

*Université Paris I, Panthéon - Sorbonne*

MASTER M.A.E.F.

## Mise à niveau en Statistique

JEAN-MARC BARDET (UNIVERSITÉ PARIS 1, SAMM)

### Plan du cours

1. Rappels de probabilités utiles en statistique inférentielle
  - (a) Statistiques descriptives
  - (b) Retour sur les variables aléatoires
  - (c) Retour sur les vecteurs aléatoires
  - (d) Le cas gaussien et les lois associées (Student, Chi<sup>2</sup>, Fisher)
  - (e) Théorèmes limite
2. Estimation paramétrique
  - (a) Estimation "intuitive"
  - (b) Estimation par maximum de vraisemblance
  - (c) Intervalles de confiance
3. Tests paramétriques
  - (a) Principe général de test
  - (b) Tests "intuitifs"
  - (c) Test du rapport de vraisemblance

## References

- [1] Barbe P. et Ledoux M. (1998) *Probabilité*. EDP Sciences.
- [2] Dacunha-Castelle, D. et Duflo, M., *Probabilités et Statistiques (I)*, Masson.
- [3] Fourdrinier, D., *Statistique inférentielle*, Dunod.
- [4] Milhaud, X., *Statistique*, Belin.
- [5] Monfort, A., *Cours de statistique mathématique*, Economica.
- [6] Saporta, G., *Probabilités, analyse des données et statistiques*. Technip.

## Documents accessibles librement sur internet

### References

- [1] Site de Philippe Besse à Toulouse: <http://wikistat.fr/>
- [2] Site de Ricco Rakotomalala: <http://eric.univ-lyon2.fr/~ricco/cours/index.html>
- [3] Cours de Marc Lavielle à l'Ecole Polytechnique: <http://sia.webpopix.org/>
- [4] Livre de Davidson-MacKinnon sur le site de R. Davidson:  
<http://russell.vcharite.univ-mrs.fr/EIE/>
- [5] Cours de V. Rivoirad à Dauphine:  
<https://www.ceremade.dauphine.fr/~rivoirar/Poly-L3-StatMath.pdf>

Feuille  $n^o$  1:**Révisions sur les variables et vecteurs aléatoires**

- (\*) On considère deux v.a.  $X$  et  $Y$  définies sur le même espace de probabilité  $(\Omega, \mathcal{A}, P)$ . Supposons que  $X$  et  $Y$  ont la même loi. Est-t-il nécessairement vrai que  $\forall \omega \in \Omega, X(\omega) = Y(\omega)$  ?
- (\*\*) Sur  $(\Omega, \mathcal{A}, P)$  un espace de probabilité, on considère une v.a. réelle positive  $X$  de fonction de répartition  $F_X$ . Déterminer dans les 2 cas suivants l'espérance et la variance de  $X$  :

$$F_X(t) = \frac{1}{2} (e^t \mathbb{I}_{]-\infty, 0[}(t) + (2 - e^{-t}) \mathbb{I}_{[0, \infty[}(t)) ;$$

$$F_X(t) = \frac{1}{4} (t + 2) \mathbb{I}_{[-1, 0[ \cup ]1, 2[}(t) + \frac{3}{4} \mathbb{I}_{[0, 1]}(t) + \mathbb{I}_{[2, \infty[}(t).$$

- (\*) On a observé  $(X_1, \dots, X_n)$ . Déterminer  $\hat{m} = \operatorname{argmin}_{m \in \mathbb{R}} \sum_{i=1}^n (X_i - m)^2$ .
- (\*\*) Soit  $X$  une v.a. réelle normale centrée réduite et soit  $Y$  une v.a. indépendante de  $X$ , à valeurs dans  $\{-1, 1\}$  telle que  $P(Y = 1) = 0.5$ . On considère la v.a.  $Z = X \cdot Y$ . Déterminer la mesure de probabilité de  $Z$ , puis celle de  $X + Z$ . En déduire que la somme de 2 variables gaussiennes peut ne pas être gaussienne.
- (\*\*) Soit  $X$  et  $Y$  deux v.a. indépendantes définies sur le même espace de probabilité  $(\Omega, P)$ ,  $X$  suivant une loi de Bernoulli de paramètre  $p$ , et  $Y$  suivant une loi de Poisson de paramètre  $\lambda$ . On pose pour tout  $\omega \in \Omega$ ,

$$Z(\omega) = \begin{cases} 0 & \text{si } X(\omega) = 0 \\ Y(\omega) & \text{si } X(\omega) = 1 \end{cases}$$

- Montrer que pour tout  $\omega \in \Omega$   $Z(\omega) = X(\omega)Y(\omega)$ .
  - Calculer l'espérance et la variance de  $Z$ .
- (\*\*\*) Soit  $(X_1, \dots, X_n)$  un échantillon de v.a.i.i.d. gaussiennes de moyenne  $m$  et de variance  $\sigma^2 > 0$ .
    - On note  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Déterminer la loi de  $\bar{X}_n$ .
    - Si on note  $\mathbb{I} = {}^t(1, 1, \dots, 1)$ , montrer que le projeté orthogonal du vecteur  ${}^t(X_1, \dots, X_n)$  sur le sev de  $\mathbb{R}^n$  engendré par  $\mathbb{I}$  est  $\bar{X}_n \mathbb{I}$ .
    - On note  $\bar{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ . En utilisant le Théorème de Cochran, démontrer que  $(n-1) \frac{\bar{\sigma}_n^2}{\sigma^2} \stackrel{\mathcal{L}}{\sim} \chi^2(n-1)$ .

- (d) En utilisant le Théorème de Cochran, démontrer que  $\bar{X}_n$  et  $\bar{\sigma}_n^2$  sont deux v.a. indépendantes. En déduire la loi de  $\hat{T}_n = \frac{\sqrt{n}(\bar{X}_n - m)}{\sqrt{\bar{\sigma}_n^2}}$ .
7. (\*\*) On effectue un sondage sur les intentions de vote d'une élection présidentielle. On supposera que chaque électeur a une probabilité  $p$  de voter pour le candidat  $C$  ( $p$  est inconnue). On interroge  $n$  personnes choisies au hasard. On note  $p_n$  la variable aléatoire qui est la proportion d'électeurs parmi  $n$  désirant voter pour  $C$ .
- (a) Donner la loi approchée de  $p_n$ .
- (b) Que peut-on dire sur  $p_n$  lorsque  $n \rightarrow +\infty$ ?
- (c) D'après le sondage,  $k$  personnes disent vouloir voter pour  $C$ . On note  $\hat{p} = k/n$ . Déterminer la valeur minimale de  $n$  telle que la probabilité de l'événement  $\{|p_n - p| \leq 1\%\}$  soit supérieure à 95%? (on étudiera les cas  $\hat{p} \sim 0.5$  et  $\hat{p} \sim 0$ ).
8. (\*\*\*) Soit  $(X_n)_{n \in \mathbb{N}}$  une suite de v.a.i.i.d. à variance finie. Soit  $Y_k = \bar{X}_k$  pour  $k \geq 1$ . Peut-on obtenir la loi faible des grands nombres pour la suite  $(Y_k)$ ? La loi forte des grands nombres? Un théorème de limite centrale? Traiter ensuite le cas particulier où les  $X_k$  suivent une loi normale centrée réduite.

## Feuille n° 2:

## Estimation et tests paramétriques

1. (\*) Soit  $(X_1, \dots, X_n)$  un échantillon de v.a.i.i.d. Déterminer l'estimateur par maximum de vraisemblance de  $\theta$  lorsque la loi de  $X_1$  est
  - (a) Une loi de Bernoulli de paramètre  $\theta$ .
  - (b) Une loi de Poisson de paramètre  $\theta$ .
  - (c) Une loi normale de paramètre  $(\theta, 1)$ .
  - (d) Une loi exponentielle de paramètre  $\theta$ .
  
2. (\*\*) Soit  $(X_1, \dots, X_n)$  un échantillon de v.a.i.i.d. gaussiennes de moyenne  $m$  et de variance  $\sigma^2 > 0$ . On note  $\theta = {}^t(m, \sigma^2)$ 
  - (a) Déterminer  $\hat{\theta} = {}^t(\hat{m}, \hat{\sigma}^2)$  l'estimateur de  $\theta$  par maximum de vraisemblance.
  - (b) En utilisant l'exercice 6 précédent, montrer que  $\hat{\theta}$  n'est pas un estimateur sans biais.
  - (c) On note  $\bar{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$ . Avec toujours l'exercice 6 précédent, montrer que le risque quadratique de  $\bar{\sigma}_n^2$  est inférieur à celui de  $\hat{\sigma}_n^2$ . Conclusion sur le fait d'être biaisé ou non?
  
3. (\*\*\*) Soit  $(X_1, \dots, X_n)$  un échantillon de v.a.i.i.d. de loi uniforme sur  $[0, 2\theta]$ , où  $\theta$  est inconnu.
  - (a) Déterminer  $\mathbb{E}[X_1]$ . En déduire que  $\tilde{\theta} = \bar{X}_n$  est un estimateur sans biais et convergent de  $\theta$ . Déterminer le risque quadratique de  $\tilde{\theta}$ .
  - (b) Déterminer  $\hat{\theta}$  l'estimateur par maximum de vraisemblance de  $\theta$ .
  - (c) Déterminer la densité de  $\hat{\theta}$ . En déduire le risque quadratique de  $\hat{\theta}$ . Comparer avec celui de  $\tilde{\theta}$  et conclusion.
  - (d) Déterminer un intervalle de confiance à 95% de  $\theta$  avec  $\tilde{\theta}$  et  $\hat{\theta}$ .
  
4. (\*\*\*)  $(X_1, \dots, X_n)$  un échantillon de v.a.i.i.d. de loi dont la densité rapport à la mesure de Lebesgue est:
 
$$f(x) = \mathbb{I}_{]0, \theta+1[}(x).$$
  - (a) Montrer que l'estimateur du maximum de vraisemblance pour ce modèle n'est pas unique.
  - (b) On pose  $\hat{\theta}_n^{(1)} = \max(X_1, \dots, X_n) - 1$  et  $\hat{\theta}_n^{(2)} = \min(X_1, \dots, X_n)$ . Pour chacun de ces estimateurs, déterminer la loi, l'espérance et la variance. Sont-ils indépendants? Convergents?

- (c) Déterminer un estimateur de la forme  $\widehat{\theta}_n = \alpha \widehat{\theta}_n^{(1)} + (1 - \alpha) \widehat{\theta}_n^{(2)}$ , avec  $\alpha \in ]0, 1[$ , qui soit sans biais. Cet estimateur a-t-il une variance inférieure à celle des précédents?
5. (\*) On a lancé 100 fois une pièce de monnaie et obtenu 58 fois pile. Avec un niveau  $\alpha = 0.05$ , tester si la pièce est équilibrée ? Déterminer la fonction puissance du test. Tester si la pièce est truquée. Aboutit-on au même résultat ?
6. (\*) Une chaîne des magasins décide d'adopter une nouvelle politique de gestion des stocks pour l'ensemble de ses succursales. Auparavant, le bénéfice mensuel d'une succursale était en moyenne égal à 300000 euros. Après la mise en place de la nouvelle politique pour 100 succursales "pilotes", on observe un bénéfice moyen de 320000 euros avec un écart-type empirique de 20000 euros. Peut-on conclure à l'efficacité de cette politique au niveau 5% ? 1% ?
7. (\*\*) Dans le cas d'un échantillon  $(X_1, \dots, X_n)$  de v.a.i.i.d. déterminer le test du rapport de vraisemblance de niveau 5% (statistique de test, région critique), pour les hypothèses:
- (a)  $H_0 : \theta = \theta_0$  contre  $H_1 : \theta = \theta_1 > \theta_0$ ;
  - (b)  $H_0 : \theta = \theta_0$  contre  $H_1 : \theta > \theta_0$ ;
  - (c)  $H_0 : \theta = \theta_0$  contre  $H_1 : \theta \neq \theta_0$ ;
  - (d)  $H_0 : \theta < \theta_0$  contre  $H_1 : \theta > \theta_1 > \theta_0$ ;
  - (e)  $H_0 : \theta \neq \theta_0$  contre  $H_1 : \theta = \theta_0$ ,
- où  $(\theta_0, \theta_1) \in \Theta^2$  sachant que la loi de  $X_1$  est
- (a) une loi de Bernoulli de paramètre  $\theta \in ]0, 1[$ ;
  - (b) une loi uniforme sur  $[0, \theta]$  avec  $\theta > 0$ ;
  - (c) une loi exponentielle de paramètre  $\theta > 0$ .