

---

EXAMEN STATISTIQUE 1MF2E

Lundi 23 mars 2026

Partiel sans document (Une feuille A4 recto-verso autorisée)

---

**Exercice 1 : Estimation (12 points)**

On considère  $n$  observations  $x_1, \dots, x_n$  issues d'un vecteur de  $n$  variables aléatoires  $X_i$  indépendantes de lois de Rademacher de paramètre  $\theta$ , c'est-à-dire, telles que

$$P[X_i = x_i; \theta] = \theta^{\frac{1+x_i}{2}} (1-\theta)^{\frac{1-x_i}{2}}, \quad x_i \in \{-1, 1\},$$

avec  $\theta > 0$  un paramètre inconnu.

1. (2pts) Montrer que l'estimateur du maximum de vraisemblance du paramètre  $\theta$  noté  $\hat{\theta}_{MV}$  est :

$$\hat{\theta}_{MV} = \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n X_i.$$

On effectue les traitements habituels

- Calcul de la vraisemblance.

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n P[X_i = x_i; \theta] = \theta^{\frac{1}{2}(n + \sum_{i=1}^n x_i)} (1-\theta)^{\frac{1}{2}(n - \sum_{i=1}^n x_i)}$$

- Calcul de la log vraisemblance

$$\ln L(x_1, \dots, x_n; \theta) = \frac{1}{2} \left( n + \sum_{i=1}^n x_i \right) \ln(\theta) + \frac{1}{2} \left( n - \sum_{i=1}^n x_i \right) \ln(1-\theta)$$

- Calcul de la dérivée de la log-vraisemblance et de l'estimateur

$$\frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta} = \frac{1}{2} \left( n + \sum_{i=1}^n x_i \right) \frac{1}{\theta} - \frac{1}{2} \left( n - \sum_{i=1}^n x_i \right) \frac{1}{1-\theta}$$

qui s'annule pour

$$(1-\theta) \left( n + \sum_{i=1}^n x_i \right) - \theta \left( n - \sum_{i=1}^n x_i \right) = 0 \Leftrightarrow \theta = \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n x_i.$$

On en déduit que l'estimateur du maximum de vraisemblance du paramètre  $\theta$  noté  $\hat{\theta}_{MV}$  est :

$$\hat{\theta}_{MV} = \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n X_i.$$

2. (2pts) Montrer que si  $X_i$  suit une loi de Rademacher, alors  $Y_i = \frac{X_i+1}{2}$  suit une loi de Bernoulli. En déduire la moyenne et la variance de  $X_i$  notées  $E[X_i]$  et  $\text{var}[X_i]$  en fonction de  $\theta$ . Comme  $x_i \in \{-1, 1\}$ , la variable  $Y_i$  prend ses valeurs dans  $\{0, 1\}$ . De plus

$$P[Y_i] = 0 = P[X_i = -1] = 1 - \theta \text{ et } P[Y_i] = 1 = P[X_i = 1] = \theta$$

Donc  $Y_i$  suit une loi de Bernoulli de paramètre  $\theta$ . Cette loi est de moyenne  $E[Y_i] = \theta$  et de variance  $\text{var}[Y_i] = \theta(1 - \theta)$ . Comme  $X_i = 2Y_i - 1$ , on en déduit

$$E[X_i] = 2\theta - 1 \text{ et } \text{var}[X_i] = 4\text{var}[Y_i] = 4\theta(1 - \theta).$$

3. (2pts) L'estimateur  $\hat{\theta}_{\text{MV}}$  est-il sans biais et convergent ?

D'après la question précédente, la moyenne de l'estimateur  $\hat{\theta}_{\text{MV}}$  est :

$$E[\hat{\theta}_{\text{MV}}] = \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n E[X_i] = \frac{1}{2} + \frac{1}{2}(2\theta - 1) = \theta.$$

L'estimateur  $\hat{\theta}_{\text{MV}}$  est donc un estimateur non biaisé de  $\theta$ . De plus, en utilisant l'indépendance des variables  $X_i$ , on a

$$\text{var}[\hat{\theta}_{\text{MV}}] = \frac{1}{4n^2} \sum_{i=1}^n \text{var}[X_i] = \frac{\theta(1 - \theta)}{n}.$$

Comme  $\hat{\theta}_{\text{MV}}$  est un estimateur non biaisé de  $\theta$  et que sa variance tend vers 0 lorsque  $n \rightarrow \infty$ ,  $\hat{\theta}_{\text{MV}}$  est un estimateur convergent de  $\theta$ .

4. (1pt) Déterminer la borne de Cramér-Rao pour un estimateur non biaisé du paramètre  $\theta$ . L'estimateur  $\hat{\theta}_{\text{MV}}$  est-il l'estimateur efficace du paramètre  $\theta$  ?

La dérivée seconde de la log-vraisemblance est

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2} = -\frac{1}{2\theta^2} \left( n + \sum_{i=1}^n x_i \right) - \frac{1}{2(1 - \theta)^2} \left( n - \sum_{i=1}^n x_i \right)$$

Comme  $E[X_i] + 1 = 2\theta$  et  $1 - E[X_i] = 2(1 - \theta)$ , on a

$$E \left[ -\frac{\partial^2 \ln L(X_1, \dots, X_n; \theta)}{\partial \theta^2} \right] = \frac{1}{2\theta^2} \times (2n\theta) + \frac{1}{2(1 - \theta)^2} \times [2n(1 - \theta)] = \frac{n}{\theta(1 - \theta)}.$$

On en déduit que la borne de Cramér-Rao pour un estimateur non biaisé du paramètre  $\theta$  est

$$BCR = \frac{\theta(1 - \theta)}{n}.$$

Comme  $\text{var}[\hat{\theta}_{\text{MV}}] = BCR$  et que l'estimateur  $\hat{\theta}_{\text{MV}}$  est non biaisé,  $\hat{\theta}_{\text{MV}}$  est l'estimateur efficace du paramètre  $\theta$ .

5. (1pt) Montrer que l'estimateur des moments de  $\theta$  construit à partir de  $E[X_i]$  est égal à l'estimateur du maximum de vraisemblance  $\hat{\theta}_{\text{MV}}$ .

D'après ce qui précède, on a :

$$E[Y_i] = \frac{1}{2} + \frac{1}{2}E[X_i] = \theta.$$

On en déduit que l'estimateur des moments de  $\theta$  construit à partir de  $E[X_i]$  est :

$$\hat{\theta}_{\text{Mo}} = \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n X_i = \hat{\theta}_{\text{MV}}.$$

6. (5pts) On suppose désormais que le paramètre  $\theta$  est muni d'une loi a priori de densité

$$f(\theta) = \begin{cases} 6\theta(1-\theta) & \text{si } \theta \in ]0, 1[ \\ 0 & \text{sinon} \end{cases}$$

- (1pt) Représenter cette densité a priori et expliquer l'information apportée par cette densité. La courbe associée à  $f(\theta) = 6\theta(1-\theta)$  est une parabole égale à 0 en  $\theta = 0$  et en  $\theta = 1$  et qui atteint son maximum en  $\theta = \frac{1}{2}$ . Cette information a priori implique que les valeurs proches de  $\frac{1}{2}$  sont a priori très probables alors que celles proches de 0 ou 1 sont très improbables a priori.
- (2pts) Déterminer l'estimateur du maximum a posteriori du paramètre  $\theta$  noté  $\hat{\theta}_{\text{MAP}}$  et montrer qu'il s'écrit

$$\hat{\theta}_{\text{MAP}} = \alpha_n \left( \frac{1}{2} \right) + (1 - \alpha_n) \hat{\theta}_{\text{MV}}.$$

où  $\alpha_n \in ]0, 1[$  est à déterminer. Déterminer les limites de  $\alpha_n$  lorsque  $n$  tend vers 0 et vers  $+\infty$  et interpréter le résultat.

La loi a posteriori du paramètre  $\theta$  vérifie

$$\begin{aligned} f(\theta|x_1, \dots, x_n) &\propto f(x_1, \dots, x_n|\theta)f(\theta) \\ &\propto \theta^{1+\frac{1}{2}(n+\sum_{i=1}^n x_i)}(1-\theta)^{1+\frac{1}{2}(n-\sum_{i=1}^n x_i)}\mathcal{I}_{]0,1[}(\theta). \end{aligned}$$

où  $\propto$  signifie "proportionnel à". L'estimateur du maximum a posteriori du paramètre  $\theta$  s'obtient par maximisation du logarithme de cette loi a posteriori. La logarithme de la loi a posteriori est

$$\left[ 1 + \frac{1}{2} \left( n + \sum_{i=1}^n x_i \right) \right] \ln(\theta) + \left[ 1 + \frac{1}{2} \left( n - \sum_{i=1}^n x_i \right) \right] \ln(1 - \theta),$$

qui admet pour dérivée

$$\left[ 1 + \frac{1}{2} \left( n + \sum_{i=1}^n x_i \right) \right] \frac{1}{\theta} + \left[ 1 - \frac{1}{2} \left( n - \sum_{i=1}^n x_i \right) \right] \frac{1}{1-\theta},$$

qui s'annule pour

$$\theta = \frac{2}{2+n} \left( \frac{1}{2} \right) + \frac{n}{n+2} \left[ \frac{1}{2} + \frac{1}{2n} \sum_{i=1}^n x_i \right]$$

Donc

$$\hat{\theta}_{\text{MAP}} = \frac{2}{2+n} \left( \frac{1}{2} \right) + \frac{n}{n+2} \hat{\theta}_{\text{MV}},$$

ce qui est le résultat attendu si on pose  $\alpha_n = \frac{2}{2+n}$ . Quand  $n$  tend vers  $+\infty$ ,  $\alpha_n$  tend vers 0, ce qui signifie qu'on oublie l'info a priori " $\theta$  est proche de  $\frac{1}{2}$ ". Par contre, quand  $n$  tend vers 0,  $\alpha_n$  tend vers 1, ce qui signifie qu'on fait confiance à l'info a priori et qu'on oublie l'information contenue dans les données.

- (2pts) Montrer que la loi de  $\theta|X_1, \dots, X_n$  est une loi beta dont on déterminera les paramètres. En déduire l'estimateur MMSE de  $\theta$  noté  $\hat{\theta}_{\text{MMSE}}$ . D'après ce qui précède

$$f(\theta|x_1, \dots, x_n) \propto \theta^{1+\frac{1}{2}(n+\sum_{i=1}^n x_i)}(1-\theta)^{1+\frac{1}{2}(n-\sum_{i=1}^n x_i)}\mathcal{I}_{]0,1[}(\theta). \quad (1)$$

D'après les tables de loi, on observe que

$$\theta|x_1, \dots, x_n \sim B \left( 2 + \frac{1}{2} \left( n + \sum_{i=1}^n x_i \right), 2 + \frac{1}{2} \left( n - \sum_{i=1}^n x_i \right) \right).$$

Donc

$$\hat{\theta}_{\text{MMSE}} = E[\theta | X_1, \dots, X_n] = \frac{2 + \frac{1}{2}(n + \sum_{i=1}^n X_i)}{2 + \frac{1}{2}(n + \sum_{i=1}^n X_i) + 2 + \frac{1}{2}(n - \sum_{i=1}^n X_i)},$$

soit

$$\hat{\theta}_{\text{MMSE}} = E[\theta | X_1, \dots, X_n] = \frac{2 + \frac{1}{2}(n + \sum_{i=1}^n X_i)}{4 + n}.$$

### Exercice 2 : Tests Statistiques (8 points)

On considère  $n$  observations  $x_1, \dots, x_n$  issues d'un vecteur de  $n$  variables aléatoires  $X_k$  indépendantes de lois de Poisson de paramètre  $k\lambda$ , c'est-à-dire, telles que

$$P[X_k = x_k; \lambda] = \frac{(k\lambda)^{x_k}}{x_k!} e^{-k\lambda}, \quad x_k \in \mathbb{N},$$

avec  $\lambda > 0$ . On notera que le paramètre de la loi de Poisson pour la variable aléatoire  $X_k$  dépend de l'indice  $k$ . On désire utiliser les observations  $x_1, \dots, x_n$  pour déterminer si  $\lambda = \lambda_0 > 0$  ou si  $\lambda = \lambda_1 > 0$  avec  $\lambda_1 < \lambda_0$ . On considère donc le test d'hypothèses

$$H_0 : \lambda = \lambda_0, \quad H_1 : \lambda = \lambda_1 \quad \text{avec } \lambda_0 > \lambda_1 > 0.$$

- (2pts) Montrer que la statistique du test de Neyman Pearson est  $T_n = \sum_{k=1}^n X_k$  et déterminer la région critique associée (le seuil associé à cette région sera noté  $S_\alpha$ ).

Le test de Neyman Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_{1,\alpha}$$

où  $S_{1,\alpha}$  est un seuil dépendant du risque de première espèce  $\alpha$ . Mais

$$\begin{aligned} \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} > S_{1,\alpha} &\Leftrightarrow \ln \left[ \frac{L(x_1, \dots, x_n; \theta_1)}{L(x_1, \dots, x_n; \theta_0)} \right] > S_{2,\alpha} \\ &\Leftrightarrow \ln \left[ \frac{\prod_{k=1}^n \frac{(k\lambda_1)^{x_k}}{x_k!} e^{-k\lambda_1}}{\prod_{k=1}^n \frac{(k\lambda_0)^{x_k}}{x_k!} e^{-k\lambda_0}} \right] > S_{2,\alpha} \\ &\Leftrightarrow [\ln(\lambda_1) - \ln(\lambda_0)] \sum_{k=1}^n x_k > S_{3,\alpha}. \end{aligned}$$

Comme  $\lambda_1 < \lambda_0$ , on rejette  $H_0$  si

$$T_n = \sum_{k=1}^n X_k < S_\alpha.$$

La région critique du test est donc l'ensemble des vecteurs  $(x_1, \dots, x_n) \in \mathbb{N}^n$  tels que  $T_n < S_\alpha$  et la statistique de test est  $T_n = \sum_{i=1}^n X_i$ .

- (1pt) Montrer que  $T_n$  suit une loi de Poisson dont on exprimera le paramètre noté  $\theta_n$  en fonction de  $n$  et  $\lambda$ . Dans la suite de cet exercice, on suppose qu'on peut approcher cette loi de Poisson par une loi normale  $\mathcal{N}(\theta_n, \theta_n)$ .

La fonction caractéristique de  $T_n$  vérifie :

$$E[e^{iuT_n}] = E\left[e^{iu \sum_{k=1}^n X_k}\right] = E\left[\prod_{k=1}^n e^{iuX_k}\right].$$

En utilisant le fait que les variables aléatoires  $X_1, \dots, X_n$  sont indépendantes et la fonction caractéristique d'une loi de Poisson donnée dans les tables, on obtient

$$E [e^{iuT_n}] = \prod_{k=1}^n E [e^{iuX_k}] = \prod_{k=1}^n \exp [\lambda k (e^{it} - 1)] = \exp \left[ \lambda \left( \sum_{k=1}^n k \right) (e^{it} - 1) \right],$$

soit

$$E [e^{iuT_n}] = \exp \left[ \frac{n(n+1)}{2} \lambda (e^{it} - 1) \right],$$

qui est la fonction caractéristique d'une loi de Poisson de paramètre  $\theta_n = \frac{n(n+1)}{2} \lambda$ . On en déduit  $T_n \sim \mathcal{P}(\theta_n)$ .

3. (2pts) On note  $F$  la fonction de répartition d'une loi du normale  $\mathcal{N}(0, 1)$ . En utilisant la loi normale trouvée à la question précédente, exprimer le risque de première espèce  $\alpha$  en fonction du seuil du test de Neyman Pearson noté  $S_\alpha$ , de la fonction  $F$ , et de  $n$  et  $\lambda_0$ . En déduire la valeur du seuil  $S_\alpha$  en fonction de  $F^{-1}(\alpha)$ ,  $n$  et  $\lambda_0$ .

Le risque  $\alpha$  est défini par

$$\alpha = P[\text{Rejeter } H_0 | H_0 \text{ vraie}] = P \left[ T_n < S_\alpha | T_n \sim \mathcal{N} \left( \frac{n(n+1)}{2} \lambda_0, \frac{n(n+1)}{2} \lambda_0 \right) \right],$$

soit

$$\alpha = F \left[ \frac{S_\alpha - \frac{n(n+1)}{2} \lambda_0}{\sqrt{\frac{n(n+1)}{2} \lambda_0}} \right],$$

d'où

$$S_\alpha = \frac{n(n+1)}{2} \lambda_0 + F^{-1}(\alpha) \sqrt{\frac{n(n+1)}{2} \lambda_0}.$$

4. (3pts) Déterminer les caractéristiques opérationnelles du récepteur (courbes COR) pour ce test et montrer qu'elles ne dépendent que de  $\frac{n(n+1)}{2}$ ,  $F^{-1}(\alpha)$ ,  $\lambda_0$  et  $\lambda_1$ . Les performances du test seront-elles meilleures pour  $(\lambda_0, \lambda_1) = (10, 1)$  ou pour  $(\lambda_0, \lambda_1) = (1000, 100)$  ?

La puissance du test est définie par

$$\pi = P[\text{Rejeter } H_0 | H_1 \text{ vraie}] = F \left[ \frac{S_\alpha - \frac{n(n+1)}{2} \lambda_1}{\sqrt{\frac{n(n+1)}{2} \lambda_1}} \right].$$

En remplaçant l'expression du seuil  $S_\alpha$  déterminée précédemment, on obtient

$$\pi = F \left[ F^{-1}(\alpha) \sqrt{\frac{\lambda_0}{\lambda_1}} + \sqrt{\frac{n(n+1)}{2} \frac{\lambda_0 - \lambda_1}{\lambda_1}} \right].$$

L'allure des courbes COR pour différentes valeurs de  $n$  est représentée ci-dessous :

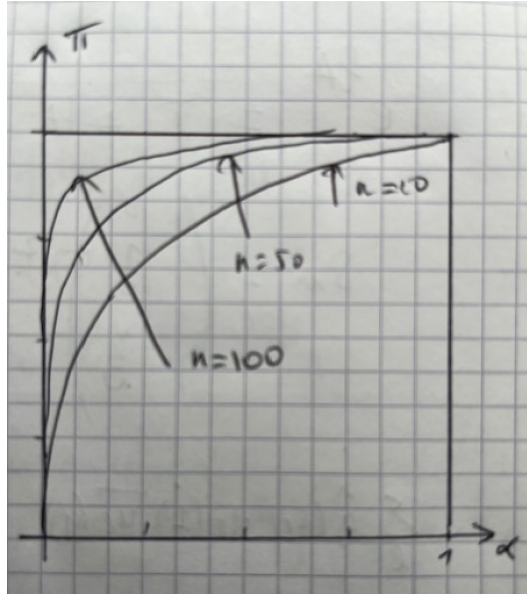


Figure 1: Allure des courbes COR pour différentes valeurs de  $n$ .

Pour les deux couples  $(\lambda_0, \lambda_1) = (10, 1)$  et  $(\lambda_0, \lambda_1) = (1000, 100)$ , on a  $\frac{\lambda_0}{\lambda_1} = 10$ . Comme  $F$  est une fonction croissante (c'est une fonction de répartition), les performances du test sont donc d'autant meilleures que  $\frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}}$  est grand. Pour le premier couple  $(\lambda_0, \lambda_1) = (10, 1)$ , on a

$$\frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}} = \frac{9}{1} = 9$$

tandis que pour  $(\lambda_0, \lambda_1) = (1000, 100)$ , on a

$$\frac{\lambda_0 - \lambda_1}{\sqrt{\lambda_1}} = \frac{900}{10} = 90.$$

Les performances du test seront donc meilleures pour  $(\lambda_0, \lambda_1) = (1000, 100)$ .

## LOIS DE PROBABILITÉ DISCRÈTES

$$p_k = P[X = k] \quad p_{1,\dots,m} = P[X_1 = k_1, \dots, X_m = k_m]$$

LOI	Probabilités	Moyenne	Variance	Fonction Caractéristique
Uniforme	$p_k = \frac{1}{n}$ $k \in \{1, \dots, n\}$	$\frac{n+1}{2}$	$\frac{n^2-1}{12}$	$\frac{e^{it}(1 - e^{itn})}{n(1 - e^{it})}$
Bernoulli	$p_1 = P[X = 1] = p$ $p_0 = P[X = 0] = q$ $p \in [0, 1] \quad q = 1 - p$	$p$	$pq$	$pe^{it} + q$
Binomiale $B(n, p)$	$p_k = \binom{n}{k} p^k q^{n-k}$ $p \in [0, 1] \quad q = 1 - p$ $k \in \{0, 1, \dots, n\}, \binom{n}{k} = \frac{n!}{k!(n-k)!}$	$np$	$npq$	$(pe^{it} + q)^n$
Binomiale négative	$p_k = \binom{n+k-1}{n-1} p^n q^k$ $p \in [0, 1] \quad q = 1 - p$ $k \in \mathbb{N}, \binom{n}{k} = \frac{n!}{k!(n-k)!}$	$n \frac{q}{p}$	$n \frac{q}{p^2}$	$\left(\frac{p}{1 - qe^{it}}\right)^n$
Multinomiale	$p_{1,\dots,m} = \frac{n!}{k_1! \dots k_m!} p_1^{k_1} \dots p_m^{k_m}$ $p_j \in [0, 1] \quad q_j = 1 - p_j$ $k_j \in \{0, 1, \dots, n\}$ $\sum_{j=1}^m k_j = n \quad \sum_{j=1}^m p_j = 1$	$np_j$	Variance : $np_j q_j$ Covariance : $-np_j p_k$	$\left(\sum_{j=1}^m p_j e^{it}\right)^n$
Poisson $P(\lambda)$	$p_k = e^{-\lambda} \frac{\lambda^k}{k!}$ $\lambda > 0 \quad k \in \mathbb{N}$	$\lambda$	$\lambda$	$\exp[\lambda(e^{it} - 1)]$
Géométrique	$p_k = pq^{k-1}$ $p \in [0, 1] \quad q = 1 - p$ $k \in \mathbb{N}^*$	$\frac{1}{p}$	$\frac{q}{p^2}$	$\frac{pe^{it}}{1 - qe^{it}}$

## LOIS DE PROBABILITÉ CONTINUES

LOI	Densité de probabilité	Moyenne	Variance	Fonction Caractéristique
Uniforme	$f(x) = \frac{1}{b-a}$ $x \in ]a, b[$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	$\frac{e^{itb} - e^{ita}}{it(b-a)}$
Gamma $\mathcal{G}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\theta x} x^{\nu-1}$ $\theta > 0, \nu > 0$ $x \geq 0$ <p>avec <math>\Gamma(n+1) = n! \forall n \in \mathbb{N}</math></p>	$\frac{\nu}{\theta}$	$\frac{\nu}{\theta^2}$	$\frac{1}{(1 - it/\theta)^\nu}$
Inverse gamma $\mathcal{IG}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\frac{\theta}{x}} \frac{1}{x^{\nu+1}}$ $\theta > 0, \nu > 0$ $x \geq 0$ <p>avec <math>\Gamma(n+1) = n! \forall n \in \mathbb{N}</math></p>	$\frac{\theta}{\nu-1}$ si $\nu > 1$	$\frac{\theta^2}{(\nu-1)^2(\nu-2)}$ si $\nu > 2$	Expression compliquée
Première loi de Laplace	$f(x) = \frac{1}{2} e^{- x }, \quad x \in \mathbb{R}$	0	2	$\frac{1}{1+t^2}$
Normale univariée $\mathcal{N}(m, \sigma^2)$	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad x \in \mathbb{R}$	$m$	$\sigma^2$	$e^{imt - \frac{\sigma^2 t^2}{2}}$
Normale multivariée $\mathcal{N}_p(\mathbf{m}, \Sigma)$	$f(x) = K e^{-\frac{1}{2}(x-m)^T \Sigma^{-1}(x-m)}$ $K = \frac{1}{\sqrt{(2\pi)^p \det(\Sigma)}}$ $x \in \mathbb{R}^p$	$\mathbf{m}$	$\Sigma$	$e^{i\mathbf{u}^T \mathbf{m} - \frac{1}{2} \mathbf{u}^T \Sigma \mathbf{u}}$
Khi2 $\chi_\nu^2$ $\Gamma(\frac{\nu}{2}, \frac{1}{2})$	$f(x) = k e^{-\frac{x}{2}} x^{\frac{\nu}{2}-1}$ $k = \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}$ $\nu \in \mathbb{N}^*, x \geq 0$	$\nu$	$2\nu$	$\frac{1}{(1-2it)^{\frac{\nu}{2}}}$
Cauchy $\mathcal{C}_{\lambda, \alpha}$	$f(x) = \frac{1}{\pi \lambda \left(1 + \left(\frac{x-\alpha}{\lambda}\right)^2\right)}$ $\lambda > 0, \alpha \in \mathbb{R}$	(-)	(-)	$e^{i\alpha t - \lambda t }$
Beta $B(a, b)$	$f(x) = k x^{a-1} (1-x)^{b-1}$ $k = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}, \Gamma(n+1) = n! \forall n \in \mathbb{N}$ $a > 0, b > 0$ $x \in ]0, 1[$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	Expression compliquée
Pareto $P(a, b)$	$f(x) = \frac{b a^b}{x^{b+1}}$ $a > 0, b > 0$ $x \in ]a, +\infty[$	$\frac{ab}{b-1}$	$\frac{a^2 b}{(b-1)^2(b-2)}$	Expression compliquée