

滚动轴承优选 WPE 与 ANVTPSO-BPNN 故障诊断*

樊红卫^{1,2}, 严 杨¹, 张旭辉^{1,2}, 张 超¹, 曹现刚^{1,2}, 薛策译¹,
毛清华^{1,2}, 李 杰¹

(1. 西安科技大学机械工程学院 西安, 710054)

(2. 西安科技大学陕西省矿山机电装备智能检测与控制重点实验室 西安, 710054)

摘要 为了提高滚动轴承故障诊断的效率和准确率,提出一种基于优选小波包能量(wavelet packet energy,简称 WPE)联合自适应无速度项粒子群优化前馈神经网络(adaptive no velocity term particle swarm optimization-back propagation neural network,简称 ANVTPSO-BPNN)的滚动轴承故障诊断方法。首先,采用小波分析对轴承振动信号进行消噪,并通过小波包分解提取能量特征,对基函数和分解层数进行优选;其次,采用自适应方式调节 PSO 算法的惯性权重和学习因子,并对标准 PSO 算法舍弃速度项以避免粒子初始速度对算法收敛速度和求解精度的影响;最后,针对某滚动轴承的实测数据,完成了 5 种不同策略的 BPNN 算法验证。结果表明:提出的方法迭代步数只有 273 步,诊断精度达到 99%,较消噪前后的 BPNN 及消噪后的 2 种 PSO-BPNN,具有更高的诊断效率和准确率。

关键词 滚动轴承;故障诊断;小波消噪;小波包分解;粒子群优化;神经网络

中图分类号 TH113.1;TH17

引 言

滚动轴承因长期处于运转状态,其内圈、外圈和滚动体等极易发生故障,轻则影响工作效率和品质,重则造成机毁人亡的事故。因此,有效识别滚动轴承的潜在故障是设备安全可靠运行的重要保障。为有效诊断滚动轴承的运行故障,振动信号处理和人工智能方法得到了广泛关注。在工业生产实际中,所测振动信号往往包含大量现场噪声,对故障特征提取造成困扰,不利于故障诊断。因此,信号消噪是滚动轴承故障诊断的基础。王宏强等^[1]提出了一种基于系数变换的小波阈值消噪算法,将信号和噪声区域放大以更好地选取阈值,达到了良好的消噪目的。王盟等^[2]提出了一种结合多尺度阈值的具有可调因子新函数,改进了小波阈值,克服了传统阈值函数存在恒等差和不连续而使信号失真等缺点。何孙东等^[3]根据小波变换系数,优选了小波基函数,对振动信号进行小波消噪,并验证了消噪效果。闫晓玲等^[4]对信号进行最优小波包滤波处理,并根据小波包系数 Shannon 熵的变化规律确定了分解层数。对实测信号消噪后准确提取轴承故障特征,再以此为

基础采用神经网络进行轴承故障诊断。吕楠等^[5]利用 BPNN 结合小波函数,实现了滚动轴承的故障诊断。赵洁等^[6]针对轴承故障识别率低、故障信号不平稳的问题,提出了改进小波包节点重构特征提取和神经网络的故障诊断方法。然而,标准的 BPNN 易陷入局部最优解,而 PSO 等优化算法可在更大空间进行搜索,能在一定程度上克服 BPNN 的不足。鞠晨等^[7]通过 PSO 对 BPNN 的权值、阈值进行优化,并通过小波包提取特征能量,使滚动轴承诊断的准确率得到提升。李益兵等^[8]利用 PSO 优选深度置信网络,解决了网络调试费时等问题。标准 PSO 也存在收敛精度不高、易陷入局部极值等问题。徐呈艺等^[9]采用驱散机制扩大 PSO 空间范围,避免了陷入局部最优时过早收敛。王丽等^[10]引入递减指数和迭代阈值对标准 PSO 的线性递减权重进行改进,验证了改进 PSO 在搜索精度、收敛速度及稳定性等方面的优势。朱雅敏等^[11]针对 PSO 中学习因子取固定值影响算法性能的问题,对学习因子进行了自适应修正,使其能更好地平衡局部和全局搜索能力。

综上所述,小波分析和小波包分解是滚动轴承振动信号消噪及特征提取的常用方法,BPNN 因其

* 国家自然科学基金资助项目(51605380,51974228,52275131);陕西省自然科学基金基础研究计划资助项目(2019JLZ-08);陕西省大学生创新创业训练计划资助项目(S202010704059)

收稿日期:2021-01-12;修回日期:2021-06-09

简单实用而在各类神经网络中被广泛应用,PSO则是最常用的一种优化算法。因此,“小波+PSO+BPNN”的集成算法是典型的滚动轴承故障诊断方法。目前,小波基函数、小波(包)分解层数的选择及PSO算法如何避免陷入局部最优和提高收敛速度仍是制约该方法广泛应用的关键问题。笔者提出一种基于WPE的ANVTPSO-BPNN算法,对小波消噪和小波包分解的基函数和分解层数进行最优选取,并对PSO舍弃速度项以及对惯性权重、学习因子等进行自适应调节,以提高该方法对滚动轴承故障诊断的效率和准确率。

1 小波消噪方法

1.1 小波消噪原理

消噪是为了准确提取有用信号的特征。对信号进行小波变换,产生含有重要信息的小波系数,以此反映有用信号中的最小频率成分。通常有用信号的小波系数较大,而噪声的小波系数较小,且有用信号的小波系数大于噪声。通过选取合适的阈值,大于阈值的小波系数被认为由有用信号产生,予以保留;而小于阈值的则认为由噪声产生,置为零,以此达到消噪目的。

1.2 小波分解层数确定

消噪过程中,噪声能量随着分解层数的递增而逐渐减少,主要体现在小波分解系数上。当分解层数过多时,不仅增加计算量,还会造成有用信号的丢失;当层数过少时,噪声不能被有效消除。为此,笔者根据有用信号的最小频率来确定小波分解的最大层数^[12]。设最大分解层数为 j ,有

$$2^{j-1} \leq f_0 / (\Delta t * f_m) \leq 2^j \quad (1)$$

其中: f_0 为小波基函数的中心频率; f_m 为有用信号的最小频率; Δt 为采样周期。

滚动轴承的振动信号尤其是故障状态信号,其有用信号的频率分为转动频率和故障频率^[13]。因此,故障轴承信号的最小频率采用故障特征频率替代。令轴承所在轴的转频为 f_r ,轴承内圈故障特征频率为

$$f_i = \frac{1}{2} f_r Z \left(1 + \frac{d}{D} \cos \alpha\right) \quad (2)$$

其中: f_r 为轴承所在轴的转频; Z 为滚动体个数; D 为节径; d 为滚动体直径; α 为接触角。

轴承外圈故障特征频率为

$$f_o = \frac{1}{2} f_r Z \left(1 - \frac{d}{D} \cos \alpha\right) \quad (3)$$

轴承滚动体故障特征频率为

$$f_b = \frac{1}{2} f_r \frac{D}{d} \left[1 - \left(\frac{d}{D} \cos \alpha\right)^2\right] \quad (4)$$

1.3 小波消噪的基函数选取

小波基函数的初选一般通过小波的正交性、紧支性、对称性、消失矩及正则性确定。但是,只根据这些性质往往难以做到最优选取,因此笔者通过噪声功率 p 来衡量噪声,其计算公式^[14]为

$$p = \frac{1}{Q} \sum (S - S_1)^2 \quad (5)$$

其中: Q 为信号长度; S 为含噪原始信号; S_1 为消噪后的信号。

原始信号中含噪量的多少由噪声功率衡量,但消噪效果的优劣并不能全由噪声功率的取值决定。当信号消噪过度,部分有用信号被当作噪声滤除,噪声功率的取值会较大。当信号消噪不理想时,信号中仍含有噪声,噪声功率的取值会较低。因此,将噪声功率作为小波基函数选取的第1个指标。

选取2种不同的小波基函数对原始含噪信号进行消噪,并对消噪后的信号求噪声功率差 Δp_h ,以此衡量残留噪声。当 Δp_h 为最小时,说明原始含噪信号达到了最好的消噪效果。因此,将噪声功率差 Δp_h 作为第2个衡量信号消噪效果的指标,即

$$\Delta p_h = \frac{1}{Q} \sum_{q=0}^{Q-1} [s_h(q) - s_{h-1}(q)]^2 \quad (6)$$

其中: $s_h(q)$ 为消噪后的信号; h 为小波基编号; $s_0(q)$ 为原始含噪信号。

小波基函数优选步骤如下:

1) 通过式(1)确定不同小波基函数在原始信号中的最优分解层数;

2) 选取不同小波基函数对原始信号按最优分解层数消噪,由式(5)求取不同小波基函数下的噪声功率;

3) 对于备选的小波基函数,按照噪声功率从小到大依次排序,从 $h=1$ 开始依次增加;

4) 通过式(6)依次计算 Δp_h ;

5) 选出最小 Δp_h ,编号为 $h-1$ 的小波基函数即为最优小波基函数。

由于消噪过程中一定存在消噪过度的现象,所以噪声功率最高的小波基函数不作为最优小波基函

数考虑,只参与计算。

2 小波包能量特征提取方法

2.1 小波包分解原理

小波包分解克服了小波分析只对信号低频部分进行分解的缺陷,其也对高频部分进行分解,提高了时频分辨率。小波包分解的具体过程为:设信号为 S ,每个节点表示为 (j, n) ,对应的小波包系数为 d_j^n ,其中 j 为分解层数, n 为第 j 层的节点索引。 S 经第1层分解后得到两部分,左节点得到信号的概貌部分 d_1^0 ,右节点得到细节部分 d_1^1 。以此类推,在第 j 层得到 2^j 个分解信号,具体算法如下。

给定尺度函数 $\phi(t)$ 和小波基函数 $\psi(t)$,满足双尺度方程

$$\begin{cases} \phi(t) = \sqrt{2} \sum_{k \in Z} h_k \phi(2t - k) \\ \psi(t) = \sqrt{2} \sum_{k \in Z} g_k \psi(2t - k) \end{cases} \quad (7)$$

其中: k 为时间平移因子; h_k 为低通滤波系数; g_k 为高通滤波系数。

小波包分解算法为

$$\begin{cases} d_i^{j, 2n} = \sum_k a_{k-2l} d_k^{j+1, n} \\ d_i^{j, 2n+1} = \sum_k b_{k-2l} d_k^{j+1, n} \end{cases} \quad (8)$$

其中: j 为小波包分解层数; $d_i^{j, 2n}$ 为第 j 层分解的低频系数; $d_i^{j, 2n+1}$ 为第 j 层分解的高频系数。

2.2 小波包分解层数确定

分解层数同样影响故障特征提取,并且决定特征向量维数。当分解层数过少时,各频段信息无法完全分解,轴承特征信息未被精确提取,影响故障诊断准确度;增加小波包分解层数虽能对故障信号进行更精细分析,但分解后信号数量增加,特征向量维数过大,对故障识别效率等造成影响。因此,小波包分解层数应考虑信号自身特点。本研究采用式(9)计算最佳分解层数^[15-16],即

$$J = \left\{ \max \left| j < \log_2 \frac{f_s}{4f_{sf}}, j \in Z \right. \right\} \quad (9)$$

其中: J 为最大层数; f_s 为采样频率; f_{sf} 为信号频率。

2.3 小波包分解的基函数选取

小波基函数的选取不仅影响特征提取准确性,

且进一步影响故障诊断结果。信号波形与所选小波基波形相似的部位被增强,其余部分被抑制^[16]。故障轴承比正常轴承的各频带能量波动大,而小波包分解正是对轴承信号提取其能量特征,因此可通过能量波动变化率对小波基函数进行优选。

因正常轴承和故障轴承各频带能量分布的差异,采用式(10)计算轴承正常和故障状态下对应的能量波动参数 E_{flu} ^[17],即

$$E_{flu} = \frac{\max(E_j^n) - \text{mean}(E_j^n)}{\max(E_j^n) - \min(E_j^n)} \quad (10)$$

其中: E_j^n 为各频带能量占总能量的百分比, $n = 0, 1, \dots, 2^j - 1$ 。

通过式(10)得到两者间的能量波动变化率 E'

$$E' = \frac{E_{flu} - E_{nor}}{E_{nor}} \times 100\% \quad (11)$$

其中: E_{nor} 为正常信号的能量波动参数。

由式(11)可知,当 E' 越大时,表明故障信号的特性偏离正常信号更多,故障信号的特征能量越大,故障特征越明显。因此, E' 最大时对应小波包分解中的小波基函数即为最优小波基。

2.4 小波包能量特征向量构造

小波包能量特征向量的构造步骤如下。

1) 对消噪后的信号进行小波包分解,信号经过 j 层分解后,生成 2^j 个子信号,第 j 层第 n 个节点 $S_{j, n}$ 的能量表示为

$$E_{j, n} = \sum_{q=1}^Q (S_{j, n}(q))^2 \quad (12)$$

其中: j 为小波包分解层数; $n = 0, 1, \dots, 2^j - 1$ 为第 j 层第 n 个节点; Q 为信号长度。

2) 信号总能量为

$$E_j = \sum_{n=0}^{2^j-1} E_{j, n} \quad (13)$$

3) 以各节点能量和总能量构造向量,即

$$E = [E_{j, n}, E_j] \quad (14)$$

4) 对式(14)向量统一进行归一化,即

$$\bar{E} = [\bar{E}_{j, n}, \bar{E}_j] \quad (15)$$

3 ANVTPSO-BPNN故障诊断方法

3.1 无速度项PSO算法

PSO是模拟鸟群随机搜寻食物的群体智能优化算法。设在一个 A 维搜索空间中,有 B 个粒子组

成的群体,其中第*i*个粒子表示为一个*A*维向量 $X_i=(X_{i1}, X_{i2}, \dots, X_{iA})$, $i=1, 2, \dots, B$ 。每个粒子的位置是一个潜在解,第*i*个粒子的飞行速度记为 $V_i=(V_{i1}, V_{i2}, \dots, V_{iA})$ 。迭代中,粒子速度和位置更新通过跟踪2个极值完成:第1个为粒子本身找到的最优解,即个体极值记为 $P_i=(P_{i1}, P_{i2}, \dots, P_{iA})$;第2个为整个种群找到的最优解,即全局极值记为 $P_g=(P_{g1}, P_{g2}, \dots, P_{gA})$ 。第*i*个粒子在第*a*维的粒子速度 $V_{ia}(t)$ 和位置 $X_{ia}(t)$ 更新公式为

$$V_{ia}(t+1)=\omega(t)V_{ia}(t)+c_1r_1(P_{i1}(t)-X_{ia}(t))+c_2r_2(P_{g1}(t)-X_{ia}(t)) \quad (16)$$

$$X_{ia}(t+1)=X_{ia}(t)+V_{ia}(t+1) \quad (17)$$

其中: $a=1, 2, \dots, A$; $\omega(t)$ 为惯性权重; t 为迭代次数; c_1 和 c_2 为学习因子; r_1 和 r_2 为 $[0, 1]$ 之间的随机数。

为避免粒子初始速度随机给定对算法收敛速度和解的精度影响,笔者舍弃了标准PSO算法的速度项^[18],即根据式(18)对位置进行更新

$$X_{ia}(t+1)=\omega(t)X_{ia}(t)+c_1r_1(P_{i1}(t)-X_{ia}(t))+c_2r_2(P_{g1}(t)-X_{ia}(t)) \quad (18)$$

3.2 自适应PSO算法

PSO算法存在易早熟收敛、收敛精度较低及后期迭代效率不高等缺点^[19],惯性权重 ω 调节粒子在解空间的搜索能力,其取值影响算法的寻优水平。在搜索前期,希望粒子先进行广域搜索,再快速确定全局最优位置区域,然后通过局部搜索获得高精度解。笔者采用自适应方式修正惯性权重,惯性权重随粒子目标函数值的改变而改变^[20],即

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}} & (f \leq f_{\text{avg}}) \\ \omega_{\max} & (f > f_{\text{avg}}) \end{cases} \quad (19)$$

其中: ω_{\max} 为最大惯性权重; ω_{\min} 为最小惯性权重; f 为粒子实时目标函数值; f_{avg} 和 f_{\min} 分别为当前所有粒子的平均值和最小值。

PSO算法具有进化的阶段性,不同阶段应设置不同的学习因子。搜索初期,为增强粒子全局搜索能力,使 c_1 取较大值, c_2 取较小值;搜索后期,应增强粒子局部搜索能力, c_1 应取较小值, c_2 取较大值。笔者采用异步非线性自适应调节学习因子^[21],即

$$\begin{cases} c_1 = 2 + (f - f_{\text{avg}})/(f_{\text{avg}} - f_{\min}) \\ c_2 = 2 - (f - f_{\text{avg}})/(f_{\text{avg}} - f_{\min}) \end{cases} \quad (20)$$

其中:2为学习因子 c_1 和 c_2 的初始值。

3.3 ANVTPSO-BPNN算法

BPNN是多层前馈神经网络,通过反复调整各层神经元权值和阈值直到网络误差达到预期精度。标准的BPNN易陷入局部最优解,而PSO算法可在更大空间进行搜索,当其用于BPNN的阈值和权值优化时,可在一定程度上避免该问题。但是,PSO算法参数设置对最终寻优结果有较大影响,笔者采用自适应方式调节PSO的惯性权重和学习因子并将其速度项舍去,即自适应无速度项PSO新算法,将其用于BPNN阈值和权值优化,ANVTPSO-BPNN算法流程如图1所示。

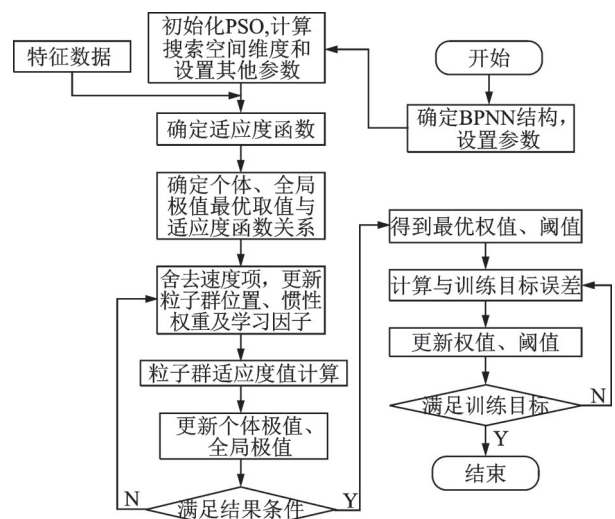


图1 ANVTPSO-BPNN算法流程图

Fig.1 Flow chart of ANVTPSO-BPNN algorithm

ANVTPSO-BPNN算法的实现步骤如下:

- 1) 根据特征数据设置输入节点*N*、隐层节点*L*及输出节点*M*等参数,明确BPNN的结构;
- 2) 初始化PSO,计算搜索空间维度*a*,设置种群数量、最大迭代次数 T_{\max} 等参数;
- 3) 将信号特征数据作为BPNN输入,计算每个粒子适应度值,适应度函数取训练实际输出与期望输出的均方误差函数MSE;
- 4) 计算PSO初始个体、全局最佳位置 P_i 和 P_g ;
- 5) 将PSO舍去速度项,按式(18)更新位置,按式(19)更新惯性权重,按式(20)更新学习因子,得到个体、全局最优极值,将PSO位置映射得到最优权值与阈值;
- 6) 将优化后的权值与阈值代入BPNN,继续调优,直至满足训练目标。

4 实验及分析

4.1 实验设计

为验证本研究所提出的方法,采用机械传动系统故障诊断综合实验台进行数据采集,如图2所示。该实验台由三相变频电机、转子轴承系统、径向加载装置及平行轴齿轮箱组成,均为滚动轴承支撑,通过磁粉制动器模拟负载。笔者选取转子左侧轴承座里的滚动轴承作为测试对象,该轴承型号为NSK-6205;设置电机转速为1.8 kr/min,径向轴向均空载,采用加速度传感器获取壳体振动,该传感器的灵敏度为103 mV/g(g 为重力加速度);采样时间设为1 s,采样率设为10.24 kHz;采集振动加速度信号共60组,其中正常、内圈故障、外圈故障和滚动体故障各15组,将不同状态下的轴承数据分割为互不重叠的5组长度为10 240个点的子样本。因此,4种状态下采集到的振动加速度信号总共分割为300组子样本,其中4类轴承各75组,将信号样本以2:1分为训练集和测试集。




图2 机械传动系统故障诊断综合实验台

Fig.2 Mechanical transmission system fault diagnosis comprehensive test platform

对正常轴承进行故障加工,得到3类不同故障轴承,其中内圈和外圈采用电火花成型机加工裂纹,滚动体采用高速激光焊接机对其进行3秒点蚀。3类故障的滚动轴承如图3所示,其结构参数如表1所示,故障尺寸如表2所示,故障特征频率如表3所示。



(a) 内圈故障 (a) Inner ring fault (b) 外圈故障 (b) Outer ring fault (c) 滚动体故障 (c) Rolling element fault

图3 3类故障的滚动轴承
Fig.3 Three faulted rolling bearings

表1 滚动轴承结构参数

Tab.1 Structural parameters of rolling bearing

滚动体个数	滚动体直径/mm	节圆半径/mm	接触角/(°)
9	7.94	39.36	0

表2 滚动轴承故障尺寸

Tab.2 Fault size of rolling bearing

轴承状态	(长×宽×高)/mm
正常	0
内圈故障	2×1.5×0.5
外圈故障	2×1.5×0.5
滚动体故障	点蚀

表3 滚动轴承故障特征频率

Tab.3 Fault characteristic frequency of rolling bearing

故障位置	f /Hz
内圈	162.23
外圈	107.76
滚动体	71.33

4.2 小波消噪方案确定

4.2.1 最优小波分解层数确定

笔者选择 sym8, db3, db4, db5 和 db10 这5个小波基函数作为确定最优小波分解层数的备选小波基函数。sym8是具有紧支性、正交性以及近似对称性的小波母函数,db系列的小波函数因其具有正则指数大的特点与被测信号相贴近^[17]。在对轴承信号的消噪和特征提取中,常用此2类小波基函数。小波基函数中心频率如表4所示,根据式(1)计算各类轴承信号基于不同小波基函数条件下的最优分解层数,如表5所示。

表4 小波基函数中心频率

Tab.4 Center frequency of wavelet basis function

类型	sym8	db3	db4	db5	db10
中心频率/Hz	0.666 7	0.800 0	0.714 3	0.666 7	0.684 2

表5 基于小波基函数的最优分解层数

Tab.5 Optimal decomposition level based on wavelet basis function

类型	sym8	db3	db4	db5	db10
正常	8	9	8	8	8
内圈	6	6	6	6	6
外圈	6	7	7	6	7
滚动体	7	7	7	7	7

由表5可知,基于不同小波基函数,各类轴承信号的最优分解层数存在差异。为了能最大限度保留

4类轴承振动信号的有用信息,在统一分解层数的选取上,分解层数若超过6层,内圈信号可能会导致消噪造成有用信息的丢失。经综合考虑,本研究统一分层取为6。

4.2.2 小波消噪的最优小波基函数确定

笔者采用基于 stein 的无偏似然估计原理计算自适应阈值^[13],结合软阈值,通过 wden 函数完成信号消噪。对未进行数据分割的4类轴承数据各选10组,根据在表5中确定的统一分解层数进行小波消噪,并按式(5)对备选小波基函数求取噪声功率 p ,代表性的1组数据噪声功率计算值如表6所示。噪声功率排序如表7所示。按式(6)计算噪声功率差 Δp_h ,结果如表8所示。基于以上计算,按1.3节的步骤确定不同状态下各类数据对应的最优小波基函数,各类小波基函数在10组数据中出现的次数如表9所示,取在不同状态下出现次数最多的小波基函数为4类轴承信号统一的最优小波基函数。

由表8可知,4类轴承信号对应的最优小波基函数均为db5。由表9可知,本研究中小波消噪所选最优小波基函数为db5。

表6 噪声功率计算值

Tab.6 Calculated value of noise power $10^{-6} g^2$

类型	sym8	db3	db4	db5	db10
正常	6.424 0	6.743 7	6.373 0	6.279 7	6.210 4
内圈	4.701 0	5.099 5	4.922 7	4.890 5	4.798 1
外圈	5.383 6	5.756 0	5.658 9	5.656 2	5.436 0
滚动体	4.398 7	5.736 5	4.972 6	4.795 7	4.311 5

表7 噪声功率排序

Tab.7 Noise power ranking $10^{-6} g^2$

类型	1	2	3	4	5
正常	6.210 4 (db10)	6.279 7 (db5)	6.373 0 (db4)	6.424 0 (sym8)	6.743 7 (db3)
内圈	4.701 0 (sym8)	4.798 1 (db10)	4.890 5 (db5)	4.922 7 (db4)	5.099 5 (db3)
外圈	5.383 6 (sym8)	5.436 0 (db10)	5.656 2 (db5)	5.658 9 (db4)	5.756 0 (db3)
滚动体	4.311 5 (db10)	4.398 7 (sym8)	4.795 7 (db5)	4.972 6 (db4)	5.736 5 (db3)

表8 噪声功率差计算值

Tab.8 Calculated value of noise power difference $10^{-6} g^2$

类型	Δp_1	Δp_2	Δp_3	Δp_4	Δp_5
正常	6.210 4	2.666 2	1.368 2	3.071 8	4.141 9
内圈	4.701 0	1.755 2	1.778 8	1.039 7	1.149 8
外圈	5.383 6	2.004 6	1.932 1	1.172 4	1.330 2
滚动体	4.311 5	4.005 7	2.318 7	1.683 0	2.149 6

表9 轴承数据的最优小波基函数个数

Tab.9 Number of optimal wavelet basis functions for bearing data

类型	sym8	db3	db4	db5	db10
正常	0	0	3	4	3
内圈	0	0	3	4	3
外圈	0	1	3	3	3
滚动体	0	0	1	9	0

4类轴承时域波形如图4所示。由图4可知,虽然不同状态下时域信号及对应幅值存在差异,但无法从具体信号特征中分辨出对应类型,需对信号进一步分析,以提取不同特征信息,进而准确识别相应的故障类型。

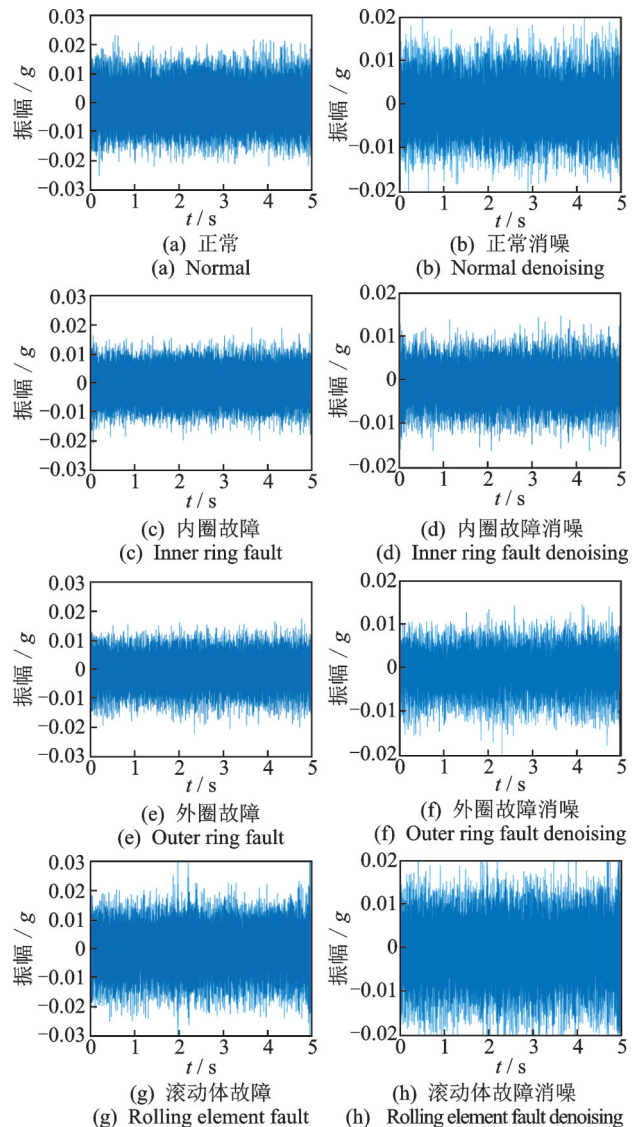


图4 4类轴承时域波形图

Fig.4 Time-domain waveform diagram of four bearings

4.3 小波包分解方案确定

4.3.1 最优小波包分解层数确定

小波包分解的目的是找到故障特征,因此信号

频率可用故障特征频率代替^[16]。通过式(9)计算得到小波包分解层数,如表 10 所示。由表可知,小波包分解层数的最佳取值为 3~5。其中,内圈故障计算得到的最优分解层数应小于 4,但所选层数过少时可能导致故障特征难以准确提取。为了最大限度保留 4 类轴承振动信号的有用信息,将小波包分解层数取为 3。

表 10 小波包分解层数

Tab.10 Decomposition level of wavelet packet

故障位置	分解层数
内圈	$J < 3.98$
外圈	$J < 4.57$
滚动体	$J < 5.16$

4.3.2 小波包分解的最优小波基函数确定

选取 4 类轴承数据各 10 组,对 sym8,db3,db4,db5 和 db10 小波基函数进行小波包 3 层分解,并按式(10)、式(11)进行计算,得到 4 类轴承数据对应的能量波动参数,如表 11 所示。3 类故障轴承间的波动变化率如表 12 所示。

表 11 4 类轴承的能量波动参数

Tab.11 Energy fluctuation parameters of four bearings

类型	sym8	db3	db4	db5	db10
正常	0.575 5	0.552 4	0.567 5	0.637 8	0.579 6
内圈	0.616 0	0.561 7	0.614 5	0.648 9	0.598 4
外圈	0.582 5	0.553 8	0.576 0	0.644 5	0.580 9
滚动体	0.603 4	0.567 9	0.595 3	0.650 5	0.601 8

表 12 故障轴承的波动变化率


Tab.12 Fluctuation rate of faulted bearing %

类型	sym8	db3	db4	db5	db10
内圈	7.03	1.68	8.28	1.74	3.24
外圈	1.22	0.25	1.50	1.05	0.22
滚动体	4.85	2.81	4.90	1.99	3.83


由表 12 可知,3 类故障轴承中波动变化率最大的均是 db4,可知故障轴承的特征能量最大,即故障特征明显。经综合考虑,选取 db4 作为本研究 4 类轴承信号小波包分解的最优小波基函数。

将 4 类轴承信号小波消噪后采用 db4 进行小波包 3 层分解求取 8 个子频带节点能量,并与总能量一起进行归一化,得到 9 维故障特征向量。信号消噪前后 4 类轴承的能量图如图 5 所示。由图可知:消噪前后 4 类轴承的能量分布在前 4 个频带中趋势变化不大,但消噪前 4 类轴承其余子频带能量分布差异不明显,易对故障区分形成干扰;而消噪后能量主要

集中在前 4 个频带,减小了其余频带的干扰,使各类轴承能量百分比比较之前差异更明显。



(a) 消噪前能量图
(a) Energy map before denoising



(b) 消噪后能量图
(b) Energy map after denoising

图 5 4 类轴承的能量图

Fig.5 Energy spectrum of four bearings

4.4 ANVTPSO-BPNN 参数确定

1) ANVTPSO 参数确定。粒子个数在 10~40 之间取值,初始粒子群位置 X 范围为 $[-1, 1]$,惯性权重 $w_{max} = 0.9, w_{min} = 0.4$,最大迭代次数 $T_{max} = 20$ 。

2) BPNN 参数确定。初始权值和阈值取值为 $[-1, 1]$,由小波包分解确定输入节点 N ,隐含层节点数 L 按式(22)选取,根据轴承 4 类状态确定输出节点 M 。网络训练终止条件是达到误差足够小,但当无法收敛到预期误差时也可采用最大迭代次数作为终止条件。训练目标越小说明 BPNN 训练计算越准确,本研究设为 10^{-8} 。学习率决定模型参数的更新速度,学习率大时可较快收敛,一般选择 0.001~1,隐含层、输出层传递函数分别为 tansig 和 purelin。

计算粒子的空间维度^[22]为

$$a = NL + LM + L + M \quad (21)$$

隐含层最佳节点数为

$$L = \sqrt{(M + N)} + \epsilon \quad (0 < \epsilon < 10) \quad (22)$$

ANVT PSO-BPNN 参数总结如表 13 所示, BPNN 模型的拓扑结构如图 6 所示。

表 13 ANVT PSO-BPNN 参数

Tab.13 Parameter of ANVT PSO-BPNN

ANVT PSO 参数	取值	BPNN 参数	取值
种群粒子个数	20	输入节点 N	9
空间维度 a	186	隐层节点 L	13
位置 X	$[-1, 1]$	输出节点 M	4
学习因子 c_1	待定	最大训练次数	1 000
学习因子 c_2	待定	训练目标	10^{-8}
惯性权重 w_{max}	0.9	学习率	0.001
惯性权重 w_{min}	0.4	隐含层传递函数	tansig
最大迭代次数 T_{max}	20	输出层传递函数	purelin




图 6 BPNN 模型的拓扑结构

Fig.6 Topological structure of BPNN model

图 6 中: $\omega_{\gamma\beta}$ 为输入层第 γ 个神经元到隐含层第 β 个神经元之间的连接权值; $\omega_{\beta\chi}$ 为隐含层第 β 个神经元到输出层第 χ 个神经元之间的连接权值; $b_{1\beta}$ 和 $b_{1\chi}$ 分别为隐含层第 β 个神经元和输出层第 χ 个神经元的阈值。

4.5 结果分析

对 4 类轴承信号设定期望输出, 如将正常轴承标识为 1 时, 期望输出为 $[1\ 0\ 0\ 0]$, 故障标记如表 14 所示。

表 14 故障标记表

Tab.14 Fault label table

标识	1	2	3	4
期望输出	$[1\ 0\ 0\ 0]$	$[0\ 1\ 0\ 0]$	$[0\ 0\ 1\ 0]$	$[0\ 0\ 0\ 1]$
故障类型	正常	内圈故障	外圈故障	滚动体故障

为证明本研究提出的基于优选 WPE 的 ANVT PSO-BPNN 算法的优越性, 采用 4 种不同的 BPNN 与之对比。首先, 消噪前后的信号通过优选 WPE 后提取能量特征, 采用原始信号的 BPNN

(raw signal BPNN, 简称 RSBPNN) 和标准 BPNN 对比, 验证优选条件下小波消噪对特征提取的准确性; 其次, 对消噪后信号分别进行标准 BPNN 和 PSO-BPNN, 验证标准 PSO-BPNN 较 BPNN 的优越性; 然后, 将统一 7 层小波消噪的 PSO-BPNN (unified layering PSO-BPNN, 简称 ULPSO-BPNN) 与上述 3 种方案 BPNN 进行对比, 研究信号消噪中分解层数对诊断结果的影响; 最后, 将 ANVT PSO-BPNN 与上述 4 种方法进行对比, 验证其优越性。5 种神经网络模型的误差曲线如图 7 所示。




图 7 5 种神经网络模型的误差曲线

Fig.7 Error curves of five neural network models

由图 7 可知: RSBPNN, PSO-BPNN 和 ANVT PSO-BPNN 等曲线在迭代步数为 100 步附近相交; 交点之前 RSBPNN 和 PSO-BPNN 误差更小, 交点之后 ANVT PSO-BPNN 更快收敛; PSO-BPNN 和 ANVT PSO-BPNN 在训练初期几乎重合, 从 100 步附近开始分叉, 分叉点之后 ANVT PSO-BPNN 更快收敛。从迭代过程看, RSBPNN, BPNN 和 PSO-BPNN 均出现了短暂陷入局部最小值的现象, 由此导致了总迭代步数增加, 其中 PSO-BPNN 较 RSBPNN 和 BPNN 表现更好。由上述结果可知: 小波消噪时优选基函数和分解层数使特征提取更准确; PSO-BPNN 和 BPNN 这 2 条曲线差异明显, PSO-BPNN 更快到达训练目标, 证明 PSO 对 BPNN 有明显优化效果。ULPSO-BPNN 训练至预设误差所需迭代步数最多, 可知在小波消噪时需根据轴承类型确定统一的分解层数, 不合理的统一划分会影响诊断算法的执行。

表 15 为轴承故障诊断结果对比。由表可知: BPNN 比 RSBPNN 诊断准确率提高了 3%; PSO-BPNN 比 BPNN 诊断准确率提高了 5%, 迭代步数减少了 191 步; ULPSO-BPNN 诊断准确率比 RSBPNN 提高了 3%, 但比 PSO-BPNN 低了 2%, 且迭代步数在所有方法中表现最差; PSO-BPNN 和

ULPSO-BPNN的PSO学习因子均按经验取 $c_1=c_2=1.49445$ 。而笔者提出的ANVTPSO-BPNN通过自适应调节惯性权重和学习因子,使惯性权重在初期搜索时取0.9,后期递减至0.4,学习因子在搜索后期 c_1 和 c_2 的取值分别为1.0581和2.9419,两者均满足了算法不同阶段的需求;经多次测试,ANVTPSO-BPNN的诊断准确率均高于其他方法,迭代步数也有较大优势,其在第273步时诊断准确率即达到99%。

表15 轴承故障诊断结果对比

Tab.15 Comparison of bearing fault diagnosis results

诊断方法	迭代步数	诊断准确率/%
RSBPNN	520	91
BPNN	329	94
PSO-BPNN	308	96
ULPSO-BPNN	665	94
ANVTPSO-BPNN	273	99

5 结 论

1) 依据采样频率和轴承有用信号的最小频率确定了小波消噪、小波包分解中最优层数及小波基函数,降低了经验选取对故障诊断带来的误差。

2) 针对标准PSO算法惯性权重和学习因子按经验选取固定值易影响算法精度的问题,引入自适应惯性权重和学习因子,满足了算法在不同阶段对参数的需求,并舍去PSO算法的速度项,使算法在搜索速度、收敛精度上较常规方法有了显著提高。

3) 利用自适应无速度项PSO(ANVTPSO)对BPNN的权值与阈值进行优选,克服了BPNN的局部极值造成早期收敛的问题,可快速准确地识别滚动轴承故障,诊断效率和准确率得到了同步改善。

参 考 文 献

[1] 王宏强,尚春阳,高瑞鹏,等.基于小波系数变换的小波阈值去噪算法改进[J].振动与冲击,2011,30(10):165-168.
WANG Hongqiang, SHANG Chunyang, GAO Ruipeng, et al. An improvement of wavelet shrinkage denoising via wavelet coefficient transformation[J]. Journal of Vibration and Shock, 2011, 30(10):165-168. (in Chinese)

[2] 王盟,余粟,冯益林.改进小波阈值对热泵电机振动信号的去噪研究[J].智能计算机与应用,2020,10(4):17-21.

WANG Meng, YU Su, FENG Yilin. Research on denoising of vibration signal of heat pump motor by improved wavelet threshold[J]. Intelligent Computer and Applications, 2020, 10(4):17-21. (in Chinese)

[3] 何孙东,金英连,王斌锐,等.风电机组齿轮振动的小波降噪与风沙侵害分类[J].太阳能学报,2016,37(5):1119-1124.
HE Sundong, JIN Yinglian, WANG Binrui, et al. Wavelet de-noising and classification for gear vibration of wind turbine suffering from wind sand erosion[J]. Acta Energetica Solaris Sinica, 2016, 37(5):1119-1124. (in Chinese)

[4] 闫晓玲,董世运,徐滨士.基于最优小波包Shannon熵的再制造电机转子缺陷诊断技术[J].机械工程学报,2016,52(4):7-12.
YAN Xiaoling, DONG Shiyun, XU Binshi. Flaw diagnosis technology for remanufactured motor rotor based on optimal wavelet packet Shannon entropy[J]. Journal of Mechanical Engineering, 2016, 52(4):7-12. (in Chinese)

[5] 吕楠,姚平喜.基于BP神经网络的滚动轴承故障诊断[J].煤矿机械,2020,41(8):172-173.
LÜ Nan, YAO Pingxi. Fault diagnosis of rolling bearing based on BP neural network[J]. Coal Mine Machinery, 2020, 41(8):172-173. (in Chinese)

[6] 赵洁,张惊雷.基于小波包神经网络分析的滚动轴承故障诊断[J].天津理工大学学报,2017,33(4):30-35,40.
ZHAO Jie, ZHANG Jinglei. Bearing fault diagnosis based on wavelet packet transform and neural network[J]. Journal of Tianjin University of Technology, 2017, 33(4):30-35,40. (in Chinese)

[7] 鞠晨,张超,樊红卫,等.基于小波包分解和PSO-BPNN的滚动轴承故障诊断[J].工矿自动化,2020,46(8):70-74.
JU Chen, ZHANG Chao, FAN Hongwei, et al. Rolling bearing fault diagnosis based on wavelet packet decomposition and PSO-BPNN[J]. Industry and Mine Automation, 2020, 46(8):70-74. (in Chinese)

[8] 李益兵,王磊,江丽.基于PSO改进深度置信网络的滚动轴承故障诊断[J].振动与冲击,2020,39(5):89-96.
LI Yibing, WANG Lei, JIANG Li. Rolling bearing fault diagnosis based on DBN algorithm improved with PSO[J]. Journal of Vibration and Shock, 2020, 39(5):89-96. (in Chinese)

[9] 徐呈艺,刘英,肖轶,等.基于改进粒子群算法的相机内参优化方法[J].激光与光电子学进展,2020,57(4):346-352.
XU Chengyi, LIU Ying, XIAO Yi, et al. Optimization

- method for camera intrinsic parameters based on improved particle swarm algorithm[J]. *Laser & Optoelectronics Progress*, 2020, 57(4):346-352. (in Chinese)
- [10] 王丽, 王晓凯. 一种非线性改变惯性权重的粒子群算法[J]. *计算机工程与应用*, 2007, 43(4):47-48, 92.
WANG Li, WANG Xiaokai. Modified particle swarm optimizer using non-linear inertia weight[J]. *Computer Engineering and Applications*, 2007, 43(4):47-48, 92. (in Chinese)
- [11] 朱雅敏, 薛鹏翔. 基于学习因子自适应改变的粒子群算法研究[J]. *陕西科技大学学报(自然科学版)*, 2015, 33(4):172-177.
ZHU Yamin, XUE Pengxiang. The research of PSO based on the adaptive changes of acceleration coefficients [J]. *Journal of Shaanxi University of Science & Technology (Natural Science Edition)*, 2015, 33(4):172-177. (in Chinese)
- [12] 臧玉萍, 张德江, 王维正. 小波分层阈值降噪法及其在发动机振动信号分析中的应用[J]. *振动与冲击*, 2009, 28(8):57-60, 198-199.
ZANG Yuping, ZHANG Dejiang, WANG Weizheng. Per-level threshold de-noising method using wavelet and its application in engine vibration analysis[J]. *Journal of Vibration and Shock*, 2009, 28(8):57-60, 198-199. (in Chinese)
- [13] 王普, 李天垚, 高学金, 等. 分层自适应小波阈值轴承故障信号降噪方法[J]. *振动工程学报*, 2019, 32(3):548-556.
WANG Pu, LI Tianyao, GAO Xuejin, et al. Bearing fault signal denoising method of hierarchical adaptive wavelet threshold function[J]. *Journal of Vibration Engineering*, 2019, 32(3):548-556. (in Chinese)
- [14] 李东钰, 田慕琴, 宋建成, 等. 基于最优小波基选取的掘进机振动信号去噪方法[J]. *工矿自动化*, 2016, 42(10):35-39.
LI Dongyu, TIAN Muqin, SONG Jiancheng, et al. Denoising method of vibration signal of roadheader based on the optimal wavelet basis selection[J]. *Industry and Mine Automation*, 2016, 42(10):35-39. (in Chinese)
- [15] 王婉秋, 杨松. 结构故障诊断中的小波分解层数选取方法研究[J]. *强度与环境*, 2009, 36(4):34-41.
WANG Wanqiu, YANG Song. A method for choosing the wavelet decomposition level in structural fault analysis[J]. *Structure & Environment Engineering*, 2009, 36(4):34-41. (in Chinese)
- [16] 刘朦月. 基于振动信号的电机轴承故障诊断方法研究[D]. 哈尔滨:哈尔滨工业大学, 2016.
- [17] 郑小霞, 钱铁群, 王帅. 基于优选小波包与马氏距离的滚动轴承性能退化GRU预测[J]. *振动与冲击*, 2020, 39(17):39-46, 63.
ZHENG Xiaoxia, QIAN Yiqun, WANG Shuai. GRU prediction for performance degradation of rolling bearings based on optimal wavelet packet and Mahalanobis distance [J]. *Journal of Vibration and Shock*, 2020, 39(17):39-46, 63. (in Chinese)
- [18] 胡旺, 李志蜀. 一种更简化而高效的粒子群优化算法[J]. *软件学报*, 2007, 18(4):861-868.
HU Wang, LI Zhishu. A simpler and more effective particle swarm optimization algorithm[J]. *Journal of Software*, 2007, 18(4):861-868. (in Chinese)
- [19] 魏星, 舒乃秋, 崔鹏程, 等. 基于改进 PSO-BP 神经网络和 D-S 证据理论的大型变压器故障综合诊断[J]. *电力系统自动化*, 2006, 30(7):46-50.
WEI Xing, SHU Naiqiu, CUI Pengcheng, et al. Power transformer fault integrated diagnosis based on improved PSO-BP neural networks and D-S evidential reasoning [J]. *Automation of Electric Power Systems*, 2006, 30(7):46-50. (in Chinese)
- [20] 温正, 孙华克. MATLAB 智能算法[M]. 北京:清华大学出版社, 2017:460-472.
- [21] 全秋娟, 赵岂, 李萌. 基于自适应动态改变的粒子群优化算法[J]. *微电子学与计算机*, 2019, 36(2):6-10, 15.
TONG Qiujuan, ZHAO Qi, LI Meng. Particle swarm optimization algorithm based on adaptive dynamic change[J]. *Microelectronics & Computer*, 2019, 36(2):6-10, 15. (in Chinese)
- [22] 董健, 钦文雯, 李莹娟, 等. 基于改进反向传播神经网络代理模型的快速多目标天线设计[J]. *电子与信息学报*, 2018, 40(11):2712-2719.
DONG Jian, QIN Wenwen, LI Yingjuan, et al. Fast multi-objective antenna design based on improved back propagation neural network surrogate model[J]. *Journal of Electronics & Information Technology*, 2018, 40(11):2712-2719. (in Chinese)



第一作者简介:樊红卫,男,1984年10月生,博士、副教授。主要研究方向为机械状态监测、信号处理、机器学习与故障诊断。曾发表《New electromagnetic ring balancer for active imbalance compensation of rotating machinery》(《Journal of Sound and Vibration》2014, No. 333)等论文。

E-mail:hw_fan@xust.edu.cn