

## 复数离散 Hopfield 网络盲检测 64QAM 信号

张 昀<sup>\*①②</sup> 张志涌<sup>②</sup>

<sup>①</sup>(南京邮电大学通信与信息工程学院 南京 210003)

<sup>②</sup>(南京邮电大学自动化学院 南京 210003)

**摘 要:** 针对复数多电平 QAM 信号的盲检测问题, 该文提出了一个新的复数离散多电平 Hopfield 神经网络。该网络的实部、虚部各含一个多电平离散激励实函数。该文分析了经典两电平离散 Hopfield 神经网络能量函数的局限性, 构造了一个新的复数多电平神经网的能量函数, 并用此能量函数讨论了神经网的稳定性。当该神经网的权重矩阵借助接收数据补投影算子构成时, 该复数离散多电平 Hopfield 网络可有效地求解带整数约束的二次规划问题, 从而实现 QAM 信号盲检测。仿真试验表明: 该算法所需接收数据较短, 就可到达全局真平衡点, 计算难度大大降低, 具有良好的快速性。

**关键词:** 信号处理; 复数离散 Hopfield 神经网络; 盲检测; QAM 信号

**中图分类号:** TN911.23

**文献标识码:** A

**文章编号:** 1009-5896(2011)02-0315-06

**DOI:** 10.3724/SP.J.1146.2010.00921

## Blind Detection of 64QAM Signals with a Complex Discrete Hopfield Network

Zhang Yun<sup>①②</sup> Zhang Zhi-yong<sup>②</sup>

<sup>①</sup>(College of Telecommunications and Information Engineering,

Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

<sup>②</sup>(College of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

**Abstract:** A novel algorithm based on Complex Discrete Hopfield Neural Network (CDHNN) is proposed to detect blindly multi-valued QAM signals in this paper. A multi-valued discrete activation function is constructed in both of the real part and imaginary part of CDHNN. Limitation for the energy function of the classic binary-valued discrete Hopfield neural network is analyzed in this paper and a new energy function for CDHNN is also constructed. Further more the stability for multi-valued CDHNN is also proved in the paper. While the weighted matrix of CDHNN is constructed by the complementary projection operator of received signals, the problem of quadratic optimization with integer constraints can successfully solved with the CDHNN, and the QAM signals are blindly detected. Simulation results show that the algorithm reaches the real equilibrium points with shorter received signals and show high speed to detect blindly multi-valued signals.

**Key words:** Signal processing; Complex Discrete Hopfield Neural Network (CDHNN); Blind detection; QAM signal

### 1 引言

在现代通信系统中, MQAM(Multi-Quadrature Amplitude Modulated)调制信号由于其高频谱利用率在很多领域得到了广泛应用, 如数字电视广播、Internet 宽带接入等。盲检测技术由于无需训练序列, 不仅提高了系统的带宽效率, 而且也使得通信具有智能性能。异步传输模式ATM(Asynchronous Transfer Mode)、局域网LAN(Local Area Network)和高速数字用户线VDSL(Very high-rate Digital Subscriber Line)等多点通信网络再次引发了对

QAM信号盲检测的研究需求<sup>[1]</sup>。

运用神经网络实现盲信号检测的文献很多, 但它们均以二阶统计量或高阶统计量为基础<sup>[2,3]</sup>, 所需的数据量都相当大, 因而缺乏实时处理的潜力。而且由于信道失真的影响, 解调器接收的MQAM信号星座图弥散且旋转, 信号星座点之间相位差随调制阶数的升高而下降, 从而使高阶QAM信号的正确解调难度变大。

二电平HNN应用于“非盲多用户检测”的文献时有所见, 且HNN构成的(非盲)多用户检测器性能明显优于其它传统检测器<sup>[4,5]</sup>。经典离散Hopfield神经网络DHNN(Discrete Hopfield Neural Network)通常基于二电平神经元模型, 由于采用符号离散激

2010-08-27收到, 2010-11-14改回

国家自然科学基金(60772060)资助课题

\*通信作者: 张昀 y021001@njupt.edu.cn

活函数, 因此只能局限于处理二进制信号, 讨论也都限在实数神经网络, 显然不能适应现代通信发展中 QAM 信号盲检测研究的需求。在连续 Hopfield 神经网络 CHNN (Continuous Hopfield Neural Network) 上, 文献 [6,7] 提出了多电平连续激活函数和相应的实数域 CHNN, 但是此文献只能解决实数域非盲的去噪问题, 即“联想记忆”问题, 而不能解决信号未知情况下的复数域最优解问题, 即 MQAM 盲检测问题。文献 [8] 构造了一个复数 CHNN, 但是只能用于检测复数二进制信号即 QPSK, 依然无法检测复数多电平信号。关于多电平 CHNN 的稳定性分析直至 2008 年才出现 [9], 由于分析时隐性利用李普希兹 (Lipschitz) 条件, 所以该文献分析方法不适用于多电平 DHNN。还有一种在极坐标中定义的“单位圆等分角多值激励函数”。由该激励函数构成的 HNN 用指数形式的复数表达 [10,11]。因此, 有的文献也把它称为 complex-valued neural network。这种激励函数只能适用于信息和权矩阵可以幅相编码 (amplitude and phase coding) 的联想记忆场合, 不能应用于权矩阵无法幅相编码的组合优化问题。综上, DHNN 用于 MQAM 信号盲检测问题迄今未见, 其稳定性研究更是缺乏。

本文构造了一个新的复数多电平离散 Hopfield 神经网络 (CDHNN), 通过求解二次规划问题实现多电平复数信号盲检测。与迄今文献方法不同, 本文引入适用于 64QAM 的离散激活函数, 构造了一个新的适用于多电平 CDHNN 的能量函数, 并给出了网络稳定性的证明。由于离散激活函数利用了发送信号的字符集信息, 信号的状态空间  $\{-7, -5, -3, -1, 1, 3, 5, 7\}^N$  相当于一个超多面体, 神经元在此超多面体的顶点上进行状态转换, 因此克服了盲检测后信号弥散、旋转的固有问题。

### 2 SIMO 离散时间信道模型及问题的提出

忽略噪声时, 单输入多输出 SIMO (Single-Input Multi-Output) 离散时间信道的接收方程、盲处理方程分别如下:

$$(\mathbf{x}(k))_{q \times 1} = \sum_{j=0}^M (\mathbf{h}_j)_{q \times 1} s(k-j) \quad (1)$$

$$\mathbf{X}_N = \mathbf{S} \mathbf{\Gamma}^T \quad (2)$$

在此, 发送信号阵  $\mathbf{S} = [\mathbf{s}_{L+M}(k), \dots, \mathbf{s}_{L+M}(k+N-1)]^T = [\mathbf{s}_N(k), \dots, \mathbf{s}_N(k-M-L)]_{N \times (L+M+1)}$ ,  $(\mathbf{\Gamma})_{(L+1)q \times (L+M+1)}$  是  $\mathbf{h}_j, j = 0, 1, \dots, M$  构成的块 Toeplitz 矩阵;  $[\mathbf{h}_0, \dots, \mathbf{h}_M]_{q \times (M+1)}$  是通信信道的冲激响应, 接收数据阵为  $(\mathbf{X}_N)_{N \times (L+1)q} = [\mathbf{x}_L(k), \dots, \mathbf{x}_L(k+N-1)]^T$ 。

式 (2) 表明,  $\mathbf{\Gamma}$  满列秩时, 一定有  $\mathbf{Q} = \mathbf{U}_c \mathbf{U}_c^H$  满

足  $\mathbf{Q} \mathbf{s}_N(k-d) = \mathbf{0}$ 。其中  $d = 0, \dots, M+L$ , 且  $\mathbf{U}_c \in R^{N \times (N-(L+M+1))}$  是奇异值分解  $\mathbf{X}_N = [\mathbf{U}, \mathbf{U}_c] \cdot \begin{bmatrix} \mathbf{D} \\ \mathbf{0} \end{bmatrix} \cdot \mathbf{V}^H$

中的酉基阵。据此构造性能函数及优化问题 [7]

$$J_0 = \mathbf{s}_N^H(k-d) \mathbf{Q} \mathbf{s}_N(k-d) = \mathbf{s}^H \mathbf{Q} \mathbf{s} \quad (3)$$

$$\hat{\mathbf{s}} = \arg \min \{J_0\} \quad (4)$$

其中  $\mathbf{s} = \mathbf{s}_R + i \cdot \mathbf{s}_I$  表示复向量, 其元素的实部、虚部都属于集合  $A, A = \{\pm 1, \pm 3, \pm 5, \pm 7\}$ 。

求解式 (4) 的优化问题, 也即实现高阶 QAM 信号的盲检测。文献 [8] 构造了一个复数 HNN, 但是依然局限于二进制信号即 QPSK, 无法检测多电平信号。考虑到 DHNN 极强的收敛速度能显著加快信号检测, 我们考虑运用多电平 CDHNN 求解式 (4)。

### 3 复 Hopfield 神经网络的构造及稳定性

鉴于经典离散 Hopfield 网无法处理多电平复数信号, 为求解式 (4) 的优化问题, 本节构造新的复数 Hopfield 神经网络如图 1 和图 2 所示, 设计了新的针对 8 电平信号的离散激活函数, 并提出了新网络的能量函数。




图 1 离散时间离散空间 Hopfield 神经网络结构图




图 2 复 Sigmoid 函数  $\sigma_s(\cdot)$  结构

如图 1 和图 2 所示, 复数 Hopfield 神经网络的动态方程为

$$\begin{aligned} \mathbf{s}(k+1) &= \mathbf{s}_R(k+1) + i \cdot \mathbf{s}_I(k+1) \\ &= \sigma_{sR}(\text{Re}(\mathbf{W}\mathbf{s}(k))) + i \cdot \sigma_{sI}(\text{Im}(\mathbf{W}\mathbf{s}(k))) \\ &= \sigma_s(\mathbf{W}\mathbf{s}(k)) \end{aligned} \quad (5)$$

其中状态向量  $\mathbf{s}(k) = [s_1(k), s_2(k), \dots, s_N(k)]^T$ ,

$$\begin{aligned} s_i(k+1) &= \sigma_{sR} \left( \text{Re} \left( \sum_{j=1}^N w_{ij} s_j(k) \right) \right) \\ &+ i \cdot \sigma_{sI} \left( \text{Im} \left( \sum_{j=1}^N w_{ij} s_j(k) \right) \right) \end{aligned} \quad (6)$$

权矩阵  $\mathbf{W} \in C^{N \times N}$ , 且  $\mathbf{W}^H = \mathbf{W}$ 。复离散激活函数  $\sigma_s(\cdot) = \sigma_{s_R}(\cdot) + i \cdot \sigma_{s_I}(\cdot)$ , 且  $\sigma_{s_R}(t) = \sigma_{s_I}(t)$  为本文构造的 8 电平离散激活函数, 如图 3 所示。




图 3 函数  $\sigma_{s_R}(t)$  示意图

$$\sigma_{s_R}(t) = \sigma_{s_I}(t) = \begin{cases} \text{sgn}(t) \cdot (1 + 2 \cdot \text{fix}(t/2)), & \forall |t| < 8 \\ 7 \cdot \text{sgn}(t), & \forall |t| \geq 8 \end{cases} \quad (7)$$

其中  $\text{fix}(\cdot)$  表示向原点取整,  $\text{sgn}(\cdot)$  表示符号函数。

文献[12]中传统形式离散 Hopfield 网络在同步运行模式下的能量函数定义为

$$E(\mathbf{s}, k) = -\frac{1}{2} \sum_{l,j=1}^N w_{lj} s_l(k) s_j(k-1) \quad (8)$$

此能量函数仅适用于“实数二电平激活函数”, 当激活函数为多电平时, 式(8)不能保证能量随时间进程而始终下降。在表 1 中的第 1、第 4 行数据就表明: 当  $s_j(k-1)$  与  $s_j(k+1)$  正负号相同, 且  $|s_j(k-1)| > |s_j(k+1)|$  时, 就会使能量增量为“正”(参见表 1 中  $A_j$  的数值)。

基于前面设计的 Hopfield 神经网络及离散激活函数, 下面给出不同于传统形式的新的能量函数。

**定理 1** 假设  $\mathbf{W}$  是 Hermitian 阵, 则

$$E(\mathbf{s}, k) = -\sum_{l,j=1}^N \text{Re}(w_{lj} s_l^*(k) s_j(k-1)) + \sum_{j=1}^N \left( \int_0^{s_{Rj}(k)} \delta(\tau) d\tau + \int_0^{s_{Ij}(k)} \delta(\tau) d\tau + \int_0^{s_{Rj}(k-1)} \delta(\tau) d\tau + \int_0^{s_{Ij}(k-1)} \delta(\tau) d\tau \right) \quad (9)$$

为多电平 CDHNN 在同步运行模式下的能量函数, 进而保证网络在 64QAM 信号下能保证逐步下降并收敛到稳定状态。其中  $t = \delta(\tau)$  用以记述式(7)所定义的  $\sigma_{s_R}(t) = \sigma_{s_I}(t)$  的反函数, 如图 4 所示。




图 4 函数  $\delta(\tau)$  示意图

**证明** 假设  $\Delta E(k) = E(\mathbf{s}, k+1) - E(\mathbf{s}, k)$ , 改写式(9)为全实数形式

$$E(\mathbf{s}, k) = -\mathbf{s}_{RI}^T(k) \mathbf{W}_{RI} \mathbf{s}_{RI}(k-1) + \sum_{j=1}^{2N} \left( \int_0^{s_{Rlj}(k)} \delta(\tau) d\tau + \int_0^{s_{RIj}(k-1)} \delta(\tau) d\tau \right) \quad (10)$$

其中  $\mathbf{s}_{RI} = \begin{bmatrix} \mathbf{s}_R \\ \mathbf{s}_I \end{bmatrix}$ ,  $\mathbf{W}_{RI} = \begin{bmatrix} \mathbf{W}_R & -\mathbf{W}_I \\ \mathbf{W}_I & \mathbf{W}_R \end{bmatrix}$ 。

由于  $\mathbf{W}_{RI}$  是对称阵, 可得

$$\Delta E(k) = -(\mathbf{s}_{RI}^T(k+1) - \mathbf{s}_{RI}^T(k-1)) \cdot \mathbf{W}_{RI} \mathbf{s}_{RI}(k) + \sum_{j=1}^{2N} \left( \int_{s_{Rlj}(k-1)}^{s_{Rlj}(k+1)} \delta(\tau) d\tau \right) \quad (11)$$

$$= -\Delta \mathbf{s}_{RI}^T \mathbf{W}_{RI} \mathbf{s}_{RI}(k) + \sum_{j=1}^{2N} \left( \int_{s_{Rlj}(k-1)}^{s_{Rlj}(k+1)} \delta(\tau) d\tau \right) = \sum_{j=1}^{2N} \left[ -\Delta s_{Rlj} \left( \sum_{i=1}^{2N} w_{Rlji} s_{RIi}(k) \right) + \int_{s_{Rlj}(k-1)}^{s_{Rlj}(k+1)} \delta(\tau) d\tau \right] = \sum_{j=1}^{2N} [A_j + C_j] = \sum_{j=1}^{2N} \Delta E_j(k) \quad (12)$$

表 1  $\Delta E_j(k)$  几种典型可能取值

	$s_{Rlj}(k-1)$	$s_{Rlj}(k+1)$	$-\Delta s_{Rlj}$	$\delta[s_{Rlj}(k+1)]$	$A_j$	$C_j$	$\Delta E_j(k)$
$\Delta s_{Rlj} > 0$	-7	-1	-6	[-2,0]	(0,12]	-24	(-24,-12]
	-3	1	-4	[0,2]	(-8,0]	-4	(-12,-4]
	1	3	-2	[2,4]	(-8,-4]	4	(-4,0]
$\Delta s_{Rlj} < 0$	5	1	4	[0,2]	[0,8]	-12	[-12,-4]
	1	-5	6	[-6,-4]	[-36,-24]	12	[-24,-12]
	-1	-7	6	(-\infty,-6)	(-\infty,-36)	24	(-\infty,-12)

式中  $A_j = -\Delta s_{RIj} \cdot \delta[s_{RIj}(k+1)]$ ,  $\delta[s_{RIj}(k+1)] = \left( \sum_{i=1}^{2N} w_{RIji} s_{RIi}(k) \right)$ ,  $C_j = \int_{s_{RIj}(k-1)}^{s_{RIj}(k+1)} \delta(\tau) d\tau$ ,  $\Delta s_{RI} = s_{RI}(k+1) - s_{RI}(k-1)$ 。

对于  $s_{RIj}(k-1)$  和  $s_{RIj}(k+1)$  的任意取值, 只要两者不等, 那么根据表 1 所列的典型情况讨论, 都可以得知  $\Delta E_j(k)$  始终小于 0, 进而可知  $\Delta E(k) < 0$ 。换句话说, 神经网的能量始终下降, 直至  $s_{RIj}(k+1) = s_{RIj}(k-1)$  为止。证毕

考虑动态过程平衡点条件及复数的实部、虚部, 可写出

$$\begin{cases} s_R(k+1) = \sigma_{sR} (\text{Re}(\mathbf{W}\mathbf{s}(k))) = s_R(k) \\ s_I(k+1) = \sigma_{sI} (\text{Im}(\mathbf{W}\mathbf{s}(k))) = s_I(k) \end{cases}$$

因此, 可得如下结论:

**定理 2** 在同步模式下, 图 1 所示复 Hopfield 神经网络到达极值点的必要条件是: 状态向量的实部和虚部同时平衡。

该定理表明: (1)极值点一定是平衡点。(2)那些实部和虚部非同时到达平衡的点, 不可能是极值点。该定理为从平衡点中筛选出极值点提供了有利的依据。

#### 4 盲检测信号的神经网络权阵配置

为运用多电平 CDHNN 求解式(4)的信号盲检测问题, 设计神经网的连接矩阵取如下形式

$$\mathbf{W}_{RI} = -\lambda [\mathbf{Q}_{RI} - \text{diag}(\mathbf{Q}_{RI})] \quad (13)$$

其中  $\mathbf{Q}_{RI} = \begin{bmatrix} \mathbf{Q}_R & -\mathbf{Q}_I \\ \mathbf{Q}_I & \mathbf{Q}_R \end{bmatrix}$ 。

将式(13)代入式(10)可得

$$E(k) = \lambda \cdot s_{RI}^T(k) \cdot [\mathbf{Q}_{RI} - \text{diag}(\mathbf{Q}_{RI})] \cdot s_{RI}(k-1) + \sum_{j=1}^{2N} \left( \int_0^{s_{RIj}(k)} \delta(\tau) d\tau + \int_0^{s_{RIj}(k-1)} \delta(\tau) d\tau \right) \quad (14)$$

在此,  $\mathbf{Q}$  是式(3)中的补投影算子,  $\text{diag}(\mathbf{Q}_{RI})$  是由  $\mathbf{Q}_{RI}$  对角元构成的对角阵,  $\lambda$  是正增益系数。

由式(11)可得, 当  $\Delta s_{RI} = s_{RI}(k+1) - s_{RI}(k-1) = \mathbf{0}$  时, 同步模式下 CDHNN 达到平衡状态。平衡状态有两种情况:

(1)  $s_{RI}(k+1) = s_{RI}(k-1) \neq s_{RI}(k)$ , CDHNN 陷入极限环, 不可能是极值点。

(2)  $s_{RI}(k+1) = s_{RI}(k-1) = s_{RI}(k)$ , CDHNN 到达平衡点, 可能是极值点。

显然, 我们希望的是第(2)种情况。一旦仿真中出现极限环现象, 将取随机初值重新迭代。

由于初始值随机产生, 由大数定理可知, 经第 1 步迭代后, 所有状态数据会向坐标原点收缩。这样为了使得搜索空间逐渐扩大, 正增益系数  $\lambda$  的取值就很重要, 经仿真经验数据, 一般取  $\lambda$  在 1.1 左右。

当 CDHNN 到达极值点时, 有

$$\begin{aligned} s_{RI}(k) &= \sigma_{sR} \left\{ \lambda \cdot [\mathbf{Q}_{RI} - \text{diag}(\mathbf{Q}_{RI})] \cdot s_{RI}(k-1) \right\} \\ &= -\sigma_{sR} \left\{ \lambda \cdot \text{diag}(\mathbf{Q}_{RI}) \cdot s_{RI}(k-1) \right\} = s_{RI}(k-1) \end{aligned}$$

所以能量函数在“平衡点集”中的极值点就是式(3)优化问题的解, 由此得到的检测信号即为所需的发送信号。

#### 5 仿真实验

实验采用  $h(t) = \sum_{j=1}^2 (w_{Rj} (h_R(\alpha, t - \tau_{Rj})) + i \cdot w_{Ij}$

$\cdot (h_I(\alpha, t - \tau_{Ij})))$  经  $q = 3$  过采样的 2 径合成复数信道。

其中  $h_R(\alpha, t - \tau_{Rj})$ ,  $h_I(\alpha, t - \tau_{Ij})$  分别是滚降因子  $\alpha = 0.1$ , 延迟因子  $\tau_{Rj}$ ,  $\tau_{Ij}$  随机产生的升余弦脉冲响应;  $w_{Rj}$ ,  $w_{Ij}$  是在 (0,1) 间均匀分布的随机权重系数。考虑噪声时, 接收信号方程为

$$\begin{aligned} (\tilde{\mathbf{x}}(k))_{q \times 1} &= \sum_{j=0}^M (\mathbf{h}_j)_{q \times 1} (s(k-j)) + (\mathbf{n}(k))_{q \times 1} \\ &= \mathbf{x}(k) + \mathbf{n}(k) \end{aligned}$$

式中  $\mathbf{n}(k)$  是正态白噪声, 与  $s(k)$  独立。而信噪比定

义为  $\text{SNR} = 10 \lg \frac{E(|x_j(k)|^2)}{E(|n_j(k)|^2)}$ ,  $\forall j = 1, \dots, q$ 。

**实验 1** 固定数据长度时, 分别采用固定信道与随机信道进行 Monte Carlo 试验的算法误码率。

对于 16QAM 信号, 固定数据长度  $N = 300$ , 对于 64QAM 信号, 固定数据长度  $N = 500$ , 各自进行 100 次 Monte Carlo 实验, 本文算法平均误码率分别如图 5, 图 6 所示。试验表明, 本文算法有效地克服了传统神经网络算法局限于二电平信号和实数域的缺点, 而适用于随机复信道高阶 QAM 信号的盲检测。

需要说明的是, 低信噪比下, 算法有可能陷入伪平衡点, 而处于局部极值。此时, 需要附加约束:  $J = \mathbf{s}^H \mathbf{Q} \mathbf{s} < \eta$ , 重新选取起始点, 以防止算法陷入局部极小。  $\eta$  是阈值, 可以根据接收数据阵  $\mathbf{X}_N$  算得。

**实验 2** 算法与数据量的关系。

本实验针对 16QAM 和 64QAM 信号的不同接收数据量, 进行了误码率比较。从图 7, 图 8 可以看出: 有效盲检测所需的数据量与 QAM 信号的星座复杂度有关。对于 16QAM 信号,  $N = 200$  数据量就可; 而对于 64QAM 信号, 则需要  $N = 500$  的




图 5 固定数据长度  $N = 300$  时 16 QAM 信号算法误码率




图 6 固定数据长度  $N = 500$  时 64 QAM 信号算法误码率




图 7 16 QAM 信号下信道盲检测性能与数据长度关系




图 8 64 QAM 信号下信道盲检测性能与数据长度关系




图 9 信噪比 40 dB 时, 传统能量函数与本文能量函数随迭代次数变化图

数据, 才能成功检测。值得指出: 本文方法所需的数据量, 约是其他二阶统计盲检测算法所需数据量的 1/5, 仅是高阶统计盲检测算法所需数据量的 1/10。

**实验 3** 信噪比 40 dB 情况下, 两种能量函数随迭代次数变化

图9为信噪比40 dB情况下, 传统DHNN能量函数式(8)随迭代次数变化, 与本文提出的适用于多电平DHNN的能量函数式(9)随迭代次数的仿真图。可以看出, 传统能量函数在迭代过程中有上升的情况, 明显不适用于多电平CDHNN。

### 6 结束语

迄今为止, 利用神经网络盲检测信号的算法文献很多, 但这些文献算法往往依赖统计量, 并且局限于两状态网络, 无法解决多电平信号问题。本文算法的权矩阵的来源和构造与传统神经网络算法相比有根本不同, 传统的神经网络只能解决实数域非盲的去噪问题, 即“联想记忆”问题, 而不能解决信号未知情况下的复数域最优解问题, 即 MQAM 盲检测问题。仿真结果表示, 本文的多电平 CDHNN 网络仅需较小数据量, 就能很好检测 64QAM 信号, 收敛速度极快, 能很好适用于随机信道, 具有很强

的实时处理的能力。本文提出的性能函数当信道含有公零点时也可以盲检测信号, 但此时的最小值为最小二乘拟合意义上的, 性能受噪声影响较大。如何扩大性能函数的应用范围以及含公零点信道下性能函数与信噪比之间的关系, 还有待进一步研究。

### 参考文献

- [1] Wang H and Zhang L. Optimal Hopfield neural network and application for multi-user detection[C]. 2009 International Conference on Communication Software and Networks, Chengdu, China, Feb. 2009: 567-570.
- [2] Ding Z and Li Y. Blind Equalization and Identification[M]. New York: Marcel Dekker 2002, Chapter 5.
- [3] Giannakis G B, Hua Y B, and Stoica P, *et al.* Signal Processing Advances in Wireless and Mobile Communications, vol. 1: Trends in Channel Estimation and Equalization[M]. NJ, USA, Prentice Hall PTR Upper Saddle River, 2000, Chapter 6.
- [4] Achim E and Werner T G, *et al.* A survey of multiuser / multisubchannel detection schemes based on recurrent neural networks[J]. *Wireless Communications and Mobile Computing*, 2002, 2(3): 269-284.
- [5] Sheikh A T and Sheikh S A. Efficient Variants of Square Contour algorithm for blind equalization of QAM signals[C]. International Conference on Electrical, Computer

- Engineering, Hong Kong, China March 23–25, 2009: 200–208.
- [6] Quan Q and Kim J. Intercarrier interference suppression for OFDM systems using Hopfield neural network[J]. *International Journal of Computer Science and Network Security*, 2006, 6(6): 157–162.
- [7] Zurada J M. Neural networks: binary monotonic and multiple-valued[C]. Proc. of the 30th IEEE International Symposium on Multiple-Valued Logic, Portland, Oregon, May 23–25, 2000: 67–74.
- [8] 张志涌, 张昀. 复数Hopfield盲恢复多用户QPSK信号[J]. 东南大学学报, 2008, 38(12): 18–22.  
Zhang Z Y and Zhang Y. Blind recovery of multiuser QPSK with a complex Hopfield network[J]. *Journal of Southeast University*, 2008, 38(12): 18–22.
- [9] Liu Y and You Z. Stability analysis for the generalized Hopfield neural networks with multi-level activation functions[J]. *Neurocomputing*, 2008, 71(16/17/18): 3595–3601.
- [10] Zhou W and Zurada J M. A class of discrete time recurrent neural networks with multivalued neurons[J]. *Neurocomputing*, 2009, 72(16/17/18): 3782–3788.
- [11] NITTA T. Complex-Valued Neural Networks: Utilizing High-Dimensional Parameters[M]. Hershey PA USA: IGI Global, 2009: 361–365.
- [12] Gupta M M, Jin L, and Homma N. Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory[M]. New Jersey: IEEE Press, 2003: 469–577.
- 张昀: 女, 1975年生, 博士生, 研究领域为通信系统中的智能算法与信号处理.
- 张志涌: 男, 1944年生, 教授, 博士生导师, 研究领域为系统辨识、盲均衡等.