

DOI:10.19651/j.cnki.emt.2212286

基于多尺度排列熵和 IWOA-SVM 的滚动轴承故障诊断^{*}

张炎亮 李营

(郑州大学管理学院 郑州 450001)

摘要: 针对滚动轴承信号表现出的非线性和非平稳性特征问题,合理的特征选择可提高故障诊断率,提出基于多尺度排列熵(MPE)与改进鲸鱼算法(IWOA)优化支持向量机(SVM)的故障诊断模型。首先,通过变分模态分解(VMD)进行信号降噪预处理,计算多尺度排列熵进行信号特征重构;其次,引入惯性动态权重对鲸鱼算法进行改进,通过训练SVM参数,建立IWOA-SVM故障诊断模型;最后用美国凯斯西储大学轴承数据集进行仿真。结果表明,相较于多尺度熵,MPE可表征的故障特征信息更加丰富,故障识别率提高了2.1%;与同类优化算法相比,采用IWOA对SVM进行优化的故障诊断模型,收敛速度快、训练时间短、故障识别精度高,可对滚动轴承进行有效诊断。

关键词: 滚动轴承故障诊断;多尺度排列熵;惯性动态权重;改进鲸鱼优化算法;支持向量机

中图分类号: TH133.33 文献标识码: A 国家标准学科分类代码: 460

Rolling bearing fault diagnosis based on multi-scale permutation entropy and IWOA-SVM

Zhang Yanliang Li Ying

(School of Management, Zhengzhou University, Zhengzhou 450001, China)

Abstract: For the nonlinear and non-stationary characteristics of rolling bearing signals, reasonable feature selection can improve the fault diagnosis rate. A fault diagnosis model based on multi-scale permutation entropy (MPE) and improved whale algorithm (IWOA) was proposed to optimize support vector machine (SVM). Firstly, signal denoising was preprocessed by VMD, and multi-scale permutation entropy was calculated to reconstruct signal features. Secondly, inertial dynamic weights were introduced to improve the whale algorithm, and SVM parameters were trained to establish the IWOA-SVM fault diagnosis model. Finally, the bearing data set of Case Western Reserve University was used for simulation experiments. The results show that, compared with multi-scale entropy, MPE can represent more abundant feature information, and the fault recognition rate is improved by 2.1%. Compared with other optimization algorithms, the fault diagnosis model optimized by IWOA based on SVM has fast convergence speed, short training time and high fault recognition accuracy, which can effectively diagnose rolling bearings.

Keywords: rolling bearing fault diagnosis; multi-scale permutation entropy; inertia dynamic weight; improved whale optimization algorithm; support vector machine

0 引言

在工业生产中,信息智能化技术的快速发展,使得机械设备逐渐向信息化、智能化和自动化发展。滚动轴承作为机械设备中的关键部件,由于其复杂的工作环境,在工作中易被损坏,这直接导致生产中断,造成人财物的损失,甚至可能发生灾难性事故^[1-4]。因此,前期对滚动轴承进行故障

精准识别具有重要的研究意义。

目前相关研究一般通过对滚动轴承振动信号进行特征提取并实现故障识别。滚动轴承受工作环境以及各种因素的影响导致产生的振动信号较为复杂,在发生故障时振动信号会表现出非线性和非平稳性,若直接利用提取出的信号进行故障识别,则存在样本特征弱而导致诊断率等问题。变分模态分解(variational mode decomposition, VMD)可

收稿日期:2022-12-05

*基金项目:NSFC联合基金重大项目(U1904210)、河南省高等学校重点科研项目(23A630006)资助

以对滚动轴承早期发生故障时产生的较弱振动信号进行降噪分析^[5], 熵可以反映信号的复杂程度, 一般可以作为构建非线性和非平稳数据特征向量的指标, 如样本熵(sample entropy, SE), 排列熵(permuation entropy, PE)等。PE 被广泛用作进行故障诊断的特征向量, 杨静宗等^[6]采用局部均值分解和 PE 并结合优化的极限学习机进行故障诊断; 杨云等^[7]用 VMD 和 PE 对滚动轴承进行故障识别和分类。但是单一尺度的熵值仅仅能反映时间序列在一个尺度上的随机性和复杂度, 多尺度排列熵(multi-scale permutation entropy, MPE)则可以反映不同尺度下信号的复杂性和随机性变化, 在提取非线性和非平稳性信号特征中取得了较优的效果^[8-9]。

故障诊断的关键在于故障识别。支持向量机(support vector machine, SVM)是一种建立在统计学习理论基础上的机器学习方法, 不需要较多的训练样本就可以取得理想的分类结果^[10-11], 处理小样本有较大的优势, 但是 SVM 受核参数(c)和惩罚因子(g)影响较大, 许多学者利用智能优化算法^[12-14]对其进行寻优, 鲸鱼算法^[15](whale optimization algorithm, WOA)具有调节参数少、结构简单等优点, 安国庆等^[16]将 WOA 运用到变压器故障诊断中, 对 SVM 参数进行寻优; 李琨等^[17]运用 WOA 对极限学习机进行寻优, 进行液压泵故障诊断, 均取得了良好的效果, 但 WOA 算法也存在着一定的局限, 收敛速度慢, 容易陷入局部最优等, 仍需进一步改进^[18]。

综上所述, 本文通过粒子群算法(particle swarm optimization, PSO)优化 VMD 对滚动轴承振动信号进行预处理; 对优选的固有模态函数(intrinsic mode function, IMF)分别计算 MPE, 并将各模态 MPE 进行信号重构, 作为故障识别的特征向量; 对 WOA 进行改进, 采用改进鲸鱼算法(improved whale optimization algorithm, IWOA)对 SVM 进行优化, 将构造的特征向量输入到模型中进行故障识别, 以分辨出滚动轴承不同的故障类型。

1 多尺度排列熵

MPE 是 PE 引入尺度因子的特征优化算法, 对原始序列进行粗粒化处理, 衡量时间序列在不同尺度因子下的复杂程度。计算过程如下:

1)首先对原始数据 $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_N\}$ 进行粗粒化处理:

$$\mathbf{y}_j(s) = \frac{1}{s} \sum_n^{j_s} x_n, 1 \leq j \leq \frac{N}{s} \quad (1)$$

s 为尺度因子, $n = (j-1)s+1$

2)对得到的粗粒化序列 $\mathbf{y}_j(s)$ 重构:

$$\mathbf{Y}_l^r = \{\mathbf{y}_l^r, \mathbf{y}_{l+r}^r, \dots, \mathbf{y}_{l+(m-1)r}^r\} \quad (2)$$

式中: l 为第 l 个重构分量; m 为嵌入维数; t 为延迟时间。

3)对重构序列式(2)进行排列:

$$\mathbf{y}_{1+(j_1-1)r}^r \leq \mathbf{y}_{1+(j_2-1)r}^r \leq \dots \leq \mathbf{y}_{1+(j_m-1)r}^r \quad (3)$$

重构序列排列之后可以得到一组序列 $S(r) = \{j_1, j_2, \dots, j_m\}, r = 1, 2, 3, \dots, R$ 且 $R \leq m$ 计算每一种序列出现的概率 p_r :

4)计算每个粗粒化序列的排列熵:

$$PE = - \sum_{r=1}^{m!} p_r \cdot \lg p_r, \quad (4)$$

对其进行归一化处理:

$$PE = PE / \ln(m!) \quad (5)$$

由式(5)可知, $0 \leq PE \leq 1$, PE 值的大小表达出时间序列的混乱程度, 越大数据越随机、混乱, 反之越规则^[19]。

2 改进鲸鱼算法优化支持向量机

2.1 改进鲸鱼算法

WOA 是根据自然界中座头鲸捕食行为, 通过采用随机或者最佳搜索代理等方式模拟螺旋气泡网进食行为达到优化目的^[18]。标准 WOA 鲸鱼主要有 3 种行为: 包围猎物、泡网攻击捕猎和随机搜索猎物, 本文在标准鲸鱼算法的基础上进行改进, 具体过程如下:

1)包围猎物: 假设群体中的最优个体为猎物, 其他个体都会向猎物进行进攻包围, 通过下式进行更新位置:

$$D = |C \cdot \mathbf{X}^*(t) - \mathbf{X}(t)| \quad (6)$$

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) - A \cdot D \quad (7)$$

$$A = 2r_1 - a \quad (8)$$

$$C = 2r_2 \quad (9)$$

$$a = 2 - 2t/T \quad (10)$$

式中: $\mathbf{X}^*(t)$ 为最优猎物位置; $\mathbf{X}(t)$ 为当前鲸鱼位置; t 为迭代次数; T 为最大迭代次数; a 为收敛因子; r_1 和 r_2 是 $[0, 1]$ 之间的随机数。

2)泡网攻击捕猎: 鲸鱼捕猎包括收缩包围和螺旋式位置更新, 在此过程中, 鲸鱼在收缩群内进行捕猎时同时沿着螺旋路径进行前进, 在优化过程中, 设置随机参数 $p \in (0, 1)$ 。
 $p < 0.5$: 收缩包围通过式(2)进行更新: $p \geq 0.5$: 通过下式进行螺旋式位置更新:

$$\mathbf{X}(t+1) = \mathbf{X}^*(t) + D^* e^{bt} \cos(2\pi l) \quad (11)$$

$$D^* = |\mathbf{X}^*(t) - \mathbf{X}(t)| \quad (12)$$

式中: D^* 为鲸鱼和猎物之间的距离; b 为螺旋形状得数量, 为常数; l 为 $[-1, 1]$ 的随机数。

3)随机搜索捕食: 座头鲸根据彼此之间的距离进行随机搜索, 根据下式进行更新位置信息:

$$\mathbf{X}(t+1) = \mathbf{X}_r - A \cdot D \quad (13)$$

$$D = |C \cdot \mathbf{X}_r - \mathbf{X}(t)| \quad (14)$$

式中: $\mathbf{X}_r(t)$ 为鲸鱼随机位置, D 探索时得更新与步长。

4)本文根据文献[20]引入了惯性动态权重 w , 改善 WOA 算法由于迭代机制而存在的收敛速度慢, 易陷入局部最优问题, 进而提高搜索能力。惯性动态权重更新公式如下:

$$w = w_{\max} - (w_{\max} - w_{\min}) \sin\left(\frac{\pi}{2} \cdot \frac{t}{T}\right) \quad (15)$$

引入惯性动态权重之后, 鲸鱼位置更新改进公式如下:

$$\mathbf{X}(t+1) = \begin{cases} \omega \cdot \mathbf{X}(t) - A \cdot D \\ \omega \cdot \mathbf{X}^*(t) + D^* e^{bt} \cos(2\pi t) \end{cases} \quad (16)$$

2.2 改进鲸鱼算法优化支持向量机

本文针对 SVM 受核参数 c 和惩罚参数 g 较大, 采用改进鲸鱼算法对两个参数进行寻优。具体步骤如下:

- 1) 输入训练集和测试集, 初始化 IWOA 和 SVM 相关参数, 设置种群数量、最大迭代次数、最大和最小惯性动态权重等, 支持向量机核参数 c 和惩罚因子 g 取值范围;
- 2) 计算每个鲸鱼的适应度, 寻找最优鲸鱼个体位置;
- 3) 选择更新鲸鱼位置方式;
- 4) 进行边界检测, 重新计算适应度并排序, 更新鲸鱼位置, 寻找最优鲸鱼个体;
- 5) 判断是否满足终止条件, 若是输出最优参数, 否则继续循环。

优化流程如图 1 所示。

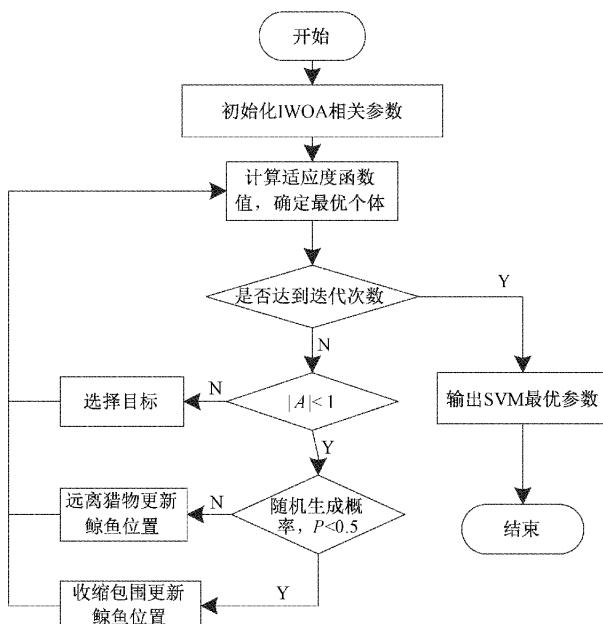


图 1 改进鲸鱼算法优化支持向量机流程

3 故障诊断模型

为实现滚动轴承故障诊断, 首先对原始信号进行 VMD, 计算每个模态下的 MPE, 进行数据重构, 构建输入特征矩阵, 采用 IWOA-SVM 分类器进行故障识别, 主要步骤如下:

- 1) 采集不同状态的滚动轴承的振动信号数据, 利用 PSO 进行优化 VMD, 得到最优参数, 对数据进行预处理, 得到不同模态数据。
- 2) 计算优选 IMF 的 MPE, 重构特征数据作为输入特征向量。
- 3) 将 MPE 特征向量作为 IWOA-SVM 模型的训练和

测试样本。

4) 利用训练样本对 IWOA-SVM 进行训练, 得到最优参数组合。

5) 利用优化后的 SVM 对测试集进行分类, 进行故障识别。

故障诊断方法流程如图 2 所示。

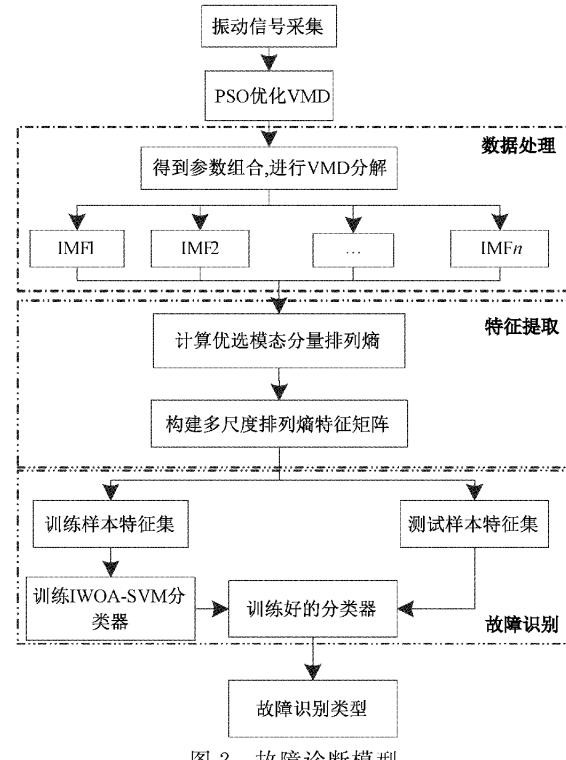


图 2 故障诊断模型

4 实验与分析

本文选取美国西储大学公开轴承数据进行实验分析。采用加速度传感器在采样频率 12 kHz, 负载 0HP 条件下采集的不同状态的轴承数据。共有 4 种轴承状态, 包括内圈故障、外圈故障、滚动体故障和正常状态。正常状态下 60 组信号数据, 以及轴承内圈、滚动体、外圈故障分别在故障直径为 0.007、0.014、0.021 in 下各 30 组信号数据, 共 330 组样本, 10 种轴承类别, 每组样本信号有 4 096 个采样点组成, 以 7 : 3 的比例划分训练集与测试集, 具体如表 1 所示。

4.1 数据处理

对滚动轴承信号进行预处理, 本文采用 VMD 进行振动信号有效分解, 而模态数 k 和惩罚因子 α 的选择对分解效果有直接的影响, 因此通过 PSO 对 VMD 进行优化, 分别对 4 种状态进行寻找最佳参数, 结果得到最佳参数如表 2 所示。

滚动轴承振动信号经过优化 VMD 分解后, 可剔除噪声保留有效信号, 如图 3~6 所示, 分别为正常轴承、内圈、外圈和滚动体故障轴承信号优化 VMD 分解图。

表 1 实验样本数据

滚动轴承状态	尺寸/in	训练集	测试集	标签
正常状态	0	42	18	0
	0.007	21	9	1
内圈故障	0.014	21	9	2
	0.021	21	9	3
外圈故障	0.007	21	9	4
	0.014	21	9	5
滚动体故障	0.021	21	9	6
	0.007	21	9	7
滚动体故障	0.014	21	9	8
	0.021	21	9	9

表 2 优化 VMD 最佳参数

状态	k	α
正常	2 421	4
内圈	2 163	9
外圈	2 870	5
滚动体	986	9

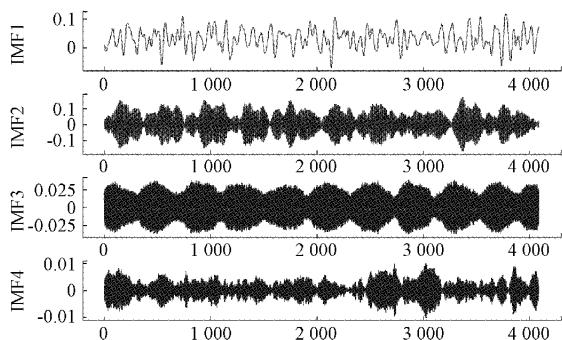


图 3 正常信号模态分量图

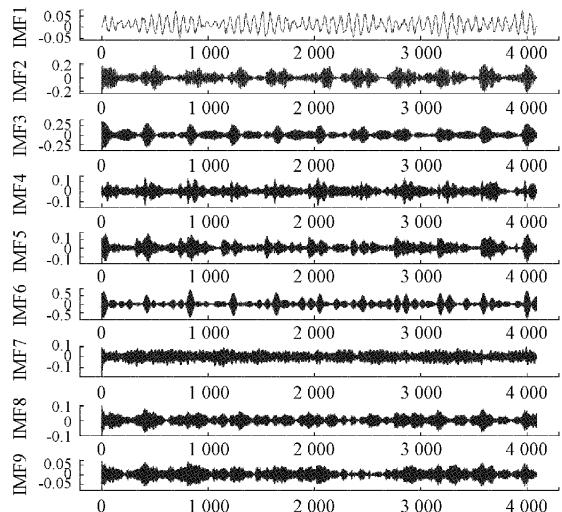


图 4 内圈故障模态分量图

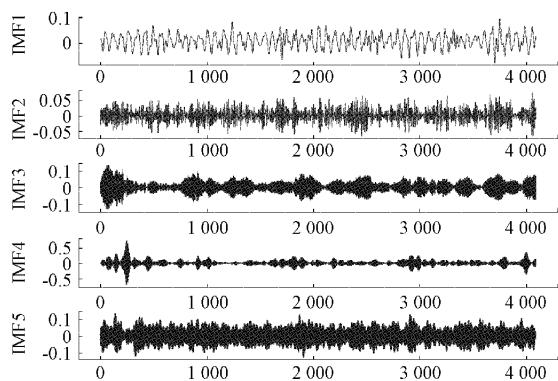


图 5 外圈故障模态分量图

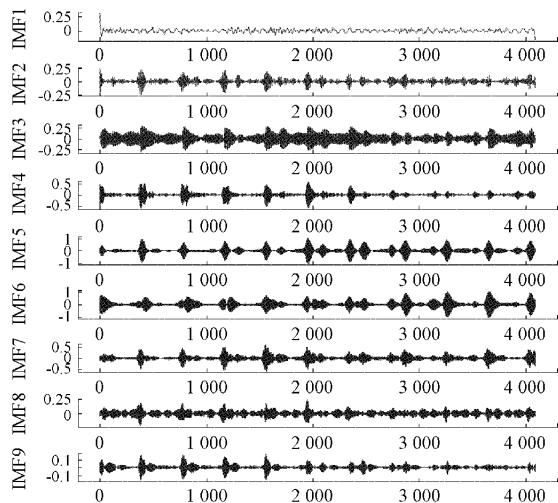


图 6 滚动体故障模态分量图

对每个状态分解的 IMF 进行计算相关系数, 各相关系数如表 3 所示, 由表 3 可知 4 种状态的振动信号最佳分解的模态数最小为 4, 根据选择相关系数较大的原则, 其他 3 种状态选择相关系数较大的 4 个模态。故本文选取每个滚动轴承状态的 4 个最优模态分量作为提取特征的数据。

表 3 相关系数筛选模态分量

状态	正常	内圈	外圈	滚动体
IMF1	0.517	0.120	0.274	0.094
IMF2	0.807	0.307	0.264	0.171
IMF3	0.265	0.385	0.311	0.255
IMF4	0.054	0.197	0.750	0.289
IMF5	—	0.228	0.439	0.639
IMF6	—	0.805	—	0.674
IMF7	—	0.232	—	0.392
IMF8	—	0.133	—	0.197
IMF9	—	0.119	—	0.094

4.2 特征提取

通过 VMD 对每一组振动信号降噪选取得到 4 个最优

变分模态分量,而仅仅根据其很难判断其故障状态,并且对于同一故障状态下的不同损伤等级也很难识别。利用 MPE 提取不同模态下的故障特征,并进行特征重构,作为特征向量进行故障诊断。其中尺度因子 s 和嵌入维数 m 的设置直接影响多尺度排列熵的计算,嵌入维度 m 取值过大或过小会导致时间序列的变化不显著或者算法对信号的突变性检测降低,本文根据先验知识^[21]选取 $m=6$,延迟因子 $t=1$ 。

4 种健康状态各选取一组信号进行分析尺度因子 s 对熵值的影响,如图 7 所示:正常滚动轴承信号的排列熵值明显区别于其他 3 种滚动轴承类型,而其他 3 种故障状态的熵值较为接近,而当 $s=1$ 时,仅仅根据单一尺度排列熵无法判断故障类型;随着尺度因子的变化,当尺度因子 $5 \leq s \leq 7$ 时,不同类型的滚动轴承熵值有明显差别;当尺度因子 $s \geq 8$ 时,4 种类型的滚动轴承熵值都趋于一个平稳状态,熵值又逐渐接近,尺度因子越大,特征信息会出现冗余。由图 7 可以看出,丰富的特征信息主要集中在前几个尺度因子,因此,本文选取前 5 个尺度的排列熵组成特征向量。

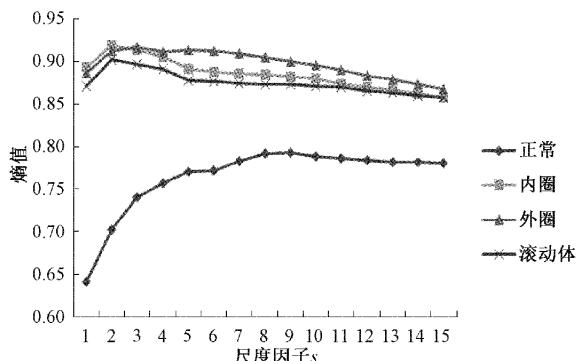


图 7 排列熵值与尺度因子的关系

4.3 结果分析

选用 IWOA 对 SVM 寻优,设置 SVM 参数 c 和 g 的取值范围均为 $[0.01, 100]$,鲸鱼群数为 20,最大迭代次数为 100。将划分的样本特征集输入到 IWOA-SVM 分类器中进行优化训练,经过训练后,寻优结果为: $c = 24.179$ 、 $g = 1.6832$ 。利用训练好的分类器对测试样本进行测试,准确率为 100%,10 种类型都可以实现准确识别。具体结果如图 8 所示。多尺度排列熵作为特征值,10 类滚动轴承故障类别都得到了准确分类,该诊断模型不仅能正确识别滚动轴承 4 种故障状态,还可以识别不能故障状态下的不同损伤等级。

通过构建的 IWOA-SVM 故障诊断模型,分别以多尺度熵(multiscale sample entropy, MSE)和 MPE 作为特征矩阵进行故障识别,结果如表 4 所示。以 MSE 和 MPE 构建特征矩阵,输入到 IWOA-SVM 进行参数寻优,通过优化后的分类器进行故障识别,以 MSE 为特征矩阵进行故障诊断,准确率为 97.9%,而以 MPE 为特征矩阵的准确率达到

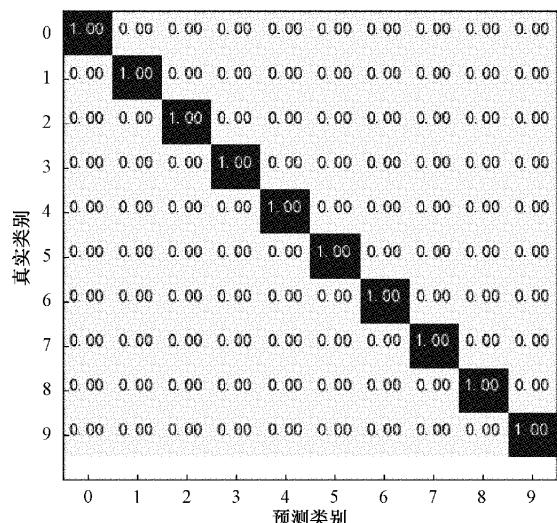


图 8 IWOA-SVM 故障诊断结果

100%,由此可知,MPE 特征矩阵包含的故障信息更加全面,诊断效果更优。

表 4 基于 IWOA-SVM 模型的诊断结果

特征向量	c	g	识别率/%
MPE	24.179	1.6832	100
MSE	11.931	0.8812	97.90

为了验证模型有效性,建立 WOA-SVM 和 IWOA-SVM 模型进行对比实验,如图 9~10 所示。随着迭代次数

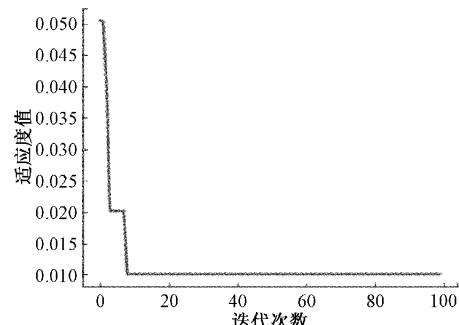


图 9 IWOA 优化 SVM 适应度变化曲线

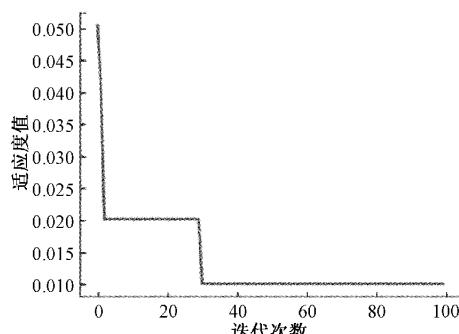


图 10 WOA 优化 SVM 适应度变化曲线

的增加,适应度值逐渐减小,IWOA 在对 SVM 进行参数寻优时,迭代次数为 10 次左右模型达到收敛状态,WOA 对 SVM 进行优化时,迭代次数为 30 次左右模型达到收敛,表明 IWOA 相比于 WOA 收敛速度更快。

进一步验证模型的可行性,采用 IWOA-SVM 和其他模型进行对比试验,将构建的 MPE 故障特征向量输入到其他 3 种模型中,结果表明,IWOA-SVM 不论在故障识别率还是寻优时间均优于其他 3 种模型。4 种模型的识别结果如表 5 所示。

表 5 算法对比分析

优化算法	c	g	识别率/%	时间/s
GWO	41.950	2.260 0	98	35.60
QPSO	55.420	17.800 0	99.30	51.06
WOA	18.178	0.182 0	98.90	54.45
IWOA	24.179	1.683 2	100	33.62

5 结 论

滚动轴承在发生故障时,振动信号会表现出非线性和不同程度的随机性和动力学突变,本文首先利用优化的 VMD 对滚动轴承信号进行预处理,采用 MPE 提取非线性和非平稳性信号特征,对滚动轴承振动信号进行特征重构。

引入惯性动态权重对 WOA 进行改进,得到 IWOA,通过 IWOA 对 SVM 进行参数寻优,提高 SVM 分类性能。

通过 MPE 和 MSE 作为特征向量进行故障识别,表明 MPE 包含更加全面的故障信息;然后对 GWO-SVM、QPSO-SVM、WOA-SVM 和 IWOA-SVM 故障诊断模型进行对比,结果表明 IWOA 优化 SVM 可减少模型达到收敛的迭代次数、缩短模型训练时间、具有更高的诊断率,验证了本文模型在滚动轴承故障诊断的可行性和有效性。

参考文献

- [1] 陈仁祥,朱玉清,胡小林,等.自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J].仪器仪表学报,2021,41(8):95-103.
- [2] LI H, LIU T, WU X, et al. Research on bearing fault feature extraction based on singular value decomposition and optimized frequency band entropy[J]. Mechanical Systems and Signal Processing, 2019,118:477-502.
- [3] 刘备,蔡剑华,彭梓齐.基于 VMD-IMDE-PNN 的滚动轴承故障诊断方法[J].噪声与振动控制,2022,42(5):96-101.
- [4] 雷春丽,焦孟萱,薛林林,等.小样本下基于 MTF 与 SSCAM-MSCNN 的滚动轴承变工况故障诊断方法[J/OL].计算机集成制造系统,2022:1-19.
- [5] 周静雷,周智,崔琳.应用变分模态分解和随机森林特征选择算法的扬声器异常声分类[J].振动与冲击,2022,41(20):277-283.
- [6] 杨静宗,施春朝,杨天晴,等.基于 LMD 和 ABC 优化 KELM 的故障诊断方法[J].工业工程,2022,25(3):124-131.
- [7] 杨云,张昊宇,薛元贺,等.基于 VMD 和排列熵的滚动轴承故障诊断研究[J].组合机床与自动化加工技术,2021(6):90-93.
- [8] 肖茂华,周爽,黄天逸,等.参数优化 VMD-MPE 和 PSO-CS-Elman 神经网络在滚动轴承故障诊断中的应用研究[J].振动工程学报,2023,36(3):861-874.
- [9] 刁宁昆,马怀祥,王金师,等.基于 MPE 与 PSO-SVM 的滚动轴承故障诊断[J].电子测量技术,2021,44(21):44-48.
- [10] 李国全,高建宇,白天宇,等.基于 SVM 与改进型乌鸦搜索算法的风电功率预测方法[J].国外电子测量技术,2022,41(2):40-45.
- [11] 张炎亮,毛贺年,赵华东.基于 VMD 与 IFWA-SVM 的滚动轴承故障诊断研究[J].机床与液压,2022,50(6):180-185.
- [12] 孙润发,汤占军. CEEMD 与 AO-SVM 结合的风机轴承故障诊断[J/OL].机械科学与技术,2022:1-7.[2023-12-19]<https://doi.org/10.13433/j.cnki.1003-8728.20220312>.
- [13] 唐宇,代琪,杨梦园,等.改进麻雀搜索算法优化 SVM 的异常点检测[J].计算机工程与科学,2023,45(2):346-354.
- [14] 李黄曼,张勇,张瑶.基于 ISSA 优化 SVM 的变压器故障诊断研究[J].电子测量与仪器学报,2021,35(3):123-129.
- [15] SEYEDADI M, ANDREW L. The whale optimization algorithm [J]. Advances in Engineering Software, 2016,95.
- [16] 安国庆,史哲文,马世峰,等.基于 RF 特征优选的 WOA-SVM 变压器故障诊断[J].高压电器,2022,58(2):171-178.
- [17] 李琨,张久亭.基于 TSMAAPE 与 WOA-KELM 的液压泵故障诊断[J].机床与液压,2022,50(9):201-209.
- [18] 赵春华,胡恒星,陈保家,等.基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J].振动与冲击,2019,38(10):31-37.
- [19] 任静波,孙根正,陈冰,等.基于多尺度排列熵的铣削颤振在线监测方法[J].机械工程学报,2015,51(9):206-212.
- [20] 邹浩,李维刚,李阳,等.基于混沌收敛因子和惯性权重的鲸鱼优化算法[J].武汉科技大学学报,2022,45(4):304-313.
- [21] 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.

作者简介

张炎亮,教授,主要研究方向为工业工程、质量管理、故障诊断等。

E-mail:yanliang@zzu.edu.cn

李营(通信作者),硕士研究生,主要研究方向为质量管理、故障诊断。

E-mail:1539320894@qq.com