



多旋翼飞行器设计与控制

第八讲 可观性和卡尔曼滤波器

全权 副教授

qq_buaa@buaa.edu.cn

自动化科学与电气工程学院

北京航空航天大学



东方智慧



盲人摸象



核心问题

什么是可观性？ 如何设计卡尔曼滤波器？



大纲

1. 可观性
2. 卡尔曼滤波
3. 多速率采样卡尔曼滤波
4. 扩展卡尔曼滤波
5. 本讲小结



可观性

可观性就是回答“**状态的变化能否由输出反映出来**”

中医“望闻问切”
是否能瞧病？



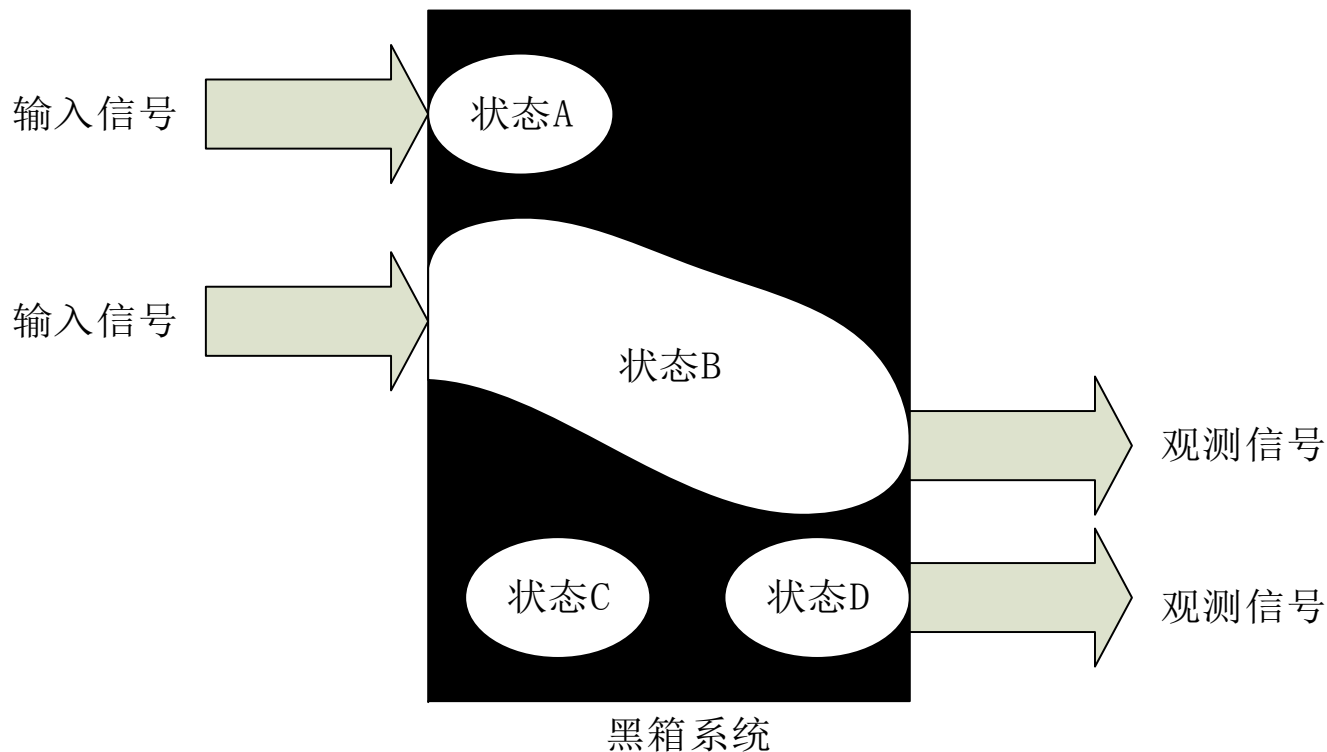
网络大数据作为输出，能否观测
更有价值信息？



三个关键词：**动态系统、状态、输出**



可观性



直观地，状态A和状态C是不可观的



可观性

□ 连续线性系统

(1) 定义

考虑如下连续线性系统

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u}$$

$$\mathbf{y} = \mathbf{C}^T \mathbf{x}$$

其中 $\mathbf{x} \in \mathbb{R}^n, \mathbf{y} \in \mathbb{R}^m, \mathbf{u} \in \mathbb{R}^m, \mathbf{A} \in \mathbb{R}^{n \times n}, \mathbf{B} \in \mathbb{R}^{n \times m}, \mathbf{C} \in \mathbb{R}^{n \times m}$

定义1. 如果在有限时间间隔 $t_0 \leq t \leq t_f$ 内, 根据输出值 $\mathbf{y}(t)$ 和输入值 $\mathbf{u}(t)$, 能够确定系统的初始状态 $\mathbf{x}(t_0)$ 的每一个分量, 那么称此系统是完全可观的, 简称可观测。

三个关键词: 动态系统、状态、输出



可观性

□ 连续线性系统

(2) 直观解释

由系统方程可知

$$y = C^T x$$

$$\dot{y} = C^T \dot{x} = C^T Ax + C^T Bu \Rightarrow \dot{y} - C^T Bu = C^T Ax$$

$$\ddot{y} = C^T A^2 x + C^T ABu + C^T B\dot{u} \Rightarrow \ddot{y} - C^T ABu - C^T B\dot{u} = C^T A^2 x$$

⋮

$$y^{(n-1)} - \sum_{k=0}^{n-2} C^T A^{n-2-k} Bu^{(k)} = C^T A^{n-1} x$$



$$\begin{bmatrix} y \\ \dot{y} - C^T Bu \\ \vdots \\ y^{(n-1)} - \sum_{k=0}^{n-2} C^T A^{n-2-k} Bu^{(k)} \end{bmatrix} = O_v x \quad \text{其中} \quad O_v = \begin{bmatrix} C^T \\ C^T A \\ \vdots \\ C^T A^{n-1} \end{bmatrix}$$

为什么不多求
几阶导数？如：

$$O'_v = \begin{bmatrix} O_v \\ C^T A^n \end{bmatrix}$$



可观性

□ 连续线性系统

为什么不多求几阶导数？如：
$$\mathbf{O}'_v = \begin{bmatrix} \mathbf{O}_v \\ \mathbf{C}^T \mathbf{A}^n \end{bmatrix}$$

根据凯利-哈密尔顿定理

$$\mathbf{C}^T \mathbf{A}^n = \alpha_0 \mathbf{C}^T + \alpha_1 \mathbf{C}^T \mathbf{A} + \cdots + \alpha_n \mathbf{C}^T \mathbf{A}^{n-1}$$

因此可观性矩阵的秩并不会增加

所以只求到 (n-1) 阶导数



可观性

□ 连续线性系统


(3) 定理

进一步

利用此方程可以通过历史观测值 y 逆向唯一求解出状态 x

$$\text{rank } \mathbf{O}_v = n \Rightarrow \mathbf{x} = \mathbf{O}_v^{-1} \begin{bmatrix} \mathbf{y} \\ \dot{\mathbf{y}} - \mathbf{C}^T \mathbf{B} \mathbf{u} \\ \vdots \\ \mathbf{y}^{(n-1)} - \sum_{k=0}^{n-2} \mathbf{C}^T \mathbf{A}^{n-2-k} \mathbf{B} \mathbf{u}^{(k)} \end{bmatrix}$$

定理1. 系统 $\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} \\ \mathbf{y} = \mathbf{C}^T \mathbf{x} \end{cases}$ 可观测的充分必要条件 $\text{rank } \mathbf{O}_v = n$ 。



可观性

□ 连续线性系统

(4) 例子

例1. 给出两个传感器**GPS**和**加速度计**，那么哪一个能够稳定地估计出一维运动小车的速度？

- **GPS**。为了简化起见，我们用GPS观测位置，一般用如下模型

$$\begin{bmatrix} \dot{p} \\ \dot{v} \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}}_A \begin{bmatrix} p \\ v \end{bmatrix} + \begin{bmatrix} 0 \\ \varepsilon_1 \end{bmatrix}$$

$$y = \underbrace{\begin{bmatrix} 1 & 0 \end{bmatrix}}_{C^T} \begin{bmatrix} p \\ v \end{bmatrix}$$

$y=x$ ，故位置状态 x 可通过输出 y 直接求导得到，需要估计的是速度状态 v

$$O_v = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

可观！
能够稳定地
估计小车的速度

其中 $x, v \in \mathbb{R}$ 分别表示位置和速度, $\varepsilon_1 \in \mathbb{R}$ 表示已知统计特性的噪声。



可观性

□ 连续线性系统

(4) 例子

- **加速度计**。为了简化起见，用加速度计估计速度，一般用如下模型

$$\begin{bmatrix} \dot{v} \\ \dot{a} \end{bmatrix} = \underbrace{\begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}}_{\mathbf{A}} \begin{bmatrix} v \\ a \end{bmatrix} + \begin{bmatrix} 0 \\ \varepsilon_2 \end{bmatrix}$$

$$y = \underbrace{\begin{bmatrix} 0 & 1 \end{bmatrix}}_{\mathbf{C}^T} \begin{bmatrix} v \\ a \end{bmatrix}$$



$$\mathbf{O}_v = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$$

不可观！
不能够稳定地
估计小车的速度

其中 $v, a \in \mathbb{R}$ 分别表示速度和加速度， $\varepsilon_2 \in \mathbb{R}$ 表示已知统计特性的噪声。




可观性

□ 连续线性系统

(4) 例子

- 加速度计。



两个自由落体的小球
加速度一样，但是初
始速度不一样。无法从
输出（加速度），观测出
小球初始速度（状态）。
不可观。



可观性

□ 离散线性系统

(1) 定义

对于连续线性系统，可以通过采样周期 T_s 精确地将连续系统转化成离散系统。将连续系统模型转换成如下离散采样线性系统

$$\mathbf{x}_k = \Phi \mathbf{x}_{k-1} + \mathbf{u}_{k-1}$$

$$\mathbf{y}_k = \mathbf{C}^T \mathbf{x}_k$$

其中 $\Phi = e^{A T_s}$, $\mathbf{u}(t) = \mathbf{u}'_{k-1}$, $t \in [(k-1)T_s, kT_s]$, $\mathbf{u}_{k-1} = \int_0^{T_s} e^{A s} \mathbf{B} ds \cdot \mathbf{u}'_{k-1}$

定义2. 如果在有限时间间隔 NT_s 内，根据输出值 \mathbf{y}_k 和外界输入值 \mathbf{u}_k ，能够确定系统的初始状态 \mathbf{x}_0 的每一个分量，那么称此系统是完全可观的，简称**可观测**。



可观性

□ 离散线性系统

(2) 直观解释

$$\begin{aligned} \mathbf{y}_0 &= \mathbf{C}^T \mathbf{x}_0 \\ \mathbf{y}_1 &= \mathbf{C}^T \mathbf{x}_1 = \mathbf{C}^T \Phi \mathbf{x}_0 + \mathbf{C}^T \mathbf{u}_0 \Rightarrow \mathbf{y}_1 - \mathbf{C}^T \mathbf{u}_0 = \mathbf{C}^T \Phi \mathbf{x}_0 \\ \mathbf{y}_2 &= \mathbf{C}^T \mathbf{x}_2 = \mathbf{C}^T \Phi \mathbf{x}_1 + \mathbf{C}^T \mathbf{u}_1 \Rightarrow \mathbf{y}_2 - \mathbf{C}^T \mathbf{u}_1 - \mathbf{C}^T \Phi \mathbf{u}_0 = \mathbf{C}^T \Phi^2 \mathbf{x}_0 \\ &\vdots \\ \mathbf{y}_n - \sum_{k=0}^{n-1} \mathbf{C}^T \Phi^{n-1-k} \mathbf{u}_k &= \mathbf{C}^T \Phi^n \mathbf{x}_0 \end{aligned}$$



$$\begin{bmatrix} \mathbf{y}_0 \\ \mathbf{y}_1 \\ \vdots \\ \mathbf{y}_{n-1} - \sum_{k=0}^{n-2} \mathbf{C}^T \Phi^{n-2-k} \mathbf{u}_k \end{bmatrix} = \begin{bmatrix} \mathbf{C}^T \\ \mathbf{C}^T \Phi \\ \vdots \\ \mathbf{C}^T \Phi^{n-1} \end{bmatrix} \mathbf{x}_0$$

(3) 定理

定理2. 系统

$$\mathbf{x}_k = \Phi \mathbf{x}_{k-1} + \mathbf{u}_{k-1}$$

$$\mathbf{y}_k = \mathbf{C}^T \mathbf{x}_k$$

可观测的充分必要条件是

$$\text{rank} \begin{bmatrix} \mathbf{C}^T \\ \mathbf{C}^T \Phi \\ \vdots \\ \mathbf{C}^T \Phi^{n-1} \end{bmatrix} = n$$



卡尔曼滤波器

□ 概述

卡尔曼滤波器是一种递推线性最小方差估计算法。它的最优估计需满足以下三个条件：

1) 无偏性：即估计值的期望等于状态的真值；

若 $E(\hat{g}) = g$ ，那么意味着 \hat{g} 是参数 g 的无偏估计，否则为有偏估计，其中 $E(\cdot)$ 表示期望。

2) 估计的方差最小；

若 $D(\hat{g}) = E\left(\left(\hat{g} - g\right)^2\right)$ ，如果对于任意一个估计 \tilde{g} ，我们有 $D(\hat{g}) \leq D(\tilde{g})$ ，那么称 \hat{g} 为最小方差估计，其中 $D(\cdot)$ 表示方差。

3) 实时性。



卡尔曼滤波器

□ 模型描述

假设线性离散系统模型如下：

$$\mathbf{x}_k = \Phi_{k-1} \mathbf{x}_{k-1} + \mathbf{u}_{k-1} + \Gamma_{k-1} \mathbf{w}_{k-1}$$

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

式中，过程噪声 \mathbf{w}_{k-1} 和观测噪声 \mathbf{v}_k 的统计特性为

自相关系数 $\mathbf{R}_{\mathbf{w}\mathbf{w}}$

互相关系数 $\mathbf{R}_{\mathbf{w}\mathbf{v}}$

系统噪声方差阵 $\mathbf{Q}_k \geq 0$

观测噪声方差阵 $\mathbf{R}_k > 0$

克罗内克 δ 函数

$$\delta_{kj} = \begin{cases} 1, & k = j \\ 0, & k \neq j \end{cases}$$

$$E(\mathbf{w}_{k-1}) = \mathbf{0}, E(\mathbf{v}_k) = \mathbf{0}, \mathbf{R}_{\mathbf{w}\mathbf{v}}(k, j) = \mathbf{0}$$

$$\mathbf{R}_{\mathbf{w}\mathbf{w}}(k, j) = E(\mathbf{w}_k \mathbf{w}_j^T) = \mathbf{Q}_k \delta_{kj} = \begin{cases} \mathbf{Q}_k, & k = j \\ \mathbf{0}, & k \neq j \end{cases}$$

$$\mathbf{R}_{\mathbf{v}\mathbf{v}}(k, j) = E(\mathbf{v}_k \mathbf{v}_j^T) = \mathbf{R}_k \delta_{kj} = \begin{cases} \mathbf{R}_k, & k = j \\ \mathbf{0}, & k \neq j \end{cases}$$

独立不相关



卡尔曼滤波器

□ 模型描述

初始状态 \mathbf{x}_0 的统计特性为

$$E(\mathbf{x}_0) = \hat{\mathbf{x}}_0, \text{cov}(\mathbf{x}_0) = \mathbf{P}_0 \quad \text{其中, cov}(\cdot) \text{表示协方差}$$

还假设状态的初始值 $\mathbf{x}_0, \mathbf{u}_k$ 与 $\mathbf{w}_{k-1}, \mathbf{v}_k, k \geq 1$, 均不相关, 并且噪声向量 \mathbf{w}_{k-1} 与 \mathbf{v}_k 也不相关, 即有:

$$\mathbf{R}_{\mathbf{xw}}(0, k) = E(\mathbf{x}_0 \mathbf{w}_k^T) = \mathbf{0}$$

$$\mathbf{R}_{\mathbf{xv}}(0, k) = E(\mathbf{x}_0 \mathbf{v}_k^T) = \mathbf{0}$$

$$\mathbf{R}_{\mathbf{uw}}(k, j) = E(\mathbf{u}_k \mathbf{w}_j^T) = \mathbf{0}$$

独立不相关



卡尔曼滤波器

□ 卡尔曼滤波器推导思路

目的：假设滤波器形式

$$\hat{\mathbf{x}}_{k|k} = \mathbf{K}'_k \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{K}_k \mathbf{z}_k + \mathbf{K}''_k \mathbf{u}_{k-1}$$

其中 $\hat{\mathbf{x}}_{k-1|k-1}$ 是 \mathbf{x}_{k-1} 的最优线性估计（**最小方差无偏估计**）。求

$$\mathbf{K}'_k, \mathbf{K}_k, \mathbf{K}''_k$$

使得 $\hat{\mathbf{x}}_{k|k}$ 是 \mathbf{x}_k 的最优线性估计。



卡尔曼滤波器

卡尔曼滤波器推导思路

第一步：求 $\mathbf{K}'_k, \mathbf{K}''_k$ 使得 $\hat{\mathbf{x}}_{k|k}$ 是 \mathbf{x}_k 的无偏估计

因为 $\tilde{\mathbf{x}}_{k|k} = \mathbf{x}_k - \hat{\mathbf{x}}_{k|k}$

$$\begin{aligned} \tilde{\mathbf{x}}_{k|k} &= \underbrace{(\Phi_{k-1} - \mathbf{K}_k \mathbf{H}_k \Phi_{k-1} - \mathbf{K}'_k)}_{\text{red underline}} \mathbf{x}_{k-1} + \mathbf{K}'_k (\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}) \\ &+ (\Gamma_{k-1} - \mathbf{K}_k \mathbf{H}_k \Gamma_{k-1}) \mathbf{w}_{k-1} + \underbrace{(\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k - \mathbf{K}''_k)}_{\text{red underline}} \mathbf{u}_{k-1} - \mathbf{K}_k \mathbf{v}_k \end{aligned}$$

又因为要求 $E(\tilde{\mathbf{x}}_{k|k}) = \mathbf{0}$ ，又已知 $E(\tilde{\mathbf{x}}_{k-1|k-1}) = \mathbf{0}, E(\mathbf{v}_k) = \mathbf{0}, E(\mathbf{w}_{k-1}) = \mathbf{0}$

不能要求 $E(\mathbf{x}_{k-1}) = \mathbf{0}, E(\mathbf{u}_{k-1}) = \mathbf{0}$ ，那么只能让

$$\Phi_{k-1} - \mathbf{K}_k \mathbf{H}_k \Phi_{k-1} - \mathbf{K}'_k = \mathbf{0}_{n \times n}$$

$$\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k - \mathbf{K}''_k = \mathbf{0}_{n \times n}$$

$$\mathbf{K}'_k = \Phi_{k-1} - \mathbf{K}_k \mathbf{H}_k \Phi_{k-1}$$

$$\mathbf{K}''_k = \mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k$$



卡尔曼滤波器

卡尔曼滤波器推导思路

第一步：求 K'_k, K''_k 使得 $\hat{x}_{k|k}$ 是 x_k 的无偏估计

$$\begin{aligned} \Phi_{k-1} - K_k H_k \Phi_{k-1} - K'_k &= \mathbf{0}_{n \times n} \\ \mathbf{I}_n - K_k H_k - K''_k &= \mathbf{0}_{n \times n} \end{aligned} \Rightarrow \begin{aligned} K'_k &= \Phi_{k-1} - K_k H_k \Phi_{k-1} \\ K''_k &= \mathbf{I}_n - K_k H_k \end{aligned}$$

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - \hat{z}_{k|k-1})$$



$$\begin{bmatrix} \text{状态} \\ \text{更新值} \end{bmatrix} = \begin{bmatrix} \text{状态} \\ \text{预测值} \end{bmatrix} + \begin{bmatrix} \text{卡尔曼} \\ \text{增益} \end{bmatrix} \begin{bmatrix} \text{新息} \\ \text{矢量} \end{bmatrix}$$

物理意义?

其中

$$\begin{aligned} \hat{x}_{k|k-1} &= \Phi_{k-1} \hat{x}_{k-1|k-1} + \mathbf{u}_{k-1} \\ \hat{z}_{k|k-1} &= \mathbf{H}_k \hat{x}_{k|k-1} \end{aligned}$$



卡尔曼滤波器

□ 卡尔曼滤波器推导思路

第二步：求 \mathbf{K}_k 使得 $\hat{\mathbf{x}}_{k|k}$ 是 \mathbf{x}_k 的**最小方差估计**

也就是求解优化问题

$$\min_{\mathbf{K}_k} \text{tr} \mathbf{P}_{k|k} = \min_{\mathbf{K}_k} \text{E} \left(\text{tr} \left(\tilde{\mathbf{x}}_{k|k} \tilde{\mathbf{x}}_{k|k}^T \right) \right)$$

这里 $\mathbf{P}_{k|k} = (\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} (\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k)^T + \mathbf{K}_k \mathbf{R}_k \mathbf{K}_k^T$

其中 $\mathbf{P}_{k|k-1} = \text{E} \left(\tilde{\mathbf{x}}_{k|k-1} \tilde{\mathbf{x}}_{k|k-1}^T \right)$

进一步可以得到 **当作已知**

$$\mathbf{P}_{k|k-1} = \mathbf{\Phi}_{k-1} \mathbf{P}_{k-1|k-1} \mathbf{\Phi}_{k-1}^T + \mathbf{\Gamma}_{k-1} \mathbf{Q}_{k-1} \mathbf{\Gamma}_{k-1}^T$$



卡尔曼滤波器

卡尔曼滤波器推导思路

第二步：求 \mathbf{K}_k 使得 $\hat{\mathbf{x}}_{k|k}$ 是 \mathbf{x}_k 的最小方差估计
也就是求解优化问题


$$\min_{\mathbf{K}_k} \text{tr} \mathbf{P}_{k|k} = \min_{\mathbf{K}_k} \text{E} \left(\text{tr} \left(\tilde{\mathbf{x}}_{k|k} \tilde{\mathbf{x}}_{k|k}^T \right) \right)$$

$$\Rightarrow \frac{\partial}{\partial \mathbf{K}_k} \text{tr} \left(\mathbf{P}_{k|k} \right) = -2\mathbf{P}_{k|k-1}^T \mathbf{H}_k^T + 2\mathbf{K}_k \left(\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \right) = \mathbf{0}_{n \times m}$$

$$\Rightarrow \mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \left(\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \right)^{-1} \quad \mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \text{ 正定矩阵}$$

$$\Rightarrow \mathbf{P}_{k|k} = \left(\mathbf{I}_n - \mathbf{K}_k \mathbf{H}_k \right) \mathbf{P}_{k|k-1}$$

一般极值在导数为零处求得



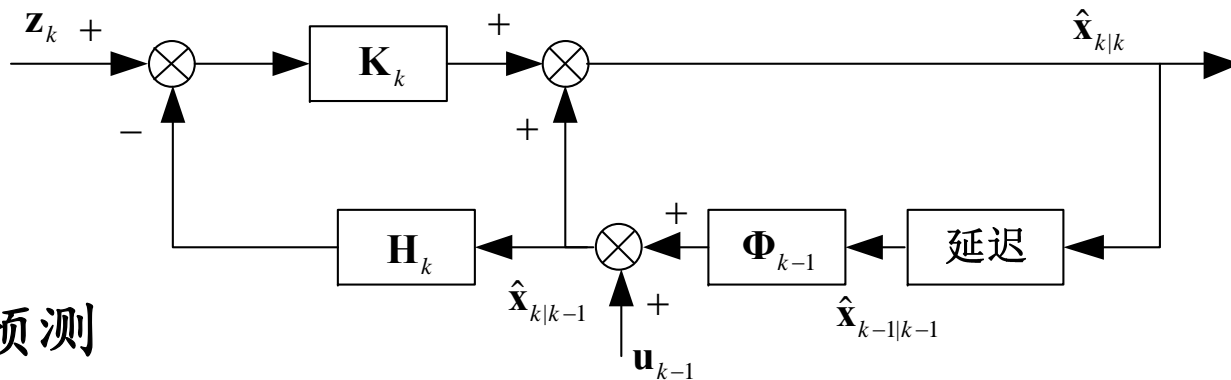
$$\frac{d}{d\mathbf{A}} \text{tr} \left(\mathbf{A} \mathbf{B} \mathbf{A}^T \right) = 2\mathbf{A} \mathbf{B}$$

其中 $\mathbf{B} = \mathbf{B}^T$, \mathbf{B} 是对称阵.



卡尔曼滤波器

卡尔曼滤波器算法总结



1. 状态预测

$$\hat{\mathbf{x}}_{k|k-1} = \Phi_{k-1} \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{u}_{k-1}$$

2. 误差协方差预测

$$\mathbf{P}_{k|k-1} = \Phi_{k-1} \mathbf{P}_{k-1|k-1} \Phi_{k-1}^T + \Gamma_{k-1} \mathbf{Q}_{k-1} \Gamma_{k-1}^T$$

3. 卡尔曼滤波器增益

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T \left(\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k \right)^{-1}$$

4. 状态估计校正

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k \left(\mathbf{z}_k - \hat{\mathbf{z}}_{k|k-1} \right)$$

$$\text{其中 } \hat{\mathbf{z}}_{k|k-1} = \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}$$

5. 误差协方差估计校正

$$\mathbf{P}_{k|k} = \left(\mathbf{I} - \mathbf{K}_k \mathbf{H}_k \right) \mathbf{P}_{k|k-1}$$



卡尔曼滤波器

□ 其他说明

(1) 一般来说，采样周期合理情况下，连续系统可观，离散化的系统也会可观。然而有时候采样周期选择不当，系统可能失去可控性及可观性。

(2) 卡尔曼滤波器是一种最优的观测器，观测增益 \mathbf{K}_k 是时变的。

(3) $\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k$ 需要是非奇异的，否则 $\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1}$ 无法实现。

(4) 如果 $(\Phi_{k-1}, \mathbf{H}_k)$ 不可观，那么卡尔曼滤波器仍然可以运行，只不过不可观的模态没有进行修正，只是递推罢了。极端情况 $\mathbf{H}_k = \mathbf{0}$ ，那么 $\mathbf{K}_k = \mathbf{0}$

整个系统完全不可观，那么

$$\hat{\mathbf{x}}_{k|k} = \Phi_{k-1} \hat{\mathbf{x}}_{k-1|k-1} + \mathbf{u}_{k-1}$$

$$\mathbf{P}_{k|k} = \Phi_{k-1} \mathbf{P}_{k-1|k-1} \Phi_{k-1}^T + \Gamma_{k-1} \mathbf{Q}_{k-1} \Gamma_{k-1}^T$$



多速率卡尔曼滤波器

□ 模型

考虑一类多速率采样的线性离散系统：

$$\begin{aligned}\mathbf{x}_k &= \Phi_{k-1} \mathbf{x}_{k-1} + \mathbf{u}_{k-1} + \Gamma_{k-1} \mathbf{w}_{k-1} \\ \mathbf{z}_k &= \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k\end{aligned}$$

其中：状态和噪声的定义与前面相同，不同在于传感器观测。假设系统基本采样周期为 T_0 ，两种不同传感器的采样周期分别为 $T_i (i=1,2)$ ，且 $T_i (i=1,2)$ 为 T_0 的整数倍，即 $T_i = n_i T_0, n_i \in \mathbb{N}$ 。它们测量矩阵为 $\mathbf{H}_{ik} \in \mathbb{R}^{m_i \times n}$ ，噪声方差阵 $\mathbf{R}_{ik} \in \mathbb{R}^{m_i \times m_i}$ （非奇异）， $i=1,2$ 。令 αT_0 表示各观测数据的采样周期的最小公倍数。当没有观测量时，我们认为 $\mathbf{H}_k = \mathbf{0}$ ，为了保证算法不发生奇异问题，方差阵设置为单位阵（只要不是0的常数阵都可以）。



多速率卡尔曼滤波器

□ 模型改进

最终，观测阵 \mathbf{H}_k 以及观测噪声方差阵 \mathbf{R}_k 均以 αT_0 为周期变化，即

$$\mathbf{H}_k = \begin{cases} \mathbf{H}_{ik}, & \text{if } \text{mod}(k, n_i) = 0 \ \& \ \text{mod}(k, \alpha) \neq 0 \\ \begin{bmatrix} \mathbf{H}_{1k} \\ \mathbf{H}_{2k} \end{bmatrix}, & \text{if } \text{mod}(k, \alpha) = 0 \\ \mathbf{0}, & \text{else} \end{cases} \quad \mathbf{R}_k = \begin{cases} \mathbf{R}_{ik}, & \text{if } \text{mod}(k, n_i) = 0 \ \& \ \text{mod}(k, \alpha) \neq 0 \\ \text{diag}(\mathbf{R}_{1k}, \mathbf{R}_{2k}), & \text{if } \text{mod}(k, \alpha) = 0 \\ \mathbf{I}, & \text{else} \end{cases}$$

其中，表达式 $\text{mod}(a, b)$ 是求余数操作，即 a 除以 b 之后的余数

在整个过程中，观测阵 \mathbf{H}_k 、观测噪声方差阵 \mathbf{R}_k 和观测量 \mathbf{z}_k 的维数在不断的变化，而 $\hat{\mathbf{x}}_{k|k}$ 和 $\mathbf{P}_{k|k}$ 会根据每一步的信息更新而更新。它的推导过程就与经典的卡尔曼滤波器就相同了。



扩展卡尔曼滤波器

□ 模型描述

假设非线性离散系统模型如下：

$$\begin{aligned}\mathbf{x}_k &= \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{w}_{k-1}) \\ \mathbf{z}_k &= \mathbf{h}(\mathbf{x}_k, \mathbf{v}_k)\end{aligned}$$

将非线性函数 $\mathbf{f}(\cdot)$ 围绕 $(k-1)$ 次滤波值 $\hat{\mathbf{x}}_{k-1|k-1}$ 展开成 Taylor 级数的形式，并忽略二次以上的高阶项，得到

$$\begin{aligned}\mathbf{f}(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{w}_{k-1}) &= \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}, \mathbf{0}) + \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u}_{k-1}, \mathbf{w})}{\partial \mathbf{x}} \Bigg|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{w}=\mathbf{0}} (\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1|k-1}) \\ &\quad + \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u}_{k-1}, \mathbf{w})}{\partial \mathbf{w}} \Bigg|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{w}=\mathbf{0}} \mathbf{w}_{k-1}\end{aligned}$$



扩展卡尔曼滤波器

□ 模型描述

类似地，非线性函数 $\mathbf{h}(\cdot)$ 在 $\hat{\mathbf{x}}_{k|k-1}$ 处的线性化值为

$$\mathbf{h}(\mathbf{x}_k, \mathbf{v}_k) = \mathbf{h}(\hat{\mathbf{x}}_{k|k-1}, \mathbf{0}) + \left. \frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}} (\mathbf{x}_k - \hat{\mathbf{x}}_{k|k-1}) + \left. \frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{v}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}} \mathbf{v}_k$$



扩展卡尔曼滤波器

□ 模型描述

$$\mathbf{x}_k = \Phi_{k-1} \mathbf{x}_{k-1} + \mathbf{u}'_{k-1} + \Gamma_{k-1} \mathbf{w}_{k-1}$$

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

其中 \mathbf{v}'_k 的统计特性为 $E(\mathbf{v}'_k) = \mathbf{0}$,

$$\mathbf{R}_{\mathbf{v}'\mathbf{v}'}(k, j) = E(\mathbf{v}'_k \mathbf{v}'_j{}^T) = \begin{cases} \mathbf{R}'_k, & k = j \\ \mathbf{0}, & k \neq j \end{cases}$$

$$\mathbf{R}'_k = \frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{v}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}} \mathbf{R}_k \left(\frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{v}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}} \right)^T$$

其中：

$$\Phi_{k-1} \triangleq \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u}_{k-1}, \mathbf{w})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{w}=\mathbf{0}_{n \times 1}}$$

$$\mathbf{H}_k \triangleq \frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{x}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}_{m \times 1}}$$

$$\Gamma_{k-1} \triangleq \frac{\partial \mathbf{f}(\mathbf{x}, \mathbf{u}_{k-1}, \mathbf{w})}{\partial \mathbf{w}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{w}=\mathbf{0}_{n \times 1}}$$

$$\mathbf{u}'_k \triangleq \mathbf{f}(\hat{\mathbf{x}}_{k-1|k-1}, \mathbf{u}_{k-1}, \mathbf{0}_{n \times 1}) - \Phi_{k-1} \hat{\mathbf{x}}_{k-1|k-1}$$

$$\mathbf{z}'_k \triangleq \mathbf{z}_k - \mathbf{h}(\hat{\mathbf{x}}_{k|k-1}, \mathbf{0}_{m \times 1}) + \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}$$

$$\mathbf{v}'_k \triangleq \frac{\partial \mathbf{h}(\mathbf{x}, \mathbf{v})}{\partial \mathbf{v}} \Big|_{\mathbf{x}=\hat{\mathbf{x}}_{k|k-1}, \mathbf{v}=\mathbf{0}_{m \times 1}} \mathbf{v}_k$$



本讲小结

- 实际中我们如何选取传感器和如何布置传感器等大部分是靠经验，没有实际的理论来支持。从理论上可以进行可观测度（Degree of Observability）的研究，即可观测的程度方面的研究。
- 在Kalman滤波方面的研究可以考虑更加实际的情况，比如：对于维数较高的模型减少计算量，减少对噪声特性的依赖，减少延迟等等。



资源

(1) 可靠飞行控制研究组主页课程中心(全部课件下载)

<http://rfly.buaa.edu.cn/course>

(2) 关注可靠飞行控制研究组公众号 buaarfly(文章、资讯等)

(3) 多旋翼设计与控制交流QQ群:183613048

(4) 视频课程(MOOC)同步发布, 网易云课堂搜索 “多旋翼”

<http://study.163.com/course/introduction/1003715005.htm>

(5) 同名中文书本教材《多旋翼飞行器设计与控制》即将在电子工业出版社出版, 敬请期待

(6) 有疑问可联系课程总助教戴训华, 邮箱: dai@buaa.edu.cn



致谢


感谢控制组同学



郭正龙



邓恒



戴训华

为本节课程准备作出的贡献。



谢谢

更详细的内容可以参考我们的教材：《多旋翼飞行器设计与控制》，电子工业出版社。

中文版目前在亚马逊、当当、京东、天猫（电子工业出版社旗舰店）等网站有售。

英文版本 *Introduction to Multicopter Design and Control*，在Springer出版，在亚马逊有售。