

Apprentissage statistique I

IFT-17587
Concepts avancés pour systèmes intelligents
Luc Lamontagne

1

Plan

- Approche probabiliste - *Naive Bayes*
- Apprentissage à base d'exemples (*Instance-based*)
- Réseaux de neurones

2

Rappel sur l'apprentissage inductif


■ Classification

- Utiliser l'hypothèse h pour déterminer la valeur (*output*) correspondant à une nouvelle instance x (*input*)

$x \rightarrow$ hypothèse h $\rightarrow f(x)$

■ Apprentissage

- Construire l'hypothèse h (un modèle) qui recouvre le mieux nos exemples d'entraînement



3

Approche probabiliste

■ Problème de classification

- Sélectionner la valeur C qui maximise $P(C | x_1, \dots, x_n)$

- x_1, \dots, x_n sont les valeurs des attributs de l'exemple à classifier

■ Exemple du restaurant :

- Décision à prendre pour un restaurant $resto_i$
 $resto_i$: *alt* = yes, *bar* = yes, ..., *est* = 0-10
- La décision consiste à retenir la probabilité maximum entre
 $P(\text{WillWait} = \text{oui} | \text{resto}_i)$ vs. $P(\text{WillWait} = \text{non} | \text{resto}_i)$



- Il nous faut toutefois le modèle probabiliste $P \rightarrow$ hypothèse...

4

Approche probabiliste :


Apprentissage du modèle

■ Règle de Bayes

$$P(C | x_1, \dots, x_n) = \alpha P(x_1, \dots, x_n | C) P(C)$$

■ Apprentissage du modèle

- Trouver la meilleure hypothèse h pour nos exemples
 - On doit donc déterminer les distributions $P(x_1, \dots, x_n | C)$ et $P(C)$



5

Approche probabiliste :

Exemple des sacs de bonbons

- Un manufacturier produit des bonbons en deux saveurs différentes :

- Cerise et lime

- Chacun bonbon est enveloppé dans un emballage opaque
 - On ne peut pas connaître la saveur du bonbon sans retirer l'emballage.

- Le manufacturier offre 5 sortes de sacs préparés à l'avance dont les proportions varient :

- h_1 : 100% cerise
- h_2 : 75% cerise + 25% lime
- h_3 : 50% cerise + 50% lime
- h_4 : 25% cerise + 75% lime
- h_5 : 100% lime

- Tous les sacs sont identiques de l'extérieur !

- Le seul moyen de distinguer les sacs est de piger des bonbons à l'intérieur du sac et de les développer pour connaître la saveur.



6

Approche probabiliste – Exemple des bonbons :

Version simple de l'exemple

■ Supposons :

- On vous remet un sac .
- Vous ne connaissez pas sa distribution de bonbons.
- 5 hypothèses possibles : h_1 , h_2 , h_3 , h_4 , h_5 .

■ Comment faire pour déterminer le type de sac?

- On pige un nombre suffisamment élevé de bonbons.
 - Les bonbons b_j que l'on pige sont nos exemples.
- A partir de ces exemples :
 - On estime la probabilité que le sac soit de type $h_i \rightarrow P(h_i | b_1, b_2, \dots, b_N)$
 - Par exemple : $P(\text{ } | \text{ } \dots \text{ })$
- On retient le type de sac qui est le plus probable.
 - On retient l'hypothèse qui explique le mieux la distribution de nos exemples.
 - Choisir la meilleure hypothèse \rightarrow apprentissage

7

Approche probabiliste – Exemple des bonbons :


Version simple de l'exemple

■ Par la règle de Bayes

$$P(h_i | b_1, b_2, \dots, b_N) = \alpha P(b_1, b_2, \dots, b_N | h_i) P(h_i)$$

■ $P(h_i)$: la distribution à priori des sacs

- On suppose que c'est déterminé par le fabricant
- Par exemple la distribution suivante :



■ $P(b_1, b_2, \dots, b_N | h_i)$: la vraisemblance de piger N bonbons

- On suppose que chaque pige est indépendante des autres.

$$P(b_1, \dots, b_N | h_i) = \prod_j P(b_j | h_i)$$

□ Exemple:


- 10 bonbons pignés :
- $P(\text{ } | \text{ } \dots \text{ }) = (0.5)^{10} = 0.000244$
- $P(\text{ } | \text{ } \dots \text{ }) = \alpha \cdot (0.000244) \cdot (0.4) = 0.000097 \alpha$

8

Approche probabiliste – Exemple des bonbons : Version simple de l'exemple

- Comparaison des hypothèses

- Exemples b_j : 
- Estimation de la probabilité à posteriori $P(h_i | b_1, b_2, \dots, b_N)$




9



Approche probabiliste – Exemple des bonbons : Version un peu moins simple

- Maintenant il n'y a plus de type de sac préparé à l'avance...

- La proportion cerise/lime varie d'un sac à l'autre
- Le % de cerise = θ (% de lime : $1 - \theta$)
- Les distributions de sac sont équiprobables



- $P(b_1, b_2, \dots, b_N | h_\theta)$: la probabilité de piger N bonbons pour l'hypothèse θ



- Si N contient c  et l 
- La vraisemblance de cet échantillon d'exemple est

$$P(b_1, \dots, b_N | h_\theta) = \prod_j P(b_j | h_\theta) = \theta^c \cdot (1 - \theta)^l$$

10

Approche probabiliste – Exemple des bonbons : Version un peu moins simple

- Quel est la meilleure hypothèse h_θ ?

- Celle qui recouvre le mieux les N exemples (c  et l )

- Donc trouver le θ qui maximise la vraisemblance $P(b_1, b_2, \dots, b_N | h_\theta)$

- Plus facile de maximiser $\log P(b_1, b_2, \dots, b_N | h_\theta)$

$$\log P(b_1, \dots, b_N | h_\theta) = \log(\theta^c \cdot (1 - \theta)^l) = c \log \theta + l \log(1 - \theta)$$

- Pour maximiser : on fait la dérivé et on rend l'expression égale à 0

$$\frac{\partial \log P(b_1, \dots, b_N | h_\theta)}{\partial \theta} = \frac{c}{\theta} - \frac{l}{(1 - \theta)} = 0$$

$$\theta = \frac{c}{c + l} = \frac{c}{N} \quad \leftarrow \text{C'est tout simplement la proportion de } \text{red circle} !$$

11

Apprentissage probabiliste : Maximum de vraisemblance

- Meilleure hypothèse

- Hypothèse contenant des paramètres continus (probabilités)
- Trouver les paramètres qui optimise $P(d|h)$ pour nos exemples d'entraînement

- Approche du maximum de vraisemblance

- Formuler l'expression $P(d|h)$
- On prend le logarithme et on dérive
- On trouve les paramètres lorsque la dérivé est égale à 0

12

Approche probabiliste – Exemple des bonbons : Version encore un peu moins simple

- Chacun des N bonbons est maintenant enveloppé dans un emballage rouge ou vert

Input :

- r_c cerises en rouge
- g_c cerises en vert
- r_l limes rouge
- g_l cerises vert

Output :

- c cerises + l limes

	Input	Output
1		
2		
3		
...
N		

- Paramètres du modèle à estimer

$$P(C = cerise) = \theta$$

$$P(\text{Emballage} = rouge | cerise) = \theta_1$$

$$P(\text{Emballage} = rouge | lime) = \theta_2$$



13

Approche probabiliste – Exemple des bonbons : Version encore un peu moins simple

- Probabilité de nos exemples d'entraînement d

$$P(d | \theta_{\theta, \theta_1, \theta_2}) = \prod_j P(d_j | \theta_{\theta, \theta_1, \theta_2}) = \theta^c \cdot (1-\theta)^l \cdot \theta_1^{r_c} \cdot (1-\theta_1)^{g_c} \cdot \theta_2^{r_l} \cdot (1-\theta_2)^{g_l}$$

- Maximum de vraisemblance (les résultats seulement...)

$$P(C = cerise) = \theta = c / (c+l) \quad \leftarrow \text{Proportion de cerises dans la colonne output}$$



$$P(\text{Emballage} = rouge | Saveur)$$

$$cerise \quad \theta_1 = r_c / (r_c + g_c)$$

$$lime \quad \theta_2 = r_l / (r_l + g_l)$$

\leftarrow Proportion de cerises qui sont emballées en rouge selon notre tableau

Apprentissage : on compte le nombre d'occurrences dans notre tableau d'exemples!

14

Apprentissage probabiliste : Naïve Bayes

- Que faire si notre variable de classe C dépend de plusieurs attributs x_i ?



- Approximation : les attributs sont mutuellement indépendants

$$P(C | x_1, \dots, x_n) = \alpha P(C) \prod_i P(x_i | C) \quad \leftarrow \text{Naïve Bayes!}$$

- Pour notre exemple du restaurant

$$P(C = WillWait | x) = \alpha \cdot P(WillWait) \cdot P(Alt = yes | WillWait) \cdot P(Bar = yes | WillWait) \dots$$

15

Apprentissage probabiliste : Naïve Bayes

- Donne de bons résultats en pratique
- Particulièrement efficace avec une approche ensemble de type *boosting*
- Un problème :
 - Si $x_i = a$ et $C = b$ n'est pas dans nos exemples
 - Alors $P(C = b | x_i = a) = 0$
- Il existe différentes fonctions de lissage (*smoothing*) pour éliminer ce problème
 - Par exemple, additionner 1 à tous les comptes (*add-one*).

16