

基于改进的稀疏最小二乘双子支撑向量回归的数字预失真技术

代志江^① 孔淑曼^① 李明玉^{*①} 蔡天赋^① 靳一^② 徐常志^②

^①(重庆大学微电子与通信工程学院 重庆 400044)

^②(中国空间技术研究院西安分院 西安 710100)

摘要: 为了补偿大容量卫星通信射频前端的功率放大器的非线性,传统的数字预失真(DPD)模型需要更多的系数和更高的阶次,严重影响预失真前馈路径的资源消耗。为了解决这一问题,该文提出一种基于改进的稀疏最小二乘双子支撑向量回归(ISLSTSVR)的低复杂度DPD方法。首先通过构建原空间的决策函数解决最小二乘双子支撑向量回归(LSTSVR)模型解不稀疏的问题;同时引用截断最小二乘损失函数增加模型的鲁棒性;然后采用Nystrom逼近方法得到核矩阵的低秩近似,进一步采用Cholesky分解降低核矩阵的运算复杂度;最后由低秩的核矩阵求得模型稀疏解。实验选用基于单管氮化镓(GaN)器件的宽带AB类功率放大器,以40 MHz的32QAM信号进行激励。预失真实验表明,该方法能在保证模型精度的情况下大幅减少DPD模型系数和计算复杂度,为星载射频前端的预失真技术提供了有效的系数降维思路和方法。

关键词: 数字预失真; 稀疏LSTSVR; Cholesky分解; 功率放大器

中图分类号: TN911.3

文献标识码: A

文章编号: 1009-5896(2023)02-0418-09

DOI: 10.11999/JEIT220372

A Digital Predistortion Technique Based on Improved Sparse Least Squares Twin Support Vector Regression

DAI Zhijiang^① KONG Shuman^① LI Mingyu^① CAI Tianfu^①

JIN Yi^② XU Changzhi^②

^①(School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400044, China)

^②(China Academy of Space Technology-Xi'an, Xi'an 710100, China)

Abstract: To compensate for the nonlinearity of the power amplifier in the RF front-end of high-capacity satellite communication, more coefficients and higher orders are required in the conventional Digital PreDistortion (DPD) model, which affects severely the resource consumption of the predistortion feedforward path. In this paper, a low-complexity DPD approach based on Improved Sparse Least Squares Twin Support Vector Regression (ISLSTSVR) modeling theory is presented to address this problem. Firstly, the problem that the solution of the Least Squares Twin Support Vector Regression(LSTSVR)model is not sparse is solved by constructing decision function in the original space; At the same time, the truncated least squares loss function is used to increase robustness of the model; Then the low-rank approximation of the kernel matrix is obtained by using Nystrom approximation method, and further Cholesky decomposition is used to reduce the operational complexity of the kernel matrix; Finally, the sparse solution of the model is obtained from low-rank kernel matrix. To verify the effectiveness of the proposed method, experiments are performed using a single-tube gallium nitride (GaN) broadband AB-class power amplifier with a 40 MHz 32 QAM signal for excitation. The experiment result shows that this method can greatly reduce the DPD model coefficients and computational complexity while ensuring the model accuracy, and provides an effective coefficient dimension reduction idea and method for the predistortion technology of the spaceborne RF front-end.

收稿日期: 2022-03-31; 改回日期: 2022-08-06; 网络出版: 2022-08-10

*通信作者: 李明玉 myli@cqu.edu.cn

基金项目: 国家自然科学基金(62171068, 62001061), 重庆市教委科技研究专项青年项目(KJQN201902403)

Foundation Items: The National Natural Science Foundation of China (62171068, 62001061), The QingNian Project of Science and Technology Research Program of Chongqing Education Commission of China (KJQN201902403)

Key words: Digital predistortion; Sparse Least Squares Twin Support Vector Regression (LSTSVR); Cholesky factorization; Power amplifier

1 引言

卫星通信逐步向高频段、大容量、高频谱效率的方向发展,对星载射频前端发射机非线性补偿系统的设计提出新的挑战^[1]。一方面,多载波、多电平、高峰均比的高阶非恒包络信号的接入使得终端功率放大器(Power Amplifier, PA)工作于回退区,效率急剧下降,同时,功放非线性产生的交调失真落在带内带外,严重降低了信号质量和频谱效率^[2];另一方面,星载射频前端功率放大器具有不连续的非线性失真特点,展现出动态发散及失真突变等现象,此外,传输带宽的增加将显著凸显射频PA的记忆效应,传统的数字预失真(Digital PreDistortion, DPD)模型很难取得良好的补偿效果^[3]。因此,开发新型宽带高效低复杂度非线性失真补偿技术成为解决大容量卫星通信可靠传输问题的关键。

由于功放的强非线性和宽带信号的引入,传统多项式预失真模型,如记忆多项式、广义记忆多项式(Generalized Memory Polynomial, GMP),模型系数呈指数型增加,参数估计的精度对反馈噪声更加敏感,亟需采用剪切算法删减模型冗余项^[4]。近几年,学术界提出使用压缩感知重构理论进行稀疏系统辨识,取得了不错的效果:Abdelhafiz教授团队^[5]提出采用压缩采样匹配追踪算法进行内核选择,获得比主成分分析算法更好的剪枝性能和建模精度,但需要利用大量采样点进行筛选;之后,大量的研究在基于正交匹配追踪及其相应的改进算法上进行,这些算法常使用贪婪规则来稀疏化PA多项式模型^[6-9]。尽管可以识别重要原子的位置,但是由于固定的批处理操作模式以及每次迭代时都涉及最小二乘法伪逆计算,在快速自适应方面的应用有所限制。同样,文献^[10,11]针对双正交匹配追踪算法中的伪逆计算进行优化,分别采用递归操作和等效正交域变换方法避免求逆运算,提升算法求解速度,此外,研究者还将稀疏贝叶斯学习准则引入多项式核的修剪过程中,减少学习样本的同时还保持相当的线性化能力^[12-14]。

以上的稀疏化方法均采用固定规则对多项式模型裁剪,在宽带强非线性失真情况下,过大的紧凑模型可能会存在稀疏辨识困难和模型删减不彻底等问题。最近的研究中,学者试图寻找脱离Volterra级数基础的模型来解决宽带系统的非线性辨识,人工神经网络以良好的非线性函数逼近能力被考虑进射频功放的行为建模及数字预失真器设计,而机器

学习中支撑向量机(Support Vector Machines, SVM)模型有着精度与复杂度的良好折衷也被广泛用于数字补偿^[15-19]。文献^[18,19]针对支撑向量回归(Support Vector Regression, SVR)、双子支撑向量回归(Twin Support Vector Regression, TSVR)算法在PA非线性建模问题上进行了详细的描述,尽管模型表现出良好的泛化能力却仍存在问题:一方面,在处理大规模问题时,训练阶段的计算复杂度非常大,会出现训练失败情况;另一方面,大样本情况下,模型表现出的不稀疏性将严重增加预失真器设计时的复杂度。为优化以上问题,Cai等人^[20]提出稀疏光滑的双子支撑向量回归(Smooth Twin Support Vector Regression, STSVR)模型用于发射机射频损伤的矫正,其主要思想是删减核矩阵和裁剪迭代计算中涉及的海塞矩阵,从而达到稀疏化模型和加速算法收敛速度的目的,但由于核矩阵的删减采用随机法,其建模精度可能会相应降低。

为解决大规模样本回归问题,本文将继续从支撑向量机理论角度出发,采用最小二乘双子支撑向量回归(Least Squares Twin Support Vector Regression, LSTSVR)结构,同时考虑模型稀疏性以及快速自适应问题,提出了一种用于补偿星载发射机非线性失真的新型模型——改进的稀疏最小二乘双子支撑向量回归(Improved Sparse Least Squares Twin Support Vector Regression, ISLSTSVR)。为提高鲁棒性,该模型用截断的损失函数替代LSTSVR中的最小二乘损失函数以构建原空间的目标函数;为进一步提高运算速度,该模型采用Cholesky分解迭代寻找核矩阵中的基本核列来简化核矩阵从而得到相应的稀疏解。通过预失真实验表明,基于该逆模结构的预失真系统的补偿性能优于其他线性度较好的预失真系统。

2 基于改进的稀疏LSTSVR (ISLSTSVR)的PA建模方法

2.1 基于非凸截断最小二乘损失函数的LSTSVR

首先,将传统TSVR模型中带不等式约束的凸二次规划问题替换为等式约束优化问题,得到原空间LSTSVR的等价目标函数为

$$\left. \begin{aligned} \min_{\omega_1, b_1} & \frac{\lambda}{2} \omega_1^T \omega_1 + \sum_{i=1}^m L_{\text{sq}}(\xi_i^+) \\ \text{s.t. } & \xi_i^+ = (\omega_1^T \varphi(x_i) + b_1 + \varepsilon_1) - y_i, \\ & i = 1, 2, \dots, m \end{aligned} \right\} \quad (1)$$

$$\left. \begin{aligned} & \min_{\omega_2, b_2} \frac{\lambda}{2} \omega_2^T \omega_2 + \sum_{i=1}^m L_{\text{sq}}(\boldsymbol{\xi}_i^-) \\ & \text{s.t. } \boldsymbol{\xi}_i^- = \mathbf{y}_i - (\omega_2^T \boldsymbol{\varphi}(x_i) + b_2 - \varepsilon_2), \\ & \quad i = 1, 2, \dots, m \end{aligned} \right\} \quad (2)$$

其中, $\lambda > 0$ 为正则化参数, $\varepsilon_1, \varepsilon_2$ 为TSVR的不敏感参数, ω_1, ω_2 为上下界超平面的法向量, $\boldsymbol{\varphi}(x_i)$ 为输入数据 x_i 到特征空间的映射, $\boldsymbol{\xi}^+$ 和 $\boldsymbol{\xi}^-$ 为松弛变量, 分别代表下界和上界的预测误差。 $L_{\text{sq}}(\boldsymbol{\xi}) = \boldsymbol{\xi}^2/2$ 为最小二乘损失函数。为了提高模型鲁棒性, $L_{\text{sq}}(\boldsymbol{\xi})$ 用截断的最小二乘损失函数 $L_\tau(\boldsymbol{\xi})$ 替代

$$L_\tau(\boldsymbol{\xi}) = \frac{1}{2} \min(\tau^2, \boldsymbol{\xi}^2) \quad (3)$$

注意到 $L_\tau(\boldsymbol{\xi})$ 不是凸函数也不具备光滑特性, 考虑将其表示为两个凸函数之差即

$$L_\tau(\boldsymbol{\xi}) = L_{\text{sq}}(\boldsymbol{\xi}) - L_2(\boldsymbol{\xi}) \quad (4)$$

其中,

$$L_2(\boldsymbol{\xi}) = \frac{1}{2} \max\{0, \boldsymbol{\xi}^2 - \tau^2\} \quad (5)$$

于是优化问题可表示为

$$\begin{aligned} & \min_{\omega_1, b_1} \frac{\lambda}{2} \omega_1^T \omega_1 + \sum_{i=1}^m L_{\text{sq}}((\omega_1^T \boldsymbol{\varphi}(x_i) + b_1 + \varepsilon_1) - \mathbf{y}_i) \\ & - \sum_{i=1}^m L_2((\omega_1^T \boldsymbol{\varphi}(x_i) + b_1 + \varepsilon_1) - \mathbf{y}_i) \end{aligned} \quad (6)$$

$$\begin{aligned} & \min_{\omega_2, b_2} \frac{\lambda}{2} \omega_2^T \omega_2 + \sum_{i=1}^m L_{\text{sq}}(\mathbf{y}_i - (\omega_2^T \boldsymbol{\varphi}(x_i) + b_2 - \varepsilon_2)) \\ & - \sum_{i=1}^m L_2(\mathbf{y}_i - (\omega_2^T \boldsymbol{\varphi}(x_i) + b_2 - \varepsilon_2)) \end{aligned} \quad (7)$$

根据对偶理论和表示理论^[21], ω 可以表示为

$$\omega = \sum_{i=1}^m \alpha_i \boldsymbol{\varphi}(x_i) \quad (8)$$

将式(8)代入优化目标式(6)和式(7)中, 得到目标函数为

$$\begin{aligned} & \min_{\boldsymbol{\alpha}, b_1} g_1(\boldsymbol{\alpha}, b_1) \\ & = \frac{\lambda}{2} \boldsymbol{\alpha}^T \mathbf{K} \boldsymbol{\alpha} + \sum_{i=1}^m L_{\text{sq}}((\mathbf{K}_{iM} \boldsymbol{\alpha} + b_1 + \varepsilon_1) - \mathbf{y}_i) \\ & - \sum_{i=1}^m L_2((\mathbf{K}_{iM} \boldsymbol{\alpha} + b_1 + \varepsilon_1) - \mathbf{y}_i) \end{aligned} \quad (9)$$

$$\begin{aligned} & \min_{\boldsymbol{\beta}, b_2} g_2(\boldsymbol{\beta}, b_2) \\ & = \frac{\lambda}{2} \boldsymbol{\beta}^T \mathbf{K} \boldsymbol{\beta} + \sum_{i=1}^m L_{\text{sq}}(\mathbf{y}_i - (\mathbf{K}_{iM} \boldsymbol{\beta} + b_2 - \varepsilon_2)) \\ & - \sum_{i=1}^m L_2(\mathbf{y}_i - (\mathbf{K}_{iM} \boldsymbol{\beta} + b_2 - \varepsilon_2)) \end{aligned} \quad (10)$$

其中, $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 均为拉格朗日乘子, \mathbf{K} 为高维特征空间的核矩阵

$$\mathbf{K} = \begin{bmatrix} k(\boldsymbol{\varphi}(\mathbf{x}_1), \boldsymbol{\varphi}(\mathbf{x}_1)) & \cdots & k(\boldsymbol{\varphi}(\mathbf{x}_1), \boldsymbol{\varphi}(\mathbf{x}_m)) \\ k(\boldsymbol{\varphi}(\mathbf{x}_2), \boldsymbol{\varphi}(\mathbf{x}_1)) & \cdots & k(\boldsymbol{\varphi}(\mathbf{x}_2), \boldsymbol{\varphi}(\mathbf{x}_m)) \\ \vdots & \ddots & \vdots \\ k(\boldsymbol{\varphi}(\mathbf{x}_m), \boldsymbol{\varphi}(\mathbf{x}_1)) & \cdots & k(\boldsymbol{\varphi}(\mathbf{x}_m), \boldsymbol{\varphi}(\mathbf{x}_m)) \end{bmatrix} \quad (11)$$

\mathbf{K}_{iM} 为核矩阵 \mathbf{K} 的第 i 行, $\mathbf{K}_{iM} = [k(\mathbf{x}_i, \mathbf{x}_1), k(\mathbf{x}_i, \mathbf{x}_2), \dots, k(\mathbf{x}_i, \mathbf{x}_m)]$ 。

以上界目标函数式(9)为例, 令

$$\min_{\boldsymbol{\alpha}, b_1} g_1(\boldsymbol{\alpha}, b_1) = H(\boldsymbol{\alpha}, b_1) - L(\boldsymbol{\alpha}, b_1) \quad (12)$$

令 $\mathbf{e} = [1, 1, \dots, 1]^T$, 有

$$\begin{aligned} H(\boldsymbol{\alpha}, b_1) &= \frac{\lambda}{2} \boldsymbol{\alpha}^T \mathbf{K} \boldsymbol{\alpha} + \sum_{i=1}^m L_{\text{sq}}((\mathbf{K}_{iM} \boldsymbol{\alpha} + b_1 + \varepsilon_1) - \mathbf{y}_i) \\ &= \frac{1}{2} \boldsymbol{\alpha}^T (\lambda \mathbf{K} + \mathbf{K} \mathbf{K}^T) \boldsymbol{\alpha} + \boldsymbol{\alpha}^T \mathbf{K} (\mathbf{e} b_1 + \mathbf{e} \varepsilon_1 - \mathbf{y}) \\ &\quad - \mathbf{y}^T (\mathbf{e} b_1 + \mathbf{e} \varepsilon_1) + \frac{m}{2} (\mathbf{e} b_1 + \mathbf{e} \varepsilon_1)^2 + \frac{1}{2} \mathbf{y}^T \mathbf{y} \end{aligned} \quad (13)$$

$$L(\boldsymbol{\alpha}, b_1) = \sum_{i=1}^m L_2((\mathbf{K}_{iM} \boldsymbol{\alpha} + b_1 + \varepsilon_1) - \mathbf{y}_i) \quad (14)$$

利用文献[22]中的CCCP方法, 通过迭代求解以下凸QP问题, 直到其收敛, 即可得到问题式(12)的解

$$\begin{aligned} \min_{\boldsymbol{\alpha}, b_1} g_1(\boldsymbol{\alpha}, b_1) &= H(\boldsymbol{\alpha}, b_1) - ([\boldsymbol{\alpha}^T, b_1 + \varepsilon_1]^T, \partial L(\boldsymbol{\alpha}^{(j)}, b_1^{(j)})) \\ &= H(\boldsymbol{\alpha}, b_1) + \boldsymbol{\psi}^{+(j)}(\mathbf{K} \boldsymbol{\alpha} + b_1 + \varepsilon_1) \end{aligned} \quad (15)$$

其中, $\boldsymbol{\psi}^{+(j)}$ 为损失函数 $L_2(\boldsymbol{\xi}^{+(j)})$ 第 j 次迭代的偏差

$$\boldsymbol{\psi}^{+(j)} = \partial L_2(\boldsymbol{\xi}^{+(j)}) \quad (16)$$

由于 $L_2(\boldsymbol{\xi})$ 不可微, 采用熵罚函数逼近 $L_2(\boldsymbol{\xi})$, 将 $L_2(\boldsymbol{\xi})$ 改写为^[23]

$$\begin{aligned} \bar{L}_2(\boldsymbol{\xi}) &= \frac{1}{2} \max\{0, \boldsymbol{\xi}^2 - \tau^2\} \\ &\quad + \frac{1}{2p} \log(1 + \exp(-p |\boldsymbol{\xi}^2 - \tau^2|)) \end{aligned} \quad (17)$$

其中, p 为惩罚因子, 显然当 $p \rightarrow \infty$ 时, 有 $\bar{L}_2(\boldsymbol{\xi}) \rightarrow L_2(\boldsymbol{\xi})$ 。对 $\bar{L}_2(\boldsymbol{\xi})$ 求导

$$\bar{L}'_2(\boldsymbol{\xi}) = \boldsymbol{\xi} \frac{\min\{1, \exp[p(\boldsymbol{\xi}^2 - \tau^2)]\}}{1 + \exp(-p |\boldsymbol{\xi}^2 - \tau^2|)} \quad (18)$$

用 $\bar{L}_2(\boldsymbol{\xi})$ 替换 $L_2(\boldsymbol{\xi})$, 得到 $\boldsymbol{\psi}^{+(j)}$ 的迭代公式为

$$\boldsymbol{\psi}^{+(j)} = \boldsymbol{\xi}^{+(j)} \frac{\min\{1, \exp[p(\boldsymbol{\xi}^{+(j)2} - \tau^2)]\}}{1 + \exp(-p |\boldsymbol{\xi}^{+(j)2} - \tau^2|)} \quad (19)$$

为了寻求最优解, 对上界目标函数式(15)中的 $\boldsymbol{\alpha}, b_1$ 求偏导

$$\begin{aligned}\frac{\partial g_1}{\partial \alpha} &= (\lambda \mathbf{K} + \mathbf{K} \mathbf{K}^T) \alpha + \mathbf{K} (e b_1 + e \varepsilon_1) \\ &\quad - \mathbf{K} (\mathbf{y} - \psi^+) = 0 \\ \frac{\partial g_1}{\partial b_1} &= e^T \mathbf{K}^T \alpha + m (b_1 + \varepsilon_1) - e^T (\mathbf{y} - \psi^+) = 0\end{aligned}\quad (20)$$

整理上面的两个偏导公式可以得到求解的目标等式

$$\begin{bmatrix} \lambda \mathbf{K} + \mathbf{K} \mathbf{K}^T & \mathbf{K} e \\ e^T \mathbf{K}^T & m \end{bmatrix} \begin{bmatrix} \alpha \\ b_1 + \varepsilon_1 \end{bmatrix} = \begin{bmatrix} \mathbf{K} \\ e^T \end{bmatrix} (\mathbf{y} - \psi^+)\quad (21)$$

联立方程, 可以得到 α 和 b_1 的计算公式为

$$\begin{aligned}& \left(\lambda \mathbf{K} + \mathbf{K} \mathbf{K}^T - \frac{1}{m} \mathbf{K} e e^T \mathbf{K} \right) \alpha \\ &= \mathbf{K} \left((\mathbf{y} - \psi^+) - \frac{e^T \mathbf{y}}{m} e \right) \\ b_1 &= \frac{1}{m} (e^T (\mathbf{y} - \psi^+) - e^T \mathbf{K}^T \alpha) - \varepsilon_1\end{aligned}\quad (22)$$

同理得到 β , b_2 的求解式

$$\begin{aligned}& \left(\lambda \mathbf{K} + \mathbf{K} \mathbf{K}^T - \frac{1}{m} \mathbf{K} e e^T \mathbf{K} \right) \beta \\ &= \mathbf{K} \left((\mathbf{y} - \psi^-) - \frac{e^T \mathbf{y}}{m} e \right) \\ b_2 &= \frac{1}{m} (e^T (\mathbf{y} - \psi^-) - e^T \mathbf{K}^T \beta) + \varepsilon_2\end{aligned}\quad (23)$$

2.2 基于改进的稀疏LSTSVR(ISLSTSVR)的PA建模方法

由于2.1节所构建的模型在求解过程中, 核矩阵 $\mathbf{K} \in \mathbb{R}^{m \times m}$ 要反复参与迭代运算, 消耗了大量的存储和计算资源。注意到, 半正定矩阵 \mathbf{K} 通常不满秩, 于是下面对 \mathbf{K} 进行低秩近似和不完全分解。

假设输入样本的索引集为 $\mathbf{M} = \{1, 2, \dots, m\}$, \mathbf{B} 是一个基本集 $\mathbf{B} \in \mathbb{R}^{r \times r}$, 用来存放挑选出的有用向量, 且 $\mathbf{B} \in \mathbf{M}$, \mathbf{N} 为非基本集, $\mathbf{N} = \mathbf{M} \setminus \mathbf{B}$, 用于存放样本集中有用向量之外的其他向量。依据Nystrom逼近原理^[24], 原来的核矩阵 \mathbf{K} 可以用低秩矩阵 $\tilde{\mathbf{K}}$ 近似逼近, 即

$$\mathbf{K} \approx \tilde{\mathbf{K}} = \mathbf{K}_{\mathbf{M}\mathbf{B}} \mathbf{K}_{\mathbf{B}\mathbf{B}}^{-1} \mathbf{K}_{\mathbf{M}\mathbf{B}}^T \quad (24)$$

其中, $\mathbf{K}_{\mathbf{M}\mathbf{B}} \in \mathbb{R}^{m \times r}$, $\mathbf{K}_{\mathbf{B}\mathbf{B}} \in \mathbb{R}^{r \times r}$ 是 \mathbf{K} 的子矩阵。对 $\mathbf{K}_{\mathbf{B}\mathbf{B}}$ 进行Cholesky分解, 有 $\mathbf{K}_{\mathbf{B}\mathbf{B}} = \mathbf{L}\mathbf{L}^T$, 代入 $\tilde{\mathbf{K}}$ 中有

$$\begin{aligned}\tilde{\mathbf{K}} &= \mathbf{K}_{\mathbf{M}\mathbf{B}} \mathbf{K}_{\mathbf{B}\mathbf{B}}^{-1} \mathbf{K}_{\mathbf{M}\mathbf{B}}^T = \mathbf{K}_{\mathbf{M}\mathbf{B}} (\mathbf{L}\mathbf{L}^T)^{-1} \mathbf{K}_{\mathbf{M}\mathbf{B}}^T \\ &= \mathbf{K}_{\mathbf{M}\mathbf{B}} (\mathbf{L}^T)^{-1} (\mathbf{K}_{\mathbf{M}\mathbf{B}} (\mathbf{L}^T)^{-1})^T\end{aligned}\quad (25)$$

令 $\mathbf{P} = \mathbf{K}_{\mathbf{M}\mathbf{B}} (\mathbf{L}^T)^{-1}$, 有

$$\tilde{\mathbf{K}} = \mathbf{K}_{\mathbf{M}\mathbf{B}} \mathbf{K}_{\mathbf{B}\mathbf{B}}^{-1} \mathbf{K}_{\mathbf{M}\mathbf{B}}^T = \mathbf{P}\mathbf{P}^T, \quad \mathbf{P} \in \mathbb{R}^{m \times r} \quad (26)$$

于是式(22)中 α 的求解式可写为

$$\begin{aligned}& \left(\lambda \mathbf{I}_r + \mathbf{P}^T \mathbf{P} - \frac{1}{m} \mathbf{P}^T e e^T \mathbf{P} \right) \mathbf{P}^T \alpha \\ &= \mathbf{P}^T \left((\mathbf{y} - \psi^+) - \frac{e^T (\mathbf{y} - \psi^+)}{m} e \right)\end{aligned}\quad (27)$$

式(23)中的 β 的求解式可写为

$$\begin{aligned}& \left(\lambda \mathbf{I}_r + \mathbf{P}^T \mathbf{P} - \frac{1}{m} \mathbf{P}^T e e^T \mathbf{P} \right) \mathbf{P}^T \beta \\ &= \mathbf{P}^T \left((\mathbf{y} - \psi^-) - \frac{e^T (\mathbf{y} - \psi^-)}{m} e \right)\end{aligned}\quad (28)$$

其中, \mathbf{I}_r 是单位阵, 对 \mathbf{P} 行变换可以得到 $[\mathbf{P}_{\mathbf{B}}^T \mathbf{P}_{\mathbf{N}}^T]^T$, $\mathbf{P}_{\mathbf{B}}$ 是满秩下三角矩阵, $\mathbf{P}_{\mathbf{N}}$ 是 \mathbf{P} 中剩下的行。这样可以得到矩阵有用行, 无用数据令 $\alpha = 0$, 简化后续计算。于是原问题上界优化目标 $(\alpha^{(j+1)}, b_1^{(j+1)})$ 的迭代公式为

$$\left. \begin{aligned}\alpha_{\mathbf{B}}^{(j+1)} &= (\mathbf{P}_{\mathbf{B}}^T)^{-1} \left[(\lambda \mathbf{I}_r + \mathbf{P}^T \mathbf{P}) - \frac{1}{m} (e^T \mathbf{P})^T e^T \mathbf{P} \right]^{-1} \\ &\quad \mathbf{P}^T \left((\mathbf{y} - \psi^{+(j)}) - \frac{e^T (\mathbf{y} - \psi^{+(j)})}{m} e \right) \\ \alpha_{\mathbf{N}}^{(j+1)} &= \mathbf{0} \\ b_1^{(j+1)} &= \frac{1}{m} \left[e^T (\mathbf{y} - \psi^{+(j)}) - e^T \mathbf{P} \mathbf{P}_{\mathbf{B}}^T \alpha_{\mathbf{B}}^{(j+1)} \right]\end{aligned}\right\} \quad (29)$$

$$\begin{aligned}\xi^{+(j)} &= (\mathbf{P} \mathbf{P}_{\mathbf{B}}^T \alpha_{\mathbf{B}}^{(j)} + b_1^{(j)}) - (\mathbf{y} - e \varepsilon_1), \psi^{+(j)} \\ &= \xi^{+(j)} \frac{\min\{1, \exp[p(\xi^{+(j)2} - \tau^2)]\}}{1 + \exp(-p|\xi^{+(j)2} - \tau^2|)}\end{aligned}\quad (30)$$

同理得到 $(\beta^{(j+1)}, b_2^{(j+1)})$ 的迭代公式为

$$\left. \begin{aligned}\beta_{\mathbf{B}}^{(j+1)} &= (\mathbf{P}_{\mathbf{B}}^T)^{-1} \left[(\lambda \mathbf{I}_r + \mathbf{P}^T \mathbf{P}) - \frac{1}{m} (e^T \mathbf{P})^T e^T \mathbf{P} \right]^{-1} \\ &\quad \mathbf{P}^T \left((\mathbf{y} - \psi^{-(j)}) - \frac{e^T (\mathbf{y} - \psi^{-(j)})}{m} e \right) \\ \beta_{\mathbf{N}}^{(j+1)} &= \mathbf{0} \\ b_2^{(j+1)} &= \frac{1}{m} \left[e^T (\mathbf{y} - \psi^{-(j)}) - e^T \mathbf{P} \mathbf{P}_{\mathbf{B}}^T \beta_{\mathbf{B}}^{(j+1)} \right]\end{aligned}\right\} \quad (31)$$

$$\begin{aligned}\xi^{-(j)} &= (\mathbf{y} + e \varepsilon_2) - (\mathbf{P} \mathbf{P}_{\mathbf{B}}^T \beta_{\mathbf{B}}^{(j)} + b_2^{(j)}), \\ \psi^{-(j)} &= \xi^{-(j)} \frac{\min\{1, \exp[p(\xi^{-(j)2} - \tau^2)]\}}{1 + \exp(-p|\xi^{-(j)2} - \tau^2|)}\end{aligned}\quad (32)$$

最后的预测函数为

$$\begin{aligned}f(\mathbf{x}) &= \frac{1}{2} (f_1(\mathbf{x}) + f_2(\mathbf{x})) \\ &= \frac{1}{2} \left(\sum_{i=1}^m \omega_1^T \varphi(\mathbf{x}_i) + b_1 + \sum_{i=1}^m \omega_2^T \varphi(\mathbf{x}_i) + b_2 \right) \\ &= \frac{1}{2} (\mathbf{K}^T \alpha + b_1 + \mathbf{K}^T \beta + b_2)\end{aligned}\quad (33)$$

2.3 改进的稀疏LSTSVR(ISLSTSVR)算法流程

基于ISLSTSVR的PA建模算法流程如图1所示。本算法主要分为两个阶段：基本集B和基本核列P的求解；偏差迭代算法求解模型系数。其中J为偏差迭代的最大次数。

第1阶段利用Nystrom逼近和Cholesky分解得到基本集B和基本核列P。方法如下：从K中随机选择r列得到 K_{Mr} ，逐列迭代寻找使得逼近误差 $\text{tr}(K_{Mr} - \tilde{K}_{Mr})$ 最大的第i列元素用于Cholesky分

解方法计算基本核列 P_i 并将索引i放入基本集B中；将第i列剔除，从剩余核列中计算逼近误差 $\text{tr}(K_{Mr_i} - \tilde{K}_{Mr_i})$ ，如果 $\text{tr}(K_{Mr_i} - \tilde{K}_{Mr_i}) > \rho$ ，则重复上述步骤；直到逼近误差满足要求，即 $\text{tr}(K_{MB} - \tilde{K}_{MB}) \leq \rho$ ，输出B和P。

第2阶段引入偏差 ψ^- 和 ψ^+ 进行鲁棒迭代求解。方法如下：利用式(29)、式(30)更新 $(\alpha^{(j+1)}, b_1^{(j+1)}, \xi^{+(j+1)}, \psi^{+(j+1)})$ ，利用式(31)、式(32)更新 $(\beta^{(j+1)}, b_2^{(j+1)}, \xi^{-(j+1)}, \psi^{-(j+1)})$ 。

3 基于ISLSTSVR的数字预失真系统

预失真的基本思想是预失真器和放大器的级联近似于线性或恒等运算符。基于ISLSTSVR的PA建模方法，本文采用间接学习结构，详细框图如图2所示。

先用PA的输入 $u(n)$ 和输出信号 $z(n)$ 构建逆向模型，估计PA的后逆参数 $(\alpha, b_1), (\beta, b_2)$ ，把后逆参数复制到预失真器中作为前逆补偿PA的非线性记忆特性。数据集的构建采用文献[18]中的时延结构，将时延的输入和输出信号分成实部和虚部。同时，为了增强对PA特性的描述，将输入信号的幅值和相位特性作为增强训练标签。基于此，输入和输出的完整关系可以写成：

$$\begin{aligned} \text{Re}\{y(n)\} &= f_1 \left(\begin{matrix} \text{abs}(x(n)), \text{angle}(x(n)), I(n), Q(n), \\ I(n-1), Q(n-1), I(n-2), Q(n-2), \dots \end{matrix} \right) \end{aligned} \tag{34}$$

$$\begin{aligned} \text{Im}\{y(n)\} &= f_1 \left(\begin{matrix} \text{abs}(x(n)), \text{angle}(x(n)), I(n), Q(n), \\ I(n-1), Q(n-1), I(n-2), Q(n-2), \dots \end{matrix} \right) \end{aligned} \tag{35}$$

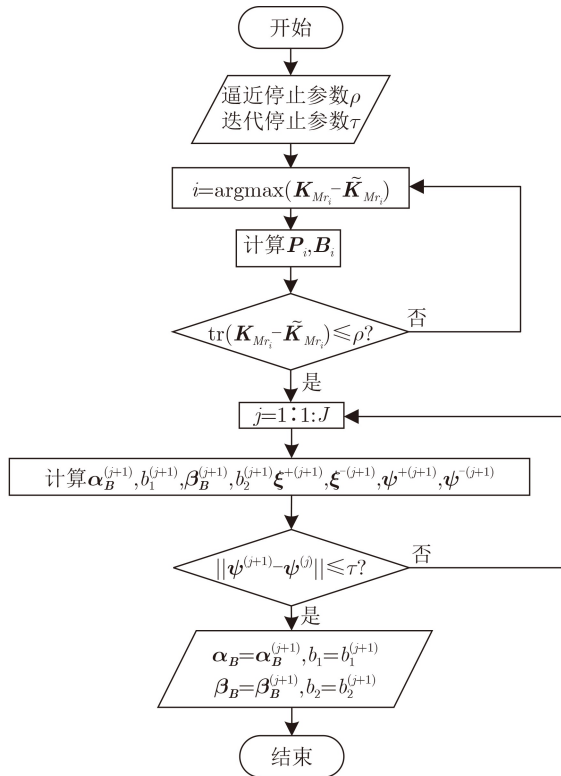


图1 ISLSTSVR算法流程图

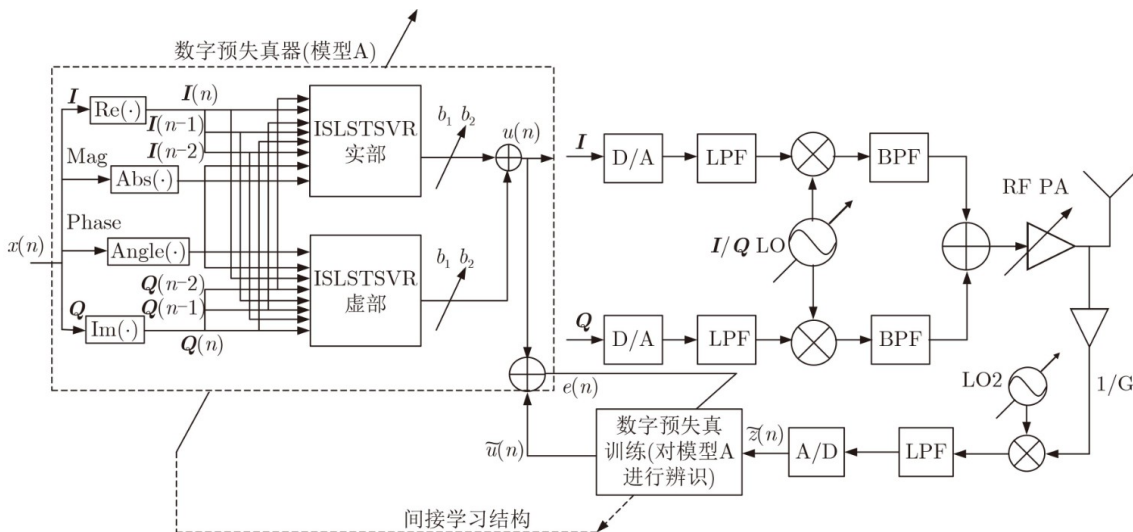


图2 预失真系统框图

4 仿真实验及结果

为了进一步验证提出的基于ISLSTSVR模型的DPD方案的有效性。利用计算机(PC)、数字电源、功率放大器(PA)、Xilinx Zynq UltraScale+ RF-SoC评估板(ZCU111)、矢量信号分析仪(Vector Signal Analyzers, VSA)、衰减器、耦合器、驱动放大器等搭建预失真验证平台,如图3所示。

其中,预失真系统的前馈路径由RFSoC的片上DAC(基带信号发送)、驱动放大器、被测设备(PA)组成;反馈路径上的PA输出经衰减器和耦合器后功分两路,分别连接至频谱分析仪(反馈信号观测)以及RFSoC的片上ADC(采样PA输出);所有的数字信号处理部分均在MATLAB中进行。实验中,利用MATLAB串口模块下载符号速率为40 Msym/s的32QAM测试信号于RFSoC评估板中,在经Tx路径后激励待测功放(基于单管氮化镓(GaN)器件的宽带AB类PA(0.5-3 GHz),工作频点1.8 GHz,饱和输出功率45.5 dBm);一路功分信号被安捷伦公司的N9010A EXA信号分析仪采集进行实时频谱检测,另一路功分信号被RFSoC评估板ADC模块所采集,并通过串口传回MATLAB进行时间对齐处理。RFSoC评估板(ZCU111)使用300 MHz的参考时钟运行,可实现600 MHz基带采样率内信号的下载,内置DAC核采用8倍内插模式,可实现0-2.4 GHz的直接频率转换发射,ADC时钟配置2.4 GHz以实现宽带射频信号直采任务。测试步骤如下:

(1)采用ADS2018设计的32QAM信号,符号速率为40 Msym/s,滚降系数为0.22,8倍过采。下载40000个点到RFSoC评估板。

(2)以320 Msps的采样率采集功率放大器的输出信号用作后逆输入;

(3)基于ISLSTSVR建模方法,构建功放后逆模型,提取后逆参数;

(4)将后逆参数复制于前逆模型并与PA级联,采集预失真系统的输出信号测试线性化效果;

(5)对比TSVR, STSVR, ISLSTSVR 3种逆模预失真算法的线性化效果。

为了验证所提ISLSTSVR算法的建模效果,对实测的PA输入输出数据进行正向建模,并与GMP, SVR, TSVR, STSVR进行对比。首先,对于GMP模型,设置记忆深度 $M = 4$,非线性阶数 $P = 9$;对于幅度相位增强结构的4种SVR模型,设置记忆深度为 $M = 2$,采用高斯核函数映射。其次,对于采用光滑损失函数的STSVR和ISLSTSVR模型,设置平滑参数 $p = 10^4$ 。最后,将 $p = 10^{-3}$ 设置为ISLSTSVR模型中Nystrom逼近的停止参数,并将

$\tau = 10^{-10}$ 设置为迭代的停止参数。为保证模型的泛化性能,从经过时间对齐和归一化后的样本集中选取无交集的训练集和测试集。

表1统计了不同训练样本数情况下, GMP, SVR, TSVR, STSVR, ISLSTSVR 5种模型对于实测PA的建模效果。其中,建模时间和建模准确度分别由训练时间和NMSE来反映,存储资源可以通过模型系数直观体现。由于SVR模型的计算复杂度过高,当训练样本点数超过16000时会出现训练失败,因此在实验中仅统计了其在8000, 12000样本点下的训练结果作为对比。由于TSVR将SVR中的两个不等式约束条件的QP问题转化为一个不等式约束条件的QP问题,因此具有较快的计算速度,然而TSVR仅考虑了经验风险极小化问题,模型解不稀疏,表现在模型系数接近样本数。文献[20]中的STSVR方法采用随机删减的方式降低黑塞矩阵的维度,模型系数得到极大简化,但样本数量较多时,其运算开销仍然过大不符合预期。本文所提ISLSTSVR

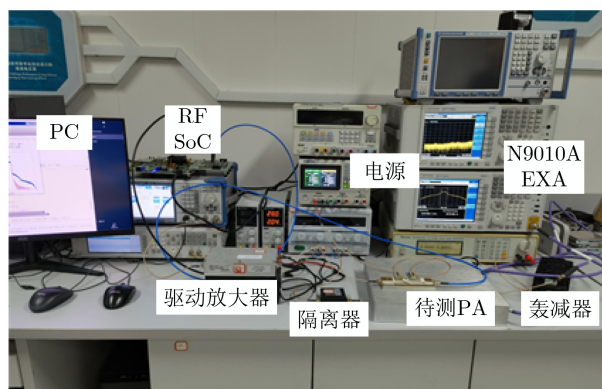


图3 实验平台现场图

表1 不同样本集大小的机器学习模型建模效果对比

模型	样本数	训练时间(s)	NMSE(dB)	模型系数
GMP	8000	0.63	-44.13	148
	12000	0.73	-45.15	148
SVR	8000	1319.00	-46.29	7386
	12000	2599.70	-48.02	11081
TSVR	8000	531.43	-46.91	7332
	12000	2024.80	-47.61	10753
	16000	5017.10	-47.89	14316
STSVR	8000	156.02	-47.27	2002
	12000	456.54	-48.12	3002
	16000	940.72	-48.98	4002
ISLSTSVR	8000	19.97	-47.23	788
	12000	49.37	-48.19	874
	16000	96.95	-48.92	940

方法相比于TSVR, 建模精度平均提升0.6 dB以上, 训练样本点数大于12000时, 其运算时间和模型系数减小2个数量级; 与STSVR相比, 模型精度相当, 而运算速度提升至70倍以上, 模型系数减少1个量级。这表明ISLSTSVR在已有的TSVR结构基础上, 能够保持相当的模型准确度, 同时极大提升模型求解速度。注意到, GMP模型在训练时长和模型系数方面具有显著优势, 这是由于GMP模型系数和多项式结构具有线性加权关系, 可采用一步估计法提取, 而支撑向量回归结构需要迭代求解, 模型复杂度高; 但另一方面, GMP的建模精度逊色于4种SVR结构, 且在同样数量级模型系数的情况下, 本文所提ISLSTSVR的NMSE相比于GMP平均提升3 dB以上, 这同样证明了ISLSTSVR具有较好的建模准确度。为了进一步研究本文所提ISLSTSVR求解过程中所占据的计算资源, 以下对时间复杂度进行分析。需说明下述分析是建立于单边带求解, 并在只涉及矩阵乘法计算以及除开构造核矩阵所耗时间上进行的。首先, 算法流程中, 利用旋转Cholesky迭代获取核矩阵的近似矩阵 \mathbf{K} 的成本为 $O(\sum_{i=1}^r mr_i) = O(mr^2)$, 其中 r 为约简集 B 中的样本总数, m 为训练样本总数; 之后, 式(29)、式(31)中 $(\lambda \mathbf{I}_r + \mathbf{P}^T \mathbf{P}) - (\mathbf{e}^T \mathbf{P})^T \mathbf{e}^T \mathbf{P} / m$ 的计算成本为 $O(mr^2)$; 最后在鲁棒迭代算法求解 α , b_1 时, 其计算成本均为 $O(T_s mr)$, T_s 为迭代总次数; 故ISLSTSVR算法整体时间复杂度为 $O(mr^2 + T_s mr) = O(\max\{r, T_s\}mr)$ 。由于总的迭代次数 T_s 和 B 中的样本个数 r 不会超过训练样本数 m , 故与TSVR($2O(m^3)$)相比有更简单的计算复杂度。以8000样本点为例, $O(m^3)$ 的数量级为11, 由于 $T_s = 300$, $r = 788$, 均小于 m 一个数量级, $O(\max\{r, T_s\}mr)$ 的数量级为9, 故而, 计算资源将减少大约2个量级。此外, 文献[20]提出的稀疏模型(STSVR)在最简情况下的复杂度为 $O(\max\{m_k, r\}T_s m_k^2)$, m_k 为测量异常点, 实验中通常 m_k 略小于 r , 故可简化为 $O(rT_s m_k^2)$, 由于 m_k^2 明显大于 m , 故本文所提出的ISLSTSVR算法与其相比也有更低的时间复杂度。

同样, 通过数字预失真实验对功放的失真特性进行测量。本实验所用的AB类PA的AM/AM曲线与AM/PM曲线绘制分别如图4紫色和蓝色所示; 基于ISLSTSVR的逆模预失真系统对PA的AM/AM, AM/PM失真的矫正效果分别如图4黄色和橘色直线所示。图4显示预失真系统的输出信号幅度随输入线性变化, 且输入输出信号的相位差近似为0, 表明PA的非线性在本文所提预失真结构下得到很好的矫正。




图4 ISLSTSVR逆模预失真的AM/AM, AM/PM曲线

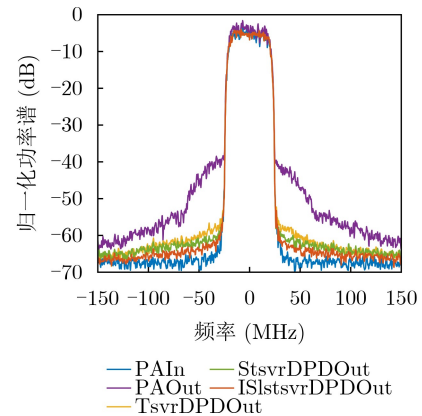


图5 不同模型预失真输出信号的功率谱密度对比

表2 不同模型预失真性能比较

预失真器	ACPR(dB)	
	-30 MHz	+30 MHz
原始功放输出	-39.68	-41.23
TSVR预失真输出	-57.19	-57.20
STSVR预失真输出	-58.89	-58.95
ISLSTSVR预失真输出	-60.28	-61.00

对所提出的ISLSTSVR预失真系统的补偿性能进行测试, 功率谱密度如图5所示。与其他模型相比, 该模型的输出谱线性化效果最好, 线性化后的PA输出信号, 其邻信道功率接近系统底噪水平。此外, 对相邻信道功率的抑制表明, 该方法有效地抑制了带外频谱的扩展。为了定量分析补偿效果, 表2给出了各模型补偿下的ACPR测量值。在-30 MHz下, 该模型可以抑制约20.60 dB, 在+30 MHz下, 该模型可以抑制约19.77 dB。与线性化能力最强的STSVR模型相比, 改进幅度为1.3 dB以上, 表明所提出的DPD模型具有良好的补偿性能。

5 结束语

本文提出了一种基于改进的稀疏最小二乘TSVR(ISLSTSVR)的低复杂度DPD方法, 该方法首先使用改进的损失函数建立基于LSTSVR的功率放

大器模型, 随后围绕简化模型系数的目的, 在求解过程中采用Nystrom逼近和Cholesky分解对核矩阵进行低秩近似从而降低运算复杂度。最后将该模型用作PA后逆估计, 提取预失真参数。预失真实验表明该方法在保证精度的同时模型系数显著减少, 使其能够成为未来卫星通信预失真系统的可行解决方案。

参 考 文 献

- [1] BEIDAS B F. Radio-frequency impairments compensation in ultra high-throughput satellite systems[J]. *IEEE Transactions on Communications*, 2019, 67(9): 6025–6038. doi: [10.1109/TCOMM.2019.2926031](https://doi.org/10.1109/TCOMM.2019.2926031).
- [2] DOSHI R J, GHODGAONKAR D, BHARDHWAJ P S, *et al.* Accurate characterization of high power SSPA under multicarrier operation for satellite communications[C]. 2017 International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT), Kerala, India, 2017: 818–823. doi: [10.1109/ICICICT1.2017.8342670](https://doi.org/10.1109/ICICICT1.2017.8342670).
- [3] 黄明光, 朱丹, 何俊, 等. Ka波段宽频带高线性空间行波管研制[J]. *电子与信息学报*, 2017, 39(11): 2777–2781. doi: [10.11999/JEIT161267](https://doi.org/10.11999/JEIT161267).
HUANG Mingguang, ZHU Dan, HE Jun, *et al.* Development of Ka-band broadband, high-linearity space traveling wave tube[J]. *Journal of Electronics & Information Technology*, 2017, 39(11): 2777–2781. doi: [10.11999/JEIT161267](https://doi.org/10.11999/JEIT161267).
- [4] CHEN Wenhua, ZHANG Silong, LIU Youjiang, *et al.* Efficient pruning technique of memory polynomial models suitable for PA behavioral modeling and digital predistortion[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2014, 62(10): 2290–2299. doi: [10.1109/TMTT.2014.2351779](https://doi.org/10.1109/TMTT.2014.2351779).
- [5] 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. doi: [10.1109/TMTT.2014.2360845](https://doi.org/10.1109/TMTT.2014.2360845).
- [6] REINA-TOSINA J, ALLEGUE-MARTÍNEZ M, CRESPO-CADENAS C, *et al.* Behavioral modeling and predistortion of power amplifiers under sparsity hypothesis[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2015, 63(2): 745–753. doi: [10.1109/TMTT.2014.2387852](https://doi.org/10.1109/TMTT.2014.2387852).
- [7] LI Mingyu, YANG Zhenxing, ZHANG Zhongming, *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. doi: [10.1109/LMWC.2016.2549024](https://doi.org/10.1109/LMWC.2016.2549024).
- [8] BECERRA J A, MADERO-AYORA M J, REINA-TOSINA J, *et al.* A doubly orthogonal matching pursuit algorithm for sparse predistortion of power amplifiers[J]. *IEEE Microwave and Wireless Components Letters*, 2018, 28(8): 726–728. doi: [10.1109/LMWC.2018.2845947](https://doi.org/10.1109/LMWC.2018.2845947).
- [9] 赵辉, 莫谨荣, 王薇, 等. OFDM系统中基于压缩感知的非线性失真恢复研究[J]. *电子与信息学报*, 2021, 43(7): 1907–1912. doi: [10.11999/JEIT200374](https://doi.org/10.11999/JEIT200374).
ZHAO Hui, MO Jinrong, WANG Wei, *et al.* Research on nonlinear distortion recovery based on compressed sensing in OFDM system[J]. *Journal of Electronics & Information Technology*, 2021, 43(7): 1907–1912. doi: [10.11999/JEIT200374](https://doi.org/10.11999/JEIT200374).
- [10] BECERRA J A, MADERO-AYORA M J, REINA-TOSINA J, *et al.* A reduced-complexity doubly orthogonal matching pursuit algorithm for power amplifier sparse behavioral modeling[C]. 2019 IEEE Topical Conference on RF/Microwave Power Amplifiers for Radio and Wireless Applications (PAWR), Orlando, USA, 2019: 1–3. doi: [10.1109/PAWR.2019.8708723](https://doi.org/10.1109/PAWR.2019.8708723).
- [11] BECERRA J A, AYORA M J M, REINA-TOSINA J, *et al.* Sparse identification of Volterra models for power amplifiers without pseudoinverse computation[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2020, 68(11): 4570–4578. doi: [10.1109/TMTT.2020.3016967](https://doi.org/10.1109/TMTT.2020.3016967).
- [12] CRESPO-CADENAS C, MADERO-AYORA M J, BECERRA J A, *et al.* A fast sparse Bayesian pursuit approach for power amplifier linearization[C]. 2021 IEEE MTT-S International Wireless Symposium (IWS), Nanjing, China, 2021: 1–3. doi: [10.1109/IWS52775.2021.9499382](https://doi.org/10.1109/IWS52775.2021.9499382).
- [13] PENG Jun, HE Songbai, WANG Bingwen, *et al.* Digital predistortion for power amplifier based on sparse Bayesian learning[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2016, 63(9): 828–832. doi: [10.1109/TCSII.2016.2534718](https://doi.org/10.1109/TCSII.2016.2534718).
- [14] BECERRA J A, MADERO-AYORA M J, NOGUER R G, *et al.* On the optimum number of coefficients of sparse digital predistorters: A Bayesian approach[J]. *IEEE Microwave and Wireless Components Letters*, 2020, 30(12): 1117–1120. doi: [10.1109/LMWC.2020.3027878](https://doi.org/10.1109/LMWC.2020.3027878).
- [15] LIU Zhijun, HU Xin, WANG Weidong, *et al.* A joint PAPR reduction and digital predistortion based on real-valued neural networks for OFDM systems[J]. *IEEE Transactions on Broadcasting*, 2022, 68(1): 223–231. doi: [10.1109/TBC.2021.3132158](https://doi.org/10.1109/TBC.2021.3132158).
- [16] WANG Zonghao, CHEN Wenhua, SU Gongzhe, *et al.* Low computational complexity digital predistortion based on direct learning with covariance matrix[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2017, 65(11): 4274–4284. doi: [10.1109/TMTT.2017.2690290](https://doi.org/10.1109/TMTT.2017.2690290).

- [17] ZHANG Yikang, LI Gang, LI Hongmin, *et al.* Simplified vector decomposition time-delay neural network model for RF power amplifier modeling and digital predistortion[C]. 2021 International Conference on Microwave and Millimeter Wave Technology (ICMMT), Nanjing, China, 2021: 1–3. doi: [10.1109/ICMMT52847.2021.9617973](https://doi.org/10.1109/ICMMT52847.2021.9617973).
- [18] CAI Jialin, YU Chao, SUN Lingling, *et al.* Dynamic behavioral modeling of RF power amplifier based on time-delay support vector regression[J]. *IEEE Transactions on Microwave Theory and Techniques*, 2019, 67(2): 533–543. doi: [10.1109/TMTT.2018.2884414](https://doi.org/10.1109/TMTT.2018.2884414).
- [19] XU Jin, JIANG Weiliang, MA Linhua, *et al.* Augmented time-delay twin support vector regression-based behavioral modeling for digital predistortion of RF power amplifier[J]. *IEEE Access*, 2019, 7: 59832–59843. doi: [10.1109/ACCESS.2019.2915281](https://doi.org/10.1109/ACCESS.2019.2915281).
- [20] CAI Tianfu, LI Mingyu, YAO Yao, *et al.* An improved nonlinear smooth twin support vector regression based-behavioral model for joint compensation of frequency-dependent transmitter nonlinearities[J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2021, 31(6): e22636. doi: [10.1002/mmce.22636](https://doi.org/10.1002/mmce.22636).
- [21] CHAPELLE O. Training a support vector machine in the primal[J]. *Neural Computation*, 2007, 19(5): 1155–1178. doi: [10.1162/neco.2007.19.5.1155](https://doi.org/10.1162/neco.2007.19.5.1155).
- [22] SUYKENS J A K and VANDEWALLE J. Least squares support vector machine classifiers[J]. *Neural Processing Letters*, 1999, 9(3): 293–300. doi: [10.1023/A:1018628609742](https://doi.org/10.1023/A:1018628609742).
- [23] CHEN Li and ZHOU Shuisheng. Sparse algorithm for robust LSSVM in primal space[J]. *Neurocomputing*, 2018, 275: 2880–2891. doi: [10.1016/j.neucom.2017.10.011](https://doi.org/10.1016/j.neucom.2017.10.011).
- [24] ZHOU Shuisheng. Sparse LSSVM in primal using Cholesky factorization for large-scale problems[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(4): 783–795. doi: [10.1109/TNNLS.2015.2424684](https://doi.org/10.1109/TNNLS.2015.2424684).
- 代志江: 男, 讲师, 博士, 研究方向为无线通信射频发射机设计.
孔淑曼: 女, 硕士生, 研究方向为超宽带数字预失真.
李明玉: 男, 教授, 博士生导师, 研究方向为射频电路与系统.
蔡天赋: 男, 博士生, 研究方向为超宽带数字预失真.
靳一: 男, 博士, 研究方向为卫星通信与网络.
徐常志: 男, 研究员, 博士, 研究方向为卫星通信与网络.

责任编辑: 马秀强