = x_{axis}' + \omega * rand(domain\ of\ definition) \quad (16)$$

式(16)称为 LGMS。

步骤3: 通过输入气味浓度判断权值 S'_i 到气味浓度判断方程来计算每个果蝇所在位置的气味浓度 $Smell'_i$:

$$Smell'_i = objective\ function(S'_i) \quad (17)$$

步骤4: 找出果蝇群中具有最大气味浓度的果蝇:

$$[Smell\ best\ best\ index'] = \max(Smell') \quad (18)$$

步骤5: 保持最大浓度值和 x 坐标, 然后果蝇群通过视觉飞向该位置:

$$\begin{aligned} Smell\ best' &= best\ smell' \\ x'_{axis} &= x(best\ index') \end{aligned} \quad (19)$$

步骤6: 输入迭代优化并重复步骤2~5, 当气味浓度达到最大值或者迭代次数达到设定的最大迭代次数时, 循环停止。

2.2.2 LGMS-FOA 算法优势

1) 式(16)中的 S'_i 范围可以涵盖整个范围;

2) 当 χ'_{axis} 的值固定时, 在式(16)中的 S'_i 服从均匀分布; 因此 LGMS 可以允许在域中统一执行搜索, 果蝇群增强了其寻找全球最佳解决方案的能力;

3) 在 LGMS 中, 由于惯性权重比较大的有利于全局搜索, 而惯性权重比较小的有助于本地搜索, 所以引入了惯性权重来平衡全局搜索和本地搜索, LGMS-FOA 在运行时趋向于具有更高的全局可搜索性, 同时在运行结束时具有更多的局部搜索能力。

3 基于 LGMS-FOA 算法的参数优化

3.1 WKELM 参数选择

正则化参数 C 及小波核函数中的参数这些因素都能够使 WKELM 受一定的影响, 特别是在进行分类过程中的效果方面造成相应影响, 如果简单的对这些参数采用随机选择的办法进行, 就会使得 WKELM 在进行分类过程中的精度降低很多, 因而, 构造 WKELM 的参数优化模型如下所示:

$$\begin{cases} \max fitness = accuracy(C, a, b, c) \\ st: C \in (l_c, u_c) \\ a, b, c \in (l_{a,b,c}, u_{a,b,c}) \end{cases} \quad (20)$$

式中, 适应度值用 $fitness$ 来表示, 训练集的分类准确程度用 $accuracy$ 来表示, 惩罚因子 C 和核函数参数 a, b, c 的上限用 u_c 和 $u_{a,b,c}$ 分别表示, l_c 和 $l_{a,b,c}$ 分别为关于惩罚因子 C 和核函数参数 a, b, c 的上限。

在利用 WKELM 对模型进行优化的过程中, a, b, c 都表示为核函数参数, C 在模型中代表惩罚因子, 这些参数因子一直作为主要因素制约着 WKELM 分类精度。就 WKELM 参数优化而言就是通过一定规律找到一个最优化格式的参数与因子有关的组合 (C, a, b, c), 从而使得 WKELM 的精度达到更好的状态, 最终提高并使得 WKELM 的学习能力更为广泛。

3.2 LGMS-FOA 算法对 WKELM 的优化步骤

利用 LGMS-FOA 算法, 对 WKELM 的参数进行优化的具体步骤如下:

步骤1: 通过 VMD 的特性, 分解出由对轴承分析产生的相关故障信号, 并处理得出与之相对应的模态分量数据, 然后再运用 SVD 对前面的模态分量进行处理, 从而得出一系列具有特性的特征向量, 而且是具有多维特性的向量, 再运用归一化处理的办法, 对前面的向量进行归一化, 得出特征向量, 最后再把得到的那些特征向量进行分类, 一类取名为训练集, 另外一类取名为测试集。

步骤2: 起初, 对取值范围进行初始化操作, 即对

WKELM 参数 $[C, a, b, c]$ 的取值范围进行初始化, 并对 LGMS-FOA 算法中的一些相关参数进行设置。

步骤 3: 通过输入气味浓度判断权值 S'_i 到气味浓度判断方程来计算每个果蝇所在位置的气味浓度 $Smell'_i$ 。

步骤 4: 找出果蝇群中具有最大气味浓度的果蝇, 保持最大浓度值和 x 坐标, 然后果蝇群通过视觉飞向该位置。

步骤 5: 输入迭代优化以重复步骤 3-5 的实现, 在运算过程中, 发现测试气味的浓度低于先前迭代的气味浓度或者迭代的次数已经达到或者超出了之前所定好的最大值的时候, 此循环过程就会停止。

步骤 6: 选择气味浓度最高的果蝇位置会被用来作为 WKELM 参数, 随后其数据还会用来作为训练对象, 与此同时对测试样本也会进一步采取分类操作。

4 实验结果分析

4.1 医疗滚动轴承故障特征提取

特征提取是轴承故障分类过程中的核心问题。本文选用 VMD 对故障信号进行处理, 对得到的各模态分量进行奇异值分解 (SVD), 从而得到故障信号的特征向量。由于 VMD 的模态数 K 过大会出现过分解, 所以在本次实验中 K 设为 4。在对 VMD 进行分解之后会得到: 模态分量 4 个和与其相关的包络图, 见图 2-7, 对应故障特征为: 医疗滚动轴承内圈故障、医疗滚动轴承外圈故障、医疗滚动轴承滚动体故障。

1) 医疗滚动轴承内圈故障 VMD 分解波形

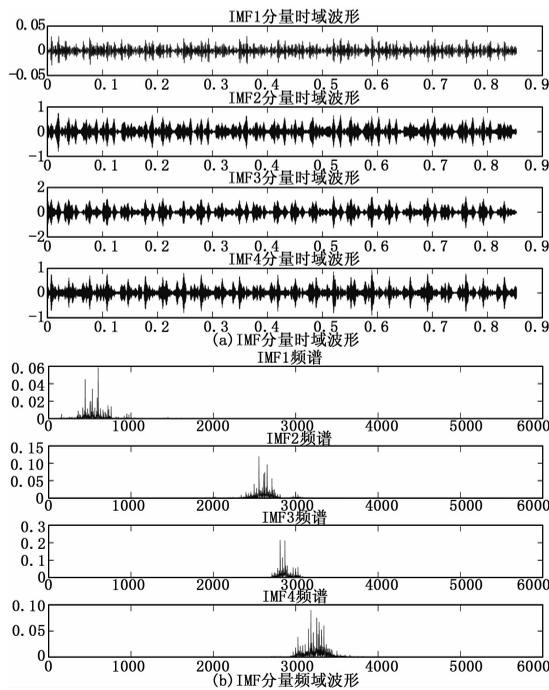


图 2 医疗滚动轴承内圈故障 VMD 分解

2) 医疗滚动轴承外圈故障 VMD 分解波形

3) 医疗滚动轴承滚动体故障 VMD 分解波形

观察图 3 可以得出, 用 VMD 分解来自内圈的故障信号, 发现有 3 个模态都存在故障信息; 观察图 5 可以得出,

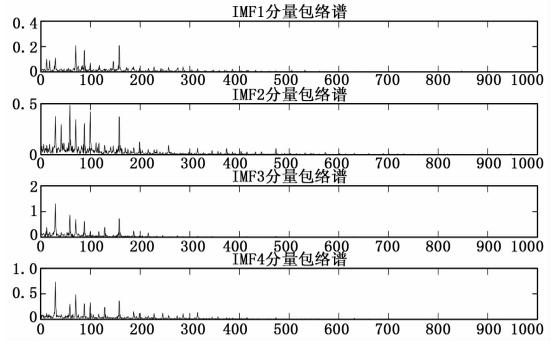


图 3 医疗滚动轴承内圈故障各模态包络谱

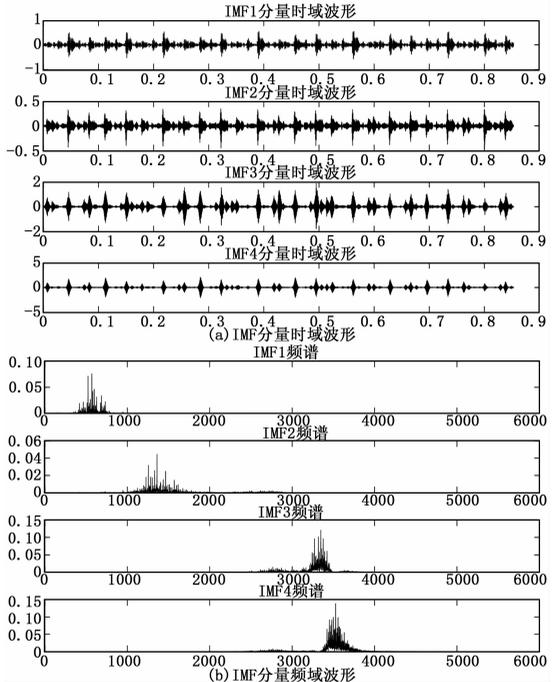


图 4 医疗滚动轴承外圈故障 VMD 分解

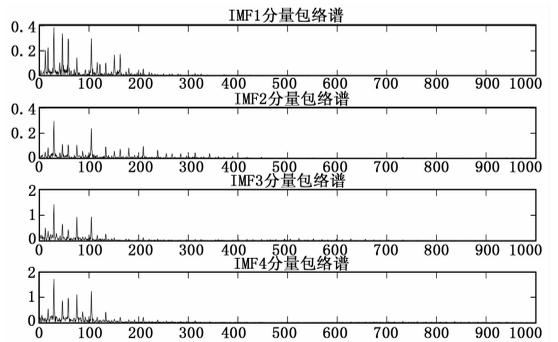


图 5 医疗滚动轴承外圈故障各模态包络谱

发现有 4 个模态都存在故障信息; 观察图 7 可以得出, 用 VMD 分解来自滚动体的故障信号, 发现有 3 个模态都存在故障信息。通过对故障信号进行 VMD 分解, 能够体现出故障信号中的局部特征; 对各模态分量进行奇异值分解 (SVD) 能够保留故障数据中的重要信息, 从而为故障的准确奠定了基础。

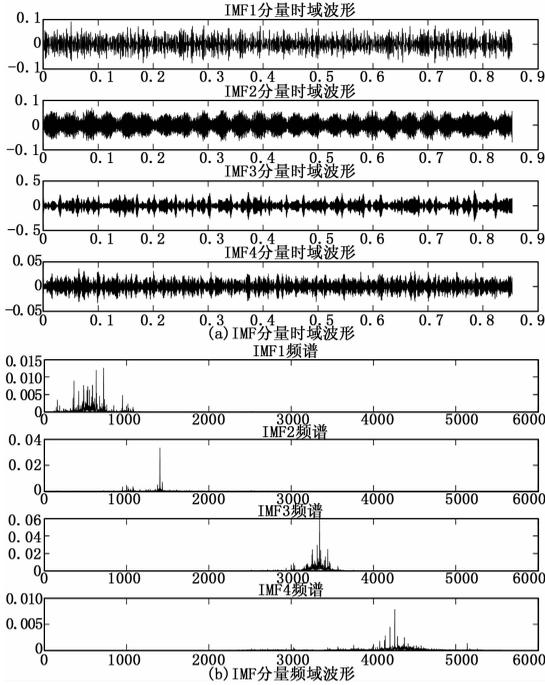


图6 医疗滚动轴承滚动体故障 VMD 分解

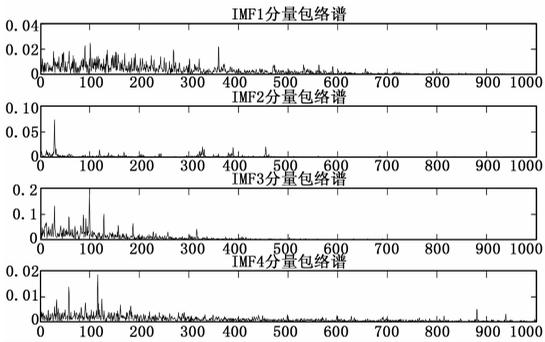


图7 医疗滚动轴承滚动体故障各模态包络谱

4.2 FOA 与 LGMS-FOA 的平均值与标准偏差

表1展示了FOA与LGMS-FOA的平均值与标准偏差,从表1中可以看出,当解决 f_{GP} , f_{SH} , f_{BR} , f_{RA} 和 f_{SP30} 时, LGMS-FOA的平均值更接近于理论上的最优值,并且LGMS-FOA具有比FOA更好的标准偏差。因此得出结论LGMS-FOA比FOA更有效,更稳定。

表1 FOA 与 LGMS-FOA 的平均值与标准偏差

f	Dimension	LGMS-FOA		FOA	
		Mean	Standard deviation	Mean	Standard deviation
f_{GP}	2	3.0010	1.8963e-09	524.1239	126.2348
f_{SH}	2	-166.369	3.2736e-11	-43.4531	16.1136
f_{BR}	2	0.3869	2.3552e-14	7.4274	4.4600
f_{RA}	2	-1.7179	0.0063	-1.6374	0.0165
f_{SP30}	30	9.2615e-09	1.2736e-09	5.8255e-06	1.5339e-06
f_{SP50}	50	2.8285e-04	1.263e-03	4.0453e-05	1.641e-06

4.3 基于 FOA-ELM、FOA-WKELM、LGMS-FOA-WKELM 的滚动轴承故障诊断结果与对比

用上述方法对原始数据进行特征提取后,得到 160×3 组数据。其中,选择 120×4 组数据作为训练样本, 40×4 组数据作为测试样本。在训练样本中,每种故障状态的数据各30组;在测试样本中,每种状态的数据各10组。设置轴承正常状态的标签为1,内圈故障的标签为2,外圈故障的标签为3,滚动体故障的标签为4。基于FOA-ELM、FOA-WKELM、LGMS-FOA-WKELM的滚动轴承故障诊断结果与对比如图8~10所示。

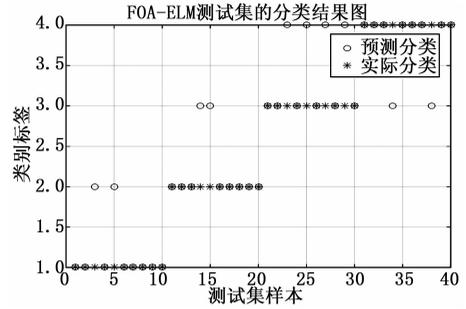


图8 FOA-ELM 的分类结果

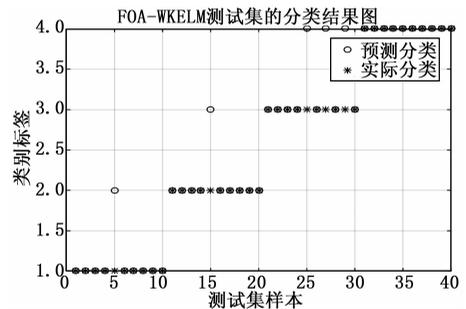


图9 FOA-WKELM 的分类结果

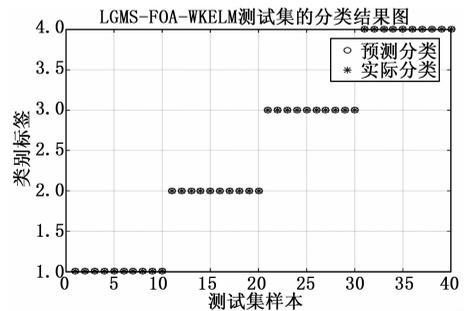


图10 LGMS-FOA-WKELM 的分类结果

表2 三种方法分类效果对比

故障诊断方法	平均分类精度(%)	平均运行时间(s)
FOA-ELM	75	25.4
FOA-WKELM	87.5	20.2
LGMS-FOA-WKELM	100	15.0

将图8~10的信息汇总归纳到表2,观察表2中的数据对比结果得出,在进行对同一个数据进行处理时,采用

LGMS-FOA-WKELM 这种方法得到的结果,其平均分类精度可以达到 100%,但是利用 FOA-ELM 这种方法,其平均分类精度只能达到 75%,采用 FOA-WKELM 方法时平均分类精度为 87.5%,两种方法的平均分类精度均低于 LGMS-FOA-WKELM 方法的平均分类精度,因而 LGMS-FOA-WKELM 方法明显优于其余两者。同时,由于利用 VMD 和 SVD 进行的特征提取相应的只能够得到 4 个相关的特征向量,并且 VMD 对噪声的抗干扰能力很强,就可以省去对噪声进行处理这一步,这样训练的时间也会相应缩短很多。因此,通过本文阐述的 LGMS-FOA-WKELM 方法用于滚动轴承对故障进行诊断,表明效果是最好的。

5 结论

针对医疗滚动轴承所出现故障分类问题,在本文中提出了对故障进行识别的方法,一种基于改进 FOA 算法优化 WKLEM 参数的故障识别法。这种方法利用 VMD 的特性,对在于滚动类型的轴承中存在的故障信号会进行一些分析和处理,并会最后得到与故障信息所对应的各模态分量,然后再结合 SVD 进行处理,得出相对应的各模态奇异值,把这些值用作特征向量。在原基础上加入 LGMS,对 FOA 算法进行改进,从而对 WKELM 进行相关参数的优化,最终使得其成为检测滚动轴承故障分离器的最佳方法。通过实验得出的对比结果表明,使用 LGMS-FOA-WKELM 这种方法的故障识别精度高,并且其使用的训练时间缩短了,稳定性也提高很多。为医疗滚动轴承的监测手段提供了一种新的参考,值得在医疗轴承监测中应用和推广。

参考文献:

[1] 张诗慧,种银保,肖晶晶,等.基于 LabVIEW 的医疗设备故障智能诊断系统 [J]. 仪表技术与传感器, 2018 (4): 98-103.

[2] 钱林,康敏,傅秀清,等.基于 VMD 的自适应形态学在轴制策略。通过构建一个测试装备可用性服务架构,目的是为研究靶场测试装备保障顶层设计与运行格局的强度关系奠定基础,并为测试装备保障一线人员在可用度目标下的保障体系最优控制决策,以及规划测试装备高效配置提供帮助。

[3] 韩朝帅,潘恩超,刘瑞起,等.基于云计算的测试装备保障系统架构研究 [J]. 计算机测量与控制, 2016, 24 (3): 103-105.

[4] 刘建军,朱元景.军事测试装备可用性指标评估模型 [J]. 四川兵工学报, 2012, 33 (7): 13-15.

[5] 陈超,王长春,刘军伟.测试装备体系结构描述方法 [J]. 火力与指挥控制, 2011, 36 (8): 1-4.

[6] 李渊,张鑫.测试装备维修保障知识管理系统构建研究 [J]. 测试装备学院学报, 2014, 25 (2): 98-101.

承故障诊断中的应用 [J]. 振动与冲击, 2017 (3): 227-233.

[3] Zhong L, Tang G. Preface, special issue on combinatorial optimization in health care. J Comb Optim, 2015, 30 (4): 839-840.

[4] Zhong L, Luo S, Wu L, et al. A two-stage approach for surgery scheduling [J]. J Comb Optim, 2014, 27 (3): 545-556.

[5] Park S, Lee J. Stochastic Opposition-Based Learning Using a Beta Distribution in Differential Evolution [J]. IEEE Transactions on Cybernetics (S2168-2267), 2016, 46 (10): 2184-2194.

[6] Tang J, Deng C, Guang G B. Extreme Learning Machine for Multilayer Perceptron [J]. IEEE Transactions on Neural Networks & Learning Systems (S2162-237X), 2016, 27 (4): 809-821.

[7] Mirjalili S, Mirjalili M, Lewis A. Grey Wolf Optimizer [J]. Advances in Engineering Software (S0965-9978), 2014, 69 (3): 46-61.

[8] Wen J, Gao H, Li S, et al. Fault Diagnosis of Ball Bearings using Synchrosqueezed Wavelet Transforms and SVM Prognostics and System Health Management Conference (PHM) [J]. USA: IEEE, 2015; 1-6.

[9] Dragomiretskiy K, Zosso D. Variational Mode Decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62 (3): 531-544.

[10] Huang G, Huang G B, Song S, et al. Trends in extreme learning machines: a review [J]. Neural Networks, 2015, 61 (C): 32.

[11] Feng G, Huang G B, Lin Q, et al. Error minimized extreme learning machine with growth of hidden nodes and incremental learning [J]. IEEE Transactions on Neural Networks, 2009, 20 (8): 1352-7.

[12] Liu N, Wang H. Ensemble Based Extreme Learning Machine [J]. IEEE Signal Processing Letters, 2010, 17 (8): 754-757.

[5] 战希臣,王传之.基于云计算的测试装备技术保障信息平台构建研究 [J]. 中国管理信息化, 2016, 19 (9): 176-178.

[6] Lindstrom J, Lofstrand M, Karlberg M. A development process for Functional Products; hardware, software, service support system and management of operation [J]. International journal of product development, 2012, 16 (4): 284-303.

[7] Lofstrand M, Backe B, Kyosti P, Lindstrom J. A model for predicting and monitoring industrial system availability [J]. International journal of product development, 2012, 16 (2): 140-157.

[8] Lofstrand M, Kyosti P, Reed S & Backe B. Evaluating availability of functional products through simulation [J]. Simulation modelling practice and theory, 2014, 47 (1): 196-209.

[9] Tzanev. A. Modeling and simulation of systems—a survey [J]. Cybernetics and Information technologies, 2013, 5: 156-159.

[10] Lindstrom J, Lofstrand M, Reed S & Alzghoul. A. Use of cloud services in functional products; availability implications [J]. Proc. CIRP, 2014, 16 (2): 368-372.