

# Задание 3 по курсу «Байесовский выбор моделей»

## Общая информация

- Время сдачи задания: 30е ноября, 23:59 по Москве;
- Максимальная базовая оценка за задание 50 баллов, так что при желании можно выполнять не всё;
- Оценка автора наилучшей работы удваивается (с учетом баллов сверх 50), но не более, чем до 125 баллов;
- Вопросы и само задание принимаются по почте: aduenko1@gmail.com & iakovlev.kd@phystech.edu (отправлять на обе сразу);
- Тема письма: вопрос по заданию #3 или решение задания #3;
- Опоздание на неделю снижает оценку в 2 раза, опоздание на час на  $0.5^{1/(7 \cdot 24)} = 0.41\%$ ;
- Работы опоздавших не участвуют в конкурсе на лучшую работу;
- Задание не принимается после его разбора и / или после объявления об этом.

**Задача 1 (15 баллов).** Пусть имеется обучающая и тестовая выборки  $(\mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}})$ ,  $\mathbf{X}_{\text{train}} \in \mathbb{R}^{m_1 \times n}$ ,  $\mathbf{y}_{\text{train}} \in [-1, 1]^{m_1}$ ;  $(\mathbf{X}_{\text{test}}, \mathbf{y}_{\text{test}})$ ,  $\mathbf{X}_{\text{test}} \in \mathbb{R}^{m_2 \times n}$ ,  $\mathbf{y}_{\text{test}} \in [-1, 1]^{m_2}$ , полученные из общей модели генерации данных с совместным правдоподобием

$$p(\mathbf{y}, \mathbf{w}, \mathbf{X}|\mathbf{A}) = \prod_j \mathcal{N}(\mathbf{x}_j|\mathbf{0}, \sigma^2 \mathbf{I}_n) \mathcal{N}(\mathbf{w}|\mathbf{0}, \mathbf{A}^{-1}) \prod_j p(y_j|\mathbf{x}_j, \mathbf{w}),$$

где  $p(y_j|\mathbf{x}_j, \mathbf{w})$  дается моделью логистической регрессии, то есть

$$\mathbb{P}(y_j = 1) = \frac{1}{1 + \exp(-\mathbf{w}^\top \mathbf{x}_j)}.$$

- а) Выписать формулу для апостериорного распределения  $p(\mathbf{w}|\mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}, \mathbf{A})$  и получить его нормальную аппроксимацию  $p(\mathbf{w}|\mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}, \mathbf{A}) \approx \mathcal{N}(\mathbf{w}_0, \mathbf{H}_0^{-1})$  (4 балла);
- б) Пусть  $\hat{\mathbf{p}}$  – вектор оценок вероятностей принадлежности классу 1 для некоторого классификатора на тестовой выборке. Введем уверенность  $C(\mathbf{X}_{\text{test}}, \mathbf{y}_{\text{test}})$  классификатора на тестовой выборке как

$$C(\hat{\mathbf{p}}) = \sum_{i=1}^{m_2} |\hat{p}_i - 0.5|.$$

Рассмотрим также правдоподобие тестовой выборки относительно вектора  $\hat{\mathbf{p}}$  как

$$l(\mathbf{y}_{\text{test}}, \hat{\mathbf{p}}) = \prod_{i=1}^{m_2} \hat{p}_i^{y_{\text{test}}^i} (1 - \hat{p}_i)^{1 - y_{\text{test}}^i}.$$

Считая  $m_2 = 1000$ , а  $\sigma^2 = 1$ ,  $\mathbf{A} = \mathbf{I}_n$  известными и фиксированными, для разных размеров обучающей выборки  $m_1$  сравнить с помощью сэмплирования уверенность классификатора на тестовой выборке и правдоподобие на ней для точечного MAP-классификатора вида

$$\hat{\mathbf{p}}_{\text{test}} = \frac{1}{1 + \exp(-\mathbf{X}_{\text{test}}^\top \mathbf{w}_{\text{MAP}})}$$

и для полного байесовского классификатора, учитывающего неопределенность в  $\mathbf{w}$  вида

$$\hat{p}_{\text{test}} = \int \frac{1}{1 + \exp(-\mathbf{X}_{\text{test}}^T \mathbf{w})} p(\mathbf{w} | \mathbf{X}_{\text{train}}, \mathbf{y}_{\text{train}}) d\mathbf{w}.$$

Какой практический вывод можно сделать из полученных результатов? (11 баллов)

**Задача 2 (20 баллов).** Пусть имеется модель линейной регрессии с нормальным шумом

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim \mathcal{N}(0, \sigma^2 \mathbf{I}),$$

где  $\sigma^2$  – известно, и априорным распределение на  $\mathbf{w}$   $p(\mathbf{w}) = \mathcal{N}(\mathbf{w} | \mathbf{m}, \text{diag}(\mathbf{s}))$ , где  $\mathbf{m}$  и  $\text{diag}(\mathbf{s})$  неизвестные гиперпараметры.

а) Выписать совместное правдоподобие  $p(\mathbf{y}, \mathbf{w} | \mathbf{X}, \mathbf{m}, \mathbf{s})$ , задающее вероятностную модель. (2 балла)

б) Получить апостериорное распределение на вектор  $\mathbf{w}$ , предполагая  $\mathbf{m}$  и  $\mathbf{s}$  известными. Что происходит, если  $s_i = 0$ ? (4 баллов)

в) Решить задачу максимизации обоснованности

$$p(\mathbf{y} | \mathbf{X}, \mathbf{m}, \mathbf{s}) = \int p(\mathbf{y} | \mathbf{X}, \mathbf{w}) p(\mathbf{w} | \mathbf{m}, \text{diag}(\mathbf{s})) d\mathbf{w}$$

по гиперпараметрам  $\mathbf{m}$  и  $\mathbf{s}$ . Какой вывод можно сделать из полученного результата? (14 баллов)

**Задача 3 (20 баллов).** Пусть имеется две двухсторонние монеты, случайно и независимо выбранные из всех существующих монет достоинством в 2 рубля. Пусть было произведено  $n_1 = 10$  бросаний первой монеты и  $n_2 = 10000$  бросаний второй. Среди  $n_1 = 10$  результатов бросания первой монеты было  $k_1 = 3$  орла, а среди  $n_2 = 10000$  бросаний второй –  $k_2 = 5100$  орлов.

а) Построить вероятностную модель эксперимента, записав правдоподобие и введя априорные распределения на вероятности  $p_1$  и  $p_2$  выпадания орлов для первой и второй монеты соответственно. Опишите, как и из каких соображений Вы выбрали априорные распределения  $q(p_1)$  и  $q(p_2)$ . (4 балла)

б) Получить апостериорные распределения  $q(p_1 | k_1, n_1)$  и  $q(p_2 | k_2, n_2)$ . (4 балла)

в) Пусть теперь рассматривается две вероятностные модели:  $M_1$  с  $p_1 = p_2 = p$  и априорным распределением, которое было ранее выбрано Вами для  $p_1$  и полная модель  $M_2$  из пункта а), где  $p_1$  и  $p_2$  априорно выбраны независимо из  $q(p_1)$  и  $q(p_2)$ . Сосчитать апостериорную вероятность обеих моделей, считая их априори равновероятными ( $p(M_1) = p(M_2) = 0.5$ ). Какой вывод можно сделать из результата? (12 баллов)

**Задача 4 (10 баллов).** а) Что такое дивергенция Кульбака-Лейблера (KL-divergence), что она показывает и когда определена? (2 балла)

б) Докажите, что значение дивергенции Кульбака-Лейблера неотрицательно (3 балла).

в) Пусть у Вас есть две модели логистической регрессии с равномерным априорным псевдораспределением на параметр  $\mathbf{w}$ , оцененные на двух разных выборках  $(\mathbf{X}_1, \mathbf{y}_1)$  и  $(\mathbf{X}_2, \mathbf{y}_2)$  с одинаковым набором из двух признаков. Пусть апостериорные распределение для первой выборки  $\mathbf{w} \sim \mathcal{N}\left(\mathbf{w} | [1, 1]^T, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}\right)$ , а для второй выборки  $\mathbf{w} \sim \mathcal{N}\left(\mathbf{w} | [-8, -3]^T, \begin{pmatrix} 10000 & 0 \\ 0 & 2000 \end{pmatrix}\right)$ .

Считая, что выборки сгенерированы с помощью модели логистической регрессии, можно ли с уверенностью утверждать, что истинные векторы параметров этих моделей  $\mathbf{w}_1$  и  $\mathbf{w}_2$  разные? (5 баллов)