



# INF 1771 – Inteligência Artificial

## Aula 19 – Incerteza 2016.1



Prof. Augusto Baffa  
<[abaffa@inf.puc-rio.br](mailto:abaffa@inf.puc-rio.br)>




# Agentes Vistos Anteriormente

- Agentes baseados em busca:
  - Busca cega
  - Busca heurística
  - Busca local
- Agentes baseados em lógica:
  - Lógica proposicional
  - Lógica de primeira ordem
- Agentes baseados em planejamento:
  - Planejamento de ordem parcial
  - Planejamento em ambientes não-determinísticos
- Agentes com Aprendizagem

# Incerteza

- Mundo parcialmente observável: Agentes raramente tem acesso à toda informação sobre o ambiente.



- Mundo de Wumpus:
  - Apenas informações locais.
  - Maior parte do ambiente não é imediatamente observável.
  - Incerteza de fatos:
- O mundo real é muito mais complexo do que o mundo de wumpus. Informações não garantem resultados.

# Incerteza

- Exemplo: Levar alguém ao aeroporto para pegar um voo.
- Seja a ação  $A_t$  = sair para o aeroporto  $t$  minutos antes do voo.
  - $A_t$  levará o passageiro ao aeroporto a tempo?
- Dificuldades de saber o resultado da ação:
  - Estados parcialmente observáveis.
    - Estados das estradas, trânsito, etc.
  - Sensores ruidosos.
    - Relatórios de tráfego
  - Incerteza quanto ao efeito das ações.
    - Acidentes, pneu furado, etc.
  - Grande complexidade em prever e modelar o trânsito.

# Incerteza

- Assim, um procedimento puramente lógico não é muito útil nesse caso:
  - Arriscaria deduzir algo potencialmente falso:
    - “ $A_{45}$  me levará a tempo ao aeroporto”
  - Levaria a conclusões fracas para tomada de decisões:
    - “ $A_{45}$  me levará a tempo ao aeroporto, se nenhum acidente ocorrer na ponte, se não chover, se nenhum pneu furar, etc.”
  - Levaria a conclusões que não práticas:
    - “ $A_{1440}$  me levará a tempo ao aeroporto”

# Incerteza

- O plano escolhido deve maximizar a performance do agente.
  - Chegar no aeroporto a tempo.
  - Não perder tempo esperando no aeroporto.
- O agente não tem como garantir nenhum sucesso em seus objetivos.
- Mas ele pode prever um certo grau de crença que ele terá sucesso em seus objetivos.

# Métodos para lidar com incerteza

- Default ou lógica não monotônica:
  - Assuma que o carro não possua um pneu furado;
  - Assuma que  $A_{25}$  funcionaria a menos que haja evidência do contrário;
  - Quais (e quantas) hipóteses são razoáveis?
  - Como manipular conclusões falhas?
- Regras com fatores de incerteza:
  - $A_{25} \mid\rightarrow 0.3$  chegar ao aeroporto a tempo
  - mangueira  $\mid\rightarrow 0.99$  grama molhada
  - Grama molhada  $\mid\rightarrow 0.7$  chuva
- Problemas com a combinação de regras contraditórias:
  - A mangueira causa chuva?

# Métodos para lidar com incerteza

- Probabilidade
  - Modela o grau de crença de um agente
  - Dado evidências disponíveis
  - $A_{25}$  chegará ao aeroporto a tempo com probabilidade 0.04
- (Fuzzy manipula o grau de veracidade NÃO incerteza. E.g. “Gramma está molhada” é verdade com um grau de 0.2)



# Incerteza

- A coisa certa a se fazer depende da importância dos objetivos e da probabilidade de que eles serão alcançados.
- É necessário lidar com a incerteza e a imprecisão dos ambientes.

# Incerteza


- Considerando a seguinte regra em lógica de primeira ordem:
  - $\forall p \text{ Sintoma}(p, \text{Dor\_de\_Dente}) \Rightarrow \text{Doença}(p, \text{Cáries})$
- A regra está errada. Nem todas as pessoas que têm dor de dente têm cáries, algumas podem ter outras doenças.
  - $\forall p \text{ Sintoma}(p, \text{Dor\_de\_Dente}) \Rightarrow \text{Doença}(p, \text{Cáries}) \vee \text{Doença}(p, \text{Gengivite}) \vee \text{Doença}(p, \text{Abscesso}) \dots$
- Para tornar essa regra verdadeira seria necessário adicionar a ela uma lista infinita de possibilidades.

# Incerteza

- Tentar utilizar lógica de primeira ordem para lidar com um domínio de diagnóstico médico falha por três razões:
  - Preguiça: É muito trabalho listar o conjunto completo de sentenças necessárias para garantir uma regra sem exceção.
  - Ignorância teórica: A medicina não tem nenhuma teoria completa para todos os domínios.
  - Ignorância prática: Mesmo conhecendo todas as regras, poderiam existir dúvidas sobre um determinado paciente.
- Este tipo de problema afeta também outros domínios: Negócios, Direito, Design, Reparação automóveis, Jardinagem...

# Fontes de Incerteza

- Informações precisas podem ser muito complexas para serem modeladas.
- É necessário lidar com informações incompletas.
  - Implicações podem ser modeladas de forma mais fraca:
    - Dor\_de\_Dente(0.7)  $\Rightarrow$  Doença(Cáries)





Quantificação do número de vezes em que a regra se aplica.

# Fontes de Incerteza

- Conflito de informações:
  - Especialistas distintos podem fornecer informações conflitantes e incertas.
- Propagação de incertezas:
  - Fatos com um certo grau de incerteza implicam em outros fatos com um grau de incerteza ainda maior.

– Exemplo:

- $a \Rightarrow b$
- $b \Rightarrow c$



# Lidando com a Incerteza

- A principal ferramenta para se lidar com a incerteza é a teoria da probabilidade. Busca-se atribuir um grau de crença numérica (entre 0 e 1) a cada sentença.
- Modela-se o grau de crença de um agente dadas as evidências disponíveis:
  - “ $A_{25}$  chegará a tempo ao aeroporto com probabilidade 0.04”
  - “ $A_{45}$  chegará a tempo ao aeroporto com probabilidade 0.85”
  - “ $A_{60}$  chegará a tempo ao aeroporto com probabilidade 0.95”

# Probabilidade

- A probabilidade subjetiva ou bayesiana estabelece o estado de crença do agente em uma sentença dadas as evidências.
  - $P(A_{25} | \text{nenhum acidente}) = 0.06$
- A probabilidade de uma sentença muda quando novas evidências chegam.
  - $P(A_{25} | \text{nenhum acidente}) = 0.06$
  - $P(A_{25} | \text{nenhum acidente, 5 a.m.}) = 0.15$

# Decisões sob Incerteza

- Supondo o seguinte conjunto de crenças:
  - $P(A_{25} | \dots) = 0.04$
  - $P(A_{90} | \dots) = 0.70$
  - $P(A_{120} | \dots) = 0.95$
  - $P(A_{1440} | \dots) = 0.9999$
- Que ação o agente deve tomar?
  - Depende da preferência entre perder o voo versus o tempo esperando no aeroporto.
    - Teoria da utilidade = representação de preferências
    - Teoria da decisão = teoria da probabilidade + teoria da utilidade



# Introdução à Probabilidade

- Elemento básico da probabilidade é uma variável aleatória.
  - Semelhante a lógica proposicional e de primeira ordem, onde os mundos possíveis são definidos pela atribuição de valores às variáveis.
  - Cada variável aleatória tem um domínio que determina seus valores possíveis.
    - Tipos de domínio:
      - Booleano, exemplo: Cárie possui valores em <verdadeiro, falso>
      - Discreto, exemplo: Clima possui valores em <ensolarado, chuvoso, nublado, neve>
      - Contínuo, exemplo: Temperatura

# Introdução à Probabilidade


- Proposições elementares:
  - São construídas através da atribuição de valores a variáveis.
  - Exemplo: Cárie = falso, Clima = chuvoso
- Proposições complexas:
  - São formadas a partir de proposições elementares e conectivos lógicos padrão.
  - Exemplo: Clima = chuvoso  $\wedge$  Cárie = falso

# Introdução à Probabilidade

- Um evento atômico consiste da especificação completa do estado do mundo sobre o qual o agente está incerto.
  - Uma atribuição de valores a TODAS as variáveis das quais o mundo é formado.
- Exemplo:
  - Cárie = verdadeiro  $\wedge$  DorDeDente = verdadeiro
  - Cárie = verdadeiro  $\wedge$  DorDeDente = falso
  - Cárie = falso  $\wedge$  DorDeDente = verdadeiro
  - Cárie = falso  $\wedge$  DorDeDente = falso

# Probabilidade incondicional ou “*a priori*”

- O grau de crença em uma proposição na ausência de outras informações pode ser definida da seguinte maneira:
  - $P(\text{Cárie} = \text{verdadeiro}) = 0.1$
  - $P(\text{Clima} = \text{ensolarado}) = 0.72$
- Distribuição de probabilidades:
  - $P(\text{Clima}) = (0.7, 0.2, 0.08, 0.02)$



Distribuição de probabilidade da variável randomica *Clima* =  
(ensolarado, chuvoso, nublado, neve)

# Distribuição de Probabilidade Conjunta

- Probabilidades de todas as combinações de valores de um conjunto de variáveis aleatórias.
  - $P(\text{Clima}, \text{Cárie}) =$  tabela 4 x 2 de valores de probabilidade.

Clima	ensolarado	chuvoso	nublado	Neve
Cárie = verdadeiro	0.144	0.02	0.016	0.02
Cárie = falso	0.576	0.08	0.064	0.08

- Uma distribuição conjunta total especifica a probabilidade de qualquer evento atômico.
  - Qualquer probabilidade nesse domínio pode ser calculada a partir da distribuição conjunta total.

# Probabilidade Condicional ou “*a posteriori*”

- O grau de crença em uma proposição dada a presença de novas evidências pode ser definido utilizando a notação  $P(a|b)$ :
  - $P(\text{Cárie} = \text{verdadeiro} | \text{Dor\_De\_Dente} = \text{verdadeiro}) = 0.6$
  - $P(\text{Cárie} = \text{verdadeiro} | \text{Dor\_De\_Dente} = \text{verdadeiro}, \text{Escova\_Dentes\_Regularmente} = \text{false}) = 0.7$
- $P(a|b) =$  “A probabilidade de a dado todo o conhecimento b”.

# Probabilidade Condicional

- A probabilidade condicional pode ser definida em termos de probabilidades a priori:

$$P(a|b) = \frac{P(a \wedge b)}{P(b)} \quad \text{para } P(b) > 0$$

- A mesma equação também pode ser escrita da seguinte maneira utilizando a regra do produto:


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

- Ou:

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

# Axiomas da Probabilidade

- Para quaisquer proposições A, B:
  - $0 \leq P(A) \leq 1$
  - $P(\text{Verdade}) = 1$
  - $P(\text{Falso}) = 0$
  - $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$





# Probabilidade

- A probabilidade de uma proposição é igual à soma das probabilidades dos eventos atômicos em que ela é válida:

$$P(a) = \sum_{e_i \in e(a)} P(e_i)$$

- Essa equação permite calcular a probabilidade de qualquer proposição dada uma distribuição conjunta total que especifique todos os eventos atômicos.

# Inferência Probabilística

- Inferência probabilística consiste na computação da distribuição de probabilidade posterior para um conjunto de variáveis de consulta  $C$  dada alguma evidência observada.
- A inferência é realizada com o uso de distribuições conjuntas totais. Ou seja, uma base de conhecimento a partir da qual são derivadas respostas para todas as consultas.

# Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total:

	Dor_De_Dente		¬Dor_De_Dente	
	Sonda	¬Sonda	Sonda	¬Sonda
Cárie	0.108	0.012	0.072	0.008
¬Cárie	0.016	0.064	0.144	0.576

- Para qualquer proposição  $a$ ,  $P(a)$  é a soma dos eventos atômicos  $w$  onde  $a$  ocorre:

$$P(a) = \sum_{e_i \in e(a)} P(e_i)$$

# Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total:

	Dor_De_Dente		¬Dor_De_Dente	
	Sonda	¬Sonda	Sonda	¬Sonda
Cárie	0.108	0.012	0.072	0.008
¬Cárie	0.016	0.064	0.144	0.576

- Para qualquer proposição  $a$ ,  $P(a)$  é a soma dos eventos atômicos  $w$  onde  $a$  ocorre:

$$P(a) = \sum_{e_i \in e(a)} P(e_i)$$

- $P(\text{Dor\_De\_Dente}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$

# Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total:

	Dor_De_Dente		¬Dor_De_Dente	
	Sonda	¬Sonda	Sonda	¬Sonda
Cárie	0.108	0.012	0.072	0.008
¬Cárie	0.016	0.064	0.144	0.576

- Para qualquer proposição  $a$ ,  $P(a)$  é a soma dos eventos atômicos  $w$  onde  $a$  ocorre:

$$P(a) = \sum_{e_i \in e(a)} P(e_i)$$

- $P(\text{Dor\_De\_Dente} \vee \text{Cárie}) = 0.108 + 0.012 + 0.016 + 0.064 + 0.072 + 0.008 = 0.28$

# Inferência Probabilística

- É possível também calcular probabilidades condicionais:  $P(a|b) = \frac{P(a \wedge b)}{P(b)}$

	Dor_De_Dente		¬Dor_De_Dente	
	Sonda	¬Sonda	Sonda	¬Sonda
Cárie	0.108	0.012	0.072	0.008
¬Cárie	0.016	0.064	0.144	0.576

$$P(\neg\text{Cárie} | \text{Dor\_De\_Dente}) = \frac{P(\neg\text{Cárie} \wedge \text{Dor\_De\_Dente})}{P(\text{Dor\_De\_Dente})}$$

$$P(\neg\text{Cárie} | \text{Dor\_De\_Dente}) = \frac{0.016 + 0.064}{0.108 + 0.012 + 0.016 + 0.064} = 0.4$$

# Inferência Probabilística

- O denominador pode ser visto como uma constante de normalização  $\alpha$ .

	Dor_De_Dente		¬Dor_De_Dente	
	Sonda	¬Sonda	Sonda	¬Sonda
Cárie	0.108	0.012	0.072	0.008
¬Cárie	0.016	0.064	0.144	0.576

$$\begin{aligned}P(\text{Cárie} \mid \text{Dor\_De\_Dente}) &= \alpha P(\text{Cárie}, \text{Dor\_De\_Dente}) \\&= \alpha [P(\text{Cárie}, \text{Dor\_De\_Dente}, \text{Sonda}) + P(\text{Cárie}, \text{Dor\_De\_Dente}, \neg \text{Sonda})] \\&= \alpha [\langle 0.108, 0.016 \rangle + \langle 0.012, 0.064 \rangle] \\&= \alpha [\langle 0.12, 0.08 \rangle] \\&= \langle 0.6, 0.4 \rangle\end{aligned}$$
$$\begin{aligned}\alpha &= P(\text{Dor\_De\_Dente}) = 0.2 \\&= [\langle 0.12, 0.08 \rangle] / 0.2 \\&= \langle 0.6, 0.4 \rangle\end{aligned}$$

# Problemas com a inferência por enumeração

- Complexidade de tempo (pior caso):  $O(dn)$ 
  - onde  $d$  é a cardinalidade do maior domínio e  $n$  é o número de variáveis.
- Complexidade de espaço:  $O(dn)$  para armazenar a distribuição conjunta.
- Como encontrar as probabilidades para  $O(dn)$  elementos?



# Independência

- X e Y são independentes se e somente se:
  - $P(X|Y) = P(X)$  ou  $P(Y|X) = P(Y)$  ou  $P(X,Y) = P(X)P(Y)$
- Exemplo:  $P(\text{Dor\_De\_Dente}, \text{Sonda}, \text{Cárie}, \text{Clima})$ 
  - Tabela com 32 elementos.
  - $P(\text{Dor\_De\_Dente}, \text{Cárie}, \text{Sonda}, \text{Clima}) = P(\text{Dor\_De\_Dente}, \text{Cárie}, \text{Sonda})P(\text{Clima})$



# Independência Condicional

- Se eu tenho cárie, a probabilidade do boticão acertar esse dente não depende de minha dor de dente:
  - (1)  $P(\text{Sonda} | \text{Dor\_De\_Dente}, \text{Cárie}) = P(\text{Sonda} | \text{Cárie})$
- A mesma independência ocorre se eu não tiver uma cárie:
  - (2)  $P(\text{Sonda} | \text{Dor\_De\_Dente}, \neg \text{Cárie}) = P(\text{Sonda} | \neg \text{Cárie})$
- I.e. Sonda (Boticão) é condicionalmente independente da Dor\_De\_Dente dado Cárie:
  - $P(\text{Sonda} | \text{Dor\_De\_Dente}, \text{Cárie}) = P(\text{Sonda} | \text{Cárie})$
- Sentenças Equivalentes :
  - $P(\text{Dor\_De\_Dente} | \text{Sonda}, \text{Cárie}) = P(\text{Dor\_De\_Dente} | \text{Cárie})$
  - $P(\text{Dor\_De\_Dente}, \text{Sonda} | \text{Cárie}) = P(\text{Dor\_De\_Dente} | \text{Cárie}) P(\text{Sonda} | \text{Cárie})$

# Independência Condicional

- Escrevendo toda a distribuição total utilizando a regra da cadeia:

$$\begin{aligned} P(\text{Dor\_De\_Dente}, \text{Sonda}, \text{Cárie}) &= P(\text{Dor\_De\_Dente} | \text{Sonda}, \text{Cárie}) P(\text{Sonda}, \text{Cárie}) \\ &= P(\text{Dor\_De\_Dente} | \text{Sonda}, \text{Cárie}) P(\text{Sonda} | \text{Cárie}) P(\text{Cárie}) \\ &= P(\text{Dor\_De\_Dente} | \text{Cárie}) P(\text{Sonda} | \text{Cárie}) P(\text{Cárie}) \end{aligned}$$

- Na maioria dos casos, o uso da independência condicional reduz o tamanho da representação em distribuição conjunta de exponencial em  $n$  para linear em  $n$ .

# Teorema de Bayes

- Seja:
  - $P(A|B)$  a probabilidade de que a hipótese  $A$  seja verdadeira dada a evidência  $B$ .
  - $P(B|A)$  a probabilidade que a evidência  $B$  será observada se a hipótese  $A$  for verdadeira.
  - $P(A)$  a probabilidade “*a priori*” que a hipótese  $A$  é verdadeira na ausência de qualquer evidência específica.
  - $k$  o número de hipóteses possíveis.
- O Teorema de Bayes é formulado como:

$$P(A|B) = \frac{P(B|A) * P(A)}{\sum_{n=0}^k P(B|A_n) * (P(A_n))}$$

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

# Regra de Bayes – Exemplo

- Para aplicar a regra de Bayes é necessário três termos:
  - Uma probabilidade condicional.
  - Duas probabilidades incondicionais.
- Exemplo de diagnostico médico:
  - “um médico sabe que a meningite causa torcicolo em 50% dos casos. Porém, o médico também conhece algumas probabilidades incondicionais que dizem que, um caso de meningite atinge 1/50000 pessoas e, a probabilidade de alguém ter torcicolo é de 1/20”.

# Regra de Bayes – Exemplo

- Considerando:
  - T = probabilidade incondicional de um paciente ter torcicolo:  
 $P(T) = 1/20$
  - M = probabilidade incondicional de um paciente ter meningite.  
 $P(M) = 1/50000$
  - $P(T|M) = 0.5$  (probabilidade de ter torcicolo tendo meningite)

# Regra de Bayes – Exemplo

- Aplicando a regra de Bayes:

$$P(M | T) = \frac{P(T | M)P(M)}{P(T)}$$

$$P(M | T) = \frac{0.5 \times 1/50000}{1/20}$$

$$P(M | T) = 0.0002$$

- É esperado que apenas 1 em 5000 pacientes com torcicolo tenha meningite.
- Apesar de torcicolo ser um fortemente indicativo de meningite (com probabilidade 0.5), a probabilidade de meningite no paciente permanece pequena.

# Regra de Bayes – Combinando Evidencias

- $P(\text{Cárie} | \text{Dor\_De\_Dente} \wedge \text{Sonda})$   
=  $\alpha < 0.108, 0.016 >$   
=  $< 0.871, 0.129 >$
- Utilizando o conceito de independência é possível reduzir o problema de escala em problemas mais complexos.
- Funcionaria se Dor\_De\_Dente e Sonda fossem independentes, mas eles não são. Essas variáveis são independentes somente dado a presença ou a ausência de Cárie.



# Regra de Bayes – Combinando Evidencias

- Dor\_De\_Dente e Sonda são causas diretas de Cárie, mas não tem nenhum efeito direto uma sobre a outra.
  - $P(\text{Dor\_De\_Dente} \wedge \text{Sonda} | \text{Cárie}) = P(\text{Dor\_De\_Dente} | \text{Cárie})P(\text{Sonda} | \text{Cárie})$
- Para obter a probabilidade de Cárie:
  - $P(\text{Cárie} | \text{Dor\_De\_Dente} \wedge \text{Sonda}) = \alpha P(\text{Dor\_De\_Dente} | \text{Cárie})P(\text{Sonda} | \text{Cárie})P(\text{Cárie})$



- O número total de parâmetros é linear  $n$

# Leitura Complementar

- Russell, S. and Norvig, P. **Artificial Intelligence: a Modern Approach**, 3rd Edition, Prentice-Hall, 2009.
  - **Capítulo 13: Uncertainty**
- Coppin, B. **Artificial Intelligence Illuminated**, Jones & Bartlett Learning, 2004.
  - **Capítulo 12: Probabilistic Reasoning and Bayesian Belief Networks**

