

面向空间定位系统的分布式融合估计*

刘莉^{1,2}, 杨傲雷¹, 屠晓伟¹, 费敏锐¹, 周文举²

(1. 上海大学机电工程与自动化学院 上海市电站自动化技术重点实验室 上海 200072;
2. 鲁东大学信息与电气工程学院 烟台 264025)

摘要:针对网络化高精度测量定位中的测量规模大、通信约束复杂以及处理信号协同困难等问题,基于线性 CCD 的空间定位原理,研究带有交叉相关噪声和传输时滞的不确定网络化系统的信息融合估计问题。提出了一种基于 Kalman 滤波的分布式感知和集中式融合的估计方法,应用测量转换策略,采用两层加权融合理论,设计了最优加权融合估计方法。减轻了处理传输延迟的通信负担和计算复杂度,提高了抵抗噪声干扰的鲁棒性能,进而减少信息冗余,并保持较高的测量精度。实验部分验证了该方法的有效性。

关键词: 分布式融合估计;鲁棒卡尔曼滤波;交叉相关噪声;传输延时;空间定位

中图分类号: TP274+.2 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.40

Distributed fusion estimation for spatial localization system

Liu Li^{1,2}, Yang Aoilei¹, Tu Xiaowei¹, Fei Minrui¹, Zhou Wenju²

(1. Shanghai Key Laboratory of Power Station Automation Technology, School of Mechatronics Engineering and Automation, Shanghai 200072, China; 2. School of Information Science and Engineering, Ludong University, Yantai 264025, China)

Abstract: In the networked high precision measurement and localization, the requirements of growing measurement scale, enlarging communication constraints and increasing signal coordination processing bring great challenges in this domain. Based on the spatial localization principle, the information fusion estimation is investigated for uncertain networked systems with cross-correlated noises and data transmission delays. A distributed fusion estimation scheme is proposed by distributed perception and centralized fusion based on Kalman filtering. The scheme designs an optimal weighted fusion estimator employing the measurement transformation and the two-stage weighted fusion approaches. As a result, the communication burden and computational cost with network-induced transmission delays can be alleviated, and the noisy disturbances can be decomposed, and robustness can be improved. Moreover, information redundancy can be reduce and the higher measurement accuracy can be maintained. An illustrative example is given to validate the effectiveness of the proposed method.

Keywords: distributed fusion estimation; robust Kalman filtering; cross-correlated noises; transmission delays; spatial localization

1 引言

近几十年来,为解决高精度测量定位问题,相关的空间测量定位系统与测量方法得到了迅速的发展。随着网络规模的日益增大,测量定位系统所覆盖的空间范围越来越大,而且覆盖方式越来越灵活。考虑到其通信任务日渐复杂,每个节点的能量和计算能力十分有限,采用所有节

点分担信号处理工作量,协作完成信号处理和通信任务的配置结构,使得网络性能不随网络规模的增大而衰减。因此,采用分布式的网络化结构,不仅增加了信息的可靠性,提高了协同计算精度,而且减少了通信负担^[1]。大规模网络化系统已成功地应用在如网络物理系统(cyber-physical systems, CPSs)、智能电网、智能交通等领域。

应用于目标跟踪和定位,以及故障诊断等领域的分布式估计策略^[2-4],目的是融合后的状态估计精度高于每个局部的状态估计值。滤波是研究信息感知和融合的基

础,根据不同的性能指标,相关的分布式滤波引起了越来越多的关注,包括分布式粒子滤波^[5]、分布式 H_∞ 滤波^[1, 6-7]、分布式 Kalman 滤波^[2-3, 8-9]等。其中,分布式 Kalman 滤波用于实现误差估计过程的协同和融合,是解决大规模系统状态估计的重要方案^[2]。

网络化系统由于受到通信设施和规模的制约,其测量信息不可避免地受到不可测干扰的影响。应用基础的 Kalman 滤波方法不能满足估计性能的要求,因此,考虑到各种噪声序列,设计了鲁棒 Kalman 滤波方法。系统参数的不确定性可以用状态依赖噪声^[10-11]来描述。文献^[12]提出基于迭代学习控制和 Kalman 滤波相结合的相机控制方法,降低噪声干扰,控制相机精确抓取高速运动目标的图像;Costa O 等人^[13]针对带有状态相关噪声的离散时间马尔可夫跳变系统研究了鲁棒的模式独立滤波。考虑到噪声的相关性;文献^[8, 14]研究了测量噪声和过程噪声之间带有交叉相关性的分布式 Kalman 滤波融合方法。此外,针对一类具有不确定方差的噪声序列,文献^[15-17]对其真实的滤波误差协方差采用对所有可容许的不确定性求解最小上界的方法。对于荷电状态 (state of charge, SOC) 估计问题,采用噪声方差可变的 Kalman 滤波方法^[18],在迭代过程中估计并设定最适当当前系统状态的噪声方差,提高估计精度。

在网络通信过程中由于传输延迟的存在,接收到的信息可能是异步的。为了减轻传输延迟对测量值的影响,提出了如利用多项式的参数依赖^[19]、测量转换^[17]等方法。其中测量转换方法采用重组新息序列的 Kalman 滤波处理多个时滞系统,将带有延时的系统转化成相关的无时滞的系统,降低了计算复杂度。

根据以上的分析,本文基于线性电荷耦合器件 (charge-coupled device, CCD) 的空间定位原理,由 3D 光电传感器测量得到的信息在通信过程中,考虑信息受到传输延时、交叉相关噪声等不确定因素影响,着重于提高系统的状态估计精度。为了提高估计器的鲁棒性能,加权融合的新息序列用于在信息交换过程中优化交叉相关性噪声的干扰。通过重组测量序列和新息序列的测量转换方法,使 Kalman 滤波转化成为 Kalman 预测,以减少计算复杂度。提出加权融合的滤波误差互协方差方法,用于两个子系统之间信息的协同和交换。因此,分布式的融合估计基于最优信息融合准则,是对局部估计值的再次优化,能够得到比局部值更高的估计精度。

2 空间定位系统模型

面向 3D 光电传感定位系统,基于空间定位原理,本节设计了光电传感器。由传感器测量得到的信息在传输过程中,考虑系统的不确定性、噪声相关性和传输延迟,建立系统模型。

2.1 空间定位原理

首先,引入 Metris Krypton 测量技术,基于三坐标定位测量方法,使用光学跟踪器再配以特殊的发光二极管 (light emission device, LED) 来取得各测量点的三维空间位置。K-DMM 产品 (K 系列的动态测量仪) 的外形如图 1 所示,其中被测目标是由特殊 LED 制作成的,它的三维坐标根据光学跟踪器上的 3 组 CCD 镜头来读取。特殊 LED 的摆放位置可任意移动,并可以置于任何活动部件上。通过光学跟踪器去追踪 LED 的位置,再计算某个 LED 在某一时间间隔内的位置变化及移动方向。

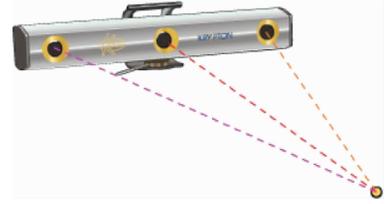


图 1 光学动态测量仪器

Fig. 1 Dynamic measurement instrument

所设计的 3D 光电传感器如图 2 所示,由 3 个线性 CCD 分别嵌入 3 个定焦距柱形光学镜组成,且 3 个 CCD 在同一平面上呈“Y”字形分布。

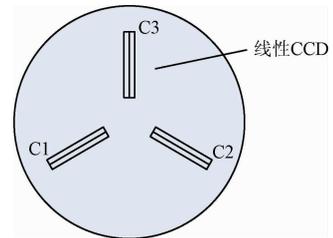


图 2 3D 光电传感器

Fig. 2 3D photoelectric sensor

3D 光电传感定位的原理如图 3 所示。被测目标即特殊 LED 与每个柱形光学镜通过的光只投影到它对应平面下的 CCD,空间的一个点光源通过柱形光学镜投影到每个 CCD 平面上是一条与 CCD 垂直相交的直线光,交与 CCD 上能够感知其在 CCD 上的位置信息。若该被测目标在 3D 光电传感器的测量范围内,则被测目标会与 3 个 CCD 镜头形成 3 个平面,计算 3 个平面的交点,即为该空间点光源的坐标 (X, Y, Z) 。

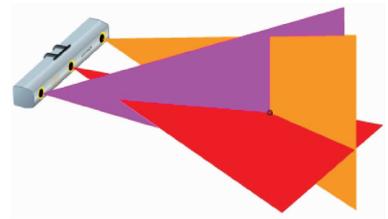


图 3 定位原理

Fig. 3 Locating principle

2.2 系统模型的建立

由3D光电传感器测量得到的信息在网络通信过程中受到不确定因素的干扰。经过分析,用于传感器网络的分布式不确定性系统可以描述为:

$$\mathbf{x}_{k+1} = (\mathbf{A}_k + \Delta\mathbf{A}_k)\mathbf{x}_k + \mathbf{B}_k\mathbf{w}_k \quad k = 1, 2, \dots \quad (1)$$

$$\mathbf{z}_k^i = \mathbf{H}_k^i\mathbf{x}_{k-\tau_k} + \boldsymbol{\omega}_k^i \quad i = 1, \dots, n \quad (2)$$

式中: $\mathbf{A}_k \in \mathbb{R}^{r \times r}$ 表示状态转移矩阵, $\mathbf{B}_k \in \mathbb{R}^r$ 是已知维度的时变向量, $\mathbf{w}_k \in \mathbb{R}$ 代表方差为 \mathbf{Q}_k 的过程噪声。状态依赖矩阵 $\Delta\mathbf{A}_k = \mathbf{C}_k\boldsymbol{\xi}_k$ 用于表达系统内部的不确定性^[8], $\mathbf{C}_k \in \mathbb{R}^{r \times r}$ 是状态转移矩阵,且状态依赖噪声 $\boldsymbol{\xi}_k \in \mathbb{R}$ 是独立的零均值白噪声。 $\mathbf{z}_k^i \in \mathbb{R}^m$ 表示 k 时刻第 i 个传感器的测量值,且 $\tau_k > 0$ 代表传输延迟, $\mathbf{H}_k^i \in \mathbb{R}^{m \times r}$ 是测量矩阵, $\boldsymbol{\omega}_k^i \in \mathbb{R}^m$ 代表第 i 个传感器的方差为 \mathbf{R}_k^i 的测量噪声。初始状态 \mathbf{x}_0 和其他噪声信号不相关,设均值为 $\boldsymbol{\mu}_0$ 、协方差为 \mathbf{P}_0 。

考虑传输延迟的影响,前一个采样时刻的噪声对当前的测量值更重要。因此,假设子系统的过程噪声和测量噪声,以及不同传感器的测量噪声是一步相关的,具有如下统计属性:

$$E(\mathbf{w}_k) = 0, E(\boldsymbol{\omega}_k^i) = 0,$$

$$E\left(\begin{pmatrix} \mathbf{w}_k \\ \boldsymbol{\omega}_k^i \end{pmatrix} \begin{pmatrix} \mathbf{w}_l^T \\ (\boldsymbol{\omega}_l^i)^T \end{pmatrix}\right) =$$

$$\begin{pmatrix} \mathbf{Q}_k\delta_{k-l} + \mathbf{Q}_{k,l}\delta_{k-l+1} & \mathbf{S}_k^i\delta_{k-l} + \mathbf{S}_{k,l}^i\delta_{k-l+1} \\ \mathbf{0} & \mathbf{R}_k^i\delta_{k-l} + \mathbf{R}_{k,l}^i\delta_{k-l+1} \end{pmatrix} \quad (3)$$

式中: δ_{k-l} 是克罗内克(Kronecker)函数,且 $\mathbf{Q}_k = \mathbf{Q}_k^T$ 和 $\mathbf{R}_k^i = (\mathbf{R}_k^i)^T$ 。

网络化系统的分布式信息融合方法,需要探测状态的最优估计值 $\hat{\mathbf{x}}_{klk}^i$,即合适的滤波参数 \mathbf{K}_k^i ,以实现提高空间定位精度的目的。

3 分布式融合估计

本节基于Kalman滤波理论,提出了加权融合重组新息序列和加权融合误差互协方差矩阵的分布式加权融合估计方法。

3.1 新息序列重组

局部稳态最优Kalman滤波器 $\hat{\mathbf{x}}_{klk}^{i,z_k}$ 是由第 i 个子系统的测量输出 \mathbf{z}_k^i 设计的。为了减轻计算负担^[17],带有 τ_k 一步延迟的测量重组为等价的无延迟的测量 $\mathbf{z}_{k+\tau_k}^i$ 及新的测量噪声 \mathbf{v}_k^i ,且满足:

$$\mathbf{y}_k^i = \mathbf{H}_k^i\mathbf{x}_k + \mathbf{v}_k^i \quad i = 1, 2, \dots, n; \quad k = 1, 2, \dots \quad (4)$$

式中: $\mathbf{y}_k^i \triangleq \mathbf{z}_{k+\tau_k}^i$, $\mathbf{H}_k^i \triangleq \mathbf{H}_{k+\tau_k}^i$, 且 $\mathbf{v}_k^i = \boldsymbol{\omega}_{k+\tau_k}^i$ 。注意 \mathbf{v}_k^i 也是白噪声,且统计属性如式(3)所示。

3.1.1 重组测量序列

重组的测量序列由 $\{\{\mathbf{y}_s^i\}_{s=0}^{k-\tau_k}\}$ 和 $\{\{\mathbf{y}_s^i\}_{s=k-\tau_k+1}^k\}$ 定义,并且 $\hat{\mathbf{x}}_{klk}^i$ 等价于预测值 $\hat{\mathbf{x}}_{klk-\tau_k}^i$ ($\hat{\mathbf{x}}_{klk}^{i,z_k} \triangleq \hat{\mathbf{x}}_{klk-\tau_k}^i$),即状态 \mathbf{x}_k 转化成在线性张成空间 $L\{\mathbf{y}_{k-\tau_k}^i, \mathbf{y}_{k-\tau_k-1}^i, \dots, \mathbf{y}_0^i\}$ 的投影。

其误差分别表示成:

$$\tilde{\mathbf{x}}_{klk}^{i,z_k} = \mathbf{x}_k - \hat{\mathbf{x}}_{klk}^{i,z_k} \quad (5)$$

$$\tilde{\mathbf{x}}_{klk-\tau_k}^i = \mathbf{x}_k - \hat{\mathbf{x}}_{klk-\tau_k}^i \quad (6)$$

相应的基于局部稳态的滤波误差协方差和互协方差用于任意两个子系统间信息交互,可以表示成如下形式:

$$\mathbf{P}_{\tau_k, \tau_k}^{i,z_k} = \mathbf{P}_{\tau_k, \tau_k}^i = E(\tilde{\mathbf{x}}_{klk-\tau_k}^i (\tilde{\mathbf{x}}_{klk-\tau_k}^i)^T) = E(\tilde{\mathbf{x}}_{k+\tau_k, k}^i (\tilde{\mathbf{x}}_{k+\tau_k, k}^i)^T) \quad (7)$$

$$\mathbf{P}_{\tau_k, \tau_k}^{i,j,z_k} = \mathbf{P}_{\tau_k, \tau_k}^{i,j} = E(\tilde{\mathbf{x}}_{klk-\tau_k}^i (\tilde{\mathbf{x}}_{klk-\tau_k}^j)^T) = E(\tilde{\mathbf{x}}_{k+\tau_k, k}^i (\tilde{\mathbf{x}}_{k+\tau_k, k}^j)^T) \quad (8)$$

注意,传输延迟一般包括一步(即 $\tau_k = 1$)和多步(即 $\tau_k \geq 2$)。当 $\tau_k = 1$ 时,分布式Kalman滤波转化成一步预测^[20];当 $\tau_k \geq 2$ 时,采用测量补偿机制,可以将状态估计转化成为一步预测补偿的形式,因此,主要研究 $\tau_k = 1$ 的情况。

3.1.2 加权融合新息序列

根据重组的测量序列,新息序列 $\boldsymbol{\varepsilon}_k^{i,z_k} = \mathbf{z}_k^i - \hat{\mathbf{z}}_k^i$ 被重组为 $\boldsymbol{\varepsilon}_k^i = \mathbf{y}_k^i - \hat{\mathbf{y}}_k^i$ 的形式,其中 $\hat{\mathbf{y}}_k^i = \mathbf{H}_k^i\hat{\mathbf{x}}_{klk-1}^i$ 。引理1引入了加权融合重组新息序列策略。

引理1 对于分布式系统式(1)和(4),重组新息序列由 $\tilde{\mathbf{Y}}_k = (\boldsymbol{\varepsilon}_k^1, \dots, \boldsymbol{\varepsilon}_k^n)^T$ 组成,其加权的形式为:

$$\tilde{\mathbf{Y}}_k = \sum_{j=1}^n \theta_k^j \boldsymbol{\varepsilon}_k^j \quad (9)$$

式中: $\boldsymbol{\Theta}_k = (\theta_k^1, \dots, \theta_k^n)^T$ 是 $mn \times m$ -维矩阵,且满足 $\theta_k^1 + \theta_k^2 + \dots + \theta_k^n = I_m$, 设 $\mathbf{I} \triangleq \underbrace{(I_m, \dots, I_m)}_n^T$ 也是 $mn \times m$ -

维矩阵。由式(9),新息序列的方差 \mathbf{P}_k 定义为:

$$\mathbf{P}_k = E(\tilde{\mathbf{Y}}_k \tilde{\mathbf{Y}}_k^T) = \boldsymbol{\Theta}_k^T \boldsymbol{\Sigma}_k \boldsymbol{\Theta}_k \quad (10)$$

式中: $\boldsymbol{\Sigma}_k = (E(\boldsymbol{\varepsilon}_k^i (\boldsymbol{\varepsilon}_k^i)^T))_{mn \times mn}$, 且 $\boldsymbol{\Sigma}_k = \boldsymbol{\Sigma}_k^T$ 是对称正定阵,因此 $\mathbf{I}^T \boldsymbol{\Sigma}_k^{-1} \mathbf{I}$ 是非奇异的。依据文献[8]得到:

$$\boldsymbol{\Theta}_k = \boldsymbol{\Sigma}_k^{-1} (\mathbf{I}^T \boldsymbol{\Sigma}_k^{-1} \mathbf{I})^{-1} \quad (11)$$

因此,方差 $\mathbf{P}_k = (\mathbf{I}^T \boldsymbol{\Sigma}_k^{-1} \mathbf{I})^{-1}$ 。

针对 n 个子系统,测量值在传输过程中,采用加权融合新息序列适用于邻居之间的信息协同,同时降低了噪声对测量值的干扰。

3.2 分布式加权融合滤波

3.2.1 滤波参数

k 时刻第 i 个子系统,通过最小化一步预测误差协方差,可以探测合适的滤波参数 \mathbf{K}_k^i 。对于局部的一步预测值 $\hat{\mathbf{x}}_{k+1|k}^i$,其预测误差协方差 $\mathbf{P}_{k+1|k}^i$ 通过以下等式计算:

$$\begin{aligned} \mathbf{P}_{k+1|k}^i &= E(\tilde{\mathbf{x}}_{k+1|k}^i (\tilde{\mathbf{x}}_{k+1|k}^i)^T) = \\ &\boldsymbol{\Phi}_k^i \mathbf{P}_{klk-1}^i (\boldsymbol{\Phi}_k^i)^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T + \mathbf{K}_k^i \mathbf{R}_k^i (\mathbf{K}_k^i)^T + \mathbf{C}_k \mathbf{X}_k \mathbf{C}_k^T + \\ &\boldsymbol{\Phi}_k^i \mathbf{W}_k^i \mathbf{B}_k^T + \mathbf{B}_k (\mathbf{W}_k^i)^T (\boldsymbol{\Phi}_k^i)^T - \mathbf{B}_k \mathbf{S}_{k,k+1}^i (\mathbf{K}_k^i)^T - \\ &\mathbf{K}_k^i (\mathbf{V}_k^i)^T (\boldsymbol{\Phi}_k^i)^T - \boldsymbol{\Phi}_k^i \mathbf{V}_k^i (\mathbf{K}_k^i)^T - \mathbf{K}_k^i (\mathbf{S}_{k,k+1}^i)^T \mathbf{B}_k^T \end{aligned} \quad (12)$$

式中: \mathbf{P}_{klk-1}^i 为 $k-1$ 时刻的一步预测误差协方差。

由于局部估计:

$$\hat{\mathbf{x}}_{k+1|k}^i = \boldsymbol{\Phi}_k^i \hat{\mathbf{x}}_{klk-1}^i + \mathbf{K}_k^i \mathbf{y}_k^i \quad (13)$$

则期望值 \mathbf{X}_k 根据状态 \mathbf{x}_k 求解,因此 \mathbf{X}_{k+1} 由:

$$\mathbf{X}_{k+1} = \mathbf{A}_k \mathbf{X}_k \mathbf{A}_k^T + \mathbf{C}_k \mathbf{X}_k \mathbf{C}_k^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T +$$

$$A_k B_{k-1} Q_{k-1,k} B_k^T + B_k Q_{k,k-1} B_{k-1}^T A_k^T \quad (14)$$

推导得到,且初始值设为 $X_0 \triangleq \mu_0 \mu_0^T + P_0$ [8]。

另外, W_k^i 和 V_k^i 分别通过以下方式得到:

$$W_k^i = E(\tilde{x}_{klk-1}^i w_k^T) = B_{k-1} Q_{k-1,k} - K_{k-1}^i (S_k^i)^T \quad (15)$$

$$V_k^i = E(\tilde{x}_{klk-1}^i (v_k^i)^T) = B_{k-1} S_{k-1,k+1}^i - K_{k-1}^i R_{k-1,k}^i \quad (16)$$

由此,推导得到最优滤波增益矩阵 K_k^i ,即:

$$K_k^i = \Xi_k^i (H_k^i P_{klk-1}^i (H_k^i)^T + R_k^i + \tilde{\Xi}_k^i)^{-1} \quad (17)$$

式中: $\Xi_k^i = A_k P_{klk-1}^i (H_k^i)^T + B_k (W_k^i)^T (H_k^i)^T + A_k V_k^i + B_k S_{k,k+1}^i$, 且 $\tilde{\Xi}_k^i = H_k^i V_k^i + (V_k^i)^T (H_k^i)^T$ 。

把式(17)代入式(12),则 P_{k+1k}^i 可以重写为:

$$P_{k+1k}^i = A_k P_{klk-1}^i A_k^T + \Gamma_k^i - K_k^i (\Xi_k^i)^T \quad (18)$$

式中: $\Gamma_k^i = B_k Q_{k,k} B_k^T + C_k X_k C_k^T + A_k W_k^i B_k^T + B_k (W_k^i)^T A_k^T$ 。

基于以上,式(10)中的 Σ_k 可以计算得到:

$$\Sigma_k^{i,j} = H_k^i P_{klk-1}^{i,j} (H_k^j)^T + H_k^i V_k^{i,j} + (H_k^j V_k^{j,i})^T + R_k^{i,j} \quad (19)$$

式中: $\Sigma_k^{i,j}$ 是一个 $nm \times nm$ -维矩阵。

3.2.2 估计误差互协方差

加权融合策略采用预测误差互协方差方法,实现任意两个子系统间的信息交互,是最小化误差协方差的再优化。因此,基于 Kalman 一步预测 \hat{x}_{k+1k}^i 和滤波增益 K_k^i , 可得到 k 时刻第 i 和第 j 个子系统的预测误差互协方差:

$$\hat{x}_{k+1k}^i = A_k \hat{x}_{klk-1}^i + K_k^i \tilde{Y}_k \quad (20)$$

$$K_k^i = \Xi_k^i (H_k^i P_{klk-1}^i (H_k^i)^T + R_k^i + \tilde{\Xi}_k^i)^{-1} \quad (21)$$

$$P_{k+1k}^{i,j} = A_k P_{klk-1}^{i,j} A_k^T + B_k Q_{k,k} B_k^T + C_k X_k C_k^T + K_k^i P_k^j (K_k^j)^T + A_k W_k^i B_k^T + B_k (W_k^j)^T A_k^T - A_k M_k^i (K_k^j)^T - B_k L_k^T (K_k^j)^T - K_k^i (M_k^j)^T A_k^T - K_k^i L_k B_k^T \quad (22)$$

式中:

$$P_k = E(\tilde{Y}_k \tilde{Y}_k^T), W_k^i = B_{k-1} Q_{k-1,k} - K_{k-1}^i (S_k^i)^T, X_{k+1}^i = A_k X_k A_k^T + C_k X_k C_k^T + B_k Q_k B_k^T + A_k B_{k-1} Q_{k-1,k} B_{k-1}^T + B_k Q_{k,k-1} B_{k-1}^T A_k^T, M_k^i = \sum_{q=1}^n (P_{klk-1}^{i,q} (H_k^q)^T + V_k^{i,q}) \theta_k^q, L_k = \sum_{q=1}^n (\theta_k^q)^T (H_k^q W_k^q + (S_{k-1,k}^q)^T) \quad (23)$$

接下来,采用加权融合策略来融合交叉相关的协方差。设 $\hat{x}_{klk-1} = ((\hat{x}_{klk-1}^1)^T, \dots, (\hat{x}_{klk-1}^n)^T)^T$ 是 $r \times n$ -维随机向量 x_k 的无偏估计,且定义:

$$J = (I x_k - \hat{x}_{klk-1})^T \Sigma_{klk-1}^{-1} (I x_k - \hat{x}_{klk-1}) \quad (24)$$

式中: $I = (I_r, \dots, I_r)^T$ 是 $rn \times r$ -维矩阵,且矩阵 $\Sigma_{klk-1} =$

$$\begin{pmatrix} P_{klk-1}^{1,1} & \dots & P_{klk-1}^{1,n} \\ \vdots & \ddots & \vdots \\ P_{klk-1}^{n,1} & \dots & P_{klk-1}^{n,n} \end{pmatrix}$$

是 $nr \times nr$ -维对称正定矩阵。由于

最优 Kalman 滤波使用线性最小方差的加权融合方法 [14], 因此,相应的最优信息融合估计的协方差 P_{klk-1} 满足 $P_{klk-1} \leq P_{klk-1}^i, i = 1, 2, \dots, n$ 。

图4所示为分布式融合估计的结构和流程。分布式鲁棒 Kalman 一步预测方法的计算过程描述如下:

- 1) 采用式(17)的滤波增益 K_k^i , 代入式(13)求解 k 时刻的融合前的局部估计值 \hat{x}_{k+1k}^i ;
- 2) 式(9)中的加权融合重组新息序列 \tilde{Y}_k 用于传输过程中融合每个子系统和它的邻居之间的噪声信息;
- 3) 根据式(13)中得到的状态估计 \hat{x}_{k+1k}^i , 计算式(18)中的预测误差互协方差 P_{k+1k}^i 。
- 4) 融合中心用于计算最优的状态估计 \hat{x}_{k+1k} 和预测误差互协方差 P_{k+1k} , 分别从式(20)和(22)推导得到。

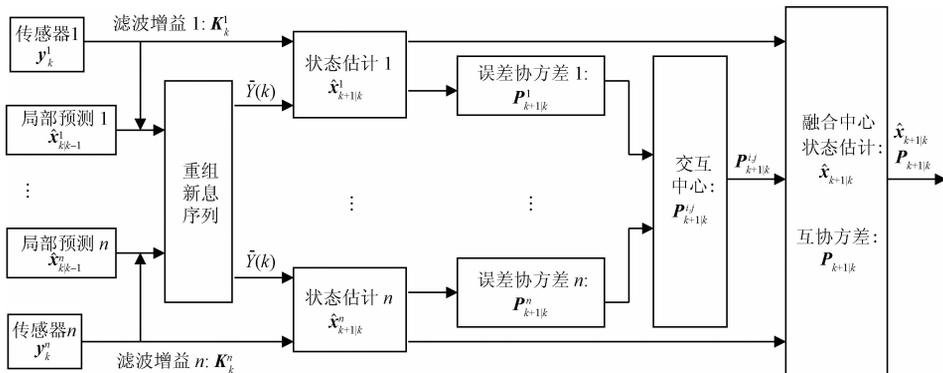


图4 分布式鲁棒 Kalman 一步预测融合方法

Fig.4 Distributed robust Kalman one-step predictor fusion

基于鲁棒 Kalman 滤波的分布式融合估计方法包含两层融合,需要计算 $nm \times nm$ 和 $nr \times nr$ -维矩阵。因此,该方法的计算复杂度是 $O((m^2 + r^2)n^3)$, 其中 r 表示状态的维度, m 表示测量维度, n 是子系统的数目。在

融合中心,对比上述的分布式融合和状态扩展方法,计算复杂度分别是 $O((nr)^3)$ 和 $O(((n+b)r)^3)$ 。因此,本文研究的分布式融合估计具有较少的计算复杂度。

4 实验结果及分析

为了验证方法的有效性和鲁棒性,设计了3D 光电传感定位测量平台,并为该平台申请了发明专利(申请号:201510167229.9)。本文涉及的内容与该专利是算法与平台的支撑关系,文中有关分布式融合估计算法的研究是对专利中设计的3D 光电传感定位系统的算法支撑。实验所采用的目标跟踪系统,其数学描述如下:

$$\mathbf{x}_{k+1} = \begin{pmatrix} 0.96 & T & T^2/2 \\ 0 & 0.96 & T \\ 0 & 0 & 0.96 \end{pmatrix} \mathbf{x}_k + \begin{pmatrix} T^2/2 \\ T \\ 1 \end{pmatrix} \mathbf{w}_k + \begin{pmatrix} 0.01 & 0 & 0 \\ 0 & 0.01 & 0 \\ 0 & 0 & 0.01 \end{pmatrix} \boldsymbol{\xi}_k \quad (25)$$

$$\mathbf{z}_k^i = \mathbf{H}_i^i \mathbf{x}_{k-\tau_k} + \boldsymbol{\omega}_k^i \quad i = 1, 2, 3, 4 \quad (26)$$

$$\mathbf{w}_k = \boldsymbol{\eta}_k + \boldsymbol{\eta}_{k-1} \quad (27)$$

$$\boldsymbol{\omega}_k^i = \boldsymbol{\beta}_i \mathbf{w}_{k-1} + \boldsymbol{\beta}_i \boldsymbol{\eta}_k \quad i = 1, 2, 3, 4 \quad (28)$$

式中: T 表示采样周期为 0.1 s 。状态 $\mathbf{x}_k = (s_k \ \dot{s}_k \ \ddot{s}_k)^T$ 分别表示目标在 kT 时刻的位置、速度和加速度。 $\boldsymbol{\xi}_k \in \mathbb{R}$ 表示均值为零方差为 $\sigma_{\boldsymbol{\xi}}^2 = 1$ 的状态依赖噪声。 $\boldsymbol{\eta}_k \in \mathbb{R}$ 是独立的方差为 $\sigma_{\boldsymbol{\eta}}^2 = 0.09$ 的白噪声。 \mathbf{z}_k^i 表示第 i 个传感器测得的带有时滞 $\tau_k = 1$ 的值。 $\mathbf{H}_1 = [1 \ 0.6 \ 0.8]$, $\mathbf{H}_2 = [0.8 \ 1 \ 0.5]$, $\mathbf{H}_3 = [0.8 \ 0.3 \ 1]$ 和 $\mathbf{H}_4 = [0.6 \ 0.5 \ 1]$ 。变量 $\boldsymbol{\beta}_i$ 用于确定噪声相关性的强度,设为 $\beta_1 = 1, \beta_2 = 0.8, \beta_3 = 2$ 和 $\beta_4 = 5$ 。

过程噪声 \mathbf{w}_k 的方差为 \mathbf{Q}_k , 由式(28)得到过程噪声和测量噪声的互协方分别为:

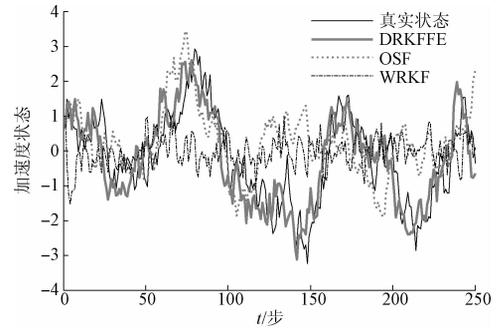
$$\mathbf{R}_k^{i,j} = \boldsymbol{\beta}_i \boldsymbol{\beta}_j (\mathbf{Q}_k + \boldsymbol{\sigma}_{\boldsymbol{\eta}}^2) \quad (29)$$

$$\mathbf{S}_k = 2(\beta_1 \sigma_{\boldsymbol{\eta}}^2 \ \beta_2 \sigma_{\boldsymbol{\eta}}^2 \ \beta_3 \sigma_{\boldsymbol{\eta}}^2 \ \beta_4 \sigma_{\boldsymbol{\eta}}^2)^T \quad (30)$$

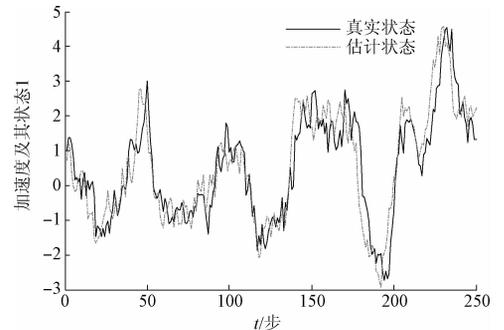
初始值为 $\hat{\mathbf{x}}_{0|0}^* = \boldsymbol{\mu}_0 = E(\mathbf{x}_0) = (1 \ 1 \ 1)^T$ 和 $\mathbf{P}_{0|0}^* = 0.01 \mathbf{I}_3$ 。实验结果基于100次蒙特卡罗模拟得到,对比了提出的分布式融合估计(distributed fusion estimation based on robust Kalman filtering, DRKFFE)方法以及加权鲁棒 Kalman 滤波方法(weighted robust Kalman filter, WRKF)^[8] 和最优序贯融合(optimal sequential fusion, OSF)方法^[14] 的状态估计效果。需要指出的是,依据过程噪声和测量噪声的概率分布以及中心极限定理,在信号与系统的数学分析中,噪声序列采用白噪声的处理方式。因为即使是有色噪声,也可以将其转化成为白噪声,再做后续的处理与理论分析。

为了清晰地刻画估计结果,加速度的状态及估计如图5所示。对比这3种方法,图5(a)所示为DRKFFE在带有交叉相关噪声和传输延迟的状态估计方面具有最佳

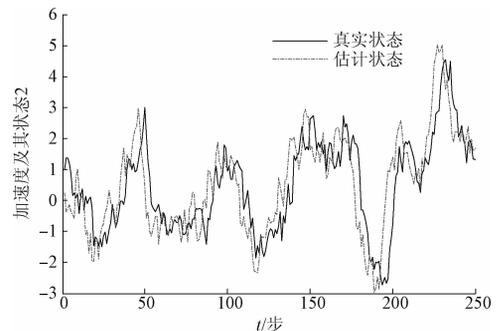
的性能。图5(b)~(d)所示为由每个传感器计算得到的加速度的状态估计。由于噪声的交叉相关性决定了状态跟随路径的曲线是不平滑的,当交叉相关强度较小时,用于目标跟踪的滤波估计更依赖于DRKFFE方法。



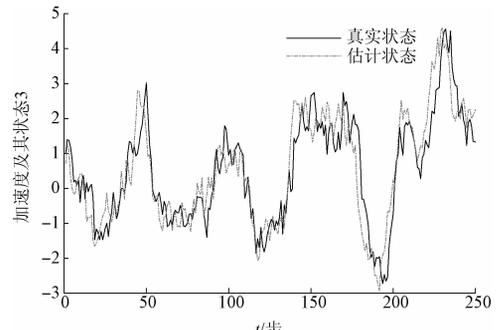
(a) 采用DRKFFE、OSF和WRKF方法的状态估计
(a) State estimation with DRKFFE、OSF and WRKF methods



(b) DRKFFE应用于传感器1的状态估计
(b) State estimation of sensor 1 with DRKFFE method



(c) DRKFFE应用于传感器2的状态估计
(c) State estimation of sensor 2 with DRKFFE method

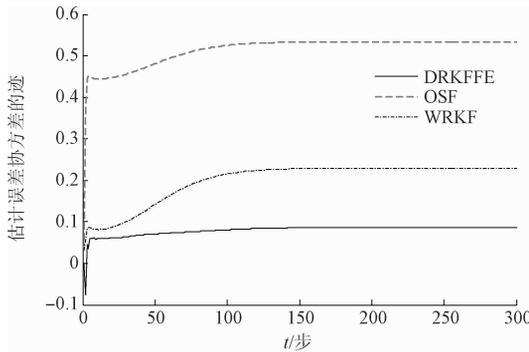


(d) DRKFFE应用于传感器3的状态估计
(d) State estimation of sensor 3 with DRKFFE method

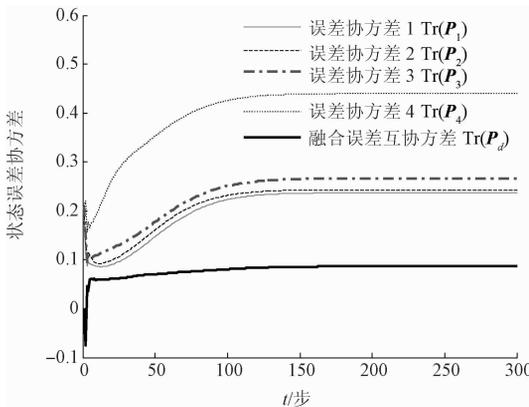
图5 对比加速度的状态估计

Fig. 5 Comparison of state estimation for acceleration

图6比较分析了相应的估计误差协方差结果。图6(a)通过3种方法演示了估计误差协方差的迹,验证了DRKFFE得到的估计误差协方差矩阵的迹小于其他两种方法。图6(b)应用DRKFFE方法,对比了每个滤波器之间的误差协方差矩阵的迹(即 $\text{Tr}(\mathbf{P}_i), i=1, \dots, 4$)以及融合后矩阵的迹(即 $\text{Tr}(\mathbf{P}_d)$),明显地,融合估计方法是最优的。进而,加权融合重组新息序列的方法能够提高估计器的鲁棒性能,并得到最优的稳态值。



(a) 对比3种方法得到的估计误差协方差的迹
(a) Trace for estimation error covariances with three methods



(b) 每个传感器和融合中心的估计误差协方差的迹
(b) Trace for estimation error covariances of each sensor and fusion center

图6 滤波误差协方差的对比

Fig. 6 Comparison of filtering error covariance

为了进一步验证DRKFFE方法的鲁棒性,引入用于验证估计精度的性能指标,即均方误差(mean square error, MSE)值^[16],它是由 k 时刻的状态值和估计值组成的。在各态历经性遍历中,当采样时间尽可能大时,MSE趋于估计误差协方差的迹,即 $\text{MSE} \rightarrow \text{Tr}(\mathbf{P}^z)$ 。加速度估计状态的各项性能指标如表1和2所示。其中,表1对比了3种方法的MSEs及其对应的状态误差协方差的迹;表2针对提出的方法,对比了每个传感器以及融合后的状态估计结果。

表1 加速度估计状态的性能指标对比

Table 1 Comparison of performance index for acceleration

方法	OSF	WRKF	DRKFFE
滤波器均方误差	1.02	0.24	0.21
误差协方差矩阵的迹	0.16	0.21	0.091

表2 传感器和融合中心的估计性能指标对比

Table 2 Comparison of performance index for sensors and fusion center

传感器	S1	S2	S3	S4	
MSEs	0.24	0.25	0.33	0.46	
传感器和融合中心	$\text{Tr}(\mathbf{P}_1)$	$\text{Tr}(\mathbf{P}_2)$	$\text{Tr}(\mathbf{P}_3)$	$\text{Tr}(\mathbf{P}_4)$	$\text{Tr}(\mathbf{P}_d)$
估计误差协方差的迹	0.14	0.15	0.16	0.21	0.09

依据仿真结果和性能指标以及均方误差准则,基于鲁棒Kalman滤波的分布式融合估计方法能够降低计算复杂度,迅速收敛到一个稳定的状态,提高抑制不确定干扰的鲁棒性,进而可以得到较高的测量精度。

5 结论

本文基于线性CCD的空间定位原理,设计3D光电传感器,测得空间目标信息,并对其运动轨迹进行跟踪与估计,研究了带有交叉相关噪声和传输延迟的分布式不确定系统的状态估计问题。根据分布式Kalman滤波融合准则,采用测量转换方法,借助分布式加权融合估计和重组新息序列,提出的方法利用估计误差互协方差矩阵实现任意两个邻居子系统之间的信息交互,用于处理随机传输延迟,实现降低网络通信负担,抑制通信约束对测量信息的影响。最后,数值实验说明了提出的分布式融合估计算法在状态估计方面具有更好的动态跟踪效果。进而实现提高空间定位精度的目的。

参考文献

[1] GE X, HAN Q L. Distributed event-triggered H_∞ filtering over sensor networks with communication delays [J]. Information Sciences, 2015, 291 (C): 128-142.

[2] LI D, KAR S, MOURA J M, et al. Distributed Kalman filtering over massive data sets: analysis through large deviations of random Riccati equations [J]. IEEE Transactions on Information Theory, 2015, 61 (3): 1351-1372.

[3] SONG E, XU J, ZHU Y. Optimal distributed Kalman filtering fusion with singular covariances of filtering errors and measurement noises [J]. IEEE Transactions on Automatic Control, 2014, 59(5): 1271-1282.

[4] HU J, WANG Z, CHEN D, et al. Estimation, filtering

- and fusion for networked systems with network-induced phenomena: New progress and prospects [J]. *Information Fusion*, 2016, 319(C): 65-75.
- [5] ZHONG X, MOHAMMADI A, PREMKUMAR A, et al. A distributed particle filtering approach for multiple acoustic source tracking using an acoustic vector sensor network [J]. *Signal Processing*, 2015, 108(C): 589-603.
- [6] SONG B, WU Z G, PARK J H, et al. H_∞ filtering for stochastic systems driven by Poisson processes [J]. *International Journal of Control*, 2015, 88(1): 2-10.
- [7] 刘晓光, 胡静涛, 王鹤. 基于自适应 H_∞ 滤波的组合导航方法研究 [J]. *仪器仪表学报*, 2014, 35(5): 1013-1021.
- LIU X G, HU J T, WANG H. Research on integrated navigation method based on adaptive H_∞ filter [J]. *Chinese Journal of Scientific Instrument*, 2014, 35(5): 1013-1021.
- [8] FENG J, WANG Z, ZENG M. Distributed weighted robust Kalman filter fusion for uncertain systems with autocorrelated and cross-correlated noises [J]. *Information Fusion*, 2013, 14(1): 78-86.
- [9] SONG H, YU L, ZHANG W A. Distributed consensus-based Kalman filtering in sensor networks with quantised communications and random sensor failures [J]. *IET Signal Processing*, 2014, 8(2): 107-118.
- [10] ZHANG W, ZHAO Y, SHENG L. Some remarks on stability of stochastic singular systems with state-dependent noise [J]. *Automatica*, 2015, 51(1): 273-277.
- [11] TIAN T, SUN S, LI N. Multi-sensor information fusion estimators for stochastic uncertain systems with correlated noises [J]. *Information Fusion*, 2016, 27(C): 126-137.
- [12] 周文举, 费敏锐, 王海宽, 等. 基于迭代学习和卡尔曼滤波的相机精确抓拍控制方法 [J]. *仪器仪表学报*, 2014, 35(5): 1044-1051.
- ZHOU W J, FEI M R, WANG H K, et al. Accurate camera image capture control based on iterative learning and Kalman filter [J]. *Chinese Journal of Scientific Instrument*, 2014, 35(5): 1044-1051.
- [13] COSTA O, BENITES G. Robust mode-independent filtering for discrete-time Markov jump linear systems with multiplicative noises [J]. *International Journal of Control*, 2013, 86(5): 779-793.
- [14] YAN L, LI X R, XIA Y, et al. Optimal sequential and distributed fusion for state estimation in cross-correlated noise [J]. *Automatica*, 2013, 49(12): 3607-3612.
- [15] QI W, ZHANG P, DENG Z. Robust weighted fusion Kalman filters for multisensor time-varying systems with uncertain noise variances [J]. *Signal Processing*, 2014, 99(1): 185-200.
- [16] ZHANG P, QI W, DENG Z. Hierarchical fusion robust Kalman filter for clustering sensor network time-varying systems with uncertain noise variances [J]. *International Journal of Adaptive Control and Signal Processing*, 2015, 29(1): 99-122.
- [17] QI W, ZHANG P, DENG Z. Robust sequential covariance intersection fusion Kalman filtering over multi-agent sensor networks with measurement delays and uncertain noise variances [J]. *Acta Automatica Sinica*, 2014, 40(11): 2632-2642.
- [18] 赵天意, 彭喜元, 彭宇, 等. 改进卡尔曼滤波的融合型锂离子电池 SOC 估计方法 [J]. *仪器仪表学报*, 2016, 37(7): 1441-1448.
- ZHAO T Y, PENG X Y, PENG Y, et al. Lithium-ion battery SOC estimation method with fusion improved Kalman filter algorithm [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(7): 1441-1448.
- [19] ZHANG W A, FENG G, YU L. Multi-rate distributed fusion estimation for sensor networks with packet losses [J]. *Automatica*, 2012, 48(9): 2016-2028.
- [20] REZAEI H, ESFANJANI R M, SEDAAGHI M H. Improved robust finite-horizon Kalman filtering for uncertain networked time-varying systems [J]. *Information Sciences*, 2015, 293(2): 263-274.

作者简介



刘莉, 2004 年于曲阜师范大学获得学士学位, 2007 年于大连海事大学获得硕士学位, 2017 年于上海大学获得博士学位, 现为鲁东大学讲师, 主要研究方向为信息融合。
E-mail: liulildu@163.com

Liu Li received her B. Sc. degree in 2004 from Qufu Normal University, and her M. Sc. degree in 2007 from Dalian Maritime University, and her Ph. D. degree in 2017 from Shanghai University. Now she is a lecturer at Ludong University. Her main research interest is information fusion.



杨傲雷 (通讯作者), 2004 年于湖北工业大学获得学士学位, 2009 年于上海大学获得硕士学位, 2012 年于英国贝尔法斯特女王大学获得博士学位, 现为上海大学副教授, 主要研究方向为多智能体的协同控制、无人机编队飞行控制、图像处理和机器视觉, 以及无线网络控制系统。
E-mail: aolei_yang@163.com

Yang Aolei (Corresponding author) received his B. Sc. degree in 2004 from Hubei University of Technology, and received his M. Sc. degree in 2009 from Shanghai University, and received his Ph. D. degree in 2012 from Queen's University Belfast, UK. Currently, he is an associate professor in Shanghai University. His main research interests include cooperative control of multi-agents, formation flight control of unmanned aerial vehicles, image processing and machine vision, and wireless networked control systems.