

正交匹配追踪和 BIC 准则的 自适应双频段预失真模型优化算法

吴林煌¹, 苏凯雄¹, 王 琳², 陈志峰¹, 陈平平¹

(1. 福州大学物理与信息工程学院, 福建福州 350116; 2. 厦门大学信息科学与技术学院, 福建厦门 361005)

摘 要: 针对双频段预失真模型复杂度高以及当前的模型优化算法不具有自适应性的问题, 提出一种自适应的模型优化算法. 采用双频段广义记忆多项式作为预失真模型, 通过正交匹配追踪算法对原始模型的基函数项进行排序, 每次迭代时用所有已挑选的基函数项构成备选模型, 推导了模型输出向量元素服从非独立同分布情况下的贝叶斯信息准则 (Bayesian Information Criterion, BIC), 并将 BIC 值最小的备选模型作为优化后模型, 从而在原始模型稀疏度和拟合误差门限未知情况下, 实现了模型的自适应优化. 结果表明: 优化后模型与原始模型相比, 二者分别预失真后的信号在邻道功率比和归一化均方误差方面均非常接近, 预失真效果良好, 而模型的系数数量减少了 75% 以上.

关键词: 功率放大器; 预失真; 稀疏性; 正交匹配追踪; 贝叶斯信息准则

中图分类号: TN911.72 **文献标识码:** A **文章编号:** 0372-2112 (2018)09-2149-08

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.09.015

Adaptive Dual-band Predistortion Model Optimization Algorithm Based on Orthogonal Matching Pursuit and Bayesian Information Criterion

WU Lin-huang¹, SU Kai-xiong¹, WANG Lin², CHEN Zhi-feng¹, CHEN Ping-ping¹

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou, Fujian 350116, China;

2. College of Information Science and Technology, Xiamen University, Xiamen, Fujian 361005, China)

Abstract: The dual-band predistortion models suffer from high complexity and non-adaptability of optimization algorithms. To address this issue, this paper proposes an adaptive optimization algorithm for dual-band predistortion model with reduced complexity. We use dual-band general memory polynomial (DB-GMP) as the predistortion model where all basis function terms of the original DB-GMP model are sorted by orthogonal matching pursuit algorithm. In each iteration, all selected basis function terms help to construct an alternative model. We then derive the Bayesian information criterion (BIC) when output vector elements of the DB-GMP model are with non-independent identical distributions, and the model with smallest BIC value is treated as the optimized model. Finally, we achieve the proposed algorithm without the information of model sparsity and fitting error threshold. Simulation results show that compared with the original DB-GMP model, the coefficient number of the optimized model is reduced by more than 75%, while both the models after predistortion have almost the same level of adjacent channel power ratio and normalized mean squared error, leading to good predistortion performance.

Key words: power amplifier; predistortion; sparsity; orthogonal matching pursuit; Bayesian information criterion

1 引言

当前无线通信网络同时存在多种不同的标准, 比如 2G、3G 和 4G 网络, 未来 5G 网络也将融入现有的网络. 不同网络的信号使用不同的频段, 按照传统方法, 不

同频段的信号需要不同的发射模块, 包括不同的射频功率放大器 (Power Amplifier, PA), 这造成基站体积大、能耗和成本高等问题. 为了克服这些问题, 研究人员提出了并发多频段发射机方案^[1], 只用一个 PA 对多个频段的信号同时进行功率放大. 然而, PA 本身存在非线性

特性^[2],当多个频段信号同时加载在一个 PA 上时,PA 不仅存在与单频段信号驱动情况下类似的带内互调失真和带外互调失真,还存在交叉频带互调失真,非线性特性更加复杂,必须采用有效的线性化方法来保证 PA 的线性度^[3].

数字预失真(Digital Predistortion,DPD)技术是单频段 PA 线性化的主流方法^[4],而多频段 DPD 技术还未成熟.单频段 DPD 技术与双频段 DPD 技术之间存在较大的不同,而双频段 DPD 技术可简便的拓展到更多频段的 DPD 技术,本文仅针对双频段 DPD 技术进行研究.目前已有多种双频段预失真模型被用于双频段 PA 线性化,比如二维复数记忆多项式模型^[3],双频段广义记忆多项式模型^[5]、二维修正的记忆多项式模型^[6]等.与单频段预失真模型相比,双频段预失真模型复杂度更高,严重阻碍了其实际应用.

文献[7,8]指出 Volterra 级数类预失真模型存在稀疏性.因此,预失真模型优化问题可以看成是一个稀疏信号重构问题.目前已有的一些稀疏信号重构技术被用于优化预失真模型,比如 LASSO 技术^[9]、主成分分析技术^[10]以及压缩感知方法^[11,12].其中,压缩感知方法已经被证明了具有更高的计算效率和精度,比如正交匹配追踪(Orthogonal Matching Pursuit,OMP)算法^[13].目前预失真模型优化的研究主要是针对单频段 Volterra 级数类型^[9-12],文献[7,8]提出把压缩感知方法用于双频段 Volterra 级数预失真模型优化,但其主要缺陷在于需要事先知道模型稀疏度或拟合误差门限才能实现.在实际的预失真系统中,预失真模型稀疏度是未知的,拟合误差门限处于什么水平才能保证预失真性能也是未知的,所以当前的双频段预失真模型优化方法不具有自适应性,无法在实际中应用.

贝叶斯信息准则(Bayesian Information Criterion,BIC)也称为 Schwarz 准则^[14-16],用于从有限备选模型中选出具有最大后验概率的模型,其不需要知道模型稀疏度或拟合误差门限,在实际中广泛应用,比如基因调控网络的自适应建模^[17]、无线信道建模^[18]以及模型阶数选择^[19]等.在这些应用中,BIC 准则的备选模型输出向量元素的概率分布都是假设独立同分布.

鉴于压缩感知和 BIC 准则的优点,以及当前双频段预失真模型优化存在的问题,本文将 BIC 准则融入 OMP 算法中,提出一种基于 OMP 和 BIC 准则的双频段预失真模型优化算法.为了满足双频段预失真模型输出向量元素非独立同分布的条件,本文还从理论上推导了非独立同分布情况下的 BIC 准则.

2 双频段数字预失真系统

DPD 的基本原理是:先用预失真器对系统输入信

号进行预失真,使得预失真后的信号经过 PA 之后与原始系统输入信号之间呈现线性关系.本文的双频段 DPD 系统采用文献[3]所提出的二维 DPD(2D-DPD)结构,其特点是每个频段的信号独立进行失真补偿,各个通道中数模转换器和模数转换器的采样率只受各自频段信号带宽的影响.

2D-DPD 结构是一种间接学习结构,如图 1 所示.输入信号 $u_1(n)$ 和 $u_2(n)$ 先经过双频段预失真器处理分别被转换成 PA 等效基带输入信号 $x_1(n)$ 和 $x_2(n)$,再各自通过数模转换和正交上变频变成射频信号,并用功率组合器合成一个信号输入给 PA,PA 输出信号分两路进行正交下变频和模数转换获得 PA 等效基带输出信号 $y_1(n)$ 和 $y_2(n)$.根据 $x_1(n)$ 、 $x_2(n)$ 和 $y_1(n)$ 、 $y_2(n)$,采用估计算法对双频段 PA 逆估计器进行辨识,再把辨识后的参数复制给双频段预失真器.PA 逆估计器和双频段预失真器内部结构相同,均由两个 DPD 处理模块组成,如图 2 所示.DPD1 和 DPD2 分别实现对频段 1 和频段 2 信号的预失真处理.

3 双频段预失真模型及其辨识

在数学上,DPD1 和 DPD2 可以分别用非线性函数 $h_1(\cdot)$ 和 $h_2(\cdot)$ 来描述,如式(1)、式(2)所示.其中, \mathbf{c}_1 和 \mathbf{c}_2 分别是模型 DPD1 和 DPD2 的系数向量, $e_1(n)$ 和 $e_2(n)$ 表示模型观测误差.

$$x_1(n) = h_1(\mathbf{c}_1, y_1(n), y_2(n)) + e_1(n) \quad (1)$$

$$x_2(n) = h_2(\mathbf{c}_2, y_1(n), y_2(n)) + e_2(n) \quad (2)$$

双频段预失真模型辨识的目标是寻找最优的 \mathbf{c}_1 和 \mathbf{c}_2 ,使得模型的估计值 $\hat{x}_1(n) = h_1(\mathbf{c}_1, y_1(n), y_2(n))$ 、 $\hat{x}_2(n) = h_2(\mathbf{c}_2, y_1(n), y_2(n))$ 与期望值 $x_1(n)$ 、 $x_2(n)$ 的均方误差(Mean Squared Error, MSE)最小, MSE 定义为:

$$E = \left[\sum_{n=1}^N (|x_1(n) - \hat{x}_1(n)|^2 + |x_2(n) - \hat{x}_2(n)|^2) \right] / (2N) \quad (3)$$

其中, N 是采样数据的数量.对于 $h_1(\cdot)$ 和 $h_2(\cdot)$ 的具体形式,本文采用双频段广义记忆多项式(Dual-Band General Memory Polynomial, DB-GMP)模型^[5],该模型是在被广泛使用的单频段 GMP 模型基础上拓展而来的,其能有效的实现对双频段 PA 的非线性补偿.假设 $i \in \{1, 2\}$ 是频段标识, P 是非线性阶数, G 是记忆深度, L 是超前滞后长度, $c_{g,l,p,j}^i$ 是基函数项 $y_i(n-g) |y_i(n-g-l)|^{p-j} |y_{3-i}(n-g-l)|^j$ 对应的系数,则考虑了观测误差的 DB-GMP 模型表达式如下:

$$x_i(n) = \sum_{g=0}^G \sum_{l=-L, p=2, 4, \dots, j=0, 2, \dots}^L \sum_{p=2, 4, \dots}^{P-1} \sum_{j=0, 2, \dots}^p c_{g,l,p,j}^i * y_i(n-g) |y_i(n-g-l)|^{p-j} |y_{3-i}(n-g-l)|^j + e_i(n), \text{ if } p=0, \text{ then } l=0 \quad (4)$$

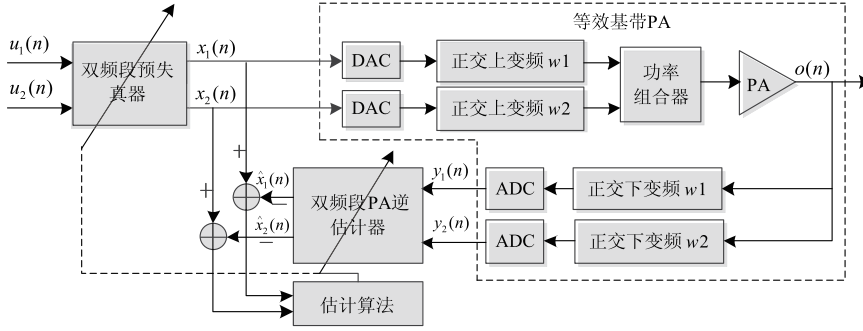


图1 2D-DPD结构




图2 双频段PA逆估计器的内部结构

DB-GMP 模型的系数数量为:

$$S = (G + 1) * [(P + 1) * (P + 3) / 8 + ((P + 1) / 2) * ((P + 3) / 4 - 1) * 2 * L] \quad (5)$$

用 $v_{i,s}(n)$ 表示第 i 个频段的 DB-GMP 模型的第 s 个基函数项在时刻 n 的值, $c_{i,s}$ 表示 $c_{g,l,p,j}^i$. 定义 $\mathbf{c}_i = [c_{i,1}, c_{i,2}, \dots, c_{i,S}]^T$, $\mathbf{v}_{i,s} = [v_{i,s}(1), v_{i,s}(2), \dots, v_{i,s}(N)]^T$, 则所有基函数项的列向量就构成一个矩阵 \mathbf{V}_i , 如式(6)所示. 此时, 式(4)可拓展成如式(7)所示的矩阵形式, $\mathbf{x}_i = [x_i(1), x_i(2), \dots, x_i(N)]^T$, $\mathbf{e}_i = [e_i(1), e_i(2), \dots, e_i(N)]^T$.

$$\mathbf{V}_i = [\mathbf{v}_{i,1}, \mathbf{v}_{i,2}, \dots, \mathbf{v}_{i,S}] = \begin{bmatrix} v_{i,1}(1) & v_{i,2}(1) & \dots & v_{i,S}(1) \\ v_{i,1}(2) & v_{i,2}(2) & \dots & v_{i,S}(2) \\ \vdots & \vdots & \ddots & \vdots \\ v_{i,1}(N) & v_{i,2}(N) & \dots & v_{i,S}(N) \end{bmatrix} \quad (6)$$

$$\mathbf{x}_i = \mathbf{V}_i \mathbf{c}_i + \mathbf{e}_i, i \in \{1, 2\} \quad (7)$$

DPD1 和 DPD2 的输入均同时包含两个频段信号, 如果每个频段的模型系数向量都独立进行辨识, 则 MSE 在迭代过程中将会不断的波动, 导致无法收敛. 所以, 本文将式(7)表示的两个方程合并为一个方程:

$$\mathbf{x} = \mathbf{V}\mathbf{c} + \mathbf{e} \quad (8)$$

其中, $\mathbf{x} = [\mathbf{x}_1; \mathbf{x}_2]$, $\mathbf{V} = \begin{bmatrix} \mathbf{V}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_2 \end{bmatrix}$, $\mathbf{c} = [\mathbf{c}_1; \mathbf{c}_2]$, $\mathbf{e} = [\mathbf{e}_1; \mathbf{e}_2]$, \mathbf{x} 的长度为 $2N$, \mathbf{c} 的长度为 $2S$. 此时双频段预失真模型的辨识问题可以用式(9)来描述, 并简便的用品式(10)的最小二乘法求解. 其中, \mathbf{H} 表示共轭转置.

$$\hat{\mathbf{c}} = \arg \min_{\mathbf{c}} \|\mathbf{x} - \mathbf{V}\mathbf{c}\|^2 \quad (9)$$

$$\hat{\mathbf{c}} = (\mathbf{V}^H \mathbf{V})^{-1} \mathbf{V}^H \mathbf{x} \quad (10)$$

4 自适应双频段预失真模型优化算法

4.1 优化算法的具体流程

从式(5)可知, DB-GMP 模型系数数量 S 随着 P 、 G 和 L 的增大而急剧上升, 导致式(10)中的求逆运算困难, 不稳定性增加. 文献[7]指出 Volterra 级数类模型的基

函数项具有稀疏性, 从压缩感知的角度分析, 寻找有效的基函数项集等价于对 $2S \times 1$ 维的系数向量 \mathbf{c} 进行稀疏重构. 在数学上, 这是一个求 p_0 范数问题, 如式(11)所示. 其中, ϵ 是重构误差门限.

$$\min_{\mathbf{c}} \|\mathbf{c}\|_0, \text{ subject to } \|\mathbf{x} - \mathbf{V}\mathbf{c}\|^2 \leq \epsilon \quad (11)$$

OMP 算法是一种非常有效的贪婪类稀疏重构算法^[13], 其遵循匹配追踪算法中的原子选择准则, 并对已选择的原子集合进行正交化, 从而获得稀疏重构信号. 但 OMP 算法需要已知稀疏度或重构误差作为迭代截止条件. BIC 准则可以在模型稀疏度和误差门限未知的情况下, 从有限备选模型 $H_s (s \in \{1, 2, \dots, 2S\})$ 中选择出具有最大后验概率的模型, 其使用估计概率 $\hat{p}(H_s | \mathbf{x})$ 来近似后验概率 $p(H_s | \mathbf{x})$ ^[16]. 假设所有备选模型等概率, 则最大化 $\hat{p}(H_s | \mathbf{x})$ 等价于最小化 BIC(s) 值, 最优模型的序号 s_* 可确定为:

$$s_* = \arg \max_s \hat{p}(H_s | \mathbf{x}) = \arg \max_s e^{-(1/2)\text{BIC}(s)} = \arg \min_s \text{BIC}(s) \quad (12)$$

BIC(s) 的定义^[16]如下:

$$\text{BIC}(s) = -2 \ln p(\mathbf{x} | \hat{\mathbf{c}}, H_s) + N_s \ln(N_p) \quad (13)$$

其中, N_p 表示模型 H_s 输出数据向量的长度, N_s 表示模型 H_s 所包含的基函数项数量. 式(13)是实数形式的 BIC 准则, 复数形式的 BIC 准则为:

$$\text{BIC}(s) = -2 \ln p(\mathbf{x} | \hat{\mathbf{c}}, H_s) + (2 * N_s + 1) \ln(2 * N_p) \quad (14)$$

本文将 BIC 准则融入 OMP 算法, 在使用 OMP 算法时将不再考虑模型的稀疏度及重构误差, 仅将 OMP 算法用于模型 $2S$ 个基函数项的排序, 提出一种基于 OMP 和 BIC 准则的自适应双频段预失真模型优化算法, 具体流程如下:

步骤 1 输入观测向量 $\mathbf{x} = [\mathbf{x}_1; \mathbf{x}_2]$, 根据 DB-GMP 模型的基函数项表达式计算矩阵 \mathbf{V}_1 和 \mathbf{V}_2 , 构造观测矩阵

$\mathbf{V} = \begin{bmatrix} \mathbf{V}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{V}_2 \end{bmatrix}$, 初始化迭代次数 $s = 0$ 、残差 $\mathbf{r}_0 = \mathbf{x}$ 、信号支撑集 $\mathbf{I}_0 = []$ (空集).

步骤 2 更新迭代索引(即备选模型序号) $s = s + 1$.

步骤 3 计算残差 \mathbf{r}_{s-1} 与观测矩阵 \mathbf{V} 每列原子的内积, 将内积最大的那列原子的索引作为候选支撑点, 即 $z_s = \arg \max_z |\mathbf{V}_z^H \mathbf{r}_{s-1}|, z \in \{1, 2, \dots, 2S\}$.

步骤 4 将候选支撑点与前次迭代的信号支撑集合合并在一起组成新的信号支撑集, 即 $\Gamma_s = \Gamma_{s-1} \cup z_s$.

步骤 5 利用信号支撑集构造新的 \mathbf{V} 矩阵(标识为 \mathbf{V}_{Γ_s}), 并估计新模型 H_s 的系数向量 $\hat{\mathbf{c}}_s = (\mathbf{V}_{\Gamma_s}^H \mathbf{V}_{\Gamma_s})^{-1} \mathbf{V}_{\Gamma_s}^H \mathbf{x}$.

步骤 6 更新残差 $\mathbf{r}_s = \mathbf{x} - \mathbf{V}_{\Gamma_s} \hat{\mathbf{c}}_s$, 并计算 $\text{BIC}(s)$ 值.

步骤 7 若 $s = 2S$ 执行步骤 8, 否则跳到步骤 2.

步骤 8 比较 $2S$ 个 $\text{BIC}(s)$ 值, 将 $\text{BIC}(s)$ 值最小的模型 H_s 作为最终优化后的模型.

步骤 9 用最小二乘法求解优化后模型的参数.

4.2 非独立同分布的 BIC 准则

根据式(14)可知, 当 N_p 固定时, 影响 BIC 值的变量只有 N_s 和 $p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s)$. 其中, N_s 等于优化算法的迭代索引 s , 关键是求 $p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s)$. 通常是假设模型 H_s 输出向量 \mathbf{x} 的各个元素相互独立, 并具有相同的概率分布. 然而在本文的双频段 DPD 系统中, DB-GMP 模型输出向量 \mathbf{x} 的各个元素是非独立的, 这导致传统的 BIC 准则并不适合预失真模型的自适应优化, 本文将推导非独立同分布条件下的 BIC 准则.

在模型输出 \mathbf{x} 各个元素非独立的情况下, $p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s)$ 的表达式如下:

$$p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s) = p(x_1) * p(x_2 | x_1) * p(x_3 | x_1, x_2) \cdots * p(x_m | x_1, x_2, \dots, x_{m-1}) * \prod_{n=m+1}^{2N} p(x_n | x_{n-m}, x_{n-m+1}, \dots, x_{n-1}) \quad (15)$$

其中, x_n 表示 \mathbf{x} 的第 n 个元素, m 表示模型 H_s 输出向量元素的相关长度. 定义列向量 $\mathbf{x}_{n-m \rightarrow n-1} = (x_{n-m}, x_{n-m+1}, \dots, x_{n-1})^T$, 并假设式(8)中的误差向量服从均值为 0, 方差为 σ_e^2 的高斯分布, 则此时 \mathbf{x} 中各个元素的概率分布将服从条件高斯分布:

$$p(x_n | \mathbf{x}_{n-m \rightarrow n-1}) = \frac{1}{\sqrt{2\pi}\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}} \exp\left(-\frac{(x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2}{2\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2}\right) \quad (16)$$

其中, $\mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}$ 、 $\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2$ 分别表示 x_n 的条件均值和条件方差.

由于 m 与 $2N$ 相比小很多, 所以可以忽略式(15)中最前面 m 个元素的概率, 同时将 $p(x_n | \mathbf{x}_{n-m \rightarrow n-1})$ 代入式(15)可得:

$$p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s) \approx \prod_{n=m+1}^{2N} \frac{1}{\sqrt{2\pi}\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}} \exp\left(-\frac{(x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2}{2\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2}\right) \quad (17)$$

对式(17)取自然对数可得:

$$\ln p(\mathbf{x} | \hat{\mathbf{c}}_s, H_s) \approx \sum_{n=m+1}^{2N} \ln\left(\frac{1}{\sqrt{2\pi}\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}}\right) - \sum_{n=m+1}^{2N} \frac{(x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2}{2\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2} \quad (18)$$

根据文献[20], 服从条件分布的向量均值和方差的求解公式分别如下:

$$\boldsymbol{\mu}_{a|b} = \boldsymbol{\mu}_a + \boldsymbol{\Sigma}_{a,b} \boldsymbol{\Sigma}_{b,b}^{-1} (b - \boldsymbol{\mu}_b) \quad (19)$$

$$\boldsymbol{\Sigma}_{a|b} = \boldsymbol{\Sigma}_{a,a} - \boldsymbol{\Sigma}_{a,b} \boldsymbol{\Sigma}_{b,b}^{-1} \boldsymbol{\Sigma}_{b,a} \quad (20)$$

其中, $\boldsymbol{\mu}_a$ 和 $\boldsymbol{\mu}_b$ 分别表示向量 \mathbf{a} 和 \mathbf{b} 的均值, $\boldsymbol{\Sigma}_{a,a}$ 和 $\boldsymbol{\Sigma}_{b,b}$ 分别表示 \mathbf{a} 和 \mathbf{b} 的方差, $\boldsymbol{\mu}_{a|b}$ 和 $\boldsymbol{\Sigma}_{a|b}$ 分别表示在已知 \mathbf{b} 情况下 \mathbf{a} 的条件均值和条件方差, $\boldsymbol{\Sigma}_{a,b}$ 表示 \mathbf{a} 与 \mathbf{b} 的协方差, $\boldsymbol{\Sigma}_{b,b}^{-1}$ 表示 $\boldsymbol{\Sigma}_{b,b}$ 的逆矩阵.

定义 $\mathbf{a} = x_n$ 、 $\mathbf{b} = \mathbf{x}_{n-m \rightarrow n-1}$, 由于 \mathbf{x} 中的元素具有相同的边缘概率分布, 因此 $\boldsymbol{\Sigma}_{a,a}$ 、 $\boldsymbol{\Sigma}_{b,b}$ 、 $\boldsymbol{\Sigma}_{a|b}$ 均不随 n 而变化, $\boldsymbol{\mu}_{a|b}$ 是向量 \mathbf{b} 的线性函数, $\boldsymbol{\Sigma}_{a|b} = \sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2$ 是一个与 n 无关的变量^[20], 后续把 $\sigma_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}^2$ 标记为 σ^2 . 根据式(19), 则式(18)中的 $\mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}$ 可推导如下:

$$\mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}} = \mu_{x_n} + \boldsymbol{\Sigma}_{x_n, \mathbf{x}_{n-m \rightarrow n-1}} \boldsymbol{\Sigma}_{\mathbf{x}_{n-m \rightarrow n-1}, \mathbf{x}_{n-m \rightarrow n-1}}^{-1} (x_{n-m \rightarrow n-1} - \boldsymbol{\mu}_{\mathbf{x}_{n-m \rightarrow n-1}}) \quad (21)$$

将式(21)代入 $x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}}$ 可得:

$$x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}} = (-\boldsymbol{\Sigma}_{x_n, \mathbf{x}_{n-m \rightarrow n-1}} \boldsymbol{\Sigma}_{\mathbf{x}_{n-m \rightarrow n-1}, \mathbf{x}_{n-m \rightarrow n-1}}^{-1}, 1) (x_{n-m \rightarrow n-1} - \boldsymbol{\mu}_{\mathbf{x}_{n-m \rightarrow n-1}}) \quad (22)$$

式(22)中的 $(-\boldsymbol{\Sigma}_{x_n, \mathbf{x}_{n-m \rightarrow n-1}} \boldsymbol{\Sigma}_{\mathbf{x}_{n-m \rightarrow n-1}, \mathbf{x}_{n-m \rightarrow n-1}}^{-1}, 1)$ 是一个行向量, 与 n 无关. 定义列向量 $\mathbf{w}_n = (x_{n-m \rightarrow n-1} - \boldsymbol{\mu}_{\mathbf{x}_{n-m \rightarrow n-1}})$, 列向量 \mathbf{u} 的转置 $\mathbf{u}^T = (-\boldsymbol{\Sigma}_{x_n, \mathbf{x}_{n-m \rightarrow n-1}} \boldsymbol{\Sigma}_{\mathbf{x}_{n-m \rightarrow n-1}, \mathbf{x}_{n-m \rightarrow n-1}}^{-1}, 1)$, 则式(18)中的 $(x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2$ 可以表示为:

$$(x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2 = \mathbf{u}^T \mathbf{w}_n \mathbf{w}_n^T \mathbf{u} \quad (23)$$

\mathbf{w}_n 中的 $\boldsymbol{\mu}_{\mathbf{x}_{n-m \rightarrow n-1}}$ 是 $\mathbf{x}_{n-m \rightarrow n-1}$ 的均值, 等于模型的实际输出值^[20], 如式(24)所示. 其中, $\mathbf{V}_{n-m \rightarrow n}$ 是式(8)中观测矩阵 \mathbf{V} 的第 $n-m$ 行到第 n 行所构成的一个 $(m+1) \times 2S$ 维子矩阵.

$$\boldsymbol{\mu}_{\mathbf{x}_{n-m \rightarrow n-1}} = \mathbf{V}_{n-m \rightarrow n} \mathbf{c} \quad (24)$$

根据式(23)和(24)可以推导出:

$$\sum_{n=m+1}^{2N} (x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2 = \sum_{n=m+1}^{2N} (\mathbf{x}_{n-m \rightarrow n-1}^T \mathbf{u} - \mathbf{c}^T \mathbf{V}_{n-m \rightarrow n}^T \mathbf{u})^2 \quad (25)$$

定义 $\mathbf{A}_n = \mathbf{x}_{n-m \rightarrow n-1}^T \mathbf{u}$, $\mathbf{A} = [\mathbf{A}_{m+1}, \mathbf{A}_{m+2}, \dots, \mathbf{A}_n, \dots, \mathbf{A}_{2N}]^T$, $\mathbf{B}_n = \mathbf{V}_{n-m \rightarrow n}^T \mathbf{u}$, $\mathbf{B} = [\mathbf{B}_{m+1}, \mathbf{B}_{m+2}, \dots, \mathbf{B}_n, \dots, \mathbf{B}_{2N}]^T$, 则式(25)可变换为:

$$\sum_{n=m+1}^{2N} (x_n - \mu_{x_n | \mathbf{x}_{n-m \rightarrow n-1}})^2 = \|\mathbf{A} - \mathbf{B}\mathbf{c}\|^2 \quad (26)$$

定义变量 $\boldsymbol{\beta} = \frac{1}{\sigma^2}$, 并把式(18)定义为函数 $f(\boldsymbol{\beta})$:

$$f(\beta) = (2N - m) \ln \left(\frac{1}{\sqrt{2\pi}} \sqrt{\beta} \right) - \sum_{n=m+1}^{2N} \frac{(x_n - \mu_{x_n | x_{n-m+1}})^2}{2} \beta \quad (27)$$

将 $f(\beta)$ 对 β 求导, 当 $\frac{\partial f(\beta)}{\partial \beta} = 0$ 时, $f(\beta)$ 取得最大值, 对应的 β 值(标记为 $\hat{\beta}$) 和方差的估计值为:

$$\frac{1}{\hat{\beta}} = \hat{\sigma}^2 = \frac{1}{2N - m} \sum_{n=m+1}^{2N} (x_n - \mu_{x_n | x_{n-m+1}})^2 \quad (28)$$

将式(26)代入式(28)可得:

$$\hat{\sigma}^2 = \frac{1}{N - m} \| \mathbf{A} - \mathbf{Bc} \|^2 \quad (29)$$

此时, 可求出 $f(\beta)$ 的最大值 $f(\hat{\beta})$ 为:

$$f(\hat{\beta}) = (2N - m) \ln \frac{1}{\sqrt{2\pi}} - \frac{2N - m}{2} \ln \hat{\sigma}^2 - \frac{2N - m}{2} \quad (30)$$

根据式(18)和(30), 可获得 BIC 准则公式中的 $\ln P(\mathbf{x} | \hat{\mathbf{c}}, \mathbf{H}_s)$ 项, 即

$$\begin{aligned} \ln P(\mathbf{x} | \hat{\mathbf{c}}, \mathbf{H}_s) &\approx \ln P(x_{m+1}, x_{m+2}, \dots, x_{2N}) \\ &= (2N - m) \ln \frac{1}{\sqrt{2\pi}} \\ &\quad - \frac{2N - m}{2} \ln \hat{\sigma}^2 - \frac{2N - m}{2} \end{aligned} \quad (31)$$

在本文中, $N_p = 2N - m$, $N_s = s$, $s \in \{1, 2, \dots, 2S\}$, 将式(31)代入式(14)即可推导出非独立同分布的 BIC 准则, 如式(32)所示.

$$\begin{aligned} \text{BIC}(s) &= -2 \left\{ (2N - m) \ln \frac{1}{\sqrt{2\pi}} - \frac{2N - m}{2} \ln \hat{\sigma}^2 - \frac{2N - m}{2} \right\} \\ &\quad + (2S + 1) \ln(2(2N - m)) \end{aligned} \quad (32)$$

将式(32)代入式(12), 并忽略常数项, 则可推导出自适应确定最优模型基函数项的公式:

$$s_* = \arg \min_s \{ (2N - m) \ln(\hat{\sigma}^2) + 2S \ln(2(2N - m)) \} \quad (33)$$

5 实验仿真分析

双频段 DPD 系统采用图 1 所示的 2D-DPD 结构, 使用 Saleh 模型级联一个 FIR 滤波器组成的 Hammerstein 模型作为 PA 模型. Saleh 模型参数设置为 $\alpha_a = 3$, $\beta_a = 2$, $\alpha_p = 4$, $\beta_p = 9$, FIR 滤波器的系统函数为 $H(Z) = 0.7692 + 0.1538Z^{-1} + 0.076Z^{-2}$, 此时 PA 具有很强的

非线性^[4]. 与文献[5]一样, 两个频段信号的带宽均设置为 4.8MHz, 每个频段信号的采样点数量均为 3000. 待优化的 DB-GMP 模型参数设置为: $P=7$ 或 $P=5$, $G=3$, $L=2$, $m=5$.

5.1 DB-GMP 模型的优化算法仿真

双频段预失真模型优化的前提是优化后模型 MSE 与原始模型 MSE 必须处于同一水平, 这与现有模型优化算法的性能指标要求一致. 将配置为 $P=5$, $G=3$, $L=2$ 和 $P=7$, $G=3$, $L=2$ 的 DB-GMP 模型分别简称为 DB-GMP-5-3-2 和 DB-GMP-7-3-2 模型, 它们的基函数项数量分别为 208 和 368. 用本文提出的算法进行优化时, 两种模型 MSE 和 BIC 值随各自备选模型的基函数项数量而变化的曲线分别如图 3 和图 4 所示.

从图 3(a) 和图 4(a) 可以看出, 刚开始时, 两种模型 MSE 均随基函数项数量的增加而降低, 但当基函数项数量达到一定值时, MSE 就处于收敛状态. 这说明处于收敛临界点之后的基函数项对于模型的非线性拟合能力没有提升作用, 验证了原始 DB-GMP 模型具有稀疏性. 从图 3(b) 和图 4(b) 可知, 两种模型的 BIC 值均随基函数项数量的增加而减小, 但达到一个最小值后, BIC 值随基函数项数量的增加而增大. 根据式(32), 影响 BIC 值的因素主要有两个, 一个是模型 MSE, 另一个是模型基函数项的数量. 在模型 MSE 曲线收敛之前, 模型 MSE 降低得比较快, 此时模型对应的 BIC 值主要取决于 MSE; 而当模型 MSE 曲线收敛之后, MSE 处于同一水平, 此时模型基函数项数量对 BIC 值的影响逐渐变得明显. 对比图 3(a) 与图 3(b)、图 4(a) 与图 4(b) 可以看出, 两种模型的最小 BIC 值所确定的基函数项数量均与各自 MSE 曲线起始收敛处对应的基函数项数量非常的接近, 并且有很少的余量, 能够有效避免欠拟合和过拟合. 优化前后的基函数项数量以及 MSE 的对比如表 1 所示. 优化后模型保持与原始模型相似的 MSE 水平, 而模型的系数数量分别减少了 75% 和 78%.

5.2 DB-GMP 模型优化前后的预失真性能仿真

优化前后 DB-GMP 模型的预失真性能从邻道功率比 (Adjacent Channel Power Ratio, ACPR) 和归一化均方误差 (Normalized Mean Squared Error, NMSE)^[3] 两个方面进行仿真比较.

表 1 优化前后 DB-GMP 模型的基函数项数量和 MSE

原始 DB-GMP 模型	模型的基函数项数量			模型的 MSE		
	MSE 收敛处模型	优化后的模型	原始模型	MSE 收敛处模型	优化后模型	原始模型
DB-GMP-7-3-2	79	80	368	1.3248×10^{-5}	1.3237×10^{-5}	1.2543×10^{-5}
DB-GMP-5-3-2	49	53	208	2.1032×10^{-5}	2.0919×10^{-5}	1.9492×10^{-5}




图3 DB-GMP-5-3-2模型迭代过程的均方误差曲线和BIC值曲线




图4 DB-GMP-7-3-2模型迭代过程的均方误差曲线和BIC值曲线

DB-GMP-5-3-2 和 DB-GMP-7-3-2 两种模型的原始模型以及优化后模型进行预失真后的两个频段信号的功率谱密度(Power Spectrum Density, PSD)分别如图 5 和图 6 所示. 对于 DB-GMP-5-3-2 和 DB-GMP-7-3-2 两种模型, 未进行预失真(标识为 No-DPD)时, 两个频段的信号经过 PA 之后均产生了严重的失真, 邻道平均功率较大; 而采用原始模型进行预失真(标识为 Original-DB-GMP-DPD)

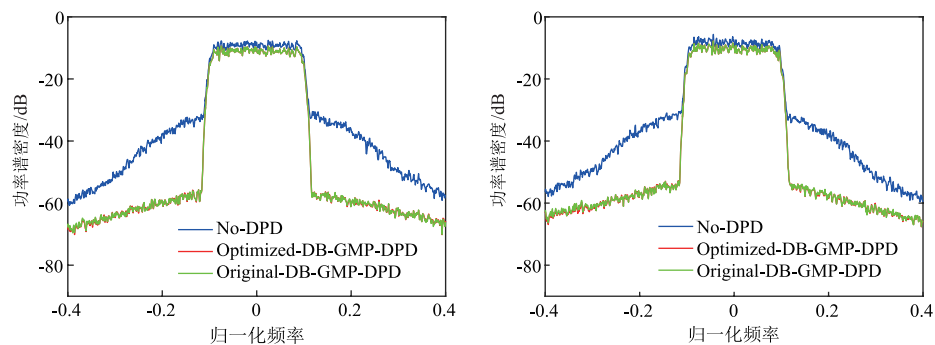
和优化后模型进行预失真(标识为 Optimized-DB-GMP-DPD)时, 邻道平均功率都得到了有效抑制, 并且两种预失真情况下的 PSD 曲线基本重合. DB-GMP-5-3-2 和 DB-GMP-7-3-2 模型的三种预失真情况下的左右邻道 ACPR 和 NMSE 分别如表 2 和表 3 所示. 两种模型的原始模型与优化后模型的预失真效果均非常接近, 均能够同时实现对两个频段信号的有效预失真补偿.

表 2 DB-GMP-5-3-2 模型的 ACPR 和 NMSE

DPD 模型	ACPR(dBc)				NMSE(dB)	
	频段 1		频段 2		频段 1	频段 2
	左邻道	右邻道	左邻道	右邻道		
No-DPD	-31.6695	-30.2792	-30.3927	-32.2429	-18.7511	-19.2287
Original-DB-GMP-DPD	-44.8821	-44.0470	-42.5083	-43.5121	-42.8299	-42.9904
Optimized-DB-GMP-DPD	-44.8201	-44.0341	-42.3979	-43.4619	-42.8107	-42.9594

表 3 DB-GMP-7-3-2 模型的 ACPR 和 NMSE


DPD 模型	ACPR(dBc)				NMSE(dB)	
	频段 1		频段 2		频段 1	频段 2
	左邻道	右邻道	左邻道	右邻道		
No-DPD	-31.6695	-30.2792	-30.3927	-32.2429	-18.7511	-19.2287
Original-DB-GMP-DPD	-48.6453	-48.2696	-44.7743	-45.7876	-47.8250	-47.6035
Optimized-DB-GMP-DPD	-48.5437	-48.1426	-43.9329	-44.9080	-47.8009	-46.4184



(a) 频段1的功率谱密度图

(b) 频段2的功率谱密度图

图5 优化前后DB-GMP-5-3-2模型预失真后两个频段信号的功率谱密度图



(a) 频段1的功率谱密度图

(b) 频段2的功率谱密度图

图6 优化前后DB-GMP-7-3-2模型预失真后两个频段信号的功率谱密度图

6 结论

针对双频段信号驱动 PA 时,用于 PA 线性化的预失真模型复杂度高以及当前模型优化算法无法实现自适应优化的问题. 本文根据双频段预失真模型具有的稀疏性,提出一种基于 OMP 和 BIC 准则的自适应双频段预失真模型优化算法. 由于模型输出信号存在相关性,本文从理论上推导了非独立同分布的 BIC 准则,并将其应用于提出的优化算法. 实验仿真结果表明本文的优化算法能够有效的降低模型复杂度,并保持良好的预失真性能. 后续将研究把本文的优化算法拓展应用于更多频段预失真模型的自适应优化.

参考文献

- [1] Qian H, Yao S, Huang H, et al. Low complexity coefficient estimation for concurrent dual-band digital predistortion [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2015, 63(10): 3153 – 3163.
- [2] 邓海林, 张德伟, 白维达, 等. 一种行波管用毫米波射频预失真线性化器 [J]. *电子学报*, 2017, 45(7): 1784 – 1791.
DENG Hai-lin, ZHANG De-wei, BAI Wei-da, et al. A millimeter-wave RF predistortion linearizer for travelling wave tube amplifier [J]. *Acta Electronica Sinica*, 2017, 45(7):

1784 – 1791. (in Chinese)

- [3] Bassam S A, Helaoui M, Ghannouchi F M. 2-D digital predistortion (2-D-DPD) architecture for concurrent dual-band transmitters [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2011, 59(10): 2547 – 2553.
- [4] 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 [J]. *通信学报*, 2014, 35(1): 16 – 23.
HUANG Chun-hui, WEN Yong-jie. Algorithm study of digital HPA predistortion using one novel memory type BP neural network [J]. *Journal on Communications*, 2014, 35(1): 16 – 23. (in Chinese)
- [5] Eriksson T, Fager C. Digital predistortion of concurrent multiband communication systems [A]. 2014 IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP) [C]. Florence: IEEE, 2014. 3918 – 3922.
- [6] Liu Y J, Chen W, Zhou J, et al. Digital predistortion for concurrent dual-band transmitters using 2-D modified memory polynomials [J]. *IEEE Transactions on Microwave Theory and Techniques*, 2013, 61(1): 281 – 290.
- [7] Hammi O, Abdelhafiz A, Ghannouchi F M, et al. On the use of compressed sampling algorithms for impairments compensation in dynamic nonlinear transmitters [A]. 2015 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT) [C]. Abu Dhabi: IEEE,

2015. 641 – 645.
- [8] Zenteno E, Amin S, Isaksson M, et al. Combating the dimensionality of nonlinear MIMO amplifier predistortion by basis pursuit [A]. 2014 44th European Microwave Conference (EuMC) [C]. Rome: IEEE, 2014. 833 – 836.
- [9] Wisell D, Jaldén J, Handel P. Behavioral power amplifier modeling using the LASSO [A]. 2008 Instrumentation and Measurement Technology Conference Proceedings (IMTC) [C]. Victoria: IEEE, 2008. 1864 – 1867.
- [10] Gilibert P L, Montoro G, López D, et al. Order reduction of wideband digital predistorters using principal component analysis [A]. 2013 IEEE MTT-S International Microwave Symposium Digest (IMS) [C]. Seattle: IEEE, 2013. 1 – 7.
- [11] Abdelhafiz A, Kwan A, Hammi O, et al. Digital predistortion of LTE-A power amplifiers using compressed-sampling-based unstructured pruning of Volterra series [J]. IEEE Transactions on Microwave Theory and Techniques, 2014, 62(11): 2583 – 2593.
- [12] Li M, Yang Z, Zhang Z, et al. Sparsity adaptive estimation of memory polynomial based models for power amplifier behavioral modeling [J]. IEEE Microwave and Wireless Components Letters, 2016, 26(5): 370 – 372.
- [13] 杨霖, 何向东, 丁长文. OFDM 系统中基于限幅和压缩感知的非线性失真补偿算法 [J]. 电子学报, 2016, 44(9): 2051 – 2056.
YANG Lin, HE Xiang-dong, DING Chang-wen. Compensation method for nonlinear distortion based on clipping and compressive sensing in OFDM system [J]. Acta Electronica Sinica, 2016, 44(9): 2051 – 2056. (in Chinese)
- [14] Schwarz G. Estimating the dimension of a model [J]. The Annals of Statistics, 1978, 6(2): 461 – 464.
- [15] 刘伟峰, 杨爱兰. 基于 BIC 准则和 Gibbs 采样的有限混合模型无监督学习算法 [J]. 电子学报, 2011, 39(3): 134 – 139.
LIU Wei-feng, YANG Ai-lan. Unsupervised learning for finite mixture models based on BIC criterion and Gibbs sampling [J]. Acta Electronica Sinica, 2011, 39(3): 134 – 139. (in Chinese)
- [16] Lee E R, Noh H, Park B U. Model selection via Bayesian information criterion for quantile regression models [J]. Journal of the American Statistical Association, 2014, 109(505): 216 – 229.
- [17] Shi M, Shen W, Wang H Q, et al. Adaptive modelling of gene regulatory network using Bayesian information criterion-guided sparse regression approach [J]. IET Systems Biology, 2016, 10(6): 252 – 259.
- [18] Selim B, Alhussein O, Muhaidat S, et al. Modeling and analysis of wireless channels via the mixture of Gaussian

distribution [J]. IEEE Transactions on Vehicular Technology, 2016, 65(10): 8309 – 8321.

- [19] Stoica P, Babu P. On the proper forms of BIC for model order selection [J]. IEEE Transactions on Signal Processing, 2012, 60(9): 4956 – 4961.
- [20] Bishop C M. Pattern Recognition and Machine Learning [M]. New York: Springer Press, 2006. 24 ~ 32, 78 ~ 113.

作者简介



吴林煌 男, 1984 年 12 月生于福建漳州, 博士, 助理研究员, 研究方向为数字预失真、基带信号处理等。
E-mail: wlh173@163.com



苏凯雄 (通信作者) 男, 1959 年 1 月生于福建福州, 教授, 博士生导师, 研究方向为微波通信、多媒体通信等。
E-mail: skx@fzu.edu.cn



王琳 男, 1963 年 6 月生于重庆, 教授, 博士生导师, 研究方向为无线通信系统算法、信源信道联合编码等。
E-mail: wanglin@xmu.edu.cn



陈志峰 男, 1979 年 9 月生于福建莆田, 教授, 博士生导师, 研究方向为无线通信、视频编码、人工智能等。
E-mail: zhifeng@fzu.edu.cn



陈平平 男, 1986 年 12 月生于福建泉州, 教授, 研究方向为联合信源信道编码、网络编码等。
E-mail: chenpingping_xmu@qq.com