

引用格式:刘艳,程诚,裴少婧.鲁棒自适应无迹卡尔曼滤波的SLAM算法[J].电光与控制,2019,26(8):12-16,23. LIU Y, CHENG C, PEI S J. SLAM algorithm for robust adaptive unscented Kalman filtering[J]. Electronics Optics & Control, 2019, 26(8):12-16, 23.

鲁棒自适应无迹卡尔曼滤波的SLAM算法

刘艳^{1,2}, 程诚^{1,2}, 裴少婧³

(1. 大连大学辽宁省北斗高精度位置服务技术工程实验室, 辽宁 大连 116622; 2. 大连大学大连市环境感知与智能控制重点实验室, 辽宁 大连 116622; 3. 中原工学院机电学院, 郑州 450007)

摘要:针对SLAM在复杂环境下对噪声干扰鲁棒性差以及运动轨迹预测误差问题,在UKF中引入自适应估计理论与鲁棒 H_∞ 控制准则,提出一种鲁棒自适应UKF-SLAM算法。该算法利用自适应估计理论,构建抗差因子和自适应因子,自适应估计测量和状态噪声等价协方差阵,实现粗差分离和噪声方差自适应补偿;利用鲁棒 H_∞ 控制准则对系统状态均值和协方差进行迭代更新,提高噪声干扰鲁棒性、降低预测误差。仿真结果表明:该算法能保证移动机器人在不同噪声环境下具有良好的鲁棒性与定位精度。

关键词: 移动机器人; SLAM; 无迹卡尔曼滤波; 自适应估计; 抗差估计

中图分类号: TP24 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.08.003

SLAM Algorithm for Robust Adaptive Unscented Kalman Filtering

LIU Yan^{1,2}, CHENG Cheng^{1,2}, PEI Shao-jing³

(1. Liaoning Engineering Laboratory of Beidou High-Precision Location Service, Dalian University, Dalian 116622, China;
2. Dalian Key Laboratory of Environmental Perception and Intelligent Control, Dalian University, Dalian 116622, China;
3. Zhongyuan University of Technology, Zhengzhou 450007, China)

Abstract: In order to solve the problem of poor robustness of Simultaneous Localization and Mapping (SLAM) to noise interference and motion trajectory prediction error in complex environment, the adaptive estimation theory and robust H_∞ control criterion are introduced into UKF, and a robust adaptive UKF-SLAM algorithm is proposed. The algorithm uses adaptive estimation theory to construct the robust factor and the adaptive factor, adaptively estimates the equivalent covariance matrix of measurement and state noise, and realizes coarse error separation and adaptive compensation of noise variance. The robust H_∞ control criterion is used to iteratively update the system state mean and covariance to improve the robustness to noise interference and reduce the prediction error. Simulation results show that the algorithm can ensure that the mobile robot has good robustness and positioning accuracy in different noise environment.

Key words: mobile robot; SLAM; UKF; adaptive estimation; robust estimation

0 引言

同步定位与地图构建(Simultaneous Localization and Mapping, SLAM)是解决移动机器人真正自主导航的关键技术,主要用于解决移动机器人在未知环境中的定位问题,移动机器人搭载特定传感器,在没有环境先验信息的情况下,在运动过程中建立环境模型,同时兼顾

自身的运动轨迹^[1-2]。

目前国内外学者主要采用各种滤波方法来提高SLAM的定位精度,其中最普遍的方法是扩展卡尔曼滤波(Extended Kalman Filter, EKF)算法,它被广泛用于解决室内外、水下及空中移动机器人的导航定位^[3-5]。但是EKF-SLAM存在线性化累积误差大、易发散和估计精度低以及不一致性等问题。JULIER等^[6]提出了无迹卡尔曼滤波的SLAM算法(UKF-SLAM),以无迹变换(UT)为基础,通过使用加权统计线性回归过程实现随机线性化,规避了EKF-SLAM线性化过程中泰勒展开式高阶项的忽略,有效地降低了SLAM问题线性化的累积误差和

收稿日期:2018-08-22 修回日期:2019-07-11

基金项目:国家自然科学基金(61271379)

作者简介:刘艳(1967—),女,辽宁大连人,博士,教授,研究方向为智能机器人技术和物联网感知技术。

发散概率。

为提高 UKF-SLAM 算法复杂环境下的抗噪鲁棒性及运动轨迹一致性,目前主要有自适应估计与鲁棒 H_∞ 方法。关于自适应估计的研究主要有:文献[7]提出了一种基于平滑变结构滤波器(ASVSF)的自适应方法,引入协方差矩阵来评估 SVSF 的估计不确定性,以解决水下机器人 SLAM 问题;文献[8]提出了一种能克服模型失配问题的新型 SLAM 算法,通过自适应滤波增益,进一步修正了定位和映射的准确性;文献[9]引入了一个多维观测噪声尺度因子,根据观测噪声统计特性的实际变化情况对每种传感器的噪声模型做出自适应调整;文献[10]提出一种对噪声自适应的 UKF-SLAM 算法,利用噪声缩放和观测残差序列准确估计了状态噪声模型。根据新息和残差序列的变化情况对噪声协方差矩阵进行在线调整,使滤波器具有自适应能力,精度有所提高,但对于现实环境中的噪声,缺乏对非线性噪声的自适应调控,仍缺少一定的鲁棒性且无法处理突变噪声。 H_∞ 滤波具有较强的鲁棒性,可将噪声干扰到估计误差的最大能量增益控制在较小范围内,可最小化恶劣噪声对估计误差干扰的影响,在 SLAM 领域抗噪滤波中具有很好的应用前景^[11-15],但对于线性过程缺乏自适应调整。

本文在自适应 UKF-SLAM 算法中引入自适应估计和鲁棒 H_∞ 控制准则,提出一种鲁棒 H_∞ 自适应 UKF-SLAM 算法,实现粗差分离、位姿方差补偿、等价协方差估计,并在鲁棒 H_∞ 控制准则下对 UKF-SLAM 算法进行迭代更新,通过结合二者的优点,有效地规避了应对不同噪声情况下鲁棒性差和缺乏自适应调整的缺点。最后,在不同噪声干扰环境下,对本文改进的 SLAM 算法、UKF-SLAM 算法、CEHF-SLAM 算法性能进行了仿真对比实验,验证了本文 SLAM 改进算法的鲁棒性及有效性。

1 SLAM 算法

1.1 SLAM 问题的数学描述

目前对于 SLAM 问题的研究都是采用概率密度的方法。SLAM 问题通过将每个机器人的位姿和地图位置表示为概率密度函数,用递归的贝叶斯条件概率公式进行估计。

SLAM 问题可以表示为

$$p(x_k, m | z_{1:k}, u_{1:k}) \quad (1)$$

式中: x_k 为 k 时刻机器人的位姿; m 为地图; $z_{1:k}$ 和 $u_{1:k}$ 分别是测量值和控制值。

根据贝叶斯理论,可以给定式(1)的 SLAM 后验。首先进行预测,后验由全后验对过去机器人位姿 $p(x_k | z_{1:k}, u_{1:k})$ 积分和对过去一致性求和得到:

$$p(x_k, m | z_{1:k-1}, u_{1:k}) =$$

$$\int p(x_k | x_{k-1}, u_{1:k}) p(x_{k-1}, m | z_{1:k-1}, u_{1:k-1}) dx_{k-1} \quad (2)$$

然后进行观测更新,用搭载传感器观测的数据,即通过观测模型 $p(z_k | x_k, m)$ 对后验概率分布进行校正:

$$p(x_k, m | z_{1:k}, u_{1:k}) = \eta p(z_k | x_k, m) p(x_k, m | z_{1:k-1}, u_{1:k}) \quad (3)$$

式中, η 为归一化系数。

1.2 UKF-SLAM 算法

UKF-SLAM 算法包括预测和观测更新两部分。假设移动机器人的运动模型和观测模型分别为

$$X_k = f(x(k-1), u(k)) + w(k) \quad (4)$$

$$z_k = h(x_k) + \delta_k \quad (5)$$

式中, w_k 和 δ_k 分别为运动过程和观测过程中的噪声,且服从 $N(0, Q_k)$ 和 $N(0, R_k)$ 。

UKF-SLAM 中的预测和观测更新具体如下。

UKF-SLAM 预测时,为了求其状态向量的均值和方差,设 $X(k)$ 为 n 维,选 $(2n+1)$ 个 Sigma 点进行采样, Sigma 点的采样规则为

$$x_{i,k-1|k-1} = \begin{cases} \hat{x}_{k-1}^a & i=0 \\ \hat{x}_{k-1}^a - (\sqrt{(n+1)P_{k-1|k-1}^a}) & i=1,2,\dots,n \\ \hat{x}_{k-1}^a + (\sqrt{(n+1)P_{k-1|k-1}^a}) & i=n+1,n+2,\dots,2n \end{cases} \quad (6)$$

式中, $\sqrt{(n+1)P_{k-1|k-1}^a}$ 表示矩阵 $(n+1)P_{k-1|k-1}^a$ 的平方根矩阵的第 i 列,可通过 Cholesky 分解获得,对高斯分布一般取 $n+1=3$ 。将上述 Sigma 点代入非线性运动模型中,可以得到经过变换以后的 Sigma 点集 $x_{i,k|k-1}$,所以得到预测的均值和协方差矩阵分别为

$$\hat{x}_{k|k-1} = \sum_{i=0}^{2n} w_i Z_{i,k|k-1} \quad (7)$$

$$P_{k|k-1} = \sum_{i=0}^{2n} w_i [x_{i,k|k-1} - \hat{x}_{k|k-1}] \times [x_{i,k|k-1} - \hat{x}_{k|k-1}]^T \quad (8)$$

在观测更新的过程中,参照式(8)的 Sigma 点采样规则,计算出新的 Sigma 点集,均值为 $\bar{x}_{k|k-1}$,协方差矩阵为 $P_{k|k-1}$,并将其代入观测模型中,得到 $Z_{i,k|k-1} = h(x_{i,k|k-1})$,则相对应的均值和方差分别为

$$\hat{z}_{k|k-1} = \sum_{i=0}^{2n} w_i Z_{i,k|k-1} \quad (9)$$

$$S_k = \sum_{i=0}^{2n} w_i [Z_{i,k|k-1} - \bar{z}_{k|k-1}] \times [Z_{i,k|k-1} - \bar{z}_{k|k-1}]^T + R_k \quad (10)$$

设新息为 V_k ,即 $V_k = z_k - \hat{z}_{k|k-1}$,则可以计算出 k 时刻的均值和协方差分别为

$$\bar{x}_k = \bar{x}_{k|k-1} + W_k V_k \quad (11)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} + \mathbf{W}_k \mathbf{V}_k \mathbf{W}_k^T \quad (12)$$

式中, $\mathbf{W}_k = \mathbf{P}_{xx,k|k-1} \mathbf{S}_k^{-1}$ 为卡尔曼增益, $\mathbf{P}_{xx,k|k-1}$ 为相交协方差阵。

最后,进行对地图的状态和协方差矩阵的更新。

2 鲁棒自适应 UKF-SLAM 算法

针对噪声干扰鲁棒性差以及运动轨迹预测误差问题,利用抗差估计对观测和状态矩阵构造等价协方差矩阵,从而提高了对噪声统计的准确性;利用鲁棒 H_∞ 控制准则对系统状态均值和方差进行迭代更新。

利用抗差估计原理实现 UKF 的自适应滤波,首先根据抗差 M 估计准则,利用观测误差方程和状态误差方程两式构造准则函数式

$$\Omega_{\min} = \mathbf{V}_{\bar{\mathbf{Y}}_k}^T \bar{\mathbf{R}}_k^{-1} \mathbf{V}_{\bar{\mathbf{Y}}_k} + \mathbf{V}_{\bar{\mathbf{X}}_k}^T \bar{\mathbf{P}}_k^{-1} \mathbf{V}_{\bar{\mathbf{X}}_k} \quad (13)$$

式中: $\bar{\mathbf{R}}_k$ 是 \mathbf{Y}_k 的等价准协方差矩阵; $\bar{\mathbf{P}}_k$ 是 \mathbf{X}_k 的等价准协方差矩阵。利用此式获得新的更新状态。

式(13)的意义是对观测值和参数先验值进行 M 估计。

2.1 矩阵等价协方差阵

为了提高观测噪声统计的准确性,减小观测中粗差的影响,首先,采用了抗差估计中的 IGG1 权函数,实现对测量值粗差和异常值的分离,提高估计的准确性,本文根据等价权原理对式(13)中的测量噪声协方差值 $\bar{\mathbf{R}}_k$ 系数进行抗差估计,得其抗差权为

$$w(v_i) = \begin{cases} 1 & |\bar{v}_i| \leq k_0 \\ \frac{k_0}{|\bar{v}_i|} & k_0 < |\bar{v}_i| \leq k_1 \\ 0 & k_1 > |\bar{v}_i| \end{cases} \quad (14)$$

式中: k_0 为参数,一般取 $k_0 = 1.5$; k_1 为淘汰点,一般取 $k_1 = 2.5$; w 表示抗差因子。此法将观测值分为 3 部分: $|\bar{v}_i| \leq k_0$ 时,采用原观测值的权,即最小二乘法; $k_0 < |\bar{v}_i| \leq k_1$ 时,采用绝对值和极小法; $k_1 > |\bar{v}_i|$ 时,观测值不可用,取 0 值,即淘汰法。其等价权为

$$\bar{r}_{ij} = r_{ij} w(v_j) \quad (15)$$

式中, r_{ij} 为噪声方差阵 \mathbf{R}_k 的 i 行 j 列的参数。

然后利用 N 个新息向量对观测残差的协方差矩阵进行自适应估计。通过对滤波过程中新息序列统计分析,自适应估计出随机测量和系统随机误差的方差。一组长度为 N 的新息序列

$$\mathbf{V}_k = \mathbf{Y}(k+1) - \bar{\mathbf{Y}}(k+1) = [v_1 \ v_2 \ v_3 \ \cdots \ v_n] \\ k = 1, 2, \dots, n \quad (16)$$

加入抗差权函数,减小粗差和异常值的影响。

$$\bar{\mathbf{V}}_k = \mathbf{W}^T \mathbf{V}_k = [w(v_1)v_1 \ w(v_2)v_2 \ \cdots \ w(v_n)v_n] \quad (17)$$

通过式(16)求出测量噪声协方差值

$$\bar{\mathbf{R}}_k = \frac{1}{N} \sum_{i=1}^N \bar{\mathbf{V}}_{k-i} \bar{\mathbf{V}}_{k-i}^T \quad (18)$$

利用式(18)计算在 k 时刻测量噪声协方差值。在 $k+1$ 时刻,在新息序列 $[\bar{\mathbf{V}}_1, \dots, \bar{\mathbf{V}}_k, \dots, \bar{\mathbf{V}}_N]$ 中每增加一个时刻的新息数据 $\bar{\mathbf{V}}_{N+1}$,则去掉最久的新息数据 $\bar{\mathbf{V}}_1$ 。

2.2 构建自适应因子

为了提高状态噪声统计的精确性,对式(13)中 $\bar{\mathbf{P}}_k$, 在单独测量值求解的基础上,整体控制状态噪声协方差矩阵。其预测残差为

$$|\Delta \tilde{\mathbf{X}}_k| = \|\bar{\mathbf{X}}_k - \tilde{\mathbf{X}}_k\| / \sqrt{\text{tr}(\mathbf{P}_{\tilde{\mathbf{X}}_k}^{-1})} \quad (19)$$

当预测残差值较小时,对于前 N 个时刻的状态预测残差,应用开窗法估计;当预测残差值较大时,采用残差 $\Delta \tilde{\mathbf{X}}_k$ 构建自适应因子 α

$$\alpha = \begin{cases} 1 & |\Delta \tilde{\mathbf{X}}_k| < c \\ \frac{c}{|\Delta \tilde{\mathbf{X}}_k|} & |\Delta \tilde{\mathbf{X}}_k| \geq c \end{cases} \quad (20)$$

式中, c 一般取 2.5。所以,状态噪声的等价协方差矩阵可以表示为

$$\bar{\mathbf{P}}_k = \begin{cases} \mathbf{P}_k = \frac{1}{N} \sum_{i=1}^N \bar{\mathbf{V}}_k & |\Delta \tilde{\mathbf{X}}_k| < c \\ \mathbf{P}_k / \alpha & |\Delta \tilde{\mathbf{X}}_k| \geq c \end{cases} \quad (21)$$

2.3 算法步骤

鲁棒自适应 UKF-SLAM 算法步骤如下所述。

1) 观测预测。

对应式(4)增广结合控制噪声的均值和协方差,将 k 时刻的机器人系统状态 \mathbf{x}_k 和状态协方差矩阵 $\mathbf{P}_{k|k}$ 增广为 \mathbf{x}_k^a 和 $\mathbf{P}_{k|k}^a$, 即

$$\mathbf{x}_{k-1}^a = \begin{bmatrix} \mathbf{x}_{k-1} \\ \mathbf{0} \end{bmatrix} \quad (22)$$

$$\mathbf{P}_{k-1|k-1}^a = \begin{bmatrix} \mathbf{P}_{k-1|k-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{Q}_t \end{bmatrix} \quad (23)$$

式中, \mathbf{Q}_t 是服从高斯分布的噪声矩阵。

产生 $2n+1$ 点进行采样,得式(6),进而得到状态均值式(7)和协方差式(8)。

2) 观测更新。

将观测模型获得的观测信息数据(即环境特征)与真实环境中已存在的特征进行数据关联,若某一个时刻重复观测到地图上的同一个特征,则需依据观测信息更新机器人状态。从观测信息中获得一系列 Sigma 点样本,即将 Sigma 点样本代入非线性观测模型

$$\mathbf{Z}_{i,k|k-1} = h(\mathbf{x}_{i,k|k-1}^*) \quad (24)$$

利用传播变换后的 Sigma 点集推导观测协方差矩

阵和相交协方差矩阵分别为

$$\mathbf{P}_{z,klk-1} = \sum_{i=0}^{2n} w_i [\hat{\mathbf{z}}_{klk-1} - \bar{\mathbf{z}}_{klk-1}] \times [\mathbf{Z}_{i,klk-1} - \bar{\mathbf{z}}_{klk-1}]^T \quad (25)$$

$$\mathbf{P}_{xz,klk-1} = \sum_{i=0}^{2n} w_i [\mathbf{x}_{i,klk-1} - \bar{\mathbf{x}}_{klk-1}] \times [\mathbf{Z}_{i,klk-1} - \bar{\mathbf{z}}_{klk-1}]^T \quad (26)$$

更新机器人 k 时刻状态

$$\bar{\mathbf{K}}_{k+1} = \mathbf{P}_{yy} [\mathbf{P}_{yy} + \bar{\mathbf{R}}_k]^{-1} \quad (27)$$

$$\tilde{\mathbf{X}}_{k+1|k+1} = \bar{\mathbf{X}}_{k+1|k} + \bar{\mathbf{K}}_{k+1} [\mathbf{Y}_{k+1} - \bar{\mathbf{Y}}_{k+1|k}] \quad (28)$$

$$\mathbf{P}_{k+1|k+1} = \bar{\mathbf{P}}_{k+1|k} - \bar{\mathbf{K}}_{k+1} [\bar{\mathbf{P}}_{yy} + \bar{\mathbf{R}}_k] \bar{\mathbf{K}}_{k+1}^T \quad (29)$$

利用 2.1 和 2.2 节中的公式,通过抗差权函数和自适应因子计算观测矩阵等价协方差阵和状态矩阵等价协方差阵,其中用式(27)计算出 $\bar{\mathbf{R}}_k$,用式(29)计算出 $\mathbf{P}_{k+1|k+1}$ 。

在迭代更新前,应用鲁棒 H_∞ 控制准则进行判断,进一步提高估计精度,即

$$\frac{\sum_{k=0}^N \|\tilde{\mathbf{z}}_k\|^2}{\|\mathbf{z}_0 - \hat{\mathbf{z}}_{0|1}\|_{\mathbf{P}_{0|1}}^2 + \sum_{k=0}^{N-1} \|\mathbf{w}_k\|_{\mathbf{Q}_k}^2 + \sum_{k=0}^{N-1} \|\mathbf{v}_k\|_{\mathbf{R}_k}^2} < \gamma^2 \quad (30)$$

具体迭代过程如下

$$\hat{\mathbf{z}}_{klk}^d = h(\hat{\mathbf{x}}_{klk}) \quad (31)$$

$$\bar{\mathbf{z}}_{klk}^d = \mathbf{z}_{klk}^d - \hat{\mathbf{z}}_{klk}^d \quad (32)$$

$$\bar{\mathbf{x}}_{klk}^d = \hat{\mathbf{x}}_{klk}^d - \hat{\mathbf{x}}_{klk}^{d-1} \quad (33)$$

$$[\bar{\mathbf{x}}_{klk}^d]^T \mathbf{P}_{klk}^d \bar{\mathbf{x}}_{klk}^d + [\hat{\mathbf{z}}_{klk}^d]^T \mathbf{R}_k^{-1} \hat{\mathbf{z}}_{klk}^d < [\bar{\mathbf{z}}_{klk}^d]^T \mathbf{R}_k^{-1} \bar{\mathbf{z}}_{klk}^d \quad (34)$$

式中, \mathbf{z}_{klk}^d 为 k 时刻的观测值, d 为迭代次数(为保证实时性一般小于 3)。若式(34)成立,且 $d \leq 3$,则返回重新采样;否则,结束迭代,返回系统状态均值 $\hat{\mathbf{x}}_{klk-1}$ 和协方差 \mathbf{P}_{klk-1} 。

3 仿真与实验对比

3.1 Matlab 仿真实验环境

为了验证算法的性能,采用悉尼大学 Tim Bailey 公开的仿真环境和 Matlab2014b 仿真软件,所有的实验都是在一台主频为 3.60 GHz 的 Intel 处理器,8 GiB 内存的计算机上完成的。仿真实验区域设定为 250 m × 200 m 的室外环境,其中包含实验人为设定的 17 个航点和 35 个路标点。机器人从地图的原点出发,逆时针方向运行。实验参数和环境分别如表 1 和图 1,实验模型为

$$\begin{bmatrix} x(k) \\ y(k) \\ \theta(k) \end{bmatrix} = \begin{bmatrix} x(k-1) + V\Delta t \cos(G + \theta(k-1)) \\ y(k-1) + V\Delta t \sin(G + \theta(k-1)) \\ \theta(k-1) + V\Delta t \end{bmatrix} \quad (35)$$

表 1 实验参数

Table 1 Experimental parameters

参数	数据
速度/(m · s ⁻¹)	3
最大转向角/(°)	30
转向角变化率/(° · s ⁻¹)	20
系统采样间隔/s	0.025
车体轴距/m	4
速度误差/(m · s ⁻¹)	0.3
转向角误差/(°)	2
激光采样时间/s	0.2
最大探测距离/m	30
距离误差/m	0.2
角度误差/(°)	1





图 1 实验环境


Fig. 1 Experimental environment

3.2 仿真实验对比


在不同噪声环境下,对 UKF-SLAM 算法、CEHF-SLAM 算法和本文算法进行仿真实验对比,如图 2 所示。



a UKF-SLAM 算法



b CEHF-SLAM 算法



c 本文算法

图 2 不同算法移动机器人运动轨迹

Fig. 2 Mobile robot trajectory of different algorithms

图 3 所示为 3 种算法均平方根误差对比。




图 3 3 种算法均平方根误差
Fig. 3 RMSE of the three algorithms

从图 3 可以看出,UKF-SLAM 算法误差很大,误差会产生累积并偏离真实航向,不能达到定位的精度要求,无法完成现实中所需的导航定位要求;而 CEHF-SLAM 算法和本文算法总体均平方根误差控制在 4 m 以内,并且在大部分情况下本文算法的误差小于 CEHF-SLAM 算法,有效地去除了粗差的影响,并得到较为精确的机器人运行的轨迹,可以满足导航定位的精度要求。

为了验证 3 种算法的鲁棒性,改变噪声的强度,观测噪声由(0.2 m,1°)调整为(0.6 m,5°)。仿真实验如图 4 所示。

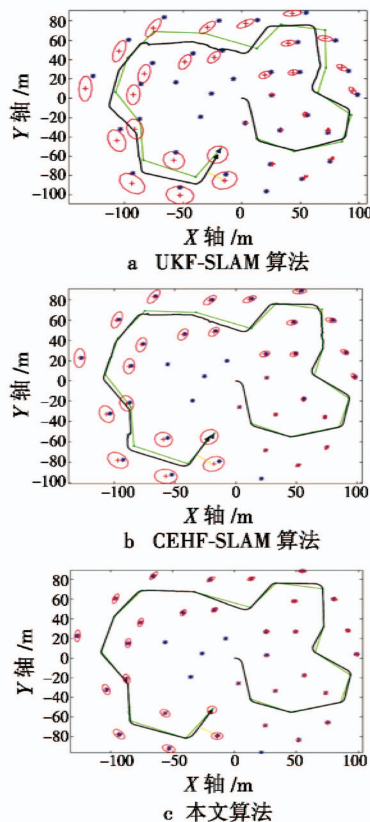


图 4 改变噪声强度后不同算法移动机器人运动轨迹
Fig. 4 Mobile robot trajectory of different algorithms after changing noise intensity

图 5 所示为改变噪声强度后 3 种算法均平方根误差对比。

差对比。




图 5 改变噪声强度后 3 种算法均平方根误差
Fig. 5 RMSE of the three algorithms after changing noise intensity

仿真实验结果表明,当实验环境改变后,相比于其他两种算法,本文算法运动轨迹估计更精确;并且,均平方根误差在 4 m 以下,其波动幅度小且稳定,表明了本文算法对不同恶劣环境下的噪声干扰具有良好的鲁棒性,从而验证了本文算法的可行性。

4 结论

本文提出了一种鲁棒自适应 UKF-SLAM 算法,该算法利用了抗差估计理论,自适应估计了测量和状态噪声等价协方差阵,利用鲁棒 H_∞ 控制准则对系统状态均值和协方差进行迭代更新,提高了移动机器人定位精度。通过仿真实验,与 UKF-SLAM 算法和 CEHF-SLAM 算法进行了对比,证明本文算法是一种有效的移动机器人 SLAM 算法。

参考文献

- [1] EMHARRAF M, BOURHALEB M, SABER M, et al. Mobile robot SLAM implementation for unknown indoor environment exploration[J]. Journal of Computer Science, 2016, 12(2):106-112.
- [2] 陈晨,程荫杭. 基于迭代无迹卡尔曼滤波的 SLAM 算法仿真研究[J]. 系统仿真学报, 2012, 24(8):1643-1650.
- [3] HULETSKI A, KARTASHOV D, KRINKIN K. TinySLAM improvements for indoor navigation[C]//IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, 2016:493-498.
- [4] 张焯林,王养柱,韩震. 基于 FastSLAM 算法的无人机着陆方法[J]. 电光与控制, 2017, 24(9):83-87,108.
- [5] BAI F, VIDAL-CALLEJA T A, HUANG S D. Robust incremental SLAM under constrained optimization formulation[J]. IEEE Robotics and Automation Letters, 2018, 3(2):1207-1214.
- [6] JULIER S J, UHLMANN J K, DURRANT-WHYTE H F. A new approach for filtering nonlinear systems[C]//Proceedings of American Control Conference, 1995:1-5.

(下转第 23 页)

- Computational Intelligence and Design, 2015:417-421.
- [4] ZONG Q, SHAO S K. Decentralized finite-time attitude synchronization for multiple rigid spacecraft via a novel disturbance observer[J]. ISA Transactions, 2016, 65:150-163.
- [5] BAYEZIT I, FIDAN B. Distributed cohesive motion control of flight vehicle formations[J]. IEEE Transactions on Industrial Electronics, 2013, 60(12):5763-5772.
- [6] HE L L, BAI P, LIANG X L, et al. Feedback formation control of UAV swarm with multiple implicit leaders[J]. Aerospace Science and Technology, 2017, 72:327-334.
- [7] WANG J Y, DUAN Z S, LI Z K, et al. Distributed H_∞ and H_2 consensus control in directed networks[J]. IET Control Theory and Applications, 2014, 8(3):193-201.
- [8] HOU Z C, FANTONI I. Distributed leader-follower formation control for multiple quadrotors with weighted topology [C]//The 10th IEEE System of Systems Engineering Conference, 2015:256-261.
- [9] NIAN X H, SU S J, PAN H. Consensus tracking protocol and formation control of multi-agent systems with switching topology[J]. Journal of Central South University of Technology, 2011, 18(4):1178-1183.
- [10] ZHOU Y, DONG X W, LU G, et al. Time-varying formation control for unmanned aerial vehicles with switching interaction topologies[J]. Control Engineering Practice, 2014, 46:1203-1209.
- [11] 刘伟,周绍磊,祁亚辉,等. 有向切换通信拓扑下多无人机分布式编队控制[J]. 控制理论与应用, 2015, 32(10):1422-1427.
- [12] 茹常剑,魏瑞轩,戴静,等. 基于纳什议价的无人机编队自主重构控制方法[J]. 自动化学报, 2013, 39(8):1349-1359.

(上接第16页)

- [7] DEMIM F, BOUCHELOUKH A, NEMRA A, et al. A new adaptive smooth variable structure filter SLAM algorithm for unmanned vehicle [C]//International Conference on Systems and Control, 2017:6-13.
- [8] JIANG X Y, LI T T, YU Y H. A novel SLAM algorithm with adaptive Kalman filter [C]//International Conference on Advanced Robotics and Mechatronics, 2016:107-111.
- [9] 杜航原,郝燕玲,高忠强,等. 基于鲁棒非线性卡尔曼滤波的自适应 SLAM 算法[J]. 宇航学报, 2012, 33(5):620-627.
- [10] 王祖麟,秦菘,梁毓明. 基于噪声缩放的自适应 UKF-SLAM 算法[J]. 计算机工程, 2014, 40(10):143-149.
- [11] PHAM V C, JUANG J C. Robust and efficient SLAM via compressed H_∞ filtering[J]. Asian Journal of Control, 2014, 16(3):878-889.
- [12] 朱奇光,袁梅,陈卫东,等. 基于 CEH^{*}F 的移动机器人 SLAM 算法研究[J]. 仪器仪表学报, 2015, 36(10):2304-2311.
- [13] YU Y H. Combining H_∞ filter and cost-reference particle filter for conditionally linear dynamic systems in unknown non-Gaussian noises[J]. Signal Processing, 2013, 93(7):1871-1878.
- [14] 罗元,苏琴,张毅,等. 基于迭代无迹 H_∞ 滤波的移动机器人 SLAM[J]. 计算机科学, 2017, 44(8):306-311.
- [15] HUR H, AHN H S. Discrete-time H_∞ filtering for mobile robot localization using wireless sensor network [J]. IEEE Sensors Journal, 2013, 13(1):245-252.



请扫描二维码关注我刊