采用 AKF 神经网络的直扩系统抗干扰技术

徐定杰,赵丕杰

(哈尔滨工程大学 自动化学院,哈尔滨 150001, zhaopijie407@163.com)

摘 要:为了消除扩频系统中的窄带干扰信号,提出了一种新的基于自适应卡尔曼滤波(AKF)学习算法的 递归神经网络预测器(RNNP),其中自适应卡尔曼滤波被用于反馈修改递归神经网络的权值系数,从而准确 地估计干扰信号,具有收敛速度快、预测精度高和数值鲁棒性较好的优点.仿真实验表明:基于 AKF 学习算 法的 RNNP 相对于自适应线性最小均方差(LMS)干扰预测器、自适应近似条件均值(ACM)干扰预测器和基 于实时递推学习(RTRL)算法的 RNNP,在预测误差的均方误差、收敛速度、干噪比改善量和信噪比损失量方 面上有不同程度改进.

关键词:扩频系统;窄带干扰;递归神经网络;自适应卡尔曼滤波 中图分类号: TN914.42 文献标志码: A 文章编号: 0367-6234(2010)03-0477-06

Interference suppression in spread spectrum system using AKF neural network

XU Ding-jie, ZHAO Pi-jie

(Automation College, Harbin Engineering University, Harbin 150001, China, zhaopijie407@163.com)

Abstract: In order to eliminate the narrowband interference, a new recurrent neural network predictor (RN-NP) based on the adaptive Kalman filter (AKF) was proposed in the spread spectrum system in this paper. The adaptive Kalman filter was used to modify the weights of the RNNP and precisely estimate the interference, with the virtue of rapid convergence rate, high prediction precision and perfect numerical robustness. Simulation results show that the RNNP based on AKF learning algorithm has improvement to different extent on interference elimination capability compared with the adaptive linear least mean square (LMS) interference predictor, the adaptive approximate conditional mean (ACM) interference predictor and the RNNP based on the real-time recurrent learning (RTRL) arithmetic.

Key words: spread spectrum system; narrowband interference; recurrent neural network; adaptive Kalman filter

扩频系统除了具有保密性强、可实现码分多址 和高精度测量的优点外其抗干扰能力也很强,因此 被广泛应用于无线电及卫星导航中.它通过本地伪 码信号与接收信号进行相关得到的扩频增益来抑 制干扰信号^[1],具有一定的抗干扰能力,但由于实 际信号发射功率限制及作用距离上的衰减,接收到 的扩频信号功率非常低,在强干扰条件下,尤其在 有意的敌对干扰条件下,干扰强度很容易超出其干 扰容限,扩频系统便不能正常工作,这就需要采取 其它技术措施增强扩频系统的抗干扰能力.

针对扩频系统时域上的抗窄带干扰技术,人 们进行了很多的研究并提出相应的解决方案.文 献[2]中给出了一种线性自适应最小均方差 (LMS)干扰预测器,这种线性干扰预测器将引入 一定误差,因此需要一种非线性干扰预测器.文献 [3]中给出了一种非线性自适应近似条件均值 (ACM)干扰预测器,它需要已知扩频信号的数量 等信息,从而得到扩频信号与环境噪声的联合概 率密度分布,然后得出其非线性关系.但在实际环

收稿日期: 2008-04-18.

基金项目:国家自然科学基金资助项目(60704018).

作者简介:徐定杰(1966—),男,教授,博士生导师.

境中,扩频信号的数量是未知的,因此很难得到准确的非线性预测函数.文献[4]和[5]中给出了一种基于递归神经网络(RNN)的非线性干扰预测器,当扩频信号的数量未知时,它能够有效地改善干噪比.但它采用的实时递推学习(RTRL)权值修改算法是基于一阶微分统计量的,因此收敛速度慢,对快时变干扰信号很难准确跟踪.

本文提出了一种基于自适应卡尔曼滤波 (AKF)的递归神经网络预测器(RNNP)来消除窄 带干扰. 它采用一种强有力的非线性工具—全连 结神经网络^[6-7]来预测干扰信号,然后运用适合 于非线性系统的 AKF 来反馈修改权值,克服了经 典卡尔曼滤波需要精确已知系统的数学模型和噪 声统计的缺点和局限性.

文中给出了抗干扰扩频系统的结构框图,并 详细描述了 RNNP,然后给出了基于渐消记忆指 数加权的 AKF 权值修改算法的递推公式,最后对 基于 AKF 学习算法的 RNNP 相对于常规抗干扰 技术的性能进行了计算机仿真.

1 抗窄带干扰扩频系统

图1给出了抗窄带干扰扩频系统的简化结构 框图. 它采用相关前抗干扰模式,主要由 RNNP 和 一个加法器组成,通过这个干扰消除模块可以对 混杂在接收扩频信号中的窄带干扰信号进行估计 并消除^[8].



图1 相关前干扰抑制扩频系统结构图

设接收信号可以表示为

$$r(t) = \sum_{i=1}^{M} A_i \cdot d_i(t) \cdot PN_i(t)\cos(\omega_0 t) + \sum_{i=1}^{K} J_k(t) + n(t) = S(t) + J(t) + n(t)$$

其中 A_i 为第i路扩频信号的幅值; $d_i(t)$ 为第i路 二进制数据信息; $PN_i(t)$ 为第i路扩频序列,其码 片速率远远大于数据信息速率; $\omega_0 = 2\pi f_0$ 为调制 载波角频率;S(t)由M路扩频信号组成;n(t)为 加性高斯白噪声,其均值为零,方差为 σ^2 ;干扰信 号 $J_k(t)$ 是指窄带干扰,它的主要来源为接收机 附近的雷达及其它射频发射装置发射的强功率信 号或敌方针对本扩频系统载波频率而发射的频率 在中心频率 ω_0 附近的压迫式干扰,可分为三种形 式:音频干扰、自回归(AR)干扰和低速率数字 干扰.

接收信号 r(t) 经过带通滤波器、AGC 固定增益放大、下变频及低通滤波器后,以采样速率 $f_s = 1/T_s$ 进行采样,得到的第k时刻的采样信号为

r(k) = S'(k) + J'(k) + n'(k).其中:S'(k) 为经过解调后的扩频信号,且 S'(k) = $\sum_{i=1}^{M} A_i \cdot d_i(k) \cdot PN(k); J'(k)$ 为带限窄 带干扰;n'(k)为带限高斯白噪声,三者是相互独 立的. 由于S'(k) 及n'(k) 的频谱很宽,幅值是随机分布的,无法进行预测,而干扰信号J'(k) 的频率很窄,可对其进行预测. 将预测的干扰信号J'(k) 从接收信号r(k) 中减去,便得到只包含环境高斯白噪声的扩频信号 $\varepsilon(k)$,其表达式为

$$\varepsilon(k) = r(k) - \hat{J}'(k) =$$

$$S'(k) + J'(k) + n'(k) - \hat{J}'(k) \approx$$

$$S'(k) + n'(k).$$

其中 $\varepsilon(k)$ 为消除干扰信号 $\hat{J}'(k)$ 后得到的宽带 信号,当RNNP得到的干扰信号的幅值比较准确 时, $\varepsilon(k)$ 为扩频信号S'(k)与窄带高斯白噪声 n'(k)之和,从而消除了窄带干扰的影响.

2 基于 AKF 的递归神经网络

2.1 递归神经网络预测器

图 2 给出了递归神经网络预测器(RNNP)的 详细结构,这个模块是一种全连结的神经网络,它 由 P 个外部输入层神经元、N 个隐层神经元及一 个输出层神经元组成.与前向神经网络不同,每个 隐层神经元都延迟一个采样周期反馈到输入层, 输入层除了 P + N 个节点外,还有固定值为 + 1 的 偏值输入.

RNNP 的非线性状态方程及线性观测方程可以表示为





$$\begin{split} \boldsymbol{X}(k+1) &= \boldsymbol{\Phi}(\boldsymbol{w}_{a}\boldsymbol{X}(k) + \boldsymbol{w}_{b}\boldsymbol{R}(k)) = \\ & \left[\boldsymbol{\varphi}(\boldsymbol{w}_{1}^{\mathrm{T}} \boldsymbol{U}(k)), \cdots, \boldsymbol{\varphi}(\boldsymbol{w}_{N}^{\mathrm{T}} \boldsymbol{U}(k)) \right], \\ & r(k) &= \boldsymbol{C}\boldsymbol{X}(k) \;. \end{split}$$

其中

 $\begin{aligned} \boldsymbol{X}(k) &= \left[x_1(k), x_2(k), \cdots, x_N(k) \right]_{N \times 1}^{\mathrm{T}}, \\ \boldsymbol{R}(k) &= \left[1, r(k), r(k-1), \cdots, r(k-P+1) \right]_{(P+1) \times 1}^{\mathrm{T}}, \\ \boldsymbol{w} &= \left[w_a \quad w_b \right]^{\mathrm{T}} = \left[w_1, w_2, \cdots, w_N \right]_{(N+P+1) \times N}, \\ \boldsymbol{U}(k) &= \left[\boldsymbol{X}^{\mathrm{T}}(k) \quad \boldsymbol{R}^{\mathrm{T}}(k) \right]_{(N+P+1) \times 1}^{\mathrm{T}}. \end{aligned}$

其中: w_a 为隐层反馈到输入层节点的权值, w_b 外部输入信号节点的权值,C 为输出层输入输出线 性权值系数,X(k) 为 RNNP 的状态向量,R(k) 为 外部输入向量,所以总的输入层向量为U(k). 输 入层的输入输出关系采用直接赋值的方式.

隐层的输入为输入层所有输出的线性组合, 即 $v_i = \sum_{j=1}^{P+N+1} w_{i,j} U$,隐层的输入输出非线性函数采 用双曲线切线方程形式的 Sigmoid 激励函数 $\phi(v_i) = \tanh(v_i)$.

输出层的输入为隐层的输出,输出 y(k) 为输入的线性组合,即其值为 RNNP 预测的干扰信号.

2.2 基于渐消记忆指数加权的 AKF 学习算法

根据上面神经网络模型可以得到隐层反馈到 输入层权值 W(k)的线性状态方程和非线性观测 方程为

$$W(k+1) = W(k) + \omega(k) , \qquad (1)$$

$$r(k) = C\varphi(v(k)) + \zeta(k).$$
(2)

其中: $W(k) = [w_1^T(k), w_2^T(k), \dots, w_N^T(k)]_{L\times 1}^T$,且 $L = (P + N + 1) \cdot N$;通过式(1)可以发现状态方 程是关于神经网络权值 W(k)的线性方程,其扰 动噪声为 $\boldsymbol{\omega}(k)$. 通常认为 $\boldsymbol{\omega}(k)$ 为高斯白噪声, 其均值为 $E[\boldsymbol{\omega}(k)] = \boldsymbol{q}(k)$,协方差矩阵为 $E[\boldsymbol{\omega}_i(k)\boldsymbol{\omega}_j^{\mathrm{T}}(k)] = \delta_{i,j}\boldsymbol{Q}(k)$;式(2)中r(k)为输 入 $\boldsymbol{v}(k)$ 的非线性方程,即 $r(k) = C \tanh(\boldsymbol{v}(k))$, 且 $v_i = \sum_{j=1}^{P+N+1} w_{i,j}\boldsymbol{U}$,其观测噪声为 $\boldsymbol{v}(k)$. 通常认为 $\boldsymbol{v}(k)$ 为高斯白噪声,其均值为 $E[\boldsymbol{v}(k)] = \boldsymbol{p}(k)$, 协方差矩阵为 $E[\boldsymbol{v}_i(k)\boldsymbol{v}_i^{\mathrm{T}}(k)] = \delta_{i,j}\boldsymbol{P}(k)$.

为解决式(2)中非线性观测方程的估值问 题,常用的方法是扩展 Kalman 滤波器 (EKF)^[9-10],它的缺点和局限性有两点,一是它 要求已知状态和观测噪声统计特性,然而实际应 用问题中噪声统计特性却常常是近似的、时变的. 运用不准确或错误的噪声统计特性设计 EKF 将 使滤波器性能变坏,甚至使滤波发散.二是 EKF 的基本原理是将非线性系统线性化,然后用线性 化常规 Kalman 滤波器解决非线性系统状态估值 问题,其中忽略了非线性化引入的模型误差,将导 致滤波性能变差.为了解决上述问题,本文采用基 于渐消记忆指数加权的 AKF 学习算法来修改递 归神经网络的权值系数,其原理为:在进行状态滤 波的同时,利用观测数据提供的信息,在线估计未 知噪声统计特性,构成状态和噪声统计特性估计 的两段互耦自适应卡尔曼滤波算法. Sage 和 Husa 的噪声统计估值器可在线互耦估计状态和噪声统 计,算法简单且具有良好的性能,因此被人们广泛 应用. 它由互耦的常规卡尔曼滤波算法和噪声统 计估值器组成. Sage 和 Husa 的噪声统计估值器 是次优无偏极大后验估值器,适合估计未知的噪 声统计,其缺点是不能处理时变噪声统计估计问题,且精度有待于进一步提高.本文引入基于渐消记忆指数加权的改进的 Sage 和 Husa 噪声估值器,它可处理时变噪声统计估值问题,且计算效率高,能加快收敛速度,提高算法的跟踪性能,使得滤波过程稳定、可靠、精度高.

由于噪声的统计特性未知,将式(2)中的 φ 在 W(k)的预测值 $\hat{W}(k/(k-1))$ 处用泰勒级数 展开有

$$r(k) = C\varphi(\widehat{W}(k/(k-1))) + C \frac{\partial \varphi}{\partial \widehat{W}(k/(k-1))} [W(k) - \widehat{W}(k/(k-1))] + hot + v(k).$$

这里引出线性化观测方程

$$r(k) = C \frac{\partial \varphi}{\partial \hat{W}(k/(k-1))} W(k) + z(k) + \eta(k).$$

其中

$$z(k) = C\varphi(\hat{W}(k/(k-1))) - C \frac{\partial\varphi}{\partial\hat{W}(k/(k-1))} \cdot \hat{W}(k/(k-1)),$$
$$\hat{W}(k/(k-1)),$$
$$n(k) = hot + \zeta(k) \cdot$$

其中:hot 为泰勒级数展开的高阶项;η(k) 为虚拟 观测噪声,用以补偿线性化误差 hot,它的时变统 计特性为

$$E[\boldsymbol{\eta}(k)] = p(k),$$

$$E[\boldsymbol{\eta}_i(k)\boldsymbol{\eta}_j^{\mathrm{T}}(k)] = \delta_{i,j}\boldsymbol{P}(k).$$

设隐层输出矩阵 $\varphi(v(k))$ 关于权值 W(k)的偏微分矩阵为 $\Omega(k)$, 它是 $N \times L$ 阶矩阵, 可以 表示为

$$\Omega(k) = \frac{\partial \varphi(\boldsymbol{v}(k))}{\partial \boldsymbol{w}(k)} = \frac{\partial \varphi(\boldsymbol{v}(k))}{\partial \boldsymbol{v}(k)} \cdot \frac{\partial \boldsymbol{v}(k)}{\partial \boldsymbol{W}(k)}.$$
(3)

其中

$$\begin{split} \frac{\partial \varphi(v_i(k))}{\partial v_j(k)} &= \operatorname{sech}^2(v_i(k)) \delta_{ij} \frac{\partial v_i(k)}{\partial W(k)} = \\ & \left[\frac{\partial v_i(k)}{\partial W_1(k)}, \frac{\partial v_i(k)}{\partial W_2(k)}, \cdots, \frac{\partial v_i(k)}{\partial W_L(k)} \right]^{\mathrm{T}}. \end{split}$$

因此带未知噪声统计的非线性方程(1)和(2) 的自适应卡尔曼滤波状态一步预测的递推公式为 $\hat{W}((k+1)/k) = \hat{W}(k/(k-1)) + K(k)\varepsilon(k) + \hat{q}(k).$ (4)

$$\varepsilon(k) = r(k) - C\varphi(\hat{W}(k/(k-1))) - \hat{p}(k),$$
(5)

$$\boldsymbol{K}(k) = \boldsymbol{M}(k/(k-1))\boldsymbol{\Omega}^{\mathrm{T}}(k) [\boldsymbol{\Omega}(k)\boldsymbol{M}(k/(k-1))\boldsymbol{\Omega}^{\mathrm{T}}(k) + \boldsymbol{\hat{P}}(k)]^{-1}, \qquad (6)$$

$$\boldsymbol{M}((k+1)/k) = \boldsymbol{M}(k/(k-1)) - \boldsymbol{K}(k)\boldsymbol{\Omega}^{\mathrm{T}}(k)\boldsymbol{M}^{\mathrm{T}}(k/(k-1)) + \boldsymbol{\hat{Q}}(k) .$$
(7)

其中 $\Omega(k)$ 由式(3)定义,基于渐消记忆指数加

权的噪声统计特性估值器为

 $\hat{\boldsymbol{q}}(k+1) = (1-d_k)\hat{\boldsymbol{q}}(k) + d_k [\hat{\boldsymbol{W}}((k+1)/k) - \hat{\boldsymbol{W}}(k/(k-1))] , \qquad (8)$ $\hat{\boldsymbol{Q}}(k+1) = (1-d_k)\hat{\boldsymbol{Q}}(k) + d_k [\boldsymbol{K}(k+1)\boldsymbol{\varepsilon}(k+1)\boldsymbol{\varepsilon}(k+1)\boldsymbol{\varepsilon}(k+1)\boldsymbol{\kappa}^{\mathrm{T}}(k+1) \boldsymbol{K}^{\mathrm{T}}(k+1) + \boldsymbol{M}((k+1)/k) - \boldsymbol{M}(k/(k-1))] , \qquad (9)$ $\hat{\boldsymbol{p}}(k+1) = (1-d_k)\hat{\boldsymbol{p}}(k) + d_k [r(k+1) - \boldsymbol{C}\boldsymbol{\varphi}(\hat{\boldsymbol{W}}((k+1)/k))] , \qquad (10)$ $\hat{\boldsymbol{P}}(k+1) = (1-d_k)\hat{\boldsymbol{P}}(k) + d_k [\boldsymbol{\varepsilon}(k+1)\boldsymbol{\varepsilon}^{\mathrm{T}}(k+1) - \boldsymbol{C}\boldsymbol{\varphi}(\hat{\boldsymbol{W}}((k+1)/k))] , \qquad (11)$

 $\hat{W}(0/(-1)) = W_0, M(0/(-1)) = M_0,$ $\hat{q}(0) = q_0, \hat{Q}(0) = Q_0, \hat{r}(0) = p_0, \hat{R}(0) = P_0,$ $d_k = (1-b)/(1-b^{k+1}), 0 < b < 1.$

式中:b 为遗忘因子,其取值范围一般 $b \in (0.95 \sim 1)$,对于慢时变噪声b取值较大,接近于1.则状态噪声统计估值的两段互耦自适应 Kalman 滤波学 习算法的程序流程为

步骤1 初始化权值向量 W_0 ,误差协方差矩 阵 M_0 ,噪声统计估值 q_0, Q_0, p_0 和 P_0 ;

步骤2 根据式(4)和式(5)计算k时刻预测 误差 $\varepsilon(k)$ 和滤波增益矩阵K(k);

步骤3 根据式(6)和式(7)更新k+1时刻 的权值预测值 $\hat{W}((k+1)/k)$ 和误差协方差矩阵 M((k+1)/k);

步骤4 根据式(8)~(11)更新k+1时刻时 变噪声统计估计值 $\hat{q}(k+1), \hat{Q}(k+1), \hat{p}(k+1), \hat{P}(k+$

步骤5 时刻 k 递增准备下一时刻的窄带干扰预测抑制.

3 仿真结果

为了比较基于 AKF 学习算法的 RNNP 相对 于自适应线性 LMS 干扰预测器、自适应 ACM 干 扰预测器和基于 RTRL 算法的 RNNP 的抗干扰性 能,进行了计算机仿真.首先,介绍输入信号的组 成;其次,介绍衡量抗干扰性能的标准;最后,给出 各种抗干扰技术的性能比较.

3.1 输入信号组成

仿真中的输入有用扩频序列采用 15 级 m 序 列,环境噪声是方差为 0.1 的加性高斯白噪声,干 扰信号只考虑下面两种形式:

1)单频连续载波干扰(CWI).它是一种最为常见的干扰信号,例如射频干扰,CWI 时域上的数学表达式为*j*(*k*) = 2sin(0.01*k*);

2) 自回归干扰(ARI). 它是由高斯白噪声递 推产生的随机信号,其时域上的数学表达式为

$$\begin{split} j(k) &= 1.980 \ 0 j(k-1) - 0.980 \ 1 j(k-2) + n_0(k). \\ 其中 n_0(k) 是方差为 0.01 的高斯白噪声. \end{split}$$

3.2 抗干扰性能标准

为了对各种预测器的抗干扰性能进行比较, 主要参考下面两个性能指标:干噪比(JNR)改善



量和信噪比(SNR)损失量,它们可以表示为

$$JNR = \frac{\sigma_j^2}{\sigma_n^2}, SNR = \frac{\sigma_s^2}{\sigma_n^2}.$$

其中 σ_j^2 , σ_s^2 和 σ_n^2 分别为窄带干扰信号、有用扩频 信号和环境噪声的方差, 为了准确可靠得到方差 的计算值, 采用自相关的方式, 如图 3 所示.



图 3 仿真中 SNR 和 JNR 的计算方式

在上面仿真中,扩频信号与噪声及干扰与噪声的互相关很小,接近于零,可以忽略.所以信号+噪声与信号的互相关值表示信号的能量 σ_s^2 ,干扰+噪声与干扰的互相关值表示干扰的能量 σ_j^2 ,信号+噪声及干扰+噪声与噪声的互相关值都表示噪声的能量 σ_n^2 ,所以通过图 3 可以计算窄带干扰抑制技术的 JNR 改善量和 SNR 损失量,表示为

$$JNR_{\text{trian}} = JNR_{\text{in/dB}} - JNR_{\text{out/dB}},$$

 $SNR_{\text{H} \notin \text{H}} = SNR_{\text{out/dB}} - SNR_{\text{in/dB}}.$

3.3 仿真结果与性能分析

RNNP 中输入层节点个数为4,隐层节点个数 为5,输出层节点个数为1,输出层输入输出线性 权值系数 *C* = [1,1,1,1,1],权值初始值为零,初 始误差协方差矩阵为 100*E*,其中 *E* 为单位矩阵, 噪声统计初始估计值为零或单位矩阵.图4 和图 5 给出了当干扰分别为频率 500 Hz 的 CWI 和低 频段的 ARI 时,基于 AKF 学习算法的 RNNP 干扰 抑制前后的信号的频谱图.可以看到,基于 AKF 学习算法的 RNNP 能准确估计并消除混杂在接收 信号中的强窄带干扰信号.

图 6 和图 7 给出了当干扰分别为 CWI 和 ARI 时,基于 AKF 学习算法的 RNNP 干扰抑制前后的 信号的伪码相关特性.可以看到,强窄带干扰存在 时,伪码相关特性不再满足理想的相关特性,导致 接收机无法正常工作,而基于 AKF 学习算法的 RNNP 能很大程度的抑制干扰信号,并且对有用 扩频信号的损伤比较小,经过干扰抑制后,可以明 显地在伪码相关曲线中码片延迟为 511 chip 时发 现相关峰值,使得接收机能够在强窄带干扰环境 下正常捕获和跟踪扩频信号.





图 6 CWI 抑制前后伪码相关特性



图 7 ARI 抑制前后伪码相关特性

图 8 和图 9 给出了当干扰分别为 CWI 和 ARI 时,基于 AKF 学习算法的 RNNP 误差输出的均方 误差曲线.可以看到:1)基于 AKF 学习算法的 RNNP 的窄带干扰预测误差比其它干扰抑制技术 要小的多,说明其干扰预测精度更高;2)基于 AKF 学习算法的 RNNP 的窄带干扰预测误差的 收敛速度很快,可以实时地预测并抑制窄带干扰 信号,大大改善了其它时域干扰预测抑制算法收 敛速度慢和实时性差等缺点,可以适应于快时变 干扰信道.



表1和表2给出了当干扰分别为CWI、ARI 时,基于AKF学习算法的RNNP相对于其它干扰 抑制技术的抗窄带干扰性能比较.其中自适应线 性LMS干扰预测器中延迟节点的个数为5,采用 最小均方差(LMS)来反馈修改权值,收敛系数为 0.0001.自适应ACM预测器中延迟节点个数为 5,采用非线性近似条件均值(ACM)来反馈修改 权值,初始收敛系数为0.001,初始估计方差为1, 遗忘因子为0.9.基于RTRL算法的RNNP与 AFK算法的递归神经网络相同,权值初始值为 零,初始误差协方差矩阵为100*E*,其中*E*为单位 矩阵.输入信噪比固定为 – 10 dB,输入干噪比是 变化的,可以通过改变单频干扰信号幅值或改变 噪声 $n_0(k)$ 的方差来改变干扰信号的能量.可以

输入 信号 <i>JNR/</i> dB	干噪比改善量/dB				_	信噪比损失量/dB				
	LMS	ACM	RTRL	AKF		LMS	ACM	RTRL	AKF	
29	46.74	47.22	50.45	60.21		-3.25	-2.75	-2.11	-1.46	
25	39.25	39. 56	45.66	53.96		-3.02	-2.25	-1.23	-1.01	
18	19.56	20. 54	29.46	39. 20		-2.76	- 1. 73	- 1. 05	-0.56	
13	9.37	9.75	15.22	23. 14		-2.55	- 1. 35	-0.76	-0.33	

表1 CWI 下干噪比提高量和信噪比损失量

输入 信号 <i>JNR/</i> dB	干噪比改善量/dB				信噪比损失量/dB				
	LMS	ACM	RTRL	AKF	LMS	ACM	RTRL	AKF	
29	42.26	44.30	49.65	58.62	-4.73	- 3. 29	-2.89	-2.51	
25	38.80	39.15	44. 32	50.10	-4.45	- 3. 05	-2.36	- 1. 95	
18	24.16	26.14	32.15	37.51	-4.12	-2.56	- 1. 73	-0.86	
13	9. 54	10. 58	17.89	22. 84	-3.38	-2.77	- 1. 03	-0.60	

表 2 ARI 下干噪比提高量和信噪比损失量

看到:1)当干扰为 CWI 时,基于 AKF 学习算法的 RNNP 在干噪比改善量上相对于自适应 LMS、 ACM 和 RTRL 干扰抑制技术分别平均有 15.4 dB,14.5 dB 和 8.9 dB 的改善,而对于 ARI 干扰,分别有13.5 dB,12.2 dB 和 6.2 dB 的改善. 输入干噪比越大,干噪比改善量越大.2)当干扰 为 CWI 时,基于 AKF 学习算法的 RNNP 在信噪 比损失量上比其它干扰抑制技术分别平均减少 2.3 dB,1.4 dB 和 0.7 dB,而对于 ARI 干扰,分别 平均减少 2.6 dB,1.4 dB 和 0.5 dB. 输入干噪比 越大,对有用信号的损伤越大.

4 结 论

本文将基于渐消记忆指数加权的自适应卡尔 曼滤波应用于递归神经网络的学习算法中,从而 准确地预测并抑制扩频系统中的窄带干扰.该方 法不需要已知信道参数,能够准确地预测窄带干 扰信号,并且收敛速度相对于基于自适应 LMS、 ACM 算法和基于 RTRL 算法的 RNNP 的干扰抑 制技术大大提高.仿真试验表明:当干扰信号为单 频连续载波干扰(CWI)和自回归干扰(ARI)时, 它的干噪比改善量和信噪比损失量相对于其它干 扰抑制技术有不同程度的改善.

参考文献:

- [1] PARKINSON B W, SPILKER J J. Global Positioning System: Theory and Applications: Volume I[M]. Reston: American Institute of Aeronautics and Astronautics, 1996.
- $\left[\,2\,\right]$ ILTIS R A, MILSTEIN L B. An approximate statistical

analysis of the widrow LMS algorithm with application to narrow-band interference rejection [J]. IEEE Transactions on Communications, 1985, COM - 33:10 - 19.

- [3] VIJAYAN R, POOR H V. Nonlinear techniques for interference suppression in spread-spectrum systems [J].
 IEEE Transactions on Communications, 2004, 38(7): 1060 - 1065.
- [4] CHANG Po Rong, HU Jen Tsung. Narrow-band interference suppression in spread-spectrum CDMA communications using pipelined recurrent neural networks
 [J]. IEEE Transactions on Vehicular Technology, 1999,48(2):467-477.
- [5] CHOI J, BOUCHARD M, YEAP T H. Decision feedback recurrent neural equalization with fast convergence rate[J]. IEEE Transactions on Neural Networks, 2005, 16(3): 699 – 708.
- [6] 胡德文,王正志,王耀南,等. 神经网络自适应控制 [M]. 长沙:国防科技大学出版社,2005.
- [7] PARISI R, DI CLAUDIO E D, ORLANDI G, et al. Fast adaptive digital equalization by recurrent neural networks[J]. IEEE Transactions on Signal Processing, 2007,45(7):2731-2739.
- [8] MAO Wei Lung. Novel SREKF-based recurrent neural predictor for narrowband/FM interference rejection in GPS[J]. International Journal of Electronics and Communications, 2008,62(3):216 – 222.
- [9] 谢胜利,何昭水,高鹰. 信号处理的自适应理论[M]. 北京:科学出版社, 2006.
- [10] Steven M Kay. 统计信号处理基础—估计与检测理论 [M]. 北京:电子工业出版社,2003.

(编辑 张 宏)