

Examen

Rappels :

- Il sera tenu compte du soin apporté à la présentation et à la rédaction. Si vous n'arrivez pas à démontrer un résultat, vous pouvez l'admettre pour la suite de l'exercice.
- Si X_1 et X_2 sont deux vecteurs gaussiens indépendants et de même dimension, avec $X_1 \sim \mathcal{N}(m_1, \Sigma_1)$ et $X_2 \sim \mathcal{N}(m_2, \Sigma_2)$, alors $Y = X_1 + X_2$ est aussi un vecteur gaussien et $Y \sim \mathcal{N}(m_1 + m_2, \Sigma_1 + \Sigma_2)$.
- On rappelle que la loi $\mathcal{E}(\lambda)$ correspond à la loi $\Gamma(1, \lambda)$.

Exercice 1 (6 points)

Soit $\theta > 0$ un paramètre inconnu et X de densité

$$f_\theta(x) = \frac{1}{\theta}(1-x)^{\frac{1}{\theta}-1} \mathbf{1}_{]0,1[}(x).$$

Dans la suite, on suppose disposer d'un échantillon (X_1, \dots, X_n) i.i.d. de même loi que X .

1. Calculer la fonction de répartition F_θ de X . En déduire la médiane de la loi de X .
2. En déduire un estimateur $\hat{\theta}_n$ de θ . Etablir sa normalité asymptotique.
3. Donner un intervalle de confiance de niveau asymptotique $(1 - \alpha)$ pour θ .
4. Déterminer l'estimateur du maximum de vraisemblance $\tilde{\theta}_n$ de θ .
5. Montrer que $T = -\log(1 - X)$ suit une loi exponentielle dont on précisera le paramètre.
6. D'un point de vue asymptotique, entre $\hat{\theta}_n$ et $\tilde{\theta}_n$, quel estimateur choisissez-vous ?
7. Montrer que $\tilde{\theta}_n/\theta$ suit une loi Gamma $\Gamma(r, \lambda)$ dont on précisera les paramètres r et λ (qui ne dépendent pas de θ). En déduire un test de niveau (non asymptotique) α pour décider entre $H_0 : \theta \leq 1$ et $H_1 : \theta > 1$.

Exercice 2 (4 points)

On suppose disposer de deux ensembles T_1, \dots, T_ℓ et U_1, \dots, U_m de variables aléatoires réelles. On note $T = [T_1, \dots, T_\ell]' \in \mathbb{R}^\ell$ et $U = [U_1, \dots, U_m]' \in \mathbb{R}^m$ les vecteurs correspondants. On suppose que les vecteurs T et U sont observés et donnés par

$$T = V\beta + \sigma\eta \quad \text{et} \quad U = W\gamma + \tau\varepsilon$$

où $\beta, \gamma \in \mathbb{R}^p$ sont inconnus, V et W sont des matrices connues de tailles $\ell \times p$ et $m \times p$ et de rang p (avec $\ell > p$ et $m > p$), σ et τ sont des réels positifs inconnus, et η, ε sont deux vecteurs gaussiens standards indépendants non observés et de dimensions respectives ℓ et m . On désigne par $\hat{\beta}, \hat{\gamma}, \hat{\sigma}^2$ et $\hat{\tau}^2$ les estimateurs usuels des moindres carrés de β, γ, σ^2 et τ^2 respectivement.

1. Rappeler la loi de $(\ell - p)\hat{\sigma}^2/\sigma^2$ ainsi que son espérance et sa variance. Quelle est la loi de $(\tau^2\hat{\sigma}^2)/(\sigma^2\hat{\tau}^2)$?
2. On veut tester $\tau = \sigma$ contre l'alternative $\tau \neq \sigma$. Proposer un test de niveau α .
3. Quelle est la loi de la variable $(\ell - p)\frac{\hat{\sigma}^2}{\sigma^2} + (m - p)\frac{\hat{\tau}^2}{\tau^2}$?
4. Jusqu'à la fin de l'exercice, on suppose que $\tau = \sigma$. Dédurre de la question précédente un estimateur sans biais $\tilde{\sigma}^2$ de σ^2 . Préciser sa variance. Comment se compare-t-il à $\hat{\sigma}^2$ en terme de risque quadratique ?
5. Quelle est la loi du vecteur $\hat{\beta} - \hat{\gamma}$?
6. Soit $X \sim \mathcal{N}(m, \Gamma)$ un vecteur gaussien en dimension d , avec Γ inversible. Rappeler (sans le justifier) la loi de la variable $(X - m)' \Gamma^{-1} (X - m)$.
7. Construire un test de niveau α de l'hypothèse $\beta = \gamma$ contre l'alternative $\beta \neq \gamma$.

Exercice 3 (7 points)

Soient $\delta, r > 0$. La loi de Pareto $\mathcal{P}(\delta, r)$ est la loi de densité par rapport à la mesure de Lebesgue sur \mathbb{R}

$$x \mapsto \delta r^\delta x^{-\delta-1} \mathbf{1}_{[r, +\infty[}(x).$$

On considère le cadre bayésien suivant:

$$\begin{aligned} \boldsymbol{\theta} &\sim \Pi = \mathcal{P}(\delta, r) \\ \mathbf{X} = (X_1, \dots, X_n) &| \boldsymbol{\theta} \sim P_{\boldsymbol{\theta}}^{\otimes n} = \text{Unif}[0, \boldsymbol{\theta}]^{\otimes n}. \end{aligned}$$

1. Représenter la densité de la loi $\mathcal{P}(\delta, r)$ et donner sa fonction de répartition.
2. Montrer que la loi a posteriori de $\boldsymbol{\theta}$ sachant \mathbf{X} est une loi de Pareto $\mathcal{P}(\delta_{\mathbf{X}}, r_{\mathbf{X}})$ pour deux paramètres $\delta_{\mathbf{X}}, r_{\mathbf{X}}$ que l'on déterminera.
3. Donner une région de crédibilité de plus haute densité a posteriori de niveau $1 - \alpha$, pour $\alpha \in]0, 1[$.
4. Dans cette question, on s'intéresse à la consistance de la loi a posteriori.
 - (a) Montrer que si $0 < \theta_0 < r$, alors la loi a posteriori n'est pas consistante en θ_0 .

On suppose maintenant que $\theta_0 \geq r$ et on rappelle que $\mathbf{X} | \boldsymbol{\theta} = \theta_0 \sim P_{\theta_0}^{\otimes n}$.

- (b) Montrer que pour tout $\varepsilon > 0$, P_{θ_0} -presque sûrement,

$$\mathbb{P}(|\boldsymbol{\theta} - \theta_0| > \varepsilon | \mathbf{X}) = \begin{cases} \left(\frac{r_{\mathbf{X}}}{\theta_0 + \varepsilon}\right)^{\delta+n} & \text{si } r_{\mathbf{X}} > \theta_0 - \varepsilon, \\ \left(\frac{r_{\mathbf{X}}}{\theta_0 + \varepsilon}\right)^{\delta+n} + 1 - \left(\frac{r_{\mathbf{X}}}{\theta_0 - \varepsilon}\right)^{\delta+n} & \text{si } r_{\mathbf{X}} \leq \theta_0 - \varepsilon. \end{cases}$$

- (c) En déduire que pour tout $\varepsilon > 0$, P_{θ_0} -presque sûrement,

$$\mathbb{P}(|\boldsymbol{\theta} - \theta_0| > \varepsilon | \mathbf{X}) \leq \mathbf{1}_{\{X_{(n)} \leq \theta_0 - \varepsilon\}} + \left(\frac{\theta_0}{\theta_0 + \varepsilon}\right)^{\delta+n},$$

où $X_{(n)} = \max\{X_1, \dots, X_n\}$.

Soit $(M_n)_{n \geq 1}$ une suite de réels positifs qui tend vers $+\infty$ quand $n \rightarrow +\infty$.

(d) Montrer que

$$\mathbb{P}_{\theta_0} \left(X_{(n)} \leq \theta_0 - \frac{M_n}{n} \right) \xrightarrow[n \rightarrow \infty]{} 0.$$

On pourra utiliser l'inégalité: $\forall u \in [0, 1], (1 - u)^n \leq e^{-un}$.

(e) Montrer que

$$\left(\frac{\theta_0}{\theta_0 + \frac{M_n}{n}} \right)^{\delta+n} \xrightarrow[n \rightarrow \infty]{} 0.$$

(f) En déduire que, sous $P_{\theta_0}^{\otimes n}$, on a

$$\mathbb{P} \left(|\theta - \theta_0| > \frac{M_n}{n} \mid \mathbf{X} \right) \xrightarrow[n \rightarrow \infty]{\mathbb{P}} 0.$$

Exercice 4 (3 points)

Expliquer en termes mathématiques précis ce que fait chacune des parties de l'illustration numérique suivante.

Partie 1

```
[2]: a, b = 2, 3
      n = 30

      prior = stats.gamma(a=a, scale=1/b)
      theta0 = prior.rvs()
      ptheta0 = stats.norm(loc=theta0)
      X = ptheta0.rvs(size=n)
```

Partie 2

```
[3]: def likelihood(theta):
      return stats.norm(loc=theta).pdf(X).prod()

      est_emv = X.mean()

      N = 1000
      thetas = prior.rvs(size=N)
      likelihoods = np.array([likelihood(theta) for theta in thetas])
      est_mc = (thetas*likelihoods).sum() / likelihoods.sum()

      print(est_emv)
      print(est_mc)
```

```
0.1743723482282432
0.27901366347949874
```

Partie 3

```
[4]: M = 2000
      thetas = prior.rvs(size=M)
      likelihoods = np.array([likelihood(theta) for theta in thetas])
      print(((thetas-est_emv)**2 * likelihoods).sum() / likelihoods.sum())
      print(((thetas-est_mc)**2 * likelihoods).sum() / likelihoods.sum())
```

0.025305233550915397

0.017664889523622763

Partie 4

```
[5]: unif = stats.uniform()

      m = 5000
      l = 2*m

      sample = []
      while len(sample) < m:
          candidates = prior.rvs(size=l)
          thresholds = unif.rvs(size=l)
          crit = np.exp(-n/2 * (est_emv - candidates)**2)
          sample += list(candidates[crit > thresholds])
      sample = sample[:m]

      est_abs = np.quantile(sample, q=0.5, interpolation='lower')

      print((np.abs(thetas-est_emv) * likelihoods).sum() / likelihoods.
            →sum())
      print((np.abs(thetas-est_mc) * likelihoods).sum() / likelihoods.sum())
      print((np.abs(thetas-est_abs) * likelihoods).sum() / likelihoods.
            →sum())
```

0.12283677437841431

0.10911696680300526

0.1066337249029515