

# IFT 615 – Intelligence artificielle

## Réseaux bayésiens

Hugo Larochelle

Département d'informatique

Université de Sherbrooke

[http ://www.dmi.usherb.ca/~larocheh/cours/ift615.html](http://www.dmi.usherb.ca/~larocheh/cours/ift615.html)

# Sujets couverts

- C'est quoi un réseau bayésien (RB)?
  - ◆ structure d'un RB
  - ◆ calcul de probabilités dans un RB
- Indépendance conditionnelle dans un RB
- Inférence dans un réseau bayésien
  - ◆ inférence exacte
  - ◆ inférence approximative
- Sujet plus poussés
  - ◆ apprentissage automatique de réseaux bayésiens

# Réseaux bayésiens


- On a vu les bases du raisonnement probabiliste et de la théorie des probabilité
  - ◆ à partir d'une table des probabilités conjointes, comment calculer toute autre probabilité
- On a utilisé un exemple simple (*MalDeDent*, *Croche*, *Carie*)
  - ◆ on aurait pu considérer le cas de la détection de « pourriels »
    - » *AuteurInconnu* : l'auteur du courriel est inconnu
    - » *ContientMotListeNoire* : le courriel contient un mot d'une « liste noire »
    - » *Pourriel* : le courriel est un pourriel
  - ◆ souvent, on aura besoin de centaines de variables aléatoires
    - » la table des probabilités ne pourra pas être stockée en mémoire
- Dans ce cours, on va voir une façon plus efficace de construire un modèle de raisonnement probabiliste

# Réseaux bayésiens

- Les **réseaux bayésiens** (RB) sont un mariage entre la théorie des graphes et la théorie des probabilités
- Un RB permet de représenter les connaissances probabilistes d'une application donnée :
  - ◆ par exemple, les connaissances cliniques d'un médecin sur des liens de causalité entre maladies et symptômes
- Les RB sont utiles pour modéliser des connaissances d'un système expert ou d'un système de support à la décision, dans une situation pour laquelle :
  - ◆ la causalité joue un rôle important (des événements en causent d'autres)
  - ◆ mais notre **compréhension de la causalité des événements est incomplète** (on doit recourir aux probabilités)


# Application : diagnostique médical

- Déterminer la maladie d'un patient, sachant des symptômes
- On peut avoir une maladie mais montrer seulement un sous-ensemble des symptômes possibles



# Application : diagnostique médical

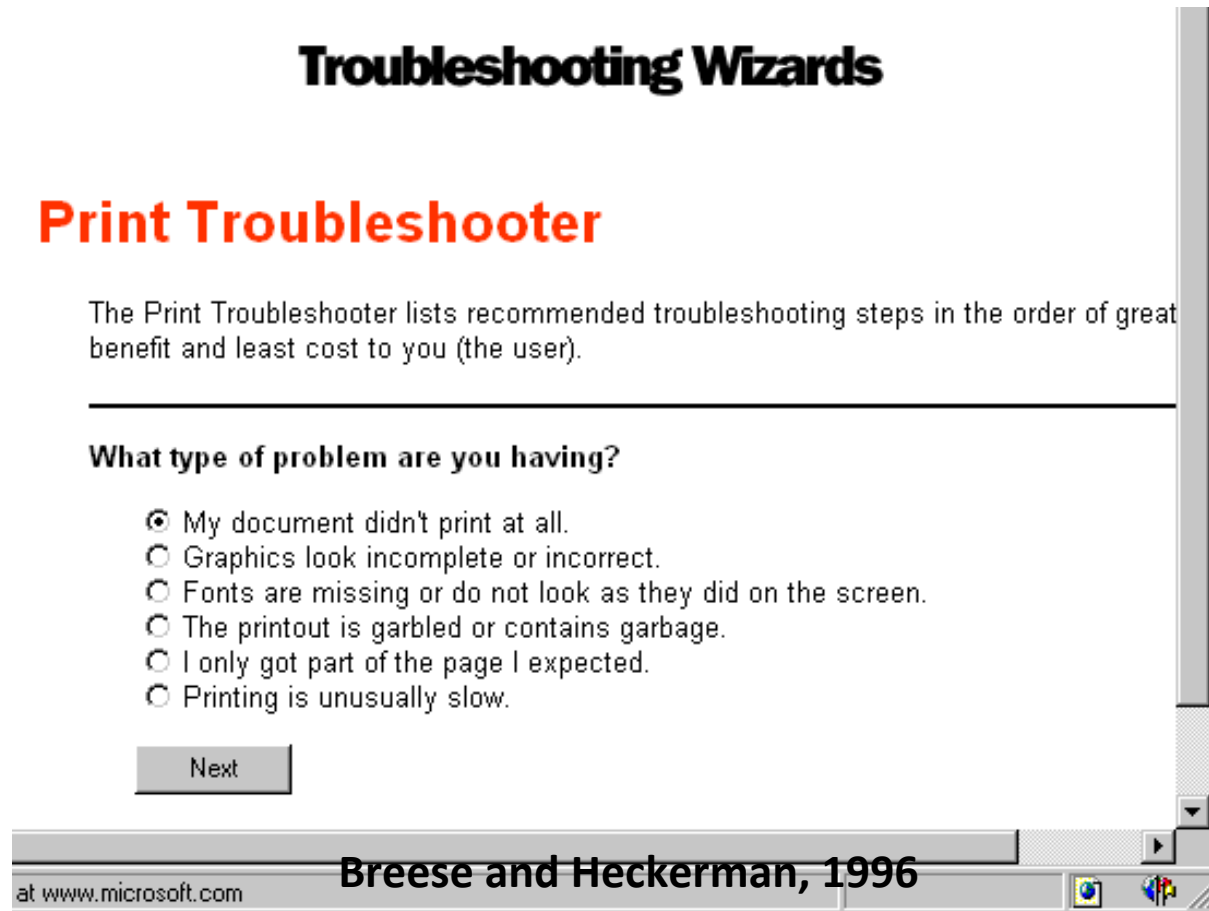
- *Pathfinder* (version 4)
  - ◆ en accord avec un panel d'experts 50 fois sur 53
  - ◆ prédictions aussi bonnes que celles des experts qui ont développé le système



M. Pradhan, G. Provan, B. Middleton, M. Henrion, UAI 1994

# Application : diagnostique informatique

- *Troubleshooting Wizard* : détection et analyse de problèmes informatiques



# Application : diagnostique informatique

- *JamBayes* : système de prédiction du trafic routier à Seattle



Horvitz, Apacible, Sarin and Liao 2005




# Autres applications

- NASA
  - ◆ support au diagnostique en temps réel des pannes du système de propulsion des navettes spatiales
- AT&T
  - ◆ détections des fraudes et des mauvais payeurs pour les factures de téléphone
- Classification de documents (à venir)
  - ◆ détection de pourriels
- Localisation d'un robot dans une carte (à venir)

# Syntaxe

- Un RB est un **graphe**
  - ◆ **orienté**
  - ◆ **acyclique**
  - ◆ dont les **nœuds** sont des **variables aléatoires** et
  - ◆ les **arcs** représentent
    - » des **dépendances** (par exemple des causalités) probabilistes entre les variables et
    - » des **distributions de probabilités conditionnelles** (locales) pour chaque variable étant donnés ses parents




# Exemple

- Considérons la situation suivante :
  - ◆ je suis au travail, et mes voisins Marie et Jean m'ont promis de m'appeler chaque fois que mon alarme sonne
  - ◆ mon voisin Jean m'appelle pour me dire que mon alarme sonne
    - » parfois il confond l'alarme avec la sonnerie du téléphone
  - ◆ par contre ma voisine Marie ne m'appelle pas toujours
    - » parfois elle met la musique trop fort
  - ◆ parfois mon alarme se met à sonner lorsqu'il y a de légers séismes
  - ◆ comment conclure qu'il y a un cambriolage chez moi?
- On peut représenter ce problème par un RB

# Exemple

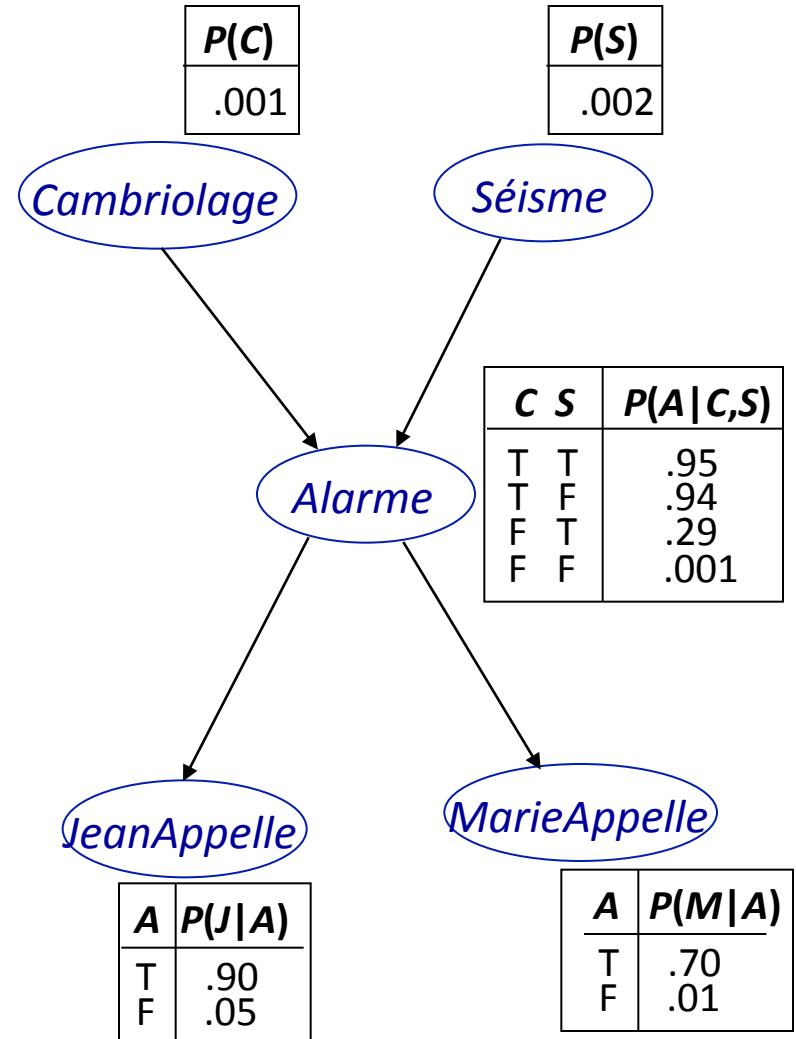
- Variables aléatoires :

- ◆ *Cambriolage*
- ◆ *Séisme*
- ◆ *Alarme*
- ◆ *JeanAppelle*
- ◆ *MarieAppelle*



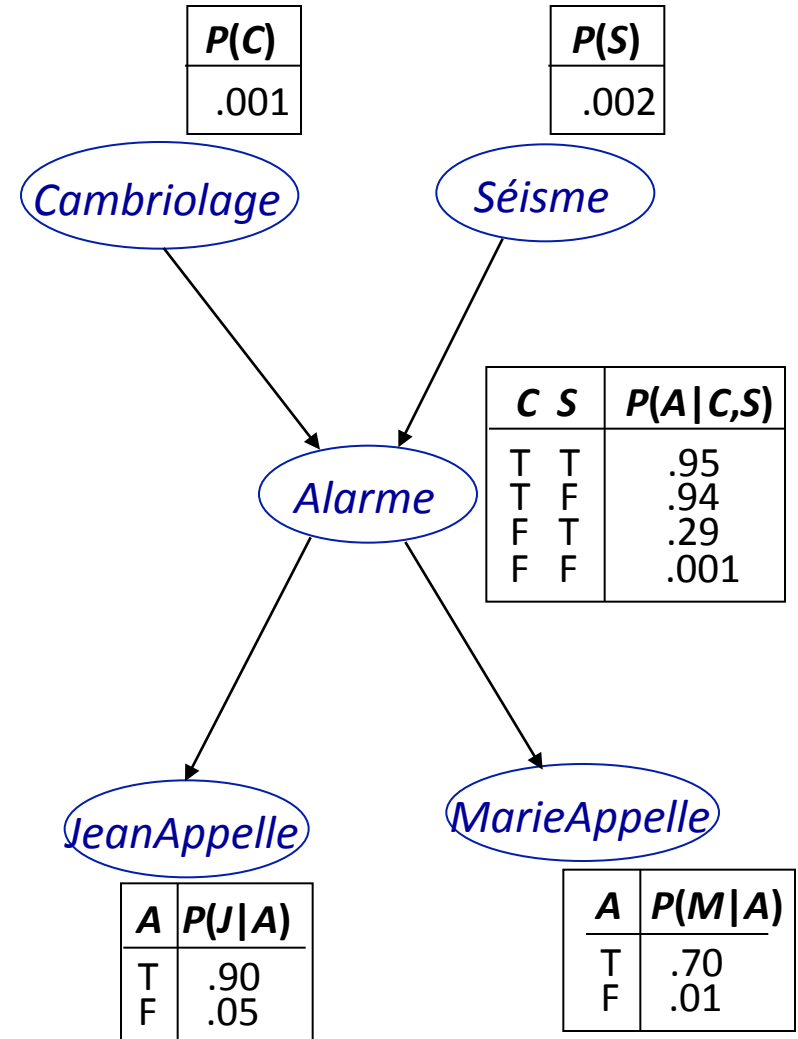
# Exemple

- La topologie du RB modélise les relations de causalité
- Un arc d'un nœud  $X$  vers un nœud  $Y$  signifie que la variable  $X$  **influence** la variable  $Y$ 
  - ◆ un cambriolage peut déclencher l'alarme
  - ◆ un séisme aussi
  - ◆ l'alarme peut inciter Jean à appeler
  - ◆ idem pour Marie
- Une **table de probabilités conditionnelles** (TPC) donne la probabilité pour chaque valeur du nœud étant donnés les combinaisons des valeurs des parents du nœud (c'est l'équivalent d'une **distribution**)



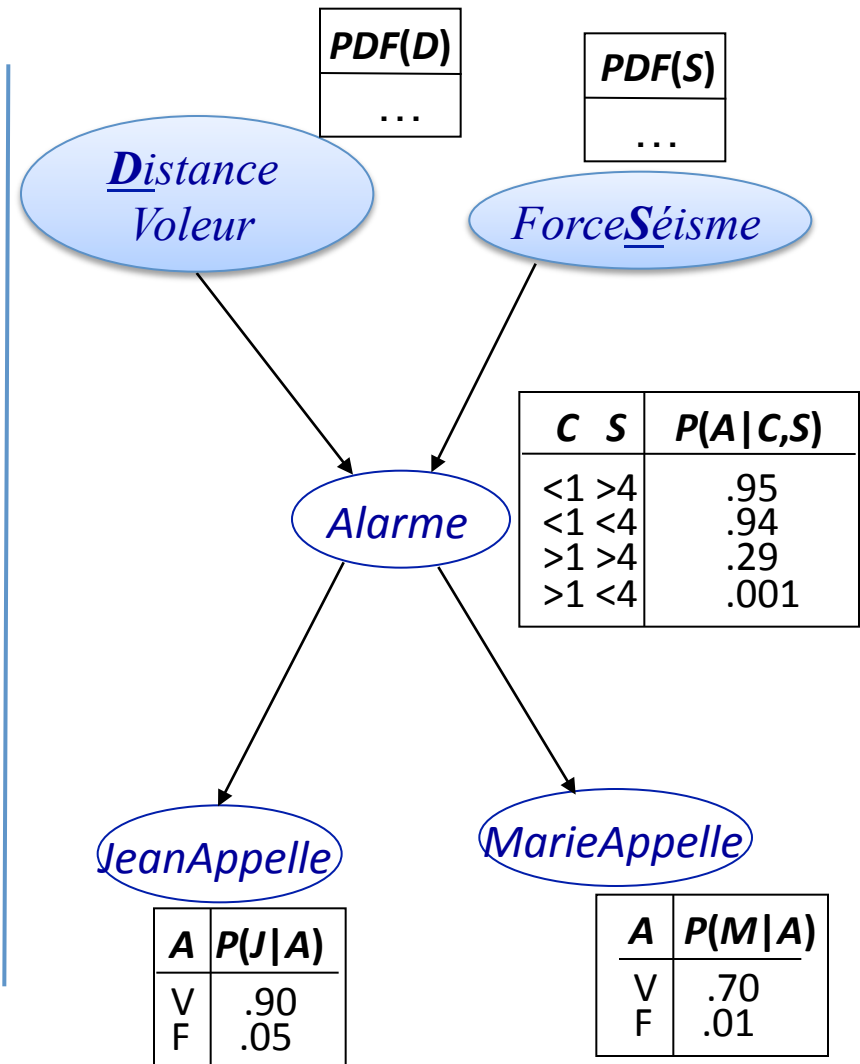
# Définitions

- S'il y a un arc d'un nœud  $Y$  vers un nœud  $X$ , cela signifie que la variable  $Y$  influence la variable  $X$ 
  - ◆  $Y$  est appelé le **parent** de  $X$
  - ◆  $Parents(X)$  est l'ensemble des parents de  $X$
- Si  $X$  n'a pas de parents, sa distribution de probabilités est dite **inconditionnelle** ou **a priori**
- Si  $X$  a des parents, sa distribution de probabilités est dite **conditionnelle**




# RB avec des variables continues

- Dans ce cours, on considère uniquement des RB avec des variables discrètes :
  - ◆ les TPC sont spécifiées en énumérant toutes les entrées
- Mais les RB peuvent aussi supporter les variables continues :
  - ◆ les probabilités conditionnelles sont spécifiées par des **fonctions de densité de probabilités** (PDF)
  - ◆ exemples :
    - » distance entre voleur et le capteur de mouvement
    - » force du séisme sur l'échelle de Richter



# Autres appellations

- Il y a d'autres appellations pour les RB :
  - ◆ réseaux de croyance (*belief networks*)
  - ◆ modèle graphique dirigé acyclique
- Les RB font partie de la classe plus générale des **modèles graphiques**





# Sémantique

- Un RB est une façon compacte de représenter des probabilités conjointes
- Par définition, la probabilité conjointe de  $X_1$  et  $X_2$  est donnée par la distribution  $P(X_1, X_2)$ , pour une valeur donnée de  $X_1$  et  $X_2$
- La distribution conditionnelle de  $X_1$  sachant  $X_2$  est notée  $P(X_1 | X_2)$ 
  - ◆  $P(X_1, X_2) = P(X_1 | X_2) P(X_2)$
- Soit  $X = \{X_1, \dots, X_n\}$ , l'ensemble des variables d'un RB :

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{Parents}(X_i))$$

- En d'autres mots, la distribution conjointe des variables d'un RB est définie comme étant le produit des distributions conditionnelles (locales)

# Calcul de probabilité conjointe

- En fait, quelque soit l'ensemble de variables  $X = \{X_1, \dots, X_n\}$ , par définition :

$$\begin{aligned} P(X_1, \dots, X_n) &= P(X_n \mid X_{n-1}, \dots, X_1) P(X_{n-1}, \dots, X_1) \\ &= P(X_n \mid X_{n-1}, \dots, X_1) P(X_{n-1} \mid X_{n-2}, \dots, X_1) \dots P(X_2 \mid X_1) P(X_1) \\ &= \prod_{i=1}^n P(X_i \mid X_{i-1}, \dots, X_1) \end{aligned}$$


- Pour un RB :  $P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i \mid \text{Parents}(X_i))$ 
  - ◆ ceci est cohérent avec l'assertion précédente pour autant que  $\text{Parents}(X_i)$  soit l'ensemble de  $\{X_{i-1}, \dots, X_1\}$
  - ◆ sinon, un RB est alors une façon de **représenter les indépendances conditionnelles**

# Exemple : probabilité conjointe

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i \mid \text{Parents}(X_i))$$


$$\begin{aligned} P(j, m, a, \neg c, \neg s) \\ &= P(j \mid a) P(m \mid a) P(a \mid \neg c, \neg s) \\ &\quad P(\neg c) P(\neg s) \\ &= .90 * .70 * .001 * \\ &\quad .999 * .998 \\ &\approx .00062 \end{aligned}$$

$P(J=j, M=m, A=a, C=\neg c, S=\neg s)$   
est aussi noté  $P(j, m, a, \neg c, \neg s)$



# Exemple : probabilité marginale

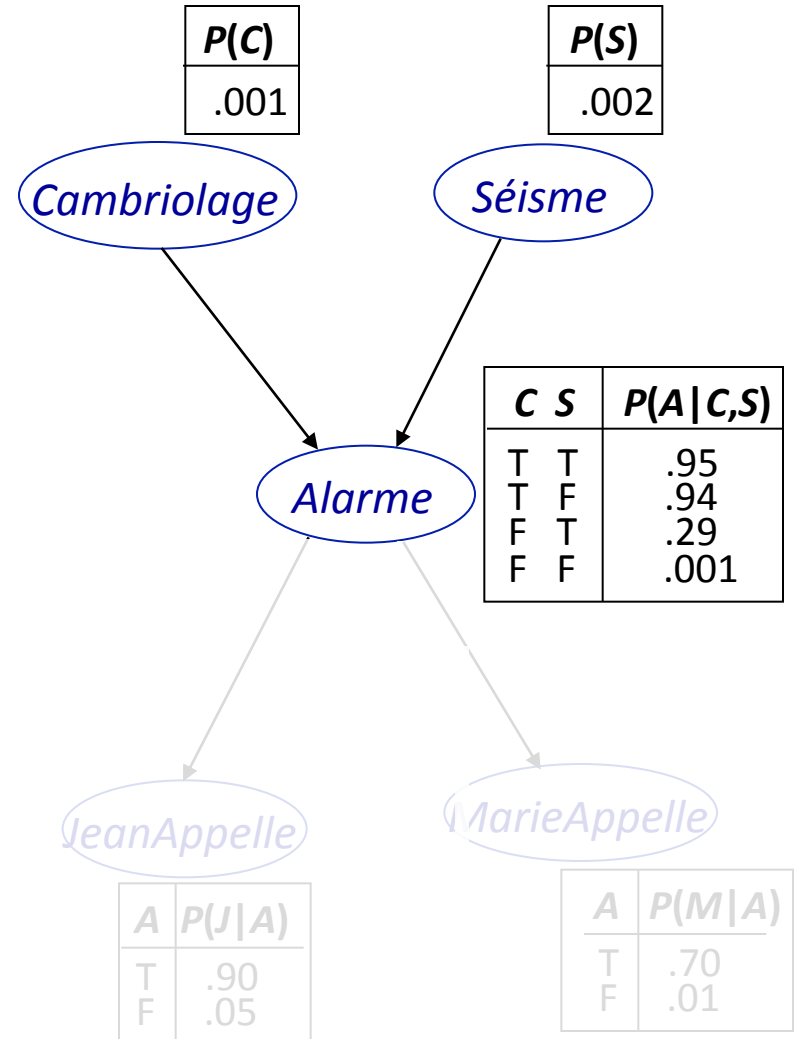
$$\begin{aligned}
 P(\neg c, a) &= \sum_m \sum_j \sum_s P(J=j, M=m, a, \neg c, S=s) \\
 &= \sum_m \sum_j \sum_s P(j|a) P(m|a) P(a | \neg c, s) P(\neg c) P(s) \\
 &= \sum_s \sum_j \sum_m P(j|a) P(m|a) P(a | \neg c, s) P(\neg c) P(s) \\
 &= \sum_s \sum_j P(j|a) P(a | \neg c, s) P(\neg c) P(s) \underbrace{\sum_m P(m|a)}_{=1} \\
 &= \sum_s P(a | \neg c, s) P(\neg c) P(s) \underbrace{\sum_j P(j|a)}_{=1} \\
 &= P(a | \neg c, s) P(\neg c) P(s) + P(a | \neg c, \neg s) P(\neg c) P(\neg s) \\
 &= .29 * .999 * .002 + .001 * .999 * .998 \\
 &\approx 0.0016
 \end{aligned}$$



# Probabilité marginale


$$P(c, \neg a) = \sum_m \sum_j \sum_s P(J=j, M=m, a, \neg c, S=s) \\ = \sum_s P(a | \neg c, S=s) P(\neg c) P(S=s)$$

- Pour les probabilités marginales, on peut ignorer les noeuds **dont les descendants ne sont pas les noeuds observés**
  - ◆ *Cambriolage* et *Alarme* ne sont pas des ancêtres de *JeanAppelle* ou *MarieAppelle*, alors on peut les ignorer
  - ◆ *Alarme* est un descendant de *Séisme*, alors on doit le marginaliser explicitement



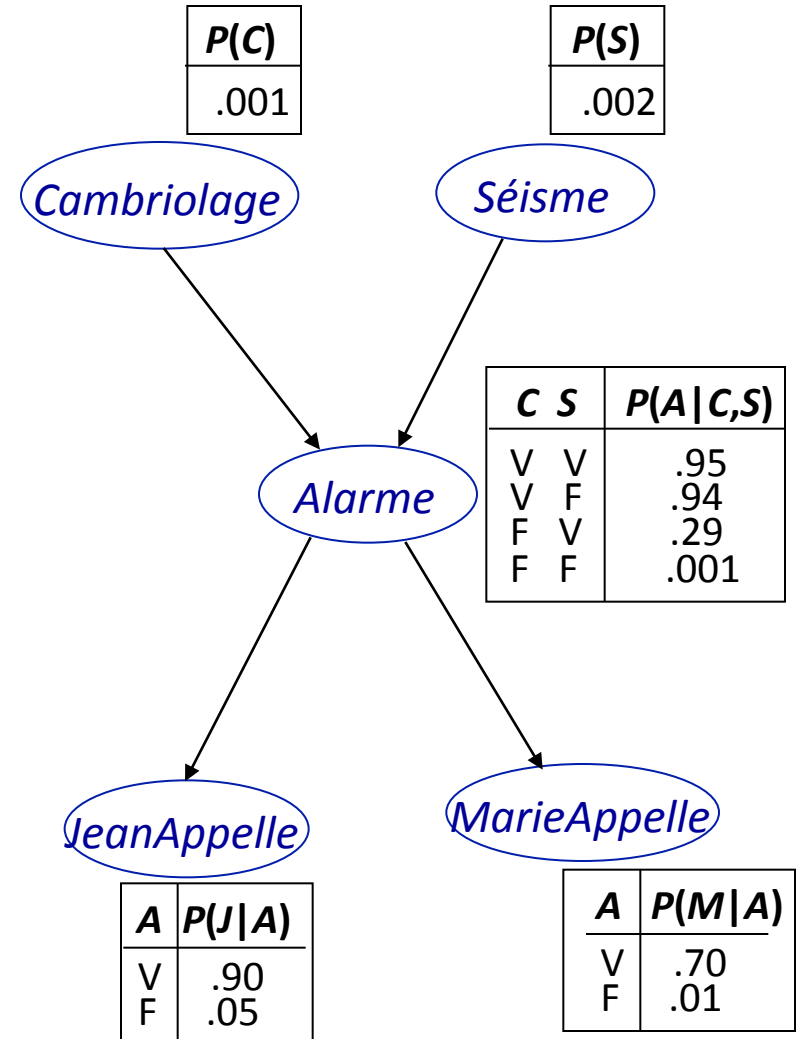
# Indépendance conditionnelle dans un RB

- Un RB modélise les relations d'indépendance conditionnelle suivantes
  - ◆ un nœud est indépendant de ses non-descendants, étant donné ses parents
  - ◆ exemples :
    - » *Cambriolage* et *MarieAppelle* sont **dépendants** a priori
    - » mais ils sont **indépendants** étant donné *Alarme* :
 
$$P(M|A,C) = P(M|A)$$
    - » si *A* est connu, *C* n'intervient pas dans le calcul
    - » **connaître** *A* « bloque » le chemin entre *M* et *C*



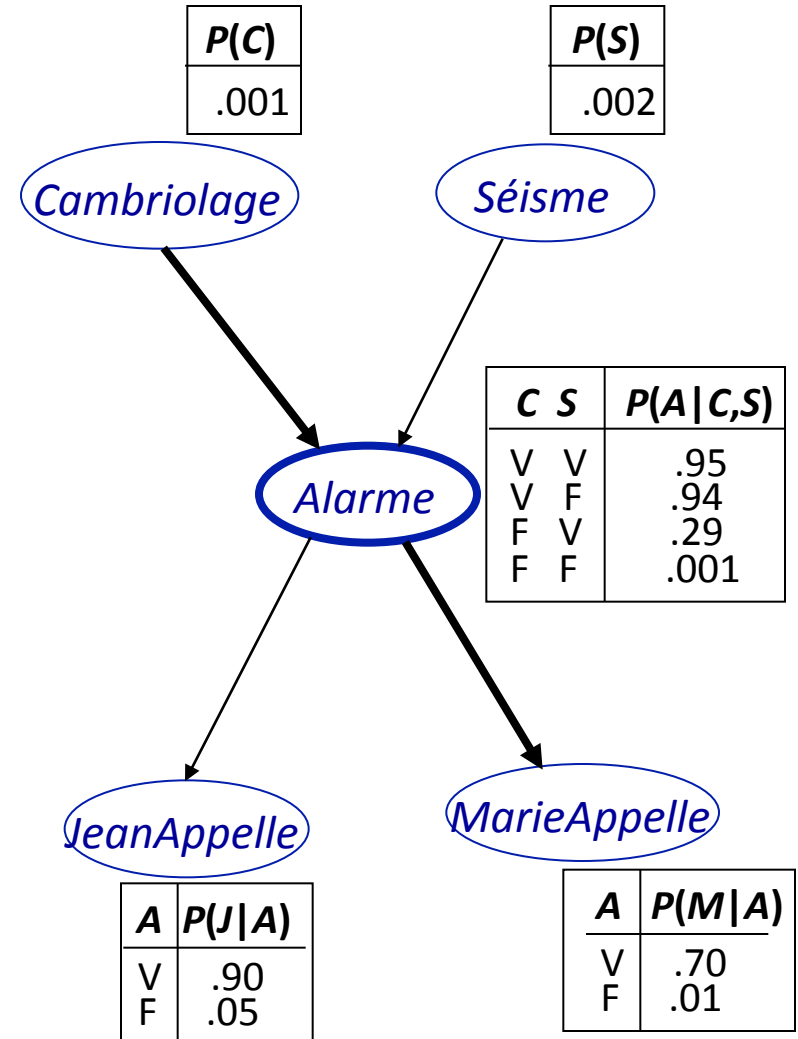
# Indépendance conditionnelle dans un RB

$$\begin{aligned}
 P(M|A,C) &= P(M,A,C) / P(A,C) \\
 &= \frac{\sum_s P(M,A,C,S=s)}{\sum_s P(A,C,S=s)} \\
 &= \frac{\sum_s P(M|A) P(A|C,S=s) P(S=s) P(C)}{\sum_s P(A|C,S=s) P(S=s) P(C)} \\
 &= \frac{P(M|A) \cancel{\sum_s P(A|C,S=s) P(S=s) P(C)}}{\cancel{\sum_s P(A|C,S=s) P(S=s) P(C)}} \\
 &= P(M|A)
 \end{aligned}$$



# Indépendance conditionnelle dans un RB


$$\begin{aligned}
 P(M|A,C) &= P(M,A,C) / P(A,C) \\
 &= \frac{\sum_s P(M,A,C,S=s)}{\sum_s P(A,C,S=s)} \\
 &= \frac{\sum_s P(M|A) P(A|C,S=s) P(S=s) P(C)}{\sum_s P(A|C,S=s) P(S=s) P(C)} \\
 &= \frac{P(M|A) \cancel{\sum_s P(A|C,S=s) P(S=s) P(C)}}{\cancel{\sum_s P(A|C,S=s) P(S=s) P(C)}} \\
 &= P(M|A)
 \end{aligned}$$






# Indépendance conditionnelle dans un RB

- Un RB modélise les relations d'indépendance conditionnelle suivantes
  - un nœud est indépendant de ses non-descendants, étant donné ses parents
  - exemples :
    - » *JeanAppelle* et *MarieAppelle* sont **dépendants** a priori
    - » mais ils sont **indépendants** étant donné *Alarme* :
 
$$P(M|A,J) = P(M|A)$$
    - » si *A* est connu, *J* n'intervient pas dans le calcul
    - » **connaître** *A* « bloque » le chemin entre *J* et *M*



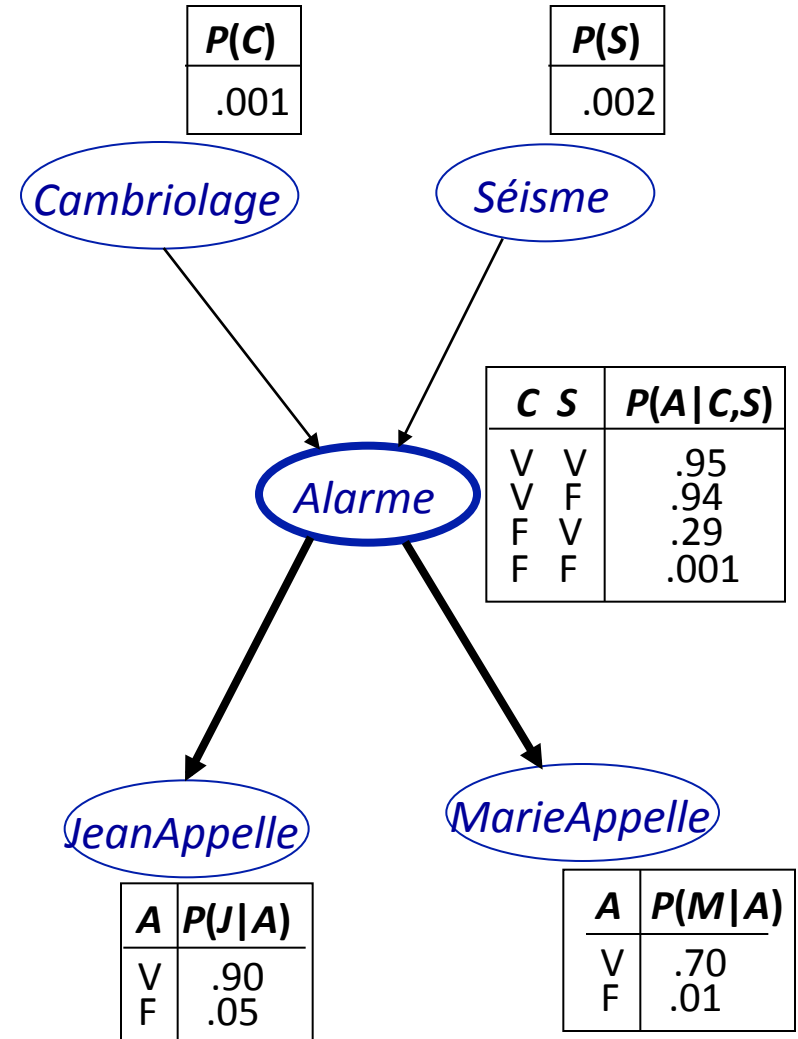
# Indépendance conditionnelle dans un RB

$$\begin{aligned}
 P(M|A,J) &= P(M,A,J) / P(A,J) \\
 &= \frac{\sum_s \sum_c P(M,A,J,S=s,C=c)}{\sum_s \sum_c P(A,J,S=s,C=c)} \\
 &= \frac{\sum_s \sum_c P(J|A) P(M|A) P(A,S=s,C=c)}{\sum_s \sum_c P(J|A) P(A,S=s,C=c)} \\
 &= \frac{P(M|A) \cancel{\sum_s \sum_c P(J|A) P(A,S=s,C=c)}}{\cancel{\sum_s \sum_c P(J|A) P(A,S=s,C=c)}} \\
 &= P(M|A)
 \end{aligned}$$




# Indépendance conditionnelle dans un RB

$$\begin{aligned}
 P(M|A,J) &= P(M,A,J) / P(A,J) \\
 &= \frac{\sum_s \sum_c P(M,A,J,S=s,C=c)}{\sum_s \sum_c P(A,J,S=s,C=c)} \\
 &= \frac{\sum_s \sum_c P(J|A) P(M|A) P(A,S=s,C=c)}{\sum_s \sum_c P(J|A) P(A,S=s,C=c)} \\
 &= \frac{P(M|A) \sum_s \sum_c P(J|A) P(A,S=s,C=c)}{\sum_s \sum_c P(J|A) P(A,S=s,C=c)} \\
 &= P(M|A)
 \end{aligned}$$



# Indépendance conditionnelle dans un RB

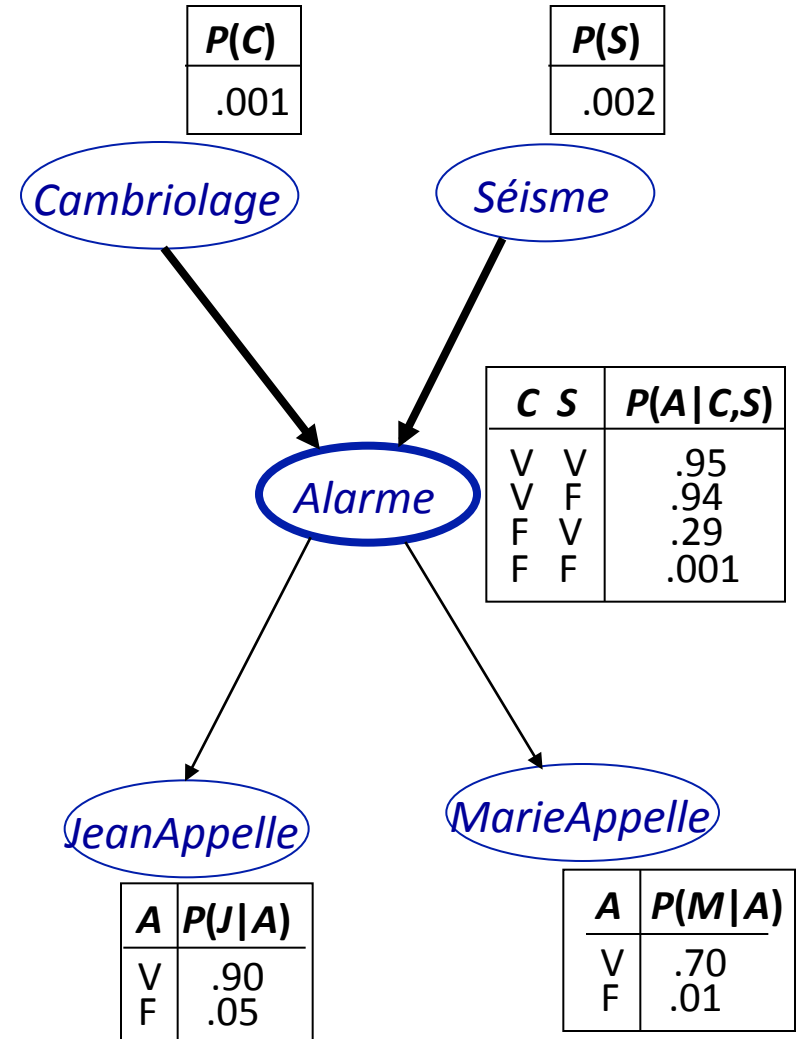
- Un RB modélise les relations d'indépendance conditionnelle suivantes
  - ◆ un nœud est indépendant de ses non-descendants, étant donné ses parents
  - ◆ exemples :
    - » *Cambriolage* et *Séisme* sont **indépendants** a priori
    - » mais ils sont **dépendants** étant donné *Alarme*
      - $P(C|A,S)$  n'est pas simplifiable, parce que  $P(A|C,S)$  n'est pas simplifiable
    - » **ne pas connaître** A « bloque » le chemine entre C et S



# Indépendance conditionnelle dans un RB

$$P(C|A,S) = P(C,A,S) / P(A,S)$$

$$= \frac{P(A|S,C) P(S) P(C)}{\sum_c P(A|S) P(S) P(C)}$$




# Indépendance conditionnelle dans un RB : D-séparation

- **D-séparation** : critère général pour décider si un nœud  $X$  est indépendant d'un nœud  $Y$ , étant donnés d'autres nœuds  $Z = \{Z_1, \dots, Z_m\}$
- $X$  est indépendant de  $Y$  sachant  $Z$  si tous **les chemins non-dirigés** entre  $X$  et  $Y$  sont **bloqués** par  $Z$
- Un **chemin est bloqué** s'il contient au moins un nœud  $N$  qui satisfait une ou l'autre des conditions suivantes :
  1. il inclue un nœud  $\rightarrow (N) \rightarrow$  ou  $\leftarrow (N) \rightarrow$ , où  $N \in \{Z_1, \dots, Z_m\}$
  2. il inclue un nœud  $\rightarrow (N) \leftarrow$  et  $N \notin \{Z_1, \dots, Z_m\}$ , ni **aucun des descendants** de  $N$


# Exemple

- Est-ce que *Age* et *Gender* sont indépendants ?



# Exemple


- Est-ce que *Age* et *Gender* sont indépendants ?
- ◆ chemin 1 est bloqué au niveau de *Smoking* →  $N$  ←
  - » *Smoking* et ses descendants *Cancer*, *Serum-Calcium* et *Lung-Tumor* ne sont pas observés






# Exemple

- Est-ce que *Age* et *Gender* sont indépendants ?
  - ◆ chemin 1 est bloqué au niveau de *Smoking* → (N) ←
    - » *Smoking* et ses descendants *Cancer*, *Serum-Calcium* et *Lung-Tumor* ne sont pas observés
  - ◆ chemin 2 est aussi bloqué au niveau de *Smoking* → (N) ←
    - » même raisons
- Réponse : **oui**




# Exemple

- Est-ce que *Age* et *Lung-Tumor* sont indépendants sachant *Smoking* ?



# Exemple

- Est-ce que *Age* et *Lung-Tumor* sont indépendants sachant *Smoking* ?
  - ◆ chemin 1 est bloqué au niveau de *Smoking* →  $N$  →
    - » *Smoking* est observé




# Exemple

- Est-ce que *Age* et *Lung-Tumor* sont indépendants sachant *Smoking* ?

- ◆ chemin 1 est bloqué au niveau de *Smoking* → (N) →  
» *Smoking* est observé


- ◆ chemin 2 n'est pas bloqué  
» *Exposure-to-Toxics* → (N) → n'est pas observé  
» *Cancer* → (N) → n'est pas observé

- Réponse : **non**



# Exemple

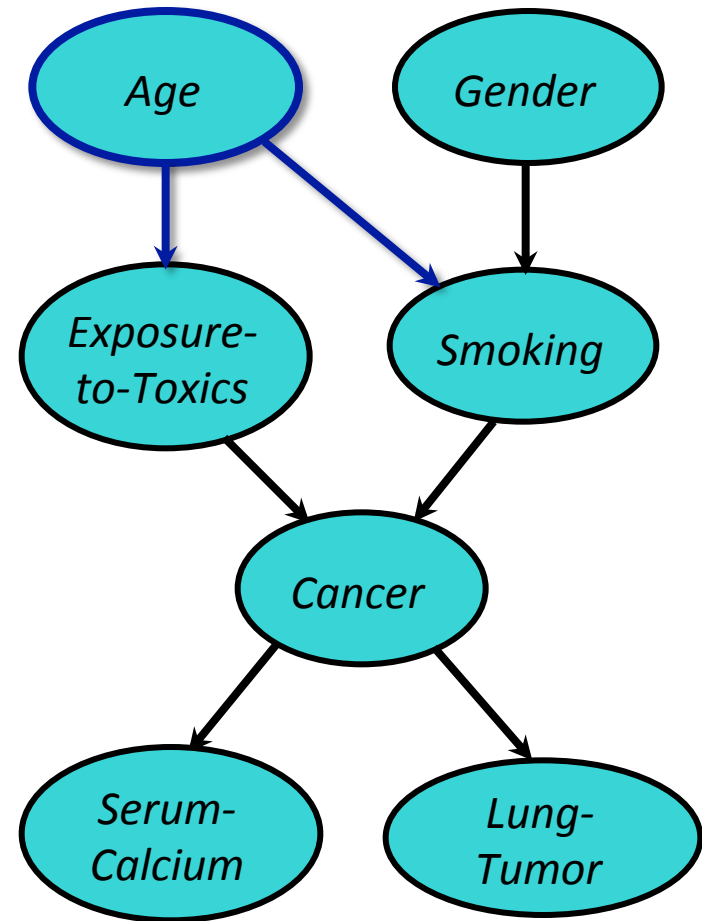
- Est-ce que *Exposure-to-Toxics* et *Smoking* sont indépendants sachant *Age* et *Lung-Tumor*?



# Exemple


- Est-ce que *Exposure-to-Toxics* et *Smoking* sont indépendants sachant *Age* et *Lung-Tumor*?

- ◆ chemin 1 est bloqué au niveau de *Age*  $\longleftrightarrow (N) \longrightarrow$   
» *Age* est observé



# Exemple

- Est-ce que *Exposure-to-Toxics* et *Smoking* sont indépendants sachant *Age* et *Lung-Tumor*?
  - ◆ chemin 1 est bloqué au niveau de *Age*  $\leftarrow (N) \rightarrow$ 
    - » *Age* est observé
  - ◆ chemin 2 n'est pas bloqué
    - » *Cancer*  $\rightarrow (N) \leftarrow$   
ne bloque pas le chemin puisque *Lung-Tumor*, un de ses descendants, est observé
- Réponse : **non**



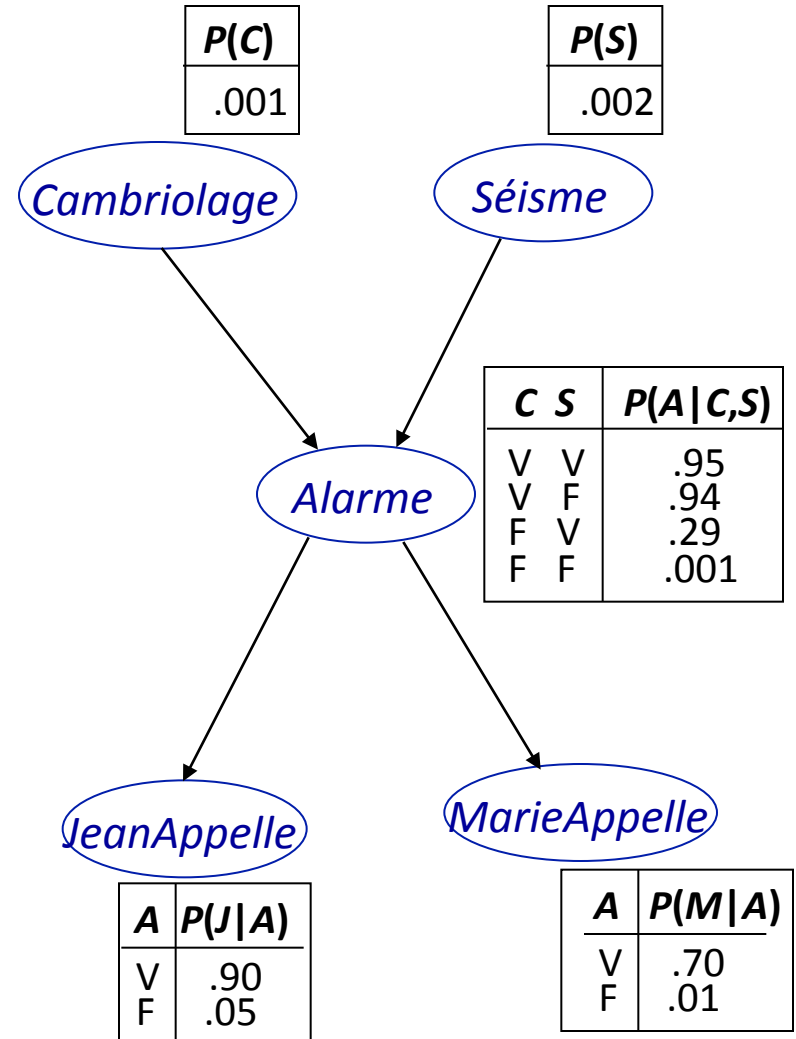
# Requête dans un RB

- L'usage principal d'un RB est de calculer les probabilités a posteriori, étant donné un événement observé
  - ◆ un événement est une assignation de valeurs à certaines variables d'observation
    - ◆ ex. : sachant le résultat d'une batterie de test, quelle est maintenant la probabilité qu'un patient ait une maladie  $X$  ?
- On va noter
  - ◆  $X$  l'ensemble de variables pour lesquelles on fait une requête
    - » ex. : la patient a la maladie  $X$
  - ◆  $E$  l'ensemble des variables d'observation et  $e$  les valeurs observées
    - » ex. :  $E_i = e_i$  est le résultat d'un test
  - ◆  $Y$  l'ensemble des variables cachées (qui ne sont pas observées)
    - » ex. :  $Y_i$  est le résultat de tests qui n'ont pas été faits
- Une **requête** est l'inférence de  $\mathbf{P}(X|e)$ , où  $e$  est une assignation de valeurs aux variables dans  $E$



# Requête dans un RB

- Exemple :  
 $P(\text{Cambriolage} \mid \text{JeanAppelle} = \text{vrai}, \text{MarieAppelle} = \text{vrai})$   
 $= [0.284, 0.716]$
- Comment fait-on un tel calcul?
  - ◆ **inférence exacte** (prohibitif)
    - » par énumération
  - ◆ **inférence approximative par échantillonnage** avec les méthodes Monte-Carlo (plus efficace)
    - » méthode de rejet



# Inférence par énumération

- On veut calculer la distribution sur les variables de requêtes **sachant** les observations

$$\mathbf{P}(X|e) = \mathbf{P}(X, E=e)/\alpha = \sum_y \mathbf{P}(X, e, y) / \alpha$$


- Les termes  $P(X, e, y)$  peuvent s'écrire comme le produit des probabilités conditionnelles du réseau
- On peut donc calculer la réponse à une requête  $P(X|e)$  dans un RB, simplement en
  1. calculant les sommes des produits des probabilités conditionnelles du RB
  2. normalisant ces sommes de façon à obtenir une distribution qui somme à 1
- Les ensembles des variables  $X$ ,  $E$  et  $Y$  couvrent ensemble tous les noeuds
  - ◆ complexité en temps :  $O(d^{|X|+|Y|})$ , avec  $d$  la taille du plus grand domaine
  - ◆ complexité en espace :  $O(d^{|X|})$ , pour stocker la distribution

# Exemple

- $P(\text{Cambriolage} \mid \text{JeanAppelle} = \text{vrai}, \text{MarieAppelle} = \text{vrai})$ 
  - ◆ noté  $P(C \mid j, m)$
- Les variables cachées sont *Séisme* et *Alarme*

$$P(C \mid j, m) = \sum_{s,a} P(C, s, a, j, m) / \alpha$$

$$= \sum_s \sum_a P(C, s, a, j, m) / \alpha$$
- Note :
  - ◆  $s$  et  $a$  prennent toutes les valeurs possibles pour  $S=s$  et  $A=a$
  - ◆ ne pas confondre avec  $j$  et  $m$  qui sont des observations fixes ( $J=\text{vrai}$  et  $M=\text{vrai}$ )



# Exemple

- $P(C \mid j, m) = \sum_{s,a} P(C, s, a, j, m) / \alpha$

- On calcule pour  $C = \text{vrai}$


$$\begin{aligned}
 P(c \mid j, m) &= \sum_{s,a} P(c) P(s) P(a \mid c,s) P(j \mid a) P(m \mid a) / \alpha \\
 &= (0.001 * 0.002 * 0.95 * 0.90 * 0.70 + \\
 &\quad 0.001 * 0.998 * 0.94 * 0.90 * 0.70 + \\
 &\quad 0.001 * 0.002 * 0.05 * 0.05 * 0.01 + \\
 &\quad 0.001 * 0.998 * 0.06 * 0.05 * 0.01) / \alpha \\
 &= 0.00059224 / \alpha
 \end{aligned}$$

- Et  $C = \text{faux}$

$$\begin{aligned}
 P(\neg c \mid j, m) &= \sum_{s,a} P(\neg c) P(s) P(a \mid \neg c,s) P(j \mid a) P(m \mid a) / \alpha \\
 &= 0.0014919 / \alpha
 \end{aligned}$$

$$\alpha = 0.00059224 + 0.0014919$$

- Donc,  $P(C \mid j, m) = [0.284, 0.716]$



# Exercice

- Soit le RB ayant les tables de probabilités conditionnelles suivantes

◆ Dessinez le graphe du RB.

◆ Calculez  $P(A=\text{faux} \mid E=\text{vrai})$ .

◆ Dites si  $B$  et  $E$  sont indépendants sachant  $F$ . Pourquoi?

◆ Dites si  $E$  et  $F$  sont indépendants sachant  $A$  et  $C$ . Pourquoi?

$A$	$C$	$F=\text{vrai}$
<i>faux</i>	<i>faux</i>	0.1
<i>faux</i>	<i>vrai</i>	0.2
<i>vrai</i>	<i>faux</i>	0.8
<i>vrai</i>	<i>vrai</i>	0.7

$E$	$C=\text{vrai}$
<i>faux</i>	0.2
<i>vrai</i>	0.4

$D=\text{vrai}$
0.2


$B$	$D$	$E$	$A=\text{vrai}$
<i>faux</i>	<i>faux</i>	<i>faux</i>	0.7
<i>faux</i>	<i>faux</i>	<i>vrai</i>	0.2
<i>faux</i>	<i>vrai</i>	<i>faux</i>	0.5
<i>faux</i>	<i>vrai</i>	<i>vrai</i>	0.1
<i>vrai</i>	<i>faux</i>	<i>faux</i>	0.2
<i>vrai</i>	<i>faux</i>	<i>vrai</i>	0.9
<i>vrai</i>	<i>vrai</i>	<i>faux</i>	0.8
<i>vrai</i>	<i>vrai</i>	<i>vrai</i>	0.6

$E=\text{vrai}$
0.9

$B=\text{vrai}$
0.7

# Inférence par élimination des variables

- Même principe que l'inférence par énumération, mais on évite les répétitions de calculs déjà faits (comme en programmation dynamique)
- Voir section 14.4.2 du livre



# Inférence approximative

- Les méthodes d'inférence exactes sont inefficaces
  - ◆ le problème d'inférence est NP-Complet
- Les méthodes d'inférence approximatives sont plus pratiques
  - ◆ en général, on n'a pas besoin d'un calcul exact des probabilités pour qu'une conclusion tirée d'un RB soit correcte
  - ◆ les méthodes approximatives assignent des valeurs aux variables aléatoires en fonction des TPC associées à ces variables
  - ◆ ces assignations sont basées sur des simulations stochastiques, plutôt que des observations réelles

# Méthode de rejet (*rejection sampling*)

- **Idée** : simuler des observations complètes du RB et estimer les probabilités à partir de la fréquence des observations échantillonnées

$$P(X=x|e) = \sum_y P(X=x, e, y) / \alpha \approx \text{freq}(x,e) / \sum_{x'} \text{freq}(x',e) = \text{freq}(x,e) / \text{freq}(e)$$

où  $\text{freq}(x,e)$  est le nombre de fois que  $X=x$  et  $E=e$  a été échantillonné et  $\text{freq}(e) = \sum_{x'} \text{freq}(x',e)$  est le nombre de fois que  $E=e$

- Cette technique est appelée **méthode de rejet** (*rejection sampling*)
  - ◆ le problème avec cette méthode est que si  $e$  est très rare selon le RB, il y aura peu d'échantillons qui correspondront à cette observation
  - ◆ d'autres méthodes sont plus efficaces et nécessitent moins d'échantillons pour obtenir une bonne estimation
  - ◆ voir la section 14.5 dans le livre



# Exemple 1 : Évaluation par énumérations

## Requête :

Calculer  $P(T=vrai | F=faux, M=vrai)$

## Variables connues :

$F = faux$

$M = vrai$

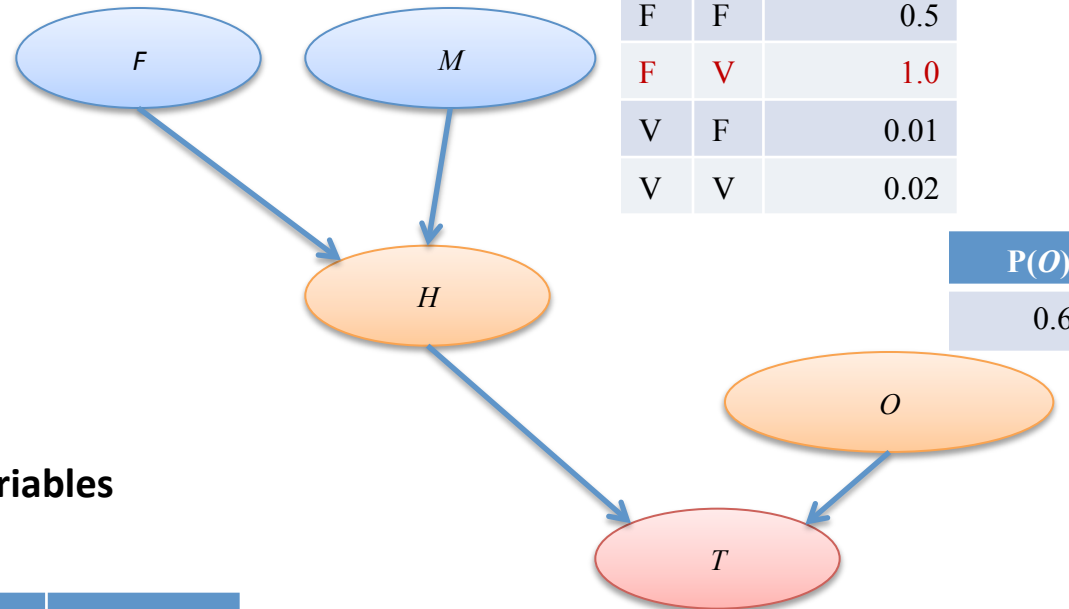
## Variables inconnues :

$H$

$O$

## Énumération des valeurs possible des variables cachées (2\*2)

$H$	$O$	$P(H F,M) * P(O) * P(T H,O)$	=
F	F	$0.0 * 0.4 * 0.1$	0
F	V	$0.0 * 0.6 * 0.5$	0
V	F	$1.0 * 0.4 * 0.5$	0.20
V	V	$1.0 * 0.6 * 1.0$	0.60
<b>TOTAL</b>			<b>0.80</b>



$F$	$M$	$P(H F,M)$
F	F	0.5
<b>F</b>	<b>V</b>	<b>1.0</b>
V	F	0.01
V	V	0.02

$P(O)$
0.6

$H$	$O$	$P(T H,O)$
F	F	0.1
F	V	0.5
V	F	0.5
V	V	1.0

# Exemple 2 : Évaluation par énumérations

## Requête :

Calculer  $P(T=vrai | M=vrai)$

## Variables connues :

$M = vrai$

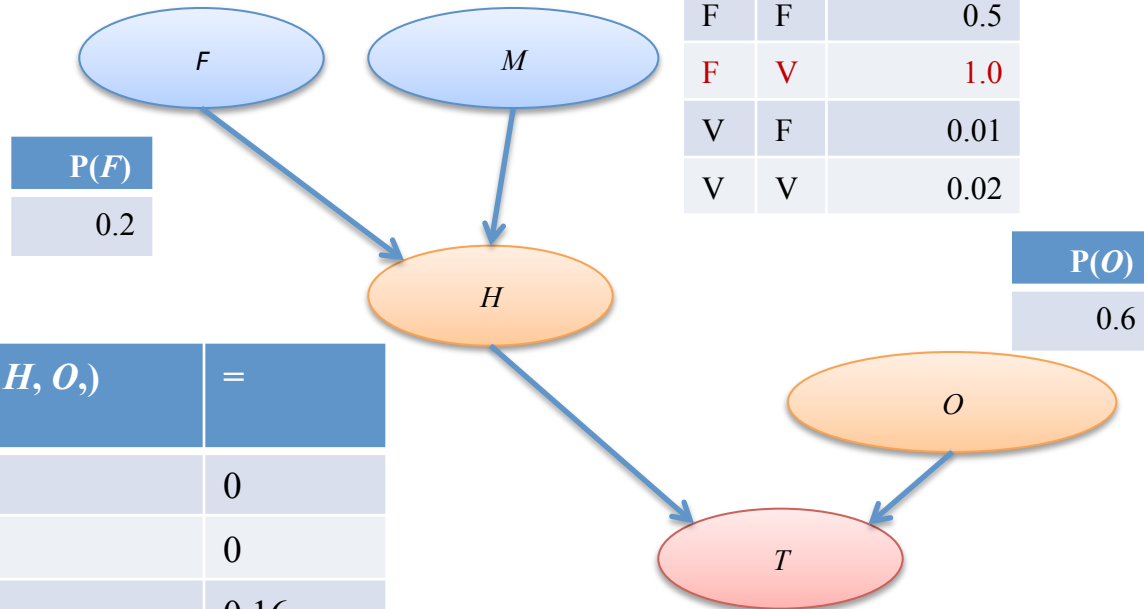
## Variables inconnues :

$H$

$O$

$F$

$F$	$H$	$O$	$P(F) * P(H F,M) * P(O) * P(T   H, O)$	=
F	F	F	$0.8 * 0.0 * 0.4 * 0.1$	0
F	F	V	$0.8 * 0.0 * 0.6 * 0.5$	0
F	V	F	$0.8 * 1.0 * 0.4 * 0.5$	0.16
F	V	V	$0.8 * 1.0 * 0.6 * 1.0$	0.48
V	F	F	$0.2 * 0.98 * 0.4 * 0.1$	0.00784
V	F	V	$0.2 * 0.98 * 0.6 * 0.5$	0.0588
V	V	F	$0.2 * 0.02 * 0.4 * 0.5$	0.0008
V	V	V	$0.2 * 0.02 * 0.6 * 1.0$	0.0024
			<b>TOTAL</b>	<b>0.71</b>



$F$	$M$	$P(H F,M)$
F	F	0.5
<b>F</b>	<b>V</b>	<b>1.0</b>
V	F	0.01
V	V	0.02

$H$	$O$	$P(T H,O)$
F	F	0.1
F	V	0.5
V	F	0.5
V	V	1.0

# Exemple 2 : Échantillonnage direct



## Requête :

Calculer  $P(T=vrai | M=vrai)$

## Variables connues :

$M = vrai$

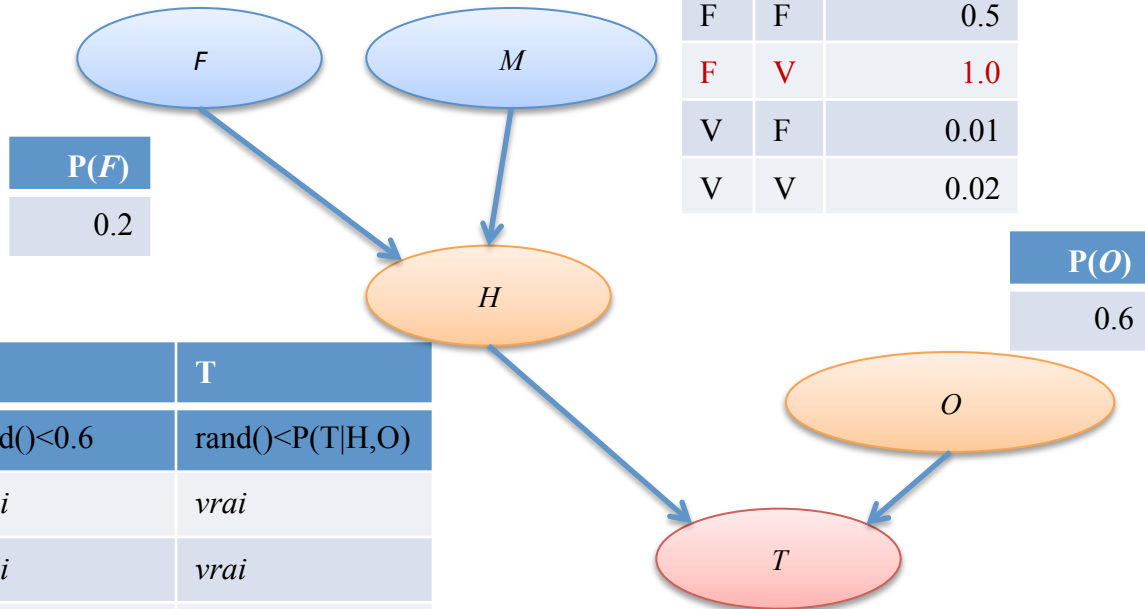
## Variables inconnues :

$H$

$O$

$T$


	F	H	O	T
#	rand() $<0.2$	rand() $<P(H F,M)$	rand() $<0.6$	rand() $<P(T H,O)$
1	<i>faux</i>	<i>vrai</i>	<i>vrai</i>	<i>vrai</i>
2	<i>faux</i>	<i>vrai</i>	<i>vrai</i>	<i>vrai</i>
3	<i>faux</i>	<i>vrai</i>	<i>faux</i>	<i>faux</i>
4	<i>vrai</i>	<i>faux</i>	<i>faux</i>	<i>faux</i>
5	<i>faux</i>	<i>vrai</i>	<i>vrai</i>	<i>vrai</i>
6	<i>faux</i>	<i>vrai</i>	<i>vrai</i>	<i>vrai</i>
7	<i>faux</i>	<i>vrai</i>	<i>vrai</i>	<i>vrai</i>
8	<i>faux</i>	<i>vrai</i>	<i>faux</i>	<i>vrai</i>
Average of $T=vrai$				<b>6/8 = 0.75</b>



Plus qu'il y a d'échantillon, plus l'erreur d'estimation est faible.

# Types d'interrogations d'un RB

- **Diagnostic** (on connaît les effets, on cherche les causes)
  - ◆  $P(\text{Cambriolage} | \text{JeanAppelle}=\text{vrai})$
  - ◆ garder à l'esprit qu'on a des arcs « causes / effets ».
- **Prédiction** (étant données les causes, quels sont les effets)
  - ◆  $P(\text{JeanAppelle} | \text{Cambriolage}=\text{vrai})$
- **Probabilité conjointe ou marginale**
  - ◆  $P(\text{Alarme})$



# Construction d'un RB

1. Choisir un ordre des variables  $X_1, \dots, X_n$
2. Pour  $i = 1$  to  $n$  :
  - ◆ ajouter  $X_i$  au réseau
  - ◆ choisir les parents  $X_1, \dots, X_{i-1}$  tels que  $P(X_i \mid \text{Parents}(X_i)) = P(X_i \mid X_1, \dots, X_{i-1})$
  - ◆ ce choix garantit que :

$$\begin{aligned} P(X_1, \dots, X_n) &= \prod_{i=1}^n P(X_i \mid X_1, \dots, X_{i-1}) \quad (\text{chain rule}) \\ &= \prod_{i=1}^n P(X_i \mid \text{Parents}(X_i)) \quad (\text{par construction}) \end{aligned}$$

- Pour construire un bon RB, sa structure doit refléter les indépendances conditionnelles du problème
- Dans quel ordre ajouter les nœuds au réseau?
  - ◆ mettre les « causes racines » d'abord, ensuite les nœuds qu'ils influencent directement

# Exemple

- Supposons qu'on ordonne les variables comme suit :  $M, J, A, C, S$

*MarieAppelle*


*JeanAppelle*

- $P(J|M) = P(J)$ ?

# Exemple

- Supposons qu'on ordonne les variables comme suit :  $M, J, A, C, S$


- $P(J|M) = P(J)$ ? **Non**
- $P(A|J,M) = P(A|J)$ ?  $P(A|J,M) = P(A)$ ?



# Exemple

- Supposons qu'on ordonne les variables comme suit :  $M, J, A, C, S$


- $P(J|M) = P(J)$ ? **Non**
- $P(A|J,M) = P(A|J)$ ?  $P(A|J,M) = P(A)$ ? **Non**
- $P(C|A,J,M) = P(C|A)$ ?
- $P(C|A,J,M) = P(C)$ ?





# Exemple

- Supposons qu'on ordonne les variables comme suit :  $M, J, A, C, S$




- $P(J|M) = P(J)$ ? **Non**
- $P(A|J,M) = P(A|J)$ ?  $P(A|J,M) = P(A)$ ? **Non**
- $P(C|A,J,M) = P(C|A)$ ? **Oui**
- $P(C|A,J,M) = P(C)$ ? **Non**
- $P(S|C,A,J,M) = P(S|A)$ ?
- $P(S|C,A,J,M) = P(S|A,C)$ ?

# Exemple

- Supposons qu'on ordonne les variables comme suit :  $M, J, A, C, S$

- $P(J|M) = P(J)$ ? **Non**
- $P(A|J,M) = P(A|J)$ ?  $P(A|J,M) = P(A)$ ? **Non**
- $P(C|A,J,M) = P(C|A)$ ? **Oui**
- $P(C|A,J,M) = P(C)$ ? **Non**
- $P(S|C,A,J,M) = P(S|A)$ ? **Non**
- $P(S|C,A,J,M) = P(S|A,C)$ ? **Oui**



# Exemple

- Déterminer l'indépendance conditionnelle est très difficile dans le sens non causal
  - ◆ par exemple, en médecine, des études ont démontré que les experts préfèrent donner des probabilités dans le sens causal (pathologie → symptôme) plutôt que dans le sens diagnostique
- Un réseau avec des dépendance diagnostiques (effet → cause) est généralement moins compacte
  - ◆ dans le cas présent :  $1 + 2 + 4 + 2 + 4 = 13$  nombres pour représenter les tables de probabilité conditionnelle du réseau au lieu de 10 pour la première version

# Apprentissage dans un RB : paramètres

- Supposons que le graphe d'un RB ait été spécifiée par un expert
- Comment estimer les tables de probabilités  $P(X_i \mid \text{Parents}(X_i))$  ?
- Si on a un ensemble de données **où tous les noeuds  $X_i$  sont observés**, c'est facile :

$$P(X_i = x \mid \text{Parents}(X_i) = p) \approx \text{freq}(x, p) / \sum_{x'} \text{freq}(x', p)$$

- On fait ce calcul pour toutes les valeurs  $x$  de  $X_i$  et toutes les valeurs  $p$  de ses parents possibles
  - ◆ pour éviter d'avoir de probabilités à 0, on peut initialiser  $\text{freq}(x, e) = \delta$  à une petite constante  $\delta$  (ex. :  $\delta=1$ )

# Apprentissage dans un RB : paramètres


- Supposons que le graphe d'un RB ait été spécifiée par un expert
- Comment estimer les tables de probabilités  $P(X_i \mid \text{Parents}(X_i))$  ?
- Si on a un ensemble de données **où certains des noeuds ne sont pas observés**, on doit utiliser des méthodes plus sophistiquées
  - ◆ Algorithme EM (voir section 20.3.2)

# Apprentissage dans un RB : graphe

- Quoi faire si on n'a pas accès à un expert pour nous donner un bon graphe de RB ?
- On peut aussi tenter d'obtenir la structure du RB à partir de données, à l'aide de la recherche locale (par exemple *Hill Climbing*) :
  1. on débute avec un **graphe acyclique aléatoire** comme graphe courant
  2. on **obtient ses tables de probabilités** à partir des fréquences d'observation du graphe courant
  3. on utilise la recherche locale pour **générer des graphes successeurs** du graphe courant
    4. on obtient les tables de probabilités du graphe successeur
    5. on remplace le graphe courant par le successeur s'il est « meilleur »
  6. on retourne à 2. jusqu'à un certain critère d'arrêt

# Apprentissage dans un RB : graphe

- On génère des successeurs à partir des modifications au graphe suivantes
  - ◆ l'ajout d'un arc
  - ◆ la suppression d'un arc
  - ◆ l'inversion d'un arc



# Apprentissage dans un RB : graphe

- La fonction objectif à maximiser par la recherche locale est :

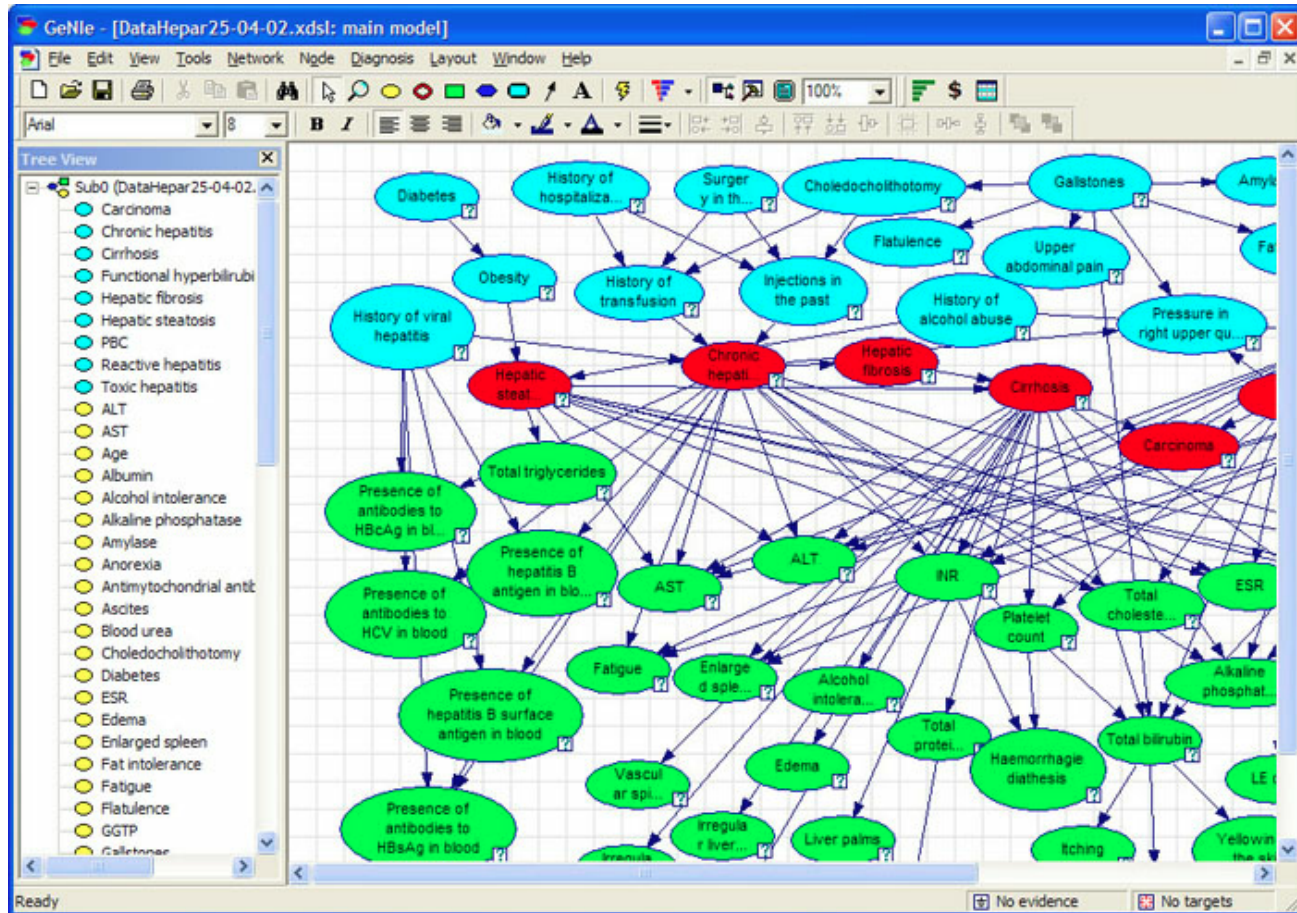
$$\underbrace{\sum_t \log P(X_1 = x_1^t, \dots, X_n = x_n^t)}_{\text{log probabilité des données}} - \underbrace{M (\log T) / 2}_{\text{complexité du graphe}}$$

- ◆  $\{x_1^t, \dots, x_n^t\}$  est la  $t^{\text{ième}}$  donnée de mon ensemble de  $T$  données
- ◆  $M$  est le nombre de paramètres requis par les tables de probabilités conditionnelles du réseau bayésien
- On cherche donc un graphe
  - ◆ qui **explique bien les données** (leur donne une haute probabilité)
  - ◆ qui est **compacte** (qui a peu de paramètres)
- Pour en savoir plus : voir section 20.2.5



# Logiciels

- SMILE / GeNIe (<http://genie.sis.pitt.edu/>)

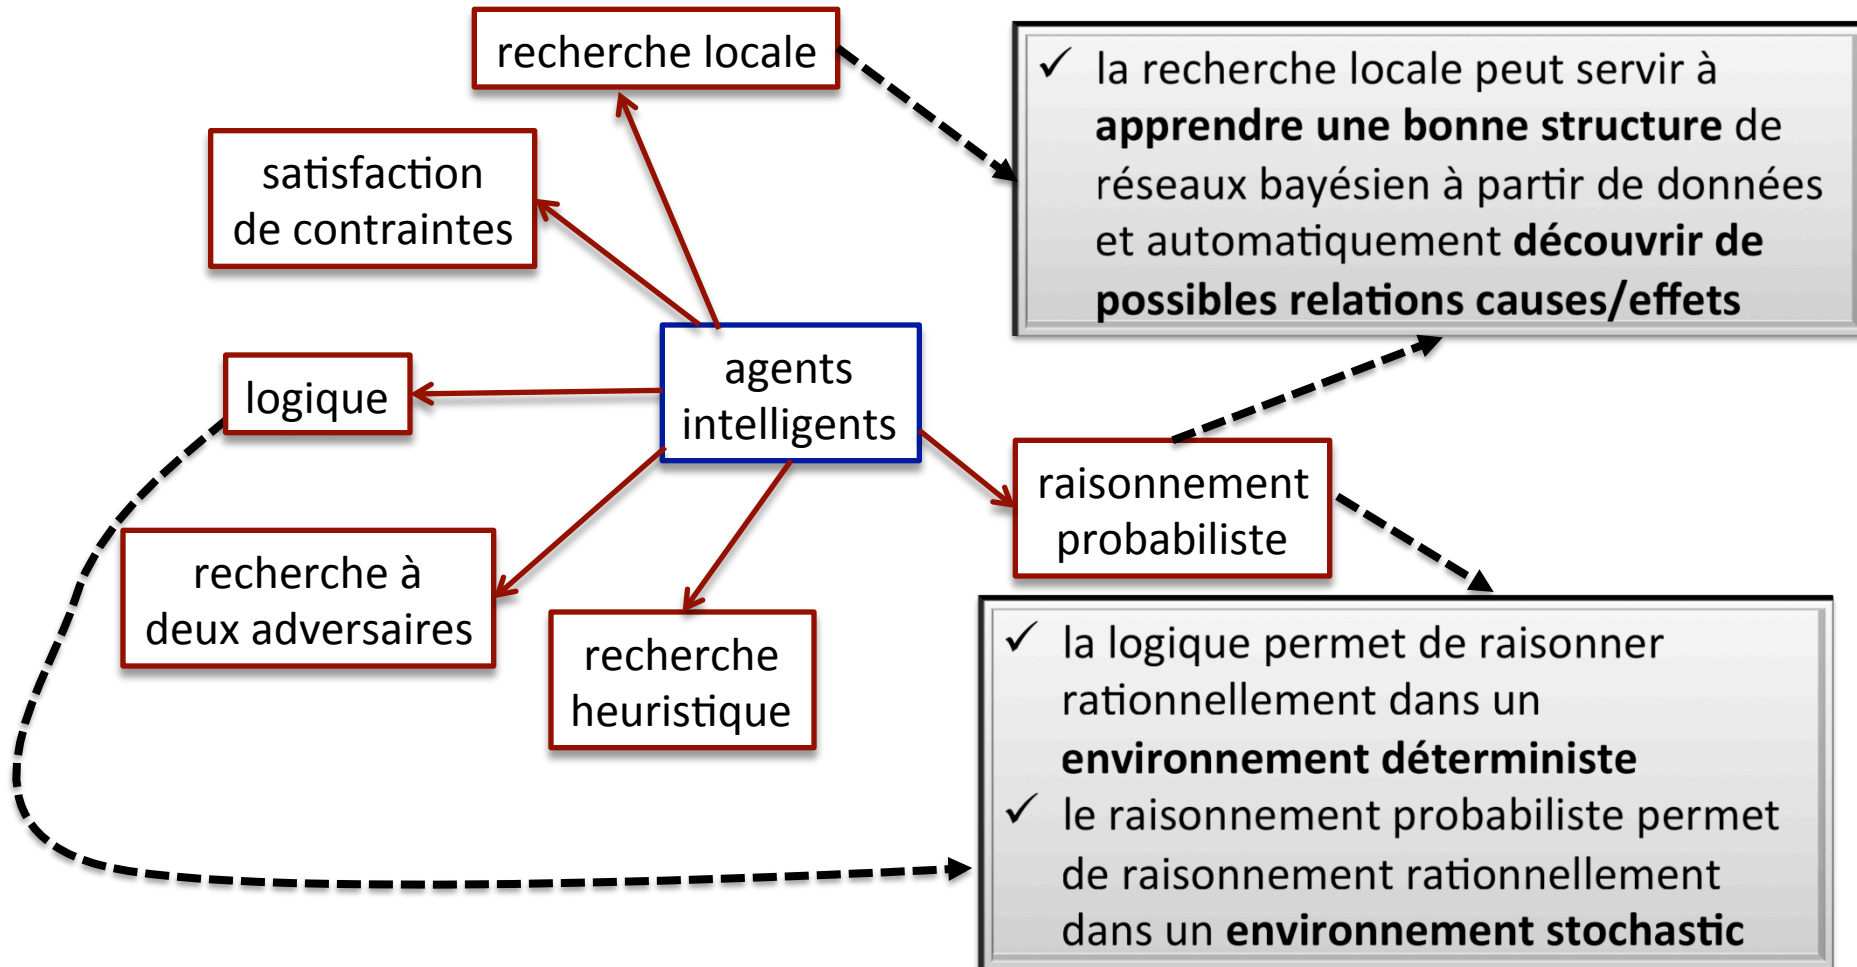


# Résumé

- Un RB est un graphe orienté, acyclique, représentant des connaissances causales, et reflétant les dépendances conditionnelles entre des variables
- La topologie du réseau (arcs entre les variables) et les TPC donnent une représentation compacte de la distribution conjointe des probabilités
- Les connaissances du réseau (liens de causalité et probabilités) sont généralement obtenus avec l'aide d'un expert
  - ◆ pour des applications concrètes, ceci peut être très laborieux

# Objectifs du cours

## Algorithmes et concepts



# Vous devriez être capable de...

- Décrire ce qu'est un réseau bayésien :
  - ◆ qu'est-ce que la topologie représente
  - ◆ quelle est la distribution conjointe associée à un réseau bayésien
- Étant donné un réseau bayésien :
  - ◆ calculer une probabilité conjointe, marginale, conditionnelle
  - ◆ dire si deux variables sont (conditionnellement) indépendantes
- Décrire comment on
  - ◆ apprend les paramètres d'un réseau bayésien à partir de données
  - ◆ apprend la structure d'un réseau bayésien à partir de données