

RFIDEC — cours 5: MAP et apprentissage non paramétrique

Christophe Gonzales

LIP6 – Université Paris 6, France

- 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 :

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

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

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

- 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

En route vers le maximum a posteriori

(YET ANOTHER) HISTORY OF LIFE AS WE KNOW IT...



Le modèle bayésien (1/4)

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 cas continu :

$$\bullet \pi(\mathbf{x}) = \Pi(X = \mathbf{x}) = \int_{\theta \in \Theta} \Pi(X = \mathbf{x}, \theta = \theta) d\theta = \int_{\theta \in \Theta} \pi(\mathbf{x}, \theta) d\theta$$

$$\bullet \pi(\theta) = \Pi(\theta = \theta) = \int_{\mathbf{x} \in \mathcal{X}} \Pi(X = \mathbf{x}, \theta = \theta) d\mathbf{x} = \int_{\mathbf{x} \in \mathcal{X}} \pi(\mathbf{x}, \theta) d\mathbf{x}$$

$$\bullet \pi(\mathbf{x}|\theta) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\theta)}$$

$$\bullet \pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}, \theta)}{\pi(\mathbf{x})}$$

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 : $\pi(\theta|\mathbf{x}) = \frac{\pi(\mathbf{x}|\theta)\pi(\theta)}{\pi(\mathbf{x})}$

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

- **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

- $$\left\{ \begin{array}{l} \text{cas discret} : \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\sum_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)} \\ \text{cas continu} : \pi(\theta|\mathbf{x}) = \frac{L(\mathbf{x}, \theta)\pi(\theta)}{\int_{\theta \in \Theta} L(\mathbf{x}, \theta)\pi(\theta)d\theta} \end{array} \right.$$

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

$\theta_1 = \ll$ biais en faveur de Pile \gg , $\theta_2 = \ll$ biais en faveur de Face \gg

- 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 $\pi(\theta)$

Lois conjuguées : exemple de la pièce de monnaie

● pièce de monnaie $\implies X \in \{0, 1\} : 0 \iff$



$1 \iff$



● $X \sim \mathcal{B}(1, \theta) \implies$ vraisemblance d'un échantillon :

$$\pi(\mathbf{x}|\theta) = \theta^x (1 - \theta)^{n-x}, \text{ avec } x = \#(x_i = 1)$$

\implies loi binomiale

Distribution de probabilité Beta

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

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

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

\implies 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 : $\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1} (1-\theta)^{b+n-x-1}$

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

Comparaison MAP – maximum de vraisemblance

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

- Max de vraisemblance :

$$\pi(\mathbf{x}|\theta) = \theta^x(1 - \theta)^{n-x} \implies \text{Beta}(\theta, x + 1, n - x + 1)$$

- Max a posteriori :

$$\pi(\theta|\mathbf{x}) \propto \theta^{x+a-1}(1 - \theta)^{b+n-x-1} \implies \text{Beta}(\theta, x + a, n - x + b)$$





\implies Max de vraisemblance \iff 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 \iff Max a posteriori avec a priori uniforme

 $n \rightarrow +\infty \implies \text{max de vraisemblance} \approx \text{max a posteriori}$
 \implies l'a priori devient négligeable

La loi Beta



Loi normale et loi conjuguée

- fonction de vraisemblance = loi normale, σ^2 connue
⇒ 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 \implies zones susceptibles d'être inondées



- 3 catégories de parcelles :
 - 1 inondables (*PI*)
 - 2 partiellement inondables (*PPI*)
 - 3 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 ?

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 \implies 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

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

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

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

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

2 estimation par max de vraisemblance

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

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


- $\text{Argmax}_{\theta}\pi(\theta|\mathbf{x}) = \text{Argmax}_{\theta}L(\mathbf{x}, \theta)\pi(\theta)$
 $= \text{Argmax}_{\theta}[(1 - \theta)^{28}\theta^7] \times [(1 - \theta)^{14}\theta]$
 $= \text{Argmax}_{\theta}(1 - \theta)^{42}\theta^8$
 $= \text{Argmax}_{\theta} 42 \ln(1 - \theta) + 8 \ln \theta$

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

② Estimation de densité

En route vers le non paramétrique

- jusqu'à maintenant : estimations des paramètres des densités :
 - max de vraisemblance
 - max a posteriori



⇒ *statistique paramétrique*

⇒ connaissance de la famille de lois a priori


Que faire si aucune loi a priori évidente ?

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

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

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*

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

- 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

$$\begin{cases} h \text{ petit} & \implies \hat{f} \text{ très irrégulière} \\ h \text{ grand} & \implies \hat{f} \text{ très (trop) lisse} \end{cases}$$

- h souvent défini empiriquement