

Raisonnement Incertain

Boi Faltings

Laboratoire d'Intelligence Artificielle
`boi.faltings@epfl.ch`
`http://moodle.epfl.ch/`

Limites de la logique

Le monde ne suit pas exactement la logique:

- informations insuffisantes.
- imprécision de la modélisation.
- conclusions disjonctives non modélisable par des clauses de Horn.

⇒ le raisonnement est *incertain*.

Représentation de l'Incertain

Principe:

associer à chaque proposition une représentation numérique de l'incertitude: plausibilité.

Raisonnement *Bayésien*:

- la plausibilité tient compte de l'ensemble des évidences.

⇒ mise à jour pendant le raisonnement:

plausibilité à-priori ⇒ plausibilité à-posteriori.

Desiderata

- Associer une plausibilité à chaque prémisse.
- Pour chaque déduction, calculer la plausibilité de la conclusion sur la base des plausibilités des prémisses et des règles.
- Nécessite que la plausibilité doit être indépendante de sa dérivation.

Formalismes pour l'incertitude

- Logique floue:
facile à appliquer mais sans base théorique solide.
- Raisonnement probabiliste:
très bien fondée, mais difficile à appliquer.
- Réseaux Bayesiens: facile à appliquer et théoriquement bien fondées, mais applicables uniquement dans une interprétation *causale*.

Exemple: système d'alarme

- 3 détecteurs: M(ouvement), E(ntrée), V(itre).
- Déclenchées soit par le propriétaire soit par un cambrioleur.
- On aimerait trouver une fonction d'alarme qui détecte les cambrioleurs, mais pas les propriétaires.

Modélisation avec des facteurs de certitude

$$A \Rightarrow B : CF(B) = CF(A) * CF(\text{R\`egle})$$

$M = \text{"D\`etecteur de mouvement"}, CF = 1.0$

$R1: M \Rightarrow C = \text{"Cambrioleur pr\`esent"}, CF=0.1$

$R2: M \Rightarrow P = \text{"Proprietaire pr\`esent"}, CF=0.9$

\Rightarrow

$C, CF = 0.1$

$P, CF = 0.9$

Lacune 1: influence du contexte

- Supposons que le propriétaire est enregistré à un autre endroit.
 $\Rightarrow \neg P$ avec certitude.
- \Rightarrow seul un cambrioleur peut déclencher le détecteur:
 $M \Rightarrow C$ avec $CF \gg 0.1$ (par exemple, 0.99).
- Il faut modéliser l'interdépendence de P et C !

Lacune 2: chainages inadmissibles

- Supposons que nous savons qu'un cambrioleur est présent.
⇒ le détecteur de mouvement sera sûrement déclenché.
⇒ le propriétaire est également présent, par la règle *R2*!
- Problème: nous avons négligé *l'interdépendance*: les cas où le détecteur est déclenché par le cambrioleur est justement pas celui où il est déclenché par le propriétaire!

Logique probabiliste

Caractériser l'incertitude par la probabilité:

$p(A)$ = probabilité que la proposition A est vraie

$p(\neg A) = 1 - p(A)$ = probabilité que A est fausse

A devient une variable aléatoire avec valeurs $\{\text{vrai}, \text{faux}\}$:

- $P(A)$ = distribution $[p(A), p(\neg A)]$.
- Majuscule = distribution, minuscule = probabilité.
- $P(A, B) = [p(A, B), p(A, \neg B), p(\neg A, B), p(\neg A, \neg B)]$.
- $P(X_1, X_2, \dots, X_n) = [p(X_1, \dots, X_n), p(\neg X_1, \dots, X_n) \dots]$
(2^n valeurs).
- $p(X|Y) = p(X, Y)/p(Y)$ = probabilité que X est vrai étant donnée que Y est également vrai
- $p(X|Y) + p(\neg X|Y) = 1$
(mais $p(X|Y) + p(X|\neg Y)$ n'est pas toujours $= 1$)

Signification de la probabilité

- normalement, probabilité \simeq fréquence.
- mais le raisonnement n'a lieu qu'une seule fois.
- Probabilité \simeq lotterie:
$$p(A) = x \Leftrightarrow \text{dans un pari qui paie 1 Fr. si } A \text{ est vrai, je suis prêt à mettre } \leq x \text{ Fr.}$$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postériori
C	$p_0(C) = 0.01$		

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$
P	$p_0(P) = 0.5$		

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$
P	$p_0(P) = 0.5$	M	$p(P M) = 0.95$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$
P	$p_0(P) = 0.5$	M	$p(P M) = 0.95$
		$\neg M$	$p(P \neg M) = 0.15$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$
P	$p_0(P) = 0.5$	M	$p(P M) = 0.95$
		$\neg M$	$p(P \neg M) = 0.15$
	$p_0(P) = 0.01$	M	$p(P M) = 0.019$
		$\neg M$	$p(P \neg M) = 0.003$

Raisonnement Bayésien

Observation \Rightarrow la probabilité attribuée à une proposition change:

Proposition	Prob. à priori	Observation	Prob. à postérieure
C	$p_0(C) = 0.01$	M	$p(C M) = 0.18$
		$\neg M$	$p(C \neg M) = 0.0036$
P	$p_0(P) = 0.5$	M	$p(P M) = 0.95$
		$\neg M$	$p(P \neg M) = 0.15$
	$p_0(P) = 0.01$	M	$p(P M) = 0.019$
		$\neg M$	$p(P \neg M) = 0.003$

Règle de Bayes:

$$p(P|M) = p_0(P)p(M|P)/p(M)$$

$p(M|P)/p(M)$ caractérise l'incertitude de l'inférence.

Inférence probabiliste

Déduction:

$$p(M), \text{ règle } M \Rightarrow C$$

Probabilité à-posteriori $p(C)$ se calcule comme suit:

$$p(C) = p(C|M) \cdot p(M) + p(C|\neg M)(1 - p(M))$$

où $p(M)$ caractérise la certitude de la condition et

$$p(C|M) = p(C, M)/p(M) = p_0(C)p(M|C)/p(M)$$

ou $p(M|C)/p(M)$ caractérise l'incertitude de la règle.

Contre-factuels

Différence par rapport aux CF:
le calcul prend en compte $p(C|\neg M)$

Permet de modéliser la probabilité à-priori:

- élevée: $p(P|\neg M)$ est élevée, P reste probable même si M n'est pas vrai.
- faible: $p(C|\neg M)$ est petit, alors il faut que M soit assez certain pour rendre C une conclusion probable.

Chaînage des inférences

Exemple 1:

$P(\text{proprietaire}) \Rightarrow M(\text{mouvement}) \Rightarrow A(\text{larme})$

Chaînage des inférences

Exemple 1:

$P(\text{propriétaire}) \Rightarrow M(\text{ouvrement}) \Rightarrow A(\text{larme})$

- $P(P) = [0.9, 0.1]$,
 $P(M|P) = [0.84, 0.16]$,
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$

Chaînage des inférences

Exemple 1:

$P(\text{propriétaire}) \Rightarrow M(\text{ouvement}) \Rightarrow A(\text{larme})$

- $P(P) = [0.9, 0.1]$,
 $P(M|P) = [0.84, 0.16]$,
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$
- $P(A|M) = [1, 0]$,
 $P(A|\neg M) = [0.01, 0.99]$
 $\Rightarrow p(A) = 0.762 \cdot 1 + 0.238 \cdot 0.01 = 0.764$

Chaînage des inférences

Exemple 1:

$P(\text{proprietaire}) \Rightarrow M(\text{ouvement}) \Rightarrow A(\text{larme})$

- $P(P) = [0.9, 0.1]$,
 $P(M|P) = [0.84, 0.16]$,
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$
- $P(A|M) = [1, 0]$,
 $P(A|\neg M) = [0.01, 0.99]$
 $\Rightarrow p(A) = 0.762 \cdot 1 + 0.238 \cdot 0.01 = 0.764$
- inférence correcte.

Chaînage des inférences

Exemple 2:

$P(\text{proprietaire}) \Rightarrow M(\text{mouvement}) \Rightarrow C(\text{ambrieur})$

Chaînage des inférences

Exemple 2:

$P(\text{propriétaire}) \Rightarrow M(\text{ouvement}) \Rightarrow C(\text{ambrioleur})$

- $P(P) = [0.9, 0.1],$
 $P(M|P) = [0.84, 0.16],$
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$

Chaînage des inférences

Exemple 2:

$P(\text{propriétaire}) \Rightarrow M(\text{ouvement}) \Rightarrow C(\text{ambrieur})$

- $P(P) = [0.9, 0.1]$,
 $P(M|P) = [0.84, 0.16]$,
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$
- $P(C|M) = [0.18, 0.82]$,
 $P(C|\neg M) = [0.0036, 0.99]$
 $\Rightarrow p(C) = 0.762 \cdot 0.18 + 0.238 \cdot 0.0036 \simeq 0.138$

Chaînage des inférences

Exemple 2:

$P(\text{roprietaire}) \Rightarrow M(\text{ouvement}) \Rightarrow C(\text{ambrioleur})$

- $P(P) = [0.9, 0.1]$,
 $P(M|P) = [0.84, 0.16]$,
 $P(M|\neg P) = [0.06, 0.94]$
 $\Rightarrow p(M) = 0.9 \cdot 0.84 + 0.1 \cdot 0.06 = 0.762$
- $P(C|M) = [0.18, 0.82]$,
 $P(C|\neg M) = [0.0036, 0.99]$
 $\Rightarrow p(C) = 0.762 \cdot 0.18 + 0.238 \cdot 0.0036 \simeq 0.138$
- pas juste: la probabilité de C ne devrait pas augmenter (prob. à priori = 0.01).

Exemple 2 (suite)

$$P(C, M|P) \neq p(C|M)P(M|P)!$$

Calcul correct tient compte des dépendances entre P, M et C:

$$\begin{aligned}
 p(C) &= \underbrace{p(C|M, P)}_{=0} \underbrace{p(M, P)}_{=0.76} \\
 &\quad + \underbrace{p(C|\neg M, P)}_{=0} \underbrace{p(\neg M, P)}_{=0.14} \\
 &\quad + \underbrace{p(C|M, \neg P)}_{=0.99} \underbrace{p(M, \neg P)}_{=0.006} \\
 &\quad + \underbrace{p(C|\neg M, \neg P)}_{=0.01} \underbrace{p(\neg M, \neg P)}_{=0.094} \\
 &= 0.9 \cdot 0.006 + 0.01 \cdot 0.094 = 0.00634
 \end{aligned}$$

Complexité

Pour être sur de faire le bon calcul, on devrait tenir compte des dépendances partout.

Exemple:

- 20 propositions (variables aléatoires) V_1, \dots, V_{20}
- calculer $p(X)$ demande la distribution $P(X|V_1, \dots, V_{20})$
 $P(X|V_1, \dots, V_{20}) = \{p(X|V_1, \dots, V_{20}), p(X|\neg V_1, \dots, V_{20}), \dots\}$
- $\Rightarrow 2^{20} \approx 1'000'000$ valeurs!

Q: Comment peut-on réduire les dépendances?

R: En se limitant aux *causes* directes.

Causalité

- $P(\text{propriétaire})$ est une cause de $M(\text{ouvement})$, et
- $M(\text{ouvement})$ est une cause de $A(\text{larme})$;
- alors: $P \rightarrow M \rightarrow A$ permet la propagation locale des probabilités!

Causalité


- $P(\text{proprietaire})$ est une cause de $M(\text{ouvement})$, et
- $M(\text{ouvement})$ est une cause de $A(\text{larme})$;
- alors: $P \rightarrow M \rightarrow A$ permet la propagation locale des probabilités!

mais:

- $C(\text{ambrioleur})$ est une cause de $M(\text{ouvement})$, et
- $P(\text{proprietaire})$ est une cause de $M(\text{ouvement})$;
- mais si C explique déjà M , P n'est pas plus probable
- donc: $C \rightarrow M \leftarrow P$ n'admet pas la propagation locale des probabilités!

Graphe des influences causales


Formalisation comme graphe:



$x \rightarrow y$: x est une cause de y

Graphe des influences causales

Formalisation comme graphe:




$x \rightarrow y$: x est une cause de y

Possible: $C \vdash E \vdash A$

Graphe des influences causales

Formalisation comme graphe:



$x \rightarrow y$: x est une cause de y


Possible: $C \vdash E \vdash A$

Impossible: $C \vdash M \vdash P$, $E \vdash A \vdash V$, ...

M, E, A sont *bloquants*: destination de plusieurs flèches.

Ordre Causale

La causalité implique un *ordre* des variables:
 $cause > effet \Leftrightarrow parent > descendant$



noeud	parents	descendants
<i>P</i>	{}	{ <i>M</i> , <i>E</i> }
<i>C</i>	{}	{ <i>M</i> , <i>E</i> , <i>V</i> }
<i>M</i>	{ <i>P</i> , <i>C</i> }	{ <i>A</i> }
<i>E</i>	{ <i>P</i> , <i>C</i> }	{ <i>A</i> }
<i>V</i>	{ <i>C</i> }	{ <i>A</i> }
<i>A</i>	{ <i>M</i> , <i>E</i> , <i>V</i> }	{}

Prix de Turing

En 2012, le prix de Turing a été decerné à Judea Pearl (UCLA):



For fundamental contributions to artificial intelligence through the development of a calculus for probabilistic and causal reasoning.

que nous allons voir maintenant.

Indépendance conditionnelle



Indépendance de A et C :

$$p(C|A) = p(C|\neg A) = p(C)$$

n'est pas donnée à cause de l'influence à travers B .

Indépendance conditionnelle



Indépendance de A et C :

$$p(C|A) = p(C|\neg A) = p(C)$$

n'est pas donnée à cause de l'influence à travers B .

Par contre, nous pouvons profiter de l'indépendance *conditionnelle* de A et C étant donné B :

$$p(C|A, B) = p(C|\neg A, B) = p(C|B)$$

et de même pour $\neg B$.

Utilité pour l'inférence

Chaînage:

$$p(C|A) = p(C|A, B) \cdot p(B|A) + p(C|A, \neg B) \cdot p(\neg B|A)$$


A , C conditionnellement indépendants étant donné B :

$$\begin{aligned} p(C|A) &= p(C|B) \cdot p(B|A) + p(C|\neg B) \cdot (1 - p(B|A)) \\ &= \sum_{b=B, \neg B} p(C|b)p(b|A) \end{aligned}$$

\Rightarrow il suffit de connaître $P(C|B)$ et $P(B|A)$ au lieu de $P(C|A, B)$.
On appelle ce chaînage la *marginalisation* de B .

Descendants multiples

Les descendants multiples ne mettent pas en cause l'indépendance conditionnelle:




$P(A|B, C) = P(A|B)$, pas besoin de connaître distribution jointe!

Causes multiples \Rightarrow dépendance conditionnelle

Inverse de l'indépendance: A et C sont indépendants, mais deviennent dépendants si B est connu:

$$\begin{aligned} p(A|C) &= p(A|\neg C)(= p(A)) \\ p(A|B, C) &\neq p(A|B, \neg C) \end{aligned}$$

Vérifiée si A et C sont les causes d'un effet commun B :



Intuition: Si A explique déjà B , C devient moins probable.
 \Rightarrow il faut la distribution jointe: $p(B|A, C)$

Exemple

- A = Entrée
 B = Alarme
 C = Vitre
 - Normalement, aucune dépendence entre A et C .
 - Si B , alors A **et** C deviennent plus probable.
 - Si A est vrai, cela explique B et la probabilité de C redescend à son niveau antérieur.
- ⇒ dépendence entre A et C .
- ⇒ besoin de connaître $p(B|A, C)$.

Resumé des Structures

**cause
directe**




$P(B|A)$

**cause
indirecte**




$P(B|A)$
 $P(C|B)$

**cause
commune**




$P(B|A)$
 $P(C|A)$

**effet
commun**



$P(C|A, B)$


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, mais rien d'autre.
Quels calculs sont possibles (par chaînage):

- ① $p(D|A)$
- ② $p(A|C)$
- ③ $p(E|C)$


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, mais rien d'autre.
Quels calculs sont possibles (par chaînage):

- ① $p(D|A)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- ② $p(A|C)$
- ③ $p(E|C)$


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, mais rien d'autre.
Quels calculs sont possibles (par chaînage):

- ① $p(D|A)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- ② $p(A|C)$ non, car D est un noeud bloquant.
- ③ $p(E|C)$

Question




Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, mais rien d'autre.
Quels calculs sont possibles (par chaînage):

- 1 $p(D|A)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- 2 $p(A|C)$ non, car D est un noeud bloquant.
- 3 $p(E|C)$ oui, car $C \rightarrow D \rightarrow E$ est une chaîne causale.

Inférence abductive

- Inférence causes \vdash effets = *déduction*.
- Inférence des causes sur la base des effets = *abduction*.
- L'abduction est très courant: diagnostic, vision, apprentissage, etc.
- Nécessite l'inférence dans le sens inversé de la causalité.

Abduction Bayésienne




Par la règle de Bayes:

$$p(A|B) = \frac{p(A, B)}{p(B)} = \frac{p(B|A)p(A)}{p(B)} = \alpha p(B|A)p(A)$$

l'inférence dans le sens invers des arcs utilise:

- $p(B|A)$: vraisemblance ("likelihood") de B
- $p(A)$: probabilité à priori.
- $p(B)$: probabilité de l'observation B ; difficile à connaître et souvent exprimé comme facteur α

Déterminer $p(B)$



Par la règle de Bayes:

$$p(\neg A|B) = \frac{p(\neg A, B)}{p(B)} = \frac{p(B|\neg A)p(\neg A)}{p(B)}$$

Comme $p(A|B) + p(\neg A|B) = 1$:

$$p(B) = p(B|A)p(A) + p(B|\neg A)p(\neg A)$$

est obtenu par normalisation, et ainsi $\alpha = 1/p(B)$.

Chaînage de l'Abduction




$$\begin{aligned} p(A|C) &= \sum_{b=B, \neg B} p(A|b) \cdot p(b|C) \\ &= \sum_{b=B, \neg B} \frac{p(b|A)p(A)}{p(b)} \cdot \frac{p(C|b)p(b)}{p(C)} \\ &= \frac{p(A)}{p(C)} \sum_{b=B, \neg B} p(b|A) \cdot p(C|b) \end{aligned}$$

- ⇒ pas besoin de connaître $p(B)$!
- ⇒ déterminer $p(C)$ par normalisation.

Abduction avec plusieurs conséquences

Problème: il peut y avoir plusieurs effets d'une cause B, donc plusieurs chaînes qui partent de B.



$$\begin{aligned}
 p(B|A, C) &= \frac{1}{p(A, C)} p(A, B, C) \\
 &= \alpha p(A|B, C) \cdot p(B, C) \\
 &= \alpha p(A|B) \cdot p(C|B) \cdot p(B)
 \end{aligned}$$

(car A et C indépendants étant donné B)

En général, pour k conséquences Y_1, \dots, Y_k :

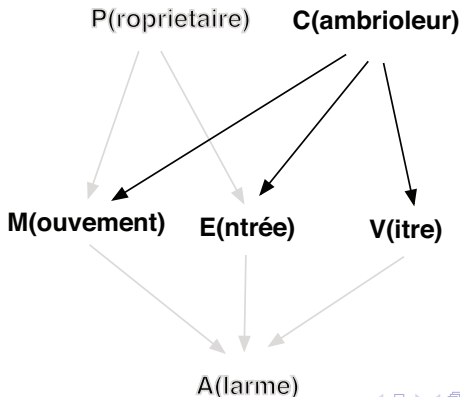
$$p(B|Y_1, \dots, Y_k) = \alpha p(B) \prod_{i=1}^k p(Y_i|B)$$

Exemple

Déclencher l'alarme si $p(C|obs) > p(P|obs)$.

Exemple: comparer $p(C|M, \neg E, V)$ et $p(P|M, \neg E, V)$.

Formalisation comme graphe (pour $p(C|M, \neg E, V)$):



Exemple

$$p(C|M, \neg E, V) = \alpha \underbrace{p(C)}_{=0.01} \underbrace{p(M|C)}_{=0.8} (1 - \underbrace{p(E|C)}_{=0.5}) \underbrace{p(V|C)}_{=0.5} = 2 \cdot 10^{-3} \alpha$$

et

$$p(P|M, \neg E, V) = \alpha \underbrace{p(P)}_{=0.5} \underbrace{p(M|P)}_{=0.9} (1 - \underbrace{p(E|P)}_{=0.99}) \underbrace{p(V|P)}_{=0.001} = 4.5 \cdot 10^{-6} \alpha$$

avec $\alpha = 1/p(M, \neg E, V)$

$p(C|M, \neg E, V) \gg p(P|M, \neg E, V)$: sonner l'alarme!

Pas besoin de calculer α

($\alpha = 473$, $p(C|M, \neg E, V) = 0.946$, $p(P|M, \neg E, V) = 0.000213$)

Système d'alarme Bayésien

Déclencher l'alarme uniquement quand:

- 1 il y a une indication (M , E ou V), et
- 2 C est plus probable que P comme la cause.

Pour vérifier la deuxième condition: comparer $p(C|\cdot)$ à $p(P|\cdot)$:
pas besoin de calculer α .

"Naive Bayes"

Souvent, on veut détecter une condition précise sur la base des plusieurs conséquences

Exemple: détecter si un mail est spam à partir de mots contenus dans un message

⇒ pour chaque mot $m \in M$, mesurer $p(m|spam)$ sur un échantillon de messages spam

Trier les messages par


$$\alpha p(spam) \prod_{m \in M} p(m|spam)$$

$\alpha, p(spam)$ sont toujours identiques ⇒

$$\prod_{m \in M} p(m|spam)$$

est suffisant comme critère.


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, et aussi $p(X)$. Quels calculs sont possibles:

- ① $p(A|D)$
- ② $p(D|E, F)$
- ③ $p(B|C, E)$


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, et aussi $p(X)$. Quels calculs sont possibles:

- 1 $p(A|D)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- 2 $p(D|E, F)$
- 3 $p(B|C, E)$


Question



Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, et aussi $p(X)$. Quels calculs sont possibles:

- ① $p(A|D)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- ② $p(D|E, F)$ oui, car E et F sont effets indépendants de D .
- ③ $p(B|C, E)$

Question

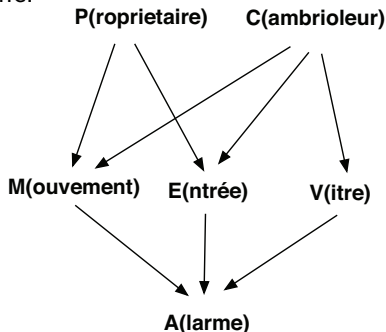


Pour chaque arc $X \rightarrow Y$, on connaît $p(Y|X)$, et aussi $p(X)$. Quels calculs sont possibles:

- ❶ $p(A|D)$ oui, car $A \rightarrow B \rightarrow D$ est une chaîne causale.
- ❷ $p(D|E, F)$ oui, car E et F sont effets indépendants de D .
- ❸ $p(B|C, E)$ non, car D est un noeud bloquant.

Vérifier la performance

Système d'alarme Bayésien: chaque capteur a une influence causale sur l'alarme.



Comment calculer la probabilité de détection $p(A|C)$ d'une alarme correct (et $p(A|P)$ d'une fausse alarme)?

Inférence avec chemins multiples

- 3 chemins: $C \rightarrow M \rightarrow A$, $C \rightarrow E \rightarrow A$, $C \rightarrow V \rightarrow A$.
- d -séparateur de x et y : ensemble de noeuds S qui coupent toutes les chemins d'inférence entre x et y .
- d -séparateur rend x et y conditionnellement indépendants étant donnée S :


$$Pr(y|S) = Pr(y|S, x)$$

et donc

$$p(y, S|x) = p(y|S, x)p(S|x) = p(y|S)p(S|x)$$

- calculer $p(y|x)$ de $p(y, S|x)$ en marginalisant sur toutes les combinaisons de valeurs de l'ensemble S .

Obtenir $P(A|C)$



- $S = \{M, E, V\}$ est d -séparateur entre $x = C$ et $y = A$.
- calculer $p(A|M, E, V)$ et $p(M, E, V|C)$
 - $P(A|M, E, V)$ doit être connue: complexe!
 - $p(M, E, V|C) = p(M|C)p(E|C)p(V|C)$ peut être dérivée.

Complexité de l'inférence

En cas de chemins multiples:

- l'inférence doit considérer toutes les combinaisons de causes dans un d-separateur.

⇒ complexité exponentielle dans sa taille.

- donné par la *largeur* de l'ordre causal (propriété du graphe).
- complexité exponentielle non seulement en temps, mais aussi en mémoire!

⇒ inférence exacte souvent pas faisable sauf si le graphe est proche d'un arbre.


Résolution stochastique

Echantillonnage: trouver les probabilités par simulation.

Pour estimer $p(A|C)$:

- ① ordonner les noeuds par ordre causale.
- ② générer des instances d'états du réseau en commençant par les noeuds sans parents, et suivant les chaînes causales:
 - générer une valeur pour chaque descendant X suivant la distribution de probabilité dès que toutes les parents ont obtenus une valeur.
 - selon la distribution $P(X|parents)$ du réseau.
 - itérer jusqu'à ce que toutes les variables ont une valeur.
- ③ enregistrer la fréquence de paires de valeurs pour C et A jusqu'à ce qu'un nombre suffisant de valeurs ont été obtenus.
- ④ estimer $p(A, C)$ et donc $p(A|C) = p(A, C)/p(C)$ par la fréquence observée.

Exemple



noeud	parents	descendants
P	$\{\}$	$\{M, E\}$
C	$\{\}$	$\{M, E, V\}$
M	$\{P, C\}$	$\{A\}$
E	$\{P, C\}$	$\{A\}$
V	$\{C\}$	$\{A\}$
A	$\{M, E, V\}$	$\{\}$

- Générer d'abord P et C selon leur distribution à priori.
- Ensuite M , E et V suivant les probabilités conditionnelles.
- Ensuite A par simulation du raisonnement Bayésien.

Simulation

	P	C	(M,E,V)	A
1	1	0	(1,0,0)	1
2	0	0	(0,0,0)	0
...				
50	0	1	(1,0,1)	1
...				

Estimations des probabilités par la fréquence, par exemple:

$$\Rightarrow p(A|C) = \frac{\text{count}(A, C)}{\text{count}(C)} = \frac{4}{5} = 0.8$$

Faiblesses de l'échantillonnage

- Les états avec faible probabilité (ex: présence du cambrioleur) ont une fréquence très faible.
- Si on s'intéresse à $P(A|C)$, alors simuler que des situations où C est vrai.
- Sous-pondérer les échantillons à haute probabilité, et corriger les fréquences à la fin.
- Utiliser Gibbs sampling: le prochain échantillon est obtenu par modification du précédent (Markov Chain Monte Carlo).

Exemple

	P	C	(M,E,V)	A
1	1	1	(1,0,0)	0
2	0	1	(1,0,0)	1
3	0	1	(1,0,1)	1
4	0	1	(1,0,0)	0
5	1	1	(1,1,1)	1
...				
50	0	1	(1,0,1)	1
...				

Estimations des probabilités par la fréquence, par exemple:

$$\Rightarrow p(A|C) = \frac{\text{count}(A, C)}{\text{count}(C)} = \frac{42}{50} = 0.84$$

Echantillonnage selon Gibbs

- Initialiser les variables de façon arbitraire.
- Fixer les variables connues, pour tous les autres variables x_i itérer:
 - 1 sélectionner une variable x_i .
 - 2 attribuer une nouvelle valeur selon la distribution $P(x_i | \text{parents}, \text{descendants})$
 - 3 ajouter l'échantillon aux statistiques.

$$P(x_i | \text{parents}, \text{descendants}) = P(x_i | \text{parents}) \prod_{Y_i \in \text{descendants}(X_i)} P(y_i | \text{parents}(Y_i))$$

Parfois en 2 phases: stabilisation des distributions, et échantillonnage par la suite.

Utilisation pour l'inférence

- Application pour l'inférence directe peut être trop inefficace.
- Peut aussi s'utiliser pour "compiler" certains relations à partir du réseau causal.
- Exemple pour un diagnostic médical: extraire la distribution conditionnelle $p(\text{maladie}|\text{symptômes visibles})$ sans passer par toute la chaîne causale.
- En général: élimination de variables cachées et de cycles pour permettre l'inférence efficace.

Les réseaux Bayesiens en pratique

Utilisés dans des systèmes experts pour:

- diagnostic médical
- diagnostic de réacteurs d'avion
- preuve que fumer \Rightarrow cancer

Fondamental pour des voitures autonomes, filtres spam, etc.

Application: Diagnostic medical par Réseaux Bayesiens

- Promedas: système général pour le diagnostic médical.
- Utilisé comme aide aux medecins dans des hopitaux aux Pays-Bas.
- Application pour un domaine très général.
- Améliore souvent le diagnostic du medecin.

Résumé

- Facteurs de certitude/logique floue: simple à implémenter, mais ne tiennent pas compte des dépendances.
- Raisonnement probabiliste: résultats corrects, mais problèmes de dépendances.
- Graphes causales pour l'identification des dépendances.
- Limitation: graphes sans chemins multiples!
- Méthode générale: simulation et échantillonnage.