

Décision dans l'incertain

Cours 4: Réseaux Bayésiens

Stéphane Airiau

Université Paris-Dauphine

Introduction

- la table des probabilités peut répondre à toutes les questions sur le domaine
 - Si le nombre de variables est grand, la table devient rapidement trop grosse
 - difficile d'obtenir tous les nombres
 - va nécessiter beaucoup d'opérations pour calculer le résultat!
 - spécifier les probabilités de chaque monde possible est difficile et pas forcément naturel.
 - l'indépendance et l'indépendance conditionnelle peuvent grandement aider à faire baisser le nombre de probabilités à connaître pour calculer la table complète.
- ➡ structure de données Réseaux Bayésiens : elle représente la dépendance entre chaque variable pour représenter de façon concise toute distribution complète de probabilité.

Rappel indépendance

Deux variables sont indépendantes ssi

$$\forall (x,y) \in \text{Dom}(X) \times \text{Dom}(Y) : \mathbb{P}(x,y) = \mathbb{P}(x)\mathbb{P}(y)$$

⇒ la distribution jointe est le produit de deux distributions plus simples.

on peut aussi écrire

$$\forall (x,y) \in \text{Dom}(X) \times \text{Dom}(Y) : \mathbb{P}(x | y) = \mathbb{P}(x)$$

On va noter $X \perp Y$

Indépendance est parfois une simplification d'une hypothèse sur la modélisation.

- on observe une distribution empirique "proche" de l'indépendance.
- Que peut on attendre pour $\{\text{Météo}, \text{Traffic}, \text{Carie}, \text{MalDeDents}\}$?
 $\{\text{Météo}, \text{Traffic}\}$ sont sûrement indépendants de $\{\text{Carie}, \text{MalDeDents}\}$
⇒ pas complète indépendance, mais des indépendances.
- ⇒ simplement vérifier les produits.

Rappel indépendance

Supposons qu'on a n dés parfaitement équilibrés

⇒ si on veut représenter la distribution jointe : 6^n nombres à spécifier

On peut suppose que les dés sont indépendants!

⇒ avec l'indépendance, on n'a besoin que de $6n$ nombres!

On est intéressé à des domaines où il y a des dépendances, sinon, on n'a pas grand chose à faire!

Rappel indépendance conditionnelle

- Si j'ai une carie, la détection d'une carie par la sonde est indépendante de si j'ai mal aux dents ou non!

$$\mathbb{P}(\text{testSonde} \mid \text{malAuDent}, \text{carie}) = \mathbb{P}(\text{testSonde} \mid \text{carie})$$

- la même chose fonctionne si je n'ai pas de carie!

$$\mathbb{P}(\text{testSonde} \mid \text{malAuDent}, \neg \text{carie}) = \mathbb{P}(\text{testSonde} \mid \neg \text{carie})$$

- La variable *TestSonde* est conditionnellement indépendante de la variable *MalauDents* étant donnée la présence de carie.

$$\mathbb{P}(\text{TestSonde} \mid \text{MalAuDent}, \text{Carie}) = \mathbb{P}(\text{TestSonde} \mid \text{Carie})$$

d'autres

- $\mathbb{P}(\text{MalAuDent} \mid \text{TestSonde}, \text{Carie}) = \mathbb{P}(\text{MalAuDent} \mid \text{Carie})$
- $\mathbb{P}(\text{MalAuDent}, \text{TestSonde} \mid \text{Carie}) = \mathbb{P}(\text{MalAuDent} \mid \text{Carie})\mathbb{P}(\text{TestSonde} \mid \text{Carie})$

Rappel indépendance conditionnelle

X est indépendante de Y sachant Z si $\forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x,y | z) = \mathbb{P}(x | z)\mathbb{P}(y | z)$

On va noter

$X \perp\!\!\!\perp Y | Z$

$$(1) \quad \forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x,y | z) = \mathbb{P}(x | z)\mathbb{P}(y | z)$$

$$(2) \quad \forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x | y,z) = \mathbb{P}(x | z)$$

Rappel indépendance conditionnelle

X est indépendante de Y sachant Z si $\forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x,y | z) = \mathbb{P}(x | z)\mathbb{P}(y | z)$

On va noter

$X \perp\!\!\!\perp Y | Z$

$$(1) \quad \forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x,y | z) = \mathbb{P}(x | z)\mathbb{P}(y | z)$$

$$(2) \quad \forall (x,y,z) \in \text{Dom}(X) \times \text{Dom}(Y) \times \text{Dom}(Z) : \mathbb{P}(x | y,z) = \mathbb{P}(x | z)$$

$$(1) \Rightarrow (2)$$

$$\begin{aligned} \mathbb{P}(x | y,z) &= \frac{\mathbb{P}(x,y,z)}{\mathbb{P}(y,z)} \\ &= \frac{\mathbb{P}(z) \cdot \mathbb{P}(x,y | z)}{\mathbb{P}(y,z)} \\ &= \frac{\mathbb{P}(z)\mathbb{P}(x | z)\mathbb{P}(y | z)}{\mathbb{P}(z)\mathbb{P}(y | z)} \\ &= \mathbb{P}(x | z) \end{aligned}$$

Rappel indépendance conditionnelle

- Traffic
- Parapluie
- Pluie

Rappel indépendance conditionnelle

- Traffic
- Parapluie
- Pluie

Traffic \perp *Parapluie* | *Pluie*

Rappel indépendance conditionnelle

- Traffic
- Parapluie
- Pluie

Traffic \perp Parapluie | Pluie

- Incendie
- Fumée
- DetecteurFumée

Rappel indépendance conditionnelle

- Traffic
- Parapluie
- Pluie

Traffic \perp *Parapluie* | *Pluie*

- Incendie
- Fumée
- DetecteurFumée

Incendie \perp *DetecteurFumée* | *Fumée*

Rappel indépendance conditionnelle & Dérivation

Dérivation : $\mathbb{P}(X_1, X_2, \dots, X_n) = \mathbb{P}(X_1)\mathbb{P}(X_2 | X_1)\mathbb{P}(X_3 | X_1, X_2) \dots$

$\mathbb{P}(\text{Traffic}, \text{Pluie}, \text{Parapluie}) = \mathbb{P}(\text{Pluie}) \cdot \mathbb{P}(\text{Traffic} | \text{Pluie}) \cdot \mathbb{P}(\text{Parapluie} | \text{Traffic}, \text{Pluie})$

Supposons que $\text{Traffic} \perp \text{Parapluie} | \text{Pluie}$.

$\mathbb{P}(\text{Traffic}, \text{Pluie}, \text{Parapluie}) = \mathbb{P}(\text{Pluie}) \cdot \mathbb{P}(\text{Traffic} | \text{Pluie}) \cdot \mathbb{P}(\text{Parapluie} | \text{Pluie})$

⇒ moins de nombres à fournir !

plus on conditionne sur des variables ⇒ plus on a à fournir des nombres


Il faut bien choisir l'ordre avec laquelle on utilise la dérivation.

Souvent, utiliser un processus causal est une bonne solution !

nouvelle manière de représenter une distribution jointe

- plus compacte : moins de nombres
 - la distribution jointe est trop grande
 - difficile à estimer
- représente directement certaines hypothèses sans avoir à lire les nombres
- on va représenter des interactions locales entre variables : plus facile à obtenir et raisonner.


Exemples de réseau bayésien : domaine de l'assurance



27 variables binaires \approx 134 millions

a-t-on même assez de données pour estimer chacune ?

Exemples de réseau bayésien : diagnostique



en bas, on a souvent les données que l'on peut observer.

16 variable $\Rightarrow 2^{16} \approx 65000$ valeurs.

La plus grande table qu'on va avoir $2^5 = 120$ valeurs.

- Les noeuds du graphe sont les variables
 - on peut connaître ou non la valeur
- On a un graphe orienté acyclique
- un arc indique une influence "directe" entre variables.
- ⇒ encode une indépendance conditionnelle.

exemple :

- n dés équilibrés
- pluie, trafic. On peut considérer plusieurs hypothèses :

- Les noeuds du graphe sont les variables
 - on peut connaître ou non la valeur
- On a un graphe orienté acyclique
- un arc indique une influence "directe" entre variables.
- ⇒ encode une indépendance conditionnelle.

exemple :


- n dés équilibrés
- pluie, trafic. On peut considérer plusieurs hypothèses :
 - indépendance
 - la pluie cause le trafic

Réseaux Bayésiens ou modèles graphiques

- trafic (T)
- pluie (P)
- basses pressions (B)
- match de foot (M)
- mal de dents (D)
- toit qui fuit (F)

Réseaux Bayésiens ou modèles graphiques

- traffic (T)
- pluie (P)
- basses pressions (B)
- match de foot (M)
- mal de dents (D)
- toit qui fuit (F)




Réseaux Bayésiens : exemple classique!


- Cambriolage
- L'alarme sonne
- il y a un tremblement de terre
- le voisin (Jacques) appelle pour prévenir que quelque chose se passe
- la voisine (Marie) appelle pour prévenir que quelque chose se passe

Réseaux Bayésiens : exemple classique!

- Cambriolage
- L'alarme sonne
- il y a un tremblement de terre
- le voisin (Jacques) appelle pour prévenir que quelque chose se passe
- la voisine (Marie) appelle pour prévenir que quelque chose se passe



- Les noeuds du graphe sont les variables
- On a un graphe orienté acyclique
- Une table de probabilités conditionnelles (TPC) pour le noeud de la variable X dont les parents sont les noeuds A_1, \dots, A_k , on a une table qui représente $\mathbb{P}(X | a_1, \dots, a_k)$




A_1	A_2	...	A_k	$\mathbb{P}(A)$
T	T	...	T	0.95
T	⊥	...	T	0.94
		...		
⊥	⊥	...	⊥	0.001

réseau bayésien = graphe + TPC

Un réseau bayésien encode la distribution jointe complète en tant que produit de distributions conditionnelles locales.

$$\mathbb{P}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \mathbb{P}(x_i \mid \text{parents}(X_i))$$

exemple :



$$\mathbb{P}(\text{carie}, \text{testSonde}, \neg \text{malDents}) = \mathbb{P}(\text{carie}) \cdot \mathbb{P}(\text{testSonde} \mid \text{carie}) \cdot \mathbb{P}(\neg \text{malDents} \mid \text{carie})$$

A-t-on la garantie que le produit est bien une probabilité jointe correcte ?

$$\mathbb{P}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \mathbb{P}(x_i \mid \text{parents}(X_i))$$

règle de dérivation :

$$\mathbb{P}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \mathbb{P}(x_i \mid x_1 \dots x_{i-1})$$


hypothèse : probabilités conditionnelles

$$\mathbb{P}(x_1, x_2, \dots, x_{i-1}) = \mathbb{P}(x_i \mid \text{parents}(X_i))$$

(on suppose qu'on a ordonné les noeuds de telle sorte que $\text{parents}(X_i) \subseteq \{x_1, \dots, x_{i-1}\}$)


$$\Rightarrow \mathbb{P}(x_1, x_2, \dots, x_n) = \prod_{i=1}^n \mathbb{P}(x_i \mid \text{parents}(X_i))$$

exemple avec trois variables X_1 , X_2 et X_3



encode seulement


$$X_2 \cdot X_3 \mid X_1$$




encode toutes distributions!

La topologie du réseau impose des probabilités conditionnelles : étant donné un réseau bayésien, on peut représenter certaines distributions jointes, mais pas toutes!

Réseaux Bayésiens & probabilités





Réseaux Bayésiens & causalité



on en déduit

Pluie	Traffic	$\mathbb{P}(Pluie, Traffic)$
T	T	3/16
T	⊥	1/16

Réseaux Bayésiens & causalité



on en déduit

Pluie	Traffic	$\mathbb{P}(Pluie, Traffic)$
⌈	⌈	3/16
⌈	⊥	1/16

on en déduit

Pluie	Traffic	$\mathbb{P}(Pluie, Traffic)$
⌈	⌈	3/16
⌈	⊥	1/16

- quand le réseau reflète la vraie structure causale
 - souvent plus petit (les noeuds ont moins de parents)
 - souvent plus facile pour le raisonnement (plus naturel)
 - plus facile pour demander aux experts (ont plus d'intuition dans ce sens)
- mais pas besoin de respecter la structure causale!
 - s'il manque des variables, la structure causale n'est pas claire. ex on veut faire un RB avec toit qui fuit et trafic, mais sans la pluie.
- la topologie encode l'indépendance conditionnelle.

- n variables booléennes : 2^n
- Supposons qu'on est un réseau bayésien avec n variables, et chaque noeud possède au plus k parents.
Il faut une table de $O(n \cdot 2^k \cdot 2)$.

On passe linéaire en n !

Si on arrive à maintenir k relativement petit!

- moins de nombres à utiliser pour les calculs!
- les nombres sont aussi plus facile à trouver!