

采用遗传算法的一种可重构 ANN 的电路设计*

卢 纯 石秉学

(清华大学微电子所, 北京 100084)

摘要: 提出了一种新型的 sigmoid 函数发生器。它不仅简单、快速, 与理想 sigmoid 函数的拟合程度好, 而且可实现阈值和增益因子的编程, 因而有很大的应用范围和良好的应用前景。设计了神经元以及 Gilbert 乘法器、数字存储器、D/A 转换器等神经网络的基本单元。说明了遗传算法 (GA) 作为人工神经网络 (ANN) 学习算法的有利因素。利用上述电路, 采用 GA, 设计了可重构 ANN。对各单元电路和整个 ANN 都用标准 $1.2\mu\text{m}$ CMOS 工艺的第 47 级模型进行了 HSPICE 模拟。结果表明它们的功能正确、性能优良。

关键词: 人工神经网络 (ANN); 模拟集成电路; 可重构; 可编程

EEACC: 1295; 1285; 2570D

中图分类号: TN492

文献标识码: A

文章编号: 0253-4177(2001)05-0664-06

1 引言

神经元电路是人工神经网络(ANN)中的关键部件, 用于实现非线性变换的功能, 其性能和复杂度对整个网络的影响很大。二十世纪八十年代以来, 各种各样的神经元相继问世。Sigmoid 函数因其良好的导数性能成为最常用的一种非线性变换形式。用于实现 sigmoid 转移特性的神经元可分为两类。一类是用一个运算放大器作为神经元, 实现求和与非线性变换的功能^[1]。这种电路的缺点是对每个神经元都需要一个运放, 因而不宜实现较大规模的神经网络。另一类是利用反向器特性实现非线性变换^[2], 这种电路的转移特性曲线虽近似于一个 sigmoid 型曲线, 但拟合程度还较差。本文将提出一种新型的可编程神经元。它简单、快速, 与理想 sigmoid 函数的相对误差不超过 3%, 并具有良好的可编程性^[3,4]。

除了神经元外, 本文还设计了乘法器、数字存储器、D/A 转换器等神经网络的基本构成单元。许多文献提出了各种结构的乘法器^[5]。最受到广泛使用

的是 Mead 根据 Gilbert 的思想提出的 Gilbert 乘法器。它是一种四象限模拟乘法器, 简单、占用面积小, 但也存在零点漂移等问题。本文针对这些问题进行了改进。

遗传算法是 Holland 于 70 年代根据生物进化模型提出的一种优化与搜索算法。近年来已普遍受到人们的关注, 并应用在人工神经网络的学习、优化和自适应等问题中^[6,7]。本文采用遗传算法(GA), 设计了一种可重构 ANN。利用它的可重构性, 在不同的拓扑结构下, 它可正确实现 XOR、AND 和 OR 和 $\sin(x)$ 函数拟合等功能。

2 系统整体方案

2.1 电路总体结构

神经网络的功能部分地由它的拓扑结构决定。根据所需解决的问题的不同, 网络的层数与各层的神经元数也不同。但如何正确地选择它们的数目, 到现在为止, 也没有理论根据。因此, 系统的拓扑结构

* 国家自然科学基金资助项目(批准号: 69636030)。

卢 纯 女, 1975 年出生, 博士研究生, 从事人工神经网络的集成电路实现、数字和模拟集成电路研究。

石秉学 男, 1936 年出生, 教授, 博士生导师, 从事人工神经网络和模糊逻辑系统及其集成电路实现、高性能 DC-DC 变换器、模拟和数/模混合集成电路与系统研究。

应具有一定的灵活性。

本文采用全随机的神经网络, 即具有随机的输入、神经元、层数和连接。每层被分为突触部分和神经元部分, 其结构如图 1 所示。CFG 为配置信号, 用来选择网络的拓扑结构。权重采用数字式存储, EN 为存储允许信号, ENN 为其反信号。W 为输入权重。X 是突触输入信号, 为电压值。X 加权求和后即得到 NET, 由于电流经简单线或便可实现求和功能, 因此 NET 用电流信号实现。Y 为神经元输出信号(即下级突触输入信号), 由于要发散到多个突触, 用电压信号实现。

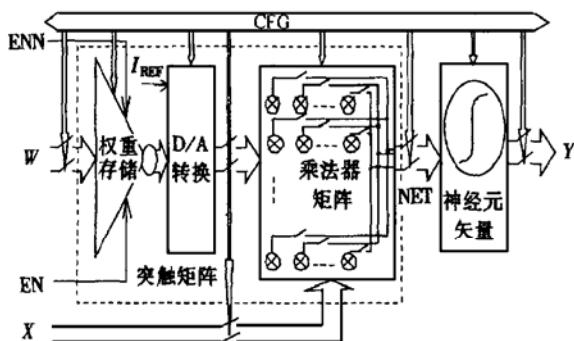


图 1 每层 ANN 的结构框图

FIG. 1 Diagram of Each ANN Layer

2.2 遗传算法

遗传算法的过程如图 2 所示, 其最大特点在于计算简单, 只有三种运算: 繁殖、交叉和变异。遗传算法中的控制参数包括种群容量 N 、变异率 P_m 和交叉率 P_c 。针对本文需解决的问题, 相关参数选择为 $N = 30$, $P_c = 0.85$, $P_m = 0.01$ 。设网络的目标向量为 T ; 对于种群中某基因型 W_n , 神经网络输出向量为 Y_n , 定义平方误差和函数

$$\text{sse}_n = \| Y_n - T \|^2 \quad n \in \{1, 2, \dots, N\} \quad (1)$$

种群的平方误差和向量为 $\text{SSE} = [\text{sse}_1; \text{sse}_2; \dots; \text{sse}_{10}]$, 设 $\min(\text{SSE})$ 为 SSE 中最小的元素, 则目标函数设置为

$$\text{fit}_n = \frac{1}{(\text{sse}_n - 0.9\min(\text{SSE}))^2} \quad (2)$$

目标函数值越大的基因型被复制的几率越大。

本文采用遗传算法, 除了考虑到其计算简单、快捷的优点外, 还有两个原因。第一, GA 对精度要求不高, 且二进制编码形式可直接映射数字式存储器。数字式权重存储数据可靠, 不易丢失, 设计和工艺简单, 在国内模拟存储工艺还很不成熟的情况下, 数字

式权重存储不失为一种最佳的存储方式。第二, GA 非定向运算的特征使其成为一种全局的优化方法, 不会使迭代陷入局部极小点。

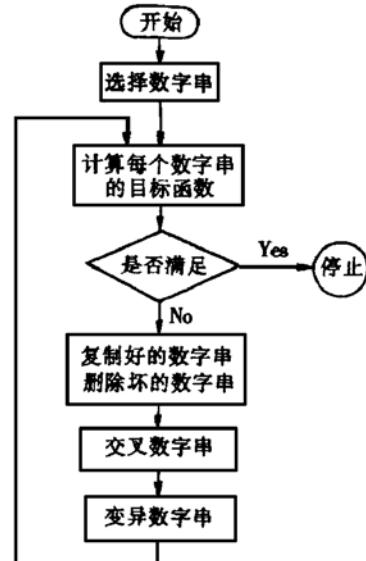


图 2 遗传算法流程图

FIG. 2 Flow Chart of Genetic Algorithm

3 基本单元的电路设计及其 HSPICE 模拟结果

3.1 神经元

ANN 中神经元所要实现的功能是对输入矢量所产生的加权和电流进行非线性 $I-V$ 变换。Sigmoid 函数为最常用的非线性变换之一, 表达式为

$$f(X) = \frac{1}{1 + \exp(-\alpha(X \cdot W) + \theta)} \quad (3)$$

其中 X 为输入矢量; W 为权重矩阵; θ 为阈值; α 为增益因子。

本文提出的新型神经元电路如图 3(a) 所示, 分为输入级、输出级两部分。输入级中 N 管 M1 和 P 管 M2 组成线性可调电阻, V_N 、 V_P 为其控制信号。 V_{ref1} 为固定电平, 它的选择保证 M1 和 M2 处于线性状态。 I_{ref1} 是用来调整阈值的参考电流。输出级为差分输入放大器, 差分输入的一端与 B 点相接, 另一端为固定电平 V_{ref2} 。两个 N 管为放大管, 4 个 P 管为负载, I_{ref2} 为恒流源电流。设 $V_d = V_B - V_{ref2}$, 当 V_d 满足 $|V_d| \leqslant \sqrt{2I_{ref2}/\beta}$ 时, M3、M4 工作于饱和区, 则 M3 的漏源电流可表达为

$$\begin{aligned} I_{d3}(V_d) &= \frac{\beta}{2}(V_B - V_C)^2 \\ &= \frac{I_{ref2}}{2} + \frac{\beta}{4}V_d \sqrt{\frac{4I_{ref2}}{\beta} - V_d^2} \end{aligned} \quad (4)$$

其中 电流因子 $\beta = \mu_N C_{ox} \left[\frac{W}{L} \right]_{M3} = \mu_N C_{ox} \left[\frac{W}{L} \right]_{M4}$. $I_{AB} = I_{in} + I_{ref1}$, V_B 随 I_{AB} 的增加缓慢下降. 当 I_{in} 较小时, $V_d > \sqrt{2I_{ref2}/\beta}$, V_{out} 为饱和低电平; 当 V_d 随 I_{in} 的增大而减小至 $\sqrt{2I_{ref2}/\beta}$ 时, V_{out} 开始上升; I_{in} 继续增大, 在 $|V_d| < \sqrt{2I_{ref2}/\beta}$ 阶段, V_{out} 保持缓慢上升; 当 $V_d \leq -\sqrt{2I_{ref2}/\beta}$ 时, V_{out} 到达并保持饱和高电平. $I_{ref1} = 20\mu A$ 恒定电流的情况下, 利用 HSPICE 对输入电流 I_{in} 从 $-20\mu A$ 到 $20\mu A$ 进行扫描, 得出的激活特性曲线如图 3(b) 中的上图实线所示. 图 3(b) 上图虚线是理想的 sigmoid 激活特性曲线. 它们间的相对误差不超过 3% 曲线, 如图 3(b) 下图所示.

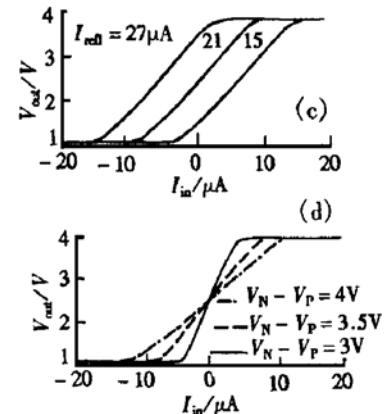
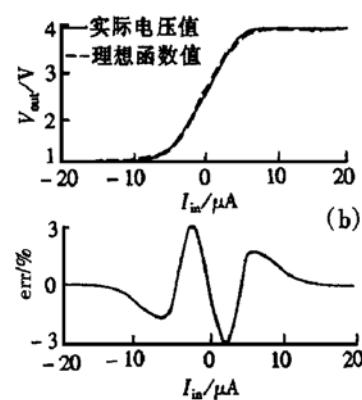
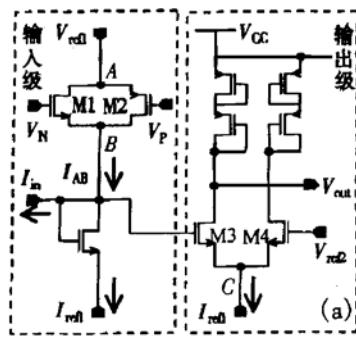


图 3 神经元电路及其 HSPICE 模拟结果 (a) 神经元电路图; (b) sigmoid 函数拟合及误差曲线; (c) 不同阈值下的转移曲线; (d) 不同增益因子下的转移曲线

FIG. 3 Neuron Circuit and Its HSPICE Simulation Result (a) Neuron Circuit; (b) Sigmoid Function Fitting and Error Curve; (c) Transfer Curves Under Different Thresholds; (d) Transfer Curves Under Different Gain Factors

3.2 其他基本单元

3.2.1 权重存储与 D/A 转换单元

本文采用与 GA 算法结果直接对应的数字式存储器^[8], 其单元电路如图 4(a) 所示, 6 个 MOS 管组成 Latch. 这种一大一小两个反相器组成的反馈环有效地防止了电荷泄漏. 当 EN 为 1' 时, 输入端 D 上的信息写入反馈环, EN 为 0' 时, 该信号被反馈环存储下来.

设神经网络的权值范围是 $(-2^u, 2^u)$, 最小精度

图 3(a) 所示的新型神经元不仅与理想 sigmoid 函数拟合得很好, 而且可实现阈值和增益因子的编程. 如图 3(c) 所示, 改变 I_{ref1} 可以调节阈值. 若 I_{ref1} 增大, V_d 到达 $\sqrt{2I_{ref2}/\beta}$ 所需 I_{in} 减小, 曲线向左平移; 反之, 则向右平移. 不同增益因子下的输出图形如图 3(d) 所示. 图 3(a) 中 M1、M2 工作在线性区, 令 $\beta_1 = \beta_2$, 则

$$\begin{aligned} R_{AB} &= \frac{V_A - V_B}{I_1 + I_2} \\ &= \frac{1}{\beta_1 [(V_N - V_P) - (V_{T1} + |V_{T2}|)]} \end{aligned} \quad (5)$$

由(5) 式可知, $(V_N - V_P)$ 越大, R_{AB} 越小, V_B 随输入电流变化的斜率越小, V_{out} 上升越缓慢, 增益因子 α 越小. 这样, 改变 V_N 、 V_P 的值就起到调节增益因子大小的作用.

为 2^{-v} , 则采用 GA 时, 每个权重元素将由包括符号位的 $(u+v+1)$ 位二进制码 $D = D_{u+v} \cdots D_1 \cdots D_0$ 表示, 其中 D_{u+v} 为符号位. 权重的 D/A 转换电路^[9] 如图 4(b) 所示, Q_i 由图 4(a) 中 QN_i 反向后得到. 虚线框中的电路实现电流的加权求和, $I = \left[\sum_{i=0}^{u+v-1} D_i \times 2^{i-v} \right] I_{ref}$. 点划线框内的电路用于控制电流的正负. 点框内电路相当于可调电阻 R_{out} . $V_W = I_W R_{out}$, 接到乘法器的输入端.

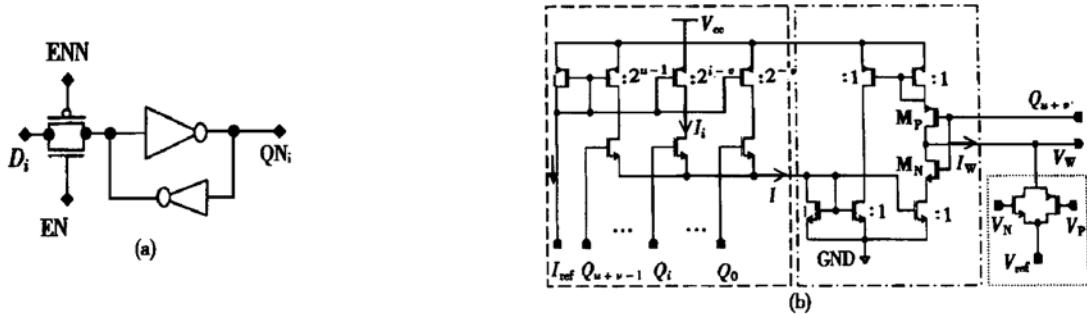


图 4 权重存储及 D/A 转换电路 (a) 权重存储单元; (b) 权重的 D/A 转换电路

FIG. 4 Weight Storage and Conversion Circuit (a) Weight Storage Unit; (b) Weight D/A Conversion Circuit

3.2.2 乘加运算单元

Gilbert 乘法器电路如图 5(a) 所示, 其中的管子都工作于饱和状态。差分对 M1、M2, M3、M4, M5、M6 的电流因子满足 $\beta_x = \beta_1 = \beta_2, \beta_w = \beta_3 = \beta_4 = \beta_5 = \beta_6$ 。虚框中的电流镜起到放大电流和电流相减的功能。设 $\Delta W = W_1 - W_0, \Delta X = X_1 - X_0$, 可以证明

$$I_{\text{out}} = \alpha \sqrt{\frac{\beta_x \beta_w}{2}} \Delta X \Delta W \quad (6)$$

由于简单电流镜精度低, Gilbert 乘法器会出现零点漂移的现象。另外, 在实现“加”(输出节点线或)

时, 若输入信号范围较大, 有可能使 M7 管与 M8 管脱离饱和状态, 使乘法器输出错误。针对这两点, 本文对 Gilbert 乘法器进行了改进: 用共源共栅电流镜代替简单电流镜; 输出端再加一级电流镜, 构成的隔离级, 将外部电路与内部节点分隔开来, 保证 M7 管与 M8 管处于饱和状态。改进后的乘法器 HSPICE 模拟结果如图 5(b) 所示, 可看出其零点准确。由下面的整体电路模拟结果也可看出, 加隔离级后, 直接“线或”, 就不会出错了。

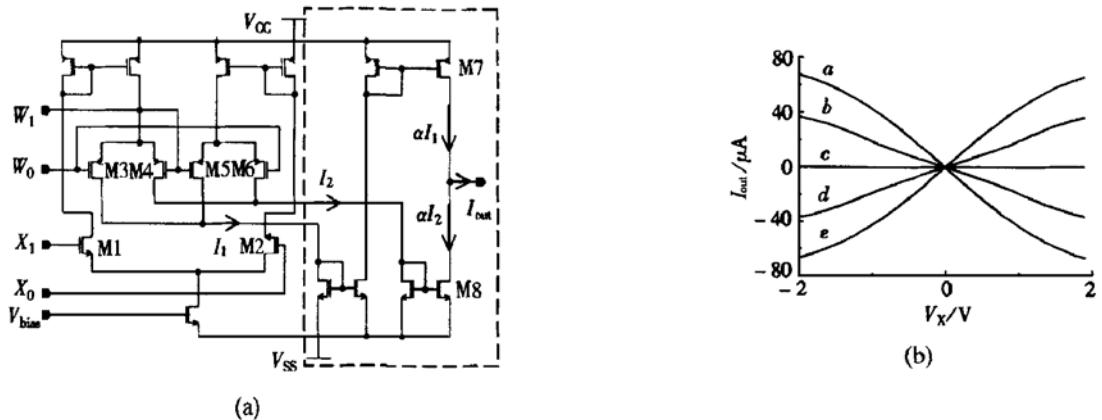


图 5 Gilbert 乘法器电路图及改进后的 HSPICE 模拟结果 (a) Gilbert 乘法器电路图; (b) 改进后的 HSPICE 模拟结果

FIG. 5 Gilbert Multiplier Circuit and HSPICE Simulation Result After Improvement (a) Gilbert Multiplier Circuit; (b) The HSPICE Simulation Result After Improvement

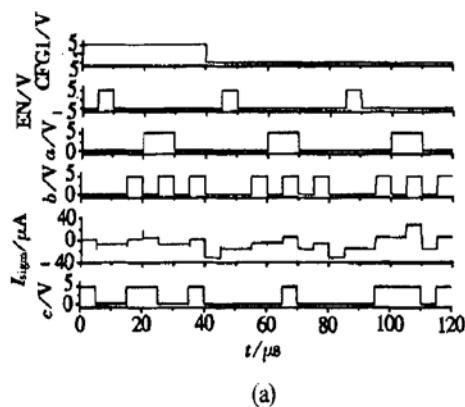
4 整体电路模拟结果

根据系统整体方案, 利用神经元、乘加运算电路及数字存储单元、A/D 转换电路, 设计了一个前向可重构的 ANN。该网络可根据不同的配置信号, 构成不同的网络拓扑结构, 从而实现 XOR、AND、OR

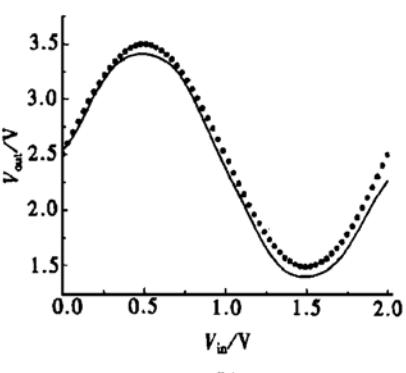
和 $\sin(x)$ 函数拟合等不同功能。

图 6(a) 为实现 XOR、AND 和 OR 功能时的 HSPICE 模拟结果。 $0 < t < 40\mu\text{s}$ 时, 配置信号中的一位 CFG1 为高电平, 构成两层 ANN。 $t = 5\mu\text{s}$ 时, EN 由低变高, 此时用 GA 求出的解决 XOR 问题的二进制编码写入并存储, 之后, 输出有效。由输入信号 a、b、第二层神经元的输入电流 I_{sigm} 和输出信号 c 可

看出, 此时该 ANN 实现了 XOR 功能。 $t = 40\mu s$ 时, CFG1 由高变低, 网络为单层 ANN。 $t = 45\mu s$ 时, EN 再次由低变高, 这时写入并存储用 GA 求出的解决 AND 问题的二进制编码, 由图可知此后至 $t = 85\mu s$, ANN 实现了 AND 功能。 $t = 85\mu s$ 时, 解决 OR 问题的权重码写入并存储, 此后 ANN 实现 OR 功能。



(a)



(b)

图 6 ANN 的 HSPICE 模拟结果 (a) XOR、OR 和 AND 功能验证; (b) $\sin(x)$ 函数拟合FIG. 6 HSPICE Simulation Result of ANN (a) Operation Verifying of XOR, OR and AND Problem; (b) $\sin(x)$ Function Fitting

5 结论

本文提出的新型 sigmoid 神经元简单、快速, 输出曲线与理想函数的拟合程度优越于当前常用的神经元, 且实现了阈值和增益因子的可编程。在 Gilbert 乘法器中采用共源共栅电流镜, 有效地解决了零点漂移的问题; 隔离级的加入则保证了内部电路的 MOS 管处于饱和状态, 避免了求和时的错误。GA 运算简单、全局收敛及运算结果可直接映射到数字存储器等优良特性使其成为神经网络领域中颇有前途的一种算法。本文采用 GA 的前向可重构 ANN 正确解决了 XOR、AND、OR 和 $\sin(x)$ 函数拟合等不同问题, 从而验证了其可重构性及其基本构成单元的正确可靠。

参考文献

[1] A. Mustafa, T. Mahmut and K. Recai, Proceedings of the In-

ternational Conference on Biomedical Engineering Days, 1998, 20—22: 51—53.

- [2] J. Choi, S. H. Bang and B. J. Sheu, IEEE Trans. Neural Networks, 1997, 4(3): 484—495.
- [3] Chun Lu and Bingxue Shi, Electron. Lett., 2000, 36(6): 553—555.
- [4] Chun Lu and Bingxue Shi, IJCNN 2000, Como, Italy, 2000.
- [5] B. J. Sheu, J. Choi and J. C. F. Chang, IEEE Trans. VLSI Systems, 1994, 2(1): 129—133.
- [6] M. Srinivas and L. M. Patnaik, Genetic Algorithms: A Survey, Computer, 1994, 27(6): 17—26.
- [7] B. Thomas, H. Ulrich and S. Hans-Paul, IEEE Trans. Evolutionary Computation, 1997, 1(1): 3—17.
- [8] LIN Gu and SHI Bingxue, Chinese Journal of Semiconductors, 2000, 21(1): 69—75 (in Chinese) [林谷, 石秉学, 半导体学报, 2000, 21(1): 69—75].
- [9] LI Guoxing, SHI Bingxue and LU Wei, Chinese Journal of Semiconductors, 1998, 19(7): 532—537 (in Chinese) [李国星, 石秉学, 路伟, 半导体学报, 1998, 19(7): 532—537].

Circuit Design of a Reconfigurable ANN with GA Training^{*}

LU Chun and SHI Bing-xue

(Institute of Microelectronics, Tsinghua University, Beijing 100084, China)

Abstract: A novel sigmoid function generator is proposed. It is not only simple, fast, fit quite well with the ideal sigmoid function, but also programmable for the threshold and the gain factor. Thus, the neuron has wide application area and good prospect. Basic cells of the neural networks including the neuron, Gilbert multiplier, digital memory, D/A converter are designed. The benefit of Genetic Algorithm (GA) as an algorithm of the ANN is explained. A reconfigurable ANN composed of the above cells is designed, using GA as the training algorithm. The cells and the whole ANN are simulated with HSPICE, using level 47 transistor models for a standard 1.2μm CMOS process. Simulation results show that they all operate correctly and excellently.

Key words: Artificial Neural Network (ANN); analog integrated circuits; reconfigurable; programmable

EEACC: 1295; 1285; 2570D

Article ID: 0253-4177(2001)05-0664-06

* Project Supported by National Natural Science Foundation of China Under Grant No. 69636030.

LU Chun female, born in 1975, Ph. D candidate. She is engaged in the research on artificial neural network, digital and analog IC.

SHI Bing-xue male, born in 1936, professor. He is engaged in the research on artificial neural network.