



Занятие 22. 4 апреля

Иван Высоцкий

Дисперсия случайной величины

На этом занятии было немного задач. Основное время было посвящено рассказу про дисперсию и стандартное отклонение случайной величины.

Обычно найти математическое ожидание случайной величины недостаточно, чтобы понять, какие ее значения следует считать вполне вероятными, а какие – маловероятными. Важно понять, каким может быть отклонение значений от среднего. Например, можно найти среднее отклонение:  $E|X - EX|$ . Это совсем не плохо, но свойства этой величины оказываются не слишком удобными – во многом мешает модуль.

Зато, если рассматривать не средний модуль, а средний квадрат отклонения, получается *дисперсия*:

$$DX = E(X - EX)^2, \tag{1}$$

которая обладает целым рядом удобных и полезных свойств. Например, есть более простая формула:

$$DX = EX^2 - E^2 X \tag{2}$$

– дисперсия равна среднему квадрату без квадрата среднего. Получается эта формула простыми преобразованиями: нужно возвести в квадрат скобку  $(X - EX)$  и аккуратно привести подобные, ничего не перепутав.

Вторая особенность дисперсии: часто ее можно находить по слагаемым. А именно:

$$D(X + Y) = DX + DY, \tag{3}$$

если только случайные величины  $X$  и  $Y$  независимы. Это свойство также несложно получить с помощью формулы (2). В ходе выкладок нужно воспользоваться свойством  $E(XY) = EX \cdot EY$ , которое верно только для независимых величин. Отсюда и требование независимости.

**Пример 1. Биномиальное распределение.** Проведено  $n$  независимых и одинаковых испытаний. Вероятность успеха в каждом равна  $p$ . Найти математическое ожидание и дисперсию числа наступивших успехов.

**Решение.** Пусть  $S$  – число успехов, а  $I_k$  – индикатор успеха в испытании номер  $k$ .

$$I_k \sim \begin{pmatrix} 0 & 1 \\ q & p \end{pmatrix},$$

тогда  $E I_k = p$  для всех индикаторов, и

$$ES = E I_1 + E I_2 + \dots + E I_n = np.$$

Индикаторы независимы, поскольку результаты испытаний по условию не связаны. Следовательно, в силу (3)

$$DS = D(I_1 + I_2 + \dots + I_n) = D I_1 + D I_2 + \dots + D I_n = n D I_1.$$

Чтобы найти дисперсию одного индикатора, воспользуемся формулой (2):

$$D I_1 = E I_1^2 - E^2 I_1 = E I_1 - E^2 I_1 = p - p^2 = pq.$$

Здесь буквой  $q$ , как обычно, обозначена вероятность неудачи:  $q = 1 - p$ . В выкладках использовано, что  $I_1^2 = I_1$  (поскольку  $0^2 = 0, 1^2 = 1$ ).

Следовательно,  $DS = npq$ .

Недостаток дисперсии в том, что она измеряется в квадратных единицах. Например, если  $X$  – расстояние в метрах, то  $DX$  измеряется в квадратных метрах, с чем можно смириться. Но вот если  $X$  – угол в градусах, то  $DX$  выражается в квадратных градусах, что очень загадочно. Чтобы получить меру рассеивания, выраженную в тех же единицах, что и исходная величина, можно извлечь квадратный корень из дисперсии и получить так называемое *стандартное отклонение*. Если вдуматься, то понятно, что стандартное отклонение всегда не меньше, чем средний модуль отклонения  $E|X - EX|$ , но все равно оно может использоваться в качестве типичного отклонения. Часто стандартное отклонение используют в качестве единицы для измерения отклонений.

В серии независимых испытаний из примера 1 стандартное отклонение равно<sup>1</sup>

$$\sigma = \sqrt{DS} = \sqrt{npq}.$$

Например, если монету бросают 10 раз, то стандартное отклонение числа орлов равно

$$\sigma = \sqrt{10 \cdot 0,5 \cdot 0,5} \approx 1,58.$$

Разумно договориться, что в однократном испытании не следует рассчитывать на отклонения, превышающие  $3\sigma$ , поскольку такие отклонения слишком маловероятны (и это соглашение почти в любом случае имеет смысл, как мы увидим в дальнейшем).

Значит, бросая 10 монет, разумно рассчитывать на число орлов от

$$ES - 3\sigma = 5 - 3 \cdot 1,58 \approx 0,26 \quad \text{до} \quad ES + 3\sigma = 5 + 3 \cdot 1,58 \approx 9,74,$$

то есть в реальности нужно взять в расчет все возможные значения от 1 до 9, а вот в 0 или в 10 орлов верить не следует (это случается слишком редко). Таким образом, имеется большая неопределенность: примерно 82% всех возможных исходов вероятны.

А что, если монет 100? Диапазон разумного ожидания, конечно, расширяется, но мало по сравнению с ростом числа бросков. При том же соглашении будем ждать от

$$ES - 3\sigma = 50 - 3 \cdot 5 = 35 \quad \text{до} \quad ES + 3\sigma = 50 + 3 \cdot 5 = 65$$

орлов. Длина диапазона теперь  $65 - 35 + 1 = 31$ , что составляет уже 31% от всех теоретически возможных исходов.

Если монет 1000? Посчитайте самостоятельно: разумно ждать от 453 до 547 орлов, то есть всего 9,5% от всего возможного множества значений.

Видим, что доля вероятных значений уменьшается с ростом числа опытов. Долю вероятных значений можно сделать сколь угодно малой, увеличивая число испытаний, и это – очень важное свойство, которое лежит в основе почти всех статистических измерений. Так происходит оттого, что стандартное отклонение пропорционально не числу испытаний  $n$ , а величине  $\sqrt{n}$ , которая растет намного медленнее, чем само  $n$ .

Вычислим дисперсию и стандартное отклонение в другом важном опыте – стрельба до первого попадания.

**Пример 2. Геометрическое распределение.** Производятся одинаковые независимые испытания с вероятностью  $p$  успеха в каждом до тех пор, пока не наступит первый успех. Найти математическое ожидание, дисперсию и стандартное отклонение.

<sup>1</sup> Мы использовали греческую букву  $\sigma$  «сигма», которой часто обозначают стандартное отклонение в разных задачах, но это всего лишь наше соглашение, а не правило.

**Решение.** Пусть  $X$  – число испытаний, а  $I_k$  – индикатор неудачи в испытании номер  $k$ . Тогда  $X = 1 + I_1 + I_2 + I_3 + \dots$

Распределения индикаторов найти легко:

$$I_k \sim \begin{pmatrix} 0 & 1 \\ 1-q^k & q^k \end{pmatrix},$$

откуда  $E I_k = q^k$ . Следовательно,

$$E X = 1 + E I_1 + E I_2 + E I_3 + \dots = 1 + q + q^2 + q^3 + \dots = \frac{1}{1-q} = \frac{1}{p}.$$

Результат согласуется с интуицией: если вероятность везения  $1/10$ , то в среднем требуется 10 попыток, чтобы добиться успеха. Но вот что с дисперсией и отклонениями? Так ли уж тут хорошо работает интуиция?

К сожалению, индикаторы в этой задаче зависимы: если успех не случился в какой-то попытке, то и во всех предыдущих успеха тоже не было. Поэтому воспользоваться формулой (3) суммирования дисперсий нельзя. Придется идти более сложным путем.

Применим формулу (2). Величина  $E X$  нам известна. Осталось найти  $E X^2$ :

$$X^2 = (1^2 + I_1^2 + I_2^2 + I_3^2 + \dots) + (2I_1 + 2I_2 + 2I_3 + \dots) + \\ + (2I_1I_2 + 2I_1I_3 + 2I_1I_4 + \dots) + (2I_2I_3 + 2I_2I_4 + 2I_2I_5 + \dots) + \dots + 2I_mI_n + \dots$$

Получается бесконечная сумма всех квадратов, потом удвоенных индикаторов и, наконец, удвоенных произведений всех пар индикаторов вида  $2I_mI_n$ , где  $m < n$ . Заметим, что  $I_k^2 = I_k$  и что  $I_mI_n = I_n$  при  $m < n$  (уже отмечалось, что если в  $n$ -м испытании неудача, то во всех предыдущих тоже). Тогда

$$X^2 = (1 + I_1 + I_2 + I_3 + \dots) + (2I_1 + 2I_2 + 2I_3 + \dots) + \\ + (2I_2 + 2I_3 + 2I_4 + \dots) + \\ + (2I_3 + 2I_4 + 2I_5 + \dots) + \dots = \\ = (1 + I_1 + I_2 + I_3 + \dots) + 2(I_1 + 2I_2 + 3I_3 + \dots).$$

Перейдем к ожиданию:

$$E X^2 = (1 + q + q^2 + q^3 + \dots) + 2(q + 2q^2 + 3q^3 + \dots) = \frac{1}{p} + 2 \frac{q}{p} (p + 2qp + 3q^2p + \dots).$$

Выражение в скобках – математическое ожидание  $E X$ . Поэтому

$$E X^2 = \frac{1}{p} + 2 \frac{q}{p} E X = \frac{1}{p} + 2 \frac{q}{p^2} = \frac{p + 2q}{p^2} = \frac{2-p}{p^2}.$$

Тогда

$$D X = E X^2 - E^2 X = \frac{2-p}{p^2} - \frac{1}{p^2} = \frac{q}{p^2}.$$

Стандартное отклонение равно  $\sigma = \sqrt{D X} = \frac{\sqrt{q}}{p}$ .

При малых вероятностях успеха  $p$  число  $\frac{\sqrt{q}}{p}$  близко к единице. Поэтому вполне вероятно, что ждать первого успеха придется долго. В этой задаче математическое ожидание – весьма ненадежный ориентир. Например, если мы захотим узнать, сколько дать патронов стрелку, чтобы он с большой вероятностью поразил цель при вероятности попадания  $0,1$

при каждом выстреле, нужно вычислить величину  $E X + 3\sigma$  (как прежде, считаем вероятными значения, удаленные от среднего не больше чем на три стандартных отклонения).

Получаем:  $\frac{1}{0,1} + 3 \cdot \frac{\sqrt{0,9}}{0,1} \approx 10 + 3 \cdot 10 \cdot 0,95 = 38,5$ . То есть стрелка придется снабдить 39 па-

тронами, не рассчитывая на то, что число выстрелов будет близко к ожидаемым десяти.

**Пример 3. Гипергеометрическое распределение.** Из урны, в которой  $N$  шаров, из них  $k$  черных, а остальные – белые, наудачу вынимают  $n$  шаров. Найти математическое ожидание, дисперсию и стандартное отклонение случайной величины  $X$  «Число черных шаров среди вынутых».

**Указание.** Если вы разобрались в примере 2, то задача не покажется вам сложной. Нужно только учесть характер зависимости индикаторов. Скорее, трудности будут с алгебраическими преобразованиями в конце.

**Ответ:**  $E X = n \frac{k}{N}$ .  $D X = \frac{kn(N-n)(N-k)}{N^2(N-1)}$ .