

控制与决策

Control and Decision

基于鲸鱼算法优化LSSVM的滚动轴承故障诊断

蔡赛男, 宋卫星, 班利明, 齐小刚, 汤润之

引用本文:

蔡赛男, 宋卫星, 班利明, 等. 基于鲸鱼算法优化LSSVM的滚动轴承故障诊断[J]. *控制与决策*, 2022, 37(1): 230–236.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.1147>

您可能感兴趣的其他文章

Articles you may be interested in

多策略融合的改进麻雀搜索算法及其应用

Improved sparrow search algorithm with multi-strategy integration and its application

控制与决策. 2022, 37(1): 87–96 <https://doi.org/10.13195/j.kzyjc.2021.0582>

嵌入Circle映射和逐维小孔成像反向学习的鲸鱼优化算法

Whale optimization algorithm for embedded Circle mapping and one-dimensional oppositional learning based small hole imaging

控制与决策. 2021, 36(5): 1173–1180 <https://doi.org/10.13195/j.kzyjc.2019.1362>

高超声速飞行器间歇故障改进自适应容错控制

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

基于平衡鲸鱼优化算法的无人车路径规划

Path planning of unmanned ground vehicle based on balanced whale optimization algorithm

控制与决策. 2021, 36(11): 2647–2655 <https://doi.org/10.13195/j.kzyjc.2020.0416>

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

基于鲸鱼算法优化LSSVM的滚动轴承故障诊断

蔡赛男^{1†}, 宋卫星², 班利明², 齐小刚¹, 汤润之²

(1. 西安电子科技大学 数学与统计学院, 西安 710126; 2. 中国人民解放军 32272 部队, 兰州 730030)

摘要: 针对轴承振动信号中的故障特征难以提取的问题, 提出一种基于改进的鲸鱼算法优化最小二乘支持向量机 (least square support vector machine, LSSVM) 的故障分类方法. 首先, 利用变分模态分解 (variational mode decomposition, VMD) 对原始信号进行分解, 使用中心频率法解决 VMD 中分解参数 K 值的选取问题; 其次, 计算每个 IMF 分量的多尺度排列熵值, 提取信号故障特征; 再次, 针对鲸鱼算法 (whale optimization algorithm, WOA) 收敛速度慢和精度低的问题, 引入冯诺依曼拓扑结构和自适应权重进行改进, 可以适当地调整全局搜索能力和局部搜索能力之间的平衡; 最后, 采用改进后的鲸鱼算法优化 LSSVM 核函数的参数和惩罚因子, 建立滚动轴承故障诊断模型, 并利用美国凯斯西储大学提供的轴承数据集进行仿真实验. 实验结果表明, 所提方法的故障分类性能更好, 准确率更高.

关键词: 滚动轴承; 故障诊断; 变分模态分解; 多尺度排列熵; 最小二乘支持向量机; 鲸鱼算法

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyj.2020.1147

开放科学(资源服务)标识码(OSID):



引用格式: 蔡赛男, 宋卫星, 班利明, 等. 基于鲸鱼算法优化 LSSVM 的滚动轴承故障诊断 [J]. 控制与决策, 2022, 37(1): 230-236.

Fault diagnosis method of rolling bearing based on LSSVM optimized by whale optimization algorithm

CAI Sai-nan^{1†}, SONG Wei-xing², BAN Li-ming², QI Xiao-gang¹, TANG Run-zhi²

(1. School of Mathematics and Statistics, Xidian University, Xi'an 710126, China; 2. Unit 32272 of the Chinese People's Liberation Army, Lanzhou 730030, China)

Abstract: Aiming at the problem that it is difficult to extract fault features from bearing vibration signals, a fault classification method based on the improved whale algorithm for optimizing the least square support vector machine (LSSVM) model is proposed. Firstly, the original signal is decomposed by variational modal decomposition, and the center frequency method is used to solve the problem of selecting the decomposition parameter K in VMD. Then, we calculate the multi-scale permutation entropy value of each IMF component and extract signal fault characteristics. Furthermore, aiming at the slow convergence speed and low accuracy of the whale optimization algorithm (WOA), the von-neumann and adaptive weights are introduced to improve the whale optimization algorithm, which can appropriately adjust the balance between global search ability and local search ability. Finally, by using an improved whale optimization algorithm, the penalty factor and kernel parameter of the LSSVM are optimized to establish the fault diagnosis model of rolling bearing, and the bearing data set provided by Case Western Reserve University is used to perform simulation experiments. The results show that the proposed method has better fault classification performance and higher accuracy.

Keywords: rolling bearing; fault diagnosis; variational modal decomposition; multi-scale permutation entropy; least squares support vector machine; whale optimization algorithm

0 引言

随着现代工业生产的发展, 机械设备的运行可靠性越来越受到重视, 诊断技术也得到了迅速的发展. 滚动轴承是广泛应用于旋转机械的关键部件, 其

运行状态直接影响设备的性能、运行效率和使用寿命. 如果能在故障发展的早期就找到故障的根源, 消除隐患, 预防重大事故的发生, 具有重大的经济和实用价值. 滚动轴承故障诊断可分为信号采集、特征

收稿日期: 2020-08-17; 录用日期: 2020-11-20.

责任编辑: 姜斌.

[†]通讯作者. E-mail: 771496511@qq.com.

提取和故障模式识别3个步骤. 滚动轴承在故障运行时,其故障信息往往是不确定的,振动信号也会出现非线性、非平稳的现象,因此如何从振动信号中提取出轴承的运行状态是滚动轴承故障诊断的关键^[1-2].

为了从噪声中提取信号,必须选择合适的信号处理技术. 信号处理可以通过快速傅里叶变换(fast Fourier transform, FFT)、短时傅里叶变换(short time Fourier transform, STFT)、小波变换(wavelet transform, WT)、希尔伯特黄变换(Hilbert Huang transform, HHT)和经验模态分解(empirical mode decomposition, EMD)等不同的方法进行^[3]. FFT只能用于平稳信号,不能用于瞬时和非平稳信号;STFT可以用于非平稳信号的分析,但对于随机信号,很难根据频率要求确定窗口大小;WT是比FFT更好的选择,但基函数的选择不当会影响分析. 除此之外,还可以通过固有模态函数(intrinsic mode functions, IMF)对信号进行诊断. 其中,较为常用的信号分解方法是经验模态分解(empirical mode decomposition, EMD),EMD是一种数据驱动的、自适应的非线性信号分解方法,非常适用于滚动轴承的非线性信号处理^[4]. 但是EMD属于递归模态分解,最主要的缺点之一是模态混叠问题. 为此, Yaguo等提出了集成经验模态分解方法(ensemble empirical mode decomposition, EEMD),该方法可以有效地解决EMD方法中的模态混叠问题^[5-6]. 然而,EEMD所添加的白噪声并不能被完全中和. 针对EMD和EEMD这两种方法存在的不足, Dragomiretskiy等^[7]提出一种新的自适应信号处理方法,即变分模态分解方法(variational mode decomposition, VMD). VMD属于非递归模态分解,是通过循环迭代求取约束变分问题的最优解来确定各模态分量的中心频率和带宽,可以有效地提取信号中各频率分量,解决了模态混叠和白噪声的问题. 但是,VMD最大的缺点是模态分解的个数 K 值和惩罚因子需要凭借经验提前设定,且 K 值的选取很大程度上影响了VMD的分解精度^[8].

利用VMD将振动信号分解为若干个IMFs后,需要解决的问题是如何从IMFs中提取故障特征. 一些学者提出采用非线性参数估计方法从振动信号中提取故障信号,即引入了熵理论. 多尺度排列熵(MPE)相比样本熵、近似熵和排列熵^[9-12]具有更强的鲁棒性,能够反映时间序列在多尺度下的复杂性信息变化,以便更加全面地提取故障特征.

从采集到的振动信号中计算出轴承的故障特征,形成特征数据集,并将其输入到多类分类器中,完

成轴承故障的识别. Cortes等^[13]提出的支持向量机(support vector machine, SVM)由于分类性能好,对样本数据输入要求低,已成功应用于回归分析^[14]、模式识别^[15]、轴承故障诊断^[16]等领域. 然而,原有的SVM分类器采用了求解二次规划问题的方法,计算量较大. 为了解决这个问题,许多方法被开发出来,例如SVM光分解算法^[17]、邻域算法^[17]、最小二乘支持向量机算法^[9]. 其中,LSSVM因其实现简单,分类和计算效率高等优点,得到广泛应用. 此外,为了提高LSSVM的分类性能,一些学者采用了量子粒子群(QPSO)算法优化LSSVM参数^[18],但是该算法仍然存在局部搜索能力弱、全局搜索能力一般、易出现早熟收敛等缺点^[19].

针对上述问题,本文提出一种基于改进鲸鱼算法优化LSSVM的故障诊断方法. 首先,通过VMD对故障信号进行分解,得到不同状态的模态分量;其次,计算包含重大故障信息的各IMF分量的多尺度排列熵值,构建特征向量数据集;再次,采用改进的鲸鱼算法对LSSVM参数进行优化,得到最佳参数组合;最后,将本文提出的方法应用于轴承故障诊断,验证其有效性.

1 理论基础

1.1 变分模态分解原理

原始信号经过VMD分解之后变成若干模态,固有模态函数被定义为调幅调频信号,如下所示:

$$u_k(t) = A_k(t) \cos \phi_k(t). \quad (1)$$

其中: $A_k(t)$ 是瞬时幅值; $\phi_k(t)$ 是相位,且 $\phi'_k(t) \geq 0$, $w_k(t) = \phi'_k(t)$ 是中心频率. 瞬时幅值和瞬时频率比相位变化缓慢. 经过VMD分解之后,每个模态都具有稀疏性,稀疏性由其所在谱域的带宽所决定. 为了估计每一个模态的带宽,首先对每一个模态进行希尔伯特黄变换,得到单边频谱;然后在各自的中心频率加入一个指数函数,将每个模态频谱转移到基带;最后通过计算解调信号的梯度平方范数估计带宽. 在每个模态分量之和等于信号的约束条件之下,变分约束问题为

$$\begin{aligned} \min_{\{u_k\}, \{w_k\}} \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-jw_k t} \right\|_2^2; \\ \text{s.t. } \sum_k u_k = f. \end{aligned} \quad (2)$$

其中: δ 表示Dirac分布,*表示卷积运算. 为了求取问题的最优解,引入二次惩罚项 α 和拉格朗日乘子 λ ,将变分约束问题转变为无约束变分问题. VMD通过乘子的交替方向法,将原问题的最优解转化为求增广

拉格朗日方程的鞍点,得到 K 个模态分量.

1.2 多尺度排列熵原理

排列熵算法是度量时间序列复杂性的一种方法,算法描述如下: 设一维时间序列 $X = \{x(1), x(2), \dots, x(n)\}$, 采用相空间重构延迟坐标法对 $x(i)$ 进行相空间重构, 对每个采样点取其连续的 m 个样点, 得到点 $x(i)$ 的 m 维空间的重构向量. 其中: m 是嵌入维数, l 是延迟时间. 然后对 $x(i)$ 的重构向量 $X(i)$ 各元素进行升序排列, 每一个 $x(i)$ 被映射到 $D(l) = \{j_1, j_2, \dots, j_m\}$, $l = 1, 2, \dots, k (k \leq m!)$, 计算每种情况出现的频率作为概率 P_1, P_2, \dots, P_k . 根据 Shannon 定理, 计算归一化后时间序列的排列熵

$$H_p(m) = - \sum_{j=1}^k p_j \ln p_j. \quad (3)$$

在实际的轴承故障诊断中, 传统的排列熵没有很好地考虑到时间序列中可能存在的不同时间尺度, 单一尺度包含的信息往往不够全面, 因此需要进行多尺度分析, 从多个时间尺度来分析问题, 找到更多隐藏的信息. 对于一维时间序列, 对其进行非重叠式粗粒化, 得到时间序列

$$y_j^\tau = \frac{1}{\tau} \sum_{i=1+(j-1)\tau}^{j\tau} x_i, \quad 1 \leq j \leq \left\lceil \frac{n}{\tau} \right\rceil, \quad (4)$$

其中 τ 表示尺度因子. 然后采用相空间重构延迟坐标法对 y_j^τ 进行相空间重构.

1.3 最小二乘支持向量机分类原理

LSSVM 是支持向量机的一个扩展, 它使用损失函数的线性最小二乘准则代替不等式约束. 基本原则是: 给定一组样本 $\{x_i, y_i\}_{i=1}^N$, $x_i \in R^n$ 是输入向量, $y_i \in R^n$ 是对应样本 i 的输出值. 通过一个非线性映射 φ , 将原始特征空间的数据映射到一个高维空间中, 如下所示:

$$f(x) = w^T \varphi(x) + b. \quad (5)$$

其中: w 表示权重向量, b 表示误差. 在原空间中, 具有等式约束的最小二乘支持向量机可表示为

$$\begin{aligned} \min J(w, e) &= \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2; \\ \text{s.t. } y_i &= w^T \varphi(x) + b + e_i, \quad i = 1, 2, \dots, n. \end{aligned} \quad (6)$$

其中: γ 是惩罚因子, e_i 是松弛变量. 拉格朗日函数 L 可以表示为

$$\begin{aligned} L(w, b, e, \alpha) &= \\ J(w, e) - \sum_{i=1}^N \alpha_i \{w^T \varphi(x_i) + b + e_i - y_i\}, \end{aligned} \quad (7)$$

其中 α_i 是拉格朗日乘子. 根据 The Karush-Kuhn-Tucker (KKT) 条件求解:

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^N \alpha_i \varphi(x_i), \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^N \alpha_i = 0, \\ \frac{\partial L}{\partial e_i} = 0 \Rightarrow \alpha_i = \gamma e_i, \\ \frac{\partial L}{\partial \alpha_i} = 0 \Rightarrow w^T \varphi(x_i) + b + e_i - y_i = 0, \\ i = 1, 2, \dots, N. \end{cases} \quad (8)$$

通过消去变量 w 和 e_i , 可将一个优化问题转化为线性求解问题

$$\begin{bmatrix} 0 & Q^T \\ Q & K + \frac{1}{\gamma} I \end{bmatrix} \cdot \begin{bmatrix} b \\ A \end{bmatrix} = \begin{bmatrix} 0 \\ Y \end{bmatrix}. \quad (9)$$

其中: $Q = [1, \dots, 1]^T$, $A = [\alpha_1, \dots, \alpha_N]^T$, $Y = [y_1, y_2, \dots, y_N]^T$. 根据 Mercer 条件, 核函数可以表示为

$$K(x_i, x_j) = \varphi(x_i)^T \varphi(x_j), \quad i, j = 1, 2, \dots, N. \quad (10)$$

LSSVM 模型可以表示为

$$f(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b. \quad (11)$$

Mercer 核函数有几种不同的类型, 例如 sigmoid、多项式和径向基函数. 径向基函数是核函数的常见选择, 需要设置的参数很少, 且总体性能很好. 因此, 本文选择 RBF 作为核函数:

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right). \quad (12)$$

因此, LSSVM 模型需要优化两个参数, 即高斯径向基核函数的参数 σ^2 和惩罚因子 γ .

2 基于鲸鱼优化算法的参数优化

2.1 鲸鱼优化算法

鲸鱼优化算法 (whale optimization algorithm, WOA) 是 Mirjalili 等^[20] 提出的一种新颖的自然启发元启发式优化算法, 该算法模拟了座头鲸的社会行为. 对于优化设计在搜索空间中的未知位置, 当前的最优候选解是目标猎物或接近 WOA 算法中的最优解, 定义了最好的搜索代理, 其他搜索代理将试图更新他们的位置, 以寻找最好的搜索代理. 位置方程如下:

$$D = |CX^*(t) - X(t)|, \quad (13)$$

$$X(t+1) = X^*(t) - AD, \quad (14)$$

$$A = 2ar - a, \tag{15}$$

$$C = 2r. \tag{16}$$

其中: t 为当前迭代次数, A 和 C 为系数向量, X^* 为得到的最优解的位置向量, X 为位置向量, r 为 $[0, 1]$ 之间的随机数, a 在迭代过程中从 2 线性减小到 0. 座头鲸在开发阶段捕杀猎物时, 假设有 50% 的可能性在缩小的环绕机制和螺旋模式之间进行选择, 以更新鲸鱼的位置, 方程如下:

$$X(t+1) = \begin{cases} X^*(t) - AD, & p < 0.5; \\ D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t), & p \geq 0.5. \end{cases} \tag{17}$$

其中: $D' = |X^*(t) - X(t)|$ 为第 i 条鲸鱼到猎物的距离, b 为定义对数螺旋形状的常数, l 为 $[-1, 1]$ 中的随机数.

事实上, 座头鲸在探索阶段会根据彼此的位置随机搜索. 因此, 使用大于 1 或小于 -1 的随机值迫使搜索代理远离参考鲸鱼. 与开发阶段不同, 在探索阶段根据随机选择的搜索代理而不是目前找到的最佳搜索代理来更新搜索代理的位置, 允许 WOA 算法执行全局搜索. 位置更新方程如下所示:

$$D = |CX_{rand}(t) - X(t)|, \tag{18}$$

$$X(t+1) = X_{rand}(t) - AD, \tag{19}$$

其中 X_{rand} 表示从当前种群中选取的随机位置向量. 将参数 a 从 2 降低到 0, 分别用于开发和探索. 当 $|A| > 1$ 时, A 被选为随机搜索代理; 当 $|A| < 1$ 时, A 被选为最优解用于更新搜索代理的位置. 根据 p 的值, WOA 可以在螺旋或圆周运动之间切换. 最后, 通过满足一个终止准则来终止 WOA 算法.

2.2 鲸鱼优化算法的改进

鲸鱼群中的个体会与其他个体进行交流, 分享其所拥有的信息, 即个体之间形成了一个邻域拓扑. 以往的研究采用了多种邻域拓扑结构, 不同的邻域拓扑结构具有不同的通信能力, 进一步提高了最终解决方案的性能. 4 种典型的邻域拓扑结构分别是全局关联、环状拓扑、星形拓扑和冯诺依曼拓扑^[21]. 其中: 前 3 种拓扑结构收敛速度很快, 但是容易陷入局部最优; 冯诺依曼形成了一个矩形晶格拓扑, 每一个个体都与 4 个邻居进行通信, 一个个体找到的最优解只会影响周围的 4 个邻居, 从而保持个体的多样性, 避免陷入早熟, 相对于其他 3 种拓扑结构, 收敛速度也得到了保证.

WOA 算法可以轻易解决单峰优化问题, 但是在

处理高峰多维度优化问题时, 可以清楚地发现得到的解并不是很好. 因此, 为了解决 WOA 算法收敛速度慢和精度低等问题, 本文使用冯诺依曼拓扑结构和自适应权重对鲸鱼算法进行改进. 通过分析鲸鱼的位置更新公式可以发现, 鲸鱼的位置更新受到全局最优解的影响, 会随着全局最优解的改变进行位置更新. 为了增强算法的局部搜索能力, 将自适应权重引入位移公式, 这样不仅能受到全局最优的引导, 还能在局部邻域与其他鲸鱼进行交流. 随着迭代的更新, 局部最优逐渐与全局最优重合, 还能加快收敛速度. 位置更新公式如下所示:

$$w = 1 - \exp(1 - t), \tag{20}$$

$$X^*(t) = w \times P_{best_i} + (1 - w) \times G. \tag{21}$$

其中: $w = 0.5$; P_{best_i} 表示座头鲸搜索代理 i 在冯诺依曼拓扑邻域 $L(i)$ 中的最优位置, 即邻域内各个鲸鱼搜索代理的适应度函数最小值对应个体的历史最优位置; G 表示全局最优位置.

2.3 IWOA 算法性能评估

为了验证 IWOA 算法的优越性, 本文使用 GA、PSO、WOA 和 IWOA 四种算法对测试函数进行仿真实验. 实验中选取单峰函数 Sphere 和多峰函数 Griewank, 其中单峰函数主要是为了验证算法的收敛速度, 而多峰函数主要是验证算法跳出局部最优的能力. 仿真实验参数设置如下: 种群个数为 30, 最大迭代次数为 500. 对 4 种算法分别运行 20 次后, 得到的测试函数结果如图 1 和图 2 所示.

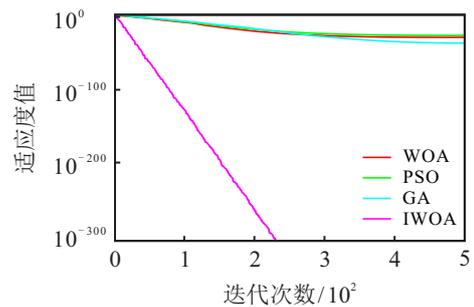


图 1 Sphere 函数优化曲线

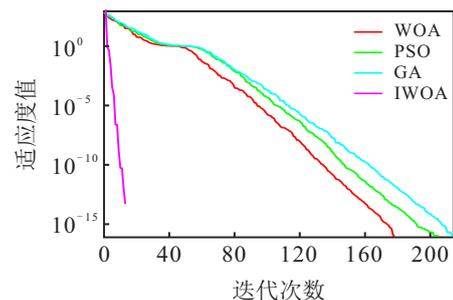


图 2 Griewank 函数优化曲线

如图1所示,在优化单峰 Sphere 函数时,IWOA 算法的收敛速度和收敛精度明显优于 GA、PSO 和 WOA 算法.如图2所示,在优化多峰 Griewank 函数时,IWOA 的收敛速度最快,且在迭代次数为20时就已经达到了最优适应度值为0,这说明 IWOA 算法的局部搜索和全局搜索能力更强.

2.4 鲸鱼优化算法步骤

基于 VMD 分解和 IWOA-LSSVM 的轴承故障诊断方法具体步骤如下:

step 1: 采集轴承4种状态下的原始信号,利用 VMD 进行信号分解,得到各 IMF 分量;

step 2: 运用多尺度排列熵提取信号特征,构造特征向量集,并将其分为训练样本和测试样本;

step 3: 初始化鲸鱼算法的种群规模、迭代次数和自适应权重值;

step 4: 利用初始化参数建立 LSSVM 模型;

step 5: 计算每头鲸鱼相应的适应度值,按照适应度大小进行排序,并选取 N 个鲸鱼作为下一代的种群;

step 6: 采用冯诺依曼拓扑结构进行邻域搜索,进行领域内的信息交流,找到邻域内最优的鲸鱼,按照式(17)~(21)进行位置更新;

step 7: 重复 step 5 和 step 6,直至达到最大迭代次数,输出适应度最佳的鲸鱼位置作为 LSSVM 的参数进行训练,然后对测试集进行故障分类.

3 实验与结果分析

3.1 数据选择

为了测试 IWOA-LSSVM 的性能,本文采用美国凯斯西储大学提供的轴承数据集进行实验.在数据集中,有驱动端轴承数据(本文只考虑驱动端轴承数据)和风扇端轴承数据.所有驱动端轴承型号为 SKF6205,振动数据由加速度计采集,采样频率为 12 kHz,失效直径分别为 0.007 英寸、0.014 英寸和 0.021 英寸.数据类型共有 4 种:正常状态(normal, N)、内圈故障(inner race fault, IR)、滚动体故障(ball fault, B)和外圈故障(outer race fault, OR).在实际故障诊断中,有时不仅要知道轴承的故障类型,还要知道故障的直径.为了测试 IWOA-LSSVM 模型诊断不同故障直径的性能,将分类标签设为 10 个,即健康轴承对应一个标签,其他 3 种故障类型分别对应 3 个标签,具体的类别标签如表 1 所示,其中每个标签取 30 个样本,每个样本含有 4096 个数据点.从每个标签的 30 个样本中随机选取 12 个作为训练样本,余下的 18 个作为测试样本.

表 1 轴承故障数据

轴承状态	类别标签	损伤直径 / 英寸
正常状态 (N)	1	0
	2	0.007
	3	0.014
内圈故障 (IR)	4	0.021
	5	0.007
	6	0.014
滚动体故障 (B)	7	0.021
	8	0.007
	9	0.014
外圈故障 (OR)	10	0.021

3.2 特征提取

首先,利用 VMD 对振动信号进行分解.值得注意的是,适当的分解数 K 对分解效果有很大的影响.如果 K 值选择不当,会导致过度分解或分解不足.本文主要是根据计算各模态的中心频率来确定 K 值.以滚动体故障为例进行分解:通过表 2 可以得出,当 $K = 5$ 时,第 4 和第 5 模态的中心频率值较为接近,由此推断出现模态混叠现象,因此确定 $K = 4$.

表 2 不同 K 值对应的模态中心频率

K	中心频率				
2	565	3347			
3	562	2847	3348		
4	109	1402	2850	3348	
5	105	1401	2825	3253	3409

计算 MPE 值时需要设置嵌入维数 m 、延迟时间 l 和尺度因子 τ .如果 m 值太小,则会降低 MPE 的突变检测性能;如果 m 值太大,则不能反映时间序列的小变化.通常 m 的取值范围设置为 3~7.延迟时间 l 对时间序列的分析结果影响不大,一般设置为 1.尺度因子 τ 的取值范围通常设置为 10 以上^[22].因此,本文设置 $m = 6, l = 1, \tau = 12$.然后计算 4 个 IMF 分量的 MPE 值,以损伤直径 0.007 为例,结果如图 3 所示.

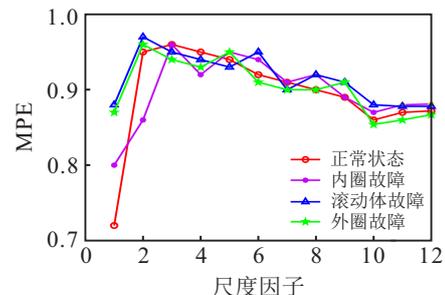


图 3 滚动轴承 4 种状态的 MPE

3.3 故障识别

通过将训练样本输入到 IWOA-LSSVM 中,得到了最佳参数 σ^2 为 97.54,惩罚因子 γ 为 632.36.得

到LSSVM模型的最佳参数之后,可以利用IWOA-LSSVM对从多尺度排列熵提取的特征向量进行识别.为了说明VMD进行信号分解的优势,图4和图5分别给出了VMD和EMD在4种状态下的故障诊断结果,具体的平均正确率如表3所示.

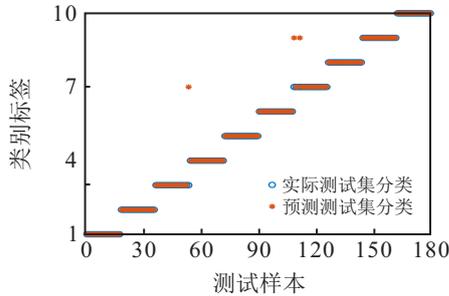


图4 VMD分解诊断结果

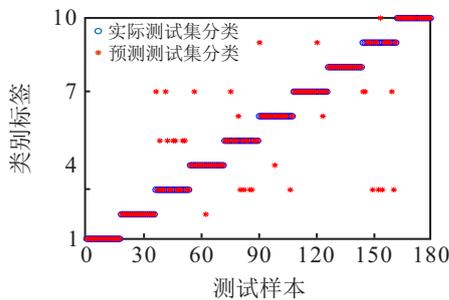


图5 EMD分解诊断结果

表3 基于VMD和EMD分解的故障诊断结果

轴承状态	VMD分解结果 平均正确率/%	EMD分解结果 平均正确率/%
正常状态(N)	100	100
内圈故障(IR)	98.1	81.5
滚动体故障(B)	96.3	79.6
外圈故障(OR)	100	85.2
平均值	98.6	86.6

由图4可以得到,有一个内圈故障被诊断为滚动体故障,有两个滚动体故障被诊断为外圈故障,诊断错误率较低,所以这种误判还是可以被接受的.同样,由图5可以看出,被误判的个数要比图4多很多.由表3可以看出,VMD和EMD这两种方法的故障识别准确率均在80%以上,其中VMD的识别准确率均在95%以上,比EMD的识别准确率高很多,在信号分解方面具有明显的优势,更适合于滚动轴承的故障诊断.

为了测试本文所提优化方法的性能,使用VMD处理原始信号,计算MPE值构成特征向量数据集,将IWOA-LSSVM与GA-LSSVM、PSO-LSSVM、WOA-LSSVM、PSO-SVM、GA-SVM和WOA-SVM进行对比实验,测试结果如表4所示.

表4 轴承故障诊断对比实验

分类器	说明	正确率/%
WOA-SVM	鲸鱼数量为20,最大迭代次数为200	90.10
GA-SVM	最大迭代次数是200,交叉概率是0.9,变异概率是0.1	91.70
PSO-SVM	种群个数为30,种群规模为300	95.00
WOA-LSSVM	维数为2,下界为0,上界为1000	92.67
GA-LSSVM	最大迭代次数是100,交叉概率是0.7,变异概率是0.05	94.71
PSO-LSSVM	最大迭代次数是100,最小权重0.5,最大权重0.9	91.00
IWOA-LSSVM	维数为2,下界为0,上界为1000	96.29

从表4可以看出,在使用WOA、GA、PSO优化SVM时,WOA没有明显的优势,故障诊断识别率相对较低.使用IWOA、GA、PSO算法优化的LSSVM模型时,IWOA在3种故障类型的诊断上优于后两者,说明使用IWOA算法在一定程度上提高了算法的性能.实验结果表明,IWOA-LSSVM算法在故障诊断中具有一定的优势.

4 结论

本文对旋转机械领域的滚动轴承故障诊断进行研究,提出了一种基于VMD-MPE和IWOA-LSSVM的滚动轴承故障诊断方法,得出以下结论:

1)通过VMD和EMD的对比实验,验证了VMD的轴承故障诊断精度更高、抗噪性更强.相对于其他智能优化算法,本文所提出的IWOA-LSSVM具有更高的故障诊断正确率.

2)变分模态分解方法主要需要解决分解层数 K 值以及惩罚因子的选取问题,本文主要是通过中心频率的计算对 K 值进行确定,尚未解决惩罚因子的选取问题.

下一步的研究工作是优化VMD算法的惩罚因子,进一步提高滚动轴承故障诊断的准确率.

参考文献(References)

[1] Lu S L, He Q B, Wang J. A review of stochastic resonance in rotating machine fault detection[J]. Mechanical Systems and Signal Processing, 2019, 116: 230-260.

[2] 曲建岭, 余路, 袁涛, 等. 基于卷积神经网络的层级化智能故障诊断算法[J]. 控制与决策, 2019, 34(12): 2619-2626.
(Qu J L, Yu L, Yuan T, et al. A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network[J]. Control and Decision, 2019, 34(12): 2619-2626.)

[3] 刘朝华, 孟旭东, 陆碧良, 等. 基于节点优化型DAG-LDM的机组滚动轴承故障诊断方法[J]. 控制与决策, 2019, 34(7): 1394-1400.
(Liu Z H, Meng X D, Lu B L, et al. Fault diagnosis

- method of wind turbine rolling bearing based on node optimized DAG-LDM[J]. *Control and Decision*, 2019, 34(7): 1394-1400.)
- [4] Wu Z H, Huang N E. A study of the characteristics of white noise using the empirical mode decomposition method[J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences of London*, 2004, 460(2046): 1597-1611.
- [5] Wu Z H, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method [J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1-41.
- [6] Wang T, Zhang M C, Yu Q H, et al. Comparing the application of EMD and EEMD on time-frequency analysis of seismic signal[J]. *Journal of Applied Geophysics*, 2012, 83: 29-34.
- [7] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [8] 黄大荣, 柯兰艳, 林梦婷, 等. 一种参数优化VMD多尺度熵的轴承故障诊断新方法[J]. *控制与决策*, 2020, 35(7): 1631-1638.
(Huang D R, Ke L Y, Lin M T, et al. A new fault diagnosis approach for bearing based on multi-scale entropy of the optimized VMD[J]. *Control and Decision*, 2020, 35(7): 1631-1638.)
- [9] Li Y J, Zhang W H, Xiong Q, et al. A rolling bearing fault diagnosis strategy based on improved multiscale permutation entropy and least squares SVM[J]. *Journal of Mechanical Science and Technology*, 2017, 31(6): 2711-2722.
- [10] Pincus S M. Approximate entropy as a measure of system complexity[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 1991, 88(6): 2297-2301.
- [11] Yan R Q, Gao R X. Approximate entropy as a diagnostic tool for machine health monitoring[J]. *Mechanical Systems and Signal Processing*, 2007, 21(2): 824-839.
- [12] Bandt C, Pompe B. Permutation entropy: A natural complexity measure for time series[J]. *Physical Review Letters*, 2002, 88(17): 174102.
- [13] Cortes C, Vapnik V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [14] Wang C P, Kim H J, Yue C, et al. Effects of solar wind ultralowfrequency fluctuations on plasma sheet electron temperature: Regression analysis with support vector machine[J]. *Journal of Geophysical Research Space Physics*, 2017, 122(4): 4210-4227.
- [15] Chen D D, Tian Y J, Liu X H. Structural nonparallel support vector machine for pattern recognition[J]. *Pattern Recognition*, 2016, 60: 296-305.
- [16] Zhang Q T, Fang L Q, Su S C, et al. Parameters optimization of SVM based on improved FOA and its application in fault diagnosis[J]. *Journal of Software*, 2015, 10(11): 1301-1309.
- [17] Joachims T. Making large-scale SVM learning practical[J]. *Technical Reports*, 1998, 8(3): 499-526.
- [18] Liu F Z, Gao J W, Liu H B. A fault diagnosis solution of rolling bearing based on MEEMD and QPSO-LSSVM[J]. *IEEE Access*, 2020, 8: 101476-101488.
- [19] Gao S Z, Li T C, Zhang Y M. Rolling bearing fault diagnosis of PSO-LSSVM based on CEEMD entropy fusion[J]. *Transactions of the Canadian Society for Mechanical Engineering*, 2020, 44(3): 405-418.
- [20] Mirjalili S, Lewis A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [21] Min X Y, Xu X F, Wang Z J. Combining von neumann neighborhood topology with approximate-mapping local search for ABC-based service composition[C]. 2014 IEEE International Conference on Services Computing. Anchorage: IEEE, 2014: 187-194.
- [22] 陈东宁, 张运东, 姚成玉, 等. 基于变分模态分解和多尺度排列熵的故障诊断[J]. *计算机集成制造系统*, 2017, 23(12): 2604-2612.
(Chen D N, Zhang Y D, Yao C Y, et al. Fault diagnosis method based on variational mode decomposition and multi-scale permutation entropy[J]. *Computer Integrated Manufacturing Systems*, 2017, 23(12): 2604-2612.)

作者简介

蔡赛男(1994—), 女, 硕士生, 从事装备故障诊断的研究, E-mail: 771496511@qq.com;

宋卫星(1982—), 男, 工程师, 博士, 从事装备维修保障的研究, E-mail: 88159073@qq.com;

班利明(1982—), 男, 工程师, 学士, 从事装备维修保障的研究, E-mail: 78503373@qq.com;

齐小刚(1973—), 男, 教授, 博士生导师, 从事健康管理与故障诊断、资源调度与优化算法等研究, E-mail: xgqi@xidian.edu.cn;

汤润之(1990—), 男, 工程师, 硕士生, 从事装备维修保障的研究, E-mail: 422657839@qq.com.

(责任编辑: 齐 粟)