

Estimation en traitement du signal

Olivier Besson



- ① Introduction - Problématique
 - Contexte de l'estimation
 - Problématique de l'estimation
- ② Approche déterministe
- ③ Approche Bayésienne

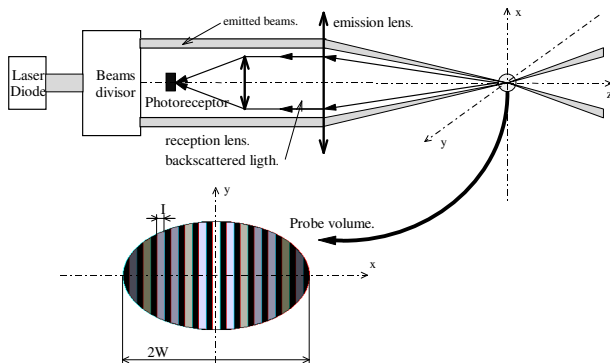
Objectif

Mettre en œuvre un système permettant d'accéder à une information pertinente, par exemple vitesse et/ou position d'un objet en mouvement.

Questions

- Quel est le problème ; qu'est-ce que je cherche ?
- Comment choisir le capteur pour résoudre le problème ?
- Quel est le principe de fonctionnement du système ?
- De quelle façon le capteur donne t-il les informations recherchées ?
- Comment vais-je utiliser les données qu'il me fournit ?

Exemple : anémométrie laser



Le signal reçu s'écrit

$$x(t) = A \exp \left\{ -2\alpha^2 f_d^2 t^2 \right\} \cos(2\pi f_d t) + b(t).$$

⇒ estimation de $v = I f_d$ à partir de $x(t)$.

Exemple : effet Doppler

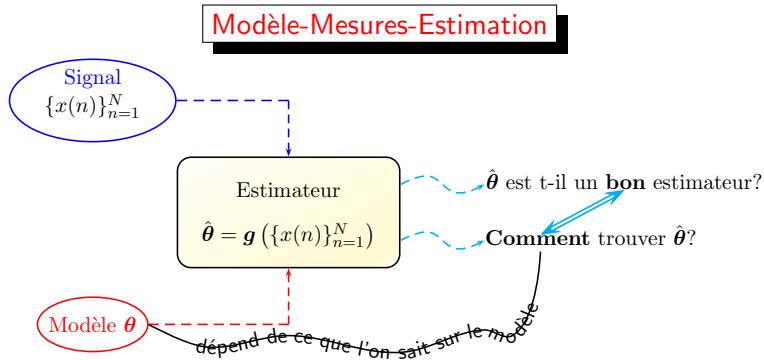
On considère une antenne émettant un signal $s(t) = e^{i\omega_c t}$ et rétro-diffusé par une cible en mouvement uniforme à la vitesse radiale v . Le signal reçu s'écrit

$$r(t) = A s(t - 2\tau(t)) = A s\left(t - 2\frac{d_0 - vt}{c}\right) = A e^{i\omega_c t} e^{-i\omega_c \frac{2d_0}{c}} e^{i\frac{2\omega_c v}{c} t}$$

Après démodulation, on obtient

$$x(t) = A e^{i\phi} e^{i2\pi \frac{2v}{\lambda} t} + b(t)$$

et donc la vitesse de la cible se déduit de la fréquence du signal utile.



Ce que l'on sait (croit savoir)

- Un capteur reçoit des mesures $x(1), \dots, x(N)$.
- Le signal contient une information via un vecteur paramètre θ , par exemple $x(n) = s(n; \theta) + b(n)$ et on connaît (ou pas) la loi de $\mathbf{b} = [b(1) \ \dots \ b(N)]^T$.

Ce que l'on veut (voudrait) savoir

- **Comment** trouver un estimateur $\hat{\theta} = g(x(1), \dots, x(N))$ de θ ?
- Est-ce que $\hat{\theta}$ est un bon estimateur ?

Contraintes

- métrologie, performance, coût calculatoire, robustesse, ...

Approche déterministe

On suppose que θ est une quantité **déterministe** inconnue et on considère alors la loi $p_{\mathbf{X}}(\mathbf{x}; \theta)$ du vecteur $\mathbf{X} = [X(1) \ X(2) \ \dots \ X(N)]^T$ qui est paramétrée par θ .

Approche Bayésienne

On suppose que θ est une réalisation d'un **vecteur aléatoire** Θ et on considère alors la loi jointe $p_{\mathbf{X}, \Theta}(\mathbf{x}, \theta) = p_{\mathbf{X}|\Theta}(\mathbf{x}|\theta) \pi_{\Theta}(\theta)$, où $\pi_{\Theta}(\theta)$ désigne la loi a priori.

① Introduction - Problématique

② Approche déterministe

- Modélisation

- Caractérisation d'un estimateur

- Estimation optimale

- Bornes de Cramér-Rao

- Estimateur MVU

- Estimateur du maximum de vraisemblance

- Méthode des moments


- Synthèse des approches

③ Approche Bayésienne

Densité de probabilité et fonction de vraisemblance

- La loi $p(\mathbf{x}; \theta)$ donne toute l'information sur le signal \mathbf{x} . Par exemple, si $x(n) = \theta + b(n)$ où $b(n)$ sont i.i.d. $b(n) \sim \mathcal{N}(0, \sigma^2)$,

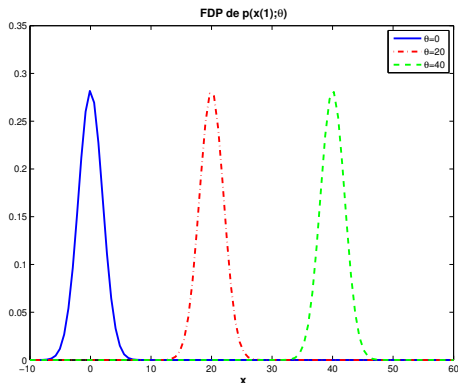
$$p(\mathbf{x}; \theta) = \frac{1}{(2\pi\sigma^2)^{N/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{n=1}^N (x(n) - \theta)^2 \right\}.$$



- $p(\mathbf{x}; \theta)$, vue comme une fonction de θ , est dénommée vraisemblance.

Vraisemblance et estimation

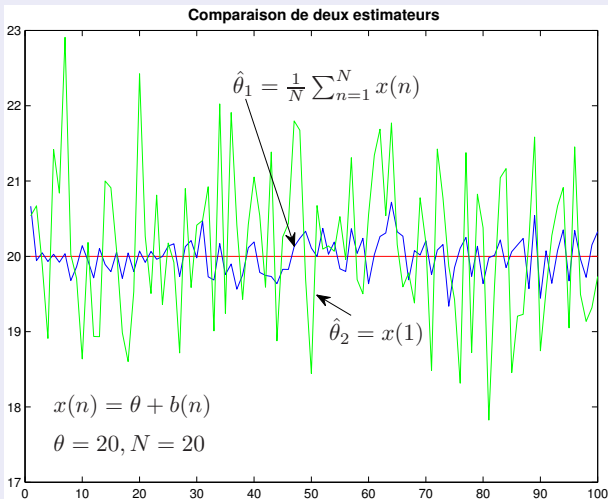
- Toute l'information sur x est contenue dans $p(x; \theta)$.
- $p(x; \theta)$ dépend de $\theta \Rightarrow$ on peut inférer θ à partir de x .



- $\hat{\theta}$ est une fonction de x : x étant aléatoire, $\hat{\theta}$ est aléatoire.

Caractérisation d'un estimateur

Critères de qualité d'un estimateur ?



Biais

$$b(\hat{\theta}) = E\{\hat{\theta}\} - \theta$$

Matrice de covariance

$$\text{cov}(\hat{\theta}) = E\{(\hat{\theta} - E\{\hat{\theta}\})(\hat{\theta} - E\{\hat{\theta}\})^T\}$$

Erreur quadratique moyenne

$$\text{eqm}(\hat{\theta}) = E\{(\hat{\theta} - \theta)(\hat{\theta} - \theta)^T\} = b(\hat{\theta})b(\hat{\theta})^T + \text{cov}(\hat{\theta})$$

Loi

La loi $p(\hat{\theta})$ constitue la caractérisation complète du vecteur aléatoire $\hat{\theta}$.

Exemple de caractérisation d'un estimateur

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

On suppose que les variables $b(n)$ sont i.i.d. $b(n) \sim \mathcal{N}(0, \sigma^2)$, i.e.

$\mathbf{b} = [b(1) \ \dots \ b(N)]^T \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$. Soit $\hat{\theta} = \frac{1}{N} \sum_{n=1}^N x(n)$. On a

$$\mathbb{E}\{\hat{\theta}\} = \mathbb{E}\left\{\frac{1}{N} \sum_{n=1}^N x(n)\right\} = \frac{1}{N} \sum_{n=1}^N \mathbb{E}\{x(n)\} = \theta$$

$$\begin{aligned} \text{cov}(\hat{\theta}) &= \frac{1}{N^2} \mathbb{E}\left\{ \sum_{n,m=1}^N (x(n) - \theta)(x(m) - \theta) \right\} \\ &= \frac{1}{N^2} \mathbb{E}\left\{ \sum_{n,m=1}^N b(n)b(m) \right\} = \frac{1}{N^2} \mathbb{E}\left\{ \sum_{n=1}^N b(n)^2 \right\} = \frac{\sigma^2}{N}. \end{aligned}$$

Dans ce cas, on a la loi de l'estimateur : $\hat{\theta} \sim \mathcal{N}(\theta, \sigma^2/N)$.

Estimateur consistant

Soit $\hat{\boldsymbol{\theta}}_N$ un estimateur de $\boldsymbol{\theta}$ à partir de N échantillons $x(1), \dots, x(N)$.
Alors $\hat{\boldsymbol{\theta}}_N$ est un estimateur consistant (au sens large) si

$$\lim_{N \rightarrow \infty} \Pr \left\{ \left\| \hat{\boldsymbol{\theta}}_N - \boldsymbol{\theta} \right\| < \delta \right\} = 1 \quad \forall \delta > 0 \quad \forall \boldsymbol{\theta}.$$

Il est dit consistant en moyenne quadratique si

$$\lim_{N \rightarrow \infty} \mathbf{E} \{ (\hat{\boldsymbol{\theta}}_N - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}}_N - \boldsymbol{\theta})^T \} = \mathbf{0} \quad \forall \boldsymbol{\theta}.$$

Estimation optimale ?

- quel critère dois-je adopter pour mesurer la performance d'un estimateur ?
- en supposant que ce critère existe, y a t-il des estimateurs qui produisent la performance optimale ?
- si oui, existe t-il une démarche systématique (et laquelle) pour calculer cet estimateur optimal ?

Approches

- ① soit on considère que l'estimateur doit être non biaisé et on cherche donc l'estimateur à minimum de variance ;
- ② soit on autorise un biais et on cherche alors à minimiser l'erreur quadratique moyenne.

Minimisation de l'eqm pour $x(n) = \theta + b(n)$

- On autorise un biais dont on espère qu'il sera contre-balançé par une diminution de la variance.
- Par exemple, on cherche un estimateur du type $\hat{\theta} = a \frac{1}{N} \sum_{n=1}^N x(n)$ dont l'eqm $\text{eqm}(\hat{\theta}) = (a - 1)^2 \theta^2 + \frac{a^2 \sigma^2}{N}$ est la plus faible possible.
- La valeur optimale de a est alors $a_{\text{opt}} = [\theta^2 + N^{-1} \sigma^2]^{-1} \theta^2$ qui dépend de θ inconnu. On a, avec ce choix de a

$$\text{b}(\hat{\theta}) = - [\theta^2 + N^{-1} \sigma^2]^{-1} \theta N^{-1} \sigma^2 \neq 0$$

$$\text{cov}(\hat{\theta}) = [\theta^2 + N^{-1} \sigma^2]^{-2} \theta^4 N^{-1} \sigma^2 < N^{-1} \sigma^2 = \text{cov}\left(\frac{1}{N} \sum_{n=1}^N x(n)\right)$$

$$\text{eqm}(\hat{\theta}) = [\theta^2 + N^{-1} \sigma^2]^{-1} \theta^2 N^{-1} \sigma^2 < N^{-1} \sigma^2 = \text{eqm}\left(\frac{1}{N} \sum_{n=1}^N x(n)\right).$$

Estimateur MVU

On considère comme “**référence**” l'estimateur non biaisé, à minimum de variance :

$$\begin{aligned} E\{\hat{\boldsymbol{\theta}}^{MVU}\} &= \boldsymbol{\theta} \\ \mathbf{C}_{\hat{\boldsymbol{\theta}}} - \mathbf{C}^{MVU} &\geq \mathbf{0} \quad \forall \hat{\boldsymbol{\theta}}, \forall \boldsymbol{\theta} \end{aligned}$$

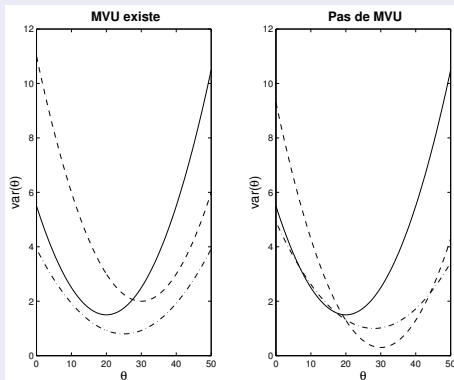
où $\mathbf{C}^{MVU} = \text{cov}(\hat{\boldsymbol{\theta}}^{MVU})$ et $\mathbf{C}_{\hat{\boldsymbol{\theta}}} = \text{cov}(\hat{\boldsymbol{\theta}})$.

Si cet estimateur existe (et si on peut l'implémenter), il est considéré comme l'estimateur optimal.

Estimation non biaisée à variance minimale

Questions

- Cet estimateur existe-t-il ? Si oui comment le trouver ?
- Existe-t-il une borne inférieure à $\text{cov}(\hat{\theta})$?



Bornes de Cramér-Rao

La borne de Cramér-Rao (BCR) donne l'expression de la covariance minimale que l'on peut atteindre en estimant (de manière non biaisée) le paramètre θ :

- si un estimateur atteint les bornes, et ce quel que soit θ , alors c'est l'estimateur MVU ;
- cette borne est une référence à laquelle on peut comparer tous les estimateurs ;
- la théorie permet de déterminer s'il existe un estimateur qui atteindra la borne.

Théorème (Borne de Cramér-Rao)

Si $p(\mathbf{x}; \boldsymbol{\theta})$ vérifie la condition de régularité $E\left\{\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}}\right\} = \mathbf{0}$ alors, quel que soit l'estimateur non biaisé $\hat{\boldsymbol{\theta}}$ de $\boldsymbol{\theta}$, sa matrice de covariance vérifie $\mathbf{C}_{\hat{\boldsymbol{\theta}}} - \mathbf{I}^{-1}(\boldsymbol{\theta}) \geq \mathbf{0}$ où

$$\mathbf{I}(\boldsymbol{\theta}) = -E\left\{\frac{\partial^2 \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T}\right\} = E\left\{\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T}\right\}$$

est la **matrice d'information de Fisher**. De plus, on peut trouver un estimateur qui atteint la borne i.e. $\mathbf{C}_{\hat{\boldsymbol{\theta}}} = \mathbf{I}^{-1}(\boldsymbol{\theta})$ **si et seulement si**

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{I}(\boldsymbol{\theta}) (\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta}).$$

Cet estimateur, **qui est l'estimateur MVU**, est donné par $\hat{\boldsymbol{\theta}} = \mathbf{f}(\mathbf{x})$ et sa matrice de covariance est alors $\mathbf{I}^{-1}(\boldsymbol{\theta})$: il est dit **efficace**.

Démonstration

$\hat{\theta}$ étant un estimateur non biaisé, on a $\int \hat{\theta} p(\mathbf{x}; \theta) d\mathbf{x} = \theta$. En différentiant, on obtient

$$\int \hat{\theta} \frac{\partial p(\mathbf{x}; \theta)}{\partial \theta^T} d\mathbf{x} = \int \hat{\theta} \frac{\partial \ln p(\mathbf{x}; \theta)}{\partial \theta^T} p(\mathbf{x}; \theta) d\mathbf{x} = \mathbf{I}$$

et ainsi

$$\mathbb{E}\left\{(\hat{\theta} - \theta) \frac{\partial \ln p(\mathbf{x}; \theta)}{\partial \theta^T}\right\} = \mathbf{I}.$$

Par conséquent, la matrice de covariance de $\left[(\hat{\theta} - \theta)^T \frac{\partial \ln p(\mathbf{x}; \theta)}{\partial \theta^T}\right]^T$ s'écrit

$$\text{cov}\left(\begin{bmatrix} \hat{\theta} - \theta \\ \partial \ln p(\mathbf{x}; \theta) / \partial \theta \end{bmatrix}\right) = \begin{bmatrix} \mathbf{C}_{\hat{\theta}} & \mathbf{I} \\ \mathbf{I} & \mathbf{I}(\theta) \end{bmatrix}.$$

Démonstration

Cette matrice étant définie positive, on a nécessairement

$$C_{\hat{\theta}} - I^{-1}(\theta) \geq \mathbf{0}.$$

D'autre part

$$\int \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} p(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x} = \mathbf{0}$$

$$\Rightarrow \int \frac{\partial^2 \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} p(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x} + \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} p(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x} = \mathbf{0}$$

$$\Rightarrow \mathbf{I}(\boldsymbol{\theta}) = \mathbb{E}\left\{ \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \right\} = -\mathbb{E}\left\{ \frac{\partial^2 \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\}.$$

Démonstration

Si de plus

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{I}(\boldsymbol{\theta}) (\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta})$$

alors, pour $\hat{\boldsymbol{\theta}} = \mathbf{f}(\mathbf{x})$, on a

$$\begin{aligned} \mathbb{E}\{\hat{\boldsymbol{\theta}} - \boldsymbol{\theta}\} &= \int (\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta}) p(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x} \\ &= \mathbf{I}^{-1}(\boldsymbol{\theta}) \int \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} p(\mathbf{x}; \boldsymbol{\theta}) d\mathbf{x} = \mathbf{0} \\ \text{cov}(\hat{\boldsymbol{\theta}}) &= \mathbb{E}\left\{ \mathbf{I}^{-1}(\boldsymbol{\theta}) \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \mathbf{I}^{-1}(\boldsymbol{\theta}) \right\} \\ &= \mathbf{I}^{-1}(\boldsymbol{\theta}) \mathbb{E}\left\{ \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \right\} \mathbf{I}^{-1}(\boldsymbol{\theta}) \\ &= \mathbf{I}^{-1}(\boldsymbol{\theta}). \end{aligned}$$

Exemple $x(n) = \theta + b(n)$, $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

On a dans ce cas

$$p(\mathbf{x}; \theta) = \frac{1}{(2\pi\sigma^2)^{N/2}} \exp \left\{ \frac{-1}{2\sigma^2} \sum_{n=1}^N (x(n) - \theta)^2 \right\}$$
$$\ln p(\mathbf{x}; \theta) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{n=1}^N (x(n) - \theta)^2.$$

Il s'ensuit que

$$\frac{\partial \ln p(\mathbf{x}; \theta)}{\partial \theta} = \frac{1}{\sigma^2} \sum_{n=1}^N (x(n) - \theta)$$
$$\frac{\partial^2 \ln p(\mathbf{x}; \theta)}{\partial \theta^2} = -\frac{N}{\sigma^2} = -I(\theta).$$

Exemple $x(n) = \theta + b(n)$, $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

La BCR est donc simplement

$$BCR(\theta) = \frac{\sigma^2}{N}.$$

De plus,

$$\frac{\partial \ln p(\mathbf{x}; \theta)}{\partial \theta} = \frac{N}{\sigma^2} \left[\frac{1}{N} \sum_{n=1}^N x(n) - \theta \right].$$

Ainsi il existe un estimateur efficace (donc forcément MVU), à savoir

$$\hat{\theta}^{MVU} = \frac{1}{N} \sum_{n=1}^N x(n).$$

Exemple $x(n) = s(n; \boldsymbol{\theta}) + b(n)$, $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

La loi s'écrit maintenant

$$\ln p(\mathbf{x}; \boldsymbol{\theta}) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{n=1}^N [x(n) - s(n; \boldsymbol{\theta})]^2.$$

Les dérivées deviennent alors

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \theta_k} = \frac{1}{\sigma^2} \sum_{n=1}^N [x(n) - s(n; \boldsymbol{\theta})] \frac{\partial s(n; \boldsymbol{\theta})}{\partial \theta_k} = \frac{1}{\sigma^2} \left[\frac{\partial \mathbf{s}^T(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} [\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})] \right]_k.$$

La matrice d'information de Fisher $\mathbf{I}(\boldsymbol{\theta})$ s'écrit donc simplement

$$\begin{aligned} \mathbf{I}(\boldsymbol{\theta}) &= \frac{1}{\sigma^4} \frac{\partial \mathbf{s}^T(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \mathbb{E}\{[\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})][\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})]^T\} \frac{\partial \mathbf{s}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} \\ &= \frac{1}{\sigma^2} \frac{\partial \mathbf{s}^T(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \mathbf{s}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T}. \end{aligned}$$

Exemple $x(n) = s(n; \boldsymbol{\theta}) + b(n)$, $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

- Considérons maintenant **l'existence** d'un estimateur efficace. On doit avoir la factorisation

$$\begin{aligned} \frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} &= \frac{1}{\sigma^2} \frac{\partial \mathbf{s}^T(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} [\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})] \\ &= \mathbf{I}(\boldsymbol{\theta}) [\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta}] = \frac{1}{\sigma^2} \frac{\partial \mathbf{s}^T(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} \frac{\partial \mathbf{s}(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} [\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta}]. \end{aligned}$$

- Cette factorisation n'est possible que si $\mathbf{s}(\boldsymbol{\theta})$ est une fonction **affine** de $\boldsymbol{\theta}$, soit $\mathbf{s}(\boldsymbol{\theta}) = \mathbf{H}\boldsymbol{\theta} + \mathbf{c}$, auquel cas $\mathbf{I}(\boldsymbol{\theta}) = \sigma^{-2} \mathbf{H}^T \mathbf{H}$ et

$$\hat{\boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T (\mathbf{x} - \mathbf{c})$$

est l'estimateur efficace.

Synthèse $x \sim \mathcal{N}(s(\boldsymbol{\theta}), \sigma^2 \mathbf{I})$ avec σ^2 connu

- si $s(\boldsymbol{\theta})$ est une fonction non linéaire de $\boldsymbol{\theta}$, il n'existe pas d'estimateur efficace ;
- si $s(\boldsymbol{\theta}) = \mathbf{H}\boldsymbol{\theta}$, il existe un estimateur efficace $\hat{\boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{x}$.

Cas σ^2 inconnu

Alors, la matrice de Fisher s'écrit

$$\mathbf{I}(\boldsymbol{\theta}, \sigma^2) = \frac{1}{\sigma^2} \begin{bmatrix} \frac{\partial s(\boldsymbol{\theta})^T}{\partial \boldsymbol{\theta}} \frac{\partial s(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^T} & \mathbf{0} \\ \mathbf{0} & \frac{N}{2\sigma^2} \end{bmatrix}.$$

Il n'y a pas d'estimateur efficace du vecteur $[\boldsymbol{\theta} \ \sigma^2]^T$. Par contre, si $s(\boldsymbol{\theta}) = \mathbf{H}\boldsymbol{\theta}$, $\hat{\boldsymbol{\theta}} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \mathbf{x}$ reste efficace.

Modèle linéaire $\mathbf{x} \sim \mathcal{N}(\mathbf{H}\boldsymbol{\theta}, \mathbf{C})$, \mathbf{C} connue

- Le signal utile s'écrit comme une combinaison linéaire, à coefficients inconnus, de signaux connus :

$$s(n; \boldsymbol{\theta}) = \sum_{k=1}^p \theta_k h_k(n) \Leftrightarrow \mathbf{s}(\boldsymbol{\theta}) = \mathbf{H}\boldsymbol{\theta}$$

et les colonnes de \mathbf{H} contiennent les signaux de la base sur laquelle on décompose $s(n; \boldsymbol{\theta})$.

- Le bruit additif est Gaussien, coloré, de matrice de covariance \mathbf{C} connue.
- La vraisemblance s'écrit

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

$$\ln p(\mathbf{x}; \boldsymbol{\theta}) = \text{const.} - \frac{1}{2} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta}).$$

- Les dérivées de la log-vraisemblance s'écrivent

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{H}^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})$$
$$\frac{\partial^2 \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} = -\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} = -\mathbf{I}(\boldsymbol{\theta})$$

- On a donc la factorisation

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{I}(\boldsymbol{\theta}) \left[(\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{C}^{-1} \mathbf{x} - \boldsymbol{\theta} \right]$$

- L'estimateur MVU efficace s'en déduit comme

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

et cet estimateur est une fonction **linéaire** de \mathbf{x} .

Remarques

- L'estimateur MVU est solution du **problème des moindres carrés pondérés** suivant :

$$\hat{\boldsymbol{\theta}}^{MVU} = \arg \min_{\boldsymbol{\theta}} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta}).$$

- Dans le cas où $\mathbf{x} = \mathbf{H}\boldsymbol{\theta} + \mathbf{b}$ où \mathbf{b} est de moyenne nulle, de matrice de covariance \mathbf{C} (mais \mathbf{b} n'est pas nécessairement Gaussien),

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

est l'estimateur **BLUE** (best linear unbiased estimate), i.e.

$$\forall \hat{\boldsymbol{\theta}} = \mathbf{F}\mathbf{x} \text{ tel que } \mathbb{E}\{\hat{\boldsymbol{\theta}}\} = \boldsymbol{\theta}, \quad \text{cov}(\hat{\boldsymbol{\theta}}) - \text{cov}(\hat{\boldsymbol{\theta}}^{BLUE}) \geq \mathbf{0}.$$

Transformation de paramètres

- Si l'on veut estimer $\boldsymbol{\beta} = f(\boldsymbol{\theta})$ alors

$$\mathbf{I}^{-1}(\boldsymbol{\beta}) = \frac{\partial \boldsymbol{\beta}}{\partial \boldsymbol{\theta}^T} \mathbf{I}^{-1}(\boldsymbol{\theta}) \frac{\partial \boldsymbol{\beta}^T}{\partial \boldsymbol{\theta}}.$$

- Si $\hat{\boldsymbol{\theta}}$ est un estimateur efficace et si $f(\cdot)$ est linéaire, alors $\hat{\boldsymbol{\beta}} = f(\hat{\boldsymbol{\theta}})$ est efficace. Si $f(\cdot)$ n'est pas linéaire, alors $\hat{\boldsymbol{\beta}} = f(\hat{\boldsymbol{\theta}})$ n'est plus efficace. Par contre, en général on a l'efficacité asymptotique car

$$\hat{\boldsymbol{\beta}} = f(\hat{\boldsymbol{\theta}}) \simeq f(\boldsymbol{\theta}) + \frac{\partial \boldsymbol{\beta}}{\partial \boldsymbol{\theta}^T} (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})$$

et donc

$$\mathbf{C}_{\hat{\boldsymbol{\beta}}} \simeq \frac{\partial \boldsymbol{\beta}}{\partial \boldsymbol{\theta}^T} \mathbf{I}^{-1}(\boldsymbol{\theta}) \frac{\partial \boldsymbol{\beta}^T}{\partial \boldsymbol{\theta}} = \mathbf{I}^{-1}(\boldsymbol{\beta}).$$

BCR pour signaux Gaussiens (formule de Slepian-Bangs)

Cas de signaux Gaussiens réels $\mathbf{x} \sim \mathcal{N}(\boldsymbol{\mu}(\boldsymbol{\theta}), \mathbf{C}(\boldsymbol{\theta}))$

$$[\mathbf{I}(\boldsymbol{\theta})]_{k,\ell} = \frac{\partial \boldsymbol{\mu}^T(\boldsymbol{\theta})}{\partial \theta_k} \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \boldsymbol{\mu}(\boldsymbol{\theta})}{\partial \theta_\ell} + \frac{1}{2} \text{Tr} \left\{ \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \mathbf{C}(\boldsymbol{\theta})}{\partial \theta_k} \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \mathbf{C}(\boldsymbol{\theta})}{\partial \theta_\ell} \right\}.$$

Cas de signaux Gaussiens complexes $\mathbf{x} \sim \mathcal{CN}(\boldsymbol{\mu}(\boldsymbol{\theta}), \mathbf{C}(\boldsymbol{\theta}))$

Pour des signaux complexes circulaires dont la loi est

$$p(\mathbf{x}; \boldsymbol{\theta}) = \pi^{-N} |\mathbf{C}(\boldsymbol{\theta})|^{-1} \exp \left\{ -(\mathbf{x} - \boldsymbol{\mu}(\boldsymbol{\theta}))^H \mathbf{C}^{-1}(\boldsymbol{\theta}) (\mathbf{x} - \boldsymbol{\mu}(\boldsymbol{\theta})) \right\}$$

la matrice d'information de Fisher devient

$$[\mathbf{I}(\boldsymbol{\theta})]_{k,\ell} = 2\text{Re} \left[\frac{\partial \boldsymbol{\mu}^H(\boldsymbol{\theta})}{\partial \theta_k} \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \boldsymbol{\mu}(\boldsymbol{\theta})}{\partial \theta_\ell} \right] + \text{Tr} \left\{ \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \mathbf{C}(\boldsymbol{\theta})}{\partial \theta_k} \mathbf{C}^{-1}(\boldsymbol{\theta}) \frac{\partial \mathbf{C}(\boldsymbol{\theta})}{\partial \theta_\ell} \right\}.$$

Exponentielle complexe

- Soit le signal $x(n) = Ae^{i(n\omega_0 + \phi)} + b(n)$, $n = 0, \dots, N-1$, où $\mathbf{b} \sim \mathcal{CN}(\mathbf{0}, \sigma^2 \mathbf{I})$ et A, ϕ et ω_0 sont des paramètres déterministes inconnus. Si $\boldsymbol{\theta} = [A \ \omega_0 \ \phi \ \sigma^2]^T$ on obtient

$$\mathbf{I}(\boldsymbol{\theta}) = \frac{2}{\sigma^2} \begin{pmatrix} N & 0 & 0 & 0 \\ 0 & A^2 Q & A^2 P & 0 \\ 0 & A^2 P & NA^2 & 0 \\ 0 & 0 & 0 & \frac{N}{2\sigma^2} \end{pmatrix}; P = \sum_{n=0}^{N-1} n, Q = \sum_{n=0}^{N-1} n^2$$

- On en déduit les bornes de Cramér-Rao :

$$BCR(A) = \frac{\sigma^2}{2N}$$

$$BCR(\sigma^2) = \frac{\sigma^4}{N}$$

$$BCR(\phi) = \frac{\sigma^2(2N-1)}{A^2 N(N+1)}$$

$$BCR(\omega_0) = \frac{6\sigma^2}{A^2 N(N^2-1)}$$

Question

Existe-t-il une fonction des données qui concentre à elle seule toute l'information sur θ ? Par exemple, pour $x(n) = \theta + b(n)$, $\hat{\theta}^{MVU} = N^{-1} \sum_{n=1}^N x(n)$ et il suffit d'observer $t = \sum_{n=1}^N x(n)$ pour obtenir l'estimateur MVU.

Statistique exhaustive

t est une statistique exhaustive pour l'estimation de θ si, une fois que l'on a observé t , rien de plus ne peut être inféré sur θ à partir des données : $p(\mathbf{x}|t)$ ne dépend plus de θ .

Exemple $x(n) = \theta + b(n)$, $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$

Puisque $\mathbf{x} \sim \mathcal{N}(\theta \mathbf{1}, \sigma^2 \mathbf{I})$ et $t = \mathbf{x}^T \mathbf{1} \sim \mathcal{N}(N\theta, N\sigma^2)$, on a

$$p(\mathbf{x}, t; \theta) = (2\pi\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{x}^T \mathbf{x} - 2t\theta + N\theta^2)\right\} \delta(t - \mathbf{x}^T \mathbf{1})$$

$$p(t; \theta) = (2\pi N\sigma^2)^{-1/2} \exp\left\{-\frac{1}{2\sigma^2} \left(\frac{t^2}{N} - 2t\theta + N\theta^2\right)\right\}.$$

Par conséquent la loi conditionnelle de $\mathbf{x}|t$ s'écrit

$$p(\mathbf{x}|t) = \frac{(2\pi N\sigma^2)^{1/2}}{(2\pi\sigma^2)^{N/2}} \exp\left\{-\frac{1}{2\sigma^2} \left(\mathbf{x}^T \mathbf{x} - \frac{t^2}{N}\right)\right\} \delta(t - \mathbf{x}^T \mathbf{1})$$

et ne dépend plus de θ .

Statistique exhaustive

- t est une statistique exhaustive pour l'estimation de θ ssi $p(\mathbf{x}|t)$ ne dépend plus de θ .
- L'estimateur MVU doit être une fonction d'une statistique exhaustive.

Recherche de l'estimateur MVU

- $p(\mathbf{x}; \theta) = g(t, \theta) h(\mathbf{x}) \Leftrightarrow t$ statistique exhaustive.
- t est **complète** s'il n'existe qu'une **seule** fonction f telle que $f(t)$ soit un estimateur non biaisé de θ : c'est justement l'estimateur MVU.
- Si $\check{\theta}$ est un estimateur non biaisé de θ et si t est une statistique exhaustive alors $\hat{\theta} = E\{\check{\theta}|t\}$ est un estimateur non biaisé de θ de variance inférieure ou égale à celle de $\check{\theta}$. Si t est complète, il s'agit de l'estimateur MVU.

Modèle $\mathbf{x} = \mathbf{H}\boldsymbol{\theta} + \mathbf{b}$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \mathbf{C})$

On a

$$p(\mathbf{x}; \boldsymbol{\theta}) = (2\pi)^{-N/2} |\mathbf{C}|^{-1/2} \exp \left\{ -\frac{1}{2} \mathbf{x}^T \mathbf{C}^{-1} \mathbf{x} \right\} \\ \times \exp \left\{ \boldsymbol{\theta}^T \mathbf{H}^T \mathbf{C}^{-1} \mathbf{x} - \frac{1}{2} \boldsymbol{\theta}^T \mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} \boldsymbol{\theta} \right\}$$

et donc $\mathbf{t} = \mathbf{H}^T \mathbf{C}^{-1} \mathbf{x}$ est une statistique exhaustive. En supposant qu'elle est complète, on cherche l'estimateur non biaisé de $\boldsymbol{\theta}$ utilisant \mathbf{t} . Or

$$\mathbb{E}\{\mathbf{t}\} = \mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} \boldsymbol{\theta} \Rightarrow \hat{\boldsymbol{\theta}}^{MVU} = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H})^{-1} \mathbf{t}.$$

Modèle $\mathbf{x} = \mathbf{s}(\boldsymbol{\theta}) + \mathbf{b}$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \mathbf{C})$

On a

$$p(\mathbf{x}; \boldsymbol{\theta}) = (2\pi)^{-N/2} |\mathbf{C}|^{-1/2} \exp \left\{ -\frac{1}{2} \mathbf{x}^T \mathbf{C}^{-1} \mathbf{x} \right\} \\ \times \exp \left\{ \mathbf{s}^T(\boldsymbol{\theta}) \mathbf{C}^{-1} \mathbf{x} - \frac{1}{2} \mathbf{s}^T(\boldsymbol{\theta}) \mathbf{C}^{-1} \mathbf{s}(\boldsymbol{\theta}) \right\}$$

et donc il n'existe pas de statistique exhaustive puisque

$\mathbf{s}^T(\boldsymbol{\theta}) \mathbf{C}^{-1} \mathbf{x} = \sum_{n=1}^N s(n; \boldsymbol{\theta}) [\mathbf{C}^{-1} \mathbf{x}] (n)$ n'est pas observable car ne dépend pas des données \mathbf{x} uniquement.

Ecart-type d'une loi uniforme

On considère N données indépendantes $x(n) \sim \mathcal{U}([- \beta, \beta])$ et on cherche à estimer β . La loi de \mathbf{x} s'écrit, avec $u(\cdot)$ la fonction échelon

$$\begin{aligned} p(\mathbf{x}; \beta) &= \frac{1}{(2\beta)^N} \prod_{n=0}^{N-1} [u(x(n) + \beta) - u(x(n) - \beta)] \\ &= \begin{cases} \frac{1}{(2\beta)^N} & -\beta < x(n) < \beta \quad n = 0, \dots, N-1 \\ 0 & \text{sinon} \end{cases} \\ &= \begin{cases} \frac{1}{(2\beta)^N} & \max |x(n)| < \beta \\ 0 & \text{sinon} \end{cases} \end{aligned}$$

et donc $t = \max |x(n)|$ est une statistique exhaustive. En supposant qu'elle est complète on cherche un estimateur non biaisé de β à partir de t . Pour cela, on cherche la loi de t .

Ecart-type d'une loi uniforme

$$\begin{aligned} \Pr [t \leq \xi] &= \prod_{n=0}^{N-1} \Pr [|x(n)| \leq \xi] = \Pr [|x(n)| \leq \xi]^N \\ &= \begin{cases} 0 & \xi \leq 0 \\ \left(\frac{\xi}{\beta}\right)^N & 0 \leq \xi \leq \beta \\ 1 & \xi \geq \beta \end{cases} \end{aligned}$$

ce qui implique que la FDP de t est

$$p_t(\xi) = \frac{\partial \Pr [t \leq \xi]}{\partial \xi} = \begin{cases} 0 & \xi \leq 0 \\ \frac{N}{\beta} \left(\frac{\xi}{\beta}\right)^{N-1} & 0 \leq \xi \leq \beta \\ 1 & \xi \geq \beta \end{cases}$$

Ecart-type d'une loi uniforme

On a

$$E\{t\} = \int_0^\beta \frac{N}{\beta} \xi \left(\frac{\xi}{\beta}\right)^{N-1} d\xi = \frac{N}{N+1} \beta \Rightarrow \hat{\beta}^{MVU} = \frac{N+1}{N} \max |x(n)|.$$

Sa variance peut se calculer :

$$\begin{aligned} \text{cov}(\hat{\beta}^{MVU}) &= \left(\frac{N+1}{N}\right)^2 \text{cov}(t) \\ &= \left(\frac{N+1}{N}\right)^2 \left\{ \int_0^\beta \frac{N}{\beta} \xi^2 \left(\frac{\xi}{\beta}\right)^{N-1} d\xi - \left(\frac{N\beta}{N+1}\right)^2 \right\} \\ &= \frac{\beta^2}{N(N+2)}. \end{aligned}$$

Exemple $x(n) = n\theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \theta\sigma^2\mathbf{I})$

- Dans ce cas on a

$$\begin{aligned} p(\mathbf{x}; \theta) &= (2\pi\theta\sigma^2)^{-N/2} e^{-\frac{1}{2\theta\sigma^2} \sum_{n=1}^N (x(n) - n\theta)^2} \\ &= (2\pi\theta\sigma^2)^{-N/2} e^{-\frac{\sum_{n=1}^N x^2(n)}{2\theta\sigma^2} - \frac{\theta \sum_{n=1}^N n^2}{2\sigma^2}} e^{\frac{\sum_{n=1}^N nx(n)}{\sigma^2}}. \end{aligned}$$

- Par conséquent $t = \sum_{n=1}^N x^2(n)$ est une statistique exhaustive pour l'estimation de θ .
- Cependant, $E\{t\} = \theta^2 \sum_{n=1}^N n^2 + N\theta\sigma^2$ et il n'est donc pas évident de trouver un estimateur non biaisé de θ à partir de t .

Définition

L'estimateur ML consiste à maximiser la fonction de vraisemblance :

$$\hat{\boldsymbol{\theta}}^{ML} = \arg \max_{\boldsymbol{\theta}} p(\mathbf{x}; \boldsymbol{\theta}).$$

Propriétés

- **Efficacité asymptotique** : $\hat{\boldsymbol{\theta}}^{ML} \stackrel{\text{as}}{\sim} \mathcal{N}(\boldsymbol{\theta}, \mathbf{I}^{-1}(\boldsymbol{\theta}))$.
- Si un estimateur efficace existe, l'estimateur ML le produit :

$$\frac{\partial \ln p(\mathbf{x}; \boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \mathbf{I}(\boldsymbol{\theta}) [\mathbf{f}(\mathbf{x}) - \boldsymbol{\theta}] \Rightarrow \hat{\boldsymbol{\theta}}^{ML} = \mathbf{f}(\mathbf{x}).$$

- Si une statistique exhaustive existe, i.e., $p(\mathbf{x}; \boldsymbol{\theta}) = g(\mathbf{t}, \boldsymbol{\theta}) h(\mathbf{x})$, alors $\hat{\boldsymbol{\theta}}^{ML}$ est une fonction de \mathbf{t} uniquement.
- **Propriété d'invariance** : $\boldsymbol{\beta} = u(\boldsymbol{\theta}) \Rightarrow \hat{\boldsymbol{\beta}}^{ML} = u(\hat{\boldsymbol{\theta}}^{ML})$.

Exemple $\mathbf{x} \sim \mathcal{CN}(\mathbf{s}(\boldsymbol{\theta}), \sigma^2 \mathbf{I})$, σ^2 inconnu

- La fonction log-vraisemblance s'écrit

$$\Lambda(\mathbf{x}; \boldsymbol{\theta}, \sigma^2) = -N \ln(\pi\sigma^2) - \frac{1}{\sigma^2} \|\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})\|^2.$$

- On maximise d'abord par rapport à σ^2 :

$$\begin{aligned} \frac{\partial \Lambda(\mathbf{x}; \boldsymbol{\theta}, \sigma^2)}{\partial \sigma^2} &= -\frac{N}{\sigma^2} + \frac{1}{\sigma^4} \|\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})\|^2 \\ \hat{\sigma}^{2ML} &= N^{-1} \left\| \mathbf{x} - \mathbf{s}(\hat{\boldsymbol{\theta}}^{ML}) \right\|^2. \end{aligned}$$

- L'estimateur ML de $\boldsymbol{\theta}$ s'obtient comme

$$\hat{\boldsymbol{\theta}}^{ML} = \arg \min_{\boldsymbol{\theta}} \|\mathbf{x} - \mathbf{s}(\boldsymbol{\theta})\|^2$$

qui est un problème des **moindres carrés non linéaires**.

Exemple $\mathbf{x} \sim \mathcal{CN}(A\mathbf{s}(\omega), \sigma^2\mathbf{I})$

- L'estimateur ML de $\boldsymbol{\theta} = [\omega \ A]^T$ avec $A \in \mathbb{C}$ s'écrit

$$\hat{\boldsymbol{\theta}}^{ML} = \arg \min_{\boldsymbol{\theta}} \|\mathbf{x} - A\mathbf{s}(\omega)\|^2.$$

- On minimise d'abord par rapport à A :

$$\begin{aligned} \|\mathbf{x} - A\mathbf{s}(\omega)\|^2 &= \mathbf{x}^H \mathbf{x} - A\mathbf{x}^H \mathbf{s}(\omega) - A^* \mathbf{s}^H(\omega) \mathbf{x} + |A|^2 \mathbf{s}^H(\omega) \mathbf{s}(\omega) \\ &= \mathbf{s}^H(\omega) \mathbf{s}(\omega) \left| A - \frac{\mathbf{s}^H(\omega) \mathbf{x}}{\mathbf{s}^H(\omega) \mathbf{s}(\omega)} \right|^2 + \mathbf{x}^H \mathbf{x} - \frac{|\mathbf{s}^H(\omega) \mathbf{x}|^2}{\mathbf{s}^H(\omega) \mathbf{s}(\omega)} \end{aligned}$$

et l'estimateur ML de A est alors

$$\hat{A}^{ML} = \frac{\mathbf{s}^H(\hat{\omega}^{ML}) \mathbf{x}}{\mathbf{s}^H(\hat{\omega}^{ML}) \mathbf{s}(\hat{\omega}^{ML})}.$$

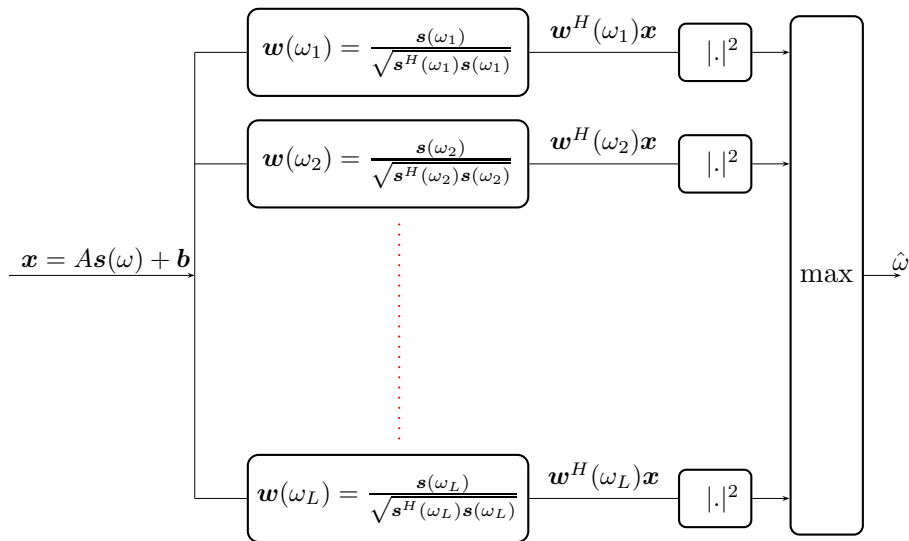
Exemple $\mathbf{x} \sim \mathcal{CN}(A\mathbf{s}(\omega), \sigma^2\mathbf{I})$

- L'estimateur ML de ω est donc obtenu comme

$$\begin{aligned}\hat{\omega}^{ML} &= \arg \max_{\omega} \frac{|\mathbf{s}^H(\omega)\mathbf{x}|^2}{\mathbf{s}^H(\omega)\mathbf{s}(\omega)} \\ &= \arg \max_{\omega} \mathbf{x}^H \mathbf{P}_{\mathbf{s}(\omega)} \mathbf{x}; & \mathbf{P}_{\mathbf{s}(\omega)} &= \frac{\mathbf{s}(\omega)\mathbf{s}^H(\omega)}{\mathbf{s}^H(\omega)\mathbf{s}(\omega)} \\ &= \arg \max_{\omega} |\mathbf{w}^H(\omega)\mathbf{x}|^2; & \mathbf{w}(\omega) &= \frac{\mathbf{s}(\omega)}{\sqrt{\mathbf{s}^H(\omega)\mathbf{s}(\omega)}}\end{aligned}$$

- Il peut s'interpréter comme
 - 1 la valeur de ω qui maximise la norme de la projection de \mathbf{x} sur la variété $\mathbf{s}(\omega)$;
 - 2 la valeur de ω qui maximise la puissance en sortie du **filtre adapté** $\mathbf{w}(\omega)$.

Filtre adapté (bruit blanc Gaussien)



Exemple $\mathbf{x} \sim \mathcal{CN}(A\mathbf{s}(\omega), \sigma^2\mathbf{I})$

- Le rapport signal sur bruit en entrée du filtre adapté s'écrit

$$RSB_{\text{in}} = \frac{|A|^2 \mathbf{s}^H(\omega) \mathbf{s}(\omega)}{\mathbb{E}\{\mathbf{b}^H \mathbf{b}\}} = \frac{|A|^2 \mathbf{s}^H(\omega) \mathbf{s}(\omega)}{N\sigma^2}.$$

- Le signal en sortie de filtre adapté s'écrit $A\mathbf{w}^H(\omega)\mathbf{s}(\omega) + \mathbf{w}^H(\omega)\mathbf{b}$, ce qui conduit à un rapport signal sur bruit

$$\begin{aligned}RSB_{\text{out}} &= \frac{|A\mathbf{w}^H(\omega)\mathbf{s}(\omega)|^2}{\mathbb{E}\{|\mathbf{w}^H(\omega)\mathbf{b}|^2\}} = \frac{|A\mathbf{w}^H(\omega)\mathbf{s}(\omega)|^2}{\sigma^2 \mathbf{w}^H(\omega)\mathbf{w}(\omega)} \\ &= \frac{|A|^2 \mathbf{s}^H(\omega)\mathbf{s}(\omega)}{\sigma^2} = N \times RSB_{\text{in}}.\end{aligned}$$

Le filtre adapté permet un gain de traitement (gain en RSB) de N .

Exemple $x \sim \mathcal{CN}(As(\omega), \sigma^2 \mathbf{I})$

- **Cas d'un retard** : si $x(t) = As(t - \tau) + b(t)$ et si la forme d'onde $s(t)$ a une énergie constante

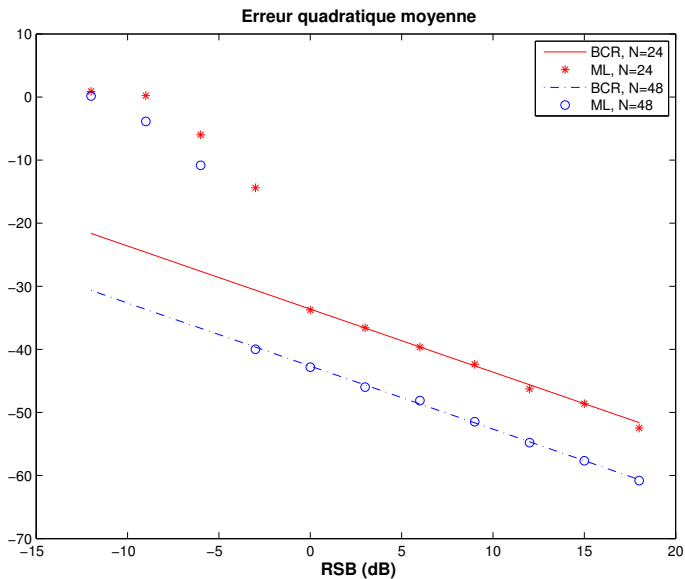
$$\hat{\tau}^{ML} = \arg \max_{\tau} \left| \sum_t x(t) s^*(t - \tau) \right|^2 .$$

- **Exponentielle complexe** : si $x(n) = Ae^{in\omega} + b(n)$ alors

$$\hat{\omega}^{ML} = \arg \max_{\omega} \frac{1}{N} \left| \sum_{n=0}^{N-1} x(n) e^{-in\omega} \right|^2$$

qui n'est autre que le maximum du **périodogramme** du signal, i.e. le module carré de sa transformée de Fourier.

ML et BCR pour une exponentielle complexe



Remarques

- Sous hypothèse **Gaussienne** $x \sim \mathcal{N}(s(\theta), C)$ avec C connue, l'estimateur ML revient à résoudre un **problème des moindres carrés** :
 - moindres carrés linéaires si $s(\theta) = H\theta$: dans ce cas on a une solution analytique ;
 - moindres carrés non linéaires si $s(\theta)$ n'est pas linéaire en θ : dans ce cas, on a recours à des méthodes itératives -utilisant gradient et éventuellement Hessien de $p(x; \theta)$ - pour trouver l'estimateur.
- Dans le cas où $\theta = [\theta_{\text{lin}} \quad \theta_{\text{nonlin}}]^T$ et où $s(\theta)$ est linéaire par rapport à θ_{lin} et non linéaire par rapport à θ_{nonlin} , on minimise explicitement $p(x; \theta)$ par rapport à θ_{lin} . On reporte dans la fonction de vraisemblance, et il reste un problème non linéaire par rapport à θ_{nonlin} .
- Les méthodes des moindres carrés sont également souvent utilisées lorsque la loi n'est plus Gaussienne : dans ce cas, on privilégie la facilité d'implémentation au détriment de l'optimalité.

Synthèse

- De part ses propriétés d'optimalité asymptotique et compte tenu de sa formulation (maximisation d'une fonction), l'estimateur du maximum de vraisemblance est très souvent utilisé.
- Les problèmes auxquels il se heurte :
 - difficulté à résoudre le problème de maximisation, par exemple due à la présence de nombreux maxima locaux
 - coût calculatoire parfois élevé dû à une maximisation compliquée, par exemple

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

- estimation peu précise à faible RSB ou faible N (mais dans ce cas peu d'estimateurs feront mieux que le ML)

Principe

Exploiter les propriétés des moments du signal (notamment la fonction de corrélation) et leur relation avec θ : par exemple, si $\theta = \mathbf{g}(r_{xx}(0), \dots, r_{xx}(M-1))$ où $r_{xx}(m) = \mathbb{E}\{x^*(n)x(n+m)\}$ est la fonction de corrélation de $x(n)$, on peut envisager l'estimateur

$$\hat{\theta} = \mathbf{g}(\hat{r}_{xx}(0), \dots, \hat{r}_{xx}(M-1))$$

où $\hat{r}_{xx}(m)$ désigne une estimée de $r_{xx}(m)$.

Avantages et inconvénients

- ☺ Estimateurs souvent simples à mettre en œuvre et ne nécessitant pas d'hypothèses sur la loi de $x(n)$.
- ☹ Pas d'optimalité (analyse statistique au cas par cas).

Exponentielle complexe

Soit le signal $x(n) = Ae^{i(n\omega_0 + \phi)} + b(n)$, $n = 0, \dots, N-1$, où $b(n)$ est un bruit blanc complexe de moyenne nulle. On a alors

$$r_{xx}(m) = E\{x^*(n)x(n+m)\} = A^2 e^{im\omega_0} + \sigma^2 \delta(m)$$

et, par exemple,

$$\omega_0 = \text{angle}[r_{xx}(1)]$$

ce qui suggère une estimation possible de ω_0 comme

$$\hat{\omega}_0 = \text{angle}[\hat{r}_{xx}(1)] = \text{angle}\left[\frac{1}{N-1} \sum_{n=0}^{N-2} x^*(n)x(n+1)\right].$$

Analyse statistique

Soit $\hat{\boldsymbol{\theta}} = \mathbf{f}(\hat{\mathbf{t}})$ où $\hat{\mathbf{t}}$ est un vecteur contenant des estimées de certains moments du signal, par exemple $\hat{\mathbf{t}} = [\hat{r}_{xx}(0) \ \cdots \ \hat{r}_{xx}(M-1)]^T$. En supposant que $\hat{\mathbf{t}}$ est un estimateur consistant de \mathbf{t} , on peut écrire un développement de Taylor au voisinage de \mathbf{t} :

$$\hat{\boldsymbol{\theta}} = \mathbf{f}(\hat{\mathbf{t}}) \simeq \mathbf{f}(\mathbf{t}) + \left[\frac{\partial \mathbf{f}}{\partial \mathbf{t}^T} \right]_{\mathbf{t}} (\hat{\mathbf{t}} - \mathbf{t}).$$

On en déduit alors $\mathbb{E}\{\hat{\boldsymbol{\theta}}\} \simeq \mathbf{f}(\mathbf{t})$ et

$$\text{cov}(\hat{\boldsymbol{\theta}}) \simeq \left[\frac{\partial \mathbf{f}}{\partial \mathbf{t}^T} \right]_{\mathbf{t}} \mathbb{E}\{(\hat{\mathbf{t}} - \mathbf{t})(\hat{\mathbf{t}} - \mathbf{t})^T\} \left[\frac{\partial \mathbf{f}}{\partial \mathbf{t}^T} \right]_{\mathbf{t}}^T.$$

$\mathbb{E}\{(\hat{\mathbf{t}} - \mathbf{t})(\hat{\mathbf{t}} - \mathbf{t})^T\}$ est souvent connu, du moins pour une grande classe de processus stationnaires.

Analyse à fort rapport signal sur bruit (RSB)

Dans le cas d'un signal déterministe noyé dans un bruit blanc $x(n) = s(n; \boldsymbol{\theta}) + b(n)$, pour lequel $\boldsymbol{\theta} = \mathbf{f}(s(\boldsymbol{\theta}))$, on fait souvent l'analyse à **fort RSB** en considérant $\mathbf{t} = \mathbf{x}$. On a alors


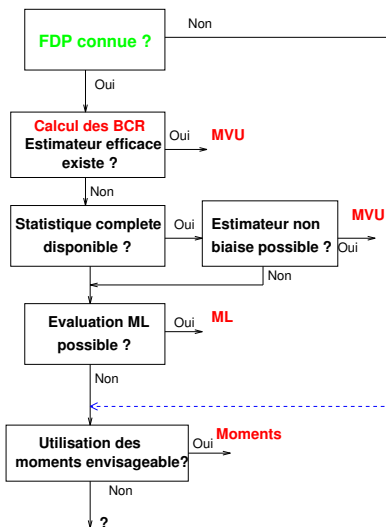
$$\hat{\boldsymbol{\theta}} = \mathbf{f}(\mathbf{x}) = \mathbf{f}(s(\boldsymbol{\theta}) + \mathbf{b}) \simeq \mathbf{f}(s(\boldsymbol{\theta})) + \left[\frac{\partial \mathbf{f}}{\partial \mathbf{x}^T} \right]_{s(\boldsymbol{\theta})} \mathbf{b}.$$

La moyenne et la matrice de covariance asymptotique (i.e. à fort RSB) s'en déduisent

$$\begin{aligned} \mathbb{E}\{\hat{\boldsymbol{\theta}}\} &\simeq \mathbf{f}(s(\boldsymbol{\theta})) = \boldsymbol{\theta} \\ \text{cov}(\hat{\boldsymbol{\theta}}) &\simeq \left[\frac{\partial \mathbf{f}}{\partial \mathbf{x}^T} \right]_{s(\boldsymbol{\theta})} \mathbb{E}\{\mathbf{b}\mathbf{b}^T\} \left[\frac{\partial \mathbf{f}}{\partial \mathbf{x}^T} \right]_{s(\boldsymbol{\theta})}^T. \end{aligned}$$

Comment chercher un estimateur ?

RECHERCHE ESTIMATEUR OPTIMAL



APPROCHE MOINDRES CARRES

① Introduction - Problématique

② Approche déterministe

③ Approche Bayésienne

Principe

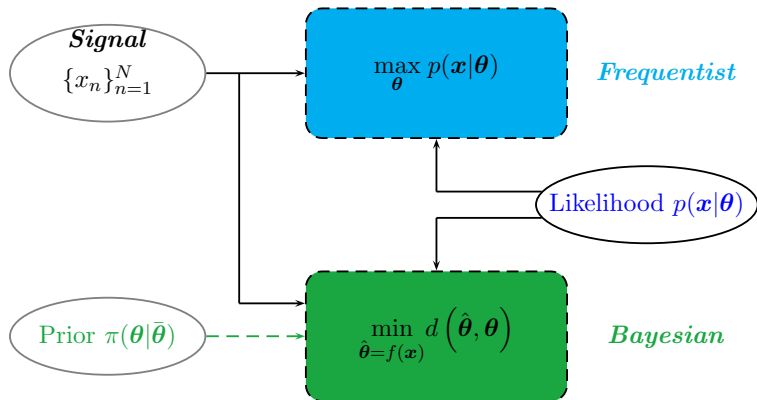
Estimateur MMSE

Maximum a posteriori

Borne Bayésienne

Exemples

Approche Bayésienne vs approche déterministe



Principe

Considérer le vecteur paramètre θ à estimer comme **aléatoire**, avec une **loi a priori** $\pi(\theta)$: nécessite d'avoir une information a priori sur θ .

Caractérisation

On considère alors la loi jointe $p(\mathbf{x}, \theta) = p(\mathbf{x}|\theta) \pi(\theta)$.

Loi a posteriori

La **loi a posteriori**

$$p(\theta|\mathbf{x}) = \frac{p(\mathbf{x}, \theta)}{p(\mathbf{x})} = \frac{p(\mathbf{x}|\theta) \pi(\theta)}{\int p(\mathbf{x}, \theta) d\theta}$$

synthétise l'information sur θ apportée par l'a priori et par les données.

Lois conjuguées

Des lois sont dites **conjuguées** si elles appartiennent à la même famille. Par exemple, si

$$\begin{aligned} p(\mathbf{x}|\mu, \sigma^2) &\propto (\sigma^2)^{-N/2} \exp\left\{-\frac{1}{2\sigma^2} (\mathbf{x} - \mu\mathbf{s})^T (\mathbf{x} - \mu\mathbf{s})\right\} \\ &\propto (\sigma^2)^{-N/2} \exp\left\{-\frac{\sigma^{-2}}{2} \left[\mathbf{x}^T \mathbf{x} - \frac{(\mathbf{s}^T \mathbf{x})^2}{\mathbf{s}^T \mathbf{s}} + (\mathbf{s}^T \mathbf{s}) \left(\mu - \frac{\mathbf{s}^T \mathbf{x}}{\mathbf{s}^T \mathbf{s}} \right)^2 \right]\right\} \end{aligned}$$

alors la loi conjuguée pour μ est $\mathcal{N}(\bar{\mu}, \sigma_\mu^2)$ et celle pour σ^2 est $\mathcal{IG}(a, b)$:

$$\begin{aligned} \pi(\mu) &\propto \exp\left\{-\frac{1}{2\sigma_\mu^2} (\mu - \bar{\mu})^2\right\} \\ \pi(\sigma^2) &\propto (\sigma^2)^{-(a+1)} \exp\{-b\sigma^{-2}\}. \end{aligned}$$

Estimateur MMSE

L'estimateur qui minimise l'erreur quadratique moyenne est donné par

$$\begin{aligned}\hat{\boldsymbol{\theta}}^{\text{mmse}} &= \arg \min_{\hat{\boldsymbol{\theta}}=f(\mathbf{x})} E_{\mathbf{x},\boldsymbol{\theta}}\{(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T\} \\ &= E_{\boldsymbol{\theta}|\mathbf{x}}\{\boldsymbol{\theta}\} = \int \boldsymbol{\theta} p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta}.\end{aligned}$$

Démonstration MMSE

On note tout d'abord que l'eqm s'écrit

$$\text{eqm}(\hat{\boldsymbol{\theta}}) = \int \left[\int (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \right] p(\mathbf{x}) d\mathbf{x}.$$

L'intégrale interne s'écrit

$$\begin{aligned} & \int (\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}} - \boldsymbol{\theta})^T p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \\ &= \hat{\boldsymbol{\theta}}\hat{\boldsymbol{\theta}}^T - \mathbb{E}_{\boldsymbol{\theta}|\mathbf{x}}\{\boldsymbol{\theta}\}\hat{\boldsymbol{\theta}}^T - \hat{\boldsymbol{\theta}}\mathbb{E}_{\boldsymbol{\theta}|\mathbf{x}}\{\boldsymbol{\theta}\}^T + \int \boldsymbol{\theta}\boldsymbol{\theta}^T p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \\ &= (\hat{\boldsymbol{\theta}} - \hat{\boldsymbol{\theta}}^{\text{mmse}})(\hat{\boldsymbol{\theta}} - \hat{\boldsymbol{\theta}}^{\text{mmse}})^T + \int (\hat{\boldsymbol{\theta}}^{\text{mmse}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}}^{\text{mmse}} - \boldsymbol{\theta})^T p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \\ &\geq \int (\hat{\boldsymbol{\theta}}^{\text{mmse}} - \boldsymbol{\theta})(\hat{\boldsymbol{\theta}}^{\text{mmse}} - \boldsymbol{\theta})^T p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \end{aligned}$$

ce qui démontre le résultat.

Remarques

- L'estimateur MMSE correspond à la **moyenne a posteriori** de θ , **conditionnellement à x** : nécessité de calculer cette loi.
- L'estimateur MMSE est non biaisé car

$$\mathbb{E}_{\mathbf{x}, \theta} \{ \hat{\theta}^{\text{mmse}} - \theta \} = \mathbb{E}_{\mathbf{x}} \{ \mathbb{E}_{\theta|\mathbf{x}} \{ \hat{\theta}^{\text{mmse}} - \theta \} \} = \mathbb{E}_{\mathbf{x}} \{ \mathbf{0} \} = \mathbf{0}.$$

- Sa matrice de covariance s'écrit

$$\mathbb{E}_{\mathbf{x}, \theta} \{ (\hat{\theta}^{\text{mmse}} - \theta)(\hat{\theta}^{\text{mmse}} - \theta)^T \} = \mathbb{E}_{\mathbf{x}} \{ \mathbf{C}_{\theta|\mathbf{x}} \}$$

où $\mathbf{C}_{\theta|\mathbf{x}} = \mathbb{E}_{\theta|\mathbf{x}} \{ (\theta - \mathbb{E}_{\theta|\mathbf{x}} \{ \theta \})(\theta - \mathbb{E}_{\theta|\mathbf{x}} \{ \theta \})^T \}$ est la matrice de covariance a posteriori de θ .

Estimateur MAP

$$\begin{aligned}\hat{\boldsymbol{\theta}}^{\text{map}} &= \arg \max_{\boldsymbol{\theta}} p(\boldsymbol{\theta}|\mathbf{x}) = \arg \max_{\boldsymbol{\theta}} \Lambda(\boldsymbol{\theta}|\mathbf{x}) \\ &= \arg \max_{\boldsymbol{\theta}} [\Lambda(\mathbf{x}|\boldsymbol{\theta}) + \Lambda(\boldsymbol{\theta})].\end{aligned}$$

Lien avec l'estimateur ML

Si $\mathbf{x} \sim \mathcal{N}(s(\boldsymbol{\theta}), \mathbf{C})$ et $\boldsymbol{\theta} \sim \mathcal{N}(\bar{\boldsymbol{\theta}}, \mathbf{C}_{\boldsymbol{\theta}})$, alors

$$\hat{\boldsymbol{\theta}}^{\text{map}} = \arg \min_{\boldsymbol{\theta}} \left\{ [\mathbf{x} - s(\boldsymbol{\theta})]^T \mathbf{C}^{-1} [\mathbf{x} - s(\boldsymbol{\theta})] + (\boldsymbol{\theta} - \bar{\boldsymbol{\theta}})^T \mathbf{C}_{\boldsymbol{\theta}}^{-1} (\boldsymbol{\theta} - \bar{\boldsymbol{\theta}})^T \right\}$$

et l'estimateur MAP peut être vu comme un **estimateur ML régularisé**.

Borne Bayésienne

L'eqm est bornée inférieurement par $\mathbf{I}_B^{-1}(\boldsymbol{\theta})$ où

$$\begin{aligned}\mathbf{I}_B(\boldsymbol{\theta}) &= \mathbb{E}_{\mathbf{x}, \boldsymbol{\theta}} \left\{ -\frac{\partial^2 \Lambda(\mathbf{x}, \boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\} \\ &= \mathbb{E}_{\boldsymbol{\theta}} \left\{ \mathbb{E}_{\mathbf{x}|\boldsymbol{\theta}} \left\{ -\frac{\partial^2 \Lambda(\mathbf{x}|\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} - \frac{\partial^2 \Lambda(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\} \right\} \\ &= \mathbb{E}_{\boldsymbol{\theta}} \left\{ \mathbb{E}_{\mathbf{x}|\boldsymbol{\theta}} \left\{ -\frac{\partial^2 \Lambda(\mathbf{x}|\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\} - \frac{\partial^2 \Lambda(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\} \\ &= \mathbb{E}_{\boldsymbol{\theta}} \{ \mathbf{I}(\boldsymbol{\theta}) \} + \mathbb{E}_{\boldsymbol{\theta}} \left\{ -\frac{\partial^2 \Lambda(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} \right\}.\end{aligned}$$

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$

$$I_B(\theta) = \frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \geq \frac{N}{\sigma^2} = I(\theta).$$

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$

On a alors

$$p(\mathbf{x}|\theta) \propto \exp \left\{ -\frac{1}{2\sigma^2} (\mathbf{x} - \theta \mathbf{1})^T (\mathbf{x} - \theta \mathbf{1}) \right\}$$

$$\pi(\theta) \propto \exp \left\{ -\frac{1}{2\sigma_\theta^2} (\theta - \bar{\theta})^2 \right\}.$$

La loi a posteriori s'écrit donc

$$p(\theta|\mathbf{x}) \propto \exp \left\{ -\frac{1}{2} \left[\theta^2 \left(\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \right) - 2\theta \left(\frac{\mathbf{x}^T \mathbf{1}}{\sigma^2} + \frac{\bar{\theta}}{\sigma_\theta^2} \right) \right] \right\}.$$

Estimation Bayésienne : exemple

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$

Par conséquent, $\theta | \mathbf{x} \sim \mathcal{N}(\mu_{\theta | \mathbf{x}}, \sigma_{\theta | \mathbf{x}}^2)$ avec

$$\mu_{\theta | \mathbf{x}} = \left(\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \right)^{-1} \left(\frac{\mathbf{x}^T \mathbf{1}}{\sigma^2} + \frac{\bar{\theta}}{\sigma_\theta^2} \right); \quad \sigma_{\theta | \mathbf{x}}^2 = \left(\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \right)^{-1}.$$


L'estimateur MMSE s'écrit donc

$$\begin{aligned} \hat{\theta}^{\text{mmse}} &= \left(\frac{N}{\sigma^2} + \frac{1}{\sigma_\theta^2} \right)^{-1} \left(\frac{\mathbf{x}^T \mathbf{1}}{\sigma^2} + \frac{\bar{\theta}}{\sigma_\theta^2} \right) \\ &= \frac{N\sigma_\theta^2}{\sigma^2 + N\sigma_\theta^2} \frac{\mathbf{x}^T \mathbf{1}}{N} + \frac{\sigma^2}{\sigma^2 + N\sigma_\theta^2} \bar{\theta} \\ &= \alpha \hat{\theta}^{\text{ml}} + (1 - \alpha) \bar{\theta}. \end{aligned}$$

C'est une combinaison de l'estimateur ML et de l'information a priori $\bar{\theta}$.

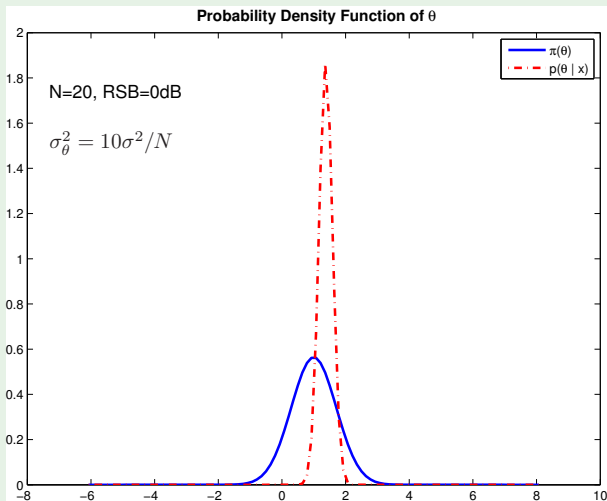
Estimation Bayésienne : exemple

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$



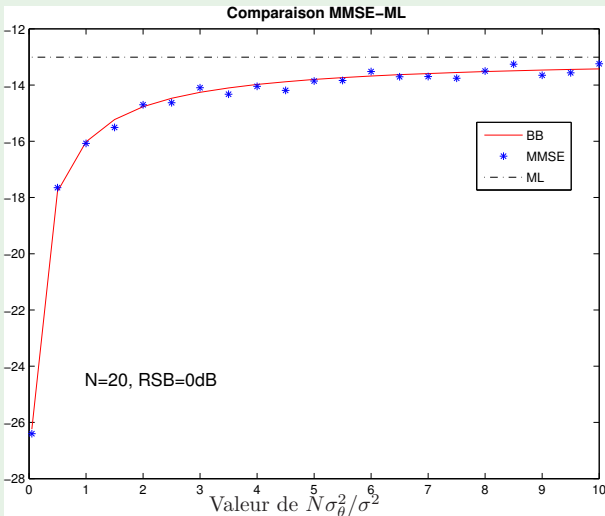
Estimation Bayésienne : exemple

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$



Estimation Bayésienne : exemple

Exemple $x(n) = \theta + b(n)$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \sigma^2 \mathbf{I})$ et $\theta \sim \mathcal{N}(\bar{\theta}, \sigma_\theta^2)$



Modèle linéaire

Soit le modèle linéaire $\mathbf{x} = \mathbf{H}\boldsymbol{\theta} + \mathbf{b}$ avec $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \mathbf{C})$ et $\boldsymbol{\theta} \sim \mathcal{N}(\bar{\boldsymbol{\theta}}, \mathbf{C}_{\boldsymbol{\theta}})$.
On a alors les lois suivantes

$$p(\mathbf{x}|\boldsymbol{\theta}) \propto \exp \left\{ -\frac{1}{2} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta})^T \mathbf{C}^{-1} (\mathbf{x} - \mathbf{H}\boldsymbol{\theta}) \right\}$$
$$\pi(\boldsymbol{\theta}) \propto \exp \left\{ -\frac{1}{2} (\boldsymbol{\theta} - \bar{\boldsymbol{\theta}})^T \mathbf{C}_{\boldsymbol{\theta}}^{-1} (\boldsymbol{\theta} - \bar{\boldsymbol{\theta}}) \right\}.$$

La loi a posteriori est dans ce cas

$$p(\boldsymbol{\theta}|\mathbf{x}) \propto \exp \left\{ -\frac{1}{2} \boldsymbol{\theta}^T (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} + \mathbf{C}_{\boldsymbol{\theta}}^{-1}) \boldsymbol{\theta} \right\}$$
$$\times \exp \left\{ \boldsymbol{\theta}^T (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{x} + \mathbf{C}_{\boldsymbol{\theta}}^{-1} \bar{\boldsymbol{\theta}}) \right\}.$$

Modèle linéaire

$\theta|x$ est donc distribuée selon une loi normale, de moyenne et de matrice de covariance

$$\begin{aligned}\mu_{\theta|x} &= (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} + \mathbf{C}_{\theta}^{-1})^{-1} (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{x} + \mathbf{C}_{\theta}^{-1} \bar{\theta}) \\ \mathbf{C}_{\theta|x} &= (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} + \mathbf{C}_{\theta}^{-1})^{-1}.\end{aligned}$$

L'estimateur MMSE est donc

$$\hat{\theta}^{\text{mmse}} = (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{H} + \mathbf{C}_{\theta}^{-1})^{-1} (\mathbf{H}^T \mathbf{C}^{-1} \mathbf{x} + \mathbf{C}_{\theta}^{-1} \bar{\theta}).$$

Puisque $\mathbf{C}_{\theta|x}$ ne dépend pas de x , la matrice de covariance de $\hat{\theta}^{\text{mmse}}$ est $\mathbb{E}_x \{ \mathbf{C}_{\theta|x} \} = \mathbf{C}_{\theta|x}$.

- Dans de nombreux cas, la loi a posteriori $p(\boldsymbol{\theta}|\mathbf{x})$ n'appartient pas nécessairement à une famille connue et on n'a pas d'expression analytique de $\int \boldsymbol{\theta} p(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta}$. Dans ce cas, une solution consiste à utiliser des méthodes de simulation qui génèrent des variables aléatoires $\boldsymbol{\theta}_n$ distribuées selon $p(\boldsymbol{\theta}|\mathbf{x})$. On approxime alors l'intégrale par

$$\hat{\boldsymbol{\theta}}^{\text{mmse}} \simeq \frac{1}{N_r} \sum_{n=1}^{N_r} \boldsymbol{\theta}_n.$$

- L'approche Bayésienne peut être utilisée pour l'estimation de paramètres déterministes : dans ce cas, on choisit en général des lois a priori $\pi(\boldsymbol{\theta})$ peu informatives.
- L'utilisation d'une information a priori permet "d'aider" l'estimation dans des cas difficiles tels que faible RSB ou faible N .

- 1 Steven M. Kay, *Fundamentals of Statistical Signal Processing : Estimation Theory*, Prentice Hall, Englewood Cliffs, NJ, 1993
- 2 Louis L. Scharf, *Statistical Signal Processing : Detection, Estimation and Time Series Analysis*, Addison Wesley, Reading, MA, 1991
- 3 Harry L. Van Trees, *Detection, estimation and modulation theory, Part I*, John Wiley, 2004
- 4 Harry L. Van Trees, Kristine L. Bell *Detection, estimation and modulation theory, 2nd Edition, Part I, Detection, Estimation, and Filtering Theory*, John Wiley, 2013
- 5 Christian Robert, *The Bayesian Choice - From Decision-Theoretic Foundations to Computational Implementation*, Springer Verlag, 2007
- 6 Christian Robert, George Casella *Monte-Carlo statistical methods, 2nd edition*, Springer Verlag, 2004