

控制与决策

Control and Decision

基于递归工具变量卡尔曼滤波算法的纯方位水下目标跟踪

郭戈, 王兴凯, 徐慧朴

引用本文:

郭戈, 王兴凯, 徐慧朴. 基于递归工具变量卡尔曼滤波算法的纯方位水下目标跟踪[J]. *控制与决策*, 2020, 35(1): 107–114.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.0643>

您可能感兴趣的其他文章

Articles you may be interested in

自适应线性预测卡尔曼滤波压缩感知算法

Adaptive linear predictive Kalman filter compressed sensing algorithm

控制与决策. 2020, 35(1): 83–90 <https://doi.org/10.13195/j.kzyjc.2018.0679>

基于不完全测距的移动传感器网络定位算法

Range-based localization algorithm for mobile sensor network with incomplete measurement

控制与决策. 2018, 33(4): 607–613 <https://doi.org/10.13195/j.kzyjc.2017.0298>

采用卡方检验的模糊自适应无迹卡尔曼滤波组合导航算法

Fuzzy adaptive unscented Kalman filter integrated navigation algorithm using Chi-square test

控制与决策. 2018, 33(1): 81–87 <https://doi.org/10.13195/j.kzyjc.2016.1444>

基于组合导航系统的非线性高斯滤波算法

Gaussian non-linear filter algorithm based on integrated navigation system

控制与决策. 2016, 31(9): 1645–1653 <https://doi.org/10.13195/j.kzyjc.2015.1038>

自适应目标新生强度的SMC-PHD/CPHD滤波

Adaptive target birth intensity for SMC-PHD/CPHD filtering

控制与决策. 2016, 31(8): 1461–1467 <https://doi.org/10.13195/j.kzyjc.2015.0901>

分块多特征目标描述子的移动机器人目标跟踪

Person tracking for robot using patches-based-multi-cues representation

控制与决策. 2016(2): 337–342 <https://doi.org/10.13195/j.kzyjc.2014.1822>

轨迹跟踪级联机器人编队控制方法

Trajectory tracking cascade robot formation control

控制与决策. 2016(2): 317–323 <https://doi.org/10.13195/j.kzyjc.2014.1676>

基于观测数据删减及量化新息的无线传感器网络目标跟踪

Target tracking in wireless sensor networks based on censoring and quantized innovations

控制与决策. 2015, 30(5): 951–954 <https://doi.org/10.13195/j.kzyjc.2014.0332>

基于递归工具变量卡尔曼滤波算法的纯方位水下目标跟踪

郭 戈[†], 王兴凯, 徐慧朴

(大连海事大学 船舶电气工程学院, 辽宁 大连 116026)

摘 要: 基于纯方位信息的水下目标跟踪中常用的伪线性卡尔曼滤波算法偏差较大、跟踪精度差, 结合偏差补偿算法提出一种用于纯方位水下目标跟踪的递归工具变量卡尔曼滤波算法, 并将过程噪声协方差的不确定性考虑在内. 针对伪线性卡尔曼滤波算法的偏差问题, 采用递归工具变量算法的工具变量矩阵来消除量测矩阵与伪线性噪声间的关联性, 从而消除偏差. 仿真结果表明, 所提出的递归工具变量卡尔曼滤波算法在水下方位角噪声较大时也能保持稳定性和跟踪精度.

关键词: 递归工具变量; 伪线性估计; 卡尔曼滤波; 偏差补偿; 纯方位; 水下目标跟踪

中图分类号: TP27

文献标志码: A

Recursive instrumental variable Kalman filtering algorithm for underwater bearing-only target tracking

GUO Ge[†], WANG Xing-kai, XU Hui-pu

(Institute of Ship Electrical and Engineering, Dalian Maritime University, Dalian 116026, China)

Abstract: The pseudolinear Kalman filter suffers from more bias and poor tracking accuracy in underwater target tracking based on bearings-only information, therefore, a recursive instrumental variable Kalman filter algorithm combined with the bias compensation algorithm is proposed for bearings-only underwater target tracking, and uncertain process noise covariance is considered. For the bias problem of the pseudolinear Kalman filter, the instrumental variable matrix in the recursive instrumental variable algorithm is adopted to remove the correlation between measurement vectors and pseudolinear noise, as to remove the bias. Simulation results show that the stability and tracking accuracy of the proposed algorithm can be kept in the environment with large underwater noise.

Keywords: recursive instrumental variable; pseudolinear estimate; Kalman filter; bias compensation; bearings-only; underwater target tracking

0 引 言

水下目标跟踪是近年来非常活跃的研究领域之一, 其应用非常广泛, 涉及鱼群定位^[1]、分类跟踪^[2]、打捞与救助^[3]、海底管道探测^[4]、海底目标定位与识别^[5]等方面, 也可在军事上用于水雷、潜艇等水下目标探测和跟踪^[6-7]. 水下目标跟踪方法众多, 如基于到达时间的水下目标跟踪、基于信号强度的水下目标跟踪、基于纯方位信息的水下目标跟踪等. 但由于水下环境的特殊性, 如声学介质约束、异质性、杂波干扰等, 使水下目标信号获取困难, 因此多数水下目标跟踪方法无法实现精准跟踪. 而纯方位水下目标跟踪一直是声呐、雷达及水下传感器网络等领域的热门研究问题之一, 旨在从方位传感器数据(被噪声污染)中估计水下运动目标的位置、速度以及加速度,

实现对水下目标的准确跟踪^[8-11].

纯方位水下目标跟踪的最大问题是方位角量测值与目标状态间的非线性关系. 目前处理方法大致可分为两类^[12]: 一类是基于扩展卡尔曼滤波 (extended Kalman filter, EKF) 的递归方法, 另一类是基于伪线性卡尔曼滤波 (pseudolinear Kalman filter, PLKF) 的批处理方法. 早期研究大多运用扩展卡尔曼滤波算法, 通过一阶泰勒近似将非线性量测方程转化为线性量测方程^[13]. EKF 算法在笛卡尔坐标系中存在发散问题, 在极坐标系中得到改善, 但解决 EKF 算法固有的收敛问题必须使初始化更加精确. 水下环境复杂多变, 初始化难度大, EKF 算法的跟踪缺陷较大. 无迹卡尔曼滤波^[14]及粒子滤波^[15]都曾用于纯方位目标跟踪问题, 但二者计算复杂度太高,

收稿日期: 2018-05-14; 修回日期: 2018-07-12.

基金项目: 国家自然科学基金项目(61273107, 61573077).

责任编辑: 关新平.

[†]通讯作者. E-mail: geguo@yeah.com.

在实时纯方位目标跟踪问题中存在限制. 针对上述问题, 平方根无迹卡尔曼滤波算法^[16]利用协方差平方根代替协方差参与递归运算, 解决无迹卡尔曼滤波算法中的发散问题, 但无法获得最佳的跟踪精度和可靠性; 强跟踪平方根容积卡尔曼滤波算法^[17]也用于纯方位目标跟踪, 利用平方根容积卡尔曼滤波器完成预测更新, 并对每个容积点采用强跟踪滤波器进行更新, 抑制方位角噪声对系统状态估计的影响, 提高数值稳定性, 相对于EKF和UKF算法跟踪性能得到了提高. 批处理方法中的极大似然估计法^[18]也用于纯方位目标跟踪, 且在白高斯方位噪声下可简化为非线性的最小二乘估计法. 极大似然估计法能在跟踪过程中达到渐近无偏和渐近有效, 但没有解析解且计算复杂, 并同样存在收敛问题. 伪线性卡尔曼滤波算法可用伪线性估计方程替换非线性方位量测方程, 相比于其他非线性卡尔曼滤波算法及粒子滤波算法降低了计算复杂度, 同时也降低了对初始化的精准度要求^[19-20]. 但在纯方位水下目标跟踪过程中, 伪线性卡尔曼滤波算法会出现严重的偏差问题而影响跟踪性能. 针对此问题, 文献[21]通过对纯方位目标运动进行偏差分析, 将偏差补偿算法应用到伪线性估计方法中, 提出偏差补偿伪线性卡尔曼滤波算法 (bias compensation pseudolinear Kalman filter, BC-PLKF), 减小量测矩阵和伪线性噪声间的关联性, 从而减小传统卡尔曼滤波算法的偏差问题, 使跟踪性能明显提高^[22-23]. BC-PLKF算法假设所处环境方位角噪声较小, 但由于水下环境干扰多, 在水下方位角噪声较大时, 此算法补偿效果下降, 无法持续做到精准跟踪. 以上算法均假设传感器运动速度慢可忽略过程噪声简化计算, 但在水下环境中, 由于传感器通信、漂移等造成的过程噪声无法忽略, 需将其考虑在内. 综上所述, 目前纯方位水下目标跟踪的主要问题为跟踪过程、跟踪精度和稳定性问题.

针对上述问题, 本文提出一种新的用于水下目标跟踪的递归工具变量卡尔曼滤波算法 (recursion instrumental variable Kalman filtering, RIVKF), 用以解决由量测向量和伪线性噪声关联性造成的偏差问题, 同时结合水下环境复杂性, 将过程误差的不确定性考虑到卡尔曼状态估计中. RIVKF算法避免直接产生IV向量, 而是通过BC-PLKF算法构造IV向量以产生无偏估计. 同时, 提出一种判定逻辑, 通过BC-PLKF与RIVKF算法之间的切换, 在方位角噪声较大时也能保持量测向量和IV向量之间的强相关性, 实现对目标的准确跟踪. 最后通过对EKF算法、PLKF算法、BC-PLKF算法以及RIVKF的仿真效果进行对比, 验证RIVKF算法跟踪精确性更佳.

1 问题描述

纯方位水下目标跟踪问题的几何描述如图1所示, 假设目标匀速运动且忽略水深的影




图1 水下纯方位目标跟踪模型

图1中, $p_k = [p_{x,k}, p_{y,k}]^T$ 和 $v_k = [v_{x,k}, v_{y,k}]^T$ 分别为 k 时刻水下目标位置和速度, $k \in \{0, 1, 2, \dots\}$; $r_k = [r_{x,k}, r_{y,k}]^T$ 为传感器 k 时刻的位置, 将 k 时刻的目标运动学状态向量记为 $x_k = [p_k^T, v_k^T]^T$, 则目标运动学模型为

$$x_k = Fx_{k-1} + \omega_{k-1}, \quad k \geq 0. \quad (1)$$

其中: F 为状态转移矩阵; ω_k 为系统过程噪声, 记为 $\omega_k \sim N(0, Q_0)$; 矩阵 F 和 Q_0 表示形式如下所示^[24]:

$$F = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix},$$

$$Q_0 = \begin{bmatrix} q_x \frac{T^3}{3} & 0 & q_x \frac{T^2}{2} & 0 \\ 0 & q_y \frac{T^3}{3} & 0 & q_y \frac{T^2}{2} \\ q_x \frac{T^2}{2} & 0 & q_x T & 0 \\ 0 & q_y \frac{T^2}{2} & 0 & q_y T \end{bmatrix},$$

T 为采样间隔, q_x 和 q_y 分别为过程噪声的功率谱密度在 x 轴和 y 轴上的分量.

时刻 k 的方位角量测值如下:

$$\tilde{\theta}_k = \theta_k + n_k, \quad (2)$$

$$\theta_k = \tan^{-1} \frac{p_{y,k} - r_{y,k}}{p_{x,k} - r_{x,k}}. \quad (3)$$

其中: $n_k \sim N(0, \sigma_k^2)$ 为独立高斯噪声 (由于水下环境的复杂性, 方位角噪声协方差是时变的, 但假设为先验量); 系统过程噪声 ω_k 与方位角量测噪声 n_k 之间相互独立.

由上述定义可得水下纯方位目标跟踪的状态空间模型

$$\begin{aligned} x_k &= Fx_{k-1} + \omega_{k-1}, \\ \tilde{\theta}_k &= h(x_k) + n_k. \end{aligned} \quad (4)$$

其中: $h(x) = \tan^{-1} \frac{p_{y,k} - r_{y,k}}{p_{x,k} - r_{x,k}}$ 是关于状态向量 x_k 的非线性方程, 因此式(4)为非线性状态空间模型.

水下目标跟踪就是通过 $0-k$ 时刻的方位角量测值来估计 k 时刻的目标状态 x_k . 而在线性状态空间方程中, 卡尔曼滤波器可通过条件均值和相关误差协方差估计最优目标状态, 因此需对式(4)中 \tilde{Q}_k 进行线性化处理.

2 伪线性卡尔曼滤波跟踪分析

将卡尔曼滤波器运用到水下纯方位目标跟踪的状态空间方程中, 必须将量测方程线性化. 令 $\Delta y_k = p_{y,k} - r_{y,k}$, $\Delta x_k = p_{x,k} - r_{x,k}$, 同时将式(2)代入(3)的方位角量测方程并作如下变换:

$$a \cos n_k + b \sin n_k = 0. \quad (5)$$

其中: $a = \Delta y_k \cos \tilde{\theta}_k - \Delta x_k \sin \tilde{\theta}_k$, $b = \Delta y_k \sin \tilde{\theta}_k + \Delta x_k \cos \tilde{\theta}_k$.

由水下环境特性可知, $n_k \ll 1$, 则 $\sin n_k \approx n_k$, $\cos n_k \approx 1$, 同时由图1可知, $b = \|d_k\|$, 代入式(5)得

$$\Delta y_k \cos \tilde{\theta}_k - \Delta x_k \sin \tilde{\theta}_k + \|d_k\| \sin n_k = 0. \quad (6)$$

线性化后, 对式(6)进一步简化得到

$$u_k^T r_k = u_k^T M x_k + \eta_k. \quad (7)$$

其中

$$u_k = \begin{bmatrix} \sin \tilde{\theta}_k \\ -\cos \tilde{\theta}_k \end{bmatrix}, \quad M = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix},$$

$$\eta_k = -\|d_k\| \sin n_k.$$

令 $z_k = u_k^T r_k$, $H_k = u_k^T M$, 代入式(7)中得到伪线性量测方程

$$z_k = H_k x_k + \eta_k, \quad (8)$$

其中 η_k 为伪线性噪声, $\eta_k \sim N(0, R_k)$.

通过以上分析, 引入伪量测和伪量测误差, 使量测矩阵 H_k 为方位角 $\tilde{\theta}_k$ 的函数, 因此量测方程被重新排列成线性形式. 线性化后, 用卡尔曼滤波算法对其进行处理, 利用最优卡尔曼滤波估计准则, 考虑估计误差的方差最小, 得到如下伪线性卡尔曼滤波算法:

1) 状态预测方程

$$\hat{x}_{k|k-1} = F\hat{x}_{k-1|k-1}; \quad (9)$$

2) 状态预测协方差矩阵

$$P_{k|k-1} = FP_{k-1|k-1}F^T + Q_0; \quad (10)$$

3) 卡尔曼增益矩阵

$$K_k = P_{k|k-1}H_k^T(R_k + H_kP_{k|k-1}H_k^T)^{-1}; \quad (11)$$

4) 状态估计

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - H_k\hat{x}_{k|k-1}); \quad (12)$$

5) 状态协方差矩阵估计

$$P_{k|k} = (I - K_kH_k)P_{k|k-1}. \quad (13)$$

通过对上述伪线性卡尔曼滤波算法的详细分析可得如下公式:

$$\begin{aligned} \hat{x}_{k|k} - x_k &= \\ & (P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k)^{-1} P_{k|k-1}^{-1} \times \\ & (F(\hat{x}_{k-1|k-1} - x_k - 1) - \omega_{k-1}) + \\ & (P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k)^{-1} H_k^T R_k^{-1} \eta_k. \end{aligned} \quad (14)$$

令

$$\begin{aligned} A_k &= (P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k)^{-1} P_{k|k-1}^{-1} \times \\ & F(\hat{x}_{k-1|k-1} - x_k - 1), \end{aligned} \quad (15)$$

$$B_k = -(P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k)^{-1} P_{k|k-1}^{-1} \omega_{k-1}, \quad (16)$$

$$C_k = (P_{k|k-1}^{-1} + H_k^T R_k^{-1} H_k)^{-1} H_k^T R_k^{-1} \eta_k, \quad (17)$$

则式(14)可变为

$$\hat{x}_{k|k} - x_k = A_k + B_k + C_k. \quad (18)$$

综上, 伪线性卡尔曼滤波估计偏差为

$$\delta_k = E\{\hat{x}_{k|k} - x_k\} = E\{A_k\} + E\{B_k\} + E\{C_k\}. \quad (19)$$

由式(15)~(17)可知, 整个水下目标跟踪过程的偏差主要由两部分构成: 1) 由量测向量 H_k 和系统噪声 ω_{k-1} 相关性造成的(见式(16)), 文献[21]假设系统过程噪声很小, H_k 和 ω_{k-1} 的相关性很小, 可将二者近似为不相关, 因此式(19)中的 $E\{B_k\} \approx 0$; 2) 由量测向量 H_k 和伪线性噪声 η_k 的相关性造成的, 二者之间的相关性不可忽略, 是伪线性卡尔曼滤波算法状态估计偏差出现的根本原因.

若想使水下目标跟踪更加精确高效, 则必须对偏差进行处理, 即减弱甚至消除 H_k 与 η_k 之间的关联性. 在伪线性卡尔曼滤波跟踪中, 消除偏差最常用的方法是通过偏差补偿算法从估计量 $\hat{x}_{k|k}$ 中减去式(17). 在每一时刻运行偏差补偿算法, 与卡尔曼滤波的递归性相结合, 不断减小误差. 但此方法不能做到真正的无偏估计, 且只在方位角量测噪声较小的水下环境中可实现, 因为在小噪声环境中, 方位角量测可得到较为精确的偏差估计, 而在方位角量测噪声较大的环境中去偏效果严重下降.

3 递归工具变量卡尔曼滤波跟踪

3.1 基本RIVKF算法

针对BC-PLKF算法中无法彻底消除偏差的问题, 本文将递归工具变量算法^[25]与偏差补偿伪线性卡尔曼滤波算法相结合, 通过改进卡尔曼增益因数及状态估计协方差的计算方式, 从估计量中消除式(17)

中 H_k 和 η_k 的关联,以达到无偏处理.

此处的递归工具变量算法是将递归最小二乘算法增益因数矩阵中的量测向量由 \mathbf{IV} 向量来代替^[26], 其具体形式如下:

$$K_k^{\text{IV}} = P_{k|k-1} G_k^{\text{T}} (R_k + H_k P_{k|k-1} G_k^{\text{T}})^{-1}, \quad (20)$$

$$\hat{x}_{k|k}^{\text{IV}} = \hat{x}_{k|k-1} + K_k^{\text{IV}} (z_k - H_k \hat{x}_{k|k-1}), \quad (21)$$

$$P_{k|k}^{\text{IV}} = (I - K_k^{\text{IV}} H_k) P_{k|k-1}. \quad (22)$$

G_k 的选取准则: 1) 与伪线性噪声 η_k 相互独立, 即 $E\{G_k^{\text{T}} \eta_k\} = 0$; 2) 与 H_k 有强相关性, 即 G_k 的构造是在 H_k 的基础上, 将偏差补偿算法估计所得的方位角引入 H_k 中. 通过 G_k 的引入, 式(17)中伪线性估计偏差可以表示成如下形式:

$$E\{C_k\} \approx E\{(P_{k|k-1}^{-1} + G_k^{\text{T}} R_k^{-1} H_k)^{-1} R_k^{-1}\} E\{G_k^{\text{T}} \eta_k\} = 0. \quad (23)$$

由于 G_k 和 η_k 的相互独立性及所用算法的递归性, 可做到渐近无偏. 但真实方位角 θ_k 未知, 故不可获得最优 \mathbf{IV} 向量, 即不可获得最优 G_k , 因此用偏差补偿伪线性估计得到的方位角 $\hat{\theta}_{k|k}^{\text{BC}}$ 来代替, 以得到次最优 \mathbf{IV} 向量

$$G_k = [\sin \hat{\theta}_{k|k}^{\text{BC}}, -\cos \hat{\theta}_{k|k}^{\text{BC}}] M. \quad (24)$$

其中: $\hat{\theta}_{k|k}^{\text{BC}} = \tan^{-1} \frac{\hat{p}_{y,k|k}^{\text{BC}} - r_{y,k}}{\hat{p}_{x,k|k}^{\text{BC}} - r_{x,k}}$, $\hat{p}_{k|k}^{\text{BC}} = M \hat{x}_{k|k}^{\text{BC}}$.

将递归 \mathbf{IV} 算法与偏差补偿卡尔曼滤波算法相结合得到递归工具变量卡尔曼滤波算法, 其具体形式如下:

1) 状态预测方程

$$\hat{x}_{k|k-1} = F \hat{x}_{k-1|k-1}^{\text{IV}}; \quad (25)$$

2) 状态预测协方差

$$P_{k|k-1} = F P_{k-1|k-1}^{\text{IV}} F^{\text{T}} + Q_0; \quad (26)$$

3) 卡尔曼增益矩阵

$$K_k^{\text{IV}} = P_{k|k-1} G_k^{\text{T}} (R_k + H_k P_{k|k-1} G_k^{\text{T}})^{-1}; \quad (27)$$

4) 状态估计

$$\hat{x}_{k|k}^{\text{IV}} = \hat{x}_{k|k-1} + K_k^{\text{IV}} (z_k - H_k \hat{x}_{k|k-1}); \quad (28)$$

5) 状态协方差估计

$$P_{k|k}^{\text{IV}} = (I - K_k^{\text{IV}} H_k) P_{k|k-1}; \quad (29)$$

6) 误差补偿

$$\hat{x}_{k|k}^{\text{BC}} = \hat{x}_{k|k} + P_{k|k} R_k^{-1} \mu_k^2 M^{\text{T}} (\hat{x}_{k|k} - r_k). \quad (30)$$

此算法需要注意: 在方位角噪声较大的环境中, 若量测方位角 $\tilde{\theta}_k$ 与估计方位角 $\hat{\theta}_{k|k}^{\text{BC}}$ 之间相差较大, 则会减弱 G_k 与 H_k 之间的强相关性. 为了避免这种情况, 进行如下处理:

若 $|\tilde{\theta}_k - \hat{\theta}_{k|k}^{\text{BC}}| < \epsilon_k$, 则执行 RIVKF 算法; 否则, 先

执行误差补偿算法减小量测方位角与估计方位角之间的差距, 达到所选择的 ϵ 阈值后, 再用 RIVKF 算法进行处理.

3.2 不确定过程协方差 RIVKF 算法

上述分析是在传感器系统误差忽略的情况下展开的, 但实际中虽然传感器运动较慢, 但硬件环境多变性以及传感器漂移等造成了传感器信息的不确定性, 使过程误差无法忽略且具有不确定性. 接下来将过程误差的不确定性考虑到 RIVKF 算法中, 令

$$Q = Q_0 + \lambda \Phi \Phi^{\text{T}}. \quad (31)$$

引入过程误差后, 式(29)的状态估计协方差 $P_{k|k}^{\text{IV}}$ 不是实际估计误差协方差, 此处将实际估计误差协方差表示为 \bar{P}_k , 接下来将对其进行推导.

将 RIV 卡尔曼滤波状态估计方程扩展为如下形式:

$$\hat{x}_{k|k}^{\text{IV}} = F \hat{x}_{k|k-1} + K_k^{\text{IV}} (z_k - H_k F \hat{x}_{k|k-1}). \quad (32)$$

将式(1)和(8)代入(32), 并令 $e_{k-1} = x_{k-1} - \hat{x}_{k|k-1}$, 得到如下形式:

$$\hat{x}_{k|k}^{\text{IV}} = F \hat{x}_{k|k-1} + K_k^{\text{IV}} (H_k F e_{k-1} + H_k \omega_{k-1} + \eta_k). \quad (33)$$

将式(1)与(33)进行变换得到误差

$$e_k = F e_{k-1} + \omega_{k-1} - K_k^{\text{IV}} (H_k F e_{k-1} + H_k \omega_{k-1} + \eta_k). \quad (34)$$

$E\{\omega_{k-1} \omega_{k-1}^{\text{T}}\} = Q_0 + \lambda \Phi \Phi^{\text{T}}$ 和 $E\{\eta_k \eta_k^{\text{T}}\} = R_k$ 分别为实际系统协方差和量测协方差, 则实际估计误差协方差 $\bar{P}_k = E\{e_k e_k^{\text{T}}\}$, 可表示成如下形式:

$$\begin{aligned} \bar{P}_k = & F \bar{P}_{k-1} F^{\text{T}} + Q_0 + \lambda \Phi \Phi^{\text{T}} + \\ & K_k^{\text{IV}} (H_k F \bar{P}_{k-1} F^{\text{T}} H_k^{\text{T}} + \\ & H_k Q_0 H_k^{\text{T}} + \lambda H_k \Phi \Phi^{\text{T}} H_k^{\text{T}} + R_k) (K_k^{\text{IV}})^{\text{T}} - \\ & F \bar{P}_{k-1} F^{\text{T}} H_k^{\text{T}} (K_k^{\text{IV}})^{\text{T}} - K_k^{\text{IV}} H_k F \bar{P}_{k-1} F^{\text{T}} - \\ & (Q_0 + \lambda \Phi \Phi^{\text{T}}) H_k^{\text{T}} (K_k^{\text{IV}})^{\text{T}} - \\ & K_k^{\text{IV}} H_k (Q_0 + \lambda \Phi \Phi^{\text{T}}). \end{aligned} \quad (35)$$

将 \bar{P}_k 代替 RIVKF 算法中的状态协方差估计方程, 将系统噪声的不确定性考虑在内, 得到如下具有不确定过程噪声协方差的 RIVKF 算法:

1) 状态预测方程

$$\hat{x}_{k|k-1} = F \hat{x}_{k-1|k-1}^{\text{IV}}; \quad (36)$$

2) 状态预测协方差

$$P_{k|k-1} = F P_{k-1|k-1}^{\text{IV}} F^{\text{T}} + Q; \quad (37)$$

3) 卡尔曼增益矩阵

$$K_k^{\text{IV}} = P_{k|k-1} G_k^{\text{T}} (R_k + H_k P_{k|k-1} G_k^{\text{T}})^{-1}; \quad (38)$$

4) 状态估计

$$\hat{x}_{k|k}^{IV} = \hat{x}_{k|k-1} + K_k^{IV}(z_k - H_k \hat{x}_{k|k-1}); \quad (39)$$

5) 状态协方差估计

$$\begin{aligned} \bar{P}_k = & F\bar{P}_{k-1}F^T + Q_0 + \lambda\Phi\Phi^T + \\ & K_k^{IV}(H_k F\bar{P}_{k-1}F^T H_k^T + \\ & H_k Q_0 H_k^T + \lambda H_k \Phi \Phi^T H_k^T + R_k)(K_k^{IV})^T - \\ & F\bar{P}_{k-1}F^T H_k^T (K_k^{IV})^T - K_k^{IV} H_k F\bar{P}_{k-1}F^T - \\ & (Q_0 + \lambda\Phi\Phi^T)H_k^T (K_k^{IV})^T - \\ & K_k^{IV} H_k (Q_0 + \lambda\Phi\Phi^T); \end{aligned} \quad (40)$$

6) 误差补偿

$$\hat{x}_{k|k}^{BC} = \hat{x}_{k|k} + P_{k|k} R_k^{-1} \mu_k^2 M^T (\hat{x}_{k|k} - r_k). \quad (41)$$

3.3 性能指标分析

针对上述 $\tilde{\theta}_k$ 与 $\hat{\theta}_{k|k}^{BC}$ 之间偏差, 提出两种计算方法: 一是通过方位角噪声方差信息计算 $\tilde{\theta}_k$ 与 $\hat{\theta}_{k|k}^{BC}$ 之间偏差, 同时阈值 ϵ_k 与方位角噪声标准差 σ_k 成比例, 即 $\epsilon_k = g\sigma_k$, g 为比例因子; 二是通过卡尔曼新息协方差 $S_k = R_k + H_k P_{k|k-1} H_k^T$ 对 $\tilde{\theta}_k$ 与 $\hat{\theta}_{k|k}^{BC}$ 之间的偏差进行检测, S_k 是新息序列 $v_k = z_k - \hat{z}_{k|k-1} = z_k - H_k \hat{x}_{k|k-1}$ 的方差. 此处 S_k 无法直接用于判断 $\tilde{\theta}_k$ 与 $\hat{\theta}_{k|k}^{BC}$ 间偏差的大小, 但通过方位角噪声 n_k 与伪线性噪声 η_k 之间的关系, 即 $\eta_k = -\|d_k\| \sin n_k \approx -\|d_k\| \times n_k$, 可将阈值 ϵ_k 表示成 $\epsilon_k = gS_k^{1/2} / \|\hat{d}_{k|k-1}\|$, 其中 g 为比例因数. 需注意: 不是阈值越大或越小, 所得效果越好, 阈值 ϵ_k 越小, G_k 与 H_k 之间的相关性越强, 但过小的阈值会造成偏差的上升, 因此阈值的选择必须与所选性能指标相结合, 既要得到更佳的均方根误差效果 (即阈值较小), 又要使偏差效果更小 (即阈值较大). 性能指标为偏差标准 (bias norm, BNorm), 均方根误差 (root mean squared error, RMSE), 平均欧几里德误差 (average Euclidean error, AEE) 和后验克拉美罗下界 (posterior Cramer-Rao lower bound, PCRLB)^[27], 形式如下:

$$\text{BNorm}_k^{\text{pos}} = \left\| \frac{1}{M} \sum_{i=1}^M (\hat{p}_{k|k}^i - p_k^i) \right\|, \quad (42)$$

$$\text{RMSE}_k^{\text{pos}} = \left(\frac{1}{M} \sum_{i=1}^M \|\hat{p}_{k|k}^i - p_k^i\|^2 \right)^{1/2}, \quad (43)$$

$$\text{AEE}_k^{\text{pos}} = \frac{1}{M} \sum_{i=1}^M \|\hat{p}_{k|k}^i - p_k^i\|, \quad (44)$$

$$\text{PCRLB}_k^{\text{pos}} = \sqrt{\text{PCRLB}_{x_k}(1, 1) + \text{PCRLB}_{x_k}(2, 2)}. \quad (45)$$

三者均通过对观测值与真值间偏差的估计来反映目标跟踪精度, 在水下方位角噪声较大时, 其位置估计值又与所选阈值有关. 若所选阈值过大, 则会导致量测方位角与估计方位角之间相差较大, 可使跟踪误差所容许的范围更大, 即有更好的误差效果, 但无法保持 G_k 与 H_k 之间的强相关性, 进而导致位置估计误差增大. 由于式 (43) 中有平方项, 会进一步凸显误差的影响, 无法逼近克拉美罗下界, 即无法达到最佳的跟踪效果. 相反, 若所选阈值过小, 则量测方位角与估计方位角之间相差较小, 跟踪误差所容许的范围更小, 误差效果相对会变差, 但更能保持 G_k 与 H_k 间的强相关性. 同时, 可以使式 (43) 更好地逼近克拉美罗下界, 达到更精准的跟踪效果. 阈值大小由比例因素 g 决定, 本文所选 g 值为 $g \in [2, 4]$.

此外, 时均 BNorm、RMSE、AEE 和 PCRLB 分别定义如下:

$$\text{BNorm}_{\text{avg}}^{\text{pos}} = \frac{1}{U} \sum_{k=L}^N \left(\left\| \frac{1}{M} \sum_{i=1}^M (\hat{p}_{k|k}^i - p_k^i) \right\| \right); \quad (46)$$

$$\text{RMSE}_{\text{avg}}^{\text{pos}} = \left(\frac{1}{MU} \sum_{i=1}^M \sum_{k=L}^N \|\hat{p}_{k|k}^i - p_k^i\|^2 \right)^{1/2}; \quad (47)$$

$$\text{AEE}_{\text{avg}}^{\text{pos}} = \frac{1}{MU} \sum_{i=1}^M \sum_{k=L}^N \|\hat{p}_{k|k}^i - p_k^i\|; \quad (48)$$

$$\begin{aligned} \text{PCRLB}_{\text{avg}}^{\text{pos}} = & \sqrt{\text{PCRLB}_{\text{avg}}(1, 1) + \text{PCRLB}_{\text{avg}}(2, 2)}, \\ \text{PCRLB}_{\text{avg}} = & \frac{1}{U} \sum_{k=L}^N \text{PCRLB}_{x_k}. \end{aligned} \quad (49)$$

其中: $U = N - L + 1$, N 为跟踪过程的总时刻数, L 为补偿参数.

3.4 RIVKF算法计算步骤

通过以上分析, 将 RIVKF 算法表示为以下步骤:

1) 根据目标初始阶段的数据, 对目标状态初始化, 设定其初始状态的估计值 $\hat{x}_{0|0}$, 误差协方差矩阵 $P_{0|0}$ 以及方位角噪声方差 σ_n .

2) 计算状态转移矩阵 F , 量测向量 H , 系统过程噪声 ω_k , 方位角量测值 $\tilde{\theta}_k$ 以及伪线性噪声 η_k .

3) 通过偏差补偿算法计算偏差补偿后的方位角估计值 $\hat{\theta}_{k|k}^{BC}$.

4) 构造递归工具变量矩阵 G_k , 并将 G_k 引入最小二乘算法的增益矩阵中, 构造新的增益矩阵

$$K_k^{IV} = P_{k|k-1} G_k^T (R_k + H_k P_{k|k-1} G_k^T)^{-1},$$

得到递归工具变量算法.

5) 将递归工具变量算法运用到卡尔曼滤波算法

中,得到新的状态估计方程

$$\hat{x}_{k|k}^{IV} = \hat{x}_{k|k-1} + K_k^{IV}(z_k - H_k \hat{x}_{k|k-1}),$$

对目标状态进行估计.

6) 将系统噪声不确定性考虑到状态估计方程中,得到实际误差协方差估计方程,并将其应用到RIVKF算法中.

7) 进行阈值计算,得到所需阈值

$$\epsilon_k = \frac{gS_k^{1/2}}{\|\hat{d}_{k|k-1}\|}.$$

8) 将 $\tilde{\theta}_k$ 与 $\hat{\theta}_{k|k}^{BC}$ 进行比较,确定其偏差大小,确保在大噪声环境中也能达到准确跟踪的目的.

4 仿真分析

4.1 参数设置

水下传感器轨迹如图2所示,具有5个匀速航段,各航段起始位置分别为: $[60, 0]^T$, $[0, 7.5]^T$, $[60, 15]^T$, $[0, 22.5]^T$, $[60, 30]^T$, $[0, 37.5]^T$. 其中声呐传感器的初始位置 $r_0 = [60, 0]^T$. 采样间隔 $T = 0.1$ s, 声呐传感器在每个固定时刻 ($t = kT, k \in \{0, 1, \dots, 149\}$) 进行方位角量测. 方位角噪声 n_k 假设服从方差 $\sigma_k^2 = \sigma_\theta^2, \sigma_\theta = \{1^\circ, 2^\circ, \dots, 10^\circ\}$ 的独立同分布, 由前文 $\sin n_k \approx n_k$ 可知 $E\{\sin^2 n_k\} \approx \sigma_k^2 = \sigma_\theta^2$, 因此 $\mu_k^2 = \sigma_\theta^2$. 目标初始位置和速度分别为 $p_0 = [30, 42]^T$ 和 $v_0 = [0, 12]^T$ (如图2所示). 过程噪声功率谱密度 $q_x = q_y = 0.2 \text{ m}^2/\text{s}^3, \lambda\Phi\Phi^T = 0.1I$.




图2 传感器及目标轨迹

在仿真中,目标跟踪初始化可通过目标状态估计 $\hat{x}_{0|0}$ 得到,其从真实目标状态附近高斯分布中得到,协方差 $P_{0|0} = \rho^2 \text{diag}(2.6^2, 2.6^2, 0.26^2, 0.26^2)$, 其中 $\rho = \{1, 2, \dots, 10\}$. 阈值设置为 $\epsilon_k = 4\sigma_k$, 且在初始收敛时期 ($0 \leq k < 39$) 仅靠误差补偿即可,递归工具变量在此后引入. 蒙特卡罗仿真次数 $M = 10000$. 将EKF、PLKF、BC-PLKF与本文提出的RIVKF进行跟踪位置误差对比分析.

4.2 算法性能分析

图3为不同量测噪声标准差下各算法目标位置估计的时均偏差标准、均方根误差和平均欧几里德误差比较结果,从比较结果可看出各算法在不同方位角噪声下的跟踪精度. 图4~图6分别为量测噪声小 ($\sigma_\theta = 3^\circ$)、中 ($\sigma_\theta = 7^\circ$)、大 ($\sigma_\theta = 10^\circ$) 时偏差标准、均方根误差和平均欧几里德误差比较结果.




图3 不同测量噪声标准差(σ_θ)下EKF、PLKF、BC-PLKF和RIVKF各偏差指标对比




图4 $\sigma_\theta = 3^\circ$ 时EKF、PLKF、BC-PLKF和RIVKF各偏差指标对比




图5 $\sigma_\theta = 7^\circ$ 时EKF、PLKF、BC-PLKF和RIVKF各偏差指标对比




图6 $\sigma_\theta = 10^\circ$ 时EKF、PLKF、BC-PLKF和RIVKF各偏差指标对比

由图3可知,无论方位角噪声多大,PLKF算法都如前文所述具有较大偏差,且方位角噪声越大,偏差越大.当 $\sigma_\theta \leq 5^\circ$ 时,EKF偏差较小,且其均方根误差逼近克拉罗下界,表明在方位角噪声较小时EKF算法对水下目标的跟踪效果较好,但随着方位角噪声增大,EKF初始化及收敛性问题显现,偏差迅速增大,跟踪精度下降.相比于传统的PLKF算法,经过偏差补偿的BC-PLKF算法偏差表现有显著提高.但随着方位角噪声增大,BC-PLKF算法的瞬时偏差估计精度下降,导致偏差逐渐增大,当 $\sigma_\theta \geq 6^\circ$ 时偏差增加显著,即便如此,BC-PLKF的偏差较PLKF、EKF有显著下降,跟踪精度明显提升.而本文所提出的RIVKF算法在方位角量测噪声较大时仍然偏差较小.

图4为 $\sigma_\theta = 3^\circ$ 时各个算法性能指标对比,可以看出,随着时间 k 的增长,OLKF算法的偏差较其他3种算法增加明显,跟踪精度较差,其他3种算法在方位角噪声较小时跟踪精度相仿;图5为 $\sigma_\theta = 7^\circ$ 时各个算法性能指标对比,可以看出,随着时间 k 的增加,PLFK和EKF算法的跟踪偏差迅速上升,跟踪精度进一步降低,而BC-PLKF与本文所提出的RIVKF算法依然有较小的跟踪误差,跟踪精度更佳;图6为 $\sigma_\theta = 10^\circ$ 时各个算法性能指标对比,可以看出,随着时间 k 的增加,4种算法的跟踪偏差相比方位角噪声较小时都有一定的增大,但本文所提出的RIVKF算法随着时间的增加仍能做到渐近稳定,跟踪精度较其他3种算法有明显的提高.

由以上分析可知,在水下纯方位目标跟踪过程

中,本文所提出的RIVKF算法可以有效消除 H_k 与 η_k 之间的相关性,使跟踪误差更小,跟踪精度更高.但在算法复杂度方面,通过对算法运行时间的观测(如表1所示)发现,相对于传统的PLKF,EKF和BC-PLKF算法,由于算法复杂度更高,RIVKF算法的平均运行时间更长(RIVKF算法复杂度主要来自于偏差补偿和IV估计阶段).

表1 各算法平均运行时间对比

算法	PLKF	EKF	BC-PLKF	RIVKF
运行时间/s	1	0.9	1.2	1.56

5 结论

本文针对传统伪线性卡尔曼滤波算法在纯方位水下目标跟踪中存在的严重偏差问题,将递归工具变量估计器引入偏差补偿伪线性卡尔曼滤波器中,通过递归工具变量矩阵来消除量测向量和伪线性噪声之间的相关性.通过仿真得出,与传统的伪线性卡尔曼滤波算法以及扩展卡尔曼滤波算法相比,本文所提出的递归工具变量卡尔曼滤波算法在纯方位水下目标跟踪中具有更好的稳定性和精确性,尤其是在复杂的大噪声水下环境中,RIVKF算法精确性最佳.

本次假设目标为匀速运动,在以后的研究中要将其逐渐扩展为匀加速以及变速运动,研究在时变情况下如何对水下目标进行精确跟踪.由于将偏差补偿算法和递归工具变量算法相结合,增加了算法复杂度,在此后的研究中应将如何在降低算法复杂度的情况下达到精准跟踪作为一个重要方向.此外,多传感

器多目标跟踪的研究也是未来很重要的领域。

参考文献(References)

- [1] Eiler J H, Grothues T M, Dobarro J A, et al. Comparing autonomous underwater vehicle (AUV) and vessel-based tracking performance for locating acoustically tagged fish[J]. *Marine Fisheries Review*, 2013, 75(4): 27-42.
- [2] Karoui I, Quidu I, Legris M. Automatic sea-surface obstacle detection and tracking in forward-looking sonar image sequences[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(8): 4661-4669.
- [3] Lionetto L, Casolla B, Mastropietri F, et al. Application research of 3D imaging sonar system in salvage process[J]. *Applied Mechanics and Materials*, 2014, 643(8): 279-282.
- [4] Zhang W, Zhou T, Peng D, et al. Underwater pipeline leakage detection via multi-beam sonar imagery[J]. *Journal of the Acoustical Society of America*, 2017, 141(5): 3917-3923.
- [5] Cho H, Gu J, Yu S C. Robust sonar-based underwater object recognition against angle-of-view variation[J]. *IEEE Sensors Journal*, 2016, 16(4): 1013-1025.
- [6] Marszal J, Salamon R. Detection range of intercept sonar for CWFM signals[J]. *Archives of Acoustics*, 2014, 39(2): 215-230.
- [7] Bryner D, Huffer F, Srivastava A, et al. Underwater minefield detection in clutter data using spatial point-process models[J]. *IEEE Journal of Oceanic Engineering*, 2016, 41(3): 670-681.
- [8] Barshalom Y, Li X R. Estimation and tracking: Principles, techniques, and software[M]. Norwood: Artech House, 1993.
- [9] BarShalom Y. Tracking and data association[J]. *Journal of the Acoustical Society of America*, 1988, 87(2): 918-919.
- [10] Zhang Q, Song T L. Improved bearings-only multi-target tracking with GM-PHD filtering[J]. *Sensors*, 2016, 16(9): 1-18.
- [11] Xiong Z, Xu K, Chen Y, et al. Research on multi-target bearings-only tracking method based on passive sonar systems[C]. *IEEE Advanced Information Technology, Electronic and Automation Control Conference*. Chicago, 2017: 1326-1330.
- [12] Pham D T. Some quick and efficient methods for bearing-only target motion analysis[J]. *IEEE Transactions on Signal Processing*, 1989, 41(9): 2737-2751.
- [13] Aidala V, Hammel S. Utilization of modified polar coordinates for bearings-only tracking[J]. *IEEE Transactions on Automatic Control*, 1983, 28(3): 283-294.
- [14] Li X, Willett P, Baum M, et al. PMHT approach for underwater bearing-only multisensor-multitarget tracking in clutter[J]. *IEEE Journal of Oceanic Engineering*, 2016, 41(4): 831-839.
- [15] Li L Q, Xie W X, Liu Z X. Auxiliary truncated particle filtering with least-square method for bearings-only maneuvering target tracking[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2017, 52(5): 2562-2567.
- [16] Li L Q, Wang X L, Liu Z X, et al. Auxiliary truncated unscented Kalman filtering for bearings-only maneuvering target tracking[J]. *Sensors*, 2017, 17(5): 1-14.
- [17] Zhu W, Wang W, Yuan G. An improved interacting multiple model filtering algorithm based on the cubature Kalman filter for maneuvering target tracking[J]. *Sensors*, 2016, 16(6): 1-12.
- [18] Nardone S C, Lindgren A G, Kai F G. Fundamental properties and performance of conventional bearings-only target motion analysis[J]. *IEEE Transactions on Automatic Control*, 1984, 29(9): 775-787.
- [19] Rao S K. Pseudo-linear estimator for bearings-only passive target tracking[J]. *Radar, Sonar and Navigation*, 2001, 148(1): 16-22.
- [20] Rao S K, Kumar D V A N R, Raju K P. Combination of pseudolinear estimator and modified gain bearings-only extended Kalman filter for passive target tracking in abnormal conditions[C]. *International Symposium on Ocean Electronics (SYMPOL)*. Kochi, 2013: 3-8.
- [21] Doğançay K I L. Bias compensation for the bearings-only pseudolinear target track estimator[J]. *IEEE Transactions on Signal Process*, 2006, 54(1): 59-68.
- [22] Doğançay K I L. 3D pseudolinear target motion analysis from angle measurements[J]. *IEEE Transactions on Signal Processing*, 2015, 63(6): 1570-1580.
- [23] Zhang Y J, Xu G Z. Bearings-only target motion analysis via instrumental variable estimation[J]. *IEEE Transactions on Signal Processing*, 2010, 58(11): 5523-5533.
- [24] Barshalom Y. Multitarget-multisensor tracking[M]. Norwood: Artech House, 1992.
- [25] Young P C. Recursive estimation and time-series analysis. An introduction for the student and practitioner[J]. *IEEE Transactions on Acoustics Speech and Signal Processing*, 2015, 31(1): 1-10.
- [26] Sorenson H W. Least-squares estimation: From Gauss to Kalman[J]. *Spectrum*, 1970, 7(7): 63-68.
- [27] Li X R, Zhao Z, Li X B. Evaluation of estimation algorithms: Credibility tests[J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, 2012, 42(1): 147-163.

作者简介

郭戈(1972—),男,教授,博士生导师,从事智能交通系统、智慧海洋监测网络等研究, E-mail: geguo@yeah.com;

王兴凯(1993—),男,硕士生,从事智慧海洋监测网络的研究, E-mail: 2274780321@qq.com;

徐慧朴(1978—),女,副教授,从事点云数据处理与三维建模等研究, E-mail: hpx1212@dlmu.edu.cn.

(责任编辑:孙艺红)