

INF623

2024/1



Inteligência Artificial

A16: Raciocínio Probabilístico III

Plano de aula

- ▶ Processos (ou cadeias) de Markov
- ▶ Modelo de transição
- ▶ Inferência
- ▶ Amostragem
- ▶ Distribuição estacionária

Exemplo 1: previsão do tempo

Considere o problema de previsão do tempo (ensolarado, chuvoso) do dia seguinte dado o panorama dos $k = 4$ dias passados:



$t - 3$



$t - 2$



$t - 1$



t

?


$t + 1$

Inferência probabilística no tempo

Em Inteligência Artificial, frequentemente precisamos fazer inferência no tempo (ou espaço):

- ▶ Reconhecimento de voz
 - ▶ Localização de robôs
 - ▶ Atenção do usuário
 - ▶ Monitoramento médico
- ▶ Para isso, é necessário introduzir tempo (ou espaço) nos modelos probabilísticos.

Reconhecimento de voz



$P(\text{"A palavra rubrica tem **acento**?"}) = 0.23$

$P(\text{"A palavra rubrica tem **assento**?"}) = 0.1$

Inferência probabilística no tempo

Até agora, vimos como fazer inferência $P(Q | E)$ dado variáveis Q e E de consulta e evidência, respectivamente.

$$P(Q | E) = \alpha \sum_h P(Q, h, e)$$


- ▶ Essa formalização não representa a relação temporal entre as variáveis.
- ▶ **Processos de Markov nos permitem estabelecer essas relações!**

Processos (ou cadeias) de Markov


Um **processo de Markov** é uma sequência de variáveis aleatórias onde a distribuição de cada variável depende apenas de um número fixo k de variáveis anteriores $X_{t-1}, X_{t-2}, \dots, X_{t-k}$:

Suposição de Markov

Para $k = 1$, dizemos que o modelo é de primeira ordem:



Para $k = 2$, dizemos que o modelo é de segunda ordem:



e assim por diante para $k = 3, 4, \dots$


Modelo de Transição

Um processo de Markov é definido por uma distribuição inicial $P(X_1)$ e um **modelo de transição** $P(X_t | X_{t-1})$ que especifique a distribuição de probabilidade do próximo evento com base nos valores possíveis do evento atual.

Modelo de Transição [para previsão do tempo]


X_{t-1}	X_t	$P(X_t X_{t-1})$
		0,9
		0,1
		0,3
		0,7

(a) Tabela



(b) Grafo

Distribuição conjunta de processos de Markov



- ▶ Pela regra da cadeia:

$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2 | X_1)P(X_3 | X_1, X_2)P(X_4 | X_1, X_2, X_3)$$

- ▶ Pela suposição de Markov para $k = 1$:

$$P(X_1, X_2, X_3, X_4) = P(X_1)P(X_2 | X_1)P(X_3 | X_2)P(X_4 | X_3)$$

- ▶ De uma maneira geral, para T estados:

$$\begin{aligned} P(X_1, X_2, \dots, X_T) &= P(X_1)P(X_2 | X_1) \dots P(X_T | X_{T-1}) \\ &= P(X_1) \prod_{t=2}^T P(X_t | X_{t-1}) \end{aligned}$$

Inferência

[Lembrete]

$$P(X = x) = \sum_y P(X = x, Y = y)$$
$$P(A, B) = P(A | B)P(B)$$

Qual a distribuição de probabilidades $P(X_t)$ no tempo t ?

Simulação para frente:

Samemos $P(X_1, X_2, \dots, X_T) = P(X_1) \prod_{t=2}^T P(X_t | X_{t-1})$

$$P(X_t) = \sum_{x_{t-1}} P(X_t, x_{t-1})$$

-----> **Marginalização**

$$= \sum_{x_{t-1}} P(X_t | x_{t-1})P(x_{t-1})$$

-----> **Regra do produto**

Como $P(X_1)$ é dado, podemos calcular $P(X_t)$ iterativamente, começando por $P(X_2)$ a partir de $P(X_1)$, depois $P(X_3)$ a partir de $P(X_2)$ e assim sucessivamente até $P(X_t)$ a partir de $P(X_{t-1})$

Exemplo

[Lembrete]

$$P(X_t) = \sum_{x_{t-1}} P(X_t | x_{t-1})P(x_{t-1})$$

Qual a probabilidade de fazer sol no segundo dia $P(X_2 = sol)$?

Assuma que $P(X_1 = sol) = 1.0$

$$P(X_t = x_t) = \sum_{x_{t-1}} P(x_t | x_{t-1})P(x_{t-1})$$

$$P(X_2 = sol) = P(X_2 = sol | X_1 = sol)P(X_1 = sol) + \\ P(X_2 = sol | X_1 = chuva)P(X_1 = chuva)$$

$$P(X_2 = sol) = 0,9 \times 1,0 + 0,3 \times 0,0 = 0,9$$

X_{t-1}	X_t	$P(X_t X_{t-1})$
		0,9
		0,1
		0,3
		0,7

Exemplo

[Lembrete]

$$P(x_t) = \sum_{x_{t-1}} P(x_t | x_{t-1})P(x_{t-1})$$

Qual a distribuição de probabilidade $P(X_4)$ no quarto dia?

Assuma que $P(X_1) = \begin{bmatrix} 1.0 \\ 0.0 \end{bmatrix}$

$$P(X_2 = sol) = P(X_2 = sol | X_1 = sol)P(X_1 = sol) + P(X_2 = sol | X_1 = chuva)P(X_1 = chuva)$$

$$P(X_2 = chuva) = P(X_2 = chuva | X_1 = sol)P(X_1 = sol) + P(X_2 = chuva | X_1 = chuva)P(X_1 = chuva)$$

$$P(X_2) = \begin{bmatrix} 0.9 \\ 0.1 \end{bmatrix} \longrightarrow P(X_3) = \begin{bmatrix} 0.84 \\ 0.16 \end{bmatrix} \longrightarrow P(X_4) = \begin{bmatrix} 0.804 \\ 0.196 \end{bmatrix}$$

X_{t-1}	X_t	$P(X_t X_{t-1})$
		0,9
		0,1
		0,3
		0,7

Amostragem

Podemos gerar sequências com processos de Markov, começando com um estado inicial e amostrando novos estados de acordo com o modelo de transição



$t = 0$




$t = 1$



$t = 2$

...

Modelo de Transição



Distribuição estacionária

Qual a distribuição de probabilidade $P(X_\infty)$ no tempo $t = \infty$?

- ▶ Considerando estado inicial igual a sol

$$\begin{array}{ccccccc} \begin{bmatrix} 1.0 \\ 0.0 \end{bmatrix} & \begin{bmatrix} 0.9 \\ 0.1 \end{bmatrix} & \begin{bmatrix} 0.84 \\ 0.16 \end{bmatrix} & \begin{bmatrix} 0.804 \\ 0.196 \end{bmatrix} & \dashrightarrow & \begin{bmatrix} 0.75 \\ 0.25 \end{bmatrix} \\ P(X_1) & P(X_2) & P(X_3) & P(X_4) & & P(X_\infty) \end{array}$$

- ▶ Considerando estado inicial igual a chuva

$$\begin{array}{ccccccc} \begin{bmatrix} 0.0 \\ 1.0 \end{bmatrix} & \begin{bmatrix} 0.3 \\ 0.7 \end{bmatrix} & \begin{bmatrix} 0.48 \\ 0.52 \end{bmatrix} & \begin{bmatrix} 0.588 \\ 0.412 \end{bmatrix} & \dashrightarrow & \begin{bmatrix} 0.75 \\ 0.25 \end{bmatrix} \\ P(X_1) & P(X_2) & P(X_3) & P(X_4) & & P(X_\infty) \end{array}$$

- ▶ Considerando qualquer distribuição inicial $P(X_1)$

$$\begin{array}{ccc} \begin{bmatrix} p \\ 1-p \end{bmatrix} & \dashrightarrow & \begin{bmatrix} 0.75 \\ 0.25 \end{bmatrix} \\ P(X_1) & & P(X_\infty) \end{array}$$

X_{t-1}	X_t	$P(X_t X_{t-1})$
		0,9
		0,1
		0,3
		0,7

Distribuição estacionária

Qual a distribuição de probabilidade $P(X_\infty)$ no tempo $t = \infty$?

$$P_\infty(\text{sun}) = P(\text{sun} | \text{sun})P_\infty(\text{sun}) + P(\text{sun} | \text{rain})P_\infty(\text{rain})$$

$$P_\infty(\text{rain}) = P(\text{rain} | \text{sun})P_\infty(\text{sun}) + P(\text{rain} | \text{rain})P_\infty(\text{rain})$$

$$P_\infty(\text{sun}) = 0,9P_\infty(\text{sun}) + 0,3P_\infty(\text{rain})$$

$$P_\infty(\text{rain}) = 0,1P_\infty(\text{sun}) + 0,7P_\infty(\text{rain})$$

$$P_\infty(\text{sun}) = 3P_\infty(\text{rain})$$

$$P_\infty(\text{rain}) = 1/3P_\infty(\text{rain})$$

Além disso:

$$P_\infty(\text{sun}) + P_\infty(\text{rain}) = 1$$

$$P_\infty(\text{sun}) = \frac{3}{4}$$

$$P_\infty(\text{rain}) = \frac{1}{4}$$

X_{t-1}	X_t	$P(X_t X_{t-1})$
		0,9
		0,1
		0,3
		0,7

Distribuição estacionária

A distribuição de probabilidade $P(X_\infty)$ no tempo $t = \infty$ é chamada de **distribuição estacionária** e possui a seguinte propriedade:

$$P_\infty(X) = P_{\infty+1}(X) = \sum_x P(X|x)P_\infty(x)$$

▶ **Para a maioria dos processos de Markov:**

- ▶ A influência da distribuição inicial diminui mais e mais ao longo tempo
- ▶ A distribuição obtida ao final é independente da distribuição inicial



Aplicação de distribuições estacionárias



▶ Algoritmo PageRank para ranquear páginas web

Modela um usuário navegando na internet, seguindo links aleatoriamente

- ▶ Cada página web é um estado
- ▶ Distribuição inicial: uniforme
- ▶ Transições:
 - ▶ Com probabilidade p , escolha uma página web aleatoriamente (linhas tracejadas, nem todas estão mostradas)
 - ▶ Com probabilidade $1 - p$, siga um link de saída aleatório (linhas sólidas)

▶ Distribuição estacionária

- ▶ Terá a probabilidade do usuário terminar a navegação em cada página web
 - ▶ E.g. probabilidade de terminar na página da Wikipedia
- ▶ Abordagem consideravelmente robusta a link spams



Próxima aula

A17: Raciocínio Probabilístico IV

Estados ocultos, modelos ocultos de Markov