

Tema 3

Modelos probabilísticos para linguagens regulares

Professora:
Ariane Machado Lima

Vídeo 1

Gramáticas estocásticas

Professora:

Ariane Machado Lima

Contextualização

- Na aula passada:
 - Hierarquia de Chomsky
 - Linguagens regulares
 - Gramáticas regulares
 - Autômatos finitos (determinísticos e não-determinísticos)
- Hoje:
 - Introdução às versões probabilísticas (gramáticas estocásticas e HMMs)
- Na próxima aula:
 - Treinamento/aprendizado (inferência gramatical)
 - Estimação de desempenho

Gramáticas Estocásticas

- Definição: uma gramática estocástica G é uma quintupla (V, Σ, S, P, ρ) , onde
 - V é o conjunto de símbolos não-terminais (variáveis)
 - Σ é o conjunto de símbolos terminais
 - S é o símbolo inicial
 - P é o conjunto de produções da forma
$$(\Sigma \cup V)^* V (\Sigma \cup V)^* \rightarrow (\Sigma \cup V)^*$$
 - ρ é o conjunto de distribuições de probabilidades sobre as produções de mesmo lado esquerdo

$$\sum_i \rho(\alpha \rightarrow \beta_i) = 1$$

Exemplo

atga
atgg
atta
aaga
cgag

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

$$P = \left\{ \begin{array}{l} S_1 \rightarrow aS_2 \quad | \quad cS_3 \\ S_2 \rightarrow tS_4 \quad | \quad aS_5 \\ S_4 \rightarrow gS_6 \quad | \quad tS_7 \\ S_6 \rightarrow a \quad | \quad g \\ S_7 \rightarrow a \\ S_5 \rightarrow gS_8 \\ S_8 \rightarrow a \\ S_3 \rightarrow gS_9 \\ S_9 \rightarrow aS_{10} \\ S_{10} \rightarrow g \end{array} \right\}$$

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

a t g a

a t g g

a t t a

a a g a

c g a g

$$P = \{ S_1 \rightarrow aS_2 \text{ [0.80]} \mid cS_3 \text{ [0.20]} \}$$

$$S_2 \rightarrow tS_4 \mid aS_5$$

$$S_4 \rightarrow gS_6 \mid tS_7$$

$$S_6 \rightarrow a \mid g$$

$$S_7 \rightarrow a$$

$$S_5 \rightarrow gS_8$$

$$S_8 \rightarrow a$$

$$S_3 \rightarrow gS_9$$

$$S_9 \rightarrow aS_{10}$$

$$S_{10} \rightarrow g$$

}

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga

atgg

atta

aaga

cgag

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 \mid tS_7$$

$$S_6 \rightarrow a \mid g$$

$$S_7 \rightarrow a$$

$$S_5 \rightarrow gS_8$$

$$S_8 \rightarrow a$$

$$S_3 \rightarrow gS_9$$

$$S_9 \rightarrow aS_{10}$$

$$S_{10} \rightarrow g$$

}

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga
atgg
atta
aaga
cgag

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a \mid g$$

$$S_7 \rightarrow a$$

$$S_5 \rightarrow gS_8$$

$$S_8 \rightarrow a$$

$$S_3 \rightarrow gS_9$$

$$S_9 \rightarrow aS_{10}$$

$$S_{10} \rightarrow g$$

}

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga

atgg

atta

aaga

cgag

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a$$

$$S_5 \rightarrow gS_8$$

$$S_8 \rightarrow a$$

$$S_3 \rightarrow gS_9$$

$$S_9 \rightarrow aS_{10}$$

$$S_{10} \rightarrow g$$

}

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

}

atga
atgg
atta
aaga
cgag

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga
atgg
atta
aaga
cgag

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

} **$P(x | G)$** = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga
atgg
atta
aaga
cgag

$$P = \{ S_1 \rightarrow aS_2 \ [0.80] \mid cS_3 \ [0.20]$$

$$S_2 \rightarrow tS_4 \ [0.75] \mid aS_5 \ [0.25]$$

$$S_4 \rightarrow gS_6 \ [0.66666] \mid tS_7 \ [0.33333]$$

$$S_6 \rightarrow a \ [0.50] \mid g \ [0.50]$$

$$S_7 \rightarrow a \ [1.00]$$

$$S_5 \rightarrow gS_8 \ [1.00]$$

$$S_8 \rightarrow a \ [1.00]$$

$$S_3 \rightarrow gS_9 \ [1.00]$$

$$S_9 \rightarrow aS_{10} \ [1.00]$$

$$S_{10} \rightarrow g \ [1.00]$$

$$P(\text{atga} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

atga
atgg
atta
aaga
cgag

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$$P(\text{atga} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atgg} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atta} \mid G) = 0.8 * 0.75 * 0.33333 * 1 = 0.2$$

$$P(\text{aaga} \mid G) = 0.8 * 0.25 * 1 * 1 = 0.2$$

$$P(\text{cgag} \mid G) = 0.2 * 1 * 1 * 1 = 0.2$$

$$P(\text{attg} \mid G) = 0$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

Estimação por Máxima Verossimilhança

$$S = S_1$$

$$P(\text{atga} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atgg} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atta} \mid G) = 0.8 * 0.75 * 0.33333 * 1 = 0.2$$

$$P(\text{aaga} \mid G) = 0.8 * 0.25 * 1 * 1 = 0.2$$

$$P(\text{cgag} \mid G) = 0.2 * 1 * 1 * 1 = 0.2$$

$$P(\text{attg} \mid G) = 0$$

$$= \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

atga
atgg
atta
aaga
cgag

E qual a vantagem???

$$\begin{aligned} P(\text{atga} \mid G) &= 0.8 * 0.75 * 0.66666 * 0.5 = 0.2 \\ P(\text{atgg} \mid G) &= 0.8 * 0.75 * 0.66666 * 0.5 = 0.2 \\ P(\text{atta} \mid G) &= 0.8 * 0.75 * 0.33333 * 1 = 0.2 \\ P(\text{aaga} \mid G) &= 0.8 * 0.25 * 1 * 1 = 0.2 \\ P(\text{cgag} \mid G) &= 0.2 * 1 * 1 * 1 = 0.2 \\ P(\text{attg} \mid G) &= 0 \end{aligned}$$

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

atga
atgg
atta
aaga
cgag

E qual a vantagem???

Conseguir atribuir uma probabilidade a cadeias que não pertencem ao treinamento (generalização)

$$P(\text{atga} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atgg} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atta} \mid G) = 0.8 * 0.75 * 0.33333 * 1 = 0.2$$

$$P(\text{aaga} \mid G) = 0.8 * 0.25 * 1 * 1 = 0.2$$

$$P(\text{cgag} \mid G) = 0.2 * 1 * 1 * 1 = 0.2$$

$$P(\text{attg} \mid G) = 0$$

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

atga
atgg
atta
aaga
cgag

E qual a vantagem???

Conseguir atribuir uma probabilidade a cadeias que não pertencem ao treinamento (generalização)

$$P(\text{atga} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atgg} \mid G) = 0.8 * 0.75 * 0.66666 * 0.5 = 0.2$$

$$P(\text{atta} \mid G) = 0.8 * 0.75 * 0.33333 * 1 = 0.2$$

$$P(\text{aaga} \mid G) = 0.8 * 0.25 * 1 * 1 = 0.2$$

$$P(\text{cgag} \mid G) = 0.2 * 1 * 1 * 1 = 0.2$$

$$P(\text{attg} \mid G) = 0$$

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [1.00]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$P(x \mid G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

Exemplo

atga
atgg
atta
aaga
cgag

E qual a vantagem???

Conseguir atribuir uma probabilidade a cadeias que não pertencem ao treinamento (generalização)

$$\begin{aligned} P(\text{atga} | G) &= 0.8 * 0.75 * 0.66666 * 0.5 = 0.2 \\ P(\text{atgg} | G) &= 0.8 * 0.75 * 0.66666 * 0.5 = 0.2 \\ P(\text{atta} | G) &= 0.8 * 0.75 * 0.33333 * 0.9 = 0.18 \\ P(\text{aaga} | G) &= 0.8 * 0.25 * 1 * 1 = 0.2 \\ P(\text{cgag} | G) &= 0.2 * 1 * 1 * 1 = 0.2 \\ P(\text{attg} | G) &= 0.8 * 0.75 * 0.33333 * 0.1 = 0.02 \end{aligned}$$

$$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$$

$$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$$

$$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$$

$$S_6 \rightarrow a [0.50] \mid g [0.50]$$

$$S_7 \rightarrow a [0.90] \mid g [0.10]$$

$$S_5 \rightarrow gS_8 [1.00]$$

$$S_8 \rightarrow a [1.00]$$

$$S_3 \rightarrow gS_9 [1.00]$$

$$S_9 \rightarrow aS_{10} [1.00]$$

$$S_{10} \rightarrow g [1.00]$$

$P(x | G)$ = produto das probabilidades das produções usadas na derivação de x (dadas pela gramática G)

E os autômatos?

- Podem ser
 - Determinísticos estocásticos
 - Não-determinísticos estocásticos
- Para cada estado, há uma distribuição de probabilidades sobre as transições que dele partem

Exemplo

gramática regular (linear à direita)

atga
atgg
atta
aaga
cgag

$$G = \{V, \Sigma, S, P\}$$

$$V = \{S_1, S_2, S_3, S_4, S_5, S_6, S_7, S_8, S_9, S_{10}\}$$

$$\Sigma = \{a, c, g, t\}$$

$$S = S_1$$

$$P = \{ S_1 \rightarrow aS_2 \mid cS_3$$

$$S_2 \rightarrow tS_4 \mid aS_5$$

$$S_4 \rightarrow gS_6 \mid tS_7$$

$$S_6 \rightarrow a \mid g$$

$$S_7 \rightarrow a$$

$$S_5 \rightarrow gS_8$$


$$S_8 \rightarrow a$$

$$S_3 \rightarrow gS_9$$

$$S_9 \rightarrow aS_{10}$$

$$S_{10} \rightarrow g$$

}



AFN

atga
atgg
atta
aaga
cgag

Exemplo

$G = \{V, \Sigma, S, P\}$

$V = \{S_1, S_2, S_3, S_4, S_5,$
 $S_6, S_7, S_8, S_9, S_{10}\}$

$\Sigma = \{a, c, g, t\}$

$S = S_1$

$P = \{ S_1 \rightarrow aS_2 [0.80] \mid cS_3 [0.20]$

$S_2 \rightarrow tS_4 [0.75] \mid aS_5 [0.25]$

$S_4 \rightarrow gS_6 [0.66666] \mid tS_7 [0.33333]$

$S_6 \rightarrow a [0.50] \mid g [0.50]$

$S_7 \rightarrow a [1.00]$

$S_5 \rightarrow gS_8 [1.00]$


$S_8 \rightarrow a [1.00]$

$S_3 \rightarrow gS_9 [1.00]$

$S_9 \rightarrow aS_{10} [1.00]$

$S_{10} \rightarrow g [1.00]$


}



AFN


Autômatos probabilísticos (ou estocásticos)

- À sua definição (AFD ou AFD) acrescenta:
 - $p: Q \times \Sigma \times Q \rightarrow [0, 1]$, de tal forma que
 - para todo $q_{\text{atual}} \in Q$, $\sum_{a \in \Sigma, q_{\text{prox}} \in Q} p(q_{\text{atual}}, a, q_{\text{prox}}) = 1$



Autômatos probabilísticos (ou estocásticos)

- À sua definição (AFD ou AFN) acrescenta-se:
 - $p: Q \times \Sigma \times Q \rightarrow [0,1]$, de tal forma que
 - para todo $q_{\text{atual}} \in Q$, $\sum_{a \in \Sigma, q_{\text{prox}} \in Q} p(q_{\text{atual}}, a, q_{\text{prox}}) = 1$
 - Em algumas formulações tenho ainda uma distribuição inicial π sobre os estados
 $\sum_i \pi(q_i) = 1$



Fim do vídeo 1

Gramáticas estocásticas

Professora:

Ariane Machado Lima

Vídeo 2

HMMs (parte 1)

Professora:
Ariane Machado Lima

AFN Probabilístico e HMM

- AFNs probabilísticos são equivalentes a HMMs

Modelo Oculto de Markov

Hidden Markov Model (HMM)

- Primeiro um caso mais simples: imagine que eu tenho uma urna de bolas coloridas (ou seja, a urna tem uma distribuição de probabilidades sobre essas cores)



- Alguém tem que adivinhar qual a próxima cor. Como isso poderia ser feito?

Modelo Oculto de Markov

Hidden Markov Model (HMM)

- Primeiro um caso mais simples: imagine que eu tenho uma urna de bolas coloridas (ou seja, a urna tem uma distribuição de probabilidades sobre essas cores)



- Alguém tem que adivinhar qual a próxima cor. Como isso poderia ser feito?
Chutando a cor de maior probabilidade

Modelo Oculto de Markov

Hidden Markov Model (HMM)

- AGORA imagine que eu tenho **várias** urnas de bolas coloridas (ou seja, cada urna tem uma **distribuição de probabilidades** sobre essas cores, **potencialmente diferente**).

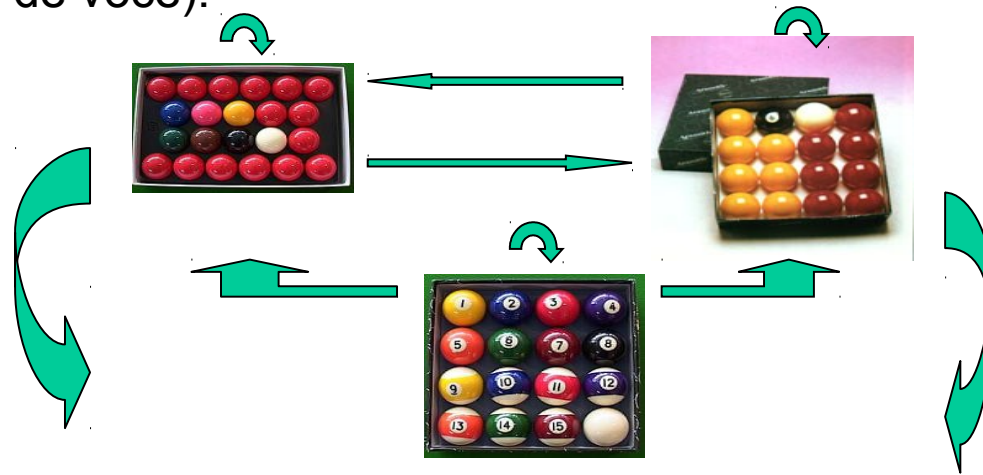


•

Modelo Oculto de Markov

Hidden Markov Model (HMM)

- AGORA imagine que eu tenho **várias** urnas de bolas coloridas (ou seja, cada urna tem uma **distribuição de probabilidades** sobre essas cores, **potencialmente diferente**). A cada sorteio de bola eu posso trocar de urna (**troca** de urnas é um processo que eu faço **escondido** de você).



- Alguém tem que adivinhar qual a próxima cor. Como isso poderia ser feito?

Modelo Oculto de Markov

Hidden Markov Model (HMM)

- Símbolos de emissão (cores de bola)
- Estados ocultos (urnas)
- Uma distribuição de probabilidades de emissão de símbolos associada a cada estado
- Probabilidade de transição entre estados
- Distribuição de probabilidades do estado inicial

Modelo Oculto de Markov Hidden Markov Model (HMM)

Q : conjunto de estados ocultos
 Σ : conjunto de símbolos de emissão

Probabilidades **iniciais** π : $Q \rightarrow [0,1]$
 $\sum_i \pi(q_i) = 1$

Probabilidades
de **transições**


$$t_{ij} = P(q_j | q_i)$$

$$\sum_j t_{ij} = 1$$

Probabilidades
de **emissões**

$$e_i(a) = P(a | q_i)$$

$$\sum_{a \in \Sigma} e_i(a) = 1$$



Modelo Oculto de Markov Hidden Markov Model (HMM)

Q: conjunto de estados ocultos

Σ : conjunto de símbolos de emissão

Probabilidades **iniciais** π : $Q \rightarrow [0,1]$

$$\sum_i \pi(q_i) = 1$$

Probabilidades
de **transições**


$$t_{ij} = P(q_j | q_i)$$

$$\sum_j t_{ij} = 1$$

Probabilidades
de **emissões**

$$e_i(a) = P(a | q_i)$$

$$\sum_{a \in \Sigma} e_i(a) = 1$$



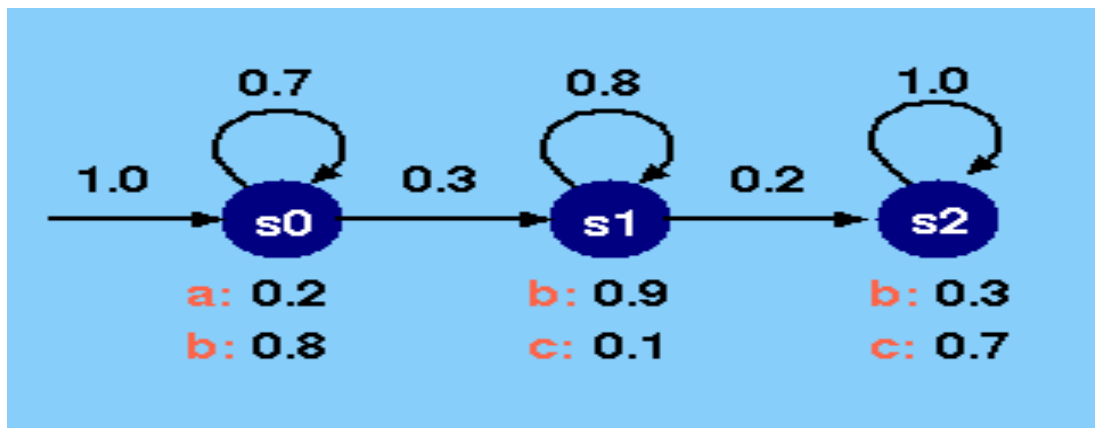
Semelhança com algo?

Modelo Oculto de Markov

Hidden Markov Model (HMM)


- Autômatos finitos (não determinísticos) probabilísticos são equivalentes a modelos ocultos de Markov

Modelo Oculto de Markov Hidden Markov Model (HMM)



- Como transformo essa HMM em um AFN probabilístico?

Modelo Oculto de Markov Hidden Markov Model (HMM)



- Como transformo essa HMM em um AFN probabilístico?

$P_{AFN}(\text{transição do estado } q_i \text{ para o estado } q_j \text{ lendo o símbolo } k) =$

$$P_{AFN}(q_i, q_j, k) = t_{ij} * e_i(k)$$

Máquinas de estados

- Máquinas de Mealy: aceitam símbolos na transição (autômatos tradicionais)
- Máquinas de Moore: aceitam símbolos nos estados (HMM – modelo oculto de Markóv)

Problemas relacionados a HMM

- 1) Dados um HMM e uma cadeia, calcular a probabilidade dessa cadeia
 - Soma das probabilidades de cada caminho
 - Probabilidade de cada caminho: produto das probabilidades do caminho (transição e emissão)
 - Algoritmo forward ou backward

Problemas relacionados a HMM

- 2) Dados um HMM e uma cadeia, calcular o caminho mais provável dessa cadeia
 - Algoritmo viterbi
- 3) Dados um HMM e conjunto de cadeias (treinamento), estimar os parâmetros (probabilidades de emissão e transição)
 - Algoritmo Baum-Welch

Problemas relacionados a HMM

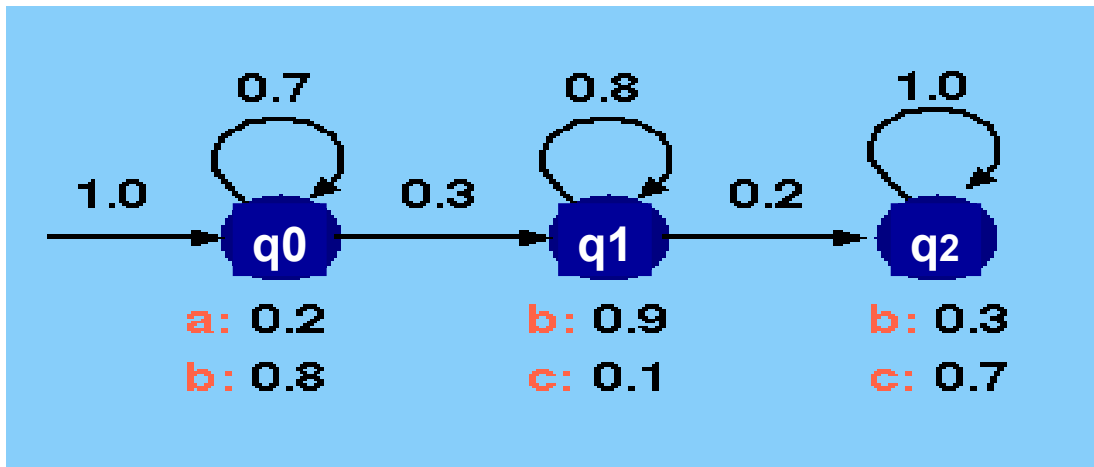
4) Projetar a topologia de uma HMM

Problemas relacionados a HMM (hoje)

- 1) Dados um HMM e uma cadeia, calcular a probabilidade dessa cadeia**
- 2) Dados um HMM e uma cadeia, calcular o caminho mais provável dessa cadeia**

Como calcular $P(x \mid \text{HMM})$

- Uma cadeia x pode percorrer diversos caminhos por um HMM



Ex: **aabbb**

Caminhos possíveis (c):

$c_1 = q_0, q_0, q_0, q_0, q_0$

$c_2 = q_0, q_0, q_0, q_0, q_1$

$c_3 = q_0, q_0, q_0, q_1, q_1$

$c_4 = q_0, q_0, q_1, q_1, q_1$

$c_5 = q_0, q_0, q_1, q_1, q_2$

$c_6 = q_0, q_0, q_1, q_2, q_2$


- Probabilidade conjunta de x e um caminho específico c :

$$P(x,c|\text{HMM}) = P(x=x_1x_2\dots x_n, c=r_1r_2\dots r_n | \text{HMM}) = \pi(r_1) * e_{r_1}(x_1) * \prod_{i=2..n} t_{(r_{i-1})r_i} * e_{r_i}(x_i)$$

$$\begin{aligned} \text{Ex: } P(x=\text{aabbb}, c_6=q_0q_0q_1q_2q_2) &= \pi(q_0) * e_{q_0}(a) * t_{q_0q_0} * e_{q_0}(a) * t_{q_0q_1} * e_{q_1}(b) * t_{q_1q_2} * e_{q_2}(b) * t_{q_2q_2} * e_{q_2}(b) \\ &= 1 * 0.2 * 0.7 * 0.2 * 0.3 * 0.9 * 0.2 * 0.3 * 1 * 0.3 = \mathbf{0,0001} \end{aligned}$$

Como calcular $P(x | \text{HMM})$

- Uma cadeia x pode percorrer diversos caminhos por um HMM



Ex: **aabbb**

Caminhos possíveis (c):

$c_1 = q_0, q_0, q_0, q_0, q_0$

$c_2 = q_0, q_0, q_0, q_0, q_1$

$c_3 = q_0, q_0, q_0, q_1, q_1$

$c_4 = q_0, q_0, q_1, q_1, q_1$

$c_5 = q_0, q_0, q_1, q_1, q_2$

$c_6 = q_0, q_0, q_1, q_2, q_2$

- Probabilidade conjunta de x e um caminho específico c :


$$P(x,c|\text{HMM}) = P(x=x_1x_2\dots x_n, c=r_1r_2\dots r_n | \text{HMM}) = \pi(r_1) * e_{r_1}(x_1) * \prod_{i=2..n} t_{(r_{i-1})r_i} * e_{r_i}(x_i)$$

- Probabilidade de x :

$$P(x | \text{HMM}) = \sum_c P(x,c | \text{HMM})$$

Como calcular $P(x | \text{HMM})$

- Uma cadeia x pode percorrer diversos caminhos por um HMM



Ex: **aabbb**

Caminhos possíveis (c):

$c_1 = q_0, q_0, q_0, q_0, q_0$

$c_2 = q_0, q_0, q_0, q_0, q_1$

$c_3 = q_0, q_0, q_0, q_1, q_1$

$c_4 = q_0, q_0, q_1, q_1, q_1$

$c_5 = q_0, q_0, q_1, q_1, q_2$

$c_6 = q_0, q_0, q_1, q_2, q_2$

- Probabilidade conjunta de x e um caminho específico c :

$$P(x,c|\text{HMM}) = P(x=x_1x_2\dots x_n, c=r_1r_2\dots r_n | \text{HMM}) = \pi(r_1) * e_{r_1}(x_1) * \prod_{i=2..n} t_{(r_{i-1})r_i} * e_{r_i}(x_i)$$

- Probabilidade de x :

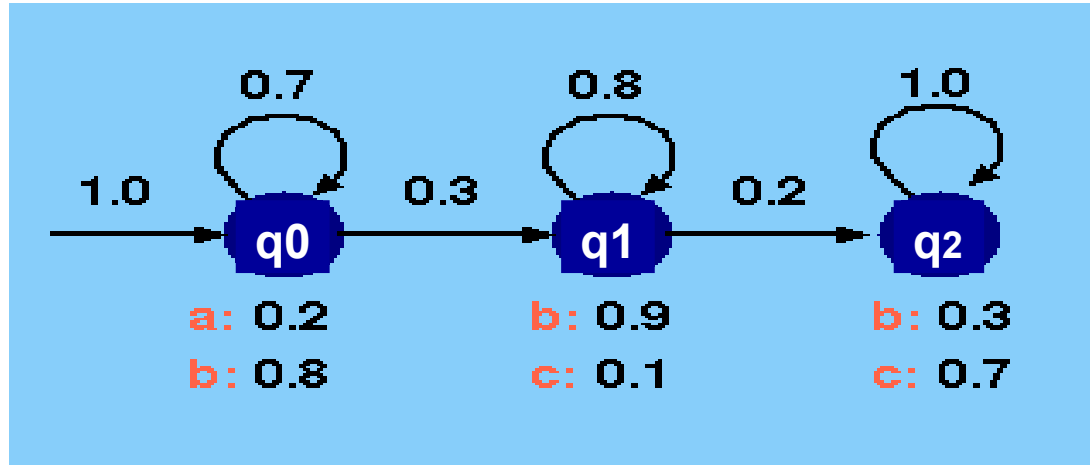
$$P(x | \text{HMM}) = \sum_c P(x,c | \text{HMM})$$

OPPS! O número de caminhos cresce exponencialmente com o tamanho da cadeia...



Como calcular $P(x | \text{HMM})$

- Uma cadeia x pode percorrer diversos caminhos por um HMM



Ex: **aabbb**

Caminhos possíveis (c):

$c_1 = q_0, q_0, q_0, q_0, q_0$

$c_2 = q_0, q_0, q_0, q_0, q_1$

$c_3 = q_0, q_0, q_0, q_1, q_1$

$c_4 = q_0, q_0, q_1, q_1, q_1$

$c_5 = q_0, q_0, q_1, q_1, q_2$

$c_6 = q_0, q_0, q_1, q_2, q_2$

- Probabilidade conjunta de x e um caminho específico c :

$$P(x,c|\text{HMM}) = P(x=x_1x_2\dots x_n, c=r_1r_2\dots r_n | \text{HMM}) = \pi(r_1) * e_{r_1}(x_1) * \prod_{i=2..n} t_{(r_{i-1})r_i} * e_{r_i}(x_i)$$

- Probabilidade de x :

$$P(x | \text{HMM}) = \sum_c P(x,c | \text{HMM})$$

OPS! O número de caminhos cresce exponencialmente com o tamanho da cadeia...

Solução: Programação Dinâmica!!!



Algoritmo forward - $P(x | \text{HMM } \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $f_k(i) = P(x_1 x_2 \dots x_i, q_k | \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido)
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $f_l(i+1) = e_{q_l}(x_{i+1}) * \sum_k f_k(i) * t_{q_k q_l}$
- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $f[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $f_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $f[l][i+1] = e_{q_l}(x_{i+1}) * \sum_k f[k][i] * t_{q_k q_l}$ // $f_l(i+1)$

//Finalização:

$P(x | \theta) = \sum_{k \in Q} f[k][n]$



Algoritmo backward - $P(x | \text{HMM } \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $b_k(i) = P(x_{i+1} x_{i+2} \dots x_n | r_i = q_k, \theta)$: probabilidade da subcadeia $x_{i+1} \dots x_n$ e estar no estado q_k no “tempo” i (a próxima transição irá para um estado no qual será emitido o símbolo x_{i+1})

- Calculando indo para trás na cadeia (estando no estado q_i):

$$- \mathbf{b}_l(i) = \sum_k t_{q_l q_k} * e_{q_k}(x_{i+1}) * b_k(i+1)$$

- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (já li toda a cadeia – inicialização “matemática”)

para $k = 1$ até $|Q|$ $b[k][n] = 1$ // $b_k(n)$

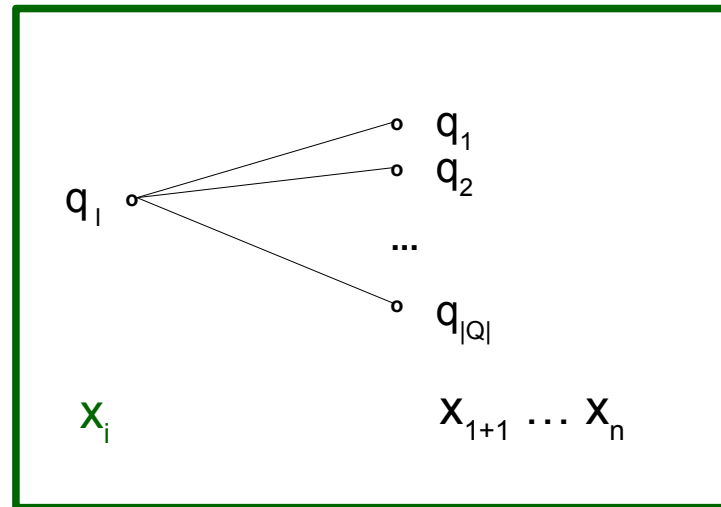
// Indução:

para $i = n-1$ até 1

 para $l = 1$ até $|Q|$ $b[l][i] = \sum_k t_{q_l q_k} * e_{q_k}(x_{i+1}) * b[k][i+1]$ // $b_l(i)$

//Finalização:

$$P(x | \theta) = \sum_{k \in Q} \pi(q_k) * e_{q_k}(x_1) * b[k][1]$$



Problemas relacionados a HMM

- 2) Dados um HMM e uma cadeia, calcular o caminho mais provável dessa cadeia
 - Algoritmo viterbi
- 3) Dados um HMM e conjunto de cadeias (treinamento), estimar os parâmetros (probabilidades de emissão e transição)
 - Algoritmo Baum-Welch

Algoritmo forward - $P(x | \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $f_k(i) = P(x_1 x_2 \dots x_i, q_k | \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido)
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $f_l(i+1) = e_{q_l}(x_{i+1}) * \sum_k f_k(i) * t_{q_k q_l}$
- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $f[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $f_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $f[l][i+1] = e_{q_l}(x_{i+1}) * \sum_k f[k][i] * t_{q_k q_l}$ // $f_l(i+1)$

//Finalização:

$P(x | \theta) = \sum_{k \in Q} f[k][n]$



Algoritmo Viterbi: $c = \operatorname{argmax}_c P(x, c \mid \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $f_k(i) = P(x_1 x_2 \dots x_i, q_k \mid \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido)
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $f_l(i+1) = e_{q_l}(x_{i+1}) * \sum_k f_k(i) * t_{q_k q_l}$
- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $f[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $f_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $f[l][i+1] = e_{q_l}(x_{i+1}) * \sum_k f[k][i] * t_{q_k q_l}$ // $f_l(i+1)$

//Finalização:

$P(x \mid \theta) = \sum_{k \in Q} f[k][n]$



Algoritmo Viterbi: $c = \operatorname{argmax}_c P(x, c \mid \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $v_k(i) = P(x_1 x_2 \dots x_i, q_k, C_{\max} \mid \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido) **no caminho mais provável**
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $f_l(i+1) = e_{q_l}(x_{i+1}) * \sum_k f_k(i) * t_{q_k q_l}$
- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $f[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $f_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $f[l][i+1] = e_{q_l}(x_{i+1}) * \sum_k f[k][i] * t_{q_k q_l}$ // $f_l(i+1)$

//Finalização:

$P(x \mid \theta) = \sum_{k \in Q} f[k][n]$



Algoritmo Viterbi: $c = \operatorname{argmax}_c P(x, c \mid \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $v_k(i) = P(x_1 x_2 \dots x_i, q_k, c_{\max} \mid \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido) **no caminho mais provável**
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $v_l(i+1) = e_{q_l}(x_{i+1}) * \max_k v_k(i) * t_{q_k q_l}$

- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $v[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $b_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $v[l][i+1] = e_{q_l}(x_{i+1}) * \max_k v[k][i] * t_{q_k q_l}$ // $v_l(i+1)$

//Finalização:

$P(x, c_{\max} \mid \theta) = \max_{k \in Q} v[k][n]$



Algoritmo Viterbi: $c = \operatorname{argmax}_c P(x, c \mid \theta)$

- Cadeia a ser analisada: $x_1 \dots x_n$
- Variável $v_k(i) = P(x_1 x_2 \dots x_i, q_k, c_{\max} \mid \theta)$: probabilidade da subcadeia $x_1 \dots x_i$ e estar no estado q_k no “tempo” i (quando x_i é emitido) **no caminho mais provável**
- Lendo mais um símbolo (x_{i+1}) e estar no estado q_l :
 - $v_l(i+1) = e_{q_l}(x_{i+1}) * \max_k v_k(i) * t_{q_k q_l}$

- **Algoritmo:** preenchimento de uma matriz f de dimensões $|Q| \times n$

// Inicialização (emissão do primeiro símbolo no “primeiro” estado)

para $k = 1$ até $|Q|$ $v[k][1] = \pi(q_k) * e_{q_k}(x_1)$ // $b_k(1)$


// Indução:

para $i = 1$ até $n-1$

 para $l = 1$ até $|Q|$ $v[l][i+1] = e_{q_l}(x_{i+1}) * \max_k v[k][i] * t_{q_k q_l}$ // $v_l(i+1)$

// Finalização:

$P(x, c_{\max} \mid \theta) = \max_{k \in Q} v[k][n]$



Para eu conhecer c_{\max} , basta sempre armazenar o argmax_k

Próxima aula (tema 4)

3) Dados um HMM e conjunto de cadeias (treinamento), estimar os parâmetros (probabilidades de emissão e transição)

- Algoritmo Baum-Welch

4) Topologia

Fim do vídeo 2

HMMs (parte 1)

Professora:

Ariane Machado Lima

Vídeo 3

Score log-odd e posteriori

Professora:
Ariane Machado Lima

Questões que agora aparecem

- 1) Quando uma probabilidade $P(x|\theta)$ (θ sendo de uma gramática G ou de uma HMM) é suficiente para eu dizer que x deveria ser classificada como sendo da classe representada por θ ? (limiar de classificação)
- 2) Como eu avalio θ e esse limiar de classificação?

Questões que agora aparecem

1) Quando uma probabilidade $P(x|\theta)$ (θ sendo de uma gramática G ou de uma HMM) é suficiente para eu dizer que x deveria ser classificada como sendo da classe representada por θ ? (limiar de classificação)

2) Como eu avalio θ e esse limiar de classificação?

Vou chamar esse θ de G no restante dessa aula...

Quando uma probabilidade $P(x | G)$ é suficiente?

- Algumas alternativas:
 - Testar vários limiares (avaliar **medidas de desempenho** para cada um e escolher o mais adequado) – que precisa da resposta da questão nr 2!
 - Razão log-odd

Razão log-odd

- Em um contexto de classificação binária (duas classes → duas gramáticas G_1 e G_2) :
- Classifico como sendo da classe 1 se:

$$P(x|G_1) > P(x|G_2)$$

$$\Rightarrow P(x|G_1) / P(x|G_2) > 1 \quad (\text{Razão de verossimilhança})$$

$$\Rightarrow \log P(x|G_1) - \log P(x|G_2) > 0 \quad (\text{log-odd})$$

Razão log-odd (com modelo nulo)

- Comparação de G com um modelo N bem mais simples, geral, aleatório (nulo)
- $P(x|G) > P(x|N)$ se x realmente é “da classe de G”
- $\Rightarrow P(x|G) / P(x|N) > 1$
- **Score log-odd $S^G(x) = \log P(x|G) - \log P(x|N) > 0$**

Limiar de classificação baseado no log-odd score



Razão log-odd (com modelo nulo)

- Comparação de G com um modelo N bem mais simples, geral, aleatório (nulo)
- $P(x|G) > P(x|N)$ se x realmente é “da classe de G”
- $\Rightarrow P(x|G) / P(x|N) > 1$
- **Score log-odd $S^G(x) = \log P(x|G) - \log P(x|N) > 0$**

Limiar de classificação baseado no log-odd score
Quanto maior o limiar, mais CONSERVADORA é a classificação

Modelo nulo

- Geralmente posição independente
- Exemplos:
 - Distribuição uniforme sobre os símbolos
 - Ex: $P(a) = P(c) = P(g) = P(t) = 0.25$
$$P(x|N) = 0.25^{|x|}$$
 - Distribuição de background
 - Ex: frequência de cada nucleotídeo no genoma sendo analisado
 - Ex: frequência de pixels 0, 1, no banco de imagens PB sendo analisado

(MACHADO-LIMA, 2010) para mais exemplos e análises

Classificação Bayesiana

- Em um contexto de classificação binária (duas classes → duas gramáticas G_1 e G_2) :
- Classifico como sendo da classe 1 se:

$$P(G_1 | x) > P(G_2 | x) \quad \text{POSTERIORI}$$

$$\Rightarrow P(x|G_1) P(G_1) > P(x|G_2) P(G_2)$$

Classificação Bayesiana

- Em um contexto de classificação binária (duas classes → duas gramáticas G_1 e G_2) :

- Classifico como sendo da classe 1 se:

$$P(G_1 | x) > P(G_2 | x) \quad \text{POSTERIORI}$$

$$\Rightarrow P(x|G_1) P(G_1) > P(x|G_2) P(G_2)$$

- **Assistam os vídeos sobre classificação Bayesiana:**
 - Vídeo 1: revisão de probabilidade
 - Vídeo 2: O que isso tem a ver com classificação
 - Vídeo 3: Generalizando (Teoria da Decisão)

Fim do vídeo 3

Score log-odd e posteriori

Professora:

Ariane Machado Lima

Referências

- DURBIN, R.; EDDY, S. R.; KROGH, A. **Biological Sequence Analysis: Probabilistic Models of Proteins and Nucleic Acids**. Cambridge University Press, 2002. Cap 3 a 6
- MACHADO-LIMA, A.; KASHIWABARA, A. Y.; DURHAM, A. M. Decreasing the number of false positives in sequence classification. **BMC Genomics** 11 (Suppl 5):S10, 2010.
- RABINER, L. R. A tutorial on hidden Markov models and selected applications in speech recognition. **Proceedings of the IEEE**, v. 77, n. 2, p. 257-286 1989