

# 双 Sigmoid Hopfield 神经网络盲检测算法

宦如松,于舒娟,张 昀

(南京邮电大学 电子科学与工程学院,江苏 南京 210003)

**摘 要:**改进 Hopfield 神经网络(HNN)的激活函数可以提高网络的抗噪能力,但是其收敛速度会大大降低。为了解决改进激活函数后 HNN 收敛速度较慢的问题,文中提出一种基于双 Sigmoid Hopfield 神经网络(DSHNN)的盲检测算法。该算法不仅继承了 HNN 所有的优点,还极大地提高了算法的收敛速度,缩短了运行时间。仿真实验表明,DSHNN 算法比 HNN 算法的抗干扰性能略强,且其能量函数的收敛速度大大提升。

**关键词:**盲检测;激活函数;双 Sigmoid Hopfield 神经网络

中图分类号:TP301.6

文献标识码:A

文章编号:1673-629X(2014)04-0100-03

doi:10.3969/j.issn.1673-629X.2014.04.025

## Blind Detection Algorithm with Double Sigmoid Hopfield Neural Network

HUAN Ru-song, YU Shu-juan, ZHANG Yun

(College of Electronic Science and Engineering, Nanjing University of Posts and Telecommunications,  
Nanjing 210003, China)

**Abstract:** Improving the Hopfield Neural Networks' (HNN) activation function could enhance this network's immunity, but its convergence speed was greatly reduced. In order to solve the problem of slow convergence of HNN after activation function improved, applied the Double Sigmoid Hopfield Neural Networks (DSHNN) for blind detection. This algorithm not only inherited all the advantages of the HNN, but also greatly improved the convergence speed and shortened the running time. Simulation results show that, the DSHNN had stronger anti-interference performance than the HNN slightly and enhanced the convergence rate of the energy function greatly.

**Key words:** blind detection; activation function; DSHNN

## 0 引 言

近年来,3G、物联网(Internet Of Things, IOT)和长期演化(Long Term Evolution, LTE)等技术的迅速发展,不仅对通信中的抗干扰性能提出了极高的要求,更要求整个网络能有较高的速率。现今,利用 Hopfield 神经网络(Hopfield Neural Networks, HNN)进行盲检测的算法已经有了一定研究<sup>[1-3]</sup>。但是,用于盲检测的这些神经网络大多通过改变其激活函数来提高其抗干扰性能<sup>[4]</sup>,这些方法都降低了能量函数的收敛速度,导致算法运行时间大大提高。

文中把双 Sigmoid 神经网络<sup>[5]</sup>(Double Sigmoid Hopfield Neural Networks, DSHNN)运用于解决盲检测问题,该网络对原有算法的性能进行改进。仿真结果表明,此算法大大加快了能量函数的收敛速度,减少了

运行时间,且表现出较强的抗噪性能。

## 1 性能函数与优化问题的建立

在无噪声情况下, SIMO 数字通信系统中接收信号方程、盲处理方程如下所示<sup>[6]</sup>:

$$(\mathbf{x}(k))_{q \times 1} = [\mathbf{h}_0, \dots, \mathbf{h}_M] (\mathbf{s}(k))_{(M+L+1) \times 1} = \sum_{j=0}^M (\mathbf{h}_j)_{q \times 1} s(k-j) \quad (1)$$

$$\mathbf{x}_N = \mathbf{s} \mathbf{I}^{\text{ti}} \quad (2)$$

在此,发送信号阵  $\mathbf{s} = [s_{L+M}(k), \dots, s_{L+M}(k+N-1)]^T = [s_N(k), \dots, s_N(k-M-L)]_{N \times (L+M+1)}$ ,  $(\mathbf{I})_{(L+1)q \times (L+M+1)}$  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  $(\mathbf{x}_N)_{N \times (L+1)q} = [\mathbf{x}_L(k), \dots, \mathbf{x}_L(k+N-1)]^T$ 。

收稿日期:2013-06-07

修回日期:2013-09-14

网络出版时间:2014-01-28

基金项目:国家自然科学基金资助项目(60772060, 61104103);南京邮电大学青蓝工程基金(NY210037)

作者简介:宦如松(1988-),男,硕士研究生,研究方向为新一代无线通信与通信信号处理;于舒娟,副教授,硕士研究生导师,研究方向为现代通信中的信号处理和智能信息处理技术;张 昀,讲师,硕士研究生导师,研究方向为通信信号处理和软计算算法理论。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20140128.1149.040.html>

式(2)表明,  $\boldsymbol{\Gamma}$  满列秩时, 一定有  $\boldsymbol{Q} = \boldsymbol{U}_c \boldsymbol{U}_c^H$  满足  $\boldsymbol{Q} \boldsymbol{s}_N(k-d) = \mathbf{0}$ 。其中  $d = 0, \dots, M+L$ , 且  $\boldsymbol{U}_c \in R^{N \times (N-(L+M+1))}$  是奇异值分解  $\boldsymbol{x}_N = [\boldsymbol{U}, \boldsymbol{U}_c] \cdot \begin{bmatrix} \boldsymbol{D} \\ \mathbf{0} \end{bmatrix} \cdot \boldsymbol{V}^H$

中的酉基阵。进而构造性能函数及优化问题:

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

$$\hat{\boldsymbol{s}} = \operatorname{argmin}\{J_0\} \tag{4}$$

显然, 式(4)是个带约束条件的二次型函数优化问题, 则求解式(4)的优化问题就是实现信号的盲检测。鉴于 HNN 可以检测出信号, 而改变激活函数的 HNN 提高了网络抗干扰能力但导致 HNN 的收敛速度下降, 算法运行时间大大增长。于是, 文中考虑运用 DSHNN 求解式(4)。

## 2 DSHNN 的构建和稳定性证明

动态神经元可以通过不同的内部联系构造出各种复杂动态神经网络<sup>[7]</sup>。文中为每个神经元又加上了一个 Sigmoid 函数, 然后把这些神经元联系在一起, 则构造出一个新的神经网络模型<sup>[3,5,8]</sup> (DSHNN), 该模型可由下面的方程来描述:

$$\dot{\boldsymbol{s}} = \boldsymbol{\sigma}_2(\boldsymbol{\sigma}_1(\boldsymbol{w} \boldsymbol{s})) \tag{5}$$

其中,  $\boldsymbol{s} = [s_1, s_2, \dots, s_N]$  为神经状态向量;  $\boldsymbol{w}$  是网络的连接权矩阵, 且  $\boldsymbol{w} \in C^{N \times N}$ ,  $\boldsymbol{w}^T = \boldsymbol{w}$ ;  $\boldsymbol{\sigma}_1(\cdot)$  为第一个 Sigmoid 函数;  $\boldsymbol{\sigma}_2(\cdot)$  为第二个 Sigmoid 函数。

式(5)也可以写成:

$$\frac{ds_i(t)}{dt} = \sigma_{2i}(\sigma_{1i}(y_i(k))) \quad i = 1, \dots, N \tag{6}$$

$$y_i(k) = \sum_{j=1}^N \omega_{ij} s_j(k) \quad i = 1, \dots, N \tag{7}$$

其中,  $s_i(t)$  为第  $i$  个神经元在  $t$  时刻的状态;  $\omega_{ij}$  是从第  $j$  个神经元  $s_j$  到第  $i$  个神经元  $s_i$  之间的神经元连接权值。

根据文献[4-5], 文中的第一个 Sigmoid 函数选为:

$$\sigma_1(x) = \frac{\tanh(\frac{x_0}{\mu}) + 0.5(1 + \tanh(\frac{x - x_0}{\mu}))}{1 + \tanh(\frac{x_0}{\mu})} \varepsilon(x) + \frac{0.5(1 + \tanh(\frac{x - x_0}{\mu}))}{1 + \tanh(\frac{x_0}{\mu})} \varepsilon(-x) \tag{8}$$

其中,  $\mu$  为放大因子;  $x_0$  是一个正实数, 是神经元输入的阈值;  $\varepsilon(x)$  为阶跃函数。

文中的第二个激活函数选为<sup>[4]</sup>:

$$\sigma_2(x) = \operatorname{sign}(x) \tag{9}$$

根据文献[5], DSHNN 的能量函数可以写成如下

形式:

$$E(t) = -\frac{1}{2} \boldsymbol{\sigma}_1^T(t) \boldsymbol{w} \boldsymbol{\sigma}_1(t) - \sum_{i=1}^N \int_0^{y_i(t)} \sigma_{1i}^{-1}(\tau) d\tau \tag{10}$$

其中,  $\sigma_{1i}^{-1}(\tau)$  为激活函数  $\sigma_{1i}(\tau)$  的反函数。

根据文献[5,9-11]可以得出 DSHNN 为稳定结构。DSHNN 的能量函数在运行过程中是逐渐下降的, 最后达到完全收敛状态。

## 3 盲检测信号的神经网络权阵配置

为运用 DSHNN 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<sup>[12]</sup>:

$$\boldsymbol{w} = -\lambda [\boldsymbol{Q} - \operatorname{diag}(\boldsymbol{Q})] \tag{11}$$

其中,  $\boldsymbol{Q}$  是式(3)中的补投影算子;  $\operatorname{diag}(\boldsymbol{Q})$  是由  $\boldsymbol{Q}$  对角元构成的对角阵;  $\lambda$  是正增益系数。

将式(11)代入式(10)可得:

$$E(t) = -\frac{\lambda}{2} \boldsymbol{\sigma}_1^T(t) (\boldsymbol{Q} - \operatorname{diag}(\boldsymbol{Q})) \boldsymbol{\sigma}_1(t) - \sum_{i=1}^N \int_0^{y_i(t)} \sigma_{1i}^{-1}(\tau) d\tau \tag{12}$$

当 DSHNN 到达解点时, 有  $y(t) = y(t+1)$ 。由于, 文中所研究信号为 BPSK, BPSK 信号只有两个极性  $\{-1, 1\}$ , 则仿真运行时运用判决参数  $\delta$ , 凡是  $y(s(t)) > \delta$ , 令  $s(t) = 1$ ;  $y(s(t)) \leq \delta$ , 令  $s(t) = -1$ , 来正确解出发送信号  $s(t)$ 。

以上述分析, 则其各自能量函数在“平衡点集”中的极值点就是各自优化问题的解, 得到的解点信号即为各自所需检测的发送信号。

## 4 仿真实验

实验采用  $h(t) = \sum_{j=1}^2 (w_j(h(\alpha, t - \tau_j)))$  经过采样因子  $q = 3$  采样得到的随机实数信道。其中:  $h(\alpha, t - \tau_j)$  是滚降因子  $\alpha = 0.1$ , 延迟因子  $\tau_j$  随机产生的升余弦脉冲响应;  $w_j$  是在  $(0, 1)$  区间满足均匀分布的随机权系数。信号传播多径数为 2。信道噪声为高斯白噪声, 每次仿真结果均由 100 次 Monte Carlo 实验得到, 为做图方便, 误码率为零的点设定为  $10^{-5}$ 。

实验 1: 固定数据长度  $N$  为 100, 分别将 HNN 算法和 DSHNN 算法的运行时间进行比较。发送信号为 BPSK, 输入信号数据量  $N$  均为 100。HNN 算法和 DSHNN 算法分别进行 100 次 Monte Carlo 仿真实验, 取 HNN 算法和 DSHNN 算法能量函数和所用时间平均值。能量函数随时间变化的曲线图, 如图 1 所示。

实验表明: 在条件相同的情况下, DSHNN 算法的收敛速度明显快于 HNN 算法, 且减少了运行时间, 有效提高了 HNN 算法能量的收敛速度。




图 1 BPSK 信号下, HNN 算法和 DSHNN 算法能量函数随时间变化的比较

实验 2: 发送信号为 BPSK, 分别在随机信道和固定信道进行 HNN 算法和 DSHNN 算法的 Monte Carlo 实验的误码率比较, 如图 2 和图 3 所示。




图 2 随机信道, HNN 算法与 DSHNN 算法误码率的比较




图 3 固定信道, HNN 算法与 DSHNN 算法误码率的比较

由图 2、图 3 可以看出, 不管是在随机信道还是在

固定信道的情况下, DSHNN 算法都没有影响 HNN 算法的抗噪性能, 反而比 HNN 算法的抗噪性能略好。

## 5 结束语

文中把双 Sigmoid Hopfield 神经网络引入盲检测算法中, 并且选择了适合该算法的两个激活函数。文中提出的算法比传统 Hopfield 神经网络在同等情况下具备更快的收敛速度和稍强的误码性能。仿真结果表明: 在同等情况下, 双 Sigmoid Hopfield 神经网络的能量函数下降更快; 在随机信道和固定信道时, 双 Sigmoid Hopfield 神经网络的误码性能都比传统 Hopfield 神经网络更好。

## 参考文献:

- [1] 张 昀, 张志涌. 复数离散 Hopfield 网络盲检测 64QAM 信号[J]. 电子与信息学报, 2011, 33(2): 315-320.
- [2] Zhang Yun, Zhang Zhiyong. Blind detection of QAM with a complex discrete Hopfield network [C]//Proceedings of the 8th world congress on intelligent control and automation. Jinnan, China; [s. n.], 2010: 6808-6812.
- [3] 张 昀. 基于复数 Hopfield 神经网络的盲信号检测[D]. 南京: 南京邮电大学, 2012.
- [4] 冯 迪, 于舒娟, 张 昀. 一种改进激活函数的 Hopfield 盲检测算法[J]. 计算机技术与发展, 2012, 22(12): 207-210.
- [5] Uykan Z. Fast-convergent double-Sigmoid Hopfield neural network as applied to optimization problems[J]. IEEE transactions on neural network and learning systems, 2013, 24(6): 990-996.
- [6] 张志涌, Bai Erwei. SIMO 含公零点信道的直接盲序列检测[J]. 电子学报, 2005, 33(4): 671-675.
- [7] Gupta M M, Jin Liang, Homma N. Static and dynamic neural networks[M]. New York: John Wiley & Sons, 2003.
- [8] Chakravarthy S V, Ghosh J. A complex-valued associative memory for storing patterns as oscillatory states[J]. Biological cybernetics, 1996, 75: 229-238.
- [9] Shen Yi, Wang Jun. Robustness analysis of global exponential stability of recurrent neural networks in the presence of time delays and random disturbances [J]. IEEE transactions on neural networks and learning systems, 2012, 23(1): 87-96.
- [10] Balavoine A, Romberg J, Rozell C J. Convergence and rate analysis of neural networks for sparse approximation[J]. IEEE transactions on neural networks and learning systems, 2012, 23(9): 1377-1389.
- [11] Nong Jifu. Global exponential stability of delayed Hopfield neural networks [C]//Proc of international conference on computer science and information processing. Xi'an, China; [s. n.], 2012: 193-196.
- [12] 阮秀凯, 张志涌. 基于连续 Hopfield 型神经网络的 QAM 信号盲检测[J]. 电子与信息学报, 2011, 33(7): 1600-1605.

双Sigmoid Hopfield神经网络盲检测算法

作者：[宦如松](#)，[于舒娟](#)，[张昀](#)，[HUAN Ru-song](#)，[YU Shu-juan](#)，[ZHANG Yun](#)

作者单位：[南京邮电大学 电子科学与工程学院, 江苏 南京, 210003](#)

刊名：[计算机技术与发展](#)

英文刊名：

Computer Technology and Development

ISTIC

年，卷(期)：

2014(4)

本文链接：[http://d.g.wanfangdata.com.cn/Periodical\\_wjfz201404025.aspx](http://d.g.wanfangdata.com.cn/Periodical_wjfz201404025.aspx)