

引用格式:王凯, 吴立新. 拟牛顿优化 BP 网络盲判决反馈均衡器[J]. 声学技术, 2021, 40(2): 188-193. [WANG Kai, WU Lixin. Blind decision feedback equalizer of quasi Newton optimized BP network[J]. Technical Acoustics, 2021, 40(2): 188-193.] DOI: 10.16300/j.cnki.1000-3630.2021.02.006

拟牛顿优化 BP 网络盲判决反馈均衡器

王 凯^{1,2}, 吴立新^{1,2}

(1. 中国科学院声学研究所, 北京 100190;
2. 中国科学院大学, 北京 100049)

摘要: 针对水声通信严重多途效应导致的码间干扰, 利用神经网络良好的非线性拟合能力, 将盲判决反馈均衡器结构与神经网络相结合, 同时通过拟牛顿算法提升神经网络的收敛速度, 提出了一种拟牛顿优化神经网络的盲判决反馈均衡器。用两个单隐层误差反向传播(Back Propagation, BP)网络替换判决反馈均衡器前馈和反馈滤波器, 利用拟牛顿迭代计算神经网络权值, 在不计算二阶导数的前提下, 使用近似矩阵来近似各层网络权值误差性能函数 Hessian 矩阵的逆矩阵, 通过测量各层权值的梯度变化进行迭代计算。应用自动增益控制和锁相环进行幅度和相位修正。仿真结果表明, 拟牛顿优化神经网络的盲判决反馈均衡器在水声信道均衡问题中具有更快的收敛速度及更低的误码率。

关键词: 反向传播(BP)神经网络; 拟牛顿算法; 信道均衡; 判决反馈均衡器

中图分类号: TN929.3

文献标志码: A

文章编号: 1000-3630(2021)-02-0188-06

Blind decision feedback equalizer of quasi Newton optimized BP network

WANG Kai^{1,2}, WU Lixin^{1,2}

(1. The Institute of Acoustics of the Chinese Academy of Sciences, Beijing 100190, China;
2. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In view of at the inter symbol interference(ISI) caused by serious multipath effect in underwater acoustic communication, a blind decision feedback equalizer based on quasi Newton optimization neural network (named as B-QNBPDFE) is proposed, in which the structure of blind decision feedback equalizer (B-DFE) and back propagation (BP) neural network are combined, and the convergence speed of neural network is improved by quasi Newton algorithm. Two single hidden layer BP networks are used to complete the function of DFE feedforward and feedback filters. The weights of neural networks are calculated by quasi Newton iteration. Without calculating the second derivative, the inverse matrix of Hessian matrix is approximated by approximate matrix. The iterative calculation is carried out by measuring the gradient change of weights of each layer. Finally, phase correction is carried out by phase-locked loop. The simulation results show that the blind decision feedback equalizer based on Quasi Newton optimization neural network has faster convergence speed and lower bit error rate in underwater acoustic channel equalization.

Key words: back propagation (BP) neural network; quasi Newton; channel equalization; decision feedback equalizer (DFE)

0 引 言

无需训练序列的盲均衡技术对于多径效应严重且带宽有限的水声信道来说是十分重要的, 可以有效降低码间干扰对通信系统的影响, 提升系统的通信性能。均衡器根据对接收信号的处理方式不同可以划分为线性均衡器和非线性均衡器。线性均衡器结构和算法简单, 适用于信道畸变不严重的情况, 当均衡器阶数足够长时, 可以达到理想的均衡

效果; 而在水声通信系统中, 信道往往存在频率选择性衰落, 非线性均衡器能够有效地消除水声信道的符号间干扰。

神经网络均衡器属于非线性均衡器, 由于其优秀的非线性拟合能力, 受到了国内外科科研工作者的关注, 文献[1]首次将多层感知器(Multi-Layer Perceptron, MLP)应用于信道均衡, 该方法采用四层多层感知器结构, 证明了多层感知器均衡器可以克服信道非线性和加性噪声的干扰, 文献[2]对误差反向传播(Back Propagation, BP)网络均衡器进行改进, 加入了函数连接结构, 均衡效果优于最小均方算法, 文献[3]将契比雪夫(Chebyshev)多项式与 BP 网络结合, 在二进制信号均衡中取得了较好的效果, 文献[4-5]分别将遗传算法与粒子滤波算法与 BP 网

收稿日期: 2020-03-15; 修回日期: 2020-04-30

作者简介: 王凯(1994—), 男, 陕西咸阳人, 博士研究生, 研究方向为水声通信。

通信作者: 吴立新, E-mail: wlx@mail.ioa.ac.cn

络结合,在收敛速度、误码率方面均有所改进。已有的基于 BP 网络的均衡器主要针对网络结构选取与优化方面进行研究,仅用神经网络结构完成均衡,没有与常规均衡方法相结合的算法。本文提出一种将神经网络与判决反馈均衡器结合的盲均衡器结构,用单隐层 BP 网络判决反馈均衡器(Decision Feedback Equalization, DFE)的前馈滤波器和反馈滤波器。

传统的神经网络都是基于梯度下降法进行迭代计算的,存在收敛速度慢的问题,影响均衡性能。牛顿法通过利用目标函数的 Hessian 矩阵进行迭代计算,具有二次收敛性,收敛速度较快,但是需要计算二阶导数,计算复杂度较高,且当 Hessian 矩阵非正定时可能出现发散的情况。拟牛顿法通过构造正定对称的近似矩阵来进行迭代计算,解决了牛顿法存在的问题。因此本文采用拟牛顿方法进行神经网络的权值迭代,利用一个近似矩阵来近似 Hessian 矩阵的逆矩阵,通过网络权值梯度的变化量进行逐层的迭代计算,兼顾了拟牛顿的收敛速度以及神经网络的非线性拟合能力。对四相相移键控(Quadrature Phase Shift Keying, QPSK)调制信号的均衡仿真验证了本文方法在消除码间干扰,降低误码率,加快收敛速度方面相比于传统方法的优越性。

1 复数 BP 网络

BP 神经网络是一种多层前馈神经网络,工作过程主要包含两部分:信号的正向传播和误差的反向传播。文献[6]已经证明:用单隐层的前馈神经网络能够以任意精度逼近任意的连续函数。图 1 为均衡器网络结构,其中输入神经元的个数为 M ,隐含层神经元的个数为 I , $W_{Mi}=[\omega_{mi}]$, $W_i=[\omega_i]$, $m=1,2,\dots,M$, $i=1,2,\dots,I$ 分别为输入层到隐含层、隐含层到输出层的连接权值,本文采用 QPSK 信号进行仿真,因此输入、输出及权值皆为复数。




图 1 单隐层 BP 网络示意图

Fig.1 Schematic diagram of single Hidden Layer BP Network

令 $v_M(n)=x(n)$ 表示输入层的输出, $u_i(n)$ 表示隐含层的输入, $v_i(n)$ 表示隐含层的输出, $y(n)$ 表示输出层的输出, $f(\cdot)$ 表示激活函数, $*$ 代表取复共轭转置, 则有:

$$u_i(n)=W_{Mi}^*(n)v_M(n) \quad (1)$$

$$v_i(n)=f[u_i(n)] \quad (2)$$

$$y(n)=W_i^*(n)v_i(n) \quad (3)$$

实数神经网络的激活函数需要满足输入区间内单调、有界及非线性等条件,常用的有 tansig、logsig、Relu 等函数。复数神经网络激活函数与实数情况下要求有所不同。根据文献[7]激活函数 $f(x+iy)=u(x,y)+iv(x,y)$ 应满足以下要求:

- (1) $f(x+iy)$ 在 x 和 y 上非线性,保证为网络引入非线性变换,否则神经网络的性能会受到影响;
- (2) $f(x+iy)$ 有界,偏导数 u_x, u_y, v_x, v_y 存在并有界,确保神经网络在迭代过程中不会出现溢出的情况;

- (3) $u_x v_y \neq v_x u_y$, 可以证明当两者相等时会出现输入不为 0 而梯度为 0,导致网络学习停止的情况。

根据以上条件,选择激活函数为

$$f(z)=\frac{z}{c+\frac{1}{r}|z|} \quad (4)$$

其中: r 和 c 为正实数。

2 BP 网络盲判决反馈均衡器

基于 BP 网络的盲判决反馈均衡器分为两个阶段:学习阶段和收敛阶段。学习阶段将反馈滤波器置于前馈滤波器之前,先对数据进行白化处理,再用横模盲均衡(Constant Modulus Algorithm, CMA)算法对数据进行均衡,当反馈项具有一定可信度时转换到收敛阶段,此时均衡器结构为常规的 DFE 均衡器,使用反馈项作为期望信号对信号进行均衡。

2.1 学习阶段

学习阶段均衡器结构设置如图 2,依次为增益控制因子 g —反馈项 BP 网络 R—前馈项 BP 网络 T 相位修正因子 $e^{-j\theta}$ —判决器。其中增益控制因子用来缩小接收信号的动态范围,便于输入到神经网络进行处理;反馈项 BP 网络 R、前馈项 BP 网络 T 分别完成常规 DFE 前馈和反馈滤波器的功能;相位修正因子 $e^{-j\theta}$ 用来修正信道和接收端处理对数据造成的相位偏移。根据文献[8]可知, R 的输出是 DFE 的反馈输入,在无训练序列的情况下只有当 R 的输出具有一定可信度时才能作为反馈项输入。因

此, 学习阶段首先将 R 置于 T 之前, 对 R 的参数进行学习。




图2 学习阶段均衡器级联框图

Fig.2 Equalizer cascade diagram in learning stage

2.1.1 级联计算过程

整个均衡计算过程为

$$r(n) = gs(n) \quad (5)$$

$$u(n) = r(n) - t(n) \quad (6)$$

其中: $t(n) = F_R[U_{N,R}(n-1)]$ 是将 $U_{N,R}(n-1)$ 经过 BP 网络 R 后的输出值, 其计算过程为

$$\begin{cases} u_{I,R}(n) = W_{M,R}^*(n)U_{N,R}(n-1) \\ v_{I,R}(n) = f[u_{I,R}(n)] \\ t(n) = W_{I,R}^*(n)V_{I,R}(n) \end{cases} \quad (7)$$

其中: $U_{N,R}(n-1) = [u(n-1) \ u(n-2) \ \cdots \ u(n-N_R)]^T$, N_R 表示 R 网络输入向量的个数。

$$v(n) = F_T[U_{N,T}(n)] \quad (8)$$

其中: $F_T[U_{N,T}(n)]$ 表示 $U_{N,T}(n)$ 经过 BP 网络 T 的输出值, 其计算过程为

$$\begin{cases} u_{I,T}(n) = W_{M,T}^*(n)U_{N,T}(n) \\ v_{I,T}(n) = f[u_{I,T}(n)] \\ v(n) = W_{I,T}^*(n)V_{I,T}(n) \end{cases} \quad (9)$$

$$\tilde{d}(n) = v(n)e^{-j\theta} \quad (10)$$

其中: $U_{N,T}(n) = [u(n) \ u(n-1) \ \cdots \ u(n-N_T)]^T$, N_T 代表 T 网络输入向量的个数。

2.1.2 各级联部分无监督学习准则

增益控制因子 g 将接收信号功率转化为 1, 即:

$$E\{|u(n)|^2\} = 1 \quad (11)$$

式(11)即为增益控制因子 g 的最优化无监督学习准则, 由此可以得到 g 的迭代公式:

$$G(n) = G(n-1) + \mu_g [1 - |u(n)|^2] \quad (12)$$

$$g(n) = \sqrt{G(n)} \quad (13)$$

其中: $G(0) = 1$, μ_g 为迭代步长。

由于网络 R 对数据进行了白化处理, 因此寻找最优权值向量应使如下代价函数最小化:

$$J_R = E[|u(n)|^2] \quad (14)$$

利用 Wirtinger 微分计算复梯度方法^[9], 将 J_R 对各层权值求偏导可得各层连接权值梯度:

$$g_{I,R} = -2u^*(n)v_{I,R}(n) \quad (15)$$

$$g_{M,R} = -2u^*(n)U_{N,R}(n-1)[W_{I,R}^*(n)f'(u_{I,R}(n))] \quad (16)$$

对于网络 T, 在无监督学习情况下对恒定包络的信号依据 Godard 盲均衡算法有:

$$\begin{cases} J_T = E\{|v(n)|^p - R_p\}^2 \\ R_p = \frac{E[|d(n)|^{2p}]}{E[|d(n)|^p]} \end{cases} \quad (17)$$

其中: p 代表对输出信号特性统计的阶数, 当 $p=2$ 时, 此算法成为最常用的恒模盲均衡算法(CMA), 令 $e_T(n) = v(n)v^*(n) - R_2$, 可得:

$$g_{I,T} = 4e_T(n)v^*(n)v_{I,T}(n) \quad (18)$$

$$g_{M,T} = 4e_T(n)v^*(n)U_{N,T}(n)\{W_{I,T}^*(n)f'[u_{I,T}(n)]\} \quad (19)$$

文献[10]已经证明, 在初始模式级联方式下, 应用 Godard 算法时, 当且仅当 T 达到迫零准则时均衡器取得最优值, 相比于 MSE 准则仅有细微的差别。

θ 用来补偿信道和接收端带来的相位误差, 通过旋转因子 $e^{-j\theta}$ 对数据进行相位修正, 代价函数为

$$J_\theta = E\{|v(n)e^{-j\theta(n-1)} - \hat{d}(n)|^2\} \quad (20)$$

由代价函数可知, 计算 J_θ 时需要用到此时刻的判决值, 因此需要将 $e^{-j\theta}$ 放置在最后。根据文献[11], 用二阶锁相环最小化 J_θ 的方法为

$$\tilde{d}(n) = v(n)e^{-j\theta(n-1)} \quad (21)$$

$$\theta(n) = \theta(n-1) + \mu_\theta \left[\varepsilon(n) + \beta \sum_{i=1}^n \varepsilon(i) \right] \quad (22)$$

$$\varepsilon(n) = \text{Im}\{\tilde{d}(n)[\hat{d}(n) - \tilde{d}(n)]^*\} \quad (23)$$

2.1.3 拟牛顿 BP 网络迭代

拟牛顿迭代方法与最速下降法一样只要求知道目标函数的梯度, 通过对梯度变化的测量, 构造一个目标函数的模型使其满足超线性收敛, 其性能要优于最速下降法。另外, 因为不需要二阶导数信息, 所以其相对于牛顿法计算量更小, 而且可以保证矩阵的正定, 防止牛顿法可能出现的收敛发散的情况。

拟牛顿法主要思想为对目标函数进行二阶泰勒展开并令其导数等于 0, 推导得出权值迭代公式。对 $J(\omega)$ 在 $\omega(n)$ 处进行二阶泰勒展开:

$$\nabla J(\omega) \approx \nabla J(\omega_{n+1}) + \nabla^2 J(\omega_{n+1}) \cdot (\omega - \omega_{n+1}) \quad (24)$$

令 $\nabla J(\omega) = 0$ 可得:

$$\omega_{n+1} = \omega - H^{-1}g \approx \omega - Gg \quad (25)$$

其中: H^{-1} 表示二阶导数 Hessian 矩阵的逆矩阵, G 表示它的近似值, g 表示梯度矩阵。

由 BFGS 迭代法可得近似矩阵 G 的迭代公式:

$$\mathbf{G}_{n+1} = \left(\mathbf{I} - \frac{\mathbf{S}_n \mathbf{V}_n^T}{\mathbf{V}_n^T \mathbf{S}_n} \right) \mathbf{G}_n \left(\mathbf{I} - \frac{\mathbf{V}_n \mathbf{S}_n^T}{\mathbf{V}_n^T \mathbf{S}_n} \right) + \frac{\mathbf{S}_n \mathbf{S}_n^T}{\mathbf{V}_n^T \mathbf{S}_n} \quad (26)$$

其中: $\mathbf{S}_n = \boldsymbol{\omega}_{n+1} - \boldsymbol{\omega}_n$, $\mathbf{V}_n = \mathbf{g}_{n+1} - \mathbf{g}_n$, 为防止出现分母过小导致迭代发散的情况, 在迭代之前进行一次判定, 当 $\mathbf{V}_n^T \mathbf{S}_n$ 小于门限值时, 将近似矩阵 $\mathbf{G}$ 赋值为初始修正矩阵, 此操作不影响迭代过程的收敛性。

由 2.1.2 节已经得到了 R、T 两个网络各层权值的梯度计算公式, 根据上述公式可以得到拟牛顿 BP 网络权值迭代步骤如下:

- (1) 初始化网络权值 $\mathbf{W}_I$ 、 $\mathbf{W}_{MI}$ 、 $\mathbf{G}_I$ 、 $\mathbf{G}_{MI}$;
- (2) 计算当前时刻数据输入及网络权值下的输出值及梯度值 $\mathbf{g}_I$ 、 $\mathbf{g}_{MI}$;
- (3) 根据 $\mathbf{W} = \mathbf{W} - \mu \mathbf{G} \mathbf{g}$ 进行一次迭代得到 $\tilde{\mathbf{W}}_I$ 、 $\tilde{\mathbf{W}}_{MI}$;
- (4) 重新计算计算 $\tilde{\mathbf{W}}_I$ 、 $\tilde{\mathbf{W}}_{MI}$ 权值下的梯度值 $\tilde{\mathbf{g}}_I$ 、 $\tilde{\mathbf{g}}_{MI}$;
- (5) 根据式(25)计算 $\mathbf{G}_I$ 、 $\mathbf{G}_{MI}$;
- (6) 将 $\tilde{\mathbf{W}}_I$ 、 $\tilde{\mathbf{W}}_{MI}$ 赋值给 $\mathbf{W}_I$ 、 $\mathbf{W}_{MI}$;
- (7) 输入新数据重复步骤(1)~(6)。

2.2 收敛阶段

当初始模式的判决输出具有一定可信度时, 均衡器级联结构由图 2 转变为图 3。此时均衡器为加入相位修正的常规 DFE 结构, 将判决输出的结果当作期望信号进行训练。当模式转化时, 均衡器受到的影响仅为 T 由近似迫零准则转化为 MSE 准则对网络权值的影响, 对整个均衡器影响较小。同时新的均衡级联结构相比于初始模式可以达到更小的均方误差。




图3 收敛阶段均衡器级联框图
Fig.3 Equalizer cascade diagram in convergence stage

由于均衡器没有训练序列, 不能直接根据误码率评价初始模式下判决信号的可靠性, 而均方差可以根据调制方式转化为误码率, 因此我们将判决信号与输出信号的均方差值作为度量初始模式均衡效果的性能指标。度量值 M 由以下公式计算:

$$M(n) = \lambda M(n-1) + (1-\lambda) |\hat{d}(n) - \tilde{d}(n)| \quad (27)$$

其中: λ 为遗忘因子, 一般取接近 1、但小于 1 的常数, 保证均衡器不会在初始阶段与收敛阶段来回震荡, 模式切换准则为

$$\begin{cases} M \geq M_0, & \text{初始模式} \\ M < M_0, & \text{收敛模式} \end{cases} \quad (28)$$

为了保证模式转换后的判决信号具有可靠性, M_0 的选择应该足够小。通常选择当误符号率小于 0.02 时进行模式转换, 相移键控(Phase Shift Keying, PSK)调制符号错误概率与信噪比关系为

$$P_M \approx 2Q\left(\sqrt{(\log_2 M) \sin^2\left(\frac{\pi}{M}\right) \frac{\mathcal{E}_e}{N_0}}\right) \quad (29)$$

其中: Q 为标准正太分布的右尾函数; $\frac{\mathcal{E}_e}{N_0}$ 表示信噪比, 与 M_0 关系为

$$\frac{\mathcal{E}_e}{N_0} = \frac{\sigma^2 - M_0}{M_0} \quad (30)$$

联立式(29)、(30)可得: 当 $P_M = 0.02$ 时, 对 QPSK 信号有 $M_0 \approx 0.25$ 。当信道发生突变时, $M \geq M_0$, 均衡器转到初始模式, 重新跟踪信道变化。

由图 3 可以得到均衡器级联计算过程为

$$r(n) = \mathbf{g}^T \mathbf{s}(n) \quad (31)$$

$$\tilde{d}(n) = F_T[\mathbf{R}(n)] e^{-j\theta(n-1)} - F_R[\hat{\mathbf{D}}(n)] \quad (32)$$

其中: $\mathbf{R}(n) = [r(n) \ r(n-1) \ \cdots \ r(n-N_T)]^T$, $\hat{\mathbf{D}}(n) = [\hat{d}(n-1) \ \hat{d}(n-2) \ \cdots \ \hat{d}(n-N_R)]^T$ 。

收敛阶段均衡器期望序列为判决信号 $\hat{d}(n)$, 误差信号 $e = \hat{d}(n) - \tilde{d}(n)$, 代价函数为

$$J = E \left[|\hat{d}(n) - \tilde{d}(n)|^2 \right] \quad (33)$$

根据 Wirtinger 计算方法, 两 BP 网络的各层权值梯度可表示为

$$\mathbf{g}_{I,R} = 2e^*(n) \mathbf{v}_{I,R}(n) \quad (34)$$

$$\mathbf{g}_{MI,R} = 2e^*(n) \hat{\mathbf{D}}(n) \{ \mathbf{W}_{I,R}^*(n) f'[\mathbf{u}_{I,R}(n)] \} \quad (35)$$

$$\mathbf{g}_{I,T} = -2e^*(n) \mathbf{v}_{I,T}(n) e^{-j\theta(n-1)} \quad (36)$$

$$\mathbf{g}_{MI,T} = -2e^*(n) \mathbf{R}(n) \{ \mathbf{W}_{I,T}^*(n) f'[\mathbf{u}_{I,T}(n)] \} e^{-j\theta(n-1)} \quad (37)$$

由 2.1.3 节的网络权值迭代步骤对网络权值进行迭代。

对锁相环, 令 $w(n) = F_T[\mathbf{R}(n)] e^{-j\theta(n-1)}$, 可得:

$$\theta(n) = \theta(n-1) + \mu_\theta \left[\varepsilon(n) + \beta \sum_{i=1}^n \varepsilon(i) \right] \quad (38)$$

$$\varepsilon(n) = \text{Im} \left\{ y [\hat{d}(n) - w(n)]^* \right\} \quad (39)$$

3 数值仿真

本文仿真对比了 QPSK 调制下, 拟牛顿优化 BP 网络盲判决反馈均衡器(Blind-Quasi Newton Optimization BP Network Decision Feedback Equalizer, B-QNBPDFE)、BP 网络盲判决反馈均衡器(Blind-BP Network Decision Feedback Equalizer, B-BPDFE)以及常规盲判决反馈均衡器(Blind-

Decision Feedback Equalizer, B-DFE)三种均衡器在衰落信道中的均衡效果。其中两个神经网络均衡器反馈项和前馈项分别有 20、5 个抽头输入, 隐层神经元个数分别为 4 和 2, B-DFE 反馈和前馈抽头个数均分别为 20、5。仿真采用具有混合相位复数信道^[12], 信道冲击响应为

$$\mathbf{H}=[0.4854-0.0971j \quad 0.3640+0.4368j \quad 0.2427 \\ 0.2912-0.3155j \quad 0.1941+0.3883j]。$$

同时为其增加一个二次的非线性变换 $y=x+0.2x^2$ 和时变相位偏移 $\phi(n)=\pi n\Delta+\theta_0$, 其中 Δ 的取值范围为 $0\sim 10^{-3}$, θ_0 代表 $0\sim 2\pi$ 的初始相移。

图 4(a)为该信道的零点, 4(b)、4(c)为幅频响应曲线。可以看出该信道具有明显的频率选择性衰落和严重的相位失真, 且单位圆内和单位圆外均有零点分布, 是典型的混合相位信道。

如图 5(a)、5(b)分别为本文方法(B-QNBPDFE)和 B-DFE 均衡后的星座图, 5(c)为信噪比 15 dB 下, 100 次蒙特卡洛仿真结果。可以看出, 本文方法相较于 B-DFE, 两种神经网络均衡器收敛时有更低的均方误差, 均衡后星座图更加收敛。同时本文方法与 B-BPDFE 相比具有更快的收敛速度, 且均方误差更小。

图 6 为不同信噪比情况下三种均衡器误码率变化曲线。从图 6 中可以看出, 本文方法与 B-DFE 相比有更低的误码率。






图 4 仿真信道的特性

Fig.4 The characteristics of the simulation channel






图 5 信噪比为 15 dB 时, 三种均衡方法的信道均衡效果的比较
Fig.5 Comparison of the equalization effects of three different equalization methods in the channel when signal to noise ratio is 15 dB




图6 不同信噪比下三种均衡方法的误码率对比图
Fig.2 Bit error rates of three different equalization methods under different signal to noise ratios

4 结论

本文基于盲判决反馈均衡器的模型，在利用神经网络良好的非线性拟合能力的同时，改进梯度下降法带来的收敛速度慢的问题，提出了拟牛顿优化 BP 网络的盲判决反馈均衡器。通过利用两个复数 BP 网络分别实现盲判决反馈均衡中数据白化及常模盲均衡部分，利用拟牛顿迭代进行网络权值的更新，通过改变均衡器级联结构实现对信道的学习与跟踪。仿真结果表明，与盲判决反馈均衡算法相比，本文算法具有更低的均方误差，同时相比梯度下降法收敛速度更快。然而，由于拟牛顿算法不是全局最优算法，虽然能提升均衡器收敛速度，但是依然存在陷入局部极小值的问题，计算复杂度低且全局最优的迭代算法还有待进一步研究。

参考文献

[1] CHEN S, GIBSON G J, COWAN C F N, et al. Adaptive equalization of finite non-linear channels using multilayer perceptrons[J]. Signal Processing, 1990, 20(2): 107-119.

[2] PATRA J C, PAL R N, BALIARSINGH R, et al. Nonlinear channel equalization for QAM signal constellation using artificial neural networks[J]. IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics), 1999, 29(2): 262-271.

[3] ZHAO H Q, ZHANG J S. Functional link neural network cascaded with Chebyshev orthogonal polynomial for nonlinear channel equalization[J]. Signal Processing, 2008, 88(8): 1946-1957.

[4] 肖瑛, 刘国枝, 李振兴, 等. 遗传优化神经网络的水声信道盲均衡[J]. 应用声学, 2006, 25(6): 340-345.

XIAO Ying, LIU Guozhi, LI Zhenxing, et al. Blind equalization for underwater acoustic communication by genetic algorithm optimizing neural network[J]. Applied Acoustics, 2006, 25(6): 340-345.

[5] DAS G, PATTNAIK P K, PADHY S K. Artificial Neural Network trained by Particle Swarm Optimization for non-linear channel equalization[J]. Expert Systems with Applications, 2014, 41(7): 3491-3496.

[6] CYBENKO G. Approximation by superpositions of a sigmoidal function[J]. Mathematics of Control, Signals and Systems, 1989, 2(4): 303-314.

[7] GEORGIU G M, KOUTSOUGERAS C. Complex domain backpropagation[J]. IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing, 1992, 39(5): 330-334.

[8] LABAT J, MACCHI O, LAOT C. Adaptive decision feedback equalization: can You skip the training period?[J]. IEEE Transactions on Communications, 1998, 46(7): 921-930.

[9] PROAKIS J G. Digital communications[M]. 4th ed. New York: McGraw-Hill, 2001.

[10] SHALVI O, WEINSTEIN E. New criteria for blind deconvolution of nonminimum phase systems (channels)[J]. IEEE Transactions on Information Theory, 1990, 36(2): 312-321.

[11] FALCONER D D. Jointly adaptive equalization and carrier recovery in two-dimensional digital communication systems[J]. Bell System Technical Journal, 1976, 55(3): 317-334.

[12] PORAT B, FRIEDLANDER B. Blind equalization of digital communication channels using high-order moments[J]. IEEE Transactions on Signal Processing, 1991, 39(2): 522-526.