

Estimation ponctuelle

Modèle paramétrique

On observe un échantillon (X_1, \dots, X_n) où les X_j sont des v.a. i.i.d.. On parle d'un modèle paramétrique si la loi commune des X_j appartient à une famille paramètre $\mathcal{P} = \{\mathbb{P}_\theta, \theta \in \Theta\}$.

Exemple 1. Modèle de Bernoulli: $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$, $\theta = p$, $\Theta = [0, 1]$.

Modèle Uniforme: $\mathcal{P} = \{\mathcal{U}([0, \theta]), \theta \in \Theta = \mathbb{R}_+ \setminus \{0\}\}$.

Modèle Gaussien: $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), \mu \in \mathbb{R}, \sigma^2 \in \mathbb{R}_+ \setminus \{0\}\}$, $\theta = (\mu, \sigma^2)$, $\Theta = \mathbb{R} \times (\mathbb{R}_+ \setminus \{0\})$

Notations.

- $\mathbb{P}_\theta(X \in A)$: probabilité que $X \in A$ lorsque X suit \mathbb{P}_θ .
- $\mathbb{E}_\theta[h(X)]$: Espérance de $h(X)$ lorsque X suit \mathbb{P}_θ .
- Si X est une v.a. discrète, i.e. X est à valeurs dans un ensemble au plus dénombrable $X \in \{1, 2, \dots\}$ on note $\mathbb{P}_\theta(X = x) = p(x, \theta)$.
- Si X est une v.a. continue alors on notera $f(x, \theta)$ la densité de X selon \mathbb{P}_θ .
- Soit $X = (X_1, \dots, X_n)$ un échantillon de taille n où les X_j sont i.i.d.

1. Dans le cas discret: $\mathbb{P}_\theta(X = x) = p(x, \theta) = \prod_{j=1}^n p(x_j, \theta)$

2. Dans le cas continu: $f(x, \theta) = \prod_{j=1}^n f(x_j, \theta)$

ou $x = (x_1, \dots, x_n)$ est la réalisation de l'échantillon $X = (X_1, \dots, X_n)$.

Exemple 2. Dans le modèle de Bernoulli (X_1, \dots, X_n) un échantillon de n v.a. i.i.d. $\sim \mathcal{B}(p)$, où $p \in [0, 1]$,

$$p(x, p) = \prod_{j=1}^n p(x_j, p) = \prod_{j=1}^n [p^{x_j}(1-p)^{1-x_j}] = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j}.$$

Dans le modèle Gaussien

$$f(x, \mu, \sigma^2) = \prod_{j=1}^n f(x_j, \mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j - \mu)^2}$$

Définition 3. On appelle statistique toute v.a. S qui dépend de l'échantillon (X_1, \dots, X_n) mais qui ne fait pas intervenir le paramètre θ .

Exemple 4. Quelques statistiques:

- $\sum_{j=1}^n X_j$

- \bar{X}_n (la moyenne empirique)
- $\max_{1 \leq j \leq n} (X_j)$
- $\frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2$ (variance empirique)

Mais θX_1 et $(\bar{X}_n + \theta^2 \max_{1 \leq j \leq n} (X_j))$ ne sont pas des statistique.

Estimation ponctuelle

Définition 5. Soit g une application sur Θ . On appelle estimateur (ponctuel) de $g(\theta)$ toute statistique T prenant ses valeurs dans $g(\Theta)$.

Exemple 6. Dans le modèle de Bernoulli $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$ la moyenne empirique \bar{X}_n est un estimateur de p ($g(p) = p$ c-à-d g est l'identité sur $\Theta = [0, 1]$).

Dans le modèle Gaussien $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2), (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+^*\}$ la variance empirique

$$S_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2$$

est un estimateur de σ^2 ($g(\mu, \sigma^2) = \sigma^2$) et $S_n = \sqrt{S_n^2}$ (l'écart-type empirique) est un estimateur de σ (l'écart-type théorique).

Quelques propriétés des estimateurs

Définition 7. Un estimateur T de $g(\theta)$ est dit sans biais (ou non biaisé) si $\mathbb{E}_\theta[T] = g(\theta)$. Autrement, le biais $b(\theta) = \mathbb{E}_\theta[T] - g(\theta) = 0$.

Définition 8. On appelle risque quadratique d'un estimateur T , et on note $R(T, \theta)$ la quantité $R(T, \theta) = \mathbb{E}_\theta[(T - g(\theta))^2]$. En particulier, si T est sans biais alors $R(T, \theta) = \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2] = \text{Var}_\theta(T)$.

Remarque 9. On peut toujours écrire

$$R(T, \theta) = \text{Var}_\theta(T) + (b(\theta))^2$$

donc dans le risque il y a une partie due à la variance de la statistique et un autre du à son biais. En effet

$$\begin{aligned} R(T, \theta) &= \mathbb{E}_\theta[(T - g(\theta))^2] = \mathbb{E}_\theta[((T - \mathbb{E}_\theta[T]) + (\mathbb{E}_\theta[T] - g(\theta)))^2] \\ &= \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2] + 2(\mathbb{E}_\theta[T] - g(\theta))(T - \mathbb{E}_\theta[T]) + (\mathbb{E}_\theta[T] - g(\theta))^2 \\ &= \mathbb{E}_\theta[(T - \mathbb{E}_\theta[T])^2] + 2b(\theta)\mathbb{E}_\theta[T - \mathbb{E}_\theta[T]] + (b(\theta))^2 \\ &= \text{Var}_\theta(T) + (b(\theta))^2 \end{aligned}$$

Définition 10. Soient T_1 et T_2 deux estimateurs non biaisés de $g(\theta)$. On dira que T_2 est plus efficace de T_1 si $R(T_2, \theta) \leq R(T_1, \theta)$ pour tout $\theta \in \Theta$, c-à-d $\text{Var}_\theta(T_2) \leq \text{Var}_\theta(T_1)$ pour tout $\theta \in \Theta$.

Exemple 11. Reprenons l'exemple du modèle de Bernoulli $\mathcal{P} = \{\mathcal{B}(p), p \in [0, 1]\}$. Comparons les estimateurs X_1 et \bar{X}_n (Il s'agit d'estimer le paramètre p).

$\mathbb{E}[X_1] = p$ donc X_1 est un estimateur non biaisé de p .

$\mathbb{E}[\bar{X}_n] = p \Rightarrow \bar{X}_n$ est aussi un estimateur non biaisé de p .

$$R(X_1, p) = \text{Var}_p(X_1) = p(1-p)$$

$$R(\bar{X}_n, p) = \text{Var}_p(\bar{X}_n) = (\text{Var}_p(X_1) + \dots + \text{Var}_p(X_n))/n^2 = p(1-p)/n$$

On en déduit que $\text{Var}_p(\bar{X}_n) \leq \text{Var}_p(X_1)$ pour tout $p \in [0, 1]$ donc \bar{X}_n est un estimateur plus efficace que X_1 .

Exemple 12. Modèle Uniforme. $\mathcal{P} = \{\mathcal{U}([0, \theta]), \theta \in \mathbb{R}_+^*\}$, $f(x, \theta) = \theta^{-1} \mathbb{I}_{x \in [0, \theta]}$. On considère les estimateurs suivants: $T_1 = 2\bar{X}_n$ et $T_2 = [(n+1)/n] \max_{1 \leq j \leq n} X_j$.

On observe un échantillon de taille n . Montrons que ces estimateurs sont non biaisés:

$$\mathbb{E}_\theta[2\bar{X}_n] = 2\mathbb{E}_\theta[X_1] = 2 \frac{\theta}{2} = \theta \text{ (non biaisé)}$$

On pose $Y = \max_{1 \leq j \leq n} X_j$. Soit $y \in \mathbb{R}$,

$$\mathbb{P}_\theta(Y \leq y) = \mathbb{P}_\theta(X_1 \leq y, \dots, X_n \leq y) = \mathbb{P}_\theta(X_1 \leq y)^n = \begin{cases} 0 & \text{si } y \leq 0 \\ (y/\theta)^n & \text{si } y \in [0, \theta] \\ 1 & \text{si } y > \theta \end{cases}$$

Donc Y admet pour densité la fonction $g(y, \theta)$ donnée par

$$g(y, \theta) = \frac{n}{\theta^n} y^{n-1} \mathbb{I}_{0 \leq y \leq \theta}$$

et

$$\mathbb{E}_\theta[Y] = \int_0^\theta \frac{n}{\theta^n} y^n dy = \frac{n}{n+1} \theta$$

ce qui donne

$$\mathbb{E}_\theta[T_2] = \frac{n+1}{n} \mathbb{E}_\theta[Y] = \theta$$

et par conséquent T_2 est un estimateur non biaisé de θ . Calculons les variances respectives de T_1 et T_2 :

$$\text{Var}_\theta(T_1) = 4\text{Var}_\theta(\bar{X}_n) = \frac{4}{n} \text{Var}_\theta(X_1) = \frac{\theta^2}{3n}$$

et

$$\text{Var}_\theta(T_2) = \left(\frac{n+1}{n}\right)^2 \text{Var}_\theta(Y) = \left(\frac{n+1}{n}\right)^2 \left[\mathbb{E}_\theta[Y^2] - \left(\frac{n}{n+1}\right)^2 \theta^2 \right]$$

Or

$$\mathbb{E}_\theta[Y^2] = \int_0^\theta \frac{n}{\theta^n} y^{n+1} dy = \frac{n}{n+2} \theta^2$$

donc

$$\text{Var}_\theta(T_2) = \left(\frac{n+1}{n}\right)^2 \left[\frac{n}{n+2} - \left(\frac{n}{n+1}\right)^2 \right] \theta^2 = \frac{\theta^2}{n(n+2)}$$

et

$$\frac{\text{Var}_\theta(T_2)}{\text{Var}_\theta(T_1)} = \frac{3}{n+2} \leq 1$$

qui montre que T_2 est plus efficace que T_1 .

Définition 13. Soit l'application $g: \Theta \rightarrow \mathbb{R}^d$. On dit que la suite $(T_n)_{n \geq 1}$ d'estimateurs de $g(\theta)$ est

1. *Convergente:* si $(T_n)_{n \geq 1}$ converge en probabilité vers $g(\theta)$ pour tout $\theta \in \Theta$.
2. *Fortement convergente:* si $(T_n)_{n \geq 1}$ converge presque sûrement vers $g(\theta)$ pour tout $\theta \in \Theta$.
3. *Asymptotiquement normale:* si pour tout $\theta \in \Theta$ existe une matrice de covariance $\Sigma(\theta)$ telle que $\sqrt{n}(T_n - g(\theta)) \xrightarrow{\mathcal{L}} \mathcal{N}_d(0, \Sigma(\theta))$.

Exemple 14. Soient X_1, \dots, X_n un échantillon de loi $\mathcal{B}(p)$. D'après la loi forte des grandes nombres

$$\bar{X}_n \xrightarrow{p.s.} p \quad \text{pour tout } p \in [0, 1]$$

la suite $(X_n)_{n \geq 1}$ est fortement convergente. De plus $\text{Var}_p(X_1) = p(1-p) < +\infty$ et d'après le TCL

$$\sqrt{n}(\bar{X}_n - p) \xrightarrow{\mathcal{L}} \mathcal{N}(0, p(1-p))$$

la suite $(X_n)_{n \geq 1}$ est asymptotiquement normale avec $\Sigma(p) = p(1-p)$.

Exhaustivité

Définition 15. Une statistique S est dite exhaustive si la loi conditionnelle de $X = (X_1, \dots, X_n)$ sachant $S = s$ ne dépend pas du paramètre θ pour tout s .

Théorème 16. (De factorisation) S est une statistique exhaustive ssi il existe des applications g et h telles que

$$p(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta) \quad \text{dans le cas discret}$$

$$f(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta) \quad \text{dans le cas continu}$$

Rappel. $p(\mathbf{x}, \theta) = \prod_{j=1}^n p(x_j, \theta)$ et $f(\mathbf{x}, \theta) = \prod_{j=1}^n f(x_j, \theta)$

Démonstration. (Uniquement dans le cas discret). (\Rightarrow) Supposons que S est exhaustive. $p(\mathbf{x}, \theta) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} \text{ et } S(\mathbf{X}) = S(\mathbf{x}))$ car $\{S(\mathbf{X}) = S(\mathbf{x})\} \supseteq \{\mathbf{X} = \mathbf{x}\}$. Donc $\mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x})) \mathbb{P}_\theta(S(\mathbf{X}) = S(\mathbf{x}))$. Or S est exhaustive $\Rightarrow \mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x}))$ ne dépend pas de θ : $\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x})) = \mathbb{P}(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x}))$ et on pose $g(\mathbf{x}) = \mathbb{P}(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x}))$ et $h(s, \theta) = \mathbb{P}_\theta(S(\mathbf{X}) = s)$. Il vient que

$$p(\mathbf{x}, \theta) = \mathbb{P}(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = S(\mathbf{x})) \mathbb{P}_\theta(S(\mathbf{X}) = S(\mathbf{x})) = g(\mathbf{x}) h(S(\mathbf{x}), \theta).$$

(\Leftarrow) Réciproquement, supposons qu'il existe g et h telles que

$$p(\mathbf{x}, \theta) = g(\mathbf{x}) h(S(\mathbf{x}), \theta)$$

et montrons que S est exhaustive. Fixons s . On pose $A_s = \{\mathbf{y} : S(\mathbf{y}) = s\}$.

$$\mathbb{P}_\theta(S(\mathbf{X}) = s) = \sum_{\mathbf{x} \in A_s} \mathbb{P}_\theta(\mathbf{X} = \mathbf{x}) = \sum_{\mathbf{x} \in A_s} g(\mathbf{x}) h(S(\mathbf{x}), \theta) = h(s, \theta) \sum_{\mathbf{x} \in A_s} g(\mathbf{x})$$

$$\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = s) = \frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x}, S(\mathbf{X}) = s)}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} = \begin{cases} 0 & \text{si } s \neq S(\mathbf{x}) \\ \frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x})}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} & \text{si } s = S(\mathbf{x}) \end{cases}$$

Si $s = S(\mathbf{x})$

$$\frac{\mathbb{P}_\theta(\mathbf{X} = \mathbf{x})}{\mathbb{P}_\theta(S(\mathbf{X}) = s)} = \frac{g(\mathbf{x}) h(s, \theta)}{h(s, \theta) \sum_{\mathbf{x} \in A_s} g(\mathbf{x})} = \frac{g(\mathbf{x})}{\sum_{\mathbf{x} \in A_s} g(\mathbf{x})}$$

donc

$$\mathbb{P}_\theta(\mathbf{X} = \mathbf{x} | S(\mathbf{X}) = s) = \begin{cases} 0 & \text{si } s \neq S(\mathbf{x}) \\ \frac{g(\mathbf{x})}{\sum_{\mathbf{x} \in A_s} g(\mathbf{x})} & \text{si } s = S(\mathbf{x}) \end{cases}$$

qui ne dépend pas de θ et qui donne l'exhaustivité de S . □

Exemple 17. Soit $\mathbf{X} = (X_1, \dots, X_n)$ un échantillon de Bernoulli de paramètre p et $S(\mathbf{X}) = \sum_{j=1}^n X_j$. Montrons que S est exhaustive pour p .

$$p(\mathbf{x}, \theta) = \prod_{j=1}^n p^{x_j} (1-p)^{1-x_j} = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j} = g(\mathbf{x}) h(S(\mathbf{x}), p)$$

avec $g(\mathbf{x}) = 1$ et $h(s, p) = p^s (1-p)^{n-s}$. Par le théorème de factorisation on en déduit que S est exhaustive pour p .

Exemple 18. Soit $\mathbf{X} = (X_1, \dots, X_n)$ un échantillon Gaussien de moyenne μ et variance σ^2 . On pose

$$S(\mathbf{X}) = \left(\sum_{j=1}^n X_j, \sum_{j=1}^n X_j^2 \right).$$

Montrons que S est exhaustive pour (μ, σ^2) :

$$\begin{aligned} f(\mathbf{x}, \theta) &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j - \mu)^2} = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} \sum_{j=1}^n (x_j^2 - 2\mu x_j + \mu^2)} \\ &= \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} (\sum_{j=1}^n x_j^2 - 2\mu \sum_{j=1}^n x_j + n\mu^2)} = g(\mathbf{x}) h(S(\mathbf{X}), (\mu, \sigma^2)) \end{aligned}$$

où $g(\mathbf{x}) = 1$ et

$$h((s_1, s_2), (\mu, \sigma^2)) = \frac{1}{(2\pi\sigma^2)^{n/2}} e^{-\frac{1}{2\sigma^2} (s_2 - 2\mu s_1 + n\mu^2)}$$

Par le théorème de factorisation on en déduit que S est exhaustive pour (μ, σ^2) .

Méthodes d'estimation

Méthode des moments

Définition 19. Soit $r \in \mathbb{N}^*$. Si X est une v.a. réelle t.a. $\mathbb{E}[|X|^r] < +\infty$ alors on appelle $\mathbb{E}[X^r]$ le moment d'ordre r de X et on le note m_r .

Définition 20. On appelle moment empirique d'ordre r la statistique

$$\frac{1}{n} \sum_{j=1}^n (X_j)^r$$

que on notera $M_{r,n}$.

Exemple 21. $M_{1,n} = \bar{X}_n$ et $M_{2,n} = n^{-1} \sum_{j=1}^n X_j^2$.

Définition 22. Soit $\theta = (\theta_1, \dots, \theta_d) \in \Theta \subseteq \mathbb{R}^d$. On suppose que X est une v.a. réelle telle que $\mathbb{E}[|X|^d] < +\infty$. S'il existe des applications $\varphi_1, \dots, \varphi_d$ telles que $\theta_j = \varphi_j(m_1, m_2, \dots, m_d)$, alors l'estimateur obtenu par la méthode des moments est donnée par

$$\hat{\theta}_n = (\varphi_1(M_{1,n}, \dots, M_{d,n}), \dots, \varphi_d(M_{1,n}, \dots, M_{d,n})).$$

Exemple 23. $X \sim \mathcal{P}(\lambda)$, $\lambda > 0$. $\lambda = \mathbb{E}[X] = m_1$. L'estimateur de λ obtenu par la méthode des moments est

$$\hat{\lambda}_n = M_{1,n} = \bar{X}_n.$$

Exemple 24. $X \sim \mathcal{N}(\mu, \sigma^2)$. $\mu = \mathbb{E}[X] = m_1$ et $\sigma^2 = \text{Var}(X) = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = m_2 - m_1^2$. L'estimateur de $\theta = (\mu, \sigma^2)$ obtenu par la méthode des moments est $\hat{\theta}_n = (\hat{\mu}_n, \hat{\sigma}_n^2)$ où $\hat{\mu}_n = M_{1,n} = \bar{X}_n$ et $\hat{\sigma}_n^2 = M_{2,n} - M_{1,n}^2$:

$$\hat{\sigma}_n^2 = M_{2,n} - M_{1,n}^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}_n^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X}_n)^2 = S_n^2$$

la variance empirique.

Méthode de maximum de vraisemblance

Définition 25. Soit $\mathbf{x} = (x_1, \dots, x_n)$ une réalisation d'un échantillon $\mathbf{X} = (X_1, \dots, X_n)$ de n v.a. iid. La fonction $L_n(\mathbf{x}, \theta)$ (ou $L_n(\theta)$) donnée par

- $L_n(\theta) = L_n(\mathbf{x}, \theta) = p(\mathbf{x}, \theta) = \prod_{j=1}^n p(x_j, \theta)$ dans le cas discret
- $L_n(\theta) = L_n(\mathbf{x}, \theta) = f(\mathbf{x}, \theta) = \prod_{j=1}^n f(x_j, \theta)$ dans le cas continu

vue comme fonction de θ pour \mathbf{x} fixé, s'appelle la vraisemblance de la réalisation $\mathbf{x} = (x_1, \dots, x_n)$.

Définition 26. On suppose que pour toute réalisation $\mathbf{x} = (x_1, \dots, x_n)$ il existe une unique valeur $\hat{\theta}_n(\mathbf{x})$ qui maximise la vraisemblance $L_n(\mathbf{x}, \theta)$. Alors la statistique $\hat{\theta}_n(\mathbf{X})$ est appelée l'estimateur de maximum de vraisemblance (EMV) du paramètre θ . Il revient au même de maximiser la vraisemblance ou son logarithme, c-à-d la log-vraisemblance, souvent notée $\ell_n(\theta)$ ou $\ell_n(\mathbf{x}, \theta)$, i.e.

$$\ell_n(\mathbf{x}, \theta) = \ell_n(\theta) = \log L_n(\theta) = \begin{cases} \sum_{j=1}^n \log(p(x_j, \theta)) & \text{dans le cas discret;} \\ \sum_{j=1}^n \log(f(x_j, \theta)) & \text{dans le cas continu.} \end{cases}$$

Remarque 27. Pour chercher l'EMV, on cherchera les solutions de l'équation

$$\left(\frac{\partial \ell_n}{\partial \theta_1}, \dots, \frac{\partial \ell_n}{\partial \theta_d} \right) = (0, \dots, 0)$$

et vérifier que la matrice Hessienne

$$\left(\frac{\partial^2 \ell_n}{\partial \theta_i \partial \theta_j} \right)_{i,j=1,\dots,d}$$

est définie négative (on a supposé que $\theta \mapsto \ell_n(\theta)$ est $C^2(\Theta)$).

Exemple 28. Soit $\mathbf{X} = (X_1, \dots, X_n)$ un échantillon Bernoulli de paramètre $p \in [0, 1]$.

$$L_n(\mathbf{x}, p) = p^{\sum_{j=1}^n x_j} (1-p)^{n - \sum_{j=1}^n x_j}$$

$$\ell_n(\mathbf{x}, p) = \sum_{j=1}^n x_j \log(p) + \left(n - \sum_{j=1}^n x_j \right) \log(1-p)$$

$$\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = \sum_{j=1}^n x_j \frac{1}{p} - \left(n - \sum_{j=1}^n x_j \right) \frac{1}{1-p}$$

$$\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = 0 \iff \sum_{j=1}^n x_j \frac{1}{p} - \left(n - \sum_{j=1}^n x_j \right) \frac{1}{1-p} = 0$$

qui donne:

$$p = \frac{1}{n} \sum_{j=1}^n x_j$$

Donc $\frac{\partial \ell_n(\mathbf{x}, p)}{\partial p} = 0$ admet unique solution $\hat{p}_n = \frac{1}{n} \sum_{j=1}^n x_j = \bar{x}_n$ et

$$\frac{\partial^2 \ell_n(\mathbf{x}, p)}{\partial p^2} = - \sum_{j=1}^n x_j \frac{1}{p^2} - \left(n - \sum_{j=1}^n x_j \right) \frac{1}{(1-p)^2} < 0$$

ce qu'implique que \hat{p}_n est un maximum globale de $p \mapsto \ell_n(\mathbf{x}, p)$ et que l'EMV de p est \bar{X}_n .