

Conhecimento Incerto

Redes de Crença

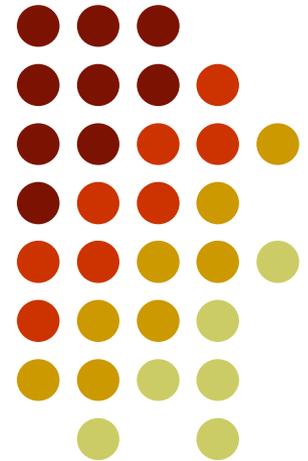
Profa. Josiane M. P. Ferreira

Texto base:

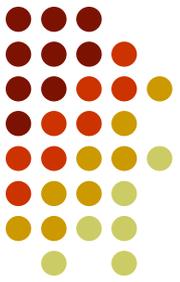
David Poole, Alan Mackworth e Randy Goebel -
“*Computational Intelligence – A logical approach*” – cap 10.

Stuart Russel e Peter Norving - “Inteligência Artificial” - cap 14.


setembro/2008



Idéia das Redes de Crença




- Dado uma variável randômica V , existe um pequeno conjunto de variáveis que afetam diretamente o valor de V .
 - Qualquer outra variável é independente de V , dado os valores para as variáveis que afetam V diretamente (variáveis **pais**).
- Este princípio de localidade é explorado nas **Redes de Crença** ou **Rede Bayesianas**.
 - São representações gráficas de independência condicional.
 - São grafos onde os nós são variáveis randômicas e existe um arco de cada um dos pais do nó para o nó.
 - A independência permite descrever os efeitos diretos no grafo e escrever quais probabilidades necessitam ser especificadas.




Idéia das Redes de Crença

- Se $I1$ está acesa (lit_{I1}) depende **somente** do estado da luz ($I1_{st}$) e se existe energia no fio $w0$.
- Assim, $I1_{lit}$ é independente de outras variáveis dado $I1_{st}$ e $w0$.
 - Em uma rede de crença, $w0$ e $I1_{st}$ **são pais** de $I1_{lit}$.
- Similarmente, $w0$ depende **somente** se existe energia no fio $w1$, se existe energia no fio $w2$, a posição da chave $s2$ ($s2_{pos}$), e o estado da chave $s2$ ($s2_{st}$).




O que é uma Rede de Crença




- São DAGs onde os nós são variáveis randômicas.
 - Os pais de um nó n são aquelas variáveis das quais n depende diretamente.
- São uma representação gráfica de dependência e independência.
 - Uma variável é independente dos seus **não-descendentes**, dados seus pais.
 - Exemplo: seja X uma variável randômica com os pais Y_1, Y_2, \dots, Y_n :
 - $P(X=a \mid Y_1=v_1, Y_2=v_2, Y_n=v_n, R) = P(X=a \mid Y_1=v_1, Y_2=v_2, Y_n=v_n)$, se R não envolve um descendente de X incluindo o próprio X .
- São constituídas por:
 - Um grafo acíclico com nós rotuladas com variáveis randômicas.
 - Um domínio para cada variável randômica.
 - Um conjunto de probabilidades condicionais para cada variável dado seus pais (incluindo probabilidades a priori para nós sem pais).

Exemplo de uma Rede de Crença




Exemplo de uma Rede de Crença - continuação



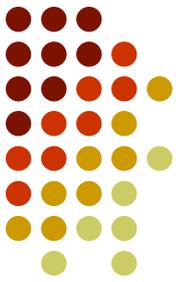
- O domínio das variáveis:
 - w_0, \dots, w_6 tem o domínio $\{live, dead\}$.
 - $s1_pos, s2_pos,$ e $s3_pos$ tem o domínio $\{up, down\}$.
 - $s1_st,$ tem $\{ok, upside_down, short, intermittent, broken\}$.
- Probabilidade condicional, incluindo os valores para:
 - $P(w_1 = live \mid s1_pos = up \wedge s1_st = ok \wedge w_3 = live)$.
 - $P(w_1 = live \mid s1_pos = up \wedge s1_st = ok \wedge w_3 = dead)$.
 - ... $2 * 5 * 2 = 20$ valores.
 - O número de probabilidades que deve ser especificada para uma variável é exponencial no número de pais desta variável.
 - $P(s1_pos = up) \Rightarrow 2$ valores.
 - $P(s1_st = upside_down) \Rightarrow 5$ valores.

Suposição de independência para Redes de Crença



- As variáveis $s1_pos$, $s1_st$, e $w3$ são pais da variável $w1$.
- Se soubermos os valores de $s1_pos$, $s1_st$, e $w3$ conhecermos os valores de $l2$ e $cb2_st$ não afetam a crença se existe energia em $w1$.
- Mas se soubermos os valores de $s1_pos$, $s1_st$, e $w3$ ficarmos sabendo que $l1$ está ligada, potencialmente muda a crença se existe energia em $w1$.
 - Neste caso a independência não é diretamente aplicável.
- Para variáveis que não tem pais, como $s1_pos$, a independência da rede de crença especifica que, para qualquer A que não envolva um descendente de $s1_pos$:
 - $P(s1_pos=up | A) = P(s1_pos=up)$

Utilizando Redes de Crença



- Ordene as variáveis de forma que os nós pais venham antes de seus filhos: X_1, \dots, X_n .

- Utilizando a regra da cadeia:

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

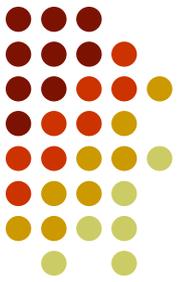
- Os pais π_{X_i} de X_i são aqueles predecessores de X_i que tornam X_i independente dos outros predecessores.

$$\pi_{X_i} \subseteq X_1, \dots, X_{i-1} \text{ and } P(X_i | \pi_{X_i}) = P(X_i | X_1, \dots, X_{i-1})$$


- Assim,

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

Utilizando Redes de Crença




- A rede de energia pode ser empregada de várias formas
 - Condicionando sobre o estado dos interruptores e disjuntores, se existir energia na rua e a posição dos interruptores, você pode simular o funcionamento das lâmpadas.
 - Dados valores para os interruptores, a energia externa, e se as lâmpadas estão ligadas, você pode determinar a probabilidade posterior de que cada interruptor ou disjuntor estar *OK* ou *Não*.
 - Dado algumas posições e algumas saídas e alguns valores intermediários, você pode determinar a probabilidade de qualquer outra variável na rede.




Redes Crença - Exemplo

- Problema: quando eu vou p/ casa eu quero saber se alguém da minha família está em casa antes que eu entre.
- Temos:
 - Toda vez que a esposa sai de casa, freqüentemente (mas não sempre) ela liga a luz de fora. (As vezes ela também liga a luz quando está esperando um convidado).
 - Quando ninguém está em casa, o cachorro é sempre deixado pra fora.
 - Se o cachorro tiver problemas intestinais, ele também é deixado pra fora.
 - Se o cachorro estiver pra fora, eu provavelmente vou ouvi-lo latir (embora ele possa não latir, ou eu posso confundir o latido de outro cachorro com o latido do meu).




Redes Crença - Exemplo

- Vamos definir as variáveis aleatórias booleanas:
 - *TF*: Todos estão fora de casa
 - *LA*: A luz está acesa
 - *CF*: O cachorro está fora de casa
 - *CP*: O cachorro tem problemas intestinais
 - *OL*: Eu posso ouvir o cachorro latir
- Dependências condicionais (ou influências causais diretas):
 - *OL* é influenciado diretamente somente por *CF*. Portanto, *OL* é condicionalmente independente de *LA*, de *TF* e de *CP* dado *CF*.
 - *CF* é influenciado diretamente somente por *TF* e *CP*. Portanto, *CF* é condicionalmente independente de *LA* dado *TF* e *CP*.





Redes de Crença - Exemplo

- Influências causais diretas:
 - *LA* é influenciado diretamente somente por *TF*. Portanto, *LA* é condicionalmente independente de *CF*, de *OL* e de *CP* dado *TF*.
 - *TF* e *CP* são independentes.



Redes de Crença – informações quantitativas




Total de **10** probb.

Enquanto a distribuição completa de probb. seria uma tabela com **32** probb.

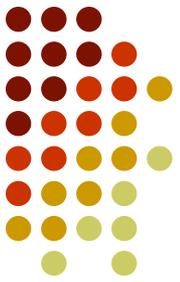
Esta redução é devido ao fato de muitas v.a. serem **condicionalmente independentes**

Independência em Redes de Crença



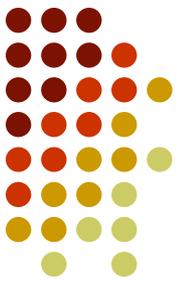
- Duas variáveis que **não** são conectadas diretamente por um arco ainda **podem** afetar uma a outra.
 - Exemplo: *CP* e *OL* não são ligadas diretamente por um arco, mas *CP* afeta *OL* indiretamente.
- Relações condicionais de independência representadas podem ser facilmente visualizadas na rede:
 - Cada nó *V* é condicionalmente independente de todos os nós que não são descendentes de *V*, dado os pais de *V*.
 - Exemplo: *OL* é condicionalmente independente de *CP*, *TF* e *LA* dado *CF*. Assim, $P(OL \mid CP, CF, TF, LA) = P(OL \mid CF)$.

Que variáveis são afetadas pela observação?




- Se você observa a variável Y , as variáveis cuja probabilidade posterior são diferentes de seus valores a priori são:
 - Os antecedentes de Y e
 - Seus descendentes.
- Intuitivamente (se você tiver uma rede de crença causal):
 - Você realiza abdução para as possíveis causas e
 - Predição a partir das causas.


Independência em Redes de Crença – descendentes comuns




- *falsificação* e *fogo* são independentes
- *falsificação* e *fogo* são dependentes dado *alarme*
- Intuitivamente, *falsificação* pode **minimizar a importância** de *fogo*




Independência em Redes de Crença – ancestrais comuns



- *alarme* e *fumaça* são dependentes
- *alarme* e *fumaça* são independentes dado *fogo*
- Intuitivamente, *fogo* pode **explicar** *alarme* e *fumaça*; aprendendo um pode afetar o outro pela troca de sua crença em *fogo*.




Independência em Redes de Crença – cadeia



- *alarme* e *relatório* são dependente
- *alarme* e *relatório* são independentes dado *evacuação*
- Intuitivamente, a única forma de que o *alarme* afeta *relatório* é por afetar *evacuação*.





D-Separação



- Dois nós V_i e V_j são condicionalmente independentes dado um conjunto de evidência E se:
 - Para todo caminho não direcionado da rede entre V_i e V_j , existe algum nó V_b , no caminho com alguma das três seguintes propriedades:
 - V_b está em E , e ambos os arcos no caminho saem de V_b .
 - V_b está em E , e um arco entra em V_b e um arco sai de V_b .
 - Nem V_b nem qualquer descendente de V_b está em E , e ambos os arcos no caminho entram em V_b .
 - Neste caso dizemos que E d-separa V_i e V_j .

D-Separação – Exemplo



G e B são independentes dado H?


G e B são independentes dado A?

D e R são independentes dado N?

D e R são independentes dado N e Q?


D e R são independentes dado Q e K?

Calculando probabilidades conjuntas em Redes de Crença



- Objetivo: calcular $P(cp, \sim tf, cf, \sim la, ol)$.
- Eu ouço o cachorro latir, ele está fora com problemas intestinais a luz esteja apagada e ninguém tenha saído.
- Vamos enumerar (1) para a regra da cadeia e $(\{x\}, \{y\})$ para independência entre as variáveis do conjunto x dado o conjunto y .
- $P(cp, \sim tf, cf, \sim la, ol) = P(\sim tf, cp, \sim la, cf, ol)$ (pais antes dos filhos) (1)
- $= P(\sim tf) * P(cp | \sim tf) * P(\sim la | \sim tf, cp) * P(cf | \sim tf, cp, \sim la) * P(ol | \sim tf, cp, \sim la, cf)$
- $= P(\sim tf) * P(cp) * P(\sim la | \sim tf) * P(cf | \sim tf, cp) * P(ol | cf)$
- Onde todos os valores numéricos estão disponíveis diretamente na rede (uma vez que $P(\sim A|B) = 1 - P(A|B)$).
- $= (1 - 0,6) * 0,3 * (1 - 0,6) * 0,1 * 0,3 = \mathbf{0,00144}$

Inferência por enumeração em uma Rede de Crença




- Qualquer probabilidade condicional pode ser calculada pelo somatório de termos da distribuição conjunta total.

$$P(X|e) = \frac{P(X \wedge e)}{P(e)} = \alpha P(X \wedge e) = \alpha \sum_{y=v} P(X \wedge e \wedge y)$$

- onde X é a variável de consulta, e é o conjunto de valores observados e y são todas as variáveis ocultas.
- A rede de crença fornece uma representação completa da distribuição conjunta total.
- Então, podemos responder uma consulta com o uso de uma rede de crença, calculando-se somas de produtos de probabilidades condicionais da rede.


Inferência por enumeração em uma Rede de Crença - Exemplo



- Suponha que eu queira calcular a probabilidade de eu ouvir o cachorro latir dado que a luz está acesa e o cachorro está com problemas intestinais: $P(ol \mid la, cp)$.

$$\begin{aligned} P(ol \mid la \wedge cp) &= \frac{P(ol \wedge la \wedge cp)}{P(la \wedge cp)} = \alpha P(ol \wedge la \wedge cp) \\ &= \alpha \sum_{TF} \sum_{CF} P(TF \wedge cp \wedge la \wedge CF \wedge ol) \\ &= \alpha \sum_{TF} \sum_{CF} P(TF) * P(cp) * P(la \mid TF) * P(CF \mid TF \wedge cp) * P(ol \mid CF) \\ &= \alpha \{P(cp) * [\sum_{TF} P(TF) * P(la \mid TF) * (\sum_{CF} P(CF \mid TF \wedge cp) * P(ol \mid CF))]\} \\ &= \alpha \{P(cp) * [\sum_{TF} P(TF) * P(la \mid TF) * (P(cf \mid TF \wedge cp) * P(ol \mid cf) + P(\sim cf \mid TF \wedge cp) * P(ol \mid \sim cf))]\} \end{aligned}$$

Inferência por enumeração em uma Rede de Crença - Exemplo



$$\begin{aligned} &= \alpha \{P(cp) * [(P(tf) * P(la | tf)) * (P(cf | tf \wedge cp) * P(ol | cf) + P(\sim cf | tf \wedge cp) * P(ol | \sim cf)) + \\ & (P(\sim tf) * P(la | \sim tf)) * (P(cf | \sim tf \wedge cp) * P(ol | cf) + P(\sim cf | \sim tf \wedge cp) * P(ol | \sim cf))] \} \\ &= \alpha \{0,3 * [(0,6 * 0,3) * (0,05 * 0,3 + 0,95 * 0,8) + (0,4 * 0,6) * (0,1 * 0,3 + 0,9 * 0,8)] \} \\ &= \alpha 0,09585 \end{aligned}$$


$$\begin{aligned} P(\sim ol | la \wedge cp) &= \\ &= \alpha \{P(cp) * [(P(tf) * P(la | tf)) * (P(cf | tf \wedge cp) * P(\sim ol | cf) + P(\sim cf | tf \wedge cp) * P(\sim ol | \sim cf)) + \\ & (P(\sim tf) * P(la | \sim tf)) * (P(cf | \sim tf \wedge cp) * P(\sim ol | cf) + P(\sim cf | \sim tf \wedge cp) * P(\sim ol | \sim cf))] \} \\ &= \alpha \{0,3 * [(0,6 * 0,3) * (0,05 * 0,7 + 0,95 * 0,2) + (0,4 * 0,6) * (0,1 * 0,7 + 0,9 * 0,2)] \} \\ &= \alpha 0,03015 \end{aligned}$$

$$\alpha = 0,09585 + 0,03015 = 0,126$$

$$P(ol | la \wedge cp) = 0,09585 / 0,126 = 0,761$$

$$P(\sim ol | la \wedge cp) = 0,03015 / 0,126 = 0,239$$

Outros tipos de inferência



- Raciocínio causal:

- Utilizando a probabilidade condicional e a regra da cadeia:

- $P(cf | cp) = P(cf, tf | cp) + P(cf, \sim tf | cp)$

- $P(cf | cp) = P(cf | tf, cp) * P(tf | cp) + P(cf | \sim tf, cp) * P(\sim tf | cp)$

- $P(cf | cp) = P(cf | tf, cp) * P(tf) + P(cf | \sim tf, cp) * P(\sim tf)$

- Raciocínio de diagnóstico:


- Utilizando a regra de Bayes:

- $P(cp | cf) = (P(cf | cp) * P(cp)) / P(cf)$


- $P(cf | cp) \Rightarrow$ pode ser calculado por raciocínio causal

- $P(cp) \Rightarrow$ na rede


- $P(cf) \Rightarrow$ por marginalização ou enumeração




Outros tipos de inferência



- Seja y uma variável booleana, e o único pai de x . Se a evidência e não contém qualquer descendente de x :
 - $P(x | e) = P(x | y, e) * P(y | e) + P(x | \sim y, e) * P(\sim y | e)$
 - $P(x | e) = P(x | y) * P(y | e) + P(x | \sim y) * P(\sim y | e)$
 - $P(x | e) = P(x | y) * P(y | e) + P(x | \sim y) * (1 - P(y | e))$
- Exemplo:
 - $P(ol | la) = P(ol | cf) * P(cf | la) + P(ol | \sim cf) * (1 - P(cf | la))$
 - ...
 - $P(cf | la) \Rightarrow cf$ tem mais de um pai



Outros tipos de inferência




- Seja y_1, y_2, \dots, y_n variáveis pais de x . Onde y_i tem o domínio D_i . Se a evidência e não contém qualquer descendente de x :

$$P(x|e) = \sum_{d \in D} P(x|y = d \wedge e) * P(y = d|e)$$


$$P(x|e) = \sum_{d \in D} P(x|y = d) * P(y = d|e)$$

- Exemplo:

- $P(cf | la) = P(cf | tf, cp) * P(tf, cp | la) + P(cf | tf, \sim cp) * P(tf, \sim cp | la) + P(cf | \sim tf, cp) * P(\sim tf, cp | la) + P(cf | \sim tf, \sim cp) * P(\sim tf, \sim cp | la)$




Fatores



- Um **fator** é a representação de uma função de uma tupla de variáveis aleatórias em um número.
- Escreveremos fator f sobre as variáveis X_1, \dots, X_j como $f(X_1, \dots, X_j)$.
- Podemos atribuir algumas ou todas as variáveis de um fator:
 - $f(X_1 = v_1, X_2, \dots, X_j)$, onde $v_1 \in \text{dom}(X_1)$, é um fator sobre X_2, \dots, X_j .
 - A equação anterior também é escrita como $f(X_1, X_2, \dots, X_j)_{X_1 = v_1}$.
 - $f(X_1 = v_1, X_2 = v_2, \dots, X_j = v_j)$ é um número que é o valor de f onde cada X_i tem valor v_i .

Exemplo de Fatores



$r(X, Y, Z):$

X	Y	Z	val
t	t	t	0.1
t	t	f	0.9
t	f	t	0.2
t	f	f	0.8
f	t	t	0.4
f	t	f	0.6
f	f	t	0.3
f	f	f	0.7

$r(X=t, Y, Z):$


Y	Z	val
t	t	0.1
t	f	0.9
f	t	0.2
f	f	0.8

$r(X=t, Y, Z=f):$

Y	val
t	0.9
f	0.8

$r(X=t, Y=f, Z=f) = 0.8$

Exemplo de Fatores – Representação matricial




$$r(X, Y, Z) = \left\{ \begin{array}{l} \left[\begin{array}{cc} x, y, z & x, y, \sim z \\ x, \sim y, z & x, \sim y, \sim z \end{array} \right] = \left[\begin{array}{cc} 0.1 & 0.9 \\ 0.2 & 0.8 \end{array} \right] \\ \left[\begin{array}{cc} \sim x, y, z & \sim x, y, \sim z \\ \sim x, \sim y, z & \sim x, \sim y, \sim z \end{array} \right] = \left[\begin{array}{cc} 0.4 & 0.6 \\ 0.3 & 0.7 \end{array} \right] \end{array} \right\}$$

$$r(x, Y, Z) = \left\{ \left[\begin{array}{cc} x, y, z & x, y, \sim z \\ x, \sim y, z & x, \sim y, \sim z \end{array} \right] = \left[\begin{array}{cc} 0.1 & 0.9 \\ 0.2 & 0.8 \end{array} \right] \right\}$$

$$r(x, Y, \sim z) = \left\{ \left[\begin{array}{c} x, y, \sim z \\ x, \sim y, \sim z \end{array} \right] = \left[\begin{array}{c} 0.9 \\ 0.8 \end{array} \right] \right\}$$

$$r(x, \sim y, \sim z) = \{ [x, \sim y, \sim z] = [0.8] \}$$

Multiplicando Fatores



- O produto do fator $f_1(X, Y)$ e $f_2(Y, Z)$, onde Y são as variáveis em comum, é o fator $(f_1 \times f_2)(X, Y, Z)$ definido por:
 - $(f_1 \times f_2)(X, Y, Z) = f_1(X, Y) f_2(Y, Z)$

f_1 :

A	B	val
t	t	0.1
t	f	0.9
f	t	0.2
f	f	0.8


f_2 :

B	C	val
t	t	0.3
t	f	0.7
f	t	0.6
f	f	0.4

$f_1 \times f_2$:

A	B	C	val
t	t	t	0.03
t	t	f	0.07
t	f	t	0.54
t	f	f	0.36
f	t	t	0.06
f	t	f	0.14
f	f	t	0.48
f	f	f	0.32

Multiplicando Fatores – representação matricial




$$f_1(A, B) = \begin{cases} \begin{bmatrix} a, b & a, \sim b \\ \sim a, b & \sim a, \sim b \end{bmatrix} = \begin{bmatrix} 0.1 & 0.9 \\ 0.2 & 0.8 \end{bmatrix} \end{cases}$$

$$f_2(B, C) = \begin{cases} \begin{bmatrix} b, c & \sim b, c \\ b, \sim c & \sim b, \sim c \end{bmatrix} = \begin{bmatrix} 0.3 & 0.6 \\ 0.7 & 0.4 \end{bmatrix} \end{cases}$$

$$f_1 \times f_2 = f_B(A, B, C) = \begin{cases} \begin{bmatrix} \begin{bmatrix} a, b, c & \sim a, b, c \\ a, b, \sim c & \sim a, b, \sim c \end{bmatrix} = \begin{bmatrix} 0.03 & 0.6 \\ 0.07 & 0.14 \end{bmatrix} \\ \begin{bmatrix} a, \sim b, c & \sim a, \sim b, c \\ a, \sim b, \sim c & \sim a, \sim b, \sim c \end{bmatrix} = \begin{bmatrix} 0.54 & 0.48 \\ 0.36 & 0.32 \end{bmatrix} \end{cases}$$

Sumarizando variáveis




- Podemos **sumarizar** uma variável, digamos X_1 com domínio $\{v_1, \dots, v_k\}$, de um fator $f(X_1, \dots, X_j)$, resultando em um fator sobre X_2, \dots, X_j definido por:

$$\left(\sum_{X_1} f\right)(X_2, \dots, X_j)$$

$$f(X_1 = v_1, X_2, \dots, X_j) + \dots + f(X_1 = v_k, X_2, \dots, X_j)$$

Sumarizando uma variável - Exemplo




f_3 :

A	B	C	val
t	t	t	0.03
t	t	f	0.07
t	f	t	0.54
t	f	f	0.36
f	t	t	0.06
f	t	f	0.14
f	f	t	0.48
f	f	f	0.32

$\sum_B f_3$:


A	C	val
t	t	0.57
t	f	0.43
f	t	0.54
f	f	0.46

Sumarizando uma variável – representação matricial



$$f_B(A, B, C) = \begin{cases} \begin{bmatrix} a, b, c & \sim a, b, c \\ a, b, \sim c & \sim a, b, \sim c \end{bmatrix} = \begin{bmatrix} 0.03 & 0.6 \\ 0.07 & 0.14 \end{bmatrix} \\ \begin{bmatrix} a, \sim b, c & \sim a, \sim b, c \\ a, \sim b, \sim c & \sim a, \sim b, \sim c \end{bmatrix} = \begin{bmatrix} 0.54 & 0.48 \\ 0.36 & 0.32 \end{bmatrix} \end{cases}$$
$$f_{\bar{B}}(A, B, C) = \begin{cases} \begin{bmatrix} a, b, c & a, \sim b, c \\ \sim a, b, \sim c & \sim a, \sim b, \sim c \end{bmatrix} = \begin{bmatrix} 0.57 & 0.54 \\ 0.43 & 0.46 \end{bmatrix} \end{cases}$$

Probabilidades posteriores como conjunções




- Se queremos computar a probabilidade a posterior de Z dado a evidência $Y_1 = v_1 \wedge \dots \wedge Y_j = v_j$:


$$\begin{aligned} & P(Z|Y_1 = v_1, \dots, Y_j = v_j) \\ &= \frac{P(Z, Y_1 = v_1, \dots, Y_j = v_j)}{P(Y_1 = v_1, \dots, Y_j = v_j)} \\ &= \frac{P(Z, Y_1 = v_1, \dots, Y_j = v_j)}{\sum_Z P(Z, Y_1 = v_1, \dots, Y_j = v_j)}. \end{aligned}$$

- Assim, a computação se reduz a probabilidade de $P(Z, Y_1 = v_1, \dots, Y_j = v_j)$.
- Normalizamos ao final.

Exemplo de probabilidade conjunta usando fatores






Construindo Redes de Crença



- Para representar um domínio em uma rede de crença, precisamos considerar:
 - Quais são as variáveis relevantes?
 - Quais valores estas variáveis deveriam ter?
 - Qual é o relacionamento entre elas?
 - Isto deveria ser expressado em termos de influência local?
 - Como os valores de uma variável dependem das variáveis que localmente a influenciam (seus pais)?
 - Isto é expressado em termos de tabelas de probabilidade condicional.

Como as variáveis devem ser colocadas na rede



- Qualquer uma das redes pode representar a mesma distribuição conjunta total
 - Alguma pode deixar de representar alguma independência condicional, e, desta forma, especificar muitos números desnecessários.