

1 Concepts fondamentaux de la statistique

Définition 1.0.1 (Modèle statistique) Un *modèle statistique* est la donnée d'un espace mesuré (E, \mathcal{E}) et d'une famille $\{P_\theta, \theta \in \Theta\}$ de lois de probabilités. Le modèle associé est noté $(E, \mathcal{E}, P_\theta, \theta \in \Theta)$. Quand il existe un entier d tel que $\Theta \subset \mathbb{R}^d$, le modèle est dit *paramétrique*, et non *paramétrique* sinon.

Définition 1.0.2 (Observation) Une *observation* \mathbb{X} est une variable aléatoire à valeurs dans E et dont la loi appartient à la famille $(P_\theta)_{\theta \in \Theta}$.

Définition 1.0.3 (Echantillon) Pour $n \in \mathbb{N}^*$, un *n-échantillon* sdde loi ν est la donnée de n variables aléatoires X_1, \dots, X_n indépendantes et identiquement distribuées de loi ν .

2 Estimation

Définition 2.0.4 (Estimateur) Soit $g : \Theta \rightarrow \mathbb{R}^p$ une fonction de θ à estimer. Un estimateur \hat{g} de $g(\theta)$ est une application mesurable de l'observation \mathbb{X} et indépendante de θ . Tout estimateur est donc de la forme $\hat{g} = h(\mathbb{X})$, où h est une application mesurable $E \rightarrow \mathbb{R}^p$.

2.1 construction de l'estimateur

Définition 2.1.1 (Estimateur consistant, fortement consistant)

Soit $\mathbb{X} = (X_1, \dots, X_n)$ un *n-échantillon*, et $\hat{g}_n = h_n(X_1, \dots, X_n)$ un estimateur de $g(\theta)$. Cet estimateur est dit :

- i) **Consistant** si, pour tout θ dans Θ , \hat{g}_n converge en \mathbb{P}_θ -probabilités vers $g(\theta)$ lorsque $n \rightarrow \infty$.
- ii) **Fortement consistant** si, pour tout θ dans Θ , \hat{g}_n converge \mathbb{P}_θ -p.s. vers $g(\theta)$ lorsque $n \rightarrow \infty$.

Par abus de langage, on parle toujours de la consistance de l'estimateur là où l'on devrait parler de la consistance de la suite d'estimateurs.

2.2 Construction d'estimateurs

Méthode des moments :

Cette méthode est utile lorsque les paramètres d'intérêt s'expriment en fonction des moments de la loi des observations : par exemple dans les cas où ces moments existent, on approchera $\mu_1 = \mathbb{E}_\theta(X_1)$ et $\mu_2 = \mathbb{E}_\theta(X_1^2)$ respectivement par

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i, \text{ et } \bar{X}_n^2 = \frac{1}{n} \sum_{i=1}^n X_i^2.$$

Plus généralement, étant données q fonctions ϕ_1, \dots, ϕ_q , en posant $g_i(\theta) = \mathbb{E}_\theta(\phi_i(1))$, on estime $g(\theta) = \psi(g_1(\theta), \dots, g_q(\theta))$ par

$$\hat{g}_n = \psi\left(\sum_{i=1}^n \phi_1(X_i), \dots, \sum_{i=1}^n \phi_q(X_i)\right).$$

Par exemple, la variance $\sigma^2 = \mathbb{E}(X_1^2) - \mathbb{E}(X_1)^2$, va être estimée par

$$\hat{S}_n^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2.$$

Méthode du maximum de vraisemblance :

Cette méthode ne s'applique que lorsque toutes les lois du modèle admettent une densité par rapport à une mesure commune, typiquement la mesure

de Lebesgue. Dans ce cas, on note f_θ cette densité. La méthode consiste à approcher $g(\theta) = \theta$ par l'élément de θ maximisant la **vraisemblance**

$$\begin{aligned} V(\mathbb{X}) &: \Theta \rightarrow \mathbb{R} \\ \theta &\mapsto f_\theta(\mathbb{X}) = \prod f_\theta(X_i) \end{aligned}$$

2.3 Normalité asymptotique

Définition 2.3.1 (Normalité asymptotique) Soit $\mathbb{X} = (X_1, \dots, X_n)$, et $\hat{\theta}$ un estimateur de θ . Il est dit **asymptotiquement normal** si les trois conditions suivantes sont vérifiées :

- i) La vitesse de convergence de l'estimateur est en \sqrt{n} .
- ii) La convergence a lieu en loi.
- iii) La loi limite est normale.

Théorème 2.3.1 (Méthode Δ) On se donne une suite $(U_n)_{n \in \mathbb{N}}$ de vecteurs aléatoires de \mathbb{R}^m , une suite déterministe $(a_n)_{n \in \mathbb{N}}$ et une application $l : \mathbb{R}^m \rightarrow \mathbb{R}^p$ tels que :

- i) $a_n \rightarrow \infty$.
- ii) $\exists U \in \mathbb{R}^m$, un vecteur déterministe et un vecteur aléatoire V tel que

$$a_n(U_n - U) \xrightarrow{\mathcal{L}} V .$$

- iii) l est une fonction différentiable en U de différentielle notée $D_l(U) \in M_{p,n}(\mathbb{R})$.

Alors, on a

$$a_n(l(U_n) - l(U)) \xrightarrow{\mathcal{L}} D_l(U)V .$$

Lemme 2.3.1 (Slutsky) Soient $(X_n)_{n \in \mathbb{N}}$ et $(Y_n)_{n \in \mathbb{N}}$ deux suites de vecteurs aléatoires prenant leurs valeurs respectivement dans \mathbb{R}^d et dans \mathbb{R}^p , où p et d sont dans \mathbb{N}^* . Si $X_n \rightarrow X$, et $Y_n \xrightarrow{\mathbb{P}} C$ pour une certaine variable aléatoire X et un vecteur déterministe C , alors

$$(X_n, Y_n) \xrightarrow{\mathcal{L}} (X, C) .$$

Corollaire 2.3.1 Soit (X_1, \dots, X_n) un n -échantillon de vecteurs de \mathbb{R}^n , de loi commune admettant un moment d'ordre 2, d'espérance μ et de matrice de variance covariance Σ . Si l est une fonction différentiable en μ , de différentielle notée $D_l(\mu)$, alors

$$\sqrt{n}(l(\bar{X}_n) - l(\mu)) \xrightarrow{\mathcal{L}} \mathcal{N}(0, D_l(\mu)\Sigma D_l(\mu)) .$$

2.4 Estimation sans biais

Définition 2.4.1 (biais) Soit \mathbb{X} une observation et $\hat{g}(\theta) = h(\mathbb{X})$ un estimateur de $g(\theta)$. vérifiant $\mathbb{E}_\theta(\|\hat{g}\|) < \infty$ pour tout θ . On appelle **biais** la fonction

$$b : \theta \mapsto \mathbb{E}_\theta(\hat{g}) - g(\theta) .$$

\hat{g} est dit sans biais lorsque son biais est identiquement nul.

Définition 2.4.2 (biais asymptotique) Soit $\mathbb{X} = (X_1, \dots, X_n)$ une observation et $\hat{g}_n(\theta) = h(\mathbb{X})$ un estimateur de $g(\theta)$. vérifiant $\mathbb{E}_\theta(\|\hat{g}_n\|) < \infty$ pour tout n, θ . On appelle **biais** la suite de fonctions

$$b_n : \theta \mapsto \mathbb{E}_\theta(\hat{g}_n) - g(\theta) .$$

\hat{g} est dit asymptotiquement sans biais lorsque la limite $n \rightarrow \infty$ de son biais est identiquement nul.

2.5 Estimation optimale

Définition 2.5.1 (Risque quadratique d'un estimateur) A tout estimateur \hat{g} de $g(\theta)$, on associe son risque (quadratique) défini comme l'application

$$\begin{aligned} R &: \Theta \rightarrow [0, +\infty] \\ \theta &\mapsto \mathbb{E}_\theta((\hat{g} - g(\theta))^2) . \end{aligned}$$

Un estimateur est d'autant meilleur que son risque est faible sur Θ . On a la relation fondamentale suivante :

$$R(\theta) = b(\theta)^2 + \text{var}(\hat{g})$$

2.6 Bornes de Cramér-Rao

On suppose $\Theta =]a, b[\subset \mathbb{R}$, et on suppose le modèle dominé par μ . On note f_θ les densités respectives, et on se place sous les hypothèses de régularité suivantes : pour μ —presque tout x , $\theta \mapsto f_\theta(x)$ est continue et continument différentiable sauf éventuellement en un nombre fini de points, et la quantité $f'_\theta(x)^2/f_\theta(x)\mathbb{1}_{f_\theta(x)>0}$ est intégrable en μ d'intégrale

$$I(\theta) = \int_{f_\theta(x)>0} \frac{f'_\theta(x)^2}{f_\theta(x)} d\mu(x) \text{ continue.}$$

Cette intégrale est appelée **information de Fisher** du modèle.

Proposition 2.6.1 *Dans ces conditions, considérons une statistique $T(\mathbb{X})$ telle que $\mathbb{E}_\theta(T^2(\mathbb{X}))$ est bornée sur Θ . Alors, l'application*

$$\theta \mapsto \mathbb{E}_\theta(T(\mathbb{X}))$$

est continument différentiable sur Θ , de dérivée

$$\int_{f_\theta(x)>0} T(x) f'_\theta(x) d\mu(x) = \mathbb{E}_\theta \left(T(\mathbb{X}) \frac{\partial}{\partial \theta} \log(f_\theta(\mathbb{X})) \right).$$

Corollaire 2.6.1 *Si la famille (P_θ) est régulière, alors*

$$\int_{f_\theta(x)>0} f'_\theta(x) d\mu(x) = 0.$$

Cela implique en particulier que

$$I(\theta) = \text{var}_\theta \left(\frac{\partial}{\partial \theta} \log f_\theta(\mathbb{X}) \right).$$

Théorème 2.6.1 *Soit $\hat{g} = h(\mathbb{X})$ un estimateur sans biais de $g(\theta)$, où g est une fonction dérivable. Si le modèle est régulier, sur $\Theta =]a, b[\subset \mathbb{R}$ d'information strictement positive, et si $\mathbb{E}_\theta(h^2(\mathbb{X}))$ est bornée, on a $\forall \theta \in \Theta$*

$$\text{var}_\theta(\hat{g}) \geq \frac{(g'(\theta))^2}{I(\theta)}.$$

Le membre de droite est appelé borne de Cramér-Rao, et donne une minoration du risque de l'estimateur \hat{g} .

Corollaire 2.6.2 *Supposons que l'on observe un n -échantillon $\mathbb{X} = (X_1, \dots, X_n)$, et que la loi commune admette I_1 comme information de Fisher. Alors, sous les notations et hypothèses du théorème précédent, pour tout $\theta \in \Theta$, on a*

$$I(\theta) = nI_1(\theta), \text{ et } \text{var}_\theta(h(X_1, \dots, X_n)) \geq \frac{(g'(\theta))^2}{nI_1(\theta)}.$$

3 Intervalles et régions de confiance

Définition 3.0.1 (Région de confiance) *Pour tout $\alpha \in]0, 1[$, une **région de confiance** de $g(\theta)$ de niveau $1 - \alpha$ est un ensemble \hat{C} construit mesurablement par rapport à \mathbb{X} et tel que, pour tout $\theta \in \Theta$, on ait*

$$\mathbb{P}_\theta(g(\theta) \in \hat{C}) \geq 1 - \alpha.$$

Lorsque cette inégalité est une égalité, on dit que le niveau de confiance est exactement égal à $1 - \alpha$.

Définition 3.0.2 (Région de confiance asymptotique) *Pour tout $\alpha \in]0, 1[$, une **région de confiance asymptotique** de $g(\theta)$ de niveau $1 - \alpha$ est une suite d'ensembles $(\hat{C}_n)_{n \in \mathbb{N}}$ chacun construit mesurablement par rapport à $\mathbb{X} = (X_1, \dots, X_n)$ et tel que, pour tout $\theta \in \Theta$, on ait*

$$\liminf_{n \rightarrow \infty} \mathbb{P}_\theta(g(\theta) \in \hat{C}_n) \geq 1 - \alpha.$$

3.1 Premières constructions

Définition 3.1.1 (quantile) *Pour tout $\beta \in [0, 1]$, on appelle quantile d'ordre β d'une loi de proba P à support inclus dans \mathbb{R} la quantité*

$$q_\beta = \inf\{x \in \mathbb{R}, P([-\infty, x]) \geq \beta\}.$$

3.2 Intervalles de confiance exacts obtenus par des inégalités de probabilités

3.2.1 Cas des variances uniformément bornées

Proposition 3.2.1 (Inégalité de Bienaymé-Tchebitchev) Soit Y une variable aléatoire admettant un moment d'ordre 2. Alors, pour tout $\varepsilon > 0$,

$$\mathbb{P}(|Y - \mathbb{E}(Y)| > \varepsilon) \leq \frac{\text{var}Y}{\varepsilon^2}.$$

3.2.2 Cas des lois à supports tous inclus dans un compact borné.

Lemme 3.2.1 (Inégalité de Hoeffding) Soient Y_1, \dots, Y_n des variables aléatoires réelles indépendantes et $(\alpha_1, \dots, \alpha_n)$ et $(\beta_1, \dots, \beta_n)$ deux n -uplets de réels tels que, pour tout i , on ait

$$\mathbb{E}(Y_i) = 0 \text{ et } \alpha_i \leq Y_i \leq \beta_i \text{ p.s.}$$

Alors, pour tout $t > 0$,

$$\mathbb{P}\left(\sum_{i=1}^n Y_i \geq t\right) \leq 2 \exp\left(-\frac{2t^2}{\sum_{i=1}^n (\beta_i - \alpha_i)^2}\right).$$

3.3 Intervalle de confiance asymptotique

4 Test d'hypothèses

4.1 Formalisme et démarche expérimentale

Dans le cadre du modèle statistique $(E, \mathcal{E}, P_\theta, \theta \in \Theta)$. On se donne deux sous ensembles disjoints Θ_0 et Θ_1 inclus dans Θ , et on souhaite déterminer

si θ est dans Θ_0 ou Θ_1 . On définit donc les deux hypothèses, l'hypothèse nulle $H_0 : \theta \in \Theta_0$, et l'hypothèse alternative $H_1 : \theta \in \Theta_1$. L'hypothèse est dite simple si l'ensemble correspondant est un singleton, et composite sinon.

Définition 4.1.1 (Test) On appelle **test** de l'hypothèse H_0 contre H_1 toute fonction $\phi(\mathbb{X})$, à valeurs dans $\{0, 1\}$, où ϕ est mesurable, et peut dépendre de Θ_0 et Θ_1 . On accepte H_i si $\phi(\mathbb{X}) = i$. On peut toujours écrire $\phi(\mathbb{X}) = \mathbb{1}_{h(\mathbb{X}) \in R}$, où R est appelé **région de rejet**.

4.2 Mesure de la qualité d'un test

Définition 4.2.1 (Risques de première et seconde espèce) Les risques de première espèce et de seconde espèce du test $\phi(\mathbb{X})$ sont définies respectivement comme les fonctions $\underline{\alpha}$ sur Θ_0 et $\underline{\beta}$ sur Θ_1 par

$$\begin{aligned} \underline{\alpha} : \Theta_0 &\rightarrow [0, 1] & \text{et} & \underline{\beta} : \Theta_1 &\rightarrow [0, 1] \\ \theta &\mapsto \mathbb{P}_\theta(\phi(\mathbb{X}) = 1) & & \theta &\mapsto \mathbb{P}(\phi(\mathbb{X}) = 0) \end{aligned}$$

On appelle **puissance** d'un test la fonction $(1 - \underline{\beta})$ la probabilité de rejeter à raison. Sa **taille** est le réel

$$\alpha^* = \sup_{\theta \in \Theta_0} \underline{\alpha} = \sup_{\theta \in \Theta_0} \mathbb{P}_\theta(\phi(\mathbb{X}) = 1).$$

On dit enfin que le test est de **niveau** α si sa **taille** α^* est inférieure à α .

4.3 propriétés éventuelles d'un test

Un test est dit **sans biais** quand sa fonction de puissance vérifie $1 - \underline{\beta} > \alpha$ sur Θ_1 . Une suite de tests est **consistante** s'ils sont tous de niveau α et si, pour tout $\theta \in \Theta_1$, $\underline{\beta}_n \rightarrow 0$ quand $n \rightarrow \infty$. La **robustesse** exprime l'absence de sensibilité d'un test éventuellement asymptotique au modèle. (i.e à la loi ou la forme de l'observation).

Définition 4.3.1 Pour $\phi(\mathbb{X})$ et $\phi'(\mathbb{X})$ deux tests de niveau α , on dit que $\phi(\mathbb{X})$ est **uniformément plus puissant** que $\phi'(\mathbb{X})$ si les fonctions puissance vérifient

$$1 - \underline{\beta}' \geq 1 - \underline{\beta}, \text{ i.e. } \forall \theta \in \Theta_1, \mathbb{P}_\theta(\phi(\mathbb{X}) = 1) \geq \mathbb{P}_\theta(\phi'(\mathbb{X}) = 1)$$

4.4 Un outil : la p -valeur

Définition 4.4.1 (p -valeur) Supposons avoir construit une famille de tests $\phi_\alpha(\mathbb{X})$ de niveau $\alpha \in]0, 1[$. La p -valeur associée à cette famille et à l'observation \mathbb{X} est le réel défini par $\hat{\alpha}(\mathbb{X}) = \sup_{\alpha \in]0, 1[} \{\phi_\alpha(\mathbb{X}) = 0\}$. En d'autres termes, c'est le plus grand niveau autorisant l'acceptation de H_0 , et forme donc, en un certain sens, l'indice de crédibilité du test.

4.5 Botanique des tests

Théorème 4.5.1 (lemme de Neymann-Pearson) On fixe θ_0 et θ_1 deux points distincts de Θ , et on s'intéresse au test de $H_0 : \theta = \theta_0$ contre $H_1 : \theta = \theta_1$. Pour $\alpha \in]0, 1[$ fixé, donné, lorsqu'il existe un seuil k_α tel que le test du rapport de vraisemblance

$$\phi(\mathbb{X}) = \mathbb{1}_{h(\mathbb{X}, \theta_0, \theta_1) > k_\alpha}, \text{ où } h(\mathbb{X}, \theta_0, \theta_1) = \frac{V_{\mathbb{X}}(\theta_1)}{V_{\mathbb{X}}(\theta_0)} = \frac{f_{\theta_1}(\mathbb{X})}{f_{\theta_0}(\mathbb{X})}$$

vérifie $\mathbb{P}(\phi(\mathbb{X}) = 1) = \alpha$, alors ce test est $\text{upp}(\alpha)$.

5 Vecteurs gaussiens

5.1 Propriétés des vecteurs gaussiens et théorème de la limite centrale

5.1.1 Loi normale multidimensionnelle

Définition 5.1.1 (Vecteur gaussien) Une variable aléatoire réelle Z est dite gaussienne centrée réduite, ou de loi normale standard, noté $Z \sim$

$\mathcal{N}(0, 1)$ si sa loi admet pour densité sur \mathbb{R}

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}.$$

Une variable aléatoire réelle X est dite gaussienne, ou de loi normale de paramètres $\mu \in \mathbb{R}$ et $\sigma^2 \in \mathbb{R}_+$, ce que l'on note $X \sim \mathcal{N}(\mu, \sigma^2)$ s'il existe une variable aléatoire Z normale standard, et tel que $X = \mu + \sigma Z$. Lorsque $\sigma = 0$, on dit que X est dégénéré.

Théorème 5.1.1 La fonction caractéristique de la loi $\mathcal{N}(\mu, \sigma^2)$ vaut

$$\phi_{\mu, \sigma^2}(t) = e^{i\mu t - \frac{\sigma^2 t^2}{2}} \quad \forall t \in \mathbb{R}.$$

5.1.2 Loi normale multidimensionnelle

Définition 5.1.2 (Loi normale multidimensionnelle) Un vecteur aléatoire X à valeurs dans \mathbb{R}^d est dit gaussien si toute combinaison linéaire de ses composantes suit une loi normale. Si $X = (X_1, \dots, X_n)$ est un vecteur gaussien, on définit son vecteur moyenne par $\mathbb{E}(X) = (\mathbb{E}(X_1), \dots, \mathbb{E}(X_n))$, et sa matrice de variance covariance par

$$\text{var}(X) = (X - \mathbb{E}(X))(X - \mathbb{E}(X))^T = (\text{cov}(X_i, X_j))_{i,j}.$$

5.1.3 Propriétés des vecteurs gaussiens

Théorème 5.1.2 Soit $X = (X_1, \dots, X_d)^T$ un vecteur gaussien d'espérance M et de matrice de variance covariance Σ . Alors, X admet pour fonction caractéristique

$$\varphi_X(t) = \mathbb{E}\left(e^{it^T X}\right) = \exp\left(it^T M - \frac{t^T \Sigma t}{2}\right), \quad \forall t \in \mathbb{R}^d.$$

Proposition 5.1.1 Soit $X = (X_1, \dots, X_d)^T$ un vecteur gaussien d'espérance M et de matrice de variance covariance Σ . Alors, pour toute matrice A $d' \times d$ et tout vecteur b dans $\mathbb{R}^{d'}$, on a $AX+b$ est un vecteur gaussien de moyenne $AM+b$ et de matrice de variance covariance $A\Sigma A^T$. Pour tout couple i, j , on a de plus

$$X_i \perp X_j \Leftrightarrow \text{cov}(X_i, X_j) = 0 .$$

Enfin, X admet une densité par rapport à la mesure de Lebesgue sur \mathbb{R}^d si et seulement si Σ est inversible, i.e. définie positive. Sa densité est alors donnée par

$$f(x) = \frac{1}{\sqrt{2\pi^d} \sqrt{\det(\Sigma)}} \exp \left(-\frac{1}{2} (x - m)^T \Sigma^{-1} (x - m) \right) .$$

Si elle n'est pas inversible, alors la loi de $X - m$ est p.s. portée par l'espace engendré par les vecteurs propres pour des valeurs propres non nulles de Σ .

Proposition 5.1.2 (Espérance conditionnelle) Quand $(Y, X_1, \dots, X_d)^T$ est un vecteur gaussien, $\mathbb{E}(Y \mid X_1, \dots, X_d)$ est une fonction affine des composantes de $(X_1, \dots, X_d)^T$.

5.1.4 version multidimensionnelle du TCL

Théorème 5.1.3 Soit (V_1, \dots, V_n) un n -échantillon de vecteurs de \mathbb{R}^d admettant un moment d'ordre 2, dont on note m l'espérance et Σ la variance-covariance commune, alors

$$\sqrt{n}(\bar{V}_n - m) \rightarrow \mathcal{N}(0, \Sigma) \text{ en loi.}$$

5.2 Loi du χ^2 et de Student

Définition 5.2.1 (Loi du χ^2) Soit $X = (X_1, \dots, X_d)^T$ un vecteur gaussien d'espérance m et de matrice de variance covariance $\Sigma = Id$. Alors,

la loi de la variable aléatoire $\|X\|_2^2 = X_1^2 + \dots + X_d^2$ ne dépend que de d et de la norme 2 de m . On dit que cette loi est une loi du χ^2 à d degrés de liberté, et de paramètre de décentrage $\|m\|_2^2$, ce que l'on note

$$\|X\|_2^2 \sim \chi^2(d, \|m\|_2^2) .$$

Cette loi est dite décentrée lorsque le paramètre de décentrage est nul, on ne note alors pas le second paramètre.

Définition 5.2.2 (Loi de Student) Lorsque X et Y sont deux variables aléatoires indépendantes, telles que $X \sim \mathcal{N}(\mu, 1)$, et $Y \sim \chi^2(d)$. Alors, la loi de la variable aléatoire $Z = X/\sqrt{Y/d}$ est appelée **loi de Student** à d degrés de liberté, notée $\mathcal{T}(d, \mu)$. Le nombre réel μ est le paramètre de décentrage, et on l'omet lorsqu'il est nul.

5.3 Conséquences statistiques : intervalles de confiance et tests

5.3.1 Un outil fondamental : le théorème de Cochran

Théorème 5.3.1 (Cochran) On considère un vecteur gaussien X de loi $\mathcal{N}(m, Id)$, et une décomposition $E_1 \oplus \dots \oplus E_r$ de \mathbb{R}^d en sous espaces orthogonaux de dimensions respectives d_1, \dots, d_r . Alors, les projections orthogonales $\Pi_{E_1} X, \dots, \Pi_{E_r} X$ forment des vecteurs gaussiens indépendants. Par ailleurs, pour $j \in \{1, \dots, r\}$,

$$\|\Pi_{E_j} X\|_2^2 \sim \chi^2(d_j, \|\Pi_{E_j} m\|_2^2) .$$

5.3.2 Intervalles de confiance et tests sur les paramètres d'une loi normale

Proposition 5.3.1 Soit (X_1, \dots, X_n) un n -échantillon de loi $\mathcal{N}(\mu, \sigma^2)$. Alors, \bar{X}_n et \hat{S}_n^2 sont indépendants, et

$$\bar{X}_n \sim \mathcal{N} \left(\mu, \frac{\sigma^2}{n} \right) \text{ et } \frac{n\hat{S}_n^2}{\sigma^2} \sim \chi^2(n-1) .$$

Enfin,

$$\sqrt{n} \frac{(\bar{X}_n - \mu)}{\sqrt{\hat{S}_n^2}} \sim \mathcal{T}(n-1).$$

6 Le modèle linéaire gaussien

6.1 Définitions

Définition 6.1.1 (Modèle linéaire gaussien) Soit Y un vecteur d'observations de \mathbb{R}^n . On dit que Y suit un modèle linéaire gaussien lorsque

$$(*) Y = m + \varepsilon, \quad \text{où } \varepsilon \sim \mathcal{N}(0, \sigma^2 I_n),$$

pour deux paramètres inconnus $m \in \mathbb{R}^n$, et $\sigma^2 \in \mathbb{R}_+^*$. On fait l'hypothèse que m appartient à un sous-espace vectoriel V de \mathbb{R}^n . Le vecteur ε est appelé le "vecteurs des erreurs". On adapte souvent l'écriture matricielle pour reformuler un modèle linéaire gaussien, selon

$$Y = X\beta + \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, \sigma^2 I_n),$$

pour les paramètres inconnus $\beta \in \mathbb{R}^p$ et σ^2 . La matrice X est connue. On notera Π_V le projecteur orthogonale sur le sous-espace V .

6.2 Estimateurs des paramètres du modèle

Théorème 6.2.1 On se place dans le modèle (*), où les paramètres sont $\sigma^2 > 0$, et $m \in V$ pour un sous-espace vectoriel V connu de \mathbb{R}^n de dimension $p \geq 1$. Alors :

- i) L'estimateur du maximum de vraisemblance de $\theta = (m, \sigma^2)$ est $\hat{\theta}_n = (\hat{m}, \hat{S}_n^2)$ où $\hat{m} = \Pi_V Y$, et $\hat{S}_n^2 = 1/n \|Y - \Pi_V Y\|_2^2$.

- ii) Les estimateurs \hat{m} et \hat{S}_n^2 sont indépendants de lois respectives

$$\hat{m} \sim \mathcal{N}(m, \sigma^2 \Pi_V), \quad \text{et} \quad \frac{n\hat{S}_n^2}{\sigma^2} \sim \chi(n-p).$$

Théorème 6.2.2 On se place dans le modèle (**), où les paramètres sont $\sigma^2 > 0$, et $\beta \in \mathbb{R}^p$. Alors :

- i) L'estimateur du maximum de vraisemblance de $\theta = (\beta, \sigma^2)$ est $\hat{\theta}_n = (\hat{\beta}_n, \hat{S}_n^2)$ où $\hat{\beta}_n = (X^T X)^{-1} X^T Y$, et $\hat{S}_n^2 = 1/n \|Y - X\hat{\beta}_n\|_2^2$.
- ii) Les estimateurs $\hat{\beta}_n$ et \hat{S}_n^2 sont indépendants de lois respectives

$$\hat{\beta}_n \sim \mathcal{N}(m, \sigma^2 (X^T X)^{-1}), \quad \text{et} \quad \frac{n\hat{S}_n^2}{\sigma^2} \sim \chi(n-p).$$

6.3 Regions de cofiance et tests fondamentaux

6.3.1 Tests et intervalles de confiance par la variance

6.3.2 Test de Student d'une relation affine

On se place dans le modèle (**). On souhaite tester, étant donné $C \in \mathbb{R}^p$ et $a \in \mathbb{R}$, l'hypothèse $H_0 : C^T \beta = a$ contre $H_1 : C^T \beta \neq a$. La statistique de test naturelle est donnée par

$$T_n = \frac{C^T \hat{\beta}_n - a}{\hat{\sigma}_n \sqrt{C^T (X^T X)^{-1} C}}.$$

Le test $\phi(Y) = \mathbb{1}_{|T_n| > t_{1-\alpha/2}(n-p)}$ est alors de taille α .

6.3.3 Test de Fisher d'un sous modèle

Définition 6.3.1 La loi de fisher à k et l degrés de liberté, notée $F(k, l)$ est la loi du quotient de deux χ^2 à k et l degrés de liberté.

On se donne W un sous-espace de V , et on souhaite tester $H_0 : m \in W$ contre $H_1 : m \in V - W$.

Théorème 6.3.1 *lorsque $m \in W$, alors la statistique*

$$\frac{(\|Y - \Pi_W Y\|_2^2 - \|Y - \Pi_V Y\|_2^2)/(p - q)}{\|Y - \Pi_V(Y)\|_2^2/(n - p)}$$

suit une loi de fisher à $p - q$ et $n - p$ degrés de liberté.

6.3.4 Test de Wall de plusieurs relations affines

On se place dans le modèle (**). On souhaite tester, étant donné une matrice de transition C et $a \in \mathbb{R}^n$, l'hypothèse $H_0 : C\beta = a$ contre

$$H_1 : C\beta \neq a.$$

Théorème 6.3.2 *Sous H_0 la statistique*

$$W = \frac{[C\hat{\beta}_n - a]^T (C(X^T X)^{-1} C)(C\hat{\beta}_n - a)}{\|Y - X\hat{\beta}_n\|_2^2/(n - p)} \sim \mathcal{F}(k - np) .$$

6.3.5 Application à la régression linéaire