

引用格式:李 超,薛士龙.改进 GA-PSO 算法的船舶电力系统故障诊断[J].科学技术与工程,2019,19(28):372-377
Li Chao, Xue Shilong. Fault diagnosis of ship power system based on improved GA-PSO algorithm[J]. Science Technology and Engineering, 2019, 19(28): 372-377

改进 GA-PSO 算法的船舶电力系统故障诊断

李 超 薛士龙*
(上海海事大学物流工程学院,上海 201306)

摘 要 为解决船舶电力系统故障识别的准确性以及快速性问题,在 BP 神经网络预测的基础上,提出一种改进的粒子群(PSO)和遗传算法(GA)混合优化 BP 神经网络的方法。改进包括两方面:一是对粒子群的惯性权重和学习因子进行改进;二是对遗传算法的变异概率和交叉概率进行改进。对发生故障时的三相电压信号进行小波包分解,提取各频率段的能量熵作为故障特征。经测试,优化后的算法诊断准确率明显提高,神经网络训练次数和误差减小,验证了改进 GA-PSO-BP 算法的可靠性,以及用于船舶电力系统故障诊断的实用性。

关键词 船舶电力系统 小波包分析 BP 神经网络 遗传粒子群 故障诊断

中图分类号 U665; **文献标志码** A

船舶电力系统由于其工作环境特殊,相对独立,出现故障时对船舶航行安全性危害很大。随着航行里程与年限的增加,船舶电力系统线路绝缘损坏愈发严重,短路故障成为影响船舶电力安全最重要的故障类型,为保证供电安全及质量,需要在故障产生初期尽可能短的时间诊断并切除故障,因此有必要建立一个高效的诊断系统来应对复杂的船舶电力系统。

船舶电力系统的诊断技术源于陆地,主要利用开关器件的动作来判断与隔离故障区域。随着技术发展,智能化的诊断技术在不断发展。文献[1]模糊推理和专家系统的诊断方式,虽然能有效处理故障的不确定性,但是诊断的精度有待提高。文献[2]中利用小波分析处理故障信号并进行神经网络技术诊断,小波分析时频定位特性良好,神经网络的优势在于其学习能力,但是 BP 神经网络存在易产生局部收敛的问题;文献[3]采用径向基函数(RBF)神经网络作为诊断核心,RBF 虽然在逼近精度上要远高于 BP,但是其网络结构过于庞大,运算量增多。文献[4]中用遗传粒子群(GA-PSO)算法进行压缩机的故障诊断提高了训练效率,很好地满足了快速性问题。

BP 算法已知的问题是权值和阈值选定问题,二者会对神经网络训练结果产生重要影响。粒子群(PSO)算法由于缺乏变化能力,后期收敛很慢,易陷

入局部最优;遗传算法(GA)记忆能力不足,群体成熟早,效率较低^[5]。针对两种算法的特异性问题进行改进,提出一种遗传粒子群算法并进行改进,PSO 提出一种随机变化与惯性递减相结合的权值变化方式,学习因子按照线性变化进行调整;GA 的交叉概率与变异概率引入相关学者意见,依照相关特性自适应变化。改进的 GA-PSO-BP 算法解决了传统技术应用于船舶电力系统故障识别时的收敛效率低及局部收敛问题。

1 小波包分析与特征量提取

小波包分析发展于小波分析,小波包分解会将细节信号和近似信号都进行分解,实质原理则是利用滤波器分离信号,随着小波包分解的持续进行,信号被分解到各个频率范围,且各个频率段都有着相同的时频分辨率^[6],如图 1 所示。这种方式对高频信号部分也提供更细节化的分解,无冗余数据,同时,小波包变化能根据原始信号特征自适应划分频率带,提高了时频分辨率。

考虑信号样本量及信号失真度,选用 db3 小波




图 1 小波包 3 层分解

Fig. 1 Wavelet packet 3-layer decomposition

2019 年 2 月 26 日收到
第一作者简介:李 超(1994—),男,汉族,安徽合肥人,硕士研究生。E-mail: 1028600833@qq.com。
* 通信作者简介:薛士龙,博士,教授。E-mail: shilongxue@126.com。

包三层分解,根据分解得到的第三层节点,求取各节点重构系数能量值作为特征量,8 个频率段成分的能量计算如下:

$$E_{3i} = \int |S_{3i}(t)|^2 dt \quad (1)$$

式(1)中: E_{3i} 为小波包第三层分解后各个节点能量值; $S_{3i}(t)$ 为各节点中各时刻重构系数值; i 代表第三层节点序号,取值为 $0 \sim 7$; t 为时间。

由于短路故障发生时,电压信号能量较大,为了压缩各频段能量的差异,对总能量取二次根号^[6],即:

$$E = \left(\sum_{i=0}^7 |E_{3i}|^2 \right)^{1/2} \quad (2)$$

由式(1)构造被测电压信号的特征向量:

$$\mathbf{H} = [E_{30}, E_{31}, E_{32}, E_{33}, E_{34}, E_{35}, E_{36}, E_{37}] \quad (3)$$

对 8 个频段范围能量进行归一化处理,得到特征向量:

$$\mathbf{T} = [E_{30}/E, E_{31}/E, E_{32}/E, E_{33}/E, E_{34}/E, E_{35}/E, E_{36}/E, E_{37}/E] \quad (4)$$

2 BP 神经网络

反向传播网络(back propagation network, BP 网络)是一种按误差反传的前馈型神经网络,是一种有监督学习算法。给定训练样本开始训练,根据误差不断调整各层的连接权值,整个过程包括正向传播和反向传播。其自学能力和分布式处理能力很强,在故障诊断领域广泛应用^[7]。图 2 表示 3 层结构 BP 神经网络模型。




图 2 BP 神经网络结构

Fig. 2 BP neural network structure

设故障样本为 $\{x_i, y_i\}$, x_i 代表短路故障电压信号的特征向量, y_i 代表对应的故障编码,影响故障的特征共有 m 个,神经网络输入有 m 个,则隐层的输入为

$$S_j = \sum_{i=1}^m w_{ij}x_i - \theta_j \quad (5)$$

式(5)中: w_{ij} 和 θ_j 表示隐含层第 j 个节点的权值和

阈值。输入层到隐含层映射选用 Sigmoid 函数,故障诊断输出共有 n 类,输出层的输入为

$$L = \sum_{j=1}^n w_{jk}b_j - \theta_k \quad (6)$$

输出层的输出为

$$x_{i+1} = \frac{1}{1 + \exp\left(-\sum_{j=1}^n v_j b_j - \gamma_j\right)} \quad (7)$$

式(7)中: v_j 和 γ_j 代表输出层第 j 个节点的连接权值和阈值。

BP 神经网络诊断的训练过程中,权值和阈值主要通过专家的经验确定,这样的情况就无法保证诊断结果达到最优,易陷入局部收敛的问题,无法进行全局寻优。

3 GA-PSO 优化 BP 神经网络

3.1 GA-PSO 混合算法

粒子群算法是一种并行随机搜索的算法,在个体适应度条件下进行全局搜索,在这个过程中需要不断更新每个粒子自身速度和位置,从而能短时间内精准接近目标。粒子在搜索空间中以一定速度向自身历史最佳位置(Pbest)和邻域历史最佳位置(Gbest)靠拢^[8],当找到两个最优值时,粒子的速度和位置更新公式如下:

$$\begin{cases} v_{ij}(t+1) = v_{ij}(t) + c_1 r_1(t)[p_{ij}(t) - x_{ij}(t)] + \\ \quad c_2 r_2(t)[p_{gj}(t) - x_{ij}(t)] \\ x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \end{cases} \quad (8)$$

式(8)中: c_1 、 c_2 为加速常数; v_{ij} 为粒子速度,用户自定义设置速度最值来限制粒子速度; r_1 、 r_2 为 $0 \sim 1$ 的随机常数; x_{ij} 为粒子位置; p_{ij} 为个体最佳位置; p_{gj} 为群体最佳位置。式(8)将速度更新为三部分之和:一为惯性,表征粒子有维持原速度的趋势;二为认知,表征粒子有靠近自身最优值的趋势;三为社会,表征粒子趋向于靠近群体最优值的趋势^[9]。

迭代次数增加,粒子种群多样性遭到破坏,易陷入局部最优。引入遗传算法的思想,对种群进行交叉变异操作,有利于克服局部收敛问题^[10]。

基因重组的过程称为交叉操作,第 k 个染色体 a_k 和第 l 个染色体 a_l 在 j 位的交叉方式为

$$\begin{cases} a_{kj} = a_{lj}(1 - b) + a_{lj}b \\ a_{lj} = a_{kj}(1 - b) + a_{kj}b \end{cases} \quad (9)$$

式(9)中: b 为 $0 \sim 1$ 的随机数。

变异是指染色体中的一些位随机变化,变异性概率性重现那些消失的好的个体。假设基因 a_{ij} (第 i 个个体的第 j 个基因)产生变异,变异方式为^[11]

$$a_{ij} = \begin{cases} a_{ij} + (a_{ij} - a_{\max})f(g), & r > 0.5 \\ a_{ij} + (a_{\min} - a_{ij})f(g), & r \leq 0.5 \end{cases} \quad (10)$$

式(10)中: $a_{\max}$ 为该染色体最大值, $a_{\min}$ 为该染色体的最小值; $f(g) = r_2(1 - g/G_{\max})$, r_2 为一个随机数, g 为当前迭代数, $G_{\max}$ 为最大进化次数, r 为 $[0, 1]$ 之间的随机数。图 3 表示 GA-PSO 混合算法流程。




图 3 GA-PSO 优化流程
Fig. 3 GA-PSO optimization process

3.2 参数的改进

基本粒子群算法中,速度更新的惯性权重默认为 1,学习因子也是固定的,由于惯性权重在不同搜索阶段影响作用不同,这里提出一种基于非线性惯性权重的粒子群算法,其迭代过程为

$$\begin{cases} v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1(t) [p_{ij}(t) - x_{ij}(t)] + \\ c_2 r_2(t) [p_{gj}(t) - x_{ij}(t)] \\ x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \end{cases} \quad (11)$$

式(11)中: ω 为惯性权重系数。在算法运行初期,较大的 ω 可以使得初始阶段粒子能够快速探测到较好的区域;而随着目标区域的不断缩小,选择相对较小的惯性权重,能够做到在极值点附近进行更加细微的搜索,增加了向最优值收敛的可能性^[12,13]。

为此提出将惯性权重分成三部分,常数部分、随机变化部分和非线性递减部分权重整体呈减小趋势,但是由于随机数的存在,保证了迭代后期也会存在较大的惯性权重和较小的惯性权重,粒子也能摆脱局部最优的问题。学习因子设计也是如此,算法初期, c_1 较大, c_2 较小,粒子自学习能力强,趋于个

体最优值;随着迭代进行, c_1 减小, c_2 增大,粒子趋于群体最优^[14,15]。

$$\begin{cases} \omega = \omega_0 + \omega_1 \text{rand}() + \omega_2 \exp[-k(i/g_{\max})^u] \\ c_1 = c_{10} + (c_{11} - c_{10})i^2/g_{\max}^2 \\ c_2 = c_{20} + (c_{21} - c_{20})i^2/g_{\max}^2 \end{cases} \quad (12)$$

式(12)中: $\omega_0 = 0.4$, $\omega_1 = 0.3$, $\omega_2 = 0.3$; $\text{rand}()$ 为范围为 $0 \sim 1$ 的随机数; k 和 u 为常数, $k = 10$; $u = 10$; $g_{\max}$ 为最大迭代次数; $c_{10} = 2$, $c_{11} = 0.5$, $c_{20} = 0.5$, $c_{21} = 2$ 。

遗传算法中,收敛性能受交叉概率和变异概率影响较大。通常,固定的概率值不利于维持种群的多样性。引入一种自适应遗传算法,交叉概率 p_c 和变异概率 p_m 按照式(13)、式(14)进行变化^[11]:

$$p_c = \begin{cases} p_{c1} - \frac{(p_{c1} - p_{c2})(f_b - f_{av})}{f_{\max} - f_{av}}, & f_b \geq f_{av} \\ p_{c1}, & \text{其他} \end{cases} \quad (13)$$

$$p_m = \begin{cases} p_{m1} - \frac{(p_{m1} - p_{m2})(f - f_{av})}{f_{\max} - f_{av}}, & f_b \geq f_{av} \\ p_{m1}, & \text{其他} \end{cases} \quad (14)$$

式中: $p_{c1} = 0.9$, $p_{c2} = 0.6$, $p_{m1} = 0.1$, $p_{m2} = 0.01$; f_b 为待交叉个体适应度值较大者; f_{av} 表示每一次迭代群体的平均适应度; $f_{\max}$ 表示群体中最大的适应度值; f 代表待变异个体的适应度。

4 故障诊断试验及结果分析

4.1 短路故障特征提取

利用 Simulink 仿真建立船舶电力系统,电压等级为 440 V/60 Hz,对电力系统进行短路故障得到的电压波形进行小波包变换,采样频率为 1 kHz。图 4 表征了船舶电力系统的基本组成,其是一个发电、配电、输电、用电于一体的独立系统。当柴油发电机组带负载达到稳定状态时,突加故障模块,通过改变故障电阻来获取不同的样本。以单相接地为例,每次采集故障电压信号 1 000 个点。

进行 A 相接地故障仿真实验,故障时 A 相电压信号如图 5 所示。三相电压信号进行 db3 的 3 层小




图 4 船舶电力系统结构
Fig. 4 Ship power system structure

波包分解,再对 8 个频带信号进行重构,计算出各个频带的能量熵值,小波包分解 A 相电压信号得出的各频带能量占比如图 6 所示,其中节点 1 对应频段为 0~62.5 Hz,节点 2 对应 62.5~125 Hz,⋯,节点 8 对应 437.5~500 Hz。

根据最佳小波分结树分析,选取前两个节点能量,简化神经网络输入,得到:

$$\boldsymbol{T} = [E_{30}/E, E_{31}/E]$$

(15)




图 5 故障时 A 相电压信号
Fig. 5 Phase A voltage signal at fault




图 6 小波包能量熵占比
Fig. 6 Wavelet packet energy entropy ratio

对 B 相和 C 相电压向量做同样分析与处理,得到 6 个神经网络输入量;仿真中,各类短路故障的仿真实验通过改变故障电阻来获得,各故障能量熵部分数据如表 1 所示。

4.2 诊断模型建立及参数设置

根据需要,建立 3 层 BP 神经网络,输入节点数

6,隐含层节点数 10,输出节点为 3,传递函数选择隐含层为 logsig,输出层为 purelin,训练函数为 trainlm,最大迭代次数为 1 000,学习速率为 0.01,目标误差为 0.001,最小性能梯度设置为 1×10^{-15} 。如图 7 所示,神经网络训练迭代 5 次达到目标误差。




图 7 改进算法训练曲线
Fig. 7 Improved algorithm training curve

改进 GA-PSO 算法中,最大迭代次数为 150,种群数量为 20,速度 $V_{\max} = 1, V_{\min} = -1$,位置 $pop_{\max} = 5, pop_{\min} = -5$ 。适应度函数选择样本误差,其表达式为

$$f = \frac{1}{N} \sum_{i=1}^N \sum_{t=1}^M (y_{it} - c_{it})^2$$

(16)

式(16)中: N 为训练样本总数; M 为 BP 神经网络输出节点数; y_{it} 为理想输出; c_{it} 为实际输出。

适应度函数值收敛时,表示模型参数已达到最优,如图 8 所示。PSO-BP 算法迭代 36 次达到最优值,而 GA-PSO 达到最优解时迭代了 20 次,改进算法迭代 9 次参数达到最优,收敛精度更高,收敛精度在 10^{-4} 左右。

4.3 诊断系统测试

对上述的训练网络进行测试,针对 4 种故障,取测试数据 80 组,将测试结果进行对比,表 2 为诊断输出,表 3 中列出了部分诊断数据。

经过改进 PSO 优化的 BP 神经网络对故障的诊断更加准确,其实际输出与期望之间的误差不超过 0.03,3 种算法诊断识别率如表 4 所示。

表 1 故障小波包能量及编码
Table 1 Fault wavelet packet energy and coding

故障类型	A 相电压		B 相电压		C 相电压		故障编码
	T_{30}	T_{31}	T_{30}	T_{31}	T_{30}	T_{31}	
AG(0.01 Ω)	1 019.65	810.61	6 960.82	5 331.89	7 080.44	5 408.06	001
AG(0.1 Ω)	2 887.28	2 164.59	5 762.91	4 704.15	5 586.21	3 935.47	001
BC(0.001 Ω)	5 301.85	1 483.11	5 312.62	1 370.26	2 659.82	460.58	010
BCG(0.1 Ω)	4 784.02	3 362.75	4 970.28	3 508.51	4 578.06	3 011.97	011
ABC	2 647.16	639.42	2 627.90	672.06	2 669.68	623.61	100

表 2 三种算法诊断输出对比
Table 2 Comparison of three algorithms for diagnostic output

故障类型	期望输出	PSO-BP	GA-PSO-BP	改进 GA-PSO-BP
AG	001	0.024 1, 0.006 9, 0.967 0	0.004 8, 0.001 8, 0.994 4	0.003 2, -0.001 6, 0.998 1
BC	010	-0.035 3, 1.049 0, 0.015 3	0.013 5, 0.994 3, 0.012 6	0.003 5, 0.998 4, 0.005 1
BCG	011	-0.064 1, 1.062 4, 1.066 2	0.030 6, 0.964 0, 1.038 5	0.011 5, 1.012 6, 0.994 5
ABC	100	0.986 1, -0.024 1, 0.014 0	1.011 4, -0.007 0, 0.001 6	0.993 2, 0.012 4, 0.010 6




图 8 3 种算法迭代过程对比

Fig. 8 Comparison of three algorithm iterative processes

表 3 测试数据(取样)
Table 3 Test data (sampling)

故障类型	测试数据特征向量(部分)
AG	2 364.17, 1 763.84, 6 318.14, 4 760.77, 5 892.02, 4 398.43
BC	5 549.34, 1 363.18, 5 846.44, 1 349.01, 3 695.76, 578.35
BCG	6 494.75, 1 825.36, 3 898.69, 945.17, 3 156.36, 552.75
ABC	3 522.41, 641.05, 3 495.16, 671.98, 3 568.85, 599.77

表 4 3 种算法诊断识别率
Table 4 Diagnostic recognition rate of three algorithms

诊断方法	确诊数	误诊数	样本总数	识别率/%
PSO-BP	75	5	80	93.75
GA-PSO-BP	76	4	80	95.00
改进 GA-PSO-BP	78	2	80	97.50

由对比结果可知,改进 GA-PSO-BP 诊断的正确率最高,说明在粒子群中引入遗传算子的做法是合理的,对参数的改进是有效的。

5 结论

针对船舶电力系统故障特征,探索一种基于小波包变换和改进 PSO-BP 算法的诊断策略,该策略从技术上包括特征提取、神经网络训练以及遗传粒子群优化 3 个部分,对诊断结果分析可得如下结论。

(1)策略利用小波包分解完整保留故障了的特征信息,提取特征能量熵值。

(2)保留了 BP 神经网络的映射学习能力。

(3)遗传粒子群算法优化神经网络权值和阈值

能显著提高收敛精度。

(4)对于 PSO 和 GA 参数的改进优化效果更加明显。通过仿真实验可知,改进算法的诊断准确性较基本算法有所提高,从而验证了该算法应用于船舶电力系统故障诊断系统的可行性。

参 考 文 献

1 赵磊磊. 基于专家系统的船舶电力系统故障诊断研究[J]. 舰船电子工程,2018,38(9):132-134,146
Zhao Leilei. Research on fault diagnosis of ship power system based on expert system[J]. Ship Electronic Engineering, 2018, 38(9): 132-134,146

2 刘志刚,赵晓燕,张涛,等. 基于小波包-神经网络的电厂发电机组故障诊断研究[J]. 机械传动,2018,42(8):179-182
Liu Zhigang, Zhao Xiaoyan, Zhang Tao, et al. Fault diagnosis of power plant generator set based on wavelet packet-neural network[J]. Journal of Mechanical Transmission,2018,42(8):179-182

3 李泽宇,吴文全. 基于 RBF 神经网络的模拟电路故障诊断的研究[J]. 舰船电子工程,2016,36(1):119-122
Li Zeyu, Wu Wenquan. Research on fault diagnosis of analog circuit based on RBF neural network[J]. Ship Electronic Engineering, 2016, 36(1): 119-122

4 刘艳明. 大型船舶电力系统脆性中的粒子群优化算法研究[J]. 舰船科学技术,2017,39(20):64-66
Liu Yanming. Study on particle swarm optimization algorithm for brittleness of large ship power system[J]. Ship Science and Technology, 2017,39(20):64-66

5 Hou C, Yu X, Cao Y, et al. Prediction of synchronous closing time of permanent magnetic actuator for vacuum circuit breaker based on PSO-BP[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(6): 3321-3326

6 Shirong Y, Guangju C, Yongle X. Wavelet neural network based fault diagnosis in nonlinear analog circuits[J]. Journal of Systems Engineering and Electronics, 2006, 17(3): 521-526

7 Kundu S, Jha A, Chattopadhyay S, et al. Framework for multiple-fault diagnosis based on multiple fault simulation using particle swarm optimization[J]. IEEE Transactions on Very Large Scale Integration (VLSI) Systems, 2014, 22(3): 696-700

8 郭雷,郭幼丹,余思睿,等. 粒子群算法及其在船舶结构中的优化应用[J]. 船海工程,2016,45(3):59-62
Guo Lei, Guo Youdan, Yu Sizhen, et al. Particle swarm algorithm and its optimization application in ship structure[J]. Ship and Ocean Engineering,2016,45(3):59-62

9 Chen W, Bazzi A M. Logic-based methods for intelligent fault diagnosis and recovery in power electronics[J]. IEEE Transactions on Power Electronics, 2017, 32(7): 5573-5589

10

单 鹏,冒晓莉,张加宏,等. 基于 PSO-BP 神经网络的探空湿度太阳辐射误差修正[J]. 科学技术与工程,2018,18(19):1-8
Shan Peng, Cao Xiaoli, Zhang Jiahong, et al. Correction of solar radiation error of sounding humidity based on PSO-BP neural network [J]. Science Technology and Engineering, 2018, 18(19): 1-8

11

李晓利,高金峰. 用于配电网多目标无功优化的改进粒子群优化算法[J]. 电力自动化设备,2019,39(1):106-111
Li Xiaoli, Gao Jinfeng. Improved particle swarm optimization algorithm for multi-objective reactive power optimization in distribution network[J]. Electric Power Automation Equipment, 2019, 39(1): 106-111

12

Li Z, Ma H, Bai Z, et al. Fast transistor open-circuit faults diagnosis in grid-tied three-phase vsis based on average bridge arm pole-to-pole voltages and error-adaptive thresholds[J]. IEEE Transactions on Power Electronics, 2018, 33(9): 8040-8051

13

王艳松,宗雪莹,衣京波. 配电网故障定位容错算法[J]. 电力自动化设备,2018,38(4):9-15
Wang Yansong, Zong Xueying, Yi Jingbo. Fault location fault tolerance algorithm for distribution network[J]. Electric Power Automation Equipment, 2018, 38(4): 9-15

14

Geng R, Wang X, Ye N, et al. A fault prediction algorithm based on rough sets and back propagation neural network for vehicular networks[J]. IEEE Access, 2018, 6: 74984-74992

15

孙利文,刘 海,王海洋,等. 应用 GA-BP 神经网络对加速工况车内声品质研究[J]. 科学技术与工程,2017,17(17):340-345
Sun Liwen, Liu Hai, Wang Haiyang, et al. Study on the acoustic quality of vehicles in accelerated working condition by GA-BP neural network[J]. Science Technology and Engineering, 2017, 17(17): 340-345

Fault Diagnosis of Ship Power System Based on Improved GA-PSO Algorithm

LI Chao, XUE Shi-long *

(Logistics Engineering College, Shanghai Maritime University, Shanghai 201306, China)

[Abstract] In order to solve the problem of accuracy and rapidity of ship power system fault identification, based on BP neural network prediction, an improved particle swarm optimization (PSO) and genetic algorithm (GA) hybrid BP neural network method is proposed. The improvement includes two aspects: one is to improve the inertia weight and learning factor of the particle swarm; the other is to improve the mutation probability and crossover probability of the genetic algorithm. Wavelet packet decomposition is performed on the three-phase voltage signal at the time of failure, and the energy entropy of each frequency segment is extracted as a fault feature. After testing, the accuracy of the optimized algorithm is obviously improved, the number of neural network training and the error are reduced, and the reliability of the improved GA-PSO-BP algorithm and the practicability for fault diagnosis of the ship power system are verified.

[Key words] ship power system wavelet packet analysis BP neural network GA-PSO algorithm fault diagnosis