

基于遗传算法与模糊控制的建模方法

王海枚* 游志胜

(四川大学计算机系图形图像研究所 成都 610041)

【摘要】从实时系统的需求出发,研究利用遗传算法实现实时模糊控制的新技术,包括规则的形成、前提参数的训练,通过对比不同的训练参数规模,讨论了训练参数规模的大小与模型“泛化”之间的关系。经检验,用遗传算法生成的模糊系统模型输入变量少、规则数目少,并且误差小于多数传统算法生成的模型,整个模型的形成过程时间空间复杂度小、易于控制,且不受经验知识的约束,适用于实时系统。

关键词 遗传算法; 模糊控制; 参数训练; 模型泛化

中图分类号 TP301.6

A New Modeling Method Based on Fuzzy Control Using GA

Wang Haimei You Zhisheng

(Institute of Computer Graphics and Image, Sichuan University Chengdu 610041)

Abstract This article proposed a new technique using Genetic Algorithms to realize Real-time fuzzy control, discussed how to form the rules, to train the parameters, the relation between the training scale and the generalization of the model comparing results of different training scales. The model has less input parameters, less rules, and smaller errors than most of other models. It has advantages in both time and space complexity. It is easy to control, and has no restriction of experience knowledge. This method is applicable to Real-time system applications.

Key words genetic algorithms; fuzzy control; parameter training; generalization ability

模糊控制是一类应用模糊集合理论的控制方法^[1],提出了一种新的机制用于实现基于知识(规则)甚至语义描述的控制规律,而且为非线性控制器提出了一个比较容易的设计方法,尤其是当受控装置(对象或过程)含有不确定性而且很难用常规非线性控制理论处理时,更是有效。因此,模糊控制成为智能控制中一个十分活跃的研究应用领域。然而在实际应用中,被研究对象模型往往十分复杂,大量的模型参数还需要依靠领域专家的经验知识提供,不利于实时系统中的控制与应用。

遗传算法是模拟达尔文生物进化论的自然选择与遗传学机理的计算模型^[1],这是一种新的全局优化搜索算法,其基本特征是利用群体进化,即在求解过程中,通过使种群不断优化,从而找到满意解或最优解。该算法具有简单通用、鲁棒性强的优点,适于并行处理,已经广泛地应用于计算机科学、优化调度、运输问题及组合优化等领域。

将遗传算法用来取代一些传统的算法并用于确定模糊系统的规则、前提参数,为模糊系统建模提供了很好的途径,本文运用这一思想以Box & Jenkins气炉系统作为建模对象^[2],将遗传算法生成

模糊系统模型与以E. Kim为代表的传统方法模型的性能进行比较^[2], 研究了建模过程中训练样本规模大小对模型性能的影响。

1 建模过程研究

1.1 E. Kim的Box & Jenkins气炉模糊模型

Box & Jenkins 气炉系统中输入数据 $u(k)$ 是向气炉内输入燃气的气流速率, 输出数据 $y(k)$ 是气炉向外排出CO₂的浓度。采样间隔为9 s, 样本数为296, 根据 $k=1,2,\dots,296$ 的采样数据建立气炉系统的模糊模型。

E.Kim的实验中所采用的模糊模型是一阶Suegno模型(从给定的输入-输出数据集产生模糊规则), 由 m 个输入变量和 c 条规则组成, 可以表达为:

R^i : 若 x_1 为 $A^i_1(p^i_{11}, p^i_{12})$, x_2 为 $A^i_2(p^i_{21}, p^i_{22})\dots$, x_m 为 $A^i_m(p^i_{m1}, p^i_{m2})$, 则

$$y^i = A^i_0 + A^i_1x_1 + \dots + A^i_mx_m \tag{1}$$

$$\begin{cases} \hat{y} = \frac{\sum_{i=1}^c w^i y^i}{\sum_{i=1}^c w^i} \\ w^i = \min A^i_j(x_j) \end{cases} \tag{2}$$

式(1)是模型的规则, R^i 表示第 i 条规则, A^i_j 是第 i 条规则的第 j 个输入变量的隶属函数, $A^i_j(x) = \exp\{-[(x-p^i_{j1})/p^i_{j2}]^2\}$, 它由两个前提参数(p^i_{j1}, p^i_{j2})确定。式(2)是模型的输出, 其中 w^i 表示当前输入和第 i 条规则的匹配度, 整个模型的输出是各条规则输出的加权和。

1.2 基于遗传算法的新模糊模型

E.Kim的模型共有 $2 \times 6 \times 2 = 24$ 个前提成员参数及 $7 \times 2 = 14$ 共38个模型参数有待确定。本模型使用4个输入, 即 $u(k)$ 、 $u(k-1)$ 、 $y(k-1)$ 、 $y(k-2)$, 两个规则 R^1 和 R^2 , 套用式(1), 得

$$y^1(k) = A^1_0 + A^1_1 u(k) + A^1_2 u(k-1) + A^1_3 y(k-1) + A^1_4 y(k-2) \tag{3}$$

$$y^2(k) = A^2_0 + A^2_1 u(k) + A^2_2 u(k-1) + A^2_3 y(k-1) + A^2_4 y(k-2) \tag{4}$$

前提成员函数 $M^i_j = \exp\{-[(x_j-p^i_{j1})/p^i_{j2}]^2\}$, 共 $2 \times 4 \times 2 = 16$ 个, 因此, 需要由遗传算法确定的参数仅有 $5 \times 2 + 16 = 26$ 个。

1.2.1 将遗传算法引入模糊系统建模的参数训练中

以往参数训练先训练规则参数, 然后训练前提参数, 例如在E.Kim的模型中, 两条规则各自产生的 $y^i(k)$ 就已经非常接近实际测试数据, 但是遗传算法是一种整体求优的算法, 分成两步训练参数也就将参数的取值范围调整截然分开, 可能失去好的解空间组合, 而且不利于体现遗传算法简单、整体性强的优势, 因此, 本文确定一次性利用遗传算法。多次运算证明, 使用两步训练参数得到的全体数据的均方差ME2总是不低于0.2, 而一次性整体训练得到的全体数据的均方差ME1多数都能小于0.2。表1记录了同样条件下100个训练样本得到的模型的全体数据(296个)的均方差, 其中参数的初始取值范围都是(-80, 80)。

表1 一步、两步训练误差对比(ME1 ME2)

规则1		规则2		加权后	
0.498 4	0.295 3	0.236 8	0.250 3	0.165 2	0.249 7
0.336 5	0.219 5	0.462 3	0.363 4	0.208 7	0.296 6
0.161 9	0.142 5	0.204 7	0.201 8	0.128 8	0.194 3

1.2.2 遗传算法目标函数的确定

为了使遗传算法能得到的计算输出最大程度地接近实际输出, 因此两者的均方差要尽量小, 而

遗传算法是求极大值,因此特定本目标函数为训练结果 $\text{train}_y(3, \dots, \text{sam_no})$ 与采样输出 $y(3, \dots, \text{sam_no})$ 的均方差的倒数的极大值, sam_no 表示有效训练样本数,即 $\max(\text{fitness})$ (注:4输入规则得到的前两个输出没有意义)

$$\text{fitness} = 1 / \text{sum}((y - \text{train}_y)^2) / \text{sam_no} \quad (5)$$

1.2.3 遗传算法参数的确定

传统的模糊模型是借鉴操作人员或专家的经验来帮助选择控制器的结构和参数。由于需要确定的参数很多,如6输入、两条规则就需要确定 $7 \times 2 + 2 \times 6 \times 2 = 38$ 个参数,4输入也需要26个参数,而专家的经验也只能起到一个指导作用,很难准确、快捷地确定各项参数,因此还要不断地反复试凑。将遗传算法应用于这个寻优过程,快速而简洁,极大地体现了其优越性。

本文在确定26个参数在遗传算法中取值范围的基本思路是:先在大范围内产生大量种群,经过多次寻优、遗传交叉产生下一代,舍去不可能产生较好目标函数值的解区间,这样反复几次取舍,很快能缩小并找到较好的解区间,整个过程并不需要太多的人工干预。

由于在初步观察实验结果时目标函数值易在不理想值收敛,说明目标函数峰值尖窄,因此交叉概率 P_c 、变异概率 P_m ,种群数目 P_o 都取得较大: $P_c = 0.96$, $P_m = 0.10$, $P_o = 100$ 。

1.3 遗传算法的一点改进

编码:由于模糊控制系统的问题计算规模一般都比较,如果对种群再进行二进制编码,试验结果的产生速度不理想。因此,本文采用十进制编码,其中种群个体发生变异的算法是在随机指定的数位上产生随机变化。

种群的适应度:由于在试验过程中发现目标函数值非常容易在并不理想的结果处收敛,其原因是由于初始种群中没有携带某种“优良特征值”的个体存在,即使经过多次交叉变异,目标函数值始终在很低的水平,直到收敛。为了解决这一问题,除了采取提高种群个体规模以及交叉变异的概率以外,还应用动态调整种群适应度的策略^[2],即

$$f' = \begin{cases} kf & f < kf \\ f & \text{else} \end{cases}$$

式中 $k > 1$,当某个体适配值太大的时候, k 修正因子起到降低其影响的作用,以防过早收敛,即起到了扩大搜索空间的作用。按照模式理论,随着遗传算法的逐代演化,平均适配值越来越大,问题将逐渐朝着优化的方向发展。

2 利用Scilab软件编程建立Box & Jenkins 气炉系统的模型

2.1 模型的范化能力与训练样本规模的确定

由模型的“范化”理论,过小的训练样本不能捕捉到系统的整体特征,而训练样本数过大时,尽管训练的样本误差很小,但生成的系统同样不能很好地拟合实际的系统。本文分别对样本数为70、100、120、150所生成的模型的范化能力进行了对比,其训练均方差和实际均方差分别为

$$e = \text{sum}((y - \text{train}_y)^2) / \text{sam_no} \quad (6)$$

$$e_c = \text{sum}((y - \text{res}_y)^2) / \text{total_no} \quad (7)$$

式中 $\text{sam_no} = 118$ 为有效训练样本数; $\text{total_no} = 294$ 为总的有效测试样本数; res_y 是最终模型输出结果; $\text{train}_y = \text{res}_y(1:120)$ 是训练样本输出结果。

当样本数为70时, e 和 e_c 的变化趋势很不一致,即使训练时的均方差 e 很理想,而当系统去拟合实际系统时误差却很大,说明此时模型的范化能力不好;样本数为100时, e 和 e_c 的变化幅度稍有出入;样本数为120时, e 、 e_c 的变化趋势和幅度基本一致,此时模型的范化能力非常理想;当样本数为150时, e 、 e_c 的变化趋势相差较大,虽然训练误差减小了,可是实际误差没有减小反而增加了,

说明训练样本数偏大, 模型泛化能力有所下降。根据以上分析结果, 故确定样本数为120。

2.2 确定的训练样本规模下由遗传算法得到的模糊控制模型

由式(6)、(7), 运行Scilab软件编程使用改进后的遗传算法得到规则 R^1 和 R^2 分别为

$$y^1(k) = -4.157\ 804 + 0.857\ 090u(k) - 0.955\ 788u(k-1) + 1.292\ 390y(k-1) - 0.194\ 001y(k-2)$$

$$y^2(k) = 0.568\ 744 + 0.276\ 121u(k) - 0.598\ 744u(k-1) + 1.265\ 796y(k-1) - 0.285\ 485y(k-2)$$

模型的前提参数如表2所示。

表2 前提参数

	P_{11}	P_{12}	P_{21}	P_{22}	P_{31}	P_{32}	P_{41}	P_{42}
R^1	-1.058 268	2.009 998	-0.110 357	3.876 038	55.044 210	2.313 053	51.645 810	1.928 707
R^2	0.338 909	1.588 735	0.055 234	2.426 071	53.427 546	1.870 583	54.584 177	1.987 502

图1是由基于遗传算法生成的模糊系统模型的计算输出曲线与实际采样输出数据曲线对比图, 从图中可以看出, 缺陷在于波峰、波谷误差值较大, 具体输出数据在此略去。图2是计算输出与实际采样输出数据的误差曲线, 从图中可以看出, 绝对误差值基本上在0.6以内。




图1 结果对比曲线




图2 误差曲线

3 结束语

模糊控制以其很强的自适应功能和对非线性系统映射的优势, 从理论和实践上都有了较大的进展, 本文将遗传算法(GA)与模糊控制系统建模相结合, 由遗传算法通过在多代种群的多个体中整体寻优, 可以不受经验知识多寡的约束, 从大范围的参数解空间入手, 通过观察目标函数达到理想化的趋势, 逐步缩小解空间范围, 寻求理想的模型控制参数。

培训参数的样本规模直接对模型的“泛化”能力有影响, 并非训练样本越大, 所形成的模型就越接近实际系统。特别对非线性系统, 尽管样本规模具有太小就不能捕捉到实际系统的特征, 但如果超出了适当的范围, 模型可能将训练样本的噪声特征当作系统本身的特征记录下来, 对于训练样本以外的数据, 模型就不能给出适当的模拟输出。

参 考 文 献

- 1 孙增圻, 张再兴, 邓志东. 智能控制理论与技术. 北京: 清华大学出版社, 1997
- 2 Kim E, Park M, Ji S, *et al.* A new fuzzy approach to fuzzy modeling. IEEE Transactions on Fuzzy Systems, 1999, 5(3): 328-340