

Вероятность, основные определения и примеры

§ 1. Предмет теории вероятностей

Теорией вероятностей называется раздел математики, изучающий *математические модели* экспериментов, исход которых не вполне однозначно определяется условиями опытов. Такие эксперименты называются *случайными опытами*.

Для более точного определения надо сказать, что теория вероятностей имеет дело лишь со случайными опытами, обладающими свойством *статистической устойчивости* или *устойчивости частот*. Это свойство описывается следующим образом. Рассмотрим случайный эксперимент и предположим, что идентичные условия проведения этого опыта и его повторение можно реализовать любое желаемое число раз. Такое повторение возможно представить себе не только реально физически осуществимым, а хотя бы мыслимым. Обозначим через A один из возможных исходов этого эксперимента. Повторим данный опыт n раз и обозначим через $n(A)$, $0 \leq n(A) \leq n$, число наступлений исхода A при этих n повторениях. Отношение

$$\frac{n(A)}{n}, \quad 0 \leq \frac{n(A)}{n} \leq 1,$$

называется *частотой* появления события (исхода) A , а свойство устойчивости частот заключается в том, что при больших значениях n частота появления события A при изменении n мало отличается от некоторого постоянного значения, которое называется *вероятностью события A* и обозначается

$$\Pr\{A\} \approx \frac{n(A)}{n}, \quad 0 \leq \Pr\{A\} \leq 1.$$

Данное определение называется *частотным* или *интуитивным* определением вероятности.

Например, многократное бросание симметричной монеты с двумя возможными исходами герб - решетка при каждом бросании, дает частоты выпадений герба, близкие к $1/2$. В данном случае для события A , означающего появление герба в одном испытании, нет сомнения в том, что его вероятность $\Pr\{A\} = 1/2$.

§ 2. Модель случайного опыта с конечным числом исходов

Рассмотрим опыт, N исходов которого обозначим символами $\omega_1, \omega_2, \dots, \omega_N$. Эти символы не обязательно являются числами и их физическая природа для нас не имеет значения.

Определение 1. Всевозможные N исходов опыта называются *элементарными событиями*, а их совокупность

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_N\} = \{\omega\}$$

называется *пространством* элементарных событий.

Определение 2. Каждому элементарному событию ω ставится в соответствие некоторое число $\Pr\{\omega\}$, называемое *вероятностью ω* . При этом числа $\Pr\{\omega_i\}$, $i = 1, 2, \dots, N$, удовлетворяют условиям

$$0 \leq \Pr\{\omega_i\} \leq 1, \quad \sum_{i=1}^N \Pr\{\omega_i\} = \sum_{\omega} \Pr\{\omega\} = 1.$$

Определение 3. Любое подмножество A пространства элементарных событий Ω , т.е. $A \subseteq \Omega$, называется *событием*. Событие $A = \Omega$ называется *достоверным*. Кроме того, введем и обозначим символом пустого множества \emptyset событие, которое не содержит элементарных событий и называется *невозможным* событием.

Определение 4. Вероятностью $\Pr\{A\}$ события A называется сумма вероятностей элементарных событий, входящих в A , иначе

$$\Pr\{A\} \stackrel{\text{def}}{=} \sum_{\omega \in A} \Pr\{\omega\}.$$

Для невозможного события \emptyset по определению полагаем $\Pr\{\emptyset\} \stackrel{\text{def}}{=} 0$.

Здесь и дальнейшем символ $\stackrel{\text{def}}{=}$ обозначает *равенство по определению*. Очевидно, что для любого события A вероятность $0 \leq \Pr\{A\} \leq 1$, а для достоверного события Ω вероятность $\Pr\{\Omega\} = 1$.

Пример. Пусть опыт Ω состоит в проведении трех испытаний, в каждом из которых регистрируется один из двух возможных исходов: успех, обозначаемый символом 1, или неудача, обозначаемая символом 0. Математическую модель этого опыта можно описать следующим образом.

- Общее число элементарных событий $N = 2^3 = 8$. Каждое элементарное событие ω есть двоичная (из 1 и 0) последовательность $\omega = (x_1, x_2, x_3)$, где $x_i = 1, 0$ обозначает исход (успех или неудачу) в i -ом, $i = 1, 2, 3$, испытании. Пространство элементарных событий имеет вид

$$\Omega = \{(0, 0, 0), (0, 0, 1), (0, 1, 0), (0, 1, 1), (1, 0, 0), (1, 0, 1), (1, 1, 0), (1, 1, 1)\},$$

т.е. $\omega_1 = (0, 0, 0)$, $\omega_2 = (0, 0, 1)$, \dots , $\omega_8 = (1, 1, 1)$.

- В качестве примера события рассмотрим событие A , состоящее в том, что *в трех испытаниях произойдет по крайней мере два успеха*. Это событие представляет собой совокупность из 4-х элементарных событий:

$$A = \{(0, 1, 1), (1, 0, 1), (1, 1, 0), (1, 1, 1)\}.$$

- Если всем элементарным событиям поставлены в соответствие одинаковые вероятности

$$\begin{aligned} \Pr\{(0, 0, 0)\} &= \Pr\{(0, 0, 1)\} = \Pr\{(0, 1, 0)\} = \Pr\{(0, 1, 1)\} = \\ &= \Pr\{(1, 0, 0)\} = \Pr\{(1, 0, 1)\} = \Pr\{(1, 1, 0)\} = \Pr\{(1, 1, 1)\} = \frac{1}{8}, \end{aligned}$$

то согласно определению 4 для вероятности введенного события A имеем

$$\Pr\{A\} = \Pr\{(0, 1, 1)\} + \Pr\{(1, 0, 1)\} + \Pr\{(1, 1, 0)\} + \Pr\{(1, 1, 1)\} = \frac{1}{8} + \frac{1}{8} + \frac{1}{8} + \frac{1}{8} = \frac{4}{8} = \frac{1}{2}.$$

Вероятностная модель этого примера очевидным образом обобщается на случай n испытаний, в каждом из которых регистрируется один из двух возможных исходов: успех, обозначаемый символом 1, или неудача, обозначаемая символом 0. Равновероятные элементарные события ω имеют вид

$$\omega = (x_1, x_2, \dots, x_n), \quad x_i = 1, 0, \quad i = 1, 2, \dots, n,$$

где вероятность каждого ω равна

$$\Pr\{\omega\} = \Pr\{(x_1, x_2, \dots, x_n)\} = \frac{1}{N} = \frac{1}{2^n}.$$

Такая модель называется моделью n испытаний Бернулли с $N = 2^n$ равновероятными исходами.

Рассмотрим дихотомическое (с возможными двоичными исходами 1 или 0) тестирования n пар однородных испытуемых, когда один из испытуемых в каждой паре становится контрольным (измерение "до"), а второй подвергается какой-либо *обработке*, например, *процедуре лечения, методике обучения или рекламе* (измерение "после"). Если сравнение этих измерений показывает их значимое отличие, то результатом дихотомического тестирования данной пары считается 1, в противном случае—0. Предполагается, что модель n испытаний Бернулли с $N = 2^n$ равновероятными исходами даёт адекватную вероятностную интерпретацию результатов тестирования n пар однородных испытуемых, если рассматриваемая обработка *не эффективна*. Эта модель позволяет разработать научно обоснованные методы принятия решения об эффективности обработки на основании результатов дихотомических наблюдений. Данная задача является предметом исследования для тесно связанного с теорией вероятностей раздела математики, называемого *математической статистикой*.

§ 3. Правила перевода

Первым этапом разработки теоретико - вероятностных моделей для применения в практических задачах является *перевод* с неформального языка, на котором обычно записывается условие задачи, на формальный язык математической модели случайного опыта. При этом следует учитывать два простых правила.

Правило 1. Пространство элементарных событий Ω есть совокупность всех мыслимых исходов опыта, при этом считается, что исходы регистрируются возможно более подробно.

Правило 2. Пусть $|A|$ обозначает число исходов (элементарных событий) при которых происходит событие A . Тогда, если $N = |\Omega|$ есть число всевозможных исходов (элементарных событий), то для события A вероятность

$$\Pr\{A\} = \frac{|A|}{|\Omega|} = \frac{|A|}{N}.$$

Если правило 2 применимо, то говорят что имеется задача на *классическую вероятность*, где вероятность события равна *отношению числа благоприятных исходов к числу всех исходов*.

Предыдущий пример модели трех испытаний Бернулли с равновероятными исходами иллюстрирует оба правила, т.е. при подсчете вероятности события A мы учли, что

$$N = |\Omega| = 2^3 = 8, \quad |A| = 4, \quad \Pr\{A\} = \frac{|A|}{N} = \frac{4}{8} = \frac{1}{2}.$$

В разделе "Комбинаторика и вероятность" излагаются некоторые методы подсчета числа элементарных событий в типичных ситуациях, встречающихся при решении задач, для которых применимо правило 2.

§ 4. Комбинаторика и вероятность

§ 4.1. Определения и примеры

Пусть N и n – произвольные натуральные числа а $[N] = \{1, 2, \dots, N\}$ обозначает множество всех целых чисел от 1 до N .

- 1) Мы выбираем *с возвращением* n элементов из множества $[N]$. Результатом выбора является N -ичная последовательность длины n , элементы которой принадлежат алфавиту $[N] = \{1, 2, \dots, N\}$. Число всех N -ичных последовательностей длины n , называемых n -последовательностями из алфавита $[N] = \{1, 2, \dots, N\}$, равно N^n .

Примеры.

- а) Число всех n -последовательностей из алфавита $\{0, 1, \dots, q-1\}$, называемых q -ичными n -последовательностями, равно q^n .
- б) Число всех двоичных n -последовательностей, т.е. n -последовательностей из алфавита $\{0, 1\}$, равно 2^n .
- в) Число комбинаций дат рождения у n людей равно 365^n .
- 2) Пусть $n \leq N$ и мы выбираем *без возвращения* n элементов из множества $[N]$. Результатом выбора является n -последовательность, элементы которой взяты из алфавита $[N] = \{1, 2, \dots, N\}$ и отличны друг от друга. Такая n -последовательность называется n -перестановкой множества $[N]$. Число всех n -перестановок обозначается символом $(N)_n$ или символом $P(N, n)$ и вычисляется по формуле

$$(N)_n = P(N, n) \stackrel{\text{def}}{=} N \cdot (N-1) \cdot (N-2) \cdot \dots \cdot (N-n+1).$$

Для частного случая $n = N$ используется обозначение

$$(N)_N = P(N, N) = N \cdot (N-1) \cdot (N-2) \cdot \dots \cdot 3 \cdot 2 \cdot 1 \stackrel{\text{def}}{=} N!.$$

Примеры

- а) Число "слов" длины 4, которые можно составить из неповторяющихся букв пятибуквенного алфавита $\{a, b, c, d, e\}$, равно

$$(5)_4 = P(5, 4) = 5 \cdot 4 \cdot 3 \cdot 2.$$

- б) Число *различных* дат рождения у n людей, где $2 \leq n \leq 365$ равно

$$(365)_n = P(365, n) = 365 \cdot 364 \cdot 363 \cdot \dots \cdot [365 - (n-1)].$$

- в) Вероятность того, что n случайно собравшихся людей имеют различные даты рождения равна

$$\pi_n = \frac{(365)_n}{(365)^n} = \left(1 - \frac{1}{365}\right) \cdot \left(1 - \frac{2}{365}\right) \cdot \dots \cdot \left(1 - \frac{n-1}{365}\right).$$

В частности, для $n = 30$ число $\pi_{30} = .2937$. Следовательно, вероятность совпадения дат рождения хотя бы у двоих среди $n = 30$ людей равна $1 - \pi_{30} = .7063$.

- 3) Пусть $n \leq N$. Число всех n -подмножеств множества $[N]$ обозначается через $\binom{N}{n}$. Если положить по определению $0! = 1$, то имеет место следующая формула

$$\binom{N}{n} = \binom{N}{N-n} = \frac{(N)_n}{n!} = \frac{N!}{n!(N-n)!}.$$

Примеры

- а) Пусть ребёнок играет с 8 карточками, на которых написаны следующие буквы:

$$\boxed{\text{О}} \quad \boxed{\text{О}} \quad \boxed{\text{О}} \quad \boxed{\text{О}} \quad \boxed{\text{К}} \quad \boxed{\text{К}} \quad \boxed{\text{Л}} \quad \boxed{\text{Т}}.$$

Он может выложить из этих карточек всего $8!$ последовательностей, из которых $4! \cdot 2! = 48$ последовательностей дают слово "ОКОЛОТОК". Заметим также, что среди $8!$ рассматриваемых последовательностей имеется лишь $\binom{8}{4} \binom{4}{2} \cdot 2!$ "различных слов". Следовательно, вероятность получить слово "ОКОЛОТОК" можно записать следующими двумя способами

$$\text{Pr}\{\text{"ОКОЛОТОК"}\} = \frac{4! \cdot 2!}{8!} = \frac{1}{\binom{8}{4} \binom{4}{2} \cdot 2!} = \frac{48}{8!} = 1.19 \times 10^{-3}.$$

Задача. Проведите аналогичные рассуждения для слов "ПСИХОЛОГИЯ" и "МАТЕМАТИКА"

- б) Каждое n -подмножество множества $[N]$ взаимно однозначно отображается в двоичную N - последовательность, содержащую единицы на позициях, соответствующих элементам данного n -подмножества. Поэтому число *всех подмножеств* множества $[N]$ совпадает с числом всех двоичных N - последовательностей, которое равно 2^N , и справедлива формула

$$\binom{N}{0} + \binom{N}{1} + \binom{N}{2} + \dots + \binom{N}{N} = \sum_{n=0}^{n=N} \binom{N}{n} = \sum_{n=0}^{n=N} \frac{N!}{n!(N-n)!} = 2^N.$$

- в) Пусть $0 \leq i \leq m \leq n < N$. Имеют место следующие утверждения

- Зафиксируем произвольное n -подмножество множества $[N]$. Тогда число m -подмножеств, i элементов которых принадлежат данному n -подмножеству, а $m-i$ элементов не принадлежат этому n -подмножеству, равно

$$\binom{n}{i} \binom{N-n}{m-i} \quad \text{и} \quad \sum_{i=0}^m \binom{n}{i} \binom{N-n}{m-i} = \binom{N}{m}.$$

Для написанных выше формул имеется следующая вероятностная интерпретация. Пусть множество $[N]$ состоит из n "счастливых" номеров и $N-n$ "несчастливых" номеров. Мы случайно *без возвращения* выбираем m номеров из множества $[N]$. Тогда вероятность того, что в нашу выборку попадут i "счастливых" и $m-i$ "несчастливых" номеров есть

$$\frac{\binom{n}{i} \binom{N-n}{m-i}}{\binom{N}{m}} = \binom{m}{i} \frac{(n)_i (N-n)_{m-i}}{(N)_m}.$$

А.Г. Дьячков: Вероятность, основные определения и примеры

Пример лотереи. Пусть $m = n = 6$, $N = 49$, $i = 0, 1, \dots, 6$. В лотерее "6 из 49" вероятность g_i угадывания i "счастливых шаров" вычисляется следующим образом

$$g_i = \frac{\binom{6}{i} \binom{43}{6-i}}{\binom{49}{6}}, \quad g_0 = .4360, \quad g_1 = .4130, \quad g_2 = .1324,$$

$$g_3 = .01765, \quad g_4 = 9.686 \times 10^{-4}, \quad g_5 = 1.845 \times 10^{-5}, \quad g_6 = 7.151 \times 10^{-8}.$$

В лотерее "6 из 49", лотерейный билет выигрывает денежный приз, если он содержит по крайней мере *три* номера "счастливых шаров". Вероятность получения такого "счастливого билета" есть

$$p = g_3 + g_4 + g_5 + g_6 = .0186.$$

– Зафиксируем произвольное m -подмножество множества $[N]$. Тогда число всех n -подмножеств, которые содержат данное m -подмножество, равно

$$\binom{N-m}{n-m} = \binom{N-m}{N-n}.$$

§ 4.2. Биномиальные вероятности

Пусть $N = N_1 + N_2$ и имеется N шаров, занумерованных числами от 1 до N . Шары, занумерованные числами от 1 до N_1 , имеют *белый* цвет, а остальные N_2 шаров являются *черными*.

Предположим, что из данного N -множества шаров выбираются случайно и с *возвращением* n шаров. Для любого $k = 0, 1, 2, \dots, n$, число n -последовательностей, содержащих k белых и $n - k$ черных шаров, равно

$$\binom{n}{k} N_1^k N_2^{n-k} \quad \text{и дробь} \quad \frac{\binom{n}{k} N_1^k N_2^{n-k}}{N^n} = \binom{n}{k} \left(\frac{N_1}{N}\right)^k \left(\frac{N_2}{N}\right)^{n-k}$$

есть *вероятность* получить при таком случайном выборе последовательность из k белых и $n - k$ черных шаров.

Определение. Зафиксируем целое число $n = 1, 2, \dots$ и произвольное число p , $0 < p < 1$. Числа

$$b_n(p, k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, 2, \dots, n,$$

называются *биномиальными вероятностями с параметрами* (n, p) .

Для случайного выбора объема n с возвращением вероятность получения k белых и $n - k$ черных шаров является биномиальной вероятностью с параметрами $(n, p = \frac{N_1}{N})$.

Примеры.

- 1) **Задача об отношениях предпочтения.** Пусть малая социальная группа объема $n + 1$ проводит (внутри себя) выборы лидера. Каждый член группы в своем протоколе голосования (ПГ), т.е. в списке из $n + 1$ участника, отмечает $m < n$ членов группы, исключая самого себя, которых он *предпочитает* остальным $n - m$ членам группы и считает кандидатами в лидеры.

Зафиксируем произвольного члена группы, которого назовем претендентом на лидерство (ПЛ). Тогда для любого из остальных n участников выборов имеем:

- а) $N = \binom{n}{m}$ —общее число способов заполнить ПГ;
- б) $N_1 = \binom{n-1}{m-1}$ —число способов заполнить ПГ, в котором отмечен ПЛ;
- в) $N_2 = \binom{n-1}{m}$ —число способов заполнить ПГ, в котором ПЛ не отмечен.

Легко проверить, что $N = N_1 + N_2$. Для данных параметров в качестве модели *случайных отношений предпочтения* в испытуемой группе объема $n + 1$ будем использовать введенную выше модель выборки с возвращением объема n . Следовательно, если отношения предпочтения в испытуемой группе случайны, то вероятность ПЛ быть отмеченным в k ПГ и быть неотмеченным в $(n - k)$ ПГ является биномиальной вероятностью вида

$$\begin{aligned} b_n \left(\frac{N_1}{N}, k \right) &= \binom{n}{k} \left(\frac{N_1}{N} \right)^k \left(\frac{N_2}{N} \right)^{n-k} = \\ &= \binom{n}{k} \left(\frac{\binom{n-1}{m-1}}{\binom{n}{m}} \right)^k \left(\frac{\binom{n-1}{m}}{\binom{n}{m}} \right)^{n-k} = \binom{n}{k} \left(\frac{m}{n} \right)^k \left(\frac{n-m}{n} \right)^{n-k}, \quad k = 0, 1, \dots, n, \end{aligned}$$

Кроме того, для модели случайных отношений предпочтения число m можно рассматривать в качестве *среднего числа* ПГ по испытуемой группе, в которых отмечен ПЛ. Пусть по итогам голосования ПЛ оказался отмеченным в K ПГ, где число K удовлетворяет условиям $m \ll K \leq n$. На основании такого результата выборов мы можем принять *решение* о том, что отношения предпочтения в данной малой социальной группе *неслучайны*. Тогда число

$$\alpha = \sum_{k=K}^n \binom{n}{k} \left(\frac{m}{n} \right)^k \left(\frac{n-m}{n} \right)^{n-k}$$

может рассматриваться в качестве *вероятности ошибки* данного решения.

- 2) Задача о лотерее "6 из 49". Если купить один лотерейный билет, то ранее вычисленная вероятность того, что он окажется "счастливым" равна .0186. Пусть мы покупаем n лотерейных билетов и случайно отмечаем 6 номеров в каждом из них. Обозначим через P_n вероятность того, что *хотя бы один из этих n билетов будет "счастливым"* вычисляется по формуле

$$P_n = \sum_{k=1}^n \binom{n}{k} (.0186)^k (.9814)^{n-k} = 1 - (.9814)^n.$$

Для оценки количества покупаемых билетов n , которое гарантирует вероятность $P_n \geq .95$, можем написать следующую цепочку эквивалентных неравенств

$$1 - (.9814)^n \geq .95 \Leftrightarrow (.9814)^n \leq .05 \Leftrightarrow n \ln .9814 \leq \ln .05 \Leftrightarrow n \geq \frac{\ln .05}{\ln .9814} = 159.55.$$

Таким образом, если мы хотим с надежностью $\geq 95\%$ быть уверенными, что по крайней мере один из наших n лотерейных билетов будет "счастливым", то надо покупать $n \geq 160$ билетов.

§ 5. Модель (n, p) - испытаний Бернулли

Пусть $n = 1, 2, \dots$ есть число испытаний, в каждом из которых регистрируется один из двух возможных исходов: *успех*, обозначаемый символом 1, или *неудача*, обозначаемая символом 0. Пусть p , $0 < p < 1$, - фиксированный параметр.

Модель (n, p) - испытаний Бернулли задается пространством $\Omega = \{\omega\}$, состоящим из $N = 2^n$ элементарных событий

$$\omega = (x_1, x_2, \dots, x_n), \quad x_i = 1, 0, \quad i = 1, 2, \dots, n,$$

где $x_i = 1, 0$ обозначает исход (успех или неудачу) в i -ом, $i = 1, 2, \dots, n$, испытании. Вероятности этих элементарных событий имеют вид:

$$\Pr\{\omega\} = \Pr\{(x_1, x_2, \dots, x_n)\} \stackrel{\text{def}}{=} p^k \cdot (1-p)^{n-k}, \quad \text{если } \sum_{i=1}^n x_i = k, \quad 0 \leq k \leq n. \quad (1)$$

Отметим, что при $p = 1 - p = 1/2$ в модели $(n, 1/2)$ - испытаний Бернулли всем 2^n элементарным событиям поставлены в соответствие одинаковые вероятности, равные $1/2^n$.

Пример. При $n = 3$ число $N = 2^3 = 8$. Из (1) получаем следующие формулы для вероятностей восьми элементарных событий в модели $(3, p)$ - испытаний Бернулли:

$$\begin{aligned} \Pr\{(0, 0, 0)\} &= (1-p)^3 & \Pr\{(0, 0, 1)\} &= \Pr\{(0, 1, 0)\} = \Pr\{(1, 0, 0)\} = p \cdot (1-p)^2, \\ \Pr\{(0, 1, 1)\} &= \Pr\{(1, 0, 1)\} = \Pr\{(1, 1, 0)\} = p^2 \cdot (1-p), & \Pr\{(1, 1, 1)\} &= p^3. \end{aligned}$$

Двоичным символам $x = 1, 0$ сопоставим числа

$$\Pr\{x\} \stackrel{\text{def}}{=} \begin{cases} p, & \text{если } x = 1, \\ 1-p, & \text{если } x = 0, \end{cases}$$

которые удобно интерпретировать как вероятности успеха или неудачи при однократном испытании Бернулли. Используя эти обозначения, вероятности (1) при n -кратном испытании Бернулли можно представить в виде произведения вероятностей

$$\Pr\{\omega\} = \Pr\{(x_1, x_2, \dots, x_n)\} = \Pr\{x_1\} \cdot \Pr\{x_2\} \cdot \dots \cdot \Pr\{x_n\}.$$

Данная запись, в частности, позволяет проверить, что сумма всех 2^n чисел, задаваемых формулами (1), равна

$$\begin{aligned} \sum_{\omega \in \Omega} \Pr\{\omega\} &= \left(\sum_{x_1=0}^1 \Pr\{x_1\} \right) \cdot \left(\sum_{x_2=0}^1 \Pr\{x_2\} \right) \cdot \dots \cdot \left(\sum_{x_n=0}^1 \Pr\{x_n\} \right) = \\ &= [p + (1-p)] \cdot [p + (1-p)] \cdot \dots \cdot [p + (1-p)] = 1, \end{aligned}$$

т.е. числа (1) являются вероятностями.

Введём величину $S_n \stackrel{\text{def}}{=} \sum_{i=1}^n x_i$, $0 \leq S_n \leq n$, равную числу единичных символов в последовательности $\omega = (x_1, x_2, \dots, x_n)$. Поскольку единицы соответствуют успехам в испытаниях, а нули – неудачам, то значение S_n представляет собой *число успехов* в элементарном событии ω , а разность $n - S_n$ есть число неудач в элементарном событии ω . Для фиксированного целого числа $k = 0, 1, \dots, n$ рассмотрим

$$\text{событие } \{S_n = k\}, \text{ состоящее из всех } \binom{n}{k} = \frac{n!}{k! \cdot (n-k)!}$$

элементарных событий $\omega = (x_1, x_2, \dots, x_n)$, в которых число единиц $\sum_{i=1}^n x_i$ равно k . Событие $\{S_n = k\}$ означает, что в n испытаниях Бернулли произошло k успехов. Если символом $b_n(p, k)$ обозначить вероятность события $\{S_n = k\}$, то из (1) следует:

$$\begin{aligned} b_n(p, k) &= \Pr\{S_n = k\} = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k} = \\ &= \frac{n!}{k! \cdot (n-k)!} \cdot p^k \cdot (1-p)^{n-k}, \quad k = 0, 1, \dots, n. \end{aligned} \quad (2)$$

Соотношения (2) описывают важную модификацию модели (n, p) -испытаний Бернулли, в которой пространство элементарных событий $\Omega = \{0, 1, 2, \dots, n\}$ представляет собой множество из $N = n + 1$ возможных значений для числа успехов в n испытаниях. Это соответствует типичной для приложений ситуации, когда экспериментатор регистрирует лишь общее количество успехов в n испытаниях и не интересуется в каких конкретно испытаниях происходили успехи или неудачи.

Пример. При $n = 3$ число $N = 3 + 1 = 4$ и из (2) получаем следующие формулы для вероятностей четырёх элементарных событий:

$$\begin{aligned} b_3(p, 0) &= \Pr\{S_3 = 0\} = (1-p)^3, & b_3(p, 1) &= \Pr\{S_3 = 1\} = 3p \cdot (1-p)^2, \\ b_3(p, 2) &= \Pr\{S_3 = 2\} = 3p^2 \cdot (1-p), & b_3(p, 3) &= \Pr\{S_3 = 3\} = p^3. \end{aligned}$$

Отметим, что известная из курса математического анализа формула *бинома Ньютона*

$$(a+b)^n = \sum_{k=0}^n \binom{n}{k} \cdot a^k \cdot b^{n-k} = \sum_{k=0}^n \frac{n!}{k! \cdot (n-k)!} \cdot a^k \cdot b^{n-k}$$

позволяет проверить, что сумма $n + 1$ чисел, задаваемых (2), равна 1:

$$\sum_{k=0}^n b_n(p, k) = \sum_{k=0}^n \frac{n!}{k! \cdot (n-k)!} \cdot p^k \cdot (1-p)^{n-k} = [p + (1-p)]^n = 1,$$

Числа $b_n(p, k)$, $k = 0, 1, 2, \dots, n$, называются *биномиальными вероятностями*. Свойства биномиальных вероятностей изучаются в Задании 1, где также анализируются необходимые для решения прикладных задач *таблицы* этих вероятностей.

§ 6. Операции над событиями, закон сложения вероятностей

С событиями, которые мы определили как подмножества пространства $\Omega = \{\omega\}$ элементарных событий ω , связывают три теоретико-множественные операции: *дополнение*, *пересечение* и *объединение*.

Приведём традиционную теоретико-вероятностную терминологию, связанную с этими операциями и их обозначениями в теории множеств.

- Если $\omega \in A$ то говорят, что *наступило* событие A .
- Операция *дополнения* для события \bar{A} определяет событие, состоящее из элементарных событий $\omega \in \Omega$, не входящих в событие A . Говорят что $\bar{A} \subseteq \Omega$ означает событие, состоящее в *ненаступлении* события A . Событие \bar{A} называют также *отрицанием* события A .
- Символ *пересечения* (A, B) событий A и B определяет событие, состоящее из элементарных событий $\omega \in \Omega$, входящих *и в A и в B* . Говорят, что (A, B) означает событие, состоящее в *одновременном наступлении* событий A и B .
- Символ *объединения* $A \cup B$ событий A и B определяет событие, состоящее из элементарных событий $\omega \in \Omega$, входящих *либо в A либо в B* . Говорят, что $A \cup B$ обозначает событие, состоящее в том, что *произошло хотя бы одно* из событий A или B .
- Символ \emptyset определяет пустое множество или *невозможное* событие.
- Символ Ω определяет множество, состоящее из всех точек, которое называется *достоверным* событием. Очевидно, $\bar{\Omega} = \emptyset$.
- Символ подмножества $A \subseteq B$ в теории вероятностей обозначает, что из осуществления события A *необходимо следует* наступление события B .
- Если события A и B не пересекаются, т.е. $(A, B) = \emptyset$, то эти события называются *несовместимыми* (не могут наступить одновременно).
- Если $(A, B) = \emptyset$, то символ $A + B$ обозначает событие, состоящее в том, что *наступит хотя бы одно из несовместимых* событий A или B .

Свойства.

- 1) Если события A и B несовместимы, т.е. $(A, B) = \emptyset$, то справедлива формула

$$\text{Pr}\{A + B\} = \text{Pr}\{A\} + \text{Pr}\{B\}.$$

Эта формула называется *законом сложения вероятностей*.

- 2) Любое событие A несовместимо с \bar{A} . Следовательно, $A + \bar{A} = \Omega$ и $\text{Pr}\{\bar{A}\} = 1 - \text{Pr}\{A\}$.
- 3) Для любой пары событий A и B событие (A, B) несовместимо с событием (A, \bar{B}) . При этом $(A, B) + (A, \bar{B}) = A$ и вероятность $\text{Pr}\{A\} = \text{Pr}\{(A, B)\} + \text{Pr}\{(A, \bar{B})\}$.

§ 7. Модель (2×2) -таблицы

Используя данные выше обозначения и их свойства, мы вводим важную для приложений математическую модель случайного опыта, называемую *моделью (2×2) -таблицы* и применяемую для описания *связи* (или взаимодействия) *признаков*.

Опыт состоит в *одновременном* тестировании испытуемого по двум признакам \mathcal{A} и \mathcal{B} . Например, \mathcal{A} – вес, а \mathcal{B} – объём талии или \mathcal{A} – рост, а \mathcal{B} – объём бёдер. Предположим, что признак \mathcal{A} (признак \mathcal{B}) может быть зарегистрирован в одном из двух состояний, интерпретируемых как событие A или его отрицание \bar{A} (событие B или его отрицание \bar{B}). В итоге такого одновременного тестирования наступает одно из четырех элементарных событий (A, B) , (\bar{A}, B) , (A, \bar{B}) или (\bar{A}, \bar{B}) , которые вместе с их вероятностями записываются в виде (2×2) -таблиц

$$\left\| \begin{array}{c|c} (A, B) & (\bar{A}, B) \\ \hline (A, \bar{B}) & (\bar{A}, \bar{B}) \end{array} \right\| \quad \left\| \begin{array}{c|c} \Pr\{(A, B)\} & \Pr\{(\bar{A}, B)\} \\ \hline \Pr\{(A, \bar{B})\} & \Pr\{(\bar{A}, \bar{B})\} \end{array} \right\|.$$

Соотношения между элементами (2×2) -таблиц, аналогичные свойству 3, имеют форму *расширенных (2×2) -таблиц*

$$\left(\begin{array}{c} \mathcal{B} = B \\ \mathcal{B} = \bar{B} \\ \Sigma \end{array} \left\| \begin{array}{c|c} \mathcal{A} = A & \mathcal{A} = \bar{A} \\ \hline (A, B) & (\bar{A}, B) \\ (A, \bar{B}) & (\bar{A}, \bar{B}) \end{array} \right\| \begin{array}{c} \Sigma \\ B = (A, B) + (\bar{A}, B) \\ \bar{B} = (A, \bar{B}) + (\bar{A}, \bar{B}) \\ \Omega = (A, B) + (A, \bar{B}) + (\bar{A}, B) + (\bar{A}, \bar{B}) \end{array} \right) \left(\begin{array}{c} \mathcal{B} = B \\ \mathcal{B} = \bar{B} \\ \Sigma \end{array} \left\| \begin{array}{c|c} \mathcal{A} = A & \mathcal{A} = \bar{A} \\ \hline \Pr\{(A, B)\} & \Pr\{(\bar{A}, B)\} \\ \Pr\{(A, \bar{B})\} & \Pr\{(\bar{A}, \bar{B})\} \\ \Pr\{A\} & \Pr\{\bar{A}\} \end{array} \right\| \begin{array}{c} \Sigma \\ \Pr\{B\} \\ \Pr\{\bar{B}\} \\ 1 \end{array} \right), \quad (1)$$

где

$$\begin{aligned} \Pr\{A\} &= \Pr\{(A, B)\} + \Pr\{(A, \bar{B})\}, & \Pr\{\bar{A}\} &= \Pr\{(\bar{A}, B)\} + \Pr\{(\bar{A}, \bar{B})\}, \\ \Pr\{B\} &= \Pr\{(A, B)\} + \Pr\{(\bar{A}, B)\}, & \Pr\{\bar{B}\} &= \Pr\{(A, \bar{B})\} + \Pr\{(\bar{A}, \bar{B})\}, \\ \Pr\{A\} + \Pr\{\bar{A}\} &= \Pr\{B\} + \Pr\{\bar{B}\} = 1. \end{aligned}$$

Таблица (1) представляет собой удобный способ записи модели (2×2) -таблицы.

Пусть для каждого из n испытуемых проведено одновременное тестирование по признакам \mathcal{A} и \mathcal{B} . Пусть символами $n(A)$, $n(\bar{A})$, $n(B)$, $n(\bar{B})$, $n(A, B)$, $n(\bar{A}, B)$, $n(A, \bar{B})$ и $n(\bar{A}, \bar{B})$ обозначают числа наступлений соответствующих событий в n опытах. Например, число

$$n(A) = n(A, B) + n(A, \bar{B}), \quad 0 \leq n(A) \leq n,$$

обозначает количество испытуемых, для которых у признака \mathcal{A} зарегистрировано событие A . Число $n(A, \bar{B})$, $0 \leq n(A, \bar{B}) \leq n(A)$, есть количество испытуемых, для которых у признака \mathcal{A} зарегистрировано событие A и одновременно у признака \mathcal{B} зарегистрировано событие \bar{B} . Очевидно, что

$$n = n(A) + n(\bar{A}) = n(B) + n(\bar{B}) = n(A, B) + n(\bar{A}, B) + n(A, \bar{B}) + n(\bar{A}, \bar{B}).$$

Указанные числа изображаются в виде расширенной (2×2) -таблицы

$$\left| \begin{array}{c} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left| \begin{array}{c} \mathcal{A} = \mathcal{A} \\ n(\mathcal{A}, \mathcal{B}) \\ n(\mathcal{A}, \bar{\mathcal{B}}) \\ n(\mathcal{A}) = n(\mathcal{A}, \mathcal{B}) + n(\mathcal{A}, \bar{\mathcal{B}}) \end{array} \right| \left| \begin{array}{c} \mathcal{A} = \bar{\mathcal{A}} \\ n(\bar{\mathcal{A}}, \mathcal{B}) \\ n(\bar{\mathcal{A}}, \bar{\mathcal{B}}) \\ n(\bar{\mathcal{A}}) = n(\bar{\mathcal{A}}, \mathcal{B}) + n(\bar{\mathcal{A}}, \bar{\mathcal{B}}) \end{array} \right\| \left| \begin{array}{c} \Sigma \\ n(\mathcal{B}) = n(\mathcal{A}, \mathcal{B}) + n(\bar{\mathcal{A}}, \mathcal{B}) \\ n(\bar{\mathcal{B}}) = n(\mathcal{A}, \bar{\mathcal{B}}) + n(\bar{\mathcal{A}}, \bar{\mathcal{B}}) \\ n(\mathcal{A}) + n(\bar{\mathcal{A}}) = n(\mathcal{B}) + n(\bar{\mathcal{B}}) \end{array} \right|$$

называемой (2×2) -*таблицей сопряжённости признаков*. Числовые данные (2×2) -таблицы сопряжённости используются для решения двух нижеформулируемых задач статистического анализа о связи (взаимодействии) признаков \mathcal{A} и \mathcal{B} .

- 1) Пользуясь соображениями *здравого смысла*, сделать *качественный вывод* либо о наличии прямой (обратной) связи между признаками \mathcal{A} и \mathcal{B} , либо об отсутствии связи между \mathcal{A} и \mathcal{B} .
- 2) Если в первой задаче принято решение о наличии прямой (обратной) связи между признаками \mathcal{A} и \mathcal{B} , то постановка второй задачи состоит в том, чтобы на основе разработанной в теории вероятностей адекватной модели случайного опыта получить *количественную* оценку для ошибки этого качественного решения.

Пример. Пусть число испытуемых $n = 27$. Приведём для сравнения записанные в форме (2×2) -таблиц сопряжённости признаков *два варианта* экспериментальных данных, которые могли бы быть получены для *двух разных пар* признаков.

$$\left| \begin{array}{c} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left| \begin{array}{c} \mathcal{A} = \mathcal{A} \\ 10 \\ 4 \\ n(\mathcal{A}) = 10 + 4 = 14 \end{array} \right| \left| \begin{array}{c} \mathcal{A} = \bar{\mathcal{A}} \\ 3 \\ 10 \\ n(\bar{\mathcal{A}}) = 3 + 10 = 13 \end{array} \right\| \left| \begin{array}{c} \Sigma \\ n(\mathcal{B}) = 10 + 3 = 13 \\ n(\bar{\mathcal{B}}) = 4 + 10 = 14 \\ n = n(\mathcal{A}) + n(\bar{\mathcal{A}}) = n(\mathcal{B}) + n(\bar{\mathcal{B}}) = 27 \end{array} \right|$$

Таблица 1.

$$\left| \begin{array}{c} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left| \begin{array}{c} \mathcal{A} = \mathcal{A} \\ 7 \\ 7 \\ n(\mathcal{A}) = 7 + 7 = 14 \end{array} \right| \left| \begin{array}{c} \mathcal{A} = \bar{\mathcal{A}} \\ 6 \\ 7 \\ n(\bar{\mathcal{A}}) = 6 + 7 = 13 \end{array} \right\| \left| \begin{array}{c} \Sigma \\ n(\mathcal{B}) = 7 + 6 = 13 \\ n(\bar{\mathcal{B}}) = 7 + 7 = 14 \\ n = n(\mathcal{A}) + n(\bar{\mathcal{A}}) = n(\mathcal{B}) + n(\bar{\mathcal{B}}) = 27 \end{array} \right|$$

Таблица 2.

В следующем разделе рассматривается теоретико-вероятностный подход к вопросу о связи событий, с помощью которого в математической статистике разработаны рецепты анализа числовых данных из (2×2) -таблиц сопряжённости признаков. Опираясь на частотное определение условной вероятности, лежащее в основе этого подхода, можно будет сделать качественные выводы о том, что числовые данные таблицы 1 показывают наличие прямой связи между соответствующими признаками, а числовые данные таблицы 2 свидетельствуют об отсутствии связи.

§ 8. Связь событий, условная вероятность, независимость

В теории вероятностей характеристикой связи событий A и B служит *условная вероятность* $\Pr\{A|B\}$ события A при условии B , определяемая как

$$\Pr\{A|B\} \stackrel{\text{def}}{=} \frac{\Pr\{(A, B)\}}{\Pr\{B\}}. \quad (1)$$

Это определение имеет смысл лишь в случае, если $\Pr\{B\} \neq 0$.

Применим интуитивное представление о вероятности, связанное с частотами, для того, чтобы оправдать определение величины $\Pr\{A|B\}$ из (1) как условной вероятности осуществления события A при условии наступления события B . Используя обозначения предыдущего раздела, назовём *условной частотой* события A при условии, что событие B наступило, отношение

$$\frac{n(A, B)}{n(B)} = \frac{n(A, B)}{n(A, B) + n(\bar{A}, B)} = \frac{n(A, B)/n}{n(B)/n}, \quad (2)$$

т.е. частоту события A , вычисленную не по совокупности всех n экспериментов, а лишь по совокупности тех $n(B)$ экспериментов, в которых наступило событие B . При больших значениях n левая часть равенства (2) интерпретируется как приближённое значение условной вероятности $\Pr\{A|B\}$ наступления события A при условии, что B наступило, а именно:

$$\text{отношение } \frac{n(A, B)}{n(B)} \approx \Pr\{A|B\}.$$

При этом в правой части равенства (2)

$$\text{отношение } \frac{n(A, B)}{n} \approx \Pr\{(A, B)\}, \quad \text{а отношение } \frac{n(B)}{n} \approx \Pr\{B\}.$$

Изложенные соображения мотивируют определение условной вероятности (1).

Естественно сказать, что событие A *не зависит* от события B , если условная вероятность события A при условии B равна безусловной вероятности события A , т.е.

$$\Pr\{A|B\} = \Pr\{A\}. \quad (3)$$

Пример. Рассмотрим числа $n(A, B)$, $n(\bar{A}, B)$, $n(A, \bar{B})$ и $n(\bar{A}, \bar{B})$ из таблиц 1 и 2 предыдущего раздела и проведем сравнение соответствующих условных и безусловных частот, получаемых по данным числам. Например, для условной частоты события A при условии B и безусловной частоты события A таблица 1 даёт

$$\frac{n(A, B)}{n(B)} = \frac{10}{13} = 0.769 \approx \Pr\{A|B\} \quad \text{и} \quad \frac{n(A)}{n} = \frac{14}{27} = 0.519 \approx \Pr\{A\}.$$

Эти условная и безусловная частоты значительно отличаются друг от друга. Для таблицы 2 те же самые условная и безусловная частоты есть

$$\frac{n(A, B)}{n(B)} = \frac{7}{13} = 0.538 \approx \Pr\{A|B\} \quad \text{и} \quad \frac{n(A)}{n} = \frac{14}{27} = 0.519 \approx \Pr\{A\}.$$

Их отличие друг от друга значительно меньше, чем для таблицы 1. Аналогичные результаты сравнения справедливы и для остальных трёх условных частот, отвечающих условным вероятностям $\Pr\{\bar{A}|B\}$, $\Pr\{A|\bar{B}\}$ и $\Pr\{\bar{A}|\bar{B}\}$. Следовательно, по данным таблицы 1 можно сделать качественный вывод о наличии связи признаков \mathcal{A} и \mathcal{B} , т.е. отвергнуть гипотезу об их независимости (отсутствии связи), а на основании данных таблицы 2 этого сделать нельзя.

С помощью определения условной вероятности (1) и определения независимости событий по формуле (3) получаем, что для независимых событий $\Pr\{(A, B)\} = \Pr\{A\} \cdot \Pr\{B\}$. Следовательно, если A не зависит от B , то и B не зависит от A , поскольку последнее равенство симметрично относительно A и B . Поэтому принимается следующее

Определение 1. События A и B называются *независимыми*, если выполнено равенство

$$\Pr\{(A, B)\} = \Pr\{A\} \cdot \Pr\{B\}. \quad (4)$$

Замечание 1. Формула (4) представляет несколько более общее определение независимости, поскольку не предполагает, что $\Pr\{B\} > 0$.

Определение 2. Модель (2×2) -таблицы называется *моделью (2×2) -таблицы для независимых признаков*, если вероятность элементарного исхода $\Pr\{(A, B)\}$ задается равенством (4), а вероятности остальных трёх элементарных исходов $\Pr\{(\bar{A}, B)\}$, $\Pr\{(A, \bar{B})\}$ и $\Pr\{(\bar{A}, \bar{B})\}$ также определяются как *произведения* соответствующих вероятностей.

Замечание 2. Пусть p , $0 < p < 1$, - фиксированный параметр. Тогда модель (2×2) -таблицы для независимых признаков, в которой

$$\Pr\{A\} = \Pr\{B\} = p, \quad \text{и} \quad \Pr\{\bar{A}\} = \Pr\{\bar{B}\} = 1 - p,$$

представляет собой модель $(2, p)$ -испытаний Бернулли. Отметим, что используя введённое понятие независимости, мы можем сказать, что общая модель (n, p) -испытаний Бернулли является последовательностью из n *независимых испытаний*, где в каждом испытании происходит либо "успех" с одной и той же вероятностью p , либо "неудача" с одной и той же вероятностью $1 - p$.

Свойства.

- 1) *Достоверное событие Ω и невозможное событие \emptyset независимы с любым событием A .*
- 2) *Если события A и B независимы, то события \bar{A} и B также независимы.*
- 3) *Из независимости событий A и B следует независимость событий \bar{A} и \bar{B} .*
- 4) *Модель (2×2) -таблицы является моделью (2×2) -таблицы для независимых признаков тогда и только тогда, когда выполнено условие (4).*

Первое свойство проверяется непосредственно по формуле (4), полагая в ней сначала $B = \Omega$, а затем $B = \emptyset$. Третье и четвёртое свойства есть очевидные следствия второго свойства, которое доказывается следующим образом:

$$\begin{aligned} \Pr\{(\bar{A}, B)\} &= \Pr\{B\} - \Pr\{(A, B)\} = \Pr\{B\} - \Pr\{(A, B)\} = \\ &= \Pr\{B\} - \Pr\{A\} \cdot \Pr\{B\} = \Pr\{B\} \cdot (1 - \Pr\{A\}) = \Pr\{B\} \cdot \Pr\{\bar{A}\}. \end{aligned}$$

Рассмотрим для сравнения два примера моделей (2×2) -таблиц:

$$\left| \begin{array}{l} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \mathcal{A} \\ \Pr\{(A, B)\} = 1/4 \\ \Pr\{(A, \bar{B})\} = 1/4 \\ \Pr\{A\} = 1/2 \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \bar{\mathcal{A}} \\ \Pr\{(\bar{A}, B)\} = 1/4 \\ \Pr\{(\bar{A}, \bar{B})\} = 1/4 \\ \Pr\{\bar{A}\} = 1/2 \end{array} \right\| \left\| \begin{array}{l} \Sigma \\ \Pr\{B\} = 1/2 \\ \Pr\{\bar{B}\} = 1/2 \\ 1 \end{array} \right\|$$

$$\left| \begin{array}{l} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \mathcal{A} \\ \Pr\{(A, B)\} = 1/2 \\ \Pr\{(A, \bar{B})\} = 0 \\ \Pr\{A\} = 1/2 \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \bar{\mathcal{A}} \\ \Pr\{(\bar{A}, B)\} = 0 \\ \Pr\{(\bar{A}, \bar{B})\} = 1/2 \\ \Pr\{\bar{A}\} = 1/2 \end{array} \right\| \left\| \begin{array}{l} \Sigma \\ \Pr\{B\} = 1/2 \\ \Pr\{\bar{B}\} = 1/2 \\ 1 \end{array} \right\|$$

Первая модель есть частный случай модели (2×2) -таблицы для независимых признаков. Она эквивалентна модели $(2, 1/2)$ -испытаний Бернулли. Вторая модель описывает сильную прямую связь признаков, когда условная вероятность

$$\Pr\{A|B\} = \frac{\Pr\{(A, B)\}}{\Pr\{B\}} = \frac{1/2}{1/2} = 1, \quad \Pr\{B|A\} = \frac{\Pr\{(A, B)\}}{\Pr\{A\}} = \frac{1/2}{1/2} = 1.$$

Отметим, что безусловные вероятности событий (состояний) $\Pr\{A\} = \Pr\{B\} = 1/2$ в обеих моделях являются одинаковыми.

§ 9. Гипергеометрические вероятности для (2×2) -таблиц сопряжённости в случае независимых признаков

Приведём список всех 14 вариантов (2×2) -таблицы сопряжённости

$$\left| \begin{array}{l} \mathcal{B} = \mathcal{B} \\ \mathcal{B} = \bar{\mathcal{B}} \\ \Sigma \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \mathcal{A} \\ n(A, B) \\ n(A, \bar{B}) \\ n(A) = n(A, B) + n(A, \bar{B}) \end{array} \right\| \left\| \begin{array}{l} \mathcal{A} = \bar{\mathcal{A}} \\ n(\bar{A}, B) \\ n(\bar{A}, \bar{B}) \\ n(\bar{A}) = n(\bar{A}, B) + n(\bar{A}, \bar{B}) \end{array} \right\| \left\| \begin{array}{l} \Sigma \\ n(B) = n(A, B) + n(\bar{A}, B) \\ n(\bar{B}) = n(A, \bar{B}) + n(\bar{A}, \bar{B}) \\ n(A) + n(\bar{A}) = n(B) + n(\bar{B}) \end{array} \right\|$$

которые возможны в опытах с $n = 27$ испытуемыми, если фиксированы значения $n(A) = 14$ и $n(B) = 13$:

$$\left| \begin{array}{c|c|c} 13-i & i = n(\bar{A}, B) & 13 \\ \hline i+1 & 13-i & 14 \\ \hline 14 & 13 & 27 \end{array} \right| = \left| \begin{array}{c|c|c} 13 & 0 & 13 \\ \hline 1 & 13 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 12 & 1 & 13 \\ \hline 2 & 12 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 11 & 2 & 13 \\ \hline 3 & 11 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|,$$

$$\left| \begin{array}{c|c|c} 10 & 3 & 13 \\ \hline 4 & 10 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 9 & 4 & 13 \\ \hline 5 & 9 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 8 & 5 & 13 \\ \hline 6 & 8 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 7 & 6 & 13 \\ \hline 7 & 7 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|,$$

$$\left| \begin{array}{c|c|c} 6 & 7 & 13 \\ \hline 8 & 6 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 5 & 8 & 13 \\ \hline 9 & 5 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 4 & 9 & 13 \\ \hline 10 & 4 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|, \quad \left| \begin{array}{c|c|c} 3 & 10 & 13 \\ \hline 11 & 3 & 14 \\ \hline 14 & 13 & 27 \end{array} \right|$$

| | | | | | | | | |
|----|----|----|----|----|----|----|----|----|
| 2 | 11 | 13 | 1 | 12 | 13 | 0 | 13 | 13 |
| 12 | 2 | 14 | 13 | 1 | 14 | 14 | 0 | 14 |
| 14 | 13 | 27 | 14 | 13 | 27 | 14 | 13 | 27 |

Каждый вариант идентифицируется числом $n(\bar{A}, B) = i$, где $i = 0, 1, \dots, 13$.

Здравый смысл подсказывает, что если в результате опытов с $n = 27$ испытуемыми будет получена одна из первых четырёх-пяти (или одна из последних четырёх-пяти) таблиц данного списка, то можно принять более или менее надёжное решение о наличии прямой (обратной) связи между признаками, т.е. сделать вывод о том, что отсутствию связи не подтверждается. В остальных случаях, видимо, можно считать, что эксперименты подтверждают отсутствие связи. Количественную оценку ошибки решения здравого смысла можно получить на основе теории вероятностей, а именно: *если признаки независимы, то можно показать, что условная вероятность*

$$\Pr\{n(\bar{A}, B) = i \mid n(A) = 14, n(B) = 13\} = \frac{\binom{13}{i} \binom{14}{13-i}}{\binom{27}{13}}, \quad i = 0, 1, \dots, 13.$$

Эти числа называются *гипергеометрическими вероятностями*, которые в общем случае задаются формулами:

$$Q_i(M_1, M_2, m) \stackrel{\text{def}}{=} \binom{M_1}{i} \cdot \binom{M_2}{m-i} / \binom{M_1 + M_2}{m}, \quad 0 \leq i \leq m \leq M_1 \leq M_2.$$

При этом $\sum_{i=1}^m Q_i(M_1, M_2, m) = 1$.

Непосредственно или по таблицам вычислим нижние α_k^- , $k = 2, 3, 4$, и верхние α_k^+ , $k = 8, 9, 10$, "хвосты" гипергеометрических вероятностей:

$$\alpha_k^- = \Pr\{n(\bar{A}, B) \leq k \mid n(A) = 14, n(B) = 13\} = \sum_{i=0}^k \frac{\binom{13}{i} \binom{14}{13-i}}{\binom{27}{13}} = \begin{cases} .0014, & \text{если } k = 2, \\ .016, & \text{если } k = 3, \\ .087, & \text{если } k = 4, \end{cases}$$

$$\alpha_k^+ = \Pr\{n(\bar{A}, B) \geq k \mid n(A) = 14, n(B) = 13\} = \sum_{i=k}^{13} \frac{\binom{13}{i} \binom{14}{13-i}}{\binom{27}{13}} = \begin{cases} .006, & \text{если } k = 10, \\ .041, & \text{если } k = 9, \\ .169, & \text{если } k = 8. \end{cases}$$

Выводы о связи между признаками могут быть сделаны в следующей форме.

Выводы. Предположим, что в результате опытов с $n = 27$ испытуемыми получена (2×2) -таблица сопряжённости, в которой

$$n(A) = 14, \quad n(B) = 13, \quad n(\bar{A}, B) = k, \quad \text{где } k = 2, 3, 4 \text{ или } k = 10, 9, 8.$$

При $k = 2, 3, 4$ ($k = 10, 9, 8$) принимается опирающееся на здравый смысл решение о наличии прямой (обратной) связи между признаками. Тогда количественной оценкой *ошибки* решения здравого смысла о наличии прямой (обратной) связи между признаками является число α_k^- , (α_k^+), которое можно интерпретировать как вероятность *напрасного отказа* от гипотезы о независимости признаков.

§ 10. Случайные величины и распределения вероятностей

§ 10.1. Дискретная модель

Рассмотрим случайный опыт, вероятностная модель которого задается пространством элементарных событий $\Omega = \{\omega\}$ и набором чисел

$$\Pr\{\omega\}, \quad 0 \leq \Pr\{\omega\} \leq 1, \quad \sum_{\omega} \Pr\{\omega\} = 1,$$

являющихся вероятностями этих элементарных событий.

Определение 1. Случайной величиной называется числовая функция $\xi = \xi(\omega)$, определённая на элементарных событиях ω пространства $\Omega = \{\omega\}$.

Пример. (Случайные величины в модели (n, p) -испытаний Бернулли.) Пусть двоичные (из 1 и 0) последовательности $\omega = (x_1, x_2, \dots, x_n)$ являются элементарными событиями для модели (n, p) -испытаний Бернулли. Этот случайный опыт представляет собой последовательность из n независимых испытаний с двумя возможными исходами в i -том, $i = 1, 2, \dots, n$, испытании: успехом или неудачей. Успех в каждом испытании происходит с одной и той же вероятностью p , $0 < p < 1$, и обозначается символом 1, а неудача происходит с вероятностью $1-p$ и обозначается символом 0. Согласно определению независимости, вероятность элементарного события $\omega = (x_1, x_2, \dots, x_n)$ задаётся как произведение вероятностей соответствующих исходов, относящихся к разным испытаниям:

$$\Pr\{\omega\} = \Pr\{(x_1, x_2, \dots, x_n)\} = \Pr\{x_1\} \cdot \Pr\{x_2\} \cdot \dots \cdot \Pr\{x_n\},$$

где $\Pr\{1\} = p$, а $\Pr\{0\} = 1 - p$. Введём двоичные случайные величины $\xi_i = \xi_i(\omega)$, каждая из которых может принять одно из двух значений 1 или 0:

$$\xi_i = \xi_i(\omega) = \begin{cases} 1, & \text{если в } i\text{-ом испытании был успех,} \\ 0, & \text{если в } i\text{-ом испытании была неудача, } i = 1, 2, \dots, n \end{cases}$$

а также случайную величину $S_n = S_n(\omega)$, называемую *числом успехов в n испытаниях*, которая может принять одно из $n + 1$ целочисленных значений $\{0, 1, \dots, n\}$:

$$S_n = S_n(\omega) = k, \text{ если в } n \text{ испытаниях произошло } k \text{ успехов, } k = 0, 1, \dots, n.$$

Для частного случая $n = 3$ эти определения иллюстрируется таблицей:

| $\omega = (x_1, x_2, x_3)$ | $\Pr\{\omega\}$ | $\xi_1 = \xi_1(\omega)$ | $\xi_2 = \xi_2(\omega)$ | $\xi_3 = \xi_3(\omega)$ | $S_3 = S_3(\omega)$ |
|----------------------------|-----------------|-------------------------|-------------------------|-------------------------|---------------------|
| $\omega = (0, 0, 0)$ | $(1-p)^3$ | 0 | 0 | 0 | 0 |
| $\omega = (0, 0, 1)$ | $p(1-p)^2$ | 0 | 0 | 1 | 1 |
| $\omega = (0, 1, 0)$ | $p(1-p)^2$ | 0 | 1 | 0 | 1 |
| $\omega = (0, 1, 1)$ | $p^2(1-p)$ | 0 | 1 | 1 | 2 |
| $\omega = (1, 0, 0)$ | $p(1-p)^2$ | 1 | 0 | 0 | 1 |
| $\omega = (1, 0, 1)$ | $p^2(1-p)$ | 1 | 0 | 1 | 2 |
| $\omega = (1, 1, 0)$ | $p^2(1-p)$ | 1 | 1 | 0 | 2 |
| $\omega = (1, 1, 1)$ | p^3 | 1 | 1 | 1 | 3 |

Формулы для записи случайных величин как функций от $\omega = (x_1, x_2, \dots, x_n)$ имеют вид:

$$\xi_i = \xi_i(\omega) = \xi_i((x_1, x_2, \dots, x_n)) = x_i, \quad i = 1, 2, \dots, n,$$

$$S_n = S_n(\omega) = S_n((x_1, x_2, \dots, x_n)) = \sum_{i=1}^n x_i = \sum_{i=1}^n \xi_i.$$

Обозначим различные значения случайной величины ξ через a_1, a_2, \dots, a_K , $K = 1, 2, \dots$. Отметим, что вырожденный случай $K = 1$ означает, что $\xi = c$, где $c = a_1$, является *постоянной* (неслучайной) величиной. Значения a_1, a_2, \dots, a_K могут быть любыми числами, как положительными, так и отрицательными. При $K \geq 2$ для определённости, не нарушая общности, будем считать, что $a_1 < a_2 < \dots < a_K$. Пусть q_k , $k = 1, 2, \dots, K$, есть вероятность события $\{\xi = a_k\}$, т.е.

$$q_k = \Pr\{\xi = a_k\}, \quad \text{где} \quad \sum_{k=1}^K q_k = 1.$$

Определение 2. *Распределением вероятностей* дискретной случайной величины ξ называется функция $q(x)$ действительного аргумента x , $-\infty \leq x \leq \infty$, вида:

$$q(x) \stackrel{\text{def}}{=} \begin{cases} q_k, & \text{если } x = a_k, \quad k = 1, 2, \dots, K, \\ 0, & \text{для остальных значений } x, \quad -\infty \leq x \leq \infty, \end{cases}$$

Такую функцию $q(x)$ назовем *вероятностной*.

Мы будем использовать следующую краткую запись данного определения:

$$\xi \sim q(x) = \begin{cases} q_k, & \text{если } x = a_k, \quad k = 1, 2, \dots, K, \\ 0, & \text{для остальных значений } x. \end{cases} \quad (1)$$

Отметим, что для неслучайной (детерминированной) величины $\xi = c$ такая запись имеет вид

$$c \sim q(x) = \begin{cases} 1, & \text{если } x = c, \\ 0, & \text{для остальных значений } x. \end{cases}$$

Для любого x , $-\infty \leq x \leq \infty$, очевидно, что вероятностная функция

$$q(x) = \Pr\{\xi = x\} \geq 0 \quad \text{и} \quad \sum_x q(x) = \sum_{k=1}^K q_k = 1. \quad (2)$$

Кроме того, для любых действительных чисел $-\infty \leq a < b \leq \infty$ вероятность события

$$\Pr\{a \leq \xi \leq b\} = \sum_{x: a \leq x \leq b} q(x). \quad (3)$$

Запись под знаком \sum означает, что суммирование берётся по всем действительным числам x таким, что $a \leq x \leq b$.

Определение 3. Функция $F(t)$ действительного аргумента t , $-\infty \leq t \leq \infty$, называется *функцией распределения* случайной величины ξ (или, кратко, $\xi \sim F(t)$), если

$$F(t) \stackrel{\text{def}}{=} \Pr\{\xi < t\} = \sum_{x: x < t} q(x) = \begin{cases} 0, & \text{если } t \leq a_1, \\ q_1, & \text{если } a_1 < t \leq a_2, \\ q_1 + q_2, & \text{если } a_2 < t \leq a_3, \\ \dots & \dots \quad \dots \\ \sum_{i=1}^k q_i, & \text{если } a_k < t \leq a_{k+1}, \quad k = 1, 2, \dots, K-1, \\ \dots & \dots \quad \dots \\ \sum_{i=1}^{K-1} q_i, & \text{если } a_{K-1} < t \leq a_K, \\ 1, & \text{если } t > a_K. \end{cases} \quad (4)$$

Функция распределения $F(t)$ есть ступенчатая функция, меняющая свои значения в точках, совпадающих со значениями $a_1 < a_2 < \dots < a_K$ случайной величины ξ .

В реальных научных опытах целью экспериментатора является получение информации о *неизвестном*¹ распределении вероятностей (1) случайной величины (признака) ξ на основании результатов опытов с n однородными испытуемыми, для каждого из которых он регистрирует одно из $\{a_1, a_2, \dots, a_K\}$ возможных значений ξ .

Пусть $n(a_k)$, – зарегистрированное в n опытах число испытуемых, у которых признак $\xi = a_k$. При этом, очевидно, $0 \leq n(a_k) \leq n$ и $\sum_{k=1}^K n(a_k) = n$. Если $K \ll n$, то в принципе можно пользоваться частотным вычислением вероятности

$$q_k = \Pr\{\xi = a_k\} \approx \frac{n(a_k)}{n}, \quad k = 1, 2, \dots, K.$$

Для многих других практически интересных ситуаций (например, когда $K > n$) такое вычисление невозможно. Желательно поэтому охарактеризовать распределении вероятностей (1) несколькими числовыми параметрами, которые можно было бы *оценивать экспериментально*. Сейчас мы займёмся формальным введением двух важнейших параметров, свойства которых будут исследованы в дальнейшем.

Определение 4. Числа

$$\mathbf{M}\xi \stackrel{\text{def}}{=} \sum_x x \cdot q(x) = \sum_{k=1}^K a_k \cdot q_k, \quad \mathbf{D}\xi \stackrel{\text{def}}{=} \sum_x (x - \mathbf{M}\xi)^2 \cdot q(x) = \sum_{k=1}^K (a_k - \mathbf{M}\xi)^2 \cdot q_k \quad (5)$$

называются соответственно *математическим ожиданием (средним значением)* и *дисперсией* (средним значением квадрата отклонений от математического ожидания) случайной величины ξ с распределением вероятностей (1).

Очевидно, что дисперсия $\mathbf{D}\xi \geq 0$. Число $\sigma_\xi \stackrel{\text{def}}{=} \sqrt{\mathbf{D}\xi}$, размерность которого совпадает с размерностью ξ , называется *среднеквадратичным отклонением* случайной величины ξ .

Замечание. Если числа $a_1 < a_2 < \dots < a_K$ являются возможными значениями случайной величины ξ , то интерпретация математического ожидания $\mathbf{M}\xi$ как среднего значения ξ связана с очевидными неравенствами $a_1 \leq \mathbf{M}\xi \leq a_K$.

¹Например, обычно экспериментатор знает множество $\{a_1, a_2, \dots, a_K\}$ возможных значений ξ , но не знает вероятности $q_k = \Pr\{\xi = a_k\}$, $k = 1, 2, \dots, K$, с которыми признак ξ принимает эти значения.

Пример. (Модель (n, p) -испытаний Бернулли.) *Различные* случайные величины ξ_i , $i = 1, 2, \dots, n$, которые в этой модели регистрируют успехи - неудачи в n независимых испытаниях, очевидно, имеют *одно и то же* распределение вероятностей:

$$\xi_i \sim q(x) = \begin{cases} 1-p, & \text{если } x = 0, \\ p, & \text{если } x = 1, \\ 0, & \text{для остальных значений } x, \quad -\infty \leq x \leq \infty, \end{cases}$$

или

$$\xi_i \sim F(t) = \Pr\{\xi_i < t\} = \begin{cases} 0, & \text{если } t \leq 0, \\ 1-p, & \text{если } 0 < t \leq 1, \\ 1, & \text{если } t > 1. \end{cases}$$

График функции распределения $F(t)$ является монотонно неубывающей ступенчатой функцией, которая меняет свои значения при $t = 0$ и при $t = 1$. Математическое ожидание

$$\mathbf{M}\xi_i = \sum_{k=1}^K a_k \cdot q_k = 0 \cdot (1-p) + 1 \cdot p = p,$$

а дисперсия

$$\mathbf{D}\xi_i = \sum_{k=1}^K (a_k - \mathbf{M}\xi_i)^2 \cdot q_k = (0-p)^2 \cdot (1-p) + (1-p)^2 \cdot p = p(1-p)[p + (1-p)] = p(1-p).$$

Число успехов в n испытаниях

$$S_n \sim q(x) = \begin{cases} \binom{n}{x} p^x (1-p)^{n-x}, & \text{если } x = 0, 1, \dots, n, \\ 0, & \text{для остальных значений } x, \quad -\infty \leq x \leq \infty. \end{cases}$$

Можно также написать, что $S_n \sim F(t)$, где функция распределения

$$F(t) = \Pr\{S_n < t\} = \begin{cases} 0, & \text{если } t \leq 0, \\ \sum_{i=0}^k \binom{n}{i} p^i (1-p)^{n-i}, & \text{если } k < t \leq k+1, \quad k = 0, 1, \dots, n-1, \\ 1, & \text{если } t > n. \end{cases}$$

Для любых целых чисел $0 \leq a \leq b \leq n$ вероятность события

$$\Pr\{a \leq S_n \leq b\} = \sum_{i=a}^b \binom{n}{i} p^i (1-p)^{n-i}.$$

Справедливы следующие формулы для вычисления математического ожидания и дисперсии числа успехов в модели (n, p) -испытаний Бернулли:

$$\mathbf{M}S_n = \sum_{i=0}^n i \cdot \binom{n}{i} p^i (1-p)^{n-i} = np,$$

$$\mathbf{D}S_n = \sum_{i=0}^n (i - np)^2 \cdot \binom{n}{i} p^i (1-p)^{n-i} = np(1-p).$$

§ 10.2. Непрерывная модель

Формально для приложений можно ограничиться изучением вышеописанной дискретной модели распределения вероятностей случайной величины ξ , принимающей лишь конечное число N значений. Это объясняется тем, что любой реальный прибор имеет ограниченную точность, т.е. число знаков, с которыми наблюдаются (измеряются) результаты случайного эксперимента ξ всегда ограничено и, следовательно, число возможных исходов N реального опыта всегда конечно. Тем не менее, для проведения различных расчётов в ситуации, когда $N \rightarrow \infty$, оказывается очень полезным вместо дискретного распределения рассматривать описываемый ниже его непрерывный аналог, который можно интерпретировать как математическую модель случайного опыта ξ в указанном предельном случае.

Пусть $p(x) \geq 0$ – произвольная неотрицательная функция аргумента x , $-\infty < x < \infty$, для которой сходится несобственный интеграл

$$\int_{-\infty}^{\infty} p(x) dx = 1, \quad p(x) \geq 0. \quad (2')$$

Определение 2'. Пусть $-\infty \leq a \leq b \leq \infty$ – произвольные действительные числа. Функция $p(x)$ называется *плотностью распределения* случайной величины ξ (или, кратко, $\xi \sim p(x)$), если вероятность события $\{a \leq \xi \leq b\}$, обозначаемая символом $\text{Pr}\{a \leq \xi \leq b\}$, задается как определенный интеграл от функции $p(x)$ по промежутку $[a; b]$:

$$\text{Pr}\{a \leq \xi \leq b\} \stackrel{\text{def}}{=} \int_a^b p(t) dt. \quad (3')$$

Плотность распределения $p(x)$ является аналогом вероятностной функции $q(x)$ в определении дискретного распределения.

Как и в дискретном случае, даются следующие определения.

Определение 3'. Функция $F(x)$ действительного аргумента x , $-\infty < x < \infty$, определяемая формулой

$$F(x) \stackrel{\text{def}}{=} \text{Pr}\{\xi < x\} = \text{Pr}\{-\infty < \xi < x\} = \int_{-\infty}^x p(t) dt, \quad -\infty < x < \infty, \quad (4')$$

называется *функцией распределения* случайной величины ξ (или, кратко, $\xi \sim F(x)$).

Определение 4'. Числа

$$\mathbf{M}\xi \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} x \cdot p(x) dx, \quad \mathbf{D}\xi \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} (x - \mathbf{M}\xi)^2 \cdot p(x) dx, \quad (5')$$

называются соответственно *математическим ожиданием* (средним значением) и *дисперсией* (средним значением квадрата отклонений от математического ожидания) случайной величины ξ с плотностью распределения $p(x)$.

Очевидно, что дисперсия $\mathbf{D}\xi \geq 0$. Число $\sigma_\xi = \sqrt{\mathbf{D}\xi}$, размерность которого совпадает с размерностью ξ , называется *среднеквадратичным отклонением* случайной величины ξ .

Применяя известную из курса математического анализа основную теорему интегрального исчисления (теорему Ньютона - Лейбница) о производной определённого интеграла по переменному верхнему пределу, получаем

Свойство 1. Если плотность распределения $p(x)$ есть непрерывная функция на всей числовой оси $-\infty < x < \infty$, то для функции распределения $F(x)$ имеют место следующие утверждения.

- 1) Производная $F'(x) = p(x)$ для любого x , $-\infty < x < \infty$, т.е. производная функции распределения равна плотности этого распределения.
- 2) Если $a < b$, то $\Pr\{a \leq \xi \leq b\} = \int_a^b p(t) dt = F(b) - F(a)$.

Пример. (Распределение вероятностей $\mathcal{N}(a, \sigma)$). Согласно определению, непрерывная случайная величина ξ имеет стандартное нормальное распределение вероятностей $\mathcal{N}(0, 1)$ (или, кратко, $\xi \sim \mathcal{N}(0, 1)$), если её плотность распределения $p(x) = g(x)$, а функция распределения $F(x) = G(x)$, где функции $g(x)$ и $G(x)$ задаются соотношениями

$$g(x) \stackrel{\text{def}}{=} \frac{1}{\sqrt{2\pi}} e^{-x^2/2} = G'(x), \quad G(x) \stackrel{\text{def}}{=} \int_{-\infty}^x g(t) dt = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt.$$

Отметим, что $g(x)$ – четная положительная функция, а функция $G(x)$ монотонно возрастает от 0 до 1, причем

$$G(-\infty) = 0, \quad G(0) = 1/2, \quad G(\infty) = 1.$$

Пусть a и $\sigma > 0$ – произвольные фиксированные числа. Согласно определению, непрерывная случайная величина η имеет нормальное распределение с параметрами a и σ (или, кратко, $\eta \sim \mathcal{N}(a, \sigma)$), если её плотность распределения $p(x) = f_\eta(x)$, а функция распределения $F(x) = F_\eta(x)$, где функции $f_\eta(x)$ и $F_\eta(x)$ задаются соотношениями

$$f_\eta(x) \stackrel{\text{def}}{=} \sigma^{-1} g\left(\frac{x-a}{\sigma}\right) = \frac{1}{\sigma\sqrt{2\pi}} e^{-(x-a)^2/2\sigma^2}, \quad F_\eta(x) \stackrel{\text{def}}{=} G\left(\frac{x-a}{\sigma}\right) = \int_{-\infty}^{\frac{x-a}{\sigma}} g(t) dt,$$

которые равносильны тому, что

$$\eta \stackrel{\text{def}}{=} a + \sigma \cdot \xi \quad \text{или} \quad \mathcal{N}(a, \sigma) \stackrel{\text{def}}{=} a + \sigma \cdot \mathcal{N}(0, 1).$$

Для математического ожидания $\mathbf{M}\eta$ и дисперсии $\mathbf{D}\eta$ справедливы равенства

$$\mathbf{M}\eta = \int_{-\infty}^{\infty} t f_\eta(t) dt = a, \quad \mathbf{D}\eta = \int_{-\infty}^{\infty} (t-a)^2 f_\eta(t) dt = \sigma^2.$$

Отметим, что параметр $\sigma = \sqrt{\mathbf{D}\eta}$ является среднеквадратичным отклонением распределения $\mathcal{N}(a, \sigma)$. Пусть $-\infty \leq A < B \leq \infty$ – произвольные заданные числа. В силу свойства 1, вероятность попадания наблюдения $\eta \sim \mathcal{N}(a, \sigma)$ в заданный промежуток $[A; B]$ вычисляется по формуле

$$\Pr\{A \leq \eta \leq B\} = \int_A^B f_\eta(t) dt = \int_{(A-a)/\sigma}^{(B-a)/\sigma} g(t) dt = G\left(\frac{B-a}{\sigma}\right) - G\left(\frac{A-a}{\sigma}\right).$$

Данная формула сводит вычисление вероятностей для $\eta \sim \mathcal{N}(a, \sigma)$ к вычислению по таблицам для стандартного нормального распределения $\xi \sim \mathcal{N}(0, 1)$. Эти таблицы называются таблицами *интеграла вероятностей*.

Методы математической статистики, в которых при обработке результатов наблюдений используется предположение об их нормальном распределении $\mathcal{N}(a, \sigma)$ с неизвестными параметрами a и σ , называются *параметрическими* методами.

Более общие методы математической статистики, в которых не используется предположение об $\mathcal{N}(a, \sigma)$ для обрабатываемых наблюдений, называются *непараметрическими* или *ранговыми* методами. Для обоснования применения ранговых методов важное значение имеет следующее *общее свойство* функции распределения $F(x)$.

Свойство 2. Пусть случайная величина ξ имеет функцию распределения $F(x)$, которая является непрерывной и монотонно возрастающей функцией при всех x , $-\infty < x < \infty$, таких что $0 < F(x) < 1$. Тогда случайная величина $\eta \stackrel{\text{def}}{=} F(\xi)$ удовлетворяет неравенствам $0 < \eta < 1$ и имеет функцию распределения

$$U(t) = \Pr\{\eta < t\} = \begin{cases} 0, & \text{если } t \leq 0, \\ t, & \text{если } 0 < t < 1, \\ 1, & \text{если } t \geq 1. \end{cases}$$

которая не зависит от исходной функции $F(x)$.

Данная стандартная функция $U(t)$ называется *равномерной* функцией распределения на интервале $(0; 1)$. Ей соответствует *плотность равномерного распределения* на интервале $(0; 1)$:

$$u(t) = U'(t) = \begin{cases} 1, & \text{если } 0 < t < 1, \\ 0, & \text{если } t \leq 0 \text{ или } t \geq 1, \end{cases}$$

Отметим, что если случайная величина (наблюдение) η имеет равномерное распределение на интервале $(0; 1)$, то для любых чисел $0 \leq a < b \leq 1$ вероятность попадания наблюдения в интервал $(a; b)$ равна длине этого интервала $b - a$, т.е. $\Pr\{a < \eta < b\} = b - a$.

Доказательство свойства 2. Поскольку $t = F(x)$ есть непрерывная и монотонно возрастающая от $t = 0$ до $t = 1$ функция аргумента x , $-\infty < x < \infty$, то согласно теореме математического анализа об обратной функции, для функции $t = F(x)$ существует непрерывная и монотонно возрастающая от $x = -\infty$ до $x = \infty$ обратная функция $x = F^{-1}(t)$, аргумента t , $0 < t < 1$. При этом, в силу строгой монотонности и непрерывности прямой и обратной функций,

$$\text{для любого } t, 0 < t < 1, \quad \text{множество } \{x : F(x) < t\} = \{x : x < F^{-1}(t)\}$$

и, кроме того,

$$\text{для любого } t, 0 < t < 1, \quad \text{справедливо тождество } F(F^{-1}(t)) = t.$$

Следовательно, для любого t , $0 < t < 1$, функция распределения

$$U(t) = \Pr\{\eta < t\} = \Pr\{F(\xi) < t\} = \Pr\{\xi < F^{-1}(t)\} = F(F^{-1}(t)) = t.$$

Свойство 2 доказано.

§ 11. Совместное распределение случайных величин, независимость случайных величин

§ 11.1. Дискретная модель

Пусть $\{a_1, a_2, \dots, a_K\}$ – набор различных значений случайной величины $\xi = \xi(\omega)$ и индекс $k = 1, 2, \dots, K$. Пусть $\{b_1, b_2, \dots, b_J\}$ – набор различных значений случайной величины $\eta = \eta(\omega)$, и индекс $j = 1, 2, \dots, J$.

Определение 1. Произвольный набор (матрица) $\{q_{kj}\} = \|q_{kj}\|$ из $K \cdot J$ чисел, удовлетворяющих условиям

$$q_{kj} \geq 0, \quad \sum_{k=1}^K \sum_{j=1}^J q_{kj} = 1 \quad (1)$$

и задающих вероятности вида

$$q_{kj} \stackrel{\text{def}}{=} \text{Pr}\{\xi = a_k, \eta = b_j\}, \quad k = 1, 2, \dots, K, \quad j = 1, 2, \dots, J, \quad (2)$$

называется *совместным распределением пары случайных величин* (ξ, η) .

Очевидно, что события

$$\{\xi = a_k, \eta = b_j\} \quad k = 1, 2, \dots, K, \quad j = 1, 2, \dots, J,$$

несовместимы, т.е. попарно непересекаются. Кроме того, событие

$$\{\xi = a_k\} = \sum_{j=1}^J \{\xi = a_k, \eta = b_j\}, \quad k = 1, 2, \dots, K,$$

а событие

$$\{\eta = b_j\} = \sum_{k=1}^K \{\xi = a_k, \eta = b_j\}, \quad j = 1, 2, \dots, J.$$

Отсюда вытекает важное

Свойство 1. *Справедливы формулы*

$$\text{Pr}\{\xi = a_k\} = \sum_{j=1}^J \text{Pr}\{\xi = a_k, \eta = b_j\} = \sum_{j=1}^J q_{kj} \stackrel{\text{def}}{=} q_{k.} \quad k = 1, 2, \dots, K,$$

$$\text{Pr}\{\eta = b_j\} = \sum_{k=1}^K \text{Pr}\{\xi = a_k, \eta = b_j\} = \sum_{k=1}^K q_{kj} \stackrel{\text{def}}{=} q_{.j} \quad j = 1, 2, \dots, J$$

с помощью которых по совместному распределению $\{q_{kj}\}$ пары случайных величин (ξ, η) вычисляются распределения самих случайных величин ξ и η .

Сопоставим совместному распределению $\{q_{kj}\} = \|q_{kj}\|$ функцию двух переменных x , $-\infty \leq x \leq \infty$, и y , $-\infty \leq y \leq \infty$:

$$q(x, y) \stackrel{\text{def}}{=} \begin{cases} q_{kj}, & \text{если } x = a_k, \text{ а } y = b_j, \\ 0, & \text{в остальных случаях.} \end{cases}$$

С помощью этой функции совместное распределение пары (ξ, η) и получаемые по формулам свойства 1 распределения самих случайных величин ξ и η можно записать в виде

$$\Pr\{\xi = x, \eta = y\} = q(x, y),$$

$$\Pr\{\xi = x\} = \sum_y q(x, y) \stackrel{\text{def}}{=} q(x, \cdot), \quad \Pr\{\eta = y\} = \sum_x q(x, y) \stackrel{\text{def}}{=} q(\cdot, y). \quad (3)$$

Определение 2. Случайные величины ξ и η называются *независимыми*, если для любой пары чисел (x, y) события $\{\xi = x\}$ и $\{\eta = y\}$ независимы между собой, т.е.

$$q(x, y) = \Pr\{\xi = x, \eta = y\} \stackrel{\text{def}}{=} \Pr\{\xi = x\} \cdot \Pr\{\eta = y\} = q(x, \cdot) \cdot q(\cdot, y). \quad (4)$$

Рассмотрим вопрос о распределении случайной величины $\xi + \eta$, т.е. задачу вычисления *распределения суммы случайных величин*. Как для произвольного числа x , $-\infty \leq x \leq \infty$, вычислить вероятность $\Pr\{\xi + \eta = x\}$?

Свойство 2. Для распределения суммы случайных величин ξ и η справедливы формулы

$$\Pr\{\xi + \eta = x\} = \sum_y \Pr\{\xi = x - y, \eta = y\} = \sum_y q(x - y, y), \quad -\infty \leq x \leq \infty, \quad (5)$$

которые для частного случая независимых слагаемых имеют вид

$$\Pr\{\xi + \eta = x\} = \sum_y \Pr\{\xi = x - y\} \cdot \Pr\{\eta = y\} = \sum_y q(x - y, \cdot) \cdot q(\cdot, y), \quad -\infty \leq x \leq \infty. \quad (6)$$

§ 11.2. Непрерывная модель

Пусть $p(x, y) \geq 0$ – произвольная неотрицательная функция двух действительных аргументов x , $-\infty < x < \infty$, и y , $-\infty < y < \infty$, для которой сходящийся несобственный интеграл

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(x, y) dx dy = 1, \quad p(x, y) \geq 0, \quad (1')$$

Определение 1'. Пусть $-\infty \leq a \leq b \leq \infty$ и $-\infty \leq c \leq d \leq \infty$ – произвольные действительные числа. Функция $p(x, y)$ называется *плотностью совместного распределения* пары случайных величин (ξ, η) , если вероятность события $\{a \leq \xi \leq b, c \leq \eta \leq d\}$ задается как определённый интеграл от функции $p(x, y)$ вида:

$$\Pr\{a \leq \xi \leq b, c \leq \eta \leq d\} \stackrel{\text{def}}{=} \int_a^b \int_c^d p(x, y) dx dy. \quad (2')$$

Формулы для вычисления плотностей распределений вероятностей величин ξ и η по плотности их совместного распределения даёт

Свойство 1'. Если пара случайных величин (ξ, η) имеет плотность совместного распределения $p(x, y)$, то функции

$$p(x, \cdot) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} p(x, y) dy \stackrel{\text{def}}{=} p_{\xi}(x) \quad \text{и} \quad p(\cdot, y) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} p(x, y) dx \stackrel{\text{def}}{=} p_{\eta}(y) \quad (3')$$

являются соответственно плотностями распределения величин ξ и η , т.е. для любых чисел $-\infty \leq a \leq b \leq \infty$ и любых чисел $-\infty \leq c \leq d \leq \infty$

$$\Pr\{a \leq \xi \leq b\} = \int_a^b p(x, \cdot) dx \quad \text{и} \quad \Pr\{c \leq \eta \leq d\} = \int_c^d p(\cdot, y) dy.$$

Определение независимости случайных величин в общем случае формулируется следующим образом.

Определение 2'. Случайные величины ξ и η называются *независимыми*, если для любых чисел $-\infty \leq a \leq b \leq \infty$ и любых чисел $-\infty \leq c \leq d \leq \infty$ события $\{a \leq \xi \leq b\}$ и $\{c \leq \eta \leq d\}$ независимы между собой, т.е. для вероятности события $\{a \leq \xi \leq b, c \leq \eta \leq d\}$ имеет место соотношение

$$\Pr\{a \leq \xi \leq b, c \leq \eta \leq d\} \stackrel{\text{def}}{=} \Pr\{a \leq \xi \leq b\} \cdot \Pr\{c \leq \eta \leq d\}.$$

Можно доказать, что справедливо

Свойство 3. Случайные величины ξ и η с плотностью совместного распределения $p(x, y)$ являются независимыми тогда и только тогда, когда для любой пары чисел (x, y) плотность $p(x, y)$ равна произведению плотностей распределения случайных величин ξ и η , т.е.

$$p(x, y) = p(x, \cdot) \cdot p(\cdot, y), \quad -\infty < x < \infty, \quad -\infty < y < \infty. \quad (4')$$

Для непрерывной модели аналогом свойства 2 является

Свойство 2'. Если пара случайных величин (ξ, η) имеет плотность совместного распределения $p(x, y)$, то функция $p_{\xi+\eta}(x)$ действительного аргумента x , $-\infty \leq x \leq \infty$, определяемая формулой

$$p_{\xi+\eta}(x) \stackrel{\text{def}}{=} \int_{-\infty}^{\infty} p(x-y, y) dy, \quad -\infty \leq x \leq \infty, \quad (5')$$

является плотностью распределения суммы случайных величин ξ и η , т.е. для любых чисел $-\infty \leq a \leq b \leq \infty$ вероятность события

$$\Pr\{a \leq \xi + \eta \leq b\} = \int_a^b p_{\xi+\eta}(x) dx = \int_a^b \left\{ \int_{-\infty}^{\infty} p(x-y, y) dy \right\} dx.$$

Для частного случая независимых слагаемых ξ и η , имеющих соответственно плотности распределения $p_{\xi}(x)$ и $p_{\eta}(x)$, плотность распределения суммы $\xi + \eta$ имеет вид

$$p_{\xi+\eta}(x) = \int_{-\infty}^{\infty} p(x-y, \cdot) \cdot p(\cdot, y) dy = \int_{-\infty}^{\infty} p_{\xi}(x-y) \cdot p_{\eta}(y) dy, \quad -\infty \leq x \leq \infty. \quad (6')$$

Пример. (Суммирование независимых нормальных величин). Применим свойство 2' для вычисления плотности распределения суммы независимых нормальных случайных величин

$$\xi \sim \mathcal{N}(a_1, \sigma_1), \mathbf{M}\xi = a_1, \mathbf{D}\xi = \sigma_1^2 \quad \text{и} \quad \eta \sim \mathcal{N}(a_2, \sigma_2), \mathbf{M}\eta = a_2, \mathbf{D}\eta = \sigma_2^2.$$

Согласно данному выше определению, плотности рассматриваемых нормальных распределений имеют вид

$$p_\xi(x-y) = \frac{1}{\sigma_1\sqrt{2\pi}} \exp\left\{-\frac{[(x-y)-a_1]^2}{2\sigma_1^2}\right\}, \quad p_\eta(y) = \frac{1}{\sigma_2\sqrt{2\pi}} \exp\left\{-\frac{[y-a_2]^2}{2\sigma_2^2}\right\},$$

где для удобства записи используется стандартное обозначение $\exp\{z\} = e^z$. Можно показать, что если эти формулы подставить в правую часть (6') и вычислить полученный определённый интеграл, то функция $p_{\xi+\eta}(x)$ примет вид:

$$p_{\xi+\eta}(x) = \frac{1}{\sqrt{\sigma_1^2 + \sigma_2^2} \cdot \sqrt{2\pi}} \exp\left\{-\frac{[x - (a_1 + a_2)]^2}{2(\sigma_1^2 + \sigma_2^2)}\right\}.$$

Это означает, что имеет место следующее важное свойство нормальных случайных величин.

Свойство 4. Сумма $\xi + \eta$ независимых нормальных случайных величин $\xi \sim \mathcal{N}(a_1, \sigma_1)$ и $\eta \sim \mathcal{N}(a_2, \sigma_2)$ является нормальной случайной величиной:

$$\xi + \eta \sim \mathcal{N}(a_1, \sigma_1) + \mathcal{N}(a_2, \sigma_2) \sim \mathcal{N}\left(a_1 + a_2, \sqrt{\sigma_1^2 + \sigma_2^2}\right),$$

математическое ожидание и дисперсия которой вычисляются по формулам

$$\mathbf{M}(\xi + \eta) = a_1 + a_2 = \mathbf{M}\xi + \mathbf{M}\eta, \quad \mathbf{D}(\xi + \eta) = \sigma_1^2 + \sigma_2^2 = \mathbf{D}\xi + \mathbf{D}\eta.$$

§ 11.3. Совместное распределение n случайных величин $(\xi_1, \xi_2, \dots, \xi_n)$

Совместное распределение n случайных величин $(\xi_1, \xi_2, \dots, \xi_n)$ задается вероятностной функцией от n переменных.

- В случае дискретной модели эта функция $q = q(x_1, x_2, \dots, x_n)$, называемая *совместным распределением вероятностей*, удовлетворяет условиям

$$q(x_1, x_2, \dots, x_n) \geq 0, \quad \sum_{i=1}^n \sum_{x_i} q(x_1, x_2, \dots, x_n) = 1$$

и определяет вероятности событий

$$\text{Pr}\{\xi_1 = x_1, \xi_2 = x_2, \dots, \xi_n = x_n\} \stackrel{\text{def}}{=} q(x_1, x_2, \dots, x_n).$$

- В случае непрерывной модели эта функция $p = p(x_1, x_2, \dots, x_n)$, называемая *плотностью совместного распределения вероятностей*, удовлетворяет условиям

$$p(x_1, x_2, \dots, x_n) \geq 0, \quad \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} p(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n = 1$$

и определяет вероятности событий

$$\Pr\{a_1 \leq \xi_1 \leq b_1; a_2 \leq \xi_2 \leq b_2; \dots; a_n \leq \xi_n \leq b_n\} \stackrel{\text{def}}{=} \\ \stackrel{\text{def}}{=} \int_{a_1}^{b_1} \int_{a_2}^{b_2} \dots \int_{a_n}^{b_n} p(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n.$$

При определении независимости n случайных величин $(\xi_1, \xi_2, \dots, \xi_n)$ мы ограничимся наиболее важным для приложений случаем n независимых одинаково распределённых (однородных) случайных величин. В математической статистике эта модель наблюдений называется *выборкой объёма n* . Рассмотрим произвольную вероятностную функцию аргумента x , $-\infty < x < \infty$, т.е. распределение вероятностей $q(x)$ (дискретная модель) или плотность распределения вероятностей $p(x)$ (непрерывная модель).

Определение 3. Будем говорить, что случайные величины $(\xi_1, \xi_2, \dots, \xi_n)$ являются *независимыми одинаково распределёнными величинами* $\xi_i \sim q(x)$ (дискретная модель) или $\xi_i \sim p(x)$ (непрерывная модель), если совместная вероятность $q = q(x_1, x_2, \dots, x_n)$ (дискретная модель) или совместная плотность $p = p(x_1, x_2, \dots, x_n)$ (непрерывная модель) задаются в виде *произведения n вероятностных функций*:

$$q = q(x_1, x_2, \dots, x_n) \stackrel{\text{def}}{=} q(x_1) \cdot q(x_2) \cdot \dots \cdot q(x_n), \\ p = p(x_1, x_2, \dots, x_n) \stackrel{\text{def}}{=} p(x_1) \cdot p(x_2) \cdot \dots \cdot p(x_n).$$

Используя это определение и формулу (6'), можно доказать следующее обобщение свойства 4 о распределении суммы n независимых нормальных случайных величин.

Свойство 5. Пусть $(\xi_1, \xi_2, \dots, \xi_n)$ – независимые одинаково распределённые величины, где $\xi_i \sim \mathcal{N}(a, \sigma)$ для любого $i = 1, 2, \dots, n$. Тогда их сумма $S_n = \sum_{i=1}^n \xi_i$ также является нормальной случайной величиной

$$S_n = \sum_{i=1}^n \xi_i \sim \mathcal{N}(na, \sigma\sqrt{n}),$$

математическое ожидание и дисперсия которой вычисляются по формулам

$$\mathbf{M} S_n = \mathbf{M} \left\{ \sum_{i=1}^n \xi_i \right\} = \sum_{i=1}^n \mathbf{M} \xi_i = na, \quad \mathbf{D} S_n = \mathbf{D} \left\{ \sum_{i=1}^n \xi_i \right\} = \sum_{i=1}^n \mathbf{D} \xi_i = n\sigma^2.$$

§ 12. Числовые характеристики распределения вероятностей

§ 12.1. Математическое ожидание, дисперсия и их свойства

1. Пусть ξ – произвольная случайная величина, которая имеет распределение вероятностей, задаваемое вероятностной функцией $q(x)$ (дискретная модель) или плотностью распределения вероятностей $p(x)$ (непрерывная модель). Символом $f(x)$ обозначим произвольную функцию действительного аргумента x , $-\infty \leq x \leq \infty$, а символом c , $-\infty \leq c \leq \infty$, – произвольную постоянную.

Рассмотрим случайную величину $\eta = f(\xi)$, которую можно называть *функцией от случайной величины* ξ . Математическое ожидание функции от случайной величины ξ обозначается символом $\mathbf{M}f(\xi)$ и определяется формулой

$$\mathbf{M}f(\xi) \stackrel{\text{def}}{=} \begin{cases} \sum_x f(x)q(x) & \text{для дискретной модели,} \\ \int_{-\infty}^{\infty} f(x)p(x) dx & \text{для непрерывной модели.} \end{cases}$$

Если для любого x , $-\infty \leq x \leq \infty$, положим функцию $f(x) = c$, то очевидно

$$\mathbf{M}c \stackrel{\text{def}}{=} \begin{cases} \sum_x cq(x) = c \cdot \sum_x q(x) = c & \text{для дискретной модели,} \\ \int_{-\infty}^{\infty} cp(x) dx = c \cdot \int_{-\infty}^{\infty} p(x) dx = c & \text{для непрерывной модели.} \end{cases}$$

Если положить функцию $f(x) = (x - \mathbf{M}\xi)^2$, то дисперсия $\mathbf{D}\xi$ представляется как математическое ожидание этой функции от случайной величины ξ :

$$\mathbf{D}\xi = \begin{cases} \sum_x (x - \mathbf{M}\xi)^2 q(x) = \mathbf{M}(\xi - \mathbf{M}\xi)^2 & \text{для дискретной модели,} \\ \int_{-\infty}^{\infty} (x - \mathbf{M}\xi)^2 p(x) dx = \mathbf{M}(\xi - \mathbf{M}\xi)^2 & \text{для непрерывной модели.} \end{cases}$$

В частности, $\mathbf{D}c = \mathbf{M}(c - \mathbf{M}c)^2 = \mathbf{M}(c - c)^2 = \mathbf{M}0 = 0$. Следовательно, имеет место

Теорема 1.

- 1) Математическое ожидание постоянной величины равно этой постоянной величине, т.е. $\mathbf{M}c = c$.
- 2) Дисперсия $\mathbf{D}\xi \geq 0$, где знак равенства, если и только если случайная величина $\xi = c = \mathbf{M}\xi$ – постоянная величина.

Аналогичным образом можно проверить и другие важные формулы для математического ожидания и дисперсии, которые описывает

Теорема 2.

- 1) $\mathbf{M}(c \cdot \xi) = c \cdot \mathbf{M}\xi$, $\mathbf{M}(\xi + c) = \mathbf{M}\xi + c$, $\mathbf{M}(\xi - \mathbf{M}\xi) = 0$;
- 2) $\mathbf{D}(\xi + c) = \mathbf{D}\xi$, $\mathbf{D}(c \cdot \xi) = c^2 \cdot \mathbf{D}\xi$, $\mathbf{D}\xi = \mathbf{M}(\xi - \mathbf{M}\xi)^2 = \mathbf{M}(\xi^2) - (\mathbf{M}\xi)^2$;
- 3) Если $\mathbf{M}\xi = 0$, то $\mathbf{D}\xi = \mathbf{M}(\xi^2)$.

Доказательство.

1)

$$\begin{aligned} \mathbf{M}(c \cdot \xi) &= \sum_x c \cdot x q(x) = c \cdot \sum_x x q(x) = c \cdot \mathbf{M}\xi, \\ \mathbf{M}(\xi + c) &= \int_{-\infty}^{\infty} (x + c) p(x) dx = \int_{-\infty}^{\infty} x p(x) dx + \int_{-\infty}^{\infty} c p(x) dx = \mathbf{M}\xi + c, \end{aligned}$$

а последнее равенство $\mathbf{M}(\xi - \mathbf{M}\xi) = 0$ является частным случаем предыдущего, если положить постоянную $c = -\mathbf{M}\xi$.

2)

$$\begin{aligned} \mathbf{D}(\xi + c) &= \int_{-\infty}^{\infty} [(x + c) - \mathbf{M}(\xi + c)]^2 p(x) dx = \int_{-\infty}^{\infty} (x - \mathbf{M}\xi)^2 p(x) dx = \mathbf{D}\xi, \\ \mathbf{D}(c \cdot \xi) &= \sum_x [c \cdot x - \mathbf{M}(c \cdot \xi)]^2 q(x) = \sum_x c^2 [x - \mathbf{M}(\xi)]^2 q(x) = c^2 \cdot \mathbf{D}\xi. \end{aligned}$$

Для непрерывного случая, применяя известные свойства определённого интеграла, проверяем

$$\begin{aligned} \mathbf{D}\xi &= \int_{-\infty}^{\infty} (x - \mathbf{M}\xi)^2 p(x) dx = \int_{-\infty}^{\infty} [x^2 - 2x\mathbf{M}\xi + (\mathbf{M}\xi)^2] p(x) dx = \\ &= \int_{-\infty}^{\infty} x^2 p(x) dx - 2\mathbf{M}\xi \int_{-\infty}^{\infty} x p(x) dx + (\mathbf{M}\xi)^2 \int_{-\infty}^{\infty} p(x) dx = \\ &= \mathbf{M}(\xi^2) - 2(\mathbf{M}\xi)^2 + (\mathbf{M}\xi)^2 = \mathbf{M}(\xi^2) - (\mathbf{M}\xi)^2. \end{aligned}$$

3) Если $\mathbf{M}\xi = 0$, то $\mathbf{D}\xi = \mathbf{M}(\xi^2) - (\mathbf{M}\xi)^2 = \mathbf{M}(\xi^2) - 0 = \mathbf{M}(\xi^2)$.

Теорема 2 доказана.

Будем говорить, что случайная величина ξ , имеющая "стандартные" параметры

$$\mathbf{M}\xi = 0 \quad \text{и} \quad \mathbf{D}\xi = \mathbf{M}(\xi^2) = 1,$$

является *нормированной*. Для произвольной случайной величины ξ с математическим ожиданием $a = \mathbf{M}\xi$ и дисперсией $\sigma^2 = \mathbf{D}\xi = \mathbf{M}(\xi - a)^2$ введём *безразмерную* величину

$$\xi^* \stackrel{\text{def}}{=} \frac{\xi - \mathbf{M}\xi}{\sqrt{\mathbf{D}\xi}} = \frac{\xi - a}{\sigma},$$

называемую *нормировкой* ξ . Из теоремы 2 вытекает

Следствие. Математическое ожидание $\mathbf{M}\xi^* = 0$, а дисперсия $\mathbf{D}\xi^* = \mathbf{M}(\xi^*)^2 = 1$.

Доказательство. Применяя соответствующие утверждения теоремы 2, проверяем

$$\mathbf{M}\xi^* = \frac{\mathbf{M}(\xi - \mathbf{M}\xi)}{\sqrt{\mathbf{D}\xi}} = 0, \quad \mathbf{M}(\xi^*)^2 = \mathbf{D}\xi^* = \frac{\mathbf{D}(\xi - \mathbf{M}\xi)}{\mathbf{D}\xi} = \frac{\mathbf{D}\xi}{\mathbf{D}\xi} = 1.$$

Следствие доказано.

2. Пусть (ξ, η) – произвольная пара случайных величин с совместным распределением $q(x, y)$ (дискретная модель) или плотностью совместного распределения $p(x, y)$ (непрерывная модель). Символом $f(x, y)$ обозначим произвольную функцию двух действительных аргументов x , $-\infty \leq x \leq \infty$ и y , $-\infty \leq y \leq \infty$.

Рассмотрим случайную величину $\theta = f(\xi, \eta)$, которую можно называть *функцией от пары* случайных величин (ξ, η) . Очевидно, что распределение вероятностей $\theta = f(\xi, \eta)$ однозначно вычисляется по совместному распределению пары (ξ, η) . Математическое ожидание функции от пары случайных величин (ξ, η) обозначается символом $\mathbf{M}f(\xi, \eta)$ и определяется формулой

$$\mathbf{M}f(\xi, \eta) \stackrel{\text{def}}{=} \begin{cases} \sum_x \sum_y f(x, y) q(x, y) & \text{для дискретной модели,} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) p(x, y) dx dy & \text{для непрерывной модели.} \end{cases} \quad (1)$$

Если в (1) положить $f(x, y) = x + y$, то для дискретного (аналогично и для непрерывного) случая имеем

$$\begin{aligned} \mathbf{M}(\xi + \eta) &= \sum_x \sum_y (x + y) q(x, y) = \sum_x \sum_y x q(x, y) + \sum_x \sum_y y q(x, y) = \\ &= \sum_x x \sum_y q(x, y) + \sum_y y \sum_x q(x, y) = \sum_x x q(x, \cdot) + \sum_y y q(\cdot, y) = \mathbf{M}\xi + \mathbf{M}\eta. \end{aligned}$$

Следовательно, математическое ожидание суммы двух случайных величин равно сумме их математических ожиданий, т.е.

$$\mathbf{M}(\xi + \eta) = \mathbf{M}\xi + \mathbf{M}\eta. \quad (2)$$

Этот результат по индукции, очевидным образом, обобщается на сумму любого числа слагаемых. Например, для случая трех слагаемых, применив два раза формулу (2), получим

$$\mathbf{M}(\xi_1 + \xi_2 + \xi_3) = \mathbf{M}[(\xi_1 + \xi_2) + \xi_3] = \mathbf{M}[(\xi_1 + \xi_2)] + \mathbf{M}\xi_3 = \mathbf{M}\xi_1 + \mathbf{M}\xi_2 + \mathbf{M}\xi_3.$$

Таким образом, справедлива

Теорема 3. *Математическое ожидание суммы случайных величин равно сумме их математических ожиданий, иначе*

$$\mathbf{M}(\xi_1 + \xi_2 + \dots + \xi_n) = \mathbf{M}\xi_1 + \mathbf{M}\xi_2 + \dots + \mathbf{M}\xi_n.$$

Для *независимых* случайных величин также верна

Теорема 4. *Математическое ожидание произведения двух независимых случайных величин ξ и η равно произведению их математических ожиданий, иначе*

$$\mathbf{M}(\xi \cdot \eta) = \mathbf{M}\xi \cdot \mathbf{M}\eta. \quad (2)$$

Доказательство. Если в определении (1) положить $f(x, y) = x \cdot y$, то для дискретного (аналогично и для непрерывного) случая имеем

$$\mathbf{M}(\xi \cdot \eta) = \sum_x \sum_y (x \cdot y) \cdot q(x, y).$$

В силу определения независимости, совместное распределение $q(x, y) = q(x, \cdot) \cdot q(\cdot, y)$. Поэтому

$$\mathbf{M}(\xi \cdot \eta) = \sum_x \sum_y [x \cdot q(x, \cdot)] \cdot [y \cdot q(\cdot, y)] = \left[\sum_x x \cdot q(x, \cdot) \right] \cdot \left[\sum_y (y \cdot q(\cdot, y)) \right] = \mathbf{M}\xi \cdot \mathbf{M}\eta$$

Теорема 4 доказана.

Рассмотрим теперь вопрос о дисперсии суммы двух случайных величин ξ и η . Введём, для краткости, обозначения математических ожиданий $a = \mathbf{M}\xi$ и $b = \mathbf{M}\eta$. Применяя определение дисперсии и теоремы 1-3, можем написать

$$\begin{aligned} \mathbf{D}(\xi + \eta) &= \mathbf{M}[(\xi + \eta) - \mathbf{M}(\xi + \eta)]^2 = \mathbf{M}[(\xi + \eta) - (a + b)]^2 = \mathbf{M}[(\xi - a) + (\eta - b)]^2 = \\ &= \mathbf{M}[(\xi - a)^2 + (\eta - b)^2 + 2(\xi - a)(\eta - b)] = \mathbf{M}(\xi - a)^2 + \mathbf{M}(\eta - b)^2 + 2\mathbf{M}[(\xi - a)(\eta - b)] = \\ &= \mathbf{M}(\xi - \mathbf{M}\xi)^2 + \mathbf{M}(\eta - \mathbf{M}\eta)^2 + 2\mathbf{M}[(\xi - \mathbf{M}\xi)(\eta - \mathbf{M}\eta)] = \mathbf{D}\xi + \mathbf{D}\eta + 2\text{cov}(\xi, \eta), \end{aligned}$$

где ввели число

$$\text{cov}(\xi, \eta) \stackrel{\text{def}}{=} \mathbf{M}[(\xi - \mathbf{M}\xi)(\eta - \mathbf{M}\eta)] = \sum_x \sum_y (x - a)(y - b) q(x, y),$$

называемое *ковариацией* пары случайных величин (ξ, η) . Таким образом, в общем случае дисперсия суммы двух случайных величин связана с дисперсиями слагаемых следующей формулой

$$\mathbf{D}(\xi + \eta) = \mathbf{D}\xi + \mathbf{D}\eta + 2\text{cov}(\xi, \eta). \quad (3)$$

Поскольку

$$\text{cov}(\xi, \eta) = \mathbf{M}[(\xi - \mathbf{M}\xi)(\eta - \mathbf{M}\eta)] = \mathbf{M}[(\xi - a)(\eta - b)] = \mathbf{M}[\xi\eta - b\xi - a\eta + ab],$$

то используя теоремы 1-3, получаем формулу

$$\begin{aligned} \text{cov}(\xi, \eta) &= \mathbf{M}(\xi \cdot \eta) - b\mathbf{M}\xi - a\mathbf{M}\eta + ab = \\ &= \mathbf{M}(\xi \cdot \eta) - 2ab + ab = \mathbf{M}(\xi \cdot \eta) - ab = \mathbf{M}(\xi \cdot \eta) - \mathbf{M}\xi \cdot \mathbf{M}\eta, \end{aligned}$$

из которой, в силу теоремы 4 следует, что для пары (ξ, η) независимых случайных величин $\text{cov}(\xi, \eta) = 0$. Поэтому из формулы (3) вытекает, что

$$\text{если случайные величины } \xi \text{ и } \eta \text{ независимы, то } \mathbf{D}(\xi + \eta) = \mathbf{D}\xi + \mathbf{D}\eta. \quad (4)$$

Этот результат по индукции распространяется на сумму любого числа независимых слагаемых. Например, для случая трех независимых слагаемых, применив два раза свойство (4), получим

$$\mathbf{D}(\xi_1 + \xi_2 + \xi_3) = \mathbf{D}[(\xi_1 + \xi_2) + \xi_3] = \mathbf{D}[(\xi_1 + \xi_2)] + \mathbf{D}\xi_3 = \mathbf{D}\xi_1 + \mathbf{D}\xi_2 + \mathbf{D}\xi_3.$$

Таким образом, справедлива

Теорема 5. *Дисперсия суммы независимых случайных величин равна сумме дисперсий слагаемых, иначе*

$$\mathbf{D}(\xi_1 + \xi_2 + \dots + \xi_n) = \mathbf{D}\xi_1 + \mathbf{D}\xi_2 + \dots + \mathbf{D}\xi_n.$$

Замечание. Теорема 5 описывает очень полезное свойство дисперсии, которое во многом объясняет выбор последней, т.е. числа $\mathbf{D}\xi = \mathbf{M}(\xi - \mathbf{M}\xi)^2$, в качестве численной меры отклонения от математического ожидания. Можно показать, что для других столь же естественных мер отклонения, например

$$\mathbf{M}|\xi - \mathbf{M}\xi|, \quad \mathbf{M}|\xi - \mathbf{M}\xi|^3, \quad \mathbf{M}(\xi - \mathbf{M}\xi)^4,$$

свойство, состоящее в том, что отклонение суммы независимых случайных величин равно сумме отдельных отклонений, не имеет места.

Пример. (Модель (n, p) испытаний Бернулли). Введённое в примерах из § 9.1 число успехов S_n в n испытаниях Бернулли представляется в виде суммы n независимых одинаково распределённых случайных величин $\xi_1, \xi_2, \dots, \xi_n$ где $\xi_i, i = 1, 2, \dots, n$, принимает значения 1 или 0, регистрируя "успех" или "неудачу" в i -ом испытании. Следовательно,

$$S_n = \xi_1 + \xi_2 + \dots + \xi_n, \quad \text{где} \quad \text{Pr}\{\xi_i = 1\} = p, \quad \text{Pr}\{\xi_i = 0\} = 1 - p.$$

В § 10.1 были вычислены математическое ожидание $\mathbf{M}\xi_i = p$ и дисперсия $\mathbf{D}\xi_i = p(1 - p)$. Поэтому, в силу теорем 3 и 5, математическое ожидание числа успехов в n испытаниях Бернулли $\mathbf{M} S_n = np$, а дисперсия числа успехов $\mathbf{D} S_n = np(1 - p)$.

§ 12.2. Выборка, выборочные характеристики, закон больших чисел

В математической статистике *выборкой* объёма n с теоретическими (неизвестными) характеристиками: математическим ожиданием (средним значением) a , дисперсией σ^2 и функцией распределения $F(t)$, $-\infty < t < \infty$, называется совокупность из n наблюдений (x_1, x_2, \dots, x_n) (случайных величин), удовлетворяющих двум условиям.

- 1) Наблюдения (x_1, x_2, \dots, x_n) *независимы*.
- 2) Наблюдения (x_1, x_2, \dots, x_n) *однородны*, т.е. имеют *одинаковые* теоретические характеристики

$$a = \mathbf{M}x_i, \quad \sigma^2 = \mathbf{D}x_i = \mathbf{M}(x_i - a)^2, \quad F(t) = \text{Pr}\{x_i < t\}, \quad i = 1, 2, \dots, n,$$

где параметр $\sigma = \sqrt{\mathbf{D}x_i}$ называется теоретическим (неизвестным) среднеквадратичным отклонением выборки.

1. Для среднего арифметического значения наблюдений (x_1, x_2, \dots, x_n) , называемого *выборочным* (или *эмпирическим*) *средним*, введём стандартное обозначение

$$\bar{x} \stackrel{\text{def}}{=} \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}.$$

Отметим, что выборочное среднее является случайной величиной, значение которой вычисляется экспериментатором после проведения n опытов.

С помощью теорем 2, 3 и 5 находим

$$\mathbf{M}\bar{x} = \frac{1}{n} \sum_{i=1}^n \mathbf{M}x_i = \frac{na}{n} = a, \quad \mathbf{D}\bar{x} = \frac{1}{n^2} \sum_{i=1}^n \mathbf{D}x_i = \frac{n\sigma^2}{n^2} = \frac{\sigma^2}{n}, \quad \sqrt{\mathbf{D}\bar{x}} = \frac{\sigma}{\sqrt{n}}. \quad (5)$$

Другими словами, математическое ожидание $\mathbf{M}\bar{x}$ выборочного среднего совпадает с теоретическим средним выборки $a = \mathbf{M}x_i$, а среднеквадратичное отклонение $\sqrt{\mathbf{D}\bar{x}}$ выборочного среднего в \sqrt{n} раз меньше теоретического $\sigma = \sqrt{\mathbf{D}x_i}$.

При $n \rightarrow \infty$ имеем

$$\lim_{n \rightarrow \infty} \mathbf{D}\bar{x} = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0. \quad (6)$$

Согласно теореме 1, $\mathbf{D}\bar{x} = 0$ тогда и только тогда, когда $\bar{x} = \mathbf{M}\bar{x} = a$. Поэтому, опираясь на (6), мы можем сформулировать *связь* вычисляемого экспериментатором выборочного среднего \bar{x} и неизвестного экспериментатору теоретического среднего a в виде следующей теоремы, называемой в теории вероятностей *законом больших чисел*.

Теорема 6. (Закон больших чисел). *Если случайные величины x_1, x_2, \dots, x_n независимы, имеют одинаковые теоретические средние $\mathbf{M}x_i = a$ и одинаковые теоретические дисперсии $\mathbf{D}x_i = \sigma^2$, то при $n \rightarrow \infty$ их среднее арифметическое значение \bar{x} стремится к теоретическому среднему a , иначе*

$$\lim_{n \rightarrow \infty} \bar{x} = \lim_{n \rightarrow \infty} \frac{\sum_{i=1}^n x_i}{n} = a \quad \text{или} \quad \bar{x} \approx a \quad \text{при больших значениях } n. \quad (7)$$

Закон больших чисел (6)-(7) отражает давно отмеченное свойство реальных опытов, состоящее в том, что *в то время как результаты отдельных измерений x_1, x_2, \dots, x_n могут колебаться сильно, их средние арифметические \bar{x} обнаруживают гораздо большую устойчивость, т.е. мало меняются в различных сериях опытов.*

Пример. (Модель (n, p) испытаний Бернулли). Пусть при $i = 1, 2, \dots, n$ измерение $x_i = 0, 1$ регистрирует "успех ~ 1 " или "неудачу ~ 0 " в i -ом испытании Бернулли. Тогда число успехов $S_n = \sum_{i=1}^n x_i$, теоретическое среднее $a = \mathbf{M}x_i = p$ совпадает с вероятностью успеха в одном испытании, а выборочное среднее $\bar{x} = S_n/n$ есть *доля* числа успехов в n испытаниях. Таким образом, для модели (n, p) испытаний Бернулли закон больших чисел означает, что при $n \rightarrow \infty$ вычисляемая экспериментатором доля числа успехов в n испытаниях стремится к теоретической (неизвестной) вероятности успеха p в одном испытании:

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = \lim_{n \rightarrow \infty} \frac{\sum_{i=1}^n x_i}{n} = p.$$

Приближенное равенство (7) можно уточнить для частного случая *нормальной выборки*, в которой предполагается, что наблюдения x_1, x_2, \dots, x_n имеют вид

$$x_i \sim \mathcal{N}(a, \sigma) \quad \text{или} \quad x_i = a + \sigma \cdot \xi_i, \quad \text{где} \quad \xi_i \sim \mathcal{N}(0, 1), \quad i = 1, 2, \dots, n.$$

В силу свойства 5 из § 11.3., среднее арифметическое \bar{x} независимых величин x_i , имеющих нормальное распределение $\mathcal{N}(a, \sigma)$, также имеет нормальное распределение, т.е.

$$\bar{x} \sim \mathbf{M}\bar{x} + \sqrt{\mathbf{D}\bar{x}} \cdot \mathcal{N}(0, 1) = a + \frac{\sigma}{\sqrt{n}} \cdot \mathcal{N}(0, 1) \quad \text{или} \quad \frac{\bar{x} - a}{\sigma/\sqrt{n}} = \frac{(\bar{x} - a)\sqrt{n}}{\sigma} \sim \mathcal{N}(0, 1). \quad (8)$$

Пусть α , $1/2 < \alpha < 1$, – фиксированное число, называемое *уровнем значимости*. Введём число $x'_\alpha > 0$, определяемое как решение уравнения

$$\Pr \{ -x'_\alpha < \mathcal{N}(0, 1) < x'_\alpha \} = \int_{-x'_\alpha}^{x'_\alpha} \frac{1}{\sqrt{2\pi}} e^{-t^2/2} dt = 1 - \alpha$$

и называемое *двусторонним критическим значением* стандартного нормального распределения $\mathcal{N}(0, 1)$ для уровня значимости α . В силу (8) можем написать, что

$$\Pr \left\{ -x'_\alpha < \frac{(\bar{x} - a)\sqrt{n}}{\sigma} < x'_\alpha \right\} = 1 - \alpha \quad \text{или} \quad \Pr \left\{ \bar{x} - \frac{x'_\alpha \cdot \sigma}{\sqrt{n}} < a < \bar{x} + \frac{x'_\alpha \cdot \sigma}{\sqrt{n}} \right\} = 1 - \alpha. \quad (9)$$

Предположим, что среднеквадратичное отклонение σ известно экспериментатору. Тогда (9) показывает, что вычисляемый на основании среднего арифметического значения наблюдений x_1, x_2, \dots, x_n интервал

$$(a_\alpha^-; a_\alpha^+), \quad \text{где} \quad a_\alpha^- \stackrel{\text{def}}{=} \bar{x} - \frac{x'_\alpha \cdot \sigma}{\sqrt{n}}, \quad a_\alpha^+ \stackrel{\text{def}}{=} \bar{x} + \frac{x'_\alpha \cdot \sigma}{\sqrt{n}}, \quad \bar{x} = \frac{\sum_{i=1}^n x_i}{n},$$

накрывает неизвестное математическое ожидание a с вероятностью $1 - \alpha$. Такой интервал в математической статистике называется *доверительным интервалом* или *интервальной оценкой* параметра a с коэффициентом доверия (надёжностью), равным $1 - \alpha$. Отметим, что при фиксированном коэффициенте доверия $1 - \alpha$ длина доверительного интервала с ростом объёма наблюдений n уменьшается пропорционально $1/\sqrt{n}$.

2. Наряду со средним арифметическим значением \bar{x} , для выборки (x_1, x_2, \dots, x_n) вычисляют *выборочную (эмпирическую) функцию распределения*:

$$F_n(t) \stackrel{\text{def}}{=} \frac{\text{число наблюдений } x_i \text{ таких, что } x_i < t}{n}, \quad -\infty < t < \infty,$$

и *выборочную (эмпирическую) дисперсию*:

$$s^2 \stackrel{\text{def}}{=} \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n - 1} = \frac{1}{n - 1} \sum_{i=1}^n (x_i - \bar{x})^2.$$

Эти характеристики представляют собой *выборочные аналоги* теоретической функции распределения $F(t) = \Pr\{x_i < t\}$, $0 \leq F(t) \leq 1$, и теоретической дисперсии $\sigma^2 = \mathbf{D}x_i$. Как функция аргумента t , $-\infty < t < \infty$, $F_n(t)$ является ступенчатой функцией, меняющей свои значения в точках x_1, x_2, \dots, x_n .

Зафиксируем произвольное t , $-\infty < t < \infty$, и введём независимые одинаково распределённые случайные величины

$$\eta_i \stackrel{\text{def}}{=} \begin{cases} 1, & \text{если } x_i < t, \\ 0, & \text{если } x_i \geq t, \end{cases} \quad i = 1, 2, \dots, n,$$

среднее арифметическое значение которых равно $F_n(t)$, т.е.

$$F_n(t) = \frac{\eta_1 + \eta_2 + \dots + \eta_n}{n} = \frac{1}{n} \sum_{i=1}^n \eta_i. \quad (10)$$

Поскольку

$$\Pr\{x_i < t\} = F(t), \quad \Pr\{x_i \geq t\} = 1 - F(t),$$

то вероятностная функция $q_t(x)$, $-\infty < x < \infty$, задающая распределение вероятностей η_i , и её числовые характеристики имеют вид:

$$q_t(x) \stackrel{\text{def}}{=} \Pr\{\eta_i = x\} = \begin{cases} 1 - F(t), & \text{если } x = 0, \\ F(t), & \text{если } x = 1, \\ 0, & \text{для остальных } x, \end{cases}$$

$$\mathbf{M}\eta_i = \sum_x x q_t(x) = 0 \cdot (1 - F(t)) + 1 \cdot F(t) = F(t),$$

$$\mathbf{M}\eta_i^2 = \sum_x x^2 q_t(x) = 0^2 \cdot (1 - F(t)) + 1^2 \cdot F(t) = F(t),$$

$$\mathbf{D}\eta_i = \mathbf{M}\eta_i^2 - (\mathbf{M}\eta_i)^2 = F(t) - F(t)^2 = F(t)(1 - F(t)).$$

Теперь, учитывая (10) и закон больших чисел теоремы 6, мы можем описать *связь* между вычисляемой экспериментатором выборочной функцией распределения $F_n(t)$ и неизвестной экспериментатору теоретической функцией распределения $F(t)$:

если $n \rightarrow \infty$, то $\lim_{n \rightarrow \infty} F_n(t) = F(t)$ или $F_n(t) \approx F(t)$ при больших значениях n .

Можно проверить, что математическое ожидание $\mathbf{M}s^2 = \sigma^2$, а дисперсия $\mathbf{D}s^2 \rightarrow 0$, если $n \rightarrow \infty$. Следовательно, связь между выборочной дисперсией s^2 и теоретической дисперсией σ^2 имеет вид:

$$\lim_{n \rightarrow \infty} s^2 = \lim_{n \rightarrow \infty} \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \sigma^2$$

или $s^2 \approx \sigma^2$ при больших значениях n .

§ 12.3. Коэффициент корреляции и его свойства

Пусть (ξ, η) – произвольная пара случайных величин с совместным распределением $q(x, y)$ (дискретная модель) или плотностью совместного распределения $p(x, y)$ (непрерывная модель). Символами

$$a_\xi = \mathbf{M}\xi, \quad \sigma_\xi = \sqrt{\mathbf{D}\xi}, \quad a_\eta = \mathbf{M}\eta, \quad \sigma_\eta = \sqrt{\mathbf{D}\eta}$$

обозначим определённые в § 9 и рассматриваемые в § 11.1 математические ожидания и среднеквадратичные отклонения, характеризующие отдельные распределения случайных величин ξ и η . Введём безразмерные нормированные случайные величины

$$\xi^* = \frac{\xi - a_\xi}{\sigma_\xi}, \quad \eta^* = \frac{\eta - a_\eta}{\sigma_\eta},$$

для которых, согласно следствию из теоремы 2,

$$\mathbf{M}\xi^* = \mathbf{M}\eta^* = 0, \quad \mathbf{D}\xi^* = \mathbf{M}(\xi^*)^2 = \mathbf{D}\eta^* = \mathbf{M}(\eta^*)^2 = 1. \quad (11)$$

Определение. Количественной мерой связи случайных величин ξ и η служит числовая характеристика совместного распределения пары (ξ, η) , определяемая формулой

$$\begin{aligned} \rho = \rho(\xi, \eta) &\stackrel{\text{def}}{=} \mathbf{M}(\xi^* \cdot \eta^*) = \frac{\mathbf{M}[(\xi - a_\xi)(\eta - a_\eta)]}{\sigma_\xi \cdot \sigma_\eta} = \frac{\mathbf{M}(\xi \cdot \eta) - a_\xi \cdot a_\eta}{\sigma_\xi \cdot \sigma_\eta} = \\ &= \begin{cases} \sum_x \sum_y \frac{(x - a_\xi)(y - a_\eta)}{\sigma_\xi \cdot \sigma_\eta} q(x, y) & \text{для дискретной модели,} \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{(x - a_\xi)(y - a_\eta)}{\sigma_\xi \cdot \sigma_\eta} p(x, y) dx dy & \text{для непрерывной модели.} \end{cases} \end{aligned} \quad (12)$$

и называемая коэффициентом корреляции (или нормированной ковариацией) пары (ξ, η) .

Свойства коэффициента корреляции ρ описывает

Теорема 7. Справедливы следующие утверждения.

- 1) Если случайные величины ξ и η независимы, то коэффициент корреляции $\rho = 0$.
- 2) Имеют место неравенства $-1 \leq \rho \leq 1$.
- 3) Коэффициент корреляции $\rho = 1$ тогда и только тогда, когда

$$\eta^* = \xi^* \quad \text{или} \quad \frac{\eta - a_\eta}{\sigma_\eta} = \frac{\xi - a_\xi}{\sigma_\xi} \quad \text{или} \quad \eta = a_\eta + \frac{\sigma_\eta}{\sigma_\xi} \cdot (\xi - a_\xi),$$

т.е. если случайная величина η связана со случайной величиной ξ прямо пропорциональной линейной зависимостью.

- 4) Коэффициент корреляции $\rho = -1$ тогда и только тогда, когда

$$\eta^* = -\xi^* \quad \text{или} \quad \frac{\eta - a_\eta}{\sigma_\eta} = -\frac{\xi - a_\xi}{\sigma_\xi} \quad \text{или} \quad \eta = a_\eta - \frac{\sigma_\eta}{\sigma_\xi} \cdot (\xi - a_\xi),$$

т.е. если случайная величина η связана со случайной величиной ξ обратно пропорциональной линейной зависимостью.

Доказательство.

- 1) Это утверждение является следствием теоремы 4.
- 2) Для любого значения x , $-\infty < x < \infty$, число

$$f(x) \stackrel{\text{def}}{=} \mathbf{M}(\eta^* - x \cdot \xi^*)^2,$$

определяемое как математическое ожидание от неотрицательной случайной величины, также является неотрицательным, т.е. $f(x) \geq 0$. Поэтому, применяя свойства математического ожидания из теорем 1-3, равенства (11) и определение коэффициента корреляции $\rho = \mathbf{M}(\xi^* \cdot \eta^*)$ из (12), можем написать

$$\begin{aligned} 0 \leq f(x) &= \mathbf{M}(\eta^* - x \cdot \xi^*)^2 = \mathbf{M} \left[(\eta^*)^2 - 2x \cdot \xi^* \cdot \eta^* + x^2 \cdot (\eta^*)^2 \right] = \\ &= \mathbf{M}(\eta^*)^2 - 2x \cdot \mathbf{M}(\xi^* \cdot \eta^*) + x^2 \cdot \mathbf{M}(\eta^*)^2 = 1 - 2x\rho + x^2. \end{aligned}$$

Следовательно, для любого действительного значения x , $-\infty < x < \infty$, квадратный трёхчлен $1 - 2x\rho + x^2 \geq 0$. Отсюда вытекает, что

корни (x_1, x_2) уравнения $1 - 2x\rho + x^2 = 0$, имеющие вид $x_{1,2} = \rho \pm \sqrt{\rho^2 - 1}$,

либо являются мнимыми, если $\rho^2 - 1 < 0$, либо совпадают между собой, если $\rho^2 - 1 = 0$. Это возможно лишь при условии $\rho^2 - 1 \leq 0$, которое равносильно доказываемому утверждению.

- 3) Случай $\rho = 1$ равносильно тому, что $x_1 = x_2 = 1$. Иначе,

$$f(1) = 0 \quad \text{или} \quad \mathbf{M}(\eta^* - \xi^*)^2 \quad \text{или} \quad \eta^* = \xi^*.$$

- 4) Случай $\rho = -1$ равносильно тому, что $x_1 = x_2 = -1$. Иначе,

$$f(-1) = 0 \quad \text{или} \quad \mathbf{M}(\eta^* + \xi^*)^2 \quad \text{или} \quad \eta^* = -\xi^*.$$

Теорема доказана.

§ 12.4. Линейная модель корреляции признаков

Пусть случайная величина (признак) η и случайная величина (признак) ξ имеют числовые характеристики

$$a_\xi = \mathbf{M}\xi, \quad \sigma_\xi = \sqrt{\mathbf{D}\xi}, \quad a_\eta = \mathbf{M}\eta, \quad \sigma_\eta = \sqrt{\mathbf{D}\eta},$$

а ρ , $-1 \leq \rho \leq 1$, — произвольное фиксированное число. Для статистического анализа связи признаков η и ξ , измеряемой коэффициентом корреляции

$$\rho = \mathbf{M} \left\{ \frac{\eta - a_\eta}{\sigma_\eta} \cdot \frac{\xi - a_\xi}{\sigma_\xi} \right\} = \mathbf{M}(\xi^* \cdot \eta^*), \quad \text{где} \quad \xi^* = \frac{\xi - a_\xi}{\sigma_\xi}, \quad \eta^* = \frac{\eta - a_\eta}{\sigma_\eta},$$

удобно применять следующую запись:

$$\frac{\eta - a_\eta}{\sigma_\eta} = A \cdot \frac{\xi - a_\xi}{\sigma_\xi} + B \cdot \delta \quad \text{или} \quad \eta^* = A \cdot \xi^* + B \cdot \delta, \quad (13)$$

в которой символы A и B обозначают постоянные (неслучайные) величины, а символ δ обозначает случайную величину, удовлетворяющую условиям:

- δ – безразмерная случайная величина, которая *не зависит от* ξ ;
- δ – *нормированная* случайная величина, т.е. $\mathbf{M}\delta = 0$ и $\mathbf{D}\delta = \mathbf{M}\delta^2 = 1$.

”Линейная” форма связи (13) между признаками η и ξ , называется *линейной корреляцией признаков*. Отметим, что линейной корреляции признаков η и ξ соответствует специальный *частный случай* совместного распределения $q(x, y)$ (дискретная модель) или плотности совместного распределения $p(x, y)$ (непрерывная модель) пары признаков (ξ, η) .

Чтобы найти в соотношениях (13) зависимость чисел A и B от коэффициента корреляции ρ , представим с помощью (13) случайные величины $(\eta^*)^2$ и $\eta^* \cdot \xi^*$ в виде

$$(\eta^*)^2 = A^2 \cdot (\xi^*)^2 + B^2 \cdot \delta^2 + 2AB \cdot \xi^* \cdot \delta, \quad \eta^* \cdot \xi^* = A \cdot (\xi^*)^2 + B \cdot \delta \cdot \xi^*.$$

Рассмотрим математические ожидания этих величин. Применяя свойства математического ожидания из теорем 1-3, равенства (11), определение коэффициента корреляции $\rho = \mathbf{M}(\xi^* \cdot \eta^*)$ из (12) и свойства случайной величины δ , можем написать

$$\begin{aligned} 1 &= \mathbf{M}(\eta^*)^2 = A^2 \cdot \mathbf{M}(\xi^*)^2 + B^2 \cdot \mathbf{M}\delta^2 + 2AB \cdot \mathbf{M}\{\xi^* \cdot \delta\} = \\ &= A^2 \cdot 1 + B^2 \cdot 1 + 2AB \cdot \mathbf{M}\xi^* \cdot \mathbf{M}\delta = A^2 + B^2 + 2AB \cdot 0 \cdot 0 = A^2 + B^2, \\ \rho &= \mathbf{M}(\eta^* \cdot \xi^*) = A \cdot \mathbf{M}(\xi^*)^2 + B \cdot \mathbf{M}\{\xi^* \cdot \delta\} = A \cdot 1 + B \cdot 0 = A. \end{aligned}$$

Из доказанных равенств $A^2 + B^2 = 1$ и $A = \rho$ получаем, что $B = \sqrt{1 - \rho^2}$. Следовательно, в соотношениях (13) зависимость чисел A и B от коэффициента корреляции ρ имеет вид

$$A = \rho, \quad B = \sqrt{1 - \rho^2}.$$

Другими словами, линейная корреляция признаков η и ξ с коэффициентом корреляции ρ записывается в виде:

$$\frac{\eta - a_\eta}{\sigma_\eta} = \rho \cdot \frac{\xi - a_\xi}{\sigma_\xi} + \sqrt{1 - \rho^2} \cdot \delta, \quad \text{или} \quad \eta^* = \rho \cdot \xi^* + \sqrt{1 - \rho^2} \cdot \delta,$$

где символ δ обозначает случайную величину, удовлетворяющую условиям:

- δ – безразмерная случайная величина, которая *не зависит от* ξ ;
- δ – *нормированная* случайная величина, т.е. $\mathbf{M}\delta = 0$ и $\mathbf{D}\delta = \mathbf{M}(\delta)^2 = 1$.

В математической статистике данная форма описания связи наблюдений (случайных величин) η и ξ называется *линейной моделью корреляционного анализа*.

Оглавление

- § 1. Предмет теории вероятностей (стр. 1).
- § 2. Модель случайного эксперимента с конечным числом исходов (стр. 1).
- § 3. Правила перевода (стр. 2).
- § 4. Комбинаторика и вероятность (стр. 4).
 - § 4.1. Определения и примеры (стр. 4).
 - § 4.2. Биномиальные вероятности (стр. 6).
- § 5. Модель (n, p) - испытаний Бернулли (стр. 8).
- § 6. Операции над событиями, закон сложения вероятностей (стр. 10).
- § 7. Модель (2×2) -таблицы (стр. 11).
- § 8. Связь событий, условная вероятность, независимость (стр. 13).
- § 9. Гипергеометрические вероятности для (2×2) -таблиц сопряжённости в случае независимых признаков (стр. 15).
- § 10. Случайные величины и распределения вероятностей (стр. 17).
 - § 10.1. Дискретная модель (стр. 17).
 - § 10.2. Непрерывная модель (стр. 21).
- § 11. Совместное распределение случайных величин, независимость случайных величин (стр. 24).
 - § 11.1. Дискретная модель (стр. 24).
 - § 11.2. Непрерывная модель (стр. 25).
 - § 11.3. Совместное распределение n случайных величин $(\xi_1, \xi_2, \dots, \xi_n)$ (стр. 27).
- § 12. Числовые характеристики распределения вероятностей (стр. 29).
 - § 12.1. Математическое ожидание, дисперсия и их свойства (стр. 29).
 - § 12.2. Выборка, выборочные характеристики, закон больших чисел (стр. 33).
 - § 12.3. Коэффициент корреляции и его свойства (стр. 37).
 - § 12.4. Линейная модель корреляции признаков (стр. 38).