

自适应扩展卡尔曼滤波器在移动机器人定位中的应用^①

孟祥萍¹, 张本法², 苑全德^{1,3}

¹(长春工程学院 电气与信息工程学院, 长春 130012)

²(东北电力大学 信息工程学院, 吉林 132012)

³(哈尔滨工业大学 计算机科学与技术学院, 哈尔滨 150001)

摘 要: 针对移动机器人定位过程中存在的误差积累问题, 提出了采用自适应扩展卡尔曼滤波算法(AEKF). 分析了扩展卡尔曼滤波(EKF)和 AEKF 两种算法, AEKF 取采样时刻的各项泰勒级数, 并利用 Sage-Husa 时变噪声估计器实时估计观测噪声, 克服了线性化误差, 增强了环境适应性; 同时, 对 AEKF 的收敛性及运算复杂度进行分析, 并结合算法实验表明 AEKF 具有良好的速度精度综合性价比; 最后对比分析两种算法实现机器人定位的效果并实验完成误差对比. 结果表明 AEKF 具有更优的定位性能.

关键词: 移动机器人; 定位; 路标; 扩展卡尔曼滤波器算法; 自适应扩展卡尔曼滤波器算法

Adaptive Extended Kalman Filter in the Application of the Mobile Robot Localization

MENG Xiang-Ping¹, ZHANG Ben-Fa², YUAN Quan-De^{1,3}

¹(School of Electrical and Information Engineering, Changchun Institute of Technology, Changchun 130012, China)

²(School of Information Engineering, Northeast Dianli University, Jilin 132012, China)

³(School of Computer Science and Technology, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Concerning the error accumulation problem in mobile robot localization, a adaptive extended Kalman filter (AEKF) algorithm is presented. The extended Kalman filter and adaptive Kalman filter algorithms are analyzed. AEKF use the Taylor series in sampling time and the Sage-Husa time-varying noise estimator to estimate observation noise in real time, it overcomes the linearization error and enhance the environmental adaptability. Meanwhile, the AEKF convergence and complexity of operation are analyzed and combined with experiments show that AEKF has good comprehensive performance in terms of speed and precision. Finally, the effect of robot localization completed by two kinds of algorithm is analyzed and the error comparison by experiment is completed. The results indicate AEKF has better performance on localization.

Key words: mobile robot; localization; landmark; extended Kalman filter; adaptive extended Kalman filter

移动机器人定位是指移动机器人可以自主确定自身在环境中的位置, 即利用先验环境地图信息、机器人当前位姿的估计以及传感器的测量值等输入信息, 经过一定的处理后估计出更加准确的当前位姿. 在非结构化环境中, 移动机器人基于内部传感器, 使用视觉、激光等外部传感器获取环境信息. 将传感器信息进行信息融合常用算法主要有卡尔曼滤波算法、人工神经网络算法等.

在 SLAM 问题中, 机器人的运动模型大多数是非

线性的. 而在直角坐标系下, 一般系统的状态方程是线性的. 扩展的卡尔曼滤波器算法是常用的非线性滤波方法. 但计算非线性系统的条件转移矩阵会产生较大的线性化误差, 研究人员试图通过减小卡尔曼滤波器的非线性误差以改善其定位效果. 文献[1]采用扩展卡尔曼滤波算法(EKF), 将里程计和数字罗盘信息进行融合, 但是普通的 EKF 线性化误差较大, 滤波结果会随着时间的增加而发散, 在机器人的移动过程中, 误差积累较大, 定位效果并不理想. 文献[2]提出了平

① 基金项目: 哈尔滨市科技创新人才研究专项资金(RC2013XK010002); 吉林省教育厅“十二五”科学技术研究项目(2014324)

收稿时间: 2015-04-03; 收到修改稿时间: 2015-05-15

方根容积卡尔曼滤波在机器人 SLAM 领域中的应用. 该算法使用平方根容积卡尔曼滤波计算 SLAM 后验概率密度, 降低了线性化误差. 文献[3]将无迹卡尔曼滤波引入 SLAM 领域, 通过无迹变换计算来估计 SLAM 问题中的后验概率. 虽然在定位的精度和稳定性上都有所改善, 但在线性化过程中, 都只取一阶泰勒级数, 仍然存在较严重的线性化误差, 没有从根本上解决移动机器人在行走过程中的误差积累问题. 这在实际应用过程中定位效果较差甚至致使任务失败.

本文提出采用扩展卡尔曼滤波改进算法(AEKF)实现机器人定位. 在某个采样时刻进行泰勒级数展开, 取各项泰勒级数, 并且对环境噪声具有自适应性, 从而更好地解决线性化误差问题, 使之具有更好的实用性.

1 机器人运动模型分析

1.1 坐标系

一个是全局坐标系(X_w, Y_w), 另一个是机器人的局部坐标系(X_r, Y_r). 如下图所示:




图 1 机器人坐标系

室内环境用二维平面表示在全局坐标系 $X_w O_w Y_w$ 中, 机器人坐标系表示为 $X_r O_r Y_r$. 机器人的位姿用三维状态矢量 (x, y, θ) 表示. 其中, 机器人在全局坐标系中的坐标 (x, y) 表示机器人的位置; θ 表示机器人的运动方向, 它是以前前方为起点的逆时针方向来定义的, 如图 1 所示, 取值范围为 $-\pi \sim \pi$.

1.2 里程计模型

里程计模型可以分为直线模型和圆弧模型. 由于圆弧模型考虑机器人在运动过程中航向角的变化, 用圆弧近似机器人移动的实际轨迹. 虽然圆弧模型的计算复杂度要高于直线模型, 但能更好地逼近实际轨迹. 如图 2 所示, 机器人从点 B 运动到点 B' 的过程:




图 2 机器人运动位姿

假设移动机器人在第 k 个采样时刻(在 B 点)的状态为 $X(k) = [x(k), y(k), \theta(k)]^T$. 同理, 在第 $k+1$ 个采样时刻(在 B' 点)时, 机器人的系统状态为 $X(k+1) = [x(k+1), y(k+1), \theta(k+1)]^T$. 结合图 2 中几何关系, 系统的状态方程为:

$$\begin{aligned} X(k+1) &= F(X(k), U(k)) + W(k) = \begin{bmatrix} x(k+1) \\ y(k+1) \\ \theta(k+1) \end{bmatrix} + W(k) \\ &= \begin{bmatrix} x(k) + \Delta D(k+1) \cos(\theta(k)) + \Delta \theta(k+1) / 2 \\ y(k) + \Delta D(k+1) \sin(\theta(k)) + \Delta \theta(k+1) / 2 \\ \theta(k) + \Delta \theta(k+1) \end{bmatrix} + W(k) \end{aligned} \quad (1)$$

其中, $U(k) = (\nabla D(k), \nabla \theta(k))$ 为里程计的输入模型. $\Delta D(k)$ 和 $\Delta \theta(k)$ 分别是机器人在第 k 个采样周期内的位置增量和方向增量. $W(k)$ 是动态的系统高斯白噪声, 其统计特性为:

$$E[W(k)] = 0, \text{Cov}[W(k), W(j)] = E[W(k)W(j)^T] = Q(k)\delta_{kj}$$

由公式可知, 里程计模型是一个非线性模型, 由误差传递近似公式可知, 机器人在 $X(k+1)$ 位姿下的误差协方差矩阵更新方程为:

$$P(k+1/K) = \nabla F_x P(k/K) \nabla F_x^T + \nabla F_u u(k+1) \nabla F_u^T + Q(k+1) \quad (2)$$

其中, $P(k/K)$ 为本次机器人位姿误差协方差矩阵, $F(x(k), u(k))$ 为里程计模型方程, ∇F_x 和 ∇F_u 分别为 F 对机器人位姿 $x(k)$ 和输入向量 $u(k+1)$ 的雅克比矩阵.

1.3 视觉探测模型

L_i 表示视觉传感器探测到的第 i 个路标的位置. 系统的状态由机器人所在位置和在此观测到的路标组成, 表示为 $x(k) = [x_v^T(k), L_1^T, \dots, L_N^T]^T$, N 表示路标的个数.

如图 3 所示, 根据几何关系可以得到如下的系统观测方程

$$z_i(k) = H_i x(k) + v_i(k) \quad (3)$$

其中, $z_i(k)$ 为双目视觉传感器对于第 i 个路标的观测输出, v_i 是动态的观测高斯白噪声, 并具有如下的统计特性:

$$E[v(k)] = 0$$

$$\text{Cov}[v(k), v(j)] = E[v(k)v(j)^T] = R(k)\delta_{kj}$$




图 3 SLAM 场景示意图

2 算法分析

将AEKF算法分为两个阶段: 一是将非线性系统线性化; 二是对系统状态进行估计. 在第一阶段, AEKF和EKF的主要区别: EKF只使用当前状态估计处的一阶泰勒级数而省略高阶项; AEKF则采用各项泰勒级数, 有效地避免引入线性化误差. 在第二阶段, 两者的主要区别是: 在AEKF中, 噪声大小是时变的, 而EKF是根据经验使用的固定值. 由于AEKF根据环境变化实时调整噪声大小, 因而具有更好的适应性. 为了更深入的理解AEKF, 首先对EKF进行分析.

2.1 EKF 算法分析

离散的非线性系统为

$$\begin{cases} X(k+1) = F(X(k), k) + B_k u_k + \omega(k) \\ z(k) = H(X(k), k) + v(k) \end{cases} \quad (4)$$

其中, $X(k)$ 是 n 维系统状态向量, $z(k)$ 是 m 维观测向量. F 是 $n \times n$ 阶的系统状态转移矩阵, 它反映了系统从 $k-1$ 个采样时刻的状态到第 k 个采样时刻的状态转换. 假设 $k-1$ 时刻到 k 时刻的物理时差为 Δt 时, F 的形式可表示为

$$F = \begin{pmatrix} 1 & \Delta t & \Delta t^2 / 2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{pmatrix}$$

H 是 $m \times n$ 阶观测矩阵, 它表示了从状态 $X(k)$ 到观测值 $z(k)$ 的转换, 其形式可表示为

$$H = \begin{pmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix}$$

$\omega(k)$ 为系统噪声, $v(k)$ 是观测噪声. 他们的统计特性可以表示为

$$E\{\omega(k)\} = 0, \text{cov}(\omega(k), \omega(j)) = Q(k)\delta_{kj}$$

$$E\{v(k)\} = 0, \text{cov}(v(k), v(j)) = R(k)\delta_{kj}$$

$$\text{cov}(\omega(k), v(j)) = 0$$

对 F 、 H 在 $\hat{X}(k)$ 处进行泰勒级数展开, 则

$$X(k+1) \approx \nabla F X(k) + [F(\hat{X}(k), k) - \nabla F \hat{X}(k)] + B_k u_k + w(k)$$

$$z(k+1) \approx \nabla H X(k+1) + [H(\hat{X}(k+1/k), k+1) - \nabla H \hat{X}(k+1/k)] + v(k+1) \quad (5)$$

其中

$$\nabla F = \frac{\partial F(X(k), k)}{\partial \hat{X}(k)}, \nabla H = \frac{\partial H(X(k+1), k+1)}{\partial \hat{X}(k+1/k)}$$

系统(4)相应的扩展卡尔曼滤波算法是:

$$\hat{X}_{k+1/k} = F(\hat{X}_{k/k}, k) + B_k u_k + q \quad (6)$$

$$P_{k+1/k} = (\partial F / \partial \hat{X}_k) P_k (\partial F / \partial \hat{X}_k)^T + Q \quad (7)$$

$$K_{k+1} = P_{k+1/k} (\partial H / \partial \hat{X}_{k+1/k})^T [(\partial H / \partial \hat{X}_{k+1/k}) P_{k+1/k} (\partial H / \partial \hat{X}_{k+1/k})^T + R]^{-1} \quad (8)$$

$$\hat{X}_{k+1} = \hat{X}_{k+1/k} + K_{k+1} [Y_{k+1} - H(\hat{X}_{k+1/k}, k+1) - r] \quad (9)$$

$$P_{k+1} = [I - K_{k+1} (\partial H / \partial \hat{X}_{k+1/k})] P_{k+1/k} \quad (10)$$

性质 1 EKF 算法最优的充要条件是其滤波增益矩阵满足

$$K_{k+1} = P_{k+1/k} (\partial H / \partial \hat{X}_{k+1/k})^T [(\partial H / \partial \hat{X}_{k+1/k}) P_{k+1/k} (\partial H / \partial \hat{X}_{k+1/k})^T + R]^{-1}$$

性质 2 EKF 算法最优的充要条件是其新息序列是零均值白噪声.

2.2 AEKF 分析

与EKF对向量函数 F 的泰勒级数展开不同, AEKF 的如下式:

$$F(X(k), k) = F(\hat{X}(k), k) + \nabla F[X(k) - \hat{X}(k-1)] + H.O.T \quad (11)$$

其中 $H.O.T$ 表示泰勒级数高阶项. 将(11)式带入(5)式得,

$$X(k+1) = \nabla F X(k) + u(k) + \xi(k) \quad (12)$$

其中, $u(k) = F(\hat{X}(k), k) - \nabla F \hat{X}(k)$,

$$\xi(k) = w(k) + H.O.T.$$

为了提高滤波精度, 减小模型线性化误差, 把线性化过程中出现的高阶项与系统噪声 $\omega(k)$ 合并为 $\xi(k)$, 并称之为虚拟系统噪声. 可以看出, 即使 $\omega(k)$

的均值为零, $\xi(k)$ 的均值也不总为零, 它的统计特性满足

$$E\{\xi(k)\} = q(k), \text{cov}(\xi(k), \xi(j)) = Q(k)\delta_{kj} \quad (13)$$

同理, 将(4)式中向量函数 H 在 $\hat{X}(k/k-1)$ 附近进行泰勒级数展开, 如下式所示:

$$z(k) = \nabla H \hat{X}(k/k-1) + y(k) + \eta(k)$$

其中, $y(k) = H(\hat{X}(k/k-1), k) - \nabla \hat{X}(k/k-1)$

$\eta(k) = v(k) + H.O.T.$

把线性化过程中出现的高阶项与观测噪声 $v(k)$ 合并为 $\eta(k)$, 称之为虚拟观测噪声. $\eta(k)$ 统计特性满足

$$E\{\eta(k)\} = r(k), \text{cov}(\eta(k), \eta(j)) = R(k)\delta_{kj}$$

利用 Sage-Husa 时变噪声估计器^[4]对 $q(k)$, $Q(k)$, $r(k)$, $R(k)$ 进行估计, 则有

$$\begin{aligned} \hat{q}(k) &= -d(k) \hat{q}(k-1) + d(k) [\hat{X}(k/k) - F(\hat{X}(k-1/k) - B(k)u(k))] \\ \hat{Q}(k) &= [1 - d(k)]\hat{Q}(k-1) + d(k) [K(k) \varepsilon(k) \varepsilon^T(k) K^T(k) + P(k) - \nabla F P(k-1) \nabla F^T] \\ \hat{r}(k+1) &= (1 - d(k)) [\hat{r}(k) - H(\hat{X}(k+1/k), k+1)] \\ \hat{R}(k+1) &= (1 - d(k))\hat{R}(k) + d(k) [\eta(k+1) \eta^T(k+1) - (\partial H / \partial \hat{X}(k+1/k) * P(k+1/k) * (\partial H / \partial \hat{X}(k+1/k))^T] \end{aligned} \quad (14)$$

其中, $d(k) = (1 - \lambda)/(1 - \lambda^k)$, $0 < \lambda < 1$, λ 是遗忘因子.

把 $q(k)$, $Q(k)$, $r(k)$, $R(k)$ 用 $\hat{q}(k)$, $\hat{Q}(k)$, $\hat{r}(k)$, $\hat{R}(k)$ 替代后, 构成自适应扩展卡尔曼滤波器算法.

2.3 AEKF 算法收敛性分析

设 k 刻最优 EKF 算法中 P_k 在有界区间内(若 P_k 无界, 由性质 1 知, EKF 不是最优, 即 k 时刻最优 EKF 已发散, 此时 AEKF 必发散), 则 AEKF 算法收敛的充要条件为 EKF 算法中 $\hat{P}_k$ 有极限, 即 $\lim_{k \rightarrow \infty} \hat{P}_k = A$. 由数列极限性质, AEKF 算法中 $\hat{P}_k$ 和 k 时刻最优 EKF 算法中 P_k 满足 $\lim_{k \rightarrow \infty} (\hat{P}_k - P_k) = 0$. 因此, 有 $\lim_{k \rightarrow \infty} (\hat{P}_k - P_k) = 0$, 即 AEKF 算法收敛于 k 时刻最优 EKF 算法.

2.4 AEKF 计算复杂度分析

对于一种算法, 不仅要考虑它是否有收敛性的保证, 而且还必须考虑它的计算成本. 一个算法所消耗的时间正比于它的计算时间复杂度. 首先分析 EKF 计算复杂度.

状态预测时, 如式(6), 其浮点算法时间复杂度为:

$$T_1(n) = n^2$$

预测均方误差, 如式(7), 其浮点算法时间复杂度为:

$$T_2(n) = n^3 + n^2 + n$$

滤波增益计算, 如式(8), 此运算包含一次矩阵求逆, 在此以初等行变换的矩阵求逆方法为例进行分析, 可得其浮点时间计算复杂度为:

$$T_3(n) = 2(m^3 + m^2n + mn) + m$$

状态估计时, 如式(9), 其浮点算法时间复杂度为:

$$T_4(n) = 2mn + m + n$$

估计均方误差, 如式(10)其浮点运算时间复杂度为:

$$T_5(n) = mn^2 + 2n^2$$

综上所述, 普通的 EKF 浮点运算时间复杂度为:

$$T(n) = 2m^3 + 2m^2n + mn^2 + 4n^2 + 4mn + 3n + m \quad (15)$$

在应用 AEKF 时, 对于式(14), 由于机器人运动模型是固定的, 所以可以不考虑虚拟系统噪声的统计特性 $\hat{q}(k)$, $\hat{Q}(k)$, 而只考虑观测模型中的虚拟观测噪声的统计特性 $\hat{r}(k)$, $\hat{R}(k)$.

由以上分析, 与 EKF 的计算相比, AEKF 通过实时监测虚拟观测噪声的变化来调整滤波增益, 进而控制状态预测值和观测值在滤波结果中的权重. 因此, 在循环迭代过程中用到滤波增益时计算观测噪声的估计值 $\hat{r}(k)$, $\hat{R}(k)$ 增加了计算复杂度. 由式(14)中

$\hat{r}(k)$, $\hat{R}(k)$ 计算公式可知, 增加的计算复杂度为:

$$\Delta T(n) = mn^2 + m$$

由于 $T(n) \gg \Delta T(n)$, 所以与 EKF 的相比, AEKF 只是增加了较小计算复杂度.

2.5 EKF 和 AEKF 算法实验结果比较




图 4 EKF 和 AEKF 滤波误差对比图

从上面的误差曲线可以看出, 结合上述理论分析, 随着滤波时间的增加, EKF 的误差越来越大, 甚至发散, 所以 EKF 自身没有抑制线性化误差增大的能力, 其性能随着滤波的进行会逐渐变差; 而 AEKF 通过实时估计虚拟观测噪声的统计特性, 并代入滤波公式对模型线性化误差进行补偿, 随着滤波时间的增加, 仍然保持着良好的滤波特性, 可以得到良好的滤波效果. 由于 AEKF 在增加很小的计算复杂度情况下, 拥有更优的定位精度, 并且随着硬件处理速度的提高, AEKF 体现出了良好速度精度综合性价比, 在实际中得到更

为广泛的应用。

3 定位过程分析

3.1 AEKF 定位原理

基于系统的状态方程对移动机器人的位置进行预测, 得到先验位置估计的均值和方差; 然后再基于系统的观测方程对路标的位置进行观测值预测, 并通过实际观测和预测观测的差值对机器人位置进行更新修正, 得到后验的位置估计均值和方差。在基于 AEKF 的 SLAM 算法中, 便是运用 AEKF 算法对机器人和路标的位置进行预测估计和更新修正。如下图所示:




图 5 AEKF 定位原理图

分为以下循环递推的过程:

1) 预测

根据当前机器人位姿及其协方差矩阵向前一步预测, 即 $X(k/k) \rightarrow X(k+1/k)$, $P(k/k) \rightarrow P(k+1/k)$ 。根据(1)、(2)两式所建立的基于里程计的预测方程, 直接用于 AEKF 定位的状态预测。

2) 观测

根据观测方程(3), 全局地图中的全局特征在当前位姿下的一步预测值为:

$$\begin{aligned}\hat{z}(k+1) &= Hx(k) + v(k) \\ v(k) &= z(k) - \hat{z}(k/k-1)\end{aligned}$$

可以将上式直接用于 AEKF 的测量预测。

3) 特征匹配

特征匹配将第二步中的预测路标与局部地图中的实际路标特征按匹配准则进行“最佳”配对。由于虚假匹配和多重匹配导致的虚假定位使得卡尔曼滤波不再收敛, 因此匹配准则的选取对卡尔曼滤波至关重要。本文采用 Mahalanobis 准则作为约束条件, 并且只限局部地图中大于一定阈值的路标特征, 有效地控制虚假

定位的出现。

4) 状态更新

假设路标特征匹配成功的数目为 $\{i=1,2,\dots,M\}$, 令:

$$X(k+1/k)_0 = X(k+1/k)$$

$$P(k+1/k)_0 = P(k+1/k)$$

则位姿迭代更新公式为:


$$\begin{cases} S(k+1)_i = H(k+1)_i P(k+1/k)_i H(k+1)_i^T + P(k)_i \\ K(k+1/k)_i = P(k+1/k)_{i-1} H(k+1)_i^T S(k+1)_i^{-1} \\ X(k+1/k)_i = X(k+1/k)_{i-1} - \\ \quad + K(k+1)(z(k)_i - z(k)_i) \\ P(k+1)_i = P(k+1/k)_{i-1} - \\ \quad - K(k+1)S(k+1)_i K(k+1)_i^T \end{cases} \quad (16)$$

利用状态更新公式对机器人位姿进行修正。迭代结束时的机器人位姿就是机器人最终的更新位姿。


3.2 机器人定位实验

本实验以 Voyager II 号机器人作为机器人定位实验平台, 在其上面安装有两个高清 CCD 摄像机构成双目视觉。设定机器人的行走路线为实验室内的对角线。

由图 6, 在机器人运动过程中, 由于噪声和里程计误差等影响, 机器人实际运动轨迹与设定的轨迹有偏差。随着机器人运动时间的增加, EKF 定位效果越来越差, 甚至最后完全偏离设定路线, AEKF 定位一直保持着较好的定位效果。



(a)EKF 定位运动轨迹



(b)AEKF 定位运动轨迹

图 6 机器人运动轨迹

机器人定位包括机器人位置和运动方向. 为此, 对比两种算法在机器人运动过程中的位置误差和方向误差.




图 7 误差曲线对比图

试验得到 EKF、AEKF 的位置和方向的估计误差曲线. EKF 定位对机器人位置、方向滤波误差会随着时间的增加而逐渐增大; 而 AEKF 对机器人的位置、方向表现出了较好的稳定性, 其误差没有随着时间的增加发散. AEKF 在移动机器人定位的过程中得到了更为精确的机器人位姿.

4 结论

在室内环境中, 基于里程计模型, 采用双目视觉采集环境路标特征; 对比 EKF 和 AEKF 算法: 由于 EKF 在当前状态估计处, 只取一阶泰勒级数, 造成很大的误差积累, 而 AEKF 取各项泰勒级数, 线性化误差很小; AEKF 的噪声统计特性是时变的, 随着机器人所处的环境而改变, 而 EKF 采用的是根据经验所得的固定值, AEKF 具有更好的环境适应性. AEKF 在增加较小运算复杂度的情况下, 表现出了明显优越的定位精度, 具有很高的速度精度综合性价比. 本文提出采用 AEKF 实现机器人定位, 实验表明, 运用 AEKF 进行机器人定位要比 EKF 定位的更加精确, 具有更好的性能, 实用性更佳

参考文献

- 1 亢海龙,徐娅萍,王涛.基于卡尔曼滤波器的轮式机器人定位方法.机械与电子,2009,7:72-74.
- 2 康轶非,宋永瑞,宋宇.平方根容积卡尔曼滤波在移动机器人 SLAM 中的应用.机器人 ROBOT,2013,35(2):186-193.
- 3 vander Merwe R, Wan EA. The square-root unscented Kalman filter for state and parameter estimation. IEEE International Conference on Acoustics, Speech, and Signal Processing. Piscataway, NJ, USA: IEEE, 2001: 3461-3464.
- 4 周获,胡振坤,胡恒章.自适应推广 Kalman 滤波应用于导弹的被动制导问题.宇航学报,1997,18 (4):31-36.
- 5 Konolige K, Agrawal M. Frame SLAM: From bundle adjustment to real-time visual mapping. IEEE Trans. on Robotics, 2008, 24(5): 1066-1077.
- 6 Meng QH, Sun YC, Cao ZL. Adaptive extended Kalman filter (AEKF)-based mobile robot localization using onar. Robotics, 2000,18:459-473.
- 7 厉茂海,洪炳镭,罗荣华.移动机器人同时定位和地图创建方法.哈尔滨工业大学学报,2004,6(7):875-876.
- 8 Durrant-Whyte H, Bailey T. Simultaneous localization and mapping: Part I. IEEE Robotics and Automation Magazine, 2006,13(2): 99-108.
- 9 沈晔青,龚华金.自适应卡尔曼滤波在目标跟踪系统中的应用.计算机仿真,2007,24(11):210-273.
- 10 Kang JG, Choi WS, An SY, et al. Augmented EKF based SLAM method for improving the accuracy of the feature map. International Conference on Intelligent Robots and Systems. Piscataway, NJ, USA:IEEE, 2010:3725-3731.
- 11 苑全德,洪炳镭,关毅.一种基于特征点三维信息的自然路标提取与快速匹配方法.微能计算机与应用,2015,5(1):25-28.
- 12 林睿.基于图像特征点的移动机器人立体视觉研究.哈尔滨工业大学,2012.
- 13 SES.Lowed G, et al. Vision-based global localization and map-ping for mobile robots. IEEE Trans. on Robotics, 2005, 21(3):364-375.