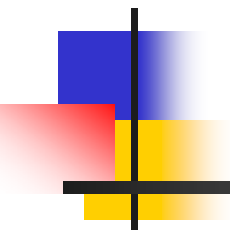


统计信号处理基础

—估计理论



杨文 电子信息学院
教学实验大楼十楼1008室
E-mail: yw@eis.whu.edu.cn



估计量总结

- 引言
- 经典估计方法
- 贝叶斯估计方法
- 线性模型
- 估计量的选择



引言

- 对于一个特定的应用，选择好的估计量与许多因素有关，最基本的考虑因素是选择一个好的数据模型，它的复杂性应该足以描述数据的基本特征，但是与此同时要简单得足以允许估计量是最佳的且易于实现。
- 对于信号处理问题，选择一个合适的估计量要从易于实现的最佳估计量开始。如果这种寻找没有效果，那么就应该考察准最佳估计量。



估计方法

- 在经典方法中，数据信息总结在概率密度函数 $p(x; \theta)$ 中，其中PDF是 θ 的函数。
- 在贝叶斯方法中，由于先验PDF $p(\theta)$ 描述了有关 θ 的知识而增加了数据的信息。数据信息总结在联合PDF $p(x, \theta)$ 中，或者等效地总结在条件PDF $p(x | \theta)$ (数据信息) 和先验PDF $p(\theta)$ 中（先验信息）中。



CRLB

经典估计方法

1. Cramer – Rao 下限 (CRLB)

a. 数据模型/假设

PDF $p(x; \theta)$ 是已知的。

b. 估计量

如果CRLB等号条件 $\frac{\partial \ln p(x; \theta)}{\partial \theta} = I(\theta)(g(x) - \theta)$ 满足，那么估计量

是 $\hat{\theta} = g(x)$ 。其中 $I(\theta)$ 是只与 θ 有关的 $p \times p$ 矩阵， $g(x)$ 是数据 x 的 p 维函数。

c. 最佳/误差准则

$\hat{\theta}$ 达到 **CRLB**, 即任何无偏估计量的方差的下限，因此也是最小方差无偏估计量 (MVU)。在所有无偏估计量中，MVU 估计量每个分量是最小的。



CRLB

d. 性能

它是无偏的且具有最小方差。

$$E(\hat{\theta}_i) = \theta_i, \text{var}(\hat{\theta}_i) = [I^{-1}(\theta)]_{ii}, i = 1, 2, \dots, p,$$

$$\text{其中} [I(\theta)]_{ij} = E \left[\frac{\partial \ln p(x; \theta)}{\partial \theta_i} \frac{\partial \ln p(x; \theta)}{\partial \theta_j} \right]$$

e. 说明

有效估计量可能不存在，因此这种方法可能失败。



RBLS

2. Rao – Blackwell – Lehmann – Scheffe

a. 数据模型/假设

PDF $p(x; \theta)$ 是已知的。

b. 估计量

i. 通过将PDF因式分解为 $p(x; \theta) = g(T(x), \theta)h(x)$ 来求出一个充分统计量 $T(x)$, 其中 $T(x)$ 是 x 的一个 p 维函数, g 只与 T 和 θ 有关, h 只与 x 有关。

ii. 如果 $E[T(x)] = \theta$, 那么 $\hat{\theta} = T(x)$; 如果不是, 我们必须求一个 p 维函数 g , 以便 $E[g(T)] = \theta$, 那么 $\hat{\theta} = g(T)$ 。



RBLS

c. 最佳/误差准则

$\hat{\theta}$ 是MVU估计量。

d. 性能

$\hat{\theta}_i (i = 1, 2, \dots, p)$ 是无偏的。方差与PDF有关—没有一般的公式。

e. 说明

另外，必须检查充分统计量的完备性， p 维的充分估计量可能不存在，因此这种方法可能失败。



BLUE

3.最佳线性无偏估计量 (BLUE)

a. 数据模型/假设

$$E(x) = H\theta$$

其中 H 是 $N \times p$ ($N > p$) 的已知矩阵, x 的协方差矩阵 C 是已知的, 等效地我们有 $x = H\theta + w$, 其中 $E(w) = 0$ 和 $C_w = C$ 。

b. 估计量

$$\hat{\theta} = (H^T C^{-1} H)^{-1} H^T C^{-1} x$$

c. 最佳/误差准则

$\hat{\theta}_i$ ($i = 1, 2, \dots, p$) 在所有的线性 (在 x 中) 无偏估计量中具有最小方差。



BLUE

d. 性能

$\hat{\theta}_i (i = 1, 2, \dots, p)$ 是无偏的。方差为

$$\text{var}(\hat{\theta}_i) = \left[\left(\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} \right)^{-1} \right]_{ii} \quad i = 1, 2, \dots, p$$

e. 说明

如果 \mathbf{w} 是高斯随机矢量，即 $\mathbf{w} \sim \mathbf{N}(0, \mathbf{C})$ ，那么 $\hat{\theta}$ 也是 *MVU* 估计量（对所有 \mathbf{x} 的线性和非线性函数的估计量）。



MLE

4.最大似然估计量 (MLE)

a. 数据模型/假设

PDF $p(x; \theta)$ 是已知的。

b. 估计量

$\hat{\theta}$ 是使 $p(x; \theta)$ 达到最大的值，其中 x 由观测数据样本代替。

c. 最佳/误差准则

一般来说没有最佳的估计量。然而在PDF一定的条件下，对于大数据记录或当 $N \rightarrow \infty$ 时（渐进），MLE是有效的。

因而它是渐进MVU估计量



MLE

d. 性能

对于有限的N, 性能与PDF有关, 没有一般的公式可用, 在一定条件下, 估计量渐进服从如下分布,

$$\hat{\theta}^a \sim N(\theta, I^{-1}(\theta))$$

e. 说明

如果有效估计量存在, 那么最大似然方法将得到有效估计量。



LSE

5.最小二乘估计量 (LSE)

a. 数据模型/假设

$$x[n] = s[n; \theta] + w[n] \quad n = 0, 1, \dots, N-1$$

其中信号 $s[n; \theta]$ 与未知参数有关，模型等效为 $x = s(\theta) + w$ ，其中 s 是已知的 θ 的 N 维函数，噪声或扰动 w 的均值为零。

b. 估计量

$\hat{\theta}$ 是使下式最小的 θ 值

$$J(\theta) = (x - s(\theta))^T (x - s(\theta)) = \sum_{n=0}^{N-1} (x[n] - s[n; \theta])^2$$



LSE

c. 最佳/误差准则

一般来说没有最佳的估计量。

d. 性能

性能与 w 的 PDF 有关，没有一般的公式可用

e. 说明

使 LS 误差最小一般来说不能转换成使估计误差最小。

另外，如果 w 是高斯随机矢量， $w \sim N(0, \sigma^2 I)$ ，那么
LSE等价于MLE

6.矩方法

a. 数据模型/假设

存在 p 阶矩 $\mu_i = E(x^i[n]) (i = 1, 2, \dots, p)$, p 阶矩以某种已知的方法与 θ 有关。整个PDF并不需要是已知的。

b. 估计量

如果 $\mu = h(\theta)$, 其中 h 是可逆的 θ 的 p 维函数, $\mu = [\mu_1 \quad \mu_2 \quad \dots \quad \mu_p]^T$, 那么: $\hat{\theta} = h^{-1}(\mu)$

其中

$$\hat{\mu} = \begin{bmatrix} \frac{1}{N} \sum_{n=0}^{N-1} x[n] \\ \frac{1}{N} \sum_{n=0}^{N-1} x^2[n] \\ \vdots \\ \frac{1}{N} \sum_{n=0}^{N-1} x^p[n] \end{bmatrix}$$



ME

c. 最佳/误差准则

一般来说没有最佳的估计量。

d. 性能

对于有限的N，性能与x的PDF有关。然而对于大的数据记录(渐进)，

如果 $\hat{\theta}_i = g_i(\hat{\mu})$, 那么 $E(\hat{\theta}_i) = g_i(\mu)$, $\text{var}(\hat{\theta}_i) = \frac{\partial g_i}{\partial \hat{\mu}} \Big|_{\hat{\mu}=\mu}^T C_{\hat{\mu}} \frac{\partial g_i}{\partial \hat{\mu}} \Big|_{\hat{\mu}=\mu}$, 其中

$$i = 1, 2, \dots, p$$

e. 说明

通常实现起来比较容易



MMSE

7.最小均方误差估计量 (MMSE)

a. 数据模型/假设

x 和 θ 的联合PDF即 $p(x, \theta)$ 是已知的, 其中 θ 为随机矢量。通常 $p(x | \theta)$ 作为数据模型而被指定, $p(\theta)$ 是 θ 的先验PDF, 所以 $p(x, \theta) = p(x | \theta)p(\theta)$

b. 估计量

$$\hat{\theta} = E(\theta | x)$$

其中数学期望是对后验PDF求取的 $p(\theta | x) = \frac{p(x | \theta)p(\theta)}{\int p(x | \theta)p(\theta)d\theta}$

如果 x 和 θ 是联合高斯的, 那么 $\hat{\theta} = E(\theta) + C_{\theta x} C_{xx}^{-1}(x - E(x))$



MMSE

c. 最佳/误差准则

$\hat{\theta}_i$ 使贝叶斯MSE最小, 即 $\text{Bmse}(\hat{\theta}_i) = E[(\theta_i - \hat{\theta}_i)^2]$, $i=1, 2, \dots, p$ 。其中数学期望是对 $p(x, \theta_i)$ 求的。

d. 性能

误差 $\varepsilon_i = \theta_i - \hat{\theta}_i$ 具有零均值和方差 $\text{var}(\varepsilon_i) = \text{Bmse}(\hat{\theta}_i) = \int [C_{\theta|x}]_{ii} p(x) dx$, 其中 $C_{\theta|x}$ 是在 x 条件下 θ 的协方差矩阵, 或者是后验PDF $p(\theta|x)$ 的协方差矩阵如果 x 和 θ 是联合高斯的, 那么误差是高斯的, 均值为零, 方差为

$$\text{var}(\varepsilon_i) = \text{Bmse}(\hat{\theta}_i) = [C_{\theta\theta} - C_{\theta x} C_{xx}^{-1} C_{x\theta}]_{ii}$$

e. 说明: 在非高斯情况下, 实现起来非常困难。



MAP

8.最大后验估计量 (MAP)

a. 数据模型/假设

与MMSE估计量相同。

b. 估计量

$\hat{\theta}$ 是使 $p(\theta | x)$ 达到最大的 θ 值, 或者等效地使 $p(x | \theta)p(\theta)$ 最大的 θ 值, 如果 x 和 θ 是联合高斯的, 那么 $\hat{\theta} = E(\theta) + C_{\theta x} C_{xx}^{-1}(x - E(x))$

c. 最佳/误差准则

使“成功—失败”代价函数最小。



MAP

d. 性能

性能与PDF有关，没有一般的公式可用，如果 x 和 θ 是联合高斯的，那么误差是高斯的，均值为零，方差为

$$\text{var}(\varepsilon_i) = \text{Bmse}(\hat{\theta}_i) = [C_{\theta\theta} - C_{\theta x} C_{xx}^{-1} C_{x\theta}]_{ii}$$

e. 说明

对于均值和众数（最大值的位置）相同的PDF，MMSE与MAP估计量是相同的，例如高斯PDF。



LMMSE

9. 线性最小均方误差估计量 (LMMSE)

a. 数据模型/假设

联合PDF即 $p(x, \theta)$ 的前二阶矩是已知的, 或者均值和协方差已知

$$\begin{bmatrix} E(\theta) \\ E(x) \end{bmatrix} \quad \begin{bmatrix} C_{\theta\theta} & C_{\theta x} \\ C_{x\theta} & C_{xx} \end{bmatrix}$$

b. 估计量

$$\hat{\theta} = E(\theta) + C_{\theta x} C_{xx}^{-1} (x - E(x))$$



LMMSE

c. 最佳/误差准则

$\hat{\theta}_i$ 在所有线性估计量中（ x 的线性函数）的贝叶斯MSE最小，
即 $\text{Bmse}(\hat{\theta}_i) = E[(\theta_i - \hat{\theta}_i)^2]$, $i=1, 2, \dots, p$ 。其中数学期望是对
 $p(x, \theta_i)$ 求的。

d. 性能

误差 $\varepsilon_i = \theta_i - \hat{\theta}_i$ 具有零均值和方差，

$$\text{var}(\varepsilon_i) = \text{Bmse}(\hat{\theta}_i) = [C_{\theta\theta} - C_{\theta x} C_{xx}^{-1} C_{x\theta}]_{ii}$$

e. 说明

如果 x 和 θ 是联合高斯的，那么性能与MMSE估计量和MAP估计量相同。



线性模型—经典方法

- 当可以应用线性模型来描述数据时，不同的估计方法产生闭合形式的估计量。通过假定线性模型，我们能够确定最佳估计量及其经典的和贝叶斯方法的性能。

经典的一般线性模型

$$x = H\theta + w$$

其中 x 是 $N \times 1$ 的观测矢量， H 是秩为 p 的已知 $N \times p$ ($N > p$)的观测矩阵， θ 是 $p \times 1$ 的待估计参数矢量， w 是一个 $N \times 1$ 的噪声矢量，PDF为 $N(0, C)$
 x 的PDF为

$$p(x; \theta) = \frac{1}{(2\pi)^{N/2} \det^{1/2}(C)} \exp\left[-\frac{1}{2}(x-H\theta)^T C^{-1}(x-H\theta)\right]$$



LM-CRLB

1. Cramer-Rao 下限

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

其中 $\hat{\boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{C}^{-1} \mathbf{x}$, 所以 $\hat{\boldsymbol{\theta}}$ 是 *MVU* 估计量, 且具有由协方差对角线元素给出的最小方差

$$\mathbf{C}_{\hat{\boldsymbol{\theta}}} = \mathbf{I}^{-1}(\boldsymbol{\theta}) = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})^{-1}。$$



LM-RBLS

2. Rao – Blackwell – Lehmann – Scheffe

PDF的因式分解为

$$p(x; \theta) = \underbrace{\frac{1}{(2\pi)^{N/2} \det^{1/2}(C)} \exp\left\{-\frac{1}{2}[(\theta - \hat{\theta})^T H^T C^{-1} H(\theta - \hat{\theta})]\right\}}_{g(T(x), \theta)} \cdot \underbrace{\exp\left\{-\frac{1}{2}[(x - H\hat{\theta})^T C^{-1}(x - H\hat{\theta})]\right\}}_{h(x)}$$

其中 $\hat{\theta} = (H^T C^{-1} H)^{-1} H^T C^{-1} x$, 充分统计量为 $T(x) = \hat{\theta}$, 可以证明它是无偏的和完备的。因此, $\hat{\theta}$ 是 *MVU* 估计量。



LM-BLUE

3. 最佳线性无偏估计量

由于 $\hat{\theta}$ 已经是 x 的线性函数，我们将有与前面两种情况相同的估计量。然而如果 w 不是高斯的， $\hat{\theta}$ 将仍然是 *BLUE*，但不是 *MVU* 估计量。注意对于 *BLUE*，一般线性模型是满足数据模型假定的。



LM-MLE

4.最大似然估计量

为求MLE, 使 $p(x; \theta) = \frac{1}{(2\pi)^{N/2} \det^{1/2}(C)} \exp\left[-\frac{1}{2}(x-H\theta)^T C^{-1}(x-H\theta)\right]$

所给出的 $p(x; \theta)$ 最大, 或者等价地使 $(x-H\theta)^T C^{-1}(x-H\theta)$ 最小, 于是得出 $\hat{\theta}=(H^T C^{-1}H)^{-1}H^T C^{-1}x$, 我们知道它是MVU估计量。这样, 正如我们希望的那样, 由于有效估计量存在 (满足CRLB), 那么最大似然方法就可以得到这个有效估计量。



LM-LSE

5.最小二乘估计量

把 $H\theta$ 看作为信号矢量 $s(\theta)$,我们必须使

$$J(\theta) = (x - s(\theta))^T (x - s(\theta)) = (x - H\theta)^T (x - H\theta)$$

最小, 当 $C = \sigma^2 I$ 时, 它与最大似然方法相同。 LSE 是 $\hat{\theta} = (H^T H)^{-1} H^T x$
如果 $C = \sigma^2 I$, 它也是 MVU 估计量。

如果 $C \neq \sigma^2 I$, 那么 $\hat{\theta}$ 将不是 MVU 估计量。然而, 如果我们使加权 LS 指标

$$J'(\theta) = (x - H\theta)^T W (x - H\theta)$$

最小, 其中加权矩阵是 C^{-1} , 那么得到的估计量是

$$\hat{\theta} = (H^T C^{-1} H)^{-1} H^T C^{-1} x, \text{ 它也是 } MVU \text{ 估计量。}$$

最后如果 w 不是高斯的, 加权 LSE 仍将由上式给出的 $\hat{\theta}$, 但是它可能只是 $BLUE$ 。

经典一般线性模型的性质

TABLE 14.1 Properties of $\hat{\theta}$ for Classical General Linear Model

	Model: $\mathbf{x} = \mathbf{H}\boldsymbol{\theta} + \mathbf{w}$	
	Assumptions: $E(\mathbf{w}) = \mathbf{0}$	
	$\mathbf{C}_{\mathbf{w}} = \mathbf{C}$	
	Estimator: $\hat{\boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{C}^{-1} \mathbf{x}$	
Properties	$\mathbf{w} \sim \text{Gaussian}$ (linear model)	$\mathbf{w} \sim \text{Non-Gaussian}$
Efficient	*	
Sufficient Statistic	*	
MVU	*	
BLUE	*	*
MLE	*	
WLS ($\mathbf{W} = \mathbf{C}^{-1}$)	*	*

* Property holds.

BAYES LM

6. 贝叶斯线性模型

$$x = H\theta + w$$

其中 x 是 $N \times 1$ 的观测矢量， H 是秩为 p 的已知 $N \times p$ (可能 $N \leq p$)的观测矩阵， θ 是 $p \times 1$ 的随机矢量，PDF为 $N(\mu_\theta, C_\theta)$ ，且 w 是一个 $N \times 1$ 的与 θ 无关的噪声矢量，PDF为 $N(0, C_w)$ 。 x 的条件PDF为

$$p(x | \theta) = \frac{1}{(2\pi)^{N/2} \det^{1/2}(C_w)} \exp\left[-\frac{1}{2}(x - H\theta)^T C_w^{-1}(x - H\theta)\right]$$

θ 的先验PDF为

$$p(\theta) = \frac{1}{(2\pi)^{p/2} \det^{1/2}(C_\theta)} \exp\left[-\frac{1}{2}(\theta - \mu_\theta)^T C_\theta^{-1}(\theta - \mu_\theta)\right]$$



BAYES LM

后验PDF $p(\theta|x)$ 也是高斯的，均值和协方差矩阵为

$$\begin{aligned} E(\theta|x) &= \mu_\theta + C_\theta H^T (H C_\theta H^T + C_w)^{-1} (x - H \mu_\theta) \\ &= \mu_\theta + \left(C_\theta^{-1} + H^T C_w^{-1} H \right)^{-1} H^T C_w^{-1} (x - H \mu_\theta) \end{aligned}$$

$$\begin{aligned} C_{\theta|x} &= C_\theta - C_\theta H^T (H C_\theta H^T + C_w)^{-1} H C_\theta \\ &= \left(C_\theta^{-1} + H^T C_w^{-1} H \right)^{-1} \end{aligned}$$



LM—MMSE

7. 最小均方误差估计量

MMSE估计量刚好是下式给出的后验PDF的均值，

$$\begin{aligned} E(\theta | x) &= \mu_\theta + C_\theta H^T (H C_\theta H^T + C_w)^{-1} (x - H \mu_\theta) \\ &= \mu_\theta + (C_\theta^{-1} + H^T C_w^{-1} H)^{-1} H^T C_w^{-1} (x - H \mu_\theta) \end{aligned}$$

由于 $C_{\theta|x}$ 并不依赖于 x ，即

$$\begin{aligned} C_{\theta|x} &= C_\theta - C_\theta H^T (H C_\theta H^T + C_w)^{-1} H C_\theta \\ &= (C_\theta^{-1} + H^T C_w^{-1} H)^{-1} \end{aligned}$$

根据 $\text{var}(\varepsilon_i) = \text{Bmse}(\hat{\theta}_i) = \int [C_{\theta|x}]_{ii} p(x) dx$ ，最小贝叶斯MSE或

$$E((\theta_i - \hat{\theta})^2) \text{ 为 } \text{Bmse}(\hat{\theta}_i) = [C_{\theta|x}]_{ii}$$



LM—MAP&LMMSE

8. 最大后验概率估计量

由于高斯PDF的峰值的位置与均值相同，故MAP估计量与MMSE估计量相同。

9. 线性最小均方误差估计量

由于MMSE是 x 的线性函数，因此LMMSE估计量由下式给出

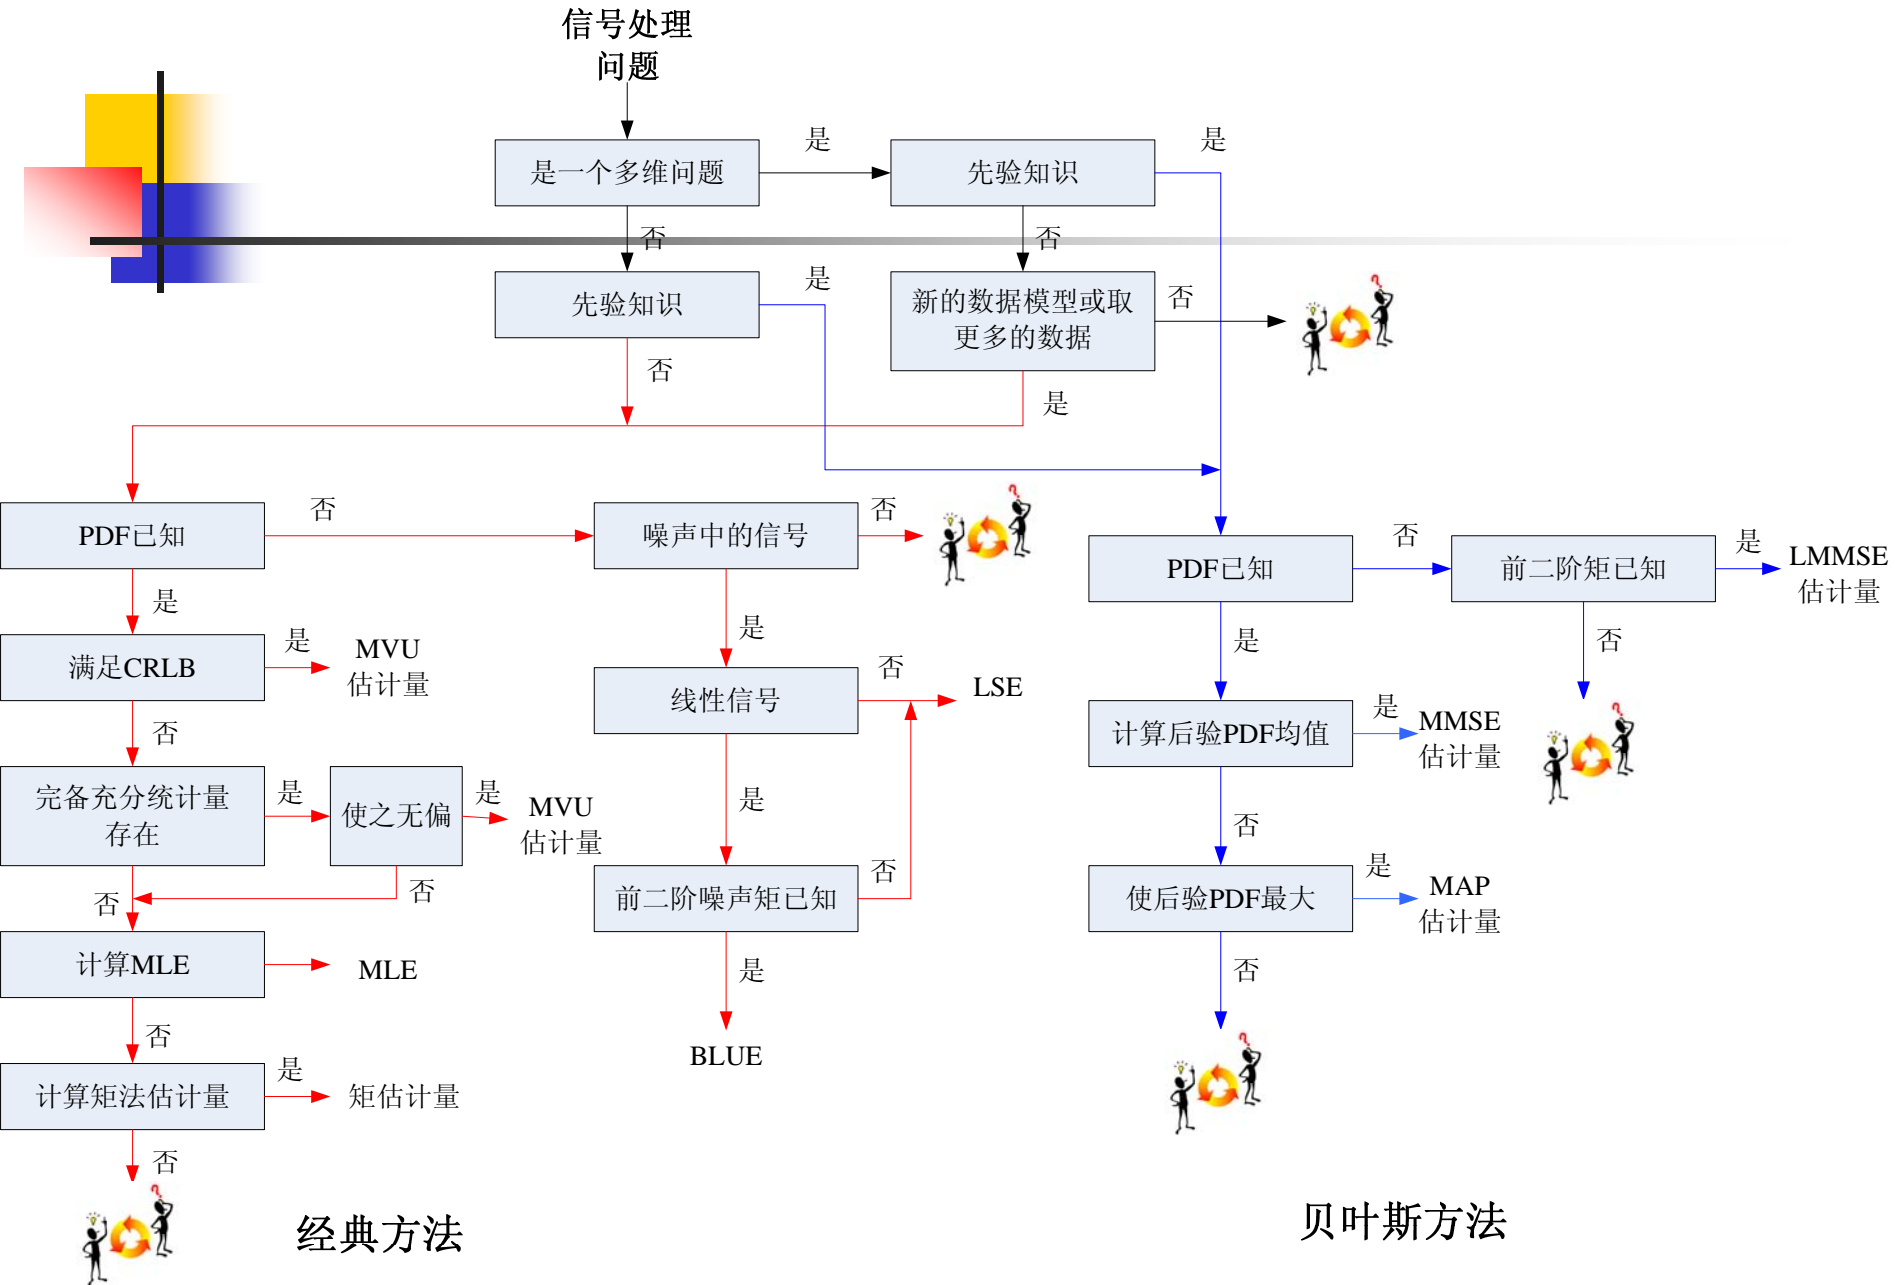
$$\begin{aligned} E(\theta|x) &= \mu_\theta + C_\theta H^T (H C_\theta H^T + C_w)^{-1} (x - H \mu_\theta) \\ &= \mu_\theta + (C_\theta^{-1} + H^T C_w^{-1} H)^{-1} H^T C_w^{-1} (x - H \mu_\theta) \end{aligned}$$

因此对于贝叶斯线性模型，MMSE估计量，MAP估计量和LMMSE估计量是相同的。没有先验信息时估计量的形式，可通过 $C_\theta^{-1} \rightarrow 0$ 来表示，

$$\text{即 } \hat{\theta} = (H^T C_w^{-1} H)^{-1} H^T C_w^{-1} x$$

它可以认为与经典一般线性模型的MVU估计量具有相同的形式。当然估计量不能真正地进行比较，因为它们是在不同的数据模型假设下推导出来的。

如何选择一个估计量&估计量选择的决策过程





谢谢大家