

# INCERTEZZA

## CAPITOLO 13

Capitolo 13

1

### Incertezza

Azione  $A_t$  = partire per l'aeroporto  $t$  minuti prima del volo  
L'azione  $A_t$  mi permetterà di arrivare in tempo?

Problemi:

- 1) osservabilità parziale (stato della strada, piano di altri veicoli, etc.)
- 2) sensori rumorosi (rapporti sul traffico di Isoracio ...)
- 3) incertezza nell'esito delle azioni (pneumatico forato, etc.)
- 4) immensa complessità nel modellare e nel predire il traffico

Quindi un approccio puramente logico o

- 1) rischia di dire il falso: " $A_{25}$  mi fa arrivare in tempo"
- o 2) conduce a conclusioni che sono troppo deboli per prendere decisioni:  
" $A_{25}$  mi fa arrivare in tempo se non c'è un incidente sul ponte e non piove e non foro i pneumatici, etc etc."

( $A_{1440}$  si può ragionevolmente dire che mi fa arrivare in tempo ma devo passare la notte all'aeroporto ...)

Capitolo 13

3

### Outline

- ◇ Incertezza
- ◇ Probabilità
- ◇ Sintassi e semantica
- ◇ Inferenza
- ◇ Incipendenza e Regola di Bayes

Capitolo 13

2

### Metodi per trattare l'incertezza

Default o nonmonotonic logic:

Assumiamo che l'auto non abbia forato

Assumiamo che  $A_{25}$  vada bene a meno che l'evidenza non lo contraddica

Problemi: quali assunzioni sono ragionevoli? Trattamento contraddizioni?

Regole con fattori di "inganno" (fudge factors):

$A_{25} \mapsto_{0.3}$  mi fa arrivare in tempo

*irrigatore*  $\mapsto_{0.99}$  *erba - bagnata*

*erba - bagnata*  $\mapsto_{0.7}$  *pioggia*

Problemi: come trattare la combinazione? p.e., *irrigatore* causa *pioggia*??

Probabilità

Data l'evidenza disponibile,

$A_{25}$  mi fa arrivare in tempo con probabilità 0.04

Mahaviracarya (9th C.), Cardano (1565) teoria del gioco

(Logica Fuzzy manipola *gradi di verità* NON incertezza p.e.,  
*erba - bagnata* è vera con grado 0.2)

Capitolo 13

4

## Probabilità

Asserzioni Probabilistiche *riassumono* gli effetti di

**pigrizia**: fallimento nell'enumerare le eccezioni, qualifica, etc.

**ignoranza**: mancanza di fatti rilevanti, condizioni iniziali, etc.

Probabilità **Soggettiva** o **Bayesiana**:

Le probabilità legano le proposizioni al proprio stato di conoscenza

p.e.,  $P(A_{25}|\text{nessun incidente riportato}) = 0.06$

**Non** indica alcuna **tendenza probabilistica** nella situazione corrente

Le probabilità delle proposizioni cambiano con l'arrivo di nuova evidenza:

p.e.,  $P(A_{25}|\text{nessun incidente riportato, 5 a.m.}) = 0.15$

## Elementi di Probabilità

Insieme  $\Omega$  — **spazio degli eventi**

p.e., 6 possibili lanci di dado.

$\omega \in \Omega$  è un campione (possibile evento atomico)

Uno **spazio di probabilità** o **modello di probabilità** è uno spazio degli eventi con un assegnamento  $P(\omega)$  per ogni  $\omega \in \Omega$  tale che

$$0 \leq P(\omega) \leq 1$$

$$\sum_{\omega} P(\omega) = 1$$

e.g.,  $P(1) = P(2) = P(3) = P(4) = P(5) = P(6) = 1/6$ .

Un **evento**  $A$  è un qualunque sottoinsieme di  $\Omega$

$$P(A) = \sum_{\{\omega \in A\}} P(\omega)$$

P.e.,  $P(\text{lancio dado} < 4) = 1/6 + 1/6 + 1/6 = 1/2$

## Decidere nell'incertezza

Supponiamo di credere che:

$$P(A_{25} \text{ mi fa arrivare in tempo} | \dots) = 0.04$$

$$P(A_{90} \text{ mi fa arrivare in tempo} | \dots) = 0.70$$

$$P(A_{120} \text{ mi fa arrivare in tempo} | \dots) = 0.95$$

$$P(A_{1440} \text{ mi fa arrivare in tempo} | \dots) = 0.9999$$

Quale azione scegliere ?

Dipende dalle mie **preferenze**: perdere l'aereo vs. la cucina dell'aeroporto, etc.

**Teoria dell'utilità** è usata per rappresentare e inferire preferenze

**Teoria delle decisioni** = teoria dell'utilità + teoria delle probabilità

## Variabili aleatorie

Una **variabile aleatoria** è una funzione da eventi a qualche intervallo, p.e., i reali o i Booleani

p.e.,  $Dispari(1) = \text{vero}$ .

$P$  induce una **distribuzione di probabilità** per ogni variabile aleatoria  $X$ :

$$P(X = x_i) = \sum_{\{\omega: X(\omega) = x_i\}} P(\omega)$$

p.e.,  $P(Dispari = \text{vero}) = 1/6 + 1/6 + 1/6 = 1/2$

## Proposizioni

Pensare ad una proposizione come un evento (insieme di eventi) dove la proposizione è vera

Date variabili Booleane aleatorie  $A$  e  $B$ :

- evento  $a$  = insieme di eventi dove  $A(\omega) = \text{vero}$
- evento  $\neg a$  = insieme di eventi dove  $A(\omega) = \text{falso}$
- evento  $a \wedge b$  = eventi dove  $A(\omega) = \text{vero}$  e  $B(\omega) = \text{vero}$

Variabili Booleane, evento = modello di logica proposizionale

p.e.,  $A = \text{vero}$ ,  $B = \text{falso}$ , o  $a \wedge \neg b$ .

Proposizione = disgiunzione di eventi atomici in cui essa è vera

- p.e.,  $(a \vee b) \equiv (\neg a \wedge \neg b) \vee (a \wedge \neg b) \vee (a \wedge b)$
- $\Rightarrow P(a \vee b) = P(\neg a \wedge \neg b) + P(a \wedge \neg b) + P(a \wedge b)$

## Sintassi per le proposizioni

Variabili aleatorie **proposizionali** o **Booleane**

p.e., *Cavit * (ho una cavit ?)

Variabili aleatorie **discrete** (*finite* o *infinite*)

p.e., *Tempo* pu  assumere i valori *(sole, pioggia, nuvole, neve)*

*Tempo = pioggia*   una proposizione

I valori devono essere esaustivi e mutuamente esclusivi

Variabili aleatorie **continue**

p.e., *Temperatura* = 21.6; ammette anche, p.e., *Temperatura* < 22.0.


Combinazioni Booleane arbitrarie di proposizioni base

## Perch  usare le probabilit ?

Le definizioni implicano che alcuni eventi logicamente correlati devono avere probabilit  correlate

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

True



de Finetti (1931): un agente che scommette secondo probabilit  che violano questi assiomi possono essere forzati a perdere soldi indipendentemente dall'esito degli eventi

## Probabilit  a priori

**Prior** o **probabilit  incondizionate** di proposizioni

p.e.,  $P(\text{Cavit } = \text{vero}) = 0.1$  e  $P(\text{Tempo} = \text{sole}) = 0.72$

corrispondono a gradi di crecenza sull'arrivo di (nuova) evidenza

**Distribuzione di probabilit ** fornisce valori per tutti i possibili assegnamenti:

$P(\text{Tempo}) = \langle 0.72, 0.1, 0.08, 0.1 \rangle$  (**normalizzate**, cio , sommano ad 1)

**Distribuzione di probabilit  congiunta** per un insieme di v.a. fornisce

la probabilit  per ogni evento atomico su tali variabili

$P(\text{Tempo}, \text{Cavit })$  = una matrice  $4 \times 2$  di valori:


<i>Tempo</i> =	<i>sole</i>	<i>pioggia</i>	<i>nuvole</i>	<i>neve</i>
<i>Cavit�</i> = <i>vero</i>	0.144	0.02	0.016	0.02
<i>Cavit�</i> = <i>falso</i>	0.576	0.08	0.064	0.08

*Ogni domanda che concerne un dominio trova risposta nella distribuzione congiunta perch  ogni evento   la somma dei possibili eventi*

## Probabilità per variabili continue

Esprimere la distribuzione come una funzione parametrizzata di valori:

$$P(X=x) = U[18, 26](x) = \text{densità uniforme tra 18 e 26}$$




$P$  è una *densità*, integra ad 1.

$P(X=20.5) = 0.125$  in realtà significa

$$\lim_{dx \rightarrow 0} P(20.5 \leq X \leq 20.5 + dx)/dx = 0.125$$

## Densità Gaussiana

$$P(x) = \frac{1}{\sqrt{2\pi\sigma}} e^{-(x-\mu)^2/2\sigma^2}$$



## Probabilità condizionale

Probabilità a posteriori o condizionale

p.e.,  $P(\text{Cavità}|\text{Mal\_di\_denti}) = 0.8$

cioè, dato che *Mal\\_di\\_denti* è tutto quello che so

Se so di più, p.e., *Cavità* è anche data, allora abbiamo

$$P(\text{Cavità}|\text{Mal\_di\_denti}, \text{Cavità}) = 1$$

Nota: la credenza meno specifica *rimane valida* dopo che nuova evidenza arriva, ma non necessariamente rimane *utile*

Nuova evidenza può essere irrilevante, permettendo semplificazioni, p.e.,

$$P(\text{Cavità}|\text{Mal\_di\_denti}, \text{Vince\_Inter}) = P(\text{Cavità}|\text{Mal\_di\_denti}) = 0.8$$

Questo tipo di inferenza, dovuta alla conoscenza del dominio, è cruciale

## Probabilità condizionale

Definizione di probabilità condizionale:

$$P(a|b) = \frac{P(a \wedge b)}{P(b)} \text{ if } P(b) \neq 0$$

La *regola del prodotto* fornisce una definizione alternativa:

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

Una versione generale vale sulle distribuzioni, p.e.,

$$\mathbf{P}(\text{Tempo}, \text{Cavità}) = \mathbf{P}(\text{Tempo}|\text{Cavità})\mathbf{P}(\text{Cavità})$$

(Visto come un insieme  $4 \times 2$  di equazioni, *no* moltiplicazione di matrici)

*Chain rule* è derivata dalla applicazione ripetuta della regola del prodotto:

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

## Inferenza tramite enumerazione

Si inizia con la distribuzione congiunta:

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

Per ogni proposizione  $\phi$ , si sommano gli eventi atomici dove essa è vera:

$$P(\phi) = \sum_{\omega:\omega\models\phi} P(\omega)$$

## Inferenza tramite enumerazione

Si inizia con la distribuzione congiunta:

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

Per ogni proposizione  $\phi$ , si sommano gli eventi atomici dove essa è vera:

$$P(\phi) = \sum_{\omega:\omega\models\phi} P(\omega)$$

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

## Inferenza tramite enumerazione

Si inizia con la distribuzione congiunta:

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

Per ogni proposizione  $\phi$ , si sommano gli eventi atomici dove essa è vera:

$$P(\phi) = \sum_{\omega:\omega\models\phi} P(\omega)$$

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

## Inferenza tramite enumerazione

Si inizia con la distribuzione congiunta:

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

Si possono calcolare anche le probabilità condizionali:

$$\begin{aligned}
 P(\neg \textit{cavity} | \textit{toothache}) &= \frac{P(\neg \textit{cavity} \wedge \textit{toothache})}{P(\textit{toothache})} \\
 &= \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4
 \end{aligned}$$

## Normalizzazione

	<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

Il denominatore può essere visto come una **costante di normalizzazione**  $\alpha$

$$\begin{aligned}
 P(\text{Cavity}|\text{toothache}) &= \alpha P(\text{Cavity}, \text{toothache}) \\
 &= \alpha [P(\text{Cavity}, \text{toothache}, \text{catch}) + P(\text{Cavity}, \text{toothache}, \neg \text{catch})] \\
 &= \alpha [(0.108, 0.016) + (0.012, 0.064)] \\
 &= \alpha (0.12, 0.08) = (0.6, 0.4)
 \end{aligned}$$

Idea generale: calcolare la distribuzione sulla variabile della query fissando le **variabili di evidenza** e sommando sulle **variabili nascoste**

## Inferenza tramite enumerazione

Tipicamente siamo interessati a

la distribuzione congiunta a posteriori delle **variabili di query**  $Y$  dati specifici valori e per le **variabili di evidenza**  $E$

Poniamo le **variabili nascoste** essere  $H = X - Y - E$

Allora la somma desiderata di entrate congiunte è ottenuta sommando sulle **variabili nascoste**:

$$P(Y|E=e) = \alpha P(Y, E=e) = \alpha \sum_h P(Y, E=e, H=h)$$

I termini nella sommatoria sono entrate congiunte perché  $Y$ ,  $E$ , e  $H$  insieme esauriscono l'insieme delle variabili aleatorie


Problemi ovvi:

- 1) Complessità caso pessimo in tempo  $O(d^n)$  dove  $d$  è l'arietà più grande
- 2) Complessità in spazio  $O(d^n)$  per memorizzare la distribuzione congiunta
- 3) Come stabilire i valori per  $O(d^n)$  entrate???

## Indipendenza

$A$  e  $B$  sono indipendenti sse

$$P(A|B) = P(A) \quad \text{or} \quad P(B|A) = P(B) \quad \text{or} \quad P(A, B) = P(A)P(B)$$



$$\begin{aligned}
 P(\text{Toothache}, \text{Catch}, \text{Cavity}, \text{Weather}) \\
 = P(\text{Toothache}, \text{Catch}, \text{Cavity})P(\text{Weather})
 \end{aligned}$$

32 entrate ridotte a 12; per  $n$  monete "truccate" indipendenti,  $2^n \rightarrow n$

Indipendenza assoluta potente ma rara

Nei problemi reali sono coinvolte centinaia di variabili, nessuna delle quali è indipendente. Che fare?

## Indipendenza condizionale

$P(\text{Toothache}, \text{Cavity}, \text{Catch})$  ha  $2^3 - 1 = 7$  entrate indipendenti

Se si ha una cavità, la probabilità che la sonda si fermi su in essa non dipende dal fatto di avere il mal di denti:

$$(1) P(\text{catch}|\text{toothache}, \text{cavity}) = P(\text{catch}|\text{cavity})$$

La stessa indipendenza vale se non c'è la cavità:

$$(2) P(\text{catch}|\text{toothache}, \neg \text{cavity}) = P(\text{catch}|\neg \text{cavity})$$

*Catch* è **condizionalmente indipendente** da *Toothache* dato *Cavity*:

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

Affermazione equivalente:

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

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

## Indipendenza condizionale

Scrivere la distribuzione congiunta completa usando la chain rule:

$$\begin{aligned} & \mathbf{P}(\textit{Toothache}, \textit{Catch}, \textit{Cavity}) \\ &= \mathbf{P}(\textit{Toothache} | \textit{Catch}, \textit{Cavity}) \mathbf{P}(\textit{Catch}, \textit{Cavity}) \\ &= \mathbf{P}(\textit{Toothache} | \textit{Catch}, \textit{Cavity}) \mathbf{P}(\textit{Catch} | \textit{Cavity}) \mathbf{P}(\textit{Cavity}) \\ &= \mathbf{P}(\textit{Toothache} | \textit{Cavity}) \mathbf{P}(\textit{Catch} | \textit{Cavity}) \mathbf{P}(\textit{Cavity}) \end{aligned}$$

Ciò,  $2 + 2 + 1 = 5$  numeri incipienti

*In molti casi, l'uso di indipendenza condizionale riduce la dimensione della rappresentazione della probabilità congiunta da essere esponenziale in  $n$  a lineare  $n$ .*

*L'indipendenza condizionale è la forma più basilare e robusta di conoscenza sugli ambienti incerti.*

## Regola di Bayes e indipendenza condizionale

$$\begin{aligned} & \mathbf{P}(\textit{Cavity} | \textit{toothache} \wedge \textit{catch}) \\ &= \alpha \mathbf{P}(\textit{toothache} \wedge \textit{catch} | \textit{Cavity}) \mathbf{P}(\textit{Cavity}) \\ &= \alpha \mathbf{P}(\textit{toothache} | \textit{Cavity}) \mathbf{P}(\textit{catch} | \textit{Cavity}) \mathbf{P}(\textit{Cavity}) \end{aligned}$$

Questo è un esempio di modello *naive Bayes*:

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



Il numero totale di parametri è *lineare* in  $n$

## Regola di Bayes

Regola del prodotto  $P(a \wedge b) = P(a|b)P(b) = P(b|a)P(a)$

$$\Rightarrow \text{Bayes' rule } P(a|b) = \frac{P(b|a)P(a)}{P(b)}$$

o in forma di distribuzione

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

Utile per ottenere probabilità *diagnostica* a partire da probabilità *causale*:

$$P(\textit{Cause} | \textit{Effect}) = \frac{P(\textit{Effect} | \textit{Cause}) P(\textit{Cause})}{P(\textit{Effect})}$$

P.e., sia  $M$  la rappresentazione di Meningite, e  $S$  di collo rigido:

$$P(m|s) = \frac{P(s|m)P(m)}{P(s)} = \frac{0.8 \times 0.0001}{0.1} = 0.0008$$

Nota: la probabilità a posteriori della Meningite ancora piccola!

## Mondo dei Wumpus

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

$P_{ij} = \textit{vero}$  sse  $[i, j]$  contiene una trappola

$B_{ij} = \textit{vero}$  sse  $[i, j]$  è ventilato

Includiamo solo  $B_{1,1}, B_{1,2}, B_{2,1}$  nel modello probabilistico

## Specifica del modello probabilistico

La distribuzione congiunta completa è  $\mathbf{P}(P_{1,1}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1})$

Applicare la regola del prodotto:  $\mathbf{P}(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,1}, \dots, P_{4,4})\mathbf{P}(P_{1,1}, \dots, P_{4,4})$

(facciamo così per ottenere  $P(Effect|Cause)$ .)

Primo termine: 1 se le trappole sono adiacenti a "brezze", 0 altrimenti


Secondo termine: le trappole sono posizionate a caso, con probabilità 0.2 per quadrato:

$$\mathbf{P}(P_{1,1}, \dots, P_{4,4}) = \prod_{i,j=1,1}^{4,4} \mathbf{P}(P_{i,j}) = 0.2^n \times 0.8^{16-n}$$

per  $n$  trappole.

## Usando l'indipendenza condizionale

Idea base: le osservazioni sono condizionalmente indipendenti da altri quadrati nascosti dati i quadrati nascosti adiacenti



Definiamo  $Unknown = Fringe \cup Other$

$$\mathbf{P}(b|P_{1,3}, Known, Unknown) = \mathbf{P}(b|P_{1,3}, Known, Fringe)$$

Poniamo la query in una forma dove si possa usare quanto sopra!

## Osservazioni e query

Noi conosciamo i seguenti fatti:

$$b = \neg b_{1,1} \wedge b_{1,2} \wedge b_{2,1}$$

$$known = \neg p_{1,1} \wedge \neg p_{1,2} \wedge \neg p_{2,1}$$

La query è  $\mathbf{P}(P_{1,3}|known, b)$

Definiamo  $unknown = i P_{ij}$  diversi da  $P_{1,3}$  e  $known$

Per effettuare inferenza per enumerazione, abbiamo

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


Cresce esponenzialmente con il numero di quadrati!

## Usando l'indipendenza condizionale

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



## Usando l'indipendenza condizionale



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

$$\mathbf{P}(P_{2,2}|known, b) \approx \langle 0.86, 0.14 \rangle$$

## Riassunto

Il calcolo delle probabilità costituisce un formalismo rigoroso per la conoscenza incerta

La **distribuzione congiunta di probabilità** specifica la probabilità di ogni **evento atomico**

Si può rispondere alle query sommando sugli eventi atomici

Per domini non banali, bisogna trovare un modo per ridurre la dimensione della rappresentazione della probabilità congiunta

**Indipendenza** ed **indipendenza condizionale** forniscono tale modo