

2. ТОЧЕЧНЫЕ ОЦЕНКИ

Одной из задач математической статистики (см. 1.2) является *оценка* неизвестных параметров выбранной *параметрической модели*.

Очень часто в приложениях рассматривают параметрическую модель. В этом случае предполагают, что закон распределения *генеральной совокупности* принадлежит множеству $\{F(x; \vec{\theta}): \vec{\theta} \in \Theta\}$, где вид функции распределения задан, а вектор параметров $\vec{\theta} = (\theta_1, \dots, \theta_r)$ неизвестен. Требуется найти оценку для $\vec{\theta}$ или некоторой функции от него (например, математического ожидания, дисперсии) по *случайной выборке* (X_1, \dots, X_n) из генеральной совокупности X .

Например, предположим, что масса X детали имеет нормальный закон распределения, но его параметры $\theta_1 = \mu$ и $\theta_2 = \sigma^2$ неизвестны. Нужно найти приближенное значение параметров по результатам наблюдений x_1, \dots, x_n , полученным в эксперименте (по реализации случайной выборки).

Как уже отмечалось (см. 1.2), в математической статистике существуют два вида *оценок*: *точечные* и *интервальные*. В этой главе будут рассмотрены точечные оценки, а интервальным оценкам посвящена следующая глава.

2.1. Состоятельные, несмещенные и эффективные оценки

Пусть $\vec{X}_n = (X_1, \dots, X_n)$ — *случайная выборка* из *генеральной совокупности* X , функция распределения $F(x; \theta)$ которой известна, а θ — неизвестный параметр, т.е. рассматривается *параметрическая модель* $\{F(x; \theta), \theta \in \Theta\}$ (для простоты изложения будем считать пока, что θ — скаляр).

Требуется построить статистику $\hat{\theta}(\vec{X}_n)$, которую можно было бы принять в качестве *точечной оценки* параметра θ .

Интуитивно ясно, что в качестве *оценки* параметра θ можно использовать различные статистики. Например, в качестве точечной оценки для $\mu = M X$ можно предложить такие статистики:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \theta^*(\vec{X}_n) = \frac{X_{(1)} + X_{(n)}}{2},$$

$$\tilde{\theta}(\vec{X}_n) = \begin{cases} \frac{1}{2} (X_{(\frac{n}{2})} + X_{(\frac{n}{2}+1)}), & n \text{ — четное;} \\ X_{(\frac{n+1}{2})}, & n \text{ — нечетное.} \end{cases}$$

Какую же из этих статистик предпочесть? В общем случае нужно дать ответ на вопрос: какими свойствами должна обладать статистика $\hat{\theta}(X_1, \dots, X_n) = \theta(\vec{X}_n)$, чтобы она была в некотором смысле наилучшей оценкой параметра θ ?

Заметим, что в дальнейшем, как правило, будем говорить об оценке параметра θ параметрической модели, хотя все сказанное можно перенести и на функцию от θ .

Определение 2.1. Статистику $\hat{\theta}(\vec{X}_n)$ называют *состоятельной оценкой* параметра $\theta \in \Theta$, если с ростом объема выборки n она сходится по вероятности к оцениваемому параметру θ , т. е.

$$\hat{\theta}(\vec{X}_n) \xrightarrow[n \rightarrow \infty]{P} \theta.$$

Иными словами, для состоятельной оценки $\hat{\theta}(\vec{X}_n)$ отклонение ее от θ на величину ε и более становится маловероятным при большом объеме выборки. Это свойство оценки является очень важным, ибо несостоятельная оценка практически бесполезна. Однако следует отметить, что на практике приходится

оценивать неизвестные параметры и при малых объемах выборки.

Естественным является то требование, при выполнении которого оценка не дает систематической погрешности в сторону завышения (или занижения) истинного значения параметра θ .

Определение 2.2. Статистику $\hat{\theta}(\vec{X}_n)$ называют **несмещенной оценкой** параметра θ , если ее математическое ожидание совпадает с θ , т.е. $M\hat{\theta}(\vec{X}_n) = \theta$ для любого фиксированного n .

Если оценка является **смещенной** (т.е. последнее равенство не имеет места), то величина смещения $b_n(\theta) = M\hat{\theta}(\vec{X}_n) - \theta$. Как мы увидим далее, смещение оценки часто можно устранить, введя соответствующую поправку.

Говорят также, что **оценка $\hat{\theta}(\vec{X}_n)$ является асимптотически несмещенной**, если при $n \rightarrow \infty$ она сходится по вероятности к своему математическому ожиданию, т.е. для любого $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P\{|\hat{\theta}(\vec{X}_n) - M\hat{\theta}(\vec{X}_n)| < \varepsilon\} = 1.$$

Предположим, что имеются две несмещенные оценки $\hat{\theta}(\vec{X}_n)$ и $\tilde{\theta}(\vec{X}_n)$ для параметра θ . Если дисперсии $D\hat{\theta}(\vec{X}_n)$ и $D\tilde{\theta}(\vec{X}_n)$ удовлетворяют условию

$$D\hat{\theta}(\vec{X}_n) \leq D\tilde{\theta}(\vec{X}_n) \quad (2.1)$$

для любого фиксированного n и $\theta \in \Theta$, то следует предпочесть оценку $\hat{\theta}(\vec{X}_n)$, поскольку разброс статистики $\hat{\theta}(\vec{X}_n)$ относительно параметра θ меньше, чем разброс статистики $\tilde{\theta}(\vec{X}_n)$.

Определение 2.3. Если в некотором классе несмещенных оценок параметра θ , имеющих конечную дисперсию, существует такая оценка $\hat{\theta}(\vec{X}_n)$, что неравенство (2.1) выполняется для всех оценок $\tilde{\theta}(\vec{X}_n)$ из этого класса, то говорят, что **оценка $\hat{\theta}(\vec{X}_n)$ является эффективной в данном классе оценок**.

Иными словами, дисперсия эффективной оценки параметра в некотором классе является минимальной среди дисперсий всех оценок из рассматриваемого класса несмещенных оценок.

Замечание 2.1. Эффективную оценку в классе всех несмещенных оценок будем называть *эффективной оценкой*, не добавляя слов „в классе несмещенных оценок“.

Замечание 2.2. В литературе по математической статистике при рассмотрении параметрических моделей вместо термина „эффективная оценка“ в классе всех несмещенных оценок используют и другие: „несмещенная оценка с минимальной дисперсией“, „оптимальная оценка“.

Теорема 2.1. Оценка

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

(выборочное среднее) математического ожидания

$$\theta = MX = \mu$$

генеральной совокупности X с конечной дисперсией является несмещенной, состоятельной и эффективной в классе всех *линейных оценок*, т.е. оценок вида

$$\tilde{\theta}(\bar{X}_n) = \sum_{i=1}^n \alpha_i X_i,$$

где $\sum_{i=1}^n \alpha_i = 1$, для произвольной параметрической модели.

◀ Напомним, что элементы X_i , $i = \overline{1, n}$, случайной выборки \vec{X}_n являются независимыми случайными величинами и распределенными так же, как и сама генеральная совокупность X . Следовательно, $MX_i = MX = \mu$ и $DX_i = DX = \sigma^2$, $i = \overline{1, n}$.

В силу свойств математического ожидания имеем

$$M\bar{X} = M\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n M X_i = \frac{1}{n} n\mu = \mu,$$

что и доказывает несмещенность оценки \bar{X} .

Далее, поскольку последовательность X_1, \dots, X_n состоит из независимых одинаково распределенных случайных величин с конечной дисперсией, то в силу закона больших чисел в форме Чебышева для любого $\varepsilon > 0$

$$P\{|\bar{X} - \mu| < \varepsilon\} \rightarrow 1, \quad n \rightarrow \infty,$$

т.е. оценка \bar{X} сходится по вероятности к оцениваемому параметру, а это и означает ее состоятельность.

Покажем теперь, что

$$D\tilde{\theta}(\vec{X}_n) = D \sum_{i=1}^n \alpha_i X_i = \sum_{i=1}^n D(\alpha_i X_i) = \sum_{i=1}^n \alpha_i^2 D X_i = \sigma^2 \sum_{i=1}^n \alpha_i^2$$

достигает своего минимального значения при $\alpha_i = 1/n$, т.е. когда оценка $\tilde{\theta}(\vec{X}_n) = \bar{X}$, что и означает эффективность оценки \bar{X} в классе линейных оценок.

Для отыскания условного минимума функции

$$g(\alpha_1, \dots, \alpha_n) = \sum_{i=1}^n \alpha_i^2$$

при ограничении

$$\sum_{i=1}^n \alpha_i = 1$$

составим функцию Лагранжа

$$L(\alpha_1, \dots, \alpha_n; \lambda) = \sum_{i=1}^n \alpha_i^2 + \lambda \left(\sum_{i=1}^n \alpha_i - 1 \right),$$

где λ — множитель Лагранжа. Необходимые условия существования условного экстремума имеют вид

$$\begin{cases} \frac{\partial L}{\partial \alpha_i} = 2\alpha_i + \lambda = 0, & i = \overline{1, n}, \\ \frac{\partial L}{\partial \lambda} = \sum_{i=1}^n \alpha_i - 1 = 0. \end{cases}$$

Решив эту систему, находим $\lambda = -2/n$ и $\alpha_i = 1/n$, $i = \overline{1, n}$, и убеждаемся в том, что при этих значениях аргументов функция $g(\alpha_1, \dots, \alpha_n)$ имеет условный минимум. ►

Замечание 2.3. Можно доказать состоятельность оценки \bar{X} для математического ожидания (если оно существует), не предполагая существования конечной дисперсии DX . #

Свойства выборочной дисперсии

$$\hat{\sigma}^2(\vec{X}_n) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

отражены в следующей теореме.

Теорема 2.2. Если \vec{X}_n — случайная выборка из генеральной совокупности X с конечной дисперсией σ^2 , то выборочная дисперсия $\hat{\sigma}^2(\vec{X}_n)$ — смещенная состоятельная оценка σ^2 .

◀ Действительно,

$$\begin{aligned} \hat{\sigma}^2(\vec{X}_n) &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n \left((X_i - \mu) - (\bar{X} - \mu) \right)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - 2(\bar{X} - \mu) \frac{1}{n} \sum_{i=1}^n (X_i - \mu) + \frac{1}{n} \sum_{i=1}^n (\bar{X} - \mu)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - 2(\bar{X} - \mu)^2 + \frac{1}{n} n (\bar{X} - \mu)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2 - (\bar{X} - \mu)^2. \end{aligned}$$

Используя свойства математического ожидания, получим

$$\begin{aligned} M\hat{\sigma}^2(\bar{X}_n) &= \frac{1}{n} M \sum_{i=1}^n (X_i - \mu)^2 - M(\bar{X} - \mu)^2 = \\ &= \frac{1}{n} \sum_{i=1}^n M(X_i - \mu)^2 - M(\bar{X} - \mu)^2 = \frac{1}{n} \sum_{i=1}^n D X_i - D \bar{X} = \\ &= \frac{1}{n} n \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2 \neq \sigma^2, \end{aligned}$$

т.е. $\hat{\sigma}^2(\bar{X}_n)$ — смещенная оценка для дисперсии.

Докажем, что $\hat{\sigma}^2(\bar{X}_n)$ является состоятельной оценкой. Доказательство проведем для случая, когда генеральная совокупность имеет моменты до четвертого порядка включительно и нулевое математическое ожидание. Последнее допущение не является принципиальным, так как дисперсия не зависит от значения ее математического ожидания (от точки отсчета). Применяя второе неравенство Чебышева, имеем

$$P \left\{ \left| \hat{\sigma}^2(\bar{X}_n) - \frac{n-1}{n} \sigma^2 \right| < \varepsilon \right\} \geq 1 - \frac{D\hat{\sigma}^2(\bar{X}_n)}{\varepsilon^2}.$$

Найдем дисперсию $\hat{\sigma}^2(\bar{X}_n)$:

$$\begin{aligned} \hat{\sigma}^2(\bar{X}_n) &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i\bar{X} + \bar{X}^2) = \\ &= \frac{1}{n} \sum_{i=1}^n X_i^2 - 2\bar{X} \frac{1}{n} \sum_{i=1}^n X_i + \frac{1}{n} n \bar{X}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2. \end{aligned}$$

Воспользуемся известным равенством, согласно которому дисперсия скалярной случайной величины равна математическому ожиданию ее квадрата минус квадрат ее математического ожидания:

$$D\hat{\sigma}^2(\bar{X}_n) = M\left(\hat{\sigma}^2(\bar{X}_n)\right)^2 - \left(M\hat{\sigma}^2(\bar{X}_n)\right)^2.$$

Поскольку

$$\begin{aligned} (\hat{\sigma}^2(\bar{X}_n))^2 &= \left(\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right)^2 = \\ &= \frac{1}{n^2} \left(\sum_{i=1}^n X_i^2 \right)^2 - 2\bar{X}^2 \frac{1}{n} \sum_{i=1}^n X_i^2 + \bar{X}^4, \end{aligned}$$

закключаем, что

$$M(\hat{\sigma}^2(\bar{X}_n))^2 = \frac{1}{n^2} M\left(\sum_{i=1}^n X_i^2\right)^2 - \frac{2}{n} M\left(\bar{X}^2 \sum_{i=1}^n X_i^2\right) + M\bar{X}^4.$$

Получим выражения для математических ожиданий трех слагаемых, используя свойства математического ожидания и независимость случайных величин X_i , $i = \overline{1, n}$, каждая из которых имеет нулевое математическое ожидание и дисперсию σ^2 . Для первого слагаемого имеем

$$\begin{aligned} M\left(\sum_{i=1}^n X_i^2\right)^2 &= M\left(\sum_{i=1}^n X_i^4 + \sum_{\substack{i,j=1 \\ i \neq j}}^n X_i^2 X_j^2\right) = \sum_{i=1}^n M X_i^4 + \\ &+ \sum_{\substack{i,j=1 \\ i \neq j}}^n M X_i^2 M X_j^2 = \sum_{i=1}^n \overset{\circ}{m}_4 + \sum_{\substack{i,j=1 \\ i \neq j}}^n \sigma^2 \sigma^2 = n \overset{\circ}{m}_4 + n(n-1)\sigma^4. \end{aligned}$$

Чтобы вычислить второе слагаемое, преобразуем его:

$$\begin{aligned} M\left(\bar{X}^2 \sum_{i=1}^n X_i^2\right) &= \frac{1}{n^2} M\left(\left(\sum_{j=1}^n X_j\right)^2 \sum_{i=1}^n X_i^2\right) = \\ &= \frac{1}{n^2} M\left(\left(\sum_{j=1}^n X_j^2 + \sum_{\substack{j,k=1 \\ j \neq k}}^n X_j X_k\right) \sum_{i=1}^n X_i^2\right) = \\ &= \frac{1}{n^2} M\left(\sum_{j=1}^n X_j^2 \sum_{i=1}^n X_i^2\right) + \frac{1}{n^2} \left(\sum_{i=1}^n X_i^2 \sum_{\substack{j,k=1 \\ j \neq k}}^n X_j X_k\right). \end{aligned}$$

Так как

$$M \sum_{\substack{i=1 \\ i \neq k}}^n X_i X_k = \sum_{\substack{i=1 \\ i \neq k}}^n M X_i M X_k = 0, \quad k = 1, n,$$

то

$$\begin{aligned} M \sum_{i=1}^n X_i^2 \sum_{\substack{j,k=1 \\ j \neq k}}^n X_j X_k &= \\ &= \sum_{\substack{i,j,k=1 \\ i \neq j, i \neq k, j \neq k}}^n M(X_i^2 X_j X_k) + 2 \sum_{\substack{i,j=1 \\ i \neq j}}^n M(X_i^3 X_j) = 0. \end{aligned}$$

Следовательно,

$$\begin{aligned} M\left(\bar{X}^2 \sum_{i=1}^n X_i^2\right) &= \frac{1}{n^2} M\left(\sum_{j=1}^n X_j^2 \sum_{i=1}^n X_i^2\right) = \\ &= \frac{1}{n^2} M\left(\sum_{i=1}^n X_i^4 + \sum_{\substack{i,j=1 \\ i \neq j}}^n X_i^2 X_j^2\right) = \frac{1}{n^2} (n \overset{\circ}{m}_4 + n(n-1)\sigma^4). \end{aligned}$$

Аналогично можно показать, что

$$M\bar{X}^4 = \frac{1}{n^4} \left(\sum_{i=1}^n X_i\right)^4 = \frac{\overset{\circ}{m}_4 + 3(n-1)\sigma^4}{n^3}.$$

В итоге получаем

$$\begin{aligned} M(\hat{\sigma}^2(\bar{X}_n))^2 &= \frac{n \overset{\circ}{m}_4 + n(n-1)\sigma^4}{n^2} - \frac{2(n \overset{\circ}{m}_4 + n(n-1)\sigma^4)}{n^3} + \\ &+ \frac{\overset{\circ}{m}_4 - 3\sigma^4}{n^3} = \sigma^4 + \frac{\overset{\circ}{m}_4 - 3\sigma^4}{n} - \frac{2 \overset{\circ}{m}_4 - 5\sigma^4}{n^2} + \frac{\overset{\circ}{m}_4 + 3(n-1)\sigma^4}{n^3}. \end{aligned}$$

Поскольку $M\hat{\sigma}^2(\bar{X}_n) = \sigma^2 - \sigma^2/n$, окончательно находим

$$D\hat{\sigma}^2(\bar{X}_n) = \frac{\overset{\circ}{m}_4 - \sigma^4}{n} - \frac{2(\overset{\circ}{m}_4 - 2\sigma^4)}{n^2} + \frac{\overset{\circ}{m}_4 - 3\sigma^4}{n^3},$$

откуда с учетом второго неравенства Чебышева и следует состоятельность оценки $\hat{\sigma}^2(\vec{X}_n)$ для дисперсии σ^2 генеральной совокупности X . ►

Замечание 2.4. Из теоремы 2.2 следует, что статистика

$$S^2(\vec{X}_n) = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

является несмещенной и состоятельной оценкой дисперсии σ^2 генеральной совокупности. Ее называют **исправленной выборочной дисперсией**.

Действительно,

$$S^2(\vec{X}_n) = \frac{n}{n-1} \cdot \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n}{n-1} \sigma^2(\vec{X}_n).$$

Имеем

$$MS^2(\vec{X}_n) = \frac{n}{n-1} M\hat{\sigma}^2(\vec{X}_n) = \frac{n}{n-1} \cdot \frac{n-1}{n} \sigma^2 = \sigma^2$$

и

$$DS^2(\vec{X}_n) = \frac{n^2}{(n-1)^2} D\hat{\sigma}^2(\vec{X}_n) \rightarrow 0$$

при $n \rightarrow \infty$, откуда и следует несмещенность и состоятельность $S^2(\vec{X}_n)$.

Отметим, что в дальнейшем ее выборочное значение будем обозначать S^2 .

Замечание 2.5. Можно доказать, что *выборочные начальные и центральные моменты* являются состоятельными оценками соответствующих моментов генеральной совокупности, если только они существуют*. Однако эти оценки, кроме X , являются смещенными.

Пример 2.1. Пусть n — число испытаний по схеме Бернулли с неизвестной вероятностью успеха θ . Рассмотрим случайную выборку (X_1, \dots, X_n) , где X_i , $i = 1, n$, — случайная величина, которая с вероятностью θ принимает значение 1 („успех“ в i -м испытании) и с вероятностью $1 - \theta$ — значение 0 („неудача“ в i -м испытании).

В качестве оценки θ возьмем относительную частоту успехов, т.е. $\hat{\theta}(\vec{X}_n) = k(\vec{X}_n)/n$, где

$$k(\vec{X}_n) = \sum_{i=1}^n X_i$$

есть суммарное число успехов в n испытаниях. Эта оценка является несмещенной, так как

$$M\hat{\theta}(\vec{X}_n) = \frac{1}{n} M(X_1 + \dots + X_n) = \frac{1}{n} (M X_1 + \dots + M X_n) = \frac{1}{n} n\theta = \theta,$$

и состоятельной, что непосредственно вытекает из закона больших чисел в форме Бернулли, согласно которому для любого $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} P \left\{ \left| \frac{k(\vec{X}_n)}{n} - \theta \right| < \varepsilon \right\} = 1. \quad \#$$

В дальнейшем в соответствии с установившейся традицией статистики $k(\vec{X}_n)$, так же как и ее значение, часто будем обозначать просто символом k . В каждом конкретном случае должно быть ясно, о чем идет речь: о случайной величине или ее реализации.

Пример 2.2. Пусть X_1, \dots, X_n — случайная выборка из генеральной совокупности X , имеющей нормальное распределение с неизвестным средним значением θ и известной дисперсией σ^2 .

Оценка $\hat{\theta} = \hat{\theta}(X_1, \dots, X_n) = X_1$ является несмещенной для θ , ибо $M X_1 = M X = \theta$, но не является состоятельной, так как, во-первых, X_1 не зависит от объема выборки и, следовательно,

ее распределение не меняется с ростом n , а во-вторых,

$$P\{|X_1 - \theta| < \varepsilon\} = \frac{2}{\sigma\sqrt{2\pi}} \int_0^\varepsilon e^{-\frac{t^2}{2\sigma^2}} dt \neq 1.$$

Пример 2.3. Имеем случайную выборку \vec{X}_n из генеральной совокупности X с равномерным законом распределения

$$p(t; \theta) = \begin{cases} \frac{1}{b-a}, & t \in [a, b], \\ 0, & t \notin [a, b], \end{cases}$$

где $b - a = l$ — известная величина, $\theta = (a + b)/2$ — неизвестный параметр.

Возьмем в качестве оценки параметра θ среднее арифметическое крайних членов вариационного ряда

$$\theta^*(\vec{X}_n) = \frac{X_{(1)} + X_{(n)}}{2}.$$

Убедимся, что $\theta^*(\vec{X}_n)$ является несмещенной оценкой параметра θ и в классе всех несмещенных оценок \bar{X} не является эффективной оценкой параметра θ для заданной параметрической модели.

Плотности распределения $X_{(1)}$ и $X_{(n)}$ на отрезке $[a, b]$ соответственно равны

$$p_{X_{(1)}}(x) = n \left(1 - \frac{x-a}{b-a}\right)^{n-1} \frac{1}{b-a}, \quad p_{X_{(n)}}(x) = n \left(\frac{x-a}{b-a}\right)^{n-1} \frac{1}{b-a}$$

(см. пример 2.20). Вычислив

$$M X_{(1)} = \int_a^b x n \left(\frac{b-x}{b-a}\right)^{n-1} \frac{1}{b-a} dx = b - \frac{n}{n+1}(b-a),$$

$$M X_{(n)} = \int_a^b x n \left(\frac{x-a}{b-a}\right)^{n-1} \frac{1}{b-a} dx = a + \frac{n}{n+1}(b-a),$$

получим

$$M\theta^*(\vec{X}_n) = \frac{1}{2}(M X_{(1)} + M X_{(n)}) = \frac{a+b}{2},$$

что и доказывает несмещенность оценки $\theta^*(\vec{x}_n)$.

Далее, используя совместную плотность распределения вероятностей случайных величин* $X_{(1)}$ и $X_{(n)}$

$$p_{X_{(1)}X_{(n)}}(x, y) = \frac{n(n-1)(y-x)^{n-2}}{(b-a)^n}, \quad a < x \leq y \leq b,$$

и равенство

$$\begin{aligned} D\theta^*(\vec{X}_n) &= \frac{1}{4} D(X_{(1)} + X_{(n)}) = \\ &= \frac{1}{4}(D X_{(1)} + D X_{(n)}) + \frac{1}{2} \text{cov}(X_{(1)}, X_{(n)}), \end{aligned}$$

можно получить

$$D\theta^*(\vec{X}_n) = \frac{(b-a)^2}{2(n+1)(n+2)}.$$

Поскольку

$$D\theta^*(\vec{X}_n) < D(\bar{X}) = \frac{\sigma^2}{n} = \frac{(b-a)^2}{12n}, \quad n \geq 3,$$

то, следовательно, в классе всех несмещенных оценок \bar{X} не является эффективной оценкой параметра θ для рассматриваемой параметрической модели.

Теорема 2.3 (о единственности эффективной оценки). Пусть $\hat{\theta}(\vec{X}_n)$ и $\tilde{\theta}(\vec{X}_n)$ — две эффективные оценки для параметра θ рассматриваемой параметрической модели. Тогда

$$\hat{\theta}(\vec{X}_n) = \tilde{\theta}(\vec{X}_n),$$

где равенство следует понимать в вероятностном смысле:

$$P\{\vec{X}_n \in \{\vec{x}_n: \hat{\theta}(\vec{x}_n) \neq \tilde{\theta}(\vec{x}_n)\}\} = 0.$$

◀ Действительно, рассмотрим статистику

$$\theta^*(\vec{X}_n) = \frac{1}{2}(\hat{\theta}(\vec{X}_n) + \tilde{\theta}(\vec{X}_n)).$$

По условию $D\hat{\theta}(\vec{X}_n) = D\tilde{\theta}(\vec{X}_n)$. Значит,

$$\begin{aligned} D\theta^*(\vec{X}_n) &= \frac{1}{4}(D\hat{\theta}(\vec{X}_n) + D\tilde{\theta}(\vec{X}_n)) + \frac{1}{2}\text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n)) = \\ &= \frac{1}{2}(D\hat{\theta}(\vec{X}_n) + \text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n))). \end{aligned}$$

Поскольку

$$|\text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n))| \leq \sqrt{D\hat{\theta}(\vec{X}_n) D\tilde{\theta}(\vec{X}_n)} = D\hat{\theta}(\vec{X}_n),$$

то

$$\begin{aligned} D\theta^*(\vec{X}_n) &= \frac{1}{2}|D\hat{\theta}(\vec{X}_n) + \text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n))| \leq \\ &\leq \frac{1}{2}(D\hat{\theta}(\vec{X}_n) + \text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n))) \leq D\hat{\theta}(\vec{X}_n). \end{aligned}$$

А так как $\hat{\theta}(\vec{X}_n)$ — эффективная оценка, то

$$D\theta^*(\vec{X}_n) = D\hat{\theta}(\vec{X}_n) = D\tilde{\theta}(\vec{X}_n)$$

и, как следствие,

$$\text{cov}(\hat{\theta}(\vec{X}_n), \tilde{\theta}(\vec{X}_n)) = D\hat{\theta}(\vec{X}_n) = D\tilde{\theta}(\vec{X}_n) = \sqrt{D\hat{\theta}(\vec{X}_n) D\tilde{\theta}(\vec{X}_n)}.$$

Из последнего равенства следует [XVI], что

$$\hat{\theta}(\vec{X}_n) = k\tilde{\theta}(\vec{X}_n) + b.$$

Так как

$$D\hat{\theta}(\vec{X}_n) = \text{cov}(k\tilde{\theta}(\vec{X}_n) + b, \tilde{\theta}(\vec{X}_n)) = kD\tilde{\theta}(\vec{X}_n) = kD\hat{\theta}(\vec{X}_n),$$

то получаем $k = 1$. Из условия несмещенности оценок следует, что $b = 0$:

$$M\tilde{\theta}(\vec{X}_n) = M\hat{\theta}(\vec{X}_n) = M(\tilde{\theta}(\vec{X}_n) + b) = M\tilde{\theta}(\vec{X}_n) + b.$$

Таким образом, $\hat{\theta}(\vec{X}_n) = \tilde{\theta}(\vec{X}_n)$. ►

В дальнейшем изложении при рассмотрении параметрических моделей будем использовать дифференцирование по параметру под знаком *интеграла, зависящего от параметра*. Параметрические модели, для которых выполнены условия, обеспечивающие законность указанных операций, называют *регулярными моделями*.

Теорема 2.4 (неравенство Рао — Крамера*). Пусть рассматриваемая параметрическая модель является регулярной и $\hat{\theta}(\vec{X}_n)$ — несмещенная оценка неизвестного параметра θ . Тогда имеет место неравенство

$$D\hat{\theta}(\vec{X}_n) \geq \frac{1}{nI(\theta)}, \quad (2.2)$$

где

$$I(\theta) = M \left(\frac{\partial \ln p(X; \theta)}{\partial \theta} \right)^2.$$

Здесь $I(\theta)$ — *количество информации по Фишеру*** в одном наблюдении, а $p(t; \theta)$ — плотность распределения генеральной совокупности X в случае *непрерывной статистической модели* и вероятность события $\{X = t\}$ в случае *дискретной статистической модели*.

◀ Доказательство проведем для непрерывной модели. Пусть $p(t; \theta) > 0$ при $t \in A \subset \mathbb{R}$ и $p(t; \theta) = 0$ при $t \notin A$. Тогда плотность распределения

$$p_{\vec{X}_n}(T, \theta) \equiv p_{\vec{X}_n}(t_1, \dots, t_n, \theta) = \prod_{i=1}^n p(t_i; \theta)$$

случайной выборки \vec{X}_n отлична от нуля на множестве

$$B = A \times A \times \dots \times A \subset \mathbb{R}^n,$$

где $T = (t_1, \dots, t_n)$ — векторный аргумент. Поскольку

$$\int_{\mathbb{R}^n} p_{\vec{X}_n}(T, \theta) dT = \int_B p_{\vec{X}_n}(T, \theta) dT = 1,$$

имеем

$$\frac{\partial}{\partial \theta} \int_{\mathbb{R}^n} p_{\vec{X}_n}(T, \theta) dT = \frac{\partial}{\partial \theta} \int_B p_{\vec{X}_n}(T, \theta) dT = \int_B \frac{\partial p_{\vec{X}_n}(T, \theta)}{\partial \theta} dT = 0,$$

или

$$\int_B \frac{\partial \ln p_{\vec{X}_n}(T, \theta)}{\partial \theta} p_{\vec{X}_n}(T, \theta) dT = 0. \quad (2.3)$$

Так как $\hat{\theta}(X_1, \dots, X_n)$ — несмещенная оценка параметра θ , то

$$M \hat{\theta}(\vec{X}_n) = \int_{\mathbb{R}^n} \hat{\theta}(T) p_{\vec{X}_n}(T, \theta) dT = \int_B \hat{\theta}(T) p_{\vec{X}_n}(T, \theta) dT = \theta.$$

Таким образом,

$$\frac{\partial}{\partial \theta} \int_{\mathbb{R}^n} \hat{\theta}(T) p_{\vec{X}_n}(T, \theta) dT = \int_B \hat{\theta}(T) p_{\vec{X}_n}(T, \theta) dT = 1,$$

или, что то же самое,

$$\int_B \hat{\theta}(T) \frac{\partial \ln p_{\vec{X}_n}(T, \theta)}{\partial \theta} p_{\vec{X}_n}(T, \theta) dT = 1. \quad (2.4)$$

Умножив равенство (2.3) на параметр θ и вычтя его из равенства (2.4), приходим к равенству

$$\int_B (\hat{\theta}(T) - \theta) \frac{\partial \ln p_{\vec{X}_n}(T, \theta)}{\partial \theta} p_{\vec{X}_n}(T, \theta) dT = 1. \quad (2.5)$$

Согласно неравенству Коши — Буняковского, имеем

$$\begin{aligned} 1 &\leq \int_B (\hat{\theta}(T) - \theta)^2 p_{\vec{X}_n}(T, \theta) dT \int_B \left(\frac{\partial \ln p_{\vec{X}_n}(T, \theta)}{\partial \theta} \right)^2 p_{\vec{X}_n}(T, \theta) dT = \\ &= \mathbf{D} \hat{\theta}(\vec{X}_n) \mathbf{M} \left(\frac{\partial \ln p_{\vec{X}_n}(\vec{X}_n, \theta)}{\partial \theta} \right)^2, \end{aligned}$$

откуда и следует неравенство (2.2), так как

$$\begin{aligned} \mathbf{M} \left(\frac{\partial \ln p_{\vec{X}_n}(\vec{X}_n, \theta)}{\partial \theta} \right)^2 &= \int_B \left(\frac{\partial \ln p_{\vec{X}_n}(\vec{X}_n, \theta)}{\partial \theta} \right)^2 p_{\vec{X}_n}(T, \theta) dT = \\ &= \int_B \left(\sum_{i=1}^n \frac{\partial \ln p(t_i, \theta)}{\partial \theta} \right)^2 p_{\vec{X}_n}(T, \theta) dT = \\ &= \sum_{i=1}^n \int_B \left(\frac{\partial \ln p(t_i, \theta)}{\partial \theta} \right)^2 p_{\vec{X}_n}(T, \theta) dT = \sum_{i=1}^n \mathbf{M} \left(\frac{\partial \ln p(X_i, \theta)}{\partial \theta} \right)^2 = \\ &= \sum_{i=1}^n \mathbf{M} \left(\frac{\partial \ln p(X, \theta)}{\partial \theta} \right)^2 = n \mathbf{M} \left(\frac{\partial \ln p(X, \theta)}{\partial \theta} \right)^2 = nI(\theta). \quad \blacktriangleright \end{aligned}$$

Неравенство (2.2) определяет нижнюю границу дисперсий несмещенных оценок параметра θ для регулярных моделей.

Величину

$$e(\theta) = \frac{1}{nI(\theta) D\hat{\theta}(\vec{X}_n)}$$

называют **показателем эффективности по Рао — Крамеру**. Из (2.2) следует, что для любой несмещенной оценки параметра θ величина $e(\theta)$ удовлетворяет условию $0 < e(\theta) \leq 1$.

Определение 2.4. Несмещенную **оценку $\hat{\theta}(\vec{X}_n)$** параметра $\theta \in \Theta \subset \mathbb{R}$ называют **эффективной по Рао — Крамеру**, если показатель эффективности $e(\theta) = 1$.

Замечание 2.6. Равенство

$$D\hat{\theta}(\vec{X}_n) = \frac{1}{nI(\theta)}$$

имеет место тогда и только тогда, когда

$$\frac{\partial \ln p_{\vec{X}_n}(\vec{X}_n, \theta)}{\partial \theta} = a(\theta) (\hat{\theta}(\vec{X}_n) - \theta),$$

что является необходимым и достаточным условием обращения неравенства Коши — Буняковского в равенство. Следовательно, это равенство является **критерием эффективности для регулярных моделей**. При этом из равенства (2.5) следует, что $a(\theta) = 1/D\hat{\theta}(\vec{X}_n)$.

Замечание 2.7. Эффективная оценка по Рао — Крамеру для рассматриваемой регулярной модели является эффективной (см. определение 2.3). Утверждение следует из теоремы 2.3 о единственности эффективной оценки в классе несмещенных оценок. Обратное утверждение неверно, поскольку не любая параметрическая модель является регулярной (см. пример 2.21).

Пример 2.4. Рассмотрим **нормальную модель $N(\theta, \sigma^2)$** в предположении, что дисперсия σ^2 известна. Оценка

$$\hat{\theta}(\vec{X}_n) = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

является несмещенной для неизвестного среднего значения $\theta = \mu$ (см. теорему 2.1). Убедимся в ее эффективности по Рао — Крамеру. Во-первых, в силу независимости элементов случайной выборки $\vec{X}_n = (X_1, \dots, X_n)$ имеем

$$D(\vec{X}_n) = D\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n D X_i = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n}.$$

Во-вторых,

$$\begin{aligned} I(\theta) &= M\left(\frac{\partial}{\partial \theta} \ln\left(\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(X-\theta)^2}{2\sigma^2}}\right)\right)^2 = \\ &= M\left(\frac{\partial}{\partial \theta} \left(\ln \frac{1}{\sqrt{2\pi}} - \ln \sigma - \frac{(X-\theta)^2}{2\sigma^2}\right)\right)^2 = M\frac{(X-\theta)^2}{\sigma^4} = \frac{\sigma^2}{\sigma^4} = \frac{1}{\sigma^2}. \end{aligned}$$

Следовательно,

$$e(\theta) = \frac{1}{n I(\theta) D \bar{X}} = \frac{n}{n \frac{1}{\sigma^2} \sigma^2} = 1,$$

т.е. для нормальной модели \bar{X} — эффективная оценка параметра μ .

Пример 2.5. Рассмотрим модель $N(\mu, \theta)$ в предположении, что среднее значение μ генеральной совокупности известно, а $\theta = \sigma^2$ — неизвестный параметр.

Покажем, что

$$\tilde{S}^2(\vec{X}_n) = \frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$$

является несмещенной и эффективной по Рао — Крамеру оценкой параметра σ^2 . Действительно,

$$M \tilde{S}^2(\vec{X}_n) = \frac{1}{n} \sum_{i=1}^n M(X_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n D X_i = \frac{1}{n} \sum_{i=1}^n \sigma^2 = \frac{1}{n} n \sigma^2 = \sigma^2,$$

т.е. $\tilde{S}^2(\vec{X}_n)$ — несмещенная оценка.

Вычислим дисперсию $S^2(\vec{X}_n)$:

$$\begin{aligned}
 D\tilde{S}^2(\vec{X}_n) &= M\tilde{S}^4(\vec{X}_n) - (M\tilde{S}^2(\vec{X}_n))^2 = \\
 &= M\left(\frac{1}{n}\sum_{i=1}^n (X_i - \mu)^2\right)^2 - \sigma^4 = \\
 &= \frac{1}{n^2}\left(\sum_{i=1}^n M(X_i - \mu)^4 + \sum_{\substack{i,j=1 \\ i \neq j}}^n M((X_i - \mu)^2(X_j - \mu)^2)\right) - \sigma^4 = \\
 &= \frac{n\dot{m}_4}{n^2} + \frac{n(n-1)}{n^2}\sigma^4 - \sigma^4 = \frac{3\sigma^4}{n} + \frac{n-1}{n}\sigma^4 - \sigma^4 = \frac{2\sigma^4}{n}.
 \end{aligned}$$

Затем определим информацию по Фишеру:

$$\begin{aligned}
 I(\theta) &= M\left(\frac{\partial}{\partial\sigma^2}\left(\ln\frac{1}{\sqrt{2\pi\sigma^2}}e^{-\frac{(X-\mu)^2}{2\sigma^2}}\right)\right)^2 = \\
 &= M\left(\frac{\partial}{\partial\sigma^2}\left(\ln\frac{1}{\sqrt{2\pi}} - \frac{1}{2}\ln\sigma^2 - \frac{(X-\mu)^2}{2\sigma^2}\right)\right)^2 = \\
 &= M\left(-\frac{1}{2\sigma^2} + \frac{(X-\mu)^2}{2\sigma^4}\right)^2 = \frac{1}{4\sigma^4} - \frac{M(X-\mu)^2}{2\sigma^6} + \frac{M(X-\mu)^4}{4\sigma^8} = \\
 &= \frac{1}{4\sigma^2} - \frac{\sigma^2}{2\sigma^6} + \frac{3\sigma^4}{4\sigma^8} = \frac{1}{2\sigma^4},
 \end{aligned}$$

поскольку для нормальной модели $\dot{m}_4 = 3\sigma^4$. В результате получим

$$D\tilde{S}^2(\vec{X}_n) = \frac{1}{nI(\theta)} \quad \text{и} \quad e(\theta) = 1,$$

т.е. $\tilde{S}^2(\vec{X}_n)$ — эффективная оценка параметра θ для нормальной модели. #

Заметим, что

$$S^2(\vec{X}_n) = \frac{1}{n-1}\sum_{i=1}^n (X_i - \bar{X})^2$$

является несмещенной оценкой параметра σ^2 (см. замечание 2.4), но для нормальной модели $N(\mu, \theta)$ эта оценка не является эффективной. Это вытекает из теоремы 2.3 о единственности существования эффективной оценки. Можно показать, что

$$D\tilde{S}^2(\vec{X}_n) = \frac{2\sigma^4}{n-1}.$$

Следовательно,

$$e(\theta) = \frac{1}{nI(\theta)DS^2(\vec{X}_n)} = \frac{n-1}{n} < 1.$$

Пример 2.6. Рассмотрим экспоненциальную модель

$$p(x; \theta) = \begin{cases} \frac{1}{\theta} e^{-\frac{1}{\theta}x}, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

Покажем, что \bar{X} является эффективной по Рао — Крамеру оценкой неизвестного параметра θ . Действительно,

$$D(\bar{X}) = D\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} DX = \frac{\theta^2}{n},$$

$$\begin{aligned} I(\theta) &= M\left(\frac{\partial}{\partial\theta} \left(\ln \frac{1}{\theta} e^{-\frac{X}{\theta}}\right)\right)^2 = M\left(-\frac{1}{\theta} + \frac{X}{\theta^2}\right)^2 = \\ &= M\left(\frac{X - \theta}{\theta^2}\right)^2 = \frac{M(X - \theta)^2}{\theta^4} = \frac{DX}{\theta^4} = \frac{\theta^2}{\theta^4} = \frac{1}{\theta^2}, \end{aligned}$$

откуда заключаем, что

$$e(\theta) = \frac{1}{n \frac{1}{\theta^2} \cdot \frac{\theta^2}{n}} = 1.$$