

Обучение байесовских сетей. Алгоритм EM.

Сергей Николенко

Машинное обучение — ИТМО, осень 2006

Outline

1 Алгоритм градиентного подъёма

- Разные варианты задачи обучения БСД
- Идея и вывод алгоритма

2 Алгоритм EM

- Идея
- Частный случай
- Сам алгоритм

Суть лекции

- На предыдущих лекциях мы поняли, что такое байесовские сети доверия.
- Теперь нужно научиться их обучать, то есть из набора тестовых данных получать вероятности.

Варианты

- Структура сети:
 - дана заранее;
 - нужно вывести из тестовых примеров.
- Каждый тестовый пример:
 - содержит значения всех переменных сети;
 - содержит некоторые переменные, о некоторых ничего не известно.

Простейший случай

Простейший случай — когда структура сети дана заранее, и каждый тестовый пример содержит значения всех переменных. Тогда можно просто получить оценки условных вероятностей, подсчитав частоты встречаемости тех или иных переменных.

Второй случай

Уже не настолько простой случай — когда структура сети дана, но не во всех примерах заданы все переменные сети. Здесь уже не обойтись подсчётом частот.

Градиентный подъем

- Будем использовать метод градиентного подъёма.
- Пространство гипотез — возможные элементы таблиц условных вероятностей.
- Задача — максимизировать $p(D|h)$ — условную вероятность имеющихся тестовых данных при условии различных гипотез.
- Метод — следовать градиенту $\ln p(D|h)$ по переменным, соответствующим элементам таблиц условных вероятностей.

Обозначения

- Узлы сети обозначим через x_i , их значения — через v_{ij} (у каждого узла своё множество значений).
- w_{ijk} — это условная вероятность того, что x_i примет значение v_{ij} при условии, что его родители $pa(x_i)$ примут значение, заданное u_{ik} ; т.е. u_{ik} может выражать сразу несколько значений переменных.

Вывод формулы

- Предполагаем, что тестовые примеры независимы:

$$\frac{\partial \ln p(D|h)}{\partial w_{ijk}} = \frac{\partial}{\partial w_{ijk}} \ln \prod_{d \in D} p(d|h) = \sum_{d \in D} \frac{1}{p(d|h)} \frac{\partial p(d|h)}{\partial w_{ijk}}.$$

- Теперь перейдём к сумме по значениям родителей:

$$\begin{aligned} \frac{\partial \ln p(D|h)}{\partial w_{ijk}} &= \sum_{d \in D} \frac{1}{p(d|h)} \times \\ &\times \frac{\partial}{\partial w_{ijk}} \sum_{j',k'} p(d|x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}, h) p(x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}|h) \\ &= \sum_{d \in D} \frac{1}{p(d|h)} \frac{\partial}{\partial w_{ijk}} \sum_{j',k'} p(d|x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}, h) \times \\ &\quad \times p(x_i = v_{ij'}|\text{pa}(x_i) = u_{ik'}, h) p(\text{pa}(x_i) = u_{ik'}|h). \end{aligned}$$

Вывод формулы

- Теперь перейдём к сумме по значениям родителей:

$$\begin{aligned}\frac{\partial \ln p(D|h)}{\partial w_{ijk}} &= \sum_{d \in D} \frac{1}{p(d|h)} \times \\ &\times \frac{\partial}{\partial w_{ijk}} \sum_{j',k'} p(d|x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}, h) p(x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}|h) \\ &= \sum_{d \in D} \frac{1}{p(d|h)} \frac{\partial}{\partial w_{ijk}} \sum_{j',k'} p(d|x_i = v_{ij'}, \text{pa}(x_i) = u_{ik'}, h) \times \\ &\quad \times p(x_i = v_{ij'}|\text{pa}(x_i) = u_{ik'}, h) p(\text{pa}(x_i) = u_{ik'}|h).\end{aligned}$$

- $w_{ijk} = p(x_i = v_{ij'}|\text{pa}(x_i) = u_{ik'}, h)$, поэтому в сумме только один ненулевой член: когда $j' = j$ и $i' = i$.

Вывод формулы

- $w_{ijk} = p(x_i = v_{ij'} | \text{pa}(x_i) = u_{ik'}, h)$, поэтому в сумме только один ненулевой член: когда $j' = j$ и $i' = i$.

$$\begin{aligned}\frac{\partial \ln p(D|h)}{\partial w_{ijk}} &= \sum_{d \in D} \frac{1}{p(d|h)} \frac{\partial}{\partial w_{ijk}} p(d|v_{ij}, u_{ik}, h) w_{ijk} p(u_{ik}|h) = \\ &= \sum_{d \in D} \frac{1}{p(d|h)} \frac{\partial}{\partial w_{ijk}} p(d|v_{ij}, u_{ik}, h) p(u_{ik}|h).\end{aligned}$$

Вывод формулы

- Перепишем это по теореме Байеса:

$$\begin{aligned}\frac{\partial \ln p(D|h)}{\partial w_{ijk}} &= \sum_{d \in D} \frac{1}{p(d|h)} \frac{p(v_{ij}, u_{ik}|d, h)p(d|h)p(u_{ik}|h)}{p(v_{ij}, u_{ik}|h)} = \\ &= \sum_{d \in D} \frac{p(v_{ij}, u_{ik}|d, h)p(u_{ik}|h)}{p(v_{ij}, u_{ik}|h)} = \\ &= \sum_{d \in D} \frac{p(v_{ij}, u_{ik}|d, h)}{p(v_{ij}|u_{ik}, h)} = \\ &= \sum_{d \in D} \frac{p(v_{ij}, u_{ik}|d, h)}{w_{ijk}}.\end{aligned}$$

Вероятности

$$\frac{\partial \ln p(D|h)}{\partial w_{ijk}} \sum_{d \in D} \frac{p(v_{ij}, u_{ik}|d, h)}{w_{ijk}}.$$

Вероятности $p(v_{ij}, u_{ik}|d, h)$ уже можно оценить из исходных данных. Либо x_i и $p(x_i)$ уже есть среди наблюдаемых величин, либо их можно вывести посредством стандартного байесовского вывода из наблюдаемых величин.

Алгоритм

- Проинициализировать w_{ijk} случайными значениями так, чтобы $w_{ijk} \in [0, 1]$ и $\forall i, k \sum_j w_{ijk} = 1$.
- Для каждого тестового примера $d \in D$:
 - Для каждого веса w_{ijk} :

$$w_{ijk} \leftarrow w_{ijk} + \eta \sum_{d \in D} \frac{p(v_{ij}, u_{ik}|d, h)}{w_{ijk}}.$$

Упражнения

Упражнение

Добавить возможность обучения по методу градиентного подъёма в имеющуюся реализацию байесовских сетей доверия.

Outline

1 Алгоритм градиентного подъёма

- Разные варианты задачи обучения БСД
- Идея и вывод алгоритма

2 Алгоритм EM

- Идея
- Частный случай
- Сам алгоритм

Постановка задачи

- Часто возникает ситуация, когда в имеющихся данных некоторые переменные присутствуют, а некоторые — отсутствуют.
- Например, в нашем примере байесовской сети может сложиться ситуация, когда известно, что компьютер упал со стола, и винчестер не читается, но про дефектные секторы ничего наверняка не известно.

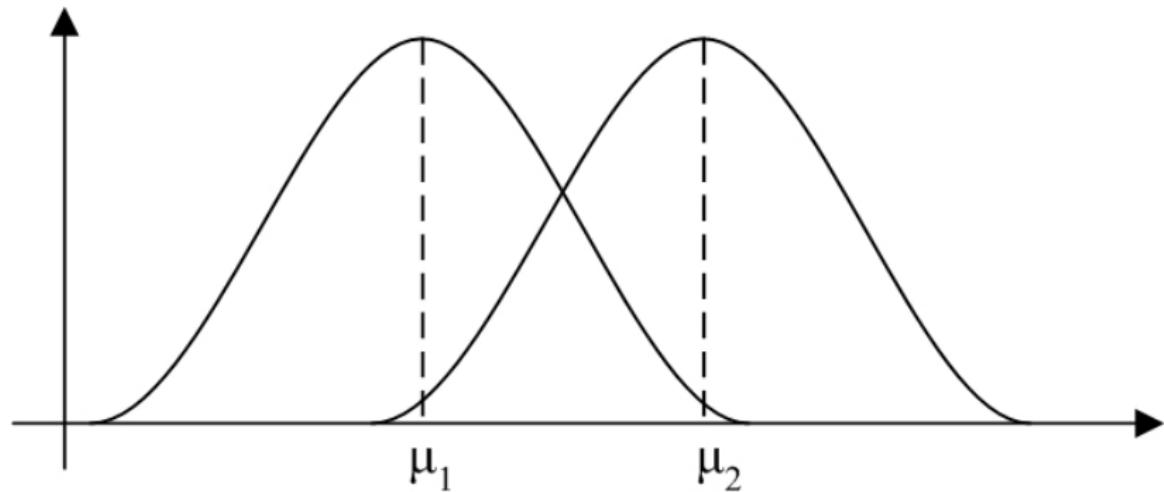
Постановка задачи

- Даны результаты сэмплирования распределения вероятностей с несколькими параметрами, из которых известны не все.
- Эти неизвестные параметры тоже расцениваются как случайные величины.
- Задача — найти наиболее вероятную гипотезу, то есть ту гипотезу h , которая максимизирует

$$E[\ln p(D|h)].$$

Частный случай

Построим один из простейших примеров применения алгоритма EM. Пусть случайная переменная x сэмплируется из суммы двух нормальных распределений. Дисперсии даны (одинаковые), нужно найти только средние μ_1, μ_2 .



Одно распределение

Если бы было одно распределение, всё было бы как раньше:

$$\mu_{ML} = \operatorname{argmin}_{\mu} \sum_{i=1}^m (x_i - \mu)^2,$$

и ответом было бы среднее арифметическое

$$\mu_{ML} = \frac{1}{m} \sum_{i=1}^m x_i.$$

Два распределения

- Теперь нельзя понять, какие x_i были порождены каким распределением.
- Это классический пример *скрытых переменных*.

Два распределения

- Как описать один тестовый пример полностью?

Два распределения

- Как описать один тестовый пример полностью?
- Например, как тройку $\langle x_i, z_{i1}, z_{i2} \rangle$, где $z_{ij} = 1$ iff x_i был сгенерирован j -м распределением.

Суть алгоритма EM

- Сгенерировать какую-нибудь гипотезу $h = (\mu_1, \mu_2)$.
- Пока не дойдём до локального максимума:
 - Вычислить ожидание $E(z_{ij})$ в предположении текущей гипотезы.
 - Вычислить новую гипотезу $h' = (\mu'_1, \mu'_2)$, предполагая, что z_{ij} принимают значения $E(z_{ij})$.

В нашем примере

В нашем примере:

$$\begin{aligned} E(z_{ij}) &= \frac{p(x = x_i | \mu = \mu_j)}{p(x = x_i | \mu = \mu_1) + p(x = x_i | \mu = \mu_2)} = \\ &= \frac{e^{-\frac{1}{2\sigma^2}(x_i - \mu_j)^2}}{e^{-\frac{1}{2\sigma^2}(x_i - \mu_1)^2} + e^{-\frac{1}{2\sigma^2}(x_i - \mu_2)^2}}. \end{aligned}$$

Мы подсчитываем эти ожидания, а потом подправляем гипотезу:

$$\mu_j \leftarrow \frac{1}{m} \sum_{i=1}^m E(z_{ij}) x_i.$$

Данные

- Итак, дан набор тестовых примеров $X = \{x_1, \dots, x_m\}$, имеется также набор скрытых переменных $Z = \{z_1, \dots, z_m\}$ для этих примеров, зависящих от параметров θ , и полный набор данных $Y = X \cup Z$.
- EM ищет гипотезу максимального правдоподобия h' , максимизируя $E(\ln p(Y|h'))$. Для этого он использует уже имеющуюся гипотезу для оценки скрытых параметров.
- Введём функцию $Q(h'|h)$ для оценки ожидания как функции от h' :

$$Q(h'|h) = E(\ln p(Y|h')|h, X).$$

Алгоритм EM

- Повторять до тех пор, пока не выполнено условие сходимости:

- Estimation:

$$Q(h'|h) \leftarrow E(\ln p(Y|h')|h, X).$$

- Maximization:

$$h \leftarrow \operatorname{argmax}_{h'} Q(h'|h).$$

Упражнения

Упражнение

Разработать версию алгоритма EM, оценивающую смесь из k нормальных распределений с разными дисперсиями σ_i ,
 $i = 1..k$.

Упражнение

Написать программу, реализующую эту версию EM; k и σ_i ,
 $i = 1..k$, должно быть возможно задавать на вход.

Спасибо за внимание!

- Lecture notes, слайды и коды программ появятся на моей homepage:
<http://logic.pdmi.ras.ru/~sergey/index.php?page=teaching>
- Присылайте любые замечания, коды программ на других языках, решения упражнений, новые численные примеры и прочее по адресам:
sergey@logic.pdmi.ras.ru, smartnik@inbox.ru