

CONHECIMENTO PROBABILÍSTICO: REPRESENTAÇÕES MODELOS DE DEPENDÊNCIA

CT215

1

Sumário

- ◇ Inadequação de Representações Numéricas
- ◇ Representação de Dependências
- ◇ Base Axiomática
- ◇ Dependências e Grafos Não-Direcionados
- ◇ Redes de Markov
- ◇ Redes Bayesianas
- ◇ Expressividade de Redes Bayesianas

CT215

2

Inadequação de Representações Numéricas

Distr. conjunta $P(X_1, \dots, X_n)$: entidade básica em probabilidade.

Computacionalmente inadequado:

- 2^n endereços de memória para armazenamento (X_i booleanos).
- Cálculo de probabilidades marginais é tarefa muito árdua:

$$P(X_i = x) = \sum_{j \neq i} P(X_1, \dots, X_i = x, \dots, X_n)$$

- Cálculo de probabilidades condicionais é tarefa muito árdua:

$$P(X_i | X_j = x_j) = \alpha P(X_i, X_j = x_j) = \alpha \sum_y P(X_i, X_j = x_j, y)$$

Além disso, valores exatos de probabilidade não tem grande significado. Precisamos representar probabilidades (como medida de incerteza) de uma maneira mais eficiente e significativa.

CT215

3

Noção Qualitativa de Independência

O que nos interessa é a noção qualitativa de independência: raciocínio humano não mede independência via $P(x,y)=P(x)P(y)$.

Por outro lado, avaliamos facilmente a relação básica de independência condicional: Dado Z , Y é influenciado por X ?

Exemplo:

X = horário em que o último ônibus deixou o ponto.

Y = tempo estimado para passar o próximo ônibus.

Z = local em que o próximo ônibus está agora.

$$P(Y|X,Z) = P(Y|Z)$$

Queremos definir uma representação que permita rapidamente visualizar e avaliar este tipo de independência.

CT215

4

Relação entre Dependência e Inferência

Seja K o conhecimento numa BC. Quero avaliar a certeza a respeito de A .
Convém consultar uma nova proposição B não armazenada na BC?

Em outras palavras: antes de examinar B , quero saber se existe algo não codificado na BC que pode gerar conhecimento relevante a respeito de A .

Relevância da informação: permite separar o que interessa do que não interessa para fins de inferência e geração de novo conhecimento.

Relevância em Teoria da Probabilidade é formalizada pelo conceito de independência condicional:

A é independente de B dado K se $P(A|B,K) = P(A|K)$ ou
 B é irrelevante para inferir A dado K se $P(A|B,K) = P(A|K)$

É este tipo de relação que devemos representar de forma eficiente!

CT215

5

Dependências: Base Axiomática

Def. Seja $U = \{ \alpha, \beta, \dots \}$ um conjunto de variáveis discretas, e seja P uma função de probabilidade conjunta sobre as variáveis em U .
Sejam X, Y e Z três subconjuntos de U . Diz-se que X e Y são condicionalmente independentes dado Z se

$$P(X = x / Y = y, Z = z) = P(X = x / Z = z)$$

Notação: $I(X,Z,Y) \Leftrightarrow P(X=x / Y=y, Z=z) = P(X=x / Z=z)$.

Algumas propriedades:

$$\begin{aligned} I(X,Z,Y) &\Leftrightarrow P(x,y/z) = P(x/z)P(y/z) \\ I(X,Z,Y) &\Leftrightarrow \exists f, g: P(x,y,z) = f(x,z)g(y,z) \\ I(X,Z,Y) &\Leftrightarrow P(x,y,z) = P(x/z)P(y,z) \end{aligned}$$

CT215

6

Teoremas

- **Simetria:** $I(X,Z,Y) \Leftrightarrow I(Y,Z,X)$. Dado Z , se Y é irrelevante para X então X é irrelevante para Y .
- **Decomposição:** $I(X,Z,Y \cup W) \Rightarrow I(X,Z,Y) \wedge I(X,Z,W)$. Se dois itens de informação são irrelevantes para X , então cada um isoladamente é irrelevante para X .
- **União Fraca:** $I(X,Z,Y \cup W) \Rightarrow I(X,Z \cup W,Y)$. Aprender a irrelevância de uma informação W não torna outras informações relevantes.
- **Contração:** $I(X,Z,Y) \wedge I(X,Z \cup Y,W) \Rightarrow I(X,Z,Y \cup W)$. Se descobrimos que W é irrelevante para X após aprendermos que Y é irrelevante para X , então W já era irrelevante antes..
- **Intersecção:** $I(X,Z \cup W,Y) \wedge I(X,Z \cup Y,W) \Rightarrow I(X,Z,Y \cup W)$.. Se Y não afeta X quando W não muda e W não afeta X quando Y não muda, então W e Y nunca afetam X

(Pearl: fig. 3.1, pág. 86)

CT215

7

Representação Gráfica de Dependências

Estrutura escolhida: grafos de dependência (nós e ligações).

- ◇ Grafos têm representação pictórica: metáfora conveniente para dependências conceituais (nós- conceitos, ligações - dependências).
- ◇ Grafos permitem operações de visualização imediata (estabelecimento de dependências via análise de caminhos, etc.)
- ◇ Parecem ter correspondência com raciocínio humano (e.g., figuras de linguagem, redes semânticas).

Esquemas gráficos mais úteis: Redes de Markov e Redes Bayesianas.

Seja portanto um grafo G representando interação entre elementos.

Idealmente:

- Independência = falta de conexão entre nós correspondentes.
- Dependência = existência de conexão entre elementos correspondentes.

CT215

8

Dependências e Grafos Não-Direcionados

Problema: topologia baseada apenas em nós, ligações e conexões é pouco expressiva. Preciso considerar ligações indiretas como um meio para representar interação condicional.

Exemplo: Dois machos $\{M_1, M_2\}$ e duas fêmeas $\{F_1, F_2\}$ em uma sociedade heterossexual. Estrutura em diamante indica:

- Falta de contato direto entre dois machos ou duas fêmeas
- Dependência condicional. *Exemplo.*

Observe que:

- Falta de direcionalidade indica origem indiferente de doença.
- Assimetria pode ser codificada (via pesos).
- Semântica da topologia é definida pelas ligações ausentes.c

CT215

9

Modelos de Dependência

Def. Seja $U = \{\alpha, \beta\}$ um conjunto de variáveis discretas, e sejam X, Y e Z três subconjuntos de U . Seja M um modelo de dependência, que atribui V ou F para o predicado $I(X, Z, Y)_M$.

O modelo M basicamente determina o subconjunto I de triplas para as quais a afirmação “ X é independente de Y dado Z ” é verdadeira.

Observe que qualquer distribuição de probabilidade P é um modelo de dependência (Posso verificar sempre se $P(x/y, z) = P(x/z)$).

Uma representação gráfica de dependência deveria estabelecer uma correspondência direta entre os elementos U de M e o conjunto de nós desta representação:

$$\langle X/Z/Y \rangle_G \Rightarrow I(X, Z, Y)_M$$

$$e \quad I(X, Z, Y)_M \Rightarrow \langle X | Z | Y \rangle_G$$

CT215

10

Modelos de Dependências

Def. Um grafo não direcionado G é um mapa de dependência (D-mapa) de M se existir uma correspondência unívoca entre elementos de U e nós de G , de modo que

$$I(X, Z, Y)_M \Rightarrow \langle X | Z | Y \rangle_G$$

No grafo: Se Z não corta X, Y então x e Y são dependentes. Caso contrário, não posso dizer nada.

Similarmente, G é uma mapa de independência (I-mapa) se:

$$I(X, Z, Y)_M \Leftarrow \langle X | Z | Y \rangle_G$$

No grafo: Se Z corta X, Y então X e Y são independentes. Caso contrário, não posso dizer nada.

G é um mapa perfeito de M se for simultaneamente um I-mapa e D-mapa de M .

CT215

11

Insuficiência de Grafos Não-Direcionados

Vários modelos de dependência não correspondem a mapas perfeitos.

Exemplo: Dependência Induzida - proposições não-relacionadas tornam-se relevantes entre si quando novos fatos são apreendidos:

$$I(X, Z_1, Y)_M \wedge \neg I(X, Z_1 \cup Z_2, Y)_M$$

Mas separações em grafos sempre satisfazem

$$\langle X | Z_1 | Y \rangle_G \Rightarrow \langle X, Z_1 \cup Z_2, Y \rangle_M$$

Exemplo: moedas e sino.

Grafos não-direcionados são portanto representacionalmente pobres. Vamos nos conformar com grafos não-direcionados que exibem apenas as dependências (I-mapas).

CT215

12

Redes de Markov

Perguntas:

1. Dada uma distribuição P , é possível construir um I-mapa G de P com número mínimo de vértices? SIM! (redes de Markov)
2. Dado um par (P, G) , é possível testar se G é um I-mapa de P ? SIM!
3. Dado um grafo G , é possível construir uma distribuição P tal que G é mapa perfeito de P ? SIM!

Número mínimo de vértices garante que pelo menos minimizaremos o número de independências não-representáveis, mas redes de Markov:

- Não podem representar dependências induzidas ou não-transitivas.
- Relacionam variáveis independentes caso estas influenciem uma terceira.

Muitas independências relevantes deixam portanto de ser representadas em redes de Markov, apesar dos nossos esforços em definí-las como I-mapas mínimos.

Precisamos enriquecer a semântica de grafos adicionando o conceito de direção à relações. Setas permitem discriminar entre dependências reais e dependências induzidas por hipóteses.

CT215

Exemplo: moedas e sino. 13

Redes Bayesianas

Perguntas:

1. Dada uma distribuição P , é possível se construir um **Grafo Acíclico Direcionado** (GAD) D que é um I-mapa mínimo de P ? SIM!
2. Dado um par (P, D) , é possível testar se D é um I-mapa de P ? SIM!
3. Dado um GAD D , é possível se construir uma distribuição P tal que D é um mapa perfeito de P ? SIM!

◇ Nós = variáveis

◇ Arcos = influência direta entre variáveis

Em redes de Markov, tínhamos: $\langle X/Z/Y \rangle_G \Rightarrow I(X, Z, Y)$

EM REDES BAYESIANAS, O CRITÉRIO DE DEPENDÊNCIA É BASEADO EM SEPARAÇÃO-d.

CT215

14

Semântica de Redes Bayesianas

Def. Sejam X , Y e Z subconjuntos disjuntos de um GAD D . Diz-se que Z d-separa X de Y ($\langle X|Z|Y \rangle_D$) se, para qualquer caminho entre X e Y , existir um nó w satisfazendo uma das seguintes condições:

- w tem apenas setas convergentes e nem w nem nenhum de seus descendentes está em Z ;
- w não tem apenas setas convergentes e está em Z .

Um caminho que satisfaz uma destas condições é dito bloqueado.

Um caminho que não satisfaz nenhuma destas condições é dito ativado (por Z).



semantica redes
bayesianas. pdf

CT215

15

Redes Bayesianas como I-Mapas

Um GAD é um I-mapa de um modelo de dependência M se

$$\langle X|Z|Y \rangle_D \Rightarrow I(X,Z,Y)_M$$

para quaisquer subconjuntos disjuntos X , Y e Z .

Um GAD é um I-mapa mínimo de M se nenhuma de suas setas puder ser removida sem destruir a condição de I-mapa..

Def. Dada uma distribuição P e um conjunto de variáveis U , um GAD D é dita uma Rede Bayesiana de P se D é um I-mapa mínimo de P .

CT215

16

Construindo Redes Bayesianas

Dada uma distribuição P e um dado ordenamento de variáveis de U , existe um procedimento recursivo simples para construir uma rede Bayesiana. E dada uma rede Bayesiana, existe um procedimento simples para reconstruir $P(X_1, X_2, \dots, X_n)$

Na prática, o problema é definir as variáveis e suas interdependências (quase nunca disponho de P). Entretanto, só preciso de relações diretas. A própria rede deve definir as influências indiretas.

EM REDES BAYESIANAS, JULGAMENTO LOCAL
MANTÉM CONSISTÊNCIA GLOBAL.



construção redes
bayesianas. pdf

CT215

17

Expressividade de Redes Bayesianas

- ◇ Redes Bayesianas são mais expressivas: indução e dependências não-transitivas.
- ◇ Redes Bayesianas capturam um conjunto maior de independências probabilísticas do que redes de Markov (especialmente aquelas que parecem ser mais úteis em problemas reais).

Entretanto:

- ◇ Redes Bayesianas não representam tudo que redes de Markov representam. Exemplo: estrutura em diamante.
- ◇ Nenhuma representação gráfica consegue distinguir **conectividade entre conjuntos** de **conectividade entre elementos**. Em probabilidade, independência entre elementos não implica independência entre conjuntos.

CT215

18