

Conhecimento Incerto

Redes de Crença

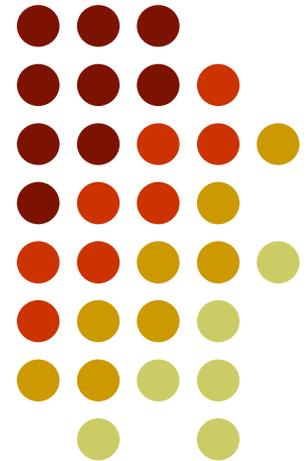
Profa. Josiane M. P. Ferreira

Texto base:

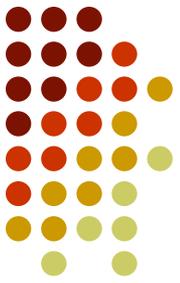
David Poole, Alan Mackworth e Randy Goebel -
“*Computational Intelligence – A logical approach*” – cap 10.

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

setembro/2007

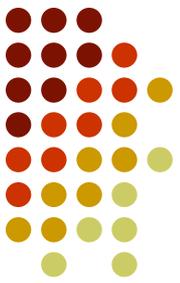


Independência entre as variáveis



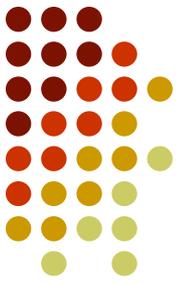
- Os axiomas de probabilidade são fracos
 - Exemplo: Se existem n variáveis binárias em um domínio.
 - Existem $2^n - 1$ diferentes números para serem associados para dar uma distribuição de probabilidade completa para este domínio.
- Para ser capaz de determinar qualquer probabilidade:
 - Temos que começar com um enorme banco de dados de probabilidades condicionais ou probabilidades dos mundos possíveis.
 - Para resolver isso podemos utilizar a idéia de **independência**:
 - O conhecimento na verdade de uma proposição não afeta a crença em outra.
 - O conhecimento na verdade da *cárie* não afeta a crença em *Tempo=chuvoso*.

Independência entre as variáveis

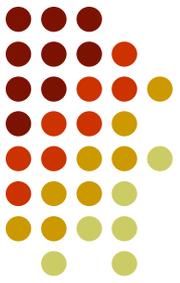


- Suponha um domínio com as variáveis *DorDeDente*, *UsarAlicate* e *Cárie* – a distribuição de probabilidade completa tem 8 valores.
- Suponha que acrescentamos mais a variável *Tempo* ao domínio.
- A distribuição de probabilidade completa se torna $P(\text{DorDeDente}, \text{UsarAlicate}, \text{Cárie}, \text{Tempo})$, que tem 32 entradas.
 - Pode ser representada por 4 tabelas, uma para cada valor de *Tempo*.
- Como $P(\text{dordedente}, \text{usaralicate}, \text{cárie}, \text{Tempo}=\text{nublado})$ e $P(\text{dordedente}, \text{usaralicate}, \text{cárie})$ estão relacionadas?
 - = $P(\text{Tempo}=\text{nublado} \mid \text{dordedente}, \text{usaralicate}, \text{cárie})$
 - = $P(\text{Tempo}=\text{nublado}) P(\text{dordedente}, \text{alicate}, \text{cárie})$

Independência entre as variáveis

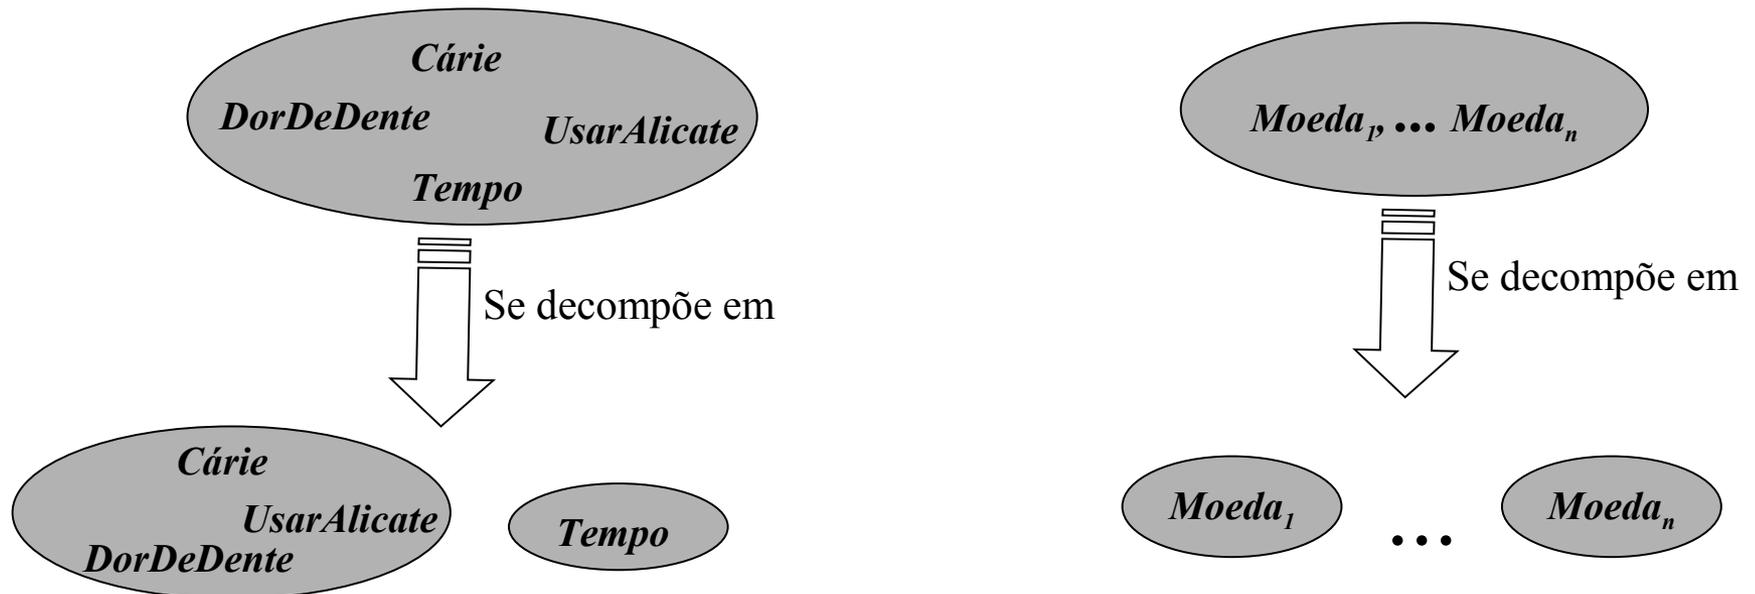


- A distribuição de probabilidade completa $P(\text{dordedente}, \text{usaralicate}, \text{cárie}, \text{Tempo}=\text{nublado})$
 - E a tabela de 32 entradas pode ser separada em uma de 4 entradas para *Tempo* e outra de 8 para as outras variáveis.
- Isto é chamado de **independência**: o tempo é independente dos problemas dentários de alguém.
- A independência entre as proposições a e b pode ser escrita como:
 - $P(a | b) = P(a)$ ou $P(b | a) = P(b)$ ou $P(a \wedge b) = P(a)P(b)$

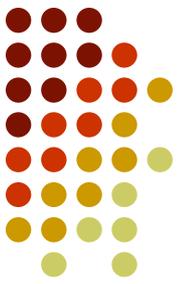


Independência

- As asserções de independência em geral se baseiam no **conhecimento do domínio**.
- **Reduzem** drasticamente a quantidade de informações necessárias para especificar a distribuição de probabilidade completa.



Independência Condicional

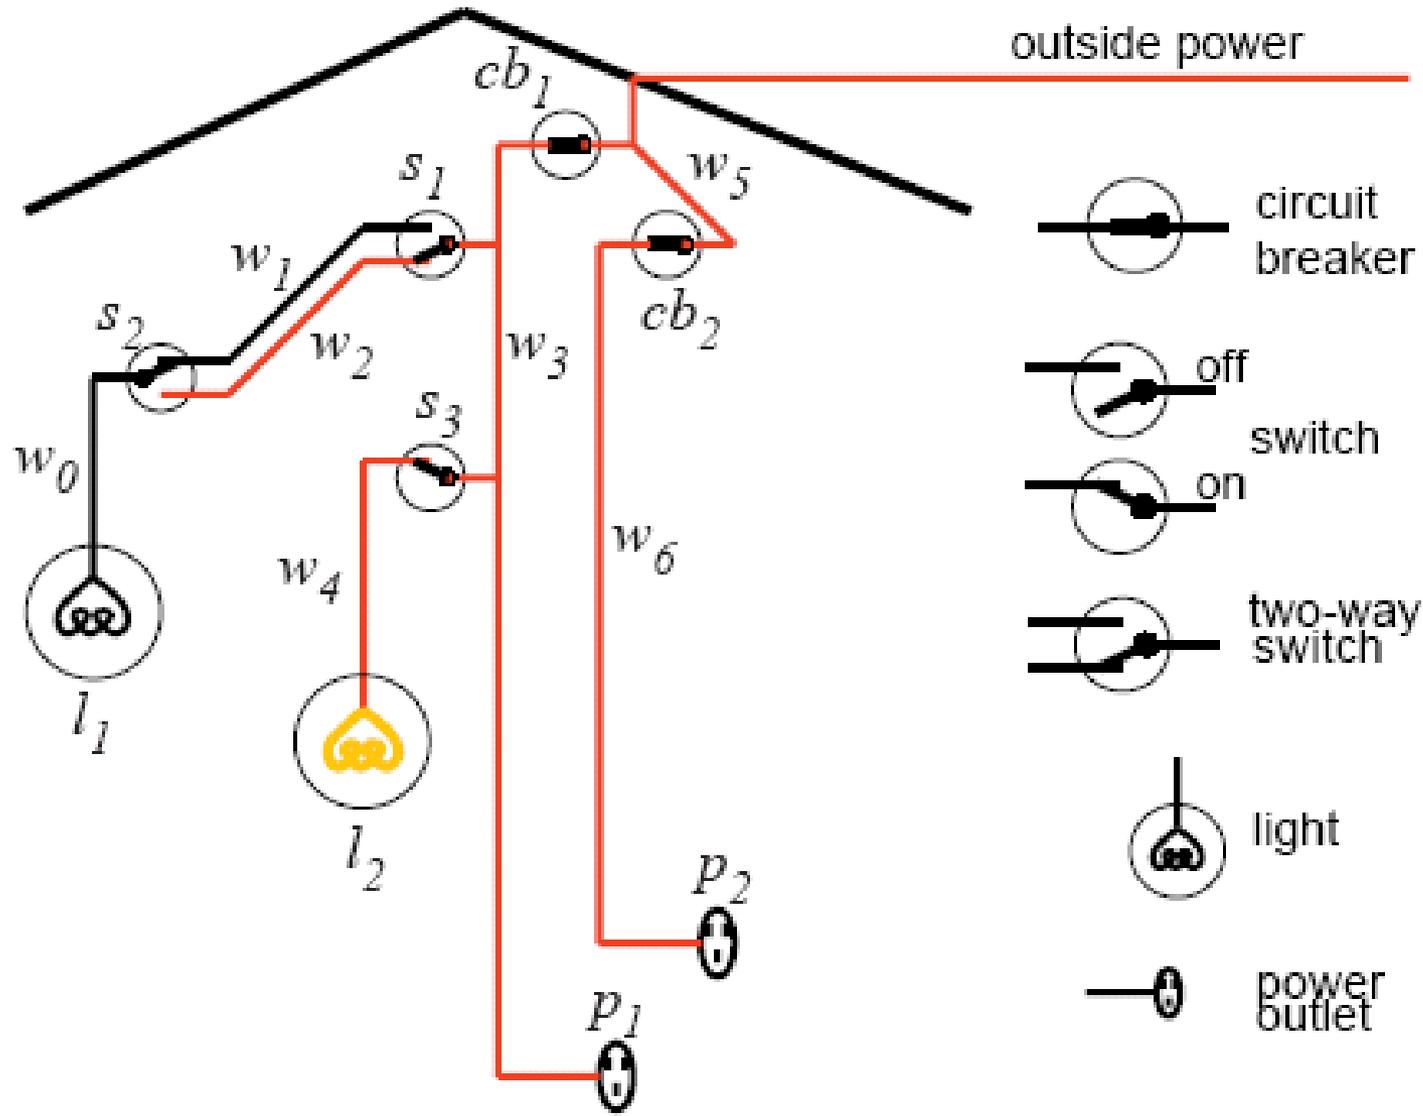
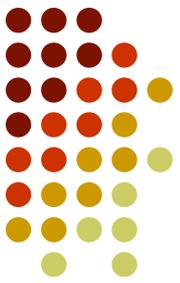


- Acontece quando as variáveis são independentes, **dada** uma (ou um conjunto de) evidência(s).
- Uma variável randômica X é independente de uma variável randômica Y **dada** uma variável randômica Z se, para todo $x_i \in \text{dom}(X)$, $y_j \in \text{dom}(Y)$ e $z_m \in \text{dom}(Z)$,

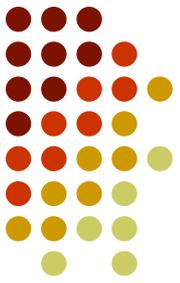
$$\begin{aligned} P(X = x_i | Y = y_j \wedge Z = z_m) \\ &= P(X = x_i | Y = y_k \wedge Z = z_m) \\ &= P(X = x_i | Z = z_m). \end{aligned}$$

- Isto é, o conhecimento dos valores de Y não afetam a crença do agente no valor de X , dado o valor de Z .

Exemplo de domínio (Assistente de diagnóstico)

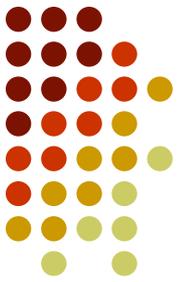


Exemplos de independência condicional



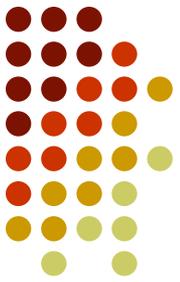
- A identidade da rainha da Inglaterra é independente de se a luz $I1$ está acesa dado se existe energia de fora.
- Se existe alguém na sala é independente de se a luz $I2$ está acesa dado a posição da chave $s3$.
- Se a luz $I1$ está acesa é independente da posição da chave $s2$ dado se existe energia no fio $w0$.
- Qualquer outra variável pode ser independente se a luz $I1$ está acesa dado se existe energia no fio $w0$ e o estado da luz $I1$ (se ela está ok ou quebrada).

Idéia das Redes de Crença

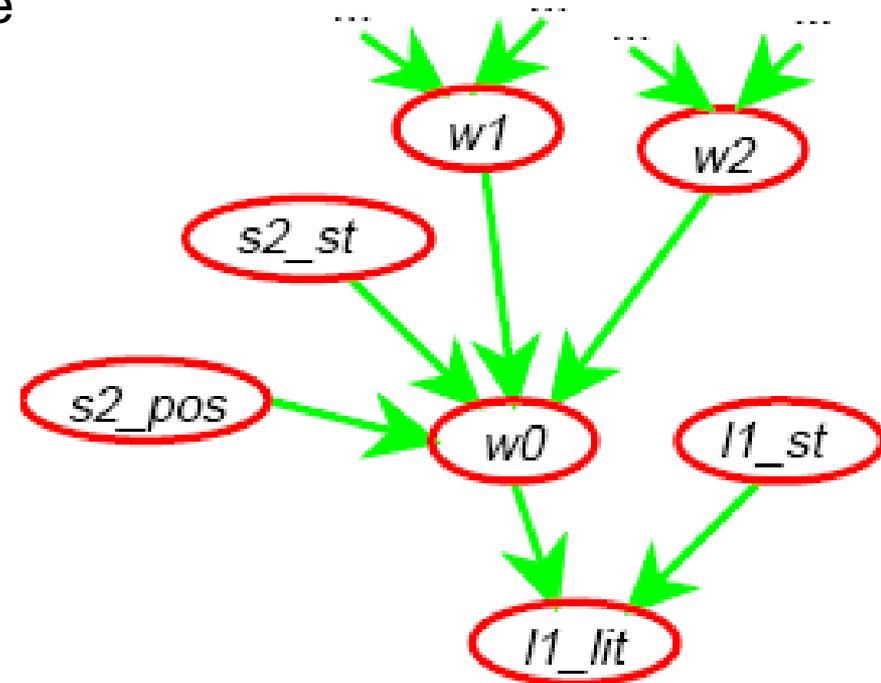


- Dado uma variável randômica v , existe um pequeno conjunto de variáveis que afetam diretamente o valor de v .
 - Qualquer outra variável é independente de v , dado os valores para as variáveis que afetam v diretamente (variáveis **pais**)
- Este princípio de localidade é explorado nas **Redes de Crença** 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.

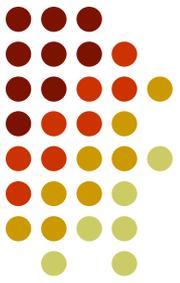
Idéia das Redes de Crença



- Se $l1$ está acesa (lit_{l1}) depende **somente** do estado da luz ($l1_{st}$) e se existe energia no fio $w0$.
- Assim, $l1_{lit}$ é independente de outras variáveis dado $l1_{st}$ e $w0$.
 - Em uma rede de crença, $w0$ e $l1_{st}$ **são pais** de $l1_{lit}$.
- 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 $s2$ ($s2_{st}$).

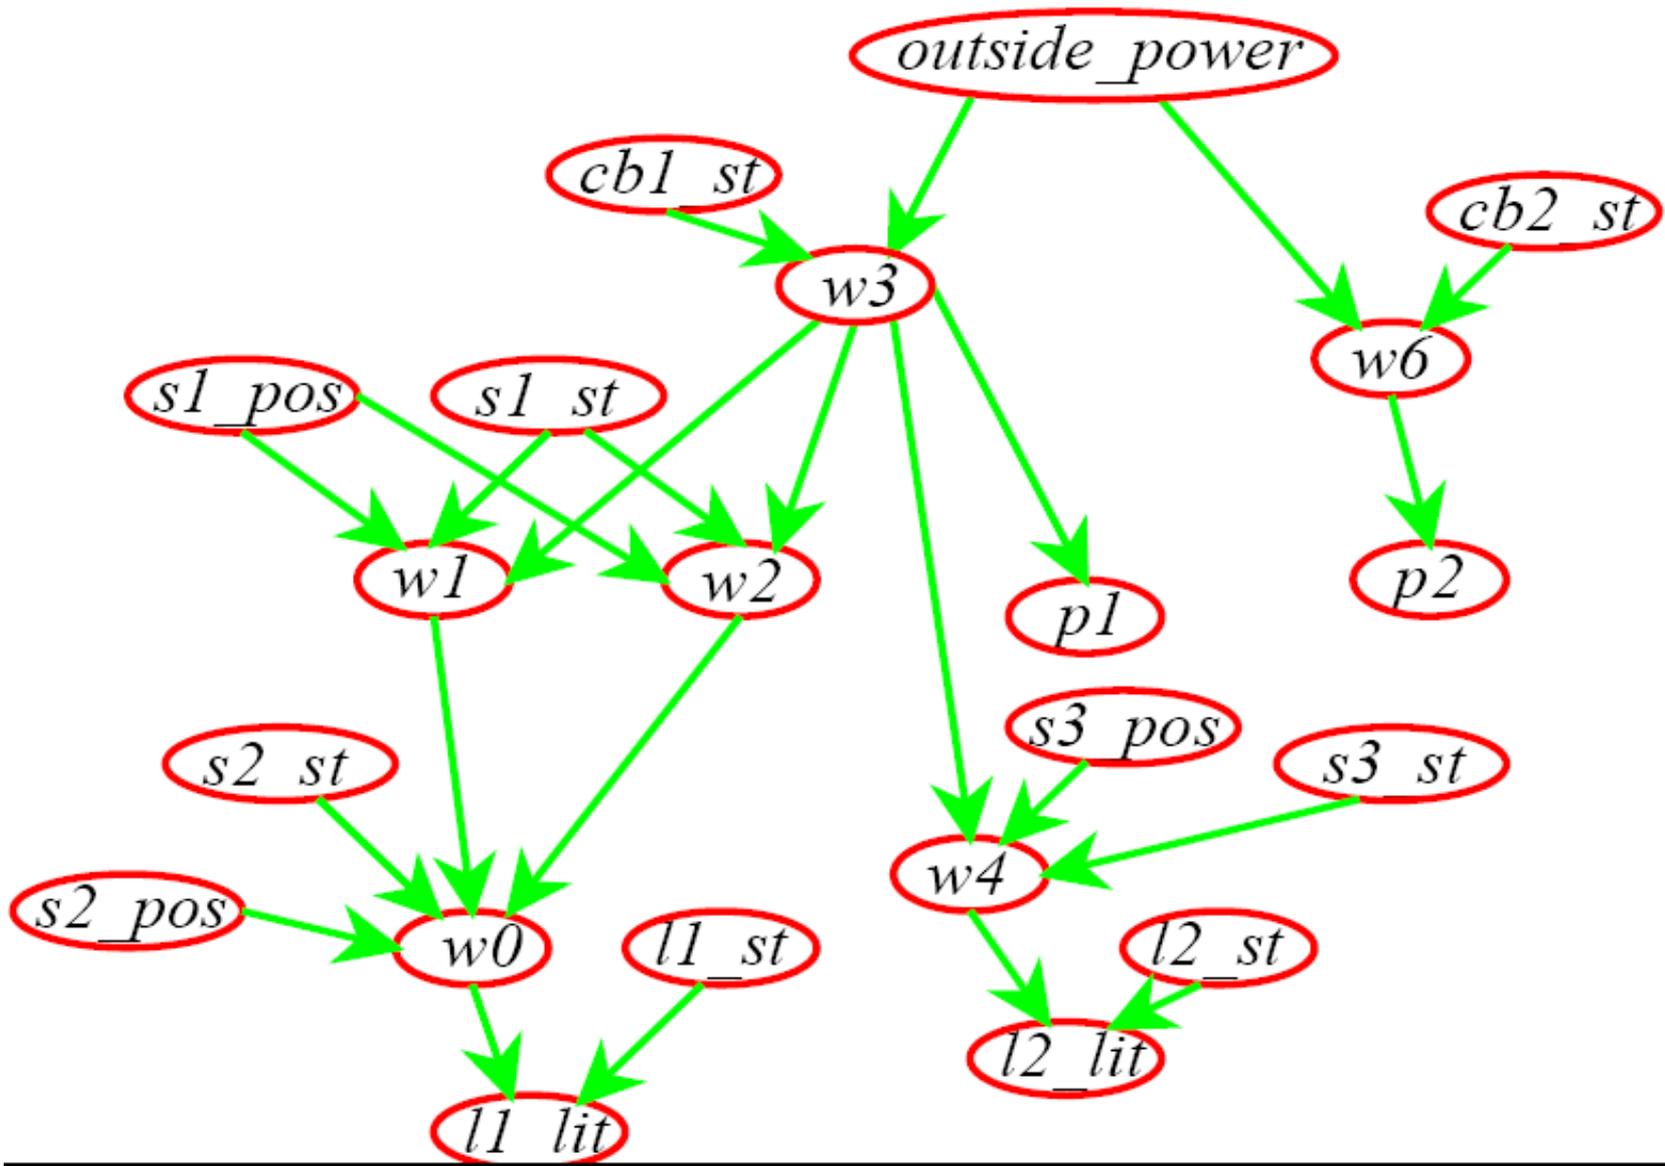
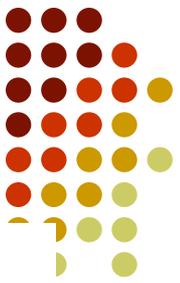


Redes de Crença

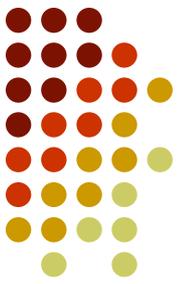


- São DAGs onde os nós são variáveis randômicas.
 - Os pais de um nó n são aquelas variáveis das quais n depende diretamente.
- São uma representação gráfica de dependência e independência.
 - Uma variável é independente dos seus não-descendentes, dados seus pais.
- São constituídas por:
 - Um grafo 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

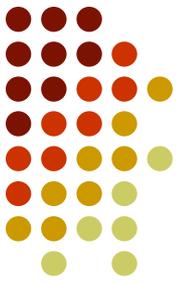


Exemplo de uma rede de crença - continuação



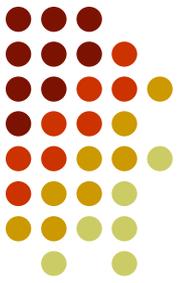
- O domínio das variáveis:
 - w_0, \dots, w_6 tem o domínio $\{live, dead\}$
 - $s1_pos, s2_pos,$ e $s3_pos$ tem o domínio $\{up, down\}$
 - $s1_st,$ tem $\{ok, upside_down, short, intermittent, broken\}$
- Probabilidade condicional, incluindo os valores para:
 - $P(w_1 = live \mid s1_pos = up \wedge s1_st = ok \wedge w_3 = live)$
 - $P(w_1 = live \mid s1_pos = up \wedge s1_st = ok \wedge w_3 = dead)$
 - ... $2 * 5 * 2 = 20$ valores
 - $P(s1_pos = up) \Rightarrow 2$ valores
 - $P(s1_st = upside_down) \Rightarrow 5$ valores

Construindo redes de crença

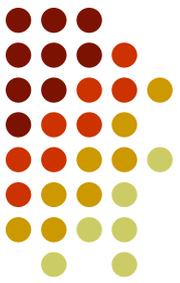


- Para representar um domínio em uma rede de crença, precisamos considerar:
 - Quais são as variáveis relevantes?
 - Quais valores estas variáveis deveriam ter?
 - Qual é o relacionamento entre elas?
 - Isto deveria ser expressado em termos de influência local?
 - Como os valores de uma variável dependem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

Utilizando redes de crença

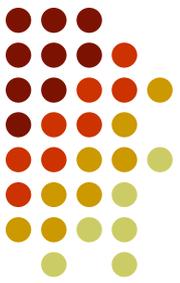


- Ordene as variáveis de forma que os nós filhos venham antes de seus pais: X_1, \dots, X_n .
- Utilizando a regra da cadeia:
- $$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | X_1, \dots, X_{i-1})$$
- Os pais π_{X_i} de X_i são aqueles sucessores de X_i que tornam X_i independente dos outros sucessores.
- Assim,
- $$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \pi_{X_i})$$



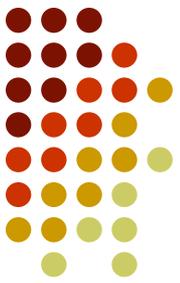
Redes Bayesianas - Exemplo

- 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).



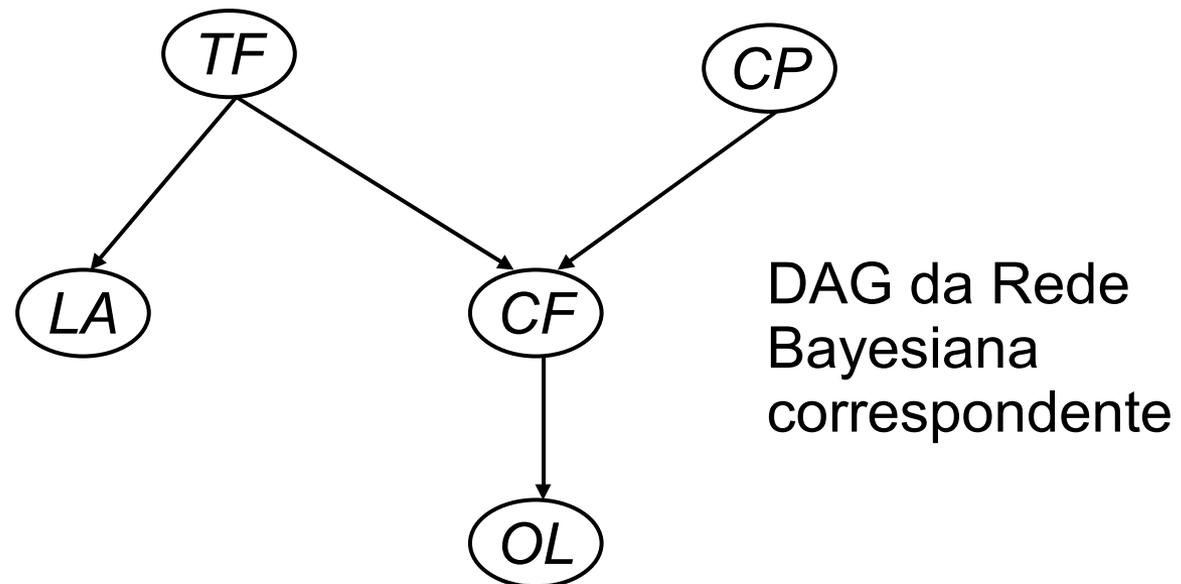
Redes Bayesianas - Exemplo

- Vamos definir as variáveis booleanas aleatórias:
 - *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*.

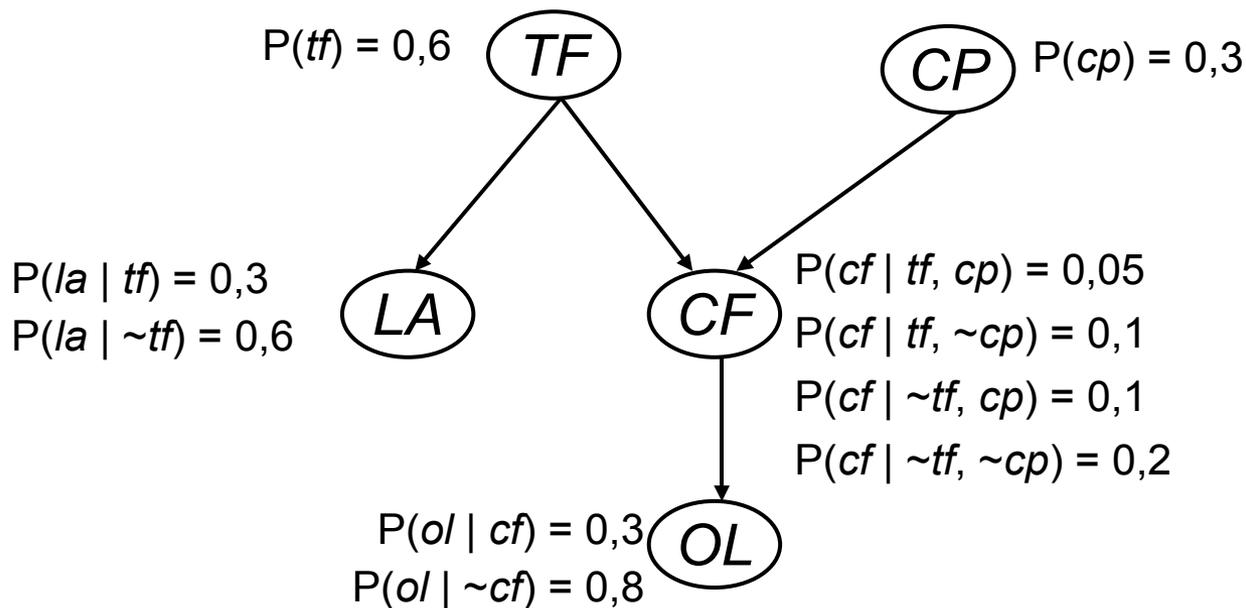
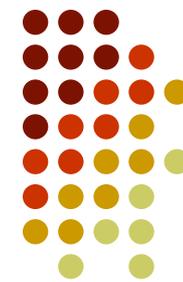


Redes Bayesianas - Exemplo

- 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 Bayesianas – informações quantitativas



Total de **10** probb.

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

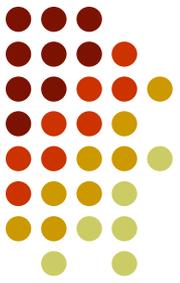
Esta redução é devido ao fato de muitas v.a. serem **condicionalmente independentes**

Independência em redes de crença



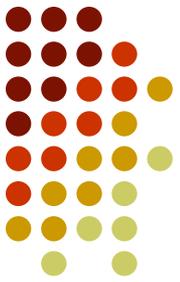
- Duas variáveis que **não** são conectadas diretamente por um arco ainda **podem** afetar uma a outra.
 - Exemplo: *CP* e *OL* não são ligadas diretamente por um arco, mas *CP* afeta *OL* indiretamente.
- Relações condicionais de independência representadas podem ser facilmente visualizadas na rede de Bayes:
 - 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, $P(OL \mid CP, CF, TF, LA) = P(OL \mid CF)$.

Calculando probabilidades conjuntas



- 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 .
- $P(cp, \sim tf, cf, \sim la, ol) = P(ol, \sim la, cf, \sim tf, cp)$ (filhos antes dos pais) (1)
- $= P(ol | \sim la, cf, \sim tf, cp) * P(\sim la, cf, \sim tf, cp)$ ($\{OL, LA, TF, CP\}, \{CF\}$)
- $= P(ol | cf) * P(\sim la, cf, \sim tf, cp)$ (1)
- $= P(ol | cf) * P(\sim la | cf, \sim tf, cp) * P(cf, \sim tf, cp)$ ($\{LA, CF, CP\}, \{TF\}$)
- $= P(ol | cf) * P(\sim la | \sim tf) * P(cf, \sim tf, cp)$ (1)

Calculando probabilidades conjuntas



$$= P(ol | cf) * P(\sim la | \sim tf) * P(cf | \sim tf, cp) * P(\sim tf, cp) \quad (1)$$

$$= P(OL | CF) * P(\sim LA | \sim TF) * P(CF | \sim TF, CP) * \mathbf{P(\sim TF | CP)} * P(CP) \quad (\{TF, CP\})$$

$$= P(OL | CF) * P(\sim LA | \sim TF) * P(CF | \sim TF, CP) * P(\sim TF) * P(CP)$$

$$= (0,3) (1-0,6) (0,1) (1-0,6) (0,3) = \mathbf{0,00144}$$

- Onde todos os valores numéricos estão disponíveis diretamente na rede (uma vez que $P(\sim A|B) = 1 - P(A|B)$).