

# Зачётный тест по курсу «Байесовский выбор моделей»

**Время выполнения:** 90 минут

**Максимальный балл:** 100 баллов, поэтому можно выполнять не все задания

**Замечание:** попавшие в ТОРЗ по баллам дополнительно получают  $\min(X, 100 - 30R)$ , где  $X$  – набранный балл, а  $R$  – ранг от 0 до 2.

**Задача 1 (20 баллов).** Пусть имеется НОР (i.i.d.) выборка  $x_1, \dots, x_n$  из нормального распределения  $N(m, \sigma^2)$ , то есть  $x_i \sim \mathcal{N}(x_i|m, \sigma^2)$ . Введем априорные распределения на  $m$  и  $\sigma^2$  вида

$$m \sim \mathcal{N}(m|m_0, \sigma_0^2), \frac{1}{\sigma^2} \sim \Gamma\left(\frac{1}{\sigma^2}|\alpha, \beta\right), \quad (1)$$

где  $\alpha, \beta, m_0, \sigma_0^2$  – известные гиперпараметры.

а) Выписать совместное правдоподобие модели  $p(\mathbf{x}, m, \sigma^2|\alpha, \beta, m_0, \sigma_0)$  (1 балл);

б) Выписать  $p(m, \sigma^2|\mathbf{x}, \alpha, \beta, m_0, \sigma_0)$ . Принадлежит ли оно параметрическому семейству нормально-гамма распределений (normal-gamma distributions) и почему? (3 балла);

в) Является ли исходное априорное распределение (1) сопряженным к правдоподобию и почему? (1 балл) Найти и обосновать параметрическое семейство сопряженных распределений (2 балла);

г) Получить вариационное приближение  $q(m, \sigma^2) = q(m)q(\sigma^2)$  для полного апостериорного распределения  $p(m, \sigma^2|\mathbf{x}, \alpha, \beta, m_0, \sigma_0)$  (13 баллов).

**Задача 2 (40 баллов).** Пусть имеется  $K$  математических кружков, в каждом из которых обучается  $N$  студентов. Пусть известны результаты решения одинаковых по сложности задач студентами кружков. Там для студента с номером  $n$  в кружке с номером  $k$  известны два числа:  $t_{kn}$  – количество задач, которые студент попробовал решить и  $s_{kn}$  – количество успешно решенных задач. В каждом кружке считаем, что вероятность каждого студента решить задачу равна  $p_k$ , зависящая от кружка, но не зависящая от студента. Успешность решения разных задач одним студентом, а также успешность решения задач между студентами независимы в совокупности. Считаем, что априорное распределение на  $p_k$  есть  $p_k \sim \text{Beta}(p_k|\alpha, \beta)$ , где  $\alpha, \beta$  – неизвестные гиперпараметры.

Обозначим  $\mathbf{p} = [p_k, k = 1, \dots, K]^T$ ,  $\mathbf{T} = \|t_{kn}\|$ ,  $\mathbf{S} = \|s_{kn}\|$ ,  $k = 1, \dots, K$ ,  $n = 1, \dots, N$ .

а) Выписать в явном виде совместное правдоподобие  $p(\mathbf{S}, \mathbf{p}|\mathbf{T}, \alpha, \beta)$  (5 баллов);

б) Получить апостериорное распределение  $p(\mathbf{p}|\mathbf{T}, \mathbf{S}, \alpha, \beta)$  и описать структуру зависимостей между компонентами  $\mathbf{p}$  (10 баллов). Вычислить  $\mathbb{E}\mathbf{p}$  по апостериорному распределению (3 балла). Какие выводы можно сделать из полученного результата? (2 балла)

в) Выписать обоснованность  $p(\mathbf{S}, \mathbf{T}|\alpha, \beta)$  в явном виде. Описать, как найти оценки гиперпараметров  $\alpha, \beta$  из принципа максимума обоснованности (20 баллов).

**Задача 3 (20 баллов).** Пусть рассматривается поток посетителей в магазин, и измеряются интервалы между приходом двух последовательных посетителей. Считаем, что интервалы  $t_1, \dots, t_k, \dots$  между последовательными посетителями независимы в совокупности имеют показательное распределение с параметром  $\lambda$ , то есть

$$p(t_k) = \lambda \exp(-\lambda t_k), t_k \geq 0.$$

а) Выписать правдоподобие модели  $p(\mathbf{t}|\lambda)$  (2 балла). Ввести априорное распределение на  $\lambda$   $p(\lambda|\alpha)$ , сопряженное с правдоподобием, где  $\alpha$  – вектор гиперпараметров (3 балла). Какое семейство распределений сопряжено с таким правдоподобием? (1 балл)

б) Получить выражения для обоснованности модели  $p(\mathbf{t}|\alpha)$  в явном виде и описать метод поиска  $\alpha$  из принципа максимума обоснованности (14 баллов).

**Задача 4 (40 баллов).** Пусть имеется обучающая выборка  $(\mathbf{X}, \mathbf{y})$ ,  $\mathbf{X} \in \mathbb{R}^{m \times n}$ ,  $\mathbf{y} \in$

$[-1, 1]^m$ , полученная из модели генерации данных с совместным правдоподобием

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

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

$$\mathbb{P}(y_j = 1) = \frac{1}{1 + \exp(-\mathbf{w}^\top \mathbf{x}_j)} = \sigma(\mathbf{w}^\top \mathbf{x}_j), \quad \mathbf{A} = \text{diag}(\alpha_j).$$

Используем принцип максимума обоснованности для отбора признаков

$$\mathbf{A} = \arg \max_{\mathbf{A}} p(\mathbf{y}_1|\mathbf{X}_1, \mathbf{A}).$$

- а) Выписать совместное правдоподобие модели  $p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \mathbf{A})$  в явном виде (1 балл);
- б) Какое значение  $\alpha_j$  соответствует тому, что признак  $j$  незначим, и не используется в модели? (1 балл)
- в) Использовать вариационную нижнюю оценку для сигмоидной функции (см. лекцию 7) для получения нижней оценки на совместное правдоподобие (требуется привести подробный вывод)  $p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \mathbf{A}) \geq L(\mathbf{w}, \mathbf{A}, \boldsymbol{\xi})$ , где  $\boldsymbol{\xi} \in \mathbb{R}^m$  – вектор дополнительных переменных (8 баллов);
- г) Для нижней оценки на обоснованность

$$p(\mathbf{y}|\mathbf{X}, \mathbf{A}) = \int p(\mathbf{y}, \mathbf{w}|\mathbf{X}, \mathbf{A}) d\mathbf{w} \geq \int L(\mathbf{w}, \mathbf{A}, \boldsymbol{\xi}) d\mathbf{w} = \tilde{L}(\mathbf{A}, \boldsymbol{\xi})$$

получить формулы EM-алгоритма для решения задачи ее максимизации

$$\tilde{L}(\mathbf{A}, \boldsymbol{\xi}) \rightarrow \max_{\mathbf{A}, \boldsymbol{\xi}} \quad (30 \text{ баллов}).$$

**Задача 5 (70 баллов).** Пусть рассматривается поток посетителей в магазин, и измеряются интервалы между приходом двух последовательных посетителей. Считаем, что распределение интервала  $t_n$  между последовательными посетителями описывается смесью  $K$  показательных распределений с показателями  $\boldsymbol{\lambda} = [\lambda_1, \dots, \lambda_K]^\top$  и весами  $\boldsymbol{\pi} = [\pi_1, \dots, \pi_K]^\top$ , то есть

$$p(t_n) = \sum_{k=1}^K \pi_k \lambda_k \exp(-\lambda_k t_n),$$

причем наблюдаемые интервалы  $\mathbf{t} = [t_1, \dots, t_N]^\top$  независимы в совокупности.

Введем на  $\boldsymbol{\pi}$  априорное симметричное распределение Дирихле  $\boldsymbol{\pi} \sim \text{Dir}(\boldsymbol{\pi}|\boldsymbol{\mu}\mathbf{e})$ , где  $\mu < 1$  – параметр распределения Дирихле (считается фиксированным и известным), а  $\mathbf{e}$  – единичный вектор.

Введем также априорные распределения на  $\lambda_k$  вида

$$\lambda_k \sim \Gamma(\alpha, \beta), \quad k = 1, \dots, K,$$

где  $\alpha, \beta$  – неизвестные параметры гамма-распределения.

- а) Выписать совместное правдоподобие модели  $p(\mathbf{t}, \boldsymbol{\pi}, \boldsymbol{\lambda}|\alpha, \beta, \mu)$  (5 баллов);
- б) Ввести матрицу скрытых переменных  $\mathbf{Z}$  принадлежности объекта компоненте смеси и выписать совместное правдоподобие модели со скрытой переменной  $p(\mathbf{t}, \boldsymbol{\pi}, \boldsymbol{\lambda}, \mathbf{Z}|\alpha, \beta, \mu)$  (5 баллов);
- в) Воспользовавшись вариационным EM-алгоритмом, получить аппроксимацию  $q(\boldsymbol{\pi}, \boldsymbol{\lambda}, \mathbf{Z}) = q(\boldsymbol{\pi})q(\boldsymbol{\lambda})q(\mathbf{Z})$  для истинного апостериорного распределения  $p(\boldsymbol{\pi}, \boldsymbol{\lambda}, \mathbf{Z}|\mathbf{t}, \mu, \alpha, \beta)$  (35 баллов), а также задачи для нахождения оценок максимума обоснованности для  $\alpha, \beta$

$$\alpha^*, \beta^* = \arg \max_{\alpha, \beta} p(\mathbf{t}|\mu, \alpha, \beta)$$

и описать способ решения полученных оптимизационных задач (25 баллов).