

L'incertain

1

Plan

- Agir dans l'incertain;
- Probabilités;
- Distributions de probabilités jointes;
- Indépendance.

2

Agir dans l'incertitude

- Les approches logiques que l'on a vues aux chapitres précédents permettent aux agents s'ils ont suffisamment d'information de construire des plans qui leur assurent d'atteindre leur but.
- En réalité, les agents n'ont presque jamais toutes les informations relatives à leur environnement.
- Ils doivent donc agir dans l'incertain.

3

Exemple de décision dans l'incertain

- Soit A_t , le plan qui me permet d'être à mon spectacle au centre ville, t minutes avant le début du concert. Est-ce que A_t me permet d'arriver à temps ?
- **Problèmes :**
 - Observabilité partielle (état des routes, plans des autres agents, etc.);
 - Senseurs bruités (Pluie/Neige/orage pas certains);
 - Les effets des actions sont incertains (crevaison);
 - Immense complexité quant à la modélisation et à la prédiction du trafic routier.

4

Exemple de décision dans l'incertain

- Une approche purement logique
 - risque de donner une réponse fausse : Ex : A_{25} fera que j'arrive à temps.
 - m'amène à des conclusions trop légères pour une prise de décision: Ex: A_{25} fera que j'arrive à temps si pas d'accidents sur le pont, s'il ne pleut pas, si mes pneus restent intacts, etc.
- **Remarque :** A_{120} (soit 2h avant) pourrait raisonnablement solutionner mon problème, mais je dois rester 2h à attendre (grande perte de temps).

5

Décision rationnelle

- Malgré l'incertitude, on doit trouver un plan permettant à l'agent de faire les « bonnes actions».
 - *Parmi tous les plans, l'agent doit choisir celui qui devrait maximiser la mesure de performance de l'agent, selon les informations qu'il a de son environnement.*

6

Décision rationnelle

- Pour notre exemple, la mesure de performance comprend:
 - arriver à temps,
 - ne pas trop attendre,
 - de pas avoir de contravention d'excès de vitesse.
- L'agent n'a pas les informations nécessaires pour garantir tous ces points.
- Mais, il peut avoir un **degré de croyance** qu'il va les atteindre.
- La décision rationnelle dépend donc:
 - de l'importance relative des différents buts,
 - de la probabilité de les atteindre,
 - du degré auquel ils seront atteints.

7

Décision rationnelle

- Pour notre exemple, la mesure de performance comprend :
 - arriver à temps,
 - ne pas trop attendre,
 - de pas avoir de contravention d'excès de vitesse.
- D'autres plans comme A_{120} pourrait augmenter les chances d'arriver à temps, mais ça va aussi augmenter les chance d'attendre.

8

Gérer les connaissances incertaines

- Exemple de diagnostique dentaire.
 - $\forall p \text{ Symptome}(p, \text{MalDeDent}) \Rightarrow \text{Maladie}(p, \text{Carie})$
 - La règle est fausse, parce qu'on peut avoir mal aux dents sans avoir de carie. Pour la rendre vrai, il faudrait lister toutes les causes possibles d'un mal de dent.
 - La règle ne fonctionne pas plus à l'envers, parce qu'on peut avoir une carie sans avoir un mal de dent.
 - $\forall p \text{ Maladie}(p, \text{Carie}) \Rightarrow \text{Symptome}(p, \text{MalDeDent})$

9

Méthodes pour gérer l'incertain

- **Logique des défauts** ou logiques non-monotones
 - Supposons que ma voiture n'a pas de crevaison.
 - Supposons que A_{25} fera l'affaire à moins d'être contredit par une évidence.
 - Questions :
 - Quelles suppositions sont raisonnables ?
 - Comment gérer les contradictions ?

10

Logique des défauts (suite)

- Logique des défauts = logique classique + règles de défauts
- Règles de défaut :
 - ψ : prérequis
 - ϕ_i : justification
 - γ : conséquent

$$\frac{\psi : \phi_1, \dots, \phi_n}{\gamma}$$

« si ψ dérivable et pour tout i , ϕ_i est non dérivable, alors dériver γ »

Brahim Chaib-draa Avril 2002

Méthodes pour gérer l'incertain

- **Utilisation de règles avec facteurs de certitudes**
 - $A_{25} \mapsto_{0,3}$ m'amènera à l'aéroport à temps
 - $Arrosage \mapsto_{0,99}$ GazonHumide
 - $GazonHumide \mapsto_{0,75}$ Pluie
 - Problème: Comment traiter les combinaisons ?
 - $Arrosage \mapsto_{\gamma} Pluie$

12

Méthodes pour gérer l'incertain

- **Probabilités**
 - Étant donné l'évidence disponible (météo à la radio, état des parkings, états de la circulation, etc.), A_{25} fera que j'arrive à temps avec une probabilité de 0.04.
- **Logique floue**
 - Gazon humide est **vrai à 70%**, donc ça gère un **degré de vérité** et non une croyance (= l'incertain).

13

Problème de la logique de premier ordre

- **Paresse**: trop de travail d'énumérer l'ensemble complet des antécédents ou des conséquences afin d'assurer qu'une règle n'a pas d'exceptions. De plus, une telle règle serait trop difficile à utiliser.
- **Ignorance théorique**: Dans le cas du diagnostic médical par exemple, la médecine n'a pas de théorie complète.
- **Ignorance pratique**: même en connaissant toutes les règles, il peut y avoir incertitude. Par exemple, pour un patient donné, il se peut que tous les tests nécessaires n'aient pas été faits ou ne peuvent pas être faits.

14

Degré de croyance

- Peu importe la direction, un mal de dent et une carie ne constituent pas une conséquence logique ni dans un sens ni dans l'autre.

$$\forall p \text{ Symptome}(p, \text{MalDeDent}) \Rightarrow \text{Maladie}(p, \text{Carie})$$
$$\forall p \text{ Maladie}(p, \text{Carie}) \Rightarrow \text{Symptome}(p, \text{MalDeDent})$$

- Les connaissances de l'agent ne peuvent que lui donner un **degré de croyance**.
- La **théorie des probabilités** permet de gérer les degrés de croyance.

15

Degré de croyance

- Par exemple, on va dire que le patient a 80% de chance d'avoir une carie s'il a un mal de dent.
- Ce qui veut dire que l'on s'attend que parmi toutes les situations identiques (du point de vue des connaissances de l'agent) le patient va avoir une carie dans 80% des cas.

16

Probabilités

- 0 = faux
- 1 = vrai
-]0,1[= degré de croyance dans la vérité de l'énoncé
 - 0.8 = dans 80% des cas, l'énoncé est vrai.
- Important de faire la distinction avec degré de vérité.
 - 0.8 = 80% vrai (logique floue)
- Probabilité a priori ou inconditionnelle: probabilité avant l'évidence (la perception).
- Probabilité a posteriori ou conditionnelle: probabilité après l'évidence (la perception).

17

Théorie de l'utilité

- Même si A_{25} a 95% de chance de réussite, est-ce que c'est une décision rationnelle ?
 - Pas nécessairement, il pourrait y avoir d'autres plans avec une plus grande probabilité.
 - Si c'est vraiment vital d'être là à l'heure, on serait plus prêt à attendre, donc le plan A_{120} pourrait être une meilleure décision.
- Pour pouvoir prendre ce type de décisions, l'agent doit avoir des préférences sur les résultats possibles des plans.
- Pour raisonner sur les préférences, on va utiliser la théorie de l'utilité.

18

Théorie de l'utilité

- Tous les états ont un degré d'utilité.
- Les préférences peuvent être égoïstes ou altruistes.
- Permet de pondérer la désirabilité des buts et la chance de les atteindre.
- L'agent va raisonner en fonction de ses préférences:
 - Chaque état a un degré d'utilité pour un agent.
 - L'agent préfère les états avec un haut degré d'utilité.

19

Théorie de la décision

- Une action non déterministe A aura les résultats possibles suivants : $Result(a) = s'$.
- Avant l'exécution de a , l'agent assigne des probabilités à chaque état résultant (s' = état résultant et e = évidence) :

$$EU(a|e) = \sum_{s'} P(Result(a) = s' | a, e) U(s')$$

EU est l'utilité espérée de l'action a :

20

Théorie de la décision

- **Théorie de la décision = théorie des probabilités + théorie de l'utilité**
- Un agent est rationnel, si et seulement s'il choisit l'action qui donne la plus grande utilité anticipée, en moyenne, sur toutes les issues anticipées de l'action.

$$action = \arg \max_a EU(a|e)$$

- Ceci est appelé le **principe de l'utilité maximale attendue** (Maximum Expected Utility, MEU)

21

Structure d'un agent utilisant la théorie de la décision

function DT-AGENT(*percept*) **returns** an *action*
static: *belief-state*, probabilistic beliefs about the current state of the world
action, the agent's action

update *belief-state* based on *action* and *percept*
calculate outcome probabilities for actions,
 given action descriptions and current *belief-state*
select *action* with highest expected utility
 given probabilities of outcomes and utility information
return *action*

22

Variables aléatoires

- Une variable aléatoire réfère à une partie du monde dont le statut est initialement inconnu.
 - Ex: *Carie* (Est-ce que j'ai une carie ?)
- Les variables aléatoires ont un domaine de valeurs
 - Ex: le domaine de *Carie* est: (*vrai*, *faux*)
- Une proposition simple est d'attribuer une valeur à une variable aléatoire:
 - Ex: *Carie* = *vrai*

23

Types de variables aléatoires

- **Booléennes:** Leur domaine de valeur est: (*vrai*, *faux*)
 - On utilise souvent les abréviations suivantes:
 - *Carie* = true par *carie*; *important*
 - *Carie* = false par *~carie*
- **Discrètes:** Elles ont un domaine de valeur discret.
 - Ex: *Température* peut avoir comme domaine (*ensoleillé*, *pluvieux*, *nuageux*, *neige*).
 - Les valeurs du domaine doivent être mutuellement exclusives et exhaustives.
 - On peut utiliser *neige* comme abréviation à *Température* = *neige*

24

Types de variables aléatoires

- **Continues:** Leur domaine de valeur est composé de valeurs réelles.
 - Le domaine de valeur peut être tous les réels ou un sous ensemble comme l'intervalle $[0,1]$.
 - Ex: $X = 4.02$ signifie que la variable a la valeur exacte 4.02
 - Les propositions peuvent contenir des inégalités, comme $X < 4.02$.

25

Probabilité inconditionnelle

- **Définition:** degré de croyance en absence de toute autre information.
 - Ex: $P(\text{carie}) = P(\text{Carie} = \text{true}) = 0.1$, $P(\text{Température} = \text{Soleil}) = 0.7$
 - Attention: $\mathbf{P}(\text{Carie}) = \langle 0.1, 0.9 \rangle$
- Ces probabilités deviennent inutilisables si de nouvelles informations sont connues.
- **Distribution de probabilité:** un vecteur contenant toutes les probabilités pour chacune des assignations possibles.
 - Ex: $\mathbf{P}(\text{Température}) = (0.7, 0.2, 0.08, 0.02)$ pour (ensoleillé, pluvieux, nuageux, neige).

26

Distribution de probabilité jointe

- Représente les probabilités pour toutes les combinaisons de valeurs possibles.
 - Ex: $\mathbf{P}(\text{Température}, \text{Carie})$

		Température			
		Soleil	Pluie	Nuage	Neige
Carie	Vrai	0.144	0.02	0.016	0.02
	Faux	0.576	0.08	0.064	0.08

27

Probabilité conditionnelle

- **Définition:** degré de croyance lorsque certaines informations sont disponibles.
- **$P(A|B)$:** probabilité de A étant donné que tout ce que l'on sait est B.
 - Ex: $P(\text{Carie} | \text{MalDeDent}) = 0.8$

$$P(a|b) = \frac{P(a \wedge b)}{P(b)}, P(b) > 0$$

$$\left. \begin{array}{l} P(a \wedge b) = P(a|b)P(b) \\ P(a \wedge b) = P(b|a)P(a) \end{array} \right\} \text{R\`egle du produit}$$

28

Axiomes probabilistes

- Pour toutes propositions a et b :
 1. Toutes les probabilités sont entre 0 et 1.
 2. Les propositions vraies ont une probabilité de 1, les fausses de 0.
 3. La probabilité d'une disjonction est donnée par:

$$P(a \wedge b) = P(a) + P(b) - P(a \vee b)$$

29

Axiomes probabilistes (2)

- Pourquoi un agent ne pourrait pas avoir l'ensemble de croyances suivant qui enfreint l'axiome 3?

$$\begin{array}{l|l} P(a) = 0.4 & P(a \wedge b) = 0.0 \\ P(b) = 0.3 & P(a \vee b) = 0.3 \end{array}$$

- L'agent 1 affirme, mon degré de croyance sur a est 0.4 et L'agent 2 est libre de parier pour ou contre.
- **Théorème (de Finetti) :** si l'agent 1 exprime un ensemble de degrés de croyances qui *violent* les axiomes de la théorie des probabilités, Il existe une combinaison de paris de l'agent 2 qui *garantit* que l'agent 1 perde de l'argent à chaque fois.

On a donc intérêt à suivre les loi des probabilités

30

Inférence par énumération

- Utilise la distribution jointe complète pour inférer des probabilités.
- Exemple d'une distribution jointe complète :

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

31

Inférence par énumération

- Pour calculer la probabilité d'une proposition, il suffit d'additionner toutes les probabilités où la proposition est vraie.
- Ex: On peut aussi obtenir la probabilité inconditionnelle (probabilité marginale) d'une variable aléatoire.

$$P(\text{toothache}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$$

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

32

Inférence par énumération

- Ex:

$$P(\text{cavity} \vee \text{toothache}) = 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28$$

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

33

Inférence par énumération

- On peut aussi calculer des probabilités conditionnelles.

• Ex:

$$P(\neg cavity|toothache) = \frac{P(\neg cavity \wedge toothache)}{P(toothache)}$$

$$= \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4$$

	toothache		¬ toothache	
	catch	¬ catch	catch	¬ catch
cavity	.108	.012	.072	.008
¬ cavity	.016	.064	.144	.576

34

Normalisation

- Le dénominateur de l'équation précédente peut être vu comme une constante de normalisation (α).
- Ex: $P(\neg cavity|toothache) = \alpha P(\neg cavity \wedge toothache)$

et donc $\alpha = \frac{1}{P(toothache)}$ soit $\alpha = \frac{1}{0.2} = 5$

35

Normalisation

$$P(Cavity|toothache) = \alpha P(Cavity, toothache)$$

$$= \alpha [P(Cavity, toothache, catch) + P(Cavity, toothache, \neg catch)]$$

$$= \alpha [(0.108, 0.016) + (0.012, 0.064)] = \alpha (0.12, 0.08) = (0.6, 0.4)$$

- Idée générale: Calculer la distribution d'une variable en fixant les variables d'évidences (*Toothache*) et en effectuant une somme sur les variables cachées (*Catch*).

	toothache		¬ toothache	
	catch	¬ catch	catch	¬ catch
cavity	.108	.012	.072	.008
¬ cavity	.016	.064	.144	.576

36

Inférence utilisant des distributions conjointes complètes

Marginalisation ou sommation partielle : On peut écrire la règle de marginalisation générale suivante pour tout ensemble de variables Y et Z .

$$P(Y) = \sum_z P(Y, z)$$

La règle de conditionnement nous permet aussi d'écrire:

$$P(Y) = \sum_z P(Y|z)P(z)$$

Finalement, une requête du type $P(X|e)$ peut être évaluée comme suit:

$$P(X|e) = \alpha P(X, e) = \alpha \sum_y P(X, e, y)$$

37

Problèmes de l'inférence par énumération

- **Complexité de temps en $O(d^n)$** où n est le nombre de variables et d le nombre maximal de valeurs pour une variable.
- **Complexité en espace de $O(d^n)$** pour emmagasiner la table de distribution.
- **Très compliqué de trouver toutes les d^n valeurs pour remplir la table.**
- Pas vraiment applicable en pratique, mais c'est une base théorique pour d'éventuelles méthodes d'approximation.

38

Exercice

- À l'aide de la table de distribution jointe suivante, calculer :

- a. $P(\text{toothache})$
- b. $P(\text{Cavity})$
- c. $P(\text{Toothache}|\text{cavity})$
- d. $P(\text{Cavity}|\text{toothache} \vee \text{catch})$.

	toothache		~toothache	
	catch	~catch	catch	~catch
cavity	0.108	0.012	0.072	0.008
~cavity	0.016	0.064	0.144	0.576

39

Correction

13.8 The main point of this exercise is to understand the various notations of bold versus non-bold P , and uppercase versus lowercase variable names. The rest is easy, involving a small matter of addition.

a. This asks for the probability that *Toothache* is true.

$$P(\text{toothache}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$$

b. This asks for the vector of probability values for the random variable *Cavity*. It has two values, which we list in the order (*true*, *false*). First add up $0.108 + 0.012 + 0.072 + 0.008 = 0.2$. Then we have

$$P(\text{Cavity}) = (0.2, 0.8)$$

c. This asks for the vector of probability values for *Toothache*, given that *Cavity* is true.

$$P(\text{Toothache}|\text{cavity}) = ((.108 + .012)/0.2, (0.072 + 0.008)/0.2) = (0.6, 0.4)$$


d. This asks for the vector of probability values for *Cavity*, given that either *Toothache* or *Catch* is true. First compute $P(\text{toothache} \vee \text{catch}) = 0.108 + 0.012 + 0.016 + 0.064 + 0.072 + 0.144 = 0.416$. Then

$$P(\text{Cavity}|\text{toothache} \vee \text{catch}) = ((0.108 + 0.012 + 0.072)/0.416, (0.016 + 0.064 + 0.144)/0.416) = (0.4615, 0.5384)$$

40

Indépendance


- Deux variables aléatoires X et Y sont indépendantes si :
 - $P(X|Y) = P(X)$ ou $P(Y|X) = P(Y)$ ou $P(X, Y) = P(X)P(Y)$



41

Indépendance

- L'indépendance absolue est très puissante pour diminuer la complexité d'un problème.
 - Dans notre exemple, le nombre d'entrées dans la table est passé de 32 (4×2^3) à 12 ($4 + 2^3$).



- Toutefois, elle est rare en pratique.
- Quoi faire quand il y a trop de variables dépendantes ?

42

Règle de Bayes

- En partant de la règle du produit

$$P(a \wedge b) = P(a|b)P(b)$$

$$P(a \wedge b) = P(b|a)P(a)$$

- On peut obtenir la règle suivante:

$$P(b|a) = \frac{P(a|b) P(b)}{P(a)}$$

- C'est la règle de Bayes qui est sous-jacente à tous les systèmes modernes d'IA utilisant l'inférence probabiliste.

43

Règle de Bayes

- Règle très utile, en particulier pour évaluer des probabilités au niveau du diagnostic à partir des probabilités causales

$$P(\text{cause}|\text{effet}) = \frac{P(\text{effet}|\text{cause}) P(\text{cause})}{P(\text{effet})}$$

44

Règle de Bayes: Ex

- Ex: m : méningite et s : raideur au cou.

$$P(s|m) = 0.5$$

$$P(m) = 1/50000$$

$$P(s) = 1/20$$

$$P(m|s) = \frac{P(s|m)P(m)}{P(s)} = \frac{0.5 \times 1/50000}{1/20} = 0.0002$$

- On s'attend à ce que seulement 1 patient sur 5000 qui a un mal de cou ait une méningite

45

Règle de Bayes et normalisation

- En utilisant la normalisation, on peut réécrire la règle de Bayes:

$$P(M|s) = \alpha \langle P(s|m)P(m), P(s|\neg m)P(\neg m) \rangle$$

- La forme générale de la règle de Bayes avec normalisation est:

$$P(Y|X) = \alpha P(X|Y)P(Y)$$

46

Indépendance conditionnelle

- Dans l'exemple du dentiste, on ne peut pas dire que les variables *Toothache* et *Catch* sont indépendantes. Si on applique la règle de Bayes, on obtient:

$$P(\text{Cavity}|\text{toothache} \wedge \text{catch}) = \alpha P(\text{toothache} \wedge \text{catch}|\text{Cavity})P(\text{Cavity}) \\ = \alpha \{0.108, 0.016\} \approx \{0.871, 0.129\}$$

- Toutefois ça ne scale pas, *Toothache* et *Catch* sont **conditionnellement indépendantes** sachant la présence ou l'absence d'une carie. Donc, on peut dire:

$$P(\text{toothache} \wedge \text{catch}|\text{Cavity}) = P(\text{toothache}|\text{Cavity})P(\text{catch}|\text{Cavity})$$

- En remplaçant, on obtient:

$$P(\text{Cavity}|\text{toothache} \wedge \text{catch}) = \alpha P(\text{toothache}|\text{Cavity})P(\text{catch}|\text{Cavity})P(\text{Cavity})$$

47

Indépendance conditionnelle

- La définition générale d'une Independence conditionnelle de 2 variables X et Y, étant donnée Z est :

$$P(X, Y|Z) = P(X|Z)P(Y|Z)$$

- Dans l'exemple des dents, on pourrait affirmer une Independence conditionnelle entre les variable *Toothache* et *Catch*, étant donnée *Cavity*, soit:

$$P(\text{Toothache}, \text{Catch}|\text{Cavity}) = P(\text{Toothache}|\text{Cavity})P(\text{Catch}|\text{Cavity})$$

48

Indépendance conditionnelle

- L'indépendance conditionnelle permet de diminuer la grandeur des tables de distribution jointe.

$P(\text{Toothache}, \text{Catch}, \text{Cavity})$

= $P(\text{Toothache}, \text{Catch} | \text{Cavity})P(\text{Cavity})$ (product rule)

= $P(\text{Toothache} | \text{Cavity})P(\text{Catch} | \text{Cavity})P(\text{Cavity})$ (using 13.14)

- On a remplacé une grande table par trois petites tables plus faciles à calculer.
- L'utilisation de l'indépendance conditionnelle permet de réduire la grandeur de la représentation de la distribution jointe d'exponentiel en n [$O(d^n)$] à linéaire en n .
- L'indépendance conditionnelle est une forme de connaissance robuste pour les environnements incertains.

49

Indépendance conditionnelle

- Comme pour le problème du dentiste, souvent on a une cause influençant directement un certain nombre d'effets qui sont tous conditionnellement indépendants sachant la cause.

$$P(\text{Toothache}, \text{Catch}, \text{Cavity}) = P(\text{Cavity})P(\text{Toothache} | \text{Cavity})P(\text{Catch} | \text{Cavity})$$

50

Indépendance conditionnelle

- Donc, la distribution complète jointe peut être écrite:

$$P(\text{Cause}, \text{Effect}_1, \dots, \text{Effect}_n) = P(\text{Cause}) \prod_i P(\text{Effect}_i | \text{Cause})$$

- Cette distribution est appelée **Modèle de Bayes naïf** ou **classificateur bayésien**

51

Wumpus World revisité

- Exemple de raisonnement probabiliste dans le monde du Wumpus.
- Supposons l'environnement ci-contre où les cases [1,3], [2,2] et [3,1] peuvent contenir un trou.
- On veut savoir la probabilité de contenir un trou pour chacune de ces cases.

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1	2,1 B OK	3,1	4,1

52

Wumpus World

- Les propriétés de l'environnement sont :
 - Un trou cause une brise (B) dans les cases adjacentes.
 - Toutes les cases sauf [1,1] contiennent un trou avec une probabilité de 0.2.
- Identifier l'ensemble des variables aléatoires:
 - P_{ij} = vrai si $[i, j]$ contient un trou.
 - B_{ij} = vrai si $[i, j]$ contient une brise. On ajoute ces variables uniquement pour les cases observées, dans notre cas: [1,1],[1,2] et [2,1].

53

Spécifier la distribution jointe complète

- La distribution jointe complète est:

$$\mathbf{P}(P_{1,1}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1})$$
- Avec la règle du produit, cette expression devient:

$$\mathbf{P}(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,1}, \dots, P_{4,4})\mathbf{P}(P_{1,1}, \dots, P_{4,4})$$
- On a appliqué la règle du produit pour obtenir une distribution de la forme: $P(\text{Effet} | \text{Cause})$

54

Spécifier la distribution jointe complète

- Distribution jointe: $\mathbf{P}(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,1}, \dots, P_{4,4}) \mathbf{P}(P_{1,1}, \dots, P_{4,4})$
- Avec cette décomposition, on peut facilement voir les valeurs des probabilités jointes.
 - Pour le premier terme, la valeur est de 1 si la brise est adjacente à un trou, 0 sinon.
 - Pour le deuxième terme, chaque case peut contenir un trou avec une probabilité de 0.2, indépendamment des autres cases, donc on peut écrire que:

$$\mathbf{P}(P_{1,1}, \dots, P_{4,4}) = \prod_{i,j=1,1}^{4,4} \mathbf{P}(P_{i,j})$$

55

Observations et requête

- On sait: $b = \neg b_{1,1} \wedge b_{1,2} \wedge b_{2,1}$
 $known = \neg p_{1,1} \wedge \neg p_{1,2} \wedge \neg p_{2,1}$
- On veut trouver: $\mathbf{P}(P_{1,3} | known, b)$
- Supposons $Unknown = P_{ij}$ autre que $P_{1,3}$ et $known$
- Pour l'inférence par énumération, on a:


$$\mathbf{P}(P_{1,3} | known, b) = \alpha \sum_{unknown} \mathbf{P}(P_{1,3}, unknown, known, b)$$

- La somme contient $2^{12} = 4096$ termes.

56

Utiliser les indépendances conditionnelles

- Supposons *Fringe*, les variables qui sont adjacentes aux cases visitées.
- Supposons *Other*, les variables pour les autres cases inconnues.
- Les brises observées sont indépendantes des autres variables sachant les variables *known*, *fringe* et *query*.



$$\mathbf{P}(b | P_{1,3}, known, unknown) = \mathbf{P}(b | P_{1,3}, known, fringe)$$

57


Calculs

$$\begin{aligned}
 \mathbf{P}(P_{1,3}|known, b) &= \alpha \sum_{unknown} \mathbf{P}(P_{1,3}, unknown, known, b) \\
 &= \alpha \sum_{unknown} \mathbf{P}(b|P_{1,3}, known, unknown) \mathbf{P}(P_{1,3}, known, unknown) \\
 &= \alpha \sum_{fringe} \sum_{other} \mathbf{P}(b|known, P_{1,3}, fringe, other) \mathbf{P}(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} \sum_{other} \mathbf{P}(b|known, P_{1,3}, fringe) \mathbf{P}(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} \mathbf{P}(b|known, P_{1,3}, fringe) \sum_{other} \mathbf{P}(P_{1,3}, known, fringe, other) \\
 &= \alpha \sum_{fringe} \mathbf{P}(b|known, P_{1,3}, fringe) \sum_{other} \mathbf{P}(P_{1,3}) P(known) P(fringe) P(other) \\
 &= \alpha P(known) \mathbf{P}(P_{1,3}) \sum_{fringe} \mathbf{P}(b|known, P_{1,3}, fringe) P(fringe) \sum_{other} P(other) \\
 &= \alpha' \mathbf{P}(P_{1,3}) \sum_{fringe} \mathbf{P}(b|known, P_{1,3}, fringe) P(fringe)
 \end{aligned}$$

58

Calculs

- Le premier terme de la somme (soit $\mathbf{P}(b | known, P_{1,3}, fringe)$) vaut 1 lorsque les valeurs de la *fringe* sont consistantes avec les observations, 0 sinon.
- Donc, on a juste à faire la somme pour les modèles consistants.



$$\mathbf{P}(P_{1,3}|known, b) = \alpha' (0.2(0.04 + 0.16 + 0.16) + 0.8(0.04 + 0.16)) \approx (0.31, 0.69)$$

59

Discussion

- Donc [1,3] (et [3,1] par symétrie) a une probabilité de 31% de contenir un puits.
- Un calcul similaire en [2,2] (à faire en exercice) montre que la probabilité de contenir un puits est de 86%, dans ces conditions l'agent Wumpus doit éviter [2,2].

60
