

INF623

2024/1



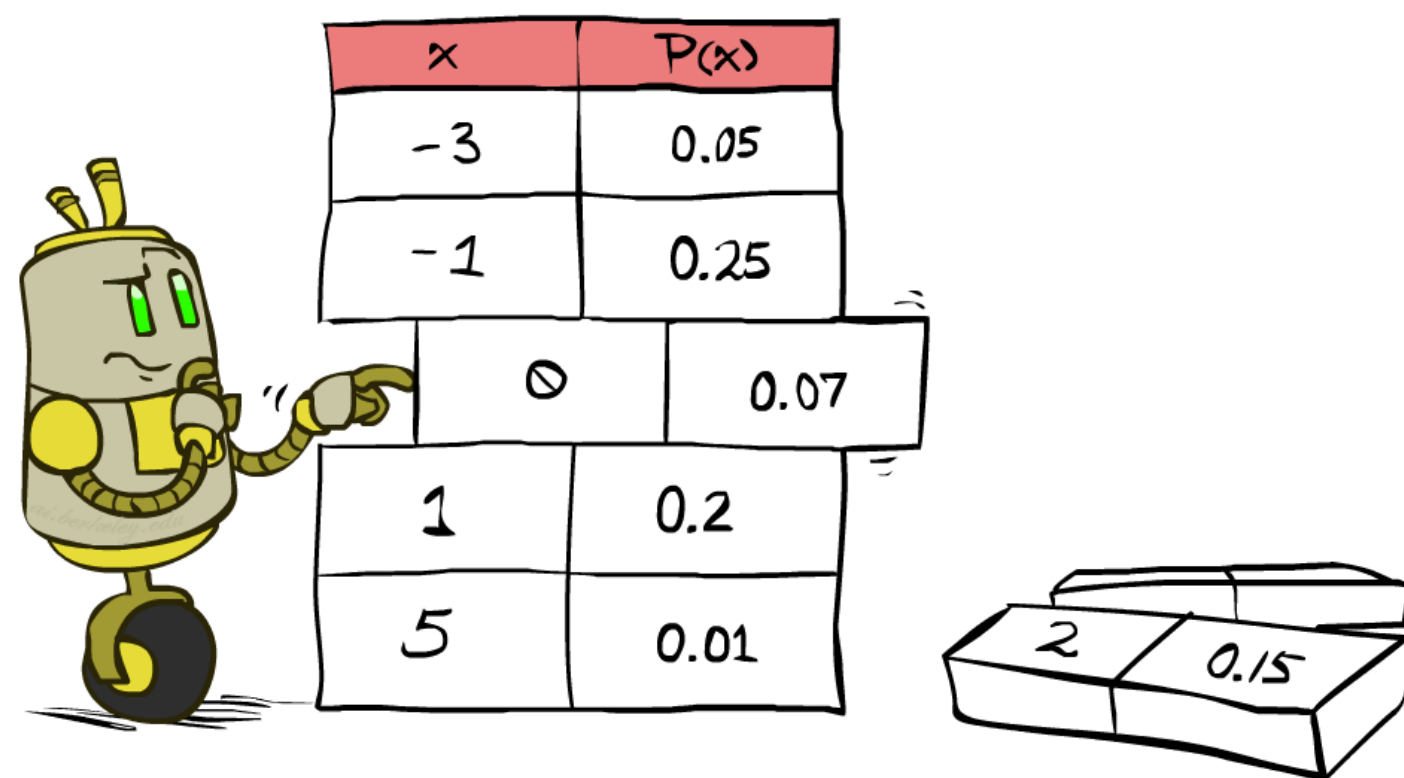
Inteligência Artificial

A15: Raciocínio Probabilístico II

Plano de aula

- ▶ Teorema de Bayes
- ▶ Independência
- ▶ Independência condicional
- ▶ Redes Bayesianas

Na última aula



x	P(x)
-3	0.05
-1	0.25
0	0.07
1	0.2
5	0.01

2 0.15

Problemas da inferência por enumeração:

- ▶ Complexidade de tempo $O(d^n)$
- ▶ Complexidade de espaço para armazenar a distribuição conjunta $O(d^n)$
- ▶ Obter $O(d^n)$ exemplos para estimar as entradas da distribuição conjunta


Teorema de Bayes

$$P(a, b) = P(a | b)P(b) = P(b | a)P(a)$$

-----> Regra do produto

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

-----> Dividindo por $P(b)$



Qual a utilidade do Teorema de Bayes?

- ▶ Podemos calcular uma probabilidade condicional a partir da sua inversa
- ▶ Frequentemente, uma probabilidade condicional é complicada mas a outra é simples
- ▶ Descreve uma regra de atualização de $P(a)$ anterior para o $P(a | b)$ posterior

Inferência com o Teorema de Bayes

O Teorema de Bayes é muito utilizado em situações de causa/efeito:

$$P(\text{causa} | \text{efeito}) = \frac{P(\text{efeito} | \text{causa})P(\text{causa})}{P(\text{efeito})}$$

Exemplo: M : Meningite, S : torcicolo

$$P(m) = 0,0001$$

$$P(s | m) = 0,8$$

$$P(s | \neg m) = 0,01$$


$$P(m | s) = \frac{P(s | m)P(m)}{P(s)} = \frac{P(s | m)P(m)}{P(s | m)P(m) + P(s | \neg m)P(\neg m)} = 0,007944$$

Independência

Duas variáveis X e Y são independentes ($X \perp\!\!\!\perp Y$) se e somente se:

$X \perp\!\!\!\perp Y \Leftrightarrow P(X, Y) = P(X)P(Y)$ \longrightarrow A distribuição conjunta é fatorada em distribuições mais simples

$X \perp\!\!\!\perp Y \Leftrightarrow P(X|Y) = P(X)$ \longrightarrow O resultado de X independente do resultado de Y



Exemplos:

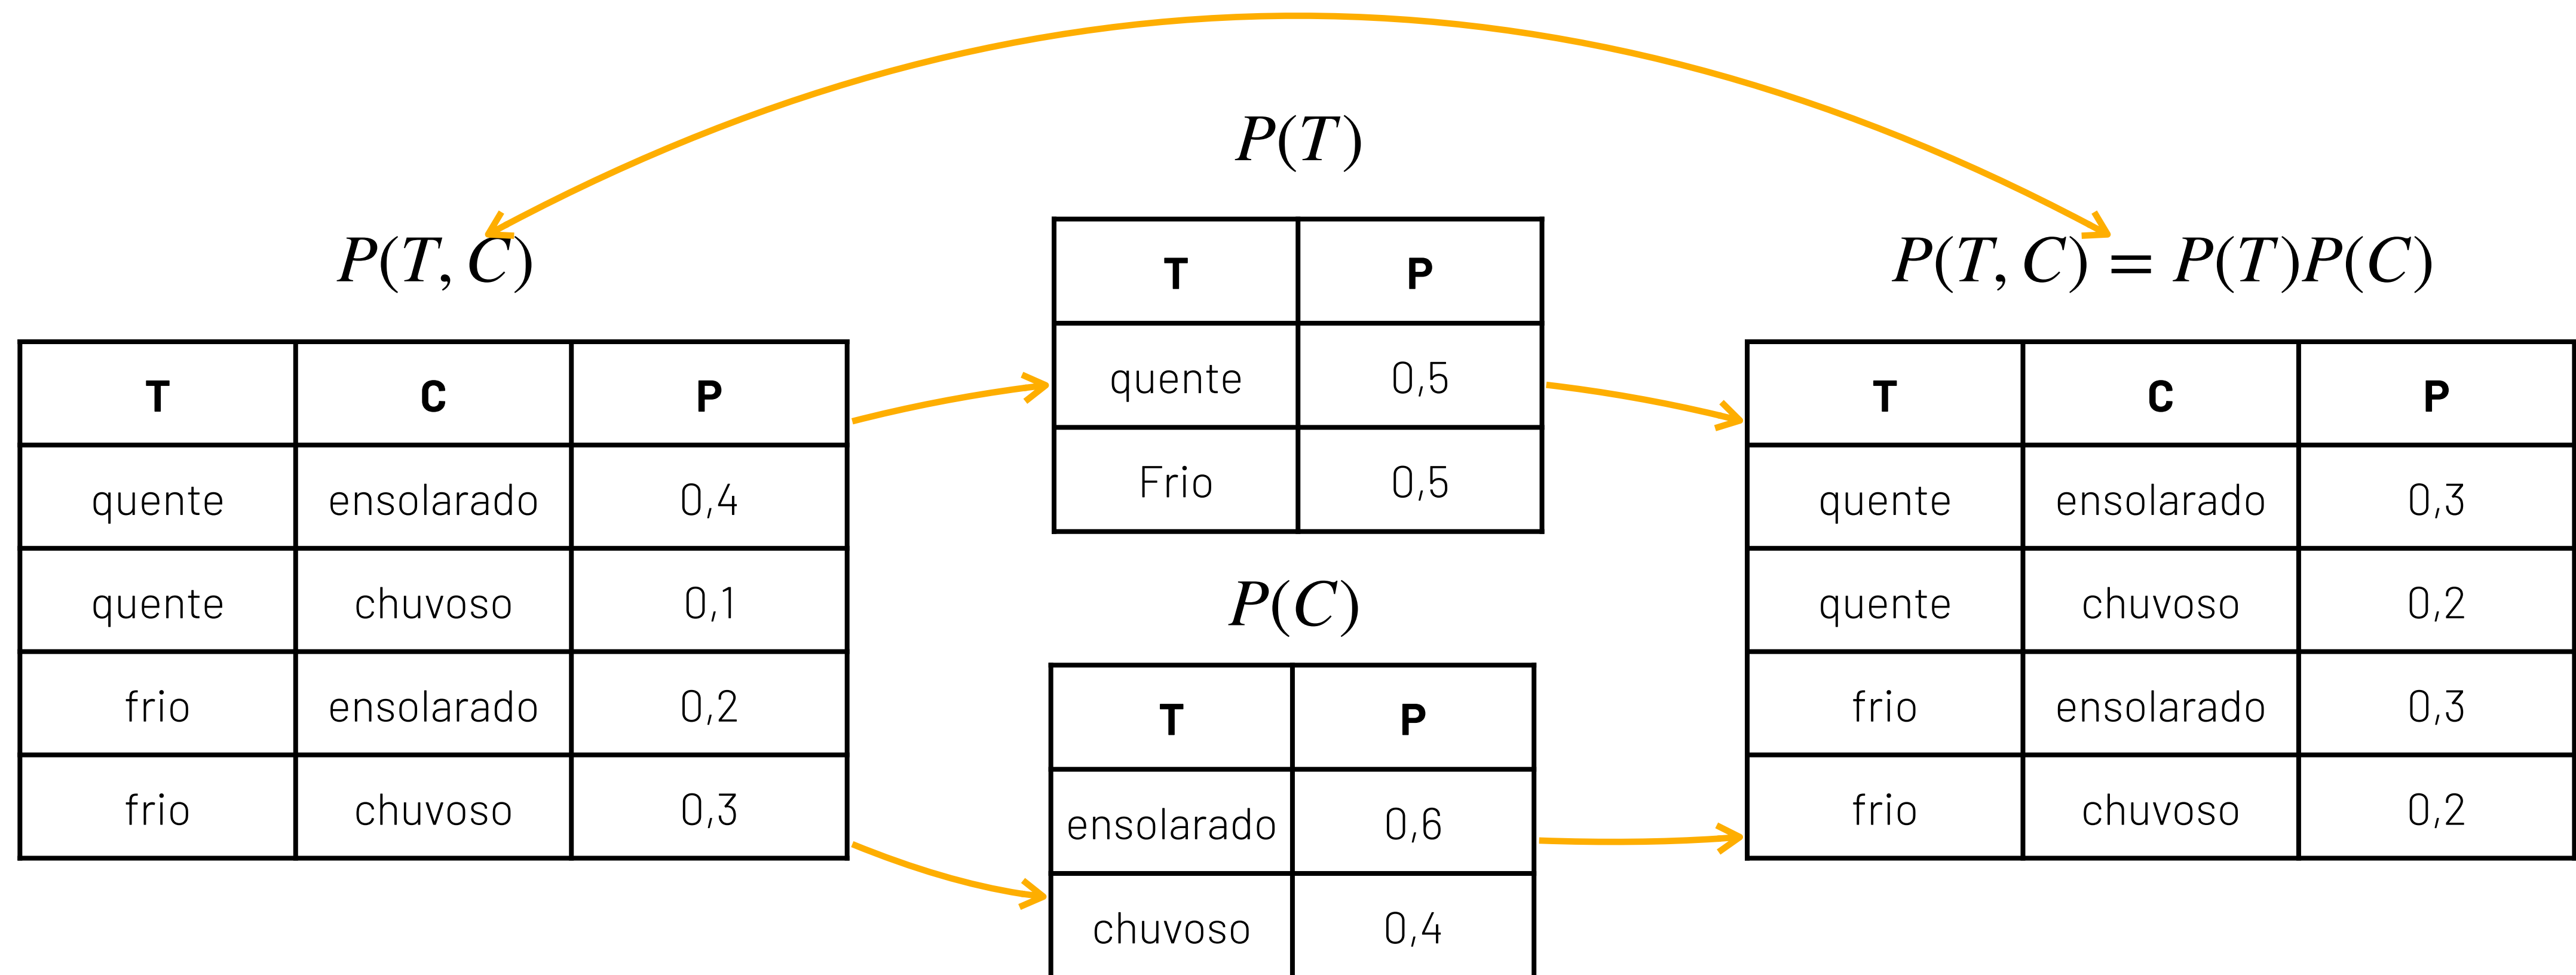
- ▶ Independentes \rightarrow lançar duas moedas
- ▶ Dependentes \rightarrow se estiver nublado pela manhã, é mais provável que chova durante o dia

- ▶ Em geral, variáveis aleatórias não são independentes. No entanto, muitas vezes assumimos independência para simplificar o modelo de probabilidades.

Exemplo 1: dependência

Temperatura T e clima C

\neq



Exemplo 2: independência

Lançamento de n moedas justas

$P(X_1)$

X1	P
cara	0,5
coroa	0,5


$P(X_2)$

X2	P
cara	0,5
coroa	0,5

...

$P(X_3)$

Xn	P
cara	0,5
coroa	0,5



$P(X_1, X_2, \dots, X_n)$



Independência condicional

Duas variáveis X e Y são condicionalmente independentes dado Z ($X \perp\!\!\!\perp Y | Z$) se e somente se:

$$\forall x, y, z : P(x, y | z) = P(x | z)P(y | z)$$

Ou, de maneira equivalente:

$$\forall x, y, z : P(x | y, z) = P(x | z)$$

- ▶ Independência (absoluta) raramente acontece, por quê?
- ▶ Independência condicional é uma suposição mais fraca que independência (absoluta) e é a nossa forma mais básica e robusta de conhecimento sobre ambientes incertos.

Exemplo 3: independência condicional

$P(\text{DorDente}, \text{Cavidade}, \text{EstileteAgarrar})$

Se eu tenho uma cavidade no dente, a probabilidade do estilete agarrar não depende de eu estar com dor de dente:

▶ $P(\text{EstileteAgarrar} \mid \text{DorDente}, \text{Cavidade}) = P(\text{EstileteAgarrar} \mid \text{Cavidade})$

A mesma independência vale se eu não tenho uma cavidade:


▶ $P(\text{EstileteAgarrar} \mid \text{DorDente}, \neg \text{Cavidade}) = P(\text{EstileteAgarrar} \mid \neg \text{Cavidade})$

EstileteAgarrar é *condicionalmente independente* de DorDente dado Cavidade

Declarações equivalentes:


▶ $P(\text{DorDente} \mid \text{EstileteAgarrar}, \text{Cavidade}) = P(\text{DorDente} \mid \text{Cavidade})$

▶ $P(\text{DorDente}, \text{EstileteAgarrar} \mid \text{Cavidade}) = P(\text{DorDente} \mid \text{Cavidade})P(\text{EstileteAgarrar} \mid \text{Cavidade})$





Exercício 1

- ▶ Trânsito
- ▶ Guarda-chuvas
- ▶ Chuva



Exercício 2

- ▶ Fogo
- ▶ Fumaça
- ▶ Alarme



Independência condicional e a regra da cadeia


▶ Regra da cadeia: $P(X_1, X_2, \dots, X_n) = P(X_1)P(X_2 | X_1)P(X_3 | X_1, X_2) \dots$

▶ Aplicação no Exercício 1 (slide 11):

$$P(\text{Trânsito}, \text{Chuva}, \text{GuardaChuva}) = \\ P(\text{Chuva})P(\text{Trânsito}|\text{Chuva})P(\text{GuardaChuva} | \text{Chuva}, \text{Trânsito})$$


▶ Supondo independência condicional

$$P(\text{Trânsito}, \text{Chuva}, \text{GuardaChuva}) = \\ P(\text{Chuva})P(\text{Trânsito}|\text{Chuva})P(\text{GuardaChuva} | \text{Chuva})$$



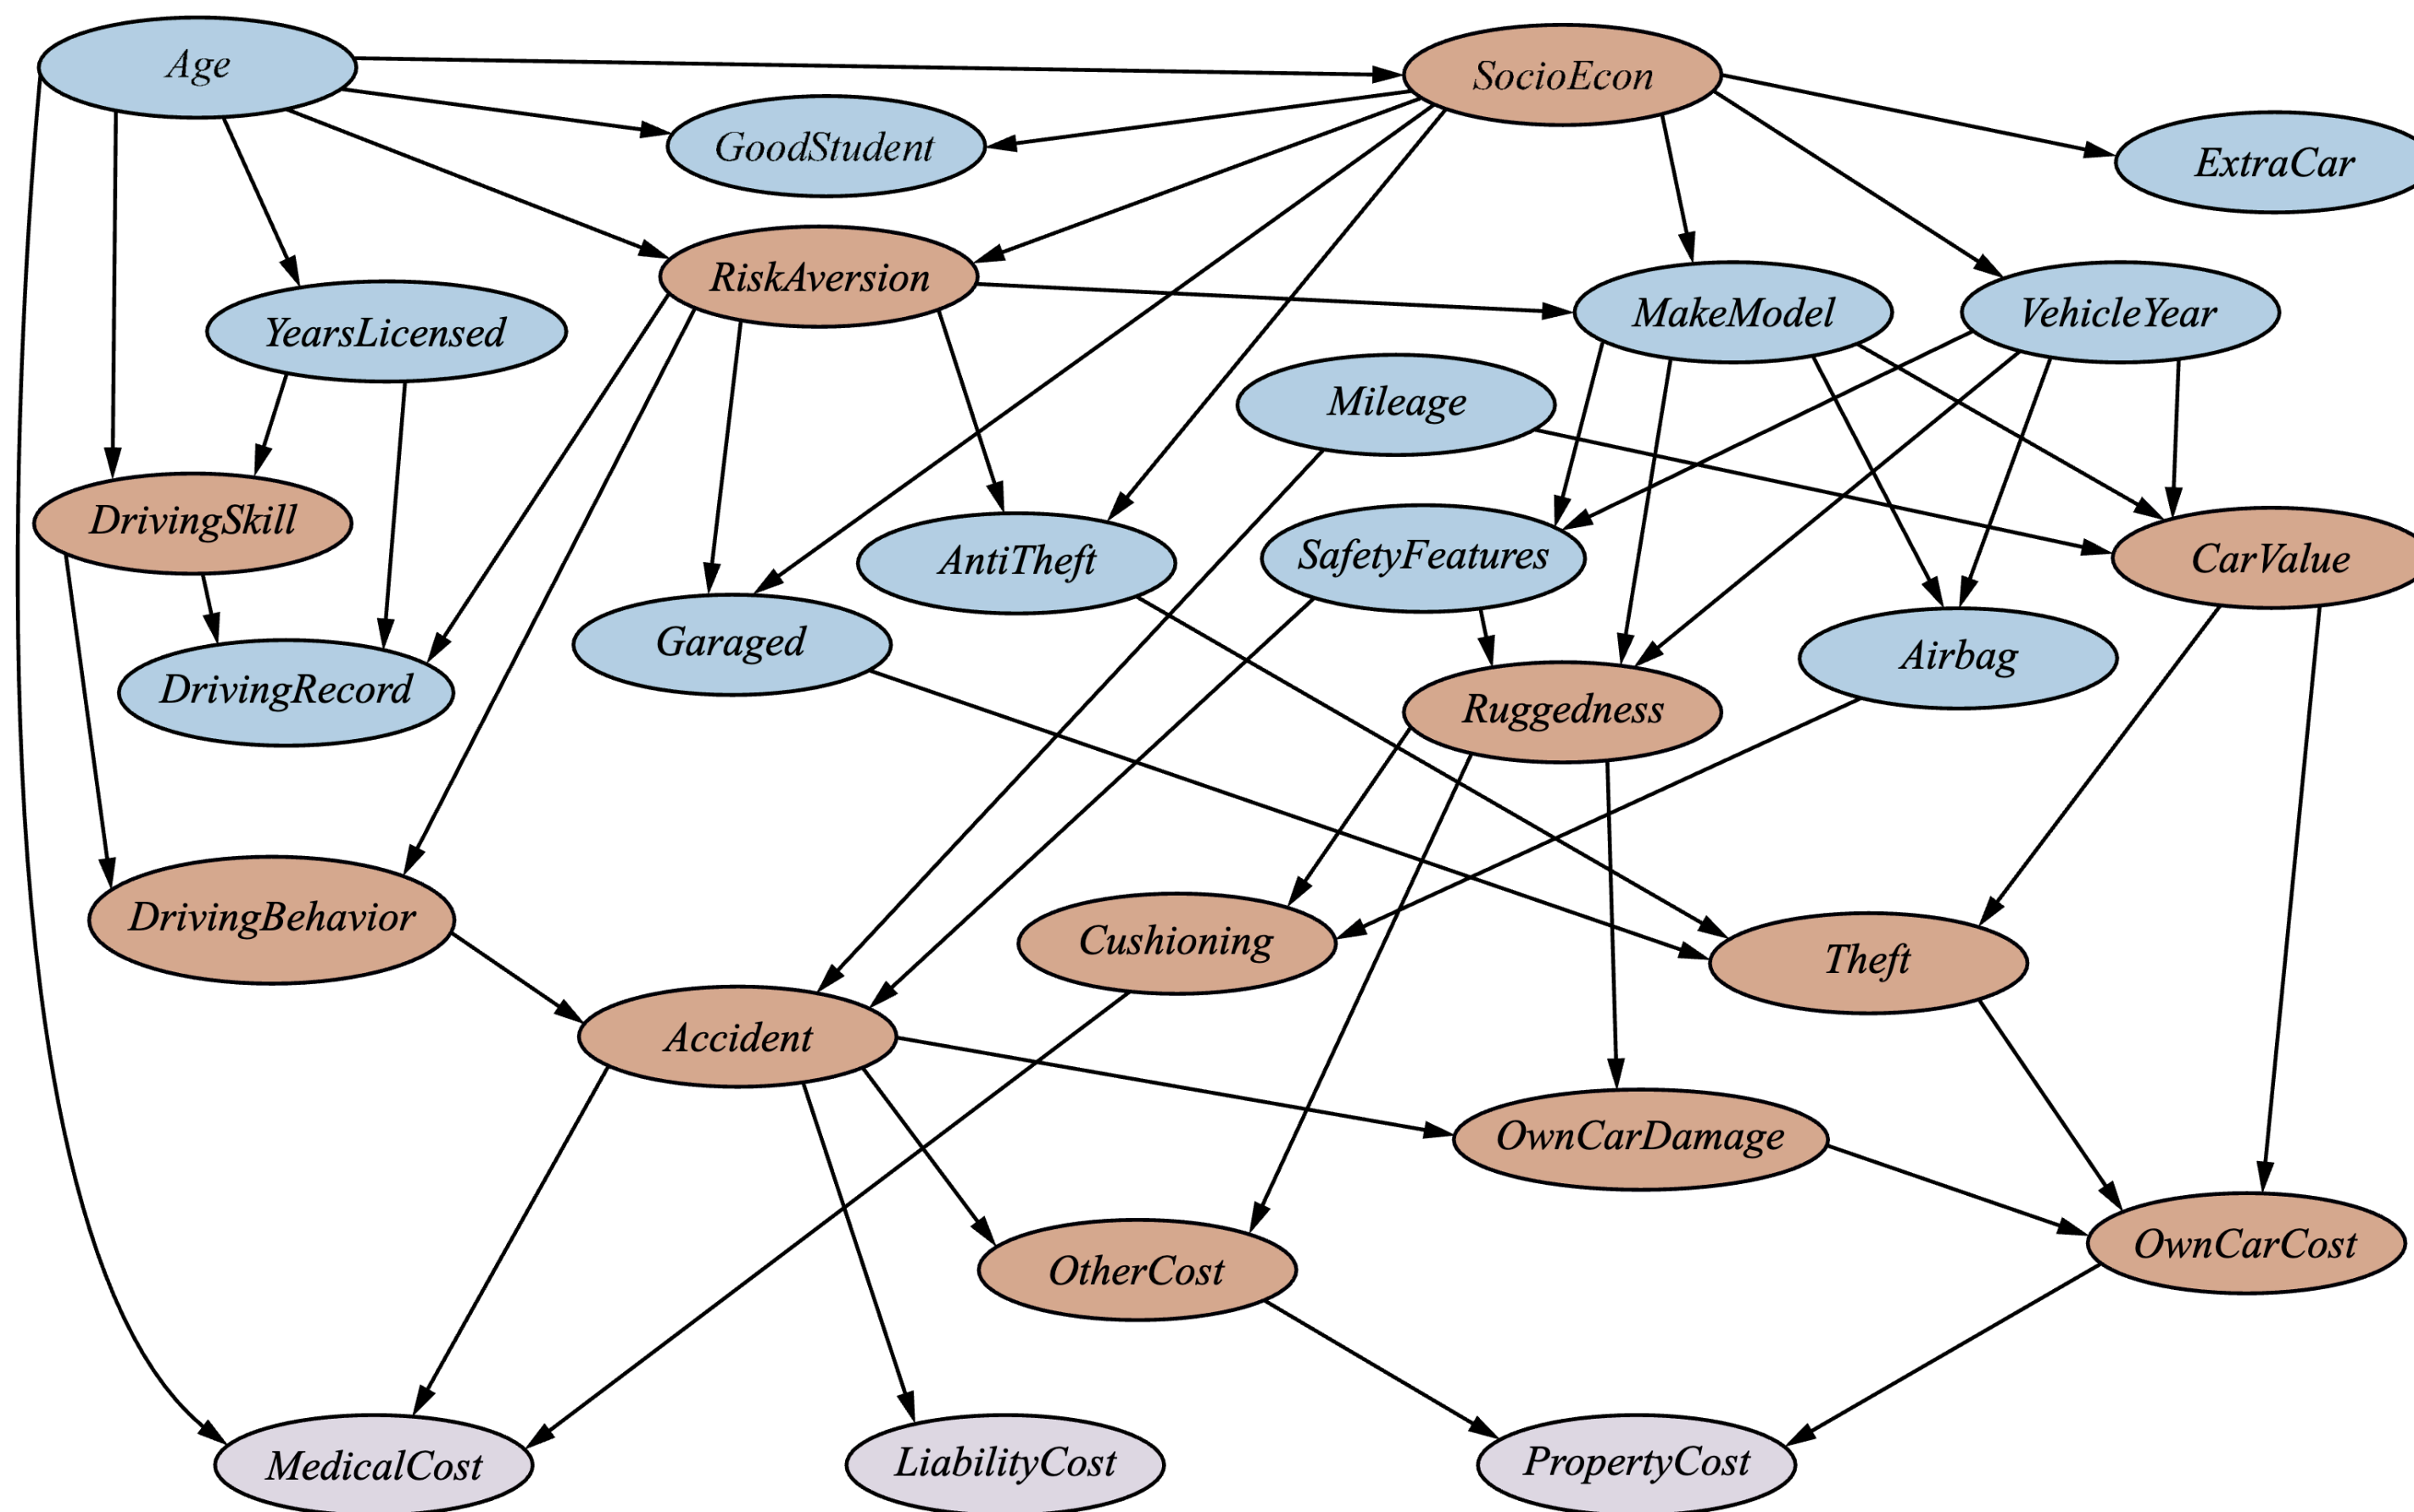
Redes Bayesianas nos ajudam a expressar suposições de independência condicional!

Redes bayesianas



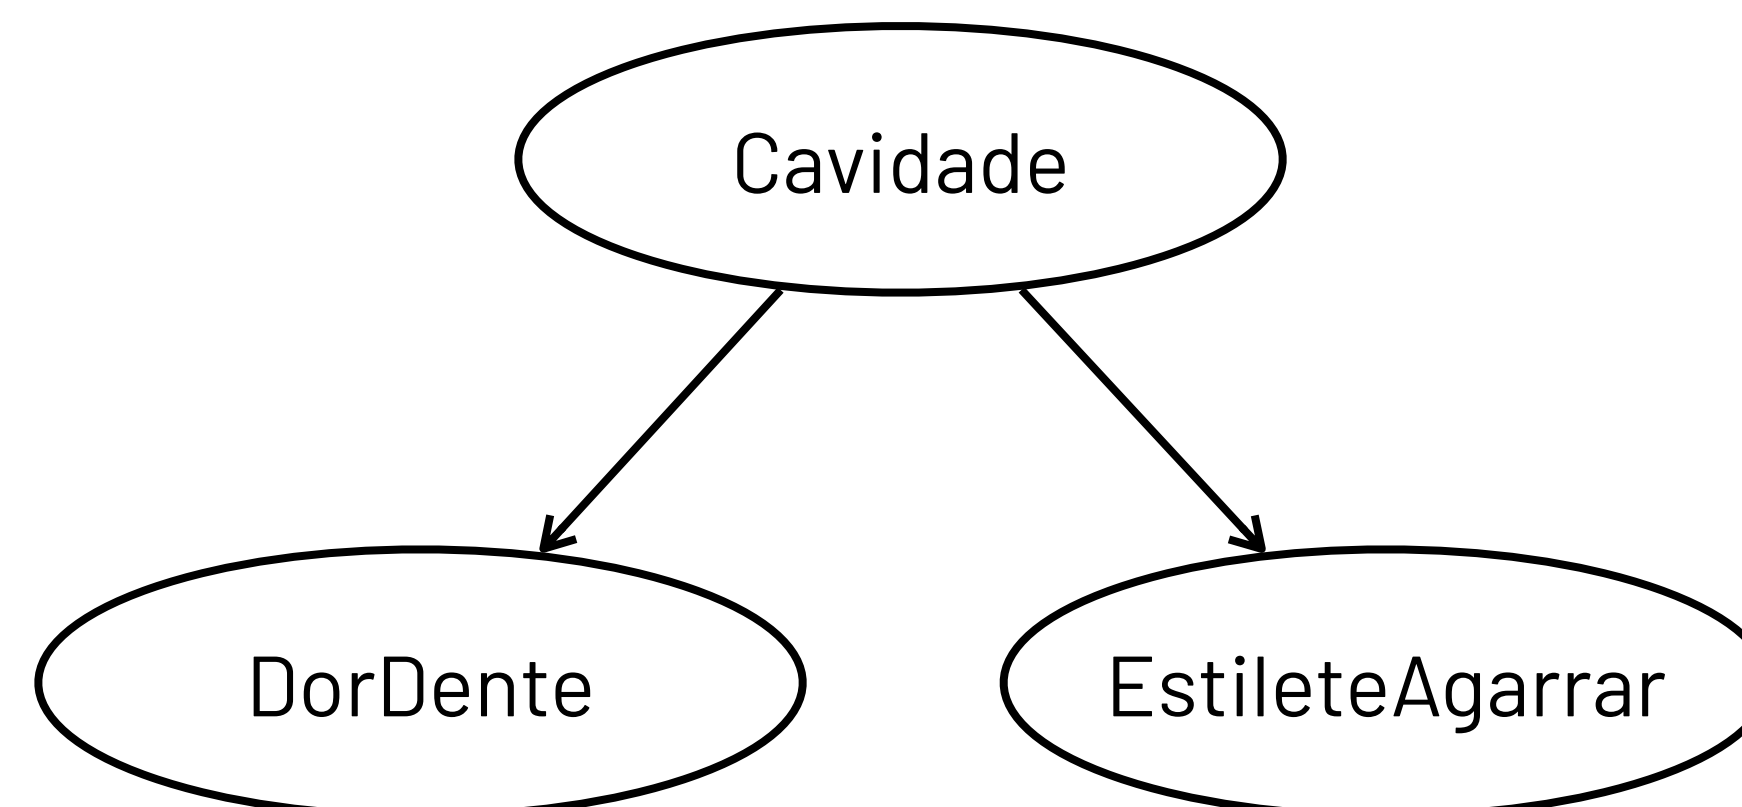

- ▶ Problemas em usar distribuições conjuntas $P(X_1, X_2, \dots, X_n)$ como modelo de probabilidades:
 - ▶ A não ser que o problema tenha poucas variáveis, a distribuição conjunta é muito grande para representar explicitamente
 - ▶ Quanto maior o número de variáveis, mais difícil é estimar os valores das variáveis empiricamente
- ▶ **Redes bayesianas** são uma técnica para descrever distribuições conjuntas (modelos probabilísticos) complexa(o)s em termos de distribuições locais mais simples:
 - ▶ Também chamadas de modelos gráficos
 - ▶ Descreve como variáveis interagem localmente
 - ▶ Interações locais são combinadas para descrever interações globais

Exemplo 4: solicitações de seguro de carro





Redes bayesianas: sintaxe

- ▶ **Vértices** representam variáveis (com seus domínios)
 - ▶ Podem estar atribuídas (observadas) ou não
- ▶ **Arestas** representam interações entre variáveis
 - ▶ Similar às restrições dos PSRs
 - ▶ Indicam “influência direta” entre variáveis
 - ▶ Formalmente codificam independência condicional



Exemplo 5: redes bayesianas

Lançamento de n moedas justas



Nenhuma interação entre variáveis: **independência absoluta!**

Exemplo 6: redes bayesianas

Ocorrência de trânsito veicular em cidades


Variáveis:

- ▶ R : está chovendo
- ▶ T : ocorrência de trânsito

Modelo 1: assumindo independência

Modelo 2: chuva causa trânsito

Porquê um agente que usa o **modelo 2** é melhor?




Exemplo 7: redes bayesianas

Construir uma rede bayesiana para modelar a ocorrência de trânsito considerando as seguintes variáveis aleatórias:

- ▶ T : ocorrência de trânsito
- ▶ R : está chovendo
- ▶ L : baixa pressão atmosférica
- ▶ D : vazamento no teto
- ▶ B : jogo de futebol
- ▶ C : cavidade



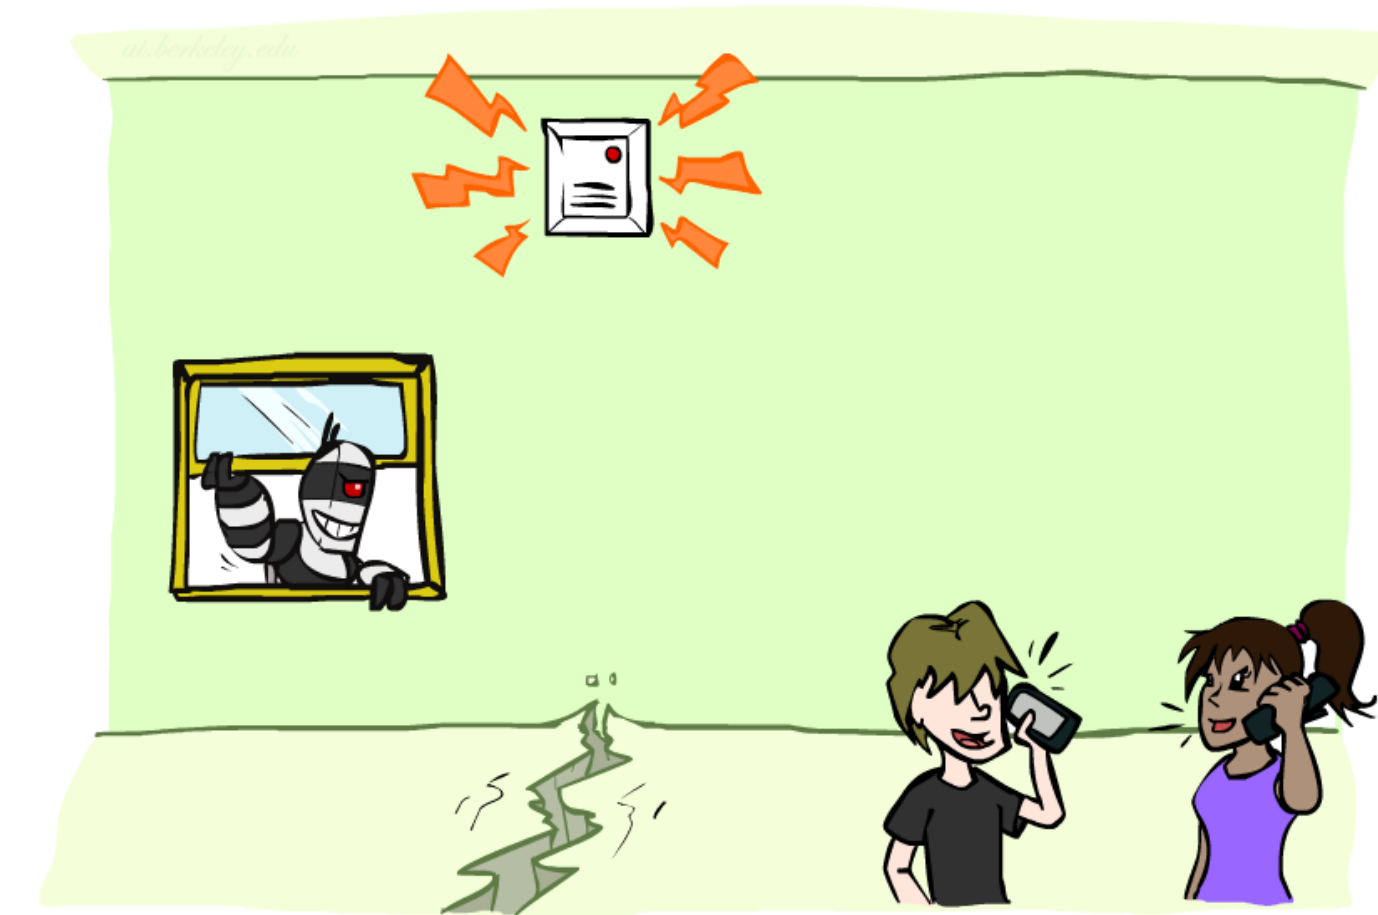
Não existe um único modelo correto. O modelo depende de como acreditamos que as variáveis influenciam umas as outras!




Exemplo 8: redes bayesianas

Alarme para detecção contra assaltos:


- ▶ A : alarme
- ▶ S : assalto
- ▶ M : ligação de Maria
- ▶ J : ligação de João
- ▶ E : terremotos



Não existe um único modelo correto. O modelo depende de como acreditamos que as variáveis influenciam umas as outras!



Redes bayesianas: semântica



- ▶ Uma rede bayesiana é um grafo acíclico dirigido com:
 - ▶ Um vértice para cada variável aleatória
 - ▶ Uma aresta entre cada par de variáveis dependentes
 - ▶ Uma distribuição condicional (tabela) para cada vértice:


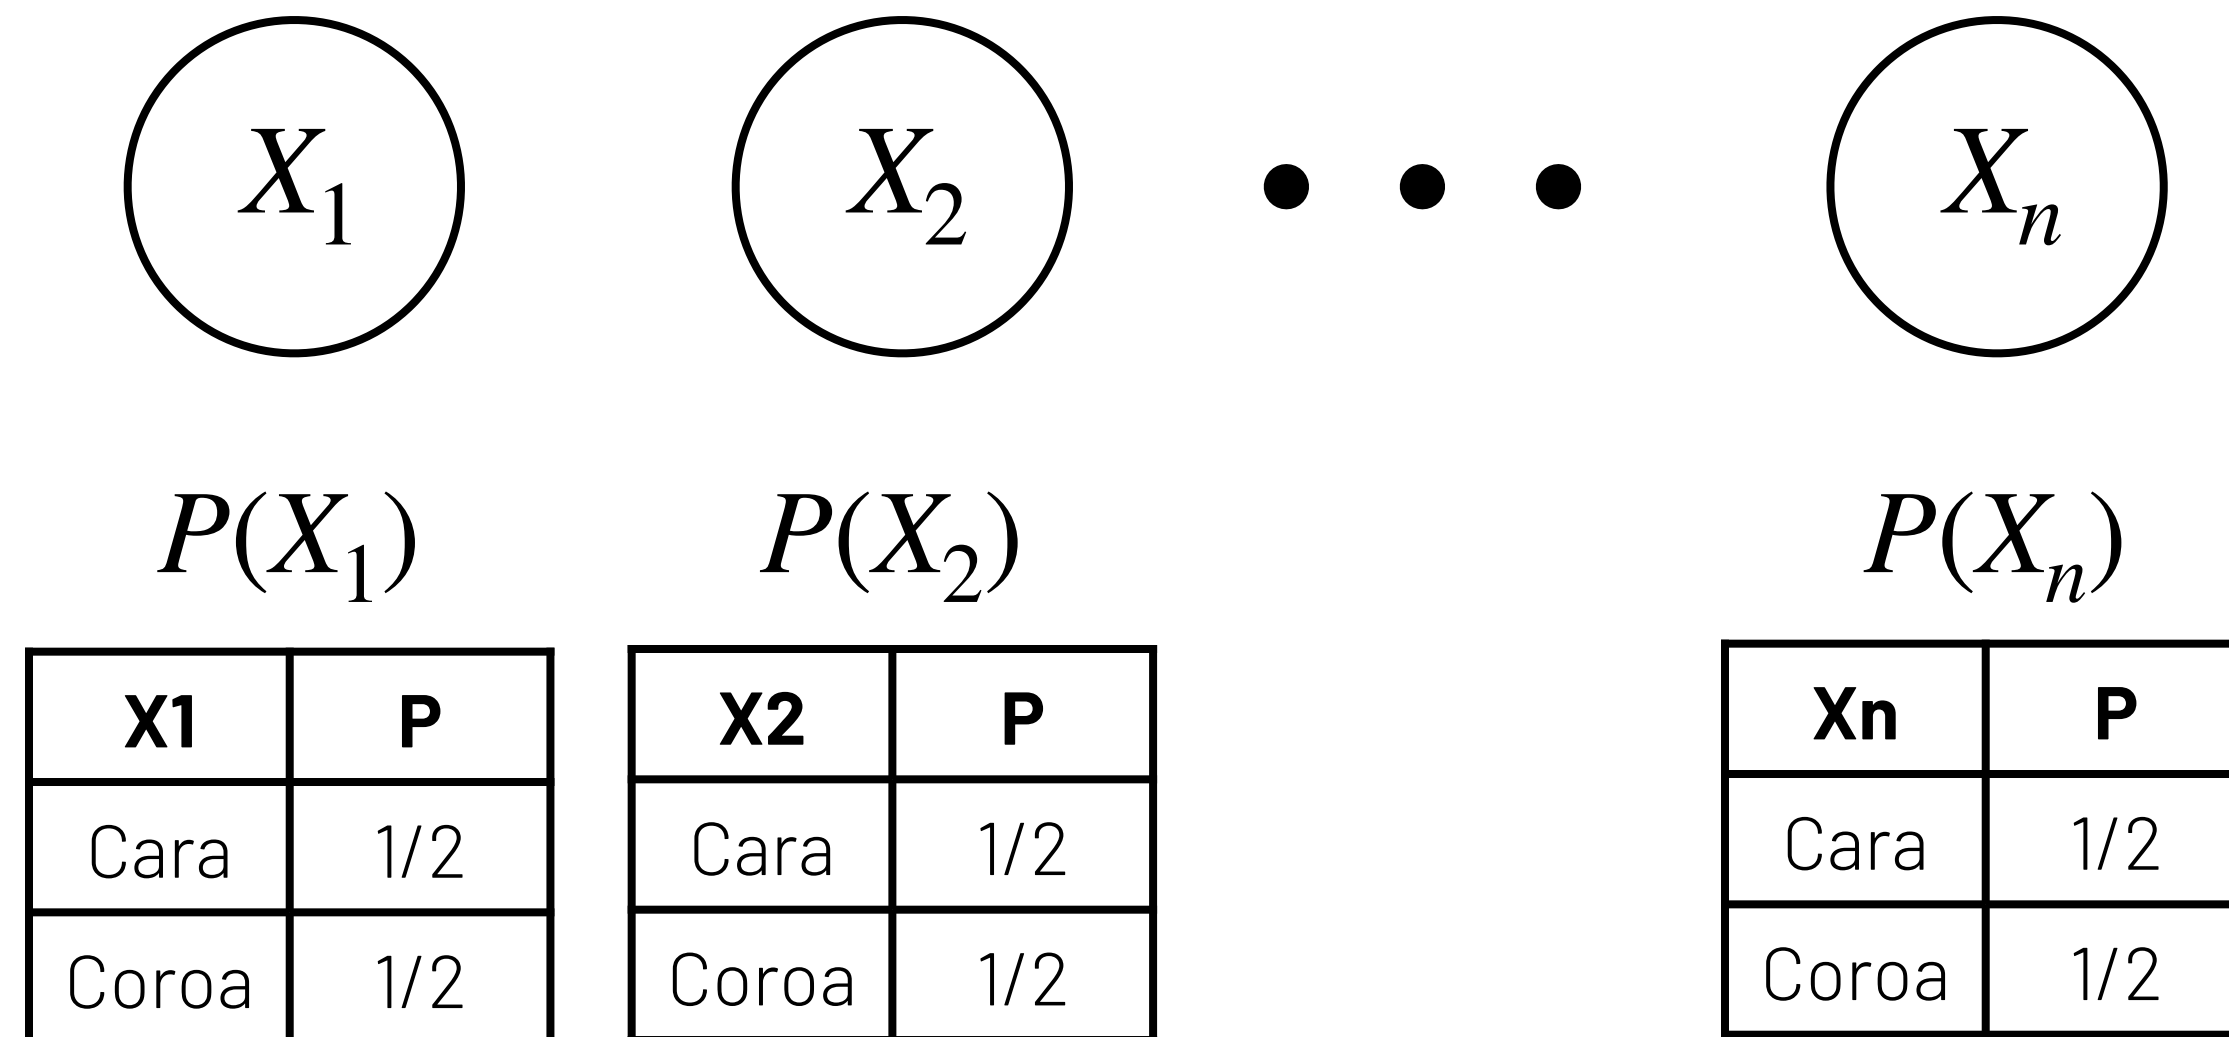
$$P(X | a_1, \dots, a_n)$$

- ▶ Uma rede bayesiana representa uma distribuição conjunta implicitamente:

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{pais}(X_i))$$


Exemplo 5: redes bayesianas

Lançamento de n moedas justas



$$P(h, h, t, h) = \frac{1}{2} \times \frac{1}{2} \times \frac{1}{2} \times \frac{1}{2} = 0,0625$$

Exemplo 6: redes bayesianas



Ocorrência de trânsito veicular em cidades

Variáveis:

- ▶ R : está chovendo
- ▶ T : ocorrência de trânsito



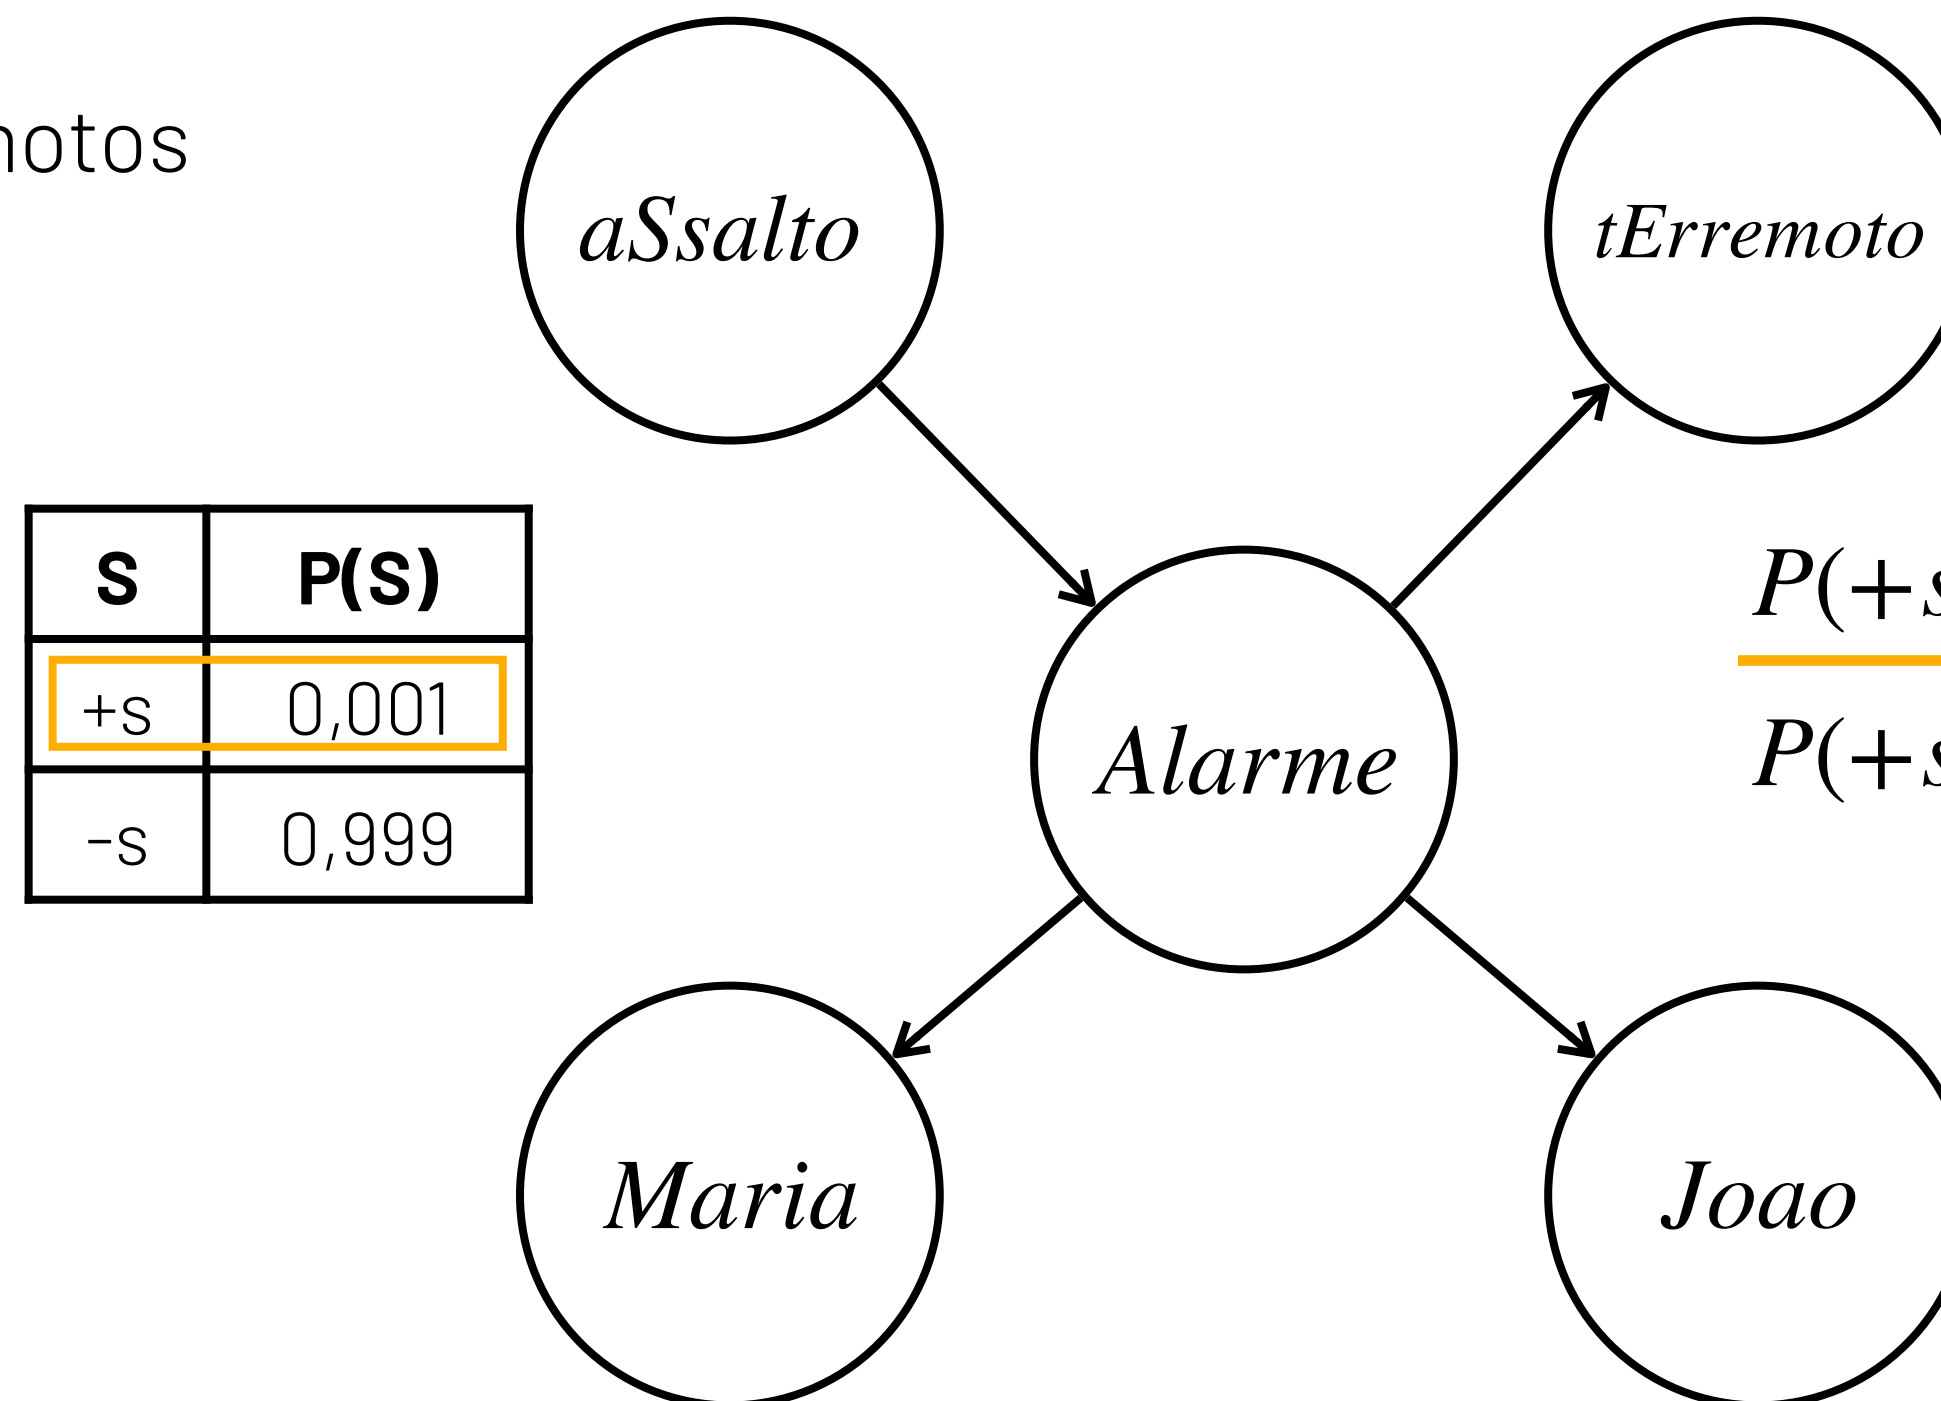

R	P
+chuva	1/2
-chuva	1/2

R	T	P
+chuva	+trânsito	3/4
+chuva	-trânsito	1/4
-chuva	+trânsito	1/2
-chuva	-trânsito	1/2

$$P(+chuva, -transito) = P(+chuva)P(-transito | +chuva) = \frac{1}{2} \times \frac{1}{4} = \frac{1}{8}$$

- ▶ *A*: alarme
- ▶ *S*: assalto
- ▶ *M*: maria
- ▶ *J*: joão
- ▶ *E*: terremotos

Exemplo 8: redes bayesianas



E	P(E)
+e	0,002
-e	0,998

S	P(S)
+s	0,001
-s	0,999

$$P(+s, -e, +a, +m, +j) = P(+s) P(-e) P(+a | -e, +s) P(+a | +m) P(+a | +j)$$

A	M	P(M A)
+a	+m	0,7
+a	-m	0,3
-a	+m	0,01
-a	-m	0,99

A	J	P(J A)
+a	+j	0,9
+a	-j	0,1
-a	+j	0,05
-a	-j	0,95

S	E	A	P(A B,E)
+s	+e	+a	0,95
+s	+e	-a	0,05
+s	-e	+a	0,94
+s	-e	-a	0,06
-s	+e	+a	0,29
-s	+e	-a	0,71
-s	-e	+a	0,001
-s	-e	-a	0,999

Inferência por enumeração

- ▶ A : alarme
- ▶ S : assalto
- ▶ M : maria
- ▶ J : João
- ▶ E : terremotos

Dada uma rede bayesiana, queremos calcular a probabilidade condicional $P(Q | e_1, \dots, e_k)$, onde:

- ▶ Q é uma variável aleatória definindo uma consulta
- ▶ $E_1, \dots, E_k = e_1, \dots, e_k$ é um conjunto de variáveis aleatórias definindo a evidência
- ▶ Além disso, H_1, \dots, H_r é o conjunto de variáveis "escondidas" do modelo, não inclusas na consulta nem na evidência

Inferência por enumeração:

1) **Selecionar** as entradas consistentes com a evidência

2) **Somar** as variáveis em H para obter $P(Q, e_1, \dots, e_k)$

$$P(Q, e_1, \dots, e_k) = \sum_{h_1, \dots, h_r} P(Q, h_1, \dots, h_r, e_1, \dots, e_k)$$

3) **Normalizar** $P(Q, e_1, \dots, e_k)$ para obter $P(Q | e_1, \dots, e_k)$

$$P(Q | e_1, \dots, e_k) = \frac{P(Q, e_1, \dots, e_k)}{\sum_q P(Q, e_1, \dots, e_k)}$$

Exemplo (alarme):

$$P(S | +j, +m)$$

$$P(S, +j, +m) = \sum_{e,a} P(S, e, a, +j, +m)$$

$$P(S, +j, +m) = \sum_{e,a} P(S)P(e)P(a | S, e)P(+j | s)P(+m | s)$$

$$P(S | +j, +m) = \frac{P(S, +j, +m)}{\sum_s P(S, +j, +m)}$$

Próxima aula

A16: Raciocínio Probabilístico III

Processos (cadeias) de Markov, modelos de transição, inferência, amostragem, distribuição estacionária