

小脑协调控制的计算机模拟


范思陆

(中国科学院心理研究所, 北京)

在Albus基本模型的基础上, 使用FORTRAN语言建立了与原型具有更强类比关系的小脑计算机模型。初步模拟了小脑协调控制的功能, 并对小脑共济失调进行了病理模拟。该模型具有学习、概括与适应能力, 并具有通过自学达到系统最佳控制精度的能力。这些特征, 对于高维输入输出和缺乏精确数学关系描述的控制问题, 具有应用价值; 同时, 该模型采用的空间变换信息处理方式, 对脑机制的研究方法, 也有一定启发。

在脑结构的相对整体水平上, 实现脑功能的模拟, 是十分困难的; 但它对于揭示“脑谜”, 对于寻找直接干预脑复杂过程的有效途径, 以及对于工程技术应用的前景, 却十分吸引人。

本文小脑模型是在Albus基本模型^[1,2]的基础上建立的。为了定量探讨小脑协调控制的原理及其应用前景, 作者致力于使模型不仅在输入输出上, 而且在结构与工作原理上, 都与小脑原型具有更强的类比关系。最后, 在计算机上检验了模型的生理与病理模拟效果。



(a)

模拟依据的主要特征

小脑与其它脑区相比, 结构比较规则, 功能相对单纯。对此, 近代神经科学已进行了很多研究。Eccles^[3]把小脑看作一台计算机, 提出了小脑实现平滑、精巧、可靠控制的空间与时间模式(图1), 认为建立小脑模型是一项值得进行的工作。Marr^[4]和Albus^[5]分别提出了可供建立模型的小脑功能学说。

1. 小脑信息转换的模拟依据

按照Marr和Albus的小脑功能学说, 蕈苔纤维以不同频率的神经脉冲形式携带频率域的输入信息,

它对大量颗粒细胞产生兴奋性影响, 但由于高尔基细胞的负反馈抑制作用, 以及颗粒层中突触联系的放散-聚集空间分布特征^[3,5], 使得激活的颗粒细胞的数量保持有限而恒定, 不同

本文1985年1月10日收到, 1986年5月修回




图1 (a,b)小脑结构示意图[3]

- | | |
|---------|----------|
| mf 藓苔纤维 | gr 颗粒细胞 |
| cf 攀缘纤维 | Go 高尔基细胞 |
| pf 平行纤维 | pc 梨状细胞 |
| cr 小脑核 | bc 筐状细胞 |
| | sc 星状细胞 |
| | + 兴奋性突触 |
| | - 抑制性突触 |

的输入信息，仅仅造成激活颗粒细胞空间分布的不同。这样，小脑颗粒层就将输入的频率域信息转换成了空间域信息。这种信息转换，不仅提高了小脑对输入的分析能力，而且由于相

似的输入具有部份共同的激活颗粒细胞，还产生了对输入的概括能力。

2. 小脑输出的模拟依据

被激活的颗粒细胞通过平行纤维直接兴奋梨状细胞，同时还通过筐状细胞和星状细胞抑制邻近的梨状细胞。梨状细胞则积累它所接受的兴奋性和抑制性两种突触作用，最后产生小脑皮层的输出。由于平行纤维横贯梨状细胞、筐状细胞和星状细胞的树突树，使得一组输入或一组激活的平行纤维同时作用于突触强度各不相同的、并控制不同肌肉的多个梨状细胞群。因此，有多个梨状细胞群对同一输入产生不同而又互相协调的输出，从而实现不同肌肉共济运动的控制。

3. 小脑工作方式的模拟依据

Albus还认为，平行纤维同梨状细胞、筐状细胞、星状细胞联系的突触强度是具有可塑性的[5]。攀缘纤维携带较高级中枢的协调信息，对梨状细胞产生强去极化作用，引起休止状态；而另一部份没有去极化的梨状细胞则处于释放状态。激活平行纤维引起处于释放状态的梨状细胞放电是正确反应，引起处于休止状态的梨状细胞放电是错误反应。当出现错误反应时，则通过改变相应的突触强度而加以纠正。这样，经过反复地突触强度修改后，一组兴奋的藓苔纤维在没有较高级中枢和攀缘纤维参与时，也能引起与相应攀缘纤维兴奋时一致的梨状细胞反应，而使小脑具有了在藓苔纤维输入下进行协调控制的能力。这个过程被认为是小脑学习、记忆的过程。在这一过程的基础上，小脑通过概括、积累经验、代偿以及对复杂环境的适应，可使控制达到相当高度的精确性和技巧性。

小脑模型的构造

Albus于1975年发表了“小脑模型关节控制器(CMAC)”的理论公式[1,2]，同时指出，在训练技术等方面，探讨得还不够充分。在Albus的进一步工作中[9]，着眼于机器人控制的实际应用，更多地采用多级模型和人工智能技术，来解决复杂控制问题。本文作者发现，对于稍为复杂的控制问题，仅用一级模型，最优训练可能发生收敛困难，并认为，这与小脑学习中的探索过程有关。因此，增加了探索过程的模拟，并获得最优训练的稳定收敛；同时，

在小脑生理与病理过程的模拟方面，进一步提高了一级模型的仿真度。

本文模型是用FORTRAN语言实现的，设向量S为一组兴奋的藓苔纤维的输入，其携带的反馈与指令两部份信息，分别以 S_F 和 S_C 来表示，

$$S = S_F + S_C = (S_1, S_2, \dots, S_N)$$

$$S_F = (S_1, \dots, S_r, 0, \dots, 0)$$

$$S_C = (0, \dots, 0, S_{r+1}, \dots, S_N)$$

设向量P为多个梨状细胞群的输出，

$$P = (P_1, P_2, \dots, P_L)$$

则小脑的输入输出关系可以表达为：

$$P = H(S)$$

H表示小脑的非解析性信息空间变换算法，它是通过 $S \rightarrow A_P$ 编码寻址和权重累加实现的。

$S \rightarrow A_P$ 编码寻址，是对S进行一系列的编码和变换。在变换前，以适当的输入分辨率 ΔS_i 将每个连续变化的 S_i 在1-R整数范围内离散化。然后按图2所示的输入空间，进行 $S \rightarrow M$ 变换：

$$S \rightarrow M = \begin{cases} S_1 \rightarrow m_1^* \\ S_2 \rightarrow m_2^* \\ \vdots \\ S_N \rightarrow m_N^* \end{cases}$$

m_i^* 是一个编码，每个编码的位数都相等，表为 $|m^*|$ 。例如，当二维输入，且 $|m^*| = 4$ 时，若 $S_1 = 3$ ， $S_2 = 6$ ，则 $m_1^* = AFGH$ ， $m_2^* = ejkh$ 。接着， $M \rightarrow A$ 变换分别将 m_i^* 中相同码位上的码按照固定顺序重新合成一个新编码 a_k^* ($k = 1, 2, \dots, |m^*|$)，且

$$A^* = (a_1^*, a_2^*, \dots, a_{|m^*|}^*)$$




图2 S→A转换输入空间编码示意图

编码向量 A^* 模拟一组激活的颗粒细胞。如在上例中， $A^* = (A_c, F_j, G_k, H_h)$ 。两个输入向量间的相似和不同，仅仅表现在这些相应编码的部份相同和不同上。因此， $S \rightarrow A$ 变换模拟了小脑颗粒层的频率域—空间域信息转换功能。

对于N维输入向量，可能输入模式的总数有 R^N 个。通常，这是计算机无法容纳的。因此，还需要进行一次 $A \rightarrow A_P$ 附加变换，即采用散列列表编译技术^[6]，将每个编码 a_k^* 变换成一个容量为 $|A_P|$ 的实际物理存储器中的地址码 A_P ，

$$A_P = [|A_P| (g a_k^*) \bmod 1]$$

$$g = (\sqrt{5} - 1) / 2$$

其中,方括号表示取结果的整数。

从 $|A_P|$ 个地址中选用 $|m^*|$ 个地址的组合数为:

$$\binom{|A_P|}{|m^*|} = \binom{V|m^*|}{|m^*|} \quad V = |A_P| / |m^*|$$

不难证明,

$$\binom{V|m^*|}{|m^*|} > (V-1)^{|m^*|}$$

因此,只要满足

$$(V-1)^{|m^*|} \geq R^N$$

便可保证输入变换的唯一性。在保证唯一性的条件下,选择计算机上可行的 $|A_P|$ 大小,是很容易做到的。仅仅需要注意,在确定 $|A_P|$ 时,要兼顾训练的收敛性和对模型分析概括能力的要求。因为它们与编码向量 A^* 的邻域大小与形状,以及与输入的平滑性,即与 V 、 ΔS_i 有关。

此外,上式还表明,当输入向量的维数 N 增加时,只需调整 V 即可。它既不改变模型的基本结构与运算,也不会对 $|A_P|$ 大小产生过高的要求。因此,这种算法很容易适应高维输入,而解析性算法则常常难于做到这一点。

完成 $S \rightarrow A_P$ 编码寻址后,就可以对存储器进行权重 w_{jk} 的存取。与 S 相应的权重向量为

$$W_j = (w_{j1}, w_{j2}, \dots, w_{j|m^*|}) \quad j = 1, 2, \dots, L$$

j 表示与 P_j 相应的不同的权重存储器。权重 w_{jk} 是对突触强度的模拟, $w_{jk} > 0$ 表示兴奋性突触强度, $w_{jk} < 0$ 表示抑制性突触强度。最后,计算模型的输出,

$$P_j = h_j(S) = \sum_{k=1}^{|m^*|} w_{jk}$$

$$j = 1, 2, \dots, L$$

上式是对梨状细胞累积效应的模拟。

模型只有贮存适当的权重后,才能输出有意义的控制信息。这要通过示教训练来完成。示教系指从模型外为模型提供理想的协调控制输出 \hat{P} ,

$$\hat{P} = (\hat{P}_1, \hat{P}_2, \dots, \hat{P}_L)$$

它相当于攀缘纤维所携带的较高级中枢的协调信息。然后,按照一定精度要求 ε_i , 使用迭代误差修正法,对模型进行如下的训练:若

$$|\hat{P}_i - P_i| > \varepsilon_i$$

则与 S 相应的每个权重都加 Δ_i ,

$$\Delta_i = \frac{\hat{P}_i - P_i}{|m^*|}$$

否则,不改变权重。经过这样的反复训练后,模型就如同小脑不需要较高级中枢的照顾一样,不再需要示教输出,而能独立给出与 \hat{P} 相似的输出 P , 获得了粗糙的独立协调控制能力,并对相似的输入,具有了一定的概括适应能力。

在示教训练的基础上，模型通过独立地反复控制操作，进行自我最优训练。设被控手臂端点要到达的空间座标为 x, y, z ，将其做为指令输入，

$$S_c = (0, \dots, 0, x, y, z)$$

$$S = (S_1, \dots, S_r, x, y, z)$$

当相应输出 P 控制手臂端点到达的实际座标为 $\hat{x}, \hat{y}, \hat{z}$ 时，模型重建一个假想的输入向量 \hat{S} ，

$$\hat{S} = (S_1, S_2, \dots, S_r, \hat{x}, \hat{y}, \hat{z})$$

其相应输出为 P' ，它不被送给被控制手臂，而以 P 为理想输出，按照上述示教训练的方法修改权重。修改后，进行试探性检验，如果与 S 相应的输出的控制精度提高，则保留对权重的修改，否则恢复原来权重。经过反复最优训练后，模型终将获得精度较高、适应性较强的控制能力。

模型的训练，可以看作是对小脑学习、记忆过程，以及自学习过程的模拟，它不要求事先对输入输出关系给出解析性的精确数学描述。此外，最优训练中的某些过程，与人或高等动物的探索性动作，以及与积累、概括经验等，也很相似。

计算机模拟试验与结果

试验的被控对象为模拟的人体手臂（图 3），该手臂模拟肩关节两个动作和肘关节的一个动作。假定上臂与前臂均 30cm 长。肩关节控制上臂，其抬落角为 $\theta_1 (-\frac{3}{4}\pi \sim \frac{\pi}{2})$ ，内收外展角为 $\theta_3 (-\frac{\pi}{2} \sim \frac{\pi}{2})$ ，不考虑旋臂动作。肘关节控制前臂，屈伸角为 $\theta_2 (0 \sim \pi)$ 。以肩关节为空间座标原点，手臂端点座标为 $x (-50 \sim 50\text{cm})$ ， $y (-40 \sim 60\text{cm})$ ， $z (-50 \sim 50\text{cm})$ 。

t 时刻控制点之前的关节状态为反馈输入，

$$S_F(t) = [\theta_1(t-1), \theta_2(t-1), \theta_3(t-1), 0, 0, 0]$$

手臂端点在 t 时刻应到达的座标为指令输入，

$$S_c(t) = [0, 0, 0, x(t), y(t), z(t)]$$

输入向量为

$$S(t) = [\theta_1(t-1), \theta_2(t-1), \theta_3(t-1), x(t), y(t), z(t)]$$

输入离散化分辨率为

$$\Delta S_i = \begin{cases} 0.0349 & i = 1, 2, 3 \\ 0.5\text{cm} & i = 4, 5, 6 \end{cases}$$

其相应的输出向量为

$$P(t) = [\theta_1(t), \theta_2(t), \theta_3(t)]$$

三个动作的驱动信号为

$$\dot{\theta}_i(t) = \theta_i(t) - \theta_i(t-1)$$




图3 臂部简单协调运动模拟图示

$$j = 1, 2, 3.$$

这里, 模型未直接输出驱动信号, 可以避免反馈输入的误差积累。

控制全程以时间为序, 共分59个控制点。全程控制点都满足精度要求时为收敛。示教训练的精度要求仅为

$$|\hat{P}_i - P| \leq \varepsilon_i$$

最优训练收敛还要以最后控制是否到达指令座标为准, 误差 $<0.5\text{cm}$ 。它等于输入分辨率, 可认为是该系统精度的极限。

手臂端点被控实际到达的座标, 以下式进行模拟计算,

$$\begin{cases} \hat{x}(t) = 30(\cos a + \cos b) \sin c \\ \hat{y}(t) = 30(\cos a + \cos b) \cos c \\ \hat{z}(t) = 30(\sin a + \sin b) \end{cases}$$

$$a = \theta_1(t), \quad b = \theta_1(t) + \theta_2(t), \quad c = \theta_3(t)$$

示教输出 $\hat{P}(t)$ 也通过模拟计算获得,

$$\hat{P}(t) = [\hat{\theta}_1(t), \hat{\theta}_2(t), \hat{\theta}_3(t)]$$

$$\begin{cases} \hat{\theta}_1(t) = \phi - \varphi \\ \hat{\theta}_2(t) = 2\varphi \\ \hat{\theta}_3(t) = \text{tg}^{-1} \frac{x(t)}{y(t)} \end{cases}$$

$$\phi = \sin^{-1} \frac{z(t)}{\sqrt{x^2(t) + y^2(t) + z^2(t)}}$$

$$\varphi = \frac{\pi}{2} - \sin^{-1} \frac{\sqrt{x^2(t) + y^2(t) + z^2(t)}}{60}$$

在实际问题中, 示教本身常常只能是很粗糙的输出。因此, 在计算上式之前, 要先对各点座标附加一个最大值 1.0cm 、平均值 0.625cm 的正负随机误差, 以获得具有一定误差的示教输出。

选择两条差异较大的指令轨迹进行试验。一条是振幅为 30cm 的类正弦空间曲线,

$$\begin{cases} x(t) = t - 29 \\ y(t) = 40\sqrt{1 - \frac{x^2(t)}{30^2}} \\ z(t) = 30\sin\left[\frac{\pi}{29}x(t)\right] \end{cases}$$

$$t = 0, 1, 2, \dots, 58.$$

另一条是半径为 30cm 的空间圆曲线,

$$\begin{cases} x(t) = 30\sin\left(\frac{\pi}{29}t - \frac{\pi}{2}\right) \\ y(t) = 30 \\ z(t) = 30\sin\left(\frac{\pi}{29}t\right) \end{cases}$$

$$t = 0, 1, 2, \dots, 58.$$

为保证最优训练的收敛並提高模型的适应能力, 令上述基本轨迹在 x, y, z 轴上平移, 以进行有限的多条类似轨迹的示教训练, 对可能的输入空间加以覆盖。每一轴向上, 覆盖的最大范围为基本轨迹 $\pm 6.0\text{cm}$ 。最优训练仅对基本轨迹进行。

完成圆轨迹训练后, 破坏存储器局部区域的权重, 或者削减每个权重的绝对值, 用来模拟小脑的病理状态控制, 並与临床病例进行比较。

表 1、表 2 给出了模拟计算的主要结果。

1. 模型对于两种差异较大的轨迹, 都能较快地收敛, 顺利完成示教训练和最优训练。示教训练收敛所需的平均重复次数, 在类正弦轨迹为 27 次, 在圆轨迹为 22 次。最优训练收敛所

表 1 小脑模型对类正弦空间轨迹控制的座标误差

指令轨迹 座标	平均 值(cm)			最 大 值(cm)			$>=0.5\text{cm}$ 的控制点数	
	示教训练后	最优训练后		示教训练后	最优训练后		示教训练后	最优训练后
基本轨迹 X	0.622	0.143		1.134	0.405		39	0
	0.639	0.190		1.260	0.487		39	0
	0.643	0.183		1.139	0.451		38	0
平 移 X	0.681	0.492		2.268	3.122		34	24
	1.693	1.248		12.046	11.236		39	35
	0.561	0.380		1.444	0.828		30	17
平 移 X	0.674	—		3.016	—		34	—
	1.931	—		12.912	—		36	—
	0.562	—		1.567	—		29	—
平 移 X	7.045	0.589		29.000	3.895		46	23
	19.205	1.812		49.785	12.955		58	42
	7.426	0.490		21.264	1.892		50	22
平 移 X	—	0.784		—	4.606		—	27
	—	3.831		—	13.883		—	44
	—	0.988		—	5.020		—	31

注1. 除基本轨迹外, 均为未训练轨迹。

2. 平移系指基本轨迹沿Z轴平移, 并附加最大振幅为 1.0cm 的随机正弦波动。

3. 示教训练项的空白因失控而省略; 最优训练项的空白处于适应范围内, 未做检验。

表 2 小脑模型对空间圆轨迹控制的座标误差

控制条件	平均 值(cm)			最 大 值(cm)			$>=0.5\text{cm}$ 的控制点数		
	X	Y	Z	X	Y	Z	X	Y	Z
示教训练后	0.640	0.656	0.666	1.971	1.080	1.294	38	41	41
最优训练后	0.170	0.174	0.168	0.459	0.390	0.484	0	0	0
破坏7%权重	0.603	4.818	0.379	1.803	9.934	1.706	30	57	15
破坏11%权重	1.474	9.969	1.180	8.441	19.737	3.612	38	58	40
削减权重值 $\pi/1800$	1.674	5.873	1.146	3.916	9.336	2.777	52	58	43
削减权重值 $\pi/1200$	3.423	10.040	2.263	8.536	18.407	4.773	58	58	58

需的平均重复次数,在类正弦轨迹为23次,在圆轨迹为19次。

2.示教训练后,只要指令轨迹处于输入空间的适应范围内,包括从未训练过的轨迹,模型都能以粗糙的精度,完成对手臂端点的协调控制。每一轴向上的适应范围为基本轨迹 ± 5.0 cm,稍小于示教覆盖范围。

3.在示教训练过程中,模型对先前训练过的轨迹的控制能力,可因后来新轨迹的训练而减弱。这意味着,模型不仅有记忆能力,也有“遗忘”现象。因此,处于适应范围中心最后训练的基本轨迹的控制,其精度较高,并可达到示教输出的精度。

4.最优训练后,模型对基本轨迹的控制精度,明显超过示教精度,控制误差低于模型对指令输入的分辨率(0.5cm)。同时,适应范围扩大到整个示教覆盖空间(基本轨迹 ± 6.0 cm),适应范围内的控制精度也普遍提高。

5.将权重存储器任意局部区域的权重置零,造成破坏。当破坏区域占存储器容量(2^{18})的11%时,虽然模型控制精度明显下降,但仍能保持已经获得的基本控制能力。其表现与小脑占位性病变(如小脑肿瘤)时的共济失调症状类似。破坏权重是对小脑局部破坏的病理模拟。这种抗破坏能力(包括下述削减权重的表现),也是对生物抗干扰性或代偿性的模拟。对于一般以严格数学解析法求解的模型(如Licata et al的模型^[7]),这种破坏可能会导致整个模型的瓦解。

6.当削减每个权重的绝对值,使削减量达到 $\pi/1200$ (相当于 0.15°)时,控制轨迹在x-z轴平面上的投影(图4)由正圆变成以不规则折线趋近圆的曲线。该曲线与遗传性小脑共济失调病人所画的“圆”很相似,与神经病学检查中的“画圈试验”阳性相似。削减权重可与小脑细胞广泛性退行性变类比,是对突触强度衰减的病理模拟。

以上结果表明,本文模拟与小脑的协调控制功能,在生理、病理、学习、记忆、概括、以及代偿等主要表现上,都具有一定程度的一致特征。这种一致性,显然依赖于模型与原型在结构与原理上的较强类比性。可以认为,本文模型初步模拟了小脑的协调控制功能。

此外,上述结果还表明:

1.如果激活颗粒细胞的空间随机分布特征和颗粒层的频率域——空间域信息转换功能得到生物学实验的证实,那么,上述模拟提示我们,仅仅观察单个激活颗粒细胞的放电活动或生化效应与外在刺激或反应的联系,就如同孤立地考察单个权重和模型输入输出的关系一样,是难于接触到小脑信息处理的实质的。上述信息处理方式还有可能存在于脑的其它部位^[3,5]。因此,在脑机制研究中,应注意发展适于这种信息处理方式的综合性手段,特别应注意脑机制的空间特征研究。

2.本文模型的工作特性,对于那些具有高维输入输出,缺乏精确数学关系描述的困难控制问题,如对机器人的控制,具有一定的应用价值;也可应用于座标变换、模式识别等方面。在模型的多级网络结构及其应用方面,Aibus进行了大量工作^[8,9]。而本文模型,由于进一步模拟了小脑学习探索过程,可以通过自我训练超过示教能力,并达到系统最佳控制精度,因此,一级模型也可直接成为一个适应性较强的多维实用学习控制系统。

结 论

本文描述了在Aibus基本模型基础上,使用FORTRAN语言建立的小脑计算机模型。它不




图4.控制轨迹在x-z轴平面上投影

.....指令迹轨
 - - - - - 减权重 0.15° 后的模型控制轨迹
 ————一例遗传性小脑共济失调病人所画的圆

也强调了适于脑信息处理特征的脑机制研究方法的重要性。

(本文前期工作在航天医学工程研究所梅磊教授指导下进行。整个工作过程中, 得到中国科学院自动化研究所黄秉宪研究员的指导。清华大学精密机械系张伯鹏副教授给予很多支持、帮助。北京友谊医院神经内科窦淑荣医生为本文提供了宝贵的医学临床资料。特致衷心谢意!)

参 考 文 献

- [1] Albus JS. A new approach to manipulator control: the cerebellar model articulation controller. *J. Dynamic Systems, Measurement, and Control* (Transaction of the ASME), Paper on Bioengineering, 1975; 97(3): 220~227
- [2] Albus S. Data storage in the cerebellar model articulation controller. *J. Dynamic Systems, Measurement, and Control* (Transaction of the ASME), Paper on Bioengineering 1975; 97(3): 228~233
- [3] Eccles J C. The cerebellum as a computer: pattern in space and time. *J. physiol.* 1973; 229(1): 1~32
- [4] Marr D. A theory of cerebellar cortex. *J. Physiol.*, 1969; 202(2): 437~470
- [5] Albus JS. A theory of cerebellar function. *Math. Biosci.*, 1971; 11(1/2): 21~51
- [6] 王廷俊: 散列选、查表法及其在汇编程序中的试验和应用。《电子计算机动态》1975; (5): 1~20
- [7] Licata F, et al. A computer model of intermediate cerebellum dynamic operations in motor control. *Biological Cybernetics*. 1979; 35(2): 137~144
- [8] Albus JS. Mechanisms of planning problem solving in the brain. *Math. Biosci.* 1979; 45(3/4): 247~293
- [9] Albus JS, et al. An architecture for real-time sensory-interactive control of robot in a manufacturing facility. *Information Control Problems: Manufacturing Technology*, 1982; 81~90 (Proceedings of The 4-th IFAC/IFIP Symposium, Maryland, USA, 26-28 Oct. 1982)

仅在输入输出, 而且在结构与工作原理上, 都与小脑原型具有较强的类比关系, 因而, 仿真度较高。计算机模拟试验结果表明, 模型的训练能以完全性的收敛来完成, 它对模拟的手臂所进行简单运动的控制, 从生理上模拟了小脑的协调控制功能, 模拟了小脑控制中的学习、记忆、概括、经验以及代偿等表现。同时, 它还能够对小脑占位性病变, 小脑细胞退行性变, 以及由此引起的小脑性共济失调, 进行病理和症状模拟。

本文模型采用非解析性的信息空间变换算法, 它通过学习(训练)建立所需的输入输出关系, 通过自学习可达到系统的最佳控制精度, 并概括适应输入的变化。这些特征, 对于具有高维输入输出, 缺乏精确数学关系描述的困难控制问题, 具有一定的应用价值。同时, 它

COMPUTER SIMULATION OF CEREBLLAR CONTROL IN COODINATION MOTION

Fan Si-lu

(Institute of Psychology, Chinese Academy of Sciences, Beijing)

ABSTRACT

A Cerebellar computer model was established in FORTRAN language, which was based on Albus's primary model and was more analogous to the cerebellar prototype. The present model could physiologically simulate control function of cerebellum in coodination motion and pathologically imitate cerebellar ataxia. It was not only able to learn, generalize and adapt changes of input, but also able to reach the optimal control precision by self-learning.

These features will be worth applying to the control of system with multiple input and output and to systems which lack precise mathematical description. Besides, the method of processing information adopted by the model (i. e. space mapping method) gave us some ideas about researching methods of brain mechanisms.