

DOI:10.3969/j.issn.1001-4551.2014.01.024

一种基于增广 EKF 的移动机器人 SLAM 方法^{*}

肖 雄^{1,2}, 李 旦^{1,2}, 陈 锡 锻^{1,2}, 李 刚^{1,2*}

(1. 浙江工业大学 信息工程学院,浙江 杭州 310023;2. 浙江省信号处理重点实验室,浙江 杭州 310023)

摘要:针对移动机器人同步定位与地图构建(SLAM)过程中系统测程法误差累积问题,采用测程法误差模型和车轮速度误差模型的映像关系,结合增广扩展卡尔曼滤波(AEKF)算法结构和实际机器人模型,提出了一种有效提高定位精度的 SLAM 方法。将机器人速度校正参数附加到卡尔曼滤波算法的向量空间中,以形成增广状态空间,同时预测和更新了 SLAM 初始状态空间和速度校正参数,笔者在线实时修正机器人的速度和航向角,避免积累航向角误差,从而降低了测程法误差。基于均方根误差和归一化估计方差进行了仿真实验分析,研究结果表明:与 EKF-SLAM 相比,所提出的方法具有更好的估计性能,使算法保持良好的一致性,大幅度提高了机器人自身定位精度和路标估计准确度。

关键词:增广扩展卡尔曼滤波;同步定位与地图构建;测程法误差;均方根误差;归一化误差

中图分类号:TP242

文献标志码:A

文章编号:1001-4551(2014)01-0109-05

SLAM method based on augmented EKF for mobile robot

XIAO Xiong^{1,2}, LI Dan^{1,2}, CHEN Xi-duan^{1,2}, LI Gang^{1,2}

(1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China;
2. Zhejiang Key Laboratory for Signal Processing, Hangzhou 310023, China)

Abstract: Aiming at the problem that the accumulation of systematic odometry error in the process of simultaneous localization and mapping (SLAM), by adopting the relationship of the odometry error model mapped to velocity error model of each wheel and combining augmented extended Kalman filter(AEKF) algorithm structure and considering reality robot model, one SLAM method efficiently improving the precision of localization was proposed. The systematic velocity calibration parameters were appended to the state vector of EKF-SLAM algorithm becoming an augmented state, and then these parameters and the SLAM initial vector were predicted and updated. Through revising the robot's velocity and orientation online, the orientation error and odometry error were decreased. The root mean squared error(RMSE) and normalized estimation error squared(NEES) were tested. The results indicate that, comparing with conventional EKF-SLAM, the proposed method has better estimation performance, keeps the algorithm consistency and generates more accurate robot localization and feature map.

Key words: augment extended Kalman filter; simultaneous localization and mapping(SLAM); odometry error; root mean squared error; normalized estimation error square

0 引言

自主移动机器人在未知环境中,行进时通过自身位姿估计和传感器观测信息增进式地构建环境地图,同时利用该地图实现自身定位和导航。这就是移动机

器人同步定位与地图构建(SLAM)^[1]。该问题一直是智能移动机器人研究领域的热点和难点,被认为是能否真正实现机器人自主导航的关键问题。

机器人在行进过程中所积累的误差大致可分为两类:非系统误差和系统误差。非系统误差通常由复杂

收稿日期:2013-08-21

基金项目:国家自然科学基金资助项目(61273195);中国博士后基金资助项目(2012M511386)

作者简介:肖 雄(1987-),男,湖北荆州人,主要从事移动机器人定位与导航方面的研究. E-mail: shaw_zjut@aliyun.com

通信联系人:李 刚,男,教授,博士生导师. E-mail:ieligang@zjut.edu.cn

的环境地图特征和机器人不规则随机运动所引起,如不平的地面、机器人过度加速或快速转弯等。一般来说,很难预测非系统误差。而系统误差则是由机器人设计缺陷、机械启动、测程法难校准等问题引起的。

对于测程法产生的系统误差,Borenste 和 Feng 等^[2]提出 UMB 校准方案进行校准;Doh 等^[3]提出 PC 校验法对系统误差进行补偿;Antonelli 等^[4]建立了包含 3 个参数的测程法模型,基于最小二乘法同样提出了校验方案。但这些校准方案都是离线的,即机器人在经过具体路径之后才执行测程法校准,不能对测程法引起的系统误差进行实时更新。

Larsen 等^[5]率先提出增广扩展卡尔曼滤波(AEKF)模型来在线校正系统误差;Martinelli 等^[6]对 AEKF 进行了扩展,能估计系统误差和非系统误差。Yun 等^[7]基于 AEKF 和家庭服务机器人的固有家庭定位也提出了测程法误差校正方案。但是,这些基于 AEKF 的方法非常依赖于精确的特征地图。

本研究基于特征地图、采用 AEKF 算法框架,并根据实际机器人模型选取速度校正参数来解决 SLAM 问题。所提出的 SLAM 方法同时用于估计初始 SLAM 状态空间和系统速度校正参数,笔者在预测和更新步骤中对这些参数进行实时修正,降低航向角误差。由于 EKF-SLAM 的状态向量与系统速度校正参数是相互独立不相关的,该方法可以实现自身的精准定位并构建更加精确的特征地图。

1 基于 AEKF 的 SLAM 数学模型

1.1 SLAM 状态空间增广

对于差速驱动系统的移动机器人来说,驱动整个机器人向前行进的车轮半径、行驶速度和航向角变化对测程法的影响至关重要。如不等的左、右车轮半径会使左、右轮产生较大的速度差,尤其是机器人在转向时左、右轮速度未加修正,导致测程法测距轨迹向左或向右倾斜,机器人航向角的偏离误差不断累积,这种情况将使传统的 SLAM(如 EKF/Fast SLAM)算法发散,性能严重受损,致使机器人无法正确构建地图、定位与自主导航。

$$\hat{x}_v^-(k) = f(\hat{x}_v^+(k-1), \hat{x}_s^+(k-1), u(k)) = \begin{bmatrix} \hat{x}_v^+(k-1) \\ \hat{y}_v^+(k-1) \\ \theta_v^+(k-1) \end{bmatrix} + \begin{bmatrix} \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \cos(\theta_v^+(k-1) + \gamma(k-1)) \\ \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \sin(\theta_v^+(k-1) + \gamma(k-1)) \\ \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \frac{\tan(\gamma(k-1))}{L} \end{bmatrix}$$

式中: $f(\cdot)$ —机器人的运力学模型方程, dt —控制时

测程法的误差模型可以映射为前驱左、右车轮的速度误差模型^[8]。设前驱左、右轮的速度分别为 v_l, v_r , 引入左、右轮速度系统校正参数 δ_l, δ_r , 则机器人的速度为:

$$v = \frac{\delta_l \cdot v_l + \delta_r \cdot v_r}{2} \quad (1)$$

在 EKF-SLAM 算法结构下,系统参数 δ_l, δ_r 将会被添加到 SLAM 的估计状态向量,形成增广 EKF 状态空间。基于 EKF 算法,在测量更新步骤中,笔者用卡尔曼增益和新息矩阵来更新机器人位姿、系统速度校正参数和地图特征位置。在预测步骤中,已更新的系统速度校正参数用于降低机器人的航向角误差和测程法误差。

1.2 AEKF-SLAM 算法总体结构

设 k 时刻机器人的位姿状态向量空间为 $\mathbf{x}_v(k) = [\mathbf{x}_v(k), \mathbf{y}_v(k), \boldsymbol{\theta}_v(k)]^T$, 系统速度校正参数向量为 $\mathbf{x}_s(k) = [\delta_l, \delta_r]^T$, 地图特征位置向量为 $\mathbf{x}_m(k) = [x_1, y_1, \dots, x_n, y_n]^T$, 其中 n 为特征数。则 AEKF-SLAM 的空间状态向量为:

$$\mathbf{x}(k) = [\mathbf{x}_v(k), \mathbf{x}_s(k), \mathbf{x}_m(k)]^T = [\mathbf{x}_v(k), \mathbf{y}_v(k), \boldsymbol{\theta}_v(k), \delta_l, \delta_r, x_1, y_1, \dots, x_n, y_n]^T \quad (2)$$

其协方差矩阵 $\mathbf{P}(k)$ 为:

$$\mathbf{P}(k) = \begin{bmatrix} \mathbf{P}_{vv} & \mathbf{P}_{vs} & \mathbf{P}_{vm} \\ \mathbf{P}_{sv}^T & \mathbf{P}_{ss} & \mathbf{P}_{sm} \\ \mathbf{P}_{mv}^T & \mathbf{P}_{sm}^T & \mathbf{P}_{mm} \end{bmatrix} \quad (3)$$

SLAM 的估计状态向量和协方差分别为 $\hat{\mathbf{x}}(k), \mathbf{P}(k)$, 滤波器根据预测值 $\hat{\mathbf{x}}^-(k), \mathbf{P}^-(k)$ 和当前的测量值 $\mathbf{z}(k)$ 来递归更新 $\hat{\mathbf{x}}^+(k)$ 和 $\mathbf{P}^+(k)$ 。

1.3 AEKF-SLAM 算法步骤

与 EKF-SLAM 相似,AEKF-SLAM 包含同样 3 个步骤:预测、更新和状态增广^[9]。

(1) 预测 $k-1$ 时刻,机器人位姿向量为 $\hat{\mathbf{x}}_v^+(k-1), k-1$ 到 k 时刻机器人的控制量为 $\mathbf{u}(k) = [\delta_l, \delta_r, \gamma]^T, \delta_l, \delta_r$ 为速度校正参数, γ 为航向角。在这里,采用运用范围较广的 Ackerman 机器人运动过程模型^[10],考虑到机器人系统校正参数,对机器人模型进行修改,则机器人的运力学方程可描述为:

$$\hat{x}_v^-(k) = f(\hat{x}_v^+(k-1), \hat{x}_s^+(k-1), u(k)) = \begin{bmatrix} \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \cos(\theta_v^+(k-1) + \gamma(k-1)) \\ \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \sin(\theta_v^+(k-1) + \gamma(k-1)) \\ \frac{\delta_l v_l + \delta_r v_r}{2} \cdot dt \cdot \frac{\tan(\gamma(k-1))}{L} \end{bmatrix} \quad (4)$$

同步长, L —前、后轴的轮基距。

那么, k 时刻 SLAM 的状态空间和协方差的预测值分别为:

$$\hat{\mathbf{x}}^-(k) = \begin{bmatrix} \hat{\mathbf{x}}_v^-(k) \\ \hat{\mathbf{x}}_s^-(k) \\ \hat{\mathbf{x}}_m^-(k) \end{bmatrix} = \begin{bmatrix} f(\hat{\mathbf{x}}_v^-(k-1), \hat{\mathbf{x}}_s^-(k-1), \mathbf{u}(k)) \\ \hat{\mathbf{x}}_s^-(k-1) \\ \hat{\mathbf{x}}_m^-(k-1) \end{bmatrix} \quad (5)$$

$$\begin{aligned} \mathbf{P}^-(k) &= \nabla \mathbf{f}_x \cdot \mathbf{P}^+(k-1) \cdot \nabla \mathbf{f}_x^T + \nabla \mathbf{f}_u \cdot \mathbf{Q}_k \cdot \nabla \mathbf{f}_u^T = \\ &\quad \begin{bmatrix} \nabla_{x_v} \mathbf{f} & \nabla_{x_s} \mathbf{f} & 0 \\ 0 & \mathbf{I}_{x_s} & 0 \\ 0 & 0 & \mathbf{I}_{x_m} \end{bmatrix} \cdot \mathbf{P}^+(k-1) \cdot \\ &\quad \begin{bmatrix} \nabla_{x_v} \mathbf{f} & \nabla_{x_s} \mathbf{f} & 0 \\ 0 & \mathbf{I}_{x_s} & 0 \\ 0 & 0 & \mathbf{I}_{x_m} \end{bmatrix}^T + \begin{bmatrix} \nabla_u \mathbf{f} \\ 0 \\ 0 \end{bmatrix} \cdot \mathbf{Q}_k \cdot \begin{bmatrix} \nabla_u \mathbf{f} \\ 0 \\ 0 \end{bmatrix}^T \end{aligned} \quad (6)$$

式中: $\nabla \mathbf{f}_x$, $\nabla \mathbf{f}_u$ —机器人运动模型关于机器人位姿向量 $\hat{\mathbf{x}}^-(k)$ 和控制向量 $\mathbf{u}(k)$ 的雅克比 (Jacobian) 行列式; \mathbf{Q}_k —过程噪声的误差协方差, 假定过程噪声是均值为零的高斯噪声。

(2) 更新。假定环境中的路标是静止的, $\mathbf{m}_i = [\hat{\mathbf{x}}_i, \hat{\mathbf{y}}_i]^T$ 是机器人观测到的第 i 个路标位置, 机器人装载的距离方位传感器返回传感器与该路标之间的距离和角度, 那么观测模型可表示为:

$$\hat{\mathbf{z}}_i(k) = \mathbf{h}_i(\hat{\mathbf{x}}_v^-(k)) = \begin{bmatrix} \hat{\rho}_i \\ \hat{\varphi}_i \end{bmatrix} = \begin{bmatrix} \sqrt{(\hat{x}_i - \hat{x}_v^-(k))^2 + (\hat{y}_i - \hat{y}_v^-(k))^2} \\ \tan^{-1}\left(\frac{\hat{y}_i - \hat{y}_v^-(k)}{\hat{x}_i - \hat{x}_v^-(k)}\right) - \theta_v^-(k) \end{bmatrix} \quad (7)$$

依据以下方式来递归更新估计的状态空间 $\hat{\mathbf{x}}^-(k)$ 和协方差 $\mathbf{P}^-(k)$:

$$\mathbf{S}(k) = \nabla \mathbf{h} \cdot \mathbf{P}^-(k) \cdot (\nabla \mathbf{h})^T + \mathbf{R}_k \quad (8)$$

上述 $\mathbf{S}(k)$ 为新息矩阵, 现对其进行如下处理:

$$\mathbf{S}_{\text{new}}(k) = 0.5 \cdot (\mathbf{S}(k) + \mathbf{S}(k)^T) \quad (9)$$

$$\mathbf{S}_{\text{Chol}}(k) = \text{chol}(\mathbf{S}_{\text{new}}(k)) \quad (10)$$

以上式(9)使新息矩阵对称化, 式(10)表示对新生成的对称化新息矩阵进行 Cholesky 分解, 这种处理结果在递归运算过程中在数值上要比简单运用新息矩阵更加稳定。

Kalman 增益 \mathbf{K}_k 则变化为:

$$\mathbf{K}_k = \hat{\mathbf{P}}^-(k) \cdot (\nabla \mathbf{h})^T \cdot \mathbf{S}_{\text{Chol}}^{-1}(k) \cdot (\mathbf{S}_{\text{Chol}}^{-1}(k))^T \quad (11)$$

递归更新方程为:

$$\hat{\mathbf{x}}^+(k) = \hat{\mathbf{x}}^-(k) + \mathbf{K}_k \cdot (\mathbf{z}_n - \hat{\mathbf{z}}_n) \quad (12)$$

$$\hat{\mathbf{P}}^+(k) = (\mathbf{I} - \mathbf{K}_k \cdot \nabla \mathbf{h}) \cdot \hat{\mathbf{P}}^-(k) \quad (13)$$

式(8~13)中: $\nabla \mathbf{h}$ —观测模型关于状态空间 $\hat{\mathbf{x}}^-(k)$ 的雅克比行列式, \mathbf{R}_k —观测噪声的误差协方差, 假定观测噪声是均值为零的高斯噪声。

(3) 状态增广。当机器人观测到一个新的路标, 经过校验后, 需要把这个新观测到的路标的位置状态添加到系统状态向量中。运用增广模型对新的系统状态向量和协方差矩阵进行更新。新观测到的路标 $\mathbf{x}_{m_{n+1}}$ 位置可表示为:

$$\begin{aligned} \hat{\mathbf{x}}_{m_{n+1}} &= g(\hat{\mathbf{x}}_v^+(k), \mathbf{z}_{n+1}) = \\ &\quad \begin{bmatrix} \hat{\mathbf{x}}_v^+(k) + \rho_{n+1} \cos(\hat{\theta}_v^+(k) + \varphi_{n+1}) \\ \hat{\mathbf{y}}_v^+(k) + \rho_{n+1} \sin(\hat{\theta}_v^+(k) + \varphi_{n+1}) \end{bmatrix} \end{aligned} \quad (14)$$

那么包含新路标的系统状态空间 $\hat{\mathbf{x}}^*(k)$ 为:

$$\hat{\mathbf{x}}^*(k) = [\hat{\mathbf{x}}_v^+(k), \hat{\mathbf{x}}_s^+, \hat{\mathbf{x}}_m^+, g(\hat{\mathbf{x}}_v^+(k), \mathbf{z}_{n+1})]^T \quad (15)$$

对应地的协方差矩阵 $\mathbf{P}^*(k)$ 为:

$$\mathbf{P}^*(k) = \nabla \mathbf{J}_{x,z} \begin{bmatrix} \mathbf{P}^+(k) & 0 \\ 0 & \mathbf{R}_k \end{bmatrix} \nabla \mathbf{J}_{x,z}^T \quad (16)$$

其中:

$$\nabla \mathbf{J}_{x,z} = \begin{bmatrix} \mathbf{I}_{x_v} & 0 & 0 & 0 \\ 0 & \mathbf{I}_s & 0 & 0 \\ 0 & 0 & \mathbf{I}_m & 0 \\ \nabla \mathbf{G}_{x_v} & 0 & 0 & \nabla \mathbf{G}_z \end{bmatrix} \quad (17)$$

式中: $\nabla \mathbf{G}_{x_v}$, $\nabla \mathbf{G}_z$ — $g(\cdot)$ 关于机器人位姿向量和观测向量的雅克比行列式。

2 实验分析

2.1 仿真环境及结果

仿真实验采用 Matlab 仿真平台。假设机器人的探索仿真环境如图 1 所示。环境中分布着 35 个特征点和 17 个路径点, 分别用“*”和“.”表示, 细实线表示路径点确定的路线。

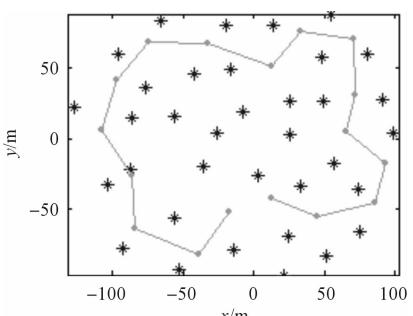


图 1 仿真环境

在实验中, 机器人的位姿初始化为 $\mathbf{x}_v = [0, 0,$

$0]^T$, 沿路径点确定的轨迹逆时针绕行一周。前、后车轴距 $L = 4 \text{ m}$, 前驱左、右轮初始化速度 $v_l = v_r = 3 \text{ m/s}$, 校正参数初始化为 $\delta_l = \delta_r = 1$, 其附加噪声是零均值, 方差为 0.1 的高斯噪声, 航向角的范围是 $(-\pi/4, \pi/4)$, 控制时间步长 $t_c = 0.025 \text{ s}$, 观测时间步长 $t_o = 0.2 \text{ s}$, 传感器最大探测距离为 30 m, 探测夹角为 $(-\pi/2, \pi/2)$, 系统协方差初始化为 0, 控制噪声协方差为 $Q_k = \text{diag}\{0.2^2, 0.2^2, (2.0 \cdot \pi/180)^2\}$, 观测噪声的协方差为 $R_k = \text{diag}\{0.2^2, (2.0 \cdot \pi/180)^2\}$ 。

标准 EKF-SLAM 和 AEKF-SLAM 的仿真结果分别如图 2(a)、2(b) 所示。图中实线为机器人真实路径, 虚线为 SLAM 算法的估计路径, “*”为 SLAM 估计的路标位置, “椭圆”表示所估计路标位置的不确定度。

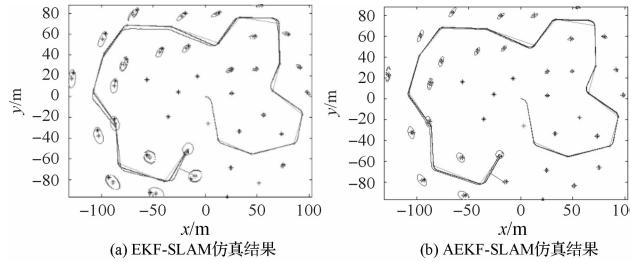


图 2 EKF 和 AEKF 仿真结果

2.2 结果分析

本研究使用标准 EKF 和 AEKF 进行状态估计产生的机器人位姿的定位误差如图 3 所示。其中, 上方的图表示的是机器人偏离原定路线 x 轴和 y 轴的位置误差(单位为 m), 下方的图表示的是机器人偏离原定路线的航向角误差(单位为 rad)。

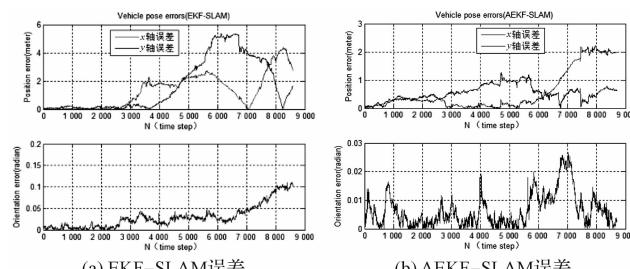


图 3 机器人位姿误差

从图 3(a) 可见, 在时间步长 N ($1 \text{ 步} = 0.025 \text{ s}$) 约在 2700 之前, 系统噪声和观测噪声对系统产生的影响较小, 机器人的定位精度保持在较高水平。由于 EKF 假设速度是不变的, 随着噪声的不断累积, 机器人不断转向, 航向角误差逐步积累, 观测值的可信度下降, 观测值误差加大, 滤波器变得不稳定, 导致机器人定位误差越来越大。注意到, 当 N 大约为 2700 时, 机器人的航向角的误差超过 0.03 rad , 即 1.7° , 滤波器开始变得不一致(见下文一致性分析)。随着噪声进一

步增强, 机器人的航向角误差呈持续上升状态, 滤波器逐渐发散, 机器人定位不准确, 估计的路标位置同样不准确。与图 3(a) 相比, 图 3(b) 机器人的位姿误差始终保持着较低水平, 航向角的误差始终低于 0.03 rad , 机器人定位和路标位置精度大大提高, 滤波器的稳定性得到有效提升, 保持了滤波器的一致性。这正是由于 AEKF 使用了机器人速度校正参数, 根据机器人的运动状态, 校正参数不断被估计和更新来产生相应的速度, 使航向角实时适应机器人的变化运动状态。

为比较所提出方法的性能, 笔者引入均方根误差(Root Mean Squared Error, RMSE)^[11], 其定义如下:

$$X_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_i)^2} \quad (18)$$

均方根误差越小说明算法的估计性能越好。使用标准 EKF 和 AEKF 两种算法进行状态估计得到的机器人位姿的均方根误差如表 1 所示, 实验数据表明 AEKF 算法很大程度上提升了估计精度。

表 1 算法均方根误差比较

方法	RMSE		
	x 方向/m	y 方向/m	航向角/rad
EKF-SLAM	1.8087	2.50757	0.4285
AEKF-SLAM	0.9305	0.6069	0.1507

现考虑这两种算法的一致性^[12], 采用归一化估计方差(Normalized Estimation Error Squared, NEES), 其定义如下:

$$\varepsilon_k = (\mathbf{x}_k - \hat{\mathbf{x}}_k)^T \mathbf{P}_k^{-1} (\mathbf{x}_k - \hat{\mathbf{x}}_k) \quad (19)$$

为估计 EKF/AEKF 的一致性, 需执行 M 次 Monte Carlo 试验, 来计算平均 NEES:

$$\hat{\varepsilon}_k = \frac{1}{M} \sum_{i=1}^M \varepsilon_{i,k} \quad (20)$$

在实验中, 执行 50 次 Monte Carlo 试验, 平均 NEES 的 95% 置信区间为 $[2.36, 3.72]$ ^[13]。如果 $\hat{\varepsilon}_k$ 上升超过上界, 则滤波算法表现出不一致性, 低于上界就是一致的, 如果 $\hat{\varepsilon}_k$ 低于下界, 则滤波算法是保守的^[14]。使用标准 EKF 和 AEKF 进行状态估计产生的机器人位姿 NEES 如图 4 所示, 实线表示平均 NEES, 虚线表示置信区间。

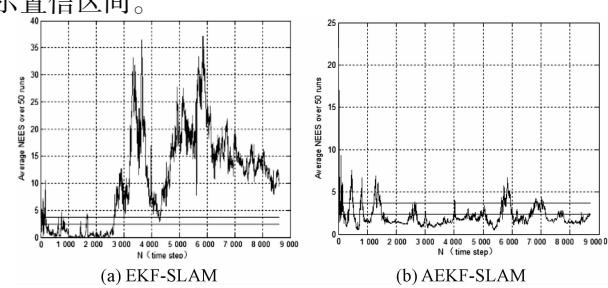


图 4 机器人位姿 NEES

从图4(a)中可以看出,当N约为2700时,平均NEES开始超过上界,滤波算法表现出不一致,该时刻的航向角误差约为0.03 rad。结果表明,滤波算法的一致性与航向角的误差息息相关,导致滤波算法不一致的航向角误差临界值约为0.03 rad。从图4(b)可见,由于航向角误差始终小于0.03 rad,平均NEES绝大多数时刻保持较低水平,滤波算法表现出一致性和稳定性。

3 结束语

笔者主要研究了一种基于增广扩展 Kalman 滤波的 SLAM 方法,并对采用的算法进行了对比分析。与 EKF-SLAM 相较而言,本研究利用所提出的方法估计的机器人平均误差在x轴方向上从1.32 m下降到0.57 m,在y轴方向上从1.67 m下降到0.54 m,航向角从0.03 rad下降到0.006 4 rad,估计准确度分别提高56.8%、67.6%、78.6%,尤其是避免了航向角误差的积累,使滤波算法保持良好的一致性,大幅度提升了机器人的自身定位精度和路标估计准确度。通过仿真实验对所提出的 SLAM 解决方法进行了验证,研究结果表明该方法是可行的、有效的,为研究 SLAM 的学者提供了一定帮助。

参考文献(References):

- [1] SMITH R, SELF M, CHEESEMAN P. Estimation uncertainty special relationships in robotics [J]. **Autonomous Robot Vehicles**, 1990(1):167-193.
- [2] BORENSTEIN J, FENG L. Measurement and correction of systematic odometry errors in mobile robots [J]. **IEEE Transactions on Robotics and Automation**, 1996, 12(6):869-880.
- [3] DOH N, CHOSET H, CHUNG W K. Accurate relative localization using odometry[C]// Proc. IEEE Int. Conf. Robotics and Automation Taipei: [s. n.], 2003:1606-1612.
- [4] ANTONELLI G, CHIAVERINI S, FUSCO G. A systematic calibration method for odometry of mobile robots based on the least-squares technique: Theory and experimental validation[J]. **IEEE Transactions on Robotics and Automation**, 2005, 21(5):994-1004.
- [5] LARSEN T D, BAK M, ANDERSEN N A , et al. Location estimation for autonomously guided vehicle using an augmented Kalman filter to auto-calibrate the odometry[C]// Proc. FUSION98, Spie Cofenrence Lasvegas: [s. n.], 1998.
- [6] MARTINELLI A, TOMATIS N, SIEGEART R. Simultaneous localization and odometry self-calibration for mobile robot[J]. **Autonomous Robots**, 2007(22):75-85.
- [7] YUN Y M, PARK B J, CHUNG W K. Odometry Calibration using Home Positioning Function for Mobile Robot[C]// in Proc. IEEE Conf. Robotics and Automation. Pasadena: [s. n.], 2008:2116-2121.
- [8] CHONG K S, KLEEMAN L. Accurate odometry and error modeling for a mobile robot[C]// Proc. IEEE Conf. Robotics and Automation. Albuquerque: [s. n.], 1997:2783-2788.
- [9] BAILY T. Mobile Robot Localization and Mapping in Extensive Outdoor Environments[D]. PhD thesis. University of Sydney, 2002.
- [10] SOTELO M A. Lateral control strategy for autonomous steering of Ackerman-like vehicles [J]. **Robotics and Automation Systems**, 2003(24):223-233.
- [11] 杜航原,郝燕玲,赵玉新. 基于模糊自适应卡尔曼滤波的 SLAM 算法[J]. 华中科技大学学报:自然科学版, 2012, 40(1):58-62.
- [12] 张国良,汤文俊,敬斌,等. 基于机器人运动模型的 EKF-SLAM 算法改进[J]. 计算机测量与控制, 2012, 20(4):1064-1066.
- [13] BAR-SHALOM Y, LI X R, KIRUBARAJAN T. Estimation with Application to Tracking and Navigation [M]. John Wiley and Sons, 2001.
- [14] BAILY T, NIETO J. Consistency of EKF-SLAM Algorithm [C]// Proc. IEEE/RSJ Int. Conf. on Intelligent Robots and Systems. Beijing: [s. n.], 2006:3562-3568.

[编辑:李 辉]

本文引用格式:

肖 雄,李 旦,陈锡锻,等. 一种基于增广 EKF 的移动机器人 SLAM 方法[J]. 机电工程,2014,31(1):109 - 113.

XIAO Xiong, LI Dan, CHEN Xi-duan, et al. SLAM method based on augmented EKF for mobile robot[J]. Journal of Mechanical & Electrical Engineering, 2014,31(1):109 - 113.

《机电工程》杂志: <http://www. meem. com. cn>