




Modelos de Markov Ocultos no Reconhecimento da Língua LIBRAS


Prof. Dr. Hemerson Pistori

GPEC - Grupo de Pesquisa em Engenharia e Computação
UCDB - Universidade Católica Dom Bosco



Sumário

- Conceitos Fundamentais de Probabilidade e Estatística
- Redes Bayesianas
- Processos Estocásticos e Modelos de Markov
- Reconhecimento de Língua de Sinais
- Modelos de Markov Ocultos
- Principais Algoritmos
- Conclusão




Conceitos Fundamentais

- Variáveis Aleatórias Discretas
- Funções de Distribuição de Probabilidade
- Probabilidade Condicional
- Independência
- Distribuição Conjunta

Variáveis Aleatórias Discretas

Função de Distribuição de Probabilidade de x



Variável Aleatória Discreta

Exemplo: x – ocorrência de uma determinada letra do alfabeto em um texto escrito em português.

Probabilidade Condicional e Independência

\mathbf{x}_k – ocorrência de uma letra na posição k

\mathbf{x}_{k-1} – ocorrência de uma letra na posição $k-1$

$$p(\mathbf{x}_k = 'a') > p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 's') \quad ?$$

$$p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 's') > p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 'a') \quad ?$$


$$p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 'z') > p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 'z', \mathbf{x}_{k-2} = 'z', \mathbf{x}_{k-3} = 'i', \mathbf{x}_{k-4} = 'p')?$$

$$p(\mathbf{x}_k = 'a') > p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-2000} = 's') \quad ?$$

Probabilidade Condicional e Independência

\mathbf{x}_s – sexo ('f' – feminino, 'm' – masculino')

\mathbf{x}_c – curso ('c' – computação, 'd' – direito, 'l' - letras)




Situação 1

$$p(\mathbf{x}_s = 'f') = 1/2$$

$$p(\mathbf{x}_c = 'c') = 1/3$$

$$p(\mathbf{x}_s = 'f' | \mathbf{x}_c = 'c') = 1/4$$




Situação 2

$$p(\mathbf{x}_s = 'f') = 1/2$$

$$p(\mathbf{x}_c = 'c') = 1/3$$


$$p(\mathbf{x}_s = 'f' | \mathbf{x}_c = 'c') = 1/2$$

Probabilidade Condicional e Independência



Situação 1

$$p(\mathbf{x}_s = 'f' | \mathbf{x}_c = 'c') = 1/4 = (1/12) / (4/12) = p(\mathbf{x}_s = 'f', \mathbf{x}_c = 'c') / p(\mathbf{x}_c = 'c')$$



Situação 2


$$p(\mathbf{x}_s = 'f' | \mathbf{x}_c = 'c') = 1/2 = p(\mathbf{x}_s = 'f')$$

Caso geral.....: $p(x|y) = p(x,y) / p(y)$

Independência.: $p(x|y) = p(x)$

Outro exemplo: $p(x|y_1,y_2,y_3,y_4,y_5) = p(x|y_1,y_2)$

Distribuição Conjunta



$$p(\mathbf{x}_s = 'f', \mathbf{x}_c = 'l')$$

	Masc.	Femin.	
Comput.	0,25	0,08	0,33
Direito	0,25	0,25	0,5
Letra	0	0,17	0,17
	0,5	0,5	

$$p(\mathbf{x}_s = 'm') = p(\mathbf{x}_s = 'm', \mathbf{x}_c = 'c') + p(\mathbf{x}_s = 'm', \mathbf{x}_c = 'd') + p(\mathbf{x}_s = 'm', \mathbf{x}_c = 'l')$$

Distribuição Conjunta

$$p(\mathbf{x}_k = 'a' | \mathbf{x}_{k-1} = 'z', \mathbf{x}_{k-2} = 'z', \mathbf{x}_{k-3} = 'i', \mathbf{x}_{k-4} = 'p')$$


Caso as variáveis não sejam independentes teremos que manter os valores da distribuição conjunta de 5 variáveis.

Considerando 23 diferentes letras:

Precisaremos de um matriz com **23⁵** células:
~ 6 Mega - 24 Mb (4 bytes por célula)

Redes Bayesianas

Utiliza informações sobre independência para diminuir custo em espaço para armazenar distribuição conjunta



$$p(x_1, x_2, x_3, x_4, x_5, x_6) = p(x_1) \cdot p(x_2 | x_1) \cdot p(x_3 | x_2) \cdot p(x_4 | x_2) \cdot p(x_5 | x_2) \cdot p(x_6 | x_3, x_4, x_5)$$

$$10^6 \longrightarrow 10 + 10^2 + 10^2 + 10^2 + 10^2 + 10^4$$

~4 Mb

~40 Kb

- 4 bytes por célula
- 10 valores por variável

Teorema de Bayes

$$p(x | y) = p(x,y) / p(y)$$

$$p(y | x) = p(y,x) / p(x)$$

$p(x,y) = p(y,x)$ Conjunção é comutativa.

$$\mathbf{p(x | y) = (p(y | x) * p(x)) / p(y)}$$


$p(d = \text{'meningite'} | s = \text{'dor na nuca'}) = ?$

$p(d = \text{'torcicolo'} | s = \text{'dor na nuca'}) = ?$

meningite ou torcicolo ?

$$p(n|m)*p(m) > p(n|t)*p(t)$$

Modelos de Markov de ordem n




$$p(x_k | x_{k-1}, x_{k-2}, \dots, x_1) = p(x_k | x_{k-1}, x_{k-2})$$



$$p(x_k | x_{k-1}, x_{k-2}, \dots, x_1) = p(x_k | x_{k-1})$$

Um tipo de modelo utilizado para representar
Processos Estocásticos.



Modelos de Markov de Ordem n

x_k – ocorrência de uma letra na posição k

Qual a ordem do modelo de Markov que melhor representaria o problema de “adivinhar a próxima letra”


Compromisso:

Complexidade no Espaço X Margem de Erro

Outras Limitações

x_k – ocorrência de uma letra na posição i

O estado pode não ser diretamente observável



Atributos: Tot. Extremidades, Comprim. do Contorno, Cruzamentos.

[4 9 1]' , [1 2 0]' , [2 5 0]' , [3 7 1]' , [1 6 0]' , [0 3 0]' , [1 2 0]'

P I S T O R I

Reconhecimento de Língua de Sinais



FRUTAS EM LIBRAS

Reconhecimento de Língua de Sinais



Exemplos de Atributos

- (1) Total pixels de pele visível,
- (2) Total pixels mão direita
- (3) Total pixels mão esquerda,
- (4) Pontas de dedos visíveis,
- (5) Distância entre centros de massa das mãos
- (6) Distância entre centro de massa da mão esquerda e face


Observações (Seqüências de Vetores de Atributos):

[200 50 0 5 20 2]' , [200 70 0 5 20 4]' , [200 60 0 2 20 3]' , ...

Estados (exemplos)

- 1 - Mão direita na configuração “C”, próxima ao queixo, e mão direita fora da área de interesse.
- 2 - Duas mãos na configuração “V”, na altura do peito, com mão direita ao lado direito do tronco e mão esquerda...


Modelos de Markov Ocultos



$p(s_k | s_{k-1}) =$ Probabilidade de termos duas mãos na configuração “V”, na altura do peito, com mão direita ao lado direito do tronco e mão esquerda do lado esquerdo do tronco, **no quadro k**, sabendo que tínhamos a mão direita na configuração “C”, próxima ao queixo, e mão direita fora da área de interesse, **no quadro k-1**.

$p(o_k | s_k) =$ Probabilidade de observarmos um vetor de atributos [200 50 0 5 20 2]' sabendo que a mão direita está na configuração “C”, próxima ao queixo, e a mão direita está fora da área de interesse.

Modelos de Markov Ocultos



$$O_1 = [200 \ 50 \ 0 \ 5 \ 20 \ 2]', \quad O_2 = [200 \ 70 \ 0 \ 5 \ 20 \ 4]', \quad O_3 = [200 \ 60 \ 0 \ 2 \ 20 \ 3]', \quad \dots$$


$$p(\lambda | o_1, o_2, \dots, o_T) = \frac{p(o_1, o_2, \dots, o_T | \lambda) * p(\lambda)}{p(o_1, o_2, \dots, o_T)}$$

Fácil de Estimar

Pode ser Ignorado

$p(o_1, o_2, \dots, o_T | \lambda)$ – Parte Interessante

Modelos de Markov Ocultos




$$p(o_1, o_2, \dots, o_T | \lambda) = \sum_{\forall s_1, \dots, s_n} p(o_1, \dots, o_T, s_1, \dots, s_T)$$

$$p(o_1, \dots, o_T, s_1, \dots, s_T) = p(s_1) \cdot p(o_1 | s_1) \cdot p(o_2 | s_2) \dots p(o_T | s_T) \cdot p(s_2 | s_1) \cdot p(s_3 | s_2) \dots p(s_T | s_{T-1})$$

$$p(o_1, \dots, o_T, s_1, \dots, s_T) = p(s_1) \cdot \prod_{k=1}^T p(o_k | s_k) \cdot p(s_{k+1} | s_k)$$

Modelos de Markov Ocultos




$$p(o_1, o_2, \dots, o_T | \lambda) = \sum_{V S_1, \dots, S_T} p(s_1) \cdot \prod_{k=1}^T p(o_k | s_k) \cdot p(s_{k+1} | s_k)$$

Homogeneidade no "Tempo" – Mesmas distribuições

$$S = \{1, \dots, N\} \quad O = \{1, \dots, M\}$$

$$p(o_1=2 | s_1=3) = p(o_3=2 | s_3=3) \quad p(s_2=1 | s_1=2) = p(s_5=1 | s_4=2)$$

Modelos de Markov Ocultos




Notação Usual:

$$\pi_i = p(s_1 = i)$$

$$a_{ij} = p(s_{k+1} = j | s_k = i)$$

$$b_{ij} = p(o_k = j | s_k = i)$$

Modelos de Markov Ocultos




$$\pi = \begin{bmatrix} 0.4 \\ 0.2 \\ 0.4 \end{bmatrix} \quad A = \begin{bmatrix} 0.7 & 0.2 & 0.1 \\ 0.8 & 0 & 0.2 \\ 0 & 0.4 & 0.6 \end{bmatrix} \quad B = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0 & 0.7 & 0.3 \\ 0.1 & 0.3 & 0.6 \end{bmatrix}$$

Modelos de Markov Ocultos


$$\pi = \begin{bmatrix} 0.4 \\ 0.2 \\ 0.4 \end{bmatrix} \quad A = \begin{bmatrix} 0.7 & 0.2 & 0.1 \\ 0.8 & 0 & 0.2 \\ 0 & 0.4 & 0.6 \end{bmatrix}^k \quad B = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0 & 0.7 & 0.3 \\ 0.1 & 0.3 & 0.6 \end{bmatrix}^s$$

$$p(\lambda | o_1=1, o_2=1, o_3=2, o_4=3, o_5=2) ?$$



Treliça

Modelos de Markov Ocultos




$$p(o_1, o_2, \dots, o_T | \lambda) = \sum_{V} p(s_1) \cdot \prod_{k=1}^T p(o_k | s_k) \cdot p(s_{k+1} | s_k)$$

Problema: Somar o custo (multiplicação dos pesos de vértices e arestas) de cada caminho ligando um vértice de V_I a um de V_F

Algoritmo Forward/Backward

- Reduz complexidade de $O(TN^T)$ para $O(T^2N)$
- Baseado em Programação Dinâmica (Tópico de Otimização e Pesquisa Operacional)




$$1*2*3*4*5*6*9 + 1*2*3*4*5*7*10 + 1*2*3*4*5*8*11$$

a_{ij} = Acumulador tempo i estado j

$$1*2*3*4*5*(6*9 + 7*10 + 8*11)$$

Algoritmo Viterbi

- Encontra seqüência mais provável de estados
- Modificação simples do Forward/Backward
- Armazenar caminhos de maior valor enquanto calcula valores a_{ij}



Algoritmo Baum-Welch

- Calcula os valores das matrizes p , A e B .
- Aprendizagem Supervisionada (amostras pré-classificadas)
- Amostras com informações “incompletas” (diferente do caso dos cursos e sexo).
- Algoritmo EM (expectation-maximization) aplicado aos modelos de Markov ocultos.




Observações (Seqüências de Vetores de Atributos):

[200 50 0 5 20 2]', [200 70 0 5 20 4]', [200 60 0 2 20 3]', ...

Estados (manualmente identificados)

1 1 1 1 2 2 3 3 4 4



Considerações Finais

- Áreas envolvidas: probabilidade, estatística, processos estocásticos, teoria dos grafos, programação dinâmica, otimização combinatória, pesquisa operacional, complexidade de algoritmos, aprendizagem de máquina, redes bayesianas, inteligência artificial.
- Conceito análogo – Filtros de Kalman (distribuições contínuas)
- Conceitos relacionados – Modelos de Markov de Tempo Contínuo. Campos Aleatórios de Markov. Modelos Gráficos.