

# Байесовский выбор моделей: введение

Александр Адуенко  
aduenko1@gmail.com

12е сентября 2023

# Байесовский выбор моделей: план курса

- Вводная лекция. Вспоминание результатов из теории вероятностей и статистики.
- Введение в байесовские методы. Базовые результаты и обозначения. Априорное распределение и неинформативные распределения (Jeffreys prior). Экспоненциальное семейство распределений.
- Байесовские модели классификации, регрессии, кластеризации, сокращения размерности.
- Понятие обоснованности в байесовском выборе моделей и его интерпретация.
- Построение интерпретируемых адекватных мультимodelей для описания сложных выборок.
- Построение и выбор моделей при анализе временных рядов. Гауссовские процессы.
- EM-алгоритм и вариационный вывод.
- Методы сэмплирования для прогноза в байесовских моделях.
- Введение в графические модели.

# Система оценивания

- 12 лекций + 3-4 небольших теста на них (суммарно до 200 баллов);
- 7 заданий:
  - 5 небольших (скорее теоретических) по 50 баллов,
  - 2 более крупных (скорее практических) по 100 баллов;
- Экзамен:
  - Письменная часть (100 баллов),
  - Устная часть (150 баллов).

## Замечания:

- На оценку  $k$  требуется набрать  $70k$  баллов;
- Экзамен можно пропустить только, если набрано не менее 400 баллов до экзамена;
- Задания содержат задачи более, чем на 50 / 100 баллов, поэтому можно выбрать, что выполнять;
- В каждом задании баллы лучшей работы удваиваются, если она оценена более, чем в 50 / 100 баллов (не более 125 / 250 баллов);
- За каждую неделю опоздания балл за задание снижается в 2 раза. Задание не принимается после его разбора или объявления об этом.

**Задача.** Пусть проводится эксперимент по угадыванию стороны выпадания честной монеты. Известно, что оракул прав с вероятностью  $p_1 = 0.9$ , а обычный человек с вероятностью  $p_2 = 0.5$ . Известно, что человек  $P$  оказался прав во всех  $n = 10$  бросаниях. С какой вероятностью  $P$  является оракулом?

**Совместная вероятность:**  $P(A \cdot B) = P(A)P(B|A) = P(B)P(A|B)$ .

**Формула Байеса:**  $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$ .

$A = [P - \text{оракул}]$ ,  $B = [n \text{ из } n]$ .

**Формула полной вероятности:**  $P(B) = P(B|A)P(A) + P(B|\bar{A})P(\bar{A})$ ,

$P(B|A) = p_1^n$ ,  $P(B|\bar{A}) = p_2^n$ .

$P(A|B) = \frac{P(A)p_1^n}{P(A)p_1^n + (1 - P(A))p_2^n}$ .

**Вопрос:** Как определить  $P(A)$ ?

## Определение априорного распределения

**Идея:** из предыдущего опыта и разумных соображений выбрать  $P(A)$ .

**Пример 1:** отсутствие опыта (оракул и обычный неразличимы)

→  $P(A) = 0.5$

**Пример 2:** оракулов не бывает ( $P(A) = 0$ ) или "я ни одного за свою жизнь не видел, но может, бывают" ( $P(A) = 0.0001$ ).

**Вопрос:** только ли нашим опытом определяется априорное распределение? Может ли постановка эксперимента повлиять на априорное распределение?

**Пример 3:** Пусть человек  $P$  хочет выглядеть оракулом в прогнозе результатов двухпартийных выборов между партиями "прелестных" и "замечательных". На первых выборах  $P$  выбирает 1024 человека (вероятно, известных и уважаемых) и рассылает 512 из них прогноз «выиграют прелестные», а 512 оставшихся - «выиграют замечательные». Пусть выиграли "замечательные". Тогда 512 людей знают, что  $P$  верно предсказал исход выборов. Далее история повторяется 9 раз. Тогда в конце есть 1 человек, который знает, что  $P$  угадал результат 10 выборов из 10.

# Определение априорного распределения (продолжение)

## Случай 1 (честный эксперимент, нет selection bias)

Пусть  $P(A) = 0.0001$  (основано на предыдущем опыте), тогда

$$P_n(A|B) = \frac{P(B|A)P(A)}{P(B)} = \frac{0.0001 \cdot 0.9^n}{0.0001 \cdot 0.9^n + 0.9999 \cdot 0.5^n}.$$

$$P_{10}(A|B) = 0.0345; P_{20}(A|B) = 0.9273, P_{30}(A|B) = 0.9998.$$

**Замечание:** для  $P(A) = 0.5$   $P_{10}(A|B) = 0.9972$ ;  $P_{20}(A|B) = 0.999992$ .

## Случай 2 (предварительно выбран лучший из 100 случайно взятых людей по $k = 100$ попыткам)

**Вопрос:** сколько оракулов среди этих 100 случайно выбранных людей?

а)  $P(\tilde{A}) = 0.5$ ; б)  $P(\tilde{A}) = 0.0001$ .

Эффективно при таком эксперименте меняется  $P(A)$ :

а)  $P(A) \approx 1$ ; б)  $P(A) = 0.01$ .

$$P_n(A|B) = \frac{P(B|A)P(A)}{P(B)} = \frac{0.01 \cdot 0.9^n}{0.01 \cdot 0.9^n + 0.99 \cdot 0.5^n}.$$

$$P_{10}(A|B) = 0.7829; P_{20}(A|B) = 0.9992, P_{30}(A|B) = 0.999998.$$

# Тестирование гипотез

Пусть имеется выборка  $\{x_1, \dots, x_n\}$ .

$H_0 : p(x_1, \dots, x_n) \in P$ , где  $P$  – некоторое множество распределений.

**Требуется:** проверить гипотезу  $H_0$  на уровне значимости

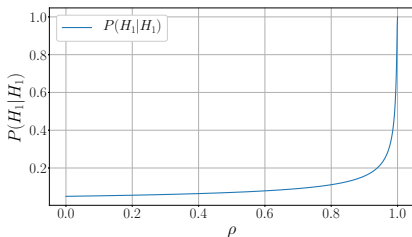
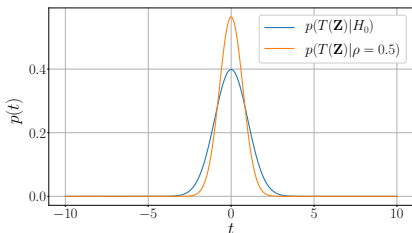
$$P(H_0 \text{ отвергнута} | H_0) \leq \alpha.$$

**Пример:** Пусть имеется выборка пар  $\mathbf{z}_i = (x_i, y_i)$ ,  $i = \overline{1, n}$ ,

$$\mathbf{z}_i \sim \mathcal{N} \left( \mathbf{z}_i | (0, 0)^\top, \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} \right).$$

**Гипотеза  $H_0$  :**  $\rho = 0$

$$T(\mathbf{Z}) = \frac{1}{\sqrt{2n}} \sum_{i=1}^n (x_i - y_i) \sim \mathcal{N}(0, 1 - \rho).$$

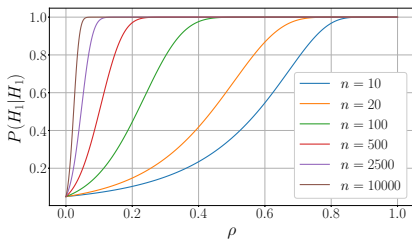
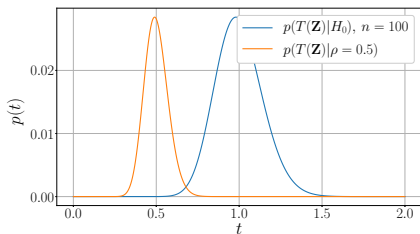


# Тестирование гипотез: продолжение

$$T(\mathbf{Z}) = \frac{1}{2n} \sum_{i=1}^n (x_i - y_i)^2 = \frac{1-\rho}{n} \xi, \quad \xi \sim \chi^2(n).$$

$$\frac{x_i - y_i}{\sqrt{2(1-\rho)}} \sim \mathcal{N}(0, 1) \implies \frac{(x_i - y_i)^2}{2(1-\rho)} \sim \chi^2(1).$$

Мощность критерия:  $P(H_0 \text{ отвергнута} | \overline{H_0})$



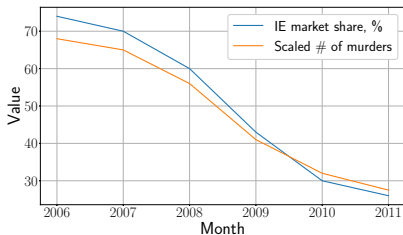
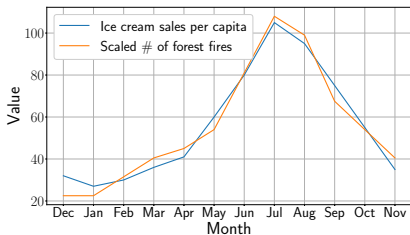
Вариант статистики:  $T(\mathbf{Z}) = \frac{1}{n} \sum_{i=1}^n x_i y_i.$



# Множественное тестирование гипотез

$H_0 = \cup_{i \in M} H_0^i$ ,  $M = \{1, \dots, m\}$ ,  $M_0 = \{i : H_0^i \text{ — верна}\}$ ,  
 $R = \{i : H_0^i \text{ — отвергнута}\}$ .

	# верных	# неверных	Всего
# принятых $H_0$	$U$	$T$	$m - R$
# отвергнутых $H_0$	$V$	$S$	$R$
Всего	$m_0$	$m - m_0$	$m$



Меры качества:

$$\text{FWER} = P(V \geq 1) \leq \alpha, \text{ FDR} = E \left( \frac{V}{R} I(R > 0) \right).$$

# Поправки для учета эффекта множественных проверок

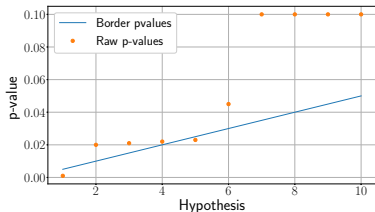
**Поправка Бонферрони.** Заменяем достигаемые уровни значимости  $p_1, \dots, p_m$  на поправленные (adjusted) уровни значимости  $\tilde{p}_1, \dots, \tilde{p}_m$ , где  $\tilde{p}_i = \min(1, mp_i)$ .

**Теорема.** Поправка Бонферрони обеспечивает  $\text{FWER} \leq \frac{m_0\alpha}{m} \leq \alpha$ .

**Доказательство.**  $\text{FWER} = P(V \geq 1) = P\left(\bigcup_{j=1}^{m_0} \{p_{i_j} \leq \alpha/m\}\right) \leq$

$$\sum_{j=1}^{m_0} P(p_{i_j} \leq \alpha/m) \leq \frac{m_0\alpha}{m} \leq \alpha.$$

**Поправка Бенджамини-Хохберга.**



Пусть  $p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(m)}$ , тогда при положительной регрессионной зависимости для  $p(p_1, \dots, p_m)$  при  $\tilde{p}_{(m)} = \min(1, p_{(m)})$ ,  $\tilde{p}_{(m-i)} = \min(1, \frac{m}{m-i} p_{(m-i)})$ ,  $\tilde{p}_{(m-i+1)}$  обеспечивается  $\text{FDR} \leq \frac{m_0}{m} \alpha$ .

# Наивный байесовский классификатор

Пусть имеется  $K$  классов  $C = \{C_1, \dots, C_K\}$  и  $\mathbf{x} \in \mathbb{R}^n$ .

Требуется построить классификатор  $f(\cdot) : \mathbb{R}^n \rightarrow C$ .

$$p(C_k|\mathbf{x}) = \frac{p(C_k)p(\mathbf{x}|C_k)}{p(\mathbf{x})} \propto p(C_k)p(\mathbf{x}|C_k).$$

$$p(C_k)p(\mathbf{x}|C_k) = p(C_k)p(x_1|C_k)p(x_2|x_1, C_k) \cdot \dots \cdot p(x_n|x_1, \dots, x_{n-1}, C_k).$$

«Наивность»:  $p(x_i|x_1, \dots, x_{i-1}, C_k) = p(x_i|C_k)$ .

$$p(C_k|\mathbf{x}) = \frac{p(C_k) \prod_{i=1}^n p(x_i|C_k)}{p(\mathbf{x})}.$$

$$\text{Классификатор: } f(\mathbf{x}) = \arg \max_k \left( p(C_k) \prod_{i=1}^n p(x_i|C_k) \right).$$

Вопросы:

- Как определить  $p(C_k)$  и  $p(x_i|C_k)$ ?
- Насколько плоха «наивность», и зачем она вводится?
- Почему классификатор такого вида?

**Вопрос:** как определить  $p(C_k)$  и  $p(x_i|C_k)$ ?

- 1 Определяем  $p(C_k)$  частотно по выборке, а для  $p(x_i|C_k)$  строим параметрическую модель и используем ML-оценки ее параметров по выборке;
- 2 Аналогично п.1, но используем непараметрическое оценивание плотностей;
- 3 Вводим априорное распределение на вектор вероятностей  $[p(C_1), \dots, p(C_K)]^\top$ , параметрическую модель на  $p(x_i|C_k)$  с неизвестными параметрами, и априорное распределение на параметры моделей.

**Вопрос:** насколько плоха «наивность», и зачем она вводится?

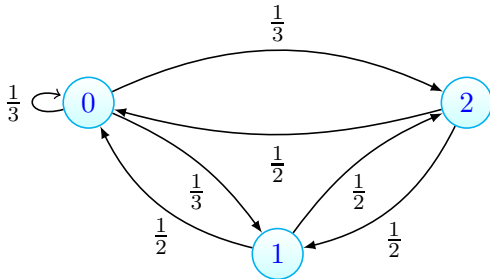
**Пример:**  $K = 2$ ,

$$p(\mathbf{x}|C_1) = \mathcal{N}\left(\mathbf{0}, \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}\right), \quad p(\mathbf{x}|C_2) = \mathcal{N}\left(\mathbf{0}, \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}\right).$$

# Наивный байесовский классификатор: продолжение

**Пример.** Классификация пользователей по интересующему атрибуту (например, полу, возрасту, достатку, интересу к некоторому товару) по истории  $x$  переходов между веб-страницами.

**Предположение:** переходы между страницами для каждого класса  $C_k$  описываются марковской цепью с некоторыми вероятностями перехода (разными для разных классов) между состояниями (веб-страницами).



$$p(C_k|\mathbf{x}) = \frac{p(C_k)p(\mathbf{x}|C_k)}{p(\mathbf{x})} \propto p(C_k)p(\mathbf{x}|C_k).$$

$$p(C_k)p(\mathbf{x}|C_k) = p(C_k)p(x_1|C_k)p(x_2|x_1, C_k) \cdot \dots \cdot p(x_n|x_1, \dots, x_{n-1}, C_k) = p(C_k)p(x_1|C_k)p(x_2|x_1, C_k) \cdot \dots \cdot p(x_n|x_{n-1}, C_k).$$

**Вопрос:** как оценить  $p(x_1|C_k)$ ,  $p(C_k)$  и  $p(x_i|x_{i-1}, C_k)$ ?

Классификатор:

$$f(\mathbf{x}) = \arg \max_k p(C_k | \mathbf{x}) = \arg \max_k \left( p(C_k) \prod_{i=1}^n p(x_i | C_k) \right).$$

**Вопрос.** Пусть  $p(C_k | \mathbf{x})$  известна точно. Какой классификатор оптимален?

Пусть  $K = 2$  и  $P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}$  есть матрица штрафа.

**Пример 1.**  $p_{11} = p_{22} = 0, p_{12} = 0, p_{21} = 1;$

**Пример 2.**  $p_{11} = p_{22} = 0, p_{12} = 1, p_{21} = 1;$

**Пример 3.**  $p_{11} = p_{22} = 0, p_{12} = 1, p_{21} = 10;$

**Пример 4.**  $p_{11} = -1, p_{22} = -100, p_{12} = 1, p_{21} = 1.$

## Положительная регрессионная зависимость.

Пусть  $\mathbf{p} = [p_1, \dots, p_m]^T$  вектор достигаемых уровней значимости в задаче множественной проверки гипотез, а  $D \subseteq \mathbb{R}^m$  – возрастающее множество ( $\mathbf{x} \in D, \mathbf{y} \geq \mathbf{x} \implies \mathbf{y} \in D$ ), тогда если  $P(\mathbf{p} \in D | p_{i_1} = x_1, \dots, p_{i_j} = x_j)$  не убывает по  $(x_1, \dots, x_j)$  для любого набора  $(i_1, \dots, i_j)$ , то имеет место положительная регрессионная зависимость для совместного распределения  $F(p_1, \dots, p_m)$ .

## Положительная регрессионная зависимость по каждому элементу из подмножества $M_0$ .

Пусть  $\mathbf{p} = [p_1, \dots, p_m]^T$  вектор достигаемых уровней значимости в задаче множественной проверки гипотез, а  $D \subseteq \mathbb{R}^m$  – возрастающее множество ( $\mathbf{x} \in D, \mathbf{y} \geq \mathbf{x} \implies \mathbf{y} \in D$ ), тогда если  $P(\mathbf{p} \in D | p_i = x_i), i \in M_0$  не убывает по  $x_i$ , то имеет место положительная регрессионная зависимость по каждому и подмножества  $M_0$  для совместного распределения  $F(p_1, \dots, p_m)$ .

- Формула Байеса и формула полной вероятности;
- Априорная вероятность и как ее выбирать; правдоподобие данных;
- Тестирование гипотез: гипотеза, уровень значимости, мощность критерия, вероятность ошибки первого и второго рода;
- Множественное тестирование гипотез: FWER, FDR, поправки Бонферрони и Бенджамини-Хохберга;
- Наивный байесовский классификатор: откуда брать  $p(C_k)$  и  $p(\mathbf{x}|C_k)$ , ограничения «наивности», учёт функции полезности.



- 1 Bishop, Christopher M. "Pattern recognition and machine learning". Springer, New York (2006).
- 2 MacKay, David JC. Bayesian methods for adaptive models. Diss. California Institute of Technology, 1992.
- 3 MacKay, David JC. "The evidence framework applied to classification networks." *Neural computation* 4.5 (1992): 720-736.
- 4 Gelman, Andrew, et al. Bayesian data analysis, 3rd edition. Chapman and Hall/CRC, 2013.
- 5 Benjamini, Yoav, and Daniel Yekutieli. "The control of the false discovery rate in multiple testing under dependency." *Annals of statistics* (2001): 1165-1188.
- 6 Дрейпер, Норман Р. Прикладной регрессионный анализ. Рипол Классик, 2007.
- 7 Кобзарь, Александр Иванович. Прикладная математическая статистика. Физматлит, 2006.