

---

EXAMEN STATISTIQUE - 1MF2E

Lundi 25 Mars 2024 (8h-9h45)

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 même loi binomiale négative définie par

$$P[X_i = x_i; p] = \binom{k + x_i - 1}{k - 1} p^k q^{x_i}, \quad x_i \in \mathbb{N}$$

avec  $p \in ]0, 1[$ ,  $q = 1 - p$ ,  $k \in \mathbb{N}$  et  $\binom{n}{k} = \frac{n!}{k!(n-k)!}$ . On fera attention car les notations sont légèrement différentes de celles des tables puisqu'ici  $n$  est le nombre d'observations et les paramètres de cette loi sont notés  $p$  et  $k$ . En tenant compte de ce changement de notation, cette loi est de moyenne  $E[X_i] = k \frac{q}{p}$ , de variance  $\text{var}(X_i) = k \frac{q}{p^2}$  et de fonction caractéristique  $\left( \frac{p}{1 - qe^{it}} \right)^k$ . On supposera dans cet exercice que  $k$  est un paramètre connu et que  $p$  est un paramètre inconnu que l'on cherche à estimer.

1. (2pts) Déterminer l'estimateur du vraisemblance du paramètre  $p$  noté  $\hat{p}_{\text{MV}}$ . Comme cet estimateur semble difficile à étudier, on s'intéresse maintenant au paramètre  $\theta = \frac{1-p}{p}$ . Montrer (en utilisant par exemple l'invariance fonctionnelle) que l'estimateur du maximum de vraisemblance de  $\theta$  est

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

La vraisemblance de l'échantillon s'écrit

$$L(x_1, \dots, x_n; p) = \prod_{i=1}^n P[X_i = x_i; p] \propto p^{nk} q^{\sum_{i=1}^n x_i},$$

où  $\propto$  signifie "proportionnel à" avec une constante multiplicative qui regroupe tous les termes indépendants de  $p$ . On sait qu'il est plus facile de travailler avec la log-vraisemblance définie par

$$\ln L(x_1, \dots, x_n; p) = \text{Cste} + (nk) \ln p + \ln(1 - p) \left( \sum_{i=1}^n x_i \right).$$

où la constante "Cste" est devenue additive. Cette log-vraisemblance admet pour dérivée

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

Les variations de cette dérivée sont définies par

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

où la seconde inégalité a été obtenue en multipliant les deux termes de l'inégalité par  $p(1-p)$ . Ceci permet de faire un tableau de variation qui indique que  $p = \frac{nk}{nk + \sum_{i=1}^n x_i}$  est le maximum global unique de la vraisemblance, d'où

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

Puisque la relation  $\theta = \frac{1-p}{p}$  est bijective, l'invariance fonctionnelle de l'estimateur du maximum de vraisemblance conduit à

$$\hat{\theta}_{MV} = \frac{1 - \hat{p}_{MV}}{\hat{p}_{MV}} = \frac{1}{\hat{p}_{MV}} - 1 = \frac{1}{nk} \sum_{i=1}^n X_i.$$

2. (2pt) Déterminer la moyenne et la variance de l'estimateur  $\hat{\theta}_{MV}$  en fonction de  $n$ ,  $k$  et  $\theta$ . L'estimateur  $\hat{\theta}_{MV}$  est-il un estimateur sans biais et convergent du paramètre  $\theta$  ?

La loi binomiale négative est de moyenne  $k\theta$  et de variance  $k\theta(1+\theta)$  car  $p = \frac{1}{1+\theta}$  implique  $\frac{q}{p} = \theta$  et  $\frac{q}{p^2} = \theta(1+\theta)$ . Donc

$$E[\hat{\theta}_{MV}] = \frac{1}{nk} \sum_{i=1}^n E[X_i] = \theta.$$

et de variance

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

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

3. (2pt) Déterminer la borne de Cramer-Rao pour un estimateur non biaisé du paramètre  $\theta$ . L'estimateur  $\hat{\theta}_{MV}$  est-il l'estimateur efficace du paramètre  $\theta$  ?

La vraisemblance de l'échantillon s'écrit en fonction de  $\theta$  comme suit

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

car  $p = \frac{1}{1+\theta}$  et  $q = 1-p = \frac{\theta}{1+\theta}$ . Son logarithme est donc

$$\ln L(x_1, \dots, x_n; \theta) = \text{Cste} - nk \ln(1+\theta) + \sum_{i=1}^n x_i [\ln \theta - \ln(1+\theta)].$$

La dérivée première de cette vraisemblance est

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

La dérivée seconde de la log-vraisemblance par rapport à  $\theta$  est donc

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

d'où

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

En simplifiant cette expression (factorisation par  $nk$  et réduction au même dénominateur), on en déduit que la borne de Cramér-Rao pour un estimateur non-biaisé de  $a$  est

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

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

4. (1pt) Déterminer un estimateur des moments du paramètre  $\theta$  noté  $\hat{\theta}_{\text{Mo}}$ .  
Puisque  $E[X_i] = k\theta$ , on a  $\theta = \frac{E[X_i]}{k}$ , d'où

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

5. (3pts) On suppose désormais que le paramètre  $\theta$  est muni d'une loi a priori de densité

$$f(\theta) = \frac{1}{(1 + \theta)^2} I_{\mathbb{R}^+}(\theta).$$

où  $I_{\mathbb{R}^+}$  est la fonction indicatrice sur  $\mathbb{R}^+$  ( $I_{\mathbb{R}^+}(\theta) = 1$  si  $\theta > 0$  et 0 sinon).

- Expliquer les connaissances sur  $\theta$  apportées par la forme de  $f(\theta)$ .  
La fonction  $f$  est une fonction décroissante de  $\theta$ . L'information a priori sur  $\theta$  aura donc tendance à favoriser les faibles valeurs de  $\theta$
- Déterminer l'estimateur du maximum a posteriori du paramètre  $\theta$  noté  $\hat{\theta}_{\text{MAP}}$  et vérifier que  $\hat{\theta}_{\text{MAP}} < \hat{\theta}_{\text{MV}}$ . Est ce que ceci est cohérent avec l'expression de la densité a priori  $f(\theta)$ ?  
On a vu que la vraisemblance de l'échantillon s'écrit en fonction de  $\theta$  comme suit

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

La loi a posteriori de  $\theta | X_1, \dots, X_n$  vérifie donc

$$p(\theta | x_1, \dots, x_n) \propto p(x_1, \dots, x_n | \theta) f(\theta) \propto \left( \frac{1}{1 + \theta} \right)^{nk+2} \left( \frac{\theta}{1 + \theta} \right)^{\sum_{i=1}^n x_i}.$$

Cette loi est obtenue en remplaçant  $nk$  par  $nk + 2$  dans la vraisemblance. On en déduit

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

Comme  $nk + 2 > nk$  et que les variables  $X_i$  sont à valeurs positives, on en déduit

$$\hat{\theta}_{\text{MAP}} < \hat{\theta}_{\text{MV}}.$$

La loi a priori de  $\theta$  favorise les faibles valeurs de  $\theta$ . Donc l'estimateur MAP de  $\theta$  est inférieur à son estimateur du maximum de vraisemblance (qui ne fait aucune hypothèse a priori sur  $\theta$ ).

## Exercice 2 : Tests Statistiques (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 même loi binomiale négative définie par

$$P[X_i = x_i; p] = \binom{k + x_i - 1}{k - 1} p^k q^{x_i}, \quad x_i \in \mathbb{N}$$

avec  $p \in ]0, 1[$ ,  $q = 1 - p$ ,  $k \in \mathbb{N}$  et  $\binom{n}{k} = \frac{n!}{k!(n-k)!}$ . On fera attention car les notations sont légèrement différentes de celles des tables puisqu'ici  $n$  est le nombre d'observations et les paramètres de cette loi sont notés  $p$  et  $k$ . En tenant compte de ce changement de notation, cette loi est de moyenne  $E[X_i] = k \frac{q}{p}$ ,

de variance  $\text{var}(X_i) = k \frac{q}{p^2}$  et de fonction caractéristique  $\left(\frac{p}{1 - qe^{it}}\right)^k$ . On supposera dans cet exercice que  $k$  est un paramètre connu et on désire utiliser les observations  $x_1, \dots, x_n$  pour déterminer si  $p = p_0 > 0$  ou si  $p = p_1 > p_0$ . On considère donc le test d'hypothèses

$$H_0 : p = p_0, \quad H_1 : p = p_1 \quad \text{avec } p_1 > p_0 > 0.$$

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

Le test de Neyman Pearson est défini par

$$\text{Rejet de } H_0 \text{ si } \frac{L(x_1, \dots, x_n; p_1)}{L(x_1, \dots, x_n; p_0)} > S_{1,\alpha}$$

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

$$\begin{aligned} \frac{L(x_1, \dots, x_n; p_1)}{L(x_1, \dots, x_n; p_0)} > S_{1,\alpha} &\Leftrightarrow \ln \frac{L(x_1, \dots, x_n; p_1)}{L(x_1, \dots, x_n; p_0)} > S_{2,\alpha} \\ &\Leftrightarrow (\ln(q_1) - \ln(q_0)) \sum_{i=1}^n x_i > S_{3,\alpha}. \end{aligned}$$

où on a utilisé le fait que la vraisemblance vérifie

$$L(x_1, \dots, x_n; p) \propto p^{nk} q^{\sum_{i=1}^n x_i},$$

Comme  $p_1 > p_0$ , on a  $q_1 = 1 - p_1 < q_0$  et  $\ln(q_1) < \ln(q_0)$ . La règle de décision est donc finalement

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

La région critique du test est 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  $T_n = \sum_{i=1}^n X_i$ .

2. (1pt) Exprimer la moyenne et la variance de  $T_n$  en fonction de  $k$ ,  $n$  et  $\theta = \frac{q}{p} = \frac{1-p}{p}$ . En déduire la loi approchée de  $T_n$  sous les deux hypothèses  $H_0$  et  $H_1$  provenant du théorème central limite (on exprimera les paramètres de cette loi en fonction de  $k$ ,  $n$  et  $\theta$ ).

La moyenne et la variance de  $X_i$  sont

$$E[X_i] = k \frac{q}{p} = k\theta \text{ et } \text{var}[X_i] = k \frac{q}{p^2} = k\theta(1 + \theta),$$

où on a utilisé le fait que  $\theta = \frac{1-p}{p} \Leftrightarrow p = \frac{1}{1+\theta}$ . D'après le théorème central limite, on a

$$\frac{T_n - kn\theta}{\sqrt{kn\theta(1 + \theta)}} \xrightarrow[n \rightarrow \infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

On en déduit

$$\text{Sous } H_0 : T_n \approx \mathcal{N}(kn\theta_0, kn\theta_0(1 + \theta_0)),$$

$$\text{Sous } H_1 : T_n \approx \mathcal{N}(kn\theta_1, kn\theta_1(1 + \theta_1)),$$

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

3. (2pts) On note  $F$  la fonction de répartition d'une loi du normale  $\mathcal{N}(0, 1)$ . En utilisant la loi approchée de  $T_n$  déterminée à la question précédente, exprimer le risque de première espèce  $\alpha$  en fonction du seuil du test de Neyman Pearson noté  $S_\alpha$ , de  $F(\alpha)$ ,  $nk$  et  $\theta_0$ . En déduire la valeur du seuil  $S_\alpha$  en fonction de  $F^{-1}(\alpha)$ ,  $nk$  et  $\theta_0$ .

Le risque  $\alpha$  est défini par

$$\alpha = P[\text{Rejeter } H_0 | H_0 \text{ vraie}] = P[T_n < S_\alpha | T_n \sim \mathcal{N}(kn\theta_0, kn\theta_0(1 + \theta_0))],$$

soit

$$\alpha = F \left[ \frac{S_\alpha - kn\theta_0}{\sqrt{kn\theta_0(1 + \theta_0)}} \right].$$

On en déduit

$$S_\alpha = F^{-1}(\alpha) \sqrt{kn\theta_0(1 + \theta_0)} + kn\theta_0.$$

4. (2pts) En utilisant la loi approchée de  $T_n$  déterminée à la question 2), déterminer les caractéristiques opérationnelles du récepteur (courbes COR) pour ce test et montrer qu'elles ne dépendent que de  $\sqrt{nk}$ ,  $F^{-1}(\alpha)$  et de deux fonctions dépendant des paramètres  $\theta_0$  et  $\theta_1$ . Analyser les performances du test en fonction de  $nk$  et tracer l'allure approximative des courbes COR pour différentes valeurs de ce paramètre.

Les courbes COR expriment  $\pi = 1 - \beta$  en fonction de  $\alpha$ . On sait qu'il suffit d'utiliser l'expression de  $\alpha$  et de changer  $\theta_0$  en  $\theta_1$  pour avoir  $\pi$ , soit

$$\pi = F \left[ \frac{S_\alpha - kn\theta_1}{\sqrt{kn\theta_1(1 + \theta_1)}} \right],$$

soit en remplaçant  $S_\alpha$  par son expression

$$\pi = F \left[ \frac{F^{-1}(\alpha) \sqrt{kn\theta_0(1 + \theta_0)} + kn\theta_0 - kn\theta_1}{\sqrt{kn\theta_1(1 + \theta_1)}} \right].$$

On obtient donc

$$\pi = F \left[ F^{-1}(\alpha) \sqrt{\frac{\theta_0(1 + \theta_0)}{\theta_1(1 + \theta_1)}} + \sqrt{nk} \frac{\theta_0 - \theta_1}{\sqrt{\theta_1(1 + \theta_1)}} \right].$$

Le paramètre  $\theta = \frac{1}{p-1}$  est une fonction décroissante de  $p$ . Donc si  $p_1 > p_0$ , on a  $\theta_1 < \theta_0$  et  $\theta_0 - \theta_1 > 0$ . On en déduit que  $\pi$  est une fonction croissante de  $nk$ . En particulier, quand  $nk$  augmente, la performance du test augmente, ce qui est attendu. L'allure approximative de ces courbes pour différentes valeurs de  $nk$  est représentée ci-dessous :




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

5. (3pts) On désire vérifier que les observations suivent une loi binomiale négative à l'aide d'un test du  $\chi^2$ . Le tableau suivant résume les quantités nécessaires pour effectuer le test

$x_i$	0	1	2	3	4	5	6	7
$n_k$	70	38	17	10	9	3	2	1
$n\pi_k$	69.49	37.60	20.10	10.70	5.69	3.02	1.60	0.85

où  $n_k$  est le nombre d'observations égales à  $k$  avec  $k \in \{0, \dots, 7\}$ ,  $n = \sum_{k=0}^7 n_k = 150$  et  $\pi_k = P[X_i = k]$  a été calculée avec une loi binomiale négative dont les deux paramètres  $k$  et  $p$  ont été estimés avec la méthode du maximum de vraisemblance. Les trois dernières observations sont regroupées dans une même classe, de manière à obtenir 6 classes définies par  $C_0 = \{0\}$ ,  $C_1 = \{1\}$ ,  $C_2 = \{2\}$ ,  $C_3 = \{3\}$ ,  $C_4 = \{4\}$  et  $C_5 = \{5, 6, 7\}$ .

- Expliquer pourquoi on a regroupé les valeurs  $\{5\}$ ,  $\{6\}$  et  $\{7\}$  dans une même classe.  
Les classes doivent vérifier  $n\pi_k \geq 5$ , ce qui n'est pas le cas avec les 8 classes d'origine. Si on regroupe les valeurs  $\{5\}$ ,  $\{6\}$  et  $\{7\}$  dans une même classe, la condition est vérifiée.
- Exprimer la statistique du test du  $\chi^2$  en fonction des données du problème pour les 6 classes définies ci-dessus (sans chercher à la calculer).  
La statistique du test du  $\chi^2$  est définie par

$$\phi = \sum_{k=0}^5 \frac{(n_k - n\pi_k)^2}{n\pi_k}.$$

- Rappeler la région critique du test du  $\chi^2$ .  
On rejette l'hypothèse  $H_0$  si  $\phi > S_\alpha$ , où  $S_\alpha$  est un seuil dépendant de la probabilité de fausse alarme  $\alpha$  (typiquement fixée à  $\alpha = 0.01$  ou à  $\alpha = 0.05$ ).
- Quelle loi doit être utilisée pour calculer le seuil de ce test noté  $S_\alpha$ ?  
Comme on a estimé deux paramètres, la loi asymptotique de  $\phi$  est une loi du  $\chi_3^2$ . Le nombre de degrés de liberté est égal  $K - 1 - n_p$  avec  $K = 6$  (nombre de classes) et  $n_p = 2$  (nombre de paramètres estimés).
- Donner l'expression de  $S_\alpha$  en fonction de  $\alpha$  et de l'inverse de la fonction de répartition de la loi trouvée à la question précédente.

On a

$$\alpha = P[\text{rejeter } H_0 | H_0 \text{ vraie}] = P[\phi > S_\alpha | \phi \sim \chi_3^2] = 1 - F_3(S_\alpha),$$

où  $F_3$  est la fonction de répartition de la loi  $\chi_3^2$ . On en conclut

$$S_\alpha = F_3^{-1}(1 - \alpha).$$

- Si on augmente la valeur de  $\alpha$ , la valeur de  $S_\alpha$  augmente-t-elle ou diminue-t-elle?  
Comme  $\alpha$  est la probabilité de rejeter l'hypothèse  $H_0$  sachant  $H_0$  vraie, plus  $\alpha$  est grand, plus on rejette  $H_0$ , donc plus le seuil est petit.

The Matlab code for this test is provided below

- Génération des valeurs observées : bins=0:7
- Comptes observés : obs=[70 38 17 10 9 3 2 1]
- Estimation des paramètre de la loi binomiale négative (nbin) : pd = fitdist(bins, 'nbin', 'Frequency', obs);
- Génération des probabilités  $\pi_k$  : pi=pdf(pd,bins)
- Compte théoriques  $n\pi_k$  : exp = n \* pi
- Test du chi2 : [h, p, st]=chi2gof(bins,'Ctrs',bins,'Frequency',obs, 'Expected',exp,'Nparams', 2)
- Conclusions :
  - \* h=0 donc on accepte  $H_0$  avec  $\alpha = 0.05$
  - \* p = pvalue = 0.4726
  - \* statistique de test = 2.5147
  - \* nombre de degrés de liberté de la loi du chi2 : df=3
  - \* Comptes observés : O =[70 38 17 10 9 6]
  - \* Comptes théoriques : E = [69.4880 37.5999 20.1011 10.7026 5.6869 5.4667]

## 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 $\mathcal{G}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\theta x} x^{\nu-1}$ $\theta > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\nu}{\theta}$	$\frac{\nu}{\theta^2}$	$\frac{1}{(1 - i\frac{t}{\theta})^\nu}$
Inverse gamma $\mathcal{IG}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\frac{\theta}{x}} \frac{1}{x^{\nu+1}}$ $\theta > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\theta}{\nu-1}$ si $\nu > 1$	$\frac{\theta^2}{(\nu-1)^2(\nu-2)}$ 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 $\mathcal{N}_p(\mathbf{m}, \Sigma)$	$f(x) = K e^{-\frac{1}{2}(x-\mathbf{m})^T \Sigma^{-1} (x-\mathbf{m})}$ $K = \frac{1}{\sqrt{(2\pi)^p \det(\Sigma)}}$ $x \in \mathbb{R}^p$	$\mathbf{m}$	$\Sigma$	$e^{i\mathbf{u}^T \mathbf{m} - \frac{1}{2} \mathbf{u}^T \Sigma \mathbf{u}}$
Khi2 $\chi_\nu^2$ $\Gamma(\frac{1}{2}, \frac{\nu}{2})$	$f(x) = k e^{-\frac{x}{2}} x^{\frac{\nu}{2}-1}$ $k = \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}$ $\nu \in \mathbb{N}^*, x \geq 0$	$\nu$	$2\nu$	$\frac{1}{(1-2it)^{\frac{\nu}{2}}}$
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 $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	(*)