

Глава 1. Нормальные (гауссовские) вектора - простейшие свойства

1. Определение и простейшие характеристики нормальных векторов.

Определение 1.1. Пусть $\vec{\eta} = (\eta_1, \dots, \eta_p)^T$ - случайный вектор, где $\eta_i \sim \mathcal{N}(0, 1)$, $i = \overline{1, p}$ независимы и одинаково распределены. Будем говорить, что этот вектор - **p -мерный стандартный нормальный (или гауссовский) вектор**, т.е. он имеет стандартное p -мерное нормальное (или гауссовское) распределение. Случайный вектор

$$\vec{\xi} = \vec{a} + B\vec{\eta} \quad (1.1)$$

где B - постоянная (неслучайная) матрица размера $n \times p$ и $\vec{a} \in \mathbb{R}^n$ - постоянный (неслучайный) вектор, называется **n -мерным нормальным (или гауссовским) случайным вектором**, а его распределение - **n -мерным нормальным (или гауссовским) распределением**. Заметим, что представление этого вектора в форме $\vec{\xi} = \vec{a} + B\vec{\eta}$ не единственно (см. упражнение 1.1 в конце главы).

Замечание 1.2. В случае $n = 1$ мы имеем обычную (одномерную) нормальную случайную величину, т. к. если $a \in \mathbb{R}^1$, $B = (b_1, \dots, b_p)$ - матрица $1 \times p$, т. е. p -мерный вектор, то $\xi = a + B\vec{\eta} = a + \sum_{i=1}^p b_i \eta_i$ - линейная комбинация нормальных случайных величин и постоянной величины, т.е. сама является случайной величиной. (Ее распределение - $\mathcal{N}(a, \sum_{i=1}^p b_i^2)$.)

Замечание 1.3. Линейное (или, если говорить точнее, аффинное) преобразование $\vec{\xi}$, т.е. $\vec{a}_1 + B_1\vec{\xi}$ (где $\vec{a}_1 \in \mathbb{R}^q$ - постоянный вектор, B_1 - постоянная матрица размера $q \times n$) также является нормальным вектором, т.к. $\vec{a}_1 + B_1\vec{\xi} = \vec{a}_1 + B_1\vec{a} + B_1B\vec{\eta}$, т.е. $\vec{a}_1 + B_1\vec{\xi} = \vec{B}\vec{\eta} + \vec{a}$ для $q \times p$ мерной матрицы $\vec{B} := B_1B$ и q -мерного вектора $\vec{a} := \vec{a}_1 + B_1\vec{a}$; таким образом, для случайного вектора $\vec{a}_1 + B_1\vec{\xi}$ имеется выражение через $\vec{\eta}$ типа (1.1), и этот вектор - нормальный q -мерный.

Теперь найдем вектор математических ожиданий и ковариационную (дисперсионную) матрицу $R = \mathbf{D}\vec{\xi} = \text{Var } \vec{\xi}$ для $\vec{\xi} = \vec{a} + B\vec{\eta}$.

Напомним некоторые определения из теории вероятностей.

Определение 1.4. Вектор математических ожиданий (средних значений) для случайного n -мерного вектора $\vec{\zeta} = (\zeta_1, \dots, \zeta_n)^T$ (не обязательно нормального) определен, если и только если $\mathbf{E}\zeta_i$ при всех $i = \overline{1, n}$ существуют и конечны, и равен, по определению,

$$(\mathbf{E}\zeta_1, \dots, \mathbf{E}\zeta_n)^T.$$

Обозначение: $\mathbf{E}\vec{\zeta}$. Для краткости этот вектор именуется просто *математическим ожиданием* или *средним значением* исходного вектора $\vec{\zeta}$. Оговорка про существование и конечность $\mathbf{E}\zeta_i$ при всех $i = \overline{1, n}$ необходима, т.к. это не всегда выполнено: например, если первая компонента $\vec{\mu}_1$ случайного вектора $\vec{\mu}$ имеет распределение Коши, то $\mathbf{E}\mu_1$, а, значит, и $\mathbf{E}\vec{\mu}$ не существует. Для таких векторов выполнены простые свойства (указанные в упражнении 1.2).

Определение 1.5. Матрицей ковариаций (или ковариационной матрицей, дисперсионной матрицей) данного n -мерного случайного вектора $\vec{\zeta}$ называется, по определению, квадратная матрица порядка n (обозначаемая как $\mathbf{D}\vec{\zeta}$, $\text{Var } \vec{\zeta}$, $R_{\vec{\zeta}}$), ij -й элемент которой равен $\text{cov}(\zeta_i, \zeta_j)$. И эта матрица определена, если и только если $\mathbf{E}\zeta_i^2$ конечны при всех $i = \overline{1, n}$ - это условие равносильно тому, что $\text{cov}(\zeta_i, \zeta_j) = \mathbf{E}(\zeta_i - \mathbf{E}\zeta_i)(\zeta_j - \mathbf{E}\zeta_j)$ конечны при всех $i, j = \overline{1, n}$. Эта оговорка важна - по тем же причинам, по которым необходима аналогичная оговорка в определении вектора

математических ожиданий: $\mathbf{E}\zeta_i^2$ может и не быть конечно (если, например, ζ_i имеет распределение Коши). Матрица ковариаций случайного вектора также обладает некоторыми важными свойствами - см. упражнение 1.3.

В дальнейшем нам понадобится понятие **математического ожидания матрицы**.

Определение 1.6. Пусть X - **случайная матрица**, т.е. матрица, элементы которой - это случайные величины; можно также рассматривать такую матрицу (размера $k \times l$) как случайный вектор размерности kl , записанный в виде матрицы. **Матрица математических ожиданий (средних значений)**, или просто **математическое ожидание (среднее значение)** данной матрицы X определена тогда и только тогда, когда у всех случайных величин - элементов X - существует и конечно математическое ожидание, и определяется как числовая матрица того же размера, ij -й элемент которой математическому ожиданию ij -го элемента матрицы X .

Для этой операции также выполнены некоторые простейшие свойства - они перечислены в упражнении 1.2.

Из свойств операции взятия математического ожидания для векторов (см. упражнение 1.2) $\mathbf{E}\vec{\xi} = \mathbf{E}\vec{a} + B\mathbf{E}\vec{\eta} = \vec{a}$. Мы использовали то, что $\eta_i \sim \mathcal{N}(0, 1)$, откуда $\mathbf{E}\eta_i = 0$ для $i = \overline{1, p}$ и $\mathbf{E}\vec{\eta} = (\mathbf{E}\eta_1, \dots, \mathbf{E}\eta_p)^T = (0, \dots, 0)^T$. Т. е. \vec{a} - вектор математических ожиданий для $\vec{\xi}$.

Полагая (в упражнении 1.3.3) $\vec{X} = \vec{\eta}$, $A = B$, $\vec{b} = \vec{a}$, имеем: $\text{Var } \vec{\xi} = B \text{Var } \vec{\eta} B^T = BB^T$ (ведь $\eta_i \sim \mathcal{N}(0, 1)$, $i = \overline{1, p}$ независимы и $\text{cov}(\eta_i, \eta_j) = 0$ для $i, j = \overline{1, n}$, $i \neq j$, а $\text{cov}(\mu_i, \mu_i) = \text{Var } \eta_i = 1$ для $i = \overline{1, n}$, и, следовательно, $\text{Var } \vec{\eta} = I_p$, где I_p - единичная матрица порядка p ; это обозначение I_p будет использоваться и дальше).

Итак, верно

Утверждение 1.7. Вектор средних значений для $\vec{\xi}$ из формулы (1.1) равен \vec{a} , а матрица ковариаций - BB^T .

2. Общие свойства многомерных характеристических функций. Характеристические функции нормальных векторов.

Определение 1.8. Если $\vec{\xi} = (\xi_1, \dots, \xi_n)^T$ - n -мерный случайный вектор, то его **многомерной (или n -мерной) характеристической функцией** называется, по определению, функция $\varphi : \mathbb{R}^n \rightarrow \mathbb{C}$, задаваемая так: для $t \in \mathbb{R}^n$

$$\varphi_{\vec{\xi}}(t) = \mathbf{E} \exp(it^T \vec{\xi}) = \mathbf{E} \exp(i(t, \vec{\xi})) = \int_{\mathbb{R}^n} e^{it^T x} P(dx),$$

где скобки (\cdot, \cdot) обозначают скалярное произведение, а P - распределение вектора $\vec{\xi}$ в \mathbb{R}^n .

(Это - естественное обобщение понятия характеристической функции случайной величины: функция $\varphi_{\xi} : \mathbb{R} \rightarrow \mathbb{R}$, задаваемая так: $\varphi_{\xi}(t) = \mathbf{E} \exp(it\xi)$, как мы знаем, называется **характеристической функцией случайной величины** ξ . В дальнейшем мы будем именно так - символами $\varphi_{\xi}, \varphi_{\vec{\xi}}$ - обозначать характеристические функции.)

Ее свойства:

1. $\varphi_{\vec{\xi}}(0) = 1, |\varphi_{\vec{\xi}}(t)| \leq 1$ при всех $t \in \mathbb{R}^n$.

2. $\varphi_{\vec{\xi}}$ равномерно непрерывна на \mathbb{R}^n .

3. Если $\vec{Y} = a + B\vec{X}$, где \vec{X} - случайный n -мерный вектор, a - постоянный (неслучайный) вектор размерности m , B - неслучайная (постоянная) матрица размера $m \times n$, то

$$\varphi_{\vec{Y}}(t) = e^{i(t, a)} \varphi_{\vec{X}}(B^T t),$$

где скобки (\cdot, \cdot) обозначают скалярное произведение.

4. Если \vec{X}, \vec{Y} - случайные вектора размерности n , то $\varphi_{\vec{X}} \equiv \varphi_{\vec{Y}}$ на \mathbb{R}^n тогда и только тогда, когда распределения векторов \vec{X} и \vec{Y} совпадают. (Поэтому также

$$\varphi(t) = \int_{\mathbb{R}^n} e^{it^T x} P(dx)$$

называется **функцией распределения для распределения P** в \mathbb{R}^n . Т.е. функция распределения случайного вектора есть функция распределения для его распределения.)

5. Если $\vec{X}_j, j = \overline{1, m}$ - n -мерные случайные вектора, то они независимы, если и только если для всех $t \in \mathbb{R}^n$

$$\varphi_{\vec{X}}(t) = \prod_{j=1}^m \varphi_{\vec{X}_j}(t),$$

где $\vec{X} = \sum_{j=1}^m \vec{X}_j$.

6. Если \vec{X}_j - k_j -мерный случайный вектор, $j = \overline{1, m}$, а у случайного $k = \sum_{j=1}^m k_j$ -мерного вектора \vec{X} первые k_1 компонент составляют вектор \vec{X}_1 , следующие k_2 компонент - вектор \vec{X}_2, \dots , последние k_m компонент - вектор \vec{X}_m , то $\vec{X}_j, j = \overline{1, m}$ независимы тогда и только тогда, когда при всех $t \in \mathbb{R}^k$

$$\varphi_{\vec{X}}(t) = \prod \varphi_{\vec{X}_j}(t_j),$$

где $t_j \in \mathbb{R}^{k_j}, j = \overline{1, m}$, а вектор t составлен из векторов $t_j, j = \overline{1, m}$: первые k_1 компонент вектора t составляют вектор t_1 , следующие k_2 компонент - вектор t_2 и т.д.

В частности, компоненты случайного вектора $\vec{\xi} = (\xi_1, \dots, \xi_n)$ независимы, если и только если

$$\varphi_{\vec{\xi}}(t) = \prod_{j=1}^n \varphi_{\xi_j}(t_j)$$

при всех $t = (t_1, \dots, t_n) \in \mathbb{R}^n$.

7. Теорема непрерывности. Пусть $\{F_m\}_{m=1}^\infty$ - последовательность функций распределения в \mathbb{R}^n , φ_m - n -мерная характеристическая функция, соответствующая распределению в \mathbb{R}^n с функцией распределения F_m . Тогда:

- Если последовательность $\{F_m\}_{m=1}^\infty$ **слабо сходится** к некоторой n -мерной функции распределения F (это означает, что $F_n(x) \rightarrow F(x), n \rightarrow \infty$ в каждой точке $x \in \mathbb{R}^n$, в которой F непрерывна), то $\forall t \in \mathbb{R}^n$

$$\varphi_n(t) \rightarrow \varphi(t),$$

при $n \rightarrow \infty$, т.е. характеристические функции поточечно сходятся к характеристической функции предельного распределения. Более того, на компактах в \mathbb{R}^n эта сходимость - равномерная.

- Если при всех $t \in \mathbb{R}^n$ предел $\lim_{m \rightarrow \infty} \varphi_m(t)$ существует, и функция

$$\lim_{m \rightarrow \infty} \varphi_m(t) = \varphi(t)$$

непрерывна в точке $t = 0$, то она является характеристической функцией некоторого распределения вероятностей в \mathbb{R}^n с функцией распределения F , и последовательность $\{F_m\}_{m=1}^\infty$ слабо сходится к функции F на \mathbb{R}^n .

(Все вышеперечисленные свойства верны для произвольных случайных векторов, а не только для нормальных.)

Доказательства данных свойств можно найти в книге [2] (глава 2, § 12; глава 3, § 1). См. также упражнение 1.7.

Утверждение 1.9. Характеристическая функция для нормального вектора - для случайного вектора $\vec{\xi}$ вида (1.1) - равна

$$\varphi_{\vec{\xi}}(t) = e^{i(t, \vec{a}) - \frac{1}{2}(BB^T t, t)} = e^{i(t, \vec{a}) - \frac{1}{2}(Rt, t)},$$

где $R = BB^T$ - матрица ковариаций нормального вектора $\vec{\xi}$ - см. п.1 данной главы.

Доказательство. По свойству 3 характеристических функций, отмеченному выше,

$$\varphi_{\vec{\xi}}(t) = e^{i(t, \vec{a})} \varphi_{\eta}(B^T t).$$

Но если обозначить $v := B^T t = (v_1, \dots, v_p) \in \mathbb{R}^p$, то

$$\varphi_{\eta}(B^T t) = \varphi_{\eta}(v) = \prod_{k=1}^p \varphi_{\eta_k}(v_k),$$

т.к. компоненты $\eta_k, k = \overline{1, p}$ случайного вектора η независимы (мы воспользовались свойством 6 характеристических функций). Известно, что $\varphi_{\eta_k}(v_k) = \exp(-v_k^2/2)$ - ведь $\eta_k \sim \mathcal{N}(0, 1)$ для всех $k = \overline{1, p}$. Значит,

$$\begin{aligned} \prod_{k=1}^p \varphi_{\eta_k}(v_k) &= \prod_{k=1}^p e^{-v_k^2/2} = e^{-\frac{1}{2} \sum_{k=1}^p v_k^2} = e^{-\frac{1}{2}(v, v)} = \\ &= e^{-\frac{1}{2}(B^T t, B^T t)} = e^{-\frac{1}{2}(BB^T t, t)} = e^{-\frac{1}{2}(Rt, t)} \end{aligned}$$

(вспомним, что $R = BB^T$ - матрица ковариаций вектора $\vec{\xi}$). Отсюда

$$\varphi_{\vec{\xi}}(t) = \exp(i(\vec{a}, t) - \frac{1}{2}(Rt, t)). \quad (1.2)$$

Доказательство завершено. ■

Замечание 1.10. Отметим как частный случай полученной формулы, что для p -мерного стандартного нормального вектора $\vec{\eta}$ $\varphi_{\vec{\eta}}(t) = \exp(-(t, t)/2)$. Это было вычислено в процессе только что проведенных выкладок; впрочем, это можно получить и непосредственно из формулы (1.2), если подставить $n = p$, $\vec{a} = \vec{0}$, $B = I_p$ - единичная матрица порядка p .

Замечание 1.11. Формула (1.2) может быть принята за эквивалентное определение многомерного нормального вектора $\vec{\xi}$: если случайный вектор имеет такую характеристическую функцию, как в (1.2), то он называется нормальным. (Ведь распределение случайного вектора однозначно восстанавливается по его характеристической функции - см. свойство 4 характеристических функций, отмеченное выше.)

3. Дополнительные замечания. Вычисление плотности распределения гауссовских векторов.

Заметим, что теория многомерных гауссовских векторов во многом аналогична теории (одномерных) случайных нормальных величин. В самом деле, если $\eta \sim \mathcal{N}(0, 1)$, то случайная величина $\xi = a + \sigma\eta$ имеет распределение $\mathcal{N}(a, \sigma)$, а это - аналог формулы (1.1). Многомерный аналог математического ожидания a - это вектор средних значений \vec{a} , а многомерный аналог среднеквадратического отклонения σ (а точнее, дисперсии σ^2) - это матрица ковариаций Σ .

Поэтому многомерное нормальное распределение с вектором математических ожиданий \vec{a} и матрицей ковариаций Σ обозначается так: $\mathcal{N}(\vec{a}, \Sigma)$, или так: $\mathcal{N}_n(\vec{a}, \Sigma)$, где n - размерность данного распределения. Например, $\mathcal{N}_p(0, I_p)$, где I_p - единичная матрица порядка p - это стандартное p -мерное нормальное распределение. Характеристическая функция у распределения $\mathcal{N}(a, \sigma)$ равна $\varphi_{\xi}(t) = \exp(iat - t^2\sigma^2/2)$, и эта формула также аналогична формуле (1.2).

Теорема 1.13. Нормальный n -мерный вектор с вектором средних \vec{a} и матрицей ковариаций Σ существует тогда и только тогда, когда матрица Σ **неотрицательно определена** (это записывается так: $\Sigma \geq 0$), т.е. она симметрична и $\forall z \in \mathbb{R}^n \quad z^t \Sigma z \geq 0$.

Доказательство. В одну сторону утверждение очевидно: любая матрица ковариаций любого случайного вектора симметрична и неотрицательно определена - см. упражнение 1.3.4. Обратное: если Σ неотрицательно определена, то, как известно из линейной алгебры, существует единственная неотрицательно определенная матрица B , для которой $B^2 = \Sigma$. (См. упражнение 1.5.)

Т.к. $B = B^T$, то $BB^T = \Sigma$. Пусть случайный вектор $\vec{\eta}$ имеет стандартное n -мерное нормальное распределение. Тогда положим $\vec{\xi} = \vec{a} + B\vec{\eta}$, как в формуле (1.1); как было показано в п.1 данной главы, $\vec{\xi}$ имеет нормальное n -мерное распределение с вектором математических ожиданий \vec{a} и ковариационной матрицей $BB^T = \Sigma$. ■

Замечание 1.14. В дальнейшем будем обозначать σ -алгебру борелевских множеств, лежащих в борелевском множестве $U \in \mathbb{R}^n$, через $\mathfrak{B}(U)$, а σ -алгебру всех борелевских множеств из \mathbb{R}^n , т.е. $\mathfrak{B}(\mathbb{R}^n)$, как \mathfrak{B}^n . Классическую меру Лебега в \mathbb{R}^n обозначим через μ . Напомним, что функция $f : U \rightarrow \mathbb{R}^n$, $U \in \mathfrak{B}^m$ называется **борелевской**, если $\forall B \in \mathfrak{B}^n \quad f^{-1}(B) \in \mathfrak{B}(U)$.

Как вычислить плотность n -мерного нормального распределения?

Напомним определение плотности случайного вектора.

Определение 1.15. Случайный вектор $\vec{\xi}$ (не обязательно гауссовский) **имеет плотность распределения** $p_{\vec{\xi}}$ (по определению, это - борелевская функция $\mathbb{R}^n \rightarrow \mathbb{R}$), если n -мерная функция распределения $F_{\vec{\xi}}(x_1, \dots, x_n)$ случайного вектора $\vec{\xi}$ представима в виде

$$F_{\vec{\xi}}(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} p_{\vec{\xi}}(t_1, \dots, t_n) dt_1 \dots dt_n,$$

где интеграл в правой части понимается в смысле Лебега.

Определение 1.16. Случайный вектор $\vec{\xi}$ (не обязательно гауссовский) **имеет плотность распределения** $p_{\vec{\xi}}$ (по определению, это - борелевская функция $\mathbb{R}^n \rightarrow \mathbb{R}$), если $\forall A \in \mathfrak{B}^n$

$$\mathbf{P}\{\vec{\xi} \in A\} = \int_A p_{\vec{\xi}}(t) d\mu,$$

где интеграл в правой части понимается в смысле Лебега.

Эти определения эквивалентны. (См. упражнение 1.8.)

Докажем предварительно лемму.

Лемма 1.17. Пусть $D, G \subset \mathbb{R}^n$ - открытые множества, $\alpha : D \rightarrow G$ - биекция, причем $\alpha \in C^1(D)$, $\alpha^{-1} \in C^1(G)$, и при этом $J(t)$ - якобиан функции α в точке $t \in D$ - отличен от нуля во всех точках $t \in D$. Пусть, далее, $f : G \rightarrow \mathbb{R}$ - борелевская функция, $A \in \mathfrak{B}(D)$ - некоторое подмножество, $\alpha(A)$ - его образ при отображении α .

Тогда $f \in L_1(\alpha(A))$, если и только если $f(\alpha(t))|J(t)| \in L_1(A)$. Если имеет место интегрируемость, то

$$\int_A f(\alpha(t))|J(t)| dt = \int_{\alpha(A)} f(x) dx. \quad (1.3)$$

(Доказательство - см. приложение.)

Лемма 1.18. Если $D, G \subset \mathbb{R}^n$ - открытые множества, $\alpha : D \rightarrow G$ - биективное отображение, причем $\alpha \in C^1(D)$, $\alpha^{-1} \in C^1(G)$, а случайный n -мерный вектор $\vec{\xi}$ с вероятностью 1 принадлежит D и имеет в D плотность распределения $p(t)$, то

$\alpha(\vec{\xi})$ - случайный n -мерный вектор, лежащий в G с вероятностью 1 и имеющий в G плотность распределения

$$q(x) = \frac{1}{J(\alpha^{-1}(x))} p(\alpha^{-1}(x)),$$

где $t \in G$, $J(t)$ - якобиан отображения α в точке t . (См. упражнение 1.11.)

Утверждение 1.19. Рассмотрим распределение $\mathcal{N}(\vec{a}, \Sigma)$. Если матрица Σ ковариаций вектора, имеющего это распределение, невырождена (или, что равносильно, **положительно определена** - это означает, что она симметрична и $\forall z \in \mathbb{R}^n, z \neq 0 \quad z^T \Sigma z > 0$; этот факт записывается как $\Sigma > 0$), то это распределение абсолютно непрерывно и имеет плотность

$$p(\vec{x}) = \frac{1}{(\sqrt{2\pi})^n \sqrt{\det \Sigma}} \exp\left(-\frac{1}{2}(\vec{x} - \vec{a})^T \Sigma^{-1}(\vec{x} - \vec{a})\right), \quad (1.4)$$

где $\vec{x} \in \mathbb{R}^n$.

Если же Σ вырождена и $\text{rk} \Sigma = k < n$, найдется линейное многообразие (т.е. плоскость) размерности k в \mathbb{R}^n , которому с вероятностью 1 принадлежит случайный вектор с данным распределением. А в этом многообразии данный вектор имеет k -мерное нормальное распределение. (См. упражнение 1.12.)

4. Связь некоррелированности и независимости для гауссовских векторов.

Определение 1.20. Пусть \vec{X}_1, \vec{X}_2 - пара случайных векторов (не обязательно гауссовских), имеющих некоторое совместное распределение (т.е. заданных на одном и том же вероятностном пространстве; можно считать, что это наблюдения, регистрируемые в одном и том же эксперименте). **Матрица ковариаций** этих двух векторов, по определению, имеет $\text{cov}(X_{1i}, X_{2j})$ в качестве ij -го элемента ($i = \overline{1, n}, j = \overline{1, m}$), где $n = \dim \vec{X}_1, m = \dim \vec{X}_2$ - размерности данных случайных векторов, $\vec{X}_1 = (X_{11}, \dots, X_{1n}), \vec{X}_2 = (X_{21}, \dots, X_{2m})$. Она обозначается через $\text{cov}(\vec{X}_1, \vec{X}_2)$.

Операция взятия матрицы ковариаций двух случайных векторов обладает важными свойствами (см. упражнение 1.13).

Утверждение 1.21. Если \vec{X}_1, \vec{X}_2 независимы, то они **некоррелированы**, т.е. их матрица ковариаций - нулевая. (См. упражнение 1.14.)

Утверждение 1.22. Обратное, вообще говоря, неверно для произвольных случайных векторов. (См. упражнение 1.15.)

Утверждение 1.23. Если случайный вектор \vec{X} размерности $n+m$ имеет гауссовское распределение, вектор \vec{X}_1 состоит из первых его n компонент, а \vec{X}_2 - из последних m , $\vec{X}_1 \sim \mathcal{N}(\vec{a}_1, \Sigma_1)$, и при этом $\vec{X}_2 \sim \mathcal{N}(\vec{a}_2, \Sigma_2)$ гауссовские (это следует из задачи 3), то обратное утверждение верно, т.е. из некоррелированности векторов \vec{X}_1, \vec{X}_2 следует их независимость.

Доказательство. Матрица ковариаций Σ вектора \vec{X} (размерности $n+m$) равна, как нетрудно вычислить, используя ее определение,

$$\begin{pmatrix} \text{Var } \vec{X}_1 & \text{cov}(\vec{X}_1, \vec{X}_2) \\ \text{cov}(\vec{X}_2, \vec{X}_1) & \text{Var } \vec{X}_2 \end{pmatrix}$$

т.е. (в предположении, что векторы \vec{X}_1, \vec{X}_2 некоррелированы)

$$\begin{pmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{pmatrix}$$

Т.е. если $\vec{a} = \begin{pmatrix} \vec{a}_1 \\ \vec{a}_2 \end{pmatrix}$ - вектор средних значений для случайного вектора $\vec{X}, \vec{t} \in \mathbb{R}^{n+m}$ - произвольный вектор, вектор \vec{t}_1 состоит из первых n его компонент, а вектор \vec{t}_2 - из последних m , то

$$\begin{aligned} \varphi_{\vec{X}}(\vec{t}) &= \exp(i(\vec{a}, \vec{t}) - \frac{1}{2} \vec{t}^T \Sigma \vec{t}) = \exp(i(\vec{a}_1, \vec{t}_1) + i(\vec{a}_2, \vec{t}_2) - \\ & - \frac{1}{2} \vec{t}_1^T \Sigma_1 \vec{t}_1 - \frac{1}{2} \vec{t}_2^T \Sigma_2 \vec{t}_2) = \exp(i(\vec{a}_1, \vec{t}_1) - \frac{1}{2} \vec{t}_1^T \Sigma_1 \vec{t}_1) \cdot \exp(i(\vec{a}_2, \vec{t}_2) - \frac{1}{2} \vec{t}_2^T \Sigma_2 \vec{t}_2) = \\ & = \varphi_{\vec{X}_1}(\vec{t}_1) \varphi_{\vec{X}_2}(\vec{t}_2), \end{aligned}$$

откуда (как известно из общих свойств характеристических функций - см. свойство 6 в п.2) следует, что векторы \vec{X}_1, \vec{X}_2 независимы. ■

Замечание 1.24. В этом доказательстве мы использовали правила блочного перемножения матриц и векторов.

Замечание 1.25. Можно было бы (в случае невырожденных матриц Σ_1, Σ_2) доказать этот факт через формулу (1.5) для плотностей \vec{X}_1, \vec{X}_2 , но приведенное доказательство проще и, кроме того, оно не использует невырожденность матриц Σ_{11}, Σ_{22} ковариаций данных векторов. (См. упражнение 1.16.)

Утверждение 1.26. (Обобщение данного пункта.) Если первые m_1 компонент нормального n -мерного вектора \vec{X} образуют вектор \vec{X}_1 , следующие m_2 компонент - вектор \vec{X}_2, \dots , последние m_p компонент - вектор $\vec{X}_p, \sum_{k=1}^p m_k = n$, то из условия некоррелированности этих векторов, т.е. условия $\text{cov}(\vec{X}_k, \vec{X}_l) = 0$ при $k, l = \overline{1, p}, k \neq l$ следует независимость этих векторов $X_k, k = \overline{1, p}$. Выше это было доказано для $p = 2$.

В частности, если $\vec{X} = (X_1, \dots, X_n)$ - n -мерный нормальный вектор, $\text{cov}(X_i, X_j) = 0$ при $i, j = \overline{1, n}, i \neq j$, то случайные величины - компоненты $X_i, i = \overline{1, n}$ независимы. (См. упражнение 1.17.)

5. Условное распределение для нормальных векторов.

В дальнейшем нам понадобится понятие **условного математического ожидания** для случайных векторов.

Определение 1.27. Пусть $\vec{X} = (X_1, \dots, X_n)$ - случайный вектор, \mathfrak{A} - σ -подалгебра в исходной σ -алгебре \mathfrak{F} (где $(\Omega, \mathfrak{F}, \mathbf{P})$ - исходное вероятностное пространство). Напомним, что **условным математическим ожиданием** случайной величины ξ относительно \mathfrak{A} (если $\mathbf{E}\xi$ существует и конечно) называется \mathfrak{A} -измеримая случайная величина $\eta : \Omega \rightarrow \mathbb{R}$ (т.е. такая, для которой прообраз любого борелевского множества из \mathbb{R} лежит в \mathfrak{A}), для которой $\forall A \in \mathfrak{A}$

$$\int_A \xi d\mathbf{P} = \int_A \eta d\mathbf{P}.$$

Обозначение: $\eta = \mathbf{E}(\xi|\mathfrak{A})$. Такая величина η существует по теореме Радона - Никодима, т.к. $\int_A \xi d\mathbf{P}$ - это счетно-аддитивная функция множества на \mathfrak{A} . Если же μ

- (другая) случайная величина (или вектор) на $(\Omega, \mathfrak{F}, \mathbf{P})$, то **условным математическим ожиданием** $\mathbf{E}(\xi|\mu)$ случайной величины ξ относительно μ называется условное математическое ожидание ξ относительно σ -подалгебры \mathfrak{A}_μ в \mathfrak{F} , порожденной μ (\mathfrak{A}_μ - это совокупность прообразов всех борелевских множеств в \mathbb{R} , если μ - случайная величина, и в \mathbb{R}^m , если μ - m -мерный случайный вектор.) Можно доказать, что $\mathbf{E}(\xi|\mu) = f(\mu)$ для некоторой борелевской функции f .

Определение 1.28. Вектором **условных математических ожиданий** (или просто **условным математическим ожиданием**) случайного вектора \vec{X} относительно μ (предполагается, что вектор \vec{X} имеет математическое ожидание) называется

$$(\mathbf{E}(X_1|\mu), \dots, \mathbf{E}(X_n|\mu)).$$

Этот вектор обозначается так: $\mathbf{E}(\vec{X}|\mu)$. Т.к. его компоненты \mathfrak{A} -измеримы, то и он сам \mathfrak{A} -измерим. Из того, что для некоторых борелевских функций $f_i, i = \overline{1, n}$ $\mathbf{E}(X_i|\mu) = f_i(\mu)$, следует, что для борелевской вектор-функции $\vec{f} = (f_1, \dots, f_n)$ выполнено $\mathbf{E}(\vec{X}|\mu) = \vec{f}(\mu)$.

Выполнены следующие важные свойства:

1. $\mathbf{E}(A\vec{X}_1 + B\vec{X}_2|\vec{Y}) = A\mathbf{E}(\vec{X}_1|\vec{Y}) + B\mathbf{E}(\vec{X}_2|\vec{Y});$
2. $\mathbf{E}(\vec{a}^T \vec{X}|\vec{Y}) = \vec{a}^T \mathbf{E}(\vec{X}|\vec{Y}),$

где $\vec{X}, \vec{X}_1, \vec{X}_2, \vec{Y}$ - случайные вектора, причем первые три из них имеют математические ожидания, A, B - постоянные (неслучайные) матрицы, и их размеры таковы, что операции сложения и умножения в п.1 выполнимы, а \vec{a} - постоянный (неслучайный) вектор той же размерности, что и \vec{X} .

3. Если ξ - случайная величина с конечным математическим ожиданием, \mathfrak{A} - σ -подалгебра в исходной σ - алгебре \mathfrak{F} , и ξ не зависит от этой σ -подалгебры (т.е. σ -подалгебры $\mathfrak{D}_\xi, \mathfrak{A}$ независимы, где мы обозначаем $\mathfrak{D}_\xi = \{\zeta^{-1}(B) : B \in \mathfrak{B}(\mathbb{R}^n)\}$, n - размерность ζ , для случайных векторов или, как частный случай, случайных величин ζ ; независимость σ -подалгебр $\mathfrak{A}_1, \mathfrak{A}_2$ означает, по определению, независимость любых событий $A_1 \in \mathfrak{A}_1, A_2 \in \mathfrak{A}_2$), то выполнено следующее равенство:

$$\mathbf{E}(\xi|\mathfrak{D}) = \mathbf{E}\xi.$$

В частности, если $\xi, \vec{\eta}$ независимы, где $\vec{\eta}$ - любой случайный вектор или, как частный случай, случайная величина (это означает по определению, что ξ не зависит от $\mathfrak{D}_{\vec{\eta}}$, т.е. $\mathfrak{D}_\xi, \mathfrak{D}_{\vec{\eta}}$ независимы), то

$$\mathbf{E}(\xi|\vec{\eta}) = \mathbf{E}\xi.$$

4. Если $\xi, \vec{\eta}$ - случайная величина и случайный n -мерный вектор, $g : \mathbb{R}^n \rightarrow \mathbb{R}$ - борелевская функция (т.е. прообраз любого борелевского множества из \mathbb{R}^n - борелевское множество из \mathbb{R}), $\mathbf{E}\xi, \mathbf{E}(\xi g(\vec{\eta}))$ существуют и конечны, то

$$\mathbf{E}(\xi g(\vec{\eta})|\vec{\eta}) = g(\vec{\eta})\mathbf{E}(\xi|\vec{\eta}).$$

Подробное изложение теории условных математических ожиданий можно найти в книге [2], гл.2, § 7. См. также упражнение 1.18.

Определение 1.29. Условное распределение нормального n - мерного вектора \vec{X}_1 относительно нормального m - мерного вектора \vec{X}_2 - это функция $f : \mathfrak{B}^n \times \mathbb{R}^m \rightarrow [0, 1]$, задаваемая так:

$$f(B, \vec{t}) := \mathbf{P}(\vec{X}_1 \in B | \vec{X}_2 = \vec{t}) = \mathbf{E}(I_{\{\vec{X}_1 \in B\}} | \vec{X}_2 = \vec{t}),$$

где $\vec{t} \in \mathbb{R}^m, B \in \mathfrak{B}^n, \mathfrak{B}^n$ - борелевская σ - алгебра в \mathbb{R}^n .

(Обозначение: $\text{Law}(\vec{X}_1 | \vec{X}_2)$. Заметим, что, в отличие от условного математического ожидания, для условного распределения нет общепринятых обозначений.)

Это распределение можно изучить, рассматривая *условную характеристическую функцию*, т.е. $\mathbf{E}(\exp(i\vec{u}^T \vec{X}_1 | \vec{X}_2) = \mathbf{E}(\exp(i(\vec{u}, \vec{X}_1) | \vec{X}_2), \vec{u} \in \mathbb{R}^n$, где скобки (\cdot, \cdot) , как обычно, обозначают скалярное произведение. Далее в этом пункте будем считать, что матрица $\text{cov} \vec{X}_2$ невырождена.

Утверждение 1.30. Такая характеристическая функция равна

$$\exp(i\vec{u}^T (\vec{a}_1 + \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2)) - \vec{u}^T (\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21})\vec{u}/2).$$

Доказательство. Подберем вектор \vec{Y} размерности m , для которого \vec{Y}, \vec{X}_2 независимы и $\vec{Y} = \vec{X}_1 + T\vec{X}_2$ для некоторой постоянной матрицы T (размера $n \times m$). Найдем эту матрицу T . Обозначим $\Sigma_{kj} := \text{cov}(\vec{X}_k, \vec{X}_j), k, j = 1, 2$, т.е. $\Sigma_{jj} = \text{Var} \vec{X}_j, j = 1, 2, \Sigma_{12} = \Sigma_{21}^T$ по утверждению из упражнения 1.14. Независимость \vec{Y}, \vec{X}_2 по предыдущему пункту равносильна некоррелированности, т.е. равенству $\text{cov}(\vec{X}, \vec{Y}) = 0 \Leftrightarrow \text{cov}(\vec{X}_1 + T\vec{X}_2, \vec{X}_2) = 0 \Leftrightarrow \text{cov}(\vec{X}_1, \vec{X}_2) + T \text{cov}(\vec{X}_2, \vec{X}_2) = 0 \Leftrightarrow T = -\Sigma_{12}\Sigma_{22}^{-1}$. (Напомним, что, по предположению, $\text{cov} \vec{X}_2 = \Sigma_{22}$ невырождена.)

Итак, $\vec{Y} = \vec{X}_1 - \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2, \vec{X}_1 = \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2 + \vec{Y}$.

Значит,

$$\begin{aligned} \mathbf{E}(\exp(i\vec{u}^T \vec{X}_1) | \vec{X}_2) &= \mathbf{E}(\exp(i\vec{u}^T \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2 + i\vec{u}^T \vec{Y}) | \vec{X}_2) = \\ &= \exp(i\vec{u}^T \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2) \mathbf{E}(\exp(i\vec{u}^T \vec{Y} | \vec{X}_2) = \exp(i\vec{u}^T \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2) \mathbf{E} \exp(i\vec{u}^T \vec{Y}), \end{aligned}$$

т.к. \vec{Y}, \vec{X}_2 независимы.

(В двух последних равенствах мы использовали вышеуказанные свойства 3, 4 условных математических ожиданий.)

Заметим далее, что нормальный вектор $\vec{Y} = \vec{X}_1 - \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2$ имеет вектор средних, равный $\vec{a}_1 - \Sigma_{12}\Sigma_{22}^{-1}\vec{a}_2$ (где положим $\vec{a}_j := \vec{X}_j, j = 1, 2$), и матрицу ковариаций

$$\begin{aligned} \text{Var } \vec{Y} &= \text{cov}(\vec{Y}, \vec{Y}) = \text{cov}(\vec{X}_1, \vec{X}_1) - \text{cov}(\vec{X}_1, \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2) - \text{cov}(\Sigma_{12}\Sigma_{22}^{-1}\vec{X}_1, \vec{X}_2) + \\ &+ \text{cov}(\Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2, \Sigma_{12}\Sigma_{22}^{-1}\vec{X}_2) = \Sigma_{11} - \text{cov}(\vec{X}_1, \vec{X}_2)(\Sigma_{12}\Sigma_{22}^{-1})^T - \\ &- \Sigma_{12}\Sigma_{22}^{-1}\text{cov}(\vec{X}_1, \vec{X}_2) + \Sigma_{12}\Sigma_{22}^{-1}\text{cov}(\vec{X}_2, \vec{X}_2)(\Sigma_{12}\Sigma_{22}^{-1})^T = \\ &= \Sigma_{11} - \Sigma_{12}(\Sigma_{12}\Sigma_{22}^{-1})^T - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} + \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{22}(\Sigma_{12}\Sigma_{22}^{-1})^T = \\ &= \Sigma_{11} - 2\Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} + \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}. \end{aligned}$$

Отсюда следует, что искомая условная характеристическая функция равна $\exp(i\vec{u}^T(\vec{a}_1 + \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2)) - \vec{u}^T(\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21})\vec{u}/2)$. ■

При фиксированном значении \vec{X}_2 это - характеристическая функция m - мерного нормального закона распределения с вектором математических ожиданий $\vec{a}_1 + \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2)$ и матрицей ковариаций $\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}$. Вектор условных математических ожиданий $\vec{a}_1 + \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2)$ (соответствующий данному условному распределению $\text{Law}(\vec{X}_1|\vec{X}_2)$) и условной характеристической функции $\mathbf{E}(\exp(i\vec{u}^T\vec{X}_1|\vec{X}_2))$, есть линейная функция от \vec{X}_2 , а условная матрица ковариаций $\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}$ не зависит от \vec{X}_2 .

Утверждение 1.31. Если положить $\vec{\xi} := \vec{X}_1 - \vec{a}_1 - \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2)$, т.е. $\vec{\xi} + \mathbf{E}(\vec{X}_1|\vec{X}_2) = \vec{X}_1$, то векторы $\vec{X}_2, \vec{\xi}$ независимы.

Доказательство. Вектор $\begin{pmatrix} \vec{\xi} \\ \vec{X}_2 \end{pmatrix}$ имеет нормальное распределение. Действительно, любая линейная комбинация его компонент есть линейная комбинация компонент вектора $\begin{pmatrix} \vec{X}_1 \\ \vec{X}_2 \end{pmatrix}$, а он имеет нормальное распределение. (Мы дважды используем утверждение упражнения 1.3 - см. выше) Но

$$\begin{aligned} \text{cov}(\vec{\xi}, \vec{X}_2) &= \text{cov}(\vec{X}_1 - \vec{a}_1 - \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2), \vec{X}_2) = \\ &= \text{cov}(\vec{X}_1 - \vec{a}_1, \vec{X}_2) - \text{cov}(\Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2), \vec{X}_2) = \\ &= \text{cov}(\vec{X}_1, \vec{X}_2) - \Sigma_{12}\Sigma_{22}^{-1}\text{cov}(\vec{X}_2 - \vec{a}_2, \vec{X}_2) = \Sigma_{12} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{22} = 0 \end{aligned}$$

(в ходе выкладок мы несколько раз воспользовались указанными в этом пункте свойствами условного математического ожидания - см. выше.) Значит, по п.4 векторы $\vec{X}_2, \vec{\xi}$ независимы. ■

6. Регрессия и линейная регрессия. Наилучшая оценка

Определение 1.32 Регрессия случайной величины (или случайного вектора) X_1 относительно случайной величины (или случайного вектора) X_2 - это $\mathbf{E}(X_1|X_2) = f(X_2)$, где f - некоторая (борелевская) функция. Тогда $X_1 = f(X_2) + \varepsilon$, где ε - случайная величина (или случайный вектор) с $\mathbf{E}(\varepsilon|X_2) = 0$, называемая **случайной ошибкой**. Если f линейна, то регрессия называется **линейной**. В разобранном выше случае мы имеем именно линейную регрессию, а $\vec{\xi} := \vec{X}_1 - \vec{a}_1 - \Sigma_{12}\Sigma_{22}^{-1}(\vec{X}_2 - \vec{a}_2) = \vec{X}_1 - \mathbf{E}(\vec{X}_1|\vec{X}_2)$ - это случайная ошибка.

Определение 1.33 Несмещенная оценка случайного n -мерного вектора (или, как частный случай, случайной величины, при $n = 1$) \vec{X}_1 по случайному m -мерному вектору (или, как частный случай, случайной величине, при $m = 1$) X_2 называют борелевскую вектор - функцию $\vec{g} : \mathbb{R}^m \rightarrow \mathbb{R}^n$, т.е. такую функцию, для которой $\forall B \in \mathfrak{B}^n \vec{g}^{-1}(B) \in \mathfrak{B}^m$, где \mathfrak{B}^k - борелевская σ - алгебра в \mathbb{R}^k (или, в случае, когда \vec{X}_1, \vec{X}_2 - случайные величины, борелевскую функцию $g : \mathbb{R} \rightarrow \mathbb{R}$), для которой $\mathbf{E}\vec{g}(\vec{X}_2) = \mathbf{E}\vec{X}_1$.

Определение 1.34 **Наилучшей несмещенной оценкой** для случайного вектора (или, как частный случай, случайной величины) \vec{X}_1 по случайному вектору (или, как частный случай, случайной величине) \vec{X}_2 называется несмещенная оценка \vec{g} , для которой выполнено неравенство

$$\mathbf{E}(X_1 - g(X_2))^2 \leq \mathbf{E}(X_1 - h(X_2))^2, \quad (1.5)$$

если X_1 - случайная величина, и

$$\mathbf{E}(X_1 - g(X_2))(X_1 - g(X_2))^T \leq \mathbf{E}(X_1 - h(X_2))(X_1 - h(X_2))^T, \quad (1.6)$$

если X_1 - случайный вектор, для любой другой несмещенной оценки \vec{h} вектора \vec{X}_1 по вектору \vec{X}_2 .

Замечание 1.35. При этом необходимо пояснить, как сравнивать матрицы $\mathbf{E}(X_1 - g(X_2))(X_1 - g(X_2))^T$ и $\mathbf{E}(X_1 - h(X_2))(X_1 - h(X_2))^T$, если X_1 - случайный вектор. Такие матрицы симметричны, а для симметричных матриц A, B одного и того же порядка можно определить отношение порядка так: $A \geq B$, если и только если $A - B \geq 0$.

Утверждение 1.36. На множестве симметричных квадратных матриц данного порядка это отношение задает частичный порядок. (См. упражнение 1.19.)

Утверждение 1.37. Такое отношение порядка удовлетворяет многим обычным свойствам:

- 1) Если $A_1 \geq B_1, A_2 \geq B_2$, то $A_1 + A_2 \geq B_1 + B_2$;
- 2) Если $\lambda \in \mathbb{R}, A \geq B$, то $\lambda A \geq \lambda B$ при $\lambda \geq 0$, $\lambda A \leq \lambda B$ при $\lambda \leq 0$.
- 3) Если $A \geq B \geq 0$ и A, B невырождены, то $A^{-1} \leq B^{-1}$. (См. упражнение 1.20.)

Утверждение 1.38. Такая оценка имеет вид $\mathbf{E}(X_1|X_2)$, т.е. это как раз регрессия X_1 по X_2 .

Доказательство. Рассмотрим сначала случай, когда X_1 - (одномерная) случайная величина.

Заметим, что $\mathbf{E}(X_1|X_2)$ - борелевская функция от X_2 , причем $\mathbf{E}\mathbf{E}(X_1|X_2) = \mathbf{E}X_1$. Этим доказано, что $\mathbf{E}(X_1|X_2)$ - несмещенная оценка X_1 по X_2 . Теперь докажем неравенство (1.5) для любой другой несмещенной оценки h X_1 по X_2 . Заметим, что

$$\begin{aligned} \mathbf{E}(X_1 - h(X_2))^2 &= \mathbf{E}((X_1 - \mathbf{E}(X_1|X_2))^2 + 2(X_1 - \mathbf{E}(X_1|X_2))(\mathbf{E}(X_1|X_2) - h(X_2)) + \\ &\quad + (\mathbf{E}(X_1|X_2) - h(X_2))^2) = \mathbf{E}(X_1 - \mathbf{E}(X_1|X_2))^2 + \\ &\quad + 2\mathbf{E}(X_1 - \mathbf{E}(X_1|X_2))(\mathbf{E}(X_1|X_2) - h(X_2)) + \mathbf{E}(\mathbf{E}(X_1|X_2) - h(X_2))^2 \geq \\ &\quad \geq \mathbf{E}(X_1 - \mathbf{E}(X_1|X_2))^2, \end{aligned}$$

т.к. $\mathbf{E}(\mathbf{E}(X_1|X_2) - h(X_2))^2 \geq 0$, а

$$\begin{aligned} \mathbf{E}(X_1 - \mathbf{E}(X_1|X_2))(\mathbf{E}(X_1|X_2) - h(X_2)) &= \mathbf{E}\mathbf{E}((X_1 - \mathbf{E}(X_1|X_2))(\mathbf{E}(X_1|X_2) - h(X_2))) = \\ &= \mathbf{E}\mathbf{E}((X_1 - \mathbf{E}(X_1|X_2))(\mathbf{E}(X_1|X_2) - h(X_2))|X_2) = \\ &= \mathbf{E}(\mathbf{E}(X_1 - \mathbf{E}(X_1|X_2)|X_2) \cdot (\mathbf{E}(X_1|X_2) - h(X_2))), \end{aligned}$$

ведь мы вынесли случайную величину $\mathbf{E}(X_1|X_2) - h(X_2)$ из-под знака условного математического ожидания относительно X_2 , т.к. эта случайная величина есть борелевская функция от X_2 , однако

$$\mathbf{E}(\mathbf{E}(X_1 - \mathbf{E}(X_1|X_2)|X_2) \cdot (\mathbf{E}(X_1|X_2) - h(X_2))) = 0,$$

т.к. $\mathbf{E}(X_1 - \mathbf{E}(X_1|X_2)|X_2) = \mathbf{E}(X_1|X_2) - \mathbf{E}(\mathbf{E}(X_1|X_2)|X_2) = \mathbf{E}(X_1|X_2) - \mathbf{E}(X_1|X_2) = 0$ (ведь $\mathbf{E}(X_1|X_2)$ - борелевская функция относительно X_2 и $\mathbf{E}(\mathbf{E}(X_1|X_2)|X_2) = \mathbf{E}(X_1|X_2)$).

Итак, неравенство (1.5) доказано, т.е. утверждение 1.38 доказано для случая, когда X_1 - случайная величина. Теперь рассмотрим общий случай: X_1 - n -мерный

случайный вектор. Аналогично, $\mathbf{E}(X_1|X_2)$ - борелевская функция от X_2 , причем $\mathbf{E}\mathbf{E}(X_1|X_2) = \mathbf{E}X_1$. Этим доказано, что $\mathbf{E}(X_1|X_2)$ - несмещенная оценка X_1 по X_2 . Далее, докажем неравенство (1.6) для любой другой несмещенной оценки h X_1 по X_2 .

Пусть $z \in \mathbb{R}^n$ - произвольный постоянный (неслучайный) вектор. Тогда по свойствам условного математического ожидания (см. упражнение 1.18) $\mathbf{E}(z^T X_1|X_2) = z^T \mathbf{E}(X_1|X_2)$. Но, по доказанному выше, $\mathbf{E}(z^T X_1|X_2)$ - наилучшая несмещенная оценка случайной величины $z^T X_1$ по X_2 . Кроме того, $\mathbf{E}(z^T h(X_2)) = z^T \mathbf{E}h(X_2) = z^T \mathbf{E}X_1$ по задаче 1.2.5, т.е. $z^T h(X_2)$ - несмещенная оценка $z^T X_1$ по X_2 . Т.е.

$$\mathbf{E}(z^T X_1 - z^T \mathbf{E}(X_1|X_2))^2 \leq \mathbf{E}(z^T X_1 - z^T h(X_2))^2,$$

или, эквивалентно,

$$z^T \mathbf{E}(X_1 - \mathbf{E}(X_1|X_2))(X_1 - \mathbf{E}(X_1|X_2))^T z \leq z^T \mathbf{E}(X_1 - h(X_2))\mathbf{E}(X_1 - h(X_2))^T z,$$

(мы использовали утверждение упражнения 1.2.11), но в силу произвольности вектора $z \in \mathbb{R}^n$ это и означает, что выполнено неравенство (1.6). ■

Заметим, что это доказательство очень похоже на доказательство теоремы Блэкуелла - Рао (Blackwell - Rao) об улучшении несмещенной оценки с помощью достаточной статистики. (Она будет сформулирована в следующей главе.)

7. Датчик нормальных случайных величин.

Как написать программу, которая выдавала бы выборку требуемого объема из стандартного нормального (одномерного) распределения? Можно, используя датчик случайных чисел, дающий выборку (ξ_1, \dots, ξ_n) из равномерного на $[0, 1]$ распределения, построить выборку $(\Phi^{-1}(\xi_1), \dots, \Phi^{-1}(\xi_n))$ из $\mathcal{N}(0, 1)$, где $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp(-t^2/2) dt$. (Здесь мы пользуемся тем, что если случайная величина ξ имеет равномерное на $[0, 1]$ распределение, то $\Phi^{-1}(\xi) \sim \mathcal{N}(0, 1)$ - ведь $\mathbf{P}\{\Phi^{-1}(\xi) \leq x\} = \mathbf{P}\{\xi \leq \Phi(x)\} =$ (т.к. ξ равномерно распределена на $[0, 1]$) $= \Phi(x)$)

Но функцию Φ^{-1} на практике трудно вычислять. Поэтому поступают иначе: если вектор (X_1, X_2) имеет двумерное стандартное нормальное распределение, то $\arg(X_1, X_2)$ имеет равномерное распределение на $[0, 2\pi]$. (Где $\arg(X_1, X_2)$ - это такой угол $\varphi \in [0, 2\pi)$, что $\cos \varphi = X_1/\sqrt{X_1^2 + X_2^2}$, $\sin \varphi = X_2/\sqrt{X_1^2 + X_2^2}$. Он определен тогда и только тогда, когда для X_1, X_2 неверно, что $X_1 = X_2 = 0$, т.е. почти наверное. При этом $\arg(X_1, X_2)$ распределен равномерно на $[0, 2\pi]$.)

(Интуитивно это очевидно, т.к. совместное распределение (X_1, X_2) "изотропно" т.е. не зависит от направления вектора (X_1, X_2) , а $\arg(X_1, X_2)$ зависит только от этого направления. См. также упражнение 1.21.) Т.е. $\arg(X_1, X_2)/2\pi$ имеет равномерное распределение на $[0, 1]$. Далее, $X_1^2 + X_2^2 \sim \chi^2(2) = \Gamma(2/2, 1/2)$ - а это показательное распределение с параметром $1/2$. Здесь использовалось то, что $\chi^2(n)$ и $\Gamma(n/2, 1/2)$ - это одно и то же распределение - см. упражнение 1.22.

(Напомним, что $\Gamma(\alpha, \lambda)$ - это одномерное абсолютно непрерывное распределение, сосредоточенное на положительной полуоси, с плотностью

$$p(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x},$$

где $\alpha, \lambda > 0$ - параметры; показательное распределение с параметром $\lambda > 0$ - это одномерное абсолютно непрерывное распределение, сосредоточенное на положительной полуоси, с плотностью $p(x) = \lambda e^{-\lambda x}$. Как видим, последнее распределение есть частный случай первого при $\alpha = 1$.)

Т.е. $X_1^2 + X_2^2$ имеет функцию распределения $F(x) = 1 - \exp(-x/2), x \geq 0, F(x) = 0, x < 0$. Отсюда следует, что $\exp(-(X_1^2 + X_2^2)/2)$ имеет равномерное на $[0, 1]$ распределение.

(Доказательство: при $x > 0$ $\mathbf{P}\{\exp(-(X_1^2 + X_2^2)/2) \leq x\} = \mathbf{P}\{X_1^2 + X_2^2 \geq -2 \ln x\} = 1 - F(-2 \ln x)$; при $x \geq 1 - 2 \ln x \leq 0$, $1 - F(-2 \ln x) = 1$; при $x < 1 - 2 \ln x \geq 0$, $1 - F(-2 \ln x) = x$; если же $x \leq 0$, то, очевидно, $\mathbf{P}\{\exp(-(X_1^2 + X_2^2)/2) \leq x\} = 0$.)

Если нам известны $a = \exp(-(X_1^2 + X_2^2)/2)$, $b = \arg(X_1/X_2)/2\pi$, то мы можем восстановить значения $\Delta = X_1^2 + X_2^2 = -2 \ln a$, $\varphi = \arg(X_1/X_2) = 2b\pi$, и тогда $X_1 = \sqrt{\Delta} \cos \varphi$, $X_2 = \sqrt{\Delta} \sin \varphi$.

На практике поступают так: с помощью датчика случайных чисел получают выборки (a_1, \dots, a_n) , (b_1, \dots, b_n) из равномерного на $[0, 1]$ распределения, а по ним восстанавливают (X_{11}, \dots, X_{1n}) , (X_{21}, \dots, X_{2n}) - выборки из распределения $\mathcal{N}(0, 1)$. (Т.е. указанным выше способом восстанавливают X_{1i}, X_{2i} по $a_i, b_i, i = \overline{1, n}$.)

Задачи и упражнения к главе 1

Упражнение 1.1. Представление нормального вектора $\vec{\xi}$ (см. формулу (1.1)) в форме $\vec{\xi} = \vec{a} + B\vec{\eta}$, где B - постоянная (неслучайная) матрица размера $n \times p$ и $\vec{a} \in \mathbb{R}^n$ - постоянный (неслучайный) вектор, $\vec{\eta}$ - p -мерный стандартный нормальный вектор, не единственно.

Упражнение 1.2. Обосновать следующие свойства операции взятия вектора средних значений (всюду здесь и в упражнении 1.3 мы рассматриваем произвольные случайные вектора, а не обязательно гауссовские):

1. $\mathbf{E}(\lambda_1 \vec{X}_1 + \lambda_2 \vec{X}_2) = \lambda_1 \mathbf{E}\vec{X}_1 + \lambda_2 \mathbf{E}\vec{X}_2$, где $\lambda_1, \lambda_2 \in \mathbb{R}$ - скаляры, \vec{X}_1, \vec{X}_2 - случайные n -мерные векторы, предполагается, что у \vec{X}_1, \vec{X}_2 есть математические ожидания;

2. $\mathbf{E}\vec{b} = \vec{b}$;

3. $\mathbf{E}(A\vec{X} + \vec{b}) = A\mathbf{E}\vec{X} + \vec{b}$, если A - постоянная (неслучайная) матрица размера $p \times n$;

4. $\mathbf{E}(\vec{X}^T A + \vec{b}) = (\mathbf{E}\vec{X})^T A + \vec{b}$, если A - постоянная (неслучайная) матрица размера $n \times p$;

5. $\mathbf{E}(\vec{c}^T \vec{X}) = \vec{c}^T \mathbf{E}\vec{X}$,

где в пп.2-5 $\vec{b} \in \mathbb{R}^p, \vec{c} \in \mathbb{R}^n$ - постоянные (неслучайные) вектора, \vec{X} - случайный вектор размерности n ; в пп. 3-5 предполагается, что $\mathbf{E}\vec{X}$ существует.

Обосновать также следующие свойства операции взятия математического ожидания случайной матрицы:

6. $\mathbf{E}(AX + BY) = A\mathbf{E}X + B\mathbf{E}Y$;

7. $\mathbf{E}(XA + YB) = \mathbf{E}XA + \mathbf{E}YB$;

8. $\mathbf{E}A = A$;

9. $\mathbf{E}X^T = (\mathbf{E}X)^T$;

10. $\mathbf{E}(\alpha X + \beta Y) = \alpha \mathbf{E}X + \beta \mathbf{E}Y$,

где X, Y - случайные, а A, B - постоянные (неслучайные) матрицы, и в пп. 6-7 предполагается, что их размеры согласованы (так, чтобы были выполнимы операции сложения и умножения), а $\alpha, \beta \in \mathbb{R}$ - постоянные числа (скаляры). В пп. 6, 7, 10 предполагается, что у матриц X, Y существуют математические ожидания, в п.9 это предполагается только для матрицы X .

Также доказать следующее свойство:

11. $\mathbf{E}(\vec{z}^T \vec{\mu})^2 = \vec{z}^T \mathbf{E}(\vec{\mu} \vec{\mu}^T) \vec{z}$,

где $\vec{z} \in \mathbb{R}^n$ - постоянный (неслучайный) вектор, $\vec{\mu} = (\mu_1, \dots, \mu_n)$ - случайный n -мерный вектор, причем предполагается, что $\mathbf{E}\mu_i^2$ существует и конечно при всех $i = \overline{1, n}$ или, эквивалентно, у матрицы $\vec{\mu} \vec{\mu}^T$ существует математическое ожидание. (Почему эти два условия эквивалентны?)

Упражнение 1.3. Доказать следующие свойства матриц ковариаций случайных векторов:

1. $\text{Var } \vec{X} = \mathbf{E}(\vec{X}\vec{X}^T) - \mathbf{E}\vec{X}\mathbf{E}\vec{X}^T;$

2. $\text{Var}(\lambda\vec{X} + \vec{b}) = \lambda^2 \text{Var } \vec{X};$

3. $\text{Var}(A\vec{X} + \vec{b}) = A \text{Var } \vec{X} A^T$, в частности, $\text{Var}(\vec{c}^T \vec{X}) = \vec{c}^T \text{Var } \vec{X} \vec{c};$

4. $\text{Var } \vec{X}$ - симметричная неотрицательно определенная матрица (свойство неотрицательной определенности для симметричной матрицы M размера $n \times n$ означает, как говорилось выше, следующее: $\forall \vec{z} \in \mathbb{R}^n \vec{z}^T M \vec{z} \geq 0$),

где в этих четырех пунктах \vec{X} - случайный вектор (не обязательно гауссовский) размерности n , $\lambda \in \mathbb{R}$ - число, A - постоянная матрица размера $m \times n$, $\vec{b} \in \mathbb{R}^m$, $\vec{c} \in \mathbb{R}^n$ - постоянные векторы, и всюду предполагается, что матрица ковариаций у случайного вектора \vec{X} существует. (А в п.1 $\mathbf{E}\vec{X}\vec{X}^T$ - математическое ожидание случайной матрицы XX^T .)

5. Если $\vec{X}_k, k = \overline{1, n}$ - независимые случайные векторы одной и той же размерности, имеющие ковариационные матрицы $\text{Var } \vec{X}_k, k = \overline{1, n}$, то $\sum_{k=1}^n \vec{X}_k$ также имеет матрицу ковариаций, и она равна $\sum_{k=1}^n \text{Var } \vec{X}_k$.

Упражнение 1.4. Доказать, что случайный вектор нормально распределен, если и только если любая линейная комбинация его компонент нормально распределена.

Упражнение 1.5. 1. Доказать, что для неотрицательно определенной симметричной квадратной матрицы A порядка n существует и единственен **квадратный корень**, т.е. такая неотрицательно определенная симметричная квадратная матрица B того же порядка n , что $B^2 = A$.

2. Доказать, что если A - неотрицательно определенная симметричная квадратная матрица порядка n , то ее невырожденность эквивалентна ее положительной определенности.

3. Доказать, что квадратный корень из неотрицательно определенной симметричной матрицы невырожден, если и только если сама эта матрица невырождена.

Упражнение 1.6. Если случайный вектор $\vec{X} = (X_1, \dots, X_n)$ - нормальный, то любой случайный вектор, составленный из его компонент, т.е. вектор вида $(X_{i_1}, \dots, X_{i_k})$, где $i_1, \dots, i_k \in \{1, \dots, n\}$ также имеет нормальное распределение.

В частности, компоненты этого нормального вектора - нормальные случайные величины: если $\vec{X} \sim \mathcal{N}_n(\vec{a}, Q)$, где $\vec{a} = (a_1, \dots, a_n)^T, q_{ij}$ - ij -й элемент матрицы ковариаций $Q, i, j = \overline{1, n}$, то $X_i \sim \mathcal{N}_n(a_i, q_{ii})$ при $i = \overline{1, n}$.

Привести пример случайного вектора $\vec{X} = (X_1, \dots, X_n)$, не являющегося нормальным, для которого при всех $k < n, i_1, \dots, i_k \in \{1, \dots, n\}$ вектор $(X_{i_1}, \dots, X_{i_k})$ имеет нормальное распределение.

Упражнение 1.7. Доказать самостоятельно свойства 1 - 3, 5, 6 характеристических функций.

(Подсказка: при доказательстве свойств 5, 6 воспользоваться свойством 4.)

Упражнение 1.8. Доказать эквивалентность определений 1.15 и 1.16.

(**Указание:** при доказательстве того, что из определения 1.16 следует определение 1.15, воспользоваться **теоремой Каратеодори:**

если $\Omega \neq \emptyset$ - некоторое множество, \mathcal{A} - алгебра его подмножеств, $\mu_0 - \sigma$ - конечная мера на \mathcal{A} , то ее можно единственным образом продолжить до меры на $\sigma(\mathcal{A})$ - на σ -алгебре, порожденной \mathcal{A} .

Положить в рассматриваемом конкретном случае $\Omega = \mathbb{R}^n, \mathcal{A} = \mathcal{A}(\mathbb{R}^n), \sigma(\mathcal{A}) = \mathfrak{B}^n$.)

Упражнение 1.9. Если $X_m, Y_m, m = \overline{1, N}$ - множества (произвольные), то

$$\left(\bigcup_{m=1}^N X_m\right) \Delta \left(\bigcup_{m=1}^N Y_m\right) \subset \bigcup_{m=1}^N (X_m \Delta Y_m).$$

Упражнение 1.10. Подробно провести рассуждения в лемме 1.17.

Упражнение 1.11. Вывести лемму 1.18. из леммы 1.17.

Упражнение 1.11. Доказать утверждение 1.21.

Упражнение 1.12. Доказать утверждение 1.22.

Упражнение 1.12. Доказать утверждение 1.19. с помощью леммы 1.18.

(Указание: в случае невырожденной Σ положить $D = G = \mathbb{R}^n, \alpha(t) = \Sigma^{1/2}t + a$. А если Σ вырождена, то положить $C\Sigma C^T = \Lambda$ - диагональная матрица с собственными значениями матрицы Σ на главной диагонали, $\vec{\zeta} := C\vec{\xi}$)

Упражнение 1.13. Проверить следующие свойства матриц ковариации:

- 1) $\text{cov}(\vec{X}, \vec{Y}) = \text{cov}(\vec{Y}, \vec{X})^T$;
- 2) $\text{cov}(A\vec{X}, \vec{Y}) = A \text{cov}(\vec{X}, \vec{Y})$;
- 3) $\text{cov}(\vec{X}, B\vec{Y}) = \text{cov}(\vec{X}, \vec{Y})B^T$;
- 4) $\text{cov}(\vec{X} + \vec{a}, \vec{Y} + \vec{b}) = \text{cov}(\vec{X}, \vec{Y})$;
- 5) $\text{cov}(\alpha\vec{X}_1 + \beta\vec{X}_2, \vec{Y}) = \alpha \text{cov}(\vec{X}_1, \vec{Y}) + \beta \text{cov}(\vec{X}_2, \vec{Y})$;
- 6) $\text{cov}(\vec{X}, \alpha\vec{Y}_1 + \beta\vec{Y}_2) = \alpha \text{cov}(\vec{X}, \vec{Y}_1) + \beta \text{cov}(\vec{X}, \vec{Y}_2)$;
- 7) $\text{cov}(\vec{X}, \vec{X}) = \text{Var } \vec{X}$,

где $\vec{X}, \vec{X}_1, \vec{X}_2, \vec{Y}, \vec{Y}_1, \vec{Y}_2$ - случайные вектора (не обязательно нормальные), A, B - постоянные (неслучайные) матрицы, \vec{a}, \vec{b} - постоянные (неслучайные) вектора, $\alpha, \beta \in \mathbb{R}$ - постоянные числа (скаляры).

Упражнение 1.14. Доказать утверждение 1.21.

Упражнение 1.15. Доказать утверждение 1.22.

Упражнение 1.16. Доказать утверждение 1.23. с помощью формулы (1.4) для плотности нормальных векторов. (См. замечание 1.25.)

Упражнение 1.17. Доказать утверждение 1.26.

Упражнение 1.18. Доказать свойства 1 - 4 условного математического ожидания, указанные в п.5.

Упражнение 1.21. Доказать, что $\arg(X_1, X_2)$ - случайная величина, равномерно распределенная на отрезке $[0, 2\pi]$.

Упражнение 1.22. Доказать, что $\chi^2(n)$ и $\Gamma(n/2, 1/2)$ - одно и то же распределение.

(Подсказка: предварительно обосновать, что если случайные величины $X_i \sim \Gamma(\alpha_i, \lambda), i = \overline{1, p}$ независимы, $\alpha_i > 0, i = \overline{1, p}, \lambda > 0$, то $\sum_{i=1}^p X_i \sim \Gamma(\sum_{i=1}^p \alpha_i, \lambda)$).

Упражнение 1.23. Пусть A - симметричная неотрицательно определенная матрица порядка p , $\lambda_i, i = \overline{1, p}$ - ее собственные значения (не обязательно попарно различные), u_i - собственный вектор, соответствующий собственному значению $\lambda_i, i = \overline{1, p}$. Тогда матрицу A можно представить в виде $A = \sum_{i=1}^p \lambda_i u_i u_i^T$, и тогда $A^{1/2} = \sum_{i=1}^p \lambda_i^{1/2} u_i u_i^T$. Это - еще один, эквивалентный способ определения квадратного корня из неотрицательно определенной матрицы A .

Упражнение 1.24. 1) Пусть $\vec{X}_i \sim \mathcal{N}(\vec{a}_i, \Sigma_i), i = \overline{1, n}$ имеют одинаковую размерность и независимы. Тогда $\sum_{i=1}^n \vec{X}_i \sim \mathcal{N}(\sum_{i=1}^n \vec{a}_i, \sum_{i=1}^n \Sigma_i)$. (Подсказка: при доказательстве воспользоваться методом характеристических функций.)

2) Если $\vec{X} \sim \mathcal{N}(\vec{a}, \Sigma), \lambda \in \mathbb{R}$, то $\lambda\vec{X} \sim \mathcal{N}(\lambda\vec{a}, \lambda^2\Sigma)$.

Задача 1.1. Рассмотрим двумерный гауссовский вектор $X = (X_1, X_2)^T$.

Положим $\mu_1 = \mathbf{E}X_1, \mu_2 = \mathbf{E}X_2, \sigma_1^2 = \text{Var } X_1, \sigma_2^2 = \text{Var } X_2, \rho = \text{corr}(X_1, X_2)$. Пусть $\sigma_1 > 0, \sigma_2 > 0$.

1. Указать формулу для плотности случайного вектора

$$\left(\frac{X_1 - \mu_1}{\sigma_1}, \frac{X_2 - \mu_2}{\sigma_2} \right)^T.$$

2. Как выглядят линии уровня этой плотности при различных ρ , в частности, при $\rho = 0$, $\rho \rightarrow 1$, $\rho \rightarrow -1$?

Задача 1.2. (Обобщение задачи 1.19. и результатов п.7) Пусть $X \sim \mathcal{N}_n(0, I)$, т.е. случайный вектор X имеет n -мерное стандартное нормальное распределение. С вероятностью 1 он не равен нулю, а все ненулевые вектора $\vec{a} \in \mathbb{R}^n$ однозначно задаются точкой ψ на единичной сфере (через которую проходит луч, выходящий из начала координат и содержащий вектор \vec{a}) и своей длиной r . Т.е. случайный вектор X порождает еще один случайный вектор ψ , с вероятностью 1 принадлежащий единичной сфере в \mathbb{R}^n , и положительную случайную величину r . Доказать:

1. $r^2 \sim \chi^2(n-1)$;
2. ψ равномерно распределен на единичной сфере в \mathbb{R}^n ;
3. ψ, r независимы.

Задача 1.3. Пусть $X \sim \mathcal{N}_p(a, \Sigma)$. Найти условное распределение $\text{Law}(X|AX)$, где A - заданная матрица. В частности, найти условное распределение X при условии $\sum_{k=1}^p X_k = 0$.

Задача 1.4. Пусть $\{W(t)\}_{t \in [0,1]}$ - винеровский процесс. (Напомним, что это понятие означает, что это - гауссовский процесс с $\mathbf{E}W(t) = 0$, $\text{cov}(W(s), W(t)) = \min(s, t)$.) Тогда при наложении условия $W(1) = 0$ мы получаем броуновский мост, т.е. такой гауссовский процесс на $[0, 1]$ (обозначаемый так: $\{B_t^0\}_{t \in [0,1]}$), что $\mathbf{E}B_t^0 = 0$, $\text{cov}(B_s^0, B_t^0) = \min(s, t) - st$. Это означает, что при всех $t_1, \dots, t_n \in [0, 1]$ $\text{Law}(W(t_1), \dots, W(t_n)|W(1) = 0) = \text{Law}(B_{t_1}^0, \dots, B_{t_n}^0)$.

Задача 1.5. (M. Bilodeau, D. Bremer - 1999). Пусть X - n -мерный случайный вектор, $\mathbf{E}X = a$, $\text{Var} X = \Sigma$. Показать, что :

$$\min_{a \in \mathbb{R}^n} \mathbf{E}|X - a|^2 = \text{tr} \Sigma, \quad \min_{a \in \mathbb{R}^n} \mathbf{E}(X - a)(X - a)^T = \Sigma$$

и оба эти минимума достигаются при $a = \mu$.

Задача 1.6. (M. Bilodeau, D. Bremer - 1999). Пусть X - нормальный $n+m$ -мерный вектор, случайный вектор X_1 составлен из его первых n компонент, а случайный вектор X_2 - из последних m компонент. Пусть, далее, $\mathbf{E}X_1 = \mu_1$, $\mathbf{E}X_2 = \mu_2$, $\text{cov}(X_i, X_j) = \Sigma_{ij}$, т.е. $\text{Var} X_1 = \Sigma_1$, $\text{Var} X_2 = \Sigma_2$, $\Sigma_{21}^T = \Sigma_{12}$ по задаче 1.14. Показать, что

$$\min_{C, d} \mathbf{E}|X_1 - (CX_2 + d)|^2 = \text{tr} \Sigma_{12}, \quad \min_{C, d} \mathbf{E}(X_1 - (CX_2 + d))(X_1 - (CX_2 + d))^T = \Sigma_{12},$$

где минимум берется по всевозможным матрицам C размера $n \times m$ и по всевозможным векторам $d \in \mathbb{R}^n$. При этом оба минимума достигаются при $C = \Sigma_{12}\Sigma_{22}^{-1}$, $d = \mu_1 - \Sigma_{12}\Sigma_{22}^{-1}\mu_2$.

Литература. [1] Т.Андерсон. Введение в многомерный статистический анализ /Пер. с англ. - М., Физматгиз, 1963.

[2] А.Н. Ширяев. Вероятность, М., Наука, 1989.

[3] В.А. Ильин, Э.Г. Позняк. Основы математического анализа, ч.2, М., Наука, 1973.

[4] П.Л. Ульянов, А.Н. Бахвалов, М.И. Дьяченко, К.С. Казарян, П. Сифуэнтес. Действительный анализ в задачах, М., Физматлит, 2005.

Глава 2. Статистические модели для гауссовских векторов

1. Напоминание основных понятий статистики.

Определение 2.1. Базовой моделью математической статистики является **статистическое пространство** - тройка $(\mathfrak{X}, \mathfrak{F}, \{P_\theta\}_{\theta \in \Theta})$, где $\mathfrak{X} \neq \emptyset$ называется **выборочным пространством** или **пространством наблюдений** (а его элементы - **наблюдениями**), \mathfrak{F} - σ -алгебра над \mathfrak{X} , а $\{P_\theta\}_{\theta \in \Theta}$ - совокупность вероятностных мер на \mathfrak{F} . Мы считаем, что какая-либо из этих мер - истинная, т.е. реально заданная на \mathfrak{F} , но нам неизвестно, какая именно эта мера. (Но заведомо известно, что она содержится в семействе $\{P_\theta\}_{\theta \in \Theta}$).

Задача статистики - по данному наблюдению $X \in \mathfrak{X}$ сделать заключение о том, какова же истинная мера, заданная на \mathfrak{F} . Для этого достаточно сделать выводы об истинном значении параметра θ , т.е. том значении, которое соответствует истинной мере. В частности, можно попытаться построить оценки этого параметра. Пусть далее $\Theta \subset \mathbb{R}^m$.

Определение 2.2. **Оценкой параметра θ** называется любая случайная величина δ (если $m = 1$) или случайный m -мерный вектор δ (в случае $m > 1$), при всех $X \in \mathfrak{X}$ приближенно равный истинному значению параметра θ .

Такое определение, разумеется, не может считаться математически строгим: слова "приближенно равна" необходимо как-то формализовать. Вот один из способов такой формализации:

Определение 2.3. **Несмещенной оценкой параметра θ** называется случайная величина δ (если $m = 1$) или случайный m -мерный вектор (в случае $m > 1$) $\delta : \mathfrak{X} \rightarrow \mathbb{R}^m$, для которой при всех $\theta \in \Theta$

$$\mathbf{E}_\theta \delta(X) = \theta,$$

где индекс θ у знака математического ожидания означает, что оно берется по мере P_θ , т.е. равно $\int_{\mathfrak{X}} \delta(X) P_\theta(dX)$ (интеграл понимается в смысле Лебега).

Определение 2.4. **Наилучшей несмещенной оценкой параметра θ** называется такая несмещенная оценка δ_0 этого параметра, что для любой другой несмещенной оценки δ этого параметра при всех $\theta \in \Theta$ выполнено неравенство

$$\mathbf{E}_\theta (\delta_0(X) - \theta)^2 \leq \mathbf{E}_\theta (\delta(X) - \theta)^2,$$

если $m = 1$ (т.е. δ, δ_0 - случайные величины), и

$$\mathbf{E}_\theta (\delta_0(X) - \theta)(\delta_0(X) - \theta)^T \leq \mathbf{E}_\theta (\delta(X) - \theta)(\delta(X) - \theta)^T, \quad (1)$$

если $m > 1$ (т.е. δ, δ_0 - случайные вектора). Можно записать эти два неравенства и так: $\text{Var } \delta_0 \leq \text{Var } \delta$, т.к. в силу несмещенности δ, δ_0 имеем: $\mathbf{E}_\theta \delta_0 = \mathbf{E}_\theta \delta = \theta$. (Матрицы в левой и правой частях неравенства (1) симметричны, ведь это - матрицы ковариаций - см. упражнение 1.3.4, т.е. их можно сравнивать; как именно - см. гл.1, п.6)

Определение 2.5. **Статистика** - это любая случайная величина (или случайный вектор), определенный на \mathfrak{X} . Статистика T называется **достаточной**, если для всех $A \in \mathfrak{F}$ $P_\theta(A|T)$ не зависит от θ . При этом, напомним, **условная вероятность $\mathbf{P}(A|\xi)$ измеримого множества A** относительно случайной величины или случайного вектора ξ - это, по определению, $\mathbf{E}(I_A|\xi)$. Часто говорят и так: T - достаточная статистика, если условное распределение $X \in \mathfrak{X}$ при заданном $T(X)$ не зависит от θ .

Теорема 2.6. (Blackwell, Rao, 1947 - 1949.) Если δ - несмещенная оценка θ , а T - достаточная статистика, то $\delta_0 := \mathbf{E}_\theta(\delta|T)$ - также несмещенная оценка θ , и при этом она не хуже δ - это означает, что для всех $\theta \in \Theta$ $\text{Var}_\theta \delta_0 \leq \text{Var}_\theta \delta$.

Кроме того, для любых $\theta \in \Theta$ $\text{Var}_\theta \delta_0 = \text{Var}_\theta \delta$ тогда и только тогда, когда $\forall \theta \in \Theta \mathbf{P}_\theta\{\delta_0 = \delta\} = 1$.

Индексы θ при знаках \mathbf{E} , Var означают, что соответствующие математические ожидания и дисперсии - или матрицы ковариаций - вычисляются по вероятностной мере P_θ . (См. упражнение 2.1.)

Таким образом, наличие достаточной статистики позволяет улучшать несмещенные оценки.

Заметим также, что $\delta_0 = \mathbf{E}_\theta(\delta|T)$ представляет собой некоторую борелевскую функцию от T . (См. свойства условного математического ожидания, гл.1, п.5.) Значит, при поиске наилучшей несмещенной оценки - т.е. несмещенной оценки с минимальной дисперсией или матрицей ковариаций - можно ограничиться лишь борелевскими функциями от достаточной статистики (если изначально мы ей располагаем).

Определение 2.7. Достаточная статистика $T : \mathfrak{X} \rightarrow \mathbb{R}^k$ называется **полной**, если для любой борелевской функции $f : \mathbb{R}^k \rightarrow \mathbb{R}$ такой, что у случайной величины $f(T)$ существует конечное математическое ожидание, из $\mathbf{E}_\theta f(T) = 0$ следует $f(T) = 0$ почти наверное.

Теорема 2.8. (Леман, Шефаре, 1955.) Если $T : \mathfrak{X} \rightarrow \mathbb{R}^k$ - полная достаточная статистика и $f(T)$ - несмещенная оценка θ , где $f : \mathbb{R}^k \rightarrow \mathbb{R}^m$ - борелевская функция, эта несмещенная оценка является наилучшей. (См. упражнение 2.2.)

Мы будем рассматривать частный случай вышеописанной общей базовой модели: $\mathfrak{X} = \mathbb{R}^{np}$, $\mathfrak{Y} = \mathfrak{B}^{np}$, $\Theta = \{(a, Q) : a \in \mathbb{R}^p, Q - \text{положительно определенная матрица порядка } p\}$, а для $\theta = (a, Q) \in \Theta$

$$P_\theta = \underbrace{\mathcal{N}_p(a, Q) \times \dots \times \mathcal{N}_p(a, Q)}_n.$$

Это означает, что P_θ - прямое произведение n экземпляров вероятностной меры Q .

В нашем случае такое прямое произведение n экземпляров меры Q - это распределение случайного np -мерного вектора, являющегося выборкой размера n из распределения $\mathcal{N}_p(a, Q)$. (Эта выборка есть n p -мерных случайных векторов, и ее можно записать как np -мерный вектор.)

Наша задача - искать, какое именно это распределение, т.е. какие параметры a, Q оно имеет.

2. Достаточная статистика (\bar{X}, S) .

Утверждение 2.9. Если $(\vec{X}_1, \dots, \vec{X}_n)$ - выборка из $\mathcal{N}_p(\vec{a}, Q)$, $\vec{a} \in \mathbb{R}^p$ - постоянный вектор, Q - невырожденная матрица порядка p , то (\bar{X}, S) , где

$$\bar{X} = \frac{\vec{X}_1 + \dots + \vec{X}_n}{n}, \quad S = \frac{1}{n-1} \sum_{k=1}^n (\vec{X}_k - \bar{X})(\vec{X}_k - \bar{X})^T -$$

достаточная статистика.

Доказательство. Мы будем использовать **теорему о факторизации**:

$T(\xi)$ - достаточная статистика для семейства вероятностных мер, заданных плотностями $p(x, \theta)$, если и только если найдутся функции g, h , для которых $p(x, \theta) = g(T(x), \theta)h(x)$ при всех x, θ .

В данном случае совместная плотность распределения векторов $\vec{X}_1, \dots, \vec{X}_n$ равна

$$p(\vec{x}_1, \dots, \vec{x}_n) = \prod_{i=1}^n \left(\frac{1}{\sqrt{2\pi}} \right)^p \frac{1}{\sqrt{\det Q}} \exp\left(-\frac{1}{2}(\vec{x}_i - \vec{a})^T Q^{-1}(\vec{x}_i - \vec{a})\right) =$$

$$= \left(\frac{1}{\sqrt{2\pi}} \right)^{pn} \left(\frac{1}{\sqrt{\det Q}} \right)^n \exp\left(-\frac{1}{2} \sum_{i=1}^n (\vec{x}_i - \vec{a})^T Q^{-1} (\vec{x}_i - \vec{a})\right)$$

Но в показателе экспоненты стоит $\text{tr } C$, где $C = X^T Q^{-1} X$, X - матрица размера $p \times n$, k - й столбец которой равен $\vec{X}_k - \vec{a}$, т.е. jk -й элемент которой равен $X_{jk} - a_j$, $j, k = \overline{1, n}$, где мы полагаем $\vec{X}_k = (X_{k1}, \dots, X_{kn})$, $k = \overline{1, n}$. Кроме того, пусть $\bar{X} = (\bar{X}_1, \dots, \bar{X}_n)$. Заметим, что $\text{tr } C = \text{tr}(Q^{-1} X X^T)$ (мы применили свойство следа матрицы: $\text{tr } AB = \text{tr } BA$.)

Но по правилу умножения матриц kl -й элемент матрицы $X X^T$ равен

$$\begin{aligned} \sum_{j=1}^n (X_{jk} - a_k)(X_{jl} - a_l) &= \sum_{j=1}^n ((X_{jk} - \bar{X}_k) + (\bar{X}_k - a_k))((X_{jl} - \bar{X}_l) + (\bar{X}_l - a_l)) = \\ &= \sum_{j=1}^n (X_{jk} - \bar{X}_k)(X_{jl} - \bar{X}_l) + \sum_{j=1}^n (\bar{X}_k - a_k)(X_{jl} - \bar{X}_l) + \sum_{j=1}^n (X_{jk} - \bar{X}_k)(\bar{X}_l - a_l) + \\ &\quad + \sum_{j=1}^n (\bar{X}_k - a_k)(\bar{X}_l - a_l) = (n-1)s_{kl} + (\bar{X}_k - a_k) \sum_{j=1}^n (X_{jl} - \bar{X}_l) + \\ &\quad + (\bar{X}_l - a_l) \sum_{j=1}^n (X_{jk} - \bar{X}_k) + n(\bar{X}_k - a_k)(\bar{X}_l - a_l) = (n-1)s_{kl} + n(\bar{X}_k - a_k)(\bar{X}_l - a_l), \end{aligned}$$

где s_{kl} - это kl -й элемент матрицы S ; мы использовали то, что $\sum_{j=1}^n (X_{jk} - \bar{X}_k) = \sum_{j=1}^n X_{jk} - n\bar{X}_k = n\bar{X}_k - n\bar{X}_k = 0$, аналогично $\sum_{j=1}^n (X_{jl} - \bar{X}_l) = 0$ при всех $k, l = \overline{1, n}$. Т.е. $X X^T = (n-1)S + n(\bar{X} - \vec{a})(\bar{X} - \vec{a})^T$. Значит, в показателе экспоненты в формуле для плотности стоит число

$$-\frac{1}{2} \text{tr}((n-1)S + n(\bar{X} - \vec{a})(\bar{X} - \vec{a})^T),$$

и плотность $p(\vec{x}_1, \dots, \vec{x}_n)$ имеет вид функции от \vec{a}, Q, \bar{X}, S , т.е. по теореме факторизации (\bar{X}, S) - достаточная статистика. Утверждение доказано.

Замечание 2.10. Матрица S называется **выборочной матрицей ковариаций**, а \bar{X} - **эмпирическим средним**. Нетрудно видеть, что это - многомерные аналоги обычных характеристик выборки (X_1, \dots, X_n) из одномерного распределения:

$$\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k, \quad \hat{\sigma}^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2.$$

Утверждение 2.11. $\mathbf{E}\bar{X} = a, \mathbf{E}S = Q$.

Доказательство. Докажем первое равенство: $\mathbf{E}\bar{X} = \mathbf{E}\left(\frac{1}{n} \sum_{k=1}^n \vec{X}_k\right) = \frac{1}{n} \sum_{k=1}^n \mathbf{E}\vec{X}_k = \frac{1}{n} \sum_{k=1}^n \mathbf{E}\vec{a} = n\vec{a}/n = \vec{a}$. Теперь докажем второе. Необходимо доказать, что $\mathbf{E}s_{ij} = q_{ij}$ (где s_{ij}, q_{ij} - ij -е элементы матриц S, Q соответственно), при всех $i, j = \overline{1, n}$. Но ij -й элемент матрицы S равен

$$\begin{aligned} \frac{1}{n-1} \sum_{k=1}^n (X_{ki} - \bar{X}_i)(X_{kj} - \bar{X}_j) &= \frac{1}{n-1} \sum_{k=1}^n (X_{ki}X_{kj} - X_{ki}\bar{X}_j - X_{kj}\bar{X}_i + \bar{X}_i\bar{X}_j) = \\ &= \frac{1}{n-1} \left(\sum_{k=1}^n X_{ki}X_{kj} - n\bar{X}_i\bar{X}_j - \bar{X}_i n\bar{X}_j + n\bar{X}_i\bar{X}_j \right) = \frac{1}{n-1} \left(\sum_{k=1}^n X_{ki}X_{kj} - n\bar{X}_i\bar{X}_j \right). \end{aligned}$$

Вычислим его математическое ожидание.

Заметим, что

$$\mathbf{E} \sum_{k=1}^n X_{ki} X_{kj} = \sum_{k=1}^n \mathbf{E} X_{ki} X_{kj} = (\text{cov}(X_{1i}, X_{1j}) + \mathbf{E} X_{1i} \mathbf{E} X_{1j}) = n(q_{ij} + a_i a_j).$$

Далее, $\mathbf{E} n \bar{X}_i \bar{X}_j = n(\text{cov}(\bar{X}_i, \bar{X}_j) + \mathbf{E} \bar{X}_i \mathbf{E} \bar{X}_j)$. Но $\bar{X} \sim \mathcal{N}(\vec{a}, Q/n)$, т.к.

$$\sum_{k=1}^n \vec{X}_k \sim \mathcal{N}(n\vec{a}, nQ)$$

(мы использовали утверждения обоих пунктов упражнения 1.24). Значит,

$$\text{cov}(\bar{X}_i, \bar{X}_j) = q_{ij}/n, \mathbf{E} \bar{X}_i = a_i, \mathbf{E} \bar{X}_j = a_j.$$

Отсюда заключаем, что $\mathbf{E} n \bar{X}_i \bar{X}_j = n(q_{ij}/n + a_i a_j) = q_{ij} + n a_i a_j$. Итак, $\mathbf{E} s_{ij} = \frac{1}{n-1}(n(q_{ij} + a_i a_j) - (q_{ij} + n a_i a_j)) = q_{ij}$. Утверждение доказано.

Итак, \bar{X}, S - несмещенная оценка для \vec{a}, Q и достаточная статистика. Можно показать, что это - полная статистика, тогда по теореме Лемана - Шефаре получим, что \bar{X}, S - наилучшая несмещенная оценка \vec{a}, Q .

3. Независимость \bar{X}, S .

Утверждение 2.12. Если имеем $p = 1$, т.е. $X_i, i = \overline{1, n}$ - случайные величины, то $\bar{X} = (X_1 + \dots + X_n)/n, \hat{\sigma}^2 = \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2$ независимы.

Доказательство. Пусть $X_1, \dots, X_n \sim \mathcal{N}(a, \sigma^2)$ независимы, $\vec{X} = (X_1, \dots, X_n)^T \sim \mathcal{N}(\vec{\mu}, \sigma^2 I)$, I - единичная матрица порядка n , $\vec{\mu} = (a, \dots, a)^T$. Пусть D - ортогональная матрица порядка n с первой строкой $(1/\sqrt{n}, \dots, 1/\sqrt{n})$. (См. задачу 2.3.)

Т.к. $\vec{X} \sim \mathcal{N}(\vec{\mu}, \sigma^2 I)$, то

$$\vec{Y} \sim \mathcal{N}(D\vec{\mu}, D\sigma^2 D^T) = \mathcal{N}(D\vec{\mu}, \sigma^2 I)$$

по упражнению 1.3.3, откуда получаем, что компоненты вектора \vec{Y} независимы. (Ведь $\text{cov}(Y_k, Y_l)$ - это kl -й элемент в матрице $\text{Var} \vec{Y} = \sigma^2 I$, т.е. 0 - применяем утверждение 1.13.) Значит, $Y_1, \sum_{k=2}^n Y_k^2$ независимы. Но $Y_1 = X_1/\sqrt{n} + \dots + X_n/\sqrt{n} = \sqrt{n} \bar{X}$, т.к. первая строка матрицы D равна $(1/\sqrt{n}, \dots, 1/\sqrt{n})$. Отсюда $Y_1^2 = n \bar{X}^2$. Значит,

$$\sum_{k=2}^n Y_k^2 = |\vec{Y}|^2 - Y_1^2 = |D\vec{X}|^2 - n \bar{X}^2.$$

Т.к. D - ортогональная матрица, то $|D\vec{X}|^2 = |\vec{X}|^2$. Значит, $|D\vec{X}|^2 - n \bar{X}^2 = |\vec{X}|^2 - n \bar{X}^2$. Но

$$\begin{aligned} \hat{\sigma}^2 &= \sum_{k=1}^n (X_k - \bar{X})^2 = \sum_{k=1}^n (X_k^2 - 2\bar{X} X_k + \bar{X}^2) = \\ &= \sum_{k=1}^n X_k^2 - 2\bar{X} \sum_{k=1}^n X_k + \sum_{k=1}^n \bar{X}^2 = |\vec{X}|^2 - n \bar{X}^2. \end{aligned}$$

Тем самым доказано, что $\hat{\sigma}^2 = \sum_{k=1}^n Y_k^2$ и $\bar{X} = Y_1$ независимы. Утверждение доказано.

Итак, независимость $\bar{X}, \hat{\sigma}^2$ в одномерном случае доказана. Как традиционно доказывается эта независимость в многомерном случае (т.е. в случае, когда выборка производится из многомерного, а не из одномерного распределения)?

Лемма 2.13. Пусть $X_i, i = \overline{1, n}$ независимые гауссовские вектора, $X_i \sim \mathcal{N}_p(\mu_i, Q), i = \overline{1, n}$. Пусть, далее, C - ортогональная матрица порядка n , $c_{\alpha\beta}$ - $\alpha\beta$ -й элемент матрицы C ,

$$Y_\alpha = \sum_{\beta=1}^n c_{\alpha\beta} X_\beta$$

при $\alpha = \overline{1, n}$. Тогда:

(a) (Y_1, \dots, Y_n) - гауссовский вектор;

(b) $\mathbf{E}Y_\alpha = \sum_{\beta=1}^n c_{\alpha\beta} \mathbf{E}X_\beta$;

(c) $\text{cov}(Y_\alpha, Y_\beta) = \delta_{\alpha\beta} Q$ (следствие: при $\alpha \neq \beta Y_\alpha, Y_\beta$ некоррелированы, а, значит, в силу утверждения 1.10 и п.(a) данного утверждения, независимы);

(d) $\sum_{i=1}^n X_i X_i^T = \sum_{\alpha=1}^n X_\alpha X_\alpha^T$.

Доказательство: см. упражнение 2.4.

Теперь докажем основное

Утверждение 2.14. И в многомерном случае \overline{X} и S тоже независимы.

Доказательство Пусть $X_i, i = \overline{1, n} \sim N_p(a, Q)$ - компоненты данной выборки; они независимы. Тогда, если

$$Y_\alpha := \sum_{\beta=1}^n c_{\alpha\beta} (X_\beta - a), \alpha = \overline{1, n},$$

где C - указанная в лемме 2.13 ортогональная матрица с первой строкой $(1/\sqrt{n}, \dots, 1/\sqrt{n})$ (см. задачу 2.1), то

$$Y_1 = \sum_{\beta=1}^n \frac{1}{\sqrt{n}} (X_\beta - a) = \frac{1}{\sqrt{n}} (n\overline{X} - na) = \sqrt{n}(\overline{X} - a).$$

Кроме того, $Y_1 Y_1^T + \sum_{\alpha=2}^n Y_\alpha Y_\alpha^T = \sum_{\alpha=1}^n (X_\alpha - a)(X_\alpha - a)^T$ и $Y_\alpha, \alpha = \overline{1, n}$, независимы. (Мы применили лемму 2.5, подставив $X_\alpha - a$ вместо $X_\alpha, \alpha = \overline{1, n}$ в условие этой леммы.) Но

$$\begin{aligned} \sum_{\alpha=1}^n (X_\alpha - a)(X_\alpha - a)^T &= \sum_{\alpha=1}^n ((X_\alpha - \overline{X}) + (\overline{X} - a))((X_\alpha - \overline{X}) + (\overline{X} - a))^T = \\ &= \sum_{\alpha=1}^n ((X_\alpha - \overline{X})(X_\alpha - \overline{X})^T + (\overline{X} - a)(X_\alpha - \overline{X})^T + (X_\alpha - \overline{X})(\overline{X} - a)^T + \\ &+ (\overline{X} - a)(\overline{X} - a)^T) = \sum_{\alpha=1}^n (X_\alpha - \overline{X})(X_\alpha - \overline{X})^T + (\overline{X} - a) \left(\sum_{\alpha=1}^n (X_\alpha - \overline{X}) \right)^T + \\ &+ \sum_{\alpha=1}^n (X_\alpha - \overline{X})(\overline{X} - a)^T + n(\overline{X} - a)(\overline{X} - a)^T = \\ &= \sum_{\alpha=1}^n (X_\alpha - \overline{X})(X_\alpha - \overline{X})^T + n(\overline{X} - a)(\overline{X} - a)^T = (n-1)S + n(\overline{X} - a)(\overline{X} - a)^T. \end{aligned}$$

Наконец, $Y_1 Y_1^T = \sqrt{n}(\overline{X} - a)(\sqrt{n}(\overline{X} - a))^T = n(\overline{X} - a)(\overline{X} - a)^T$. Значит, $\sum_{\alpha=2}^n Y_\alpha Y_\alpha^T = (n-1)S$,

$$S = \frac{1}{n-1} \sum_{\alpha=2}^n Y_\alpha Y_\alpha^T.$$

Т.к. $Y_\alpha, \alpha = \overline{1, n}$, независимы (см. выше), $\sqrt{n}(\overline{X} - a) = Y_1$, откуда $\overline{X} = Y_1/\sqrt{n} + a$, а S зависит только от $Y_\alpha, \alpha = \overline{2, n}$, то S и \overline{X} независимы. Утверждение доказано.

Заметим, что $(n-1)S = \sum_{\alpha=2}^n Y_\alpha Y_\alpha^T \sim \mathcal{W}_p(n-1, Q)$, где

$$\mathcal{W}_p(m, Q) = \sum_{i=1}^m \xi_i \xi_i^T -$$

статистика Уишарта (Wishart) с m степенями свободы. (Предполагается, что $\xi_i \sim \mathcal{N}(0, Q), i = \overline{1, m}$ независимы.)

4. Оценка максимального правдоподобия для параметров \vec{a}, Q .

Напомним понятие "оценка максимального правдоподобия".

Пусть $(\mathfrak{X}, \mathfrak{F}, \{P_\theta\}_{\theta \in \Theta})$ - рассмотренная в начале данной главы общая статистическая модель, и при этом $\mathfrak{X} = \mathbb{R}^m$. Пусть, далее, при всех $\theta \in \Theta$ P_θ - абсолютно непрерывная мера на \mathbb{R}^m , т.е. при любом $\theta \in \Theta$ P_θ имеет плотность; обозначим значение этой плотности в точке $x \in \mathbb{R}^m$ через $p(x, \theta)$. Положим $X \in \mathfrak{X}$, т.е. будем считать, что мы провели наблюдение и X - его результат.

Определение 2.15. Правдоподобием для данного наблюдения X называется функция из Θ в \mathbb{R} , сопоставляющая элементу $\theta \in \Theta$ значение $p(X, \theta)$.

Здравый смысл подсказывает, что "хорошей" оценкой для истинного значения θ является, по-видимому, такое θ , при котором достигается максимум $p(X, \theta)$.

Определение 2.16. Значение $\theta = \hat{\theta} \in \Theta$, при котором правдоподобие $p(X, \theta)$ достигает максимума, называется **оценкой максимального правдоподобия**.

Найдем эту оценку для рассматриваемой конкретной модели - для выборки из нормального многомерного распределения.

Утверждение 2.17.

$$\hat{Q} = S_n := \frac{1}{n} \sum_{i=1}^n (X_i - \overline{X})(X_i - \overline{X})^T, \hat{a} = \overline{X} -$$

оценка максимального правдоподобия для неизвестных параметров \vec{a}, Q распределения $\mathcal{N}_p(\vec{a}, Q)$ (по умолчанию считаем, что $Q > 0$) по известной выборке (X_1, \dots, X_n) из этого распределения.

Доказательство. Правдоподобие при данных значениях параметров \vec{a}, Q - это плотность, если подставить $\vec{x}_i = \vec{X}_i, i = \overline{1, n}$. Необходимо показать, что при указанных в условии значениях \vec{a}, Q это правдоподобие принимает наибольшее значение.

Но компоненты выборки независимы, т.е. если

$$p_0(\vec{x}; \vec{a}, Q) = \frac{1}{\sqrt{(2\pi)^p \det Q}} \exp\left(-\frac{1}{2}(\vec{x} - \vec{a})^T Q^{-1}(\vec{x} - \vec{a})\right) -$$

плотность $\mathcal{N}_p(\vec{a}, Q)$ (напомним, что по условию $Q > 0$, т.е. Q невырождена), то $p(\vec{x}_1, \dots, \vec{x}_n; \vec{a}, Q) = p_0(\vec{x}_1; \vec{a}, Q) \cdot \dots \cdot p_0(\vec{x}_n; \vec{a}, Q)$, т.е.

$$\begin{aligned} p(\vec{X}_1, \dots, \vec{X}_n; \vec{a}, Q) &= \prod_{i=1}^n \frac{1}{\sqrt{(2\pi)^p \det Q}} \exp\left(-\frac{1}{2}(\vec{X}_i - \vec{a})^T Q^{-1}(\vec{X}_i - \vec{a})\right) = \\ &= \frac{1}{(\sqrt{2\pi})^{np}} \frac{1}{(\sqrt{\det Q})^n} \exp\left(-\frac{1}{2} \sum_{i=1}^n (\vec{X}_i - \vec{a})^T Q^{-1}(\vec{X}_i - \vec{a})\right). \end{aligned}$$

Показатель полученной экспоненты равен

$$-\frac{1}{2}n(\overline{X} - \vec{a})^T Q^{-1}(\overline{X} - \vec{a}) + n \operatorname{tr}(Q^{-1}S_n).$$

(См. доказательство теоремы 2.9, формулу для показателя экспоненты; мы использовали также, что $(n-1)S = nS_n$.) Если бы $\hat{a} \neq \bar{X}$, то

$$-\frac{1}{2}n(\bar{X} - \hat{a})^T \hat{Q}^{-1}(\bar{X} - \hat{a}) + n \operatorname{tr}(\hat{Q}^{-1}S_n) < n \operatorname{tr}(\hat{Q}^{-1}S_n)$$

и

$$p(\vec{X}_1, \dots, \vec{X}_n; \hat{a}, \hat{Q}) < p(\vec{X}_1, \dots, \vec{X}_n; \bar{X}, \hat{Q}),$$

но это противоречит тому, что \hat{a}, \hat{Q} - оценка наибольшего правдоподобия.

Т.е. $\hat{a} = \bar{X}$. Теперь докажем, что $\hat{Q} = S_n$.

Заметим, что

$$\ln p(\vec{X}_1, \dots, \vec{X}_n; \hat{a}, Q) = -\frac{n}{2} \ln \det Q - \frac{n}{2} \operatorname{tr}(Q^{-1}S_n) + \text{const},$$

Пусть

$$q(Q) = -\frac{n}{2} \ln \det Q - \frac{n}{2} \operatorname{tr}(Q^{-1}S_n).$$

Это - функция, определенная на E - множестве всех положительно определенных симметричных матриц порядка p . Нам необходимо доказать, что при $Q = S_n$ у этого выражения достигается строгий максимум, т.е. для любой $Q \in E, Q \neq S_n$ $q(Q) < q(S_n)$. Для этого докажем, что при $T = I_p$ у выражения $\tilde{r}(T) := q(S_n T^{-1})$ достигается строгий максимум, т.е. если $T \in E, T \neq I_p$, то $r(T) < r(I)$. (Ведь $T \mapsto S_n T^{-1}$ - биекция $E \rightarrow E$ - см. упражнение 2.7.) Достаточно доказать, что у функции

$$r(T) := \frac{2}{n} \tilde{r}(T) + \ln \det S_n$$

в точке $T = I_p$ достигается строгий максимум. Преобразуем эту функцию:

$$\begin{aligned} r(T) &= \frac{2}{n} \left(-\frac{n}{2} \ln \det(S_n T^{-1}) - \frac{n}{2} \operatorname{tr}((S_n T^{-1})^{-1} S_n) \right) + \ln \det S_n = \\ &= -\ln \det(S_n T^{-1}) - \operatorname{tr}(T S_n^{-1} S_n) + \ln \det S_n = -\ln \left(\frac{\det S_n}{\det T} \right) - \operatorname{tr} T + \ln \det S_n = \\ &= -(\ln \det S_n - \ln \det T) - \operatorname{tr} T + \ln \det S_n = \ln \det T - \operatorname{tr} T. \end{aligned}$$

Пусть $T \in E, T \neq I_p$. Тогда найдется ортогональная матрица C порядка p , для которой $C^{-1}TC = C^TTC = \Lambda$, где Λ - диагональная матрица с собственными значениями $\lambda_i, i = \overline{1, p}$ матрицы T на главной диагонали. Но эти собственные значения положительны, т.к. матрица T положительно определена. (См. упражнение 2.8.) Далее, $\det T = \det(C^{-1}TC) = \det \Lambda = \lambda_1 \lambda_2 \dots \lambda_p$, $\operatorname{tr} T = \operatorname{tr}(C^{-1}TC) = \operatorname{tr} \Lambda = \sum_{i=1}^p \lambda_i$, т.к. матрицы T, Λ подобны, а у подобных матриц след и определитель равны.

Отсюда получаем: $r(T) = \ln(\lambda_1 \lambda_2 \dots \lambda_p) - \sum_{i=1}^p \lambda_i$.

Мы можем ограничиться рассмотрением случая, когда все числа $\lambda_i, i = \overline{1, p}$ равны. Действительно, если хотя бы два из этих чисел не равны, то по неравенству Коши для

$$\mu_1 = \mu_2 = \dots = \mu_p := \frac{1}{n} \sum_{i=1}^n \lambda_i$$

выполнено следующее:

$$\sqrt[p]{\lambda_1 \lambda_2 \dots \lambda_p} < \mu_1 = \sqrt[p]{\mu_1 \mu_2 \dots \mu_p},$$

т.е.

$$\lambda_1 \lambda_2 \dots \lambda_p < \mu_1 \mu_2 \dots \mu_p,$$

а, кроме того,

$$\sum_{i=1}^p \lambda_i = \sum_{i=1}^p \mu_i.$$

Отсюда имеем:

$$\ln(\lambda_1 \lambda_2 \dots \lambda_p) - \sum_{i=1}^p \lambda_i < \ln(\mu_1 \mu_2 \dots \mu_p) - \sum_{i=1}^p \mu_i.$$

Но все числа $\mu_i, i = \overline{1, p}$ равны.

Итак, пусть далее $\lambda_1 = \dots = \lambda_p$. Тогда $\lambda_1 = \dots = \lambda_p \neq 1$, иначе бы $\Lambda = I_p$, т.е. $C^{-1}TC = I_p, T = CI_pC^{-1} = I_p$, что противоречит предположению $T \neq I_p$. Значит, $r(T) = \ln(\lambda_1^p) - p\lambda_1 = p(\ln \lambda_1 - \lambda_1) < -p$, т.к. $\lambda_1 \neq 1$. (См. упражнение 2.9.) Однако $r(I_p)$ как раз равно $-p$: $r(I_p) = \ln \det I_p - \text{tr } I_p = \ln 1 - p = -p$. Тем самым неравенство $r(T) < r(I_p)$ при $T \in E, T \neq I_p$ доказано, а вместе с ним - и исходное утверждение. ■

5. Скобка Тюринга для выборок из многомерных распределений.

Запишем выборку (X_1, \dots, X_n) из p -мерного распределения в виде матрицы $X = \|X_1| \dots |X_n\|$ размера $p \times n$, столбцы которой - X_i , т.е. компоненты выборки.

Определение 2.18. Положим для двух таких матриц $X = \|X_1| \dots |X_n\|, Y = \|Y_1| \dots |Y_n\|$ $\langle X, Y \rangle := \sum_{\alpha=1}^n X_\alpha Y_\alpha^T = XY^T$. Т.е. $\langle X, Y \rangle$ - квадратная матрица порядка p ; она называется **скобкой Тюринга**. Если $p = 1$, то эта операция - обычное скалярное произведение n -мерных векторов $(X_1, \dots, X_n), (Y_1, \dots, Y_n)$.

Утверждение 2.19. Скобка Тюринга обладает следующими свойствами (аналогичными свойствам обычного скалярного произведения):

1. $\langle X, Y \rangle = \langle Y, X \rangle^T$;
2. $\langle \alpha_1 X_1 + \alpha_2 X_2, Y \rangle = \alpha_1 \langle X_1, Y \rangle + \alpha_2 \langle X_2, Y \rangle$;
3. $\langle X, \alpha_1 Y_1 + \alpha_2 Y_2 \rangle = \alpha_1 \langle X, Y_1 \rangle + \alpha_2 \langle X, Y_2 \rangle$;
4. $\langle AX, Y \rangle = A \langle X, Y \rangle$;
5. $\langle X, AY \rangle = \langle X, Y \rangle A^T$;
6. $\langle X, X \rangle$ неотрицательно определена для всех матриц X размера $p \times n$;
7. Если A ортогональна, то $\langle X, Y \rangle = \langle XA, YA \rangle$,

где всюду здесь X, Y - матрицы размера $p \times n$, A - квадратная матрица порядка p , $\alpha_1, \alpha_2 \in \mathbb{R}$. (См. упражнение 2.5.)

Пусть (X_1, \dots, X_n) - выборка из распределения $\mathcal{N}_p(a, Q)$, $X = \|X_1| \dots |X_n\|$ - матрица размера $p \times n$. Тогда $\|X_1 - a| \dots |X_n - a\| = X - ae$, $e = (1, \dots, 1)$ - n -мерная строка.

Утверждение 2.20. $X - ae \sim \mathcal{W}_p(n, Q)$.

Доказательство. Пусть $Y = (X - ae)C$, C - ортогональная матрица порядка n с первым столбцом $(1/\sqrt{n}, \dots, 1/\sqrt{n})^T = (e/\sqrt{n})^T$. (См. задачу 2.1.) Тогда $Y_1 = (X - ae)(e/\sqrt{n})^T =$

§5. Доверительные эллипсоиды (метод Шеффе).

Задачи и упражнения к главе 2

Упражнение 2.1. Доказать теорему 2.1.

(Подсказка: рассмотреть вначале случай одномерного θ и потом свести к нему случай многомерного θ . Доказательство этой теоремы очень похоже на доказательство теоремы 1.18 из гл.1.)

Упражнение 2.2. Доказать теорему 2.2.

Упражнение 2.3. Почему существует ортогональная матрица порядка n с первой строкой $(\frac{1}{\sqrt{n}}, \dots, \frac{1}{\sqrt{n}})$ или с первым столбцом $(\frac{1}{\sqrt{n}}, \dots, \frac{1}{\sqrt{n}})^T$

Упражнение 2.4. Доказать лемму 2.13.

Упражнение 2.5. Доказать утверждение 2.19.

Упражнение 2.6. Доказать, что для квадратной матрицы C порядка p

$$W_p(m, CQC^T) = CW_p(m, Q)C^T.$$

В частности, $W_p(m, Q) = Q^{1/2}W_p(m, I_p)Q^{1/2}$.

Глава 3.

Проверки статистических гипотез.

Рассмотрим проверку по выборке X_1, \dots, X_n из $N_p(a, Q)$ простой гипотезы

$$H : a = a_0, \quad (*)$$

где a_0 - заданный p -мерный вектор.

В последующих разделах будет рассказано о двух способах, с помощью которых можно строить статистические критерии для проверки гипотез о средних (о математических ожиданиях) по многомерным гауссовским наблюдениям: это метод Роя (S.N.Roy) и метод отношения правдоподобий. Второй метод связан с применением леммы Неймана-Пирсона и широко используется для проверки простых гипотез. Для одной выборки, при проверке (*), оба метода приводят к одному и тому же статистическому критерию (критерию Хотеллинга), но для более сложных многомерных линейных моделей статистические правила получаются разными. Об этом будет рассказано в последующих главах. Сопоставляя эти конкретные критерии, мы придем к пониманию, как в многомерном линейном анализе устроены разумные критерии для проверки линейных гипотез (и как распределены их статистики при гипотезах и альтернативах).

Замечание. Для выборки X_1, \dots, X_n из $N_p(a, Q)$ параметр a называется параметром положения, а параметр Q — параметром масштаба. Обычно при изменении условий проведения эксперимента, в результате которого мы получаем выборку X_1, \dots, X_n , вначале меняется параметр положения, затем — параметр масштаба и в последнюю очередь — распределение выборки.

1. Метод Роя для проверки простой гипотезы.

Пусть u обозначает переменный p -мерный вектор, $u \in \mathbb{R}^p$. От выборки X_1, \dots, X_n из $N_p(a, Q)$, где матрица Q невырождена, перейдем к скалярным величинам x_1, \dots, x_n , положив $x_i = u^T X_i, i = \overline{1, n}$. Случайные величины x_1, \dots, x_n образуют выборку из $N(u^T a, u^T Q u)$. Таким образом, гипотеза (*) для данного u переходит в гипотезу

$$H^{(u)} : u^T a = u^T a_0. \quad (3.1)$$

Ясно, что гипотеза $H : a = a_0$ верна тогда и только тогда, когда гипотеза $H^{(u)}$ верна для любого $u \in \mathbb{R}^p$. Поэтому гипотезу (*) следует отвергнуть, если отвергнутой окажется хотя бы одна из гипотез $H^{(u)}$.

В зависимости от того, задана наблюдателю матрица Q или нет, надо пользоваться либо гауссовским, либо стьюдентовским распределениями для проверки гипотезы $H^{(u)}$. Положим (как обычно)

$$\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i, \bar{x} := \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{i=1}^n u^T X_i = u^T \left(\frac{1}{n} \sum_{i=1}^n X_i \right) = u^T \bar{X}.$$

Рассмотрим сначала более трудный случай, когда матрица Q неизвестна. Тогда неизвестна и дисперсия наблюдений x_1, \dots, x_n . В этом случае для проверки гипотезы $H^{(u)}$ (3.1) следует использовать "отношение Стьюдента" или, что то же самое, "Стьюдентову дробь":

$$\sqrt{n} \frac{u^T (\bar{X} - a_0)}{s}, \quad (3.2)$$

где

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \sum_{i=1}^n (u^T X_i - u^T \bar{X})^2 =$$

$$\begin{aligned}
&= \frac{1}{n-1} \sum_{i=1}^n [u^T(X_i - \bar{X})][u^T(X_i - \bar{X})]^T = \\
&= \frac{1}{n-1} u^T \left(\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X}) \right) u = \frac{1}{n-1} u^T S u
\end{aligned}$$

Утверждение 3.1. Статистика (3.2) имеет распределение Стьюдента с $(n-1)$ степенями свободы и параметром нецентральности

$$\delta = \frac{\sqrt{n} u^T (a - a_0)}{\sqrt{u^T Q u}}. \quad (3.3)$$

(См. упражнение 3.1.)

Гипотезу $H^{(u)} : \mu = \mu_0$, или эквивалентно $H^{(u)} : \delta = 0$, следует отвергнуть (на уровне 2α , $0 < \alpha < 0.5$), если

$$\left| \sqrt{n} \frac{u^T (\bar{X} - a_0)}{s} \right| > t_{1-\alpha}, \quad (3.4)$$

где $t_{1-\alpha}$ обозначает $(1-\alpha)$ -квантиль распределения Стьюдента с $(n-1)$ степенями свободы.

Поскольку правая часть (3.4) одна и та же для всех $u \in \mathbb{R}^p$, представляется разумным отвергать гипотезу (*), когда статистика

$$\max_{u \in \mathbb{R}^p} \sqrt{n} \frac{u^T (\bar{X} - a_0)}{s}, \quad (3.5)$$

где $s = \sqrt{\frac{u^T S u}{n-1}}$, принимает "слишком большие" значения. При этом ясно, что критические значения для (3.5) надо выбирать, руководствуясь ее распределением при гипотезе (*).

Если же матрица Q задана, то нужно использовать статистику

$$\max_{u \in \mathbb{R}^p} \sqrt{n} \frac{u^T (\bar{X} - a_0)}{\sqrt{u^T Q u}}, \quad (3.6)$$

и отвергать гипотезу, когда эта статистика принимает достаточно большие значения. (См. упражнение 3.2.)

2. Вычисление статистик (3.5) и (3.6).

Лемма 3.2. Пусть R - произвольная положительно определенная симметричная матрица порядка p , Y - произвольный p -мерный вектор. Тогда

$$\max_{u \in \mathbb{R}^p} \frac{u^T Y}{\sqrt{u^T R u}} = \sqrt{Y^T R^{-1} Y}.$$

Доказательство. Заметим, что функция

$$f(u) = \max_{u \in \mathbb{R}^p} \frac{u^T Y}{\sqrt{u^T R u}} \quad (3.10)$$

не меняет своего значения при замене $v = \alpha u$, где $\alpha > 0$. (См. упражнение 3.3.) Таким образом, задачу о нахождении данного максимума можно заменить задачей о нахождении

$$\max_{\substack{u \in \mathbb{R}^p \\ u^T R u = 1}} u^T Y \quad (3.11)$$

Для нахождения полученного максимума воспользуемся методом Лагранжа отыскания локального условного экстремума.

Напомним его. (См. также [3], гл. 15, § 5.)

Пусть требуется найти экстремум дифференцируемой функции $f : U \rightarrow \mathbb{R}$, где $U \subset \mathbb{R}^{k+m}$ - открытое множество, при наличии m условий связи:

$$\begin{aligned} F_1(x_1, \dots, x_k, y_1, \dots, y_m) &= 0 \\ F_2(x_1, \dots, x_k, y_1, \dots, y_m) &= 0 \\ &\dots \\ F_m(x_1, \dots, x_k, y_1, \dots, y_m) &= 0 \end{aligned}$$

При этом будем предполагать, что функции $F_i, i = \overline{1, m}$, определены и непрерывно дифференцируемы на множестве U , и в любой точке этого множества якобиан

$$\begin{vmatrix} \frac{\partial F_1}{\partial y_1} & \dots & \frac{\partial F_1}{\partial y_m} \\ \vdots & \ddots & \vdots \\ \frac{\partial F_m}{\partial y_1} & \dots & \frac{\partial F_m}{\partial y_m} \end{vmatrix}$$

отличен от нуля.

Если в точке $P_0 \in U$ функция f имеет локальный условный экстремум, то найдутся $\lambda_i \in \mathbb{R}, i = \overline{1, m}$, для которых функция $\Psi := f + \sum_{i=1}^m \lambda_i F_i$ удовлетворяет в точке P_0 условиям:

$$\begin{aligned} \frac{\partial \Psi}{\partial x_i} &= 0, i = \overline{1, k} \\ \frac{\partial \Psi}{\partial y_i} &= 0, i = \overline{1, m}, \end{aligned}$$

а, кроме того, $F_i(P_0) = 0, i = \overline{1, m}$.

Обратно, если в точке $P_0 \in U$ выполнены данные условия и при этом $d^2\Psi$ в этой точке - положительно (отрицательно) определенная квадратичная форма, то P_0 есть точка локального условного минимума (соответственно, максимума).

Замечание. Напомним, что квадратичная форма $b : \mathbb{R}^m \rightarrow \mathbb{R}$ называется **отрицательно определенной**, если при всех $x \in \mathbb{R}^m, x \neq 0$ $b(x) < 0$. Симметричная матрица B порядка m называется **отрицательно определенной**, если при всех $x \in \mathbb{R}^m, x \neq 0$ $x^T B x < 0$. Будем обозначать это так: $B < 0$. Очевидно, квадратичная форма отрицательно определена, если и только если ее матрица отрицательно определена. (См. упражнение 3.2.) Для данного понятия выполнены некоторые простые свойства - см. упражнение 3.3.

Заметим, что в изложенном утверждении все $m + k$ переменных $x_1, \dots, x_k, y_1, \dots, y_m$ равноправны, т.е. можно не требовать, чтобы именно якобиан функций $F_i, i = \overline{1, m}$ по переменным $y_i, i = \overline{1, m}$ не обращался в ноль. Переформулируем метод Лагранжа следующим образом.

Пусть $f : U \subset \mathbb{R}^l$ - дифференцируемая функция на открытом множестве $U \subset \mathbb{R}^l$, даны $q < l$ условий связи $F_i = 0, F_i, i = \overline{1, q}$, определены и непрерывно дифференцируемы на U , причем ранг матрицы Якоби

$$\begin{pmatrix} \frac{\partial F_1}{\partial x_1} & \dots & \frac{\partial F_1}{\partial x_l} \\ \vdots & \ddots & \vdots \\ \frac{\partial F_q}{\partial x_1} & \dots & \frac{\partial F_q}{\partial x_l} \end{pmatrix}$$

максимален, т.е. равен q . Тогда необходимые условия условного локального экстремума в точке $P_0 \in U$ таковы: найдутся числа $\lambda_i \in \mathbb{R}, i = \overline{1, q}$, для которых

$$\frac{\partial \Psi}{\partial x_i} = 0, i = \overline{1, l}$$

в точке P_0 , где

$$\Psi := f + \sum_{i=1}^q \lambda_i F_i,$$

а также $F_i(P_0) = 0, i = \overline{1, q}$.

Если к этим условиям добавить еще положительную (отрицательную) определенность квадратичной формы $d^2\Psi$ в точке P_0 , то получим достаточные условия того, что в точке P_0 функция f имеет локальный условный минимум (соответственно, максимум).

Применим этот метод к данной задаче. В нашем случае $q = 1, l = p, f(u_1, \dots, u_p) = u^T Y = \sum_{i=1}^p u_i Y_i$, где $u_i, Y_i - i$ -е компоненты векторов $u, Y \in \mathbb{R}^p$. Условие связи - лишь одно:

$$u^T R u = 1 \Leftrightarrow \sum_{i,j=1}^p u_i u_j r_{ij} = 1 \Leftrightarrow F_1(u_1, \dots, u_p) = 0,$$

где $F_1(u_1, \dots, u_p) := \sum_{i,j=1}^p u_i u_j r_{ij} - 1$. Функция F_1 определена и непрерывно дифференцируема на открытом множестве $U := \mathbb{R}^p \setminus \{0\}$, и матрица Якоби в любой точке этого множества (в данном случае это вектор-строка - градиент функции F_1) отлична от нуля, т.е., эквивалентно, имеет ранг 1, иными словами, максимальный ранг. Действительно,

$$\frac{\partial F_1}{\partial u_k} = \frac{\partial}{\partial u_k} \left(\sum_{\substack{i,j=1 \\ i,j \neq k}}^p u_i u_j r_{ij} + 2 \sum_{\substack{i=1 \\ i \neq k}}^p u_i u_k r_{ik} + p_k^2 r_{kk} \right)$$

(мы использовали то, что матрица

■

Следствие 3.3. Статистика (3.6) равна

$$\sqrt{n(\bar{X} - a_0)^T Q^{-1}(\bar{X} - a_0)}.$$

Следствие 3.4. Статистика (3.5) равна

$$\sqrt{n(\bar{X} - a_0)^T S^{-1}(\bar{X} - a_0)}.$$

Поскольку мы отвергаем гипотезу (*) при больших значениях статистик (3.5) или (3.6), в качестве критериальных статистик для (*) можно взять статистики

$$n(\bar{X} - a_0)^T Q^{-1}(\bar{X} - a_0) \quad (3.12)$$

в случае, когда матрица Q известна, или

$$T^2 := n(\bar{X} - a_0)^T S^{-1}(\bar{X} - a_0) \quad (3.13)$$

в случае, когда неизвестную матрицу Q приходится замещать ее выборочной оценкой S .

Статистику T^2 называют статистикой Хотеллинга (Hotelling, Harold; 1931). Она является многомерным обобщением статистики Стьюдента $t = \sqrt{n} \frac{\bar{x} - \mu}{s}$. Хотеллинг нашел распределение T^2 при гипотезе (*).

3. Метод отношения правдоподобий.

Напомним, в чем состоит этот общий метод, часто применяемый для построения статистических критериев. Пусть ξ - случайная величина (неважно, в каком пространстве ξ принимает значения), имеющая плотность $p(x, \theta)$ относительно некоторой меры; θ - параметр, $\theta \in \Theta, \Theta$ - заданное множество.

Гипотеза, подлежащая проверке по наблюдению $H : \theta \in \mathcal{K}$, где \mathcal{K} - заданное множество, $\mathcal{K} \subset \Theta$.

По аналогии со статистикой Неймана-Пирсона (для проверки простой гипотезы против простой альтернативы) предлагается следующее семейство критических множеств:

$$Q_z := \left\{ x : \frac{p(x, \hat{\theta})}{p(x, \tilde{\theta})} > z \right\},$$

где $\hat{\theta}$ - оценка наибольшего правдоподобия для θ , при условии $\theta \in \Theta$; $\tilde{\theta}$ - оценка наибольшего правдоподобия для θ при условии $\theta \in \mathcal{K}$ (то есть при гипотезе).

Статистику этого критерия можно записать как отношение двух правдоподобий:

$$\lambda := \frac{p(\xi, \hat{\theta})}{p(\xi, \tilde{\theta})}, \text{ или } \lambda := \frac{\max_{\theta \in \Theta} p(\xi, \theta)}{\max_{\theta \in \mathcal{K}} p(\xi, \theta)}. \quad (3.14)$$

Гипотезу $H : \theta \in \mathcal{K}$ предлагается отвергать, если наблюдаемое λ чрезмерно велико, то есть если λ превосходит критическое значение. Это критическое значение следует вычислять, имея распределение статистики λ при гипотезе $\theta \in \mathcal{K}$.

Не исключается, вообще говоря, что распределение статистики λ (3.14) окажется зависящим от истинного значения параметра θ , даже если $\theta \in \mathcal{K}$, то есть даже если проверяемая гипотеза верна. К счастью, в этой и последующих гауссовских задачах распределение отношения правдоподобий λ оказывается свободным от влияния θ , если $\theta \in \mathcal{K}$ (одним и тем же для всех $\theta \in \mathcal{K}$). Как говорят, при гипотезе статистика λ оказывается свободной (distribution free). Именно это обстоятельство, уже отмеченное ранее для одномерных гауссовских линейных моделей, оправдывает применение здесь метода отношения правдоподобий.

В нашей задаче параметром θ служит пара (a, Q) , гипотеза (*) относится к вектору a . Множества \mathcal{K} и Θ определяются в зависимости от того, известна наблюдателю матрица Q или нет.

В этом случае Θ - это множество возможных значений параметра $a \in \mathbb{R}^p$, то есть $\Theta = \mathbb{R}^p$; множество \mathcal{K} состоит из одной точки $a_0 \in \mathbb{R}^p$. Поэтому $\tilde{\theta} = (a_0, Q)$, $\hat{\theta} = (\bar{X}, Q)$.

Напомним, что правдоподобие для выборки X_1, \dots, X_n из $N_p(a, Q)$ имеет вид:

$$\begin{aligned} p(\vec{X}_1, \dots, \vec{X}_n; \vec{a}, Q) &= \prod_{i=1}^n \frac{1}{\sqrt{(2\pi)^p \det Q}} \exp\left(-\frac{1}{2}(\vec{X}_i - \vec{a})^T Q^{-1}(\vec{X}_i - \vec{a})\right) = \\ &= \frac{1}{(\sqrt{2\pi})^{np}} \frac{1}{(\sqrt{\det Q})^n} \exp\left(-\frac{1}{2} \sum_{i=1}^n (\vec{X}_i - \vec{a})^T Q^{-1}(\vec{X}_i - \vec{a})\right). \end{aligned}$$

Замещая в выражении для правдоподобий параметр указанными значениями, находим статистику:

$$\lambda = \exp \left\{ -\frac{1}{2} \left[\sum_{i=1}^n (X_i - \bar{X})^T Q^{-1} (X_i - \bar{X}) - \sum_{i=1}^n (X_i - a_0)^T Q^{-1} (X_i - a_0) \right] \right\}. \quad (3.15)$$

Воспользуемся формулой, которая уже встречалась нам в предыдущих главах:

$$\sum_{i=1}^n (X_i - a)^T Q^{-1} (X_i - a) = \sum_{i=1}^n (X_i - \bar{X})^T Q^{-1} (X_i - \bar{X}) + n(\bar{X} - a)^T Q^{-1} (\bar{X} - a). \quad (3.16)$$

Таким образом, статистика (3.15) преобразуется к виду:

$$\lambda = \exp \left\{ \frac{n}{2} (\bar{X} - a_0)^T Q^{-1} (\bar{X} - a_0) \right\}.$$

Следовательно, критической статистикой для проверки (*) может служить следующая статистика:

$$n(\bar{X} - a_0)^T Q^{-1} (\bar{X} - a_0). \quad (3.17)$$

Отвергать гипотезу (*) следует при больших значениях статистики (3.17).

Нетрудно видеть, что мы получили ту же статистику (3.12) и то же правило для проверки (*), что мы нашли, применив метод Роя.

Здесь Θ - это множество всех пар (a, Q) , где $a \in \mathbb{R}^p$, Q - произвольная положительно определенная $(p \times p)$ -матрица. Множество \mathcal{K} состоит из пар (a_0, Q) . Как в главе 2,

$$\hat{\theta} = (\bar{X}, S_n), \tilde{\theta} = (a_0, \tilde{Q}),$$

где

$$\tilde{Q} = \frac{1}{n} \sum_{i=1}^n (X_i - a_0)(X_i - a_0)^T, S_n = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T.$$

Следовательно, отношение правдоподобий в данном случае примет вид:

$$\lambda = \left(\frac{\sqrt{\det \tilde{Q}}}{\sqrt{\det S_n}} \right)^n \exp \left\{ -\frac{1}{2} \left[\sum_{i=1}^n (X_i - \bar{X})^T S_n^{-1} (X_i - \bar{X}) - \sum_{i=1}^n (X_i - a_0)^T \tilde{Q}^{-1} (X_i - a_0) \right] \right\}. \quad (3.18)$$

Воспользуемся уже знакомым нам приемом, который использовался в главе 2:

$$\sum_{i=1}^n (X_i - a_0)^T \tilde{Q}^{-1} (X_i - a_0) = \text{tr} \tilde{Q}^{-1} \sum_{i=1}^n (X_i - a_0)(X_i - a_0)^T = \text{tr}(nI) = np.$$

Аналогично,

$$\sum_{i=1}^n (X_i - \bar{X})^T S_n^{-1} (X_i - \bar{X}) = \text{tr} S_n^{-1} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T = \text{tr}(nI) = np.$$

Поэтому статистика λ (3.18) равна:

$$\lambda = \left(\frac{\det \left[\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T + n(\bar{X} - a_0)(\bar{X} - a_0)^T \right]}{\det \left[\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \right]} \right)^{\frac{n}{2}}.$$

Таким образом, получаем следующее промежуточное правило для проверки гипотезы (*):

отвергать гипотезу $H : a = a_0$ при больших значениях статистики

$$\frac{\det \left[\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T + n(\bar{X} - a_0)(\bar{X} - a_0)^T \right]}{\det \left[\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T \right]} \quad (3.19)$$

Статистику (2.5) можно упростить и довести до вида T^2 (1.13), если воспользоваться следующей леммой об определителях блочных матриц.

Упростим статистику (3.19), воспользовавшись следующей леммой.

Лемма 3.2: Пусть квадратная матрица Σ разбита на блоки, причем Σ_{11} , Σ_{22} - квадратные невырожденные матрицы:

$$\Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$$

Тогда

$$\det(\Sigma) = \det(\Sigma_{11}) \det(\Sigma_{22} - \Sigma_{21}\Sigma_{11}^{-1}\Sigma_{12}) = \det(\Sigma_{22}) \det(\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}) \quad (3.20)$$

Доказательство. \square При доказательстве воспользуемся правилом перемножения блочных матриц. Кроме того, будет использовано следующее тождество:

$$\det \begin{pmatrix} A & 0 \\ B & C \end{pmatrix} = \det A \det C,$$

где A , B , C - матрицы размера $n \times n$, $m \times n$, $m \times m$ соответственно, а 0 - нулевая матрица размера $n \times m$. (Такая лемма известна из линейной алгебры.)

Таким образом, воспользовавшись сделанными замечаниями, получим:

$$\begin{aligned} \det \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} &= \det \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \det \begin{pmatrix} I & -\Sigma_{11}^{-1}\Sigma_{12} \\ 0 & I \end{pmatrix} = \\ &= \det \begin{pmatrix} \Sigma_{11} \cdot I + \Sigma_{12} \cdot 0 & -\Sigma_{11}\Sigma_{11}^{-1}\Sigma_{12} + \Sigma_{12} \cdot I \\ \Sigma_{21} \cdot I + \Sigma_{22} \cdot 0 & -\Sigma_{21}\Sigma_{11}^{-1}\Sigma_{12} + \Sigma_{22} \cdot I \end{pmatrix} = \det(\Sigma_{11}) \det(\Sigma_{22} - \Sigma_{21}\Sigma_{11}^{-1}\Sigma_{12}). \end{aligned}$$

Вторая формула доказывается аналогично:

$$\begin{aligned} \det \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} &= \det \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \det \begin{pmatrix} I & 0 \\ -\Sigma_{22}^{-1}\Sigma_{21} & I \end{pmatrix} = \\ &= \det \begin{pmatrix} \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} & \Sigma_{11} \cdot 0 + \Sigma_{12} \cdot I \\ \Sigma_{21} - \Sigma_{22}\Sigma_{22}^{-1}\Sigma_{21} & \Sigma_{21} \cdot 0 + \Sigma_{22} \cdot I \end{pmatrix} = \det(\Sigma_{11}) \det(\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}). \end{aligned}$$

■

Теперь вернемся к отношению (3.19). Определитель, который стоит в числителе этой дроби, представим в следующем виде:

$$\det \begin{pmatrix} \sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T & -\sqrt{n}(\bar{X} - a_0) \\ \sqrt{n}(\bar{X} - a_0)^T & 1 \end{pmatrix} \quad (3.21)$$

В том, что это верно, можно убедиться, воспользовавшись второй из формул (3.20) только что доказанной леммы. Теперь для вычисления (3.21) применим первую из формул (3.20). Попутно заменим на $(n-1)S$ выражение $\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})^T$. Таким образом, получаем, что числитель (3.19) равен:

$$\det[(n-1)S] \det[1 + n(\bar{X} - a_0)^T [(n-1)S]^{-1} (\bar{X} - a_0)] = \det[(n-1)S] \det[1 + \frac{1}{n-1} T^2],$$

где определение статистики Хотеллинга T^2 было введено ранее, см. (3.13). После таких преобразований числитель дроби (3.19) упрощается, и правило для проверки гипотезы (*) можно теперь сформулировать следующим образом:

отвергать гипотезу (*) при больших значениях статистики

$$\det(1 + \frac{1}{n-1} T^2).$$

Заметим, что символ \det можно опустить, т.к. $1 + \frac{1}{n-1}T^2$ - число, т.е. матрица размера 1×1 , а определитель матрицы такого размера, т.е. числа - это само это число. В итоге получаем, что (*) следует отвергать, если

$$T^2 \geq Const,$$

что совпадает с (3.13).

Глава 4. Проверки статистических гипотез - продолжение; доверительные эллипсоиды.

1. Распределение статистики T^2 .

Для нахождения распределения статистики T^2 докажем следующую теорему:

Лемма 4.1. Пусть Y, Y_1, \dots, Y_k - независимые одинаково распределенные случайные величины с распределением $N_p(0, \Sigma)$, причем матрица Σ невырождена (т.е., эквивалентно, она положительно определена - см. упражнение 5.2 в главе 1) . Пусть

$$W = \sum_{i=1}^k Y_i Y_i^T, \quad T^2 = (\nu + Y)^T W^{-1} (\nu + Y), \quad (3.21),$$

где ν - произвольный вектор, $\nu \in \mathbb{R}^p$. Тогда для $k \geq p$

$$T^2 \stackrel{d}{=} \frac{\chi^2(p, \Delta)}{\chi^2(k - p + 1)}, \quad (3.22)$$

причем случайные величины в числителе и знаменателе независимы, и параметр нецентральности Δ определяется равенством

$$\Delta = \nu^T \Sigma^{-1} \nu. \quad (3.23)$$

Замечание 4.2. Из (3.22) следует, что

$$\frac{k - p + 1}{p} T^2 \stackrel{d}{=} F(p, k - p + 1, \Delta). \quad (3.24)$$

Замечание 4.3. При $k \geq p$ матрица W невырождена с вероятностью 1, а при $k < p$ вырождена почти наверное. (См. упражнения 3.1, 3.2.)

Введем обозначения для элементов матриц $\Sigma, \Sigma^{-1}, W, W^{-1}$. Пусть $\sigma_{ij}, \sigma^{ij}, w_{ij}, w^{ij}$ - ij -е элементы этих матриц; $\Sigma, \Sigma^{-1}, W, W^{-1}$ соответственно.

Доказательство теоремы существенно опирается на следующие леммы.

Лемма 4.4. $\frac{\sigma^{11}}{w^{11}} \stackrel{d}{=} \chi^2(k - p + 1)$.

Доказательство. \square Рассмотрим случайный вектор $X \sim N_p(0, \Sigma)$, $X = (x_1, \dots, x_p)^T$. Разобьем на блоки матрицы Σ и W :

$$\Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix} \quad W = \begin{pmatrix} W_{11} & W_{12} \\ W_{21} & W_{22} \end{pmatrix}.$$

Здесь $\Sigma_{11} = \sigma_{11}, W_{11} = w_{11}$ - матрицы размера 1×1 , т.е. являющиеся числами, матрицы $\Sigma_{22} ? W_{22}$ - квадратные матрицы размера $(p - 1) \times (p - 1)$.

Ранее было отмечено, что

$$\mathcal{L}(X^{(1)}/X^{(2)}) = N(\Sigma_{12}\Sigma_{22}^{-1}X^{(2)}, \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}).$$

Заметим, что в данном случае, когда размерность $X^{(1)}$ равна единице, верно следующее:

$$(\sigma^{11})^{-1} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}. \quad (3.25)$$

Действительно, по определению

$$\sigma^{11} = \frac{\det(\Sigma_{22})}{\det(\Sigma)},$$

а в силу леммы 3.2

$$\det(\Sigma) = \det(\Sigma_{22}) \cdot \det(\Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}).$$

Аналогично,

$$(w^{11})^{-1} = W_{11} - W_{12}W_{22}^{-1}W_{21}. \quad (3.26)$$

Как уже отмечалось,

$$X^{(1)} = \Sigma_{12}\Sigma_{22}^{-1}X^{(2)} + \xi, \quad (3.27)$$

где ξ — независимая от $X^{(2)}$ случайная величина, распределенная по гауссовскому закону

$N(0, \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21})$, то есть в силу (3.25) — по закону $N(0, (\sigma^{11})^{-1})$.

Для случайных векторов, фигурирующих в условии теоремы 3.1, равенство (3.27) означает, что

$$Y_i^{(1)} = \Sigma_{12}\Sigma_{22}^{-1}Y_i^{(2)} + \xi_i \quad i = \overline{1, k}, \quad (3.28)$$

где ξ_1, \dots, ξ_k суть независимые и не зависящие от $Y_1^{(2)}, \dots, Y_k^{(2)}$ гауссовские случайные величины, распределенные по закону $N(0, (\sigma^{11})^{-1})$.

Положим

$$R^2 = \min_{\beta \in \mathbb{R}^{p-1}} \sum_{i=1}^k \left(Y_i^{(1)} - \beta^T Y_i^{(2)} \right)^2. \quad (3.29)$$

При фиксированных значениях $Y_1^{(2)}, \dots, Y_k^{(2)}$ случайная величина R^2 распределена как

$(\sigma^{11})^{-1}\chi^2(k-p+1)$, что следует из теории гауссовской линейной регрессии, примененной к модели (3.29). Поскольку $Y_1^{(2)}, \dots, Y_k^{(2)}$ — случайные величины, сказанное выше относится к условному распределению R^2 при фиксированных $Y_1^{(2)}, \dots, Y_k^{(2)}$. Поскольку при любых значениях $Y_1^{(2)}, \dots, Y_k^{(2)}$ условное распределение R^2 одно и то же, то оно не зависит от значений $Y_1^{(2)}, \dots, Y_k^{(2)}$ и совпадает с безусловным (т.е. обычным) распределением R^2 . Итак, установлено, что случайная величина R^2 распределена по закону

$$R^2 \sim (\sigma^{11})^{-1}\chi^2(k-p+1). \quad (3.30)$$

Остается лишь указать для R^2 явное выражение. Для этого можно воспользоваться готовыми формулами из главы 1, п.5 (условное математическое ожидание для гауссовских векторов, т.е. линейная регрессия — см. также п.6 в той же главе), но проще проделать необходимые выкладки непосредственно. Найдем сначала значение $\hat{\beta}$, при котором правая часть (3.29) достигает минимума. Введем функцию

$$Q(\beta) := \sum_{i=1}^k \left(Y_i^{(1)} - \beta^T Y_i^{(2)} \right)^2 = \sum_{i=1}^k \left(Y_i^{(1)} - \beta^T Y_i^{(2)} \right) \left(Y_i^{(1)} - \beta^T Y_i^{(2)} \right)^T \quad (3.31)$$

Пусть $d\beta$ обозначает приращение β . Вычислим приращение $Q(\cdot)$, представив его в виде

$$Q(\beta + d\beta) - Q(\beta) = \nabla Q(\beta)d\beta + o(d\beta).$$

здесь $\nabla Q(\beta)$ обозначает градиент функции $Q(\cdot)$ в точке β , ∇Q — вектор-строка. Прямым вычислением находим, что

$$Q(\beta + d\beta) - Q(\beta) = -2 \sum_{i=1}^k (Y_i^{(1)} - \beta^T Y_i^{(2)}) (Y_i^{(2)})^T d\beta + o(d\beta).$$

Приравняв нулю подученное для ∇Q выражение, получим, что градиент обращается в ноль (а функция $Q(\beta)$, соответственно, достигает минимального значения) при

$$\hat{\beta} = \left[\sum_{i=1}^k \left(Y_i^{(2)} \right) \left(Y_i^{(2)} \right)^T \right]^{-1} \left[\sum_{i=1}^k \left(Y_i^{(1)} \right) \left(Y_i^{(2)} \right)^T \right]. \quad (3.32)$$

Подставив полученное выражение (3.32) в (3.31), найдем, что R^2 (3.29) равно

$$R_0^2 = \sum_{i=1}^k Y_i^{(1)} Y_i^{(1)} - \left(\sum_{i=1}^k Y_i^{(1)} Y_i^{(2)} \right)^T \left(\sum_{i=1}^k Y_i^{(2)} Y_i^{(2)} \right)^{-1} \left(\sum_{i=1}^k Y_i^{(1)} Y_i^{(2)} \right)^T. \quad (3.33)$$

Теперь заметим, что составляющие выражения (3.33) — это блоки матрицы $W = \sum_{i=1}^k Y_i Y_i^T$, которые мы указали ранее. Поэтому

$$R^2 = W_{11} - W_{12} W_{22}^{-1} W_{21},$$

и, согласно (3.26), равно $(w^{11})^{-1}$. Поэтому

$$R^2 = (w^{11})^{-1} \quad (3.34)$$

Сопоставив (3.34) с (3.30), найдем, что

$$(w^{11})^{-1} \stackrel{d}{=} (\sigma^{11})^{-1} \chi^2(k-p+1).$$

Таким образом, утверждение леммы доказано. ■

Лемма 4.5. $\frac{l^T \Sigma^{-1} l}{l^T W^{-1} l} \stackrel{d}{=} \chi^2(k-p+1)$ для любого $l \in \mathbb{R}^p$, $l \neq 0$.

□ Выберем l таким, что $|l| = 1$. Рассмотрим ортогональную матрицу B , первая строка которой есть l^T . Введем случайные векторы $\tilde{Y}_1, \dots, \tilde{Y}_k$, положив $\tilde{Y}_i = B Y_i$, $i = \overline{1, k}$. Ясно, что $\tilde{Y}_1, \dots, \tilde{Y}_k$ суть независимые $N_p(0, \tilde{\Sigma})$, где $\tilde{\Sigma} = B \Sigma B^T$. Рассмотрим матрицу $\tilde{W} = \sum_{i=1}^k \tilde{Y}_i \tilde{Y}_i^T = B W B^T$. Введем обозначения для элементов матрицы $\tilde{\Sigma}, \tilde{W}, \tilde{\Sigma}^{-1}, \tilde{W}^{-1}$. Положим

$$\tilde{\Sigma} = \|\tilde{\sigma}_{ij}\|, \tilde{\Sigma}^{-1} = \|\tilde{\sigma}^{ij}\|, \tilde{W} = \|\tilde{w}_{ij}\|, \tilde{W}^{-1} = \|\tilde{w}^{ij}\|.$$

Заметим, что в силу выбора матрицы B

$$l^T \Sigma^{-1} l = (Bl)^T [B \Sigma B^T]^{-1} (Bl) = (1, 0, \dots, 0)^T \tilde{\Sigma}^{-1} (1, 0, \dots, 0) = \tilde{\sigma}^{11}.$$

Аналогично:

$$l^T W^{-1} l = \tilde{w}^{11}.$$

Поэтому

$$\frac{l^T \Sigma^{-1} l}{l^T W^{-1} l} = \frac{\tilde{\sigma}^{11}}{\tilde{w}^{11}} \stackrel{d}{=} \chi^2(k-p+1)$$

по доказанной лемме 3. ■

Обратимся теперь к **доказательству теоремы 1**.

□ Представим (3.21) в виде:

$$\mathcal{T}^2 = \frac{(Y + \nu)^T W^{-1} (Y + \nu)}{(Y + \nu)^T \Sigma^{-1} (Y + \nu)} (Y + \nu)^T \Sigma^{-1} (Y + \nu). \quad (3.35)$$

В силу леммы 4.4 условное распределение при фиксированном Y случайной величины

$$\frac{(Y + \nu)^T W^{-1} (Y + \nu)}{(Y + \nu)^T \Sigma^{-1} (Y + \nu)} \quad (3.36)$$

— это распределение $\chi^2(k - p + 1)$. Заметим, что это распределение - одно и то же при всех значениях Y . Следовательно, "безусловное" распределение, т.е. просто распределение (3.36) есть $\chi^2(k - p + 1)$. Кроме того, как случайная величина, (3.36) не зависит от Y . Следовательно, (3.36) не зависит от

$$(Y + \nu)^T \Sigma^{-1} (Y + \nu). \quad (3.37)$$

Как известно, случайная величина (3.37) распределена по закону $\chi^2(k - p + 1, \Delta)$, где значение параметра нецентральности Δ определяется формулой (3.23).

В результате получаем, что распределение \mathcal{T}^2 (3.35) - такое же, как у отношения двух независимых случайных величин, распределенных по закону χ^2 , как это и утверждается в (3.32). Остается лишь напомнить, что по определению

$$F(p, k - p + 1, \Delta) = \frac{\frac{1}{p} \chi^2(p, \Delta)}{\frac{1}{k - p + 1} \chi^2(k - p + 1)},$$

так что

$$\mathcal{T}^2 \stackrel{d}{=} \frac{p}{k - p + 1} F(p, k - p + 1, \Delta),$$

где $F(p, k - p + 1, \Delta)$ — это распределение Фишера со степенями свободы $p, k - p + 1$ и параметром нецентральности Δ . Таким образом, теорема полностью доказана. ■

Теперь мы можем доказать следующую теорему, касающуюся статистики T^2 Хотеллинга:

Теорема 4.6. Если $n > p$, то

$$T^2 = n(\bar{X} - a_0)^T S^{-1} (\bar{X} - a_0) \stackrel{d}{=} \frac{(n - 1)p}{n - p} F(p, n - p, \Delta), \quad (3.38)$$

где параметр нецентральности Δ определяется формулой:

$$\Delta = n(a - a_0)^T Q^{-1} (a - a_0), \quad (3.39)$$

□ Для доказательства надо учесть, что

(a)

$$(n - 1)S = W \stackrel{d}{=} \sum_{i=1}^{n-1} Y_i Y_i^T,$$

где Y_1, \dots, Y_{n-1} суть независимые $N_p(0, Q)$;

(b)

$$\sqrt{n}(\bar{X} - a_0) \stackrel{d}{=} Y \sim N_p(\nu, Q),$$

где $\nu = \sqrt{n}(a - a_0)$, и случайный вектор Y не зависит от Y_1, \dots, Y_{n-1} .

Следовательно, к статистике

$$T^2 = (n-1)(Y + \nu)^T W^{-1} (Y + \nu)$$

применима теорема 1 с заменой k на $n-1$. Отсюда

$$T^2 \stackrel{d}{=} \frac{(n-1)p}{n-p} F(p, n-p, \Delta),$$

где

$$\Delta = n(a - a_0)^T Q^{-1} (a - a_0). \blacksquare$$

§2. Доверительные эллипсоиды.

Определение 4.7. Пусть $(\mathfrak{X}, \mathfrak{F}, \{\mathbf{P}_\theta | \theta \in \Theta\})$ - исходное статистическое пространство (напомним, это определение было введено в §1 главы 2), $\tau : \Theta \rightarrow \mathbb{R}^n$ - заданная функция, $\alpha \in [0, 1]$ - некоторое число. Тогда **доверительное множество для функции τ с доверительной вероятностью α** - это любое подмножество $A_X \subset \mathbb{R}^n$, зависящее от $X \in \mathfrak{X}$ (или, более формально, функция $\mathfrak{X} \rightarrow 2^{\mathbb{R}^n}$, где $2^{\mathbb{R}^n}$ - множество всех подмножеств \mathbb{R}^n), для которого при всех $\theta \in \Theta$

$$\mathbf{P}_\theta \{X \in \mathfrak{X} | \tau(\theta) \in A_X\} \geq \alpha.$$

Возникает естественный частный случай этого очень общего определения. Пусть $\Theta := \Theta_1 \times \Theta_2 \times \dots \times \Theta_m$, где $\Theta_k \subset \mathbb{R}^{n_k}$. Т.е. неизвестный параметр θ есть набор из m неизвестных параметров $(\theta_1, \dots, \theta_m)$, которые представляют из себя конечномерные векторы. Тогда доверительное множество для θ_k , где $k = \overline{1, m}$ - некоторый фиксированный индекс, есть, по определению, доверительное множество для функции $\tau : \Theta \rightarrow \mathbb{R}^{n_k}$, $\tau(\theta) := \theta_k$, т.е., говоря по-другому, соответствие, которое каждому $X \in \mathfrak{X}$ сопоставляет подмножество $A_X \subset \mathbb{R}^{n_k}$ так, что при всех $\theta \in \Theta$

$$\mathbf{P}_\theta \{X \in \mathfrak{X} | \theta_k \in A_X\} \geq \alpha.$$

Здесь $\alpha \in [0; 1]$ - заданная доверительная вероятность.

Если α достаточно близко к единице (например, $\alpha = 0,99$), то, построив доверительное множество, мы можем сказать, что функция τ от неизвестного параметра θ , по-видимому, лежит именно в этом множестве - хотя неизвестно точно, чему же эта функция равна. Это - другой подход к оцениванию неизвестного параметра θ и функций τ от него; в известном смысле он противоположен построению оценок.

Замечание 4.8. Частный случай доверительных множеств, доверительные интервалы - хорошо известное понятие в математической статистике. Напомним, что для одномерной нормальной выборки $X = (X_1, \dots, X_n)^T$, где $X_k \sim \mathcal{N}(a, \sigma^2)$, $k = \overline{1, n}$ - независимые и одинаково распределенные случайные величины, а дисперсия σ^2 известна,

$$\left(\bar{X} - \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}}, \bar{X} + \frac{\sigma}{\sqrt{n}} z_{1-\frac{\alpha}{2}} \right) -$$

доверительный интервал для a с доверительной вероятностью $1-2\alpha$, где $\alpha \in (0; 1/2)$, а через z_β обозначен квантиль стандартного нормального распределения $\mathcal{N}(0, 1)$, соответствующий уровню $\beta \in (0; 1)$.

Если же дисперсия σ^2 неизвестна, то

$$\left(\bar{X} - \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}}, \bar{X} + \frac{s}{\sqrt{n}} z_{1-\frac{\alpha}{2}} \right) -$$

доверительный интервал для a , соответствующий уровню значимости $1-2\alpha$, где опять $\alpha \in (0; 1/2)$, но t_β - квантиль распределения Стьюдента с $n-1$ степенями

свободы, соответствующий уровню $\beta \in (0; 1)$. Это - классические результаты статистики.

Теперь мы стоим перед аналогичной, совершенно естественно возникающей многомерной задачей: как же построить доверительный интервал для неизвестного параметра a (вектора математических ожиданий для многомерного гауссовского распределения) по выборке из этого распределения? При этом не только вектор средних a , но и матрица ковариаций Q этого распределения нам не известна; однако мы считаем, что она заведомо невырождена, т.е., эквивалентно, положительно определена.

Более формально: если $\Theta := \{(a, Q) | a \in \mathbb{R}^p, Q > 0\}$, $\mathbf{P}_\theta = \mathcal{N}_p(a, Q) \times \mathcal{N}_p(a, Q) \times \dots \times \mathcal{N}_p(a, Q)$ для $\theta = (a, Q) \in \Theta$,

$$(\mathfrak{X}, \mathfrak{F}, \{\mathbf{P}_\theta | \theta \in \Theta\}) = (\mathbb{R}^{pn}, \mathfrak{B}(\mathbb{R}^{pn}), \{\mathcal{N}_p(a, Q) \times \mathcal{N}_p(a, Q) \times \dots \times \mathcal{N}_p(a, Q) | a \in \mathbb{R}^p, Q > 0\})$$

(произведение состоит из n сомножителей) - исходное статистическое пространство, являющееся, как отмечалось в §1 главы 2, базой для наших многомерных моделей, то каково доверительное множество $A_X \subset \mathbb{R}^p$ для функции $\tau : \Theta \rightarrow \mathbb{R}^p$, определяемой так: $\tau(\theta) := a$ для $\theta = (a, Q) \in \Theta$?

Но мы уже располагаем инструментами для решения этой задачи. А именно: мы знаем, что если $X = (X_1, \dots, X_n)^T$ - выборка из распределения $\mathcal{N}_p(a, Q)$ (мы будем считать ее pn -мерным вектором - столбцом), то

$$n(\bar{X} - a)^T S^{-1}(\bar{X} - a) \sim \frac{(n-1)p}{n-p} F(p, n-p),$$

где, напомним, $F(p, n-p)$ - распределение Фишера (Снедекора) с p , $n-p$ степенями свободы, $\bar{X} = \frac{1}{n} \sum_{k=1}^n X_k$ - эмпирическое среднее, $S := \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})(X_k - \bar{X})^T$ - эмпирическая матрица ковариаций.

Отсюда немедленно получаем следующий результат.

Утверждение 4.9. Если для $X \in \mathbb{R}^{pn}$ мы определим множество

$$E_X := \left\{ a \in \mathbb{R}^p | n(\bar{X} - a)^T S^{-1}(\bar{X} - a) < \frac{(n-1)p}{n-p} F_{1-\varepsilon}(p, n-p) \right\} \subset \mathbb{R}^p,$$

то оно будет доверительным множеством для параметра a , соответствующим доверительной вероятности $1 - \varepsilon$ ($\varepsilon \in (0; 1)$).

В случае, когда матрица Q ковариаций известна, т.е., формально говоря, $\Theta := \mathbb{R}^p$, $\mathbf{P}_\theta = \mathcal{N}_p(a, Q) \times \mathcal{N}_p(a, Q) \times \dots \times \mathcal{N}_p(a, Q)$ для $\theta = a$ (сомножителей, как всегда, n ; кроме того, $Q > 0$), имеем:

$$n(\bar{X} - a)^T Q^{-1}(\bar{X} - a) \sim \chi^2(p),$$

и очевидным образом строится доверительное множество.

Утверждение 4.10. Если $\varepsilon \in (0; 1)$, то для $X \in \mathfrak{X} = \mathbb{R}^{pn}$

$$E'_X := \{ a \in \mathbb{R}^p | n(\bar{X} - a)^T Q^{-1}(\bar{X} - a) < \chi^2_{1-\varepsilon}(p) \} \subset \mathbb{R}^p -$$

доверительное множество с доверительной вероятностью $1 - \varepsilon$.

Эти доверительные множества являются n -мерными эллипсоидами (или, вернее, областями, ограниченными эллипсоидами - ведь, формально говоря, в аналитической геометрии эллипсоидом называется не область в \mathbb{R}^p , а поверхность.) Они так и называются - **доверительными эллипсоидами**.

После этих простых соображений изложим более содержательные - так называемый **метод Шеффе (Н. Sheffe)**. Зададимся некоторым набором векторов $C \subset \mathbb{R}^p$,

не содержащим нулевой вектор, и будем строить доверительные множества для a с помощью набора $\{c^T a | c \in C\}$.

Определение 4.11. Выражения $c^T a, c \in C$ являются линейными формами от аргумента a . Такие формы называются в данном методе **контрастами**. Одновременное построение доверительных интервалов для этих контрастов называется **множественным сравнением**. Метод будет основан именно на таком одновременном построении.

Теорема 4.12. (Шеффе, 1952) Введем следующее вспомогательное обозначение: если $\alpha \in (0; 1)$ - заданная доверительная вероятность, то пусть $k^2 := \frac{p(n-1)}{(n-p)n} F_{1-\alpha}(p, n-p)$. Тогда множество

$$A_X := \{a \in \mathbb{R}^p | -k\sqrt{c^T S c} + c^T \bar{X} < c^T a < k\sqrt{c^T S c} + c^T \bar{X} \forall c \in C\}$$

есть доверительное множество для a с доверительной вероятностью $1 - \alpha$.

□ Необходимо доказать, что при любом $\theta \in \Theta$ (где $\Theta = \{(a, Q) | a \in \mathbb{R}^p, Q > 0\}$)

$$\mathbf{P}_\theta\{X \in \mathbb{R}^{pn} | a \in A_X\} > 1 - \alpha.$$

Для этого достаточно показать, что

$$\{X \in \mathbb{R}^{pn} | a \in E_X\} \subset \{X \in \mathbb{R}^{pn} | a \in A_X\},$$

или что $E_X \subset A_X$ при любом $X \in \mathbb{R}^{pn}$. Но

$$A_X = \bigcap_{c \in C} \{a \in \mathbb{R}^p | -k\sqrt{c^T S c} + c^T \bar{X} < c^T a < k\sqrt{c^T S c} + c^T \bar{X}\}.$$

Значит, будет достаточно показать, что

$$E_X \subset \{a \in \mathbb{R}^p | -k\sqrt{c^T S c} + c^T \bar{X} < c^T a < k\sqrt{c^T S c} + c^T \bar{X}\}$$

при всех $X \in \mathbb{R}^{pn}$, $c \in C$. Этот последний факт следует из того, что (мы фиксировали $X \in \mathbb{R}^{pn}$, $c \in C$) для $E_X(a - \bar{X})^T S^{-1}(\bar{X}) \leq k^2$, а

$$\max_{(a-\bar{X})^T S^{-1}(\bar{X}) \leq k^2} c^T(a-\bar{X}) = \max_{(a-\bar{X})^T S^{-1}(\bar{X})=k^2} c^T(a-\bar{X}) = k \max_{(a-\bar{X})^T S^{-1}(\bar{X})=1} c^T(a-\bar{X}) = k\sqrt{c^T S c}.$$

Последнее равенство следует из леммы 3.2 главы 3. (Обосновать другие два равенства в этой цепочке!) Этим все и доказано. ■

Мы можем рассмотреть частный случай конструкции Шеффе: $C = \{c_k | k = \overline{1, m}\}$ - конечное множество. Тогда доверительный эллипсоид E_X вкладывается в множество A_X , которое представляет из себя область в пространстве \mathbb{R}^p , ограниченную m парами параллельных гиперплоскостей, касательных к границе - поверхности эллипсоида E_X . Т.е. эта область - многогранник. (Проведите это рассуждение подробнее!)

3. Проверка приближенной гипотезы.

Статистические гипотезы часто высказывают как точные утверждения о параметре θ из базовой модели статистики - статистического пространства, или, иными словами, о неизвестном параметре (параметрах) распределения наблюдений. Очевидный пример - гипотеза $H : a = a_0$, которой была посвящена глава 3. Но в данном случае при неограниченном увеличении размера выборки возникает неприятная ситуация: рано или поздно мы отвергнем любую наперед заданную гипотезу $H : a = a_0$, кроме той, которая является действительно истинной - т.е. той, где a_0 - истинное значение параметра a распределения.

Однако как можно, предлагая вектора a_0 для гипотез $a = a_0$, угадать действительно истинное значение этого параметра? Совершенно невероятно, чтобы нам удалось так точно угадать - но только тогда мы не попадем в описанную выше ловушку. Как же быть?

Заметим, что мы отвергаем гипотезу о точном равенстве вовсе не тогда, когда истинное значение параметра a не равно точно объявленному. (Иначе, по-видимому, пришлось бы практически всегда отвергать такие гипотезы.) Мы отвергаем гипотезу, если видим: расхождение между объявленным значением параметра и тем, которое, по-видимому, истинно, настолько велико, что мы не можем пренебречь этой разницей. И это надо иметь в виду при формулировании и проверке таких гипотез. Однако содержащееся в них утверждение - это все-таки именно равенство. Сейчас же мы рассмотрим гипотезы, изначально в своей формулировке содержащие неравенства, касающиеся неизвестного параметра a . Эти неравенства будут как раз строго выражать мысль о том, что истинное значение a близко к a_0 - тому значению, которое называли мы.

Сперва рассмотрим одномерный случай. Пусть $X = (X_1, \dots, X_n)$ - выборка из $\mathcal{N}(a, \sigma^2)$. Тогда из классической математической статистики нам известно следующее:

Утверждение 4.13. Вероятность того, что

$$\left| \sqrt{n} \frac{\bar{X} - a}{s} \right| < t_\varepsilon,$$

равна $1 - 2\varepsilon$ при любых значениях параметров распределения a, σ . Здесь $\varepsilon \in (0; 1/2)$, $s := \frac{1}{n-1} \sum_{k=1}^n (X_k - \bar{X})^2$ - эмпирическая дисперсия (несмещенная оценка для σ^2), а $t_{1-2\varepsilon}$ - квантиль распределения Стьюдента с $n - 1$ степенями свободы, соответствующий уровню $1 - 2\varepsilon$.

Перефразируем этот факт так: если a_0 - объявленное значение параметра a распределения $\mathcal{N}(a, \sigma^2)$, то мы отвергаем на уровне 2ε эту гипотезу тогда и только тогда, когда Так мы выразили мысль

В многомерном случае мысль о малости $a - a_0$, где a_0 - объявленное, а a - истинное значение параметра, можно выразить с помощью метода Роя сведения многомерных задач к одномерным. Другими словами, мы считаем, что $a - a_0$ мало тогда и только тогда, когда $u^T a - u^T a_0$ мало при всех $u \in \mathbb{R}^p, u \neq 0$. Но мы же располагаем способом формально объяснить, что значит, что $u^T a - u^T a_0$ мало для фиксированного $u \in \mathbb{R}^p, u \neq 0$. А именно, пусть (X_1, \dots, X_n) - наша исходная выборка из $\mathcal{N}_p(a, Q)$ ($a \in \mathbb{R}^p, Q > 0$ - матрица размера $p \times p$ - неизвестные параметры распределения. Тогда $(u^T X_1, \dots, u^T X_n)$ есть выборка из уже одномерного гауссовского распределения $\mathcal{N}(u^T a, u^T Q u)$. Выборочная дисперсия s для данной выборки равна (подсчитайте это!) $u^T S u$. Значит, $u^T a - u^T a_0$ мало, если

$$\left| \sqrt{n} \frac{u^T a - u^T a_0}{u^T S u} \right| < \delta. \quad (4.5)$$

(Здесь $\delta > 0$ - некоторое число; мы можем его выбирать, вообще говоря, произвольно.) Но нам необходимо, чтобы $u^T a - u^T a_0$ было мало не при каком-то отдельном u , а при всех $u \in \mathbb{R}^p, u \neq 0$. Это можно формализовать таким образом: неравенство (4.5) выполнено при всех $u \in \mathbb{R}^p, u \neq 0$. Иначе говоря,

$$\max_{u \in \mathbb{R}^p, u \neq 0} \left| \sqrt{n} \frac{u^T a - u^T a_0}{u^T S u} \right| < \delta. \quad (4.6)$$

По лемме 3.2 из главы 3 (проведите подробнее в этом месте рассуждение!) это выполнено тогда и только тогда, когда

$$(a - a_0)^T S^{-1} (a - a_0) < \delta^2.$$

Это можно сформулировать так: параметр нецентральности статистики Хотеллинга $T^2 := n(\bar{X} - a_0)^T S^{-1}(\bar{X} - a_0)$ не превосходит $n\delta^2$. Поэтому станем отвергать гипотезу (4.6) при больших значениях T^2 . Критическое значение уровня α - обозначим его $t(\alpha)$ - определим как решение относительно t экстремальной задачи

$$\max_{\Delta \leq n\delta^2} \mathbf{P} \left\{ \frac{(n-1)p}{n-p} F(p, n-p, \Delta) \leq t \right\} = 1 - \alpha.$$

Эта задача равносильна уравнению

$$\mathbf{P} \left\{ \frac{(n-1)p}{n-p} F(p, n-p, n\delta^2) \leq t \right\} = 1 - \alpha,$$

т.к. распределения Фишера $F(\nu_1, \nu_2, \Delta)$ стохастически возрастают при возрастании Δ .

Глава 7. Проверка независимости.

Пусть $(X_k, Y_k)^T, k = \overline{1, n}$ - выборка из распределения $\mathcal{N}_2((a, b)^T, \Sigma)$, где матрица ковариаций Σ - квадратная матрица порядка 2 - имеет вид $\begin{pmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{pmatrix}$, здесь $\sigma_x^2 = \text{Var } X, \sigma_y^2 = \text{Var } Y, \rho = \text{corr}(X, Y)$ для $(X, Y)^T \sim \mathcal{N}_2((a, b)^T, \Sigma)$. Построим правило для проверки гипотезы $\rho = 0$, т.е. гипотезы о том, что X, Y некоррелированы (или, что то же самое, независимы - это равносильные предположения, т.к. X, Y имеют совместное гауссовское распределение, см. §4 главы 1).

Приложение.

Доказательство теоремы о замене переменных в интеграле Лебега по множествам в евклидовом n -мерном пространстве.

Пусть $D, G \subset \mathbb{R}^n$ - открытые множества, $\alpha : D \rightarrow G$ - биекция, причем $\alpha \in C^1(D)$, $\alpha^{-1} \in C^1(G)$, и при этом $J(t)$ - якобиан функции α в точке $t \in D$ - отличен от нуля во всех точках $t \in D$. Пусть, далее, $f : G \rightarrow \mathbb{R}$ - борелевская функция, $A \in \mathfrak{B}(D)$ - некоторое подмножество, $\alpha(A)$ - его образ при отображении α .

Тогда $f \in L_1(\alpha(A))$, если и только если $f(\alpha(t))|J(t)| \in L_1(A)$. Если имеет место интегрируемость, то

$$\int_A f(\alpha(t))|J(t)|dt = \int_{\alpha(A)} f(x)dx. \quad (1.3)$$

Доказательство. Шаг 1. Сначала заметим, что мы можем перейти от множеств $A, \alpha(A)$ к множествам D, G : $f \in L_1(\alpha(A))$ тогда и только тогда, когда $I_{\alpha(A)} \in L_1(G)$, и в случае интегрируемости

$$\int_{\alpha(A)} f(x)dx = \int_G f(x)I_{\alpha(A)}(x)dx.$$

Аналогично, $f(\alpha(t))|J(t)| \in L_1(A)$ тогда и только тогда, когда $f(\alpha(t))|J(t)|I_A(t) \in L_1(D)$, и в случае интегрируемости

$$\int_A f(\alpha(t))|J(t)|dt = \int_D f(\alpha(t))|J(t)|I_A(t)dt.$$

Т.е. достаточно доказать следующий **факт** для функции $g(x) = f(x)I_{\alpha(A)}(x)$: $g(x) \in L_1(G)$ тогда и только тогда, когда $g(\alpha t)|J(t)| \in L_1(D)$, и в случае интегрируемости

$$\int_G g(x)dx = \int_D g(\alpha t)|J(t)|dt.$$

Шаг 2. Пусть сначала $g = I_B$, $B = \prod_{k=1}^n [a_k, b_k)$, где при $k = \overline{1, n}$ $[a_k, b_k)$ - ограниченный полуинтервал на действительной прямой (будем называть такие множества B n -мерными брусками), и при этом $\overline{B} = \prod_{k=1}^n [a_k, b_k] \subset G$ (т.е., как говорят, B компактно содержится в G). Тогда доказываемое утверждение верно. Действительно, сформулируем **теорему о замене переменных в кратном интеграле Римана**:

Пусть $\alpha : V \rightarrow W$ - биекция ограниченных замкнутых кубируемых областей $V, W \subset \mathbb{R}^n$ (напомним, что замкнутая область - это замыкание области в обычном смысле этого слова, т.е. открытого связного множества), причем $\psi \in C^1(V)$, $\psi^{-1} \in C^1(W)$, $J(t)$ - якобиан функции ψ в точке $t \in V$ - отличен от нуля во всех точках $t \in V$. Пусть, далее, функция $h : W \rightarrow \mathbb{R}$ интегрируема по Риману на W . Тогда функция $h(\psi(t))|J(t)|$ интегрируема по Риману на V и их интегралы равны.

(Доказательство - см. [3], том 2, гл. 2, §5.)

Применим эту теорему к $V = \alpha^{-1}(\overline{B}), W = \overline{B}, \psi = \alpha, h = 1$. Заметим, что \overline{B} - замкнутая ограниченная кубируемая область в \mathbb{R}^n . Кроме того, $\alpha^{-1}(\overline{B})$ - также ограниченная замкнутая кубируемая область в \mathbb{R}^n . (См. [3], том 2, гл. 2, § 5.) Т.к. функция h , тождественно равная единице, интегрируема по Риману на W (а кроме того, и по Лебегу - ведь она измерима, ограничена, а множество W - борелевское и

имеет конечную меру Лебега), то по этой теореме функция $h(\alpha(t))|J(t)|$ интегрируема по Риману на V (а кроме того, и по Лебегу - ведь она измерима, ограничена, а множество V - борелевское и имеет конечную меру Лебега) и верно равенство

$$\int_{\overline{B}} h(x)dx = \int_{\alpha^{-1}(\overline{B})} h(\alpha(t))|J(t)|dt,$$

или, вспоминая то, что $h = 1$ на W ,

$$\int_{\overline{B}} dx = \int_{\alpha^{-1}(\overline{B})} |J(t)|dt.$$

Далее, т.к. $\overline{B} \setminus B \subset \partial B$ и $\mu(\overline{B} \setminus B) \leq \mu(\partial B)$, а n -мерный брус B кубируем, т.е. $\mu(\partial B) = 0$, то $\mu(\overline{B} \setminus B) = 0$. Кроме того, $\alpha^{-1}(\overline{B}) \setminus \alpha^{-1}(B) = \alpha^{-1}(\overline{B} \setminus B)$, а $\mu(\overline{B} \setminus B) = 0$. Значит, $\mu(\alpha^{-1}(\overline{B}) \setminus \alpha^{-1}(B)) = \mu(\alpha^{-1}(\overline{B} \setminus B)) = 0$. (Обоснование того факта, что непрерывно дифференцируемое отображение α^{-1} переводит множество меры нуль в множество меры нуль, см. в книге [3], том 2, гл. 2, § 5, лемма 5.) Отсюда следует, что $h \in L_1(B)$, $h(\alpha(t))|J(t)| \in L_1(\alpha^{-1}(B))$ и при этом

$$\int_B dx = \int_{\alpha^{-1}(B)} |J(t)|dt.$$

Т.е. $g = I_B$ интегрируема по Лебегу на G , $g(\alpha(t))|J(t)| = I_{\alpha^{-1}(B)}|J(t)|$ интегрируема по Лебегу на D , и последнее равенство дает нам равенство (1.4) для функции $g = I_B$. Т.е. доказываемое утверждение верно для $g = I_B$.

Шаг 3. Если $W \in \mathfrak{B}(G)$, то пусть $\mathcal{A}(W)$ - множество, состоящее из всех конечных объединений n -мерных брусков, лежащих в W , а также пустого множества. Заметим, что множество n -мерных брусков, лежащих в W - полукольцо, а конечные объединения таких брусков образуют минимальное кольцо, содержащее это полукольцо; такое минимальное кольцо и есть $\mathcal{A}(W)$. Если же $W = U$ - n -мерный брус, то это минимальное кольцо является алгеброй подмножеств U , ведь само U лежит в $\mathcal{A}(W)$. Можно определить $\mathcal{A}(W)$ как совокупность всевозможных конечных объединений непересекающихся n -мерных брусков, лежащих в W . (См. книгу [4], гл. 5, задачи 5.10, 5.21, 5.22, 5.31.)

В силу линейности интеграла Лебега доказываемое утверждение верно и для функций $g = I_C$, $C \in \mathcal{A}(U)$, т.е. для функций вида $g = \sum_{j=1}^k I_{B_j}$, где $B_j, j = \overline{1, k}$ - непересекающиеся n -мерные брусы, лежащие в U .

Заметим также, что $\mathfrak{B}(U) = \sigma(\mathcal{A}(U))$. (Это будет использовано в дальнейшем доказательстве.) Напомним **теорему об аппроксимации**:

если \mathcal{A} - алгебра подмножеств $\Omega \neq \emptyset$, $\sigma(\mathcal{A})$ - σ -алгебра, порожденная ей, P -вероятностная мера на $\sigma(\mathcal{A})$, то

$$\forall \varepsilon > 0 \forall A \in \sigma(\mathcal{A}) \exists B \in \mathcal{A} : P(A \Delta B) < \varepsilon.$$

Применим эту теорему для доказательства промежуточного предложения:

Предложение. Если $E \in \mathfrak{B}(G)$, $\mu E < \infty$, то при всех $\varepsilon > 0$ найдется $C \in \mathcal{A}(G)$, для которого $\mu(C \Delta E) < \varepsilon$.

Доказательство предложения.

Представляем G как $\bigcup_{m=1}^{\infty} U_m$, где для всех $m \in \mathbb{N}$ U_m - n - мерный брус, компактно содержащийся в G . Подробнее: пусть для $x \in G$ $\varepsilon(x) > 0$ таково, что $B_{2\sqrt{n}\varepsilon(x)}(x) \subset G$ - мы используем то, что G открыто, т.е. точка $x \in G$ - внутренняя. $\{B_{\varepsilon(x)}(x)\}_{x \in G}$ - открытое покрытие G ; т.к. G сепарабельно как метрическое пространство - ведь

G - подпространство метрического пространства \mathbb{R}^n - то из этого покрытия можно выделить счетное подпокрытие $\{B_{\varepsilon_j}(x_j)\}_j$, где $\varepsilon_j = \varepsilon(x_j)$. Пусть, далее, $B_j = \prod_{i=1}^n [x_{ji} - \varepsilon_j, x_{ji} + \varepsilon_j]$ - n -мерный брус, где $x_j := (x_{j1}, \dots, x_{jn})$. Он компактно содержится в $B_{2\sqrt{n}\varepsilon_j}(x_j)$, а, значит, и в G . Но $B_{\varepsilon_j}(x_j) \subset B_j$, т.е. $G \subset \bigcup_j B_j$ и, таким образом, $\{B_j\}_j$ - не более чем счетное покрытие G .

и рассматриваем $\mathcal{A} = \mathcal{A}(U_m)$, $\sigma(\mathcal{A}) = \sigma(\mathcal{A}(U_m)) = \mathfrak{B}(U_m)$ и вероятностную меру на $\sigma(\mathcal{A})$, равную $P = P_m$, где $P_m(A) = \mu(A)/\mu(U_m)$. Пусть $\varepsilon > 0$. Разберем случаи:

1) Полученное покрытие счетно. Тогда $\bigcap_{m=1}^{\infty} (E \setminus U_m) = E \setminus \left(\bigcup_{m=1}^{\infty} U_m \right) = E \setminus G = \emptyset$, откуда в силу непрерывности меры μ и того, что $\mu E < \infty$, следует, что $\exists M \in \mathbb{N}$: $\mu\left(\bigcap_{m=M+1}^{\infty} (E \setminus U_m)\right) < \varepsilon/2$. Полагая $V := \bigcup_{m=1}^M U_m$, имеем:

$$\mu E - \mu(E \setminus V) = \mu(E \setminus (E \setminus V)) = \mu(E \cap V) = \mu\left(\bigcap_{m=M+1}^{\infty} (E \setminus U_m)\right) < \frac{\varepsilon}{2}.$$

Но при всех $m \in \mathbb{N}$ $E \cap U_m \in \mathfrak{B}(U_m)$ и по теореме об аппроксимации $\exists C_m \in \mathcal{A}(U_m)$:

$$P_m((E \cap U_m) \Delta C_m) < \frac{\varepsilon}{2^{m+1} \mu(U_m)}.$$

Отсюда $\mu((E \cap U_m) \Delta C_m) < \varepsilon/2^{m+1}$. Отметим теоретико - множественный факт: если $X_m, Y_m, m = \overline{1, N}$ - множества (произвольные), то

$$\left(\bigcup_{m=1}^N X_m\right) \Delta \left(\bigcup_{m=1}^N Y_m\right) \subset \bigcup_{m=1}^N (X_m \Delta Y_m).$$

(См. упражнение 1.9.) Значит, имеем:

$$\begin{aligned} \mu\left(\bigcup_{m=1}^M (E \cap U_m) \Delta \left(\bigcup_{m=1}^M C_m\right)\right) &\leq \mu\left(\bigcup_{m=1}^M ((E \cap U_m) \Delta C_m)\right) \leq \\ &\leq \sum_{m=1}^M \mu((E \cap U_m) \Delta C_m) < \sum_{m=1}^M \frac{\varepsilon}{2^{m+1}} < \frac{\varepsilon}{2}. \end{aligned}$$

Т.к.

$$\bigcup_{m=1}^M (E \cap U_m) = E \cap \left(\bigcup_{m=1}^M U_m\right) = E \cap V,$$

то для $C_0 := \bigcup_{m=1}^M C_m$ $\mu((E \cap V) \Delta C_0) < \varepsilon/2$. Заметим, что $E \Delta C_0 \subset ((E \cap V) \Delta C_0) \cup (E \setminus V)$, откуда мы получаем, что $\mu(E \Delta C_0) \subset \mu((E \cap V) \Delta C_0) + \mu(E \setminus V) < \varepsilon/2 + \varepsilon/2 = \varepsilon$.

Осталось лишь заметить, что $C_0 = \bigcup_{m=1}^M C_m \in \mathcal{A}(G)$, $C_m \in \mathcal{A}(U_m) \subset \mathcal{A}(G)$.

2) Полученное покрытие конечно. Этот случай разбирается совершенно аналогично, но он проще первого.

Тем самым предложение доказано. ■

Шаг 4. Если $E \in \mathfrak{B}(G)$, $\mu E < \infty$, то, используя только что доказанное предложение, подберем $C^{(m)} \in \mathcal{A}(G)$, для которых при $m \in \mathbb{N}$ $\mu(E \Delta C^{(m)}) < 1/2^m$. Тогда

$$\mu\left(E \Delta \left(\bigcap_{m=1}^{\infty} C^{(m)}\right)\right) = \mu\left(\bigcap_{m=1}^{\infty} (E \Delta C^{(m)})\right) = 0,$$

а при $x \in E, x \in \bigcap_{m=1}^{\infty} C^{(m)}$ $I_{C^{(m)}}(x) = 1 = I_E(x)$ для всех $m \in \mathbb{N}$; при $x \notin E, x \notin \bigcap_{m=1}^{\infty} C^{(m)}$ $I_{C^{(m)}}(x) = 0 = I_E(x)$ для всех $m \in \mathbb{N}$. Мы заключаем, что $\lim_{m \rightarrow \infty} I_{C^{(m)}} = I_E$ почти всюду. Кроме того,

$$\bigcup_{m=1}^{\infty} C^{(m)} = \left(\bigcup_{m=1}^{\infty} (C^{(m)} \setminus E) \right) \cup E \subset \left(\bigcup_{m=1}^{\infty} (C^{(m)} \Delta E) \right) \cup E,$$

т.е.

$$\mu\left(\bigcup_{m=1}^{\infty} C^{(m)}\right) \leq \sum_{m=1}^{\infty} \mu(C^{(m)} \Delta E) + \mu E < \sum_{m=1}^{\infty} \frac{1}{2^m} + \mu E = 1 + \mu E.$$

Значит, $I_H \in \mathcal{L}_1(G)$, где $H := \bigcup_{m=1}^{\infty} C^{(m)}$. Но $0 \leq I_{C^{(m)}} \leq I_H$ для всех $m \in \mathbb{N}$.

Применяя теорему Лебега о мажорируемой сходимости, имеем: доказываемый факт верен и для функций $g = I_E, E \in \mathfrak{B}(G), \mu E < \infty$.

Отсюда получаем, в силу линейности интеграла Лебега, что доказываемое утверждение верно и для простой g , т.е. являющейся конечной линейной комбинацией индикаторов $I_E, E \in \mathfrak{B}(G), \mu E < \infty$. Но любую неотрицательную борелевскую функцию $g : G \rightarrow \mathbb{R}$ можно представить в виде предела п.в. монотонной последовательности простых функций. Применяя теорему Б.Леви о монотонной сходимости, доказываем данный факт и для неотрицательных борелевских функций $g : G \rightarrow \mathbb{R}$.

А любую борелевскую функцию $g : G \rightarrow \mathbb{R}$ произвольного знака можно представить в виде разности $g_+ - g_-$, $g_+ = \max(g, 0), g_- = \max(-g, 0)$ - неотрицательные борелевские функции. Таким образом, утверждение полностью доказано. См. также упражнение 1.10. ■

Приложение 2. Напоминание некоторых основных понятий математической статистики.

Мы предполагаем, что наш читатель знаком с классической математической статистикой - такое знакомство существенно необходимо для чтения главы 2 и последующих. Тем не менее, напомним хотя бы частично фундаментальные понятия этой науки. Надеемся, что нижеприведенные материалы облегчат понимание как математической статистики вообще, так и многомерного гауссовского анализа в частности.

Определение А2.1. Базовой моделью математической статистики является **статистическое пространство**. Это - тройка $(\mathcal{X}, \mathfrak{F}, \mathcal{P})$, где $\mathcal{X} \neq \emptyset$ - какое-то множество, называемое **пространством наблюдений** (а его элементы $X \in \mathcal{X}$, разумеется, называются **наблюдениями**); \mathfrak{F} - σ -алгебра на этом множестве \mathcal{X} , т.е. $(\mathcal{X}, \mathfrak{F})$ - измеримое пространство; а \mathcal{P} - некоторое непустое множество (разумеется, не обязательно всевозможных) вероятностных мер, заданных на \mathfrak{F} . Мы считаем, что какая-то (только одна) из этих мер истинна, т.е. реально, в действительности задана на \mathfrak{F} , но нам неизвестно, какова же именно эта мера. (Однако заведомо известно, что она лежит в этом семействе \mathcal{P} .)

Основная задача математической статистики - по наблюдению $X \in \mathcal{X}$ сделать выводы о том, какова же истинная вероятностная мера $\mathbf{P} \in \mathcal{P}$. Что это значит - "сделать выводы"? Точно мы, по-видимому, не сможем указать эту искомую меру \mathbf{P} . (Почти во всех статистических моделях это на самом деле невозможно.) Но можно попытаться разрешить эту задачу приближенно. Значит, нужно формализовать это понятие - "приближенно". И оказывается, что это можно сделать по-разному - мы увидим это ниже.

Можно сказать так: статистика занимается вопросами, в известном смысле противоположными вопросам теории вероятностей. Ведь последняя по заданной вероятностной мере \mathbf{P} на измеримом пространстве (Ω, \mathfrak{F}) делает выводы о вероятностях событий, связанных с какими-то случайными величинами, векторами и т.д. - иногда более простых, а иногда довольно сложных, как, например, в законе больших чисел или центральной предельной теореме. А статистика занимается тем, что по данной величине (наблюдению) $X \in \mathcal{X}$ пытается сколько-нибудь точно восстановить вероятностную меру $\mathbf{P} \in \mathcal{P}$ на $(\mathcal{X}, \mathfrak{F})$.

Часто множество \mathcal{P} параметризовано, т.е. $\mathcal{P} = \{\mathbf{P}_\theta | \theta \in \Theta\}$, где $\Theta \neq \emptyset$ - некоторое множество индексов, причем $\mathbf{P}_\theta \neq \mathbf{P}_{\theta'}$ при любых $\theta, \theta' \in \Theta$, $\theta \neq \theta'$. (Проще говоря, каждой мере $\mathbf{P} \in \mathcal{P}$ взаимно-однозначно сопоставляется индекс $\theta \in \Theta$.) Разумеется, тогда существует какое-то неизвестное нам истинное значение индекса $\theta \in \Theta$ (только одно). И тогда сделать вывод об истинной вероятностной мере \mathbf{P} - равносильно тому, чтобы сделать вывод об истинном значении индекса $\theta \in \Theta$. Вы уже знаете, что это можно сделать разными способами, а именно тремя:

- построить точечную оценку;
- построить доверительное множество;
- проверить гипотезу.

В этой главе мы остановимся на точечных оценках для конкретного случая этой общей модели - для параметров многомерного нормального распределения; а позже, в следующих главах, пойдет речь о двух других способах.

Проиллюстрируем абстрактное понятие статистического пространства на конкретном примере, который, кстати, для нас еще очень пригодится. Пусть мы делаем n последовательных независимых наблюдений X_1, \dots, X_n , и нам заведомо известно, что для $k = \overline{1, n}$ $X_k \sim \mathcal{N}(l_k, \sigma^2)$. При этом мы не знаем ни параметров $l_k, k = \overline{1, n}$ (будем также записывать их в виде вектора - столбца $l = (l_1, \dots, l_n)^T$), ни среднеквадратического отклонения σ . Правда, считается известным, что $\sigma > 0$. Ставится

естественная задача: сделать выводы об этих неизвестных параметрах l и σ . Но как это формализовать - как построить статистическое пространство для такой ситуации?

Можно сделать это специальным приемом, используемым в теории вероятностей, а именно: непосредственно задать случайный вектор $X = (X_1, \dots, X_n)^T$. Что это означает?

Определение A2.2. Пусть дана функция $\xi : \Omega \rightarrow S$, заданная на измеримом пространстве (Ω, \mathcal{F}) со значениями в измеримом пространстве (S, \mathcal{B}) , являющаяся \mathcal{B}/\mathcal{F} -измеримой, т.е. при $B \in \mathcal{B}$ $\xi^{-1}(B) \in \mathcal{F}$. Она называется **непосредственно заданной**, если $\Omega = S, \mathcal{F} = \mathcal{B}$ и ξ - тождественное отображение, т.е. при $\omega \in \Omega$ $\xi(\omega) = \omega$.

Такие функции иногда удобны в теоретических доказательствах существования. Например, если вы изучали доказательство теоремы Колмогорова о существовании случайного процесса, то знаете: там искомый процесс строится именно как непосредственно заданный. И здесь мы построим случайный вектор X как непосредственно заданный - правда, ситуация у нас несравненно проще, чем в теореме Колмогорова. А именно: пусть $\mathfrak{X} := \mathbb{R}^n, \mathfrak{F} := \mathfrak{B}(\mathbb{R}^n)$ - борелевская σ -алгебра на \mathbb{R}^n . Пусть, далее, $\Theta := \{(l, \sigma) | l \in \mathbb{R}^n, \sigma > 0\}$ и для $\theta = (l, \sigma) \in \Theta$ имеем:

$$\mathbf{P}_\theta = \mathcal{N}(l_1, \sigma^2) \otimes \mathcal{N}(l_2, \sigma^2) \otimes \dots \otimes \mathcal{N}(l_n, \sigma^2). \quad (\text{A2.1})$$

(Знак \otimes обозначает прямое произведение мер; это понятие считается известным, см., впрочем, [2], гл. 2, §6 или [4], гл. 12, или любое руководство по теории меры и интеграла.)

И наконец, пусть $X : \Omega \rightarrow \mathbb{R}^n$ - непосредственно заданный случайный вектор, а проще говоря - тождественное отображение $\mathbb{R}^n \rightarrow \mathbb{R}^n$, и пусть при $k = \overline{1, n}$ X_k - его k -я компонента, т.е. функция $\Omega \rightarrow \mathbb{R}$, заданная так: для $x = (x_1, \dots, x_n)^T \in \mathbb{R}^n$ $X_k(x) := x_k$. Тогда $X_k, k = \overline{1, n}$ - независимые случайные величины, причем если $\theta = (l, \sigma)$ - истинное значение индекса, $l = (l_1, \dots, l_n)^T$, то $X_k \sim \mathcal{N}(l_k, \sigma^2)$. (Обосновать это, исходя из того, что \mathbf{P}_θ - это прямое произведение одномерных мер!) Так мы построили статистическое пространство, реализующее возникшую ситуацию независимых случайных величин X_1, \dots, X_n , распределенных следующим образом: $X_k \sim \mathcal{N}(l_k, \sigma^2)$.

Случайный вектор X имеет распределение $\mathcal{N}_n(l, \sigma^2 I_n)$ (проверьте это сами!) Такой вектор есть основная составляющая линейной гауссовской модели - классической главы математической статистики.

Если в предыдущей ситуации нам заведомо известно, что $l \in L$, где L - некоторое фиксированное линейное подпространство пространства \mathbb{R}^n , а мы хотим сделать выводы о неизвестных параметрах l и σ , уже зная этот факт (т.е. что $l \in L$), то соответствующее статистическое пространство строится так: $\mathfrak{X} := \mathbb{R}^n, \mathfrak{F} := \mathfrak{B}(\mathbb{R}^n), \Theta := \{(l, \sigma) | l \in L, \sigma > 0\}$ и для $\theta := (l, \sigma) \in \Theta$ мера \mathbf{P}_θ определяется так же, как и для предыдущего статистического пространства - т.е. по формуле (A2.1).

Теперь приступим к введению важнейшего понятия статистики - а именно, понятия оценки параметра распределения.

Пусть \mathfrak{T} - некоторое непустое множество, $\tau : \Theta \rightarrow \mathfrak{T}$ - заданная функция. Мы можем говорить, что существует некоторое (единственное) истинное значение этой функции - разумеется, это $\tau(\theta_0)$, где θ_0 - истинное значение параметра θ . Будем делать выводы об этом истинном значении функции.

Определение A2.3. Оценка истинного значения τ - это любая функция $\delta : \mathfrak{X} \rightarrow \mathfrak{T}$, достаточно хорошо приближающая неизвестное истинное значение τ . Часто говорят просто: **оценка** τ . Частный случай этого понятия - оценка τ для $\mathfrak{T} := \Theta$

и для τ - тождественного отображения Θ . Такая функция $\delta : \mathfrak{X} \rightarrow \mathfrak{T}$ называется **оценкой истинного значения** θ . Это, как легко видеть

Для чего служит такое определение? Мы получили наблюдение $X \in \mathfrak{X}$ и хотели бы по нему восстановить истинное значение τ - пусть не точно, хотя бы приближенно. Это можно сделать, если мы располагаем оценкой τ .

Но последнее определение, естественно, не может считаться математически строгим. Что означают слова "достаточно хорошо приближающая"? Необходимо как-то математически формализовать это.

Определение A2.4. Пусть $\mathfrak{X} \subset \mathbb{R}^n$ - борелевское подмножество \mathbb{R}^n , $\mathfrak{F} = \mathfrak{B}(\mathfrak{X})$ - σ -алгебра всех борелевских подмножеств \mathfrak{X} и при всех $\theta \in \Theta$ \mathbf{P}_θ - вероятностная мера, абсолютно непрерывная относительно классической меры Лебега на $\mathfrak{B}(\mathfrak{X})$, т.е. имеющая плотность (или, более точно, производную Радона - Никодима относительно этой меры Лебега) $f_\theta : \mathfrak{X} \rightarrow \mathbb{R}^n$. (Эти понятия - абсолютная непрерывность, производная Радона - Никодима - считаются известными из курса действительного анализа.) Вместо $f_\theta(x)$ будем писать так: $f(x, \theta)$. Тогда при фиксированном $X \in \mathfrak{X}$ функция $\Theta \rightarrow \mathbb{R}^n$, $\theta \mapsto f(X, \theta)$ называется **правдоподобием**.

Определение A2.5. Если при любом $X \in \mathfrak{X}$ правдоподобие, соответствующее этому X , имеет строгий глобальный максимум - или, более формально, найдется такое значение $\theta_X \in \Theta$, что при всех $\theta \in \Theta$ $f(X, \theta) \leq f(X, \theta_X)$, причем равенство достигается только при $\theta = \theta_X$, то функция $\delta : \mathfrak{X} \rightarrow \Theta$, сопоставляющая наблюдению $X \in \mathfrak{X}$ значение θ_X , называется **оценкой наибольшего правдоподобия** (или **оценкой максимального правдоподобия**).

Почему же так определенная функция $\delta : \mathfrak{X} \rightarrow \Theta$ действительно является оценкой, т.е. почему оправдано название "оценка наибольшего правдоподобия"? По нестрогому определению A2.3, оценка должна хорошо