

Второй семинар.

ММП, осень 2012–2013

11 сентября

Темы семинара:

- работа с вероятностью, формула Байеса, формула полной вероятности;
- вероятностная постановка задачи обучения по прецедентам, минимизация среднего риска, МЭР; оценки максимального правдоподобия.
- нормальное распределение, свойства, оценки максимального правдоподобия его параметров.

1 Первая половина

Задача 1. Пусть имеется две корзины: красная (r) и синяя (b). В красной корзине лежит 6 апельсинов (o) и 2 яблока (a), а в синей — 3 яблока и один апельсин. Пусть мы вытягиваем фрукт из этих корзин следующим образом: сначала случайным образом выбираем корзину, из которой будем тянуть, а затем вытягиваем из выбранной корзины случайно один фрукт. Будем обозначать корзину буквой B , а фрукт — буквой F . При этом пусть вероятность выбрать красную корзину на первом шаге равна 0,4: $P(B = r) = 0,4$. На втором шаге фрукты из выбранной корзины вытягиваются с равными вероятностями.

- а) Вычислите все значения условного распределения $P(F|B)$, $F \in \{o, a\}$, $B \in \{r, b\}$.
- б) Является ли функция $f(Y) = P(X|Y)$ при фиксированном X распределением?
- в) Вычислите все значения $P(F)$, $F \in \{o, a\}$, $B \in \{r, b\}$.
- г) Вычислите $P(B = r|F = o)$ и $P(B = r|F = a)$. Вспомните про б).

Вспоминаем определения и полезные свойства математического ожидания дисперсии и ковариации:

$$E\{X + Y\} = EY + EX;$$

$$E\{XY\} = EXEY, \text{ если } X \text{ и } Y \text{ независимы};$$

$$D\{X + Y\} = DX + DY, \text{ если } X \text{ и } Y \text{ независимы; (вывести)}$$

$$E_{X,Y} f(X, Y) = E_X E_{Y|X} f(X, Y) = E_Y E_{X|Y} f(X, Y) - \text{conditioning (обосновать)};$$

$$\text{cov}(X, Y) = E\{(X - EX)(Y - EY)\} = E\{XY\} - EXEY = 0, \text{ если } X \text{ и } Y \text{ независимы.}$$

Напоминание вероятностной постановки задачи обучения по прецедентам. Коротко обсуждаем суть априорных вероятностей классов и условных вероятностей

$P(X|Y)$ и $P(Y|X)$. Еще одно обоснование МЭР — желание решить задачу минимизации риска:

$$E_{X,Y}\{L(a(X), Y)\} \rightarrow \min_a,$$

где L — функция потерь. Поскольку мы не знаем $P(X, Y)$, можно воспользоваться законом больших чисел и перейти к решению минимизации эмпирического риска:

$$\frac{1}{\ell} \sum_{i=1}^{\ell} L(Y_i - a(X_i)) \rightarrow \min_a.$$

Задача 2. Пусть в задаче регрессии ($Y = \mathbb{R}$) мы используем квадратичную функцию потерь $L(a, b) = (a-b)^2$. Доказать, что решением описанной задачи минимизации риска будет функция регрессии $a(X) = E\{Y|X\}$.

2 Вторая половина

Напоминаю, что такое функция правдоподобия (данных при условии параметров модели), метод максимального правдоподобия и как выглядит одномерное нормальное распределение:

$$\mathcal{N}(x|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}.$$

Задача 3. Найдите оценку максимального правдоподобия для математического ожидания одномерного нормального распределения. Смещена?

Напоминаю вид многомерного нормального распределения, смысл и свойства матрицы ковариаций и вектора среднего.

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \Sigma) = \frac{1}{\sqrt{2\pi^n} \sqrt{\det \Sigma}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^\top \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})\right), \quad \mathbf{x} \in \mathbb{R}^n$$

Напоминаю ряд свойств матриц и производной по матрице. Алгебраическое дополнение элемента $a_{i,j}$ квадратной матрицы $A \in \mathbb{R}^{n,n}$: $A_{i,j} = (-1)^{i+j} \det \bar{A}^{i,j}$, где $\bar{A}^{i,j}$ — матрица, полученная из A выбрасыванием i -й строки и j -го столбца. Тогда определитель можно разложить по i -й строке: $\det A = \sum_{j=1}^n a_{i,j} A_{i,j}$. Присоединенная матрица — транспонированная матрица алгебраических дополнений: $\{C^*(A)\}_{i,j} = A_{j,i}$. Справедлива следующая формула: $A^{-1} = \frac{1}{\det A} C^*(A)$, а значит $(A^{-1})_{i,j} = \frac{A_{j,i}}{\det A}$.

Произвольная A	Симметричная A
(1) $\frac{\partial}{\partial u} u^\top A u = A^\top u + A u$	(4) $\frac{\partial}{\partial u} u^\top A u = 2A u$
(2) $\frac{\partial}{\partial A} \ln \det A = (A^{-1})^\top$	(5) $\frac{\partial}{\partial A} \ln \det A = 2(A^{-1}) - \text{diag} A^{-1}$
(3) $\frac{\partial}{\partial A} u^\top A u = u u^\top$	(6) $\frac{\partial}{\partial A} u^\top A u = 2u u^\top - \text{diag} u u^\top$

Докажите (1), (4) и (6) дома самостоятельно.

Докажем (2). Поскольку $A_{i,j}$ не зависит от элементов соответствующего столбика и строки, то с учетом сказанного, получаем $\frac{\partial \det A}{\partial a_{i,j}} = A_{i,j} = (A^{-1})_{j,i} \det A$, или $\frac{\partial \det A}{\partial A} = \det A (A^{-1})^\top$. А значит $\frac{\partial \ln \det A}{\partial A} = \frac{1}{\det A} \det A (A^{-1})^\top = (A^{-1})^\top$.

Докажем (5), что немного сложнее. В данном случае у нас $n(n-1)/2$ аргументов, что придется брать в расчет. Представим, что у нас есть матрица B , элементы $b_{i,j}$ и $b_{j,i}$ которой зависят от $a_{i,j}$, $i = 1, \dots, n$, $j = 1, \dots, n$. Тогда

$$\begin{cases} \frac{\partial \det B}{\partial a_{i,j}} = \frac{\partial \det B}{\partial b_{i,j}} \frac{\partial b_{i,j}}{\partial a_{i,j}} + \frac{\partial \det B}{\partial b_{j,i}} \frac{\partial b_{j,i}}{\partial a_{i,j}} = B_{i,j} \frac{\partial b_{i,j}}{\partial a_{i,j}} + B_{j,i} \frac{\partial b_{j,i}}{\partial a_{i,j}}, & i \neq j \\ \frac{\partial \det B}{\partial a_{i,i}} = B_{i,i} \frac{\partial b_{i,i}}{\partial a_{i,i}}, & i = j. \end{cases}$$

Положив $b_{i,j} = b_{j,i} = a_{i,j} = a_{j,i}$, с учетом $A_{i,j} = A_{j,i}$ получим окончательно

$$\begin{cases} \frac{\partial \det A}{\partial a_{i,j}} = 2A_{i,j}, & i \neq j \\ \frac{\partial \det A}{\partial a_{i,i}} = A_{i,i}, & i = j. \end{cases} \text{ и как следствие:}$$

$$\frac{\partial}{\partial A} \ln \det A = 2A^{-1} - \text{diag} A^{-1}.$$

Докажем (3). $u^\top A u = \sum_i \sum_j u_i a_{i,j} u_j$. Производная по $a_{i,j}$ равна $u_i u_j$. Чтд.

Задача 4. Получите оценки максимального правдоподобия для параметров n -мерного нормального распределения.

3 Решения

Задача 1:

а) В данном случае (с конечным числом значений сл. величин) можно пользоваться правилом $P(X = x | Y = y)$ — доля исходов с $X = x$ среди тех, у которых $Y = y$. (В более общем случае так не получится.)

$$P(F = o | B = b) = \frac{1}{4}; \tag{1}$$

$$P(F = a | B = b) = 1 - \frac{1}{4} = \frac{3}{4}; \tag{2}$$

$$P(F = o | B = r) = \frac{6}{8} = \frac{3}{4}; \tag{3}$$

$$P(F = a | B = r) = 1 - \frac{3}{4} = \frac{1}{4}. \tag{4}$$

б) Нет, эта функция не нормирована. Это мы увидим в пункте г).

в) По формуле полной вероятности

$$\begin{aligned} P(F = a) &= P(F = a | B = b)P(B = b) + P(F = a | B = r)P(B = r) = \\ &= \frac{3}{4} \times \frac{6}{10} + \frac{1}{4} \times \frac{4}{10} = \frac{11}{20}. \end{aligned}$$

Учитывая условие нормировки $P(F = a) + P(F = o) = 1$, получаем $P(F = o) = \frac{9}{20}$.
 г) Используя формулу Байеса получаем:

$$P(B = r|F = o) = \frac{P(F = o|B = r)P(B = r)}{P(F = o)} = \frac{3}{4} \times \frac{4}{10} \times \frac{20}{9} = \frac{2}{3};$$

$$P(B = r|F = a) = \frac{P(F = a|B = r)P(B = r)}{P(F = a)} = \frac{1}{4} \times \frac{4}{10} \times \frac{20}{11} = \frac{2}{11}.$$

Задача 2: применим хитрый трюк:

$$\begin{aligned} \mathbb{E}(a(X) - Y)^2 &= \mathbb{E}(a(X) - \mathbb{E}\{Y|X\} + \mathbb{E}\{Y|X\} - Y)^2 = \\ &= \mathbb{E}(a(X) - \mathbb{E}\{Y|X\})^2 + \mathbb{E}(\mathbb{E}\{Y|X\} - Y)^2 + 2\mathbb{E}\left\{(a(X) - \mathbb{E}\{Y|X\})(\mathbb{E}\{Y|X\} - Y)\right\}. \end{aligned}$$

С помощью conditioning легко показать, что последний член равен нулю, поскольку $a(X) - \mathbb{E}\{Y|X\}$ не зависит от Y и $\mathbb{E}_{Y|X}(\mathbb{E}\{Y|X\} - Y) = 0$.

Задача 3: Функция правдоподобия:

$$L(X^\ell | \mu, \sigma^2) = \prod_{i=1}^{\ell} \mathcal{N}(X_i | \mu, \sigma^2) \rightarrow \max_{\mu, \sigma^2};$$

$$\ln L(X^\ell | \mu, \sigma^2) = \ln \prod_{i=1}^{\ell} \mathcal{N}(X_i | \mu, \sigma^2) = \sum_{i=1}^{\ell} \ln \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(X_i - \mu)^2}{2\sigma^2}} \rightarrow \max_{\mu, \sigma^2};$$

$$\begin{cases} \frac{\partial \ln L(X^\ell | \mu, \sigma^2)}{\partial \mu} = 0; \\ \frac{\partial \ln L(X^\ell | \mu, \sigma^2)}{\partial \sigma^2} = 0. \end{cases} \quad \frac{\partial \ln L(X^\ell | \mu, \sigma^2)}{\partial \mu} = - \sum_{i=1}^{\ell} \frac{(X_i - \mu)}{\sigma^2} \dots$$

Задача 4: Пусть у нас есть ℓ наблюдений n -мерной нормальной случайной величины $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_\ell\}$. Для начала найдем $\boldsymbol{\mu}_{\text{MP}}$.

$$\ln \mathcal{N}(\mathbf{X} | \boldsymbol{\mu}, \Sigma) = \frac{1}{2} \ln \det \Sigma^{-1} - \frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^\top \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) + \text{const}(\boldsymbol{\mu}, \Sigma);$$

$$\frac{\partial}{\partial \boldsymbol{\mu}} \ln L(\mathbf{X} | \boldsymbol{\mu}, \Sigma) = \frac{\partial}{\partial \boldsymbol{\mu}} \sum_{i=1}^{\ell} -\frac{1}{2} (\mathbf{x}_i - \boldsymbol{\mu})^\top \Sigma^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) = \sum_{i=1}^{\ell} \Sigma^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) = \Sigma^{-1} \sum_{i=1}^{\ell} (\mathbf{x}_i - \boldsymbol{\mu}) = 0$$

поскольку матрица Σ^{-1} невырождена, получаем $\boldsymbol{\mu}_{\text{MP}} = \frac{1}{\ell} \sum_{i=1}^{\ell} \mathbf{x}_i$.

Теперь найдем Σ_{MP} :

$$\frac{\partial}{\partial \Sigma^{-1}} \ln L(\mathbf{X} | \boldsymbol{\mu}, \Sigma) = \ell \frac{1}{2} (2\Sigma - \text{diag} \Sigma) - \frac{1}{2} \sum_{i=1}^{\ell} (2(\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^\top - \text{diag}(\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^\top) = 0$$

Обозначим $S = \ell \Sigma - \sum_{i=1}^{\ell} (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^{\top}$, тогда

$$\frac{\partial}{\partial \Sigma^{-1}} \ln L(\mathbf{X} | \boldsymbol{\mu}, \Sigma) = \frac{1}{2} (2S - \text{diag} S) = 0,$$

откуда получаем

$$S = \ell \Sigma - \sum_{i=1}^{\ell} (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^{\top} = 0$$

и окончательно

$$\Sigma_{\text{MP}} = \frac{1}{\ell} \sum_{i=1}^{\ell} (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^{\top}.$$