

一种改进的递归神经网络盲均衡算法

徐 戎

(中国科学院研究生院 北京 石景山区 100039)

【摘要】提出了一种新的基于递归神经网络的快速收敛盲均衡算法。设计中采用观测信号的四阶统计量构造代价函数，简化了系统的复杂度；利用实时递归学习算法对系统参数进行动态调节。该算法具有镇定性，其收敛性能不会受到失真信道的影响，适用于均衡衰落性严重的信道。实验仿真结果表明对具有频率选择性衰落的非线性信道，该算法在收敛速度和对抗码间串扰方面都具有良好的性能。

关键词 盲均衡；代价函数；非线性信道；递归神经网络
中图分类号 TP183 文献标识码 A

An Improved Blind Equalization Algorithm Based on Recurrent Neural Networks

XU Rong

(Graduate University of Chinese Academy of Sciences Shijingshan Beijing 100039)

Abstract A novel fast convergence blind equalization algorithm based on recurrent neural network is proposed. Four-order statistics of the observation signals are used to calculate the cost function in order to simplify the complexity of the equalization system. Real-time recursion training algorithm is used to dynamically adjust the system parameters. The blind equalization algorithm is “equanimous” and the characteristic of convergence is not influenced by distortion of channel, it is fit for equalizing deep attenuation channel. Simulation results show that the algorithm has good performance on convergence speed and compensating for inter-symbol interference created by multi-path within non-linear channel.

Key words blind equalization; cost function; non-linear channel; recurrent neural network

在高速数字传输系统中，由于信道多径效应的影响会产生码间干扰(Inter Symbol Interference, ISI)，必须使用均衡方法来消除ISI。该方法通常将接收到的信号通过一个特性与信道特性相反称为均衡器的滤波器。均衡器的参数需要不断地调整以跟踪信道的变化，即为自适应均衡^[1]。

自适应均衡可以分为有训练的均衡算法和盲均衡算法两大类。本文提出的递归神经网络的盲均衡算法(Recurrent Neural Network Equalizer, RNNE)基于梯度算法的盲均衡算法^[2-4]，充分利用了递归神经网络规模小、性能优的特点，在系统性能和实现复杂度上进行了折衷。

1 问题陈述

均衡算法中的盲均衡算法不需要训练序列，利用输出信号序列的高阶统计特性进行均衡^[5]。常见

的算法有常模算法^[6](Constant Modulus Algorithm, CMA)，通过调整均衡滤波器的权系数最小化代价函数为 $J_p(\mathbf{c}) = 1/2E\{(|\hat{x}|^p - R_p)^2\}$, $p = 1, 2, \dots$ ，其中 R_p 为常模。可以通过计算信号序列的高阶统计量得到

$$R_p = \frac{E\{|x(t)|^{2p}\}}{E\{|x(t)|^p\}}$$

采用Godard算法^[7]，令 $p = 2$ ，则均衡器系数通过梯度学习的方法计算为 $c(t+1) = c(t) - \gamma(|\hat{x}(t)|^2 - R_2)\hat{x}(t)\hat{y}_e(t)$ ，其中 γ 为收敛速率。由于代价函数的非U性，这种随机梯度下降的算法可能陷入局部极小点而难以获得最优解。改进的递归神经网络盲均衡算法可以减少均衡器的局部极小点，弥补代价函数非U性引起的缺陷。

2 递归神经网络

递归神经网络(Recurrent Neural Networks, RNN)是一种常见的神经网络^[3]，在RNN中每个神经元都

与其他所有神经元互连,是高度非线性的动力系统。RNN的学习算法有RLS算法及实时递归学习算法(Real Time Recursive Learning, RTRL)^[8]等。

RTRL算法描述如下:

具有单层神经元的递归神经网络的方程为:

$$\begin{cases} s_k(t) = \sum_{l=1}^n w_{kl} y_l(t) + \sum_{l=n+1}^{n+m} w_{kl} x_l(t) \\ y_k(t+1) = f(s_k(t+1)) \end{cases} \quad (1)$$

该方程具有 n 个输出反馈单元和 m 个前向输入单元,阈值为零。

(1) 前向阶段:计算神经元在 $t+1$ 时刻的输出。

(2) 学习阶段:令 $d_k(t+1)$, $k=1,2,\dots,n$ 是第 k 个神经元在时刻 $t+1$ 的预定输出,定义第 k 个神经元的训练误差为:

$$e_k(t+1) = d_k(t+1) - y_k(t+1)$$

网络的瞬时总误差为:

$$J(t+1) = \frac{1}{2} \sum_{k=1}^n e_k^2(t+1)$$

算法的目的是调整联结权的 w_{ij} 值,使 $J(t+1)$ 最小。

定义“灵敏度”函数为:

$$p_{ij}^k(t) = \frac{\partial y_k(t)}{\partial w_{ij}}$$

学习阶段的步骤包括评价“灵敏度”函数和沿最陡下降方向更新权值,即:

$$\begin{aligned} p_{ij}^k(t+1) &= f'(s_k(t+1)) [\sum_{h=1}^n w_{kh}(t) p_{ij}^h(t) + \delta_{ik} z_j(t)] \\ w_{ij}(t+1) &= w_{ij}(t) + \alpha \sum_{k=1}^n e_k(t+1) p_{ij}^k(t+1) \\ \alpha &> 0, i=1,2,\dots,n, k=1,2,\dots,n \\ j &= 1,2,\dots,n, n+1,\dots, n+m \end{aligned} \quad (2)$$

式中

$$\delta_{ip} = \begin{cases} 1 & i = p \\ 0 & i \neq p \end{cases}$$

$$f'(x) = \frac{4}{[\exp(x) + \exp(-x)]^2}$$

$z_j(t)$ 分别代表RNN的内部结点反馈输出($j=1,2,\dots,n$)及输入信号($j=n+1,\dots,n+m$); α 为自适应过程的学习步长。

递归神经网络盲均衡算法的系统如图1所示。




图1 递归神经网络盲均衡算法的系统框图

利用信号的高阶统计特性构造代价函数,通过最小化代价函数达到调整权值的目的。采用递归神经网络盲均衡算法^[2]的代价函数为:

$$J(t+1) = \sum_{k=1}^4 \alpha_k e_k(t+1) = \sum_{k=1}^4 \alpha_k (E_{t+1}\{\hat{x}^k\} - E\{x^k\})^2$$

式中 递归神经网络采用具有一个输出反馈结构和三个内部输入反馈结构的模型; E_{t+1} 为应用递归神经网络开始 $t+1$ 时刻输出得到的估计均值; α_k 为正常数。定义了相应误差的权值,根据 $t+1$ 时刻的 $\hat{x}(t+1)$ 计算更新递归神经网络的权值,代价函数中的均值可以递归计算为:

$$E_{t+1}\{\hat{x}^k\} = \frac{1}{t+1} (t E_t\{\hat{x}^k\} + \hat{x}^k(t+1)) \quad (3)$$

对 $J(t+1)$ 以 w_{ij} 进行微分可得:

$$\frac{\partial J}{\partial w_{ij}}(t+1) = -\frac{2}{t+1} \left\{ \sum_{k=1}^4 \alpha_k (E_{t+1}\{\hat{x}^k\} - E\{x^k\}) k x^{k-1}(\hat{t}+1) \right\} \frac{\partial \hat{x}(t+1)}{\partial w_{ij}} \quad (4)$$

式中 $\frac{\partial \hat{x}(t+1)}{\partial w_{ij}} = p_{ij}^k(t+1)$, 可以由式(2)计算得到。

3 改进的递归神经网络盲均衡算法

算法的改进主要是对代价函数的简化,由于上面的算法代价函数利用了信号的高阶统计量,参数比较多,计算复杂。通过和CMA算法结合,可以将代价函数化简为两项,即:

$$J(t+1) = \sum_{k=1}^2 \alpha_k e_k(t+1) = \sum_{k=1}^2 \alpha_k (E_{t+1}\{\hat{x}^k\} - R_k)^k$$

式中 $R_k = \frac{E\{x^{2k}\}}{E\{x^k\}}$ 。同样代价函数的梯度矢量也得到了简化,由式(4)可得:

$$\frac{\partial J}{\partial w_{ij}}(t+1) = \frac{1}{t+1} \{ \alpha_1 + 4\alpha_2 (E_{t+1}\{\hat{x}^2\} - R_2) \times x(\hat{t}+1) \} \frac{\partial \hat{x}(t+1)}{\partial w_{ij}}$$

式中 $\frac{\partial \hat{x}(t+1)}{\partial w_{ij}} = p_{ij}^k(t+1)$ 可以由式(2)计算得到。

简化后算法依然利用了信号的4阶统计特性,但在计算量上得到了简化,代价函数的梯度矢量中只需计算信号的2阶和4阶统计量。

4 算法的仿真验证

利用随机数据产生器作为信号源,产生了双极性的随机序列 $\{x_r[n], x_l[n]\}$ ($x_r[n] + jx_l[n]$), 随机取

为 $\{\pm 1, \pm 1\}$ 。随机信号通过信道传输，信道性质由一个三系数FIR滤波器刻画，滤波器的系数分别为 $0.3 + 0.35j, 0.9 + 0.8j, 0.3 + 0.35j$ 。在信道输出经过非线性处理如图2所示，增益系数 $D_2 = 1, D_3 = 0.5, D_4 = 0.5$ ，加入了方差为 σ^2 的复高斯白噪声，信噪比为 20 dB。RNN网络选择具有 $n = 3$ 个输出反馈单元和 $m = 1$ 个前向输入单元，阈值为零。初始化权值 $w_{ij} < 0.1$ ，自适应过程的学习步长初始值 $\alpha = 1$ ，代价函数中的参数设为 $\alpha_1 = \alpha_2 = 1$ ，激励函数为：

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$$




图2 非线性信道模型




图3 CMA算法




图4 改进RNN算法

图3、图4对比了采用CMA算法和改进RNN算法的均衡性能。从仿真结果可知，改进的RNN算法比CMA算法具有更好的性能。

图5、图6所示为算法改进前后RNN收敛速度的比较。改进后的算法具有更快的收敛速度，波动较小，而且降低了计算复杂度。




图5 一般RNN算法




图6 改进RNN算法

5 结论

本文提出了改进的基于递归神经网络算法可以有效地处理盲均衡问题，其性能和收敛速度优于CMA算法及一般RNN算法；通过简化代价函数降低了运算量。利用实时递归学习算法对系统参数进行动态调节，适用于均衡具有非线性失真和衰落的信道。

由于递归神经网络本身反馈的特点，对于具有U性的代价函数容易陷入局部最小点，无法获得全局最优解。对于代价函数的简化在一定程度上也是为了弥补这一缺陷。

(下转第287页)

100%的氧气。且响应时间和恢复时间分别约为50 s和60 s。




图5 Silica-Ni-P敏感复合镀层分别在100%的氮气和100%的氧气环境中的响应时间和重现性

2.6 寿命及稳定性

对传感器进行了长达4个月的考察, Silica-Ni-P敏感复合镀层各项性能都没有发生变化,其使用寿命约4个月。另外还对Silica-Ni-P敏感复合镀层对光照的稳定性进行了考察。在100%的氮气环境中,该复合镀层在469 nm的激发光下连续照射1 h,其荧光强度基本上没有发生变化(仅下降了不到0.1),如图5所示,表明该复合镀层对激发光有很好的稳定性。

3 结论

采用以铜网做基材进行化学镀得到的Silica-Ni-P复合化学镀层为支持体系,用敏感物质 $[Ru(bpy)_3]Cl_2$ 处理后,对气态氧响应特性的实验结果表明:该法对气态氧有着较好的响应,符合Stern-Volmer方程;重现性和稳定性良好,寿命长达4个月;该敏感复合镀层全固态,且惰性,可以防止

外界水蒸气进入支持体系内部而使荧光染料溶解泄漏。因此,该法提供了一种全新的固定敏感物质的方法。

本文研究工作得到西南科技大学青年预研基金项目(ZK043002)资助,在此表示感谢。

参 考 文 献

- [1] CHOI M F, XIAO D. Oxygen-sensitive reverse-phase optode membrane using silica gel-adsorbed ruthenium() complex embedded in gelatin film[J]. *Anal. Chim. Acta.*, 1999, 387(2): 197-205.
- [2] YUTAKA A A, ICHIRO O. Optical oxygen sensing materials: chemisorption film of ruthenium() polypyridyl complexes attached to anionic polymer[J]. *Sens.. Actuators B*, 2003, 88(2): 162-167.
- [3] CHOI M F, XIAO D. Single standard calibration for an optical oxygen sensor based on luminescence quenching of a ruthenium complex[J]. *Anal. Chim., Acta.*, 2000, 403(1-2): 57-65.
- [4] 李 宁, 袁国伟, 黎德育. 化学镀镍基合金理论与技术[M]. 哈尔滨: 哈尔滨工业大学出版社, 2000: 89-90.
- [5] KNEAS K A, DEMAS J N, NGUYEN B. Method for measuring oxygen diffusion coefficients of polymer films by luminescence quenching[J]. *Anal. Chem. Acta.*, 2002, 74(5): 1111- 1118.
- [6] AMAO Y, ASAI K, OKURA I, et al. Platinum porphyrin embedded in poly(1-trimethylsilyl-1-propyne) film as an optical oxygen sensor for trace analysis of oxygen[J]. *Analyst*, 2000, 125(11): 1911-1914.

编辑 孙晓丹

(上接第212页)

参 考 文 献

- [1] CARDOSO J F, LAHELD B H. Equivariant adaptive source separation[J]. *IEEE Trans. on Signal Processing*, 1996, 44(12): 3017-3029.
- [2] KECHRITIS G, ZERVAS E, MANOLAKOS E S. Using recurrent neural networks for adaptive communication channel equalization[J]. *IEEE Trans. on Neural Network*, 1994, 5(2): 267-278.
- [3] ICCHI P G, PRATI G. Blind equalization and carrier recovering using a " Stop-and-Go " decision directed algorithm [J]. *IEEE Trans. on Commun.*, 1987, 35(9): 877-887.
- [4] ZQT LUO, MENG M, WONG K M, et al. A fractionally spaced blind equalizer based on linear programming[J]. *IEEE Trans. on SP*, 2002, 50(7): 1650-1659.
- [5] PORAT B, FRIEDLANDER B. Blind equalization of digital communication channels using high-order moments[J]. *IEEE Trans. on SP*, 1991, 39(2): 522-526.
- [6] 徐金标, 葛建华, 王育民. 基于CMA算法的双模式盲均衡算法[J]. *通信学报*, 1997, 18(2): 65-69.
- [7] GODARD D J. Self-recovering equalization and carrier tracking in two dimensional data communication systems[J]. *IEEE Trans. Commun.*, 1980, 28: 1867-1875.
- [8] WILLIAMS R J, ZIPSER D. A learning algorithm for continually running fully recurrent neural networks[J]. *Neural Computation*, 1989, 1: 270-280.

编辑 黄 莘