



参数估计理论

蔡远利 教授
西安交通大学自动化学院

0. Outline

- 1 问题描述 / 2
- 2 贝叶斯估计 / 3
- 3 极大似然估计 / 49
- 4 最小二乘估计 / 66
- 5 『经典参数估计与融合估计算法』 / 88

1. 问题描述

根据随机向量 Z 的一个样本（实现） z ，推断随机向量 X 最可能的取值（最优估计） $\hat{x} = \hat{x}(z)$ 。

Table 1: 符号惯例

符号	含义
x	被估计量
z	测量（量测）量
\hat{x}	被估计量的估计值，是量测量的向量函数
\tilde{x}	估计误差， $x - \hat{x}$

2. 贝叶斯估计

Definition 2.1 (代价函数) 若标量函数 $L[x - \hat{x}(z)] = L(\tilde{x})$ 满足:

- 1) 当 $\|\tilde{x}_2\| \geq \|\tilde{x}_1\|$ 时, 有 $L(\tilde{x}_2) \geq L(\tilde{x}_1)$;
- 2) 当 $\tilde{x} = 0$ 时, $L(\tilde{x}) = 0$;
- 3) $L(\tilde{x}) = L(-\tilde{x})$ 。

则称 $L(\tilde{x})$ 为用 $\hat{x}(z)$ 对 x 进行估计时的代价函数 (或称为损失函数)。

Definition 2.2 (贝叶斯风险) 代价函数的数学期望 $B(\tilde{x}) = E[L(\tilde{x})]$, 称为估计 $\hat{x}(z)$ 的贝叶斯风险 (Bayes Risk)。

Definition 2.3 (贝叶斯估计) 若 $\hat{x}(z)$ 是使 $B(\tilde{x}) \Rightarrow \min$ 的估计, 那么称 $\hat{x}(z)$ 为 x 的贝叶斯估计。

2.1 最小方差估计 (Minimum Variance Estimation)

Definition 2.4 (最小方差估计) 取 $L(\tilde{\mathbf{x}}) = [\mathbf{x} - \hat{\mathbf{x}}(z)]^T [\mathbf{x} - \hat{\mathbf{x}}(z)]$ 的贝叶斯估计, 称为最小方差估计, 记为 $\hat{\mathbf{x}}_{MV}(z)$ 。

Theorem 2.1 最小方差估计的结论是条件均值, 即

$$\hat{\mathbf{x}}_{MV}(z) = E[\mathbf{x}|z] \quad (1)$$

Proof 2.1 根据最小方差估计的定义可知

$$\begin{aligned} B(\tilde{\boldsymbol{x}}) &= E[\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})]^T [\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})] \\ &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} [\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})]^T [\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})] f_{\boldsymbol{x}\boldsymbol{z}}(\boldsymbol{x}, \boldsymbol{z}) d\boldsymbol{x} d\boldsymbol{z} \\ &= \int_{-\infty}^{+\infty} f_z(\boldsymbol{z}) \left\{ \int_{-\infty}^{+\infty} [\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})]^T [\boldsymbol{x} - \hat{\boldsymbol{x}}(\boldsymbol{z})] f_{\boldsymbol{x}|\boldsymbol{z}}(\boldsymbol{x}|\boldsymbol{z}) d\boldsymbol{x} \right\} d\boldsymbol{z} \\ &= \int_{-\infty}^{+\infty} f_z(\boldsymbol{z}) B_z(\tilde{\boldsymbol{x}}) d\boldsymbol{z} \end{aligned}$$

由于 $f_z(\boldsymbol{z}) \geq 0$, 不难发现

$$B(\tilde{\boldsymbol{x}}) \Rightarrow \min \Leftrightarrow B_z(\tilde{\boldsymbol{x}}) \Rightarrow \min$$

由

$$\frac{\partial B_z(\tilde{\mathbf{x}})}{\partial \hat{\mathbf{x}}} = -2 \int_{-\infty}^{+\infty} (\mathbf{x} - \hat{\mathbf{x}}) f_{\mathbf{x}|z}(\mathbf{x}|z) d\mathbf{x} = 0$$

可知

$$\hat{\mathbf{x}}_{MV}(z) = \int_{-\infty}^{+\infty} \mathbf{x} f_{\mathbf{x}|z}(\mathbf{x}|z) d\mathbf{x} = E[\mathbf{x}|z]$$

可进一步验证极值的充分条件

$$\frac{\partial^2 B_z(\tilde{\mathbf{x}})}{\partial^2 \hat{\mathbf{x}}} = 2I > 0$$

Corollary 2.1 最小方差估计的均值及估计误差协方差分别为

$$(1) E\hat{\boldsymbol{x}}_{MV}(\boldsymbol{z}) = E\boldsymbol{x}, \quad \text{即 } E\tilde{\boldsymbol{x}}_{MV} = 0$$

$$(2) P_{\tilde{\boldsymbol{x}}_{MV}} = \int_{-\infty}^{+\infty} P_{\boldsymbol{x}|\boldsymbol{z}} f_{\boldsymbol{z}}(\boldsymbol{z}) d\boldsymbol{z} = E_{\boldsymbol{z}} P_{\boldsymbol{x}|\boldsymbol{z}}$$

Proof 2.2 根据均值的定义

$$\begin{aligned}
 E\bar{\mathbf{x}}|z &= \int_{-\infty}^{+\infty} \bar{\mathbf{x}}|z f_z(z) dz = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \mathbf{x} f_{x|z}(\mathbf{x}) f_z(z) d\mathbf{x} dz \\
 &= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \mathbf{x} f_{xz}(\mathbf{x}, z) d\mathbf{x} dz = \bar{\mathbf{x}}
 \end{aligned}$$

因此 $E\hat{\mathbf{x}}_{MV}(z) = E\mathbf{x}$, 即 $E\tilde{\mathbf{x}}_{MV} = 0$ 。

再由协方差的定义可知

$$\begin{aligned}
 P_{\tilde{\mathbf{x}}_{MV}} &= E\tilde{\mathbf{x}}_{MV}\tilde{\mathbf{x}}_{MV}^T = E\{(\mathbf{x} - \bar{\mathbf{x}}|z)(\mathbf{x} - \bar{\mathbf{x}}|z)^T\} \\
 &= \int_{-\infty}^{+\infty} f_z(z) dz \int_{-\infty}^{+\infty} (\mathbf{x} - \bar{\mathbf{x}}|z)(\mathbf{x} - \bar{\mathbf{x}}|z)^T f_{x|z}(\mathbf{x}) d\mathbf{x} = E_z P_{x|z}
 \end{aligned}$$

Corollary 2.2 若 x 与 z 相互独立, 则 $\hat{x}_{MV} = E[x|z] = Ex = \bar{x}$ 。

Proof 2.3 根据贝叶斯公式, 考虑到 x 与 z 相互独立, 则有

$$\begin{aligned} E[x|z] &= \int_{-\infty}^{+\infty} x f_{x|z}(x) dx = \int_{-\infty}^{+\infty} x \frac{f_{xz}(x, z)}{f_z(z)} dx \\ &= \int_{-\infty}^{+\infty} x \frac{f_x(x) f_z(z)}{f_z(z)} dx = \int_{-\infty}^{+\infty} x f_x(x) dx \end{aligned}$$

所以, x 与 z 相互独立时 $E[x|z] = Ex = \bar{x}$ 。

Corollary 2.3 (最小方差估计一般求解公式)

$$\hat{\mathbf{x}}_{MV}(\mathbf{z}) = \frac{\int_{-\infty}^{+\infty} \mathbf{x} f_{z|x}(\mathbf{z}|\mathbf{x}) f_x(\mathbf{x}) d\mathbf{x}}{\int_{-\infty}^{+\infty} f_{z|x}(\mathbf{z}|\mathbf{x}) f_x(\mathbf{x}) d\mathbf{x}} \quad (2)$$

Proof 2.4 因为

$$\begin{aligned} \hat{\mathbf{x}}_{MV}(\mathbf{z}) &= \overline{\mathbf{x}|\mathbf{z}} = \int_{-\infty}^{+\infty} \mathbf{x} f_{x|z}(\mathbf{x}|\mathbf{z}) d\mathbf{x} \\ &= \int_{-\infty}^{+\infty} \mathbf{x} \frac{f_{xz}(\mathbf{x}, \mathbf{z})}{f_z(\mathbf{z})} d\mathbf{x} = \frac{\int_{-\infty}^{+\infty} \mathbf{x} f_{xz}(\mathbf{x}, \mathbf{z}) d\mathbf{x}}{\int_{-\infty}^{+\infty} f_{xz}(\mathbf{x}, \mathbf{z}) d\mathbf{x}} \end{aligned}$$

分子、分母分别再一次应用贝叶斯公式 $f_{xz}(\mathbf{x}, \mathbf{z}) = f_{z|x}(\mathbf{z}|\mathbf{x}) f_x(\mathbf{x})$, 即得证。

Theorem 2.2 (最优估计的不变性) 假设

1. $L(\tilde{x})$ 关于 $\tilde{x} = 0$ 对称且凹；
2. $B_z(\tilde{x}) = \int_{-\infty}^{+\infty} L(\mathbf{x} - \hat{\mathbf{x}}_B) f(\mathbf{x}|z) d\mathbf{x}$ 存在；
3. $f(\mathbf{x}|z)$ 关于条件均值 $\hat{\mathbf{x}}_{MV} = E[\mathbf{x}|z]$ 对称且凸。

那么, $\hat{\mathbf{x}}_B = \hat{\mathbf{x}}_{MV}$ 。

Theorem 2.3 (随机正交原理) 设 \mathbf{x} 与 \mathbf{z} 是两随机向量, 那么对任意的函数 $g(\mathbf{z})$, 有

$$Eg(\mathbf{z})(\mathbf{x} - E[\mathbf{x}|\mathbf{z}])^T = 0 \quad (3)$$

Proof 2.5

$$\begin{aligned} Eg(\mathbf{z})(\mathbf{x} - E[\mathbf{x}|\mathbf{z}])^T &= Eg(\mathbf{z})\mathbf{x}^T - Eg(\mathbf{z})E[\mathbf{x}|\mathbf{z}]^T \\ &= Eg(\mathbf{z})\mathbf{x}^T - \int_{-\infty}^{+\infty} g(\mathbf{z})f_z(\mathbf{z}) \left[\int_{-\infty}^{+\infty} \mathbf{x}f_{x|\mathbf{z}}(\mathbf{x})d\mathbf{x} \right]^T d\mathbf{z} \\ &= \overline{g(\mathbf{z})\mathbf{x}^T} - \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(\mathbf{z})\mathbf{x}^T f(\mathbf{x}, \mathbf{z})d\mathbf{x}d\mathbf{z} = 0 \end{aligned}$$

Corollary 2.4 (随机投影定理) 设 $g(\cdot)$ 为任一函数, 那么

$$E\|\mathbf{x} - E[\mathbf{x}|\mathbf{z}]\|^2 \leq E\|\mathbf{x} - g(\mathbf{z})\|^2 \quad (4)$$

Proof 2.6 根据范数的定义

$$\begin{aligned} \|\mathbf{x} - g(\mathbf{z})\|^2 &= \|\mathbf{x} - E[\mathbf{x}|\mathbf{z}] + E[\mathbf{x}|\mathbf{z}] - g(\mathbf{z})\|^2 \\ &= \|\mathbf{x} - E[\mathbf{x}|\mathbf{z}]\|^2 + \|E[\mathbf{x}|\mathbf{z}] - g(\mathbf{z})\|^2 \\ &\quad + (\mathbf{x} - E[\mathbf{x}|\mathbf{z}])^T (E[\mathbf{x}|\mathbf{z}] - g(\mathbf{z})) \\ &\quad + (E[\mathbf{x}|\mathbf{z}] - g(\mathbf{z}))^T (\mathbf{x} - E[\mathbf{x}|\mathbf{z}]) \end{aligned}$$

根据随机正交原理式 (3), 可知

$$E\|\mathbf{x} - g(\mathbf{z})\|^2 = E\|\mathbf{x} - E[\mathbf{x}|\mathbf{z}]\|^2 + E\|E[\mathbf{x}|\mathbf{z}] - g(\mathbf{z})\|^2$$

因此 $E\|\mathbf{x} - E[\mathbf{x}|\mathbf{z}]\|^2 \leq E\|\mathbf{x} - g(\mathbf{z})\|^2$ 。

Theorem 2.4 (高斯条件均值与协方差) 设 $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, P_x)$, $\mathbf{z} \sim \mathcal{N}(\bar{\mathbf{z}}, P_z)$,
 $\mathbf{y} = [\mathbf{x}^T, \mathbf{z}^T]^T \sim \mathcal{N}(\bar{\mathbf{y}}, P_y)$, 其中 $P_y = \begin{bmatrix} P_x & P_{xz} \\ P_{zx} & P_z \end{bmatrix}$, $P_{xz} = E(\mathbf{x} - \bar{\mathbf{x}})(\mathbf{z} - \bar{\mathbf{z}})^T$ 。

那么

$$E[\mathbf{x}|\mathbf{z}] = \bar{\mathbf{x}} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}}) \quad (5)$$

$$P_{x|z} = P_x - P_{xz}P_z^{-1}P_{zx} \quad (6)$$

Proof 2.7 因为

$$\begin{aligned} f_{x|z}(\mathbf{x}|\mathbf{z}) &= \frac{f_{xz}(\mathbf{x}, \mathbf{z})}{f_z(\mathbf{z})} = \frac{f_y(\mathbf{y})}{f_z(\mathbf{z})} \\ &= \frac{\sqrt{(2\pi)^m |P_z|}}{\sqrt{(2\pi)^{n+m} |P_y|}} \exp\left\{-\frac{1}{2}[(\mathbf{y} - \bar{\mathbf{y}})^T P_y^{-1}(\mathbf{y} - \bar{\mathbf{y}}) - (\mathbf{z} - \bar{\mathbf{z}})^T P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})]\right\} \end{aligned}$$

考虑到

$$P_y^{-1} = \begin{bmatrix} D^{-1} & -D^{-1}P_{xz}P_z^{-1} \\ -P_z^{-1}P_{zx}D^{-1} & P_z^{-1} + P_z^{-1}P_{zx}D^{-1}P_{xz}P_z^{-1} \end{bmatrix} \quad (7)$$

其中, $D = P_x - P_{xz}P_z^{-1}P_{zx}$ 。从而有

$$\begin{bmatrix} \mathbf{x} - \bar{\mathbf{x}} \\ \mathbf{z} - \bar{\mathbf{z}} \end{bmatrix}^T P_y^{-1} \begin{bmatrix} \mathbf{x} - \bar{\mathbf{x}} \\ \mathbf{z} - \bar{\mathbf{z}} \end{bmatrix} - (\mathbf{z} - \bar{\mathbf{z}})^T P_z^{-1} (\mathbf{z} - \bar{\mathbf{z}}) = [\mathbf{x} - E(\mathbf{x}|\mathbf{z})]^T P_{x|z}^{-1} [**]$$

其中, $E(\mathbf{x}|\mathbf{z}) = \bar{\mathbf{x}} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})$, $P_{x|z} = P_x - P_{xz}P_z^{-1}P_{zx}$ 。

注意到

$$\frac{|P_y|}{|P_z|} = |P_{x|z}| \quad (8)$$

于是可导出

$$f_{x|z}(\mathbf{x}|z) = \frac{1}{\sqrt{(2\pi)^2 |P_{x|z}|}} \exp\left\{-\frac{1}{2}[\mathbf{x} - E(\mathbf{x}|z)]^T P_{x|z}^{-1} [**]\right\}$$

在上面的证明中，分别用了 (*) 和 [**] 表示前面对应的对称项部分，以简化符号。

Corollary 2.5 在定理2.4条件下, $P_{\tilde{x}_{MV}} = E_z P_{x|z} = P_{x|z}$, 即

$$\tilde{x}_{MV} \sim \mathcal{N}(0, P_x - P_{xz}P_z^{-1}P_{zx})$$

Proof 2.8 由推论2.1可知

$$P_{\tilde{x}_{MV}} = \int_{-\infty}^{+\infty} P_{x|z} f_z(z) dz = E_z P_{x|z}$$

而定理2.4表明 $P_{x|z} = P_x - P_{xz}P_z^{-1}P_{zx}$, 是常值矩阵, 因此 $E_z P_{x|z} = P_{x|z}$ 。结合最小方差估计是无偏估计的结论, 所以定理2.4条件下 $\tilde{x}_{MV} \sim \mathcal{N}(0, P_x - P_{xz}P_z^{-1}P_{zx})$ 。

Theorem 2.5 若 $z = Hx + v$, $v \sim \mathcal{N}(0, R)$, $x \sim \mathcal{N}(\bar{x}, P_x)$, 而且 $Exv^T = 0$ (正交), 则有

$$E[x|z] = \bar{x} + P_{x|z}H^T R^{-1}(z - H\bar{x}) \quad (9)$$

$$P_{x|z} = P_{\tilde{x}_{MV}} = (P_x^{-1} + H^T R^{-1}H)^{-1} \quad (10)$$

Proof 2.9 根据给定的量测方程 $z = Hx + v$, 可导出

$$\bar{z} = H\bar{x}, \quad \dot{z} = z - \bar{z} = Hx + v - H\bar{x} = H\dot{x} + v$$

$$P_z = E\dot{z}\dot{z}^T = E(H\dot{x} + v)(H\dot{x} + v)^T = HP_xH^T + R$$

$$P_{xz} = E\dot{x}\dot{z}^T = E\dot{x}(H\dot{x} + v)^T = P_xH^T$$

根据定理2.4可得

$$E[\mathbf{x}|\mathbf{z}] = \bar{\mathbf{x}} + P_{xz}P_z^{-1}(\mathbf{z} - \hat{\mathbf{z}}) = \bar{\mathbf{x}} + P_x H^T (HP_x H^T + R)^{-1}(\mathbf{z} - H\bar{\mathbf{x}})$$

$$P_{x|z} = P_{\tilde{x}_{MV}} = P_x - P_{xz}P_z^{-1}P_{zx} = P_x - P_x H^T (HP_x H^T + R)HP_x$$

由矩阵求逆引理可导出

$$P_x - P_x H^T (HP_x H^T + R)HP_x = (P_x^{-1} + H^T R^{-1}H)^{-1}$$

所以在线性量测高斯分布条件下，最小方差估计为

$$E[\mathbf{x}|\mathbf{z}] = \bar{\mathbf{x}} + P_{x|z}H^T R^{-1}(\mathbf{z} - H\bar{\mathbf{x}})$$

$$P_{x|z} = P_{\tilde{x}_{MV}} = (P_x^{-1} + H^T R^{-1}H)^{-1}$$

上述估计误差协方差关系可以表示为

$$P_{x|z}^{-1} = P_x^{-1} + H^T R^{-1} H \quad (11)$$

具有重要的物理含义。另外，注意到

$$I - P_{x|z} H^T R^{-1} H = P_{x|z} (P_x^{-1} - H^T R^{-1} H) = P_{x|z} P_x^{-1} \quad (12)$$

我们可得定理2.5的另外一种形式。

Theorem 2.6 (线性量测高斯分布最小方差估计) 如果 $z = Hx + v$, 当 $v \sim \mathcal{N}(0, R)$, $x \sim \mathcal{N}(\bar{x}, P_x)$, 且 $Exv^T = 0$, 那么

$$\hat{x}_L = P_{\hat{x}_L} (P_x^{-1} \bar{x} + H^T R^{-1} z) \quad (13)$$

$$P_{\hat{x}_L}^{-1} = P_x^{-1} + H^T R^{-1} H \quad (14)$$

Example 2.1 设 $x \sim U[0, 1]$, 即 $f_x(x) = \begin{cases} 1, & 0 \leq x \leq 1 \\ 0, & \text{otherwise} \end{cases}$.

(1) 求 x 的先验估计 \bar{x} ;

(2) 如果 x 的量测为 $z = \ln \frac{1}{x} + v$, v 服从指数分布, 即

$$f_v(v) = \begin{cases} e^{-v}, & v \geq 0 \\ 0, & v < 0 \end{cases}$$

此外假设 x 与 v 相互独立, 求 x 的最小方差估计。

Solution 2.1 (1) $\bar{x} = \int_{-\infty}^{+\infty} x f_x(x) dx = \frac{1}{2}$;

(2) 因为 x 与 v 相互独立, 因此

$$f_{z|x}(z|x) = f_v(z - \ln \frac{1}{x}) = \begin{cases} e^{-z - \ln \frac{1}{x}}, & z - \ln \frac{1}{x} \geq 0 \\ 0, & z - \ln \frac{1}{x} < 0 \end{cases}$$

$$= \begin{cases} \frac{1}{x} e^{-z}, & x \geq e^{-z} \\ 0, & x < e^{-z} \end{cases}$$

所以

$$\hat{x}_{MV}(z) = \frac{\int_{e^{-z}}^1 e^{-z} dx}{\int_{e^{-z}}^1 \frac{1}{x} e^{-z} dx} = \frac{e^{-z}(1 - e^{-z})}{e^{-z} \ln x|_{e^{-z}}^1} = \frac{1 - e^{-z}}{z}$$

2.2 线性最小方差估计

Definition 2.5 (Linear Minimum Variance Estimation) 取 $L(\tilde{x}) = [x - \hat{x}(z)]^T [x - \hat{x}(z)]$ 且形式上限制为 $\hat{x} = a + Bz$ 的贝叶斯估计, 其中 a 和 B 分别是常系数向量和矩阵, 则称为线性最小方差估计, 记为 $\hat{x}_L(z)$ 。

Lemma 2.1 设 A, B, C 是合适维数的矩阵, 关于矩阵迹有如下公式:

$$\begin{aligned}\operatorname{tr}(AB) &= \operatorname{tr}(BA) \\ \frac{\partial \operatorname{tr}(ABA^T)}{\partial A} &= AB + AB^T \\ \frac{\partial \operatorname{tr}(BAC)}{\partial A} &= B^T C^T\end{aligned}$$

Proof 2.10 (练习)

Lemma 2.2 令 $L = [\mathbf{x} - \mathbf{a} - B\mathbf{z}]^T[\mathbf{x} - \mathbf{a} - B\mathbf{z}]$, 有

$$\frac{\partial L}{\partial \mathbf{a}} = 2(\mathbf{a} + B\mathbf{z} - \mathbf{x}) \quad (15)$$

$$\frac{\partial L}{\partial B} = 2(B\mathbf{z} + \mathbf{a} - \mathbf{x})\mathbf{z}^T \quad (16)$$

Proof 2.11 展开 L 可得

$$L = \mathbf{x}^T \mathbf{x} + \mathbf{a}^T \mathbf{a} + \mathbf{z}^T B^T B \mathbf{z} - 2\mathbf{x}^T \mathbf{a} + 2\mathbf{a}^T B \mathbf{z} - 2\mathbf{x}^T B \mathbf{z}$$

由此可直接可导出式 (15)。另外, 对于任意相同维数向量 \mathbf{u} 和 \mathbf{v} , 有

$$\mathbf{u}^T \mathbf{v} = \text{tr}(\mathbf{v}\mathbf{u}^T)$$

因此

$$\begin{aligned}\frac{\partial L}{\partial B} &= \frac{\partial}{\partial B} (\mathbf{z}^T B^T B \mathbf{z} + 2\mathbf{a}^T B \mathbf{z} - 2\mathbf{x}^T B \mathbf{z}) \\ &= \frac{\partial}{\partial B} \text{tr}(B \mathbf{z} \mathbf{z}^T B^T + 2B \mathbf{z} \mathbf{a}^T - 2B \mathbf{z} \mathbf{x}^T)\end{aligned}$$

根据引理2.1, 可导出

$$\frac{\partial L}{\partial B} = 2B \mathbf{z} \mathbf{z}^T + 2\mathbf{a} \mathbf{z}^T - 2\mathbf{x} \mathbf{z}^T = 2(B \mathbf{z} + \mathbf{a} - \mathbf{x}) \mathbf{z}^T$$

Theorem 2.7 线性最小方差估计 $\hat{\mathbf{x}}_L(\mathbf{z})$ 的充要条件为

$$E \{ [\mathbf{x} - \hat{\mathbf{x}}_L(\mathbf{z})] \mathbf{z}^T \} = 0 \quad (17)$$

$$E[\mathbf{x} - \hat{\mathbf{x}}_L(\mathbf{z})] = 0 \quad (18)$$

Proof 2.12 (1) 充分性: 设以上两式成立, 对任意的 $\hat{\boldsymbol{x}}$, 有

$$\begin{aligned} E\|\boldsymbol{x} - \hat{\boldsymbol{x}}\|^2 &= E\|\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z}) + \hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}\|^2 \\ &= E\|\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})\|^2 + E\|\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}\|^2 \\ &\quad + E[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})]^\text{T}[\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}] + E[\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}]^\text{T}[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})] \end{aligned}$$

记 $\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \boldsymbol{a}_o + B_o \boldsymbol{z}$, $\hat{\boldsymbol{x}} = \boldsymbol{a} + B \boldsymbol{z}$, 那么 $\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}} = \boldsymbol{a}_o - \boldsymbol{a} + (B_o - B) \boldsymbol{z}$, 可见

$$\begin{aligned} &E[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})][\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}]^\text{T} \\ &= E[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})][\boldsymbol{a}_o - \boldsymbol{a}]^\text{T} + E\{[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})] \boldsymbol{z}^\text{T} (B_o - B)^\text{T}\} = 0 \end{aligned}$$

同时说明 $E[\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}]^\text{T}[\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})] = 0$, 因而有

$$E\|\boldsymbol{x} - \hat{\boldsymbol{x}}\|^2 = E\|\boldsymbol{x} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})\|^2 + E\|\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \hat{\boldsymbol{x}}\|^2 \quad (19)$$

所以

$$E\|\mathbf{x} - \hat{\mathbf{x}}_L(\mathbf{z})\|^2 \leq E\|\mathbf{x} - \hat{\mathbf{x}}\|^2 \quad (20)$$

说明 $\hat{\mathbf{x}}_L(\mathbf{z})$ 是线性最小方差估计。

(2) 必要性: 设 $\hat{x}_L(z) = A_o + B_o z$ 是线性最小方差估计, 由式 (17) 可得

$$\frac{\partial}{\partial \mathbf{a}} E \|(\mathbf{x} - \mathbf{a} - B\mathbf{z})\|^2 |_{\mathbf{a}=\mathbf{a}_o, B=B_o} = -2E[\mathbf{x} - \mathbf{a}_o - B_o \mathbf{z}] = 0$$

即 $E[\mathbf{x} - \hat{x}_L(z)] = 0$ 。而由式 (18) 可得

$$\frac{\partial}{\partial B} E \|(\mathbf{x} - \mathbf{a} - B\mathbf{z})\|^2 |_{\mathbf{a}=\mathbf{a}_o, B=B_o} = -2E\{[\mathbf{x} - \mathbf{a}_o - B_o \mathbf{z}]\mathbf{z}^T\} = 0$$

因此 $E\{[\mathbf{x} - \hat{x}_L(z)]\mathbf{z}^T\} = 0$ 。

Corollary 2.6 对任意合适维数的矩阵 A 和向量 \mathbf{b} , 有

$$E\|\mathbf{x} - \hat{x}_L(z)\|^2 \leq E\|\mathbf{x} - A\mathbf{z} - \mathbf{b}\|^2 \quad (21)$$

Theorem 2.8 (线性最小方差估计及其协方差)

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \bar{\boldsymbol{x}} + P_{xz}P_z^{-1}(\boldsymbol{z} - \bar{\boldsymbol{z}}) \quad (22)$$

$$P_{\hat{\boldsymbol{x}}_L} = E\tilde{\boldsymbol{x}}_L\tilde{\boldsymbol{x}}_L^T = P_x - P_{xz}P_z^{-1}P_{zx} \quad (23)$$

Proof 2.13 设 $\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \boldsymbol{a}_o + B_o\boldsymbol{z}$, 根据线性最小方差估计充要条件 (18) 可知

$$\bar{\boldsymbol{x}} = \boldsymbol{a}_o + B_o\bar{\boldsymbol{z}} \quad (24)$$

而由式 (17) 可得

$$E\{[\boldsymbol{x} - \bar{\boldsymbol{x}} + \bar{\boldsymbol{x}} - \hat{\boldsymbol{x}}_L(\boldsymbol{z})]\boldsymbol{z}^T\} = 0 \Rightarrow E\{[\boldsymbol{x} - \bar{\boldsymbol{x}}]\boldsymbol{z}^T\} = E\{[\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \bar{\boldsymbol{x}}]\boldsymbol{z}^T\}$$

因此

$$P_{xz} = E \{ [\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \bar{\boldsymbol{x}}][\boldsymbol{z} - \bar{\boldsymbol{z}}]^T \} \quad (25)$$

注意到

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) - \bar{\boldsymbol{x}} = B_o(\boldsymbol{z} - \bar{\boldsymbol{z}})$$

上式两边右乘 $[\boldsymbol{z} - \bar{\boldsymbol{z}}]^T$ 并取数学期望，并带入式 (24)，得

$$P_{xz} = B_o P_z \Rightarrow B_o = P_{xz} P_z^{-1}$$

将上式带入式 (25)，可得

$$\boldsymbol{a}_o = \bar{\boldsymbol{x}} - P_{xz} P_z^{-1} \bar{\boldsymbol{z}}$$

将 \mathbf{a}_o, B_o 带入 $\hat{\mathbf{x}}_L(\mathbf{z}) = \mathbf{a}_o + B_o\mathbf{z}$, 即得

$$\hat{\mathbf{x}}_L(\mathbf{z}) = \bar{\mathbf{x}} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})$$

由上式可知

$$\begin{aligned} P_{\hat{\mathbf{x}}_L} &= E \{ [\hat{\mathbf{x}}_L(\mathbf{z}) - \mathbf{x}][\hat{\mathbf{x}}_L(\mathbf{z}) - \mathbf{x}]^T \} \\ &= E \{ [\bar{\mathbf{x}} - \mathbf{x} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})][\bar{\mathbf{x}} - \mathbf{x} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})]^T \} \\ &= P_x - P_{xz}P_z^{-1}P_{zx} \end{aligned}$$

上式中用到了 $P_z^T = P_z, P_{zx} = P_{xz}^T$ 。

Theorem 2.9 当 $(x, z) \sim$ 高斯分布时, $\hat{x}_L(z) = \hat{x}_{MV}(z)$ 。

Proof 2.14 在高斯分布假设下, 最小方差估计为

$$\hat{x}_{MV}(z) = E[x|z] = \bar{x} + P_{xz}P_z^{-1}(z - \bar{z})$$

比较 (22) 即得证。此外, 还有 $P_{x|z} = P_{\tilde{x}_L}$ 。即在正态分布情况下, 线性最小方差估计即为最小方差估计。

Example 2.2 设 z 为量测值, x_1, x_2 为未知的随机量, A, B, r 是确定性量, 此外, $y = Ax_1 + Bx_2 + r + w$ 。 w 为随机噪声, 与 z 不相关, 而且 $Ew = 0$, 证明

$$(1) \hat{y}_L(z) = A\hat{x}_{1L}(z) + B\hat{x}_{2L}(z) + r;$$

$$(2) E\tilde{y}_L(z) = 0。$$

Solution 2.2 由定理2.7可知 $\hat{y}_L(z) = \bar{y} + P_{yz}P_z^{-1}(z - \bar{z})$ 。其中

$$\bar{y} = A\bar{x}_1 + B\bar{x}_2 + r$$

$$P_{yz} = E[y - \bar{y}][z - \bar{z}]^T = AP_{x_1z} + BP_{x_2z}$$

所以

$$\begin{aligned}\hat{y}_L(z) &= A\bar{x}_1 + B\bar{x}_2 + r + (AP_{x_1z} + BP_{x_2z})P_z^{-1}(z - \bar{z}) \\ &= A\bar{x}_1 + AP_{x_1z}P_z^{-1}(z - \bar{z}) + B\bar{x}_2 + BP_{x_2z}P_z^{-1}(z - \bar{z}) + r \\ &= A\hat{x}_{1L}(z) + B\hat{x}_{2L}(z) + r\end{aligned}$$

另外注意到 $E\hat{y}_L(z) = A\bar{x}_1 + B\bar{x}_2 + r = \bar{y}$, 因此有

$$E\tilde{y}_L(z) = E[\hat{y}_L(z) - E\hat{y}_L(z)] = E[\hat{y}_L(z) - \bar{y}] = 0$$

Corollary 2.7 若 z_1, z_2, \dots, z_k 互不相关, 那么

$$\hat{x}_L(z_1, z_2, \dots, z_k) = \hat{x}_L(z_1) + \hat{x}_L(z_2) + \dots + \hat{x}_L(z_k) - (k-1)\bar{x}$$

Proof 2.15 令

$$z = [z_1^T, z_2^T, \dots, z_k^T]^T$$

那么

$$\bar{z} = [\bar{z}_1^T, \bar{z}_2^T, \dots, \bar{z}_k^T]^T$$

$$P_{xz} = E(x - \bar{x})(z - \bar{z})^T = [P_{xz_1}, P_{xz_2}, \dots, P_{xz_k}]$$

$$P_z = \begin{bmatrix} P_{z_1} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & P_{z_k} \end{bmatrix}$$

根据定理2.7, 可知

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \bar{\boldsymbol{x}} + P_{xz}P_z^{-1}(\boldsymbol{z} - \bar{\boldsymbol{z}}) = \bar{\boldsymbol{x}} + \sum_{i=1}^k P_{xz_i}P_{z_i}^{-1}(\boldsymbol{z}_i - \bar{\boldsymbol{z}}_i)$$

考虑到

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}_i) = \bar{\boldsymbol{x}} + P_{xz_i}P_{z_i}^{-1}(\boldsymbol{z}_i - \bar{\boldsymbol{z}}_i)$$

所以

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \sum_{i=1}^k \hat{\boldsymbol{x}}_L(\boldsymbol{z}_i) - (k-1)\bar{\boldsymbol{x}}$$

Example 2.3 设 $x \sim \mathcal{N}(\bar{x}, P_x)$, $v \sim \mathcal{N}(0, P_v)$, 两者不相关, 如果

$$z = Hx + v \quad (26)$$

试求 x 的线性最小方差估计。

Solution 2.3 根据线性最小方差估计定理2.8

$$\hat{x}_L(z) = \bar{x} + P_{xz}P_z^{-1}(z - \bar{z})$$

$$P_{\hat{x}_L} = P_x - P_{xz}P_z^{-1}P_{zx}$$

由 (26) 可知 $\bar{z} = H\bar{x}$, 令 $\overset{\circ}{x} = x - \bar{x}$, $\overset{\circ}{z} = z - \bar{z} = H\overset{\circ}{x} + v$, 可得

$$P_z = E[\overset{\circ}{z}\overset{\circ}{z}^T] = HP_xH^T + P_v$$

$$P_{xz} = E(\overset{\circ}{x})\overset{\circ}{z}^T = E(\overset{\circ}{x})(H\overset{\circ}{x} + v)^T = P_xH$$

因此

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = \bar{\boldsymbol{x}} + P_x H (H P_x H^T + P_v)^{-1} (H \boldsymbol{z} - \bar{\boldsymbol{z}}) \quad (27)$$

$$P_{\tilde{x}_L} = P_x - P_x H (H P_x H^T + P_v)^{-1} H^T P_x \quad (28)$$

考虑到

$$\begin{aligned} I - P_x H (H P_x H^T + P_v)^{-1} H &= P_{\tilde{x}_L} P_x^{-1} \\ P_x H (H P_x H^T + P_v)^{-1} H &= I - P_{\tilde{x}_L} P_x^{-1} = P_{\tilde{x}_L} (P_{\tilde{x}_L}^{-1} - P_x^{-1}) \end{aligned}$$

将以上两式代入 (27), 可得

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = P_{\tilde{x}_L} P_x^{-1} \bar{\boldsymbol{x}} + P_{\tilde{x}_L} (P_{\tilde{x}_L}^{-1} - P_x^{-1}) \boldsymbol{z} \quad (29)$$

另外应用矩阵求逆引理, 由 (28) 可知

$$P_{\tilde{x}_L}^{-1} = P_x^{-1} + H^T P_v^{-1} H \quad (30)$$

代入 (27), 最后导出

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = P_{\tilde{x}_L} P_x^{-1} \bar{\boldsymbol{x}} + P_{\tilde{x}_L} H^T P_v^{-1} H \boldsymbol{z} \quad (31)$$

(30) 和 (31) 即为简化表达的结果。总结起来, \boldsymbol{x} 的线性最小方差估计及其协方差矩阵为

$$\hat{\boldsymbol{x}}_L(\boldsymbol{z}) = P_{\tilde{x}_L} (P_x^{-1} \bar{\boldsymbol{x}} + H^T P_v^{-1} H \boldsymbol{z}) \quad (32)$$

$$P_{\tilde{x}_L}^{-1} = P_x^{-1} + H^T P_v^{-1} H \quad (33)$$

以上两式和 (27) 与 (28) 数学上是等价的。

Example 2.4 已知 $z = x + v$, $x \sim \mathcal{N}(\bar{x}, \sigma_x^2)$, $v \sim \mathcal{N}(0, \sigma_v^2)$, 试求 x 的线性最小方差估计。

Solution 2.4 由于 $H = 1$, $P_v = \sigma_v^2$, 所以

$$H^T P_v^{-1} H = \sigma_v^{-2}$$

又 $P_x = \sigma_x^2$, 由 (33) 可知

$$P_{\tilde{x}_L}^{-1} = \sigma_{\tilde{x}_L}^{-2} = \sigma_x^{-2} + \sigma_v^{-2} \quad (34)$$

由 (32) 可以求得

$$\hat{x}_L(z) = \frac{\sigma_x^2 \sigma_v^2}{\sigma_x^2 + \sigma_v^2} \left(\frac{1}{\sigma_x^2} \bar{x} + \frac{1}{\sigma_v^2} z \right) \quad (35)$$

如果没有任何先验信息, 意味着 $\sigma_x^{-2} = 0$, 此时

$$\hat{x}_L(z) = z$$

如果量测误差特别大, 即 $\sigma_v^{-2} \rightarrow 0$, 则

$$\hat{x}_L(z) = \bar{x}$$

这称为先验估计。

Example 2.5 已知 $z = \ln \frac{1}{x} + v, x \sim U[0, 1], v$ 服从指数分布, 即

$$f_v(v) = \begin{cases} e^{-v}, & v \geq 0 \\ 0, & v < 0 \end{cases}$$

假设 x 与 v 相互独立, 试求 x 的线性最小方差估计。

Solution 2.5 因为 $\bar{x} = 1/2, f_{xz}(x, z) = f(z|x)(z|x)f_x(x)$, 注意到

$$f_{z|x}(z|x) = f_v(z - \ln \frac{1}{x}) = \begin{cases} e^{-(z - \ln \frac{1}{x})}, & z - \ln \frac{1}{x} \geq 0 \\ 0, & z - \ln \frac{1}{x} < 0 \end{cases} = \begin{cases} \frac{1}{x} e^{-z}, & x \geq e^{-z} \\ 0, & x < e^{-z} \end{cases}$$

$$f_{xz}(x, z) = f_{z|x}(z|x)f_x(x) = \begin{cases} \frac{1}{x} e^{-z}, & 1 \geq x \geq e^{-z} \\ 0, & 0 \leq x < e^{-z} \end{cases}$$

所以

$$f_z(z) = \int_{-\infty}^{+\infty} f_{xz}(x, z) dx = \begin{cases} ze^{-z}, & z \geq 0 \\ 0, & z < 0 \end{cases}$$

因此

$$Exz = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} xz f_{xz}(x, z) dx dz = \frac{3}{4}$$

$$P_{xz} = E(x - \bar{x})(z - \bar{z}) = Exz - \bar{x}\bar{z} = -\frac{1}{4}$$

$$P_z = E(z - \bar{z})^2 = Ez^2 - \bar{z}^2 = \int_{-\infty}^{+\infty} z^2 f_z(z) dz - \left[\int_{-\infty}^{+\infty} z f_z(z) dz \right]^2 = 6 - 2^2$$

根据定理2.7, 可得

$$x_L = \bar{x} + P_{xz} P_z^{-1} (z - \bar{z}) = \frac{1}{2} - \frac{1}{4} \cdot \frac{1}{2} (z - 2) = \frac{3}{4} - \frac{1}{8} z$$

Remark 2.1 在这个问题中

$$P(Z \leq z | X = x) = P\left(\frac{1}{\ln x} + V \leq z\right) = P\left(V \leq z - \frac{1}{\ln x}\right)$$

由此可知

$$F_{z|x}(z|x) = F_v\left(z - \frac{1}{\ln x}\right) \Rightarrow f_{z|x}(z|x) = f_v\left(z - \frac{1}{\ln x}\right)$$

在上面示例求解过程中，直接用到了上式。

2.3 最大后验估计

Definition 2.6 (Maximum A Posteriori Estimation) 使 $f(\mathbf{x}|\mathbf{z}) \Rightarrow \max$ 的估计称为 \mathbf{x} 的最大后验估计, 记为 $\hat{\mathbf{x}}_{MA}(\mathbf{z})$ 。称

$$\left. \frac{\partial \ln f(\mathbf{x}|\mathbf{z})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{MA}} = 0 \quad (36)$$

为后验方程。

Theorem 2.10 若 (\mathbf{x}, \mathbf{z}) 服从联合高斯分布, 那么 $\hat{\mathbf{x}}_{MA}(\mathbf{z}) = \hat{\mathbf{x}}_{MV}(\mathbf{z})$ 。

Proof 2.16 因为

$$f_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) = \frac{1}{\sqrt{(2\pi)^n |P_{\mathbf{x}|\mathbf{z}}|}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \overline{\mathbf{x}}|\mathbf{z})^T P_{\mathbf{x}|\mathbf{z}}(\mathbf{x} - \overline{\mathbf{x}}|\mathbf{z})\right\}$$

可见

$$\frac{\partial \ln f_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z})}{\partial \mathbf{x}} = 0 \Leftrightarrow \frac{1}{2}(\mathbf{x} - \overline{\mathbf{x}}|\mathbf{z})^T P_{\mathbf{x}|\mathbf{z}}(\mathbf{x} - \overline{\mathbf{x}}|\mathbf{z}) \Rightarrow \min$$

所以

$$\hat{\mathbf{x}}_{MA}(\mathbf{z}) = \hat{\mathbf{x}}_{MV}(\mathbf{z}) = \overline{\mathbf{x}}|\mathbf{z}$$

Theorem 2.11 取代价函数为 $L(\tilde{\boldsymbol{x}}) = \begin{cases} 0, & \|\tilde{\boldsymbol{x}}\| < \frac{\varepsilon}{2} \\ \frac{1}{\varepsilon}, & \|\tilde{\boldsymbol{x}}\| \geq \frac{\varepsilon}{2} \end{cases}$ ($\varepsilon > 0$ 且足够小),
由此获得的贝叶斯估计 $\hat{\boldsymbol{x}}_B(\boldsymbol{z})$ 即为 $\hat{\boldsymbol{x}}_{MA}(\boldsymbol{z})$ 。

3. 极大似然估计

Definition 3.1 (Maximum-Likelihood Estimation) 使似然函数

$$\Lambda(\mathbf{x}) = f(\mathbf{z}|\mathbf{x}) \quad (37)$$

最大的估计称为 \mathbf{x} 的极大似然估计，记为 $\hat{\mathbf{x}}_{ML}(\mathbf{z})$ 。

一般通过求解似然方程获得极大似然估计，似然方程是指

$$\left. \frac{\partial \ln \Lambda(\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{ML}} = \left. \frac{\partial \ln f(\mathbf{z}|\mathbf{x})}{\partial \mathbf{x}} \right|_{\mathbf{x}=\hat{\mathbf{x}}_{ML}} = 0 \quad (38)$$

Example 3.1 已知 $z = \ln \frac{1}{x} + v, x \sim U(0, 1), v$ 服从指数分布, 即

$$f_v(v) = \begin{cases} e^{-v}, & v \geq 0 \\ 0, & v < 0 \end{cases}$$

假设 x 与 v 相互独立, 试求 x 的极大似然估计 \hat{x}_{ML} 。

Solution 3.1 因为

$$\begin{aligned} f_{z|x}(z|x) &= f_v(z - \ln \frac{1}{x}) = \begin{cases} e^{-(z - \ln \frac{1}{x})}, & z - \ln \frac{1}{x} \geq 0 \\ 0, & z - \ln \frac{1}{x} < 0 \end{cases} \\ &= \begin{cases} \frac{1}{x} e^{-z}, & x \geq e^{-z} \\ 0, & x < e^{-z} \end{cases} \end{aligned}$$

所以 $\hat{x}_{ML} = e^{-z}$ 。

Theorem 3.1 当对 \boldsymbol{x} 的先验信息一无所知时, $\hat{\boldsymbol{x}}_{ML}(\boldsymbol{z}) = \hat{\boldsymbol{x}}_{MA}(\boldsymbol{z})$

Proof 3.1 由

$$f_{z|x}(\boldsymbol{z}|\boldsymbol{x}) = \frac{f_{zx}(\boldsymbol{z}, \boldsymbol{x})}{f_x(\boldsymbol{x})} = \frac{f_{x|z}(\boldsymbol{x}|\boldsymbol{z})f_z(\boldsymbol{z})}{f_x(\boldsymbol{x})}$$

可知

$$\ln f_{z|x}(\boldsymbol{z}|\boldsymbol{x}) = \ln f_{x|z}(\boldsymbol{x}|\boldsymbol{z}) + \ln f_z(\boldsymbol{z}) - \ln f_x(\boldsymbol{x})$$

当对 \boldsymbol{x} 的先验信息一无所知时

$$\frac{\partial \ln f_x(\boldsymbol{x})}{\partial \boldsymbol{x}} = 0$$

因此

$$\frac{\partial \ln f_{z|x}(\boldsymbol{z}|\boldsymbol{x})}{\partial \boldsymbol{x}} = \frac{\partial \ln f_{x|z}(\boldsymbol{x}|\boldsymbol{z})}{\partial \boldsymbol{x}}$$

从而导出

$$\hat{\boldsymbol{x}}_{ML}(\boldsymbol{z}) = \hat{\boldsymbol{x}}_{MA}(\boldsymbol{z})$$

Theorem 3.2 (Linear Gaussian Measurement) 如果 $z = Hx + v, v \sim \mathcal{N}(0, R)$, 那么

$$\hat{x}_{ML}(z) = (H^T R^{-1} H)^{-1} H^T R^{-1} z \quad (39)$$

Proof 3.2 因为

$$\begin{aligned} f_{z|x}(z|x) &= f_v(z - Hx) = \frac{1}{\sqrt{(2\pi)^n |R|}} \exp\left\{-\frac{1}{2} \mathbf{v}^T R^{-1} \mathbf{v}\right\} \Bigg|_{v=z-Hx} \\ &= \frac{1}{\sqrt{(2\pi)^n |R|}} \exp\left\{-\frac{1}{2} (z - Hx)^T R^{-1} (z - Hx)\right\} \end{aligned}$$

显然, 极大化似然函数相当于

$$J = \frac{1}{2} (z - Hx)^T R^{-1} (z - Hx) \Rightarrow \min$$

由此，有

$$\frac{\partial J}{\partial \mathbf{x}} = -H^T R^{-1}(\mathbf{z} - H\mathbf{x}) = 0$$

当 $H^T R^{-1}H$ 非奇异时，即有

$$\hat{\mathbf{x}}_{ML}(\mathbf{z}) = (H^T R^{-1}H)^{-1}H^T R^{-1}\mathbf{z}$$

Corollary 3.1 线性量测高斯噪声条件下, 有

(1) $E\tilde{\mathbf{x}}_{ML} = 0$; (无偏估计)

(2) $P_{\tilde{\mathbf{x}}_{ML}} = (H^T R^{-1} H)^{-1}$;

(3) $\hat{\mathbf{x}}_{ML} = P_{\tilde{\mathbf{x}}_{ML}} H^T R^{-1} \mathbf{z}$ 。

Remark 3.1 (1) 推论3.1中(2)、(3)合称为 Gauss-Markov 估计器;

(2) 特别地, $P_{\tilde{\mathbf{x}}_{ML}}$ 与测量值无关;

(3) 当 $H = I, P_{\tilde{\mathbf{x}}_{ML}} = R$, 此时 $\hat{\mathbf{x}}_{ML} = \mathbf{z}$;

(4) 如果没有先验知识, 可以认为 $\bar{x} = 0, P_x \rightarrow \infty$, 由线性高斯量测最小方差估计知

$$\begin{cases} E[\mathbf{x}|z] = \bar{x} + P_{x|z}H^T R^{-1}(z - H\bar{x}) \\ P_{x|z} = P_{\hat{x}_{MV}} = (P_x^{-1} + H^T R^{-1}H)^{-1} \end{cases}$$

可见, 此时 $E[\mathbf{x}|z] \rightarrow \hat{x}_{ML}, P_{\hat{x}_{MV}} = P_{\hat{x}_{ML}} = (H^T R^{-1}H)^{-1}$ 。

Example 3.2 设 x 是服从参数为 (μ, σ) 的正态分布的随机变量, 即

$$f(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2\sigma^2}(x - \mu)^2\right\}$$

假设进行了 N 次独立的采样, 获得了相互独立的 x_1, x_2, \dots, x_N , 试估计参数 (μ, σ) 。

Solution 3.2 根据独立性假设, 可知

$$\Lambda(\mu, \sigma) = f(x_1, x_2, \dots, x_N | \mu, \sigma) = \frac{1}{\sqrt{(2\pi)^N \sigma^N}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^N (x_i - \mu)^2 \right\}$$

根据似然函数极大化条件 $\frac{\partial \Lambda(\mu, \sigma)}{\partial \mu} = 0, \frac{\partial \Lambda(\mu, \sigma)}{\partial \sigma} = 0$, 可得

$$\sum_{i=1}^N (x_i - \mu) = 0, \quad \sum_{i=1}^N (x_i - \mu)^2 - N\sigma^2 = 0$$

由此可得两个参数的极大似然估计如下:

$$\hat{\mu} = \frac{1}{N} \sum_{i=1}^N x_i, \quad \hat{\sigma}^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$$

Example 3.3 设估计确定性电压 x 有两种不同的方案，其一是用两个昂贵的电压表，它们的测量噪声为 $\mathcal{N}(0, 2)$ ；其二是用四个廉价的电压表，它们的测量噪声为 $\mathcal{N}(0, 3.5)$ 。问哪一种方案测量到的结果更加可靠？

Solution 3.3 (a) 用两个昂贵的电压表时

$$z = \begin{bmatrix} 1 \\ 1 \end{bmatrix} x + v$$

其中， $v \sim \mathcal{N}(0, \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix})$ 。因此

$$P_{\hat{x}} = (H^T R^{-1} H)^{-1} = \left[[1, 1] \begin{bmatrix} 2 & 0 \\ 0 & 2 \end{bmatrix}^{-1} \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right]^{-1} = 1$$

(b) 用四个廉价电压表时

$$z = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} x + v$$

其中, $v \sim \mathcal{N}(0, 3.5I)$ 。此时

$$P_{\tilde{x}} = (H^T R^{-1} H)^{-1} = \frac{7}{8}$$

结论: 第二个方案更可靠些。

3.1 克拉默-拉奥下界

Theorem 3.3 (1) 设 \hat{x} 为确定性量 x 基于测量 z 的无偏估计, 那么

$$P_{\hat{x}} \geq J_F^{-1} \quad (40)$$

其中

$$J_F = E \left\{ \left[\frac{\partial \ln \Lambda(\mathbf{x})}{\partial \mathbf{x}} \right] \left[\frac{\partial \ln \Lambda(\mathbf{x})}{\partial \mathbf{x}} \right]^T \right\} \quad (41a)$$

$$= - E \left[\frac{\partial^2 \ln \Lambda(\mathbf{x})}{\partial \mathbf{x} \partial \mathbf{x}^T} \right] \quad (41b)$$

称为费希尔信息矩阵 (Fisher Information Matrix)。此外, $\Lambda(\mathbf{x}) = f(z|\mathbf{x})$ 。

(2) 设 \hat{x} 为随机量 x 基于量测 z 的无偏估计, 那么

$$P_{\hat{x}} \geq L^{-1} \quad (42)$$

其中

$$L = E \left\{ \left[\frac{\partial \ln f(\mathbf{x}, \mathbf{z})}{\partial \mathbf{x}} \right] \left[\frac{\partial \ln f(\mathbf{x}, \mathbf{z})}{\partial \mathbf{x}} \right]^T \right\} \quad (43a)$$

$$= -E \left[\frac{\partial^2 \ln f(\mathbf{x}, \mathbf{z})}{\partial \mathbf{x} \partial \mathbf{x}^T} \right] \quad (43b)$$

称为信息矩阵 (*information matrix*)。

Lemma 3.1 (Schwarz Inequality) 设 $f, g \in L^2$, 那么

$$\begin{cases} \langle f, g \rangle \leq \|f\| \cdot \|g\| \\ \int_{-\infty}^{+\infty} f(x)g(x)dx \leq \sqrt{\int_{-\infty}^{+\infty} |f(x)|^2 dx} \sqrt{\int_{-\infty}^{+\infty} |g(x)|^2 dx} \end{cases} \quad (44)$$

Remark 3.2 施瓦尔兹不等式可以类比于常规三维空间中的点积计算。在空间解析几何中, 一般向量的点积公式为 $a \cdot b \leq |a||b|$ 。这里, a, b 是常规三维空间中任意两个向量。

对于确定性标量估计情况, $\Lambda(x) = f(z|x)$ 。因为

$$E[\hat{x}(z) - x] = \int_{-\infty}^{+\infty} [\hat{x}(z) - x]f(z|x)dz = 0 \quad (45)$$

所以

$$\frac{d}{dx} \int_{-\infty}^{+\infty} [\hat{x}(z) - x]f(z|x)dz = 0 \quad (46)$$

于是

$$-\int_{-\infty}^{+\infty} f(z|x)dz + \int_{-\infty}^{+\infty} [\hat{x}(z) - x] \frac{\partial}{\partial x} f(z|x)dz = 0 \quad (47)$$

从而有

$$\int_{-\infty}^{+\infty} [\hat{x}(z) - x] \frac{\partial \ln f(z|x)}{\partial x} f(z|x)dz = 1 \quad (48)$$

由施瓦尔兹不等式可知

$$\int_{-\infty}^{+\infty} [\hat{x}(z) - x]^2 f(z|x) dz \int_{-\infty}^{+\infty} \left[\frac{\partial \ln f(z|x)}{\partial x} \right]^2 f(z|x) dz \geq 1 \quad (49)$$

即

$$P_{\hat{x}} \geq \left\{ E \left[\frac{\partial \ln f(z|x)}{\partial x} \right]^2 \right\}^{-1} \quad (50)$$

又根据 $\int_{-\infty}^{+\infty} f(z|x) dz = 1$ ，可知

$$\int_{-\infty}^{+\infty} \frac{\partial \ln f(z|x)}{\partial x} f(z|x) dz = 0 \quad (51)$$

可化为

$$\int_{-\infty}^{+\infty} \frac{\partial^2 \ln f(z|x)}{\partial x^2} f(z|x) dz = - \int_{-\infty}^{+\infty} \left[\frac{\partial \ln f(z|x)}{\partial x} \right]^2 f(z|x) dz \quad (52)$$

因此有

$$E\left[\frac{\partial^2 \ln f(z|x)}{\partial x^2}\right] = -E\left\{\left[\frac{\partial \ln f(z|x)}{\partial x}\right]^2\right\} \quad (53)$$

到此完成了标量情况下定理3.3 的证明。

- Remark 3.3**
- 似然函数比后验概率要容易获得；
 - 极大似然估计中，被估计量 x 可以是随机变量，也可以是非随机参数；
 - 当有先验信息时，极大似然估计的精度不如最大后验估计；
 - 对于确定性未知量 x ，随着量测样本数 N 增加 ($N \rightarrow +\infty$)， \hat{x}_{ML} 依概率收敛于真值 x ；(任何具有该性质的估计称为**一致的**)
 - 极大似然估计是渐进高斯的，即当 $N \rightarrow +\infty$ ， $\hat{x}_{ML} \sim \mathcal{N}(x, P_{\hat{x}})$ ；
 - 当 $N \rightarrow +\infty$ ，极大似然估计 \hat{x}_{ML} 是**有效的** (估计误差协方差达到克拉默-拉奥下界)。

4. 最小二乘估计

设 \boldsymbol{x} 是未知的常值向量，考虑线性量测

$$\boldsymbol{z} = H\boldsymbol{x} + \boldsymbol{v} \quad (54)$$

其中， \boldsymbol{v} 为量测误差或噪声。我们的问题是基于 \boldsymbol{z} 求 \boldsymbol{x} 的最佳估计 $\hat{\boldsymbol{x}}$ 。

4.1 基本最小二乘估计

Definition 4.1 使指标函数

$$J(\hat{x}) = (z - H\hat{x})^T(z - H\hat{x}) \Rightarrow \min \quad (55)$$

的估计 \hat{x} 称为 x 的最小二乘估计, 记为 $\hat{x}_{LS}(z)$ 。

Theorem 4.1 (1) 当 $H^T H$ 非奇异时, $\hat{x}_{LS}(z) = (H^T H)^{-1} H^T z$ 。

(2) 若 v 为零均值噪声, 那么 $E\tilde{x}_{LS}(z) = 0$ 。

Proof 4.1 由

$$\frac{\partial J(\hat{\boldsymbol{x}})}{\partial \hat{\boldsymbol{x}}} = -2H^T(\boldsymbol{z} - H\hat{\boldsymbol{x}}) = 0 \quad (56)$$

可知

$$H^T H \hat{\boldsymbol{x}} = H^T \boldsymbol{z} \quad (57)$$

$H^T H$ 是方阵，如果非奇异，则

$$\hat{\boldsymbol{x}}_{LS}(\boldsymbol{z}) = (H^T H)^{-1} H^T \boldsymbol{z} \quad (58)$$

$H^T H$ 非奇异保证了 $J(\hat{\boldsymbol{x}})$ 关于 $\hat{\boldsymbol{x}}$ 的二阶导数矩阵非负定，说明上式的确是最优解。

将 (54) 代入 (58), 得

$$\hat{\boldsymbol{x}}_{LS}(\boldsymbol{z}) = \boldsymbol{x} + (H^T H)^{-1} H^T \boldsymbol{v}$$

如果 $E\boldsymbol{v} = 0$, 则

$$E\hat{\boldsymbol{x}}_{LS}(\boldsymbol{z}) = \boldsymbol{x}$$

即

$$E\tilde{\boldsymbol{x}}_{LS}(\boldsymbol{z}) = 0$$

Example 4.1 用万用表对未知阻值的电阻进行 k 次测量, 根据含噪声的 k 个测量 $z_i (i = 1, 2, \dots, k)$ 对电阻值 x 进行估计。此时, x 是一个标量, k 个含噪声的测量值如下:

$$z_1 = x + v_1$$

$$\vdots$$

$$z_k = x + v_k$$

写成矩阵方程形式

$$\begin{bmatrix} z_1 \\ \vdots \\ z_k \end{bmatrix} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} x + \begin{bmatrix} v_1 \\ \vdots \\ v_k \end{bmatrix}$$

由 (58) 可得电阻值 x 的最小二乘估计为

$$\begin{aligned}\hat{x}_{LS}(\mathbf{z}) &= (H^T H)^{-1} H^T \mathbf{z} = ([1 \cdots 1] \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix})^{-1} [1 \cdots 1] \begin{bmatrix} z_1 \\ \vdots \\ z_k \end{bmatrix} \\ &= \frac{1}{k} (z_1 + z_2 + \cdots + z_k)\end{aligned}$$

□

4.2 加权最小二乘估计

Definition 4.2 设 W 是正定对称方阵, 使指标函数

$$J(\hat{x}) = (z - H\hat{x})^T W (z - H\hat{x})$$

最小的估计 \hat{x} 称为 x 的加权最小二乘估计, 记为 $\hat{x}_{WLS}(z)$ 。

Theorem 4.2 当 $H^T W H$ 非奇异时

$$\hat{x}_{WLS}(z) = (H^T W H)^{-1} H^T W z \quad (59)$$

若 v 为零均值噪声, $\hat{x}_{WLS}(z)$ 是 x 的无偏估计。如果进一步假设 $R = E[vv^T]$, 那么

$$P_{\hat{x}_{WLS}} = (H^T W H)^{-1} H^T W R W H (H^T W H)^{-1} \quad (60)$$

Theorem 4.3 (Markov 估计) 设 $v \sim \mathcal{N}(0, R)$ ($R > 0$), 取 $W = R^{-1}$, 那么

$$\hat{x}_{WLS}(z) = (H^T R^{-1} H)^{-1} H^T R^{-1} z \quad (61)$$

而且此时估计的均方误差最小,

$$P_{\hat{x}_{WLS}} = (H^T R^{-1} H)^{-1} \quad (62)$$

Proof 4.2 将 $W = R^{-1}$ 带入一般的加权最小二乘估计 (59), 即可得到 (61)。同时由 (61) 可导出 (62)。此外, 根据线性量测高斯分布情况下的线性最小方差估计定理, 可知

$$\hat{x}_L = P_{\tilde{x}_L} (P_x^{-1} \bar{x} + H^T R^{-1} z) \quad (63)$$

$$P_{\tilde{x}_L}^{-1} = P_x^{-1} + H^T R^{-1} H \quad (64)$$

在最小二乘估计中, 认为没有 x 的先验信息 ($P_x^{-1} = 0$), 所以此时的最小方差估计为

$$\hat{x}_L = P_{\tilde{x}_{LMV}} H^T R^{-1} z$$
$$P_{\tilde{x}_L}^{-1} = H^T R^{-1} H$$

与 (61)、(62) 是一致的, 即说明了此时的加权最小二乘估计的均方误差最小。

Example 4.2 在例题4.1中, 假设 $v_i \sim \mathcal{N}(0, \sigma_i^2) (i = 1, \dots, k)$, 同时认为每次测量是独立进行的, 即

$$R = \text{diag}(\sigma_1^2, \dots, \sigma_k^2)$$

此时电阻值的最优估计为

$$\begin{aligned} \hat{x}_{WLS}(z) &= (H^T R^{-1} H)^{-1} H^T R^{-1} z \\ &= ([1 \cdots 1] \begin{bmatrix} \sigma_1^2 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_k^2 \end{bmatrix}^{-1} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix})^{-1} [1 \cdots 1] \begin{bmatrix} \sigma_1^2 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_k^2 \end{bmatrix}^{-1} \begin{bmatrix} z_1 \\ \vdots \\ z_k \end{bmatrix} \\ &= \frac{1}{\sum_{i=1}^k 1/\sigma_i^2} \left(\frac{z_1}{\sigma_1^2} + \frac{z_2}{\sigma_2^2} + \cdots + \frac{z_k}{\sigma_k^2} \right) \end{aligned} \quad (65)$$

可见每次的测量精度作为权重进入了最后的估计, 当 $\sigma_i^2 = \sigma^2$ (每次测量精度相同), 则退化为例题4.1了。

4.3 递推最小二乘估计

假设我们已经获得了 k 时刻的最小二乘估计, 即由

$$\mathbf{z}_k = H_k \mathbf{x} + \mathbf{v}_k \quad (66)$$

得到了加权最小二乘估计

$$P_k = (H_k^T W_k H_k)^{-1} \quad (67)$$

$$\hat{\mathbf{x}}_k = P_k H_k^T W_k \mathbf{z}_k \quad (68)$$

如果现在又获得了 $k+1$ 时刻的量测, 即

$$z_{k+1} = h_{k+1} \mathbf{x} + v_{k+1} \quad (69)$$

注意, 一般情况下这仍然是一个向量形式的测量方程。

综合考虑 (66) 和 (69), 加权最小二乘意味着

$$\left(\begin{bmatrix} z_k \\ z_{k+1} \end{bmatrix} - \begin{bmatrix} H_k \\ h_{k+1} \end{bmatrix} \hat{\mathbf{x}}_{k+1} \right)^T \begin{bmatrix} W_k & 0 \\ 0 & w_{k+1} \end{bmatrix} \left(\begin{bmatrix} z_k \\ z_{k+1} \end{bmatrix} - \begin{bmatrix} H_k \\ h_{k+1} \end{bmatrix} \hat{\mathbf{x}}_{k+1} \right) \Rightarrow \min$$

即为

$$\begin{aligned} & (z_k - H_k \hat{\mathbf{x}}_{k+1})^T W_k (z_k - H_k \hat{\mathbf{x}}_{k+1}) \\ & + (z_{k+1} - h_{k+1} \hat{\mathbf{x}}_{k+1})^T w_{k+1} (z_{k+1} - h_{k+1} \hat{\mathbf{x}}_{k+1}) \Rightarrow \min \end{aligned}$$

由极值必要条件, 可得

$$\begin{aligned} & H_k^T W_k (z_k - H_k \hat{\mathbf{x}}_{k+1}) + h_{k+1}^T w_{k+1} (z_{k+1} - h_{k+1} \hat{\mathbf{x}}_{k+1}) = 0 \\ \Rightarrow & (H_k^T W_k H_k + h_{k+1}^T w_{k+1} h_{k+1}) \hat{\mathbf{x}}_{k+1} = H_k^T W_k z_k + h_{k+1}^T w_{k+1} z_{k+1} \end{aligned}$$

考虑到 (68), 上式可写为

$$(H_k^T W_k H_k + h_{k+1}^T w_{k+1} h_{k+1}) \hat{\mathbf{x}}_{k+1} = P_k^{-1} \hat{\mathbf{x}}_k + h_{k+1}^T w_{k+1} z_{k+1} \quad (70)$$

而由 (67) 可知

$$P_{k+1} = \left(\begin{bmatrix} H_k \\ h_{k+1} \end{bmatrix}^T \begin{bmatrix} W_k & 0 \\ 0 & w_{k+1} \end{bmatrix} \begin{bmatrix} H_k \\ h_{k+1} \end{bmatrix} \right)^{-1} = (H_k^T W_k H_k + h_{k+1}^T w_{k+1} h_{k+1})^{-1}$$

带入 (67), (70) 化为出

$$\hat{\mathbf{x}}_{k+1} = P_{k+1} (P_k^{-1} \hat{\mathbf{x}}_k + h_{k+1}^T w_{k+1} z_{k+1}) \quad (71)$$

其中

$$P_{k+1} = (P_k^{-1} + h_{k+1}^T w_{k+1} h_{k+1})^{-1} \quad (72)$$

式 (71) 和式 (72) 一起构成了递推最小二乘估计。

如果知道 $v_{k+1} \sim \mathcal{N}(0, R_{k+1})$, 可以取 $w_{k+1} = R_{k+1}^{-1}$, 此时递推最小二乘估计算法公式为

$$\hat{\mathbf{x}}_{k+1} = P_{k+1}(P_k^{-1}\hat{\mathbf{x}}_k + h_{k+1}^T R_{k+1}^{-1} z_{k+1}) \quad (73)$$

$$P_{k+1}^{-1} = P_k^{-1} + h_{k+1}^T R_{k+1}^{-1} h_{k+1} \quad (74)$$

递推最小二乘估计也有其他等价形式, 例如由 (74) 可知

$$P_{k+1} P_k^{-1} = I - P_{k+1} h_{k+1}^T R_{k+1}^{-1} h_{k+1} \quad (75)$$

代入 (71), 可得如下结构的递推最小二乘估计

$$\hat{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_k + K_{k+1}[z_{k+1} - h_{k+1}\hat{\mathbf{x}}_k] \quad (76)$$

其中

$$K_{k+1} = P_{k+1} h_{k+1}^T R_{k+1}^{-1} \quad (77)$$

由矩阵求逆引理, (72) 可以化为

$$P_{k+1} = P_k - P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} h_{k+1} P_k \quad (78)$$

这样可以减小递推计算量。(76)、(77) 和 (78) 构成了一组完整的递推算法。

由 (77), 可得

$$P_{k+1}h_{k+1}^T = K_{k+1}R_{k+1} \quad (79)$$

由 (78) 可知

$$\begin{aligned} P_{k+1}h_{k+1}^T &= P_k h_{k+1}^T - P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} h_{k+1} P_k h_{k+1}^T \\ &= P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} [(R_{k+1} + h_{k+1} P_k h_{k+1}^T) - h_{k+1} P_k h_{k+1}^T] \\ &= P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} R_{k+1} \end{aligned}$$

比较 (77), 可得 K_{k+1} 的另外一个计算公式

$$K_{k+1} = P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} \quad (80)$$

代入 (78), 可得

$$P_{k+1} = (I - K_{k+1}h_{k+1})P_k \quad (81)$$

(76)、(80) 和 (81) 是另外一组常见的递推公式, 汇总如下:

$$\begin{aligned}\hat{\boldsymbol{x}}_{k+1} &= \hat{\boldsymbol{x}}_k + K_{k+1}[z_{k+1} - h_{k+1}\hat{\boldsymbol{x}}_k] \\ K_{k+1} &= P_k h_{k+1}^T (R_{k+1} + h_{k+1} P_k h_{k+1}^T)^{-1} \\ P_{k+1} &= (I - K_{k+1}h_{k+1})P_k\end{aligned}$$

Example 4.3 仍然考虑例题4.1中的问题, 即用万用表对未知阻值的电阻进行测量, 这里用递推最小二乘估计来求解。 k 时刻的量测方程为

$$z_k = x + v_k$$

假设 $v_k \sim (0, R_k)$, $R_k = R$ 。本问题中 $h_{k+1} = 1$ 。

$k = 0$: (给定 \hat{x}_0, P_0)

$$K_1 = \frac{P_0}{R + P_0}, \quad P_1 = (1 - K_1)P_0 = \frac{RP_0}{R + P_0}$$

$$\hat{x}_1 = \hat{x}_0 + K_1(z_1 - \hat{x}_0) = (1 - K_1)\hat{x}_0 + K_1z_1 = \frac{R}{R + P_0}\hat{x}_0 + \frac{P_0}{R + P_0}z_1$$

$k = 1$:

$$K_2 = \frac{P_1}{R + P_1} = \frac{P_0}{R + 2P_0}, \quad P_2 = (1 - K_2)P_1 = \frac{RP_0}{R + 2P_0}$$

$$\hat{x}_2 = \hat{x}_1 + K_2(z_2 - \hat{x}_1) = \frac{R + P_0}{R + 2P_0}\hat{x}_1 + \frac{P_0}{R + 2P_0}z_2$$

一般地 $k \geq 1$:

$$K_k = \frac{P_{k-1}}{R + P_{k-1}} = \frac{P_0}{R + kP_0}, \quad P_k = \frac{RP_0}{R + kP_0}$$

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

$$= \frac{R + (k-1)P_0}{R + kP_0}\hat{x}_{k-1} + \frac{P_0}{R + kP_0}z_k$$

我们分三种初始条件进行讨论：

$$(1) \hat{x}_0 = \bar{x}_0, P_0 = 0$$

$$K_k = 0: \hat{x}_k = \hat{x}_{k-1} = \cdots = \bar{x}_0$$

说明无需量测。

$$(2) R = +\infty。$$

$$K_k = 0: \hat{x}_k = \hat{x}_{k-1} = \cdots = \bar{x}_0$$

说明量测不能带来任何有意义信息。

$$(3) \hat{x}_0 = \bar{x}_0, P_0 = +\infty。$$

$$K_k = \frac{1}{k} : \hat{x}_k = \frac{k-1}{k} \hat{x}_{k-1} + \frac{1}{k} z_k = \frac{1}{k} [(k-1) \hat{x}_{k-1} + z_k]$$

说明电阻值的最优估计就是量测值的几何平均, 即

$$\hat{x}_k = \frac{1}{k} \sum_{i=1}^k z_i = \frac{1}{k} [(k-1) \frac{1}{k-1} \sum_{i=1}^{k-1} z_i + z_k] = \frac{1}{k} [(k-1) \hat{x}_{k-1} + z_k]$$

- Remark 4.1**
- 最小二乘估计不需要任何统计信息，但精度较低，适用于确定量或变化规律确定的量之估计。
 - 在递推最小二乘估计中，初始估计 \hat{x}_0 可取为零向量、初始 P_0 矩阵可取为元素足够大的对角线阵。若干步后，初值的影响就会逐渐消失。
 - 滑动窗技术与遗忘因子法是工程中有效的改进算法。

5. 『经典参数估计与融合估计算法』

在经典估计理论中，一般考虑如下量测方程：

$$\boldsymbol{z} = H\boldsymbol{x} + \boldsymbol{v} \quad (82)$$

其中， $\boldsymbol{z} \in \mathbb{R}^N$ ， $\boldsymbol{x} \in \mathbb{R}^n$ ， $H \in \mathbb{R}^{N \times n}$ ， $\boldsymbol{v} \in \mathbb{R}^N \sim \mathcal{N}(0, R)$ 。此外， $R \in \mathbb{R}^{N \times N}$ 。估计问题就是基于量测 \boldsymbol{z} ，对未知量 \boldsymbol{x} 进行推断。

5.1 最小二乘估计

取权重矩阵为 $W = R^{-1}$, (加权) 最小二乘估计 意味着

$$J = \frac{1}{2} \|z - H\mathbf{x}\|_{R^{-1}}^2 = \frac{1}{2} (z - H\mathbf{x})^T R^{-1} (z - H\mathbf{x}) \Rightarrow \min$$

由此可得

$$\hat{\mathbf{x}}_{LMS} = (H^T R^{-1} H)^{-1} H^T R^{-1} z$$

估计误差为

$$\begin{aligned} \tilde{\mathbf{x}}_{LMS} &= \hat{\mathbf{x}}_{LMS} - \mathbf{x} = (H^T R^{-1} H)^{-1} H^T R^{-1} (H\mathbf{x} + \mathbf{v}) - \mathbf{x} \\ &= (H^T R^{-1} H)^{-1} H^T R^{-1} \mathbf{v} \end{aligned}$$

根据量测噪声 \boldsymbol{v} 的性质, 易知

$$E\tilde{\boldsymbol{x}}_{LMS} = 0, \quad P_{\tilde{\boldsymbol{x}}_{LMS}} = E[\tilde{\boldsymbol{x}}_{LMS}(\tilde{\boldsymbol{x}}_{LMS})^T] = (H^T R^{-1} H)^{-1}$$

对于确定性未知量 \boldsymbol{x} , 有

$$E\hat{\boldsymbol{x}}_{LMS} = \boldsymbol{x}, \quad P_{\hat{\boldsymbol{x}}_{LMS}} = E(\hat{\boldsymbol{x}}_{LMS} - \boldsymbol{x})(\hat{\boldsymbol{x}}_{LMS} - \boldsymbol{x})^T = (H^T R^{-1} H)^{-1} = P_{\tilde{\boldsymbol{x}}_{LMS}}$$

所以, 最小二乘估计可以表示为

$$\begin{cases} \hat{\boldsymbol{x}}_{LMS} = (H^T R^{-1} H)^{-1} H^T R^{-1} \boldsymbol{z} \\ P_{\hat{\boldsymbol{x}}_{LMS}} = (H^T R^{-1} H)^{-1} \end{cases} \quad (83)$$

5.2 极大似然估计

而极大似然估计是指

$$f_{z|x}(z|x) \Rightarrow \max \quad \text{或} \quad \ln f_{z|x}(z|x) \Rightarrow \max$$

对于系统 (82), 注意到给定 \mathbf{x} 时 $\mathbf{z} \sim \mathcal{N}(H\mathbf{x}, R)$, 上述极值问题变为

$$J = \frac{1}{2}(\mathbf{z} - H\mathbf{x})^T R^{-1}(\mathbf{z} - H\mathbf{x}) \Rightarrow \min$$

由此可得

$$\begin{cases} \hat{\mathbf{x}}_{ML} = (H^T R^{-1} H)^{-1} H^T R^{-1} \mathbf{z} \\ P_{\hat{\mathbf{x}}_{ML}} = (H^T R^{-1} H)^{-1} \end{cases} \quad (84)$$

不难发现, 极大似然估计和最小二乘估计是一致的。

5.3 最大后验估计

最大后验估计 的出发点是

$$\ln f_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) \Rightarrow \max$$

考虑到贝叶斯公式 $f_{\mathbf{x}|\mathbf{z}}(\mathbf{x}|\mathbf{z}) = \frac{f_{\mathbf{z}|\mathbf{x}}(\mathbf{z}|\mathbf{x})f_{\mathbf{x}}(\mathbf{x})}{f_{\mathbf{z}}(\mathbf{z})}$, 如果 $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, P_x)$, 而且与 \mathbf{v} 无关, 极大似然估计意指

$$J = \frac{1}{2}(\mathbf{z} - H\mathbf{x})^T R^{-1}(\mathbf{z} - H\mathbf{x}) + \frac{1}{2}(\mathbf{x} - \bar{\mathbf{x}})^T P_x^{-1}(\mathbf{x} - \bar{\mathbf{x}}) \Rightarrow \min$$

由 $\frac{\partial J}{\partial \mathbf{x}}|_{\hat{\mathbf{x}}} = 0$, 可得

$$\begin{aligned} -H^T R^{-1}(\mathbf{z} - H\hat{\mathbf{x}}) + P_x^{-1}(\hat{\mathbf{x}} - \bar{\mathbf{x}}) &= 0 \\ H^T R^{-1} H \hat{\mathbf{x}} + P_x^{-1} \hat{\mathbf{x}} &= P_x^{-1} \bar{\mathbf{x}} + H^T R^{-1} \mathbf{z} \end{aligned}$$

即

$$\hat{\boldsymbol{x}}_{MA} = (H^T R^{-1} H + P_x^{-1})^{-1} (P_x^{-1} \bar{\boldsymbol{x}} + H^T R^{-1} \boldsymbol{z})$$

同时可以容易验证最大后验估计的无偏性, $E\hat{\boldsymbol{x}}_{MA} = \bar{\boldsymbol{x}}$ 。此外

$$\begin{aligned}\tilde{\boldsymbol{x}}_{MA} &= \hat{\boldsymbol{x}}_{MA} - \boldsymbol{x} \\ &= (H^T R^{-1} H + P_x^{-1})^{-1} [P_x^{-1} \bar{\boldsymbol{x}} + H^T R^{-1} \boldsymbol{z} - (H^T R^{-1} H + P_x^{-1}) \boldsymbol{x}] \\ &= (H^T R^{-1} H + P_x^{-1})^{-1} [H^T R^{-1} \boldsymbol{v} - P_x^{-1} \dot{\boldsymbol{x}}]\end{aligned}$$

由此, 可得

$$\begin{aligned}P_{\tilde{\boldsymbol{x}}_{MA}} &= E\tilde{\boldsymbol{x}}_{MA}\tilde{\boldsymbol{x}}_{MA}^T \\ &= (H^T R^{-1} H + P_x^{-1})^{-1} [H^T R^{-1} H + P_x^{-1}] (H^T R^{-1} H + P_x^{-1})^{-1} \\ &= (H^T R^{-1} H + P_x^{-1})^{-1}\end{aligned}$$

总结起来，最大后验估计即为

$$\begin{cases} \hat{\mathbf{x}}_{MA} = P_{\tilde{\mathbf{x}}_{MA}}(P_x^{-1}\bar{\mathbf{x}} + H^T R^{-1}\mathbf{z}) \\ P_{\tilde{\mathbf{x}}_{MA}} = (H^T R^{-1}H + P_x^{-1})^{-1} \end{cases} \quad (85)$$

当无先验信息时， $P_x^{-1} = 0$ 。可见，此时最大后验估计与最小二乘估计、极大似然估计都是一致的。

5.4 最小方差估计

对于线性量测系统 (82), 最小方差估计即为线性最小方差估计。假设 $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, P_x)$, 且与 $\mathbf{v} \sim \mathcal{N}(0, R)$ 无关。因为 $\hat{\mathbf{x}}_{MV} = \bar{\mathbf{x}} + P_{xz}P_z^{-1}(\mathbf{z} - \bar{\mathbf{z}})$, 注意到

$$\bar{\mathbf{z}} = H\bar{\mathbf{x}}$$

$$P_z = E\dot{\mathbf{z}}\dot{\mathbf{z}}^T = E(H\dot{\mathbf{x}} + \mathbf{v})(H\dot{\mathbf{x}} + \mathbf{v})^T = HP_xH^T + R$$

$$P_{xz} = E\dot{\mathbf{x}}\dot{\mathbf{z}}^T = E\dot{\mathbf{x}}(H\dot{\mathbf{x}} + \mathbf{v})^T = P_xH^T$$

所以

$$\hat{\mathbf{x}}_{MV} = \bar{\mathbf{x}} + P_xH^T(HP_xH^T + R)^{-1}(\mathbf{z} - H\bar{\mathbf{x}}) \quad (86)$$

$$P_{\tilde{x}_{MV}} = P_x - P_{xz}P_z^{-1}P_{zx} = P_x - P_xH^T(HP_xH^T + R)^{-1}HP_x \quad (87)$$

应用矩阵求逆引理，式 (87) 可化为

$$P_{\tilde{x}_{MV}} = (P_x^{-1} + H^TR^{-1}H)^{-1} \quad (88)$$

另外，式 (86) 可以化为

$$\hat{\mathbf{x}}_{MV} = [I - P_xH^T(HP_xH^T + R)^{-1}H]\bar{\mathbf{x}} + P_xH^T(HP_xH^T + R)^{-1}\mathbf{z}$$

注意到

$$\left\{ \begin{aligned} & [I - P_x H^T = (HP_x H^T + R)^{-1} H] \\ & = [P_x - P_x H^T (HP_x H^T + R)^{-1} H P_x] P_x^{-1} \\ & = (P_x^{-1} + H^T R^{-1} H)^{-1} P_x^{-1} \\ & P_x H^T (HP_x H^T + R)^{-1} \\ & = (**)^{-1} \underbrace{(P_x^{-1} + H^T R^{-1} H)}_{**} P_x H^T (HP_x H^T + R)^{-1} \\ & = (P_x^{-1} + H^T R^{-1} H)^{-1} H^T R^{-1} \end{aligned} \right.$$

因此，有

$$\hat{\mathbf{x}}_{MV} = (P_x^{-1} + H^T R^{-1} H)^{-1} (P_x^{-1} \bar{\mathbf{x}} + H^T R^{-1} \mathbf{z}) = \hat{\mathbf{x}}_{MA} \quad (89)$$

上述讨论表明，对于系统 (82)，最小方差估计与最大后验估计是一致的。

5.5 融合估计

下面基于上面介绍的理论基础，讨论融合估计的思想和方法。对于未知的 \boldsymbol{x} ，设独立地获得了两个估计： $(\hat{\boldsymbol{x}}_1, P_1)$ 和 $(\hat{\boldsymbol{x}}_2, P_2)$ 。可以认为

$$\begin{cases} \hat{\boldsymbol{x}}_1 = \boldsymbol{x} + \boldsymbol{v}_1, & \boldsymbol{v}_1 \sim \mathcal{N}(0, P_1) \\ \hat{\boldsymbol{x}}_2 = \boldsymbol{x} + \boldsymbol{v}_2, & \boldsymbol{v}_2 \sim \mathcal{N}(0, P_2) \end{cases}$$

即

$$\begin{bmatrix} \hat{\boldsymbol{x}}_1 \\ \hat{\boldsymbol{x}}_2 \end{bmatrix} = \begin{bmatrix} I_n \\ I_n \end{bmatrix} \boldsymbol{x} + \begin{bmatrix} \boldsymbol{v}_1 \\ \boldsymbol{v}_2 \end{bmatrix}$$

引入符号

$$\mathcal{H} = \begin{bmatrix} I_n \\ I_n \end{bmatrix}, \mathcal{V} = \begin{bmatrix} \mathbf{v}_1 \\ \mathbf{v}_2 \end{bmatrix}, E\mathcal{V} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}, E\mathcal{V}\mathcal{V}^T \triangleq \mathcal{R} = \begin{bmatrix} P_1 & 0 \\ 0 & P_2 \end{bmatrix}$$

注意到

$$\mathcal{H}^T \mathcal{R}^{-1} = [I_n, I_n] \begin{bmatrix} P_1^{-1} & 0 \\ 0 & P_2^{-1} \end{bmatrix} = [P_1^{-1}, P_2^{-1}],$$

$$\mathcal{H}^T \mathcal{R}^{-1} \begin{bmatrix} \hat{\mathbf{x}}_1 \\ \hat{\mathbf{x}}_2 \end{bmatrix} = P_1^{-1} \hat{\mathbf{x}}_1 + P_2^{-1} \hat{\mathbf{x}}_2, (\mathcal{H}^T \mathcal{R}^{-1} \mathcal{H})^{-1} = (P_1^{-1} + P_2^{-1})^{-1}$$

由最小二乘估计可知

$$\begin{aligned}\hat{\boldsymbol{x}} &= (P_1^{-1} + P_2^{-1})^{-1}(P_1^{-1}\hat{\boldsymbol{x}}_1 + P_2^{-1}\hat{\boldsymbol{x}}_2) \\ P &= E(\hat{\boldsymbol{x}}_1 - \boldsymbol{x})(\hat{\boldsymbol{x}}_1 - \boldsymbol{x})^T = (P_1^{-1} + P_2^{-1})^{-1}\end{aligned}$$

上述结论可以总结为如下定理。

Theorem 5.1 如果对于 \boldsymbol{x} 有两个独立的最优估计 $(\hat{\boldsymbol{x}}_1, P_1)$ 和 $(\hat{\boldsymbol{x}}_2, P_2)$, 那么融合后的最优估计为

$$\begin{cases} P^{-1} = P_1^{-1} + P_2^{-1} \\ \hat{\boldsymbol{x}} = P(P_1^{-1}\hat{\boldsymbol{x}}_1 + P_2^{-1}\hat{\boldsymbol{x}}_2) \end{cases} \quad (90)$$

Example 5.1 已知 $(\hat{x}_1 = 1, P_1 = 0.1)$, $(\hat{x}_2 = 2, P_2 = 0.5)$, 求融合估计 \hat{x} 。

Solution 5.1 因为 $P^{-1} = P_1^{-1} + P_2^{-1} = 10 + 2 = 12$, 所以

$$\hat{x} = P(P_1^{-1}(\hat{x}_1 + P_2^{-1}\hat{x}_2)) = \frac{1}{12}(10\hat{x}_1 + 2\hat{x}_2) = \frac{10}{12} + \frac{4}{12} = \frac{14}{12} \approx 1.167$$

$$P = \frac{1}{12} \approx 0.083$$

Theorem 5.2 (最优融合估计) 如果对于 x 有 N 个相互独立的最优估计 $(\hat{x}_1, P_1), (\hat{x}_2, P_2), \dots, (\hat{x}_N, P_N)$ 。那么，融合后的最优估计为

$$\begin{cases} P^{-1} = \sum_{i=1}^N P_i^{-1} \\ \hat{x} = P \sum_{i=1}^N P_i^{-1} \hat{x}_i \end{cases} \quad (91)$$

算法 (91) 是集中式融合算法。可以容易地建立如下序贯式融合算法:

$$\begin{cases} P_{(k+1)}^{-1} = P_{(k)}^{-1} + P_{k+1}^{-1} \\ \hat{\boldsymbol{x}}_{(k+1)} = P_{(k+1)} [P_{(k)}^{-1} \hat{\boldsymbol{x}}_{(k)} + P_{k+1}^{-1} \hat{\boldsymbol{x}}_{k+1}] \end{cases} \quad (92)$$

在上述序贯式融合算法中, $(\hat{\boldsymbol{x}}_{(k)}, P_{(k)}^{-1})$ 表示前 k 个传感器的融合估计结果, $(\hat{\boldsymbol{x}}_{k+1}, P_{k+1}^{-1})$ 表示第 $k+1$ 个传感器的最优估计, $(\hat{\boldsymbol{x}}_{(k+1)}, P_{(k+1)}^{-1})$ 表示 $k+1$ 个传感器的融合估计结果。

5.6 融合估计的最优性

对于估计问题

$$\begin{cases} \mathbf{z} = H\mathbf{x} + \mathbf{v}, & \mathbf{v} \sim \mathcal{N}(0, R) \\ \mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, P_x) \end{cases}$$

可以看作

$$\begin{cases} \mathbf{z} = H\mathbf{x} + \mathbf{v}, & \mathbf{v} \sim \mathcal{N}(0, R) \\ \bar{\mathbf{x}} = \mathbf{x} + \boldsymbol{\epsilon}, & \boldsymbol{\epsilon} \sim \mathcal{N}(0, P_x) \end{cases}$$

可见，融合估计对应的优化问题为

$$J = \frac{1}{2}(\mathbf{z} - H\mathbf{x})^T R^{-1}(\mathbf{z} - H\mathbf{x}) + \frac{1}{2}(\mathbf{x} - \bar{\mathbf{x}})^T P_x^{-1}(\mathbf{x} - \bar{\mathbf{x}}) \Rightarrow \min$$

显然，这与最大后验估计是一致的。

5.7 融合估计的等价解算方法

对于未知的 \boldsymbol{x} ，基于两个独立估计 $(\hat{\boldsymbol{x}}_1, P_1)$ 和 $(\hat{\boldsymbol{x}}_2, P_2)$ 的综合估计假设为

$$\hat{\boldsymbol{x}} = K_1 \hat{\boldsymbol{x}}_1 + K_2 \hat{\boldsymbol{x}}_2$$

式中， K_1, K_2 是两个待定系数矩阵。根据估计的无偏性要求，可知 $K_1 + K_2 = I$ 。记 $K_1 = K$ ，那么 $K_2 = I - K$ 。因此 $\hat{\boldsymbol{x}} = K \hat{\boldsymbol{x}}_1 + (I - K) \hat{\boldsymbol{x}}_2$ ， $\tilde{\boldsymbol{x}} = \hat{\boldsymbol{x}} - \boldsymbol{x} = K \tilde{\boldsymbol{x}}_1 + (I - K) \tilde{\boldsymbol{x}}_2$ 。由此可得估计误差指标函数

$$J = E \|\tilde{\boldsymbol{x}}\|^2 = \text{tr}(E \tilde{\boldsymbol{x}} \tilde{\boldsymbol{x}}^T) = \text{tr}[K P_1 K^T + (I - K) P (I - K)^T]$$

由 $\frac{\partial J}{\partial K} = 0$, 可导出 $KP_1 - (I - K)P_2 = 0$, $K(P_1 + P_2) = P_2$ 。因此

$$\begin{cases} K = P_2(P_1 + P_2)^{-1} = (P_1^{-1} + P_2^{-1})^{-1}P_1^{-1} \\ I - K = I - (P_1^{-1} + P_2^{-1})^{-1}P_1^{-1} = (P_1^{-1} + P_2^{-1})^{-1}P_2^{-1} \end{cases}$$

所以

$$\begin{cases} \hat{\mathbf{x}} = (P_1^{-1} + P_2^{-1})^{-1}(P_1^{-1}\hat{\mathbf{x}}_1 + P_2^{-1}\hat{\mathbf{x}}_2) \\ P = P_{\hat{\mathbf{x}}} = (P_1^{-1} + P_2^{-1})^{-1}(P_1^{-1} + P_2^{-1})(P_1^{-1} + P_2^{-1})^{-1} \end{cases}$$

即

$$\begin{cases} \hat{\mathbf{x}} = P(P_1^{-1}\hat{\mathbf{x}}_1 + P_2^{-1}\hat{\mathbf{x}}_2) \\ P^{-1} = P_1^{-1} + P_2^{-1} \end{cases} \quad (93)$$

5.8 融合估计与最小方差估计

对于参数估计问题

$$\mathbf{z} = H\mathbf{x} + \mathbf{v}, \quad \mathbf{v} \sim \mathcal{N}(0, R)$$

我们首先可以容易地获得最小二乘估计（或极大似然估计）

$$\begin{cases} \hat{\mathbf{x}}_1 = (H^T R^{-1} H)^{-1} H^T R^{-1} \mathbf{z} \\ P_1 = (H^T R^{-1} H)^{-1} \end{cases} \quad (94)$$

如果我们有关于 \mathbf{x} 的先验知识，即 $\mathbf{x} \sim \mathcal{N}(\bar{\mathbf{x}}, P_x)$ ，可以认为是获得了如下估计：

$$\begin{cases} \hat{\mathbf{x}}_2 = \bar{\mathbf{x}} \\ P_2 = P_x \end{cases} \quad (95)$$

根据融合估计定理5.1, 将估计 (94) 和 (95) 融合可得

$$\begin{cases} P^{-1} = P_x^{-1} + (H^T R^{-1} H)^{-1} \\ \hat{\mathbf{x}} = P(P_x^{-1} \bar{\mathbf{x}} + H^T R^{-1} \mathbf{z}) \end{cases} \quad (96)$$

注意到最小方差估计 (88)、(89), 即

$$\begin{cases} P_{\hat{\mathbf{x}}_{MV}} = (P_x^{-1} + H^T R^{-1} H)^{-1} \\ \hat{\mathbf{x}}_{MV} = (P_x^{-1} + H^T R^{-1} H)^{-1}(P_x^{-1} \bar{\mathbf{x}} + H^T R^{-1} \mathbf{z}) \end{cases} \quad (97)$$

比较 (96) 和 (97), 不难发现两者是一致的, 这进一步说明了上面介绍的融合估计算法的最优性。

5.9 递推最小二乘估计

假设 k 时刻已经获得了估计 $(\hat{\boldsymbol{x}}_k, P_k)$ 。由 $k+1$ 时刻的量测

$$\boldsymbol{z}_{k+1} = H_{k+1}\boldsymbol{x} + \boldsymbol{v}_{k+1}$$

可以获得一个附加的估计（最小二乘估计）

$$\begin{cases} \hat{\boldsymbol{x}}_a = (H_{k+1}^T w_{k+1} H_{k+1})^{-1} H_{k+1}^T w_{k+1} \boldsymbol{z}_{k+1} \\ P_a = (H_{k+1}^T w_{k+1} H_{k+1})^{-1} \end{cases}$$

对以上关于未知量 \boldsymbol{x} 的两个估计进行融合，可得

$$\begin{cases} \hat{\boldsymbol{x}}_{k+1} = P_{k+1}(P_k^{-1}\hat{\boldsymbol{x}}_k + P_a^{-1}\hat{\boldsymbol{x}}_a) \\ P_{k+1} = (P_k^{-1} + P_a^{-1})^{-1} \end{cases}$$

因而有

$$P_{k+1} = (P_k^{-1} + H_{k+1}^T w_{k+1} H_{k+1})^{-1} \quad (98)$$

同时

$$\begin{aligned} \hat{\mathbf{x}}_{k+1} &= P_{k+1} [(P_k^{-1} + P_a^{-1}) \hat{\mathbf{x}}_k + P_a^{-1} \hat{\mathbf{x}}_a - P_a^{-1} \hat{\mathbf{x}}_k] \\ &= \hat{\mathbf{x}}_k + P_{k+1} H_{k+1}^T w_{k+1} \mathbf{z}_{k+1} - P_{k+1} H_{k+1}^T w_{k+1} H_{k+1} \hat{\mathbf{x}}_k \end{aligned}$$

即

$$\hat{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_k + P_{k+1} H_{k+1}^T w_{k+1} (\mathbf{z}_{k+1} - H_{k+1} \hat{\mathbf{x}}_k) \quad (99)$$

式 (98) 和 (99) 便构成了递推最小二乘估计, 即

$$\begin{cases} \hat{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_k + P_{k+1} H_{k+1}^T w_{k+1} (\mathbf{z}_{k+1} - H_{k+1} \hat{\mathbf{x}}_k) \\ P_{k+1} = (P_k^{-1} + H_{k+1}^T w_{k+1} H_{k+1})^{-1} \end{cases} \quad (100)$$

Questions?