

用于干扰对消的稀疏约束卡尔曼滤波算法

郝治理, 刘春生, 周青松

(国防科技大学电子对抗学院, 合肥, 230037)

摘要 无人机等小型平台上干扰机的收发隔离问题是影响其收发同时工作的关键。对于动态稀疏系统来说, 常规的卡尔曼滤波算法并未考虑干扰信号耦合路径的稀疏性, 对路径衰减系数的辨识精度不够, 导致隔离性能不佳。针对此问题, 从 KF 算法的修正步出发, 将其等效为一个凸问题, 并在此基础上, 增加对待估计参数的稀疏性约束, 重新推导了算法的修正步, 提出了一种稀疏约束的 KF 算法, 充分利用了待辨识系统的先验信息, 提高了估计参数的稀疏倾向性。理论分析和仿真结果表明, 新算法能够有效适用于动态稀疏环境下的系统辨识, 提高了 KF 算法对于动态稀疏系统的辨识精度, 并且能够将干扰机的收发隔离度提高 3~5 dB, 改善了干扰机的收发隔离性能。

关键词 干扰机; 收发隔离; 系统辨识; 卡尔曼滤波; 凸优化; 稀疏正则化

DOI 10.3969/j.issn.1009-3516.2020.02.012

中图分类号 TN973.3 **文献标志码** A **文章编号** 1009-3516(2020)02-0078-06

A Sparse Constraint Kalman Filter Algorithm for Interference Cancellation

HAO Zhili, LIU Chunsheng, ZHOU Qingsong

(College of Electronic Countermeasure, National University of Defense Technology, Hefei 230037, China)

Abstract: The transceiver isolation of jammers on small platforms such as UAV is the key to affect the simultaneous operation of transceiver. As for the dynamic sparse systems, the conventional Kalman filter (KF) algorithm does not consider the sparsity of the coupling paths of interference signals, and the identification accuracy of paths attenuation coefficients are not enough, so that the isolation performance is poor. Aimed at the problems that starting from the correction step of KF algorithm and regarding this as equivalent to a convex problem, on the basis of this, the sparse constraints on estimated parameters are added, the correction steps of the algorithm are deduced again, and a KF algorithm with sparse constraint (SC) is proposed, by so doing, this makes full use of the prior information of the system to be identified and improves the sparse tendency of estimated parameters. The theoretical analysis and the simulation results show that the new algorithm can effectively apply to the system identification in the dynamic sparse environment, and improve the identification accuracy of KF algorithm for the dynamic sparse system. Moreover, the isolation degree of transceiver of jammer can be improved by 3~5 dB, improving the isolation performance of jammer.

Key words: jammer; transceiver isolation; system identification; Kalman filter; convex optimization; sparse regularization

收稿日期: 2019-07-01

作者简介: 郝治理(1995—), 男, 河南周口人, 硕士生, 主要从事干扰机收发隔离技术研究。E-mail: hzlxx13@163.com

引用格式: 郝治理, 刘春生, 周青松. 用于干扰对消的稀疏约束卡尔曼滤波算法[J]. 空军工程大学学报(自然科学版), 2020, 21(2): 78-83.
HAO Zhili, LIU Chunsheng, ZHOU Qingsong. Sparse Constraint Kalman Filter Algorithm for Interference Cancellation[J]. Journal of Air Force Engineering University (Natural Science Edition), 2020, 21(2): 78-83.

在日益激烈的电子战中,干扰机作为实施有源干扰的关键设备,发挥着重要作用,它可以通过向敌方雷达发射各种样式的干扰信号,使敌方雷达无法正常工作^[1]。然而对于架设在无人机等小型平台上的干扰机,尤其是收发一体的干扰机,其发射天线和接收天线之间存在着较强的电磁耦合现象。干扰机发射的干扰信号往往会有部分耦合到接收端,影响接收机的正常工作,轻则会降低接收机的灵敏度,减小侦察作用距离,重则形成自激励,无法检测信号^[2-3]。因此,如何解决干扰机的收发隔离问题是保证其收发同时工作的关键。国内外比较常用的收发隔离方法有收发分时、极化隔离、物理隔离、空间隔离等^[3]。近年来,系统辨识技术成为了研究的热点,它从信号处理的角度出发,将干扰机的外界耦合环境看作是一个待辨识的系统,利用系统辨识方法对其进行辨识。一旦辨识出系统传递函数,就可以根据己方发射的干扰信号和系统传递函数重构耦合到接收端的干扰信号,最后在接收端进行对消,实现收发隔离。文献[4~7]研究了基于静态环境下的系统辨识技术,可以在一定程度上提高干扰机的收发隔离度。目前,针对动态环境的系统辨识方法也有很多的研究,KF算法就是其中一种比较成熟的算法^[8]。

现实环境中很多系统都具有稀疏性质,即系统的冲激响应在时间域上只有少量的非零值,比如水声通信信道、回声路径等^[9]。针对动态稀疏系统的辨识问题,文献[10]结合压缩感知技术,首先估计出系统参数的支撑集,然后再利用降阶的KF算法对系统参数进行估计。不足之处在于没有分析这种算法的稳定性,也没有与常规算法进行对比。文献[11]将伪测量技术应用于卡尔曼滤波的递推过程中,提高了算法在稀疏环境下的辨识性能。文献[12]采用期望最大化(Expectation-Maximization, EM)方法,在期望步利用KF算法来提供一步预测值,然后在最大化步骤中加入 l_1 范数等稀疏性约束,最后利用软阈值方法,提高了待辨识系统参数的稀疏性。文献[13]提出了一种稀疏融合卡尔曼滤波算法,它同样是利用迭代软阈值方法不断地更新系统的稀疏模型,并且结合了伪测量技术,在提高系统辨识性能的同时,具有较好的鲁棒性。文献[14]从KF算法的修正步出发,将其等效为一个凸优化问题,然后对等效后的问题加入稀疏约束,提出了一种稀疏卡尔曼滤波(SKF)算法。但其是利用凸优化工具箱进行求解,并未给出加入约束以后的解析解,也没有对估计误差协方差矩阵进行修正。本文是在文献[14]的基础上,进一步推导出了加入稀疏约束以

后系统参数的解析解和预测误差协方差矩阵的递推表达式,提出了一类SCKF算法。并且引入了一种较 l_1 范数更逼近于 l_0 范数的稀疏约束函数,期望进一步提高KF算法对动态稀疏系统的辨识精度,进而能够提高干扰机的收发隔离性能。

1 问题描述

为了运用系统辨识技术解决干扰机的收发隔离问题,首先要将干扰信号耦合路径等效为一个待辨识系统,构建基于系统辨识的收发隔离模型见图1^[6]。

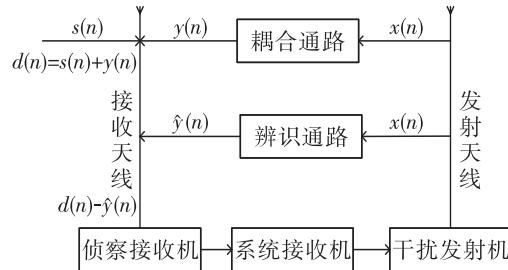


图1 基于系统辨识的收发隔离模型

图1中, n 表示任意大于零的时刻, $x(n)$ 表示干扰机发射的干扰信号, $y(n)$ 表示干扰信号经过耦合通路到达接收端的耦合干扰信号, $s(n)$ 表示正在侦察的雷达信号,令:

$$d(n) = s(n) + y(n) \quad (1)$$

式中: $d(n)$ 表示接收机接收到的混合信号,在这里构建一个辨识通路,其结构应该与耦合通路一致; $\hat{y}(n)$ 表示干扰信号经过辨识通路到达接收端的信号。如果系统辨识结果比较精确,那么在接收端进行 $d(n) - \hat{y}(n)$,便可以将耦合干扰信号对消掉。因此,整个过程的关键在于寻找一种比较好的系统辨识方法,能够使 $\hat{y}(n)$ 尽可能地逼近 $y(n)$ 。

通常可以利用一组FIR自适应滤波器来近似耦合通路,干扰信号 $x(n)$ 经过耦合路径到达接收端的过程可表示为:

$$y(n) = \sum_{i=1}^M w_i(n)x(n-i+1) + v(n) =$$

$$x^T(n) w(n) + v(n) \quad (2)$$

式中: M 为滤波器阶数; $w(n)$ 为耦合路径对应的衰减系数,在本文的稀疏条件下,存在部分的 $w_i(n) = 0 (i=1, 2, \dots, M)$; $v(n)$ 为均值为 0, 方差为 σ_v^2 的系统噪声。在这里,滤波器各元件之间的延时间隔设为采样间隔 t_s ,假设耦合路径所对应的最大延时为 t_{\max} ,为了不遗漏任意一条耦合路径,则必须要满足 $t_{\max}/t_s \leq M$ 。

实际上,当载有干扰机的载体运动时,比如车

载,机载的环境下, $w(n)$ 往往是随时间发生变化的,一般情况下其变化符合高斯-马尔科夫过程,它的模型可以表示:

$$w(n) = Fw(n-1) + u(n) = F^n w(0) + \sum_{i=1}^n u(i) \quad (3)$$

式中: F 表示 $M \times M$ 的状态转移矩阵; $u(n)$ 表示驱动噪声,服从分布 $u(n) \sim N(0, R(n))$; $w(0)$ 服从分布 $w(0) \sim N(w_0, C_0)$ 。因为 $w(n)$ 是稀疏的,其中有很多元素为 0,假设它的支撑集为 I ,则会有 $w_i(n) = 0, u_i(n) = 0, i \notin I$,即待辨识系统参数和驱动噪声在支撑集之外的元素为零,并且对应的 $C_{il} = \sigma_0^2 I$, $R_{il}(n) = \sigma_d^2(n) I$ 。这里假设支撑集不随时间发生变化,并且非零元素的个数以及它们在待辨识系统参数中的位置是未知的。

2 稀疏约束卡尔曼滤波算法

针对第 1 节所描述的动态系统,常规 KF 算法求解此问题的递推形式为:

预测:

$$\begin{aligned} \hat{w}(n|n-1) &= F\hat{w}(n-1|n-1) \\ M(n|n-1) &= FM(n-1|n-1)F^T + R(n) \end{aligned} \quad (4)$$

$$K(n) = \frac{M(n|n-1)x(n)}{\sigma_v^2 + x^T(n)M(n|n-1)x(n)}$$

修正:

$$\begin{aligned} e(n) &= y(n) - x^T(n)\hat{w}(n|n-1) \\ \hat{w}(n|n) &= \hat{w}(n|n-1) + K(n)e(n) \\ M(n|n) &= (I - K(n)x^T(n))M(n|n-1) \end{aligned} \quad (5)$$

式中: $K(n)$ 为增益矩阵; $M(n|n)$ 为预测误差协方差矩阵; $e(n)$ 为误差,也称为新息。本文待辨识参数 $w(n)$ 是稀疏的,常规的卡尔曼滤波并未考虑到这一先验信息,针对此问题,这里将修正步中 $w(n)$ 的递推形式转换为求解一个凸问题^[15]:

minimize

$$\begin{aligned} &(y(n) - x^T(n)w(n))^T Q^{-1}(n)(y(n) - \\ &x^T(n)w(n)) + (w(n) - \hat{w}(n|n-1))^T \cdot \\ &M^{-1}(n|n-1)(w(n) - \hat{w}(n|n-1)) \end{aligned} \quad (6)$$

式中: $Q(n)$ 为观测噪声 $v(n)$ 的协方差矩阵,在这里即为 σ_v^2 ,文献[14]在式(6)的基础上加入了 $w(n)$ 的 l_1 范数约束,进而提高了 $\hat{w}(n|n)$ 的稀疏倾向性,其目标函数如下:

minimize

$$\begin{aligned} &(y(n) - x^T(n)w(n))^T Q^{-1}(n)(y(n) - \\ &x^T(n)w(n)) + (w(n) - \hat{w}(n|n-1))^T \cdot \\ &M^{-1}(n|n-1)(w(n) - \hat{w}(n|n-1)) + \\ &\eta \|w(n)\|_1 \end{aligned} \quad (7)$$

文献[14]是直接利用凸优化工具箱求解目标函数(7),没有给出 $w(n)$ 的解析解,并且没有注意到预测误差协方差矩阵的变化,没有对它的递推形式进行更新。针对此问题,本文推导了增加稀疏约束以后 $w(n)$ 的解析解以及新形式下的预测误差协方差矩阵,并引用了一种近似零范数的函数,期望进一步提高算法的辨识精度。

首先,定义函数 $f(w(n))$ 是关于 $w(n)$ 的稀疏性约束,它可以取 l_1 范数或者其他更接近于 l_0 范数的函数。重新将目标函数(6)改写为:

minimize

$$\begin{aligned} &(y(n) - x^T(n)w(n))^T Q^{-1}(n)(y(n) - \\ &x^T(n)w(n)) + (w(n) - \hat{w}(n|n-1))^T M^{-1}(n|n-1) \\ &(w(n) - \hat{w}(n|n-1)) + \eta f(w(n)) \end{aligned} \quad (8)$$

对式(8)进行求导,并令其导数为零,可以得到:

$$\begin{aligned} &x(n)Q^{-T}(n)y(n) + x(n)Q^{-1}(n)y(n) - \\ &x(n)Q^{-T}(n)x^T(n)w(n) - x(n)Q^{-1}(n)x^T(n)w(n) - \\ &M^{-T}(n|n-1)w(n) - M^{-1}(n|n-1)w(n) + \\ &M^{-T}(n|n-1)\hat{w}(n|n-1) + M^{-1}(n|n-1) \\ &\hat{w}(n|n-1) - \eta \nabla^s f(w(n)) = 0 \end{aligned} \quad (9)$$

式中: $\nabla^s f(w(n))$ 表示 $f(w(n))$ 的次微分,这是因为函数 $f(w(n))$ 在某些点可能不可导,故用其次微分代替。以 $\|w(n)\|_1$ 为例,它在 $w_i(n) = 0$ 处不可导,因此取它的次微分为 $\text{sgn}(w(n))$, $\text{sgn}(\cdot)$ 为符号函数,它的定义为:

$$\text{sgn}(w_i(n)) = \begin{cases} \frac{w_i(n)}{|w_i(n)|}, & w_i(n) \neq 0 \\ 0, & \text{elsewhere} \end{cases} \quad (10)$$

对式(9)进行化简可得:

$$\begin{aligned} &x(n)Q^{-1}(n)x^T(n)w(n) + M^{-1}(n|n-1)w(n) = \\ &x(n)Q^{-1}(n)y(n) + M^{-1}(n|n-1) \cdot \hat{w}(n|n-1) - \\ &\frac{\eta}{2} \nabla^s f(w(n)) \end{aligned} \quad (11)$$

因为 $w(n)$ 是未知的待辨识系统参数,无法直接利用,故这里假设 $\nabla^s f(w(n))$ 从预测步到修正步之间不会发生明显的变化,即 $\nabla^s f(w(n)) \approx \nabla^s f(\hat{w}(n|n-1))$,取 $\xi = \eta/2$,进而可以得到:

$$\begin{aligned} \hat{w}(n|n) &= (x(n)Q^{-1}(n)x^T(n) + M^{-1}(n|n-1))^{-1} \cdot \\ &(x(n)Q^{-1}(n)y(n) + M^{-1}(n|n-1)\hat{w}(n|n-1) - \\ &\xi \nabla^s f(\hat{w}(n|n-1))) \end{aligned} \quad (12)$$

利用矩阵求逆引理,可以将式(12)化简为:

$$\begin{aligned} \hat{w}(n|n) &= (M(n|n-1) - \\ &K(n)x^T(n)M(n|n-1))(x(n)Q^{-1}(n)y(n) + \\ &M^{-1}(n|n-1)\hat{w}(n|n-1) - \xi \nabla^s f(\hat{w}(n|n-1))) \end{aligned} \quad (13)$$

式中: $K(n)$ 表示增益矩阵,在这里与式(4)保持一致。进一步化简,可以得到 $w(n)$ 的解析解为:

$$\begin{aligned} \hat{\mathbf{w}}(n|n) &= \hat{\mathbf{w}}(n|n-1) + \mathbf{K}(n)(y(n) - \\ &\quad \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1)) + (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1) \\ &\quad \xi \nabla^s f(\hat{\mathbf{w}}(n|n-1)) \end{aligned} \quad (14)$$

对比式(14)和式(5)中 $\mathbf{w}(n)$ 的递推式,式(14)多了最后一项,因此预测误差协方差矩阵也会发生变化,故需要重新推导它的递推式,根据定义,预测误差协方差矩阵为:

$$\begin{aligned} \mathbf{M}(n|n) &= \\ E[(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n))(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n))^T] & \quad (15) \\ \text{将式(14)代入到式(15)中,可以得到:} \\ \mathbf{M}(n|n) &= E[(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n-1) - \\ &\quad \mathbf{K}(n)(y(n) - \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1)) - \\ &\quad (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1)\xi \nabla^s f \cdot \\ &\quad (\hat{\mathbf{w}}(n|n-1)))(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n-1) - \\ &\quad \mathbf{K}(n)(y(n) - \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1)) - (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I}) \cdot \\ &\quad \mathbf{M}(n|n-1)\xi \nabla^s f(\hat{\mathbf{w}}(n|n-1)))^T] \end{aligned} \quad (16)$$

为了方便后面的计算,令:

$$\begin{aligned} \mathbf{m}(n) &= (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1) \cdot \\ &\quad \xi \nabla^s f(\hat{\mathbf{w}}(n|n-1)) \end{aligned} \quad (17)$$

将式(17)代入到式(16)中,进一步化简可得,

$$\begin{aligned} \mathbf{M}(n|n) &= (\mathbf{I} - \mathbf{K}(n)\mathbf{x}^T(n))\mathbf{M}(n|n-1) - \\ E[(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n-1))\mathbf{m}^T(n)] &- \\ E[\mathbf{m}(n)(\mathbf{w}(n) - \hat{\mathbf{w}}(n|n-1))^T] &+ E[\mathbf{K}(n)(y(n) - \\ &\quad \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1))\mathbf{m}^T(n)] + E[\mathbf{m}(n)(y(n) - \\ &\quad \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1))^T\mathbf{K}^T(n)] + \mathbf{m}(n)\mathbf{m}^T(n) \end{aligned} \quad (18)$$

根据式(18)可见,其第1项与加入约束之前的标准KF算法相同,而后面几项均与 $\mathbf{m}(n)$ 有关,并且式(18)中含有待估计量 $\mathbf{w}(n)$ 的期望,不能直接计算。然而在算法的收敛过程中,根据式(15)预测误差协方差矩阵的定义,当满足 $\text{tr}(\mathbf{M}(n|n))/\mathbf{M} \leq \delta$ 时,这里 δ 取一个较小的数,作为阈值,可以作一个近似,令 $E[\mathbf{w}(n)] \approx \hat{\mathbf{w}}(n|n)$,并代入到式(18)中化简得到:

$$\begin{aligned} \mathbf{M}(n|n) &= \\ (\mathbf{I} - \mathbf{K}(n)\mathbf{x}^T(n))\mathbf{M}(n|n-1) - \mathbf{m}(n)\mathbf{m}^T(n) & \quad (19) \end{aligned}$$

经过上述推导,得到了增加稀疏约束以后 $\mathbf{w}(n)$ 的解析解和新的预测误差协方差矩阵。将这种方法统称为SCKF算法,并对该算法进行总结如下。

初始化: $\sigma_0^2, \sigma_d^2, \xi, \mathbf{F}, \mathbf{w}(0) = 0, \mathbf{M}(0|0) = \delta_0^2 \mathbf{I}$

for $n=1, 2, \dots, N$

预测:

$$\begin{aligned} \hat{\mathbf{w}}(n|n-1) &= \mathbf{F}\hat{\mathbf{w}}(n-1|n-1) \\ \mathbf{M}(n|n-1) &= \mathbf{F}\mathbf{M}(n-1|n-1)\mathbf{F}^T + \mathbf{R}(n) \\ \mathbf{K}(n) &= \frac{\mathbf{M}(n|n-1)\mathbf{x}(n)}{\sigma_v^2 + \mathbf{x}^T(n)\mathbf{M}(n|n-1)\mathbf{x}(n)} \\ \text{if } \text{tr}(\mathbf{M}(n|n-1))/\mathbf{M} \leq \delta & \end{aligned}$$

修正:

$$\begin{aligned} \hat{\mathbf{w}}(n|n) &= \\ \hat{\mathbf{w}}(n|n-1) + \mathbf{K}(n)(y(n) - \mathbf{x}^T(n)\hat{\mathbf{w}}(n|n-1)) + \\ &\quad (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1)\xi \nabla^s f \cdot \\ &\quad (\hat{\mathbf{w}}(n|n-1))^T \end{aligned}$$

$$\begin{aligned} \mathbf{M}(n|n) &= \\ (\mathbf{I} - \mathbf{K}(n)\mathbf{x}^T(n))\mathbf{M}(n|n-1) - m(n)\mathbf{m}^T(n) & \quad \text{else} \\ \hat{\mathbf{w}}(n|n) &= \hat{\mathbf{w}}(n|n-1) + \mathbf{K}(n)e(n) \\ \mathbf{M}(n|n) &= (\mathbf{I} - \mathbf{K}(n)\mathbf{x}^T(n))\mathbf{M}(n|n-1) \end{aligned}$$

end
end for
当 $f(\mathbf{w}(n)) = \|\mathbf{w}(n)\|_1$ 时,为了与文献[14]算法有所区别,这里命名为 l_1 -KF算法,根据表1可知,当 $\text{tr}(\mathbf{M}(n|n-1))/\mathbf{M} \leq \delta$ 时,它的修正步骤如下:

$$\begin{aligned} \hat{\mathbf{w}}(n|n) &= \hat{\mathbf{w}}(n|n-1) + \mathbf{K}(n)(y(n) - \mathbf{x}^T(n) \cdot \\ &\quad \hat{\mathbf{w}}(n|n-1)) + (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I}) \cdot \\ &\quad \mathbf{M}(n|n-1)\xi \text{sgn}(\hat{\mathbf{w}}(n|n-1)) \end{aligned} \quad (20)$$

$$\begin{aligned} \mathbf{M}(n|n) &= (\mathbf{I} - \mathbf{K}(n)\mathbf{x}^T(n))\mathbf{M}(n|n-1) - \\ &\quad (\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1)\xi \text{sgn}(\hat{\mathbf{w}}(n|n-1)) \cdot \\ &\quad [(\mathbf{K}(n)\mathbf{x}^T(n) - \mathbf{I})\mathbf{M}(n|n-1)\xi \text{sgn}(\hat{\mathbf{w}}(n|n-1))]^T \end{aligned} \quad (21)$$

为了进一步提高对稀疏参数 $\mathbf{w}(n)$ 的辨识精度,本文利用一种新的稀疏约束函数^[16],令:

$$f(\mathbf{w}(n)) = \sum_{k=1}^M (1 - e^{-\tau |w_k(n)|}) \quad (22)$$

式中: τ 是一个正实数,为了进一步说明 $f(\mathbf{w}(n))$ 对 l_0 范数的逼近程度,图2为 $M=1, \tau=50$ 时, $f(\mathbf{w}(n))$ 与 l_1, l_0 范数在 $[-1, 1]$ 区间上的对比。

如图2所示,在一维空间中, $f(\mathbf{w})$ 比 l_1 范数更接近 l_0 范数,类比在 M 维空间也是如此,并且根据式(22)可知 τ 取值越大, $f(\mathbf{w}(n))$ 越接近 l_0 范数。

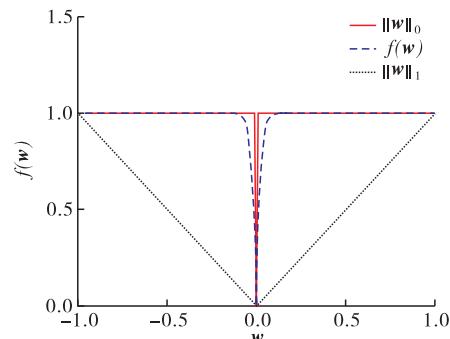


图2 $f(\mathbf{w})$ 与 l_1, l_0 范数

根据式(14),要对函数 $f(\mathbf{w}(n))$ 进行求导,这里同样需要利用次微分,可以得到:

$$\left\{ \nabla^s f^\tau(\mathbf{w}(n)) \right\}_k = \tau \text{sgn}(w_k(n)) e^{-\tau |w_k(n)|} \quad (23)$$

将加入式(22)约束的方法称为 l_0 -KF算法,将式

(23)代入到表 1,即可以得到它的完整递归过程。

3 仿真实验

3.1 性能指标

在进行仿真实验之前,首先定义几个性能指标,用来评价算法对稀疏系统的辨识性能以及对耦合干扰信号的隔离性能。

1) 归一化均方误差 NMSE,一般定义为:

$$\frac{\|\mathbf{w}(n) - \hat{\mathbf{w}}(n)\|_2^2}{\|\mathbf{w}(n)\|_2^2} \quad (24)$$

式中: $\mathbf{w}(n)$ 为真实的滤波器矢量; $\hat{\mathbf{w}}(n)$ 为经过辨识算法估计出的滤波器矢量。NMSE 越小,表示估计值越接近于真实值,即算法的辨识性能越好。

2) 隔离度 I ,定义为:

$$I = 10 \lg \frac{p_t}{p_r} \quad (25)$$

式中: p_t 为干扰机发射的干扰信号功率; p_r 为经过隔离以后的残余干扰信号功率。可以看出隔离度 I 反映了发射干扰信号相对于残余干扰信号的大小,当隔离度达到发射干扰信号与系统噪声的功率比时,表示干扰信号被隔离至噪声水平,此时可以很好地实现收发同时工作。

3) 隔离后信干比 SIR,定义为:

$$SIR = 10 \lg p_s / p_r \quad (26)$$

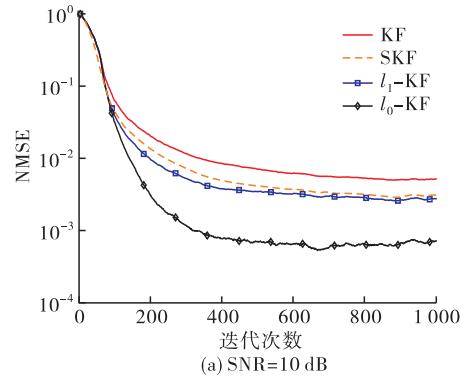
式中: p_s 为接收机接收到的雷达信号的功率; p_r 与前面定义相同。当发射干扰信号功率一定时,可以看出隔离后的信干比越大表示隔离性能越好。

3.2 仿真分析

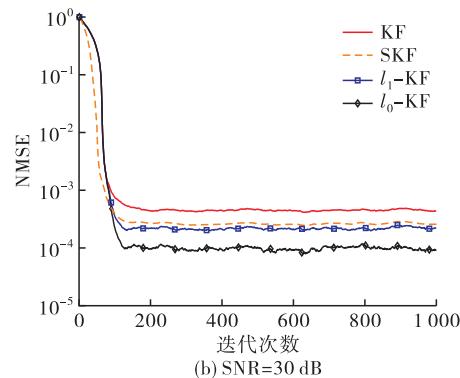
验证本文所提出的 SCKF 算法相对于常规算法和文献[14]中的 SKF 算法对于稀疏路径辨识是否具有优势。假设待辨识参数长度为 64,其中只有 4 条干扰耦合路径对应的衰减系数为非零值,它们的位置随机挑选,幅值在 [0.1, 1] 之间,其他位置全为 0。设 $\sigma_0^2 = 0.02$, $\sigma_d^2 = 10e-6$, 状态转移矩阵 $\mathbf{F} = 0.99999\mathbf{I}$, 在不同探测信噪比(SNR)下,分别进行 100 次试验,对各算法的 NMSE 取均值。

图 3 分别对比了探测信噪比为 10 dB 和 30 dB 时的系统辨识误差曲线。其中,SKF 算法的 ξ 取值分别为 0.1 和 1,表 1 给出了本文 SCKF 算法的实验参数取值。结合 SCKF 算法和式(23)可知 τ 的取值会影响修正步骤中的 $\hat{\mathbf{w}}(n|n)$,取值过大会导致算法失调,取值过小又会使 $f(\mathbf{w})$ 的稀疏倾向性不足,这里参照文献[16]取 τ 为 50。分析图 3(a)和图 3(b)可以看出在稀疏条件下,本文所提出的 SCKF 算法的辨识性能要优于常规 KF 算法和 SKF 算法。

其中, l_0 -KF 算法最优, l_1 -KF 算法与 SKF 算法的性能比较接近。当探测信噪比较低时, l_0 -KF 算法的优势比较明显;当探测信噪比较高时,各算法的性能均有所提升, l_0 -KF 算法的优势有所下降。



(a) SNR=10 dB



(b) SNR=30 dB

图 3 系统辨识误差对比情况

表 1 实验参数取值

信噪比/dB	算法	τ	ξ	δ
10	l_1 -KF		0.25	0.005 0
	l_0 -KF	50	0.05	0.005 0
30	l_1 -KF		2.50	0.000 1
	l_0 -KF	50	0.15	0.000 1

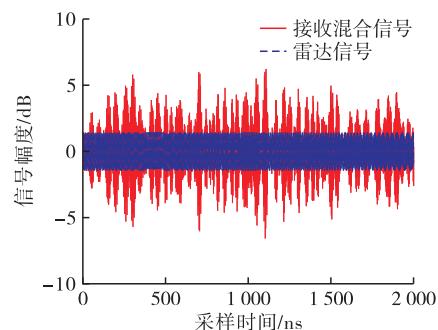


图 4 接收混合信号和雷达信号

图 4 显示了接收机接收到的混合信号和雷达信号。可以看出,耦合干扰信号已经完全覆盖住了雷达信号,这会影响对雷达信号的侦察分析以及后续的干扰工作。因此必须对耦合干扰信号进行隔离,才能保证良好的侦察和干扰工作。

图5显示了经过本文算法隔离之后的信号与雷达信号,可以看出,隔离后信号与雷达信号基本重合,即本文2种算法都能够对干扰信号起到较好的隔离作用,并且对正在侦察的雷达信号几乎没有造成影响。

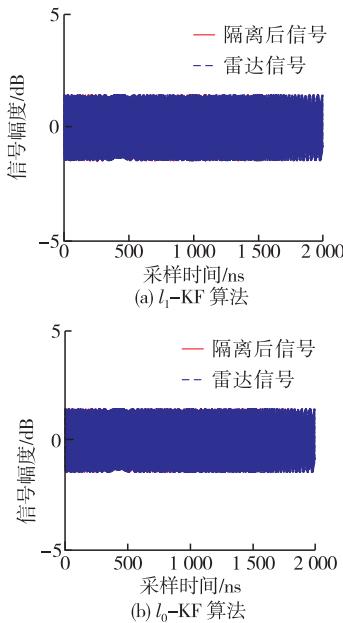


图5 隔离后信号和雷达信号

从图6可以看出通过本文2种算法隔离后能够将大部分的干扰信号对消掉。

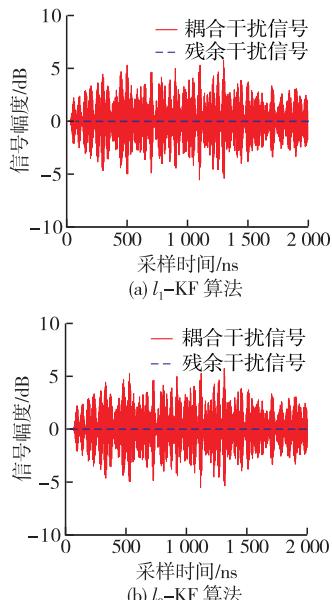


图6 隔离前后干扰信号

图7显示了50次试验的隔离度变化曲线,可以看出本文所提出的2种算法相对于常规KF算法能够取得更好的隔离度。表2列出了它们的隔离度均值,本文算法将隔离度提高了大概3~5 dB。而通过实验数据得到干扰信号与噪声的功率比为36.69 dB,如果隔离度能达到干噪比,则说明可以将干扰信号隔离至噪声水平,这是很难实现的,在实际操作

中还需要结合其他隔离技术。

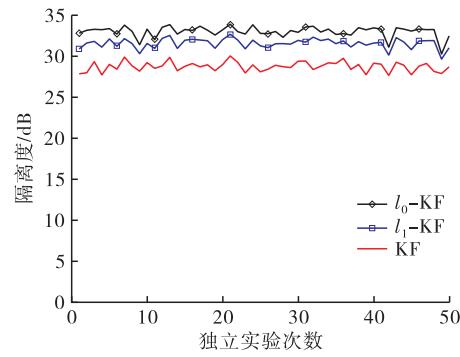


图7 隔离度

表2 隔离度

算法	I/dB
KF	28.73
l_1 -KF	31.56
l_0 -KF	33.00

图8显示了50次试验经过3种算法隔离后的信干比变化曲线,可以看出经过本文所提出的2种算法隔离后相对于常规KF算法能够取得更高的信干比。同样表3列出了它们的隔离后信干比均值,与信噪比30 dB进行对比,本文 l_0 -KF算法仅相差了3~4 dB。

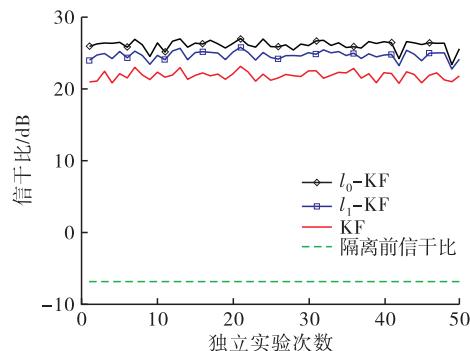


图8 信干比

表3 信干比

算法	SIR/dB
KF	21.85
l_1 -KF	24.68
l_0 -KF	26.11

4 结语

本文针对动态稀疏耦合环境下,常规KF算法对系统参数的辨识精度不够,导致干扰机的隔离性能不佳。从新的角度出发,将KF算法中的修正步等效为一个凸优化问题,在其基础上加入了2种稀疏约束,重新推导了它们的递推过程,提出了一类新

(下转第105页)