

# ECN 7060, cours 11

William McCausland

2022-11-23

# Hypothèses sur un paramètre $\theta \in \Theta$

- ▶ Deux hypothèses sur  $\theta$  :
  - ▶ hypothèse nulle  $H_0, \theta \in \Theta_0$
  - ▶ hypothèse alternative  $H_1, \theta \in \Theta_0^c$
- ▶ Notes :
  - ▶ Les hypothèses viennent d'une question scientifique d'intérêt.
  - ▶ Il n'y a rien ici de classique ou de bayésien.
  - ▶ La spécification de  $\Theta_0$  devrait précéder la recherche d'un test et l'évaluation d'un test.
  - ▶ Il n'y a pas d'asymétrie explicite ici entre  $H_0$  et  $H_1$ .
  - ▶ L'asymétrie est une question d'erreur : on favorise le control d'un type d'erreur.

# Tests

- ▶ Deux décisions (même notation pour les actions que la semaine passée)
  - ▶  $a_0$ , ne pas rejeter  $H_0$
  - ▶  $a_1$ , rejeter  $H_0$
- ▶ Deux régions de l'espace échantillonal :
  - ▶ région critique (ou de rejet)  $R \subseteq \mathcal{X}$
  - ▶ région de non-rejet  $R^c$
- ▶ Notes :
  - ▶ Une règle de décision est un  $\delta: \mathcal{X} \rightarrow \{a_0, a_1\}$
  - ▶  $R = \{x: \delta(x) = a_1\}$ ,  $R^c = \{x: \delta(x) = a_0\}$ .
  - ▶ réduction de dimension, comme dans le cas d'estimation ponctuelle : il y a souvent une statistique  $W(X)$  scalaire tel que  $R$  ou  $R^c$  prend la forme  $\{x: W(x) \in [a, b]\}$ , des fois avec  $a = -\infty$  ou  $b = \infty$ .
  - ▶ attention : quand  $W(X)$  est un estimateur de  $\theta$ , il est facile de confondre une hypothèse avec  $R$  ou  $R^c$ .

# Optimalité par fonction de perte

- ▶ Une fonction de perte assez générale :

$$L(\theta, a_0) = \begin{cases} 0 & \theta \in \Theta_0 \\ c_{II} & \theta \in \Theta_0^c \end{cases}$$

$$L(\theta, a_1) = \begin{cases} c_I & \theta \in \Theta_0 \\ 0 & \theta \in \Theta_0^c \end{cases}$$

- ▶ Notes :
  - ▶  $c_I$  est le coût d'une erreur du type I,  $c_{II}$  le coût d'une erreur du type II
  - ▶ Avec cette généralité, on peut briser la symétrie entre les deux hypothèses : choisir  $c_I \neq c_{II}$ .
  - ▶ Si la mesure de coût est l'espérance de l'erreur, la spécification du coût se réduit à la choix de  $c_I/c_{II}$ .

## Les fonctions de risque et de puissance

- ▶ Le risque  $R(\theta, \delta) = E_{\theta}[L(\theta, \delta(X))]$  est

$$R(\theta, \delta) = \begin{cases} 0 \cdot P_{\theta}(\delta(X) = a_0) + c_I \cdot P_{\theta}(\delta(X) = a_1), & \theta \in \Theta_0, \\ c_{II} \cdot P_{\theta}(\delta(X) = a_0) + 0 \cdot P_{\theta}(\delta(X) = a_1), & \theta \in \Theta_0^c. \end{cases}$$

- ▶ Cela motive la définition de la fonction de puissance :

$$\beta(\theta) \equiv P_{\theta}(X \in R) = P_{\theta}(\delta(X) = a_1)$$

- ▶ On peut écrire tout court

$$R(\theta, \delta) = \begin{cases} c_I \beta(\theta), & \theta \in \Theta_0, \\ c_{II}(1 - \beta(\theta)), & \theta \in \Theta_0^c \end{cases}$$

- ▶ Rappel : ce calcul est une exercice *ex ante*.

## Risque de Bayes

- ▶ Rappel :  $r(\pi, \delta) = \int R(\theta, \delta)\pi(\theta) d\theta = E[E[L(\theta, \delta(X))|\theta]] = E[L(\theta, \delta(X))] = E[E[L(\theta, \delta(X))|X]]$ .
- ▶ Pour un échantillon  $x$  observé, la perte espérée *a posteriori* est

$$\begin{aligned} & E[L(\theta, \delta(X))|x] \\ &= \begin{cases} 0 \cdot P[\theta \in \Theta_0|x] + c_{II} \cdot P[\theta \in \Theta_0^c|x], & \delta(x) = a_0 \\ c_I \cdot P[\theta \in \Theta_0|x] + 0 \cdot P[\theta \in \Theta_0^c|x], & \delta(x) = a_1 \end{cases} \end{aligned}$$

- ▶ La solution  $\delta(x)$  qui minimise la perte *a posteriori* est

$$\delta(x) = \begin{cases} a_0, & \frac{c_I}{c_{II}} \frac{P[\theta \in \Theta_0|x]}{P[\theta \in \Theta_0^c|x]} \geq 1, \\ a_1, & \text{autrement.} \end{cases}$$

- ▶ Notes :
  - ▶ Ce calcul est une exercice *ex post*.
  - ▶ L'asymétrie entre  $H_0$  et  $H_1$  est seulement en termes de  $c_{II}/c_I$ .

# Lemme Neyman Pearson

## Définition 8.3.5

Pour  $\alpha \in [0, 1]$ , un test avec fonction de puissance  $\beta(\theta)$  a un niveau de  $\alpha$  si  $\sup_{\theta \in \Theta_0} \beta(\theta) \leq \alpha$ .

## Définition 8.3.11

Pour  $\alpha \in [0, 1]$ , un test de niveau  $\alpha$  avec fonction de puissance  $\beta(\theta)$  est uniformément plus puissant si pour chaque  $\theta \in \Theta_0^c$  et pour chaque fonction de puissance  $\beta'(\theta)$  d'un test de niveau  $\alpha$ ,  $\beta(\theta) \geq \beta'(\theta)$ .

## Lemme Neyman Pearson

- ▶ Supposons que la densité des données est  $f(x|\theta_0)$  ou  $f(x|\theta_1)$ , selon la valeur de  $\theta \in \Theta = \{\theta_0, \theta_1\}$ .
- ▶ On considère des tests de l'hypothèse  $H_0: \theta = \theta_0$  contre l'hypothèse  $H_1: \theta = \theta_1$ .
- ▶ À une condition technique près, un test de niveau  $\alpha$  est uniformément plus puissant ssi le test prend la forme  $R = \{x \in \mathcal{X}: f(x|\theta_1) > kf(x|\theta_0)\}$  et  $P_{\theta_0}[R] = \alpha$ .

# Intuition Neyman Pearson I

- ▶ On divise  $\mathcal{X}$  en deux :  $R$  où  $\delta(x) = a_1$  et  $R^c$  où  $\delta(x) = a_0$ .
- ▶ On choisit  $R$  pour maximiser  $P[R|\theta_1]$  sous la contrainte  $P[R|\theta_0] \leq c$ .
- ▶ Une fonction de Lagrange pour ce problème :

$$P[R|\theta_1] - \lambda(P[R|\theta_0] - c).$$

- ▶ Si  $(\lambda^*, R^*)$  est la solution,  $\lambda^*$  est le prix d'ombre de la puissance.
- ▶ Pour  $x_2 \in \mathcal{X}$  à la frontière entre  $R$  optimal et  $R^c$  et un voisinage infinitesimal  $dR_2$  autour de  $x_2$ ,

$$P[R + dR_2|\theta_1] - P[R|\theta_1] - \lambda(P[R + dR_2|\theta_0] - P[R|\theta_0]) = 0.$$

ou

$$p(x_2|\theta_1) - \lambda p(x_2|\theta_0) = 0.$$



## Intuition Neyman Pearson II

- ▶ De la diapo précédente :

$$\frac{p(x_2|\theta_1)}{p(x_2|\theta_0)} = \lambda.$$

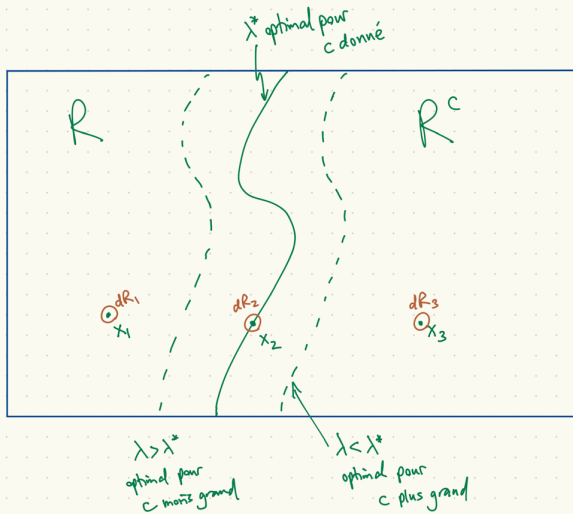
- ▶ Pour  $x_1 \in \mathcal{X}$  à l'intérieure de  $R$ ,

$$\frac{p(x_1|\theta_1)}{p(x_1|\theta_0)} > \lambda.$$

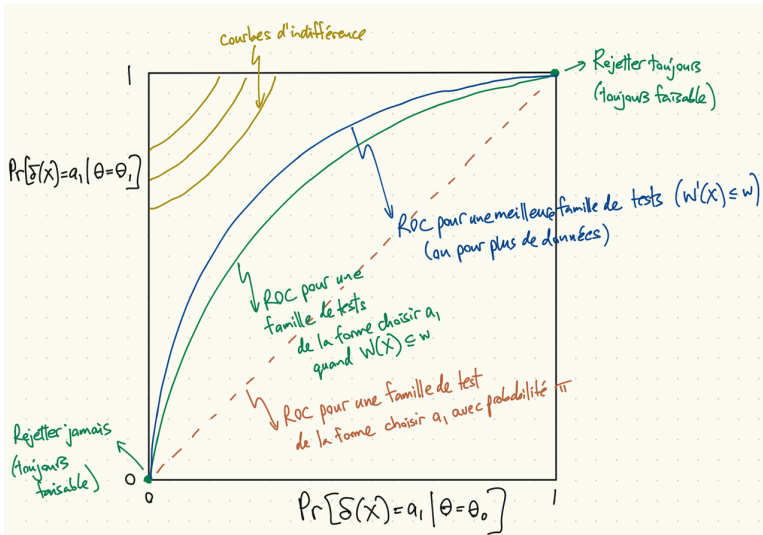
- ▶ Pour  $x_3 \in \mathcal{X}$  à l'intérieure de  $R^c$ ,

$$\frac{p(x_3|\theta_1)}{p(x_3|\theta_0)} < \lambda.$$

# Illustration pour l'intuition Neyman Pearson



# ROC



## Test du rapport de vraisemblance (LRT, likelihood ratio test)

- ▶ La région de rejet d'un test LRT en général, avec  $c \in [0, 1]$  à spécifier:

$$R = \left\{ x \in \mathcal{X} : \lambda(x) \equiv \frac{\sup_{\theta \in \Theta_0} L(\theta|x)}{\sup_{\theta \in \Theta} L(\theta|x)} \leq c \right\}$$

- ▶ Notes :
  - ▶ attrait intuitive dans la lumière du lemme Neymann-Pearson
  - ▶ réduction de dimension (on spécifie seulement le scalaire  $c$ )
  - ▶ on utilise souvent  $-2 \log \lambda$  comme la statistique test à cause de sa loi khi-carré asymptotique.

## Exemple récurrent Bernoulli

- ▶ Rappel :
  - ▶  $X_1, \dots, X_n \sim \text{iid Bn}(\theta)$ ,  $\theta \in [0, 1]$ .
  - ▶  $L(\theta|x) = \theta^r(1 - \theta)^{(n-r)}$ , où  $r$  est le nombre de uns.
  - ▶  $\hat{\theta}_{\text{EMV}} = \hat{\theta} = r/n$ .
  - ▶  $r$  est une statistique exhaustive minimale.
- ▶ Considérons les hypothèses  $H_0 : \theta \geq 1/2$  et  $H_1 : \theta < 1/2$ 
  - ▶ Alors  $\Theta_0 = [1/2, 1]$ ,
  - ▶  $\Theta = [0, 1]$
  - ▶  $\Theta_0^c = [0, 1/2)$

## Exemple Bernoulli (cont.)

- ▶ Calculer le rapport des vraisemblances

$$\sup_{\theta \in \Theta_0} L(\theta|x) = \begin{cases} L(\hat{\theta}|x) = \left(\frac{r}{n}\right)^r \left(\frac{n-r}{n}\right)^{n-r} & \hat{\theta} \geq 1/2 \\ L(\frac{1}{2}|x) = \left(\frac{1}{2}\right)^n & \hat{\theta} < 1/2 \end{cases}$$

$$\sup_{\theta \in \Theta} L(\theta|x) = L(\hat{\theta}|x) = \left(\frac{r}{n}\right)^r \left(\frac{n-r}{n}\right)^{n-r}$$

$$\lambda(x) = \begin{cases} 1, & r \geq n/2, \\ \frac{(n/2)^n}{r^r (n-r)^{n-r}}, & r < n/2. \end{cases}$$

- ▶  $\lambda(x)$  est une fonction de la statistique exhaustive  $r$ .
- ▶ En général, on peut utiliser  $f(t|\theta)$  directement, obtenir le même résultat.
- ▶ Les régions de rejet des tests LRT sont

$$R_r = \{x \in \mathcal{X} : \sum_i x_i \leq r\}, \quad r = 0, 1, 2, 3, 4, 5, 12.$$

## Les valeurs de $\lambda(x)$ pour $n = 12$

$r$	$\lambda(x)$	$\beta_r(\theta) = P_\theta(R \leq r)$
0	0.000244	$(1 - \theta)^n$
1	0.007629	$(1 - \theta)^n + n\theta(1 - \theta)^{n-1}$
2	0.054420	$(1 - \theta)^n + n\theta(1 - \theta)^{n-1} + \binom{n}{2}\theta^2(1 - \theta)^{n-2}$
3	0.208098	...
4	0.506822	
5	0.845821	
6	1	
...	...	
12	1	1

## Quelques fonctions de puissance $\beta_r(\theta)$


- Soit  $\beta_r(\theta)$  la fonction de puissance pour la région critique  $\{x: \sum_i x_i \leq r\}$

```
theta = seq(0, 1, by=0.01); n=12
beta_0 = pbinom(0, n, theta) # R = {r <= 0}
beta_1 = pbinom(1, n, theta) # R = {r <= 1}
beta_2 = pbinom(2, n, theta) # R = {r <= 2}
beta_3 = pbinom(3, n, theta)
beta_4 = pbinom(4, n, theta)
beta_5 = pbinom(5, n, theta)
beta_12 = pbinom(12, n, theta)
```



## Graphique des fonctions de puissance

```
plot(theta, beta_0, type='l'); lines(theta, beta_1)  
lines(theta, beta_2); lines(theta, beta_3)  
lines(theta, beta_4); lines(theta, beta_5); lines(theta, beta_6)
```



## Exemple, même modèle, hypothèse ponctuelle

- ▶ Considérons les hypothèses  $H_0 : \theta = 1/2$  et  $H_1 : \theta \neq 1/2$
- ▶ Ici, le rapport de vraisemblance est

$$\lambda(x) = \frac{L(\frac{1}{2})}{L(\hat{\theta})} = \frac{(\frac{1}{2})^n}{(\frac{r}{n})^r (\frac{n-r}{n})^{n-r}} = \frac{(n/2)^n}{r^r (n-r)^{n-r}}.$$

Les valeurs de  $\lambda(x)$  pour  $n = 12$

$r$	$\lambda(x)$
0	0.000244
1	0.007629
2	0.054420
3	0.208098
4	0.506822
5	0.845821
6	1.000000
7	0.845821
8	0.506822
9	0.208098
10	0.054420
11	0.007629
12	0.000244


## Quelques fonctions de puissance $\beta_r(\theta)$

- Soit  $\beta_c(\theta)$  la fonction de puissance pour la région critique  $\{x: |\sum_i x_i - n/2| \geq c\}$

```
theta = seq(0, 1, by=0.01); n=12
# R = {0,12}
beta_6 = pbinom(0, n, theta) + pbinom(0, n, 1-theta)
# R = {0,1,11,12}
beta_5 = pbinom(1, n, theta) + pbinom(1, n, 1-theta)
# Autres régions de rejet R
beta_4 = pbinom(2, n, theta) + pbinom(2, n, 1-theta)
beta_3 = pbinom(3, n, theta) + pbinom(3, n, 1-theta)
beta_2 = pbinom(4, n, theta) + pbinom(4, n, 1-theta)
# R = {0,1,2,3,4,5,7,8,9,10,11,12}
beta_1 = pbinom(5, n, theta) + pbinom(5, n, 1-theta)
```

## Graphique des fonctions de puissance

```
plot(theta, beta_6, type='l'); lines(theta, beta_5)  
lines(theta, beta_4); lines(theta, beta_3)  
lines(theta, beta_2); lines(theta, beta_1)
```



Un test bayésien de  $H_0 : \theta \geq \frac{1}{2}$  contre  $H_1 : \theta < \frac{1}{2}$ .

- ▶ Soit  $n = 12$ , comme avant.
- ▶ Soit  $\theta \sim \text{Be}(\alpha, \beta)$ , où  $\alpha = 1$ ,  $\beta = 1$  (loi uniforme).
- ▶ La loi *a posteriori* est  $\theta|x \sim \text{Be}(\alpha + r, \beta + n - r)$ .
- ▶ Mettons qu'on observe  $r = 4$ .
- ▶ La loi *a posteriori* est  $\theta|x \sim \text{Be}(5, 9)$  (prochaine diapo).
- ▶ Aparté : considérons la possibilité d'arrêter ici.
- ▶ La probabilité *a posteriori* de  $H_0$  est

$$P(\theta \geq 1/2 | r(x) = 4) = 1 - F_{\text{Be}(5,9)}(1/2) = 0.1334229.$$


- ▶ On choisit  $a_0$  ssi

$$\frac{c_I}{c_{II}} \cdot \frac{1 - F_{\text{Be}(5,9)}(1/2)}{F_{\text{Be}(5,9)}(1/2)} \geq 1,$$

ou si

$$\frac{c_I}{c_{II}} \geq 6.494968.$$

## La densité a posteriori $\text{Be}(5, 9)$



## La probabilité *a posteriori* $P(\theta \geq 1/2|x)$ , plusieurs $r$

- ▶ Soit  $n = 12$ ,  $\alpha = 1$ ,  $\beta = 1$ ,  $\Omega_0 = [1/2, 1]$
- ▶ La probabilité *a posteriori* dépend du  $r$  observé :

$r$	$P[\theta \in \Omega_0 x]$
0	0.0001220703
1	0.0017089844
2	0.0112304688
3	0.0461425781
4	0.1334228516
5	0.2905273437
6	0.5000000000
7	0.7094726563
8	0.8665771484
9	0.9538574219
10	0.9887695312
11	0.9982910156
12	0.9998779297



## Test d'une hypothèse ponctuelle, une approche bayésienne

Un modèle composé, où le modèle  $M \in \{H_0 : \theta = \frac{1}{2}, H_1 : \theta \neq \frac{1}{2}\}$ , le paramètre  $\theta$  et les données sont aléatoires :

$$f(M, \theta, x) = \Pr[M = H_0]1_{\{H_0\}}(M)\delta_{1/2}(\theta)(1/2)^n \\ + \Pr[M = H_1]1_{\{H_1\}}(M)f_{\text{Be}}(\theta; \alpha, \beta)\theta^r(1 - \theta)^{n-r}.$$

Après l'intégration par rapport à  $\theta$ ,

$$f(M, x) = \Pr[M = H_0]1_{\{H_0\}}(M)f_0(x) + \Pr[M = H_1]1_{\{H_1\}}(M)f_1(x),$$

où

$$f_0(x) = (1/2)^n, \quad f_1(x) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \frac{\Gamma(\alpha + r)\Gamma(\beta + n - r)}{\Gamma(\alpha + \beta + n)}.$$

(cont.)

- ▶ Les probabilités postérieures :

$$\Pr[M = H_0|x] = \frac{\Pr[M = H_0]f_0(x)}{\Pr[M = H_0]f_0(x) + \Pr[M = H_1]f_1(x)}$$

$$\Pr[M = H_1|x] = \frac{\Pr[M = H_1]f_1(x)}{\Pr[M = H_0]f_0(x) + \Pr[M = H_1]f_1(x)}$$

- ▶ Le rapport de chances (rapport des cotes) postérieur :

$$\frac{\Pr[M = H_0|x]}{\Pr[M = H_1|x]} = \frac{\Pr[M = H_0]}{\Pr[M = H_1]} \cdot \frac{f_0(x)}{f_1(x)},$$

où

- ▶ Le premier facteur est le rapport des cotes *a priori*
- ▶ Le deuxième facteur est le facteur de Bayes, le ratio de *vraisemblances marginales*
- ▶ La vraisemblance marginal  $f_0(x)$  est un genre de score de succès de prévision hors échantillon du modèle  $H_0$  où  $\theta = \frac{1}{2}$
- ▶  $f_1(x)$  est celui du modèle  $H_1$ .

## La décision optimale

Pour la loi *a priori*  $\text{Be}(\alpha, \beta)$ ,  $\alpha = \beta = 1$ ,  $r = 4$  et  $n = 12$ ,


$$f_0(x) = 2.4414062 \times 10^{-4},$$

$$f_1(x) = 1.5540016 \times 10^{-4},$$


$$\frac{f_0(x)}{f_1(x)} = 1.5710449$$

$$\delta(x) = \begin{cases} a_0 & \frac{c_I \Pr[M=H_0]}{c_{II} \Pr[M=H_1]} \frac{f_0(x)}{f_1(x)} \geq 1, \\ a_1 & \text{autrement.} \end{cases}$$

# DID THE SUN JUST EXPLODE? (IT'S NIGHT, SO WE'RE NOT SURE.)



FREQUENTIST STATISTICIAN:



BAYESIAN STATISTICIAN:

