

ECN 7060, cours 10

William McCausland

2021-11-16

Éléments de la théorie de décision

Objets :

- ▶ $X = (X_1, \dots, X_n)$, données aléatoires
- ▶ $x = (x_1, \dots, x_n)$, réalisation des données
- ▶ θ , le paramètre de la loi des données
- ▶ a , une action (par exemple, le choix d'une estimation de θ)

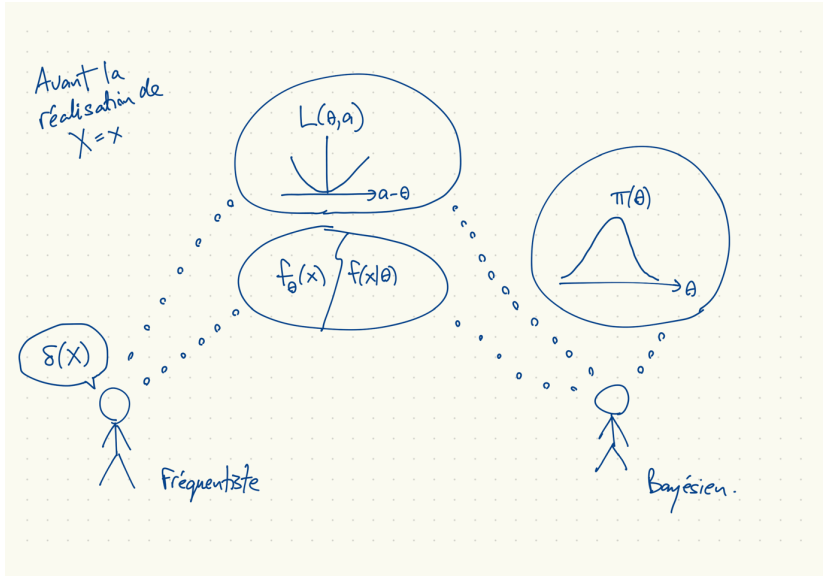
Fonctions primitives :

- ▶ $f(x|\theta)$, la densité des données
- ▶ $\pi(\theta)$, la densité *a priori* de θ
- ▶ $L(\theta, a)$, une fonction de perte

Fonction (ou règle) de décision :

- ▶ $\delta(X)$ est l'action comme fonction des données.

Fréquentiste et bayésien avant l'observation des données



Fréquentiste et bayésien après l'observation des données

Après la
réalisation de
 $X=x$

$$a = \delta(x)$$



Fréquentiste

$$a = \underset{\alpha}{\operatorname{argmin}} E[L(\theta, \alpha) | X=x]$$



Bayésien.

Fonction de risque

- ▶ Pour une fonction de perte $L(\theta, a)$ donnée et un estimateur $\delta(X)$ donné, la fonction de risque (une fonction de θ) est, dans la notation de Casella et Berger :

$$R(\theta, \delta) = E_{\theta}[L(\theta, \delta(X))].$$

- ▶ L'espérance est par rapport à la loi de X pour θ donné.
- ▶ Pour un bayésien, θ est aléatoire et on peut écrire

$$R(\theta, \delta) = E[L(\theta, \delta(X))|\theta].$$

- ▶ Problèmes :
 - ▶ Besoin de spécifier $\delta(x)$ pour tout résultat x possible.
 - ▶ Calculer $R(\theta, \delta)$ même pour une seule valeur de θ est souvent infaisable. Un recours aux méthodes asymptotiques est habituel.
 - ▶ $R(\theta, \delta)$ est une fonction de θ . Ce qui marche bien pour une valeur de θ ne marche pas toujours bien pour une autre.

Risque de Bayes

- ▶ Le risque de Bayes, pour une densité *a priori* $\pi(\theta)$ donnée, est

$$\begin{aligned}r(\pi, \delta) &\equiv E[R(\theta, \delta)] = \int \pi(\theta) E[L(\theta, \delta(X)) | \theta] d\theta \\ &= E[E[L(\theta, \delta(X)) | \theta]] \\ &= E[L(\theta, \delta(X))],\end{aligned}$$

où la dernière espérance est par rapport à la loi conjointe de θ et X . (La première est l'espérance d'une fonction de θ seulement.)

- ▶ En même temps,

$$r(\pi, \delta) = E[E[L(\theta, \delta(X)) | X]].$$

Règles (de décision) de Bayes

- ▶ Rappel : $r(\pi, \delta) = E[E[L(\theta, \delta(X))|X]]$.
- ▶ Une *règle de Bayes* est une fonction de décision δ^* qui minimise $r(\pi, \delta)$ pour $\pi(\theta)$ et $L(\theta, a)$ donnés.
- ▶ Difficultés potentielles :
 - ▶ non-unicité de δ
 - ▶ absence d'une solution parce que $R(\theta, \delta) = \infty$ pour tous δ
- ▶ Même si $r(\pi, \delta)$ est toujours infini, on peut souvent trouver, pour x donné, $\delta(x)$ qui minimise la perte *a posteriori* espérée $E[L(\theta, \delta(X))|X]$ quand $X = x$.
 - ▶ C'est une règle de Bayes *généralisée*.
 - ▶ En pratique, on le fait pour x observée seulement; $\delta(x)$ a souvent la même dimension que θ .
 - ▶ Pour la perte quadratique, $\delta(x)$ est la moyenne *a posteriori*.
 - ▶ Pour la perte valeur absolue, $\delta(x)$ est la médiane *a posteriori*.
 - ▶ Pour une autre perte, on peut approximer $\delta(x)$ par simulation.

Dominance et admissibilité

- ▶ La fonction de décision δ^* domine la fonction de décision δ par rapport à la fonction de perte $L(\theta, a)$ si $R(\theta, \delta^*) \leq R(\theta, \delta)$, avec une inégalité stricte pour au moins une valeur de θ .
- ▶ Une fonction de décision est admissible s'il n'y a pas d'autre fonction de décision qui la domine.
- ▶ Supposons que δ minimise $r(\pi, \delta) = \int \pi(\theta)R(\theta, \delta) d\theta$, pour une fonction $\pi: \Theta \rightarrow \mathbb{R}_+$.
 - ▶ Si δ est inadmissible, il existe une δ^* qui la domine : il y a un ensemble $\bar{\Theta}$ où $R(\theta, \delta) > R(\theta, \delta^*)$. Il faut que $\pi(\bar{\Theta}) = 0$. Sinon, $\delta(x)$ ne minimise $r(\pi, \delta)$ parce que $r(\pi, \delta^*) < r(\pi, \delta)$.
- ▶ À quelques conditions techniques près, un estimateur admissible est une règle de Bayes généralisée (avec possiblement une loi *a priori* impropre).

Biais, EMQ

- ▶ Notation, définitions
 - ▶ W est un estimateur de θ ou plus généralement de $\tau(\theta)$
 - ▶ Le biais de W est $E_\theta[W] - \theta$ ou $E_\theta[W] - \tau(\theta)$
 - ▶ L'espérance moyenne quadratique est
$$E_\theta[(W - \theta)(W - \theta)^\top] = \text{Var}_\theta[W] + \text{biais}_\theta[W]\text{biais}_\theta[W]^\top.$$
- ▶ L'importance du biais et l'EMQ est largement due à la solubilité des problèmes.
- ▶ La perte quadratique est seulement un choix possible parmi plusieurs. Quelques problèmes :
 - ▶ paramètres d'échelle, qui sont toujours positifs,
 - ▶ impossibilité de la perte asymétrique,
 - ▶ non-existence de la moyenne ou la variance d'un estimateur.
- ▶ Le non-biais n'est pas un principe fiable, si on considère l'exemple suivant.

Un estimateur non-biaisé ridicule (RUBE)

- ▶ $X_i \sim \text{Po}(\lambda)$, $n = 1$.
- ▶ On veut estimer $\tau(\lambda) = e^{-3\lambda}$.
- ▶ Considérons la statistique $T(X) = (-2)^X$.
- ▶ Vraiment ridicule :
 - ▶ Pour $x = 9, 10, 11$, $T(x) = -512, 1024, -2048$
 - ▶ Pour $\lambda = 10$, $e^{-3\lambda} \approx 9.357623 \times 10^{-14}$.
- ▶ Mais non-biaisé :

$$E[T] = e^{-\lambda} \sum_{k=0}^{\infty} \frac{(-2)^k \lambda^k}{k!} = e^{-3\lambda}.$$

- ▶ Par complétion de la famille de loi Poisson, T est l'estimateur *unique* non-biaisé de $\tau(\lambda)$.
 - ▶ Si $E_{\theta}[g(X)] = 0$ pour tous θ , $P(\{g(X) = 0\}) = 1$.
 - ▶ Soit $g(x) = T(x) - T'(x)$ la différence entre deux candidats pour un estimateur non-biaisé.

Statistiques suffisantes dans un modèle gaussien

- ▶ Modèle : $X_i \sim \text{iid } N(\mu, \sigma^2)$, $\theta = (\mu, \sigma^2)$
- ▶ Densité des données :

$$\begin{aligned} f(x|\theta) &= \prod_{i=1}^n (2\pi\sigma^2)^{-1/2} \exp\left[-\frac{1}{2} \frac{(x_i - \mu)^2}{\sigma^2}\right] \\ &= (2\pi)^{-n/2} \sigma^{-n} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right], \\ &= (2\pi)^{-n/2} \sigma^{-n} \exp\left[-\frac{1}{2\sigma^2} ((n-1)S^2 + n(\bar{x} - \mu)^2)\right] \end{aligned}$$

où $S^2 \equiv \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$

- ▶ Une statistique suffisante minimale pour (μ, σ^2) : (\bar{x}, S^2) .

EMQ de $\hat{\sigma}^2$ et S^2 dans le modèle $X_i \sim \text{iid } N(\mu, \sigma^2)$

- ▶ Rappel: $S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$.
- ▶ L'estimateur EMV de (μ, σ^2) est $(\hat{\mu}, \hat{\sigma}^2) = (\bar{x}, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2)$.
- ▶ S^2 est non-biaisé ; $\hat{\sigma}^2$ est biaisé mais sa EMQ est moins grande, peu importe la valeur de σ^2 . (exemples 7.3.3, 7.3.4)

Analyse bayésienne avec une loi *a priori* conjuguée

- ▶ Soit $\omega = \sigma^{-2}$, $\theta = (\mu, \omega)$.
- ▶ Densité des données, en termes de ω :

$$f(x|\theta) \propto \omega^{n/2} \exp \left[-\frac{\omega}{2} ((n-1)S^2 + n(\bar{x} - \mu)^2) \right]$$

- ▶ La famille des lois *a priori* conjuguée est Normal-gamma, où
 - ▶ $\omega \sim \text{Ga}(\alpha_0, \beta_0)$
 - ▶ $\mu|\omega \sim N(\mu_0, (\omega\lambda_0)^{-1})$
- ▶ Après des manipulations, on découvre que

$$\omega|x \sim \text{Ga} \left(\alpha_0 + n/2, \beta_0 + \frac{1}{2} \left((n-1)S + \frac{\lambda_0 n (\bar{x} - \mu_0)^2}{\lambda_0 + n} \right) \right),$$

$$\mu|\omega, x \sim N \left(\frac{\lambda_0 \mu_0 + n\bar{x}}{\lambda_0 + n}, (\omega(\lambda_0 + n))^{-1} \right).$$

- ▶ Détails à https://en.wikipedia.org/wiki/Normal-gamma_distribution, section "Posterior distribution of the parameters"

La fonction de score

- ▶ Soit $L(\theta; x)$ une vraisemblance, $f(x|\theta)$ la densité des données.
- ▶ La fonction de score est le gradient :

$$V(\theta, x) = \frac{\partial \log L(\theta; x)}{\partial \theta^\top} = \frac{1}{L(\theta; x)} \frac{\partial L(\theta; x)}{\partial \theta}.$$

- ▶ Si on peut changer l'ordre de l'intégrale et la dérivée,

$$E \left[\frac{\partial \log L(\theta; x)}{\partial \theta^\top} \right] = \int \frac{f(x|\theta)}{f(x|\theta)} \frac{\partial f(x|\theta)}{\partial \theta^\top} dx = \frac{\partial \int f(x|\theta) dx}{\partial \theta^\top} = 0.$$

- ▶ Conditions suffisantes pour pouvoir changer l'ordre de l'intégrale et la dérivée
 1. La densité $f(x|\theta)$ a un support borné et ce support ne dépend pas de θ .
 2. La densité $f(x|\theta)$ a un support infini et est continument différentiable en θ ; l'intégral converge uniformement sur Θ .

Inégalité Cramér-Rao

- ▶ Échantillon X_1, \dots, X_n , pas nécessairement iid, densité $f(x|\theta)$.
- ▶ Supposons que $E[V(\theta, X)] = 0$, où $V(\theta, X)$ est la fonction de score.
- ▶ Supposons que $W(X)$ est un estimateur de $\tau(\theta)$, $\text{Var}_\theta[W(X)] < \infty$, et

$$\frac{d}{d\theta} E_\theta[W(X)] = \int \frac{\partial}{\partial \theta} [W(x)f(x|\theta)] dx.$$

- ▶ Alors

$$\text{Var}_\theta[W(X)] \geq \frac{\left(\frac{d}{d\theta} E_\theta[W(X)]\right)^2}{E_\theta[V(\theta, X)^2]}.$$

Preuve de l'inégalité Cramér-Rao

- ▶ L'égalité encore :

$$\text{Var}_\theta[W(X)] \geq \frac{\left(\frac{d}{d\theta} E_\theta[W(X)]\right)^2}{E_\theta[V(\theta, X)^2]}.$$

- ▶ Preuve :

$$\begin{aligned}\frac{d}{d\theta} E_\theta[W(X)] &= \int W(x) \left[\frac{\partial f(x|\theta)}{\partial \theta} \right] dx \\ &= \int W(x) \left[\frac{\partial \log f(x|\theta)}{\partial \theta} \right] f(x|\theta) dx \\ &= E_\theta[W(X)V(\theta, X)] = \text{Cov}_\theta[W(X), V(\theta, X)]\end{aligned}$$

et

$$\text{Var}_\theta[V(\theta, X)] = E_\theta[V(\theta, X)^2]$$

et par l'inégalité de Cauchy-Schwarz :

$$\text{Var}_\theta[W(X)]\text{Var}_\theta[V(\theta, X)] \geq \text{Cov}_\theta[W(X), V(\theta, X)]^2.$$

Remarques, inégalité Cramér-Rao

- ▶ Le dénominateur est l'information de Fisher, qui dépend du modèle et non l'estimateur.
- ▶ L'inégalité est très utile dans le cas où $W(X)$ est non-biaisé pour $\tau(\theta) = \theta$:
 - ▶ $E_{\theta}[W(X)] = \theta$ alors le numérateur est 1
 - ▶ la variance $\text{Var}_{\theta}[W(X)]$ a une borne qui ne dépend pas de l'estimateur.
- ▶ La borne est toujours une fonction de θ , par contre.
- ▶ Un estimateur qui atteint la borne est dit "efficace".
- ▶ Attention :
 - ▶ un estimateur biaisé peut avoir une EMQ en dessous de cette borne.
 - ▶ le critère de non-biais et la fonction de perte quadratique ne sont pas sans difficultés.

Théorème Rao-Blackwell

- ▶ Soit W un estimateur non-biaisé de $\tau(\theta)$, T une statistique suffisante pour θ . Alors $\phi(T) = E[W|T]$ est un estimateur de $\tau(\theta)$ qui est non-biaisé et uniformément meilleur en termes de variance.
- ▶ Preuve :
 - ▶ $\phi(T)$ est une fonction de T et alors une fonction de l'échantillon seulement.
 - ▶ Non-biais : $E_\theta[\phi(T)] = E_\theta[E[W|T]] = E_\theta[W] = \tau(\theta)$.
 - ▶ Uniformément meilleur en termes de variance :

$$\begin{aligned}\text{Var}_\theta[W] &= \text{Var}_\theta[E[W|T]] + E_\theta[\text{Var}_\theta[W|T]] \\ &= \text{Var}_\theta[\phi(T)] + E_\theta[\text{Var}_\theta[W|T]] \\ &\geq \text{Var}_\theta[\phi(T)].\end{aligned}$$