

# Modelos probabilísticos relacionais e de primeira ordem

Paulo Santos

FEI - São Paulo

August 31, 2016

# Introdução

- lógica de primeira ordem está relacionada à existência de objetos e relações entre eles
- pode expressar fatos sobre alguns ou todos os objetos do domínio
- redes Bayesianas são intrinsecamente proposicionais: o conjunto de variáveis aleatórias é fixo e finito, e cada um possui um domínio fixo de valores possíveis
- idéia: combinar teoria de probabilidade com o poder de expressividade da lógica de 1a ordem para abordar novos (e mais abrangentes) problemas

# Introdução

- lógica de primeira ordem está relacionada à existência de objetos e relações entre eles
- pode expressar fatos sobre alguns ou todos os objetos do domínio
- redes Bayesianas são intrinsecamente proposicionais: o conjunto de variáveis aleatórias é fixo e finito, e cada um possui um domínio fixo de valores possíveis
- idéia: combinar teoria de probabilidade com o poder de expressividade da lógica de 1ª ordem para abordar novos (e mais abrangentes) problemas

# Exemplo

- suponha que a Amazon quer fazer um sistema de recomendação de seus livros a partir da opinião dos consumidores. Como fazer isso?
- caso mais simples: basear a avaliação na média das recomendações
- isso falha por não levar em consideração o fato de alguns consumidores serem mais “bonzinhos” que outros, ou alguns serem desonestos (e.g. trabalham para uma determinada editora)
- essas **dependências causais** podem ser representadas por uma rede Bayesiana

# Exemplo

- suponha que a Amazon quer fazer um sistema de recomendação de seus livros a partir da opinião dos consumidores. Como fazer isso?
- caso mais simples: basear a avaliação na média das recomendações
- isso falha por não levar em consideração o fato de alguns consumidores serem mais “bonzinhos” que outros, ou alguns serem desonestos (e.g. trabalham para uma determinada editora)
- essas **dependências causais** podem ser representadas por uma rede Bayesiana

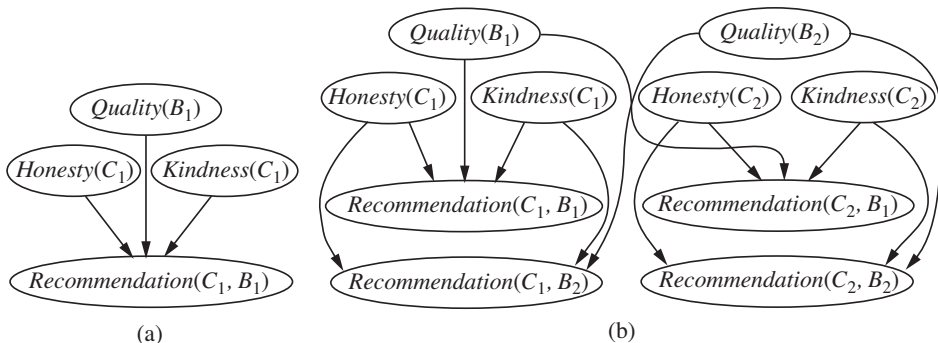
# Exemplo

- suponha que a Amazon quer fazer um sistema de recomendação de seus livros a partir da opinião dos consumidores. Como fazer isso?
- caso mais simples: basear a avaliação na média das recomendações
- isso falha por não levar em consideração o fato de alguns consumidores serem mais “bonzinhos” que outros, ou alguns serem desonestos (e.g. trabalham para uma determinada editora)
- essas **dependências causais** podem ser representadas por uma rede Bayesiana

# Exemplo

- suponha que a Amazon quer fazer um sistema de recomendação de seus livros a partir da opinião dos consumidores. Como fazer isso?
- caso mais simples: basear a avaliação na média das recomendações
- isso falha por não levar em consideração o fato de alguns consumidores serem mais “bonzinhos” que outros, ou alguns serem desonestos (e.g. trabalham para uma determinada editora)
- essas **dependências causais** podem ser representadas por uma rede Bayesiana

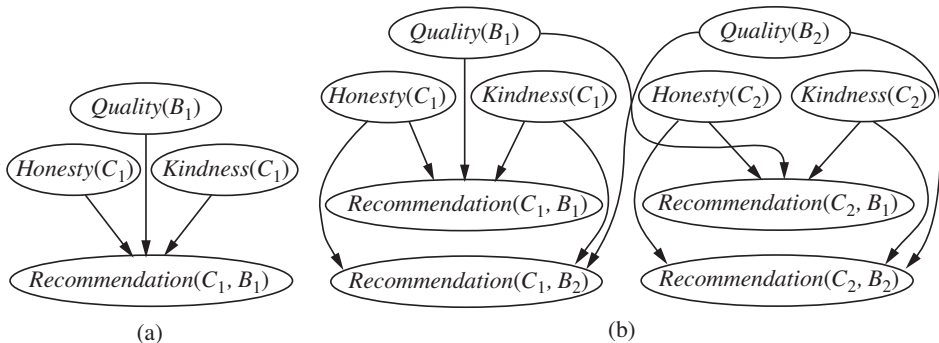
# Exemplo



- a) rede para um único consumidor  $C_1$  e um único livro  $B_1$ ;
- b) rede para dois consumidores  $C_1$  e  $C_2$  e dois livros  $B_1$  e  $B_2$
- para muitos livros e clientes, montar a rede pode ficar impraticável




# Exemplo




- a) rede para um único consumidor  $C_1$  e um único livro  $B_1$ ;
- b) rede para dois consumidores  $C_1$  e  $C_2$  e dois livros  $B_1$  e  $B_2$
- para muitos livros e clientes, montar a rede pode ficar impraticável

# Exemplo



- a) rede para um único consumidor  $C_1$  e um único livro  $B_1$ ;
- b) rede para dois consumidores  $C_1$  e  $C_2$  e dois livros  $B_1$  e  $B_2$
- para muitos livros e clientes, montar a rede pode ficar impraticável


# Exemplo



Felizmente podemos utilizar a estrutura da rede:

- cada  $Recommendation(c, b)$  possui os mesmos pais:  $Honest(c)$ ,  $Kindness(c)$  and  $Quality(b)$ ;
- as TPC de  $Recommendation(c, b)$  são idênticas, bem como as tabelas para as variáveis  $Honest(c)$ , etc.
- queremos então escrever algo como:  
 $Recommendation(c, b) \sim RecCPT(Honest(c), Kindness(c), Quality(b))$

# Exemplo



Felizmente podemos utilizar a estrutura da rede:

- cada  $Recommendation(c, b)$  possui os mesmos pais:  $Honest(c)$ ,  $Kindness(c)$  and  $Quality(b)$ ;
- as TPC de  $Recommendation(c, b)$  são idênticas, bem como as tabelas para as variáveis  $Honest(c)$ , etc.
- queremos então escrever algo como:  
 $Recommendation(c, b) \sim RecCPT(Honest(c), Kindness(c), Quality(b))$

# Desenvolvendo a linguagem

- um modelo probabilístico define um conjunto  $\Omega$  de mundos possíveis com probabilidade  $P(w)$  para cada mundo  $w$ ;
- para redes Bayesianas os mundos possíveis são associações de valores a variáveis
- no caso Booleano, os mundos possíveis são idênticos aos da lógica proposicional
- para um modelo probabilístico de 1a ordem, os mundos possíveis devem ser aqueles da lógica de 1a ordem:
  - ▶ um conjunto de objetos com relações entre eles e uma interpretação que associa símbolos de constantes a objetos, símbolos de predicados a relações e símbolos de funções à funções sobre os objetos
  - ▶ o modelo probabilístico também precisa definir uma probabilidade para cada mapeamento desses

# Desenvolvendo a linguagem

- um modelo probabilístico define um conjunto  $\Omega$  de mundos possíveis com probabilidade  $P(w)$  para cada mundo  $w$ ;
- para redes Bayesianas os mundos possíveis são associações de valores a variáveis
- no caso Booleano, os mundos possíveis são idênticos aos da lógica proposicional
- para um modelo probabilístico de 1a ordem, os mundos possíveis devem ser aqueles da lógica de 1a ordem:
  - ▶ um conjunto de objetos com relações entre eles e uma interpretação que associa símbolos de constantes a objetos, símbolos de predicados a relações e símbolos de funções à funções sobre os objetos
  - ▶ o modelo probabilístico também precisa definir uma probabilidade para cada mapeamento desses

# Desenvolvendo a linguagem

Supondo que isso tudo seja possível:

- a probabilidade de qualquer sentença de 1a ordem  $\phi$  é obtida pela soma sobre os mundos possíveis onde ela é verdadeira:

$$P(\phi) = \sum_{w: \phi \text{ verdade em } w} P(w).$$

- analogamente para prob. condicionais
- portanto, é possível perguntar “Quais livros são comumente recomendados por consumidores desonestos?”

# Desenvolvendo a linguagem

Supondo que isso tudo seja possível:

- a probabilidade de qualquer sentença de 1a ordem  $\phi$  é obtida pela soma sobre os mundos possíveis onde ela é verdadeira:

$$P(\phi) = \sum_{w: \phi \text{ verdade em } w} P(w).$$

- analogamente para prob. condicionais
- portanto, é possível perguntar “Quais livros são comumente recomendados por consumidores desonestos?”



# Desenvolvendo a linguagem


Supondo que isso tudo seja possível:

- a probabilidade de qualquer sentença de 1a ordem  $\phi$  é obtida pela soma sobre os mundos possíveis onde ela é verdadeira:

$$P(\phi) = \sum_{w: \phi \text{ verdade em } w} P(w).$$


- analogamente para prob. condicionais
- portanto, é possível perguntar “Quais livros são comumente recomendados por consumidores desonestos?”

# Mundos possíveis




- problema: modelos de 1a ordem são infinitos
- podemos reduzir para semântica de base de dados assumindo o seguinte:
  - ▶ *unique names assumption*
  - ▶ *domain closure* (não há mais objetos do que os mencionados explicitamente)
- esses são os casos mais simples de Modelos Probabilísticos Relacionais (MPR)

# Mundos possíveis



- problema: modelos de 1a ordem são infinitos
- podemos reduzir para semântica de base de dados assumindo o seguinte:
  - ▶ *unique names assumption*
  - ▶ *domain closure* (não há mais objetos do que os mencionados explicitamente)
- esses são os casos mais simples de Modelos Probabilísticos Relacionais (MPR)

# Mundos possíveis



- problema: modelos de 1a ordem são infinitos
- podemos reduzir para semântica de base de dados assumindo o seguinte:
  - ▶ *unique names assumption*
  - ▶ *domain closure* (não há mais objetos do que os mencionados explicitamente)
- esses são os casos mais simples de Modelos Probabilísticos Relacionais (MPR)

# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!

# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!

# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!

# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!



# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!

# Mundos possíveis

- Quando essas condições não são garantidas, MPRs não funcionam.
- Exemplos:
  - ▶ identificar livros pelo ISBN: um livro pode ter vários ISBNs; há incerteza quanto a um ISBN ser referir realmente a um livro específico;
  - ▶ os usuários desonestos podem ter centenas de IDs! (e.g. *sibil attack* em segurança de redes)
- Portanto, mesmo em domínios bem definidos, há incerteza na **existência de objetos** (quais são os livros e consumidores reais nos dados observados) e **incerteza na identidade** (quais símbolos realmente se referem a um mesmo objeto)
- deve-se definir modelos probabilísticos sobre a semântica de 1a ordem!

# Modelos Probabilísticos Relacionais (MPR)

- MPRs possuem símbolos para funções, constantes e predicados (funções que retornam *true* or *false*;
- assume-se *tipos* para cada função: modelos espúrios são eliminados
- Ex. no domínio de recomendação de livros:
  - ▶  $Honest : Customer \rightarrow \{true, false\}$
  - ▶  $Kindness : Customer \rightarrow \{1, 2, 3, 4, 5\}$
  - ▶  $Quality : Book \rightarrow \{1, 2, 3, 4, 5\}$
  - ▶  $Recommendation : Customer \times Book \rightarrow \{1, 2, 3, 4, 5\}$
- as variáveis aleatórias de um MPR são todas as instanciações possíveis de *Honest*, *Kindness*, *Quality*, *Recommendation* (todas as variáveis na figura (b) anterior)

# Modelos Probabilísticos Relacionais (MPR)

- MPRs possuem símbolos para funções, constantes e predicados (funções que retornam *true* or *false*;
- assume-se *tipos* para cada função: modelos espúrios são eliminados
- Ex. no domínio de recomendação de livros:
  - ▶ *Honest* : *Customer*  $\rightarrow$  {*true*, *false*}
  - ▶ *Kindness* : *Customer*  $\rightarrow$  {1, 2, 3, 4, 5}
  - ▶ *Quality* : *Book*  $\rightarrow$  {1, 2, 3, 4, 5}
  - ▶ *Recommendation* : *Customer*  $\times$  *Book*  $\rightarrow$  {1, 2, 3, 4, 5}
- as variáveis aleatórias de um MPR são todas as instanciações possíveis de *Honest*, *Kindness*, *Quality*, *Recommendation* (todas as variáveis na figura (b) anterior)

# Modelos Probabilísticos Relacionais (MPR)

- MPRs possuem símbolos para funções, constantes e predicados (funções que retornam *true* or *false*;
- assume-se *tipos* para cada função: modelos espúrios são eliminados
- Ex. no domínio de recomendação de livros:
  - ▶ *Honest* : *Customer*  $\rightarrow$  {*true*, *false*}
  - ▶ *Kindness* : *Customer*  $\rightarrow$  {1, 2, 3, 4, 5}
  - ▶ *Quality* : *Book*  $\rightarrow$  {1, 2, 3, 4, 5}
  - ▶ *Recommendation* : *Customer*  $\times$  *Book*  $\rightarrow$  {1, 2, 3, 4, 5}
- as variáveis aleatórias de um MPR são todas as instanciações possíveis de *Honest*, *Kindness*, *Quality*, *Recommendation* (todas as variáveis na figura (b) anterior)

# Modelos Probabilísticos Relacionais (MPR)

- Para completar esse MPRs deve-se escrever as distribuições de probabilidade:
  - ▶  $Honest(c) \sim \langle 0.99, 0.01 \rangle$
  - ▶  $Kindness(c) \sim \langle 0.1, 0.1, 0.2, 0.3, 0.3 \rangle$
  - ▶  $Quality(b) \sim \langle 0.05, 0.2, 0.4, 0.2, 0.15 \rangle$
  - ▶  $Recommendation(c, b) \sim RecCPT(Honest(c), Kindness(c), Quality(b))$
- onde  $RecCPT$  é uma tabela com  $2 \times 5 \times 5$  células, cada uma com 5 entradas.

# Modelos Probabilísticos Relacionais (MPR)

- Para completar esse MPRs deve-se escrever as distribuições de probabilidade:
  - ▶  $Honest(c) \sim \langle 0.99, 0.01 \rangle$
  - ▶  $Kindness(c) \sim \langle 0.1, 0.1, 0.2, 0.3, 0.3 \rangle$
  - ▶  $Quality(b) \sim \langle 0.05, 0.2, 0.4, 0.2, 0.15 \rangle$
  - ▶  $Recommendation(c, b) \sim RecCPT(Honest(c), Kindness(c), Quality(b))$
- onde RecCPT é uma tabela com  $2 \times 5 \times 5$  células, cada uma com 5 entradas.

# Modelos Probabilísticos Relacionais (MPR)

- Pode-se inserir *independências relacionadas ao contexto*, permitindo uma variável ser independente de seus pais para certos valores: E.g. consumidores desonestos ignoram qualidade na hora de fazer uma recomendação
- Portanto,  $Recommendation(c, b)$  é independente de  $Kindness(c)$  e  $Quality(b)$  quando  $Honest(c) = falso$

$Recommendation(c, b) \sim$   
if  $Honest(c) = falso$  then  
     $HonestRecCPT(Kindness(c), Quality(b))$   
else  $\langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle$

- o valor do teste condicional não precisa ser definido!



# Modelos Probabilísticos Relacionais (MPR)

- Pode-se inserir *independências relacionadas ao contexto*, permitindo uma variável ser independente de seus pais para certos valores: E.g. consumidores desonestos ignoram qualidade na hora de fazer uma recomendação
- Portanto,  $Recommendation(c, b)$  é independente de  $Kindness(c)$  e  $Quality(b)$  quando  $Honest(c) = falso$

$$\begin{aligned} Recommendation(c, b) &\sim \\ &\text{if } Honest(c) = falso \text{ then} \\ &\quad HonestRecCPT(Kindness(c), Quality(b)) \\ &\text{else } \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{aligned}$$

- o valor do teste condicional não precisa ser definido!

# Modelos Probabilísticos Relacionais (MPR)

- Pode-se inserir *independências relacionadas ao contexto*, permitindo uma variável ser independente de seus pais para certos valores: E.g. consumidores desonestos ignoram qualidade na hora de fazer uma recomendação
- Portanto,  $Recommendation(c, b)$  é independente de  $Kindness(c)$  e  $Quality(b)$  quando  $Honest(c) = falso$

$$\begin{aligned} Recommendation(c, b) &\sim \\ &\text{if } Honest(c) = falso \text{ then} \\ &\quad HonestRecCPT(Kindness(c), Quality(b)) \\ &\text{else } \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{aligned}$$

- o valor do teste condicional não precisa ser definido!

# Modelos probabilísticos relacionais

- O modelo pode ficar ainda mais realista: e.g. suponha que um consumidor honesto, que é fã de um determinado autor, sempre da nota 5 para seus livros, independente da qualidade:

*Recommendation(c, b) ~*  
*if Honest(c) then*  
*if Fan(c, Author(b)) then Exactly(5)*  
*HonestRecCPT(Kindness(c), Quality(b))*  
*else(0.4, 0.1, 0.0, 0.1, 0.4)*

- novamente,  $Fan(c, Author(b))$  não precisa ser conhecido, porém se um consumidor somente pontua 5s a um determinado autor (e não é “bonzinho”), então a probabilidade de que este consumidor é um fã deste autor é alta.
- a rede pode descontar, então, os 5s deste consumidor para um determinado autor.

# Modelos probabilísticos relacionais

- O modelo pode ficar ainda mais realista: e.g. suponha que um consumidor honesto, que é fã de um determinado autor, sempre da nota 5 para seus livros, independente da qualidade:

$$\begin{aligned} \textit{Recommendation}(c, b) \sim \\ \textit{if } \textit{Honest}(c) \textit{ then} \\ \quad \textit{if } \textit{Fan}(c, \textit{Author}(b)) \textit{ then } \textit{Exactly}(5) \\ \quad \textit{HonestRecCPT}(\textit{Kindness}(c), \textit{Quality}(b)) \\ \textit{else} \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{aligned}$$

- novamente,  $\textit{Fan}(c, \textit{Author}(b))$  não precisa ser conhecido, porém se um consumidor somente pontua 5s a um determinado autor (e não é “bonzinho”), então a probabilidade de que este consumidor é um fã deste autor é alta.
- a rede pode descontar, então, os 5s deste consumidor para um determinado autor.

# Modelos probabilísticos relacionais

- O modelo pode ficar ainda mais realista: e.g. suponha que um consumidor honesto, que é fã de um determinado autor, sempre da nota 5 para seus livros, independente da qualidade:

$$\begin{aligned} \textit{Recommendation}(c, b) \sim \\ \textit{if } \textit{Honest}(c) \textit{ then} \\ \quad \textit{if } \textit{Fan}(c, \textit{Author}(b)) \textit{ then } \textit{Exactly}(5) \\ \quad \textit{HonestRecCPT}(\textit{Kindness}(c), \textit{Quality}(b)) \\ \textit{else} \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{aligned}$$

- novamente,  $\textit{Fan}(c, \textit{Author}(b))$  não precisa ser conhecido, porém se um consumidor somente pontua 5s a um determinado autor (e não é “bonzinho”), então a probabilidade de que este consumidor é um fã deste autor é alta.
- a rede pode descontar, então, os 5s deste consumidor para um determinado autor.

# Modelos probabilísticos relacionais

- O modelo pode ficar ainda mais realista: e.g. suponha que um consumidor honesto, que é fã de um determinado autor, sempre da nota 5 para seus livros, independente da qualidade:

$$\begin{aligned} \textit{Recommendation}(c, b) \sim \\ \textit{if } \textit{Honest}(c) \textit{ then} \\ \quad \textit{if } \textit{Fan}(c, \textit{Author}(b)) \textit{ then } \textit{Exactly}(5) \\ \quad \textit{HonestRecCPT}(\textit{Kindness}(c), \textit{Quality}(b)) \\ \textit{else} \langle 0.4, 0.1, 0.0, 0.1, 0.4 \rangle \end{aligned}$$

- novamente,  $\textit{Fan}(c, \textit{Author}(b))$  não precisa ser conhecido, porém se um consumidor somente pontua 5s a um determinado autor (e não é “bonzinho”), então a probabilidade de que este consumidor é um fã deste autor é alta.
- a rede pode descontar, então, os 5s deste consumidor para um determinado autor.

# Modelos probabilísticos relacionais

- no exemplo anterior assumimos implicitamente que  $Author(b)$  é conhecido para todo  $b$ , mas isso não é sempre o caso;
- como o sistema pode então fazer inferências sobre se  $C_1$  é fã do  $Author(B_2)$  quando  $Author(B_2)$  não é conhecido?
- o sistema deve considerar todos os possíveis autores!
- suponha (por simplicidade) que  $Author(B_2)$  possa ter somente dois valores  $A_1$  e  $A_2$ , e é um pai de  $Recommendation(C_1, B_2)$
- as variáveis  $Fan(C_1, A_1)$  e  $Fan(C_1, A_2)$  são pais também.

# Modelos probabilísticos relacionais

- no exemplo anterior assumimos implicitamente que  $Author(b)$  é conhecido para todo  $b$ , mas isso não é sempre o caso;
- como o sistema pode então fazer inferências sobre se  $C_1$  é fã do  $Author(B_2)$  quando  $Author(B_2)$  não é conhecido?
- o sistema deve considerar todos os possíveis autores!
- suponha (por simplicidade) que  $Author(B_2)$  possa ter somente dois valores  $A_1$  e  $A_2$ , e é um pai de  $Recommendation(C_1, B_2)$
- as variáveis  $Fan(C_1, A_1)$  e  $Fan(C_1, A_2)$  são pais também.



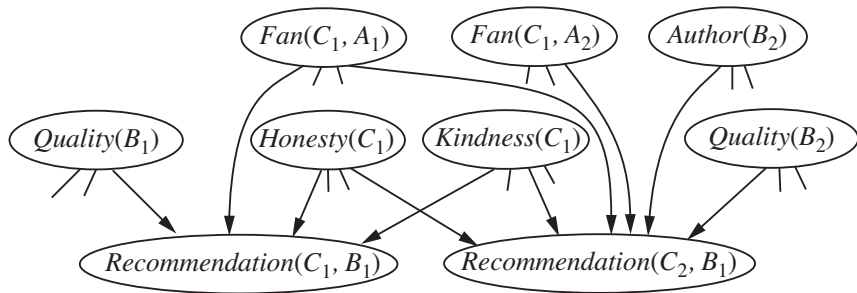
# Modelos probabilísticos relacionais

- no exemplo anterior assumimos implicitamente que  $Author(b)$  é conhecido para todo  $b$ , mas isso não é sempre o caso;
- como o sistema pode então fazer inferências sobre se  $C_1$  é fã do  $Author(B_2)$  quando  $Author(B_2)$  não é conhecido?
- o sistema deve considerar todos os possíveis autores!
- suponha (por simplicidade) que  $Author(B_2)$  possa ter somente dois valores  $A_1$  e  $A_2$ , e é um pai de  $Recommendation(C_1, B_2)$
- as variáveis  $Fan(C_1, A_1)$  e  $Fan(C_1, A_2)$  são pais também.

# Modelos probabilísticos relacionais

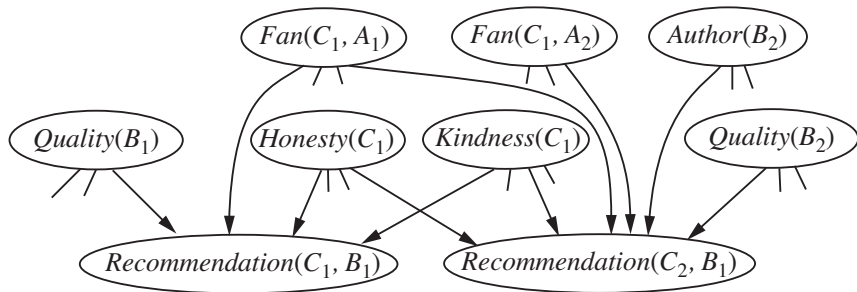
- no exemplo anterior assumimos implicitamente que  $Author(b)$  é conhecido para todo  $b$ , mas isso não é sempre o caso;
- como o sistema pode então fazer inferências sobre se  $C_1$  é fã do  $Author(B_2)$  quando  $Author(B_2)$  não é conhecido?
- o sistema deve considerar todos os possíveis autores!
- suponha (por simplicidade) que  $Author(B_2)$  possa ter somente dois valores  $A_1$  e  $A_2$ , e é um pai de  $Recommendation(C_1, B_2)$
- as variáveis  $Fan(C_1, A_1)$  e  $Fan(C_1, A_2)$  são pais também.

# Exemplo



- a distribuição para  $Recommendation(C_1, B_2)$  é um “multiplexador” em que o pai  $Author(B_2)$  age como um seletor que qual  $Fan(C_1, A_1)$  ou  $Fan(C_1, A_2)$  influencia na recomendação.
- a incerteza no valor de  $Author(B_2)$ , que afeta a estrutura de dependências na rede, é um exemplo de **incerteza relacional**.

# Exemplo



- a distribuição para  $Recommendation(C_1, B_2)$  é um “multiplexador” em que o pai  $Author(B_2)$  age como um seletor que qual  $Fan(C_1, A_1)$  ou  $Fan(C_1, A_2)$  influencia na recomendação.
- a incerteza no valor de  $Author(B_2)$ , que afeta a estrutura de dependências na rede, é um exemplo de **incerteza relacional**.

# Exemplo

- como o sistema pode saber quem é o autor de  $B_2$ ?
- considere a possibilidade de 3 outros consumidores, fãs de  $A_1$  (mas sem outro autor preferido em comum) e todos deram a  $B_2$  nota 5, mesmo que outros achem a obra medíocre
- neste caso, é provável que  $A_1$  seja o autor de  $B_2$
- a possibilidade de inferências tão fortes quanto estas, a partir de um modelo MPR de somente algumas linhas é um exemplo de como influências probabilísticas se espalham pela rede de interconexões de objetos.

# Exemplo

- como o sistema pode saber quem é o autor de  $B_2$ ?
- considere a possibilidade de 3 outros consumidores, fãs de  $A_1$  (mas sem outro autor preferido em comum) e todos deram a  $B_2$  nota 5, mesmo que outros achem a obra mediocre
- neste caso, é provável que  $A_1$  seja o autor de  $B_2$
- a possibilidade de inferências tão fortes quanto estas, a partir de um modelo MPR de somente algumas linhas é um exemplo de como influências probabilísticas se espalham pela rede de interconexões de objetos.

# Exemplo

- como o sistema pode saber quem é o autor de  $B_2$ ?
- considere a possibilidade de 3 outros consumidores, fãs de  $A_1$  (mas sem outro autor preferido em comum) e todos deram a  $B_2$  nota 5, mesmo que outros achem a obra mediocre
- neste caso, é provável que  $A_1$  seja o autor de  $B_2$
- a possibilidade de inferências tão fortes quanto estas, a partir de um modelo MPR de somente algumas linhas é um exemplo de como influências probabilísticas se espalham pela rede de interconexões de objetos.

# Exemplo

- como o sistema pode saber quem é o autor de  $B_2$ ?
- considere a possibilidade de 3 outros consumidores, fãs de  $A_1$  (mas sem outro autor preferido em comum) e todos deram a  $B_2$  nota 5, mesmo que outros achem a obra mediocre
- neste caso, é provável que  $A_1$  seja o autor de  $B_2$
- a possibilidade de inferências tão fortes quanto estas, a partir de um modelo MPR de somente algumas linhas é um exemplo de como influências probabilísticas se espalham pela rede de interconexões de objetos.



- **unrolling**: tomar as evidências, queries e símbolos de constantes e construir a rede Bayesiana (proposicional) equivalente
- executar algum dos métodos de inferência tradicionais para RB.
- problemas óbvios:
  - ▶ a rede resultante pode ser muito extensa
  - ▶ se existem muitos candidatos para uma relação desconhecida (e.g. o autor desconhecido de  $B_2$ , algumas variáveis na rede podem ter muitos pais

- **unrolling**: tomar as evidências, queries e símbolos de constantes e construir a rede Bayesiana (proposicional) equivalente
- executar algum dos métodos de inferência tradicionais para RB.
- problemas óbvios:
  - ▶ a rede resultante pode ser muito extensa
  - ▶ se existem muitos candidatos para uma relação desconhecida (e.g. o autor desconhecido de  $B_2$ , algumas variáveis na rede podem ter muitos pais

- **unrolling**: tomar as evidências, queries e símbolos de constantes e construir a rede Bayesiana (proposicional) equivalente
- executar algum dos métodos de inferência tradicionais para RB.
- problemas óbvios:
  - ▶ a rede resultante pode ser muito extensa
  - ▶ se existem muitos candidatos para uma relação desconhecida (e.g. o autor desconhecido de  $B_2$ , algumas variáveis na rede podem ter muitos pais

# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).

# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).

# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).

# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).

# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).



# Inferência em MPR

Algumas saídas:

- 1 há como melhorar os métodos tradicionais utilizando redundâncias da rede (*effective catching*)
- 2 desenvolver métodos de inferência que utilizem as independências dependentes de contexto
- 3 algoritmos baseados em MCMC possuem características interessantes em MPR:
  - ▶ como MCMC funciona por amostragem em mundos possíveis completos, em cada estado a estrutura relacional é completamente conhecida
  - ▶ e.g. cada estado/amostra do MCMC especifica um valor para a variável  $Author(B_2)$ . Portanto, os outros possíveis autores não são pais dos nos de recomendação em estados da rede
  - ▶ Assim para MCMC a incerteza relacional não causa aumento na complexidade da rede; mas o processo de amostragem inclui transições que mudam a estrutura relacional da rede e, portanto, as dependências probabilísticas da rede *sem variáveis* (unrolled).

- sintaxe: um vocabulário  $\Phi$ : conjunto de proposições; conjunto de conectivos usuais
- semântica: tabelas verdades
- probabilidades são atribuídas a fórmulas (proposições)”
  - ▶  $P(\phi) = \alpha$  (prob. de todas as atribuições de valores que fazem  $\phi$  verdadeira)
  - ▶  $P(\theta) \geq \beta$

- sintaxe: um vocabulário  $\Phi$ : conjunto de proposições; conjunto de conectivos usuais
- semântica: tabelas verdades
- probabilidades são atribuídas a fórmulas (proposições)”
  - ▶  $P(\phi) = \alpha$  (prob. de todas as atribuições de valores que fazem  $\phi$  verdadeira)
  - ▶  $P(\theta) \geq \beta$

# Lógica probabilística proposicional: draft

- o espaço de probabilidades será o conjunto de atribuições:  
 $\Omega = \{w: w \text{ é uma atribuição a } \phi\}$  e  $P(\phi) = \alpha$
- significa:  $P(\{w : w \in \Omega \wedge w \models \phi\}) = \alpha$ , onde  $w \models \phi$  significa que  $\phi$  é verdadeira na atribuição  $w$
- essas asserções são restrições lineares sobre  $p_k = p(w_k)$ , pois  
$$\sum_{k: w_k \models \phi} p_k = \alpha$$
- o problema de satisfação probabilística é calcular  $p(\theta)$  para uma fórmula  $\phi$ , a partir de asserções  $p(\phi_i) \geq \alpha_i$
- esse é um problema de prog. linear:  $\max/\min \sum_{w_k \models \phi} p_k$  tal que
  - ▶  $p_k \geq 0$ ,
  - ▶  $\sum_k p_k = 1$  e
  - ▶  $\sum_k p_k \geq \alpha_i$

# Lógica probabilística proposicional: draft

- o espaço de probabilidades será o conjunto de atribuições:  
 $\Omega = \{w: w \text{ é uma atribuição a } \phi\}$  e  $P(\phi) = \alpha$
- significa:  $P(\{w : w \in \Omega \wedge w \models \phi\}) = \alpha$ , onde  $w \models \phi$  significa que  $\phi$  é verdadeira na atribuição  $w$
- essas asserções são restrições lineares sobre  $p_k = p(w_k)$ , pois  
$$\sum_{k: w_k \models \phi} p_k = \alpha$$
- o problema de satisfação probabilística é calcular  $p(\theta)$  para uma fórmula  $\phi$ , a partir de asserções  $p(\phi_i) \geq \alpha_i$
- esse é um problema de prog. linear:  $\max/\min \sum_{w_k \models \phi} p_k$  tal que
  - ▶  $p_k \geq 0$ ,
  - ▶  $\sum_k p_k = 1$  e
  - ▶  $\sum_k p_k \geq \alpha_i$

# Lógica probabilística proposicional: draft

- o espaço de probabilidades será o conjunto de atribuições:  
 $\Omega = \{w: w \text{ é uma atribuição a } \phi\}$  e  $P(\phi) = \alpha$
- significa:  $P(\{w : w \in \Omega \wedge w \models \phi\}) = \alpha$ , onde  $w \models \phi$  significa que  $\phi$  é verdadeira na atribuição  $w$
- essas asserções são restrições lineares sobre  $p_k = p(w_k)$ , pois  
$$\sum_{k: w_k \models \phi} p_k = \alpha$$
- o problema de satisfação probabilística é calcular  $p(\theta)$  para uma fórmula  $\phi$ , a partir de asserções  $p(\phi_i) \geq \alpha_i$
- esse é um problema de prog. linear:  $\max/\min \sum_{w_k \models \phi} p_k$  tal que
  - ▶  $p_k \geq 0$ ,
  - ▶  $\sum_k p_k = 1$  e
  - ▶  $\sum_k p_k \geq \alpha_i$

# Lógica probabilística proposicional: draft

- o espaço de probabilidades será o conjunto de atribuições:  
 $\Omega = \{w: w \text{ é uma atribuição a } \phi\}$  e  $P(\phi) = \alpha$
- significa:  $P(\{w : w \in \Omega \wedge w \models \phi\}) = \alpha$ , onde  $w \models \phi$  significa que  $\phi$  é verdadeira na atribuição  $w$
- essas asserções são restrições lineares sobre  $p_k = p(w_k)$ , pois  
$$\sum_{k: w_k \models \phi} p_k = \alpha$$
- o problema de satisfação probabilística é calcular  $p(\theta)$  para uma fórmula  $\phi$ , a partir de asserções  $p(\phi_i) \geq \alpha_i$
- esse é um problema de prog. linear:  $\max/\min \sum_{w_k \models \phi} p_k$  tal que
  - ▶  $p_k \geq 0$ ,
  - ▶  $\sum_k p_k = 1$  e
  - ▶  $\sum_k p_k \geq \alpha_i$

## Métodos de solução:

- Scozzafava; Vincis
- Poggi de Aragão et al.
- Hansen, Jaumard. Probabilistic Satisfiability



- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

# Lógica Probabilística de 1a ordem (draft)

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

# Lógica Probabilística de 1a ordem (draft)

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

# Lógica Probabilística de 1a ordem (draft)

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

# Lógica Probabilística de 1a ordem (draft)

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

# Lógica Probabilística de 1a ordem (draft)

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

- sintaxe:  $P(\phi) = \alpha$  onde  $\phi$  é uma fórmula de 1a ordem
- semântica: estrutura relacional
  - ▶ Domínio D
  - ▶ função de atribuição:
    - ★ associa uma constante a um indivíduo
    - ★ cada relação a um conjunto de tuplas em D
    - ★ cada função a uma função em D
  - ▶  $P(\{w_k : w_k \models \phi\}) = \alpha$
  - ▶ pode-se portanto associar probabilidades a conjuntos de indivíduos no domínio, e.g.:
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall y \text{ filho}(x, y) \geq 0.9$
    - ★  $\forall x \text{ filho}(x, y) \geq 0.9$

- J. Halpern. Reasoning about uncertainty, 2003
- Baccus, (c.1980)