

# Занятие четвертое. О непараметрическом оценивании, о том как хорошо оценивать и как оценивать еще лучше, о том, как бутстрэпить без знания распределения

## Общие слова

Мы привыкли рассматривать именно параметрическую модель  $X_i \sim F_\theta$ . С другой стороны, начиная исследование, мы часто не имеем никакой предварительной информации о распределении. В таком случае более подходящей является непараметрическая модель  $X_i \sim F$ , а оценки мы будем строить для  $F(x)$ ,  $EX_1$  или другого показателя, связанного с моделью. При этом все мы сохраняем определения состоятельности, несмещенности и асимптотическое нормальность, просто не апеллируем в них к параметризации модели

**Пример 1.** Так  $\bar{X} = (X_1 + \dots + X_n)/n$  будет несмещенной состоятельной оценкой  $EX_1$  и в непараметрической модели, а при  $EX_1^2 < \infty$  еще и асимптотически нормальной. Аналогично  $S_0^2 = \sum_{i=1}^n (X_i - \bar{X})^2 / (n - 1)$  будет несмещенной состоятельной оценкой дисперсии, а при  $EX_1^4 < \infty$  асимптотически нормальной.

**Как оценивать функции распределения и как с помощью этого строить непараметрические оценки?**

Итак, давайте начнем с того, что оценим функцию распределения и плотность нашей выборки  $X_i$ . Достаточно хорошей (несмещенной состоятельной и асимптотически нормальной) оценкой функции распределения в конкретной точке  $x$  является эмпирическая функция распределения

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n I_{X_i \leq x}$$

**Вопрос 1.** Почему она обладает всеми свойствами 1)-3)?

**Вопрос 2.** Показать, что  $\hat{F}_n$  — ОМП для ф.р. в непараметрической модели.

Теорема Гливленко-Кантелли утверждает, что оценка состоятельна как оценка всей функции распределения, даже более,  $\hat{F}_n \rightarrow F$  п.н. по равномерной норме. Отсюда можно сделать вывод, что  $f(\hat{F}_n) \rightarrow f(F)$  для любого непрерывного (по равномерной норме) функционала  $f$  от ф.р.  $F$  сходится п.н. Кроме того, полезна также явная оценка, так называемое неравенство Дворецкого-Кифера-Вольфовица

$$P(\|\hat{F}_n - F\| > \varepsilon) \leq 2e^{-2n\varepsilon^2}, \quad \varepsilon > 0.$$

**Упражнение 1.** Построить доверительное множество для ф.р. распределения Коши с помощью неравенства Д.-К.-В.

Вполне естественно, таким образом, исследуя функционалы  $f(F)$ , оценивать их  $f(\hat{F}_n)$ .

**Пример 2.** Для оценки математического ожидания  $EX_1 = \int_{\mathbb{R}} x dF(x)$ , а дисперсии  $DX_1 = \int_{\mathbb{R}} x^2 dF(x) - (\int_{\mathbb{R}} x dF(x))^2$  возьмем

$$\hat{\theta}_1 = \int_{\mathbb{R}} x d\hat{F}_n(x), \quad \hat{\theta}_2 = \int_{\mathbb{R}} x^2 d\hat{F}_n(x) - \hat{\theta}_1^2.$$

**Вопрос 3.** Почему  $\hat{\theta}_1 = \bar{X}$ ,  $\hat{\theta}_2 = S^2$ ?

**Упражнение 2.** Построить оценку для асимметрии:  $E(X - EX)^3 DX^{-3/2}$ .

**Как оценить плотность?**

С той же целью полезно бывает оценить плотность. Простейшей оценкой является гистограмма, с которой вы и так хорошо знакомы. В целом, гистограмма неплохая оценка, стремящаяся с ростом числа наблюдений и уменьшением ширины интервалов разбиения к истинному значению плотности, но она кусочно-постоянна. Хорошим методом получения непрерывной оценки для плотности является так называемая *ядерная оценка*. Назовем ядерной неотрицательную функцию  $K(x)$ , т.ч.  $\int_{\mathbb{R}} K(x) dx = 1$ ,  $\int_{\mathbb{R}} xK(x) dx = 0$ ,  $\int_{\mathbb{R}} x^2 K(x) dx > 0$ . В роли  $K(x)$  сходится любая плотность. Назовем ядерной оценкой плотности

$$\hat{f}_n(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h_n} K\left(\frac{x - X_i}{h_n}\right),$$

где  $K$  — ядерная функция, а  $h_n$  — ширина окна сглаживания. Если  $f$  — непрерывна,  $h_n \rightarrow 0$ ,  $nh_n \rightarrow \infty$ , то  $\hat{f}_n(x)$  сходится по вероятности к  $f(x)$ . При этом  $E(\hat{f}_n(x) - f(x))^2$  есть  $O(h_n^4) + O\left(\frac{1}{nh_n}\right) + O\left(\frac{1}{n}\right)$ . Таким образом, наилучший порядок  $h$  есть  $O(n^{1/5})$ . Более точная формула для  $h$ , дающего минимум квадратичного отклонения

$$h^* = \left( \frac{\int K(x)^2 dx}{n \left( \int x^2 K(x) dx \right)^2 \int (f''(x))^2 dx} \right)^{1/5}.$$

Эта формула не вполне удовлетворительна для применения, поскольку использует неизвестное нам  $f''(x)$ , но дает представить порядок  $h^*$ . Функция  $K$ , как мы видим, не влияет на порядок сходимости. Часто берут в роли  $K(x)$  равномерную на  $[-1, 1]$  плотность (прямоугольное ядро), стандартную нормальную плотность (гауссово ядро) или  $3(1 - x^2)I_{|x| \leq 1}/4$  (ядро Епанчикова).

**Упражнение 3.** Оцените а) стандартную нормальную плотность на выборке размера 100. б) смесь из трех нормальных плотностей  $\mathcal{N}(0, 1)$ ,  $\mathcal{N}(6, 1)$ ,  $\mathcal{N}(-3, 1)$  с равными вероятностями. Что происходит при уменьшении ширины окна  $h$ ?

Оценкой кросс-валидацией для оценки плотности  $\hat{f}_n$  называют

$$\hat{J}(h) = \int \hat{f}_n^2 dx - \frac{2}{n} \hat{f}_{n,i}(X_i),$$

где  $\hat{f}_{n,i}$  — оценка, построенная по выборке с исключенным  $X_i$ . Для ядерной оценки ее можно найти по формуле

$$\hat{J}(h) = \frac{1}{hn^2} \sum_i \sum_j K^* \left( \frac{X_i - X_j}{h} \right) + \frac{2}{nh} K(0) + O\left(\frac{1}{n^2}\right).$$

$K^* = K * K - 2K$ ,  $*$  — свертка. Это несмещенная оценка кросс-валидации  $-\int (\hat{f}_n(x) - f(x))^2 dx$ , расстояния между плотностью и оценкой в  $L^2$ . С помощью оценки кросс-валидации удобно измерять качество приближения. В частности, с ее помощью можно откалибровать ширину  $h$ .

С помощью оценки для плотности можно строить оценки  $\int g(x) \hat{f}_n(x) dx$  для функционалов вида  $\int g(x) f(x) dx$ . Например, для математического ожидания мы получим оценку

$$\int_{\mathbb{R}} x \hat{f}_n(x) dx = \bar{X}$$

**Вопрос 4.** Почему верно последнее тождество?

**Бутстреп или как прикрывать свои недостатки в непараметрическом случае**

Если мы захотим получать несмещенные оценки, то нам, как и прежде, будет полезна процедура бутстрепинга. Однако, раньше мы брали выборку из распределения с оцениваемым параметром, то теперь мы будем брать выборку из распределения с оцениваемой функцией распределения. Если в качестве оценки для функции распределения используется эмпирическая функция распределения, то это равносильно рассмотрению выборок  $X_1^*, \dots, X_n^*$ , взятых из нашего распределения с возвращением.

Таким образом, если мы рассматриваем статистику  $f(\hat{F}_n)$  в качестве оценки  $f(F)$ , мы можем брать выборки из распределения  $\hat{F}_n$  и на основе этих выборок изучать распределение  $f(\hat{F}_n)$ , ожидая, что оно близко к распределению  $f(F)$ . В частности, мы можем исследовать смещение  $f(\hat{F}_n)$  по сравнению с  $f(F)$ , приближая его смещением  $f(\tilde{F}_n) - f(\hat{F}_n)$ ,  $\tilde{F}_n$  — ЭФР выборки из  $\hat{F}_n$ . Аналогичным образом мы можем изучать и другие параметры распределения  $f(\hat{F}_n)$ , например, дисперсию.

**Упражнение 4.** Сгенерировать выборку  $R[0, 1]$  размера 50 и оценить дисперсию оценок а)  $\bar{X}$ , б)  $MED$ .

**Упражнение 5.** Оценить ф.р. статистики  $\bar{X}$  по выборке размера 100 из распределения  $\mathcal{N}(0, 1)$ .

Предположим, что  $\hat{\theta} = f(\hat{F}_n)$  — оценка для какого-то параметра распределения  $f(F)$ . Тогда мы можем оценить ее среднее квадратичное отклонение  $S(F)$ . Рассматривая величину  $(f(\hat{F}_n) - f(F))/S(F)$ , мы можем оценить построить для нее bootstrap-интервал ширины 0.95, откуда получим доверительный

интервал для  $f(F)$ , так называемый Стьюдентовский pivotal интервал.

Можно было делать аналогичную операцию без использования  $S(F)$ , строя интервал для  $f(\hat{F}_n) - f(F)$  напрямую. Такой интервал называется pivotal

**Упражнение 6.** Испытайте метод pivotal для интервалов для а) среднего  $R[0, 1]$ , б) дисперсии  $\exp(1)$ . Рассмотренные интервалы не точные, их уровень доверия близок к  $1 - \alpha$  с ростом  $n$ , но не равен ему. Стьюдентовский интервал имеет более высокую скорость сходимости к  $1 - \alpha$ , равную  $O(1/n)$ , обычный pivotal интервал имеет скорость  $O(1/\sqrt{n})$ .

### Функции влияния и Дельта-метод в непараметрическом случае

Пусть  $f$  — функционал от ф.р. Рассмотрим  $L_{f,F}(x) = \lim_{p \rightarrow 0} (f((1-p)F + p\delta_x) - f(F))/p$ , где  $\delta_x$  — ф.р. константы  $x$ . Иначе говоря, мы рассматриваем насколько изменится функционал, если в данные добавлять некоторый процент данных со значением  $x$ .  $L_{f,F}$  называется функцией влияния.

**Вопрос 5.** Пусть  $f(F) = \int_{\mathbb{R}} a(x)dF(x)$ . Найти  $L_{f,F}$ .

Оказывается, что верна такая теорема

$$\sqrt{n} \frac{T(\hat{F}_n) - T(F)}{\tau} \rightarrow Z \sim \mathcal{N}(0, 1),$$

где  $\tau^2 = \int_{\mathbb{R}} L_{T,F}(x)^2 dF(x)$ . Кроме того,

$$\sqrt{n} \frac{T(\hat{F}_n) - T(F)}{\hat{\tau}} \rightarrow Z \sim \mathcal{N}(0, 1),$$

где  $\hat{\tau} = \frac{1}{n} \sum_{i=1}^n L_{T,\hat{F}_n}^2(X_i)$ . Это некоторый аналог Дельта-метода — мы видим, как меняется дисперсия величины при применении функционала  $T$ .

Нетрудно заметить, что этот метод упрощает построение Стьюдентовских интервалов, поскольку позволяет сократить расходы на подсчет дисперсии.

**Упражнение 7.** Рассматривая  $f(F) = F(1/3) - F(1/4)$ , найти для  $R[0, 1]$  с помощью функции влияния доверительный интервал для  $f(F)$  а) обычный б) бутстрэповский стьюдентовский.