


# 估计与预测



姚远

yaoyuan@shu.edu.cn



上海大学机自学院


2020/10/28

# 大纲




- 估计器
- 卡尔曼滤波
- 校正的理论基础
- 预测与校正
- 粒子滤波

# 估计器(Estimators)



反馈

观测位置



撞击位置



- 噪声
- 运动
- 非直接测量

# 估计器(Estimators)



- 预测：根据过去的信息预测*真实值*
- 校正：根据预测的信息校正*观测值*



实现估计器的两个步骤

# 估计器(Estimators)



- 从经验中预测的实例

贝叶斯规则

条件概率  $p(A|B)$  表达当**B**发生的条件下**A**发生的概率

- 组合概率

$$P(A \wedge B) = p(A \cap B) = p(A)p(B|A)$$

$$P(A \wedge B) = p(A \cap B) = p(B)p(A|B)$$

- 贝叶斯规则


$$p(A)p(B|A) = p(B)p(A|B)$$

$$\Rightarrow p(B|A) = \frac{p(A|B)p(B)}{p(A)}$$

# 估计器(Estimators)



- 从经验中预测的实例



无人驾驶问题

如何从从观察**s**中推测是否遇到障碍**obstacle**?

$$p(\text{obstacle} | s)$$



# 估计器(Estimators)



- 从经验中预测的实例

以下哪一种更难?

$$p(\text{obstacle} | s)$$


从观察到某种特征，判断其属于障碍的概率

如何从从观察**s**中推测是否遇到障碍**obstacle**?

$$p(s | \text{obstacle})$$

如果确定观察对象是障碍，观察到某种特征的概率

$$p(\text{obstacle} | s)$$




# 估计器(Estimators)



- 从经验中预测的实例

应用贝叶斯规则估计

$$p(\text{obstacle} | s) = \frac{p(s | \text{obstacle})p(\text{obstacle})}{p(s)}$$



$p(s)?$

# 估计器(Estimators)



- 从经验中预测的实例

应用贝叶斯规则估计

$$p(\text{obstacle} | s) = \frac{p(s | \text{obstacle}) p(\text{obstacle})}{p(s)}$$

$$p(!\text{obstacle} | s) = \frac{p(s | !\text{obstacle}) p(!\text{obstacle})}{p(s)}$$

# 估计器(Estimators)



- 从经验中预测的实例

应用贝叶斯规则估计

$$p(obstacle | s) + p(!obstacle | s) = 1 \Rightarrow$$

$$p(s) = p(s | obstacle)p(obstacle) + p(s | !obstacle)p(!obstacle)$$

$$p(obstacle | s) = \frac{p(s | obstacle)p(obstacle)}{p(s | obstacle)p(obstacle) + p(s | !obstacle)p(!obstacle)}$$

# 估计器(Estimators)




- 从经验中预测的实例

假如  $p(\text{obstacle}) = 0.2$

$p(s \mid \text{obstacle}) = 0.8$

$p(s \mid \neg \text{obstacle}) = 0.05$



$p(\text{obstacle} \mid s) = ?$

# 估计器(Estimators)




- 从经验中预测的实例

假如  $p(\text{obstacle}) = 0.2$

$p(s | \text{obstacle}) = 0.8$

$p(s | \neg \text{obstacle}) = 0.05$



$$\begin{aligned} p(\text{obstacle} | s) &= \frac{p(s | \text{obstacle})p(\text{obstacle})}{p(s | \text{obstacle})p(\text{obstacle}) + p(s | \neg \text{obstacle})p(\neg \text{obstacle})} \\ &= \frac{0.8 * 0.2}{0.8 * 0.2 + 0.05 * 0.8} = 0.8 \end{aligned}$$

# 估计器(Estimators)



- 贝叶斯估计从已知的状态中推测位置未知状态
- 在**Kalman**滤波中，每一步通过演变当前的数据分布推测下一步的数据分布。
- 在**粒子滤波**中，使用一组包含不同分布的粒子，通过其权值组合推测下一步的数据分布

Kalman滤波器和粒子滤波器都可看作贝叶斯滤波的**特殊实例**

# 大纲



- 估计器
- 卡尔曼滤波简介
- 校正的理论基础
- 预测与校正
- 粒子滤波

# 卡尔曼滤波简介



■ 卡尔曼滤波是从一组有限的，包含噪声的，对物体位置的**观察序列**（可能有偏差）**预测**出物体的位置的**坐标及速度**。在很多工程应用(如雷达、计算机视觉)中都可以找到它的身影。同时，卡尔曼滤波也是控制理论以及控制系统工程中的一个重要课题。



■ Rudolph E. Kalman

- Swerling 1958 提出通用形式
- Rudolph E. Kalman 1960 发表滤波器算法
- Stanley Schmidt 实现算法

- 用于阿波罗登月导航
- 用于弹道导弹潜艇的导航
- 用于战斧巡航导弹的导航
- 用于... ..

# 卡尔曼滤波简介



## ■卡尔曼滤波

- 从一组有限的,  
包含噪声的,  
对物体位置的观察序列 (可能有偏差)  
预测出物体的位置的坐标及速度。



## ■用于很多工程应用

- 雷达
- 机器人
- 航空导航
- 是控制理论以及控制系统工程中的一个重要课题。

# 卡尔曼滤波简介



## ■卡尔曼滤波

- 从一组有限的,  
包含噪声的,  
对物体位置的观察序列 (可能有偏差)  
预测出物体的位置的坐标及速度。

## ■用于很多工程应用

- 雷达
- 机器人
- 航空导航
- 是控制理论以及控制系统工程中的一个重要课题。



## 基本思想

- 给定一组合理的假设, 可以从观测到的历史数据中推断出系统模型的描述。
- 方法: 通过最大化 (假设模型) 后验概率

# 卡尔曼滤波简介




卡尔曼滤波本质上是一种数据融合技术

## 三个假设

- 线性模型
- 白噪声
- 正态分布的噪声

$$\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$



在三个假设基础上，合并旧信息和新的信息。

# 卡尔曼滤波简介



卡尔曼滤波本质上是一种数据融合技术

- 合并不同传感器数据
- 合并不同时间数据
- 仅需要上一个时刻的信息

包含校正和预测两个环节，可通过扩展用于非线性系统

# 大纲




- 估计器
- 卡尔曼滤波
- 校正的理论基础
- 预测与校正
- 粒子滤波

# 校正的理论基础



- 假设有两个带有噪声的位置观测数据



$$p_i(x) = \frac{1}{\sigma_i \sqrt{2\pi}} \exp\left(-\frac{(x-\bar{x})^2}{2\sigma_i^2}\right) (i = 1,2)$$

- 描述观测数据  $p_{12}(x) = p_1(x)p_2(x)$

$$p_{12}(x) \propto \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2}\right) \exp\left(-\frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right) = \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2} - \frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right)$$

# 校正的理论基础



- 描述观测数据  $p_{12}(x) = p_1(x)p_2(x)$

$$p_{12}(x) \propto \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2}\right) \exp\left(-\frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right) = \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2} - \frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right)$$

$$\bar{x}_{12} = ?$$

正态分布，均值出现的位置概率最大

$$\sigma_{12}^2 = ?$$

$$\left. \frac{dp_{12}}{dx} \right|_{\bar{x}_{12}} = -\left[ \frac{\bar{x}_{12} - \bar{x}_1}{\sigma_1^2} + \frac{\bar{x}_{12} - \bar{x}_2}{\sigma_2^2} \right] \cdot p_{12}(\bar{x}_{12}) = 0$$

# 校正的理论基础



- 描述观测数据  $p_{12}(x) = p_1(x)p_2(x)$

$$p_{12}(x) \propto \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2}\right) \exp\left(-\frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right) = \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2} - \frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right)$$

$$\bar{x}_{12} = ? \quad \bar{x}_{12} = \left(\frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\right)\bar{x}_1 + \left(\frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\right)\bar{x}_2$$

$$\sigma_{12}^2 = ? \quad \sigma_{12}^2 = \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 + \sigma_2^2}$$

# 校正的理论基础



- 描述观测数据  $p_{12}(x) = p_1(x)p_2(x)$

$$p_{12}(x) \propto \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2}\right) \exp\left(-\frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right) = \exp\left(-\frac{(x-\bar{x}_1)^2}{2\sigma_1^2} - \frac{(x-\bar{x}_2)^2}{2\sigma_2^2}\right)$$

- 假设在时间  $t$  观测为  $(x_i, \sigma_i)$ , 我们的预测为  $(\hat{x}_i, \hat{\sigma}_i^2)$

$p_i$

$p_{i+1}$

$$\bar{x}_{12} = \left(\frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2}\right)x_1 + \left(\frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2}\right)x_2$$

$$\sigma_{12}^2 = \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 + \sigma_2^2}$$

- 在第一步

$$\hat{x}_1 = x_1$$

$$\hat{\sigma}_1^2 = \sigma_1^2$$

- 在第二步


$$\hat{x}_2 = \left(\frac{\sigma_2^2}{\hat{\sigma}_1^2 + \sigma_2^2}\right)\hat{x}_1 + \left(\frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2}\right)x_2 = \hat{x}_1 + \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2}(x_2 - \hat{x}_1)$$

$$\hat{\sigma}_2^2 = \frac{\hat{\sigma}_1^2 \sigma_2^2}{\hat{\sigma}_1^2 + \sigma_2^2} = \left(1 - \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2}\right) \hat{\sigma}_1^2$$

# 校正的理论基础



- 假设在时间  $t$  观测为  $(x_i, \sigma_i)$ ，我们的估计为  $(\hat{x}_i, \hat{\sigma}_i^2)$



- 在第一步

$$\hat{x}_1 = x_1$$

$$\hat{\sigma}_1^2 = \sigma_1^2$$

- 在第二步

$$\hat{x}_2 = \left( \frac{\sigma_2^2}{\hat{\sigma}_1^2 + \sigma_2^2} \right) \hat{x}_1 + \left( \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2} \right) x_2 = \hat{x}_1 + \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2} (x_2 - \hat{x}_1)$$

$$\hat{\sigma}_2^2 = \frac{\hat{\sigma}_1^2 \sigma_2^2}{\hat{\sigma}_1^2 + \sigma_2^2} = \left( 1 - \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2} \right) \hat{\sigma}_1^2$$

增益  $K$     更新

$$\hat{x}_k = \hat{x}_{k-1} + K(x_k - \hat{x}_{k-1})$$


$$\hat{\sigma}_k^2 = (1 - K) \hat{\sigma}_{k-1}^2$$

# 大纲




- 估计器
- 卡尔曼滤波简介
- 校正理论基础
- 预测与校正
- 粒子滤波

# 预测过程



实现估计器的两个步骤

顺序?



# 预测过程



## 卡尔曼滤波的预测中所考虑的运动

- 动态运动


$x + vdt$  可能包含更多的参数。

- 可控运动

从外部引入系统的控制指令

- 随机运动

未知的运动，高斯分布的随机运动



# 预测过程



## 建立预测方程

### ■ 动态运动

$x + vdt$  可能包含更多的参数。

运动方程 $M=F(x)$ ，系统变量如何按照已知规律变化

### ■ 可控运动

从外部引入系统的控制指令

引入控制变量 $u$

### ■ 随机运动

未知的运动，高斯分布的随机运动

引入影响系统的随机因素

# 预测过程



建立预测方程

$$\mathbf{x}_k = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{B}u_{k-1} + \mathbf{w}_k$$

$\downarrow$   
 $\sim N(0, Q)$

$$\mathbf{B} = \begin{bmatrix} \frac{\Delta t^2}{2} \\ \Delta t \\ 1 \\ 0 \end{bmatrix} \quad u = a$$

$$\mathbf{x}_k = \begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix} \quad \mathbf{F} = \begin{bmatrix} 1 & 0 & dt & 0 \\ 0 & 1 & 0 & dt \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

# 预测过程



建立观测方程

$$\mathbf{z}_k = \mathbf{H}_k^T \mathbf{x}_k + \mathbf{v}_k$$

↓

$$\sim N(\mathbf{0}, R_k)$$

$$\mathbf{v}_k \sim N(\mathbf{0}, R_k)$$

$$\mathbf{z}_k = \begin{bmatrix} z_x \\ z_y \end{bmatrix}_k$$

$$\mathbf{H}_k = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \end{bmatrix}$$

$$\mathbf{x}_k = \begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix}$$

# 预测与校正




- 预测

$$\mathbf{x}_k^- = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_{k-1} + \mathbf{w}_k$$

- 更新方差

$$\mathbf{P}_k^- = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{Q}_{k-1}$$

$$(\mathbf{P}^- = \Sigma^-)$$



# 预测与校正



预测 → 更新方差

$$\mathbf{x}_k^- = \mathbf{F}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_{k-1} + \mathbf{w}_k$$


$$\mathbf{P}_k^- = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{Q}_{k-1}$$

观测 → 校正

$$\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^- \quad \text{更新}$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_k^- \quad \text{校正}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)$$



# 预测过程



需要被预测的值

■增益:  $\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T \left( \mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R}_k \right)^{-1}$

$$\hat{\sigma}_2^2 = \frac{\hat{\sigma}_1^2 \sigma_2^2}{\hat{\sigma}_1^2 + \sigma_2^2} = \left( 1 - \frac{\hat{\sigma}_1^2}{\hat{\sigma}_1^2 + \sigma_2^2} \right) \hat{\sigma}_1^2$$

增益K

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^-$$

# 预测过程

## ■ 整体流程

### - 预测

$$\hat{\mathbf{x}}_k^- = \mathbf{F}\hat{\mathbf{x}}_{k-1} + \mathbf{B}\mathbf{u}_{k-1}$$
$$\mathbf{P}_k^- = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{Q}_{k-1}$$

### - 校正 (观测值)


$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H}\mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1}$$
$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)$$
$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^-$$



# 实例演示



## 1D位置预测



# 大纲




- 估计器
- 卡尔曼滤波
- 校正的理论基础
- 预测过程
- 粒子滤波

# 粒子滤波简介



▪ 粒子滤波(PF: **Particle Filter**)的思想基于蒙特卡洛方法(Monte Carlo methods), 它是利用粒子集来表示概率, 可以用在任何形式的状态空间模型上。其核心思想是通过从后验概率中抽取的随机状态粒子来表达其分布, 是一种顺序重要性采样法(Sequential Importance Sampling)。



- 粒子滤波有很多名字  
Importance Sampling, the Metropolis Algorithm, Monte Carlo Methods, CONDENSATION algorithm
- 源于Bayes估计的顺序采样(SIS)方法(Hammersley 1950-1960)
- 基于SIS的Bootstrap方法(Gordon 1993)

# 粒子滤波简介





$$\hat{x}_k = \hat{x}_{k-1} + K(x_k - \hat{x}_{k-1})$$

$$\hat{\sigma}_k^2 = (1 - K)\hat{\sigma}_{k-1}^2$$




t1

# 粒子滤波简介



# 粒子滤波简介



## ■ 粒子滤波解决

1. 我们想知道 $A$
2. 我们能够测量 $A$ 的一些相关的信息
3. 我们知道这些相关信息和 $A$ 之间的关系

# 粒子滤波简介




- 一种依赖多种不同假设的信息融合技术

$$P(x_t | y_{1:t}) = \frac{1}{c_t} P(y_t | x_t) \int_Z P(x_t | x_{t-1} = z) P(x_{t-1} = z | y_{1:t-1}) dz$$


运动模型

使用的分布(粒子)

观测模型(=权值)




# 粒子滤波的基础-采样




原始数据

# 粒子滤波的基础-采样




原始数据




采样-200个


# 粒子滤波的基础-采样



原始数据




采样-500个




采样-200个


# 粒子滤波的基础-采样



原始数据




采样-1000个




采样-200个

采样-500个


# 粒子滤波的基础-采样




原始数据



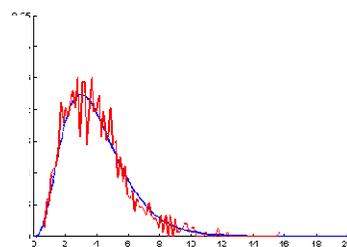
采样-5000个



采样-200个




采样-500个




采样-1000个


# 粒子滤波的基础-采样




原始数据




采样-20000个




采样-200个



采样-500个



采样-1000个






采样-5000个

# 粒子滤波的基础-采样



## ▪ 顺序重要性采样




# 预测过程与实例



## Kalman Filter

- ▶  $\mathbf{x}_0 \sim N(\hat{\mathbf{x}}_0, P_0)$
- ▶  $\mathbf{x}_t = A\mathbf{x}_{t-1} + \mathbf{w}_t$        $\mathbf{x}_t = A\mathbf{x}_{t-1} + B\mathbf{u}_{t-1} + \mathbf{w}_{t-1}$
- ▶  $\mathbf{y}_t = H\mathbf{x}_t + \mathbf{v}_t$
- ▶  $\mathbf{w}_t \sim N(0, Q)$  iid,  $\mathbf{v}_t \sim N(0, R)$  iid

线性模型



# 预测过程与实例




## Particle Filter 的策略

- 根据初始概率分布，采样 $N$ 个样本（粒子），设计权值

$$x_0^{(1)}, \dots, x_0^{(N)} \sim \pi(x_0)$$

- 在其后每一步，根据具体问题的观测更新粒子权值
- 在每一步使用所有粒子近似表达 $x_i$ 的分布



# 预测过程与实例




## 粒子重采样

- 根据初始概率分布，采样N个样本（粒子）

$$\mathbf{x}_0^{(1)}, \dots, \mathbf{x}_0^{(N)} \sim \pi(\mathbf{x}_0)$$

- 在其后每一步，根据具体问题更新粒子（根据观测）
- 根据更新粒子，重新采样



粒子存在退化的情况，需要去除  
权值过低的粒子

# 预测过程与实例



## 粒子滤波器的表达

$$Bel(\bar{x}) \approx \{x^i, w^i\} \quad i \in [1..m]$$

- $m$  表示粒子的数量
- $x^i$  表示每个粒子要预测的状态
- $w^i$  表示每个粒子相应的权值，且  $\sum w^i = 1$

# 预测过程与实例



```
function  $X_{k+1} = \text{runFilter}(X_k, z_k, u_k)$   
 $X_{k+1} = \emptyset$   
for  $i = 1 : m$   
    generate random  $x$  from  $X_k$  based on sample weights;  
    generate random  $x' \sim p(x' | u_k, x)$ ;  
     $w = p(z_k | x')$ ;  
    Insert  $(x', w) \in X_{k+1}$ ;  
end  
Normalize weight factors  $\forall w_i \in X_{k+1}$ ;  
return  $X_{k+1}$ ;
```

- $u_k$  表示预测目标的运动， $z_k$  为观测状态

# 预测过程与实例



- 典型实例 – 基于视频的目标跟踪



- 视频

# 预测过程与实例



## ■ 典型实例 – 基于视频的目标跟踪

- 第一步：提取目标特征，初始化粒子滤波器。



- 第二步：搜索，均匀撒点或者高斯分布撒点




# 预测过程与实例



## ■ 典型实例 – 基于视频的目标跟踪

- 第三步：评估，将不同点取回的数据特征与原始特征相比较，将结果加权平均。



是否相似？

- 第四步：根据相似度进行重采样



# 预测过程与实例



## ■ 典型实例 – 基于视频的目标跟踪

- 无论目标是否被遮挡，重采样算法保证目标出现时可以重新跟踪



# 总结



## ■ 粒子滤波

需要记住的

- 一种顺序重要性采样方法
- 使用观测更新权值
- 根据权值进行重采样
- 同时考虑使用运动模型来预测粒子
- 可用于人工智能、信号处理、金融风险分析和计算物理等不同领域。

# 作业-4



- 1) 在给出的**Kalman Filter** 代码实例的基础上(或自行寻找**Kalman**的实现代码), 设计目标物体的运动轨迹, 测试**Kalman Filter**的跟踪效果;
- 2) 根据实验结果整理报告, 说明**Kalman Filter**的原理, 以及最基本的**Kalman Filter**有何局限性, 给出可能的改进方法和相关文献。

# 课堂报告



- 1) 选定一个作业/与课题相关问题
- 2) 思路与方案
- 3) 预期实验设计与实施过程
- 4) 预期实验结果与说明

▪课堂报告：在第**8**周课堂上报告（准备**ppt**）。