

基于 Kalman 滤波的车位侧方距离修正方法

杨述斌^{1,2}, 蒋宗霖¹, 刘寒¹

(1. 武汉工程大学 电气信息学院, 武汉 430205; 2. 智能机器人湖北省重点实验室, 武汉 430205)

摘要: 通常车位识别技术通过超声波传感器获取侧方障碍物位置信息来判断车位边缘, 由于测量时超声波传感器与障碍物形成波束角的跳变, 及其本身的固有特性会带来随机噪声, 导致不能直接得到状态变量的真实精确值; 通过建立合适的距离修正系统状态方程和观测方程, 采用 Kalman 滤波算法, 由 $k-1$ 时刻的超声波传感器测量值与随机噪声获得该时刻的协方差, 并与测量噪声计算获得 k 时刻的 Kalman 增益, 再结合 k 时刻的超声波传感器测量值与观测方程得到 $k+1$ 时刻的距离修正值; 仿真结果表明, 经过 150 次迭代计算后的绝对误差为 1.575 cm, 平均修正时间仅需 0.028 s; 该方法可有效降低了随机噪声干扰, 具有良好的准确性和实时性, 滤波测量距离修正值更加逼近真实值。

关键词: 车位识别技术; 超声波传感器; Kalman 滤波

Vehicle Side Distance Correction Method Based on Kalman Filter

Yang Shubin^{1,2}, Jiang Zonglin¹, Liu Han¹

(1. School of Electrical and Information Engineering, Wuhan Institute of Technology, Wuhan 430205, China;

2. Hubei Provincial Key Laboratory of Intelligent Robot, Wuhan 430205, China)

Abstract: Generally, the parking space recognition technology uses the ultrasonic sensor to obtain the position information of the side obstacle to determine the edge of the parking space. Due to the jump of the beam angle formed by the ultrasonic sensor and the obstacle during the measurement, and its inherent characteristics will bring random noise, which may not directly obtain the true exact value of the state variable. By establishing a suitable distance correction system state equation and observation equation, Kalman filtering algorithm is used to obtain the covariance of the moment from the ultrasonic sensor measurement value and random noise at time $k-1$, and obtain the Kalman gain at time k from the measurement noise calculation. Then, the distance correction value of $k+1$ time is obtained by combining the measured value of the ultrasonic sensor at time k with the observation equation. The simulation results show that the absolute error after 150 iterations is 1.575 cm, and the average correction time is only 0.028 s, which is much smaller than the average correction error of the dual probe average method, the dual probe fusion method and the sensor error compensation method. It effectively reduces random noise interference, has good accuracy and real-time performance, and the filter measurement distance correction value is closer to the true value.

Keywords: parking space recognition technology; ultrasonic sensor; Kalman filter

0 引言

传统国外汽车厂商所采用的车位识别方案都基于超声波传感器或者毫米波雷达获取车位信息识别, 如丰田、奥迪、奔驰、宝马等公司, 利用安装于车身保险杠两端的超声波传感器进行车位的检测, 但由于存在传感器本身的固有特性以及在测量过程中因波束角的跳变等问题带来的随机干扰, 导致传感器不能直接得到所需要的测量真实值。

针对超声波传感器测量数据准确度不高、实时性较差的特性问题, 学者们提出了不同的解决办法。如陈乔松等提出采用双探头平均值法和双探头融合数据法来降低测量误差, 以此来提高超声波传感器的探测精度, 虽计算简单, 但因瞬时测量值绝对误差大, 导致实时性差^[1]。又如毕清磊通过大量实验数据得到障碍物距离与误差值之间的关系

式, 利用传感器误差补偿公式来进行修正误差, 但公式运算复杂, 大幅度降低单片机的运算速度, 且传感器测量误差会随着测量距离的增大而增大, 导致该方法准确性低^[2]。因此, 如何提高超声波测距的准确性和实时性, 并有效降低由传感器带来的随机噪声干扰是自动泊车系统中车位识别技术的一个新研究趋势。

Kalman 滤波就是这种能够有效降低随机噪声影响的工具。近年来, 随着科学技术的日益发展, Kalman 滤波与相关改进算法都能够在计算机的辅助下得以快速实现, 无论是在机器人的轨迹规划还是决策领域或者是在航天航空领域等重大军工业领域都有广泛地应用^[3]。总之, Kalman 滤波在信号处理与控制技术方面得到了均可有效地运用, 所以文章将以 Kalman 滤波算法为重点研究对象, 阐述其在自动泊车系统中车位识别技术的应用与实现。

1 线性离散 Kalman 滤波原理

Kalman 滤波由系统状态方程和系统观测方程两组基本方程组成。

系统状态方程是被估计状态 X_k 与受噪声驱动 W_{k-1} 的关

收稿日期: 2019-08-12; 修回日期: 2019-08-29。

基金项目: 智能机器人湖北省重点实验室开放基金(HBIR201406)。

作者简介: 杨述斌(1971-), 男, 湖北襄阳人, 教授, 硕士生导师, 主要从事信号、图像处理与多媒体通信的教学方向的研究。

系式:

$$X_k = A_{k,k-1}X_{k-1} + BU_{k-1} + W_{k-1} \quad (1)$$

对 X_k 的观测满足线性关系, 观测方程为:

$$Z_k = H_k X_k + V_k \quad (2)$$

X_k 是 k 时刻的系统状态, U_k 是 k 时刻对系统的控制量。 $A_{k,k-1}$ 是从 $k-1$ 时刻到 k 时刻的状态转移矩阵。 H_k 是观测矩阵。 W_k 是系统的激励噪声, V_k 是观测噪声。在 Kalman 滤波中, 要求 W_k 和 V_k 是正态分布的白色噪声。因此有:

$$\begin{cases} E[W_k] = 0, Cov[W_k, W_j] = E[W_k W_j^T] = Q_k \delta_{kj} \\ E[V_k] = 0, Cov[V_k, V_j] = E[V_k V_j^T] = R_k \delta_{kj} \\ Cov[W_k, W_j] = E[W_k W_j^T] = 0 \end{cases} \quad (3)$$

其中, Q_k 和 R_k 分别是系统噪声 W_k 和观测噪声 V_k 的方差矩阵。

Kalman 滤波信息更新由时间更新和观测更新这两个过程组成, 其中时间更新过程也称为预测过程, 观测更新过程也称为修正过程。

预测过程:

1) 根据上一状态预测的当前系统状态:

$$\hat{X}_k^- = A_{k,k-1} \hat{X}_{k-1} + BU_{k-1} \quad (4)$$

\hat{X}_k^- 的上标 “-” 代表是被估计量的预测值, 并非真实值。 \hat{X}_{k-1} 是上一时刻的最优估计, 上标 “^” 代表是估计值。 U_k 是状态的控制量, 若没有控制量, 则为零。

2) 对误差协方差的预测:

$$P_k^- = A_{k,k-1} P_{k-1} A_{k,k-1}^T + Q_k \quad (5)$$

P_{k-1} 是与 \hat{X}_{k-1} 对应的误差协方差, 即上一时刻的误差协方差, Q_k 是系统噪声序列 W_k 的方差矩阵。

上述两个方程是系统的预测过程, 式 (4) 根据 $k-1$ 时刻的状态最优估计预测 k 时刻的状态估计, 式 (5) 描述了这种预测的均方差, 对预测的好坏程度做定量描述, 其值也是由上一时刻的误差协方差来做预测。从时间角度来分析, 即这两个式子将时间从 $k-1$ 时刻推进到 k 时刻, 于是这个过程称为 Kalman 滤波的预测过程。

修正阶段:

1) 计算 Kalman 增益:

$$K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (6)$$

Kalman 增益的校正状态值得误差协方差的重要参数, 用来权衡系统预测的传感器量测。其中 H_k 是观测矩阵, R_k 是观测噪声序列的方差阵。

2) 对系统状态预测值的修正:

$$\hat{X}_k = \hat{X}_k^- + K_k (Z_k - H_k \hat{X}_k^-) \quad (7)$$

当系统的第 k 时刻的观测值 Z_k 到达止之后, Kalman 滤波要求利用观测值来校正第 k 时刻的状态预测值, 经过校正后的 \hat{X}_k 就是 k 时间的状态最优估计, 将会用于下一时刻, 即 $k+1$ 时刻有: $\hat{X}_{k+1}^- = A_{k,k-1} \hat{X}_k + BU_k$ 。

3) 对误差协方差的修正:

$$P_k = (I - K_k H_k) P_k^- \quad (8)$$

其中: I 是单位矩阵, 对于单模型单测量, $I = 1$ 。更新 k

时刻状态估计 \hat{X}_k 的误差协方差是使 Kalman 滤波算法自回归的关键, 将会用于下一时刻的误差协方差预测中。因此, $k+1$ 时刻有 $P_{k+1}^- = A_{k+1,k} P_k A_{k+1,k}^T + Q_{k+1}$ 。

式 (6) 和式 (8) 利用状态预测的质量优劣 (P_k^-)、观测信息的质量优劣 (R_k)、观测与状态的关系 (H_k) 以及观测信息 Z_k 修正时间上的预测, 构造改进后的最优估计, 描述了 Kalman 滤波的修正过程。得到的最优估计又会作为先验数据供下次预测使用, 由此行成递归推算。其中, Kalman 滤波也就是由式 (4) ~ 式 (8) 这个五项基本方程组成^[4-7]。

2 Kalman 滤波的距离修正原理

2.1 测距系统建模

超声波测距模块采样时间为 25 ms, 在 3.75 s 内采样到 150 组距离数据信息, 对这 150 组数据滤波及修正, 便可以稳定输出一个比较接近真实值的数值。经过多次测量, 并取平均值得到小车离侧方障碍物大约为 5 cm, 这个距离可能会受到传感器固有特性等问题带来一些外部因素的干扰, 于是将这个扰动则为过程噪声 W_k , 其方差矩阵为 Q , 大小假定为 $Q = 0.0001$ (如果不考虑过程噪声的影响, 此时 $Q = 0$)。因为考虑系统中的 X_k 是在第 k 时刻采样时的距离信息是一维的, 而且无控制量。由此对照式子 (1), 可以得出该系统的状态方程是:

$$X_k = X_{k-1} + W_{k-1} \quad (9)$$

小车侧方传感器与障碍物的实时测量部分数据如表 1 所示。

取前 20 组数据作为实验输入, 经过如下式 (10) 计算得测量误差方差为: $R = 0.7959$ 。

$$R = s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (10)$$

由此得超声波第 k 次测的的数据不一定是准确的, 因含有测量噪声 V_k , 所以得到系统的观测方程为:

$$Z(k) = X(k) + V(k) \quad (11)$$

综上所述, 该系统的状态方程和观测方程为:

$$\begin{aligned} X_k &= A_{k,k-1} X_{k-1} + W_{k-1} \\ Z_k &= H_k X_k + V_k \end{aligned} \quad (12)$$

表 1 小车与障碍物距离信息表

		实时测量距离信息																						
序号	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	
真实值/cm	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	
测量值/cm	3.97	6.14	3.97	5.70	5.70	5.72	5.70	3.95	5.70	5.00	2.90	4.02	4.83	6.56	4.86	4.97	5.28	5.28	5.28	4.81	5.70	4.23	3.97	

式中, X_k 是距离信息为一维变量, 则 $A_{k,k-1} = 1, H_k = 1, W_{k-1}$ 和 V_k 的方差矩阵分别为 Q 和 R [8-10]。

建好系统之后, 即可用 Kalman 滤波来处理过程噪声 W_k 和测量噪声 V_k 。根据 Kalman 滤波的实质, 可以知道如果要估算 k 时刻的实际值, 就要根据 $k-1$ 时刻的值来对其进行估算。

2.2 Kalman 滤波的距离修正

1) 假定前 20 组值测得第一组距离值为 $k-1$ 时刻的值 L_{k-1} , 距离的真实值为 S , 那么该测量值的偏差是 $S - L_{k-1}$, 即该时刻的协方差 $P_{k-1} = (S - L_{k-1})^2 = M$ 。

2) 在 k 时刻, 超声波测距传感器的测量值由于传感器的固有特性, 测得第二组值 L_k , 偏差为 $S - L_k$ 。现在用于估算第 kk 时刻的测量值由两个测量值, 分别是 $k-1$ 时刻的 L_k 和 k 时刻的 $S - L_k$, 将以上两组测量值进行融合使其逼近真实值, Kalman 滤波也非常适合循环迭代运算, 因此也适合采用计算机程序实现, 实现流程如图 1 所示。




图 1 Kalman 滤波的数据修正过程

因为 $A_{k,k-1}$ 及 H_k 均为 1, 所以具体操作步骤如下。根据 Kalman 滤波的五项基本方程 (4~8), 这里分 5 步来分析 Kalman 滤波的数据修正流程。

1) 根据 $k-1$ 时刻的值, 对状态预测

$$\hat{X}_k^- = L_{k-1}$$

2) 计算协方差预测,

$$P_k^- = P_{k-1} + Q(S - L_{k-1})^2 + Q = M + QP_k^-$$

3) 计算 Kalman 增益,

$$K_k = P_k^- / (P_k^- + R) = (M + Q) / [(M + Q) + R]$$

4) 状态更新, 由

$$\hat{X}_k = \hat{X}_k^- + K_k(Z_k - H_k \hat{X}_k^-)$$

得:

$$\hat{X}_k = L_{k-1} + [(M + Q) / (M + Q + R)] * (L_k - L_{k-1})$$

5) 协方差更新,

$$P_k = (I - K_k H_k) P_k^- =$$

$$\{I - [(M + Q) / (M + Q + R)] * H_k\} * (M + Q)$$

根据表 1 的记录数据, 令 $L_{k-1} = 3.97$ cm, $L_k = 6.14$ cm 且 $S = 5$ cm 时, 由上述 5 步迭代计算得到的一个滤波结果 $\hat{X}_k = 5.2099$ cm, 此值与 k 时刻测量值的 L_k 相比, k 时刻滤波效果更接近真实值 S , 将噪声从 $L_k - S = 1.14$ cm 减小到 $\hat{X}_k - S = 0.2099$ cm, 这就是 Kalman 滤波的效果。

其中, Matlab 开发平台下的部分核心代码如下:

```
% State initialization
S=zeros(1,T);S(1,1)=5.00;
% observation initialization
L=zeros(1,T);L(1,1)=3.97;
```

```
%State initialization by Kalman filtering
Skf=zeros(1,T);Skf(1,1)=L(1,1);
% covariance initialization
P=zeros(1,T);P(1,1)=1.0609;
% The measured target is one-dimensional information
for k=2:T
% X is the true distance value, which consists of the real value
and the disturbance caused by the disturbance.
% Equation of state S(1,k)=F * S(1,k-1)+G * W(1,k);
% The range finder can only be measured by the sensor, the
measurement information is Z, and the filter starts according to the
measurement information.
% observation equation
L(1,k)=H * X(1,k)+V(1,k);
% Step 1: Status Forecast
Spre=H * Skf(1,k-1);
% Step 2: Covariance prediction
Ppre=F * P(k-1) * F'+Q;
% Step 3: Calculate the Kalman gain
K=Ppre * inv(H * Ppre * H'+R);
% calculation information
e=L(k)-H * Xpre;
% Step 4: Status Update
Skf(1,k)=Spre+K * e;
% Step 5: Covariance update
P(1,k)=(I-K * H) * Ppre;
end
```

其中, 状态转移矩阵 $F = 1$; 噪声驱动矩阵 $G = 1$; 观测矩阵 $H = 1$; 过程噪声方差 $Q = 0.0001$; 观测噪声方差 $R = 0.7959$; 仿真总步数 $T = 150$; 过程噪声为 $W = \text{sqr}t(Q) * \text{randn}(1, T)$; 观测噪声为 $V = \text{sqr}t(R) * \text{randn}(1, T)$; 单位矩阵 $I = \text{eye}(1)$;

从 Kalman 滤波的本质来看, Step 1 和 Step 2 将时间从 $k-1$ 时刻推进至 k 时刻, 描述了 Kalman 滤波的预测过程, 具体的距离修正量由时间更新的质量优劣 (P_k^-)、观测信息的质量优劣 (R)、观测与状态的关系 (H) 及具体的观测信息 $L(k)$ 得以确定, 这些步骤都是以如何正确合理的利用观测 $L(k)$ 为目的的, 同时这 5 步也恰恰描述了 Kalman 滤波的修正过程。

3 距离修正仿真结果与分析

应用以上的系统的状态方程和测量方程, 在 Inter (R) Core (TM) CPU 主频为 2.3 GHz, 安装内存 4 GB 的计算机上运行 Matlab R2018a 进行仿真实验, 分析小车与侧方障碍物距离信息的真实值、测量值和滤波修正值的差异, 同时也计算了测量偏差与滤波偏差, 部分核心代码已在上文给出。

图 2 中, 实线代表的是真实值, 圆圈代表的是在随机噪声干扰下的超声波传感器测量值, 而星号线则代表的是滤波修正值。由图 2 可见, 超声波传感器的测量值准确度低, 绝对误差的波动非常大, 但滤波修正值逐渐地逼近真实值, 且趋于稳定。标记出 6 组样本值, 记录如表 2 所示。

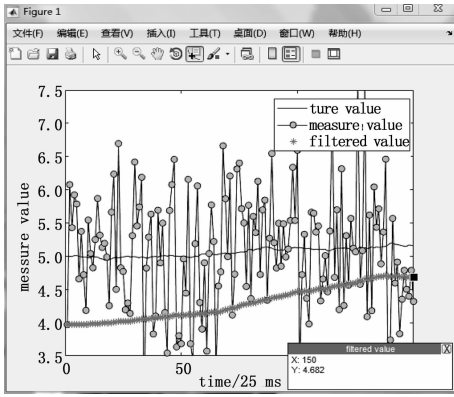


图 2 真实值、测量值与滤波值的差异图

表 2 kalman 滤波算法样本值实验结果

序号	真实值/cm	滤波值/cm	绝对误差/cm	相对对误差/%
1	5.00	4.02	-0.98	19.60
2	5.00	4.11	-0.89	17.80
3	5.00	4.25	-0.75	15.00
4	5.00	4.47	-0.53	10.60
5	5.00	4.59	-0.41	8.20
6	5.00	4.68	-0.32	6.40

图 3 中, 将各个采样时刻、滤波结果和真实值去做差, 计算其绝对值, 这个值就是偏差值, 定义为:

$$X_{dev}(k) = | X_n(k) - X(k) | \quad (13)$$

同样地, 将其用于 Matlab 的“Figure”中自带的数据标尺工具在图 3 中将第 1 次和第 150 次的偏差标出, 结果发现其测量偏差值由 1 逐渐减小到 0.4779, 且其偏差逐渐趋于稳定值。

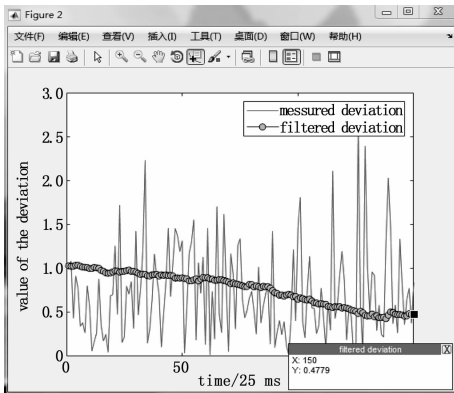


图 3 误差分析图

表 2 中的 6 组样本值分别代表第 25、50、75、100、125、150 次的滤波结果, 由表 2 可知经过 150 次迭代计算后的测量值已经达 4.68 cm, 相对误差由 0.98 cm 减少到 0.32 cm, 可见反复迭代计算值的绝对误差逐渐降低, 并将继续减小, 使其测量值逼近真实值, 且趋于稳定。

为了验证 Kalman 滤波在自动泊车系统中车位识别技术的普适性, 在真实距离 S 为 15 cm, 25 cm, 35 cm, 45 cm, 55 cm, 65 cm 的不同情况下, 利用上述原理进行测量数据的滤波修正, 并记录其结果, 如表 3 所示。

表 3 不同真实距离下的测量数据滤波修正结果

序号	真实值/cm	滤波值/cm	数据修正所需时间/s
1	15.00	13.49	0.032
2	25.00	23.02	0.033
3	35.00	33.25	0.025
4	45.00	43.60	0.027
5	55.00	53.45	0.033
6	65.00	63.74	0.022

由表 3 数据发现, 经过 150 次迭代计算后的测量值, 其绝对误差不会随着距离增加而增加, 且绝对误差可以保证在 2 cm 以内, 实验的平均绝对误差仅 1.575 cm, 准确度高。

同上, 运行在真实距离 S 为 15 cm, 25 cm, 35 cm, 45 cm, 55 cm, 65 cm 的不同情况下, 并用 MATLAB 的“Etime”函数获取各数据修正所需的时间, 并记录如表 4 所示。

表 4 不同真实距离下的测量数据滤波修正所需时间

序号	真实值/cm	滤波值/cm	绝对误差/cm	相对误差/%
1	15.00	13.49	-1.51	10.60
2	25.00	23.02	-1.98	7.92
3	35.00	33.25	-1.75	5.00
4	45.00	43.60	-1.40	3.10
5	55.00	53.45	-1.55	2.80
6	65.00	63.74	-1.26	1.93

由表 4 可计算得到这 6 次实验的数据修正所需平均时间为 0.028 s, 而且 Kalman 滤波计算过程为一个不断“预测—修正”的过程, 在数据修正时不需要存储大量的数据, 且一旦观测到新的数据, 随时可以计算得滤波修正值, 有非常好的实时处理性。

综上所述, 该方法使用的 kalman 滤波算法可有效降低了随机噪声干扰, 使车位识别技术中侧方障碍物距离数据得以修正, 准确性高且实时性好, 同时也完全符合安全泊车距离±5 cm 的标准, 进而使车辆泊车可达到理想效果。

4 结语

本文通过合理地设计状态方程及观测方程, 采用 Kalman 滤波的车位侧方距离修正方法得到的距离平均修正误差小, 运行时间更短, 表明该算法具有更好的准确性和实时性。逐步迭代的计算使滤波修正值继续逼近真实值, 可以有效应用于实际的车位识别系统中。

参考文献:

[1] 陈乔松, 等. 自动泊车系统设计 [M]. 北京: 科学出版社, 2014.

[2] 毕清磊. 自动泊车辅助系统的研究与开发 [D]. 重庆: 重庆交通大学, 2017: 33-36.

[3] 董辉, 王亚男, 童辉. 基于自适应 Kalman 滤波的机器人人体目标跟随 [J]. 高技术通讯, 2019, 29 (3): 51-58.