

# Графические модели и байесовский вывод на них

Сергей Николенко

Академический Университет, 2012

# Outline

- 1 Алгоритм передачи сообщений
  - Графические модели

# В чём же проблема

- В предыдущих лекциях мы рассмотрели задачу байесовского вывода, ввели понятие сопряжённого априорного распределения, поняли, что наша основная задача – найти апостериорное распределение.
- Но если всё так просто – взяли интеграл, посчитали, всё получилось – о чём же здесь целая наука?
- Проблема заключается в том, что распределения, которые нас интересуют, обычно слишком сложные (слишком много переменных, сложные связи).
- Но, с другой стороны, в них есть дополнительная структура, которую можно использовать, структура в виде независимостей и условных независимостей некоторых переменных.

# Графические модели с направленными графами

- Пример: рассмотрим распределение трёх переменных и запишем его по формуле полной вероятности:

$$p(x, y, z) = p(x \mid y, z)p(y \mid z)p(z).$$

- Теперь нарисуем граф, в котором стрелки указывают, какие условные вероятности заданы.
- Пока график полностью связанный, это нам ничего не даёт – любое распределение  $p(x_1, \dots, x_n)$  так можно переписать.
- Но если некоторых связей нет, это даёт нам важную информацию и упрощает жизнь.

# Графические модели с направленными графами

- Рассмотрим направленный ациклический граф на вершинах  $x_1, \dots, x_k$  и зададим в каждой вершине распределения  $p(x_i | \text{pa}(x_i))$ . Тогда будем говорить, что граф с этими локальными распределениями является графической моделью (байесовской сетью доверия) для совместного распределения вероятностей

$$p(x_1, \dots, x_k) = \prod_{i=1}^k p(x_i | \text{pa}(x_i)).$$

- Другими словами, если мы можем разложить большое совместное распределение в произведение локальных распределений, каждое из которых связывает мало переменных, это хорошо. :)

# Графические модели с направленными графами

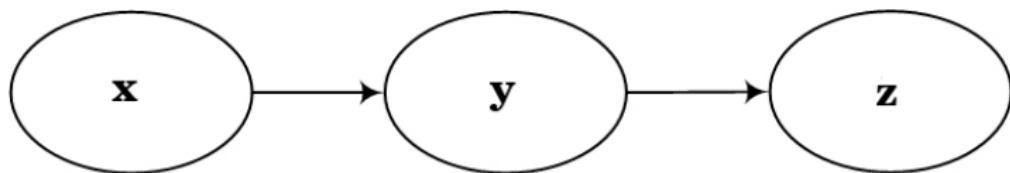
- Пример: обучение параметров распределения по нескольким экспериментам (плашки, можно нарисовать параметры явно):

$$p(x_1, \dots, x_n, \theta) = p(\theta) \prod_{i=1}^n p(x_i | \theta).$$

- Что можно сказать о (не)зависимости случайных величин  $x_i$  и  $x_j$ ?
- Задача вывода на графической модели: в некоторой части вершин значения наблюдаются, надо пересчитать распределения в других вершинах (подсчитать условные распределения). Например, из этой модели получатся и задача обучения параметров, и задача последующего предсказания.

# Графические модели с направленными графами

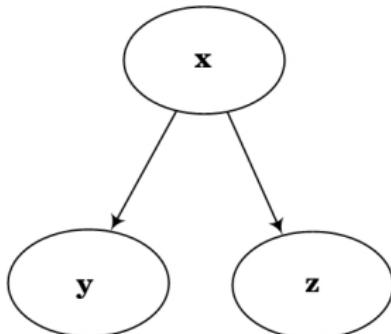
- $d$ -разделимость – условная независимость, выраженная в структуре графа:
  - последовательная связь,  $p(x, y, z) = p(x)p(y | x)p(z | y)$ :
    - если  $y$  не наблюдается, то  
 $p(x, z) = p(x) \int p(y | x)p(z | y) dy = p(x)p(z | x)$ ;
    - если  $y$  наблюдается, то  
 $p(x, z | y) = \frac{p(x, y, z)}{p(y)} = \frac{p(x)p(y|x)p(z|y)}{p(y)} = p(x | y)p(z | y)$ ,  
получили условную независимость.



Последовательная связь

# Графические модели с направленными графами

- расходящаяся связь,  $p(x, y, z) = p(x)p(y | x)p(z | x)$ , – так же:
  - если  $y$  не наблюдается, то
$$p(x, z) = p(x)p(z | x) \int p(y | x)dy = p(x)p(z | x);$$
  - если  $y$  наблюдается, то
$$p(x, z | y) = \frac{p(x, y, z)}{p(y)} = \frac{p(x)p(y|x)p(z|x)}{p(y)} = p(x | y)p(z | y),$$
получили условную независимость.



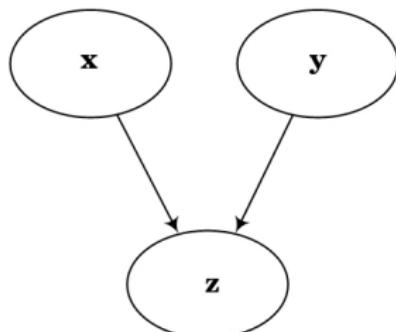
Расходящаяся связь

# Графические модели с направленными графами

- Интересный случай – сходящаяся связь,

$$p(x, y, z) = p(x)p(y)p(z | x, y):$$

- если  $z$  не наблюдается, то  $p(x, y) = p(x)p(y)$ , независимость есть;
- если  $z$  наблюдается, то  $p(x, y | z) = \frac{p(x,y,z)}{p(z)} = \frac{p(x)p(y)p(z|x,y)}{p(z)}$ , и условной независимости нету.



Сходящаяся связь

Обобщение: если наблюдается хотя бы один из потомков  $z$ , уже может не быть независимости между  $x$  и  $y$ .

# Графические модели с направленными графами

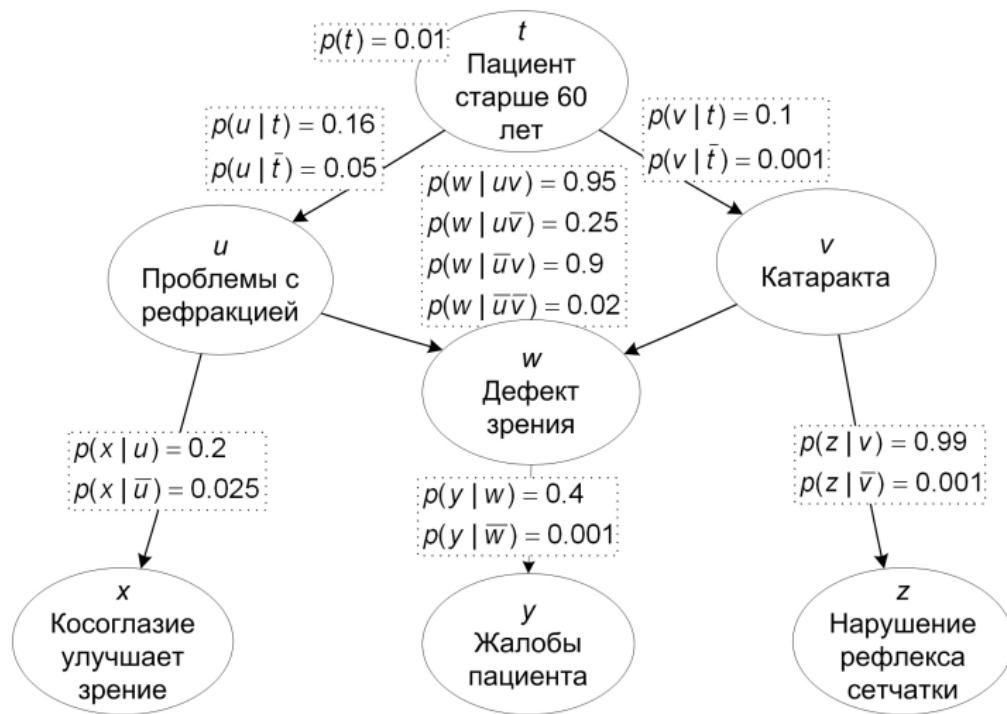
- Можно сформулировать, как структура графа соотносится с условной независимостью: в графе, где вершины из множества  $Z$  получили означивания (evidence), две ещё не означенные вершины  $x$  и  $y$  условно независимы при условии множества означенных вершин  $Z$ , если любой (ненаправленный) путь между  $x$  и  $y$ :
  - либо проходит через означенную вершину  $z \in Z$  с последовательной или расходящейся связью;
  - либо проходит через вершину со сходящейся связью, в которой ни она, ни её потомки не получили означиваний.

# Графические модели с направленными графами

- Можно сказать, что граф задаёт некоторое семейство распределений – не все распределения на вершинах графа будут соответствовать тем ограничениям по условной независимости, которые накладывает структура графа.
- Теорема (без доказательства): это семейство распределений в точности совпадает с семейством тех распределений, которые можно разложить в произведение

$$p(x_1, \dots, x_k) = \prod_{i=1}^k p(x_i | \text{pa}(x_i)).$$

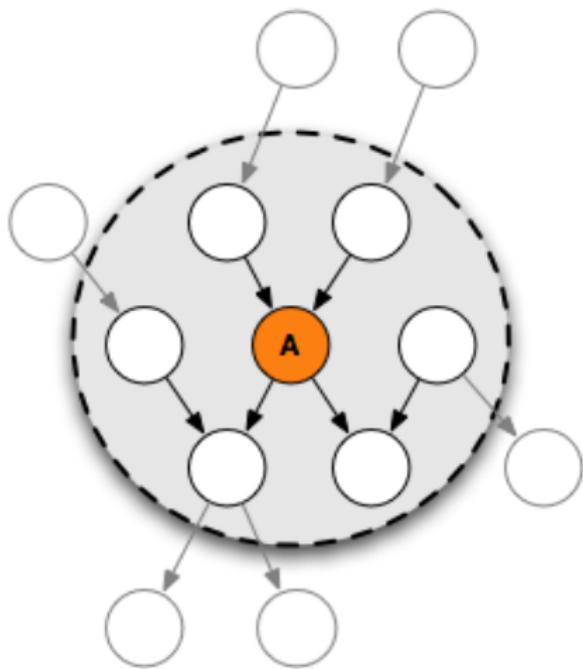
# Пример байесовской сети



# Markov blanket

- Интересный вопрос: какие вершины нужно означить, чтобы наверняка «отрезать» одну вершину (Markov blanket)?
- Иначе говоря, для какого минимального множества вершин  $X$   $p(x_i \mid x_{j \neq i}) = p(x_i \mid X)$ ?

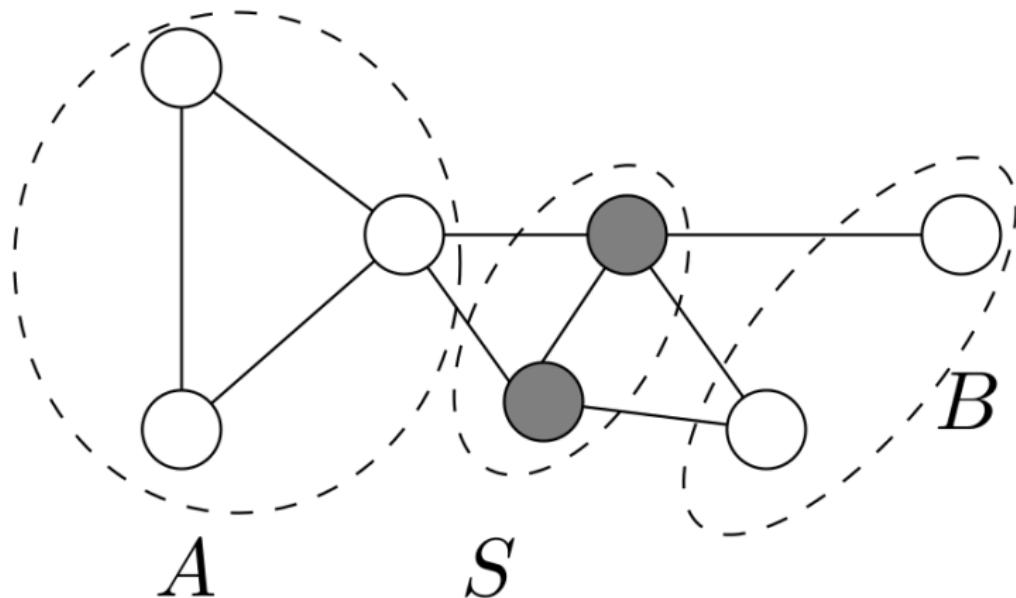
# Markov blanket



# Графические модели с ненаправленными графами

- Можно сделать и так, чтобы условие независимости было (более) локальным.
- Для этого нужно задавать модели ненаправленными графиками. В них условие совсем естественное: множество вершин  $X$  условно независимо от множества вершин  $Y$  при условии множества вершин  $Z$ , если любой путь от  $X$  к  $Y$  проходит через  $Z$ .
- В частности, очевидно,  
 $p(x_i, x_j \mid x_{k \neq i, j}) = p(x_i \mid x_{k \neq i, j})p(x_j \mid x_{k \neq i, j})$  тогда и только тогда, когда  $x_i$  и  $x_j$  не соединены ребром.
- Такие модели называются *марковскими сетями* (Markov random fields).

## Условная независимость в ненаправленных моделях



# Графические модели с ненаправленными графами

- Поэтому в ненаправленных моделях локальные распределения соответствуют кликам в графе, и факторизация получается в виде

$$p(x_1, \dots, x_k) = \frac{1}{Z} \prod \psi_C(x_C),$$

где  $C$  – максимальные клики,  $\psi_C$  – неотрицательные функции (потенциалы), а  $Z$  – нормировочная константа (partition function).

- Поскольку  $\psi_C \geq 0$ , их обычно представляют как экспоненты:

$$\psi_C(x_C) = \exp(-E_C(x_C)),$$

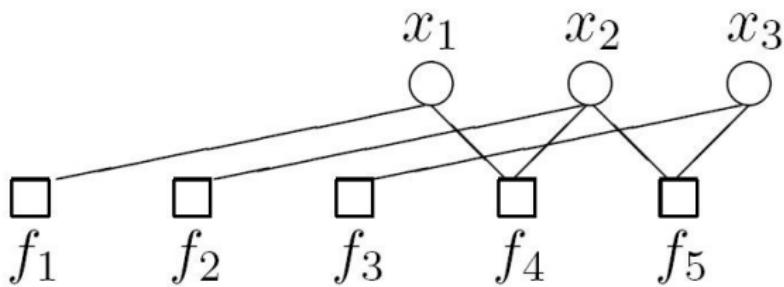
$E_C$  – функции энергии, они суммируются в полную энергию системы (это всё похоже на статистическую физику, отсюда и терминология).

# Графические модели с ненаправленными графами

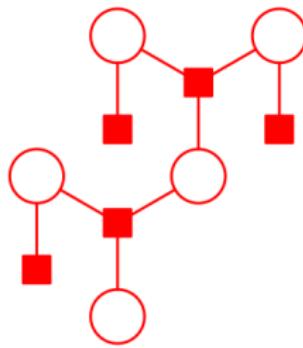
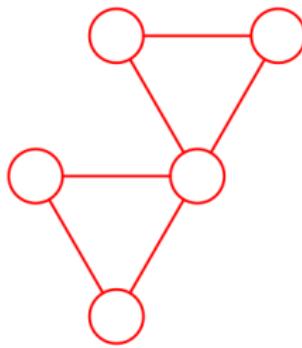
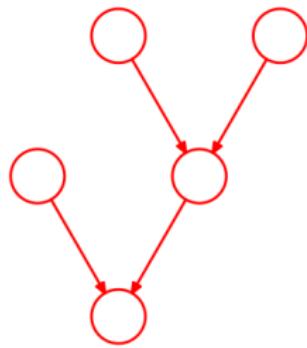
- Интересный факт: назовём *идеальной картой* (*perfect map*) распределения  $D$  графическую модель  $G$ , если все условные независимости, присутствующие в  $D$ , отображены в  $G$ , и наоборот (ничего лишнего). Тогда идеальные карты в виде направленных моделей существуют не у всех распределений, в виде ненаправленных тоже не у всех, и эти множества существенно различаются (бывают распределения, которые нельзя идеально выразить направленной моделью, но можно ненаправленной, и наоборот).

# Фактор-графы

- Важная для вывода модификация – *фактор-граф* (можно построить и по направленной модели, и по ненаправленной).
- Фактор-граф – двудольный граф функций и переменных.
- Функция, соответствующая графу, – произведение всех входящих в него функций (т.е. то самое разложение и есть).
- Пример:  $p(x_1, x_2, x_3) = f_1(x_1)f_2(x_2)f_3(x_3)f_4(x_1, x_2)f_5(x_2, x_3)$ .



# Три представления



# Функция в общем виде

- Чтобы поставить задачу в общем виде, рассмотрим функцию

$$p^*(X) = \prod_{j=1}^m f_j(X_j),$$

где  $X = \{x_i\}_{i=1}^n$ ,  $X_j \subseteq X$ .

- Т.е. мы рассматриваем функцию, которая раскладывается в произведение нескольких других функций.

# Задачи

- Задача нормализации: найти  $Z = \sum_X \prod_{j=1}^m f_j(X_j)$ .
- Задача маргинализации: найти

$$p_i^*(x_i) = \sum_{k \neq i} p^*(X).$$

Также может понадобиться, например,  $p_{i_1 i_2}$ , но реже.

- Поиск гипотезы максимального правдоподобия:

$$\mathbf{x}^* = \arg \max_X p(X).$$

# Задачи

- Все эти задачи NP-трудные.
- То есть, если мир не рухнет, сложность их решения в худшем случае возрастает экспоненциально.
- Но можно решить некоторые частные случаи.

# Пример

- Давайте начнём с графа в виде (ненаправленной) цепи:

$$p(x_1, \dots, x_n) = \frac{1}{Z} \psi_{1,2}(x_1, x_2) \dots \psi_{n-1,n}(x_{n-1}, x_n).$$

- Мы хотим найти

$$p(x_k) = \sum_{x_1} \dots \sum_{x_{k-1}} \sum_{x_{k+1}} \dots \sum_{x_n} p(x_1, \dots, x_n).$$

# Пример

- Очевидно, тут можно много чего упростить; например, справа налево:

$$\begin{aligned} & \sum_{x_n} p(x_1, \dots, x_n) = \\ &= \frac{1}{Z} \psi_{1,2}(x_1, x_2) \dots \psi_{n-2,n-1}(x_{n-2}, x_{n-1}) \sum_{x_n} \psi_{n-1,n}(x_{n-1}, x_n). \end{aligned}$$

- Эту сумму можно вычислить отдельно и продолжать в том же духе справа налево, потом аналогично слева направо.

# Пример

- В итоге процесс сойдётся на узле  $x_k$ , куда придут два «сообщения»: слева

$$\mu_\alpha(x_k) = \sum_{x_{k-1}} \psi_{k-1,k}(x_{k-1}, x_k) \left[ \dots \sum_{x_2} \psi_{2,3}(x_2, x_3) \left[ \sum_{x_1} \psi_{1,2}(x_1, x_2) \right] \dots \right],$$

справа

$$\mu_\beta(x_k) = \sum_{x_{k+1}} \psi_{k,k+1}(x_k, x_{k+1}) \left[ \dots \left[ \sum_{x_n} \psi_{n-1,n}(x_{n-1}, x_n) \right] \dots \right].$$

- Каждую частичную сумму можно рассматривать как «сообщение» от узла к своему соседу, причём это сообщение – функция от соседа.

Thank you!

**Спасибо за внимание!**