

---

EXAMEN STATISTIQUE 1SN

Lundi 3 avril 2023

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

---

**Exercice 1 : Estimation (10 points)**

On considère  $n$  observations  $x_1, \dots, x_n$  issues d'un vecteur  $(X_1, \dots, X_n)$  de  $n$  variables aléatoires indépendantes de mêmes lois de densités

$$f_r(x_i; \lambda) = \frac{\lambda^r}{\Gamma(r)} \frac{1}{x_i^{r+1}} \exp\left(-\frac{\lambda}{x_i}\right) I_{\mathbb{R}^+}(x_i),$$

où  $I_{\mathbb{R}^+}$  est la fonction indicatrice sur  $\mathbb{R}^+$  ( $I_{\mathbb{R}^+}(x) = 1$  si  $x > 0$  et 0 sinon) et où  $r$  est un paramètre supposé connu. La moyenne et la variance d'une telle loi appelée loi inverse-gamma et notée  $\mathcal{IG}(r, \lambda)$  sont

$$E[X_i] = \frac{\lambda}{r-1} \text{ et } \text{var}[X_i] = \frac{\lambda^2}{(r-1)^2(r-2)}.$$

On admettra que si  $X_i \sim \mathcal{IG}(r, \lambda)$ , alors  $Y_i = \frac{1}{X_i} \sim \mathcal{G}(r, \lambda)$  et qu'inversement si  $Y_i \sim \mathcal{G}(r, \lambda)$ , alors  $X_i = \frac{1}{Y_i} \sim \mathcal{IG}(r, \lambda)$ .

1. (2pts) Montrer que l'estimateur du maximum de vraisemblance du paramètre  $\lambda$  est

$$\hat{\lambda}_{\text{MV}} = \frac{nr}{\sum_{k=1}^n \frac{1}{X_k}}.$$

On justifiera que la vraisemblance admet un maximum en ce point.

La vraisemblance de l'échantillon s'écrit

$$L(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n f_r(x_i; \lambda) \propto \lambda^{rn} \prod_{i=1}^n \exp\left(-\frac{\lambda}{x_i}\right) I_{\mathbb{R}^+}(x_i),$$

où  $I_{\mathbb{R}^+}$  est la fonction indicatrice sur l'intervalle  $\mathbb{R}^+$ . On sait qu'il est plus facile de travailler avec la log-vraisemblance définie par

$$\ln L(x_1, \dots, x_n; \lambda) = (rn) \ln \lambda - \lambda \sum_{i=1}^n \frac{1}{x_i}.$$

Cette log-vraisemblance admet pour dérivée

$$\frac{\partial \ln L(x_1, \dots, x_n; \lambda)}{\partial \lambda} = \frac{rn}{\lambda} - \sum_{i=1}^n \frac{1}{x_i}.$$

Les variations de cette dérivée sont définies par

$$\begin{aligned} \frac{\partial \ln L(x_1, \dots, x_n; \lambda)}{\partial \lambda} \geq 0 &\Leftrightarrow \frac{rn}{\lambda} \geq \sum_{i=1}^n \frac{1}{x_i} \\ &\Leftrightarrow \lambda \leq \frac{rn}{\sum_{i=1}^n \frac{1}{x_i}}. \end{aligned}$$

Ceci permet de faire un tableau de variation qui indique que  $\lambda = \frac{rn}{\sum_{i=1}^n \frac{1}{x_i}}$  est le maximum global unique de la vraisemblance, d'où

$$\hat{\lambda}_{\text{MV}} = \frac{rn}{\sum_{i=1}^n \frac{1}{X_i}}.$$

2. (2pt) En utilisant les propriétés des lois gamma et inverse gamma données en début d'énoncé, déterminer la loi de  $Y_k = \frac{1}{X_k}$ . Montrer que  $Y = \sum_{k=1}^n \frac{1}{X_k}$  suit une loi gamma dont on précisera les paramètres. En déduire la loi de  $\frac{1}{Y}$ .

Comme  $X_k \sim \mathcal{IG}(r, \lambda)$ , alors  $Y_k = \frac{1}{X_k} \sim \mathcal{G}(r, \lambda)$ . D'après les tables de lois, la fonction caractéristique de  $Y_k$  est

$$\phi_{Y_k}(t) = E[e^{iY_k t}] = \frac{1}{(1 - i\frac{t}{\lambda})^r}.$$

Donc la fonction caractéristique de  $Y$  est (en utilisant l'indépendance des variables  $Y_k$ )

$$\phi_Y(t) = E[e^{iYt}] = \prod_{k=1}^n E[e^{iY_k t}] = \frac{1}{(1 - i\frac{t}{\lambda})^{rn}}.$$

On en déduit  $Y \sim \mathcal{G}(nr, \lambda)$  et donc  $\frac{1}{Y} \sim \mathcal{IG}(nr, \lambda)$

3. (2pts) Calculer l'espérance de  $\hat{\lambda}_{MV}$ . En déduire un estimateur non biaisé de  $\lambda$  noté  $\tilde{\lambda}_{MV}$ . L'estimateur  $\hat{\lambda}_{MV}$  est-il convergent?

Comme  $\hat{\lambda}_{MV} = \frac{nr}{Y}$ , en utilisant les tables de lois, on obtient

$$E[\hat{\lambda}_{MV}] = nr E\left[\frac{1}{Y}\right] = \frac{nr}{nr-1} \lambda.$$

$\hat{\lambda}_{MV}$  est donc un estimateur asymptotiquement non biaisé de  $\lambda$ . On peut construire un estimateur non biaisé en multipliant  $\hat{\lambda}_{MV}$  par  $\frac{nr-1}{nr}$ . On obtient alors

$$\tilde{\lambda}_{MV} = \frac{nr-1}{nr} \hat{\lambda}_{MV} = \frac{nr-1}{\sum_{i=1}^n \frac{1}{X_i}}.$$

D'après la table de lois, la variance de  $\tilde{\lambda}_{MV}$  s'écrit

$$\text{var}[\tilde{\lambda}_{MV}] = (nr-1)^2 \text{var}\left[\frac{1}{Y}\right] = (nr-1)^2 \times \frac{\lambda^2}{(nr-1)^2(nr-2)} = \frac{\lambda^2}{nr-2}.$$

Comme  $E[\tilde{\lambda}_{MV}] - \lambda = 0$  et que la variance de  $\tilde{\lambda}_{MV}$  tend vers 0 lorsque  $n \rightarrow \infty$ ,  $\tilde{\lambda}_{MV}$  est un estimateur sans biais et convergent du paramètre  $\lambda$ .

4. (2pts) Déterminer la borne de Cramér-Rao d'un estimateur non biaisé de  $\lambda$ . L'estimateur  $\tilde{\lambda}_{MV}$  est-il l'estimateur efficace du paramètre  $\lambda$  ?

La dérivée seconde de la log-vraisemblance de  $X_1, \dots, X_n$  est

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; \lambda)}{\partial \lambda^2} = \frac{-rn}{\lambda^2}.$$

d'où

$$E\left[-\frac{\partial^2 \ln L(X_1, \dots, X_n; \lambda)}{\partial \lambda^2}\right] = \frac{rn}{\lambda^2}.$$

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

$$\text{BCR} = \frac{1}{E\left[-\frac{\partial^2 \ln L(X_1, \dots, X_n; \lambda)}{\partial \lambda^2}\right]} = \frac{\lambda^2}{nr}.$$

Comme  $\text{var}[\tilde{\lambda}_{MV}] = \frac{\lambda^2}{nr-2} > \frac{\lambda^2}{nr}$ ,  $\tilde{\lambda}_{MV}$  n'est pas l'estimateur efficace du paramètre  $\lambda$ . On notera que cet estimateur est asymptotiquement efficace.

5. (2pts) On suppose désormais que le paramètre  $\lambda$  est muni d'une loi a priori de densité

$$f(\lambda) = \begin{cases} e^{1-\lambda} & \text{si } \lambda > 1 \\ 0 & \text{sinon} \end{cases}$$

Déterminer l'estimateur du maximum a posteriori du paramètre  $a$  noté  $\hat{\lambda}_{\text{MAP}}$  et le comparer à  $\hat{\lambda}_{\text{MV}}$  pour  $n \rightarrow \infty$ . Commenter ce résultat.

La loi a posteriori du paramètre  $\lambda$  vérifie

$$\begin{aligned} f_r(\lambda|x_1, \dots, x_n) &\propto f_r(x_1, \dots, x_n|\lambda)f(\lambda) \\ &\propto \lambda^{rn} \exp \left\{ -\lambda \left[ 1 + \sum_{i=1}^n \frac{1}{x_i} \right] \right\} \mathcal{I}_{]1, +\infty[}(\lambda), \end{aligned}$$

qui a la même forme que la log-vraisemblance si on remplace  $\sum_{i=1}^n \frac{1}{x_i}$  par  $1 + \sum_{i=1}^n \frac{1}{x_i}$ . L'estimateur du maximum a posteriori du paramètre  $\lambda$  s'obtient donc à partir de l'estimateur du maximum de vraisemblance en faisant cette même transformation, soit

$$\hat{\lambda}_{\text{MAP}} = \frac{nr}{1 + \sum_{i=1}^n \frac{1}{X_i}}.$$

*Remarque* : l'estimateur du maximum a posteriori du paramètre  $\lambda$  s'écrit

$$\hat{\lambda}_{\text{MAP}} = \frac{nr}{1 + \frac{nr}{\hat{\lambda}_{\text{MV}}}}$$

On peut donc remarquer que  $\hat{\lambda}_{\text{MAP}}$  et  $\hat{\lambda}_{\text{MV}}$  se comportent de manière similaire lorsque  $n \rightarrow +\infty$ . Lorsqu'on a beaucoup de données, on a tendance à oublier l'information a priori et à faire confiance à l'estimateur du maximum de vraisemblance qui résume l'information contenue dans les données.

## Exercice 2 : Test Statistique (10 points)

On considère  $n$  observations  $x_1, \dots, x_n$  issues d'un vecteur  $(X_1, \dots, X_n)$  de  $n$  variables aléatoires indépendantes de mêmes lois de densités

$$f_r(x_i; \lambda) = \frac{\lambda^r}{\Gamma(r)} \frac{1}{x_i^{r+1}} \exp\left(-\frac{\lambda}{x_i}\right) I_{\mathbb{R}^+}(x_i),$$

où  $I_{\mathbb{R}^+}$  est la fonction indicatrice sur  $\mathbb{R}^+$  ( $I_{\mathbb{R}^+}(x) = 1$  si  $x > 0$  et 0 sinon) et où  $r$  est un paramètre supposé connu. La moyenne et la variance d'une telle loi appelée loi inverse-gamma et notée  $\mathcal{IG}(r, \lambda)$  sont

$$E[X_i] = \frac{\lambda}{r-1} \text{ et } \text{var}[X_i] = \frac{\lambda^2}{(r-1)^2(r-2)}.$$

On désire utiliser les observations  $x_1, \dots, x_n$  pour déterminer si  $\lambda = \lambda_0 > 0$  ou si  $\lambda = \lambda_1 > \lambda_0$ . On considère donc le test d'hypothèses

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

1. (2pts) Déterminer la statistique  $T_n$  du test de Neyman Pearson et la région critique associée.

Le test de Neyman Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; \lambda_1)}{L(x_1, \dots, x_n; \lambda_0)} > S_{1,\alpha}$$

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

$$\begin{aligned} \frac{L(x_1, \dots, x_n; \lambda_1)}{L(x_1, \dots, x_n; \lambda_0)} > S_{1,\alpha} &\Leftrightarrow \ln \frac{L(x_1, \dots, x_n; \lambda_1)}{L(x_1, \dots, x_n; \lambda_0)} > S_{2,\alpha} \\ &\Leftrightarrow nr \ln \left( \frac{\lambda_1}{\lambda_0} \right) + (\lambda_0 - \lambda_1) \sum_{i=1}^n \frac{1}{x_i} > S_{2,\alpha}. \end{aligned}$$

Comme  $\lambda_1 > \lambda_0$ , on a  $\lambda_0 - \lambda_1 < 0$ , d'où la règle de décision

$$\text{Rejet de } H_0 \text{ si } T_n = \sum_{i=1}^n \frac{1}{X_i} < S_\alpha.$$

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

2. (1pt) En admettant que  $Y_i = \frac{1}{X_i}$  suit une loi gamma de paramètres  $r$  et  $\lambda$ , i.e.,  $Y_i \sim G(r, \lambda)$ , déterminer la loi asymptotique de  $T_n$  sous les deux hypothèses  $H_0$  et  $H_1$ .

La loi gamma  $\mathcal{G}(r, \lambda)$  est de moyenne  $\frac{r}{\lambda}$  et de variance  $\frac{r}{\lambda^2}$ . Donc

$$E[T_n] = \frac{nr}{\lambda} \text{ et } \text{var}[T_n] = \frac{nr}{\lambda^2}.$$

Comme  $T_n$  peut s'écrire comme une somme de variables indépendantes, l'application du théorème central limite permet alors d'obtenir les résultats suivants

$$\text{Sous } H_0 : T_n \approx \mathcal{N}\left(\frac{nr}{\lambda_0}, \frac{nr}{\lambda_0^2}\right),$$

$$\text{Sous } H_1 : T_n \approx \mathcal{N}\left(\frac{nr}{\lambda_1}, \frac{nr}{\lambda_1^2}\right),$$

où  $\approx$  signifie "de loi approchée (pour  $n$  grand)".

3. (2pts) On note  $G$  la fonction de répartition d'une loi du normale  $\mathcal{N}(0, 1)$ . En utilisant la loi asymptotique 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  $G(\alpha)$ ,  $n$ ,  $r$  et  $\lambda_0$ . En déduire la valeur du seuil  $S_\alpha$  en fonction de  $G^{-1}(\alpha)$  et de  $n$ ,  $r$  et  $\lambda_0$ .

Le risque  $\alpha$  est défini par

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

soit

$$\alpha = G \left[ \frac{S_\alpha - \frac{nr}{\lambda_0}}{\sqrt{\frac{nr}{\lambda_0^2}}} \right].$$

Pour obtenir le seuil  $S_\alpha$ , il suffit d'inverser cette relation :

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

4. (2pts) Déterminer les caractéristiques opérationnelles du récepteur (courbes COR) pour ce test et montrer qu'elles ne dépendent que de  $nr$  et de  $\frac{\lambda_1}{\lambda_0}$ . Analyser les performances du test en fonction de  $\frac{\lambda_1}{\lambda_0}$  et tracer l'allure approximative des courbes COR pour différentes valeurs de  $\frac{\lambda_1}{\lambda_0}$ .

Les courbes COR expriment  $\pi = 1 - \beta$  en fonction de  $\alpha$ . On a

$$\beta = P[\text{Rejeter } H_1 | H_1 \text{ vraie}] = P \left[ T_n \geq S_\alpha | T_n \sim \mathcal{N} \left( \frac{nr}{\lambda_1}, \frac{nr}{\lambda_1^2} \right) \right],$$

soit

$$\beta = 1 - G \left[ \frac{S_\alpha - \frac{nr}{\lambda_1}}{\sqrt{\frac{nr}{\lambda_1^2}}} \right].$$

On a donc

$$\pi = G \left[ \frac{S_\alpha - \frac{nr}{\lambda_1}}{\sqrt{\frac{nr}{\lambda_1^2}}} \right].$$

En remplaçant  $S_\alpha = \sqrt{\frac{nr}{\lambda_0^2}} G^{-1}(\alpha) + \frac{nr}{\lambda_0}$  dans cette expression, on a

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

On observe donc que  $\pi$  ne dépend que de  $nr$  et de  $\frac{\lambda_1}{\lambda_0}$ . De plus, comme  $G$  est une fonction croissante (c'est une fonction de répartition),  $\pi$  est une fonction croissante de  $nr$ . On en déduit que plus le nombre d'observations est grand, meilleure est la performance du test, ce qui est habituel. La puissance du test est aussi une fonction croissante de  $\frac{\lambda_1}{\lambda_0}$ , ce qui donne des courbes COR similaires à celles représentées dans la figure 1.




Figure 1: Allure des courbes COR pour différentes valeurs de  $\frac{\lambda_1}{\lambda_0}$ .

5. (3pts) On désire vérifier que les observations  $x_i$  suivent la loi de densité  $f_r(x_i; \lambda)$  avec  $r = \lambda = 1$  à l'aide d'un test de Kolmogorov.

- Déterminer la fonction de répartition de la loi de densité  $f_r(x_i; \lambda)$  notée  $F$  lorsque  $r = \lambda = 1$ .
- On observe l'échantillon de taille  $n = 4$  suivant :  $x_1 = 2, x_2 = 3, x_3 = 4$  et  $x_4 = \frac{3}{2}$ . Le tableau suivant résume les quantités nécessaires pour effectuer un test de Kolmogorov

$x_{(i)}$	1.5	2	3	4
$F(x_{(i)})$	0.5134	0.6065	0.7165	0.7788
$\hat{F}(x_{(i)}^-)$	0	0.25	0.50	0.75
$\hat{F}(x_{(i)}^+)$	0.25	0.50	0.75	1
$E_i^- =  F(x_{(i)}) - \hat{F}(x_{(i)}^-) $	0.5134	0.3565	0.2165	0.0288
$E_i^+ =  F(x_{(i)}) - \hat{F}(x_{(i)}^+) $	0.2634	0.1065	0.0335	0.2212

où  $(x_{(1)}, x_{(2)}, x_{(3)}, x_{(4)})$  est l'échantillon ordonné. Expliquer ce que représentent  $\hat{F}(x_{(i)}^-)$  et  $\hat{F}(x_{(i)}^+)$ .

- Rappeler la région critique du test de Kolmogorov. Pour  $\alpha = 0.01$  et  $n = 4$ , on a  $S_{0.01} = 0.7342$ . Que peut-on en conclure ?
- La fonction de répartition associée à  $f_r(x_i; \lambda)$  pour  $r = \lambda = 1$  s'écrit

$$F(x) = \int_{-\infty}^x f_1(u; 1) du = \begin{cases} 0 & \text{si } x \leq 0 \\ \int_0^x \frac{1}{u^2} \exp(-\frac{1}{u}) du & \text{si } u > 0 \end{cases}$$

En faisant le changement de variables  $v = \frac{1}{u}$ , on obtient

$$F(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ \int_{\frac{1}{x}}^{+\infty} \exp(-v) dv & \text{si } v > 0 \end{cases}$$

En faisant une intégration par parties, on obtient

$$F(x) = \begin{cases} 0 & \text{si } x \leq 0 \\ \exp(-\frac{1}{x}) & \text{si } x > 0 \end{cases}$$

- $\hat{F}(x_{(i)}^-)$  et  $\hat{F}(x_{(i)}^+)$  représentent les valeurs à gauche et à droite de la fonction en escaliers  $\hat{F}$  au point  $x_{(i)}$ .

- Le test de Kolmogorov rejette l'hypothèse  $H_0$  si

$$D_n = \max_{i \in \{1, \dots, n\}} \max\{E_i^+, E_i^-\} > S_\alpha.$$

Dans notre cas  $D_n = 0.5134 < S_{0.01} = 0.7342$  et donc on accepte l'hypothèse  $H_0$  (les observations  $x_i$  suivent la loi de densité  $f_r(x_i; \lambda)$  avec  $r = \lambda = 1$ ) avec le risque  $\alpha = 0.01$

## LOIS DE PROBABILITÉ CONTINUES

m : moyenne     $\sigma^2$  : variance    F. C. : fonction caractéristique

LOI	Densité de probabilité	m	$\sigma^2$	F. C.
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 $\mathcal{G}(\nu, \lambda)$	$f(x) = \frac{\lambda^\nu}{\Gamma(\nu)} e^{-\lambda x} x^{\nu-1}$ $\lambda > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\nu}{\lambda}$	$\frac{\nu}{\lambda^2}$	$\frac{1}{(1 - i\frac{t}{\lambda})^\nu}$
Inverse gamma $\mathcal{IG}(\nu, \lambda)$	$f(x) = \frac{\lambda^\nu}{\Gamma(\nu)} e^{-\frac{\lambda}{x}} \frac{1}{x^{\nu+1}}$ $\lambda > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\lambda}{\nu-1}$ si $\nu > 1$	$\frac{\lambda^2}{(\nu-1)^2(\nu-2)}$ si $\nu > 2$	(*)
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 $\mathcal{N}_p(\mathbf{m}, \Sigma)$	$f(\mathbf{x}) = K e^{-\frac{1}{2}(\mathbf{x}-\mathbf{m})^T \Sigma^{-1}(\mathbf{x}-\mathbf{m})}$ $K = \frac{1}{\sqrt{(2\pi)^p \det(\Sigma)}}$ $\mathbf{x} = (x_1, \dots, x_p)^T \in \mathbb{R}^p$	$\mathbf{m}$	$\Sigma$	$e^{i\mathbf{u}^T \mathbf{m} - \frac{1}{2} \mathbf{u}^T \Sigma \mathbf{u}}$
Khi <sub>2</sub> $\chi_\nu^2$ $\Gamma(\frac{\nu}{2}, \frac{1}{2})$	$f(x) = k e^{-\frac{x}{2}} x^{\frac{\nu}{2}-1}$ $k = \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}$ $\nu \in \mathbb{N}^*, x \geq 0$	$\nu$	$2\nu$	$\frac{1}{(1-2it)^{\frac{\nu}{2}}}$
Cauchy $c_{\lambda, \alpha}$	$f(x) = \frac{1}{\pi \lambda \left(1 + \left(\frac{x-\alpha}{\lambda}\right)^2\right)}$ $\lambda > 0, \alpha \in \mathbb{R}$	(-)	(-)	$e^{i\alpha t - \lambda t }$
Beta $B(a, b)$	$f(x) = k x^{a-1} (1-x)^{b-1}$ $k = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$ $a > 0, b > 0$ $x \in ]0, 1[$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	(*)



## LOIS DE PROBABILITÉ DISCRÈTES

$m$  : moyenne     $\sigma^2$  : variance    **F. C.** : fonction caractéristique

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

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