

## 基于 MWPE 和 DBO-SVM 的齿轮故障诊断\*

飞 能<sup>1</sup>, 钱 晶<sup>1</sup>, 李 佳<sup>1,2</sup>, 张淦源<sup>1</sup>, 杨卫斌<sup>3</sup>, 曾 云<sup>1</sup>, 李 想<sup>1</sup>

(1. 昆明理工大学冶金与能源工程学院 昆明, 650000)

(2. 西安许继电力电子有限公司 西安, 710000)

(3. 昆明电机厂有限责任公司 昆明, 650000)

**摘要** 针对齿轮故障领域识别率低和识别时间长的问题, 基于多尺度加权排列熵(multiscale weighted permutation entropy, 简称 MWPE)、蜣螂算法(dung beetle optimizer, 简称 DBO)与支持向量机(support vector machine, 简称 SVM)的原理, 提出基于 MWPE 和 DBO 结合 SVM 的故障识别方法。首先, 由于 MWPE 的嵌入维数难以确定且对结果影响较大, 通过 MWPE 熵值分析引入变异系数(coefficient of variation, 简称 CV)来确定嵌入维数; 其次, 构建故障特征集; 最后, 利用 DBO 与 SVM 结合的分类器 DBO-SVM 进行故障识别。结果表明: MWPE 与多尺度排列熵(multiscale permutation entropy, 简称 MPE)、多尺度熵(multiscale entropy, 简称 MSE)、多尺度模糊熵(multiscale fuzzy entropy, 简称 MFE)等算法相比, 对齿轮故障信息的提取效果较好; DBO-SVM 分类器在识别准确率和效率上均优于常规优化分类器, 所提方法在齿轮特征测试集上达到 99.13% 的识别准确率, 在噪声状态下达到 94.10% 的识别准确率, 证明 MWPE 的噪声鲁棒性较好。

**关键词** 齿轮故障诊断; 多尺度加权排列熵; 蜣螂算法; 支持向量机; 变异系数; 噪声鲁棒性

**中图分类号** TH132.411; TH113.1

### 引 言

齿轮是机械传动核心部件, 在工业中广泛应用。然而, 齿轮长期连续运行且工况复杂, 易出现故障, 因此开展齿轮故障诊断研究具有重要意义<sup>[1]</sup>。

由于机械振动信号是非线性、非平稳的, 这类信号的特征提取受到科研人员的高度关注。熵值算法是信号特征提取算法中的一类, 如排列熵(permutation entropy, 简称 PE)、MSE<sup>[2-3]</sup>、MFE<sup>[4]</sup>、MPE<sup>[5]</sup>等方法。其中, PE 不依赖时间序列的长短和数值大小, 仅通过相邻数据点获取特征信息, 具有灵敏度高、运算量小、抗噪能力强等优点, 广泛应用于故障诊断领域<sup>[6]</sup>, 然而, 该算法未考虑数据的幅度特性。为此, Xia 等<sup>[7]</sup>提出了加权排列熵(weighted permutation entropy, 简称 WPE)。但是, WPE 和 PE 算法仅能进行单一尺度的分析, 无法多尺度地从突变的复杂信号中提取有用信息。

Yin 等<sup>[8]</sup>将 WPE 融入多尺度, 提出了 MWPE, 克服了信息缺失和单一尺度的局限。Wan 等<sup>[9]</sup>提出了一种 MWPE 和局部线性嵌入相结合的算法, 用于风电轴承性能评价和早期故障识别。Yuan 等<sup>[10]</sup>采

用 MWPE 提取单向阀振动信号特征, 故障诊断准确率达 97.22%。上述研究表明, MWPE 在齿轮故障信号特征提取方面展现出显著优势。

在齿轮故障诊断中, 利用特征信息进行模式识别是故障诊断的关键<sup>[11]</sup>。SVM 在小样本和低维数据的分类上表现出较高的辨识精度, 且用时少, 在故障诊断领域广泛应用<sup>[12]</sup>。然而, 其性能对核函数参数和惩罚因子的敏感性较高。因此, 有研究者采用模拟退火算法<sup>[13]</sup>、人工鱼群算法(artificial fish swarm algorithm, 简称 AFSA)和粒子群算法<sup>[14]</sup>对 SVM 参数进行寻优, 但此类方法寻优时间较长, 且易陷入局部最优解。DBO 同时考虑了全局探索和局部开发, 具有收敛速度快、稳定性好和求解精度高等优点<sup>[15]</sup>。

综上所述, 本研究对 MWPE 算法进行进一步优化, 通过熵值分析, 引入 CV 法对 MWPE 的嵌入维数进行分析确定, 并将其用于提取齿轮故障信息。将 DBO 用于 SVM 参数寻优, 以提高齿轮特征信号的识别率。建立基于 MWPE 提取特征与 DBO-SVM 模式识别的齿轮故障诊断模型, 并将该方法用于分析齿轮振动数据, 为齿轮的故障诊断提供优化策略。

\* 国家自然科学基金资助项目(52269020, 52079059)

收稿日期: 2023-07-30; 修回日期: 2023-10-19

## 1 振动信号特征提取方法

### 1.1 WPE算法

WPE基本理论如下。

1) 对于给定信号序列 $\{A_i\}_{i=1}^N$ ,利用相空间重构理论重构出多个子序列,即

$$X_i^{m,\tau} = \{A_i, A_{i+\tau}, \dots, A_{i+(m-1)\tau}\} \quad (1)$$

其中: $m$ 为嵌入维数; $\tau$ 为时延; $N$ 为信号长度。

2) 为引入信号的幅值特性,计算每个子序列 $X_i^{m,\tau}$ 的权重值 $\omega_i$ 为

$$\omega_i = \frac{1}{m} \sum_{t=1}^m [A_{i+(t-1)\tau} - \overline{X_i^{m,\tau}}]^2 \quad (2)$$

其中: $\overline{X_i^{m,\tau}} = \frac{1}{m} \sum_{t=1}^m A_{i+(t-1)\tau}$ ,为每个子序列的均值。

3) 对于每个信号子序列 $X_i^{m,\tau}$ ,以权重值 $\omega_i$ 和排列组合模式 $\pi_k^{m,\tau}$ 表示特征信息。信号序列的排列模式共有 $K$ 种,每种模式 $\pi_k^{m,\tau}$ 的概率加权值为 $P_\omega(\pi_k^{m,\tau}) =$

$$\frac{\sum \{\omega_i | 1 \leq i \leq N - (m-1)\tau, i \in \mathbf{Z}^+\}}{\sum \omega_i} \quad (3)$$

4) 计算信号序列的WPE( $X, m, \tau$ )为

$$\text{WPE}(X, m, \tau) = - \sum_{k=1}^K P_\omega(\pi_k^{m,\tau}) \log(P_\omega(\pi_k^{m,\tau})) \quad (4)$$

### 1.2 MWPE算法

WPE是从单一尺度来衡量数据的复杂性和动态性,MWPE对时间序列进行粗粒化,然后计算每个尺度上的WPE值,是对时间序列在不同尺度上的定量描述。对于样本长度为 $N$ 的时间序列 $A(i)$ ,进行粗粒化处理得到粗粒化序列 $y^{(s)}(j)$ 为

$$y^{(s)}(j) = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} A_i \quad (1 \leq j \leq N/s, j \in \mathbf{Z}^+) \quad (5)$$

其中: $s$ 为尺度因子; $\mathbf{Z}^+$ 为正整数。

对粗粒化的序列计算多尺度下的WPE值为

$$E_{\text{MWPE}}(X, \tau, s, m) = \text{WPE}(y^{(s)}(j), m, \tau) \quad (6)$$

MWPE算法需要人为设置4个关键参数,即样本长度 $N$ 、尺度因子 $s$ 、嵌入维数 $m$ 和时延 $\tau$ 。目前,尺度因子尚无选定标准,一般大于10即可<sup>[16]</sup>,本研究中 $s=12$ 。信号长度应满足 $N \geq 1024$ ,本研究中 $N=3600$ 。时延参数对熵值的影响极小,一般设为 $\tau=1$ 。

嵌入维数 $m$ 对熵值的影响较大,若 $m$ 取值过小,重构的信号序列中仅有少量的状态信息,算法将不能有效反映信号序列的突变;若 $m$ 取值过大,信号序列被均匀化,没有包含序列的细微变化,且计算量大,算法运行时间增加。通常 $m$ 的取值范围为 $[3,$

7]。为进一步确定 $m$ 的具体数值,本研究引入CV法进行分析确定。CV法是一种比较不同组或不同样本数据之间变异程度的方法,用于衡量数据的离散程度,其不受数据量级影响。CV的数学表达式为

$$CV = \sigma/\mu \quad (7)$$

其中:CV为变异系数; $\sigma$ 为标准差; $\mu$ 为均值。

## 2 DBO算法和DBO-SVM分类器

### 2.1 DBO算法

DBO主要包括4个过程:滚球、繁殖、觅食和偷窃,其具体过程如下。

1) 滚球:当蛱螂面前无障碍物时,DBO根据太阳导航滚动粪球更新位置,描述为

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \quad (8)$$

其中: $t$ 为当前迭代次数; $x_i(t)$ 为第 $i$ 次的蛱螂在第 $t$ 次迭代中的位置信息; $k \in (0, 0.2]$ ,为扰动系数; $b$ 为 $(0, 1)$ 之间的随机数; $\alpha$ 取-1或1; $X^w$ 为全局最差位置; $\Delta x = |x_i(t) - X^w|$ ,用于模拟光的强度变化。

有障碍物时,DBO通过跳舞来确定前进的新方向。用切线函数模仿跳舞行为,描述为

$$x_i(t+1) = x_i(t) + \tan(\theta) |x_i(t) - x_i(t-1)| \quad (9)$$

其中: $\theta$ 为偏转角,取值为 $[0, \pi]$ ,当 $\theta=0, \pi/2, \pi$ 时,蛱螂位置不更新。

2) 繁殖:采用一种边界选择策略来模拟雌性蛱螂产卵的区域,其定义为

$$b_L^* = \max(X^* \times (1-R), b_L) \quad (10)$$

$$b_U^* = \min(X^* \times (1+R), b_U) \quad (11)$$

其中: $R=1-t/Q$ , $Q$ 为最大迭代次数; $b_L^*$ 和 $b_U^*$ 分别为产卵区域的下界和上界,产卵区域随着迭代次数动态变化; $X^*$ 为当前局部最佳位置。

动态变化的边界范围是产卵区的边界范围,主要由 $R$ 值决定。因此,在迭代过程中,产卵球的位置也是动态的,定义为

$$B_i(t+1) = X^* + b_1 \times (B_i(t) - b_L^*) + b_2 \times (B_i(t) - b_U^*) \quad (12)$$

其中: $B_i$ 为第 $t$ 次迭代时第 $i$ 个雏球的位置; $b_1, b_2$ 为2个独立的随机变量,大小为 $1 \times D$ , $D$ 为优化问题的维数。

3) 觅食:小蛱螂的最佳觅食区建模为

$$b_L^b = \max(X^b \times (1-R), b_L) \quad (13)$$

$$b_U^b = \min(X^b \times (1+R), b_U) \quad (14)$$

其中: $X^b$ 为全局最优位置; $b_L^b$ 和 $b_U^b$ 分别为觅食区的

最佳下限和上限。

小蛻螂位置更新为

$$x_i(t+1) = x_i(t) + C_1 \times (x_i(t) - b_L^b) + C_2 \times (x_i(t) - b_U^b) \quad (15)$$

其中:  $C_1$  为服从正态分布的随机数;  $C_2$  为  $(0, 1)$  之间的随机向量。

4) 偷窃: 偷窃蛻螂的位置更新为

$$x_i(t+1) = X^b + S \times G \times \left( |x_i(t) - X^*| + |x_i(t) - X^b| \right) \quad (16)$$

其中:  $G$  为  $1 \times D$  的随机向量;  $S$  为常数。

## 2.2 DBO-SVM 分类器

SVM 对惩罚因子  $c$  和核函数参数  $g$  较为敏感, 为解决这一优化问题, 笔者提出一种采用 DBO 算法优化 SVM 参数的方法, 步骤如下:

1) 对齿轮数据进行 MWPE 熵值特征信息提取, 将熵值划分为训练集和测试集, 训练集可使 SVM 识别精度更高, 测试集可评价 SVM 的效果;

2) 初始化参数包括惩罚因子  $c$ 、核函数  $g$ 、蛻螂种群数  $p$  和初始位置  $x$  等;

3) 以训练集识别错误率最小值为适应度函数值, 采用 2.1 节中式 (8)、(9)、(12)、(15)、(16) 更新蛻螂位置和适应度函数值, 以获得最佳的惩罚因子  $c$  和核函数  $g$ ;

4) 使用优化后的参数  $c$ 、 $g$  进行 SVM 模型训练, 并进行测试集预测分类。

DBO-SVM 框图如图 1 所示。

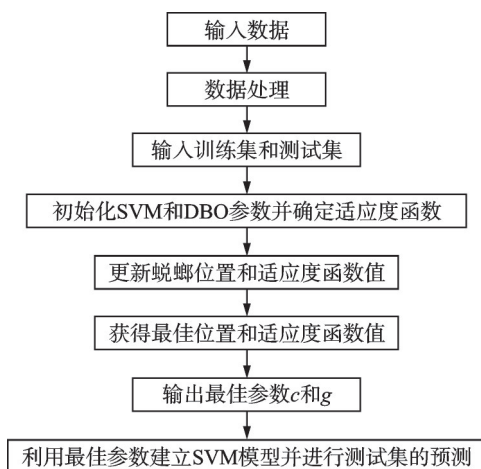


图1 DBO-SVM 框图

Fig.1 Block diagram of DBO-SVM

## 3 故障诊断模型与试验研究

针对齿轮故障诊断识别, 在得到原始齿轮时间

序列信号后, 采用 MWPE 和 DBO-SVM 相结合的方法进行识别, 步骤如下:

1) 根据齿轮数据分析确定 MWPE 各参数, 包括样本长度  $N$ 、嵌入维数  $m$ 、尺度因子  $s$  和时延  $\tau$  等;

2) 为易于识别, 对每种故障类型打上标签, 每种故障类型包含训练样本和测试样本;

3) 测试样本特征集采用经过训练的 DBO-SVM 分类器模型进行故障类型识别。

齿轮故障诊断模型框图如图 2 所示。

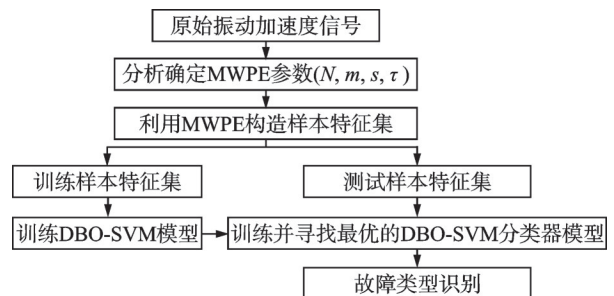


图2 齿轮故障诊断模型框图

Fig.2 Block diagram of gear fault diagnosis model

## 3.1 试验数据

为验证 MWPE 与 DBO-SVM 故障诊断模型方法的可行性和有效性, 采用美国康涅狄格大学齿轮数据集进行分析验证<sup>[17]</sup>。试验数据包括 5 种状态: 健康 (healthy, 简称 HE)、缺齿 (missing tooth, 简称 MT)、裂纹 (root crack, 简称 RC)、剥落 (spalling, 简称 SP) 和削尖 (chipping tip, 简称 CT), 其中削尖包含 5 个等级的损伤程度, 分别用 CT-1、CT-2、CT-3、CT-4、CT-5 表示。

将 9 种不同类型的齿轮数据进行对应的标签 1~9 标识, 每种齿轮状态选取 104 个数据样本, 每个样本有 3 600 个数据点。5 种不同类型的齿轮信号时域波形如图 3 所示。




图3 齿轮信号时域波形

Fig.3 Time domain waveform of gear signal



### 3.2 MWPE 参数选择和分析

以不同齿轮振动信号的 MWPE 熵值作曲线图,从宏观上进行熵值对比分析,引入 CV 法从内部熵值关联性确定 MWPE 的嵌入维数  $m$ 。 $m$  对 MWPE 的影响较大,因此本节主要对  $m$  进行深入讨论,其他参数则选取 1.2 节中的结果。分别从 HE、MT 状态信号中随机选取 1 组样本数据,将不同嵌入维数  $m$  (分别取 3、4、5、6、7) 应用于 5 种齿轮状态信号。

图 4 为不同  $m$  和 MWPE 对 2 种信号的影响,多尺度下的熵值 WPE 即为 MWPE (下同)。当  $m=3,4,5$  时,对应曲线多尺度下的熵值 WPE 较大,这说明齿轮振动信号随机性较强,不能较好地体现齿轮的状态信息特征;当  $m=7$  时,熵值整体较小,相空间重构向量时间序列被均匀化,无法表征齿轮信号的细微变化,可能导致算法不能有效识别故障类型。

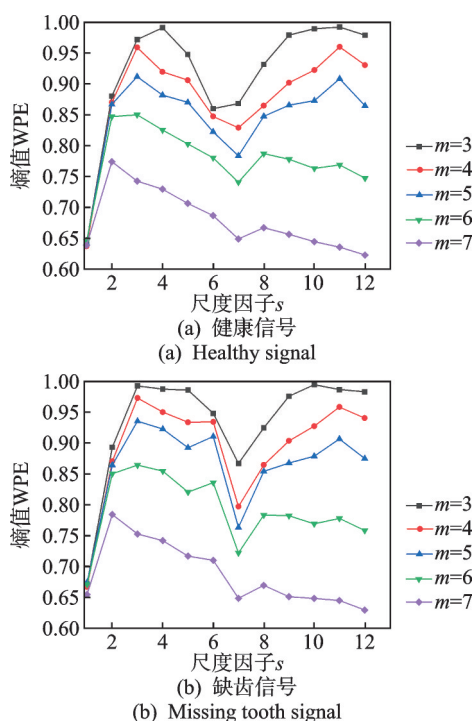


图 4 不同  $m$  和 MWPE 对 2 种信号的影响  
Fig.4 Influence of different  $m$  and MWPE on 2 signals

图 5 为 MWPE 对 2 种信号的影响。当  $m=3,4,5,7$  时,该 4 组的 2 种齿轮信号熵值交叠部分较多;当  $m=6$  时,该组的 2 种齿轮状态熵值交叠最少,说明 2 种齿轮信号识别特征最明显。因此,本研究中设定  $m=6$ ,在此基础上进一步研究齿轮各种状态的熵值。




图 5 MWPE 对 2 种信号的影响  
Fig.5 Influence of MWPE on 2 signals

为衡量熵值的离散程度,引入 CV 法,按式(7)进行计算,2 种齿轮信号熵值分析结果如表 1 所示。从表 1 结果发现,嵌入维数  $m=6$  时,2 种齿轮状态的变异系数 CV 最小,即熵值离散程度小,稳定性好,说明嵌入维数  $m$  的选择是合理的。

表 1 2 种齿轮信号熵值分析结果

Tab.1 Analysis results of entropy values of 2 gear signals

$m$	齿轮状态	标准差	平均值	CV
3	HE	0.100 3	0.918 9	0.109 2
4	HE	0.086 9	0.878 4	0.098 9
5	HE	0.072 7	0.844 2	0.086 1
6	HE	0.054 9	0.777 3	0.070 7
7	HE	0.048 5	0.678 7	0.071 5
3	MT	0.093 1	0.934 4	0.099 7
4	MT	0.086 9	0.893 3	0.097 3
5	MT	0.074 2	0.861 9	0.086 0
6	MT	0.058 1	0.790 3	0.073 5
7	MT	0.051 5	0.686 8	0.075 0

图 6 为  $m=6$  时不同状态齿轮信号的 MWPE。由图可知, $m$  相同时,在第 1 尺度上,HE 状态的熵值低于齿轮故障状态。原因在于,HE 状态的齿轮振动特性冲击性小、熵值低。对于同一种故障,在不同损伤程度下,其故障熵值也存在差异。




图 6  $m=6$  时不同状态齿轮信号的 MWPE  
Fig.6 MWPE of gear signals in different state when  $m=6$

### 3.3 特征提取

对于齿轮振动信号,先计算 MWPE 以提取特征,再构建数据特征集。为验证 MWPE 算法的优越性,将其与 MPE、MFE、MSE 算法进行对比分析。4 种算法熵值曲线如图 7 所示。

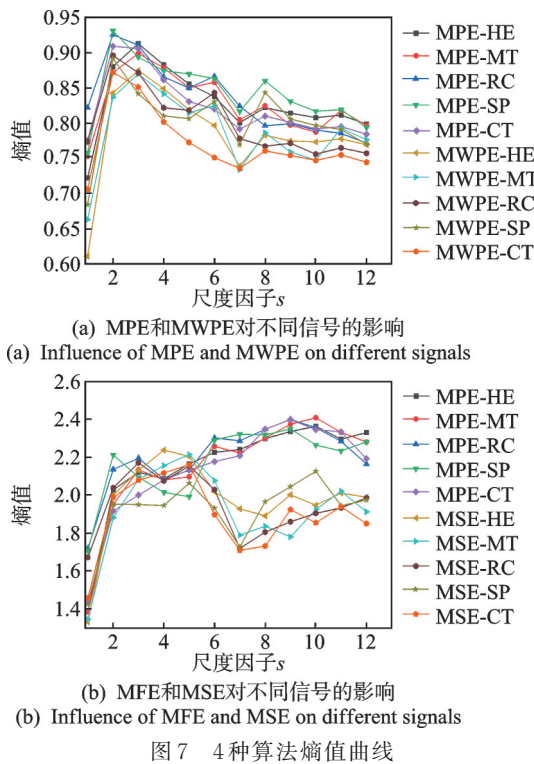


图 7 4 种算法熵值曲线

综上考虑,结合齿轮实际运行经验,选取尺度因子  $s=12$ 、相似容限  $r=0.2$ 、嵌入维数  $m=2$ 。其中, MPE 和 MWPE 的参数选取相同。

图 8 为 4 种熵值误差棒分析。分析图 7(a)和图 8(a)可知,与 MWPE 相比, MPE 的熵值曲线重叠较多,且 MPE 熵值曲线波动平缓,不利于从多个尺度衡量齿轮状态信息。对于 MWPE 熵值曲线,曲线从第 2 尺度开始相对平稳,混叠较少,熵值曲线包含状态信息较多,易于区分齿轮不同状态的振动信号。此外,仅从熵值方面对比 2 种算法较为单一。为此,引入误差棒对 2 种算法的齿轮状态熵值做进一步分析。HE 齿轮振动信号的熵值比故障齿轮振动信号的熵值小,但不能简单认为故障齿轮的振动信号比 HE 齿轮复杂。HE 齿轮振动信号 MWPE 熵值的误差棒最大,而 MPE 熵值误差棒并未体现这一特征,侧面表现了 MWPE 算法结合权重的优越性(权重计算见式(2))。对于齿轮的实际工况, HE 齿轮的振动信号波动具有随机性和无规律性。当齿轮

出现故障时,其振动信号波动表现出一定的规律性和周期性。

分析图 7(b)和图 8(b)可知, MFE 和 MSE 算法的熵值曲线较为接近,但 MFE 熵值曲线比 MSE 稳定,这是由于 MFE 算法采用均值运算,消除了基线漂移的影响,因此 MFE 的特征提取稳定性更好。分析熵值误差棒可知, MFE 和 MSE 算法熵值误差棒趋势(从齿轮 HE 到 CT)为先增大后减小再增大,齿轮缺齿状态的熵值误差棒最大,振动信号特征表现不明显,不易于后期输入到分类器进行识别。综上,分析结果验证了将 MWPE 算法运用于齿轮故障特征提取的可行性和优势性。

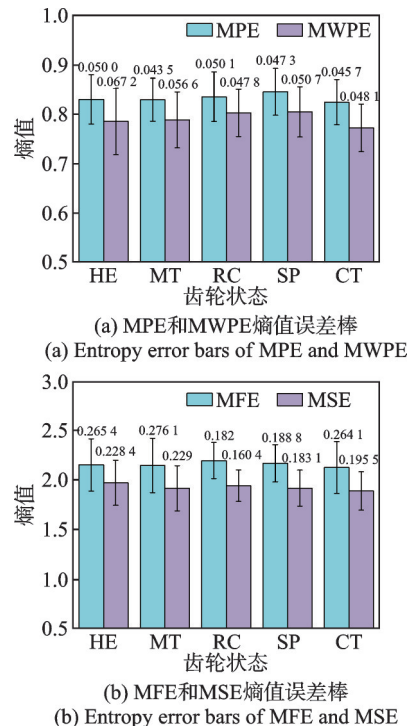


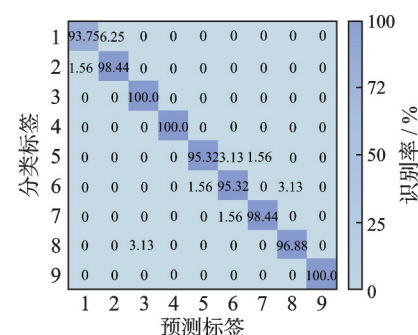
图 8 4 种熵值误差棒分析

Fig.8 Analysis of 4 entropy value error bars


### 3.4 模式识别

基于以上 4 种齿轮特征提取方法,将各自提取的特征值分别输入 DBO-SVM 进行识别。DBO-SVM 分类器识别结果和混淆矩阵如图 9 所示。


齿轮样本的参数设置为:在每种齿轮状态数据中,选取 40 组样本作为训练集,剩余 64 组样本作为测试集,训练集共计 360 组,测试集共计 576 组。DBO-SVM 参数设置为:蜣螂种群数为 10,最大迭代次数为 100,惩罚因子  $c$ 、核函数参数  $g$  寻优范围均为 0.01~100。




(a) MSE与DBO-SVM混淆矩阵  
(a) Confusion matrix of MSE and DBO-SVM



(b) MFE与DBO-SVM混淆矩阵  
(b) Confusion matrix of MFE and DBO-SVM



(c) MPE与DBO-SVM混淆矩阵  
(c) Confusion matrix of MPE and DBO-SVM



(d) MWPE与DBO-SVM混淆矩阵  
(d) Confusion matrix of MWPE and DBO-SVM

图9 DBO-SVM分类器识别结果和混淆矩阵

Fig.9 Recognition results and confusion matrix of DBO-SVM classifier

分析图9可知, DBO-SVM分类器对MFE的总体识别率比MSE高出1.04%, 以MFE和MSE作为特征向量输入分类器, 齿轮HE状态识别率均最低, 表明其运行时信号复杂, 2种特征提取算法效果均不佳。DBO-SVM分类器对MWPE的总体识别率

比MPE高出2.25%。MPE的识别中, 第7种齿轮削尖状态识别率较低(84.38%), 说明MPE算法对某些故障特征提取不敏感, 存在缺陷。此外, DBO-SVM分类器对MWPE和MFE的总体识别率, 分别比MSE和MPE高出1.56%和1.73%, 体现了MWPE算法对齿轮故障特征提取的优势。综上, 笔者所提出的MWPE与DBO-SVM方法对齿轮故障识别率达到99.13%, 表明该方法能够有效对齿轮故障进行识别。

为验证DBO-SVM分类器的高效性, 将MWPE作为特征值输入, 并与基于粒子群优化(particle swarm optimization, 简称PSO)、模拟退火(simulated annealing, 简称SA)、AFSA的SVM算法进行比较, 分别记为PSO-SVM、SA-SVM、AFSA-SVM和DBO-SVM。各分类器的惩罚因子 $c$ 、核函数参数 $g$ 寻优范围均为0.01~100。分类器参数如表2所示。

表2 分类器参数

Tab.2 Classifier parameters

分类器	参数设置
PSO-SVM	粒子种群大小为10, 停止迭代次数为100, 局部搜索能力为1.5, 全局搜索能力为1.5, 粒子速率系数为0.6
SA-SVM	Markov链长度为100, 衰减参数为0.85, 步长为0.2, 开始温度为8, 最终温度为3, Boltzmann常数为1
AFSA-SVM	人工鱼数为10, 停止迭代次数为100, 最多试探次数为5, 感知距离为10, 拥挤因子为0.3, 步长为1.25
DBO-SVM	种群数为10, 停止迭代次数为100

试验所用软件为Matlab, 试验次数为5次, 通过试验记录分类器的惩罚因子 $c$ 、核函数参数 $g$ 、识别准确率(accuracy, 简称ACC)和识别时间 $T$ , 最后计算各部分参数均值。

表3为不同分类器识别结果。以MWPE为分类器的特征值输入均取得较高的识别准确率, 最低的平均识别率为97.77%。PSO-SVM、SA-SVM和AFSA-SVM分类器每次识别准确率均存在小范围波动, 具有不稳定性。3种分类器的平均识别时间从多到少依次为: AFSA-SVM(77.97 s) > SA-SVM(59.92 s) > PSO-SVM(17.91 s)。与其他3种分类器相比, DBO-SVM的平均识别时间分别减少6.6、48.61和66.66 s, 平均识别准确率分别高出0.96%、0.42%和1.36%。DBO-SVM分类器识别时间较



表 3 不同分类器识别结果  
Tab.3 Recognition results of different classifiers

分类器	参数	试验次数					均值
		1	2	3	4	5	
PSO-SVM	$c$	85.95	45.07	16.99	9.42	4.94	32.47
	$g$	13.03	0.01	11.27	5.06	6.63	7.20
	ACC/%	97.50	98.61	97.78	98.61	98.33	98.17
	$T/s$	17.91	17.39	16.66	18.89	18.70	17.91
SA-SVM	$c$	9.50	19.55	92.57	49.64	42.14	42.68
	$g$	59.18	75.88	25.36	69.33	17.85	49.52
	ACC/%	98.61	98.26	99.13	99.13	98.44	98.71
	$T/s$	61.00	62.46	59.45	53.55	63.16	59.92
AFSA-SVM	$c$	44.05	41.43	8.57	45.44	74.97	42.89
	$g$	25.96	7.84	2.93	24.51	9.57	14.16
	ACC/%	96.39	98.88	97.22	97.50	98.88	97.77
	$T/s$	84.08	73.00	74.52	76.54	81.69	77.97
DBO-SVM	$c$	28.19	11.52	100.00	14.38	14.79	33.78
	$g$	0.09	0.22	0.03	0.18	0.17	0.14
	ACC/%	99.13	99.13	99.13	99.13	99.13	99.13
	$T/s$	11.72	10.88	11.56	11.30	11.10	11.31

短,准确率较高,说明将其运用于齿轮故障诊断识别是可行的。

由于齿轮多在噪声环境下运行,为探究 MWPE 特征提取的鲁棒性,进行噪声状态下的齿轮状态信号故障识别试验,试验样本分组、各参数设置与前述相同。在原始齿轮各组数据样本中加入信噪比为 5 dB 的高斯白噪声,分别计算 MWPE、MPE、MSE、MFE 等熵值,构建数据集并建立 DBO-SVM 故障诊断模型,分别把将训练特征集代入模型训练,通过各自测试集进行验证,最后得出模型识别率。噪声状态下各分类器识别率如图 10 所示。加入高斯白噪声后,基于 MWPE 的特征输入故障识别率比 MSE、MFE、MPE 分别高出 23.79%、21.01%、5.21%,验证了 MWPE 与 DBO-SVM 模型具有较好的鲁棒性和抗噪性。




图 10 噪声状态下各分类器识别率  
Fig.10 Recognition rates of each classifier under noise conditions

4 结 论

1) 提出了一种用于齿轮信号特征提取的算法 MWPE,该算法对原始振动信号的排列熵进行加权处理,进而从多个尺度进行分析,可以有效提取齿轮状态特征信息。试验结果表明,该方法优于 MSE、MFE 与 MPE 算法。

2) 提出了 DBO-SVM 模式识别新算法,将 MWPE 提取的信号特征熵值作为特征向量输入,采用 DBO-SVM 分类器完成识别。齿轮故障诊断试验表明,DBO-SVM 分类器的识别准确率和识别时间表现均优于常规优化分类器 PSO-SVM、SA-SVM 与 AFSA-SVM。

3) MWPE 和 DBO-SVM 在齿轮故障诊断识别试验取得了 99.13% 的识别准确率。在噪声状态下,MWPE 和 DBO-SVM 方法取得了 94.10% 的识别准确率,分别高出 MPE 和 DBO-SVM 算法 5.21%,高出 MFE 和 DBO-SVM 算法 21.01%,高出 MSE 和 DBO-SVM 方法 23.79%,表明 MWPE 特征提取算法具有更强的噪声鲁棒性。

参 考 文 献

[1] 申勇,章翔峰,周建星,等. 多级齿轮传动裂纹故障频率分析与特征提取[J]. 振动、测试与诊断, 2022, 42(2): 328-334.

- SHEN Yong, ZHANG Xiangfeng, ZHOU Jianxing, et al. Frequency analysis and feature extraction of cracked multi-stage gear transmission[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 328-334. (in Chinese)
- [2] VERMA A K, SARANGI S, KOLEKAR M. Misalignment faults detection in an induction motor based on multi-scale entropy and artificial neural network[J]. Electric Power Components and Systems, 2016, 44(8): 916-927.
- [3] 苟先太, 李昌喜, 金伟东. VMD多尺度熵用于高速列车横向减振器故障诊断[J]. 振动、测试与诊断, 2019, 39(2): 292-297.
- GOU Xiantai, LI Changxi, JIN Weidong. Fault diagnosis method for high-speed train lateral damper based on variational mode decomposition and multiscale entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2): 292-297. (in Chinese)
- [4] 郑近德, 陈敏均, 程军圣, 等. 多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. 振动工程学报, 2014, 27(1): 145-151.
- ZHENG Jinde, CHEN Minjun, CHENG Junsheng, et al. Multiscale fuzzy entropy and its application in rolling bearing fault diagnosis[J]. Journal of Vibration Engineering, 2014, 27(1): 145-151. (in Chinese)
- [5] YASIR M N, KOH B H. Data decomposition techniques with multi-scale permutation entropy calculations for bearing fault diagnosis[J]. Sensors, 2018, 18(4): 1278.
- [6] HUO Z Q, ZHANG Y, SHU L, et al. A new bearing fault diagnosis method based on fine-to-coarse multiscale permutation entropy, laplacian score and SVM[J]. IEEE Access, 2019, 7: 17050-17066.
- [7] XIA J A, SHANG P J, WANG J, et al. Permutation and weighted-permutation entropy analysis for the complexity of nonlinear time series[J]. Communications in Nonlinear Science and Numerical Simulation, 2016, 31(1/2/3): 60-68.
- [8] YIN Y, SHANG P J. Weighted multiscale permutation entropy of financial time series[J]. Nonlinear Dynamics, 2014, 78(4): 2921-2939.
- [9] WAN X J, SUN W L, CHEN K, et al. State degradation evaluation and early fault identification of wind turbine bearings[J]. Fuel, 2022, 311: 122348.
- [10] YUAN X Y, FAN Y G, ZHOU C J, et al. Research on twin extreme learning fault diagnosis method based on multi-scale weighted permutation entropy[J]. Entropy, 2022, 24(9): 1181.
- [11] 王贡献, 张森, 胡志辉, 等. 基于多尺度均值排列熵和参数优化支持向量机的轴承故障诊断[J]. 振动与冲击, 2022, 41(1): 221-228.
- WANG Gongxian, ZHANG Miao, HU Zhihui, et al. Bearing fault diagnosis based on multiscale mean ranking entropy and parameter optimization support vector machine[J]. Journal of Vibration and Shock, 2022, 41(1): 221-228. (in Chinese)
- [12] KANG J C, WANG Z H, SOARES C G. Condition-based maintenance for offshore wind turbines based on support vector machine[J]. Energies, 2020, 13(14): 3518.
- [13] 姚德臣, 杨建伟, 程晓卿, 等. 基于多尺度本征模态排列熵和SA-SVM的轴承故障诊断研究[J]. 机械工程学报, 2018, 54(9): 168-176.
- YAO Dechen, YANG Jianwei, CHENG Xiaoqing, et al. Railway rolling bearing fault diagnosis based on multi-scale IMF permutation entropy and SA-SVM classifier[J]. Journal of Mechanical Engineering, 2018, 54(9): 168-176. (in Chinese)
- [14] XIAO Y, KANG N, HONG Y, et al. Misalignment fault diagnosis of DFWT based on IEMD energy entropy and PSO-SVM[J]. Entropy, 2017, 19(1): 6.
- [15] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [16] 郑近德, 程军圣, 杨宇. 多尺度排列熵及其在滚动轴承故障诊断中的应用[J]. 中国机械工程, 2013, 24(19): 2641-2646.
- ZHENG Jinde, CHENG Junsheng, YANG Yu. Multi-scale permutation entropy and its applications to rolling bearing fault diagnosis[J]. China Mechanical Engineering, 2013, 24(19): 2641-2646. (in Chinese)
- [17] CAO P, ZHANG S L, TANG J. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning[J]. IEEE Access, 2018, 6: 26241-26253.



**第一作者简介:** 飞能,男,1998年2月生,硕士生。主要研究方向为机械故障诊断、水电机组监测与故障诊断。  
E-mail: 2770781399@qq.com

**通信作者简介:** 钱晶,女,1967年6月生,硕士、教授。主要研究方向为发电机组的稳定控制及故障诊断。  
E-mail: qj0117@163.com