

# 基于 PLS 快速剪枝法的神经网络盲均衡\*

李振兴<sup>1</sup>, 韩仿仿<sup>2</sup>

(1. 大连 91550 部队 94 分队, 辽宁 大连 116023;

2. 国家无线电监测中心 乌鲁木齐监测站, 乌鲁木齐 830000)

**摘要:**针对利用前馈神经网络实现盲均衡的网络拓扑结构选择缺乏依据的问题, 利用均衡初始阶段收集的有限长样本数据, 根据隐含层的输出信息, 通过 PLS 快速剪枝法一次性剪掉多余节点, 获得了最优的网络拓扑结构, 同时完成了对网络权系数的初始化. 在此基础上利用梯度下降算法继续对网络进行训练, 实现了对信道特性的跟踪和补偿. 计算机仿真结果表明, 该方法相对于普通剪枝算法计算复杂度低, 且具有良好的均衡性能.

**关键词:**盲均衡; 神经网络; 拓扑结构; 快速剪枝

中图分类号: TN911.5

文献标识码: A

文章编号: 1006-0707(2010)01-0129-03

盲均衡技术无需训练序列即能实现对通信信道的补偿, 消除由于信道多径时变特性<sup>[1]</sup>引起的码间干扰 (ISI: inter-symbol interference), 可有效节省通信带宽, 提高通信效率和通信质量<sup>[2]</sup>, 在现代宽带高速数字通信以及无训练序列可用的场合中 (如军事信息拦截) 具有重要的研究意义.

由于实际通信信道往往为非最小相位系统<sup>[3]</sup>, 有时具有非线性特性, 而神经网络作为 1 种非线性动态系统, 具有大规模并行处理能力, 故采用神经网络的盲均衡算法既可均衡最小相位信道, 也可均衡非最小相位信道, 包括非线性信道, 因此利用神经网络作为盲均衡器实现盲均衡具有独特的优势<sup>[4]</sup>. 但是, 利用神经网络实现盲均衡有两大难题一直没能得到较好的解决, 一是网络权重的初始化问题, 另一个是网络拓扑结构的选择问题. 目前大多数方法基于传统的神经网络, 并采用随机初始化方法和经验性设置网络结构. 研究表明网络权重的初始化方法和网络结构对网络训练性能具有重要影响. 针对这一问题, 本文中提出了 1 种基于部分最小二乘 (portion least square, PLS) 快速剪枝法<sup>[5]</sup>的神经网络盲均衡方法. 该方法在进行信道均衡初始阶段收集 1 段样本数据, 利用该段样本数据并结合 PLS 快速剪枝算法实现对网络拓扑结构的优化和网络权重的初始化.

## 1 神经网络盲均衡

### 1.1 基本原理

神经网络盲均衡原理如图 1 所示, 发送信号  $x(n)$  经过未知信道  $h(n)$  并叠加高斯白噪声  $n(n)$ , 在神经网络均衡

器前得到观测序列  $y(n)$ .




图 1 神经网络盲均衡原理

信号传输过程的公式表示为:

$$s(n) = x(n) \cdot h(n) \quad (1)$$

$$y(n) = s(n) + n(n) \quad (2)$$

如果用  $w(n)$  等效表示神经网络滤波器的卷积权系数, 则

$$\hat{x}(n) = w(n) \cdot y(n) \quad (3)$$

盲均衡的目标就是直接根据观测序列  $y(n)$  实现对发送信号  $x(n)$  的恢复以得到  $\hat{x}(n)$ , 并使得  $\hat{x}(n)$  满足

$$\hat{x}(k) = x(k - D)e^{j\phi} \quad (4)$$

式中:  $D$  为一整数时延;  $\phi$  为一常数相移. 整数时延  $D$  不影响信号的恢复质量, 常数相移  $\phi$  可通过一判决装置去除.

联合式(1)和式(3)并忽略卷积噪声项, 可得到

$$\hat{x}(n) = h(n) \cdot w(n) \cdot x(n) \quad (5)$$

可以看出, 式(4)成立的条件是信道与均衡器的联合冲击响应满足

$$h(n) \cdot w(n) = [0, \dots, 0, e^{j\phi}, 0, \dots, 0]^T \quad (6)$$

前馈神经网络盲均衡的实现可根据观测序列设定神经网络学习目标函数, 通过自适应算法对神经网络权系数进行

\* 收稿日期: 2009-11-27

作者简介: 李振兴(1977—), 男(满族), 河北承德人, 工程师, 硕士, 主要从事智能信息处理等研究.

调节使得目标函数达到最小,即使等效卷积权  $w(n)$  与信道的联合冲击响应满足式(6). 前馈神经网络盲均衡常利用 CMA 算法的代价函数作为网络训练的目标函数,学习算法采用误差反传(BP)算法.

### 1.2 前馈神经网络盲均衡算法

Cybenco 已经证明,用 1 个隐层的前馈神经网络(feed-forward neural network, FNN)可以任意精确度逼近任意的连续函数,所以文中采用 3 层 FNN 结构作为盲均衡器,对前馈神经网络盲均衡算法进行分析,其结构如图 2 所示.




图 2 三层前馈神经网络结构

图 2 中:  $w_{ij}(n)$  ( $i=1, 2, \dots, m, j=1, 2, \dots, n$ ) 为输入层与隐层单元的连接权重;  $w_j(n)$  ( $j=1, 2, \dots, n$ ) 为隐层单元与输出层单元的连接权重. 设隐层单元的输入为  $u_j(n)$ , 隐层单元输出为  $v_j(n)$ , 输出层单元的输入为  $I(n)$ , 这样网络的状态方程为:

$$u_j(n) = \sum_{i=1}^m w_{ij}(n) \tilde{x}(n-i) \quad (7)$$

$$v_j(n) = f[u_j(n)] \quad (8)$$

$$I(n) = \sum_{j=1}^n w_j(n) v_j(n) \quad (9)$$

$$\tilde{x}(n) = f[I(n)] \quad (10)$$

式中:  $f(\cdot)$  为神经网络的传递函数,这里选取神经网络的传递函数为

$$f(x) = \lambda \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

为保证传递函数的单调性,要求传递函数的导函数恒大于零,这就要求调节参数  $\lambda$  大于零. 根据信号幅度的不同,选取不同的  $\lambda$  值. 如果信号幅度较大,选用较大的  $\lambda$ ; 反之,则选择较小的  $\lambda$ .

结合常数模代价函数可给出神经网络盲均衡的代价函数为<sup>[6]</sup>

$$J_D = \frac{1}{2} [|\tilde{x}(n)|^2 - R_{CM}]^2 \quad (12)$$

其中

$$R_{CM} = \frac{E(|\tilde{x}(k)|^4)}{E(|\tilde{x}(k)|^2)} \quad (13)$$

利用 BP 算法的神经网络迭代算法如下:

$$w(n+1) = w(n) - \mu \frac{\partial J_D}{\partial w(n)} \quad (14)$$

$$\frac{\partial J_D}{\partial w(n)} = 2 \{ \tilde{x}^2(n) - R_{CM} \} \tilde{x}(n) \frac{\partial \tilde{x}(n)}{\partial w(n)} \quad (15)$$

对于输出层

$$\frac{\partial \tilde{x}(n)}{\partial w_j(n)} = f'[I(n)] v_j(n) \quad (16)$$

联合式(14)~(16),有

$$w_j(n+1) = w_j(n) + \mu H(n) v_j(n) \quad (17)$$

式中:  $\mu$  为迭代步长.

$$H(n) = -2 \{ \tilde{x}^2(n) - R_{CM} \} \tilde{x}(n) f'(I(n)) \quad (18)$$

对于隐层

$$\frac{\partial \tilde{x}(n)}{\partial w_{ij}(n)} = f'[I(n)] \frac{\partial I(n)}{\partial w_{ij}(n)} \quad (19)$$

而

$$\frac{\partial I(n)}{\partial w_{ij}(n)} = w_j(n) f'[u_j(n)] y(n-i) \quad (20)$$

将式(19)、(20)代入式(14)得到

$$w_{ij}(n+1) = w_{ij}(n) + \mu H_j(n) y(n-i) \quad (21)$$

式中:  $H_j(n) = f'[u_j(n)] w_j(n) H(n)$ .

## 2 PLS 算法基本原理

假设 2 个数据矩阵  $X$  和  $Y$  满足关系式(22)

$$Y = X\beta + e \quad (22)$$

式中:  $X \in \mathbf{R}^{n \times m}$ ;  $Y \in \mathbf{R}^{n \times l}$ ;  $e$  为噪声项. 那么对参数  $\beta$  的估计值可以用最小二乘法得到<sup>[7]</sup>

$$\beta = (X^T X)^{-1} X^T Y \quad (23)$$

用最小二乘法对参数  $\beta$  进行估计时,如果数据矩阵  $X$  具有较强的相关性,那么式(23)中将会存在 1 个对病态矩阵求逆的问题,估计结果误差会很大. 而部分最小二乘算法则可避免对病态矩阵进行求逆. 其原理是将式(23)中的矩阵  $X$  和  $Y$  的关系分解为 2 个内部关系,如式(24)和式(25),以及 1 个外部关系,如式(26):

$$X = TP^T + E = \sum_{h=1}^a t_h p_h^T + E \quad (24)$$

$$Y = UQ^T + F = \sum_{h=1}^a u_h q_h^T + F \quad (25)$$

其中:  $T, U$  为  $X$  和  $Y$  的得分矩阵,  $T = [t_1, t_2, \dots, t_a]$ ,  $U = [u_1, u_2, \dots, u_a]$ ;  $t_h, u_h$  为矩阵  $X$  和  $Y$  的第  $h$  个主元,  $h=1, 2, \dots, a$ ;  $a$  为数据矩阵中主成分的个数,可以由交叉验证法确定;  $P, Q$  为荷载矩阵,  $P = [p_1, p_2, \dots, p_a]$ ,  $Q = [q_1, q_2, \dots, q_a]$ .

外部关系  $U$  和  $T$  可表示为

$$U = TB + R = \sum_{h=1}^a b_h t_h + R \quad (26)$$

式(24)~(26)中  $E, F, R$  为残差矩阵.

PLS 是一种将高维空间信息投影到由几个相互独立的主成分组成的低维信息空间去的多变量回归方法,主要是

为了解决自变量中存在的多重相关性问题,他在进行成分提取时,综合考虑了自变量和因变量中的信息,要求从自变量中提取的主成分不仅要最好地概括自变量中的信息,而且必须对因变量具有最强的解释性。这样,对因变量无解释作用的噪声就自然地排除掉了。由此可见,PLS 方法不但能消除原始数据间的多重共线性影响,还能处理含有噪声的数据。

### 3 PLS 剪枝法的神经网络盲均衡

普通剪枝算法先从 1 个足够大的网络开始,待其训练收敛后再逐个剪去隐含层节点,并重新训练网络,直至得到满足要求的最小网络结构。普通剪枝算法属于 1 种试探性的探索方法,需要反复重构、训练和测试网络,故计算复杂度相当高。在神经网络盲均衡中,输出单元为 1,所以主要考虑隐层单元对网络性能的影响。本文中根据 PLS 剪枝算法利用均衡初始阶段收集的小段样本数据对网络拓扑结构进行优化,同时获得 1 组渐近最优的网络初始化权重,在此基础上继续利用梯度下降算法对网络进行训练以实现通信信道的跟踪和补偿,具体步骤如下。

1) 将均衡初始阶段收集的小段样本数据分为  $m$  组,每组的样本数据长度为  $l$ ,对应的隐层节点数取为  $l$ ;

2) 将第  $i$  组接收数据作为输入矩阵  $X$ ,并根据输出获得输出矩阵  $Y$ ,训练误差限设定为  $\epsilon$ ,当训练满足误差收敛条件时,转到步骤 3);

3) 记录此时的隐层输出矩阵  $G$ ,连接权系数  $W$ ,输出矩阵  $Y$ ,对矩阵  $G$  和  $Y$  提取 PLS 主成分  $T = [t_1, t_2, \dots, t_a]$ ;

4) 依次对每个  $t_i (1 \leq i \leq a)$  计算出其与每个隐含层节点输出向量间的相关系数,并从中选取最大相关系数值对应的节点(且无重复)作为保留节点,最终保留节点个数即为主成分个数  $a$ ;

5) 转到步骤 2) 选择下 1 组样本数据  $i = i + 1$ ,重复步骤 3) 和 4),直到第  $m$  组数据输入完成;

6) 删除多余节点,在此网络拓扑结构和网络权系数条件下继续利用梯度下降算法训练网络,实现盲均衡。

### 4 计算机仿真

仿真发送信号采用等概率二进制序列,调制方式为 BPSK,接收观测信号叠加零均值带限高斯白噪声。均衡初始阶段采集 500 点数据作为样本数据,学习步长  $\mu = 0.001$ ,则非线性信道<sup>[8]</sup>的输出为:

$$y(n) = x(n) + 0.2x^2(n) + 0.15x^3(n) + v(n) \quad (27)$$

$$x(n) = 0.5s(n) + s(n-1) \quad (28)$$

相应的网络初始拓扑结构设定为 (20, 25, 1),采用 PLS 快速剪枝算法对网络结构进行优化后获得网络结构为 (20, 16, 1);而传统剪枝算法优化后获得的网络结构为

(20, 20, 1)。在信噪比为 15 dB 的条件下,200 次蒙特卡洛仿真获得的均方误差曲线如图 3 所示,不同信噪比条件下的误码率曲线如图 4 所示。

从图 3 中可看出,基于 PLS 快速剪枝算法的前馈神经网络盲均衡 (PLSP-FNN) 相对直接前馈神经网络 (FNN) 和传统剪枝算法的前馈神经网络盲均衡 (TP-FNN) 具有更快的收敛速度和收敛后稳态剩余误差。在不同信噪比条件下的仿真结果可以看出,PLSP-FNN 方法具有更好的均衡性能。

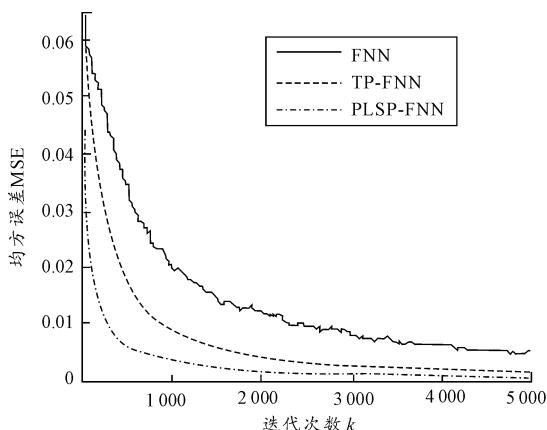


图 3 均方误差收敛曲线




图 4 误码率曲线

### 5 结束语

采用 PLS 快速剪枝法的神经网络盲均衡算法利用均衡初始阶段接收的小段样本数据就可实现对网络拓扑结构的优化;多余节点的剔除则减小了网络规模,同时降低了计算复杂度。该方法优于传统的剪枝算法,同时加快了神经网络盲均衡算法的收敛速度和均衡性能,具有实用性。由于剪枝只在均衡初始阶段,其并不影响利用附加动量法或自适应学习步长等来获得更好的均衡效果。

(下转第 143 页)