

文章编号 1004-924X(2019)01-0260-11

采用自适应一致性 UKF 的分布式目标跟踪

郑斌琪^{1,2}, 李宝清¹, 刘华巍^{1,2}, 袁晓兵^{1*}

- (1. 中国科学院 上海微系统与信息技术研究所 微系统技术重点实验室, 上海 201800;
2. 中国科学院大学, 北京 100049)

摘要: 由于传统分布式跟踪方法在先验噪声协方差与其实际值不相匹配时跟踪误差较大, 提出了一种采用自适应一致性无迹卡尔曼滤波的分布式目标跟踪方法, 该方法首先执行分布式 UKF 算法得到对当前移动目标状态的估计值, 然后通过一个系统错误检测机制, 确定是否需要更新噪声协方差值。如需要, 则根据当前获得的测量信息去估计当前噪声协方差, 并联合该估计值和先前的噪声协方差值获得一个新的先验噪声协方差值。最后根据新获得的噪声协方差值对获得的目标状态估计值进行修正。实验结果表明该方法具有较好的准确性和鲁棒性; 在噪声未知环境下, 基于 ACUKF 的分布式跟踪方法相比于基于容积信息滤波和基于分布式无迹卡尔曼滤波的跟踪方法, 最大跟踪误差值分别减少了 49.93% 和 51.46%; 在目标过程噪声发生动态变化的情况下, 提出的方法相比于上述两种传统跟踪方法, 跟踪误差值分别减少了 40.67% 和 40.06%。

关键词: 分布式跟踪; 图像传感器网络; 自适应滤波; 不确定性噪声; 非线性估计

中图分类号: TP394.1; TH691.9 **文献标识码:** A **doi:** 10.3788/OPE.20192701.0260

Distributed target tracking based on adaptive consensus UKF

ZHENG Bin-qi^{1,2}, LI Bao-qing¹, LIU Hua-wei^{1,2}, YUAN Xiao-bing^{1*}

- (1. *Science and Technology on Microsystem Laboratory, Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Sciences, Shanghai 200080, China;*
2. *University of Chinese Academy of Sciences, Beijing 100049, China)*

* *Corresponding author, E-mail: sinowsn@mail.sim.ac.cn*

Abstract: As the traditional distributed methods of target tracking may suffer from performance degradation owing to mismatch between the noise distributions assumed a priori and the actual ones, a distributed target tracking method was proposed based on adaptive consensus unscented Kalman filter to improve the accuracy and robustness of the tracking results. More specifically, at each time step, a distributed UKF (DUK) would be implemented to obtain the estimations of the moving target. Next, an online fault-detection mechanism was adopted to judge if it was necessary to update current noise covariance. If it was necessary, the estimations of the current noise covariance would be calculated according to the measurement information. By utilizing a weighting factor, the filter would combine the last noise covariance matrices with the estimations to obtain the new noise covariance matrices. Finally, the state estimations would be corrected according to the new noise covariance matrices and previ-

收稿日期: 2018-06-28; 修订日期: 2018-08-20.

基金项目: 微系统技术重点实验室基金资助项目 (No. 6142804010205)

ous state estimations. The experiment results demonstrate that: in unknown noise environments the tracking errors of the proposed method are reduced by as much as 49.93% and 51.46% when compared with those of the distributed tracking methods based on the cubature information filter and DUK, respectively; in dynamic noise environments the tracking errors of the proposed method are reduced by as much as 40.67% and 40.06% when compared with those of the above two traditional methods, respectively. These results demonstrate that the proposed method performs well in terms of accuracy and robustness on distributed tracking with uncertain noise.

Key words: distributed tracking; camera sensor networks; adaptive filter; uncertain noise; nonlinear estimation

1 引言

随着视频处理、传感器以及半导体技术的快速发展,图像传感器的价格快速降低,这些都有力地推动了图像传感器网络的发展。目标跟踪^[1-2]是图像传感器网络的一个重要应用,其目的是实时准确地获取移动目标当前状态信息。分布式跟踪方法由于其易于建立,对于节点失败的高容错性等特点,适用于需要处理数据量较大且节点较多的图像传感器网络中^[3]。在基于图像传感器网络的分布式跟踪系统中,节点的可观性能够得到保证和加强。特别地,当构成跟踪系统的图是强连接图时,系统的联合可观性(Observability)能够通过邻居节点之间的信息交互来得到保证,甚至在部分节点的观测值与实际值存在较大误差的条件下也能最终保证一个较好的可观性^[4]。

在基于图像传感器网络的目标跟踪中,非线性状态估计算法是一个非常重要的研究方向,常用来实时且准确地获得当前目标的状态信息。许多经典的非线性估计算法,如扩展信息滤波(Extended Kalman Filter, EKF)、无迹卡尔曼滤波(Unscented Kalman Filter, UKF)、粒子滤波(Particle Filter, PF)以及它们的各种变形算法被提出用来解决非线性系统中的状态估计问题^[5]。其中,UKF算法作为一种经典的非线性状态估计算法,拥有很多诸如实现简单、准确率高、收敛速度快等优点,因此被广泛应用到目标跟踪应用中^[6-7]。UKF算法作为卡尔曼滤波的一种变种,仍然是一种最小均方误差估计器,它需要提前较准确地获得系统噪声的先验统计特性。其中过程

噪声协方差矩阵和测量噪声协方差矩阵是两个最重要的统计量,因为它们直接决定了状态预测值和系统测量值对最终估计结果的影响^[8]。但是在实际应用中,使用者通常很难准确地获取这两个量的当前值。因为在实际应用中,场景环境通常为未知或者即使已知的环境系统状态也可能会发生突变。比如,在跟踪移动的车辆时,车辆的突然加速或者道路较为曲折时,车辆需要不断的改变方向。上述情况在应用卡尔曼滤波进行状态估计时,都可视为过程噪声环境发生了突变,如果不能自适应的改变滤波算法的先验噪声,状态估计误差会迅速扩大,甚至导致跟踪结果出现发散。因此,要想获得一个鲁棒性较好跟踪算法,自适应的更新先验噪声协方差的值是一个非常有必要的手段。

最近几年,国内外的学者提出了许多自适应滤波算法来解决非线性系统中的鲁棒状态估计问题。文献[9]构建了基于模型自适应卡尔曼滤波算法的复合控制结构,对目标角位置数据进行滤波估计以获得目标角速度信息来实现复合控制以提高跟踪精度。为了准确获得噪声协方差的估计值,窗口平滑法是一个常用来估计系统噪声统计特性的近似方法。例如,在文献[10]中作者通过联合一个窗口平滑和随机权重概念去呈现一个自适应UKF算法,然后将这个方法扩展到非线性系统中。与窗口平滑自适应估计方法不同,文献[11]采用一个动态调增的衰落因子去自适应调增设置的先验噪声协方差矩阵。然而这个方法并不能够保证所得到的噪声协方差矩阵是正定矩阵。

上述文献中,基于窗口平滑法的自适应算法,其计算复杂度通常较高,在计算能力较低的传感器上很难做到实时性运算。而对于基于权重因子

的自适应估计算法,其权重因子的计算通常较复杂,且较难保证获得的先验协方差一定为正定矩阵。而且,目前大多数自适应估计算法均为针对集中式系统的非线性估计应用,对于常采用分布式系统的基于图像传感器网络的目标跟踪,这些集中式的估计算法并不完全适用。此外,当前很多基于图像传感器的分布式目标跟踪方法并没有考虑先验噪声协方差与实际值不相匹配的问题。为此本文首先提出了一种一致性自适应 UKF (Adaptive Consensus Unscented Kalman Filter, ACUKF) 算法,来动态调整先验噪声协方差值,并将该算法扩展到基于图像传感器网络的分布式跟踪系统中,以实现在不确定性噪声环境下提出的目标跟踪方法具有较好的准确性和鲁棒性。具体来说,该算法首先执行分布式 UKF 算法得到对当前移动目标状态的估计值,然后通过一个系统错误检测机制,确定是否需要更新噪声协方差值。如果需要,则根据当前获得的测量信息去估计当前系统噪声协方差。然后,利用权重联合该估计值和先前的噪声协方差值的方法获得一个新的先验噪声协方差值。最后根据新获得的噪声协方差值对获得的目标状态估计结果进行修正。

2 分布式目标跟踪基本原理

2.1 问题阐述

假设在二维区域 R 内存在一个由 N 个分离铺设的图像传感器节点构成的监控网络。网络内的各传感器节点之间的通信拓扑结构由一个无向连接图来表示, $Z = (V, \xi)$ 此处的节点集 $V = \{s_1, s_2, \dots, s_N\}$ 代表网络中的 N 个节点构成的集合,边集合 $\xi \subset V \times V$ 代表节点之间可工作的通信链路。对于集合 ξ 中的任意一个边 (s_i, s_j) , 它表示节点 s_i 和节点 s_j 之间存在一个可靠的通信链路。节点集 $\phi_i = \{s_k | (s_i, s_k) \in \xi\}$ 代表节点 s_i 的所有邻居节点所构成的集合,则节点 s_i 的邻居节点的个数可以表示为 $|\phi_i|$ 。假设所有节点在监控网络初始化时能够获得它们所有的邻居节点信息。需要指出的是本文仅讨论的是在同一时刻区域内仅存在一个移动目标的情况,实际上采用相关的数据关联算法(联合概率数据关联^[12])可以将适用于单目

标的方法扩展到解决多目标跟踪的问题,这也是下一步工作的方向。

目标进入监控区域前,所有节点将处在警报状态。一旦有目标进入区域,所有能检测到目标的节点将被激活去检测目标信息并且与其邻居节点交换信息。向量 $x_k \in \mathbb{R}^n$ 表示目标在时刻 k 时的 n 维状态值。对于目标 \hat{A} 的运动模型,我们采用一个简单的线性分离时间运动模型^[13]:

$$x_k = f(x_{k-1}) + w_{k-1}. \quad (1)$$

其中: k 代表采样时刻, $f(\cdot)$ 为目标状态转移函数, w_{k-1} 是运动过程噪声向量,在本文中被假设为协方差矩阵为 Q_{k-1} 的零均值高斯白噪声。同样地,在 k 时刻节点 s_i 对目标 \hat{A} 的观测值 $z_{k,i} \in \mathbb{R}^p$ 可以间接由下面的分离时刻观测模型给出:

$$z_{k,i} = h_i(x_k) + v_{k,i}, \quad (i = 1, 2, \dots, N), \quad (2)$$

其中 $v_{k,i}$ 是测量值噪声向量,同样被假设为零均值高斯白噪声,其协方差矩阵为 R_k 。

一般来说,分布式目标跟踪的目的是在每一个相关节点均估计当前的目标状态值,然后各邻居节点之间交换估计的目标状态信息,进而最终获得更加准确的目标状态估计值^[14]。在实际目标跟踪应用环境中,目标状态转移模型和节点的测量值模型通常都是非线性的。因此,很多非线性估计算法被提出用来解决非线性系统中的目标状态估计问题。其中,UKF 作为最小方差估计器是一种常用的非线性滤波算法。在使用 UKF 时,使用者需要提前知道系统噪声的统计特性,进而设立合理的先验噪声协方差值。然而在实际应用中,应用环境的噪声统计特性通常是很难获取到的,或者环境噪声特性会发生动态变化,我们称这样的环境为“不确定噪声环境”^[5]。在不确定噪声环境下,基于标准 UKF 的目标跟踪所得结果可能不准确甚至出现估计值发散。因此,在这种情况下 UKF 的先验噪声协方差矩阵需要根据实际获得的测量值进行更新。

2.2 平均一致性方法

平均一致性方法是一种很常用的分布式算法,它通过使用局部和邻居信息来计算全局节点信息的算数平均值,同时使网络中的所有节点都能获得该结果^[15]。假设网络中每个节点都有一个状态向量 x_i , 则当前所有节点的状态向量集合

为 $\{\mathbf{x}_j\}_{j=1}^N$ 。这些节点的状态向量的平均值 $\frac{1}{N} \sum_{j=1}^N \mathbf{x}_j$ 可以通过一个分布式的方式通过多次迭代计算获得^[16]。

在平均一致性方法中迭代开始时,假设节点 s_i 获得它的初始状态 $\mathbf{x}_i(0)$ 。第 τ 次迭代开始时,节点 s_i 将会发送它先前的状态估计值 $\mathbf{x}_i(\tau-1)$ 给它所有的直接邻居节点,同时它也接收来自其邻居节点的状态值信息。平均一致性算法的第 τ 次迭代可以用式(3)来表示:

$$\mathbf{x}_i(\tau) = \mathbf{x}_i(\tau-1) + \omega \sum_{j \in \mathcal{N}_i} [\mathbf{x}_j(\tau-1) - \mathbf{x}_i(\tau-1)], \quad (3)$$

其中: $\omega \in (0, 1/\Delta_{\max})$ 表示速率参数, Δ_{\max} 代表当前网络的最大度。 ω 用来保证网络中节点估计的收敛速率,一个较大的 ω 参数意味着较快的估计值收敛速率。对于参数 ω 的选取,文献^[17]给出了 Metropolis weights 方法,能够很好地选择一个合适的值。在经过若干次迭代后,各邻居节点之间的估计值将会收敛到初始状态的均值^[18]。

3 噪声不确定环境下的分布式目标跟踪方法

首先呈现基于一致性理论的 UKF (Consensus-based UKF, CUKF),然后将它扩展为自适应的一致性 UKF (Adaptive Consensus UKF, ACUKF)算法,最后基于该算法提出一种分布式目标跟踪方法。

3.1 基于一致性理论的 UKF

与集中式卡尔曼滤波需要构建融合的测量值和协方差不同,基于一致性的卡尔曼滤波构建了测量值和协方差值的一致性信息适用于分布式跟踪系统。具体来说,分布式跟踪问题可以被规约为两个动态一致性问题,这两个问题可以通过一致性滤波算法来解决^[19]。本文首先利用 CUKF 来解决分布式跟踪问题。

假设节点 s_i 在 $k-1$ 采样时刻得到目标状态估计值 $\bar{\mathbf{x}}_{k-1|k-1}^i$ 及其误差协方差矩阵 $\bar{\mathbf{P}}_{k-1|k-1}^i$, 则其预测的 k 时刻状态值的均值及其误差协方差矩阵可以表示为:

$$\bar{\mathbf{x}}_{k|k-1}^i = \sum_{s=0}^{2n_x} \omega_s f(\varphi_{k-1|k-1}^{i,s}), \quad (4)$$

$$\bar{\mathbf{P}}_{k|k-1}^{i,xx} = \sum_{s=0}^{2n_x} \omega_s [f(\varphi_{k-1|k-1}^{i,s}) - \bar{\mathbf{x}}_{k|k-1}^i] \times [f(\varphi_{k-1|k-1}^{i,s}) - \bar{\mathbf{x}}_{k|k-1}^i]^T + \mathbf{Q}_{k-1}, \quad (5)$$

其中: ω_s 是权重参数, $\{\varphi_{k-1|k-1}^{i,s}\}_{s=0}^{2n_x}$ 是相称性的 sigma 点。

定义 k 时刻节点 s_i 得到的新息向量为 $\mathbf{u}_k^i = \mathbf{z}_k^i - h_i(\bar{\mathbf{x}}_{k|k-1}^i)$, \mathbf{z}_k^i 是节点 s_i 在 k 时刻对目标的测量值。进而,预测的新息协方差矩阵 $\bar{\mathbf{P}}_{k|k-1}^{i,zz}$ 和互协方差矩阵 $\bar{\mathbf{P}}_{k|k-1}^{i,xz}$ 可以由式(6)~式(8)计算得出:

$$\bar{\mathbf{P}}_{k|k-1}^{i,zz} = \sum_{s=0}^{2n_x} \omega_s [h_i(\varphi_{k|k-1}^{i,s}) - \bar{\mathbf{z}}_{k|k-1}^i] \times [h_i(\varphi_{k|k-1}^{i,s}) - \bar{\mathbf{z}}_{k|k-1}^i]^T + \mathbf{R}_k^i, \quad (6)$$

$$\bar{\mathbf{P}}_{k|k-1}^{i,xz} = \sum_{s=0}^{2n_x} \omega_s [f(\varphi_{k|k-1}^{i,s}) - \bar{\mathbf{x}}_{k|k-1}^i] \times [h_i(\varphi_{k|k-1}^{i,s}) - \bar{\mathbf{z}}_{k|k-1}^i]^T, \quad (7)$$

$$\bar{\mathbf{z}}_{k|k-1}^i = \sum_{s=0}^{2n_x} \omega_s h_i(\varphi_{k-1|k-1}^{i,s}). \quad (8)$$

标准的 UKF 通常为集中式 UKF,其更新的目标状态估计均值及其误差协方差矩阵的估计值可以由式(9)得到^[20]:

$$\begin{aligned} [\hat{\mathbf{P}}_{k|k}^i]^{-1} &= [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} + \\ &\sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{j,xz} [\mathbf{R}_k^j]^{-1} [\bar{\mathbf{P}}_{k|k-1}^{j,xz}]^T [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1}, \end{aligned} \quad (9)$$

$$\begin{aligned} \hat{\mathbf{x}}_{k|k}^i &= \bar{\mathbf{x}}_{k|k-1}^i + \\ &\bar{\mathbf{P}}_{k|k-1}^{i,xx} \sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{j,xz} [\mathbf{R}_k^j]^{-1} (\mathbf{z}_k^j - \bar{\mathbf{z}}_{k|k-1}^j). \end{aligned} \quad (10)$$

为了方便后面进一步推导,本文定义:

$$\mathbf{y}_{k|k} \triangleq \frac{1}{N} \sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{j,xz} [\mathbf{R}_k^j]^{-1} (\mathbf{z}_k^j - \bar{\mathbf{z}}_{k|k-1}^j), \quad (11)$$

$$\mathbf{Y}_{k|k} \triangleq \frac{1}{N} \sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{j,xz} [\mathbf{R}_k^j]^{-1} [\bar{\mathbf{P}}_{k|k-1}^{j,xz}]^T [\bar{\mathbf{P}}_{k|k-1}^{j,xx}]^{-1}. \quad (12)$$

如果当前跟踪任务节点的 $\mathbf{y}_{k|k}$ 和 $\mathbf{Y}_{k|k}$ 能够获得,那么就可以将整个滤波算法拆分成两个一致性滤波算法,然后以分布式的方式执行滤波算法得到目标状态估计值。详细来说,将节点 s_i 在 k 时刻的 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$ 值分别赋值为:

$$\mathbf{y}_{k|k}^i \triangleq [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{i,xz} [\mathbf{R}_k^i]^{-1} (\mathbf{z}_k^i - \bar{\mathbf{z}}_{k|k-1}^i), \quad (13)$$

$$\mathbf{Y}_{k|k}^i \triangleq [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{i,xx} [\mathbf{R}_k^i]^{-1} [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^T [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1}. \quad (14)$$

然后,将 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$ 分别作为公式(3)中所示的一致性滤波算法的初始输入项,进而可以分别得到新的 $\hat{\mathbf{y}}_{k|k}^i$ 和 $\hat{\mathbf{Y}}_{k|k}^i$, 这两个新的值将会更加接近系统的一致性状态估计结果。因此,与集中式 UKF 算法的更新过程不同(式(9)、式(10)),基于 CUKF 算法的更新部分可以表示为:

$$[\hat{\mathbf{P}}_{k|k}^{i,xx}]^{-1} = [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} + \mathbf{N} \hat{\mathbf{Y}}_{k|k}^i, \quad (15)$$

$$\hat{\mathbf{x}}_{k|k}^i = \bar{\mathbf{x}}_{k|k-1}^i + \mathbf{N} \hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{y}}_{k|k}^i. \quad (16)$$

CUKF 算法需要在标准的 UKF 基础上对权重测量值 $\hat{\mathbf{y}}_{k|k}^i$ 和相应的协方差信息矩阵 $\hat{\mathbf{Y}}_{k|k}^i$ 进行一致性运算,且通常需要经过若干次迭代后才能最终达到统一的均值结果。

3.2 采用自适应一致性 UKF 的分布式目标跟踪方法

在第 $k-1$ 采样周期结束时,假设系统中的每一个节点均获得了 $k-1$ 时刻目标状态及其误差协方差矩阵的一致性状态估计值,对于节点 s_i 来说分别为 $\hat{\mathbf{x}}_{k-1|k-1}^i$, $\hat{\mathbf{P}}_{k-1|k-1}^{i,xx}$ 。在第 k 个采样周期,对于任意节点 $s_i \in \mathcal{N}$,当获得当前时刻对目标的测量值 \mathbf{z}_k^i 后,根据式(13)、式(14)计算 k 时刻的一致性滤波算法的初始输入项 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$,然后利用平均一致性方法使系统内各节点的状态估计值均收敛到一个统一的估计值。

由式(5)、式(6)可知,CUKF 算法需要提前设定系统的先验噪声协方差矩阵。然而,在使用者无法获得实际环境噪声特性或者系统的噪声特性在算法运行过程中出现了大幅度的变化时,设定的先验噪声协方差矩阵与实际噪声协方差值不匹配,则会导致 UKF 的滤波结果出现较大误差甚至发散^[21]。所以,对于噪声不匹配的情况下进行自适应更新是提高跟踪算法鲁棒性一个重要手段。

文献[5]中提出了一种用来非线性状态估计的自适应 UKF 算法,该算法能够很好的应用于集中式的目标跟踪,但并不适用于分布式目标跟踪方法。本文中,将这个算法扩展到适用于分布式系统的一致性 UKF 算法中去。以第 k 个采样周期节点 s_i 为例,该方法的原理归纳如下:

(1) 系统故障检测机制。在对噪声进行更新

之前需要确定判断是否有必要去更新当前设置的先验噪声协方差矩阵。如式(17)所示的一个统计函数被用来判断系统是否发生故障:

$$\hat{\varphi}_k^i = (\mathbf{u}_k^i)^T [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \mathbf{u}_k^i. \quad (17)$$

根据文献[21]所述, $\hat{\varphi}_k^i$ 服从一个自由度为 s 的卡方分布,此处的 s 是新息向量 \mathbf{u}_k^i 的维数。将 $\hat{\varphi}_k^i$ 作为公式(3)中所示的一致性滤波算法的初始输入项,进而可以分别得到新的 $\hat{\varphi}_k^i$ 。假设需要以概率 $1-\rho$ 来检测一个系统是否发生了故障,此处的 ρ 是一个已选择的参数。则存在一个由 $\hat{\varphi}_k^i$ 的卡方分布决定的阈值 $\chi_{\alpha,s}^2$ 使得式(18)满足:

$$P(\hat{\varphi}_k^i > \chi_{\alpha,s}^2) = \rho. \quad (18)$$

因此通过设置合适的概率值 ρ ,可以得到一个相应的错误检测阈值 $\chi_{\alpha,s}^2$,使得算法能够以概率 $1-\rho$ 来检测出系统是否发生故障。

(2) 自适应调整噪声协方差。新息向量 \mathbf{u}_k^i 表示新获得的测量值带来的有用信息,因此可以利用它进行噪声协方差的更新。目标运动过程噪声向量的估计值可以表示为:

$$\begin{aligned} \hat{\mathbf{w}}_{k-1} &= \hat{\mathbf{x}}_{k|k}^i - f(\hat{\mathbf{x}}_{k-1|k-1}^i) \approx \hat{\mathbf{x}}_{k|k}^i - \bar{\mathbf{x}}_{k|k-1}^i = \\ &= \hat{\mathbf{P}}_{k|k}^{i,xx} \sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{i,xx} [\mathbf{R}_k^i]^{-1} (\mathbf{z}_k^i - \bar{\mathbf{z}}_{k|k-1}^i) \approx \\ &= \hat{\mathbf{P}}_{k|k}^{i,xx} \sum_{j=1}^N [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{i,xx} [\mathbf{R}_k^i]^{-1} \mathbf{u}_k^i. \end{aligned} \quad (19)$$

令 $\mathbf{K}_k^i \triangleq [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k-1}^{i,xx} [\mathbf{R}_k^i]^{-1} \mathbf{u}_k^i$ 作为式(3)中所示的一致性算法的初始输入项,与系统中其他节点进行迭代交互最终得到新的 $\hat{\mathbf{K}}_k^i$ 。则式(19)变化为:

$$\hat{\mathbf{w}}_{k-1} \approx \hat{\mathbf{P}}_{k|k}^{i,xx} \mathbf{N} \hat{\mathbf{K}}_k^i. \quad (20)$$

因此节点 s_i 的过程噪声协方差矩阵的估计值为:

$$\begin{aligned} \hat{\mathbf{Q}}_{k-1}^i &= \text{cov}(\hat{\mathbf{w}}_{k-1}) = \\ &= \mathbf{N}^2 (\hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{K}}_k^i) (\hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{K}}_k^i)^T. \end{aligned} \quad (21)$$

与文献[5]中所采用的方法一样,本文通过使用一个权重因子 λ 去平衡先前噪声协方差值设定值与其当前理论估计值 $\hat{\mathbf{Q}}_{k-1}^i$,从而得到一个新的值:

$$\mathbf{Q}_{k-1}^i = (1-\lambda) \mathbf{Q}_{k-1}^i + \lambda \mathbf{N}^2 (\hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{K}}_k^i) (\hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{K}}_k^i)^T, \quad (22)$$

其中 $\lambda = \max\{\lambda_0, (\varphi_k - a \times \chi_{\rho, s}^2) / \varphi_k\}$ 。此处的 $\lambda_0 \hat{I}(0, 1)$ 是 λ 的一个下限,用来确保更新强度, $a > 0$ 是一个跟实际环境相关的转换参数。由上述公式可看出,当 φ_k^i 超出一个阈值后 λ 会随着 φ_k^i 的增大而增大。

对于各个的测量值噪声协方差矩阵的更新,由于利用新息向量获得的测量值噪声协方差矩阵的估计值不能保证为正定矩阵^[22],所以本文利用节点 s_i 在 k 采样时刻的残差向量 ϵ_k^i 去获得的其测量噪声协方差 \mathbf{R}_k^i 的估计值:

$$\epsilon_k^i = \mathbf{z}_k^i - h_i(\hat{\mathbf{x}}_{k|k}^i). \quad (23)$$

进一步地,其测量值噪声协方差矩阵可表示为^[23]:

$$\hat{\mathbf{R}}_k^i = \text{cov}(\hat{\mathbf{v}}_{k,i}) = E[\boldsymbol{\epsilon}_k^i (\boldsymbol{\epsilon}_k^i)^T] + \mathbf{H}_k^i \hat{\mathbf{P}}_{k|k}^{i,xx} (\mathbf{H}_k^i)^T, \quad (24)$$

其中: $[\mathbf{H}_k^i]^T \triangleq [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]^{-1} [\bar{\mathbf{P}}_{k|k-1}^{i,xx}]$, \mathbf{H}_k^i 是定义的伪测量值矩阵^[7]。与过程协方差矩阵的更新规则类似,本文使用一个权重因子 σ^i 去平衡先前噪声协方差值设定值与其当前估计值 $\hat{\mathbf{R}}_k^i$, 进而节点 s_i 得到一个新的测量值噪声协方差矩阵:

$$\mathbf{R}_k^i = (1 - \sigma^i) \mathbf{R}_k^i + \sigma^i [\boldsymbol{\epsilon}_k^i (\boldsymbol{\epsilon}_k^i)^T + \mathbf{H}_k^i \hat{\mathbf{P}}_{k|k}^{i,xx} (\mathbf{H}_k^i)^T], \quad (25)$$

其中 $\sigma^i = \max\{\alpha_0, (\varphi_k^i - b \times \chi_{\rho, s}^2) / \varphi_k^i\}$ 。此处的 $\alpha_0 \hat{I}(0, 1)$, $b > 0$ 是一个跟实际环境相关的转换参数。 α_0 和 b 的挑选规则与 λ_0 和 a 相同。

(3)修正目标状态估计值。节点 s_i 得到一个更新的目标运动过程噪声协方差矩阵 \mathbf{Q}_{k-1} 和测量值噪声协方差矩阵 \mathbf{R}_k^i 后,需要对先前的目标状态估计值进行修正。

将新得到的 \mathbf{Q}_{k-1} 和 \mathbf{R}_k^i , 分别依次代入 3.1 节所述的相关公式中,即可得到修正后的 $\bar{\mathbf{P}}_{k|k}^{i,xx}$ 、 $\bar{\mathbf{P}}_{k|k}^{i,yy}$ 和 $\bar{\mathbf{P}}_{k|k}^{i,xy}$ 。则节点 s_i 在 k 时刻的 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$ 的修正值为:

$$\mathbf{y}_{k|k}^i \triangleq [\bar{\mathbf{P}}_{k|k}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k}^{i,xx} [\mathbf{R}_k^i]^{-1} (\mathbf{z}_k^i - \bar{\mathbf{z}}_{k|k}^i), \quad (26)$$

$$\mathbf{Y}_{k|k}^i \triangleq [\bar{\mathbf{P}}_{k|k}^{i,xx}]^{-1} \bar{\mathbf{P}}_{k|k}^{i,xx} [\mathbf{R}_k^i]^{-1} [\bar{\mathbf{P}}_{k|k}^{i,xx}]^T [\bar{\mathbf{P}}_{k|k}^{i,xx}]^{-1}. \quad (27)$$

将更新后的 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$ 分别作为式(3)中所示的一致性算法的初始输入项,与系统中其他节点进行交互,进而得到修正的一致性的 $\hat{\mathbf{y}}_{k|k}^i$ 和 $\hat{\mathbf{Y}}_{k|k}^i$ 。最终修正状态估计值 $\hat{\mathbf{x}}_{k|k}^i$ 和误差协方差矩

阵 $\hat{\mathbf{P}}_{k|k}^{i,xx}$:

$$[\hat{\mathbf{P}}_{k|k}^{i,xx}]^{-1} = [\bar{\mathbf{P}}_{k|k}^{i,xx}]^{-1} + \hat{\mathbf{N}}\mathbf{Y}_{k|k}^i, \quad (28)$$

$$\hat{\mathbf{x}}_{k|k}^i = \bar{\mathbf{x}}_{k|k}^i + \hat{\mathbf{N}}\hat{\mathbf{P}}_{k|k}^{i,xx} \hat{\mathbf{y}}_{k|k}^i. \quad (29)$$

本文提出的基于自适应一致性 UKF 的目标跟踪算法,总结如表 1 所示。

表 1 基于自适应一致性 UKF 的目标跟踪算法

Tab.1 Target tracking algorithm based on ACUKF

输入:任意节点 s_i 获得的 $k-1$ 时刻的目标状态估计

值 $\hat{\mathbf{x}}_{k-1|k-1}^i$ 及其误差协方差矩阵 $\hat{\mathbf{P}}_{k-1|k-1}^{i,xx}$, \mathbf{Q}_{k-1} 和 \mathbf{R}_k^i 。

①利用 $\hat{\mathbf{x}}_{k-1|k-1}^i$ 和 $\bar{\mathbf{P}}_{k|k-1}^{i,xx}$ 根据式(4)、式(5)预测 k 时刻目标状态 $\hat{\mathbf{x}}_{k|k-1}^i$ 及其误差协方差矩阵 $\bar{\mathbf{P}}_{k|k-1}^{i,xx}$ 。

②由 $\hat{\mathbf{x}}_{k|k-1}^i$ 和 $\bar{\mathbf{P}}_{k|k-1}^{i,xx}$ 可得到 $\bar{\mathbf{P}}_{k|k-1}^{i,yy}$ 和 $\bar{\mathbf{P}}_{k|k-1}^{i,xy}$ 。

③获得测量值 \mathbf{z}_k^i 后根据式(13)、式(14)和式(17)分别计算 $\mathbf{y}_{k|k}^i$ 、 $\mathbf{Y}_{k|k}^i$ 、 $\boldsymbol{\varphi}_k^i$, 同时计算 \mathbf{K}_k^i 。

④将 $\mathbf{y}_{k|k}^i$ 、 $\mathbf{Y}_{k|k}^i$ 、 $\boldsymbol{\varphi}_k^i$ 、 \mathbf{K}_k^i 分别作为初始值,执行一致性算法得到 $\hat{\mathbf{y}}_{k|k}^i$ 、 $\hat{\mathbf{Y}}_{k|k}^i$ 、 $\hat{\boldsymbol{\varphi}}_k^i$ 、 $\hat{\mathbf{K}}_k^i$ 。

⑤根据式(15)、式(16)分别计算 $\hat{\mathbf{P}}_{k|k}^{i,xx}$ 、 $\hat{\mathbf{x}}_{k|k}^i$ 。

⑥判断 $\hat{\boldsymbol{\varphi}}_k^i$ 是否大于 $\chi_{\rho, s}^2$, 如果小于则结束当前算法运行。

⑦如果 $\hat{\boldsymbol{\varphi}}_k^i > \chi_{\rho, s}^2$, 则分别根据式(22)、式(25)计算更新后的 \mathbf{Q}_{k-1}^i 、 \mathbf{R}_k^i 。

⑧根据 $\hat{\mathbf{P}}_{k|k}^{i,xx}$ 、 $\hat{\mathbf{x}}_{k|k}^i$ 以及更新后的 \mathbf{Q}_{k-1}^i 、 \mathbf{R}_k^i , 分别得到修正的 $\bar{\mathbf{P}}_{k|k}^{i,xx}$ 、 $\bar{\mathbf{P}}_{k|k}^{i,yy}$ 和 $\bar{\mathbf{P}}_{k|k}^{i,xy}$ 。

⑨利用式(26)、式(27)计算修正后的 $\mathbf{y}_{k|k}^i$ 和 $\mathbf{Y}_{k|k}^i$ 。

⑩将新得到的 $\mathbf{y}_{k|k}^i$ 、 $\mathbf{Y}_{k|k}^i$ 、 \mathbf{Q}_{k-1}^i 和 \mathbf{R}_k^i 分别作为初始值,执行一致性算法得到一致性的 $\mathbf{y}_{k|k}^i$ 、 $\mathbf{Y}_{k|k}^i$ 、 \mathbf{Q}_{k-1}^i 和 \mathbf{R}_k^i 。最终利用式(28)、式(29)获得修正的 $\hat{\mathbf{x}}_{k|k}^i$ 和 $\hat{\mathbf{P}}_{k|k}^{i,xx}$ 。

输出: $\hat{\mathbf{x}}_{k|k}^i$ 、 $\hat{\mathbf{P}}_{k|k}^{i,xx}$ 、 $\mathbf{Q}_k^i \leftarrow \mathbf{Q}_{k-1}^i$ 和 $\mathbf{R}_{k+1}^i \leftarrow \mathbf{R}_k^i$, $k = k + 1$ 。

4 实验结果与分析

为了验证基于 ACUKF 的目标跟踪算法的性能, 本文将从两个方面对提出的算法进行验证: 第一是噪声环境未知的情况下; 第二是实际噪声环境在跟踪过程中发生突变。实验的对比算法分别为基于一致性分布式 UKF (DUKF)^[24] 的跟踪

算法,基于容积信息滤波(Cubature Information Filter,CIF)^[25]的跟踪算法。

4.1 仿真实验建立

如图 1 所示,在一个 100×100 m 的 2 维区域内均匀分布 N=49 个图像传感器节点,每个节点的感知范围为半径 R_s=20 m 的圆形区域。为保证所有感知到同一目标的节点之间能够通信,节

点的通信距离 D_c=2R_s=40 m,则 Δ_{max}=21。状态向量 $\mathbf{x}_k = [x(k), v_x(k), y(k), v_y(k)]^T$ 包括了位置向量 $\mathbf{c}_k = [x(k), y(k)]^T$ 和速度向量 $\mathbf{j}_k = [v_x(k), v_y(k)]^T$,节点 s_i 的位置坐标为 $\mathbf{p}_i = [o_x^i, o_y^i]^T$ 。系统的运动模型和各节点的测量模型如式(30)所示:

$$\begin{cases} \mathbf{x}_k = f(\mathbf{x}_{k-1}) + \mathbf{w}_{k-1} = \mathbf{A} \mathbf{x}_{k-1} + \mathbf{w}_{k-1} \\ \mathbf{z}_{k,i} = h_i(\mathbf{x}_k) + \mathbf{v}_{k,i} = \begin{bmatrix} H_{11}^i x(k) + H_{12}^i y(k) + H_{13}^i \\ H_{31}^i x(k) + H_{32}^i y(k) + H_{33}^i \\ H_{21}^i x(k) + H_{22}^i y(k) + H_{23}^i \\ H_{31}^i x(k) + H_{32}^i y(k) + H_{33}^i \end{bmatrix} + \mathbf{v}_{k,i}, \end{cases} \quad (30)$$

其中: \mathbf{A} 是目标 $\hat{\mathbf{A}}$ 运动的状态转移矩阵, H₁₁ⁱ,..., H₃₃ⁱ是图像传感器节点 s_i 的单应性矩阵 \mathbf{H}^i 中的元素。为了简化问题,本文中假设每一个图像传感器均被标定过且其单应性矩阵都相同,采用 APIDIS 数据集^[26]中图像传感器 C₆的单应性矩阵值:

$$\mathbf{H}^i = \begin{bmatrix} 1 & 930.893 & 9 & -89.803 & 3 & -2,393,800 \\ 117.253 & 0 & 91.812 & 1 & 1,022,700 \\ 0.348 & 5 & -0.872 & 0 & 1 & 971.886 & 2 \end{bmatrix}.$$

跟踪的采样周期 Δ=0.1 s,一次跟踪的采样时刻 K=100。由于节点的测量值向量的自由度为 2,为了保证系统故障检测可靠性为 50%,则 χ_{0.5}²值被设置为 1.39。根均方误差(Root Mean-Squared Error, RMSE)及其均值 ARMSE^[27]被用作表征跟踪准确率大小。实验结果均为经过

1 000次蒙特卡洛运行之后所得。仿真实验所需的其他参数被设置如表 2 所示。

表 2 中 \mathbf{Q}° 和 \mathbf{R}° 分别是系统的实际过程和测量噪声协方差矩阵。

表 2 本文重要仿真参数设置
Tab. 2 Parameter settings in simulation of paper

$$\mathbf{Q}^\circ = 4 \times \begin{bmatrix} \Delta^3/3 & \Delta^2/2 & 0 & 0 \\ \Delta^2/2 & \Delta & 0 & 0 \\ 0 & 0 & \Delta^3/3 & \Delta^2/2 \\ 0 & 0 & \Delta^2/2 & \Delta \end{bmatrix} \quad \mathbf{A} = \begin{bmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\mathbf{R}^\circ = \text{diag}([5, 5]) \quad \hat{\mathbf{P}}_0 = \text{diag}([2, 3, 2, 3])$$

$$\omega = 0.7/\Delta_{\max} \quad \lambda_0 = \delta_0 = 0.2$$

表 3 基于 CIF 的目标跟踪算法的 ARMSE 值

Tab. 3 ARMSE results of CIF

ARMSE 值	$\mathbf{R}_1 = m \times \mathbf{R}^\circ$					
	m=0.01	m=0.1	m=1	m=10	m=100	
$\mathbf{Q}_0 = n \times \mathbf{Q}^\circ$	n=0.01	1.752 9	1.574 9	1.320 2	1.514 3	3.377 2
	n=0.1	3.411 2	1.816 6	1.415 3	1.452 0	3.080 6
	n=1	3.315 1	2.216 4	1.697 9	1.421 6	2.190 0
	n=10	4.895 1	3.738 0	2.149 6	2.654 9	1.518 0
	n=100	5.786 3	4.290 5	3.705 4	3.124 8	1.650 9

4.2 噪声未知环境下的跟踪

本小节实验所采用的目标运动轨迹如图 1 所

示,3 种分布式跟踪算法的初始先验噪声协方差矩阵 \mathbf{Q}_0 和 \mathbf{R}_1 分别从小到大被设置为不同的值,

来验证各算法在不同条件下的准确性和鲁棒性。设置规则为,将 \mathbf{Q}_0 和 \mathbf{R}_1 分别设置为实际噪声协方差乘以不同的尺度因子,尺度因子 m, n 分别从

0.01 变化到 100。表 3~表 5 分别总结了 3 种不同的分布式算法在不同初始先验噪声协方差下的 ARMSE 值。

表 4 基于 DUKF 的目标跟踪算法的 ARMSE 值

Tab. 4 ARMSE results of DUKF

ARMSE 值		$\mathbf{R}_1 = m \times \mathbf{R}^0$				
		$m=0.01$	$m=0.1$	$m=1$	$m=10$	$m=100$
$\mathbf{Q}_0 = n \times \mathbf{Q}^0$	$n=0.01$	1.753 4	1.575 1	1.319 9	1.513 4	3.373 0
	$n=0.1$	3.408 8	1.819 1	1.415 5	1.451 2	3.076 2
	$n=1$	3.319 9	2.230 7	1.700 7	1.421 6	2.186 8
	$n=10$	4.941 2	2.796 4	2.164 4	2.657 8	1.518 6
	$n=100$	5.969 0	4.477 2	3.564 2	3.139 6	1.655 6

表 5 基于 ACUKF 的目标跟踪算法的 ARMSE 值

Tab. 5 ARMSE results of ACUKF

ARMSE 值		$\mathbf{R}_1 = m \times \mathbf{R}^0$				
		$m=0.01$	$m=0.1$	$m=1$	$m=10$	$m=100$
$\mathbf{Q}_0 = n \times \mathbf{Q}^0$	$n=0.01$	1.842 0	1.564 4	1.389 6	1.521 8	2.369 5
	$n=0.1$	1.716 0	2.177 9	1.807 7	1.447 9	2.074 0
	$n=1$	1.519 5	2.181 6	1.946 8	1.365 8	2.086 7
	$n=10$	2.044 4	2.077 7	2.149 6	2.783 7	1.520 4
	$n=100$	2.897 2	2.623 7	2.424 9	2.143 5	1.757 3

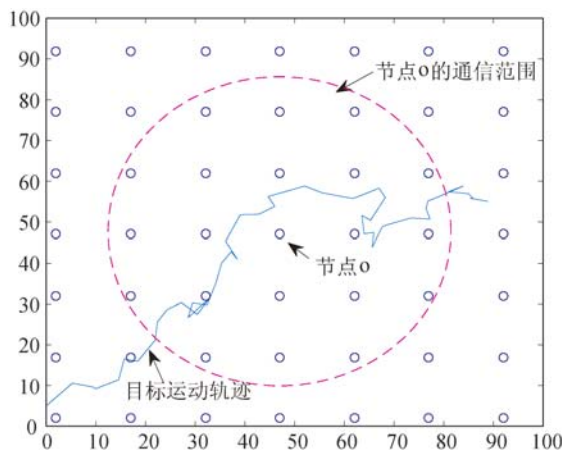


图 1 节点分布和目标运动示意图

Fig. 1 Sensor distribution and network connectivity

比较上述 3 个表格可以看出在 3 种不同的算法中基于 ACUKF 算法的分布式跟踪算法在准

确性和鲁棒性上表现的最好。具体来说,从表 3 和表 4 可以看出,对于传统的分布式跟踪算法在 \mathbf{Q}_0 和 \mathbf{R}_1 与实际系统值相比过大或者过小时,跟踪误差都会较大。特别地,对比 3 个表格的左下方会发现,在基于 CIF 和 DUKF 的分布式算法的 ARMSE 值较大时,基于 ACUKF 的分布式跟踪算法对于跟踪误差的改进更加的明显(相比于 CIF,ARMSE 值最大减少了 49.93%,相比于 DUKF,ARMSE 值最大减少了 51.46%)。这说明对于先验噪声协方差与系统实际值不匹配时,传统的分布式跟踪算法效果较差,而基于 ACUKF 的分布式跟踪算法通过调增先验噪声协方差的值,能够明显改善跟踪结果。需要指出的是,当 $\mathbf{Q}_0 : \mathbf{R}_1 = \mathbf{Q}^0 : \mathbf{R}^0$ 时,基于 CIF 和 DUKF 的跟踪算法的 ARMSE 值要稍小于基于 ACUKF 的跟踪算法。这是因为,ACUKF 算法

在先验噪声值和实际值相匹配时,也可能自适应地调整了先验噪声协方差的值,且该值为通过近似操作获得的估计值与实际值会有误差。但在实际的应用中 $\mathbf{Q}^{\circ} : \mathbf{R}^{\circ}$ 是不可能获得的,设置的 $\mathbf{Q}_0 : \mathbf{R}_1$ 值不可能正好与实际值的比值相同。所以提出的基于 ACUKF 的分布式跟踪算法能够系统的估计噪声协方差的值,使其与实际值相匹配,进而能够获得一个更加准确和稳定的跟踪结果。

4.3 动态过程噪声环境下的跟踪

假设机动目标在移动过程中由于外界或者自身的原因,其运动状态会突然发生较大变化,即过程噪声协方差发生突变,具体用数学表达可以描述为:

$$\begin{cases} \mathbf{Q}_k^{(v)} = \mathbf{Q}^{\circ}, k = 1, \dots, 20 \\ \mathbf{Q}_k^{(v)} = 100 \times \mathbf{Q}^{\circ}, k = 21, \dots, K. \end{cases} \quad (31)$$

在时刻 20 时,目标运动状态发生突变,目标实际过程噪声协方差矩阵 $\mathbf{Q}_k^{(v)}$ 变为原来的 100 倍。需要指出的是,由于只是目标运动状态发生变化,所以测量噪声协方差矩阵 $\mathbf{R}_1 = \mathbf{R}^{\circ}$,同时各节点的 $\sigma = 0$ 。其他参数设置同上小节。

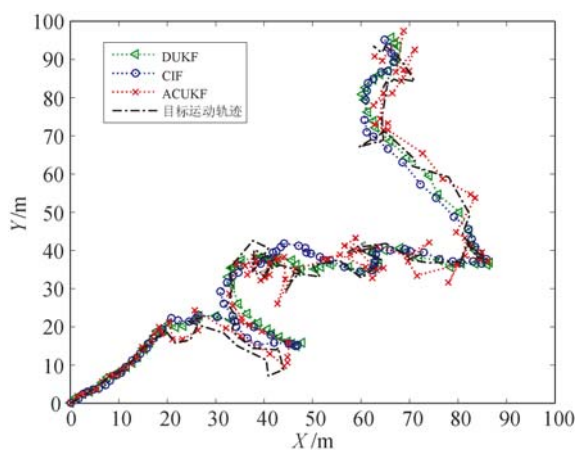


图 3 过程噪声变化前后基于不同分布式算法的跟踪结果

Fig. 3 Tracking results of different distributed algorithms before and after abrupt change of $\mathbf{Q}_k^{(v)}$

图 3 给出了过程噪声变化前后不同分布式算法的跟踪结果。从该图中可以看出,在采样时刻 20 之前,目标运动的过程噪声较小且与算法设置的先验过程噪声协方差相匹配,各种分布式跟踪算法都能较好的跟踪目标的运动状态。在时刻

20 时目标的运动状态突然发生了较大的变化,实际过程噪声协方差矩阵变为原来的 100 倍,则各算法设置的先验过程噪声协方差矩阵与实际值并不匹配,各算法的跟踪结果均变差。从图 4 给出的 RMSE 结果同样验证了上述描述。但是对于基于 ACUKF 的跟踪算法来说,相对于另外两种分布式跟踪算法,它在目标过程噪声协方差发生突变后仍能较好的跟踪目标。具体来说,在目标的实际过程噪声发生变化后,由于当前的先验噪声与实际值不相匹配,导致 RMSE 值均出现增大。但是由于基于 ACUKF 的跟踪算法在检测到系统出现问题时能够根据实际测量信息去自适应的更新其先验噪声协方差矩阵,所以其 RMSE 值在时刻 20 之后经历短暂升高后逐渐下降。这是因为其先验噪声协方差矩阵在经过数次不断的更新后接近了实际值,所以跟踪误差下降,跟踪精度也提高了。对于基于 DUKF 和 CIF 的分布式跟踪算法,其先验噪声协方差值是固定的,不能提供足够的动力使目标状态预测值发生变化使其更接近真实值,所以他们的跟踪结果在时刻 20 以后变得很差。




图 4 过程噪声变化前后不同分布式算法的 RMSE 对比图

Fig. 4 Comparison of RMSE results of different distributed algorithms before and after abrupt change of $\mathbf{Q}_k^{(v)}$

表 6 时刻 20 前后平均根方误差 (ARMSE)

Tab. 6 ARMSE results before and after timestep 20

ARMSE 值	CIF	DUKF	ACUKF
采样时刻 1~19	1.600 2	1.570 9	1.713 1
采样时刻 20~100	4.830 2	4.781 1	2.865 7

表 6 给出了采样时刻 20 前后 3 种不同算法的平均根方误差值对比。从该表中我们可以看出,在采样时刻 20 之前,3 种不同分布式跟踪算法的跟踪误差几乎相同,由于 ACUKF 可能会改变先验噪声协方差值,所以此时误差值稍大于另外两种分布式算法。在采样时刻 20 以后,3 种算法的平均根方误差都变大,但是基于 ACUKF 的跟踪算法误差值最小,相对于基于 CIF 和 DUKF 的跟踪算法分别减小了 40.67% 和 40.06%。从上面的结果中可以看出,基于 ACUKF 的分布式跟踪算法具有较好的鲁棒性和准确性,能够有效的应对目标运动状况发生较大幅度突变的情况。

5 结 论

本文在基于传统滤波的分布式跟踪算法的基础上,将噪声协方差的自适应更新与一致性估计方法结合起来,得到一个更加鲁棒的目标跟踪方

法。该方法能够利用错误检测机制决定是否需要更新先验噪声协方差。如果需要,则通过当前时刻获得的新息向量与残差向量分别估计当前时刻的系统过程与测量噪声协方差值。然后将该值与先前时刻的噪声协方差结合起来获得一个更新的先验噪声协方差值,使其更加接近当前系统的真实值。为了验证提出方法的效果,实验通过在两种不同的情况下与传统分布式跟踪方法作对比。结果表明,在噪声未知环境下,当先验噪声协方差与实际值不匹配的情况时,基于 ACUKF 的分布式跟踪方法相比于基于 CIF 和基于 DUKF 的跟踪方法,跟踪误差值分别最大减少了 49.93% 和 51.46%。在目标过程噪声发生动态变化的情况下,基于 ACUKF 的分布式跟踪方法相比于基于 CIF 和基于 DUKF 的跟踪方法,跟踪误差值分别最大减少了 40.67% 和 40.06%。上述实验结果表明,提出的基于 ACUKF 的分布式跟踪方法在应对不确定性噪声环境下的目标跟踪具有较好的鲁棒性。

参考文献:

- [1] 王秀友,范建中,刘华明,等. 自适应交互式融合的视觉跟踪[J]. 光学精密工程,2017,25(9):2499-2507.
WANG X Y, FAN J Z, LIU H M, XU D Q. Compound control of photoelectric tracking by using adaptive Kalman filtering algorithm[J]. *Opt. Precision Eng.*, 2017, 25(9): 2499-2507. (in Chinese)
- [2] 杨德东,毛宁,杨福才,等. 利用最佳伙伴相似性的改进空间正则化判别相关滤波目标跟踪[J]. 光学精密工程,2018,26(2):492-502.
YANG D D, MAO N, YANG F C, et al. Improved SRDCF object tracking via the Best-Buddies Similarity[J]. *Opt. Precision Eng.*, 2018, 26(2): 492-502. (in Chinese)
- [3] KAMAL A T, BAPPY J, FARRELL J, et al.. Distributed multi-target tracking and data association in vision networks. [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, 38(7):1397-1410.
- [4] ZHANG H, ZHOU X, WANG Z, et al. Adaptive consensus-based distributed target tracking with dynamic cluster in sensor networks[J]. *IEEE Transactions on Cybernetics*, 2018,99:1-12.
- [5] ZHENG B, FU P, LI B, et al.. A robust adaptive unscented kalman filter for nonlinear estimation with uncertain noise covariance[J]. *Sensors*, 2018, 18(3):808-822.
- [6] JULIER S J, UHLMANN J K. Unscented filtering and nonlinear estimation [J]. *Proceedings of the IEEE*, 2004, 92(3):401-422.
- [7] LEE D J. Nonlinear estimation and multiple sensor fusion using unscented information filtering [J]. *IEEE Signal Processing Letters*, 2008, 15:861-864.
- [8] ARDESHIRI T, ÖZKAN E, ORGUNER U, et al. Approximate bayesian smoothing with unknown process and measurement noise covariances [J]. *IEEE Signal Processing Letters*, 2015, 22(12): 2450-2454.
- [9] 田俊林,胡晓阳,游安清. 利用自适应卡尔曼滤波实现光电跟踪中的复合控制[J]. 光学精密工程, 2017, 25(7): 1941-1947.
TIAN J L, HU X Y, YOU A Q. Compound control of photoelectric tracking by using adaptive Kalman filtering algorithm[J]. *Opt. Precision Eng.*, 2017, 25(7):1941-1947. (in Chinese)
- [10] GAO S, HU G, ZHONG Y. Windowing and random weighting - based adaptive unscented Kalman filter[J]. *International Journal of Adaptive Control & Signal Processing*, 2015, 29(2):201-223.

- [11] LI W, SUN S, JIA Y, *et al.*. Robust unscented Kalman filter with adaptation of process and measurement noise covariances [J]. *Digital Signal Processing*, 2016, 48(C):93-103.
- [12] BAR-SHALOM Y, DAUM F, HUANG J. The probabilistic data association filter[J]. *IEEE Control Systems*, 2009, 29(6):82-100.
- [13] FU P, TANG H, CHENG Y, *et al.*. An energy-balanced multi-sensor scheduling scheme for collaborative target tracking in wireless sensor networks[J]. *International Journal of Distributed Sensor Networks*, 2017, 13(3):155014771769896.
- [14] YU Y. Consensus-based distributed linear filter for target tracking with uncertain noise statistics [J]. *IEEE Sensors Journal*, 2017, 17(15):4875-4885.
- [15] CHEN Y, ZHAO Q, AN Z, *et al.* Distributed multi-target tracking based on the K-MTSCF algorithm in camera networks [J]. *IEEE Sensors Journal*, 2016, 16(13):5481-5490.
- [16] JIA B, PHAM K D, BLASCH E, *et al.*. Information weighted consensus-based cooperative space object tracking to overcome malfunctioned sensors and noisy links[C]. *International Conference on Information Fusion*. IEEE, 2015:1286-1292.
- [17] XIAO L, BOYD S, LALL S. A scheme for robust distributed sensor fusion based on average consensus[C]. *International Symposium on Information Processing in Sensor Networks*. IEEE, 2005:9.
- [18] KATRAGADDA S, SANMIGUEL J C, CAVALLARO A. Consensus protocols for distributed tracking in wireless camera networks[C]. *International Conference on Information Fusion*. IEEE, 2014:1-8.
- [19] OLFATI-SABER R. Distributed Kalman filter with embedded consensus filters[C]. *Decision and Control, 2005 and 2005 European Control Conference. Cdc-Ecc '05. IEEE Conference on*. IEEE, 2006:8179-8184.
- [20] LI W, JIA Y. Consensus-based distributed multiple model UKF for jump markov nonlinear systems [J]. *IEEE Transactions on Automatic Control*, 2012, 57(1):227-233.
- [21] HAJIYEV C, SOKEN H E. Robust adaptive unscented Kalman filter for attitude estimation of pico satellites [J]. *International Journal of Adaptive Control & Signal Processing*, 2014, 28(2):107-120.
- [22] GAO S, HU G, ZHONG Y. Windowing and random weighting - based adaptive unscented Kalman filter[J]. *International Journal of Adaptive Control & Signal Processing*, 2015, 29(2):201-223.
- [23] ZHOU J, STEFAN K, OTMAR L. INS/GPS tightly-coupled integration using adaptive unscented particle filter[J]. *Journal of Navigation*, 2010, 63(3):491-511.
- [24] LI W, WEIG, HAN F, *et al.*. Weighted average consensus-based unscented Kalman filtering [J]. *IEEE Transactions on Cybernetics*, 2015, 46(2):558-567.
- [25] CHANDRA K P B, GU D W, POSTLETHWAITE I. Square root cubature information filter[J]. *IEEE Sensors Journal*, 2013, 13(2):750-758.
- [26] CHEN F, DELANNAY D, DE V C. An autonomous framework to produce and distribute personalized team-sport video summaries: a basketball case study[J]. *IEEE Transactions on Multimedia*, 2011, 13(6):1381-1394.
- [27] FU P, CHENG Y, TANG H, *et al.*. An effective and robust decentralized target tracking scheme in wireless camera sensor networks [J]. *Sensors*, 2017, 17(3):639-652.

作者简介:



郑斌琪(1978—),男,浙江宁波人,博士研究生,2001年、2004年于中国科学技术大学分别获得学士、硕士学位。主要从事特种无线传感器网络、传感器信息融合技术研究。Email: bqzheng@mail.sim.ac.cn



袁晓兵(1969—),男,吉林长春人,博士生导师,研究员,1991年于浙江大学获得学士学位,1997年、2000年分别于中国科学院长春光学精密机械与物理研究所获得硕士、博士学位。主要从事无线传感器网络、物联网相关应用技术研究。Email: sinowsn@mail.sim.ac.cn