

Modélisation statistique (STA221)

Examen (3h)

Olivier Rioul

11 octobre 2024

Contrôle avec **notes de cours manuscrites, UNIQUEMENT.** Calculatrices autorisées.
On détaillera avec précision tous les raisonnements.
Rédiger lisiblement, **en faisant des phrases en langue humaine SVP.**
Le soin et la présentation comptent pour la note finale.

I Non existence d'un estimateur non biaisé

ON CONSIDÈRE le modèle statistique i.i.d. $\mathcal{B}(\frac{1}{\theta})$ Bernoulli de paramètre $1/\theta$, où $\theta > 1$, avec un N -échantillon $X = (X_1, X_2, \dots, X_N)$.

1. Justifier que c'est un modèle régulier et trouver la borne de Cramér-Rao pour un estimateur $\hat{\theta}$ non biaisé.
2. Démontrer que $S = X_1 + X_2 + \dots + X_N$ est une statistique suffisante. Quelle est sa loi?

Dorénavant on s'intéresse uniquement aux estimateurs fonctions de S , de la forme $\hat{\theta} = \hat{\theta}(S)$.

3. En utilisant la loi de S , trouver une expression du *biais* d'un estimateur quelconque $\hat{\theta} = \hat{\theta}(S)$ en fonction notamment de $\theta > 1$.
4. La borne de Cramér-Rao établie ci-dessus s'applique-t-elle à $\hat{\theta}$? Pourquoi?

II Non existence d'un estimateur MVU

ON SE DONNE un échantillon normal de deux mesures indépendantes seulement : $X = (X_1, X_2)$ avec $X_1 \sim \mathcal{N}(\theta, 1)$ pour tout $\theta \in \mathbb{R}$, et $X_2 \sim \mathcal{N}(\theta, 1)$ si $\theta > 0$, mais $X_2 \sim \mathcal{N}(\theta, 2)$ si $\theta \leq 0$.

1. Calculer l'information de Fisher en fonction de θ , en distinguant les cas $\theta > 0$ et $\theta \leq 0$.
2. Existe-t-il un estimateur efficace?
3. Calculer le biais et la variance des deux estimateurs $\hat{\theta}_1 = \frac{X_1 + X_2}{2}$ et $\hat{\theta}_2 = \frac{2X_1 + X_2}{3}$ et comparer à la borne de Cramér-Rao.
4. Montrer qu'un estimateur MVU serait nécessairement efficace. Conclure.

III Estimateurs inadmissibles

ON CONSIDÈRE l'estimateur de la moyenne \bar{X}_N qui estime la moyenne $\theta = \mathbb{E}(X_i)$ pour un N échantillon i.i.d. $X = (X_1, X_2, \dots, X_N)$ avec $N > 1$. On dit qu'un estimateur est uniformément meilleur qu'un autre si son risque quadratique est toujours plus faible (strictement pour au moins une valeur du paramètre). On dit qu'un estimateur est *inadmissible* s'il existe un estimateur uniformément meilleur, *admissible* dans le cas contraire.

1. Donner le biais et la variance de \bar{X}_N . En déduire que l'estimateur X_1 est *inadmissible*.

On suppose dorénavant un modèle gaussien i.i.d. $\mathcal{N}(\theta, \sigma^2)$ avec $\theta \in [0, 1]$.

2. Construire l'estimateur MAP noté $\hat{\theta}_N$, pour un a priori uniforme (de Laplace) sur $\theta \in [0, 1]$.
3. En déduire que \bar{X}_N est *inadmissible* pour ce modèle.
4. Montrer que l'estimateur constant $\hat{\theta} = 1/2$ est *admissible*. Commenter.

IV Règle de succession de Laplace

ON CONSIDÈRE le modèle bayésien i.i.d. $\mathcal{B}(\theta)$ Bernoulli de paramètre θ , dont on rappelle qu'une statistique suffisante est $S = X_1 + X_2 + \dots + X_N$, avec un a priori uniforme (de Laplace) pour $\theta \in [0, 1]$.

1. Trouver la loi de l'a posteriori, en fonction de S .
2. En déduire l'estimateur MMSE $\hat{\theta}(X)$ et le comparer au ML.
3. Démontrer que $\hat{\theta}(X) = \mathbb{P}(X_{N+1} = 1 | X_1 + X_2 + \dots + X_N = S)$.
4. Sachant que le soleil s'est levé tous les jours "depuis le début de la Terre" (soit 5000 ans selon Laplace, 1814), quelle la probabilité que le soleil se lève demain?

Solutions

I-1) Pour un échantillon, $p_\theta(x) = (1/\theta)^x(1-1/\theta)^{1-x}$ de support $\{0, 1\}$ et différentiable en θ . Le modèle est donc régulier. On a $\log p_\theta(x) = -x \log(\theta) + (1-x)(\log(\theta-1) - \log \theta)$, score $S_\theta(X) = -\frac{X}{\theta} + (1-X)(\frac{1}{\theta-1} - \frac{1}{\theta}) = -\frac{X}{\theta} + \frac{1-X}{\theta(\theta-1)}$, information de Fisher $J_{\theta,1} = \mathbf{V}(S_\theta(X)) = (\frac{1}{\theta} + \frac{1}{\theta(\theta-1)})^2 \frac{1}{\theta} (1 - \frac{1}{\theta}) = \frac{1}{\theta^2(\theta-1)}$, $J_\theta = \frac{N}{\theta^2(\theta-1)}$ car le modèle est i.i.d., d'où la CRB = $\frac{\theta^2(\theta-1)}{N}$.

N.B. : On peut aussi obtenir J_θ par reparamétrisation $\theta \rightarrow 1/\theta$ à partir de $J_\theta = \frac{N}{\theta(1-\theta)}$ pour le modèle i.i.d. $\mathcal{B}(\theta)$. On obtient alors $J_\theta = \frac{N}{(1/\theta)(1-1/\theta)} / g'(1/\theta)^2$ où $g(x) = 1/x$, soit $J_\theta = \frac{N}{(\theta^2/\theta)(1-1/\theta)} = \frac{N}{\theta^2(\theta-1)}$.

I-2) On vérifie la factorisation de Fisher : $p_\theta(x) = \prod_{i=1}^N (1/\theta)^{x_i} (1-1/\theta)^{1-x_i} = (\frac{1}{\theta-1})^s (1-1/\theta)^N$ où $s = \sum_{i=1}^N x_i$, d'où le résultat. Puisque $X \sim \mathcal{B}(\frac{1}{\theta})$ i.i.d., on sait que $S = X_1 + X_2 + \dots + X_N \sim \mathcal{B}(N, \frac{1}{\theta})$, loi binomiale.

I-3) $B(\hat{\theta}) = \mathbf{E}(\hat{\theta}(S)) - \theta = \sum_{s=0}^N \hat{\theta}(s) \binom{N}{s} (\frac{1}{\theta})^s (1 - \frac{1}{\theta})^{N-s} - \theta$.

I-4) Si l'estimateur $\hat{\theta} = \hat{\theta}(S)$ est non biaisé (pour tout $\theta > 1$), on obtient l'identité suivante : $\sum_{s=0}^N \hat{\theta}(s) \binom{N}{s} (\frac{1}{\theta})^s (1 - \frac{1}{\theta})^{N-s} = \theta$ de la forme $P(1/\theta) = \theta$ où P est un polynôme de degré N ; identité qui doit être satisfaite pour tout $\theta > 1$ pour que la borne de Cramér-Rao ci-dessus s'applique sur la variance de $\hat{\theta}$. Mais ceci est impossible, car on aurait $P(x) = 1/x$ fraction rationnelle et non polynôme. Donc la borne de Cramér-Rao établie ci-dessus ne s'applique pas, puisqu'il n'existe pas d'estimateur $\hat{\theta} = \hat{\theta}(S)$ non biaisé pour tout $\theta > 1$.

II-1) Pour $\theta > 0$, on trouve comme dans le cas normal classique vu en cours, $J_\theta = N/\sigma^2 = 2/1 = 2$. Pour $\theta \leq 0$, on a $p_\theta(x) = \frac{1}{2\sqrt{2\pi}} \exp -[\frac{(x_1-\theta)^2}{2} + \frac{(x_2-\theta)^2}{4}]$, d'où $S_\theta(X) = (X_1 - \theta) + \frac{X_2 - \theta}{2}$ et $J_\theta = \mathbf{V}(S_\theta(X)) = 1 + \frac{2}{4} = \frac{3}{2}$.

II-2) S'il existe, l'estimateur efficace aurait donc pour expression $\theta(X) = \theta + \frac{S_\theta(X)}{J_\theta}$ qui vaut $\frac{X_1+X_2}{2}$ si $\theta > 0$, et $\frac{2X_1+X_2}{3}$ si $\theta \leq 0$. Mais cette expression dépend de la valeur de θ , donc l'estimateur efficace n'existe pas.

II-3) Ces deux estimateurs sont non biaisés, de variance $\mathbf{V}(\hat{\theta}_1) = 1/2$, $\mathbf{V}(\hat{\theta}_2) = 10/18 > 1/2$ pour $\theta > 0$, et $\mathbf{V}(\hat{\theta}_1) = 3/4 > 2/3$, $\mathbf{V}(\hat{\theta}_2) = 2/3$ pour $\theta \leq 0$. Ainsi $\hat{\theta}_1$ atteint la CRB pour $\theta > 0$ (mais pas pour $\theta \leq 0$), et $\hat{\theta}_2$ atteint la CRB pour $\theta \leq 0$ (mais pas pour $\theta > 0$).

II-4) Puisque la CRB est atteinte à la fois pour $\theta > 0$ et pour $\theta \leq 0$, un estimateur MVU atteindrait nécessairement la CRB pour tout θ puisqu'il serait au moins aussi bon que $\hat{\theta}_1$ et $\hat{\theta}_2$. Il serait donc efficace, ce qui est impossible comme on l'a vu.

III-1) \bar{X}_N est non biaisé de variance $\frac{\sigma^2}{N}$ où σ^2 est la variance d'un échantillon. De même $X_2 = \bar{X}_1$ est non biaisé de variance $\frac{\sigma^2}{1} = \sigma^2 > \frac{\sigma^2}{N}$ car $N > 1$, il est donc inadmissible puisque \bar{X}_N est uniformément meilleur.

III-2) $\theta = \hat{\theta}_N$ maximise $p(x|\theta)1_{[0,1]}(\theta)$, donc minimise $\sum_1^N |X_i - \theta|^2 1_{[0,1]}(\theta)$, c'est donc $\hat{\theta}_N = \bar{X}_N$ si $0 < \theta < 1$, $\hat{\theta}_N = 1$ si $\bar{X}_N > 1$ et $\hat{\theta}_N = 0$ si $\bar{X}_N \leq 0$. Autrement dit $\hat{\theta}_N = \bar{X}_N 1_{[0,1]}(\bar{X}_N)$.

III-3) On voit facilement que $|\theta - \hat{\theta}_N| \leq |\theta - \bar{X}_N|$ avec inégalité stricte si $\bar{X}_N \leq 0$ ou $\bar{X}_N \geq 1$, d'où $\hat{\theta}_N$ est uniformément meilleur que \bar{X}_N (pour le MSE).

III-4) Si un certain estimateur $\hat{\theta}'$ était meilleur, on aurait $\mathbf{E}((1/2 - \theta)^2) \geq \mathbf{E}((\hat{\theta}' - \theta)^2)$ pour tout $\theta \in [0, 1]$, d'où en faisant $\theta = 1/2$ il vient $\hat{\theta}' = \hat{\theta} = 1/2$. Il n'existe donc aucun estimateur uniformément meilleur (strictement meilleur pour au moins une valeur du paramètre). L'estimateur constant $\hat{\theta} = 1/2$ est donc admissible.

Commentaire : $\hat{\theta} = 1/2$, bien que très mauvais, est admissible, alors que l'estimateur efficace (MVU) \bar{X}_N est inadmissible. Cela relativise donc l'utilité de la notion d'"estimateur admissible".

IV-1) On a $p(X|\theta) = \prod_1^N (\theta)^{X_i} (1-\theta)^{1-X_i} = \theta^S (1-\theta)^{N-S}$, puis $p(\theta|X) \propto (X|\theta)p(\theta) = \theta^S (1-\theta)^{N-S}$, c'est une loi Bêta $B(S+1, N-S+1)$.

IV-2) La moyenne d'une loi $B(\alpha, \beta)$ est $\frac{\alpha}{\alpha+\beta}$, d'où $\hat{\theta}(X) = \frac{S+1}{N+2}$. L'estimateur ML est $\bar{X}_N = \frac{S}{N}$.

IV-3) $\mathbb{P}(X_{N+1} = 1 | X_1 + X_2 + \dots + X_N = S) = \mathbf{E}(X_{N+1} | X_1 + X_2 + \dots + X_N = S) = \mathbf{E}\mathbf{E}(X_{N+1} | \theta, S)$ où sachant θ , X_{N+1} est indépendant de S et suit la loi $\mathcal{B}(\theta)$ de moyenne θ , d'où $\mathbb{P}(X_{N+1} = 1 | X_1 + X_2 + \dots + X_N = S) = \mathbf{E}(\theta | S) = \hat{\theta}(X) = \frac{S+1}{N+2}$.

IV-4) Ici $X_i = 1$ signifie que le soleil se lève le i ème jour. Sachant que $S = N = 5000 \times 365 \approx 1825000$, la probabilité en question est $= \frac{N+1}{N+2} = \frac{1825001}{1825002} = 0,999999452\dots$