

DOI:10.19651/j.cnki.emt.2211749

基于小波包信息熵和 SO-SVM 的滚动轴承故障诊断

胡业林 马向阳 钱文月 宋晓
(安徽理工大学 淮南 232001)

摘要: 针对滚动轴承振动信号的特征提取和故障诊断,提出了一种基于小波包信息熵和蛇优化算法(SO)优化支持向量机的滚动轴承故障诊断方法。使用小波包处理采集到的振动信号,构建小波包的能谱熵和系数熵,将构建的特征向量输入 SO-SVM 进行识别和分类;最终实现多故障模式识别,输出诊断结果。通过仿真实验表明,此方法对五组不同的样本诊断准确率达到 99.17%~100%,且相比于果蝇算法优化支持向量机(FOA-SVM)和粒子群算法优化支持向量机(PSO-SVM)具有更高的故障识别分类效果。

关键词: 小波包;信息熵;SO-SVM 算法;滚动轴承;故障诊断

中图分类号: TH133.33 文献标识码: A 国家标准学科分类代码: 470.40

Fault diagnosis of rolling bearing based on wavelet packet entropy and SO-SVM

Hu Yelin Ma Xiangyang Qian Wenyue Song Xiao
(Anhui University of Science and Technology, Huainan 232001, China)

Abstract: Aiming at the problem of feature extraction and fault diagnosis of rolling bearing vibration signals, a fault diagnosis method of rolling bearing based on wavelet packet information entropy and support vector machine (SVM) optimized by snake optimization algorithm (SO) is proposed. The collected vibration signals are processed by using the wavelet packet, the energy spectrum entropy and the coefficient entropy of the wavelet packet are constructed, and the constructed feature vectors are input into the SO-SVM for identification and classification; Finally, the multi-fault pattern recognition is realized and the diagnosis results are output. The simulation results show that the diagnostic accuracy of this method for five different groups of samples reaches 99.17%~100%, and compared with FOA-SVM and PSO-SVM, it has a higher effect of fault recognition and classification.

Keywords: wavelet packet;information entropy;SO-SVM algorithm;rolling bearing;fault diagnosis

0 引言

滚动轴承广泛应用于电力、能源和现代工业,作为旋转机械设备的关键部件,其故障将直接影响到整个生产系统。因此,对滚动轴承进行早期故障诊断研究非常重要^[1-2]。

因为旋转机器中约 30% 的故障与滚动轴承有关,而故障发生时的振动信号多为非线性、非平稳。目前,滚动轴承故障诊断得到了大量研究。信号的特征提取和机器学习算法是故障诊断很好的发展方向^[3-4]。例如,文献[5]采用带自适应噪声的完全集成经验模式分解(complete ensemble empirical mode decomposition, CEEMDAN) 提取时域特征,同时对时域特征进行快速傅里叶变换(fast Fourier transformation, FFT)得到频域特征。其次,利用递归特征消除(recursive feature elimination, RFE) 和卡方检验相结合

的方法,从得到的时频特征中选择最优的特征子集。最后,送入多个分类器进行轴承故障识别。文献[6]采用小波包变换方法提取滚动轴承的特征信号,然后利用极限学习机(extreme learning machine, ELM) 实现滚动轴承故障分类。文献[7]采用近似等距投影结合支持向量机(support vector machine, SVM) 的滚动轴承故障诊断方法,有效提高了分类的准确性。SVM 分类效果会受到参数选择的影响,为了提高滚动轴承故障诊断的准确率,出现了粒子群优化算法(PSO)、果蝇优化算法(FOA) 等一系列优化 SVM 的模型。文献[8]使用集成经验模态分解(ensemble empirical mode decomposition, EEMD) 方法提取振动信号的特征,并使用蝙蝠算法(BA) 优化 SVM 惩罚参数(C) 和径向基核函数参数(σ),确定出了不同类型的滚动轴承故障。文献[9]采用改进的 FOA 算法对 SVM 参数进行优化,提高

了故障诊断的准确性。文献[10]采用了部分域自适应对抗网络(partial domain adversarial neural network, PDAAN)这种新的无监督局部域自适应故障诊断方法对变工况下的轴承状态具有较高的识别精度。文献[11]采用 PSO 算法对 SVM 进行优化, 取得了较好的效果。作者使用小波包能谱熵、系数熵构建出信号的信息熵作为特征向量, 将其送入采用蛇优化算法^[12](SO)优化的 SVM, 并与 PSO-SVM 和 FOA-SVM 进行比较, 实验结果表明该方法具有更高的识别效率和更好的性能。

1 基于小波信息熵的特征提取

1.1 小波变换和小波包

Fourier 变换是一种经典且运用最广泛的信号分析方式, 用于信号在时频域之间转换, 但是它存在明显的不足, 即缺乏空间局部性。小波变换则很好的解决了此问题^[13]: 小波变换可以聚焦到信号的时频域上任何局部细节, 因此它具有“数学显微镜”的美称。

小波变换是将傅里叶变换中无限长的三角函数 $\sin(\omega t)$ 和 $\cos(\omega t)$ 转化为具有衰减小波基的有限长函数。假设存在一个复杂信号 $f(t)$, 则它能够使用母小波 $\psi(t)$ 通过伸缩平移生成不同“高矮胖瘦”的小波基函数 $\varphi_{a,\tau}(t)$ 线性组合来表示。使用小波变换可以更有效地将目标函数空间 $L^2(R)$ 划分为低频粗略信号空间 V_j 和高频详细信号空间 W_j , 可以描述为:

$$L^2(R) = V_{j_0} \oplus W_{j_0} \oplus W_{j_0+1} \oplus \dots \oplus V_j \in Z \quad (1)$$

式中: j_0 是一个任意起点。

定义信号 $f(t) \in L^2(R)$, 则可以用尺度函数 $\varphi(t)$ 和小波函数 $\psi(t)$ 表示为:

$$f(t) = \sum_k c_{j_0}(k) \varphi_{j_0,k}(t) + \sum_{j=j_0}^{\infty} \sum_k d_j(k) \psi_{j,k}(k) \quad (2)$$

式中: c_{j_0} 和 $d_j(j \geq j_0)$ 分别叫做近似和精细系数。第一项是 $f(t)$ 的 j_0 级近似, 第二项是更高级别的细节细化。

1.2 小波包信息熵的特征提取

小波包分析方法是小波分析的一个延伸, 其对信息加以解释和重建时, 信息解析功用更强。小波包的三层分解过程如图 1 所示。基于小波包能量谱 $E_i(i=1,2,\dots,j)$, 定义滚动轴承故障检测信号的小波包能谱熵和小波包系数熵这个特征向量。具体概念如下:

假设信号 S 的小波包在 j 尺度上的能谱为 E_1, E_2, \dots, E_j , 则信号 S 的总能量为尺度所有分量能量之和, 即 $E = \sum_{i=1}^j E_i$ 。每个尺度的能量与总能量之比为 $p_j = E_j/E$, 所以小波包的能谱熵定义为:

$$W_{EE} = -\sum_j p_j \ln p_j \quad (3)$$

小波包分解本质上是对低通和高通信号的组合后使用共轭正交滤波器将信号分成不同的频带。对信号进行 i 层小波包分解后得到多小波包分解序列 $s_{i,j}(j=0 \sim 2^i - 1)$

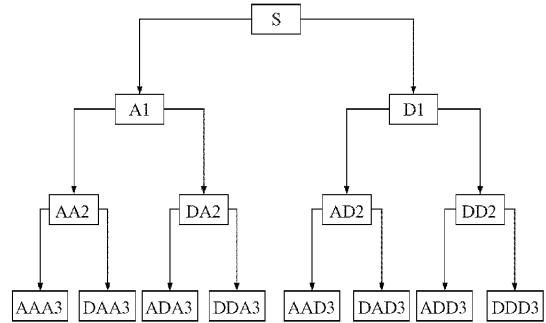


图 1 小波包分解树型结构

的过程是对原始信号的一种划分。对于小波包络的不同层, 定义小波包系数熵为:

$$W_{CE_{i,j}} = -\sum_{k=1}^j \epsilon_{i,j}(k) \ln \epsilon_{i,j}(k) \quad (4)$$

$$\epsilon_{i,j}(k) = \frac{|s_{i,j}(k)|^2}{\sum_{k=1}^N |s_{i,j}(k)|^2} \quad (5)$$

式中: $s_{i,j}(k)$ 为序列 $s_{i,j}$ 的第 k 个值; N 为序列长度; $\epsilon_{i,j}(k)$ 为第 i 层第 j 个频带第 k 个系数的概率值; $W_{CE_{i,j}}$ 为第 i 层第 j 个频带的系数熵。

小波包能谱熵 W_{EE} 表征了信号高频能量的分布和变化, 小波包系数熵 $W_{CE_{i,j}}$ 表征了信号能量分布在第 i 层第 j 个频带上的细节, 两者形成的特征向量可以表示滚动轴承故障信息。

2 SO 优化 SVM

2.1 SVM

SVM 是统计学习理论中比较年轻的学习理论, 它是由 Vapnik 提出的一种学习方法^[14]。SVM 是从平面可以线性分离的前提下寻找最优分类线的概念发展而来的, 当映射到高维空间时发展为最优超平面。当遇到线性不可分时, 需要在约束中加入松弛变量 ξ 来放松约束, 最终得到如下优化问题求解公式^[15]:

$$\min \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \xi_i \quad (6)$$

$$s.t. \quad y_i [\mathbf{w}^T \varphi(x_i) + b] \geq 1 - \xi_i, \\ \xi_i \geq 0, i = 1, 2, \dots, n \quad (7)$$

式中: b 为偏移量; \mathbf{w} 为权向量; C 是惩罚参数。

加入 Lagrange 乘子法将上述问题转化成为对偶二次规划, 得到最优分类决策函数:

$$f(x) = \operatorname{sgn} \sum_{i=1, j=1}^n \alpha_i^* y_i (x_i \cdot x) + b^* \quad (8)$$

式中: α 是拉格朗日乘子, 是遇到非线性分类问题通常需要加入输入变量 x 来进行非线性变换, 将问题映射到高维空间中, 在高维空间中去寻找最优分类面, 即使用一种核函数 $K(x_i, x_j)$ 对应变换空间中的内积映射得到非线性最优分类决策函数:

$$f(x) = \operatorname{sgn} \sum_{i=1, j=1}^n \alpha_i^* y_i K(x_i \cdot x_j) + b^* \quad (9)$$

式中: α_i^* 、 b^* 是优化问题式(8)的解, 本文所采用的是径向基(RBF)核函数:

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (10)$$

SVM 的核函数参数 σ 和惩罚因子 C 决定了分类效果。目前, SVM 中应用最广泛的参数优化方法是交叉验证法, 但找到最佳参数的效果一般。为了解决这个问题, 本文采用 SO 进行 SVM 参数寻优。最终, 取得了不错的效果。

2.2 SO

SO 是由 Hashim 等通过对蛇的交配行为进行观察和总结性的研究。若温度低且食物量充足, 每条蛇(雄性/雌性)都会争夺最佳伴侣。该算法在数学上模拟了觅食和繁殖的行为和模式, 具有良好的优化效率。SO 首先生成一个均匀分布的随机种群, 以启动优化算法过程。初始化种群的公式如下:

$$X_i = X_{\min} + r \times (X_{\max} - X_{\min}) \quad (11)$$

其中, X_i 是第 i 个个体的位置, r 是 $0 \sim 1$ 的随机数, X_{\min} 和 X_{\max} 分别表示位置变量的下界和上界。

假设雄性数量为 50%, 雌性数量为 50%。把它们分为两组: 雄性组和雌性组。按以下两个方程式划分群体:

$$N_m \approx N/2 \quad (12)$$

$$N_f = N - N_m \quad (13)$$

其中, N 是个体数, N_m 是指雄性个体数, N_f 是指雌性个体数。

评估每组并定义温度和食物数量, 在每组中找到最佳个体, 并获得最佳雄性($f_{best,m}$)和最佳雌性($f_{best,f}$)以及食物位置(f_{food})。温度 $Temp$ 用下式定义:

$$Temp = \exp\left(\frac{-t}{T}\right) \quad (14)$$

其中, t 指的是当前迭代, T 指的是最大迭代次数。

食物量 Q 使用下式定义:

$$Q = c_1 \times \exp\left(\frac{t - T}{T}\right) \quad (15)$$

其中, c_1 是常数, 值为 0.5。

在无食物的探索阶段中, 如果 $\{Q < \text{Threshold}; \text{Threshold} = 0.25\}$, 蛇会通过选择任何随机位置来搜索食物并更新它们的位置。探索阶段的公式如下:

$$X_{i,m}(t+1) = X_{rand,m}(t) \pm c_2 \times A_m \times ((X_{\max} - X_{\min}) \times rand + X_{\min}) \quad (16)$$

其中, $X_{i,m}$ 指第 i 个雄性位置, $X_{rand,m}$ 指随机雄性的位置, $rand$ 是 $0 \sim 1$ 的随机数, A_m 是雄性寻找食物的能力, 用下式计算:

$$A_m = \exp\left(\frac{-f_{rand,m}}{f_{i,m}}\right) \quad (17)$$

其中, $f_{rand,m}$ 是 $X_{rand,m}$ 的适应度, $f_{i,m}$ 是雄性组中第 i 个个体的适应度, c_2 是常数, 值为 0.05。

$$X_{i,f} = X_{rand,f}(t+1) \pm c_2 \times A_f \times ((X_{\max} - X_{\min}) \times rand + X_{\min}) \quad (18)$$

其中, $X_{i,f}$ 指第 i 个雌性位置, $X_{rand,f}$ 指随机雌性的位置, $rand$ 是 $0 \sim 1$ 的随机数, A_f 是雌性寻找食物的能力, 用下式计算:

$$A_f = \exp\left(\frac{-f_{rand,f}}{f_{i,f}}\right) \quad (19)$$

其中, $f_{rand,f}$ 是 $X_{rand,f}$ 的适应度, $f_{i,f}$ 是雌性组中第 i 个个体的适应度。

在有食物的探索阶段中, 如果 $\{Q > \text{Threshold} \text{ 且 } Temp > \text{Threshold}; \text{Threshold} = 0.6\}$ 蛇只会移动到食物上, 其数学表达式如下:

$$X_{i,j}(t+1) = X_{food} \pm c_3 \times Temp \times rand \times (X_{food} - X_{i,j}(t)) \quad (20)$$

其中, $X_{i,j}$ 是个体(雄性或雌性)的位置, X_{food} 是最佳个体的位置, c_3 是常数, 值为 2。

如果 $\{Q > \text{Threshold} \text{ 且 } Temp < \text{Threshold}; \text{Threshold} = 0.6\}$ 蛇将处于战斗模式或交配模式。

战斗模式:

$$X_{i,m}(t+1) = X_{i,m}(t) + c_3 \times FM \times rand \times (Q \times X_{best,f} - X_{i,m}(t)) \quad (21)$$

其中, $X_{i,m}$ 指第 i 个雄性位置, $X_{best,f}$ 指雌性群体中最佳个体的位置, FM 是雄性个体的战斗能力。

$$X_{i,f}(t+1) = X_{i,f}(t) + c_3 \times FF \times rand \times (Q \times X_{best,m} - X_{i,f}(t+1)) \quad (22)$$

其中, $X_{i,f}$ 指第 i 个雌性位置, $X_{best,m}$ 指雄性群体中最佳个体的位置, FF 是雌性个体的战斗能力。

FM 和 FF 可以通过以下等式计算:

$$FM = \exp\left(\frac{-f_{best,f}}{f_i}\right) \quad (23)$$

$$FF = \exp\left(\frac{-f_{best,m}}{f_i}\right) \quad (24)$$

其中, $f_{best,f}$ 是雌性组最佳个体的适应度, $f_{best,m}$ 是雄性组最佳个体的适应度, f_i 是总体适应度。

交配模式:

$$X_{i,m}(t+1) = X_{i,m}(t) + c_3 \times M_m \times rand \times (Q \times X_{i,f} - X_{i,m}(t)) \quad (25)$$

$$X_{i,f}(t+1) = X_{i,f}(t) + c_3 \times M_f \times rand \times (Q \times X_{i,m} - X_{i,f}(t+1)) \quad (26)$$

其中, $X_{i,f}$ 为第 i 个智能体在雌性组中的位置, $X_{i,m}$ 为第 i 个智能体在雄性组中的位置, M_m, M_f 分别表示雄性和雌性的交配能力, 两者表达式如下:

$$M_m = \exp\left(\frac{-f_{i,f}}{f_{i,m}}\right) \quad (27)$$

$$M_f = \exp\left(\frac{-f_{i,m}}{f_{i,f}}\right) \quad (28)$$

如果蛇蛋孵化, 选择最差的雄性和雌性并替换它们:

$$X_{worst,m} = X_{\min} + rand \times (X_{\max} - X_{\min}) \quad (29)$$

$$X_{worst,f} = X_{\min} + rand \times (X_{\max} - X_{\min}) \quad (30)$$

其中, $X_{worst,m}$ 是雄性组中最差的个体, $X_{worst,f}$ 是雌性组中最差的个体。标志方向算子 \pm 也称为多样性因子, 它提供了增加或减少位置解决方案的可能性, 以提供改变个体方向的机会, 从而在所有可能的方向上对给定的搜索空间进行良好的扫描。该参数随机生成以实现随机化。基于 SO 优化 SVM 的算法流程如图 2 所示。

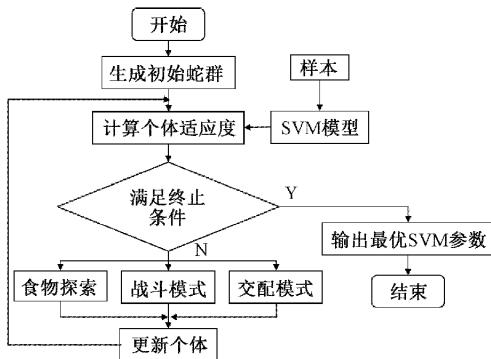


图 2 SO-SVM 优化流程

3 实验结果与分析

3.1 样本选择与特征提取

笔者采用美国凯斯西储大学实验室提供的数据。选择电机驱动轴端部的深沟球轴承 6205-2RSSKF 作为试验轴承, 在 0、2、3 HP 3 个状态下采集加速度传感器信号数据, 采样频率为 12 kHz。所用电机轴承的负载和转速如表 1 所示。本文识别的轴承故障状态主要包括内圈故障、外圈故障和滚动体故障, 每种故障状态包括损伤直径为 0.007、0.014、0.021 inch (1 inch = 2.54 cm) 3 种故障类型^[15]。为了避免诊断出现的偶然性, 笔者选用和文献[16]相同的样本, 即如表 2 所示的 5 组不同载荷、不同损伤程度的样本数据进行实验, 并且验证了本文所提出的方法在诊断轴承不同的故障状态和损伤程度下可以得到优越的成效。本次实验中的样本集包括 100 个不同数据类型的样本, 每一个样本含有 1 000 个采样点, 随机抽出 70 组样本用于训练, 剩下的 30 组样本作为测试。此处运用 Daubechies 小波系处理, 使用 db5 小波对各个样本信号进行 4 层小波包分解, 得到对应子代细节信号能量谱, 使用计算出的系数根据式(3)~(5)解出小波包能谱熵(W_{EE})和第 4 层 4 个频带的系数熵($W_{CE_1}, W_{CE_2}, W_{CE_3}, W_{CE_4}$), 最后利用 70 个测试样本对优化好的分类器进行滚动轴承工作状态的分类诊断。如图 3~6 所示为表 2 样本集 A 中正常和不同故障类型的滚动轴承的小波包信息熵提取结果。从分解后的特征样本可以看出, 特征信息比较稳定, 可以更好地表征轴承的各种故障信息。

表 1 电机轴承的载荷及转速

负载/HP	转速/(r·min ⁻¹)
0	1 797
2	1 750
3	1 730

表 2 不同状态识别的故障诊断实验样本

样本集	负载/HP	故障类型
A	0	正常
		0.007 inch 内圈故障
		0.007 inch 滚动体故障
B	2	正常
		0.021 inch 内圈故障
		0.021 inch 滚动体故障
C	3	正常
		0.021 inch 外圈故障
		0.021 inch 滚动体故障
D	0	正常
		0.007 inch 内圈故障
		0.014 inch 内圈故障
E	0	正常
		0.007 inch 外圈故障
		0.014 inch 外圈故障
		0.021 inch 滚动体故障

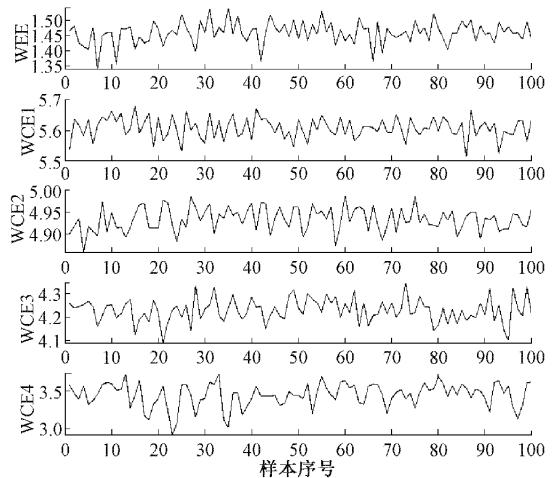


图 3 正常振动信号小波包信息熵提取后的结果

3.2 建模与诊断

分别利用 FOA、PSO、SO 对 SVM 进行训练。三者的迭代次数均为 100, 种群规模均为 20, C 和 g 的范围为

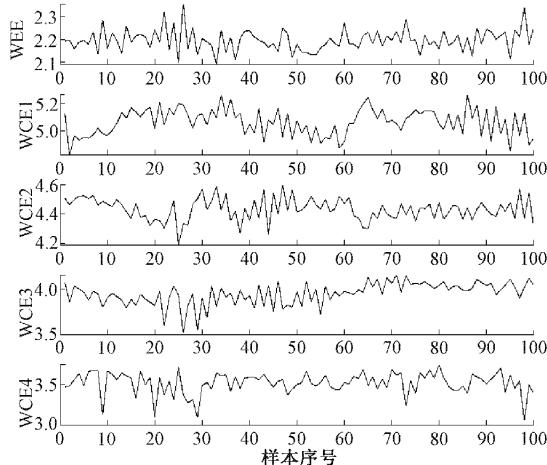


图 4 内圈故障振动信号小波包信息熵提取后的结果

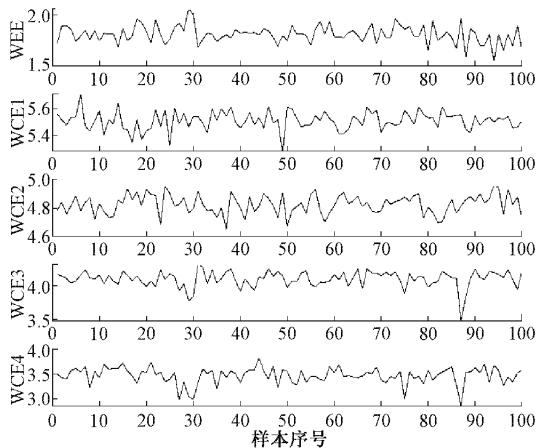


图 5 滚动体故障振动信号小波包信息熵提取后的结果

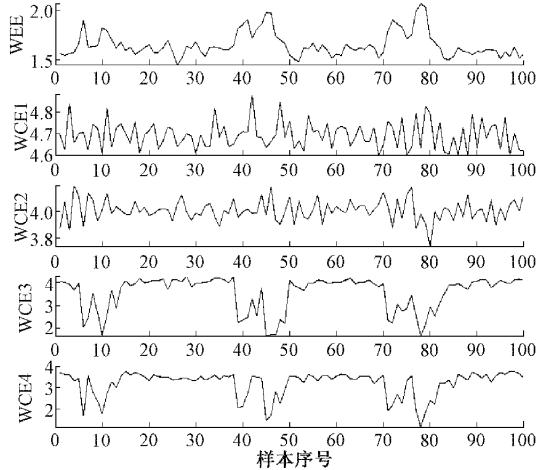


图 6 外圈故障振动信号小波包信息熵提取后的结果

0.01~200, PSO 的粒子速度范围为 $-2 \sim 2$ 。FOA-SVM、PSO-SVM、SO-SVM 对五组样本的寻优过程如图 7~11 所示, 测试集的预测结果如图 8~12 所示(由于篇幅有限, 只展示 SO-SVM 分类结果)。如表 3 和图 12~16 所示的分析可以看出, 从 SO-SVM 模型优化后的结果可以看出各

种情况下轴承故障诊断的准确率提高的同时还降低了用时, 迭代次数也显著减少。通过 SO 寻优 A~E 类样本 SVM 的最优参数 C 分别为 175.978、23.5875、47.3803、185.7941、76.9897, σ 分别为 0.4703、0.01、0.1674、0.6217、0.4611, 在迭代次数分别为 6、5、4、2、6 就找到最优值。因此, 在轴承故障诊断中, 使用 SO 对 SVM 进行优化对于提高准确精度和收敛速度具有重要意义。

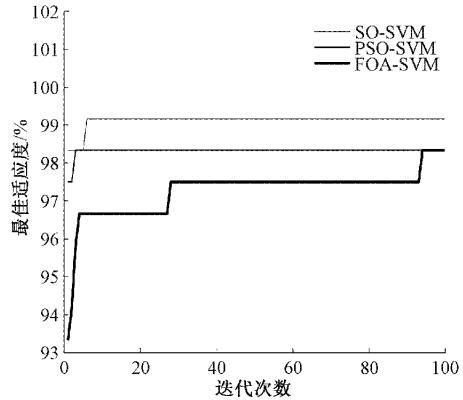


图 7 A 类样本最佳适应度曲线

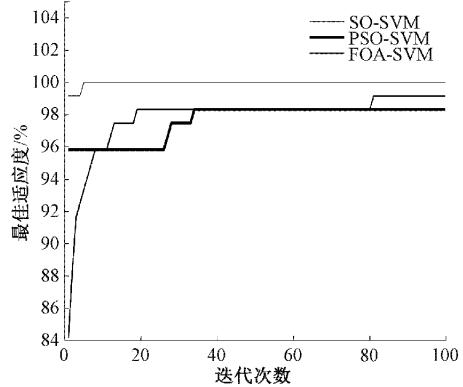


图 8 B 类样本最佳适应度曲线

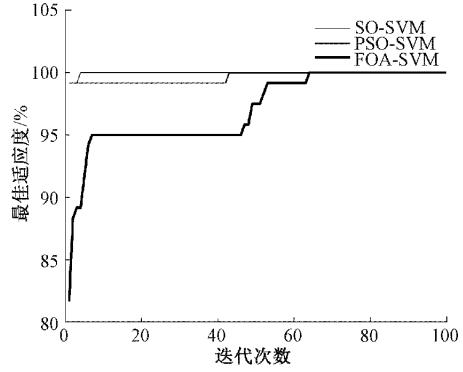


图 9 C 类样本最佳适应度曲线

实验表明 SO 和 PSO 处理后的 SVM 分类效果更好, 相比较而言 SO-SVM 准确率最高。在 B、C、D、E 四种样本集上, 准确率达到了 100%。在选用相同数据集的基础上,

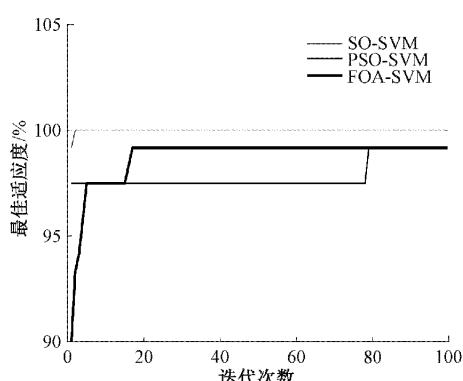


图 10 D 类样本最佳适应度曲线

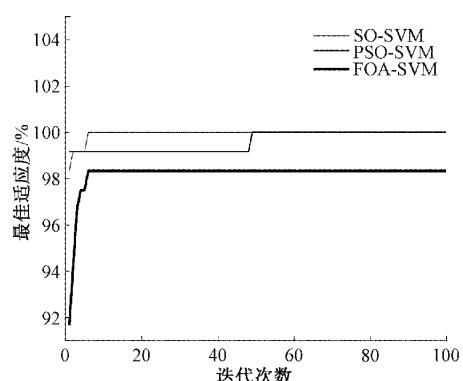


图 11 E 类样本最佳适应度曲线

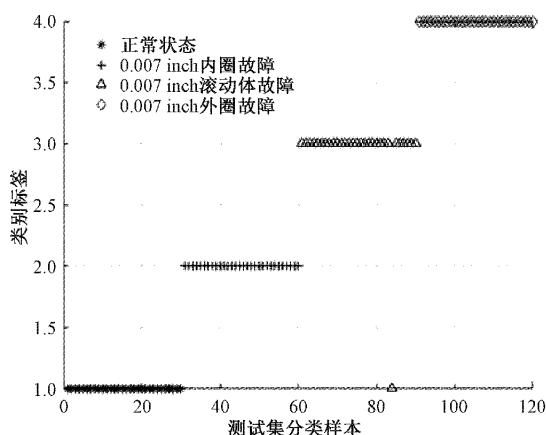


图 12 A 类样本 SO-SVM 分类结果

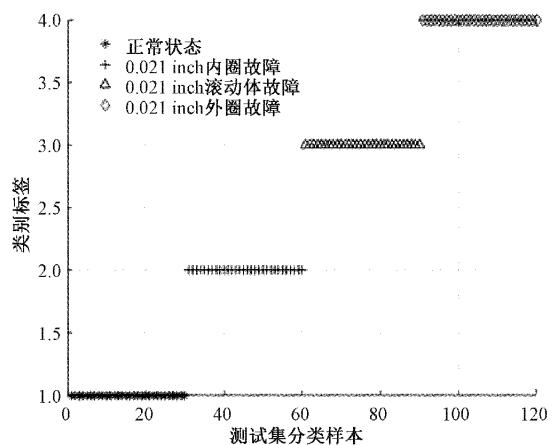


图 13 B 类样本 SO-SVM 分类结果

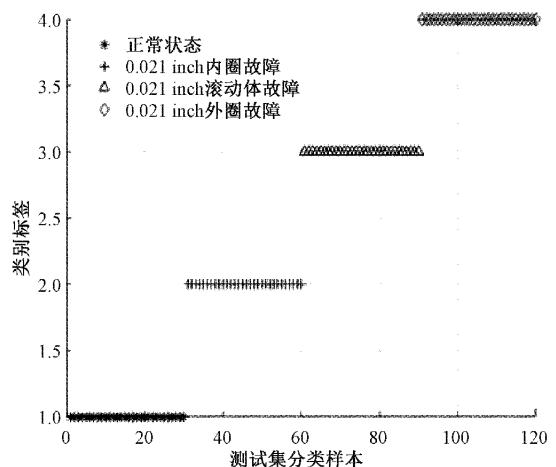


图 14 C 类样本 SO-SVM 分类结果

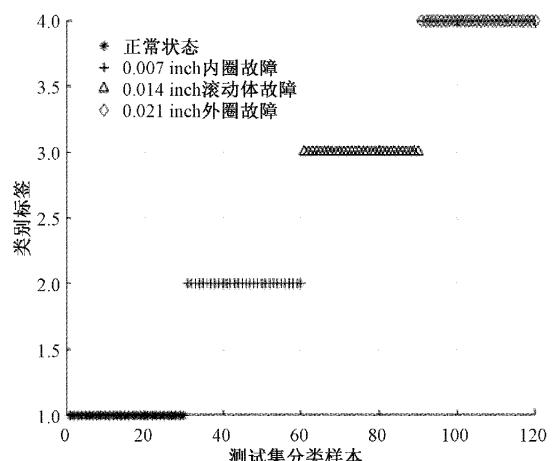


图 15 D 类样本 SO-SVM 分类结果

表 3 不同方法对于识别不同状态轴承故障诊断的实验结果

样本集	准确率/%, 运行时间/s		
	FOA-SVM	PSO-SVM	SO-SVM
A	98.33, 4.768	98.33, 5.917	99.17, 3.869
B	99.17, 5.082	98.33, 5.973	100, 4.061
C	100, 5.458	100, 6.624	100, 5.178
D	99.17, 5.063	99.17, 5.693	100, 4.461
E	98.33, 4.664	100, 4.671	100, 4.267

本文所提方法在样本集 B、C、E 上相比于文献[16]所使用的方法准确率分别提高了 3.33%、1.67%、2.5%，不过相比于样本集 A 准确率降低了 0.83%。从图 3 和 5 可以看出样本集 A 的正常、滚动体故障振动信号在能谱熵 (W_{EE}) 大于 1.5 处存在相近的特征点，且系数熵 (W_{CE_1} 、 W_{CE_2})

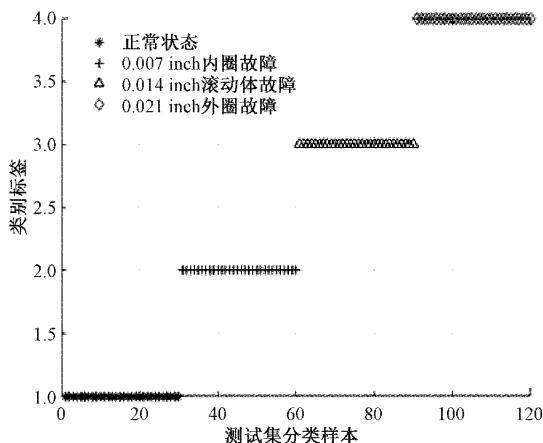


图 16 E 类样本 SO-SVM 分类结果

W_{CE_3} 、 W_{CE_4}) 的值相差较小, 也正是这个原因导致系统把滚动体故障信号错误的分类成正常信号, 故对信号进行更有效的特征提取是研究工作的难点。今后, 可把小波包信息熵技术与变分模态分解 (variational mode decomposition, VMD)、CEEMDAN 等信号提取的方法进行融合来提高信号的故障特征, 也可以对蛇优化算法进行改进或者换成性能更好的智能优化算法以减少迭代次数、提高运算效率。综上所述, SO-SVM 算法模型在滚动轴承故障诊断中具有较高的诊断效果。

4 结 论

本文提出一种基于小波包信息熵和 SO-SVM 的滚动轴承故障诊断方法, 可有效实现 SVM 参数的自适应调整。实验结果表明, 小波包信息熵技术可较好的用于提取滚动轴承故障信息, 从表 3 可以看出 SO-SVM 比 FOA-SVM 和 PSO-SVM 具有更好的故障诊断性能。可以证明该优化模型具有良好的实际应用价值, 为滚动轴承故障诊断领域提供了一种新的方法。未来可推广应用于其他领域的故障诊断。

参考文献

- [1] QIAO W, LU D G. A survey on wind turbine condition monitoring and fault diagnosis-part II: Signals and signal processing methods [J]. IEEE Transactions on Industrial Electronics, 2015, 62(10), DOI: 10.1109/TIE.2015.2422112.
- [2] LIU X W, PEI D, LODEWIJKS G, et al. Acoustic signal based fault detection on belt conveyor idlers using machine learning [J]. Advanced Powder Technology, 2020, 31(7), DOI: 10.1016/j.ap.2020.04.034.
- [3] KANKAR P K, SATISH C S, HARSHA S P. Fault diagnosis of rolling element bearing using cyclic autocorrelation and wavelet transform [J]. Neurocomputing, 2013, 110, DOI: 10.1016/j.neucom.2012.11.012.
- [4] 刘颖, 陶建峰, 黄武涛, 等. 小波包能量与 CNN 相结合的滚动轴承故障诊断方法 [J]. 机械设计与制造, 2021, (11): 127-131, DOI: 10.19356/j.cnki.1001-3997.2021.11.029.
- [5] TANG ZH H, WANG M J, OUYANG T H, et al. A wind turbine bearing fault diagnosis method based on fused depth features in time-frequency domain [J]. Energy Reports, 2022, 8: 12727-12739.
- [6] 姚峰林, 谢长开, 吕世宁, 等. 基于小波包变换和 ELM 的滚动轴承故障诊断研究 [J]. 安全与环境学报, 2021, 21(6): 2466-2472, DOI: 10.13637/j.issn.1009-6094.2020.0999.
- [7] 刘畅, 伍星, 刘韬, 等. 基于近似等距投影和支持向量机的滚动轴承故障诊断 [J]. 振动与冲撞, 2018, 37(5): 234-239, DOI: 10.13465/j.cnki.jvs.2018.05.035.
- [8] 罗源睿, 王海瑞. 基于蝙蝠算法优化支持向量机的滚动轴承故障诊断 [J]. 化工自动化及仪表, 2021, 48(3): 248-252, 263.
- [9] 黄晓璐, 周湘贞. 基于改进果蝇优化算法优化支持向量机的故障诊断 [J]. 机械强度, 2019, 41(3): 568-574, DOI: 10.16579/j.issn.1001-9669.2019.03.011.
- [10] ZHOU H F, CHENG P Y, SHAO S Y, et al. Bearing fault diagnosis based on partial domain adaptation adversarial network [J]. Measurement Science and Technology, 2022, 33(12), DOI: 10.1088/1361-6501/AC85D4.
- [11] 李嫄源, 袁梅, 王璐, 等. SVM 与 PSO 相结合的电机轴承故障诊断 [J]. 重庆大学学报, 2018, 41(1): 99-107.
- [12] HASHIM FATMA A, HUSSIEN ABDELAZIM G. Snake Optimizer: A novel meta-heuristic optimization algorithm [J]. Knowledge-Based Systems, 2022, 242, DOI: 10.1016/j.knosys.2022.108320.
- [13] 吴建萍, 姜斌, 刘剑慰. 基于小波包信息熵和小波神经网络的异步电机故障诊断 [J]. 山东大学学报(工学版), 2017, 47(5): 223-228, 237.
- [14] 朱哈娜, 刘慧明. 基于改进 VMD 与 GS_SVM 的轴承故障诊断 [J]. 电子测量技术, 2020, 43(21): 71-76, DOI: 10.19651/j.cnki.emt.2004917.
- [15] 胡业林, 代斌, 宋晓. 基于小波包和 AFSA-SVM 的电机故障诊断 [J]. 电子测量技术, 2021, 44(2): 48-55, DOI: 10.19651/j.cnki.emt.2005463.
- [16] 杨婧, 续婷, 白艳萍, 等. 基于网格搜索与支持向量机的轴承故障诊断 [J]. 科学技术与工程, 2021, (22): 9360-9364.

作者简介

胡业林, 博士, 教授, 硕士生导师, 主要研究方向为自动控制工程、计算机控制与检测技术、仪器仪表等。

E-mail: 2439498035@qq.com

马向阳(通信作者), 硕士, 主要研究方向为信号处理、人工智能算法、电气设备故障诊断技术等。

E-mail: 1454107734@qq.com