

# 汽轮发电机组的粒子群可拓故障诊断算法

王永林

(中原工学院电子信息学院, 河南 郑州 450007)

**摘要:** 为更准确方便地诊断汽轮发电机组的各种故障, 引入了可拓故障诊断方法。描述了可拓故障诊断的基本步骤, 采用粒子群算法优化确定经典域, 提出了一种用于故障诊断的适应度函数形式。实例表明, 该方法可避免神经网络需确定网络结构和优化参数过多的缺点, 能有效诊断汽轮发电机组的振动故障, 具有较高的准确性和实用性。

**关键词:** 可拓故障诊断; 粒子群算法; 经典域; 汽轮发电机组

## Extension fault diagnosis for turbine-generator set based on PSO algorithm

WANG Yong-lin

(School of Electronic and Information, Zhongyuan University of Technology, Zhengzhou 450007, China)

**Abstract:** For diagnosing faults of turbine-generator set conveniently, an extension fault method is introduced. The basic steps of the extension fault diagnosis method are described at first. Then particle swarm optimization (PSO) algorithm is employed to optimize its classical domains. One form of the fitness function for fault diagnosis is proposed. Simulation results show that the proposed method can avoid disadvantages of neural network that need to determine the network structure and have too many parameters to optimize. It can diagnose the vibration faults of steam turbine-generator set effectively and has higher accuracy and practicability.

**Key words:** extension fault diagnosis; PSO algorithm; classical domain; turbine-generator set

中图分类号: TP181; TP277 文献标识码: A 文章编号: 1674-3415(2010)17-0087-04

## 0 引言

汽轮发电机组故障诊断可认为是一个对机组运行状态进行模式识别的问题, 每种故障类型都有一定的故障特征模式相对应, 如果能建立起故障特征和故障类型之间的映射关系, 则将待测样本通过该映射进行处理, 就可诊断出故障类型, 这属于分类问题, 神经网络方法<sup>[1-2]</sup>就属此类; 如果能找到待测故障特征与已知故障特征之间的关系, 如待测样本和典型样本之间的相似性, 则可根据样本间的这种“关系”进行诊断, 这属于聚类问题, 如模糊聚类分析<sup>[3]</sup>。这两种方法都取得了不错的效果, 但也存在一定的问题, 如神经网络的局部收敛和和隐层节点数目的确定问题, 模糊聚类最优聚类和多故障诊断问题等。基于物元理论和关联函数的可拓方法<sup>[4-5]</sup>能避免这些缺点, 但可拓诊断方法中经典域的确定需要一定的技术或经验, 本文通过建立合适的适应度函数, 采用粒子群算法优化确定经典域。

## 1 可拓故障诊断方法

可拓诊断的基本思想是先根据生产中积累的数据资料和已成功的试验数据, 把故障分为若干类型, 确定经典域和节域, 建立关联函数, 最后通过计算综合关联度来诊断故障类型。一个故障类型对应一个经典域, 经典域表示形式如式(1):

$$R_{0j} = [N_{0j} \quad C \quad V_{0j}] = \begin{bmatrix} N_{0j} & c_1 < a_{0j1}, b_{0j1} > \\ & c_2 < a_{0j2}, b_{0j2} > \\ & M \\ & c_m < a_{0jm}, b_{0jm} > \end{bmatrix} \quad (1)$$

其中:  $N_{0j}$  表示第  $j$  种故障类型,  $j=1, 2, \dots, L$ ,  $L$  为故障类型数;  $c_i$  表示故障的第  $i$  个特征,  $i=1, 2, \dots, m$ ,  $m$  为特征个数;  $V_{0j}$  表示故障类型  $j$  关于特征  $c_i$  所限定的量值范围, 即经典域;  $a_{0j}$  和  $b_{0j}$  为  $V_{0j}$  的下界和上界。

节域是各特征所容许的取值范围, 覆盖所有经典域, 描述如式(2):

$$R_p = [P \ C \ V_p] = \begin{bmatrix} P & c_1 & \langle a_{p1}, b_{p1} \rangle \\ & c_2 & \langle a_{p2}, b_{p2} \rangle \\ & & M \\ & & c_m & \langle a_{pm}, b_{pm} \rangle \end{bmatrix} \quad (2)$$

关联函数是用来描述事物的量值符合某种要求程度的量化函数,通常取式(3)所示初等关联函数:

$$K_j(v_i) = \begin{cases} \frac{\rho(v_i, V_{0ji})}{\rho(v_i, V_{pi}) - \rho(v_i, V_{0ji})} & v_i \notin V_{0ji} \\ \frac{-\rho(v_i, V_{0ji})}{|V_{0ji}|} & v_i \in V_{0ji} \end{cases} \quad (3)$$

$$\rho(v, V) = \rho(v, \langle a, b \rangle) = |v - \frac{1}{2}(a+b)| - \frac{1}{2}(b-a)$$

其中:  $K_j(v_i)$  为待评故障样本第  $i$  个特征量值  $v_i$  关于第  $j$  类故障第  $i$  个特征的经典域区间  $V_{0ji}$  的关联度;  $\rho(v_i, V_{0ji})$  为相应的距;  $a$  和  $b$  为区间  $V$  的下界和上界,  $|V| = b - a$  为区间  $V$  模。

将待评故障样本  $p_k$  各特征关于各故障类型的关联度  $K_j(v_i)$  加权求和,就得到了该样本关于各故障类型的综合关联度,见式(4):

$$K_j(p_k) = \sum_i \beta_i K_j(v_i) \quad (4)$$

式中:  $\beta_i$  为第  $i$  个指标的权系数,  $\sum \beta_i = 1$ , 等权时  $\beta_i = 1/m$ ;  $k=1, 2, \dots, n$  为待评故障样本序号。

按最大综合关联度法判定故障类别归属,若

$$K_{j_0}(p_k) = \max_{j \in \{1, 2, \dots, L\}} \{K_j(p_k)\} \quad (5)$$

则将样本  $p_k$  诊断为故障类型  $j_0$ 。

根据可拓学知识,通常希望发生故障的综合关联度大于 0,而不发生故障的综合关联度小于 0;根据最大综合关联度评判原理,发生故障的综合关联度宜尽量大些,以便于诊断,若有多个故障的综合关联度都较大且数值接近,则诊断为多故障同时发生。

上述诊断方法中,关联函数和节域相对容易确定,但是各故障的经典域的确定比较麻烦,它关系到诊断的准确率。本文提出采用粒子群算法优化经典域,以提高精确度,减少人为经验参与,并给出了一种适用于故障诊断的适应度函数形式。

## 2 可拓诊断的粒子群算法训练

粒子群算法是由 Eberhart 博士和 Kennedy 博士提出的一种进化计算技术<sup>[6-8]</sup>,源于对鸟群捕食行为的模拟。它首先在解空间初始化一群粒子,然后粒子根据个体和群体的飞行经验来动态调整自己的速度,通过迭代寻找最优解。在每一次迭代中,粒子通过跟踪两个“极值”来更新自己,一个是粒子本身的最优解  $p_i$ ,另一个极值是整个粒子群目前找

到的最优解  $p_g$ 。粒子更新速度和位置公式如式(6)、(7):

$$v_{ij}^{k+1} = w \cdot v_{ij}^k + c_1 \cdot r_1 \cdot (p_{ij}^k - x_{ij}^k) + c_2 \cdot r_2 \cdot (p_{gj}^k - x_{ij}^k) \quad (6)$$

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (7)$$

其中:  $v_{ij}^k$  和  $x_{ij}^k$  为第  $i$  个粒子的第  $j$  个参数在第  $k$  次迭代中的速度和位置;  $r_1$  和  $r_2$  为  $[0,1]$  间的随机数;  $c_1$  和  $c_2$  为学习因子,通常  $c_1, c_2 \in [0,4]$ ;  $w$  为惯性权重,调整公式如式(8)。

$$w = w_{\max} - \frac{w_{\max} - w_{\min}}{T_m} \cdot t \quad (8)$$

其中:  $T_m$  为最大迭代次数;  $t$  为当前迭代次数;  $w_{\max}$  和  $w_{\min}$  为开始时和结束时的权重。

粒子最优解是根据适应度函数确定的,本文提出如式(9)适应度函数形式:

$$\min F = E - \sum_k K_{j_0}(p_k) + \sum_k |\min(K_{j_0}(p_k), 0)| \quad (9)$$

其中:  $K_{j_0}(p_k)$  为样本  $p_k$  所属故障的综合关联度;  $E$  为故障诊断错误的次数。式(9)等号后第一项是使故障错判次数尽量小,第二项是使各样本发生故障的综合关联度之和尽量大,第三项是惩罚项,要求  $K_{j_0}(p_k)$  大于 0。这里适应度函数值越小越好。

粒子群训练时,每个粒子位置对应一组经典域参数,决定一个可拓故障诊断器,可拓故障诊断器的粒子群算法训练步骤如下:

- 1) 初始化群体的规模、参数维数和取值范围、惯性权重、最大迭代次数、各粒子的初始位置和初始速度,设定可拓故障诊断器的节域和各指标权重;
- 2) 将粒子位置转化为经典域,用可拓诊断方法进行诊断,并根据式(9)计算适应度值;
- 3) 比较每个粒子的当前适应度和历史最优适应度,更新个体最优解;
- 4) 比较所有粒子的当前适应度和群体历史最优适应度,更新全局最优解;
- 5) 更新惯性权重,根据公式(6)和(7)更新每个粒子的速度和位置;
- 6) 检查是否满足停止条件,如满足,则搜索停止,输出结果;否则,返回 2) 继续搜索。

为保证训练的有效性,最优解的更新在没有错判的粒子中进行,对于有错判的粒子,可以生成新粒子替换、用最优个体替换或者不做处理;为提高算法性能,采用轮番优化策略,即上次运行的最优解作为下次运行的一个初始解;为避免搜索停滞,当最大适应度与最小适应度之差小于某一阈值(如 0.0005)时,惯性权重  $w$  取随机值。

### 3 应用分析

采用汽轮发电机组转子试验平台上常见的油膜振荡 F1, 不平衡 F2 和不对中 F3 三种故障进行分析和测试, 分别取振动信号频谱图中  $<0.4f$ 、 $(0.4 \sim 0.5)f$ 、 $1f$ 、 $2f$ 、 $\geq 3f$  ( $f$  为一阶转频) 等 5 个不同频段上的幅值分量归一化值作为特征, 如表 1 所示, 取前 15 组作为训练样本, 后 9 组作为测试样本。

表 1 汽轮发电机组故障数据

Tab.1 Faults data of turbine-generator set

序号	$<0.4f$	$(0.4 \sim 0.5)f$	$1f$	$2f$	$\geq 3f$	故障
1	0.052	0.783	0.225	0.036	0.013	F1
2	0.232	0.975	0.314	0.056	0.014	F1
3	0.161	0.925	0.285	0.023	0.016	F1
4	0.106	0.858	0.230	0.017	0.028	F1
5	0.079	0.819	0.201	0.016	0.012	F1
6	0.028	0.061	0.980	0.225	0.057	F2
7	0.045	0.022	1.000	0.316	0.065	F2
8	0.010	0.054	0.875	0.183	0.073	F2
9	0.015	0.032	0.923	0.219	0.037	F2
10	0.023	0.025	0.758	0.115	0.019	F2
11	0.033	0.037	0.386	0.531	0.230	F3
12	0.017	0.023	0.397	0.458	0.103	F3
13	0.012	0.039	0.427	0.496	0.175	F3
14	0.021	0.017	0.298	0.403	0.132	F3
15	0.017	0.056	0.483	0.599	0.301	F3
16	0.280	0.893	0.313	0.036	0.028	F1
17	0.167	0.743	0.125	0.005	0.003	F1
18	0.086	0.672	0.211	0.032	0.021	F1
19	0.042	0.232	0.979	0.386	0.015	F2
20	0.008	0.087	0.855	0.337	0.065	F2
21	0.013	0.051	0.722	0.252	0.107	F2
22	0.026	0.043	0.346	0.517	0.098	F3
23	0.023	0.137	0.378	0.421	0.152	F3
24	0.005	0.026	0.315	0.345	0.222	F3

根据故障特征的可能取值可确定出节域, 本文取节域如下:

表 2 采用 PSO 法确定的经典域

Tab.2 Classical domains optimized by PSO

	$<0.4f$	$(0.4 \sim 0.5)f$	$1f$	$2f$	$\geq 3f$
F1	$<0, 0.300 0>$	$<0.638 0, 1.000 0>$	$<0.100 0, 0.456 6>$	$<0, 0.072 0>$	$<0, 0.031 9>$
F2	$<0, 0.056 0>$	$<0, 0.108 0>$	$<0.516 0, 1.000 0>$	$<0, 0.441 8>$	$<0, 0.130 0>$
F3	$<0, 0.042 0>$	$<0, 0.078 0>$	$<0.100 0, 0.749 8>$	$<0.228 7, 0.700 0>$	$<0, 0.400 0>$

$$R_p = [P \ C \ V_p] = \begin{bmatrix} P <0.4f & <0, 0.300 0 > \\ (0.4 \sim 0.5)f & <0, 1.000 0 > \\ 1f & <0.100 0, 1.000 0 > \\ 2f & <0, 0.700 0 > \\ \geq 3f & <0, 0.400 0 > \end{bmatrix}$$

经典域通过优化获得。本例共有 3 种故障, 即 3 个经典域, 每种故障 5 个特征, 共 15 个量值区间, 每个区间有两个参数 (上界和下界), 所以共 30 个参数, 各参数的优化范围采用下述方法确定:

$$\begin{aligned} a_{0ji}^{\min} &= a_{Pi}, & a_{0ji}^{\max} &= (a'_{0ji} + b'_{0ji})/2 \\ b_{0ji}^{\min} &= (a'_{0ji} + b'_{0ji})/2, & b_{0ji}^{\max} &= b_{Pi} \end{aligned} \quad (10)$$

其中:  $a_{Pi}$  和  $b_{Pi}$  为特征  $i$  的节域的下界和上界;  $a'_{0ji}$  和  $b'_{0ji}$  为故障类型  $j$  的训练样本第  $i$  个特征的最小值和最大值;  $a_{0ji}^{\min}$  为故障类型  $j$  的第  $i$  个特征的下界值  $a_{0ji}$  的优化范围下界, 本文取节域的下界,  $b_{0ji}^{\min}$  为故障类型  $j$  的第  $i$  个特征的上界值  $b_{0ji}$  的优化范围上界, 本文取节域的上界;  $a_{0ji}^{\max}$  为  $a_{0ji}$  的优化范围上界,  $b_{0ji}^{\max}$  为  $b_{0ji}$  的优化范围下界, 两者都取故障类型  $j$  的训练样本各特征最大值与最小值之和的一半。

各指标权重一般按经验确定, 对于本文采用训练方法确定的诊断模型, 可按等权处理, 取  $w_{\max}=0.9$ ,  $w_{\min}=0.4$ ,  $c_1=c_2=1.4$ ,  $T_m=200$ , 群体规模  $S=60$ , 优化得到的一组较满意的经典域参数如表 2 所示。

采用表 2 的经典域对 9 组待测样本进行诊断, 诊断结果如表 3 所示, 表 3 还给出了文献[1]采用遗传 BP 神经网络的诊断结果。由表 3 可知, 可拓方法诊断结果与实际吻合, 效果非常理想。采用粒子群算法优化确定经典域, 能使故障关联度尽量大于 0, 在可拓学解释上更加合理, 也解决了不易确定经典域的问题。其中 21 号样本诊断为 F2 故障, 但也存在发生 F3 故障的可能性, 其关于 F2 的综合关联度为 0.347 3, 关于 F3 的综合关联度为 0.203 1, 神经网络方法也有这方面的体现。

表 3 两种方法的诊断结果对比表

Tab.3 Diagnosis results of different methods

序号	遗传 BP 神经网络				PSO 法			
	F1	F2	F3	故障	F1	F2	F3	故障
16	0.915	0.171	0.005	F1	0.277 4	-0.397 8	-0.450 2	F1
17	0.881	0.030	0.099	F1	0.193 4	-0.414 5	-0.427 6	F1
18	0.811	0.112	0.167	F1	0.295 6	-0.278 0	-0.323 9	F1
19	0.032	0.920	0.163	F2	-0.297 5	0.037 4	-0.188 8	F2
20	0.055	0.883	0.179	F2	-0.469 5	0.274 8	0.013 7	F2
21	0.131	0.722	0.205	F2	-0.438 8	0.347 3	0.203 1	F2
22	0.047	0.068	0.912	F3	-0.329 4	0.081 7	0.368 3	F3
23	0.105	0.129	0.875	F3	-0.297 1	-0.035 0	0.273 4	F3
24	0.132	0.112	0.843	F3	-0.300 7	-0.055 0	0.295 0	F3

### 4 结论

本文将可拓方法应用于汽轮发电机组故障诊断中，采用粒子群算法优化确定经典域并提出了一种适应度函数，通过实例分析可知：

1) 可拓方法用于汽轮机故障诊断，诊断结果与实际吻合，且可用于多故障诊断。

2) 与 BP 神经网络相比，不存在确定网络结构的问题，神经网络隐层节点数目的确定目前尚无较好的依据。优化参数也比神经网络少，文献[1]的神经网络采用 5-10-3 结构，包含阈值有 90 多个参数。

3) 采用粒子群算法优化确定经典域，能使可拓方法在解释上更为合理，也减少了对专家经验的依赖性。

### 参考文献

[1] 欧健, 孙才新, 胡雪松, 等. 基于遗传优化 BP 网络的振动故障诊断[J]. 高电压技术, 2006, 32 (7): 46-48.  
 OU Jian, SUN Cai-xin, HU Xue-song, et al. BP neural network based on genetic algorithm for vibration fault diagnosis of turbine-generator set[J]. High Voltage Engineering, 2006, 32 (7) : 46-48.

[2] 张彼德, 欧健, 孙才新. 汽轮发电机多故障诊断的 SOM 神经网络方法[J]. 重庆大学学报: 自然科学版, 2005, 285 (2): 36-38.  
 ZHANG Bi-de, OU Jian, SUN Cai-xin. Applications of SOM neural network in multiple-faults diagnosis of turbogenerator set[J]. Journal of Chongqing University:

Natural Science Edition, 2005, 285 (2): 36-38.

[3] 张彼德, 潘凌. 汽轮发电机组故障诊断的模糊聚类分析新方法[J]. 西华大学学报: 自然科学版, 2006, 25 (3): 8-10.  
 ZHANG Bi-de, PAN Ling. New approach to fuzzy clustering analysis in multiple-faults diagnosis of a turbogenerator set[J]. Journal of Xihua University: Natural Science Edition, 2006, 25 (3) : 8-10.

[4] 蔡文, 杨春燕, 林伟初. 可拓工程方法[M]. 北京: 科学出版社, 1997.

[5] WANG Meng-hui. A novel extension method for transformer fault diagnosis[J]. IEEE Trans on Power Delivery, 2003, 18 (1): 164-169.

[6] Kennedy J, Eberhart R. Particle swarm optimization[C]. // IEEE International Conference on Neural Networks. Perth (Australia) : 1995.

[7] Eberhart R, Kennedy J. A new optimizer using particle swarm theory[C]. //Proc of the Sixth International Symposium on Micro Machine and Human Science. Nagoya (Japan) : 1995.

[8] SHI Yu-hui, Eberhart R. Empirical study of particle swarm optimization[C]. //Proc of International Conference on Evolutionary Computation. Washington: (USA): 1999.

收稿日期: 2009-10-09; 修回日期: 2009-12-17

作者简介:

王永林 (1977-), 男, 讲师, 硕士, 研究方向为人工智能方法与应用. E-mail: wylin77@126.com