

一种基于周期平稳的鲁棒盲神经网络波束形成器¹

何振亚 陈宇欣

(东南大学无线电系 DSP 室 南京 210096)

摘 要 本文提出了一种鲁棒的盲神经网络波束形成算法。该算法利用信号的周期平稳特性估计阵列的导引矢量,利用 LCMV 方法抑制噪声干扰,利用对角加载技术增强算法的鲁棒性,利用神经网络的网状计算结构特点便于其实现。理论分析和计算机仿真表明,该算法实现简单,鲁棒性强,易于实时应用。

关键词 盲波束形成,周期平稳,对角加载,神经网络,鲁棒

中图分类号 TN911.7, TN-052

1 引 言

波束形成器是一个与阵元阵列一起构成的空域滤波系统,它能够分离出频谱重叠而波达方向不同的信号。盲波束形成就是无需知道波达方向或导引矢量而完成波束形成。目前,盲波束形成主要有三类:(1)常模量(CM)算法^[1]。(2)基于高阶累积量的算法^[2]。(3)基于周期平稳的算法^[3-7]。CM算法采用的代价函数不能保证收敛到全局最小点。基于高阶累积量的算法由于利用信号的高阶统计特性,能够去除任何高斯噪声。但是,它对于非高斯干扰信号却比较困难,收敛速度过慢,运算复杂。而绝大多数通信信号是周期平稳的,且很容易找出它们之间不同的周期频率,因此基于周期平稳的算法引起了广泛注意。最先利用周期平稳特性进行盲波束形成的是 SCORE (Self-COherence REstore) 算法^[3]。然而,SCORE 算法的巨大运算量令人无法忍受,其它一些算法^[4-7]应运而生。其中, Q.Wu 等提出的 C-CAB(Constrained Cyclic Adaptive Beamforming)快速算法^[4]性能与 SCORE 相似,运算量大大降低,但算法的鲁棒性又不太理想。

目前,人工神经网络方兴未艾,取得了不少突破性的进展。它的特点之一就是神经网络具有巨量并行性,能以极快的速度求解复杂的问题以得到实时应用。而它能够做到这一点正是在于它的网状计算结构。本文利用一种变形的 Hopfield 网络很好地解决了运算量与运算复杂度之间的矛盾。理论分析和计算机仿真表明该盲神经网络波束形成器具有输出信噪比高,鲁棒性强,结构简单,收敛速度快等特点。

2 问题的陈述

假设阵列由 M 个阵元组成,接收的数字信号 $x(n)$ 为 $M \times 1$ 维复矢量。通常用 $x(n)$ 中的第 j 个元素 $x_j(n)$ 的实部和虚部表示由第 j 个传感器分别从同相和正交信道中采样信号。 $x(n)$ 表示为

$$x(n) = \sum_{k=1}^K d(\theta_k) s_k(n) + i(n) + v(n), \quad (1)$$

其中 $s_k(n)$, $d(\theta_k)$ 分别为由 θ_k 角入射的有用信号和信号的导引矢量, $i(n)$ 为干扰信号, $v(n)$ 为 $M \times 1$ 维白噪声。通常假设信号和干扰均为窄带平面波。

¹ 1998-06-22 收到, 1999-04-22 定稿

国家自然科学基金会重点项目与国家攀登计划重大项目(神经网络)资助课题

波束形成的目的就是根据某种准则找到权矢量 w , 使有用信号可由下式提取

$$y(n) = w^H x(n), \quad n = 1, \dots, N. \quad (2)$$

本文涉及的盲波束形成算法均运用了信号的周期平稳特性^[8]. 对于一 $M \times 1$ 维矢量 $x(n)$, 所谓周期平稳就是在某些时延 τ 或频移 α 情况下, 它的周期平稳相关矩阵或共轭周期平稳相关矩阵的秩为 $L_\alpha (L_\alpha \leq M)$. 周期平稳相关矩阵 $R_{xx}^\alpha(\tau)$ 和共轭周期平稳相关矩阵 $R_{xx}^{\alpha*}(\tau)$ 定义为

$$R_{xu} = \begin{cases} R_{xx}^\alpha(\tau) = \langle x(n)x^H(n+\tau)e^{-j2\pi\alpha n} \rangle_\infty, & \mathbf{u}(n) = x(n+\tau)e^{-j2\pi\alpha n}; \\ R_{xx}^{\alpha*}(\tau) = \langle x(n)x^T(n+\tau)e^{-j2\pi\alpha n} \rangle_\infty, & \mathbf{u}(n) = x^*(n+\tau)e^{-j2\pi\alpha n}; \end{cases} \quad (3)$$

其中 $\langle \cdot \rangle_\infty$ 定义为无限时间观测域上的平均, 实际中均采用 N 次有限采样的集平均 $\langle \cdot \rangle_N$, 以 \hat{R}_{xu} 表示, α 指周期平稳频率, 上标 “*”、“ T ”和“ H ”分别表示共轭、转置和共轭转置.

通信信号通常都具有它所独具的非零周期平稳特性, 如载频, 波特率, 导频等等. 例如, 对于 BPSK 信号来说, 若以 f_c 、 f_b 分别表示载频和波特率, 则存在周期平稳频率 $\alpha = lf_b \neq 0$, 共轭周期平稳频率 $\alpha = \pm 2f_c + lf_b$, $l = 0, \pm 1, \dots$. 因此, 利用信号的周期平稳特性就可以构造出盲阵列波束形成器.

3 盲神经网络波束形成器结构

3.1 基于周期平稳特性的 C-CAB 算法

Q.Wu 等人根据周期平稳的定义, 提出了 CAB 算法^[4], 代价函数如下:

$$\text{Max}_{w,c} |w^H \hat{R}_{xu} c|^2, \quad \text{st.} \begin{cases} w^H w = 1, \\ c^H c = 1. \end{cases} \quad (4)$$

其中 c 称为辅助控制矢量, 可以不必计算. 文献 [4] 证明了当 $N \rightarrow \infty$ 时 $w_{CAB} \propto d(\theta)$, 并提出相应的快速迭代算法如下, 运算量为 $O(M)$.

$$w_{CAB}(n) = \frac{n-1}{n} w_{CAB}(n-1) + \frac{1}{n} \sum_{m=1}^M u_m^*(n) x(n), \quad (5)$$

$u(n)$ 见 (3) 式定义. 显然, CAB 算法没有考虑抑制噪声, 在强干扰情况下算法的性能会有所降低. 因此, Q.Wu 等考虑用 LCMV (Linear Constraint Minimum Variance) 波束形成器来抑制噪声, 并得到如下关系:

$$w_{CCAB} = \hat{R}_{xx}^{-1} w_{CAB}. \quad (6)$$

其中 \hat{R}_{xx} 为自相关采样阵, 该算法被称作 C-CAB 算法, 在低输入信噪比情况下性能明显优于 CAB 算法. 然而 \hat{R}_{xx}^{-1} 即使采用 Sherman-Morrison 公式 (即矩阵迭代求逆引理), 运算量也要达到 $O(M^2)$, 影响了实时应用, 尤其是对于多阵元阵列.

3.2 神经网络盲波束形成

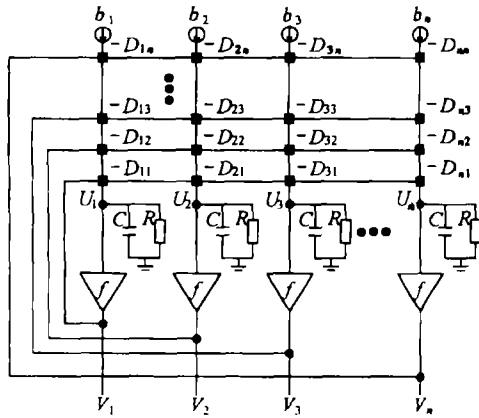


图 1 Hopfield 网络结构

根据第 2 节定义的模型，接收信号为复数，不能直接用该网络实现。但我们能够很容易地将其推广为实数情况。显然 (6) 式等价于

$$\hat{R}_{xx}w_{CCAB} = w_{CAB} \quad (7)$$

令 $\hat{R}_{xx} = \hat{R}_{xxr} + j\hat{R}_{xxi}$, $w_{CCAB} = w_{CCABr} + jw_{CCABi}$, $w_{CAB} = w_{CABr} + jw_{CABi}$, 其中 j 代表虚数, 则

$$(\hat{R}_{xxr} + j\hat{R}_{xxi})(w_{CCABr} + jw_{CCABi}) = w_{CABr} + jw_{CABi} \quad (8)$$

$$(\hat{R}_{xxr}w_{CCABr} - \hat{R}_{xxi}w_{CCABi}) + j(\hat{R}_{xxr}w_{CCABi} + \hat{R}_{xxi}w_{CCABr}) = w_{CABr} + jw_{CABi} \quad (9)$$

$$\begin{bmatrix} \hat{R}_{xxr} & -\hat{R}_{xxi} \\ \hat{R}_{xxi} & \hat{R}_{xxr} \end{bmatrix} \begin{bmatrix} w_{CCABr} \\ w_{CCABi} \end{bmatrix} = \begin{bmatrix} w_{CABr} \\ w_{CABi} \end{bmatrix} \quad (10)$$

若令 $\hat{R}_{xxc} = \begin{bmatrix} \hat{R}_{xxr} & -\hat{R}_{xxi} \\ \hat{R}_{xxi} & \hat{R}_{xxr} \end{bmatrix}$, $w_{CCABc} = \begin{bmatrix} w_{CCABr} \\ w_{CCABi} \end{bmatrix}$, $w_{CABc} = \begin{bmatrix} w_{CABr} \\ w_{CABi} \end{bmatrix}$, 得

$$\hat{R}_{xxc}w_{CCABc} = w_{CABc} \quad (11)$$

$$w_{CCABc} = \hat{R}_{xxc}^{-1}w_{CABc} \quad (12)$$

令 $D = \hat{R}_{xxc}^T$, $b = w_{CABc}$, $x_c = \begin{bmatrix} x_r & x_i \\ x_i & -x_r \end{bmatrix}$, $u_c = \left[\text{Re} \left(\sum_{m=1}^M u_m \right) \quad \text{Im} \left(\sum_{m=1}^M u_m \right) \right]^T$,

易证

$$\hat{R}_{xxc}(n) = \langle x_c(n)x_c^T(n) \rangle_N \quad (13)$$

$$b = x_c u_c \quad (14)$$

该网络相应的能量函数定义为

$$E = (1/2)V^T D v - b^T v + (1/(2Rk))\|v\|^2 \quad (15)$$

考察 C-CAB 算法, 发现存在两个缺陷:
 (1) 运算量较大. (2) C-CAB 采用 w_{CAB} 估计导引矢量, 然而任何估计方法都不可避免地存在误差. LCMV 波束形成器对失配非常敏感^[9], 特别是在高信噪比和多阵元阵列情况下. 针对这两个问题, 我们设计了一种鲁棒性强的神经网络盲波束形成器. 网络结构如图 1, 其中放大器的输入输出关系为线性关系 $f(u) = ku$, 放大器输入电流矢量为 b , 联接电导矩阵为 D , 图中的方块代表电导联接. 联接电阻 $R_{ij} = 1/|D_{ij}|$. 如果联接电导 $D_{ij} < 0$, 放大器 $f(u)$ 采用正向放大; 反之采用反向放大. 显然, 这是一种变型的 Hopfield 网络^[10].

其中 $\|\cdot\|$ 表示 2-范数. 将定义的输入电流矢量 \mathbf{b} 、联接电导矩阵 \mathbf{D} 代入上式, 得

$$\begin{aligned} \mathbf{E} &= \frac{1}{2} \mathbf{v}^T \mathbf{D} \mathbf{v} - \mathbf{b}^T \mathbf{v} + \frac{1}{2Rk} \|\mathbf{v}\|^2 = E \left[\frac{1}{2} \mathbf{v}^T \mathbf{x}_c \mathbf{x}_c^T \mathbf{v} - (\mathbf{x}_c \mathbf{u}_c)^T \mathbf{v} \right] + \frac{1}{2Rk} \|\mathbf{v}\|^2 \\ &= E \left[\frac{1}{2} \|\mathbf{v}^T \mathbf{x}_c - \mathbf{u}_c\|^2 - \frac{1}{2} \|\mathbf{u}_c\|^2 \right] + \frac{1}{2Rk} \|\mathbf{v}\|^2 \geq -\frac{1}{2} E [\|\mathbf{u}_c\|^2]. \end{aligned} \quad (16)$$

(16) 式说明该网络的能量函数是有下界的. 对 (15) 式能量函数 \mathbf{E} 求导, 得

$$\frac{d\mathbf{E}}{dt} = \mathbf{v}^T \mathbf{D} \frac{d\mathbf{v}}{dt} - \mathbf{b}^T \frac{d\mathbf{v}}{dt} + \frac{1}{Rk} \mathbf{v}^T \frac{d\mathbf{v}}{dt}. \quad (17)$$

又由基尔霍夫定律推得

$$\mathbf{C} \left(\frac{d\mathbf{U}}{dt} \right)^T = -\mathbf{v}^T \mathbf{D} + \mathbf{b}^T - \frac{1}{Rk} \mathbf{v}^T. \quad (18)$$

将 (18) 式代入 (17) 式得

$$\frac{d\mathbf{E}}{dt} = -\mathbf{C} \left(\frac{d\mathbf{U}}{dt} \right)^T \frac{d\mathbf{v}}{dt} = -\frac{\mathbf{C}}{k} \left(\frac{d\mathbf{v}}{dt} \right)^T \left(\frac{d\mathbf{v}}{dt} \right) \leq 0, \quad (19)$$

$$\frac{d\mathbf{E}}{dt} = 0 \rightarrow \frac{d\mathbf{V}_i}{dt} = 0. \quad (20)$$

(19),(20) 式说明网络的能量函数持续下降, 直至能量最小点, 这个最小点对应于 $d\mathbf{U}/dt = 0$, 则得稳定输出如下:

$$\mathbf{v}_{\text{final}} = (\mathbf{I}/(Rk) + \hat{\mathbf{R}}_{xxc})^{-1} \mathbf{w}_{\text{CAB}c}, \quad (21)$$

其中 \mathbf{I} 为单位阵. 稳定输出 $\mathbf{v}_{\text{final}}$ 定义为权矢量 \mathbf{w}_c , 即

$$\mathbf{w}_c = \begin{bmatrix} \mathbf{w}_r \\ \mathbf{w}_i \end{bmatrix} = \mathbf{v}_{\text{final}}. \quad (22)$$

3.3 鲁棒约束方法

C-CAB 采用 \mathbf{w}_{CAB} 估计导引矢量, 它的估计误差会导致信号消除, 这种失配情况可以看作是带有轻微阵元扰动的优化阵列. 文献 [2] 和文献 [11] 均考虑用对角加载抑制噪声增益来解决轻微阵元扰动. 我们可以用类似的方法来降低估计误差带来的失配以增强鲁棒性.

定义波束形成的功率响应:

$$P(\theta) = |\mathbf{w}^H \mathbf{d}(\theta)|^2. \quad (23)$$

对波达方向 θ 求偏导,

$$\frac{\partial P(\theta)}{\partial \theta} = 2\text{Re} \left\{ \mathbf{w}^H \mathbf{d}(\theta) \left[\sum_{m=1}^M w_m \frac{\partial \mathbf{d}_m^H(\theta)}{\partial \theta} \right] \right\}. \quad (24)$$

由 \mathbf{w}_{CAB} 估计的导引矢量对应的入射角估计量设为 θ_0 , 而真实值设为 θ_d . 那么在 θ_0 与 θ_d 之间 (24) 式的值应越小越好. 但 $\mathbf{d}(\theta)$ 和 $\left. \frac{\partial \mathbf{d}_m^H(\theta)}{\partial \theta} \right|_{m=1}^M$ 都是限定的, 因此权矢量 \mathbf{w} 的模式应该越小越好. LCMV 算法的核心是在对权矢量线性约束的情况下, 使输出功率最小. 而

任何波束形成器其白噪声放大因子都为 $w^H w$ ，所以在估计信号方差阵中加入足够大的白噪声，可以有效地限制 w 的模的大小，增强算法的鲁棒性。此过程可以简单地通过下式实现：

$$\hat{R}_P = \hat{R}_{xx} + \gamma I, \quad (25)$$

其中 γ 是用来控制扰动强度的非负数。在神经网络方法中，该值可以方便地用 $1/(Rk)$ 来控制。这一点在下一节的实验中得到验证。

3.4 收敛时间分析

这种网络从初始状态达到稳态的时间（即收敛时间）取决于 $(I/(Rk) + \hat{R}_{xx})/C$ 的特征值，可能的最小特征值为 $1/(kRC)$ ，若 $k = 1$, $R = 10k\Omega$, $C = 10pF$ ，则相应的时间常数 $kRC = 100ns$ ，所以对于每一快拍情况神经网络的收敛速度为 $5kRC = 500ns$ 。这样，不管初始状态如何，电路可以在大约 500ns 时间内求出与准确值任意接近的解。若 k 、 R 的值取得更小，则收敛时间更短。在一般情况下，由于特征值大于 $1/(kRC)$ ，所以收敛时间会更短，非常适合用电路实时实现。

4 实验仿真

仿真实验中我们采用四阵元的均匀线性阵列。阵元间距为二分之一波长。波束形成器的输出信噪比 SINR 定义为

$$SINR = w^H d(\theta) R_{ss} d^H(\theta) w / (w^H R_{ii} w), \quad (26)$$

其中 R_{ss} 为目标信号的真实功率， R_{ii} 为干扰和噪声的真实自相关矩阵。

实验 1 该实验用来验证使用鲁棒约束时算法的性能。设有用信号为 BPSK 调制，传输码元采用 100% 升余弦调制。信号功率为 10dB，信号入射角为 40° 。背景噪声为白噪声。鲁棒约束强度由参数 γ 决定。当网络中电阻 R 取为 1Ω ，电容 C 取为 $10pF$ ， $k = 1$ 。显然相应的 γ 为 1，结果见图 2 (a)，2(b)。当网络中电阻 R 取为 0.1Ω ，电容 C 取 $10pf$ ， $k = 1$ 。相应的 γ 为 10，结果见图 3(a)，3(b)。随着约束强度的增大，算法性能随之显著上升。这是因为由导引矢量估计误差而引起的失配被虚拟噪声屏蔽了。注意：实验中为保证约束强度，电阻 R 的取值较小，这是为了仿真的需要。实际上 \hat{R}_{xx}^T 对应的联接电阻此时取值也较小，在实际神经网络的编程中可以同倍扩大，并不影响算法的性能。




图 2 (a) 输入信噪比为 10dB， $\gamma = 1$ 时的性能；(b) 1000 次快拍时的波瓣图

----- 优化解 — 神经网络鲁棒算法 C-CAB 算法




图 3 (a) 输入信噪比为 10dB, $\gamma = 10$ 时的性能; (b) 1000 次快拍时的波瓣图

--- 优化解 — 神经网络鲁棒算法 C-CAB 算法




图 4 (a) 信号为 10dB, 干扰为 5dB 时性能, $\gamma = 1$; (b) 信号为 5dB, 干扰为 10dB 时性能, $\gamma = 1$

--- 优化解 — 神经网络鲁棒算法 C-CAB 算法

实验 2 设有用信号和干扰均为 BPSK 调制, 传输码元采用 100% 升余弦调制. 信号和干扰的入射角分别为 40° 、 -30° , 干扰的归一化载频与信号相差 0.1, 信号功率为 10dB, 干扰功率为 5dB, 背景噪声为白噪声. 电阻 R 取为 1Ω , 电容 C 取为 10pF, $k = 1$, 也就是说约束强度系数 γ 为 1. 性能曲线如图 4(a). 若信号功率为 5dB, 干扰功率为 10dB, 结果如图 4(b).

5 结 论

本文提出了一种盲波束形成器的神经网络解决方案. 显然, 经过 (7)-(14) 式的分解, 应用神经网络网状计算结构, 除了计算 \hat{R}_{xxc} 的运算量, 该方法不存在其它任何计算, 完全能够胜任实时工作的要求. 除此之外, 通过矩阵的对角加载, 鲁棒性大大加强. 因为目前受实验条件限制, 以上实验均为计算机仿真实验, 神经网络的动态方程采用经典龙格-库塔法求解. 不过本文采用的神经网络结构简单, 放大器的输入输出关系不需要常规 Hopfield 网络中的 Sigmoid 函数, 而是线性函数. 这意味着采用一般的线性放大器即可, 很容易利用 VLSI 技术实现.

同时,可以将这种神经网络解决方案看作一种通用方法,因为盲波束形成通常是预先估计阵列的导引矢量。因此对于其它方法,如基于高阶累积量的方法^[2],也可以由此得到优化解,而且可以保证其鲁棒性。可以预见,该盲神经网络波束形成器由于其简单、实时和鲁棒,必将在未来数字移动通信系统中得到广泛应用。

参 考 文 献

- [1] Gooch R, Lundell J. The CM array: An adaptive beamformer for constant modulus signal. ICASSP86', Japan, 1986: 2523-2526.
- [2] Dogan M C, Mendel J M. Cumulant-based blind optimum beamforming. IEEE Trans on AES, 1994, AES-30(3): 722-740.
- [3] Agee B G, Schell S V, Gardner W A. Spectral self-coherence restoral: A new approach to blind adaptive signal extraction using antenna arrays. Proc. IEEE, 1990, 78(4): 753-767.
- [4] Wu Q, Wong K M. Blind adaptive beamforming for cyclostationary signals. IEEE Trans. on SP, 1996, SP-44(11): 2757-2767.
- [5] Burns Paul, Ding Zhi. Robustification of cyclostationary array processing techniques. ICASSP95', Michigan, USA: 1995, 5: 51589-1592.
- [6] Castedo L, Figueiras-Vidal A R. An adaptive beamforming technique based on cyclostationary signal properties. IEEE Trans. on SP, 1995, SP-43(7): 1637-1650.
- [7] Biedka Thomas E. A method for reducing computations in cyclostationarity-exploiting beamforming. ICASSP95'. Michigan, USA: 1995, 5: 1828-1831.
- [8] Gardner W A. Statistical Spectral Analysis: A Nonprobabilistic Theory. Englewood Cliffs, NJ: Prentice-Hall, 1987.
- [9] Cox H, Zeskind R M, Owen M M. Effects of amplitude and phase errors on linear predictive array processors. IEEE Trans. on ASSP, 1988, ASSP-36(1): 10-19.
- [10] Tank D W, Hopfield J J. Simple "neural" optimization networks: An A/D converter, signal decision circuit, and a linear programming circuit. IEEE Trans. on CAS, 1986, CAS-33(5): 533-541.
- [11] Cox H, Zeskind R M, Owen M M. Robust adaptive beamforming. IEEE Trans. on ASSP, 1987, ASSP-35(10): 1365-1375.

ROBUST BLIND NEURAL NETWORK BEAMFORMER BASED ON CYCLOSTATIONARY

He Zhenya Chen Yuxin

(Department of Radio Engineering, Southeast University, Nanjing 210096)

Abstract A new blind beamformer with improved Hopfield network is presented in this paper. To estimate the steering vector, the signal property of cyclostationary is used. To suppress interference, traditional LCMV beamforming is employed. To improve the robustness, diagonal loading technique is exploited. To turn into realization in real time, a neural network structure is given. Simulations demonstrate the excellent performance of the proposed approach in a wide variety of situations.

Key words Blind beamforming, Cyclostationary, Diagonal loading, Neural network, Robust

何振亚: 男, 1923年生, 教授、博士生导师, IEEE fellow, 国家攀登计划重大关键项目首席科学家, 全国神经网络委员会副主席。研究领域有: 神经网络, 自适应信号处理, 多维数字信号处理。
陈宇欣: 男, 1972年生, 博士生, 研究方向为自适应信号处理, 阵列信号处理和神经网络。