

基于小波神经网络的卡尔曼滤波在 GPS/DR 系统中的应用

魏 武, 魏 敏

(华南理工大学 自动化科学与工程学院, 广东 广州 510641)

摘 要: 针对 GPS/DR 定位过程中采用卡尔曼滤波时噪声的统计特性与实际不符, 提出采用小波神经网络嵌入到卡尔曼滤波, 来实现自适应调整噪声协方差矩阵. 通过对基于小波神经网络的自适应卡尔曼滤波辅助的 GPS/DR 定位系统进行仿真, 结果表明既能有效抑制发散, 又能有效提高定位精度.

关键词: GPS/DR 系统; 自适应卡尔曼滤波; 小波神经网络

中图分类号: TP273

文献标识码: A

文章编号: 1000-7180(2010)07-0021-04

Application of the Kalman Filter Based on Wavelet Neural Network in GPS/DR Navigation System

WEI Wu, WEI Min

(School of Automation Science and Engineering, South China University of Technology, Guangzhou 510641, China)

Abstract: GPS/DR positioning using Kalman filter has a large margin of error after a period of time, even divergent. This paper uses wavelet neural network in the Kalman filter to adjust the noise covariance matrix. Simulation results of mobile robot GPS/DR positioning system show that the divergence can effectively suppress, and can effectively improve the positioning accuracy.

Key words: GPS/DR navigation system; adaptive kalman filter; wavelet neural networks

1 引言

目前 GPS/DR 定位系统已经在导航定位中得到广泛应用, 在较好的环境下可以得到较高精度的位置和速度数据. 但由于采用 GPS 进行连续定位时存在信号被遮蔽和多路效应的影响, 而 DR 中陀螺仪也存在不断的误差积累, 观测值包含多种随机误差^[1], 不能准确反映系统的真实状态, 需要采用必要的数据处理技术.

文中提出了在 GPS/DR 定位中利用小波神经网络具有较强的学习能力和自适应性, 以实时获取的新息的理论方差与实际方差的比值, 用小波神经网络辅助卡尔曼滤波器实时修正模型中的噪声协方差矩阵, 使其能根据实际的噪声水平得到在线调整, 来达到抑制滤波发散和提高定位精度^[2-3].

2 基于小波神经网络的自适应卡尔曼滤波方法及在 GPS/DR 定位中应用

2.1 GPS/DR 定位数学模型

GPS/DR 定位采用机动载体的“当前”统计模型, 利用观测到的位置信息进行实时卡尔曼滤波数据处理, 获取最优估算的位置和速度. GPS/DR 组合导航系统的扩展卡尔曼滤波器的状态 $X(k) = [e, v_e, a_e, n, v_n, a_n]^T$, 分别表示东向和北向的位置、速度、加速度分量. 观测量 $Z(k) = [e', n', \omega, s]^T$ 是通过 GPS 获得的位置 e' , n' 和陀螺仪输出的角速度 ω 以及里程表在一个采样周期 T 内输出的距离 s . 采取以下离散化状态方程和观测方程:

$$X(k) = \begin{bmatrix} \Phi_e(k, k-1) & 0 \\ 0 & \Phi_n(k, k-1) \end{bmatrix}.$$

收稿日期: 2009-06-02; 修回日期: 2009-08-02

基金项目: 国家自然科学基金重点项目(60736024)

$$X(k-1) + U(k) + W(k) \quad (1)$$

$$Z(k) = \begin{bmatrix} e, n, \frac{v_n a_e - v_e a_n}{v_e^2 + v_n^2}, T\sqrt{v_e^2 + v_n^2} \end{bmatrix}^T + [w_1, w_2, \epsilon_w, \epsilon_s]^T \quad (2)$$

$$\Phi_e(k, k-1)$$

$$= \begin{bmatrix} 1 & T & (T/\tau_{ae} - 1 + e^{-T/\tau_{ae}})\tau_{ae}^2 \\ 0 & 1 & (1 - e^{-T/\tau_{ae}})\tau_{ae} \\ 0 & 0 & e^{-T/\tau_{ae}} \end{bmatrix}$$

$$\Phi_n(k, k-1)$$

$$= \begin{bmatrix} 1 & T & (T/\tau_{an} - 1 + e^{-T/\tau_{an}})\tau_{an}^2 \\ 0 & 1 & (1 - e^{-T/\tau_{an}})\tau_{an} \\ 0 & 0 & e^{-T/\tau_{an}} \end{bmatrix}$$

构成了系统的状态转移矩阵。其中取 $T = 0.5s$, τ_{ae} 和 τ_{an} 分别为东向和北向机动加速度的相关时间常数; $U(k) = [0, 0, \overline{a_e}/\tau_{ae}, 0, 0, \overline{a_n}/\tau_{an}]^T$ 为控制向量, $W(k) = [0, 0, w_{ae}, 0, 0, w_{an}]^T$ 为系统噪声向量, w_1, w_2 分别为 GPS 输出的东向位置和北向位置的观测噪声, ϵ_w, ϵ_s 分别为陀螺仪的漂移和里程表的观测噪声, 均近似为高斯白噪声。将式(2)的观测向量 $Z(k)$ 在系统状态预测值附近用泰勒级数展开, 并忽略二次以上的高次项, 就可得到离散化、线性的观测方程:

$$Z(k) = h(k, \hat{X}(k, k-1)) + H(k)[X(k) - \hat{X}(k, k-1)] + V(k) \quad (3)$$

$$h(k, X(k)) = \begin{bmatrix} e, n, \frac{v_n a_e - v_e a_n}{v_e^2 + v_n^2}, T\sqrt{v_e^2 + v_n^2} \end{bmatrix}^T$$

$$H(k) = \frac{\partial h(k, X(k))}{\partial X(k)} | X(k) | = \hat{X}(k, k-1)$$

式中, $\omega(k)$ 是对系统状态产生影响的加速度噪声, $v(k)$ 是系统的观测噪声, $\omega(k)$ 和 $v(k)$ 的期望值均为零, 方差相互独立。卡尔曼滤波就是基于观测量 $Z(k)$ 求全局最优系统估计状态 $\hat{X}(k)$ 。

2.2 基于小波神经网络的自适应卡尔曼滤波

2.2.1 卡尔曼滤波

卡尔曼滤波采用时域上的递推算法, 由新获得的数据和前一时刻的估计值按照递推计算出新的估计值, 最后得到系统状态的最优估计。首先要确定初始状态的统计特性 $\hat{X}(0), P(0)$ 。 $\hat{X}(0)$ 直接由单点定位给出, $P(0)$ 按照经验确定, 选择大一些可使滤波收敛更快。

应用卡尔曼滤波获得最优估值的先决条件之一

是, 需预先知道系统的状态噪声方差阵 Q 和观测噪声方差阵 R , 而实际中对它们的统计特性的掌握往往不是很精确, 这不仅会影响滤波精度, 甚至会造成滤波发散。因此, 需要采用改进的卡尔曼滤波更精确估计模型中的噪声方差阵 Q 和 R 。以下介绍自适应卡尔曼滤波的基本思路。

由上节的离散状态方程和观测方程:

$$X(k) = \Phi(k, k-1)X(k-1) + U(k) + W(k) \quad (4)$$

$$Z(k) = H(k)X(k) + V(k) \quad (5)$$

式中, $X(k)$ 为 k 时刻的状态向量, $Z(k)$ 为观测向量, $V(k), W(k)$ 都是零均值的白噪声序列, $E\{W(k)\} = 0, E\{V(k)\} = 0, E\{W(k)W^T(j)\} = Q(k)\delta_{kj}, E\{V(k)V^T(j)\} = R(k)\delta_{kj}, \Phi(k, k-1)$ 为 $k-1$ 时刻到 k 时刻的系统状态转移矩阵, $H(k)$ 为系统观测矩阵。

获得新息 $\epsilon(k) = Z(k) - H(k)\hat{X}(k, k-1)$, 它是观测值与和估计值之差, 其统计性质对于滤波器输出的统计性质有决定的影响^[4]。由于新息序列与观测序列含有相同的统计数据, 故当滤波器模型准确时, 卡尔曼滤波器新息应该为零均值白噪声, 故利用实际检测到的新息来判断模型是否发生改变, 是否需要调整参数。当实际的余项在原假设 $Q(k-1), R(k-1)$ 下不相容时, 则对 $Q(k), R(k)$ 进行估计来取代原来假设的值。提出通过实时调整系统的噪声协方差来改变卡尔曼滤波器的误差方差矩阵和滤波增益阵。

将递推卡尔曼滤波方程的噪声协方差矩阵按以下方式进行调整:

$$R(k) = S_R^0(k)R \quad (6)$$

$$Q(k) = S_Q^0(k)Q \quad (7)$$

式中, R, Q 分别是噪声的初始常矩阵, $S_R^0(k)$ 和 $S_Q^0(k)$ 分别是由神经网络输出的自适应调解因子, 其中 $S > 0$, 而 a, b 是事先选定的常数。针对如何利用新息产生调节因子, 提出基于神经网络的调节因子产生方法——基于小波神经网络的自适应卡尔曼滤波技术。

2.2.2 基于新息的小波神经网络自适应卡尔曼滤波

首先根据观测数据离线进行神经网络的训练, 用来实现调解因子的实时获取, 然后再使用神经网络在线调整噪声方差阵, 使其根据实际的噪声水平得到动态的调整。

由于经过小波变换,小波系数在观测的粗差点邻域内远大于正常点的小波系数,采用周围点进行内插,可以有效剔除GPS/DR导航信号中的粗差.小波神经网络是基于小波分析理论所构造的一种神经网络模型,它充分利用小波变换良好的局部化性质,并结合神经网络的自学习能力,因而具有较强的逼近能力^[5].较BP网络比较,网络采用的基函数是正交小波基,权重之间相关冗余度很小,对某一权重的训练不会影响其他权重,故收敛速度快;另外,小波神经网络是局部逼近网络,易适应新数据,能避免较大的外推误差的优点;其结构也简单,可调参数最少,有利于缩短训练时间.

对小波母函数 $\Psi(\cdot)$ 进行伸缩、平移和旋转变换,得小波基函数:

$$(\Psi_{a,\theta,b}(x_{t-1}, \dots, x_{t-p}) = a^{-1} \Psi_{a,\theta,b}(a^{-1}r_{-\theta}, (x_{t-1} - b_{t-1}, \dots, x_{t-p} - b_{t-p})))$$

式中, a 是伸缩尺度, $b = [b_{t-1}, \dots, b_{t-p}]$ 为平移向量, $r_{-\theta}(x_{t-1}, \dots, x_{t-p}) = x_{t-i} \cos \theta - x_{t-j} \sin \theta$ 为旋转向量, 其中 $1 \leq i \leq j \leq p$. 小波神经网络逼近 $f(\cdot)$ 的形式为

$$\hat{f}(\cdot) = \sum_{i=1}^n w_i \Psi_{a,\theta,b}(\cdot) \quad (8)$$

采用梯度下降学习算法训练网络,构造代价函数为 $E = c(\phi) = \frac{1}{2} \sum_p [f_\phi(\cdot) - y]^2$, 其中 ϕ 为 $\hat{f}(\cdot)$ 中所有的参数, p 为训练样本数. 用输入/输出数据对去递归减小代价函数, 经过每个测量值的梯度算法, 参数 ϕ 沿函数 $c_k(\phi) = \frac{1}{2} [f_\phi(\cdot) - y_k]^2$ 的梯度方向减缓. 下面确定 $w_i, a_i, b_i, r_{-\theta}$ 使得小波网络的预测值 $f_\phi(\cdot)$ 与实际值 y_k 序列拟合最优.

隐层神经元采用高斯调频小波 $\Psi(t) = (e^{-i\omega_0 t} - e^{-\omega_0^2/2})e^{-t^2/2}$ 作为激活函数, 当 $\omega_0 \geq 5$ 时, 可忽略第二项, 近似表示为 $\Psi(t) = e^{-i\omega_0 t} e^{-t^2/2}$. 增加隐含层数虽然可以提高精度, 但是网络也需要更多的训练时间, 故采取的网络拓扑结构采用含有一个隐含层的结构, 而误差的减小通过增加隐含层神经元的数量来实现. 隐含层神经元的数量根据正交最小二乘法确定.

记 $e_k = f_\phi(\cdot) - y_k, Z_i = a(x - t_i)$, 则 $c_k(\phi)$ 关于参数向量 ϕ 的每个分量的偏微分为

$$\frac{\partial c}{\partial f} = e_k \quad (9)$$

$$\Delta w_i = \frac{\partial c}{\partial w_i} = e_k \cdot \Psi(Z_i) \quad (10)$$

$$\frac{\partial c}{\partial b_i} = -e_k \cdot w_i \cdot r_{-\theta} \cdot \Psi'(r_{-\theta}(Z_i)) \quad (11)$$

$$\frac{\partial c}{\partial a_i} = -e_k \cdot w_i \cdot r_{-\theta}^2 \cdot \Psi'(r_{-\theta}(Z_i)) \quad (12)$$

$$\frac{\partial c}{\partial r_{-\theta}} = -e_k \cdot w_i \cdot (x - t_i) \cdot \Psi'(r_{-\theta}(Z_i)) \quad (13)$$

训练算法具体步骤如下

- (1) 初始化 $w_i, a_i, b_i, r_{-\theta}$;
- (2) 按式(9) ~ 式(13) 计算(1) 中的参数;
- (3) 将(1) 中所求的参数代入式(8) 中, 求 $\hat{f}(\cdot)$;

$$(4) \text{ 计算误差 } \text{err} = \sqrt{\frac{\sum_{i=1}^n (f_i(\cdot) - y_i)^2}{\sum_{i=1}^n y_i}};$$

- (5) 重复步骤(2) ~ (4), 直到满足精度要求;
- (6) $i = i + 1$ 转到(2).

调解因子的实时获取采用协方差匹配技术, 通过新息协方差的理论值与实际值的一致程度来预测噪声协方差与实际噪声水平的一致程度, 并由此采用小波神经网络产生自适应调节因子, 抑制滤波器的发散.

卡尔曼滤波器新息方差的理论值^[6-7] 为

$$P_\epsilon(k) = H(k)(\Phi(k, k-1)P(k-1)\Phi^T(k, k-1))H^T(k) + R(k) \quad (14)$$

根据统计学的相关理论可以得到卡尔曼滤波器新息的实际值^[6-7] 为

$$\hat{P}_\epsilon(k) = \frac{1}{N} \sum_{i=k-N+1}^k \epsilon_i \epsilon_i^T \quad (15)$$

它是由当前时刻 k 的前 N 步的新息值来估计新息的实际值, 窗口宽度 N 由经验和试验反复测试获得^[6-7]. 定义一个新的矩阵变量 $\text{DOM}(k)$ 表示新息方差的理论值和实际值之间的不一致程度, 称为判断滤波状态因子.

$$\text{DOM}(k) = \text{diag}(P_\epsilon(k)) / \text{diag}(\hat{P}_\epsilon(k)) \quad (16)$$

当滤波器噪声的统计特性比较精确时, $\text{DOM}(k)$ 中的每个元素应该在 1 附近. 当 $\text{DOM}(k)$ 偏离 1 时, 表示噪声增大或是减小, 此时以 $\text{DOM}(k)$ 元素作为神经网络的输入, 输出为 R 和 Q 的自适应调节因子 $S_R^0(k)$ 和 $S_Q^0(k)$, 通过调节 $R(k)$ 和 $Q(k)$ 使 $\text{DOM}(k)$ 重新回到 1 附近. 基本流程如图 1 所示.




图1 基于神经网络的自适应卡尔曼滤波流程图

3 仿真分析

试验以基于小波神经网络的自适应卡尔曼滤波 GPS/DR 定位系统对位置和速度进行跟踪. 主要考虑观测噪声改变时的滤波效果, 取 R 的调节因子 $S_R^k(k)$ 中的定值 $a = 2$, 取 Q 的调节因子 $S_Q^k(k)$ 中的 $b = 0$, 即忽略系统噪声 $W(k)$ 改变的影响. 对小波神经网络进行训练, 训练样本对由实验选取, 当精度达到要求后训练结束, 进入在线工作状态.

在 MATLAB 6.5 中运行仿真程序, 比较在小波神经网络辅助下的卡尔曼滤波所获得的运动位置轨迹、速度曲线和实际曲线, 以及它们的误差曲线.

从图 2 和图 3 可以看出用基于神经网络辅助的卡尔曼滤波对的位置和速度的估计与实际运动曲线基本上重合, 误差较小, 经过长时间的运行也不会产生巨大偏差, 证明卡尔曼滤波器没有产生发散现象, 并能很好地提高 GPS/DR 系统的定位精度.

4 结束语

研究在一段连续时间提高 GPS/DR 定位精度, 减小定位误差的问题, 提出了基于小波神经网络的自适应卡尔曼滤波算法, 利用最近 N 个滤波新息数据, 监测新息序列协方差理论值和实际值比值的大




图2 位置测量值与估计值的比较曲线以及它们的误差曲线




图3 速度测量值与估计值的比较曲线以及误差曲线

小来评估卡尔曼滤波器的工作状况, 并通过神经网络跟踪系统参数的变化, 产生一个合适的自适应调节因子, 对卡尔曼滤波器进行在线调节, 从而显著改善了卡尔曼滤波器的性能, 防止滤波器发散. 通过试验

(下转第 30 页)

坡补偿电路. 电流检测电路通过检测功率管上的电压反应电感电流的变化, 同时消除了温度, 工艺等因素的影响, 斜坡补偿电路实现了补偿斜率随输入, 输出电压的自动调节, 避免了过补偿问题, 并成功应用于一款 BUCK 型 DC-DC 变换器中.

参考文献:

- [1] 程晓洁, 冯全源. 一种低功耗高可靠性的 CMOS 过流保护电路[J]. 微电子学与计算机, 2006, 23(1): 52-54.
- [2] Hassan Pooya Forghani-zadeh. Current-sensing techniques for DC-DC converters[J]. Midwest Symp on Circuits Syst, 2002(2): 577-580.
- [3] Cheung Fai Lee, Philip K T. Mok a monolithic current-mode CMOS DC-DC converter with on-chip current-sensing technique[J]. IEEE Journal of Solid-state Circuits, 2004, 39(1): 3-14.
- [4] Leung C Y, Mok P, Leung K N. A 1.2V buck converter with a novel on-chip low-voltage current-sensing scheme[C]// IEEE Int. Symp. on Ckt. & Sys. Canada, 2004.
- [5] Hylas Y H Lam, Wing-Hung Ki, Dongsheng Ma. Loop gain analysis and development of high-speed high-accuracy current sensors for switching converters[C]// ISCAS. Georgia: Atlanta, 2004: 828-831.
- [6] 李演明, 来新泉, 王红义. 降压型 DC-DC 转换器自调节型斜坡补偿电路设计[J]. 微电子学与计算机, 2005, 22(3): 274-276.
- [7] 来新泉, 周丽霞, 陈富吉. 升压型 DC-DC 转换器中的动态斜坡补偿电路设计[J]. 微电子学, 2005, 35(4): 420-423.
- [8] Chen Chilin, Hsieh Weilun. A high-speed and precise current sensing circuit with bulk control (CCB) technique [C]// IEEE Int. conf. Electronics, Circuits Syst. China: Shanghai, 2008: 283-287.

作者简介:

刘颖杰 女, (1984-), 硕士研究生. 研究方向为低压/低功耗模拟集成电路设计.
冯全源 男, 博士, 教授, 博士生导师. 研究方向为集成电路设计和半导体材料及器件.

(上接第 24 页)

仿真, 比较了经过滤波后所估计的位置和速度与实际测量位置和速度曲线, 说明这种算法能够很好地提高系统的定位精度, 使 GPS 定位有很强的鲁棒性.

参考文献:

- [1] 王惠南. GPS 导航原理与应用[M]. 北京: 科学出版社, 2003: 206-266.
- [2] 王志贤. 最优状态估计与系统辨识[M]. 西安: 西北工业大学出版社, 2004: 109-118.
- [3] 付梦印, 邓志红, 张继伟. Kalman 滤波理论及其在导航系统中的应用[M]. 北京: 科学出版社, 2003: 74-97.
- [4] 徐宁寿. 随机信号估计与系统控制[M]. 北京: 北京工业大学出版社, 2001: 236-250.
- [5] 田景问, 高美娟. 人工神经网络算法研究及应用[M]. 北京: 北京理工大学出版社, 2006: 109-119.
- [6] Sasiadek J Z, Wang Q, Zeremba M B. Fuzzy adaptive kalman filtering for INS/GPS data fusion[C]//Proc of the 15th IEEE Int Symposium on Intelligent Control. Patras, 2000: 181-186.
- [7] Mehra R K. Approaches to adaptive filtering[J]. IEEE Trans on Automatic Control, 1972, 17(10): 693-698.

作者简介:

魏武 男, (1970-), 博士, 教授, 硕士生导师. 研究方向为机器人.
魏敏 男, (1983-), 硕士研究生. 研究方向为嵌入式系统及应用.