

『非线性滤波算法』

Dr. Yuan-Li Cai

Spring 2024

0. Outline

- 1 非线性贝叶斯滤波理论 / 3
- 2 基于标称状态的线性化滤波方法 / 16
- 3 扩展卡尔曼滤波 / 23
- 4 递代扩展卡尔曼滤波 / 30
- 5 Unscented Kalman Filter(UKF) / 33
- 6 粒子滤波 (PF) / 34

我们在实际应用中遇到的系统绝大多数都是非线性的，此时的状态估计远比线性系统要复杂和困难。和线性系统类似，非线性系统的状态估计也可以分为预测、滤波和平滑三类。

这里我们仅讨论若干非线性系统的滤波算法，可以类似地建立对应的预测和平滑算法。

1. 非线性贝叶斯滤波理论

我们首先讨论非线性贝叶斯滤波理论框架，这是所有非线性系统估计理论的基础，具有重要的理论价值和意义。

1.1 问题描述

考虑如下形式的非线性系统:

$$\mathbf{x}_{k+1} = \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k, k) + \mathbf{w}_k \quad (1)$$

$$\mathbf{y}_{k+1} = \mathbf{h}(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, k+1) + \mathbf{v}_{k+1} \quad (2)$$

这里考虑的是加性噪声。

假设

1. $\{\mathbf{u}_k\}$ 是确定性的输入;
2. $\{\mathbf{w}_k\}$ 、 $\{\mathbf{v}_k\}$ 和 \mathbf{x}_0 相互独立, $\{\mathbf{w}_k\}$ 和 $\{\mathbf{v}_k\}$ 都是白噪声序列;

3. \boldsymbol{w}_k 的概率分布密度函数为 $f_w(\boldsymbol{w}_k)$;

4. \boldsymbol{v}_k 的概率分布密度函数为 $f_v(\boldsymbol{v}_k)$;

5. \boldsymbol{x}_0 的概率分布密度函数为 $f_x(\boldsymbol{x}_0)$;

贝叶斯滤波就是在给定量测 $\mathbf{Y}_1^k = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_k\}$ 下，根据 $f_x(\boldsymbol{x}_0)$ 求 \boldsymbol{x}_k 的验后概率分布密度函数 $f_x(\boldsymbol{x}_k | \mathbf{Y}_1^k)$ 。

1.2 切普曼—郭尔莫洛夫方程

设 $\{\boldsymbol{x}(t)\}$ 是一随机过程，对于任意的正整数 m ，如果随机向量

$$[\boldsymbol{x}(t_1), \boldsymbol{x}(t_2), \dots, \boldsymbol{x}(t_m)]^T = [\boldsymbol{x}_1, \boldsymbol{x}_2, \dots, \boldsymbol{x}_m]^T$$

的条件概率密度满足

$$f(\boldsymbol{x}_m | \boldsymbol{x}_{m-1}, \boldsymbol{x}_{m-2}, \dots, \boldsymbol{x}_1) = f(\boldsymbol{x}_m | \boldsymbol{x}_{m-1}) \quad (3)$$

那么称 $\{\boldsymbol{x}(t)\}$ 为一阶马尔科夫过程。其中 $t_1 \sim t_m$ 是任意选取的。 $f(\boldsymbol{x}_m | \boldsymbol{x}_{m-1})$ 称为一步转移概率密度函数， $f(\boldsymbol{x}_m | \boldsymbol{x}_{m-l})$ 称为 l 步转移概率密度函数。

对于马尔科夫过程，根据贝叶斯法则易得

$$\begin{aligned}
 & f(\mathbf{x}_m, \mathbf{x}_{m-1}, \mathbf{x}_{m-2}, \dots, \mathbf{x}_1) \\
 &= f(\mathbf{x}_m | \mathbf{x}_{m-1}, \mathbf{x}_{m-2}, \dots, \mathbf{x}_1) f(\mathbf{x}_{m-1}, \mathbf{x}_{m-2}, \dots, \mathbf{x}_1) \\
 &= f(\mathbf{x}_m | \mathbf{x}_{m-1}) f(\mathbf{x}_{m-1} | \mathbf{x}_{m-2}) \cdots f(\mathbf{x}_2 | \mathbf{x}_1) f(\mathbf{x}_1) \\
 &= f(\mathbf{x}_1) \prod_{k=1}^{m-1} f(\mathbf{x}_{k+1} | \mathbf{x}_k)
 \end{aligned} \tag{4}$$

另外，由边缘密度函数计算可知

$$\int_{-\infty}^{+\infty} f(\mathbf{x}_m, \mathbf{x}_{m-1}, \mathbf{x}_{m-2}) d\mathbf{x}_{m-1} = f(\mathbf{x}_m, \mathbf{x}_{m-2}) \tag{5}$$

即

$$\int_{-\infty}^{+\infty} f(\mathbf{x}_m | \mathbf{x}_{m-1}) f(\mathbf{x}_{m-1} | \mathbf{x}_{m-2}) f(\mathbf{x}_{m-2}) d\mathbf{x}_{m-1} \\ = f(\mathbf{x}_m | \mathbf{x}_{m-2}) f(\mathbf{x}_{m-2}) \quad (6)$$

所以

$$f(\mathbf{x}_m | \mathbf{x}_{m-2}) = \int_{-\infty}^{+\infty} f(\mathbf{x}_m | \mathbf{x}_{m-1}) f(\mathbf{x}_{m-1} | \mathbf{x}_{m-2}) d\mathbf{x}_{m-1} \quad (7)$$

这就是著名的切普曼—郭尔莫洛夫方程。

更一般地，可以表示为

$$f(\mathbf{x}_m | \mathbf{x}_{m-l}) = \int_{-\infty}^{+\infty} f(\mathbf{x}_m | \mathbf{x}_{m-1}) f(\mathbf{x}_{m-1} | \mathbf{x}_{m-l}) d\mathbf{x}_{m-1} \quad (8)$$

切普曼—郭尔莫洛夫方程给出了求一步或多步转移概率函数的方法。

1.3 贝叶斯滤波公式

根据贝叶斯法则，我们有

$$\begin{aligned}
 f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^{k+1}) &= f_x(\mathbf{x}_{k+1} | \mathbf{y}_{k+1}, \mathbf{Y}_1^k) \\
 &= \frac{f_{xy}(\mathbf{x}_{k+1}, \mathbf{y}_{k+1}, \mathbf{Y}_1^k)}{f_y(\mathbf{y}_{k+1}, \mathbf{Y}_1^k)} \\
 &= \frac{f_{xy}(\mathbf{x}_{k+1}, \mathbf{y}_{k+1} | \mathbf{Y}_1^k)}{f_y(\mathbf{y}_{k+1} | \mathbf{Y}_1^k)}
 \end{aligned} \tag{9}$$

注意到（因为 \mathbf{v}_k 的统计性质）

$$\begin{aligned}
 f_{xy}(\mathbf{x}_{k+1}, \mathbf{y}_{k+1} | \mathbf{Y}_1^k) &= f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) f_y(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_1^k) \\
 &= f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) f_y(\mathbf{y}_{k+1} | \mathbf{x}_{k+1})
 \end{aligned}$$

(9) 即为

$$f_x(\mathbf{x}_{k+1}|\mathbf{Y}_1^{k+1}) = \frac{f_x(\mathbf{x}_{k+1}|\mathbf{Y}_1^k)f_y(\mathbf{y}_{k+1}|\mathbf{x}_{k+1})}{f_y(\mathbf{y}_{k+1}|\mathbf{Y}_1^k)} \quad (10)$$

根据切普曼—郭尔莫洛夫方程，则有

$$\begin{aligned} f_x(\mathbf{x}_{k+1}|\mathbf{Y}_1^k) &= \int_x f_x(\mathbf{x}_{k+1}|\mathbf{x}_k, \mathbf{Y}_1^k) f_x(\mathbf{x}_k|\mathbf{Y}_1^k) d\mathbf{x}_k \\ &= \int_x f_x(\mathbf{x}_{k+1}|\mathbf{x}_k) f_x(\mathbf{x}_k|\mathbf{Y}_1^k) d\mathbf{x}_k \end{aligned} \quad (11)$$

$$\begin{aligned} f_y(\mathbf{y}_{k+1} | \mathbf{Y}_1^k) &= \int_x f_y(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}, \mathbf{Y}_1^k) f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) d\mathbf{x}_{k+1} \\ &= \int_x f_y(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}) f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) d\mathbf{x}_{k+1} \end{aligned} \quad (12)$$

而由系统方程 (1)、(2), 可知

$$f_x(\mathbf{x}_{k+1} | \mathbf{x}_k) = f_w(\mathbf{x}_{k+1} - \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k, k)) \quad (13)$$

$$f_y(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}) = f_v(\mathbf{y}_{k+1} - \mathbf{h}(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, k + 1)) \quad (14)$$

将以上二式代入 (11)、(12)，得

$$f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) = \int_x f_w(\mathbf{x}_{k+1} - \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k, k)) f_x(\mathbf{x}_k | \mathbf{Y}_1^k) d\mathbf{x}_k \quad (15)$$

$$f_y(\mathbf{y}_{k+1} | \mathbf{Y}_1^k) = \int_x f_v(\mathbf{y}_{k+1} - \mathbf{h}(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, k+1)) f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^k) d\mathbf{x}_{k+1} \quad (16)$$

在起始时刻

$$f_x(\mathbf{x}_0 | \mathbf{Y}_1^0) = f_x(\mathbf{x}_0) \quad (17)$$

(9)、(15) ~ (17) 便构成了计算的递推算式，即贝叶斯滤波算法，见表1。

Table 1: 贝叶斯滤波算法

状态方程	$\mathbf{x}_{k+1} = \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k, k) + \mathbf{w}_k$
量测方程	$\mathbf{y}_{k+1} = \mathbf{h}(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, k+1) + \mathbf{v}_{k+1}$
状态初始 概率密度	$f_x(\mathbf{x}_0 \mathbf{Y}_1^0) = f_x(\mathbf{x}_0)$
状态预测 概率密度	$f_x(\mathbf{x}_{k+1} \mathbf{Y}_1^k) = \int_x f_w(\mathbf{x}_{k+1} - \mathbf{g}(\mathbf{x}_k, \mathbf{u}_k, k)) f_x(\mathbf{x}_k \mathbf{Y}_1^k) d\mathbf{x}_k$
量测预测 概率密度	$f_y(\mathbf{y}_{k+1} \mathbf{Y}_1^k) = \int_x f_v(\mathbf{y}_{k+1} - \mathbf{h}(\mathbf{x}_{k+1}, \mathbf{u}_{k+1}, k+1)) f_x(\mathbf{x}_{k+1} \mathbf{Y}_1^k) d\mathbf{x}_{k+1}$
状态验后 概率密度	$f_x(\mathbf{x}_{k+1} \mathbf{Y}_1^{k+1}) = \frac{f_x(\mathbf{x}_{k+1} \mathbf{Y}_1^k) f_y(\mathbf{y}_{k+1} \mathbf{x}_{k+1})}{f_y(\mathbf{y}_{k+1} \mathbf{Y}_1^k)}$

有了状态的验后概率密度，可以根据需要，进一步求出状态的滤波值及误差协方差等低阶统计信息。例如

$$\hat{\mathbf{x}}_{k+1|k+1} = E(\mathbf{x}_{k+1} | \mathbf{Y}_1^{k+1}) = \int_x \mathbf{x}_{k+1} f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^{k+1}) d\mathbf{x}_{k+1} \quad (18)$$

$$P_{k+1|k+1} = E(\tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{x}}_{k+1}^T) = \int_x \tilde{\mathbf{x}}_{k+1} \tilde{\mathbf{x}}_{k+1}^T f_x(\mathbf{x}_{k+1} | \mathbf{Y}_1^{k+1}) d\mathbf{x}_{k+1} \quad (19)$$

对于线性系统，上述公式可以解析求解，即可导出卡尔曼滤波算法。一般情况下，需要求高维的非线性积分，通常非常困难，由此发展出了许多近似处理方法。

2. 基于标称状态的线性化滤波方法

非线性系统线性化是解决工程问题常用而且有效的方法。如果系统的真实状态 x 总是围绕标称状态 \bar{x}^* 附近变化，当标称状态 \bar{x}^* 已知时，我们可以取 $x = \bar{x}^* + \Delta x$ ，从而建立一种可行的滤波算法。

考虑如下非线性离散时间随机系统

$$\boldsymbol{x}_{k+1} = \boldsymbol{g}(\boldsymbol{x}_k, k) + \boldsymbol{w}_k \quad (20)$$

$$\boldsymbol{y}_{k+1} = \boldsymbol{h}(\boldsymbol{x}_{k+1}, k+1) + \boldsymbol{v}_{k+1} \quad (21)$$

其中，过程噪声 $\mathbf{w}_k \sim (0, Q_k)$ 与量测噪声 $\mathbf{v}_k \sim (0, R_k)$ 互不相关，设 $Q_k \geq 0, R_k > 0$ 。

标称状态及量测方程定义为

$$\mathbf{x}_{k+1}^* = \mathbf{g}(\mathbf{x}_k^*, k) \quad (22)$$

$$\mathbf{y}_{k+1}^* = \mathbf{h}(\mathbf{x}_{k+1}^*, k + 1) \quad (23)$$

设

$$\mathbf{x}_{k+1} = \mathbf{x}_{k+1}^* + \Delta \mathbf{x}_{k+1}$$

$$\mathbf{y}_{k+1} = \mathbf{y}_{k+1}^* + \Delta \mathbf{y}_{k+1}$$

一阶近似地

$$\Delta \boldsymbol{x}_{k+1} = \Phi_{k+1,k} \Delta \boldsymbol{x}_k + \boldsymbol{w}_k \quad (24)$$

$$\Delta \boldsymbol{y}_{k+1} = H_{k+1} \Delta \boldsymbol{x}_{k+1} + \boldsymbol{v}_{k+1} \quad (25)$$

其中

$$\Phi_{k+1,k} = \left. \frac{\partial \boldsymbol{g}(\boldsymbol{x}_k, k)}{\partial \boldsymbol{x}_k^T} \right|_{\boldsymbol{x}_k=\boldsymbol{x}_k^*}, \quad H_k = \left. \frac{\partial \boldsymbol{h}(\boldsymbol{x}_k, k)}{\partial \boldsymbol{x}_k^T} \right|_{\boldsymbol{x}_k=\boldsymbol{x}_k^*}$$

如果 $\boldsymbol{x}_0 \sim (\boldsymbol{x}_0^*, P_0)$, 即 $\Delta \boldsymbol{x}_0 \sim (0, P_0)$, 而且与过程噪声 $\boldsymbol{w}_k \sim (0, Q_k)$ 与量测噪声 $\boldsymbol{v}_k \sim (0, R_k)$ 互不相关。那么, 我们可以应用卡尔曼滤波算法于 (24)、(25), 从而得到原系统一种滤波算法, 如表2所示。

Table 2: 基于标称状态线性化的卡尔曼滤波算法

状态方程	$\boldsymbol{x}_{k+1} = \boldsymbol{g}(\boldsymbol{x}_k, k) + \boldsymbol{w}_k$
量测方程	$\boldsymbol{y}_{k+1} = \boldsymbol{h}(\boldsymbol{x}_{k+1}, k+1) + \boldsymbol{v}_{k+1}$
滤波初值	$\hat{\boldsymbol{x}}_{0 0} = E\boldsymbol{x}_0 = \boldsymbol{x}_0^*, P_{0 0} = \text{var}(\boldsymbol{x}_0) = P_0$
一步预测	$\hat{\boldsymbol{x}}_{k+1 k} = \boldsymbol{g}(\hat{\boldsymbol{x}}_{k k}, k)$ $P_{k+1 k} = \Phi_{k+1,k}P_{k k}\Phi_{k+1,k}^T + Q_k$

滤波增益	$K_{k+1} = P_{k+1 k} H_{k+1}^T (H_{k+1} P_{k+1 k} H_{k+1}^T + R_{k+1})^{-1}$
滤波计算	$\hat{\mathbf{x}}_{k+1 k+1} = \hat{\mathbf{x}}_{k+1 k} + K_{k+1} [\mathbf{y}_{k+1} - \mathbf{h}(\hat{\mathbf{x}}_{k+1 k}, k+1)]$ $P_{k+1 k+1} = (I - K_{k+1} H_{k+1}) P_{k+1 k}$
辅助方程	$\Phi_{k+1,k} = \left. \frac{\partial \mathbf{g}(\mathbf{x}_k, k)}{\partial \mathbf{x}_k^T} \right _{\mathbf{x}_k=\mathbf{x}_k^*}$ $H_k = \left. \frac{\partial \mathbf{h}(\mathbf{x}_k, k)}{\partial \mathbf{x}_k^T} \right _{\mathbf{x}_k=\mathbf{x}_k^*}$

[Remarks]

1. 一步预测

$$\hat{\mathbf{x}}_{k+1|k} = E[\mathbf{x}_{k+1} | \mathbf{Y}_1^k]$$

$$\hat{\mathbf{x}}_{k+1|k} = E[\mathbf{g}(\mathbf{x}_k, k) + \mathbf{w}_k | \mathbf{Y}_1^k] = E[\mathbf{g}(\mathbf{x}_k, k) | \mathbf{Y}_1^k]$$

$$\simeq E[\mathbf{g}(\mathbf{x}_k^*, k) + \Phi_{k+1,k}(\mathbf{x}_k^* - \mathbf{x}_k) | \mathbf{Y}_1^k]$$

$$= \underbrace{\mathbf{g}(\mathbf{x}_k^*, k) + \Phi_{k+1,k}(\mathbf{x}_k^* - \hat{\mathbf{x}}_{k|k})}_{\text{由此计算 } P_{k+1|k}}$$

$$\simeq \mathbf{g}(\hat{\mathbf{x}}_{k|k}, k)$$

2. 量测预报

$$\hat{\mathbf{y}}_{k+1|k} = E[\mathbf{y}_{k+1} | \mathbf{Y}_1^k]$$

$$\begin{aligned}\hat{\mathbf{y}}_{k+1|k} &= E[\mathbf{h}(\mathbf{x}_{k+1}, k+1) + \mathbf{v}_{k+1} | \mathbf{Y}_1^k] \\ &= E[\mathbf{h}(\mathbf{x}_{k+1}, k+1) | \mathbf{Y}_1^k] \\ &\simeq E[\mathbf{h}(\mathbf{x}_{k+1}^*, k+1) + H_{k+1}(\mathbf{x}_{k+1}^* - \mathbf{x}_{k+1}) | \mathbf{Y}_1^k] \\ &= \mathbf{h}(\mathbf{x}_{k+1}^*, k+1) + H_{k+1}(\mathbf{x}_{k+1}^* - \hat{\mathbf{x}}_{k+1|k}) \\ &\simeq \mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1)\end{aligned}$$

3. 扩展卡尔曼滤波

研究如下非线性离散时间随机系统：

$$\mathbf{x}_{k+1} = \mathbf{g}(\mathbf{x}_k, k) + \mathbf{w}_k \quad (26)$$

$$\mathbf{y}_{k+1} = \mathbf{h}(\mathbf{x}_{k+1}, k+1) + \mathbf{v}_{k+1} \quad (27)$$

其中，过程噪声 $\mathbf{w}_k \sim (0, Q_k)$ 与量测噪声 $\mathbf{v}_k \sim (0, R_k)$ 互不相关，设 $Q_k \geq 0, R_k > 0$ ； $\mathbf{x}_0 \sim (\bar{\mathbf{x}}_0, P_0)$ 与 $\mathbf{w}_k \sim (0, Q_k)$ 、 $\mathbf{v}_k \sim (0, R_k)$ 均不相关。

定义

$$\Phi_{k+1,k} = \frac{\partial \mathbf{g}(\mathbf{x}_k, k)}{\partial \mathbf{x}_k^T} \Big|_{\mathbf{x}_k=\hat{\mathbf{x}}_{k|k}} \quad (28)$$

$$H_{k+1} = \frac{\partial \mathbf{h}(\mathbf{x}_{k+1}, k+1)}{\partial \mathbf{x}_{k+1}^T} \Big|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1|k}} \quad (29)$$

那么

$$\mathbf{x}_{k+1} \approx \Phi_{k+1,k} \mathbf{x}_k + [\mathbf{g}(\hat{\mathbf{x}}_{k|k}, k) - \Phi_{k+1,k} \hat{\mathbf{x}}_{k|k}] + \mathbf{w}_k \quad (30)$$

$$\mathbf{y}_{k+1} \approx H_{k+1} \mathbf{x}_{k+1} + [\mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1) - H_{k+1} \hat{\mathbf{x}}_{k+1|k}] + \mathbf{v}_{k+1} \quad (31)$$

因为在求 $k+1$ 时刻状态的滤波时， $\hat{\mathbf{x}}_{k|k}$ 、 $\hat{\mathbf{x}}_{k+1|k}$ 已经知道，可以视为确定性信号。即可以将 $\mathbf{g}(\hat{\mathbf{x}}_{k|k}, k) - \Phi_{k+1,k} \hat{\mathbf{x}}_{k|k}$ 与 $\mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1) - H_{k+1} \hat{\mathbf{x}}_{k+1|k}$

视为确定性输入信号。这样，我们便可以借助卡尔曼滤波基本方程建立一套有效的非线性滤波算法，称为 **扩展卡尔曼滤波 (EKF)**，如表3所示。

Table 3: 扩展卡尔曼滤波算法

状态方程	$\boldsymbol{x}_{k+1} = \boldsymbol{g}(\boldsymbol{x}_k, k) + \boldsymbol{w}_k$
量测方程	$\boldsymbol{y}_{k+1} = \boldsymbol{h}(\boldsymbol{x}_{k+1}, k+1) + \boldsymbol{v}_{k+1}$
滤波初值	$\hat{\boldsymbol{x}}_{0 0} = E\boldsymbol{x}_0 = \bar{\boldsymbol{x}}_0, P_{0 0} = \text{var}(\boldsymbol{x}_0) = P_0$

一步预测

$$\hat{\mathbf{x}}_{k+1|k} = \mathbf{g}(\hat{\mathbf{x}}_{k|k}, k)$$

$$P_{k+1|k} = \Phi_{k+1,k} P_{k|k} \Phi_{k+1,k}^T + Q_k$$

滤波增益

$$K_{k+1} = P_{k+1|k} H_{k+1}^T (H_{k+1} P_{k+1|k} H_{k+1}^T + R_{k+1})^{-1}$$

滤波计算

$$\hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + K_{k+1} [\mathbf{y}_{k+1} - \mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1)]$$

$$P_{k+1|k+1} = (I - K_{k+1} H_{k+1}) P_{k+1|k}$$

辅助方程

$$\Phi_{k+1,k} = \frac{\partial \mathbf{g}(\mathbf{x}_k, k)}{\partial \mathbf{x}_k^T} \Big|_{\mathbf{x}_k=\hat{\mathbf{x}}_{k|k}}$$

$$H_{k+1} = \frac{\partial \mathbf{h}(\mathbf{x}_{k+1}, k+1)}{\partial \mathbf{x}_{k+1}^T} \Big|_{\mathbf{x}_{k+1}=\hat{\mathbf{x}}_{k+1|k}}$$

上述扩展卡尔曼滤波算法是解决非线性滤波使用最广泛的方法，大量实际应用证明是行之有效的。

[Remarks]

1. 一步预测

$$\hat{\mathbf{x}}_{k+1|k} = E[\mathbf{x}_{k+1} | \mathbf{Y}_1^k]$$

$$\begin{aligned}\hat{\mathbf{x}}_{k+1|k} &= E[\mathbf{g}(\mathbf{x}_k, k) + \mathbf{w}_k | \mathbf{Y}_1^k] = E[\mathbf{g}(\mathbf{x}_k, k) | \mathbf{Y}_1^k] \\ &\simeq E[\mathbf{g}(\hat{\mathbf{x}}_{k|k}, k) + \Phi_{k+1,k}(\hat{\mathbf{x}}_{k|k} - \mathbf{x}_k) | \mathbf{Y}_1^k] \\ &= \mathbf{g}(\hat{\mathbf{x}}_{k|k}, k)\end{aligned}$$

2. 量测预报

$$\hat{\mathbf{y}}_{k+1|k} = E[\mathbf{y}_{k+1} | \mathbf{Y}_1^k]$$

$$\begin{aligned}\hat{\mathbf{y}}_{k+1|k} &= E[\mathbf{h}(\mathbf{x}_{k+1}, k+1) + \mathbf{v}_{k+1} | \mathbf{Y}_1^k] \\ &= E[\mathbf{h}(\mathbf{x}_{k+1}, k+1) | \mathbf{Y}_1^k] \\ &\simeq E[\mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1) + H_{k+1}(\hat{\mathbf{x}}_{k+1|k} - \mathbf{x}_{k+1}) | \mathbf{Y}_1^k] \\ &= \mathbf{h}(\hat{\mathbf{x}}_{k+1|k}, k+1)\end{aligned}$$

4. 递代扩展卡尔曼滤波

设按上一节介绍的扩展卡尔曼滤波器已经获得了 $\hat{\mathbf{x}}_{k|k}$ 、 $\hat{\mathbf{x}}_{k|k-1}$ ，记

$$\hat{\mathbf{x}}_{k|k}^{(0)} = \hat{\mathbf{x}}_{k|k-1}$$

可以以此进一步改善 $\hat{\mathbf{y}}_{k|k-1}$ 的计算。

定义

$$H(\hat{\mathbf{x}}_{k|k}^{(i)}, k) = \left. \frac{\partial \mathbf{h}(\mathbf{x}_k, k)}{\partial \mathbf{x}_k^T} \right|_{\mathbf{x}_k = \hat{\mathbf{x}}_{k|k}^{(i)}}, \quad i = 0, 1, 2, \dots$$

可得

$$\mathbf{y}_k \approx H(\hat{\mathbf{x}}_k^{(i)}, k) \mathbf{x}_k + \mathbf{h}(\hat{\mathbf{x}}_{k|k}^{(i)}, k) - H(\hat{\mathbf{x}}_k^{(i)}, k) \hat{\mathbf{x}}_{k|k}^{(i)} + \mathbf{v}_k$$

于是

$$\begin{aligned}\hat{\mathbf{y}}_{k|k-1}^{(i)} &\approx \mathbf{h}(\hat{\mathbf{x}}_{k|k}^{(i)}, k) + H(\hat{\mathbf{x}}_k^{(i)}, k)(\hat{\mathbf{x}}_{k|k-1} - \hat{\mathbf{x}}_{k|k}^{(i)}) \\ &\approx \mathbf{h}(\hat{\mathbf{x}}_{k|k}^{(i)}, k)\end{aligned}$$

从而可得 $\hat{\mathbf{x}}_{k|k}$ 更好的估计 $\hat{\mathbf{x}}_{k|k}^{(i+1)}$, 即

$$\hat{\mathbf{x}}_{k|k}^{(i+1)} = \hat{\mathbf{x}}_{k|k-1} + K_k^{(i)}(\mathbf{y}_k - \hat{\mathbf{y}}_{k|k-1}^{(i)}) \quad (32)$$

$$K_k^{(i)} = P_{k|k-1} H^T(\hat{\mathbf{x}}_{k|k}^{(i)}, k) (H(\hat{\mathbf{x}}_{k|k}^{(i)}, k) P_{k|k-1} H^T(\hat{\mathbf{x}}_{k|k}^{(i)}, k) + R_{k+1})^{-1} \quad (33)$$

$$P_{k|k}^{(i+1)} = (I - K_k^{(i)} H(\hat{\mathbf{x}}_{k|k}^{(i)}, k)) P_{k+1|k} \quad (34)$$

按上述方程反复迭代 ($i=1,2,3\dots$), 直到不能改善为止。这便是 **递代扩展卡尔曼滤波 (IEKF)**, 其精度将高于普通扩展卡尔曼滤波, 但计算时间会增加。以计算时间增加换取滤波精度提高。工程应用中, 为了保证滤波算法的实时性, 迭代次数一般取 $3 \sim 5$ 。

5. Unscented Kalman Filter(UKF)

UKF Link

6. 粒子濾波 (PF)

PF LINK



Questions?