

Modélisation de l'incertitude (M2 MIAGE IA²)

Andrea G. B. Tettamanzi
Laboratoire I3S – Équipe SPARKS
`andrea.tettamanzi@univ-cotedazur.fr`



Séance 2

Raisonnement probabiliste

Réseaux bayésiens

Dans cette séance

- Classification bayésienne
- Indépendance conditionnelle
- Réseaux bayésiens

Classification bayésienne

- **Un classificateur statistique** : il effectue une prédiction probabiliste, c'est-à-dire qu'il prédit les probabilités d'appartenance à une classe
- **Fondation** : Basée sur le théorème de Bayes.
- **Performance** : Un classificateur bayésien simple, le classificateur naïf de Bayes, a des performances comparables à celles des arbres de décision et de certains classificateurs basés sur les réseaux de neurones
- **Incrémentale** : chaque exemple d'entraînement peut augmenter/diminuer progressivement la probabilité qu'une hypothèse soit correcte – les connaissances préalables peuvent être combinées avec les données observées
- **Standard** : Même lorsque les méthodes bayésiennes sont difficiles à calculer, elles peuvent fournir une norme de prise de décision optimale par rapport à laquelle d'autres méthodes peuvent être mesurées

Rappels sur le théorème de Bayes

- Soit X un tuple de données : l'étiquette de classe est inconnue
- Soit H l'hypothèse que X appartienne à la classe C
- La classification consiste à déterminer $P(H | X)$, la probabilité que l'hypothèse soit correcte, étant donné le tuple de données observées X
- $P(H)$ (probabilité *a priori*), la probabilité initiale
 - Par exemple, X achètera un ordinateur, quels que soient son âge, ses revenus, etc.
- $P(X)$: probabilité que les données du tuple soient observées
- $P(X | H)$ (probabilité *a posteriori*), la probabilité d'observer le tuple X , étant donné que l'hypothèse H est correcte
 - Par exemple, étant donné que X va acheter un ordinateur, la probabilité que X soit de 31..40, revenu moyen, etc.

Théorème de Bayes

- Étant données les données d'entraînement \mathbf{X} , la probabilité a posteriori de l'hypothèse H , $P(H | \mathbf{X})$, suit la formule de Bayes

$$P(H | \mathbf{X}) = \frac{P(\mathbf{X} | H)P(H)}{P(\mathbf{X})}$$

Informellement, ceci peut s'écrire comme

a posteriori = vraisemblance x a priori / évidence

- On prédit que \mathbf{X} appartienne à C_i ssi la probabilité $P(C_i | \mathbf{X})$ est la plus haute parmi toutes les $P(C_k | \mathbf{X})$ pour toutes les k classes
- Difficulté pratique : cela requiert une connaissance initiale de beaucoup de probabilités, ce qui signifie un coût de calcul

Classification bayésienne naïve

- Soit D un jeu de données d'entraînement de tuples avec leurs étiquettes de classe, et soit chaque tuple représenté par un vecteur de n attributs $\mathbf{X} = (x_1, x_2, \dots, x_n)$
- Supposons qu'il y ait m classes C_1, C_2, \dots, C_m .
- La classification se fait sur la base de la plus grande probabilité a posteriori, c-à-d, du $P(C_i | \mathbf{X})$ maximum

On peut calculer ceci grâce au Théorème de Bayes :

$$P(C_i | \mathbf{X}) = \frac{P(\mathbf{X} | C_i)P(C_i)}{P(\mathbf{X})}$$

- Puisque $P(\mathbf{X})$ est constante pour toute classe, il suffit juste de maximiser $P(\mathbf{X} | C_i)P(C_i)$

Classificateur naïf bayésien

- Simplification : on suppose que les attributs soit conditionnellement indépendant :

$$P(\mathbf{X} | C_i) = \prod_{k=1}^n P(X_k | C_i)$$

- Ceci réduit beaucoup la complexité des calculs : il suffit juste de prendre en compte la distribution de chaque classe
- Si A_k est catégorielle, $P(X_k | C_i)$ est le nombre de tuples de C_i ayant la valeur X_k pour A_k , divisé par $|C_{i,D}|$ (nombre de tuples de C_i en D)
- Si A_k est à valeurs continues, $P(X_k | C_i)$ est généralement calculé sur la base d'une distribution gaussienne avec une moyenne μ et un écart-type σ et $P(x_k | C_i)$ est

$$\mathcal{N}(x; \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$P(\mathbf{X} | C_i) = \mathcal{N}(X_k; \mu_{C_i}, \sigma_{C_i})$$

Classificateur naïf bayésien : données entraînement

Classes :

C1:buys_computer = 'yes'

C2:buys_computer = 'no'

Tuple donné :

X = (age <=30,

Income = medium,

Student = yes

Credit_rating = Fair)

age	income	student	credit_rating	com
<=30	high	no	fair	no
<=30	high	no	excellent	no
31...40	high	no	fair	yes
>40	medium	no	fair	yes
>40	low	yes	fair	yes
>40	low	yes	excellent	no
31...40	low	yes	excellent	yes
<=30	medium	no	fair	no
<=30	low	yes	fair	yes
>40	medium	yes	fair	yes
<=30	medium	yes	excellent	yes
31...40	medium	no	excellent	yes
31...40	high	yes	fair	yes
>40	medium	no	excellent	no

Classificateur naïf bayésien : exemple

- $P(C_i)$: $P(\text{buys_computer} = \text{"yes"}) = 9/14 = 0.643$
 $P(\text{buys_computer} = \text{"no"}) = 5/14 = 0.357$
 - Compute $P(X|C_i)$ for each class
 $P(\text{age} = \text{"<=30"} | \text{buys_computer} = \text{"yes"}) = 2/9 = 0.222$
 $P(\text{age} = \text{"<= 30"} | \text{buys_computer} = \text{"no"}) = 3/5 = 0.6$
 $P(\text{income} = \text{"medium"} | \text{buys_computer} = \text{"yes"}) = 4/9 = 0.444$
 $P(\text{income} = \text{"medium"} | \text{buys_computer} = \text{"no"}) = 2/5 = 0.4$
 $P(\text{student} = \text{"yes"} | \text{buys_computer} = \text{"yes"}) = 6/9 = 0.667$
 $P(\text{student} = \text{"yes"} | \text{buys_computer} = \text{"no"}) = 1/5 = 0.2$
 $P(\text{credit_rating} = \text{"fair"} | \text{buys_computer} = \text{"yes"}) = 6/9 = 0.667$
 $P(\text{credit_rating} = \text{"fair"} | \text{buys_computer} = \text{"no"}) = 2/5 = 0.4$
 - **$X = (\text{age} \leq 30, \text{income} = \text{medium}, \text{student} = \text{yes}, \text{credit_rating} = \text{fair})$**
- $P(X|C_i)$: $P(X|\text{buys_computer} = \text{"yes"}) = 0.222 \times 0.444 \times 0.667 \times 0.667 = 0.044$
 $P(X|\text{buys_computer} = \text{"no"}) = 0.6 \times 0.4 \times 0.2 \times 0.4 = 0.019$
- $P(X|C_i) \cdot P(C_i)$: $P(X|\text{buys_computer} = \text{"yes"}) \cdot P(\text{buys_computer} = \text{"yes"}) = 0.028$
 $P(X|\text{buys_computer} = \text{"no"}) \cdot P(\text{buys_computer} = \text{"no"}) = 0.007$

Therefore, **X belongs to class ("buys_computer = yes")**

Problème de la probabilité nulle

- La classification naïve bayésienne requiert que chaque probabilité conditionnelle soit non-nulle. Sinon, la probabilité prédite sera nulle !

$$P(\mathbf{X} | C_i) = \prod_{k=1}^n P(X_k | C_i)$$

- Exemple : soit un jeu de données de 1000 tuples, avec income=low (0), income=medium (990), et income = high (10),
- On utilise la correction laplacienne
 - On ajoute 1 à chaque cas
 - $\Pr(\text{income} = \text{low}) = 1/1003$
 - $\Pr(\text{income} = \text{medium}) = 991/1003$
 - $\Pr(\text{income} = \text{high}) = 11/1003$
 - Ainsi, les estimations de probabilité « corrigées » sont proches de leur contreparties « brutes » ; en outre, elle ne sont jamais nulles

Remarques sur Naïve Bayes

- Avantages
 - Facile à coder
 - De bons résultats dans la plupart des cas
- Inconvénients
 - Hypothèse de fond : indépendance statistique des classes, ce qui rarement est vrai, et qui donc entraîne une perte de précision
 - Dans la réalité, il existe des dépendances entre les variables
 - Exemples : patients d'un hôpital : âge, familiarité, etc.
 - Symptômes: fièvre, tous, etc. ; Maladie : tumeur, diabète, etc.
 - Ces dépendances ne peuvent pas être modélisées par un classificateur naïf bayésien
- Comment modéliser ces dépendances ?
 - Avec les **réseaux bayésiens**

Indépendance

- Deux variables aléatoires sont (absolument) indépendantes ssi

$$P(A | B) = P(A)$$

ou
$$P(A, B) = P(A | B)P(B) = P(A)P(B)$$

– Exemple : deux lances d'une pièce

- Si n v.a. booléennes sont indépendantes la distribution conjointe complète est

$$P(X_1, \dots, X_n) = \prod_i P(X_i)$$

- Elle a donc n degrés de liberté

Indépendance conditionnelle

- Considérons les trois v.a. (booléennes)
 - Covid, PCR, Dyspnée
- La distribution conjointe a $2^3 = 8$ évts élémentaires
- Si un patient a la Covid, la probabilité qu'il ait une dyspnée ne dépend pas du résultat du test PCR :

$$P(Dyspnée \mid Covid, PCR) = P(Dyspnée \mid Covid)$$

- Dyspnée est conditionnellement indépendante de PCR
- De même, s'il n'a pas la Covid,
$$P(Dyspnée \mid \neg Covid, PCR) = P(Dyspnée \mid \neg Covid)$$

Indépendance conditionnelle

- Des propositions équivalentes sont

$$P(PCR \mid Covid, Dyspnée) = P(PCR \mid Covid)$$

$$P(PCR, Dyspnée \mid Covid,) = P(PCR \mid Covid)P(Dyspnée \mid Covid)$$

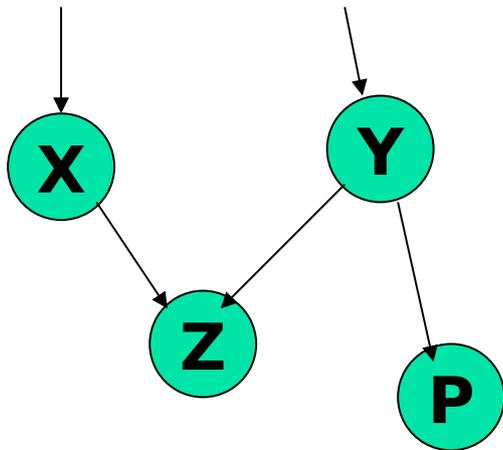
- La distribution conjointe peut donc s'écrire

$$\begin{aligned} P(PCR, Dyspnée, Covid) &= \\ &= P(PCR, Dyspnée \mid Covid)P(Covid) \\ &= P(PCR \mid Covid)P(Dyspnée \mid Covid)P(Covid) \end{aligned}$$

- $2 + 2 + 1 = 5$ degrés de liberté

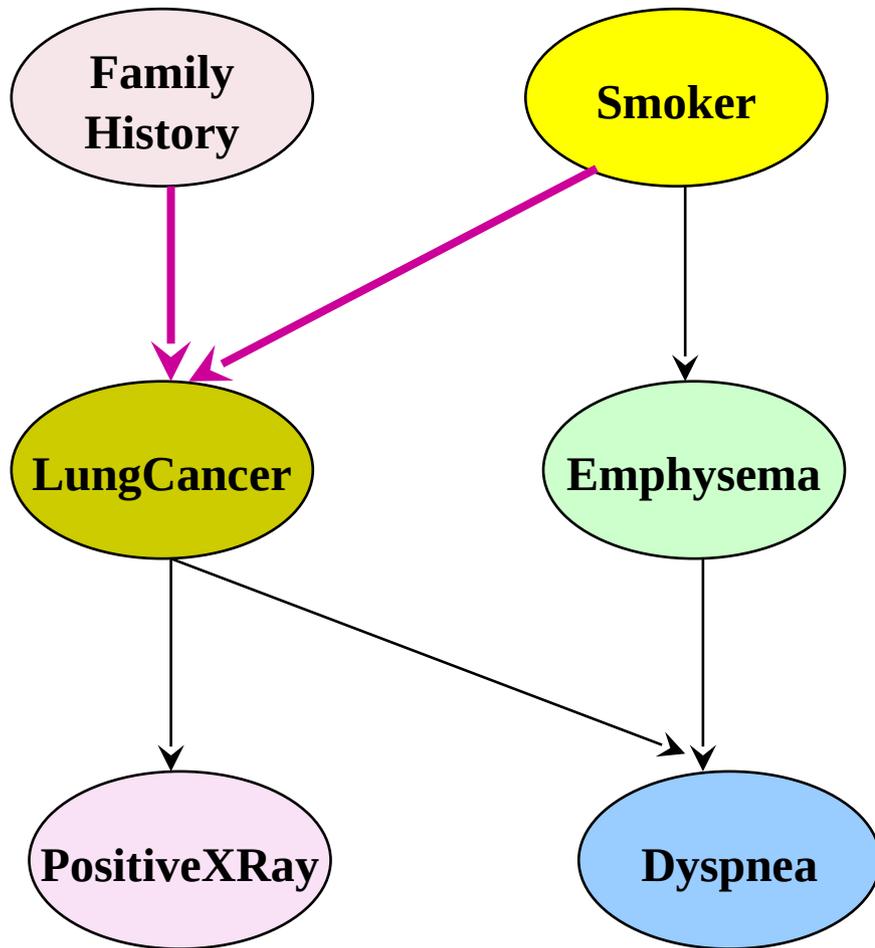
Réseaux bayésiens

- Le réseau bayésien (ou de croyance) permettent une spécification concise d'une distribution de probabilité conjointe en prenant en compte l'indépendance conditionnelle
- Un modèle graphique des relations causales
 - Les arcs représentent les dépendances entre variables



- Nœuds: variables aléatoires
- Arcs: dépendance
- X et Y sont les parents de Z, Y est le parent de P
- Z et P sont indépendants
- Graphe acyclique

Exemple



La **table de probabilité conditionnelle (TPC)** de la v.a. LungCancer :

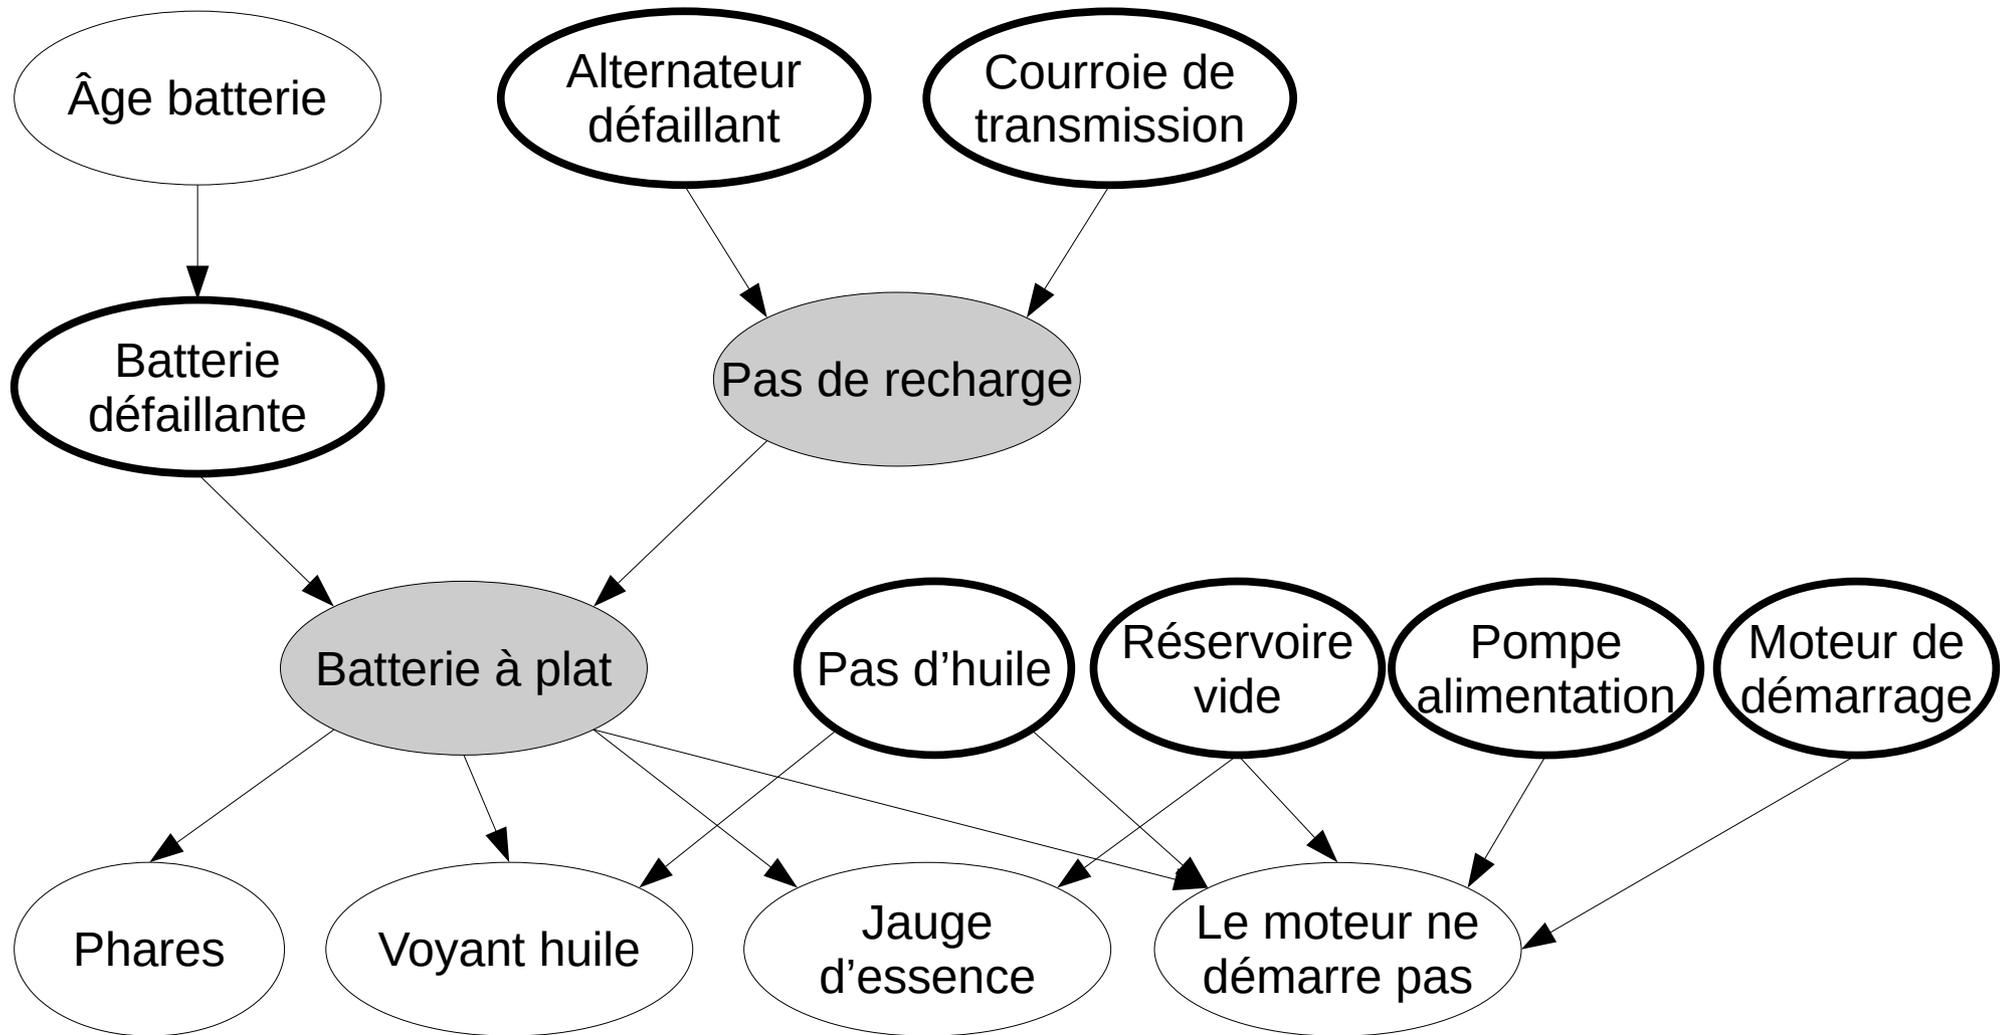
	(FH, S)	(FH, ~S)	(~FH, S)	(~FH, ~S)
LC	0.8	0.5	0.7	0.1
~LC	0.2	0.5	0.3	0.9

La TPC donne la probabilité conditionnelle pour chaque combinaison des valeurs de ses parents

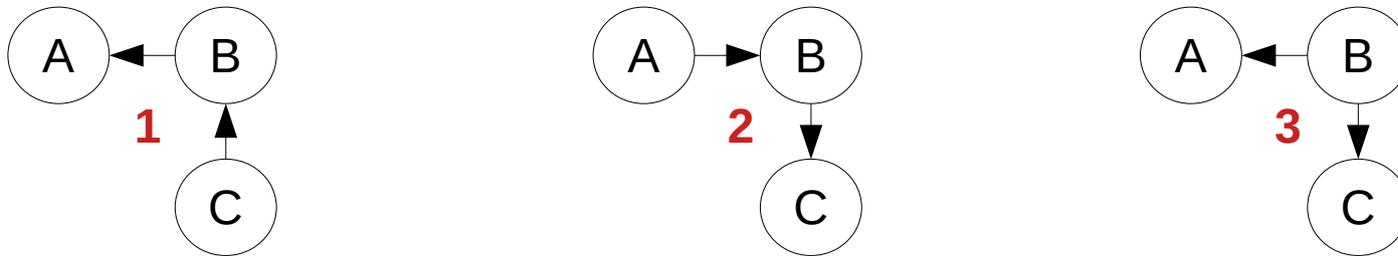
Calcul de la probabilité conjointe de **X**, à partir des TPC :

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{Parents}(Y_i))$$

Exemple avec variables cachées



Dépendance \neq causalité



$$P_1(A, B, C) = P(A | B)P(B | C)P(C)$$

$$\begin{aligned} P_2(A, B, C) &= P(A) \cdot P(B | A) \cdot P(C | B) \\ &= P(A) \cdot \frac{(P(A|B)P(B))}{P(A)} \cdot \frac{P(B|C)P(C)}{P(B)} \\ &= P(A | B) \cdot P(B | C)P(C) = P_1(A, B, C) \end{aligned}$$

$$\begin{aligned} P_3(A, B, C) &= P(A | B) \cdot P(B) \cdot P(C | B) \\ &= P(A | B) \cdot P(B) \cdot \frac{P(B|C)P(C)}{P(B)} \\ &= P(A | B) \cdot P(B | C)P(C) = P_1(A, B, C) \end{aligned}$$

Apprentissage de RB

- Plusieurs scénarios :
 - Structure donnée, toutes les variables observables: on apprend juste les TPCs
 - Structure connue, mais quelques variables cachées : descente du gradient, comme pour les réseaux de neurones
 - Structure non connue, variables observables : recherche dans l'espace des structures
 - Structure non connue, variables cachées : pas d'algorithmes efficaces connus

