

Семинар 3. Выбор модели по Байесу

Курс: Байесовские методы в машинном обучении, 2015

1. Рассмотрим модель BetaMix-Binomial:

$$\begin{aligned} p(k, q|N, \mathbf{w}, \mathbf{a}, \mathbf{b}) &= p(k|N, q)p(q|\mathbf{w}, \mathbf{a}, \mathbf{b}), \\ p(k|N, q) &= C_N^k q^k (1-q)^{N-k}, \\ p(q|\mathbf{w}, \mathbf{a}, \mathbf{b}) &= \sum_j w_j \text{Beta}(q|a_j, b_j), \quad a_j, b_j > 0, \quad w_j \geq 0, \quad \sum_j w_j = 1. \end{aligned}$$

Требуется вычислить апостериорное распределение $p(q|k, N, \mathbf{w}, \mathbf{a}, \mathbf{b})$, а также найти обоснованность модели $p(k|N, \mathbf{w}, \mathbf{a}, \mathbf{b})$.

2. Для модели BetaMix-Binomial вычислить прогноз для k_1 успехов в новых N_1 испытаниях, т.е. найти $p(k_1|N_1, k, N, \mathbf{w}, \mathbf{a}, \mathbf{b})$. Пусть имеется M моделей BetaMix-Binomial, т.е. заданы распределения $p(k, q|N, \mathbf{w}_m, \mathbf{a}_m, \mathbf{b}_m)$, $m = \overline{1, M}$. Требуется вычислить байесовский прогноз $p(k_1|N_1, k, N, \{\mathbf{w}_m, \mathbf{a}_m, \mathbf{b}_m\}_{m=1}^M)$ для всей совокупности моделей.
3. Пусть дискретная случайная величина x принимает значения $1, 2, \dots, l$ с вероятностями q_1, q_2, \dots, q_l соответственно. Пусть далее в N независимых испытаниях с величиной x значение 1 выпало k_1 раз, значение 2 – k_2 раз, …, значение $l - k_l$ раз. Требуется найти вероятность данного события $p(k_1, k_2, \dots, k_l | \mathbf{q}, N)$, подобрать сопряжённое априорное распределение для \mathbf{q} , найти апостериорное распределение $p(\mathbf{q}|\mathbf{k}, N)$, обоснованность модели $p(\mathbf{k}|N)$ и прогнозное распределение $p(\mathbf{k}_1|N_1, \mathbf{k}, N)$.
4. Рассмотрим задачу моделирования уровней смертности в городах от заданного заболевания. Пусть N_i – население i -го города, а x_i – число зафиксированных смертей за определённый период времени, $i = 1, \dots, N$. Пусть θ_i – уровень смертности в i -ом городе. Составим следующую вероятностную модель:

$$\begin{aligned} p(X, \Theta|N, \boldsymbol{\alpha}) &= \prod_{i=1}^N p(x_i|\theta_i, N_i)p(\theta_i|\boldsymbol{\alpha}), \\ p(x_i|\theta_i, N_i) &= C_{N_i}^{x_i} \theta_i^{x_i} (1-\theta_i)^{N_i-x_i}, \\ p(\theta_i|\boldsymbol{\alpha}) &= \text{Beta}(\theta_i|\boldsymbol{\alpha}). \end{aligned}$$

Требуется найти обоснованность модели $p(X|N, \boldsymbol{\alpha})$, а также байесовскую оценку для θ_i в виде мат.ожидания $p(\theta_i|X, N, \boldsymbol{\alpha})$.

5. Рассмотрим задачу моделирования уровней подготовки в школах по ЕГЭ по заданному предмету. Пусть N_i – количество учеников в i -й школе, а x_{ij} – оценка по ЕГЭ j -го ученика в i -й школе. Пусть средняя оценка по школе θ_i и оценка x_{ij} связаны как $p(x_{ij}|\theta_i) = \mathcal{N}(x_{ij}|\theta_i, \beta^{-1})$, где величина β известна. Требуется по аналогии с предыдущей задачей составить вероятностную модель описания данных с введением общего априорного распределения на θ_i для всех школ, выбранного в семействе сопряжённых. Требуется также записать обоснованность введённой модели и найти байесовскую оценку для θ_i как мат.ожидание апостериорного распределения $p(\theta_i|X)$.