

# ПАРАМЕТРИЧЕСКАЯ ИДЕНТИФИКАЦИЯ

ФН-12. Магистры - 3 семестр

## Лекция 1. (1-2.) ИДЕНТИФИКАЦИЯ МАТЕМАТИЧЕСКИХ МОДЕЛЕЙ. ВВЕДЕНИЕ. ЭЛЕМЕНТЫ ТЕОРИИ ВЕРОЯТНОСТИ И МАТЕМАТИЧЕСКОЙ СТАТИСТИКИ

# 1.1. Задачи и методы идентификации математических моделей.

Литература.

1. Гроп Д. Методы идентификации систем. - М.: Мир, 1979. -302 с.
2. Льюнг Л. Идентификация систем. Теория для пользователя. - М.: Наука, 1991. - 432 с.
3. Закс Ш. Теория статистических выводов - М.: Мир, 1975. -570 с.
4. Дилигенская А.Н. Идентификация объектов управления (учебное пособие). ГОУВПО "Самарский государственный технический университет".
5. Бар-Шалом Я., Ли Х-Р,(перевод Дмитриев Д. Д.). Траекторная обработка. Принципы, способы и алгоритмы. МГТУ, 2011.
6. Зарубин В.С. Математическое моделирование в технике. - М.: МГТУ им. Н.Э. Баумана, 2003.
7. Коровин С. К., Фомичев В. В. Наблюдатели состояния для линейных систем с неопределенностью. - М.: "Физматлит", 2007.
8. Isermann R., Münchhof M. Identification of Dynamic Systems. Springer-Verlag, Berlin. 2011.
9. Волков И.К., Зуев С.М., Цветкова Г.М. Случайные процессы. - М.: МГТУ им. Н.Э. Баумана, 2003.
10. Горяинов В.Б., Павлов И.В., Цветкова Г.М., Тескин О.И. Математическая статистика- М.: МГТУ им. Н.Э. Баумана, 2001.

Термин "идентификация" стал широко применяться в качестве одного из базовых терминов теории управления в шестидесятых годах XX века (identifico - отождествляю, распознаю).

Модель объекта управления — информация о наиболее существенных характеристиках ОУ. ■

### **Модели объектов управления:**

- физические или математические;
- статические или динамические;
- одномерные или многомерные;
- линейные или нелинейные;
- детерминированные или стохастические;
- непрерывные или дискретные;
- стационарные или нестационарные;
- с сосредоточенными или распределенными параметрами;
- структурированные или агрегированные;
- параметрические или непараметрические;
- т.д. ■

Решение задачи построение модели динамической системы по данным наблюдений за их поведением составляет основной предмет теории идентификации (Льюнг Л.).

**Математическая модель** (образ) представляет собой абстрактное отражение реального объекта (оригинала, прообраза).■

### **Свойства математических моделей.**

**Полнота** ММ позволяет отразить в достаточной мере именно те характеристики и особенности ТО, которые интересуют нас с точки зрения поставленной цели проведения вычислительного эксперимента.

**Точность** ММ дает возможность обеспечить приемлемое совпадение реальных и найденных при помощи ММ значений выходных параметров ТО.

**Адекватность** ММ - это способность ММ описывать выходные параметры ТО с относительной погрешностью не более некоторого заданного значения.

**Экономичность** ММ оценивают затратами на вычислительные ресурсы, необходимые для реализации ММ на ЭВМ.

**Робастность** ММ характеризует ее устойчивость по отношению к погрешностям исходных данных, способность нивелировать эти погрешности.

**Наглядность** ММ является ее желательным, но необязательным свойством.

ММ объектов, рассматриваемых в курсе можно представить в виде

$$y = f(x, a, u),$$

или

$$\begin{cases} \dot{x} = h(x, a, u) \\ y = f(x, a, u), \end{cases}$$

где  $f$  — скалярная или векторная функция векторного аргумента;

$x \in R^n$  — вектор состояния объекта управления;

$a \in R^m$  — внутренние параметры объекта управления;

$y \in R^k$  — выходы объекта управления;

$u \in R^l$  — управление. ■

Построение ММ объекта может производиться несколькими методами: аналитическим, экспериментальным и экспериментально-аналитическим.

## Основные задачи идентификации.

1. Выбор общей структуры модели.
2. Определение оценок **неизвестных параметров модели объекта** на основе информации об управлении и о выходе объекта, и информации о действующих на объект случайных помех.
3. Получении оценки **вектора состояния системы** по данным о входе и выходе при наличии случайных помех. ■

Задача получения оценки полного вектора состояния на основе информации о прилагаемой управлении и выходе системы может решаться с использованием **наблюдателей**.

Параметры моделей системы полагаются известными, вся неизвестная информация о изучаемой системе моделируется с помощью неопределенной помехи, представляемой некоторой неизвестной функцией (например, липщевой или ограниченной).

С точки зрения **теории наблюдателей** можно выделить две задачи

1. **Задача наблюдения** — задача оценки состояния системы в момент времени  $t_0$  по известным входу и выходу системы  $u(t)$  и  $y(t)$  при  $t \geq t_0$ , т.е. задача восстановления начального значения фазового вектора по будущим измерениям входа и выхода. ■

2. **Задача идентификации** — задача оценки состояния системы в момент времени  $t_*$  по данным о входе и выходе при  $t \leq t_*$ , т.е. задача восстановления фазового вектора в текущий момент времени  $t_*$  по измерениям входа и выхода в прошлом.

*Замечание: часто не делают различия между задачами наблюдением и идентификацией, объединяя эти понятия.*

Динамическая система характеризуется своим начальным состоянием и законом, по которому система переходит из начального состояния в другое. В рамках курса под математической моделью ДС будем рассматривать модель представленную системой ОДУ с управлением и выходом вида

$$\begin{aligned}\dot{x} &= f(x, u, t), \\ y &= \varphi(x, u, t),\end{aligned}$$

или разностных уравнений вида

$$\begin{aligned}\Delta x_{k+1} &= f_k(x_k, u_k, t_k), \\ y_{r+1} &= \varphi_k(x_k, u_k, t_k).\end{aligned}$$

Идентификация — это нахождение оптимальной (в смысле выбранных критериев) модели, построенной по результатам наблюдений над входными и выходными переменными объекта.




Рис. 1. Динамическая система

На рисунке  $u$  — контролируемый (управляемый) входной сигнал,  $y$  — выходной (наблюдаемый) сигнал.  $w$  и  $v$  — помехи (возмущения),  $w$  — измеряемая непосредственно помеха (возмущение),  $v$  — неизмеряемая, или измеряемые косвенно, по воздействию, оказанному ими на выходной сигнал. Характер помех может изменяться в широком диапазоне.

Помехи можно разбить на два класса: измеряемые и измеряемые косвенно, по воздействию, оказанному ими на выходной сигнал.

Воздействие помех (как правило) обнаруживается лишь по тому совокупному эффекту, который порождает действие помех в выходном сигнале.

## ”Черный ящик”. ”Серый ящик”. ”Белый ящик”.

Идентификация динамических объектов в общем случае состоит в переходе от ”черного ящика” к ”белому”.

1. Структурная идентификация;
2. Параметрическая идентификация. ■

### ”Черный ящик” (black-box model)

Априорных знаний об объекте мало. Проводилось только экспериментальное моделирование (измерения входных/выходных сигналов).

Есть предположения о структуре модели и/или используются стандартные (линейные) математические модели. Параметры моделей — средства подстройки моделей к экспериментальным данным. ■

### ”Белый ящик”. (white-box model)

Известны теоретические (физические, химические, биологические) законы, на основе которых строится модель, структура и параметры математической модели. ■

### ”Серый ящик” (gray-box model)

Известны физические законы, на основе которых строится модель. Проводилось экспериментальное моделирование (измерения сигналов).

1. Известна структура математической модели, оценки параметров. Часто задается системой ДУ (light-gray-box model).
2. Параметры и структура математической модели неизвестны (dark-gray-box model).

# Общая схема идентификации модели

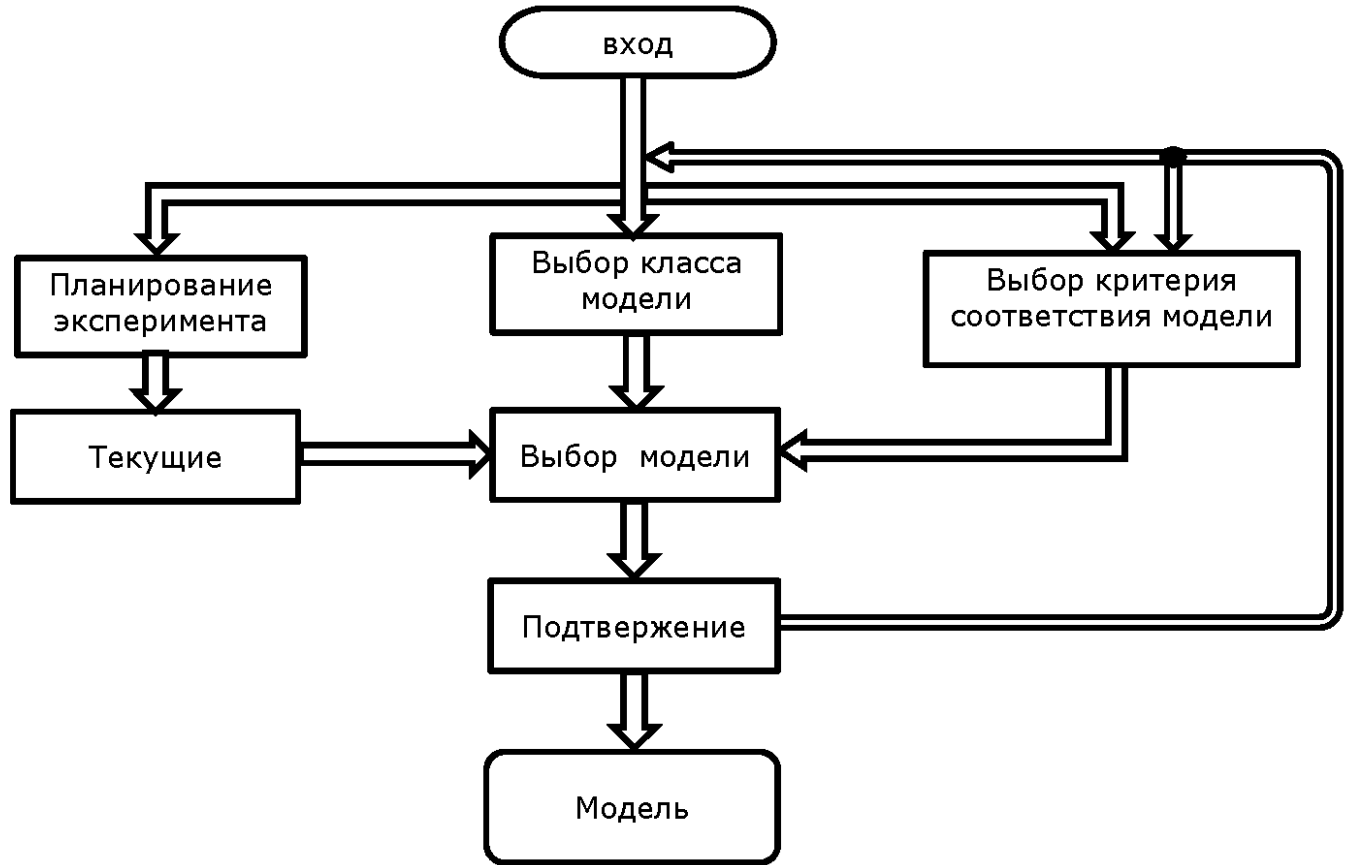


Рис. 2

## Структурная идентификация

Объект управления представляет собой ”черный ящик”. Задачей структурной идентификации является представление реального объекта в виде математической модели.

Необходимо получить описание структуры математической модели (переход от ”черного ящика” к ”серому ящику”).

1. Выбор класса моделей-кандидатов из которых будет выбрана подходящая модель, т.е. выбор общей структуры модели и класс уравнений, которыми предполагается описывать объект.

2. Выбор точек приложения внешних воздействий и сбора информации о реакциях объекта (размещение управляющих устройств и датчиков).

3. Приложение внешних воздействий и анализ реакции объекта на них. ■

Выбор класса ММ зависит от типа объекта. Модели основывающиеся на теории множеств (инфологические, семантические, синтаксические...)

Модели в виде систем дифференциальных или разностных уравнений используются для описания динамических систем.

### Проверка модели

Проверка модели путем сравнения выходных данных модели и соответствующих выходных сигналов объекта. Критерий соответствия модели и объекта выбирается в зависимости от наличия априорной информации об объекте, требуемой точности, выбраного метода идентификации, времени, выделенного на проведение эксперимента и др.

## Параметрическая идентификация

Структура ММ объекта заранее известна, параметры неизвестны, имеются данные экспериментов (данные наблюдений). Переход от ”серого ящика” к ”белому ящику”.

К данным наблюдений обычно относятся входные и выходные сигналы. ■

### Классификация методов идентификации по способу получения данных.

- 1) активная идентификация — в процессе эксперимента, эксперимент спланирован заранее;
- 2) пассивная идентификация — в процессе эксплуатации (невозможно провести эксперимент или влиять на процедуру регистрации (изменения) данных);
- 2) идентификация смешанного типа — в процессе эксплуатации к рабочим управляющим сигналам добавляются тестовые сигналы.

## Активная идентификация

Объект исследования выводится из нормального режима эксплуатации. Исследования проводятся в специализированных лабораторных условиях. На входы объекта подаются тестовые сигналы специального вида. Виды сигналов: ступенчатые, импульсные, гармонические, случайные воздействия с заданными параметрами. ■

Активная идентификация ОУ может производиться во временной области и/или в частотной области.

Активную идентификацию используют при разработке новых технологий применительно к действующим промышленным объектам, в изучении новых явлений, в первоначальной разработке математической модели.

В результате экспериментов получают частотные характеристики системы как ответ на гармонические воздействия (АФЧХ, ЛАЧХ, ЛФЧХ и др.), или переходные (временные) характеристики системы (ступенчатое изменение управления, управление в виде "узкого" импульса и др.)

## **Пассивная идентификация**

Объект функционирует в режиме нормальной эксплуатации.

На его входы поступают рабочие сигналы управления.

Возможна идентификация динамических систем без управления.

Пассивную идентификацию используют для уточнения математической модели, для слежения за изменениями в объекте. Информация оперативно используется в системе управления объектом.

## **Идентификация смешанного типа**

Объект не выводится из нормального режима эксплуатации, к управляющим сигналам добавляются тестовые воздействия.

Условия проведения эксперимента, с учетом всевозможных ограничений, определяются заранее, при планировании эксперимента.

Определяются: диапазон изменения входных сигналов, возможность их изменения, количество опытов, частоту регистрации выходных сигналов необходимых для решения поставленной задачи с требуемой точностью.

## 1.2. Элементы теории вероятности

Теория вероятностей является разделом математики, в котором изучают математические модели **случайных экспериментов**, т.е. экспериментов, исходы которых нельзя определить однозначно условиями проведения опыта. ■

Важнейший принцип ТВ состоит в **статистической устойчивости частот** возможных исходов испытаний. При неограниченном возрастании количества случайных испытаний доля испытаний, приведших к заданному исходу, в ряду всех проведенных испытаний стабилизируется около некоторого предельного числа. ■

При построении вероятностной модели выделяют такой набор исходов данного случайного испытания, который удовлетворяет двум условиям.

1. При проведении случайного испытания должен наступить один из (элементарных) исходов  $\omega$  в выбранном наборе исходов.
2. Все исходы в наборе являются взаимно исключающими, т.е. случайное испытание не должно завершаться одновременно двумя исходами.

## Теоретико-множественная трактовка основных понятий и аксиоматическое построение ТВ

Аксиоматический подход был введен А.Н. Колмогоровым (в 30-х гг.).

$\Omega$  — множество всех возможных исходов испытания. Каждый  $\omega \in \Omega$  называют элементарным исходом (событием).

Любое событие  $A$  рассматривается как некоторое подмножество универсального множества  $\Omega$  ( $A \subseteq \Omega$ ).

$\emptyset \subseteq \Omega$  — невозможное событие.

$\Omega$  — событие, происходящее всегда (при любом элементарном исходе), называется достоверным событием. ■

Суммой нескольких событий  $A_1, A_2, \dots, A_n$  называется объединение множеств  $A_1 \cup A_2 \cup \dots \cup A_n$ .

Произведением нескольких событий  $A_1, A_2, \dots, A_n$  называется пересечение множеств  $A_1 \cap A_2 \cap \dots \cap A_n$ .

Событием  $\bar{A}$ , противоположным событию  $A$ , называется дополнение множества  $A$  до  $\Omega$ ,  $\Omega \setminus A$ .

Под операциями над событиями понимаются операции над соответствующими множествами.

**Определение 1.1.** Пусть  $\Omega$  — некоторое множество. Некоторое семейство  $\mathcal{A}$  подмножеств из  $\Omega$  называют  $\sigma$ -алгеброй, если:

1.  $\Omega \in \mathcal{A}$  (множество  $\Omega$  содержится в  $\mathcal{A}$ );
2.  $(\forall B) \in \mathcal{A} \Rightarrow \overline{B} \in \mathcal{A}$
3.  $(\forall B) B_k \in \mathcal{A}, (\forall k) k \in \mathbb{N} :$

$$\bigcup_{k=1}^{\infty} B_k \in \mathcal{A} \quad \text{и} \quad \bigcap_{k=1}^{\infty} B_k \in \mathcal{A}. \blacksquare$$

$\sigma$ -алгебра замкнута относительно теоретико-множественных операций.

**Определение 1.2.** Пару  $(\Omega, \mathcal{A})$  из множества  $\Omega$  и  $\sigma$ -алгебры  $\mathcal{A}$  подмножеств из  $\Omega$  называют **измеримым пространством**.

**Определение 1.3.** Вероятностью (вероятностной мерой) на измеримом пространстве  $(\Omega, \mathcal{A})$  называют скалярную функцию  $\mathbf{P} : \mathcal{A} \rightarrow \mathbb{R}$ , определенную на  $\sigma$ -алгебре  $\mathcal{A}$ , которая удовлетворяет трем условиям:

а)  $\mathbf{P}[A] \geq 0$ ,  $A \in \mathcal{A}$ ;

б)  $\mathbf{P}[\Omega] = 1$ ;

в) для любых попарно не пересекающихся множеств  $B_k \in \mathcal{A}$ ,  $k \in \mathbb{N}$ , имеет место равенство

$$\mathbf{P}\left[\bigcup_{k=1}^{\infty} B_k\right] = \sum_{k=1}^{\infty} \mathbf{P}[B_k]. \blacksquare$$

Множество  $\Omega$ , на котором задана  $\sigma$ -алгебра  $\mathcal{A}$ , — это пространство элементарных исходов, элементы  $\sigma$ -алгебры  $\mathcal{A}$  — это события, вероятностная мера  $\mathbf{P}$  — это функция, задающая вероятности всевозможных событий.

**Определение 1.4.** Тройку  $(\Omega, \mathcal{A}, \mathbf{P})$  из непустого множества  $\Omega$ , заданной на  $\Omega$   $\sigma$ -алгебры  $\mathcal{A}$  и определенной на  $\sigma$ -алгебре  $\mathcal{A}$  вероятностной меры  $\mathbf{P}$  называют **вероятностным пространством**. ■

**Определение 1.5.** Пусть  $(\Omega, \mathcal{A}, \mathbf{P})$  — вероятностное пространство и  $A_1, A_2 \in \mathcal{A}$  — события, причем  $\mathbf{P}[A_1] > 0$ . Под **условной вероятностью** события  $A_2$  относительно события  $A_1$  понимают число

$$\mathbf{P}[A_2 | A_1] \triangleq \frac{\mathbf{P}[A_1 \cap A_2]}{\mathbf{P}[A_1]}. \blacksquare$$

**Определение 1.6.** Пусть  $(\Omega, \mathcal{A}, \mathbf{P})$  — вероятностное пространство. События  $A, B \in \mathcal{A}$ , для которых  $\mathbf{P}[A] > 0$  и  $\mathbf{P}[B] > 0$ , называют **независимыми**, если выполнены равенства

$$\mathbf{P}[A | B] = \mathbf{P}[A] \quad \text{и} \quad \mathbf{P}[B | A] = \mathbf{P}[B].$$

В противном случае события  $A$  и  $B$  называют **зависимыми**.

**Определение 1.7.** Отображение  $\xi: \Omega \rightarrow X$  измеримого пространства  $(\Omega, \mathcal{A})$  в измеримое пространство  $(X, \mathcal{B})$  называют **измеримой функцией**, если для любого  $B \in \mathcal{B}$  прообраз множества  $B$ , т.е. множество  $\xi^{-1}(B) = \{\omega \in \Omega: \xi(\omega) \in B\}$ , принадлежит  $\mathcal{A}$ . ■

Измеримое пространство  $(\Omega, \mathcal{A})$  входит в состав вероятностного пространства  $(\Omega, \mathcal{A}, \mathbf{P})$  (дополнительно задана вероятностная мера).

Измеримая функция  $\xi(\omega)$ ,  $\omega \in \Omega$ , преобразует вероятностную меру  $\mathbf{P}$  на  $(\Omega, \mathcal{A})$  в вероятностную меру  $\mathbf{P}_\xi$ , определяемую равенством  $\mathbf{P}_\xi[B] = \mathbf{P}[\xi^{-1}(B)]$  и превращает измеримое пространство  $(X, \mathcal{B})$  в вероятностное пространство  $(X, \mathcal{B}, \mathcal{P}_\xi)$ . Таким способом можно заменить вероятностное пространство, „данное от природы“, на более удобное и простое.

Особый случай:  $X = \mathbb{R}$ , а  $\mathcal{B}$  — **борелевская  $\sigma$ -алгебра**, т.е. минимальная  $\sigma$ -алгебра, содержащая все промежутки (открытые, замкнутые, полуоткрытые) на числовой оси.

В этом случае, измеримая функция определяется, как функция  $\xi(\omega)$ ,  $\omega \in \Omega$ , для которой прообраз любого множества  $B$  вида  $B = \{x \in \mathbb{R}: x < a\}$  принадлежит  $\sigma$ -алгебре  $\mathcal{A}$ , т.е. является событием.

Такую измеримую функцию в теории вероятностей называют **случайной величиной**. ■

На множестве  $\mathbb{R}^n$  можно задать  $\sigma$ -алгебру, отталкиваясь от множеств вида

$$T_1 \times T_2 \times \dots \times T_n = \{(x_1, \dots, x_n) \in \mathbb{R}^n: x_i \in T_i, i = \overline{1, n}\},$$

где  $T_i$  — промежутки числовой оси.

Борелевская  $\sigma$ -алгебра  $\mathcal{B}$  в  $\mathbb{R}^n$  — это наименьшая  $\sigma$ -алгебра, содержащая указанные множества.

Измеримая функция, отображающая  $\Omega$  в  $\mathbb{R}^n$ , представляет собой совокупность  $n$  случайных величин — ее координатных функций.

Такую функцию называют  $n$ -мерным **случайным вектором**.

Случайный вектор — многомерное обобщение понятия случайной величины.

Случайная величина —  $n$ -мерный случайный вектор с  $n = 1$ .

Случайный вектор можно определить как  $n$ -мерную векторную функцию  $\xi(\omega)$ ,  $\omega \in \Omega$ , для которой при любом  $x \in \mathbb{R}^n$  множество

$$A_x \triangleq \{\omega \in \Omega: \xi(\omega) < x\}$$

принадлежит  $\mathcal{A}$  (является событием).

Здесь

$$\xi(\omega) \triangleq \begin{pmatrix} \xi_1(\omega) \\ \vdots \\ \xi_n(\omega) \end{pmatrix}, \quad x \triangleq \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix},$$

неравенство  $\xi(\omega) < x$  означает, что  $\xi_k(\omega) < x_k$ ,  $k = \overline{1, n}$ . ■

Изучение случайной величины  $\xi(\omega)$ ,  $\omega \in \Omega$ , сводится к анализу вероятностной меры  $\mathbf{P}_\xi$ , которая порождается этой функцией на борелевской  $\sigma$ -алгебре.

Исходное вероятностное пространство  $(\Omega, \mathcal{A}, \mathbf{P})$  перестает играть роль.

Вероятностная мера  $\mathbf{P}_\xi$  полностью определяется по своим значениям на промежутках вида  $(-\infty, a)$ . Можно найти значение вероятности на любом множестве борелевской  $\sigma$ -алгебры, комбинируя такие промежутки и используя свойства аддитивности и счетной аддитивности вероятности.

**Определение 1.8.** Пусть  $\xi(\omega)$ ,  $\omega \in \Omega$ , — случайная величина (случайный вектор). Скалярную функцию  $F_\xi(x) \triangleq \mathbf{P}_\xi[A_x]$ , где  $x \in \mathbb{R}$  ( $x \in \mathbb{R}^n$ ) и  $A_x \triangleq \{\omega \in \Omega: \xi(\omega) < x\}$ , называют **функцией распределения (вероятностей) случайной величины (случайного вектора)  $\xi(\omega)$ ,  $\omega \in \Omega$** . ■

Случайные величины  $\xi_i(\omega)$ ,  $\omega \in \Omega$ ,  $i = \overline{1, n}$ , можно рассматривать как координаты  $n$ -мерного случайного вектора. Иногда функцию распределения случайного вектора называют **совместной функцией распределения**.  
Сокращенные формы записи:

$$F_\xi(x) = \mathbf{P}[\xi(\omega) < x], \quad F_\xi(x_1, \dots, x_n) = \mathbf{P}[\xi_k(\omega) < x_k, k = \overline{1, n}].$$

**Определение 1.9.** Случайную величину (случайный вектор), принимающую не более чем счетное множество значений, называют **дискретной случайной величиной (дискретным случайным вектором)**. ■

Для дискретного случайного вектора  $\xi(\omega)$ ,  $\omega \in \Omega$ , множество значений можно записать в виде конечной или бесконечной последовательности  $\{x_{(k)}\}_{k=1}^N \subset \mathbb{R}^n$ , где  $N \leq \infty$ . Функция распределения случайного вектора имеет вид

$$F_{\xi}(x) \equiv \sum_{x_{(k)} < x} \mathbf{P}[\xi(\omega) = x_{(k)}].$$

**Определение 1.10.** **Непрерывным случайным вектором (СВ)** называют  $n$ -мерный случайный вектор  $\xi(\omega)$ , функцию распределения которого можно представить в виде

$$F_{\xi}(x) = \int_{-\infty}^x f_{\xi}(y) dy,$$

где  $x \triangleq (\eta^{\mathbb{T}}(x_1 \dots x_n))^{\mathbb{T}}$ ,  $y \triangleq (y_1 \dots y_n)^{\mathbb{T}}$ , или, что то же самое,

$$F_{\xi}(x_1, \dots, x_n) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f_{\xi}(y_1, \dots, y_n) dy_1 \dots dy_n.$$

Функцию  $f_{\xi}(x) = f_{\xi}(x_1, \dots, x_n)$  называют **плотностью распределения (вероятностей)**. В частном случае при  $n = 1$  непрерывный СВ  $\xi(\omega)$  называют **непрерывной случайной величиной**.

## Свойства плотности распределения $f_\xi(x)$ $n$ -мерного НСВ $\xi(\omega)$ .

1.  $f_\xi(x) \geq 0$ ,  $x \in \mathbb{R}^n$ ;
  2. Вероятность  $\mathbf{P}[\xi(\omega) \in G]$  попадания в произвольную  $n$ -мерную область  $G$ :  $\mathbf{P}[\xi(\omega) \in G] = \int_G f_\xi(x) dx$ ;  
 $\int_{\mathbb{R}^n} f_\xi(x) dx = 1$ ;
- вероятность попадания значения СВ в множество нулевой площади в  $\mathbb{R}^n$  (в фиксированную точку) всегда равна нулю;
3. Плотность распределения  $f_\xi(x)$  в своих точках непрерывности равна:

$$f_\xi(x_1, \dots, x_n) = \frac{\partial^n F_\xi(x_1, \dots, x_n)}{\partial x_1 \dots \partial x_n};$$

4. Если  $\xi(\omega) \triangleq (\eta^\mathbb{T}(\omega) \varepsilon^\mathbb{T}(\omega))^\mathbb{T}$ , где  $\xi(\omega)$  —  $n$ -мерный,  $\eta(\omega)$  —  $m$ -мерный ( $0 < m < n$ ), а  $\varepsilon(\omega)$  —  $(n - m)$ -мерный непрерывные СВ с плотностями распределения  $f_\xi(x)$ ,  $f_\eta(y)$ ,  $f_\varepsilon(z)$ , то

$$f_\eta(y) = \int_{\mathbb{R}^{n-m}} f_\xi(y, z) dz, \quad f_\varepsilon(z) = \int_{\mathbb{R}^m} f_\xi(y, z) dy,$$

где  $y \in \mathbb{R}^m$ ,  $z \in \mathbb{R}^{n-m}$ ,  $x = (y^\mathbb{T} z^\mathbb{T})^\mathbb{T} \in \mathbb{R}^n$ .

**Обобщенная плотность распределения вероятностей** дискретного СВ  $\xi(\omega)$  с множеством возможных значений  $\{x_{(k)}\}_{k=1}^N \subset \mathbb{R}^n$ ,  $N \leq \infty$ :

$$f_{\xi}(x) = \sum_{k=1}^{N \leq \infty} \mathbf{P}[\xi(\omega) = x_{(k)}] \delta(x - x_{(k)}),$$

где  $\delta(x) \equiv \delta(x_1)\delta(x_2)\dots\delta(x_n)$  —  $\delta$ -функция Дирака. ■

Функцию и плотность распределения вероятностей СВ  $\xi(\omega) = (\xi_1(\omega) \dots \xi_n(\omega))^{\mathbb{T}}$  называют **совместной функцией распределения вероятностей** и **совместной плотностью распределения вероятностей** случайных величин  $\xi_1(\omega), \dots, \xi_n(\omega)$ . ■

Для СВ задан **закон распределения случайного вектора** (при  $n = 1$  **случайной величины**), если задана функция или плотность распределения вероятностей случайного вектора  $\xi(\omega)$ .

Закон распределения СВ  $\xi(\omega) = (\xi_1(\omega) \dots \xi_n(\omega))^{\mathbb{T}}$  называют также **совместным законом распределения вероятностей** случайных величин  $\xi_1(\omega), \dots, \xi_n(\omega)$ .

**Определение 1.11.** Случайные векторы  $\xi_k(\omega)$ ,  $k = \overline{1, N}$ , заданные на одном и том же вероятностном пространстве  $(\Omega, \mathcal{A}, \mathbf{P})$ , называют **независимыми в совокупности**, если функция распределения  $F_\xi(x_1, \dots, x_n)$  блочного случайного вектора  $\xi(\omega) = (\xi_1(\omega) \dots \xi_n(\omega))^{\mathbb{T}}$  имеет вид

$$F_\xi(x_1, \dots, x_n) = \prod_{k=1}^N F_{\xi_k}(x_k),$$

где  $F_{\xi_k}(x_k)$ ,  $k = \overline{1, N}$ , — функции распределения случайных векторов  $\xi_k(\omega)$ . Если  $\xi_k(\omega)$ ,  $k = \overline{1, N}$ , — случайные величины, то говорят о **независимых случайных величинах**.

**Определение 1.12.** Пусть  $\eta(\omega)$  —  $n$ -мерный,  $\varepsilon(\omega)$  —  $m$ -мерный,  $\xi(\omega) \triangleq (\eta^\top(\omega) \varepsilon^\top(\omega))^\top$  —  $(n+m)$ -мерный случайные векторы с плотностями распределения (возможно, обобщенными)  $f_\eta(x)$ ,  $f_\varepsilon(y)$ ,  $f_\xi(x, y)$ . **Условной плотностью распределения (условным законом распределения)** случайного вектора  $\eta(\omega)$  при условии, что случайный вектор  $\varepsilon(\omega)$  принял некоторое фиксированное значение  $y \in \mathbb{R}^m$ , называют функцию

$$f(x | y) = \frac{f_\xi(x, y)}{f_\varepsilon(y)}. \blacksquare$$

Пусть на вероятностном пространстве  $(\Omega, \mathcal{A}, \mathbf{P})$  задан  $n$ -мерный случайный вектор  $\xi(\omega)$ ,  $S$  — множество возможных значений  $\xi(\omega)$ ,  $S \subset \mathbb{R}^n$  и измеримая (относительно борелевской алгебры  $\mathcal{B}$  в  $\mathbb{R}^n$ ) векторная функция  $\varphi: S \rightarrow \mathbb{R}^m$ .

**Определение 1.13.** Векторной (скалярной,  $m = 1$ ) функцией случайного вектора (случайной величины,  $n = 1$ )  $\xi(\omega)$  называют композицию функций

$$\eta(\omega) = \varphi(\xi(\omega)).$$

В качестве измеримой функции  $\varphi(x)$  можно взять любую непрерывную, кусочно непрерывную или интегрируемую векторную функцию.

**Определение 1.14.** Математическим ожиданием  $n$ -мерного случайного вектора  $\xi(\omega) = (\xi_1(\omega) \dots \xi_n(\omega))^T$  с функцией плотности вероятностей  $f_\xi(x) = f_\xi(x_1, \dots, x_n)$  называют  $n$ -мерный вектор

$$\mathbf{M}[\xi(\omega)] \triangleq \int_{\mathbb{R}^n} x f_\xi(x) dx,$$

компонентами которого являются числа

$$\mathbf{M}[\xi_k(\omega)] = \int_{\mathbb{R}^n} x_k f_\xi(x) dx, \quad k = \overline{1, n}.$$

Числа  $\mathbf{M}[\xi_k(\omega)]$  представляют собой математические ожидания координатных случайных функций  $\xi_k(\omega)$ .

Математическое ожидание случайного вектора не определено, если хотя бы один несобственный интеграл  $\int_{\mathbb{R}^n} x_k f_\xi(x) dx$  расходится.

## Свойства математического ожидания

Математическое ожидание случайного вектора составляется из математических ожиданий координатных случайных функций, рассмотрим свойства математического ожидания для одномерного случая.

Пусть  $\xi(\omega)$ ,  $\eta(\omega)$  — случайные величины, имеющие математические ожидания, а  $\alpha, \beta \in \mathbb{R}$  — произвольные постоянные. ■

1. Если  $\xi(\omega) \geq 0$  (т.е. принимает только неотрицательные значения), то  $\mathbf{M}[\xi(\omega)] \geq 0$ ;
2.  $\mathbf{M}[\alpha\xi(\omega) + \beta\eta(\omega)] = \alpha\mathbf{M}[\xi(\omega)] + \beta\mathbf{M}[\eta(\omega)]$ ;
3.  $|\mathbf{M}[\xi(\omega)]| \leq \mathbf{M}[|\xi(\omega)|]$ ;
4. Если  $\xi(\omega)$ ,  $\eta(\omega)$  — независимые случайные величины, то  $\mathbf{M}[(\xi(\omega)\eta(\omega))] = \mathbf{M}[\xi(\omega)]\mathbf{M}[\eta(\omega)]$ ;
5.  $(\mathbf{M}[\xi(\omega)\eta(\omega)])^2 \leq \mathbf{M}[\xi^2(\omega)]\mathbf{M}[\eta^2(\omega)]$ .

## Условное математическое ожидание

Рассмотрим математическое ожидание части компонент случайного вектора с использованием их условной плотности распределения вероятностей относительно других компонент.

Например, пусть  $\eta(\omega)$  —  $n$ -мерный,  $\varepsilon(\omega)$  —  $m$ -мерный случайные векторы и  $f(x | y)$  — условная плотность распределения  $\eta(\omega)$  при условии, что  $\varepsilon(\omega)$  принял значение  $y$ . ■

**Определение 1.15.** Значением  $\mathbf{M}[\eta(\omega) | y]$  условного математическим ожидания случайного вектора  $\eta(\omega)$  при условии  $\varepsilon(\omega) = y$  называют  $m$ -мерный вектор

$$\mathbf{M}[\eta(\omega) | y] \triangleq \int_{\mathbb{R}^n} x f(x | y) dx. \blacksquare$$

Значение условного математического ожидания  $\mathbf{M}[\eta(\omega) | y]$  является функцией  $\varphi(y)$  переменного  $y$ , меняющегося в области значений случайного вектора  $\varepsilon(\omega)$ .

**Определение 1.16.** Функцию  $\varphi(\varepsilon(\omega)) \equiv \mathbf{M}[\eta(\omega) | \varepsilon(\omega)]$  от случайного вектора  $\varepsilon(\omega)$  называют **условным математическим ожиданием** случайного вектора  $\eta(\omega)$  при условии  $\varepsilon(\omega)$ .

**Определение 1.17.** Дисперсией  $\mathbf{D}[\xi(\omega)]$  скалярной случайной величины  $\xi(\omega)$  называют математическое ожидание случайной величины  $(\xi(\omega) - \mathbf{M}[\xi(\omega)])^2$ , т.е. число

$$\mathbf{D}[\xi(\omega)] \triangleq \mathbf{M}[(\xi(\omega) - \mathbf{M}[\xi(\omega)])^2]. \blacksquare$$

Для случайной величины  $\xi(\omega)$  с плотностью распределения  $f_\xi(x)$  дисперсия может быть вычислена:

$$\mathbf{D}[\xi(\omega)] = \int_{-\infty}^{\infty} (x - \mathbf{M}[\xi(\omega)])^2 f_\xi(x) dx. \blacksquare$$

### Свойства дисперсии

1.  $\mathbf{D}[\xi(\omega)] \geq 0$ ;
2.  $\mathbf{D}[\alpha\xi(\omega)] = \alpha^2\mathbf{D}[\xi(\omega)]$ ,  $\alpha \in \mathbb{R}$ ;
3.  $\mathbf{D}[\xi(\omega) + \alpha] = \mathbf{D}[\xi(\omega)]$ ,  $\alpha \in \mathbb{R}$ ;
4. если случайные величины  $\xi(\omega)$  и  $\eta(\omega)$  независимые, то  $\mathbf{D}[\xi(\omega) + \eta(\omega)] = \mathbf{D}[\xi(\omega)] + \mathbf{D}[\eta(\omega)]$ ;
5.  $\mathbf{D}[\alpha] = 0$ , т.е. дисперсия случайной величины, имеющей постоянное значение (детерминированной величины), равна нулю;
6.  $\mathbf{D}[\xi(\omega)] = \mathbf{M}[\xi^2(\omega)] - (\mathbf{M}[\xi(\omega)])^2$ ;

**Определение 1.18.** Ковариацией двух случайных величин  $\xi(\omega)$  и  $\eta(\omega)$  называют число

$$\mathbf{cov}[\xi(\omega), \eta(\omega)] \triangleq \mathbf{M}[(\xi(\omega) - \mathbf{M}[\xi(\omega)])(\eta(\omega) - \mathbf{M}[\eta(\omega)])]. \blacksquare$$

$$\mathbf{cov}[\xi(\omega), \eta(\omega)] = \int \int_{\mathbb{R}^2} (x - \mathbf{M}[\xi(\omega)])(y - \mathbf{M}[\eta(\omega)]) f_{\xi\eta}(x, y) dx dy,$$

где  $f_{\xi\eta}(x, y)$  совместная плотность распределения случайных величин  $\xi(\omega)$  и  $\eta(\omega)$ .  $\blacksquare$

### Свойства ковариации

а)  $\mathbf{cov}[\xi(\omega), \eta(\omega)] \equiv \mathbf{cov}[\eta(\omega), \xi(\omega)]$ ;

б)  $\mathbf{cov}[\xi(\omega), \xi(\omega)] \equiv \mathbf{D}[\xi(\omega)]$ ;

в) если случайные величины  $\xi(\omega)$  и  $\eta(\omega)$  независимые, то  $\mathbf{cov}[\xi(\omega), \eta(\omega)] = 0$ ;

г)  $\mathbf{cov}[\xi(\omega), \eta(\omega)] = \mathbf{M}[\xi(\omega)\eta(\omega)] - \mathbf{M}[\xi(\omega)] \mathbf{M}[\eta(\omega)]$ ;

д)  $2\mathbf{cov}[\xi(\omega), \eta(\omega)] = \mathbf{D}[\xi(\omega) + \eta(\omega)] - \mathbf{D}[\xi(\omega)] - \mathbf{D}[\eta(\omega)]$ .

**Определение 1.19.** Коэффициентом корреляции скалярных случайных величин  $\xi(\omega)$  и  $\eta(\omega)$  называют число

$$\rho[\xi(\omega), \eta(\omega)] \triangleq \frac{\text{cov}[\xi(\omega), \eta(\omega)]}{\sqrt{\mathbf{D}[\xi(\omega)] \mathbf{D}[\eta(\omega)]}}.$$

Две случайные величины  $\xi(\omega)$  и  $\eta(\omega)$  называют **некоррелированными**, если  $\rho[\xi(\omega), \eta(\omega)] = 0$ , или, что то же самое,  $\text{cov}[\xi(\omega), \eta(\omega)] = 0$ . ■

### Свойства коэффициента корреляции

1.  $|\rho[\xi(\omega), \eta(\omega)]| \leq 1$ ;
2.  $|\rho[\xi(\omega), \eta(\omega)]| = 1$  тогда и только тогда, когда  $\eta(\omega) = \alpha\xi(\omega) + \beta$ , где  $\alpha, \beta \in \mathbb{R}$ , при  $\rho[\xi(\omega), \eta(\omega)] = 1$   $\alpha > 0$   
при  $\rho[\xi(\omega), \eta(\omega)] = -1$   $\alpha < 0$ .

**Определение 1.20.** Ковариационной матрицей случайного вектора  $\xi(\omega) \triangleq (\xi_1(\omega) \dots \xi_n(\omega))^{\mathbb{T}}$  называют матрицу

$$\mathbf{cov}[\xi(\omega)] \triangleq (\mathbf{cov} [\xi_i(\omega), \xi_j(\omega)]).$$

Ковариационная матрица  $n$ -мерного случайного вектора представляет собой квадратную матрицу порядка  $n$  из ковариаций пар координатных случайных функций. ■

### Свойства ковариационной матрицы

1.  $\mathbf{cov}[\xi(\omega)]$  — симметрическая неотрицательно определенная квадратная матрица порядка  $n$ ;
2. если  $\eta(\omega) = A\xi(\omega) + b$ , где  $A \in M_{mn}(\mathbb{R})$  — фиксированная матрица,  $b \in \mathbb{R}^m$  — фиксированный вектор, то  $\mathbf{cov}[\eta(\omega)] = A\mathbf{cov}[\xi(\omega)]A^{\mathbb{T}}$ .

**Определение 1.21.** Характеристической функцией  $n$ -мерного случайного вектора  $\xi$  называют функцию

$$\varphi_\xi(\lambda) \triangleq \mathbf{M}[\exp(i\lambda^\mathbb{T}\xi(\omega))],$$

где  $\lambda \in \mathbb{R}^n$ , а  $i$  — мнимая единица. ■

Характеристическая функция является изображением экспоненциального интегрального преобразования Фурье.

$$\varphi_\xi(\lambda) = \int_{\mathbb{R}^n} \exp(i\lambda^\mathbb{T}x) f_\xi(x) dx,$$

В классе функций, интегрируемых с квадратом, существует взаимно однозначное соответствие между характеристическими функциями и плотностями распределения.

## Свойства характеристической функции

1.  $|\varphi_\xi(\lambda)| \leq 1$ .
2.  $\varphi_\xi(\mathbf{0}) = \mathbf{1}$ .
3.  $\varphi_\xi(-\lambda) = \varphi_\xi^*(\lambda)$ , при изменении знака аргумента значение характеристической функции меняется на комплексно сопряженное.
4. Если  $\eta(\omega) = A\xi(\omega) + b$ , где матрица  $A \in M_{mn}(\mathbb{R})$  и вектор  $b \in \mathbb{R}^m$  фиксированы, то  $\varphi_\eta(\mu) = \exp(i\mu^\top b)\varphi_\xi(A^\top \mu)$ .
5. Если случайные величины  $\xi_k(\omega)$ ,  $k = \overline{1, N}$ , независимы в совокупности,  $\eta(\omega) = \xi_1(\omega) + \dots + \xi_n(\omega)$ , то  $\varphi_\eta(\lambda) = \prod_{k=1}^N \varphi_{\xi_k}(\lambda)$ , где  $\lambda = (\lambda_1 \dots \lambda_n)^\top$ .

## 1.3. Элементы математической статистики

Математическая статистика — раздел математики, который занимается разработкой методов получения научно обоснованных выводов о массовых явлениях и процессах по данным наблюдений или экспериментов.

**Определение 1.22.** В математической статистике множество возможных значений случайной величины  $X$  называют **генеральной совокупностью** случайной величины  $X$  или просто генеральной совокупностью  $X$ . ■

Исходным материалом для изучения свойств генеральной совокупности (т.е. некоторой случайной величины) являются **экспериментальные (статистические) данные**, под которыми понимают значения случайной величины, полученные в результате повторений случайного эксперимента (наблюдений над случайной величиной)

Эксперимент (хотя бы теоретически) может быть повторен сколько угодно раз в одних и тех же условиях. ■

Распределение случайной величины  $X_i$ ,  $i = 1, 2, \dots$ , заданной на множестве исходов  $i$ -го эксперимента, не зависит от номера испытания и совпадает с распределением генеральной совокупности  $X$  (**независимые повторные эксперименты, испытания, независимые повторные наблюдения**).

**Определение 1.23.** **Случайная выборка** из генеральной совокупности  $X$   $\vec{X}_n = (X_1, \dots, X_n)$   $(X_1, \dots, X_n)$ . — это совокупность независимых случайных величин  $X_1, \dots, X_n$ , каждая из которых имеет то же распределение, что и случайная величина  $X$ , где  $n$  — **объем случайной выборки**, случайные величины  $X_i$  — **элементы случайной выборки**. ■

Любое возможное значение  $\vec{x}_n = (x_1, \dots, x_n)$  случайной выборки  $\vec{X}_n$  — **выборка** из генеральной совокупности  $X$  (**реализация случайной выборки**  $\vec{X}_n$ ).

Выборка  $\vec{x}_n$  — совокупность  $n$  чисел  $x_1, \dots, x_n$ , полученных в результате проведения  $n$  повторных независимых наблюдений над случайной величиной  $X$ . ■

Основой любых выводов о вероятностных свойствах генеральной совокупности  $X$ , т.е. **статистических выводов**, является **выборочный метод**, суть которого заключается в том, что свойства случайной величины  $X$  устанавливаются путем изучения тех же свойств на случайной выборке.

Множество возможных значений случайной выборки  $\vec{X}_n$  называют **выборочным пространством** и обозначают  $\mathcal{X}_n$  ( $n$ -мерное линейное арифметическое пространство  $\mathbb{R}^n$ , или его подмножество).

Если  $X$  — дискретная случайная величина, то выборочное пространство — конечное или счетное.

Элементы  $X_i$ ,  $i = \overline{1, n}$ , случайной выборки  $\vec{X}_n$  независимы и имеют то же распределение, что и генеральная совокупность  $X$ . Функция распределения  $F_{\vec{X}}(t_1, \dots, t_n)$  случайной выборки  $\vec{X}_n$  имеет вид

$$\begin{aligned} F_{\vec{X}}(t_1, \dots, t_n) &= \mathbf{P} \{X_1 < t_1, \dots, X_n < t_n\} = \\ &= \prod_{i=1}^n \mathbf{P} \{X_i < t_i\} = \prod_{i=1}^n F(t_i), \end{aligned}$$

где  $F(t)$  — функция распределения случайной величины  $X$  (генеральной совокупности  $X$ ). ■

О распределении случайной величины  $X$  могут быть самые общие представления. Например,  $X$  является непрерывной случайной величиной, о распределении практически ничего не известно. Или функция распределения известна, но не известны параметры, от которых она зависит.

Часто можно говорить только о семействе (классе)  $\mathcal{P}$  распределений случайной выборки, в котором содержится **априорная информация**.

**Статистическая модель** — выборочное пространство, на котором задан класс распределений  $\mathcal{P}$ , обозначается  $\{F(x)\}$ .

**Статистическую модель** называют **параметрической**, если функция (плотность) распределения вероятности задана с точностью до неизвестного вектора параметров  $\vec{\theta} = (\theta_1 \dots \theta_r)$  множеством возможных значений  $\Theta$ , т.е.  $\vec{\theta} \in \Theta$ . Обозначение:  $\{F(x; \vec{\theta}); \vec{\theta} \in \Theta\}$ .

Множество  $\Theta$  называют **параметрическим множеством**.

**Статистическую модель** называют **непрерывной (дискретной)**, если случайная величина  $X$  является непрерывной (дискретной).

Если генеральная совокупность  $X$  является дискретной случайной величиной, распределение  $X$  задают в виде таблицы (ряда распределений).

Если генеральная совокупность  $X$  является непрерывной случайной величиной распределение  $X$  задают в виде плотности распределения  $p_X(x)$ .

Любую функцию  $g(\vec{X}_n)$  случайной выборки в математической статистике называют **статистикой (выборочной характеристикой)**.

Распределение этой случайной величины называют **выборочным распределением**.

Выборочное распределение однозначно определяется совместным распределением случайных величин  $X_1, \dots, X_n$ , т.е. распределением случайной выборки  $\vec{X}_n$ .

Значение  $g(\vec{x}_n)$  выборочной характеристики  $g(\vec{X}_n)$ , определенное по реализации  $\vec{x}_n$  случайной выборки  $\vec{X}_n$ , называют ее **выборочным значением**.

**Сходимость по вероятности и сходимость по распределению (слабая сходимость).**

**Определение 1.24.** Последовательность  $\{Y_n\}$  случайных величин называют сходящейся по вероятности к  $Y$  ( $Y_n \xrightarrow{P} Y$ ), если для любого  $\varepsilon > 0$

$$\lim_{n \rightarrow \infty} \mathbf{P}|Y_n - Y| > \varepsilon \rightarrow 0. \blacksquare$$

**Определение 1.25.** Последовательность  $F_{Y_n}(x)$  функций распределения называют сходящейся по распределению (слабо сходящейся)  $F_{Y_n}(x) \Rightarrow F_Y(x)$ , если имеет место равенство

$$\lim_{n \rightarrow \infty} F_{Y_n}(x) = F_Y(x)$$

в каждой точке непрерывности  $F_Y(x)$ .

## Основные задачи математической статистики

Источниками информации для решения задачи математической статистики.

1. Результаты наблюдений (эксперимента) в виде выборки из некоторой генеральной совокупности скалярной (векторной) случайной величины.
2. Априорная информация о свойствах изучаемого объекта.

### 1. Задача оценивания неизвестных параметров

Функция распределения генеральной совокупности известна с точностью до параметра  $\theta$  ;

**Определение 1.26.** **Оценкой**  $\tilde{\theta}$  параметра  $\theta$  называют всякую функцию результатов наблюдений над случайной величиной(СВ)  $X$  (статистику), с помощью которой судят о значении  $\theta$  .  $\tilde{\theta}_n = \tilde{\theta}_n(X_1, X_2, \dots, X_n)$

$X_1, X_2, \dots, X_n$  — СВ,  $\tilde{\theta}$  — СВ, закон распределения  $\tilde{\theta}$  зависит от закона распределения случайной величины  $X$  и от  $n$  .

### 2. Проверка статистических гипотез

**Определение 1.27.** **Статистической гипотезой** называют любое предположение о распределении вероятностей (законе распределения и/или параметрах закона распределения вероятностей) наблюдаемой случайной величины (скалярной или векторной).

**3. Установление формы и степени связи между случайными величинами** (корреляционный, дисперсионный, регрессионный анализ и др.)

# Задача оценивания неизвестных параметров

## Точечные оценки

Необходимо найти такую статистику  $\hat{\theta}(\vec{X}_n)$ , выборочное значение  $\hat{\theta} = \hat{\theta}(\vec{x}_n)$  которой для рассматриваемой реализации  $\vec{x}_n$  случайной выборки можно было бы считать приближенным значением параметра  $\vec{\theta}$ . Статистику  $\hat{\theta}(\vec{X}_n)$ , выборочное значение  $\hat{\theta}$  которой для любой реализации  $\vec{x}_n$  принимают за приближенное значение неизвестного параметра  $\theta$ , называют его **точечной оценкой (оценкой)**, а  $\hat{\theta}$  — значением **точечной оценки (оценки)**.

**Требование:** выборочное значение  $\hat{\theta}$  ( $\hat{\theta}(\vec{X}_n)$ ,  $\theta^*(\vec{X}_n)$ ) соответствовало истинному значению параметра  $\vec{\theta}$ .

### Свойства точечных оценок

Состоятельные, несмещенные и эффективные оценки.

**Определение 1.28.** Статистику  $\hat{\theta}(\vec{X}_n)$  называют **состоятельной оценкой** параметра  $\theta \in \Theta$ , если с ростом объема выборки  $n$  она сходится по вероятности к оцениваемому параметру  $\theta$ , т.е.

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

Для состоятельной оценки  $\hat{\theta}(\vec{X}_n)$  отклонение ее от  $\theta$  на величину  $\varepsilon$  и более становится маловероятным при большом объеме выборки.

**Определение 1.29.** Статистику  $\widehat{\theta}(\vec{X}_n)$  называют **несмещенной оценкой** параметра  $\theta$ , если ее математическое ожидание совпадает с  $\theta$ , т.е.  $\mathbf{M}\widehat{\theta}(\vec{X}_n) = \theta$  для любого фиксированного  $n$ .

Оценка не дает систематической погрешности относительно истинного значения параметра  $\theta$ .

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

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

**Определение 1.30.** Если в некотором классе несмещенных оценок параметра  $\theta$ , имеющих конечную дисперсию, существует такая оценка  $\widehat{\theta}(\vec{X}_n)$ , что для всех оценок  $\widetilde{\theta}(\vec{X}_n)$  из этого класса, выполняется неравенство

$$\mathbf{D}\widehat{\theta}(\vec{X}_n) \leq \mathbf{D}\widetilde{\theta}(\vec{X}_n),$$

то **оценку**  $\widehat{\theta}(\vec{X}_n)$  называют **эффективной в данном классе оценок**.

Дисперсия эффективной оценки параметра в некотором классе является минимальной среди дисперсий всех оценок из рассматриваемого класса несмещенных оценок.

**Теорема 1.** Оценка  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$  (**выборочное среднее**) математического ожидания  $\theta = \mathbf{M}X = \mu$  генеральной совокупности  $X$  с конечной дисперсией является несмещенной, состоятельной и эффективной в классе всех **линейных оценок**, т.е. оценок вида  $\tilde{\theta}(\vec{X}_n) = \sum_{i=1}^n \alpha_i X_i$ , где  $\sum_{i=1}^n \alpha_i = 1$ , для произвольной параметрической модели.

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

### Исправленная выборочная дисперсия

Статистика

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

называется **исправленной выборочной дисперсией**.

Из теоремы 2 следует, что она является несмещенной и состоятельной оценкой дисперсии  $\sigma^2$  генеральной совокупности.

**Теорема 3 (о единственности эффективной оценки).** Пусть  $\hat{\theta}(\vec{X}_n)$  и  $\tilde{\theta}(\vec{X}_n)$  — две эффективные оценки для параметра  $\theta$  рассматриваемой параметрической модели. Тогда

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

где равенство следует понимать в вероятностном смысле:

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

**Теорема 4 (неравенство Рао — Крамера).** Пусть параметрическая модель является *регулярной* и  $\hat{\theta}(\vec{X}_n)$  — несмещенная оценка неизвестного параметра  $\theta$ . Тогда имеет место неравенство

$$\mathbf{D}\hat{\theta}(\vec{X}_n) \geq \frac{1}{nI(\theta)}, \quad (1.1)$$

где  $I(\theta) = \mathbf{M} \left( \frac{\partial \ln p(X; \theta)}{\partial \theta} \right)^2$  — **количество информации по Фишеру** в одном наблюдении,  $p(t; \theta)$  — плотность распределения генеральной совокупности  $X$  (*непрерывная стат. модель*) или вероятность события  $\{X = t\}$  (*дискретная стат. модели*).

$e(\theta) = \frac{1}{nI(\theta) \mathbf{D}\hat{\theta}(\vec{X}_n)}$  — **показатель эффективности по Рао — Крамеру**.

**Определение 1.31.** Несмещенную оценку  $\hat{\theta}(\vec{X}_n)$  параметра  $\theta \in \Theta \subset \mathbb{R}$  называют **эффективной по Рао — Крамеру**, если показатель эффективности  $e(\theta) = 1$ .

## Понятие достаточных статистик

$\vec{X}_n$  — случайная выборка из генеральной совокупности  $X$  с функцией распределения  $F(x; \theta)$ , где  $\theta$  — неизвестный параметр.

$T = T(\vec{X}_n)$  — некоторая статистика. Значение  $T(\vec{x}_n) = t$  статистики  $T$  — известно, выборка  $\vec{x}_n$  — реализация случайной выборки  $\vec{X}_n$  не известна.

**Определение 1.32.** Статистику  $T(\vec{X}_n)$  называют **достаточной** для параметра  $\theta$ , если условная функция распределения  $F_{\vec{X}_n}(z_1, \dots, z_n | T(\vec{X}_n) = t)$  случайной выборки  $\vec{X}_n$  при условии  $T(\vec{X}_n) = t$  не зависит от параметра  $\theta$  при любом возможном значении  $t$ .

### Критерий достаточности статистики

Функцию  $L(X_1, \dots, X_n; \theta) = p(x_1; \theta) \dots p(x_n; \theta)$ , называют **функцией правдоподобия**.

Здесь  $p(x; \theta)$  — ПРВ НСВ или вероятность события  $\{X = x\}$  в случае ДСВ,  $X_i, i = \overline{1, n}$ , — элементы случайной выборки  $\vec{X}_n$ .

**Теорема 5 (критерий факторизации Неймана — Пирсона).** Статистика  $T = T(x_1, \dots, x_n)$  является достаточной для параметра  $\theta$  тогда и только тогда, когда для любой реализации  $(x_1, \dots, x_n)$  случайной выборки  $(X_1, \dots, X_n)$  выборочное значение функции правдоподобия имеет вид

$$L(X_1, \dots, X_n; \theta) = g(T(x_1, \dots, x_n), \theta) h(x_1, \dots, x_n), \quad (1.2)$$

т.е. может быть представлено в виде произведения двух сомножителей, первый зависит от результатов наблюдений  $x_1, \dots, x_n$  только через статистику  $T = T(x_1, \dots, x_n)$ , второй не зависит от  $\theta$ .

Всякая эффективная по Рао — Крамеру оценка  $\hat{\theta} = \hat{\theta}(\vec{X}_n)$  параметра  $\theta$  является достаточной статистикой.

**Методы оценивания неизвестных параметров** по данным сл. выборки:  
( наиболее часто использующиеся)

- метод моментов;
- метод максимального правдоподобия;
- метод наименьших квадратов.

## Интервальные оценки

Интервальная оценка позволяет получить вероятностную характеристику точности оценивания неизвестного параметра.

**Определение 1.33.** Интервал  $(\underline{\theta}(\vec{X}_n), \bar{\theta}(\vec{X}_n))$  называют **доверительным интервалом** для  $\theta$  с **коэффициентом доверия (уровнем доверия)**  $\gamma$ , если выполнено неравенство  $\mathbf{P}\{\underline{\theta}(\vec{X}_n) \leq \theta \leq \bar{\theta}(\vec{X}_n)\} = \gamma$ .

Интервальная оценка  $(\underline{\theta}(\vec{X}_n), \bar{\theta}(\vec{X}_n))$  представляет собой интервал со случайными границами, который с заданной вероятностью  $\gamma$  покрывает неизвестное истинное значение параметра  $\theta$ .

Для любой реализации  $\vec{x}_n$  случайной выборки  $\vec{X}_n$ , вероятностной характеристикой точности оценивания параметра  $\theta$  является длина интервала, т.е. случайная величина  $l(\vec{X}_n) = \bar{\theta}(\vec{X}_n) - \underline{\theta}(\vec{X}_n)$ .

Статистику  $\underline{\theta}(\vec{X}_n)$  ( $\bar{\theta}(\vec{X}_n)$ ) называют **односторонней нижней (односторонней верхней)**  $\gamma$ -доверительной границей, если выполнено неравенство  $\mathbf{P}\{\underline{\theta}(\vec{X}_n) < \theta\} = \gamma$  ( $\mathbf{P}\{\theta < \bar{\theta}(\vec{X}_n)\} = \gamma$ ).

## Алгоритм построения доверительного интервала

- построение центральной статистики  $T(\vec{X}_n, \theta)$  с известной функцией распределения  $F_T(t)$ ;
- представление заданного коэффициента доверия  $\gamma$  в виде  $\gamma = 1 - \alpha - \beta$ ;
- нахождение квантилей  $h_\alpha$  и  $h_{1-\beta}$  уровня  $\alpha$  и  $1 - \beta$  функции распределения  $F_T(t)$ ;
- нахождение значений *нижней*  $\underline{\theta}(\vec{x}_n)$  и *верхней*  $\bar{\theta}(\vec{x}_n)$  *границ* искомой интервальной оценки.

Если  $T(\vec{x}_n, \theta)$  — возрастающая функция параметра  $\theta$ , то путем решения уравнений

$$T(\vec{x}_n, \underline{\theta}) = h_\alpha, \quad T(\vec{x}_n, \bar{\theta}) = h_{1-\beta} \quad (1.3)$$

Если  $T(\vec{x}_n, \theta)$  — убывающая функция параметра  $\theta$ , то путем решения уравнений

$$T(\vec{x}_n, \underline{\theta}) = h_{1-\beta}, \quad T(\vec{x}_n, \bar{\theta}) = h_\alpha \quad (1.4)$$

## 2. Проверка статистических гипотез

**Статистической гипотезой** называют любое предположение о виде или параметрах неизвестного закона распределения.

Проверяемая гипотеза  $H_0$  (нулевая). Альтернативная гипотеза  $H_1$ .

Если гипотеза не противоречит статистическим данным и ее следует принять, если гипотеза противоречит — отклонить

Если имеются предположения об известном законе распределения генеральной совокупности, то статистические гипотезы относительно неизвестного истинного значения параметра  $\theta$  называют **параметрическими гипотезами**. Никакой *априорной информацией* относительно параметра  $\theta$  нет.

Если  $\theta$  — скаляр, то гипотеза называется **однопараметрической**, а если  $\theta$  — вектор, то **многопараметрической**.

Если закон распределения генеральной совокупности неизвестен, то гипотезы называют **непараметрическими**.

Основные типы гипотез:

- 1) о равенстве числовых характеристик генеральных совокупностей ( $\mu_1 = \mu_2, \sigma_1^2 = \sigma_2^2$ );
- 2) о числовых значениях ( $\mu = \mu_0, \sigma^2 = \sigma_0^2$ );
- 3) о виде закона распределения ( $F(x) = F_T(x)$ ,  $F(x)$  — неизвестная ФРСВ  $X$ ,  $F_T(x)$  — теоретическая ФР);
- 4) проверка гипотез об однородности выборок;
- 5) о стохастической независимости выборок.

## Основные понятия

**Статистическую гипотезу  $H$**  называют **простой**, если она имеет вид  $H : \vec{\theta} = \vec{\theta}_0$ , где  $\vec{\theta}_0$  — некоторое заданное значение параметра.

**Статистическую гипотезу** называют **сложной**, если она имеет вид  $H : \vec{\theta} \in D$ , где  $D$  — некоторое множество значений параметра  $\theta$ , состоящее более чем из одного элемента.

## Проверка двух простых гипотез

Проверяются две *простые статистические гипотезы* вида  $H_0 : \theta = \theta_0$ ,  $H_1 : \theta \neq \theta_0$ , где  $\theta_0, \theta_1$  — два заданных (различных) значения параметра.  $H_0$  — основная,  $H_1$  — альтернативная гипотеза.

По данным *выборки*  $\vec{x}_n$  необходимо принять решение о справедливости одной из указанных гипотез.

**Критерием (статистическим критерием)**, проверки гипотез называют правило, по которому по данным выборки  $\vec{x}_n$  принимается решение о справедливости либо гипотезы  $H_0$ , либо гипотезы  $H_1$ .

Критерий задают с помощью **критического множества**  $W$  являющегося подмножеством *выборочного пространства*  $\mathcal{X}_n$  случайной выборки  $\vec{X}_n$ . Все *выборочное пространство* разбивается на два непересекающихся подмножества:  $W$  — критическую область (область отклонения гипотезы  $H_0$ ) и  $\bar{W}$  (дополнение множества  $W$ ) — область допустимых значений (область принятия гипотезы  $H_0$ ).

## Решение :

- 1) выборка  $\vec{x}_n$  принадлежит  $W$  — принимают альтернативную гипотезу  $H_1$ , основную гипотезу  $H_0$  отвергают;
- 2) выборка  $\vec{x}_n$  принадлежит  $\bar{W}$  — принимают основную гипотезу  $H_0$ , альтернативную гипотезу  $H_1$  отвергают.

## Ошибки

- 1) **ошибка первого рода** — принять гипотезу  $H_1$ , но верна  $H_0$ ;
- 2) **ошибка второго рода** — принять гипотезу  $H_0$ , но верна  $H_1$ .

Вероятность совершения ошибок:

$$1) \text{ первого рода } \alpha = \mathbf{P}\{\vec{X}_n \in W \mid H_0\} = \int_{\dots} \int_{\dots} \prod_{k=1}^n p(t_k; \theta_0) dt_1 \dots dt_n,$$

$$2) \text{ второго рода } \beta = \mathbf{P}\{\vec{X}_n \in \bar{W} \mid H_1\} = \int_{\dots} \int_{\dots} \prod_{k=1}^n p(t_k; \theta_1) dt_1 \dots dt_n,$$

где  $\mathbf{P}\{A \mid H_j\}$  — вероятность события  $A$  при условии, что справедлива гипотеза  $H_j$ ,  $j = 0, 1$ ,  $\prod_{k=1}^n p(t_k; \theta_0)$  — ФПРВ случайной выборки  $\vec{X}_n$

**Уровень значимости критерия** — вероятность совершения ошибки первого рода  $\alpha$ .

## Критерий Неймана — Пирсона

Вероятность  $1 - \beta$  не допустить ошибку второго рода (отвергнуть  $H_0$ , когда она неверна) называется **мощностью** критерия.

### Требования к критической области

$$\mathbf{P}(\theta_n \in W/H_0) = \alpha \quad \mathbf{P}(\theta_n \in W/H_1) = \max$$

Вероятность попадания статистики  $\theta$  в критическую область  $W$  — минимальна и равна  $\alpha$ , если верна  $H_0$  и максимальна в противоположном случае (при заданном уровне значимости  $\alpha$  мощность критерия  $1 - \beta$  — максимальна).

**Лемма 1. Критерий Неймана — Пирсона.** Среди всех критериев заданного уровня значимости  $\alpha$ , проверяющих простую гипотезу  $H_0 : \theta = \theta_0$  против альтернативной гипотезы  $H_1 : \theta = \theta_1$ , критерий отношения правдоподобия

$\varphi(\vec{X}_n) = \frac{L(\vec{X}_n; \theta_1)}{L(\vec{X}_n; \theta_0)}$ , где  $L(\vec{X}_n; \theta) = \prod_{i=1}^n p(X_i; \theta)$ , является наиболее мощным.

Для построения **оптимального** (наиболее мощного) при заданном уровне значимости  $\alpha$  **критерия Неймана — Пирсона** в *критическое множество*  $W$  включают элементы  $\vec{x}_n$  *выборочного пространства*  $\mathcal{X}_n$  случайной выборки  $\vec{X}_n$ , для которых выполняется неравенство  $\varphi(\vec{x}_n) \geq C_\varphi$ , константу  $C_\varphi$  выбирают из условия  $\mathbf{P}\{\varphi(\vec{X}_n) \geq C_\varphi | H_0\} = \int_{\varphi(t_1, \dots, t_n) \geq C_\varphi} \dots \int L(t_1, \dots, t_n; \theta_0) dt_1 \dots dt_n = \alpha$ , ко-

торое обеспечивает заданное значение уровня значимости  $\alpha$ .

Вероятность ошибки второго рода не может быть уменьшена при данном значении вероятности ошибки первого рода  $\alpha$ .

## Определение объема выборки

Определить объем  $n^*$  случайной выборки, при котором может быть построен критерий для проверки двух простых гипотез  $H_0: \theta = \theta_0$  и  $H_1: \theta = \theta_1$  с заданными или меньшими значениями вероятностей  $\alpha$  и  $\beta$  совершения ошибок первого и второго рода соответственно.

Величину  $n^*$  определяют как минимальное целое значение  $n$ , для которого система неравенств 1.5 может быть выполнена при некотором значении константы  $C = C^*$ .

$$\begin{cases} \mathbf{P}\{\varphi(X_1, \dots, X_n) \geq C_\varphi | \theta = \theta_0\} \leq \alpha, \\ \mathbf{P}\{\varphi(X_1, \dots, X_n) < C_\varphi | \theta = \theta_1\} \leq \beta. \end{cases} \quad (1.5)$$

*Критическое множество* определяемое в соответствии с оптимальным критерием Неймана — Пирсона, с заданными значениями  $\alpha$ ,  $\beta$  будет задаваться неравенством  $\varphi(x_1, \dots, x_n) \geq C_\varphi^*$ .

## Сложные параметрические гипотезы

Даны две сложные гипотезы

$$H_0 : \theta \in \Theta_0, \quad H_1 : \theta \in \Theta_1, \quad (1.6)$$

где  $\Theta_0, \Theta_1$  — некоторые непересекающиеся области значений параметра  $\theta$ . Например,  $\Theta_0 : \theta \leq \theta_0$  и  $\Theta_1 : \theta \geq \theta_1$ , где  $\theta_0$  и  $\theta_1$  — некоторые фиксированные значения параметра, удовлетворяющие неравенству  $\theta_0 < \theta_1$ .

*Критерий* проверки сложных гипотез (1.6) задается с помощью *критического множества*  $W$  реализаций случайной выборки  $\vec{X}_n$ .

**Решение :**

- реализация  $\vec{x}_n$  сл. выборки  $\vec{X}_n \in W$ ,  $H_0$  отвергают,  $H_1$  принимают;
- реализация  $\vec{x}_n$  сл. выборки  $\vec{X}_n \notin W$ ,  $H_1$  отвергают,  $H_0$  принимают.

Вероятность совершения ошибок:

1) первого рода  $\alpha(\theta) = \mathbf{P}\{(X_1, \dots, X_n) \in W | \theta\}$ ,  $\theta \in \Theta_0$ ;

2) второго рода  $\beta(\theta) = \mathbf{P}\{(X_1, \dots, X_n) \in \overline{W} | \theta\}$ ,  $\theta \in \Theta_1$ ,

Величины  $\alpha(\theta)$ ,  $\beta(\theta)$  являются функциями от параметра  $\theta$ .

Максимально возможное значение вероятности совершения ошибки первого рода  $\alpha = \max_{\theta \in \Theta_0} \alpha(\theta)$  называют **размером критерия**.

## Непараметрические гипотезы

Предположения о виде статистической модели можно сформулировать как статистические гипотезы и проверить при помощи *статистических критериев* на основании *статистических данных*.

### Критерии согласия. Простая гипотеза

**Критериями согласия** называют статистические критерии, предназначенные для обнаружения расхождений между гипотетической статистической моделью и реальными данными (насколько предположения о распределении случайных величин соответствуют экспериментальным данным).

Предположения о распределении случайных величин (виде закона распределения) может быть выдвинуто исходя из теоретических предпосылок, результатов экспериментов, гистограмм и др.

**Стандартные гипотезы.** Нулевая гипотеза  $H_0 : F_n(x) = F(x)$ .

Альтернативная гипотеза  $H_1 : F_n(x) \neq F(x)$ .

$F(x)$  — теоретическая ФРВ,  $F_n(x)$  — эмпирическая ФРВ.

**Теорема 6.** Пусть  $\widehat{R}(t, \vec{X}_n)$  — выборочная ФРВ, построенная по сл. выборке  $\vec{X}_n$  объема  $n$  из ГС с равномерным законом распределения на  $[0, 1]$ . Если  $H_0$  — истина ФРВ СВ, то  $D(\vec{X}_n)$  совпадает с ФРВ СВ  $\sup_{0 \leq t \leq 1} |\widehat{R}(t, \vec{X}_n) - t|$ .

## Критерий Колмогорова.

$\vec{X}_n$  — случайная выборка объема  $n$  из генеральной совокупности (ГС) **непрерывной** СВ  $X$ .  $H_0 : F_n(x) = F(x)$ ,  $H_1 : F_n(x) \neq F(x)$ , где  $F(x)$  — теоретическая ФРВ,  $F_n(x)$  — эмпирическая ФРВ.

Мера расхождения между теоретическим и эмпирическим распределением — максимальное значение абсолютной разности между  $F(x)$  и  $F_n(x)$ :  
$$D_n = \sup_{-\infty < x < \infty} |F(x) - F_n(x)|.$$

Распределение статистики критерия  $D_n$  при гипотезе  $H_0$  не зависит от вида ФРВ  $F(x)$  (теор.6). Если  $F(x)$  **непрерывна**, то при  $\forall \lambda > 0$

$$\lim_{n \rightarrow \infty} P(\sqrt{n}D_n \leq \lambda) = K(\lambda) = \sum_{j=-\infty}^{\infty} ((-1)^j \exp(-2j^2\lambda^2)).$$

Величина  $\sup_{-\infty < x < \infty} |F(x) - F_n(x)|$  имеет порядок  $1/\sqrt{n}$ , в качестве статистики используют величину  $\sqrt{n}D_n$ .

Предельную ФРВ  $K(\lambda)$  можно использовать при  $n \geq 20$ , критическую границу полагать равной  $\lambda_\alpha/\sqrt{n}$ . Критическое значение  $\lambda_\alpha$  получают из соотношения  $1 - K(\lambda_\alpha) = \alpha$ .

Критерий Колмогорова ”хорошо различает” сильно отличающиеся друг от друга ФРВ  $F(x)$  и  $F_n(x)$  (даже на небольшом интервале).

## Критерий $\omega^2$

$\vec{X}_n$  — случайная выборка объема  $n$  из ГС непрерывной СВ  $X$ .

Если  $F_n(x) \neq F(x)$  на достаточно большом промежутке, но максимальное значение абсолютной разности между  $F(x)$  и  $F_n(x)$  невелико, то для проверки стандартных гипотез  $H_0$  и  $H_1$  применяют  $\omega^2$ , использующий статистику

$$\omega^2(\vec{X}_n) = \frac{1}{12n^2} + \frac{1}{n} \sum_{i=1}^n \left( F_0(X_{(i)}) - \frac{2i-1}{2n} \right)^2, \quad (1.7)$$

где  $X_{(i)}$ ,  $i = \overline{1, n}$ , — элементы вариационного ряда случайной выборки  $X_1, \dots, X_n$ . Гипотеза  $H_0$  отклоняется в пользу  $H_1$  на уровне значимости  $\alpha$ , если  $\omega^2(\vec{x}_n) > \omega_{1-\alpha}^2$ , где  $\omega_{1-\alpha}^2$  — квантиль уровня  $1 - \alpha$  распределения статистики  $\omega^2(\vec{X}_n)$  при условии истинности гипотезы  $H_0$ .

Распределение статистики  $\omega^2(\vec{X}_n)$  при истинности основной гипотезы  $H_0$  не зависит от  $F_0$ .

Таблицы квантилей статистики  $\omega^2(\vec{X}_n)$  для малых  $n$  существуют. Для больших  $n$  — таблицы предельного распределения статистики  $n\omega^2(\vec{X}_n)$ .

## Критерий согласия $\chi^2$ (критерий Пирсона).

Пусть  $X$  — дискретная случайная величина, принимающая  $r$  различных значений  $u_1, \dots, u_r$  с положительными вероятностями  $p_1, \dots, p_r$ :

$$\mathbf{P}\{X = u_k\} = p_k, \quad k = \overline{1, r}, \quad \sum_{k=1}^r p_k = 1.$$

Пусть в выборке  $\vec{x}_n = (x_1, \dots, x_n)$  число  $u_k$  встретилось  $n_k(\vec{x}_n)$  раз,  $k = \overline{1, r}$ , случайные величины  $n_1(\vec{X}_n), \dots, n_r(\vec{X}_n)$  зависимы  $\left(\sum_{k=1}^r n_k(\vec{x}_n) = n\right)$ .

**Теорема 7 (теорема Пирсона).** Распределение случайной величины  $\sum_{k=1}^r \frac{(n_k(\vec{X}_n) - np_k)^2}{np_k}$  при  $n \rightarrow \infty$  слабо сходится к  $\chi^2$ -распределению с  $r - 1$  степенями свободы.

Простые гипотезы:

$$H_0 : p_1 = p_{10}, \dots, p_r = p_{r0},$$

$$H_1 : \text{существуют такие } k, \text{ что } p_k \neq p_{k0}, \quad k = \overline{1, r}$$

где  $p_{10}, \dots, p_{r0}$  — известные величины.

1. Если  $H_0$  — истинна, при  $n \rightarrow \infty$  распределение СВ (теор. 7)

$$\chi^2(\vec{X}_n) = \sum_{k=1}^r \frac{(n_k(\vec{X}_n) - np_{k0})^2}{np_{k0}} = n \sum_{k=1}^r \frac{\left(\frac{n_k(\vec{X}_n)}{n} - p_{k0}\right)^2}{p_{k0}} \quad (1.8)$$

стремится к распределению  $\chi^2$  с  $r - 1$  степенями свободы.

2. Если  $H_0$  — ложная, то при  $n \rightarrow \infty$   $\frac{n_k(\vec{X}_n)}{n} \rightarrow p_k$ ,  $k = \overline{1, r}$  (по закону больших чисел).

При  $n \rightarrow \infty$

$$\frac{n_k(\vec{X}_n)}{n} - p_{k0} = \left(\frac{n_k(\vec{X}_n)}{n} - p_k\right) + (p_k - p_{k0}) \rightarrow p_k - p_{k0}.$$

Если  $\exists k = \overline{1, r} | p_k - p_{k0} \neq 0$ , то статистика  $\chi^2(\vec{X}_n)$  принимает большие значения, чем в случае 1.

**Критерий согласия  $\chi^2$ .**

При больших  $n$  на уровне значимости  $\alpha$  гипотезу  $H_0$  **отклоняют** в пользу гипотезы  $H_1$ , если  $\chi^2(\vec{x}_n) > \chi_{1-\alpha}^2(r - 1)$ ,

где  $\chi_{1-\alpha}^2(r - 1)$  — квантиль уровня  $1 - \alpha$   $\chi^2$ -распределения с  $r - 1$  степенями свободы,  $\chi^2(\vec{x}_n)$  — реализация случайной величины (1.8).

Гипотезу  $H_0$  **принимают**, если  $\chi^2(\vec{x}_n) \leq \chi_{1-\alpha}^2(r - 1)$ ,

## Критерии согласия. Сложная гипотеза

### Критерии Колмогорова и $\omega^2$ для сложной гипотезы

Задача: проверить по случайной выборке  $\vec{X}_n$  из генеральной совокупности  $X$  сложную гипотезу о принадлежности ФРВ  $F(x)$  СВ  $X$  заданному параметрическому множеству (семейству) распределений  $F(x; \theta)$ ,  $\theta \in \Theta$ ,  $\Theta \subset \mathbb{R}^d$ :

$$H_0 : F_n(x) = F(x; \theta), \quad \theta \in \Theta.$$

Для критериев Колмогорова и  $\omega^2$  достаточно иметь только одну таблицу для каждого семейства (нормальное,  $t$ -распределение...). При небольшой модификации статистик  $\widehat{D}(\vec{X}_n)$  и  $\widehat{\omega}^2(\vec{X}_n)$  их распределение при  $n \geq 5$  практически перестает зависеть от  $n$ .

$$H_0 : F_n(x) = F(x; \widehat{\theta}(\vec{x}_n)),$$

где  $\widehat{\theta}(\vec{x}_n)$  — значение оценки параметра  $\theta$  полученные методом максимального правдоподобия (ММП), элементы  $F(x; \theta)$  параметрического множества  $\{F(x; \theta), \theta \in \Theta\}$  ФРВ получаются при помощи преобразования сдвига и масштаба какого-нибудь одного своего представителя

$$F(x; \theta), \text{ т.е. } F(x; \theta) = F\left(\frac{x - a}{b}, \theta_0\right), .$$

## Критерий $\chi^2$ Пирсона для сложной гипотезы

Пусть ФРВ ДСВ  $X = \{u_1, \dots, u_r\}$ , зависит от  $d$ -мерного вектора параметров  $\theta$ .  $p_k = p_k(\theta)$ ,  $k = \overline{1, r}$  — вероятность того, что  $X$  примет значение  $u_k$ .

Вероятности  $p_1(\theta), \dots, p_r(\theta)$  полностью определяют ФРВ СВ  $X$ . Основная гипотеза:  $H_0 : P(X = u_k) = p_k(\theta)$ ,  $k = \overline{1, r}$ ,  $\theta \in \Theta \subset \mathbb{R}^d$ .

Пусть  $\hat{\theta}(\vec{x}_n)$  — значение оценки параметра  $\theta(\vec{X}_n)$ , полученная ММП для  $\theta$ ,  $n_k(\vec{x}_n)$  — количество элементов выборки  $\vec{x}_n$ , равных  $u_k$ ,  $k = \overline{1, r}$ .

Оценку  $\hat{\theta}(\vec{X}_n)$  получают в результате минимизации логарифма функции правдоподобия

$$L(\vec{X}_n; \theta) = \frac{n!}{n_1! \dots n_r!} \prod_{k=1}^r p_k^{n_k(\vec{X}_n)}(\theta), \quad \sum_{i=1}^r n_i(\vec{X}_n) = n,$$

как решение системы уравнений

$$\sum_{k=1}^r \frac{n_k(\vec{X}_n)}{p_k(\theta)} \frac{\partial p_k(\theta)}{\partial \theta_j} = 0, \quad j = \overline{1, d}.$$

Распределение СВ при  $n \rightarrow \infty$

$$\chi^2(\vec{X}_n) = \sum_{i=1}^r \frac{(n_i(\vec{X}_n) - np_i(\hat{\theta}(\vec{X}_n)))^2}{np_i(\hat{\theta}(\vec{X}_n))}$$

слабо сходится к СВ, имеющей  $\chi^2$ -распределение с  $r - d - 1$  степенями свободы.

Если  $X$  — НСВ с ФРВ  $F(x)$ , то множество возможных значений  $X$  разбивают на конечное число непересекающихся подмножеств и переходят к ДСВ  $X'$ .

$$H_0 : F(x) \in \{F(t; \theta), \theta \in \Theta \subset \mathbb{R}^d\}.$$

Оценку  $\hat{\theta}(\vec{X}_n)$  строят ММП по значениям частот  $n_1(\vec{x}'_n), \dots, n_r(\vec{x}'_n)$  СВ  $X'$  (не по наблюдениям  $X_1, \dots, X_n$  СВ  $X$ ).

### 3. Установление формы и степени связи между случайными величинами

Пусть  $Y$  — СВ, поведение которой необходимо определить по значениям СВ  $X_1$  и  $X_2$ .

Например,  $Y$  — это степень шума двигателя автомашины, а  $X_1$  и  $X_2$  — соответственно величина пробега автомобиля и вес груза в нем.

Корреляционный и дисперсионный анализ позволяет дать ответ на вопрос: есть ли связь между  $X_1$ ,  $X_2$  и  $Y$  и насколько она существенна.

На основе регрессионного анализа по имеющимся статистическим данным можно построить регрессионную модель .

$$y = \varphi(x_1, x_2),$$

где  $y$  — среднее значение шума  $Y$  в зависимости от значений  $x_1$  и  $x_2$  случайных величин  $X_1$  и  $X_2$ .

Такая модель позволяет в дальнейшем различные задачи.

### Задача

Трёхмерный случайный вектор  $\vec{X} = (X_1, X_2, X_3)$  распределен по нормальному закону с вектором средних значений  $\vec{m} = (2,5, 1, 2)$  и матрицей ковариаций

$$\Sigma = \begin{pmatrix} 2 & 1 & 0,5 \\ 1 & 3 & 2 \\ 0,5 & 2 & 4 \end{pmatrix}.$$

Найти:

- совместную плотность распределения случайного вектора  $\vec{X}$ ;
- одномерные плотности распределения случайных величин  $X_1$ ,  $X_2$  и  $X_3$ .

а. Вычислим определитель матрицы  $\Sigma$  и матрицу  $\tilde{\Sigma} = \Sigma^{-1}$ :

$$\begin{pmatrix} 2 & 1 & 0,5 \\ 1 & 3 & 2 \\ 0,5 & 2 & 4 \end{pmatrix} = 13,25,$$

$$\tilde{\Sigma} = \Sigma^{-1} = \frac{1}{13,25} \begin{pmatrix} 8 & -3 & 0,5 \\ -3 & 7,75 & -3,5 \\ 0,5 & -3,5 & 5 \end{pmatrix},$$

Тогда

$$\begin{aligned} (\vec{x} - \vec{m}) \tilde{\Sigma} (\vec{x} - \vec{m})^T &= (x_1 - 2,5 \quad x_2 - 1 \quad x_3 - 2) \times \\ &\times \frac{1}{13,25} \begin{pmatrix} 8 & -3 & 0,5 \\ -3 & 7,75 & -3,5 \\ 0,5 & -3,5 & 5 \end{pmatrix} \begin{pmatrix} x_1 - 2,5 \\ x_2 - 1 \\ x_3 - 2 \end{pmatrix} = \\ &= \frac{1}{13,25} \left[ 8(x_1 - 2,5)^2 - 6(x_1 - 2,5)(x_2 - 1) + 7,75(x_2 - 1)^2 + \right. \\ &\left. + (x_1 - 2,5)(x_3 - 2) - 7(x_2 - 1)(x_3 - 2) + 5(x_3 - 2)^2 \right], \end{aligned}$$

Совместная плотность распределения случайного вектора  $\vec{X}$ , имеет вид

$$p_{\vec{X}}(\vec{x}) = \frac{1}{(\sqrt{2\pi})^3 \sqrt{13,25}} \times \\ \times \exp \left[ -\frac{1}{26,5} \left( 8(x_1 - 2,5)^2 - 6(x_1 - 2,5)(x_2 - 1) + \right. \right. \\ \left. \left. + 7,75(x_2 - 1)^2 + (x_1 - 2,5)(x_3 - 2) - 7(x_2 - 1)(x_3 - 2) + 5(x_3 - 2)^2 \right) \right].$$

б. Случайные величины  $X_1$ ,  $X_2$  и  $X_3$  распределены по нормальному закону с параметрами  $m_1 = 2,5$  и  $\sigma_1 = \sqrt{2}$ ,  $m_2 = 1$  и  $\sigma_2 = \sqrt{3}$ ,  $m_3 = 2$  и  $\sigma_3 = \sqrt{2}$ . Поэтому

$$P_{X_1}(x) = \frac{1}{2\sqrt{\pi}} e^{-(x-2,5)^2/4}, \quad P_{X_2}(x) = \frac{1}{\sqrt{6\pi}} e^{-(x-1)^2/6}, \\ P_{X_3}(x) = \frac{1}{2\sqrt{2\pi}} e^{-(x-2)^2/8}.$$

## Многомерное нормальное распределение

**Плотность (невыврожденного) нормального распределения для случайного вектора**  $\vec{X} = (X_1, \dots, X_n)$  произвольной размерности  $n > 2$ .

**Многомерный нормальный закон** определяется вектором средних значений  $\vec{m} = (m_1, \dots, m_n)$  и положительно определенной симметрической матрицей ковариаций (ковариационной матрицей)  $\Sigma = (\sigma_{ij})$ ,  $i, j = \overline{1, n}$ . Диагональный элемент  $\sigma_{ii}$  — дисперсия СВ  $X_i$ ,  $\sigma_i = \sqrt{\sigma_{ii}}$  — СКО  $X_i$ . Элемент  $\sigma_{ij}$ ,  $i \neq j$  называют ковариацией СВ  $X_i$  и  $X_j$  ( $\sigma_{ij} = \rho_{ij}\sigma_i\sigma_j$ ,  $\rho_{ij}$  — коэффициент корреляции  $X_i$  и  $X_j$ ).

**Плотность многомерного (n-мерного) нормального распределения (матричная запись)**

$$p_{\vec{X}}(\vec{x}) = \frac{1}{(\sqrt{2\pi})^n (\det \Sigma)^{\frac{1}{2}}} e^{-\frac{1}{2}(\vec{x}-\vec{m})\tilde{\Sigma}(\vec{x}-\vec{m})^T},$$

где  $\tilde{\Sigma} = \Sigma^{-1}$ .

**Плотность стандартного многомерного  $\Sigma = I$ ,  $\vec{m} = (0, \dots, 0)$  (n-мерного) нормального распределения.**

$$p_{X_1, \dots, X_n}(x_1, \dots, x_n) = \frac{1}{(\sqrt{2\pi})^n} e^{-\frac{1}{2}(x_1^2 + \dots + x_n^2)}.$$