

基于回声状态网络的卫星信道在线盲均衡算法

杨凌* 赵宾 陈亮 李媛 张国龙

(兰州大学信息科学与工程学院 兰州 730000)

摘要: 针对非线性卫星信道, 该文提出了两种基于回声状态网络(ESN)的在线盲均衡算法。利用ESN良好的非线性逼近能力, 将发送信号的高阶统计量(HOS)代入ESN, 结合常模算法(CMA)和多模算法(MMA)构造盲均衡的代价函数, 并采用递归最小二乘(RLS)算法对ESN输出权值进行迭代寻优, 实现了Volterra卫星信道下常模和多模信号的在线盲均衡。实验表明, 该文算法可以有效降低非线性信道对发送信号产生的畸变, 相较于传统的Volterra滤波方法, 有更快的收敛速度和更低的均方误差值。

关键词: Volterra卫星信道; 回声状态网络; 常模算法; 多模算法; 递归最小二乘算法

中图分类号: TN927.2; TN911.7

文献标识码: A

文章编号: 1009-5896(2019)10-2334-08

DOI: 10.11999/JEIT190034

Online Blind Equalization Algorithm for Satellite Channel Based on Echo State Network

YANG Ling ZHAO Bin CHEN Liang LI Yuan ZHANG Guolong

(School of Information Science and Engineering, Lanzhou University, Lanzhou 730000, China)

Abstract: Two online blind equalization algorithms based on Echo State Network (ESN) in this paper are proposed for the nonlinear satellite channel. These two algorithms take advantage of the good nonlinear approximation of ESN to bring the High-Order Statistics (HOS) of the transmitted signal into the ESN, and constructing cost function of blind equalization by combining Constant Modulus Algorithm (CMA) and Multi-Modulus Algorithm (MMA). Then, the Recursive Least Squares (RLS) algorithm is used to iteratively optimize the network output weights, and the online blind equalization of the constant modulus signals and the multi-modulus signals over the channel of Volterra satellite are realized. Experiments show that the proposed algorithms can effectively reduce the distortion of the transmitted signal by the nonlinear channel. Compared with the traditional Volterra filtering method, they have faster convergence speed and lower mean square error.

Key words: Volterra satellite channel; Echo State Network (ESN); Constant Modulus Algorithm (CMA); Multi-Modulus Algorithm (MMA); Recursive Least Squares (RLS)

1 引言

由于卫星通信相较于地面通信的特殊性, 星载高功率放大器(High Power Amplifier, HPA)通常工作在饱和点附近, 使得放大器的输入/输出信号不再是简单的线性关系, 进而导致源信号通过信道后产生严重的畸变, 通常采用接收端均衡技术克服这种非线性失真^[1]。传统的自适应均衡技术需要定

时发送训练序列以提供均衡器自适应训练的监督信号, 由于卫星通信系统发送训练序列成本高, 所以自适应均衡技术将受到限制。盲均衡技术可以直接对接收信号进行均衡, 节省了宝贵的带宽资源^[2]。

目前, 卫星信道的盲均衡方法大致分为3类: Volterra滤波、粒子滤波和神经网络方法。文献[3,4]使用蒙特卡洛法及衍生出的粒子滤波方法, 该方法需要大量的粒子用于后验概率密度的计算, 计算量随着调制信号阶数的增大而增大。文献[5,6]提到的Volterra均衡器由于引入了大量的核系数, 导致运算复杂度增加。人工神经网络(Artificial Neural Networks, ANN)能够以高精度逼近复杂的非线性关系, 文献[7]首次提出了用误差反向传播(Back Propagation, BP)算法训练的多层感知机盲均衡器, 但其计算量较大。

收稿日期: 2019-01-15; 改回日期: 2019-05-30; 网络出版: 2019-06-12

*通信作者: 杨凌 lingyang@lzu.edu.cn

基金项目: 中央高校基本科研业务费专项资金项目(lzujbky-2017-38), 甘肃省自然科学基金(纵20180322)

Foundation Items: The Fundamental Research Fund for the Central Universities (lzujbky-2017-38), The Natural Science Foundation of Gansu Province (Longitudinal 20180322)

结合具体的神经网络构造盲均衡的代价函数, 通过训练神经网络确定其连接权值, 以获得代价函数的最小值, 为神经网络盲均衡提供了一种新的思路^[8-10]。其中, 文献^[10]提出了用支持向量回归训练回声状态网络(Echo State Network, ESN)的盲均衡方法, 该方法将传统盲均衡的代价函数与ESN结合在了一起, 由于是一种批量算法, 不能实时追踪信道的变化, 此外, 文中的实验仅仅针对线性信道。

本文基于ESN框架, 提出了两种针对非线性卫星信道的在线盲均衡算法。对于常模信号, 将传统常模算法(CMA)的误差函数代入ESN模型构造代价函数, 并利用递归最小二乘(RLS)算法迭代求解输出权值向量, 得到基于ESN的递归最小二乘常模算法ESN-RLS-CMA; 对于多模信号, 将多模算法(MMA)的误差函数带入ESN模型, 同时, 为了防止发散, 采用一种双模式操作方案, 得到基于ESN的递归最小二乘多模算法ESN-RLS-MMA。

2 问题描述

2.1 卫星信道的盲均衡

卫星信道的等效基带盲均衡框图如图1所示, 盲均衡器接收到的信号可以表示为

$$x(n) = f(s(n)) + v(n) \quad (1)$$

其中, $s(n)$ 是第 n 个发送源信号, $v(n)$ 是高斯白噪声, $f(\cdot)$ 表征卫星信道。盲均衡器的目的是使输出的估计信号尽量接近源信号 $s(n)$ 。




图1 卫星信道的等效基带盲均衡系统框图

通常用两种方式建模卫星信道, 一种是分别表示非线性和记忆效应: 用非线性函数表示非线性, 用FIR滤波器表示记忆效应^[11]。另一种是积分方法, 如Volterra级数模型^[12], 本文用Volterra级数建模。

2.2 回声状态网络结构

ESN是一种新型的递归神经网络, 拓扑结构如图2所示, 包括输入层、动态储备池(隐含层)和输出层3部分。储备池的状态更新和网络的输出表达式分别为

$$\mathbf{u}(n) = f(\mathbf{W}_{\text{res}}\mathbf{u}(n-1) + \mathbf{W}_{\text{in}}\mathbf{x}(n)) \quad (2)$$

$$\mathbf{y}(n) = f_{\text{out}}(\mathbf{W}_{\text{out}}\mathbf{u}(n)) \quad (3)$$

其中, $\mathbf{u}(n) \in \mathbb{C}^{N \times 1}$ 表示 n 时刻储备池的内部状

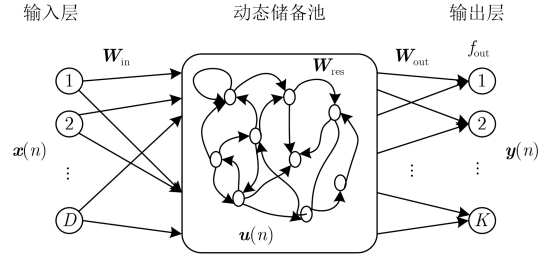


图2 回声状态网络结构

态, $\mathbf{W}_{\text{res}} \in \mathbb{C}^{N \times N}$ 为储备池神经元的连接权值矩阵, $\mathbf{W}_{\text{in}} \in \mathbb{C}^{N \times D}$ 是输入权值矩阵, $\mathbf{W}_{\text{out}} \in \mathbb{C}^{K \times N}$ 是输出权值矩阵, $\mathbf{x}(n) \in \mathbb{C}^{D \times 1}$ 和 $\mathbf{y}(n) \in \mathbb{C}^{K \times 1}$ 分别为 n 时刻网络的输入和输出信号。 N 为储备池神经元的节点个数, D 和 K 分别为网络的输入和输出节点数。 $f(\cdot)$ 为神经元的激活函数, 通常为非线性函数(比如tanh函数)。 $f_{\text{out}}(\cdot)$ 为输出层的读出函数, 可为线性函数, 如 $f_{\text{out}}(\cdot)=1$, 也可为非线性函数。

不同于传统的递归神经网络, ESN的输入权值矩阵 \mathbf{W}_{in} 和隐含层(储备池)权值矩阵 \mathbf{W}_{res} 随机生成且固定不变, 无需训练, 只有输出权值矩阵 \mathbf{W}_{out} 需要训练, 一般通过已知序列求伪逆的方式来更新 \mathbf{W}_{out} 。为保证储备池的回声特性, \mathbf{W}_{res} 需要满足谱半径 $\rho(\mathbf{W}_{\text{res}})$ 和稀疏度SD的要求^[13]。

3 基于ESN的卫星信道在线盲均衡算法

针对盲均衡问题, 设置ESN的输入和输出节点数均为1, $x(n)$ 和 $y(n)$ 分别 n 时刻均衡器的输入和输出信号。将ESN输出权值 \mathbf{W}_{out} 的训练方式与盲均衡理论相结合, 首先构造代价函数, 之后以迭代寻优的方式代替传统求伪逆的方法更新 \mathbf{W}_{out} , 训练网络直至收敛即获得代价函数的最小值。

3.1 基于ESN的递归最小二乘常模算法

为了在线迭代更新ESN的输出权值 \mathbf{W}_{out} , 采用RLS算法。对于常模信号, 将CMA中的信号统计量 $R_{\text{CMA}} = E[|s(n)|^4]/E[|s(n)|^2]^2$, 其中 $E\{\cdot\}$ 表示数学期望, 代入ESN构造盲均衡的代价函数

$$\begin{aligned} J(n) &= \sum_{k=1}^n \lambda^{n-k} |R_{\text{CMA}} - |y(k, n)|^2|^2 \\ &= \sum_{k=1}^n \lambda^{n-k} |e(k)|^2 \end{aligned} \quad (4)$$

其中, $0 < \lambda < 1$ 为遗忘因子; $y(k, n)$ 是对过去 k 时刻输出序列数据的重新估计, 考虑ESN的输出层取线性读出函数, 即令 $f_{\text{out}}(\cdot)=1$, 则有 $y(k, n) = \mathbf{W}_{\text{out}}(n)\mathbf{u}(k)$, 其中 $\mathbf{u}(k)$, ($k=1, 2, \dots, n$)为 k 时刻储备池状态, $\mathbf{W}_{\text{out}}(n)$ 是代价函数达到最小时ESN的输出权值向量; $e(k)$ 为 k 时刻估计误差。

RLS算法需要代价函数满足标准二次型, 故定义

$$\mathbf{U}(k, n) = \mathbf{u}(k)(\mathbf{W}_{\text{out}}(n)\mathbf{u}(k))^* \quad (5)$$

其中, “*”表示共轭。则式(4)可写为

$$J(n) = \sum_{k=1}^n \lambda^{n-k} |R_{\text{CMA}} - \mathbf{W}_{\text{out}}(n)\mathbf{U}(k, n)|^2 \quad (6)$$

考虑 $\mathbf{U}(k, n)$ 的近似式

$$\tilde{\mathbf{U}}(k, n) = \mathbf{u}(k)(\mathbf{W}_{\text{out}}(n-1)\mathbf{u}(k))^* \quad (7)$$

若算法收敛, 那么必有 $\lim_{n \rightarrow \infty} \|\mathbf{W}_{\text{out}}(n) - \mathbf{W}_{\text{out}}(n-1)\| = 0$, 因此, 利用 $\tilde{\mathbf{U}}(k, n)$ 近似表示 $\mathbf{U}(k, n)$ 具有合理性。所以, 式(6)可进一步写成

$$J(n) = \sum_{k=1}^n \lambda^{n-k} |R_{\text{CMA}} - \mathbf{W}_{\text{out}}(n)\tilde{\mathbf{U}}(k, n)|^2 \quad (8)$$

指数代价函数式(8)的梯度为

$$\nabla J(n) = \mathbf{R}(n)\mathbf{W}_{\text{out}}(n) - \mathbf{r}(n) \quad (9)$$

其中, $\mathbf{R}(n) = \sum_{k=1}^n \lambda^{n-k} \tilde{\mathbf{U}}(k, n)\tilde{\mathbf{U}}^H(k, n)$ 为自相关矩阵, $\mathbf{r}(n) = \sum_{k=1}^n \lambda^{n-k} \tilde{\mathbf{U}}(k, n)R_{\text{CMA}}$ 为互相关向量。

根据无约束指数加权最优化问题的最优解由 $\nabla J(n) = 0$ 给出, 可以得到

$$\mathbf{W}_{\text{out}}(n) = \mathbf{R}^{-1}(n)\mathbf{r}(n) \quad (10)$$

式(10)可以用时间递推的方式进行求解, 考虑 $\mathbf{W}_{\text{out}}(n)$ 的时间递推, 并根据指数滑动窗对 $\mathbf{R}(n)$ 和 $\mathbf{r}(n)$ 进行递推估计, 使用矩阵求逆引理, 可以得到自相关逆矩阵 $\mathbf{P}(n) = \mathbf{R}^{-1}(n)$ 的递推估计式为

$$\mathbf{P}(n) = \frac{1}{\lambda} [\mathbf{P}(n-1) - \mathbf{k}(n)\tilde{\mathbf{U}}^H(n, n)\mathbf{P}(n-1)] \quad (11)$$

其中, $\mathbf{k}(n) = \frac{\mathbf{P}(n-1)\tilde{\mathbf{U}}(n, n)}{\lambda + \tilde{\mathbf{U}}^H(n, n)\mathbf{P}(n-1)\tilde{\mathbf{U}}(n, n)}$ 为增益矢量, 符号“H”表示矩阵的共轭转置。

将式(11)代入式(10)中, 得到 \mathbf{W}_{out} 的递推公式

$$\mathbf{W}_{\text{out}}(n) = \mathbf{W}_{\text{out}}(n-1) + \mathbf{k}(n)e^*(n) \quad (12)$$

其中, $e(n) = R_{\text{CMA}} - \mathbf{W}_{\text{out}}(n-1)\tilde{\mathbf{U}}(n, n)$ 为先验估计误差。

上述算法以最小二乘准则构造代价函数式(4), 利用矩阵求逆引理以迭代的方式求解确定性正则方程, 代替直接求逆方式求解ESN输出权值 \mathbf{W}_{out} 的全局最优解。由于式(12)的迭代求解过程满足严格意义的递归最小二乘准则, 算法因此是收敛的。需要说明的是, 遗忘因子 λ 是影响RLS算法性能的一个重要参数, 本文采用文献[14]的方法对 λ 进行自适应调整。

上述基于ESN的递归最小二乘常模算法简称为ESN-RLS-CMA, 具体流程如表1。

表1 ESN-RLS-CMA算法

步骤 1	均衡器初始化: 随机生成 $(\mathbf{W}_{\text{res}}, \mathbf{W}_{\text{in}})$, 初始化 $\mathbf{u}(0), \mathbf{W}_{\text{out}}$ 和 λ ; $\mathbf{P}(0) = \delta^{-1}\mathbf{I}$ (δ 是一个很小的正数);
步骤 2	For: $n=1, 2, \dots, N$;
	(1) 更新储备池状态: $\mathbf{u}(n) = f(\mathbf{W}_{\text{res}}\mathbf{u}(n-1) + \mathbf{W}_{\text{in}}x(n))$;
	(2) 计算 $\mathbf{y}(n) = \mathbf{W}_{\text{out}}(n-1)\mathbf{u}(n)$;
	(3) 由式(7)得到 $\tilde{\mathbf{U}}(n, n)$, 通过式(11)计算自相关矩阵 $\mathbf{P}(n)$;
	(4) 按照式(12)更新ESN的输出权值 $\mathbf{W}_{\text{out}}(n)$;
	(5) 根据文献[14]的方法调整 λ 值。
	End;
步骤 3	迭代直到网络收敛为止。

3.2 基于ESN的递归最小二乘多模算法

3.1节提出的ESN-RLS-CMA对解决常模信号的盲均衡有良好的性能。对于多模信号, 会出现较大的误差, 且不能解决相位偏转问题。多模算法(MMA)^[15]通过分别最小化均衡器输出的实部和虚部来解决上述问题。本节基于ESN的框架, 借鉴MMA对多模信号的处理方式, 构造盲均衡的代价函数

$$J(n) = (1 - \lambda) \sum_{k=1}^n \lambda^{n-k} \left\{ [R_{\text{MMA}} - y_{\text{R}}^2(k, n)]^2 + [R_{\text{MMA}} - y_{\text{I}}^2(k, n)]^2 \right\} \quad (13)$$

其中, $0 \ll \lambda < 1$ 是遗忘因子, $R_{\text{MMA}} = E\{s_{\text{R}}^4(n)\}/E\{s_{\text{R}}^2(n)\} = E\{s_{\text{I}}^4(n)\}/E\{s_{\text{I}}^2(n)\}$ 是发送信号的统计量, $E\{\cdot\}$ 表示数学期望; y_{R} 和 y_{I} 分别为ESN输出 y 的实部和虚部。同样令 $f_{\text{out}}(\cdot) = 1$, 则有

$$\mathbf{y}(k, n) = y_{\text{R}}(k, n) + jy_{\text{I}}(k, n) = \mathbf{W}_{\text{out}}(n)\mathbf{u}(k) \quad (14)$$

式(13)对输出权值 $\mathbf{W}_{\text{out}}(n)$ 求梯度, 并令其等于0, 得到

$$R_{\text{MMA}}\hat{\mathbf{R}}(n)\mathbf{W}_{\text{out}}(n) = \mathbf{p}(n) \quad (15)$$

其中,

$$\begin{aligned} \hat{\mathbf{R}}(n) &= \sum_{k=1}^n \lambda^{n-k} \mathbf{u}^*(k)\mathbf{u}^T(k) \\ &= \lambda\hat{\mathbf{R}}(n-1) + \mathbf{u}^*(n)\mathbf{u}^T(n) \end{aligned} \quad (16)$$

$$\mathbf{p}(n) = \sum_{k=1}^n \lambda^{n-k} [y_{\text{R}}^3(k, n) + jy_{\text{I}}^3(k, n)]\mathbf{u}^*(k) \quad (17)$$

为了通过式(15)获得 $\mathbf{W}_{\text{out}}(n)$ 的更新公式, 需要首先得到辅助项 $\hat{\mathbf{R}}(n)$ 和 $\mathbf{p}(n)$ 的递归方程。定义 $\mathbf{W}_{\text{out}}(n)$ 的迭代误差为

$$\Delta \mathbf{W}_{\text{out}}(n) = \mathbf{W}_{\text{out}}(n) - \mathbf{W}_{\text{out}}(n-1) \quad (18)$$

由式(16)和式(18)可得式(15)等号左边 $\hat{\mathbf{R}}(n)$ 的迭代公式为

$$\begin{aligned} R_{\text{MMA}} \hat{\mathbf{R}}(n) \mathbf{W}_{\text{out}}(n) \\ = \lambda R_{\text{MMA}} \hat{\mathbf{R}}(n-1) \mathbf{W}_{\text{out}}(n-1) \\ + R_{\text{MMA}} \hat{\mathbf{R}}(n) \Delta \mathbf{W}_{\text{out}}(n) + R_{\text{MMA}} y(n) \mathbf{u}^*(n) \end{aligned} \quad (19)$$

其中, $y(n) = y_{\text{R}}(n) + jy_{\text{I}}(n) = \mathbf{W}_{\text{out}}(n-1) \mathbf{u}(n)$ 。由于式(17)含有非线性项, 为了得到 $\mathbf{p}(n)$ 的近似递归方程, 定义

$$\begin{aligned} \Delta y_{\text{R}}^3(k, n) + j \Delta y_{\text{I}}^3(k, n) = [y_{\text{R}}^3(k, n) - y_{\text{R}}^3 \\ \cdot (k, n-1)] + j[y_{\text{I}}^3(k, n) - y_{\text{I}}^3(k, n-1)] \end{aligned} \quad (20)$$

将式(20)代入式(17)得到

$$\begin{aligned} \mathbf{p}(n) = \sum_{k=1}^n \lambda^{n-k} [y_{\text{R}}^3(k, n-1) + jy_{\text{I}}^3(k, n-1)] \mathbf{u}^*(k) \\ + \sum_{k=1}^n \lambda^{n-k} [\Delta y_{\text{R}}^3(k, n) + j \Delta y_{\text{I}}^3(k, n)] \mathbf{u}^*(k) \end{aligned} \quad (21)$$

式(21)右边第2项的近似可以通过以下假设获得。定义高阶累积量

$$\begin{aligned} \kappa_{\text{R}}(n) = E\{y_{\text{R}}^3(n) \mathbf{u}^*(n)\} \\ - 3E\{y_{\text{R}}^2(n)\}E\{y_{\text{R}}(n) \mathbf{u}^*(n)\} \end{aligned} \quad (22)$$

$$\begin{aligned} \kappa_{\text{I}}(n) = E\{y_{\text{I}}^3(n) \mathbf{u}^*(n)\} \\ - 3E\{y_{\text{I}}^2(n)\}E\{y_{\text{I}}(n) \mathbf{u}^*(n)\} \end{aligned} \quad (23)$$

这里, 用经验平均代替期望, 并将 $E\{y_{\text{R}}^2(n)\}$ 和 $E\{y_{\text{I}}^2(n)\}$ 替换为 $E\{s_{\text{R}}^2(n)\} = E\{s_{\text{I}}^2(n)\}$ ^[16]。则当输出权值为 $\mathbf{W}_{\text{out}}(n-1)$ 时, 复向量 $\boldsymbol{\kappa}(n) = \kappa_{\text{R}}(n) + j\kappa_{\text{I}}(n)$ 可以被近似替代为

$$\begin{aligned} \hat{\boldsymbol{\kappa}}_{n-1}(n) = \sum_{k=1}^n \lambda^{n-k} [y_{\text{R}}^3(k, n-1) + jy_{\text{I}}^3(k, n-1)] \\ \cdot \mathbf{u}^*(k) - 3E\{s_{\text{R}}^2(n)\} \hat{\mathbf{R}}(n) \mathbf{W}_{\text{out}}(n-1) \end{aligned} \quad (24)$$

同样的, 当输出权值为 $\mathbf{W}_{\text{out}}(n)$ 时, $\boldsymbol{\kappa}(n)$ 可以被近似替代为

$$\begin{aligned} \hat{\boldsymbol{\kappa}}_n(n) = \sum_{k=1}^n \lambda^{n-k} [y_{\text{R}}^3(k, n) + jy_{\text{I}}^3(k, n)] \\ \cdot \mathbf{u}^*(k) - 3E\{s_{\text{R}}^2(n)\} \hat{\mathbf{R}}(n) \mathbf{W}_{\text{out}}(n) \end{aligned} \quad (25)$$

由于 λ 充分接近1且 n 足够大, 则由 $\mathbf{W}_{\text{out}}(n-1)$ 计算得到 $\hat{\boldsymbol{\kappa}}_{n-1}(n)$ 可近似为由 $\mathbf{W}_{\text{out}}(n)$ 计算得到 $\hat{\boldsymbol{\kappa}}_n(n)$, 即

$$\boldsymbol{\kappa}(n) \approx \hat{\boldsymbol{\kappa}}_{n-1}(n) \approx \hat{\boldsymbol{\kappa}}_n(n) \quad (26)$$

由式(24)—式(26)得

$$\begin{aligned} \sum_{k=1}^n \lambda^{n-k} [\Delta y_{\text{R}}^3(k, n) + j \Delta y_{\text{I}}^3(k, n)] \mathbf{u}^*(k) \\ \approx 3E\{s_{\text{R}}^2(n)\} \hat{\mathbf{R}}(n) \Delta \mathbf{W}_{\text{out}}(n) \end{aligned} \quad (27)$$

将式(27)代入式(21)就可以得到 $\mathbf{p}(n)$ 的近似迭代公式为

$$\begin{aligned} \hat{\mathbf{p}}(n) = \lambda \hat{\mathbf{p}}(n-1) + [y_{\text{R}}^3(n) + jy_{\text{I}}^3(n)] \mathbf{u}^*(n) \\ + 3E\{s^2(n)\} \hat{\mathbf{R}}(n) \Delta \mathbf{W}_{\text{out}}(n) \end{aligned} \quad (28)$$

通过以上分析, 可以得到ESN输出权值的更新公式为

$$\mathbf{W}_{\text{out}}(n) = \mathbf{W}_{\text{out}}(n-1) + \frac{e(n)}{\gamma} \hat{\mathbf{R}}^{-1}(n) \mathbf{u}^*(n) \quad (29)$$

其中, $e(n) = e_{\text{R}}(n) + je_{\text{I}}(n) = [R_{\text{MMA}} - y_{\text{R}}^2(n)]y_{\text{R}}(n) + j[R_{\text{MMA}} - y_{\text{I}}^2(n)]y_{\text{I}}(n)$, $\gamma = 3E\{s_{\text{R}}^2(n)\} - R_{\text{MMA}}$ 。 $\hat{\mathbf{R}}^{-1}(n)$ 可以通过矩阵求逆引理以递归的方式得到, 如式(30)

$$\begin{aligned} \hat{\mathbf{R}}^{-1}(n) = \frac{1}{\lambda} \left[\hat{\mathbf{R}}^{-1}(n-1) \right. \\ \left. - \frac{\hat{\mathbf{R}}^{-1}(n-1) \mathbf{u}^*(n) \mathbf{u}^{\text{T}}(n) \hat{\mathbf{R}}^{-1}(n-1)}{\lambda + \mathbf{u}^{\text{T}}(n) \hat{\mathbf{R}}^{-1}(n-1) \mathbf{u}^*(n)} \right] \end{aligned} \quad (30)$$

由于算法存在非线性估计的不一致性, 式(29)在进行权值更新的过程中可能会发散, 为了避免该问题, 将误差项归一化得到

$$\frac{e(n)}{\gamma} = d(n) - y(n) \quad (31)$$

其中, $d(n) = d_{\text{R}}(n) + jd_{\text{I}}(n) = t_{\text{R}}(n)y_{\text{R}}(n) + jt_{\text{I}}(n)y_{\text{I}}(n)$ 为期望输出, $t_{\text{R}}(n) = \frac{3E\{s_{\text{R}}^2(n)\} - y_{\text{R}}^2(n)}{\gamma}$, $t_{\text{I}}(n) = \frac{3E\{s_{\text{I}}^2(n)\} - y_{\text{I}}^2(n)}{\gamma}$ 。

则式(29)重新写为

$$\begin{aligned} \mathbf{W}_{\text{out}}(n) = \mathbf{W}_{\text{out}}(n-1) + [d(n) \\ - y(n)] \hat{\mathbf{R}}^{-1}(n) \mathbf{u}^*(n) \end{aligned} \quad (32)$$

由上述推导可知, ESN输出权值 \mathbf{W}_{out} 的更新公式以及求解最优解的迭代过程与超指数算法相似, 其收敛性证明亦类似于超指数算法^[17]。

为了防止 \mathbf{W}_{out} 在迭代过程中的发散问题, 采用一种双模式操作方案, 设置一个门限值 T , 当 $|y(n)|^2 \leq T$ 时, $d(n) = t_{\text{R}}(n)y_{\text{R}}(n) + jt_{\text{I}}(n)y_{\text{I}}(n)$; 当 $|y(n)|^2 > T$ 时, 忽略期望值 $d(n)$, 即令 $d(n) = 0$ 。通常设置 $T = 3E\{|s(n)|^2\}$ 。虽然这一操作阻碍了信号均衡, 但却使得权值系数向量 \mathbf{W}_{out} 的欧几里德范数随着迭代减小^[18]。

上述基于ESN的递归最小二乘多模算法简称为ESN-RLS-MMA, 具体流程如表2。

表2 ESN-RLS-MMA算法

步骤1 均衡器初始化: 随机生成($\mathbf{W}_{res}, \mathbf{W}_{in}$); 初始化 $\mathbf{u}(0), \mathbf{W}_{out}, \lambda(0 \ll \lambda < 1), \hat{\mathbf{R}}^{-1}(0) = \delta \mathbf{I}$ (δ 是一个很小的正数); 设置 $\gamma = 3E\{s_R^2(n)\} - R_{MMA}$, 门限值 $T = 3E\{|s(n)|^2\}$;

步骤2 For: $n=1, 2, \dots, N$;

(1) 更新储备池状态: $\mathbf{u}(n) = f(\mathbf{W}_{res}\mathbf{u}(n-1) + \mathbf{W}_{in}x(n))$;

(2) 计算 $y(n) = \mathbf{W}_{out}(n-1)\mathbf{u}(n)$;

(3) 通过式(30)计算 $\hat{\mathbf{R}}^{-1}(n)$;

(4) 计算: $d_R(n) = [\gamma + R_{MMA} - y_R^2(n)]y_R(n)$,
 $d_I(n) = [\gamma + R_{MMA} - y_I^2(n)]y_I(n)$
 $d(n) = \gamma^{-1}[d_R(n) + jd_I(n)]$;

(5) If $|y(n)|^2 > T$;
 $d(n) = 0$

End;

(6) 根据式(32)更新 $\mathbf{W}_{out}(n)$.

End;

步骤3 迭代直到网络收敛为止。

4 实验仿真

本文设计3组仿真实验, 验证本文算法的性能。实验中, 用5阶Volterra级数对卫星信道建模^[2], 记忆深度 $M=4$ 。发送信号 $s(n)$ 满足独立同分布条件, 添加零均值高斯白噪声, 信噪比 $SNR=30$ dB。在ESN-RLS-CMA中, λ 初始化为0.99, δ 通过交叉验证设为0.01; 在ESN-RLS-MMA中, λ 和 δ 通过交叉验证分别设为0.99和0.01。算法的评价标准为均方误差(Mean Square Error, MSE), 计算公式为

$$MSE = \frac{1}{L} \sum_{n=1}^L (y(n) - s(n))^2 \quad (33)$$

其中, L 为数据长度。

实验平台为, CPU: Intel(R) Core i7-7700 3.6 GHz; Windows10 64 bit; MATLAB R2014b。

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 $f_{out}(\cdot)$ 验证不同的ESN

参数设置对于两种在线盲均衡算法的性能影响。实验中, 对于常模(如QPSK调制)信号采用ESN-RLS-CMA, 对于多模(如16QAM调制)信号采用ESN-RLS-MMA。ESN的谱半径 $\rho(\mathbf{W}_{res})=0.9$, 稀疏度 $SD=0.2$ 。

表3是选取不同 N 时两种算法的MSE值。表3数据表明, 当 N 过小, 如 $N=20$ 时, ESN的非线性映射能力较弱, 均衡后的MSE值较大, 均衡效果较差。当 N 超过50时, 两种算法所表现出来的均衡性能均相差无几。另外, 实验结果表明, 随着 N 的成倍增加, 网络的运行时间大约以2的指数倍增长, 所以选择不同的 N , 对于两种算法的性能有着重要的影响。

图3是选取不同 $f(\cdot)$ 时两种算法的收敛曲线。可以看出, 对于ESN-RLS-CMA, 选用3种不同的 $f(\cdot)$, 算法都在迭代1000次左右后收敛, 其中 $\tanh(\cdot)$ 函数对应的MSE值最低, 约为 -30 dB。对于ESN-RLS-MMA, 由于双模式操作的原因, 算法存在两次收敛过程。当 $f(\cdot)$ 选用 $\tanh(\cdot)$ 函数时, 算法迭代大约5000次时第1次收敛, 迭代约15000次时第2次收敛, 收敛后的MSE值最低约为 -29 dB; 当 $f(\cdot)$ 选用 $\sinh(\cdot)$ 和 $\text{sigmoid}(\cdot)$ 函数时, 算法大约需要6000次迭代第1次收敛, 第2次收敛分别需要15000次和12000次迭代, 收敛后的MSE值大致相同, 均约为 -27 dB。

图4给出了当 $N=100, f(\cdot)$ 为 $\tanh(\cdot)$ 函数, 选择不同 $f_{out}(\cdot)$ 时, 两种在线盲均衡算法收敛性能比较。实验中, $f_{out}(\cdot)$ 分别取线性读出函数 $f_{out}(y) = 1$ 和非线性读出函数 $f_{out}(y) = g(y) + jg(y), g(y) = y + \beta \sin(\pi y) (\beta=0.3)$ 。由图4可以看出, 选取不同的

表3 取不同储备池规模 N 时两种算法的MSE值(dB)

算法	$N=20$	$N=50$	$N=100$	$N=200$	$N=300$
ESN-RLS-CMA	-22.56	-28.12	-29.06	-28.41	-28.72
ESN-RLS-MMA	-18.12	-29.58	-30.62	-29.10	-29.29

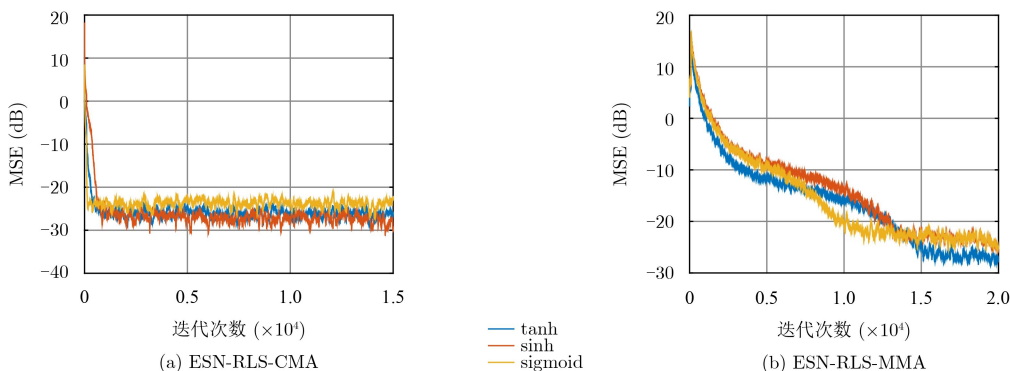


图3 不同激活函数 $f(\cdot)$ 对两种算法性能的影响

$f_{out}(\cdot)$, ESN-RLS-CMA的收敛速度大致是相同的, 均在大约1000次迭代后收敛, 但选择非线性 $f_{out}(\cdot)$ 时算法的MSE值可达到-30 dB, 比选择线性 $f_{out}(\cdot)$ 的MSE值降低了大约13 dB。ESN-RLS-MMA存在两次收敛过程, 无论是选择线性 $f_{out}(\cdot)$ 还是非线性 $f_{out}(\cdot)$, 算法均在迭代5000次左右时第1次收敛, 迭代15000次左右时第2次收敛, 收敛后的MSE值分别为-24 dB和-29 dB。

4.2 两种在线盲均衡算法的性能分析

本组实验将本文的两种算法分别在QPSK以及16QAM信号下的均衡性能作对比。实验中设置ESN的 $N=200$, $f(\cdot)$ 为 $\tanh(\cdot)$ 函数, 谱半径 $\rho(\mathbf{W}_{res})=0.9$, 稀疏度 $SD=0.2$, $f_{out}(\cdot)$ 取4.1节的非线性读出函数。

图5(a)是两种算法均衡QPSK信号的MSE随迭代次数的变化曲线, 可以明显看出, 对于常模信号, ESN-RLS-CMA相比于ESN-RLS-MMA有更快的收敛速度, 且收敛后的MSE值稍低。图5(b)是两种算法均衡16QAM信号的MSE随迭代次数的变化曲线, 可以看出, 当算法收敛后, ESN-RLS-MMA的MSE值比ESN-RLS-CMA的MSE值低14 dB左右。实验结果表明, 对于常模信号, ESN-RLS-CMA相较于ESN-RLS-MMA有更好的均衡性能; 而对于多模信号, ESN-RLS-MMA则更加适合。

图6是ESN-RLS-CMA和ESN-RLS-MMA对16QAM信号均衡前后的星座图。从图6(b)和图6(c)




图6 两种算法对16QAM信号均衡前后的星座图




图4 网络读出层函数 $f_{out}(\cdot)$ 对两种算法性能的影响

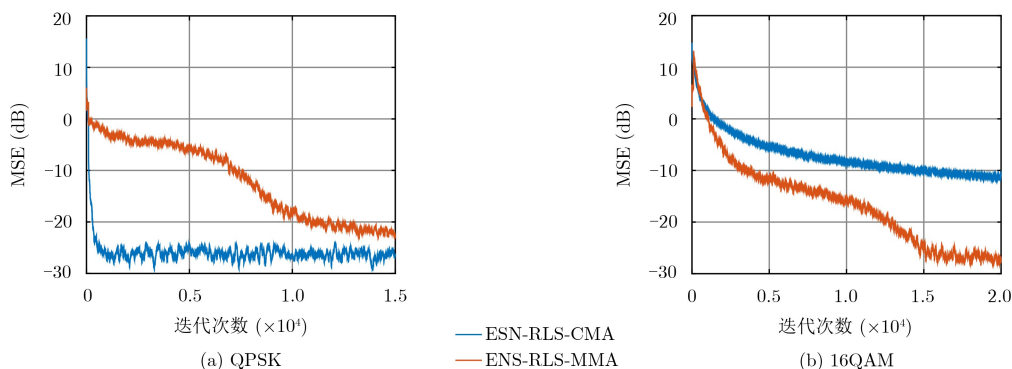


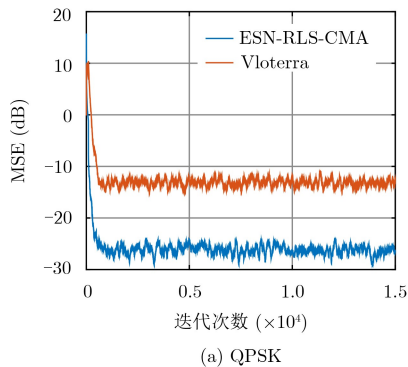
图5 QPSK和16QAM信号下的两种算法的MSE性能比较

可以看出,对于多模信号,ESN-RLS-MMA具有更好的均衡性能,相较于ESN-RLS-CMA,其星座图更加紧凑,而且纠正了相位旋转。

4.3 本文算法与Volterra滤波算法的性能对比

本组实验将本文的两种算法与传统的Volterra滤波算法^[5]的性能作对比。本文算法设置ESN储备池规模 $N=50$,其它设置与4.2节相同;Volterra滤波算法选择5阶且设置滤波器的记忆深度 $M=9$ 。

图7(a)是ESN-RLS-CMA与5阶Volterra滤波算法均衡QPSK信号的性能对比曲线,可以看出,



ESN-RLS-CMA迭代大约1000次后收敛,收敛后的MSE值可达到-27 dB;Volterra滤波算法收敛同样迭代1000次后收敛,收敛后的MSE值仅为-14 dB。图7(b)是ESN-RLS-MMA与5阶Volterra滤波算法均衡16QAM信号的性能对比曲线,可以看出,当两种算法最终完全收敛时,ESN-RLS-MMA的MSE值相比Volterra滤波算法的MSE值大约降低了14 dB。由此可以看出,本文提出的两种基于ESN的在线盲均衡算法的性能明显优于传统的Volterra滤波算法。




图7 两种在线盲均衡算法与Volterra滤波算法的性能对比

此外,以获得1次输出信号所需乘法次数作为计算量的衡量标准,对本文提出的两种在线算法以及5阶Volterra滤波算法进行运算复杂度分析,结果如表4所示。根据表4,代入实验中具体的 M 和 N 值可算得,本文提出的两种基于ESN的在线盲均衡算法的运算量低于5阶Volterra滤波算法。

表4 本文算法与5阶Volterra滤波算法的运算复杂度对比

算法	运算复杂度
Volterra	$O(24M^6+16M^5+8M)$
ESN-RLS-CMA	$O(4N^3+18N^2+10N)$
ESN-RLS-MMA	$O(4N^3+19N^2+10N)$

5 结论

本文提出了两种基于回声状态网络的卫星信道在线盲均衡算法——ESN-RLS-CMA和ESN-RLS-MMA。利用ESN的非线性逼近能力,将发送信号的高阶统计量代入ESN构造代价函数,以在线迭代寻优的方式对ESN的输出权值进行训练,实现了非线性卫星信道下常模与多模信号的盲均衡。仿真实验表明,本文所提出的在线盲均衡算法相比于传统的Volterra滤波算法,以较小的计算代价获得了更低的MSE水平。

参考文献

- [1] MELONI A and MURRONI M. On the genetic optimization of APSK constellations for satellite broadcasting[C]. 2014 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting, Beijing, China, 2014: 1–6. doi: [10.1109/BMSB.2014.6873465](https://doi.org/10.1109/BMSB.2014.6873465).
- [2] MOUSSA A, POULIQUEN M, FRIKEL M, *et al.* Blind equalisation in the presence of bounded noise[J]. *IET Signal Processing*, 2018, 12(8): 957–965. doi: [10.1049/iet-spr.2017.0445](https://doi.org/10.1049/iet-spr.2017.0445).
- [3] 孙海飞,江桦.非线性卫星信道下的粒子滤波盲均衡方法[J].信号处理,2015,31(5):587–593. doi: [10.3969/j.issn.1003-0530.2015.05.011](https://doi.org/10.3969/j.issn.1003-0530.2015.05.011).
SUN Haifei and JIANG Hua. Particle filtering blind equalization method in nonlinear satellite channel[J]. *Journal of Signal Processing*, 2015, 31(5): 587–593. doi: [10.3969/j.issn.1003-0530.2015.05.011](https://doi.org/10.3969/j.issn.1003-0530.2015.05.011).
- [4] SÉNÉCAL S, AMBLARD P O, and CAVAZZANA L. Particle filtering equalization method for a satellite communication channel[J]. *EURASIP Journal on Advances in Signal Processing*, 2004, 2004: 591429. doi: [10.1155/S1110865704404090](https://doi.org/10.1155/S1110865704404090).
- [5] MALONE J and WICKERT M A. Practical volterra equalizers for wideband satellite communications with TWTA nonlinearities[C]. 2011 Digital Signal Processing and

- Signal Processing Education Meeting, Sedona, USA, 2011: 481–53. doi: [10.1109/DSP-SPE.2011.5739185](https://doi.org/10.1109/DSP-SPE.2011.5739185).
- [6] 郭业才, 费赛男, 王惠. 基于多小波双变换的非线性卫星信道盲均衡算法[J]. 电子学报, 2016, 44(10): 2384–2390. doi: [10.3969/j.issn.0372-2112.2016.10.015](https://doi.org/10.3969/j.issn.0372-2112.2016.10.015).
- GUO Yecai, FEI Sainan, and WANG Hui. Nonlinear satellite channel blind equalization algorithm based on multi-wavelet double transformation[J]. *Acta Electronica Sinica*, 2016, 44(10): 2384–2390. doi: [10.3969/j.issn.0372-2112.2016.10.015](https://doi.org/10.3969/j.issn.0372-2112.2016.10.015).
- [7] BENVENUTO N, MARCHESI M, PIAZZA F, *et al.* Non linear satellite radio links equalized using blind neural networks[C]. 1991 International Conference on Acoustics, Speech, and Signal Processing, Toronto, Canada, 1991: 1521–1524. doi: [10.1109/ICASSP.1991.150526](https://doi.org/10.1109/ICASSP.1991.150526).
- [8] LI Yanqin, GUO Chunsheng, ZHANG Zhen, *et al.* A novel feed-forward neural network blind equalization algorithm[C]. 2010 International Conference on Intelligent Control and Information Processing, Dalian, China, 2010: 404–408. doi: [10.1109/ICICIP.2010.5564245](https://doi.org/10.1109/ICICIP.2010.5564245).
- [9] 王贵银. 复数Hopfield神经网络盲均衡QAM信号[J]. 电子测试, 2011(5): 57–60. doi: [10.3969/j.issn.1000-8519.2011.05.014](https://doi.org/10.3969/j.issn.1000-8519.2011.05.014).
- WANG Guiyin. Blind equalization of QAM with a complex Hopfield neural network[J]. *Electronic Test*, 2011(5): 57–60. doi: [10.3969/j.issn.1000-8519.2011.05.014](https://doi.org/10.3969/j.issn.1000-8519.2011.05.014).
- [10] RUAN Xiukai, LI Chang, YANG Weibo, *et al.* Blind sequence detection using reservoir computing[J]. *Digital Signal Processing*, 2017, 62: 81–90. doi: [10.1016/j.dsp.2016.10.012](https://doi.org/10.1016/j.dsp.2016.10.012).
- [11] ZORN S, EHM H J, and WEIGEL R. A novel technique for determining kernels of volterra based behavioral models for RF amplifiers[C]. The 38th European Microwave Conference, Amsterdam, Netherlands, 2008: 246–249. doi: [10.1109/EUMC.2008.4751434](https://doi.org/10.1109/EUMC.2008.4751434).
- [12] 唐成凯, 张玲玲, 廉保旺. 卫星高阶调制信号通信下非线性误差修正均衡方法[J]. 通信学报, 2017, 38(1): 117–125. doi: [10.11959/j.issn.1000-436x.2017014](https://doi.org/10.11959/j.issn.1000-436x.2017014).
- TANG Chengkai, ZHANG Lingling, and LIAN Baowang. Nonlinear error modified equalization algorithm in high-order modulation of satellite communication[J]. *Journal of Communications*, 2017, 38(1): 117–125. doi: [10.11959/j.issn.1000-436x.2017014](https://doi.org/10.11959/j.issn.1000-436x.2017014).
- [13] ZHOU Haowen, HUANG Jinqian, LU Feng, *et al.* Echo state kernel recursive least squares algorithm for machine condition prediction[J]. *Mechanical Systems and Signal Processing*, 2018, 111: 68–86. doi: [10.1016/j.ymsp.2018.03.047](https://doi.org/10.1016/j.ymsp.2018.03.047).
- [14] PARK D J, JUN B E, and KIM J H. Fast tracking RLS algorithm using novel variable forgetting factor with unity zone[J]. *Electronics Letters*, 1991, 27(23): 2150–2151. doi: [10.1049/el:19911331](https://doi.org/10.1049/el:19911331).
- [15] 李进, 冯大政, 刘文娟. 快速QAM信号多模盲均衡算法[J]. 电子与信息学报, 2013, 35(2): 273–279. doi: [10.3724/SP.J.1146.2012.00609](https://doi.org/10.3724/SP.J.1146.2012.00609).
- LI Jin, FENG Dazheng, and LIU Wenjuan. A fast multimodulus blind equalization algorithm for QAM signal[J]. *Journal of Electronics & Information Technology*, 2013, 35(2): 273–279. doi: [10.3724/SP.J.1146.2012.00609](https://doi.org/10.3724/SP.J.1146.2012.00609).
- [16] PAVAN F R M, SILVA M T M, and MIRANDA M D. A numerically robust blind equalization scheme applied to MIMO communication systems[J]. *Journal of the Franklin Institute*, 2018, 355(1): 596–624. doi: [10.1016/j.jfranklin.2017.10.036](https://doi.org/10.1016/j.jfranklin.2017.10.036).
- [17] MBOUP M and REGALIA P A. A gradient search interpretation of the super-exponential algorithm[J]. *IEEE Transactions on Information Theory*, 2000, 46(7): 2731–2734. doi: [10.1109/18.887889](https://doi.org/10.1109/18.887889).
- [18] MIRANDA M D, SILVA M T M, and NASCIMENTO V H. Avoiding divergence in the shalvi-weinstein algorithm[J]. *IEEE Transactions on Signal Processing*, 2008, 56(11): 5403–5413. doi: [10.1109/TSP.2008.928505](https://doi.org/10.1109/TSP.2008.928505).
- 杨 凌: 女, 1966年生, 副教授, 研究方向为盲信号处理和神经网络、支持向量机等。
- 赵 宸: 男, 1994年生, 硕士生, 研究方向为神经网络盲信号处理。
- 陈 亮: 男, 1992年生, 硕士生, 研究方向为支持向量回归盲信号处理。
- 李 媛: 女, 1994年生, 硕士生, 研究方向为卫星信道盲均衡。
- 张国龙: 男, 1985年生, 硕士生, 研究方向为水声信道盲均衡。