

# 基于预测原理的回声状态网络在线盲均衡算法

杨凌, 韩琴, 程丽, 赵傲男, 杜娟

(兰州大学信息科学与工程学院, 甘肃 兰州 730000)

**摘 要:** 针对非线性信道, 基于预测原理提出了回声状态网络 (ESN) 在线盲均衡算法, 首先将具有良好非线性映射能力的 ESN 代替传统的线性预测误差滤波器, 并采用递归最小二乘 (RLS) 算法计算网络的输出权值, 使网络预测误差达到最小; 然后进行幅值和相位的调整。仿真实验表明, 对于 16QAM 信号, 所提算法可以有效降低非线性信道对发送信号产生的畸变。与其他基于预测原理的盲均衡算法相比, 所提算法有更低的均方误差值和更快的收敛速度。

**关键词:** 非线性信道; 预测误差滤波器; 回声状态网络; 递归最小二乘算法

**中图分类号:** TN911.5

**文献标识码:** A

**doi:** 10.11959/j.issn.1000-436x.2020031

## Online blind equalization algorithm with echo state network based on prediction principle

YANG Ling, HAN Qin, CHENG Li, ZHAO Aonan, DU Juan

Institute of Information Science and Engineering, Lanzhou University, Lanzhou 730000, China

**Abstract:** In view of the nonlinear channel, the online blind equalization algorithm with echo state network was proposed based on prediction principle. In the proposed algorithm, the traditional linear prediction error filter was replaced by the ESN with good nonlinear mapping ability, and recursive least square (RLS) algorithm was used to calculate the output weight of the network to minimize the network prediction error. Then, the amplitude and phase were adjusted. Simulation results show that the proposed algorithm can effectively reduce the distortion caused by nonlinear channel to the transmitted signal for 16QAM signal, which has lower mean square error and faster convergence speed in comparison with other blind equalization algorithms based on prediction principle.

**Key words:** nonlinear channel, predictive error filter, echo state network, recursive least square algorithm

### 1 引言

通信系统中, 由于信道的非理想特性, 接收机接收到的信号会产生严重的畸变, 通常采用均衡技术尽可能地恢复失真信号。传统的自适应均衡需要发送训练序列以提供均衡器所需的监督信号, 对于时变信道, 需要频繁发送训练序列以达到实时跟踪信道的目的, 不仅降低了通信系统的信息传输速率, 而且加大了信息传输成本。1975 年, Sato<sup>[1]</sup>首

次提出了盲均衡的概念。盲均衡技术不需要发送训练序列, 仅仅利用接收序列本身的先验信息, 便可自适应地调整均衡器参数, 跟踪信道特性, 完成对信号的最佳估计<sup>[2-3]</sup>。

Bussgang 类盲均衡算法应用较广泛, 它将构造的代价函数的极小值对应于理想系统, 并通过自适应算法得到相应的极小值, 继而得到系统参数<sup>[4-7]</sup>。该类算法稳定性强, 但存在收敛后剩余误差较大、易陷于局部最小等缺点。考虑到传输序列由独立随

收稿日期: 2019-09-10; 修回日期: 2019-12-20

基金项目: 甘肃省自然科学基金资助项目 (No.20180322); 中央高校基础研究基金资助项目 (No.lzujbky-2019-91)

**Foundation Items:** The Natural Science Foundation of Gansu Province (No.20180322), The Fundamental Research Funds for the Central Universities (No.lzujbky-2019-91)

机变量组成, 文献[8]提出了基于预测原理的盲均衡思想, 利用二阶统计量调整线性预测误差滤波器结构的参数, 并以此消除失真信号中存在的冗余, 但有限长的线性预测误差滤波器存在自身结构的局限性, 很难获得理想的均衡效果。由于非线性系统能产生高阶统计量信息, 文献[9]用非线性的模糊滤波器代替传统的线性结构, 降低了均衡误码率。文献[10]首次提出将神经网络作为非线性预测误差滤波器实现盲均衡的方法, 随后, 前馈神经网络如径向基函数 (RBF, radial basis function) [11]网络、多层感知器 (MLP, multi-layer perceptron) [12]、极限学习机 (ELM, extreme learning machine) [13], 以及递归神经网络如回声状态网络 (ESN, echo state network) [14-15]相继用于构造非线性预测误差滤波器。其中, 前馈神经网络各层神经元之间无反馈, 非线性映射能力弱于递归神经网络, 对非线性信道的均衡效果较差。文献[14-15]选用只需要训练输出权值的新型递归神经网络 ESN [16-17]作为非线性预测误差滤波器, 在非线性信道下获得了较理想的均衡性能。然而, 文献[14-15]中的实验仅针对 BPSK 调制信号的盲均衡, 没有涉及抗噪声能力强且可充分利用通信带宽的正交幅度调制 (QAM, quadrature amplitude modulation) 信号, 此外, 文献[14-15]的算法均采用数据批处理方式进行盲均衡, 对于时变信道, 不能有效地实时跟踪信道变化。

本文针对非线性信道的 QAM 信号, 采用复数型回声状态网络 [18]作为非线性预测误差滤波器, 用递归最小二乘算法计算网络的输出权值, 实时跟踪信道变化, 并通过自动增益控制 (AGC, automatic gain control) 和旋转因子分别调整信号的幅值和相位旋转, 提出了基于预测原理的回声状态网络在线盲均衡算法 (ESN-PEF, echo state network-prediction error fitter)。

## 2 问题描述

### 2.1 基于预测原理的盲均衡方法

基于预测原理的盲均衡框架如图 1 所示。其中  $s(n)$  是发送序列,  $h$  是发送序列通过的信道,  $\bar{x}(n)$  是信道输出序列,  $v(n)$  是高斯白噪声序列,  $x(n)$  是加噪信道输出序列,  $Z^{-1}$  是单位延迟,  $P$  是预测误差滤波器,  $y(n)$  是加噪信道输出序列的预测值,  $e(n)$  是预测误差,  $g$  是 AGC 装置,  $\hat{s}(n)$  是恢复的发送序列。




图 1 基于预测原理的盲均衡框架

设发送序列  $s(n)$  通过式(1)所示的信道, 即

$$h(z) = \sum_{i=0}^{L_h-1} h_i z^{-i} \quad (1)$$

其中,  $L_h$  是信道阶数,  $h_i$  是信道系数。

则加噪信道输出序列可以表示为

$$\begin{aligned} x(n) &= \bar{x}(n) + v(n) = \\ &= s(n)h_0 + s(n-1)h_1 + \dots + \\ &+ s(n-L_h+1)h_{L_h-1} + v(n) \\ x(n-1) &= \bar{x}(n-1) + v(n-1) = \\ &= s(n-1)h_0 + s(n-2)h_1 + \dots + \\ &+ s(n-L_h+2)h_{L_h-1} + v(n-1) \\ x(n-2) &= \bar{x}(n-2) + v(n-2) = \\ &= s(n-2)h_0 + s(n-3)h_1 + \dots + \\ &+ s(n-L_h+3)h_{L_h-1} + v(n-2) \\ &\dots \end{aligned} \quad (2)$$

由图 1 可知, 预测误差为

$$e(n) = x(n) - P(\mathbf{X}(n-1)) \quad (3)$$

其中,  $\mathbf{X}(n-1) = [x(n-1), x(n-2), \dots]^T$ ,  $P(\cdot)$  表示预测误差滤波器。

设预测误差滤波器为

$$P(z) = \sum_{k=1}^{L_w} p_k z^{-k} \quad (4)$$

其中,  $L_w$  是滤波器阶数。

则预测误差可以扩展为

$$\begin{aligned} e(n) &= s(n)h_0 + s(n-1)h_1 + \dots + v(n) - \\ &-(x(n-1)p_1 + x(n-2)p_2 + \dots + x(n-L_w)p_{L_w}) = \\ &= s(n)h_0 + s(n-1)h_1 + \dots + v(n) - ((s(n-1)h_0 + \\ &+ s(n-2)h_1 + \dots + v(n-1))p_1 + (s(n-2)h_0 + \\ &+ s(n-3)h_1 + \dots + v(n-2))p_2 + \dots + (s(n-L_w)h_0 + \\ &+ s(n-L_w+1)h_1 + \dots + v(n-L_w))p_{L_w}) \end{aligned} \quad (5)$$

整理式(5), 可得

$$\begin{aligned} e(n) &= s(n)h_0 + v(n) + s(n-1)(h_1 - h_0 p_1) - \\ &- v(n-1)p_1 + s(n-2)(h_2 - h_1 p_1 - h_0 p_2) - \\ &- v(n-2)p_2 + \dots - s(n-L_h+1)h_{L_h-1} p_{L_w} - \\ &- v(n-L_h+1)p_{L_w} \end{aligned} \quad (6)$$

理想的均衡结果是只保留  $s(n)h_0$ ，消除其他冗余项，然后通过 AGC 调整幅值得到原始发送序列的估计  $\hat{s}(n)$ 。

由于有限长的线性滤波器不可能在保留  $s(n)h_0$  的同时使其他冗余项的系数为 0，因此很难获得理想的均衡效果。为尽可能地消除冗余项的影响，一般的做法是增加线性预测误差滤波器的阶数  $L_w$ ，但  $L_w$  的增加会带来较大的计算量，且性能的提升也非常有限。考虑到非线性结构能产生高阶统计量信息且具有强大的非线性映射能力，文献[9]提出用非线性结构代替线性预测误差滤波器。

### 2.2 回声状态网络

回声状态网络是一种由输入层、动态储备池（隐含层）、输出层三部分组成的递归神经网络，其拓扑结构如图 2 所示，其中  $L$  是网络的输入节点数， $M$  是输出层节点数。




图 2 回声状态网络的拓扑结构

储备池的状态更新和网络的输出计算式分别为

$$\mathbf{u}(n) = \mathbf{f}(\mathbf{W}_{in}\mathbf{x}(n) + \mathbf{W}_{res}\mathbf{u}(n-1)) \quad (7)$$

$$\mathbf{y}(n) = \mathbf{f}_{out}(\mathbf{W}_{out}\mathbf{u}(n)) \quad (8)$$

其中， $\mathbf{x}(n) = [x_1(n), \dots, x_L(n)]^T$  是  $n$  时刻网络的输入信号； $\mathbf{u}(n) = [u_1(n), \dots, u_N(n)]^T$  是  $n$  时刻的储备池状态； $\mathbf{y}(n) = [y_1(n), \dots, y_M(n)]^T$  是  $n$  时刻网络的输出信号； $\mathbf{W}_{in} \in R^{N \times L}$  是输入权值矩阵； $\mathbf{W}_{res} \in R^{N \times N}$  是储备池内部连接权值矩阵； $\mathbf{W}_{out} \in R^{M \times N}$  是输出权值矩阵； $\mathbf{f}(\cdot) = (f_1(\cdot), \dots, f_N(\cdot))$  是储备池内部神经元的激活函数，通常为非线性函数，其中  $N$  是储备池神经元的节点数； $\mathbf{f}_{out}(\cdot) = (f_1(\cdot), \dots, f_M(\cdot))$  是网络输出层的读出函数，可采用线性读出和非线性读出 2 种形式。

ESN 的输入权值矩阵  $\mathbf{W}_{in}$  和储备池内部连接矩阵  $\mathbf{W}_{res}$  随机生成且固定不变，不需要反复训练，唯一需要训练的是输出权值矩阵  $\mathbf{W}_{out}$ ，通常通过如式(9)所示的伪逆求解方式得到。

$$\mathbf{W}_{out} = \mathbf{T}^T \mathbf{H}^\dagger \quad (9)$$

其中， $\mathbf{T} = [d(1), \dots, d(n)]^T$  是目标向量， $d(n)$  是  $n$  时刻网络的期望输出， $\mathbf{H} \in R^{N \times n}$  是储备池矩阵， $\mathbf{H}^\dagger$  表示矩阵的伪逆。

由上述分析可知，ESN 极大地简化了神经网络的学习过程，而且避免了梯度下降算法引起的局部最小问题，与传统的递归神经网络相比，其在利用大规模、稀疏连接的递归隐层提高映射能力的同时，仍保留了前馈网络的简单性原则，使网络具有较少的训练参数和较小的计算量。

### 3 ESN-PEF 算法描述

针对盲均衡问题，将 ESN 作为图 1 所示框架中的预测误差滤波器  $P$ ，设置其输入节点和输出节点的个数均为 1。对于 QAM 信号而言，若选用实数型 ESN，需分别处理信号的实部和虚部，这样忽略了信号实部与虚部之间的相互依赖性，无法得到最优的均衡性能，故本文选用激活函数、相关权值均为复数值的复数型 ESN。考虑到实际通信中信道特性会随着工作条件的变化而变化，为达到实时跟踪信道变化的目的，本文采用递归最小二乘 (RLS, recursive least square) 法迭代计算 ESN 的输出权值矩阵  $\mathbf{W}_{out}$ ，代替传统 ESN 中通过求伪逆计算  $\mathbf{W}_{out}$  的方式，构造了将 ESN 作为预测误差滤波器的在线盲均衡算法，算法具体推导如下。

在图 1 所示的盲均衡框架下，加噪信道的输出序列  $\mathbf{x}(n)$  为接收机的输入信号。本文将  $\mathbf{x}(n)$  设置为 ESN 的期望输出，并将其单位时间延迟  $\mathbf{x}(n-1)$  作为 ESN 的输入，网络迭代的目的是依据预测原理使 ESN 的实际输出  $\mathbf{y}(n)$  无限逼近其期望输出  $\mathbf{x}(n)$ ，即

$$\mathbf{x}(n) \approx \mathbf{y}(n) = \sum_{j=1}^N w_{j,out}(n) u_j(n) \quad (10)$$

其中， $w_{j,out}(n)$  是 ESN 输出权值矩阵  $\mathbf{W}_{out}(n)$  的元素。为使网络的均方误差最小，需求解

$$\begin{aligned} E \left[ e(n)^2 \right]_{\min} &= E \left[ |(\mathbf{x}(n) - \mathbf{y}(n))|^2 \right]_{\min} = \\ E \left[ \left( \mathbf{x}(n) - \sum_{j=1}^N w_{j,out}(n) u_j(n) \right)^2 \right]_{\min} \end{aligned} \quad (11)$$

式(11)是一个线性回归问题，可以等价

$$\mathbf{T}_n = [\mathbf{W}_{out}(n) \mathbf{H}_n]^T \quad (12)$$

其中， $\mathbf{T}_n = [x(1), \dots, x(n)]^T$  是  $n$  时刻的目标向量，

$\mathbf{H}_n \in \mathbb{R}^{N \times n}$  是  $n$  时刻的储备池矩阵。

式(12)可以看成有一个有  $n$  个等式的方程组，从中可以得到最小二乘解为

$$\mathbf{W}_{\text{out}}(n) = [\mathbf{P}(n)\mathbf{H}_n\mathbf{T}_n]^\top \quad (13)$$

其中，有

$$\mathbf{P}(n) = (\mathbf{H}_n\mathbf{H}_n^\top)^{-1} = \left( \sum_{i=1}^n \mathbf{u}(i)\mathbf{u}^\top(i) \right)^{-1} \quad (14)$$

将式(13)展开可以得到

$$\mathbf{W}_{\text{out}}(n) = \left[ \mathbf{P}(n) \left[ \sum_{i=1}^{n-1} \mathbf{u}(i)x(i) + \mathbf{u}(n)x(n) \right] \right]^\top \quad (15)$$

同理可得

$$\mathbf{W}_{\text{out}}(n-1) = \left[ \mathbf{P}(n-1) \left[ \sum_{i=1}^{n-1} \mathbf{u}(i)x(i) \right] \right]^\top \quad (16)$$

由式(14)可得

$$\mathbf{P}(n-1) = (\mathbf{H}_{n-1}\mathbf{H}_{n-1}^\top)^{-1} = \left( \sum_{i=1}^{n-1} \mathbf{u}(i)\mathbf{u}^\top(i) \right)^{-1} \quad (17)$$

将式(16)和式(17)代入式(15)得

$$\mathbf{W}_{\text{out}}(n) = [\mathbf{P}(n)[\mathbf{P}^{-1}(n-1)\mathbf{W}_{\text{out}}^\top(n-1) + \mathbf{u}(n)x(n)]]^\top = [\mathbf{W}_{\text{out}}^\top(n-1) + \mathbf{P}(n)\mathbf{u}(n)\tilde{e}(n)]^\top \quad (18)$$

其中， $\tilde{e}(n) = x(n) - \mathbf{u}^\top(n)\mathbf{W}_{\text{out}}^\top(n-1)$ ，化简  $\tilde{e}(n)$  可得

$$\begin{aligned} \tilde{e}(n) &= x(n) - \mathbf{u}^\top(n)[\mathbf{W}_{\text{out}}^\top(n-1) + \mathbf{P}(n)\mathbf{u}(n)\tilde{e}(n)] = \\ &= x(n) - \mathbf{u}^\top(n)\mathbf{W}_{\text{out}}^\top(n-1) - \mathbf{u}^\top(n)\mathbf{P}(n)\mathbf{u}(n)\tilde{e}(n) = \\ &= \frac{e(n)}{1 - \mathbf{u}^\top(n)\mathbf{P}(n)\mathbf{u}(n)} \end{aligned} \quad (19)$$

将式(19)代入式(18)得

$$\mathbf{W}_{\text{out}}(n) = \left[ \mathbf{W}_{\text{out}}^\top(n-1) + \frac{\mathbf{P}(n)\mathbf{u}(n)e(n)}{1 - \mathbf{u}^\top(n)\mathbf{P}(n)\mathbf{u}(n)} \right]^\top \quad (20)$$

式(20)中的  $\mathbf{P}(n)$  可以根据式(14)和式(17)得到

$$\begin{aligned} \mathbf{P}(n) &= [\mathbf{P}^{-1}(n-1) + \mathbf{u}^\top(n)\mathbf{u}(n)]^{-1} = \\ &= \mathbf{P}(n-1) - \frac{\mathbf{P}(n-1)\mathbf{u}(n)\mathbf{u}^\top(n)\mathbf{P}(n-1)}{1 + \mathbf{u}^\top(n)\mathbf{P}(n-1)\mathbf{u}(n)} \end{aligned} \quad (21)$$

当  $\mathbf{W}_{\text{out}}(0)$  和  $\mathbf{P}(0)$  已知时，可以通过式(20)在线更新 ESN 的  $\mathbf{W}_{\text{out}}(n)$ ，进而计算 ESN 的实际输出  $y(n)$ ，使其逼近 ESN 的期望输出  $x(n)$ 。然而，由于  $x(n-1)$  中未包含  $n$  时刻的发送序列信号  $s(n)$ ，因此  $y(n)$  只能无限接近  $x(n)$  中除  $s(n)h_0$  项之外的冗余项，即  $e(n) = x(n) - y(n)$  无限接近  $s(n)h_0$ 。

由于  $s(n)h_0$  中仍存在未知的信道系数  $h_0$ ，因此将  $e(n)$  作为 AGC 的输入序列，通过式(22)和式(23)调整信号的幅值

$$b(n) = c(n)e(n) \quad (22)$$

$$c(n+1) = c(n) + \alpha[R - |c(n)e(n)|] \quad (23)$$

其中， $b(n)$  是 AGC 的输出序列； $c(n)$  是 AGC 的控制信号，其初始值设置为 1； $R$  是用户自定义的电平； $\alpha < 1$  是幅值加权因子。

由于 AGC 只能解决幅值失真问题，而信道的非理想特性引起的 QAM 信号的相位旋转问题无法解决，因此本文在图 1 所示的 AGC 装置后进行了相位调整，将 AGC 的输出序列  $b(n)$  与旋转因子  $\exp(ja(n))$  相乘，最终得到发送信号  $s(n)$  的估计  $\hat{s}(n)$ 。

$$\hat{s}(n) = \exp(ja(n))b(n) \quad (24)$$

$$a(n+1) = a(n) - \beta[\text{angle}(b(n)\exp(ja(n)))] \quad (25)$$

其中， $a(n)$  表示相位，其初始值设为 0； $\beta < 1$  表示相位加权因子； $\text{angle}(\cdot)$  表示相位。

由以上推导可知，针对非线性信道，本文将复数型 ESN 作为非线性预测误差滤波器，采用递归最小二乘迭代训练方式，在不需要发送序列  $s(n)$  的情况下，仅利用均衡器接收序列  $x(n)$ ，实现了 QAM 信号的盲恢复。为方便叙述，将上述在线盲均衡算法简记为 ESN-PEF，具体流程如算法 1 所示。

#### 算法 1 ESN-PEF 算法流程

- 1) 均衡器初始化：随机生成  $\mathbf{W}_{\text{in}}$ ， $\mathbf{W}_{\text{res}}$ ；初始化  $\mathbf{u}(0)$ ， $\mathbf{W}_{\text{out}}(0)$ ， $\mathbf{P}(0) = \mathbf{I}$ ， $c(0)$  和  $a(0)$ 。
- 2) for  $n=1, 2, \dots$
- 3) 由式(7)更新储备池状态。
- 4) 由式(8)计算 ESN 的输出  $y(n)$ 。
- 5) 由式(21)更新  $\mathbf{P}(n)$ 。
- 6) 由式(20)更新  $\mathbf{W}_{\text{out}}(n)$ 。
- 7) 计算预测误差  $e(n) = x(n) - y(n)$ 。
- 8) 根据式(22)和式(23)调整信号幅值。
- 9) 根据式(24)和式(25)调整信号相位。
- 10) 网络收敛，停止迭代。
- 11) end for

## 4 实验仿真

为充分验证本文提出的 ESN-PEF 算法的有效性和性能优势，本节设计了 3 组仿真实验，第一组

实验探究不同的 ESN 参数设置对算法的影响及均衡后的星座图；第二组实验在非线性信道下，从收敛速度、均方误差 (MSE, mean square error)、算法复杂度三方面比较了本文算法与其他基于预测原理的盲均衡算法的均衡性能；第三组实验验证 ESN-PEF 算法对信道的跟踪性能。

实验平台设置如下，CPU 为 Intel(R) Core i7-7700 3.6 GHz, Windows10 64 bit, Matlab R2015b。

在 3 组实验中，发送序列  $s(n)$  均为随机生成且满足独立同分布的 16QAM 信号，所加噪声均为 0 均值的高斯白噪声。ESN 的  $W_{in}$ 、 $W_{res}$  和储备池状态的初始值  $u(0)$  随机生成，输出权值的初始值  $W_{out}(0)$  设置为全 0 向量，AGC 的控制信号的初始值  $c(0)$  设置为 1，相位的初始值  $a(0)$  设置为 0，幅值调整和相位调整的加权因子  $\alpha$  和  $\beta$  分别设置为 0.001 和 0.000 5。为了确保网络的稳定性，本节设置 ESN 储备池神经元连接权值  $W_{res}$  的谱半径  $\rho(W_{res}) = 0.9$ 。算法的评判标准为均方误差，计算式为

$$MSE = \frac{1}{L_d} \sum_{n=1}^{L_d} (s(n) - \hat{s}(n))^2 \quad (26)$$

其中， $L_d$  表示数据长度。

#### 4.1 ESN 参数设置对算法性能的影响

本组实验通过选取不同的储备池规模  $N$ 、神经元激活函数  $f(\cdot)$  和读出函数  $f_{out}(\cdot)$  来验证不同的 ESN 参数设置对 ESN-PEF 算法性能的影响。实验针对式(26)所示的非线性信道为

$$y_1(n) = d_1 y_{(1)}(n) + d_2 y_{(1)}^3(n) \quad (27)$$

其中， $y_{(1)}(n) = 0.7625 + 0.1538z^{-1} + 0.0769z^{-2}$ ，系数  $d_1$ 、 $d_2$  确定了由信道引起的非线性失真程度。

表 1 给出了在不同信噪比 SNR 下，储备池规模  $N$  对算法 MSE 值的影响。由表 1 可以看出，在

不同的信噪比下，随着储备池规模  $N$  的增大，算法的 MSE 值基本不变，当  $N$  增大到 50 时，MSE 值反而有增加的趋势，这说明  $N$  的增大并不能达到降低 MSE 值的目的。

表 2 给出了当 SNR=30 dB 时，不同储备池规模  $N$  对算法收敛速度的影响。当  $N$  分别为 5、10、20 时，算法均在迭代 2 000 次左右收敛；当  $N$  为 50 时，算法在迭代 5 500 次左右收敛，收敛速度明显变慢。因此，即使增大  $N$  也不能使算法的性能提升。

表 2 SNR=30 dB 时，不同储备池规模  $N$  对 ESN-PEF 算法收敛速度的影响

储备池规模	迭代次数/次
$N=5$	2 000~2 050
$N=10$	2 000~2 050
$N=20$	2 000~2 050
$N=50$	5 500~5 600

考虑到较大的  $N$  值会增大算法的计算复杂度，且并不能有效地提升算法的均衡性能，故在以下的实验中，均设置储备池规模  $N=5$ 。

表 3 给出了储备池规模  $N=5$  时，不同信噪比下，不同激活函数  $f(\cdot)$  对算法 MSE 值的影响。由表 3 可以看出，在不同的信噪比下，使用  $\tanh(\cdot)$  和  $\sinh(\cdot)$  作为激活函数时，两者的 MSE 值相差不大，但使用  $\text{tribas}(\cdot)$  作为激活函数时，其 MSE 值在信噪比大于 15 dB 之后明显高于其他 2 种激活函数。

表 4 给出了储备池规模  $N=5$ ，SNR=30 dB 时，不同激活函数  $f(\cdot)$  对算法收敛速度的影响。由表 4 可以看出，使用  $\tanh(\cdot)$  和  $\sinh(\cdot)$  作为激活函数时，算法均在 2 000 次左右收敛，而选取  $\text{tribas}(\cdot)$  作为激活函数时，算法收敛速度变慢，大约迭代 5 000 次后收敛，所以为保证算法的性能优势，应选择合适的激活函数。

表 1 不同信噪比下，不同储备池规模  $N$  对 ESN-PEF 算法 MSE 值的影响

储备池规模	MSE/dB							
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB	SNR=25 dB	SNR=30 dB	SNR=35 dB
$N=5$	9.58	4.81	-0.34	-8.31	-18.92	-27.71	-29.12	-29.42
$N=10$	9.24	4.58	-0.32	-8.71	-19.23	-27.72	-29.20	-29.45
$N=20$	9.05	4.72	-0.36	-8.51	-19.48	-27.31	-29.15	-29.41
$N=50$	9.61	4.46	-0.41	-8.42	-19.15	-25.37	-28.01	-28.35

表 3 N=5 时, 不同信噪比下, 不同激活函数  $f(\cdot)$  对 ESN-PEF 算法 MSE 值的影响

激活函数	MSE/dB							
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB	SNR=25 dB	SNR=30 dB	SNR=35 dB
tanh( $\cdot$ )	9.58	4.81	-0.34	-8.31	-18.92	-27.71	-29.12	-29.42
sinh( $\cdot$ )	9.15	4.69	-0.12	-7.81	-18.95	-26.82	-28.51	-28.61
tribas( $\cdot$ )	9.21	4.72	-0.18	-7.71	-15.88	-21.31	-24.85	-25.41

表 4 N=5, SNR=30 dB 时, 不同激活函数  $f(\cdot)$  对 ESN-PEF 算法收敛速度的影响

激活函数	迭代次数/次
tanh( $\cdot$ )	2 000~2 050
sinh( $\cdot$ )	2 000~2 050
tribas( $\cdot$ )	5 000~5 100

表 5 和表 6 给出了当  $N=5$ , 激活函数为  $\tanh(\cdot)$  时, 不同的输出层读出函数  $f_{out}(\cdot)$  对算法性能的影响。实验中  $f_{out}(\cdot)$  分别取线性和非线性的读出函数, 其中, 线性读出函数  $f_{out}(\cdot)=1$ , 非线性读出函数  $f_{out}(\cdot)=g(y)+jg(y)$ ,  $g(y)=y+\varphi\sin(\pi y)$ ,  $\varphi=0.4$ 。

表 5 给出了不同信噪比下, 读出层函数对算法 MSE 值的影响。由表 5 可以看出, 选择非线性读出函数可以得到更小的 MSE 值, 当 SNR=30 dB 时, 选择非线性读出函数均衡的 MSE 值比选择线性读出函数均衡的 MSE 值降低了 15 dB 左右, 所以读出层函数的选取对算法的 MSE 值有较大的影响。表 6 分析了当 SNR=30 dB 时, 读出层函数的选择对算法收敛速度的影响。由表 6 可以看出, 无论选取线性读出函数还是非线性读出函数, 算法均在 2 000 次左右收敛, 因此读出层函数的选择对算法的收敛速度无影响。

图 3 给出了当  $N=5$ , 激活函数  $f(\cdot)$  为  $\tanh(\cdot)$ , SNR=30 dB 时, 16QAM 信号均衡前后的星座图。图 3(a)是发送信号的星座图, 图 3(b)是均衡前的星座图, 可以看出均衡器接收端的信号存在着严重畸变。首先选择线性读出函数, 图 3(c)给出了算法进行相位调整之前的均衡星座图, 可以看出此时幅值已经被调整, 星座图较清晰, 但存在相位旋转问题。

表 5 N=5, 激活函数为  $\tanh(\cdot)$  时, 不同信噪比下, 读出层函数对 ESN-PEF 算法 MSE 值的影响

读出层函数	MSE/dB							
	SNR=0 dB	SNR=5 dB	SNR=10 dB	SNR=15 dB	SNR=20 dB	SNR=25 dB	SNR=30 dB	SNR=35 dB
线性读出函数	9.35	4.85	-0.31	-5.76	-9.82	-13.61	-14.11	-14.12
非线性读出函数	9.58	4.81	-0.34	-8.31	-18.92	-27.71	-29.12	-29.42

图 3(d)是经过相位调整后的均衡星座图, 可以看出, 因信道引起的相位旋转问题已基本解决。图 3(e)是非线性读出函数的均衡星座图, 与使用线性读出函数的图 3(d)相比, 图 3(e)星座图更加清晰紧凑, 较好地恢复出了图 3(a)所示的发送信号。

表 6 N=5, 激活函数为  $\tanh(\cdot)$ , SNR=30 dB 时, 读出层函数对 ESN-PEF 算法收敛速度的影响

读出层函数	迭代次数/次
线性读出函数	2 000~2 050
非线性读出函数	2 000~2 050

#### 4.2 与其他基于预测原理盲均衡算法的性能对比

本组实验分别在 2 种不同的非线性信道下, 将本文提出的 ESN-PEF 算法与线性预测误差滤波器 (Linear-PEF) 以及 MLP 作为预测误差滤波器 (MLP-PEF) 的盲均衡算法进行性能比较。实验所用非线性信道 1 如式(27)所示, 非线性信道 2 如式(28)所示。

$$y_2(n) = \sum_l^{L_c-1} h_l s(n-l) + \sum_{l=0}^{L_c-1} \sum_{m=l}^{L_c-1} \sum_{k=m}^{L_c-1} h_{l,m,k} \cdot s(n-l)s(n-m)s^*(n-k) + \dots \quad (28)$$

式(28)是用 Volterra 级数构建的非线性记忆卫星信道, 其中,  $h_l, h_{l,m,k}$  表示 Volterra 级数的系数, 第二项有一个共轭输入信号和 2 个非共轭输入信号,  $L_c$  表示记忆深度。

实验中, 设置均衡器接收机的 SNR=30 dB, ESN-PEF 算法中, ESN 的储备池规模  $N=5$ , 内部神经元的激活函数为  $\tanh(\cdot)$ , 输出层的读出函数为  $f_{out}(\cdot)=g(y)+jg(y)$ ,  $g(y)=y+\varphi\sin(\pi y)$ ,  $\varphi=0.4$ , 均衡器初始化设置与 4.1 节相同。Linear-PEF 算法

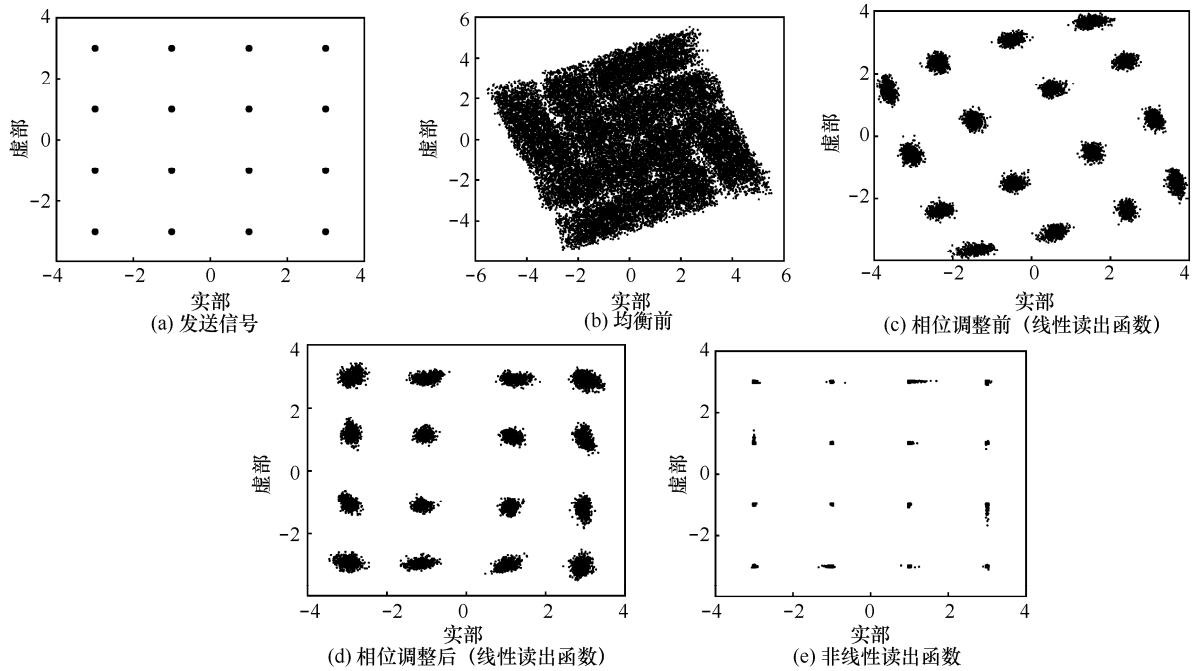


图 3 16QAM 信号均衡前后的星座图

中，滤波器的阶数  $L_w=20$ ，MLP-PEF 算法中，网络的输入层节点数为 1，隐层节点数  $N_{MLP}=20$ ，输出层节点数为 1，MLP 网络输出层同样采用上述非线性读出函数。

图 4 和图 5 分别在非线性信道 1 和非线性信道 2 下，比较了 Linear-PEF、MLP-PEF 和 ESN-PEF 这 3 种算法的性能。图 4(a)和图 5(a)描述了在不同的信噪比下，3 种算法的 MSE 值曲线，可以看出，ESN-PEF 算法均衡后的 MSE 值明显小于 Linear-PEF 算法和 MLP-PEF 算法的 MSE 值，当 SNR=30 dB 时，ESN-PEF 算法均衡后的 MSE 值比 Linear-PEF 算法降低了 20 dB 左右，比 MLP-PEF 算法降低了 8 dB 左右，这说明与 Linear-PEF 算法和 MLP-PEF 算法相比，本文提出的 ESN-PEF 算法在降低 MSE 值方面具有较大的优势。图 4(b)和图 5(b)描述了 3 种算法的收敛曲线，其中，Linear-PEF 算法在 2 种信道下均在 14 000 次左右收敛，MLP-PEF 算法分别在 4 000 次和 5 000 次左右收敛，ESN-PEF 算法均在 2 000 次左右收敛，这说明 ESN-PEF 算法具有最快的收敛速度。

在非线性信道下，本文提出的具有良好非线性映射能力的 ESN-PEF 算法仅需要 5 个储备池神经元，便可获得更低 MSE 值和更快的收敛速度。相较于采用线性结构和前馈神经网络，MLP 作为预

测误差滤波器的盲均衡算法，具有更强的去冗余项能力和更快的学习速率。

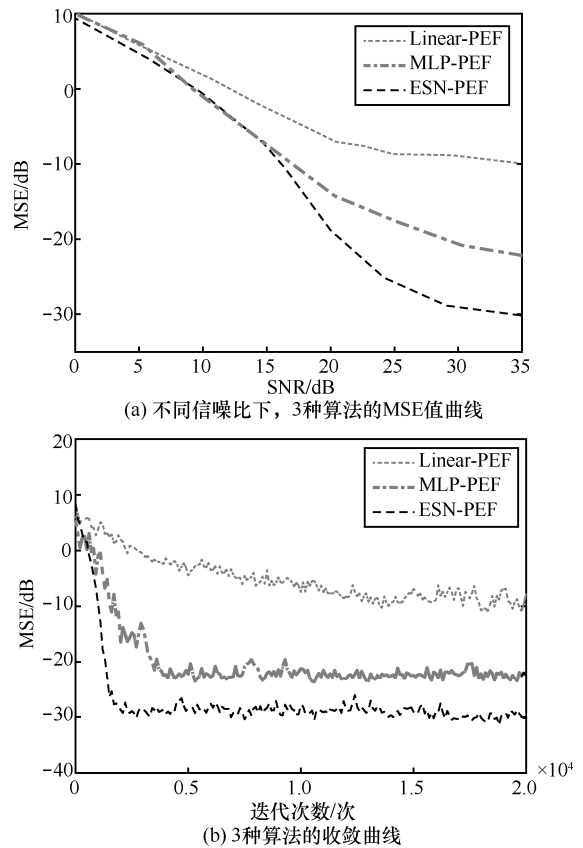


图 4 非线性信道 1 下的性能对比

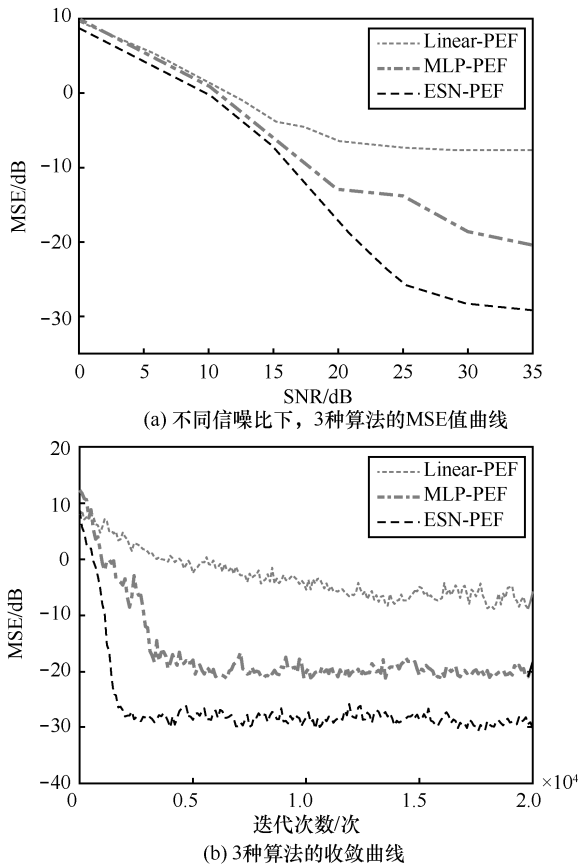


图 5 非线性信道 2 下的性能比较

表 7 给出了 3 种算法一次输出所需的计算复杂度<sup>[19]</sup>。其中, ESN-PEF 算法一次输出的计算复杂度可从算法 1 中得到。算法 1 的步骤 3)~步骤 6)运用了较多的矩阵乘法, 其计算复杂度分别为  $O(N^2 + 6N)$ 、 $O(N)$ 、 $O(N^3 + 3N^2 + 2N)$ 、 $O(2N^2 + 2N)$ ; 步骤 7)~步骤 9)涉及的计算复杂度均为常数, 每次计算记为  $O(1)$ , 因此得到 ESN-PEF 算法的计算复杂度为  $O(N^3 + 6N^2 + 11N + 5)$ 。从表 7 中可得, ESN-PEF 算法与 Linear-PEF 算法相比, 运用了较多的矩阵乘法, 所以在降低 MSE 值、加快收敛速度的同时, 不可避免地增加了计算复杂度。ESN-PEF 算法与 MLP-PEF 算法相比, 虽然前者复杂度的最高阶大于后者, 但由于 MLP 所需隐含层节点数目  $N_{MLP}$  大于 ESN 的储备池规模  $N$ , 因此, ESN-PEF 算法的计算复杂度低于 MLP-PEF 算法的计算复杂度。

### 4.3 信道跟踪性能

文献[14-15]将 ESN 作为预测误差滤波器进行盲均衡时需要批量处理数据, 不能实时跟踪信道变化。本文提出的 ESN-PEF 算法用递归最小二乘法训练获得最小预测误差, 可以有效弥补上述不足。为验证

表 7 Linear-PEF 算法、MLP-PEF 算法与 ESN-PEF 算法的复杂度比较

算法	复杂度
Linear-PEF	$O(3L_w + 5)$
MLP-PEF	$O(2N_{MLP}^2 + 6N_{MLP} + 6)$
ESN-PEF	$O(N^3 + 6N^2 + 11N + 5)$

ESN-PEF 算法的信道跟踪性能, 本节采用非线性信道 2 设置如下两组实验: 1) 使用三阶 Volterra 级数构造卫星信道, 当迭代次数达到 10 000 次后更换 Volterra 级数的系数  $h_l, h_{l,m,k}$ , 实现信道的切换; 2) 首先使用三阶 Volterra 级数构造信道, 当迭代次数达到 10 000 次后, 切换到五阶 Volterra 级数构造的信道。

图 6 是 ESN-PEF 算法的信道跟踪曲线。从图 6(a)中可以看出, ESN-PEF 算法在迭代 2 000 次左右后第一次收敛, 当三阶 Volterra 级数建模信道的系数改变后, 算法迭代大约 1 000 次后再次收敛, 这说明 ESN-PEF 算法具有迅速跟踪信道变化的性能, 可适用于时变信道。从图 6(b)中可以看出, 由三阶 Volterra 级数建模信道切换为五阶 Volterra 级数建模信道后, 算法迭代 1 500 次后再次收敛, 进一步说明即使信道发生较大的改变, ESN-PEF 算法仍具有良好的跟踪性能。




图 6 ESN-PEF 算法的信道跟踪曲线

## 5 结束语

本文针对非线性信道下的 QAM 信号, 采用复数型回声状态网络作为非线性预测误差滤波器, 用递归最小二乘算法迭代计算网络的输出权值, 实时跟踪信道变化, 并通过自动增益控制和旋转因子分别调整信号的幅值和相位旋转, 提出了基于预测原理的回声状态网络在线盲均衡算法。仿真实验表明, 与线性预测误差滤波器结构以及 MLP 作为预测误差滤波器的盲均衡算法相比, 本文提出的算法无论是在 MSE 值, 还是在收敛速度上均具有一定的性能优势, 且能够快速跟踪信道变化。

## 参考文献:

- [1] SATO Y. A method of self-recovering equalization for multilevel amplitude-modulation systems[J]. IEEE Transactions on Communications, 1975, 23(6): 679-682.
- [2] DING Z, KENNEDY R A. On the (non)existence of undesirable equilibria of Godard blind equalizers[J]. IEEE Transactions on Signal Processing, 1992, 40(10): 2425-2432.
- [3] LEE W, CHEUN K. Convergence analysis of the stop-and-go blind equalization algorithm[J]. IEEE Transactions on Communications, 1999, 47(2): 177-180.
- [4] SHARMA V, RAJ V N. Convergence and performance analysis of Godard family and multimodulus algorithms for blind equalization[J]. IEEE Transactions on Signal Processing, 2005, 53(4): 1520-1533.
- [5] XUE W, YANG X N, ZHANG Z Y. A stop and go blind equalization algorithm for QAM signals[C]//2010 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM). Piscataway: IEEE Press, 2010: 1-4.
- [6] 马思扬, 彭华, 王彬. 适用于稀疏多径信道的稀疏自适应盲均衡算法[J]. 通信学报, 2017, 38(1): 149-157.  
MA S J, PENG H, WANG B. Sparse adaptive normal mode blind equalization algorithm for sparse multipath channels[J]. Journal on Communications, 2017, 38(1): 149-157.
- [7] 赵太飞, 刘龙飞, 王晶. 无线紫外光散射通信中的改进 CMA-FSE 盲均衡算法[J]. 通信学报, 2019, 40(3): 102-108.  
ZHAO T F, LIU L F, WANG J. An improved CMA-FSE blind equalization algorithm in wireless ultraviolet light scattering communication[J]. Journal on Communications, 2019, 40(3): 102-108.
- [8] SLOCK D T M. Blind fractionally-spaced equalization, perfect-reconstruction filter banks and multichannel linear prediction[C]// IEEE International Conference on Acoustics, Speech, & Signal Processing. Piscataway: IEEE Press, 1994: 585.
- [9] FERRARI R, PANAZIO C M, ATTUX R R F, et al. Unsupervised channel equalization using fuzzy prediction-error filters[C]// IEEE Workshop on Neural Networks for Signal Processing. Piscataway: IEEE Press, 2003: 869-878.
- [10] CAVALCANTE C C, MONTALVAO F J R, DORIZZI B, et al. A neural predictor for blind equalization of digital communication systems[C]//Proceedings of the IEEE 2000 Adaptive Systems for Signal Processing, Communications, and Control Symposium. Piscataway: IEEE Press, 2000:347-351.
- [11] XIE N, LEUNG H. Blind equalization using a predictive radial basis function neural network[J]. IEEE Transactions on Neural Networks, 2005, 16(3): 709-720.
- [12] WADA C, CONSOLARO D M, FERRARI R, et al. Nonlinear blind source deconvolution using recurrent prediction-error filters and an artificial immune system[C]//Proceedings of the 8th International Conference on Independent Component Analysis and Signal Separation. Berlin: DBLP, 2009: 371-378.
- [13] CHEN L, YANG L, DU J, et al. An extreme learning machine architecture based on volterra filtering and PCA[J]. IEICE Transactions on Information and Systems, 2017, E100-D(11): 2690-2701.
- [14] BOCCATO L, LOPES A, ATTUX R, et al. An extended echo state network using Volterra filtering and principal component analysis[J]. Neural Networks: the Official Journal of the International Neural Network Society, 2012, 32(2): 292-302.
- [15] 马涛. 最简储备池回声状态网络及其应用研究[D]. 兰州: 兰州大学, 2013.  
MA T. Minimum reserve pool ESN and its application [D]. Lanzhou: Lanzhou University, 2013.
- [16] MAASS W, NATSCHLÄGER T, MARKRAM H. Real-time computing without stable states: a new framework for neural computation based on perturbations[J]. Neural Computation, 2002, 14(11): 2531-2560.
- [17] JAEGER H, HAAS H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication[J]. Science, 2004, 304(5667): 78-80.
- [18] SETH S, OZTURK M C, PRINCIPE J C. Signal processing with echo state networks in the complex domain[C]//2007 IEEE Workshop on Machine Learning for Signal Processing. Piscataway: IEEE Press, 2007: 408-412.
- [19] 曾娟, 王颖, 李晓娜, 等. 基于频域迭代判决反馈均衡的低复杂度 FTN 接收机[J]. 通信学报, 2017, 38(4): 190-198.  
ZENG J, WANG Y, LI X N, et al. Low-complexity FTN receivers based on frequency domain iterative decision feedback equalization[J]. Journal on Communications, 2017, 38(4): 190-198.

## [作者简介]



杨凌 (1966-), 女, 甘肃张掖人, 兰州大学副教授、硕士生导师, 主要研究方向为机器学习理论与通信系统智能信号处理。

韩琴 (1996-), 女, 山西忻州人, 兰州大学硕士生, 主要研究方向为储备池计算模型及其在盲均衡中的应用。

程丽 (1996-), 女, 贵州铜仁人, 兰州大学硕士生, 主要研究方向为极限学习机及其在盲均衡中的应用。

赵傲男 (1995-), 男, 河南周口人, 兰州大学硕士生, 主要研究方向为神经网络理论及其在盲均衡中的应用。

杜娟 (1979-), 女, 博士, 兰州大学讲师、硕士生导师, 主要研究方向为非线性电路和系统以及混沌安全通信。