

INF4230 – Intelligence Artificielle

Réseaux bayésiens

Hiver 2017

Sommaire

- Qu'est-ce qu'un **réseau bayésien (RB)** ?
 - Structure et formalisme
 - Signification
- Indépendance conditionnelle dans un RB.
- Inférence dans un réseau bayésien
 - Inférence exacte
 - Inférence approximative
- Diagrammes d'influence


Contexte

- Jusqu'à présent, nous avons notamment étudié des techniques pour des environnements déterministes
- Que faire lorsque l'environnement est non déterministe?
- Quel type d'agent? Un qui doit pouvoir:
 - Gérer l'incertitude lié à l'environnement

→ probabilité

– Gérer la qualité de ses

→ utilité



Exemple de décision sous incertitude

- Soit l'action A_t d'aller à l'aéroport t minutes avant le départ de l'avion.
- A_t me permettra-t-il d'arriver à temps?
- Caractéristique (de l'environnement) du problème:
 - Observabilité partielle (conditions routières, etc.)
 - Senseurs bruités (annonces du trafic, etc.)
 - Incertitude dans l'effet des actions (crevaisons, pannes, etc.)
 - Immense complexité pour modéliser les actions et le trafic.



Exemple de décision sous incertitude

- Un raisonnement purement logique
 - Risque de tirer des conclusions erronées: « A_{25} me permettra d'arriver à temps », ou
 - Risque de tirer des conclusions peu exploitables du point de vue « prise de décision »:
 - « A_{25} me permettra d'arriver à temps, s'il ne pleut pas, s'il n'y a pas d'accident, si mes pneus ne crèvent pas, etc. »
 - « A_{1440} me permettra raisonnable d'arriver à temps, mais je devrai passer une nuit à l'aéroport. »



Prise de décision sous incertitude

- Supposons que je crois ceci :

$P(A_{25} \text{ me permet d'arriver à temps} \mid \dots)$	= 0.04
$P(A_{90} \text{ me permet d'arriver à temps} \mid \dots)$	= 0.70
$P(A_{120} \text{ me permet d'arriver à temps} \mid \dots)$	= 0.95
$P(A_{240} \text{ me permet d'arriver à temps} \mid \dots)$	= 0.999
$P(A_{1440} \text{ me permet d'arriver à temps} \mid \dots)$	= 0.9999

- Quelle action devrai-je choisir?
 - Cela dépend de mes **préférences**: manquer l'avion vs. trop d'attente.
- **La théorie de l'utilité** est utilisée pour modéliser et inférer sur les préférences.
 - Une préférence exprime le degré d'utilité d'une action/situation.
- **Théorie de la décision** = théorie des probabilités + théorie de l'utilité.

Discussion : utilité de l'argent

- Lors d'un quiz, vous gagnez 1 000 000 \$!
- On vous propose un dernier jeu facultatif à pile ou face:
 - On lance une pièce de monnaie équilibrée :
 - Vous ne jouez pas : vous partez avec 1 000 000 \$.
 - Face : vous tripler votre gain 3 000 000 \$.
 - Pile : vous repartez les mains vides : 0 \$
 - Acceptez-vous ce dernier jeu?
- Même décision si gain initial était de 10\$?



Réseaux bayésiens: Préambule

Notions de bases: Probabilité conditionnelle & Variables indépendantes

- Variables aléatoires X et Y avec les domaines de valeurs possibles suivants:

Exemple: $X = \{1,2,3,4,5,6\}$, $Y = \{\text{oui, non, peut-être}\}$

- Règle de produit: $P(X,Y) = P(X|Y) * P(Y) = P(Y|X) * P(X)$
- Règle de Bayes: $P(X|Y) = P(Y|X) P(X) / P(Y) = \alpha P(Y|X) P(X)$
- Variables aléatoires booléennes Heureux et Riche avec les domaines de valeurs = $\{\text{vrai, faux}\}$
- $P(\text{Heureux}=\text{vrai}, \text{Riche}=\text{faux}) == P(\text{Heureux}, \neg \text{Riche})$
 $= P(\text{Heureux} | \neg \text{Riche}) * P(\neg \text{Riche})$

Réseaux bayésiens: Préambule

- Avec trois variables aléatoires...
- Soit une variable aléatoire $Z = \{a,b,c\}$

$$P(X=3, Y=\text{non}, Z=a)$$

$$= P(X=3 \mid Y=\text{non}, Z=a) * P(Y=\text{Non}, Z=a)$$

$$= P(X=3 \mid Y=\text{non}, Z=a) * \mathbf{P(Y=Non, Z=a)}$$

$$= P(X=3 \mid Y=\text{non}, Z=a) * \mathbf{P(Y=Non \mid Z=a) * P(Z=a)}$$

Réseaux bayésiens: Préambule

- **Variables indépendantes**

Si X et Y sont indépendantes,

$$\mathbf{P(X,Y) = P(X)*P(Y)}$$

Ex: $P(\text{Pluie}, \text{Riche}) = P(\text{Pluie}) * P(\text{Riche})$

Par ailleurs:

$$\mathbf{P(X|Y) = P(X)}$$

Ex: $P(\text{Pluie} | \text{Riche}) = P(\text{Pluie})$

Réseaux bayésiens: Préambule

- 4 variables aléatoires booléennes:
 - Détecte (vrai si le dentiste détecte une anomalie)
 - Douleur (vrai si le patient ressent une douleur)
 - Carie (vrai si le patient a une carie)
 - Compétent (vrai si le dentiste est compétent)

P(Detecte, Douleur, Carie, Compétent)

= $P(\text{Détecte} \mid \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur}, \text{Carie}, \text{Compétent})$

= $P(\text{Détecte} \mid \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur} \mid \text{Carie}, \text{Compétent})$
* $P(\text{Carie}, \text{Compétent})$

= **$P(\text{Détecte} \mid \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur} \mid \text{Carie}, \text{Compétent})$**
* **$P(\text{Carie} \mid \text{Compétent}) * P(\text{Compétent})$**

Réseaux bayésiens: Préambule

- Détection et élimination des liens d'indépendance

$P(\text{Detecte}, \text{Douleur}, \text{Carie}, \text{Compétent})$

= $P(\text{Détecte} | \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur}, \text{Carie}, \text{Compétent})$

= $P(\text{Détecte} | \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur} | \text{Carie}, \text{Compétent})$
* $P(\text{Carie}, \text{Compétent})$

= **$P(\text{Détecte} | \text{Douleur}, \text{Carie}, \text{Compétent}) * P(\text{Douleur} | \text{Carie}, \text{Compétent})$**
* **$P(\text{Carie} | \text{Compétent}) * P(\text{Compétent})$**

= **$P(\text{Détecte} | \text{Carie}, \text{Compétent}) * P(\text{Douleur} | \text{Carie}) * P(\text{Carie}) * P(\text{Compétent})$**

Ces simplifications dérivent des faits de l'indépendance conditionnelle entre les variables concernées.


Par exemple, puisque Compétent est conditionnellement indépendant de Douleur ,

$P(\text{Douleur} | \text{Carie}, \text{Compétent}) = P(\text{Douleur} | \text{Carie})$.

- Notes: Dans des cas idéals, l'exploitation de l'indépendance conditionnelle réduit la complexité de représentation de la distribution conjointe d'une exponentielle ($O(2^n)$) en linéaire ($O(n)$), pour n variables aléatoires.


Réseaux bayésiens: Préambule

- Représentation graphique: modélisation du graphe



Réseaux bayésiens: Préambule

- Représentation graphique: Probabilités




Réseaux bayésiens

En bref:

- Les RB sont un mariage entre la théorie des graphes et la théorie des probabilités.
- Un RB représente les connaissances probabilistes à partir d'une situation 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 causent d'autres.
 - Notre compréhension de la causalité des événements est incomplète : on doit recourir aux probabilités.

Formalisme

- Un **réseau bayésien** est un **graphe orienté et acyclique** où :
 - les **nœuds** sont des **variables** (généralement aléatoires);
 - les **arcs** représentent des relations de **dépendance** (causalités) entres les variables;
 - des distributions de probabilités conditionnelles («tables de probabilités») sont attachées aux variables.




Exemple : Détection de cambriolage

- Je suis souvent à l'extérieur de chez moi.
- Je m'inquiète d'un cambriolage durant mon absence.
- J'ai fait installé un système d'alarme chez moi.
- Mes voisins, Marie et Jean, m'ont promis de m'appeler à chaque fois qu'ils entendent mon système d'alarme.
- Jean confond parfois l'alarme avec le téléphone.
- Marie n'entend pas toujours l'alarme, car elle met la musique trop forte chez elle.
- Parfois mon système d'alarme déclenche lors de légers tremblements de terre.
- Comment conclure qu'il y a un cambriolage chez moi ?


Exemple

- Variables aléatoires :
 - *Cambriolage*
 - *TremblementDeTerre*
 - *Alarme*
 - *Jean appelle*
 - *Marie appelle.*




Exemple

- La topologie du RB modélise la connaissance causale.
- 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 tremblement de terre aussi.
 - L'alarme peut inciter Jean à appeler.
 - Idem pour Marie à appeler.
- Pour chaque nœud, une table de probabilité conditionnelle (TPC) donne la probabilité pour chaque valeur du nœud étant donné les combinaisons des valeurs des parents du nœud.



Définitions

- S'il y a un arc d'un nœud X vers un nœud Y , cela signifie que la variable X influence la variable Y .
 - X est appelé le parent de Y .
 - $Parents(X)$ est l'ensemble des parents de X .
- Si X n'a pas de parents, sa distribution de probabilités est dite *inconditionnelle* ou *à priori*.
- Si X a des parents, sa distribution de probabilités est dite *conditionnelle* (par rapport aux parents) ou *à postérieure*.
- Si X est une variable observée, on dit que c'est une *évidence*.



Sémantique

- Un RB est une façon compacte de représenter des probabilités conjointes.
- Par définition, la probabilité conjointe de X_1 et X_2 est la probabilité d'avoir X_1 et X_2 : $P(X_1, X_2)$.
- La probabilité 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).
 - *Seules comptent les probabilités de chaque variable connaissant ses parents, pour calculer la distribution conjointe.*

Sémantique

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

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

- Pour un RB : $P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | Parents(X_i))$
- Ceci est cohérent avec l'assertion précédente pour autant que $Parents(X_i)$ soit un sous-ensemble de $\{X_{i-1}, \dots, X_1\}$.
- Cette condition est satisfaite en étiquetant les nœuds du RB dans un ordre cohérent avec la relation d'ordre partielle implicite dans la topologie du RB.

Exemple

- $P(X_1, \dots, X_n) =$

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


- $P(j, m, a, \neg c, \neg t)$

$$= P(j|a) P(m|a) P(a | \neg c, \neg t) P(\neg c) P(\neg t)$$

$$= .90 \times .70 \times .001 \times$$


$$0.999 \times .998$$

$$= .00062$$



Construction d'un RB

- Il y a un arc de X vers Y si X influence *directement* Y.
- S'il y a un arc d'un nœud X vers un nœud Y, on dit que :
 - X donne le support causal à Y.
 - Y donne le support diagnostique à X.



Construction d'un RB

- Pour construire un RB correcte, on s'assure que chaque nœud est indépendant de tous ses prédécesseurs, étant donné ses parents.
 - En d'autres mots, les parents du nœud X_i devraient être tous les nœuds dans $\{X_1, \dots, X_{i-1}\}$ qui influencent/cause directement X_i
- Dans quel ordre ajouter les nœuds au réseau?
 - Mettre les « causes racines » d'abord, ensuite les nœuds qu'ils influencent directement.

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} tel que $\mathbf{P}(X_i | \text{Parents}(X_i)) = \mathbf{P}(X_i | X_1, \dots, X_{i-1})$
- Ce choix garantit que:
 - $\mathbf{P}(X_1, \dots, X_n) = \prod_{i=1}^n \mathbf{P}(X_i | X_1, \dots, X_{i-1})$ (chain rule)
 - $\quad \quad \quad = \prod_{i=1}^n \mathbf{P}(X_i | \text{Parents}(X_i))$ (par construction)

Exemple

- Supposons qu'on ordonne les variables comme suit: M, J, A, C, T .

MarieAppelle

JeanApelle

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


Exemple

- Supposons qu'on ordonne les variables comme suit: M, J, A, C, T

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

Non.

$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)?$$



Exemple

- Supposons qu'on ordonne les variables comme suit: M, J, A, C, T .


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

Non.

$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)? \quad \text{Non.}$$

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

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



Example

- Supposons qu'on ordonne les variables comme suit: M, J, A, C, T .

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


Non.

$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)? \quad \text{Non.}$$

$$P(C | A, J, M) = P(C | A)? \quad \text{Oui.}$$

$$P(C | A, J, M) = P(C)? \quad \text{Non.}$$

$$P(T | C, A, J, M) = P(T | A)?$$



Exemple

- Supposons qu'on ordonne les variables comme suit: M, J, A, C, T .

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

Non.


$$P(A | J, M) = P(A | J)? \quad P(A | J, M) = P(A)? \quad \text{Non.}$$

$$P(C | A, J, M) = P(C | A)? \quad \text{Oui.}$$


$$P(C | A, J, M) = P(C)? \quad \text{Non.}$$

$$P(T | C, A, J, M) = P(T | A)? \quad \text{Non.}$$

$$P(T | C, A, J, M) = P(T | A, C)? \quad \text{Oui.}$$




Exemple



- Déterminer l'indépendance conditionnelle est très difficile dans le sens non causal.
 - Par exemple, en médecine, des études ont montré que les experts préfèrent donner des probabilités dans le sens causal (pathologie → symptôme) plutôt que dans le sens diagnostique.
- Un réseau avec des dépendance diagnostique (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.


Autres appellations

- Il y a d'autres appellations pour les RB :
 - Réseaux de croyances (*beleif networks*).
 - Réseaux probabilistes.
 - Réseaux causals.
- Les nœuds d'un réseau bayésien sont aussi appelés des « nœuds chances ».




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 fonctionnent aussi avec des variables continues :
 - Les probabilités conditionnelles sont spécifiées par des fonctions de densité de probabilités (PDF).
 - Ex:
 - Distance entre voleur et le capteur de mouvement.
 - Force du séisme sur l'échelle de Richter.




Indépendance conditionnelle dans un RB (1)

- 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.
 - Mais ils sont indépendants étant donné **Alarme** :
$$P(M | A, C) = P(M | A).$$
 - Si **A** est connu, alors **C** n'intervient pas dans le calcul.




Indépendance conditionnelle dans un RB (2)

- 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.
 - Mais ils sont indépendants étant donné *Alarme* :
$$P(J | A, M) = P(J | A).$$
 - Si *A* est connu, alors *M* n'intervient pas dans le calcul.



Dépendance conditionnelle dans un RB (1)


- Un RB modélise les relations d'indépendance conditionnelle suivantes
 - Un nœud est indépendante de ses non-descendants, étant donné ses parents.
 - Exemples :
 - *Cambriolage* et *TremTerre* sont **indépendants**.
 - Mais ils sont **dépendants** étant donné *Alarme*.
 - $P(A | C, S)$ n'est pas simplifiable.



Indépendance conditionnelle dans un RB (2)

- Un nœud est conditionnellement indépendant étant donné tous ses parents, enfants et parents de ses enfants (autrement dit étant donné sa **couverture de Markov**).

Couverture de Markov de X




Inférence / Interrogation d'un RB

- On exploite un réseau bayésien (RB) pour calculer la **distribution de probabilités à postériori** pour un ensemble de variables, étant donné un **événement observé**.
- Un **événement observé** est un ensemble d'assignations de valeur à un ensemble de variables observées (évidences).
- Plus formellement, on a :
 - X l'ensemble de variables pour laquelle on fait l'interrogation;
 - E les variables d'évidences (qu'on peut observer);
 - H les variables cachées (qu'on ne peut pas observer).
- Une interrogation à un RB a la forme $P(X|e)$, où e est une assignation de valeurs aux variables dans E .
- Une interrogation s'appelle aussi faire une **inférence**.

Exemple d'inférence/interrogation

- Situation : Jean et Marie appellent.
- Interrogation : **quelle est la probabilité d'un cambriolage?**
- $P(\text{Cambriolage} | \text{JeanAppelle}=\text{True}, \text{MarieAppelle}=\text{True})$
= [0.284, 0.716]
- Comment faire ce calcul ?
 - **Inférence exacte (prohibitif)**
 - Par énumération
 - Élimination de variables
 - **Inférence approximative** par échantillonnage avec les méthode de Monte-Carlo
 - Échantillonnage direct
 - Vraisemblance pondérée
 - Chaînes de Markov simulées



Rappel de notions de base en probabilités

- Ceci nous donne
 - $P(X|Z) = \alpha P(X,Z)$
 - α est une constante de normalisation pour s'assurer que la somme des probabilités de la distribution $P(X,Z)$ soit égale à 1.
- De manière générale, soit
 - X , l'ensemble de variables pour laquelle on fait l'interrogation,
 - E , les variables d'évidences (qu'on peut observer) et
 - Y , les variables cachées (qu'on ne peut pas observer).
 - e , les valeurs observées pour les variables dans E .
- $P(X|E=e) = \alpha P(X,E=e) = \sum_y P(X, E=e, Y=y)$
- *Noté aussi* $P(X|e) = \alpha \sum_y P(X, e, y)$

Inférence par énumération dans un RB


- On a vu que : $P(X/e) = \alpha \sum_y P(X, e, y)$
- On a vu aussi que selon la sémantique d'un RB

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

- Les termes $P(X, e, y)$ peuvent donc s'écrire comme le produit des probabilités conditionnelles du réseau.
- En d'autres termes, on peut calculer la réponse à une interrogation $P(X/e)$ sur un RB, simplement en *calculant les sommes des produits des probabilités conditionnelles du RB*.
 - [Algorithme Figure 14.9, Page 506 du livre.](#)


Exemple

- Requête : $P(\text{Cambriolage} \mid \text{JeanApelle}=\text{T}, \text{MarieAppelle}=\text{T})$
- Aussi noté $P(C \mid j, m)$
- Les variables cachées : $H = \{\text{TremTerre}, \text{Alarme}\}$.
- $P(C \mid j, m) = \alpha \sum_{s,a} P(C, s, a, j, m)$
- *Note* : s et a veulent dire, toutes les valeurs possibles de $S=s$ et $A=a$ variables. Ne pas confondre avec j et m qui sont des évidences fixes ($J=j$ et $M=m$).



Exemple

- $P(C | j, m) = \alpha \sum_{s,a} P(C, s, a, j, m)$
- On calcule pour $C = true$
 $P(c | j, m)$
 $= \alpha \sum_{s,a} P(c)P(s)P(a|c,s)P(j|a)P(m|a)$
 $= 0.284$
- Et $C = false$
 $P(c | j, m)$
 $= \alpha \sum_{s,a} P(\neg c)P(s)P(a| \neg c,s)P(j|a)P(m|a)$
 $= 0.716$
- Ce qui donne $P(C | j, m) = [0.284, 0.716]$




Inférence par élimination des variables

- Même principe que l'inférence par énumération, mais on évite les répétitions de calculs déjà faits.
 - Voir section 14.4.2 du livre (3^e édition).

Types d'interrogations d'un RB

- **Diagnostic** (on connaît les effets, on cherche les causes)
 - $P(\text{Cambriolage} | \text{JeanAppelle}=\text{T})$
 - Garder à l'esprit qu'on a des arcs « causes → effets ».
- **Prédiction** (étant donné les causes, quels sont les effets)
 - $P(\text{JeanAppelle} | \text{Cambriolage}=\text{T})$.
- **Probabilité conjointe**
 - $P(\text{Alarme})$



Exercices (sens prédictif)

Exercice 1 : Inférence par énumérations

Requête:

Calculer $P(T=\text{true})$

Variables connues:


F = False

M = true

Variables inconnues:

H

O



Exercice 1 : Inférence par énumérations

Requête:

Calculer $P(T=\text{true})$

Variables connues:

F = False


M = true

Variables inconnues:

H

O

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



H	O	$P(H) * P(O) * P(T=\text{vrai} H, O)$	$P(H) * P(O) * P(T=\text{faux} H, O)$
F	F	$0.0 * 0.4 * 0.1 = 0.0$	$0.0 * 0.4 * 0.9 = 0.0$
F	T	$0.0 * 0.6 * 0.5 = 0.0$	$0.0 * 0.6 * 0.5 = 0.0$
T	F	$1.0 * 0.4 * 0.5 = \mathbf{0.2}$	$1.0 * 0.4 * 0.5 = \mathbf{0.2}$
T	T	$1.0 * 0.6 * 1.0 = 0.6$	$1.0 * 0.6 * 0.0 = 0.0$
TOTAL		0.8	0.2

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

Exercice 2 : Inférence par énumérations

Requête:


Calculer $P(T=\text{true})$

Variables connues:

$M = \text{true}$

Variables inconnues:

H
O
F



Exercice 2 : Inférence par énumérations

Requête:

Calculer $P(T=true)$

Variables connues:


$M = true$

Variables inconnues:

H

O

F



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

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

Exercice 3: Évaluation avec décomposition

Requête:


Calculer $P(T=\text{true})$

Variables connues:

$M = \text{true}$

Variables inconnues:

H
O
F



Exercice 3: Évaluation avec décomposition

Requête:


Calculer $P(T=true)$

Variables connues:

$M = true$

Variables inconnues:

H
O
F




1	F	$P(F)*P(H F)$	=
	F	$0.8*1.0$	0.8
	T	$0.2*0.02$	0.004
	Total		0.804

2	H	O	$P(H)*P(O)*P(T H,O)$	=
	F	F	$(1-0.804)*0.4 * 0.1$	0.00784
	F	T	$(1-0.804)*0.6 * 0.5$	0.0588
	T	F	$0.804*0.4 * 0.5$	0.1068
	T	T	$0.804*0.6 * 1.0$	0.4824
	TOTAL			0.71

Exercice 4 : par échantillonnage direct (approximation)




P(F)
0.2



F	M	P(H F,M)
F	F	0.5
F	T	1.0
T	F	0.01
T	T	0.02

P(O)
0.6



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

```

Random random = new Random();
int n=10000000;
int nbT = 0;
for(int i=0;i<n;i++){
    boolean F, M, H, O, T;
    M=true;
    double pF=0.2;
    F = random.nextDouble() < pF;
    double pH=0;
    if(!F && !M) pH = 0.5;
    if(!F && M) pH = 1.0;
    if(F && !M) pH = 0.01;
    if(F && M) pH = 0.02;
    H = random.nextDouble() < pH;
    double pO = 0.6;
    O = random.nextDouble() < pO;
    double pT=0;
    if(!H && !O) pT = 0.1;
    if(!H && O) pT = 0.5;
    if(H && !O) pT = 0.5;
    if(H && O) pT = 1.0;
    T = random.nextDouble() < pT;
    if(T) nbT++;
}
System.out.println("P(T|M=true)=" + ((double)nbT/n);
    
```

Requête:
 Calculer $P(T=true)$
Variables connues:
 M = true
Variables inconnues:
 H
 O
 F

artificielle
 us l'erreur d'estimation est faible.

Exercice 4 : par échantillonnage direct (approximation)



Requête:


Calculer $P(T=\text{true})$

Variables connues:

$M = \text{true}$

Variables inconnues:

H
O
F



F	M	P(H F,M)	P(O)
F	F	0.5	
F	T	1.0	
T	F	0.01	
T	T	0.02	


	F	H	O	T
#	Random<0.2	Random<P(H F,M)	Random<0.6	Random<P(T H,O)
1	False	True	True	True
2	False	True	True	True
3	False	True	False	False
4	True	False	False	False
5	False	True	True	True
6	False	True	True	True
7	False	True	True	True
8	False	True	False	True
Average of T=True				6/8 = 0.75

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

Apprentissage d'un RB

- La structure d'un RB (le graphe) est le plus souvent spécifiée à l'aide d'un expert.
- Dans d'autres applications, la structure est générée automatiquement à partir des données statistiques.
 - *C'est un des problèmes d'apprentissage machine.*
- Dans d'autres problèmes, on connaît la structure du RB, mais on ne connaît pas les TPC.
 - Là aussi, on peut les apprendre à partir des données statistiques.
 - *C'est un autre problème d'apprentissage machine.*

Exemple de RB complexe



Diagrammes d'influence

- Un diagramme d'influence (DI) est une extension d'un RB avec des **nœuds de décision** et des **nœuds d'utilité**.
 - Les nœuds habituels d'un RB sont appelés des **nœuds chances**.
 - On ajoute :
 - Des nœuds de décision représentant une prise de décision
 - Des nœuds d'utilité représentant l'utilité (coût ou degré de désirabilité) des nœuds chances influencés par les actions.
- Ainsi on peut modéliser des prises des décisions simples
 - Pour des décisions complexes (séquentielles), les processus de décision de Markov sont généralement préférables.

Exemple

Prendre / Ne pas prendre

Parapluie

pluvieux	\neg pluvieux
.4	.6

Trainer parapluie

$P(\text{trainer} \mid \text{prendre}) = 1$
 $P(\neg \text{trainer}, \neg \text{prendre}) = 1$

Bonheur

$U(\text{trainer}, \text{pluvieux}) = 25$
 $U(\text{trainer}, \neg \text{pluvieux}) = -20$
 $U(\neg \text{trainer}, \text{pluvieux}) = -100$
 $U(\neg \text{trainer}, \neg \text{pluvieux}) = 100$

Temps

Prévision

Temps	Prévision	
pluvieux	ensoleillé	.3
pluvieux	pluvieux	.7
\neg pluvieux	ensoleillé	.8
\neg pluvieux	pluvieux	.2

Évaluation des diagrammes d'influence

1. Mettre à jour les variables d'évidence.
2. Pour chaque valeur possible d'un nœud décision
 - a. Change le nœud décision pour lui donner cette valeur.
 - b. Calcule les probabilités à postérioris des parents des nœuds utilités (en utilisant un algorithme d'inférence standard pour les RB).
 - c. Calcule l'utilité résultante pour l'action.
3. Retourne l'action avec la plus grande utilité

Autres appellations pour DI

- Diagrammes d'influence (*influence diagrams*).
- Réseaux de décision (*decision networks*)
- Diagrammes de pertinence (*relevance diagrams*)

Exemples d'applications

- Microsoft
 - Windows : identification des problèmes d'impression.
 - Office : Microsoft Agent.
- NASA
 - Support au diagnostique en temps réel des pannes du système de propulsion des navettes spatiales.
- Médecine
 - *Intellipath* : aide au diagnostique des maladies (proposer le diagnostique le plus probable à partir des symptômes; recommander les tests de laboratoires les plus pertinents; recommander les traitements).
- AT&T
 - Détections des fraudes et des mauvais payeurs pour les factures de téléphone.

Logiciels

- Hugin (commercial).
- **Génie/Smile** (domaine publique)

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.
- Un diagramme d'influence est un réseau bayésien avec des nœuds de décision et des nœuds d'utilité.