

RFIDEC — cours 5: MAP et apprentissage non paramétrique

Christophe Gonzales

LIP6 – Université Paris 6, France

Plan du cours n°5

- 1 Maximum a posteriori
- 2 Estimation de densité

Max de vraisemblance et loi binomiale (1/2)

- pièce de monnaie
- $X \in \{0, 1\}$, $0 \iff$ Face, $1 \iff$ Pile
- $X \sim \mathcal{B}(1, p) \implies P(X = x|p) = p^x(1 - p)^{1-x}$
- n lancers de la pièce \implies observations $\mathbf{x} = \{x_1, \dots, x_n\}$
- $P(\mathbf{x}|p) = \prod_{i=1}^n P(x_i|p) = \prod_{i=1}^n p^{x_i}(1 - p)^{1-x_i}$

Problème : à partir de \mathbf{x} , peut-on raisonnablement déduire p ?

- maximum de vraisemblance :

$$\ln P(\mathbf{x}|p) = \sum_{i=1}^n [x_i \ln p + (1 - x_i) \ln(1 - p)]$$

$$\frac{\partial \ln P(\mathbf{x}|p)}{\partial p} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{n - \sum_{i=1}^n x_i}{1 - p} = 0 \implies p_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$$


Max de vraisemblance et loi binomiale (2/2)

$$p_{ML} = \frac{1}{n} \sum_{i=1}^n x_i$$

- 3 lancers \implies observations : {Pile,Pile,Pile}
- Maximum de vraisemblance $\implies p_{ML} = 1$



- \implies on considère que tout lancer de la pièce devrait tomber sur Pile
- \implies résultat à l'encontre du bon sens
- \implies autre estimateur : maximum a posteriori



Maximum a posteriori \implies modèle bayésien

Modèle bayésien

événements : parties de $\mathcal{X} \times \Theta$, où :

- \mathcal{X} = l'espace des observations (échantillons) \mathbf{x} de taille n
- Θ = espace des paramètres θ
- famille des événements dotée d'une loi de proba Π

- **cas discret** : Π déterminée par les probas des événements élémentaires $\pi(\mathbf{x}, \theta)$

- **cas continu** : Π déterminée par la densité jointe $\pi(\mathbf{x}, \theta)$

! Max de vraisemblance : $\pi(\mathbf{x}|\theta)$ au lieu de $\pi(\mathbf{x}, \theta) = \pi(\mathbf{x}|\theta)\pi(\theta)$

Le modèle bayésien (2/4)

Le cas discret :

- $\pi(\mathbf{x}, \theta) = \Pi(X = \mathbf{x}, \theta = \theta)$, où X, θ variables aléatoires
- $\pi(\mathbf{x}) = \Pi(X = \mathbf{x}) = \sum_{\theta \in \Theta} \Pi(X = \mathbf{x}, \theta = \theta) = \sum_{\theta \in \Theta} \pi(\mathbf{x}, \theta)$
- $\pi(\theta) = \Pi(\theta = \theta) = \sum_{\mathbf{x} \in \mathcal{X}} \Pi(X = \mathbf{x}, \theta = \theta) = \sum_{\mathbf{x} \in \mathcal{X}} \pi(\mathbf{x}, \theta)$
- $\pi(\mathbf{x}|\theta) = \Pi(X = \mathbf{x}|\theta = \theta) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\theta)}$
- $\pi(\theta|\mathbf{x}) = \Pi(\theta = \theta|X = \mathbf{x}) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\mathbf{x})}$

Probabilités a priori et a posteriori

- $\pi(\theta)$ = probabilité a priori de θ
- $\pi(\theta|\mathbf{x})$ = probabilité a posteriori de θ

Le modèle bayésien (3/4)

Le cas continu :

- $\pi(\mathbf{x}) = \Pi(X = \mathbf{x}) = \int_{\theta \in \Theta} \Pi(X = \mathbf{x}, \theta = \theta) d\theta = \int_{\theta \in \Theta} \pi(\mathbf{x}, \theta) d\theta$
- $\pi(\theta) = \Pi(\theta = \theta) = \int_{\mathbf{x} \in \mathcal{X}} \Pi(X = \mathbf{x}, \theta = \theta) d\mathbf{x} = \int_{\mathbf{x} \in \mathcal{X}} \pi(\mathbf{x}, \theta) d\mathbf{x}$
- $\pi(\mathbf{x}|\theta) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\theta)}$
- $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\mathbf{x})}$

Le modèle bayésien (4/4)

Probabilités a priori et a posteriori

- $\pi(\theta)$ = probabilité a priori de θ
= idée que l'on se fait de θ avant observation
- $\pi(\theta|\mathbf{x})$ = probabilité a posteriori de θ
= idée que l'on se fait de θ après observation

- Formule de Bayes : $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\pi(\mathbf{x})}$

- $$\begin{cases} \text{cas discret : } \pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}, \theta)} = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)} \\ \text{cas continu : } \pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}, \theta) d\theta} = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta) d\theta} \end{cases}$$

- **Rappel** : $\pi(\mathbf{x}|\theta) =$ vraisemblance de l'échantillon = $L(\mathbf{x}, \theta)$

Maximum a posteriori

Maximum a posteriori (MAP)

T estimateur du maximum a posteriori de θ :

défini par $\mathbf{x} \mapsto t = \underset{\theta \in \Theta}{\text{Argmax}} \pi(\theta|\mathbf{x})$


- échantillon i.i.d de n observations
- $X = (X_1, \dots, X_n) \implies \mathbf{x} = (x_1, \dots, x_n)$ observation de X
- $$\begin{cases} \text{cas discret : } \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \\ \text{cas continu : } \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\int_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta) d\theta} \end{cases}$$
- échantillon i.i.d $\implies \pi(\mathbf{x}|\theta) = L(\mathbf{x}, \theta) = \begin{cases} \prod_{i=1}^n P(x_i|\theta) & (\text{discret}) \\ \prod_{i=1}^n p(x_i|\theta) & (\text{continu}) \end{cases}$

MAP : retour sur la pièce de monnaie (1/2)

- pièce de monnaie $\implies X \in \{0, 1\}$

0 \iff Face  1 \iff Pile 

- $X \sim \mathcal{B}(1, \theta) \implies P(X = x|\theta) = \theta^x(1 - \theta)^{1-x}$

- échantillon \mathbf{x} de 3 lancers $\implies \{\text{Pile, Pile, Pile}\}$ 

- Max de vraisemblance $\implies \theta_{ML} = 1$

\implies tous les lancers devraient tomber sur Pile

- Modèle bayésien : $\Theta = \{\theta_1, \theta_2\}$

$\theta_1 =$ « biais en faveur de Pile », $\theta_2 =$ « biais en faveur de Face »

- Info a priori : $\pi(\theta_1) = \frac{2}{3}, \pi(\theta_2) = \frac{1}{3}$

Problème : quelle est la valeur du maximum a posteriori ?

MAP : retour sur la pièce de monnaie (2/2)

- Info a priori : $\pi(\theta_1) = \frac{2}{3}, \pi(\theta_2) = \frac{1}{3}$


- $L(\mathbf{x}, \theta_1) = \pi(\mathbf{x}|\theta_1) = \prod_{i=1}^3 P(x_i|\theta_1) = \frac{2}{3}^3 \times (1 - \frac{2}{3})^0 = \frac{2}{3}^3 \approx 0,296$

- $L(\mathbf{x}, \theta_2) = \pi(\mathbf{x}|\theta_2) = \prod_{i=1}^3 P(x_i|\theta_2) = \frac{1}{3}^3 \times (1 - \frac{1}{3})^0 = \frac{1}{3}^3 \approx 0,037$

- $\pi(\theta_1|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_1)\pi(\theta_1)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} = \frac{\frac{2}{3}^3 \times \frac{2}{3}}{\frac{2}{3}^3 \times \frac{2}{3} + \frac{1}{3}^3 \times \frac{1}{3}} \approx 0,941$

- $\pi(\theta_2|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_2)\pi(\theta_2)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \approx 0,059$

Max a posteriori : $\theta = \theta_1 \implies X \sim \mathcal{B}(1, \theta_1) = \mathcal{B}(1, 0.941)$



 probabilité que la pièce tombe sur Face $\neq 0$

calcul de la distribution a posteriori : $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\int_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)d\theta}$

⇒ si $\pi(\mathbf{x}|\theta)\pi(\theta)$ complexe analytiquement alors calcul de l'intégrale compliqué

Lois conjuguées

- $\pi(\theta)$: loi a priori
- $\pi(\mathbf{x}|\theta)$: fonction de vraisemblance
- $\pi(\theta|\mathbf{x})$: distribution a posteriori
- $\pi(\theta)$ et $\pi(\mathbf{x}|\theta)$ sont conjuguées si $\pi(\theta|\mathbf{x})$ appartient à la même famille de lois que $\pi(\theta)$

- pièce de monnaie ⇒ $X \in \{0, 1\}$: 0 ⇔  1 ⇔ 
- $X \sim \mathcal{B}(1, \theta)$ ⇒ vraisemblance d'un échantillon : $\pi(\mathbf{x}|\theta) = \theta^x(1 - \theta)^{n-x}$, avec $x = \#(x_i = 1)$
⇒ loi binomiale

Distribution de probabilité Beta

Loi Beta : $\text{Beta}(\theta, a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \theta^{a-1}(1-\theta)^{b-1}$

avec $\Gamma(x) = \int_0^{+\infty} t^{x-1} e^{-t} dt$

Espérance = $\frac{a}{a+b}$ Variance = $\frac{ab}{(a+b)^2(a+b+1)}$



⇒ loi Beta et loi binomiales conjuguées

Lois conjuguées : loi binomiale et loi Beta


- loi a priori : $\pi(\theta) = \text{Beta}(\theta, a, b) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \theta^{a-1}(1-\theta)^{b-1}$
- fonction de vraisemblance : $\pi(\mathbf{x}|\theta) = \theta^x(1-\theta)^{n-x}$, avec $x = \#(x_i = 1)$
- loi a posteriori : $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\sum_{\theta \in \Theta} \pi(\mathbf{x}|\theta)\pi(\theta)} \propto \pi(\mathbf{x}|\theta)\pi(\theta)$
- loi a posteriori : $\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1}(1-\theta)^{b+n-x-1}$

⇒ $\pi(\theta|\mathbf{x}) \sim \text{Beta}(\theta, x+a, b+n-x)$

Comparaison MAP – maximum de vraisemblance

- pièce de monnaie ⇒ $X \in \{0, 1\}$: 0 ⇔  1 ⇔ 
- Max de vraisemblance : $\pi(\mathbf{x}|\theta) = \theta^x(1-\theta)^{n-x} \Rightarrow \text{Beta}(\theta, x+1, n-x+1)$
- Max a posteriori : $\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1}(1-\theta)^{b+n-x-1} \Rightarrow \text{Beta}(\theta, x+a, n-x+b)$
⇒ Max de vraisemblance ⇔ Max a posteriori avec $a = 1$ et $b = 1$
Or $\text{Beta}(\theta, 1, 1) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} = \text{constante}$
Max de vraisemblance ⇔ Max a posteriori avec a priori uniforme
- ⚠ $n \rightarrow +\infty \Rightarrow \text{max de vraisemblance} \approx \text{max a posteriori}$
⇒ l'a priori devient négligeable

La loi Beta



Loi normale et loi conjuguée

- fonction de vraisemblance = loi normale, σ^2 connue
 \Rightarrow loi a priori conjuguée : loi Γ

La loi Γ

- $X \sim \Gamma(x, k, \theta)$

- fonction de densité de la loi Γ :

$$f(x, k, \theta) = x^{k-1} \frac{e^{-x/\theta}}{\theta^k \Gamma(k)} \quad \forall x, k, \theta > 0$$

- $\Gamma(k) = \int_0^{+\infty} t^{k-1} e^{-t} dt$

- $E(X) = k\theta, \quad V(X) = k\theta^2$




Lorsque k entier : $\Gamma(x, k, \theta)$ = loi de k variables indépendantes suivant une loi exponentielle d'espérance θ

- Familles de lois conjuguées :

http://en.wikipedia.org/wiki/Conjugate_prior

Loi Gamma



Prévention des risques d'inondation (1/3)

- Plan de prévention des risques d'inondations (PPR-I) :

photos satellite SPOT5 \Rightarrow zones susceptibles d'être inondées



- 3 catégories de parcelles :

- inondables (PI)
- partiellement inondables (PPI)
- non inondables (NI)

Prévention des risques d'inondation (2/3)

- images en teintes de gris
- proba d'obtenir un niveau de gris n dépend du type de zone :

$$P(n|PI) = \mathcal{N}(100, 20^2) \quad P(n|PPI) = \mathcal{N}(85, 5^2)$$

- nouvelle image envoyée par SPOT5 :



- zone Z : niveau de gris = $n = 80$
- **Connaissance a priori** : 60% de PI , 10% de PPI , 30% de NI

Problème : zone $Z = PI$ ou PPI ?

Prévention des risques d'inondation (3/3)

Problème : zone $Z = PI$ ou PPI ?

- 2 hypothèses :

- 1 $\theta_1 = \ll Z \text{ est de type } PI \gg$
- 2 $\theta_2 = \ll Z \text{ est de type } PPI \gg$

- **Idée** : calcul du MAP d'obtenir la zone Z sous θ_1 ou sous θ_2

$$\pi(\theta_1|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_1)\pi(\theta_1)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \quad \pi(\theta_2|\mathbf{x}) = \frac{L(\mathbf{x}, \theta_2)\pi(\theta_2)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)}$$

- Rappel cours 4 : $L(\mathbf{x}, \theta_1) \approx 0,0121$ $L(\mathbf{x}, \theta_2) \approx 0,0484$


- a priori : $\pi(\theta_1) = 0,6$ $\pi(\theta_2) = 0,1$

$$\pi(\theta_1|\mathbf{x}) = \frac{0,0121 \times 0,6}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \quad \pi(\theta_2|\mathbf{x}) = \frac{0,0484 \times 0,1}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)}$$

MAP \Rightarrow parcelle inondable (PI)

Analyse d'un trafic réseau (1/4)

- Réseau informatique : transfert de paquets



- **Problème** : analyse des paquets perdus sur un sous-réseau
- X : variable aléatoire « nombre de paquets envoyés jusqu'à bonne réception »
- X loi géométrique : $P(X = n) = (1 - p)^{n-1}p$
 p : probabilité qu'un paquet soit correctement transmis

Analyse d'un trafic réseau (2/4)

- observation de 7 réalisations de X :

2	3	8	3	4	7	8
---	---	---	---	---	---	---

Estimation de p ?

- 1 estimation par max de vraisemblance
- 2 estimation par MAP

1 estimation par max de vraisemblance

2	3	8	3	4	7	8
---	---	---	---	---	---	---

- vraisemblance : $L(\mathbf{x}, \theta) = \prod_{i=1}^7 P(x_i|\theta)$

θ = estimation de p

- observations $\Rightarrow L(\mathbf{x}, \theta) = (1 - \theta)^{28}\theta^7$

$$\Rightarrow \ln L(\mathbf{x}, \theta) = 28 \ln(1 - \theta) + 7 \ln \theta$$

$$\Rightarrow \frac{\partial \ln L(\mathbf{x}, \theta)}{\partial \theta} = \frac{-28}{1 - \theta} + \frac{7}{\theta} = \frac{7 - 35\theta}{\theta(1 - \theta)}$$

$$\Rightarrow \text{maximum de vraisemblance} = \theta = 0,2$$

2 estimation par max de vraisemblance

2	3	8	3	4	7	8
---	---	---	---	---	---	---

- A priori : $\pi(\theta) = \text{Beta}(\theta, 2, 15) = \frac{\Gamma(17)}{\Gamma(2)\Gamma(15)}\theta^1(1 - \theta)^{14}$

- Argmax $_{\theta} \pi(\theta|\mathbf{x}) = \text{Argmax}_{\theta} L(\mathbf{x}, \theta)\pi(\theta)$

$$= \text{Argmax}_{\theta} [(1 - \theta)^{28}\theta^7] \times [(1 - \theta)^{14}\theta]$$

$$= \text{Argmax}_{\theta} (1 - \theta)^{42}\theta^8$$

$$= \text{Argmax}_{\theta} 42 \ln(1 - \theta) + 8 \ln \theta$$


$$\Rightarrow \theta_{MAP} = 0,16$$

2 Estimation de densité

En route vers le non paramétrique

- jusqu'à maintenant : estimations des paramètres des densités :

- max de vraisemblance
- max a posteriori



\Rightarrow *statistique paramétrique*

\Rightarrow connaissance de la famille de lois a priori


Que faire si aucune loi a priori évidente ?

\Rightarrow statistique non paramétrique

Estimation de densité : idée naïve

- X : variable aléatoire
- $\{x_1, \dots, x_n\}$: les classes de X
- échantillon de taille $n \implies n_i$ individus dans la classe x_i

Densité \approx histogramme des valeurs observées




Problème : fonction de densité très irrégulière

Estimation de densité : la fenêtre mobile (1/2)

Idée de la fenêtre mobile

- X : variable aléatoire
- $\forall x$ valeur de X , $I_x = [x - \frac{h}{2}, x + \frac{h}{2}[$ = classe de longueur h
- densité estimée : $\hat{f}(x) = \frac{1}{n} \#x_i : x - \frac{h}{2} \leq x_i < x + \frac{h}{2}$



Problème : fonction de densité encore trop irrégulière

Estimation de densité : la fenêtre mobile (2/2)

densité estimée : $\hat{f}(x) = \frac{1}{n} \#x_i : x - \frac{h}{2} \leq x_i < x + \frac{h}{2}$

$$\implies \hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

où K = fonction indicatrice de l'intervalle $[-\frac{1}{2}, \frac{1}{2}[$:

$$K(u) = \begin{cases} 0 & \text{si } u \geq \frac{1}{2} \text{ ou } u < -\frac{1}{2} \\ 1 & \text{si } -\frac{1}{2} \leq u < \frac{1}{2} \end{cases}$$

Estimation de densité par la méthode du noyau

- X : variable aléatoire
 - $\forall x$ valeur de X , $I_x = [x - \frac{h}{2}, x + \frac{h}{2}[$ = classe de longueur h
 - densité estimée : $\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$
- avec K = fonction continue = **noyau**

Estimation de densité par la méthode du noyau

$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right)$$

- noyaux fréquemment utilisés :
 - noyau gaussien : $K(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}}$
 - noyau d'Epanechnikov : $K(u) = \frac{3}{4\sqrt{5}} \left(1 - \frac{u^2}{5}\right)$ pour $|u| < \sqrt{5}$
- constante h = constante de lissage
 - $\left\{ \begin{array}{l} h \text{ petit} \implies \hat{f} \text{ très irrégulière} \\ h \text{ grand} \implies \hat{f} \text{ très (trop) lisse} \end{array} \right.$
- h souvent défini empiriquement