

## **9.2. Критерии проверки гипотез о законах распределения случайной величины.**

# 9.2.1. Критерий А.Н. Колмогорова

Критерий А.Н. Колмогорова применяется для проверки простой гипотезы  $H_0$  о том, что независимые одинаково распределенные случайные величины  $X_1, X_2, \dots, X_n$  имеют заданную непрерывную функцию распределения  $F(x)$ .

Требуется принять или отклонить эту гипотезу по реализации случайной выборки независимых измерений. Для решения этой задачи введем статистику  $T(X^n)$  критерия проверки гипотезы  $H$ . Реализация  $t$  статистики  $T$  соответствующая выборке  $x^n$  определяется по формуле

$$t = \sup_{(x)} |F^*(x) - F(x)|$$

Доказано, что  $(H - \text{истинна}) \Rightarrow (T=D)$ . Здесь  $D$  – случайная величина, распределенная по известному закону Колмогорова. Для этой величины можно найти  $t_\alpha$  из условия:

$$P(D \geq t_\alpha) = \alpha, \quad (*)$$

где  $\alpha$  - вероятность практически невозможного события, и следовательно, событие  $(D \geq t_\alpha)$  - практически невозможное.

С точностью до принципа практической уверенности имеем:

$$(H - \text{истинна}) \Rightarrow (t < t_{\alpha});$$

$$(t \geq t_{\alpha}) \Rightarrow (H - \text{ложна}).$$

Из этих соотношений следует, что неравенство  $(t < t_{\alpha})$  необходимо для принятия, а неравенство  $(t \geq t_{\alpha})$  достаточно для отклонения гипотезы  $H$  (с точностью до принципа практической уверенности).

Руководствуясь этими соображениями, принимают следующее правило решения поставленной задачи:

$$(t < t_{\alpha}) \Rightarrow (H - \text{принять});$$

$$(t \geq t_{\alpha}) \Rightarrow (H - \text{отклонить}).$$

Это правило называют критерием согласия Колмогорова проверки гипотезы о непрерывной функции распределения случайной величины.

Алгоритм:

- 1) Провести независимые  $n$ -кратные измерения СВ  $X$  с непрерывной функцией распределения и получить выборку  $x^n$ ;
- 2) Исключить из выборки грубые ошибки;

- 3) Построить реализацию  $F^*(x)$  статистической ФР;
- 4) Выдвинуть гипотезу  $F(x)$  о ФР СВ  $X$ ;
- 5) Вычислить параметр  $t$ .
- 6) Задать вероятность  $\alpha$  практически невозможного события и из таблицы распределения Колмогорова найти параметр  $t_\alpha$  как решение уравнения (\*).
- 7) Принять или отклонить гипотезу  $H=(X \in F(x))$  по решающему правилу.

Доказано, что критерий А.Н. Колмогорова состоятельный и в общем случае смещенный.

Он более чувствителен к различию гипотез, поэтому при прочих равных условиях может применяться для меньших объемов выборки. Поскольку результат проверки признака критерия  $t$  зависит от наибольших различий  $F(x)$  и  $F^*(x)$ , то нет необходимости построения  $F(x)$  и  $F^*(x)$  на всем диапазоне изменения  $x$ ; достаточно ограничиться областями наибольших различий  $F(x)$  и  $F^*(x)$ .

Недостатком критерия является то, что точность его выводов нарушается, если в формулировании гипотезы о  $F(x)$  используются характеристики эмпирических распределений, т.к. в этом случае статистика  $T$  зависит от  $F(x)$ ; неудобство доставляет также значительная трудоемкость построения статистики Колмогорова А.Н.

## 9.2.2. Критерий Пирсона

Критерий Пирсона (критерий  $\chi^2$ ) используется для проверки гипотезы о различных законах распределения с применением статистики:

$$T(X^n) = \sum_{j=1}^q (N_j - np_j)^2 / np_j = \sum_{j=1}^q N_j^2 / np_j - n$$

Здесь  $N_j$  – число  $X_i$  в разряде  
статистического ряда,  $q$  – число разрядов.

Решающее правило состоит в следующем:  
если  $p_j$  удовлетворяет неравенству

$$\sum_{j=1}^q \frac{n_j^2}{np_j} - n \geq t_\alpha$$

то гипотеза  $H$  отвергается, в противном  
случае  $H$  принимается.

Алгоритм:

- 1) по выборке  $x^n$ , освобожденной от ошибок, строим статистический ряд, предварительно задав число разрядов  $q$  и установив границы разрядов;
- 2) задав гипотезу о функции распределения или плотности распределения, определяем гипотетические вероятности разрядов

$$p_j = F(x_j - x_{j-1}) = \int_{x_{j-1}}^{x_j} f(x) dx$$

- 3) вычисляем реализацию  $t = T(x^n)$  статистики  $T(X^n)$ ;
- 4) задавая уровень значимости  $\alpha$ , при помощи табл.  $\chi^2$  – распределения находим  $t_\alpha$ ;
- 5) применяем решающее правило, если  $(t \geq t_\alpha)$ , то  $H$  отклоняем, в противном случае  $H$  принимаем.

Достоинства:

- относительная простота;
- возможность применения для векторной  $X$ ;
- состоятельность;

- возможность применения оценок параметров при формулировании гипотезы  $H$  без потерь точности выводов;
- несмещенность при  $p_j = \text{const}$ ;
- пониженная требовательность к точности  $x_i$ .

Недостатки:

- потери информации за счет предварительного группирования данных по разрядам;
- неопределенность в выборе  $q$  и границ разрядов;

- неучет знака разности  $N_j - np_j$ .

## 9.2.2.1. Проверка гипотезы о нормальном распределении

Пусть получена выборка достаточно большого объема  $n$  с большим количеством различных значений вариант. Для удобства ее обработки, разделим интервал от наименьшего до наибольшего из значений вариант на  $q$  равных частей.

Будем считать, что значения вариант, попавших в каждый интервал, приблизительно равны числу, задающему середину интервала. Подсчитав число вариант, попавших в каждый интервал, составим так называемую сгруппированную выборку:

варианты.....	$x_1$	$x_2$	...	$x_s$
частоты.....	$n_1$	$n_2$	...	$n_s$

где  $x_i$  – значения середин интервалов, а  $n_i$  – число вариант, попавших в  $i$ -й интервал (эмпирические частоты).

По полученным данным можно вычислить выборочное среднее и выборочное среднее квадратическое отклонение  $\sigma_B$ . Проверим предположение, что генеральная совокупность распределена по нормальному закону с параметрами  $M(X) =$  ,  $D(X) =$  . Тогда можно найти количество чисел из выборки объема  $n$ , которое должно оказаться в каждом интервале при этом предположении (то есть теоретические частоты).

Для этого по таблице значений функции Лапласа найдем вероятность попадания в  $i$ -й интервал:

$$p_i = \Phi\left(\frac{b_i - \bar{x}_B}{\sigma_B}\right) - \Phi\left(\frac{a_i - \bar{x}_B}{\sigma_B}\right)$$

где  $a_i$  и  $b_i$  - границы  $i$ -го интервала. Умножив полученные вероятности на объем выборки  $n$ , найдем теоретические частоты:  $n_i = n \cdot p_i$ .

Наша цель – сравнить эмпирические и теоретические частоты, которые, конечно, отличаются друг от друга, и выяснить, являются ли эти различия несущественными, не опровергающими гипотезу о нормальном распределении исследуемой случайной величины, или они настолько велики, что противоречат этой гипотезе.

Для этого используется критерий в виде случайной величины

$$\chi^2 = \sum_{i=1}^s \frac{(n_i - n'_i)^2}{n'_i}$$

Вне зависимости от реального закона распределения генеральной совокупности закон распределения случайной величины при  $n \rightarrow \infty$  стремится к закону распределения с числом степеней свободы  $k = q - 1 - r$ , где  $r$  – число параметров предполагаемого распределения, оцененных по данным выборки. Нормальное распределение характеризуется двумя параметрами, поэтому  $k = q - 3$ .

Для выбранного критерия строится правосторонняя критическая область, определяемая условием

$$P(\chi^2 > \chi_{кр}^2(\alpha, k)) = \alpha,$$

где  $\alpha$  – уровень значимости. Следовательно, критическая область задается неравенством

$$\chi^2 > \chi_{кр}^2(\alpha, k),$$

а область принятия гипотезы –

$$\chi^2 < \chi_{кр}^2(\alpha, k)$$

Итак, для проверки нулевой гипотезы  $H_0$ : генеральная совокупность распределена нормально – нужно вычислить по выборке наблюдаемое значение критерия:

$$\chi_{\text{набл}}^2 (*) = \sum_{i=1}^s \frac{(n_i - n'_i)^2}{n'_i}$$

а по таблице критических точек распределения  $\chi^2$  найти критическую точку  $\chi_{\text{кр}}^2(\alpha, k)$ , используя известные значения  $\alpha$  и  $k = q - 3$ . Если  $\chi_{\text{набл}}^2 < \chi_{\text{кр}}^2$  – нулевую гипотезу принимают,

при  $\chi_{\text{набл}}^2 > \chi_{\text{кр}}^2$  ее отвергают.

