

# Sistemas Inteligentes

## **Incerteza**

# Incerteza

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

# Incerteza

- Um procedimento puramente lógico não é muito útil nesse caso, porque:
  1. Arriscaria deduzir algo potencialmente falso
    - “ $A_{45}$  me levará a tempo ao aeroporto”
  2. 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.”
  3. Levaria a conclusões não práticas
    - “ $A_{1440}$  me levará a tempo ao aeroporto”

# Lidando com a incerteza

- Probabilidade

- Modela o **grau de crença** de um agente dadas as evidências disponíveis

- “ $A_{25}$  chegará a tempo com probabilidade 0,04”
    - “ $A_{45}$  chegará a tempo com probabilidade 0,85”
    - “ $A_{60}$  chegará a tempo com probabilidade 0,95”

# Probabilidade

- A probabilidade proporciona um meio para resumir a incerteza que vem de:
  - Preguiça = falha em enumerar todas as possíveis exceções à regra
  - Ignorância = falta de conhecimento sobre fatos relevantes, condições iniciais

# Probabilidade

- Probabilidade subjetiva ou bayesiana
  - Estabelece o estado de crença do agente em uma sentença, dadas as evidências.
  - Muda quando novas evidências chegam
    - $P(A_{25} | \text{nenhum acidente}) = 0,06$
    - $P(A_{25} | \text{nenhum acidente, 5 a.m.}) = 0,15$
- As sentenças são verdadeiras ou falsas.
  - O que muda é o grau de crença do agente na sentença.
  - Atribuir probabilidade 0 a uma sentença significa acreditar que ela é falsa com certeza absoluta.
  - Atribuir probabilidade 1 a uma sentença significa acreditar que ela é verdadeira com certeza absoluta.

# Decisões sob incerteza

- Suponha o seguinte conjunto de crenças:
  - $P(A_{25} \text{ chega a tempo} \mid \dots) = 0,04$
  - $P(A_{90} \text{ chega a tempo} \mid \dots) = 0,70$
  - $P(A_{120} \text{ chega a tempo} \mid \dots) = 0,95$
  - $P(A_{1440} \text{ chega a tempo} \mid \dots) = 0,9999$
- Que ação o agente deve tomar?
  - Depende de suas **preferências** sob perder o voo versus o tempo esperando no aeroporto.
    - Teoria da utilidade = representação de preferências
    - Teoria da decisão = teoria da probabilidade + teoria da utilidade

# Agente de teoria da decisão

- Representação não apenas de *possibilidades*, mas de *probabilidades* dos estados do mundo.
- Esboço da estrutura de um agente que usa a teoria da decisão para selecionar ações:

**função** AGENTE-TD(*percepção*) **retorna** uma *ação*

**variáveis estáticas:** *estado\_de\_crença*, crenças probabilísticas sobre o estado atual do mundo  
*ação*, a ação do agente

atualizar *estado\_de\_crença* com base em *ação* e *percepção*

calcular probabilidades de resultados de ações,

dadas descrições de ações e o *estado\_de\_crença* atual

selecionar *ação* com utilidade esperada mais alta

dadas as probabilidades de resultados e informações de utilidade

**retornar** *ação*

# Introdução à probabilidade

- Elemento básico: variável aleatória
  - Análogo à lógica proposicional
    - 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**, ex.: *Cárie* possui valores em <verdadeiro,falso>
      - **Discreto**, ex.: *Clima* possui valores em <ensolarado, chuvoso, nublado, neve>
      - **Contínuo**, ex.: *Temperatura*

# Introdução à probabilidade

- Proposições elementares
  - São construídas por meio da atribuição de valores a variáveis.
  - Ex.: *Clima* = ensolarado, *Cárie* = falso (abreviado como  $\neg$ *Cárie*)
- Proposições complexas
  - São formadas a partir de proposições elementares e conectivos lógicos padrão
  - Ex.: *Clima* = ensolarado  $\vee$  *Cárie* = falso

# Introdução à probabilidade

- Evento atômico
  - 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.
    - Eventos atômicos são mutuamente exclusivos e exaustivos.


# Evento atômico: exemplo

- Se o mundo consistir somente de 2 variáveis booleanas (*Cárie* e *DorDeDente*), então há 4 eventos atômicos distintos:
  - *Cárie* = verdadeiro  $\wedge$  *DorDeDente* = verdadeiro
  - *Cárie* = verdadeiro  $\wedge$  *DorDeDente* = falso
  - *Cárie* = falso  $\wedge$  *DorDeDente* = verdadeiro
  - *Cárie* = falso  $\wedge$  *DorDeDente* = falso

# Axiomas da Probabilidade

- Para quaisquer proposições  $A, B$ 
  - $0 \leq P(A) \leq 1$
  - $P(\textit{verdade}) = 1$  e  $P(\textit{falso}) = 0$
  - $P(A \vee B) = P(A) + P(B) - P(A \wedge B)$

True



# 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.

# Probabilidade incondicional ou “a priori”

- É o grau de crença em uma proposição na ausência de outras informações.
  - Exemplos:
    - $P(\text{Cárie} = \text{verdadeiro}) = 0,1$
    - $P(\text{Clima} = \text{ensolarado}) = 0,72$
- Distribuição de probabilidades
  - Dá probabilidades a todos os valores possíveis de uma variável aleatória.
    - Climas: <ensolarado, chuvoso, nublado, neve>
    - $P(\text{Clima}) = \langle 0,72; 0,1; 0,08; 0,1 \rangle$  (**normalizado**, soma 1)

# 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:

<i>Clima =</i>	ensolarado	chuvoso	nublado	neve
<i>Cárie = verdadeiro</i>	0,144	0,02	0,016	0,02
<i>Cárie = falso</i>	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”

- É o grau de crença em uma proposição dada a presença de evidências (valores de variáveis aleatórias conhecidos).
- “|” é pronunciado como “considerando que”
  - Exemplos:
    - $P(\text{Cárie} = \text{verdadeiro} \mid \text{DorDeDente} = \text{verdadeiro}) = 0,8$
    - $P(\text{Cárie} = \text{verdadeiro} \mid \text{DorDeDente} = \text{verdadeiro}, \text{Cárie} = \text{verdadeiro}) = 1$
    - $P(\text{Cárie} = \text{verdadeiro} \mid \text{DorDeDente} = \text{verdadeiro}, \text{Ensolarado} = \text{verdadeiro}) = P(\text{Cárie} = \text{verdadeiro} \mid \text{DorDeDente}) = 0,8$
- Distribuição condicional
  - $P(Y|X)$  fornece o valor de  $P(Y=y_i \mid X=x_j)$  para cada valor de  $i$  e  $j$  possíveis.

# Probabilidade Condicional

- Definição de probabilidade condicional:

$$P(a | b) = P(a \wedge b) / P(b) \text{ se } P(b) > 0$$

- Regra do produto** como formulação alternativa:

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

- Pode ser generalizado para distribuições totais,

$$P(\text{Clima}, \text{Cárie}) = P(\text{Clima} | \text{Cárie}) P(\text{Cárie})$$

(um conjunto de  $4 \times 2$  equações)

- Regra da cadeia** é obtida a partir de aplicações sucessivas da regra do produto:

$$\begin{aligned} P(X_1, \dots, X_n) &= P(X_1, \dots, X_{n-1}) P(X_n | X_1, \dots, X_{n-1}) \\ &= P(X_1, \dots, X_{n-2}) P(X_{n-1} | X_1, \dots, X_{n-2}) P(X_n | X_1, \dots, X_{n-1}) \\ &= \dots \\ &= \prod_{i=1}^n P(X_i | X_1, \dots, X_{i-1}) \end{aligned}$$

# Inferência Probabilística

- **Inferência probabilística:** a computação a partir de evidências observadas de probabilidades posteriores para proposições de consulta.
- **Inferência com o uso de distribuições conjuntas totais:** base de conhecimento a partir da qual são derivadas respostas para todas as consultas.

# Exemplo:

## Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total: :

	<i>dordedente</i>		$\neg$ <i>dordedente</i>	
	<i>boticão</i>	$\neg$ <i>boticão</i>	<i>boticão</i>	$\neg$ <i>boticão</i>
<i>cárie</i>	<b>.108</b>	<b>.012</b>	<b>.072</b>	<b>.008</b>
$\neg$ <i>cárie</i>	<b>.016</b>	<b>.064</b>	<b>.144</b>	<b>.576</b>

- Para qualquer proposição  $\varphi$ ,  $P(\varphi)$  é a soma dos eventos atômicos  $\omega$  onde  $\varphi$  ocorre:  $P(\varphi) = \sum_{\omega: \omega \models \varphi} P(\omega)$

# Exemplo:

## Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total:

	<i>dordedente</i>		$\neg$ <i>dordedente</i>	
	<i>boticão</i>	$\neg$ <i>boticão</i>	<i>boticão</i>	$\neg$ <i>boticão</i>
<i>cárie</i>	<b>.108</b>	<b>.012</b>	<b>.072</b>	<b>.008</b>
$\neg$ <i>cárie</i>	<b>.016</b>	<b>.064</b>	<b>.144</b>	<b>.576</b>

- Para qualquer proposição  $\varphi$ ,  $P(\varphi)$  é a soma dos eventos atômicos  $\omega$  onde  $\varphi$  ocorre:  $P(\varphi) = \sum_{\omega: \omega \models \varphi} P(\omega)$
- $P(\textit{dordedente}) = 0,108 + 0,012 + 0,016 + 0,064 = 0,2$

# Exemplo:

## Inferência Probabilística

- Suponha um domínio com a seguinte distribuição conjunta total:

	<i>dordedente</i>		$\neg$ <i>dordedente</i>	
	<i>boticão</i>	$\neg$ <i>boticão</i>	<i>boticão</i>	$\neg$ <i>boticão</i>
<i>cárie</i>	<b>.108</b>	<b>.012</b>	<b>.072</b>	<b>.008</b>
$\neg$ <i>cárie</i>	<b>.016</b>	<b>.064</b>	<b>.144</b>	<b>.576</b>

- Para qualquer proposição  $\varphi$ ,  $P(\varphi)$  é a soma dos eventos atômicos  $\omega$  onde  $\varphi$  ocorre:  $P(\varphi) = \sum_{\omega: \omega \models \varphi} P(\omega)$

$$P(\textit{dordedente} \vee \textit{cárie}) = 0,108 + 0,012 + 0,016 + 0,064 + 0,072 + 0,008 = 0,28$$

# Exemplo:

## Inferência Probabilística

- Podemos calcular probabilidades condicionais:

	<i>dordedente</i>		$\neg$ <i>dordedente</i>	
	<i>boticão</i>	$\neg$ <i>boticão</i>	<i>boticão</i>	$\neg$ <i>boticão</i>
<i>cárie</i>	<b>.108</b>	<b>.012</b>	<b>.072</b>	<b>.008</b>
$\neg$ <i>cárie</i>	<b>.016</b>	<b>.064</b>	<b>.144</b>	<b>.576</b>

$$\begin{aligned}
 P(\neg \textit{cárie} \mid \textit{dordedente}) &= \frac{P(\neg \textit{cárie} \wedge \textit{dordedente})}{P(\textit{dordedente})} \\
 &= \frac{0,016 + 0,064}{0,108 + 0,012 + 0,016 + 0,064} \\
 &= 0,4
 \end{aligned}$$

# Normalização

## Inferência Probabilística

	<i>dordedente</i>		<i>¬dordedente</i>	
	<i>boticão</i>	<i>¬boticão</i>	<i>boticão</i>	<i>¬boticão</i>
<i>cárie</i>	<b>.108</b>	<b>.012</b>	<b>.072</b>	<b>.008</b>
<i>¬cárie</i>	<b>.016</b>	<b>.064</b>	<b>.144</b>	<b>.576</b>

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

$$\begin{aligned} P(\text{Cárie} | \text{dordedente}) &= \alpha P(\text{Cárie}, \text{dordedente}) \\ &= \alpha [P(\text{Cárie}, \text{dordedente}, \text{boticão}) + P(\text{Cárie}, \text{dordedente}, \neg \text{boticão})] \\ &= \alpha [0,108 + 0,012] \\ &= \alpha [0,12] \\ &= 0,6 \end{aligned}$$

# Inferência Probabilística: Inferência por Enumeração

- Objetivo: calcular a distribuição de probabilidade das **variáveis de consulta**  $X$  (*Cárie* no exemplo), dados valores para as **variáveis de evidência**  $E$  (*DorDeDente* no ex.).
  - Sejam  $Y$  as variáveis restantes, não observadas (*Boticão* no ex.), temos

$$\mathbf{P}(X | e) = \alpha \sum_y \mathbf{P}(X, e, y)$$

Note que cada  $\mathbf{P}(X, e, y)$  aparece na distribuição conjunta total


# Problemas com a inferência por enumeração

- Complexidade de tempo (pior caso):  $O(d^n)$   
onde  $d$  é a cardinalidade do maior domínio e  $n$  é o número de variáveis (se booleano,  $d=2$ ).
- Complexidade de espaço:  $O(d^n)$  para armazenar a distribuição conjunta.
- Como encontrar as probabilidades para  $O(d^n)$  elementos?
- Em um problema realista,  $n$  pode ser maior que 100, e a forma tabular não é prática.

# Independência

- A e B são independentes se e somente se

$$\mathbf{P(A|B) = P(A)} \quad \text{ou} \quad \mathbf{P(B|A) = P(B)} \quad \text{ou} \quad \mathbf{P(A, B) = P(A) P(B)}$$



$$\begin{aligned} &\mathbf{P(\text{DorDeDente}, \text{Cárie}, \text{Boticão}, \text{Clima})} \\ &= \mathbf{P(\text{DorDeDente}, \text{Cárie}, \text{Boticão})P(\text{Clima})} \\ &\quad \text{(32 entradas reduzidas a 12).} \end{aligned}$$

- Porém, independência total é rara.

# Independência Condicional

- Se eu tenho cárie, a probabilidade de uso do boticão não depende de eu ter ou não dor de dente.
  - $P(\text{Boticão} \mid \text{dordedente}, \text{cárie}) = P(\text{Boticão} \mid \text{cárie})$
- A mesma independência ocorre se eu não tiver cárie.
  - $P(\text{Boticão} \mid \text{dordedente}, \neg \text{cárie}) = P(\text{Boticão} \mid \neg \text{cárie})$
- Logo Boticão é condicionalmente independente de DorDeDente dado cárie:
  - $P(\text{Boticão} \mid \text{DorDeDente}, \text{Cárie}) = P(\text{Boticão} \mid \text{Cárie})$

# Independência Condicional

- Escrevendo a distribuição total usando a regra da cadeia:  
 $P(\text{DorDeDente}, \text{Boticão}, \text{Cárie})$   
 $= P(\text{DorDeDente} \mid \text{Boticão}, \text{Cárie}) P(\text{Boticão} \mid \text{Cárie}) P(\text{Cárie})$   
 $= P(\text{DorDeDente} \mid \text{Cárie}) P(\text{Boticão} \mid \text{Cárie}) P(\text{Cárie})$
- Nesse exemplo, o número de valores para especificar a distribuição conjunta passa de 8 para 6.
- Na maioria dos casos, o uso da independência condicional reduz o tamanho da distribuição conjunta de exponencial em  $n$  para linear em  $n$ .

# Regra de Bayes

- Da regra do produto  $P(a \wedge b) = P(a | b) P(b) = P(b | a) P(a)$   
 $\Rightarrow$  Regra de Bayes:  $P(a | b) = P(b | a) P(a) / P(b)$
- Ou na forma da distribuição conjunta::
  - $P(Y|X) = P(X|Y) P(Y) / P(X) = \alpha P(X|Y) P(Y)$
- Útil para acessar regras probabilísticas de diagnóstico por meio de probabilidades causais:
  - $P(\text{Causa}|\text{Efeito}) = P(\text{Efeito}|\text{Causa}) P(\text{Causa}) / P(\text{Efeito})$

# Regra de Bayes


- $P(\text{Causa}|\text{Efeito}) = P(\text{Efeito}|\text{Causa}) P(\text{Causa}) / P(\text{Efeito})$
- Exemplo:
  - O médico sabe que a meningite faz o paciente ter uma rigidez no pescoço em aproximadamente 70% do tempo
  - O médico conhece alguns fatos incondicionais:
    - Probabilidade *a priori* de um paciente com meningite: 1 / 50000
    - Probabilidade *a priori* de um paciente ter rigidez no pescoço: 1%
  - Seja  $M$  meningite,  $S$  rigidez no pescoço:  
$$P(m|s) = P(s|m) P(m) / P(s) = 0,7 \times (1/50000) / 0,01 = 0,0014$$
  - Nota: probabilidade posterior de meningite ainda é muito pequena (1 em 5000 pacientes com pescoço duro).

# Regra de Bayes e Independência Condicional

$$\begin{aligned} \mathbf{P}(\text{Cárie} \mid \text{dordedente} \wedge \text{boticão}) \\ &= \alpha \mathbf{P}(\text{dordedente} \wedge \text{boticão} \mid \text{Cárie}) \mathbf{P}(\text{Cárie}) \\ &= \alpha \mathbf{P}(\text{dordedente} \mid \text{Cárie}) \mathbf{P}(\text{boticão} \mid \text{Cárie}) \mathbf{P}(\text{Cárie}) \end{aligned}$$

- Este é um exemplo de modelo de **Bayes ingênuo** (naive Bayes):

$$\mathbf{P}(\text{Causa}, \text{Efeito}_1, \dots, \text{Efeito}_n) = \mathbf{P}(\text{Causa}) \prod_i \mathbf{P}(\text{Efeito}_i \mid \text{Causa})$$



- O número total de parâmetros é **linear**  $n$

---

# Classificação

## Usando Naive Bayes

Apresentação baseada:

no livro Introduction to Data Mining (Tan, Steinbach, Kumar) e  
em apresentações dos Profs. José Todesco (UFSC) e Luis  
OtavioAlvares (UFSC)

# Naive Bayes


---

- Abordagem estatística, baseada no teorema de Bayes. Naive (ingênuo) porque considera que os atributos são independentes.

# Naive Bayes – visão geral

---

Seja o exemplo de dados:



Os objetos podem ser classificados em vermelho ou verde


Como há mais objetos verdes que vermelhos, a probabilidade *a priori* é que um novo objeto seja verde

*Probabilidade a priori de verde = número de objetos verdes / número total de objetos =  $40/60 = 4/6$*

*Probabilidade a priori de vermelho = número de objetos vermelhos / número total de objetos =  $20/60 = 2/6$*

# Naive Bayes – visão geral

---



- Queremos classificar um novo objeto X (ponto branco)
- Como os objetos estão agrupados, é razoável considerar que quanto mais objetos de uma classe houver “parecidos” com X, maior a chance de X ser daquela classe.
- Vamos considerar o “parecido” pelo círculo na figura (estar dentro do círculo) e calcular a probabilidade:
- *Probabilidade de “parecido” dado que é verde = número de objetos verdes no círculo/ número total de verdes = 1/40*
- *Probabilidade de “parecido” dado que é vermelho = número de objetos vermelhos no círculo/ número total de vermelhos = 3/20*

# Naive Bayes – visão geral

---

- Na análise Bayesiana, a classificação final é realizada considerando estas duas informações usando a probabilidade condicional do Teorema de Bayes:
- A probabilidade condicional de X ser verde dado que é “parecido” = probabilidade a priori de verde vezes *Probabilidade de “parecido” dado que é verde* =  
$$4/6 \cdot 1/40 = 1/60$$
- *Analogamente,*
- A probabilidade condicional de X ser vermelho dado que é “parecido” =  $2/6 \cdot 3/20 = 1/20$
- Portanto, a classe predita de X seria vermelho, pois é a maior probabilidade

# Mais tecnicamente....

- Aprendizagem da classificação: qual é a probabilidade da classe dado um exemplo?
  - Evidência  $E = \text{exemplo (registro, com os valores dos atributos)}$
  - Hipótese  $H = \text{valor da classe para o exemplo}$

- Teorema de Bayes (1763):

$$P(H|E) = \frac{P(E|H).P(H)}{P(E)}$$

- Suposição do classificador bayesiano ingênuo: evidência pode ser separada em partes independentes (os atributos do exemplo)

$$P(E_1, E_2, \dots, E_n | H) = P(E_1 | H) \cdot P(E_2 | H) \dots \cdot P(E_n | H)$$



$$P(H|E) = \frac{P(E_1 | H) \cdot P(E_2 | H) \dots \cdot P(E_n | H) \cdot P(H)}{P(E_1) \cdot P(E_2) \dots \cdot P(E_n)}$$

# Exemplo: Naive Bayes

<b>Dia</b>	<b>Aspecto</b>	<b>Temperatura</b>	<b>Umidade</b>	<b>Vento</b>	<b>Decisão</b>
1	Sol	Quente	Alta	Fraco	N
2	Sol	Quente	Alta	Forte	N
3	Nublado	Quente	Alta	Fraco	S
4	Chuva	Agradável	Alta	Fraco	S
5	Chuva	Fria	Normal	Fraco	S
6	Chuva	Fria	Normal	Forte	N
7	Nublado	Fria	Normal	Forte	S
8	Sol	Agradável	Alta	Fraco	N
9	Sol	Fria	Normal	Fraco	S
10	Chuva	Agradável	Normal	Fraco	S
11	Sol	Agradável	Normal	Forte	S
12	Nublado	Agradável	Alta	Forte	S
13	Nublado	Quente	Normal	Fraco	S
14	Chuva	Agradável	Alta	Forte	N

# Exemplo: Naive Bayes

---

Qual será a *decisão* (valor da classe), se o dia estiver com sol, a temperatura fria, a umidade alta e o vento forte ?

$P(\text{Jogar} = \text{S} \mid \text{Aspecto} = \text{Sol}, \text{Temperatura} = \text{Fria}, \text{Umidade} = \text{Alta} \text{ e } \text{Vento} = \text{Forte}) = ?$

$P(\text{Jogar} = \text{N} \mid \text{Aspecto} = \text{Sol}, \text{Temperatura} = \text{Fria}, \text{Umidade} = \text{Alta} \text{ e } \text{Vento} = \text{Forte}) = ?$

# Exemplo: Naive Bayes

$$P(H|E) = \frac{P(E_1|H) \cdot P(E_2|H) \dots \cdot P(E_n|H) \cdot P(H)}{P(E_1) \cdot P(E_2) \dots \cdot P(E_n)}$$

**$P(\text{Jogar} = S \mid \text{Aspecto} = \text{Sol}, \text{Temperatura} = \text{Fria}, \text{Umidade} = \text{Alta e Vento} = \text{Forte}) =$**

$$= \frac{P(\text{Sol}|S) * P(\text{Fria}|S) * P(\text{Alta}|S) * P(\text{Forte}|S) * P(S)}{P(\text{Sol}) * P(\text{Fria}) * P(\text{Alta}) * P(\text{Forte})}$$

# Exemplo: Naive Bayes

---

$$P(\text{Jogar} = S) = 9/14; \quad P(\text{Jogar} = N) = 5/14;$$

$$P(\text{Aspecto} = \text{Sol} \mid \text{Jogar} = S) = 2/9;$$

$$P(\text{Aspecto} = \text{Sol} \mid \text{Jogar} = N) = 3/5;$$

$$P(\text{Temperatura} = \text{Fria} \mid \text{Jogar} = S) = 3/9;$$

$$P(\text{Temperatura} = \text{Fria} \mid \text{Jogar} = N) = 1/5;$$

$$P(\text{Umidade} = \text{Alta} \mid \text{Jogar} = S) = 3/9;$$

$$P(\text{Umidade} = \text{Alta} \mid \text{Jogar} = N) = 4/5;$$

$$P(\text{Vento} = \text{Forte} \mid \text{Jogar} = S) = 3/9;$$

$$P(\text{Vento} = \text{Forte} \mid \text{Jogar} = N) = 3/5;$$

# Exemplo: Naive Bayes

---

$$P(\text{Aspecto} = \text{Sol}) = 5/14$$

$$P(\text{Temperatura} = \text{Fria}) = 4/14$$

$$P(\text{Umidade} = \text{Alta}) = 7/14$$

$$P(\text{Vento} = \text{Forte}) = 6/14$$

# Exemplo: Naive Bayes

---

$P(\text{Jogar} = \text{S} \mid \text{Aspecto} = \text{Sol}, \text{Temperatura} = \text{Fria}, \text{Umidade} = \text{Alta e Vento} = \text{Forte}) =$

$$= \frac{P(\text{Sol}|\text{S}) * P(\text{Fria}|\text{S}) * P(\text{Alta}|\text{S}) * P(\text{Forte}|\text{S}) * P(\text{S})}{P(\text{Sol}) * P(\text{Fria}) * P(\text{Alta}) * P(\text{Forte})} =$$

$$= (2/9 * 3/9 * 3/9 * 3/9 * 9/14) / (5/14 * 4/14 * 7/14 * 6/14) =$$

$$= 0,0053 / 0,02186 = \mathbf{0,242}$$

# Exemplo: Naive Bayes

$P(\text{Jogar} = \text{N} \mid \text{Aspecto} = \text{Sol}, \text{Temperatura} = \text{Fria}, \text{Umidade} = \text{Alta e Vento} = \text{Forte}) =$

$$= \frac{P(\text{Sol}|\text{N}) * P(\text{Fria}|\text{N}) * P(\text{Alta}|\text{N}) * P(\text{Forte}|\text{N}) * P(\text{N})}{P(\text{Sol}) * P(\text{Fria}) * P(\text{Alta}) * P(\text{Forte})} =$$

$$= (3/5 * 1/5 * 4/5 * 3/5 * 5/14) / (5/14 * 4/14 * 7/14 * 6/14) =$$

$$= 0,0206 / 0,02186 = \mathbf{0,942}$$

**Como**  $(\text{J}=\text{N}) 0,942 > (\text{J}=\text{S}) 0,242$  **Então Jogar = Não**

# O problema da *frequência zero*

---

- Se um valor de atributo nunca ocorrer para uma classe (como por exemplo Aspecto=nublado para a classe N)
  - A probabilidade será zero!  $P(\text{nublado} \mid N) = 0$
  - A probabilidade a posteriori será zero, independentemente dos outros valores!  $P(N \mid E) = 0$
- Solução: *Estimador de Laplace*  $\Rightarrow$  somar 1 à contagem de todas as combinações de classe e valor de atributo.
- Resultado: as probabilidades nunca serão zero!

# Naive Bayes

---

- Vantagens:
  - Rápido
  - Bons resultados em dados reais
- Desvantagens:
  - Resultados não tão bons em problemas complexos
  
- Mozilla Thunderbird e Microsoft Outlook usam classificadores naive bayes para filtrar (marcar) emails que seriam spam

# Redes Bayesianas: Cálculo da Probabilidade Conjunta

- ◆ Redes Bayesianas levam em consideração a **Independência Condicional** entre **subconjuntos** de variáveis


$$P(y_1 \wedge \dots \wedge y_n) = P(y_n | y_1 \wedge \dots \wedge y_{n-1}) \dots P(y_2 | y_1) P(y_1)$$

↓

$$P(y_n | \text{Predecessores}(Y_n))$$


↘

$$P(y_2 | \text{Predecessores}(Y_2))$$



$$P(y_1, \dots, y_n) = \prod_{i=1}^n P(y_i | \text{Predecessores}(Y_i))$$

# Exemplo do **alarme** para experimentar rede Baysiana no software Hugin



## Questão 2 da P2 (25%)

- ◆ Instalar o software Hugin
  - <http://www.hugin.com/productservices/demo/hugin-lite>
  - (é preciso um pequeno registro; ao executar pela primeira vez, um código, recebido por e-mail, deve ser digitado)
- ◆ Testar uma rede pronta, alterando probabilidades para perceber a propagação. Há vários exemplos em:
  - <pasta de instalação>/Hugin Expert/Hugin Lite 8.1/Samples
- ◆ Criar uma rede qualquer, de preferência, sobre um assunto que tenha conhecimento ou interesse
- ◆ Entregar no Moodle o arquivo “.net” do Hugin e um arquivo PDF explicando a modelagem
  - Prazo: 19/11