

Cours du 15/01/2024

$X_i \sim N(m, \sigma^2)$ σ^2 connue $\theta = m$

$$\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n X_i \quad \begin{array}{l} E(X_i) \\ \text{Var}(X_i) \end{array}$$

$$\tilde{\theta}_n = \frac{2}{n(n+1)} \sum_{i=1}^n (i X_i)$$

Lequel des deux estimateurs est le meilleur?

Biais

$$\text{Biais de } \hat{\theta}_n = E(\hat{\theta}_n) - \theta = m$$

$$= E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] - m$$

$$= \frac{1}{n} \sum_{i=1}^n E(X_i) - m$$

linéarité
de E

$$= \frac{1}{n} \sum_{i=1}^n m - m = 0$$

l'estimateur $\hat{\theta}_n$ est non-biaisé (biais égal à θ)

$$\text{Biais de } \tilde{\theta}_n : E(\tilde{\theta}_n) - \theta = E\left[\frac{2}{n(n+1)} \sum_{i=1}^n i X_i\right] - m$$

$$= \frac{2}{n(n+1)} \sum_{i=1}^n \underbrace{E[i X_i]}_{i E(X_i)} - m$$

$$= \frac{2m}{n(n+1)} \underbrace{\left(\sum_{i=1}^n i\right)}_{\frac{n(n+1)}{2}} - m$$

$$\tilde{\theta}_n \text{ est aussi un estimateur non biaisé de } \theta = m = m - m = 0$$

variance des estimateurs

$$\text{Var}(aX + b) = a^2 \text{Var} X$$

$$\text{Si } X \text{ et } Y \text{ sont ind alors } \text{Var}(X+Y) = \text{Var} X + \text{Var} Y$$

$$\begin{aligned} \text{Var}[\hat{\theta}_n] &= \text{Var}\left[\frac{1}{n} \sum_{i=1}^n X_i\right] \\ &= \frac{1}{n^2} \text{Var}\left[\sum_{i=1}^n X_i\right] \\ &= \frac{1}{n^2} \sum_{i=1}^n \text{Var} X_i = \frac{n \sigma^2}{n^2} = \boxed{\frac{\sigma^2}{n}} \end{aligned}$$

\nearrow
 X_1, \dots, X_n ind

$$\begin{aligned} \text{Var}[\tilde{\theta}_n] &= \text{Var}\left[\frac{2}{n(n+1)} \sum_{i=1}^n i X_i\right] \\ &= \frac{4}{n^2(n+1)^2} \sum_{i=1}^n \text{Var}(i X_i) \\ &= \frac{4 \sigma^2}{n^2(n+1)^2} \sum_{i=1}^n i^2 \quad \left(\text{Admiss} \right) \\ &= \frac{2 \sigma^2}{3} \frac{2n+1}{n(n+1)} = \frac{\sigma^2}{n} \times \left[\frac{2}{3} \frac{2n+1}{n+1} \right] \\ &\approx \frac{4}{3} > 1 \quad n \rightarrow \infty \end{aligned}$$

\nearrow
les va $i X_i$ sont ind

donc $\text{Var}[\tilde{\theta}_n] > \text{Var}[\hat{\theta}_n]$ pour n "grand"

donc on préfère $\hat{\theta}_n$

$$E[(\hat{\theta} - \theta)^2] = (\text{biais})^2 + \text{Variance}$$

$$\begin{aligned} E[(\hat{\theta} - E(\hat{\theta}) + E(\hat{\theta}) - \theta)^2] &= E[(\hat{\theta} - E(\hat{\theta}))^2] \\ &\quad + E[(E(\hat{\theta}) - \theta)^2] + 2 E[(E(\hat{\theta}) - \theta)(\hat{\theta} - E(\hat{\theta}))] \end{aligned}$$

$\underbrace{\hspace{10em}}_{\text{biais}^2}$ $\underbrace{\hspace{10em}}_{\text{Var } \hat{\theta}}$ $\underbrace{\hspace{10em}}_{0 \text{ car } \perp}$

un aleatoire

donc $E[(\hat{\theta} - \theta)^2] = \text{Var } \hat{\theta} + (\text{biais})^2 + 2(E[\hat{\theta}] - \theta) E[\hat{\theta} - E[\hat{\theta}]]$

donc

$$\text{MSE}_m = \text{variance} + (\text{biais})^2$$

EQN

$$E[\hat{\theta}] - E(\underbrace{E[\hat{\theta}]}_{E[\hat{\theta}]}) = 0$$

MSE = mean square error

EQN = erreur quadratique moyenne

$$E[\otimes] \rightarrow \frac{1}{n} \sum_{i=1}^n \otimes$$

Exemple 2

$X_i \sim N(m, \sigma^2) \quad \theta = \sigma^2$

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

l'estimateur $\hat{\sigma}_n^2$ est-il biaisé ou non?

$$E[\hat{\sigma}_n^2] = \frac{1}{n} \sum_{i=1}^n E[(X_i - m + m - \bar{X}_n)^2]$$

variance de \bar{X}_n quand $\theta = m$

$$\sigma^2 \left(E[(X_i - m)^2] + E[(m - \bar{X}_n)^2] + 2 E[(X_i - m)(m - \bar{X}_n)] \right) = \frac{\sigma^2}{n}$$

calculé avant

$$-2 E\left[(X_i - m) \left(\frac{1}{n} \sum_{k=1}^n X_k - m \right) \right] = -2 E\left[\frac{(X_i - m)}{n} \sum_{k=1}^n (X_k - m) \right]$$

\uparrow
 $\frac{1}{n} \sum_{k=1}^n m$

$$= -\frac{2}{n} \sum_{k=1}^n E[(X_i - m)(X_k - m)] = \begin{cases} 0 & i \neq k \\ \sigma^2 & i = k \end{cases}$$

Conclusion

$$E[\hat{\sigma}_n^2] = \sigma^2 + \frac{\sigma^2}{n} - \frac{2\sigma^2}{n} = \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2 \neq \sigma^2$$

donc $\hat{\sigma}_n^2$ est un estimateur biaisé de σ^2

Un bon estimateur de σ^2 est $(\hat{\sigma}^2)^* = \frac{n}{n-1} \hat{\sigma}_n^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$

vraisemblance

$X_i \sim N(\mu, \sigma^2)$
Loi normale

$$L(x_1, \dots, x_n) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

$X_i \sim P(\lambda)$
Loi de Poisson

$$L(x_1, \dots, x_n) = \prod_{i=1}^n \left(\frac{\lambda^{x_i}}{x_i!} e^{-\lambda} \right)$$

Borne de Cramér-Rao pour un estimateur non biaisé de $\theta = m$
grand $X_i \sim N(\mu, \sigma^2)$

log vraisemblance

$$\sum_{i=1}^n \left[-\frac{1}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} (x_i - m)^2 \right]$$

$$\frac{\partial \ln L}{\partial m} = \sum_{i=1}^n \frac{-1}{2\sigma^2} 2(x_i - m)(-1) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - m)$$

$$\frac{\partial^2 \ln L}{\partial m^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (-1) = -\frac{n}{\sigma^2}$$

$$E\left[\frac{\partial^2 \ln L}{\partial \mu^2}\right] = E\left[-\frac{n}{\sigma^2}\right] = -\frac{n}{\sigma^2} \Rightarrow \boxed{\text{BCR} = \frac{\sigma^2}{n}}$$

On connaît un estimateur non biaisé de μ qui est $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i$
dont la variance est égale à $\frac{\sigma^2}{n}$
C'est le meilleur estimateur possible de μ

COURS du 5/02/2024

X_1, \dots, X_n échantillon de loi $P(v, \theta)$
 Estimer des moments de $\begin{pmatrix} v \\ \theta \end{pmatrix}$?

TABLES

$$\begin{cases} E[X_i] = \frac{v}{\theta} \\ E[X_i^2] = \text{Var } X_i + E[X_i]^2 = \frac{v}{\theta^2} + \frac{v^2}{\theta^2} \end{cases}$$

Inversion de ce système

$$\begin{cases} v = \theta E[X_i] \\ E[X_i^2] = \frac{v}{\theta} + E[X_i]^2 \end{cases} \Leftrightarrow \begin{cases} (E[X_i^2] - E^2[X_i]) \theta = E[X_i] \\ \text{d'où } \theta = \frac{E[X_i]}{E[X_i^2] - E^2[X_i]} \\ v = \frac{E^2[X_i]}{E[X_i^2] - E^2[X_i]} \end{cases}$$

Estimateurs des moments

$$\hat{\theta}_{Mo} = \frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}$$

$$\hat{v}_{Mo} = \frac{\left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}$$

BAYES

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

$$P(\theta | x_1, \dots, x_n) = \frac{P(x_1, \dots, x_n | \theta) P(\theta)}{P(x_1, \dots, x_n)}$$

Loi a posteriori de θ
← vraisemblance (a priori)
"constante" de normalisation
proportionnelle à $P(x_1, \dots, x_n | \theta) P(\theta)$

MMSE = minimum mean square error.

$$\hat{\theta}_{\text{MMSE}} = \text{moyenne de la loi a posteriori qui minimise } E[(\hat{\theta} - \theta)^2]$$

$$= E[\theta | x_1, \dots, x_n]$$

Exemple

$$x_i \sim N(\theta, \sigma^2) \Rightarrow \text{vraisemblance}$$

$$\prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x_i - \theta)^2}{2\sigma^2}\right] \quad (*)$$

Loi a priori $\theta \sim N(\mu, \nu^2)$ μ et ν connus

$$p(\theta) = \frac{1}{\sqrt{2\pi\nu^2}} \exp\left[-\frac{(\theta - \mu)^2}{2\nu^2}\right] \quad (**)$$

Estimateurs MAP et MMSE de θ ?

Loi a posteriori

$$p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2\right] \times \exp\left[-\frac{(\theta - \mu)^2}{2\nu^2}\right]$$

$$\ln p(\theta | x_1, \dots, x_n) = K - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2 - \frac{1}{2\nu^2} (\theta - \mu)^2$$

$$\frac{\partial \ln p}{\partial \theta} = 0 \Leftrightarrow -\frac{1}{\cancel{\sigma^2}} \sum_{i=1}^n \cancel{\cancel{x_i - \theta}} (-1) - \frac{1}{\cancel{2\nu^2}} \cancel{2} (\theta - \mu) = 0$$

$$\Leftrightarrow \frac{\theta}{\nu^2} + \frac{n\theta}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n x_i + \frac{\mu}{\nu^2}$$

$$\theta \left(\frac{1}{\nu^2} + \frac{n}{\sigma^2} \right)$$

$$\theta \left(\frac{\sigma^2 + n\nu^2}{\nu^2 \sigma^2} \right)$$

d'où

$$\theta = \frac{\nu^2}{\sigma^2 + n\nu^2} \sum_{i=1}^n x_i + \frac{\sigma^2}{\sigma^2 + n\nu^2} \mu$$

donc

$$\hat{\theta}_{\text{MAP}} = \frac{n\nu^2}{n\nu^2 + \sigma^2} \left(\frac{1}{n} \sum_{i=1}^n x_i \right) + \frac{\sigma^2}{\sigma^2 + n\nu^2} \mu$$

d_n

$\hat{\theta}_{MV}$
vient des données

vient de la loi a priori

n "grand"
 $n \rightarrow +\infty$
 $d_n \rightarrow 1$
 $1 - d_n \rightarrow 0$

$\hat{\theta}_{MAP} \approx \hat{\theta}_{MV}$
On fait confiance aux données !

n "petit"
 $n \rightarrow 0$
 $d_n \rightarrow 0$
 $1 - d_n \rightarrow 1$

$\hat{\theta}_{MAP} \approx \mu$
on fait confiance à l'information a priori!

$\sigma^2 \rightarrow 0$
 $d_n \approx 1$
 $1 - d_n \approx 0$
on fait confiance aux données !

$\sigma^2 \rightarrow +\infty$
 $d_n \approx 0$
 $1 - d_n \approx 1$
on fait confiance à l'info a priori !

Estimateur MMSE

$$\hat{\theta}_{MMSE} = E[\theta | x_1, \dots, x_n]$$

TD du 5/02

$$f(x) = \begin{cases} \frac{1}{\theta} x^{1/2-1} \exp(-\frac{x}{\theta}) & x > 0 \\ 0 & x \leq 0 \end{cases}$$

1) Loi de $U = X^{1/2}$ $\Leftrightarrow X = U^{1/2}$

$$g(u) = \frac{1}{\theta} u^{1/2-1} \exp(-\frac{u}{\theta}) \left| \frac{dx}{du} \right|$$

$\underbrace{\quad}_{\frac{1}{2} u^{1/2-1}}$

$$g(u) = \frac{1}{\theta} \exp(-\frac{u}{\theta})$$

Domaine de U

$$x > 0 \Leftrightarrow u^{1/2} > 0 \Leftrightarrow u > 0$$

$$\text{donc } g(u) = \frac{1}{\theta} \exp(-\frac{u}{\theta}) \mathbb{1}_{\mathbb{R}^+}(u)$$

$$U \sim \Gamma\left(\frac{1}{2}, \frac{1}{\theta}\right)$$

$$E[U] = \frac{a}{b} = \theta$$
$$\text{Var}(U) = \frac{a}{b^2} = \theta^2$$

2) Estimateur du max de vraisemblance de θ


vraisemblance $L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n \left[\frac{1}{\theta} x_i^{\theta-1} \exp\left(-\frac{x_i^\theta}{\theta}\right) \right]$

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

max de vraisemblance $\frac{\partial \ln L}{\partial \theta} \stackrel{\geq 0}{=} 0 \Leftrightarrow -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i^\theta \stackrel{\geq 0}{=} 0$

$\Leftrightarrow \theta = \frac{1}{n} \sum_{i=1}^n x_i^\theta$

donc $\hat{\theta}_{MV} = \frac{1}{n} \sum_{i=1}^n x_i^\theta$



Estimateur sans biais? convergent? efficace?

Biais $b_n(\theta) = E[\hat{\theta}] - \theta$
 $E[\hat{\theta}] = E\left[\frac{1}{n} \sum_{i=1}^n x_i^\theta\right] = \frac{1}{n} \sum_{i=1}^n E\left[\frac{x_i^\theta}{\sqrt{x_i}}\right]$
 $= \frac{1}{n} \sum_{i=1}^n \theta = \theta$

donc $\hat{\theta}$ non biaisé

Variance

$$\begin{aligned} \text{Var}(\hat{\theta}) &= \text{Var}\left[\frac{1}{n} \sum_{i=1}^n x_i^{\lambda}\right] \\ &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}\left(\frac{x_i^{\lambda}}{\sigma^2}\right) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 \\ &= \boxed{\frac{\sigma^2}{n}} \end{aligned}$$

x_1, \dots, x_n ind
 $\Rightarrow x_1^{\lambda}, \dots, x_n^{\lambda}$ ind

Biais $(\hat{\theta}) = 0 \Rightarrow \hat{\theta}$ convergent
 $\text{Var } \hat{\theta} \xrightarrow[n \rightarrow +\infty]{} 0$

Efficacité

$$\text{BCR} = \frac{1}{E\left[-\frac{\partial^2 \ln L}{\partial \theta^2}\right]}$$

$$\frac{\partial \ln L}{\partial \theta} = -\frac{n}{\theta} + \frac{1}{\sigma^2} \sum_{i=1}^n x_i^{\lambda}$$

$$\frac{\partial^2 \ln L}{\partial \theta^2} = \frac{n}{\theta^2} - \frac{2}{\sigma^2} \sum_{i=1}^n x_i^{\lambda}$$

$$E[\] = \frac{n}{\theta^2} - \frac{2}{\sigma^2} \sum_{i=1}^n \underbrace{E(x_i^{\lambda})}_{\theta} = \frac{n}{\theta^2} - \frac{2n}{\sigma^2} = -\frac{n}{\sigma^2}$$

donc $\boxed{\text{BCR} = \frac{\sigma^2}{n}}$


$\hat{\theta}$ non biaisé
 $\text{Var } \hat{\theta} = \text{BCR}$

$\Rightarrow \hat{\theta}$ est l'estimateur efficace de θ

Erreur quadratique moyenne

$$E[(\hat{\theta} - \theta)^2] = \text{Biais}^2 + \text{Variance} = \boxed{\frac{\theta^2}{3}}$$

Exo 1



$$E(T_i) = \frac{\theta}{2}$$
$$\text{Var}(T_i) = \frac{\theta^2}{12}$$

Taux

$$2) \quad \bar{T} = \frac{1}{n} \sum_{i=1}^n T_i \quad (= \hat{\theta})$$

$$E(\bar{T}) = \frac{1}{n} \sum_{i=1}^n E(T_i) = \frac{\theta}{2}$$

$$\text{donc } E(\bar{T}) - \theta = \frac{\theta}{2} - \theta = -\frac{\theta}{2} \neq 0$$

donc \bar{T} est un estimateur biaisé de θ

$$\hat{\theta} = 2\bar{T} \quad E(\hat{\theta}) = 2 \times \frac{\theta}{2} = \theta$$

$\hat{\theta}$ non biaisé

$$\text{Var} \hat{\theta} = 4 \text{Var}(\bar{T}) = 4 \text{Var}\left(\frac{1}{n} \sum T_i\right)$$


$$= \frac{4}{n^2} \sum_{i=1}^n \text{Var} T_i$$
$$= \frac{4}{n^2} \sum_{i=1}^n \frac{\theta^2}{12}$$

$$= \boxed{\frac{\theta^2}{3n}}$$


$$\begin{cases} \hat{\theta} \text{ non biaisé} \\ \text{Var} \hat{\theta} \xrightarrow[n \rightarrow \infty]{} 0 \end{cases} \text{ donc } \boxed{\hat{\theta} \text{ estimateur convergent}}$$

3) Estimateur du max de vraisemblance

$$L(t_1, \dots, t_n; \theta) = \prod_{i=1}^n \left[\frac{1}{\theta} \mathbb{1}_{]0, \theta[}(t_i) \right]$$



$$p(t_i) = \frac{1}{\theta} \mathbb{1}_{]0, \theta[}(t_i)$$



$$\boxed{\hat{\theta}_{ML} = \max_{i \in \{1, \dots, n\}} T_i}$$


$E(\hat{\theta}_{ML})$?

$$P[\sup T_i < y] = P[T_1 < y, \dots, T_n < y]$$

$$\begin{matrix} T_1, \dots, T_n \text{ ind.} \\ \nearrow \end{matrix} = \prod_{i=1}^n P(T_i < y)$$

$T_i \sim U(]0, \theta[)$ donc $P(T_i < y) = \begin{cases} 0 & y \leq 0 \\ \frac{y}{\theta} & y \in]0, \theta[\\ 1 & y \geq \theta \end{cases}$

$\int_0^y \frac{1}{\theta} dt_i$ y ∈]0, θ[



$$P(\underbrace{\text{Sup} T_i}_{Y_n} < y) = \begin{cases} 0 & y \leq 0 \\ 1 & y \geq \theta \\ \left(\frac{y}{\theta}\right)^n & y \in]0, \theta[\end{cases}$$

La densité de $\text{Sup} T_i$ est donc

$$p(y_n) = \begin{cases} 0 & y \notin]0, \theta[\\ \frac{n y^{n-1}}{\theta^n} & y \in]0, \theta[\end{cases}$$

$$P(X < x) = \int_{-\infty}^x p(u) du$$

Mojeux $E(Y_n) = \int_0^{\theta} y \frac{n y^{n-1}}{\theta^n} dy$

$$= \frac{n}{\theta^n} \left[\frac{y^{n+1}}{n+1} \right]_0^{\theta}$$

$$= \theta \frac{n}{n+1} \neq \theta$$

donc Y_n est biaisé

Mais $\frac{n+1}{n} Y_n = \hat{\theta}_2$ est bien un estimateur non biaisé de θ

Pour comparer $\hat{\theta}_1$ et $\hat{\theta}_2$, il faut calculer $Va(\hat{\theta}_2)$

$$\text{Var}[\hat{\theta}_2] = \text{Var}\left[\frac{n+1}{n} Y_n\right] = \left(\frac{n+1}{n}\right)^2 \text{Var} Y_n$$

$$\text{Var}(Y_n) = E(Y_n^2) - \underbrace{E(Y_n)}_{\left(\theta \frac{n}{n+1}\right)^2}$$

$$\int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{\theta^n} \frac{\theta^{n+2}}{n+2} = \theta^2 \frac{n}{n+2}$$

$$\begin{aligned} \text{Var}(Y_n) &= \left[\frac{n}{n+2} - \left(\frac{n}{n+1}\right)^2 \right] \theta^2 \\ &= n \frac{(n+1)^2 - n(n+2)}{(n+2)(n+1)^2} \theta^2 \end{aligned}$$

$$= \frac{n \theta^2}{(n+2)(n+1)^2}$$

donc $\boxed{\text{Var} \hat{\theta}_2 = \frac{\theta^2}{n(n+2)}}$

à comparer avec $\boxed{\text{Var } \hat{\theta}_1 = \frac{\theta^2}{3n}}$

On préfère l'estimateur $\hat{\theta}_2$ qui a une variance plus faible pour n grand !!

COURS du 5/02/2024

X_1, \dots, X_n échantillon de loi $P(v, \theta)$
 Estimer des moments de $\begin{pmatrix} v \\ \theta \end{pmatrix}$?

TABLES

$$\begin{cases} E[X_i] = \frac{v}{\theta} \\ E[X_i^2] = \text{Var } X_i + E[X_i]^2 = \frac{v}{\theta^2} + \frac{v^2}{\theta^2} \end{cases}$$

Inversion de ce système

$$\begin{cases} v = \theta E[X_i] \\ E[X_i^2] = \frac{E[X_i]}{\theta} + E[X_i]^2 \end{cases} \quad \Leftrightarrow$$

$$(E[X_i^2] - E^2[X_i]) \theta = E[X_i]$$

donc $\theta = \frac{E[X_i]}{E[X_i^2] - E^2[X_i]}$

$$v = \frac{E^2[X_i]}{E[X_i^2] - E^2[X_i]}$$

Estimateurs des moments

$$\hat{\theta}_{Mo} = \frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}$$

$$\hat{v}_{Mo} = \frac{\left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2}$$

BAYES

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

$$P(\theta | x_1, \dots, x_n) = \frac{P(x_1, \dots, x_n | \theta) P(\theta)}{P(x_1, \dots, x_n)}$$

Loi a posteriori de θ

vraisemblance (li a priori)

"constante" de normalisation

\propto proportionnel à $P(x_1, \dots, x_n | \theta) P(\theta)$

MMSE = minimum mean square error.

$$\hat{\theta}_{\text{MMSE}} = \text{moyenne de la loi a posteriori qui minimise } E[(\hat{\theta} - \theta)^2]$$

$$= E[\theta | x_1, \dots, x_n]$$

Exemple

$$x_i \sim N(\theta, \sigma^2) \Rightarrow \text{vraisemblance}$$

$$\prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(x_i - \theta)^2}{2\sigma^2}\right] \quad (*)$$

Loi a priori $\theta \sim N(\mu, \nu^2)$ μ et ν connus

$$p(\theta) = \frac{1}{\sqrt{2\pi\nu^2}} \exp\left[-\frac{(\theta - \mu)^2}{2\nu^2}\right] \quad (**)$$

Estimateurs MAP et MMSE de θ ?

Loi a posteriori

$$p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2\right] \times \exp\left[-\frac{(\theta - \mu)^2}{2\nu^2}\right]$$

$$\ln p(\theta | x_1, \dots, x_n) = K - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2 - \frac{1}{2\nu^2} (\theta - \mu)^2$$

$$\frac{\partial \ln p}{\partial \theta} = 0 \Leftrightarrow -\frac{1}{\cancel{\sigma^2}} \sum_{i=1}^n \cancel{\cancel{x_i - \theta}} (-1) - \frac{1}{\cancel{\nu^2}} \cancel{\cancel{\theta - \mu}} = 0$$

$$\Leftrightarrow \frac{\theta}{\nu^2} + \frac{n\theta}{\sigma^2} = \frac{1}{\sigma^2} \sum_{i=1}^n x_i + \frac{\mu}{\nu^2}$$

$$\theta \left(\frac{1}{\nu^2} + \frac{n}{\sigma^2} \right)$$

$$\theta \left(\frac{\sigma^2 + n\nu^2}{\nu^2 \sigma^2} \right)$$

d'où

$$\theta = \frac{\nu^2}{\sigma^2 + n\nu^2} \sum_{i=1}^n x_i + \frac{\sigma^2}{\sigma^2 + n\nu^2} \mu$$

donc

$$\hat{\theta}_{\text{MAP}} = \frac{n\nu^2}{n\nu^2 + \sigma^2} \left(\frac{1}{n} \sum_{i=1}^n x_i \right) + \frac{\sigma^2}{\sigma^2 + n\nu^2} \mu$$

d_n

$\hat{\theta}_{MV}$
vient des données

vient de la loi a priori

n "grand"
 $n \rightarrow +\infty$
 $d_n \rightarrow 1$
 $1 - d_n \rightarrow 0$

$\hat{\theta}_{MAP} \approx \hat{\theta}_{MV}$
On fait confiance aux données !

n "petit"
 $n \rightarrow 0$
 $d_n \rightarrow 0$
 $1 - d_n \rightarrow 1$

$\hat{\theta}_{MAP} \approx \mu$
on fait confiance à l'information a priori!

$\sigma^2 \rightarrow 0$
 $d_n \approx 1$
 $1 - d_n \approx 0$
on fait confiance aux données !

$\sigma^2 \rightarrow +\infty$
 $d_n \approx 0$
 $1 - d_n \approx 1$
on fait confiance à l'info a priori !

Estimateur MMSE

$$\hat{\theta}_{MMSE} = E[\theta | x_1, \dots, x_n]$$

TD du 5/02

$$f(x) = \begin{cases} \frac{1}{\theta} x^{1/2-1} \exp(-\frac{x}{\theta}) & x > 0 \\ 0 & x \leq 0 \end{cases}$$

1) Loi de $U = X^{1/2}$ $\Leftrightarrow X = U^{1/2}$

$$g(u) = \frac{1}{\theta} u^{1/2-1} \exp(-\frac{u}{\theta}) \left| \frac{dx}{du} \right|$$

$\underbrace{\quad}_{\frac{1}{2} u^{1/2-1}}$

$$g(u) = \frac{1}{\theta} \exp(-\frac{u}{\theta})$$

Domaine de U

$$x > 0 \Leftrightarrow u^{1/2} > 0 \Leftrightarrow u > 0$$

$$\text{donc } g(u) = \frac{1}{\theta} \exp(-\frac{u}{\theta}) \mathbb{1}_{\mathbb{R}^+}(u)$$

$$U \sim \Gamma\left(\frac{1}{2}, \frac{1}{\theta}\right)$$

$$E[U] = \frac{a}{b} = \theta$$
$$\text{Var}(U) = \frac{a}{b^2} = \theta^2$$

2) Estimateur du max de vraisemblance de θ


vraisemblance $L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n \left[\frac{1}{\theta} x_i^{\theta-1} \exp\left(-\frac{x_i^\theta}{\theta}\right) \right]$

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

max de vraisemblance $\frac{\partial \ln L}{\partial \theta} \stackrel{\geq 0}{=} 0 \Leftrightarrow -\frac{n}{\theta} + \frac{1}{\theta^2} \sum_{i=1}^n x_i^\theta \stackrel{\geq 0}{=} 0$

$\Leftrightarrow \theta = \frac{1}{n} \sum_{i=1}^n x_i^\theta$

donc $\hat{\theta}_{MV} = \frac{1}{n} \sum_{i=1}^n x_i^\theta$



Estimateur sans biais? convergent? efficace?

Biais $b_n(\theta) = E[\hat{\theta}] - \theta$

$$E[\hat{\theta}] = E\left[\frac{1}{n} \sum_{i=1}^n x_i^\theta\right] = \frac{1}{n} \sum_{i=1}^n E\left[\frac{x_i^\theta}{\sqrt{x_i}}\right]$$

$$= \frac{1}{n} \sum_{i=1}^n \theta = \theta$$

donc $\hat{\theta}$ non biaisé

Variance

$$\begin{aligned} \text{Var}(\hat{\theta}) &= \text{Var}\left[\frac{1}{n} \sum_{i=1}^n x_i^{\lambda}\right] \\ &= \frac{1}{n^2} \sum_{i=1}^n \text{Var}\left(\frac{x_i^{\lambda}}{\sigma^2}\right) = \frac{1}{n^2} \sum_{i=1}^n \sigma^2 \\ &= \boxed{\frac{\sigma^2}{n}} \end{aligned}$$

x_1, \dots, x_n ind
 $\Rightarrow x_1^{\lambda}, \dots, x_n^{\lambda}$ ind

Biais $(\hat{\theta}) = 0 \Rightarrow \hat{\theta}$ convergent
 $\text{Var } \hat{\theta} \xrightarrow[n \rightarrow +\infty]{} 0$

Efficacité

$$\text{BCR} = \frac{1}{E\left[-\frac{\partial^2 \ln L}{\partial \theta^2}\right]}$$

$$\frac{\partial \ln L}{\partial \theta} = -\frac{n}{\theta} + \frac{1}{\sigma^2} \sum_{i=1}^n x_i^{\lambda}$$

$$\frac{\partial^2 \ln L}{\partial \theta^2} = \frac{n}{\theta^2} - \frac{2}{\sigma^2} \sum_{i=1}^n x_i^{\lambda}$$

$$E[\] = \frac{n}{\theta^2} - \frac{2}{\sigma^2} \sum_{i=1}^n \underbrace{E(x_i^{\lambda})}_{\theta} = \frac{n}{\theta^2} - \frac{2n}{\sigma^2} = -\frac{n}{\sigma^2}$$

donc $\boxed{\text{BCR} = \frac{\sigma^2}{n}}$


$\hat{\theta}$ non biaisé
 $\text{Var } \hat{\theta} = \text{BCR}$

$\Rightarrow \hat{\theta}$ est l'estimateur efficace de θ

Erreur quadratique moyenne

$$E[(\hat{\theta} - \theta)^2] = \text{Biais}^2 + \text{Variance} = \boxed{\frac{\theta^2}{3}}$$

Exo 1



$$E(T_i) = \frac{\theta}{2}$$
$$\text{Var}(T_i) = \frac{\theta^2}{12}$$

Taux

$$2) \quad \bar{T} = \frac{1}{n} \sum_{i=1}^n T_i \quad (= \hat{\theta})$$

$$E(\bar{T}) = \frac{1}{n} \sum_{i=1}^n \underbrace{E(T_i)}_{\frac{\theta}{2}} = \frac{\theta}{2}$$

$$\text{donc } E(\bar{T}) - \theta = \frac{\theta}{2} - \theta = -\frac{\theta}{2} \neq 0$$

donc \bar{T} est un estimateur biaisé de θ

$$\hat{\theta} = 2\bar{T} \quad E(\hat{\theta}) = 2 \times \frac{\theta}{2} = \theta$$

$\hat{\theta}$ non biaisé

$$\text{Var} \hat{\theta} = 4 \text{Var}(\bar{T}) = 4 \text{Var}\left(\frac{1}{n} \sum T_i\right)$$


$$= \frac{4}{n^2} \sum_{i=1}^n \underbrace{\text{Var} T_i}_{\frac{\theta^2}{12}}$$

$$= \boxed{\frac{\theta^2}{3n}}$$


$$\begin{cases} \hat{\theta} \text{ non biaisé} \\ \text{Var} \hat{\theta} \xrightarrow[n \rightarrow \infty]{} 0 \end{cases} \text{ donc } \boxed{\hat{\theta} \text{ estimateur convergent}}$$

3) Estimateur du max de vraisemblance

$$L(t_1, \dots, t_n; \theta) = \prod_{i=1}^n \left[\frac{1}{\theta} \mathbb{1}_{]0, \theta[}(t_i) \right]$$



$$p(t_i) = \frac{1}{\theta} \mathbb{1}_{]0, \theta[}(t_i)$$



$$\boxed{\hat{\theta}_{ML} = \max_{i \in \{1, \dots, n\}} T_i}$$


$E(\hat{\theta}_{ML})$?

$$P[\sup T_i < y] = P[T_1 < y, \dots, T_n < y]$$

$$\xrightarrow{T_1, \dots, T_n \text{ ind}} = \prod_{i=1}^n P(T_i < y)$$

$T_i \sim U(]0, \theta[)$ donc $P(T_i < y) = \begin{cases} 0 & y \leq 0 \\ \frac{y}{\theta} & y \in]0, \theta[\\ 1 & y \geq \theta \end{cases}$

$\int_0^y \frac{1}{\theta} dt_i$ y ∈]0, θ[



$$P(\underbrace{\text{Sup} T_i}_{Y_n} < y) = \begin{cases} 0 & y \leq 0 \\ 1 & y \geq \theta \\ \left(\frac{y}{\theta}\right)^n & y \in]0, \theta[\end{cases}$$

La densité de $\text{Sup} T_i$ est donc

$$p(y_n) = \begin{cases} 0 & y \notin]0, \theta[\\ \frac{n y^{n-1}}{\theta^n} & y \in]0, \theta[\end{cases}$$

$$P(X < x) = \int_{-\infty}^x p(u) du$$

Mojeune $E(Y_n) = \int_0^{\theta} y \frac{n y^{n-1}}{\theta^n} dy$

$$= \frac{n}{\theta^n} \left[\frac{y^{n+1}}{n+1} \right]_0^{\theta}$$

$$= \theta \frac{n}{n+1} \neq \theta$$

donc Y_n est biaisé

Mais $\frac{n+1}{n} Y_n = \hat{\theta}_2$ est bien un estimateur non biaisé de θ

Pour comparer $\hat{\theta}_1$ et $\hat{\theta}_2$, il faut calculer $Va(\hat{\theta}_2)$

$$\text{Var}[\hat{\theta}_2] = \text{Var}\left[\frac{n+1}{n} Y_n\right] = \left(\frac{n+1}{n}\right)^2 \text{Var} Y_n$$

$$\text{Var}(Y_n) = E(Y_n^2) - \underbrace{E(Y_n)^2}_{\left(\theta \frac{n}{n+1}\right)^2}$$

$$\int_0^\theta y^2 \frac{ny^{n-1}}{\theta^n} dy = \frac{n}{\theta^n} \frac{\theta^{n+2}}{n+2} = \theta^2 \frac{n}{n+2}$$

$$\begin{aligned} \text{Var}(Y_n) &= \left[\frac{n}{n+2} - \left(\frac{n}{n+1}\right)^2 \right] \theta^2 \\ &= n \frac{(n+1)^2 - n(n+2)}{(n+2)(n+1)^2} \theta^2 \end{aligned}$$

$$= \frac{n \theta^2}{(n+2)(n+1)^2}$$

donc $\boxed{\text{Var} \hat{\theta}_2 = \frac{\theta^2}{n(n+2)}}$

à comparer avec $\boxed{\text{Var } \hat{\theta}_1 = \frac{\theta^2}{3n}}$

On préfère l'estimateur $\hat{\theta}_2$ qui a une variance plus faible pour n grand !!

COURS du 12/02/2024

(H_0) pas d'anomalie

(H_1) anomalie

$\Delta \sum x_i = T > S_\alpha$

$\alpha = P[\text{Rejeter } H_0 \mid H_0 \text{ vraie}] = P[\underbrace{\text{décider qu'il y a une anomalie}}_{\text{si n'y a pas d'anomalie}} \mid \text{il n'y a pas d'anomalie}]$
 $= \text{PFA}$ probabilité de fausse alarme

$\beta = P[\text{Rejeter } H_1 \mid H_1 \text{ vraie}] = P[\underbrace{\text{décider qu'il n'y a pas d'anomalie}}_{T < S_\alpha} \mid \text{il y a une anomalie}]$
 $= \text{PND}$ probabilité de non détection

Exercice $X_i \sim N(m, \sigma^2)$ σ^2 connue

(H_0) $m = m_0$ Rejet de H_0 si $\frac{1}{n} \sum_{i=1}^n x_i > S_\alpha$

(H_1) $m = m_1 > m_0$ Comment déterminer S_α ?

On se fixe $\alpha (= 0.01 \text{ ou } 0.05)$ $= P[\underbrace{T = \frac{1}{n} \sum_{i=1}^n x_i}_{> S_\alpha} \mid m = m_0]$
 $= 1 - P[\frac{1}{n} \sum_{i=1}^n x_i \leq S_\alpha \mid m = m_0] //$

$\Rightarrow \frac{1}{n} \sum_{i=1}^n x_i = \begin{pmatrix} \frac{1}{n} & \dots & \frac{1}{n} \end{pmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$

x_1, \dots, x_n ind
 $x_i \sim N(m, \sigma^2)$

$\Rightarrow \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$ vecteur gaussien

$\Rightarrow \underbrace{A}_{T} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$ de loi gaussienne
 $\text{rang}(A) = 1 \text{ max}$

$$\boxed{\frac{1}{n} \sum_{i=1}^n x_i \sim N\left(m, \frac{\sigma^2}{n}\right)}$$

\uparrow $\frac{1}{n} \sum_{i=1}^n E(x_i) = m$ \uparrow $\frac{1}{n^2} \sum_{i=1}^n \text{Var}(x_i) = \frac{\sigma^2}{n}$

$$U = \frac{\frac{1}{n} \sum_{i=1}^n x_i - m}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0,1)$$

$$\alpha = 1 - P\left[\frac{1}{n} \sum_{i=1}^n x_i \leq S_\alpha \mid \underbrace{H_0 \text{ vraie}}_{m=m_0}\right] \quad (*)$$

$$= 1 - P\left[\underbrace{\frac{\frac{1}{n} \sum_{i=1}^n x_i - m}{\sqrt{\frac{\sigma^2}{n}}}}_{U \sim N(0,1)} \leq \frac{S_\alpha - m}{\sqrt{\frac{\sigma^2}{n}}} \mid m = m_0\right]$$

$$\boxed{\alpha = 1 - F_{N(0,1)}\left[\frac{S_\alpha - m_0}{\sqrt{\frac{\sigma^2}{n}}}\right]} \quad (*)$$

$$F_{N(0,1)}[x] = 1 - \alpha \quad \text{donc} \quad \frac{S_\alpha - m_0}{\sqrt{\frac{\sigma^2}{n}}} = F_{N(0,1)}^{-1}(1 - \alpha)$$

donc

$$\boxed{S_\alpha = m_0 + \sqrt{\frac{\sigma^2}{n}} F_{N(0,1)}^{-1}(1 - \alpha)}$$

1^{re} étape : veuil S_α

Seconde étape : PND = β ?

$$PND = P\left[\underbrace{\text{rejet } H_0}_{\frac{1}{n} \sum_{i=1}^n x_i \leq S_\alpha} \mid \underbrace{H_0 \text{ vraie}}_{m=m_0 (> m_1)}\right]$$


$$\text{Pg } PD = \pi = 1 - PND = P\left[\frac{1}{n} \sum_{i=1}^n x_i > S_\alpha \mid m = m_1\right]$$

On en déduit, en changeant m_0 en m_1 dans (*)

$$\pi = 1 - F_{N(0,1)} \left[\frac{s_2 - m_1}{\sqrt{\frac{\sigma^2}{n}}} \right]$$

ou

$$\beta = F_{N(0,1)} \left[\frac{s_2 - m_1}{\sqrt{\frac{\sigma^2}{n}}} \right]$$



COURBES COR π en fonction de α

$$\left| \begin{array}{l} \pi = 1 - F \left[\frac{s_2 - m_1}{\sigma/\sqrt{n}} \right] \\ s_2 = m_0 + \sqrt{\frac{\sigma^2}{n}} F^{-1}(1-\alpha) \end{array} \right. \left. \begin{array}{l} \leftarrow \\ \leftarrow \end{array} \right.$$


$$\pi = 1 - F \left[\underbrace{\frac{m_0 - m_1}{\sigma/\sqrt{n}}}_{\ominus} + F^{-1}(1-\alpha) \right]$$

$$\ominus \frac{(m_1 - m_0)}{\sigma/\sqrt{n}}$$


Ce qui est important pour le test est la valeur de

$$\frac{\sqrt{n}(m_1 - m_0)}{\sigma}$$

π est d'autant plus grand que $\frac{\sqrt{n} (\mu_1 - \mu_0)}{\sigma}$ est grand



p-value = plus petite valeur de α pour laquelle on rejette $H_0 = \alpha^*$



NEYMAN PEARSON

Rejet de H_0 si $\frac{L(x_1, \dots, x_n | H_1)}{L(x_1, \dots, x_n | H_0)} > S_\alpha$

Ex $x_i \sim N(m, \sigma^2)$ $(H_0) m = m_0$
 $(H_1) m = m_1 > m_0$
 Neyman Pearson?

On rejette H_0 si $\frac{\prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left[-\frac{(x_i - m_1)^2}{2\sigma^2}\right]}{\prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left[-\frac{(x_i - m_0)^2}{2\sigma^2}\right]} > S_\alpha$

Un test équivalent est

Rejet de H_0 si $\sum_{i=1}^n \left[-\frac{(x_i - m_1)^2}{2\sigma^2} + \frac{(x_i - m_0)^2}{2\sigma^2} \right] > \frac{\ln S_\alpha}{S_\alpha}$
 (on perd le \ln)

$\frac{1}{2\sigma^2} \sum_{i=1}^n \left[-x_i^2 + 2m_1 x_i - m_1^2 + x_i^2 - 2m_0 x_i + m_0^2 \right] > S_\alpha'$

$2(m_1 - m_0) \sum_{i=1}^n x_i + n(m_0^2 - m_1^2) > 2\sigma^2 S_\alpha'$

$m_1 > m_0 \Rightarrow m_1 - m_0 > 0$

Rejet de H_0 si $\sum_{i=1}^n x_i > A_\alpha$

stat de test
 zone critique $T = \sum_{i=1}^n x_i$
 $\{ (x_1, \dots, x_n) / \sum_{i=1}^n x_i > A_\alpha \}$

TD du 12/02/2024

d) vraisemblance $\prod_{i=1}^n \theta e^{-\theta t_i} = \theta^n \exp\left(-\theta \sum_{i=1}^n t_i\right)$

Log vraisemblance $l(\theta) = n \ln \theta - \theta \sum_{i=1}^n t_i$

$$\frac{\partial l(\theta)}{\partial \theta} = 0 \Leftrightarrow \frac{n}{\theta} - \sum_{i=1}^n t_i = 0$$

$$\theta = \frac{n}{\sum_{i=1}^n t_i}$$

done

$$\hat{\theta}_{MV} = \frac{n}{\sum_{i=1}^n T_i}$$

$$\text{Rq } \hat{\theta}_{MV} = \frac{1}{\frac{1}{n} \sum_{i=1}^n T_i}$$

T_i est de densité $\theta e^{-\theta t_i}$ $t_i \geq 0$

$$E(T_i) = \frac{1}{\theta}$$


$$\text{donc } \theta = \frac{1}{E(T_i)} \approx \frac{1}{\frac{1}{n} \sum T_i}$$

c'est logique !!

Est-ce que c'est bien un maximum?

$$\frac{\partial l(\theta)}{\partial \theta} \geq 0 \Leftrightarrow \frac{n}{\theta} - \sum_{i=1}^n t_i \geq 0$$

$$4 \Rightarrow \theta \leq \frac{n}{\sum t_i}$$



donc $\theta = \frac{n}{\sum t_i}$ est le maximum global
unique de la vraisemblance!

② $\hat{\theta}_{MAP}$ et $\hat{\theta}_{MMSE}$?

loi a posteriori de l'échantillon (t_1, \dots, t_n)

$$P(\theta | t_1, \dots, t_n) \propto \underbrace{P(t_1, \dots, t_n | \theta)}_{\text{vraisemblance}} \times \underbrace{p(\theta)}_{\text{loi a priori}}$$

$$\propto \theta^n \exp\left(-\theta \sum_{i=1}^n t_i\right) \propto e^{-d\theta}$$

proportionnel.

$$\propto \theta^n \exp\left[-\theta \left(1 + \sum_{i=1}^n t_i\right)\right]$$

donc

$$\hat{\theta}_{MAP} = \frac{n}{\sum_{i=1}^n t_i + 1}$$

quand le nombre de données augmente, on fait confiance aux données

Exo 2

$$Z_1 \sim N(0, \sigma^2)$$

$$Z_2 \sim N(0, \sigma^2)$$

$$L(Z_1, Z_2; \theta) = \frac{1}{2\pi\sigma^2} \exp\left[-\frac{(Z_1 - \theta)^2}{2\sigma^2} - \frac{(Z_2 - \theta)^2}{2\sigma^2}\right]$$

$Z_1 \text{ et } Z_2 \text{ ind}$

$$\hat{\theta}_{MV} = 0 \Leftrightarrow L(Z_1, Z_2; \theta = 0) > L(Z_1, Z_2; \theta = 1)$$


$$\Leftrightarrow \frac{1}{2\pi\sigma^2} e^{-\frac{Z_1^2 + Z_2^2}{2\sigma^2}} > \frac{1}{2\pi\sigma^2} e^{-\frac{(Z_1 - 1)^2 + (Z_2 - 1)^2}{2\sigma^2}}$$

$$\Leftrightarrow \text{(on prend le)} \quad \log \quad -\frac{1}{2\sigma^2}(Z_1^2 + Z_2^2) > -\frac{1}{2\sigma^2}((Z_1 - 1)^2 + (Z_2 - 1)^2)$$

$$\Leftrightarrow -Z_1^2 - Z_2^2 \geq -|Z_1^2 - 2Z_1 + 1| - |Z_2^2 - 2Z_2 + 1|$$

$$\Leftrightarrow 2(Z_1 + Z_2 - 1) \leq 0$$

$$\Leftrightarrow \boxed{Z_1 + Z_2 \leq 1}$$



$$3) \quad p(\theta) = p^{1-\theta} (1-p)^\theta \quad \begin{matrix} \nearrow p & \delta^\theta = 0 \\ \searrow 1-p & \delta^\theta = 1 \end{matrix}$$

Li a priori

Li a posteriori

$$L(z_1, z_2 | \theta) \times p(\theta)$$

||

$$\frac{1}{2\pi\sigma^2} \exp\left\{ -\frac{1}{2\sigma^2} \left[(z_1 - \theta)^2 + (z_2 - \theta)^2 \right] \right\} \times p^{1-\theta} (1-p)^\theta$$

$$\hat{\theta}_{MAP} = 0 \Leftrightarrow \exp\left[-\frac{1}{2\sigma^2} (z_1^2 + z_2^2) \right] p \geq \exp\left[-\frac{1}{2\sigma^2} (z_1 - 1)^2 + (z_2 - 1)^2 \right] \times (1-p)$$

$$\Leftrightarrow -\frac{1}{2\sigma^2} (z_1^2 + z_2^2) + \ln p \geq -\frac{1}{2\sigma^2} \left[\underbrace{(z_1 - 1)^2 + (z_2 - 1)^2}_{z_1^2 + z_2^2 - 2z_1 - 2z_2 + 2} \right] + \ln(1-p)$$

$$\hat{\theta} = 0$$

$$\Leftrightarrow \ln\left(\frac{p}{1-p}\right) \geq \frac{z_1 + z_2 - 1}{\sigma^2}$$

$$\Leftrightarrow z_1 + z_2 \leq 1 + \sigma^2 \ln\left(\frac{p}{1-p}\right)$$

