

DOI:10.19651/j.cnki.emt.2416272

# 基于 IESOA-BP 的滚动轴承故障诊断\*

张炎亮 回彦静 王研迪  
(郑州大学管理学院 郑州 450001)

**摘要:** 在机械设备故障诊断中,输入特征向量的差异会影响诊断精度,为了提高智能制造模式下滚动轴承故障诊断的准确性和可靠性,提出一种基于变分模态分解(VMD)和时频域熵的故障特征提取结合改进的白鹭群算法(IESOA)优化BP神经网络的故障诊断方法。首先,借助变分模态分解,成功解决模式混叠的问题;其次,提取各模态分量的时域香农熵和频域频谱熵构造故障特征向量,作为故障诊断模型的输入;再次,引入霍尔顿序列初始化白鹭种群,增强白鹭群优化算法的全局寻优能力,构建改进的白鹭群算法以优化BP神经网络(IESOA-BP),最后用美国凯斯西储大学轴承数据集进行仿真;研究结果表明,VMD加时频域熵表征故障特征信息更丰富;相较于传统BP、PSO-BP、SSA-BP、ESOA-BP、SCESOA-BP等方法,IESOA-BP方法在滚动轴承故障诊断方面表现出更高的分类准确率和更好的稳定性。

**关键词:** 故障诊断;白鹭群优化算法;变分模态分解;霍尔顿序列;滚动轴承

**中图分类号:** TH133.3;TN98 **文献标识码:** A **国家标准学科分类代码:** 460

## Fault diagnosis of rolling bearing based on IESOA-BP

Zhang Yanliang Hui Yanjing Wang Yandi  
(School of Management, Zhengzhou University, Zhengzhou 450001, China)

**Abstract:** In order to improve the accuracy and reliability of rolling bearing fault diagnosis in intelligent manufacturing mode, a fault diagnosis method based on Variational Mode Decomposition (VMD) and time-frequency domain entropy combined with improved Egret Swarm Algorithm (IESOA) to optimize BP neural network was proposed. Firstly, with the help of variational mode decomposition, the problem of pattern aliasing was successfully solved. Secondly, the time-domain Shannon entropy and frequency-domain spectral entropy of each modal component were extracted to construct fault feature vectors as input to the fault diagnosis model. Thirdly, the Halton sequence was introduced to initialize the egret population, the global optimization ability of the egret population optimization algorithm was enhanced, and the improved egret population algorithm was constructed to optimize the BP neural network (IESOA-BP), and finally the bearing dataset of Case Western Reserve University in United States was used for simulation. The results show that the entropy in the frequency domain of VMD time-added is more abundant in the characterization of fault characteristics. Compared with the traditional methods such as BP, PSO-BP, SSA-BP, ESOA-BP and SCESOA-BP, the IESOA-BP method shows higher classification accuracy and better stability in the fault diagnosis of rolling bearings.

**Keywords:** fault diagnosis; egret swarm optimization algorithm; variational mode decomposition; Halton sequence; rolling bearing

## 0 引言

在智能制造背景下,制造环节正经历着革命性的变革。文献[1]提出智能制造主要应用了数字化、自动化和智能化方法显著提高制造环节的生产效率和产品质量。在此模式

下,设备智能故障诊断方法的便捷性、准确性、可靠性成为关键。因此,作为技术支持的传感器和实时数据采集系统可以提供更准确的数据支持,使异常情况能够迅速捕捉定位,设备故障诊断的准确性高低不仅有助于降低因生产中带来的时间成本,而且有利于控制维修成本,从而推动制

收稿日期:2024-06-20

\* 基金项目:河南省高等学校重点科研项目计划(23A630006)资助

造业朝着更高效可靠的方向发展。

滚动轴承属于机械设备中重要的组成部件,对设备的性能和使用寿命具有关键性影响。一旦滚动轴承出现问题,就会极大地降低机械设备的运行效率,甚至导致设备损坏。数据表明,在所有旋转机械中,由轴承损伤引起的失效问题占到将近 40%。因此,进行滚动轴承的故障诊断研究意义重大。

滚动轴承的故障诊断方法主要包括决策树、支持向量机和神经网络。文献[2]提出利用决策树,在小规模故障诊断问题上效果良好,但处理高维复杂数据分类时表现不佳。文献[3]提出利用支持向量机,适用于分类,但对于缺失数据敏感。与之对比,文献[4]提出利用神经网络,可以通过非线性映射和自适应学习进行信息分布式处理。其中,文献[5]提出利用浅层反向传播(shallow backpropagation, BP)神经网络,其模型流程简洁并且训练效率较高,因此在故障诊断中得到广泛应用。

在将 BP 神经网络应用于故障诊断中,其权值和阈值会对诊断精度产生影响。为克服此问题,研究者们采用了各种智能算法来优化其权重和阈值。文献[6]提出利用遗传算法(genetic algorithm, GA)来优化 BP 神经网络。然而,GA 的参数较多,局部寻优能力较差,且存在实时性和易于早熟收敛的问题。文献[7]提出利用粒子群优化算法(particle swarm optimization, PSO)优化 BP 神经网络。PSO 结构简单、调节参数较少且收敛速度较快。但仍存在诊断准确率较低和不稳定性的局限性。随着研究的深入该领域陆续出现了许多智能优化算法,如文献[8]提出麻雀搜索算法(sparrow search algorithm, SSA)、文献[9]提出灰狼优化算法(grey wolf optimizer, GWO)等。其中文献[10]提出的白鹭群优化算法(egret swarm optimization algorithm, ESOA)在局部寻优方面表现更为优越,有助于避免过早收敛和陷入局部最优值的题。文献[11]提出引入正余弦算法改进 ESOA (sine cosine egret swarm optimization algorithm, SCESOA)优化燃气轮机冷却控制系统,取得良好效果。但上述改进算法仍存在一定的局限,在故障诊断精度及模型稳定性等方面仍需进一步改进空间。

在滚动轴承故障诊断中,建立适当的输入特征向量对于增强诊断准确性具有极其重要的作用。目前,主要采用 3 种时频处理方法来构建特征向量,分别为经验模态分解(empirical mode decomposition, EMD)、集成经验模态分解(ensemble empirical mode decomposition, EEMD)和变分模态分解(variational mode decomposition, VMD)。文献[12]提出利用 EMD,但是 EMD 存在模态混叠问题,从而影响了特征提取的准确性。文献[13]提出利用 EEMD,通过对信号添加噪声来解决模态混叠的问题。但引入噪声可能导致信号信息丢失,仍存在一定局限性。文献[14]提出利用 VMD 能够逐步分解信号并产生更加集中的带宽分量,从而克服了 EMD 和 EEMD 所面临的问题。并且,VMD 需要调整的参

数更少,借助各种信息熵的结合,VMD 构建的特征向量能够有效地提取滚动轴承故障信号的特征。

针对旋转机械滚动轴承故障诊断中 BP 神经网络参数和网络输入特征向量对精度的影响,本文提出了一种改进的故障诊断方法,基于变分模态分解和文献[15]提出的霍尔顿序列(Halton squence, HALTON)改进白鹭群算法(improved egret swarm optimization algorithm, IESOA)来优化 BP 神经网络:首先,采用 VMD 结合时域香农熵和频域频谱熵的方法构建信号特征向量。这一方法解决了仅使用 VMD 结合单一信息熵构建信号特征向量的不足,能够更充分地提取故障信号的特征。其次,通过 IESOA 算法获得 BP 神经网络的最优权值和阈值。传统的 BP 网络容易陷入局部最优,将会降低故障诊断的准确性。通过 IESOA 算法,可以避免这一问题,提高 BP 神经网络的性能。

## 1 VMD 熵特征矩阵

本文提出的改进的故障诊断方法如图 1 所示。

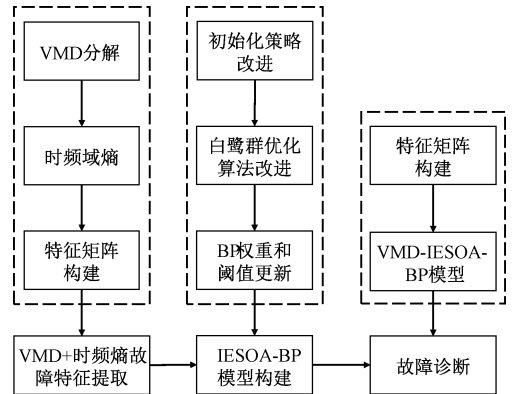


图 1 故障诊断模型

Fig. 1 Fault diagnosis model

VMD 是一种用于信号分解的方法,通过将信号拆分为多个噪声和本征模态分量(intrinsic mode function, IMF)的组合,从而得到信号的本征模态函数。VMD 在时频领域具有良好的局部化性质和高分辨能力,适用于非平稳和非线性信号的分析。其可以表示为以下变分模型:

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

其中,  $u_k$  为模态函数;  $\omega_k$  为各中心频率;  $\delta(t)$  为脉冲函数;  $f$  为原始信号。

为了获得式(1)的最优解,构建增广拉格朗日函数,即:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^k \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^k u_k(t) \right\|_2^2 + \lambda(t), f(t) - \sum_{k=1}^k u_k(t) \quad (2)$$

式(2)中,  $\lambda(t)$  为拉格朗日乘子,  $\alpha$  为二次惩罚因子。

利用交替方向乘子方法反复迭代寻找式(2)的鞍点。

获得  $u_k$ 、 $\omega_k$  的表达式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (5)$$

其中,  $n$  为迭代次数;  $\varepsilon$  为判别精度。当迭代满足式(5)时,求解完毕。

在轴承出现故障时,其振动信号的幅值将会发生变化,从而引起信号中各频率、各时间点的能量分布也将随之改变。时频域信息熵是一种常用的信息处理方法,尤其适用于提取机械设备不同状态下振动信号的时频域信息。本文针对轴承故障特征的提取,采用了以下方法:首先,对振动信号进行变分模态分解将信号分解成不同频率的 IMF,有助于捕捉信号中的不同频率成分。然后,针对每个 IMF,计算其时域香农熵和频域频谱熵,以获取其在时频域上的能量分布特性。这种方法结合了 VMD 分解和时频域熵计算,有助于全面地提取出轴承故障特征,从而在故障诊断中起到重要作用。

## 2 IESOA-BP 算法

### 2.1 ESOA 算法

ESOA 由陈祖岩等于 2022 年提出。ESOA 的灵感来自于雪白鹭和大白鹭的捕食行为,主要包括 3 个部分:坐等策略,攻击策略和判别条件。种群可以由  $n$  个白鹭团队组成,每个白鹭团队包括 3 只白鹭。白鹭 A 采取坐等策略,白鹭 B 和白鹭 C 在攻击策略中分别采用随机游走和包围机制。与其他群智能算法相比,ESOA 具有原理简单、兼顾开发与探索、变动参数比较少等优点。

#### 1) 坐等策略

观测方程,假设  $\hat{y}$  是估计的当前猎物位置,第  $i$  个白鹭 A 的初始位置为  $x_i \in R^n$ ,  $n$  为空间维度。 $\omega_i$  是对当前位置可能存在猎物的权重估计方法,它的误差方程可以描述为  $e_i$ 。

$$\hat{y}_i = \omega_i \cdot x_i \quad (6)$$

$$e_i = \|\hat{y}_i - y_i\|^2 / 2 \quad (7)$$

同时,对误差方程  $e_i$  求  $\omega_i$  的偏导数,可以得到  $\omega_i$  的实

际梯度  $\hat{g}_i$ , 梯度方向为  $\hat{d}_i$ 。

$$\hat{g}_i = \partial \hat{e}_i / \partial \hat{\omega}_i = \frac{\partial \|\hat{y}_i - y_i\|^2 / 2}{\partial \hat{\omega}_i} = (\hat{y}_i - y_i) \cdot x_i \quad (8)$$

$$\hat{d}_i = \hat{g}_i / |\hat{g}_i| \quad (9)$$

白鹭会借鉴以往捕食方向的经验修正群体最佳位置和个体最佳位置。 $d_{h,i}$  为群体最佳位置的的方向修正量,  $d_{g,i}$  为个体最佳位置的方向修正量。

$$d_{h,i} = \frac{x_{ibest} - x_i}{|x_{ibest} - x_i|} \cdot \frac{f_{ibest} - f_i}{|f_{ibest} - f_i|} + d_{ibest} \quad (10)$$

$$d_{g,i} = \frac{x_{gbest} - x_i}{|x_{gbest} - x_i|} \cdot \frac{f_{gbest} - f_i}{|f_{gbest} - f_i|} + d_{gbest} \quad (11)$$

其中,  $d_{ibest}$  表示白鹭群体中最优秀个体的飞行方向,  $d_{gbest}$  表示白鹭群体中最优秀个体的飞行方向。 $x_{ibest}$  和  $x_{gbest}$  个体和种群的最优值。 $f_{ibest}$  和  $f_{gbest}$  是白鹭群个体和种群的最佳适合度。

积分梯度  $g_i$  表达式如下,其中  $r_h \in [0, 0.5]$ ,  $r_g \in [0, 0.5]$ 。

$$g_i = (1 - r_h - r_g) \hat{d}_i + r_h \cdot d_{h,i} + r_g \cdot d_{g,i} \quad (12)$$

$\omega_i$  是一个随机生成的位置。 $\omega_i$  的更新方式如下:

$$m_i = \beta_1 \cdot m_i + (1 - \beta_1) \cdot g_i \quad (13)$$

$$v_i = \beta_2 \cdot v_i + (1 - \beta_2) \cdot g_i^2 \quad (14)$$

$$\omega_i = \omega_i - m_i / \sqrt{v_i} \quad (15)$$

其中,  $\beta_1$  设为 0.9,  $\beta_2$  设为 0.99,  $m_i$  和  $v_i$  的初始值设为 0。白鹭 A 的位置  $x_{a,i}$  更新为:

$$x_{a,i} = x_i + step_a \cdot \exp(-t / (0.1 \cdot t_{max})) hop \cdot g_i \quad (16)$$

其中,  $t$  和  $t_{max}$  分别为当前迭代时间和最大迭代时间,  $hop$  为解空间下界和上界之间的距离。 $step_a \in (0, 1]$  为白鹭 A 的步长因子。

#### 2) 攻击策略

白鹭 B 的攻击策略是随机行走。虽然能量消耗较大,但白鹭 B 可能获得更高效益。白鹭 B 的位置更新方程为:

$$x_{b,i} = x_i + step_b \cdot \tan(r_{b,i}) \cdot hop / (1 + t) \quad (17)$$

其中,  $r_{b,i}$  是包含于区间  $(-\pi/2, \pi/2)$  的随机数,  $step_b \in (0, 1]$  为白鹭 B 的步长因子。

白鹭 C 采取包围战略。一旦发现猎物,它就会一直追逐,直到猎物被抓住为止。

$$D_h = x_{ibest} - x_i \quad (18)$$

$$D_g = x_{gbest} - x_i \quad (19)$$

$$x_{c,i} = (1 - r_i - r_g) x_i + r_h \cdot D_h + r_g \cdot D_g \quad (20)$$

其中,  $D_h$  是当前位置和这个白鹭队伍最佳位置之间的差距,  $D_g$  是所有白鹭队伍最佳位置之间的差距。

#### 3) 判别条件

白鹭队的每只白鹭计算出更新后的位置后,共同确定白鹭队更新后的位置。解矩阵为:

$$x_{s,i} = [x_{a,i}, x_{b,i}, x_{c,i}] \quad (21)$$

白鹭团队将更新后的 3 只白鹭的位置和适合度与之前迭代的位置和适合度进行比较。如果一个白鹭的更新位置比前一次迭代的位置好,它将采用更新。如果所有白鹭的

更新位置都比前一个白鹭差,则有 30% 的概率采用更新位置差的方案。

### 2.2 IESOA 算法

本文提出的 IESOA-BP 算法,通过 HALTON 序列初始化白鹭群的位置,实现种群更好的均匀分布。种群更好地覆盖整个搜索空间,可以提高种群的质量,增强 ESOA 算法的全局寻优能力,进而降低陷入局部极值的风险。原式(6)改为:

$$\hat{y}_i = \omega_i \cdot x_i(n) \quad (22)$$

$$n = \sum_{i=1}^m k_i \cdot q^i = k_m \cdot q^m + \dots + k_1 \cdot q^1 + k_0 \quad (23)$$

$$x_i(n) = k_0 \cdot q^{-1} + k_1 \cdot q^{-2} + \dots + k_m \cdot q^{-m-1} \quad (24)$$

其中,  $n \in (1, N)$  是整数;  $q \geq 2$  是一个质数,用来表示 HALTON 序列的基础量;  $k_i \in \{0, 1, 2, \dots, p-1\}$  是常数,用来组合生成 HALTON 序列的各维度。

利用 IESOA 算法,对 BP 神经网络进行深度优化,确保获取最优的权重和阈值。在这一模型中,IESOA 算法充分发挥了其在全局搜索和优化领域的特点,为 BP 神经网络的权重和阈值寻找到更加精准的组合,使得模型在故障诊断时表现出更高的精确性和可靠性。IESOA-BP 算法的流程图如图 2 所示。

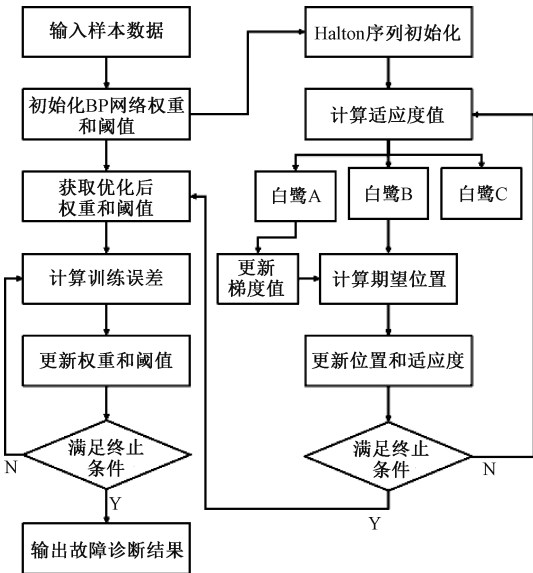


图 2 IESOA-BP 算法流程图  
Fig. 2 IESOA-BP algorithm flow

### 3 VMD-IESOA-BP 模型构建

本文提出的混合算法为基于 VMD 组合熵结合 IESOA-BP 的智能制造故障诊断方法,其流程可以具体划分为 4 个步骤:

- 1) 运用 VMD 分解样本数据信号,得到各信号的 IMF。
- 2) 计算各 IMF 的香农熵和频谱熵,构建多维度特征向量,然后按照 3 : 1 随机划分为训练集和测试集,用于神经

网络的故障诊断。

3) 利用 IESOA 算法将划分好的带标签训练集输入到 BP 神经网络中,以获得最佳权重和阈值,从而提升 BP 神经网络在故障诊断中的性能。

4) 得到优化后的 BP 模型,将之前划分的测试集输入神经网络,得到故障诊断结果,测试模型的性能。

计算组合熵时,每个 IMF 各输出一个香农熵、频谱熵,特征向量的维度为 8,因此确定输入层节点等于 8;滚动轴承存在 4 种标签,因此输出层节点数等于 4。隐藏层节点数选取可参照经验式(25):

$$n_1 = \sqrt{m+n} + a \quad (25)$$

式中:  $n_1$  为隐藏层节点;  $m$  为输出层节点;  $n$  为输入层节点;  $a$  取自区间  $[1, 10]$ 。

据式(25),  $n_1$  取值范围是  $[4, 13]$ 。实验可知,当隐藏层节点数取值为 6 时,神经网络诊断的准确率最高。因此本文的神经网络结构为 8-6-4。

## 4 故障诊断模型实验验证

### 4.1 实验数据


实验采用了美国凯斯西储大学提供的一组采样频率为 12 kHz 的滚动轴承振动信号公共数据,以验证所提出方法的有效性。实验涵盖了 4 种不同的轴承状态,分别为 0 负载、1 负载、2 负载条件下的 0.177 8 mm 外圈故障信号、内圈故障信号、滚动体故障信号,以及正常信号。每个数据类别下共选择了 160 个样本数据,每个样本数据的长度为 2 048 个数据点。为确保训练与测试的有效性,按照 3 : 1 的比例对数据进行了训练集与测试集的划分。详细的数据样本组成信息请参如表 1 所示。

表 1 滚动轴承样本数据集  
Table 1 Sample data set of rolling bearings


负载/ hp	损坏 位置	损坏尺寸/ mm	样本 数量	类别 标签
0/1/2/	正常	—	160	1000
0/1/2/	内圈	0.177 8	160	0100
0/1/2/	滚动体	0.177 8	160	0010
0/1/2/	外圈	0.177 8	160	0001

### 4.2 故障特征提取

实验数据集构建完成后,使用 VMD 算法进行信号分解。在 VMD 的分解过程中,着重考虑了两个关键参数,即模态分解数  $K$  和二次惩罚因子  $\alpha$ 。研究过程中,将  $\alpha$  设定为 1 000,  $K$  设定为 4。为了充分呈现 VMD 算法在实验数据集中的性能,以 2 负载条件下发生内圈故障为例,绘制了图 3。图 3(a)为原始信号及各 IMF 时域图,图 3(b)为 IMF 中心频率图。该图清晰地展示了 VMD 算法在信号分解方面的优越性,特别是对于 IMF 的分离以及信号频域特性的明确划分方面。



(a) 原始信号及各IMF时域图  
(a) Timedomain plots of the raw signal and each IMF



(b) 各IMF中心频率图  
(b) Center frequency plot of each IMF

图 3 1 负载下内圈故障 VMD 分解

Fig. 3 VMD breakdown of inner loop failure under load

为了展示故障特征提取方法的效果,运用“t-SNE”方法进行数据可视化。在图 4 中,展示了在 1 负载状态下,原始数据与其他 3 种对比方法的“t-SNE”图。如图 4(a),原始振动数据无法区分。从图 4(b)中明显可知,采用 EMD+组合熵构建的特征向量在故障信号特征提取方面效果最差,4 种轴承状态混合在一起,难以区分。图 4(c)显示,采用 VMD+单一熵值构建的特征向量能相对有效地区分正常状态和滚动体故障状态,但内圈和外圈故障的信号特征会重叠,难以区分。至于图 4(d),展示了本文采用的 VMD+组合熵的特征向量构建方法,能清晰地区分出不同的 4 种故障状态。

### 4.3 轴承故障诊断结果及分析

为了验证模型的有效性,建立 ESOA-BP 与 IESOA-BP 模型的对比实验,如图 5 所示。在对 BP 神经网络进行参数寻优时,IESOA 算法初始适应度值与收敛值均小于 ESOA 算法。并且,IESOA 算法在迭代 11 次左右达到收

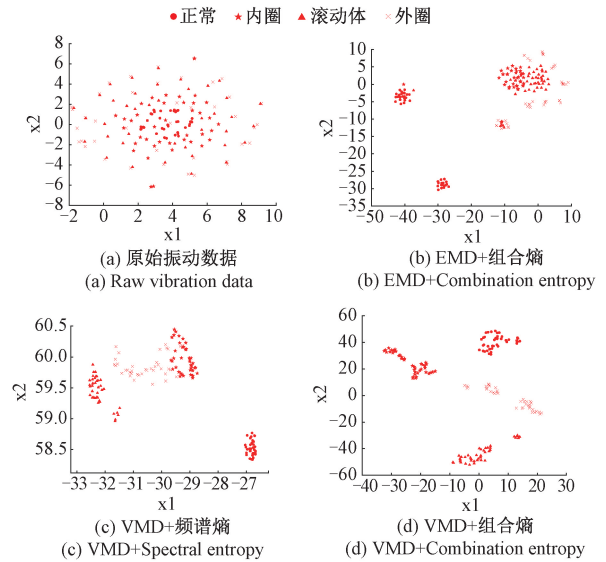


图 4 不同提取方法的“t-SNE”可视化

Fig. 4 Visualization of “t-SNE” for different extraction methods

敛,ESOA 算法在迭代 16 次左右达到收敛,表明 IESOA 比 ESOA 收敛速度更快。




图 5 算法改进前后适应度变化曲线对比图

Fig. 5 Comparison of fitness change curves before and after algorithm improvement

为了进行故障类型诊断的对比研究,选取 BP、PSO-BP、SSA-BP、ESOA-BP、SCESOA-BP 作为对照组。为确保公平,均采用 VMD 组合熵的方法构建输入特征向量;每组实验的训练数据集和测试数据集均按照 3:1 的比例进行划分。本实验针对涵盖 3 种不同负载情况的对比研究进行了深入分析,相关模型的诊断结果如表 2 所示。在诊断精度方面,经对比实验表明,IESOA-BP 算法表现出卓越优势,超越了原始的 BP 算法、对比的 PSO-BP 算法、ESOA-BP 算法、SCESOA-BP 算法、SSA-BP 算法。

经过多次实验验证,IESOA-BP 算法的诊断结果表现出更高的稳定性。为了量化不同算法的稳定性,引入了标准差作为衡量指标。在不同负载条件下,6 种算法结果的

表 2 不同算法诊断精度对比表

Table 2 Comparison of diagnostic accuracy of different algorithms

诊断方法	0 负载	1 负载	2 负载
BP	85.36	79.64	81.79
PSO-BP	92.86	91.43	94.82
SSA-BP	95.71	92.92	96.43
ESOA-BP	92.50	94.29	97.14
SCESOA-BP	93.33	92.92	93.33
IESOA-BP	98.57	97.14	99.29

标准差情况如表 3 所示。从表 3 可以看出, BP 方法的稳定性较差, 特别是在 1 负载条件下, 标准差高达 15.08; PSO-BP 算法、SSA-BP 算法、ESOA-BP 算法和 SCESOA-BP 算法的稳定性差异较小, 但不同负载条件下标准差波动较大; 相较之下, IESOA-BP 算法的稳定性相对更优, 3 种负载下的标准差均小于 2, 与对比算法相比具有明显的优势。考虑到不同算法之间的稳定性差异, 表 2 中的数据结果基于 7 次实验的平均值得出。

表 3 不同算法诊断精度标准差对比表

Table 3 Comparison of standard deviation of diagnostic accuracy of different algorithms

诊断方法	标准差		
	0 负载	1 负载	2 负载
BP	8.81	15.08	13.07
PSO-BP	7.12	3.98	4.25
SSA-BP	2.90	6.02	2.95
ESOA-BP	5.00	3.19	2.81
SCESOA-BP	4.49	5.29	4.71
IESOA-BP	1.82	1.60	1.13

## 5 结 论

利用 VMD 结合时域香农熵与频域频谱熵, 更加充分提取振动信号在不同时间段、不同频段的能量分布特征, 构建故障特征信息更加完整的信号特征向量。在标准的 ESOA 中加入 HALTON 序列, 均匀分布种群的初始位置, 提高 ESOA 的全局搜索能力, 避免因初始位置集中, 算法陷入局部最优。并且利用 IESOA 优化 BP 网络, 得到了精度更高、稳定性更好的故障类型诊断模型。通过与多组其他算法的实验对比表明, VMD-IESOA-BP 故障诊断模型在故障特征提取与故障诊断方面性能均优于对比算法, 并且算法的稳定性更好。

## 参 考 文 献

[1] TANG H T, GAO SH B, WANG L, et al. A novel intelligent fault diagnosis method for rolling bearings

based on wasserstein generative adversarial network and convolutional neural network under unbalanced dataset [J]. *Sensors (Basel, Switzerland)*, 2021, 21(20):6754-6754.

- [2] YU Z, ZHANG B, HU G, et al. Early fault diagnosis model design of reciprocating compressor valve based on multiclass support vector machine and decision tree[J]. *Scientific Programming*, 2022(1):1-7.
- [3] 张炎亮, 李营. 基于多尺度排列熵和 IWOA-SVM 的滚动轴承故障诊断[J]. *电子测量技术*, 2023, 46(19): 29-34.
- ZHANG Y L, LI Y. Rolling bearing fault diagnosis based on multi-scale permutation entropy and IWOA-SVM[J]. *Electronic Measurement Technology*, 2023, 46(19):29-34.
- [4] TANG S, YUAN S, ZHU Y. Convolutional neural network in intelligent fault diagnosis toward rotatory machinery[J]. *Ieee Access*, 2020, 8:86510-86519.
- [5] XIAO M, LIAO Y, BARTOS P, et al. Fault diagnosis of rolling bearing based on back propagation neural network optimized by cuckoo search algorithm[J]. *Multimedia Tools and Applications*, 2022, 81(2):1567-1587.
- [6] 何勇, 王红, 谷穗. 一种基于遗传算法的 VMD 参数优化轴承故障诊断新方法[J]. *振动与冲击*, 2021, 40(6): 184-189.
- HE Y, WANG H, GU S. New fault diagnosis approach for bearings based on parameter optimized VMD and genetic algorithm[J]. *Journal of Vibration and Shock*, 2021, 40(6):184-189.
- [7] 王永鼎, 金子琦. 基于融合 CNN 与 PSO-SVM 的滚动轴承故障诊断[J]. *机械强度*, 2021, 43(4):793-797.
- WANG Y D, JIN Z Q. Rolling bearing fault diagnosis based on fusion CNN and PSO-SVM[J]. *Journal of Mechanical Strength*, 2021, 43(4):793-797.
- [8] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [9] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. *Advances in Engineering Software*, 2014, 69: 46-61.
- [10] CHEN Z, FRANCIS A, LI S, et al. Egret swarm optimization algorithm: An evolutionary computation approach for model free optimization[J]. *Biomimetics (Basel, Switzerland)*, 2022, 7(4):144.
- [11] LI T, LIU Y, CHEN Z. Application of sine cosine egret swarm optimization algorithm in gas turbine cooling system[J]. *Systems*, 2022; 10(6):201.

- [12] 雷春丽,焦孟萱,樊高峰,等. 基于 SSA-IWT-EMD 的滚动轴承故障诊断方法[J/OL]. 北京航空航天大学学报, 1-19 [2023-07-10]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0174>.  
LEI CH L, JIAO M X, FAN G F, et al. Rolling bearing fault diagnosis method based on SSA-IWT-EMD [J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 1-19 [2023-07-10]. <https://doi.org/10.13700/j.bh.1001-5965.2023.0174>.
- [13] 王博磊,曹伟,邢红涛,等. 基于 EEMD 多维特征的旋转机械故障识别方法研究[J]. 机床与液压, 2021, 49(21):201-204.  
WANG B L, CAO W, XING H T, et al. Research on rotating machinery fault recognition method based on EEMD multi-dimensional features[J]. Machine Tool & Hydraulics, 2021, 49(21):201-204.
- [14] 陈剑,阚东,孙太华,等. 基于 SVD-VMD 和 SVM 滚动轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(1): 220-226.  
CHEN J, KAN D, SUN T H, et al. Rolling bearing fault

diagnosis method based on SVD-VMD and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 220-226.

- [15] 董跃华,李俊,朱东林. 基于 Halton 序列改进蝠鲞算法的 K-means 图像分割[J]. 电光与控制, 2023, 30(2): 91-98.  
DONG Y H, LI J, ZHU D L, et al. K-means image segmentation based on halton sequence improved manta ray foraging optimization [J]. Electronics Optics & Control, 2023, 30(2):91-98.

### 作者简介

张炎亮,教授,博士,主要研究方向为质量管理、故障诊断。

E-mail:yanliang@zzu.edu.cn

回彦静(通信作者),硕士研究生,主要研究方向为管理科学与工程、故障诊断。

E-mail:huiyanjing2021@163.com

王研迪,硕士研究生,主要研究方向为管理科学与工程、故障诊断。

E-mail:1753564948@qq.com