

Chapitre 8

Modélisation des données

1. Maximum de vraisemblance
 - Statistique de Poisson
 - Statistique de Gauss
2. Principe général
 - Statistique de Gauss
3. Ajustement d'une droite
4. Ajustement d'une fonction linéaire
5. Ajustement d'une fonction non linéaire
 - Méthode de Levenberg-Marquardt

Maximum de vraisemblance

On désire ajuster une fonction (« modèle ») $f(x)$ dépendant de certains paramètres a_j ($j = 1, \dots, M$) :

$$f(x; a_1, \dots, a_M)$$

sur des données

$$y_j \quad (j = 1, \dots, N)$$

entachées d'une incertitude

$$\sigma_j \quad (j = 1, \dots, N)$$

N = nombre de données

M = nombre de paramètres

Si nous supposons *a priori* équiprobables toutes les valeurs que peuvent prendre les paramètres, le modèle le plus probable, *compte tenu des données* y_j , est celui pour lequel la *vraisemblance*

$$P(r \mid q^i . p)$$

est maximale

Dans le cas présent, on a :

p = les connaissances de base (lois de la physique, . . .)

r = le résultat de l'expérience
= l'ensemble des données $y_j \pm \sigma_j$

q^i = un modèle particulier
= la fonction $f(x)$ pour un choix particulier
des paramètres a_1, \dots, a_M

Si nous supposons les erreurs sur les différentes mesures y_j indépendantes les unes des autres, nous pouvons écrire :

$$P(r | q^i . p) = \prod_{j=1}^N P(y_j | q^i . p)$$

Or,

$$P(y_j | q^i . p) = P(y_j | f(x_j; a_1^i, \dots, a_M^i) . p)$$

Remarque :

l'effet du profil instrumental est supposé inclus dans $f(x)$

Cas particuliers :

1. Statistique de Poisson

Soit

$$f_j = f(x_j; a_1^i, \dots, a_M^i)$$

$$P(y_j | f_j \cdot p) = \frac{f_j^{y_j}}{y_j!} e^{-f_j}$$

$$\Rightarrow P(r | q^i \cdot p) = \prod_{j=1}^N \frac{f_j^{y_j}}{y_j!} e^{-f_j}$$

$$\Rightarrow \ln P(r | q^i \cdot p) = C + \sum_{j=1}^N (y_j \ln f_j - f_j)$$

Les paramètres a_1, \dots, a_M cherchés sont ceux qui maximisent

$$\mathcal{S}_P = \sum_{j=1}^N (y_j \ln f_j - f_j)$$

2. Statistique de Gauss

$$P(y_j | f_j \cdot p) = \frac{1}{\sqrt{2\pi}\sigma_j} e^{-\frac{(y_j - f_j)^2}{2\sigma_j^2}}$$

$$\Rightarrow P(r | q^i \cdot p) = \frac{1}{\sqrt{2\pi}} \prod_{j=1}^N \frac{1}{\sigma_j} e^{-\frac{(y_j - f_j)^2}{2\sigma_j^2}}$$

$$\Rightarrow \ln P(r | q^i \cdot p) = C - \frac{1}{2} \sum_{j=1}^N \left(\frac{y_j - f_j}{\sigma_j} \right)^2$$

Les paramètres a_1, \dots, a_M cherchés sont ceux qui maximisent

$$\mathcal{S}_G = -\frac{1}{2} \sum_{j=1}^N \left(\frac{y_j - f_j}{\sigma_j} \right)^2$$

et donc qui minimisent

$$\chi^2 = \sum_{j=1}^N \left(\frac{y_j - f_j}{\sigma_j} \right)^2$$

Principe général

1. Construire une « fonction de mérite » qui mesure l'accord entre le modèle et les données

(dans notre cas, cette « fonction de mérite » est déduite du maximum de vraisemblance)

2. Déterminer les paramètres du modèle de façon à minimiser la « fonction de mérite »

3. Estimer dans quelle mesure le modèle est compatible avec les données

4. Estimer l'incertitude sur les paramètres ajustés

Statistique de Gauss :

Minimiser

$$\chi^2 = \sum_{j=1}^N \left(\frac{y_j - f_j(a_1, \dots, a_M)}{\sigma_j} \right)^2$$

χ^2 = somme de carrés de N variables aléatoires normales

Lorsque a_1, \dots, a_M sont ajustés pour minimiser χ^2 , les termes de la somme ne sont plus statistiquement indépendants

Cependant, les différentes valeurs de χ^2 à son minimum suivent une distribution du chi-carré à $\nu = N - M$ degrés de liberté

La probabilité d'obtenir par hasard une valeur du chi-carré au moins aussi élevée que celle que l'on obtient, χ^2 , est donnée par

$$Q\left(\frac{\nu}{2}, \frac{\chi^2}{2}\right) = 1 - P\left(\frac{\nu}{2}, \frac{\chi^2}{2}\right)$$

où $P(a, x)$ est la *fonction gamma incomplète* :

$$P(a, x) \equiv \frac{\gamma(a, x)}{\Gamma(a)} \equiv \frac{1}{\Gamma(a)} \int_0^x e^{-t} t^{a-1} dt$$

Si Q est petit, c'est qu'il est peu probable qu'une fluctuation statistique soit responsable d'une si grande valeur de χ^2

\Rightarrow soit :

(1) le modèle est erroné

(2) les incertitudes de mesure ont été sous-estimées

(3) les erreurs de mesure ne suivent pas une distribution normale

En règle générale, on s'attend à avoir une valeur

$$\chi^2 \simeq \nu = N - M$$

Plus précisément, pour les grandes valeurs de ν , χ^2 suit une distribution normale

– de moyenne ν

– d'écart-type $\sigma = \sqrt{2\nu}$

Ajustement d'une droite

Nous désirons ajuster la fonction

$$f(x; a_1, a_2) = a_1 + a_2 x$$

sur les points

$$(x_j, y_j \pm \sigma_j) \quad (j = 1, \dots, N)$$

où nous supposons les x_j connus exactement et les erreurs de mesure sur y_j distribuées normalement

(1) *Estimation des paramètres*

Minimiser :

$$\chi^2(a_1, a_2) = \sum_{j=1}^N \left(\frac{y_j - a_1 - a_2 x_j}{\sigma_j} \right)^2$$

Remarque : si les erreurs ne sont pas distribuées normalement, la minimisation du χ^2 ne correspond pas au maximum de vraisemblance, mais peut néanmoins donner de bons résultats

$$\begin{cases} \frac{\partial \chi^2}{\partial a_1} = 0 \Rightarrow a_1 S + a_2 S_x = S_y \\ \frac{\partial \chi^2}{\partial a_2} = 0 \Rightarrow a_1 S_x + a_2 S_{xx} = S_{xy} \end{cases}$$

avec

$$\begin{aligned} S &\equiv \sum_{j=1}^N \frac{1}{\sigma_j^2} \\ S_x &\equiv \sum_{j=1}^N \frac{x_j}{\sigma_j^2} \\ S_y &\equiv \sum_{j=1}^N \frac{y_j}{\sigma_j^2} \\ S_{xx} &\equiv \sum_{j=1}^N \frac{x_j^2}{\sigma_j^2} \\ S_{xy} &\equiv \sum_{j=1}^N \frac{x_j y_j}{\sigma_j^2} \end{aligned}$$

Posons

$$\Delta \equiv S S_{xx} - S_x^2$$

$$\Rightarrow \begin{cases} a_1 = \frac{S_{xx} S_y - S_x S_{xy}}{\Delta} \\ a_2 = \frac{S S_{xy} - S_x S_y}{\Delta} \end{cases}$$

(2) *Estimation de l'incertitude sur les paramètres*

Si les erreurs sur les différentes mesures sont non corrélées :

$$\sigma_{a_i}^2 = \sum_{k=1}^N \sigma_k^2 \left(\frac{\partial a_i}{\partial y_k} \right)^2$$

$$\frac{\partial a_1}{\partial y_k} = \frac{S_{xx} - x_k S_x}{\sigma_k^2 \Delta}$$

$$\frac{\partial a_2}{\partial y_k} = \frac{x_k S - S_x}{\sigma_k^2 \Delta}$$

$$\Rightarrow \begin{cases} \sigma_{a_1}^2 = \frac{S_{xx}}{\Delta} \\ \sigma_{a_2}^2 = \frac{S}{\Delta} \end{cases}$$

Covariance :

$$\text{Cov}(a_1, a_2) = \sum_{k=1}^N \sigma_k^2 \frac{\partial a_1}{\partial y_k} \frac{\partial a_2}{\partial y_k}$$

$$\Rightarrow \text{Cov}(a_1, a_2) = -\frac{S_x}{\Delta}$$

(3) *Accord entre le modèle et les données*

Calculer :

$$Q = 1 - P\left(\frac{\nu}{2}, \frac{\chi^2}{2}\right)$$

- Si $Q \gtrsim 0.1$, on peut estimer que l'ajustement est satisfaisant

- Si $Q \gtrsim 0.001$, l'ajustement est peut-être acceptable (les erreurs ne sont peut-être pas distribuées normalement, ou ont peut-être été sous-estimées)

- Si $Q \lesssim 0.001$, on doit se poser des questions : le modèle n'est probablement pas une bonne représentation des données

- Si $Q \simeq 1$, on doit aussi se poser des questions : les erreurs ont peut-être été surestimées (à moins que les données n'aient été « arrangées »...)

Cas particulier : si les σ_j ne sont pas connus

\Rightarrow on peut les estimer à partir de l'ajustement :

on calcule a_1 et a_2 par les formules habituelles, avec

$$\sigma_j = 1, \quad \forall j$$

l'incertitude sur les données peut alors être estimée par :


$$\sigma^2 = \frac{1}{N} \sum_{j=1}^N (y_j - a_1 - a_2 x_j)^2$$

σ_{a_1} et σ_{a_2} sont calculés par les formules habituelles, multipliées par $\sqrt{\chi^2/(N-2)}$


Attention !

Tout ceci présuppose que le modèle fournit une bonne représentation des données

\Rightarrow pas de test indépendant de l'accord entre le modèle et les données



$$a_1 = 10.63 \pm 0.09 \quad a_2 = 0.446 \pm 0.008 \quad \chi^2 = 19.7$$



$$a_1 = 11.85 \pm 0.09 \quad a_2 = 0.360 \pm 0.008 \quad \chi^2 = 999.6$$

Ajustement d'une fonction linéaire

Soit

$$f(x; a_1, \dots, a_M)$$

une fonction qui dépend linéairement des paramètres a_1, \dots, a_M

Exemples :

$$f(x) = a_1 + a_2 x + a_3 x^2 + a_4 x^3 + \dots$$

$$f(x) = a_1 \cos x + a_2 \ln x$$

Forme générale :

$$f(x) = \sum_{i=1}^M a_i F_i(x)$$

où $F_1(x), \dots, F_M(x)$ sont des fonctions arbitraires de x

(« fonctions de base »)

(1) *Estimation des paramètres*

Minimiser

$$\chi^2 = \sum_{j=1}^N \left[\frac{y_j - \sum_{i=1}^M a_i F_i(x_j)}{\sigma_j} \right]^2$$

$$\frac{\partial \chi^2}{\partial a_k} = 0 \Leftrightarrow \sum_{j=1}^N \frac{1}{\sigma_j^2} \left[y_j - \sum_{i=1}^M a_i F_i(x_j) \right] F_k(x_j) = 0$$

Posons

$$\alpha_{ki} \equiv \sum_{j=1}^N \frac{F_i(x_j) F_k(x_j)}{\sigma_j^2}$$

$$\beta_k \equiv \sum_{j=1}^N \frac{y_j F_k(x_j)}{\sigma_j^2}$$

$$\Rightarrow \sum_{i=1}^M \alpha_{ki} a_i = \beta_k \quad (k = 1, \dots, M)$$

système linéaire de M équations à M inconnues

Soit C_{ik} la matrice inverse de α_{ik}

$$\Rightarrow a_i = \sum_{k=1}^M C_{ik} \beta_k$$

(2) *Estimation de l'incertitude sur les paramètres*

$$\sigma_{a_i}^2 = \sum_{j=1}^N \sigma_j^2 \left(\frac{\partial a_i}{\partial y_j} \right)^2$$

$$\frac{\partial a_i}{\partial y_j} = \sum_{k=1}^M C_{ik} \frac{\partial \beta_k}{\partial y_j}$$

$$\frac{\partial \beta_k}{\partial y_j} = \frac{F_k(x_j)}{\sigma_j^2}$$

$$\Rightarrow \sigma_{a_i}^2 = \sum_{j=1}^N \sigma_j^2 \sum_{k=1}^M C_{ik} \frac{F_k(x_j)}{\sigma_j^2} \sum_{l=1}^M C_{il} \frac{F_l(x_j)}{\sigma_j^2}$$

$$\Rightarrow \sigma_{a_i}^2 = \sum_{k=1}^M \sum_{l=1}^M C_{ik} C_{il} \alpha_{kl}$$

Or,

$$\sum_{k=1}^M C_{ik} \alpha_{kl} = \delta_{il}$$

$$\Rightarrow \sigma_{a_i}^2 = C_{ii}$$

Les éléments diagonaux de C sont les variances des paramètres ajustés

On montre de même que les autres éléments sont les covariances

Remarque :

La solution directe du problème de l'ajustement linéaire par moindres carrés est assez susceptible d'être sensible aux erreurs numériques

Des méthodes différentes permettent d'éviter ces problèmes

(voir le chapitre 14 de *Numerical Recipes*, par W.H. Press, B.P. Flannery, S.A. Teukolsky et W.T. Vetterling, *Cambridge University Press*)

Ajustement d'une fonction non linéaire

Soit

$$f(x; a_1, \dots, a_M)$$

une fonction qui dépend non linéairement des paramètres a_1, \dots, a_M

Exemples :

$$f(x) = a_1 \cos(a_2 x)$$

$$f(x) = a_1 e^{-a_2 x}$$

⇒ Méthode itérative nécessaire

Posons

$$(a_1, \dots, a_M) = \vec{a}$$

$$\chi^2(a_1, \dots, a_M) = S(\vec{a})$$

1^{er} cas : si on est près du minimum \vec{a}_{\min}

$$\Rightarrow S(\vec{a}) \simeq \gamma - \vec{d} \cdot \vec{a} + \frac{1}{2} \vec{a} D \vec{a} \quad (1)$$

où \vec{d} = vecteur à M dimensions (- dérivée 1^{ère})

D = matrice $M \times M$ (dérivée 2^{de})

Supposons (1) exacte

$$\Rightarrow \nabla S(\vec{a}) = D \vec{a} - \vec{d} \quad (2)$$

Au minimum, on a :

$$\nabla S(\vec{a}_{\min}) = 0$$

$$\Rightarrow D \vec{a}_{\min} = \vec{d} \quad (3)$$

En un point $\vec{a}_0 \neq \vec{a}_{\min}$, on a :

$$\Rightarrow D \vec{a}_0 = \nabla S(\vec{a}_0) + \vec{d} \quad (4)$$

$$(3) - (4) : \quad D (\vec{a}_{\min} - \vec{a}_0) = -\nabla S(\vec{a}_0) \quad (5)$$

$$\Rightarrow \vec{a}_{\min} = \vec{a}_0 - D^{-1} [\nabla S(\vec{a}_0)] \quad (6)$$

2^e cas : si on est loin du minimum :

(1) peut être une très mauvaise approximation de $S(\vec{a})$

⇒ tout ce qu'on peut faire pour se rapprocher de \vec{a}_{\min} est de se déplacer dans la direction opposée au gradient :

$$\Rightarrow \vec{a}_1 = \vec{a}_0 - \eta \nabla S(\vec{a}_0) \quad (7)$$

où $\eta =$ constante positive à déterminer

Calcul de \vec{d} et D

Soit

$$f = f(x; \vec{a})$$

le modèle à ajuster

$$\chi^2(\vec{a}) = \sum_{j=1}^N \left[\frac{y_j - f(x_j; \vec{a})}{\sigma_j} \right]^2$$

$$\nabla S = \left(\frac{\partial \chi^2}{\partial a_1}, \dots, \frac{\partial \chi^2}{\partial a_M} \right)$$

$$\frac{\partial \chi^2}{\partial a_k} = -2 \sum_{j=1}^N \frac{y_j - f(x_j; \vec{a})}{\sigma_j^2} \frac{\partial f(x_j; \vec{a})}{\partial a_k}$$

$$\begin{aligned}
\frac{\partial^2 \chi^2}{\partial a_k \partial a_l} &= \\
&= 2 \sum_{j=1}^N \frac{1}{\sigma_j^2} \left[\frac{\partial f(x_j; \vec{a})}{\partial a_k} \frac{\partial f(x_j; \vec{a})}{\partial a_l} - [y_j - f(x_j; \vec{a})] \frac{\partial^2 f(x_j; \vec{a})}{\partial a_k \partial a_l} \right] \\
&\simeq 2 \sum_{j=1}^N \frac{1}{\sigma_j^2} \left[\frac{\partial f(x_j; \vec{a})}{\partial a_k} \frac{\partial f(x_j; \vec{a})}{\partial a_l} \right]
\end{aligned}$$

Raisons qui permettent de négliger la dérivée seconde :

- elle est nulle dans le cas linéaire
- si l’ajustement est bon, son coefficient multiplicatif est l’erreur de mesure sur y_j ; ces erreurs de mesure s’annulent approximativement en moyenne :

$$\sum_{j=1}^N \frac{1}{\sigma_j^2} [y_j - f(x_j; \vec{a})] \simeq 0$$

- une approximation sur le calcul des dérivées secondes ne modifie en rien le résultat, qui est déterminé par la condition que la dérivée première s’annule ; elle ne modifie que la manière de parvenir au résultat \Rightarrow la convergence

Posons

$$\beta_k \equiv -\frac{1}{2} \frac{\partial \chi^2}{\partial a_k} = +\frac{1}{2} d_k$$

$$\alpha_{kl} \equiv \frac{1}{2} \frac{\partial^2 \chi^2}{\partial a_k \partial a_l} = \frac{1}{2} D_{kl}$$

α_{kl} = matrice de courbure

Près du minimum :

(5) devient :

$$\sum_{l=1}^M \alpha_{kl} \delta a_l = \beta_k \quad (8)$$

Loin du minimum :

(7) devient :

$$\delta a_k = \eta \beta_k \quad (9)$$

Méthode de Levenberg-Marquardt

On voudrait connaître l'ordre de grandeur de η

Or, le gradient ne donne aucune information sur η ; il n'indique que la direction de la pente, mais pas jusqu'où elle s'étend

Marquardt \Rightarrow les composantes de la matrice de courbure contiennent de l'information quant à l'ordre de grandeur de η :

χ^2 est sans dimension

β_k a la dimension de $\frac{1}{a_k}$

$\Rightarrow \eta$ doit avoir la dimension de a_k^2

Or, il n'y a dans la matrice de courbure que $\frac{1}{\alpha_{kk}}$ qui ait la dimension de a_k^2

\Rightarrow on suppose que $\frac{1}{\alpha_{kk}}$ définit l'échelle de η

Mais il faut se garder de choisir η trop grand, sinon on pourrait dépasser le minimum

⇒ on choisit

$$\eta_k = \frac{1}{\lambda \alpha_{kk}} \quad (\lambda > 0)$$

⇒ (9) devient :

$$\delta a_k = \frac{1}{\lambda \alpha_{kk}} \beta_k$$

ou encore :

$$\lambda \alpha_{kk} \delta a_k = \beta_k \quad (10)$$

⇒ on peut combiner (8) et (10) en écrivant :

$$\sum_{l=1}^M \alpha'_{kl} \delta a_l = \beta_k \quad (11)$$

avec

$$\alpha'_{kk} = \alpha_{kk} (1 + \lambda)$$

et

$$\alpha'_{kl} = \alpha_{kl} \quad (k \neq l)$$

Lorsque λ est grand, on se déplace selon la plus grande pente

Lorsque λ est petit, on retombe sur la méthode quadratique (métrique variable, *quasi-Newton*)

Algorithme :

- (1) choisir une valeur initiale de \vec{a}
- (2) calculer $\chi^2(\vec{a})$
- (3) prendre une valeur initiale de λ (ex.: $\lambda = 0.001$)
- (4) résoudre (11) et calculer $\chi^2(\vec{a} + \delta\vec{a})$
- (5) si $\chi^2(\vec{a} + \delta\vec{a}) > \chi^2(\vec{a})$, augmenter λ d'un facteur 10 et retourner en (4)
- (6) si $\chi^2(\vec{a} + \delta\vec{a}) < \chi^2(\vec{a})$, diminuer λ d'un facteur 10, se déplacer de \vec{a} en $\vec{a} + \delta\vec{a}$ et retourner en (4)

Critère d'arrêt :

- s'arrêter lorsque χ^2 décroît d'une valeur négligeable (ex.: 0.001)
- ne jamais s'arrêter après une augmentation de λ

Une fois le minimum atteint :

Poser $\lambda = 0$ puis calculer la matrice de covariance

$$C = \alpha^{-1}$$