

# 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

# test du rapport de vraisemblance

formulation générale

- ensemble de paramètres  $\Omega$ , sous ensemble  $\omega \subset \Omega$  associé à  $H_1$ ,
- 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  $\mathcal{N}(\mu, \sigma^2)$ .
- On ne connaît pas  $\mu$ , mais  $\sigma^2$  est connu.
- On aimerait un test  $H_0 : \theta = \mu$ ,  $H_1 : \theta \neq \mu$ . C'est un test composite.

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

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

## 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

$$\begin{aligned}\hat{\mu} &= \frac{\sum x_i}{n} = \bar{x} \\ \hat{\sigma}^2 &= \frac{1}{n} \sum (x_i - \bar{x})^2\end{aligned}$$



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...

$$\begin{aligned}(x_i - \mu)^2 &= (x_i - \bar{x} + \bar{x} - \mu)^2 \\ &= (x_i - \bar{x})^2 + (\bar{x} - \mu)^2 + 2(x_i - \bar{x})(\bar{x} - \mu) \\ \sum (x_i - \mu)^2 &= \sum (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2 + 2\bar{x} - \mu) \sum (x_i - \bar{x})\end{aligned}$$

et comme  $\bar{x} \frac{1}{n} \sum x_i$  on a

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

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

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

- $X_1, X_2, \dots, X_n \sim \mathcal{Exp}(\lambda)$
- La moyenne est  $\theta$  et donc  $\lambda = \frac{1}{\theta}$  et la distribution de  $X_i$  est  $f_i(x) = \lambda e^{-\lambda x} = \frac{1}{\theta} e^{-\frac{1}{\theta}x}$  avec  $x \in [0; +\infty[$

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

$$\begin{aligned}\theta &= \frac{\frac{1}{\theta_0^n} e^{-(\sum x_i)/\theta_0}}{\sup_{\theta} \frac{1}{\theta^n} e^{-(\sum x_i)/\theta}} \\ &= \frac{\frac{1}{\theta_0^n} e^{-\sum x_i/\theta_0}}{\frac{1}{(\sum x_i/n)^n} e^{-n}} = \left( \frac{\sum x_i}{n\theta_0} \right)^n e^n e^{-\sum x_i/\theta_0}\end{aligned}$$

Le test est rejeté lorsque la condition suivante est vérifiée

$$C = \left\{ x \mid \left( \frac{\sum x_i}{\theta_0} \right)^n e^{-\sum x_i/\theta_0} < k \right\}$$

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 observés alors on peut faire l'inférence

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

# 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

$$\begin{aligned} & P_{\theta}(\theta \in [U(x_1, \dots, x_n); ](x_1, \dots, x_n)]) \\ = & P_{\theta}(L(x_1, \dots, x_n) \leq \theta, U(x_1, \dots, x_n) \geq \theta) \end{aligned}$$

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

- 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  $H_0$

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

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.

## 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  $\theta_0$  fixé, l'ensemble d'acceptation s'écrit

$$\mathcal{A}(\theta_0) = \left\{ x \mid \left( \frac{\sum x_i}{\theta_0} \right)^n \exp \left( - \sum x_i / \theta_0 \right) \geq k \right\}$$

avec  $k$  choisit de telle sorte que  $P_{\theta_0}(X \in \mathcal{A}(\theta_0))$

- Inversion de l'ensemble d'acceptation conduit à l'intervalle de confiance à  $1 - \alpha$  probabilité

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

- 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.

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

- 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  $n = 2$

- $\alpha = 0.1$

- 

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

- 

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

- 

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

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

- on a

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

## 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 estimer  $\sigma^2$
- pivot

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

- 

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

- 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  $T = \sum X_i$

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

- 

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

- l'inversion de l'ensemble d'acceptation

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

- conduit à l'ensemble de confiance

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