

# Introduction au cours.

*Contenu et organisation.*

- Méthodologies de construction d'estimateurs de paramètres.
- Méthodologies d'évaluation des performances des estimateurs.
- Applications aux communications numériques.

3 intervenants : J.P. Barbot (ENS Cachan), W. Hachem (Supelec), Ph. Loubaton (UMLV).

Exemples: synchronisation

Signal transmis  $x(t) = \sum_{n \in \mathbb{Z}} a_n g(t - nT)$ .

Dans le cas d'un canal mono-trajet, et présence d'un offset de fréquence

Signal reçu.

$$\begin{aligned} y(t) &= \lambda x(t - \tau) e^{2i\pi\delta f_0 t} + b(t) \\ &= \mu e^{i\phi_0} \left( \sum_{n \in \mathbb{Z}} a_n g(t - \tau - nT) \right) e^{2i\pi\delta f_0 t} + b(t) \end{aligned}$$

Exemples: synchronisation

$$y(t) = \mu e^{i\phi_0} \left( \sum_{n \in \mathbb{Z}} a_n g(t - \tau - nT) \right) e^{2i\pi\delta f_0 t} + b(t)$$

A partir d'échantillons prélevés à la période  $T$  ou  $\frac{T}{2}$ , estimer  $\phi_0, \delta f_0, \tau$ .

- Contexte entraîné : les  $a_n$  connus sur la durée d'observation (séquence d'apprentissage).
- Contexte aveugle : les  $a_n$  inconnus sur la durée d'observation.
- Contexte semi-aveugle : une partie des  $a_n$  est connue sur la durée d'observation.

Exemples: estimation de canal.

Signal transmis  $x(t) = \sum_{n \in \mathbb{Z}} a_n g(t - nT)$ .

Dans le cas d'un canal multi-trajets-trajet, sans offset de fréquence

Signal reçu :  $y(t) = \sum_k \lambda_k x(t - \tau_k) + b(t)$

A partir d'échantillons prélevés à la période  $T$  ou  $\frac{T}{2}$ , estimer les  $(\lambda_k, \tau_k)$ .

**Autre formulation.**

Signal reçu :  $y(t) = \sum_n a_n h(t - nT) + b(t)$

$$h(t) = \sum_k \lambda_k g(t - \tau_k)$$

Si  $y_n = y(nT)$ ,  $y_n = \sum_l h_l a_{n-l} + b_n$

Estimer  $h_0, \dots, h_L$  à partir de  $(y_n)_{n=0, \dots, N-1}$ .

*Le formalisme de l'estimation statistique.*

L'observation:  $\mathbf{y} = (y_0, y_1, \dots, y_N)^T$  vecteur aléatoire.

La densité de probabilité de  $\mathbf{y}$  est connue à un nombre fini de paramètres près

Notations:  $\theta$  le vecteur des paramètres inconnus, de dimension  $K$ ,  $p_\theta(\mathbf{x})$  la densité de probabilité de  $\mathbf{y}$ .

Le problème: on observe  $\mathbf{y} = (y_0, y_1, \dots, y_N)^T$ , et il s'agit d'estimer  $\theta$ .

Estimateur  $\hat{\theta}$  correspondance qui à  $\mathbf{y}$  associé un vecteur de dimension  $K$  noté  $\hat{\theta}(\mathbf{y})$ .

Exemple: estimation entraînée de canal.

L'observation  $y_n = \sum_{l=0}^L h_l a_{n-l} + b_n$ , pour  $n = 0, \dots, N-1$ .

Estimation entraînée: les symboles  $a_{-L}, \dots, a_0, \dots, a_{N-1}$  sont connus.

$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{b}$ .

- $\mathbf{h} = (h_0, \dots, h_L)^T$ ,  $\mathbf{b} = (b_0, \dots, b_{N-1})^T$

- $\mathbf{A} = \begin{pmatrix} a_0 & a_1 & \dots & a_{-L} \\ a_1 & a_0 & \dots & a_{-(L-1)} \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ a_{N-1} & a_{N-2} & \dots & a_{N-1-L} \end{pmatrix}$

Exemple: estimation entraînée de canal.

Le paramètre  $\theta = \mathbf{h}$ .

On suppose que  $\mathbf{b}$  est blanc Gaussien complexe de variance  $\sigma^2$ .

$$p_{\mathbf{h}}(\mathbf{x}) = \frac{1}{\pi^N \sigma^{2N}} \exp - \frac{\|\mathbf{x} - \mathbf{A}\mathbf{h}\|^2}{\sigma^2}$$

Estimateurs "raisonnables"

- Moindre carrés :  $\min_{\mathbf{h}} \|\mathbf{y} - \mathbf{A}\mathbf{h}\|^2$ ,  $\hat{\mathbf{h}} = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{y}$ .
- Si les colonnes de  $\mathbf{A}$  sont proches d'être orthogonales,  $\hat{\mathbf{h}} = \frac{1}{N} \mathbf{A}^H \mathbf{y}$



Exemple: synchronisation en fréquence.

L'observation:  $y_n = \lambda a_n e^{2i\pi n \delta f_0} + b_n$ , estimer  $\delta f_0$ .

Estimation entraînée: les symboles  $a_L, \dots, a_0, \dots, a_N$  sont connus, et de module 1.

$\lambda$  inconnu,  $\delta f_0$  inconnu,  $\theta = (\lambda, \delta f_0)$

$$p_{\theta}(\mathbf{x}) = \frac{1}{\pi^N \sigma^{2N}} \exp - \frac{\sum_{n=0}^{N-1} |y_n - \lambda a_n e^{2i\pi n \delta f_0}|^2}{\sigma^2}$$

**Estimateurs "raisonnables"**

- $\hat{\delta f}_0 = \text{Arg}\left(\frac{1}{N} \sum_{n=0}^{N-1} y_n y_{n-1}^* a_n^* a_{n-1}\right)$
- $\hat{\delta f}_0$  maximise  $\left| \frac{1}{N} \sum_{n=0}^{N-1} y_n a_n^* e^{-2i\pi \delta f} \right|^2$

## Comparaison des estimateurs.

Biais.

$$\mathbf{b}_{\hat{\theta}}(\theta) = \mathbb{E}_{\theta} \left( (\hat{\theta}(\mathbf{y}) - \theta) \right)$$

Covariance et erreur quadratique moyenne

$$\mathbf{\Gamma}_{\hat{\theta}}(\theta) = \mathbb{E}_{\theta} \left( (\hat{\theta}(\mathbf{y}) - \theta)(\hat{\theta}(\mathbf{y}) - \theta)^H \right)$$

$$R_{\hat{\theta}}(\theta) = \mathbb{E}_{\theta} \left( \|\hat{\theta}(\mathbf{y}) - \theta\|^2 \right) = \text{Trace}(\mathbf{\Gamma}_{\hat{\theta}}(\theta))$$

Ces quantités dépendent de  $\theta$ .

Inégalité de Cramer Rao.

Information de Fisher :  $\mathbf{I}(\theta) = \mathbf{E} \left( \frac{\partial}{\partial \theta} \log p_{\theta}(\mathbf{y}) \frac{\partial}{\partial \theta} \log p_{\theta}(\mathbf{y})^H \right)$ .

Aussi égal à  $\mathbf{I}(\theta) = -\mathbf{E}_{\theta} \left( \frac{\partial^2}{\partial \theta^2} \log p_{\theta}(\mathbf{y}) \right)$ .

**Théorème 1** Si  $\hat{\theta}(\mathbf{y})$  est un estimateur sans biais, alors pour tout  $\theta$ ,

$$\mathbf{\Gamma}_{\hat{\theta}}(\theta) \geq \mathbf{I}^{-1}(\theta)$$

Exemple: estimation de canal.

$$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{b}.$$

$$\text{Information de Fisher: } \mathbf{I}(\mathbf{h}) = \frac{\mathbf{A}^H \mathbf{A}}{\sigma^2}.$$

$$\text{Borne de Cramer Rao : } \sigma^2 (\mathbf{A}^H \mathbf{A})^{-1}.$$

Coincide avec la variance de l'estimateur des moindres carrés.

Exemple: synchronisation.

$$y_n = \lambda a_n e^{2i\pi n \delta f_0} + b_n, \quad n = 0, \dots, N-1$$

- Les  $(a_n)_{n=0, \dots, N-1}$  sont connus et de modules 1.
- $\lambda$  est réel et positif.

Se ramène au modèle:  $y_n = \lambda e^{2i\pi n \delta f_0} + b_n, \quad n = 0, \dots, N-1, \quad \theta = (\lambda, \delta f_0)^T$ .

$$(\mathbf{I}(\theta))^{-1} = \begin{pmatrix} \frac{\sigma^2}{2N} & 0 \\ 0 & \frac{\sigma^2}{\lambda} \frac{3}{4\pi^2 N(N+1)(2N+1)} \end{pmatrix}$$

Estimateur du maximum de vraisemblance.

$\hat{\theta}_{ml}$  maximise en  $\theta$   $\log p_{\theta}(y)$ .

**Exemples.**

- Estimation de canal :  $\hat{\mathbf{h}}_{ml} = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{y}$ .
- Synchronisation,  $\lambda$  réel :

$$\delta \hat{f}_{0ml} = \operatorname{Argmax} \left| \frac{1}{N} \sum_{n=0}^{N-1} y_n e^{-2i\pi n \delta f} \right|^2$$
$$\hat{\lambda}_{ml} = \left| \frac{1}{N} \sum_{n=0}^{N-1} y_n e^{-2i\pi n \delta \hat{f}_{0ml}} \right|$$

Propriétés asymptotiques des estimateurs.

Comportement des estimateurs quand  $N \rightarrow +\infty$ .

**Définition 1**  $\hat{\theta}_N(\mathbf{y})$  consistant si  $\hat{\theta}_N(\mathbf{y}) \rightarrow \theta$  presque sûrement.

Tous les estimateurs "raisonnables" sont consistants.

**Définition 2**  $\hat{\theta}_N(\mathbf{y})$  est asymptotiquement gaussien si il existe  $\alpha > 0$  tel que  $N^\alpha (\hat{\theta}_N(\mathbf{y}) - \theta) \rightarrow \mathcal{N}(0, \Delta(\theta))$ .

$\mathcal{N}(0, \Delta(\theta))$  gaussienne centrée de covariance  $\Delta(\theta)$ .

Propriétés asymptotiques de l'estimateur du maximum de vraisemblance.

Les  $(y_n)_{n=0, \dots, N-1}$  indépendantes de même loi  $p_\theta(x)$ .

$$\log p_\theta(\mathbf{y}) = \sum_{n=0}^{N-1} \log p_\theta(y_n)$$

$$(\hat{\theta}_N - \theta_0) \simeq - \frac{\left(\frac{\partial}{\partial \theta} \log p_\theta(\mathbf{y})\right)_{\theta_0}}{\left(\frac{\partial^2}{\partial \theta^2} \log p_\theta(\mathbf{y})\right)_{\theta_0}}$$

$$\sqrt{N}(\hat{\theta}_N - \theta_0) \simeq - \frac{\frac{1}{\sqrt{N}} \sum_{n=0}^{N-1} \left(\frac{\partial}{\partial \theta} \log p_\theta(y_n)\right)_{\theta_0}}{\frac{1}{N} \sum_{n=0}^{N-1} \left(\frac{\partial^2}{\partial \theta^2} \log p_\theta(y_n)\right)_{\theta_0}}$$

$$\sqrt{N}(\hat{\theta}_N - \theta_0) \simeq \mathcal{N}(0, \mathbf{I}^{-1}(\theta_0))$$

$\hat{\theta}_N$  est asymptotiquement efficace.



Méthode des moments généralisés.

On suppose que  $E_{\theta}(\mathbf{g}(y_n)) = \mathbf{h}(\theta)$ .

On peut alors estimer  $\theta$  par  $\hat{\theta}$  défini par

$$\hat{\theta} = \text{Argmin} V_N(\mathbf{y}, \theta)$$

où

$$V_N(\mathbf{y}, \theta) = \left\| \frac{1}{N} \sum_{n=0}^{N-1} \mathbf{g}(y_n) - \mathbf{h}(\theta) \right\|$$

Méthode des moments généralisés: exemple.

synchronisation aveugle sans résidu de porteuse et avec symboles binaires.

$y_n = \mu e^{i\phi} a_n + b_n$  avec  $a_n = \pm 1$  inconnus,  $\sigma^2$  connu. Estimer  $\theta = (\mu, \phi)$ .

Utiliser que  $E_\theta(y_n^2) = \mu^2 e^{2i\phi}$  et  $E_\theta(|y_n|^2) = \mu^2 + \sigma^2$ .

Estimer  $E_\theta(y_n^2)$  par  $\frac{1}{N} \sum_{n=0}^{N-1} y_n^2$

Estimer  $E_\theta(|y_n|^2)$  par  $\frac{1}{N} \sum_{n=0}^{N-1} |y_n|^2$

Puis ajuster  $\mu$  et  $\phi$ .

$$\hat{\phi} = \frac{1}{2} \text{Arg} \left( \frac{1}{N} \sum_{n=0}^{N-1} y_n^2 \right)$$
$$\hat{\mu}^2 = \frac{1}{2} \left( \left| \frac{1}{N} \sum_{n=0}^{N-1} y_n^2 \right| + \frac{1}{N} \sum_{n=0}^{N-1} |y_n|^2 \right)$$

Propriétés asymptotiques de la méthode des moments I.

Faire un développement limité au second de  $V_N(\mathbf{y}, \theta)$  au voisinage du vrai paramètre  $\theta_0$ .

$$\hat{\theta}_N - \theta_0 \simeq - \left( \frac{\partial^2}{\partial \theta^2} V_N(\mathbf{y}, \theta) \right)_{\theta=\theta_0}^{-1} \left( \frac{\partial}{\partial \theta} V_N(\mathbf{y}, \theta) \right)_{\theta=\theta_0}$$

Etudier les comportements des 2 termes.

Propriétés asymptotiques de la méthode des moments II.

La dérivée seconde:

$$\frac{\partial^2 V_N}{\partial \theta_k \partial \theta_l} = 2 \frac{\partial \mathbf{h}^T}{\partial \theta_k} \frac{\partial \mathbf{h}}{\partial \theta_l} - 2 \frac{\partial^2 \mathbf{h}^T}{\partial \theta_k \partial \theta_l} \left( \frac{1}{N} \sum_{n=1}^N g(y_n) - \mathbf{h}(\theta) \right)$$

Or,  $\frac{1}{N} \sum_{n=1}^N g(y_n) - \mathbf{h}(\theta_0) \rightarrow 0$ .

Le terme de dérivée seconde converge donc vers  $2 \left( \frac{\partial \mathbf{h}^T}{\partial \theta} \frac{\partial \mathbf{h}}{\partial \theta} \right)_{\theta=\theta_0}$

Propriétés asymptotiques de la méthode des moments II.

La dérivée première:

$$\frac{\partial V_N}{\partial \theta} = -2 \left( \frac{\partial \mathbf{h}^T}{\partial \theta} \right) \left( \frac{1}{N} \sum_{n=1}^N g(y_n) - \mathbf{h}(\theta) \right)$$

Or, dans la plupart des cas,  $\sqrt{N} \left[ \frac{1}{N} \sum_{n=1}^N g(y_n) - \mathbf{h}(\theta_0) \right] \rightarrow \mathcal{N}(0, \Gamma(\theta_0))$ .

Propriétés asymptotiques de la méthode des moments III.

Conclusion:

$$\sqrt{N}(\hat{\theta}_N - \theta_0) \rightarrow \mathcal{N}(0, \Delta(\theta_0))$$

avec

$$\Delta(\theta_0) = \left( \frac{\partial \mathbf{h}^T}{\partial \theta} \frac{\partial \mathbf{h}}{\partial \theta} \right)_{\theta=\theta_0} \left( \left( \frac{\partial \mathbf{h}^T}{\partial \theta} \right)_{\theta_0} \Gamma(\theta_0) \left( \frac{\partial \mathbf{h}}{\partial \theta} \right)_{\theta_0} \right) \left( \frac{\partial \mathbf{h}^T}{\partial \theta} \frac{\partial \mathbf{h}}{\partial \theta} \right)_{\theta=\theta_0}$$

Estimation de canal.

Signal transmis  $x(t) = \sum_{n \in \mathbb{Z}} a_n g(t - nT)$ .

Signal reçu :  $y(t) = \sum_{k=1}^K \lambda_k x(t - \tau_k) + b(t)$

Signal reçu :  $y(t) = \sum_n a_n h(t - nT) + b(t)$

$$h(t) = \sum_{k=1}^K \lambda_k g(t - \tau_k)$$

Si  $y_n = y(nT)$  et  $h_l = h(lT) = \sum_{k=1}^K \lambda_k g(lT - \tau_k)$ , alors  $y_n = \sum_l h_l a_{n-l} + b_n$

Estimation entraînée standard.

L'observation  $y_n = \sum_{l=0}^L h_l a_{n-l} + b_n$ , pour  $n = 0, \dots, N-1$ .

Estimation entraînée: les symboles  $a_{-L}, \dots, a_0, \dots, a_{N-1}$  sont connus.

$\mathbf{y} = \mathbf{A}\mathbf{h} + \mathbf{b}$ .

- $\mathbf{h} = (h_0, \dots, h_L)^T$ ,  $\mathbf{b} = (b_0, \dots, b_{N-1})^T$

- $\mathbf{A} = \begin{pmatrix} a_0 & a_1 & \dots & a_{-L} \\ a_1 & a_0 & \dots & a_{-(L-1)} \\ \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots \\ a_{N-1} & a_{N-2} & \dots & a_{N-1-L} \end{pmatrix}$

$\hat{\mathbf{h}} = (\mathbf{A}^H \mathbf{A})^{-1} \mathbf{A}^H \mathbf{y}$ .



### Estimation entraînée multi-slots I.

Estimer le canal sur chaque slot à partir d'une séquence d'apprentissage.

Sur le slot  $m$ ,  $\mathbf{h}_m = \sum_{k=1}^K \lambda_{k,m} \mathbf{g}(\tau_k)$ , avec :

- les  $(\lambda_{k,m})_{m=1,\dots,M}$  variables aléatoires centrées de même loi
- $K < (L + 1)$
- $\mathbf{g}(\tau_k)$  fixe sur un nombre de slots raisonnables.

Profiter de ce modèle pour améliorer l'estimation de  $\mathbf{h}_m$  pour tout  $m$ .

Estimation entraînée multi-slots II.

$\Gamma = \mathbb{E}(\mathbf{h}_m \mathbf{h}_m^H)$  matrice de rang  $K < L$ .

Si  $\Gamma$  était connue :  $\Gamma = \mathbf{U} \Delta \mathbf{U}^H$  la décomposition en elts propres.

$\mathbf{h}_m = \mathbf{U} \mathbf{f}_m$  avec  $\mathbf{U}$  orthogonale, et  $\mathbf{f}_m$  de dimension  $K$  à composantes indépendantes.

Estimer  $\mathbf{h}_m$  équivaut à estimer  $\mathbf{f}_m$ : moins de paramètres, estimation meilleure.

En pratique, il faut estimer  $\Gamma$  à partir des  $(\hat{\mathbf{h}}_m)_{m=1, \dots, M}$ .

Estimation entraînée multi-slots III.

Estimation de  $\Gamma$ : on suppose que  $\mathbf{A}^H \mathbf{A} = N \mathbf{I}_N$ .

$$\hat{\mathbf{h}}_m = \mathbf{h}_m + \epsilon_m \text{ avec } \mathbb{E}(\epsilon_m \epsilon_m^H) = \frac{\sigma^2}{N} \mathbf{I}_{L+1}$$

$$\mathbb{E}(\hat{\mathbf{h}}_m \hat{\mathbf{h}}_m^H) = \Gamma + \frac{\sigma^2}{N} \mathbf{I}_{L+1}.$$

Estimer  $\Gamma$  par

$$\hat{\Gamma} = \frac{1}{M} \sum_{m=1}^M \hat{\mathbf{h}}_m \hat{\mathbf{h}}_m^H - \frac{\sigma^2}{N} \mathbf{I}_{L+1}$$

## Estimation aveugle / semi-aveugle.

estimer  $\mathbf{h}$  à partir de la séquence d'apprentissage  $\mathbf{e}$  et des observations correspondant aux symboles inconnus.

Quelques notations.

- $\mathbf{h} = \theta$
- $(a_n, \dots, a_{n-L})^T = \mathbf{z}_n$
- $\mathbf{y} = (y_0, \dots, y_{N-1})^T$
- $\mathbf{z} = (\mathbf{z}_0^T, \dots, \mathbf{z}_{N-1}^T)^T$

Estimer  $\theta$  à partir de  $\mathbf{y}$ ,  $y_n = \theta^T \mathbf{z}_n + b_n$

Estimation au sens du maximum de vraisemblance.

Maximiser  $p(\mathbf{y}/\theta)$ .

$$p(\mathbf{y}/\theta) = \sum_{\mathbf{z}} p(\mathbf{y}, \mathbf{z}/\theta)$$

$$p(\mathbf{y}, \mathbf{z}/\theta) = p(\mathbf{y}/\mathbf{z}, \theta)p(\mathbf{z})$$

$$p(\mathbf{y}/\mathbf{z}, \theta) = \frac{1}{(2\pi)^{N/2}} \exp - \frac{1}{2\sigma^2} \left( \sum_{n=0}^{N-1} |y_n - \theta^T \mathbf{z}_n|^2 \right)$$

Impossible de calculer  $p(\mathbf{y}/\theta)$ .

### Algorithme EM.

Algorithme itératif : supposons que  $\theta^{[k]}$  soit disponible.

On considère  $p(\mathbf{z}/\mathbf{y}, \theta^{[k]})$  la loi conditionnelle de  $\mathbf{z}$  sachant  $\mathbf{y}$  si le paramètre était  $\theta^{[k]}$ .

$$Q(\theta, \theta^{[k]}) = \int \log p(\mathbf{y}, \mathbf{z}/\theta) p(\mathbf{z}/\mathbf{y}, \theta^{[k]}) d\mathbf{z}$$

$\theta^{[k+1]}$  est la valeur de  $\theta$  qui maximise  $Q(\theta, \theta^{[k]})$ .

**Théorème 2** *Au cours de l'algorithme, la vraisemblance augmente, c'est-à-dire que*

$$\log p(\mathbf{y}/\theta^{[k+1]}) \geq \log p(\mathbf{y}/\theta^{[k]})$$