

基于自适应扩展卡尔曼滤波与神经网络的 HPA 预失真算法

吴林煌¹ 苏凯雄¹ 郭里婷¹ 吴子静¹

摘 要 针对强记忆功放的非线性问题, 提出一种基于自适应扩展卡尔曼滤波与神经网络的高功放 (High power amplifier, HPA) 预失真算法. 采用实数固定延时神经网络 (Real-valued focused time-delay neural network, RVFTDNN) 对间接学习结构预失真系统中的预失真器和逆估计器进行建模, 扩展卡尔曼滤波 (Extended Kalman filter, EKF) 算法训练神经网络, 从理论上指出 Levenberg-Marquardt (LM) 算法是 EKF 算法的特殊情况, 并用李亚普诺夫稳定性理论分析 EKF 算法的稳定收敛条件, 推导出测量误差矩阵的自适应迭代公式. 结果表明: 自适应 EKF 算法的训练误差和泛化误差均比 LM 算法更低, 预失真后的邻道功率比 (Adjacent channel power ratio, ACPR) 比 LM 算法改善了 2 dB.

关键词 高功率放大器, 预失真, 神经网络, 非线性, 自适应扩展卡尔曼滤波

引用格式 吴林煌, 苏凯雄, 郭里婷, 吴子静. 基于自适应扩展卡尔曼滤波与神经网络的 HPA 预失真算法. 自动化学报, 2016, 42(1): 122–130

DOI 10.16383/j.aas.2016.c150240

HPA Predistortion Algorithm Based on Adaptive Extended Kalman Filter and Neural Network

WU Lin-Huang¹ SU Kai-Xiong¹ GUO Li-Ting¹ WU Zi-Jing¹

Abstract For the nonlinearity of high power amplifier (HPA) with strong memory effects, a novel HPA predistortion algorithm based on adaptive extended Kalman filter and neural network is proposed. In the predistortion system with indirect learning architecture, the predistorter and HPA inverse estimator are modeled with the same real-valued focused time-delay neural network (RVFTDNN), and the extended Kalman filter (EKF) is used to iteratively train and update the coefficients of the neural network. It is concluded that Levenberg-Marquardt (LM) algorithm is a special case of EKF algorithm in theory. The stably convergence condition of EKF training algorithm is analysed with the Lyapunov stability theory and adaptive covariance matrix of measurement noise is derived for iterative computation. Simulation results show that compared with LM algorithm the training error and generalization error of adaptive EKF predistortion algorithm are both less. The adjacent channel power ratio (ACPR) of HPA output signal with adaptive EKF predistortion is better than that of LM predistortion by 2 dB.

Key words High power amplifier (HPA), predistortion, neural network, nonlinearity, adaptive extended Kalman filter

Citation Wu Lin-Huang, Su Kai-Xiong, Guo Li-Ting, Wu Zi-Jing. HPA predistortion algorithm based on adaptive extended Kalman filter and neural network. *Acta Automatica Sinica*, 2016, 42(1): 122–130

宽带射频高功率放大器 (High power amplifier, HPA) 应用于无线发射系统, 是发射机中的关键部件. 高效非均匀包络调制方式的使用, 使得目前的数字电视宽带信号, 比如国标地面数字电视 (Digital television terrestrial multimedia, DTMB), 具有较高峰均功率比 (Peak-to-average power ratio, PAPR), 容易使 HPA 进入饱和区, 产生强记忆效应

和非线性, 造成邻道干扰和带内失真, 从而导致数字电视发射机性能下降. 因此, 必须对 HPA 进行线性化处理.

数字预失真 (Digital predistortion, DPD) 因其可采用数字算法实现精确的非线性拟合并具有可重配置特性, 已在实际应用中普遍采用, 如查找表预失真^[1–3]、多项式预失真^[4–7]、神经网络预失真等^[8–13]. 文献 [13] 对这三类预失真方法进行分析和比较后认为, 实数固定延时神经网络 (Real-valued focused time-delay neural network, RVFTDNN) 的预失真方法总体性能最佳, 其神经网络训练算法采用 Levenberg-Marquardt (LM) 算法^[14]. 根据数值优化技术的特点, 目前神经网络的训练算法大致分成三类: 共轭梯度类算法、近似牛顿类算法以及 LM 算法^[15]. 文献 [15–16] 对比了这三类训练算法

收稿日期 2015-04-22 录用日期 2015-09-14
Manuscript received April 22, 2015; accepted September 14, 2015

国家自然科学基金 (61401099, 61401100) 资助
Supported by National Natural Science Foundation of China (61401099, 61401100)

本文责任编辑 赵千川
Recommended by Associate Editor ZHAO Qian-Chuan

1. 福州大学物理与信息工程学院 福州 350116
1. College of Physics and Information Engineering, Fuzhou University, Fuzhou 350116

后指出, 在神经网络预失真系统应用中, LM 训练算法在收敛速度和误差精度方面性能最好。

然而, 使用 LM 算法对神经网络进行训练存在两个问题: 一是 LM 算法学习率的选择问题. 目前关于该参数的最优选择还缺乏明确的理论支持, 通常是根据工程经验设定, 从而造成神经网络的训练误差精度具有一定的随机性^[17]; 二是 LM 算法容易陷入局域最小化和出现过拟合现象^[18]。

卡尔曼滤波器最早被用于确定性线性系统的估计, 后被改善为扩展卡尔曼滤波器 (Extended Kalman filter, EKF) 以便用于对非线性系统估计, 是工程领域中广泛使用的非线性估计方法^[19-20], 如惯性导航^[21]、目标跟踪^[22] 等. 神经网络理论上可以看成是一个非线性系统, 如果把神经网络的系数当成非线性系统的待估计状态, 则可以用扩展卡尔曼滤波方法对神经网络参数进行估计^[23-25]. 由于扩展卡尔曼滤波方法能够有效地避免陷入局域最小化, 同时可以改善算法的收敛速度^[26], 目前扩展卡尔曼滤波方法已经被成功应用于多个领域的神经网络参数估计, 比如工业时间序列预测^[26]、机械故障检测与分类^[27]、心脏杂音检测^[28] 以及基于超宽带无线通信的个人导航^[29] 等. 这些应用都属于开路系统, 而预失真系统属于闭环系统, 其神经网络输入数据并非按照某种规则固定下来, 而是随着训练过程而不断调整变化, 目前还未发现有相关文献将扩展卡尔曼滤波方法用于功率放大器的神经网络预失真。

鉴于扩展卡尔曼滤波存在的优点以及当前 LM 算法存在的问题, 本文提出一种联合自适应扩展卡尔曼滤波和神经网络的 HPA 预失真算法, 用神经网络对预失真器和 HPA 逆估计器进行建模, 把神经网络的系数向量当作扩展卡尔曼滤波器的状态进行最优化估计, 推导出基于扩展卡尔曼滤波的神经网络预失真训练算法及其自适应收敛条件, 降低误差水平, 并从理论上指出 LM 算法只是扩展卡尔曼滤波训练算法的特殊情况。

1 实数固定延时神经网络模型

有记忆效应的功率放大器的非线性特性可以由下式来描述

$$y(n) = F[u(n), u(n-1), \dots, u(n-M)] \quad (1)$$

其中, $u(n)$ 为 n 时刻的复数基带输入信号, $y(n)$ 为 n 时刻 HPA 输出信号变换到基带的复数信号, M 为 HPA 的记忆深度, F 为 HPA 的非线性响应函数. 由于预失真系统建模及预失真参数提取过程的复数运算具有高复杂度和不稳定性, 故把式 (1) 变换成

实数 I 、 Q 分量的形式。

$$I_{\text{out}}(n) = F_1[I(n), I(n-1), \dots, I(n-M), Q(n), Q(n-1), \dots, Q(n-M)] \quad (2)$$

$$Q_{\text{out}}(n) = F_2[I(n), I(n-1), \dots, I(n-M), Q(n), Q(n-1), \dots, Q(n-M)] \quad (3)$$

其中, $I(n)$ 和 $Q(n)$ 表示基带输入信号 $u(n)$ 的 I 和 Q 分量, $I_{\text{out}}(n)$ 和 $Q_{\text{out}}(n)$ 表示 HPA 基带输出 $y(n)$ 的 I 和 Q 分量, F_1 和 F_2 表示功率放大器对输入 I 、 Q 分量的非线性响应函数。

本文采用文献 [15] 中的 RVFTDNN 作为预失真器和 HPA 逆估计器的非线性模型, 其结构如图 1 所示. 该 RVFTDNN 模型是一个三层前馈神经网络^[30], 包含一个输入层、一个中间隐藏层和一个输出层. 输入层的输入信号为当前时刻的实数 I 、 Q 分量以及经过延时后的以前若干个时刻的实数 I 、 Q 分量, 隐藏层有若干个神经元, 输出层的输出信号为实数 I 、 Q 分量。




图 1 三层实数固定延时神经网络结构

Fig. 1 Real-valued focused time-delay neural network architecture with three layers

网络中的每个神经元节点由线性混合器和激活函数两部分构成. 假设网络中某层的第 j 个节点的输入向量为 $\mathbf{x} = [x_1, x_2, \dots, x_d]$, 则该节点的输出可以表示如下:

$$y_j = f \left(\sum_{i=1}^d w_{j,i} \cdot x_i + b_j \right) \quad (4)$$

其中, y_j 表示第 j 个神经元节点的输出, $w_{j,i}$ 表示第 j 个神经元与前一层中第 i 个神经元的权值系数, 该神经元的第 i 个输入为 x_i , 阈值系数为 b_j , d 为前一层的神元节点个数, f 表示节点神经元的激活函

数. 本文选用双极性 Sigmoid 函数作为隐藏层神经元的激活函数, 线性函数 $x=f(x)$ 作为输出层神经元激活函数^[18].

2 间接学习结构的神经网络预失真系统

要实现 HPA 的预失真, 关键是找出 HPA 非线性特性的逆函数. 根据求解过程的不同, 预失真系统的结构可以分为间接学习结构和直接学习结构^[31]. 由于功放非线性特性未知, 且随时间变化, 而间接结构不需要预先知道 HPA 模型, 计算复杂度较低, 适用于 HPA 模型不断变化的自适应预失真系统. 因此本文采用间接学习结构.

基于 RVFTDNN 模型构建的间接学习结构预失真系统如图 2 所示. 神经网络预失真器和神经网络 HPA 逆估计器均采用 RVFTDNN 模型, 逆估计器每次训练获得的神经网络系数复制给预失真器, 并以预失真器输出的 $I_{out}(n)$ 和 $Q_{out}(n)$ 作为逆估计器输出的期望值, 二者输出的 I 、 Q 分量分别作差, 得到的误差 $e1(n)$ 和 $e2(n)$ 作为神经网络进行下次系数调整的依据, 直到训练误差达到收敛要求.

3 逆估计器的神经网络训练算法

逆估计器的神经网络训练算法的优劣决定了整个预失真系统的性能. 文献 [15–16] 已经充分验证了多种常用训练算法的性能, 均指出 LM 算法在训练精度和收敛速度方面的性能最佳. 从理论上分析, 文献 [32] 也指出 LM 算法属于二阶训练算法, 其性能会比其他一阶训练算法及其改进算法更好. 由于本文预失真系统的结构和神经网络模型分别采用与文献 [15–16] 均相同的间接学习结构和多层感知神经网络, 各种常用训练算法的性能将与文献 [15–16] 一致. 因此本节从理论层面分析 EKF 算法和 LM 算

法的异同, 并推导 EKF 算法的自适应稳定收敛条件. 为了避免重复和冗余, 最后仿真也仅将本文的自适应扩展卡尔曼滤波算法与性能最好的 LM 算法进行比较.

3.1 LM 训练算法

神经网络的目标函数 $V(\mathbf{w})$ 设为均方误差, 即

$$V(\mathbf{w}) = \frac{1}{s_1 \times s_2} \sum_{j_1=1}^{s_1} \sum_{j_2=1}^{s_2} e_{j_1, j_2}^2(\mathbf{w}) = \frac{1}{N} \sum_{j=1}^N e_j^2(\mathbf{w}) \quad (5)$$

其中, $\mathbf{w} = [w_1, w_2, \dots, w_K]^T$ 为神经网络的系数向量 (包括权值系数和阈值系数), $\mathbf{e}(\mathbf{w}) = [e_1, e_2, \dots, e_N]^T$ 为误差向量, 误差向量长度 $N = s_1 \times s_2$, s_1 为每次迭代时用于训练的样本数量, s_2 为输出层节点数量. 采用批处理方式训练神经网络, 避免下一次训练擦除前一次训练获得的部分神经网络记忆.

LM 算法是一种二阶梯度算法, 其系数向量迭代公式^[14] 为

$$\mathbf{w}_{i+1} = \mathbf{w}_i - [J^T(\mathbf{w}_i)J(\mathbf{w}_i) + \mu I]^{-1} J^T(\mathbf{w}_i) \mathbf{e}(\mathbf{w}_i) \quad (6)$$

其中 I 为单位矩阵, μ 为算法学习率, $J(\mathbf{w})$ 为 Jacobian 矩阵, 即训练误差对所有系数的一阶偏导数, $J(\mathbf{w})$ 的表达式为

$$J(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{w})}{\partial w_1} & \frac{\partial e_1(\mathbf{w})}{\partial w_2} & \dots & \frac{\partial e_1(\mathbf{w})}{\partial w_K} \\ \frac{\partial e_2(\mathbf{w})}{\partial w_1} & \frac{\partial e_2(\mathbf{w})}{\partial w_2} & \dots & \frac{\partial e_2(\mathbf{w})}{\partial w_K} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\mathbf{w})}{\partial w_1} & \frac{\partial e_N(\mathbf{w})}{\partial w_2} & \dots & \frac{\partial e_N(\mathbf{w})}{\partial w_K} \end{bmatrix} \quad (7)$$




图 2 间接学习结构的神经网络预失真系统

Fig. 2 Indirect learning architecture of neural network predistortion system

3.2 自适应 EKF 训练算法

3.2.1 标准 EKF 算法

扩展卡尔曼滤波的核心思想是将非线性函数 f 和 h 在滤波值处展开成泰勒级数并略去高阶项, 把非线性系统转化为线性系统.

假设随机离散非线性系统为

$$\begin{aligned} \mathbf{w}(k+1) &= f(\mathbf{w}(k), \mathbf{x}(k)) + \boldsymbol{\varepsilon}(k) \\ \mathbf{y}(k) &= h(\mathbf{w}(k), \mathbf{x}(k)) + \boldsymbol{\eta}(k) \end{aligned} \quad (8)$$

其中, $\mathbf{x}(k)$ 和 $\mathbf{y}(k)$ 为系统输入和输出向量, $\mathbf{w}(k)$ 为待估计系统参数向量, $\boldsymbol{\varepsilon}(k)$ 和 $\boldsymbol{\eta}(k)$ 均为独立的零均值白噪声序列, 其统计特性为

$$\begin{aligned} E[\boldsymbol{\varepsilon}(k)] &= 0, E[\boldsymbol{\varepsilon}(k)\boldsymbol{\varepsilon}^T(k)] = Q(k) \\ E[\boldsymbol{\eta}(k)] &= 0, E[\boldsymbol{\eta}(k)\boldsymbol{\eta}^T(k)] = R(k) \end{aligned} \quad (9)$$

则标准 EKF 方程^[23] 为:

$$\begin{cases} \mathbf{w}^*(k) = f(\mathbf{w}(k), \mathbf{x}(k)) \\ \mathbf{y}(k) = h(\mathbf{w}(k), \mathbf{x}(k)) \\ \mathbf{w}(k+1) = \mathbf{w}^*(k) - K(k)(\mathbf{y}(k) - \mathbf{y}^*(k)) \\ K(k) = P(k)H(k)[R(k) + H^T(k)P(k)H(k)]^{-1} \\ P(k+1) = Q(k) + [I - K(k)H^T(k)]P(k) \end{cases} \quad (10)$$

$\mathbf{y}^*(k)$ 是 $\mathbf{y}(k)$ 的观测值, $K(k)$ 为卡尔曼增益矩阵, $R(k)$ 是测量噪声协方差矩阵, $Q(k)$ 是过程噪声协方差矩阵, $P(k)$ 是 $\mathbf{w}(k)$ 的方差矩阵.

3.2.2 EKF 与神经网络预失真系统的结合及其与 LM 算法的分析比较

本文在标准 EKF 算法基础上, 将其与神经网络预失真系统结合起来, 把逆估计器神经网络系数向量 $\mathbf{w}(k)$ 、输入 $\mathbf{x}(k)$ 和输出 $\mathbf{y}(k)$ 分别作为 EKF 方程的待估计参数向量、输入和输出, 则 EKF 方程中的 f 函数可简化为 $\mathbf{w}^*(k) = \mathbf{w}(k)$, h 函数为神经网络输出与神经网络输入之间的映射, 预失真器的输出作为逆估计器神经网络输出的观测值 $\mathbf{y}^*(k)$, 预失真器神经网络的输入为 $\mathbf{x}(k)$. 最终推导出逆估计器神经网络的 EKF 训练算法如下:

$$\begin{cases} \mathbf{y}(k) = h(\mathbf{w}(k), \mathbf{x}(k)) \\ \mathbf{y}^*(k) = h(\mathbf{w}(k), \mathbf{x}(k)) \\ K(k) = P(k)H(k)[R(k) + H^T(k)P(k)H(k)]^{-1} \\ \mathbf{w}(k+1) = \mathbf{w}(k) - K(k)(\mathbf{y}(k) - \mathbf{y}^*(k)) \\ P(k+1) = Q(k) + [I - K(k)H^T(k)]P(k) \end{cases} \quad (11)$$

其中, $H(k)$ 为式 (7) 中 $J(\mathbf{w})$ 的转置矩阵. 把式 (11) 中的 $K(k)$ 代入系数向量更新公式可得

$$\begin{aligned} \mathbf{w}(k+1) &= \mathbf{w}(k) - \\ &P(k)H(k)[R(k) + H^T(k)P(k)H(k)]^{-1} \times \\ &(\mathbf{y}(k) - \mathbf{y}^*(k)) = \mathbf{w}(k) - \\ &P(k)H(k)[R(k) + H^T(k)P(k)H(k)]^{-1} \mathbf{e}(\mathbf{w}(k)) \end{aligned} \quad (12)$$

假设 $P(k) = I$ 、 $R(k) = r(k)I$, 且 $r(k)$ 为常数, 则式 (12) 变换为

$$\begin{aligned} \mathbf{w}(k+1) &= \mathbf{w}(k) - H(k)[r(k)I + \\ &H^T(k)H(k)]^{-1} \mathbf{e}(\mathbf{w}(k)) \end{aligned} \quad (13)$$

由于 $H^T(k) = J(\mathbf{w}(k))$, 所以式 (13) 和式 (6) 一致, 由此可以看出 LM 算法只是 EKF 算法的特殊情况, 此时 EKF 算法受到一定的约束, 测量噪声协方差矩阵 $R(k)$ 和系数向量方差矩阵 $P(k)$ 无法根据训练过程的变化情况自适应更新, 对神经网络系数向量的估计能力有限.

3.2.3 自适应 EKF 训练算法稳定收敛条件推导

测量噪声协方差矩阵 R 描述了预失真系统的神经网络模型误差统计特性, 该信息在训练过程中无法得到. 标准 EKF 算法是根据先验信息对矩阵 R 取确定值, 并保持不变, 然而训练误差不断变化, 若矩阵 R 不随之改变, 则 EKF 算法将与 LM 算法采用固定学习率类似, 训练误差很难进一步改善, 并可能导致滤波发散, 即与 LM 算法类似的过拟合现象. 本文采用李亚普诺夫稳定性理论分析 EKF 算法稳定收敛条件, 对矩阵 R 进行自适应调整, 保证滤波稳定收敛和较低的训练误差.

把逆估计器神经网络的 n 维输出 $\mathbf{y}(k)$ 在最优系数向量 $\mathbf{w}^*$ 处按泰勒级数展开:

$$\begin{aligned} \mathbf{y}(k) &= h(\mathbf{w}^*) + \frac{\partial h}{\partial \mathbf{w}}(\mathbf{w}(k) - \mathbf{w}^*) + \boldsymbol{\xi}(k) = \\ &\mathbf{y}^*(k) + H^T(k)\mathbf{w}_e(k) + \boldsymbol{\xi}(k) \end{aligned} \quad (14)$$

$\mathbf{w}_e(k) = \mathbf{w}(k) - \mathbf{w}^*$ 表示当前时刻网络系数向量与最优系数向量 $\mathbf{w}^*$ 的差, $\boldsymbol{\xi}(k)$ 表示一阶近似留数. 根据式 (14), 则输出估计误差可以用以下公式表示

$$\mathbf{e}(k) = \mathbf{y}(k) - \mathbf{y}^*(k) = H^T(k)\mathbf{w}_e(k) + \boldsymbol{\xi}(k) \quad (15)$$

每次测量的噪声一般具有相似的统计特性, 因此假设 $R(k) = r(k)I$ 是一个正定对角矩阵, 选择的李亚普诺夫函数^[24] 为

$$V(k) = \mathbf{w}_e^T(k)P(k)\mathbf{w}_e(k) \quad (16)$$

根据李亚普诺夫稳定性定理, 只要满足

$$\Delta V(k) = V(k+1) - V(k) < 0 \quad (17)$$

则输出估计误差将稳定收敛, 这也是推导自适应矩阵 $R(k)$ 的充分条件.

根据式 (11)、式 (15) ~ (17) 以及矩阵理论和不等式性质可以推导出 $\Delta V(k)$ 关于误差、 R 和一阶近似留数的表达式^[25]:

$$\Delta V(k) < \frac{1}{\frac{1}{n}h(k) + r(k)} \|e(k)\|^2 + \frac{3}{r(k)} \|\xi(k)\|^2 \quad (18)$$

其中, n 是每次批处理时逆估计器神经网络的输出维数, $h(k)$ 为矩阵 $H^T(k)P(k)H(k)$ 的秩, $\|e(k)\|^2 = e^T(k)e(k)$. 当式 (18) 右边的式子小于零时, $\Delta V(k)$ 也满足小于零的稳定条件, 则 EKF 训练算法稳定收敛时关于 $r(k)$ 的条件如下:

$$r(k) > \frac{\frac{3h(k)}{n} \|\xi(k)\|^2}{\|e(k)\|^2 - 3\|\xi(k)\|^2} \quad (19)$$

式 (19) 中的 $h(k)$, $e(k)$ 和 n 均可以根据当前时刻的信息计算获得, 而一阶近似留数 $\xi(k)$ 无法精确计算. 假设 $\|\xi(k)\|$ 的上边界为 $\tilde{\xi}(k)$, 即 $\tilde{\xi}(k) \geq \|\xi(k)\|$, 由于 $\xi(k)$ 是 $e(k)$ 的近似一阶留数, 根据 EKF 算法, $\xi(k)$ 服从归一化分布 $N([0]_{n \times 1}, r(k)I_{n \times n})$, $\|\xi(k)\|$ 的上边界 $\tilde{\xi}(k)$ 可以近似表示为 $4\sqrt{r(k)}$ ^[25]. 当 $\|e(k)\|^2 > 3\|\tilde{\xi}(k)\|^2$, 则式 (19) 可以变换成:

$$r(k) > \frac{\frac{3h(k)}{n}}{\frac{\|e(k)\|^2}{\|\xi(k)\|^2} - 3} > \frac{\frac{3h(k)}{n}}{\frac{\|e(k)\|^2}{\|\tilde{\xi}(k)\|^2} - 3} \quad (20)$$

根据 $e(k)$ 与 $\tilde{\xi}(k)$ 之间的关系分三种情况进行讨论, 以确定不同情况下 $r(k)$ 如何更新.

1) 当 $\|e(k)\|^2 < 3\|\tilde{\xi}(k)\|^2$ 时, 式 (19) 右边的式子恒为负数, 由于 $r(k)$ 恒为正值, 此时, 保持原来的 $r(k)$ 值不变就可以保证 $\Delta V(k)$ 小于零.

2) 当 $3\|\tilde{\xi}(k)\|^2 \leq \|e(k)\|^2 \leq 4\|\tilde{\xi}(k)\|^2$ 时, $\|e(k)\|^2$ 有界且很小, 可以近似表示为

$$3 \times 16r(k) \leq \|e(k)\|^2 \leq 4 \times 16r(k) \quad (21)$$

只需把 $r(k)$ 变成原来的 $3/4$, 则情况 2) 转化为情况 1), 因此情况 2) 的 $r(k)$ 更新公式如下:

$$r'(k) = \frac{3}{4}r(k), \quad 48r(k) \leq \|e(k)\|^2 \leq 64r(k) \quad (22)$$

3) 当 $\|e(k)\|^2 > 4\|\tilde{\xi}(k)\|^2$ 时,

$$\|e(k)\|^2 > 4\|\tilde{\xi}(k)\|^2 = 64r(k) \times n > 4\|\xi(k)\|^2 \quad (23)$$

把 $\|e(k)\|^2$ 用 $4\|\tilde{\xi}(k)\|^2$ 代入式 (20), 可得

$$r(k) > \frac{3h(k)}{n} \quad (24)$$

联立式 (23) 和式 (24) 可得

$$\frac{3h(k)}{n} < r(k) < \frac{\|e(k)\|^2}{64n} \quad (25)$$

只要 $r(k)$ 满足式 (25) 则 EKF 训练算法将保证稳定收敛, 但式 (25) 还要求 $\frac{3h(k)}{n} < \frac{\|e(k)\|^2}{64n}$ 才能成立, 即 $\|e(k)\|^2 > 192h(k)$. 为了在保持稳定收敛的同时, 降低误差水平, 应该使 $r(k)$ 的值尽可能小, 即让 $r(k)$ 取值靠近其允许范围的左边界, 本文对 $r(k)$ 下一轮迭代的取值如下:

$$r'(k) = \frac{0.9 \times \frac{3h(k)}{n} + 0.1 \times \frac{\|e(k)\|^2}{64n}}{2} \quad (26)$$


4 仿真结果及分析

功放预失真系统采用图 2 所示的间接学习结构, 采用 Saleh 模型作为带记忆功放模型, 参数选择 $\alpha_a = 3$ 、 $\beta_a = 2$ 、 $\alpha_p = 4$ 、 $\beta_p = 9$, 记忆特性由 FIR 滤波器表征, 其系统函数为 $H(Z) = 0.7692 + 0.1538Z^{-1} + 0.076Z^{-2}$, 此时功放具有强非线性^[18]. 输入信号为 DTMB 信号, 抽头延时数为 4, 隐藏层节点数为 9, 训练算法分别采用 LM 算法和自适应 EKF 算法, 训练样本数据量为 3000 和 1000, 迭代次数均为 2000 次; 用新的样本数据进行泛化测试, 神经网络预失真器和逆估计器的系数分别采用 LM 算法和 EKF 算法训练后获得的优化参数.

LM 算法和自适应 EKF 算法的训练误差和泛化误差的对比见表 1、图 3 ~ 图 5. 从表 1 可以看出, 当样本数为 3000 时, 自适应 EKF 算法的训练误差和泛化误差均比 LM 算法低一个数量级; 当样本数为 1000 时, 自适应 EKF 算法的训练误差约为 LM 算法的 0.5 倍, 泛化误差约为 0.7 倍.


从图 3 可以看出, 样本数为 3000 和 1000 时, 自适应 EKF 算法的收敛速度均比 LM 算法更快, 训练误差更低. 图 4 和图 5 表明, 自适应 EKF 算法的泛化误差均比 LM 算法更低.

图 6 为两种预失真算法的 HPA 输出信号功率谱密度 (Power spectral density, PSD) 曲线图, 其中图 6(b) 是图 6(a) 右边带处的放大图. 由图可见, 未进行预失真处理时, 原始 DTMB 信号经过功放后的邻道功率比 (Adjacent channel power ratio, ACPR) 由 50 dB 降到 22 dB, 说明功放存在很强的非线性. 经过 LM 算法和 EKF 算法优化后的神经



(a) 样本量为 3000 的训练误差

(a) Training errors with 3000 sample data




(b) 样本量为 1000 的训练误差

(b) Training errors with 1000 sample data


图 3 LM 算法和自适应 EKF 算法的训练误差比较

Fig.3 Comparison of training errors using LM algorithm and adaptive EKF algorithm



(a) LM 算法泛化误差

(a) Generalization errors using LM algorithm




(b) 自适应 EKF 算法泛化误差

(b) Generalization errors using adaptive EKF algorithm


图 4 样本量为 3000 时的泛化误差比较

Fig.4 Comparison of generalization errors with 3000 sample data



(a) LM 算法泛化误差

(a) Generalization errors using LM algorithm



(b) 自适应 EKF 算法泛化误差

(b) Generalization errors using adaptive EKF algorithm

图 5 样本量为 1000 时的泛化误差比较

Fig.5 Comparison of generalization errors with 1000 sample data

表 1 LM 算法和自适应 EKF 算法的训练误差和泛化误差比较

Table 1 Comparison of training errors and generalization errors using LM algorithm and adaptive EKF algorithm

	训练误差 (样本数 3 000)	泛化误差 (样本数 3 000)	训练误差 (样本数 1 000)	泛化误差 (样本数 1 000)
LM 算法	7.5877×10^{-7}	1.7229×10^{-6}	4.9250×10^{-6}	9.4585×10^{-6}
自适应 EKF 算法	5.4270×10^{-8}	7.4936×10^{-7}	2.4373×10^{-6}	6.8848×10^{-6}


网络预失真系统均能够很好地对功放进行线性化补偿. EKF 预失真方法的功放输出信号 ACPR 为 49 dB, LM 算法情况下的 ACPR 为 47 dB, 即 EKF 算法比 LM 算法在 ACPR 方面改善了 2 dB.

综上仿真结果表明, EKF 算法的预失真效果比 LM 算法更好.


论推广应用于预失真系统的神经网络训练, 从理论上指出 LM 算法只是扩展卡尔曼滤波训练算法的特殊情况, 并推导了自适应扩展卡尔曼滤波训练算法的稳定收敛条件. 从训练误差、泛化误差和邻道功率比三个方面对自适应 EKF 训练算法和 LM 算法进行比较, 结果表明自适应 EKF 算法的训练误差和泛化误差均比 LM 算法降低一个数量级, 分别达到 5.4270×10^{-8} 和 7.4936×10^{-7} , ACPR 达到 49 dB, 比 LM 算法的 ACPR 改善了 2 dB, 自适应 EKF 训练算法的预失真总体性能比 LM 算法更优.

References

- 1 Liu Y J, Lu B, Cao T, Zhou B H, Zhou J, Liu Y N. On the robustness of look-up table digital predistortion in the presence of loop delay error. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2012, **59**(10): 2432–2442
- 2 Hammi O, Ghannouchi F M, Boumaiza S, Vassilakis B. A data-based nested LUT model for RF power amplifiers exhibiting memory effects. *IEEE Microwave and Wireless Components Letters*, 2007, **17**(10): 712–714
- 3 Muhonen K J, Kavehrad M, Krishnamoorthy R. Look-up table techniques for adaptive digital predistortion: a development and comparison. *IEEE Transactions on Vehicular Technology*, 2000, **49**(5): 1995–2002
- 4 Liu Y J, Zhou J, Chen W H, Zhou B H. A robust augmented complexity-reduced generalized memory polynomial for wideband RF power amplifiers. *IEEE Transactions on Industrial Electronics*, 2014, **61**(5): 2389–2401
- 5 Morgan D R, Ma Z, Kim J, Zierdt M G, Pastalan J. A generalized memory polynomial model for digital predistortion of RF power amplifiers. *IEEE Transactions on Signal Processing*, 2006, **54**(10): 3852–3860
- 6 Moon J, Bumman K. Enhanced Hammerstein behavioral model for broadband wireless transmitters. *IEEE Transactions on Microwave Theory and Techniques*, 2011, **59**(4): 924–933
- 7 Liu Y J, Chen W H, Zhou J, Zhou B H, Ghannouchi F M. Digital predistortion for concurrent dual-band transmitters using 2-D modified memory polynomials. *IEEE Transactions on Microwave Theory and Techniques*, 2013, **61**(1): 281–290
- 8 Ibnkahla M, Sombrin J, Castanie F, Bershad N J. Neural networks for modeling nonlinear memoryless communication channels. *IEEE Transactions on Communications*, 1997, **45**(7): 768–771



(a) LM 与 EKF 预失真后的信号功率谱密度
(a) Signal power spectrum density with LM and EKF predistortion



(b) 图 (a) 右边带的放大图
(b) Amplification of right side-band in (a)


图 6 LM 和 EKF 预失真后的信号功率谱密度图比较

Fig. 6 Comparison of signal power spectrum density with LM and EKF predistortion

5 结论

针对强记忆 HPA 存在的非线性问题以及现有神经网络预失真算法的缺陷, 把扩展卡尔曼滤波理

- 9 Liu T J, Boumaiza S, Ghannouchi F M. Dynamic behavioral modeling of 3G power amplifiers using real-valued time-delay neural networks. *IEEE Transactions on Microwave Theory and Techniques*, 2004, **52**(3): 1025–1033
- 10 Zhai Jian-Feng, Zhou Jian-Yi, Hong Wei, Zhang Lei. Real-valued time-delay neuro-fuzzy model for power amplifier with memory effects. *Journal of Microwaves*, 2009, **25**(5): 41–44
(瞿建峰, 周健义, 洪伟, 张雷. 有记忆效应的功放实数延时模糊神经网络模型. 微波学报, 2009, **25**(5): 41–44)
- 11 Mkaem F, Boumaiza S. Physically inspired neural network model for RF power amplifier behavioral modeling and digital predistortion. *IEEE Transactions on Microwave Theory and Techniques*, 2011, **59**(4): 913–923
- 12 Chen S, Hong X, Gong Y, Harris C J. Digital predistorter design using B-spline neural network and inverse of De Boor algorithm. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 2013, **60**(6): 1584–1594
- 13 Rawat M, Ghannouchi F M. Distributed spatiotemporal neural network for nonlinear dynamic transmitter modeling and adaptive digital predistortion. *IEEE Transactions on Instrumentation and Measurement*, 2012, **61**(3): 595–608
- 14 Hagan M T, Menhaj M B. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 1994, **5**(6): 989–993
- 15 Rawat M, Rawat K, Ghannouchi F M. Adaptive digital predistortion of wireless power amplifiers/transmitters using dynamic real-valued focused time-delay line neural networks. *IEEE Transactions on Microwave Theory and Techniques*, 2010, **58**(1): 95–104
- 16 Zayani R, Bouallegue R, Roviras D. Levenberg-Marquardt learning neural network for adaptive predistortion for time-varying HPA with memory in OFDM systems. In: *Proceedings of the 16th European Signal Processing Conference*. Lausanne, Switzerland: IEEE, 2008. 1–5
- 17 Zhang R, Xu Z B, Huang G B, Wang D H. Global convergence of online BP training with dynamic learning rate. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, **23**(2): 330–341
- 18 Huang Chun-Hui, Wen Yong-Jie. Algorithm study of digital HPA predistortion using one novel memory type BP neural network. *Journal on Communications*, 2014, **35**(1): 16–23
(黄春晖, 温永杰. 用记忆型 BP 神经网络实现 HPA 预失真的算法研究. 通信学报, 2014, **35**(1): 16–23)
- 19 Zhao Guang-Qiong, Chen Shao-Gang, Fu Kui, Tang Zhong-Liang, He Wei. A particle filter algorithm based on scaled UKF with reduced sigma points. *Acta Automatica Sinica*, 2015, **41**(7): 1350–1355
(赵光琼, 陈绍刚, 付奎, 唐忠樑, 贺威. 基于变尺度变换减少 Sigma 点的粒子滤波算法研究. 自动化学报, 2015, **41**(7): 1350–1355)
- 20 Bonnabel S, Slotine J J. A contraction theory-based analysis of the stability of the deterministic extended Kalman filter. *IEEE Transactions on Automatic Control*, 2015, **60**(2): 565–569
- 21 Wang B, Ren Q, Deng Z H, Fu M Y. A self-calibration method for nonorthogonal angles between gimbals of rotational inertial navigation system. *IEEE Transactions on Industrial Electronics*, 2015, **62**(4): 2353–2362
- 22 Zhao Xin, Wang Shi-Cheng, Liao Shou-Yi, Ma Long, Liu Zhi-Guo. An ultra-tightly coupled tracking method based on robust adaptive cubature Kalman filter. *Acta Automatica Sinica*, 2014, **40**(11): 2530–2540
(赵欣, 王仕成, 廖守亿, 马龙, 刘志国. 基于抗差自适应容积卡尔曼滤波的超紧耦合跟踪方法. 自动化学报, 2014, **40**(11): 2530–2540)
- 23 Choi J, de C Lima A C, Simon H. Kalman filter-trained recurrent neural equalizers for time-varying channels. *IEEE Transactions on Communications*, 2005, **53**(3): 472–480
- 24 de Jesús Rubio J, Yu W. Nonlinear system identification with recurrent neural networks and dead-zone Kalman filter algorithm. *Neurocomputing*, 2007, **70**(13–15): 2460–2466
- 25 Wang X Y, Huang Y. Convergence study in extended Kalman filter-based training of recurrent neural networks. *IEEE Transactions on Neural Networks*, 2011, **22**(4): 588–600
- 26 Jun Z, Zhu X L, Wang W, Liu Y. Extended Kalman filter-based Elman networks for industrial time series prediction with GPU acceleration. *Neurocomputing*, 2013, **118**: 215–224
- 27 Ahmed R, Sayed M E, Gadsden S A, Tjong J, Habibi S. Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques. *IEEE Transactions on Vehicular Technology*, 2015, **64**(1): 21–33
- 28 Guillemoa J E, Castellanos L J R, Sanchez E N, Alanis A Y. Detection of heart murmurs based on radial wavelet neural network with Kalman learning. *Neurocomputing*, 2015, **164**: 307–317
- 29 Feng X X, Snoussi H, Liang Y. Constrained extended Kalman filter for ultra-wideband radio based individual navigation. In: *Proceedings of the 17th International Conference on Information Fusion*. Salamanca, Spain: IEEE, 2014. 1–7
- 30 Yin Li-Sheng, He Yi-Gang, Dong Xue-Ping, Lu Zhao-Quan. Research on the multi-step prediction of Volterra neural network for traffic flow. *Acta Automatica Sinica*, 2014, **40**(9): 2066–2072
(殷礼胜, 何怡刚, 董学平, 鲁照权. 交通流量 VNNTF 神经网络模型多步预测研究. 自动化学报, 2014, **40**(9): 2066–2072)
- 31 Qian Ye-Qing. High-efficient adaptive predistortion structure for RF power amplifier linearization. *Journal on Communications*, 2006, **27**(5): 35–40, 46–46
(钱业青. 一种高效的用于 RF 功率放大器线性化的自适应预失真结构. 通信学报, 2006, **27**(5): 35–40, 46–46)
- 32 Hunter D, Yu H, Pukish M S, Kolbusz J, Wilamowski B M. Selection of proper neural network sizes and architectures—a comparative study. *IEEE Transactions on Industrial Informatics*, 2012, **8**(2): 228–240



吴林煌 福州大学物理与信息工程学院助理研究员, 博士研究生. 2009 年获得福州大学物理与信息工程学院硕士学位. 主要研究方向为数字预失真与神经网络优化. 本文通信作者.

E-mail: wlh173@163.com

(**WU Lin-Huang** Assistant researcher and Ph.D. candidate at the


College of Physics and Information Engineering, Fuzhou University. He received his master degree from Fuzhou University in 2009. His research interest covers digital predistortion and neural network optimization. Corresponding author of this paper.)



苏凯雄 福州大学物理与信息工程学院教授. 1988 年获得中国科学技术大学通信与电子系统专业硕士学位. 主要研究方向为微波通信与图像处理.

E-mail: skx@fzu.edu.cn

(**SU Kai-Xiong** Professor at the College of Physics and Information Engineering, Fuzhou University. He received his master degree from University of Science and Technology of China in 1988. His research interest covers microwave communication and image processing.)



郭里婷 福州大学物理与信息工程学院副教授. 2006 年获得中国科学技术大学通信与信息系统专业博士学位. 主要研究方向为数字基带信号的信道编码与调制.

E-mail: guoliting@fzu.edu.cn

(**GUO Li-Ting** Associate professor at the College of Physics and Information Engineering, Fuzhou University. She received her Ph.D. degree from University of Science and Technology of China in 2006. Her research interest covers channel coding and modulation of digital baseband signal.)



吴子静 福州大学物理与信息工程学院博士研究生. 2010 年获得福州大学物理与信息工程学院学士学位. 主要研究方向为 LDPC 编解码.

E-mail: wuzj87@163.com

(**WU Zi-Jing** Ph.D. candidate at the College of Physics and Information Engineering, Fuzhou University. She received her bachelor degree from Fuzhou University in 2010. Her research interest covers LDPC coding and decoding.)