

Paramétrique: suppose que les données obéissent à un modèle (probabiliste ou non) défini par un nombre fini de paramètres à estimer. L'objectif est de déterminer les paramètres avec la meilleure précision possible.

Non paramétrique: tente de construire un modèle pour les données avec le moins possible d'hypothèses a priori.

exemple: l'estimation d'un loi de probabilité à partie d'un échantillon peut se faire à partir de la donnée a priori d'une loi (exemple gaussienne) ou sans hypothèse de loi par la méthode de Parzen.
En pratique, on s'intéressera essentiellement ici à l'estimation paramétrique.

De quoi dépendent les méthodes d'estimation

Les méthodes d'estimation sont très nombreuses. Elles dépendent de la connaissance de la loi physique théorique liant mesures et observations.

- de la connaissance de la loi de probabilité liant observation et mesures (modélisation probabiliste de l'erreur)
- de la connaissance d'une valeur approximative de l'estimation cherchée
- du critère retenu

estimation d'un paramètre \longleftrightarrow minimum d'une fonction de coût traduisant la compatibilité entre mesures et paramètres.

En général, le lien entre mesures et vecteur d'état est connu.

$$Z = f(X) + u$$

ou u est un bruit le plus souvent blanc dont la variance est connue et f souvent non linéaire.

Part II

Les méthodes d'estimation

Estimation au minimum de variance

On cherche un estimateur $\hat{\theta}$ de θ sans biais et de variance minimale

$$E(\hat{\theta}) = \theta, \quad \text{Var}(\hat{\theta}) \text{ minimale}$$

Théorème: la meilleure estimation de X au minimum de variance est $E(X/Z)$.
cadre d'utilisation: les estimations récursives

Le problème de la cible

Déterminer le centre de dispersion des tirs pour le faire coïncider avec le centre de la cible.
Pour améliorer l'efficacité, ne pas attendre que toutes les mesures soient faites mais apporter une correction après chaque tir → estimer les paramètres inconnus après chaque tir et adapter la correction apportée au paramètre en fonction de la mesure effectuée.
Voir le cours sur les estimateurs récursifs et le filtrage de Kalman.

Méthode explicite de détermination de $\hat{\theta}$.

Estimation au maximum de vraisemblance

Principe: Étant donné l'échantillon de mesures obtenues, la méthode du maximum de vraisemblance consiste à choisir parmi les valeurs possibles du paramètre, celle qui **maximise la probabilité d'obtenir l'échantillon** dont on dispose.

la loi $f(x|\theta)$ de la variable observée X est supposée connue.
exemple: l'observation suit une loi normale de paramètre $\theta = (m, \sigma)$:

$$f(x|\theta) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(\frac{x-m}{\sigma})^2}.$$

soit x le vecteur des observations $[x_1, \dots, x_n]^t$ résultat des épreuves X_1, \dots, X_n . **On choisit $\hat{\theta}$ pour que la densité de probabilité des épreuves X_1, \dots, X_n prenne sa plus grande valeur pour les réalisations obtenues x_1, \dots, x_n .**

$$\hat{\theta} = \operatorname{argmax} g(x_1, \dots, x_n | \theta)$$

$g(x_1, \dots, x_n | \theta)$ est la fonction de vraisemblance.

$\hat{\theta}$ est l'estimation au maximum de vraisemblance du paramètre θ .
Remarque: mène souvent à des estimateurs biaisés.

Exemples d'estimation au maximum de vraisemblance

estimation du paramètre μ d'une distribution de Poisson.

$$P(x) = \frac{\mu^x e^{-\mu}}{x!}$$

estimer les paramètres λ et μ d'une distribution connaissant les observations x_1, \dots, x_n sachant que $P(x|\mu) = \frac{\mu^x e^{-\mu}}{x!}$ on a

$$\begin{aligned} 0 &= \sum_k \frac{\partial}{\partial \mu} (\ln(\mu^{x_k} e^{-\mu} / x_k!)) \\ &= \sum_k \frac{\partial}{\partial \mu} (x_k \ln(\mu) - \mu) \\ &= \sum_k (x_k / \mu - 1) \end{aligned}$$

d'où $\mu = 1/n \sum_k x_k$

$$\operatorname{argmax}_\theta g(x_1, \dots, x_n | \theta) = \operatorname{argmax} \ln(g(x_1, \dots, x_n | \theta))$$

Si les épreuves sont indépendantes:

$$\begin{aligned} g(x_1, \dots, x_n | \theta) &= \prod_{k=1}^n f(x_k | \theta) \\ \ln(g(x_1, \dots, x_n | \theta)) &= \sum_k \ln(f(x_k | \theta)) \end{aligned}$$

si f est dérivable,

$$\sum \frac{\partial \ln(f(x_k | \theta))}{\partial \theta} = 0$$

(si $\theta = (\theta_1, \dots, \theta_r)$, il y a r équations scalaires).

Exemples d'estimation au maximum de vraisemblance (2)

Exemple : apprentissage non supervisé [DH73]

Détermination d'une densité de probabilité

Problème du calcul de $p(x|C_1)$ connaissant des éléments $x_1 \dots x_n$ appartenant à C_1 .

Si la forme générale de p est connue paramétriquement (ex loi de gauss, de poisson ...), alors p peut être déterminée au maximum de vraisemblance.

ex: on considère n mesures indépendantes $x_1 \dots x_n$ suivant une loi de Maxwell de densité

$$p(x|A) = \sqrt{\frac{2}{\pi}} A^3 x^3 \exp\left(-\frac{A^2 x^2}{2}\right)$$

déterminer A au maximum de vraisemblance.

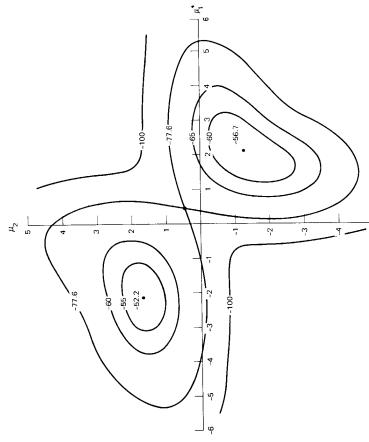
Marie-Odile Berger () Méthodes d'estimation November 8, 2011 13 / 46

Apprentissage supervisé

estimation au maximum de vraisemblance: maximiser $\sum \log p(x | \mu_1, \mu_2)$.

TABLE 6-1. Twenty-five Samples from a Normal Mixture

k	x_k	(Class)
13	3.240	2
14	2.400	2
15	-2.499	1
16	2.608	2
17	-3.458	1
18	0.237	2
19	2.569	2
20	1.415	2
21	1.410	2
22	-2.653	1
23	1.396	2
24	3.286	2
25	-0.712	1



$$2 \maxima((l_1, l_2) \equiv (-2, 130, 1, 668) \text{ et } (l_1, l_2) \equiv (2, 085, -1, 257))$$

En pratique, l'estimation au maximum de vraisemblance débouche sur des équations sans solutions directes et nécessite de recourir à des résolutions numériques

Un exemple simple tiré de [DH73]

- on considère un ensemble de mesures pouvant provenir de 2 classes sans que l'on sache de laquelle.
 - on connaît $p(\omega_1)$ et $p(\omega_2)$.
 - on sait que $p(z|\omega_1)$ et $p(z|\omega_2)$ sont des gaussiennes de variance $\sigma^2 = 1$ mais de moyenne μ_1 et μ_2 inconnue.

Problème: estimer μ_1 et μ_2 à partir des observations.

$$\begin{aligned}
 p(x|\mu_1, \mu_2) &= p(x = X(\omega) \text{ et } \omega \in \omega_1) + p(x = X(\omega) \text{ et } \omega \in \omega_2) \\
 &= p(x|\omega_1) * p(\omega_1) + p(x|\omega_2) * p(\omega_2) \\
 &= \frac{1}{3\sqrt{2\pi}} \exp\left(-\frac{1}{2}(x - \mu_1)^2\right) + \frac{2}{3}\frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}(x - \mu_2)^2\right)
 \end{aligned}$$

déterminer A au maximum de vraisemblance.

Marie-Odile Berger () Méthodes d'estimation November 8, 2011 13 / 46

Apprentissage non supervisé

Méthode des moments

Méthode des moments

Le cadre est le même que pour l'estimation au maximum de vraisemblance.
méthode: déterminer les paramètres en égalant les estimations empiriques et théoriques des moments.

exemple

Déterminer par la méthode des moments les estimations des paramètres m et α de la distribution uniforme sur $[m - \alpha, m + \alpha]$.
densité: $\frac{1}{2\alpha} \mathbf{1}_{[m-\alpha, m+\alpha]}$
moment d'ordre 1 = m
moment d'ordre 2 = $\frac{3m^2 + \alpha^2}{3}$
d'où

$$\frac{m}{\frac{3m^2 + \alpha^2}{3}} = \frac{\frac{1}{n} \sum x_k}{\frac{1}{n} \sum x_k^2}$$

Modèle déterministe et estimation aux moindres carrés

On se place dans le cas où le paramètre p et les mesures z sont décrites linéairement $A\theta = z$

Rappel: on peut choisir une norme significative du problème, par exemple $\|Z\|^2 = \sum \frac{1}{\sigma^2} z_i^2$ ou plus généralement $\|Z\|^2 = Z^t \Lambda^{-1} Z$ où Λ est la matrice de covariance des mesures.

On a l'estimation

$$\hat{\theta} = (A^t \Lambda^{-1} A)^{-1} A^t \Lambda^{-1} Z$$

Si on considère qu'en fait $Z = A\theta + v$ où v est un bruit gaussien de moyenne nulle et de variance $E(vv^t) = \Lambda$, alors

$$p(Z|\theta) = \frac{1}{(2\pi)^{n/2} \sqrt{\det(\Lambda)}} \exp\left(-\frac{1}{2}(Z - A\theta)^t \Lambda^{-1} (Z - A\theta)\right)$$

puisque z est gaussienne d'espérance $A\theta$ et de variance Λ . $\hat{\theta}$ maximise $p(Z|\theta) \rightarrow$ estimation au maximum de vraisemblance.

Interprétation statistique des moindres carrés

Exemple d'estimateur linéaire aux moindres carrés

Exemple d'estimateur linéaire aux moindres carrés (2)

Fusion de données Soient deux mesures (m_1, Λ_1) et (m_2, Λ_2) d'une même quantité. Déterminer une estimation m de cette quantité tenant compte de ces deux mesures.

Une façon de calculer m est de minimiser :

$$(m - m_1)^t \Lambda_1^{-1} (m - m_1) + (m - m_2)^t \Lambda_2^{-1} (m - m_2)$$

donc, en dérivant

$$\Lambda_1^{-1} (m - m_1) + \Lambda_2^{-1} (m - m_2) = 0$$

et

$$m = (\Lambda_1^{-1} + \Lambda_2^{-1})^{-1} (\Lambda_1^{-1} m_1 + \Lambda_2^{-1} m_2)$$

ou d'utiliser les moindres carrés avec $A = \begin{pmatrix} I \\ I \end{pmatrix}$

Modèles auto-régressifs: résolution statistique

méthode 2: utilisation des corrélations $r_k = \text{cov}(y_{t+k}, y_t)$

$$y_t + \sum_{k=1}^p a_k y_{t-k} = u_t$$

donc

$$\begin{aligned} \text{cov}(u_t, u_t) &= \text{cov}(u_t, y_t) \\ &= \frac{\text{cov}(y_t + \sum_{k=1}^p a_k y_{t-k}, y_t)}{r_0 + \sum a_k r_k} \\ &= \frac{r_0}{r_0 + \sum a_k r_k} \end{aligned}$$

$$0 = \text{cov}(u_t, y_{t-1}) = \text{cov}(y_t + \sum_{k=1}^p a_k y_{t-k}, y_{t-1}) = r_1 + a_1 r_0 + a_2 r_1 + \dots + a_p r_{p-1}$$

d'où

$$\begin{bmatrix} r_0 & r_1 & \dots & r_p \\ r_1 & r_0 & \dots & r_{p-1} \\ \vdots & \vdots & \ddots & \vdots \\ r_p & r_{p-1} & \dots & r_0 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_u^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (*)$$

Modèles auto-régressifs Un processus temporel $\{y_t\}$ suivant un modèle auto-régressif est défini par

$$y_t + \sum_{k=1}^p a_k y_{t-k} = u_t$$

où u_t est un processus non corrélé de moyenne 0 et de variance σ_u^2 . modèle utilisé pour la parole et pour décrire des phénomènes temporels complexes mais assez réguliers.

Méthode 1: détermination des a_k aux moindres carrés étant données des observations y_0, \dots, y_n , on a

$$\underbrace{\begin{bmatrix} y_p \\ y_{p+1} \\ \vdots \\ y_{n-1} \end{bmatrix}}_Y + \underbrace{\begin{bmatrix} y_{p-1} & y_{p-2} & \dots & y_0 \\ y_p & y_{p-1} & \dots & y_1 \\ \vdots & \vdots & \ddots & \vdots \\ y_{n-2} & y_{n-3} & \dots & y_{n-p-1} \end{bmatrix}}_Y \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = 0$$

Modèles auto-régressifs

Estimation de Yule-Walker: solution de (*) en remplaçant les covariances inconnues par les covariances estimées

$$\begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix} = - \begin{bmatrix} \hat{r}_0 & \hat{r}_1 & \dots & \hat{r}_{p-1} \\ \hat{r}_1 & \hat{r}_0 & \dots & \hat{r}_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{r}_{p-1} & \hat{r}_{p-2} & \dots & \hat{r}_0 \end{bmatrix}^{-1} \begin{bmatrix} \hat{r}_1 \\ \hat{r}_2 \\ \vdots \\ \hat{r}_p \end{bmatrix}$$

Moindres carrés non linéaires

Évaluer la précision de l'estimation

Le cas des moindres carrés L'erreur d'estimation dans un moindre carré est $(A^T \Lambda^{-1} A)^{-1}$.

Dans le cas non linéaire

$$\hat{\theta} = \text{argmin}_{\theta} \phi(\theta) \quad \hat{\phi} = \phi(\hat{\theta})$$

Il n'y a pas de raison de préférer θ à $\hat{\theta}$ lorsque

$$\hat{\theta} = \text{argmin} \sum (z_i - f_i(\theta))^2$$

L'approche aux moindres carrés se généralise à toute fonction liant mesure et paramètres $z_i = f_i(\theta)$.
Dans ce cas, il n'y a pas (en général) de solution explicite et $[\hat{\theta}]$ est obtenu par minimisation numérique.

$$|\phi(\theta) - \hat{\phi}| \leq \epsilon$$

→ définition d'une **région d'indifférence** dans l'espace des paramètres.
En utilisant un développement de Taylor à l'ordre 1

$$\phi(\theta) \approx \hat{\phi} + \hat{q}^t \delta\theta + \frac{1}{2} \delta\theta^t \hat{H} \delta\theta$$

où $\delta\theta = \theta - \hat{\theta}$, \hat{q} est le gradient de ϕ calculé en $\theta = \hat{\theta}$ et \hat{H} est le hessien de ϕ calculé en $\theta = \hat{\theta}$.

November 8, 2011 25 / 46
Marie-Odile Berger () Méthodes d'estimation

Navigation icons: back, forward, search, etc.

November 8, 2011 26 / 46
Marie-Odile Berger () Méthodes d'estimation

Navigation icons: back, forward, search, etc.

Évaluer la précision de l'estimation

$$\phi(\theta) \approx \hat{\phi} + \hat{q}^t \delta\theta + \frac{1}{2} \delta\theta^t \hat{H} \delta\theta$$

À l'optimum, $\hat{q} = 0$, donc

$$\phi(\theta) \approx \hat{\phi} + \frac{1}{2} \delta\theta^t \hat{H} \delta\theta$$

La région d'indifférence est donc définie par

$$\delta\theta^t \hat{H} \delta\theta \leq 2\epsilon$$

définit un ellipsoïde de dimension $\dim(\theta)$.

Part III

Minimisation : considérations numériques

November 8, 2011 27 / 46
Marie-Odile Berger () Méthodes d'estimation

Navigation icons: back, forward, search, etc.

November 8, 2011 28 / 46
Marie-Odile Berger () Méthodes d'estimation

Navigation icons: back, forward, search, etc.

Pourquoi étudier les méthodes de minimisation numérique

Recherche d'un optimum local

Résolution de l'équation $f'(x) = 0$ on cherche à trouver le minimum d'une fonction en résolvant l'équation $f'(x) = 0$.

Méthode de Newton nécessite l'évaluation de f et f' .
on définit la suite

$$x_0 \quad x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$$

[Cia82] est un bon ouvrage de référence.
pourquoi: les modes d'estimation au max de vraisemblance et les moindres

carrés généralisés conduisent à minimiser des fonctions complexes →

optimisation numérique
La difficulté varie selon que

- on cherche un optimum local (ou un optimum global avec une bonne solution initiale)
- on cherche un optimum global

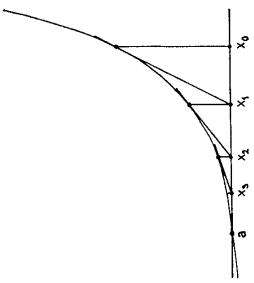


Fig. 7.5.1.

Recherche d'un optimum local: méthode de Newton

origine: si ζ est le zéro de f , le développement de Taylor de f au voisinage de x_0 est

$$f(\zeta) = 0 = f(x_0) + (\zeta - x_0)f'(x_0) + \dots$$

en négligeant les termes d'ordre 2,

$$\zeta = x_0 - \frac{f(x_0)}{f'(x_0)}$$

nécessité de disposer d'une estimée initiale de la solution

généralisation en dimension supérieure

$f: R^n \rightarrow R$ Si la matrice de dérivée f' est une bijection en tout point x , on considère le schéma de Newton

$$x_{k+1} = x_k - \{f'(x_k)\}^{-1}f(x_k)$$

en pratique, calculer $f'(x_k)$ à chaque itération est coûteux. →
conserver la même matrice pendant p itérations.

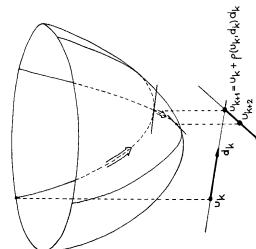
$$\begin{aligned} x_{k+1} &= x_k - \{f'(x_0)\}^{-1}f(x_k) & 0 \leq k \leq p-1 \\ x_{k+1} &= x_k - \{f'(x_p)\}^{-1}f(x_k) & p \leq k \leq 2p-1 \end{aligned}$$

Le cas multi dimensionnel: les méthodes de relaxation

Comment choisir les directions de descente?

principe des méthodes de relaxation: se ramener à des minimisation successives de fonctions d'une seule variable réelle.

- solution initiale x_0 .
 - se donner une direction de descente d_k au point x_k .
 - chercher le minimum de f le long de la droite passant par x_k et de vecteur directeur d_k . déterminer ρ tel que
- $$f(x_k + \rho(x_k, d_k)d_k) = \inf_{\rho} f(x_k + \rho d_k)$$
- on pose $x_{k+1} = x_k + \rho(x_k, d_k)d_k$



Recherche d'un optimum global et le recuit simulé

Méthode alternative: utiliser les méthodes d'optimisation locale en partant d'un grand nombre d'initialisations bien réparties... aléatoire

Principe du Recuit simulé [KGV83]: établir une analogie entre le problème à résoudre et un système physique évoluant à une certaine température.

Le recuit métallurgique:

pour trouver les états de basse énergie (états fondamentaux) d'un système complexe: réchauffer à une température élevée puis le refroidir (très) lentement → états cristallins de très faible énergie (forcer l'état du système dans des régions de basse énergie tout en lui évitant d'être piégé dans des états correspondants à des minima locaux d'énergie élevée). Si la descente est trop rapide, matériau amorphe.

Principe du Recuit simulé

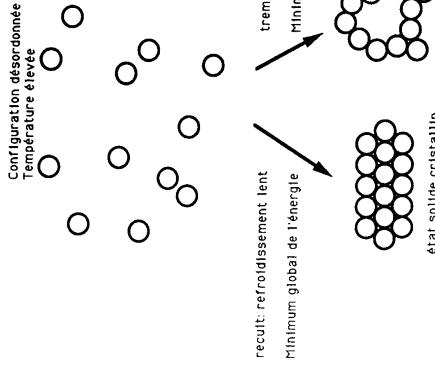
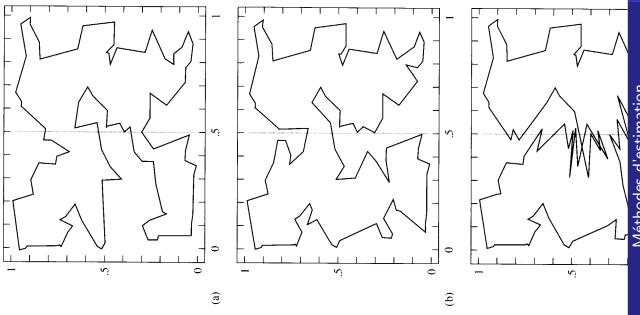


Figure 2.4: Comparaison des techniques du recuit et de la trempe.

Exemple : Le problème du voyageur de commerce

Recuit simulé

- fonction à minimiser $\sum \sqrt{(x_i - x_{i+1})^2 + (y_i - y_{i+1})^2}$
- mise en œuvre: T est maintenu tant que on n'a pas atteint $100 \times n$ reconfigurations ou si on a atteint $10 \times n$ reconfigurations acceptées



November 8, 2011 41 / 46

Méthodes d'estimation

Marie-Odile Berger ()

Bibliographie

- F. Chaumette.
Image moments: a general and useful set of features for visual servoing.
IEEE Trans. on Robotics, 20:713–723, 2004.

- P. G. Ciarlet.
Introduction à l'analyse numérique matricielle et à l'optimisation.
Masson, 1982.

- R. O. Duda and P. E. Hart.
Pattern Classification and Scene Analysis.
Wiley-Interscience, 1973.

- R. Fletcher
Practical Methods of Optimization, Wiley, 1987

- A. Foulonneau, P. Charbonnier, and F. Heitz.
Affine-Invariant Geometric Shape Priors. for Region-Based Active Contours.
Rapport de recherche RR-AF01-2005, LSIIT, 2005.

- S. Geman and D. Geman.
Stochastic Relaxation, Gibbs Distribution, and Bayesian Restoration of Images.
IEEE Transactions on PAMI, 6:721–741, 1984.

- L. Héault.
Réseaux de neurones récursifs pour l'optimisation combinatoire ; application à la théorie des graphes et à la vision par ordinateur.
Thèse de doctorat, Institut National Polytechnique de Grenoble, February 1991.

Bibliographie

Bibliographie

-  S. Kirkpatrick, C. D. Gelatt, and M. P. Vecchi.
Optimization by Simulated Annealing.
Science, 220:671–680, 1983.
-  N. Metropolis, A. W. Rosenbluth, A. H. Teller, and E. Teller.
Equations of state Calculations by Fast Computing Machines.
J. Chem. Phys., 21:1087–1092, 1953.
-  W. H. Press, B. P. Flannery, S. A. Teukolsky, and W. T. Vetterling.
Numerical Recipes in C, The Art of Scientific Computing.
Cambridge University Press, 1988.
-  V. Pugachev.
Théorie des probabilités et statistique mathématique.
Editions de Moscou, Mir, 1982.