

Eléments de statistiques pour les data sciences

Cours 9: tests d'hypothèses - Neyman-Pearson - rapport de vraisemblance

Dr. Ph. Müllhaupt

IGM - EPFL

—

- 1 les tests de signification
- 2 la vraisemblance
- 3 tests statistiques d'une hypothèse versus une alternative
- 4 l'hypothèse alternative H_1
- 5 théorie de Neyman-Pearson
- 6 test statistique du rapport de vraisemblance, déviance
test de signification basé sur le rapport de vraisemblance

les tests de signification

ce que l'on a rencontré jusqu'à présent

- une seule hypothèse H_0
- une statistique permettant d'inférer sur l'hypothèse
- une distribution associée à la statistique Z , T , χ^2
- un seuil de signification α (i.e. 5 %)

OBJECTIF :

- Vérifier si les données observées donnent de l'évidence contre l'hypothèse.
- Est-ce que les différences observées sont plutôt le fruit du hasard ou d'une erreur de modèle ?
- Encourager à poursuivre les analyses, si pas assez d'évidence concernant l'hypothèse, en effectuant de nouvelles expériences,
- L'analyse ne conduit pas à une décision dure ; difficulté d'interprétation.

la vraisemblance

pour construire des estimateurs, MLE

- Une expérience conduit à obtenir un échantillon x .
- La structure de probabilité étant définie avant l'expérience, les données conduisent à déterminer les paramètres θ rendant le plus vraisemblable les données observées (l'échantillon x).
- Si on multiplie par une constante positive (ou une fonction positive qui ne dépend pas des paramètres) la probabilité $p(x, \theta)$

$$\hat{\theta}_{\text{MLE}} \triangleq \arg \max_{\theta \in \Theta} k p(x, \theta) = \arg \max_{\theta \in \Theta} L(\theta)$$

est appelé l'estimateur du maximum de vraisemblance.

- Pour des raisons de calcul, on introduit également le logarithme de la vraisemblance.

$$l(\theta) \triangleq \log L(\theta)$$

l'hypothèse alternative H_1

On introduit une hypothèse alternative appelée H_1 .

- deux hypothèses en concurrence H_0 et H_1
- Est-ce que l'échantillon est mieux décrit selon H_0 ou H_1 ?
- On peut rejeter H_0 alors qu'elle est vraie, probabilité α , erreur de type I.
- On peut accepter H_0 alors que H_1 est vraie (H_0 est fausse), probabilité β , erreur de type II.

	accepter H_0	accepter H_1
H_0 est vraie	Décision correcte	Erreur I
H_1 est vraie	Erreur II	Décision correcte

une asymétrie du problème est introduite

H_0 est plus importante que H_1

Une asymétrie est introduite :

- On aimerait contrôler α en fixant α .
- On minimise β (maximise la puissance $1 - \beta$) sous contrainte de α constant.
- Cela aboutit \Rightarrow la théorie de Neyman-Pearson

partition de l'espace des paramètres

définition équivalente de H_0 et H_1

Pour aboutir à une formulation générale de la théorie de Neyman-Pearson, on va reformuler les hypothèses H_0 et H_1 comme une partition de l'espace des paramètres.

- Une hypothèse nulle H_0 est dite simple si elle invoque uniquement la valeur précise d'un seul paramètre.
- L'hypothèse alternative H_1 est dite simple si elle invoque uniquement la valeur précise d'un seul paramètre.
- Tous les autres cas sont dits composites.

de manière générale

- H_0 est équivalent à dire que $\theta \in \omega \subset \Theta$
- H_1 est équivalent à dire que $\theta \in \Theta \setminus \omega$

H_0 est plus important que H_1
on fixe α

- L'hypothèse H_0 est plus importante que H_1 .
- On aimerait donc contrôler α (appelé la taille du test)
- On aimerait également minimiser β .
- En conséquence : il faut maximiser $1 - \beta$, appelé la puissance du test.

La région critique C (espace des échantillons)

rejet de H_0 alors que H_0 est vraie

la région critique C

On désigne par C la région de l'espace des échantillons $C \subset \mathcal{X}$ qui est associée au rejet de H_0 alors que H_0 est vraie.

Notations :

- L'espace des paramètres est Θ . ω est associée à l'hypothèse H_0 et $\Theta \setminus \omega$ représente l'hypothèse H_1 .
- Lorsque H_0 est vraie, et qu'il s'agit d'une hypothèse simple $\theta = \theta_0$, on notera la probabilité sous ce modèle comme p_{θ_0} ou lorsqu'il n'y a pas de confusion p_0 .
- Lorsque H_1 est vraie, et qu'il s'agit d'une hypothèse simple $\theta = \theta_1$, on notera la probabilité sous ce modèle comme p_{θ_1} ou lorsqu'il n'y a pas de confusion p_1 .

La région critique C (espace des échantillons)

rejet de H_0 alors que H_0 est vraie

Une partition de l'espace des échantillons \mathcal{X} conduit à étiqueter les échantillons selon si on décide H_0 ou si on décide H_1 , indépendamment si H_0 est vraie ou si H_1 est vraie. La partition est donnée par une statistique.

- La région critique C correspond à l'étiquetage H_1 de l'espace des échantillons. (C'est un sous-ensemble de tous les échantillons possibles.)
- La probabilité d'erreur de type I s'écrit :

$$\alpha \triangleq P_{\theta_0}(C)$$

Le lemme de Neymann-Pearson

intuition

- Les hypothèses H_0 et H_1 sont simples.
- L'idée est que plus $p_{\theta_1}/p_{\theta_0}$ est grand plus l'hypothèse H_1 semble plausible par rapport à H_0 .
- Toute la subtilité est de garantir une condition pour que la probabilité d'erreur de type I, à savoir α , soit sous contrôle.
- On décidera sur H_1 lorsque la statistique utilisée conduira à ce que $p_{\theta_1}/p_{\theta_0}$ dépassera un seuil critique k .

Le lemme de Neyman-Pearson

lemme

lemme de Neyman-Pearson

Si les hypothèses suivantes sont respectées :

- Soit C une région de l'espace des échantillon \mathcal{X} telle que $P_{\theta_0}(C) \leq \alpha$.
- Supposons qu'il existe une région C^* de \mathcal{X} de la forme $C^* = \{x | p_{\theta_1}(x)/p_{\theta_0}(x) \geq k\}$ telle que $P_{\theta_0}(C^*) = \alpha$

alors

$$P_{\theta_1}(C^*) \geq P_{\theta_1}(C)$$

Explication : il n'est pas possible d'obtenir plus de puissance du test par rapport à celle donnée par la région critique C^* . Cette région donne la probabilité β la plus faible en garantissant une probabilité α donnée (erreur de type I sous contrôle au niveau maximum α).

Le lemme de Neyman-Pearson

démonstration

démonstration

On suppose que C^* existe. \bar{C} désigne le complémentaire de C et \bar{C}^* désigne le complémentaire de C^* .

$$P_{\theta_1}(C^*) - P_{\theta_1}(C) = \int_{C^* \cap \bar{C}} p_1(x) dx - \int_{\bar{C}^* \cap C} p_1(x) dx$$

Dans $C^* \cap \bar{C}$ on a la propriété $p_1(x) \geq k p_0(x)$ et donc

$$\int_{C^* \cap \bar{C}} p_1(x) dx \geq k \int_{C^* \cap \bar{C}} p_0(x) dx$$

De manière similaire

$$\int_{\bar{C}^* \cap C} p_1(x) dx < k \int_{\bar{C}^* \cap C} p_0(x) dx$$

en conséquence

$$\begin{aligned}
 P_{\theta_1}(C^*) - P_{\theta_1}(C) &\geq k \left[\int_{C^* \cap \bar{C}} p_0(x) dx - \int_{\bar{C}^* \cap C} p_0(x) dx \right] \\
 &= k \left[\int_{C^*} p_0(x) dx - \int_C p_0(x) dx \right] \\
 &= k [P_{\theta_0}(C^*) - P_{\theta_0}(C)] \\
 &\geq 0
 \end{aligned}$$

étant donné que $k \geq 0$, $P_{\theta_0}(C^*) = \alpha$ et $P_{\theta_0}(C) \leq \alpha$. On arrive donc à la conclusion du lemme

$$P_{\theta_1}(C^*) \geq P_{\theta_1}(C) \quad \text{C.Q.F.D.}$$

Le lemme de Neyman-Pearson

commentaire

Le lemme indique une méthode pour trouver la constante k :

- Choisir k de telle sorte que

$$P_{\theta_0} \left\{ x \left| \frac{p_1(x)}{p_0(x)} \geq k \right. \right\} = \alpha$$

- Dans beaucoup de cas $p_1(x)/p_0(x)$ est une fonction croissante, on commence donc par choisir k petit et l'on augmente jusqu'à atteindre la valeur α désirée.
- La condition $p_1(x)/p_0(x) \geq k$ est ensuite montrée être équivalente à une condition sur une statistique $T(x) \geq k'$ avec k' une nouvelle constante fonction de k . On dimensionne alors k' pour que α soit atteint. Lorsque la distribution de T est connue (par exemple Student t , gaussienne Z , ou Pearson χ^2) on utilise les tables correspondantes.

Exemple 1

application du lemme de Neyman-Pearson

- 3 variables aléatoires indépendantes $X_i \sim \mathcal{Ber}(p)$, $i = 1, 2, 3$
- observation : $X = \sum_{i=1}^3 X_i \sim \mathcal{Bin}(n, p)$, $x = 0, 1, 2, 3$
- $\theta \triangleq p$
- $H_0 : \theta_0 = \frac{1}{4}$ $H_1 : \theta_1 = \frac{3}{4}$
- $\alpha = 0.05$

On doit choisir k si possible pour que

$$P_{\theta_0} \left\{ x \left| \frac{p_1(x)}{p_0(x)} \geq k \right. \right\} = 0.05$$

Cette condition est équivalente (à cause de la croissance monotone de p_1/p_0) à déterminer une nouvelle constante k' telle que

$$P_{\theta_0} \{x | x > k'\} = 0.05$$

On examine cas par cas :

- si $k' \in]2, 3[$ alors $\{x | x > k'\} = 3$, ce qui donne $P_{\theta_0}(3) = \left(\frac{1}{4}\right)^3 = \frac{1}{64}$
- si $k' \in]1; 2[$ alors $P_{\theta_0}\{x | x \geq k'\} = P\{x = 2 \text{ ou } x = 3\}$

On calcule successivement :

$$P_{\theta_0}(x = 2) = C_2^3 \left(\frac{1}{4}\right)^2 \frac{3}{4} = \frac{9}{64} = 0.140625$$

$$P_{\theta_0}(x = 3) = \frac{1}{64} = 0.015625$$

$$\begin{aligned} P_{\theta_0}(x = 2 \text{ ou } x = 3) &= P_{\theta_0}(x = 2) + P_{\theta_0}(x = 3) \\ &= \frac{9}{64} + \frac{1}{64} = \frac{10}{64} = 0.15625 \end{aligned}$$

Dans cet exemple, on ne peut pas atteindre précisément $\alpha = 0.05$ car

$$0.015625 < 0.05 < 0.15635$$

Exemple 2

application du lemme de Neyman-Pearson

- soit $X = (X_1, X_2, \dots, X_n)$ un échantillon avec $X_i \sim \mathcal{N}(\mu, 1)$
- $H_0 : \mu = \theta_0$ $H_1 : \mu = \theta_1$ $\theta_1 > \theta_0$

$$\frac{p_1(x)}{p_0(x)} = e^{-\frac{1}{2} \sum (x_i - \theta_1)^2 + \frac{1}{2} \sum (x_i - \theta_0)^2}$$

$$\geq k$$

$$\Leftrightarrow$$

$$n\bar{x}(\theta_1 - \theta_0) - \frac{1}{n}(\theta_1^2 - \theta_0^2) \geq k'$$

$$\Leftrightarrow$$

$$\bar{x} \geq k''$$

On peut ainsi déterminer un k tel que $P_{\theta_0}\{x | p_1(x)/p_0(x) \geq k\} = \alpha$ si on peut déterminer un k'' tel que $P_{\theta_0}\{x | \bar{x} \geq k''\} = \alpha$

Si θ_0 est la vrai paramètre

$$\bar{x} \sim \mathcal{N}(\theta_0, 1/n) \Leftrightarrow \sqrt{n}(\bar{x} - \theta_0) \sim \mathcal{N}(0, 1)$$

Soit k_α la valeur de la probabilité de 100α pourcents supérieurs d'une loi gaussienne

$$P_{\theta_0}(\sqrt{n}(\bar{x} - \theta_0) \geq k_\alpha) = \alpha$$

$$P_{\theta_0} \left\{ \bar{x} \geq \frac{k_\alpha}{\sqrt{n}} + \theta_0 \right\} = \alpha$$

$$C^* = \left\{ x \mid \bar{x} \geq \frac{k_\alpha}{\sqrt{n}} + \theta_0 \right\}$$

est la région critique du test le plus puissant pour un test au niveau α de signification de l'hypothèse simple $\mu = \theta_0$ contre l'hypothèse simple $\mu = \theta_1$ avec $\theta_1 > \theta_0$.

Hypothèse simple contre hypothèse composite

Dans le cas d'une hypothèse simple $H_0 : \theta = \theta_0$ et une hypothèse composite $H_1 : \theta \neq \theta_0$, le lemme de Neyman-Pearson n'indique plus nécessairement le test le plus puissant.

Si on examine le ratio dans le test de Neyman-Pearson il fait apparaître un rapport de vraisemblance.

On va procéder en utilisant un rapport de vraisemblance, mais avec une fraction inverse. Ceci est dû à la connection avec le maximum de vraisemblance.

Test de signification pur et rapport de vraisemblance

Revenons en arrière et considérons un test de signification.

Définissons

$$\lambda = \frac{L(\theta|H_0; x)}{\max_{\theta} L(\theta; x)} = \frac{L(\theta|H_0; x)}{L(\hat{\theta}_{\text{MLE}}; x)}$$

Il s'agit du rapport entre la vraisemblance sous l'hypothèse $\theta = \theta_0$ divisé par le maximum de vraisemblance qui conduit au paramètre $\theta = \hat{\theta}_{\text{MLE}}$.

- Le maximum est pris sur tout l'ensemble des paramètres. Le maximum n'est pas contraint à un sous-ensemble particulier de Θ . On trouve donc $\hat{\theta}_{MLE}$ rendant maximum la vraisemblance.
- $1 \leq \lambda \leq 0$
- Lorsque H_0 est le plus vraisemblant on aura tendance à ce que $\lambda \rightarrow 1$ (à cause de faire apparaître H_0 au numérateur plutôt qu'au dénominateur dans la cas du lemme de Neyman-Pearson).

Définition de la déviance

Cette définition est conséquence du rapport de vraisemblance λ en prenant les logarithmes.

Comme $\lambda < 1$, il est mieux de changer le signe du logarithme pour faire apparaître une quantité positive.

A cause de la relation avec le χ^2 on introduit un facteur 2.

définition de la déviance

$$D = -2[l_0 - \hat{l}] = 2[\hat{l} - l_0] = 2[l(\hat{\theta}) - l(\theta_0)] = -2r(\hat{\theta}_0)$$

avec $l_0 = \log(L(\theta_0; x))$ et $\hat{l} = \log(L(\hat{\theta}_{\text{MLE}}; x))$

Propriété de la déviance

niveau de signification et $D \approx \chi^2_{(1)}$

niveau de signification

$$NS = P\{D \geq D_{\text{obs}} | H_0 \text{ est vraie}\}$$

relation avec le χ^2

Le théorème central limite permet d'établir la propriété

$$\lim_{n \rightarrow \infty} P(D \leq d | \theta = \theta_0) = P\{\chi^2_{(1)} \leq d\}$$