

# Сопряженные априорные распределения

---

Сергей Николенко



Академия больших данных MADE — VK

31 января 2022 г.

---

*Random facts:*

- 31 января 1606 г. лидеры Порохового заговора были hanged, drawn, and quartered; приговорённых к этой казни последовательно вешали (не до смерти), кастрировали, потрошили, четвертовали и обезглавливали; впрочем, сам Гай Фокс умудрился спрыгнуть с эшафота и удачно сломать себе шею ещё на первом этапе
- 31 января 1714 г. Пётр I учредил «Государев кабинет», будущую Кунсткамеру, а также издал указ об обучении дворянских детей «цыфири и геометрии»; «не постигшим основ знаний» запрещалось жениться
- 31 января 1968 г. была провозглашена независимость Науру, самой маленькой независимой республики на Земле (21.3 км<sup>2</sup>, 10000 человек)
- 31 января 1990 г. на Пушкинской площади в Москве открылся первый (и единственный) McDonald's в СССР
- 31 января 2020 г. Великобритания потеряла представительство и право голоса в органах власти ЕС; в полночь с 31 января на 1 февраля было прекращено членство Великобритании в ЕС, продолжавшееся с 1973 года


## Еще немного про вероятности

---

# Зачем нужны вероятностные модели

- Зачем нужны вероятностные модели? Апостериорные вероятности помогают:
  - добавить опцию «я не знаю»;
  - минимизировать риск, учесть разные веса ошибок;
  - перебалансировать классы или по-другому добавить априорные вероятности;
  - комбинировать модели (например, наивным Байесом)...
- Понимание смысла помогает:
  - понимать границы применимости, предположения, которые делают модели;
  - обобщать и переносить идеи моделей на другие задачи;
  - содержательно интерпретировать происходящее.

- (1) Прокурор указал, что O.J. Simpson уже бил жену в прошлом. Адвокат ответил: «Убивают только одну из 2500 женщин, подвергавшихся семейному насилию, так что это вообще нерелевантно». Суд согласился с адвокатом; верно ли это рассуждение?
- (2) У Салли Кларк погибли два младенца; прокурор указал, что вероятность двух случаев SIDS в одной семье, которую он получил из статистики одиночных случаев, — около 1 из 73 миллионов; в чём он не прав?



# Байесовский вывод для монетки

---

- Итак, в статистике обычно ищут *гипотезу максимального правдоподобия* (maximum likelihood):

$$\theta_{ML} = \arg \max_{\theta} p(D | \theta).$$

- В байесовском подходе ищут *апостериорное распределение* (posterior)

$$p(\theta|D) \propto p(D|\theta)p(\theta)$$

и, возможно, *максимальную апостериорную гипотезу* (maximum a posteriori):

$$\theta_{MAP} = \arg \max_{\theta} p(\theta | D) = \arg \max_{\theta} p(D | \theta)p(\theta).$$

## Постановка задачи

- Простая задача вывода: дана нечестная монетка, она подброшена  $N$  раз, имеется последовательность результатов падения монетки. Надо определить её «нечестность» и предсказать, чем она выпадет в следующий раз.

## Постановка задачи

- Если у нас есть вероятность  $p_h$  того, что монетка выпадет решкой (вероятность орла  $p_t = 1 - p_h$ ), то вероятность того, что выпадет последовательность  $s$ , которая содержит  $n_h$  решек и  $n_t$  орлов, равна

$$p(s|p_h) = p_h^{n_h}(1 - p_h)^{n_t}.$$

- Сделаем предположение: будем считать, что монетка выпадает равномерно, т.е. у нас нет априорного знания  $p_h$ .
- Теперь нужно использовать теорему Байеса и вычислить скрытые параметры.

## Пример применения теоремы Байеса

- Правдоподобие:  $p(s|p_h) = \frac{p(s|p_h)p(p_h)}{p(s)}$ .
- Здесь  $p(p_h)$  следует понимать как непрерывную случайную величину, сосредоточенную на интервале  $[0, 1]$ , коей она и является. Наше предположение о равномерном распределении в данном случае значит, что априорная вероятность  $p(p_h) = 1, p_h \in [0, 1]$  (т.е. априори мы не знаем, насколько нечестна монетка, и предполагаем это равновероятным). А  $p(s|p_h)$  мы уже знаем.
- Итого получается:

$$p(p_h|s) = \frac{p_h^{n_h}(1 - p_h)^{n_t}}{p(s)}.$$

## Пример применения теоремы Байеса

- Итого получается:

$$p(p_h|s) = \frac{p_h^{n_h}(1-p_h)^{n_t}}{p(s)}.$$

- $p(s)$  можно подсчитать как

$$\begin{aligned} p(s) &= \int_0^1 p_h^{n_h}(1-p_h)^{n_t} dp_h = \\ &= \frac{\Gamma(n_h+1)\Gamma(n_t+1)}{\Gamma(n_h+n_t+2)} = \frac{n_h!n_t!}{(n_h+n_t+1)!}, \end{aligned}$$

но найти  $\arg \max_{p_h} p(p_h | s) = \frac{n_h}{n_h+n_t}$  можно и без этого.

## Пример применения теоремы Байеса

- Итого получается:

$$p(p_h|s) = \frac{p_h^{n_h}(1-p_h)^{n_t}}{p(s)}.$$

- Но это ещё не всё. Чтобы предсказать следующий исход, надо найти  $p(\text{heads}|s)$ :

$$\begin{aligned} p(\text{heads}|s) &= \int_0^1 p(\text{heads}|p_h)p(p_h|s)dp_h = \\ &= \int_0^1 \frac{p_h^{n_h+1}(1-p_h)^{n_t}}{p(s)} dp_h = \\ &= \frac{(n_h+1)!n_t!}{(n_h+n_t+2)!} \cdot \frac{(n_h+n_t+1)!}{n_h!n_t!} = \frac{n_h+1}{n_h+n_t+2}. \end{aligned}$$

- Получили правило Лапласа.

# Пример применения теоремы Байеса

- Итого получается:

$$p(p_h|s) = \frac{p_h^{n_h}(1-p_h)^{n_t}}{p(s)}.$$

- Это была иллюстрация двух основных задач байесовского вывода:
  1. найти апостериорное распределение на гипотезах/параметрах:

$$p(\theta | D) \propto p(D|\theta)p(\theta)$$

(и/или найти гипотезу максимального правдоподобия  $\arg \max_{\theta} p(\theta | D)$ );

2. найти апостериорное распределение исходов дальнейших экспериментов:

$$p(x | D) \propto \int_{\theta \in \Theta} p(x | \theta)p(D|\theta)p(\theta)d\theta.$$

# Сопряжённые априорные распределения

---

- Напоминаю, что основная наша задача – как обучить параметры распределения и/или предсказать следующие его точки по имеющимся данным.
- В байесовском выводе участвуют:
  - $p(x | \theta)$  – правдоподобие данных;
  - $p(\theta)$  – априорное распределение;
  - $p(x) = \int_{\Theta} p(x | \theta)p(\theta)d\theta$  – маргинальное правдоподобие;
  - $p(\theta | x) = \frac{p(x|\theta)p(\theta)}{p(x)}$  – апостериорное распределение;
  - $p(x' | x) = \int_{\Theta} p(x' | \theta)p(\theta | x)d\theta$  – предсказание нового  $x'$ .
- Задача обычно в том, чтобы найти  $p(\theta | x)$  и/или  $p(x' | x)$ .

# Априорные распределения

- Когда мы проводим байесовский вывод, у нас, кроме правдоподобия, должно быть ещё *априорное распределение* (prior distribution) по всем возможным значениям параметров.
- Мы раньше к ним специально не присматривались, но они очень важны.
- Задача байесовского вывода – как подсчитать  $p(\theta | x)$  и/или  $p(x' | x)$ .
- Но чтобы это сделать, сначала надо выбрать  $p(\theta)$ . Как выбирать априорные распределения?

# Сопряжённые априорные распределения

- Разумная цель: давайте будем выбирать распределения так, чтобы они оставались такими же и *a posteriori*.
- До начала вывода есть априорное распределение  $p(\theta)$ .
- После него есть какое-то новое апостериорное распределение  $p(\theta | x)$ .
- Я хочу, чтобы  $p(\theta | x)$  тоже имело тот же вид, что и  $p(\theta)$ , просто с другими параметрами.

# Сопряжённые априорные распределения

- Не слишком формальное определение: семейство распределений  $p(\theta | \alpha)$  называется семейством *сопряжённых априорных распределений* для семейства правдоподобий  $p(x | \theta)$ , если после умножения на правдоподобие апостериорное распределение  $p(\theta | x, \alpha)$  остаётся в том же семействе:  $p(\theta | x, \alpha) = p(\theta | \alpha')$ .
- $\alpha$  называются *гиперпараметрами* (hyperparameters), это «параметры распределения параметров».
- Тривиальный пример: семейство всех распределений будет сопряжённым чему угодно, но это не очень интересно.

- Разумеется, вид хорошего априорного распределения зависит от вида распределения собственно данных,  $p(x | \theta)$ .
- Сопряжённые априорные распределения подсчитаны для многих распределений, мы приведём несколько примеров.

- Каким будет сопряжённое априорное распределение для бросания нечестной монетки (испытаний Бернулли)?
- Ответ: это будет бета-распределение; плотность распределения нечестности монетки  $\theta$

$$p(\theta \mid \alpha, \beta) = \frac{\theta^{\alpha-1}(1-\theta)^{\beta-1}}{B(\alpha, \beta)}.$$

# Испытания Бернулли

- Плотность распределения нечестности монетки  $\theta$

$$p(\theta | \alpha, \beta) = \frac{\theta^{\alpha-1}(1-\theta)^{\beta-1}}{B(\alpha, \beta)}.$$

- Тогда, если мы посэмплируем монетку, получив  $s$  орлов и  $f$  решек, получится

$$p(s, f | \theta) = \binom{s+f}{s} \theta^s (1-\theta)^f, \text{ и}$$

$$\begin{aligned} p(\theta | s, f) &= \frac{\binom{s+f}{s} \theta^{s+\alpha-1} (1-\theta)^{f+\beta-1} / B(\alpha, \beta)}{\int_0^1 \binom{s+f}{s} x^{s+\alpha-1} (1-x)^{f+\beta-1} / B(\alpha, \beta) dx} = \\ &= \frac{\theta^{s+\alpha-1} (1-\theta)^{f+\beta-1}}{B(s+\alpha, f+\beta)}. \end{aligned}$$

# Испытания Бернулли

- Итого получается, что сопряжённое априорное распределение для параметра нечестной монетки  $\theta$  – это


$$p(\theta | \alpha, \beta) \propto \theta^{\alpha-1}(1 - \theta)^{\beta-1}.$$

- После получения новых данных с  $s$  орлами и  $f$  решками гиперпараметры меняются на

$$p(\theta | s + \alpha, f + \beta) \propto \theta^{s+\alpha-1}(1 - \theta)^{f+\beta-1}.$$

- На этом этапе можно забыть про сложные формулы и выводы, получилось очень простое правило обучения (под обучением теперь понимается изменение гиперпараметров).

# Бета-распределение



# Мультиномиальное распределение

- Простое обобщение: рассмотрим мультиномиальное распределение с  $n$  испытаниями,  $k$  категориями и по  $x_i$  экспериментов дали категорию  $i$ .
- Параметры  $\theta_i$  показывают вероятность попасть в категорию  $i$ :

$$p(x | \theta) = \binom{n}{x_1, \dots, x_k} \theta_1^{x_1} \theta_2^{x_2} \dots \theta_k^{x_k}.$$

- Сопряжённым априорным распределением будет распределение Дирихле:

$$p(\theta | \alpha) \propto \theta_1^{\alpha_1-1} \theta_2^{\alpha_2-1} \dots \theta_k^{\alpha_k-1}.$$



- Сопряжённым априорным распределением будет распределение Дирихле:

$$p(\theta | \alpha) \propto \theta_1^{\alpha_1-1} \theta_2^{\alpha_2-1} \dots \theta_k^{\alpha_k-1}.$$


**Упражнение.** Докажите, что при получении данных  $x_1, \dots, x_k$  гиперпараметры изменятся на

$$p(\theta | x, \alpha) = p(\theta | x + \alpha) \propto \theta_1^{x_1+\alpha_1-1} \theta_2^{x_2+\alpha_2-1} \dots \theta_k^{x_k+\alpha_k-1}.$$


# Распределение Дирихле



$\{\alpha_k\} = 0.1$



$\{\alpha_k\} = 1$



$\{\alpha_k\} = 10$

# Линейная регрессия

---

# Метод наименьших квадратов

- Линейная регрессия: рассмотрим линейную функцию

$$y(\mathbf{x}, \mathbf{w}) = w_0 + \sum_{j=1}^p x_j w_j = \mathbf{x}^T \mathbf{w}, \quad \mathbf{x} = (1, x_1, \dots, x_p).$$

- Таким образом, по вектору входов  $\mathbf{x}^T = (x_1, \dots, x_p)$  мы будем предсказывать выход  $y$  как

$$\hat{y}(\mathbf{x}) = \hat{w}_0 + \sum_{j=1}^p x_j \hat{w}_j = \mathbf{x}^T \hat{\mathbf{w}}.$$

# Метод наименьших квадратов

- Как найти оптимальные параметры  $\hat{\mathbf{w}}$  по тренировочным данным вида  $(\mathbf{x}_i, y_i)_{i=1}^N$ ?
- Метод наименьших квадратов: будем минимизировать

$$\text{RSS}(\mathbf{w}) = \sum_{i=1}^N (y_i - \mathbf{x}_i^\top \mathbf{w})^2.$$

- Как минимизировать?

# Метод наименьших квадратов

- Можно на самом деле решить задачу точно – записать как

$$\text{RSS}(\mathbf{w}) = (\mathbf{y} - \mathbf{X}\mathbf{w})^\top (\mathbf{y} - \mathbf{X}\mathbf{w}),$$

где  $\mathbf{X}$  – матрица  $N \times p$ , продифференцировать по  $\mathbf{w}$ , получится

$$\hat{\mathbf{w}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y},$$

если матрица  $\mathbf{X}^\top \mathbf{X}$  невырожденная.

- Замечание:  $(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$  называется *псевдообратной матрицей Мура–Пенроуза* (Moore–Penrose pseudo-inverse) матрицы  $\mathbf{X}$ ; это обобщение понятия обратной матрицы на неквадратные матрицы.

# Байесовская регрессия

- Теперь давайте поговорим о линейной регрессии по-байесовски.
- Основное наше предположение – в том, что шум (ошибка в данных) распределён нормально, т.е. переменная  $t$ , которую мы наблюдаем, получается как

$$t = y(\mathbf{x}, \mathbf{w}) + \epsilon, \quad \epsilon \sim \mathcal{N}(0, \sigma^2).$$

Иными словами,

$$p(t \mid \mathbf{x}, \mathbf{w}, \sigma^2) = \mathcal{N}(t \mid y(\mathbf{x}, \mathbf{w}), \sigma^2).$$

- Здесь пока  $y$  – любая функция.

- Чтобы не повторять совсем уж то же самое, мы рассмотрим не в точности линейную регрессию, а её естественное обобщение – линейную модель с базисными функциями:

$$y(\mathbf{x}, \mathbf{w}) = w_0 + \sum_{j=1}^{M-1} w_j \phi_j(\mathbf{x}) = \mathbf{w}^\top \boldsymbol{\phi}(\mathbf{x})$$

( $M$  параметров,  $M - 1$  базисная функция,  $\phi_0(\mathbf{x}) = 1$ ).

- Базисные функции  $\phi_i$  – это, например:
  - результат feature extraction;
  - расширение линейной модели на нелинейные зависимости (например,  $\phi_j(x) = x^j$ );
  - локальные функции, которые существенно не равны нулю только в небольшой области (например, гауссовские базисные функции  $\phi_j(\mathbf{x}) = e^{-\frac{(x-\mu_j)^2}{2s^2}}$ );
  - ...

# Байесовская регрессия

- Рассмотрим набор данных  $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  со значениями  $\mathbf{t} = \{t_1, \dots, t_N\}$ .
- Будем предполагать, что данные взяты независимо по одному и тому же распределению:

$$p(\mathbf{t} | \mathbf{X}, \mathbf{w}, \sigma^2) = \prod_{n=1}^N \mathcal{N}(t_n | \mathbf{w}^\top \phi(\mathbf{x}_n), \sigma^2).$$

- Прологарифмируем (опустим  $\mathbf{X}$ , т.к. по нему всегда условная вероятность будет):

$$\ln p(\mathbf{t} | \mathbf{w}, \sigma^2) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{n=1}^N (t_n - \mathbf{w}^\top \phi(\mathbf{x}_n))^2.$$

- Прологарифмируем (опустим  $\mathbf{X}$ , т.к. по нему всегда условная вероятность будет):

$$\ln p(\mathbf{t} | \mathbf{w}, \sigma^2) = -\frac{N}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{n=1}^N (t_n - \mathbf{w}^\top \phi(\mathbf{x}_n))^2.$$

- И вот мы получили, что для максимизации правдоподобия по  $\mathbf{w}$  нам нужно как раз минимизировать среднеквадратичную ошибку!

$$\nabla_{\mathbf{w}} \ln p(\mathbf{t} | \mathbf{w}, \sigma^2) = \frac{1}{\sigma^2} \sum_{n=1}^N (t_n - \mathbf{w}^\top \phi(\mathbf{x}_n)) \phi(\mathbf{x}_n).$$

- Решая систему уравнений  $\nabla \ln p(\mathbf{t} | \mathbf{w}, \sigma^2) = 0$ , получаем то же самое, что и раньше:

$$\mathbf{w}_{ML} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{t}.$$

- Здесь  $\Phi = (\phi_j(\mathbf{x}_i))_{i,j}$ .

- Теперь можно и относительно  $\sigma^2$  максимизировать правдоподобие; получим

$$\sigma_{ML}^2 = \frac{1}{N} \sum_{n=1}^N (t_n - \mathbf{w}_{ML}^T \phi(\mathbf{x}_n))^2,$$

т.е. как раз выборочная дисперсия имеющихся данных вокруг предсказанного значения.

Спасибо!

Спасибо за внимание!