

# Семинар 4.

## ММП, осень 2012–2013

### 9 октября

#### Темы семинара:

- смеси нормальных распределений;
- скрытые переменные, совместное распределение скрытых и наблюдаемых переменных;
- KL-дивергенция, свойства;
- EM-алгоритм в общем случае.

## 1 Введение

Напомним вкратце часть материала, рассмотренного на лекции. Мы рассматриваем случайную величину, описываемую смесью нормальных распределений:

$$p(\mathbf{x}|\boldsymbol{\theta}) = \sum_{i=1}^K \pi_i \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_i, \Sigma_i).$$

При этом мы хотим найти параметры  $\boldsymbol{\theta} = \{\pi_i, \boldsymbol{\mu}_i, \Sigma_i\}$ , максимизируя правдоподобие наблюдаемой выборки:

$$\ln p(\mathbf{X}|\boldsymbol{\theta}) = \sum_{i=1}^{\ell} \ln \left[ \sum_{j=1}^K \pi_j \mathcal{N}(\mathbf{x}_i|\boldsymbol{\mu}_j, \Sigma_j) \right] \rightarrow \max_{\boldsymbol{\theta}}.$$

В отличие от случая нормально распределенных случайных величин, где логарифмирование плотности позволяло выписать решение задачи в аналитическом виде, здесь сумма под логарифмом кардинально меняет картину. Лекция была посвящена EM алгоритму, который (в частности) позволяет решить эту проблему, вводя в модель скрытые переменные  $\mathbf{z} \in \{0, 1\}^K$ ,  $\sum_{i=1}^K z_i = 1$ , отвечающие за компоненту смеси, породившую наблюдаемую случайную величину.

Рассмотрим еще раз роль скрытых переменных в описанной процедуре.

**Задача 1.** Рассмотрим совместное распределение  $p(\mathbf{x}, \mathbf{z})$  на  $\mathbf{x} \in \mathbb{R}^n$  и  $\mathbf{z} \in \{0, 1\}^K$ ,  $\sum_{i=1}^K z_i = 1$ , такое что выполнены следующие тождества для маргинального распределения  $\mathbf{z}$

$$p(\mathbf{z}) = \prod_{i=1}^K \pi_i^{z_i}, \quad 0 \leq \pi_i \leq 1, \quad \sum_{i=1}^K \pi_i = 1,$$

и условного распределения

$$p(\mathbf{x}|\mathbf{z}) = \prod_{i=1}^K [\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_i, \Sigma_i)]^{Z_i}, \quad \boldsymbol{\mu}_i \in \mathbb{R}^n, \Sigma_i \in \mathbb{R}^{n \times n}.$$

Найдите маргинальное распределение переменной  $\mathbf{x}$ .

Итак, нам удалось получить смесь нормальных распределений в качестве маргинального распределения, вводя в модель скрытые переменные. Что же мы при этом получаем?

Алгоритм начинается с инициализации вектора параметров  $\boldsymbol{\theta} \equiv \boldsymbol{\theta}_0$  и заключается в последующем применении двух шагов:

**E-шаг:** вычисление апостериорных вероятностей  $p(\mathbf{z}_k = 1|\mathbf{x})$  с помощью формулы Байеса:

$$p(\mathbf{z}_k = 1|\mathbf{x}) = \frac{p(\mathbf{z}_k = 1)p(\mathbf{x}|\mathbf{z}_k = 1)}{p(\mathbf{x})} = \frac{\pi_k \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_k, \Sigma_k)}{\sum_{i=1}^K \pi_i \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_i, \Sigma_i)};$$

**M-шаг:** решение задачи максимизация правдоподобия наблюдаемых переменных  $\ln p(\mathbf{X}|\boldsymbol{\theta}) \rightarrow \max_{\boldsymbol{\theta}}$  и выражение параметров модели  $(\boldsymbol{\theta})$  через апостериорные вероятности  $g_{i,k} \equiv p(\mathbf{z}_k = 1|\mathbf{x}_i)$ :

$$\begin{aligned} \frac{\partial \ln(\mathbf{X}|\boldsymbol{\theta})}{\partial \boldsymbol{\pi}_k} = 0 &\Leftrightarrow \boldsymbol{\pi}_k = \frac{\sum_{j=1}^{\ell} g_{j,k}}{\ell}; \\ \frac{\partial \ln(\mathbf{X}|\boldsymbol{\theta})}{\partial \boldsymbol{\mu}_k} = 0 &\Leftrightarrow \boldsymbol{\mu}_k = \frac{\sum_{j=1}^{\ell} g_{j,k} \mathbf{x}_j}{\sum_{i=1}^{\ell} g_{i,k}}; \\ \frac{\partial \ln(\mathbf{X}|\boldsymbol{\theta})}{\partial \Sigma_k} = 0 &\Leftrightarrow \Sigma_k = \frac{\sum_{j=1}^{\ell} g_{j,k} (\mathbf{x}_j - \boldsymbol{\mu}_k)(\mathbf{x}_j - \boldsymbol{\mu}_k)^{\top}}{\sum_{i=1}^{\ell} g_{i,k}}. \end{aligned}$$

Описанная процедура не дает нам аналитического решения интересующей нас задачи (поскольку апостериорные вероятности  $g_{i,k}$  зависят от параметров модели  $\boldsymbol{\theta}$ ), но позволяет решать её эффективно с помощью итерационной процедуры.

## 2 ЕМ-алгоритм в общем случае

Теперь введем ЕМ алгоритм, как общую процедуру максимизации правдоподобия в моделях со скрытыми переменными. Пусть имеется модель, в которую входят наблюдаемые переменные  $X$  и скрытые переменные  $Z$  с совместным распределением  $p(X, Z|\boldsymbol{\theta})$ , где  $\boldsymbol{\theta}$  — параметры модели. Мы будем решать задачу

$$\ln p(X|\boldsymbol{\theta}) \rightarrow \max_{\boldsymbol{\theta}}.$$

Заметим, что справедлива следующая цепочка неравенств:

$$\begin{aligned} \ln p(X|\boldsymbol{\theta}) &= \int q(Z) \ln p(X|\boldsymbol{\theta}) dZ = \int q(Z) \ln \frac{p(X, Z|\boldsymbol{\theta})}{p(Z|X, \boldsymbol{\theta})} dZ = \int q(Z) \ln \left[ \frac{p(X, Z|\boldsymbol{\theta})}{q(Z)} \frac{q(Z)}{p(Z|X, \boldsymbol{\theta})} \right] dZ = \\ &= \underbrace{\int q(Z) \ln p(X, Z|\boldsymbol{\theta}) dZ}_{\mathcal{L}(q, \boldsymbol{\theta})} - \underbrace{\int q(Z) \ln q(Z) dZ + \int q(Z) \ln \frac{q(Z)}{p(Z|X, \boldsymbol{\theta})} dZ}_{KL(q||p(Z|X, \boldsymbol{\theta}))}, \end{aligned} \quad (1)$$

где  $KL(q\|p(Z|X, \theta))$  — дивергенция Кульбака-Лейблера между распределениями  $q$  и апостериорным распределением  $p(Z|X, \theta)$ .

**Задача 2.** Докажите, что

$$a) KL(p\|q) \geq 0;$$

**Решение:**  $-KL(p\|q) = \int q(x) \ln \frac{p(x)}{q(x)} dx \leq \ln \int q(x) \frac{p(x)}{q(x)} dx = 0$  (неравенство Йенсена).

б) в общем случае  $KL(p\|q) = 0$  тогда и только тогда, когда  $p \equiv q$ .

**Задача 3.** Покажите, что максимизация функции правдоподобия  $p(X|\theta)$  эквивалентна минимизации  $KL$ -дивергенции  $KL(\text{эмпирическое распределение}\|p(x|\theta))$ .

Таким образом, мы нашли нижнюю оценку интересующей нас функции правдоподобия:

$$\ln p(X|\theta) \geq \mathcal{L}(q, \theta) = \int q(Z) \ln p(X, Z|\theta) dZ - \int q(Z) \ln q(Z) dZ. \quad (2)$$

Сейчас мы опишем ЕМ-алгоритм с помощью неравенств (1) и (2), попутно показав, что эта процедура сходится к локальному максимуму функции правдоподобия  $p(X|\theta)$ .

Фиксируем некоторое начальное значение  $\theta = \theta^0$ . (**Е-шаг:**) Попробуем максимизировать нижнюю оценку (2)  $\mathcal{L}(q, \theta)$  по распределению  $q$  при фиксированном  $\theta = \theta^0$ :

$$\mathcal{L}(q, \theta^0) \rightarrow \max_q.$$

**Задача 4.** Найдите распределение  $q$ , максимизирующее оценку (2)  $\mathcal{L}(q, \theta)$  при фиксированном значении  $\theta = \theta^0$ .

**Решение:** поскольку левая часть (1) не зависит от  $q$ , то несложно сделать вывод, что оценка максимизируется при  $q(Z) = p(Z|X, \theta^0)$ .

В этом случае  $KL$ -дивергенция обнуляется и нижняя оценка  $\mathcal{L}(q, \theta)$  превращается в точную оценку логарифма функции правдоподобия  $\ln p(X|\theta)$  в точке  $\theta = \theta^0$ .

(**М-шаг:**) Теперь при фиксированном распределении  $q$ , найденном на Е-шаге, максимизируем нижнюю оценку  $\mathcal{L}(q, \theta)$  по параметрам модели  $\theta$ , что эквивалентно:

$$\int q(Z) \ln p(X, Z|\theta) dZ \rightarrow \max_{\theta}, \quad (3)$$

поскольку  $q$  зависит лишь от первичной инициализации вектора параметров. Решение этой задачи назовем  $\theta^{\text{new}}$ . В левой части (3) записано ни что иное, как матожидание логарифма правдоподобия всех переменных  $\ln p(X, Z|\theta)$  (скрытых и наблюдаемых) относительно апостериорной вероятности скрытых переменных  $q(Z) = p(Z|X, \theta^0)$ .

Заметим, что М-шаг непременно увеличит значение нижней оценки  $\mathcal{L}(q, \theta)$ , а значит и правдоподобия  $p(X|\theta)$ , благодаря особому выбору распределения  $q$  на Е-шаге (сделавшего нижнюю оценку точной). Поскольку правдоподобие наблюдаемых данных ограничено сверху и в результате описанных Е-М итераций монотонно возрастает, то описанная процедура непременно сойдется (правда всего лишь к локальному максимуму).

ВСТАВИТЬ КАРТИНКУ, ИЛЛЮСТРИРУЮЩУЮ ИТЕРАЦИИ.

**Задача 5.** (задачка к картинке) Докажите, что производные нижней оценки (2) (для  $q(Z) = p(Z|X, \theta^0)$ ) и логарифма правдоподобия  $\ln p(X|\theta)$  в точке  $\theta = \theta^0$  совпадают.

**Решение:** поскольку  $KL(q\|p)$  зависит от  $\theta$  и достигает своего минимума (значения 0) в точке  $\theta = \theta^0$ , то

$$\frac{\partial}{\partial \theta} KL(q\|p) = 0 \text{ в точке } \theta = \theta^0.$$

Таким образом, продифференцировав обе части неравенства (1) по вектору параметров и подставив в полученное тождество  $\theta = \theta^0$ , мы получим искомое утверждение.

## Список литературы

- [1] Д. П. Ветров, Д. А. Кропотов. Байесовские методы машинного обучения. — Курс лекций, ММП ВМиК МГУ.  
[www.machinelearning.ru](http://www.machinelearning.ru)
- [2] C. Bishop. Pattern Recognition and Machine Learning. 9-я глава. — Springer, 2006.