

# 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

肖茂华<sup>1</sup>, 周爽<sup>1</sup>, 黄天逸<sup>1</sup>, 赵远方<sup>1</sup>, 费秀国<sup>2</sup>

(1. 南京农业大学工学院, 江苏 南京 210031; 2. 南京创力传动机械有限公司, 江苏 南京 211122)

**摘要:** 针对滚动轴承振动信号的非线性、非平稳特征, 提出了基于参数优化变分模态分解 (Variational Mode Decomposition, VMD)、多尺度排列熵 (Multi-scale Permutation Entropy, MPE) 和粒子群-布谷鸟搜索融合算法优化 Elman 神经网络的故障诊断方法。针对 VMD 中模态分量个数和惩罚因子难以确定的问题, 引入鲸鱼优化算法, 令其自主搜寻最优解; 利用获得最优参数的 VMD 对滚动轴承故障仿真信号进行分解, 对最佳模态分量进行包络谱分析, 对比仿真故障频率与实际值的吻合度, 验证该方法的可行性。考虑到 MPE 具有可探究信号内动力突变的优点, 将其与参数优化 VMD 相结合, 求取滚动轴承振动信号各阶模态分量的 MPE 值, 选择部分熵值构建特征向量, 并将其投放在三维空间观察其差异性, 判断其是否能够良好地表征不同故障类型。针对 Elman 神经网络识别精度低的问题, 将粒子群优化 (Particle Swarm Optimization, PSO) 算法和布谷鸟搜索 (Cuckoo Search, CS) 算法相融合, 以此联合优化 Elman 网络的权重和阈值, 以提升网络的收敛精度和诊断精度。以实验采集和凯斯西储大学的滚动轴承振动信号为研究对象, 应用所提方法进行分析。结果表明, 所提方法不仅能够自适应地将信号分解, 并提取出有效的故障特征, 还能准确实现故障模式的分类, 提高故障识别率。

**关键词:** 故障诊断; 滚动轴承; 参数优化变分模态分解; 多尺度排列熵; PSO-CS-Elman

**中图分类号:** TH165<sup>+</sup>.3; TH133.33 **文献标志码:** A **文章编号:** 1004-4523(2023)03-0861-14

**DOI:** 10.16385/j.cnki.issn.1004-4523.2023.03.029

## 引言

滚动轴承因具有转速高、效率高以及噪声低等优点而被广泛应用于机械行业的各个领域。它的工作环境通常较为恶劣, 导致其寿命离散性大且故障率高。据统计, 在使用滚动轴承的旋转机械设备中, 约有 30% 的机械故障与轴承损伤有关<sup>[1]</sup>。利用其工作过程中产生的振动信号进行故障诊断, 不仅能够降低机械设备发生意外事故的几率, 还可为设备的后期维修提供一定参考<sup>[2-3]</sup>。

滚动轴承振动信号受诸多因素的影响而呈现出非线性与非平稳性, 如何从中提取出有效信息尤为重要<sup>[4]</sup>。传统手段主要包括时域和频域分析, 但对于非平稳复杂信号, 其时域和频域的统计特性均随时间变化, 需同时在时域与频域内进行分析与处理<sup>[5]</sup>。常用的时频分析方法主要有小波分析<sup>[6]</sup>、经验模态分解 (Empirical Mode Decomposition, EMD)、局部均值分解 (Local Mean Decomposition, LMD)<sup>[7]</sup>

等。EMD 可将信号自适应地分解为若干个本征模态函数, 但易存在端点效应、模态混叠等问题<sup>[8]</sup>。徐卓飞等<sup>[9]</sup>提出了一种融合 EMD 和多元统计的轴承故障诊断方法, 实现了对常见的三类轴承故障的分类。与它相比, LMD 在迭代次数与运算速度方面有一定改善, 但仍解决不了端点效应等问题。于是, Dragomiretskiy 等<sup>[10]</sup>提出一种可变尺度的处理方法, 即变分模态分解 (Variational Mode Decomposition, VMD)。该方法引入变分模型, 将信号的分解转换为约束模型最优解的寻优问题, 可以避免端点效应、抑制模态混淆, 并且具有很高的分解效率。武英杰等<sup>[11]</sup>将 VMD 应用于风电机组的故障诊断中, 证明了 VMD 能够有效避免模态混叠现象, 对轴系不平衡故障有良好的诊断效果。但是, VMD 在应用过程中, 其分解层数与惩罚因子难以精确选取。唐贵基等<sup>[12]</sup>曾使用智能算法优化 VMD 参数, 获得了比较好的分解效果; 但选用谱峭度作为适应度函数参数, 导致最终求得的分解层数值不稳定。

采集的故障滚动轴承的振动信号比较复杂, 不

**收稿日期:** 2021-10-25; **修订日期:** 2022-01-10

**基金项目:** 江苏省农业科技自主创新资金资助项目 (CX(22)3101); 江苏省自然科学基金资助项目 (BK20210407); 国家重点研发计划项目 (2022YFD2001805)。

容易直接获取较好的信号特征。若直接将原始信号作为神经网络的输入,不仅存在样本过大、训练时间过长等问题,还会影响最终的故障分类效果。常用的复杂性分析方法主要包括近似熵、样本熵、排列熵、多尺度排列熵等。其中,多尺度排列熵(Multi-scale Permutation Entropy, MPE)具有可探究信号内动力突变的优点<sup>[13]</sup>,使用它来表征不同工况下的振动信号将会达到较好效果。但是,因其参数选取对于特征提取的好坏具有决定性作用,通常需对其所构建特征向量的性能作出进一步判定。

当前,故障诊断方法已经从早期的人工检测逐步演变为智能化诊断。支持向量机(Support Vector Machine, SVM)是对有限数据进行处理的工具之一,它具有非常好的泛化能力,不需要设定太多的训练样本就可以保证最终的故障分类结果保持在一个较高水平<sup>[14]</sup>。Van等<sup>[15]</sup>搭建了一个混合SVM模型,并成功应用于轴承故障分类。Parmar等<sup>[16]</sup>利用小波包分解和SVM对圆柱滚子轴承的多种故障进行了分类研究,并证明了其在分类效果和训练时间方面的优越性。聚类分析(Clustering Analysis, CA)是用来描述数据的一种方法,有着独特的分类原则,在同一聚类中分出非常相似的对象,但又对每个记录进行合理划分,从而确定每个记录所属的类别。姚立国等<sup>[17]</sup>利用模拟退火方法挑出最优局部解,并与CA相结合,较好地应用于轴承的故障诊断。采用神经网络进行故障诊断,就是将各类故障信息的有效特征向量作为网络结构的输入值,利用网络的不断迭代训练测试,最终完成类别的划分。目前,在机械故障诊断中应用较多的主要有Elman, BP, 径向基和小波等神经网络。此类方法在目前研究中是一种主流方法,但它对于特征向量构建及参数选取的依赖性较强。针对原始网络中总存在收敛精度低、分类精度低等问题,学者们纷纷采用各类方法对其进行优化。Li等<sup>[18]</sup>基于BPNN的多尺度局部特征学习开展了滚动轴承智能故障诊断研究。任学平等<sup>[19]</sup>和唐立力等<sup>[20]</sup>分别用了粒子群(Particle Swarm Optimization, PSO)算法和思维进化算法对神经网络进行结构参数优化,最终的分类效果都有明显提升。皮骏等<sup>[21]</sup>使用改进PSO优化Elman神经网络,并应用于航空发动机的故障诊断,提升了网络训练速度和诊断精度。除此之外,深度学习方法的故障诊断应用也逐渐增多<sup>[22]</sup>,它与神经网络在很多时候有些交叉成分,它最大的不足就是训练时间往往过长。所以目前使用浅层神经网络实现更高效率和实时的故障诊断依然很有必要。

综上所述,VMD虽在端点效应、模态混叠等问

题上有所改善,但其分解层数与惩罚因子难以精确选取。Elman神经网络可以用于故障分类,但其收敛精度与分类精度还有很大提升空间。

为解决上述问题,本文基于鲸鱼优化算法(Whale Optimization Algorithm, WOA),使VMD能够自动搜寻最优参数;利用信号分解与MPE提取的融合方法来构建特征向量,以更好地表征不同类型的振动信号;提出基于PSO-CS优化的Elman神经网络,以提升收敛精度及故障分类精度。

## 1 参数优化的变分模态分解

### 1.1 VMD方法

#### 1.1.1 VMD基本原理

VMD的实质是以频域迭代方式将振动信号分解为若干个幅频调制信号。假设存在一多频信号 $f$ ,可被划分为 $K$ 个离散时间序列 $u_k(t)$ ,且带宽有限;它们相应的中心基频带为 $\omega_k(t)$ ;并且,由 $u_k(t)$ 所得频谱都拥有稀疏特性。带宽求取的具体步骤如下:

(1)利用Hilbert变换,将分解所得各阶本征模态分量(Intrinsic Mode Functions, IMF)的解析信号以及单边频谱加以计算:

$$\left[ \delta(t) + \frac{j}{\pi t} \right] * u_k(t) \quad (1)$$

式中  $\delta(t)$ 为脉冲函数; $j$ 表示模态分解的次数。

(2)在各模态信号上乘以一个指数项,以调整其中心频带:

$$\left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \quad (2)$$

(3)计算解调信号的梯度范数 $L_2$ ,估计各模态信号带宽:

$$\left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \quad (3)$$

(4)上面所获取的中心频率及带宽是有条件限制的,即要符合各个IMF信号带宽之和最小的要求。所以,有必要构建约束变分模型:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{k=1}^K u_k = f \end{cases} \quad (4)$$

式中  $\omega_k$ 表示各IMF的频率中心; $u_k$ 表示第 $k$ 个IMF; $f$ 表示原始信号。

为获得式(4)最优解,引入二次惩罚因子法和Lagrange函数乘法,将其转换为无约束变分问题。推广Lagrange函数为:

$$L(u_k, \omega_k, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[ (\delta(t) + \frac{j}{\pi t}) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (5)$$

式中  $\lambda$  和  $\lambda(t)$  为乘法算子;  $\alpha$  为二次惩罚因子。

接着,引入交替乘子方向算法(Alternate Direction Method of Multipliers, ADMM)便能够搜寻该变分问题的鞍点。每个 IMF 的中心频率和带宽可以更新:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (6)$$

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (7)$$

式中  $\hat{u}_k(\omega)$  和  $\hat{u}_k^{n+1}(\omega)$  为残余量滤波结果;  $\omega$  为对  $t$  做 FFT 变换得到的变量;  $\hat{f}(\omega)$  与  $\hat{\lambda}(\omega)$  分别为对  $f(t)$  与  $\lambda(t)$  做 FFT 变换并进行微分得到的结果;  $\omega_k^{n+1}$  为当前模态的功率谱重心; 对  $\hat{u}_k(\omega)$  做逆向 FFT 变换能获得实部  $\hat{u}_k(t)$ 。

### 1.1.2 VMD 算法分解过程

VMD 分解步骤为:

(1) 对参数  $u_k, \omega_k, \lambda, \alpha$  和  $N$  (迭代次数) 进行初始化;

(2)  $N=N+1$ , VMD 算法进行迭代计算;

(3)  $k$  值从 1 不断叠加至  $K$ , 并通过式(6)和(7)的计算对  $u_k$  和  $\omega_k$  进行不断更新,  $K$  即是最终分解所得 IMF 的总数量;

(4)  $\lambda$  依照下式更新:

$$\lambda^{n+1} = \lambda^n + \tau \left( f - \sum_k \hat{u}_k^{n+1} \right) \quad (8)$$

式中  $\tau$  表示 Hilbert 反变换。

(5) 给出判定精度  $\epsilon > 0$ , 将步骤(3)与(4)不断重复, 直到符合终止条件:

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \epsilon \quad (9)$$

式中  $\epsilon$  为收敛性判定准则。

## 1.2 鲸鱼优化算法(WOA)

WOA 属于群体人工智能优化算法, 主要步骤如下:

(1) 包围猎物。在鲸鱼搜捕猎物的过程中, 若某只鲸鱼锁定一个最佳的待捕捉猎物, 那么其他鲸鱼将会尝试识别到该猎物所处位置, 并向该处移动聚集, 最终将目标猎物包围。可描述为:

$$D = |C \cdot X(t) - X(t)| \quad (10)$$

$$X(t+1) = X^*(t) - A \cdot D \quad (11)$$

式中  $t$  为当前迭代次数;  $X$  为鲸鱼当前位置;  $X^*$  为猎物当前位置;  $D$  为鲸鱼与猎物之间的距离向量;  $A$  和  $C$  为系数向量, 表示为:

$$\begin{cases} A = 2a \cdot r - a \\ C = 2r \end{cases} \quad (12)$$

式中  $r$  为随机向量, 范围为  $[0, 1]$ ;  $a$  从 2 线性递减到 0。

(2) 冒泡进攻方式。有两种数学模型可描述该方式, 第一种是收缩包围机制, 能利用  $a$  的降低来完成, 设置  $A$  为  $[-1, 1]$  内的任意数, 那么可以在初始值与最优位置中选取新的位置。第二种是螺旋更新位置, 通过鲸鱼和猎物之间的螺旋式转换, 不断更新位置:

$$X(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t) \quad (13)$$

式中  $D'$  为某鲸鱼与猎物的间距;  $b$  决定了对数螺旋形式;  $l$  为  $[-1, 1]$  之间的随机值。

WOA 设定了 50% 的概率, 随机选择以上两种方式, 以便模拟两者同时发生的情况。此过程的迭代更新表示为:

$$X(t+1) = \begin{cases} D' \cdot e^{bl} \cdot \cos(2\pi l) + X^*(t), & p \geq 0.5 \\ X^*(t) - A \cdot D, & p < 0.5 \end{cases} \quad (14)$$

式中  $p$  为  $[0, 1]$  范围内的任意值。

(3) 搜索猎物。鲸鱼识别同类或搜索猎物的过程都是随机的, 利用这个随机值代替最优的结果。其数学模型为:

$$\begin{cases} D = |C \cdot X_{\text{rand}} - X| \\ X(t+1) = X_{\text{rand}} - A \cdot D \end{cases} \quad (15)$$

式中  $X_{\text{rand}}$  为鲸鱼群中随机一个鲸鱼个体的位置。

探索及开发能力可以利用  $|A|$  的范围来决定。当  $|A| < 1$ , 就选择最优结果; 当  $|A| > 1$ , 就随机选取搜索个体。

在进行全局搜索时, 为了对迭代情况进行良好判断, 选用样本熵的最小值作为 WOA 的适应度函数。若某信号的样本熵值越逼近于 0, 它的内部相似性程度越高, 其中夹杂的噪音就越少<sup>[23]</sup>。

## 1.3 基于 WOA 的 VMD 参数寻优流程

基于以上分析, 提出了参数自适应的 VMD 方法, 如图 1 所示。主要步骤可归结如下:

(1) 获取滚动轴承的振动加速度信号;

(2) 设置鲸鱼优化算法循环初始条件;

(3) 设置 VMD 分解层数和惩罚因子的寻优空间;



(4)依据样本熵值最小准则对结果进行统计,选取熵值最小时的分解层数和惩罚因子为最优VMD参数;

(5)对信号分解后所得最优IMF进行包络谱分析,观察仿真与实际故障频率的契合程度。

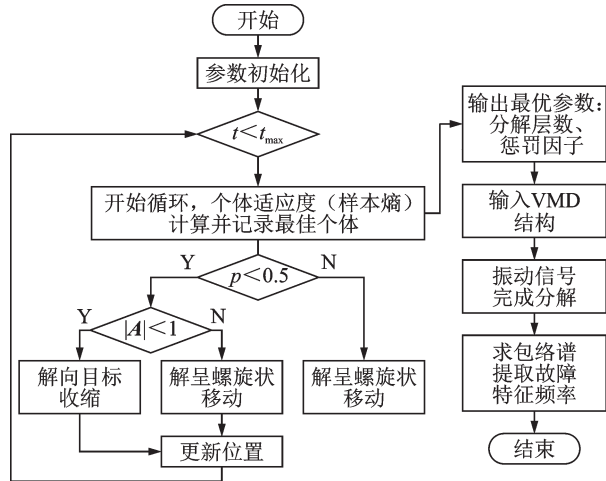


图 1 参数优化及信号分解流程

Fig. 1 Parameter optimization and signal decomposition process

1.4 仿真信号测试

基于轴承内圈单个损伤点的故障理论模型<sup>[24]</sup>,模拟轴承内圈故障产生的冲击信号。此外,对它添加一定信噪比的高斯白噪声,模拟实际工况下轴承内圈故障信号。最终仿真信号模型为:

$$\begin{cases} x(t) = s(t) + n(t) = \sum_i A_m h(t - iT - \tau_i) + n(t) \\ h(t) = e^{-Ct} \sin(2\pi f_n t) \\ A_m = A_0 \sin(2\pi f_r t) \end{cases} \quad (16)$$

式中  $x(t)$ 为仿真信号; $s(t)$ 为周期性故障脉冲; $T$ 为故障周期; $h(t)$ 为随指数衰减的正弦冲击信号; $A_0$ 为幅值,取值0.5; $f_r$ 为转频,取值20 Hz; $C$ 为衰减系数,取值800; $f_n$ 为共振频率,取值4000 Hz;内圈故障频率 $f_i=1/T=110$  Hz; $\tau_i$ 为微小波动,本次取值为0; $n(t)$ 为白噪声,其信噪比取为+2 dB。

采样频率设置为12 kHz,采样时间设置为0.5 s。冲击信号与仿真信号的波形图与频谱图如图2所示。

WOA的相关参数如表1所示。在寻优过程中,每次迭代更新后,计算分解所得全部IMF的样本熵值,选取其最小值作为最佳目标函数值。图3为适应度值的变化曲线。

由图3可知,样本熵值先随着迭代次数的增加而减小,且最小的样本熵值0.1066第一次出现在第

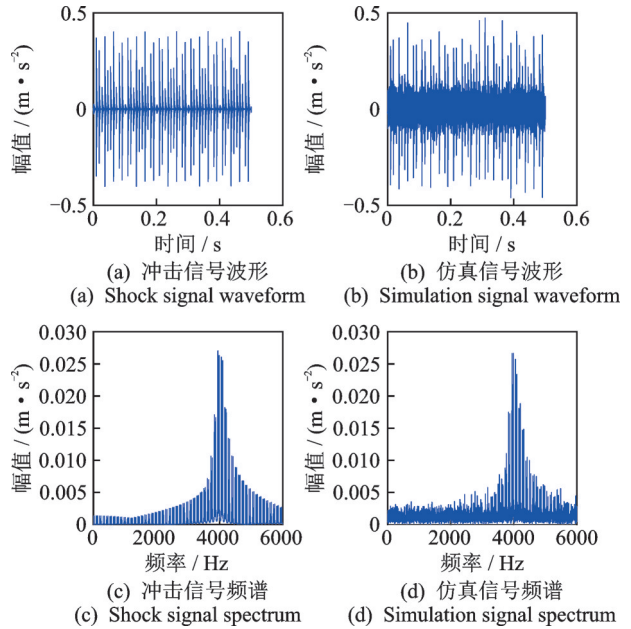


图 2 冲击与仿真信号的波形与频谱

Fig. 2 Waveform and spectrum of shock and simulation signals

表 1 WOA 参数设置

Tab. 1 Parameter setting of the WOA

参数名称	数值
问题维度	2
种群规模	10
最大迭代次数/次	50
二次惩罚因子 $\alpha$	50~5000
分解个数 $K$ /个	2~8




图 3 样本熵值随种群迭代的变化

Fig. 3 Variation of sample entropy with population iteration

12代,然后样本熵值便一直保持不变。迭代结束后,可以得到优化后的参数组合为 $[\alpha, K]=[3896, 4]$ 。于是VMD的分解参数自动更新为 $\alpha=3896, K=4$ ,接着便对输入的仿真信号完成分解。然后,原始仿真信号经VMD分解后即可形成4个IMF,其时域波形图与频谱图如图4所示,各分量的样本熵值如表2所示。




图4 WOA-VMD分解后的仿真信号波形和频谱

Fig. 4 Simulation signal waveform and spectrum after WOA-VMD decomposition

表2 4个模态分量的样本熵

Tab. 2 Sample entropy of the four IMFs

模态分量	样本熵
IMF1	0.3180
IMF2	0.3067
IMF3	0.1066
IMF4	0.1089

由图4和表2可知,IMF3中包含着频带中心为4000 Hz的共振频带,且样本熵值最小,其所含杂质信号的成分也较少。然后,通过下式计算它们与原始信号的信噪比SNR和相关度R:

$$SNR = 10 \lg \left[ \frac{\sum_{i=1}^n y_i^2}{\sum_{i=1}^n (y_i - \hat{y}_i)^2} \right] \quad (17)$$

$$R = \frac{n \sum_{i=1}^n (y_i \hat{y}_i - \sum_{i=1}^n y_i \sum_{i=1}^n \hat{y}_i)}{\sqrt{\left[ n \sum_{i=1}^n y_i^2 - \left( \sum_{i=1}^n y_i \right)^2 \right] \left[ n \sum_{i=1}^n \hat{y}_i^2 - \left( \sum_{i=1}^n \hat{y}_i \right)^2 \right]}} \quad (18)$$

式中  $n$  为信号的总数目;  $y_i$  为信号分量;  $\hat{y}_i$  为原始信号。计算结果如图5所示。

从图5中可以看出,IMF3在两方面都优于另外三项。

于是,选择IMF3,绘制其包络谱如图6所示。由图6可明显看见内圈故障仿真信号的故障频率及其二倍频、三倍频等。通过寻优后的VMD信号分解,轴承内圈的重要故障频率信息就被提取出来,可以作为判定轴承内圈存在损伤的依据。此仿真信号分析充分证明了WOA参数寻优的有效性,以及WOA-VMD信号分解的高效性。

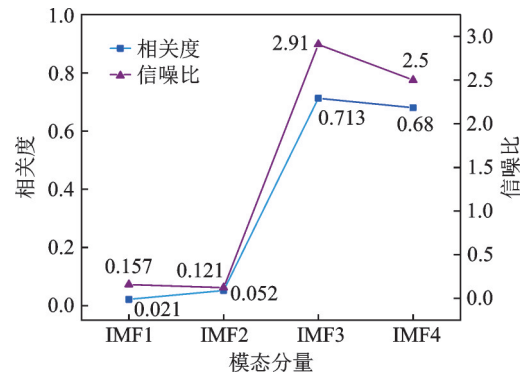


图5 不同IMF的相关度与信噪比

Fig. 5 The R and SNR of different IMFs




图6 IMF3的包络谱

Fig. 6 Envelope spectrum of IMF3

## 2 PSO-CS-Elman方法

### 2.1 Elman神经网络

Elman神经网络属于反馈型网络,它由输入、隐含、输出和承接四层构成,如图7所示。 $y_n(t)$ 为 $n$ 维输出节点向量; $U_d(t)$ 为 $d$ 维输入向量; $X_m(t)$ 为 $m$ 维中间层节点单元向量; $X_m(t)$ 为反馈状态向量; $w(t)$ 为中间层到输出层连接权值; $r(t)$ 为承接层到中间层的连接权值; $v(t)$ 为输入层到中间层的连接权值。




图7 Elman神经网络结构

Fig. 7 Structure of Elman neural network

Elman神经网络空间表达式如下:

$$Y(k) = g(w_3 u(k)) \quad (19)$$

$$u(k) = q(w_1 u_c(k)) + w_2 X(k-1) \quad (20)$$

$$u_c(k) = u(k-1) \quad (21)$$

式中  $X(k)$  为外端输入;  $u(k)$  为隐含层输出;  $Y(k)$  为网络输出;  $w_1, w_2$  和  $w_3$  分别为承接层、隐含层和输出层的权值;  $q(\cdot)$  为中间层神经元的传递函数;  $g(\cdot)$  为输出神经元的传递函数。

其误差函数为:

$$E = \frac{1}{2} [y_j(k) - y(k)]^2 \quad (22)$$

式中  $y_j(k)$  为系统的实际输出向量;  $y(k)$  为系统的输出向量。

## 2.2 粒子群算法(PSO)

PSO算法的基本思路是:在可行域内放入一群粒子,每个粒子都有适应度和速度向量。通过适应度来判断目前个体的最优解和群体的最优解,每次迭代都向适应度最优的方向搜寻,并不断优化每个粒子的适应度和速度向量,直到达到所需的精度,则迭代完毕,当前适应度最优的粒子所处的位置即为可行域内的最优解。

其具体实施方式为:设粒子  $i$  位置为  $X_i = [x_{i1}, x_{i2}, \dots, x_{im}]$ , 速度为  $V_i = [v_{i1}, v_{i2}, \dots, v_{im}]$ ,  $m$  为解空间维数;第  $j$  次迭代时个体最优解为  $P_{best}^i = [P_{best1}^i, P_{best2}^i, \dots, P_{bestm}^i]$ ;全局最优解为  $g_{best}^j$ ,  $n$  为粒子总数。粒子按照下式更新:

$$\begin{cases} V_i^{j+1} = \omega \cdot V_i^j + c_1 \cdot \text{rand}() \cdot (P_{best}^i - X_i^j) + \\ \quad c_2 \cdot \text{rand}() \cdot (g_{best}^j - X_i^j) \\ X_i^{j+1} = X_i^j + V_i^{j+1} \end{cases} \quad (23)$$

式中  $\omega$  为惯性权重;  $c_1$  和  $c_2$  为学习因子;  $\text{rand}() \in [0, 1]$ , 为随机数;  $V_i^j$  为第  $i$  个粒子第  $j$  次迭代的速度;  $V_i^{j+1}$  为第  $i$  个粒子第  $j+1$  次迭代的速度;  $X_i^j$  为第  $i$  个粒子第  $j$  次迭代的位置;  $X_i^{j+1}$  为第  $i$  个粒子第  $j+1$  次迭代的位置。

PSO算法简便易行,但它在搜寻最优解的时候容易出现收敛不成熟和误差较大等问题。

## 2.3 布谷鸟搜索(CS)算法

CS算法的灵感来源于布谷鸟的寄生繁衍方式,其流程如图8所示,具体步骤如下:

首先对种群初始化,并判别是否达到了最大迭代次数。如达到目标,则将最优解立刻输出。

利用莱维飞行机制,不断将鸟窝位置更新:

$$x_i^{t+1} = x_i^t + \alpha \oplus L(\lambda); \quad i = 1, 2, 3, \dots, n \quad (24)$$

式中  $x_i^t$  和  $x_i^{t+1}$  分别为第  $i$  个鸟窝在第  $t$  和  $t+1$  次迭代时的位置;  $\oplus$  为点对点乘法;  $\alpha$  为步长因子,能调节搜索范围,为了获取更有用的步长,可由下式

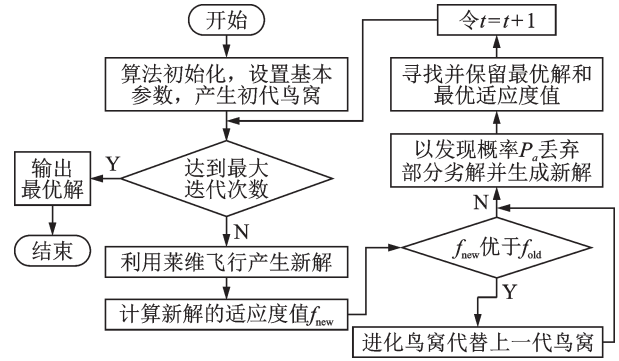


图8 布谷鸟搜索算法流程图

Fig. 8 Flow chart of cuckoo search algorithm

计算:

$$\alpha = \alpha_0 (x_i^t - x_{best}^t) \quad (25)$$

式中  $\alpha_0$  为常数,  $\alpha_0 = 0.01$ ;  $x_{best}^t$  为第  $t$  代最优解。

莱维飞行随机搜索服从如下分布:

$$L(\lambda) \sim \frac{\phi \times u}{|v|^{\frac{1}{\beta}}} \quad (26)$$

式中  $u \sim N(0, 1)$ ;  $v \sim N(0, 1)$ ;  $\beta$  为幂系数,一般取值 1.5;  $\phi$  如下所示:

$$\phi = \left[ \frac{\Gamma(1 + \beta) \times \sin(\pi \times \frac{\beta}{2})}{\Gamma(\frac{1 + \beta}{2} \times \beta \times 2^{\frac{\beta-1}{2}})} \right]^{\frac{1}{\beta}} \quad (27)$$

式中  $\Gamma$  为标准 Gama 函数。

结合式(24)~(27),CS算法在莱维飞行机制中形成新解的表达式为:

$$x_i^{t+1} = x_i^t + \alpha \frac{\phi \times u}{|v|^{\frac{1}{\beta}}} (x_i^t - x_{best}^t) \quad (28)$$

在算法运行过程中,随机生成一个数  $r$  在  $0 \sim 1$  之间,将其与发现概率  $P_a$  相比较。如果数值大于  $P_a$ ,则将该解舍弃,并利用下式再次形成新解;否则保持原解。

$$x_i^{t+1} = x_i^t + r(x_i^t - x_k^t) \quad (29)$$

式中  $x_j^t$  和  $x_k^t$  均为第  $t$  次迭代过程中的随机解。

## 2.4 PSO-CS算法

虽然CS算法存在结构简单、全局搜索能力好等优点,但其也有不足,如参数设置固定、缺乏种群内部交流机制和局部搜索性能较差。针对这些缺点,将PSO算法与CS算法相融合,进行二者混合编程。其基本原理可总结归纳为:在  $n$  个粒子群不停迭代时,通过PSO算法将各代的粒子速度及位置进行更新,获得一组粒子的最佳位置;接着,将上一步获得的粒子最佳位置随即代入到CS算法中,继续更新。这样,与原算法相比,除了本身的迭代次数以

外,所有的粒子群都会增加一次CS算法的更新及计算,这在迭代时间上相差也不算大。它的具体算法流程如图9所示。

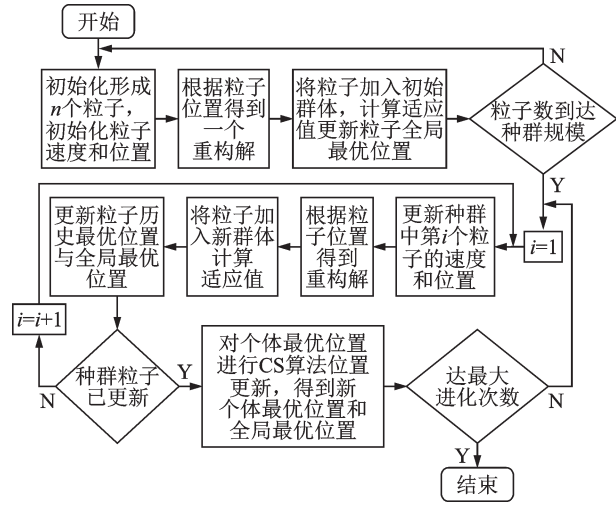


图9 PSO-CS算法流程

Fig. 9 PSO-CS algorithm flow

此方法最大的优点是,它将粒子群算法的搜索能力与布谷鸟算法的全局搜索能力叠加起来,在总体上可将算法的优化能力提升许多。

### 3 信号降噪与特征提取

#### 3.1 奇异值分解(SVD)

奇异值分解(Singular Value Decomposition, SVD)实质上是一种非线性滤波,能够较好地滤除信号中的随机噪声。

假设有一组信号  $Y=[y_1, y_2, \dots, y_n]$ , 其中  $Y(i)=s(i)+\xi(i); i=1, 2, \dots, n; s(i)$  为有用信号;  $\xi(i)$  为噪声信号。构建一个Hankle矩阵:

$$A = \begin{bmatrix} y_1 & y_2 & \dots & y_m \\ y_2 & y_3 & \dots & y_{m+1} \\ \dots & \dots & \dots & \dots \\ y_{n-m+1} & y_{n-m+2} & \dots & y_n \end{bmatrix} \quad (30)$$

式中 矩阵  $A \in \mathbb{R}^{(n-m+1) \times m}$ , 秩为  $r, r \leq m$ 。

因此,存在两个正交矩阵  $U \in \mathbb{R}^{(n-m+1) \times (n-m+1)}$  和  $V \in \mathbb{R}^{m \times m}$ , 与一个对角矩阵  $D \in \mathbb{R}^{(n-m+1) \times m}$ , 使得:

$$A = UDV^T \quad (31)$$

式中 对角矩阵  $D$  也可表示为  $D=(\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r), 0)$ , 其中,  $0$  为零矩阵,  $\sigma_r$  代表该对角矩阵的非零对角元素,它们就是所谓的奇异值,并且由大到小进行排序。

因  $Y(i)=s(i)+\xi(i)$ , 而矩阵  $A$  是由它的序列构成,所以  $A$  可另外表示为:

$$A = A_s + A_\xi \quad (32)$$

式中  $A_s$  为有用信号矩阵;  $A_\xi$  为噪声信号矩阵。

SVD的降噪效果通常取决于奇异值个数的选择,由于有用信号主要集中在前面  $i$  个较大的奇异值,通过保留合适的奇异值,再进行SVD的逆过程就可以消除原始振动信号中的噪声,从而提取到有用的特征信号。

#### 3.2 多尺度排列熵

假设存在一组原始时域信号  $X=\{x(i), i=1, 2, \dots, n\}$ , 将其粗粒化处理,获得新序列如下:

$$y^s(j) = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x(i); j=1, 2, \dots, [N/s] \quad (33)$$

式中  $[N/s]$  为取整数值;  $s$  为尺度因子,若  $s$  取值为1,则原始序列和处理后序列相等。

再将此步骤得到的序列进行重构,可得:

$$Y_l^{(s)} = \{y_l^{(s)}, y_{l+\tau}^{(s)}, \dots, y_{l+(m-1)\tau}^{(s)}\} \quad (34)$$

式中  $\tau$  为延迟时间;  $m$  为嵌入维数。

首先,将该步骤的  $Y_l^{(s)}$  按照由小到大的顺序完成排列;接着,全部粗粒化序列  $y^s(j)$  均可得到相应的符号序列  $S(r)=(l_1, l_2, \dots, l_m)$ , 其中  $r=1, 2, \dots, R$  且  $R \leq m!$ ; 最后,各个符号序列随机出现的概率  $P_r$  大小以及相对应的排列熵值可按下式计算:

$$H_p(m) = - \sum_{r=1}^R P_r \ln P_r \quad (35)$$

式中  $H_p(m)$  为排列熵值。

### 4 故障诊断流程

基于以上分析,提出本文故障诊断方法,其流程如图10所示。主要步骤可以归结为:

- (1)采集各类轴承在不同工况下的振动信号。
- (2)通过SVD分解对采集数据进行降噪。
- (3)对各类信号进行VMD分解,再利用MPE计算及归一化,挑选有用数值,构建多组特征向量作

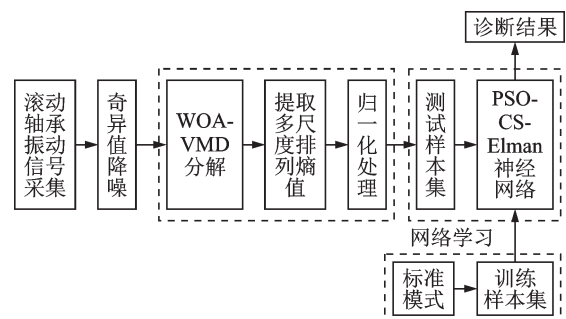


图10 故障诊断流程图

Fig. 10 Flow chart of fault diagnosis



为网络的输入。

(4)对Elman神经网络完成优化设计,将特征向量进行分组,输入到网络中进行训练及测试。同时,通过不同网络结构对同组样本数据的分类结果加以对比分析。

## 5 试验验证

为检验上述方法的诊断性能,本文以实验室内机械传动故障植入诊断试验平台和凯斯西储大学轴承故障诊断试验台采集的两份传感器数据为研究对象,进行故障诊断试验。

### 5.1 试验数据来源

#### 5.1.1 试验数据

通过线切割在圆柱滚子轴承的外圈、内圈和滚子上开槽来制造故障,各状态轴承如图11所示。利用图12试验台模拟正常轴承和这三种故障轴承的实际运行状况。在此过程中,设置电机频率为45 Hz,径向载荷为200 kg,采样频率为16 kHz,连续采集振动加速度信号。



图11 轴承各状态

Fig. 11 Each state of bearing




图12 机械传动故障植入诊断试验平台

Fig. 12 Mechanical transmission fault implantation diagnosis test platform

#### 5.1.2 凯斯西储大学数据

凯斯西储大学以图13所示电机驱动端和风扇端的轴承作为诊断对象,分别在测试轴承的内圈、外圈及滚子上采用电火花加工的方式引入单点损伤来模拟轴承的三种故障,损伤尺寸分别为0.007(0.1778),0.014(0.3556)和0.021(0.5334) inch(mm),然后在不同工况下由加速度传感器采集信号<sup>[25]</sup>。




图13 轴承故障诊断试验台

Fig. 13 Test bench of bearing fault diagnosis

本文仅将电机驱动端正常轴承、内圈、外圈以及滚子故障的轴承振动信号作为研究对象,故障数据具体如表3所示。采样频率为12 kHz。

表3 样本故障数据


Tab. 3 Sample fault data

样本编号	故障类型	故障直径/mm
1	正常	-
2	内圈裂纹	2.13
3	内圈裂纹	4.27
4	外圈裂纹	2.13
5	外圈裂纹	4.27
6	滚子裂纹	2.13
7	滚子裂纹	4.27
8	滚子裂纹	6.40

### 5.2 特征向量的构建


将实验采集的振动信号集按照类别平滑划分为若干个点数为16000的小样本。为了避免环境对有效信号的影响,采用SVD对信号进行降噪。图14所示为正常轴承的原始振动信号与降噪信号。

接着,采用WOA-VMD方法对全部样本信号



(a) 原始信号

(a) Original signal



(b) 降噪信号

(b) Noise reduction signal

图14 正常轴承的原始振动信号与降噪信号

Fig. 14 Original vibration signal and noise reduction signal of normal bearing



进行合理分解,并提取其MPE作为特征值。图 15 即为某组信号的时域、频域自适应分解结果。

利用该方法对多组样本信号进行参数寻优,发现分解层数均超过 5 层。关于 MPE 的参数选取,郑近德等<sup>[26]</sup>通过仿真发现,当尺度因子  $s=11$ 、嵌入维数  $m=6$ 、时间延迟  $\tau=1$  时,能够有效提取出轴承信号中的特征信息;本文借鉴其试验参数,分别计算各信号分量的 MPE 值并归一化。刁宁坤等<sup>[27]</sup>通过仿真发现当  $s$  逐渐增大时,4 种状态的排列熵值逐渐接近,在前几个尺度的排列熵值中包含较多信息。于是,本文从多尺度排列熵中选用前 4 行、前 2 列的数据进行排列,组合成一个 8 列 1 行的特征向量,当作网络的一个输入样本。按照上述方法,利用 MATLAB 为 4 种类型信号分别生成 60 组输入样本,其图形表示如图 16 所示。可以看出,4 类信号的 MPE 特征向量在某些元素上有较明显差别,信号特征提取

效果较好。

类似地,针对凯斯西储大学的 6 类振动信号,分别构造出 45 组输入样本,其图形化表示如图 17 所示,各类型的特征向量均可发现明显差别。






图 16 不同故障类型的 MPE 分布(实验数据)

Fig. 16 MPE distribution of different fault types (Experimental data)



(a) Diagram of time domain waveform



(b) Spectrum diagram

图 15 振动信号的 WOA-VMD 分解

Fig. 15 WOA-VMD decomposition of vibration signal




图 17 不同故障类型的 MPE 分布(开源数据)

Fig. 17 MPE distribution of different fault types (Open source data)

### 5.3 仿真试验与结果分析

#### 5.3.1 基于试验数据的仿真试验与结果分析

本文选择仅包含一个隐含层的 4 层 Elman 神经网络结构。该仿真试验是以归一化 MPE 8 元素特征向量作为输入,而输出则以单个标签形式呈现,于是,将输入和输出层的神经元数目分别定为 8 和 1。隐含层神经元个数的选取参考下式,最终定为 17。

$$i = \sqrt{m + n} + a \quad (36)$$

式中  $m$  和  $n$  分别为输入和输出层个数; $a$  为  $[1, 10]$  内的一个定值。

马位涛<sup>[28]</sup>曾做过多组传递函数搭配的测试对比,发现“tansig+purelin”的测试性能最佳,它在结果准确度以及网络训练时间上均有较大优越性。本文借鉴其经验,将该组合确定为隐藏和输出层的传递函数。

PSO 及 CS 算法的各参数对测试结果有着至关

重要的作用。通过多次仿真,确定其参数:对于 PSO,学习因子  $c_1=c_2=1.5$ ,最大速度  $V_{max}=0.9$ ,最小速度  $V_{min}=0.4$ ,粒子数为 20;对于 CS 算法,巢穴数量为 20,被宿主发现的概率  $P_a=0.25$ ,最大迭代次数为 100。

将所有特征样本输入至 PSO-CS-Elman 中运行,将 Elman 神经网络的训练误差作为适应度函数。此过程中,将 240 个总样本按照类别均等划分为训练样本和测试样本,即保证各类型的训练和测试样本数均为 30;但具体样本不指定用于训练或测试,而是通过程序使其随机完成分组。为了评价其优化性能的好坏,再将相同样本分别输入至 Elman, PSO-Elman 和 CS-Elman 神经网络中进行测试,相关参数设置保持一致。

图 18 为 3 种优化算法运行时适应度的变化曲线, PSO-CS 算法在第 29 次迭代时便达到了最优适应度值 0.0152,它在迭代次数与收敛精度方面明显优于其他两者。图 19 所示为 4 种网络结构此次对测

试样本的识别结果对比。由图 18, 19 的曲线可知, PSO 和 CS 优化 Elman 的识别结果比较相近,都比原始网络结构识别准确率高,但 PSO-CS-Elman 故障识别的出错数目最少,其准确率比原始 Elman 神经网络提升了 10%,优越性比较明显。




图 18 3 种优化算法的适应度变化

Fig. 18 Variation of fitness of three optimization algorithms

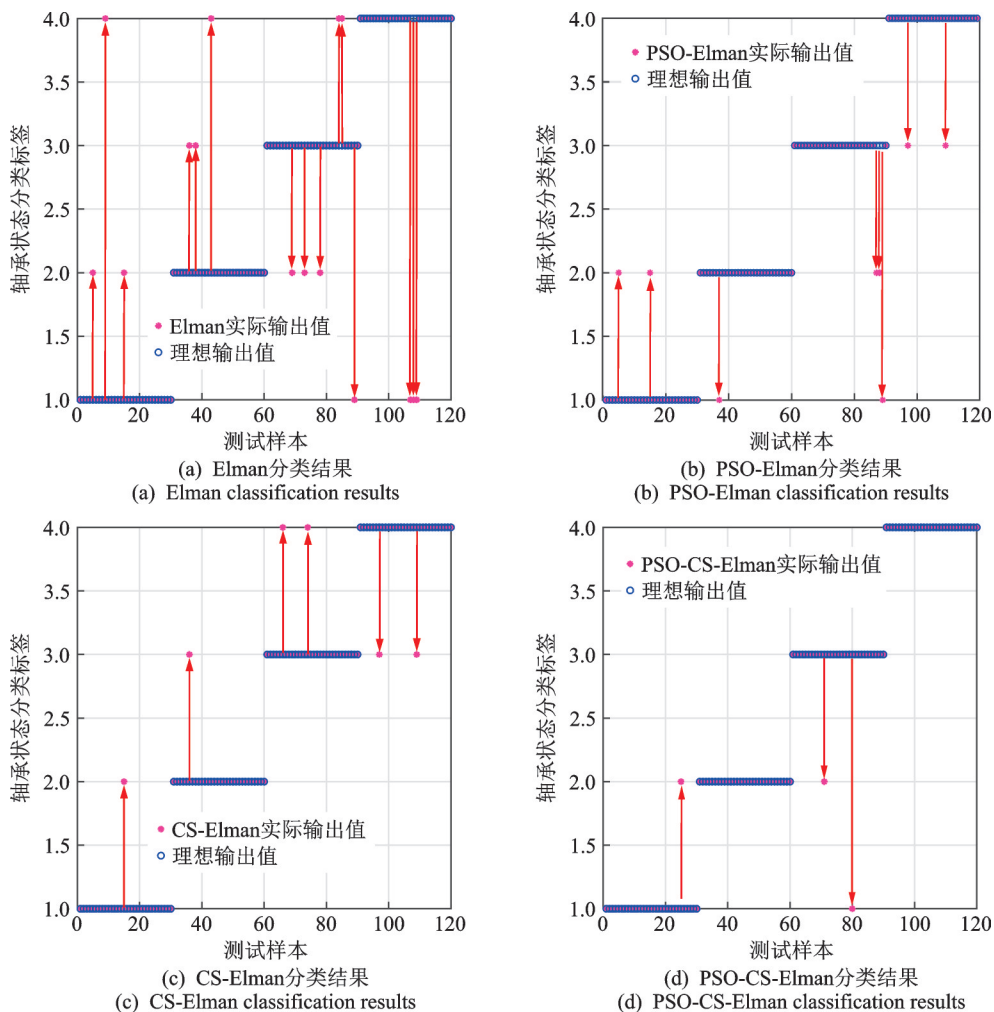


图 19 4 种方法的单次分类结果对比

Fig. 19 Comparison of single classification results of four methods

之后,将 4 种方法分别再运行 5 次,这样处理可以避免网络结构对某组既定的测试样本有偶然的较

高识别率。同时,引入 BP, PSO-BP 和 SVM 方法进行同样的分析,所得分类结果如表 4 所示。从表 4 的

表4 不同算法故障诊断结果对比(实验数据)

Tab. 4 Comparison of fault diagnosis results of different algorithms (Experimental data)

算法	测试出错数量/个						平均准确率/%	平均耗时
	第1次	第2次	第3次	第4次	第5次	第6次		
Elman	15	12	12	12	14	12	89.31	2'33"
PSO-Elman	8	10	6	7	7	5	94.03	3'34"
CS-Elman	6	6	5	7	6	7	94.86	3'52"
PSO-CS-Elman	3	4	3	3	4	3	97.22	6'17"
BP	11	11	12	9	9	9	91.53	2'27"
PSO-BP	9	7	7	10	7	8	93.33	3'26"
SVM	8	7	7	7	8	8	93.25	2'27"

平均准确率中可以看出,PSO-CS-Elman拥有最好的故障识别率,比原始网络提升了7.91%;但是,它在获取较高准确率的同时放弃了一定的诊断速率,其平均速率低于其他方法。尽管如此,参照以往的深度学习故障诊断模型,其速率在可接受范围内。

5.3.2 基于开源数据的仿真试验与结果分析

该试验的训练和测试样本数量分别定为210组

和105组,且每种类型均匀划分。然后将其输入至4种神经网络结构中进行仿真测试;其中,各参数均与上节所述一致。图20为各优化算法适应度的变化曲线;图21为4种网络结构对测试样本的单次分类结果对比。

由图20可知,PSO-CS算法在迭代次数为30时,适应度值达到了最低值0.0238,而PSO和CS算






图20 3种优化算法的适应度变化


Fig. 20 Variation of fitness of three optimization algorithms



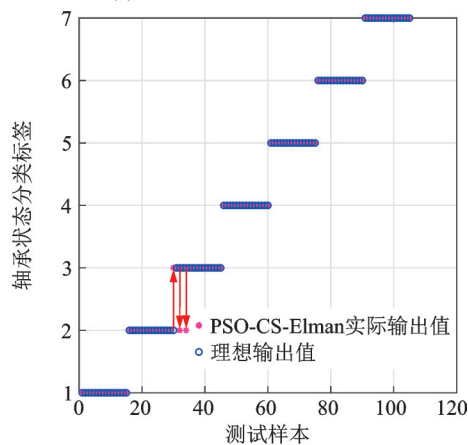
(a) Elman分类结果  
(a) Elman classification results



(b) PSO-Elman分类结果  
(b) PSO-Elman classification results



(c) CS-Elman分类结果  
(c) CS-Elman classification results



(d) PSO-CS-Elman分类结果  
(d) PSO-CS-Elman classification results

图21 4种方法的单次分类结果对比

Fig. 21 Comparison of single classification results of four methods



法分别在第 59 和 47 次迭代时,适应度值达到 0.0462 和 0.0401;明显地,PSO-CS 算法在迭代次数和收敛精度上依然占据优势。通过观察图 21 的仿真结果,总体上,PSO-CS-Elman 神经网络仍然具有最高的故障分类识别效果,准确率高达 97.14%。

同样地,引入多种算法进行多次测试,获得结果如表 5 所示。对比可知,PSO-CS-Elman 的高故障识别率具有一定的稳定性,且比原始神经网络准确率提升了 10.32%,但其运算速率依然最低,这是因为在算法迭代过程中,为了追求更高准确率,不断调整参数,将模型结构计算过程稍微复杂化,但总的来说,其运算速率与诊断正确率达到了一定平衡。

表 5 不同算法故障诊断结果对比(凯斯西储大学数据)

Tab. 5 Comparison of fault diagnosis results of different algorithms (Data from Case Western Reserve University)

算法	测试出错数量/个						平均准确率/%	平均耗时
	第 1 次	第 2 次	第 3 次	第 4 次	第 5 次	第 6 次		
Elman	16	13	14	13	14	13	86.83	2'17"
PSO-Elman	12	9	10	9	9	10	90.64	3'46"
CS-Elman	9	10	10	9	6	8	91.75	3'40"
PSO-CS-Elman	3	5	3	2	2	3	97.15	5'43"
BP	12	12	10	9	10	10	90.00	2'12"
PSO-BP	10	9	8	9	9	10	91.27	2'54"
SVM	9	8	7	7	8	8	92.54	2'31"

## 6 结 论

基于参数优化 VMD 多尺度排列熵和 PSO-CS-Elman 神经网络,可以有效地实现对滚动轴承的故障诊断。

(1) 针对振动信号在 VMD 分解时受分解数量  $K$  和惩罚因子  $\alpha$  的影响,提出采用鲸鱼优化算法对 VMD 进行参数优化,使滚动轴承振动信号可以自适应地分解,以便于后续的有效特征提取。通过仿真分析证明了 WOA 参数寻优的有效性,以及 WOA-VMD 信号分解的高效性。

(2) 通过开源数据和自行搭建试验台数据的多重分析对比,发现利用优化变分模态分解与多尺度排列熵所构建的特征向量,能够较好地地区分各个类型的轴承振动信号。

(3) PSO-CS-Elman 神经网络在训练过程中,在迭代次数和收敛精度上依然占据优势。并且它有着更为优越和稳定的故障分类效果:在实验数据与开

源数据仿真测试中的平均分类准确率高达 97.22% 和 97.15%,相较于原始 Elman 神经网络分别提升了 7.91% 和 10.32%;在此过程中,牺牲了一定的运算速率,但总体而言,其速率比通常深度学习速率要快很多。在某种意义上,本文方法在运算速率与诊断准确率上做到了互相平衡。

## 参考文献:

- [1] LIN P, LEI Y G, LIN J, et al. An improved exponential model for predicting remaining useful life of rolling element bearings [J]. IEEE Transactions on Industrial Electronics, 2015, 62(12): 7762-7773.
- [2] XIA T B, ZHUO P C, XIAO L, et al. Multi-stage fault diagnosis framework for rolling bearing based on OHF Elman AdaBoost-Bagging algorithm [J]. Neurocomputing, 2021, 433: 237-251.
- [3] WANG Z Y, YAO L G, CHEN G, et al. Modified multiscale weighted permutation entropy and optimized support vector machine method for rolling bearing fault diagnosis with complex signals [J]. ISA Transactions, 2021, 114: 470-484.
- [4] 郑近德, 代俊习, 朱小龙, 等. 基于改进多尺度模糊熵的滚动轴承故障诊断方法 [J]. 振动、测试与诊断, 2018, 38(5): 929-934.  
ZHENG Jinde, DAI Junxi, ZHU Xiaolong, et al. A rolling bearing fault diagnosis approach based on improved multiscale fuzzy entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38 (5) : 929-934.
- [5] 陈东宁, 张运东, 姚成玉, 等. 基于 FVMD 多尺度排列熵和 GK 模糊聚类的故障诊断 [J]. 机械工程学报, 2018, 54(14): 16-27.  
CHEN Dongning, ZHANG Yundong, YAO Chengyu, et al. Fault diagnosis based on FVMD multi-scale permutation entropy and GK fuzzy clustering [J]. Journal of Mechanical Engineering, 2018, 54 (14) : 16-27.
- [6] Staszewski W J, Tomlinson G R. Application of the wavelet transform to fault detection in a spur gear [J]. Mechanical Systems and Signal Processing, 1994, 8 (3): 289-307.
- [7] Smith J S. The local mean decomposition and its application to EEG perception data [J]. Journal of the Royal Society Interface, 2005, 2(5): 443-454.
- [8] 陈是扞, 彭志科, 周鹏. 信号分解及其在机械故障诊断中的应用研究综述 [J]. 机械工程学报, 2020, 56 (17): 91-107.  
CHEN Shiqian, PENG Zhike, ZHOU Peng. Review of signal decomposition theory and its applications in

- machine fault diagnosis[J]. Journal of Mechanical Engineering, 2020, 56(17): 91-107.
- [9] 徐卓飞,刘凯,张海燕,等.基于经验模式分解和主元分析的滚动轴承故障诊断方法研究[J].振动与冲击,2014,33(23):133-139.
- XU Zhuofei, LIU Kai, ZHANG Haiyan, et al. A fault diagnosis method for rolling bearings based on empirical mode decomposition and principal component analysis [J]. Journal of Vibration and Shock, 2014, 33(23): 133-139.
- [10] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [11] 武英杰,甄成刚,刘长良.变分模态分解在风电机组故障诊断中的应用[J].机械传动,2015,39(10):129-132.
- WU Yingjie, ZHEN Chenggang, LIU Changliang. Application of variational mode decomposition in wind power fault diagnosis[J]. Journal of Mechanical Transmission, 2015, 39(10): 129-132.
- [12] 唐贵基,王菲,周福成,等.基于谱峭度与变分模态分解的转子微弱不对中故障诊断[J].噪声与振动控制,2018,38(1):204-208.
- TANG Guiji, WANG Fei, ZHOU Fucheng, et al. Fault diagnosis of weak misalignment of rotors based on spectral kurtosis and VMD[J]. Noise and Vibration Control, 2018, 38(1): 204-208.
- [13] 武哲,张强,黄华蒙,等.基于多尺度排列熵的复合行星齿轮故障诊断研究[J].机械设计与制造,2020(9):182-186.
- WU Zhe, ZHANG Qiang, HUANG Huameng, et al. Research on fault diagnosis of compound planetary gear based on dynamic model and multiscale permutation entropy[J]. Machinery Design & Manufacture, 2020(9): 182-186.
- [14] 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.
- [15] Van M, Kang H J. Bearing defect classification based on individual wavelet local fisher discriminant analysis with particle swarm optimization[J]. IEEE Transactions on Industrial Informatics, 2015, 12(1): 124-135.
- [16] Parmar U, Pandya D H. Experimental investigation of cylindrical bearing fault diagnosis with SVM[J]. Materials Today: Proceedings, 2021, 44(1): 1286-1290.
- [17] 姚立国,黄海松.改进K均值模拟退火聚类算法的滚动轴承故障诊断[J].组合机床与自动化加工技术,2017(4):114-117.
- YAO Ligu, HUANG Haisong. Rolling bearing fault diagnosis based on improved K-means simulated annealing clustering algorithm[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2017(4): 114-117.
- [18] LI J M, YAO X F, WANG X D, et al. Multiscale local features learning based on BP neural network for rolling bearing intelligent fault diagnosis[J]. Measurement, 2020, 153: 107419.
- [19] 任学平,霍灿鹏.基于小波包-SVD和IPSO-BP的滚动轴承故障诊断[J].煤矿机械,2021,42(2):148-151.
- REN Xueping, HUO Canpeng. Fault diagnosis of rolling bearing based on wavelet packet-SVD and IPSO-BP [J]. Coal Mine Machinery, 2021, 42(2): 148-151.
- [20] 唐立力,陈国彬.基于MEA优化BP神经网络的农机滚动轴承故障诊断[J].农机化研究,2019,41(3):214-218.
- TANG Lili, CHEN Guobin. Fault diagnosis for rolling bearing of agricultural mechanical based on BP neural network optimized by mind evolutionary algorithm[J]. Journal of Agricultural Mechanization Research, 2019, 41(3): 214-218.
- [21] 皮骏,黄江博.基于IPSO-Elman神经网络的航空发动机故障诊断[J].航空动力学报,2017,32(12):3031-3038.
- PI Jun, HUANG Jiangbo. Aero-engine fault diagnosis based on IPSO-Elman neural network[J]. Journal of Aerospace Power, 2017, 32(12): 3031-3038.
- [22] 沈长青,汤盛浩,江星星,等.独立自适应学习率优化深度信念网络在轴承故障诊断中的应用研究[J].机械工程学报,2019,55(7):81-88.
- SHEN Changqing, TANG Shenghao, JIANG Xingxing, et al. Bearings fault diagnosis based on improved deep belief network by self-individual adaptive learning rate[J]. Journal of Mechanical Engineering, 2019, 55(7): 81-88.
- [23] 王振亚,姚立纲.广义精细复合多尺度样本熵与流形学习相结合的滚动轴承故障诊断方法[J].中国机械工程,2020,31(20):2463-2471.
- WANG Zhenya, YAO Ligang. Rolling bearing fault diagnosis method based on generalized refined composite multiscale sample entropy and manifold learning [J]. China Mechanical Engineering, 2020, 31(20): 2463-2471.
- [24] 陈丙炎,宋冬利,张卫华,等.基于自适应MCKD的滚动轴承故障特征提取[J].机械强度,2020,42(6):1293-1301.
- CHEN Bingyan, SONG Dongli, ZHANG Weihua, et

- al. Fault feature extraction of rolling element bearings based on adaptive MCKD [J]. *Journal of Mechanical Strength*, 2020, 42(6): 1293-1301.
- [25] LOPARO K A. Bearing vibration data set [D]. Cleveland, Ohio: Case Western Reserve University, 2003.
- [26] 郑近德, 刘涛, 孟瑞, 等. 基于广义复合多尺度排列熵与 PCA 的滚动轴承故障诊断方法 [J]. *振动与冲击*, 2018, 37(20): 61-66.
- ZHENG Jinde, LIU Tao, MENG Rui, et al. Generalized composite multiscale permutation entropy and PCA based fault diagnosis of rolling bearings [J]. *Journal of Vibration and Shock*, 2018, 37(20): 61-66.
- [27] 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.
- DIAO Ningkun, MA Huaixiang, WANG Jinshi, et al. Fault diagnosis of rolling bearing based on MPE and PSO-SVM [J]. *Electronic Measurement Technology*, 2021, 44(21): 44-48.
- [28] 马位涛. 基于小波包变换和优化 Elman 神经网络的滚动轴承故障诊断方法研究 [D]. 武汉: 华中科技大学, 2016.
- MA Weitao. Research on fault diagnosis method of rolling bearings based on wavelet packet transform and optimized Elman neural network [D]. Wuhan: Huazhong University of Science and Technology, 2016.

## Rolling bearing fault diagnosis based on parameter optimized VMD-MPE and PSO-CS-Elman neural network

XIAO Mao-hua<sup>1</sup>, ZHOU Shuang<sup>1</sup>, HUANG Tian-yi<sup>1</sup>, ZHAO Yuan-fang<sup>1</sup>, FEI Xiu-guo<sup>2</sup>

(1. College of Engineering, Nanjing Agricultural University, Nanjing 210031, China;

2. Nanjing Chuangli Transmission Machinery Co., Ltd., Nanjing 211122, China)

**Abstract:** Aiming at the nonlinear and non-stationary characteristics of rolling bearing vibration signals, a fault diagnosis method based on parameter optimization variational modal decomposition (VMD), multi-scale permutation entropy (MPE) and particle swarm-cuckoo search fusion algorithm optimized Elman neural network is proposed. Aiming at the problem that the number of modal components and the penalty factor are difficult to determine in VMD, the whale optimization algorithm is introduced to make it autonomously search for the optimal solution. The VMD with the optimal parameters is used to decompose the simulation signal of the rolling bearing fault, and the envelope spectrum analysis of the optimum modal component is carried out, and then the coincidence degree of the simulated fault frequency with the actual value is compared to verify the feasibility of the method. Considering that MPE has the advantage of being able to explore dynamic changes in the signal, it is combined with parameter optimization VMD to obtain the MPE value of each modal component of the rolling bearing vibration signal. Part of the entropy value is selected to construct the feature vector and put in the three-dimensional space to observe its difference, so that it can well characterize different fault types. Aiming at the problem of low recognition accuracy of the Elman neural network, the particle swarm optimization (PSO) algorithm and the cuckoo search (CS) algorithm are combined to jointly optimize the weights and thresholds of the Elman network to improve the convergence accuracy and diagnosis accuracy of the network. The experimental collection and Case Western Reserve University's rolling bearing vibration signals are observed as the research objects, and the proposed method is used for analysis. The results show that the proposed method can not only decompose the signal adaptively and extract effective fault features, but also accurately realize the classification and recognition of fault modes, and the fault recognition rate is improved.

**Key words:** fault diagnosis; rolling bearing; parameter optimized variational mode decomposition; multi-scale permutation entropy; PSO-CS-Elman

**作者简介:** 肖茂华(1981—),男,博士,教授。电话: 13951756153; E-mail: xiaomaohua@njau.edu.cn。