

基于 SCFNN 之 PAM 非线性信道均衡器 成效研究

李庆海, 林瑞昌

(浙江工贸职业技术学院 电子工程系, 浙江 温州 325003)

摘要: 自组织型模糊类神经网络 (SCFNN) 可依据一定的法则自我构建神经网络的组织结构, 从而适用于当前控制对象; 多层神经元是传统的类神经网络, 广泛应用于各个领域; 倒传递学习与最陡坡降法相结合, 可使以上两种类神经网络进行有效的融合; 目前, 信道均衡器上的系统架构种类非常多, 各种类神经网络应用于信道均衡器也颇为普遍; 在研究 SCFNN 的基础上, 将其应用于通道均衡器确实可行, 效果良好; 比较了 SCFNN 与 MLP 在通道均衡器的成效; 仿真表明, 在相同通道环境下, SCFNN 的训练收敛速度、位错误率与系统敏感度优于 MLP, 完成结构学习后 SCFNN 的结构也颇为精简。

关键词: 自组织型模糊类神经网络; 均衡器; 多层神经元; 最陡坡降法

A SCFNN Based PAM Channel Equalizer Performance Research

Li Qinghai, Lin Ruichang

(Department of Electronic Engineering, Zhejiang Industry & Trade Vocational College, Wenzhou 325003, China)

Abstract: Self-Constructing Fuzzy Neural Network (SCFNN) can create a fuzzy neural network for a target in accordance with a dedicated algorithm. Multi-layer Perceptron (MLP) neural network is a very traditional neural network and many applications were developed in different fields. Back Propagation (BP) combined with steepest descent method make the SCFNN and MLP learned efficiently. Today, many kinds of channel equalizers were constructed, and many kinds channel equalizers based on neural network were also constructed. We prove that the SCFNN can be a superior equalizer. We also compare the performance of SCFNN and MLP applied in channel equalizer. The simulation results show the SCFNN is superior than the MLP in convergence speed, bit error rate and sensitivity. When the SCFNN learning processes is completed the, we found the structure is very simpler.

Keywords: self-constructing fuzzy neural network (SCFNN); equalizer; multi-layer perceptron (MLP); steepest descent method

0 引言

在信道中传送数字信号, 难免会遭受到噪声的干扰及产生符号干扰 (ISI), 或是信号能量在传送过程中衰减, 使接收端收到的是失真的信号, 因此, 我们必须在接收端补偿或修正收到的信号, 希望能恢复失真的信号。过去以线性信道均衡器解决此类问题, 慢慢的通道环境日趋复杂, 线性信道均衡器难以恢复严重的非线性失真信号^[1]。

经过学习的类神经网络可以在输入信号与输出信号间行成复杂的决策边界 (decision boundary), 所具有的复杂映射 (Mapping) 能力能解决非线性或高度非线性分类问题, 所以, 多采用类神经网络解决信道非线性失真的问题^[2-3]。在复数类神经网络方面, Chen 等专家^[3-9]证实各种类神经网络均衡器可以产生复数非线性隔离曲线, 亦即等化高度非线性信道。上述这些类神经网络都是训练架构已经确定的神经网络, 训练期间调整其前后层间链接权重 (link weight), 或神经元的偏权值 (Bias), 或同一层间神经元的链接权重, 经过数十次甚至于上万次学习循环网络收敛后, 才是一个可以工作的类神经网络。

图 1 的自组织型模糊类神经网络 (self-constructing fuzzy neural network, SCFNN) 最早由 Faa-Jeng Lin 等提出并实现于永久磁铁式同步马达速度控制^[10]。本文将 SCFNN 加上

Hard decision 之后, 应用在有 ISI 效应、非线性与噪声的信道失真后衰败信号重建, 我们去仿真 ISI、非线性、与噪声不同组合模型, 经过一再测试, SCFNN 所建出来的类神经网络均衡器, 有很好的信号恢复能力且硬件需求简单。以目前均衡器所使用的类神经网络架构来说, 图 2 的多层神经元 (multi-layer perceptron, MLP) 结构^[11-12]是信号恢复程度相当高的一种, 虽然 MLP 存在收敛容易落入局部极小值与训练周期数过长的普遍也有专家学者改善传统 MLP 后, 将其应用于通

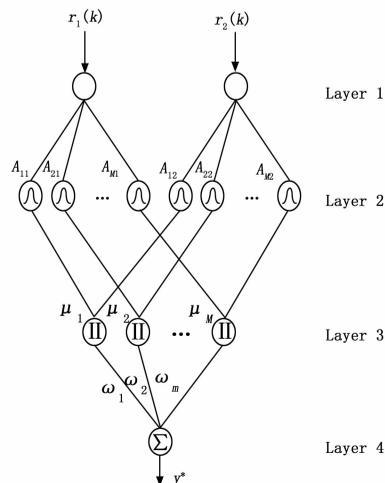


图 1 自组织型模糊类神经网络应用于均衡器

收稿日期: 2016-12-27; 修回日期: 2017-01-19。

作者简介: 李庆海 (1980-), 男, 黑龙江哈尔滨人, 研究生, 讲师, 主要从事自动化控制, 神经网络方向的研究。

道均衡器^[5-13]。本文除了测试 SCFNN 在通道均衡器的表现之外, 并以 MLP 信道均衡器为比照对象, 来验证 SCFNN 在信号恢复上能否比 MLP 更为强健 (Robustness)。

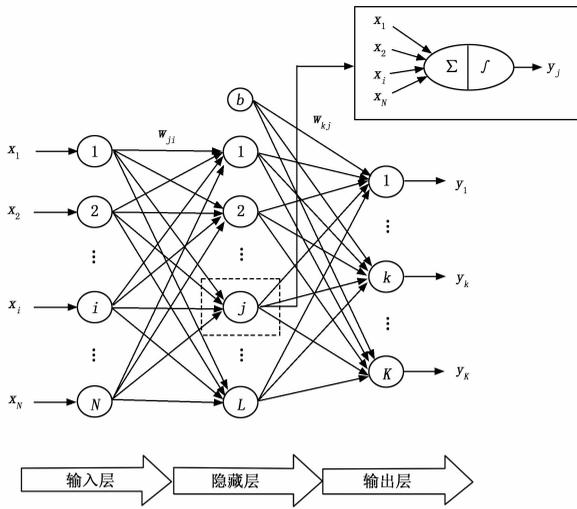


图 2 多层神经元类神经网络

1 数字传输系统

具有均衡器的数字通信系统如图 3 所示, 在时间 kT 时传送的信号 $t(k)$, $k=0, 1, 2$ 表示原始数字序列, 假设其具有统计独立与机率相等的特性, 其中, $1/T$ 代表符号率, 信道 (Channel) 表示信号行经路线特性, 一个被广泛使用的线性分散信道模型是有限长度脉冲响应 (finite impulse response, FIR) 模型, 在时间 kT 时通道的输出 $a(k)$ 可表示为^[4]:

$$a(k) = \sum_{i=0}^{n_k-1} h(i) \cdot t(k-1) \quad (1)$$

$h(i)$, $i=0 \dots n_k-1$ 为通道的脉冲响应而 n_k 是 FIR 通道的长度。传送设备的电子组件可能会引起信号产生非线性失真, $a(k)$ 经 NL 后的输出 $b(k)$ 可表示为:

$$b(k) = f[a(k), a(k-1), \dots, a(k-n_k+1), h(0), h(1), \dots, h(n_k-1)] \quad (2)$$

$f(\dots)$ 表示 NL 产生的非线性函数。通道也可能受具有变方差 σ^2 平均值为 0 的白色高斯噪声影响, 所以, 当我们考虑白色高斯噪声时, 均衡器收到的信号 $r(k) = b(k) + q(k)$, $q(k)$ 即代表白色高斯噪声, $y^*(k)$ 是经均衡器补偿后的输出, $y^*(k)$ 与正确信号 $y(k)$ 比较, 产生一个误差信号 $e(k) = y(k) - y^*(k)$, 若所有训练数字序列的 $e(k)$ 均方根值超出可容许的误差范围, 则持续训练修正均衡器的参数, 直至 $e(k)$ 均方根值在许可范围之内为止。

在本研究中所采用的信道模型有以下 3 种, 其转移函数分别表示如下^[6-8]:

$$\begin{aligned} CH = 1; & 1.0 \\ CH = 2; & 0.447 + 0.89z^{-1} \\ CH = 3; & 0.2.9 + 0.995z^{-1} + 0.2.9z^{-2} \end{aligned} \quad (3)$$

$CH=1$ 因具单位脉冲响应所以相当于是一个没有任何 ISI 的通道, $CH=2$ 相当于是一个不具最小相的通道。 $CH=3$ 表示目前的位数受后续两个位影响的信道。ISI 效应产生主要是因为数据在高速传输时需要相当高的符元速率, 然而在多重传

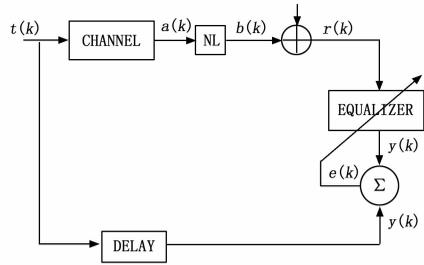


图 3 具有均衡器的数字传输系统

输环境中, 由于时间的不准确性, 频宽不足, 振幅失真, 相位失真, 而受到严重的“相邻符元互相干扰”, 如图 4 所示。为了处理由 ISI 所引起的有限频宽通道, 首先必须要有此 ISI 之离散时间模型。如图 5 所示, 为有 ISI 之通道离散时间截线滤波器 (transversal filter) 模型, 其跳阶增益为 X_k , 时间区间为 $2LT$, 其输入信号为 I_n , 输出信号为 y_n , 噪声信号为 v_n 。

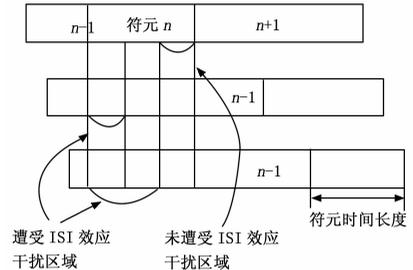


图 4 ISI 效应

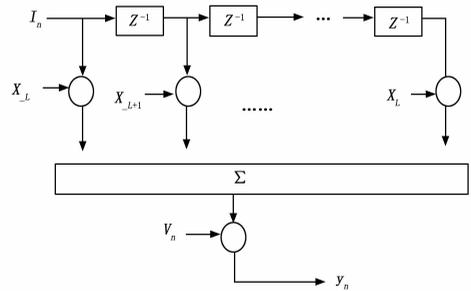


图 5 ISI 效应的通道离散时间模型

在本研究中, 采用的非线性现象有以下 4 种^[6-8]:

$$\begin{aligned} NL = 0; & b(k) = a(k) \\ NL = 1; & b(k) = \tanh(a(k)) \\ NL = 2; & b(k) = a(k) + 0.2a^2(k) - 0.1a^3(k) \\ NL = 3; & b(k) = a(k) + 0.2a^2(k) - 0.1a^3(k) + 0.5\cos(\pi a(k)) \end{aligned} \quad (4)$$

$NL=0$ 相当于一个线性信道模型, $NL=1$ 相当于传输系统放大器饱和的非线性信道, $NL=2$ 与 $NL=3$ 则是两个任意非线性信道。本研究中仿真各种信道模型、非线性模型、讯号噪声强度比 (SNR=8-18, 间隔 2) 不同组合条件下, 研究 SCFNN 所建出来的结构与信号恢复情形。

2 自组织型模糊类神经网络应用在信道均衡器

图 1 自组织型模糊类神经网络系统^[10], 运作之始就是三个输入节点与一个输出节点, 随着训练动作的进行逐步加入第二层归属函数 (membership function) 节点与第三层乘积运作

节点, 并逐步调整第二层每一个高斯型归属函数的平均值 (Mean) m_{ji} 、标准差 (Deviation) σ_{ji} 与第三层、输出节点间的链接权重 (link weight) ω_j , 直至所有训练样本的推论输出值与期望输出值差的均方根值收敛为止。训练周期视训练样本的复杂度而异, 可能需数个至数十个训练周期, 所谓一个训练周期表示所有的训练样本执行过一次。

我们逐步说明自组织型模糊类神经网络推论输出值的计算过程与学习方法, 训练样本逐笔进入自组织型模糊类神经网络, 经过逐层运算得到一个推论输出值。以下是各层的计算过程。

Layer 1: 此层是输入节点, 序列 $r(k)$ 、 $r(k-1)$ 、 $r(k-2)$ 透过此节点传到下一层, 没有计算动作。其中:

- $r(k)$: 非线性模型输出加上白色高斯噪声后的数字序列;
- $r(k-1)$: 较 $r(k)$ 延迟 1 个位的数字序列;
- $r(k-2)$: 较 $r(k)$ 延迟 2 个位的数字序列。

Layer 2: 此层的每一节点相当于是第一层输入变量的语意项 (linguistic label), 亦即算出输入变量 i 属于此归属函数的程度 A_{ji} , 本研究中采用高斯函数作为归属函数 (membership function),

$$A_{ji} = \exp\left(-\frac{(r(k-i) - m_{ji})^2}{\sigma_{ji}^2}\right), i = 0, 1, 2 \quad (5)$$

- m_{ji} : 信号 $r(k-i)$ 对第 j 个归属函数的中点 (Mean)。
- σ_{ji} : 信号 $r(k-i)$ 对第 j 个归属函数的标准差 (Standard deviation)。

Layer 3: 此层的每一节点表示模糊规则的命题部 (Precondition part), 其函数是:

$$u_j = A_{j1}(r(k)) \cdot A_{j2}(r(k-1)) \cdot A_{j3}(r(k-2)) \quad (6)$$

亦即第二层三个输入归属函数群中第 j 个归数函数值进入此节点相乘, 得一乘积为此层的输出。

Layer 4: 此层仅有一个节点主要的动作是解模糊化 (Defuzzify), 若以 y^* 表示推论输出值, 则:

$$y^* = \sum_{j=1}^M u_j \omega_j \quad (7)$$

u_j ($1 \leq j \leq M$) 表示第三层的输出, ω_j ($1 \leq j \leq M$) 表示第三层每一节点与第四层输出节点之间的链接权重, M 是系统学习过程中已建立的规则数目。

SCFNN 的特色之一是在线学习 (on-line learning), SCFNN 在初始状态仅有 n 个输入节点与一个输出节点, 经由结构学习 (structure learning) 建立系统, 经由参数学习 (parameter learning) 将系统每个规则的 3 个参数调到最佳状态。开始结构学习之后, 每一训练样本进入 SCFNN 输入节点, 对每一输入值产生每一个归属函数的激发量, 若发现激发量的值都小于设定值, 则在第二层为每一个输入变量增加一个节点, 第三层也增加一个节点, 亦即增加一条规则, 完成结构学习后系统可以将输入变量的论域 (universe of discourse), 做合理的模糊分割 (fuzzy partition), 当然我们希望建立最少的规则也希望产生最少的模糊集合 (fuzzy sets)。

接着我们说明学习过程的参数学习, 倒传递 (back propagation) 算法是参数学习的主要精神, 我们将一笔三位的数据 $r(k)$ 、 $r(k-1)$ 、 $r(k-2)$ 输入给自组织型模糊类神经网络经过计算得到一个推论输出值的同时, 也有一个位的正确输出值 $y(k)$ 传到自组织型模糊类神经网络以比较两者的差, 进

而推论出 3 个要修正参数 (链接权重 ω_j 、归属函数的平均值 m_{ji} 与标准差 σ_{ji} 的修正量然后进行修正。这个动作在每一笔数据进入系统就做一次, 直至系统学习完成, 完成学习后系统可以工作。我们以求输出值相反方向说明上述 3 个参数修正量的公式。首先定义能量函数 E 如下:

$$E = \frac{1}{2} (y - y^*)^2 \quad (8)$$

y : 对应每一训练样本的正确输出值。

y^* : $r(k)$ 、 $r(k-1)$ 、 $r(k-2)$ 进入系统之后的推论输出值。

Layer 4:

链接权重 ω_j 变化量及更新方式如下:

$$\begin{aligned} \Delta\omega_j &= -\eta_w \frac{\partial E}{\partial \omega_j} = \\ &= -\eta_w \frac{\partial E}{\partial y^*} \frac{\partial y^*}{\partial \omega_j} \quad j = 1, 2, 3, \dots, M = \\ &= \eta_w (y - y^*) u_j \end{aligned} \quad (9)$$

$$\omega_j(N+1) = \omega_j(N) + \Delta\omega_j \quad (10)$$

N 为学习样本编号; j 为第三层节点编号。

由 (8) 式可看出每输入一笔训练样本给自组织型类神经网络得到推论输出值后, 调整计算正确输出值与推论输出值差后进行参数调整。

归属函数的中间值与标准差之调整量公式如下:

Layer 3:

$$\begin{aligned} \Delta m_{ji} &= -\eta_m \frac{\partial E}{\partial m_{ji}} = -\eta_m \frac{\partial E}{\partial y^*} \frac{\partial y^*}{\partial u_j} \frac{\partial u_j}{\partial A_{ji}} \frac{\partial A_{ji}}{\partial m_{ji}} = \\ &= -\eta_m (-(y - y^*)) \omega_j u_j \frac{2(x_i - m_{ji})}{\sigma_{ji}^2} \end{aligned} \quad (11)$$

$$\begin{aligned} \Delta \sigma_{ji} &= -\eta_\sigma \frac{\partial E}{\partial \sigma_{ji}} = -\eta_\sigma \frac{\partial E}{\partial y^*} \frac{\partial y^*}{\partial u_j} \frac{\partial u_j}{\partial A_{ji}} \frac{\partial A_{ji}}{\partial \sigma_{ji}} = \\ &= -\eta_\sigma (-(y - y^*)) \omega_j u_j \frac{2(x_i - m_{ji})^2}{\sigma_{ji}^3} \end{aligned} \quad (12)$$

式中, η_m 、 η_σ 是参数, 可调整以得到较佳的结果。接着实际进行归属函数参数的调整,

$$m_{ji}(N+1) = m_{ji}(N) + \Delta m_{ji} \quad (13)$$

$$\sigma_{ji}(N+1) = \sigma_{ji}(N) + \Delta \delta_{ji} \quad (14)$$

经过了结构学习与参数学习, 系统也收敛, 表示这是一个可以工作的自组织型模糊类神经网络, 即可切换进入传输模式进行信息接收工作。在模拟过程中, 我们另外随机产生 100,000 位 PAM {+1, -1} 测试数据, 逐笔进入系统进行运算, 求推论输出值并计算位错误率。

3 总结自组织型模糊类神经网络为基础的信道均衡器算法

为仿真通道的 ISI 现象, 本研究以 $r(k)$ 、 $r(k-1)$ 、 $r(k-2)$ 三个数字序列作为自组织型模糊类神经网络的输入信号, 图 1 与图 3 是本研究之系统结构。以下总结本研究的算法:

1) 学习部分。

(a) 若是第一笔数据则分别对 n 个输入变量建立 n 个高斯型归属函数, 以输入变量值为高斯函数中点 m , 偏离值 (Deviation) σ 采固定值。计算 3 个激发量 (firing strength) A_{j1} 、 A_{j2} 、 A_{j3} 的乘积 u_1 , u_1 与输出端间之链接权重 ω_1 (link weight) 初始时采随意值。 j 在本论文中表示图一第二层每一群归属函数编号, 亦是第三层乘积运作节点编号。

(b) 第二笔数据起, 对已建立之归属函数求出 $u_1、u_2、\dots、u_n$ 并找出这中间最大值 U_{max} , 将此值与既定值 U_{min} 做比较, 若小于 U_{min} 则建立一个新规则, 亦即第二层每群增加一个高斯归属函数。归属函数的平均值 $m_{ji} = r(k)、r(k-1)、r(k-2)$, 标准差 σ_{ji} 则采随机值, 因为后续尚需调整), 第三层增加一个乘积运作节点, 链接权重值 ω_j 亦采随机值。

(c) 计算推论输出值 $y^* = u_1\omega_1 + u_2\omega_2 + u_3\omega_3 + \dots + u_M\omega_M$, M 表示目前归属函数的数目。

(d) 调整每一个高斯型归属函数中点 m_{ij} 、偏离值 (Deviation) σ_{ij} 与链接权重 (Link Weight) ω_j 。

(e) 计算所有训练样本之推论输出值与正确输出值误差之均方根值。

2) 重复步骤 (b) ~ (e) 直至所有训练样本之推论, 输出与正确输出之均方根值收敛至设定值或训练次数已达一定次数为止。

3) 使用另一数字序列, 测试已训练好的自组织型类神经网络均衡器计算其位错误率 (Bit Error Rate)。

4 模拟结果

我们仿真 3 种主要的信道模型搭配非线性模型、不同信号噪声强度比, 每一种状况都以 500 位 PAM 信号 $\{+1, -1\}$ 进行 20 个学习循环的训练, 再以 100000 位 PAM 信号 $\{+1, -1\}$ 进行测试, 记录均方根值收敛曲线、位错误率与 SCFNN 完成学习后的规则数。在上一节曾提到训练样本进入输入节点之后, 若激发量小于设定值, 则需建立一个规则, 此最小激发量我们设定为 0.125。在参数学习过程中, 更新链接权重、高斯函数平均值与标准差时有三个重要的参数 $\eta_w、\eta_m、\eta_p$, 我们分别设定为 0.025。本文以信道转移函数 CH=3, 非线性模型 (NL=0-3) 与噪声 (SNR=8-18) 作为模拟条件。在仿真过程中 SCFNN 所建立的规则数列于表 1。图 6~7 是 MLP 与

表 1 SCFNN 在 CH=3, NL=0-3, 最小激发量 0.125 经 500 bit/20cycle 训练的最后规则数

CH	NL	Fm	SNR = 8	SNR = 10	SNR = 12	SNR = 14	SNR = 16	SNR = 18
3	0	0.125	12	10	9	8	8	6
3	1	0.125	13	11	10	9	8	7
3	2	0.125	13	12	11	10	10	9
3	3	0.125	13	12	12	11	11	10

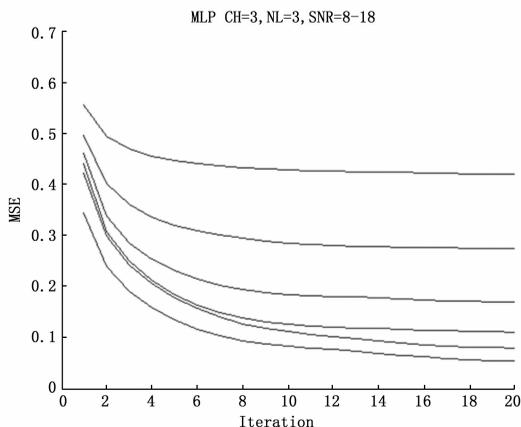


图 6 MLP-CH=3, NL=3, 训练期间均方根值收敛曲线

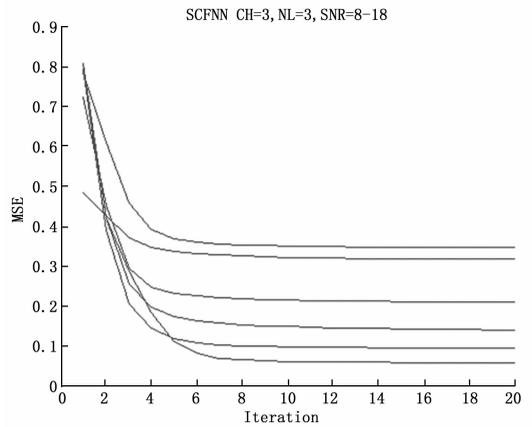


图 7 SCFNN-CH=3, NL=3, 训练期间均方根值收敛曲线

SCFNN 的 MSE 值、由图中可看出 SCFNN 的收敛较为快速, 亦即可在较短训练周期下达到相等程度信号恢复。NL=3 加上低 SNR 值会产生收敛不是很理想情况。图 8~9 是 MLP 与 SCFNN 的位错误率值, 本文发现相对于 MLP, 我们可看出, SCFNN 对此 4 种非线性现象变化较大, 亦即 SCFNN 对不同的非线性现象, 展现出其高敏感度。

图 10~13 是 SCFNN 与 MLP 位错误率的比较, 我们可以发现, SCFNN 的位错误率都在 MLP 之下, 亦即 SCFNN 的信恢复能力比较高。

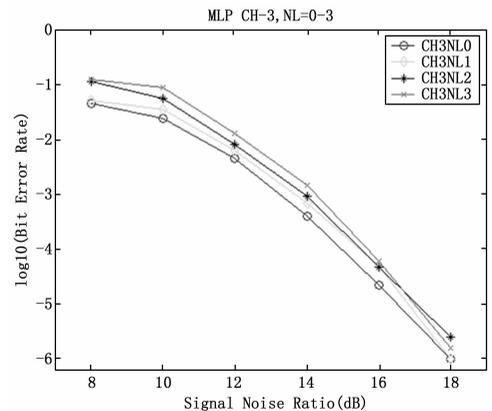


图 8 MLP-CH=3, NL=0-3, 位错误率

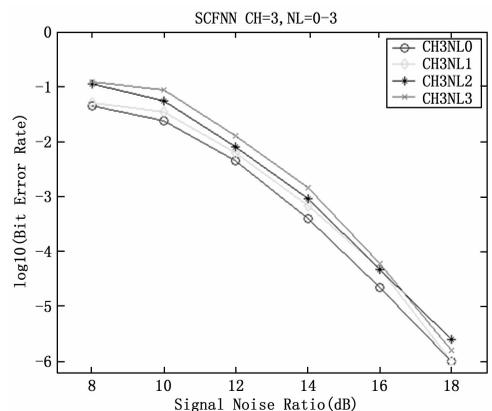


图 9 SCFNN-CH=2, NL=0-3, 位错误率

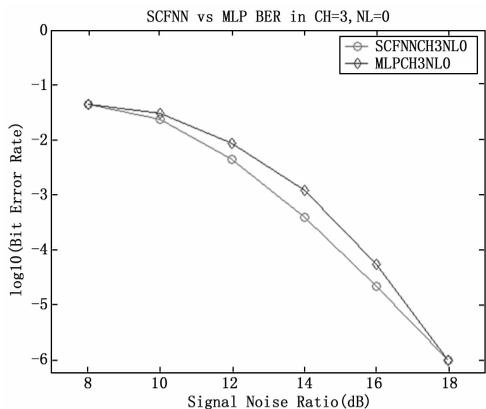


图 10 MLP 与 SCFNN CH=3, NL=0, 位错误率比对

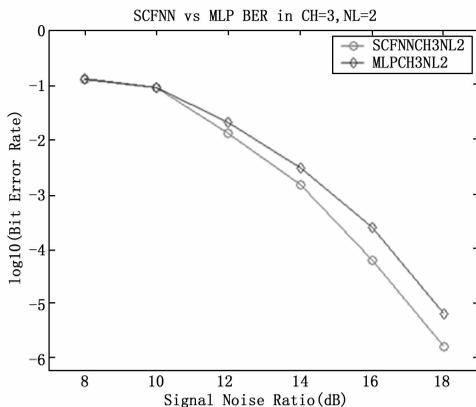


图 13 MLP 与 SCFNN CH=3, NL=2 位错误率比对

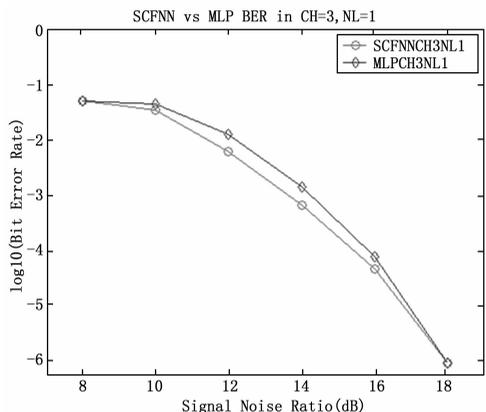


图 11 MLP 与 SCFNN CH=3, NL=1 位错误率比对

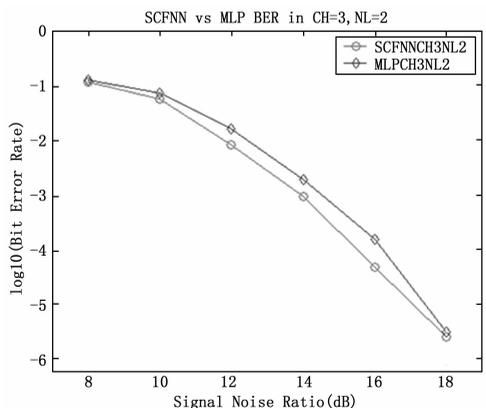


图 12 MLP 与 SCFNN CH=3, NL=2 位错误率比对

5 结论

本研究以自组织型模糊类神经网络 (SCFNN) 设计数字传输系统非线性均衡器, 在适度非线性搭配不同程度 SNR 仿真条件组合下, 检视 SCFNN 在数字传输系统非线性均衡器的成效。证实 SCFNN 在信号恢复程度明显优于 MLP, 且其 M. S. E 曲线收敛状况亦比较快速。系统敏感度是目前各个架构所欠缺的能力, 本文验证了 SCFNN 在系统敏感度优于 MLP。SCFNN 架构虽简单但也不是很精简, 再进一步, 为了使硬件成本降低, 将结构数降低乃是必要途径, 也是后续可努力改善

的目标之一。

参考文献:

- [1] Haykin S. Communication Systems [A]. 4th ed [C] ., New york: Wiley, 2001.
- [2] Lee C C, Fuzzy logic in control system: Fuzzy logic controller—Part I and part II [J]. IEEE Trans. Syst., Man, Cybern, 1990, 20 (9): 404-436.
- [3] Bernard Mulgrew. Applying radial basis functions [J]. IEEE Signal Processing Magazines, 1996, 23 (6): 50-65.
- [4] Jean-pierre Martens, Nico Weymaere, An equalized error back-propagation algorithm for the on-line training of multilayer perceptrons [J]. IEEE Trans. Neural Networks., 2002, 13 (6): 532-541.
- [5] Azzedine zerguine, Ahmar shafi, and Maamar bettayeb, Multilayer perceptron-based lattice structure [J]. IEEE Trans. Neural Networks, 2001, 9 (12): 532-545.
- [6] Deng Jianping, P. Saratchandran, Communication channel equalization using complex-valued minimal radial basis function neural networks [J]. IEEE Trans. Neural Networks, 2003, 13 (6): 687-696.
- [7] Kechriotis G, Zervas E, Manolakos E S. Using recurrent neural networks for adaptive communication channel equalization [J]. IEEE Trans. Neural Networks, 1994, 9 (19): 267-278.
- [8] Chen S, Gibson G, Cowan C, et al. Reconstruction of binary signals using an adaptive radial-basis-function equalizer [J]. Signal Processing, 1991, 22 (6): 77-93.
- [9] Chen S, Gibson G, Cowan C, et al. Adaptive equalization of finite non-linear channels using multilayer perceptron [J]. Signal Processing, 1990, 20 (6): 107-119.
- [10] Faa-Jeng Lin, Chih-Hing Lin, Po-Hung Shen. Self-constructing fuzzy neural network speed controller for permanent-magnetic synchronous motor drive [J]. IEEE Tran. Fuzzy Syst, 2001, 9 (5): 751-759.
- [11] 暴春, 谢邦昌. 浅谈类神经网络 [J]. 山西科技, 2006, 10 (1): 132-132.
- [12] 赵娟, 高正明. 基于 BP 神经网络的盲均衡器设计 [J]. 声学技术, 2013, 32 (2): 141-145.
- [13] 董玉华, 张俊星. 修正的解相关前馈神经网络盲均衡算法研究 [J]. 大连民族学院学报, 2012, 14 (5): 460-462.