

# 基于前馈神经网络的自适应回声消除方法

崔海徽, 王石刚, 王高中  
(上海交通大学 机电设计与自动化所, 上海 200030)  
蒋志辉  
(三一重工股份有限公司, 长沙 410100)

**摘要:** 回声消除常用的 LMS 算法收敛性差, 而收敛性好的 RLS 算法计算量大。文章中提出一种全新的求解方法: 基于前馈神经网络的自适应回声消除方法。把回声消除模型中求解滤波器系数的问题转化为前馈神经网络神经元权值的训练问题, 并运用误差反向传播算法(BP 算法)得出神经元权值的递推公式。经仿真计算, 能较好地实现回声消除, 与原传统算法 LMS 和 RLS 计算比较: 该方法能得到非常高的计算精度和明显优越的收敛性能, 而计算量只有 RLS 算法的一半。

**关键词:** 回声消除; 前馈神经网络; 自适应滤波

中图分类号: TN12.2, TP183, 文献标识码: A 文章编号: 1000-3630(2004)02-0124-04

## A novel adaptive method for echo cancellation based on feedforward neural networks

CUI Hai-hui, WANG Shi-gang, WANG Gao-zhong

(Institute for Mechatronic Design and Automation Technology, Shanghai Jiaotong Univ., Shanghai 200030, China)

JIANG Zhi-hui

(Sany Heavy Industry Limited Co., Changsha 410100, China)

**Abstract:** The LMS algorithm widely used in echo cancellation performs poorly in terms of convergence, and the RLS algorithm with good convergence characteristics, on the other hand, needs considerably more computation overhead. A novel adaptive method based on feed-forward neural networks for echo cancellation is proposed in this paper. Computation of filter weights is converted into training of neural network weights. Recursive formulas of the neuron weights are derived with the BP algorithm. Simulations show that the algorithm has a better performance in echo cancellation. The results of echo calculation indicate that the precision and convergence are significantly improved compared to LMS and RLS algorithms, and the computation overhead is only half of the RLS algorithm.

**Key words:** echo cancellation; feed-forward neural networks; adaptive filter

## 1 引言

回声反馈是电声仪器中的常见问题, 如电话、助听器等都存在此问题。回声反馈严重影响语音信号的质量, 常常产生啸叫、笛鸣等噪音问题, 并且降低系统的增益, 改变了系统的响应<sup>[1,2]</sup>。

回声的产生是由于语音输出端有部分语音信号反馈到麦克风, 如图 1 所示, 输出信号  $s(n)$  在输出端通过反馈路径反馈回输入端。这个反馈路径包括仪器本身反馈路径和声学反馈路径<sup>[1]</sup>, 其两者用传递函数  $H(z)$  表示, 用  $G(z)$  表示仪器的系统目标传递函数, 则带回声反馈的系统传递函数为  $G/(1-GH)$ 。分析传递函数可得: 当  $|GH| > 1$  并且  $GH = k360$  ( $k$  是整数) 时, 系统将不稳定。换言之, 当某个频率的信号的回声信号回到麦克风时, 正好与原信号同相且声压级相当或更大, 就会发生振荡。当  $G(z)$

含有较大增益时, 振荡更易发生<sup>[2]</sup>。

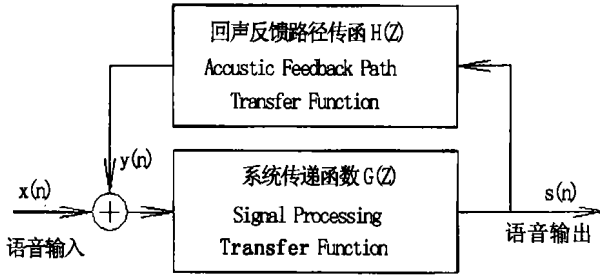


图 1 回声产生原理图

目前最常用的回声消除方法, 是在系统中制造一路信号, 与回声信号抵消<sup>[3]</sup>。如图 2, 在系统中设置一个滤波器  $W(z)$ , 用来生成信号  $\hat{y}(n)$ , 使其接近回声信号  $y(n)$ , 并在系统输入端减去  $\hat{y}$  抵消  $y(n)$ , 以达到回声消除的目的。

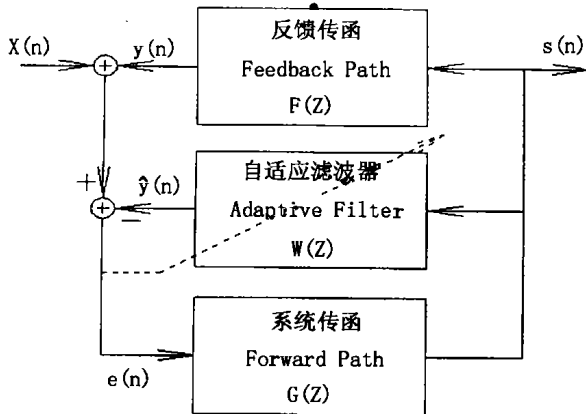


图 2 回声消除原理图

由于回声反馈的传递函数根据环境会有很大变化, 这就要求采用自适应回声消除<sup>[1]</sup>。具体方法是采用自适应滤波器, 在估计误差  $(e(n) = \hat{y} - y(n))$  的最小均方差意义下不断调整滤波器系数  $W$ , 以实时模仿出反馈传递函数  $H(z)$ , 也实时估计出回声信号  $y(n)$ , 从而实现回声消除<sup>[2]</sup>。

目前广泛应用于自适应回声消除的是 LMS (Least Means Square) 算法, 同时针对回声消除的 RLS (Recursive Least Means) 算法正在广泛研究中<sup>[4]</sup>。回声消除使用 LMS 算法的原因是 LMS 算法简单, 计算量小, 但存在收敛慢的问题, 尤其是在信号相关性大时, 收敛更差<sup>[5]</sup>。而语音信号相关性恰好很大。另一方面, RLS 算法收敛较 LMS 快, 但因其计算量大 ( $O(N^2)$ ) 和较差的数值性能, 使其没能在产品上应用起来, 一些 RLS 算法如 FTF, 计算不太复杂, 但数值性能不太稳定<sup>[4]</sup>。

本文提出了一种应用于自适应回声消除的前馈神经网络方法。即把神经元权值等价于自适应滤波

器权系数, 把求解最佳滤波器权系数的问题转变为前馈神经网络的训练过程。从本质上看, 两者在目标函数上是一致的, 且该方法从总体上使估计误差趋于最小, 从而能得到较为精确的滤波器系数。前馈神经网络常常计算复杂, 但本文根据回声消除问题的特点提出了一种简化网络, 且训练过程采用误差反向传播算法 (BP 算法) 来实现, 使计算量大大降低。




图 3 回声消除系统模型

## 2 回声消除系统模型

回声消除的基本原理是用一个自适应滤波器模拟回声路径, 通过自适应滤波算法的调整, 使其冲激响应与实际回声路径相逼近, 从而得到回声预测信号, 再将预测信号从麦克风接收到的语音信号中减去, 即可实现回声抵消。回声消除模型如图 3 所示。

估计信号为:

$$\hat{d}(n) = \sum_{i=1}^M w_i(n)x(n-i+1) = W^T(n)X(n) \quad (1)$$

估计误差为:

$$e(n) = \hat{d}(n) - d(n) = W^T(n)X(n) - d(n) \quad (2)$$

其中

$$W^T(n) = \{w_1(n), w_2(n), \dots, w_M(n)\}$$

$$X(n) = \{x(n), x(n-1), \dots, x(n-M+1)\}$$

LMS 回声消除算法定义目标函数为:

$$J(n) = E[e^2(n)]$$

并按下式调整滤波器系数:

$$W(n+1) = W(n) + \frac{1}{2}ue(n)X(n) \quad (3)$$

RLS 回声消除算法详见文献[6]。由此可见回声消除模型的核心是不断调整滤波器权系数  $W$ , 以使  $\hat{d}(n)$  不断地最佳接近于  $d(n)$ 。

## 3 基于简化前馈神经网络的回声消除实现方法

由式(1)表达的最佳滤波器系数求解模型可采

用简化的三层前馈神经网络实现, 如图 4 所示, 它包括输入层、一个隐层和输出层。输入层有  $N$  个神经元, 是时间上顺序采样的  $N$  个离散语音信号。隐层仅有一个神经元, 用于对输入层的前馈进行加权求和处理。输出层也仅有一个神经元, 输出值为根据上述  $N$  个采样值估计出信号  $\hat{d}(n)$ 。输入层到隐层的连接权为  $W_1, W_2, \dots, W_N$ 。

在此前馈神经网络中, 设定隐层单元的阈值为  $\theta = 0$ , 变换函数为  $f(S) = S$ , 则该神经网络的输入输出变换关系为:

$$S = \sum_{i=1}^N w_i x(n-i+1) - \theta = \sum_{i=1}^N w_i x(n-i+1) \quad (4)$$

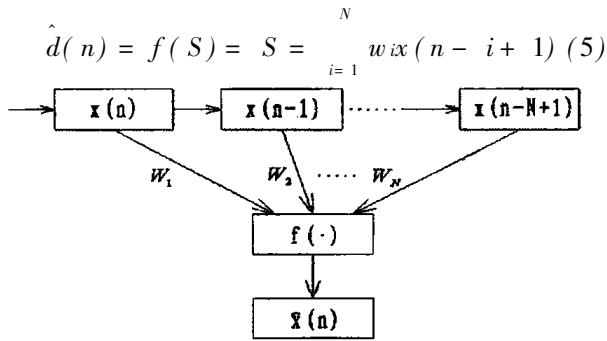


图 4 本文采用的神经网络实现方法

式(4)和式(5)表明, 该神经网络的输入输出函数为 FIR 滤波器的一种实现形式, 采用该前馈神经网络, 就可以把求解最佳滤波器系数问题转化为前馈神经网络的连接权值的训练问题。采用语音采样序列对神经元进行训练, 反复训练可得到稳定的神经元连接权值, 亦即最佳滤波器系数。

取同一语音单元内近似平稳的一段语音采样点  $x(n), x(n-1), \dots, x(m)$ , (假定取  $m-n=N$ ), 就可得到如下一组共  $m-n-N+1$  个训练样本: 输入  $[x(p), x(p-1), \dots, x(p-N+1)]$ , 输出  $\hat{d}(p)$ ,  $p=n, \dots, m-N$ , 反馈神经网络的训练可采用单层的前馈网络误差反向传播算法(BP 算法)进行。设取估计误差总能量为代价函数:

$$E = \sum_{p=n}^{m-N} [d(p) - \hat{d}(p)]^2 = \sum_{p=n}^{m-N} \left[ x(p) - \sum_{i=1}^N w_i x(p-i+1) \right]^2 = \sum_{p=n}^{m-N} e^2(p) \quad (6)$$

训练的目标就是调整连接权系数以使代价函数  $E$  最小。这与自适应滤波器的求解准则是一致的。

由式(6)可看出,  $E$  实际上为连接权系数  $W_i$  的二次多项式, 因此, 它存在唯一的极值(最小值)。前馈网络经训练后, 估计误差总能量将向最小值收敛, 故不存在收敛到局部极值的情况。

根据式(5)、式(6)和 BP 算法<sup>[7]</sup>, 可得如下连接权系数逆推训练公式。

$$w_i(n) = w_i(n-1) + d_i(n)$$

$$d_i(n) = \sum_{p=n-M+1}^n x(p-i)$$

$$p = y(p) - \hat{x}(p)$$

$$\hat{x}(p) = \sum_{j=1}^N w_j(n)x(p-j+1)$$

其中  $N$  是滤波器阶数,  $M$  是滑动窗长,  $M \geq N$ 。

为避免语音信号来源和测量方法不同而导致的评价差异, 采样相对估计误差总能量(即绝对估计误差总能量与期望信号总能量的比值)

$$r = \sum_{p=n+1}^m e^2(p) / \sum_{p=n+1}^m x^2(p)$$

作为神经网络训练是否收敛的判别标准。又由于声强能量的对数特性, 数据分析上采用  $ERL = 20 \log r$  ( $ERL$ : Echo Return Loss) 代替  $r$ , 即  $ERL$  小于某一个门限值, 则认为该训练已经收敛。

### 4 仿真结果与计算分析

采用本文方法对回声消除进行了仿真计算和分析。输入信号采用一段英语语音片段(见图 5), 采样率为 8kHz。  $t_1, t_2$  和  $t_3$  段分别延迟 6ms, 8ms 和 10ms 模拟时变回声(如图 5), 采用 100 阶滤波器计算回声路径。

采用 LMS 算法、RLS 算法和本文方法进行仿真计算后, 实际聆听效果: 本文方法能有效消除回声, 且效果优于前两者。

同时比较三种方法在三段时间区域稳定后的  $ERL$  值, 并列于表 1。




图 5 一段语音信号

表 1 ERL 值对比

ERL	$t_1$	$t_2$	$t_3$
LMS	- 17.121	- 19.38	- 4.1805
RLS	- 10.466	- 10.593	- 3.0711
本文方法	- 36.392	- 36.088	- 14.584

由表 1 可见, 本文方法在消除回声反馈上, 明显优于 LMS 算法和 RLS 算法。

图 6 比较了 RLS 算法、LMS 算法和本文方法的学习曲线, 采用高斯白噪声, 采样率为 8kHz。由图可得, 本文方法的性能在多次训练后明显优于 LMS 算法和 RLS 算法, EPL 在 1100 次后收敛于 -600dB, 而 RLS 算法和 LMS 算法分别收敛于 -200dB 和 -50dB。




图 6 本文方法、RLS 和 LMS 算法学习曲线比较(白噪声输入)

表 2 比较了三种算法的计算量: LMS 算法计算量虽最小但其精度和收敛速度已经不能满足语音处理的实时性要求。虽然本文方法(取  $M = N$ )和 RLS 算法在计算量上属于同一数量级, 但前馈神经网络乘法和加法计算量都比 RLS 算法少一半以上, 尤其是  $N^2$  级的乘法, 能大大节约运行时间。

表 2 计算量对比

	LMS	RLS	本文方法
乘法	$3N$	$5N^2 + 4N$	$2N^2 + N$
加法	$2N$	$4N^2 - 1$	$2N^2 + 3N$

对于前馈神经网络方法的实施, 应该注意几个方面: (1) 选取适当的学习率: 学习率过小收敛缓慢, 学习率过大者失调量增大甚至发散, 对于白噪声可以选取  $\lambda = 0.05 \sim 0.1$ , 对于语音信号, 应该取更小, 其中对于不同的语音信号应该有不同的学习率, 如浊音的学习率比清音更小, 故对于此算法能在学习率的自动调节方面作改进, 将会有更好的效果。(2) 选取合适的计算精度: 对于不同的回声消除场合和不同的语音信号应该选取相合适的相对误差能

量门限值, 太高的精度会大大增加计算量, 这对于语音这种短时平稳信号没有多少实际意义。

## 5 结 论

(1) 提出回声消除的前馈神经网络求解方法, 结合回声消除模型提出了一种简单有效的神经网络结构, 把原自适应滤波器系数的求解问题转化为神经网络神经元的权值的训练问题。针对其网络结构, 采用误差反向传播算法(BP 算法)可以得到相对简明的迭代公式。

(2) 通过仿真计算, 本文方法能有效实现回声消除, 保持原信号的完整性。本文方法可以使误差能量迅速收敛, 从而得到非常高的计算精度。在较大迭代次数下稳定收敛于非常低的损失水平, 算法性能明显优于 LMS 算法和 RLS 算法。

(3) 在算法计算量上, 该算法虽然和 RLS 算法同属一个数量级, 但实际计算量(乘法和加法)比后者少一半以上。

(4) 对于本文提出的前馈神经网络回声消除方法, 同样适用于自适应噪声消除等类似问题。

## 参 考 文 献

- [1] Bustamante D K, Worrall T L, Williamson M J. Measurement of adaptive suppression of acoustic feedback in hearing aids [A]. International Conference on Acoustics, Speech, and Signal Processing, ICASSP-1989 (vol. 3) [C]. 1989. 2017-2020.
- [2] Maxwell J A, Zurek P M. Reducing acoustic feedback in hearing aids [J]. IEEE Transactions on Speech and Audio Processing, 1995, 3(4): 303-314.
- [3] 郑陶冶, 高翔. 基于遗传算法的自适应噪声消除[J]. 声学技术, 2003, 22(1): 26-29.
- [4] Siqueira M G, Alwan A. New adaptive-filtering techniques applied to speech echo cancellation [A]. International Conference on Acoustics, Speech, and Signal Processing, ICASSP-94 (vol. 2) [C]. 1994, II/265-II/268.
- [5] 向大威, 顾亚平, 李秀红, 许伟杰. 自适应声干扰抵消系统[J]. 声学技术, 1996, 15(1): 10-11.
- [6] 何振亚. 自适应信号处理[M]. 北京: 科学出版社, 2002. 74-75.
- [7] 焦李成. 神经网络计算[M]. 西安: 西安电子科技大学出版社, 1996. 38-40.