

# 一种基于扩展交替投影神经网络的弱信号分离方法研究<sup>\*</sup>)

王金根<sup>1</sup> 陈世福<sup>1</sup> 龚沈光<sup>2</sup> 陈兆乾<sup>1</sup>

(南京大学计算机软件新技术国家重点实验室 南京210093)<sup>1</sup> (海军工程大学 武汉430033)<sup>2</sup>

## A Weak-Signal Separation Algorithm Based on Extended Alternating Projection Neural Networks

WANG Jin-Gen<sup>1</sup> CHEN Shi-Fu<sup>1</sup> GONG Shen-Guang<sup>2</sup> CHEN Zhao-Qian<sup>1</sup>

(State Key Lab for Novel Software Technology, Nanjing University, Nanjing 210093)<sup>1</sup> (Navy Engineering University, Wuhan 430033)<sup>2</sup>

**Abstract** Aiming at a kind of specific situation encountered in practice, the paper proposes a weak-signal separation algorithm based on Extended Alternating Projection Neural Networks (EAPNN) by combining the time-domain features of the signal with the frequency-domain features of the signal and taking advantage of conclusions on EAPNN. Simulation results demonstrate that the algorithm is effective and that the EAPNN-based signal separation algorithm is better than the RLS-based signal separation algorithm. Although the EAPNN-based algorithm is designed for the specific situation, it is also applicable to the other situations and a basic frame of the EAPNN-based signal separation is presented. Owing to adopting neural network structure, the EAPNN-based algorithm is prone to parallel computation and VLSI design, consequently can satisfy real-time processing needs.

**Keywords** Alternating projection, Neural networks, Signal processing, Signal separation, Signal detection

## 1 引言

交替投影神经网络(Alternating Projection Neural Networks, APNN)<sup>[1]</sup>是由美国 Washington 大学 Marks II 等人提出的。该神经网络自从提出到现在,没有引起同行的太多注意,关于其应用方面的研究更是寥寥无几。

文[1]在研究 APNN 网时,首先假定了网络用于学习的  $N$  个库模式是线性独立的,于是连接权矩阵可以用这样的方法获得,即  $T = F(F^T F)^{-1} F^T$ ;但是实际中  $N$  个库模式极可能不是线性独立的,这样  $F^T F$  可能是奇异阵或者严重病态,前述获取  $T$  的方法不再有效。为此, Marks II 等人给出了一种实用的方法。这种方法考虑到了  $N$  个库模式不是线性独立的情况,但是这也引起一个疑问。由于 APNN 收敛条件及其证明是建立在  $N$  个库模式线性独立这一前提条件基础上的,而实用方法却考虑了线性相关情况,那么这种方法获得的连接权矩阵具体是什么?还能不能保证网络稳定?若能,网络用于联想记忆时稳态收敛条件是什么?这是一个值得研究的问题。另外,围绕 APNN 的一切工作都是在实数域内展开的,为了使 APNN 能够广泛用于信号处理领域,需将其应用范围从实数域扩展到复数域。

针对上述问题,文[2]对 APNN 进行了深入研究,并取得了如下有益结论:(1)对原 APNN 的连接权矩阵进行修改,将其应用范围从实数域拓展到复数域,从而提出一种新的神经网络——扩展交替投影神经网络(Extended Alternating Projection Neural Networks);并从数学上严格证明了 EAPNN 网络的稳定性;(2)对 EAPNN 网络进行详细研究后,给出了网络稳态值的数学表达式,并从表达式中得到了网络具备联想记忆功能的充要条件,所有结论都经过了严格的数学证明。(3)得到了有关 EAPNN 网络的若干结论,并从数学上进行了严格证明;讨论了有限精度 EAPNN 网络,并给出

一种改进权值学习方法,从而保证了有限精度 EAPNN 网络稳定可靠。

文[3]将扩展后的 APNN 网络用于带限信号外推,研究出一种新的带限信号外推算法。文[4]将扩展后的 APNN 网络用于陷波器设计。

本文将研究如何用 EAPNN 网络进行弱信号分离。在工程实际中经常会遇到这样一种情况,那就是:①感兴趣的信号较弱,集中在某时间段内,而在其它时间段内接近于0;②背景干扰信号很强,将有用信号完全淹没;③感兴趣信号的频谱与背景干扰的频谱相重叠;④数据采集频率不高,采样点数较少。对于这种情况,若采用经典滤波方法则很难取得满意效果。此时需要综合考虑信号的时域与频域特征来研究一种新的信噪分离方法。针对这种情况,本文研究出了一种基于 EAPNN 的弱信号分离方法,并设计仿真实验进行了验证。仿真结果表明基于 EAPNN 的方法是切实有效的,而且优于 RLS 自适应方法。

## 2 扩展交替投影神经网络(EAPNN)

文[2]对原 APNN 网进行扩展,提出一种扩展交替投影神经网络(EAPNN 网),该网络的作用域为复数域,其连接权矩阵  $T = FF^+$ ,  $F$  是由  $M$  个长为  $N$  的复模式  $f_1, f_2, \dots, f_M$  组成的矩阵,它等于  $[f_1 \ f_2 \ \dots \ f_M]$ ,  $F^+$  为  $F$  的广义逆, EAPNN 网络的拓扑结构以及联想过程同 APNN,它的一种实用权值获取方法如下:

(a)将初始连接权矩阵  $T$  置0,  $i \leftarrow 1$ 。

(b)  $\epsilon_i = (I - T)f_i$ , 此处  $I$  为  $N \times N$  单位阵,  $f_i$  为网络用于学习的复模式。

(c)若  $\|\epsilon_i\| = 0$ , 则认为  $f_i$  已经记忆在网络中,转到(d);否则,  $T \leftarrow T + \epsilon_i \epsilon_i^H / \epsilon_i^H \epsilon_i$ 。

(d)  $i \leftarrow i + 1$ , 如果  $i > M$  则结束,否则转(b)。

<sup>\*</sup>)本项研究得到国家自然科学基金(No. 60273033)和江苏省自然科学基金(No. DK2002081)资助。

从文[2]可知这种实用方法获得的连接权矩阵  $T$  等于  $FF^+$ 。

### 3 基于 EAPNN 的弱信号分离方法

在工程实际中经常会遇到这样一种情况,那就是:①感兴趣的信号较弱,集中在某时间段内,而在其它时间段内接近于0;②背景干扰信号很强,将有用信号完全淹没;③感兴趣信号的频谱与背景干扰的频谱相重叠;④数据采样频率不高,采样点数较少。对于这种情况,若采用经典滤波方法则很难取得满意效果。此时需要综合考虑信号的时域与频域特征来研究一种新的信噪分离方法。

为了讨论问题的方便,假设离散化的传感器输出信号为  $s(n) = x_1(n) + x_2(n), n = 0, 1, \dots, N-1$ 。其中  $x_1(n)$  为背景干扰信号,  $x_2(n)$  为感兴趣的信号,现要将  $x_2(n)$  从  $s(n)$  中分离出来。

由于  $|x_1(n)| \gg |x_2(n)|$ , 那么  $s(n) \approx x_1(n)$ , 于是  $s(n)$  与  $x_1(n)$  的频谱结构大致相同。对  $s(n)$  进行离散傅里叶变换,找出最大谱峰对应的位置  $p$ 。根据  $x_1(n)$  的频谱特点,确定 EAPNN 网络的库模式及其个数。

假定 EAPNN 网络的库模式的个数为  $2M+1$ , 库模式为  $f_k, k = -M, \dots, -1, 0, 1, 2, \dots, M$ , 则

$$f_k = [e^{i2\pi(\rho+k) \times 0/N} \ e^{i2\pi(\rho+k) \times 1/N} \ e^{i2\pi(\rho+k) \times 2/N} \ \dots \ e^{i2\pi(\rho+k) \times (N-1)/N}]^T$$

将  $2M+1$  个库模式依次训练到 EAPNN 网络中,然后采用下面的方法即可从  $s(n)$  中分离出  $x_2(n)$ 。

基于 EAPNN 的信号分离方法:

(1) 将原信号  $s(n)$  平分分成  $d$  段( $d$  一般取  $2 \sim 4$ ), 依次记为段1, 段2, ..., 段  $d$ 。  $k=0$

(2)  $k=k+1$ , 将原始信号序列  $s(n)$  作为网络神经元的状态向量, 将与段  $k$  对应的神经元指定为强制神经元, 其它神经元则为浮动神经元。

(3) 网络经过一百多次联想后, 将强制神经元改为浮动神经元, 浮动神经元变为强制神经元, 网络接着进行一百多次联想, 将网络所有浮动神经元状态组成的序列记为  $S_k$ 。

(4) 如果  $k < d$ , 转到(3); 否则, 将  $S_1, S_2, \dots, S_d$  组成的序列记为  $S$ , 将原始序列减去  $S$  的结果记为  $\Psi$ 。

(5) 若  $\Psi$  的能量集中在某区间段(不妨将此区间段记为段  $d+1$ ), 则令  $k=d+1$ , 将原始信号序列作为网络神经元的状态向量, 与段  $k$  对应的神经元指定为浮动神经元, 其它神经元则为强制神经元。网络经过几十次联想后, 将得到的  $S_{d+1}$  去覆盖  $S$  中的对应部分, 将原始序列再减去  $S$  后结果赋给  $\Psi$ ; 否则, 结束。

这样得到的  $\Psi$  即为从  $s(n)$  中分离出的信号  $x_2(n)$  的最佳估计值  $\hat{x}_2(n)$ 。

尽管上面的信号分离方法是针对前述特定情况提出的, 但它的设计思想具有通用性。我们可以将这种思想广泛用于一般信号分离, 从而提出一般信号分离的基本框架。具体如下:

若已知  $s(n) = x_1(n) + x_2(n)$ , 现要将  $x_1(n)$  从  $s(n)$  中分离出来, 可采用如下思路加以解决。

(1) 根据具体问题寻找一组库模式  $f_1, f_2, \dots, f_M$ , 使得  $x_1(n)$  能够用  $f_1, f_2, \dots, f_M$  线性表示, 而且  $x_2(n)$  要与  $f_1, f_2, \dots, f_M$  局部近似正交;

(2) 将  $f_1, f_2, \dots, f_M$  训练到 EAPNN 中;

(3) 将  $s(n)$  作为 EAPNN 网络神经元的初始状态, 根据具体问题来确定 EAPNN 网中哪些神经元为强制神经元, 哪些为浮动神经元;

(4) 网络经过充分联想后, 将强制神经元改为浮动神经元, 浮动神经元改为强制神经元, 网络接着联想……;

(5) 这样网络的最终状态即为  $x_1(n)$  的最佳估计值,  $s(n) - x_1(n)$  即为  $x_2(n)$  的最佳估计值。

由上面的思路可知, 问题能否成功解决的关键是第(1)步和第(3)步, 即库模式的合理选取和神经元的科学划分。

为了验证上述方法的有效性, 下面进行仿真实验。

### 4 仿真实验及其结果

在进行仿真实验之前, 首先定义两个性能指标:

① 感兴趣信号的理论计算值  $x_2(n)$  与背景干扰  $x_1(n)$  之间的信噪比  $SNR_1 = 20 \log(std(x_2(n))/std(x_1(n)))$ , 其中

$$std(x(n)) = \sqrt{\frac{1}{N-1} \sum_{n=0}^{N-1} (x(n) - \frac{1}{N} \sum_{n=0}^{N-1} x(n))^2}$$

② 感兴趣信号的理论计算值  $x_2(n)$  与  $\hat{x}_2(n)$  中的噪声之间的信噪比  $SNR_2 = 20 \log(std(x_2(n))/std(\hat{x}_2(n) - x_2(n)))$

下面用三组不同的实验数据进行仿真实验。

第一组实验:

数据长度  $N=140, s(n) = x_1(n) + x_2(n)$ ,  $x_1(n)$  为一组实测数据,  $x_2(n)$  为第一种参数下的理论计算值。现分别采用基于 EAPNN 的方法 ( $d=3, M=2$ ) 和基于 RLS 的方法 ( $\delta=0.01, \lambda=0.99$ ) 从  $s(n)$  中分离  $x_2(n)$ , 结果如表1和图1、图2所示。

表1 第一组实验两种方法的信噪比改善情况

	EAPNN-based	RLS-based
$SNR_1(dB)$	0.2471	0.2471
$SNR_2(dB)$	5.6154	4.5749
$SNR_2 - SNR_1(dB)$	5.3683	4.3278

图1、图2中的实线(1)皆表示  $s(n)$ , 实线(2)皆表示  $x_2(n)$ , 实线(3)皆表示分离结果  $\hat{x}_2(n)$ 。

第二组实验:

数据长度  $N=140, s(n) = x_1(n) + x_2(n)$ ,  $x_1(n)$  同第一组实验,  $x_2(n)$  为第二种参数下的理论计算值。现分别采用基于 EAPNN 的方法 ( $d=3, M=2$ ) 和基于 RLS 的方法 ( $\delta=0.01, \lambda=0.99$ ) 从  $s(n)$  中分离  $x_2(n)$ , 结果如表2和图3、图4所示。

表2 第二组实验两种方法的信噪比改善情况

	EAPNN-based	RLS-based
$SNR_1(dB)$	-7.7932	-7.7932
$SNR_2(dB)$	4.0442	3.6927
$SNR_2 - SNR_1(dB)$	11.8374	11.4859




图1 基于 RLS 分离方法的时域结果




图2 基于 EAPNN 分离方法的时域结果




图6 基于 EAPNN 分离方法的时域结果




图3 基于 RLS 分离方法的时域结果




图4 基于 EAPNN 分离方法的时域结果

图3、图4中的实线(1)皆表示  $s(n)$ , 实线(2)皆表示  $x_2(n)$ , 实线(3)皆表示分离结果  $\hat{x}_2(n)$ 。

第三组实验:

数据长度  $N=140$ ,  $s(n) = x_1(n) + x_2(n)$ ,  $x_1(n)$  同第一组实验,  $x_2(n)$  为第三种参数下的理论计算值。现分别采用基于 EAPNN 的方法 ( $d=3, M=2$ ) 和基于 RLS 的方法 ( $\delta=0.01, \lambda=0.99$ ) 从  $s(n)$  中分离  $x_2(n)$ , 结果如表3和图5、图6所示。图5、图6中的实线(1)皆表示  $s(n)$ , 实线(2)皆表示  $x_2(n)$ , 实线(3)皆表示分离结果  $\hat{x}_2(n)$ 。

表3 第三组实验两种方法的信噪比改善情况

	EAPNN-based	RLS-based
$SNR_1(dB)$	-14.0880	-14.0880
$SNR_2(dB)$	0.0398	-1.1716
$SNR_2 - SNR_1(dB)$	14.1278	12.9164




图5 基于 RLS 分离方法的时域结果

观察表1~3、图1~6可以发现,基于 EAPNN 的分离方法效果明显优于基于 RLS 的分离方法,而且  $SNR_1$  越小,  $SNR_2 - SNR_1$  越大,说明这两种方法皆适合微弱信号分离(或检测)。另外,观察图1~6还可以发现,两种方法分离出的目标信号皆含有高频噪声。其实对于这种噪声,用一个零相移低通 FIR 数字滤波器就可将其大大削弱。在此测试实验中,没有做这一步主要是为了重点比较这两种分离方法。

总之,这两种分离方法对这种特定情况都是有效的,其中,基于 EAPNN 的方法与基于 RLS 的方法相比,具有如下优点:(1)分离效果优于基于 RLS 的方法;(2)由于 EAPNN 采用全互连神经网络结构,而且各神经元的运算都极为简单,因而易于并行计算和 VLSI 实现,从而可满足高实时性的要求;(3)在基于 RLS 的方法中,参数  $\delta, \lambda$  与具体问题有关,难以调整,而这种情况在基于 EAPNN 的方法中不可能发生。

**结束语** 在工程实际中经常会遇到这样一种情况,那就是:①感兴趣的信号较弱,集中在某时间段内,而在其它时间段内接近于0;②背景干扰信号很强,将有用信号完全淹没;③感兴趣信号的频谱与背景干扰的频谱相重叠;④数据采样频率不高,采样点数较少。对于这种情况,若采用经典滤波方法则很难取得满意效果。针对这种情况,在综合考虑信号的时域与频域特征的基础上提出了一种基于 EAPNN 的弱信号分离方法,并设计仿真实验进行了验证。仿真结果表明基于 EAPNN 的方法是切实有效的,而且优于 RLS 自适应方法。另外还将这种设计思想用到一般信号分离中,提出一般信号分离的基本框架。

参考文献

- Marks R J II, Oh S, Atlas L E. Alternating Projection Neural Networks. IEEE Trans. CAS, 1989, 36(6): 846~857
- 王金根. 航空磁探系统中目标信号检测与磁性目标定位研究[D]: [博士学位论文]. 武汉: 海军工程大学, 2001
- 王金根, 林春生, 龚沈光. 基于交替投影神经网络的带限信号外推算法. 电子学报, 2000, 28(10): 52~55
- 王金根, 龚沈光, 林春生, 唐劲飞, 刘胜道. 基于复交替投影神经网络的陷波器. 数据采集与处理, 2001, 16(4): 440~445