

IFT 615 – Intelligence artificielle

Réseaux bayésiens

Hugo Larochelle

Département d'informatique

Université de Sherbrooke

<http://www.dmi.usherb.ca/~larocheh/cours/ift615.html>

Sujets couverts


- C'est quoi un réseau bayésien (RB)?
 - ◆ structure d'un RB
 - ◆ signification
- Indépendance conditionnelle dans un RB
- Inférence dans un réseau bayésien
 - ◆ inférence exacte
 - ◆ inférence approximative
- Diagrammes d'influence

Réseaux bayésiens

- Les 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)
 - ◆ notre compréhension de la causalité des événements est incomplète (on doit recourir aux probabilités)

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 donné 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
 - » 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*

Cambriolage

Séisme


Alarme

JeanApelle

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**
- Si X est une variable observée, on dit que c'est une observation (*evidence*)



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 $\mathbf{P}(X_1, X_2)$, pour une valeur donnée de X_1 et X_2
- La distribution conditionnelle de X_1 sachant X_2 est notée $\mathbf{P}(X_1 | X_2)$
 - ◆ $\mathbf{P}(X_1, X_2) = \mathbf{P}(X_1 | X_2) \mathbf{P}(X_2)$
- Soit $X = \{X_1, \dots, X_n\}$, l'ensemble des variables d'un RB:
 - ◆ $\mathbf{P}(X_1, \dots, X_n) = \prod_{i=1}^n \mathbf{P}(X_i | \text{Parents}(X_i))$
- En d'autres mots, la distribution conjointe des variables d'un RB est définie comme étant le produit des distributions conditionnelles (locales)

Sémantique


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

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

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


Exemple

- $P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i \mid \text{Parents}(X_i))$
- $P(j, m, a, \neg c, \neg s)$
 $= P(j \mid a) P(m \mid a) P(a \mid \neg c, \neg s)$
 $P(\neg c) P(\neg s)$
 $= .90 \times .70 \times .001 \times$
 $0.999 \times .998$
 $= .00062$



Construction d'un RB

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



Construction d'un RB

- Pour construire un RB correct, on s'assure que chaque nœud est indépendant de tous ses prédécesseurs, étant donnés 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/causent 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 $\mathbf{P}(X_i \mid \text{Parents}(X_i)) = \mathbf{P}(X_i \mid X_1, \dots, X_{i-1})$
 - ◆ Ce choix garantit que:

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

Exemple

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


MarieAppelle

JeanApelle

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

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


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**



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



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, *C* n'intervient pas dans le calcul



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:
 - » *JeanAppelle* et *MarieAppelle* sont **dépendants**.
 - » mais ils sont **indépendant** étant donné *Alarme*:

$$P(J|A,M) = P(J|A)$$
 - » si *A* est connu, *M* n'intervient pas dans le calcul



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 *Séisme* sont **indépendants**
 - » 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




Indépendance conditionnelle dans un RB (2)

- Soit la **couverture de Markov** (**Markov blanket**) $MB(X)$ d'un noeud X , c'est à dire:
 - ◆ les parents de X
 - ◆ les enfants de X
 - ◆ et les parents des enfants de X
- Le noeud X est conditionnellement indépendant des autres noeuds (hors de la couverture de Markov), étant donné les noeuds de la couverture de Markov:


$$\mathbf{P}(X|MB(X),Others) = \mathbf{P}(X|MB(X))$$

Couverture de Markov de X



Indépendance conditionnelle dans un RB (3)

- ◆ **D-séparation:** critère pour décider si un nœud X est indépendant d'un nœud Y , étant donné un autre nœud Z
- ◆ Ce cas est non traité ici




Requête dans un RB

- L'usage principal d'un RB est de calculer la distribution de probabilités a posteriori pour un ensemble de variables, étant donné un événement observé
- Un événement est une assignation de valeurs à certaines variables d'observation
- Soit
 - ◆ X l'ensemble de variables pour lesquelles on fait une requête
 - ◆ E les variables d'observation et
 - ◆ Y les variables cachées (qui ne sont pas observées)
- 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:
 $P(\text{Cambriolage} \mid \text{JeanAppelle} = \text{true}, \text{MarieAppelle} = \text{true})$
 $= \langle 0.287, 0.716 \rangle$
- Comment fait-on un tel calcul?
 - ◆ **inférence exacte** (prohibitif)
 - » par énumération
 - » élimination de variables
 - ◆ **inférence approximative par échantillonnage** avec les méthodes Monte-Carlo (plus efficace)
 - » échantillonnage direct
 - » échantillonnage par chaînes de Markov



Rappel de notions de base en probabilités

- $\mathbf{P}(X,Z) = \mathbf{P}(X|Z) \mathbf{P}(Z)$
- $\mathbf{P}(Z,X) = \mathbf{P}(Z|X) \mathbf{P}(X)$

- On en déduit
 - ◆ $\mathbf{P}(X|Z) = \mathbf{P}(X,Z) / \mathbf{P}(Z)$
 - ◆ $\mathbf{P}(X|Z) = \mathbf{P}(Z|X) \mathbf{P}(X) / \mathbf{P}(Z)$ (règle de Bayes)
- **Marginalisation:** si on a une distribution conjointe $\mathbf{P}(Z,Y)$ on peut calculer la distribution $\mathbf{P}(Z)$ par la somme des probabilités pour toutes les valeurs possibles de Y : $\mathbf{P}(Z) = \sum_y \mathbf{P}(Z, Y = y)$
- Si on a une distribution conditionnelle $\mathbf{P}(Z|Y)$: $\mathbf{P}(Z) = \sum_y \mathbf{P}(Z | Y = y) \mathbf{P}(Y = y)$
- $\mathbf{P}(Z)$ peut donc être considéré comme un facteur α

Rappel de notions de base en probabilités

- Ceci nous donne
 - ◆ $\mathbf{P}(X|Z) = \alpha \mathbf{P}(X,Z)$
 - ◆ α est une constante de normalisation pour s'assurer que la somme des probabilités de la distribution $\mathbf{P}(X,Z)$ soit égale à 1
- De manière générale, soit
 - ◆ X l'ensemble de variables pour laquelle on fait la requête
 - ◆ E les variables d'observation
 - ◆ Y les variables cachées (qui ne sont pas observées)
 - ◆ e les valeurs observées pour les variables dans E
- $\mathbf{P}(X|E=e) = \alpha \mathbf{P}(X,E=e) = \alpha \sum_y \mathbf{P}(X, E=e, Y=y)$
- Noté aussi $\mathbf{P}(X|e) = \alpha \sum_y \mathbf{P}(X, e, y)$

Inférence par énumération

- On a vu que: $\mathbf{P}(X|e) = \alpha \sum_y \mathbf{P}(X, e, y)$
- On a vu aussi que selon la sémantique d'un RB
$$\mathbf{P}(X_1, \dots, X_n) = \prod_{i=1}^n \mathbf{P}(X_i | \text{Parents}(X_i))$$
- Les termes $\mathbf{P}(X, e, y)$ peuvent donc s'écrire comme le produit des probabilités conditionnelles du réseau
- En d'autres termes, on peut calculer la réponse à une requête $\mathbf{P}(X|e)$ dans un RB, simplement en calculant les sommes des produits des probabilités conditionnelles du RB


Inférence par énumération

```
function ENUMERATION-ASK( $X, e, bn$ ) returns a distribution over  $X$   
  inputs:  $X$ , the query variable  
            $e$ , observed values for variables  $E$   
            $bn$ , a Bayes net with variables  $\{X\} \cup E \cup Y$  /*  $Y =$  hidden variables */  
  
   $Q(X) \leftarrow$  a distribution over  $X$ , initially empty  
  for each value  $x_i$  of  $X$  do  
     $Q(x_i) \leftarrow$  ENUMERATE-ALL( $bn.VARS, e_{x_i}$ )  
    where  $e_{x_i}$  is  $e$  extended with  $X = x_i$   
  return NORMALIZE( $Q(X)$ )
```

```
function ENUMERATE-ALL( $vars, e$ ) returns a real number  
  if EMPTY?( $vars$ ) then return 1.0  
   $Y \leftarrow$  FIRST( $vars$ )  
  if  $Y$  has value  $y$  in  $e$   
    then return  $P(y \mid parents(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e$ )  
    else return  $\sum_y P(y \mid parents(Y)) \times$  ENUMERATE-ALL(REST( $vars$ ),  $e_y$ )  
    where  $e_y$  is  $e$  extended with  $Y = y$ 
```

Exemple

- $P(\text{Cambriolage} \mid \text{JeanAppelle} = \text{true}, \text{MarieAppelle} = \text{true})$
- Noté $P(C \mid j, m)$
- Les variables cachées sont *Séisme* et *Alarme*
 - ◆ $P(C \mid j, m) = \alpha \sum_{s,a} P(C, s, a, j, m)$
- Note:
 - ◆ s et a prennent 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 $C = true$

$$P(c | j, m)$$

$$= \alpha \sum_{s,a} P(c) P(s) P(a|c,s) P(j|a) P(m|a)$$

$$= \alpha (0.001*0.002*0.95*0.90*0.70+$$

$$0.001*0.998*0.94*0.90*0.70+$$

$$0.001*0.002*0.05*0.05*0.01+$$

$$0.001*0.998*0.06*0.05*0.01)$$

$$= \alpha (0.00059224)$$

- Et $C = false$


$$P(\neg c | j, m)$$

$$= \alpha \sum_{s,a} P(\neg c) P(s) P(a | \neg c, s) P(j|a) P(m|a)$$

$$= \alpha (0.0014919)$$


$$\alpha = 1/(0.00059224 + 0.0014919)$$

- Donc, $P(C | j, m) = \langle 0.284, 0.716 \rangle$



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

Inférence par échantillonnage direct

- Simuler des observations complètes du RB
- Estimer les distributions de probabilités à partir de la fréquence des observations échantillonnées

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

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

- 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

Méthode de rejet

```
function PRIOR-SAMPLE(bn) returns an event sampled from the prior specified by bn  
  inputs: bn, a Bayesian network specifying joint distribution  $P(X_1, \dots, X_n)$   
  
   $x \leftarrow$  an event with  $n$  elements  
  foreach variable  $X_i$  in  $X_1, \dots, X_n$  do  
     $x[i] \leftarrow$  a random sample from  $P(X_i \mid \text{parents}(X_i))$   
  return  $x$ 
```

```
function REJECTION-SAMPLING( $X, e, bn, N$ ) returns an estimate of  $P(X \mid e)$   
  inputs:  $X$ , the query variable  
          $e$ , observed values for variables  $E$   
         bn, a Bayesian network  
          $N$ , the total number of samples to be generated  
  local variables:  $\mathbf{N}$ , a vector of counts for each value of  $X$ , initially zero  
  
  for  $j = 1$  to  $N$  do  
     $x \leftarrow$  PRIOR-SAMPLE(bn)  
    if  $x$  is consistent with  $e$  then  
       $\mathbf{N}[x] \leftarrow \mathbf{N}[x] + 1$  where  $x$  is the value of  $X$  in  $x$   
  return NORMALIZE( $\mathbf{N}$ )
```

Exemple 1: Évaluation par énumérations

Requête:

Calculer $P(T=true | F=false, M=true)$

Variables connues:


$F = false$

$M = true$

Variables inconnues:

H

O



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

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	T	$0.0 * 0.6 * 0.5$	0
T	F	$1.0 * 0.4 * 0.5$	0.20
T	T	$1.0 * 0.6 * 1.0$	0.60
TOTAL			0.80

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

Exemple 2: Évaluation par énumérations

Requête:

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

Variables connues:


$M = true$

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	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

Exemple 2: Échantillonnage direct



Requête:

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

Variables connues:


$M = true$

Variables inconnues:

H

O

F




	F	H	O	T
#	rand() $<$ 0.2	rand() $<$ P(H F,M)	rand() $<$ 0.6	rand() $<$ 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

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

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

Types d'interrogations d'un RB

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



Apprentissage dans 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 automatique
- 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 automatique.

Diagrammes d'influence

- Un **diagramme d'influence** (DI) est une extension d'un RB avec en plus des **nœuds de décision** et des **nœuds d'utilité**
 - ◆ les nœuds habituels d'un RB sont appelés des **nœuds chance**
 - ◆ 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 chance influencés par les actions
- Ainsi on peut modéliser des prises de décision simples
 - ◆ pour des décisions complexes (séquentielles), les processus de décision markoviens sont généralement préférables
- Les diagrammes d'influence sont aussi appelés réseaux de décision (*decision networks*)

Exemple

Prendre / Ne pas prendre

Parapluie

TrainerParapluie

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

Bonheur

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

<i>pluvieux</i>	$\neg \text{pluvieux}$
.4	.6

Temps

Prévision

<i>Temps</i>	<i>Prévision</i>	$P(P \mid T)$
<i>pluvieux</i>	<i>ensoleillé</i>	.3
<i>pluvieux</i>	<i>pluvieux</i>	.7
$\neg \text{pluvieux}$	<i>ensoleillé</i>	.8
$\neg \text{pluvieux}$	<i>pluvieux</i>	.2

Évaluation des diagrammes d'influence

- Mettre à jour les variables d'observation
- Pour chaque valeur possible d'un nœud décision
 - ◆ change le nœud décision pour lui donner cette valeur
 - ◆ calcule les probabilités a posteriori des parents des nœuds utilités (en utilisant un algorithme d'inférence standard pour les RB)
 - ◆ calcule l'utilité espérée résultante pour l'action
- Retourne l'action avec la plus grande utilité

- Pour en savoir plus: section 16.5

Valeur de l'information

- Parfois un agent est amené à prendre des décisions sans posséder toute l'information
- Un aspect important de la prise de décision est de déterminer les questions à poser pour chercher de l'information (pour obtenir des observations $E=e$)
- La valeur d'une information pour une action dépend de deux choses:
 - ◆ est-ce que l'obtention d'une observation particulière $E=e$ augmenterait grandement notre utilité espérée
 - ◆ est-ce que cette observation est vraisemblable
- Les inférences sur les DI permettent de déterminer les questions qui apportent le plus d'information, pour chaque action
- Pour en savoir plus: section 16.6

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

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