

# Estimation par Maximum de Vraisemblance

## Exemples

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi normale – Présentation

- ▶ La loi normale est omniprésente en statistique :
  - ▶ Erreurs de mesure en physique, métrologie
  - ▶ Taille, poids et caractéristiques biologiques
  - ▶ Scores de tests psychométriques
  - ▶ Rendements financiers (en première approximation)
  - ▶ Distribution limite par le théorème central limite
- ▶ C'est la distribution de référence pour la théorie de l'estimation : c'est souvent le cas où les calculs sont les plus explicites.

- ▶  $X_i \sim \mathcal{N}(\mu, \sigma^2)$  avec  $\mu \in \mathbb{R}$  et  $\sigma^2 > 0$  :

$$f(x; \mu, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

- ▶ Moments :

$$\mathbb{E}[X] = \mu, \quad \mathbb{V}[X] = \sigma^2$$

- ▶ On peut paramétrer par  $(\mu, \sigma^2)$  ou par  $(\mu, \sigma)$ . Nous utilisons  $(\mu, \sigma^2)$ .

## Loi normale – Log-vraisemblance

- Vraisemblance :

$$L(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

- Log-vraisemblance :

$$\ell(\mu, \sigma^2) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

- On peut réécrire le dernier terme :

$$\sum_{i=1}^n (x_i - \mu)^2 = \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu)^2$$

## Loi normale – Estimateur de $\mu$

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0 \quad \Rightarrow \quad \sum_{i=1}^n x_i = n\mu$$

- Solution :

$$\hat{\mu}_{MV} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

- C'est la moyenne empirique.

## Loi normale – Estimateur de $\sigma^2$

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0$$

- En remplaçant  $\mu$  par  $\hat{\mu} = \bar{x}$  :

$$\frac{n}{2\sigma^2} = \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \bar{x})^2$$

- Solution :

$$\hat{\sigma}_{MV}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

- C'est la variance empirique (avec diviseur  $n$ , pas  $n - 1$ ).



## Loi normale – Distribution exacte de $\hat{\mu}$

- ▶ Puisque  $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$  est une combinaison linéaire de variables normales indépendantes :

$$\hat{\mu} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$$

- ▶ Propriétés :
  - ▶  $\mathbb{E}[\hat{\mu}] = \mu$  : estimateur sans biais
  - ▶  $\mathbb{V}[\hat{\mu}] = \frac{\sigma^2}{n}$  : variance exacte
  - ▶ Distribution exactement normale pour tout  $n$

## Loi normale – Distribution exacte de $\hat{\sigma}^2$

- ▶ On montre que :

$$\frac{n\hat{\sigma}^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

- ▶ Puisque  $\mathbb{E}[\chi_{n-1}^2] = n - 1$  :

$$\mathbb{E}\left[\frac{n\hat{\sigma}^2}{\sigma^2}\right] = n - 1 \quad \Rightarrow \quad \mathbb{E}[\hat{\sigma}^2] = \frac{n-1}{n}\sigma^2$$

- ▶ L'estimateur MV est biaisé : il sous-estime  $\sigma^2$ .

- ▶ Biais :  $\text{Biais}(\hat{\sigma}^2) = -\frac{\sigma^2}{n}$

## Loi normale – Estimateur sans biais de $\sigma^2$

- ▶ L'estimateur sans biais de  $\sigma^2$  est :

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n}{n-1} \hat{\sigma}_{MV}^2$$

- ▶ On a  $\mathbb{E}[S^2] = \sigma^2$ .
- ▶ Le diviseur  $n - 1$  (et non  $n$ ) correspond aux degrés de liberté : on perd un degré de liberté en estimant  $\mu$  par  $\bar{X}$ .
- ▶ C'est l'estimateur utilisé par défaut dans la plupart des logiciels statistiques.

## Loi normale – Variance de $\hat{\sigma}^2$

► Puisque  $\mathbb{V}[\chi_k^2] = 2k$ , on a  $\mathbb{V}[\chi_{n-1}^2] = 2(n-1)$ .

► Variance de l'estimateur MV :

$$\mathbb{V}\left[\frac{n\hat{\sigma}^2}{\sigma^2}\right] = 2(n-1) \quad \Rightarrow \quad \frac{n^2}{\sigma^4}\mathbb{V}[\hat{\sigma}^2] = 2(n-1)$$

$$\boxed{\mathbb{V}[\hat{\sigma}^2] = \frac{2(n-1)\sigma^4}{n^2}}$$

► Pour  $n$  grand :  $\mathbb{V}[\hat{\sigma}^2] \approx \frac{2\sigma^4}{n}$

## Loi normale – Variance de $S^2$

- Puisque  $S^2 = \frac{n}{n-1}\hat{\sigma}^2$  :

$$\mathbb{V}[S^2] = \frac{n^2}{(n-1)^2} \mathbb{V}[\hat{\sigma}^2] = \frac{n^2}{(n-1)^2} \cdot \frac{2(n-1)\sigma^4}{n^2}$$

$$\boxed{\mathbb{V}[S^2] = \frac{2\sigma^4}{n-1}}$$

- Pour  $n$  grand,  $\mathbb{V}[\hat{\sigma}_{MV}^2] < \mathbb{V}[S^2]$ .
- L'estimateur MV (biaisé) a une variance légèrement plus faible que l'estimateur sans biais.

## Loi normale – Indépendance de $\hat{\mu}$ et $\hat{\sigma}^2$

### Théorème de Cochran

Pour un échantillon i.i.d. de loi normale,  $\bar{X}$  et  $\sum_{i=1}^n (X_i - \bar{X})^2$  sont indépendants.

- ▶ Conséquence :  $\hat{\mu} = \bar{X}$  et  $\hat{\sigma}^2$  sont indépendants.
- ▶ Cette indépendance est cruciale pour construire la statistique de Student :

$$T = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$$

où  $S = \sqrt{S^2}$  est l'écart-type empirique corrigé.

► Dérivées secondes :

$$\frac{\partial^2 \ell}{\partial \mu^2} = -\frac{n}{\sigma^2}$$

$$\frac{\partial^2 \ell}{\partial (\sigma^2)^2} = \frac{n}{2\sigma^4} - \frac{1}{\sigma^6} \sum_{i=1}^n (x_i - \mu)^2$$

$$\frac{\partial^2 \ell}{\partial \mu \partial \sigma^2} = -\frac{1}{\sigma^4} \sum_{i=1}^n (x_i - \mu)$$

## Loi normale – Matrice d'information de Fisher

►  $\mathbb{E} \left[ \sum_{i=1}^n (X_i - \mu)^2 \right] = n\sigma^2$  et  $\mathbb{E} \left[ \sum_{i=1}^n (X_i - \mu) \right] = 0$

► Matrice d'information de Fisher :

$$I(\mu, \sigma^2) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix}$$

► La matrice est diagonale :  $\mu$  et  $\sigma^2$  sont orthogonaux.

► Les estimateurs  $\hat{\mu}$  et  $\hat{\sigma}^2$  sont asymptotiquement indépendants (et même exactement indépendants pour la loi normale).



## Loi normale – Bornes de Cramér-Rao

- Pour  $\mu$  :

$$\mathbb{V}[\hat{\mu}] \geq \frac{1}{I_{\mu\mu}} = \frac{\sigma^2}{n}$$

Variance exacte de  $\hat{\mu}$  :  $\frac{\sigma^2}{n} \Rightarrow$  efficace à distance finie.

- Pour  $\sigma^2$  :

$$\mathbb{V}[\hat{\sigma}^2] \geq \frac{1}{I_{\sigma^2\sigma^2}} = \frac{2\sigma^4}{n}$$

Variance exacte de  $\hat{\sigma}_{MV}^2$  :  $\frac{2(n-1)\sigma^4}{n^2} = \frac{2\sigma^4}{n} \left(1 - \frac{1}{n}\right)$

- L'estimateur MV de  $\sigma^2$  est asymptotiquement efficace (mais pas exactement efficace à distance finie).

## Loi normale – Erreur quadratique moyenne

- L'erreur quadratique moyenne (EQM) combine biais et variance :

$$\text{EQM}(\hat{\theta}) = \mathbb{V}[\hat{\theta}] + \text{Biais}(\hat{\theta})^2$$

- Comparaison pour l'estimation de  $\sigma^2$  :

Estimateur	Biais	Variance	EQM
$\hat{\sigma}_{MV}^2$	$-\sigma^2/n$	$\frac{2(n-1)\sigma^4}{n^2}$	$\frac{(2n-1)\sigma^4}{n^2}$
$S^2$	0	$\frac{2\sigma^4}{n-1}$	$\frac{2\sigma^4}{n-1}$

- Pour  $n \geq 2$  :  $\text{EQM}(\hat{\sigma}_{MV}^2) < \text{EQM}(S^2)$  (l'estimateur MV biaisé a une EQM plus faible).

## Loi normale – Résumé

- Estimateurs du maximum de vraisemblance :

$$\hat{\mu}_{MV} = \bar{X}, \quad \hat{\sigma}_{MV}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

- Propriétés :

	$\hat{\mu}$	$\hat{\sigma}_{MV}^2$
Biais	0	$-\sigma^2/n$
Variance	$\sigma^2/n$	$2(n-1)\sigma^4/n^2$
Efficace	Oui (exact)	Asymptotiquement
Distribution	$\mathcal{N}(\mu, \sigma^2/n)$	$\frac{\sigma^2}{n} \chi_{n-1}^2$

- Les estimateurs  $\hat{\mu}$  et  $\hat{\sigma}^2$  sont indépendants (théorème de Cochran).

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi de Bernoulli – Présentation

- ▶ La loi de Bernoulli modélise une épreuve à deux issues (succès/échec) :
  - ▶ Pile ou face
  - ▶ Réussite ou échec d'un traitement médical
  - ▶ Défectueux ou conforme dans un contrôle qualité
  - ▶ Clic ou non sur une publicité en ligne
  - ▶ Vote pour ou contre une proposition
- ▶ C'est la brique de base pour construire :
  - ▶ Loi binomiale (somme de  $n$  Bernoulli i.i.d.)
  - ▶ Loi géométrique (nombre d'essais jusqu'au premier succès)

# Loi de Bernoulli – Modèle

- $X_i \sim \text{Bernoulli}(p)$  avec  $p \in (0, 1)$  :

$$P(X = x) = p^x(1 - p)^{1-x}, \quad x \in \{0, 1\}$$

Ou :  $P(X = 1) = p$ ,  $P(X = 0) = 1 - p$

- Moments :

$$\mathbb{E}[X] = p, \quad \mathbb{V}[X] = p(1 - p)$$

- La variance est maximale pour  $p = 1/2$  (incertitude maximale).

# Loi de Bernoulli – Log-vraisemblance

- Vraisemblance :

$$L(p) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i}$$

- En notant  $S = \sum_{i=1}^n x_i$  le nombre de succès :  $L(p) = p^S (1-p)^{n-S}$

- Log-vraisemblance :

$$\ell(p) = S \log p + (n - S) \log(1 - p)$$

## Loi de Bernoulli – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial p} = \frac{S}{p} - \frac{n - S}{1 - p} = 0 \quad \Rightarrow \quad S = pn$$

- Solution :

$$\hat{p}_{MV} = \frac{S}{n} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

C'est la proportion empirique de succès.

- Vérification :  $\frac{\partial^2 \ell}{\partial p^2} = -\frac{S}{p^2} - \frac{n - S}{(1 - p)^2} < 0 \quad \checkmark$



## Loi de Bernoulli – Variance exacte de l'estimateur

- La somme  $S = \sum_{i=1}^n X_i$  suit une loi binomiale  $\text{Bin}(n, p)$  :

$$\mathbb{E}[S] = np, \quad \mathbb{V}[S] = np(1 - p)$$

- Puisque  $\hat{p} = S/n$  :  $\mathbb{E}[\hat{p}] = p$  (estimateur sans biais).

- Variance exacte :

$$\mathbb{V}[\hat{p}] = \frac{\mathbb{V}[S]}{n^2} = \frac{np(1 - p)}{n^2} = \frac{p(1 - p)}{n}$$

# Loi de Bernoulli – Information de Fisher

- Dérivée seconde de la log-vraisemblance :

$$\frac{\partial^2 \ell}{\partial p^2} = -\frac{S}{p^2} - \frac{n - S}{(1 - p)^2}$$

- Espérance (avec  $\mathbb{E}[S] = np$ ) :

$$\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial p^2} \right] = -\frac{np}{p^2} - \frac{n - np}{(1 - p)^2} = -\frac{n}{p} - \frac{n}{1 - p}$$

- Information de Fisher :

$$I(p) = -\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial p^2} \right] = \frac{n}{p} + \frac{n}{1 - p} = \frac{n}{p(1 - p)}$$

# Loi de Bernoulli – Efficacité de l'estimateur

- ▶ Borne de Cramér-Rao :  $\mathbb{V}[\hat{p}] \geq \frac{1}{I(p)} = \frac{p(1-p)}{n}$
- ▶ Variance exacte de  $\hat{p}$  :  $\frac{p(1-p)}{n}$

## Résultat remarquable

L'estimateur  $\hat{p} = \bar{X}$  atteint exactement la borne de Cramér-Rao.  
C'est un estimateur efficace (pas seulement asymptotiquement).

# Loi de Bernoulli – Distribution de l'estimateur

- Distribution exacte (puisque  $S = n\hat{p} \sim \text{Bin}(n, p)$ ) :

$$P(\hat{p} = k/n) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n$$

- Distribution asymptotique (par le TCL) :

$$\sqrt{n}(\hat{p} - p) \xrightarrow{d} \mathcal{N}(0, p(1-p))$$

$$\text{soit } \hat{p} \overset{\text{approx}}{\sim} \mathcal{N}\left(p, \frac{p(1-p)}{n}\right)$$

- Cette approximation est bonne pour  $np \geq 5$  et  $n(1-p) \geq 5$ .

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi de Poisson – Présentation

- ▶ La loi de Poisson modélise le nombre d'événements rares dans un intervalle :
  - ▶ Nombre d'appels reçus par heure dans un centre
  - ▶ Nombre de défauts par mètre de tissu
  - ▶ Nombre d'accidents par jour sur une autoroute
  - ▶ Nombre de mutations par génome
  - ▶ Nombre de clients arrivant dans une file d'attente
- ▶ Limite de la loi binomiale  $\text{Bin}(n, p)$  quand  $n \rightarrow \infty$  et  $p \rightarrow 0$  avec  $np \rightarrow \lambda$ .

## Loi de Poisson – Modèle

- ▶  $X_i \sim \text{Poisson}(\lambda)$  avec  $\lambda > 0$  :

$$P(X = k) = \frac{\lambda^k e^{-\lambda}}{k!}, \quad k = 0, 1, 2, \dots$$

- ▶ Moments :

$$\mathbb{E}[X] = \lambda, \quad \mathbb{V}[X] = \lambda$$

- ▶ L'égalité espérance = variance est caractéristique de la loi de Poisson.

## Loi de Poisson – Calcul des moments

- Espérance :

$$\mathbb{E}[X] = \sum_{k=1}^{\infty} \frac{\lambda^k e^{-\lambda}}{(k-1)!} = \lambda e^{-\lambda} \sum_{j=0}^{\infty} \frac{\lambda^j}{j!} = \lambda e^{-\lambda} \cdot e^{\lambda} = \boxed{\lambda}$$

- Calcul de  $\mathbb{E}[X(X-1)]$  :

$$\mathbb{E}[X(X-1)] = \sum_{k=2}^{\infty} \frac{\lambda^k e^{-\lambda}}{(k-2)!} = \lambda^2 e^{-\lambda} \sum_{j=0}^{\infty} \frac{\lambda^j}{j!} = \lambda^2$$

- Donc  $\mathbb{E}[X^2] = \lambda^2 + \lambda$ , et :

$$\mathbb{V}[X] = \mathbb{E}[X^2] - \mathbb{E}[X]^2 = \lambda^2 + \lambda - \lambda^2 = \boxed{\lambda}$$



# Loi de Poisson – Log-vraisemblance

- Vraisemblance :

$$L(\lambda) = \prod_{i=1}^n \frac{\lambda^{x_i} e^{-\lambda}}{x_i!} = \frac{\lambda^{\sum_{i=1}^n x_i} e^{-n\lambda}}{\prod_{i=1}^n x_i!}$$

- En notant  $S = \sum_{i=1}^n x_i$  :  $L(\lambda) = \frac{\lambda^S e^{-n\lambda}}{\prod_{i=1}^n x_i!}$

- Log-vraisemblance :

$$\ell(\lambda) = S \log \lambda - n\lambda - \sum_{i=1}^n \log(x_i!)$$

## Loi de Poisson – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \lambda} = \frac{S}{\lambda} - n = 0$$

- Solution :

$$\hat{\lambda}_{MV} = \frac{S}{n} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

L'estimateur est la moyenne empirique.

- Vérification :  $\frac{\partial^2 \ell}{\partial \lambda^2} = -\frac{S}{\lambda^2} < 0 \checkmark$

## Loi de Poisson – Variance exacte de l'estimateur

- La somme  $S = \sum_{i=1}^n X_i \sim \text{Poisson}(n\lambda)$ , donc :

$$\mathbb{E}[S] = n\lambda, \quad \mathbb{V}[S] = n\lambda$$

- L'estimateur est sans biais :  $\mathbb{E}[\hat{\lambda}] = \lambda$

- Variance exacte :

$$\mathbb{V}[\hat{\lambda}] = \frac{\mathbb{V}[S]}{n^2} = \frac{n\lambda}{n^2} = \frac{\lambda}{n}$$

# Loi de Poisson – Information de Fisher

- Dérivée seconde de la log-vraisemblance :

$$\frac{\partial^2 \ell}{\partial \lambda^2} = -\frac{S}{\lambda^2}$$

- Espérance (avec  $\mathbb{E}[S] = n\lambda$ ) :

$$\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial \lambda^2} \right] = -\frac{n\lambda}{\lambda^2} = -\frac{n}{\lambda}$$

- Information de Fisher :

$$I(\lambda) = -\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial \lambda^2} \right] = \frac{n}{\lambda}$$

## Loi de Poisson – Efficacité de l'estimateur

- ▶ Borne de Cramér-Rao :  $\mathbb{V}[\hat{\lambda}] \geq \frac{1}{I(\lambda)} = \frac{\lambda}{n}$
- ▶ Variance exacte de  $\hat{\lambda}$  :  $\frac{\lambda}{n}$

### Résultat remarquable

L'estimateur  $\hat{\lambda} = \bar{X}$  atteint exactement la borne de Cramér-Rao.  
C'est un estimateur efficace (pas seulement asymptotiquement).

## Loi de Poisson – Distribution de l'estimateur

- Distribution exacte (puisque  $n\hat{\lambda} = S \sim \text{Poisson}(n\lambda)$ ) :

$$P(\hat{\lambda} = k/n) = \frac{(n\lambda)^k e^{-n\lambda}}{k!}, \quad k = 0, 1, 2, \dots$$

- Distribution asymptotique (par le TCL) :

$$\sqrt{n}(\hat{\lambda} - \lambda) \xrightarrow{d} \mathcal{N}(0, \lambda)$$

soit  $\hat{\lambda} \overset{\text{approx}}{\sim} \mathcal{N}\left(\lambda, \frac{\lambda}{n}\right)$

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

**Loi exponentielle**

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi exponentielle – Présentation

- ▶ La loi exponentielle modélise la durée de vie ou le temps d'attente :
  - ▶ Temps entre deux appels dans un centre téléphonique
  - ▶ Durée de vie d'un composant électronique
  - ▶ Temps d'attente à un guichet
  - ▶ Temps entre deux tremblements de terre
- ▶ Propriété sans mémoire (seule loi continue la vérifiant) :

$$P(X > s + t \mid X > s) = P(X > t)$$



## Loi exponentielle – Modèle

- ▶  $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Exp}(\lambda)$  avec  $\lambda > 0$  :

$$f(x; \lambda) = \lambda e^{-\lambda x}, \quad x \geq 0$$

- ▶ Moments :

$$\mathbb{E}[X] = \frac{1}{\lambda}, \quad \mathbb{V}[X] = \frac{1}{\lambda^2}$$

- ▶ La somme  $S = \sum_{i=1}^n X_i$  est une statistique suffisante.

# Loi exponentielle – Log-vraisemblance

► Vraisemblance :

$$L(\lambda) = \prod_{i=1}^n \lambda e^{-\lambda x_i} = \lambda^n \exp \left( -\lambda \sum_{i=1}^n x_i \right)$$

► Log-vraisemblance :

$$\ell(\lambda) = \log L(\lambda) = n \log \lambda - \lambda \sum_{i=1}^n x_i$$

## Loi exponentielle – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i = 0$$

- Solution :

$$\hat{\lambda}_{MV} = \frac{n}{\sum_{i=1}^n X_i} = \frac{1}{\bar{X}}$$

- Vérification :  $\frac{\partial^2 \ell}{\partial \lambda^2} = -\frac{n}{\lambda^2} < 0 \checkmark$

## Loi exponentielle – Variance exacte de l'estimateur

- ▶ On a  $\hat{\lambda} = n/S$  où  $S = \sum_{i=1}^n X_i$ .
- ▶ La somme  $S$  a pour densité (loi Gamma) :

$$f_S(s) = \frac{\lambda^n s^{n-1} e^{-\lambda s}}{(n-1)!}, \quad s > 0$$

- ▶ Calcul de  $\mathbb{E}[1/S]$  (pour  $n > 1$ ) :

$$\mathbb{E} \left[ \frac{1}{S} \right] = \frac{\lambda^n}{(n-1)!} \int_0^\infty s^{n-2} e^{-\lambda s} ds$$

## Loi exponentielle – Variance exacte (suite)

- En utilisant  $\int_0^\infty s^k e^{-\lambda s} ds = \frac{k!}{\lambda^{k+1}}$  :

$$\mathbb{E}\left[\frac{1}{S}\right] = \frac{\lambda^n}{(n-1)!} \cdot \frac{(n-2)!}{\lambda^{n-1}} = \frac{\lambda}{n-1}$$

- Donc  $\mathbb{E}[\hat{\lambda}] = n \cdot \frac{\lambda}{n-1} = \frac{n\lambda}{n-1}$  (estimateur biaisé à distance finie).

- Calcul de  $\mathbb{E}[1/S^2]$  (pour  $n > 2$ ) :

$$\mathbb{E}\left[\frac{1}{S^2}\right] = \frac{\lambda^n}{(n-1)!} \cdot \frac{(n-3)!}{\lambda^{n-2}} = \frac{\lambda^2}{(n-1)(n-2)}$$

## Loi exponentielle – Variance exacte (fin)

$$\blacktriangleright \mathbb{E}[\hat{\lambda}^2] = n^2 \cdot \mathbb{E}\left[\frac{1}{S^2}\right] = \frac{n^2 \lambda^2}{(n-1)(n-2)}$$

► Variance :

$$\mathbb{V}[\hat{\lambda}] = \frac{n^2 \lambda^2}{(n-1)(n-2)} - \frac{n^2 \lambda^2}{(n-1)^2} = \frac{n^2 \lambda^2}{(n-1)^2} \cdot \frac{1}{n-2}$$

$$\boxed{\mathbb{V}[\hat{\lambda}] = \frac{n^2 \lambda^2}{(n-1)^2(n-2)}}$$

$$\blacktriangleright \text{Pour } n \text{ grand : } \mathbb{V}[\hat{\lambda}] \approx \frac{\lambda^2}{n}$$

# Loi exponentielle – Information de Fisher

- Information de Fisher :

$$I(\lambda) = -\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial \lambda^2} \right] = -\mathbb{E} \left[ -\frac{n}{\lambda^2} \right] = \frac{n}{\lambda^2}$$

- Borne de Cramér-Rao :  $\mathbb{V}[\hat{\lambda}] \geq \frac{1}{I(\lambda)} = \frac{\lambda^2}{n}$

- Comparaison :

- Variance exacte :  $\frac{n^2 \lambda^2}{(n-1)^2 (n-2)} \approx \frac{\lambda^2}{n}$  pour  $n$  grand

- L'estimateur atteint la borne de Cramér-Rao seulement asymptotiquement

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

**Loi géométrique**

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse



# Loi géométrique – Présentation

- ▶ La loi géométrique modélise le nombre d'essais jusqu'au premier succès :
  - ▶ Nombre de lancers de dé jusqu'à obtenir un 6
  - ▶ Nombre de clients démarchés jusqu'à une vente
  - ▶ Nombre de tentatives jusqu'à la réussite d'un examen
  - ▶ Position du premier défaut dans une chaîne de production
- ▶ C'est la version discrète de la loi exponentielle, elle vérifie aussi la propriété sans mémoire.

- $X_i \sim \text{Geom}(p)$  avec  $p \in (0, 1)$  :

$$P(X = k) = (1 - p)^{k-1}p, \quad k = 1, 2, 3, \dots$$

- Moments :

$$\mathbb{E}[X] = \frac{1}{p}, \quad \mathbb{V}[X] = \frac{1-p}{p^2}$$

- La somme  $S = \sum_{i=1}^n X_i$  suit une loi binomiale négative  $\text{NegBin}(n, p)$ .

## Loi géométrique – Séries utiles

► Série géométrique (pour  $|q| < 1$ ) : 
$$\sum_{k=0}^{\infty} q^k = \frac{1}{1-q}$$

► Dérivée première par rapport à  $q$  :

$$\sum_{k=1}^{\infty} kq^{k-1} = \frac{d}{dq} \left( \frac{1}{1-q} \right) = \frac{1}{(1-q)^2}$$

► Dérivée seconde par rapport à  $q$  :

$$\sum_{k=2}^{\infty} k(k-1)q^{k-2} = \frac{d^2}{dq^2} \left( \frac{1}{1-q} \right) = \frac{2}{(1-q)^3}$$

► Avec  $q = 1 - p$ , on a  $1 - q = p$ , donc :

$$\boxed{\sum_{k=1}^{\infty} kq^{k-1} = \frac{1}{p^2}, \quad \sum_{k=2}^{\infty} k(k-1)q^{k-2} = \frac{2}{p^3}}$$

## Loi géométrique – Série du logarithme

- De la série géométrique  $\frac{1}{1-x} = \sum_{k=0}^{\infty} x^k$  pour  $|x| < 1$ , en intégrant de 0 à  $q$  :

$$\int_0^q \frac{dx}{1-x} = \sum_{k=0}^{\infty} \int_0^q x^k dx$$

- À gauche :  $-\log(1-q)$ . À droite :  $\sum_{j=1}^{\infty} \frac{q^j}{j}$

- Conclusion :  $\boxed{\sum_{k=1}^{\infty} \frac{q^k}{k} = -\log(1-q)}$

- Avec  $q = 1-p$  :  $\sum_{k=1}^{\infty} \frac{(1-p)^k}{k} = -\log(p)$

## Loi géométrique – Calcul des moments

- Espérance (avec  $q = 1 - p$ ) :

$$\mathbb{E}[X] = \sum_{k=1}^{\infty} k \cdot q^{k-1} p = p \sum_{k=1}^{\infty} k q^{k-1} = p \cdot \frac{1}{p^2} = \boxed{\frac{1}{p}}$$

- Calcul de  $\mathbb{E}[X(X-1)]$  :

$$\mathbb{E}[X(X-1)] = \sum_{k=2}^{\infty} k(k-1) q^{k-1} p = pq \sum_{k=2}^{\infty} k(k-1) q^{k-2} = pq \cdot \frac{2}{p^3} = \frac{2q}{p^2}$$

- Donc  $\mathbb{E}[X^2] = \frac{2q}{p^2} + \frac{1}{p} = \frac{2q+p}{p^2} = \frac{1+q}{p^2}$

- Variance :

$$\mathbb{V}[X] = \mathbb{E}[X^2] - \mathbb{E}[X]^2 = \frac{1+q}{p^2} - \frac{1}{p^2} = \frac{q}{p^2} = \boxed{\frac{1-p}{p^2}}$$

# Loi géométrique – Log-vraisemblance

- Vraisemblance :

$$L(p) = \prod_{i=1}^n (1-p)^{x_i-1} p = p^n (1-p)^{\sum_{i=1}^n x_i - n}$$

- Log-vraisemblance (avec  $S = \sum_{i=1}^n x_i$ ) :

$$\ell(p) = n \log p + (S - n) \log(1 - p)$$

## Loi géométrique – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial p} = \frac{n}{p} - \frac{S - n}{1 - p} = 0 \quad \Rightarrow \quad n = pS$$

- Solution :

$$\hat{p}_{MV} = \frac{n}{\sum_{i=1}^n X_i} = \frac{1}{\bar{X}}$$

## Loi géométrique – Biais de l'estimateur

- ▶ Par l'inégalité de Jensen (puisque  $g(x) = 1/x$  est convexe) :

$$\mathbb{E}[\hat{p}] = n \cdot \mathbb{E}\left[\frac{1}{S}\right] > n \cdot \frac{1}{\mathbb{E}[S]} = p$$

L'estimateur surestime  $p$  en moyenne.

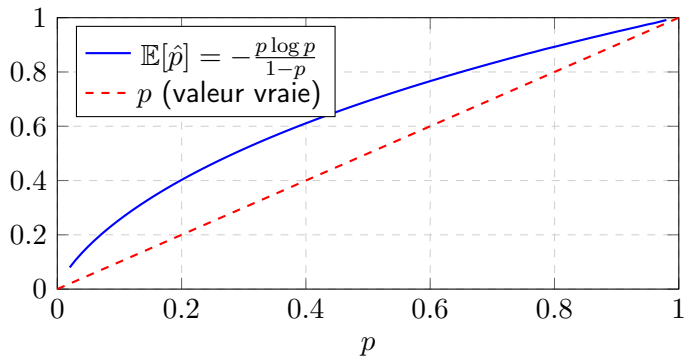
- ▶ Calcul exact pour  $n = 1$  (avec  $\sum_{k=1}^{\infty} \frac{q^k}{k} = -\log(1 - q)$ ) :

$$\mathbb{E}\left[\frac{1}{X}\right] = \frac{p}{q} \sum_{k=1}^{\infty} \frac{q^k}{k} = -\frac{p \log p}{1 - p}$$

- ▶ Exemple : pour  $p = 0.5$ ,  $\mathbb{E}[\hat{p}] = \log 2 \approx 0.693$ , soit un biais de  $+0.193$ .



## Loi géométrique – Biais ( $n = 1$ ) : représentation graphique



Le biais (écart entre les courbes) est toujours positif : l'estimateur surestime  $p$ .

## Loi géométrique – Biais : formule exacte (1/5)

- Pour  $S \sim \text{NegBin}(n, p)$  avec  $P(S = k) = \binom{k-1}{n-1} p^n q^{k-n}$  :

$$\mathbb{E} \left[ \frac{1}{S} \right] = \sum_{k=n}^{\infty} \frac{1}{k} \binom{k-1}{n-1} p^n q^{k-n} \quad (q = 1 - p)$$

- En notant que :  $\frac{1}{k} = \int_0^1 t^{k-1} dt$ , il vient :

$$\mathbb{E} \left[ \frac{1}{S} \right] = \sum_{k=n}^{\infty} \int_0^1 t^{k-1} \binom{k-1}{n-1} p^n q^{k-n} dt$$

$$\Leftrightarrow \int_0^1 p^n t^{n-1} \sum_{j=0}^{\infty} \binom{j+n-1}{n-1} (tq)^j dt$$

## Loi géométrique – Biais : formule exacte (2/5)

- Sachant que  $\sum_{j=0}^{\infty} \binom{j+n-1}{n-1} x^j = (1-x)^{-n}$ , il vient :

$$\mathbb{E} \left[ \frac{1}{S} \right] = p^n \int_0^1 \frac{t^{n-1}}{(1-tq)^n} dt$$

- En posant  $u = 1 - tq$ , on a  $dt = -\frac{du}{q}$ , et :

$$\mathbb{E} \left[ \frac{1}{S} \right] = \left( \frac{p}{q} \right)^n \int_{1-q}^1 \frac{(1-u)^{n-1}}{u^n} du$$

- En posant  $v = (1-u)/u$ , on a  $du = -\frac{1}{(1+v)^2} dv$ , et :

$$\mathbb{E} \left[ \frac{1}{S} \right] = \left( \frac{p}{q} \right)^n \int_0^{q/p} \frac{v^{n-1}}{1+v} dv$$

## Loi géométrique – Biais : formule exacte (3/5)

**Vérification pour  $n = 1$  :**

$$\mathbb{E} \left[ \frac{1}{X} \right] = \frac{p}{q} \int_0^{q/p} \frac{1}{1+v} \mathrm{d}v = \frac{p}{q} \log \left( 1 + \frac{q}{p} \right) = \frac{p}{q} \log \left( \frac{1}{p} \right) = -\frac{p \log p}{1-p} \quad \checkmark$$

## Loi géométrique – Biais : formule exacte (4/5)

► Pour  $v \in [0, q/p]$ , on a :

$$\text{► } v \geq 0 \Rightarrow 1 + v \geq 1 \Rightarrow \frac{1}{1+v} \leq 1$$

$$\text{► } v \leq \frac{q}{p} \Rightarrow 1 + v \leq \frac{p+q}{p} = \frac{1}{p} \Rightarrow \frac{1}{1+v} \geq p$$

► Ainsi, pour tout  $v \in [0, q/p]$  :  $p \leq \frac{1}{1+v} \leq 1$

► En multipliant par  $v^{n-1} \geq 0$ , puis en intégrant sur  $[0, q/p]$  :

$$\frac{p}{n} \left( \frac{q}{p} \right)^n \leq \int_0^{q/p} \frac{v^{n-1}}{1+v} dv \leq \frac{1}{n} \left( \frac{q}{p} \right)^n$$

## Loi géométrique – Biais : formule exacte (5/5)

Finalement, en multipliant par  $n \left(\frac{p}{q}\right)^n$  :

$$p \leq n \left(\frac{p}{q}\right)^n \int_0^{q/p} \frac{v^{n-1}}{1+v} dv \leq 1$$
$$\Leftrightarrow p \leq \mathbb{E}[\hat{p}] \leq 1$$

L'estimateur  $\hat{p}$  surestime  $p$  en moyenne, mais reste borné par 1 (c'est heureux).

## Loi géométrique – Convergence : concentration de $v^{n-1}$

- ▶ Pour  $n$  grand,  $v^{n-1}$  se concentre près de la borne supérieure  $v = q/p$ .
- ▶ Considérons  $v \in [0, q/p]$  avec  $q/p > 0$  :
  - ▶ Si  $v < q/p$ , alors  $\frac{v}{q/p} < 1$ , donc  $\left(\frac{v}{q/p}\right)^{n-1} \rightarrow 0$  quand  $n \rightarrow \infty$
  - ▶ Plus  $v$  est petit par rapport à  $q/p$ , plus  $v^{n-1}$  décroît vite
- ▶ Découpons l'intégrale :

$$\int_0^{q/p} \frac{v^{n-1}}{1+v} dv = \underbrace{\int_0^{q/p-\varepsilon} \frac{v^{n-1}}{1+v} dv}_{I_1} + \underbrace{\int_{q/p-\varepsilon}^{q/p} \frac{v^{n-1}}{1+v} dv}_{I_2}$$

avec  $\varepsilon > 0$  petit.

## Loi géométrique – Convergence : la première intégrale $I_1$

- Sur  $[0, q/p - \varepsilon]$ , on a  $v \leq q/p - \varepsilon$  et  $\frac{1}{1+v} \leq 1$ , donc :

$$I_1 = \int_0^{q/p - \varepsilon} \frac{v^{n-1}}{1+v} dv \leq \int_0^{q/p - \varepsilon} v^{n-1} dv = \frac{(q/p - \varepsilon)^n}{n}$$

- En comparant avec l'intégrale totale :

$$\frac{I_1}{\int_0^{q/p} v^{n-1} dv} \leq \frac{(q/p - \varepsilon)^n/n}{(q/p)^n/n} = \left(1 - \frac{\varepsilon p}{q}\right)^n \xrightarrow{n \rightarrow \infty} 0$$

- La contribution de  $I_1$  décroît **exponentiellement** vers 0.



## Loi géométrique – Convergence : la seconde intégrale $I_2$

- ▶ En  $v = q/p$ , on a  $\frac{1}{1+v} = \frac{1}{1+q/p} = \frac{p}{p+q} = p$ .
- ▶ Pour  $v$  proche de  $q/p$ , on peut approximer  $\frac{1}{1+v}$  par sa valeur en  $q/p$ .
- ▶ Ainsi, avec cette approximation :

$$\begin{aligned} I_2 &= \int_{q/p-\varepsilon}^{q/p} \frac{v^{n-1}}{1+v} dv \approx p \int_{q/p-\varepsilon}^{q/p} v^{n-1} dv \\ &\approx p \cdot \frac{1}{n} [(q/p)^n - (q/p - \varepsilon)^n] \\ &\approx \frac{p}{n} (q/p)^n \left[ 1 - \left( 1 - \frac{\varepsilon p}{q} \right)^n \right] \end{aligned}$$

- ▶ Pour  $n$  grand :  $\left( 1 - \frac{\varepsilon p}{q} \right)^n \rightarrow 0$ , donc :  $I_2 \approx \frac{p}{n} \left( \frac{q}{p} \right)^n$

## Loi géométrique – Convergence : conclusion

- Puisque  $I_1/I \rightarrow 0$  et  $I_2 \approx \frac{p}{n}(q/p)^n$  :

$$\int_0^{q/p} \frac{v^{n-1}}{1+v} dv \approx \frac{p}{n} \left(\frac{q}{p}\right)^n \quad \text{pour } n \text{ grand}$$

- On a donc :

$$\mathbb{E}[\hat{p}] = n \left(\frac{p}{q}\right)^n \int_0^{q/p} \frac{v^{n-1}}{1+v} dv \approx n \left(\frac{p}{q}\right)^n \cdot \frac{p}{n} \left(\frac{q}{p}\right)^n = p$$

et

$$\boxed{\text{Biais}(\hat{p}) = \mathbb{E}[\hat{p}] - p \xrightarrow[n \rightarrow \infty]{} 0}$$

L'estimateur est **asymptotiquement sans biais**.

## Loi géométrique – Variance : approche exacte

- Variance exacte :

$$\mathbb{V}[\hat{p}] = \mathbb{E}[\hat{p}^2] - \mathbb{E}[\hat{p}]^2 = n^2 \mathbb{E} \left[ \frac{1}{S^2} \right] - n^2 \mathbb{E} \left[ \frac{1}{S} \right]^2$$

- On connaît  $\mathbb{E}[1/S]$ . Pour  $\mathbb{E}[1/S^2]$ , on utilise :

$$\frac{1}{k^2} = \int_0^1 \frac{-\log t}{1} t^{k-1} dt$$

- Il faut alors calculer l'intégrale suivante :

$$\mathbb{E} \left[ \frac{1}{S^2} \right] = p^n \int_0^1 \frac{(-\log t) t^{n-1}}{(1-tq)^n} dt$$

- Cette intégrale n'a pas de forme simple, mais on peut montrer que pour  $n$  grand :

$$\mathbb{V}[\hat{p}] \sim \frac{p^2(1-p)}{n}$$

## Loi géométrique – La méthode delta

- Problème : on connaît  $\mathbb{E}[S]$  et  $\mathbb{V}[S]$ , mais on veut  $\mathbb{V}[g(S)]$  pour  $g(x) = n/x$ .
- Méthode delta : si  $\sqrt{n}(S_n - \mu) \xrightarrow{d} \mathcal{N}(0, \sigma^2)$ , alors pour  $g$  dérivable en  $\mu$  :

$$\sqrt{n}(g(S_n) - g(\mu)) \xrightarrow{d} \mathcal{N}(0, [g'(\mu)]^2 \sigma^2)$$

- Conséquence pratique pour  $n$  grand :

$$\boxed{\mathbb{V}[g(S)] \approx [g'(\mathbb{E}[S])]^2 \cdot \mathbb{V}[S]}$$

- Justification par développement de Taylor de  $g$  autour de  $\mathbb{E}[S]$  :

$$g(S) \approx g(\mathbb{E}[S]) + g'(\mathbb{E}[S])(S - \mathbb{E}[S])$$

$$\text{d'où } \mathbb{V}[g(S)] \approx [g'(\mathbb{E}[S])]^2 \mathbb{V}[S].$$

## Loi géométrique – Variance : approximation par méthode delta

- ▶ On a  $\hat{p} = n/S = g(S)$  avec  $g(x) = n/x$ .
- ▶ Application :  $g'(x) = -n/x^2$ , donc  $g'(\mathbb{E}[S]) = -n/(n/p)^2 = -p^2/n$ .

$$\mathbb{V}[\hat{p}] \approx \left(\frac{p^2}{n}\right)^2 \cdot \mathbb{V}[S] = \frac{p^4}{n^2} \cdot \frac{n(1-p)}{p^2}$$

$$\boxed{\mathbb{V}[\hat{p}] \approx \frac{p^2(1-p)}{n}}$$

- ▶ Cette approximation est asymptotique : elle devient exacte quand  $n \rightarrow \infty$ .

## Loi géométrique – Information de Fisher

- Dérivée seconde :

$$\frac{\partial^2 \ell}{\partial p^2} = -\frac{n}{p^2} - \frac{S - n}{(1 - p)^2}$$

- Sachant que  $\mathbb{E}[S] = n\mathbb{E}[X] = n/p$  :

$$I(p) = -\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial p^2} \right] = \frac{n}{p^2} + \frac{n/p - n}{(1 - p)^2} = \frac{n}{p^2} + \frac{n(1 - p)}{p(1 - p)^2}$$

$$I(p) = \frac{n}{p^2(1 - p)}$$

- Borne de Cramér-Rao (cas sans biais) :  $\mathbb{V}[\hat{p}] \geq \frac{1}{I(p)} = \frac{p^2(1 - p)}{n}$

## Loi géométrique – Efficacité : MSE vs borne de Cramér-Rao

- ▶ La variance peut être calculée avec de l'intégration numérique.
- ▶ On peut aussi calculer l'erreur quadratique moyenne de l'estimateur :

$$\text{MSE}[\hat{p}] = \mathbb{V}[\hat{p}] + \text{Biais}[\hat{p}]^2$$

- ▶ Exemple pour  $p = 0.5$  :

$n$	Biais <sup>2</sup>	Variance	CR	MSE	CR/Var
1	0.037	0.102	0.125	0.139	123%
5	0.002	0.028	0.025	0.031	89%
10	0.001	0.014	0.0125	0.014	92%
50	0.000	0.003	0.0025	0.003	98%

- ▶ Le biais domine en petit échantillon, puis devient négligeable.

## Loi géométrique – Efficacité selon $p$

- L'efficacité dépend fortement de  $p$  (ici pour  $n = 5$ ) :

$p$	$\mathbb{E}[\hat{p}]$	Biais	Variance	CR	MSE	CR/Var
0.2	0.236	+0.036	0.011	0.0064	0.012	58%
0.5	0.549	+0.049	0.028	0.025	0.031	89%
0.8	0.828	+0.028	0.021	0.0256	0.022	122%

- Pour  $p$  petit :  $\text{Variance} > \text{CR}$  (estimateur à variance élevée)
- Pour  $p$  grand :  $\text{Variance} < \text{CR}$  (possible car l'estimateur est biaisé)
- Explication : pour  $p$  petit, les  $X_i$  sont grands et variables, amplifiant le biais de  $\hat{p} = 1/\bar{X}$ .



## Loi géométrique – Efficacité asymptotique

- ▶ Résumé :

- ▶ L'estimateur  $\hat{p} = n/S$  est biaisé pour  $n$  fini

- ▶ Le biais est positif :  $\mathbb{E}[\hat{p}] > p$

- ▶ Le biais tend vers 0 quand  $n \rightarrow \infty$  : estimateur asymptotiquement sans biais

- ▶ Quand  $n \rightarrow \infty$  :

$$\mathbb{V}[\hat{p}] \sim \frac{p^2(1-p)}{n} = \frac{1}{I(p)}$$

- ▶ L'EMV  $\hat{p}$  est asymptotiquement efficace, comme attendu.

## Loi géométrique – Un estimateur sans biais

- ▶ À partir de l'expression du biais, on peut construire un estimateur sans biais. Pour  $n \geq 2$ , considérons l'estimateur :

$$\tilde{p} = \frac{n-1}{S-1}$$

- ▶ On utilise l'identité :  $\frac{1}{k-1} \binom{k-1}{n-1} = \frac{1}{n-1} \binom{k-2}{n-2}$

- ▶ Calcul de l'espérance :

$$\begin{aligned}\mathbb{E} \left[ \frac{n-1}{S-1} \right] &= (n-1) \sum_{k=n}^{\infty} \frac{1}{k-1} \binom{k-1}{n-1} p^n q^{k-n} \\ &= \sum_{k=n}^{\infty} \binom{k-2}{n-2} p^n q^{k-n} = p^n \sum_{j=0}^{\infty} \binom{j+n-2}{n-2} q^j \\ &= p^n \cdot \frac{1}{(1-q)^{n-1}} = p^n \cdot \frac{1}{p^{n-1}} = \boxed{p}\end{aligned}$$

## Loi géométrique – Variance de l'estimateur sans biais

► Pour  $n = 2$ , on a  $\tilde{p} = \frac{1}{S-1}$  avec  $S \sim \text{NegBin}(2, p)$ .

► En utilisant des techniques similaires aux calculs précédents :

$$\mathbb{E} \left[ \frac{1}{(S-1)^2} \right] = \frac{p}{2} (-\log p) = -\frac{p \log p}{2}$$

► Variance exacte pour  $n = 2$  :

$$\mathbb{V}[\tilde{p}] = \mathbb{E} \left[ \frac{1}{(S-1)^2} \right] - p^2 = -\frac{p \log p}{2} - p^2$$

## Loi géométrique – La borne de Cramér-Rao est-elle atteignable ?

- Comparaison pour  $n = 2$ ,  $p = 0.5$  :

Estimateur	Variance	MSE	Biais
$\tilde{p} = (n - 1)/(S - 1)$ (sans biais)	0.097	0.097	0
$\hat{p} = n/S$ (EMV)	0.067	0.080	0.114
Borne de Cramér-Rao	0.0625	–	–

- On a  $\mathbb{V}[\tilde{p}] > \mathbb{V}[\hat{p}] > 0.0625 = \text{BCR}$  : aucun estimateur n'est efficace à distance finie.
- Cependant, puisque :

$$\tilde{p} = \frac{n - 1}{S - 1} = \hat{p} \cdot \frac{n - 1}{n}$$

L'EMV  $\hat{p}$  étant asymptotiquement efficient, l'estimateur sans biais  $\tilde{p}$  l'est aussi.

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

**Loi Gamma**

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi Gamma – Présentation

- ▶ La loi Gamma généralise la loi exponentielle et modélise :
  - ▶ Temps d'attente jusqu'au  $\alpha$ -ième événement (processus de Poisson)
  - ▶ Précipitations, débits de rivières (hydrologie)
  - ▶ Temps de service dans les files d'attente
  - ▶ Distribution des revenus, taille des sinistres (assurance)
- ▶ Cas particuliers :
  - ▶  $\alpha = 1$  : loi exponentielle
  - ▶  $\alpha = n/2, \beta = 1/2$  : loi du chi-deux à  $n$  degrés de liberté

## Loi Gamma – Modèle (forme connue)

- ▶  $X_i \sim \text{Gamma}(\alpha, \beta)$  avec  $\alpha > 0$  connu et  $\beta > 0$  inconnu :

$$f(x; \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}, \quad x > 0$$

- ▶ Moments :

$$\mathbb{E}[X] = \frac{\alpha}{\beta}, \quad \mathbb{V}[X] = \frac{\alpha}{\beta^2}$$

- ▶ La somme  $S = \sum_{i=1}^n X_i \sim \text{Gamma}(n\alpha, \beta)$ .

## Loi Gamma – Log-vraisemblance

- Log-vraisemblance :

$$\ell(\beta) = n\alpha \log \beta - n \log \Gamma(\alpha) + (\alpha - 1) \sum_{i=1}^n \log x_i - \beta \sum_{i=1}^n x_i$$



## Loi Gamma – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \beta} = \frac{n\alpha}{\beta} - \sum_{i=1}^n x_i = 0$$

- Solution :

$$\hat{\beta}_{MV} = \frac{n\alpha}{\sum_{i=1}^n X_i} = \frac{\alpha}{\bar{X}}$$

- Si  $\alpha$  était aussi inconnu, pas de forme explicite pour  $\hat{\alpha}$ .

## Loi Gamma – Variance exacte de l'estimateur

► On a  $\hat{\beta} = n\alpha/S$  où  $S \sim \text{Gamma}(n\alpha, \beta)$ .

► Pour  $n\alpha > 2$  :

$$\mathbb{E}[\hat{\beta}] = \frac{n\alpha\beta}{n\alpha - 1}, \quad \mathbb{E}[\hat{\beta}^2] = \frac{(n\alpha)^2\beta^2}{(n\alpha - 1)(n\alpha - 2)}$$

► Variance exacte :

$$\mathbb{V}[\hat{\beta}] = \frac{(n\alpha)^2\beta^2}{(n\alpha - 1)^2(n\alpha - 2)}$$

► Pour  $n$  grand :  $\mathbb{V}[\hat{\beta}] \approx \frac{\beta^2}{n\alpha}$

## Loi Gamma – Information de Fisher

► Dérivée seconde :  $\frac{\partial^2 \ell}{\partial \beta^2} = -\frac{n\alpha}{\beta^2}$

► Information de Fisher :

$$I(\beta) = -\mathbb{E} \left[ \frac{\partial^2 \ell}{\partial \beta^2} \right] = \frac{n\alpha}{\beta^2}$$

► Borne de Cramér-Rao :  $\mathbb{V}[\hat{\beta}] \geq \frac{\beta^2}{n\alpha}$

► Plus  $\alpha$  est grand, plus l'estimation est précise.

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

**Loi log-normale**

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi log-normale – Présentation

- ▶ La loi log-normale modélise des phénomènes multiplicatifs :
  - ▶ Prix des actions, rendements financiers
  - ▶ Taille des particules, diamètre des gouttelettes
  - ▶ Distribution des revenus, des richesses
  - ▶ Durée de survie en médecine
  - ▶ Concentrations chimiques
- ▶ Caractéristique :  $X$  suit une loi log-normale  $\Leftrightarrow \log X$  suit une loi normale.

## Loi log-normale – Modèle

- ▶  $X_i \sim \text{LogNormal}(\mu, \sigma^2)$  si  $\log X_i \sim \mathcal{N}(\mu, \sigma^2)$  :

$$f(x; \mu, \sigma^2) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left(-\frac{(\log x - \mu)^2}{2\sigma^2}\right), \quad x > 0$$

- ▶ Moments de  $X$  :

$$\mathbb{E}[X] = e^{\mu + \sigma^2/2}, \quad \mathbb{V}[X] = e^{2\mu + \sigma^2} (e^{\sigma^2} - 1)$$

## Loi log-normale – Log-vraisemblance

- En posant  $Y_i = \log X_i \sim \mathcal{N}(\mu, \sigma^2)$  :

$$\begin{aligned}\ell(\mu, \sigma^2) = & -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \sum_{i=1}^n \log x_i \\ & - \frac{1}{2\sigma^2} \sum_{i=1}^n (\log x_i - \mu)^2\end{aligned}$$

- C'est la log-vraisemblance d'un échantillon normal sur les  $Y_i = \log X_i$ .

## Loi log-normale – Estimateurs MV

- Conditions du premier ordre :

$$\frac{\partial \ell}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (\log x_i - \mu) = 0, \quad \frac{\partial \ell}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (\log x_i - \mu)^2 = 0$$

- Solutions :

$$\hat{\mu}_{MV} = \frac{1}{n} \sum_{i=1}^n \log X_i = \overline{\log X}, \quad \hat{\sigma}_{MV}^2 = \frac{1}{n} \sum_{i=1}^n (\log X_i - \hat{\mu})^2$$



## Loi log-normale – Variance exacte des estimateurs

► Les  $Y_i = \log X_i$  sont i.i.d.  $\mathcal{N}(\mu, \sigma^2)$ .

► Pour  $\hat{\mu} : \hat{\mu} = \bar{Y} \sim \mathcal{N}\left(\mu, \frac{\sigma^2}{n}\right)$ , donc  $\mathbb{V}[\hat{\mu}] = \frac{\sigma^2}{n}$

► Pour  $\hat{\sigma}^2 : \frac{n\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-1}^2$ , donc  $\mathbb{V}[\hat{\sigma}^2] = \frac{2(n-1)\sigma^4}{n^2}$

## Loi log-normale – Matrice d'information de Fisher

- Dérivées secondes :

$$\frac{\partial^2 \ell}{\partial \mu^2} = -\frac{n}{\sigma^2}, \quad \frac{\partial^2 \ell}{\partial \mu \partial \sigma^2} = -\frac{1}{\sigma^4} \sum_{i=1}^n (\log x_i - \mu)$$

- Matrice d'information de Fisher :

$$I(\mu, \sigma^2) = n \begin{pmatrix} \frac{1}{\sigma^2} & 0 \\ 0 & \frac{1}{2\sigma^4} \end{pmatrix}$$

- Les paramètres sont orthogonaux :  $\hat{\mu}$  et  $\hat{\sigma}^2$  sont asymptotiquement indépendants.

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

**Loi de Pareto**

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi de Pareto – Présentation

- ▶ La loi de Pareto modélise des phénomènes avec des valeurs extrêmes fréquentes :
  - ▶ Distribution des revenus et des richesses (loi des 80-20)
  - ▶ Taille des villes, des entreprises
  - ▶ Popularité des sites web, des mots dans un texte
  - ▶ Montants des sinistres en assurance
  - ▶ Magnitude des tremblements de terre
- ▶ Propriété : décroissance en loi de puissance (queue épaisse) :  $P(X > x) \propto x^{-\alpha}$

## Loi de Pareto – Modèle

- ▶  $X_i \sim \text{Pareto}(\alpha, x_m)$  avec  $x_m > 0$  connu et  $\alpha > 0$  inconnu :

$$f(x; \alpha) = \frac{\alpha x_m^\alpha}{x^{\alpha+1}}, \quad x \geq x_m$$

- ▶ Moments (pour  $\alpha > 2$ ) :

$$\mathbb{E}[X] = \frac{\alpha x_m}{\alpha - 1}, \quad \mathbb{V}[X] = \frac{\alpha x_m^2}{(\alpha - 1)^2(\alpha - 2)}$$

- ▶ Attention : la variance n'existe que si  $\alpha > 2$ .

# Loi de Pareto – Log-vraisemblance

- Log-vraisemblance :

$$\ell(\alpha) = n \log \alpha + n\alpha \log x_m - (\alpha + 1) \sum_{i=1}^n \log x_i$$

## Loi de Pareto – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial \alpha} = \frac{n}{\alpha} + n \log x_m - \sum_{i=1}^n \log x_i = 0$$

- Solution :

$$\hat{\alpha}_{MV} = \frac{n}{\sum_{i=1}^n \log X_i - n \log x_m} = \frac{n}{\sum_{i=1}^n \log(X_i/x_m)}$$

C'est l'inverse de la moyenne des log-rapports.

## Loi de Pareto – Variance exacte de l'estimateur

- Posons  $Y_i = \log(X_i/x_m)$ . Si  $X_i \sim \text{Pareto}(\alpha, x_m)$ , alors  $Y_i \sim \text{Exp}(\alpha)$ .
- Donc  $S = \sum_{i=1}^n Y_i \sim \text{Gamma}(n, \alpha)$  et  $\hat{\alpha} = n/S$ .
- Pour  $n > 2$  :  $\mathbb{E}[\hat{\alpha}] = \frac{n\alpha}{n-1}$

$$\mathbb{V}[\hat{\alpha}] = \frac{n^2\alpha^2}{(n-1)^2(n-2)}$$

- Asymptotiquement :  $\mathbb{V}[\hat{\alpha}] \approx \frac{\alpha^2}{n}$



## Loi de Pareto – Information de Fisher

- ▶ Dérivée seconde :  $\frac{\partial^2 \ell}{\partial \alpha^2} = -\frac{n}{\alpha^2}$  (ne dépend pas des observations !)
- ▶ Information de Fisher :  $I(\alpha) = \frac{n}{\alpha^2}$
- ▶ Borne de Cramér-Rao :  $\mathbb{V}[\hat{\alpha}] \geq \frac{\alpha^2}{n}$
- ▶ Même forme que pour la loi exponentielle (lien via la transformation log).

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

**Loi binomiale négative**

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi binomiale négative – Présentation

- ▶ La loi binomiale négative modélise le nombre d'échecs avant  $r$  succès :
  - ▶ Nombre de lancers ratés avant de gagner  $r$  fois
  - ▶ Nombre de clients non intéressés avant  $r$  ventes
  - ▶ Données de comptage avec surdispersion (alternative à Poisson)
  - ▶ Nombre d'accidents par conducteur (hétérogénéité)
- ▶ Relations :
  - ▶  $r = 1$  : loi géométrique
  - ▶ Mélange Poisson-Gamma : modélise la surdispersion

## Loi binomiale négative – Modèle

- $X_i \sim \text{NegBin}(r, p)$  avec  $r > 0$  connu et  $p \in (0, 1)$  inconnu :

$$P(X = k) = \binom{k+r-1}{k} (1-p)^k p^r, \quad k = 0, 1, 2, \dots$$

( $X$  = nombre d'échecs avant  $r$  succès)

- Moments :

$$\mathbb{E}[X] = \frac{r(1-p)}{p}, \quad \mathbb{V}[X] = \frac{r(1-p)}{p^2}$$

## Loi binomiale négative – Log-vraisemblance

- Log-vraisemblance (avec  $S = \sum_{i=1}^n x_i$ ) :

$$\ell(p) = \text{const} + S \log(1 - p) + nr \log p$$

## Loi binomiale négative – Estimateur MV

- Condition du premier ordre :

$$\frac{\partial \ell}{\partial p} = -\frac{S}{1-p} + \frac{nr}{p} = 0 \quad \Rightarrow \quad nrp = S(1-p)$$

- Solution :

$$\hat{p}_{MV} = \frac{nr}{nr + S} = \frac{r}{r + \bar{X}}$$

## Loi binomiale négative – Variance de l'estimateur

- ▶ Méthode delta avec  $g(x) = r/(r + x)$  et  $g'(x) = -r/(r + x)^2$ .
- ▶ Avec  $\mathbb{E}[\bar{X}] = r(1 - p)/p : r + \mathbb{E}[\bar{X}] = r/p$ , donc  $g'(\mathbb{E}[\bar{X}]) = -p^2/r$ .
- ▶ Variance approchée :

$$\mathbb{V}[\hat{p}] \approx \frac{p^4}{r^2} \cdot \frac{r(1 - p)}{np^2} = \boxed{\frac{p^2(1 - p)}{nr}}$$

## Loi binomiale négative – Information de Fisher

► Dérivée seconde :  $\frac{\partial^2 \ell}{\partial p^2} = -\frac{S}{(1-p)^2} - \frac{nr}{p^2}$

► Espérance (avec  $\mathbb{E}[S] = nr(1-p)/p$ ) :

$$I(p) = \frac{nr(1-p)/p}{(1-p)^2} + \frac{nr}{p^2} = \boxed{\frac{nr}{p^2(1-p)}}$$

► Borne de Cramér-Rao :  $\mathbb{V}[\hat{p}] \geq \frac{p^2(1-p)}{nr} \checkmark$



# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

**Loi de Cauchy**

Loi uniforme – Un cas singulier

Synthèse

# Loi de Cauchy – Présentation

- ▶ La loi de Cauchy apparaît dans plusieurs contextes :
  - ▶ Rapport de deux variables normales indépendantes centrées
  - ▶ Distribution de certains phénomènes physiques (résonance)
  - ▶ Modélisation de données avec valeurs extrêmes fréquentes
  - ▶ Finance : modèles à queues épaisses
- ▶ Exemple : si  $X, Y \stackrel{iid}{\sim} \mathcal{N}(0, 1)$ , alors  $X/Y \sim \text{Cauchy}(0, 1)$ .

## Loi de Cauchy – Modèle

- ▶  $X_i \sim \text{Cauchy}(\mu, \sigma)$  avec  $\mu \in \mathbb{R}$  (position) et  $\sigma > 0$  (échelle) :

$$f(x; \mu, \sigma) = \frac{1}{\pi \sigma \left( 1 + \left( \frac{x - \mu}{\sigma} \right)^2 \right)}$$

- ▶ Fonction de répartition :

$$F(x; \mu, \sigma) = \frac{1}{\pi} \arctan \left( \frac{x - \mu}{\sigma} \right) + \frac{1}{2}$$

- ▶ Propriétés de symétrie :

- ▶  $\mu$  est la médiane et le mode
- ▶ Distribution symétrique autour de  $\mu$

# Loi de Cauchy – Absence de moments

## Propriété fondamentale

La loi de Cauchy n'a ni espérance ni variance !

- Pour que  $\mathbb{E}[X]$  existe, il faut que l'intégrale soit absolument convergente, i.e.  $\mathbb{E}[|X|] < \infty$ .

- Vérification pour  $\mu = 0$ ,  $\sigma = 1$  :

$$\mathbb{E}[|X|] = \int_{-\infty}^{\infty} \frac{|x|}{\pi(1+x^2)} dx = \frac{2}{\pi} \int_0^{\infty} \frac{x}{1+x^2} dx = \frac{2}{\pi} \left[ \frac{1}{2} \log(1+x^2) \right]_0^{\infty} = +\infty$$

- L'intégrale diverge logarithmiquement :  $\mathbb{E}[X]$  n'existe pas.

# Loi de Cauchy – Conséquences sur les estimateurs classiques

- ▶ Si  $X_1, \dots, X_n \stackrel{iid}{\sim} \text{Cauchy}(\mu, \sigma)$  :

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \sim \text{Cauchy}(\mu, \sigma)$$

La moyenne suit la même loi quelle que soit la taille de l'échantillon !

- ▶ Fonction caractéristique d'une v.a. de Cauchy  $\varphi(t) = e^{i\mu t - \sigma|t|}$
- ▶ Pour la somme :  $\varphi_{\sum X_i}(t) = e^{in\mu t - n\sigma|t|}$
- ▶ Pour la moyenne :  $\varphi_{\bar{X}}(t) = \varphi_{\sum X_i}(t/n) = e^{i\mu t - \sigma|t|}$

## Loi de Cauchy – Pourquoi l'EMV fonctionne quand même

- ▶ Les conditions de Cramér-Rao sont satisfaites
- ▶ Ces conditions ne requièrent pas l'existence des moments de  $X$  !
- ▶ L'information de Fisher fait intervenir  $\mathbb{E} \left[ \left( \frac{\partial \log f}{\partial \theta} \right)^2 \right]$ , pas  $\mathbb{E}[X]$ .

# Loi de Cauchy – Log-vraisemblance

- Cas général ( $\mu$  et  $\sigma$  inconnus) :

$$\ell(\mu, \sigma) = -n \log \pi - n \log \sigma - \sum_{i=1}^n \log \left( 1 + \left( \frac{x_i - \mu}{\sigma} \right)^2 \right)$$

- Cas simplifié ( $\sigma = 1$  connu, estimation de  $\mu$  seul) :

$$\ell(\mu) = -n \log \pi - \sum_{i=1}^n \log (1 + (x_i - \mu)^2)$$

# Loi de Cauchy – Équations du maximum de vraisemblance

- Dérivée par rapport à  $\mu$  (avec  $\sigma = 1$ ) :

$$\frac{\partial \ell}{\partial \mu} = \sum_{i=1}^n \frac{2(x_i - \mu)}{1 + (x_i - \mu)^2} = 0$$

- En posant  $u_i = x_i - \mu$ , on cherche  $\mu$  tel que :

$$\sum_{i=1}^n \frac{u_i}{1 + u_i^2} = 0$$

- C'est une somme pondérée où les observations extrêmes reçoivent un poids faible (la fonction  $u \mapsto \frac{u}{1+u^2}$  est bornée par  $\pm 1/2$ ).



## Loi de Cauchy – Robustesse de l'EMV

- ▶ La fonction  $\psi(u) = \frac{2u}{1+u^2}$  qui apparaît dans l'équation de l'EMV :
  - ▶ Est bornée :  $|\psi(u)| \leq 1$
  - ▶ Tend vers 0 quand  $|u| \rightarrow \infty$
- ▶ L'EMV de  $\mu$  est naturellement robuste aux valeurs extrêmes, contrairement à la moyenne empirique.
- ▶ Une observation très éloignée a une contribution bornée à l'équation d'estimation.

# Loi de Cauchy – Résolution numérique

- ▶ L'équation  $\sum_{i=1}^n \frac{x_i - \mu}{1 + (x_i - \mu)^2} = 0$  n'a pas de forme fermée.
- ▶ Méthodes de résolution :
  - ▶ Newton-Raphson avec  $\frac{\partial^2 \ell}{\partial \mu^2} = \sum_{i=1}^n \frac{2[(x_i - \mu)^2 - 1]}{[1 + (x_i - \mu)^2]^2}$
  - ▶ Point fixe :  $\mu^{(k+1)} = \frac{\sum_i w_i(\mu^{(k)}) x_i}{\sum_i w_i(\mu^{(k)})}$  avec  $w_i(\mu) = \frac{1}{1 + (x_i - \mu)^2}$
  - ▶ Optimisation directe de  $\ell(\mu)$
- ▶ La médiane empirique est un bon point de départ.

## Loi de Cauchy – Information de Fisher pour $\mu$

- Score (avec  $\sigma = 1$ ) :

$$\frac{\partial \log f}{\partial \mu} = \frac{2(x - \mu)}{1 + (x - \mu)^2}$$

- Information de Fisher pour une observation :

$$I_1(\mu) = \mathbb{E} \left[ \left( \frac{\partial \log f}{\partial \mu} \right)^2 \right] = \int_{-\infty}^{\infty} \frac{4(x - \mu)^2}{[1 + (x - \mu)^2]^2} \cdot \frac{1}{\pi[1 + (x - \mu)^2]} dx$$

- En posant  $u = x - \mu$  :  $I_1(\mu) = \frac{4}{\pi} \int_{-\infty}^{\infty} \frac{u^2}{(1+u^2)^3} du$

## Loi de Cauchy – Calcul de l'information de Fisher

- ▶ On utilise  $\int_{-\infty}^{\infty} \frac{u^2}{(1+u^2)^3} du = \frac{\pi}{8}$  (par résidus, ou par parties).
- ▶ Résultat :  $I_1(\mu) = \frac{4}{\pi} \cdot \frac{\pi}{8} = \frac{1}{2}$
- ▶ Information de Fisher pour  $n$  observations :

$$I_n(\mu) = \frac{n}{2}$$

## Loi de Cauchy – Variance asymptotique de l'EMV

► Borne de Cramér-Rao :  $\mathbb{V}[\hat{\mu}_{MV}] \geq \frac{1}{I_n(\mu)} = \frac{2}{n}$

► L'EMV est asymptotiquement efficace :

$$\sqrt{n}(\hat{\mu}_{MV} - \mu) \xrightarrow{d} \mathcal{N}(0, 2)$$

► Variance asymptotique :

$$\boxed{\mathbb{V}[\hat{\mu}_{MV}] \approx \frac{2}{n}}$$

► Malgré l'absence de moments de  $X$ , l'EMV a une variance qui décroît en  $1/n$  !

## Loi de Cauchy – Cas général avec $\sigma$ inconnu

- Équations de vraisemblance :

$$\frac{\partial \ell}{\partial \mu} = \frac{2}{\sigma^2} \sum_{i=1}^n \frac{x_i - \mu}{1 + \left(\frac{x_i - \mu}{\sigma}\right)^2} = 0$$

$$\frac{\partial \ell}{\partial \sigma} = -\frac{n}{\sigma} + \frac{2}{\sigma^3} \sum_{i=1}^n \frac{(x_i - \mu)^2}{1 + \left(\frac{x_i - \mu}{\sigma}\right)^2} = 0$$

- Système non linéaire à résoudre numériquement (Newton-Raphson multidimensionnel).

## Loi de Cauchy – Matrice d'information de Fisher

- Pour le modèle complet  $(\mu, \sigma)$  :

$$I_1(\mu, \sigma) = \frac{1}{2\sigma^2} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Les paramètres sont orthogonaux.

- Pour  $n$  observations :

$$I_n(\mu, \sigma) = \frac{n}{2\sigma^2} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

- Variances asymptotiques :

$$\mathbb{V}[\hat{\mu}_{MV}] \approx \frac{2\sigma^2}{n}, \quad \mathbb{V}[\hat{\sigma}_{MV}] \approx \frac{2\sigma^2}{n}$$

## Loi de Cauchy – Comparaison des estimateurs de $\mu$

- La médiane  $\tilde{\mu}$  est un estimateur consistant avec :

$$\mathbb{V}[\tilde{\mu}] \approx \frac{1}{4n[f(\mu)]^2} = \frac{\pi^2 \sigma^2}{4n}$$

Pour  $\sigma = 1$  :  $\mathbb{V}[\tilde{\mu}] \approx \frac{2.47}{n}$

- Tableau comparatif (pour  $\sigma = 1$ ) :

Estimateur	Consistant ?	Var. asympt.	Efficacité
Moyenne $\bar{X}$	<b>Non</b>	$\nexists$	–
Médiane $\tilde{\mu}$	Oui	$\pi^2/(4n) \approx 2.47/n$	81%
EMV $\hat{\mu}_{MV}$	Oui	$2/n$	100%



# Loi de Cauchy – Efficacité relative

- ▶ Rapport des variances :

$$e(\tilde{\mu}, \hat{\mu}_{MV}) = \frac{\mathbb{V}[\hat{\mu}_{MV}]}{\mathbb{V}[\tilde{\mu}]} = \frac{2/n}{\pi^2/(4n)} = \frac{8}{\pi^2} \approx 0.81$$

- ▶ Pour atteindre la même précision que l'EMV avec  $n$  observations, la médiane nécessite environ  $n/0.81 \approx 1.23n$  observations.
- ▶ Compromis pratique :
  - ▶ La médiane est simple à calculer et robuste
  - ▶ L'EMV est plus efficace mais nécessite une optimisation numérique
  - ▶ La médiane est un excellent point de départ pour l'algorithme de l'EMV

## Loi de Cauchy – Résumé

- ▶ La loi de Cauchy n'a pas de moments (espérance, variance).
- ▶ La moyenne empirique ne converge pas (suit toujours une loi de Cauchy).
- ▶ Malgré cela, l'EMV est consistant et asymptotiquement normal.
- ▶ L'information de Fisher est bien définie :  $I_n(\mu) = n/2$  (pour  $\sigma = 1$ ).
- ▶ Variance asymptotique de l'EMV :  $2\sigma^2/n$ .
- ▶ L'EMV est plus efficace que la médiane (rapport  $\approx 81\%$ ).
- ▶ L'EMV est naturellement robuste aux valeurs extrêmes.

# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

# Loi uniforme – Présentation

- ▶ La loi uniforme modélise l'incertitude totale dans un intervalle :
  - ▶ Erreurs d'arrondi
  - ▶ Position d'un point sur un segment
  - ▶ Génération de nombres pseudo-aléatoires
  - ▶ Modèle de base en théorie des probabilités

**Attention : cas non-régulier !**

La loi uniforme est un exemple où les conditions de régularité de Cramér-Rao ne sont pas satisfaites.

## Loi uniforme – Modèle

- $X_i \sim U(0, \theta)$  avec  $\theta > 0$  inconnu :

$$f(x; \theta) = \begin{cases} \frac{1}{\theta} & \text{si } 0 \leq x \leq \theta \\ 0 & \text{sinon} \end{cases}$$

- Moments :  $\mathbb{E}[X] = \frac{\theta}{2}$ ,  $\mathbb{V}[X] = \frac{\theta^2}{12}$

### Le problème

Le support  $[0, \theta]$  dépend du paramètre  $\theta$  !


# Loi uniforme – Vraisemblance

- Vraisemblance :

$$L(\theta) = \prod_{i=1}^n f(x_i; \theta) = \begin{cases} \frac{1}{\theta^n} & \text{si } \theta \geq \max_i x_i \\ 0 & \text{sinon} \end{cases}$$

- $L(\theta) = 0$  si  $\theta < X_{(n)} = \max(X_1, \dots, X_n)$
- $L(\theta) = \theta^{-n}$  est décroissante pour  $\theta \geq X_{(n)}$
- Maximum atteint en  $\theta = X_{(n)}$
- Estimateur MV :  $\hat{\theta}_{MV} = X_{(n)} = \max(X_1, \dots, X_n)$

## Loi uniforme – Vraisemblance (représentation graphique)



- La vraisemblance est nulle pour  $\theta < X_{(n)}$ , puis décroît en  $\theta^{-n}$ .
- Le maximum est atteint en  $\theta = X_{(n)}$  (discontinuité).

## Loi uniforme – Pourquoi c'est un cas singulier ?

- ▶ Les conditions de Cramér-Rao supposent que :
  1. Le support de  $f(x; \theta)$  ne dépend pas de  $\theta$  **VIOLÉ**
  2. On peut intervertir dérivation et intégration
  3. La log-vraisemblance est deux fois dérivable en  $\theta$
- ▶ Conséquences :
  - ▶ L'information de Fisher classique ne s'applique pas
  - ▶ La borne de Cramér-Rao n'est pas valide
  - ▶ L'estimateur peut converger plus vite que  $1/\sqrt{n}$  !



## Loi uniforme – Distribution de l'estimateur

- Fonction de répartition du maximum :

$$F_{X_{(n)}}(x) = P(X_{(n)} \leq x) = P(\text{tous les } X_i \leq x) = \prod_{i=1}^n P(X_i \leq x)$$

Pour  $0 \leq x \leq \theta$  :  $F_{X_{(n)}}(x) = \left(\frac{x}{\theta}\right)^n$

- Densité du maximum :

$$f_{X_{(n)}}(x) = \frac{nx^{n-1}}{\theta^n}, \quad 0 \leq x \leq \theta$$

- C'est une loi Beta( $n, 1$ ) mise à l'échelle sur  $[0, \theta]$ .

## Loi uniforme – Calcul de l'espérance

- Calcul direct :

$$\mathbb{E}[X_{(n)}] = \int_0^\theta x \cdot \frac{nx^{n-1}}{\theta^n} dx = \frac{n}{\theta^n} \int_0^\theta x^n dx = \frac{n}{\theta^n} \cdot \frac{\theta^{n+1}}{n+1}$$

$$\boxed{\mathbb{E}[X_{(n)}] = \frac{n}{n+1}\theta}$$

- Biais :  $\text{Biais}(\hat{\theta}) = \mathbb{E}[X_{(n)}] - \theta = -\frac{\theta}{n+1}$
- L'estimateur MV est biaisé (il sous-estime systématiquement  $\theta$ ).

## Loi uniforme – Estimateur sans biais

- Puisque  $\mathbb{E}[X_{(n)}] = \frac{n}{n+1}\theta$ , on peut définir :

$$\tilde{\theta} = \frac{n+1}{n}X_{(n)}$$

Alors  $\mathbb{E}[\tilde{\theta}] = \theta$  : c'est un estimateur sans biais.

- Autre estimateur sans biais : la moyenne  $\bar{X}$  vérifie  $\mathbb{E}[\bar{X}] = \theta/2$ , donc  $\tilde{\theta}_2 = 2\bar{X}$  est aussi sans biais, mais il est moins efficace que  $\tilde{\theta}$ .

## Loi uniforme – Calcul de la variance

- Moment d'ordre 2 :

$$\mathbb{E}[X_{(n)}^2] = \int_0^\theta x^2 \cdot \frac{nx^{n-1}}{\theta^n} dx = \frac{n}{\theta^n} \cdot \frac{\theta^{n+2}}{n+2} = \frac{n}{n+2} \theta^2$$

- Variance :

$$\mathbb{V}[X_{(n)}] = \mathbb{E}[X_{(n)}^2] - \mathbb{E}[X_{(n)}]^2 = \frac{n}{n+2} \theta^2 - \left( \frac{n}{n+1} \right)^2 \theta^2$$

$$\boxed{\mathbb{V}[X_{(n)}] = \frac{n\theta^2}{(n+1)^2(n+2)}}$$

## Loi uniforme – Convergence exceptionnelle

- Développement asymptotique :

$$\mathbb{V}[X_{(n)}] = \frac{n\theta^2}{(n+1)^2(n+2)} \sim \frac{\theta^2}{n^2} \quad \text{quand } n \rightarrow \infty$$

- Comparaison des vitesses de convergence :

Cas	Variance	Vitesse
Cas régulier (Cramér-Rao)	$\approx c/n$	$O(1/n)$
Loi uniforme	$\approx \theta^2/n^2$	$O(1/n^2)$

### Résultat remarquable

L'estimateur du maximum converge deux fois plus vite qu'habituellement !

## Loi uniforme – Comparaison des estimateurs

- Variance de  $\tilde{\theta} = \frac{n+1}{n}X_{(n)}$  :

$$\mathbb{V}[\tilde{\theta}] = \left(\frac{n+1}{n}\right)^2 \mathbb{V}[X_{(n)}] = \frac{\theta^2}{n(n+2)}$$

- Variance de  $\tilde{\theta}_2 = 2\bar{X}$  :

$$\mathbb{V}[\tilde{\theta}_2] = 4 \cdot \mathbb{V}[\bar{X}] = 4 \cdot \frac{\theta^2/12}{n} = \frac{\theta^2}{3n}$$

- Rapport d'efficacité :

$$\frac{\mathbb{V}[\tilde{\theta}]}{\mathbb{V}[\tilde{\theta}_2]} = \frac{\theta^2/[n(n+2)]}{\theta^2/(3n)} = \frac{3}{n+2} \rightarrow 0$$

L'estimateur basé sur le maximum est beaucoup plus efficace.

## Loi uniforme – Distribution asymptotique

- Posons  $Y_n = n(\theta - X_{(n)})$ . Pour  $y \geq 0$  :

$$P(Y_n > y) = P\left(X_{(n)} < \theta - \frac{y}{n}\right) = \left(1 - \frac{y}{n\theta}\right)^n$$

- Quand  $n \rightarrow \infty$  :  $\left(1 - \frac{y}{n\theta}\right)^n \rightarrow e^{-y/\theta}$

### Distribution asymptotique

$$n(\theta - X_{(n)}) \xrightarrow{d} \text{Exp}(1/\theta)$$

Convergence vers une loi exponentielle, pas une loi normale !

## Loi uniforme – Résumé des originalités

1. Estimateur MV :  $\hat{\theta} = X_{(n)} = \max(X_1, \dots, X_n)$
2. Distribution exacte : Beta( $n, 1$ ) sur  $[0, \theta]$
3. Biais :  $-\theta/(n+1)$  (sous-estimation systématique)
4. Variance exacte :  $\frac{n\theta^2}{(n+1)^2(n+2)} = O(1/n^2)$
5. Distribution asymptotique : exponentielle, pas normale
6. Information de Fisher : non applicable (conditions violées)



# Plan

Loi normale

Loi de Bernoulli

Loi de Poisson

Loi exponentielle

Loi géométrique

Loi Gamma

Loi log-normale

Loi de Pareto

Loi binomiale négative

Loi de Cauchy

Loi uniforme – Un cas singulier

Synthèse

## Tableau récapitulatif (1/2)

Loi	Param.	EMV	Variance
Normale	$\mu$	$\bar{X}$	$\frac{\sigma^2}{n}$ (exacte, efficace)
Normale	$\sigma^2$	$\frac{1}{n} \sum (X_i - \bar{X})^2$	$\frac{2(n-1)\sigma^4}{n^2}$
Bernoulli	$p$	$\bar{X}$	$\frac{p(1-p)}{n}$ (exacte, efficace)
Poisson	$\lambda$	$\bar{X}$	$\frac{\lambda}{n}$ (exacte, efficace)
Exponentielle	$\lambda$	$1/\bar{X}$	$\frac{n^2 \lambda^2}{(n-1)^2 (n-2)}$
Géométrique	$p$	$1/\bar{X}$	$\approx \frac{p^2(1-p)}{n}$

## Tableau récapitulatif (2/2)

Loi	Param.	EMV	Variance
Gamma ( $\alpha$ connu)	$\beta$	$\alpha/\bar{X}$	$\frac{(n\alpha)^2\beta^2}{(n\alpha-1)^2(n\alpha-2)}$
Log-normale	$\mu$	$\overline{\log X}$	$\frac{\sigma^2}{n}$ (exacte)
Pareto ( $x_m$ connu)	$\alpha$	$n/\sum \log(X_i/x_m)$	$\frac{n^2\alpha^2}{(n-1)^2(n-2)}$
Binomiale nég.	$p$	$r/(r+\bar{X})$	$\approx \frac{p^2(1-p)}{nr}$
Cauchy	$\mu$	numérique	$\approx \frac{2\sigma^2}{n}$
Uniforme	$\theta$	$X_{(n)}$	$\frac{n\theta^2}{(n+1)^2(n+2)}$

Légende : Bleu = pas de moments, EMV fonctionne ; Rouge = conditions violées,  $O(1/n^2)$

## Conclusion

- ▶ L'EMV est généralement asymptotiquement efficace (atteint la borne de Cramér-Rao).
- ▶ La matrice d'information de Fisher permet de quantifier la précision de l'estimation.
- ▶ Les conditions de régularité sont essentielles : leur violation (loi uniforme) peut conduire à des comportements atypiques.
- ▶ L'absence de moments (loi de Cauchy) n'empêche pas l'EMV de fonctionner si les conditions de régularité sont satisfaites.
- ▶ La distribution asymptotique est généralement normale, sauf dans les cas non-réguliers (loi uniforme  $\rightarrow$  exponentielle).
- ▶ Quand l'estimateur est une fonction non linéaire de statistiques simples, la méthode delta permet d'approximer la variance.