



Optimisation non linéaire sans contraintes

Recherche opérationnelle
GC-SIE

Moindres carrés

Moindres carrés

$$\min f(x) = \frac{1}{2} \|g(x)\|^2 = \frac{1}{2} \sum_{i=1}^m \|g_i(x)\|^2$$

- $g_i: \mathbb{R}^m \rightarrow \mathbb{R}^{r(i)}$ est continûment différentiable, $i=1, \dots, m$
- On a souvent $r(i) = 1$.

Moindres carrés

Exemple :

Estimation des paramètres d'un modèle

- Soit un modèle mathématique

$$z = h(x, y)$$

- x est le vecteur des paramètres inconnus.
- y est le vecteur d'entrée du modèle.
- z est le vecteur de sortie du modèle.
- On dispose de m observations (y_i, z_i)

Moindres carrés

- Question : quelles sont les valeurs des paramètres telles que le modèle reproduise le mieux les observations ?

$$\min \sum_{i=1}^m (z_i - h(x, y_i))^2$$

Moindres carrés

Exemple :

- On veut mesurer la résistivité du cuivre.
- On dispose d'une barre de 1m de cuivre, de section 1cm².
- L'expérience consiste à envoyer des courants de diverses intensités et de mesurer la différence de potentiel.
- Le modèle mathématique est donné par la loi d'Ohm.

Moindres carrés

- Paramètre inconnu : résistance R
- Entrée du modèle : intensité I
- Sortie du modèle : diff. potentiel V
- Modèle mathématique :

$$V = R I = (\lambda/S) \rho I$$



où λ est la longueur, S la section et ρ la résistivité du cuivre.

Moindres carrés

- Données récoltées :

Intensité	Voltage
0.100	1.70E-05
0.105	1.74E-05
0.110	1.89E-05
0.115	2.01E-05
0.120	1.94E-05
0.125	2.16E-05
0.130	2.01E-05
0.135	2.28E-05
0.140	2.37E-05
0.145	2.34E-05

Intensité	Voltage
0.150	2.19E-05
0.155	2.68E-05
0.160	2.67E-05
0.165	2.76E-05
0.170	2.72E-05
0.175	2.77E-05
0.180	2.62E-05
0.185	2.78E-05
0.190	2.80E-05
0.195	3.09E-05
0.200	3.45E-05




Moindres carrés

Réseaux de neurones.

- Modèle spécifié par un système multi-niveaux.
- Le niveau consiste en n_k unités d'activation ou **neurone**.
- Chaque unité d'activation est une relation entrée-sortie

$$\phi: \mathbb{R} \rightarrow \mathbb{R}$$

Moindres carrés



Moindres carrés

- La sortie de la $j^{\text{ème}}$ unité d'activation du niveau $k+1$ est notée x_{k+1}^j .
- L'entrée est une fonction linéaire des sorties du niveau k .
- Donc

$$x_{k+1}^j = \phi \left(u_k^{0j} + \sum_{s=1}^{n_k} x_k^s u_k^{sj} \right) \quad j = 1, \dots, n_{k+1}.$$

Moindres carrés

- Les u_k^s sont appelés « poids »
- Ce sont les paramètres à déterminer.
- Pour un ensemble de paramètres donnés, et si N est le nombre de niveaux, à chaque vecteur d'entrée x_0 du niveau 0 correspond un vecteur de sortie x_N du niveau N .

Moindres carrés

- Le réseau de neurones peut donc être considéré comme un modèle mathématique

$$z=h(x,y)$$

- où
 - x est le vecteur de poids
 - y est le vecteur d'entrées au niveau 0
 - z est le vecteur de sorties au niveau N

Moindres carrés

- La phase d'entraînement du réseau, ou phase d'apprentissage peut donc être considérée comme la résolution d'un problème de moindres carrés.
- Exemples typiques de fonctions d'activation :

Fonction sigmoïdale :

$$\phi(\xi) = \frac{1}{1 + e^{-\xi}}$$

Fonction hyperbolique tangente :

$$\phi(\xi) = \frac{e^{\xi} - e^{-\xi}}{e^{\xi} + e^{-\xi}}$$


Moindres carrés

- Le problème d'entraînement de réseaux neuronaux est souvent très compliqué. Les fonctions de coûts associées sont non-convexes et possèdent souvent des minima locaux multiples.
- Exemple à deux paramètres.

Moindres carrés

Michel Bierlaire

17



Gauss-Newton

$$\min f(x) = \frac{1}{2} \|g(x)\|^2 = \frac{1}{2} \sum_{i=1}^m \|g_i(x)\|^2$$

Idée

- Travailler sur g et non sur f .
- Linéarisation de g :

$$m(x) = g(x_k) + \nabla g(x_k)^T (x - x_k)$$

Gauss-Newton

- Minimiser la norme de $m(x)$



$$\begin{aligned} \frac{1}{2} \|m(x)\|^2 = & \\ & \frac{1}{2} \|g(x_k)\|^2 \\ & + (x - x_k)^T \nabla g(x_k) g(x_k) \\ & + \frac{1}{2} (x - x_k)^T \nabla g(x_k) \nabla g(x_k)^T (x - x_k) \end{aligned}$$

Gauss-Newton

- Si $f(x) = \frac{1}{2} \|m(x)\|^2$, alors

$$\nabla f(x) = \nabla g(x_k) \nabla g(x_k)^T (x - x_k) + \nabla g(x_k) g(x_k)$$

- Le minimum est atteint en

$$x = x_k - (\nabla g(x_k) \nabla g(x_k)^T)^{-1} \nabla g(x_k) g(x_k)$$

si la matrice est inversible.

Gauss-Newton

- Une itération Gauss-Newton pure est

$$x_{k+1} = x_k - (\nabla g(x_k) \nabla g(x_k)^T)^{-1} \nabla g(x_k) g(x_k)$$

- $\nabla g(x_k) g(x_k)$ est le gradient de $\frac{1}{2} \|g(x)\|^2$ en x_k
- Si $\nabla g(x_k) \nabla g(x_k)^T$ est définie positive, nous avons donc une **direction de descente**.

Gauss-Newton

- Tout comme la méthode de Newton pure pour le cas général, la méthode de Gauss-Newton pure pour les moindres carrés peut ne pas converger.
- Solution :

$$x_{k+1} = x_k - \alpha_k (\nabla g(x_k) \nabla g(x_k)^T + \Delta_k)^{-1} \nabla g(x_k) g(x_k)$$

Gauss-Newton

$$x_{k+1} = x_k - \alpha_k (\nabla g(x_k) \nabla g(x_k)^T + \Delta_k)^{-1} \nabla g(x_k) g(x_k)$$

- α_k est choisi par la règle d'Armijo.
- Δ_k est une matrice diagonale telle que $\nabla g(x_k) \nabla g(x_k)^T + \Delta_k$ soit défini positif.
- Méthode de Levenberg-Marquardt :
 $\Delta_k =$ multiple de l'identité

Gauss-Newton

Cas linéaire

- $g(x) = Cx - z$
- $\nabla g(x) = C^T$
- $x_{k+1} = x_k - (C^T C)^{-1} C^T (Cx_k - z)$
 $= (C^T C)^{-1} C^T z \quad \forall k$
- **La solution est obtenue en une itération**
- **Note:** le système d'équations
 $C^T C x = C^T z$
est appelé **équations normales**.



Gauss-Newton

Relation avec la méthode de Newton

- Soit $g: \mathbb{R}^n \rightarrow \mathbb{R}^m$
- $f(x) = \frac{1}{2} \|g(x)\|^2$

$$\nabla f(x) = \nabla g(x)^T g(x)$$

$$= \sum_{i=1}^m \nabla g_i(x) g_i(x)$$




Gauss-Newton


$$\begin{aligned}\nabla^2 f(x) &= \sum_{i=1}^m [\nabla^2 g_i(x) g_i(x) \\ &\quad + \nabla g_i(x) \nabla g_i(x)^T] \\ &= \nabla g(x) \nabla g(x)^T \\ &\quad + \sum_{i=1}^m \nabla^2 g_i(x) g_i(x)\end{aligned}$$

Gauss-Newton = Newton
en négligeant le second terme

Régression orthogonale



Régression orthogonale



Régression orthogonale

Notes :

- Cette régression est utilisée lorsque des erreurs sont présentes aussi dans les entrées du modèle.
- On suppose que les erreurs dans les entrées et les erreurs dans les sorties sont indépendantes, de moyenne nulle.
- Même si le modèle est linéaire, le problème de moindres carrés n'est pas linéaire.

Régression orthogonale

- Exemples :
 - Résistivité du cuivre
 - Moindres carrés : $r = 1.61046 \cdot 10^{-8}$
 - Régression orthogonale : $1.60797 \cdot 10^{-8}$
 - Modèle sphérique :
 - $z = x_1 + [x_2^2 - (y - x_3)^2]^{1/2}$

Moindres carrés

Michel Bierlaire

31

Régression orthogonale

y	z
0.0000	5.8776
0.0974	5.7608
0.2042	5.5878
0.3090	5.7680
0.3911	6.0966
0.5092	6.3744
0.5972	5.9919
5.2431	6.4085
5.8022	5.9953
5.6136	5.7521
5.7435	5.6481
6.1645	5.6582
6.1940	5.5383

Modèle réel :

- $x_1 = 3$
- $x_2 = 4$
- $x_3 = 3$

Moindres carrés :

- $x_1 = 1.9809$
- $x_2 = 4.7794$
- $x_3 = 2.9938$

Orthogonale :

- $x_1 = 3.2759$
- $x_2 = 3.8001$
- $x_3 = 3.0165$

Moindres carrés

Michel Bierlaire

32

