

*Все вероятности равны 50%. Либо случится, либо нет.
Мерфология, Логические предложения Кольварда*

Типовые распределения



Johann Carl Friedrich Gauß

При проверке гипотез широкое применение находят ряд теоретических законов распределения. Наиболее важным из них является нормальное распределение. С ним связаны распределения хи-квадрат, Стьюдента, Фишера, а также интеграл вероятностей. Для указанных законов функции распределения аналитически в простой форме не представимы и определяются с использованием стандартных процедур прикладных программ.

П1.1. Нормальное распределение

Нормальное распределение занимает важное место в статистике, поскольку очень многие эмпирические распределения биологических признаков приближаются к нему.




Рис. П1.1. Нормальная вариационная кривая

Размещение вариантов в вариационном ряду при нормальном распределении характеризуется определенными закономерностями. В частности, в нормальной кривой отклонения от средней арифметической охватывают приблизительно 6 σ : 3 σ справа от средней и 3 σ слева.

Зная вариационную кривую распределения вариант по тому или иному признаку и предполагая, что распределение является нормальным, можно заранее предсказать, какой процент изученных особей (или вариант) укладывается в пределах $\pm 1\sigma$; в пределах $\pm 2\sigma$; в пределах $\pm 3\sigma$. А именно, в пределах

$\pm 1\sigma$ располагается 68,3% всех вариант данного ряда;

$\pm 2\sigma$ – 95,5% и в пределах $\pm 3\sigma$ – 99,7% всех вариант.

Например, при исследовании размеров раковин моллюсков рода *Benedictia* были получены следующие данные (мм): 32, 35, 37, 45, 41, 35, 39, 39, 45, 41. "Перенос" данных на генеральную совокупность позволяет предположить (рис. П1.2), что 68% популяции будут иметь средний размер раковины плюс-минус одно стандартное отклонение $\bar{x} \pm 1\sigma$, т.е. размеры раковин будут лежать в интервале от 34,62 до 43,18 мм.




Рис. П1.2. Нормальное распределение значений размеров раковин у моллюсков *Benedictia* вокруг среднего

Около 98% популяции будет иметь размер раковины 38,9 плюс-минус два стандартных отклонения (8, 56), т.е. размер раковины будет лежать в интервале (30,34÷47,46) мм, и практически 100% будут лежать в интервале плюс-минус три стандартных отклонения от 38,9.

Нормальное распределение является наиболее важным в связи с центральной предельной теоремой теории вероятностей: распределение суммы независимых случайных величин стремится к нормальному с увеличением их количества при произвольном законе распределения отдельных слагаемых, если слагаемые обладают конечной дисперсией.

Так как реальные физические, химические, биологические явления часто представляют собой результат суммарного воздействия многих факторов, то в таких случаях нормальное распределение является хорошим приближением наблюдаемых значений. Функция плотности нормального распределения

$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \bar{x})^2}{2\sigma^2}\right)$$

– унимодальная, симметричная, аргумент x может принимать любые действительные значения (см. рис. П1.3).

Стандартизирующее преобразование. Если случайная величина X имеет известное математическое ожидание μ и дисперсию σ^2 то случайная величина $Y=X-\mu$ называется центрированной, величина $Y=\ X/\sigma$ – нормированной, а $Y=(X-\mu)/\sigma$ – стандартизированной. Последнее преобразование называется стандартизирующим и используется на практике для получения стандартизированных выборок (в качестве значений μ и σ обычно берутся выборочные среднее и стандартное отклонение). Для выполнения этого преобразования в Excel есть специальная функция НОРМАЛИЗАЦИЯ($x; \bar{x}; \sigma$) {STANDARDIZE ($x; \bar{x}; \sigma$)}.

Отметим, что стандартизирующее преобразование не изменяет тип распределения, а изменяет только значения математического ожидания и дисперсии.

Функция плотности нормального распределения стандартизированной величины u имеет вид $f(u) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right)$.

	A	B	C	D	E	F	G	H	I
1	ПЛОТНОСТЬ НОРМАЛЬНОГО РАСПРЕДЕЛЕНИЯ								
2									
3	x	P(x,σ=1)	P(x,σ=1,5)						
4	-3,00	0,004	0,036	← =1/КОРЕНЬ(2*ПИ())/F\$13/EXP(((A4-F\$11)/F\$13)^2/2)					
5	-2,75	0,009	0,050						
6	-2,50	0,018	0,066						
7	-2,25	0,032	0,086						
8	-2,00	0,054	0,109						
9	-1,75	0,086	0,135						
10	-1,50	0,130	0,161						
11	-1,25	0,183	0,188						
12	-1,00	0,242	0,213						
13	-0,75	0,301	0,235						
14	-0,50	0,352	0,252						
15	-0,25	0,387	0,262						
16	0,00	0,399	0,266						
17	0,25	0,387	0,262						
18	0,50	0,352	0,252						
19	0,75	0,301	0,235						
20	1,00	0,242	0,213						
21	1,25	0,183	0,188						
22	1,50	0,130	0,161						
23	1,75	0,086	0,135						
24	2,00	0,054	0,109						
25	2,25	0,032	0,086						
26	2,50	0,018	0,066						
27	2,75	0,009	0,050						
28	3,00	0,004	0,036						

$$P(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x - \bar{x})^2}{2\sigma^2}\right)$$

\bar{x}	= 0,00
σ_1	= 1,00
σ_2	= 1,50




Рис. П1.3. Плотность вероятности нормального распределения

П1.2. Распределение χ^2 хи-квадрат

Распределению хи-квадрат (χ^2 -распределение) с k степенями свободы соответствует распределение суммы $\chi^2 = \sum u_i^2$ квадратов n стандартизованных случайных величин u_i , каждая из которых распределена по нормальному закону, причем k из них независимы, $n > k$. Функция плотности распределения χ^2 с k степенями свободы

$$P(x) = \frac{1}{2^{k/2}\Gamma(k/2)} x^{(k/2-1)} \exp\left(-\frac{x}{2}\right), \quad \text{где } x = \chi^2, \quad \Gamma(z) = \int_0^{+\infty} x^{z-1} e^{-x} dx$$

– гамма-функция.

Число степеней свободы k определяет количество независимых слагаемых в выражении для χ^2 . Функция плотности при k , равном одному или двум, – монотонная, а при $k > 2$ – унимодальная, несимметричная, рис. П1.4.

Математическое ожидание и дисперсия величины χ^2 равны соответственно k и $2k$. Распределение χ^2 является частным случаем более общего гамма-распределения, а величина, равная корню квадратному из хи-квадрат с двумя степенями свободы, подчиняется распределению Рэлея.

С увеличением числа степеней свободы ($k > 30$) распределение χ^2 приближается к нормальному распределению с математическим ожиданием k и дисперсией $2k$. В таких случаях критическое значение $\chi^2(k; \alpha) \gg u_{1-\alpha}(k, 2k)$, где $u_{1-\alpha}(k, 2k)$ – квантиль нормального распределения. Погрешность аппроксимации не превышает нескольких процентов.




Рис. П1.4. Распределения плотности вероятности χ^2

П1.3. Распределение Стьюдента

Распределение Стьюдента (t -распределение, предложенное в 1908 г. английским статистиком В. Госсетом, опубликовавшим научные труды под псевдонимом *Student*) характеризует распределение случайной величины $t = \frac{u_0}{\sqrt{(u_1^2 + u_2^2 + \dots + u_k^2)/k}}$, где u_0, u_1, \dots, u_k

взаимно независимые нормально распределенные случайные величины с нулевым средним и конечной дисперсией.

Аргумент t не зависит от дисперсии слагаемых. Функция плотности распределения Стьюдента

$$P(t) = \frac{1}{\sqrt{\pi k}} \frac{\Gamma\left(\frac{k+1}{2}\right)}{\Gamma\left(\frac{k}{2}\right)} \left[1 + \frac{t^2}{k}\right]^{-\frac{k+1}{2}}.$$

Величина k характеризует количество степеней свободы. Плотность распределения – унимодальная и симметричная функция, похожая на нормальное распределение, рис. П1.5.

Область изменения аргумента t от $-\infty$ до $+\infty$. Математическое ожидание и дисперсия равны (при $k > 2$) 0 и $k/(k-2)$ соответственно. По сравнению с нормальным распределением Стьюдента более пологое, оно имеет меньшую дисперсию. Это отличие заметно при небольших значениях k , что следует учитывать при проверке статистических гипотез (критические значения аргумента распределения Стьюдента превышают аналогичные показатели нормального распределения).




Рис. П1.5. Распределения плотности вероятности Стьюдента

Таблицы распределения (и возвращаемые значения функций электронных таблиц) содержат значения для односторонней $\int_{t(k;\alpha)}^{\infty} f(t)dt = \alpha$ или двусторонней $\int_{-t(k;\alpha)}^{t(k;\alpha)} f(t)dt = \alpha$ критической области.

Распределение Стьюдента применяется для описания ошибок выборки при $k < 30$. При $k > 100$ данное распределение практически соответствует нормальному, для $30 < k < 100$ различия между распределением Стьюдента и нормальным распределением составляют несколько процентов. Поэтому относительно оценки ошибок малыми считаются выборки объемом не более 30 единиц, большими – объемом более 100 единиц. При аппроксимации распределения Стьюдента нормальным распределением для односторонней критической области вероятность

$$P\{t > t(k; \alpha)\} = u_{1-\alpha} \left(0, \frac{k}{k-2}\right),$$

где $u_{1-\alpha} \left(0, \frac{k}{k-2}\right)$ – квантиль нормального распределения. Аналогичное соотношение можно составить и для двусторонней критической области.

П1.4. Распределение Фишера

Распределению Фишера (F -распределению Фишера – Снедекора) подчиняется случайная величина $x = \frac{y_1/k_1}{y_2/k_2}$, равная отношению двух случайных величин y_1 и y_2 , имеющих хи-квадрат распределение с k_1 и k_2 степенями свободы. Область изменения аргумента x от 0 до $+\infty$. Плотность распределения

$$P(x) = \left(\frac{k_1}{k_2}\right)^{k_1/2} \frac{\Gamma\left(\frac{k_1 + k_2}{2}\right)}{\Gamma\left(\frac{k_1}{2}\right)\Gamma\left(\frac{k_2}{2}\right)} x^{(k_1-2)/2} \left(1 + \frac{k_1}{k_2}x\right)^{-(k_1+k_2)/2}.$$

В этом выражении k_1 обозначает число степеней свободы величины y_1 с большей дисперсией, k_2 – число степеней свободы величины y_2 с меньшей дисперсией. Плотность распределения – унимодальная, несимметричная (см. рис. П1.6).

Аналогами используемых в приведенных построениях функций русифицированных сред являются следующие английские.

квадратный корень	КОРЕНЬ(...)	SQRT(...)
число π	ПИ()	PI()
натуральный логарифм гамма-функции	ГАММАНЛОГ(...)	GAMMALN(...)




Рис. П1.6. Распределения плотности вероятности Фишера