

基于 EKF 神经网络的扩频系统抗窄带干扰技术*

徐定杰, 赵丕杰

(哈尔滨工程大学 自动化学院, 黑龙江 哈尔滨 150001)

摘要: 针对消除扩频系统中的窄带干扰问题, 文章提出了一种基于扩展卡尔曼滤波(EKF)的递归神经网络预测器(RNNP)。扩展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、预测精度高和适用于非线性处理的优点。仿真结果表明: 基于 EKF 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、信噪比改善量方面上有不同程度的改进。

关键词: 扩频系统; 窄带干扰; 递归神经网络; 扩展卡尔曼滤波

中图分类号: TN914.42

文献标识码: A

Narrowband interference suppression in spread spectrum system based on EKF neural network

XU Ding Jie, ZHAO Pi Jie

(Automation College, Harbin Engineering University, Harbin 150001, China)

Abstract: A recurrent neural network predictor based on the extended Kalman filter to eliminate the narrowband interference was proposed in the spread spectrum in this paper. The extended 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 suiting for nonlinear disposition. Simulation results showed that the RNNP based on EKF learning algorithm had improvement to different extent on interference elimination capability compared to the adaptive linear least mean square (LMS) interference predictor, the adaptive approximate conditional mean (ACM) interference predictor and the RNNP based on real time recurrent learning (RTRL) arithmetic.

Key words: spread spectrum system; narrowband interference; recurrent neural network; extended 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导航中。它通过本地伪码信号与接收到的信号进行相关得到的扩频增益来抑制干扰信号^[1]。但当干扰信号幅值远远大于扩频信号时, 扩频系统将无法从接收信号中提取扩频信号, 从而导致扩频系统不能正常工作。由于扩频系统的频谱非常平, 因此不能直接进行预测, 需要与本地伪码信号相关。然而干扰信号的频谱比较窄, 能被准确预测。因此, 通过以前时刻的输入信号, 可以估计出干扰信号的幅值, 然后将估计的干扰信号从采样值中减去, 得到只包含环境高斯白噪声的扩频信号, 窄带干扰的影响将会被消除或减弱。

针对扩频系统抗窄带干扰技术, 人们从时域方面进

行了很多的研究并提出了相应的解决方案。参考文献[2]给出了一种线性自适应最小均方差(LMS)干扰预测器, 由于扩频信号的存在使其与环境噪声的联合分布不再满足高斯分布, 因此这种线性 LMS 干扰预测器不可能是最优的。

参考文献[3]给出了一种非线性自适应近似条件均值(ACM)干扰预测器, 它需要已知的联合分布, 然后求出其非线性关系。但在实际环境中, 扩频信号的数量是未知的, 因此这种方法也将引入误差偏移。

参考文献[4]给出了一种基于神经网络(PRNN)的非线性干扰消除技术, 无论扩频信号的数量是否已知, 都能有效地提高信噪比, 且不引入误差偏移。但它采用的实时递推学习(RTRL)权值修改算法是一阶微分量, 收敛速度慢, 对快时变干扰很难及时预测。

* 基金项目: 国家自然科学基金项目(60704018)

本文提出了一种基于扩展卡尔曼滤波(EKF)^[5]的递归神经网络预测器(RNNP)来消除窄带干扰。它采用强有力的非线性工具——全连接神经网络^[6,7]来预测干扰信号,然后运用二阶滤波算法——扩展卡尔曼滤波(EKF)来反馈修改权值系数,其预测误差小且收敛速度快,可以用来消除扩频系统中的强窄带干扰信号。

1 抗干扰扩频系统

图1给出了抗干扰扩频系统的简化结构框图。它主要由递归神经网络预测器(RNNP)和一个加法器组成,通过该干扰消除模块可以对混杂在接收扩频信号中的干扰信号进行估计和消除。




图1 抗干扰扩频系统结构

设接收信号的形式为:

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

$$= s(t) + J(t) + n(t)$$

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; $\omega_0 = 2\pi f_0$ 为调制载波速率; $S(t)$ 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 ; 本文干扰信号 $J_k(t)$ 分为 2 种形式: 多频连续载波干扰(MCWI)和线性调频干扰(LFM)。

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

$$r(k) = S(k) + J(k) + n(k) \quad (2)$$

式(2)中的三项是相互独立的, 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 $J(k)$ 的频谱很窄, 可以对其进行预测。

将预测的干扰信号 $\hat{J}(k)$ 从接收信号 $r(k)$ 中减去, 便可得到只包含环境高斯白噪声的扩频信号 $\varepsilon(k)$, 其表达式为:

$$\begin{aligned} \varepsilon(k) &= r(k) - \hat{J}(k) \\ &= S(k) + J(k) + n(k) - \hat{J}(k) \\ &\approx S(k) + n(k) \end{aligned} \quad (3)$$

其中, $\varepsilon(k)$ 为消除干扰信号 $\hat{J}(k)$ 后得到的宽频信号, 当 RNNP 得到的干扰信号的幅值比较准确时, $\varepsilon(k)$ 为扩频信号与环境高

斯白噪声之和, 从而消除了干扰信号的影响。

2 自适应 EKF 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, 该模块是一种全连接的神经网络, 它由 P 个外部输入层神经元、 N 个隐层神经元及 1 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 的非线性状态及观测方程可以表示为:

$$\begin{aligned} X(k+1) &= \Phi(w_a X(k) + w_b R(k)) \\ &= [\phi(w_1^T U(k)), \dots, \phi(w_N^T U(k))] \end{aligned} \quad (4)$$

$$y(k) = CX(k) \quad (5)$$

其中

$$X(k) = [x_1(k), \dots, x_N(k)]_{N \times 1}^T \quad (6)$$

$$R(k) = [1, r(k), r(k-1), \dots, r(k-P+1)]_{(P+1) \times 1}^T \quad (7)$$

$$w = [w_a \ w_b]^T = [w_1, \dots, w_N]_{(N+P+1) \times N} \quad (8)$$

$$U(k) = [X^T(k) \ R^T(k)]_{(N+P+1) \times N}^T \quad (9)$$

w_a 为隐层反馈到输入层节点的权值, w_b 为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实现。

隐层的输入为输入层所有输出的线性组合, 即 $v_i = \sum_{j=1}^{P+N+1} w_{i,j} U_j$, 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 EKF 算法

基于扩展卡尔曼滤波(EKF)的学习算法是一种二阶递推过程, 它通过比较神经网络的预测值与实际输入值




图2 递归神经网络预测器(RNNP)结构框图

来对非线性系统的状态向量进行准确估计。可建立关于权值的非线性状态方程和观测方程为:

$$\mathbf{W}(k+1) = \mathbf{W}(k) + \boldsymbol{\omega}(k) \quad (10)$$

$$\mathbf{y}(k) = C\boldsymbol{\varphi}(v(k)) + v(k) \quad (11)$$

其中, $\mathbf{W}(k) = [w_1^T(k), w_2^T(k), \dots, w_N^T(k)]_{L \times 1}^T$, 且 $L = (P+N+1) \cdot N$; 通过式(10)可以发现状态方程是关于神经网络权值 $\mathbf{W}(k)$ 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, 其均值为零, 协方差矩阵为 $E[\boldsymbol{\omega}_i(k)\boldsymbol{\omega}_j^T(k)] = \delta_{i,j}Q(k)$; 式(11)中 $\mathbf{y}(k)$ 为输入 $v(k)$ 的非线性方程, 其观测噪声为 $v(k)$ 。通常认为 $v(k)$ 为高斯白噪声, 其均值为零, 协方差矩阵为 $E[v_i(k)v_j^T(k)] = \delta_{i,j}R(k)$ 。

利用泰勒级数展开将式(11)线性化, 可以得到其偏微分矩阵 $\boldsymbol{\Omega}(k)$, 它是隐层输出矩阵 $\boldsymbol{\varphi}(v(k))$ 关于权值 $\mathbf{W}(k)$ 的偏微分, 为 $N \times L$ 阶矩阵, 可以表示为:

$$\boldsymbol{\Omega}(k) = \frac{\partial \boldsymbol{\varphi}(v(k))}{\partial \mathbf{W}(k)} = \frac{\partial \boldsymbol{\varphi}(v(k))}{\partial v(k)} \cdot \frac{\partial v(k)}{\partial \mathbf{W}(k)} \quad (12)$$

其中 $\frac{\partial \boldsymbol{\varphi}(v_i(k))}{\partial v_j(k)} = \text{sech}^2(v_i(k))\delta_{ij}$; $\frac{\partial v_i(k)}{\partial \mathbf{W}(k)} = [\frac{\partial v_i(k)}{\partial W_1(k)}, \frac{\partial v_i(k)}{\partial W_2(k)}, \dots, \frac{\partial v_i(k)}{\partial W_L(k)}]^T$ 。

因此扩展卡尔曼滤波(EKF)学习算法的递推公式为:

$$\mathbf{K}(k) = \mathbf{M}(k)\boldsymbol{\Omega}^T(k)[\boldsymbol{\Omega}(k)\mathbf{M}(k)\boldsymbol{\Omega}^T(k) + \mathbf{R}(k)]^{-1} \quad (13)$$

$$\hat{\mathbf{W}}(k+1) = \hat{\mathbf{W}}(k) + \mathbf{K}(k)(r(k+1) - \mathbf{y}(k)) \quad (14)$$

$$\mathbf{M}(k+1) = \mathbf{M}(k) - \mathbf{K}(k)\boldsymbol{\Omega}(k)\mathbf{M}(k) + \mathbf{Q}(k) \quad (15)$$

其中, $\mathbf{K}(k)$ 为 $L \times 1$ 阶滤波增益矩阵; $\mathbf{M}(k)$ 为 $L \times L$ 阶滤波均方误差矩阵; $\mathbf{R}(k)$ 为 1×1 阶测量噪声协方差矩阵; $\hat{\mathbf{W}}(k)$ 为 $L \times 1$ 阶估计权值向量; $r(k+1)$ 为第 $k+1$ 次输入; $\mathbf{y}(k) = C\boldsymbol{\varphi}(v(k))$ 为第 k 次神经网络预测输出值; $\mathbf{Q}(k)$ 为 $L \times L$ 阶扰动噪声协方差矩阵。

3 仿真结果

针对基于 EKF 学习算法的 RNNP、自适应 LMS 干扰预测器和自适应 ACM 干扰预测器的抗干扰性能给出了相应的计算机仿真。自适应 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 干扰预测器中延迟节点的个数为 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 EKF 的 RNN 干扰预测器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, $\alpha=5, \beta=0.01, \chi=100$, 输出层输入输出线性权值系数 $C=[1, 1, 1, 1, 1]$ 。

设输入扩频信号为 10 级 m 序列, 幅值为 0.05; 环境噪声为高斯白噪声, 均值为零, 方差为 0.1; 干扰信号分为 2 种形式: 多频连续载波干扰(MCWI)和线性调频干扰(LFM); 它们的幅值远远大于噪声, 干噪比为 26 dB 左右, 总的输入信号如图 3、图 4 和图 5 所示。为了对上述 3 种预测器进行性能比较, 主要参考下面两个性能指




图 3 MCWI 干扰预测误差的均方误差曲线




图 4 MCWI 信噪比提高量与干噪比的关系曲线

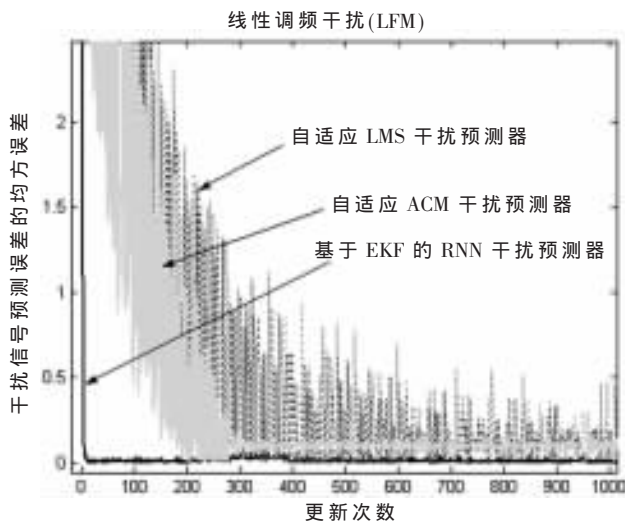


图 5 LFM 干扰预测误差的均方误差曲线

标: 均方误差 (MSE) 和信噪比 (SNR) 提高量^[4,8]。

图 3 和图 5 给出了当干扰信号分别为 MCWI 和

LFM时,干扰信号预测误差的均方误差曲线。可以看到,基于EKF学习算法的RNN干扰预测器相对于自适应LMS和ACM干扰预测器在收敛速度和方差大小上都有明显改善。

图4和图6分别给出了多频连续载波干扰和线性调频干扰下,信噪比提高量与输入干扰噪声之比(干噪比)的关系曲线。可以看到,基于EKF的RNN干扰预测器的信噪比提高量比其他两种方法大。当干扰为MCWI时,基于EKF的RNN干扰预测器的信噪比提高量相对于自适应LMS和ACM干扰预测器有2~9dB和1~5dB的增加;当干扰为LFM时,基于EKF的RNN干扰预测器的信噪比提高量相对于自适应LMS和ACM干扰预测器有4~10dB和2~8dB的增加,且它们的信噪比提高量都随干噪比的增大而增大。

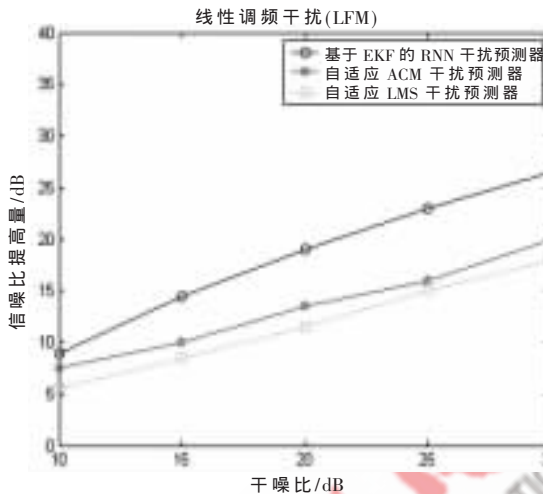


图6 LFM信噪比提高量与干噪比的关系曲线

本文提出了一种基于扩展卡尔曼滤波(EKF)权值修改算法的自适应递归神经网络干扰预测器(RNNP),并将其应用于扩频通信抗窄带干扰中。它能够准确地预测干扰信号的幅值,并且相对于自适应LMS和ACM干扰抑

制技术其收敛速度快、预测误差小。仿真结果表明:当干扰为多频连续载波干扰(MCWI)和线性调频干扰(LFM)时,它的信噪比提高量平均分别为21.7dB和20.9dB。当输入干噪比为20dB时,相对于自适应LMS和ACM干扰预测器,输出信噪比平均分别有4~7dB和2~4dB的改善。

参考文献

- [1] PARKINSON B W, SPILKER J J. Global positioning system: Theory and applications volume I[M]. Cambridge, American Institute of Aeronautics and Astronautics, 1996: 304-310.
- [2] ILLIS R A, MILSTEIN L B. An approximate statistical analysis of the widrow LMS algorithm with application to narrow-band interference rejection [J]. IEEE Trans on Communications, 1985, 33(1): 10-19.
- [3] VIJAYAN R, POOR H V. Nonlinear techniques for interference suppression in spread-spectrum systems[J]. IEEE Transactions on Communications, 1990, 38(7):56-60.
- [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):158-161.
- [5] 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, 2006:22-26.
- [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: 33-35.
- [7] 李国勇. 智能控制及其 MATLAB 实现[M]. 北京: 电子工业出版社, 2005: 321-324.
- [8] PARISI R, CLAUDIO D E D, ORLANDI G, et al. Fast adaptive digital equalization by recurrent neural networks [J]. IEEE Trans. Signal Process, 1999, 45(11):2731-2739.

(收稿日期: 2009-03-10)