

一种针对拖尾噪声的鲁棒神经网络信号检测算法

简涛 苏峰 何友 曲长文 平殿发
(海军航空工程学院信息融合技术研究所 烟台 264001)

摘要: 与高斯噪声相比, 拖尾有更多的异常值, 利用传统的神经网络不能有效的检测信号。该文提出一种基于中值滤波的鲁棒神经网络进行处理, 首先利用中值滤波抑制异常值, 进一步利用 BP (Back Propagation) 神经网络消除残留噪声, 检测目标信号。基于误差分析的实验结果表明, 与传统神经网络相比, 所提出的方法不仅能更好地消除拖尾噪声, 有效检测信号, 而且能有效检测高斯噪声中的目标信号, 具有很好的鲁棒性和自适应特性。

关键词: 信号检测; 神经网络; BP 算法; 拖尾噪声; 中值滤波

中图分类号: TN911.23

文献标识码: A

文章编号: 1009-5896(2007)08-1864-04

A Detection Algorithm of Robust Neural Network for Heavy-tailed Noise

Jian Tao Su Feng He You Qu Chang-wen Ping Dian-fa

(Research Institute of Information Fusion, Naval Aeronautical Engineering Institute, Yantai 264001, China)

Abstract: Compared with Gaussian noise, Heavy-tailed noise has more outliers, and the traditional neural network can not suppress outliers. A new neural network based on median filter is proposed. After suppressing the outliers in signal through median filter, the BP (Back Propagation) is used and remained noise is eliminated further. The experiment based on the error analyses shows that compared with the traditional neural network, the proposed method can suppress heavy-tailed noise and detect target signal more effectively. It can perform well for both heavy-tailed noise and Gaussian noise background, which shows its robustness and adaptiveness.

Key words: Signal detection; Neural network; BP algorithm; Heavy-tailed noise; Median filter

1 引言

信号处理应用的领域日益广泛, 信号的结构越来越复杂, 为了更加清楚地分析和研究实际工程中信号的有用信息, 信号的有效检测至关重要。信号检测的关键是提取信号的特征, 但目标信号总是淹没在大量的杂波或干扰中, 而且目标信号的幅值或功率较杂波或干扰信号可能还低得多, 这就需要进行有效的信号处理。在实际的信号检测中, 例如雷达或声纳回波信号, 包含许多幅值较大的噪声部分, 此时的噪声不再服从传统的高斯分布, 而必须用各种合适的拖尾分布噪声来建模^[1,2]。对于淹没在拖尾噪声中的有用信号, 许多基于高斯假设的经典消噪方法已无能为力。由于人工神经网络是一种由大量处理单元组成的非线性自适应动态系统, 能通过简单非线性单元的复合映射获得较强的非线性处理能力, 因而在信号检测中得到了广泛应用^[3,4]。神经网络具有很强的自适应性和学习能力、鲁棒性和容错能力, 从而可以代替复杂耗时的传统算法, 使信号处理过程更接近于人类的思维活动。

针对拖尾噪声中的信号检测问题, 本文提出了一种基于中值滤波的鲁棒神经网络信号检测算法。该算法通过中值滤波对异常值进行有效地抑制, 将噪声限制在幅度较小的范

围, 接着利用神经网络所具有的强大的学习能力和描述非线性关系的能力, 进一步对含噪信号进行处理, 达到提高信噪比, 检测信号的目的。与传统的神经网络相比, 经过训练的鲁棒神经网络不仅能有效地检测拖尾噪声中的信号, 而且能检测高斯噪声环境下的信号。基于信号检测的误差分析进一步表明了本文方法的鲁棒性。

2 拖尾噪声模型

相对于高斯分布来说, 拖尾分布含有更多的异常值, 它的概率密度函数PDF(Probability Density Function)在两端仍有较大的值, 即有着更大更长的“尾巴”。本文采用 ϵ 污染的正态分布族^[5]来描述拖尾噪声模型。 ϵ 污染的正态分布族的定义为

$$P_{\epsilon} = \{(1 - \epsilon)\Phi + \epsilon G : G \in F\} \quad (1)$$

其中 Φ 是正态分布, F 是所有合适的光滑分布函数的集合, $\epsilon \in (0,1)$ 是已知的污染系数。实验中原始信号采用方波, 信号长度为 $N = 512$, 加性噪声是相互独立同分布的, 服从污染系数 $\epsilon = 0.1$ 时式(1)的噪声模型。为了分析方便, 其中 Φ 为 $N(0,1)$ 分布, 假设 $A \sim N(0, \sigma)$, 噪声 G 可取 A 的 3 次方^[6], 即 $G = A^3$, 实验中取 $\sigma = 1.8$ 。原始信号 $S(n)$, 含高斯噪声信号 $X_1(n)$ 和含拖尾噪声信号 $X_2(n)$ 如图 1 所示, 消噪前 $X_1(n)$ 和 $X_2(n)$ 的信噪比为 6.0621dB 和 -6.9227dB, 由图可知与高斯噪声相比, 拖尾噪声存在更多的异常值。




图 1 原始信号和含噪信号

3 基于中值滤波的鲁棒神经网络信号检测算法

本部分利用中值滤波和神经网络的不同处理特点，将二者有机的结合，获得一种有效抑制拖尾噪声的算法。

中值滤波方法^[7]在某些条件下可以做到既去除噪声，又保护信号边缘的有效复原。它是一种去除噪声的非线性处理方法。基本原理是把数字序列中一点的值用该点的邻域中各点值的中值代替。假设原始数字序列为 $x_1x_2x_3 \cdots x_n$ ，把 n 个数按值大小顺序排列如下 $x_{(1)} \leq x_{(2)} \leq x_{(3)} \leq \cdots \leq x_{(n)}$ ，则中值定义为

$$y = \text{Med}(x_1x_2x_3 \cdots x_n) = \begin{cases} x_{(n+1)/2}, & n \text{ 为奇数} \\ \frac{1}{2}[x_{(n/2)} + x_{(n/2+1)}], & n \text{ 为偶数} \end{cases} \quad (2)$$

在一维情况下，中值滤波器是一个有一定长度的滑动窗口，窗口正中的值用窗口内各值的中值代替。中值滤波能有效地去除脉冲型噪声。对于脉冲干扰来讲，特别是脉冲宽度小于滤波窗口宽度一半，相距较远的窄脉冲干扰，中值滤波是有很有效的。噪声平滑效果与窗口的宽度有关，窗口宽度越宽，噪声平滑效果越好，但容易产生过平滑现象。

基于中值滤波的鲁棒神经网络信号检测算法首先对原始含噪信号进行中值滤波，然后对去除异常值的含噪信号进一步进行神经网络消噪处理。在处理过程中，由于中值滤波主要是去除幅值较大的异常值，因此窗的长度应适当小些，避免在处理过程中产生过平滑，而含有幅度较小的噪声可以通过神经网络进行检测。

本文中神经网络算法采用具有良好函数逼近特性的BP神经网络。BP算法是当前在前馈型神经网络中研究得最为成熟，应用最广的有监督学习算法。该算法采用梯度下降方法在权矢量空间中求取误差函数的极小值，能够使误差函数极小化的权值组合即为学习问题的解答。因此，BP网络可以看作是一个从输入到输出的高度非线性映射，首先不加证明的给出BP定理^[8]。

BP 定理 给定任意的 $\varepsilon > 0$ 和任意的 L_2 函数 $f: [0,1]^n \rightarrow$

R^m ，存在一个 3 层 BP 网络，它可以在任意 ε 平方误差精度内逼近 f 。

这个定理说明，只要有一个隐含层的 BP 网络，就可以实现所期望的由输入矢量空间到输出矢量空间的映射，也就是能实现给定的输入输出样本对的学习。

设 BP 神经网络的拓扑结构如图 2 所示。将第 k 层第 i 个元素的输入和记为 I_i^k ，输出记为 O_i^k ；将第 $k-1$ 层第 i 个元素向第 k 层第 j 个元素的连接权值记为 $w_{i,j}^{k-1,k}$ ，则有

$$O_i^k = f(I_i^k) \quad (3)$$

其中

$$I_j^k = \sum_i w_{i,j}^{k-1,k} O_i^{k-1} \quad (4)$$

误差函数定义为输出层各元素误差的平方和，即

$$r = \frac{1}{2} \sum_j (O_j^m(W, X) - y_j)^2 \quad (5)$$

式中 $O_j^m(W, X)$ 为与权矢量 \mathbf{W} 和输入矢量 \mathbf{X} 有关的第 m 层 (即输出层) 第 j 元素的实际输出值， y_j 为该元素的期望输出。

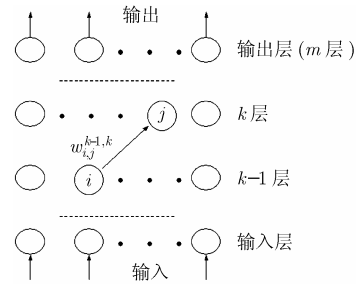


图 2 采用 BP 学习算法的前馈神经网络

根据梯度下降的原理，各层神经元相应权值的改变量正比于误差函数对该权值的负导数，即由式(4)有

$$\begin{aligned} \Delta w_{i,j}^{k-1,k} &= -\eta \frac{\partial r}{\partial w_{i,j}^{k-1,k}} = -\eta \frac{\partial r}{\partial I_j^k} \frac{\partial I_j^k}{\partial w_{i,j}^{k-1,k}} \\ &= -\eta \frac{\partial r}{\partial I_j^k} O_i^{k-1} = -\eta d_j^k O_i^{k-1} \end{aligned} \quad (6)$$

式中 η 为常数。

对于输出层 $k = m$ ，由式(3)，式(5)有

$$d_j^k = \frac{\partial r}{\partial I_j^m} = \frac{\partial r}{\partial O_j^m} \frac{\partial O_j^m}{\partial I_j^m} = (O_j^m - y_j) f'(I_j^m) \quad (7)$$

对于 $k < m$ 的其他层，则由全导数公式有

$$\begin{aligned} d_j^k &= \frac{\partial r}{\partial I_j^k} = \sum_l \frac{\partial r}{\partial I_l^{k+1}} \frac{\partial I_l^{k+1}}{\partial O_j^k} \frac{\partial O_j^k}{\partial I_j^k} \\ &= \sum_l \frac{\partial r}{\partial I_l^{k+1}} w_{j,l}^{k,k+1} f'(I_j^k) \\ &= \sum_l d_l^{k+1} w_{j,l}^{k,k+1} f'(I_j^k) \end{aligned} \quad (8)$$

当利用式(7)求出输出层的 $d_j^k = d_j^m$ 后，就可以利用递推公式(8)由 $k+1$ 层的 d_l^{k+1} 递推出比它低一层的 k 层 d_j^k 了。

于是，根据式(3)~式(8)，可以将整个学习算法步骤归纳如下：

(1)将网络各权值 $w_{i,j}$ 赋予小的非零随机实数值，设定学

习率 η 和惯性系数 α 。

(2)输入 p 个(输入, 输出)样本对中的第一个样本对。

(3)按公式

$$O_i^k = f(I_i^k) = f\left(\sum_i w_{i,j}^{k-1,k} O_i^{k-1}\right) \quad (9)$$

计算出网络各层元素的实际输出值。

(4)按式(10)调整各连接权值

$$w_{i,j}^{k-1,k}(t+1) = \alpha w_{i,j}^{k-1,k}(t) - \eta d_j^k O_i^{k-1} \quad (10)$$

其中当 $k = m$ 时

$$d_j^k = (O_j^m - y_j) f'(I_j^m) \quad (11)$$

当 $k < m$ 时

$$d_j^k = \sum_l d_l^{k+1} w_{j,l}^{k,k+1} f'(I_j^k) \quad (12)$$

转第(2)步, 输入第二组样本对, 循环利用 p 个样本对, 直至 $w_{i,j}$ 趋于稳定不变为止。

关于BP网络隐含层单元数量的确定, 在神经网络处理中也是非常重要的。隐含层单元过少, 无法产生足够的连接权组合数来满足若干样本对的学习; 隐含层单元过多, 则学习以后网络的泛化能力变差。有如下 3 种选择隐含层单元数 n_1 的公式^[9]。

方法 1

$$k < \sum_{i=0}^n C \binom{n_1}{i} \quad (13)$$

式中 k 为样本数, n 为输入层单元数, 当 $i > n_1$ 时取

$$C \binom{n_1}{i} = 0。$$

方法 2

$$n_1 = \sqrt{n + M} + a \quad (14)$$

式中 M 为输出层单元数, 常数 $a=1-10$ 。

方法 3

$$n_1 = \log_2 n \quad (15)$$

实验中采用的图 1 所示的含噪声信号和方波信号作为样本对, 网络输入为含噪声信号, 网络输出为方波信号, 实验中提供了 100 个含拖尾噪声的样本和 100 个含高斯噪声的样本, 其中有 50 个训练样本和 50 个检验样本。为了增强网络的自适应性, 先采用 50 个含高斯噪声的样本对网络进行训练, 接着采用 50 个含拖尾噪声的样本对网络进行训练。采用信号长度均为 512, 训练样本数为 100。由以上 3 种方法确定的隐含层单元数分别为 $n_1 > \log_2 100$, $n_1 = \sqrt{513} + a$ 和 $n_1 = 9$ 。由于所需逼近的函数变化剧烈, 波动很大, 则要求可调整的连接权数多, 从而隐含层单元数也较多。所以选用方法 2 的隐含层单元数 $n_1 = \sqrt{513} + a$, 在此可取 $n_1 = 26$ 。为了防止过消噪现象, 中值滤波的滑窗大小为 8。在采用相同的训练样本的前提下, 文中对比了直接用 BP 神经网络检测信号和利用基于中值滤波的鲁棒神经网络检测信号的效果。

对含拖尾噪声信号训练时的学习曲线如图 3 所示, 图 3(a)和图 3(b)分别是鲁棒神经网络和 BP 神经网络的学习曲线, 其中实线是均方误差曲线, 虚线是目标误差。由图可知鲁棒神经网络比 BP 神经网络有更快的收敛速度。鲁棒神经网络在第 297 次训练中就达到了误差目标, 而 BP 神经网络在整个训练过程中的误差一直保持在 0.31 左右, 直到最大的 1000 次训练后依然没能达到目标误差。




图 3 鲁棒神经网络和 BP 神经网络的训练学习曲线

利用训练好的 BP 网络和鲁棒神经网络对检验样本进行信号检测的结果如图 4 所示。其中 $S_1(n)$ 和 $S_2(n)$ 分别表示 BP 网络和鲁棒神经网络对含拖尾噪声信号检测的结果, $S_3(n)$ 和 $S_4(n)$ 分别表示 BP 网络和鲁棒神经网络对含高斯噪声信号检测的结果。由图 4 可知用 BP 网络检测拖尾噪声中的信号效果很差, 检测后的信号仍然含有很大的异常值, 而且信号还是淹没在噪声之中; 而用 BP 网络对高斯噪声中的信号进行检测, 效果也不明显, 检测后仍然有很多噪声分量。由 $S_2(n)$ 和 $S_4(n)$ 可知, 鲁棒神经网络能适应不同的噪声环境, 有效的检测信号。




图 4 利用 BP 神经网络和鲁棒神经网络在拖尾噪声和高斯噪声中信号检测结果

4 性能分析

本节对 BP 神经网络和鲁棒神经网络在不同信噪比条件下的信号检测能力进行了分析比较。

文中采用 L_p 范数误差^[10]

$$L_p = \sum_{i=1}^N |x_i - \hat{x}_i|^p / N \quad (16)$$

L_p 能有效地反映对总体噪声的抑制效果。其中, x_i 和 \hat{x}_i 分别代表原始目标信号和检测信号, N 是信号长度, p 为正整数。 p 为不同值时产生不同的范数定义, 但均具有相似性,

本文采用 $p = 1$ 时的 L_1 作为不同方法的比较标准。

实验中原始目标信号仍采用方波信号, 对于不同的输入信噪比(SNR)的拖尾噪声信号和含高斯噪声信号, 采用蒙特卡罗方法, 试验次数为 300, BP 神经网络和鲁棒神经网络检测信号的 L_1 误差曲线如图 5 所示, 其中图 5(a)和图 5(b)分别表示对含拖尾噪声信号和含高斯噪声信号的检测后误差分析, 实线代表鲁棒神经网络, 虚线代表 BP 神经网络。总的来看, 随着输入信噪比的提高, 两种方法的检测效果均有所改善。但无论是对信噪比较低的含拖尾噪声信号, 还是含高斯噪声的信号, 鲁棒神经网络的检测误差均小于 BP 神经网络, 这也充分体现了所提方法在信号检测中的鲁棒性。




图 5 BP 神经网络和鲁棒神经网络进行信号检测的误差分析

5 结束语

拖尾噪声比高斯噪声有更多的异常值, 在拖尾噪声环境中, 传统的 BP 神经网络不能有效地检测信号, 提出基于中值滤波的鲁棒神经网络对含拖尾噪声信号进行检测。基于 L_1 误差的实验分析表明, 与基于 BP 网络相比, 文中所提方法能很好抑制异常值, 有效地去除拖尾噪声, 检测目标信号, 具有较强的鲁棒性。

参 考 文 献

- [1] Barkat B and Abed-Meraim K. An effective technique for the IF estimation of FM signals in heavy-tailed noise. Proceedings of the 3rd IEEE International Symposium on Signal Processing and Information Technology [C]. Darmstadt, Germany, 2003: 637-640.
- [2] Breich R F, Iskander D R, and Zoubir A M. The stability test for symmetric alpha-stable distributions [J]. *IEEE Trans. on Signal Processing*, 2005, 53(3): 977-986.
- [3] Akhtar S, Elshafei-Abmed M, and Ahmed M S. Detection of helicopters using neural nets [J]. *IEEE Trans. on Instrumentation and Measurement*, 2001, 50(3): 749-756.
- [4] Wang Zhishun, He Zhenya, and Chen J D Z. Robust time delay estimation of bioelectric signals using least absolute deviation neural network [J]. *IEEE Trans. on Biomedical Engineering*, 2005, 52(3): 454-462.
- [5] Huber P. Robust estimation of a location parameter [J]. *Ann. Math. Stat.*, 1964, 35: 1753-1758.
- [6] Djurovic I, Katkovnik V, and Stankovic L. Instantaneous frequency estimation based on the robust spectrogram. IEEE International Conference on Acoustics, Speech, and Signal Processing [C], Salt Lake City, Utah, 2001, 6: 3517-3520.
- [7] Fitch J P, Coyle E J, and Gallagher N C, et al. Median filtering by threshold decomposition [J]. *IEEE Trans. on Acoust. Speech, Signal Proc.*, 1984, 32(6): 1183-1188.
- [8] 靳蕃. 神经计算智能基础原理方法 [M]. 成都: 西南交通大学出版社, 2000: 123-137.
- [9] 张立明. 人工神经网络的模型及其应用 [M]. 上海复旦大学出版社, 1993: 87-164.
- [10] Tsakalides P, Reveliotis P, and Nikias C L. Scalar quantisation of heavy-tailed signals [J]. *IEE Proceedings Vision, Image and Signal Processing*, 2000, 147(5): 475-484.

简 涛: 男, 1980 年生, 硕士生, 研究方向为雷达信号检测与信号处理。

苏 峰: 男, 1977 年生, 博士生, 研究方向为雷达信号检测与信号处理。

何 友: 男, 1956 年生, 教授, 博士生导师, 研究方向为雷达自适应检测方法、多传感器信息融合、模式识别等。