

基于改进扩展卡尔曼滤波的姿态解算算法研究

冯少江¹ 徐泽宇² 石明全² 王晓东²

(重庆邮电大学计算机科学与技术学院 重庆 400065)¹

(中国科学院重庆绿色智能技术研究院 重庆 400714)²

摘要 为了解决标准扩展卡尔曼滤波器(EKF)在多旋翼无人机姿态解算中精度较低的问题,提出了一种改进扩展卡尔曼滤波算法(BPNN-EKF),使得解算精度得到较大提升。针对 EKF 存在预测模型参数要求具有先验已知性,在工程实践中难以获得准确的参数,以及标准 EKF 对非线性系统采用线性化模型带来的误差等问题,利用神经网络的非线性映射能力和自适应能力对标准 EKF 的估计值进行补偿,减小模型以及滤波参数误差对最优估计值的影响,从而提高最优估计精度。仿真实验证明,BPNN-EKF 对多旋翼无人机姿态解算精度的提升具有显著作用。

关键词 扩展卡尔曼滤波器,姿态解算算法,非线性系统,BP 神经网络

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.09.042

Research on Attitude Algorithm Based on Improved Extended Kalman Filter

FENG Shao-jiang¹ XU Ze-yu² SHI Ming-quan² WANG Xiao-dong²

(College of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)¹

(Research Institute of Chongqing Green Intelligent Technology, Chinese Academy of Sciences, Chongqing 400714, China)²

Abstract In order to solve the problem that standard extended Kalman filter (EKF) in the multi-rotor UAV attitude solver has lower accuracy, an improved extended Kalman filter algorithm (BPNN-EKF) was proposed to improve the accuracy greatly. EKF prediction model parameters require the presence of priori known properties, but in engineering practice it is difficult to obtain accurate parameters. And nonlinear systems using linear model will cause error problem for standard EKF. Aiming at above problems, we used nonlinear mapping ability of neural network and adaptive ability to compensate the estimated value of the standard EKF, reduce the impact of the model as well as filtering parameters error for optimal estimates, thereby enhancing optimal estimation accuracy. The simulation results show that BPNN-EKF plays a significant role in improving multi-rotor UAV attitude solver accuracy.

Keywords Extended Kalman filter, Attitude algorithm, Nonlinear system, BP neural network

1 引言

卡尔曼滤波算法广泛应用在多传感器数据融合、航天器姿态解算与控制中。卡尔曼滤波在线性系统的假设下要求预测模型和观测模型的噪声具有先验已知性^[1]。但在工程实践中所遇到的物理系统数学模型往往不满足这些前提,例如姿态解算系统的预测模型是非线性的,噪声具有非先验性。无人机的姿态解算系统采用扩展卡尔曼滤波算法(EKF)进行参数估计与信息融合,该算法针对系统姿态解算参数建模,滤波器的预测方程是非线性的,在线性化时会引入模型误差^[2]。

人工神经网络自提出以来,由于良好的非线性映射能力、

较强的自学习能力,应用领域不断拓展^[3]。其中 BP 网络模型是常用的神经网络模型之一。随着神经网络技术的不断发展以及应用领域的不断延伸,神经网络与卡尔曼滤波有机结合为新的数据融合方法,成为了国内外在该领域的研究热点^[4-6]。

本文采用描述多旋翼无人机姿态变化的运动学模型,从惯性传感器输出的当前姿态数据入手,将各种误差因素综合起来看作一个总误差因素,提出了一种改进的扩展卡尔曼滤波算法。该算法采用 BP 神经网络在时间更新部分对标准扩展卡尔曼滤波器进行补偿,提高了其在动态噪声扰动环境中的自适应能力。最后,仿真结果表明 BPNN-EKF 有效提升了姿态角的解算精度。

到稿日期:2016-08-17 返修日期:2016-12-09 本文受国家质检公益性行业科研专项项目:民用涵道式无人飞行器和工业机器人质量安全检测技术研究(Y42Z130I10)资助。

冯少江(1991-),男,硕士生,主要研究方向为多旋翼无人机姿态解算算法,E-mail: fengshaojiang@cigit.ac.cn;徐泽宇(1973-),硕士,高级工程师,主要研究方向为精密测量与智能控制技术,E-mail: xzy@cigit.ac.cn;石明全(1975-),男,博士,副教授,主要研究方向为虚拟样机技术、复杂机械系统动态仿真及优化,E-mail: shimq@cigit.ac.cn;王晓东(1987-),男,硕士,工程师,主要研究方向为机电一体化,E-mail: sdwang@cigit.ac.cn。

2 改进的扩展卡尔曼滤波算法设计

2.1 标准的扩展卡尔曼滤波算法分析

非线性离散系统的方程可由以下形式描述^[7]:

$$\begin{cases} X_k = f[X_{k-1}, k-1] + \Gamma_{k-1} W_{k-1} \\ Z_k = h[X_k, k] + V_k \end{cases} \quad (1)$$

其中, $f[\cdot]$ 是 n 维向量函数, 对其自变量而言是非线性的; $h[\cdot]$ 是 m 维向量函数, 它对自变量而言也是非线性的; W_{k-1} 与 V_k 为彼此不相关的零均值白噪声序列, 与初始状态 X_0 不相关; Γ_{k-1} 为 $k-1$ 时刻状态方程误差向量的系数矩阵; X_k 为 k 时刻的状态向量, Z_k 为 k 时刻的观测向量。对于 $k-1 \geq 0$, 有:

$$\begin{cases} E[W_{k-1}] = 0, & E[W_{k-1} W_j^T] = Q_{k-1} \delta_{k-1, j-1} \\ E[V_k] = 0, & E[V_k V_j^T] = R_k \delta_{k, j} \end{cases} \quad (2)$$

对于式(1)对应的非线性系统, 由于 $f[\cdot]$ 和 $h[\cdot]$ 不能直接应用在协方差矩阵的推导中, 因此将其转化为求雅克比矩阵来实现非线性方程的线性化^[8]。EKF 算法主要包括以下递推方程:

(1) 状态一步预测

$$\hat{X}_{k|k-1} = \Phi_{k, k-1} \hat{X}_{k-1} \quad (3)$$

(2) 状态估计

$$\hat{X}_k = \hat{X}_{k-1} + K_k (Z_k - H_k \hat{X}_{k|k-1}) \quad (4)$$

(3) 滤波增益

$$K_k = (P_{k|k-1} H_k^T) (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (5)$$

(4) 一步预测均方误差

$$P_{k|k-1} = \Phi_{k, k-1} P_{k-1} \Phi_{k, k-1}^T + \Gamma_{k-1} Q_{k-1} \Gamma_{k-1}^T \quad (6)$$

(5) 估计均方误差

$$P_k = (I - K_k H_k) P_{k|k-1} \quad (7)$$

其中, $\Phi_{k, k-1}$ 为第 $k-1$ 时刻到第 k 时刻的状态转移矩阵, H_k 为第 k 时刻的观测方程系数矩阵, Q_{k-1} 为第 k 时刻的动态噪声, R_k 为第 k 时刻的量测噪声。

式(3)~式(7)是卡尔曼滤波的基本关系式, 它是一种递推式的方法, 结合前一时刻的估计值、系统本身的状态方程及新数据的更新, 即可求得新的估计值。从以上推导过程中可以看到标准卡尔曼滤波的问题:

(1) 非线性模型线性化的最优估计问题。卡尔曼滤波是一种线性最小方差估计, 一般通过保留泰勒展开式的线性部分来实现非线性模型的线性化, 显然存在线性化误差。

(2) 滤波增益的计算与维数问题。由增益的表达式(5)可以看出, 增益是由状态转移矩阵、量测矩阵、过程噪声协方差矩阵、量测噪声协方差矩阵计算得到的^[9], 这些参数要求具有先验已知性, 但在实际问题中往往不具有这种特性, 由于参数的不准确会导致最优估计值的误差较大, 且状态预测协方差矩阵依然较小, 因此增益矩阵将会逐渐失去调整作用, 最终导致滤波值失去收敛性^[10]。

2.2 BP 网络辅助的扩展卡尔曼滤波算法设计

BP 神经网络是一种智能信息融合技术, 具有高度非线性映射能力和自适应能力, 适合于比较复杂的系统^[11], 因此采用 BP 神经网络对扩展卡尔曼滤波估计值进行补偿, 从而减小模型以及滤波参数误差对最优估计值的影响, 提高滤波算法的精度。

BP 网络辅助的扩展卡尔曼滤波算法的原理是: 通过设计好的神经网络结构的初始参数, 根据输入样本对 BP 网络进行训练, 然后保存训练好的神经网络权值和阈值; 在扩展卡尔曼滤波器执行姿态参数估计时, 将影响姿态估计误差的参数作为神经网络的输入, 利用神经网络对整体误差进行调控, 利用神经网络的非线性映射能力和自适应能力从补偿角度修正扩展卡尔曼滤波的结果, 从而提高滤波精度。具体的训练方法为: 获取扩展卡尔曼滤波的状态一步预测值与状态估计值的差值 $\hat{X}_k - \hat{X}_{k|k-1}$ 作为 BP 神经网络的输入样本, 将真实值与状态估计值的差值 $Z_k - \hat{X}_k$ 作为 BP 神经网络的输出样本, 神经网络通过学习扩展卡尔曼滤波预测误差与实际误差的映射关系, 就可以近似输出滤波估计值与实际值之间的误差 B_{perr} 。

改进的扩展卡尔曼滤波算法流程如图 1 所示, 将传感器信息以及用于预测方程推导的三轴角加速度输入扩展卡尔曼滤波, 经过时间更新与量测更新, 得到滤波结果, 同时将滤波的状态估计值与状态一步预测值差值 $\hat{X}_k - \hat{X}_{k|k-1}$ 输入到训练好的 BP 网络中; 然后, 网络给出滤波结果与实际值的误差; 最后, 对 EKF 滤波的最优估计值与神经网络的输出求和即为改进的 EKF 算法最优估计值:

$$\hat{X}_k' = \hat{X}_k + B_{perr} \quad (8)$$

其中, \hat{X}_k' 为改进后算法的输出值, B_{perr} 为 BP 神经网络的输出值, \hat{X}_k 为 EKF 状态估计值。




图1 改进的扩展卡尔曼滤波算法示意图

3 姿态解算仿真实验与结果分析

3.1 样本数据说明

从多旋翼无人机飞行控制器飞控日志中提取 2000 组 IMU 与 MAG 数据作为样本, 其中 IMU 为三轴陀螺仪和三轴加速度计的测量值, MAG 为三轴磁力计的测量值。多旋翼无人机在飞行过程中的姿态变化较慢, 姿态角的变化范围在 10° 以内。

3.2 BP 神经网络训练及性能评价

由于姿态角的变化具有时序性, 取 2000 组样本的前 1800 组作为 BP 网络的离线训练样本, 其余 200 组作为验证样本。采用 MATLAB R2012b 编程, 网络结构为 9-20-9, 因为为了方便角速度的动力学建模而在预测模型中引入了角加速度, 但没有对应的传感器, 所以状态值中的第 3~5 维数据即角加速度无法作为神经网络的输入值, 因此输入样本为 $(\tilde{X}_k(1:3); \tilde{X}_k(7:12)) - (\tilde{X}_{k|k-1}(1:3); \tilde{X}_{k|k-1}(7:12))$, 输出样本为 $Z_k - (\tilde{X}_k(1:3); \tilde{X}_k(7:12))$, 隐层单元的传递函数取 tan-sig, 其表达式为:

$$y \leftarrow 2 / [1 + \exp(-2 \cdot r)] - 1 \quad (9)$$

输出层神经元采用线性函数 purelin 对神经网络进行训

练,当网络输出结果符合要求时保存网络的权值与阈值。

采用预测值均值与实际值均值的偏差来评价算法性能,采用预测相对误差(PRE)来评价姿态角的解算精度:

$$performance = \sum_{i=1}^n |\overline{pre} - \bar{z}| / n \quad (10)$$

$$PRE = \frac{\sum_{i=1}^n |x_{i,predicted} - x_{i,actual}|}{n} \quad (11)$$

其中, \overline{pre} 为预测值均值, \bar{z} 为实际值均值, $x_{i,predicted}$ 为预测过程中 i 样本的预测值, $x_{i,actual}$ 为 i 样本的量测值, PRE 和 $performance$ 的值越小说明模型的预测能力越强。

3.3 BPNN-EKF 算法的仿真过程

以下是算法的执行过程。

Step1 初始化: EKF 状态预测模型状态初值 $\tilde{X}_0 = [0; 0; 0; 0; 0; 0; 0; 0; -9.81; 1; 0; 0]$ 、状态协方差初值 $P_0 = 200 * \text{ones}(12)$ 、量测噪声 $R = \text{diag}[0.0008, 0.0008, 0.0008, 10000, 10000, 10000, 100, 100, 100]$ 、动态噪声 $Q = \text{diag}([0.001, 0.001, 0.001; 0.08, 0.08, 0.08; 0.009, 0.009, 0.009; 0.005, 0.005, 0.005])$ 、时间间隔 $dt = 0.1$ 、转动惯量 $J = [0.0018 \ 0 \ 0; 0 \ 0.0018 \ 0; 0 \ 0 \ 0.0037]$ 。

Step2 计算状态一步预测值 \tilde{X}_k^- 、新息 η_k 、滤波增益 K_k 、状态最优估计值 \tilde{X}_k 、状态预测协方差矩阵 \tilde{P}_k 。

状态预测值的计算可以分为 4 个部分。

1) 计算下一时刻角速度 $\omega_k = (\omega_{kx}, \omega_{ky}, \omega_{kz})$:

$$\omega_k \leftarrow \omega_{k-1} + \omega a_k * dt$$

2) 计算下一时刻角加速度 $\omega a_k = (\omega a_{kx}, \omega a_{ky}, \omega a_{kz})$:

$$\omega a_k \leftarrow \omega a_{k-1} + J^{-1} * [-\omega a_{k-1} \otimes (J * \omega a_{k-1})] * dt$$

3) 计算下一时刻加速度 $a_k = (a_{kx}, a_{ky}, a_{kz})$:

$$R_k^{\phi} \leftarrow \begin{bmatrix} \cos\theta\cos\psi & \sin\theta\sin\psi\cos\phi - \cos\phi\sin\psi & \sin\theta\cos\phi\cos\psi + \sin\phi\sin\psi \\ \cos\theta\sin\psi & \sin\theta\sin\psi\sin\phi + \cos\phi\cos\psi & \sin\theta\sin\phi\cos\phi - \sin\phi\sin\psi \\ -\sin\theta & \sin\phi\cos\theta & \cos\phi\cos\theta \end{bmatrix}$$

Step6 根据 Step5 得到的 R_k^{ϕ} 可以计算得到横滚角 ϕ 和俯仰角 θ 和偏航角 ψ :

$$\begin{bmatrix} \phi \\ \theta \\ \psi \end{bmatrix} \leftarrow \begin{bmatrix} \arctan(\frac{R_{32}}{R_{33}}) \\ -\arcsin(R_{31}) \\ \arctan(\frac{R_{21}}{R_{11}}) \end{bmatrix}$$

Step7 根据 Step2—Step6 将得到的新值进行下一轮运算。

3.4 实验结果与分析

由于传感器的度量单位不同,因此不同传感器的数量级差距较大。改进后的 EKF 算法与标准 EKF 算法的性能对比如表 1 所列。

表 1 经过 BP 网络改进的 EKF 与标准 EKF 的性能预测效果

状态变量	EKF	BPNN_EKF	误差降低度/%
Gyro_x	0.0086	0.0050	41.86
Gyro_y	0.0011	0.0008	27.27
Gyro_z	0.0086	0.0080	6.98
Acc_x	3.8149	0.3295	91.36
Acc_y	4.7571	0.5560	88.31
Acc_z	1.2795	1.0663	16.66
Mag_x	14.6397	3.0018	79.50
Mag_y	30.1998	2.3283	92.29
Mag_z	33.9592	1.5046	95.57

将 EKF 模型、BPNN-EKF 模型的姿态角解算值与实际

$$a_k \leftarrow (I_{3 \times 3} + O * dt) * a_{k-1}$$

其中, $I_{3 \times 3}$ 是单位矩阵, O 为动坐标系相对地理坐标系的角速度叉乘算子。

4) 计算磁向量 $mag_k = (mag_{kx}, mag_{ky}, mag_{kz})$:

$$mag_k \leftarrow (I_{3 \times 3} + O * dt) * mag_{k-1}$$

5) 计算新息 η_k :

$$\eta_k \leftarrow Z_k - H_k * \tilde{X}_k^-$$

6) 计算滤波增益矩阵 K_k :

$$K_k \leftarrow (P_{k|k-1} H_k^T) / (H_k P_{k|k-1} H_k^T + R_k)$$

7) 计算最优估计值 $\tilde{X}_k = (\tilde{X}_{k1}, \tilde{X}_{k2}, \dots, \tilde{X}_{k12})$:

$$\tilde{X}_k \leftarrow \tilde{X}_k^- + K_k * \eta_k$$

8) 更新预测协方差矩阵 \tilde{P}_k :

$$\tilde{P}_k \leftarrow (I_{12 \times 12} - K_k * H_k) * \tilde{P}_k^-$$

Step3 由 Step2 可计算 $\tilde{X}_k - \tilde{X}_k^-$, 将其中 1~3, 7~12 维数据输入到训练好的 BP 神经网络中, 经过计算得到网络输出值 $Bperr$ 。

Step4 将 Step2 计算得到的 \tilde{X}_k 中第 1~3, 7~12 维数据与 Step3 中计算得到的 $Bperr$ 相加:

$$\tilde{X}_k' \leftarrow (\tilde{X}_k(1:3); \tilde{X}_k(7:12)) + Bperr$$

Step5 将 Step4 中的数据 \tilde{X}_k' 进行数据归一化处理得到地理坐标系到机体坐标系的余弦转换矩阵, 将地理坐标系 X 轴、Y 轴、Z 轴方向定义为北、东、天方向, 机体坐标系 X 轴位于飞行器参考平面内平行于机身轴线并指向飞行器前方, Y 轴垂直于飞行器参考面并指向飞行器右方, Z 轴在参考面内垂直于 XOY 平面, 指向航空器下方^[12]。 $R_n^b = [X_n^b, Y_n^b, Z_n^b]$, 即:

值进行对比, 结果如图 2—图 4 所示。从图 2—图 4 中可以看到, 在 0~400 时序内, 经过神经网络补偿的扩展卡尔曼滤波器由于初值选取不当, 模型误差以及参数误差导致两种算法的预测误差都比较大, 但 BPNN-EKF 的预测效果明显优于标准 EKF; 在 400~2000 时序内, 经过 BP 神经网络补偿的滤波输出值几乎等于实际值, 而标准 EKF 的预测误差一直保持在较大范围内。这表明经过训练的神经网络对扩展卡尔曼滤波估计值进行补偿修正, 使 EKF 很大程度上摆脱了对系统数学模型、过程噪声以及量测噪声的先验性要求, 不仅加快了滤波器的收敛速度, 还大大提高了滤波器的稳定性和估计值精度。




图 2 预测横滚角与实际角度的对比曲线

commender system[C]//Xxv International Conference on Information, Communication and Automation Technologies, 2015; 1-6.

[10] XIA C, JIANG X, LIU S, et al. Dynamic item-based recommendation algorithm with time decay[C]//International Conference on Natural Computation(Icnc 2010). Yantai, Shandong, China, 2010; 242-247.

[11] KARAHODZA B, SUPIC H, DONKO D. An approach to design of time-aware recommender system based on changes in group user's preferences[C]// X International Symposium on Telecommunications, 2014; 1-4.

[12] ZHANG Y C, CHEN C. A Collaborative Filtering Algorithm Based on Time Period Partition[C]//Third International Symposium on Intelligent Information Technology and Security Informatics. IEEE Computer Society, 2010; 777-780.

[13] CREMONESI P, KOREN Y, TURRIN R. Performance of recommender algorithms on top-n recommendation tasks[C]// ACM Conference on Recommender Systems(Recsys 2010). Barcelona, Spain, 2010; 39-46.

[14] JIN R, SI L, ZHAI C X, et al. Collaborative filtering with decoupled models for preferences and ratings[C]// ACM CIKM International Conference on Information and Knowledge Management. New Orleans, Louisiana, Usa, 2003; 309-316.

[15] ADIBI P, LADANI B T. A collaborative filtering recommender system based on user's time pattern activity[C]// Information and Knowledge Technology, 2013; 252-257.

[16] BOBADILLA J, ORTEGA F, HERNANDO A, et al. A collaborative filtering approach to mitigate the new user cold start problem[J]. Knowledge-Based Systems, 2012, 26; 225-238.

(上接第 229 页)




图 3 预测俯仰角与实际角度的对比曲线




图 4 预测偏航角与实际角度的对比曲线

结束语 本文将神经网络的非线性映射能力运用到扩展卡尔曼滤波算法中,提出了一种改进的扩展卡尔曼滤波算法,并将该算法应用于无人机姿态解算中,经过神经网络输出值的误差补偿,改进后的扩展卡尔曼滤波器各个维度的预测值的误差分别降低了 41.86%, 27.27%, 6.98%, 91.36%, 88.31%, 16.66%, 79.50%, 92.29%, 95.57%;由式(14)计算得到姿态角 φ, θ, ψ 的解算精度分别提升了 41.63%, 22.88%, 64.33%。仿真结果证明,改进的 EKF 算法是一种非常有效的姿态解算算法。

参 考 文 献

[1] LIU M M, QIN P L, CHANG J, et al. New improved algorithm based on EKF information theory [J]. Application Research of Computers, 2015, 32(5): 1569-1571. (in Chinese)

刘毛毛,秦品乐,常江,等.基于多新息理论的 EKF 改进算法[J].计算机应用研究,2015,32(5):1569-1571.

[2] JIANG E S, LI M C, SUN L J. Improved Kalman filter method based on neural network [J]. Journal of Electronics & Information Technology, 2007, 29(9): 2073-2076. (in Chinese)

蒋恩松,李孟超,孙刘杰.一种基于神经网络的卡尔曼滤波改进方法[J].电子与信息学报,2007,29(9):2073-2076.

[3] GURUNG H, BANERJEE A. Self-sensing SMA Actuator Using Extended Kalman Filter and Artificial Neural Network[J]. Procedia Engineering, 2016, 144(25): 629-634.

[4] HAJIYEV C, CILDEN D, SOMOV Y. Gyro-free attitude and rate estimation for a small satellite using SVD and EKF [J]. Aerospace Science and Technology, 2016, 74(8): 325-328.

[5] ZHAO Y W. Performance evaluation of Cubature Kalman filter in a GPS/IMU tightly-coupled navigation system [J]. Signal Processing, 2016, 119(21): 178-182.

[6] HE Y, GUAN X, WANG G H. multi-sensor data fusion research progress and Prospect [J]. Journal of Astronautics, 2005, 26(4): 524-529. (in Chinese)

何友,关欣,王国宏.多传感器信息融合研究进展与展望[J].宇航学报,2005,26(4):524-529.

[7] 秦永元,张洪钺,汪叔华.卡尔曼滤波与组合导航原理(第三版)[M].西安:西北工业大学出版社,2015:199-200.

[8] TANG L. Neural Networks and Kalman filter algorithm [D]. Harbin: Harbin Institute of Technology, 2007. (in Chinese)

唐蕾.神经网络与卡尔曼滤波算法的研究[D].哈尔滨:哈尔滨工业大学,2007.

[9] GREWAL M S, ANDREWS A P. Kalman Filtering: Theory and Practice Using Matlab (3rd edition) [M]. Hoboken: Wiley & Sons, Inc, 2008.

[10] LI Z L, CHEN W B, ZOU H J, et al. Adaptive Neural Network Information Kalman filter [J]. Hunan University of Technology, 2011, 25(1): 105-108. (in Chinese)

李忠良,陈卫兵,邹豪杰,等.基于信息的神经网络自适应卡尔曼滤波[J].湖南工业大学学报,2011,25(1):105-108.

[11] JIANG C P. Design and Realization of a four-rotor UAV control system [D]. Harbin: Harbin Institute of Technology, 2014. (in Chinese)

姜成平.一种四旋翼无人机控制系统的设计与实现研究[D].哈尔滨:哈尔滨工业大学,2014.