

多自适应策略粒子群优化算法及应用^①

谭爱国¹, 琚长江^{2,3}

¹(上海理工大学 光电信息与计算机工程学院, 上海 200093)

²(上海交通大学 电子信息与电气工程学院, 上海 200240)

³(上海电器科学研究所(集团)有限公司, 上海 200063)

摘要: 为了平衡粒子群优化算法的全局和局部搜索能力, 提出了一种多自适应策略粒子群优化算法。该算法在粒子进化过程中, 采用了基于粒子进化度和局部开启混沌搜索相结合的速度自适应调节策略。将算法应用于模拟电路故障诊断的 BP 神经网络训练中, 有效地解决了常规 BP 算法收敛速度慢、易陷入局部极小的问题。仿真结果表明算法具有较快的收敛速度和较高的诊断精度。

关键词: 粒子群优化; 神经网络; 自适应策略; 混沌搜索; 故障诊断

Particle Swarm Optimization Algorithm with Multi-Adaptive Strategies and its Application

TAN Ai-Guo¹, JU Chang-Jiang^{2,3}

¹(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

²(School of Electronics, Information and Electrical Engineering, Shanghai Jiaotong University, Shanghai 200240, China)

³(Shanghai Electrical Apparatus Research Institute(Group)Co. Ltd., Shanghai 200063, China)

Abstract: In order to balance local and global search ability of particle swarm optimization algorithm, a particle swarm optimization algorithm with multi-adaptive strategies (MAS-PSO) has been proposed. In the process of particle evolution, the algorithm adopted adaptive velocity setting strategies which were based on the evolution degree of particles and local opening chaotic search. The MAS-PSO is applied to BP neural network training of analog circuit fault diagnosis, and it solved effectively the problems of slow network convergence rate in conventional BP algorithm and easily falling into partial minimum. The simulation results show it works with quicker convergence rate and higher forecast precision.

Key words: particle swarm optimization; neural network; adaptive strategy; chaotic search; fault diagnosis

模拟电路故障由于电路元器件具有容差、非线性、反馈等因素, 操作人员很难快速准确判断发生故障的元件或位置, 设计科学、合理的模拟电路故障诊断方案, 可以提高系统的可靠性, 并及时排查故障, 保证电路正常运行。传统的模拟电路故障诊断方法如故障字典法、故障参数识别法、K 故障诊断法等, 由于模拟电路自身的困难进展一直比较缓慢。随着人工智能技术的发展, 模拟电路故障诊断开始往智能诊断方向发展, 智能故障诊断技术由于不需要建立对象的精确数学模型, 它部分解决了故障诊断的模糊性和不确定性等经典常规方法不能解决各类问题, 因而在故障

诊断中得到了越来越广泛的重视。目前智能诊断方法包含模糊诊断方法、专家系统诊断方法、神经网络诊断方法和混合智能的诊断方法等。其中神经网络诊断方法由于克服基于逻辑与符号处理的专家系统的局限性, 自适应能力和非线性逼近能力强的优点应用最为普遍^[1,2]。神经网络性能的实现依赖于对神经网络的充分训练, BP(Back Propagation)算法是最普遍的神经网络训练算法。但是, 基于梯度下降的 BP 算法存在着网络权值和阈值收敛速度慢、收敛精度不理想、易陷入局部极小等缺陷。针对这些不足, 许多研究者提出采用粒子群优化(Particle Swarm Optimization, PSO)算法

① 基金项目:上海市科学技术委员会火炬计划(09HJC006100)

收稿时间:2011-05-24;收到修改稿时间:2011-07-03

训练神经网络。PSO 是一种全局随机优化算法，其速度-位移搜索模型操作简单、计算复杂度低、收敛速度快，但它也存在易陷于局部极值、收敛精度不高、种群多样性易丢失的问题，且算法在接近最优解时收敛缓慢甚至出现停滞现象，导致网络训练难以达到理想效果^[3-8]。针对 PSO 算法存在上述全局搜索和局部搜索能力难以平衡的矛盾，文中提出了一种多自适应策略粒子群优化算法 (Particle Swarm Optimization Algorithm with Multi-adaptive Strategies, MAS-PSO)。在粒子进化过程中，引入基于粒子进化度和局部开启混沌搜索相结合的速度自适应调节策略。将该算法应用于模拟电路故障诊断的 BP 神经网络训练中，有效地解决了上述常规 BP 算法和基本 PSO 算法的不足。仿真结果表明算法具有较快的收敛速度和较高的诊断精度。

1 粒子群优化算法

1.1 基本粒子群算法

粒子群优化算法是一种基于种群的全局搜索策略的优化算法，通过群体间的信息共享和个体自身经验总结来修正个体的移动策略，最终求取优化问题的解^[7]。基本粒子群优化算法描述为：假定在一个 D 维的目标搜索空间中，有 N 个代表潜在问题解的粒子组成一个种群 $S=\{X_1, X_2, \dots, X_N\}$ ，其中 $X_i=\{x_{i1}, x_{i2}, \dots, x_{iD}\}$ ， $i=1, 2, \dots, N$ 表示第 i 个粒子在 D 维空间的位置。将 X 代入一个与求解问题相关的目标函数，可以计算出相应的适应度值。用 $P_i=\{p_{i1}, p_{i2}, \dots, p_{iD}\}$ ， $i=1, 2, \dots, N$ ，记录第 i 个粒子本身搜索到的最优个体极值，用 $P_g=\{p_{g1}, p_{g2}, \dots, p_{gD}\}$ 记录整个种群目前搜索到的最优全局极值，每个粒子的速度变量用 $V_i=\{v_{i1}, v_{i2}, \dots, v_{iD}\}$ 表示，粒子的运动通过下面两个公式进行。

$$V_i^{k+1} = \omega V_i^k + c_1 \times r_1 \times (P_i^k - X_i^k) + c_2 \times r_2 \times (P_g^k - X_i^k) \quad (1)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (2)$$

式中，k 为迭代次数，r1 和 r2 是介于(0,1)之间的随机数，c₁、c₂ 是学习因子，为了控制 V_i^k 和 X_i^k 的值在合理的区域内，需要指定 Vmax 和 Xmax。ω 为惯性权重因子，用于权衡全局搜索和局部搜索能力。

1.2 多自适应策略粒子群优化算法

在基本粒子群算法基础上，研究人员提出了许多改进的 PSO，如：自适应 PSO、混合 PSO，协同 PSO

等，这些算法从不同角度对基本 PSO 进行了改进，在不同程度上获得了较为理想的优化结果。本文在综合考虑算法全局搜索和局部搜索能力的平衡、算法的运算量以及应用对象特征几方面的基础上，提出了一种多自适应策略粒子群优化算法，在粒子进化过程中，引入基于粒子进化度和局部开启混沌搜索相结合的速度自适应调节策略。

从基本粒子群算法的迭代公式可知粒子进化速度与 ω 相关，ω 对优化粒子群算法的性能有很大的影响，ω 较大时算法具有较强的全局搜索能力，ω 较小时算法有利于局部搜索，在局部搜索过程中，算法性能还与粒子内部的个体特性有关，将粒子的个体差异反映到迭代公式中，才能适应具有复杂非线性变化问题的优化。因此本文采用的算法在粒子进化过程中依据粒子整体的进化度和个体进化度来调节每个粒子的 ω，从而实现每个粒子进化速度的自适应调节^[8]。在粒子群算法的迭代过程中还会出现种群多样性丢失，收敛速度缓慢甚至停滞的现象，以致网络训练效果不理想，为了解决此问题，文中对进入速度缓慢或停滞区的粒子，通过开启混沌搜索来实现进化速度的自适应调节，提升算法的局部寻优能力。

该算法具体描述如下：采用 Ge 和 Pe 两个变量表示粒子整体进化度和粒子个体进化度。

粒子整体进化度：

$$Ge = \frac{f_i(p_g^k)}{f_i(p_g^{k-1})} \quad (3)$$

粒子个体进化度：

$$Pe(i) = \frac{\sqrt{\sum_{d=1}^D (p_{id}^k - p_{gd}^k)^2}}{\max_{i=1 \dots N} \sqrt{\sum_{d=1}^D (p_{id}^k - p_{gd}^k)^2}} \quad (4)$$

粒子的惯性权值：

$$\begin{aligned} \omega(i) &= f(Ge, Pe(i)) \\ &= \omega_0 - c_3 \cdot \sin(Ge \cdot \pi / 2) + c_4 \cdot \sin(Pe(i) \cdot \pi / 2) \end{aligned} \quad (5)$$

(3)式中 f_i 代表适应度函数，(5)式中 ω₀ 为初始惯性权值，c₃、c₄ 为调节因子，取值在(0, 1)之间；粒子整体进化度考虑了粒子以前的运行状态，反应了粒子群整体进化的程度，Ge 值较小，速度进化快，算法可以在较大的空间内继续搜索，反之可以减小 ω 使得粒子在较小的范围内搜索，增强局部寻优能力。粒子个体进化度反映了个体粒子在以最优粒子为中心的群

体中的离散情况, Pe 越小时, 说明粒子越靠近最优粒子, 粒子应在较小的范围内进行搜索, Pe 越大时, 可适当放大粒子的搜索范围。

在进化后期, 粒子呈紧密聚集状态, 粒子移动速度慢或停滞, 种群多样性匮乏。为此在算法中, 对运行速度很低或速度为零的粒子, 启动局部混沌扰动策略来增加种群的多样性。混沌是自然界广泛存在能在一定范围内按自身规律不重复的遍历所有状态^[9], Logistic 映射是一个典型的混沌系统。迭代公式如下:

$$u_{1j} = z \cdot u_{0j}(1 - u_{0j}) \quad (6)$$

式中: $j=1, 2, \dots, n$, u_{0j} 为 (0, 1) 的随机数, $z=4$ 时系统完全混沌状态。本文采用 Logistic 映射作为混沌系统, 对速度很低或速度为零的粒子施加混沌扰动, 粒子速度更新公式如下:

$$u_{1j} = 4 \cdot u_{0j}(1 - u_{0j}) \quad (7)$$

$$\Delta V_j = r3 \cdot u_{1j} \quad (8)$$

$$V_{ij}^{k+1} = V_{ij}^k + \Delta V_j \quad (9)$$

其中, ΔV_j 为进化速度的混沌扰动项, $r3$ 是介于 (0,1) 之间的随机数, u_{0j} 初始化为 n 维的随机取值为 (0, 1) 的行向量。

2 基于 MAS-PSO 算法的 BP 神经网络训练

粒子群优化算法训练 BP 神经网络的基本思想为: 用粒子群优化算法代替梯度下降法训练神经网络的权值和阈值, 最终搜索出粒子适应度函数最小时的 BP 网络最佳权值和阈值。操作方法为选取 N 个粒子构成粒子群, 其中每个粒子都是 D 维的向量, 这个向量代表神经网络模型中的所有权值和阈值, 所有权值和阈值的初始值随机产生。粒子初始群体随机产生后, 以后各代粒子的位置根据飞行速度的变化而变化。采用神经网络均方差作为适应度函数, 具体算法流程如下:

① 根据研究对象特征建立神经网络的拓扑结构, 初始化输入层、隐含层、输出层的神经元个数, 将神经元之间所有的连接权值和阈值编码成实数向量表示种群中的个体粒子。

② 初始化粒子的初始位置、速度、惯性权重 ω_0 、学习因子 $C1$ 和 $C2$ 、调节因子 $C3$ 和 $C4$ 、最大迭代次数、 P_i 和 P_g 等。

③ 根据输入、输出样本, 按 BP 网络的前向计算方法计算出每个粒子的适应度函数值。

④ 确定粒子群的全局极值和每个粒子的个体极值。

⑤ 检验是否符合结束条件。如果粒子的当前位置达到预定的误差要求或最大迭代次数达到, 则停止迭代, 此时全局极值所对应的神经网络的权值和阈值即为问题的最优解, 可输入检测样本进行测试。否则转⑥执行。

⑥ 利用 MAS-PSO 中的式③④⑤计算每个粒子的惯性权值。

⑦ 依据式①对每个粒子的速度进行更新。检查粒子速度是否在限定的范围之内, 对速度超限的粒子进行超限处理后, 转⑧执行; 对速度没有超限的粒子继续检查粒子速度是否缓慢或停滞, 对速度缓慢或停滞的粒子需先按式⑦⑧⑨启动局部混沌搜索策略来更新粒子速度后再转⑧执行。

⑧ 依据式②对每个粒子的位置进行更新; 检查粒子位置是否在限定的范围之内, 在范围内转③继续迭代。否则先进行越界处理再转③继续迭代。

3 MAS-PSO 算法在模拟电路故障诊断中的应用

为了验证所述方法和所建模型的可行性和有效性, 本文以某装备雷达喇叭控制继电器板的电路故障数据进行了网络训练和故障诊断^[2]。网络拓扑结构为三层 BP 网络, 输入层节点数 $n1=5$, 代表 5 个关键测试点的电压信号, 将测试点数据进行模糊化处理形成网络训练样本, 取输出层节点数 $n3=10$, 分别代表 9 种故障元件和正常情况, BP 网络隐含层节点数依据经验公示 $n2 = \sqrt{n1 \cdot n3} + \alpha$ ($\alpha=1 \sim 10$), 取 $n2=12$ 。在网络训练过程中, 将 MAS-PSO 算法、基本 PSO 算法、遗传算法 (Genetic Algorithm, GA)^[10] 以及带动量和学习因子的 BP 算法进行对比研究, 其中基本 PSO 和遗传算法在训练时陷入局部最优, 算法停滞, 无法达到训练要求。MAS-PSO 算法的初始参数依据训练性能设定为^[11,12]: 惯性因子 $\omega_0=0.7298$, $c1=c2=1.4962$, $c3=0.5$, $c4=0.1$, 最大迭代次数 6500, 控制精度为 0.004。四种算法的适应度变化曲线如图 1 所示, 训练性能和数据测试结果见表 1。

从图 1 的适应度变化曲线可以看出, MAS-PSO 算法克服了 BP 算法收敛速度慢、易陷入局部极小的缺陷。同时该算法还有效的平衡了基本 PSO 全局和局部的寻优能力, 解决了基本 PSO 易陷入局部极值、种群多样性易丢失的问题, 网络训练效果好, MAS-PSO 算

法有着更快的速度和更高的收敛精度。表 1 数据显示 MAS-PSO 算法训练的迭代次数和平均误差都明显优于 BP 算法。




图 1 适应度变化曲线

表 1 BP 和 MAS-PSO 算法训练性能对比

| 算法 | 控制精度 | 迭代次数 | 平均误差 |
|---------|-------|------|-------|
| BP | 0.004 | 6373 | 0.007 |
| MAS-PSO | 0.004 | 2187 | 0.003 |

4 结语

将粒子群优化算法和 BP 神经网络相融合用于模拟电路故障诊断, 改善了 BP 网络模型的性能, 使其不易陷入局部最小, 提高了算法收敛速度, 增强了算法解决具有复杂、非线性变化问题的能力。文中提出多自适应性策略粒子群优化算法, 在粒子进化过程中依据粒子整体的进化度和个体进化度来调节每个粒子的惯性权值 ω , 从而实现每个粒子进化速度的自适应调节。同时针对粒子群在迭代过程中出现种群多样性丢失, 收敛速度缓慢甚至停滞的现象, 通过开启混沌搜索来实现进化速度的自适应调节, 进一步提升了算

法的局部寻优能力。多自适应性策略粒子群优化算法有效的平衡了粒子群全局搜索和局部搜索能力, 实例仿真表明该诊断模型具有较快的收敛速度和较高的诊断精度, 具有很好的工程应用价值。

参考文献

- 1 黄洁,何怡刚.模拟电路故障诊断的发展现状与展望.微电子学,2004,34(1):21-24.
- 2 朱大奇,史慧.神经网络原理及应用.北京:科学出版社,2006:11-17,44.
- 3 宁东方,章卫国,田娜.基于改进粒子群优化算法的神经网络设计.计算机应用研究,2008,25(11):3343-3345.
- 4 王晓霞,王涛,谷根代.基于改进粒子群优化的神经网络及应用.华北电力大学学报,2009,36(5):99-102.
- 5 师彪,李郁侠,于新花,闫旺.改进粒子群-BP神经网络模型的短期电力负荷预测.计算机应用,2009,29(4):1036-1039.
- 6 魏秀业,潘宏侠.速度自适应粒子群优化算法在故障诊断中的应用.太原理工大学学报,2009,40(1):47-50.
- 7 潘立登.先进控制与在线优化技术及其在应用.北京:机械工业出版社,2009.348-349.
- 8 徐以山,曾碧,尹秀文,卢博生.基于改进粒子群算法的BP神经网络及其在应用.计算机工程与应用,2009,45(35):233-235.
- 9 罗豪,雷友诚.基于改进粒子群算法的PID控制器参数优化.计算机仿真,2009,26(9):156-159.
- 10 黄友锐.智能优化算法及其在应用.北京:国防工业出版社,2008.168-173.
- 11 易云飞,陈国鸿.一种基于收缩因子的改进粒子群算法.软件导刊,2009,8(9):59-60.
- 12 何怡刚,祝文姬,周炎涛,刘美容.基于粒子群算法的模拟电路故障诊断方法.电工技术学报,2010,25(6):163-170.