

# Eléments de statistiques pour les data sciences

## Cours 10: tests et ensembles de confiance

Dr. Ph. Müllhaupt

IGM - EPFL

—

- 1 test composite et rapport de vraisemblance
- 2 estimateur d'intervalle
- 3 inversion d'une statistique de test
- 4 ensemble d'acceptation et ensemble de confiance
- 5 inversion d'un test de rapport de vraisemblance
- 6 quantités pivot

# test du rapport de vraisemblance

formulation générale

- ensemble de paramètres  $\Omega$  sous ensemble  $\omega \subset \Omega$  associé à  $H_0$
- hypothèses composites  $H_0 : \theta \in \omega$  vs.  $H_1 : \theta \in \Omega \setminus \omega$
- $x \in \mathcal{X}$
- rapport de vraisemblance

$$\lambda(x) = \frac{\sup_{\omega} L(\theta|x)}{\sup_{\Omega} L(\theta|x)}$$

- région de rejet (= ensemble critique  $C$ )

$$\mathcal{R} = C = \{x | \lambda(x) \leq k\} \quad 0 \leq k \leq 1$$

- ensemble d'acceptation

$$\mathcal{A} = \{x | \lambda(x) > k\} \quad 0 \leq k \leq 1$$

# test du rapport de vraisemblance

seuil d'acceptation  $k$  et probabilité  $\alpha$

- hypothèses composites  $H_0 : \theta \in \omega \subset \Omega$  vs.  $H_1 : \theta = \Omega \setminus \omega$
- la constante  $0 \leq k \leq 1$  est choisie de telle sorte que

$$\sup_{\theta \in \omega} P_{\theta}(\lambda(x) \leq k) = \alpha$$

## test composite

$$H_0 : \theta = \theta_0 \text{ vs } H_1 : \theta \neq \theta_0$$

- rapport de vraisemblance

$$\lambda = \frac{L(\theta|H_0; x)}{\max_{\theta \neq \theta_0} L(\theta; x)}$$

- Le dénominateur est  $L(\hat{\theta}_{\text{MLE}})$
- $0 < \lambda \leq 1$
- En prenant le logarithme de la vraisemblance, ceci conduit à

$$\log L(\theta_0|H_0; x) - \log L(\hat{\theta}_{\text{MLE}}; x)$$

- Taille du test : la constante  $k$  est choisie telle que

$$\alpha = \sup_{\theta \in \omega} P_{\theta} \{ \lambda(X) \leq k \}$$

avec  $\omega$  est l'ensemble des paramètres associés à  $H_0$ .

## Exemple

$X_1, \dots, X_n$  i.i.d  $\sim \mathcal{N}(\mu, \sigma^2)$ ,  $\mu$  inconnu

- On observe la réalisation de  $n$  variables gaussiennes indépendantes
- On ne connaît pas  $\mu$ , mais  $\sigma^2$  est connu.
- On aimerait un test  $H_0 : \mu \leq \mu_0$   $H_1 : \mu > \mu_0$  C'est un test composite.

Comme les variables sont indépendantes, la probabilité jointe est le produit des probabilités individuelles.

$$L(\mu) = \prod_{i=1}^n f(x_i) = k \exp(-(x_i - \mu)^2 / (2\sigma^2))$$

## Exemple

Maximum de vraisemblance pour Gaussiennes  $\mu$  et  $\sigma$  inconnus

Supposons que la variance ne soit pas connue également. On ne connaît ni la moyenne, ni la variance. Calculons l'estimateur de maximum de vraisemblance.

$$L(\mu, \sigma) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp(-(x_i - \mu)^2 / (2\sigma^2))$$

avec  $\sigma > 0$ ,  $-\infty < \mu < +\infty$ .

$$l(\mu, \sigma) = -n \log \sigma - \frac{1}{2\sigma^2} \sum (x_i - \mu)^2$$

les conditions nécessaires pour  $\hat{\sigma}$ ,  $\hat{\mu}$  sont

$$\frac{\partial l}{\partial \mu} = \frac{1}{\sigma^2} (\sum x_i - n\mu) \triangleq 0$$

$$\frac{\partial l}{\partial \sigma} = \frac{1}{\sigma^3} [\sum (x_i - \mu)^2 - n\sigma^2] \triangleq 0$$

et après résolution on trouve les estimateurs de maximum de vraisemblance

$$\hat{\mu} = \frac{\sum x_i}{n} = \bar{x}$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum (x_i - \bar{x})^2$$



A première vue, il semblerait que la vraisemblance dépende de toutes les variables individuelles  $x_i$ . On va montrer que la vraisemblance dépend uniquement de deux fonctions de celles-ci...

$$\begin{aligned}(x_i - \mu)^2 &= (\underbrace{x_i - \bar{x}}_A + \underbrace{\bar{x} - \mu}_B)^2 = A^2 + B^2 + 2AB \\ &= (x_i - \bar{x})^2 + (\bar{x} - \mu)^2 + 2(x_i - \bar{x})(\bar{x} - \mu) \\ \sum (x_i - \mu)^2 &= \sum (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 + 2(\bar{x} - \mu) \sum (x_i - \bar{x})\end{aligned}$$

et comme  $\sum_{i=1}^n x_i$  on a  
 $\sum (x_i - \bar{x}) = 0$

$$\sum (x_i - \bar{x}) = \left( \sum x_i \right) - n\bar{x} = 0$$

et donc

$$\sum (x_i - \mu)^2 = \sum (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 = n\hat{\sigma}^2 + n(\hat{\mu} - \mu)^2$$

de telle sorte que la vraisemblance s'écrit sous la forme

$$L(\mu, \sigma) = \sigma^{-n} \exp \left( -\frac{n}{2\sigma^2} [\hat{\sigma}^2 + (\hat{\mu} - \mu)^2] \right)$$

## Exemple

variance  $\sigma^2$  connue

Lorsque la variance  $\sigma^2$  est connue, la vraisemblance devient alors

$$L(\mu) = \exp \left\{ -\frac{n}{2\sigma^2} (\bar{X} - \mu)^2 \right\}$$

Elle est maximale lorsque  $\hat{\mu} = \bar{x}$  car alors  $L(\hat{\mu}) = 1$  et

$$\lambda(\mu) = L(\mu) = \exp \left\{ -\frac{n}{2\sigma^2} (\bar{x} - \mu)^2 \right\}$$

et la statistique de la déviance prend la forme

$$D = -2 \log \lambda = n \left( \frac{\bar{X} - \mu}{\sigma} \right)^2 \triangleq Z$$

avec

$$Z = \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma}$$

On peut maintenant déterminer la distribution de  $D$ .

$$\bar{X} \sim \mathcal{N}(\mu, \sigma^2/n)$$

$$Z \sim \mathcal{N}(0, 1)$$

comme  $D = Z^2$

$$D \sim \chi_{(1)}^2$$

## Exemple

test pour  $H_0 : \mu = \mu_0$

On obtient une valeur de  $D$  observée, appelée  $d$

$$d = z_{\text{obs}}^2 \quad z_{\text{obs}} = \frac{\sqrt{n}(\bar{x} - \mu_0)}{\sigma}$$

Comme  $D = Z^2$  on aura le niveau de signification qui dans le cas composite  $H_1 : \mu \neq \mu_0$  sera également la probabilité d'erreur de type I

$$\alpha = \text{NS} = P(D \geq d) = P(|Z| \geq |z_{\text{obs}}|)$$

L'hypothèse  $H_0$  est rejetée lorsque


$$\frac{|\bar{X} - \mu|}{\sigma/\sqrt{n}} > k$$

On a justifié ce qui était dans l'énoncé de l'Exercice 5, Série 10

## Exemple 2

variables distribuées exponentiellement

$$H_0 : \theta = \theta_0 \text{ vs } H_1 : \theta \neq \theta_0$$



- $X_1, X_2, \dots, X_n \sim \text{Exp}(\lambda)$
- La moyenne est  $\theta$  et donc  $\lambda = \frac{1}{\theta}$  et la distribution de  $X_i$  est  

$$f_i(x) = \lambda e^{-\lambda x} = \frac{1}{\theta} e^{-\frac{1}{\theta} x} \text{ avec } x \in [0; +\infty[$$



$$\lambda = \frac{\theta_0 \frac{1}{\lambda_0^n} e^{-(\sum x_i)/\lambda_0}}{\sup_{\lambda} \frac{1}{\lambda^n} e^{-(\sum x_i)/\lambda}}$$

$$\begin{aligned}\lambda &= \frac{\frac{1}{\lambda_0^n} e^{-(\sum x_i)/\lambda_0}}{\sup_{\lambda} \frac{1}{\lambda^n} e^{-(\sum x_i)/\lambda}} \\ &= \frac{\frac{1}{\lambda_0^n} e^{-\sum x_i/\lambda_0}}{\frac{1}{(\sum x_i/n)^n} e^{-n}} = \left( \frac{\sum x_i}{n\lambda_0} \right)^n e^n e^{-\sum x_i/\lambda_0}\end{aligned}$$

$$\bar{x} = \frac{\sum x_i}{n}$$

Le test est rejeté lorsque la condition suivante est vérifiée

$$C = \left\{ x \mid \left( \frac{\sum x_i}{\lambda_0} \right)^n e^{-\sum x_i/\lambda_0} < k \right\}$$

$\frac{e^n}{n^n}$  dépend  
de  $\lambda_0$  et  
 $\sum x_i$

avec  $k$  choisi de telle sorte que

$$P_x\{C\} = \alpha$$

## estimateur d'intervalle

non nécessairement symétrique

Soit  $X_1, X_2, \dots, X_n$  des variables aléatoires.

### définition

Un estimateur d'intervalle d'un paramètre réel  $\theta$  est une paire de fonctions  $L(x_1, \dots, x_n)$  et  $U(x_1, \dots, x_n)$  d'un échantillon  $x_1, x_2, \dots, x_n$  qui satisfait

$$L(x_1, \dots, x_n) \leq U(x_1, \dots, x_n), \forall x_1, \dots, x_n$$

Lorsque  $x_1, \dots, x_n$  sont observé alors on peut faire l'inférence

$$\theta \in [L(x_1, \dots, x_n); U(x_1, \dots, x_n)]$$

*pas nécessairement symétrique par rapport à  
un estimateur ponctuel  $\hat{\theta}_{MLE}$*

# estimateur d'intervalle

## exemple

Soit  $X_1, X_2, X_3, X_4 \sim \mathcal{N}(\mu, 1)$

Un estimateur d'intervalle pour  $\mu$  est, par exemple,

$$[\bar{X} - 1; \bar{X} + 1]$$



$$\begin{aligned}P(\mu \in [\bar{X} - 1; \bar{X} + 1]) &= P(\bar{X} - 1 \leq \mu \leq \bar{X} + 1) \\&= P\left(-2 \leq \frac{\bar{X} - \mu}{\sqrt{1/4}} \leq 2\right) \\&= P(-2 \leq Z \leq 2) \\&= 0.9544\end{aligned}$$

## probabilité de couverture

définition

Comme l'intervalle dépend des échantillons, il peut ou non couvrir le paramètre  $\theta$ .

définition

probabilité de couverture

$$P_{\theta}(\theta \in [L(x_1, \dots, x_n); U(x_1, \dots, x_n)])$$

$$= P_{\theta}(\underbrace{L(x_1, \dots, x_n)}_{\text{lower bound}} \leq \theta, \underbrace{U(x_1, \dots, x_n)}_{\text{upper bound}} \geq \theta)$$

définition

coefficient de confiance

$$\inf_{\theta} P_{\theta}(\theta \in [L(x_1, \dots, x_n); U(x_1, \dots, x_n)])$$

ATTENTION : c'est l'intervalle qui est aléatoire, pas le paramètre  $\theta$ !!!

## estimateur d'intervalle — intervalle de confiance

- estimateur d'intervalle + coefficient de confiance = intervalle de confiance
- On a déjà utilisé ce concept pour  $Z \sim \mathcal{N}(\mu, \sigma)$  et pour  $T$  de la distribution de Student  $\Rightarrow$  intervalles symétriques.
- On peut utiliser de manière équivalente "estimateur d'intervalle" et "intervalle de confiance"

inversion d'un test normal

variables i.i.d.

- Soit  $X_1, X_2, \dots, X_n$  des variables aléatoires identiquement distribuées et indépendantes de loi  $\mathcal{N}(\mu, \sigma^2)$
- $H_0 : \mu = \mu_0$  vs.  $H_1 : \mu \neq \mu_0$
- $\alpha$  fixé
- région de rejet  $\{x \mid |\bar{x} - \mu_0| > z_{\alpha/2} \sigma / \sqrt{n}\}$

En partant de la région d'acceptation de  $H_0$

$$\mathcal{A} = \left\{ x_1, \dots, x_n \left| \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu_0 \leq \bar{x} - z_{\alpha/2} \frac{\alpha}{\sqrt{n}} \right. \right\}$$

on a

$$P\left(\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu_0 \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \mid \mu = \mu_0\right) = 1 - \alpha$$

### remarque importante

Cette équation est vraie *quelle que soit la valeur de*  $\mu_0$ .

## inversion d'un test normal

cela conduit donc à ce que la proposition


$$P_{\mu} \left( \bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right) = 1 - \alpha$$

soit vraie.

L'intervalle

$$[\bar{x} - z_{\alpha/2} \sigma / \sqrt{n}; \bar{x} + z_{\alpha/2} \sigma / \sqrt{n}]$$

obtenu en *inversant* la région d'acceptation de  $H_0$  d'un test de taille  $\alpha$  s'appelle un intervalle de confiance à  $1 - \alpha$  probabilité.



$C$  : ~~région critique~~

$C$  : intervalle  
de confiance

## inversion d'un test normal

- région de l'espace des échantillons  $\mathcal{X}$  d'acceptation du test  $H_0$

$$\mathcal{A}(\mu_0) = \left\{ (x_1, \dots, x_n) \left| \mu_0 - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \bar{x} \leq \mu_0 + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right. \right\}$$

- intervalle de confiance, ensemble de l'espace des paramètres, ensemble plausible des  $\mu$

$$\mathcal{C}(x_1, \dots, x_n) = \left\{ \mu \left| \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right. \right\}$$

## Exemple

variables i.i.d. exponentielles

On revient vers l'exemple 2 des variables exponentielles. Le rapport de vraisemblance conduit à

- Pour  $\lambda_0$  fixé, l'ensemble d'acceptation s'écrit

$$\mathcal{A}(\lambda_0) = \left\{ \mathbf{x} \mid \left( \frac{\sum x_i}{\lambda_0} \right)^n \exp \left( - \sum x_i / \lambda_0 \right) \geq k \right\}$$

avec  $k$  choisit de telle sorte que  $P_{\lambda_0}$

- Inversion de l'ensemble d'acceptation conduit à l'intervalle de confiance à probabilité

$$\mathcal{C}(\mathbf{x}) = \left\{ \lambda \mid \left( \frac{\sum x_i}{\lambda} \right)^n \exp \left( - \sum x_i / \lambda \right) \geq k \right\}$$



- Les échantillons  $x_i$  apparaissent dans les expressions précédentes que sous la forme  $\sum x_i$ . Par la théorème de factorisation c'est une statistique suffisante.

$$\mathcal{C}(\sum x_i) = \{\lambda | L(\sum x_i) \leq \lambda \leq U(\sum x_i)\}$$

- les fonctions  $L$  et  $U$  sont déterminées par l'ensemble d'acceptation  $\mathcal{A}(\lambda_0)$  de telle sorte qu'il soit associé à une probabilité  $1 - \alpha$ . De plus

$$\left(\frac{\sum x_i}{L(\sum x_i)}\right)^n \exp(-\sum x_i / L(\sum x_i)) = \left(\frac{\sum x_i}{U(\sum x_i)}\right)^n \exp(-\sum x_i / U(\sum x_i))$$

- posons

$$a \triangleq \frac{\sum x_i}{L(\sum x_i)} \quad b \triangleq \frac{\sum x_i}{U(\sum x_i)}$$

- 

$$a^n e^{-a} = b^n e^{-b}$$

## Exemple 2

valeur particulière  $n = 2$

- cas particulier  $n = 2$

- $\alpha = 0.1$

- 

$$\sum X_i \sim \Gamma(2, \lambda) \quad \sum X_i / \lambda \sim \Gamma(2, 1)$$

- 

$$P_\lambda \left( \frac{1}{a} \sum X_i \leq \lambda \leq \frac{1}{b} \sum X_i \right) = P \left( b \leq \frac{\sum X_i}{\lambda} \leq a \right) =$$

- 

$$\begin{aligned} P \left( b \leq \frac{\sum X_i}{\lambda} \leq a \right) &= \int_b^a t e^{-t} dt \\ &= e^{-b}(b+1) - e^{-a}(a+1) \end{aligned}$$

*intégration  
par parties.*

$$\begin{array}{c}
 \int t e^{-t} \\
 \begin{array}{cc}
 \nearrow F & \nwarrow g \\
 & 
 \end{array}
 \end{array}
 = F G - \int f G$$

$$\begin{array}{c}
 t e^{-t} - \int e^{-t} \\
 \hline
 t e^{-t} - (-e^{-t})
 \end{array}$$

- $a = 5.48$  et  $b = 0.441$

défini.



- on a

$$P_{\lambda} \left( \frac{1}{5.48} \sum_{i=1}^2 X_i \leq \lambda \leq \frac{1}{0.441} \sum_{i=1}^2 X_i \right) = 0.90006$$

*1 - \alpha*

## quantité pivot

### définition

### quantité pivot

Une variable aléatoire  $Q(X_1, \dots, X_n, \theta)$  est une quantité pivot si la distribution de  $Q(X_1, \dots, X_n, \theta)$  est indépendante des paramètres.

Quel que soit l'ensemble  $\mathcal{A}$ ,

$$P_{\theta}(Q(X_1, \dots, X_n, \theta) \in \mathcal{A})$$

ne peut pas dépendre des paramètres.

On cherche le pivot de telle sorte que

$$\{\theta | Q(x_1, \dots, x_n), \theta) \in \mathcal{A}\}$$

est un ensemble estimateur du paramètre  $\theta$ .

## quantité pivot

exemple  $T \sim \Gamma(n, \lambda)$

- $X_1, \dots, X_n$  i.i.d.  $\mathcal{Exp}(\lambda)$
- $T = \sum X_i$  est une statistique suffisante pour  $\lambda$
- $T \sim \Gamma(n, \lambda)$

- 

$$Q(T, \lambda) \sim \Gamma(n, \lambda(2/\lambda)) = \Gamma(n, 2)$$

ne dépend plus de  $\lambda$  et devient une quantité pivot de distribution

- 

$$\Gamma(n, 2) = \chi^2_{(2n)}$$

## quantité pivot

exemple  $\mathcal{N}(\mu, \sigma^2)$

- $\sigma^2$  inconnu
- le pivot

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$$

- 

$$P\left(-a \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq a\right) = P(-a \leq T_{n-1} \leq a)$$

- $\forall \alpha,$

$$a = t_{n-1, \alpha/2}$$

- l'intervalle de confiance à  $1 - \alpha$  probabilité

$$\left\{ \mu \left| \bar{x} - t_{n-1, \alpha/2} \frac{s}{\sqrt{n}} \leq \mu \leq \bar{x} + t_{n-1, \alpha/2} \frac{s}{\sqrt{n}} \right. \right\}$$

## quantité pivot

suite de l'exemple

- on aimerait estimé
- pivot

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2$$

- 

$$P\left(a \leq \frac{(n-1)S^2}{\sigma^2} \leq b\right) = P(a \leq \chi_{(n-1)}^2 \leq b) = 1 - \alpha$$

- on peut inverser cet ensemble pour obtenir un intervalle de confiance

$$\left\{ \sigma \left| \sqrt{\frac{(n-1)s^2}{b}} \leq \sigma \leq \sqrt{\frac{(n-1)s^2}{a}} \right. \right\}$$

- un choix possible de  $a$  et  $b$

$$a = \chi_{(n-1), 1-\alpha/2} \quad b = \chi_{(n-1), \alpha/2}$$



## quantité pivot

retour à l'exemple des distributions exponentielles

- on a obtenu un intervalle de confiance en inversant un test de rapport de vraisemblance  $H_0 : \lambda = \lambda_0$  vs.  $H_1 : \lambda \neq \lambda_0$

- pivot avec

$$Q(T, \lambda) = \frac{2T}{\lambda} \sim \chi^2_{(2n)}$$

- 

$$P_\lambda(a \leq Q(T, \lambda) \leq b) = P_\lambda\left(a \leq \frac{2T}{\lambda} \leq b\right) = P(a \leq \chi^2_{(2n)} \leq b) = 1 - \alpha$$

- l'inversion de l'ensemble d'acceptation

$$\mathcal{A}(\lambda) = \left\{ t \mid a \leq \frac{2t}{\lambda} \leq b \right\}$$

- conduit à l'ensemble de confiance

$$\mathcal{C}(t) = \left\{ \lambda \mid \frac{2t}{b} \leq \chi^2_{(2n)} \leq \frac{2t}{a} \right\} = 1 - \alpha$$