

神经网络自适应噪声抵消系统的性能比较与仿真

张磊 李方鑫 王建新 肖超恩

(北京电子科技学院 北京 100070)

摘要 线性自适应滤波算法(LMS、NLMS、RLS)对非线性噪声抵消效果较差。针对这一问题,研究神经网络自适应噪声抵消系统中不同隐含层神经元节点数、不同隐含层传输函数、不同神经网络学习算法以及不同信噪比原始输入下系统的噪声抵消性能。建立结构为单层隐含层,且输入层、隐含层和输出层节点数为 1-N-1 结构的神经网络模型。通过仿真分析,优化神经网络自适应噪声抵消系统中,隐含层节点数经验公式的参数取值。结果表明该系统中噪声抵消效果受到神经网络结构的影响;对于原始输入信噪比在 2 ~ 10 dB 的信号,参考输入与原始输入中噪声非线性相关;选择传输函数为 tansig,神经网络隐含层节点数使用优化后的参数取值,输出信号信噪比提高了 1.0 ~ 1.5 dB。

关键词 神经网络 自适应噪声抵消系统 隐含层节点数 信噪比

中图分类号 TP391.9

文献标识码 A

DOI:10.3969/j.issn.1000-386x.2018.12.049

PERFORMANCE COMPARISON AND SIMULATION OF ADAPTIVE NOISE CANCELLATION SYSTEM BASED ON NEURAL NETWORK

Zhang Lei Li Fangxin Wang Jianxin Xiao Chaoen

(Beijing Electronic Science and Technology Institute, Beijing 100070, China)

Abstract The linear adaptive filtering algorithm such as LMS, NLMS and RLS has a poor performance in handling nonlinear noise cancellation. To solve this problem, we studied the noise cancellation performance in the neural network adaptive noise cancellation system with number of nodes in different hidden layers, transfer functions in different hidden layer, different neural network learning algorithms and originated input with different signal-to-noise ratio (SNR). We established a neural network model with single hidden layer, in which the number of nodes in input layer, hidden layer and output layer was 1-N-1. Through simulation analysis, the range of parameter in empirical formula for the number of nodes in hidden layer was optimized in the adaptive noise cancellation system based on neural network. The results show that the structure of neural network has influence on the noise cancellation performance. For the original input signal with SNR of 2 ~ 10 dB, the reference input is nonlinearly related to the noise in original input, tansig is selected as the transfer function, and the number of hidden layer nodes in the neural network uses the optimized parameter value, and the SNR of the output signal improves by 1.0 ~ 1.5 dB.

Keywords Neural network Adaptive noise cancellation system Node in hidden layer SNR

0 引言

自适应噪声抵消系统的基本要求是原始输入和参考输入中信号必须统计相关^[1]。在传统的抵消算法中,要求噪声满足线性相关的条件。然而在现实中,噪

声通道往往十分复杂,具有非线性的特性;当两路输入噪声非线性相关时,传统的自适应噪声抵消算法(LMS、NLMS、RLS)^[2-5]去噪效果难以保证,甚至产生信号失真。因此,需要寻找一种有效应对噪声非线性相关的自适应噪声抵消方法。

神经网络^[6-7]利用大量的人工神经元相互连接进

行计算,根据外界的信息改变自身的结构,主要通过调整神经元之间的权值来对输入的数据进行建模,最终具备解决实际问题的效果。目前,在神经网络的实际应用中,绝大多数的神经网络模型都采用 BP 网络及其变化形式,它是前馈型神经网络的核心部分^[8]。近年来,已有部分研究将神经网络应用于自适应噪声抵消系统中,在有源噪声控制方面取得了一定的效果。

2010 年, Miry 等^[9]提出了一种基于模糊神经网络的自适应噪声消除算法,该算法用于长距离通信信道的噪声消除,系统的主要优点是易于实施和快速收敛。2010 年,李晓艳^[11]将基于神经网络的自适应噪声抵消器与基于 LMS 算法的自适应噪声抵消器进行对比,在两路噪声信号线性和非线性相关时进行了性能比较。结果表明基于神经网络的自适应噪声抵消器在两路信号线性相关和非线性相关时,均具有良好的噪声抵消能力。2011 年,蒋威等^[12]为了提高无线电引信的抗干扰性,采用量子神经网络建立自适应干扰抵消系统,实现对无线电引信干扰噪声的自适应抵消,提高了无线电引信的抗干扰性。2012 年,周伟等^[13]研究了基于最小均方误差 LMS 准则、递推最小二乘 RLS 准则和线性神经网络 ADALINE^[14]的三种自适应噪声抵消算法。结果表明,采用 ADALINE 算法信噪比至少改善 26.6 dB,实现了高性能滤波。2014 年, Dixit 等^[15]利用神经网络实现了基于最小均方自适应滤波器算法(LMS)的自适应噪声抵消器,提出了自适应噪声抵消器的系数通过神经网络而不是数值自适应算法进行调整的方法。与直接使用 LMS 作为自适应算法相比,使用神经网络调整系数后的 LMS 算法,收敛速度更快。但是相关文献均没有考虑神经网络结构的变化对噪声抵消效果的影响。

本文基于上述问题,分别在原始输入和参考输入中,噪声线性相关和非线性相关的条件下,研究神经网络自适应噪声抵消系统不同隐含层神经元节点数、不同隐含层传输函数、不同神经网络学习算法以及不同信噪比原始输入下,系统的噪声抵消效果。

1 神经网络自适应噪声抵消系统基本原理

神经网络自适应噪声抵消系统的噪声抵消原理如图 1 所示,噪声和信号沿信道传到传感器 A、B 中。除了接收到信号 s 之外,传感器 A 还接收到一个不相关的噪声 n_1 。信号加噪声为 $s + n_1$,组成抵消系统的“原

始输入”。传感器 B 用来接收与信号不相关的,但是以某种未知的方式与噪声 n_1 相关的噪声 n_0 ,这个传感器给系统提供“参考输入”。将噪声 n_0 通过神经网络自适应滤波系统加以调整,使其产生近似为 n_1 的输出 y 。再将该输出从原始输入 $s + n_1$ 中减去,得到系统输出为 $z = s + n_1 - y$ 。

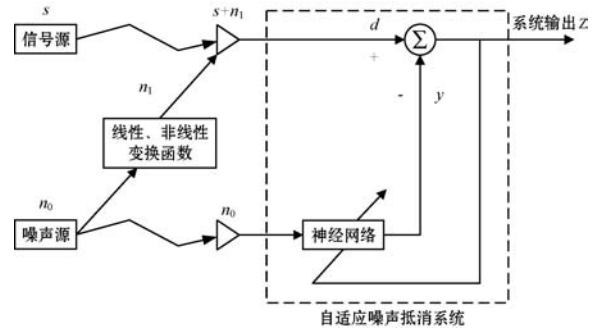


图1 神经网络算法自适应噪声抵消系统

噪声源的噪声 n_0 经过实际环境得到噪声 n_1 , 两路噪声 (n_0 和 n_1) 往往是非线性的, 可以用非线性变换来模拟实际中噪声所经过的通道。要想得到滤波器的输出 y , 必须尽可能地辨识出该非线性函数, 相当于获得自适应神经网络, 使得在获得噪声源 n_0 的条件下, 自适应神经网络无限逼近非线性变换函数, 此时 y 就能无限逼近原始输入中的噪声 n_1 。现实条件中, 由于 n_1 难以获得, 而传感器 A 能得到 d , 且 d 为信号 s 与 n_1 的叠加, s 与 n_1 不相关, 所以利用 d 替代 n_1 对网络进行训练, 完成对噪声通道的模拟, 得到系统输出为 $z = d - y$, 达到噪声抵消的目的。

2 自适应噪声抵消系统的模型

2.1 输入信号模型

噪声抵消系统的输入信号分为两个部分: 原始输入和参考输入。根据文献[11]提出的参考输入与原始输入中, 噪声信号相关性的模型, 在 MATLAB R2014a 环境下对两路输入信号进行建模, 如图 2 所示。设原始输入为 50 Hz 单频信号和 randn 函数产生的服从正态分布的随机噪声信号的线性叠加, 采样频率为 1 kHz。




图2 两路噪声信号建模

根据图 2 的模型, 在两路噪声线性相关条件下, 设参考输入 n_1 与原始输入中噪声信号 n_0 的关系为线性变换 $n_0 = n_1 + 1$ 。在两路噪声非线性相关条件下, 设参考输入 n_1 与原始输入中噪声信号 n_0 的关系为非线性

变换 $n_0 = \sin(n_1)$ 。

2.2 BP 神经网络模型

根据图 1 的噪声抵消模型,本文采用的单输入单输出 BP 神经网络结构如图 3 所示。BP 神经网络输入层、隐含层、输出层的层数各为一层。输入层节点数和输出层节点数为 1,隐含层节点数为 N 。




图 3 BP 神经网络结构

输入层节点的输出等于整个网络的输入信号 $x(n)$,隐含层第 i 个神经元节点的输入 $v_i(n)$ 等于权向量 $\omega_{1i}(n)$ 与 $x(n)$ 的乘积:

$$v_i(n) = \omega_{1i}(n)x(n) \quad (1)$$

假设 $f(\cdot)$ 是隐含层传输函数,则隐含层第 i 个神经元的输出等于:

$$u_i(n) = f(v_i(n)) \quad (2)$$

输出层节点的输入等于权向量 $\omega_{2i}(n)$ 与 $u_i(n)$ 的加权和:

$$w(n) = \sum_{i=1}^I \omega_{2i}(n)u_i(n) \quad (3)$$

假设 $g(\cdot)$ 是输出层传输函数,输出层神经元的输出等于:

$$y(n) = g(w(n)) \quad (4)$$

网络的总误差为:

$$e(n) = d(n) - y(n) \quad (5)$$

式中: $d(n)$ 为期望信号。

2.3 噪声抵消系统的评价指标

若按照信号功率来计算信噪比^[16],自适应噪声抵消系统的输入信噪比为原始输入信号中的有用信号 s 的功率与干扰噪声 n_0 的总功率之比,并将结果取以 10 为底数的对数,即:

$$SNR_{in} = 10\log_{10}\left(\frac{\sum s(n)^2}{\sum n_0(n)^2}\right) \quad (6)$$

输出信噪比为有用信号 s 与经过噪声抵消系统的剩余噪声 $z - s$ 总功率之比,将结果取对数:

$$SNR_{out} = 10\log_{10}\left(\frac{\sum s(n)^2}{\sum (z(n) - s(n))^2}\right) \quad (7)$$

式中: z 为噪声抵消系统的输出信号。

本文定义信噪比增量 ΔSNR 为:

$$\Delta SNR = SNR_{out} - SNR_{in} \quad (8)$$

3 仿真分析

根据前述模型,分别对不同隐含层节点数、不同神经网络学习算法、不同隐含层传输函数和不同信噪比原始输入下系统的噪声抵消效果进行仿真分析。

在 MATLAB R2014a 环境下,使用 newff 函数创建一个结构为 1-N-1 的 BP 神经网络(N 表示隐含层节点数)。网络的隐含层使用 tansig 或 logsig 函数,输出层使用 purelin 型线性函数,训练过程的学习速率取为 0.01,期望误差值为 0.01,学习算法^[17]使用 GD(标准梯度下降算法)、GDM(带动量的梯度下降算法)、GDA(可变学习速率梯度算法)、RP(弹性梯度算法)、LM(Levenberg-Marquardt 算法)、BFG(拟牛顿算法)、OSS(一步正割算法)。

3.1 改变隐含层节点数

隐含层节点数对 BP 神经网络性能有很大影响。一般较多的隐含层节点数可以带来更好的性能,但会导致训练时间过长。目前并没有一个理想的解析式可以用来确定合理的神经元节点数,通常的做法是采用经验公式给出估计值^[18]。

本节中,神经网络学习算法使用 LM 算法,网络的隐含层使用 tansig 函数,改变隐含层节点数,对噪声抵消系统进行仿真。

原始输入和参考输入中,噪声线性相关时(两路噪声线性相关),进行 10 次实验并对结果取平均值后,仿真结果如图 4 所示。设定原始输入信号信噪比为 -0.87 dB,输出信号信噪比随隐含层节点数增加呈下降趋势。在本节仿真的 1-N-1 网络结构中,当隐含层节点数为 1 个时,输出信号信噪比为 26.24 dB,输出信号与原始输入的 ΔSNR 为 27.11 dB,达到最佳的噪声抵消效果。




图 4 隐含层节点数仿真结果图

在两路噪声线性相关的条件下,根据实验结果,优化的单输入单输出 BP 神经网络隐含层节点数的公式为:

$$q = \sqrt{2} + a \quad (9)$$

式中:取值范围为 $[0,5]$ 的整数,计算结果向0取整。

原始输入和参考输入中,噪声非线性相关时(两路噪声非线性相关),进行10次实验并对结果取平均值后,仿真结果如图5所示。设定原始输入信号信噪比为0.42 dB,输出信号信噪比随隐含层节点数增加呈下降趋势。在本节仿真的1-N-1网络结构中,当隐含层节点数为1时,输出信号信噪比为4.76 dB,输出信号与原始输入的 ΔSNR 为5.18 dB,达到最佳的噪声抵消效果。




图5 隐含层节点数仿真结果图

在两路噪声非线性相关的条件下,根据实验结果,优化的隐含层节点数的经验公式与式(9)相同。

3.2 改变学习算法

使用式(9),在两路噪声线性相关和非线性相关的条件下,本节将隐含层节点数 q 确定为3。网络的隐含层使用 tansig 函数,神经网络学习分别使用 GD、GDM、GDA、RP、BFG、LM、OSS 算法,进行仿真。

两路噪声线性相关时,设定原始输入信号信噪比为-5.58 dB,经过神经网络噪声抵消系统后,输出的信号信噪比如图6所示。对仿真结果取10次平均后,神经网络学习算法改善效果依次为:

$$OSS > LM > BFG > RP > GDA > GDM > GD$$

其中,OSS、LM、BFG 和 RP 四种学习算法对原始输入信号的 ΔSNR 都超过了25 dB,噪声抵消效果明显优于其他3种算法。




图6 神经网络学习算法仿真结果图

两路噪声非线性相关时,设定原始输入信号信噪比为-3.34 dB,经过神经网络噪声抵消系统后,输出信号的信噪比如图7所示。在两路输入非线性相关时,神经网络噪声抵消器的改善效果较两路输入线性相关时较弱,7种学习算法中对原始输入信号的 ΔSNR 最大为6.70 dB(BFG),且经过各学习算法噪声抵消后的输出信号平均信噪比为3.11 dB,噪声抵消效果差别不大。




图7 神经网络学习算法仿真结果图

3.3 改变传输函数

logsig 函数的特点是 $(-\infty, +\infty)$ 范围的数据被映射到区间 $(0,1)$,使用的计算公式为:

$$\text{logsig}(n) = \frac{1}{1 + e^{-n}} \quad (10)$$

tansig 函数是双曲正切 sigmoid 函数,在 tansig 函数中,输出被映射在 $(-1,1)$ 内。计算公式为:

$$\text{tansig}(n) = \frac{2}{1 + e^{-2n}} - 1 \quad (11)$$

神经网络学习使用 GD、GDA、GDM、LM、OSS、RP、BFG 算法,根据式(9),在两路噪声线性相关和非线性相关的条件下,本节将隐含层节点数 q 确定为3,对网络的隐含层分别使用 logsig、tansig 函数进行仿真。各组仿真实验进行10次,并对结果取平均值。

两路噪声线性相关时,设定原始输入信号信噪比

为 -3.43 dB, 仿真结果如图 8 所示。神经网络学习使用 GD 和 GDM 算法, 经过不同传输函数得到的输出信号之间的 SNR 差值大于 3 dB; GDA、LM、OSS、RP 和 BFG 算法经过不同传输函数得到的输出信号之间的 SNR 差值小于 1 dB。结果表明, 神经网络学习使用 GD 和 GDM 算法时, 相比 logsig 函数, 噪声抵消系统使用 tansig 作为传输函数得到的输出信号, 噪声抵消效果显著; 其余五种算法由传输函数的差异产生的噪声抵消效果差别不大。




图 8 传输函数仿真结果图

两路噪声非线性相关时, 设定原始输入信号信噪比为 -2.50 dB, 仿真结果如图 9 所示。神经网络训练使用 GD 和 GDM 算法, 经过不同传输函数得到的输出信号之间的 SNR 差值小于 1.3 dB; GDA、LM、OSS、RP 和 BFG 算法经过不同传输函数得到的输出信号之间的 SNR 差值小于 0.5 dB。结果表明, 两路噪声非线性相关时, 噪声抵消系统使用 tansig 作为传输函数得到的输出信号, ΔSNR 较大, 噪声抵消效果较好; 其余五种算法由传输函数的差异产生的噪声抵消效果差别不大。




图 9 传输函数仿真结果图

3.4 不同信噪比原始输入下的噪声抵消效果

两路噪声线性相关和非线性相关时, 根据式(9), 将隐含层节点数 q 确定为 3, 隐含层传输函数使用 tansig 。设定原始输入为不同信噪比的信号, 在两路噪声线性相关和非线性相关的条件下, 比较使用 BFG、GD、GDA、LM 学习算法的噪声抵消效果。

两路噪声线性相关时, 噪声抵消系统的原始输

入和神经网络不同算法训练后, 输出信号信噪比如图 10 所示。原始输入信号的信噪比取 $-10 \sim 0$ dB 中的值, 经过系统噪声抵消后, 各算法输出信号信噪比至少提高了 2 dB, 且随着原始输入信号信噪比的提高, 系统的输出信号信噪比也在提高。结果表明, 两路噪声线性相关时, 神经网络噪声抵消系统对信噪比小于 0 dB 的输入信号有显著的噪声抵消效果。




图 10 系统的噪声抵消效果

两路噪声非线性相关时, 噪声抵消系统的原始输入和神经网络不同算法训练后, 输出信号的信噪比如图 11 所示。原始输入信号的信噪比取 $2 \sim 10$ dB 中的值, 经过系统噪声抵消后, 各算法输出信号信噪比平均提高了 $1 \sim 1.5$ dB, 且随着原始输入信号信噪比的提高, 系统的输出信号信噪比也在提高。结果表明, 两路噪声非线性相关时, 神经网络噪声抵消系统对信噪比大于 0 dB 的输入信号有良好的噪声抵消效果。




图 11 系统的噪声抵消效果

4 结 语

BP 神经网络具有非线性映射和学习的能力, 可用于噪声抵消系统中噪声的非线性建模。本文利用 BP 神经网络组成自适应噪声抵消系统, 在原始输入和参考输入中噪声线性相关和非线性相关的条件下, 研究了不同隐含层节点数、不同神经网络学习算法、不同隐含层传输函数对系统噪声抵消效果的影响, 并优化了噪声抵消系统中单输入单输出 BP 神经网络隐含层节点公式。在不同信噪比原始输入下, 比较了系统的噪声抵消效果。从仿真结果可知, 系统的噪声抵消效果

受到隐含层节点数的影响;在隐含层传输函数选择上,建议使用 tansig 作为传输函数;在原始输入和参考输入中噪声线性相关时,神经网络噪声抵消系统对信噪比小于 0 dB 的输入信号有显著的噪声抵消效果;两路输入中噪声非线性相关时,系统对信噪比大于 0 dB 的输入信号有提高信噪比的效果。噪声抵消系统中 BP 神经网络采用优化后的隐含层节点数公式,具有很强的降噪能力,可用于低信噪比下噪声抵消。

参 考 文 献

- [1] Widrow B, Glover J R, Mccool J M, et al. Adaptive noise cancelling: principles and applications[J]. Proceedings of the IEEE, 2005, 63(12):1692-1716.
- [2] 邹进, 曹茜红, 韩迎春, 等. 基于自适应噪声抵消的微弱振动信号提取方法[J]. 探测与控制学报, 2015(5):47-50.
- [3] Jamel T M, Mohamed H A. Noise canceller using a new modified adaptive step size LMS algorithm [J]. Wseas Transactions on Signal Processing, 2014(10):637-644.
- [4] Jagadesh T, Mahalakshmi P. A novel pipelined adaptive RLS filter for ECG noise cancellation[J]. Research Journal of Applied Sciences Engineering & Technology, 2015, 11(5):501-506.
- [5] Bai L, Yin Q. A modified NLMS algorithm for adaptive noise cancellation[C]//IEEE International Conference on Acoustics Speech and Signal Processing. IEEE, 2010: 3726-3729.
- [6] Sun G, Xue G, Li C. The experiment of RBF network used in active noise controlling in tracked vehicle cabins[C]//8th International Symposium on Test and Measurement. 2009: 505-508.
- [7] Zhang M. Application of BP neural network in acoustic wave measurement system[J]. Modern Physics Letters B, 2017, 31:1740052.
- [8] Liu S, Pan J, Yang M H. Learning recursive filters for low-level vision via a hybrid neural network[C]//European Conference on Computer Vision. Springer, Cham, 2016: 560-576.
- [9] Miry M H, Miry A H, Khleaf H K. Adaptive noise cancellation for speech employing fuzzy and neural network[C]//International Conference on Energy, Power and Control. IEEE, 2010:289-296.
- [10] 李安平, 刘国荣. 一类非线性系统的自组织模糊神经网络控制[J]. 电机与控制学报, 2016, 20(12):82-91.
- [11] 李晓艳. 基于神经网络的自适应噪声抵消的研究[D]. 武汉:武汉理工大学, 2010.
- [12] 蒋威, 张东阳. 基于量子神经网络的无线电引信干扰抵消[J]. 微计算机信息, 2011(5):199-201.
- [13] 周伟, 吴晗平, 吴晶, 等. 紫外目标探测弱信号处理方法研究[J]. 红外技术, 2012(9):508-514.
- [14] Cai Z F, Jian Z, Chen L D. Harmonic analysis approach using enhanced adaline neural network[J]. Journal of Zhejiang University, 2009, 43(1):166-171.
- [15] Dixit S, Nagaria D. Neural network implementation of least-mean-square adaptive noise cancellation[C]//International Conference on Issues and Challenges in Intelligent Computing Techniques. IEEE, 2014:134-139.
- [16] 彭耿, 黄知涛, 陆凤波等. 中频通信信号信噪比的快速盲估计[J]. 电子与信息学报, 2010, 32(1):102-106.
- [17] Zhao B, Lu H, Chen S, et al. Convolutional neural networks for time series classification[J]. Journal of Systems Engineering and Electronics, 2017, 28(1):162-169.
- [18] Zhang L, Wang F, Sun T, et al. A constrained optimization method based on BP neural network[J]. Neural Computing & Applications, 2018, 29(2):413-421.

(上接第 262 页)

- [2] García V, Sánchez J S, Mollineda R A. On the effectiveness of preprocessing methods when dealing with different levels of class imbalance[J]. Knowledge-Based Systems, 2012, 25(1):13-21.
- [3] Wang S, Yao X. Using Class Imbalance Learning for Software Defect Prediction[J]. IEEE Transactions on Reliability, 2013, 62(2):434-443.
- [4] Han H, Wang W Y, Mao B H. Borderline-SMOTE: A New Over-Sampling Method in Imbalanced Data Sets Learning [C]//International Conference on Advances in Intelligent Computing. Springer-Verlag, 2005:878-887.
- [5] He H, Bai Y, Garcia E A, et al. ADASYN: Adaptive synthetic sampling approach for imbalanced learning[C]//IEEE International Joint Conference on Neural Networks. IEEE, 2008:1322-1328.
- [6] Maciejewski T, Stefanowski J. Local neighbourhood extension of SMOTE for mining imbalanced data[C]//Computational Intelligence and Data Mining. IEEE, 2011:104-111.
- [7] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1):5-32.
- [8] Verikas A, Gelzinis A, Bacauskiene M. Mining data with random forests: A survey and results of new tests[J]. Pattern Recognition, 2011, 44(2):330-349.
- [9] 尹华. 面向高维和不平衡数据分类的集成学习算法研究[D]. 武汉:武汉大学, 2012.