

DOI:10.13203/j.whugis20180475

文章编号:1671-8860(2020)10-1602-08



一种改进的多传感器数据自适应融合方法

戴海发¹ 卞鸿巍¹ 王荣颖¹ 张甲甲¹

1 海军工程大学电气工程学院,湖北 武汉,430033

摘要:传感器的异常观测是多传感器信息融合的一个重要问题,且对融合精度有很大的影响。贝叶斯信息融合技术是解决该问题的一种有效方法,但是该方法需要进行无穷区间的积分运算,容易出现数值不稳定的问题。针对该问题提出了一种改进的多传感器自适应融合方法,利用传感器测量值之间的差值自适应建立传感器的后验概率分布模型,并结合互信息的理论实时识别和剔除异常观测值,从而避免了求熵时的积分计算。仿真和实测数据试验结果表明,所提方法在无异常观测值的条件下得到的结果与简单贝叶斯融合方法相当;对于存在异常观测值的情况下,信息融合的性能明显优于一般的贝叶斯融合方法。

关键词:多传感器信息融合;贝叶斯方法;异常观测;自适应建模;互信息

中图分类号:P228

文献标志码:A

多传感器系统的主要目标是通过一致和协调的方法将来自多种传感器的信息结合起来得到一个特定变量在某种环境下的更可靠、准确、一致的描述^[1-8]。在多传感器信息融合中面临一种不确定性是传感器偶尔会输出异常观测,即明显偏离真实值的数据^[8]。这些异常观测的产生可能是由于传感器永久性故障、传感器受到瞬时干扰、传感器缓变故障引起的^[8]。大多数通过试验得到的传感器模型都是利用无异常观测的数据得到的,它只能表示由于噪声和原理性误差产生的不确定性。如果将异常观测和正常数据进行融合通常会得到一个不准确的估计,甚至会使系统完全崩溃^[8]。因此,在融合多源信息之前有必要对这些传感器测量值进行有效性验证,剔除异常观测数据。

目前为止,在文献中有许多可用的技术用于传感器有效性的验证和不一致数据的识别。它们中的大部分都是针对特定的故障模式进行建模,然而要对所有的故障模式都进行建模并不现实。为了检测出数据的不一致,一般需要提供余度数据或者先验信息。有学者已经成功地利用Nadaraya-Waston估计器^[9]和先验观测来验证传感器测量的有效性。还有一些学者提出了基于模型的卡尔曼滤波方法^[10-12]、基于抗差滤波的方

法^[13]、基于协方差的方法^[14]、基于概率的方法^[15]、基于模糊逻辑的方法^[16-17]以及基于神经网络的方法^[18]等。这些方法有些依赖于模型,而有些需要复杂的调参和训练过程。

传统的基于贝叶斯方法的信息融合技术^[19]提供了一种将先验信息和当前试验得到的信息结合起来的良好的架构,因此被广泛应用,但是该方法不能够识别异常观测值,因此在传感器测量值存在异常观测时融合结果不理想。针对这个问题,文献[20]结合贝叶斯估计和熵理论^[21],提出了一种基于后验概率熵的异常观测识别和信息融合方法。该方法通过计算信息融合前后后验概率熵的变化来判断传感器测量值是否为异常观测值,但是该方法在计算熵时需要进行无穷区间的积分,容易产生数值发散问题。因此,本文在该方法的基础上提出了一种改进的基于互信息的异常观测值识别和信息融合方法。本文先简要介绍了贝叶斯融合方法,其次介绍了基于熵理论的贝叶斯融合方法及其改进,然后介绍了该方法在集中式融合和分布式融合中的应用,最后通过试验验证了所提方法的有效性。

1 基于贝叶斯方法的传感器融合

贝叶斯推理是一种基于贝叶斯理论的统计

收稿日期:2019-06-02

项目资助:国家自然科学基金(41876222)。

第一作者:戴海发,博士生,主要从事多传感器组合导航与信息融合技术研究。daihaifa1990@163.com

通讯作者:卞鸿巍,博士,教授。travisbian@fox.com

数据融合算法,得到测量或观测值 z 后,根据条件概率或者后验概率估计 n 维状态向量 x 。观测值 z 中包含的概率信息由概率密度函数 $p(z|x)$ 表示,即似然函数,也就是传感器的模型。似然函数表示后验概率密度可能发生变化的程度,一般通过离线试验或者可用信息确定。如果在得到测量信息之前,能够独立得到关于状态向量 x 的先验概率 $p(x)$,那么似然函数能够得到更准确的结果。根据贝叶斯理论,可得到状态向量 x 的后验概率密度:

$$p(x|z) = \frac{p(z|x)p(x)}{p(z)} \quad (1)$$

式中, $p(z)$ 为传感器测量值为 z 的概率,只与测量值有关。因此,通过最大化后验概率密度(maximum a posteriori, MAP),可以得到状态向量 x 的最大化后验概率估计:

$$\begin{aligned} \hat{x}_{\text{MAP}} &= \arg \max_x p(x, z) = \\ &= \arg \max_x p(z|x)p(x) \end{aligned} \quad (2)$$

传感器建模是传感器融合的关键步骤,有助于形成对传感器提供的测量值特性和传感器性能的深刻理解。传感器提供的信息一般建模成真实值的均值和表征传感器不确定性的方差,方差同时依赖于测量质量和工作环境参数。由于概率传感器模型方便地描述了测量数据的统计特性,因此被广泛使用。这个概率模型表征在状态量 x 已知的条件下,传感器测量值的概率分布。

来自多个传感器的数据可以一次性融合(集中融合),也可以分布融合。记 $\bar{Z}_n = \{z_1, z_2, \dots, z_n\}$ 表示从第1个传感器到第 n 个传感器测量值的集合。

1)在集中式融合方案中,所有传感器的信息同时进行融合,可通过下式使用贝叶斯方法融合来自 n 个传感器的数据:

$$p(x|\bar{Z}_n) = \frac{p(x)}{p(\bar{Z}_n)} \times p(z_1|x) \cdots p(z_n|x) \quad (3)$$

2)分布式融合方案,采取分步逐级融合的策略,将上一次融合的结果作为下一次融合的先验信息。同样地,分布式贝叶斯方法可以通过下式实现融合:

$$p(x|\bar{Z}_n) = \frac{p(z_n|x)p(x|\bar{Z}_{n-1})}{p(\bar{Z}_n)} \quad (4)$$

2 含有异常观测的贝叶斯融合

由于传感器故障、传感器受到外部干扰或者多径效应,传感器经常会输出异常观测值。 $\S 1$ 中

描述的贝叶斯方法不能够处理这些异常观测,因为该方法没有能够识别来自传感器的数据是否可用的机制。如果融合了这些异常观测,将会得到不准确的估计结果。下文将研究考虑测量值不一致的基于贝叶斯方法的多源信息融合策略。

在构建传感器随机模型时,通常这些异常观测值都会事先被识别并剔除。因此,通过试验得到的传感器模型只表征由于噪声引起的不确定性。本文重点研究在存在异常观测值的条件下,自适应建立传感器模型并将其应用于信息融合的方法。假设事件 $s_i = 0$ 表示第 i 个传感器的数据是非异常观测值, $s_i = 1$ 表示第 i 个传感器的数据是异常观测值,那么通过这个方法得到的传感器模型实际上表示分布 $p(z_i|x, s_i = 0)$ 。根据贝叶斯理论,在真实状态 x 和测量值 z_i 已知的条件下,传感器的测量值为非异常观测值的概率密度为:

$$p(s_i = 0|x, z_i) = \frac{p(s_i = 0)p(z_i|x, s_i = 0)}{\sum_{s_i} p(s_i)p(z_i|x, s_i)} \quad (5)$$

式中, $p(s_i = 0)$ 为传感器 i 输出非异常观测值的概率,可根据试验确定。式(5)等号右边式子的分母可通过遍历 s_i 的取值 $\{0, 1\}$,累加化简,因此式(5)可重写为:

$$p(s_i = 0|x, z_i) = \frac{p(s_i = 0)p(z_i|x, s_i = 0)}{p(z_i|x)} \quad (6)$$

或者

$$p(z_i|x) = \frac{p(s_i = 0)p(z_i|x, s_i = 0)}{p(s_i = 0|x, z_i)} \quad (7)$$

将式(7)代入式(3)可得到集中式融合方案的后验概率分布:

$$\begin{aligned} p(x|\bar{Z}_n) &= \frac{p(s_1 = 0)p(z_1|x, s_1 = 0)}{p(s_1 = 0|x, z_1)} \times \\ &\cdots \frac{p(s_n = 0)p(z_n|x, s_n = 0)}{p(s_n = 0|x, z_n)} \times \frac{p(x)}{p(\bar{Z}_n)} \end{aligned} \quad (8)$$

比较式(8)和式(3)发现,分母中多出了 $p(s_i = 0|x, z_i)$ 这些项。这些项将改变相应传感器测量值协方差大小,如果来自第 i 传感器的测量值具有较高概率为异常观测,那么该传感器测量值协方差将会变大,在融合时给予较小的权值。

同理,可得到分布式融合方案的后验概率分布:

$$\begin{aligned} p(x|\bar{Z}_n) &= \frac{p(s_n = 0)}{p(\bar{Z}_n)} \times \\ &\frac{p(z_n|x, s_n = 0)p(x|\bar{Z}_{n-1})}{p(s_n = 0|x, z_n)} \end{aligned} \quad (9)$$

式中, $p(s_i = 0|x, z_i)$ 同样会影响传感器测量值的

协方差。后验概率的协方差表征了根据测量值估计状态量的不确定度,方差越大,表示估计不确定度越高,即估计效果越不好;反之,估计方差越小,不确定度越低,估计效果越好。而后验概率方差的增减可通过信息熵来衡量,信息熵表示变量的不确定度,大的信息熵表明不确定较大,因而信息量少。当融合一个新的可靠的测量值时,熵应该是减少的,否则可能是异常观测。因此文献[20]基于信息熵的增减提出了一种识别传感器异常观测的方法。

变量 x 的信息熵计算公式为^[22]:

$$H(x) = \sum p(x) \log_2 \left(\frac{1}{p(x)} \right) \quad (10)$$

式中, $\sum(\cdot)$ 表示对变量求期望; $\log_2(\cdot)$ 表示以 2 为底的对数。

对于连续的随机过程,将 x 的范围平分成宽度为 δx 的离散线段,那么概率密度函数将会形成一系列的直方图, x 等于某个特定值的概率近似为 $p(x)\delta x$ 。式(10)的离散化结果为:

$$H(x) = \sum p(x)\delta x \log_2 \left(\frac{1}{p(x)\delta x} \right) \quad (11)$$

对 δx 取极限 $\delta x \rightarrow 0$, 得到连续随机过程的熵:

$$H(x) = \int p(x) \log_2 \left(\frac{1}{p(x)} \right) dx \quad (12)$$

因此,式(9)后验概率的熵为:

$$H(x|\bar{Z}_k) = \int -p(x|\bar{Z}_k) \log_2(p(x|\bar{Z}_k)) dx \quad (13)$$

融合前后的熵增量为:

$$\Delta H = H(x|\bar{Z}_k) - H(x|\bar{Z}_{k-1}) \quad (14)$$

通过比较 $H(x|\bar{Z}_{k-1})$ 和 $H(x|\bar{Z}_k)$ 的大小,可以判断第 k 个传感器的测量值是否为异常观测,如果 $\Delta H > 0$, 表明融合后熵增加了,即不确定度变大了,因此该测量值可能是异常观测,剔除该测量值;如果 $\Delta H < 0$, 表明融合后不确定度减小了,因此是正常数据,允许该数据进入融合算法。但是不难发现,要求后验概率的信息熵需要进行无穷区间的积分运算,这将会造成算法的数值不稳定。针对该问题,笔者提出一种改进的异常观测识别方法。

对于分布式融合方案,上一步融合的结果将作为下一步融合的先验信息。因此定义第 $k-1$ 步得到的后验概率为 $p(\hat{x}_{k-1})$, 则第 k 步的后验概率密度 $p(x_k|\bar{Z}_k)$ 满足:

$$p(\hat{x}_k|\bar{Z}_k) = \frac{p(\hat{x}_{k-1})p(z_k|\hat{x}_{k-1})}{p(z_k)} \quad (15)$$

为了避免积分的运算,采用式(10)的离散化形式:

$$H(x) = \sum p(x,z) \delta x \delta z \log_2 \left(\frac{1}{p(x)\delta x} \right) \quad (16)$$

式中, $p(x,z)$ 为变量 x,z 的联合概率密度。

同理,得到:

$$H(x|z) = \sum p(x,z) \delta x \delta z \log_2 \left(\frac{1}{p(x|z)\delta x} \right) \quad (17)$$

由式(16)、式(17)得到互信息 $I(x;z)$ 为:

$$I(x;z) = H(x) - H(x|z) = \sum p(x,z) \delta x \delta z \log_2 \left(\frac{p(x|z)}{p(x)} \right) \quad (18)$$

该值表征了融合后熵的减少量,即信息的增加量。取极限 $\delta x \rightarrow 0, \delta z \rightarrow 0$, 得到:

$$I(x;z) = \int_{x,z} p(x,z) \log_2 \left(\frac{p(x|z)}{p(x)} \right) dx dz = \sum \left[\log_2 \left(\frac{p(x|z)}{p(x)} \right) \right] \quad (19)$$

假设变量 x,z 满足高斯分布,那么其联合分布也满足高斯分布。即:

$$p(x) = (2\pi)^{-n/2} |P_{xx}|^{-\frac{1}{2}} (x - \hat{x})^T P_{xx}^{-1} (x - \hat{x}) \quad (20)$$

$$p(x|z) = (2\pi)^{-n/2} |P'_{xx}|^{-\frac{1}{2}} e^{-\frac{1}{2}(x - \hat{x}')^T P'^{-1}_{xx} (x - \hat{x}')} \quad (21)$$

式中, n 为状态向量 x 的维数; \hat{x}, P_{xx} 分别为融合前的均值和误差协方差; \hat{x}', P'_{xx} 分别为融合后的均值和误差协方差。将式(21)代入式(19), 得到:

$$I(x;z) = \frac{1}{2} \log_2 \frac{|P_{xx}|}{|P'_{xx}|} \quad (22)$$

根据式(22),如果融合后的方差大于融合前的方差,那么互信息 $I < 0$,表明融合后系统从测量值中得到关于状态量的信息量是减少的,因此该测量值可能是异常观测。反之,该测量值是正常值。

3 多高斯分布变量的贝叶斯融合

高斯模型是比较常用的传感器测量模型,在实践中比较有代表性。此外,高斯模型的自适应信息融合方法也是非高斯问题的理论基础,因此本文选择高斯分布作为贝叶斯融合方法的应用对象。

3.1 不考虑异常观测值的贝叶斯融合(方法1)

如果不考虑传感器数据中的异常观测值, N 个模型由以下高斯似然函数给出:

$$p(z_k|x) = (2\pi)^{-n/2} \sigma_k e^{-\frac{-(x-z_k)}{2\sigma_k^2}}, k=1,2,\dots,N \quad (23)$$

其中, $k=i$ 表示第 i 个传感器,由贝叶斯原理可得

到融合的最大后验估计为:

$$\hat{x}_{\text{MAP}} = \arg \max [p(z_1|x) \times p(z_2|x) p(z_3|x)] \quad (24)$$

多个高斯分布进行融合,其后验概率分布为联合高斯分布,均值和方差分别为:

$$\hat{x}_{\text{MAP}} = (\sigma')^2 \sum_{k=1}^N [z_k \sigma_k^{-2}] \quad (25)$$

$$(\sigma')^2 = \left[\sum_{k=1}^N (\sigma_k^{-2}) \right]^{-1} \quad (26)$$

因此,如果没有可用的关于变量 x 的先验信息,那么 n 个高斯分布的贝叶斯融合结果即为 N 个传感器数据按照标准差加权平均。由式(26)可知,融合后的分布标准差要小于 N 个独立分布任一分布的标准差,这表明通过融合估计,结果不确定性降低了。

3.2 考虑异常观测值的贝叶斯融合

如果考虑传感器测量的异常观测值,那么高斯传感器模型为:

$$p(z_k|x, s_k=0) = (2\pi)^{-n/2} \sigma_k e^{\left\{ -\frac{(x-z_k)^2}{2\sigma_k^2} \right\}}, k=1, 2 \dots N \quad (27)$$

在真实状态 x 和测量值 z_k 给定的条件下,第 k 个传感器测量值为非异常观测的概率按照文献 [13] 给出:

$$p(s_k=0|x, z_k) = e^{\left\{ -\frac{(x-z_k)^2}{2a_k^2} \right\}} \quad (28)$$

选择这一函数的依据是:当测量值 z_k 等于真实状态 x 时,该概率为 1,随着测量值远离真实状态,该概率逐渐减小。参数 a_k 依赖于模型参数以及该传感器的输出与其他传感器输出的偏差。

3.2.1 集中式融合方案(方法 2)

根据式(8)得到考虑异常观测值的集中式融合方案的后验分布为:

$$p(x|z_1, z_2, z_3) = \frac{p(x)}{p(z_1, z_2, z_3)} \times \prod_{k=1}^N \frac{p(s_k=0)p(z_k|x, s_k=0)}{p(s_k=0|x, z_k)} \quad (29)$$

式(28)中的参数 a_k 设为:

$$a_k^2 = \frac{b_k^2}{\prod_{l \neq k, l=1}^3 (z_k - z_l)^2} \quad (30)$$

将式(30)代入式(29)得到:

$$p(x|\bar{Z}_k) = \frac{p(x)}{p(\bar{Z}_k)} \times \prod_{k=1}^N p(s_k=0) \times \frac{1}{\sigma_k \sqrt{2\pi}} \exp \left\{ -\frac{(x-z_k)^2}{2\sigma_k^2} \frac{\prod_{l \neq k, l=1}^N (z_k - z_l)^2}{b_k^2} \right\} \quad (31)$$

其中,参数 b_k 满足:

$$b_k^2 \geqslant 2\sigma_k^2 \prod_{l \neq k, l=1}^N (z_k - z_l)^2 \quad (32)$$

满足该不等式可以确保式(31)仍然是高斯分布,因此只有一个峰值。由式(31)可知,如果某个测量值与其余测量值距离较大,就会自适应地增大该独立分布(表征从该测量值得到的置信)的方差。因此,如果两个测量值彼此很接近,那么分配给这些测量值的权值就会增加。

集中式融合方案的最大后验估计的均值和方差分别为:

$$\hat{x}_{\text{MAP}} = (\sigma')^2 \left[\sum_{k=1}^N z_k (\sigma_k^{-2} - 2a_k^{-2}) \right] \quad (33)$$

$$(\sigma')^2 = \left[\sum_{k=1}^N (\sigma_k^{-2} - 2a_k^{-2}) \right]^{-1} \quad (34)$$

3.2.2 分布式融合方案(方法 3)

在分布式或者序贯融合方案中,先融合两个传感器的测量值,然后将融合结果与第 3 个传感器的测量值进行融合,以此类推直到完成所有测量值的融合。根据式(35)融合第 1 个传感器和第 2 个传感器的信息:

$$\begin{aligned} p(x|z_2, z_1) &= \frac{p(s_1=0)p(z_1|x, s_1=0)}{p(s_1=0|x, z_1)} \times \\ &\quad \frac{p(s_2=0)p(z_2|x, s_2=0)}{p(s_2=0|x, z_2)} \times \frac{p(x)}{p(z_2, z_1)} \end{aligned} \quad (35)$$

将式(28)中的参数 a_k 设为:

$$a_k^2 = \frac{b_k^2}{(z_k - z_{k-1})^2} \quad (36)$$

$$b_k^2 = 2\sigma_k^2 m^2 \quad (37)$$

式中, m 为测量偏差的最大期望值。代入式(35)得:

$$\begin{aligned} p(x|z_1, z_2) &= \frac{p(x)}{p(\bar{Z}_2)} \times p(s_1=0) \times \frac{1}{\sigma_1 \sqrt{2\pi}} \times \\ &\quad \exp \left\{ -(x-z_1)^2 \left[\frac{1}{2\sigma_1^2} - \frac{(z_k-z_1)^2}{b_1^2} \right] \right\} \times p(s_2=0) \times \\ &\quad \frac{1}{\sigma_2 \sqrt{2\pi}} \exp \left\{ -(x-z_2)^2 \left[\frac{1}{2\sigma_2^2} - \frac{(z_2-z_1)^2}{b_2^2} \right] \right\} \end{aligned} \quad (38)$$

根据§2 基于互信息的异常观测识别方法判断这两个测量值中是否存在异常观测。如果互信息大于 0,表明这两个测量值都是正常的,其融合结果将与第 3 个测量值进行融合,且融合结果将作为下一步融合的先验值;如果互信息小于 0,则表明至少存在一个异常观测值,进一步评估这两个传感器与第 3 个传感器的融合结果,如果两个组合中有一组的互信息是大于 0 而另一组小于 0,则可确定只有一个异常观测值且为互信息小

于0的那组中的测量值,正常测量值将和第3个测量值融合得到一个估计值;如果都小于0,则表明至少存在两个异常观测值,且前两个必定为异常观测值,以此类推。

假设第 $k-1$ 步的估计值和标准差分别为 $\hat{x}_{k-1}, \hat{\sigma}'_{k-1}$ 。根据式(9),将第 $k-1$ 步的估计值和第 k 个传感器的信息进行融合:

$$p(x|\bar{Z}_k) = \frac{p(x)}{p(\bar{Z}_k)} \times \frac{1}{\hat{\sigma}'_{k-1} \sqrt{2\pi}} e^{-\frac{(x-\hat{x}_{k-1})^2}{2(\hat{\sigma}'_{k-1})^2}} \times p(s_k=0) \frac{1}{\sigma_k \sqrt{2\pi}} e^{-\frac{(x-z_k)^2}{2\sigma_k^2} \left(\frac{1}{2\sigma_k^2} - \frac{(z_k-\hat{x}_{k-1})^2}{b_k^2} \right)} \quad (39)$$

$$a_k^2 = \frac{b_k^2}{(z_k - \hat{x}_{k-1})^2} \quad (40)$$

最大后验估计的均值和方差分别为:

$$\hat{x}_{k,\text{MAP}} = (\sigma'_k)^2 [\hat{x}_{k-1}(\sigma'_{k-1})^{-2} + z_k(\sigma_k^{-2} - 2a_k^{-2})] \quad (41)$$

$$(\hat{\sigma}'_k)^2 = [(\hat{\sigma}'_{k-1})^{-2} + (\sigma_k^{-2} - 2a_k^{-2})]^{-1} \quad (42)$$

4 试验结果与分析

为了验证本文所提出的方法能够识别传感器测量产生的随机异常观测,本文设计了仿真试验和实测数据试验比较了上述3种方法在不同情况下处理异常测量值的性能。其中,方法1是简单的贝叶斯融合方法,方法2和方法3都考虑了测量值的一致性,且方法2采用集中式融合方案,而方法3采用分布式融合方案。

4.1 仿真实验

仿真实验中模拟了3个高斯分布传感器的情形,真实状态值为 $x=20$,各传感器性能参数如表1所示。

表1 传感器性能参数设置

Tab.1 Performance Parameters of Sensors

| 传感器 | 正常观测值 | | 异常观测值 | |
|-----|-------|---------------|-------|---------------|
| | 概率 | 分布 | 概率 | 分布 |
| 1 | 0.98 | $N(20, 4)$ | 0.02 | $N(30, 4)$ |
| 2 | 0.90 | $N(20, 6.25)$ | 0.10 | $N(35, 6.25)$ |
| 3 | 0.80 | $N(20, 9)$ | 0.20 | $N(38, 9)$ |

多种情景的试验结果见图1。图1(a)展示了3种传感器测量值基本一致的测试结果,可以看出,根据3种方法得到的后验概率分布相同,这说明这3种方法对于没有异常观测时的估计结果是相同的。图1(b)展示了3个传感器中有一个传感

器的测量值明显偏离其他两个测量值时的测试结果,中可以看出,方法1由于没有考虑异常观测的影响,估计结果偏离真实值,方法2考虑了异常观测的影响,给偏差较大的测量值赋予了较小的权值,得到的结果稍优于方法1;而方法3识别并剔除了异常观测值,因此融合结果更接近真实值。

图1 多种情景的试验结果

Fig.1 Fusion Results of Three Sensors with Different Situations

此外,利用上述方法产生了10 000个数据点,并分别利用3种方法进行融合,实验结果如表2所示。由表2可知,方法3的均值最接近真实值,方法2次之,方法1误差最大。和方法1相比,方法3减少了均方根误差约28%,方法2减少了均方根误差约20%。

表2 3种方法的均值和均方差比较

Tab.2 Comparison of Mean Values and Covariance of Three Methods

| 方法 | 均值 | 均方差 |
|----|-------|------|
| 1 | 22.28 | 2.60 |
| 2 | 21.49 | 2.08 |
| 3 | 20.23 | 1.86 |

上述10 000个数据的试验结果见图2。图2(a)展示了10 000个数据点中的100个样本点。

图 2(b)展示了有两个传感器同时产生异常观测值的测试结果,可以看出,方法 3 的融合结果最接近真实值。这是因为方法 3 具有识别和消除异常观测值的内部机制,这是通过比较其中一个传感器与其他两个传感器的差值来实现的。但是当 3 个传感器中同时有两个传感器产生相近的异常观测值时,该方法失效,因为其错误地将第 3 个传感器数据识别为异常观测值。如在图 2(a)中,圆圈里的数据就是这种情况。传感器 2 和传感器 3 同时产生异常观测值,但由于它们相互接近,方法 3 反而将传感器 1 的测量值当成了异常观测值,并从融合结果中剔除了该测量值,从而产生错误估计。同样地,方法 2 对传感器 2 和传感器 3 的测量值赋予了较大权值,产生了不准确的结果。在实际中,当传感器在同一测量平台上,且具有一定的耦合关系时,出现这种情况的可能性是存在的。对于这种极端情况,可以在平台上安装一个稳定性、自主性较好的传感器,用于监测其他传感器的状态。对于明显偏离参考传感器测量值的传感器测量值直接剔除,不进行融合。

其中包括两台 GPS(global positioning system)接收机以及两台北斗(Beidou, BD)接收机,利用组合接收机的结果作为基准。4 套卫星导航的经纬度测量值如图 3 所示,从图 3 中可以看出,各接收机的测量数据都含有一些幅值较大的异常观测值,而由于采集过程中出现了问题导致第二套北斗接收机的纬度与经度是完全相同的。对于上述数据,采用文中的 3 种方法以及抗差加权融合方法进行对比,试验结果如图 4 所示。

图 3 卫星导航接收机的经纬度测量值

Fig.3 Latitude and Longitude Measurements of Satellite Navigation Receivers

图 2 10 000 个数据的试验结果

Fig.2 Experiment Results of 10 000 Sample Points

4.2 实测数据试验

算例中,选取 4 套卫星导航系统的实测数据,

图 4 4 种方法的估计误差对比

Fig.4 Comparison of Estimation Errors of Four Methods

从图4可看出,简单的贝叶斯融合(方法1)受到异常测量值的影响,在异常测量时刻得到的估计结果严重偏离真实值,方法2在一定程度上抑制了异常测量的影响,但是结果仍然不够理想,因为该方法对于异常测量值只是降低了观测值的权值,对结果还是会产生的影响。方法3和抗差加权融合的方法都对异常测量值进行了有效的抑制,估计误差在10 m以内。从局部放大图中可以看出,方法3的估计误差要略小于抗差加权平均的结果。

5 结语

传感器经常会产生异常观测,异常观测值的识别和消除对于精确的状态估计十分重要。本文提出了一种统一的多源数据融合方法,能够自动识别传感器数据中的异常观测值。该方法在传统的贝叶斯方法中增加了一个置信因子,表示在测量值和真实值给定的条件下,测量为非异常观测值的置信度。为了避免求熵的积分计算,提出利用最大后验概率的互信息作为检测量的方法识别异常观测值。本文比较了3种方法,第1种方法是基于简单的贝叶斯融合方法,第2种方法增加了上述的置信因子并采用集中融合的方式,第3种方法采用分步的融合传感器数据,并识别剔除异常观测。并通过仿真实验和实测数据实验测试了上述3种方法,结果表明,第3种方法识别异常观测的效果最好,因为异常观测的剔除保证了更准确的结果。第2种方法要优于第1种方法,因为该方法存在一种内部机制,该机制会将一致的数据赋予较大的权值,而对于异常观测会赋予较小的权值。本文选用了高斯测量模型作为研究对象,这与真实的传感器测量值存在一定的差距。对于实际传感器非高斯测量值的信息融合问题,将是下一步的研究方向。

参 考 文 献

- [1] Groves P D, Wang L, Walter D, et al. The Four Key Challenges of Advanced Multisensor Navigation and Positioning [C]. IEEE/ION Position Location and Navigation Symposium, Monterey, CA, 2014
- [2] Bahador K, Alaa K, Fakhreddine O, et al. Multisensor Data Fusion: A Review of the State-of-the-Art [J]. *Information Fusion*, 2013, 14(1): 28-44
- [3] Groves P D. The PNT Boom: Future Trends in Integrated Navigation[J]. *Inside GNSS*, 2013, 8: 44-49
- [4] Waltz E, James L. Handbook of Multisensor Data Fusion[J]. *Artech House Radar Library*, 2001, 39(5): 180-184
- [5] Wang G, Hall David L, McMullen Sonya AH. Mathematical Techniques in Multisensor Data Fusion[J]. *BioMedical Engineering OnLine*, 2005, 4(1): 23
- [6] Martin Liggins I I, Hall D, Llinas J. Handbook of Multisensor Data Fusion: Theory and Practice, Second Edition [J]. *Artech House Radar Library*, 2008, 39(5): 180 - 184
- [7] Groves P D. The Complexity Problem in Future Multisensor Navigation and Positioning Systems: A Modular Solution[J]. *Journal of Navigation*, 2014, 67(2): 311-326
- [8] Young S Y R, McGraw G A. Method and System for Fault Detection and Exclusion for Multi-Sensor Navigation Systems [J]. *Google Patents*, 2007, 5: 631 314
- [9] Cai Li, Yang Lijian. A Smooth Simultaneous Confidence Band for Conditional Variance Function [J]. *Test*, 2015, 24(3): 632-655
- [10] Wang Rong, Xiong Zhi, Liu Jianye, et al. Chi-square and SPRT Combined Fault Detection for Multisensor Navigation [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(3): 1 352-1 365
- [11] Yun S H, Kang C W, Park C G. Reducing the Computation Time in the State Chi-Square Test for IMU Fault Detection [C]. 2014 14th International Conference on Control, Automation and Systems (ICCAS 2014), IEEE, Kintex, Korea, 2014
- [12] Wen Xin, Ji Long, Zhang Xingwang, et al. Fault Detection and Diagnosis in the INS/GPS Navigation System [C]. World Automation Congress, IEEE, Shenyang, China, 2014
- [13] Yang Yuanxi, Gao Weiguang. Integrated Navigation Based on Robust Estimation Outputs of Multisensor Measurements and Adaptive Weights of Dynamic Model Information[J]. *Geomatics and Information Science of Wuhan University*, 2004, 29(10):885-888(杨元喜,高为广. 基于多传感器观测信息抗差估计的自适应融合导航[J]. 武汉大学学报·信息科学版, 2004, 29(10):885-888)
- [14] Li G R, Wang Y. Automatic ARIMA Modeling-Based Data Aggregation Scheme in Wireless Sensor Networks[J]. *Eurasip Journal on Wireless Communications & Networking*, 2013, 2013(1): 85
- [15] Zhao X, Wang S C, Zhang J S, et al. Real-Time Fault Detection Method Based on Belief Rule Base for Aircraft Navigation System [J]. *Chinese Journal*

- of Aeronautics*, 2013, 26(3): 717-729
- [16] Mahmood Y A, Ahmadi A, Verma A K, et al. Fuzzy Fault Tree Analysis: A Review of Concept and Application[J]. *International Journal of System Assurance Engineering & Management*, 2013, 4(1): 19-32
- [17] Jaradat M A , Abdel-Hafez M F , Saadeddin K , et al. Intelligent Fault Detection and Fusion for INS/GPS Navigation System[C]. International Symposium on Mechatronics & Its Applications, IEEE, Amman, Jordan, 2013
- [18] Penner M R, Mizumori S J Y. Neural Systems Analysis of Decision Making During Goal-Directed Navigation[J]. *Progress in Neurobiology*, 2012, 96(1): 96-135
- [19] Sun Wenzhou, Yin Xiaodong, Li Shujun. Underwater Carrier Navigation Information Fusion Method Based on Entropy Weight[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(10): 1465-1471(孙文舟, 殷晓冬, 李树军. 基于熵权重的水下载体导航信息融合方法[J]. 武汉大学学报·信息科学版, 2018, 43(10): 1465-1471)
- [20] Kumar M. Stochastic Adaptive Sensor Modeling and Data Fusion[J]. *Proc SPIE*, 2006, 6174: 246-251
- [21] Kumar M , Garg D P , Zachery R A . A Generalized Approach for Inconsistency Detection in Data Fusion From Multiple Sensors[C]. American Control Conference, IEEE, Minneapolis, MN, Xplore, USA, 2006
- [22] Davison A J . Active Search for Real-Time Vision [C]. Tenth IEEE International Conference on Computer Vision, IEEE Computer Society, Beijing, China, 2005

An Improved Multi-sensor Data Adaptive Fusion Method

DAI Haifa¹ BIAN Hongwei¹ WANG Rongying¹ ZHANG Jiajia¹

1 Collage of Electrical Engineering, Naval University of Engineering, Wuhan 430033, China

Abstract: One of the major problems of multi-sensor information fusion is that sensors frequently produce spurious observations, which have a great impact on the fusion accuracy and are difficult to be modeled and predicted. Bayesian information fusion technology based on entropy theory is an effective method to solve this problem. However, this method needs the integral operation in infinite interval, and the problem of numerical instability is prone to occur. To solve this problem, this paper proposes an improved multi-sensor data adaptive fusion method. In the framework of Bayesian theory, we use the difference between the measured values of sensors to adaptively establish the posterior probability distribution model of the sensor. Combined with the theory of mutual information, the pseudo-measured values can be identified and eliminated in real time, without integral calculation. The simulation and measured data test results show that the proposed method achieves the same results as the simple Bayesian fusion method without any spurious measurement, and the information fusion performance is obviously better than the simple Bayesian fusion method.

Key words: multi-sensor information fusion; Bayesian method; spurious data; adaptive modeling; mutual information

First author: DAI Haifa, PhD candidate, specializes in multi-sensors integrated navigation and information fusion. E-mail: daihaifa1990@163.com

Corresponding author: BIAN Hongwei, PhD, professor. E-mail: travisbian@fox.com

Foundation support: The National Natural Science Foundation of China(41876222).

引文格式: DAI Haifa, BIAN Hongwei, WANG Rongying, et al. An Improved Multi-sensor Data Adaptive Fusion Method[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(10): 1602-1609. DOI:10.13203/j.whugis20180475(戴海发, 卞鸿巍, 王荣颖, 等. 一种改进的多传感器数据自适应融合方法[J]. 武汉大学学报·信息科学版, 2020, 45(10): 1602-1609. DOI:10.13203/j.whugis20180475)