

文章编号: 1001-0920(2009) 06-0843-06

一种新的模糊自适应模拟退火遗传算法

彭勇刚¹, 罗小平², 韦巍¹

(1. 浙江大学 电气工程学院, 杭州 310027; 2. 浙江大学 城市学院, 杭州 310015)

摘要: 针对遗传算法收敛速度慢、容易“早熟”等缺点, 结合模糊推理、模拟退火算法和自适应机制, 提出一种改进的遗传算法——模糊自适应模拟退火遗传算法(FASAGA), 并分析了该算法的性能和特点. 实验研究表明, 该算法比标准的遗传算法(SGA)具有更快的收敛速度和寻优效果.

关键词: 遗传算法; 模糊控制; 模拟退火; 自适应

中图分类号: TP273

文献标识码: A

New fuzzy adaptive simulated annealing genetic algorithm

PENG Yong-gang¹, LUO Xiao-ping², WEI Wei¹

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China; 2. City College, Zhejiang University, Hangzhou 310015, China. Correspondent: PENG Yong-gang, E-mail: hppygang@sina.com)

Abstract: Due to shortcomings of genetic algorithm that its convergence speed is slow and it is often premature convergence, an improved genetic algorithm, fuzzy adaptive simulated annealing genetic algorithm (FASAGA), is presented by integrating fuzzy inference, simulated annealing algorithm and adaptive mechanism. Then the performance and the characteristic of this method are analyzed. Simulation results illustrate that FASAGA has better convergence speed and optimal results than standard genetic algorithm.

Key words: Genetic algorithm; Fuzzy control; Simulated annealing; Adaptive

1 引言

遗传算法是一种宏观意义上的仿生算法, 由美国 Holland 教授于 20 世纪 60 年代末、70 年代初提出. 它模仿的机制是一切生命与智能的产生与进化过程. 它通过模拟达尔文“优胜劣汰、适者生存”的原理激励好的结构; 通过模拟孟德尔遗传变异理论在迭代过程中保持已有结构, 同时寻找更好的结构.

遗传算法因其运算简单、解决问题的有效能力而被广泛应用于众多的领域. 理论上已经证明, 遗传算法能从概率的意义上以随机的方式寻求到问题的最优解. 然而在遗传算法的应用中也会出现一些不尽人意的现象, 其中最主要的是它容易产生“早熟”现象、局部寻优能力较差等.

遗传算法的过早局部收敛, 有些是由于目标函数的特性造成的, 例如函数具有欺骗性、不满足构造模块假说等; 另外一些则是由于算法设计不当. 为此, 不断有人对遗传算法提出各种改进方案. Schraudolph 提出了一种动态编码技术(DPE), 以提

高二进制编码的映射精度. 但是 DPE 在高维、多峰值的非线性优化中存在着明显的不足. Srinivas 等^[1]提出了根据种群分布情况调整遗传概率以提高种群多样性的方法. 优胜劣汰的选择机制使得适应值大的个体有较大的存活机会. 不同的选择策略对算法性能有较大的影响. 轮盘赌法是使用最多的选择策略, 但这种策略可能会产生较大的抽样误差. 于是人们对此提出了很多的改进方法, 如繁殖池选择^[2], Boltzman 选择等. 但这几种策略都是基于适应值比例的选择, 易出现“早熟”收敛和停滞现象. 文献[3]采用类似梯度的方式来选择, 不仅使较差的染色体比较好的染色体得到更大的改进, 而且还不断产生新的个体, 从而拓展了新的搜索空间. 文献[4]采用了 Disruptive Selection, 它吸收了优等和劣等个体, 结果表明两极分化有可能更容易找到最优解. 针对原先遗传算法各控制参数在进化过程中不变的情况, 人们还提出了退化遗传算法和自适应遗传算法^[5-7]等.

收稿日期: 2008-05-29; 修回日期: 2008-07-18.

基金项目: 国家科技支撑计划项目(2007BAF13B03); 浙江省自然科学基金项目(Y1080776).

作者简介: 彭勇刚(1978—), 男, 武汉人, 讲师, 博士, 从事智能控制、遗传算法的研究; 韦巍(1964—), 男, 浙江东阳人, 教授, 博士生导师, 从事智能控制、机器人控制等研究.

标准遗传算法(SGA)交叉和选择操作的概率都是固定的,而过大和过小的操作概率在遗传算法的参数自适应研究方面,除了文献[1]提出的方法以外,文献[6,7]借鉴模糊控制所具有的专家推理能力,提出了一些模糊自适应技术的遗传算法.另外,针对不同问题还出现了分布式遗传算法以及并行遗传算法等.

另一方面,梯度法、爬山法、模拟退火算法、列表寻优法等优化算法具有很强的局部搜索能力.在遗传算法的搜索过程中融合上述优化方法的思想,构成一种混合遗传算法,是提高遗传算法运行效率和求解质量的一种有效手段^[8,9].

2 模糊自适应模拟退火遗传算法

遗传算法在实际应用中常常出现收敛速度慢和“早熟”等现象,主要是因为早期的优良个体由于适应值大大高于群体的平均适应值,当按比例进行选择时,该个体很快会在群体中占据绝对的比例,而其他个体被淘汰,这样就造成“早熟”现象;同时优化后期由于适应值相近,遗传算子很难选择出优化的个体基因,所以收敛速度慢.遗传算法的交叉率和变异率通过经验选择,较小的交叉率和变异率将导致遗传算法收敛速度慢,而过大的交叉率和变异率又会破坏后期的优良个体,导致收敛速度慢甚至无法收敛.所以需要一个自适应的机制,随着遗传算法的过程来调整交叉率和变异率.

模拟退火算法是一种随机搜索算法.其思想源于金属的退火过程,由高温到低温,遍历整个搜索空间.搜索过程中除了接受优化解以外,还按照Metropolis 准则接受恶化解,因此该算法具有“爬山”的能力,或跳出局部最优解的能力.

近来有研究者将模拟退火算法和遗传算法相结合,提出了遗传退火控制策略^[10,11].但该方法没有将模拟退火算法和遗传算法紧密结合起来,只是机械地融合起来进行控制.尽管如此,这个思路还是很值得研究的,将模拟退火算法和遗传算法紧密结合起来,可以克服各自的不足,发挥各自的优势,从而提高其寻优性能.

模糊控制能够模拟人的决策行为作出正确的输出,如果能够使用模糊控制来指导遗传算法的操作,则可加入人的干预策略,调整遗传算法中的选择、交叉和变异操作,从而改善遗传算法的性能.

基于以上讨论,本文结合模糊控制、模拟退火算法和遗传算法来设计一种改进的遗传算法——模糊自适应模拟退火遗传算法(FASAGA).

2.1 自适应机制

自适应机制可使遗传算法的选择过程以及交叉

率和变异率随着适应度的自动改变而变化.普通的遗传选择按照如下进行:个体 x_i 的适应值为 $f(x_i)$, 其选择概率为 $f(x_i) / \sum_{i=1}^n f(x_i)$. 由前面的分析可知,这种选择方法容易造成“早熟”现象.于是可采用以下方法进行适应值的变换,随着遗传过程的进行改变概率变换 $f(x_i) / \sum_{i=1}^n f(x_i)$ 的灵敏度:

$$f'(x_i) = af(x_i) + \frac{e - e^{\frac{k}{K_{\max}}}}{e + e^{\frac{k}{K_{\max}}}}(f_{\max} - f_{\min}). \quad (1)$$

式中: $f_{\max}$ 为当前最大适应值, $f_{\min}$ 为当前最小适应值, k 为当前遗传代数, $K_{\max}$ 为最大遗传代数, $a > 0$ 为常数.变换以后按照概率 $f'(x_i) / \sum_{i=1}^n f'(x_i)$ 进行选择操作.

由式(1)可以看出,在遗传初期, $\frac{e - e^{\frac{k}{K_{\max}}}}{e + e^{\frac{k}{K_{\max}}}} \approx 1$, 改变了个体适应值之间的相对差异度, $f'(x_i)$ 的选择灵敏度降低,超级个体的选择概率降低,其他个体的选择概率增加,这样便增加了整个种群的多样性;在遗传进行的后期, $\frac{e - e^{\frac{k}{K_{\max}}}}{e + e^{\frac{k}{K_{\max}}}} \approx 0$, $f'(x_i) \approx f(x_i)$, $f'(x_i)$ 选择的灵敏度增加,有利于群体的收敛速度.通过式(1)的变换可以克服选择操作多遗传过程的制约.

2.2 模糊参数自适应

在遗传操作过程中,交叉操作和变异操作的概率也影响着遗传过程的进行.交叉率 P_c 和变异率 P_m 过大或过小都会影响收敛速度和过程.所以 P_c 和 P_m 的选择很重要,最好能够根据遗传算法的进程自动地改变 P_c 和 P_m .

文献[2]中提出按照下式自动改变遗传交叉率 P_c 和变异率 P_m :

$$P_c = \begin{cases} p_{c1}(f_{\max} - f') / (f_{\max} - f_{\text{avg}}), \\ f_{\text{avg}} \leq f', p_{c1} \leq 1; \\ p_{c2}, f_{\text{avg}} > f', p_{c2} \leq 1; \end{cases} \quad (2)$$

$$P_m = \begin{cases} p_{m1}(f_{\max} - f) / (f_{\max} - f_{\text{avg}}), \\ f_{\text{avg}} \leq f, p_{m1} \leq 1; \\ p_{m2}, f_{\text{avg}} > f, p_{m2} \leq 1. \end{cases} \quad (3)$$

式中: $f_{\max}$ 为当前种群最大适应值; f_{avg} 为当前种群平均适应值; f' 为待交叉两个个体适应值中较大者; f 为待变异个体的适应值; p_{c1} , p_{c2} , p_{m1} , p_{m2} 为正的常数.

该算法能够较好地调整 P_c 和 P_m , 克服了固定交叉率和变异率遗传算法的一些不足.在此基础上,很多学者进行了应用研究,并提出了修改算法.但这些算法都存在一个重要不足:虽然这些自适应机制

能够根据个体的不同自动调整交叉率和变异率, 但这些调整只考虑了个体本身的因素, 而没有考虑遗传算法整个过程的全局因素. 当遗传算法个体差异较大且样本多样性较好时, 交叉率 P_c 和变异率 P_m 不需要很大; 而当遗传算法个体多样性较差且个体比较接近时, 就需要较大的交叉率 P_c 和变异率 P_m 来加快遗传过程, 并跳出局部最优. 所以根据遗传算法的全局性来调整交叉率 P_c 和变异率 P_m 显得尤为重要.

遗传算法的进程状况可以使用样本的差异性来简单表示, 即

$$E_1 = \frac{f_{\max} - f_{\text{avg}}}{f_{\max}} \in [0, 1]. \tag{4}$$

因为遗传算法处理不同问题时, 适应值函数是根据具体问题和要求而设计的, 其数值也随具体问题而变化, 所以无法简单的根据 $f_{\max} - f_{\text{avg}}$ 的差值来判断当前遗传算法的进程. 通过式(4) 的变换就增加了算法的通用性. 在遗传开始阶段, 样本的多样性较好, 所以式(4) 的值较大; 而在遗传的后阶段或者当遗传过程陷入局部极值时, 式(4) 的值则较小.

样本个体的差异性可表示为

$$E_2 = \frac{f - f_{\text{avg}}}{f_{\max}} \in [-1, 1]. \tag{5}$$

式(5) 同样通过除以 $f_{\max}$ 将数值转换到 $[-1, 1]$ 区间, 增加了算法的通用性, 便于进行模糊推理.

式(4) 和(5) 中: $f_{\max}$ 为当前种群最大适应值, f_{avg} 为当前种群平均适应值, f 为待操作个体的适应值.

这样便可根据遗传过程信息和样本信息调整遗传算法的交叉率 P_c 和变异率 P_m . 模糊推理正好具有很强的推理分析能力, 因此可根据 E_1 和 E_2 判断遗传过程和样本个体的情况, 然后进行模糊推理以获得交叉率 P_c 和变异率 P_m .

模糊变量 E_1 可以简单划分为 3 个语言集合{大, 中, 小}, 同样模糊变量 E_2 可以划分为 3 个语言集合{正, 零, 负}, 输出的交叉率 P_c 和变异率 P_m 也划分为 3 个语言集合{大, 中, 小}. 如果 E_1 为“大”, 则表明样本多样性较好, 交叉率 P_c 和变异率 P_m 应取“小”; 反之如果 E_1 为“小”, 则交叉率 P_c 和变异率 P_m 应取“大”. 如果 E_2 为“正”, 则说明该个体比较“优秀”, 交叉率 P_c 和变异率 P_m 应取“小”; 反之如果 E_2 为“负”, 则说明该个体较“差”, 交叉率 P_c 和变异率 P_m 应取“大”. 于是基于上述规律可以得到下列模糊推理过程:

若 E_1 是 小 and E_2 是 负, then P_c 和 P_m 是 大;
若 E_1 是 大 and E_2 是 正, then P_c 和 P_m 是 小.

其他规则可以类似推理得到. 总结得到的模糊规则如表 1 所示.

表 1 模糊自适应遗传算子规则表

E_1	E_2		
	负	零	正
小	大	大	中
中	大	中	小
大	中	小	小

从模糊推理中可以看出, 当种群个体适应度趋于一致或趋于局部最优时, 可使交叉率和变异率增加; 而当群体适应值比较分散时, 交叉率和变异率将减小. 同时, 对于适应值高于群体平均适应值的个体, 对应于较低的交叉率和变异率, 使该个体得以保护而进入下一代; 而对于适应值小于群体平均适应值的个体, 则对应于较高的交叉率和变异率, 使得个体得以进化. 因此, 自适应机制的交叉率和变异率可提供给个体对应于优化的交叉率和变异率, 该算法在保持群体多样性的同时, 保证了遗传算法的收敛性.

2.3 模糊自适应模拟退火遗传算法结构

在模拟退火机制和遗传算法的结合中, 是将模拟退火机制结合到遗传算法的交叉算子和遗传算子当中, 而不是单独进行模拟退火处理, 这样不仅改进了遗传算子, 同时保留了遗传算法群体优化和新解产生灵活的特点, 而且增加了模拟退火算法的“爬山”能力. 因此模糊自适应模拟退火遗传算法具有 3 个新的遗传算子:

- 1) 自适应的选择算子: 按照式(1) 修正后的适应值进行概率选择;
- 2) 模糊自适应退火交叉算子: 交叉率由模糊推理产生, 新旧个体利用退火机制选择优化的个体作为下一代的个体;
- 3) 模糊自适应退火变异算子: 变异率由模糊推理产生, 新旧个体利用退火机制选择优化的个体作为下一代的个体.

模糊自适应模拟退火遗传算法的步骤如下:

- Step1: 初始化种群 P 及模糊控制参数, 初始问题 T_0 , 降温参数 T_k .
- Step2: 计算代数 $k = 1$, 初始温度 $T = T_0$.
- Step3: 对种群个体依次进行以下操作:
- 1) 计算个体适应值.
- 2) 进行自适应选择操作, 同时进行最优保留策略, 当前最优的一个个体不参与下面的交叉和变异操作.
- 3) 进行模糊自适应交叉退火操作. 由个体 x_1 和 x_2 交叉产生新个体 x_i 和 x_j , 交叉率由上述模糊推

理获得. 如果 x_i 和 x_j 的适应值分别大于 x_1 和 x_2 的适应值, 则使用新个体 x_i 和 x_j 代替老个体 x_1 和 x_2 . 如果 x_i 和 x_j 的适应值分别小于 x_1 和 x_2 的适应值, 则采用 Boltziman 机制来接受新的个体. 如果 $P_i > \text{random}(0, 1)$, 则使用个体 x_i 代替 x_1 ; 否则不接受 x_i . 如果 $P_j > \text{random}(0, 1)$, 则使用个体 x_j 代替 x_2 ; 否则不接受 x_j . 其中 P_i 和 P_j 按下式计算:

$$P_i = \frac{1}{1 + \exp((f_{x_i} - f_{x_1})/T)},$$
$$P_j = \frac{1}{1 + \exp((f_{x_j} - f_{x_2})/T)}. \tag{6}$$

这里 $f_{x_1}, f_{x_2}, f_{x_i}, f_{x_j}$ 分别为对应个体的适应值.

4) 进行模糊自适应变异退火操作. 由个体 x_1 变异产生新个体 x_k , 变异率由上述模糊推理获得. 如果新个体的适应值 f_{x_k} 大于原来个体的适应值 f_{x_1} , 则使用新个体 x_k 代替老个体 x_1 ; 否则采用 Boltziman 机制来接受新的个体. 如果 $P_k > \text{random}(0, 1)$, 则使用个体 x_k 代替 x_1 ; 否则不接受 x_k . 其中 P_k 按下式计算:

$$P_k = \frac{1}{1 + \exp((f_{x_k} - f_{x_1})/T)}. \tag{7}$$

Step4: 终止条件判断. 如果条件不满足, 则增加代数 $k = k + 1$, 降温 $T = T * (T_k)^k$, 转 Step3; 如果条件满足, 则获得最优解, 算法结束.

3 模糊自适应模拟退火遗传算法早熟改善分析

Whitley^[14] 认为, GA 中最重要的两个因素就是“种群多样性”和“选择压力”, 而选择压力过大是导致“早熟”收敛的一个重要原因. 过大的选择压力虽然可以加快算法的收敛速度, 但会使种群中适应值不利于问题求解的个体迅速“死亡”, 种群的多样性遭到破坏, 使得算法搜索空间减小, 进而导致算法错误地收敛到局部最优值; 而降低选择压力虽然可以增大算法搜索到全局最优值的概率, 但却会降低搜索效率, 使算法的收敛速度变慢. 为使算法具有良好的性能, 必须在提高选择压力和保持种群多样性之间达到某种平衡.

通常使用的 SGA 的选择策略大都采用个体繁殖机会与其适应值成正比例的蒙特卡罗方法, 即对于规模为 N 的遗传种群, 根据 SGA 选择算子有

$$f(X_i(n)) / \sum_{i=1}^N f(X_i(n)).$$

根据上式, 若当前解群中存在很少的一个或几个优势个体的复制概率远远大于其他个体, 其繁殖机会很多, 则这类个体将很快占领全部种群, 从而很容易导致超级个体问题. 这便限制了遗传算法的全

局搜索能力.

本文设计的 FASAGA 遗传算法针对此缺陷的成因对遗传算法进行了改进, 因此有效地避免了超级个体以及其他问题导致的“早熟”收敛问题.

为便于分析, 首先作如下定义:

$$PK \triangleq \frac{\text{select_pro}_{\max}}{\text{select_pro}_{\min}}, \tag{8}$$

式中 $\text{select_pro}_{\max}$ 和 $\text{select_pro}_{\min}$ 分别表示种群中适应值最大和最小个体的复制概率.

由式(8)进一步有, 在 SGA 中

$$PK = \frac{f_{\max}(n)}{f_{\min}(n)}. \tag{9}$$

式(9)表明, PK 的取值大小实际上给出了优化过程中种群内部不同个体作为母体在蒙特卡罗意义上被复制到下一代的概率大小差异的上界. 如下分析所示, PK 对于优化过程有着显著和重要的影响. 下面分两种情况详细讨论.

- 1) 当 $f_{\min}(n) \xrightarrow{n \uparrow} f_{\max}(n)$ 时, 有 $PK(n) \xrightarrow{n \uparrow} 1$. 此时所有个体都具有极为相近的适应度, 由此导致所有概率都有几乎一致的复制概率. 这样, 选择算子趋于被屏蔽的失效状态, 优化过程退化为纯粹的随机徘徊行为, 使得遗传算法丧失了良好搜索导向的优点.
- 2) 当 $f_{\min} \ll f_{\max}$ 时, 表示种群个体间的适应度和选择概率相差很大, 于是有 $PK \gg 1$ 或 $PK \rightarrow \infty$. 此时仅有极少数优势个体以极大的概率被复制到下一代. 种群在搜索过程初期就快速收敛到某个或某几个优势个体集中, 种群多样性急剧减小, 从而发生过早收敛现象.

文献[12]指出, 遗传种群一旦落入“早熟”集, 则选择杂交算子无法使其逃离“早熟”集, 且杂交算子在搜索过程中存在严重的成熟化效应——它在起搜索作用的同时, 不可避免地使种群多样性渐趋于 0, 从而逐渐减小自己的搜索范围, 引起“早熟”收敛.

而本文的 FASAGA 通过改进遗传算子, 有效地解决了这些问题.

3.1 自适应选择机制对早熟的预防

根据上节 FASAGA 的设计, 有 FASAGA 种群的复制概率

$$\text{FASAGA copy_probi}(n) = \frac{f'(X_i(n))}{\sum_{i=1}^N f'(X_i(n))}.$$

通过适应值的自适应机制, 即使遗传种群中出现超级个体而使得 $f_{\min} \ll f_{\max}$, FASAGA 中的自适应也可使这些个体的复制概率不会过大, 在后代群体中的浓度不会过高, 故有 $PK_{\text{FASAGA}} < PK_{\text{SGA}}$. 由上

述情况1)和2)可知,在FASAGA的优化中,种群在初始阶段不太可能快速收敛到某个或某几个优势个体集,因而能有效地维持种群的多样性.这样上面分析的情况2)就不会出现了.

3.2 模糊自适应机制对于脱离早熟集的作用

如前所述,文献[12]在限定变异概率 $p_m \equiv 0$ 的条件下对交叉算子隔离研究,得出结论:遗传种群一旦落入早熟集,则选择杂交算子无法使其逃离“早熟”集.另外,文献[13]提出了在 $p_m \neq 0$ 时,交叉算子将引起多个相似数字串问题或称封闭问题.而一旦种群中出现这种现象,将会出现情况1),从而难以找到最优解.此时,通过模糊自适应机制将会出现增加 P_c 和 P_m 的推理输出,帮助遗传过程增加新的个体,以跳出当前“早熟”子集.

3.3 模拟退火机制可提高局部搜索能力,避免进入“早熟”

定义1 对于遗传算法形成的种群 $\{X(n); n \geq 0\}$,如果种群的全部元素(属于个体空间 S)相同,则该种群的状态为吸收态.吸收态并不一定就是最优解状态.而在由相同个体构成的群体中,遗传保持静止,因此可将属于非最优解吸收态的个体称为局部优化点.

定义变量 $T = \inf\{k \geq 1; \text{当前种群和吸收态交集非空}\}$ 为FASAGA进入吸收态的首达时间.

由文献[15]知,种群进入吸收态的期望时间 $E(T) \leq 1/\alpha^2$, (10) 其中 $\alpha(0 < \alpha < 1)$ 为当前种群进入吸收态的最小时间, α 正比于当前种群进入吸收态的概率.

对于标准简单遗传算法SGA而言,针对遗传种群 $X(n)$,设 q 表示当前种群与相同规模的吸收态种群的不同等位基因的数目,则该种群进入吸收态的概率下界为

$$\alpha_{m-SGA} = p_m^q (1 - p_m)^{Nl-q}. \tag{11}$$

对于本文的FASAGA而言 $\alpha_{m-FASAGA} = p_m^q (1 - p_m)^{Nl-q} a_{ij}^{Nl}, \tag{12}$ 其中 $\alpha_{ij}(0 \leq \alpha_{ij} \leq 1)$ 为模拟退火接受概率.因此模拟退火 Boltzmann 接受机制的加入,使得 $\alpha_{m-FASAGA} \leq \alpha_{m-SGA}$.这样FASAGA遗传算法进入局部最优吸收态的概率比简单遗传算法小,从而增强了选择优化解、跳出局部最优优点的能力.

通过模拟退火算法 Boltzmann 机制来接受子代,不但有利于优良个体的保留,同时也防止了“早熟”收敛问题的发生.而且随着进化过程的进行,温度逐渐下降,接受劣解的概率也逐渐减小,从而有效地利用了模拟退火算法的“爬山”特性,提高了算法的收敛速度.

4 仿真实验

为验证本文算法的有效性,采用如下函数进行实验仿真:

$$f_1(x,y) = 0.9 \exp\left[-\frac{(x+5)^2 + (y+5)^2}{10}\right] + 0.99996 \exp\left[-\frac{(x-5)^2 + (y-5)^2}{20}\right],$$
$$x,y \in [-10,10]; \tag{13}$$

$$f_2(x,y) = \frac{\sin x}{x} \cdot \frac{\sin y}{y},$$
$$x,y \in [-10,10]; \tag{14}$$

$$f_3(x,y) = (-1) \times (x^2 + 2y^2 - 0.3 \cos(3\pi x) - 0.4 \cos(4\pi y)) + 4, \quad x,y \in [-1,1]. \tag{15}$$

其中函数 f_3 为典型的多峰值函数.

算法参数选择如下:种群个数 $N_m = 50$,个体编码长度16位,初始温度 $T_0 = 500$;降温系数 $T_k = 0.95$,最大遗传代数 $N_{max} = 100$,模糊推理自适应的输入输出变量隶属度函数均采用三角形函数.




图1 f_1 的3种算法平均适应值变化比较




图2 f_2 的3种算法平均适应值变化比较




图3 f_3 的3种算法平均适应值变化比较

表 2 3 种算法相同精度平均遗传代数比较

实验次数	FASAGA 寻优代数				SAGA 寻优代数				AGA 寻优代数			
	1	2	3	4	1	2	3	4	1	2	3	4
f_1	26	28	18	36	45	38	56	62	31	28	45	65
f_2	23	15	18	21	36	51	45	50	45	40	56	60
f_3	20	22	21	23	35	47	64	56	35	31	45	51

表 3 3 种算法相同代数不同函数寻优精度比较

	FASAGA 优化结果	SAGA 优化结果	AGA 优化结果
f_1	0. 999 960 001 818 80	0. 999 824 958 725 53	0. 999 632 453 478 35
f_2	0. 999 995 835 700 36	0. 999 741 253 614 99	0. 999 843 275 483 40
f_3	4. 699 632 746 808 46	4. 611 992 576 775 92	4. 508 722 708 191 05

分别采用本文的 FASAGA 算法、文献[2] 的自适应遗传算法(AGA) 和文献[12] 的模拟退火遗传算法(SAGA) 进行仿真研究对比. 分别以相同遗传代数(固定为 100 代) 和相同精度(精度为 0. 000 1) 作为停止条件. 通过 Matlab 环境编程仿真得到如图 1~ 图 3 和表 2, 表 3 所示的实验结果.

由表 2 可以看出,FASAGA 算法达到相同的寻优精度,平均需要的遗传代数比 SGA 算法少,因此 FASAGA 的寻优速度要比 SAGA 和 SGA 都快. 另外从表 3 可以看出, 经过相同代数的遗传操作, FASAGA 的寻优结果要优于 SAGA 和 SGA 的结果.

5 结 论

本文在分析了模糊控制、遗传算法和模拟退火算法的优缺点的基础上, 提出了一种混合的改进遗传算法——模糊自适应模拟退火遗传算法(FASAGA), 并分析了 FASAGA 对标准遗传算法容易陷入“早熟”和收敛速度慢的改进. 仿真实验表明, 该方法明显提高了标准遗传算法的性能, 克服了标准遗传算法早熟和收敛速度慢的缺点.

参考文献(References)

[1] Srinivas M. Adaptive probabilities of crossover and mutation in genetic algorithms [J]. IEEE Trans on Systems, Man and Cybernetics, 1994, 4(24): 656-667.

[2] Gao Feng, Shen Y, Li L. Optimal design of piezo-electric actuators for plate vibroacoustic control using genetic algorithms with immune diversity [J]. SmartM aterials and Structures Aug 2000 IOP: 485-491.

[3] 杨旭东, 张彤. 遗传算法应用于系统在线辨识研究[J]. 哈尔滨工业大学学报, 2000, 32(1): 102-105. (Yang X D, Zhang T. Genetic algorithm for on-line system identification [J]. J of Harbin Institute of Technology, 2000, 32(1): 102-105.)

[4] Jun, J H, Lee D W, Sim K B. Realization of cooperative and swarm behavior in distributed autonomous robotic systems using artificial immune system[C]. Proc of IEEE SM C° 99. Tokyo, 1999, 4: 614-619.

[5] 戚志东, 朱新坚, 朱伟兴. 基于模糊规则优化的改进模糊遗传算法[J]. 计算机工程与应用, 2003, 39(27): 18-21. (Qi Z D, Zhu X J, Zhu W X. An improved FGA based on the optimization of fuzzy rules [J]. Computer Engineering and Applications, 2003, 39(27): 18-21.)

[6] Herrera F, Lozano M, Verdegay J L. Fuzzy connectives based crossover operators to model genetic algorithms population diversity[J]. Fuzzy Sets and Systems, 1997, 92(1): 21-30.

[7] Yougsu Yun, Mitsuo Gen. Performance analysis of adaptive genetic algorithms with fuzzy logic and heuristics[J]. Fuzzy Optimization and Decision Making, 2003, 2(2): 161-175.

[8] Grefenstette J J. Incorporating problem specific knowledge into genetic algorithm [C]. Genetic Algorithm and Simulated Annealing. Pitman, 1987: 42-60.

[9] Orvosh D, Davis L. Using a genetic algorithm to optimize problem with feasibility constraints [C]. Proc of 1st IEEE Conf on Evolutionary Computation. Orlando, 1994: 548-553.

[10] 谢经明, 徐小凤, 陈冰, 等. 基于模拟退火遗传算法的电动汽车网络优化调度[J]. 中国机械工程, 2007, 8(14): 1697-1700. (Xie J M, Xu X F, Chen B, et al. Optimized scheduling of electrical vehicle network based on genetic simulated[J]. China Mechanical Engineering, 2007, 8(14): 1697-1700.)

(下转第 853 页)

6 结 论

本文利用与人耳听觉感知特点相符合的听觉感知小波包变换对含噪语音信号进行分解, 并利用能够更好跟踪小波包系数分布的语音存在概率调节去噪阈值, 再通过软阈值处理和小波包逆变换获得增强后的语音, 实现了一种改进的时间自适应阈值的小波包语音增强方法. 实验结果表明, 与传统的小波包去噪方法和基于 TEO 的语音增强方法相比, 本文所提出的算法能够更好地抑制噪声, 以恢复更多的有效语音信息. 因此, 将该算法置于语音识别系统的前端, 有利于语音识别系统更好地提取语音信号的特征参数, 进而提高识别系统的抗噪性.

参考文献(References)

[1] Donoho D, Johnstone I M. Ideal spatial adaptation by wavelet shrinkage[J]. Biometrika, 1994, 81(3): 425-455.

[2] Johnstone I M, Silverman B W. Wavelet threshold estimators for data with correlated noise[J]. J of the Royal Statistical Society, 1997, 59(2): 319-351.

[3] Chen S H, Wang J F. Speech enhancement using perceptual wavelet packet decomposition and teager energy operator[J]. J of VLSI Signal Processing, 2004, 36(2/3): 125-139.

[4] 成礼智, 郭汉伟. 小波与离散变换理论及工程实践[M]. 北京: 清华大学出版社, 2005.

(Cheng L Z, Guo H W. Wavelet and discrete transform

theory and application [M]. Beijing: Tsinghua University Press, 2005.)

[5] 彭玉华. 小波变换与工程应用[M]. 北京: 科学出版社, 1999.

(Peng Y H. Wavelet transform and engineering application[M]. Beijing: Science Press, 1999.)

[6] 易克初, 田斌, 付强. 语音信号处理[M]. 北京: 国防工业出版社, 2000.

(Yi K C, Tian B, Fu Q. Speech signal processing[M]. Beijing: National Defence Industry Press, 2000.)

[7] Pinter I. Perceptual wavelet-representation of speech signals and its application to speech enhancement[J]. Computer Speech and Language, 1996, 10(2): 1-22.

[8] Cohen I. Enhancement of speech using bark scaled wavelet packet decomposition [C]. Proc of the 7th European Conf on Speech, Communication and Technology. Aalborg, 2001: 1933-1936.

[9] Sundarrajan R, Philipos C L. A noise-estimation algorithm for highly non-stationary environment [J]. Speech Communication, 2006, 48(2): 220-231.

[10] 陈文钢, 田岚, 姜晓庆, 等. 一种噪声谱快速跟踪的语音增强方法[J]. 山东大学学报, 2006, 36(4): 26-28.

(Chen W G, Tian L, Jiang X Q, et al. A speech enhancement method based on quickly tracking the noise spectrum[J]. J of Shandong University, 2006, 36(4): 26-28.)

(上接第 848 页)

[11] 王雪, 姜爱国, 王晟. 无线传感器网络的改进 GASA 优化设计[J]. 控制理论与应用, 2006, 23(4): 593-596.

(Wang X, Jiang A G, Wang S. Optimal designs of wireless sensor network by adapted GASA[J]. Control Theory and Applications, 2006, 23(4): 593-596.)

[12] Whitley D. The genetic algorithm and selection pressure: Why rank-based allocation reproduction trials is best [C]. Proc of the 3rd Int Conf on Genetic Algorithm. Los Altos: Morgan Kaufmann Publishers, 1989: 116-121.

[13] Yee Leung, Gao Y, Xu Z B. Degree of population diversity—A perspective on premature convergence in genetic algorithms and its Markov chain analysis [J]. IEEE Trans on Neural Network, 1997, 8(5): 1165-1175.

[14] 罗小平. 人工免疫遗传学习算法及其工程应用研究[D]. 杭州: 浙江大学, 2002.

(Luo X P. A study on immune genetic algorithm and its application [D]. Hangzhou: Zhejiang University, 2002.)