

# 自适应粒子群优化 BP 神经网络的 变压器故障诊断

付宝英, 王启志

(华侨大学 机电及自动化学院, 福建 厦门 361021)

**摘要:** 在分析粒子群参数特征的基础上,提出自适应粒子群优化算法,使用自适应粒子群优化 BP 神经网络,建立基于自适应粒子群优化 BP 神经网络(PSO-BP)的变压器故障诊断系统.通过对 52 组训练样本和 28 组测试样本的仿真实验,可知自适应 PSO-BP 法能提高变压器故障诊断的准确率,有效减小网络的误差精度.

**关键词:** 变压器;故障诊断;BP 神经网络;粒子群算法

**中图分类号:** TP 183; TP 301

**文献标志码:** A

变压器的运行状态直接影响着电力系统的安全,对变压器故障做到及时、准确的诊断,可有效减少故障隐患所带来的安全事故.传统的故障诊断方法,如四比值法、三比值法、电协研法等,由于存在编码不全、诊断准确率较低而被日益淘汰. BP 神经网络具有良好的自学习能力和强大的非线性映射能力<sup>[1]</sup>,在变压器故障领域发挥着较大作用.但 BP 神经网络存在易陷入局部极点、学习速率较难准确选取等问题,采用新型智能算法对其进行改进成为一种较可行的方法.粒子群算法作为最有潜力的神经网络训练方法,具有收敛速度快、全局搜索能力强等优点<sup>[2-3]</sup>,用来优化 BP 神经网络,可以有效弥补 BP 神经网络的不足.杨道武等<sup>[4]</sup>使用带惯性权重的粒子群算法优化 BP 神经网络;王晓霞等<sup>[5]</sup>将惯性权重和收缩因子同时引入粒子群算法中用于优化 BP 网络的权值和阈值.然而大多改进粒子群算法都是针对惯性权重的改进,忽略了粒子群其他参数对算法性能的影响.本文在分析粒子群各参数对算法性能影响的基础上,对粒子群的惯性权重和加速因子进行非线性调整,提出自适应粒子群算法用于优化 BP 神经网络的权值和阈值,将其应用于变压器故障诊断中.

## 1 自适应粒子群算法的策略制定

### 1.1 标准粒子群算法<sup>[6]</sup>

假设粒子的群体规模为  $N$ ,那么在  $D$  维的搜索空间中,第  $i$  个粒子的位置可表示为  $\mathbf{x}_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$ ,速度可表示为  $\mathbf{v}_i = (v_{i,1}, v_{i,2}, \dots, v_{i,D})$ ,其中  $i = 1, 2, \dots, N$ .若将第  $i$  个粒子目前所搜索到的最优位置记为  $\mathbf{p}_i = (p_{i,1}, p_{i,2}, \dots, p_{i,D})$ ,将群体目前所搜索到的最优位置记为  $\mathbf{p}_g = (p_{g,1}, p_{g,2}, \dots, p_{g,D})$ ,那么在每次迭代过程中,粒子  $i$  在第  $d$  维子空间中的速度  $v_{i,d}$  和位置  $x_{i,d}$  的更新公式表示为

$$\mathbf{v}_{i,d}(t+1) = \omega \mathbf{v}_{i,d}(t) + c_1 r_1 (\mathbf{p}_{i,d} - \mathbf{x}_{i,d}(t)) + c_2 r_2 (\mathbf{p}_{g,d} - \mathbf{x}_{i,d}(t)), \quad (1)$$

$$\mathbf{x}_{i,d}(t+1) = \mathbf{x}_{i,d}(t) + \mathbf{v}_{i,d}(t+1). \quad (2)$$

式(1)~(2)中: $\omega$  为惯性权重; $c_1, c_2$  为非负的加速常数,也称加速因子或学习因子; $r_1, r_2$  为  $[0, 1]$  之间的随机数; $i = 1, 2, \dots, N$ ;  $d = 1, 2, \dots, D$ .

在粒子群算法中,一般会对速度向量  $\mathbf{v}_{i,d}$  进行最值限制,当  $\mathbf{v}_{i,d} > v_{\max}$  时,取  $\mathbf{v}_{i,d} = v_{\max}$ ;当  $\mathbf{v}_{i,d} < -v_{\max}$

收稿日期: 2012-04-20

通信作者: 王启志(1971-),男,副研究员,主要从事先进智能控制方面的研究. E-mail: wangqz@hqu.edu.cn.

基金项目: 福建省自然科学基金资助项目(A0640004)

时, 则取  $v_{i,d} = -v_{\max}$ .

## 1.2 粒子群算法的参数分析及自适应粒子群算法的提出

选取一个合适的惯性权重值( $\omega$ )可以平衡粒子全局搜索能力和局部搜索能力, 增强粒子群的寻优性能. 在粒子群寻优的初期, 可以采用较大的惯性权值, 以获得较好的全局搜索能力; 而在寻优的后期, 则采用较小的惯性权值, 以达到尽快收敛的目的. 因此, 惯性权重的调整策略可以制定为一个逐步递减的调整方案. 同时, 对于适应度值较小的粒子, 可以适当加大粒子的权重值, 以激励这些较好粒子在粒子更新中所起的积极作用, 而对于适应度值较大的粒子, 则可以削弱这些粒子在粒子更新中所起的作用. 由此建立惯性权重的调整公式为

$$\omega = \begin{cases} \omega_{\max} + \omega_{\min} - \frac{\omega_{\max} - \omega_{\min}}{n_{\max}} \cdot n_{\text{er}}, & f \leq C, \\ \omega_{\max} - \frac{\omega_{\max} - \omega_{\min}}{n_{\max}} \cdot n_{\text{er}}, & f > C. \end{cases} \quad (3)$$

式(3)中:  $\omega_{\max}$ ,  $\omega_{\min}$  为设定的权重最大值和最小值;  $n_{\max}$  为粒子的最大迭代次数,  $n_{\text{er}}$  为粒子的当前迭代次数;  $f$  为粒子的当前适应度值;  $C$  为粒子的当前最优适应值.

在粒子群算法中, 除了惯性权重的这个重要参数外, 加速因子在算法性能中也起着较为重要的作用. 合适的加速因子搭配可以加快粒子的搜索速度, 减少粒子陷入局部极小的可能. 在寻优初期, 可采用较大的  $c_1$  和较小的  $c_2$ , 以确保每个粒子都能做到较全面的局部搜索, 而在粒子的后期则应该适当减小  $c_1$ 、增大  $c_2$ , 以促进粒子之间的相互交流, 达到尽快收敛的目的. 因此, 可采用  $c_1$  非线性递减策略, 并构建  $c_1$ ,  $c_2$  之间的非线性搭配关系  $c_2 = a^{-c_1} + b$ , 实现  $c_1$  随迭代次数逐渐减小,  $c_2$  随迭代次数逐渐增加的目的. 建立的加速因子调整公式表示为

$$\begin{cases} c_1 = c_{\max} - \frac{c_{\max} - c_{\min}}{n_{\max}} \cdot n_{\text{er}}, \\ c_2 = a^{-c_1} + b. \end{cases} \quad (4)$$

式(4)中:  $c_{\max}$ ,  $c_{\min}$  为设定的参数最大值和最小值;  $a$ ,  $b$  为正常数.

## 2 自适应粒子群优化 BP 神经网络的流程

在自适应 PSO 算法优化 BP 神经网络时, 首先要确定神经网络的拓扑结构, 并根据网络的拓扑结构来确定粒子的维数. 在 PSO 优化 BP 时, 神经网络权值和阈值总个数应等于粒子的维数. 其次, 在 BP 网络中, 网络不断调整权值和阈值是以误差均方值为基准的, 那么在 PSO 优化 BP 时, 就应建立误差均方值与 PSO 适应度函数的对等关系. 故 PSO-BP 中的适应度函数可表示为

$$F = \frac{1}{2N} \sum_{i=1}^m \sum_{j=1}^N (y_{i,j} - y'_{i,j})^2. \quad (5)$$

式中:  $y_{i,j}$ ,  $y'_{i,j}$  分别为样本的理想输出值和实际输出值;  $m$  为网络输出层的个数;  $N$  为输入样本的个数.

将上述 2 个关键点解决后就可以进行自适应粒子群算法的寻优, 其具体流程有如下 8 个步骤.

1) 初始化算法参数, 需要初始化的参数有最大迭代次数  $n_{\max}$ 、最大速度  $v_{\max}$ 、群体规模  $N$ 、惯性权重  $\omega_{\max}$  和  $\omega_{\min}$ 、加速因子  $c_{\max}$  和  $c_{\min}$ , 以及随机初始的位置向量和速度向量等.

2) 根据实际求解的问题确定 BP 神经网络的拓扑结构, 建立网络初始模型; 并根据网络的拓扑结构, 计算粒子的维数, 如 5-12-4 的三层 BP 网络, 则粒子维数为 124.

3) 输入网络的训练样本, 将初始化的位置向量作为当前全局最优值映射到网络的权值和阈值中, 计算网络的实际输出值和误差均方值, 并以误差均方值作为粒子群的适应度函数.

4) 按照粒子群的更新公式进行粒子速度和位置的更新.

5) 进行迭代运算, 将当前最优适应度值与粒子群的局部最优值  $p_{\text{best}}$  进行比较, 若当前最优适应度值优于  $p_{\text{best}}$  时, 则取代当前局部最优值, 完成粒子群的局部极值更新.

6) 将当前全局最优值与粒子群的全局最优值  $g_{\text{best}}$  进行比较, 若当前全局最优值优于  $g_{\text{best}}$  时, 则取代  $g_{\text{best}}$ , 完成粒子群的全局极值更新.

- 7) 将全局最优粒子中的位置向量映射到 BP 神经网络的权值和阈值中.
- 8) 将测试样本输入粒子群优化后的 BP 神经网络中,分析测试样本的输出结果,检验算法的性能.

3 基于自适应 PSO-BP 变压器故障诊断

3.1 故障诊断系统的建立

变压器的故障特征气体有 5 种:  $H_2$ ,  $CH_4$ ,  $C_2H_6$ ,  $C_2H_4$ ,  $C_2H_2$ ; 对应的故障类型有 4 种: 高能量放电、低能量放电、高温过热和中低温过热; 建立 BP 神经网络的拓扑结构为 5-14-4. 参考文献[7-9]搜集了 80 组样本数据, 以其中的 52 组作为训练样本, 28 组作为测试样本, 将这 52 组训练样本输入故障诊断系统, 完成系统的训练, 再使用 28 组测试样本检验系统的性能. 建立的自适应 PSO-BP 变压器故障诊断系统, 如图 1 所示.




图 1 自适应 PSO-BP 的变压器故障诊断系统  
Fig. 1 Transformer fault diagnosis system of adaptive PSO-BP

由图 1 可知, 该系统包含了三大模块: 归一化处理模块、自适应粒子群优化 BP 神经网络模块和故障编码输出模块. 故障样本经归一化处理后, 进入自适应 PSO-BP 模块进行学习和训练, 得出故障编码, 进而诊断出故障类型.

3.2 自适应 PSO-BP 的参数设置

粒子群优化算法中, 参数的初始化对网络的性能有较大的影响, 在仿真分析中, 需要经过多次尝试方可确定比较满意的初始值. 经过多次仿真试验, 设置最大迭代次数  $n_{max}$  为 200, 最大速度  $v_{max}$  为 1.0, 群体规模  $N$  为 40, 神经网络结构为 5-14-4, 粒子维数  $D$  为 144 (维数计算 =  $5 \times 14 + 14 \times 4 + 14 + 4$ ), 惯性权值的最大值  $\omega_{max}$  为 0.7, 最小值  $\omega_{min}$  为 0.3, 加速因子的最大值  $c_{max}$  为 2.5, 最小值  $c_{min}$  为 0.5. 速度和位置的初始化选择公式  $v = a + (b - a) \times n_{max}$  和  $X = c + (d - c) \times n_{max}$ , 设置参数  $a = c = 0.5$ ,  $b = d = -0.5$ .

3.3 变压器故障诊断结果及分析

将 52 组训练样本输入自适应粒子群优化的 BP 神经网络中进行网络训练, 确定网络最优的权值和阈值, 并使用 28 组测试样本进行性能测试, 评估粒子群优化后的网络性能. 28 组样本经训练后的自适应 PSO-BP 变压器故障系统的输出结果, 如表 1 所示.

为方便对比分析, 使用 BP 神经网络和标准 PSO-BP 神经网络分别进行了变压器的故障诊断. 在 BP 神经网络中, 训练方法选择最小梯度下降法, 训练步数为 1 000, 训练目标误差精度为  $10^{-3}$ . 在标准 PSO-BP 中, 惯性权重选用线性递减  $\omega = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{n_{max}} \times n_{er}$ ,  $\omega_{max}$  为 0.7,  $\omega_{min}$  为 0.3, 加速因子常用搭配  $c_1 = c_2 = 2.0$ , 其他参数与自适应粒子群优化 BP 网络的参数相同. 将两种对比方法的诊断结果与自适应 PSO-BP 的诊断结果统计, BP 神经网络法、标准 PSO-BP 法和自适应 PSO-BP 法的误差均方值分别为: 0.180 3, 0.170 2, 0.031 7; 诊断错误组数分别为: 6 组, 5 组, 2 组; 准确率分别为: 78.57%, 82.14%, 92.86%.


分析三组诊断结果可知: 使用自适应 PSO 优化 BP 神经网络进行变压器的故障诊断时, 只有 2 组出现诊断错误, 其余 26 组诊断结果都与实际故障类型相吻合, 诊断的准确率达到了 92.86%; 在标准粒子群优化的 BP 神经网络故障诊断中, 有 5 组数据出现诊断错误, 诊断的准确率只达到 82.14%, 误差均方值也较大; 而 BP 神经网络的诊断准确率只有 78% 左右, 诊断效果较差.

仿真自适应 PSO-BP 的训练误差曲线和标准 PSO-BP 的训练误差曲线,如图 2 所示.图 2 中, $n$  为迭代次数, $\sigma$  为误差均方值.由图 2 可知:在自适应 PSO 优化 BP 神经网络中,粒子群的迭代寻优效果良好,前 25 步左右可以迅速减小网络的训练误差均方值至 0.048 左右,在 140 步左右就基本达到了平衡,使  $\sigma$  减小到了 0.03 左右.而在标准粒子群优化 BP 神经网络中,刚开始随着迭代次数的增加,网络的误差均方值也能较快减小,但之后在较长迭代次数内都下降缓慢,在 120 步时达到  $\sigma$  的最小值 0.17,之后

表 1 28 组测试数据仿真结果

Tab. 1 Simulation results of 28 groups of test data

故障类型	输出故障编码				正确与否
高能量 放电 (1 0 0 0)	0.895 0	0.135 0	-0.153 3	0.119 5	正确
	1.056 7	-0.081 1	-0.006 4	0.028 3	正确
	0.763 4	0.260 3	0.026 5	-0.045 4	正确
	0.894 5	0.122 9	0.052 5	-0.071 9	正确
	0.904 2	-0.157 8	-0.026 7	0.291 7	正确
	0.284 9	-0.080 4	0.692 6	0.103 0	错误
	0.993 6	0.062 1	-0.179 5	0.105 9	正确
	0.997 6	-0.047 7	0.050 4	-0.006 0	正确
	0.707 8	0.411 4	-0.088 2	-0.028 1	正确
低能量 放电 (0 1 0 0)	-0.019 6	0.390 2	0.467 0	0.160 0	错误
	0.264 7	0.901 9	-0.126 1	-0.032 6	正确
	-0.114 0	0.902 8	0.081 5	0.114 5	正确
	-0.144 5	0.978 1	0.187 8	-0.024 9	正确
	0.025 1	0.891 5	0.066 9	0.015 2	正确
	-0.056 9	0.916 2	0.079 6	0.059 6	正确
高温 过热 (0 0 1 0)	0.042 0	-0.078 4	0.814 9	0.221 0	正确
	-0.018 7	0.015 9	0.867 2	0.134 8	正确
	0.038 0	-0.077 5	0.818 1	0.220 8	正确
	0.317 0	-0.086 6	0.653 6	0.115 9	正确
	0.077 8	0.019 0	0.905 8	-0.002 1	正确
	0.042 5	0.144 9	0.757 3	0.054 8	正确
	0.078 1	0.011 1	0.896 7	0.014 5	正确
	-0.233 8	0.401 6	1.007 7	-0.161 5	正确
中低温 过热 (0 0 0 1)	0.207 7	-0.166 1	0.177 4	0.782 2	正确
	0.001 2	-0.049 0	0.060 1	0.993 8	正确
	0.135 2	-0.018 8	-0.033 8	0.919 9	正确
	-0.022 0	-0.066 8	0.114 7	0.971 4	正确
	0.024 2	-0.009 2	-0.058 1	1.046 6	正确



(a) 自适应 (b) 标准

图 2 PSO-BP 的训练误差曲线  
Fig. 2 PSO-BP training error curve

就不再发生变化,整体动态性能没有自适应 PSO-BP 好. 自适应 PSO-BP 的最终误差均方值为 0.03 左右,标准 PSO-BP 的最终误差均方值为 0.17 左右,是自适应 PSO-BP 误差均方值的 5.67 倍,寻优误差较大. 由此可见,自适应 PSO-BP 可以获得较好的寻优效果和较快的收敛速度,并有效减小训练误差.

4 结 束 语

针对 BP 神经网络对变压器故障诊断准确率不高的问题,提出使用粒子群算法优化 BP 神经网络;并针对粒子群算法的参数特征,提出基于惯性权重和加速因子非线性调整的自适应粒子群算法. 建立自适应粒子群优化 BP 神经网络的变压器故障诊断系统,通过仿真对比分析,验证该系统能较大程度地提高变压器故障诊断的准确率.

参考文献:

[1] 回敬,律方成. 将具有可信度的 BP 神经网络应用于变压器故障诊断[J]. 电力科学与工程,2010,26(2):9-13.  
[2] SHI Y, EBERHART R C. A modified particle swarm optimizer[C]//IEEE International Conference on Evolutionary Computation. Alaska: Anchorage, 1998: 69-73.  
[3] 崔长彩,李兵,张认成. 粒子群优化算法[J]. 华侨大学学报:自然科学版,2006,27(4):343-346.  
[4] 杨道武,李海如,向卫东,等. 基于改进 PSO-BP 混合算法的电力变压器故障诊断[J]. 电力科学与技术学报,2011,26(1):99-103.  
[5] 王晓霞,王涛. 基于粒子群优化神经网络的变压器故障诊断[J]. 高电压技术,2008,34(11):2362-2367.  
[6] EBERHART R C, KENNEDY J. A new optimizer using particle swarm theory[J]. Institute of Electrical and Electronics Engineers, 1995(10):39-43.  
[7] 刘晓津. 基于支持向量机和油中溶解气体分析的变压器故障诊断[D]. 天津:天津大学,2007:53-55.  
[8] 吴宏崎,周妮娜,王春英. 基于 RBF 神经网络的变压器故障诊断及 MATLAB 仿真研究[J]. 科学技术与工程,2010,10(5):1249-1251.  
[9] 程加堂,熊伟,段志梅,等. 灰色神经网络在变压器故障诊断中的应用[J]. 高压电器,2010,46(8):56-58.

Transformer Fault Diagnosis of Adaptive Particle Swarm Optimization BP Neural Network

FU Bao-ying, WANG Qi-zhi

(College of Mechanical Engineering and Automation, Huaqiao University, Xiamen 361021, China)

**Abstract:** Based on the analysis of the particle swarm parameter characteristic, adaptive particle swarm optimization algorithm is put forward. Using adaptive particle swarm optimization back propagation (PSO-BP) neural network, transformer fault diagnosis system is built up based on adaptive particle swarm optimization BP neural network. By the simulation experiment using 52 groups of training samples and 28 groups of test samples, it can be seen that the adaptive PSO-BP method can improve the transformer fault diagnosis accuracy and reduce the network error precision effectively.

**Keywords:** transformer; fault diagnosis; BP neural network; particle swarm algorithm

(责任编辑: 黄晓楠      英文审校: 杨建红)