

基于粗大误差检测和补偿的改进型 EKF 动态目标跟踪算法

张迪, 张正江, 胡桂廷, 朱志亮

(温州大学 电气数字化设计技术国家地方联合工程实验室, 浙江 温州 325035)

摘要: 卡尔曼滤波作为当前动态目标跟踪中的常用滤波算法, 研究其动态跟踪的准确性对于军事制导, 交通导航等领域具有重大意义; 针对动态系统目标跟踪观测过程中存在的坏值、静差和漂移 3 种粗大误差, 基于传统扩展卡尔曼滤波 (Extended Kalman Filter, EKF) 算法框架, 引入了一种粗大误差检测和补偿方法, 实现了对动态系统观测值中粗大误差的准确辨识和优化补偿, 使得扩展卡尔曼滤波能够结合粗大误差检测和补偿方法有效地排除观测值中的粗大误差, 滤波后的状态估计值更加准确地逼近真实值; 经过仿真实验和对比, 提出的改进型 EKF 算法能有效地排除粗大误差观测值对状态预测过程的影响, 并且实现了对动态系统目标的准确跟踪, 这大大提高了动态目标跟踪的精确度。

关键词: 动态目标跟踪; 粗大误差; 扩展卡尔曼滤波

Gross Error Detection and Compensation Based Modified EKF Algorithm for Dynamic Target Tracking

Zhang Di, Zhang Zhengjiang, Hu Guiting, Zhu Zhiliang

(National-Local Joint Engineering Laboratory for Digitalize Electrical Design Technology, Wenzhou University,
Wenzhou 325035, China)

Abstract: Kalman filtering is a commonly used filtering algorithm in current dynamic target tracking. It is of great significance to study its dynamic tracking accuracy for military guidance, traffic navigation and other fields. Three kinds of gross errors including outliers, biases and drifts, are considered in the observations of dynamic target tracking system. Based on the traditional Extended Kalman Filter (EKF) framework, a methodology of gross error detection and compensation realizes the accurate identification and compensation of the gross errors in the observations. So that the modified EKF can effectively eliminate the gross errors in the observations by combining the system equations and the results of state estimation is closer to the true values. After simulations and comparisons, the modified EKF algorithm achieves accurate tracking of dynamic targets by effectively eliminating the influence under the condition of different types of gross errors in the observations. It can greatly improve the accuracy of dynamic target tracking.

Keywords: dynamic target tracking; gross error; extended Kalman filter

0 引言

卡尔曼滤波理论^[1-2]是目前最重要的最优估计理论之一, 因其目标跟踪算法实用性强, 滤波效率高, 状态估计结果较为优化, 在寻的制导、路径识别、视频监控等领域得到广泛应用。卡尔曼滤波算法在线性系统中为最优估计算法, 但工业中实际的系统往往为非线性系统, 因此, 针

对非线性系统提出了扩展卡尔曼滤波算法 (Extended Kalman Filter, EKF)^[3]。扩展卡尔曼滤波的思想是基于非线性方程的线性化。扩展卡尔曼滤波状态估计的精确度与系统方程非线性程度密切相关。系统的非线性程度越小, 滤波结果越精确。

目前, 国内外学者基于扩展卡尔曼滤波解决了很多工业中的工程问题。赵佳等为解决无人飞行器姿态传感器低成本高精度的要求, 引入扩展卡尔曼滤波算法, 有效地消除了无人机飞行器运动过程对姿态解算精度的影响^[4]。陈清华等针对锂电池剩余电量 (SOC) 无法精确估算的问题, 提出了一种基于改进 Thevenin 模型的 EKF 算法^[5], 实现了锂电池 SOC 的精确估算。

上述扩展卡尔曼滤波算法是基于动态目标跟踪过程中观测值只含随机误差的情况, 但是实际观测值中难免会出现各种粗大误差 (gross errors)^[6], 比如坏值 (outlier)、静

收稿日期: 2019-03-27; 修回日期: 2019-04-28。

基金项目: 国家自然科学基金项目 (61703309); 浙江省自然科学基金项目 (LY18F030014); 浙江省科技计划项目 (LGG18F040002)。

作者简介: 张迪 (1998-), 男, 浙江湖州人, 主要从事状态估计方向的研究。

张正江 (1982-), 男, 江西乐平人, 副教授, 硕士研究生导师, 主要从事状态估计、系统建模与控制方向的研究。

差 (bias) 和漂移 (drift) 等^[6]。受到粗大误差的影响, 动态目标跟踪的滤波状态容易出现异常, 这直接影响状态估计的准确性。本文提出一种基于粗大误差观测值检测和补偿的改进型 EKF 动态目标跟踪算法, 通过对粗大误差观测值的精确检测和优化分类补偿, 弥补了传统的 EKF 算法对于实际应用中的不足。实验仿真结果表明, 改进型 EKF 算法能够实现粗大误差观测值下的动态系统目标跟踪, 且具有较好的准确性。

1 扩展卡尔曼滤波算法

非线性离散系统的动态方程如下:

$$\mathbf{X}(k+1) = f[k, \mathbf{X}(k)] + \mathbf{G}(k)\mathbf{W}(k) \quad (1)$$

$$\mathbf{Z}(k) = h[k, \mathbf{X}(k)] + \mathbf{V}(k) \quad (2)$$

式 (1) 为系统状态方程, 式 (2) 为观测方程。 $\mathbf{X}(k)$ 是 n 维系统状态向量; $\mathbf{Z}(k)$ 是 m 维观测向量; $f[k, \mathbf{X}(k)]$ 和 $h[k, \mathbf{X}(k)]$ 是 $\mathbf{X}(k)$ 和 $\mathbf{Z}(k)$ 对应的非线性系统函数; $\mathbf{G}(k)$ 是系统噪声驱动矩阵; $\mathbf{W}(k)$ 则是零均值系统白噪声矩阵; $\mathbf{V}(k)$ 是零均值观测白噪声, 且 $\{\mathbf{W}(k)\}$ 和 $\{\mathbf{V}(k)\}$ 互不相关。将式 (1) 中 $\mathbf{X}(k+1)$ 做一阶泰勒展开, 得:

$$\begin{aligned} \mathbf{X}(k+1) \approx f[k, \hat{\mathbf{X}}(k)] + \frac{\partial f}{\partial \mathbf{X}(k)} [\mathbf{X}(k) - \hat{\mathbf{X}}(k)] + \\ \mathbf{G}[\hat{\mathbf{X}}(k), k]\mathbf{W}(k) = \mathbf{F}(k+1|k)\mathbf{X}(k) + \mathbf{G}(k) + \\ \mathbf{W}(k) + \varphi(k) \end{aligned} \quad (3)$$

$$\mathbf{F}(k+1|k) = \left. \frac{\partial f}{\partial \mathbf{X}(k)} \right|_{\mathbf{X}(k)=\hat{\mathbf{X}}(k)} \quad (4)$$

$$\varphi(k) = f[\hat{\mathbf{X}}(k)] - \left. \frac{\partial f}{\partial \mathbf{X}(k)} \right|_{\mathbf{X}(k)=\hat{\mathbf{X}}(k)} \hat{\mathbf{X}}(k) \quad (5)$$

$\hat{\mathbf{X}}(k)$ 表示状态估计值, $\mathbf{X}(k) - \hat{\mathbf{X}}(k)$ 表示 k 时刻的估计值与状态值的差值。 $\mathbf{F}(k+1|k)$ 是状态转移矩阵, 是根据 k 时刻的最优状态值来估计 $k+1$ 时刻的状态值。

将式 (2) 中的 $\mathbf{Z}(k)$ 做一阶泰勒展开, 得:

$$\mathbf{Z}(k) \approx h[k, \hat{\mathbf{X}}(k)] + \frac{\partial h}{\partial \mathbf{X}(k)} [\mathbf{X}(k) - \hat{\mathbf{X}}(k)] +$$

$$\mathbf{V}(k) = \mathbf{H}(k)\mathbf{X}(k) + y(k) + \mathbf{V}(k) \quad (6)$$

$$\mathbf{H}(k) = \left. \frac{\partial h}{\partial \mathbf{X}(k)} \right|_{\mathbf{X}(k)=\hat{\mathbf{X}}(k)} \quad (7)$$

$$y(k) = h[\hat{\mathbf{X}}(k)] - \left. \frac{\partial h}{\partial \mathbf{X}(k)} \right|_{\mathbf{X}(k)=\hat{\mathbf{X}}(k)} \hat{\mathbf{X}}(k) \quad (8)$$

通过式 (1) ~ (8) 的变换, n 维的非线性状态方程和 m 维的非线性观测方程可以转化为下式:

$$\mathbf{X}(k+1) = \mathbf{F}(k+1|k)\mathbf{X}(k) + \mathbf{G}(k)\mathbf{W}(k) + \varphi(k) \quad (9)$$

$$\mathbf{Z}(k) = \mathbf{H}(k)\mathbf{X}(k) + y(k) + \mathbf{V}(k) \quad (10)$$

式 (9) 和式 (10) 是将非线性方程线性化之后的一阶线性方程, 与传统的卡尔曼滤波方程相比, 状态转移矩阵 $\mathbf{F}(k+1|k)$ 和观测矩阵 $\mathbf{H}(k)$ 都是根据 $f[k, \mathbf{X}(k)]$ 和 $h[k, \mathbf{X}(k)]$ 的 Jacobian 矩阵代替。根据传统线性卡尔曼滤波的递推方程, 对系统进行滤波处理, 得到非线性系统近似的最优估计值。

与卡尔曼滤波的基本方程^[1] 类比, 可以得到扩展卡尔

曼滤波递推方程:

$$\hat{\mathbf{X}}(k+1|k) = f(\hat{\mathbf{X}}(k|k)) \quad (11)$$

$$\mathbf{P}(k+1|k) = \mathbf{F}(k+1|k)\mathbf{P}(k|k)$$

$$\mathbf{F}^T(k+1|k) + \mathbf{Q}(k+1) \quad (12)$$

$$\mathbf{K}(k+1) = \mathbf{P}(k+1|k)\mathbf{H}^T(k+1|k)$$

$$[\mathbf{H}(k+1)\mathbf{P}(k+1|k)\mathbf{H}^T(k+1) + \mathbf{R}(k+1)]^{-1} \quad (13)$$

$$\hat{\mathbf{X}}(k+1|k+1) = \hat{\mathbf{X}}(k+1|k) +$$

$$\mathbf{K}(k+1)[\mathbf{Z}(k+1) - h(\hat{\mathbf{X}}(k+1|k))] \quad (14)$$

$$\mathbf{P}(k+1) = [\mathbf{I} - \mathbf{K}(k+1)\mathbf{H}(k+1)]\mathbf{P}(k+1|k) \quad (15)$$

式中, $\mathbf{P}(k+1|k)$ 表示根据上一个 k 时刻的协方差值来估计 $k+1$ 时刻的协方差值。 $\mathbf{P}(k+1)$ 表示 $k+1$ 时刻更新的协方差值。

2 观测值的粗大误差

2.1 粗大误差的类型

观测数据中通常出现的粗大误差大致有 3 种, 分别是坏值 (outlier), 静差 (bias) 和漂移 (drift), 如图 1 所示。

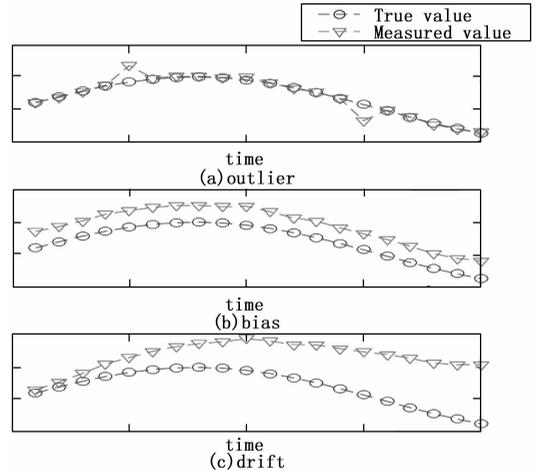


图 1 存在粗大误差情况下的观测值

坏值: 也称异常值或离群值, 如图 1 (a) 所示, 坏值是观测数据中明显偏离其他观测数据的异常观测值, 通常情况下为个别观测数据。假设第 n 个观测变量在 k_i 时刻出现了坏值, 那么 k_i 时存在坏值的观测值可以被记为式 (16) 的形式。

$$\mathbf{Z}(k_i) = h[k_i, \mathbf{X}(k_i)] + outlier_{n,k_i} + \mathbf{V}(k_i) \quad (16)$$

其中: $outlier_{n,k_i}$ 表示在 n 个观测变量在 k_i 时刻出现的坏值与实际值的偏差量大小。

静差: 属于稳态误差的一种。如图 1 (b) 所示, 由于测控设备本身的问题, 导致观测值与真实值之间存在误差近似为常数的现象, 偏差量可正可负, 可能发生在所有观测数据中, 也可能发生在部分观测数据中。假设在 n 个观测变量在 k_i 至 k_j 时刻存在静差, 则存在静差的观测值可以被记为式 (17) 所示的形式。

$$\mathbf{Z}(k) = h[k, \mathbf{X}(k)] + bias_{n,k_i \sim k_j} + \mathbf{V}(k) \quad (17)$$

其中: $k = k_i, k_i+1, \dots, k_j$, $bias_{n,k_i \sim k_j}$ 表示在 n 个观测变量在 k_i 至 k_j 时刻存在静差的观测值与实际值的偏差量大小。

漂移：如图 1 (c) 所示，与前两种粗大误差不同，观测数据的漂移表现为观测值与真实值之间存在偏差量为非线性函数的异常情况。假设第 n 个观测变量在 k_i 至 k_j 时刻存在漂移，则存在漂移的观测值可以被记为式 (18) 所示的形式。

$$Z(k) = h[k, X(k)] + drift_{n, k_i \sim k_j} + V(k) \quad (18)$$

其中： $k = k_i, k_i + 1, \dots, k_j$, $drift_{n, k_i \sim k_j}$ 是复杂变化的函数，通常情况下为非线性的形式。

2.2 粗大误差的检测

对于动态目标识别中传感器得到观测数据中存在的粗大误差值，需要对其进行准确检测，从而进行相应的补偿。

2.2.1 坏值 (outlier) 的检测

对于坏值的检测：坏值是一组观测数据中存在的孤立异常值，因此需要对每个时刻每个观测数据进行检测，从而判断坏值存在与否。

坏值的检测通常可采用依拉达准则^[7]。假设动态目标传感器观测值数据与扩展卡尔曼滤波方程中预估的观测数据偏差量的绝对值为 $Residual_{n, k}$ ，即残差，可表示为式 (19)。

$$Residual_{n, k} = |Z(k) - \hat{Z}(k)| \quad (19)$$

其中： $Z(k)$ 为传感器的观测数据， $\hat{Z}(k)$ 为扩展卡尔曼滤波中根据系统理想模型得到的观测预估值。由式 (10) 可得观测预估值为：

$$\hat{Z}(k) = H(k)X(k) + y(k) \quad (20)$$

根据贝塞尔法求得标准差 σ 。

$$\sigma = \sqrt{\frac{\sum_{k=1}^T Residual_{n, k}^2}{T-1}} \quad (21)$$

T 为设定的检测区间长度，当 $Residual$ 服从正态分布时，一组观测数据中， $Residual < 3\sigma$ 的占比为 99.73%，这说明观测数据中残差 $Residual < 3\sigma$ 的情况是占大多数的。

若 $Residual > 3\sigma$ ，此时出现该观测数据的可能性为 0.07%，可信度低，为高度异常的坏值，可以确定该观测值为坏值，将坏值标记为 $outlier_Flag = 1$ ，非坏值标记为 $outlier_Flag = 0$ 。当每次检测出一个坏值时，就对坏值进行一次标记和补偿。

需要注意的是，依拉达准则只适用于观测次数较多的情况 (观测次数 $n > 10$)^[8]。

2.2.2 静差 (bias) 的检测

静差与坏值不同，静差的存在使得连续多个观测值与真实值之间的差值近似为常数，且差值可正可负。静差可能发生在所有的观测值中，也可能发生在部分观测值中。因此，准确检测静差时不能只对 k 时刻第 n 个观测值进行检测，而是对 k 时刻前的第 $T-l$ 时刻观测值到第 T 时刻观测值进行检测，其中， l 为设定的检测区间长度，可长可短。先设定个静差检测移动窗口^[9]，长度为 l 。那么对于该静差检测移动窗口，则标准差和残差的平均值分别为：

$$\sigma = \sqrt{\frac{\sum_{k=T-l+1}^T (Residual_{n, k} - \overline{Residual_{n, kl}})^2}{l-1}} \quad (22)$$

$$\overline{Residual_{n, kl}} = \frac{1}{l} \sum_{k=T-l+1}^T Residual_{n, k} \quad (23)$$

$$bias = \overline{Residual_{n, kl}} \quad (24)$$

由于对应于非线性系统的随机误差服从正态分布，因此当存在静差的观测值与原正态分布进行比较时就是存在一个平移量为 $bias$ 的正态分布。 $bias$ 为静差偏移量，是一个常数，可正可负。式 (25) 和式 (26) 分别表示正常观测时和存在静差时的残差情况。

$$Residual(k) \sim N(0, \sigma^2) \quad (25)$$

$$Residual(k) \sim N(\mu, \sigma^2), \mu = bias \quad (26)$$

式中， μ 为一段时间内残差的平均值。

在静差检测移动窗口内，根据求得的标准差和残差，可以对观测值中是否存在静差进行判断。如果移动窗口移动 3 个时间点，3 次移动窗口中残差的平均值可以近似表示为一个常数量，即残差的平均值 $\mu = bias$ ，这里 $\mu = bias$ 表示一个近似的常数，并且移动窗口内的标准差满足依拉达法则，即 $Residual > 3\sigma$ 。移动窗口内标准差的浮动范围小于一定的阈值，即 $|\sigma| < Threshold$ ，则可以标记为 $bias_Flag = 1$ 。 $Threshold$ 为标准差 σ 的阈值范围。 $Threshold$ 的大小是根据 F 分布表中所取，因为观测值的噪声为白噪声，则残差满足 F 分布^[10]。如果 μ 不为一个常数，而是一个变化的函数形式，并且标准差 $|\sigma| \geq Threshold$ ，说明这种粗大误差不为静差，可能为漂移。

2.2.3 漂移 (drift) 的检测

与坏值和静差不同，漂移表现为连续多个观测值与真实值的偏差量很大且难以用具体的函数来表示。

漂移的检测是基于静差检测基础之上的，当移动检测窗口的观测值中已经检测出 $Residual > 3\sigma$ 且残差的平均值 μ 不为一个常数时，如果满足 $|\sigma| \geq Threshold$ ，即标准差大于一定的阈值^[8]，则检测到该时间的观测值为漂移，标记为 $drift_Flag = 1$ ，否则，标记为 $drift_Flag = 0$ ，对于漂移，可以采用局部线性拟合的方式，在局部构建一个线性方程近似漂移量，如 (27) 所示：

$$drift = p_1 k + p_2 \quad (27)$$

其中： $drift$ 表示 k 时刻的观测漂移偏差量， p_1 表示局部线性区线性方程的斜率大小， p_2 表示局部线性区线性方程的截距大小。

2.3 粗大误差的补偿

粗大误差值已经可以通过上述讨论的方法进行检测，下一步就需要对已经检测到的不同类型的粗大误差进行分类补偿。

2.3.1 坏值 (outlier) 的补偿

根据依拉达法则，可以检测出此时的观测值是否存在坏值，并将其标记为 $outlier_Flag = 1$ 。

对于标记为 $outlier_Flag = 1$ 的观测值, 可以通过式 (21) 中的残差 $Residual_{n,ki}$ 来对此时的观测值进行补偿, 即此时的观测值减去残差, 使得最后观测值得以修正。若用 $Z_{rec}(k)$ 表示补偿后的观测值, 则可得到式 (28):

$$Z_{rec}(k) = Z(k) - Residual_{n,k} \quad (28)$$

2.3.2 静差 (bias) 的补偿

通过式 (26) 可以检测到存在静差的观测值, 并将其标记为 $bias_Flag = 1$ 。对于移动窗口内标记为 $bias_Flag = 1$ 的观测值, 对其进行补偿。静差与坏值不同, 静差为连续多个观测值存在的粗大误差, 如果直接采用此时的残差进行补偿, 很有可能会导致 EKF 滤波估计值依然偏离了真实状态值, 无法达到预期目标跟踪效果。为了尽量避免单个残差补偿以及减少多个观测值的偏差, 可以利用移动检测窗口的残差平均值来代替此时的残差进行补偿。因此, 静差的补偿方法是利用存在静差的观测值减去移动检测窗口内的残差平均值来进行观测值的补偿, 移动检测窗口内的残差平均值即式 (23) 中 $\overline{Residual_{n,kl}}$ 的大小, 可以表示为式 (29):

$$Z_{rec}(k) = Z(k) - \overline{Residual_{n,kl}} \quad (29)$$

其中, 观测补偿量 $\overline{Residual_{n,kl}}$ 可以根据移动检测窗口的移动而发生实时变化, 式 (23) 时间长度 l 也是会随着观测值中静差的标记量的多少而发生变化, 时间长度 l 越长, 补偿量就越精确, 补偿效果就越好。

2.3.3 漂移 (drift) 的补偿

通过 $|\mu| > 0, |\sigma| > Threshold$ 可以检测到观测值中的漂移, 并标记为 $drift_Flag = 1$ 。与坏值和静差不同, 漂移的偏移量不为一个常数, 如果采用移动检测窗口中的残差量对漂移的观测值进行补偿, 观测值的偏移量依然跟真实差距很大, 这会导致 EKF 滤波后的状态估计量依然偏离真实状态量, 补偿结果并不理想, 不利于动态目标跟踪。

虽然漂移量不为具体的函数形式, 但在局部位置偏移量仍然可以近似为一个线性拟合的方程。因此, 对于存在漂移的观测值, 可以通过局部线性拟合的方式对观测值进行近似补偿。补偿过程可以表示为式 (30):

$$Z_{rec}(k) = Z(k) - drift \quad (30)$$

式中, $drift$ 为式 (27) 中线性方程近似漂移量。如果此时 p_1 近似为 0, 则可以认为此时的 $drift$ 是 $bias$, 因此, 当两种粗大误差均存在的情况下, 为了更佳地补偿效果, 两种粗大误差均可以采用线性拟合进行补偿。

3 实验仿真

三维非线性系统状态模型:

$$\begin{aligned} X(k) = [r_x(k), r_y(k), r_z(k), v_x(k), \\ v_y(k), v_z(k), a_x(k), a_y(k), a_z(k)]^T \end{aligned} \quad (31)$$

三维系统运动状态方程可以表示为:

$$X(k+1) = \mathbf{F}X(k) + \mathbf{G}U(k) + W(k) \quad (32)$$

其中, \mathbf{F} 为状态转移矩阵, \mathbf{G} 为过程噪声驱动矩阵, 矩

阵如下所示:

$$\mathbf{F} = \begin{bmatrix} I_3 & \Delta t I_3 & \frac{1}{\lambda^2}(e^{-\lambda\Delta t} + \lambda\Delta t - 1)I_3 \\ 0_3 & I_3 & \frac{1}{\lambda}(1 - e^{-\lambda\Delta t})I_3 \\ 0_3 & 0_3 & e^{-\lambda\Delta t}I_3 \end{bmatrix} \quad (33)$$

$$\mathbf{G} = \begin{bmatrix} -(\Delta t^2/2)I_3 \\ -\Delta t I_3 \\ 0_3 \end{bmatrix} \quad (34)$$

在此三维系统中, 导弹对动态目标采用纯方位观测, 观测为俯仰角和水平方向偏向角, 实际观测中雷达具有加性观测噪声, 观测方程为:

$$Z(k) = h[X(k)] + V(k) \quad (35)$$

式中,

$$h[X(k)] = \left[\arctan \frac{r_y(k)}{\sqrt{r_x^2(k) + r_z^2(k)}}, \arctan \frac{-r_x(k)}{r_z(k)} \right]^T \quad (36)$$

在三维寻的制导的初始化中, 采样时间 $\Delta t = 0.01 \text{ s}$, $t = 4.0 \text{ s}$ 。

导弹的初始状态:

$$x(0) = [3500, 1500, 1000, -1100, -150, -50, 10, 10, 10]^T$$

EKF 滤波估计的初始状态:

$$ex(0) = [3000, 1000, 800, -950, -100, -100, 0, 0, 0]^T$$

初始化 EKF 滤波估计的状态协方差矩阵:

$$P_0 = [10^4 \times I_6, 0_{6 \times 3}; 0_{3 \times 6}, 10^2 \times I_3]$$

实验仿真中, 在传感器观测值中加入粗大误差 (坏值、静差和漂移), 对比优化前后 EKF 的跟踪状态情况。得到经粗大误差检测前后的观测值如图 2 所示。

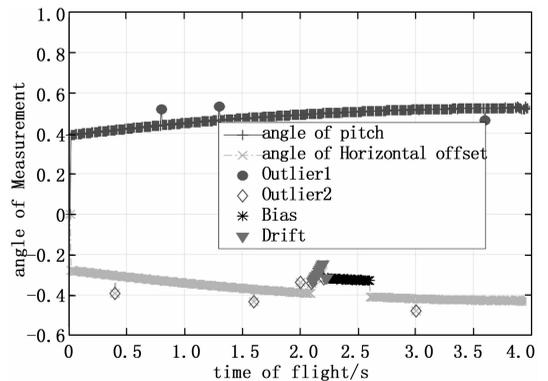


图 2 粗大误差检测结果

图 2 为三维寻的跟踪的俯仰角和水平方向偏向角随时间变化的曲线。图 2 中, 俯仰角的观测值在 0.8 s、1.3 s 和 3.6 s 有坏值点存在, 水平方向偏向角在 0.4 s、1.6 s、2.0 s 和 3.0 s 存在坏值点, 2.2~2.6 s 存在静差, 2.1~2.2 s 存在漂移。改进型 EKF 能将所有的粗大误差精确检测和分类标记出来。精确检测之后, 改进型 EKF 算法可以通过式子 (28)~(30) 对不同的粗大误差进行分类补偿。

对传统 EKF 和改进型 EKF 进行 50 组仿真实验后, 得到每组实验的均方根误差 (RMSE), 经统计后, 所得结果如表 1 所示。

表 1 传统 EKF 与改进型 EKF 滤波后的 50 组仿真实验均方根误差 (RMSE) 统计结果

传统 EKF 的 RMSE			改进 EKF 的 RMSE		
位置	速度	加速度	位置	速度	加速度
均方根误差 (RMSE) 平均值					
40.136 9	27.693 7	0.010 9	6.208 1	3.081 4	0.010 9
均方根误差 (RMSE) 标准差					
0.993 4	0.924 6	0	0.082 1	0.055 0	0

根据表 1 中传统 EKF 和改进 EKF 在 50 次仿真实验下的位置、速度和加速度的均方根误差 (RMSE) 的数据, 可以绘制出如图 3 所示改进前后均方根误差比较图。

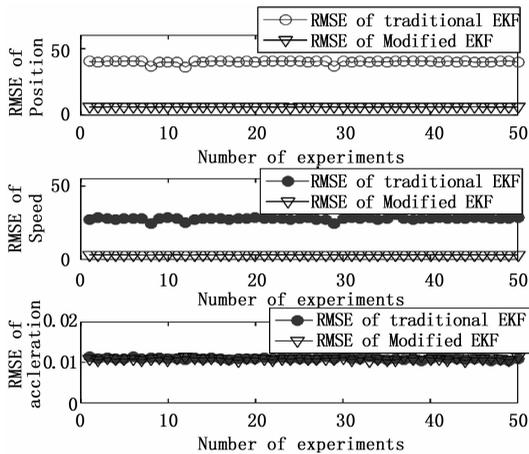


图 3 传统 EKF 与改进型 EKF 滤波后的均方根误差比较图

由表 1 和图 3 可知, 在 50 次的仿真实验中, 改进型 EKF 算法的位置和速度的均方根误差明显比优化前的均方根误差要小, 其中, 改进型 EKF 滤波后位置均方根误差的平均值比传统 EKF 小 33.9287, 标准差比传统 EKF 小 0.9113. 改进型 EKF 滤波后速度均方根误差的平均值比传统 EKF 小 24.6123, 标准差比传统 EKF 小 0.8696. 这说明改进型 EKF 算法滤波受到粗大误差干扰的影响更小, 性能更稳定, 跟踪的精确度更高. 经过传统 EKF 和改进型 EKF 算法后, 实验仿真得到图 4 所示三维寻的跟踪状态图。

根据图 4 所示寻的制导跟踪状态图可知, 在粗大误差干扰情况下, 传统 EKF 的状态估计值已经严重偏离实际的状态值. 相比传统 EKF, 改进型 EKF 滤波后的寻的制导跟踪偏差明显较小, 没有出现偏离实际状态值, 这说明三维动态目标的跟踪精度较高。

5 结束语

本文针对动态系统目标跟踪观测过程中存在的坏值、静差和漂移 3 种粗大误差, 提出了一种基于粗大误差检测和补偿的改进型 EKF 动态目标跟踪算法. 该方法能实时检测粗大误差并补偿观测量, 能有效地减小粗大误差对滤波

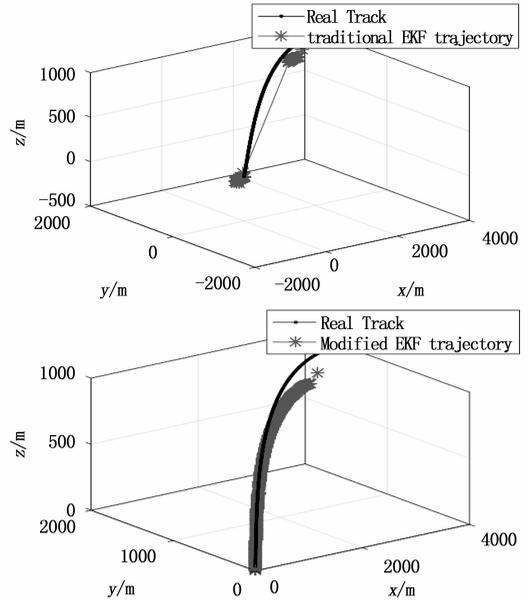


图 4 三维寻的跟踪状态图

结果的影响, 从而提高跟踪的精确度. 仿真结果表明, 相比于传统 EKF, 改进型 EKF 算法滤波抗干扰能力较强, 滤波性能较为稳定, 实现了对动态系统目标的准确跟踪。

参考文献:

- [1] Kalman R E. A New Approach to Linear Filtering and Prediction Problems [J]. Journal of Basic Engineering Transactions, 1960, 82: 35-45.
- [2] Kalman R E, Bucy R S. New results in linear filtering and prediction theory [J]. Journal of Basic Engineering Transactions, 1961, 83 (1): 95-108.
- [3] Senne K. Review of stochastic processes and filtering theory—Andrew H. Jazwinski [J]. IEEE Transactions on Automatic Control, 1972, 17 (5): 752-753.
- [4] 赵佳, 吕弘, 周智恺, 等. 基于扩展卡尔曼滤波的无人飞行器姿态解算 [J]. 电子技术与软件工程, 2018 (24): 67-68.
- [5] 陈清华, 卢宇, 何志杰. 基于改进 EKF 算法的锂电池 SOC 估算方法 [J]. 福建师范大学学报 (自然科学版), 2018, 34 (6): 39-44, 51.
- [6] Zhu Z, Meng Z, Zhang Z, et al. Robust particle filter for state estimation using measurements with different types of gross errors [J]. ISA transactions, 2017, 69: 281-295.
- [7] 张敏, 袁辉. 拉依达 (PauTa) 准则与异常值剔除 [J]. 郑州工业大学学报, 1997 (1): 84-88.
- [8] 熊艳艳, 吴先球. 粗大误差 4 种判别准则的比较和应用 [J]. 大学物理实验, 2010, 23 (1): 66-68.
- [9] Tao S, Li B, Li N, et al. A Novel Approach for Moving Window Size Selection utilizing recursive PCA [A]. 第 37 届中国控制会议论文集 [C]. 2018: 710-715.
- [10] 刘晓鹏, 刘坤会. F 分布密度函数之性质 [J]. 应用概率统计, 2016, 21 (3): 304-314.