

Retour sur le maximum de vraisemblance

- Soient x_1, \dots, x_n des données supposées être une réalisation d'un échantillon aléatoire $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} f(x; \theta)$ (densité / masse). La **vraisemblance** pour θ est la fonction


$$L(\theta) = f(x_1; \theta) \times f(x_2; \theta) \times \dots \times f(x_n; \theta) = \prod_{i=1}^n f(x_i; \theta).$$

- $\hat{\theta}_{\text{ML}}$ satisfait

$$L(\hat{\theta}_{\text{ML}}) \geq L(\theta) \quad \text{pour tout } \theta$$

- Interprétation** : dans le cas discret, on maximise $\Pr_{\theta}(X_1 = x_1, \dots, X_n = x_n)$
- Il est plus facile de maximiser $\ell(\theta) := \log L(\theta)$, souvent en résolvant $d\ell(\theta)/d\theta = 0$, et vérifiant qu'il s'agit bien d'un maximum

La vraisemblance est une fonction aléatoire



Fonctions de vraisemblances correspondant à 50 échantillons de taille $n = 40$. La vraie valeur est $\theta = 0$ et les 50 maxima sont en rouge.

Distribution asymptotique/approximative de $\hat{\theta}_{ML}$

- Dans des modèles "réguliers" (normal, exponentiel, Poisson, ...) on a $\ell'(\hat{\theta}_{ML}) = 0$
- Comme $\ell(\theta)$ est une somme de variables aléatoires iid, le théorème central limite s'applique
- Grâce à la méthode delta $\hat{\theta}_{ML} \stackrel{\text{app}}{\sim} \mathcal{N}(\theta, 1/I_n(\theta))$ avec **l'information de Fisher**

$$I_n(\theta) = -\mathbb{E}_\theta(\ell''(\theta)) = \mathbb{E}_\theta(J_n(\theta)), \quad J_n(\theta) = -\ell''(\theta)$$

$1/I_n(\theta)$ est la **variance asymptotique** de $\hat{\theta}_{ML}$, $I_n(\theta)$ est la courbure

- **L'information observée** est $J_n(\hat{\theta}_{ML})$
- **Attention !** Certains modèles, tel que $U[0, \theta]$, ne sont pas réguliers

Exemple x_1, \dots, x_n réalisations d'une loi $\exp(\lambda)$ avec densité $\lambda e^{-\lambda x} I(x \geq 0)$, $\lambda > 0$

Exemple

Exemple x_1, \dots, x_n réalisations d'une loi $\exp(\lambda)$ avec densité $\lambda e^{-\lambda x} I(x \geq 0)$, $\lambda > 0$

3.2 Estimation par intervalle

Les intervalles de confiance

Un élément clé de la statistique est de donner une idée de l'incertitude d'un constat

Soit θ un paramètre inconnu, et soit $\tilde{\theta}_n = 1$ une estimation de θ basée sur y_1, \dots, y_n :

- si $n = 10^5$ on est beaucoup plus sûr que $\theta \approx \tilde{\theta}_n$ que si $n = 10$
- pour exprimer ceci on aimerait donner un intervalle qui serait plus large quand $n = 10$ que quand $n = 10^5$, pour expliciter l'incertitude liée à $\tilde{\theta}_n$


Définition: Soient $Y \equiv Y_1, \dots, Y_n$ des données issues d'une loi F de paramètre $\theta \in \mathbb{R}$. Un **intervalle de confiance** (IC, 'confidence interval' en anglais) (L_n, U_n) pour θ est une statistique sous forme d'intervalle qui contient θ avec une probabilité spécifiée $1 - \alpha$

$$\Pr_{\theta}(L_n \leq \theta \leq U_n) = 1 - \alpha \quad \forall \theta$$

- $1 - \alpha \in (0, 1)$ est le **niveau**, souvent $\alpha \in \{0.05, 0.01, 0.1\}$
- Les bornes $L_n = L_n(Y)$, $U_n = U_n(Y)$ sont des statistiques et non pas des inconnus
- Un IC **bilatéral**, de la forme (L_n, U_n) , est le plus souvent utilisé
- Un IC **unilatéral à droite** est $(-\infty, U_n]$ tel que $\Pr_{\theta}(U_n \geq \theta) = 1 - \alpha$
- Un IC **unilatéral à gauche** est $[L_n, \infty)$ tel que $\Pr_{\theta}(L_n \leq \theta) = 1 - \alpha$

Interprétation d'un intervalle de confiance

- (L_n, U_n) est un intervalle aléatoire qui contient θ avec probabilité $(1 - \alpha)$
- Si on répète l'expérience avec d'autres données, on aura un autre intervalle de confiance
- Nous ne savons pas si notre IC contient θ , mais cette procédure nous fournit une garantie statistique que cet événement a une probabilité $(1 - \alpha)$



Construire un IC dans le cas normal

- Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, 1)$, et

$$\bar{Y}_n = \frac{1}{n} \sum_{j=1}^n Y_j$$

la moyenne de l'échantillon. On a $\bar{Y}_n \sim \mathcal{N}(\mu, 1/n)$ et donc

$$Z_n = n^{1/2}(\bar{Y}_n - \mu) \sim \mathcal{N}(0, 1)$$

a une distribution qui ne dépend pas de μ . On obtient

$$\Pr_{\mu} \left(\bar{Y}_n - \frac{z_{1-\alpha/2}}{\sqrt{n}} \leq \mu \leq \bar{Y}_n + \frac{z_{1-\alpha/2}}{\sqrt{n}} \right) = 1 - \alpha$$

avec $z_{\beta} = \Phi^{-1}(\beta)$ les quantiles de la loi $\mathcal{N}(0, 1)$

- Si $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$, et **on connaît** σ^2 , alors

$$\frac{Z_n}{\sigma} = \frac{n^{1/2}(\bar{Y}_n - \mu)}{\sigma} \sim \mathcal{N}(0, 1)$$

et l'intervalle de confiance pour μ est

$$\left[\bar{Y}_n - \frac{z_{1-\alpha/2}}{\sqrt{n}}\sigma, \bar{Y}_n + \frac{z_{1-\alpha/2}}{\sqrt{n}}\sigma \right]$$

- La largeur \downarrow avec n , \uparrow avec σ et avec le niveau $(1 - \alpha)$, car $\Pr_{\theta}(L_n \leq \theta \leq U_n) \uparrow$ 179

Exemple

Exemple On suppose que la résistance Y d'un certain type d'équipements électriques est distribuée selon une loi normale avec $\sigma = 0.12$ ohm.

Un échantillon de taille $n = 64$ a donné comme moyenne la valeur $\bar{y}_n = 5.34$ ohm.

Trouver un intervalle de confiance pour μ au niveau 95%.

Intervalle de Student

- Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ avec σ^2 **inconnue**
- $\left[\bar{Y}_n - \frac{z_{1-\alpha/2}}{\sqrt{n}} \sigma, \bar{Y}_n + \frac{z_{1-\alpha/2}}{\sqrt{n}} \sigma \right]$ n'est plus un intervalle de confiance
- On suppose $n > 1$ et estime σ^2 par

$$S_n^2 = \frac{1}{n-1} \sum_{j=1}^n (Y_j - \bar{Y}_n)^2$$

- On remplace σ par S_n : soit

$$T_n = \frac{Z_n}{S_n} = n^{1/2} \frac{\bar{Y}_n - \mu}{S_n} = \frac{Z_n/\sigma}{\sqrt{S_n^2/\sigma^2}}$$

- Nommateur et dénominateur indép, leurs lois ne dépendent pas de (μ, σ^2)
- T_n suit une **loi de Student avec $n - 1$ degrés de liberté**, $T_n \sim t_{n-1}$, qui ne dépend de $\theta = (\mu, \sigma^2)$. C'est une loi symétrique, on dénote les quantiles par $t_{n-1, \beta}$
- L'intervalle de confiance qui en résulte est

$$\left[\bar{Y}_n - \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n, \bar{Y}_n + \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n \right]$$

- La largeur \downarrow avec n , \uparrow avec S_n et avec le niveau $(1 - \alpha)$

Exemple

Exemple Pour déterminer le point de fusion μ d'un certain alliage, on a procédé à $n = 9$ observations qui ont donné une moyenne $\bar{y}_n = 1040^\circ$ avec $s_n = 16^\circ$. On suppose que les données suivent une loi normale.

Trouver un intervalle de confiance pour μ à niveau 95%.

Intervalles de confiance pour μ dans le cas normal : résumé

Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$ avec μ inconnu

- Pour σ **connue** $n^{1/2} \frac{\bar{Y}_n - \mu}{\sigma} \sim \mathcal{N}(0, 1)$ et on a les IC de niveau $1 - \alpha$

$$\left[\bar{Y}_n - \frac{z_{1-\alpha/2}}{\sqrt{n}} \sigma, \bar{Y}_n + \frac{z_{1-\alpha/2}}{\sqrt{n}} \sigma \right]$$

$$\left[\bar{Y}_n - \frac{z_{1-\alpha}}{\sqrt{n}} \sigma, \infty \right] \quad \left[-\infty, \bar{Y}_n + \frac{z_{1-\alpha}}{\sqrt{n}} \sigma \right]$$

avec $z_\beta = \Phi^{-1}(\beta)$ les quantiles de la loi $\mathcal{N}(0, 1)$


- Pour σ **inconnue** (et $n > 1$) $n^{1/2} \frac{\bar{Y}_n - \mu}{S_n} \sim t_{n-1}$ et on a les IC de niveau $1 - \alpha$

$$\left[\bar{Y}_n - \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n, \bar{Y}_n + \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n \right]$$


$$\left[\bar{Y}_n - \frac{t_{n-1, 1-\alpha}}{\sqrt{n}} S_n, \infty \right] \quad \text{ou} \quad \left[-\infty, \bar{Y}_n + \frac{t_{n-1, 1-\alpha}}{\sqrt{n}} S_n \right]$$

avec t_{n-1} la **loi de Student avec $n - 1$ degrés de liberté**, $t_{n-1, \beta}$ sont les quantiles de cette distribution, S_n définie à la diapositive [182](#).

Densités de t_k et $\mathcal{N}(0, 1)$



Quantiles de t_k et $\mathcal{N}(0,1)$



Pivots

- Une fonction $T(Y_1, \dots, Y_n, \theta)$ dont la loi est connue et ne dépend pas de θ s'appelle un **pivot**
- Attention !** Ce n'est pas une statistique car c'est une fonction de θ
- Si $a \leq b$,

$$\alpha_1 = \Pr(T < a), \quad \alpha_2 = \Pr(T > b), \quad \alpha_1 + \alpha_2 = \alpha \in [0, 1]$$

(souvent $\alpha_1 = \alpha_2 = \alpha/2$) alors

$$\Pr_{\theta}(a \leq T \leq b) = \Pr_{\theta}(T \leq b) - \Pr_{\theta}(T < a) = (1 - \alpha_2) - \alpha_1 = 1 - \alpha$$

- Si on peut isoler θ , on peut trouver des variables aléatoires L et U telles que

$$\Pr_{\theta}(L \leq \theta \leq U) = 1 - \alpha$$

Exemples T_n (diapositive 182), Z_n (diapositive 179).

$$\sqrt{n} (\bar{Y}_n - \mu) / \sigma \sim N(0, 1)_{187}$$

Pivot : cas uniforme

Exemple Soient $Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} U(0, \theta)$, $M_n = \max(Y_i)$. Alors $T(Y_1, \dots, Y_n, \theta) = M_n/\theta$ est un pivot.

$$\begin{aligned} P_{\theta}(T \leq t) &= P_{\theta}(M_n \leq t\theta) \\ &= P_{\theta}(Y_1 \leq t\theta, \dots, Y_n \leq t\theta) \\ &\stackrel{\text{i.i.d.}}{=} \prod_{i=1}^n P_{\theta}(Y_i \leq t\theta) = \left(P_{\theta}(Y_1 \leq t\theta) \right)^n \\ &= \begin{cases} 1 & \text{si } t \geq 1 \\ 0 & \text{si } t < 0 \\ t^n & \text{si } t \in [0, 1] \end{cases} \end{aligned}$$

ne dépend pas de $\theta \Rightarrow T$ pivot

Intervalles de confiance approximatifs

- En pratique la plupart des intervalles de confiance se basent sur des approximations fournies par le théorème central limite, étant de la forme

$$(L_n, U_n) = (\hat{\theta}_n - \sqrt{V_n}z_{1-\alpha/2}, \hat{\theta}_n + \sqrt{V_n}z_{1-\alpha/2}),$$

où V_n est un estimateur de $\text{var}_\theta(\hat{\theta}_n)$ dont la racine s'appelle **erreur type (standard error)** de $\hat{\theta}_n$. Sa réalisation $v_n^{1/2}$ est aussi appelée erreur type

- L'intervalle de confiance est approximatif dans le sens que

$$\Pr_\theta(L_n \leq \theta \leq U_n) \rightarrow 1 - \alpha, \quad n \rightarrow \infty$$

- Dans des modèles réguliers, la variance asymptotique de $\hat{\theta}_{\text{ML}}$ (voir diapositive 174) est $1/I_n(\theta)$, estimée par $1/J_n(\hat{\theta}_{\text{ML}})$ et donc

$$(L_n, U_n) = \left(\hat{\theta}_{\text{ML}} - z_{1-\alpha/2} / \sqrt{J_n(\hat{\theta}_{\text{ML}})}, \hat{\theta}_{\text{ML}} + z_{1-\alpha/2} / \sqrt{J_n(\hat{\theta}_{\text{ML}})} \right)$$

Exemples

Exemple Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} \text{Poiss}(\lambda)$, $\lambda > 0$ inconnu. Trouver une erreur type pour $\hat{\lambda}_{\text{ML}}$, et ainsi donner un intervalle de confiance approximatif de niveau 90% pour λ . $\alpha = 0.1 \rightarrow 1 - \frac{\alpha}{2} = 0.95$

$$L(\lambda) = \prod_{i=1}^n e^{-\lambda} \frac{\lambda^{y_i}}{y_i!} = e^{-n\lambda} \lambda^{n\bar{Y}_n} \prod_{i=1}^n \frac{1}{y_i!}$$
$$l(\lambda) = -n\lambda + n\bar{Y}_n \log \lambda + \sum_{i=1}^n \log \frac{1}{y_i!}$$
$$l'(\lambda) = -n + \frac{n\bar{Y}_n}{\lambda} = 0 \Leftrightarrow \lambda = \bar{Y}_n$$
$$l''(\lambda) = -\frac{n\bar{Y}_n}{\lambda^2} < 0 \Rightarrow \lambda_{\text{ML}} = \bar{Y}_n$$
$$J_n(\lambda) = -l''(\lambda) = \frac{n\bar{Y}_n}{\lambda^2}$$
$$J_n(\lambda_{\text{ML}}) = \frac{n\bar{Y}_n}{\lambda_{\text{ML}}^2} = \frac{n}{\bar{Y}_n}$$

IC approximatif $\left[\bar{Y}_n - z_{0.95} \sqrt{\frac{\bar{Y}_n}{n}}, \bar{Y}_n + z_{0.95} \sqrt{\frac{\bar{Y}_n}{n}} \right]$

Exemples

Exemple Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} U(0, \theta)$ avec θ inconnu et

$$E Y_i = \frac{\theta}{2}$$

$\bar{Y}_n = n^{-1} \sum_{j=1}^n Y_j$. Utiliser le théorème central limite pour trouver un

intervalle de confiance approximatif de niveau 95% pour θ . $\text{Var}_\theta Y_i = \frac{\theta^2}{12}$

$$T_n = \sqrt{n} \frac{\bar{Y}_n - \frac{\theta}{2}}{\sqrt{\frac{\theta^2}{12}}} \stackrel{\text{app}}{\sim} \mathcal{N}(0, 1)$$

pivot approximatif

$$T_n = \sqrt{12n} \left(\frac{\bar{Y}_n}{\theta} - \frac{1}{2} \right)$$

$$1 - \alpha \approx P_\theta \left(-z_{1-\frac{\alpha}{2}} \leq T_n \leq z_{1-\frac{\alpha}{2}} \right) = P_\theta \left(\frac{1}{2} - \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{12n}} \leq \frac{\bar{Y}_n}{\theta} \leq \frac{1}{2} + \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{12n}} \right)$$

$$\Rightarrow \text{IC approximatif} \left[\frac{\bar{Y}_n}{\frac{1}{2} + \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{12n}}}, \frac{\bar{Y}_n}{\frac{1}{2} - \frac{z_{1-\frac{\alpha}{2}}}{\sqrt{12n}}} \right]$$

3.3 Tests statistiques

Démarche scientifique

Toute **démarche scientifique** s'effectue selon le même schéma. Afin d'analyser la plausibilité d'une théorie, on itère les étapes suivantes :

- Enoncé d'une hypothèse (théorie) pouvant être contredite par des données.
- Récolte de données
- Comparaison des données avec les prédictions/implications de l'hypothèse.
- Non-rejet, rejet ou modification éventuelle de l'hypothèse.

Dans un cadre statistique, en supposant que l'on dispose d'un modèle pour le phénomène étudié, on itère les étapes suivantes :

- Enoncé d'une hypothèse (typiquement sur les paramètres du **modèle statistique**). Cette hypothèse peut être contredite par des données (via une statistique, appelée **statistique de test**).
- Récolte de données
- **Rejet (ou non) de l'hypothèse** à partir de la comparaison entre les données et les implications de l'hypothèse. En cas d'écart, à partir de quel seuil juge-t-on cet écart **significatif**, i.e., suffisamment important pour justifier le rejet de l'hypothèse ?

Exemple

Exemple Question : L'alcool ralentit-il les réflexes?

hypothèse: oui

Afin d'étudier l'effet de l'alcool sur les réflexes, on fait passer à 14 sujets un test de dextérité avant et après qu'ils aient consommé 100 ml de vin. Leurs temps de réaction (en ms) avant et après sont donnés dans le tableau suivant :

Sujet	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Avant	57	54	62	64	71	65	70	75	68	70	77	74	80	83
Après	55	60	68	69	70	73	74	74	75	76	76	78	81	90

-2 6 6 5 -1 -1

$$D = Y - X \quad T_n = 3,5 > 0$$

$$W = \begin{cases} 1 & \text{si } D > 0 \\ 0 & \text{sinon} \end{cases}$$

$$\bar{w}_n = \frac{10}{14}$$

*si l'alcool a
pas d'effet
 $T_n < 0$
 $w_n \approx \frac{1}{2}$*

Cadre statistique : [1] Hypothèse nulle et alternative

Etant donné un modèle statistique (de densité $f(x; \theta)$), nous voulons choisir entre deux théories concurrentes à propos du paramètre θ . Ces dernières forment une paire d'hypothèses :

H_0 : l'hypothèse nulle vs H_1 : l'hypothèse alternative.

Exemple. Dans une population décrite par la loi $\mathcal{N}(\mu, \sigma^2)$, nous pouvons former des hypothèses sur μ comme suit :

$$\underbrace{\left\{ \begin{array}{l} H_0 : \mu = \mu_0 \\ H_1 : \mu \neq \mu_0 \end{array} \right\}}_{\text{paire bilatérale}} \quad \text{ou} \quad \underbrace{\left\{ \begin{array}{l} H_0 : \mu = \mu_0 \\ H_1 : \mu > \mu_0 \end{array} \right\} \quad \text{ou} \quad \left\{ \begin{array}{l} H_0 : \mu = \mu_0 \\ H_1 : \mu < \mu_0 \end{array} \right\}}_{\text{paires unilatérales}}.$$

Cadre statistique : [2] Statistique de test

Comment choisir entre les deux hypothèses ?

- Nous tirons un échantillon $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} f(x; \theta)$ tiré de la population.
Comment l'utiliser pour prendre notre décision ?
- Nous choisissons une statistique $T = T_n = g(X_1, \dots, X_n)$ qui a tendance à prendre des valeurs "typiques" sous l'hypothèse nulle H_0 (i.e., si H_0 est vraie) et "extrêmes" (dans la direction de l'hypothèse alternative H_1) sous H_1
- Ainsi, si on observe une valeur plutôt "extrême" ("extrême" dans la direction de l'hypothèse alternative H_1) de T , nous avons de l'évidence contre H_0 .

Notre règle de décision est donc :

$\left. \begin{array}{l} H_0: \mu = \mu_0 \\ H_1: \mu \neq \mu_0 \end{array} \right\} \rightarrow \text{extrême} = \text{grandes valeurs}$

- Rejeter H_0 si la valeur observée de T est assez extrême (au-delà d'une valeur critique à déterminer).
- Ne pas rejeter H_0 si la valeur observée de T n'est pas assez extrême.

negatives ou positives

On n'accepte pas H_0

Exemple : paire bilatérale

Soient $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$, où σ^2 est inconnue, et considérons la paire d'hypothèses :


μ_0 connue

$$\left\{ \begin{array}{l} H_0 : \mu = \mu_0 \\ H_1 : \mu \neq \mu_0 \end{array} \right\}.$$

pas de rejet

On parle de paire bilatérale car $\mu \neq \mu_0$ est équivalent à $\mu < \mu_0$ ou $\mu > \mu_0$.

Considérons la statistique de test $T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}}$.

- 
- Si H_0 est vraie, alors $T \sim t_{n-1}$ (donc si ~~H_0 est vraie~~, T prend typiquement des valeurs proches de 0).
 - Compte tenu de H_1 , nous considérons donc les valeurs de T comme "extrêmes" si elles sont "éloignées" de 0. Notons qu'ici, la notion d'"extrême" dans la direction de l'hypothèse alternative H_1 signifie une valeur "extrême" de la valeur absolue de T .
 - Nous allons rejeter H_0 si $|T|$ est **suffisamment élevée**, i.e., $|T| > v^*$, où $v^* > 0$ est une valeur critique à déterminer.

Exemple : paire unilatérale

Soient $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$, où σ^2 est inconnu, et considérons la paire d'hypothèses :

$$\begin{cases} H_0 : \mu = \mu_0 \\ H_1 : \mu < \mu_0 \end{cases}$$



Considérons la statistique de test $T_n = \frac{\bar{X} - \mu_0}{S/\sqrt{n}}$.

- Si H_0 est vraie, alors $T \sim t_{n-1}$.
- Compte tenu de H_1 , nous considérons donc les valeurs de T comme “extrêmes” si elles sont fortement négatives. Donc ici, la notion d’“extrême” dans la direction de l’hypothèse alternative H_1 signifie une valeur “extrême” de $|\min(T, 0)|$ et non de $|T|$.
- Nous allons donc rejeter H_0 si T est **suffisamment négative**, i.e., $T < v_*$, où $v_* < 0$ est la valeur critique à déterminer.

Cadre statistique : [3] Significativité statistique

Choix de la valeur critique (par exemple v^* et v_*) : Comment définir **suffisamment élevée** ou **suffisamment négative**. En d'autres termes, quelle ampleur est considérée comme **significative** ?

Pour répondre à cette question, il faut considérer les deux types d'erreurs que l'on peut commettre lorsque l'on se décide en faveur de l'une des hypothèses :

Décision \ Vérité	H_0 vraie	H_0 fausse
Non-rejet de H_0	😊	Erreur de type II
Rejet de H_0	Erreur de type I	😊

Erreur de type I (**faux positif**) considérée plus grave que l'erreur de type II (**faux négatif**) — filtre de spam

Cadre statistique : [3] Significativité statistique

- On ne peut pas contrôler les deux erreurs à la fois :

Pr(erreur type I) petite



rejet uniquement pour des valeurs très extrêmes



difficile de rejeter



Pr(erreur type II) grande

- L'asymétrie entre la gravité des erreurs nous aide à choisir H_0 et H_1
- On va contrôler l'erreur de type I, qui est plus grave
- Parfois on choisit H_0 par convenance mathématique (de sorte que mathématiquement il serait plus facile de contrôler l'erreur de type I)

$H_0: \mu = \mu_0$ compliqué

Cadre statistique : [3] Significativité statistique

- Nous choisissons la valeur maximale que l'on tolère pour la probabilité d'erreur de type I (éventuellement en tenant compte de l'avis d'un spécialiste). Cette quantité est notée α et appelée **niveau/seuil de significativité du test** ; $\alpha \in (0, 1)$. On choisit généralement une valeur faible pour α . Typiquement, $\alpha = 0.1, 0.05, 0.01, 0.001$; le plus souvent, $\alpha = 0.05$.

le niveau α de l'IC $(1-\alpha)$

- La valeur critique est déterminée de manière à ce que

$$\Pr_{H_0}[\text{Rejet de } H_0] = \alpha.$$

- Ainsi, la **valeur critique** est telle que

$$\Pr_{H_0}[|T| > \text{valeur critique}] = \alpha \quad (\text{cas bilatéral}),$$

$$\Pr_{H_0}[T < \text{valeur critique}] = \alpha \quad \text{ou}$$

$$\Pr_{H_0}[T > \text{valeur critique}] = \alpha \quad (\text{cas unilatéral}).$$

- Les probabilités sont sous l'hypothèse que H_0 **est vraie** !

Cadre statistique : [3] Significativité statistique

Exemple, paire bilatérale : Soient $X_1, \dots, X_n \stackrel{iid}{\sim} \mathcal{N}(\mu, \sigma^2)$, où σ^2 est inconnu, et considérons la paire $H_0 : \mu = \mu_0$ contre $H_1 : \mu \neq \mu_0$.

Nous allons rejeter H_0 si $|T| = \left| \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \right|$ est **assez large**, c'est à dire $|T| > v^*$.

Soit α le niveau de significativité. La valeur critique v^* satisfait

$$\Pr_{H_0}[|T| > v^*] = \alpha,$$

i.e.,

$$\Pr_{H_0}[T < -v^* \text{ ou } T > v^*] = \alpha.$$

Quand H_0 est vraie $T \sim t_{n-1}$. On doit donc choisir

$$v^* = t_{n-1, 1-\alpha/2},$$


où $t_{n-1, 1-\alpha/2}$ est le $(1 - \alpha/2)$ quantile de la loi de Student t_{n-1} .

Handwritten notes:
 $\Pr(T > v^*) + \Pr(T < -v^*)$
symétrie
 $= 2\Pr(T < -v^*)$
 $= \alpha$

Cadre statistique : [4] La p -valeur

Au lieu d'utiliser des valeurs critiques pour choisir entre H_0 et H_1 , nous pouvons utiliser une autre approche, basée sur la notion de p -valeur.

- La p -valeur (notée p_{obs}) est la probabilité d'obtenir une valeur de la statistique de test au moins aussi élevée (élevée dans la direction de H_1) que celle que nous avons observée si H_0 était vraie.
- Supposons que la réalisation de la statistique de test sur nos données est $T = t_{\text{obs}}$. Alors :
 - Cas bilatéral : $p_{\text{obs}} = \Pr_{H_0}[|T| > |t_{\text{obs}}|]$,
 - Cas unilatéral à gauche : $p_{\text{obs}} = \Pr_{H_0}[T < t_{\text{obs}}]$,
 - Cas unilatéral à droite : $p_{\text{obs}} = \Pr_{H_0}[T > t_{\text{obs}}]$.
- Petites valeurs de p_{obs} s'opposent à H_0 car elles démontrent que la réalité observée serait très improbable si l'hypothèse nulle H_0 était vraie.
- Cas bilatéral (203) : $p_{\text{obs}} = 2(1 - F_{t_{n-1}}(|t_{\text{obs}}|))$, où $F_{t_{n-1}}$ est la fonction de répartition de la loi de Student t_{n-1} .



t_{obs} est défective \Rightarrow p_{obs} aléatoire

Cadre statistique : [4] La p -valeur

On peut utiliser la p -valeur pour faire un test d'hypothèse :

$$\boxed{\text{rejetter } H_0 \iff p_{obs} < \alpha}$$

Exemple bilatérale (203) $p_{obs} = 2(1 - F_{t_{n-1}}(t_{obs}))$ donc

α
✓

$$p_{obs} < \alpha \iff F_{t_{n-1}}(|t_{obs}|) > 1 - \alpha/2 \iff |t_{obs}| > t_{n-1, 1-\alpha/2}$$

De manière générale, l'approche de la p -valeur est équivalente à l'approche des valeurs critiques. Cependant, la p -valeur p_{obs} fournit une information plus facilement interprétable que la valeur t_{obs} . Il s'agit d'une mesure de l'évidence contre H_0 contenue dans les données.

Attention : la p -valeur **n'est pas** la probabilité que H_0 soit vraie.

Résumé : les éléments d'un test

- A Une **hypothèse nulle** H_0 à tester contre une hypothèse alternative H_1 .
- B Une **statistique de test** T , choisie de telle sorte que des valeurs "extrêmes" de T (en direction de H_1) suggèrent que H_0 est fautive. La valeur observée de T est t_{obs} .
- C Un **niveau de significativité** α , qui la probabilité d'erreur de type I (rejet de H_0 quand H_0 est vraie) maximale que nous allons tolérer.
- D1 Des **valeurs critiques**, telles que quand T tombe au-delà de ces valeurs, nous rejetons H_0 en faveur de H_1 . Les valeurs critiques sont choisies pour respecter le niveau de significativité α .

Au lieu de D1, nous pouvons utiliser l'approche équivalente D2 :
- D2 Une **valeur** p_{obs} donnant la probabilité d'observer une valeur de T aussi élevée que t_{obs} sous H_0 . On rejette alors H_0 en faveur de H_1 quand $p_{\text{obs}} < \alpha$.

Exemple

Exemple On a contrôlé 10 compteurs d'électricité nouvellement fabriqués et obtenu les valeurs suivantes (en MW) :

983 1002 998 996 1002 983 994 991 1005 986.

On suppose qu'il s'agit de réalisation d'un échantillon iid d'une loi normale. On aimerait savoir s'il y a un écart entre la moyenne attendue de 1000 MW et la moyenne réelle des compteurs qui sortent de la fabrication. Nous avons obtenu $\bar{x} = 994 < 1000$. S'agit-il d'un hasard ou une faute de production ?

On va prendre $\alpha = 5\%$.

Solution Exemple 208

Supposons que nos observations x_1, \dots, x_n soient des réalisations de variables aléatoires $X_1, \dots, X_n \stackrel{\text{iid}}{\sim} \mathcal{N}(\mu, \sigma^2)$, avec σ^2 inconnu. On veut tester : $H_0 : \mu = \mu_0$ contre $H_1 : \mu \neq \mu_0$, où $\mu_0 = 1000$. On prend comme statistique de test

$$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t_{n-1} \text{ sous } H_0 : \mu = \mu_0.$$

Dans notre cas $n = 10$, $\mu_0 = 1000$, $\bar{x} = 994$, et

$$s^2 = \frac{1}{9} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{9} \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = 64.88,$$

donc $t_{\text{obs}} = -2.35$.

On rejette H_0 si et seulement si $|t_{\text{obs}}| > t_{n-1, 1-\alpha/2}$ (cas bilatéral). , $t_{n-1, 1-\alpha/2} = 2.262$ (voir les tables), et comme $t_{\text{obs}} = -2.35 < -2.262$, on rejette l'hypothèse H_0 .

Intervalles de confiance et tests

- Soient $Y_1, \dots, Y_n \sim \mathcal{N}(\mu, \sigma^2)$ avec μ, σ inconnus
- Considérons $H_0 : \mu = 0$ et $H_1 : \mu \neq 0$
- On rejette H_0 au niveau α si et seulement si

$$|T_n| = \left| \sqrt{n} \frac{\bar{Y}_n}{S_n} \right| > t_{n-1, 1-\alpha/2}$$

- Intervalle de confiance (IC) de niveau $1 - \alpha$

$$\left[\bar{Y}_n - \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n, \bar{Y}_n + \frac{t_{n-1, 1-\alpha/2}}{\sqrt{n}} S_n \right]$$

- Cet intervalle contient zéro si et seulement si

$$|\bar{Y}_n| \leq t_{n-1, 1-\alpha/2} S_n / \sqrt{n} \text{ et donc}$$

on rejette $H_0 \iff 0$ n'est pas dans l'intervalle de confiance

- De manière générale, rejet de $H_0^{\theta_0} : \theta = \theta_0$ est équivalent à {l'IC ne contient pas θ_0 } si on se base sur la même statistique de test
- α petit \iff difficile à rejeter \iff IC de niveau $1 - \alpha$ large

- Rejet $\iff p_{obs} \leq \alpha \iff \theta_0 \notin \text{IC de niveau } 1 - \alpha$
- **IC** : α fixé, pour quels $\theta_0 \in \mathbb{R}$ $H_0^{\theta_0}$ n'est pas rejetée ?
- **p-valeur** : θ_0 fixé, pour quels $\alpha \in (0, 1)$ $H_0^{\theta_0}$ est rejetée ?

3.4 Tests khi-deux

Le test khi-deux

- On se pose la question de l'adéquation d'une distribution théorique à des données
- Supposons que dans une expérience on observe n résultats différents avec des
 - **fréquences observées** dans k classes disjointes o_1, \dots, o_k , alors que les
 - **fréquences théoriques** correspondantes sont e_1, \dots, e_k ,
 - où $\sum_{i=1}^k o_i = \sum_{i=1}^k e_i = n$
- On a H_0 : "les observations proviennent de la loi théorique spécifiée"
- Une mesure de l'écart entre les o_j et les e_j est donnée par la **statistique khi-deux**

$$T_n = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$$

- Si n est grand et les e_i ne sont pas trop petites (règle de pouce : $e_i \geq 5$ pour la plupart), alors $T_n \stackrel{\text{app}}{\sim} \chi_\nu^2$ sous H_0 , où
 - χ_ν^2 est la loi **khi-carré**, la loi de $\sum_{i=1}^\nu Z_i^2$ où $Z_i \stackrel{\text{iid}}{\sim} \mathcal{N}(0, 1)$
 - $\nu = k - 1$ si les e_i peuvent être calculés sans devoir estimer des paramètres inconnus
 - $\nu = k - 1 - c$ si les e_i sont calculés après avoir estimé c paramètres

Exemple

$$\text{rejet de } H_0 \text{ au niveau } \alpha \iff t_{\text{obs}} = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i} > \chi_{\nu, 1-\alpha}^2$$

Exemple $n = 60$ jets d'un dé ont donné la répartition suivante :

Valeur x_i	1	2	3	4	5	6	
Valeur o_i	8	10	9	16	13	4	60

Ici $k = 6$ et H_0 : "équilibre du dé" est équivalente au modèle

$$\Pr(X = x) = 1/6, \quad x \in \{1, \dots, 6\}.$$

Exemple

Exemple L'intelligence (QI) X de $n = 1000$ personnes est testée :

Score X	[0, 70)	[70, 85)	[85, 100)	[100, 115)	[115, 130)	[130, ∞)
Nombre o_i	34	114	360	344	120	28

Est-il plausible que $X \sim \mathcal{N}(100, 15^2)$?

On a

$$\begin{aligned}e_i &= n \Pr_{\mathcal{N}(100, 15^2)}(a_i \leq X \leq b_i) = n \Pr \left(\frac{a_i - 100}{15} \leq \frac{X_i - 100}{15} \leq \frac{b_i - 100}{15} \right) \\ &= n \Phi \left(\frac{b_i - 100}{15} \right) - n \Phi \left(\frac{a_i - 100}{15} \right)\end{aligned}$$

Tableaux de contingence

Un **tableau de contingence** est une classification de n objets ou individus selon plusieurs critères

- Une question fondamentale concerne **l'indépendance** des critères
- Supposons qu'on observe deux caractères A (h classes) et B (k classes) sur chacun de n individus, donnant le **tableau de contingence** suivant :

	B						
A	1	2	...	j	...	k	Σ
1	n_{11}	n_{12}	...	n_{1j}	...	n_{1k}	$n_{1.}$
2	n_{21}	n_{22}	...	n_{2j}	...	n_{2k}	$n_{2.}$
...
i	n_{i1}	n_{i2}	...	n_{ij}	...	n_{ik}	$n_{i.}$
...
h	n_{h1}	n_{h2}	...	n_{hj}	...	n_{hk}	$n_{h.}$
Σ	$n_{.1}$	$n_{.2}$...	$n_{.j}$...	$n_{.k}$	$n_{..} = n$

Indépendance

- Soit n_{ij} le nombre de personnes tombant dans la classe i du caractère A et dans la classe j du caractère B , et soit

$$n_{i.} = \sum_{j=1}^k n_{ij}, \quad n_{.j} = \sum_{i=1}^h n_{ij}, \quad i \in \{1, \dots, h\}, j \in \{1, \dots, k\}$$

- On désire tester H_0 : **A et B sont indépendants**. Dans ce cas

$$\Pr(A = i, B = j) = \Pr(A = i) \times \Pr(B = j), \quad i \in \{1, \dots, h\}, j \in \{1, \dots, k\},$$

et les probabilités empiriques sont

$$\Pr(\widehat{A = i}) = \frac{n_{i.}}{n}, \quad \Pr(\widehat{B = j}) = \frac{n_{.j}}{n}$$

Ainsi, sous H_0 , l' (i, j) ième élément du tableau de contingence est

$$E_{ij} = n \times \Pr(A = i, B = j) = n \times \Pr(A = i) \times \Pr(B = j)$$

qu'on va estimer par

$$e_{ij} = n \frac{n_{i.}}{n} \frac{n_{.j}}{n} = \frac{n_{i.} n_{.j}}{n}$$

Calcul sous H_0

- Sous H_0 et pour n grand, la statistique T_n suit une distribution χ^2_ν avec $\nu = (h-1)(k-1)$, car on a dû estimer $c = (h-1) + (k-1)$ probabilités, et
$$hk - 1 - c = kh - 1 - (h-1) - (k-1) = (h-1)(k-1)$$
- Pour tester à un niveau de significativité α fixé, on rejette H_0 si $t_{\text{obs}} > \chi^2_{(h-1)(k-1), 1-\alpha}$, sinon on ne rejette pas H_0

Exemple On a relevé parmi 95 personnes la couleur de leurs yeux (caractère A) et celle de leurs cheveux (caractère B) et on a obtenu les résultats suivants :

A	B		
	Cheveux clairs	Cheveux sombres	
Yeux bleus	$n_{11} = 32$	$n_{12} = 12$	$n_{1.} = 44$
Yeux bruns	$n_{21} = 14$	$n_{22} = 22$	$n_{2.} = 36$
Autres	$n_{31} = 6$	$n_{32} = 9$	$n_{3.} = 15$
Σ	$n_{.1} = 52$	$n_{.2} = 43$	$n = 95$

On désire tester si la couleur des cheveux est indépendante de celle des yeux

Donc on a H_0 : indépendance entre couleur des cheveux et couleur des yeux

Régularité (non-examinable)

Les conditions de régularité sont compliquées. Elles sont fausses le plus souvent quand

- un des paramètres est discret
- le support de $f(y; \theta)$ dépend de θ
- le vrai θ se trouve sur une borne des valeurs possibles

Elles sont satisfaites dans la grande majorité des cas rencontrés en pratique

Exemple Soient $Y_1, \dots, Y_n \stackrel{\text{iid}}{\sim} U(0, \theta)$, trouver la vraisemblance $L(\theta)$ et le $\hat{\theta}_{\text{ML}}$. Montrer que la loi limite de $n(\theta - \hat{\theta}_{\text{ML}})/\theta$ quand $n \rightarrow \infty$ est $\exp(1)$.
Discuter.

Preuve (non-examinable)

- Les fonctions de densité et de répartition de y_j sont

$$f(y; \theta) = \theta^{-1} I(0 \leq y \leq \theta), \quad F(y) = y/\theta, \quad 0 \leq y \leq \theta.$$

- L'indépendance donne

$$L(\theta) = \prod \theta^{-1} I(Y_j < \theta) = \theta^{-n} I(\max Y_j \leq \theta), \quad \theta > 0,$$

qui est maximisée au point $\hat{\theta}_{\text{ML}} = M_n = \max Y_j$

- On a

$$\Pr(M_n \leq x) = \prod_{j=1}^n \Pr(Y_j \leq x) = (x/\theta)^n, \quad 0 \leq x \leq \theta$$







- Donc pour $x \geq 1$ et $n \geq x$,

$$\begin{aligned} \Pr \left\{ n(\theta - \hat{\theta}_{\text{ML}})/\theta \leq x \right\} &= \Pr(\hat{\theta}_{\text{ML}} \geq \theta - x\theta/n) = 1 - \{(\theta - x\theta/n)/\theta\}^n \\ &\rightarrow 1 - \exp(-x), \end{aligned}$$

comme requis

Exemple (non examinable)

Comparaison des lois de $\hat{\theta}$ dans un cas régulier (en haut, avec écart-type $\propto n^{-1/2}$ et loi limite normale) et dans un cas non-régulier (en bas, avec écart-type $\propto n^{-1}$ et loi limite non-normale)



4. Régression

4.1 Introduction