

Optimisation

Thierry Dhorne by Salim Lardjane

1^{er} février 2018

Introduction

Exemple

Moindres carrés

Autre exemple

Vraisemblance

Problématique

Applications

Introduction

Exemple

Introduction

Exemple

Moindres carrés

Autre exemple

Vraisemblance

Problématique

Applications

- problème usuel dans le cours de Statistique
- estimer les paramètres d'un modèle
- par exemple un modèle de régression linéaire
- le modèle s'écrit généralement

$$Y_r = \beta_0 + \beta_1 x_r + E_r$$

avec

- Y_r valeurs observables de la variable (aléatoire) expliquée
- x_r valeurs observées de la variable (aléatoire) explicative
- E_r valeurs de l'erreurs (aléatoire) résiduels postulés d'espérance nulle (non restrictif) et i.i.d. (assez restrictif)

Moindres carrés

Introduction

Exemple

Moindres carrés

Autre exemple

Vraisemblance

Problématique

Applications

- l'estimation de β_0 et de β_1 peut être réalisée par le maximum de vraisemblance

- qui conduit aux critère des moindres carrés

$$S(\beta_0, \beta_1) = \sum_{r=1}^n (y_r - \beta_0 - \beta_1 x_r)^2$$

où les y_r désignent des réalisations de la variable aléatoire expliquée

- $S(\beta_0, \beta_1)$ quantifie en un certain sens l'ajustement du modèle aux données

- la maximisation de la vraisemblance conduit à la minimisation du critère des moindres carrés

Autre exemple

Introduction

Exemple

Moindres carrés

Autre exemple

Vraisemblance

Problématique

Applications

- estimation des paramètres d'une densité de probabilité
- à partir d'un échantillon aléatoire issu de la loi correspondante.
- on dispose d'un échantillon observé

$$x_1, x_2, \dots, x_r, \dots, x_n$$

- issu d'une loi de probabilité de densité $f_\theta(x)$ (ou de masse $p_\theta(k)$)
- prenons l'exemple d'une loi exponentielle

$$f(x) = \lambda e^{-\lambda x} = \frac{1}{\sigma} e^{-\frac{x}{\sigma}}$$

- et cherchons à estimer λ (ou σ)

Vraisemblance

Introduction

Exemple

Moindres carrés

Autre exemple

Vraisemblance

Problématique

Applications

- on rappelle que la vraisemblance est vue comme une fonction
 - d'argument λ
 - de paramètres $\{x_1, x_2, \dots, x_r, \dots, x_n\}$

$$\mathcal{L}_{x_1, x_2, \dots, x_r, \dots, x_n}(\lambda) = \prod_{r=1}^n \lambda e^{-\lambda x_r}$$

- l'estimation du maximum de vraisemblance de λ est la valeur qui maximise

$$\prod_{r=1}^n \lambda e^{-\lambda x_r}$$

encore notée l

$$l = \arg \max_{\lambda} \prod_{r=1}^n \lambda e^{-\lambda x_r}$$

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -

Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

Problématique

Problème d'optimisation

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions
Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- le problème considéré porte sur l'optimisation (minimisation ou maximisation) d'une fonction

$$f(x_1, x_2, \dots, x_m)$$

de m arguments x_1, x_2, \dots, x_m

- c'est-à-dire une fonction de \mathbb{R}^m dans \mathbb{R}
- ★ il est équivalent de maximiser f et de minimiser $-f$
- on se limite habituellement à l'étude du problème de minimisation.

- dans le cas de l'estimation statistique
 - les arguments de la fonction à minimiser (- la vraisemblance) sont les paramètres du modèle
 - les solutions de la minimisation sont les estimations (ou les estimateurs sous forme analytique)
- ces arguments peuvent être contraints ou non
 - b_0 et b_1 sont a priori non contraints
 - l est censé être strictement positif

Présentation du problème

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- on va présenter le problème dans un cas simple
- univarié
- on étendra les intuitions (démonstrations?) au cas multivarié

Un exemple de fonction à minimiser

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -

Constatations

Conclusions

Conditions
d'extremum


Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications



Optimisation(s)

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions
Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- le graphique montre que la fonction possède
 - deux minima -> on les appelle x_1 et x_2
 - un maximum -> on l'appelle x_3
- x_1 est un minimum global (absolu)
- x_2 est un minimum local (relatif)
- x_3 est un maximum local
- il n'y a pas (semble-t-il?) de maximum global

Conditions

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- ★ les gens qui ont le sens de l'analyse ont noté que
- pour les points concernés les tangentes sont horizontales
- donc les dérivées sont nulles

$$x^* = \text{arg ext}(\text{max ou min}) \Rightarrow \frac{df}{dx}(x^*) = 0$$

- ★ mais la réciproque est fausse

Points de dérivée nulle

Introduction

Problématique

Problème d'optimisation

Présentation du problème

Un exemple de fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée nulle

Points selles (ou d'inflexion) -

Constatations

Conclusions

Conditions d'extremum


Vérification avec la dérivée première

Vérification avec la dérivée seconde

Cas multivarié

Condition suffisante

Applications



Points selles (ou d'inflexion) - Constatations

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- on retrouve sur le graphique les trois points prévus
 - plus un quatrième dont on peut démontrer que la dérivée s'annule pour lui
 - on l'appelle x_4
- on s'aperçoit que pour ce point (à vélo) la vitesse diminue puis réaugmente
 - la dérivée première va jusqu'à s'annuler mais reprend des valeurs positives
 - elle passe donc par un minimum
 - ★ elle s'annule ponctuellement sans changer de signe
- à la différence des minima pour lesquels
- la vitesse diminue et continue de diminuer
 - elle ne passe donc pas par un minimum
 - ★ elle s'annule en changeant de signe

Conclusions

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions
Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- on a vu que $x^* = \text{arg ext}(\max \text{ ou } \min) \Rightarrow \frac{df}{dx}(x^*) = 0$

- mais la réciproque n'est pas vraie

$$\frac{df}{dx}(x^*) = 0 \not\Rightarrow x^* = \text{arg ext}(\max \text{ ou } \min)$$

- pour les points d'inflexion
 - on a vu que la dérivée s'annule mais ne change pas de signe
 - ★ elle passe donc (elle) par un extremum
- et pour les extrema
 - elle s'annule et change de signe sans atteindre d'extremum

Conditions d'extremum

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- pour un extremum la dérivée change de signe (sans passer par un extremum) et donc sa dérivée vérifie

$$\frac{d^2 f}{dx^2}(x^*) > 0$$

ou

$$\frac{d^2 f}{dx^2}(x^*) < 0$$

- à ajouter à la contrainte sur la dérivée première

$$\frac{df}{dx}(x^*) = 0$$

- à l'inverse pour les points d'inflexion, pour la valeur précise d'annulation de la dérivée première on a

$$\frac{d^2 f}{dx^2}(x^*) = 0$$

Vérification avec la dérivée première

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum


Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications



Vérification avec la dérivée seconde

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum


Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications



Cas multivarié

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions
Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- on peut étendre le raisonnement à la minimisation d'une fonction de plusieurs variables

$$f(x_1, x_2, \dots, x_m)$$

- une condition nécessaire pour qu'un point $x^* = (x_1^*, x_2^*, \dots, x_m^*)$ corresponde à un minimum est

$$\frac{\partial f}{\partial x_1}(x^*) = \frac{\partial f}{\partial x_2}(x^*) = \dots = \frac{\partial f}{\partial x_m}(x^*) = 0$$

- ★ les solutions de cette équation peuvent également correspondre à des maxima ou à des points-selles
- il s'agit donc comme plus haut d'une condition nécessaire

Condition suffisante

Introduction

Problématique

Problème
d'optimisation

Présentation du
problème

Un exemple de
fonction à minimiser

Optimisation(s)

Conditions

Points de dérivée
nulle

Points selles (ou
d'inflexion) -
Constatations

Conclusions

Conditions
d'extremum

Vérification avec la
dérivée première

Vérification avec la
dérivée seconde

Cas multivarié

Condition suffisante

Applications

- une condition suffisante pour qu'une solution x^* de l'équation précédente corresponde à un minimum

- est que la matrice $H(x^*)$ d'éléments

$$h_{ij}(x^*) = \frac{\partial^2 f}{\partial x_i \partial x_j}(x^*)$$

soit définie positive

- cette matrice de dimension m est naturellement symétrique
- ★ elle est appelée matrice hessienne (ou hessien) de f

Mais savez-vous bien ce qu'est une matrice définie positive?



Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

Applications

Estimation par ML du paramètre d'une loi exponentielle

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- la vraisemblance de l'échantillon a été indiquée plus haut

$$\mathcal{L}_{x_1, x_2, \dots, x_r, \dots, x_n}(\lambda) = \prod_{r=1}^n \lambda e^{-\lambda x_r}$$

- on cherche la valeur l qui maximise en λ l'expression précédente
- on va d'abord prendre le ln de cette expression
- ★ en effet la fonction ln
 - ne modifie pas l'argument du maximum car c'est une fonction strictement monotone (croissante)
 - simplifie les calculs en « supprimant » les exponentiations

Passage par la ln-vraisemblance

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- l'expression devient

$$\begin{aligned}\ln(\mathcal{L})_{x_1, x_2, \dots, x_r, \dots, x_n}(\lambda) &= \sum_{r=1}^n (\ln(\lambda) - \lambda x_r) \\ &= n(\ln(\lambda) - \lambda \sum_{r=1}^n x_r)\end{aligned}$$

- on dérive cette expression par rapport à λ

$$\frac{\partial \ln(\mathcal{L})}{\partial \lambda} = n \frac{1}{\lambda} - \sum_{r=1}^n x_r$$

- on annule cette dérivée

$$n \frac{1}{\lambda} - \sum_{r=1}^n x_r = 0$$

Solution

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- la solution est

$$l = \frac{n}{\sum_{r=1}^n x_r} = \frac{1}{\bar{x}}$$

- la dérivée seconde de la ln-vraisemblance est

$$\frac{\partial^2 \ln(\mathcal{L})}{\partial \lambda^2} = -\frac{n}{l^2} < 0$$

- la dérivée seconde est toujours négative

- la vraisemblance atteint donc bien un maximum au point concerné

Régression linéaire simple

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- on veut minimiser la somme des carrés des écarts

$$S(\beta_0, \beta_1) = \sum_{r=1}^n (y_r - \beta_0 - \beta_1 x_r)^2$$

- la condition nécessaire de minimum s'écrit

$$\begin{cases} \frac{\partial S}{\partial \beta_0}(b_0, b_1) = 0 \\ \frac{\partial S}{\partial \beta_1}(b_0, b_1) = 0 \end{cases}$$

- soit

$$\begin{cases} \sum_{r=1}^n (y_r - b_0 - b_1 x_r) = 0 \\ \sum_{r=1}^n x_r (y_r - b_0 - b_1 x_r) = 0 \end{cases}$$

Matrice hessienne

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- la matrice hessienne est

$$2 \begin{pmatrix} \sum_{r=1}^n 1 & \sum_{r=1}^n x_r \\ \sum_{r=1}^n x_r & \sum_{r=1}^n x_r^2 \end{pmatrix}$$

- les valeurs propres de la matrice vérifient l'équation

$$(n - \alpha) \left(\sum_{r=1}^n x_r^2 - \alpha \right) - \left(\sum_{r=1}^n x_r \right)^2 = 0$$

$$\alpha^2 - \left(\sum_{r=1}^n x_r^2 + n \right) \alpha + n \sum_{r=1}^n x_r^2 - \left(\sum_{r=1}^n x_r \right)^2 = 0$$

- elles sont égales à

$$n + \sum_{r=1}^n x_r^2 \pm \sqrt{\left(n - \sum_{r=1}^n x_r^2 \right) + 4 \left(\sum_{r=1}^n x_r \right)^2}$$

Signe des valeurs propres - 1

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- la première valeur propre

$$n + \sum_{r=1}^n x_r^2 + \sqrt{(n - \sum_{r=1}^n x_r^2) + 4(\sum_{r=1}^n x_r)^2}$$

- est manifestement positive

- montrons que la seconde l'est aussi c'est-à-dire que

$$n + \sum_{r=1}^n x_r^2 > \sqrt{(n - \sum_{r=1}^n x_r^2) + 4(\sum_{r=1}^n x_r)^2}$$

- soit en élevant au carré

$$(n + \sum_{r=1}^n x_r^2)^2 > (n - \sum_{r=1}^n x_r^2) + 4(\sum_{r=1}^n x_r)^2$$

Signe des valeurs propres - 2

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- ce qui est équivalent à

$$n^2 + \left(\sum_{r=1}^n x_r^2\right)^2 + 2n \sum_{r=1}^n x_r^2 > n^2 + \left(\sum_{r=1}^n x_r^2\right)^2 - 2n \sum_{r=1}^n x_r^2 + 4\left(\sum_{r=1}^n x_r\right)^2$$

\Leftrightarrow

$$4n \sum_{r=1}^n x_r^2 > 4\left(\sum_{r=1}^n x_r\right)^2$$

\Leftrightarrow

$$n \sum_{r=1}^n x_r^2 - \left(\sum_{r=1}^n x_r\right)^2 > 0$$

\Leftrightarrow

$$\sum_{r=1}^n (x_r - \bar{x})^2 > 0$$

★ cette dernière égalité est évidemment vérifiée et donc la matrice est s.d.p.

Conclusions

Introduction

Problématique

Applications

Estimation par ML
du paramètre d'une
loi exponentielle

Passage par la
ln-vraisemblance

Solution

Régression linéaire
simple

Matrice hessienne

Signe des valeurs
propres - 1

Signe des valeurs
propres - 2

Conclusions

- dans les deux cas précédents, les équations spécifiant l'optimum ont pu être résolues explicitement.
- ce n'est pas toujours le cas en pratique
- comme pour les paramètres de la loi Γ
- ★ d'où l'intérêt des algorithmes de résolution numérique