

AUV 视觉与短基线定位自适应融合方法

孙海涛¹, 晏正新², 王 玥¹, 张 皓¹

(1. 中国船舶重工集团公司第七一〇研究所, 湖北 宜昌 443003;

2. 江南工业集团有限公司, 长沙 410025)

摘要:为了使 AUV(自主水下航行器)在水下自主对接过程中获得更可靠的定位数据,本文研究了基于视觉和短基线定位系统同时工作时的定位数据融合问题;由于卡尔曼滤波算法在进行数据融合时对于过程噪声与测量噪声统计数据具有依赖性的缺点,提出了一种基于模糊逻辑的在线自适应卡尔曼滤波定位数据融合方法;水池试验结果表明,该方法有效地提高了视觉和短基线融合后的定位精度,切实可行。

关键词: AUV; 视觉; 短基线; 数据融合; 模糊

本文引用格式:孙海涛,晏正新,王玥,等. AUV 视觉与短基线定位自适应融合方法[J]. 四川兵工学报,2015(5):60-62.

Citation format:SUN Hai-tao, YAN Zheng-xin, WANG Yue, et al. Adaptive Data Fusion Method of Vision and SBL Position for AUV[J]. Journal of Sichuan Ordnance,2015(5):60-62.

中图分类号:TP24

文献标识码:A

文章编号:1006-0707(2015)05-0060-04

Adaptive Data Fusion Method of Vision and SBL Position for AUV

SUN Hai-tao¹, YAN Zheng-xin², WANG Yue¹, ZHANG Hao¹

(1. 710 Research & Development Institute, China Shipbuilding Industrial Cooperation, Yichang 443003, China; 2. Jiangnan Industries Group Co., LTD., Changsha 410025, China)

Abstract: The vision position and SBL position were applied to underwater docking of AUV, and thus the problem of the data fusion method for vision and SBL was researched for position precision improvements. In order to overcome the shortcomings of Kalman filtering algorithm for its dependence of process noise and measurement noise statistics during the data fusion, an online adaptive Kalman filter positioning data fuzzy method was proposed. The results of underwater docking in pool tests indicate the position precision is improved by data fusion of vision and SBL position, which proves that the proposed method is effective.

Key words: autonomous underwater vehicle; vision; short baseline; data fusion; fuzzy

AUV(Autonomous Underwater Vehicle)水下自主对接技术为其完成水下作业能源供给、任务使命下载和数据回传等任务提供了重要技术保障。

在 AUV 与水下平台自主对接中,成功对接的关键在于近端对接时 AUV 姿态的数据实时准确获取和对 AUV 的精准控制,传感器数据的精准程度直接决定了完成自主对接的效果,一般采用精度较高的视觉传感器和短基线(Short Baseline, SBL)定位系统进行数据融合^[1]。AUV 与传感器间的距离决定了这两种传感器的能力,当距离较远时, SBL 发挥主

要作用,其获取的姿态数据足以使 AUV 朝大体的方向接近对接平台;当距离适中时,两种传感器同时工作,数据融合系统开始发挥作用^[2]。

由于视觉传感器和 SBL 定位系统在不同作用范围下的精度和可靠性不同,为了使 AUV 能在两套定位系统同时工作时实现精准的自主对接,本文重点研究了两套定位系统同时工作时的定位数据融合方法,并通过水池试验验证了方法的有效性。

1 融合数据的预处理

本文在传感器数据融合之前,对传感器采集过来的数据采用了一种基于软阈值小波方法进行数据滤波^[3-4]。

在 AUV 与平台对接过程中,AUV 携带了多种传感器,用到的视觉传感器和 SBL 每次开机时间并不是同步的,并且视觉传感器的采样频率为 0.5 Hz,SBL 传感器的频率为 2 Hz,由于传感器测量数据的时间并不严格均匀,数据并不是都为均匀采样,存在着时间基准点和采样基准点的不统一。另外各个传感器安装的位置不同,所获取的空间位置必须进行相应的空间坐标变换,统一到同一参考坐标系下来。在进行数据融合之前,传感器的数据必须要进行时间和空间的统一配准。

通常为简化算法,选择一个传感器做为融合中心时基,其他的传感器都随此融合中心进行配准,作为中心时基的传感器一般要求测量频率较高。在视觉传感器和 SBL 数据融合系统中,以 SBL 传感器的时间基作为融合中心基,将视觉传感器的数据匹配到 SBL 时间基上,视觉传感器的采样大多为 0.5 Hz,但存在一定比例的数据采样频率并不严格稳定,其采样依然看作是不均匀采样,对采样时刻不均匀数据一般采用曲线拟合法,在具体的时间配准过程应用如下步骤:

1) 各个传感器的开机时间不一样,数据融合的起点设定在最晚开机的传感器之后;

2) 对于视觉采样的数据,选取 N 个采样点先进行数据拟合,得到基于这 N 个点的光滑曲线函数 $y=f(x)$;

3) 根据 SBL 的采样频率,选取下一拍即 $x(k+1)$ 时间点得到拟合的视觉采样数据,如果视觉传感器在这的拍点上未进行采样,则将拟合的数据作为次拍的采样数据,反之,则用视觉传感器实测数据作为采样数据,送入融合中心。

传感器的空间配准主要是对传感器在各个坐标系下进行空间坐标变化,将各个传感器的坐标配准到同一坐标系下,一般都配准到传感器精度较高的传感器系统坐标下^[5]。对于视觉传感器和 SBL 数据融合系统,视觉传感器在其有效的距离内传感器精度要远高于 SBL,选择将 SBL 的空间配准到视觉传感器坐标系下。

试验采用高度计在初始位置对 AUV 和对接平台静止数据进行初始校准。

2 系统模型描述

目标测量向量位于直角坐标系下,并且视觉的测量模型如式(1)

$$Z_v(k) = H_v(k, X_v(k)) + V_v(k) \quad (1)$$

其中, $Z_v(k) = [x_v \ y_v \ z_v]^T$, x_v , y_v 和 z_v 为视觉传感器测得 AUV 与对接中心点两个轴向距离和高度距离。

$$H_v(k, X(k)) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (2)$$

SBL 的测量模型如式(3)

$$Z_s(k) = H_s(k, X_s(k)) + V_s(k) \quad (3)$$

其中, $Z_s(k) = [x_s \ y_s \ z_s]^T$, x_s , y_s 和 z_s 为 SBL 传感器测的 AUV 与对接中心点两个轴向距离和高度距离。

$$H_s(k, X(k)) = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \quad (4)$$

$V_v(k)$ 和 $V_s(k)$ 分别为零均值的高斯测量噪声,协方差为 $R_v(k)$ 和 $R_s(k)$ 。

离散非线性动态过程模型如式(5)

$$\begin{cases} X(k+1) = F(k+1, k)X(k) + \omega(k) \\ Z(k) = H(k, X(k)) + v(k) \end{cases} \quad (5)$$

其中, $X(k) \in R^n$, $X(k)$ 为第 k 时刻系统的状态向量, $\omega(k) \in R^n$, $\omega(k)$ 为一组零均值高斯白噪声序列,假设其协方差矩阵为 $Q(k)$, $Q(k) = E[\omega(k)\omega(k)^T]$ 。 $F(k+1, k) \in R^{n \times n}$, $F(k+1, k)$, 为已知的状态转移矩阵。

$$F(k+1, k) = \begin{bmatrix} 1 & T & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & T \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (6)$$

式(6)中, T 为采样周期。 $Z(k) \in R^l$, $Z(k)$ 为传感器测量向量, $v(k) \in R^l$, $v(k)$ 为零均值高斯观测噪声,且其协方差为 $R(k) = E[v(k)v(k)^T]$ 。

将式(3)进行线性化得到如下方程

$$\begin{aligned} Z(k) &\approx H(k, \hat{X}(k|k-1)) + \\ &\frac{\partial H[\cdot]}{\partial X} \Big|_{\hat{X}(k,k-1)} [X(k) - \hat{X}(k, k-1)] + v(k) \approx \\ &C(k)X(k) + \bar{Z}(k) + v(k) \end{aligned} \quad (7)$$

其中:

$$\begin{cases} C(k) = \frac{\partial H[\cdot]}{\partial X} \Big|_{\hat{X}(k,k-1)} \\ \hat{Z}(k|k-1) = H(k, \hat{X}(k|k-1)) \\ \bar{Z}(k) = \hat{Z}(k|k-1) - C(k)\hat{X}(k|k-1) \end{cases} \quad (8)$$

式(3)所描述的模型可以通过卡尔曼滤波的方法得到估计值 $\hat{X}(k|k)$ 和预测值 $\hat{X}(k+1|k)$ 。具体融合算法过程入下:首先得到如下估计方程

$$\begin{cases} \hat{X}(k|k) = \hat{X}(k|k-1) + K(k)[Z(k) - \hat{Z}(k|k-1)] \\ K(k) = P(k|k)C^T(k)R^{-1}(k) \end{cases} \quad (9)$$

估计的不确定性由式(10)矩阵得到

$$P^{-1}(k|k) = P^{-1}(k|k-1) + C^T(k)R^{-1}(k)C(k) \quad (10)$$

预测方程定义如式(11)所示

$$\begin{cases} \hat{X}(k+1|k) = F(k+1, k)\hat{X}(k|k) \\ P(k+1|k) = F(k+1, k)P(k|k)F^T(k+1, k) + Q(k) \end{cases} \quad (11)$$

$$\hat{X}_j(k|k) = \hat{X}(k|k-1) + K_j(k)[Z_j(k) - H(k)\hat{X}(k|k-1)] \quad (12)$$

为了更新状态向量, $\hat{X}(k|k-1)$ 通过结合两传感器获得的测量数据 $Z_v(k)$ 和 $Z_s(k)$ 得到。新状态向量的局部估计如式(13)所示

$$\begin{cases} P_j(k|k) = (I - K_j(k)C_j(k))P(k|k-1) \\ j = s, v \end{cases} \quad (13)$$

$$K_j(k) = P(k|k-1)C_j^T(k) * (C_j(k)P(k|k-1)C_j^T(k) + R_j(k))^{-1} \quad (14)$$

最后, 根据标准 Bar-Shalom 公式, 将两个相互联系的估计做最优结合, 即可得到状态的全局估计如式(15)所示

$$\begin{cases} \hat{X}(k|k) = \hat{X}_1(k|k) + (P_v - P_{vs})(P_v + P_s - P_{vs} - P_{sv})(\hat{X}_s(k|k) - \hat{X}_v(k|k)) \\ P(k|k) = P_v - (P_v - P_{12})(P_v + P_s - P_{sv} - P_{vs})^{-1}(P_v - P_{sv}) \end{cases} \quad (15)$$

$P(k|k)$ 为全局误差协方差; $P_{vs}(k|k)$ 和 $P_{sv}(k|k)$ 为两传感器的交互协方差, 并且为了方便, 将其表示为 P_{vs} 和 P_{sv} ; $P_v(k|k)$ 和 $P_s(k|k)$ 为两传感器的局部误差协方差, 表示为 P_v 和 P_s 。

3 模糊自适应 EKF 融合算法

传统的卡尔曼滤波算法要求先得到系统过程噪声和测量噪声的先验统计信息, 即矩阵 $Q(k)$ 和 $R(k)$ 。在实际应用中, 这些数据信息的初始值均为估计得到, 是根据系统的先前经验而得到的, 并且不能做到与系统状态时刻进行的实时更新, 这种先验的估计的准确程度的决定了算法的精确度^[6]。也就是说 EKF 估计算法的实际应用效果与这些先验的统计信息有着直接的关系^[7]。事实证明, 噪声信息的估计误差会严重降低 EKF 算法的准确性, 甚至会导致滤波器的发散^[8,9]。

因此, 本文提出了一种基于模糊逻辑的在线自适应卡尔曼算法。通过获取的实时测量数据, 自适应调整噪声的协方差矩阵, 这种方法的基本思想是使系统残差的协方差实际值与理论值相一致^[10]。残差 $R(k)$ 如式(16)所示的理论协方差

$$S(k) = H(k)(P(k|k-1)H(k)^T + R(k)) \quad (16)$$

实际协方差 $C(k)$ 通过大小为 N 的移动估计窗口内的平均值估计得到, 如式(17)所示

$$\hat{C}(k) = \frac{1}{N} \sum_{i=i_0}^k R_i R_i^T \quad (17)$$

其中: $i_0 = k - N + 1$ 是估计窗口的第 1 个样本。根据经验选择窗口尺寸的大小, 以进行统计滤波。在算法运行过程中, 对实际协方差和理论协方差进行实时比较, 如果 $R(k)$ 的实际协方差和理论协方差有差异, 那么调整 $R(k)$ 修正差异。

定义残差的实际协方差和理论协方差的比值

$$Ra(k) = \frac{Tr(\hat{C}_r(k))}{Tr(S(k))} \quad (18)$$

$Tr()$ 表示对矩阵求迹。从式(18)可知, 如果量测噪声增

大, 则 $\hat{C}_r(k)$ 增大, 继而 $Ra(k)$ 增大, 此时需要增大 $R(k)$ 使 $Ra(k)$ 回到 1 附近; 反之, 如果量测噪声减少, 就需要减小 $Ra(k)$ 。 $Ra(k)$ 的变化由 $t(k)$ 来控制, 即 $t(k) = FIS(Ra(k))$ 。

定义模糊子集 equal1 表示在 1 附近, more1 表示基本大于 1, less1 表示基本小于 1, 调整系数 $t(k)$ 的 FIS 规则如下:

- 1) if $Ra(k)$ is equal1, then $t(k)$ is equal1
- 2) if $Ra(k)$ is less1, then $t(k)$ is less1
- 3) if $Ra(k)$ is more1, then $t(k)$ is more1

4 实验结果

图 1~图 3 为 AUV 对视觉数据和 SBL 数据进行自适应融合后的水池试验结果, 选取系统开机后 350 s 到 550 s 短基线定位系统和视觉定位系统获取 AUV 三个轴向的位置数据, 经过模糊自适应算法进行数据融合后, 其结果表明融合后的位置数据好于单个任意传感器系统的数据, 能为 AUV 水下对接控制系统提供更为可靠的定位数据。

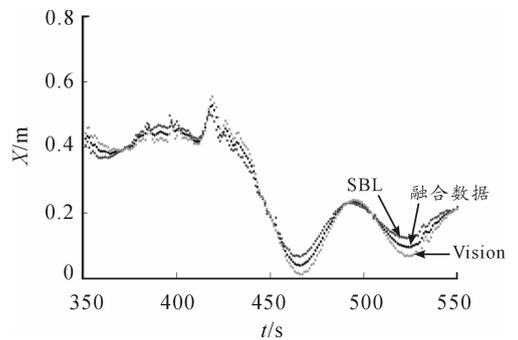


图 1 X 轴向数据融合

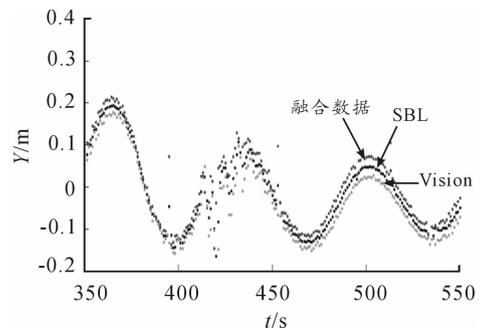


图 2 Y 轴向数据融合

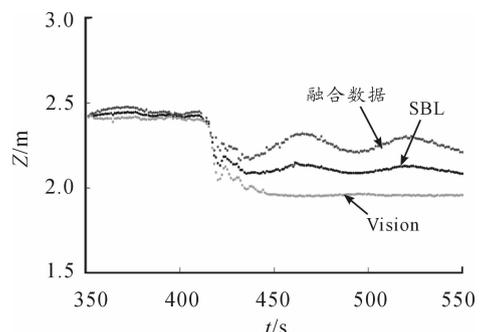


图 3 Z 轴向数据融合

$$N = \text{int} \left(\frac{\sqrt{D_{q\max}^2 - H^2 - d_j^2}}{V_m} + t_s \right) \quad (11)$$

在上述假定条件下,自行高炮在不同高度和航路捷径时的点射次数见表2。在上述假定条件下,自行高炮在不同高度和航路捷径时两次点射的毁伤概率见表3。通过以上分析可知,射击条件不同,该型自行高炮的毁伤概率是不同的,随着点射次数的增加毁伤概率逐渐增大。因此,自行高炮具有较高的毁伤效能。

表2 自行高炮在不同高度和航路捷径时的点射次数

N	d_j	H					
		0	400	800	1 200	1 600	2 000
1 000		4	4	4	4	4	3
2 000		3	3	3	3	3	3
3 000		3	3	3	2	2	2

注:点射为长点射;点射时间为2 s,点射间隔时间为2 s; $V_m = 250 \text{ m/s}$, $\lambda = 0^\circ$ 。

表3 自行高炮战车主从作战模式时在不同高度和航路捷径时两次点射的毁伤概率

N	P_c	d_j					
		600	800	1 000	1 200	1 400	2 000
1 000		0.731 5	0.782 2	0.710 3	0.634 5	0.564 1	0.408 6
1 500		0.587 1	0.665 1	0.665 0	0.597 0	0.532 2	0.386 9
2 000		0.457 6	0.575 1	0.560 5	0.575 4	0.517 8	0.376 1

注:点射为长点射,采用点射步长为6,点射次数为2; H 为目标高度, d_j 为目标航路投影捷径, d 为目标水平距离。

5 结束语

本文着重对自行高炮主从作战模式下火力毁伤效能进行分析计算,得出从作战模式时在不同高度下一个点射的毁伤概率、主从作战模式时在不同高度和航路捷径时两个点射的毁伤概率等重要数值,具有一定的适用性。

参考文献:

- [1] 王兴春. 防空兵作战效能分析[M]. 郑州:防空兵指挥学院,2005.
- [2] 田隼华. 高炮武器系统效能分析[M]. 北京:国防工业出版社,1985.
- [3] 张最良. 军事运筹学[M]. 北京:军事科学出版社出版社,1993.
- [4] 曹泽阳,高虹霓,王颖龙. 区域防空部署射击效能评估模型[J]. 系统工程与电子技术,2003(3):32-35.
- [5] 韩松臣. 导弹武器系统效能分析的随机理论方法[M].

北京:国防工业出版社,2001.

- [6] 刘天坤,胡志学,刘养科. 防空武器系统效能分析[J]. 火力与指挥控制,2007(7):65-68.
- [7] 万自明,廖良才,陈英武. 武器系统效能评估模式研究[J]. 系统工程与电子技术,2000(3):23-26.

(责任编辑 杨继森)

(上接第62页)

5 结束语

本文研究了基于视觉与短基线定位系统的AUV数据融合定位方法,为提高水下定位精度,提出了一种基于模糊自适应思想的卡尔曼滤波数据融合方法。水池试验结果表明:融合后的定位数据优于单传感器定位系统,为AUV水下自主对接提供了更可靠的定位数据。

参考文献:

- [1] 燕奎臣,吴利红. AUV水下对接关键技术研究[J]. 机器人,2007,29(3):267-273.
- [2] 晏正新. UUV回收对接的数据融合及预报方法研究[D]. 哈尔滨:哈尔滨工程大学,2012:38-41.
- [3] DONOHO D L. Deoising by Soft-threthoding [J]. IEEE Trans on Info Theory,1995,5(41):613-627.
- [4] 张帆,卢峰. 自适应抗野值Kalman滤波[J]. 电机与控制学报,2007,11(2):188-195.
- [5] 邓自立. 信息融合滤波理论及其应用[M]. 哈尔滨:哈尔滨工业大学出版社,2007:78-156;272-404.
- [6] 程峰. 多传感器目标跟踪中的数据融合理论与算法[D]. 西安:西北工业大学,2007:9-15.
- [7] 王晓娟. 基于视觉的AUV水下回收导引定位技术研究[D]. 哈尔滨:哈尔滨工程大学,2011:68-69.
- [8] 宋振华,战兴群,张炎华. 基于多传感器融合的水下机器人导航系统[J]. 机器人技术,2008,24(1-2):240-241.
- [9] GAN Q,HARRIS C. J. Comparison of two measurement fusion methods for kalman-filter based multisensor data fusion [J]. IEEE Trans. on Aerospace and Electronic Systems, 2001,37(1):273-279.
- [10] 严涛,王跃刚,杨波,等. 模糊自适应卡尔曼滤波算法在航位推算系统中的应用[J]. 计算机测量与控制,2012,20(3):774-796.

(责任编辑 杨继森)