


Estimation





Yves Goussard

GBM6103A

24 septembre 2014



Exemple : effet des incertitudes



- 1 Position du problème
- 2 Méthodologie de l'estimation
 - Démarche générale
 - Estimateurs classiques
 - Caractéristiques des estimateurs
- 3 Estimation dans le cas linéaire et gaussien
- 4 Calcul pratique de la solution
 - Nature des difficultés
 - Notions d'optimisation sans contrainte

Exemple : estimation d'une quantité scalaire x

- Estimation de x par une moyenne : hypothèses sous-jacentes sur
 - la structure du système
 - le comportement statistiques de certaines grandeurs
- Éléments importants
 - mise en équation du problème
 - utilisation d'un *contraste* entre bruit et quantité à estimer
 - possibilité d'introduire des informations sur x sous forme probabiliste

Démarche

- Mise en équation du problème
 - partie déterministe
 - partie probabiliste
 - incertitudes (bruit)
 - informations *a priori* sur x
- Estimation : utilisation du contraste entre x et les incertitudes
 - taille
 - comportement

Comment ?

Démarche générale

- Mise en équation du problème
 - partie déterministe : structure du modèle
 - partie probabiliste
 - incertitudes (bruit) : $f_B(\mathbf{b})$
 - informations *a priori* sur \mathbf{x} : $f_X(\mathbf{x})$
 - on peut calculer $f_{Z|X=\mathbf{x}}(\mathbf{z})$

- Estimation

- on en déduit $f_{X|Z=\mathbf{z}}(\mathbf{x}) = \frac{f_{Z|X=\mathbf{x}}(\mathbf{z})f_X(\mathbf{x})}{f_Z(\mathbf{z})}$ qui représente la totalité de l'information disponible sur \mathbf{X}
- détermination d'une estimée (estimateur ponctuel) : maximum de $f_{X|Z=\mathbf{z}}(\mathbf{x})$, moyenne *a posteriori*, ...

Exemples

- Estimation d'une quantité scalaire très bruitée : voir `demo_caraest.m`
- Estimation d'un retard (échographie) : voir `demo_corr.m`

Estimateurs classiques (1)

Maximum *a posteriori* (MAP)

- $\hat{x} = \arg \max_x \{f_{\mathbf{X}|\mathbf{Z}=\mathbf{z}}(\mathbf{x})\} = \arg \max_x \{f_{\mathbf{Z}|\mathbf{X}=\mathbf{x}}(\mathbf{z}) f_{\mathbf{X}}(\mathbf{x})\}$
- \hat{x} : valeur de \mathbf{x} « la plus probable » compte tenu de la valeur des mesures
- Estimation : problème d'optimisation

Maximum de vraisemblance (MV)

- MAP avec $f_{\mathbf{X}}(\mathbf{x})$ constante $\implies \hat{x} = \arg \max_x \{f_{\mathbf{Z}|\mathbf{X}=\mathbf{x}}(\mathbf{z})\}$

Moyenne *a posteriori*

- $\hat{x} = E[\mathbf{X}|\mathbf{Z} = \mathbf{z}] = \int \mathbf{x} f_{\mathbf{X}|\mathbf{Z}=\mathbf{z}}(\mathbf{x}) d\mathbf{x}$
- Robuste
- Interprétation : erreur quadratique moyenne minimale
- Mise en œuvre difficile

Estimateur linéaire d'erreur quadratique moyenne minimale

- $\hat{x} = w * g$; $E [(\hat{x} - x)^2]$ minimale
- Hypothèse gaussienne implicite
- Mise en œuvre par filtre de Kalman ou de Wiener

Estimateurs empiriques

- $\hat{x} = \Psi(z)$
- Choix de Ψ ?
- Qualité de l'estimateur

Comment choisir un estimateur ?

Position du problème

- Tous les estimateurs ponctuels sont de la forme $\hat{x} = \Psi(z)$
- \hat{X} aléatoire car Z aléatoire
- Comportement statistique de \hat{X} ?

Principales caractéristiques

- Comportement statistique de \hat{X} résumé par sa moyenne et sa matrice de covariance
- Moyenne : précision
- Matrice de covariance : fidélité

Biais et variance

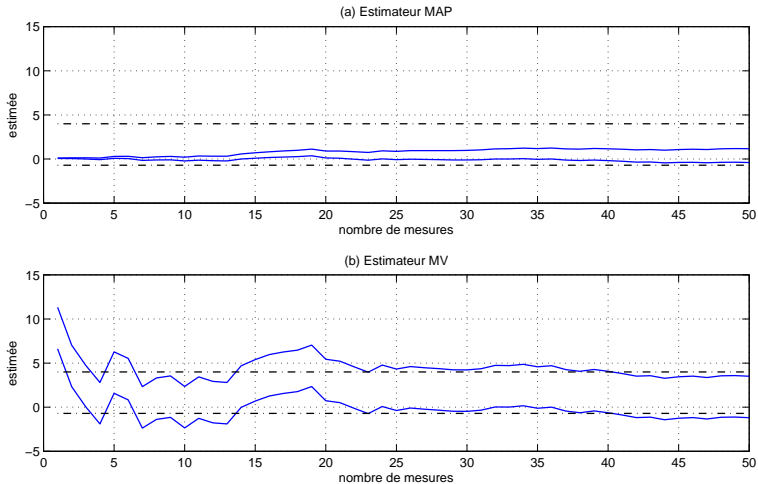
- Biais : $\mathbf{B} = E [\hat{\mathbf{X}} - \mathbf{x}_v]$; \mathbf{x}_v : vraie valeur de \mathbf{X}
- Erreur quadratique moyenne : $\|\mathbf{B}\|^2 + \sum \text{diagCov} [\hat{\mathbf{X}}]$

En général, nécessité d'un compromis entre biais et covariance

Comportement asymptotique

- L'erreur quadratique moyenne doit tendre vers 0 lorsque la taille de \mathbf{Z} augmente à taille de \mathbf{X} constante
- Pertinence à évaluer au cas par cas

Exemple : estimation d'une quantité scalaire dans un bruit fort



Estimation MAP dans le cas linéaire et gaussien (1)

Hypothèses

- \mathbf{X} et \mathbf{Z} de dimension finie
- Structure linéaire et bruit additif : $\mathbf{z} = \mathbf{H}\mathbf{x} + \mathbf{b}$
- Bruit gaussien ; $f_{\mathbf{B}} : \mathcal{N}(0, \sigma_{\mathbf{B}}^2 \bar{\mathbf{R}}_{\mathbf{B}})$
- \mathbf{X} gaussien ; $f_{\mathbf{X}} : \mathcal{N}(0, \sigma_{\mathbf{X}}^2 \bar{\mathbf{R}}_{\mathbf{X}})$

Approche MAP

- $\{\mathbf{Z} | \mathbf{X} = \mathbf{x}\}$ gaussien ; $f_{\mathbf{Z} | \mathbf{X} = \mathbf{x}} : \mathcal{N}(\mathbf{H}\mathbf{x}, \sigma_{\mathbf{B}}^2 \bar{\mathbf{R}}_{\mathbf{B}})$
- $\hat{\mathbf{x}} = \arg \max_{\mathbf{x}} \left\{ \exp \left(-\frac{(\mathbf{z} - \mathbf{H}\mathbf{x})^t \bar{\mathbf{R}}_{\mathbf{B}}^{-1} (\mathbf{z} - \mathbf{H}\mathbf{x})}{2\sigma_{\mathbf{B}}^2} - \frac{\mathbf{x}^t \bar{\mathbf{R}}_{\mathbf{X}}^{-1} \mathbf{x}}{2\sigma_{\mathbf{X}}^2} \right) \right\}$
- $\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \left\{ \frac{(\mathbf{z} - \mathbf{H}\mathbf{x})^t \bar{\mathbf{R}}_{\mathbf{B}}^{-1} (\mathbf{z} - \mathbf{H}\mathbf{x})}{2\sigma_{\mathbf{B}}^2} + \frac{\mathbf{x}^t \bar{\mathbf{R}}_{\mathbf{X}}^{-1} \mathbf{x}}{2\sigma_{\mathbf{X}}^2} \right\}$

Estimation MAP dans le cas linéaire et gaussien (2)

Forme de l'estimateur

- Estimateur général : $\hat{x} = \left(H^t \bar{R}_B^{-1} H + \frac{\sigma_B^2}{\sigma_X^2} \bar{R}_X^{-1} \right)^{-1} H^t \bar{R}_B^{-1} z$
- Si le bruit est blanc : $\hat{x} = \left(H^t H + \frac{\sigma_B^2}{\sigma_X^2} \bar{R}_X^{-1} \right)^{-1} H^t z$
- Si X est déterministe : $\hat{x} = \left(H^t \bar{R}_B^{-1} H \right)^{-1} H^t \bar{R}_B^{-1} z$
- Deux cas précédents : $\hat{x} = \left(H^t H \right)^{-1} H^t z$

Moindres carrés

Choix d'un estimateur

- Dépend du contraste entre x et b et du « contenu informationnel » de z
- Conditions favorables : moindres carrés OK
- Autrement : MAP
- Illustration : demo_estRI.m

Calcul pratique de la solution

Position du problème

Cas linéaire et gaussien

- \hat{x} solution de $Qx = b$
- Taille de Q ?
- Inversion de Q ?

Cas général

- \hat{x} défini par : $\hat{x} = \arg \min_x f(x)$; \hat{x} solution de $\nabla f(x) = 0$
- Taille des grandeurs permettant le calcul de $f(x)$?
- Pas de forme explicite de \hat{x}

Approche itérative

- Suite de x_k *convergeant* vers \hat{x}
- Calcul *simple* de x_k à partir de x_{k-1} et $f(x)$

Optimisation sans contrainte (1)

Définition

- $\hat{x} = \arg \min_x f(x)$
- f deux fois continuellement différentiable

Condition nécessaire d'optimalité

Si \hat{x} est un minimum *local* de f , alors

- $\nabla f(\hat{x}) = 0$
- $\nabla^2 f(\hat{x})$ est **semi-définie** positive

Condition suffisante d'optimalité

Si

- $\nabla f(\hat{x}) = 0$
- $\nabla^2 f(\hat{x})$ est **définie** positive

alors \hat{x} est un minimum *local* de f

Interprétation

- Conditions d'optimalité relatives aux minima *locaux*
- Minimum local = minimum global si $f(\mathbf{x})$ est *convexe*
- Cas général
 - $\nabla f(\mathbf{x})$ non linéaire par rapport à \mathbf{x}
 - $\nabla^2 f(\mathbf{x})$ varie en fonction de \mathbf{x}
 - $\nabla^2 f(\mathbf{x})$ semi-définie positive pour tout \mathbf{x} si $f(\mathbf{x})$ est convexe
- Cas linéaire et gaussien
 - $f(\mathbf{x})$ est une forme quadratique semi-définie positive
 - $f(\mathbf{x})$ est convexe
 - $\nabla f(\mathbf{x})$ est linéaire par rapport à \mathbf{x}
 - $\nabla^2 f(\mathbf{x})$ est une matrice constante (indépendante de \mathbf{x})

Principe

En \mathbf{x}_k

- Choisir une direction de déplacement \mathbf{d}_k
- Choisir $\alpha_k > 0$ tel que $f(\mathbf{x}_k + \alpha_k \mathbf{d}_k) < f(\mathbf{x}_k)$
- $\mathbf{x}_{k+1} \leftarrow \mathbf{x}_k + \alpha_k \mathbf{d}_k$

Intérêt

- Structure simple
- Choix de \mathbf{d}_k et α_k généralement lié à $f(\mathbf{x}_k)$ et $\nabla f(\mathbf{x}_k)$

Difficultés

- Convergence vers $\hat{\mathbf{x}}$?
- Vitesse de convergence ?
- Règle d'arrêt pratique ?

Principe

- Choisir \mathbf{d}_k suffisamment loin de l'orthogonalité à la plus grande pente
- Choisir α_k pour se rapprocher suffisamment du minimum de f dans la direction \mathbf{d}_k

Formalisation

Soit $f(\mathbf{x})$ deux fois continuellement différentiable et vérifiant des conditions de régularité supplémentaires. Si $\exists (c_1, c_2)$; $0 < c_1 < c_2 < 1$ tels que

- $\forall k ; f(\mathbf{x}_k + \alpha_k \mathbf{d}_k) - f(\mathbf{x}_k) \leq c_1 \alpha_k \mathbf{d}_k^t \nabla f(\mathbf{x}_k)$
- $\forall k ; |\mathbf{d}_k^t \nabla f(\mathbf{x}_k + \alpha_k \mathbf{d}_k)| \leq c_2 |\mathbf{d}_k^t \nabla f(\mathbf{x}_k)|$

alors la suite \mathbf{x}_k converge vers un minimum local de f (convergence globale)

Choix pratique de \mathbf{d}_k et α_k ?

Directions de descente \mathbf{d}_k

- Quasi-Newton : $\mathbf{d}_k = -\mathbf{H}_k \nabla f(\mathbf{x}_k)$; $\mathbf{H}_k \approx (\nabla^2 f(\mathbf{x}_k))^{-1}$
En général, \mathbf{H}_k Calculé à partir de $\nabla f(\mathbf{x}_k)$, $\nabla f(\mathbf{x}_{k-1})$, ...
- Gradient conjugué : quasi-Newton simplifié
- Gradient : $\mathbf{d}_k = -\nabla f(\mathbf{x}_k)$

Pas α_k

Méthodes de *backtracking* assurant que les conditions de descente suffisante sont vérifiées

En pratique...

- Algorithmes tout faits
- Écriture d'une fonction retournant $f(\mathbf{x})$ et $\nabla f(\mathbf{x})$ pour tout \mathbf{x}
- Critère d'arrêt : seuil sur la norme de $\nabla f(\mathbf{x}_k)$

Caractéristiques de $f(\mathbf{x})$

- $f(\mathbf{x})$ forme quadratique semi-définie positive, donc convexe :
$$f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^t \mathbf{Q} \mathbf{x} - \mathbf{b}^t \mathbf{x} + c$$
- $\nabla f(\mathbf{x})$ linéaire par rapport à \mathbf{x} , $\nabla^2 f(\mathbf{x})$ constant
- $f(\mathbf{x}_k + \alpha_k \mathbf{d}_k)$ polynôme du 2^e degré en α_k .

Calcul explicite du α_k qui minimise $f(\mathbf{x}_k + \alpha_k \mathbf{d}_k)$ (pas optimal)

Conséquences pratiques

- Pas optimal et directions de descente du gradient ou du gradient conjugué : **convergence globale**
- Simplification importante (calcul direct de α_k)
- Algorithmes nécessitant seulement une fonction retournant $\mathbf{Q}\mathbf{x}$ et \mathbf{b} pour tout \mathbf{x}
- Critère d'arrêt : souplesse accrue