


МОСКОВСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
имени М. В. ЛОМОНОСОВА  
Механико-математический факультет



## Курс лекций по математической статистике

Лектор — Александр Васильевич Прохоров

III курс, 5 семестр, поток математиков

Москва, 2006 г.

# Оглавление

<b>1. Краткий обзор курса</b>	<b>4</b>
1.1. Модель конечного случайного выбора . . . . .	4
1.2. Статистическая модель схемы Бернулли . . . . .	5
1.2.1. Точечная оценка . . . . .	5
1.2.2. Интервальная оценка . . . . .	6
1.2.3. Выбор из двух гипотез . . . . .	7
<b>2. Точечные оценки</b>	<b>8</b>
2.1. Общие понятия математической статистики . . . . .	8
2.1.1. Статистическая модель . . . . .	8
2.1.2. Обоснование предельного перехода при стремлении размера выборки к бесконечности . . . . .	8
2.1.3. Модель повторных испытаний . . . . .	8
2.1.4. Выборочные характеристики . . . . .	9
2.2. Эмпирическая функция распределения . . . . .	10
2.2.1. Определение и свойства . . . . .	10
2.2.2. Теорема Гливленко–Кантелли . . . . .	11
2.2.3. Статистика Колмогорова . . . . .	12
2.2.4. Критерий Колмогорова . . . . .	12
2.2.5. Выборочные характеристики как характеристики эмпирической функции распределения . . . . .	13
2.2.6. Распределение порядковых статистик . . . . .	13
2.3. Функция правдоподобия. Регулярные модели . . . . .	14
2.4. Количество информации Фишера. Неравенство Рао–Крамера . . . . .	15
2.4.1. Информация Фишера . . . . .	15
2.4.2. Неравенство Рао–Крамера . . . . .	16
2.4.3. Семейства распределений экспоненциального типа . . . . .	16
2.4.4. Многомерный случай . . . . .	17
2.5. Методы получения оценок . . . . .	17
2.5.1. Метод моментов . . . . .	17
2.5.2. Асимптотические свойства оценок . . . . .	17
2.5.3. Метод максимального (наибольшего) правдоподобия . . . . .	18
2.6. О свойствах информации Фишера . . . . .	20
2.7. Достаточные статистики . . . . .	21
2.8. Условное математическое ожидание . . . . .	22
2.8.1. Свойства УМО . . . . .	23
2.9. Теорема Колмогорова–Блекуэлла–Рао . . . . .	23
2.10. Полная достаточная статистика . . . . .	23
2.10.1. Замечания о минимальной достаточной статистике . . . . .	24
<b>3. Байесовские статистические оценки</b>	<b>24</b>
3.1. Байесовские точечные оценки . . . . .	24
3.1.1. Функция риска . . . . .	24
3.1.2. Байесовский подход . . . . .	24
3.2. Минимаксные оценки . . . . .	25
3.3. Теорема о байесовской оценке для квадратичной функции риска . . . . .	25
3.4. Апостериорный риск . . . . .	25
3.5. Связь байесовских оценок с понятием достаточной статистики . . . . .	26
3.6. Байесовские интервальные оценки . . . . .	26
<b>4. Доверительные интервалы</b>	<b>26</b>
4.1. Доверительные интервалы для параметров нормального распределения . . . . .	27
4.1.1. Доверительный интервал для среднего при известной дисперсии . . . . .	27
4.1.2. Доверительный интервал для дисперсии при известном среднем . . . . .	27
4.2. Точный доверительный интервал для параметра биномиального распределения . . . . .	27
4.3. Общие способы получения доверительных интервалов . . . . .	28
4.3.1. Метод центральной статистики . . . . .	28
4.3.2. Ещё один метод . . . . .	28
4.4. Асимптотические доверительные интервалы . . . . .	29

<b>5.</b>	<b>Отступление про некоторые распределения вероятностей</b>	<b>29</b>
5.1.	Хи-квадрат распределение . . . . .	29
5.2.	Распределение Стьюдента . . . . .	30
5.3.	Многомерное нормальное распределение . . . . .	30
5.3.1.	Четыре эквивалентных определения . . . . .	30
5.3.2.	Свойства многомерного нормального распределения . . . . .	31
5.3.3.	Лемма Фишера . . . . .	31
5.3.4.	Доверительные интервалы для параметров нормального распределения $\Pi$ . . . . .	32
<b>6.</b>	<b>Проверка статистических гипотез</b>	<b>32</b>
6.1.	Проверка гипотез о параметрах нормального распределения . . . . .	32
6.2.	Проверка гипотезы однородности нормальных выборок . . . . .	32
6.2.1.	О распределении Фишера–Снедекора ( $F$ -распределении) . . . . .	32
6.2.2.	Критерий Фишера равенства дисперсий . . . . .	33
6.2.3.	Критерий Стьюдента равенства средних значений при условии равенства дисперсий . . . . .	33
6.3.	Дисперсионный анализ однофакторной модели . . . . .	33
6.4.	Множественные сравнения . . . . .	34
6.4.1.	Парное сравнение . . . . .	34
6.4.2.	Собственно множественные сравнения . . . . .	35
6.5.	Критерий Пирсона ( $\chi^2$ ) . . . . .	35
6.5.1.	Биномиальный критерий . . . . .	35
6.5.2.	Критерий $\chi^2$ для схемы Бернулли (предисловие к критерию Пирсона) . . . . .	35
6.5.3.	Полиномиальный критерий . . . . .	36
6.5.4.	Теорема Пирсона . . . . .	36
6.5.5.	Критерий $\chi^2$ . . . . .	37
6.6.	Критерий знаков . . . . .	37
6.7.	Задача различения двух статистических гипотез . . . . .	38
6.7.1.	Сравнение двух простых гипотез. Теорема Неймана–Пирсона . . . . .	38

## Предисловие

Ну что Вам рассказать про Сахалин? . . . Это незавершённый курс, который, вообще говоря, можно доТрЕХать. Но у нас нет на это времени. Если у кого-то из читателей найдутся силы и желание это делать, это будет просто замечательно. Исходные тексты будут выданы всякому, кто захочет набрать остатки.

### ДОПОЛНЕНИЕ К ПРЕДИСЛОВИЮ

Текст существенно дополнен С. Л. Кузнецовым и А. В. Харитоновым. Работа постепенно продвигается к завершению. Нам ещё много нужно сделать, но многое мы уже сделали. Спасибо Тиме Архангельскому и Владимиру Гаврилину за обнаружение и исправление лажи.

*С.К., А.Х.*

Последняя компиляция: 10 января 2011 г.  
 Обновления документа — на сайтах <http://dmvn.mexmat.net>,  
<http://dmvn.mexmat.ru>.  
 Об опечатках и неточностях пишите на [dmvn@mccme.ru](mailto:dmvn@mccme.ru).

# 1. Краткий обзор курса

Математическая статистика — это наука, посвященная разработке оптимального вывода, основанного на неизвестных закономерностях.

Напомним некоторые основные определения из курса теории вероятностей.

**Определение.** *Пространством элементарных событий* называется множество исходов некоторого эксперимента. Элементарным событием называется любой элемент пространства элементарных событий. Событием называется любое подмножество пространства элементарных событий. Экспериментом называется функция, принимающая значение на пространстве элементарных событий.

**Определение.** *Генеральной совокупностью* называется достаточно большое, быть может, бесконечное подмножество элементарных событий.

**Определение.** *Случайной величиной* называют функцию от элементарного события.

## 1.1. Модель конечного случайного выбора

Рассмотрим модель «Выбор без возвращения». Пусть  $N$  — общее число элементов генеральной совокупности,  $M$  — число отмеченных (каким-то свойством) элементов,  $n$  — размер выборки, т. е. число элементов, выбранных из генеральной совокупности,  $m$  — число отмеченных элементов в выборке.

Вероятностная задача рассматривает случай, когда  $n$ ,  $M$  и  $N$  заданы, а  $m \in \{0, \dots, \min(n, M)\}$ . Тогда вероятность того, что среди выборки размера  $n$  окажется ровно  $m$  отмеченных элементов, может быть вычислена по известной формуле

$$Q_{n,m}(N, M) = \frac{C_M^m C_{N-M}^{n-m}}{C_N^n}.$$

Статистическая задача ставится несколько иначе. Например:

а) Допустим, что  $n$ ,  $m$ ,  $N$  известны, а  $M$  — неизвестно. Требуется оценить  $M$ . Это в некотором смысле задача, обратная вероятностной. Решить ее не так-то просто. Простейшее (но довольно грубое) приближение для  $M$  можно найти, например, из соотношений

$$\frac{M}{N} \approx \frac{m}{n}, \quad M \approx \frac{m}{n}N.$$

Для того, чтобы найти более точные оценки, нужны специальные методы, которыми и занимается математическая статистика.

б) Пусть заданы  $n$ ,  $m$  и  $M$ , а  $N$  неизвестно. Требуется оценить  $N$ . Пример такой задачи — оценка числа рыб в водоеме: производится выборка размера  $M$ , помечаются все рыбы из этой выборки, а спустя некоторое время производится еще одна выборка размера  $n$  и подсчитывается число помеченных рыб  $m$  из этой выборки. По этим данным требуется оценить число рыб в водоеме. Для решения этой задачи рассматривается вероятность  $\tilde{Q}_{n,m}(N)$  как функция переменной  $N$ . Оказывается, что функция  $\tilde{Q}$  сначала возрастает, а затем убывает. В качестве оценки искомого значения  $N$  выбирается такое целое  $N_*$ , для которого  $\tilde{Q}_{n,m}(N)$  максимально. Можно показать, что

$$N_* = \left[ M \frac{n}{m} \right] \leq M \frac{n}{m}.$$

Рассмотрим следующий эксперимент: два раза независимо друг от друга бросается монетка. Можно рассматривать две модели этого эксперимента:

1) 4 исхода: выпали последовательно орел–орел, орел–решка, решка–орел, решка–решка. Каждому исходу приписывается вероятность  $\frac{1}{4}$ .

2) 3 исхода: 2 орла, 2 решки, 1 орел и 1 решка; каждому исходу приписывается вероятность  $\frac{1}{3}$ .

Практика показывает, что первая модель более соответствует действительности, чем вторая: при большом числе испытаний каждый из четырех исходов появляется с частотой, близкой к  $\frac{1}{4}$ , в то время как во второй модели последний исход появляется с частотой, близкой к  $\frac{1}{2}$ , а первые два — с частотой  $\frac{1}{4}$ , что плохо соответствует приписанным вероятностям.

В некотором смысле задача математической статистики обратна задаче теории вероятностей. В теории вероятностей в каждой конкретной ситуации вероятность считается полностью определенной и основной задачей теории вероятностей является разработка методов нахождения вероятностей различных сложных событий (исходя из известных вероятностей более простых событий) для данной вероятностной модели. В математической статистике рассматривается статистическая модель, которая описывает такие ситуации, когда в вероятностной модели изучаемого эксперимента имеется та или иная неопределенность в задании вероятности, и задача математической статистики состоит в том, чтобы уменьшить эту неопределенность, уточнить (выявить) структуру статистической модели по результатам проводимых наблюдений.

## 1.2. Статистическая модель схемы Бернулли

Зафиксируем число  $n \in \mathbb{N}$ . Рассмотрим случайные величины  $\xi_1, \xi_2, \dots, \xi_n(\omega)$  на некотором общем вероятностном пространстве  $(\Omega, \mathcal{A}, P)$ ,  $\omega \in \Omega$ . Их совместное распределение:

$$P(\xi_1 = a_1, \xi_2 = a_2, \dots, \xi_n = a_n) = p^{a_1 + \dots + a_n} q^{n - (a_1 + \dots + a_n)}, \quad a_k \in \{0, 1\}, \quad p, q \geq 0, \quad p + q = 1.$$

Значение случайной величины  $\xi_1$  — исход первого испытания,  $P(\xi_1 = 1) = p$ ,  $P(\xi_1 = 0) = q = 1 - p$ , и аналогично для  $\xi_2, \dots, \xi_n$ . Отсюда  $P(\xi_1 = a_1) = p^{a_1} q^{1 - a_1}$ , и т.д. Значит,

$$P(\xi_1 = a_1, \xi_2 = a_2, \dots, \xi_n = a_n) = p^{a_1 + \dots + a_n} q^{n - (a_1 + \dots + a_n)} = \prod_{k=1}^n \left( p^{a_k} q^{1 - a_k} \right) = P(\xi_1 = a_1) \dots P(\xi_n = a_n).$$

Отсюда следует, что  $\xi_1, \xi_2, \dots, \xi_n$  — независимые испытания.

Рассмотрим случайную величину  $S_n = \xi_1 + \dots + \xi_n$ . Она имеет биномиальное распределение:

$$P(\xi_1 + \dots + \xi_n = m) = C_n^m p^m q^{n-m}, \quad S_n = \xi_1 + \dots + \xi_n, \quad MS_n = np, \quad DS_n = npq.$$

Задача математической статистики — оценить неизвестное значение  $p$ . Для этого используются три подхода — точечная оценка, интервальная оценка и выбор из двух гипотез. Продемонстрируем каждый из них на примере схемы Бернулли.

### 1.2.1. Точечная оценка

Запишем закон больших чисел для схемы Бернулли:

$$\frac{S_n}{n} = \frac{\xi_1 + \dots + \xi_n}{n} \xrightarrow{P} M \frac{S_n}{n} = \frac{np}{n} = p, \quad n \rightarrow \infty.$$

т. е. частота появления успешного исхода  $\frac{S_n}{n}$  сходится по вероятности к параметру  $p$ :  $\frac{S_n}{n} \xrightarrow{P} p$ ,  $n \rightarrow \infty$ .

Возьмем в качестве оценки параметра  $p$  эту частоту  $\frac{S_n}{n} =: \hat{p}_n$ . Это случайная величина со значениями  $\frac{m}{n}$ ,  $m = 0, \dots, n$ .

**Теорема 1.1.** *Эта оценка обладает следующими свойствами:*

1) *Несмещенность:*  $M\hat{p}_n = p$ .

2) *Состоятельность:*  $\hat{p}_n \xrightarrow{P} p$ ,  $n \rightarrow \infty$ .

3) *Эффективность:* Дисперсия частоты  $\hat{p}_n$  является наименьшей среди дисперсий всех других оценок, которые обладают свойствами 1) и 2).

□ Выше уже было показано, что оценка  $\hat{p}_n$  несмещенная (это следует из того, что  $MS_n = np$ ), а в силу закона больших чисел для схемы Бернулли она состоятельна; тем самым свойства 1) и 2) доказаны.

Докажем свойство 3) — эффективность. Пусть  $\tilde{p}_n$  — любая оценка параметра  $p$ , удовлетворяющая условиям 1) и 2) (несмещенность и состоятельность). Рассмотрим величину  $M(\tilde{p}_n - p)^2$ . Она называется средней квадратической ошибкой оценки  $\tilde{p}_n$ .

Для несмещенных оценок средняя квадратическая ошибка совпадает с дисперсией, в частности для нашей оценки  $\hat{p}_n$ :  $M(\hat{p}_n - p)^2 = D\hat{p}_n$ .

Обозначим

$$P(\xi_1 = a_1, \xi_2 = a_2, \dots, \xi_n = a_n) = p^{a_1 + \dots + a_n} (1 - p)^{n - (a_1 + \dots + a_n)} = g(p; a_1, \dots, a_n).$$

Для любого  $p \in (0, 1)$  имеет место равенство  $\sum_{(a_1, \dots, a_n)} g(p; a_1, \dots, a_n) \equiv 1$ . Условие несмещенности оценки означает, что  $M\tilde{p}_n = \sum_{(a_1, \dots, a_n)} \tilde{p}_n(a_1, \dots, a_n) g(p; a_1, \dots, a_n) = p$ . Рассмотрим  $g(p; a_1, \dots, a_n) = g(p)$  как функцию параметра  $p$ . Тогда наши условия могут быть записаны в следующем виде (суммирование ведется по всем наборам  $(a_1, \dots, a_n)$ ):

$$\begin{cases} \sum g(p) \equiv 1, \\ \sum \tilde{p}_n \cdot g(p) \equiv p; \end{cases} \quad 0 < p < 1.$$

Продифференцируем каждое из этих соотношений по  $p$ , а затем, умножив первое на  $p$ , вычтем его из второго; получим:

$$\sum (\tilde{p}_n - p) g'_p(p) \equiv 1.$$

Теперь представим  $g'_p(p)$  как логарифмическую производную:  $g'_p(p) = g(p) \frac{\partial \ln g(p)}{\partial p}$ , а затем применим неравенство Коши–Буняковского, представив  $g(p)$  в виде  $g(p) = \sqrt{g} \sqrt{g}$ :

$$1 \equiv \left( \sum (\tilde{p}_n - p) g(p) \frac{\partial \ln g(p)}{\partial p} \right)^2 \leq \left( \sum (\tilde{p}_n - p)^2 g(p) \right) \left( \sum \left[ \frac{\partial \ln g(p)}{\partial p} \right]^2 g(p) \right).$$

Так как  $M\tilde{p}_n = p$  (условие несмещённости оценки  $\tilde{p}_n$ ), то первый из множителей в правой части этого неравенства — это дисперсия  $\tilde{p}_n$ . Обозначим второй множитель через  $I(p)$ , тогда неравенство переписется в виде  $1 \leq D\tilde{p}_n \cdot I(p)$ , или  $D\tilde{p}_n \geq \frac{1}{I(p)}$ . Найдём  $I(p)$  в явном виде:

$$I(p) = M \left[ \frac{\sum \xi_k}{p} - \frac{n - \sum \xi_k}{1-p} \right]^2 = \frac{M(\sum \xi_k - np)^2}{p^2(1-p)^2} = \frac{D(\sum \xi_k)}{p^2(1-p)^2} = \frac{np(1-p)}{p^2(1-p)^2} = \frac{n}{p(1-p)}.$$

Подставляя найденное значение  $I(p)$  в неравенство для дисперсии, получаем:  $D\tilde{p}_n \geq \frac{p(1-p)}{n} = D\hat{p}_n$ , т. е. оценка  $\hat{p}_n$  действительно обладает наименьшей дисперсией из всех несмещённых состоятельных оценок  $\tilde{p}_n$ . Теорема доказана. ■

Если задана произвольная оценка  $\hat{p}_n$  параметра  $p$ , то представим ее математическое ожидание  $M\hat{p}_n$  в виде  $M\hat{p}_n = p + \Delta_n$ . Тогда  $\Delta_n$  называется смещением оценки  $\hat{p}_n$ . Несмещённые оценки обладают нулевым смещением:  $\Delta_n = 0$ .

Для нашей оценки  $\hat{p}_n = \frac{S_n}{n}$ , очевидно,  $D\hat{p}_n \rightarrow 0$ ,  $n \rightarrow \infty$ , т. е. частота обладает наименьшим рассеянием, если рассеяние измеряется с помощью дисперсии.

### 1.2.2. ИНТЕРВАЛЬНАЯ ОЦЕНКА

Интервальной оценкой параметра  $p$  называется интервал  $[\bar{p}_n, \bar{\bar{p}}_n]$ , который обладает следующим свойством:  $P\{p \in [\bar{p}_n, \bar{\bar{p}}_n]\} \geq 1 - \alpha$ ,  $0 < \alpha < 1$ ;  $\bar{p}_n = \bar{p}_n(\alpha)$ ,  $\bar{\bar{p}}_n = \bar{\bar{p}}_n(\alpha)$ . При этом длина интервала должна быть наименьшей.

**Пример 2.1.** Рассмотрим  $n = 100$  бросаний правильной монеты (схема Бернулли с параметром  $p = 0,5$ ),  $x_k$  — исход  $k$ -го испытания (значение бернуллиевской случайной величины  $\xi_k$ );  $S_n = \xi_1 + \dots + \xi_n$ . Очевидно,  $P(0 \leq S_n \leq 100) = 1$ . Прямой подсчет вероятностей показывает, что

$$P(35 \leq S_n \leq 65) = 0,99822; \quad P(39 \leq S_n \leq 61) \approx 0,98.$$

Таким образом,  $[\frac{35}{100}, \frac{65}{100}]$  — доверительный интервал для параметра  $p$  с доверительной вероятностью 0,99822; а  $[\frac{39}{100}, \frac{61}{100}]$  — доверительный интервал для параметра  $p$  с доверительной вероятностью  $\approx 0,98$ .

Для построения доверительного интервала для схемы Бернулли запишем для оценки  $\hat{p}_n = \frac{S_n}{n}$  неравенство Чебышёва:

$$P\left(\left|\frac{S_n}{n} - M\frac{S_n}{n}\right| \geq \varepsilon\right) \leq \frac{D\frac{S_n}{n}}{\varepsilon^2} \implies P\left(\left|\frac{S_n}{n} - M\frac{S_n}{n}\right| \leq \varepsilon\right) \geq 1 - \frac{D\frac{S_n}{n}}{\varepsilon^2},$$

$$P(|\hat{p}_n - p| \leq \varepsilon) \geq 1 - \frac{pq}{n\varepsilon^2} \geq 1 - \frac{1}{4n\varepsilon^2} \geq 1 - \alpha, \quad \alpha = \frac{1}{4n\varepsilon^2}.$$

Теперь зададим произвольное  $\alpha \in (0, 1)$ . Тогда для  $\varepsilon_\alpha = \sqrt{\frac{1}{4n\alpha}}$  получим:

$$P(|\hat{p}_n - p| \leq \varepsilon_\alpha) \geq 1 - \alpha, \quad \text{т. е.} \quad P(\hat{p}_n - \varepsilon_\alpha \leq p \leq \hat{p}_n + \varepsilon_\alpha) \geq 1 - \alpha.$$

Таким образом, мы построили интервал  $[\hat{p}_n - \varepsilon_\alpha, \hat{p}_n + \varepsilon_\alpha]$ , в котором с задаваемой нами вероятностью ошибки  $\alpha$  находится неизвестный параметр  $p$ . Он называется доверительным интервалом для параметра  $p$  с доверительной вероятностью  $1 - \alpha$  (или с вероятностью ошибки  $\alpha$ ). Чем меньше мы выбираем  $\alpha$ , тем больше этот интервал. Для заданного  $\alpha$  длину интервала можно уменьшить за счёт увеличения числа испытаний  $n$ .

Укажем еще один (более точный) способ нахождения интервальной оценки в схеме Бернулли. По теореме Муавра–Лапласа число «успехов» схемы Бернулли с ростом  $n$  стремится к нормальной случайной величине:

$$\frac{S_n - MS_n}{\sqrt{DS_n}} = \frac{S_n - np}{\sqrt{npq}} \xrightarrow{D} \mathcal{N}(0, 1). \quad (1)$$

Используя это, можно оценить вероятность

$$P(|\hat{p}_n - p| \leq \varepsilon) = P\left(\left|\frac{S_n - np}{n}\right| \sqrt{\frac{n}{pq}} \leq \varepsilon \sqrt{\frac{n}{pq}}\right) \simeq \Phi\left(\varepsilon \sqrt{\frac{n}{pq}}\right) - \Phi\left(-\varepsilon \sqrt{\frac{n}{pq}}\right) = 2\Phi(u) - 1, \quad u = \varepsilon \sqrt{\frac{n}{pq}}.$$

Здесь  $\Phi(u) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^u e^{-\frac{t^2}{2}} dt$  — функция распределения стандартной нормальной случайной величины.

Фиксируем  $0 < \alpha < 1$ . Нам нужно, чтобы  $2\Phi(u) - 1 = 1 - \alpha$ , т. е.  $\Phi(u) = 1 - \frac{\alpha}{2}$ . Обозначим такое значение  $u$ , при котором это выполнено, через  $u_{1-\frac{\alpha}{2}}$  (квантиль порядка  $1 - \frac{\alpha}{2}$  нормального распределения, находится из таблицы квантилей). Тогда искомое  $\varepsilon$  найдем из условия  $\varepsilon \sqrt{\frac{n}{pq}} = u_{1-\frac{\alpha}{2}}$ ;  $\varepsilon = u_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}$ . Итак, неравенство

$$|\hat{p}_n - p| \leq u_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \quad (2)$$

выполняется с вероятностью  $\simeq 1 - \alpha$ . Осталось найти границы доверительного интервала. Возведем неравенство в квадрат:

$$(\hat{p}_n - p)^2 \leq u_{1-\frac{\alpha}{2}}^2 \frac{p(1-p)}{n}.$$

Получили квадратное уравнение на  $p$ . В качестве  $\bar{p}_n$  и  $\underline{p}_n$  берут корни этого квадратного уравнения (можно показать, что всегда  $D > 0$  и корней действительно два).

### 1.2.3. ВЫБОР ИЗ ДВУХ ГИПОТЕЗ

Пусть задано  $p_0$ . Рассмотрим две (взаимоисключающих) гипотезы о параметре  $p$ :  $H_0$  (основная, или нулевая, гипотеза) и  $H_1$  (альтернативная, или конкурирующая, гипотеза). (Например,  $H_0: p = p_0$ ,  $H_1: p \neq p_0$ .) Наша задача: выбрать из этих двух гипотез ту, которой соответствует наименьшая вероятность ошибки.

**Определение.** Вероятность ошибки I рода — это вероятность отклонить верную гипотезу  $H_0$ . Вероятность ошибки II рода — это вероятность принять неверную гипотезу  $H_0$ .

Критерий проверки гипотезы  $H_0$  — это правило, на основании которого мы можем считать, что она верна или неверна (т. е. принимаем ее или не принимаем). Составим таблицу:

	$H_0$	$H_1$
принимаем $H_0$		$\beta$
отклоняем $H_0$	$\alpha$	

Здесь вероятность ошибки I рода (отклоняем  $H_0$  в то время как она верна) обозначена через  $\alpha$ , а вероятность ошибки II рода (принимаем неверную гипотезу  $H_0$ ) —  $\beta$ .

Рассмотрим две гипотезы  $H_0: p = p_0$ ,  $H_1: p \neq p_0$  ( $p_0$  задано). Пусть для параметра  $p$  получена интервальная оценка для заданной вероятности ошибки  $\alpha$  — доверительный интервал  $[\bar{p}_n, \underline{p}_n]$ . Тогда можно предложить такой критерий:

- 1) Если  $p_0 \in [\bar{p}_n, \underline{p}_n]$ , то  $H_0$  принимаем (и соответственно, отклоняем  $H_1$ );
- 2) Если  $p_0 \notin [\bar{p}_n, \underline{p}_n]$ , то  $H_0$  отклоняем (и тем самым принимаем  $H_1$ ).

Поскольку  $[\bar{p}_n, \underline{p}_n]$  — доверительный интервал с доверительной вероятностью  $1 - \alpha$ , то вероятность ошибки I рода не превосходит  $\alpha$ .

Рассмотрим еще один пример гипотез о параметре  $p$  схемы Бернулли. Пусть  $H_0: p = p_0$ ,  $H_1: p = p_1$ , где  $p_0 < p_1$  — заданы, и пусть  $\alpha$  — вероятность ошибки I рода,  $\beta$  — вероятность ошибки II рода. Как всегда, обозначаем  $S_n = \xi_1 + \dots + \xi_n$ . Тогда существует такой критерий: если  $S_n > m_*$ , то  $H_0$  отклоняем (тем самым принимая  $H_1$ ), а если  $S_n \leq m_*$ , то  $H_0$  принимаем ( $H_1$  отклоняем). Число  $m_*$  называется критическим значением и находится из соображений минимизации при фиксированном  $n$  сумм (вероятностей ошибок I и II рода)

$$\alpha = \sum_{m=m_*+1}^n C_n^m p_0^m (1-p_0)^{n-m}, \quad \beta = \sum_{m=0}^{m_*} C_n^m p_1^m (1-p_1)^{n-m}.$$

**Задача 1.1.** Пусть заданы  $0 < \alpha' < 1$  и  $0 < \beta' < 1$ . Найти наименьшее значение  $n$  и соответствующее ему  $m_*(n)$ , такие что данный критерий различает гипотезы  $H_0$  и  $H_1$  с вероятностями ошибок I и II рода, не превосходящими соответственно  $\alpha'$  и  $\beta'$ .

На этом мы завершаем обзор. Далее речь пойдёт подробнее о точечных оценках, интервальных оценках и проверке гипотез.

## 2. Точечные оценки

### 2.1. Общие понятия математической статистики

#### 2.1.1. СТАТИСТИЧЕСКАЯ МОДЕЛЬ

Фундаментальным понятием теории вероятностей является вероятностная модель (вероятностное пространство) — это тройка  $(\Omega, \mathcal{A}, P)$ , где  $\Omega$  — пространство элементарных событий,  $\mathcal{A}$  —  $\sigma$ -алгебра подмножеств этого пространства (событий),  $P$  — вероятностная мера на  $\sigma$ -алгебре  $\mathcal{A}$ .

Основным объектом исследования математической статистики является статистическая модель. Определим это понятие.

Результатом статистического эксперимента являются вещественные числа  $x_1, \dots, x_n$  — статистические данные. Это значения случайных величин  $\xi_1, \dots, \xi_n$ . Их совокупность  $x^{(n)} = (x_1, \dots, x_n)$  называется *выборкой* размера (порядка)  $n$ .

**Определение.** *Статистической моделью* называется тройка  $(\mathcal{X}, \mathcal{B}(\mathcal{X}), \mathcal{P})$ , где  $\mathcal{X} = \{x^{(n)}\}$  — выборочное пространство, т.е. совокупность всевозможных выборок размера  $n$ ,  $\mathcal{B}(\mathcal{X})$  —  $\sigma$ -алгебра на выборочном пространстве,  $\mathcal{P} = \{P\}$  — некоторое *семейство* распределений вероятностей, заданное на  $\mathcal{B}(\mathcal{X})$ .

В простейшем случае считаем, что  $\mathcal{X} \subseteq \mathbb{R}^m$ , а  $\mathcal{B}(\mathcal{X})$  — борелевская  $\sigma$ -алгебра.

Примерами семейств распределений могут служить, например, семейство бернуллиевских распределений,  $p \in [0, 1]$ ; семейство пуассоновских распределений,  $\lambda \in (0, \infty)$ ; семейство биномиальных распределений с параметрами  $(n, p)$ , где  $n$  фиксировано, а  $p \in (0, 1)$  и т.д.

Наша цель — выделить из семейства распределений то единственное распределение, которое наилучшим образом соответствует нашим запросам, точнее, полученной выборке (после этого мы сможем работать с вероятностной моделью).

Если  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ , где  $\theta$  — параметр,  $\Theta \subset \mathbb{R}^m$  — параметрическое множество, то говорят, что  $\mathcal{P}$  — *параметрическое семейство распределений*, а  $(\mathcal{X}, \mathcal{B}(\mathcal{X}), \mathcal{P})$  — *параметрическая модель*.

Пусть имеется случайный вектор  $\xi^{(n)} = \{\xi_1, \dots, \xi_n\}$  со значениями  $(x_1, \dots, x_n)$  в выборочном пространстве  $\mathcal{X}$ . В соответствии с определением статистической модели,  $\mathcal{P}$  — семейство распределений случайного вектора  $\xi^{(n)}$ . Чтобы не путать набор случайных величин (случайный вектор)  $\xi_1, \dots, \xi_n$  с его конкретными значениями  $x_1, \dots, x_n$ , говорят, что  $x_1, \dots, x_n$  — выборка, а  $\xi_1, \dots, \xi_n$  ( $\xi_i = \xi_i(\omega)$ ) — случайная выборка.

#### 2.1.2. ОБОСНОВАНИЕ ПРЕДЕЛЬНОГО ПЕРЕХОДА ПРИ СТРЕМЛЕНИИ РАЗМЕРА ВЫБОРКИ К БЕСКОНЕЧНОСТИ

Считаем, что  $R^{(n)}$  —  $n$ -мерное евклидово пространство<sup>1</sup>. Рассмотрим последовательность выборочных пространств

$$(R^{(1)}, \mathcal{B}(R^{(1)})), \dots, (R^{(n)}, \mathcal{B}(R^{(n)})), \dots$$

с вероятностными мерами  $P_1, \dots, P_n, \dots$ . Исследуем их предельные свойства при  $n \rightarrow \infty$ .

**Определение.** Вероятностные меры  $P_1, \dots, P_n, \dots$  называются *согласованными*, если

$$\forall n \in \mathbb{N} \quad \forall B \in \mathcal{B}(R^{(n)}) \quad P_{n+1}(B \times \mathbb{R}) = P_n(B)$$

Введём пространство  $(R^{(\infty)}, \mathcal{B}(R^{(\infty)}))$ , где  $R^{(\infty)} = \{x = (x_1, \dots, x_n, \dots) \mid x_k \in \mathbb{R}\}$ ,  $\mathcal{B}(R^{(\infty)})$  — борелевская  $\sigma$ -алгебра.

**Определение.** Пусть  $B \in \mathcal{B}(R^{(n)})$ . Тогда *борелевским цилиндром* называется следующее множество:

$$Z_n(B) = \{x = (x_1, \dots) \in R^{(\infty)} \mid (x_1, \dots, x_n) \in B\}.$$

**Теорема 2.1 (Колмогоров).** *Если меры на  $R^{(1)}, \dots, R^{(n)}, \dots$  согласованы, то существует единственная вероятностная мера  $P$  на  $(R^{(\infty)}, \mathcal{B}(R^{(\infty)}))$  такая, что  $P(Z_n(B)) = P_n(B)$  для всех  $B \in \mathcal{B}(R^{(n)})$  и для всех натуральных  $n$ .*

Эта теорема обосновывает законность перехода к пределу при  $n \rightarrow \infty$  ( $n$  — размер выборки).

#### 2.1.3. МОДЕЛЬ ПОВТОРНЫХ ИСПЫТАНИЙ

**Определение.** *Моделью повторных испытаний* называется статистическая модель, в которой случайные величины  $\xi_1, \dots, \xi_n$  (со значениями  $x_1, \dots, x_n$  соответственно,  $(x_1, \dots, x_n) \in \mathcal{X}$ ) независимы и одинаково распределены.

В дальнейшем мы будем рассматривать только модели повторных испытаний.

<sup>1</sup>Почему-то лектор обозначил его нестандартно... — *примеч. С. К.*



**Пример 1.1.** Рассмотренная выше статистическая модель схемы Бернулли — модель повторных испытаний. Действительно, в этом случае рассматриваются независимые испытания с одним и тем же распределением вероятности  $P(\xi = 0) = p$ ,  $P(\xi = 1) = 1 - p$ , где  $p \in (0, 1)$  — параметр.

**Пример 1.2.** Рассмотрим эксперимент по измерению температуры. Мы считаем, что измерения независимы и результаты измерений — значения одинаково распределенных случайных величин  $\xi_1, \dots, \xi_n \sim \xi$ . На практике обычно результаты измерений колеблются около некоторого постоянного значения  $a$ , поэтому удобно рассматривать  $\xi$  в виде  $\xi = a + \Delta$ , где  $\xi = (\xi_1, \dots, \xi_n)$ ,  $\Delta = (\Delta_1, \dots, \Delta_n)$  — случайная ошибка, или в координатах:  $\xi_k = a + \Delta_k$ ,  $k = 1, \dots, n$ . Случайные величины  $\Delta_1, \dots, \Delta_n$  также независимы и одинаково распределены; при этом  $M\Delta_k = 0$ ,  $D\Delta_k = \sigma^2 \forall k$ . Средняя температура вычисляется как среднее арифметическое результатов измерений:

$$\bar{\xi}_n = \frac{\xi_1 + \dots + \xi_n}{n} = a + \frac{\Delta_1 + \dots + \Delta_n}{n}, \quad \bar{\Delta}_n = \frac{\Delta_1 + \dots + \Delta_n}{n} \text{ — средняя ошибка,} \quad M\bar{\Delta}_n = 0, \quad D\bar{\Delta}_n = \frac{\sigma^2}{n}.$$

#### 2.1.4. ВЫБОРОЧНЫЕ ХАРАКТЕРИСТИКИ

Пусть в некоторой статистической модели имеется выборка порядка  $n$ :  $x_1, \dots, x_n$ .

**Определение.** *Статистикой* называется произвольная измеримая функция  $f(x_1, \dots, x_n)$  от элементов выборки  $x_1, \dots, x_n$ .

**Определение.** Если случайная величина  $\xi$  имеет распределение  $F(x)$ , то *медианой* распределения называется такое число  $\mu$ , что  $F(\mu) = \frac{1}{2}$ .

Медиана распределения обладает тем свойством, что  $P(\xi \geq \mu) = P(\xi \leq \mu)$ .

Рассмотрим примеры наиболее часто встречающихся статистик (или *выборочных характеристик*):

- Выборочное среднее:

$$\bar{x}_n := \sum_{i=1}^n x_i; \tag{1}$$

- Выборочная дисперсия:

$$S_n^2 := \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2; \tag{2}$$

- Выборочный момент порядка  $k$ :

$$\hat{\mu}_k = \frac{1}{n} \sum_{i=1}^n x_i^k \tag{3}$$

- Выборочный центральный момент порядка  $k$ :

$$\widehat{M}_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^k; \tag{4}$$

- Порядковые статистики: упорядочим элементы выборки по возрастанию, получим последовательность

$$x_{(1)}, \dots, x_{(n)}. \tag{5}$$

Она называется вариационным рядом выборки, а её элементы — порядковыми статистиками. Случайные величины  $\xi_{(n)}$  со значениями  $x_{(n)}$  также называются порядковыми статистиками. Более формально,

$$x_{(1)} := \min(x_1, \dots, x_n), \tag{6}$$

$$x_{(2)} := \max[\min(x_1, \dots, \widehat{x}_k, \dots, x_n)], \tag{7}$$

$$x_{(3)} := \max[\min_{i \neq j}(x_1, \dots, \widehat{x}_i, \dots, \widehat{x}_j, \dots, x_n)], \tag{8}$$

$$\dots \tag{9}$$

$$x_{(n)} := \max(x_1, \dots, x_n), \tag{10}$$

где «крышка», как обычно, означает пропуск этого элемента.

- Выборочная медиана:

$$\hat{\mu} = \begin{cases} x_{(m)}, & n = 2m - 1; \\ \frac{1}{2}(x_{(m)} + x_{(m+1)}), & n = 2m. \end{cases} \tag{11}$$

**Пример 1.3.** Рассмотрим равномерное распределение на  $[0, \theta]$ ,  $\theta$  — неизвестный параметр. Параметр  $\theta$  можно оценить двумя способами:

1.  $\hat{\theta}^1 = 2\bar{x}_n$  — несмещённая оценка
2.  $\hat{\theta}^2 = x_{(n)}$  (оценка по крайней точке) — смещённая, но средне-квадратичная ошибка меньше, чем у  $\hat{\theta}^1$ .

## 2.2. Эмпирическая функция распределения

### 2.2.1. ОПРЕДЕЛЕНИЕ И СВОЙСТВА

**Определение.** Эмпирической функцией распределения для данной выборки  $x_1, \dots, x_n$  называется функция

$$\hat{F}_n(x; x_1, \dots, x_n) = \frac{1}{n} \sum_{k=1}^n I_{(-\infty, x]}(x_k) = \frac{1}{n} \sum_{k=1}^n I_{(x_k \leq x)},$$

где  $I_A(x) = \begin{cases} 1, & x \in A; \\ 0, & x \notin A. \end{cases}$  — индикатор множества  $A$ .

Перейдем от выборки  $x_1, \dots, x_n$  к вариационному ряду (совокупности порядковых статистик); иными словами, упорядочим выборку по возрастанию:  $x_{(1)}, \dots, x_{(n)}$ . Тогда, очевидно, эмпирическая функция распределения может быть записана в виде

$$\hat{F}_n(x; x_1, \dots, x_n) = \hat{F}_n(x; x_{(1)}, \dots, x_{(n)}) = \begin{cases} 0, & x < x_{(1)}; \\ \frac{k}{n}, & x_{(k)} \leq x < x_{(k+1)}, 1 \leq k \leq n-1; \\ 1 & x \geq x_{(n)}. \end{cases}$$

Если выборка  $x_1, \dots, x_n$  фиксирована, то эмпирическая функция распределения — это функция от переменной  $x \in \mathbb{R}$ :  $\hat{F}_n(x; x_1, \dots, x_n) = \hat{F}_n(x)$ . Она является функцией распределения некоторой случайной величины  $\xi$  (проверьте это!):  $\hat{F}_n(x) = F_\xi(x) = \mathbf{P}(\xi \leq x)$ .

Если же выборка не фиксирована, а случайные величины  $\xi_1, \dots, \xi_n$ , породившие эту выборку, независимы и одинаково распределены с функцией распределения  $F(x)$ , то можно рассматривать  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$ . Для каждого  $x \in \mathbb{R}$  это случайная величина:  $\hat{F}_n(x; \xi_1, \dots, \xi_n) = \hat{F}_n(x; \omega)$ .

**Теорема 2.2.** 1) Случайная величина  $n\hat{F}_n(x; \xi_1, \dots, \xi_n)$  имеет биномиальное распределение с параметрами  $(n, p = F(x))$  при любом фиксированном  $x \in \mathbb{R}$ ;

2)  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  является несмещённой состоятельной оценкой  $F(x)$ ;

3)  $\mathbf{P}\left(\lim_{n \rightarrow \infty} \hat{F}_n(x; \xi_1, \dots, \xi_n) = F(x), \forall x \in \mathbb{R}\right) = 1$ ;

4)  $n\hat{F}_n(x; \xi_1, \dots, \xi_n) \xrightarrow{d} \mathcal{N}\left(F(x), \frac{F(x)(1-F(x))}{n}\right)$ ,  $n \rightarrow \infty$ .

□ Найдем распределение случайной величины  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  при любом фиксированном  $x \in \mathbb{R}$ . Если  $\xi_k \leq x$ , то  $I_{(-\infty, x]}(\xi_k) = 1$ , а если  $\xi_k > x$ , то  $I_{(-\infty, x]}(\xi_k) = 0$ . Значит, при каждом  $x \in \mathbb{R}$   $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  — это частота наступления события  $\{\xi_k \leq x\}$ , вероятность которого равна  $\mathbf{P}(\xi_k \leq x) = F_{\xi_k}(x) = F(x)$ . Отсюда получаем, что случайная величина  $n\hat{F}_n(x; \xi_1, \dots, \xi_n)$  имеет биномиальное распределение с параметрами  $(n, p = F(x))$  при любом фиксированном  $x \in \mathbb{R}$  (утверждение 1) теоремы). Её математическое ожидание и дисперсия соответственно равны  $np$  и  $np(1-p)$ , поэтому получаем

$$\mathbf{M}\hat{F}_n(x; \xi_1, \dots, \xi_n) = F(x), \quad \mathbf{D}\hat{F}_n(x; \xi_1, \dots, \xi_n) = \frac{F(x)(1-F(x))}{n} \quad \forall x \in \mathbb{R}. \quad (12)$$

Таким образом, эмпирическую функцию распределения  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  можно рассматривать как оценку (теоретической) функции распределения  $F(x)$ . Поскольку  $\mathbf{M}\hat{F}_n(x; \xi_1, \dots, \xi_n) = F(x)$ , то эта оценка несмещённая, а в силу неравенства Чебышева  $\mathbf{P}(|\hat{F}_n(x; \xi_1, \dots, \xi_n) - F(x)| \geq \varepsilon) \leq \frac{\mathbf{D}\hat{F}_n}{\varepsilon^2} = \frac{p(1-p)}{n\varepsilon^2} \rightarrow 0, n \rightarrow \infty \forall x \in \mathbb{R}$ , т.е.  $\hat{F}_n(x; \xi_1, \dots, \xi_n) \xrightarrow{\mathbf{P}} F(x), n \rightarrow \infty \forall x \in \mathbb{R}$ , значит эта оценка состоятельная. Таким образом, утверждение 2) также доказано.

Утверждение 3) следует из УЗБЧ для схемы Бернулли (теорема Бореля), а утверждение 4) — из формул (12) и центральной предельной теоремы для независимых одинаково распределённых случайных величин, применённой к сумме  $n\hat{F}_n(x; \xi_1, \dots, \xi_n) = \sum_{k=1}^n I_{(-\infty, x]}(\xi_k)$ . ■

**Задача 2.1.** Доказать, что  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  является эффективной оценкой  $F(x) \forall x \in \mathbb{R}$ .

На самом деле имеет место еще более сильное утверждение, чем утверждение 3) доказанной теоремы, а именно равномерная сходимости  $\hat{F}_n(x; \xi_1, \dots, \xi_n)$  к  $F(x)$  с вероятностью 1, что и составляет содержание следующей теоремы.

### 2.2.2. ТЕОРЕМА ГЛИВЕНКО – КАНТЕЛЛИ

**Теорема 2.3 (Гливенко – Кантелли).** Пусть  $\xi_1, \dots, \xi_n$  – взаимно независимые, одинаково распределенные случайные величины с функцией распределения  $F(x)$ ;  $\widehat{F}_n(x; \xi_1, \dots, \xi_n) = \frac{1}{n} \sum_{k=1}^n I_{(-\infty, x]}(\xi_k)$  – их эмпирическая функция распределения. Тогда

$$\mathbb{P} \left( \lim_{n \rightarrow \infty} \sup_x \left| \widehat{F}_n(x; \xi_1, \dots, \xi_n) - F(x) \right| = 0 \right) = 1$$

(т. е.  $\widehat{F}_n(x; \xi_1, \dots, \xi_n)$  равномерно сходится к  $F(x)$  с вероятностью 1).

**Замечание.** Для определения эмпирической функции распределения в теореме Гливенко – Кантелли не требуется понятия выборки: она определяется для заданного (известного) набора взаимно независимых одинаково распределенных случайных величин.

□ Для краткости будем обозначать эмпирическую функцию распределения через  $\widehat{F}_n(x) = \widehat{F}_n(x; \omega)$ . По условию теоремы,  $F(x)$  – функция распределения случайных величин  $\xi_1, \dots, \xi_n$ . Рассмотрим два случая.

1) Пусть  $F(x)$  – непрерывная и строго монотонная функция. Фиксируем произвольное  $\varepsilon > 0$  и  $k \in \mathbb{N}$ ,  $k \neq 1$ :  $\frac{1}{k} \leq \varepsilon$ . Поскольку функция  $F(x)$  непрерывна и строго монотонна, то для каждого  $i = 0, \dots, k$  найдется  $x_i$ :  $F(x_i) = \frac{i}{k}$  (возможно,  $x_1 = -\infty$  или  $x_k = +\infty$ ), причем такие  $x_1, \dots, x_k$  определены однозначно. Для соседних точек, по определению,

$$F(x_{i+1}) - F(x_i) = \frac{1}{k} \leq \varepsilon. \quad (13)$$

Зафиксируем  $i$  и произвольную точку  $x$ :  $x_i < x < x_{i+1}$ . В силу монотонности функций  $F$  и  $\widehat{F}$  имеем:

$$\widehat{F}_n(x_i) - F(x_{i+1}) \leq \widehat{F}_n(x) - F(x) \leq \widehat{F}_n(x_{i+1}) - F(x_i), \quad (14)$$

и используя неравенство (13), отсюда получаем:

$$\begin{aligned} \widehat{F}_n(x_i) - F(x_i) - \varepsilon &\leq \widehat{F}_n(x) - F(x) \leq \widehat{F}_n(x_{i+1}) - F(x_{i+1}) + \varepsilon, \\ |\widehat{F}_n(x) - F(x)| &\leq \max_{0 \leq i \leq k} |\widehat{F}_n(x_i) - F(x_i)| + \varepsilon, \quad \forall x \in \mathbb{R}, \implies \\ \sup_{x \in \mathbb{R}} |\widehat{F}_n(x) - F(x)| &\leq \max_{0 \leq i \leq k} |\widehat{F}_n(x_i) - F(x_i)| + \varepsilon, \quad \forall \varepsilon > 0, \text{ где } \frac{1}{k} \leq \varepsilon. \end{aligned} \quad (15)$$

Рассмотрим событие  $A_i = \{\omega : \widehat{F}_n(x_i; \omega) \rightarrow F(x_i), n \rightarrow \infty\}$ . По УЗБЧ для схемы Бернулли  $\mathbb{P}(A_i) = 1$ . Далее, рассмотрим событие  $A^{(k)} = \bigcap_{i=1}^k A_i$ . Его вероятность равна  $\mathbb{P}(A^{(k)}) = 1$  (проверьте!). Очевидно, событие  $A^{(k)}$  равносильно тому, что  $\max_{0 \leq i \leq k} |\widehat{F}_n(x_i; \omega) - F(x_i)| \rightarrow 0, n \rightarrow \infty$ . Определим события

$$\tilde{A} = \bigcap_{k=2}^{\infty} A^{(k)}, \quad B = \left\{ \omega : \sup_{x \in \mathbb{R}} |\widehat{F}_n(x; \omega) - F(x)| \rightarrow 0, n \rightarrow \infty \right\}.$$

В силу неравенства (15)  $\tilde{A} \subset B$ , а поскольку  $\mathbb{P}(\tilde{A}) = 1$ , то и  $\mathbb{P}(B) = 1$ .

2) Пусть теперь  $F(x)$  – произвольная (неубывающая) непрерывная функция. Тогда определим  $x_i$  так:

$$x_i = \inf \left\{ x : F(x-0) \leq \frac{i}{k} \leq F(x) \right\}.$$

Далее рассуждаем аналогично первому случаю. Осталось заметить, что при применении УЗБЧ для схемы Бернулли в данном случае нужно представить событие  $A_i$  в виде  $A_i = A'_i \cap A''_i$ , где

$$A'_i = \left\{ \omega : \widehat{F}_n(x_i; \omega) \rightarrow F(x_i), n \rightarrow \infty \right\}, \quad A''_i = \left\{ \omega : \widehat{F}_n(x_i - 0; \omega) \rightarrow F(x_i - 0), n \rightarrow \infty \right\}.$$

Вероятность каждого из этих событий равна  $\mathbb{P}(A'_i) = \mathbb{P}(A''_i) = 1$ , поэтому и  $\mathbb{P}(A_i) = 1$ ; дальнейшие рассуждения в точности такие же, как и в случае 1). ■

### 2.2.3. СТАТИСТИКА КОЛМОГОРОВА

Пусть дана случайная выборка  $\xi_1, \dots, \xi_n$  — независимые одинаково распределенные случайные величины с непрерывной функцией распределения  $F(x)$ .

**Определение.** Случайная величина  $D_n = D_n(\xi_1, \dots, \xi_n) = \sup_{x \in \mathbb{R}} |\widehat{F}_n(x; \xi_1, \dots, \xi_n) - F(x)|$  называется статистикой Колмогорова.

В терминах статистики Колмогорова теорему Гливленко–Кантелли можно переформулировать так:  $D_n$  сходится к нулю при  $n \rightarrow \infty$  с вероятностью 1 (т. е. Р-п.н.).

Вид асимптотической функции распределения статистики  $\sqrt{n}D_n$  дает следующая теорема.

**Теорема 2.4 (Колмогоров).** Если функция  $F(x)$  непрерывна, то при любом  $y > 0$

$$\lim_{n \rightarrow \infty} \mathbb{P}(\sqrt{n}D_n \leq y) = K(y) := \sum_{m=-\infty}^{\infty} (-1)^m e^{-2m^2 y^2}.$$

**Замечание.** Для  $y \leq 0$ , очевидно,  $\mathbb{P}(\sqrt{n}D_n \leq y) = 0$ .

Участвующая в теореме функция  $K(y) = \sum_{m=-\infty}^{\infty} (-1)^m e^{-2m^2 y^2}$ ,  $y > 0$  называется функцией Колмогорова.

Мы докажем только часть теоремы Колмогорова, а именно следующую лемму:

**Лемма 2.5.** Распределение статистики Колмогорова  $D_n(\xi_1, \dots, \xi_n)$ , где  $\xi_1, \dots, \xi_n$  — независимые одинаково распределенные случайные величины с непрерывной функцией распределения  $F(x)$ , не зависит от вида функции  $F(x)$ .

□ Рассмотрим два случая.

1) Пусть  $y = F(x)$  — непрерывная и строго монотонная функция. Тогда существует обратная функция:  $x = F^{-1}(y)$ . Рассмотрим случайные величины  $Y_1, \dots, Y_n$ ,  $Y_k = F(\xi_k)$ ,  $k = 1, \dots, n$ . Они независимы и имеют одинаковое равномерное распределение на отрезке  $[0, 1]$ :

$$R(y) = \mathbb{P}(Y_k \leq y) = \mathbb{P}(F(\xi_k) \leq y) = \mathbb{P}(\xi_k \leq F^{-1}(y)) = F(F^{-1}(y)) = y, \quad 0 < y < 1.$$

Эмпирическая функция распределения  $Y_1, \dots, Y_n$ :

$$\widehat{R}_n(y; Y_1, \dots, Y_n) = \frac{1}{n} \sum_{k=1}^n I_{\{Y_k \leq y\}} = \frac{1}{n} \sum_{k=1}^n I_{\{\xi_k \leq F^{-1}(y)\}} = \widehat{F}_n(F^{-1}(y)),$$

где  $\widehat{F}_n(x) = \widehat{F}_n(x; \xi_1, \dots, \xi_n)$  — эмпирическая функция распределения случайной выборки  $\xi_1, \dots, \xi_n$ .

Рассмотрим очевидное равенство

$$\sup_{x: 0 < F(x) < 1} |\widehat{F}_n(x) - F(x)| = \sup_{y: 0 < y < 1} |\widehat{R}_n(y) - R(y)|.$$

Его левая часть с вероятностью 1 совпадает с  $D_n(\xi_1, \dots, \xi_n)$ , а правая часть — с  $D_n(Y_1, \dots, Y_n)$ . Статистика  $D_n(Y_1, \dots, Y_n)$  от вида функции  $F(x)$  не зависит, поскольку от  $F(x)$  не зависит распределение случайных величин  $Y_1, \dots, Y_n$ .

Для завершения доказательства осталось показать, что на множестве  $C = \{x : F(x) = 0 \text{ или } F(x) = 1\}$  эмпирическая функция распределения  $\widehat{F}_n(x)$  и теоретическая  $F(x)$  совпадают с вероятностью 1. Для этого достаточно проверить, что  $\mathbb{P}\left(\sup_{x \in C} |\widehat{F}_n(x) - F(x)| = 0\right) = 1$ . Проверку этого факта мы предоставляем читателю.

2) Если функция  $F(x)$  — произвольная (неубывающая) непрерывная функция, то рассуждения аналогичны предыдущему случаю, только в этом случае нужно положить  $F^{-1}(y) = \sup\{x : F(x) = y\}$ . Читателю рекомендуется аккуратно провести рассуждения для этого случая самостоятельно. ■

### 2.2.4. КРИТЕРИЙ КОЛМОГОРОВА

Рассмотрим две гипотезы о функции распределения  $F(x)$ :  $H_0: F(x) = F_0(x)$  (нулевая гипотеза), где  $F_0(x)$  — заданная непрерывная функция распределения;  $H_1: F(x) \neq F_0(x)$  (альтернативная гипотеза).

Статистика Колмогорова позволяет сформулировать критерий, согласно которому выбирается одна из этих двух гипотез. А именно:

**Критерий Колмогорова.** Если  $\sqrt{n}D_n > y_*$ , то  $H_0$  отклоняем ( $H_1$  принимаем), если же  $\sqrt{n}D_n \leq y_*$ , то  $H_0$  принимаем ( $H_1$  отклоняем). Здесь число  $y_*$  называется критическим значением и равно  $y_* = y_{1-\alpha}$  — квантиль уровня  $(1 - \alpha)$  функции Колмогорова  $K(y)$  (т. е. решение уравнения  $K(y) = 1 - \alpha$ ).

На практике для заданного  $\alpha$  квантиль  $y_{1-\alpha}$  находится по таблице квантилей функции Колмогорова.

Действительно, по теореме Колмогорова  $\mathbb{P}_{H_0}(\sqrt{n}D_n > y_*) = 1 - \mathbb{P}_{H_0}(\sqrt{n}D_n \leq y_{1-\alpha}) \xrightarrow{n \rightarrow \infty} 1 - K(y_{1-\alpha}) = 1 - (1 - \alpha) = \alpha$ , т. е. вероятность ошибки I рода приближенно равна  $\alpha$  (если  $n$  достаточно велико).

### 2.2.5. ВЫБОРОЧНЫЕ ХАРАКТЕРИСТИКИ КАК ХАРАКТЕРИСТИКИ ЭМПИРИЧЕСКОЙ ФУНКЦИИ РАСПРЕДЕЛЕНИЯ

Напомним некоторые определенные в п. 2.1.4 выборочные характеристики — выборочное среднее и выборочную дисперсию:

$$\bar{x} = \frac{x_1 + \dots + x_n}{n}, \quad s^2 = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}.$$

**Утверждение 2.6.**  $\bar{x}$  и  $s^2$  — соответственно математическое ожидание и дисперсия эмпирического распределения (т. е. распределения, определяемого функцией распределения  $\hat{F}_n(x; x_1, \dots, x_n) = \hat{F}_n(x)$ ).

□ Обозначим эмпирическое распределение  $\hat{\xi}$ ,  $\hat{F}_n(x)$  — функция распределения  $\hat{\xi}$ . Тогда доказательство следует из соотношений

$$\begin{aligned} M\hat{\xi} &= \int_{\mathbb{R}} x d\hat{F}_n(x) = \frac{1}{n} \sum_{k=1}^n \int_{\mathbb{R}} x dI_{\{x \geq x_k\}} = \frac{1}{n} \sum_{k=1}^n x_k = \bar{x}; \\ D\hat{\xi} &= \int_{\mathbb{R}} (x - \bar{x})^2 d\hat{F}_n(x) = \frac{1}{n} \sum_{k=1}^n \int_{\mathbb{R}} (x - \bar{x})^2 dI_{\{x \geq x_k\}} = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2 = s^2. \end{aligned}$$

Здесь мы воспользовались определением эмпирической функции распределения, линейностью интеграла Стильтеса и формулой для интеграла Стильтеса  $\int f(x) dg(x) = f(\xi)c$ , где  $g(x)$  — функция одного скачка (в точке  $\xi$ ),  $c = g(\xi + 0) - g(\xi - 0)$  — величина скачка. ■

Аналогично можно показать, что выборочные моменты порядка  $k$  являются моментами порядка  $k$  эмпирического распределения. Покажем, что выборочные моменты можно рассматривать как хорошие оценки моментов теоретического распределения.

Пусть  $x_1, \dots, x_k$  — выборка, порожденная независимыми одинаково распределенными случайными величинами  $\xi_1, \dots, \xi_n \sim \xi$ ,  $F(x)$  — их (теоретическая) функция распределения (неизвестная, или известно в каком классе лежит, но неизвестно какая именно). Её  $k$ -тый момент равен

$$\mu_k = \int_{-\infty}^{+\infty} x^k dF(x), \quad k \in \mathbb{N}.$$

( $\mu_1$  — математическое ожидание,  $\mu_2$  — второй момент,  $\sigma^2 = \mu_2 - \mu_1^2$  — дисперсия, и т.д.). Рассмотрим выборочные моменты — моменты эмпирического распределения:

$$\hat{\mu}_{k,n} = \frac{1}{n} \sum_{i=1}^k x_i^k = \frac{x_1^k + \dots + x_n^k}{n} = \int_{-\infty}^{+\infty} x^k d\hat{F}_n(x).$$

Если рассматривать  $\hat{\mu}_{k,n}$  как оценки  $\mu_k$ , то легко получаем следующие её свойства:

- 1) Несмещённость:  $M\hat{\mu}_{k,n} = M\left(\frac{\xi_1^k + \dots + \xi_n^k}{n}\right) = M\xi^k = \mu_k$ ;
- 2) Состоятельность: по закону больших чисел  $\hat{\mu}_{k,n} \xrightarrow{n \rightarrow \infty} M\hat{\mu}_{k,n} = \mu_k \implies \hat{\mu}_{k,n} \xrightarrow{P} \mu_k, n \rightarrow \infty$ .

### 2.2.6. РАСПРЕДЕЛЕНИЕ ПОРЯДКОВЫХ СТАТИСТИК

Пусть  $\xi_1, \dots, \xi_n$  — случайная выборка с теоретической функцией распределения  $F(x)$ ,  $\xi_{(1)}, \dots, \xi_{(n)}$  — её порядковые статистики.

Найдем распределение  $\xi_{(k)}$ ,  $k \in \mathbb{N}$ . Пусть  $G_{\xi_{(k)}}(x) = P(\xi_{(k)} \leq x)$  — функция распределения  $\xi_{(k)}$ . При каждом фиксированном  $x \in \mathbb{R}$  имеем:

$$G_{\xi_{(k)}}(x) = P(\xi_{(k)} \leq x) = P\left(\hat{F}_n(x) \geq \frac{k}{n}\right) = \sum_{i=k}^n C_n^i (F(x))^i (1 - F(x))^{n-i}.$$

**Пример 2.1.** Пусть  $F(x)$  — функция распределения равномерного распределения на отрезке  $[0, 1]$ :  $F(x) = x$ ,  $0 < x < 1$ . Тогда

$$G_{\xi_{(k)}}(x) = P(\xi_{(k)} \leq x) = \sum_{i=k}^n C_n^i x^i (1 - x)^{n-i}.$$

Найдем плотность этого распределения. Для этого продифференцируем функцию распределения:

$$\begin{aligned} (G_{\xi_{(k)}}(x))'_x &= \sum_{i=k}^n i C_n^i x^{i-1} (1-x)^{n-i} - \sum_{i=k}^{n-1} (n-i) C_n^i x^i (1-x)^{(n-1)-i} = \\ &= \sum_{i=k}^n n C_{n-1}^{i-1} x^{i-1} (1-x)^{(n-1)-(i-1)} - \sum_{i=k}^{n-1} n C_{n-1}^i x^i (1-x)^{(n-1)-i} = \\ &= n C_{n-1}^{k-1} x^{k-1} (1-x)^{(n-1)-(k-1)} + n C_{n-1}^k x^k (1-x)^{n-k-1} + \dots - n C_{n-1}^k x^k (1-x)^{n-k-1} - \dots = n C_{n-1}^{k-1} x^{k-1} (1-x)^{n-k}. \end{aligned}$$

(во втором равенстве воспользовались тождествами  $i C_n^i = n C_{n-1}^{i-1}$ ,  $(n-i) C_n^i = n C_{n-1}^i$ ). Таким образом, плотность распределения  $\xi_{(k)}$  равна  $[P(\xi_{(k)} \leq x)]' = n C_{n-1}^{k-1} x^{k-1} (1-x)^{n-k} = \frac{n!}{(k-1)!(n-k)!} x^{k-1} (1-x)^{n-k}$ , а функция распределения —

$$G_{\xi_{(k)}}(x) = P(\xi_{(k)} \leq x) = \frac{n!}{(k-1)!(n-k)!} \int_0^x t^{k-1} (1-t)^{n-k} dt, \quad 0 < x < 1. \quad (16)$$

**Определение.** Пусть  $a > 0$ ,  $b > 0$ . Распределение с плотностью

$$p(x) = \begin{cases} \frac{1}{B(a,b)} x^{a-1} (1-x)^{b-1}, & 0 < x < 1; \\ 0, & x \leq 0 \text{ или } x \geq 1, \end{cases}$$

где  $B(a,b) = \int_0^1 t^{a-1} (1-t)^{b-1} dt$  — бета-функция (эйлеров интеграл I рода), называется бета-распределением с параметрами  $a > 0$ ,  $b > 0$ . Функция распределения бета-распределения  $I_x(a,b) = \frac{1}{B(a,b)} \int_0^x t^{a-1} (1-t)^{b-1} dt$  ( $0 < x < 1$ ) называется неполной бета-функцией.

Из математического анализа известно, что  $B(a,b) = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}$ , где  $\Gamma(\lambda) = \int_0^\infty x^{\lambda-1} e^{-x} dx$  — гамма-функция Эйлера (эйлеров интеграл II рода), и для  $n \in \mathbb{N}$   $\Gamma(n+1) = n!$ , поэтому формулу (16) можно переписать в виде

$$G_{\xi_{(k)}}(x) = P(\xi_{(k)} \leq x) = \frac{1}{B(k, n-k+1)} \int_0^x t^{k-1} (1-t)^{n-k} dt = I_x(k, n-k+1), \quad 0 < x < 1.$$

Таким образом, нами доказан следующий результат.

**Утверждение 2.7.** *Распределение порядковой статистики  $\xi_{(k)}$ ,  $1 \leq k \leq n$ , для случайной выборки  $\xi_1, \dots, \xi_n$  с равномерным распределением на отрезке  $[0, 1]$  является бета-распределением с параметрами  $a = k$ ,  $b = n - k + 1$ .*

**Замечание.** Функция распределения порядковых статистик в случае произвольной непрерывной функции распределения  $F(x)$  случайной выборки  $\xi_1, \dots, \xi_n$  имеет вид  $P(\xi_{(k)} \leq x) = I_{F(x)}(k, n-k+1)$ .

### 2.3. Функция правдоподобия. Регулярные модели

Пусть в некоторой статистической модели  $(X, \mathcal{A}_X, \mathcal{P} = \{P_\theta, \theta \in \Theta\})$  имеется выборка  $x = (x_1, \dots, x_n)$ , порожденная случайной выборкой  $\xi_1, \dots, \xi_n \sim \xi(\theta)$ , где случайные величины  $\xi_1, \dots, \xi_n$  независимы и одинаково распределены с функцией распределения  $F_\theta(x)$ ,  $\theta \in \Theta$  — параметр распределения.

Оценка параметра  $\theta$  — это подходящая статистика (измеримая функция от выборочных данных):  $\hat{\theta} = \hat{\theta}(x)$ . Пусть имеются две оценки параметра  $\theta$ . Определим, что значит, что одна оценка «лучше» другой.

**Определение.** Пусть  $\hat{\theta}_1$  и  $\hat{\theta}_2$  — две оценки параметра  $\theta$ . Говорят, что оценка  $\hat{\theta}_1$  лучше (или предпочтительней) оценки  $\hat{\theta}_2$ , если

$$\begin{aligned} M_\theta(\hat{\theta}_1 - \theta)^2 &\leq M_\theta(\hat{\theta}_2 - \theta)^2 \quad \forall \theta \in \Theta, \\ \text{и } \exists \theta_0: \quad M_{\theta_0}(\hat{\theta}_1 - \theta_0)^2 &< M_{\theta_0}(\hat{\theta}_2 - \theta_0)^2. \end{aligned}$$

**Определение.** Эффективной оценкой параметра  $\theta$  называется несмещенная оценка с минимальной дисперсией, т. е. такая оценка  $\hat{\theta}^*$ , для которой выполнены следующие свойства:

- 1)  $M_\theta \hat{\theta}^* = \theta \quad \forall \theta \in \Theta$ ;
- 2)  $M_\theta (\hat{\theta}^* - \theta)^2 = \min_{\hat{\theta}: M_\theta \hat{\theta} = \theta} M_\theta (\hat{\theta} - \theta)^2$ .

Напомним, что для несмещенных оценок среднеквадратичное отклонение совпадает с дисперсией:

$$M_\theta (\hat{\theta} - \theta)^2 = M_\theta (\hat{\theta} - M\hat{\theta})^2 = D\hat{\theta}.$$

Таким образом, эффективная оценка — это наилучшая из всех несмещенных оценок. Аналогично можно определить эффективную оценку в классе оценок с заданным смещением  $\Delta$ :  $M_\theta \hat{\theta}_1 = M_\theta \hat{\theta}_2 = \Delta$ .

Нас будут интересовать два случая: распределение  $\xi$  дискретно (с распределением вероятностей  $P_\theta$ ) или абсолютно непрерывно (с плотностью  $p(\theta; x)$ ). Чтобы в дальнейшем не рассматривать эти случаи отдельно, введем следующее удобное обозначение:

$$f(\theta; x) = \begin{cases} P_\theta(\xi = x), & \text{если модель дискретна;} \\ p(\theta; x), & \text{если модель абсолютно непрерывна.} \end{cases}$$

В дальнейшем придется интегрировать по выборочному пространству, поэтому отметим, что если модель дискретна, то интегрирование заменяется суммированием (для краткости, мы будем проводить все выкладки для абсолютно непрерывной модели).

**Определение.** Функцией правдоподобия (для данной выборки  $x_1, \dots, x_n$ ) называется следующая функция (параметра  $\theta$ ):

$$L(\theta; x_1, \dots, x_n) := \prod_{i=1}^n f(\theta; x_i), \quad \theta \in \Theta.$$

В дальнейшем для краткости мы будем писать  $L(\theta; x) = L(\theta; x_1, \dots, x_n)$ ,  $x = (x_1, \dots, x_n)$ .

**Определение.** Статистическая модель называется регулярной (по Рао–Крамеру), если выполнены следующие условия (регулярности):

- 1)  $L(\theta; x) > 0$  и дифференцируема по  $\theta \quad \forall \theta \in \Theta$  и  $\forall x \in X$ ;
- 2) Случайная величина  $U(\theta; x) = \frac{\partial \ln L(\theta; x)}{\partial \theta} = \sum_{i=1}^n \frac{\partial \ln f(\theta; x_i)}{\partial \theta}$  (которая называется функцией вклада выборки) имеет ограниченную дисперсию:

$$0 < M_\theta^2 U(\theta; x) < \infty, \quad \forall \theta \in \Theta.$$

- 3) Для любой статистики  $\hat{\theta} = \hat{\theta}(x)$  имеет место равенство

$$\frac{\partial}{\partial \theta} \int_X \hat{\theta}(x) L(\theta; x) dx = \int_X \hat{\theta}(x) \frac{\partial L(\theta; x)}{\partial \theta} dx$$

(Это означает, что выборочное пространство  $X$  не зависит от параметра  $\theta$ ).

**Пример 3.1.** (нерегулярной модели). Рассмотрим модель  $R(0, \theta)$  (равномерное распределение на отрезке  $(0, \theta)$ ,  $\theta > 0$ ). Условие 3) регулярности для этой модели не выполнено:

$$\frac{\partial}{\partial \theta} \left( \int_0^\theta \frac{1}{\theta} dx \right) = \frac{\partial}{\partial \theta} \left( \frac{1}{\theta} \theta \right) = \frac{\partial}{\partial \theta} (1) = 0, \quad \text{но} \quad \int_0^\theta \frac{\partial}{\partial \theta} \left( \frac{1}{\theta} \right) dx = - \int_0^\theta \frac{1}{\theta^2} dx = -\frac{1}{\theta}.$$

Таким образом, эта модель не является регулярной.

**Задача 2.2.** Проверить условие регулярности 3) для экспоненциального распределения с плотностью

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

## 2.4. Количество информации Фишера. Неравенство Рао – Крамера

### 2.4.1. ИНФОРМАЦИЯ ФИШЕРА

Пусть модель регулярна. Рассмотрим тождество  $\int_X L(\theta; x) dx \equiv 1$  (оно выполнено, так как  $L(\theta; x)$  — плотность распределения случайного вектора  $\xi_1, \dots, \xi_n$ ). Продифференцируем его по  $\theta$ :

$$\frac{\partial}{\partial \theta} \int_X L(\theta; x) dx = \int_X \frac{\partial \ln L(\theta; x)}{\partial \theta} L(\theta; x) dx = 0.$$

Отсюда следует, что математическое ожидание функции вклада равно 0:  $M_\theta U(\theta; x) = M_\theta \frac{\partial \ln L(\theta; x)}{\partial \theta} = 0$ .

**Определение.** Количеством информации Фишера (или просто информацией Фишера) называется дисперсия функции вклада:

$$I_n(\theta) := D_\theta U(\theta; x) = M_\theta U^2(\theta; x) = \int_X \left( \frac{\partial \ln L(\theta; x)}{\partial \theta} \right)^2 L(\theta; x) dx.$$

Количество информации для одного наблюдения равно  $I_1(\theta) = \int_X \left( \frac{\partial \ln f(\theta; x)}{\partial \theta} \right)^2 f(\theta; x) dx$ , а поскольку наблюдения (случайные величины)  $\xi_1, \dots, \xi_n$  независимы, то информация Фишера о выборке размера  $n$  равна  $I_n(\theta) = nI_1(\theta)$ .

#### 2.4.2. НЕРАВЕНСТВО РАО – КРАМЕРА

Пусть имеется регулярная модель с параметрическим семейством распределений  $\mathcal{P} = \{P_\theta, \theta \in \Theta\}$ . Следующая теорема дает нижнюю границу дисперсий оценок произвольной дифференцируемой функции от параметра  $\theta$  в классе оценок с заданным смещением.

**Теорема 2.8 (Неравенство Рао – Крамэра<sup>2</sup>).** Пусть модель с параметрическим семейством распределений  $\mathcal{P}$  регулярна,  $x = (x_1, \dots, x_n)$  – выборка, и пусть некоторая статистика  $\hat{\theta}(x)$  оценивает дифференцируемую функцию  $\tau(\theta)$  параметра  $\theta$ . Обозначим  $b(\theta) = M_\theta \hat{\theta}(x) - \tau(\theta)$  – смещение оценки  $\hat{\theta}(x)$ . Если  $b(\theta)$  – дифференцируемая функция, то справедливо неравенство

$$D_\theta (\hat{\theta}(x) - \tau(\theta) - b(\theta)) \geq \frac{[\tau'(\theta) + b'(\theta)]^2}{I_n(\theta)},$$

где  $I_n(\theta)$  – количество информации Фишера о выборке  $x$ . При этом неравенство обращается в равенство тогда и только тогда, когда оценка  $\hat{\theta}(x)$  является линейной функцией вклада выборки, т. е.  $\hat{\theta}(x) - \tau(\theta) - b(\theta) = a(\theta)U(\theta; x)$ .

В частности, если оценка  $\hat{\theta}(x)$  несмещенная,  $M_\theta \hat{\theta}(x) = \tau(\theta)$ , то  $b(\theta) = 0$ , и с учетом  $I_n(\theta) = nI_1(\theta)$  неравенство принимает вид  $D_\theta \hat{\theta}(x) \geq \frac{(\tau'(\theta))^2}{nI_1(\theta)}$ .

□ По определению смещения оценки  $\hat{\theta}(x)$  имеем  $\tau(\theta) + b(\theta) = M_\theta \hat{\theta}(x)$ . Продифференцируем это равенство, записав  $M_\theta \hat{\theta}(x)$  в виде интеграла и пользуясь условием регулярности 3):

$$\tau'(\theta) + b'(\theta) = \frac{\partial}{\partial \theta} \int_X \hat{\theta}(x) L(\theta; x) dx = \int_X \hat{\theta}(x) \frac{\partial \ln L(\theta; x)}{\partial \theta} L(\theta; x) dx = \int_X \hat{\theta}(x) U(\theta; x) L(\theta; x) dx = M_\theta (\hat{\theta}(x) U(\theta; x)).$$

Учитывая, что  $M_\theta U(\theta; x) = 0$ , получаем:

$$\begin{aligned} \tau'(\theta) + b'(\theta) &= M_\theta (\hat{\theta}(x) U(\theta; x)) = M_\theta [(\hat{\theta}(x) - \tau(\theta) - b(\theta) + \tau(\theta) + b(\theta)) U(\theta; x)] = M_\theta [(\hat{\theta}(x) - \tau(\theta) - b(\theta)) U(\theta; x)] + \\ &+ (\tau(\theta) + b(\theta)) M_\theta U(\theta; x) = M_\theta \left[ (\hat{\theta}(x) - M_\theta \hat{\theta}(x)) (U(\theta; x) - M_\theta U(\theta; x)) \right] = \text{cov}_\theta (\hat{\theta}(x), U(\theta; x)). \end{aligned}$$

Применим к  $\text{cov}_\theta (\hat{\theta}(x), U(\theta; x))$  неравенство Коши–Буняковского  $(\text{cov}(\xi, \eta))^2 \leq D\xi \cdot D\eta$ :

$$(\tau'(\theta) + b'(\theta))^2 = (\text{cov}_\theta (\hat{\theta}(x), U(\theta; x)))^2 \leq D_\theta \hat{\theta}(x) D_\theta U(\theta; x) = D_\theta (\hat{\theta}(x) - \tau(\theta) - b(\theta)) \cdot I_n(x).$$

Отсюда следует требуемое неравенство. А так как неравенство Коши–Буняковского превращается в равенство тогда и только тогда, когда функции (в нашем случае случайные величины) линейно связаны, то и наше неравенство превращается в равенство в том и только том случае, когда (при каждом  $\theta$ )  $\hat{\theta}(x)$  и  $U(\theta; x)$  линейно связаны:  $\hat{\theta}(x) - \tau(\theta) - b(\theta) = a(\theta)U(\theta; x)$ . Теорема доказана. ■

#### 2.4.3. СЕМЕЙСТВА РАСПРЕДЕЛЕНИЙ ЭКСПОНЕНЦИАЛЬНОГО ТИПА

Если мы будем рассматривать несмещённые оценки параметра  $\theta$  ( $b(\theta) = 0$ ,  $\tau(\theta) = \theta$ ), то равенство в теореме Крамера–Рао ( $D\hat{\theta} = \frac{1}{I_n}(\theta)$ ) достигается при

$$\frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta} = K(\theta)(\hat{\theta} - \theta),$$

<sup>2</sup>а не Крамэра!



где  $K$  не зависит от выборки (это условие пропорциональности, при котором неравенство Коши–Буняковского обращается в равенство). Отсюда

$$L(\theta; x_1, \dots, x_n) = C(x_1, \dots, x_n) e^{a_1(\theta)\hat{\theta}(x_1, \dots, x_n) + a_2(\theta)}.$$

Мы получили явный вид функции правдоподобия. Это плотность параметрического семейства распределений, принадлежащих к так называемому *экспоненциальному типу*. Примерами таких распределений служат биномиальное, показательное, нормальное и другие.

#### 2.4.4. МНОГОМЕРНЫЙ СЛУЧАЙ

Пусть  $\theta = (\theta_1, \dots, \theta_s)^T$  — вектор-параметр,  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ . Рассматривается оценка  $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_s)$ ,  $\hat{\theta}_k = \hat{\theta}_k(x_1, \dots, x_n)$ . Положим

$$\lambda_j = \frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta_j}, \quad \Lambda = (\lambda_1, \dots, \lambda_s)^T.$$

В многомерном случае роль дисперсии играет *ковариационная матрица*  $\Sigma = \Sigma_{\hat{\theta}(\xi)} = M_\theta((\hat{\theta}(\xi) - M\hat{\theta}(\xi))(\hat{\theta}(\xi) - M\hat{\theta}(\xi))^T)$ ;  $\Sigma = (\sigma_{ij})$ ,  $\sigma_{ij} = M((\hat{\theta}_i - M\hat{\theta}_i)(\hat{\theta}_j - M\hat{\theta}_j)) = \text{cov}(\hat{\theta}_i, \hat{\theta}_j)$ ;  $\sigma_{ii} = \sigma_i^2$  — дисперсия, остальные — попарные ковариации. Несмещённость оценки задаётся равенством  $M_\theta \hat{\theta}(\xi) = \theta$ .

Аналогом количества информации Фишера является *информационная матрица Фишера*  $J(\theta) = M_\theta(\Lambda\Lambda^T)$ . Предположим, что эта матрица обратима (существует  $J^{-1}(\theta)$ ). Тогда имеет место аналог теоремы Крамера–Рао: матрица  $\Sigma_{\hat{\theta}(\xi)} - J^{-1}(\theta)$  является неотрицательно определённой.

### 2.5. Методы получения оценок

#### 2.5.1. МЕТОД МОМЕНТОВ

Рассматривается статистическая модель с  $s$ -мерным параметром  $\theta = (\theta_1, \dots, \theta_s)$ .  $m_k(\theta) = M\xi_i^k$  ( $i = 1, \dots, n$ , выборка повторная) —  $k$ -й момент (истинный);  $\hat{m}_k(\theta) = \frac{\xi_1^k + \dots + \xi_n^k}{n}$  — эмпирический момент. Предположим, что  $M\xi_i^s = m_s(\theta) < \infty$ . Эмпирические моменты являются оценками для истинных. Запишем систему *моментных уравнений*:

$$\begin{cases} m_k(\theta_1, \dots, \theta_s) = \hat{m}_k \\ 1 \leq k \leq s \end{cases}$$

Рассмотрим полученную систему относительно переменных  $\theta_1, \dots, \theta_s$ . Пусть существует единственное решение  $\hat{\theta}_j = f_j(\hat{m}_1, \dots, \hat{m}_s)$  ( $1 \leq j \leq s$ ). Мы получили некоторую оценку для  $\theta$ . Следующая теорема сообщает, что оценка не совсем плохая.

**Теорема 2.9 (О состоятельности статистических оценок, полученных методом моментов).** Пусть  $\hat{\theta}_1, \dots, \hat{\theta}_s$  есть решение системы моментных уравнений и пусть функции  $f_j$  непрерывны. Тогда оценки  $\hat{\theta}_j = f_j(\hat{m}_1, \dots, \hat{m}_s)$  для всех  $j$  являются состоятельными оценками параметров  $\theta_j$  (т.е.  $\hat{\theta}_j \xrightarrow[n \rightarrow \infty]{P} \theta_j$  для всех  $j$ ).

□ Это следует из непрерывности  $f_j$  и асимптотического свойства моментов:  $\hat{m}_k(n) \xrightarrow[n \rightarrow \infty]{P} m_k(\theta)$ . ■

**Пример 5.1.** Схема Бернулли.  $p = M\xi_i$  — параметр (вероятность удачи);  $\xi_i = 1$  или  $0$ .  $\bar{x} = \frac{1}{n}(x_1 + \dots + x_n)$  — первый выборочный момент.  $\hat{p} = \bar{x}$  — оценка  $p$  по методу моментов. Это хорошая оценка (несмещённая, состоятельная, эффективная в смысле неравенства Крамера–Рао).

**Пример 5.2.**  $\xi_1, \dots, \xi_n \sim \mathcal{N}(a, \sigma^2)$ ,  $M\xi_i = a$ ,  $D\xi_i = \sigma^2$ .  $\bar{x} = \hat{a}$  — хорошая оценка.  $\widehat{\sigma^2} = s^2 = \frac{1}{n}((x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2)$  — выборочная дисперсия — смещённая оценка  $\sigma^2$ . Это оценки, полученные по методу моментов. А вот такая оценка:  $\widehat{\sigma^2} = s^2 \frac{n}{n-1}$  является несмещённой.

#### 2.5.2. АСИМПТОТИЧЕСКИЕ СВОЙСТВА ОЦЕНОК

1. *Состоятельность оценки.*  $\{P_\theta \mid \theta \in \Theta\}$  — параметрическая модель,  $\hat{\theta}_n$  — оценка по выборке длины  $n$ ,  $\theta_0$  — истинное значение параметра. Оценка состоятельна, если  $\hat{\theta}_n \xrightarrow[n \rightarrow \infty]{P} \theta_0$ .
2. *Асимптотическая несмещённость.*  $M_\theta \hat{\theta}_n \xrightarrow[n \rightarrow \infty]{} \theta$  (т.е. смещение  $b_n(\theta) = M_\theta \hat{\theta}_n - \theta \xrightarrow[n \rightarrow \infty]{} 0$ ).
3. *Асимптотическая нормальность.*  $\hat{\theta}_n$  асимптотически нормальна, если существует монотонно сходящаяся к нулю последовательность положительных чисел  $\{c_n\}_{n=1}^\infty$  такая, что

$$\frac{\hat{\theta}_n - \theta}{c_n} \xrightarrow{d} Z \sim \mathcal{N}(0, 1)$$

(сходимость по распределению к некоторой случайной величине со стандартным нормальным распределением). Говорят, что  $\frac{\hat{\theta}_n - \theta}{c_n}$  асимптотически нормальна с  $\mathcal{N}(0, 1)$ , а  $\hat{\theta}_n$  асимптотически нормальна с  $\mathcal{N}(\theta, c_n^2)$ ;  $\theta$  называется асимптотическим средним, а  $c_n^2$  — асимптотической дисперсией оценки  $\hat{\theta}_n$ . Асимптотически нормальная оценка автоматически является асимптотически несмещённой. В качестве  $c_n$  обычно берут  $c_n^2 = \frac{\sigma^2(\theta)}{n}$  ( $\sigma^2$  не зависит от выборки).

**Пример 5.3.** Схема Бернулли с параметром  $p$  (вероятность успеха).  $\xi_1, \dots, \xi_n$  — выборка.

$$\hat{p} = \frac{\xi_1 + \dots + \xi_n}{n}, \quad M\hat{p} = p, \quad D\hat{p} = \frac{p(1-p)}{n} = \frac{\sigma^2(p)}{n}.$$

$\hat{p}$  асимптотически нормальна в силу теоремы Муавра – Лапласа (ЦПТ). (Обычно через эту теорему асимптотическую нормальность и доказывают.)

**Пример 5.4.**  $\xi_1, \dots, \xi_n, \xi_i \sim \mathcal{N}(a, \sigma^2)$ .  $D\bar{\xi} = \frac{\sigma^2}{n}$ .

4. *Асимптотическая эффективность.* Рассмотрим семейство распределений, подчинённых условиям регулярности, для оценок параметров которого имеет место неравенство Крамера–Рао.  $1/I_n(\theta)$  — нижняя граница дисперсий всех оценок. Коэффициент эффективности оценки:  $e_n(\hat{\theta}_n) = \frac{1/I_n(\theta)}{D\hat{\theta}_n}$ .  $0 < e_n(\hat{\theta}_n) \leq 1$ . Если  $e_n(\hat{\theta}_n) = 1$ , то оценка называется эффективной.  $e_\infty(\hat{\theta}_n) = \lim_{n \rightarrow \infty} e_n(\hat{\theta}_n)$ . Если  $e_\infty(\hat{\theta}_n) = 1$ , то оценка называется асимптотически эффективной.

*Асимптотическая эффективность в рамках асимптотической нормальности.* Пусть  $\hat{\theta}_n$  асимптотически нормальна с  $\mathcal{N}(\theta, \frac{\sigma^2(\theta)}{n})$ . Она называется асимптотически эффективной (в рамках асимптотической нормальности), если

$$\frac{1/I_n(\theta)}{\sigma^2(\theta)/n} \xrightarrow{n \rightarrow \infty} 1.$$

### 2.5.3. МЕТОД МАКСИМАЛЬНОГО (НАИБОЛЬШЕГО) ПРАВДОПОДОБИЯ

**Принцип МП в простейшем случае** Принцип МП был рассмотрен ещё Гауссом в следующей форме: найдём такие значения параметров, чтобы вероятность получить данную выборку была максимальной (берём  $\max_{\theta \in \Theta} P_\theta(\xi_1 = x_1, \dots, \xi_n = x_n) = P_{\theta^*}(\xi_1 = x_1, \dots, \xi_n = x_n)$ ).  $\theta^*$  — оценка МП (наиболее правдоподобное значение  $\theta$ ).

**Общая ситуация**  $x_1, \dots, x_n$  — выборка в  $(\mathcal{X}, \mathcal{A}, \mathcal{P})$ ,  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ .  $L(\theta; x_1, \dots, x_n)$  — функция правдоподобия. Возьмём  $\theta^*$  такое, что

$$\sup_{\theta \in \Theta} L(\theta; x_1, \dots, x_n) = L(\theta^*; x_1, \dots, x_n)$$

(если точная верхняя грань достигается).  $\theta^*$  называется *оценкой максимального правдоподобия (ОМП)*.

**Пример 5.5.**  $\xi_1, \dots, \xi_n$  взаимно независимы и равномерно распределены на  $[0, \theta]$ ;  $\theta \in \Theta = (0, +\infty)$ .  $L(\theta; x_1, \dots, x_n) = f_\theta(x_1) \cdots f_\theta(x_n)$ , где  $f_\theta(x) = \frac{1}{\theta} I_{[0, \theta]}(x)$  — плотность равномерного распределения.  $L \neq 0$  тогда и только тогда, когда для всех  $i$   $x_i \in [0, \theta]$ .

$$L = \begin{cases} \frac{1}{\theta^n} & x_{(n)} \leq \theta \\ 0 & \text{в ином случае} \end{cases}$$

Ясно, что максимум  $L$  достигается при  $\theta = \theta^* = x_{(n)} = \max_i x_i$ .  $\theta^*$  — ОМП.

Предположим, что функция  $L(\theta; x_1, \dots, x_n)$  дифференцируема по параметру  $\theta$  ( $\theta \in \Theta \subset \mathbb{R}$ ). Тогда ОМП можно найти, решая *уравнение правдоподобия*:  $\frac{\partial L(\theta)}{\partial \theta} = 0$  (или переходим к логарифмам:  $\frac{\partial \ln L}{\partial \theta} = 0$ , если это возможно). В случае  $\Theta \subset \mathbb{R}^k$  получаем систему уравнений.

**Теорема 2.10 (о свойствах ОМП — теорема Дюге).** При выполнении условий регулярности (\*) ОМП обладает следующими асимптотическими свойствами:

1. состоятельность;
2. асимптотическая нормальность и асимптотическая эффективность.

**Условия регулярности (\*):**

1.  $\Theta$  — невырожденный замкнутый интервал на  $\mathbb{R}$ ; существуют  $\frac{\partial \ln f}{\partial \theta}$ ,  $\frac{\partial^2 \ln f}{\partial \theta^2}$ ,  $\frac{\partial^3 \ln f}{\partial \theta^3}$  для  $\theta \in \Theta$ .

2. Для всех  $\theta \in \Theta$ :

$$\left| \frac{\partial \ln f}{\partial \theta} \right| \leq g_1(x), \quad \left| \frac{\partial^2 \ln f}{\partial \theta^2} \right| \leq g_2(x), \quad \left| \frac{\partial^3 \ln f}{\partial \theta^3} \right| \leq H(x),$$

где  $g_1$  и  $g_2$  интегрируемы на  $\mathbb{R}$ , а  $H$  обладает следующим свойством:

$$M_\theta H = \int_{-\infty}^{+\infty} H(x) f_\theta(x) dx < M$$

( $M$  не зависит от  $\theta$ ).

3.

$$0 < I_1(\theta) = \int_{-\infty}^{+\infty} \left( \frac{\partial \ln f}{\partial \theta} \right)^2 f_\theta(x) dx < \infty.$$

Эти условия содержат условия Крамера–Рао.

**Лемма 2.11.** Пусть

$$B_0 = \frac{1}{n} \sum_{i=1}^n \left( \frac{\partial \ln f_\theta(\xi_i)}{\partial \theta} \right) \Big|_{\theta=\theta_0} \quad B_1 = \frac{1}{n} \sum_{i=1}^n \left( \frac{\partial^2 \ln f_\theta(\xi_i)}{\partial \theta^2} \right) \Big|_{\theta=\theta_0} \quad B_2 = \frac{1}{n} \sum_{i=1}^n H(\xi_i)$$

(все  $B_j$  являются функциями от  $\xi_1, \dots, \xi_n$ ). Тогда  $B_0 \xrightarrow{P} MB_0 = 0$ ;  $B_1 \xrightarrow{P} MB_1 = -k^2$ , где  $k^2 = I_1(\theta)$ ;  $B_2 \xrightarrow{P} MH(\xi_1) < M$  (при  $n \rightarrow \infty$ ).

□ Предельные свойства  $B_1$ ,  $B_2$  и  $B_3$  следуют из ЗБЧ ( $B_j$  являются средними арифметическими независимых одинаково распределённых случайных величин с конечными математическими ожиданиями).

В условиях регулярности меняем дифференцирование по  $\theta$  и интегрирование:

$$M \frac{\partial \ln f_\theta(\xi)}{\partial \theta} = \int_{-\infty}^{+\infty} \frac{\partial \ln f_\theta(x)}{\partial \theta} f_\theta(x) dx = \int_{-\infty}^{+\infty} \frac{1}{f_\theta(x)} \cdot \frac{\partial f_\theta(x)}{\partial \theta} \cdot f_\theta(x) dx = \frac{\partial}{\partial \theta} \underbrace{\int_{-\infty}^{+\infty} f_\theta(x) dx}_{=1} = 0$$

Отсюда  $MB_0 = \frac{1}{n} \sum_{i=1}^n M \frac{\partial \ln f_\theta(\xi_i)}{\partial \theta} = 0$ .

Утверждение  $MB_1 = -k^2$  вытекает из следующей выкладки<sup>3</sup>:

$$\begin{aligned} M \frac{\partial^2 \ln f_\theta(\xi)}{\partial \theta^2} &= \int_{-\infty}^{+\infty} \frac{\partial}{\partial \theta} \frac{\partial \ln f_\theta(x)}{\partial \theta} f_\theta(x) dx = \int_{-\infty}^{+\infty} \frac{\partial}{\partial \theta} \left( \frac{1}{f_\theta(x)} \cdot \frac{\partial f_\theta(x)}{\partial \theta} \right) f_\theta(x) dx = \\ &= \int_{-\infty}^{+\infty} \frac{-1}{f_\theta^2(x)} \cdot \frac{\partial f_\theta(x)}{\partial \theta} \cdot \frac{\partial f_\theta(x)}{\partial \theta} f_\theta(x) dx + \int_{-\infty}^{+\infty} \frac{\partial^2 f_\theta(x)}{\partial \theta^2} \cdot \frac{1}{f_\theta(x)} f_\theta(x) dx = - \int_{-\infty}^{+\infty} \left( \frac{\partial f_\theta(x)}{\partial \theta} \right)^2 \frac{1}{f_\theta(x)} dx + \\ &+ \underbrace{\frac{\partial^2}{\partial \theta^2} \int_{-\infty}^{+\infty} f_\theta(x) dx}_{=0} = - \int_{-\infty}^{+\infty} \left( \frac{\partial \ln f_\theta(x)}{\partial \theta} f_\theta(x) \right)^2 \frac{1}{f_\theta(x)} dx = - \int_{-\infty}^{+\infty} \left( \frac{\partial \ln f_\theta(x)}{\partial \theta} \right)^2 f_\theta(x) dx = \\ &= -M \left( \frac{\partial \ln f_\theta(\xi)}{\partial \theta} \right)^2 = -I_1(\theta) = -k^2. \end{aligned}$$

■

**Лемма 2.12.**

1.  $X_n \xrightarrow[n \rightarrow \infty]{d} X, Y_n \xrightarrow[n \rightarrow \infty]{P} 0 \Rightarrow X_n + Y_n \xrightarrow[n \rightarrow \infty]{d} X.$
2.  $X_n \xrightarrow[n \rightarrow \infty]{d} X, Z_n \xrightarrow[n \rightarrow \infty]{P} 1 \Rightarrow X_n Z_n \xrightarrow[n \rightarrow \infty]{d} X, X_n / Z_n \xrightarrow[n \rightarrow \infty]{d} X.$

<sup>3</sup>Лектор на неё забил, но я всё же приведу её. — примеч. С. К.

(Это — задача по теории вероятностей)

□ [Доказательство теоремы Дюге]

$$\frac{\partial \ln f_\theta(x)}{\partial \theta} = \{\text{разложение Тейлора}\} = \frac{\partial \ln f_\theta}{\partial \theta} \Big|_{\theta=\theta_0} + (\theta - \theta_0) \frac{\partial^2 \ln f_\theta}{\partial \theta^2} \Big|_{\theta=\theta_0} + \frac{1}{2} \tau (\theta - \theta_0)^2 H(x)$$

( $x \in \mathbb{R}$ ,  $|\tau| < 1$ ). Вспоминаем, что  $L(\theta; x_1, \dots, x_n) = f_\theta(x_1) \cdots f_\theta(x_n)$ , и переписываем уравнение правдоподобия

$$\frac{1}{n} \frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta} = 0$$

в виде:

$$\mathbb{Y}(\theta) = B_0 + (\theta - \theta_0)B_1 + \frac{1}{2} \tau (\theta - \theta_0)^2 B_2 = 0.$$

Зададим  $\varepsilon > 0$ ,  $\delta > 0$  — малые числа. Выберем  $n > n_0(\delta, \varepsilon)$  так, чтобы

$$\mathbb{P}(|B_0| \geq \delta^2) < \frac{\varepsilon}{3} \quad \mathbb{P}\left(B_1 \geq -\frac{k^2}{2}\right) < \frac{\varepsilon}{3} \quad \mathbb{P}(|B_2| \geq 2M) < \frac{\varepsilon}{3}.$$

Положим  $S = \{x \mid |B_0| < \delta^2, B_1 < -\frac{1}{2}k^2, |B_2| < 2M\}$ . При  $n > n_0$   $\mathbb{P}(S) > 1 - \varepsilon$ . Пусть  $x \in S$ . Положим  $\theta = \theta_0 \pm \delta$ . Так как  $|B_0 + \frac{1}{2} \tau \delta^2 B_2| \leq \delta^2(1 + M)$ , при малых  $\delta$  знак выражения  $\mathbb{Y}(\theta) = B_0 \mp \delta B_1 + \frac{1}{2} \tau \delta^2 B_2$  определяется вторым слагаемым. Поэтому (при малых  $\delta$ ) если  $\theta = \theta_0 - \delta$ , то  $\frac{\partial \ln L}{\partial \theta} > 0$ , а если  $\theta = \theta_0 + \delta$ , то  $\frac{\partial \ln L}{\partial \theta} < 0$ . Отсюда по непрерывности  $\exists \theta^* \in (\theta_0 - \delta, \theta_0 + \delta)$  т.ч.  $\frac{\partial \ln L}{\partial \theta} \Big|_{\theta=\theta^*} = 0$ , т.е.  $\theta^*$  — точка максимума. Итак, с вероятностью, не меньшей, чем  $1 - \varepsilon$ , точка максимума лежит в  $(\theta_0 - \delta, \theta_0 + \delta)$ , откуда следует состоятельность.

Докажем асимптотическую нормальность и асимптотическую эффективность. Имеем  $\mathbb{Y}(\theta^*) = 0$ . Отсюда

$$\theta^* - \theta_0 = \frac{B_0}{-B_1 - \frac{1}{2} \tau (\theta^* - \theta_0) B_2}.$$

Далее ( $k^2 = I_1(\theta)$ ),

$$\frac{\theta^* - \theta_0}{\frac{1}{\sqrt{nk^2}}} = \frac{\frac{1}{\sqrt{nk^2}} \sum_{i=1}^n \frac{\partial \ln f(\xi_i)}{\partial \theta}}{-\frac{B_1}{k^2} + \frac{1}{2} \tau \frac{\theta^* - \theta_0}{k^2} B_2}.$$

$Y_i = \frac{\partial \ln f(\xi_i)}{\partial \theta}$  — независимые и одинаково распределённые с  $\mathbb{M}Y_i = 0$  и  $\mathbb{D}Y_i = \mathbb{M}Y_i^2 = k^2$ . В силу ЦПТ числитель

$$\frac{1}{\sqrt{nk^2}} \sum \frac{\partial \ln f(\xi_i)}{\partial \theta} \xrightarrow[n \rightarrow \infty]{d} Z \sim \mathcal{N}(0, 1).$$

В силу леммы 2.11  $B_1 \xrightarrow{\mathbb{P}} -k^2$ ,  $B_2 \xrightarrow{\mathbb{P}} \mathbb{M}H(\xi_1) < M$ , откуда знаменатель

$$-\frac{B_1}{k^2} + \frac{1}{2} \tau \frac{\theta^* - \theta_0}{k^2} B_2 \xrightarrow{\mathbb{P}} 1$$

(второе слагаемое оценивается через  $\frac{1}{2} \frac{M}{k^2} (\theta^* - \theta_0)$ , а  $\theta^* - \theta_0 < \delta \rightarrow 0$ ). Тогда (в силу леммы 2.12)  $\sqrt{nk^2}(\theta^* - \theta_0)$  асимптотически нормальна с  $\mathcal{N}(0, 1)$ . Отсюда  $\theta^*$  асимптотически нормальна с  $\mathcal{N}(\theta_0, \frac{1}{nk^2})$ , а т.к. асимптотическая дисперсия  $nk^2 = I_n(\theta)$ , то  $\theta^*$  асимптотически эффективна (в рамках асимптотической нормальности). ■

**Задача 2.3.** Пусть  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$  — регулярное параметрическое семейство распределений. Докажите, что если существует эффективная (в смысле неравенства Крамера–Рао) оценка  $\hat{\theta}$ , то  $\hat{\theta}$  есть ОМП.

## 2.6. О свойствах информации Фишера

$\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ ,  $x_1, \dots, x_s$  — выборка.  $L(\theta; x_1, \dots, x_n)$  — функция правдоподобия. Информация Фишера:

$$I_n(\theta) = \mathbb{M}_\theta \left( \frac{\partial \ln L(\theta; \xi_1, \dots, \xi_n)}{\partial \theta} \right)^2 =: I^\xi(\theta).$$

$I^{\xi_1}(\theta) = I_1(\theta)$  ( $I^\xi(\theta)$  — информация в выборке  $\xi$  — это просто такое обозначение). Для информации Фишера выполняются все обычные свойства информации:

**Утверждение 2.13 (свойства информации Фишера).**

1.  $I^\xi(\theta) = I^{\xi_1}(\theta) + \dots + I^{\xi_n}(\theta)$ , если  $\xi_1, \dots, \xi_n$  независимы.

2. Для повторной выборки  $I^\xi(\theta) = nI^{\xi_1}(\theta)$ .

3. Пусть  $(\mathcal{X}, \mathcal{C})$  — измеримое пространство значений статистики  $T$ ,  $\mathbf{Q}_\theta$  — распределение статистики  $T$ ,  $\tilde{L}(\theta; T(x))$  — функция правдоподобия для  $T(x)$  (статистика  $T$  не обязательно одномерна),  $I^{T(\xi)}(\theta) = \mathbf{M}_\theta \left( \frac{\partial \ln \tilde{L}(\theta; T(\xi))}{\partial \theta} \right)^2$  — информация Фишера в статистике  $T$ . Тогда  $I^\xi(\theta) \geq I^{T(\xi)}(\theta)$ .

□ Докажем только пункт 3 (остальные тривиальны), да и то лишь в дискретном случае.  $L(\theta; x) = \mathbf{P}_\theta(\xi = x)$ .

$$\tilde{L}(\theta; T(x)) = \tilde{L}(\theta; t) = \sum_{x: T(x)=t} \mathbf{P}_\theta(\xi = x)$$

$$0 \leq \mathbf{M}_\theta \left( \frac{\partial \ln L(\theta; x)}{\partial \theta} - \frac{\partial \ln \tilde{L}(\theta; T(x))}{\partial \theta} \right)^2 = I^\xi(\theta) - 2\mathbf{M}_\theta \left( \frac{\partial \ln L(\theta; x)}{\partial \theta} \cdot \frac{\partial \ln \tilde{L}(\theta; T(x))}{\partial \theta} \right) + I^{T(\xi)}(\theta).$$

Далее (здесь штрих означает производную по  $\theta$ ),

$$\tilde{L}'(\theta; t) = \sum_{x: T(x)=t} \mathbf{P}'_\theta(\xi = x) = \sum_{x: T(x)=t} L'(\theta; x),$$

откуда

$$\begin{aligned} \mathbf{M}_\theta \left( \frac{\partial \ln L}{\partial \theta} \cdot \frac{\partial \ln \tilde{L}}{\partial \theta} \right) &= \sum_t \sum_{x: T(x)=t} \frac{L'(\theta; x)}{L(\theta; x)} \cdot \frac{\tilde{L}'(\theta; T(x))}{\tilde{L}(\theta; T(x))} L(\theta; x) = \sum_t \frac{\tilde{L}'(\theta; t)}{\tilde{L}(\theta; t)} \cdot \sum_{x: T(x)=t} L'(\theta; x) = \\ &= \sum_t \frac{\tilde{L}'(\theta; t)}{\tilde{L}(\theta; t)} \tilde{L}'(\theta; t) = \sum_t \left( \frac{\tilde{L}'(\theta; t)}{\tilde{L}(\theta; t)} \right)^2 \tilde{L}(\theta; t) = \mathbf{M} \left( \frac{\tilde{L}'(\theta; T(\xi))}{\tilde{L}(\theta; T(\xi))} \right)^2 = I^{T(\xi)}(\theta), \end{aligned}$$

поэтому  $0 \leq I^\xi(\theta) - 2I^{T(\xi)}(\theta) + I^{T(\xi)}(\theta) = I^\xi(\theta) - I^{T(\xi)}(\theta)$ , то есть  $I^\xi(\theta) \geq I^{T(\xi)}(\theta)$ . ■

## 2.7. Достаточные статистики

$(\mathcal{X}, \mathcal{A}, \mathcal{P} = \{\mathbf{P}_\theta \mid \theta \in \Theta\})$  — параметрическая модель;  $x_1, \dots, x_n$  — выборка.

**Определение.** Статистика  $T(x) = T(x_1, \dots, x_n)$  называется *достаточной* (для данной модели), если для всех  $\theta \in \Theta$  и для всех  $A \in \mathcal{A}$  условная вероятность  $\mathbf{P}_\theta(A \mid T(\xi) = t)$  не зависит от  $\theta$  для всех  $t$ , для которых определена условная вероятность.

Найти достаточную статистику по определению не представляется возможным.

**Пример 7.1.** Схема Бернулли.  $T(x) = \sum x_i$ . Пусть  $t$  и  $x$  таковы, что  $T(x) = t$ . Тогда

$$\mathbf{P}_\theta(\xi = x \mid T(\xi) = t) = \frac{\mathbf{P}_\theta(\xi = x)}{\mathbf{P}_\theta(T(\xi) = t)} = \frac{\theta^t (1 - \theta)^{n-t}}{C_n^t \theta^t (1 - \theta)^{n-t}} = \frac{1}{C_n^t} \quad \text{— не зависит от } \theta.$$

Следовательно,  $T(x) = \sum x_i$  — достаточная статистика.

**Теорема 2.14 (критерий достаточности — теорема Неймана–Фишера — теорема о факторизации).**  $T$  — достаточная статистика тогда и только тогда, когда имеет место следующее представление функции правдоподобия:

$$L(\theta; x) = g_\theta(T(x))h(x) \quad g_\theta(T(x)) = g(\theta; T(x)),$$

где  $g_\theta$  и  $h$  — неотрицательные измеримые функции (каждая — в своей области).

**Замечание.**  $L(\theta; x)$  — плотность совместного распределения  $\xi_1, \dots, \xi_n$  по некоторой мере  $\mu$ ; семейство  $\{\mathbf{P}_\theta\}$  абсолютно непрерывно относительно меры  $\mu$ , плотность — производная Радона–Никодима. Нам важны два случая: а)  $\mu$  — мера Лебега, б)  $\mu$  — считающая мера.

□ [Доказательство для дискретного случая]  $x \in \mathcal{X}$  — выборка.

$$\mathbf{P}_\theta(\xi = x \mid T(\xi) = t) = \begin{cases} \frac{\mathbf{P}_\theta(\xi=x)}{\mathbf{P}_\theta(T(\xi)=t)}, & T(x) = t \\ 0, & T(x) \neq t \end{cases} \quad ^4$$

<sup>4</sup>Лектор использовал странное обозначение  $x \in \{x \mid T(x) = t\}$  — примеч. С. К.

*Необходимость.* Пусть  $T$  — достаточная статистика. Тогда положим

$$h(x) = \frac{\mathbb{P}_\theta(\xi = x)}{\mathbb{P}_\theta(T(\xi) = t)} — \text{не зависит от } \theta \text{ в силу достаточности } T,$$

откуда  $L(\theta; x) = \mathbb{P}_\theta(\xi = x) = \mathbb{P}_\theta(T(\xi) = t) \cdot h(x) = g_\theta(T(x)) \cdot h(x)$ .

*Достаточность.* Пусть  $T(x) = t$ . Тогда

$$\mathbb{P}_\theta(\xi = x | T(\xi) = t) = \frac{g_\theta(t)h(x)}{\sum_{T(x)=t} g_\theta(t)h(x)} = \frac{h(x)}{\sum h(x)} — \text{не зависит от } \theta,$$

поэтому  $T$  — достаточная статистика. ■

## 2.8. Условное математическое ожидание

**Определение.** Пусть  $(\Omega, \mathcal{A}, \mathbb{P})$  — вероятностное пространство,  $\xi$  —  $\mathcal{A}$ -измеримая функция (случайная величина),  $\mathcal{C}$  —  $\sigma$ -подалгебра в  $\mathcal{A}$ . Тогда *условным математическим ожиданием* (УМО; обозначение:  $\mathbb{M}(\xi | \mathcal{C})$ )  $\xi$  относительно  $\mathcal{C}$  (более точно, *вариантом* УМО) называется случайная величина  $\tilde{\xi}(\omega)$ , удовлетворяющая следующим условиям:

1.  $\tilde{\xi}$   $\mathcal{C}$ -измерима;
2. для всех  $C \in \mathcal{C}$

$$\int_C \xi d\mathbb{P} = \int_C \tilde{\xi} d\mathbb{P}, \text{ т.е. } \mathbb{M}\xi I_C = \mathbb{M}\tilde{\xi} I_C.$$

**Замечание.**  $\xi$  не обязана быть  $\mathcal{C}$ -измеримой (иначе определение тривиально: возьмём  $\tilde{\xi} = \xi$ ). УМО есть осреднение случайной величины, чтобы та стала измеримой относительно более грубой  $\sigma$ -алгебры.

Следующие два утверждения обосновывают корректность определения:

**Утверждение 2.15.** *Варианты УМО существуют, если  $\mathbb{M}|\xi| < \infty$ .*

□ Сначала рассмотрим случай неотрицательной случайной величины  $\xi$ .  $Q(C) := \int_C \xi d\mathbb{P}$  определяет меру на  $(\Omega, \mathcal{C})$ , абсолютно непрерывную относительно меры  $\mathbb{P}$ , рассмотренной на  $(\Omega, \mathcal{C})$ . По теореме Радона–Никодима существует  $\mathcal{C}$ -измеримая функция  $g(\omega) \geq 0$  такая, что  $\int_\Omega g(\omega) d\mathbb{P} = 1$  и  $Q(C) = \int_C g(\omega) d\mathbb{P}$  ( $g$  — производная Радона–Никодима).  $g$  по определению является вариантом УМО.

В случае знакопеременной  $\xi$  полагаем  $\xi = \xi^+ - \xi^-$  ( $\xi^+$  и  $\xi^-$  неотрицательны) и берём в качестве варианта УМО  $\mathbb{M}(\xi | \mathcal{C}) = \mathbb{M}(\xi^+ | \mathcal{C}) - \mathbb{M}(\xi^- | \mathcal{C})$ . ■

**Замечание.** Условие  $\mathbb{M}|\xi| < \infty$  не является необходимым.

**Утверждение 2.16.** *Любые два варианта УМО совпадают почти наверное.*

□ От противного: пусть  $g_1$  и  $g_2$  — два варианта УМО  $\mathbb{M}(\xi | \mathcal{C})$ . Пусть также  $C = \{\omega | g_1(\omega) \neq g_2(\omega)\}$ ,  $\mathbb{P}(C) > 0$ . Имеем, что  $C = C_< \cup C_>$ , где  $C_* = \{\omega | g_1(\omega) * g_2(\omega)\}$ ,  $*$   $\in \{<, >\}$ . Хотя бы одно из множеств  $C_<$  и  $C_>$  имеет положительную меру (иначе  $\mathbb{P}(C) = 0$ ); без ограничения общности считаем  $\mathbb{P}(C_<) > 0$ .  $g_1$  и  $g_2$  измеримы, поэтому  $D = C_< \in \mathcal{C}$ . Тогда по определению варианта УМО

$$\int_D g_1 d\mathbb{P} = \int_D \xi d\mathbb{P} = \int_D g_2 d\mathbb{P},$$

что противоречит тому, что  $g_1 < g_2$  всюду на  $D$  и  $\mathbb{P}(D) > 0$ . ■

Поэтому УМО можно считать однозначно определённым с точностью до множеств  $\mathbb{P}$ -меры нуль.

**Определение.** Пусть  $(\Omega, \mathcal{A}, \mathbb{P})$  — вероятностное пространство,  $\mathcal{C}$  —  $\sigma$ -подалгебра в  $\mathcal{A}$ ,  $A \in \mathcal{A}$ . Тогда *условная вероятность*  $A$  относительно  $\mathcal{C}$  определяется так:  $Pf(A | \mathcal{C}) = \mathbb{M}(I_A | \mathcal{C})$ , где  $I_A$  — характеристическая функция  $A$ .

**Определение.** Пусть  $(\Omega, \mathcal{A}, \mathbb{P})$  — вероятностное пространство,  $\xi$  и  $\eta$  — случайные величины,  $\mathcal{C}_\eta$  —  $\sigma$ -подалгебра в  $\mathcal{A}$ , порождённая  $\eta$  (т.е. прообразы всех борелевских множеств из  $\mathbb{R}$ ). Тогда *условным математическим ожиданием*  $\xi$  относительно  $\eta$  называется  $\mathbb{M}(\xi | \eta) = \mathbb{M}(\xi | \mathcal{C}_\eta)$ .

### 2.8.1. Свойства УМО

**Определение.**  $\xi$  не зависит от  $\sigma$ -алгебры  $\mathcal{C}$ , если для любого события  $C \in \mathcal{C}$  случайные величины  $\xi$  и  $I_C$  независимы.

Обозначение:  $\mathcal{C}_0 = \{\Omega, \emptyset\}$  — тривиальная  $\sigma$ -алгебра.

**Утверждение 2.17.**

1. Если  $P(\xi = c) = 1$ , то  $M(\xi | \mathcal{C}) = c$  п.н.
2. Линейность:  $M(\alpha_1 \xi_1 + \alpha_2 \xi_2 | \mathcal{C}) = \alpha_1 M(\xi_1 | \mathcal{C}) + \alpha_2 M(\xi_2 | \mathcal{C})$  п.н.
3. Если  $\xi \leq \eta$  п.н., то  $M(\xi | \mathcal{C}) \leq M(\eta | \mathcal{C})$  п.н.
4.  $|M(\xi | \mathcal{C})| \leq M(|\xi| | \mathcal{C})$  п.н.
5. Неравенство Йенсена: пусть  $g(x)$  — непрерывная выпуклая вниз функция,  $M|g(\xi)| < \infty$ . Тогда  $g(M(\xi | \mathcal{C})) \leq M(g(\xi) | \mathcal{C})$  п.н. Равенство имеет место тогда и только тогда, когда  $\xi$   $\mathcal{C}$ -измерима (точнее, совпадает с некоторой  $\mathcal{C}$ -измеримой функцией почти всюду).
6.  $M(\xi | \mathcal{A}) = \xi$  п.н.
7. Если  $\xi$  не зависит от  $\mathcal{C}$ , то  $M(\xi | \mathcal{C}) = M\xi$  п.н.
8. Пусть  $\eta$  является  $\mathcal{C}$ -измеримой и  $M|\xi\eta| < \infty$ . Тогда  $M(\xi\eta | \mathcal{C}) = \eta M(\xi | \mathcal{C})$ .
9.  $M(\xi | \mathcal{C}_0) = M\xi$
10. Если  $\mathcal{C}_1 \subseteq \mathcal{C}_2$ , то  $M(M(\xi | \mathcal{C}_2) | \mathcal{C}_1) = M(\xi | \mathcal{C}_1)$ . Если  $\mathcal{C}_1 \supseteq \mathcal{C}_2$ , то  $M(M(\xi | \mathcal{C}_2) | \mathcal{C}_1) = M(\xi | \mathcal{C}_2)$ .
11.  $M(M(\xi | \mathcal{C})) = M\xi$
12. Если  $M\xi^2 < \infty$ , то

$$\inf_{g(\omega) - \mathcal{C}\text{-измер.}} M(\xi - g(\omega))^2 = M(\xi - M(\xi | \mathcal{C}))^2,$$

т. е.  $g_{\min}(\omega) = M(\xi | \mathcal{C})$  имеет наименьшее среднеквадратичное отклонение.

## 2.9. Теорема Колмогорова – Блекуэлл – Рао

$(\mathcal{X}, \mathcal{A}, \mathcal{P} = \{P_\theta | \theta \in \Theta\})$  — параметрическая модель.  $T(x)$  — достаточная статистика, если существует вариант регулярной условной вероятности  $P_\theta(A | T(\xi)) \forall A \in \mathcal{A}$ , не зависящий от параметра  $\theta$ .

**Теорема 2.18 (Колмогоров – Блекуэлл – Рао).** Пусть  $T(x)$  — достаточная статистика;  $\hat{\theta}(x)$  — оценка параметра  $\theta \in M_\theta \hat{\theta}^2 < \infty$ . Тогда оценка  $\theta^*(\xi) = M_\theta(\hat{\theta}(\xi) | T(\xi))$  обладает следующими свойствами:

1.  $M_\theta \theta^*(\xi) = M_\theta \hat{\theta}(\xi)$ ,
2.  $M_\theta(\theta^*(\xi) - \theta)^2 \leq M(\hat{\theta}(\xi) - \theta)^2$ . Равенство имеет место тогда и только тогда, когда  $\hat{\theta}$  измерима относительно  $\mathcal{C}_T$  (является измеримой функцией достаточной статистики).

□ В силу определения достаточной статистики  $\theta^* = M(\hat{\theta} | T)$  не зависит от  $\theta$ , поэтому  $\theta^*$  — статистика.  $\theta^*$   $\mathcal{C}_T$ -измерима (в силу определения УМО), поэтому  $\theta^*$  есть функция от  $T$ .  $M\theta^* = M(M(\hat{\theta} | T)) = M\hat{\theta}$ . В силу неравенства Йенсена  $M((\hat{\theta} - \theta)^2 | T) \geq (M(\hat{\theta} | T) - \theta)^2 = (\theta^* - \theta)^2$ . Возьмём математическое ожидание:  $M(\hat{\theta} - \theta)^2 = M(M((\hat{\theta} - \theta)^2 | T)) \geq M(\theta^* - \theta)^2$ , причём равенство в неравенстве Йенсена достигается тогда и только тогда, когда  $\hat{\theta}$   $\mathcal{C}_T$ -измерима, т.е. есть функция от  $T$ . ■

## 2.10. Полная достаточная статистика

**Определение.** Достаточная статистика  $T(x)$  называется *полной* (для данного параметрического семейства распределений), если для любой измеримой функции  $f(t)$  при любом значении параметра из условия  $M_\theta f(T(\xi)) = 0$  следует, что  $f(T(\xi)) = 0$  почти наверное.

Полная достаточная статистика  $T$  обладает следующим свойством: если

$$M_\theta f_1(T(\xi)) = M_\theta f_2(T(\xi)),$$

то  $f_1(T(\xi)) = f_2(T(\xi))$  почти наверное. Доказательство очевидно.

**Теорема 2.19.** Пусть  $T(x)$  — полная достаточная статистика и  $f$  и  $g$  таковы, что  $M_\theta f(T(\xi)) = g(\theta)$ . Тогда  $f(T)$  является эффективной оценкой для  $g(\theta)$ .

□ Докажем теорему в частном случае  $g(\theta) = \theta$ .

Дано, что  $M_\theta f(T) = \theta$ , т.е.  $\hat{\theta}(\xi) = f(T(\xi))$  — несмещённая оценка параметра  $\theta$ . Докажем, что эта оценка имеет наименьшую дисперсию среди всех возможных несмещённых оценок. От противного. Пусть существует такая оценка  $\tilde{\theta}$ , что  $M\tilde{\theta}(\xi) = \theta$  ( $\tilde{\theta}$  — несмещённая оценка) и  $D_{\theta_0} \tilde{\theta}(\xi) < D_{\theta_0} \hat{\theta}(\xi)$  хотя бы для одного  $\theta_0 \in \Theta$ . Улучшим оценку  $\tilde{\theta}$  при помощи теоремы Колмогорова – Блекуэлл – Рао:  $\theta^* = M_\theta(\tilde{\theta} | T(\xi))$ , причём

1.  $\theta^* = \theta^*(T(x))$ ;
2.  $M_\theta \theta^* = \theta$ ;
3.  $D_\theta \theta^* \leq D_\theta \tilde{\theta} \forall \theta \in \Theta$ .

Имеем:  $D_{\theta_0} \theta^* \leq D_{\theta_0} \tilde{\theta} < D_{\theta_0} \hat{\theta}$ . Но  $\theta^*$  и  $\hat{\theta}$  суть функции полной достаточной статистики  $T$ ,  $M_\theta \theta^* = \theta = M_\theta \hat{\theta}$ , откуда  $\theta^*(\xi) = \hat{\theta}(\xi)$  почти наверное, а поэтому  $D_{\theta_0} \theta^* = D_{\theta_0} \hat{\theta}$ . Противоречие. ■

**Замечание.** Полная достаточная статистика существует не всегда.

### 2.10.1. ЗАМЕЧАНИЯ О МИНИМАЛЬНОЙ ДОСТАТОЧНОЙ СТАТИСТИКЕ

1. Любая измеримая взаимно-однозначная функция от достаточной статистики сама является достаточной статистикой.
2. Если для любой достаточной статистики  $T$  существует такая измеримая взаимно-однозначная функция  $\psi$ , что  $T_{\min}(x) = \psi(T(x))$ , то  $T_{\min}$  называется *минимальной* достаточной статистикой. Минимальная достаточная статистика существует всегда (для любой параметрической модели). Можно проводить редукцию (без потери информации) от выборки к минимальной достаточной статистике. Дальнейшая редукция невозможна.
3. Как правило, в разложении, которое даёт теорема Неймана – Фишера, появляется минимальная достаточная статистика.
4. Полная достаточная статистика (если она существует) является минимальной.

## 3. Байесовские статистические оценки

### 3.1. Байесовские точечные оценки

#### 3.1.1. ФУНКЦИЯ РИСКА

Рассмотрим функцию  $u$ , называемую функцией штрафа (потерь), обладающую следующими свойствами:

1.  $u$  чётна;
2.  $u$  возрастает на  $(0; +\infty)$ ;
3.  $u(0) = 0$ .

*Функцией риска* оценки  $\delta$  параметра  $\theta$  называется функция  $R(\theta; \delta) = M(u(\delta - \theta))$ . В частном случае  $u(x) = x^2$  (обычно рассматриваемом на практике) функция риска  $R(\theta; \delta) = M(\delta - \theta)^2$  называется *квадратичной функцией риска*. В теории эффективных оценок статистики сравниваются в смысле равномерной минимизации риска.

**Пример 1.1.** В схеме Бернулли оцениваем параметр  $p$ . Эффективная оценка — частота  $\hat{p} = \frac{1}{n}(x_1 + \dots + x_n)$ . Для неё функция риска (квадратичная) равна  $R_1 = R(p; \hat{p}) = \frac{p(1-p)}{n}$ . Пусть теперь  $n = 2$  (выборка состоит из двух элементов  $x_1, x_2$ ). Рассмотрим странную оценку  $\hat{p} = \frac{1}{2}$  для всех значений  $x_i$ . Её функция риска есть  $R_2 = R(p; \hat{p}) = (\frac{1}{2} - p)^2$ . Если нам откуда-то известно (имеется априорная информация), что  $\frac{1}{3} \leq p \leq \frac{2}{3}$ , то странная оценка  $\hat{p}$  оказывается лучше.

#### 3.1.2. БАЙЕСОВСКИЙ ПОДХОД

Параметр  $\theta$  рассматривается как случайная величина  $\theta$  со значениями  $\theta \in \Theta$  и распределением вероятностей  $\Pi$  на измеримом пространстве  $(\Theta, \mathcal{B}_\Theta)$ . Распределение  $\Pi$  называется *априорным распределением* параметра.

Усредним функцию риска  $R(\theta; \delta)$  по распределению параметра:

$$R(\Pi; \delta) = \int_{\Theta} R(\theta; \delta) \Pi(d\theta).$$

$R(\Pi; \delta)$  называется *априорным риском*. Оценка  $\delta^*$ , минимизирующая априорный риск, называется *байесовской оценкой* параметра  $\theta$ :  $R(\Pi; \delta^*) = \inf_{\delta \in \Delta} R(\Pi; \delta)$  ( $\Delta$  — множество оценок). Можно считать: взять априорное распределение так, чтобы получить лучшую оценку.



### 3.2. Минимаксные оценки

Пусть теперь нет ни эффективной оценки, ни априорной информации.  $R_M(\delta) = \sup_{\theta \in \Theta} R(\theta; \delta)$  — наихудшее значение функции риска.

**Определение.**  $\delta^*$  называется *минимаксной* оценкой  $\theta$ , если  $R_M(\delta^*) = \inf_{\delta \in \Delta} R_M(\delta)$  (т.е. она минимизирует максимальное значение функции риска).

**Замечание.** Минимаксную оценку можно получить как байесовскую при некотором („наименее благоприятном“) априорном распределении.

### 3.3. Теорема о байесовской оценке для квадратичной функции риска

Рассмотрим функцию  $P_\theta(A)$ , зависящую от  $A \in \mathcal{A}$  и  $\theta \in \Theta$ . При каждом фиксированном  $A$   $P_\theta(A)$  есть  $\mathcal{B}_\Theta$ -измеримая функция от  $\theta$ , а при каждом фиксированном  $\theta$  — задаёт распределение вероятностей на  $(\mathcal{X}, \mathcal{A})$ . Рассмотрим на декартовом произведении  $\Theta \times \mathcal{X}$   $\sigma$ -алгебру, порождённую прямоугольниками  $B \times A$ , где  $B \in \mathcal{B}_\Theta$ ,  $A \in \mathcal{A}$ . На этих прямоугольниках введём меру  $Q$ :

$$Q(B \times A) = \int_B P_\theta(A) \Pi(d\theta).$$

Более-менее очевидно, что эта мера  $\sigma$ -аддитивна. Значит, она продолжается по Лебегу на всю  $\sigma$ -алгебру, которую мы назовём  $\mathcal{B}_\Theta \times \mathcal{A}$ . Будем рассматривать квадратичную функцию потерь и предполагать, что  $R(\Pi; \delta) = M_Q(\theta - \delta(\xi))^2 < \infty$ .

**Теорема 3.1 (о байесовской оценке для квадратичной функции риска).** Пусть априорное распределение  $\Pi$  и оценка  $\delta(x)$  таковы, что  $R(\Pi; \delta) = M_Q(\theta - \delta(\xi))^2 < \infty$ . Тогда байесовской оценкой параметра  $\theta$  является  $\delta^*(\xi) = M_Q(\theta | \xi)$  (она определена с точностью до множеств  $Q$ -меры нуль).

□

1.  $\delta^*$  является статистикой, т.к. она зависит от  $\theta$  посредством распределения, а оно фиксировано.
2.  $M_Q((\theta - \delta(\xi))^2 | \xi)$ ,  $M_Q(\theta^2 | \xi)$  и  $M_Q(\theta | \xi)$  существуют.
3.  $M_Q(\theta - \delta^*(\xi))^2 = M_Q(M_Q((\theta - \delta^*(\xi))^2 | \theta)) \leq M_Q(\theta - \delta^*(\xi))^2$  в силу свойств УМО ( $\delta^* = M_Q(\theta | \xi)$ ). Равенство — при  $\delta^*(\xi) = M_Q(\theta | \xi)$ .

■

**Следствие 3.1 (единственность байесовской оценки).** Пусть  $\delta_1^*, \delta_2^*$  — две байесовские оценки (относительно квадратичной функции потерь). Тогда  $Q(\delta_1^* \neq \delta_2^*) = 0$ .

### 3.4. Апостериорный риск

Пусть семейство  $\mathcal{P}$  абсолютно непрерывно относительно лебеговой меры. Тогда для любого события  $A \in \mathcal{A}$

$$P_\theta(A) = \int_A p_\theta(x) dx.$$

**Утверждение 3.2.** Пусть  $\delta^*$  — байесовская оценка относительно квадратичной функции потерь. Тогда  $P_\theta$ -п. н. имеем

$$\delta^* = \frac{\int_{\Theta} \theta p_\theta(x) \Pi(d\theta)}{\int_{\Theta} p_\theta(x) \Pi(d\theta)}.$$

□ Пусть  $A \in \mathcal{A}$  — произвольное событие. Положим  $C = \Theta \times A \in \mathcal{B}_\Theta \times \mathcal{A}$ . По определению УМО и теореме о байесовской оценке

$$\int_C \delta^* dQ = \int_C \theta dQ.$$

Вспоминая определение меры  $Q$  и теорему Фубини, получаем:

$$\int_A \delta^*(x) \left( \int_{\Theta} p_\theta(x) \Pi(d\theta) \right) dx = \int_C \delta^* dQ = \int_C \theta dQ = \int_A \left( \int_{\Theta} \theta p_\theta(x) \Pi(d\theta) \right) dx,$$

откуда в силу произвольности выбора  $A$  получаем, что

$$\delta^*(x) \int_{\Theta} p_{\theta}(x) \Pi(d\theta) = \int_{\Theta} \theta p_{\theta}(x) \Pi(d\theta) \quad \mathbb{P}_{\theta}\text{-п.н.}$$

■

Если априорное распределение  $\Pi$  имеет плотность  $\pi(\theta)$ , то

$$\delta^*(x) = \frac{\int_{\Theta} \theta p_{\theta}(x) \pi(\theta) d\theta}{\int_{\Theta} p_{\theta}(x) \pi(\theta) d\theta} = \int_{\Theta} \theta q(\theta | x) d\theta,$$

где

$$q(\theta | x) = \frac{p_{\theta}(x) \pi(\theta)}{\int_{\Theta} p_{\theta}(x) \pi(\theta) d\theta}$$

называется *апостериорной плотностью* (плотностью апостериорного распределения параметра). Это условное распределение  $\theta$  при условии  $\xi$ . Последняя формула называется формулой Байеса для плотностей.

**Замечание.** Байесовская оценка минимизирует апостериорный риск  $M_Q((\theta - \delta(\xi))^2 | \xi)$  (без доказательства).

### 3.5. Связь байесовских оценок с понятием достаточной статистики

1. Апостериорное распределение параметра относительно любого априорного распределения является функцией достаточной статистики. Действительно, пусть  $T(x)$  — достаточная статистика. Тогда по теореме Неймана – Пирсона  $p_{\theta}(x) = g(\theta; T(x))h(x)$ . При условии существования плотности  $\pi$  априорного распределения для плотности  $q(\theta | x)$  условного распределения имеет место следующее:

$$q(\theta | x) = \frac{p_{\theta} \pi(\theta)}{\int_{\Theta} p_{\theta}(x) \pi(\theta) d\theta} = \frac{g(\theta; T(x)) \pi(\theta)}{\int_{\Theta} g(\theta; T(x)) \pi(\theta) d\theta} = f(T(x)),$$

т.е. плотность апостериорного распределения есть функция достаточной статистики.

2. При некоторых дополнительных условиях на  $\Pi$  (например, если  $\pi(\theta) \neq 0$  при всех  $\theta \in \Theta$ ) верно и обратное: если апостериорное распределение  $\theta$  зависит от  $x$  посредством статистики  $T(x)$ , то  $T(x)$  является достаточной статистикой. Таким образом мы получили байесовский критерий достаточности статистики.

### 3.6. Байесовские интервальные оценки

Предположим, что распределения  $\mathbb{P}_{\theta}$  и  $\Pi$  абсолютно непрерывны относительно лебеговой меры, т.е. существуют плотности  $p_{\theta}(x)$  и  $\pi(\theta)$ .  $q(\theta | x)$  — апостериорная плотность. Возьмём произвольное  $\alpha \in (0, 1)$  и произвольным образом разобьём его на две части:  $\alpha = \alpha_1 + \alpha_2$ ,  $\alpha_{1,2} \in (0, 1)$ . Найдём  $\alpha_1$ - и  $(1 - \alpha_2)$ -квантили апостериорного распределения и обозначим их  $\underline{\theta} = \underline{\theta}(\alpha_1, x)$  и  $\bar{\theta} = \bar{\theta}(\alpha_2, x)$  соответственно:

$$\int_{-\infty}^{\underline{\theta}} q(\theta | x) d\theta = \alpha_1, \quad \int_{-\infty}^{\bar{\theta}} q(\theta | x) d\theta = 1 - \alpha_2.$$

$$\mathbb{P}(\underline{\theta} \leq \theta \leq \bar{\theta}) = \int_{\underline{\theta}}^{\bar{\theta}} q(\theta | x) d\theta = 1 - \alpha_2 - \alpha_1 = 1 - \alpha,$$

где вероятность рассматривается в смысле меры  $Q$  (и по априорному распределению  $\theta$ , и по распределениям из семейства  $\mathcal{P}$ ). Получили интервал  $[\underline{\theta}, \bar{\theta}]$  для параметра — это и есть *байесовская интервальная оценка* (этот интервал определяется по  $\alpha$  неоднозначно).  $\alpha$  — вероятность того, что  $\theta$  не попадёт в интервал (вероятность ошибки при использовании этого интервала).

## 4. Доверительные интервалы

$(\mathcal{X}, \mathcal{A}, \mathcal{P} = \{\mathbb{P}_{\theta} | \theta \in \Theta\})$  — параметрическая модель,  $\theta$  — скалярный параметр (иначе интервалы заменяются более сложными областями).  $(\xi_1, \dots, \xi_n)$  — случайная выборка,  $x = (x_1, \dots, x_n)$  — её реализация. По

заданному  $\alpha \in (0, 1)$  и по выборке находим такие статистики  $\underline{\theta}(\alpha; x) < \bar{\theta}(\alpha; x)$ , что  $P_\theta([\underline{\theta}, \bar{\theta}] \ni \theta) \geq 1 - \alpha$ . В этом случае интервал  $[\underline{\theta}, \bar{\theta}]$  называется (точным) *доверительным интервалом* для  $\theta$  с *доверительной вероятностью* (доверительным уровнем)  $1 - \alpha$ .  $\alpha$  — вероятность ошибки при использовании данного интервала.  $\underline{\theta}$  и  $\bar{\theta}$  называются *доверительными границами*.

Доверительный интервал — частный случай интервальной оценки. В отличие от байесовского подхода здесь  $\theta$  — не случайная величина; зато у Байеса границы постоянные, а у нас — случайные (зависят от выборки).

*Сравнение* двух доверительных интервалов производится по двум характеристикам:

1. по  $\alpha$  (или по доверительной вероятности  $1 - \alpha$ );
2. по средней длине доверительного интервала.

## 4.1. Доверительные интервалы для параметров нормального распределения

### 4.1.1. Доверительный интервал для среднего при известной дисперсии

$\xi_1, \dots, \xi_n$  — повторная выборка,  $\xi \sim \mathcal{N}(a, \sigma^2)$ ,  $a = M\xi$ ,  $\sigma^2 = D\xi$ ;  $\sigma^2$  известно.  $\bar{\xi}$  — лучшая точечная оценка для  $a$ .

$\bar{\xi} \sim \mathcal{N}(a, \frac{\sigma^2}{n})$ . Отсюда  $\frac{\bar{\xi} - a}{\sqrt{\sigma^2/n}} \sim \mathcal{N}(0, 1)$  — распределение не зависит от неизвестного параметра (заметим, что это не статистика, т.к. она зависит от параметра  $a$ ). Поэтому

$$P_a \left( \left| \frac{\bar{\xi} - a}{\sqrt{\sigma^2/n}} \right| \leq u \right) = \Phi(u) - \Phi(-u) = 2\Phi(u) - 1, \quad \text{где } \Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du = \Phi. \text{ р. } \mathcal{N}(0, 1).$$

Пусть задано  $\alpha \in (0, 1)$ . По таблицам стандартного нормального распределения находим  $(1 - \frac{\alpha}{2})$ -квантиль  $\mathcal{N}(0, 1)$ . Обозначим эту квантиль  $u_{1-\frac{\alpha}{2}}$ . Тогда  $\Phi(u_{1-\frac{\alpha}{2}}) = 1 - \frac{\alpha}{2}$ , откуда  $2\Phi(u_{1-\frac{\alpha}{2}}) - 1 = 1 - \alpha$ . В силу предыдущего

$$P_a \left( \left| \frac{\bar{\xi} - a}{\sigma/\sqrt{n}} \right| \leq u_{1-\frac{\alpha}{2}} \right) = 1 - \alpha,$$

поэтому  $\left[ \bar{x} - u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}, \bar{x} + u_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right]$  — доверительный интервал для  $a$  с доверительной вероятностью  $1 - \alpha$ .

### 4.1.2. Доверительный интервал для дисперсии при известном среднем

$s_0^2 = \frac{1}{n} \sum_{k=1}^n (x_k - a)^2$  — несмещённая ( $Ms_0^2 = \sigma^2$ ) оценка для  $\sigma^2$ .

$$Z_k = \frac{\xi_k - a}{\sigma} \sim \mathcal{N}(0, 1), \quad \frac{ns_0^2}{\sigma^2} = \sum_{k=1}^n \left( \frac{\xi_k - a}{\sigma} \right)^2 = Z_1^2 + \dots + Z_n^2.$$

$Z_k$  взаимно независимы и одинаково распределены с  $\mathcal{N}(0, 1)$ . Распределение случайной величины  $Z_1^2 + \dots + Z_n^2$  называется *хи-квадрат* распределением с  $n$  степенями свободы и обозначается  $\chi_n^2$ . Для квантилей этого распределения составлены таблицы. Используя эти таблицы, находим квантили  $g_1 = g_1(\frac{\alpha}{2})$  —  $\frac{\alpha}{2}$ -квантиль и  $g_2 = g_2(\frac{\alpha}{2})$  —  $(1 - \frac{\alpha}{2})$ -квантиль  $\chi_n^2$ . Получаем, что

$$P_{\sigma^2} \left( g_1 \leq \frac{ns_0^2}{\sigma^2} \leq g_2 \right) = \left( 1 - \frac{\alpha}{2} \right) - \frac{\alpha}{2} = 1 - \alpha,$$

то есть  $\left[ \frac{ns_0^2}{g_2}, \frac{ns_0^2}{g_1} \right]$  является доверительным интервалом для  $\sigma^2$  с доверительной вероятностью  $1 - \alpha$ .

## 4.2. Точный доверительный интервал для параметра биномиального распределения

Пусть дана случайная выборка  $(\xi_1, \dots, \xi_n)$  со значениями  $x_1, \dots, x_n$ ,  $\xi_k$  взаимно независимы и распределены следующим образом:

$$\xi_k = \begin{cases} 0 & \text{с вероятностью } 1 - p, \\ 1 & \text{с вероятностью } p, \end{cases}$$

где  $p$  — неизвестный параметр.  $S_n = \sum_{i=1}^n \xi_i$ ,  $P(S_n = m) = C_n^m p^m (1 - p)^{n-m}$ .

Ранее было показано, что если  $\eta_1, \dots, \eta_n$  взаимно независимы и равномерно распределены на  $[0, 1]$ , то

$$P(\xi_{(m)} \leq x) = \sum_{k \geq m} C_n^k x^k (1-x)^{n-k} = I_x(m; n-m+1),$$

где  $I_x(a; b)$  — неполная бета-функция с аргументом  $x$  и параметрами  $a$  и  $b$ , которая удовлетворяет соотношению  $I_x(a; b) + I_{1-x}(b; a) = 1$ .

Положим

$$f_m(p) := \sum_{k=0}^m C_n^k p^k (1-p)^{n-k} = 1 - \sum_{k=m+1}^n C_n^k p^k (1-p)^{n-k} = 1 - I_p(m+1; n-m) = I_{1-p}(n-m; m+1).$$

(При фиксированном  $m$  это функция от аргумента  $p \in [0, 1]$ ; а  $m = S_n$  известно нам из выборки.)  $f_m$  — непрерывная и строго убывающая функция,  $f_m(0) = 1$ ,  $f_m(1) = 0$ . Поэтому для каждого  $\beta \in (0, 1)$  уравнение  $f_m(p) = \beta$  имеет единственный корень  $p = \bar{p} = \bar{p}_m(\beta)$ .  $\sum_{k=m}^n C_n^k p^k (1-p)^{n-k} = 1 - f_{m-1}(p)$ . Для каждого  $\beta \in (0, 1)$  уравнение  $1 - f_{m-1}(p) = \beta$  имеет единственный корень  $p = \underline{p} = \underline{p}_{m-1}(\beta)$ .

Полагаем  $\beta = \alpha/2$  и получаем, что

$$P_p(p > \bar{p}) = P_p(f_m(p) < \beta) = P_p\left(\sum_{k=S_n}^n C_n^k p^k (1-p)^{n-k} < \beta\right) = \sum_{j: \sum_{k \leq j} P(S_n = k) \leq \beta} P(S_n = j) \leq \beta,$$

то есть  $P(p > \bar{p}) \leq \beta$ . Аналогично  $P(p < \underline{p}) \leq \beta$ . Окончательно,

$$P_p(\underline{p} \leq p \leq \bar{p}) \geq 1 - 2\beta = 1 - \alpha,$$

то есть интервал  $[\underline{p}, \bar{p}]$  есть доверительный интервал для  $p$  с доверительной вероятностью  $1 - \alpha$ .

### 4.3. Общие способы получения доверительных интервалов

#### 4.3.1. МЕТОД ЦЕНТРАЛЬНОЙ СТАТИСТИКИ

Пусть  $\xi_1, \dots, \xi_n$  взаимно независимы и распределены с абсолютно непрерывным распределением вероятностей  $P_\theta$ . Найдём функцию  $S(\xi; \theta)$  — так называемую *центральную статистику*, хотя на самом деле она статистикой не является, — со следующими свойствами:

1. распределение  $S(\xi; \theta)$  не зависит от  $\theta$  и имеет плотность  $f_S(y)$ ,
2. при каждом фиксированном  $x \in \mathcal{X}$  функция  $S(x; \theta)$  (как функция аргумента  $\theta$ ) является непрерывной и строго монотонной.

Зададим  $\alpha \in (0, 1)$  и найдём  $u_1 < u_2$  так, чтобы

$$P(u_1 \leq S(\xi; \theta) \leq u_2) = \int_{u_1}^{u_2} f_S(y) dy = 1 - \alpha.$$

( $u_1$  и  $u_2$  находятся неоднозначно.) Заметим, что распределение вероятностей в правой части не зависит от параметра  $\theta$ . Обратим неравенство относительно  $\theta$  и получим, что  $P(T_1(\xi) \leq \theta \leq T_2(\xi)) = 1 - \alpha$ , т. е.  $[T_1(x), T_2(x)]$  есть доверительный интервал для  $\theta$  с доверительной вероятностью  $1 - \alpha$ .

#### 4.3.2. ЕЩЁ ОДИН МЕТОД

Пусть  $T(x)$  — некоторая статистика,  $G_\theta(t) = P_\theta(T(\xi) \leq t)$  — её функция распределения. Пусть  $G_\theta(t)$  при любом фиксированном  $\theta$  непрерывна и строго монотонна относительно  $t$  и при любом фиксированном  $t$  является непрерывной строго убывающей функцией от  $\theta$ . Тогда  $P_\theta(G_\theta(t_1) \leq G_\theta(T(\xi)) \leq G_\theta(t_2)) = P_\theta(t_1 \leq T(\xi) \leq t_2) = G_\theta(t_2) - G_\theta(t_1)$  при любых  $t_1 < t_2$ . Если  $G_\theta(t_1) = \alpha_1$ ,  $G_\theta(t_2) = 1 - \alpha_2$ ,  $\alpha_1 + \alpha_2 = \alpha$ , то  $P_\theta(\alpha_1 \leq G_\theta(T) \leq 1 - \alpha_2) = 1 - \alpha_2 - \alpha_1 = 1 - \alpha$ . Положим  $\bar{\theta}: G_{\bar{\theta}}(T(x)) = \alpha_1$ ;  $\underline{\theta}: G_{\underline{\theta}}(T(x)) = \alpha_2$ . Тогда  $P(\underline{\theta} \leq \theta \leq \bar{\theta}) = 1 - \alpha$ , т. е.  $[\underline{\theta}, \bar{\theta}]$  — доверительный интервал с вероятностью ошибки  $\alpha$ .

## 4.4. Асимптотические доверительные интервалы

Как правило, они основаны на асимптотической нормальности некоторых статистик.

**Пример 4.1.** В схеме Бернулли с параметром  $p \in [0, 1]$  рассматривается оценка  $\hat{p}_n = \frac{1}{n}(x_1 + \dots + x_n)$ .  $M\hat{p}_n = p$ ,  $D\hat{p}_n = \frac{p(1-p)}{n}$ . В силу ЦПТ  $\hat{p}_n$  асимптотически нормальна с  $\mathcal{N}\left(p, \frac{p(1-p)}{n}\right)$ , т. е.

$$\frac{\hat{p}_n - p}{\sqrt{\frac{p(1-p)}{n}}} \xrightarrow[n \rightarrow \infty]{d} Z \sim \mathcal{N}(0, 1).$$

Положим  $u = u_{1-\frac{\alpha}{2}} - (1 - \frac{\alpha}{2})$ -квантиль стандартного нормального распределения. Получаем, что

$$P\left(\left|\frac{\hat{p}_n - p}{\sqrt{\frac{p(1-p)}{n}}}\right| \leq u\right) \approx \Phi(u) - \Phi(-u) = 1 - \alpha,$$

где  $\Phi$  — функция стандартного нормального распределения. Точность вычисляется из оценок скорости сходимости в ЦПТ. Решая неравенство под знаком вероятности, получаем интервал для  $p$ :  $P(\underline{p}_n \leq p \leq \bar{p}_n) \approx 1 - \alpha$ .

**Лемма 4.1.** Пусть оценка  $\hat{\theta}_n(x)$  параметра  $\theta$  асимптотически нормальна с  $\mathcal{N}(\theta; \sigma^2(\theta)/n)$ . Пусть  $f(\theta)$  дифференцируема и  $f'(\theta) \neq 0$  в рассматриваемой области. Тогда  $f(\hat{\theta}_n)$  асимптотически нормальна с распределением

$$\mathcal{N}\left(f(\theta); \frac{(f'(\theta))^2 \sigma^2(\theta)}{n}\right).$$

**Замечание.** Функцию  $f(\theta)$  можно выбрать так, чтобы  $f'(\theta)\sigma(\theta) = \text{const}$ , и таким образом избавиться от зависимости дисперсии от параметра.

□ Разложим  $f$  по формуле Тейлора:  $f(t) = f(\theta) + (t-\theta)(f'(\theta) + \gamma(t; \theta))$ , где  $\gamma(t; \theta) \rightarrow 0$  при  $t \rightarrow \theta$ . Подставим  $t = \hat{\theta}_n$ :

$$f(\hat{\theta}_n) - f(\theta) = (\hat{\theta}_n - \theta)f'(\theta) \left(1 + \frac{\gamma(\hat{\theta}_n; \theta)}{f'(\theta)}\right).$$

Положим

$$Y_n := \frac{\hat{\theta}_n - \theta}{\sigma(\theta)/\sqrt{n}}, \quad Z_n := \frac{\gamma(\hat{\theta}_n; \theta)}{f'(\theta)}, \quad W_n := \frac{f(\hat{\theta}_n) - f(\theta)}{f'(\theta)\sigma(\theta)/\sqrt{n}}$$

и получим, что  $W_n = Y_n(1 + Z_n)$ . Но из асимптотической нормальности  $\hat{\theta}_n$   $Y_n \xrightarrow{d} Y \sim \mathcal{N}(0, 1)$ , а  $\gamma(\hat{\theta}_n; \theta) \xrightarrow{P} 0$  в силу состоятельности, поэтому  $W_n \xrightarrow{d} Y \sim \mathcal{N}(0, 1)$ , что и даёт асимптотическую нормальность  $f(\hat{\theta}_n)$ . ■

**Пример 4.2.** В схеме Бернулли оценка  $\hat{p}_n = \frac{1}{n}(x_1 + \dots + x_n)$  асимптотически нормальна с  $\mathcal{N}(p; p(1-p)/n)$ . Положим  $f(p) = \arcsin \sqrt{p}$ ,  $p \in (0, 1)$ .  $f'(p) = \frac{1}{2\sqrt{p(1-p)}}$ ,  $f'(p)\sigma(p) = \frac{\sqrt{p(1-p)}}{2\sqrt{p(1-p)}} = \frac{1}{2} = \text{const}$ . В силу предыдущей леммы оценка  $\arcsin \sqrt{\hat{p}_n}$  асимптотически нормальна с  $\mathcal{N}(\arcsin \sqrt{p}, \frac{1}{4n})$ . Пользуясь монотонностью, получаем асимптотический доверительный интервал для  $p$ .

## 5. Отступление про некоторые распределения вероятностей

### 5.1. Хи-квадрат распределение

Пусть случайные величины  $Z_1, \dots, Z_n$  взаимно независимы и имеют стандартное нормальное распределение. Тогда распределение случайной величины  $Z_1^2 + \dots + Z_n^2$  называется *хи-квадрат* распределением с  $n$  степенями свободы и обозначается  $\chi_n^2$ . При  $\chi_2^2$  имеет показательное распределение с параметром  $\lambda = \frac{1}{2}$ . Плотность хи-квадрат распределения даётся формулой:

$$p_{\chi_n^2} = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}}, \quad \text{где } \Gamma(\lambda) = \int_0^{\infty} x^{\lambda-1} e^{-x} dx \text{ — гамма-функция Эйлера.}$$

$M\chi_n^2 = n$ ,  $D\chi_n^2 = 2n$ . Характеристическая функция:  $\varphi_{\chi_n^2} = (1 - 2it)^{-\frac{n}{2}}$ .

**Мелким шрифтом про вычисление плотности  $\chi^2$ .**

$$P(Z_1^2 + \dots + Z_n^2 \leq y) = \int \dots \int_{\sum_k x_k^2 \leq y} \left(\frac{1}{\sqrt{2\pi}}\right)^n \exp\left(-\frac{1}{2} \sum_k x_k^2\right) dx_1 \dots dx_n.$$

Применяем обобщённую сферическую замену координат:  $x_1, \dots, x_n \mapsto \rho, \varphi_1, \dots, \varphi_{n-1}$ ,  $\rho \in [0, \sqrt{y}]$ ,  $\varphi_i \in [0, \pi]$  при  $i = 1, \dots, n-2$ ,  $\varphi_{n-1} \in [0, 2\pi]$ .

$$\begin{cases} x_1 = \rho \cos \varphi_1 \\ x_2 = \rho \sin \varphi_1 \cos \varphi_2 \\ \dots \\ x_{n-1} = \rho \sin \varphi_1 \dots \sin \varphi_{n-2} \cos \varphi_{n-1} \\ x_n = \rho \sin \varphi_1 \dots \sin \varphi_{n-1} \end{cases}$$

Якобиан замены равен  $J = \rho^{n-1} \sin^{n-2} \varphi_1 \sin^{n-3} \varphi_2 \dots \sin \varphi_{n-2}$ . Исходный интеграл распадается в произведение одномерных интегралов и записывается в виде:

$$C_n \int_0^{\sqrt{y}} e^{-\frac{\rho^2}{2}} \rho^{n-1} d\rho,$$

где  $C_n$  есть произведение интегралов по  $\varphi_k$ , не зависит от  $y$  и вычисляется при  $y \rightarrow \infty$ :

$$C_n = \frac{1}{\Gamma(\frac{n}{2}) 2^{\frac{n}{2}+1}}.$$

Собирая всё вместе и заменяя  $\rho^2 = x$ , получаем требуемое.

## 5.2. Распределение Стьюдента

Если  $Z_0, Z_1, \dots, Z_n$  взаимно независимы и имеют стандартное нормальное распределение, то распределение случайной величины

$$\frac{Z_0}{\sqrt{\frac{Z_1^2 + \dots + Z_n^2}{n}}} = \frac{Z_0}{\sqrt{\chi_n^2/n}}$$

называется *распределением Стьюдента* ( $t$ -распределением) и обозначается  $t_n$ . Плотность распределения Стьюдента даётся формулой

$$p_{t_n}(x) = \frac{C_n}{(1 + \frac{x^2}{n})^{\frac{n+1}{2}}}, \quad \text{где } C_n = \frac{\Gamma(\frac{n+1}{2})}{\Gamma(\frac{n}{2})\sqrt{\pi n}}.$$

При  $n = 1$  распределение Стьюдента совпадает с распределением Коши, имеющим плотность  $\frac{1}{\pi(1+x^2)}$ .

## 5.3. Многомерное нормальное распределение

### 5.3.1. ЧЕТЫРЕ ЭКВИВАЛЕНТНЫХ ОПРЕДЕЛЕНИЯ

Пусть  $\xi = (\xi_1, \dots, \xi_n)^T$  — случайный вектор<sup>5</sup>,  $a = (a_1, \dots, a_n)^T$  — некоторый постоянный вектор,  $x = (x_1, \dots, x_n)^T \in \mathbb{R}^n$ ,  $A$  — положительно определённая матрица  $n \times n$ .

**Первое определение.** Если плотность (совместного) распределения вектора  $\xi$  имеет вид

$$p_\xi(x, a, A) = \frac{1}{(\sqrt{2\pi})^n} (\det A)^{\frac{1}{2}} \exp\left(-\frac{1}{2}(x-a)^T A(x-a)\right),$$

то говорят, что  $\xi$  имеет *многомерное ( $n$ -мерное) нормальное распределение*. Вектор  $a = M\xi$  ( $a_i = M\xi_i$ ) называется средним значением, а матрица  $\Sigma = \Sigma_\xi = A^{-1} = M(\xi-a)(\xi-a)^T$  — *ковариационной матрицей*.  $\Sigma = (\sigma_{ij})$ ,  $\sigma_{ij} = M(\xi_i - a_i)(\xi_j - a_j)$ . Ковариационная матрица является квадратной, симметричной и положительно определённой. Распределение, заданной такой плотностью, обозначается  $\mathcal{N}(a, \Sigma)$ .

<sup>5</sup>Здесь и далее буква  $T$  обозначает транспонирование. Векторы-столбцы записаны как транспонированные строки для экономии места. — *примеч. С. К.*

**Второе определение.** Определим многомерное нормальное распределение через характеристические функции.  $t = (t_1, \dots, t_n)^T \in \mathbb{R}^n$ .  $\varphi_\xi(t) = \text{Me}^{it^T \xi}$  — характеристическая функция случайного вектора. Будем считать, что  $\xi \sim \mathcal{N}(a, \Sigma)$ , если

$$\varphi_\xi(t) = \exp\left(it^T a - \frac{1}{2}t^T \Sigma t\right).$$

В отличие от предыдущего определения, сюда включается случай вырожденной ковариационной матрицы.

**Замечание.** Характеристическая функция вычисляется по плотности, а по многомерной формуле обращения плотность однозначно восстанавливается по характеристической функции. Поэтому первое и второе определения равносильны.

**Третье определение.** Если любая линейная комбинация компонент вектора  $\xi$  имеет (одномерное) нормальное распределение, то  $\xi$  имеет многомерное нормальное распределение.

**Четвёртое определение.**  $\xi$  имеет  $\mathcal{N}(a; \Sigma)$ , если для некоторого  $k$  существует набор независимых и имеющих стандартное нормальное распределение случайных величин  $\eta_1, \dots, \eta_k$  и существует  $n \times k$ -матрица  $A$  такие, что  $\xi = A\eta$ ,  $\eta = (\eta_1, \dots, \eta_k)^T$ . На самом деле  $k$  есть ранг матрицы  $\Sigma$ . На практике обычно считается, что  $k = n$ , а  $a$  — нулевой вектор.

Третье и четвёртое определения будут использоваться в теории случайных процессов.

### 5.3.2. СВОЙСТВА МНОГОМЕРНОГО НОРМАЛЬНОГО РАСПРЕДЕЛЕНИЯ

#### 5.3.3. ЛЕММА ФИШЕРА

**Лемма 5.1 (Фишер).** Пусть  $\eta_1, \dots, \eta_n$  — независимые (одномерные) случайные величины с  $\mathcal{N}(a, \sigma^2)$ . Тогда:

1. существуют ортогональная матрица  $C$  и случайный вектор  $\xi$  такие, что  $\xi = C\eta$ ,  $\text{M}\xi_1 = \sqrt{na}$ ,  $\text{M}\xi_i = 0$  при  $i > 1$  и  $\text{D}\xi_i = \sigma^2$  при всех  $i$ ;
2.  $\bar{\eta} = \frac{\eta_1 + \dots + \eta_n}{n}$  и  $\sum_{i=1}^n (\eta_i - \bar{\eta})^2$  независимы;
- 3.

$$\frac{1}{\sigma^2} \sum (\eta_i - \bar{\eta})^2 \sim \chi_{n-1}^2, \quad \frac{\sqrt{n}(\bar{\eta} - a)}{s} \sim t_{n-1}, \quad \text{где } s^2 = \frac{1}{n-1} \sum_{i=1}^n (\eta_i - \bar{\eta})^2.$$

□

1. Положим  $c_{11} = c_{12} = \dots = c_{1n} = c_1 = \frac{1}{\sqrt{n}}$ .  $\sum_{j=1}^n c_{1j}^2 = 1$ .  $\xi_1 = \sum_{j=1}^n c_{1j} \eta_j = \sqrt{n} \bar{\eta}$ ,  $\text{M}\xi_1 = \sqrt{na}$ ,  $\text{D}\xi_1 = n \frac{\sigma^2}{n} = \sigma^2$ .

Остальные  $c_{ij}$  ( $2 \leq i \leq n$ ,  $1 \leq j \leq n$ ) подбираются из условий:  $\sum_{j=1}^n c_{ij}^2 = 1$  (при всех  $i > 1$ ) и  $\frac{1}{\sqrt{n}} \sum_{j=1}^n c_{ij} = 0$ .

Из этих условий получаем, что матрица  $C = (c_{ij})$  ортогональна, и при  $i > 1$   $\text{M}\xi_i = 0$  и  $\text{D}\xi_i = \sigma^2$ .

2. В силу ортогональности  $C$   $\sum_{i=1}^n \xi_i^2 = \sum_{i=1}^n \eta_i^2$ . Отсюда  $\sum_{i=2}^n \xi_i^2 = \sum_{i=1}^n \eta_i^2 - \xi_1^2 = \sum_{i=1}^n \eta_i^2 - n\bar{\eta}^2$ , то есть  $\sum_{i=1}^n (\eta_i - \bar{\eta})^2 = \sum_{i=2}^n \xi_i^2$  — не зависит от  $\bar{\eta} = \xi_1 / \sqrt{n}$ .

**Замечание.** Если  $\eta_1, \dots, \eta_n$  независимы и имеют одинаковое нормальное распределение, то  $\bar{\eta}$  и  $\frac{1}{n} \sum (\eta_i - \bar{\eta})^2$  независимы. На самом деле это характеристическое свойство нормальных распределений.

3.  $Z_i = \frac{\xi_i}{\sigma} \sim \mathcal{N}(0, 1)$  при  $i > 1$ , откуда

$$\frac{1}{\sigma^2} \sum_{i=1}^n (\eta_i - \bar{\eta})^2 = \sum_{i=2}^n \frac{\xi_i^2}{\sigma^2} = Z_2^2 + \dots + Z_n^2 \sim \chi_{n-1}^2, \quad s^2 = \frac{1}{n-1} \sum_{i=1}^n (\eta_i - \bar{\eta})^2,$$

откуда  $\frac{(n-1)s^2}{\sigma^2} \sim \chi_{n-1}^2$ .

$\frac{\bar{\eta} - a}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ ,  $\frac{(n-1)s^2}{\sigma^2} \sim \chi_{n-1}^2$  и эти случайные величины независимы по предыдущему пункту, поэтому

$$\frac{\sqrt{n}(\bar{\eta} - a)}{s} = \frac{\frac{\bar{\eta} - a}{\sigma/\sqrt{n}}}{\sqrt{s^2/\sigma^2}} \sim t_{n-1}.$$

■

### 5.3.4. ДОВЕРИТЕЛЬНЫЕ ИНТЕРВАЛЫ ДЛЯ ПАРАМЕТРОВ НОРМАЛЬНОГО РАСПРЕДЕЛЕНИЯ II

$x_1, \dots, x_n$  — повторная выборка из  $\mathcal{N}(a, \sigma^2)$ .

**I. Доверительный интервал для  $a$  при неизвестном  $\sigma^2$ .**  $M\bar{\xi} = a$ ,  $D\bar{\xi} = \sigma^2/n$ . По лемме Фишера  $\frac{\bar{x} - a}{\sqrt{s^2/n}}$  имеет распределение Стьюдента с  $n - 1$  степенью свободы. Зафиксируем  $\alpha \in (0, 1)$   $t = t_{1-\frac{\alpha}{2}}(n - 1) = (1 - \frac{\alpha}{2})$ -квантиль  $t_{n-1}$ .

$$P_{a, \sigma^2} \left( \left| \frac{\bar{\xi} - a}{s} \sqrt{n} \right| \leq t \right) = 1 - \alpha \quad (\text{на самом деле распределение вероятностей не зависит от параметров}),$$

поэтому  $\left[ \bar{x} - t \frac{s}{\sqrt{n}}, \bar{x} + t \frac{s}{\sqrt{n}} \right]$  — доверительный интервал для  $a$  с доверительной вероятностью  $\alpha$ .

**II. Доверительный интервал для  $\sigma^2$  при неизвестном  $a$ .** По лемме Фишера  $\frac{(n-1)s^2}{\sigma^2} \sim \chi_{n-1}^2$ . Пусть задано  $\alpha$ .  $g_{\frac{\alpha}{2}}(n-1)$  есть  $\frac{\alpha}{2}$ -квантиль, а  $g_{1-\frac{\alpha}{2}}(n-1) = 1 - \frac{\alpha}{2}$ -квантиль распределения хи-квадрат с  $n-1$  степенью свободы. С помощью этих квантилей строится доверительный интервал для  $\sigma^2$ .

## 6. Проверка статистических гипотез

### 6.1. Проверка гипотез о параметрах нормального распределения

Пусть дана выборка из  $\mathcal{N}(a, \sigma^2)$ .  $H_0: a = a_0$  ( $a_0$  фиксировано);  $H_1: a \neq a_0$ . Пусть  $\sigma^2$  известно и равно  $\sigma_0^2$ . Тогда (см. выше)  $\left[ \bar{x} - u_{1-\frac{\alpha}{2}} \frac{\sigma_0}{\sqrt{n}}, \bar{x} + u_{1-\frac{\alpha}{2}} \frac{\sigma_0}{\sqrt{n}} \right]$  — доверительный интервал для  $a$  с доверительной вероятностью  $1 - \alpha$ . Критерий: если  $a_0$  принадлежит нашему доверительному интервалу, то  $H_0$  принимается, иначе отклоняется. Вероятность ошибки первого рода (отклонить  $H_0$ , когда она верна) равна  $\alpha$ . Вероятность ошибки второго рода явно не вычисляется (гипотеза  $H_1$  — не конкретная).

Если альтернативная гипотеза имеет вид  $H_1: a > a_0$ , то вместо рассмотренного ранее двустороннего используем *односторонний критерий*: оставляем только верхнюю критическую границу.

Аналогично при помощи доверительных интервалов строятся критерии для  $a$  при неизвестном  $\sigma^2$  и для  $\sigma^2$  (при известном или неизвестном  $a$ ).

Критерии, в которых  $H_0$  задаёт конкретное распределение вероятностей, а  $H_1 = \neg H_0$ , называются *критериями согласия*.

### 6.2. Проверка гипотезы однородности нормальных выборок

Пусть имеется две выборки  $x_1, \dots, x_m; y_1, \dots, y_n$ , порожденные соответственно независимыми в совокупности случайными величинами  $\xi_1, \dots, \xi_m, \eta_1, \dots, \eta_n$ , причём  $\xi_1, \dots, \xi_m \sim \mathcal{N}(a_1, \sigma_1^2), \eta_1, \dots, \eta_n \sim \mathcal{N}(a_2, \sigma_2^2)$  и все параметры  $a_1, \sigma_1^2, a_2, \sigma_2^2$  неизвестны.

$H_0: a_1 = a_2, \sigma_1 = \sigma_2$  — гипотеза однородности.  $H_1 = \neg H_0$ . Разобьём задачу проверки гипотезы однородности на две задачи:

I.  $H'_0: \sigma_1^2 = \sigma_2^2$  (при любых  $a$ ),  $H'_1: \sigma_1^2 \neq \sigma_2^2$  (если  $H'_0$  отклоняется, то отклоняем  $H_0$ ; в противном случае движемся дальше).

II. Если  $H'_0$  принимается, то  $H''_0: a_1 = a_2, H''_1: a_1 \neq a_2$ . Теперь  $H_0$  принимается тогда и только тогда, когда принимается  $H''_0$ .

#### 6.2.1. О РАСПРЕДЕЛЕНИИ ФИШЕРА – СНЕДЕКОРА ( $F$ -РАСПРЕДЕЛЕНИИ)

Случайная величина  $F_{m,n} = \frac{\chi_m^2/m}{\chi_n^2/n}$ , где  $\chi_m^2$  и  $\chi_n^2$  независимы, имеет  $F$ -распределение с  $m$  и  $n$  степенями свободы. Плотность:

$$p_{m,n}(x) = \begin{cases} \frac{1}{B(m/2, n/2)} \left(\frac{m}{n}\right)^{m/2} x^{n/2-1} \left(1 + \frac{m}{n}x\right)^{-\frac{m+n}{2}}, & x \geq 0 \\ 0, & x \leq 0 \end{cases}$$

Функция распределения:

$$P(F_{m,n} \leq x) = \frac{I_{\frac{m}{n}x}(m/2, n/2)}{1 + \frac{m}{n}x}, \quad \text{где } I_x(a, b) \text{ - неполная } \beta\text{-функция с параметрами } a \text{ и } b.$$



### 6.2.2. КРИТЕРИЙ ФИШЕРА РАВЕНСТВА ДИСПЕРСИЙ

Рассмотрим две статистики:

$$s_1^2 = \frac{1}{m-1} \sum_{k=1}^m (x_k - \bar{x})^2, \quad s_2^2 = \frac{1}{n-1} \sum_{j=1}^n (y_j - \bar{y})^2.$$

Отношение  $\hat{F}_{m,n} = \frac{s_1^2/\sigma_1^2}{s_2^2/\sigma_2^2}$  при условии  $H'_0$  ( $\sigma_1^2 = \sigma_2^2$ ) равно  $s_1^2/s_2^2$  и имеет  $F$ -распределение с  $(m-1)$  и  $(n-1)$  степенями свободы:

$$\frac{s_1^2}{s_2^2} = \frac{\frac{(m-1)s_1^2}{\sigma^2} \cdot \frac{1}{m-1}}{\frac{(n-1)s_2^2}{\sigma^2} \cdot \frac{1}{n-1}} = \frac{\chi_{m-1}^2 \cdot \frac{1}{m-1}}{\chi_{n-1}^2 \cdot \frac{1}{n-1}} = F_{m-1, n-1},$$

где предпоследнее равенство справедливо в силу леммы Фишера.

Для заданного  $\alpha$  находим квантили  $f_{\frac{\alpha}{2}}(m-1, n-1)$  и  $f_{1-\frac{\alpha}{2}}(m-1, n-1)$   $F$ -распределения с  $(m-1)$  и  $(n-1)$  степенями свободы и берем их в качестве критических значений.

**Критерий Фишера.** Если  $f_{\frac{\alpha}{2}} \leq \hat{F}_{m,n} \leq f_{1-\frac{\alpha}{2}}$ , то  $H'_0$  принимается, иначе отвергается. Вероятность ошибки первого рода в точности равна  $\alpha$ . (Можно использовать и односторонний критерий)

### 6.2.3. КРИТЕРИЙ СТЬЮДЕНТА РАВЕНСТВА СРЕДНИХ ЗНАЧЕНИЙ ПРИ УСЛОВИИ РАВЕНСТВА ДИСПЕРСИЙ

Если  $H'_0$  отклоняется, то отклоняется и гипотеза однородности  $H_0$ . Пусть теперь  $H'_0$  принята (т.е.  $\sigma_1^2 = \sigma_2^2 = \sigma^2$ ). Будем проверять гипотезу  $H''_0 : a_1 = a_2$  ( $H''_1 = \neg H''_0$ ).

Мы знаем, что  $M(\bar{x} - \bar{y}) = a_1 - a_2$  и  $D(\bar{x} - \bar{y}) = \sigma^2(1/m + 1/n)$  ( $\bar{x}$  и  $\bar{y}$  независимы и  $\bar{x} - \bar{y} \sim \mathcal{N}(a_1 - a_2, \sigma^2(1/m + 1/n))$ ).

$$\frac{(\bar{x} - \bar{y}) - (a_1 - a_2)}{\sqrt{\sigma^2(1/m + 1/n)}} \sim \mathcal{N}(0, 1),$$

но  $\sigma^2$  неизвестно. Подставим для неё несмещённую оценку

$$\hat{\sigma}^2 = \frac{(m-1)s_1^2 + (n-1)s_2^2}{m+n-2}$$

При условии  $H''_0 : a_1 - a_2 = 0$  статистика  $\hat{t}_{m+n-2} = \frac{\bar{x} - \bar{y}}{\sqrt{\hat{\sigma}^2(1/m + 1/n)}}$  имеет распределение Стьюдента с  $m+n-2$  степенями свободы (следует из леммы Фишера).

Зададим  $\alpha \in (0, 1)$ .  $t_{\alpha/2} = -t_{1-\alpha/2}$  — соответствующие квантили распределения Стьюдента (равенство имеет место в силу симметричности распределения).

**Критерий Стьюдента.** Если  $|\hat{t}_{m+n-2}| > t_{1-\alpha/2}$ , то  $H''_0$  отклоняется, иначе — принимается. Вероятность ошибки первого рода равна  $\alpha$ . Если при этом  $H''_0$  принимается, то принимается и исходная гипотеза однородности  $H_0$ .

## 6.3. Дисперсионный анализ однофакторной модели

Пусть  $x_1, \dots, x_n$  — выборка, где все элементы получены независимо. А priori разобьём её на  $k, k \geq 3$  подвыборки:  $x_{11}, \dots, x_{n_1 1}; \dots; x_{1k}, \dots, x_{n_k k}$ ,  $n = n_1 + \dots + n_k$ .  $\bar{x}_i = (x_{1i} + \dots + x_{n_i i})/n_i$  — средние значения по подвыборкам,  $\bar{\bar{x}} = (x_{11} + \dots + x_{n_k k})/n$  — среднее значение.

Эти данные удобно представлять в виде *таблицы дисперсионного анализа*:

1	2	...	$k$	
$x_{11}$	$x_{12}$	...	$x_{1k}$	
$x_{21}$	$x_{22}$	...	$x_{2k}$	
$\vdots$	$\vdots$		$\vdots$	
$n_1$	$n_2$	...	$n_k$	$n$
$\bar{x}_1$	$\bar{x}_2$	...	$\bar{x}_k$	$\bar{\bar{x}}$

Предполагается, что существуют постоянные (но неизвестные нам)  $a_1, \dots, a_k$  такие, что  $x_{ij} = a_j + e_{ij}$  при всех  $i$  и  $j$ , где  $e_{ij}$  — случайные ошибки, взаимно независимые при разных  $i$  и  $j$ ,  $Me_{ij} = 0$ ,  $De_{i,j} = \sigma^2$  (считаем измерения равноточными),  $\sigma^2$  неизвестно.

Эта модель называется *однофакторной*. Считается, что на эксперименты, порождающие данные в столбцах, отличаются влиянием некоторого фактора;  $1, 2, \dots, k$  — номера уровней фактора,  $a_j$  — характеристики уровня фактора. Различия между элементами одних столбцов „чисто случайны”. Существуют и многофакторные модели.

$H_0$ : гипотеза об отсутствии фактора ( $a_1 = \dots = a_k$ ) (гипотеза однородности подвыборок),  $H_1 = \neg H_0$ . Если  $e_{ij} \sim \mathcal{N}(0, \sigma^2) \Leftrightarrow x_{ij} \sim \mathcal{N}(a_j, \sigma^2)$ , то  $H_0$  есть гипотеза о равенстве средних значений  $k$  нормальных выборок. [Случай, когда  $x_{ij}$  имеют непрерывные распределения, существенно отличающиеся от нормального, относится к непараметрическому анализу (ранговые критерии, etc). Этим мы заниматься не будем.]

*Изменчивость данных* — отклонение от среднего (измеряется как выборочная дисперсия)

$$\sum_{i,j} (x_{ij} - \bar{x})^2 = \sum_{i,j} (x_{ij} - \bar{x}_j)^2 + \sum_{i,j} (\bar{x}_j - \bar{x})^2$$

$$\sum_{i,j} x_{ij} = n\bar{x} = \sum_{j=1}^k n_j \bar{x}_j$$

Найдём распределение первой суммы. По лемме Фишера

$$\frac{\sum_{i=1}^{n_j} (x_{ij} - \bar{x}_j)^2}{\sigma^2} = \chi_{n_j-1}^2,$$

откуда

$$\frac{1}{\sigma^2} \sum_{i,j} (x_{ij} - \bar{x}_j)^2 = \sum_{j=1}^k \chi_{n_j-1}^2 = \chi_{\sum_j (n_j-1)}^2 = \chi_{n-k}^2,$$

т.к. все  $\chi_{n_j-1}^2$  у нас независимы.

$\bar{x}_j$  не зависит от  $\sum (x_{ij} - \bar{x}_j)^2$  по лемме Фишера, следовательно,  $\sum_j (x_{ij} - \bar{x}_j)^2$  и  $\sum_j (\bar{x}_j - \bar{x})^2$  независимы.

Если  $H_0$  верна, то  $\frac{1}{\sigma^2} \sum (x_{ij} - \bar{x})^2 = \chi_{n-1}^2$ :

$$\frac{1}{\sigma^2} \sum_j n_j (\bar{x}_j - \bar{x})^2 = \chi_{k-1}^2 \text{ (по лемме Фишера)}$$

$$\chi_{n-1}^2 = \chi_{n-k}^2 + \chi_{k-1}^2 \quad (\text{эти величины независимы})$$

$\hat{\sigma}_1^2 = \frac{1}{n-k} \sum_{i,j} (x_{ij} - \bar{x}_j)^2$  — оценка, не зависящая от гипотезы  $H_0$ ,  $\hat{\sigma}_2^2 = \frac{1}{k-1} \sum_j n_j (\bar{x}_j - \bar{x})^2$  — реагирует на  $H_0$

Дисперсионное отношение  $\frac{\hat{\sigma}_2^2}{\hat{\sigma}_1^2}$  имеет распределение Фишера–Снедекора с  $k-1, n-k$  степенями свободы.

**Правосторонний критерий Фишера.** Пусть  $\alpha : f_{1-\alpha}(k-1, n-k)$  —  $(1-\alpha)$ -квантиль  $F$ -распределения с  $k-1, n-k$  степенями свободы. Если  $\hat{F}_{k-1, n-k} > f_{1-\alpha}$ , то  $H_0$  отклоняется (фактор существует); иначе — принимается.

## 6.4. Множественные сравнения

Рассмотрим случай, когда в дисперсионном анализе однофакторной модели гипотеза отсутствия фактора ( $H_0$ ) отвергнута. Проведём более тонкое исследование.

### 6.4.1. ПАРНОЕ СРАВНЕНИЕ

Проверяем гипотезу  $H_{0(j,l)}: a_j = a_l \Leftrightarrow a_j - a_l = 0$ ;  $H_1 = \neg H_0$ . (однородности двух подвыборок).

Строим доверительный интервал для разности  $a_j - a_l$ .  $\bar{x}_j, \bar{x}_l$  — оценки для  $a_j, a_l$ .

$$\frac{(\bar{x}_j - \bar{x}_l) - (a_j - a_l)}{\sqrt{\hat{\sigma}_1^2 \left( \frac{1}{n_j} + \frac{1}{n_l} \right)}} = \hat{t}_{n-k}$$

$\hat{t}_{n-k}$  имеет распределение Стьюдента с  $(n-k)$  степенями свободы, фиксируем  $\alpha$ , строим доверительный интервал для  $a_j - a_l$  стандартным способом:

$$\left[ (\bar{x}_j - \bar{x}_l) - t_{1-\frac{\alpha}{2}}(n-k) \sqrt{\hat{\sigma}_1^2 \left( \frac{1}{n_j} + \frac{1}{n_l} \right)}, (\bar{x}_j - \bar{x}_l) + t_{1-\frac{\alpha}{2}}(n-k) \sqrt{\hat{\sigma}_1^2 \left( \frac{1}{n_j} + \frac{1}{n_l} \right)} \right].$$

**Критерий:** если 0 лежит внутри этого интервала, то принимаем  $H_{0(j,l)}$ , иначе — отклоняем. Таким образом можем выявить излишние уровни факторов.

## 6.4.2. СОБСТВЕННО МНОЖЕСТВЕННЫЕ СРАВНЕНИЯ

$$\Psi = \sum_{j=1}^k c_j a_j, \quad \sum_{j=1}^k c_j = 0$$

$\Psi$  — „сравнение”  $a_1, \dots, a_k$  („контраст”), парное сравнение — частный случай такого. Оценим:  $\hat{\Psi} = \sum_{j=1}^k c_j$

$$M\hat{\Psi} = \Psi, \quad D\hat{\Psi} = \sigma^2 \sum_{j=1}^k c_j^2 / n_j$$

$$\frac{\hat{\Psi} - \Psi}{\sqrt{\hat{\sigma}_1^2 \sum_j \frac{c_j^2}{n_j}}} = \hat{t}_{n-k}$$

Далее стандартным образом строим доверительный интервал для  $\Psi$  ( $\hat{t}_{n-k}$  имеет распределение Стьюдента).

## 6.5. Критерий Пирсона ( $\chi^2$ )

### 6.5.1. БИНОМИАЛЬНЫЙ КРИТЕРИЙ

Рассмотрим схему Бернулли с параметром  $p \in (0, 1)$ . Проверяем гипотезу  $H_0 : p = p_0$ ,  $H_1 : p \neq p_0$ .  $T(x) = x_1 + \dots + x_n$  — достаточная статистика,  $\alpha$  — уровень значимости (вероятность ошибки первого рода),  $m_\alpha^*$  — некоторая критическая граница.

**Критерий:** если  $T(x) > m_\alpha^*$ , то  $H_0$  отклоняем, иначе принимаем. Запишем вероятность ошибки первого рода:

$$\sum_{m > m_\alpha^*} \mathbf{C}_n^m p_0^m (1 - p_0)^{n-m} \leq \alpha$$

Заменяем точный критерий на приближенный с помощью ЦПТ.

$$\frac{T(\xi) - np}{\sqrt{np(1-p)}} \xrightarrow[n \rightarrow \infty]{d} \mathcal{N}(0, 1).$$

Вероятность ошибки первого рода:

$$P_{p_0} \left( \frac{T(\xi) - np_0}{\sqrt{np_0(1-p_0)}} > \frac{m_\alpha^* - np_0}{\sqrt{np_0(1-p_0)}} \right) = \alpha$$

$$1 - \Phi \left( \frac{m_\alpha^* - np_0}{\sqrt{np_0(1-p_0)}} \right) = \alpha$$

$$u_{1-\alpha} = \frac{m_\alpha^* - np_0}{\sqrt{np_0(1-p_0)}} = (1-\alpha)\text{-квантиль } \mathcal{N}(0, 1)$$

Из последнего условия находится граница  $m_\alpha^* = np_0 + u_{1-\alpha} \sqrt{np_0(1-p_0)}$ .

### 6.5.2. КРИТЕРИЙ $\chi^2$ ДЛЯ СХЕМЫ БЕРНУЛЛИ (ПРЕДИСЛОВИЕ К КРИТЕРИЮ ПИРСОНА)

Есть и другой критерий. Пусть  $m = x_1 + \dots + x_n$ .  $P(S_n = m) = \mathbf{C}_n^m p^m (1-p)^{n-m}$ . Рассмотрим статистику

$$\hat{X}_1^2 = \frac{(m - np_0)^2}{np_0} + \frac{(n - m - n(1-p_0))^2}{n(1-p_0)}$$

$\hat{X}_1^2$  есть сумма относительных квадратичных отклонений эмпирических результатов от ожидаемых. В условиях  $H_0$   $MS_n = np_0$ .

$$\hat{X}_1^2 = \frac{(m - np_0)^2}{np_0} + \frac{(m - np_0)^2}{n(1-p_0)} = \frac{(m - np_0)^2}{np_0(1-p_0)} = \left( \frac{m - np_0}{\sqrt{np_0(1-p_0)}} \right)^2$$

Следовательно, так как в силу ЦПТ  $\frac{S_n - np_0}{\sqrt{np_0(1-p_0)}} \xrightarrow{d} \mathcal{N}(0, 1)$ , то  $\hat{X}_1^2$ , как квадрат этой величины, сходится по распределению к  $\chi_1^2$  при условии  $H_0$ .  $\hat{X}_1^2$  называется *статистикой Пирсона (хи-квадрат)*. Критерий строится стандартным образом при помощи квантилей хи-квадрат распределения.

### 6.5.3. ПОЛИНОМИАЛЬНЫЙ КРИТЕРИЙ

Обобщим наш критерий. Будем проверять гипотезу о том, что данная выборка  $x_1, \dots, x_n$  имеет полиномиальное распределение с  $s$  исходами и заданными вероятностями:  $H_0 : p_1 = p_1^0, \dots, p_s = p_s^0, H_1 = \neg H_0$ . Обозначим за  $m_k$  количество исходов типа  $k$  и составим статистику а ла  $\hat{X}_{s-1}^2$ .

**Статистика Пирсона:**

$$\hat{X}_{s-1}^2 = \sum_{k=1}^s \frac{(m_k - np_k^0)^2}{np_k^0}$$

Далее мы покажем, что в условии  $H_0$  и  $n \rightarrow \infty$   $\hat{X}_{s-1}^2$  имеет асимптотическое распределение  $\chi_{s-1}^2$  (теорема Пирсона).

**Критерий Пирсона** ( $\chi^2$ ) о данном распределении в полиномиальной модели. Пусть  $g_{1-\alpha}$  —  $(1-\alpha)$ -квантиль  $\chi_{s-1}^2$ . Если  $\hat{X}_{s-1}^2 > g_{1-\alpha}(s-1)$ , то  $H_0$  отклоняется, иначе принимается. Асимптотическая ошибка первого рода, как будет следовать из теоремы, которую мы сейчас докажем, будет равна  $\alpha$ .

### 6.5.4. ТЕОРЕМА ПИРСОНА

Пусть  $\xi_1, \dots, \xi_n$  взаимно независимы и одинаково распределены:  $\xi_i = (\xi_{i1}, \dots, \xi_{is})^T$  — случайные векторы, причем  $P(\xi_{i1} = a_1, \dots, \xi_{is} = a_s) = p_1^{a_1} \dots p_s^{a_s}$  для всех  $i$ ,  $p_i > 0$ ,  $\sum_i p_i = 1$ ;  $a_i \in \{0, 1\}$ ,  $\sum_i a_i = 1$  ( $\xi_i$  — вектор из 0 и 1 с ровно одной единицей). Очевидно, что  $M\xi_{i_k} = p_k$ ,  $D\xi_{i_k} = p_k(1-p_k)$ ,  $M\xi_i = (p_1, \dots, p_s)^T = \vec{p}$ . Элементы ковариационной матрицы  $\Sigma = \Sigma_\xi = M(\xi - M\xi)(\xi - M\xi)^T = (\sigma_{jl})$  имеют вид  $\sigma_{jl} = M(\xi_{ij} - p_j)(\xi_{il} - p_l) = -p_j p_l$  при  $j \neq l$  (в общем случае  $\sigma_{jl} = p_j \delta_{jl} - p_j p_l$ ). Рассмотрим случайный вектор  $S_n = \xi_1 + \dots + \xi_n = (\mu_1, \dots, \mu_s)^T$ , где  $\mu_k = \sum_{i=1}^n \xi_{ik}$  — сумма независимых случайных величин.  $M\mu_k = np_k$ ,  $D\mu_k = np_k(1-p_k)$ ,  $MS_n = (np_1, \dots, np_s)^t = n\vec{p}$ ;  $\Sigma_{S_n} = n\Sigma_\xi$  (докажите это!).

Распределение  $S_n$  называется *полиномиальным* распределением. Найдём распределение статистики

$$\hat{X}_{s-1}^2 = \sum_{k=1}^s \frac{(\mu_k - np_k)^2}{np_k}, \quad M\hat{X}_{s-1}^2 = s-1$$

**Теорема 6.1 (Пирсон).**  $\hat{X}_{s-1}^2 \xrightarrow{d} \chi_{s-1}^2$

□ Перейдём к  $S_n^* = \frac{S_n - n\vec{p}}{\sqrt{n}}$ ,  $MS_n^* = 0$ ,  $\Sigma_{S_n^*} = \Sigma_\xi = \Sigma$ . Доказательство будет основано на одном из вариантов многомерной ЦПТ, а именно  $\boxed{S_n^* \xrightarrow{d} Z \sim \mathcal{N}(0, \Sigma)}$  [Севастьянов, гл. 11, § 46, теорема 7]

Положим  $\Delta_k = \frac{\mu_k - np_k}{\sqrt{np_k}}$ ,  $k = 1, \dots, s$ ;  $\Delta = (\Delta_1, \dots, \Delta_s)^T$ .  $\sum_{k=1}^s \sqrt{np_k} \Delta_k = \frac{(n-n)}{\sqrt{n}} = 0$ , поэтому  $s$ -мерное распределение  $\Delta$  — вырожденное.

$S_n^* = B\Delta$ ,  $B = \text{diag}(\sqrt{np_1}, \dots, \sqrt{np_s})$ .  $\Delta = B^{-1}S_n^*$ , поэтому  $M\Delta = 0$ . Ковариационная матрица  $\Sigma_\Delta = M(\Delta\Delta^T) = B^{-1}M(S_n^*S_n^{*T})B^{-1} = B^{-1}\Sigma B^{-1}$ .  $(\Sigma_\Delta)_{ij} = \delta_i^j - \sqrt{p_i p_j}$  (на главной диагонали  $1 - p_1, \dots, 1 - p_s$ , вне неё:  $-\sqrt{p_k p_j}$ ).

Положим  $\eta = C\Delta$ , где  $C$  — ортогональная матрица с заданной первой строкой:  $c_{1k} = \sqrt{p_k}$ .  $\eta = (\eta_1, \dots, \eta_s)^T$ ,  $M\eta = 0$ ;  $\eta_1 = \sum_{k=1}^s c_{1k} \Delta_k = 0$ . Докажем, что  $(\Sigma_\eta)_{ij} = \delta_i^j$ , если  $i, j \geq 2$ , и 0 иначе. При  $j, l \geq 2$  имеем:

$$\begin{aligned} M(\eta_j \eta_l) &= M\left(\sum_k c_{jk} \Delta_k \cdot \sum_k c_{lk} \Delta_k\right) = M\left(\sum_{s,t} c_{js} c_{lt} \Delta_s \Delta_t\right) = \sum_{s=1}^m c_{js} c_{ls} M\Delta_s^2 + \sum_{s \neq t} c_{js} c_{lt} M(\Delta_s \Delta_t) = \\ &= \sum_{s=1}^m c_{js} c_{ls} (1 - p_s) - \sum_{s \neq t} c_{js} c_{lt} \sqrt{p_s p_t} = \sum_s c_{js} c_{ls} - \left(\sum_s c_{js} \sqrt{p_s}\right) \left(\sum_t c_{lt} \sqrt{p_t}\right) = \sum_s c_{js} c_{ls} = \delta_{jl} \end{aligned}$$

Последнее равенство верно в силу ортогональности строк матрицы  $C$ .

$$\hat{X}_{s-1}^2 = \sum_{k=1}^s \Delta_k^2 = \sum_{k=1}^s \eta_k^2 = \eta_2^2 + \dots + \eta_s^2 \quad (\eta_1 = 0)$$

Мы доказали, что при  $i > 2$   $\eta_i$  не коррелируют. Если докажем, что  $\eta_i \xrightarrow{d} \mathcal{N}(0, 1)$  (и к тому же они независимы, а не просто не коррелируют — тут-то нам и потребуется многомерная ЦПТ!), то получим  $\chi_{s-1}^2$ . При  $j \geq 2$

$$\eta_j = \sum_{k=1}^s c_{jk} \Delta_k = \sum_{i=1}^n \sum_{k=1}^s \frac{c_{jk}}{\sqrt{np_k}} (\xi_{ik} - p_k) = \sum_{i=1}^n \eta_{ij}$$

При фиксированном  $j$  и разных  $i$   $\eta_{ij}$  независимы и одинаково распределены,  $M\eta_{ij} = 0$ ,  $D\eta_j = 1$ .

$$\eta_j = \sum_i \eta_{ij}, \quad M\eta_{ij} = 0, \quad D\eta_{ij} = \frac{1}{n} \quad \text{докажите это!}$$

По одномерной ЦПТ  $\eta_j \xrightarrow{d} \mathcal{N}(0, 1)$  для всех  $j \geq 2$ .

Памятуя, что  $\eta = (CB^{-1})S_n^*$ , а  $S_n^*$  сходится по распределению к  $\mathcal{N}(0, \Sigma)$  (по формуле в рамочке), получаем, что  $\eta \xrightarrow{d} \mathcal{N}(0, E')$ , где  $E'$  — единичная матрица без верхней левой единицы ( $\eta_1 = 0$ ), причём компоненты его некоррелированы, а потому независимы (это свойство многомерного нормального распределения). Поэтому  $\hat{X}_{s-1}^2 = \eta_2^2 + \dots + \eta_s^2 \xrightarrow{d} \chi_{s-1}^2$ , что и требовалось. ■

### 6.5.5. КРИТЕРИЙ $\chi^2$

Пусть  $x_1, \dots, x_n$  — повторная выборка,  $\xi_i$  одинаково распределены с ф.р.  $\mathcal{F}(x)$ .

$$H_0: \mathcal{F}(x) = F_0(x), \quad H_1 = \neg H_0.$$

Разобьем  $\mathbb{R}$  на  $s$  интервалов  $\Delta_k = (t_{k-1}, t_k]$  произвольным образом. Тогда наша задача сведется к проверке гипотезы о данном распределении вероятностей успеха в полиномиальной модели, где  $m_k$  — число  $x_i$ , попавших в  $\Delta_k$ ,  $p_k^0$  — вероятностная мера  $\Delta_k$  (при условии  $H_0$ ), и  $\hat{X}_{s-1}^2$ , определенное ранее, будет иметь асимптотическое распределение  $\chi_{s-1}^2$ .

**Замечания.** Задачи, решаемые с помощью  $\chi^2$ :

- $F_0(x)$  может быть задана с точностью до  $r$  параметров; тогда статистика Пирсона, в которой  $p_k^0$  вычислены с подстановкой вместо неизвестных параметров статистик для них, будет иметь асимптотическое распределение  $\chi_{s-1-r}^2$ .
- Критерий  $\chi^2$  можно использовать для проверки гипотезы однородности. Пусть есть две полиномиальные схемы с  $n$  и  $l$  испытаниями, с результатами испытаний  $(m_1, \dots, m_s)$ , вероятностями  $(p_1, \dots, p_s)$  и  $(m'_1, \dots, m'_s)$  и  $(p'_1, \dots, p'_s)$  соответственно.

$H_0: p'_i = p_i$ ,  $H_1 = \neg H_0$ . При условии  $H_0$  выборки объединяются и оцениваются общие значения  $p_i = p'_i$ :  $\hat{p}_i = \frac{m_i + m'_i}{n + l}$  (по методу МП). Тогда

$$\hat{X}_{s-1}^2 = \sum_{k=1}^s \frac{(m_k - n\hat{p}_k)^2}{n\hat{p}_k} + \sum_{k=1}^s \frac{(m'_k - l\hat{p}_k)^2}{l\hat{p}_k} \Rightarrow \chi_{s-1}^2$$

(в общем случае, имея  $r$  полиномиальных схем, получим  $\chi_{(s-1)(r-1)}^2$ ).

### 6.6. Критерий знаков

$(x_1, y_1), \dots, (x_n, y_n)$  — набор парных наблюдений, порождённый парой многомерных случайных величин  $(\xi, \xi')$  ( $\xi$  и  $\xi'$  могут быть зависимыми, а вот  $\xi_1, \dots, \xi_n$  независимы в совокупности и одинаково распределены, равно как и  $\xi'_1, \dots, \xi'_n$ ). Пусть  $\xi_1, \dots, \xi_n$  распределены с функцией распределения  $F(x)$ , а  $\xi'_1, \dots, \xi'_n$  — с функцией распределения  $G(x) = F(x - \theta)$ ,  $\theta \in \mathbb{R}$  — параметр. Гипотеза  $H_0$  состоит в однородности выборок (т.е.  $\theta = 0$ );  $H_1 = \neg H_0$ .

Перейдём к разностям  $z_i = x_i - y_i$  (это значения случайных величин  $\eta_i = \xi_i - \xi'_i$ ;  $\eta_1, \dots, \eta_n$  независимы в совокупности). Рассмотрим случай, когда  $\forall i z_i \neq 0$ . Тогда гипотеза  $H_0$  равносильна гипотезе  $H'_0: \forall i P(\eta_i > 0) = P(\eta_i < 0) = \frac{1}{2}$ . Судим о справедливости гипотезы  $H_0$  по соотношению знаков „+” и „-” среди  $z_i$ . По сути имеется  $n$  испытаний Бернулли, где элементарными событиями являются  $A_i = \{\eta_i > 0\}$ ,  $\bar{A}_i = \{\eta_i < 0\}$ . Гипотеза  $H'_0$  равносильна гипотезе  $H''_0$ : „в этой схеме Бернулли  $p = \frac{1}{2}$ ” ( $p = P(A_i)$  — параметр схемы Бернулли). Строим биномиальный критерий для случайной величины

$$\mu_n^+ = \sum_{i=1}^n \varphi_i, \quad \varphi_i = \begin{cases} 1, & \eta_i > 0 \\ 0, & \eta_i < 0 \end{cases}$$

с основной гипотезой  $H''_0: p = \frac{1}{2}$ .

*Практический совет* на случай, когда среди  $z_i$  встречаются нули: если нулей много, то критерий неприменим (потому что в этом критерии считается, что  $P(\eta_i = 0) = 0$ ). Если же нулей мало, то просто выкидываем те испытания, в которых  $z_i = 0$ .

## 6.7. Задача различения двух статистических гипотез

$(\mathcal{X}, \mathcal{A}, \mathcal{P})$  — статистическая модель,  $x = (x_1, \dots, x_n) \in \mathcal{X}$  — выборка. Пусть семейство распределений разбито на два подсемейства:  $\mathcal{P} = \mathcal{P}_1 \sqcup \mathcal{P}_2$ . Хотим построить критерий для выбора одной из двух гипотез:  $H_0: P \in \mathcal{P}_0, H_1: P \in \mathcal{P}_1$ . Рассмотрим произвольное множество  $S \in \mathcal{A}$  и назовём его *критическим множеством* (критической областью) критерия. Сам критерий в терминах  $S$  формулируется так: если  $x \in S$ , то  $H_0$  отклоняется ( $H_1$  принимается); если  $x \notin S$ , то  $H_0$  принимается ( $H_1$  отклоняется). Критерий с критическим множеством  $S$  называется  $S$ -критерием.

*Ошибка первого рода* — отклонить  $H_0$ , когда она верна. *Ошибка второго рода* — принять  $H_0$ , когда верна  $H_1$ . Нужно принять решение так, чтобы вероятности ошибок были минимальными. (Пока это не вполне понятно: как считать вероятность ошибки, если в  $\mathcal{P}_0$  и  $\mathcal{P}_1$  много разных распределений?)

**Пример 7.1.**  $\mathcal{P} = \{P_0, P_1\}$  — два разных распределения,  $\mathcal{P}_i = \{P_i\}, i \in \{0, 1\}$ . Пусть заданы малые числа  $\alpha, \beta \in (0, 1)$ . Потребуем  $P_0(S) \leq \alpha$  и  $P_1(S) \leq \beta$  (или, что то же самое,  $P_0(\bar{S}) \geq 1 - \alpha$  и  $P_1(S) \geq 1 - \beta$ ), то есть числа  $\alpha$  и  $\beta$  ограничивают сверху ошибки первого и второго рода соответственно. Нужно найти такое множество  $S$ , чтобы различить распределения  $P_0$  и  $P_1$ .

Перейдём к параметрической модели:  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ , причём распределения попарно различны ( $\theta' \neq \theta \Rightarrow P_{\theta'} \neq P_\theta$ ).  $\Theta = \Theta_0 \sqcup \Theta_1$ ;  $H_0: \theta \in \Theta_0, H_1: \theta \in \Theta_1$ .

Пусть дан критерий, заданный критическим множеством  $S$  ( $S$ -критерий). Тогда функция  $g_S(\theta) := P_\theta(S)$  от переменной  $\theta$  называется *функцией мощности*  $S$ -критерия. При  $\theta \in \Theta_0$   $g_S(\theta) = P_\theta(S)$  есть вероятность ошибки первого рода, а для  $\theta \in \Theta_1$  вероятность ошибки второго рода выражается так:  $P_\theta(\bar{S}) = 1 - P_\theta(S) = 1 - g_S(\theta)$ .  $\sup_{\theta \in \Theta_0} g_S(\theta)$  — *размер критерия*. Мы требуем, чтобы  $\sup_{\theta \in \Theta_0} g_S(\theta) \leq \alpha$ ; в этом случае  $\alpha$  есть *уровень значимости* критерия.  $\inf_{\theta \in \Theta_1} g_S(\theta)$  — *мощность критерия* (мощность есть наименьшая вероятность принять альтернативную гипотезу, когда она верна). Идеальной (недостижимой) функцией мощности является индикатор множества  $\Theta_1$ .

Критерий можно определить также при помощи *критической функции*  $\varphi_S$  — индикатора множества  $S$ . Тогда  $g_S(\theta) = P_\theta(S) = M_\theta \varphi_S(\xi)$ .

Статистическая гипотеза называется *простой*, если она имеет вид  $P = P_0$ , где  $P_0$  — заданное распределение (или, что то же самое,  $F(x) = F_0(x)$  или  $\theta = \theta_0$ ;  $F_0$  и  $\theta_0$  известны), т.е. речь идёт о конкретном распределении вероятностей. Остальные гипотезы — сложные.

### 6.7.1. Сравнение двух простых гипотез. ТЕОРЕМА НЕЙМАНА – ПИРСОНА

Пусть  $\Theta = \{\theta_0, \theta_1\} \subset \mathbb{R}, \theta_0 < \theta_1$ .  $H_0: \theta = \theta_0, H_1: \theta = \theta_1$ .  $P_{\theta_0}(S)$  — вероятность ошибки первого рода (размер критерия).  $P_{\theta_1}(\bar{S})$  — вероятность ошибки второго рода;  $1 - P_{\theta_1}(\bar{S}) = P_{\theta_1}(S)$  — мощность критерия.

**Сравнение критериев.** Зададим  $\alpha \in (0, 1)$  — уровень значимости (ограничитель размера критерия). Рассмотрим все критерии (критические функции)  $\varphi_S(x)$  с  $M_{\theta_0} \varphi_S(\xi) = \alpha$  (если  $P_{\theta_0}$  — дискретное распределение, то такого  $S$  может и не найтись — тогда требуем  $\leq \alpha$  или применяем рандомизацию — см. ниже). Среди этих критериев выделяем  $\varphi_{S^*} = \varphi_S^*$  — такой, что  $M_{\theta_1} \varphi_{S^*}(\xi) = \sup_{\varphi_S: \alpha = M_{\theta_0} \varphi_S(\xi)} M_{\theta_1} \varphi_S(\xi)$  (в общем случае берём  $\sup$  по  $\theta \in \Theta_1$ ) — если такой критерий существует, то это *наиболее мощный критерий* уровня значимости  $\alpha$ .

**Рандомизированные критерии.** Расширим множество рассматриваемых критериев. Пусть  $\varphi(x)$  — произвольная функция, принимающая значения из  $[0, 1]$  (не обязательно индикатор). Если  $\varphi(x) = 1$ , то  $H_0$  отклоняется, если  $\varphi(x) = 0$ , то  $H_0$  принимается, а вот если  $0 < \varphi(x) < 1$ , то бросается жюльническая монетка и  $H_0$  отклоняется в вероятностью  $\varphi(x)$ . Такая процедура называется *рандомизацией*, а сам критерий — *рандомизированным*. (Бросание монетки — вспомогательный эксперимент.) В этом случае функция мощности критерия задаётся формулой:  $g(\theta) = M_\theta \varphi(\xi)$ .

**Теорема 6.2 (теорема Неймана–Пирсона; фундаментальная лемма).** Пусть  $\mathcal{P} = \{P_\theta \mid \theta \in \Theta\}$ ,  $\Theta = \{\theta_0, \theta_1\} \subset \mathbb{R}, \theta_0 < \theta_1$ ; семейство  $\mathcal{P}$  абсолютно непрерывно относительно некоторой меры (например, меры Лебега в  $\mathbb{R}^n$ ), т.е. существует плотность  $p_\theta(x) = L(\theta; x)$  — функция правдоподобия;  $L_i(x) = L(\theta_i; x), i \in \{0, 1\}$ . Пусть  $p_\theta(x) > 0$  (для всех  $x \in \mathbb{R}, \theta \in \Theta$ ).  $H_0: \theta = \theta_0, H_1: \theta = \theta_1$ . Задано  $\alpha \in (0, 1)$  — уровень значимости (вероятность ошибки первого рода).

Тогда критерий с критической функцией

$$\varphi^*(x) = \begin{cases} 1, & L_1(x) > c_\alpha L_2(x), \\ \varepsilon_\alpha, & L_1(x) = c_\alpha L_2(x), \\ 0, & L_1(x) < c_\alpha L_2(x), \end{cases}$$

где  $c_\alpha$  и  $\varepsilon_\alpha$  определяются из условия  $M_{\theta_0} \varphi^*(\xi) = \alpha$ , таков, что для любой критической функции  $\varphi$  с  $M_{\theta_0} \varphi(\xi) = \alpha$  имеет место неравенство  $M_{\theta_1} \varphi^*(\xi) \geq M_{\theta_1} \varphi(\xi)$  (т.е. этот критерий обладает максимальной мощностью среди критериев уровня значимости  $\alpha$ ).

□ Сначала найдём  $c_\alpha$  и  $\varepsilon_\alpha$ . Рассмотрим функцию  $f(c) = P_{\theta_0}\{L_1(\xi) > cL_0(\xi)\}$ ,  $c \in [0, +\infty)$ .  $f$  — невозрастающая функция  $f(0) = 1$ ,  $f(+\infty) = 0$  (последняя запись понимается как предел).  $1 - f(c) = P_{\theta_0}\left\{\frac{L_1(\xi)}{L_2(\xi)} \leq c\right\}$  — функция распределения отношения значений функций правдоподобия (*отношения правдоподобия*) — неубывающая непрерывная слева функция.

Положим  $c_\alpha = \min\{c \mid f(c) \leq \alpha < f(c-0)\}$  (если  $c_\alpha$  — точка непрерывности  $f$ , то  $f(c_\alpha) = \alpha$ ). Определим  $\varepsilon_\alpha$ :

$$\varepsilon_\alpha = \begin{cases} 0, & \text{если } c_\alpha \text{ — точка непрерывности } f \text{ (} f(c_\alpha) = f(c_\alpha - 0)\text{),} \\ \frac{\alpha - f(c_\alpha)}{f(c_\alpha - 0) - f(c_\alpha)} & \text{в ином случае.} \end{cases}$$

Критерий определён. Будем доказывать его свойства.

$$\begin{aligned} M_{\theta_0}\varphi^*(\xi) &= \int_{\mathcal{X}} \varphi^*(x)p_{\theta_0}(x) dx = \int_{\{x \mid L_1(x) > c_\alpha L_0(x)\}} p_{\theta_0}(x) dx + \varepsilon_\alpha \int_{\{x \mid L_1(x) = c_\alpha L_0(x)\}} p_{\theta_0}(x) dx = \\ &= \begin{cases} f(c_\alpha) = \alpha, & \text{если } c_\alpha \text{ — точка непрерывности } f, \\ f(c_\alpha) + \frac{\alpha - f(c_\alpha)}{f(c_\alpha - 0) - f(c_\alpha)}(f(c_\alpha - 0) - f(c_\alpha)) = \alpha & \text{в ином случае.} \end{cases} \end{aligned}$$

Итак, ошибка первого рода равна  $\alpha$ .

Теперь возьмём любой другой критерий с критической функцией  $\varphi$  с условием  $M_{\theta_0}\varphi(\xi) = \alpha$ . Покажем, что  $M_{\theta_1}\varphi^*(\xi) \geq M_{\theta_1}\varphi(\xi)$ .  $\mathcal{X}^+ := \{x \in \mathcal{X} \mid \varphi^*(x) - \varphi(x) \geq 0\}$ ,  $\mathcal{X}^- := \{x \in \mathcal{X} \mid \varphi^*(x) - \varphi(x) < 0\}$ .  $\mathcal{X} = \mathcal{X}^+ \sqcup \mathcal{X}^-$ . Для всех  $x \in \mathcal{X}^+$  имеем, что  $\varphi^*(x) - \varphi(x) \geq 0 \Rightarrow \varphi^*(x) \geq \varphi(x) \geq 0 \Rightarrow \varphi^*(x) \geq 0 \Rightarrow L_1(x) \geq c_\alpha L_0(x)$ , откуда  $(\varphi^*(x) - \varphi(x))(p_{\theta_1}(x) - c_\alpha p_{\theta_0}(x)) \geq 0$ . Если же  $x \in \mathcal{X}^-$ , то  $\varphi^*(x) - \varphi(x) < 0$ , откуда  $\varphi^*(x) < 1$ , то есть  $L_1(x) \leq c_\alpha L_0(x)$ , и опять  $(\varphi^*(x) - \varphi(x))(p_{\theta_1}(x) - c_\alpha p_{\theta_0}(x)) \geq 0$ . Поэтому

$$M_{\theta_1}(\varphi^*(\xi) - \varphi(\xi)) = \int_{\mathcal{X}} (\varphi^*(x) - \varphi(x))p_{\theta_1}(x) dx = \int_{\mathcal{X}} (\varphi^* - \varphi)(p_{\theta_1}(x) - \underbrace{c_\alpha p_{\theta_0}(x)}_{\text{вычли нулевой интеграл}}) dx \geq 0.$$

■

Если  $P_{\theta_0}(S) \leq P_{\theta_1}(S)$ , то  $S$ -критерий называется *несмещённым*. Теорема Неймана–Пирсона даёт наиболее мощный критерий, который к тому же является несмещённым.