

# 基于 EEMD 能量熵和 GJO-KELM 的 滚动轴承故障诊断<sup>\*</sup>

史书杰 赵凤强 王 波 杨晨昊 周 帅

(大连民族大学机电工程学院 大连 116650)

**摘 要:** 滚动轴承在旋转机械中发挥着重要作用,若出现故障,轻则引起设备停机,重则危及现场人员生命安全,因此有必要对其进行故障诊断。针对滚动轴承故障特征难以提取,传统分类方法正确率不高的问题,本文提出一种基于集合经验模态分解(EEMD)能量熵和金豺优化算法(GJO)优化核极限学习机(KELM)的故障诊断方法,实现了提取滚动轴承故障特征并正确分类的目标。通过实验数据进行验证,该方法能够提取到滚动轴承原始信号中隐含的故障信息特征,其诊断正确率高达 98.47%。

**关键词:** EEMD;能量熵;金豺优化算法;核极限学习机;故障诊断

**中图分类号:** TH133.3      **文献标识码:** A      **国家标准学科分类代码:** 510.80

## Fault diagnosis of rolling bearings based on EEMD energy entropy and GJO-KELM

Shi Shujie Zhao Fengqiang Wang Bo Yang Chenhao Zhou Shuai

(School of Electromechanical Engineering, Dalian Minzu University, Dalian 116650, China)

**Abstract:** Rolling bearings play an important role in rotating machinery. If a fault occurs, it can cause equipment shutdown, and in severe cases, endanger the safety of on-site personnel. Therefore, it is necessary to diagnose the fault. In response to the difficulty in extracting fault features of rolling bearings and the low accuracy of traditional classification methods, this paper proposes a fault diagnosis method based on Set Empirical Mode Decomposition (EEMD) energy entropy and Golden Jackal Optimization Algorithm (GJO) optimized Kernel Extreme Learning Machine (KELM), achieving the goal of extracting fault features of rolling bearings and correctly classifying them. Through experimental data validation, this method can extract the fault information features hidden in the original signal of rolling bearings, with a diagnostic accuracy of up to 98.47%.

**Keywords:** EEMD; energy entropy; golden jackal optimization algorithm; kernel extreme learning machine; fault diagnosis

## 0 引 言

滚动轴承作为旋转机械的重要组成部分,是保障安全稳定运转的关键环节,也是整个系统中最容易出现故障的部件<sup>[1]</sup>。据调查,在机械设备的各种故障中,滚动轴承造成的故障占比约为 30%<sup>[2]</sup>。因此,有必要对滚动轴承进行故障诊断,不仅可以减少维修成本,还能有效保证设备正常运行,提高装备可靠性<sup>[3]</sup>。

滚动轴承在工作过程中,会产生非线性、非平稳的振动信号,鉴于此,Huang 等<sup>[4]</sup>提出了经验模态分解(empirical

mode decomposition, EMD)信号分析方法。EMD 能够自适应地将时间序列分解为若干个独立的 IMF 分量以及一个残差<sup>[5]</sup>,适用范围广,但是该方法存在缺点:模态混叠。模态混叠现象是指同一尺度信号存在于不同分量中<sup>[6]</sup>。为了解决这个问题,集合经验模态分解(ensemble empirical mode decomposition, EEMD)<sup>[7]</sup>被提了出来。EEMD 算法通过引入白噪声并利用其频谱均匀分布的统计特性,经过多次平均计算得到结果来减轻模态混叠的影响<sup>[8]</sup>。信息熵可用来分析信号的复杂度,因此在特征提取领域应用十分广泛。高淑芝等<sup>[9]</sup>将 EEMD 和各种熵相结合,从多个角度

提取信号的故障特征信息,但是会加大计算量,导致计算效率低下。周静雷等<sup>[10]</sup>选择样本熵作为特征向量,成功实现了故障特征的提取,但是样本熵的参数需要依据个人经验设定,存在主观性。因此,本文选取计算简单,不需要设置参数的能量熵作为特征向量,可以在保证原始信号故障信息不丢失的情况下,提高运算效率。

在故障分类识别方面,机器学习算法以其适应性强、可快速决策等优点而被广泛应用。常用的算法有支持向量机(support vector machine, SVM)、随机森林(random forest, RF)、核极限学习机(kernel based extreme learning machine, KELM)等,其中,核极限学习机是由 Huang 等<sup>[11]</sup>提出来的,是在极限学习机(extreme learning machine, ELM)的基础上结合核函数的改进算法。在实际应用过程中,不需要考虑隐藏层神经元个数、输入参数和系统偏置,提升了 ELM 的泛化能力和学习速度。KELM 的分类精度很大程度上取决于正则化系数  $C$  和核参数  $g$  的选择,所以有学者<sup>[12-13]</sup>采用群智能算法对 KELM 进行优化。鉴于此,本文采用原理简单、寻优能力强的金豺优化算法(golden jackal optimization, GJO)<sup>[14]</sup>优化 KELM 的关键参数,以此来提高 KELM 的分类正确率。

综上所述,为了实现滚动轴承的故障诊断,本文选择将 EEMD 和能量熵结合起来提取故障特征,采用 GJO-KELM 对故障类型进行分类识别,以实验数据为基础,通过和其他算法比较得出结论,该方法存在一定优越性,从而为实际生产过程提供参考。

## 1 基本原理

### 1.1 集合经验模态分解

集合经验模态分解(EEMD)用于分解非线性、非稳态的数据序列。它的优势在于能够有效地分解噪声干扰下的信号,对模态混叠问题有很好的表现。具体计算公式如下:

1)向原始信号中加入噪声信号,得到新的信号,即:

$$x_i(t) = x(t) + n_i(t) \quad (1)$$

其中,  $x(t)$  表示原始信号,  $n_i(t)$  表示第  $i$  次加入的噪声信号,  $x_i(t)$  表示第  $i$  次得到的新信号。

2)对所有的新信号进行 EMD 分解,得到一系列 IMF 分量和残余分量,即:

$$x_i(t) = \sum_{j=1}^n c_{ij}(t) + r_i(t) \quad (2)$$

其中,  $c_{ij}(t)$  表示第  $i$  次分解得到的第  $j$  个 IMF 分量,  $r_i(t)$  表示残余分量。

3)对步骤 1)和步骤 2)重复  $N$  次,对得到的每组 IMF 分量和残余分量进行均值处理,即:

$$\begin{cases} c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{ij}(t) \\ r(t) = \frac{1}{N} \sum_{i=1}^N r_i(t) \end{cases} \quad (3)$$

其中,  $c_j(t)$  表示最终得到的第  $j$  个 IMF 分量,  $r(t)$  表示最终的残余分量。

4)经过 EEMD 分解的原始信号,可以得到  $M$  个 IMF 分量以及一个残余分量,即:

$$x(t) = \sum_{j=1}^M c_j(t) + r(t) \quad (4)$$

### 1.2 相关系数

相关系数能够准确地刻画 IMF 分量与原始数据之间的紧密程度,根据相关系数,能够保留信息量更多的 IMF 分量<sup>[15]</sup>。将原始信号设为  $x(t) = (x_1, x_2, \dots, x_n)$ , 经过分解得到的 IMF 分量设为  $y(t) = (y_1, y_2, \dots, y_n)$ , 那么二者的相关系数表达式为:

$$\rho_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (5)$$

其中,  $n$  表示信号的个数,  $\bar{x}$  表示原始信号的平均值,  $\bar{y}$  表示 IMF 分量的平均值。

### 1.3 能量熵

滚动轴承发生故障时,能量会集中在某些特定频段,熵值的大小可以反映出能量分布的均匀性,因此,可以选择能量熵作为特征向量<sup>[16]</sup>。具体的计算方式如下:

1)根据相关系数,选取  $k$  个有效的 IMF 分量。

2)计算每个 IMF 分量的能量值,即:

$$E_j = \int_{-\infty}^{+\infty} |C_j(t)|^2 dt \quad (6)$$

其中,  $j = 1, 2, \dots, k$ 。

3)计算这  $k$  个 IMF 分量的总能量值,即:

$$E = \sum_{j=1}^k E_j \quad (7)$$

4)计算每个 IMF 分量的概率熵值,即:

$$p_j = \frac{E_j}{E} \quad (8)$$

5)计算每个 IMF 分量的能量熵值,即:

$$H_j = - \sum_{j=1}^k p_j \log p_j \quad (9)$$

### 1.4 金豺优化算法

金豺优化算法(GJO)是 2022 年提出的一种新的元启发式算法,具有寻优速度快、收敛性好的优点。该算法根据金豺的狩猎策略来进行数学建模,算法优化具体过程如下:

1)种群初始化

金豺种群初始化,即:

$$Y_0 = Y_{\min} + rand \cdot (Y_{\max} - Y_{\min}) \quad (10)$$

其中,  $Y_0$  表示金豺种群的初始位置,  $rand$  是  $[0, 1]$  之间的随机数,  $Y_{\min}$  表示求解问题的下界,  $Y_{\max}$  表示求解问题的上界。

猎物矩阵 **Prey** 可表示为:

$$\text{Prey} = \begin{bmatrix} Y_{1,1} & \dots & Y_{1,d} \\ \vdots & \ddots & \vdots \\ Y_{n,1} & \dots & Y_{n,d} \end{bmatrix} \quad (11)$$

其中,  $n$  为猎物的数量,  $d$  为求解问题的维度,  $Y_{n,d}$  表示第  $n$  个猎物的第  $d$  维位置。

猎物的适应度值矩阵  $F_{OA}$  如下:

$$F_{OA} = \begin{bmatrix} f(Y_{1,1}; Y_{1,2}; \cdots; Y_{1,d}) \\ \vdots \\ f(Y_{n,1}; Y_{n,2}; \cdots; Y_{n,d}) \end{bmatrix} \quad (12)$$

其中,  $f(\cdot)$  为适应度函数, 将适应度值最优的作为雄豺狼, 适应度值次优的作为雌豺狼。

## 2) 搜索猎物

金豺知道如何感知并跟随猎物, 狩猎工作通常由雄豺狼领导, 雌性豺狼跟随, 具体的数学公式实现如下:

$$\begin{cases} Y_1(t) = Y_M(t) - E \cdot |Y_M(t) - r_1 \cdot \text{Prey}(t)| \\ Y_2(t) = Y_{FM}(t) - E \cdot |Y_{FM}(t) - r_1 \cdot \text{Prey}(t)| \end{cases} \quad (13)$$

其中,  $t$  表示当前迭代次数,  $Y_M(t)$  表示第  $t$  次迭代时的雄豺狼的位置,  $Y_{FM}(t)$  表示第  $t$  次迭代时的雌豺狼的位置,  $\text{Prey}(t)$  表示第  $t$  次迭代时猎物的位置,  $Y_1(t)$  表示第  $t$  次迭代后的雄豺狼的更新位置,  $Y_2(t)$  表示第  $t$  次迭代后的雌豺狼的更新位置。

$E$  表示猎物的逃脱能量, 可用如下公式计算:

$$\begin{cases} E = E_1 \cdot E_0 \\ E_0 = 2 \cdot r - 1 \\ E_1 = c_1 \cdot (1 - \frac{t}{T}) \end{cases} \quad (14)$$

其中,  $E_1$  表示猎物能量的下降过程,  $E_0$  表示猎物能量的初始状态,  $r$  是  $[0, 1]$  之间的随机数,  $c_1$  取值 1.5,  $t$  表示当前迭代次数,  $T$  表示最大迭代次数。

$r_1$  是基于莱维分布的一个随机数, 可用以下公式计算:

$$\begin{cases} r_1 = 0.05 \cdot LF(y) \\ LF(y) = 0.01 \cdot (\mu \cdot \sigma) / (|v^{(1/\beta)}|) \\ \sigma = (\frac{\Gamma(1+\beta) \cdot \sin(\pi\beta/2)}{\Gamma(\frac{1+\beta}{2}) \cdot \beta \cdot (2^{\frac{\beta-1}{2}})})^{1/\beta} \end{cases} \quad (15)$$

其中,  $\mu$  和  $v$  表示  $(0, 1)$  之间的随机数,  $\beta$  取值 1.5。

综上, 金豺的位置更新公式可表示为:

$$Y(t+1) = (Y_1(t) + Y_2(t))/2 \quad (16)$$

## 3) 包围并攻击猎物

当猎物被金豺侵扰时, 逃脱能量会逐渐减少, 随后金豺会将它们包围, 开始攻击并吞食猎物。此时豺狼的行为可用如下数学模型描述:

$$\begin{cases} Y_1(t) = Y_M(t) - E \cdot |r_1 \cdot Y_M(t) - \text{Prey}(t)| \\ Y_2(t) = Y_{FM}(t) - E \cdot |r_1 \cdot Y_{FM}(t) - \text{Prey}(t)| \end{cases} \quad (17)$$

最后, 金豺的位置公式仍按式(16)更新。

## 1.5 核极限学习机

KELM 与传统神经网络相比, 计算量和搜索空间较少, 在非线性回归和分类方面具有较好的应用效果<sup>[17]</sup>。算

法具体实现过程如下:

对于  $n$  个不同的输入样本  $x_1, x_2, \cdots, x_n$ , 假设隐藏层的激活函数为  $g(x)$ , 隐藏层输出矩阵  $H$  为:

$$H = \begin{bmatrix} g(\omega_1 x_1 + b_1) & \cdots & g(\omega_m x_1 + b_m) \\ \vdots & \ddots & \vdots \\ g(\omega_1 x_n + b_1) & \cdots & g(\omega_m x_n + b_m) \end{bmatrix} \quad (18)$$

其中,  $\omega$  表示隐藏层节点的权重,  $b$  表示隐藏层节点的偏置,  $m$  表示隐藏层的神经元个数。

$$H\beta = T \quad (19)$$

其中,  $\beta$  表示输出层权重矩阵,  $T$  表示期望输出矩阵。

为了增强 ELM 网络的稳定性, 将惩罚系数  $C$  和单位矩阵  $I$  引入, 则输出权值的最小二乘解为:

$$\beta = H^T(HH^T + \frac{I}{C})^{-1}T \quad (20)$$

引入核函数到 ELM 中, 核矩阵  $\Omega_{ELM}$  为:

$$\Omega_{ELM} = HH^T = h(x_i)h(x_j) = K(x_i, x_j) \quad (21)$$

其中,  $K(\cdot)$  表示核函数。

在本次实验中, 为了提高运算速度, 减少参数设置, 选择径向基核函数, 即:

$$K(x_i, x_j) = \exp(-\frac{\|x_i - x_j\|^2}{2\gamma^2}) \quad (22)$$

综上, KELM 的诊断输出函数为:

$$F(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_m) \end{bmatrix} (\Omega + \frac{I}{C})^{-1}T \quad (23)$$

根据以上描述, 参数  $C$  和  $\gamma$  将会影响 KELM 的诊断性能。

## 2 故障诊断模型

对滚动轴承原始信号进行 EEMD 分解, 会得到若干 IMF 分量, 计算它们的相关系数, 然后筛选有效的 IMF 分量, 计算它们的能量熵, 构建特征向量数据集, 输入到 GJO-KELM 分类模型中。具体的诊断流程图如图 1 所示。




图 1 滚动轴承故障诊断流程图

其中, 使用 GJO 优化 KELM 的流程图如图 2 所示。

具体步骤如下:

步骤 1) 将特征向量数据集输入 KELM 中。

步骤 2) 初始化种群, 并计算种群适应度值。

步骤 3) 根据适应度值的大小, 确定金豺对和猎物的位置。

步骤 4) 计算猎物能量的大小, 执行相应的位置更新公式。

步骤 5) 重复步骤 2)~4), 直到满足终止条件, 输出最佳参数  $C$  和  $g$ 。

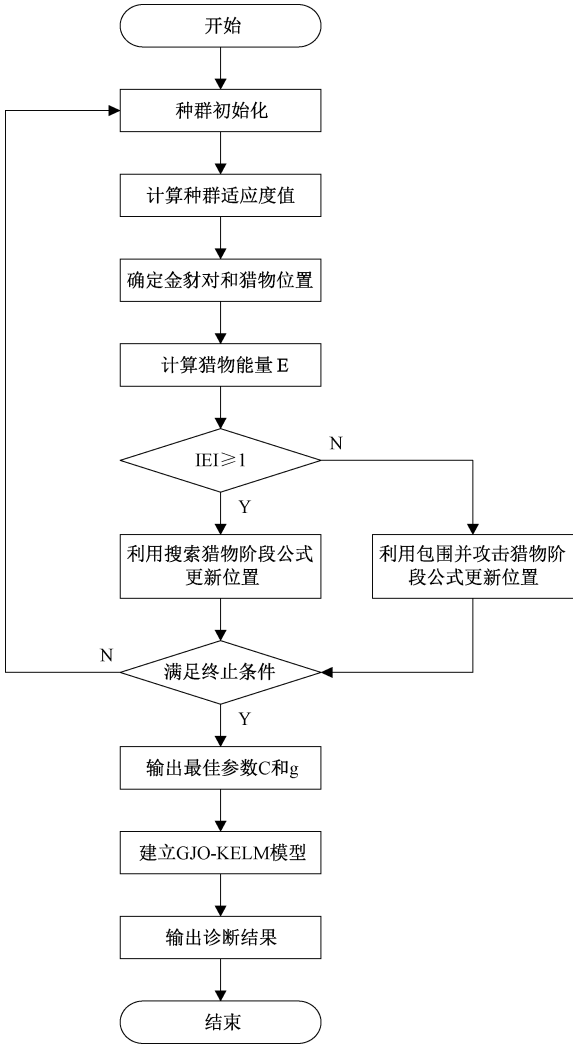


图 2 GJO-KELM 优化流程图

步骤 6) 建立 GJO-KELM 模型, 输出诊断结果。

3 实验分析

为了验证本文提出的故障诊断模型是可行的, 经过 GJO 优化后的 KELM 能够提高分类准确率, 现进行如下实验。

在实验开始之前, 需要给作对比的机器学习算法设置参数: 其中, 将 ELM 的隐藏层个数设置为 20, 选择 Sigmoid 函数作为激活函数; SVM 的惩罚系数取 0.2, 核参数取 10; RF 的决策树数目是 2, 最小叶子数取值为 8; KELM 的正则化系数取 10, 核参数是 0.5, 核函数是径向基函数; 金豺优化算法的种群数量是 20, 最大迭代次数是 100, 参数维度是 2, 参数变量下界是 0.01, 上界是 20。

3.1 实验数据

本文采用美国西储大学 SKF6205 驱动端轴承, 在 12 kHz、0 负载情况下测试得到的数据集<sup>[18]</sup>。该数据集包括正常状态、滚动体故障、内圈故障和外圈故障 4 种工作状

态, 其中, 在故障情况下, 轴承故障直径有 0.177 8、0.355 6 和 0.533 4 mm 3 种, 因此, 有 9 种故障状态和 1 种正常状态, 共 10 种类型的轴承数据作为实验样本, 将每个样本的数据序列长度设置为 2 048, 每种类型数据提取 50 组, 所以数据集共有 500 组。在进行实验时, 在打乱数据集原有顺序之后, 以 3 : 2 的比例划分训练集和测试集, 以数字 1 表示正常状态, 数字 2 表示滚动体故障状态, 数字 3 表示内圈故障状态, 数字 4 表示外圈故障状态, 具体分配如表 1 所示。

表 1 实验样本表

状态类型	故障尺寸/mm	样本数	标签
正常状态	0	50	1
滚动体故障	0.177 8	50	2
	0.355 6	50	2
	0.533 4	50	2
内圈故障	0.177 8	50	3
	0.533 4	50	3
	0.355 6	50	3
外圈故障	0.177 8	50	4
	0.355 6	50	4
	0.533 4	50	4

3.2 信号分解与特征提取

本文所采用的滚动轴承数据集, 不同状态信号的时域波形图如图 3 所示。

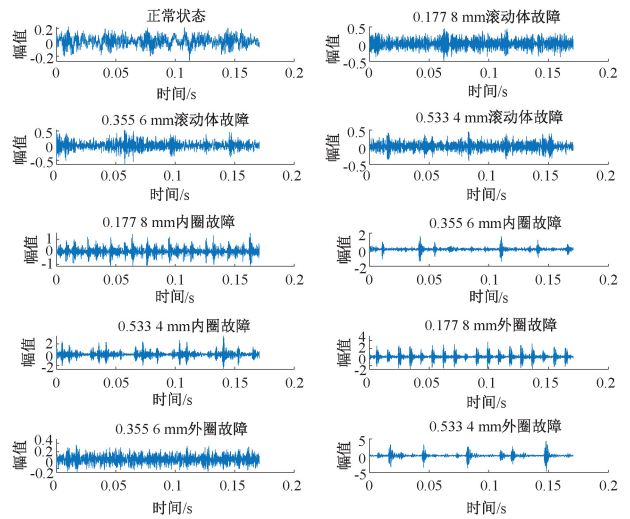


图 3 不同状态信号的时域波形图

图 3 表明, 仅凭肉眼观察滚动轴承不同类型故障的时域波形图, 不能有效地判断出是何种故障, 因此需要进行信号分解, 从而发现其中隐藏的关键信息。

对滚动轴承正常状态进行 EEMD 分解得到的 IMF 分量图如图 4 所示。故障状态下数据类型较多, 篇幅有限, 这



里只展示故障直径为 0.177 8 mm 的 EEMD 分解图,如图 5~7 所示。




图 4 正常状态 EEMD 信号分解图

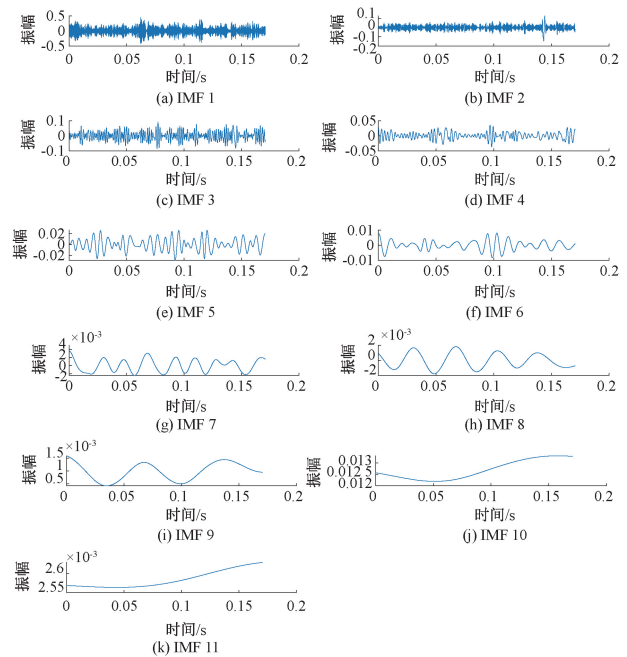


图 5 滚动体故障状态 EEMD 信号分解图

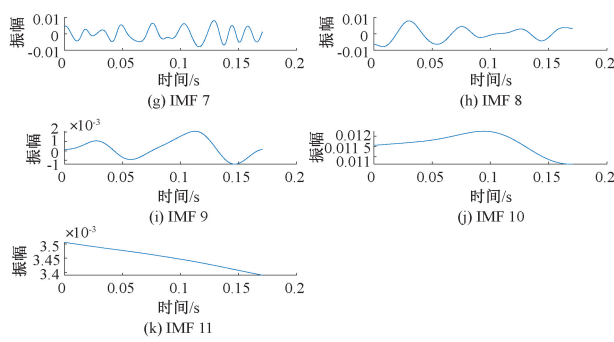
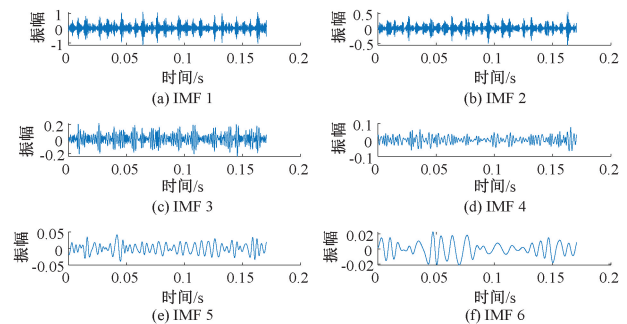


图 6 内圈故障状态 EEMD 信号分解图

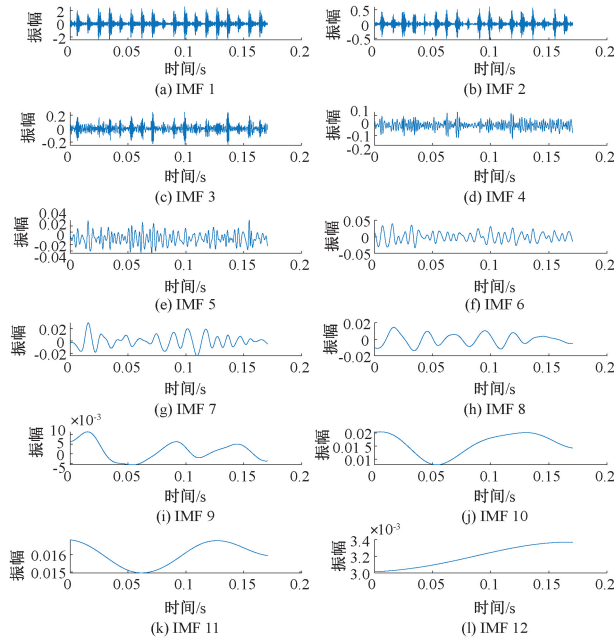


图 7 外圈故障状态 EEMD 信号分解图

在滚动轴承的 4 种状态下,数据序列经过 EEMD 分解,得到的 IMF 分量与原始信号之间的相关系数图如图 8 所示。




图 8 IMF 分量与原始信号的相关系数图

为了最大程度表示原信号的特征,根据相关系数图,选取前 6 个 IMF 分量,计算他们的能量熵,构成本次实验的特征数据集,部分样本的特征向量如表 2 所示。

表 2 部分样本特征向量

标签	$E_1$	$E_2$	$E_3$	$E_4$	$E_5$	$E_6$
1	0.355	0.351	0.274	0.132	0.154	0.069
2	0.087	0.134	0.108	0.028	0.027	0.001
2	0.166	0.208	0.194	0.076	0.026	0.002
2	0.127	0.135	0.151	0.030	0.030	0.003
3	0.189	0.290	0.148	0.027	0.013	0.003
3	0.092	0.125	0.068	0.049	0.012	0.002
3	0.054	0.121	0.058	0.023	0.003	0.001
4	0.029	0.078	0.024	0.015	0.004	0.003
4	0.173	0.199	0.173	0.079	0.041	0.008
4	0.087	0.158	0.107	0.028	0.005	0.001

3.3 故障识别

本文将金豺优化算法优化的核极限学习机(GJO-KELM)与极限学习机(ELM)、随机森林(RF)、支持向量机(SVM)、核极限学习机(KELM)作对比分析,对特征向量数据集进行分类识别。上述几种方法对测试集单次诊断结果如图 9~13 所示。




图 11 RF 测试集单次诊断图




图 12 KELM 测试集单次诊断图

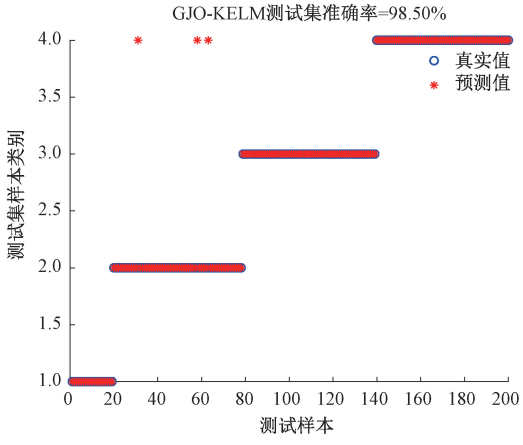


图 13 GJO-KELM 测试集单次诊断图




图 9 ELM 测试集单次诊断图




图 10 SVM 测试集单次诊断图

图 9 表明,ELM 的正确率只有 86.00%,对滚动轴承的每种状态均出现了多个误判的情况,尤其在诊断外圈故障时表现糟糕。

图 10 表明,SVM 的正确率是 87.00%,相较于 ELM,在识别外圈故障时,有了明显进步,但是在识别滚动轴承正常状态方面表现欠佳,超过半数的样本出现了误判的情况。

图 11 表明, RF 的正确率是 90.50%, 比 ELM 高 4.50%, 比 SVM 高 3.50%, 对于滚动轴承的正常状态, 做到了全部正确识别, 但是 3 种故障状态, 还都存在识别错误的情况, 远远没有达到预想效果。

图 12 表明, KELM 的正确率是 96.50%, 可以将滚动轴承的正常状态和内圈故障全部识别正确, 但是将 2 个外圈故障识别为内圈故障, 将 5 个滚动体故障错误判断为其他状态。

图 13 表明, GJO 优化后的 KELM, 正确率高达 98.50%, 基本可以做到精准识别, 只在诊断滚动体故障时, 将 3 例样本错误判断为外圈故障, 但仍然比 KELM 的诊断准确率提高了 2.00%, 与前面几种其他算法相比, 其诊断正确率有较大提高, 故 GJO-KELM 用于滚动轴承的故障诊断是行之有效的。

为了全面评估模型性能, 保证实验结果的准确性和可信度, 对上述所有分类方法进行 30 次重复实验。在完成实验后, 分别计算训练集和测试集的均值与标准差, 具体数据整理如表 3 所示。

表 3 实验结果对比表 %

故障诊断方法	训练集准确率均值	标准差	测试集准确率均值	标准差
ELM	88.06	3.06	86.15	3.21
SVM	92.32	2.59	86.80	2.50
RF	94.50	1.48	90.82	2.04
KELM	97.97	0.51	96.73	1.30
GJO-KELM	99.53	0.78	98.47	0.84

4 结 论

通过研究证明, 本文提出的 EEMD 能量熵和 GJO-KELM 故障诊断模型, 用于识别不同类型的轴承故障是正确的和有效的; 在 KELM 关键参数的选择上, 采用 GJO 算法对其进行寻优操作, 可以自适应确定参数取值, 提高了 KELM 的诊断精度; 但是, 该诊断模型在识别轴承的滚动体故障还存在不足, 可以考虑选取其他更优的信号分解方法或优化算法。

参考文献

[1] 朱良玉, 崔倩文, 陶林, 等. 滚动轴承故障定量诊断方法综述[J]. 轴承, 2023, (2): 1-11.

[2] 史鸣, 潘长领, 许自强. 基于振动的机车轴箱轴承故障诊断[J]. 铁道机车车辆, 2023, 43(5): 85-90.

[3] 赵磊, 张永祥, 朱丹宸. 复杂装备滚动轴承的故障诊断与预测方法研究综述[J]. 中国测试, 2020, 46(3): 17-25.

[4] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings Mathematical Physical &

Engineering Sciences, 1998, 454(1971):903-995.

[5] 单显明, 那崇正, 汤健, 等. 基于 CEEMDAN-GPR 的球磨机负荷软测量[J]. 电子测量技术, 2022, 45(17): 127-133.

[6] 刘少康, 武英杰, 安伟伦, 等. 基于声音信号和改进 MS-LMD 的风电齿轮箱故障诊断[J]. 振动与冲击, 2021, 40(11):230-239.

[7] ZHAOHUA W, NORDEN E, HUANG. Ensemble empirical mode decomposition: A noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1):1-41.

[8] 朱俊杰, 张清华, 朱冠华, 等. 基于 EEMD 和 CNN-SVM 的滚动轴承故障诊断[J/OL]. 机床与液压, 2023, (12): 1-9.

[9] 高淑芝, 王拳, 张义民. EEMD 熵特征和 t-SNE 相结合的滚动轴承故障诊断[J]. 机械设计与制造, 2023, (6): 229-233.

[10] 周静雷, 房乔楚, 颜婷. EEMD 样本熵的扬声器异常音分类方法[J]. 电子测量与仪器学报, 2019, 33(4): 195-201.

[11] HUANG G B, ZHOU H M, DING X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(2): 513-529.

[12] 米根锁, 窦媛媛. 基于 CEEMDAN 与改进核极限学习机的 S700K 转辙机健康状态诊断[J]. 电子测量与仪器学报, 2023, 37(6):232-239.

[13] 汤占军, 孙栋钦, 李英娜, 等. 基于特征融合的风机叶片表面缺陷检测模型[J]. 电子测量技术, 2022, 45(11): 161-166.

[14] CHOPRA N, ANSARI M M. Golden jackal optimization: A novel nature-inspired optimizer for engineering applications [J]. Expert Systems with Applications, 2022(198): 116924. 1-116924. 15.

[15] 王洪, 张锐丽, 吴凯. 基于 ICEEMDAN 和 IMWPE-LDA-BOA-SVM 的齿轮箱损伤识别模型[J]. 机电工程, 2023, 40(11):1709-1717.

[16] 杨旭, 张涛, 李玉梅, 等. ISSA 优化 SVM 的电机滚动轴承故障诊断[J]. 电子测量技术, 2023, 46(15):186-192.

[17] 易灵芝, 龙娇, 王雅慧, 等. 基于改进天鹰算法优化核极限学习机的油浸式变压器故障诊断研究[J]. 湖南电力, 2022, 42(6):7-14.

[18] HENDRIKS J, DUMOND P, KNOX DA. Towards better benchmarking using the CWRU bearing fault dataset[J]. Mechanical Systems and Signal Processing, 2022, 169(2):108-732.

作者简介

史书杰, 硕士研究生, 主要从事故障诊断与信号处理研究。

赵凤强, 副教授, 博士, 主要从事智能系统优化、故障诊断及环境噪声监测与控制研究。

E-mail: fqzhao2002@163.com