

# Conhecimento Incerto

## Introdução


Profa. Josiane M. P. Ferreira

Texto base:

David Poole, Alan Mackworth e Randy Goebel -  
“*Computational Intelligence – A logical approach*” – cap10.

Stuart Russel e Peter Norving - “Inteligência Artificial” - cap 13.

setembro/2008



# Usando conhecimento incerto



- Agentes **não** tem conhecimento completo sobre o mundo.
- Agentes necessitam fazer decisões baseadas na incerteza deles sobre o mundo.
- Supor como o mundo é não é o bastante.
  - Exemplo: colocar o sinto de segurança.
- Um agente necessita raciocinar sobre esta incerteza.
- Quando um agente faz um ação sobre incerteza ele está apostando no resultado => probabilidade.

# Probabilidade



- Probabilidade é a medida de crença de um agente em alguma proposição – **probabilidade subjetiva**.
- Exemplo: A probabilidade de um pássaro voar é medida de crença do agente na habilidade de voar de um indivíduo, baseado somente no conhecimento de que o indivíduo é um pássaro.
  - Outros agentes podem ter diferentes probabilidades.
    - Eles podem ter tido diferentes experiências com pássaros ou diferentes conhecimentos sobre este pássaro em particular.
  - A crença de uma agente na habilidade de um pássaro voar é afetada pelo que o agente conhece sobre aquele pássaro.

# Probabilidade subjetiva



- Ao invés de usar probabilidade como uma medida sobre uma população (ou seqüência de eventos)
- A probabilidade de um agente pode ser vista como uma medida sobre todos os mundos que são possíveis dado o conhecimento do agente sobre uma situação particular
  - Em cada mundo possível, ou o pássaro voa ou não voa
- Por esta razão agentes diferentes podem ter probabilidades diferentes para a mesma questão
  - O agente necessita da teoria da probabilidade porque ele não sabe em qual dos mundos possíveis ele está
- **Subjetivo** neste contexto não significa arbitrário, mas “pertencente ao assunto”

# Probabilidade subjetiva – exemplo




- Três agentes:  $A$ ,  $B$  e  $C$  e um *dado* que foi lançado.
- Supõe que  $A$  observa que o resultado é “6” e conta a  $B$  que o resultado é par, mas  $C$  não sabe de nada.
- Neste caso:
  - $A$  tem uma probabilidade = 1 do resultado ser “6”.
  - **$B$  tem uma probabilidade =  $1/3$  do resultado ser “6”.**
  - **$C$  tem uma probabilidade =  $1/6$  do resultado ser “6”.**
- Eles têm diferentes probabilidades porque têm diferentes conhecimentos sobre a mesma situação.

# Medidas de crença numéricas



- A teoria da probabilidade pode ser definida como o estudo de como o conhecimento afeta a crença.
- A crença em uma proposição,  $f$ , pode ser medida em termos de um número entre 0 e 1 – esta é a **probabilidade de  $f$** .
  - A probabilidade  $f = 0$  significa que acredita-se que  $f$  seja definitivamente falsa.
  - A probabilidade  $f = 1$  significa que acredita-se que  $f$  seja definitivamente verdadeira.
  - Usar 0 e 1 é puramente uma convenção.
- $f$  ter uma probabilidade entre 0 e 1 **não** significa que  $f$  é verdadeira em algum grau, mas que o agente é ignorante sobre o seu valor verdade.
  - Probabilidade é uma medida da ignorância do agente.

# Variáveis randômicas (ou aleatória)



- Uma **variável randômica** é um termo na linguagem que pode assumir uma quantidade de valores diferentes.
  - São chamadas randômicas porque tipicamente os agentes não conhecem o valor das variáveis.
  - Assim, podemos nos referir a variáveis mesmo que não saibamos seus valores.
- O **domínio** de uma variável  $X$ , escrito como  $dom(X)$ , é o conjunto de valores que  $X$  pode assumir.
  - Os elementos do domínio de  $X$  são exclusivos e exaustivos.
  - Exemplo: a variável *Cárie* tem como domínio (*true*, *false*).
  - De acordo com o domínio, uma variável randômica pode ser **booleana, discreta ou contínua**.

# Tipos de variáveis randômicas



- **Booleanas:** tem o domínio  $\langle true, false \rangle$ .
  - Normalmente  $Cárie = true$  é escrito somente *cárie* e  $Cárie = false$  como  $\sim cárie$
  - $P(cárie)$  é probabilidade de  $Cárie = true$ .
- **Discretas:** admitem valores de um domínio *enumerável*.
  - Exemplo: a variável *Tempo* pode ter um domínio como  $dom(ensolarado, chuvoso, nevoento, nublado)$
- **Contínuas:** assumem valores a partir dos números reais.
  - O domínio pode ser a linha real inteira ou um intervalo como  $[0, 1]$ .
  - Exemplo:
    - A afirmação  $PreçoDoLeite=1,18$  afirma que a variável randômica *PreçoDoLeite* tem o valor exato 1,18.
    - $P(PreçoDoLeite=1,18)$  é a probabilidade do preço do leite ser exatamente 1,18.



# Variáveis randômicas complexas



- Sejam  $X_1, \dots, X_n$  *variáveis randômicas*.
- Uma tupla de variáveis randômicas  $\langle X_1, \dots, X_n \rangle$  é uma **variável randômica complexa**.
- O domínio da variável randômica complexa é o produto cartesiano dos domínios de seus componentes:
  - $dom(\langle X_1, \dots, X_n \rangle) = dom(X_1) \times \dots \times dom(X_n)$ .
  - A tupla sempre é escrita como  $\langle X_1, \dots, X_n \rangle$ .
- Uma **proposição** é uma fórmula booleana feita das associações de valores a variáveis.

# Variáveis randômicas complexas - exemplo



- Suponha um sistema de diagnóstico médico onde existem  $n$  possíveis doenças que o paciente pode ter ou não.
- A variável randômica que representa o estado do paciente associa uma das  $2^n$  doenças complexas ao paciente.
  - $EstadoPaciente = \langle Gripe, Dengue, Meningite \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle False, False, False \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle True, False, False \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle False, True, False \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle True, True, False \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle False, False, True \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle True, False, True \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle False, True, True \rangle$
  - $\langle Gripe, Dengue, Meningite \rangle = \langle True, True, True \rangle$

# Semântica dos mundos possíveis



- Um **mundo possível** é uma associação de exatamente um valor para cada variável randômica.
- Seja  $\Omega$  o conjunto de todos os mundo possíveis.
- Se  $w \in \Omega$  e  $f$  é uma fórmula,  $f$  é verdadeiro em  $w$  (escrito como  $w \models f$ ) é definido como:
  - $w \models X = x$  se  $w$  associa o valor  $x$  para a variável  $X$ .
  - $w \models f \wedge g$  se  $w \models f$  e  $w \models g$ .
  - $w \models f \vee g$  se  $w \models f$  ou  $w \models g$  (ou ambos).
  - $w \models \neg f$  se  $w \not\models f$ .

# Semântica de probabilidade: caso finito



- Para um número finito de mundos possíveis:
  - Define uma medida não negativa  $\mu(w)$  para mundo possível  $w$  de forma que a soma das medidas dos mundos possíveis seja 1.
    - A medida especifica quanto o agente pensa que o mundo  $w$  é semelhante ao mundo real.
  - A **probabilidade da proposição  $f$**  é definida pela soma das medidas dos mundos possíveis nos quais  $f$  é verdadeira:

$$P(f) = \sum_{w \models f} \mu(w)$$

# Axiomas de probabilidade: caso finito




- Quatro axiomas definem o que segue de um conjunto de probabilidades:
  - **Axioma 1:**  $P(f) = P(g)$  se  $f \leftrightarrow g$  é uma tautologia.
    - Isto é, se  $f$  e  $g$  são logicamente equivalentes, elas tem a mesma probabilidade.
  - **Axioma 2:**  $0 \leq P(f)$  para qualquer fórmula  $f$ .
  - **Axioma 3:**  $P(\tau) = 1$  se  $\tau$  é uma tautologia.
  - **Axioma 4:**  $P(f \vee g) = P(f) + P(g)$  se  $\neg(f \wedge g)$  é uma tautologia.
    - $f$  e  $g$  são mutuamente exclusivos.
    - A probabilidade da disjunção pode ser calculada pela soma da probabilidade dos disjuntos.
- Estes axiomas são corretos e completos com respeito à semântica.

# Axiomas de probabilidade: caso finito



- Negação de uma proposição:
  - $P(\neg f) = 1 - P(f)$ .
- Raciocinando por casos:
  - $P(f) = P(f \wedge g) + P(f \wedge \neg g) \Rightarrow g$  tem os valores verdadeiro ou falso.
  - É a **probabilidade marginal de  $f$**  (ou marginalização de  $f$ ).
- Se  $v$  é uma variável randômica com domínio  $D$ , então para todas as fórmulas  $f$ ,
$$P(f) = \sum_{d \in D} P(f \wedge v = d).$$
  - Marginalização de  $f$ .
- Disjunção para disjuntos não exclusivos:
  - $P(f \vee g) = P(f) + P(g) - P(f \wedge g)$ .


# Distribuição de probabilidade



- A **distribuição de probabilidade** sobre uma variável randômica  $X$  é uma função  $dom(X) \rightarrow [0, 1]$ 
  - É a probabilidade para todos os valores que  $X$  pode assumir (domínio).
  - Exemplo: suponha a variável randômica  $Tempo$ . A distribuição de probabilidade para tempo  $P(Tempo)$  é:
    - $P(Tempo=ensolarado) = 0,7$
    - $P(Tempo=nublado) = 0,08$
    - $P(Tempo=chuvoso) = 0,2$
    - $P(Tempo=nevoento) = 0,02$
- Isto também inclui o caso onde temos tuplas de variáveis (distribuição de probabilidade conjunta).
  - Por exemplo:  $P(X, Y, Z)$  significa  $P(\langle X, Y, Z \rangle)$ .

$$P(Tempo = ensolarado) = \sum_{w | (Tempo = ensolarado)} \mu(w)$$

# Distribuição de probabilidade Conjunta



- Exemplo:  $P(\text{Tempo}, \text{Cárie})$

$$P(\text{Tempo}=\text{ensolarado}, \text{carie}) = 0,3 \quad P(\text{Tempo}=\text{ensolarado}, \sim\text{carie}) = 0,2$$

$$P(\text{Tempo}=\text{chuvoso}, \text{carie}) = 0,06 \quad P(\text{Tempo}=\text{chuvoso}, \sim\text{carie}) = 0,04$$

$$P(\text{Tempo}=\text{nublado}, \text{carie}) = 0,1 \quad P(\text{Tempo}=\text{nublado}, \sim\text{carie}) = 0,2$$

$$P(\text{Tempo}=\text{nevoento}, \text{carie}) = 0,04 \quad P(\text{Tempo}=\text{nevoento}, \sim\text{carie}) = 0,06$$

Distribuição de Probabilidade Conjunta (Tempo e Cárie)					
		Tempo			
		Ensolarado	Chuvoso	Nublado	Nevoento
Cárie	VERDADEIRO	0,3	0,06	0,1	0,04
	FALSO	0,2	0,04	0,2	0,06



# Exercícios:

## Calcule as seguintes probabilidades



- Sabendo-se que  $P(\text{Tempo}, \text{Carie})$

$$P(\text{Tempo}=\text{ensolarado}, \text{carie}) = 0,3$$

$$P(\text{Tempo}=\text{chuvoso}, \text{carie}) = 0,06$$

$$P(\text{Tempo}=\text{nublado}, \text{carie}) = 0,1$$

$$P(\text{Tempo}=\text{nevoento}, \text{carie}) = 0,04$$

$$P(\text{Tempo}=\text{ensolarado}, \sim\text{carie}) = 0,2$$

$$P(\text{Tempo}=\text{chuvoso}, \sim\text{carie}) = 0,04$$

$$P(\text{Tempo}=\text{nublado}, \sim\text{carie}) = 0,2$$

$$P(\text{Tempo}=\text{nevoento}, \sim\text{carie}) = 0,06$$

- Calcule:

- $P(\text{Tempo}=\text{chuvoso})$

- $P(\text{carie})$

- $P(\sim\text{carie})$

- $P(\text{Tempo}=\text{nublado} \wedge \text{carie})$

- $P(\text{Tempo}=\text{nublado} \vee \text{carie})$

$$P(f) = \sum_{d \in D} P(f \wedge v = d)$$

$$P(f) = P(f \wedge g) + P(f \wedge \neg g)$$

# Condicionamento



- **Probabilidade condicional** especifica como revisar crenças baseadas em uma nova informação.
- O agente constrói um modelo de probabilidade levando em consideração toda a informação passada  $h$ .
  - Isto lhe dá a **probabilidade a priori**  $P(h)$ .
- Qualquer outra informação deve ser condicionada sobre  $h$ .
- Se a **evidência**  $e$  é a informação obtida subsequente a  $h$ , a **probabilidade condicional**  $P$  de  $h$  dado  $e$  ( $P(h|e)$ ) é a **probabilidade posterior** de  $h$ .
  - A fórmula  $e$  representa a conjunção de todas as observações de mundo de agente.

# Condicionamento – exemplo



- Assistente de diagnóstico:
  - Os sintomas do paciente serão as evidências.
  - As distribuições de probabilidade sobre as possíveis doenças são usadas antes do sistema ver ou conhecer qualquer coisa sobre o paciente.
    - Exemplo:  $P(\textit{meningite}) = 0,02$ .
- A distribuição de probabilidade posterior é a probabilidade que o sistema usa depois de ter conseguido alguma evidência.
  - A probabilidade posterior é a medida do conhecimento do sistema.
    - Exemplo:  $P(\textit{meningite} \mid \textit{rigidezPescoço}) = 0,28$ .
  - Quando surgirem observações de sintomas, ou resultados de exames, o sistema pode mudar a probabilidade posterior para refletir a nova evidência.
    - Exemplo:  $P(\textit{meningite} \mid \textit{rigidezPescoço} \wedge \textit{f7ebre}) = 0,35$ .

# Condicionamento x conjunção




- Exemplo:
  - Uma urna (I) contém 2 bolas brancas (B) e 3 vermelhas (V)
  - Uma segunda urna (II) contém 4 bolas brancas (B) e 2 vermelhas (V)
  - Escolhe-se ao acaso uma urna e retira-se dela, também ao acaso, uma bola.
  - Qual a probabilidade da bola ser branca?
  - $P(B) = P(I).P(B|I) + P(II).P(B|II)$
  - Suponha que a escolha das urnas é equiprovável
    - $P(I) = 1/2$  e  $P(II) = 1/2$
  - $P(B|I) = 2/5$  e  $P(B|II) = 4/6$
  - Então  $P(B) = (1/2 * 2/5) + (1/2 * 4/6) = 8/15$

# Condicionamento x conjunção



- Árvore de probabilidades para o exemplo das bolas e urnas:



- $P(V \wedge I) = 3/10$
- $P(B \wedge I) = 1/5$
- $P(V \wedge II) = 1/6$
- $P(B \wedge II) = 1/3$
  
- $P(V|I) = 3/5$
- $P(B|I) = 2/5$
- $P(V|II) = 2/6$
- $P(B|II) = 4/6$

# Condicionamento x implicação



- $P(f | e) \neq P(e \rightarrow f)$
- $P(e \rightarrow f) = P(\sim e \vee f)$
- Suponha um domínio onde pássaros são relativamente raros e pássaros que não voam são uma pequena proporção destes.
  - $P(\sim voa | pássaro)$  seria a proporção de pássaros que não voam, que seria baixa.
  - $P(pássaro \rightarrow \sim voa)$  é o mesmo que  $P(\sim pássaro \vee \sim voa)$ , como os não pássaros são dominantes, seria alta.
  - $P(pássaro \rightarrow voa)$  é o mesmo que  $P(\sim pássaro \vee voa)$ , como os não pássaros são dominantes, também seria alta.

# Semântica da probabilidade condicional



- A evidência  $e$  descarta os mundos possíveis incompatíveis com  $e$ .
- A evidência  $e$  induz a uma nova medida,  $\mu_e$ , sobre os mundos possíveis.

$$\mu_e = \begin{cases} \frac{1}{P(e)} \times \mu(\omega) & \text{se } \omega \models e \\ 0 & \text{se } \omega \not\models e \end{cases}$$

- A probabilidade condicional da fórmula  $h$  dado a evidência  $e$  é

$$P(h | e) = \sum_{\omega \models h} \mu_e(\omega)$$

$$P(h | e) = \frac{1}{P(e)} \times \sum_{\omega \models h \wedge e} \mu(\omega)$$

$$P(h | e) = \frac{P(h \wedge e)}{P(e)}$$

# Exercícios:

## Calcule as seguintes probabilidades



- $P(\text{cárie})$
- $P(\sim\text{cárie})$
- $P(\text{cárie} \mid \text{dorDeDente})$
- $P(\text{cárie} \mid \sim\text{dorDeDente})$
- $P(\sim\text{cárie} \mid \sim\text{dorDeDente})$

	<i>dorDeDente</i>		<i>~dorDeDente</i>	
	<i>boticão</i>	<i>~boticao</i>	<i>boticão</i>	<i>~boticao</i>
<i>cárie</i>	0,108	0,012	0,072	0,008
<i>~cárie</i>	0,016	0,064	0,144	0,576



# Propriedades da probabilidade condicional



- Regra da cadeia:

$$\begin{aligned} & P(f_1 \wedge f_2 \wedge \dots \wedge f_n) \\ &= P(f_1) \times P(f_2|f_1) \times P(f_3|f_1 \wedge f_2) \\ &\quad \times \dots \times P(f_n|f_1 \wedge \dots \wedge f_{n-1}) \\ &= \prod_{i=1}^n P(f_i|f_1 \wedge \dots \wedge f_{i-1}) \end{aligned}$$

# Teorema de Bayes



- Nos diz com modificar a crença em  $h$  dado que uma evidência  $e$  é acumulada ao conhecimento  $k$  do agente.
- Da regra da cadeia e da comutatividade da conjunção ( $h \wedge e$  é equivalente a  $e \wedge h$ ) temos:

$$P(h \wedge e) = P(h | e) \times P(e)$$

$$P(h \wedge e) = P(e | h) \times P(h)$$

$$P(h | e) \times P(e) = P(e | h) \times P(h)$$

$$P(h | e) = \frac{P(e | h) \times P(h)}{P(e)}$$

- Este é o **Teorema de Bayes**.

# Teorema de Bayes



- A aplicação do Teorema de Bayes normalmente omite o conhecimento anterior do agente  $k$ :

$$P(h | e \wedge k) = \frac{P(e | h \wedge k) \times P(h | k)}{P(e | k)}$$

$$P(h | e) = \frac{P(e | h) \times P(h)}{P(e)}$$

# Teorema de Bayes - Exemplo



- Um médico sabe que:
  - Meningite faz o paciente ter rigidez no pescoço durante 50% do tempo
    - $P(r | m) = 0,5$ .
  - A probabilidade a priori de um paciente ter meningite é 1/50000
    - $P(m) = 1/50.000$ .
  - A probabilidade a priori de um paciente ter rigidez no pescoço é 1/20
    - $P(r) = 1/20$ .
- Vamos determinar a probabilidade de um paciente que tem rigidez no pescoço, ter meningite:
  - $P(m | r) = P(r | m)P(m) / P(r) = (0,5 \times 1/50.000) / (1/20) = 0,0002$ .
  - Ou seja, esperamos que apenas 1 paciente em 5.000 com rigidez no pescoço tenha meningite.

# Aplicação do Teorema de Bayes



- Por que a probabilidade condicional pode estar disponível em um sentido, mas não em outro?  $\Rightarrow P(r | m)$  e não  $P(m | r)$ ?
- Talvez o médico tenha informações quantitativas no sentido do **diagnóstico** de sintomas para causas.
- O conhecimento de diagnóstico freqüentemente é mais frágil que o conhecimento causal.
  - Exemplo: Se houver um epidemia de meningite:
    - A probabilidade incondicional de meningite,  $P(m)$ , crescerá.
    - Então calculando  $P(m|r)$  a partir da regra de Bayes, esta deve subir proporcionalmente a  $P(m)$ .
    - As informações causais  $P(r | m)$  **não** serão afetadas, pois refletem o modo como a meningite atua.

# Quando o teorema de Bayes é interessante?



- Sempre que temos conhecimento causal:
  - $P(\textit{sintoma} \mid \textit{doença})$
  - $P(\textit{luz está desligada} \mid \textit{estado das chaves e posições das chaves})$
  - $P(\textit{alarme} \mid \textit{fogo})$
- E queremos raciocinar sobre a evidência:
  - $P(\textit{doença} \mid \textit{sintoma})$
  - $P(\textit{estado das chaves} \mid \textit{luz está desligada e posição das chaves})$
  - $P(\textit{fogo} \mid \textit{alarme})$ .



# Teorema de Bayes - Exemplo



- Supõe que temos a informação sobre a confiabilidade dos alarmes para fogo.
  - $P(\text{alarme} \mid \text{fogo})$  – probabilidade que o alarme dispare dados que existe fogo.
  - $P(\text{fogo})$  – probabilidade de fogo dado nenhuma outra informação (ex. baseado em quanto o prédio foi construído à prova de fogo).
  - $P(\text{alarme})$  – probabilidade do alarme soar, dado nenhuma outra informação.
- Supõe que queremos saber a probabilidade de existir fogo dado que o alarme soou – aplicamos o teorema de Bayes:
  - $P(\text{fogo} \mid \text{alarme}) = (P(\text{alarme} \mid \text{fogo}) \times P(\text{fogo})) / P(\text{alarme})$

# Exemplo de domínio

## Assistente de diagnóstico





# Exemplo de domínio

## Assistente de diagnóstico



- Supõe que um assistente de diagnóstico está interessado em diagnosticar o *switch*  $s1$ .
- Supõe que o estado de  $s1$  seja representado pela variável  $s1\_st$ , para a qual temos o domínio  $\{ok, upside\_down, short, intermittent, broken\}$ .
- Supõe que já temos o conhecimento de que  $w3$  tem energia (*live*) e que  $s1$  está para baixo (*down*).
  - $(s1\_pos = down \wedge live(w3)) = k$
- As probabilidades abaixo especificam como  $s1$  trabalha com a situação acima:
  - $P(live(w2)|k \wedge s1\_st = ok) = 1$
  - $P(live(w2)|k \wedge s1\_st = upside\_down) = 0$
  - $P(live(w2)|k \wedge s1\_st = short) = 1$
  - $P(live(w2)|k \wedge s1\_st = intermittent) = 0,5$
  - $P(live(w2)|k \wedge s1\_st = broken) = 0$

# Exemplo de domínio

## Assistente de diagnóstico



- Supõe que temos as seguintes probabilidades a priori:
  - $P(s1\_st = ok) = 0,9$
  - $P(s1\_st = upside\_down) = 0,02$
  - $P(s1\_st = short) = 0,02$
  - $P(s1\_st = intermitent) = 0,02$
  - $P(s1\_st = broken) = 0,04$
- Vamos assumir que estas probabilidades não dependem da posição do *switch* *s1* ou se *w3* tem energia. Assim,  $P(s1\_st = ok | k) = 0,9$ .
- Supõe que a saída do switch (*w2*), é observada como sem energia:
  - $\sim live(w2)$
- Vamos determinar a probabilidade posterior do estado do *switch* *s1* considerando *k* e a evidência  $\sim live(w2)$

# Exemplo de domínio

## Assistente de diagnóstico



- $P(s1\_st = ok \mid k \wedge \sim live(w2)) = ?$
- $P(s1\_st = upside\_down \mid k \wedge \sim live(w2)) = ?$
- $P(s1\_st = short \mid k \wedge \sim live(w2)) = ?$
- $P(s1\_st = intermitent \mid k \wedge \sim live(w2)) = ?$
- $P(s1\_st = broken \mid k \wedge \sim live(w2)) = ?$

# Exemplo de domínio

## Assistente de diagnóstico



- $P(s1\_st = ok \mid k \wedge \sim live(w2))$
- $= (P(\sim live(w2) \mid s1\_st = ok \wedge k) * P(s1\_st = ok \mid k)) / (P(\sim live(w2) \mid k))$
- $= (1 - P(live(w2) \mid s1\_st = ok \wedge k)) * P(s1\_st = ok \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - 1 * P(s1\_st = ok \mid k)) / (P(\sim live(w2) \mid k)) = 0$
  
- $P(s1\_st = upside\_down \mid k \wedge \sim live(w2))$
- $= P(\sim live(w2) \mid s1\_st = upside\_down \wedge k) * P(s1\_st = upside\_down \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - (P(live(w2) \mid s1\_st = upside\_down \wedge k))) * P(s1\_st = upside\_down \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - 0 * 0,02) / (P(\sim live(w2) \mid k)) = (0,02) / (P(\sim live(w2) \mid k))$

# Exemplo de domínio

## Assistente de diagnóstico



- $P(s1\_st = short \mid k \wedge \sim live(w2))$
- $= (P(\sim live(w2) \mid s1\_st = short \wedge k) * P(s1\_st = short \mid k)) / (P(\sim live(w2) \mid k))$
- $= (1 - P(live(w2) \mid s1\_st = short \wedge k)) * P(s1\_st = short \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - 1 * P(s1\_st = short \mid k)) / (P(\sim live(w2) \mid k)) = 0$
  
- $P(s1\_st = intermittent \mid k \wedge \sim live(w2))$
- $= P(\sim live(w2) \mid s1\_st = intermittent \wedge k) * P(s1\_st = intermittent \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - (P(live(w2) \mid s1\_st = intermittent \wedge k)) * P(s1\_st = intermittent \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - 0,5 * 0,02) / (P(\sim live(w2) \mid k)) = (0,01) / (P(\sim live(w2) \mid k))$

# Exemplo de domínio

## Assistente de diagnóstico



- $P(s1\_st = broken \mid k \wedge \sim live(w2))$
- $= (P(\sim live(w2) \mid s1\_st = broken \wedge k) * P(s1\_st = broken \mid k)) / (P(\sim live(w2) \mid k))$
- $= (1 - P(live(w2) \mid s1\_st = broken \wedge k)) * P(s1\_st = broken \mid k) / (P(\sim live(w2) \mid k))$
- $= (1 - 0 * 0,04) / (P(\sim live(w2) \mid k)) = (0,04) / (P(\sim live(w2) \mid k))$

- O denominador  $P(\sim live(w2) \mid k)$  pode ser computado somando os numeradores, pois eles relacionam todos os estados possíveis de  $s1\_st$ :

$$\begin{aligned} & P(\sim live(w2) \mid k) \\ &= \sum_{s \in D} P(\sim live(w2) \mid k \wedge s1\_st = s) * P(s1\_st = s \mid k) \\ &= 0 + 0,02 + 0 + 0,01 + 0,4 \\ &= 0,07 \end{aligned}$$

- Isto é chamado de **normalização** de uma constante. A soma final de todas as probabilidades posteriores deve somar 1.

# Exemplo de domínio

## Assistente de diagnóstico



- $P(s1\_st = ok \mid k \wedge \sim live(w2)) = 0$
- $P(s1\_st = upside\_down \mid k \wedge \sim live(w2)) = 2/7$
- $P(s1\_st = short \mid k \wedge \sim live(w2)) = 0$
- $P(s1\_st = intermitent \mid k \wedge \sim live(w2)) = 1/7$
- $P(s1\_st = broken \mid k \wedge \sim live(w2)) = 4/7$

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

# Independência entre as variáveis

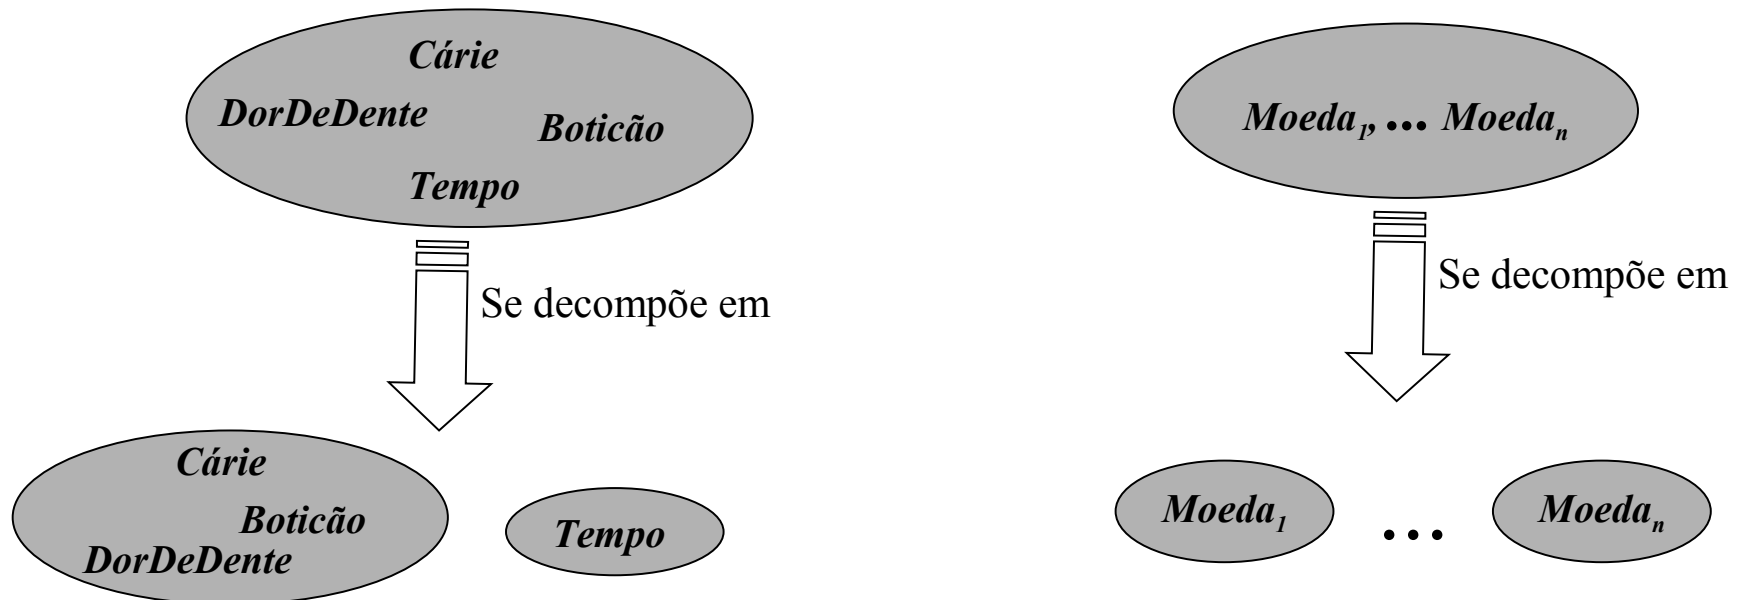


- A distribuição de probabilidade completa  $P(\text{Dor dedente}, \text{Boticão}, \text{Cárie}, \text{Tempo}=\text{nublado})$ .
  - E a tabela de 32 entradas pode ser separada em uma de 4 entradas para *Tempo* e outra de 8 para as outras variáveis.
- Isto é chamado de **independência**: o tempo é independente 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  $l1$  está acesa dado que existe energia de fora.
- Se existe alguém na sala é independente de se a luz  $l2$  está acesa dado a posição da chave  $s3$ .
- Se a luz  $l1$  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  $l1$  está acesa dado se existe energia no fio  $w0$  e o estado da luz  $l1$  (se ela está ok ou quebrada).