

ECR 源控制用的网络模型

杨化中 韩雪梅 张 宇 姚泽恩

(兰州大学 兰州 730000)

摘要 在研究 ECR 源智能控制的理论模型时,对几种模型进行理论探讨,编程并做仿真实验,对其结果进行了分析。着重对模糊 modular 神经网络(即组合网络)进行描述,分析该模型的优缺点,并在实验中对仿真计算结果随学习次数、规则条数和学习率之间的变化关系进行了深入研究。

关键词 电子回旋共振离子源,模糊神经网络,智能控制

中图分类号 O571

微波放电技术现已是气体放电物理和技术研究中的新领域。它具有以下的放电特性:等离子体密度高(10^{11} — $10^{13}/\text{cm}^3$);电离度高($>10\%$);运行气压低(1 — 10^{-3}Pa);可形成大体积均匀的等离子体;无电极、高活性、易形成多电荷离子和负离子,可稳定运行,设备简单,效率高,参数易于控制,引出束流强等。

由于电子回旋共振(ECR)源具有上述特点,ECR 放电等离子体在许多等离子体应用中具有很大优势。因为 ECR 离子源可以引出很强的离子流,所以把它用于强流中子发生器中,以引出很强的离子流,来提高中子发生器的中子产额。

ECR 离子源的参数很多,有的是固定的,不随引出束流变化;有的参数是可改变的,引出束流可随参数的变化而改变。我们着重研究与引出束流有关的五个参数:微波功率、磁场电流、引出电压、抑制电压和动真空。其中每个参数的变化,都会直接影响引出束流的改变。以前 ECR 源的控制是由人工来完成的,因此实现对它的智能控制非常必要,而且这种智能控制的应用领域非常广泛。通过对 ECR 源智能控制模型的研究,可以找出对高频离子源和双等离子源及强流中子发生器智能控制的理论模型和方法。

1 ECR 源智能控制的理论模型

在对 ECR 离子源智能控制的理论模型研究中,我们曾采用过几种模型,即人工神经网络、改进的模糊神经网络^[1]和组合网络^[2]等。人工神经网络主要应用了 BP 网络,它采用反向传播法、半线性前馈网络、误差反向传播及推广的 δ 规则等方法。它

们存在以下不足:其一,输入人工神经网络的数据必须在 $[0, 1]$ 或 $[-1, 1]$ 之间,这对多参数归一比较麻烦。其二,计算过程比较长,计算结果随学习次数的增加而逐渐增大,达到平衡点时依然增大,然后出现振荡。其三,也是最重要的一点,当学习完成后,根据学习的结果对 ECR 离子源进行智能控制时,它计算不出理想的结果以实现智能控制。

改进的模糊神经网络模型^[1]虽可以使误差变得非常小,但学习时间长,计算结果随学习次数增加而逐渐增大,可以达到所要求的误差点,它增加的速度与规则条件、学习率等因素有关,有时参数(规则条数和学习率等)不合理时,会出现振荡。当输入参数处理不当时,会出现混乱现象。把学习结果用在 ECR 源的智能控制时,会出现需要再学习的过程,使智能控制达不到理想的效果。因此我们采用了模糊 Modular 神经网络(即组合网络)模型^[1],得到了理想的效果。下面对此模型进行详细的讨论,以便应用到高频离子源、双等离子源及中子发生器的智能控制中。

模糊 Modular 神经网络的结构如图 1 所示。




图 1 Modular 网络结构图

Fig.1 Structure of a modular network

国家自然科学基金(19975024)资助项目

第一作者:杨化中,男,1942年2月出生,1965年毕业于兰州大学,实验核物理专业,教授

收稿日期:2004-03-02,修回日期:2004-06-10

该系统由两类网络组成,即专家网络和门网络。系统训练采用混合学习算法,即门网络学习采用无教师 FCM 算法,而专家网络的训练采用有教师的 LMS 算法,以提高系统的收敛性能,同时模糊神经网络所对应的模糊系统是一个全局逼近器。

下面就组合网络的两个网络系统分别叙述。

1.1 门网络

门网络的结构如图 2 所示。




图 2 门网络结构图

Fig.2 Structure of a gate network

它给出每条规则对输入样本 X 的适应程度。其中 n 为输入样本维数, N 为输入样本数, m 为规则条数。 $Z_j = [Z_{1j}, Z_{2j}, \dots, Z_{nj}]$ 为第 j 条规则输入空间的中心向量。

模糊系统的输出为：

$$Y = \sum_{j=1}^m g_j y_j \quad (1)$$

其中
$$y_j = \prod_{i=1}^n u_{ij} \quad (2)$$

其中
$$u_{ij} = \exp[-(x_i - z_{ij})^2 / b_{ij}^2] \quad (3)$$

$$0 \leq g_j \leq 1 \text{ 且 } \sum_{j=1}^m g_j = 1 \quad (4)$$

$$g_j(k) = d_j(k) / \sum_{l=1}^m h_l(k) \quad (5)$$

$$h_j(k) = u_j(k) = 1 / \left[\sum_{l=1}^m \left(\frac{d_l(k)}{d_j(k)} \right)^{\frac{2}{\lambda-1}} \right] \quad (6)$$

$$[d_j(k)]^2 = \sum_{i=1}^n [d_{ij}(k)]^2 \quad (7)$$

$$[d_{ij}(k)]^2 = [x_i(k) - z_{ij}]^2 \quad (8)$$

其中 $i=1, 2, \dots, n$ $j=1, 2, \dots, m$ $l=1, 2, \dots, m$; $k=1, 2, \dots, N$ 。

1.2 专家网络

专家网络系统如图 3 所示,它采用了一个单层神经网络,用来表示模糊规则结论部函数。




图 3 第 L 条规则对应的专家网络

Fig.3 The L rule corresponding to expert network

设外部输入 $X = [1, x_1, x_2, \dots, x_n]$, 输出表示第 j 个专家网络对输入样本的运算结果：

$$y_j = X^T b_j \quad (j=1, 2, \dots, m) \quad (9)$$

其中 $b_j = (b_{0j}, b_{1j}, b_{2j}, \dots, b_{nj})$ 表示权值。在训练过程中定义误差函数

$$E = \frac{1}{2} [y(k) - y^*(k)]^2 \quad (10)$$

其中, $y(k)$ 是模糊输出值, $y^*(k)$ 是期望值。

采用 LMS 算法对专家网络中的权值 b_j 的训练按下式进行。

$$b_j(k+1) - b_j(k) = -\eta [y(k) - y^*(k)] [X(k) / (X^T(k) X(k))] g_j \quad (11)$$

2 智能控制理论的仿真实验及结果分析

用模糊 Modular 神经网络对 ECR 源进行智能仿真研究,是在取得大量 ECR 源的实验数据的基础上,对实验数据进行分析,在不影响实际控制的条件下,对实验数据进行必要的处理,以满足模糊 Modular 神经网络模型的需要,然后采用减法聚类^[2]的方法,找到适合于此模型的规则条数 m_0 。用减法聚类法找规则条数,是在多维空间进行的,它找出的规则条数是一个范围,因此根据实际仿真实验来确定比较好。

影响 ECR 离子源引出束流大小的参变量有 5 个,分别为:微波功率(微波功率的实际测量参数为磁控管的阳极电流, mA)、磁场电流(A)、引出电压(kV)、抑制电压(kV)和动真空(Pa)。表 1 的实验数据的实验条件为:本底真空 1×10^{-4} Pa, 减速电压为 -3 kV, 法拉第筒电位为 25 V, 引出孔直径为 6 mm, 极间距离为 7 mm, 引出离子为 $H(H^+, H_2^+, H_3^+)$ 。

从表 1 可以看出引出束流与 5 个参数之间的关系,用模糊 Modular 神经网络模型计算的束流也列

在此表中。在仿真计算过程中，条件为 $m=4$ ， $\eta=0.1$ ，循环次数为 10^5 。其结果与实际测量的引出束流之间的偏差是比较大的，最大的偏差为 5.0 mA，一般都在 ± 3.0 mA 之间，平均偏差为 1.40 mA。其他模型计算的引出束流的偏差很小，还可使要求的误差范围做得更小。表 1 列出了实际引出束流与模型计算束流之间的差异，此差异与模型有关，还与数据的实验精度有关，实验误差大的，

偏差就大。如表 1 中序号为 12、34 和 40 的引出束流都是 63.5 mA，其他都大概同值，只有它们的微波功率分别为 145、125 和 125 mA，这就导致 12 号的计算结果偏大，这样的现象在表中不少。尤其是第 15 号的计算值与测量值相差 5 mA，这与实验状态有很大关系。还有其他的几个点也存在此问题，只是没有那么明显。

表 1 ECR 源引出束流与计算值比较

Table 1 Comparison of the computed current with the extracted current for ECR source

序号 Number	微波功率 Microwave power / mA	磁场电流 Magnetic field current / A	引出电压 Extracted voltage / kV	抑制电压 Restraining voltage / kV	动真空 Changing vacuum / $\times 10^{-3}$ Pa	引出束流 Extracted current / mA	计算束流 Computed current / mA	误差 Error
1	125	3.0	20	3.00	3.1	58.0	58.0	0.0
2	75	2.5	16	3.00	2.4	43.0	43.6	-0.6
3	125	4.0	20	3.00	3.1	64.0	61.9	2.1
4	125	2.3	16	3.00	2.3	47.5	49.0	-1.5
5	75	2.0	18	3.00	2.4	47.0	46.6	0.4
6	100	1.0	18	3.00	2.2	52.0	52.9	-0.9
7	125	2.0	18	3.00	2.2	53.0	50.6	2.4
8	145	3.0	18	3.00	2.3	54.0	54.1	-0.1
9	125	6.0	20	3.00	3.1	54.0	52.9	1.1
10	100	3.0	20	3.00	2.3	52.0	49.1	2.9
11	125	4.0	20	3.00	2.7	61.0	63.1	2.1
12	145	4.0	20	3.00	3.0	63.5	66.5	-3.0
13	125	4.0	20	3.00	3.1	64.0	61.8	2.2
14	160	4.0	22	3.00	3.1	76.0	76.4	-0.4
15	125	2.5	20	3.00	3.1	48.0	53.0	-5.0
16	50	3.5	16	3.00	2.8	38.0	37.8	0.2
17	160	4.5	22	3.18	3.0	77.0	75.1	1.9
18	100	2.3	16	3.00	2.4	46.0	45.9	0.1
19	125	5.0	20	3.00	3.1	60.0	58.9	1.1
20	75	3.0	20	3.00	2.4	47.5	48.0	-0.5
21	125	7.0	20	3.00	3.1	47.0	48.7	-1.7
22	120	4.0	20	3.00	2.9	58.0	61.0	-3.0
23	125	4.0	20	3.00	2.6	59.0	61.2	-2.2
24	125	4.0	20	3.00	2.8	63.0	60.4	2.6
25	140	4.0	22	3.00	3.1	73.5	73.2	0.3
26	160	4.5	22	3.52	3.0	78.0	77.7	0.3
27	125	4.0	20	3.00	3.2	60.0	61.5	-1.5
28	160	4.5	22	3.00	3.0	76.5	74.9	1.6
29	125	3.5	20	3.00	3.1	62.0	61.3	0.7
30	75	2.0	18	3.34	2.4	47.0	46.7	0.3
31	160	4.5	22	3.00	3.0	77.5	77.6	-0.1
32	140	3.0	18	3.00	2.3	54.0	53.3	0.7
33	50	3.5	16	3.00	2.8	38.0	37.8	0.2
34	125	4.0	20	3.00	3.0	63.5	61.3	2.2
35	75	3.0	20	3.00	2.4	47.5	47.9	-0.4
36	120	4.0	20	3.00	2.9	58.0	60.9	-2.9
37	160	4.0	22	3.00	3.1	76.0	77.7	-1.7
38	125	2.0	18	3.00	2.2	53.0	50.8	2.2
39	100	2.3	16	3.00	2.4	46.0	46.6	-0.6
40	125	4.0	20	3.00	3.0	63.5	61.0	2.5

$m=4$, $\eta=0.1$, Times= 10^5

2.1 学习次数对计算结果的影响

表 2 列出实测引出束流为 77 mA 时, 模型计算结果随学习次数的增加而呈现出的变化规律。从表 2 可看出, 学习次数在 $1-10^5$ 之间变化时, 计算束流在 75.5—77.2 mA 之间变化, 无规律可寻, 也没有出现振荡。束流最小的是第一次和最末一次, 而最大的则是第 2 和第 3 次。从其他几十组数据的学习结果看, 也有上面的特点, 即第一次学习就可以使束流值达到实际值附近, 每次的学习结果与实际引出束流相差很小, 也不存在实际束流值上下振荡的现象, 这是模糊 Modular 神经网络模型的最重要的特点, 正因为如此, 我们把它应用在 ECR 源的智能控制中, 并取得了满意的仿真实验结果。因此,

本模型的学习率的确定, 在先确定规则条数的情况下, 再通过仿真实验定出学习率来。

2.2 规则条数和学习率对计算结果的影响

从前面的分析可以看出, 模糊 Modular 神经网络模型的计算结果与实际值之间的偏差较大, 但它们在学习过程中第 1 次学习就可以达到实际束流值附近, 其达到的程度与规则条数和学习率的大小有关。我们对表 1 的实验数据的 5 个参数和 40 组数据进行适当处理后, 用减法聚类法计算规则条数 m 。从计算结果看, $m=1、2、3、4、5$ 等都有可能聚类, 但它们的聚类程度有所差异。究竟 m 取多少, 由仿真实验来确定。在仿真计算中取 $m=2、3、4、5$ 四

表 2 束流为 77mA 时学习循环次数与计算结果的比较

Table 2 The computed extracted currents for different numbers of times of learning cycle (mA)

次数 Number of times	1	2	3	4	5	6	7	8
结果 Compute current	75.5	77.2	77.2	77.1	77.1	77.1	77.0	77.0
次数 Number of times	9	10	20	30	40	50	100	250
结果 Compute current	76.9	76.9	76.6	76.4	76.2	77.0	76.9	76.7
次数 Number of times	500	750	1000	2000	3000	4000	5000	10000
结果 Compute current	76.8	76.6	76.7	76.6	76.9	76.8	76.8	75.5

* $m=4$, $\eta=0.2$

表 3 规则条数和学习率对理论计算结果的影响

Table 3 Effects of rule number and learning rate on the computed extracted current

规则条数 m	学习率 η	计算结果 Computed current / mA								
		54	52	61	63.5	64	76	48	38	77
4	0.4	51.1	48.6	67.0	63.1	67.2	82.6	47.7	38.1	80.6
	0.3	56.7	49.6	66.1	67.0	66.3	81.0	48.9	38.1	78.6
	0.2	54.5	50.8	64.3	69.0	64.5	78.9	50.2	38.0	76.5
	0.1	54.7	50.8	63.6	66.3	63.8	77.7	51.1	37.8	75.4
	0.08	54.6	50.9	63.5	66.4	63.7	77.3	51.3	37.9	75.1
	0.07	54.6	52.1	63.4	68.2	63.1	77.0	51.8	38.0	75.0
	0.05	54.6	51.0	63.3	66.7	63.5	76.5	51.6	37.9	74.8
	0.03	54.6	52.2	63.1	68.2	63.3	75.8	52.4	38.0	74.4
	0.01	54.8	52.1	62.7	68.4	62.9	75.2	52.7	37.9	74.3
	0.4	52.5	50.8	63.1	68.5	63.4	73.9	48.3	40.0	73.8
3	0.3	54.1	50.4	64.3	69.4	64.6	77.9	48.6	38.9	76.2
	0.2	54.5	50.5	64.5	69.2	64.8	79.6	49.9	38.2	76.7
	0.1	54.7	51.4	62.0	64.7	62.0	73.1	51.5	36.9	77.2
	0.05	54.3	51.3	63.4	68.1	63.4	76.6	52.3	37.8	74.6
	0.5	30.4	47.1	42.9	49.6	42.9	73.3	49.7	32.5	67.8
	0.4	49.2	48.8	57.8	61.3	57.8	78.5	55.3	39.7	73.8
	0.3	56.0	48.4	61.9	65.2	61.9	79.8	55.8	39.9	75.7
	0.2	57.5	48.1	62.4	65.9	62.4	79.6	55.7	39.3	75.4
	0.1	57.2	48.2	61.8	65.3	61.9	78.6	55.5	38.7	74.4
	0.08	57.2	48.2	61.7	65.2	61.8	78.3	55.5	38.7	74.1
2	0.05	57.2	48.3	61.6	65.2	61.6	77.4	55.4	38.6	73.7
	0.03	57.3	48.2	61.5	65.4	61.6	76.3	55.3	38.7	73.3
	0.01	54.6	48.3	61.4	65.7	61.4	73.9	55.2	38.7	72.6

* Times = 10^5

种情况,但 $m=5$ 的结果不太理想,问题较多。所以在表 3 中只列出了 $m=2、3、4$ 三种结果的束流计算值。从表 3 可以看出,计算束流不仅受 m 的影响,而且同时又受到学习率 η 大小的影响。表中第一行为实际测量的引出束流,其他为模型计算的束流。由表可见,不同的规则条数和学习率的搭配,其计算的结果有所不同。当 m 一定时,选择合适的学习率,每个实验值和计算值之间可以找到偏差最小的学习率来。总的来说,在表 3 中, $m=4$ 比 $m=2,3$ 模型计算束流与实际测量值的偏差要小些,但对每个实际测量值来说,还是有较大的差别。如 48 mA 和 63.5 mA 两个值不管在 m 等于那一种条件下,计算值都与实际值相差较大,这可能是实验值测量不精确所致。因此,在实际应用时,可根据情况选择 m 和 η ,这一点对智能控制来说是非常重要的。

3 结论

通过前面的讨论,在我们选择的几种模型中,模糊 Modular 神经网络的模型计算束流与实际测量束流值之间存在一些偏差,但通过改变规则条数 m 和学习率 η 可使差别减少。它的主要优点是模型计

算束流一次学习就可以接近实际测量值,并随着学习次数的增加,计算束流在实际测量值上下变化,不出现振荡现象,这对智能控制有很大的好处。因此,在对 ECR 离子源的智能控制研究中,我们采用模糊 Modular 神经网络模型,在仿真实验中,取得了满意的结果。

致谢 姚伟同志参加了早期工作,在此表示感谢。

参考文献

- 1 王士同. 神经模糊系统及其应用. 北京: 北京航空航天大学出版社, 1998. 183—186, 229—232
WANG Shitong. Neural-Fuzzy system and its application. Beijing: Beijing Aviation and Spaceflight University Press. 1998. 183—186, 229—232
- 2 张智星, 孙春在, 水谷英二, 等译. 神经—模糊和软计算. 西安: 西安交通大学出版社, 2000. 308—309
ZHANG Zhixing, SUN Chunzai, Mizuya, *et al.* Neural-fuzzy and soft computing. Xi'an: Xi'an Jiaotong University Press, 2000. 308—309

Network models for controlling ECR source

YANG Huazhong HAN Xuemei ZHANG Yu YAO Ze'en

(University of Lanzhou, Lanzhou 730000)

Abstract Various theoretical models of intelligentized control for ECR source were reviewed. Program compilation, simulation experiments and analysis of experiment results for some theoretical models were described, with emphasis on theoretical model of fuzzy-neural modular network (combinatorial network). The merits and demerits of this model was analyzed in the light of simulation experiments of intelligentized control for ECR source. The computed results of simulation experiments are dependent on learning times, rule number and study rate.

Key words ECR source, Fuzzy-neural modular, Intelligentized control

CLC O571