

Лабораторная работа 5.

Имеются две выборки X_1 и X_2 (функции распределения генеральных совокупностей непрерывны). Проверьте гипотезу об однородности выборок с помощью критерия Колмогорова-Смирнова.

Критерий однородности Колмогорова-Смирнова

Проверяем гипотезу о равенстве функций распределения $H_0: F(\cdot) = G(\cdot)$ при альтернативной гипотезе $H_1: F(\cdot) \neq G(\cdot)$, функции непрерывны, $m \leq n$

Статистика Смирнова определяется следующей формулой $D_{m,n} = \sup_{|x| < \infty} |F_n(x) - G_m(x)|$

На практике значение статистики рекомендуется вычислять по формулам:

$$D_{m,n}^+ = \max_{1 \leq r \leq m} \left[\frac{r}{m} - F_n(y_{(r)}) \right] = \max_{1 \leq s \leq n} \left[G_m(x_{(s)}) - \frac{s-1}{n} \right] \quad (1)$$

$$D_{m,n}^- = \max_{1 \leq r \leq m} \left[F_n(y_{(r)}) - \frac{r-1}{m} \right] = \max_{1 \leq s \leq n} \left[\frac{s}{n} - G_m(x_{(s)}) \right] \quad (2)$$

$$D_{m,n} = \max \left[D_{m,n}^+, D_{m,n}^- \right] \quad (3)$$

При справедливости нулевой гипотезы и неограниченном увеличении объемов выборок статистика

$$\sqrt{\frac{mn}{m+n}} D_{m,n} \quad (4) \text{ асимптотически подчиняется распределению Колмогорова.}$$

Алгоритм:

Строим эмпирические функции распределения $F_n(x), G_m(x)$

Вычисляем статистики по формулам (1), (2), (3)

Находим значение исправленной статистики (4)

Находим критическую область – интервал $(k_{1-\alpha}, \infty)$

Если значение статистики попадает в критическую область, нулевая гипотеза отвергается.

Ранговый критерий однородности Вилкоксона

Проверяем гипотезу о равенстве непрерывных функций распределения $H_0 : F(\cdot) = G(\cdot)$

Возможны альтернативные гипотезы:

$$H_1 : F(\cdot) \geq G(\cdot)$$

$$H_1 : F(\cdot) \leq G(\cdot)$$

$$H_1 : F(\cdot) \neq G(\cdot)$$

Алгоритм

1. Объединим выборки $X_{[n]}, Y_{[m]}$ в общий вариационный ряд.

Припишем каждому элементу ранг, т.е. номер в вариационном ряду.

Обозначим ранги элементов выборки $Y_{[m]}$ через r_1, \dots, r_m .

Вычислим статистику Вилкоксона по следующей формуле:

$$W(X_{[n]}, Y_{[m]}) = r_1 + \dots + r_m$$

3. Задаем уровень значимости α .

4. Найдем критическую область для критерия:

- При альтернативе $H_1 : F(\cdot) \leq G(\cdot)$, критическая область

$$\left[0, w_{\alpha, m, n} \right],$$

$w_{\alpha, m, n}$ - квантиль предельного распределения статистики Вилкоксона.

- При альтернативе $H_1 : F(\cdot) \geq G(\cdot)$, критическая область

$$\left[m(n + m + 1) - w_{\alpha, m, n}, \infty \right)$$

- При альтернативе $H_1 : F(\cdot) \neq G(\cdot)$, критическая область

$$\left[0, w_{\frac{\alpha}{2}, m, n} \right] \cup \left[m(n + m + 1) - w_{\frac{\alpha}{2}, m, n}, \infty \right)$$

Для больших выборок можно использовать следующую аппроксимацию

$$W^*(X_{[n]}, Y_{[m]}) = \frac{(r_1 + \dots + r_m) - m(m + n + 1)/2}{\sqrt{mn(m + n + 1)/12}}$$

- При альтернативе $H_1 : F(\cdot) \leq G(\cdot)$, критическая область $(-\infty, u_\alpha]$,

квантиль нормального стандартного распределения.

- При альтернативе $H_1 : F(\cdot) \geq G(\cdot)$, критическая область $[u_{1-\alpha}, \infty)$

- При альтернативе $H_1 : F(\cdot) \neq G(\cdot)$, критическая область

$$\left(-\infty, u_{\frac{\alpha}{2}} \right] \cup \left[u_{1-\frac{\alpha}{2}}, \infty \right)$$

Ранговый критерий однородности Манна-Уитни

Статистика Манна-Уитни это число успехов в парных сравнениях.

$$I\{x_i < y_j\} = \begin{cases} 1, & x_i < y_j \\ 0, & x_i \geq y_j \end{cases}$$

Статистика вычисляется по формуле:

$$U(X_{[n]}, Y_{[m]}) = \sum_{i=1}^n \sum_{j=1}^m I\{x_i < y_j\}$$

Статистика Манна-Уитни и Вилкоксона связаны следующим образом:

$$U_Y(X_{[n]}, Y_{[m]}) = mn + \frac{m(m+1)}{2} - W(X_{[n]}, Y_{[m]})$$

$$U_X(X_{[n]}, Y_{[m]}) = mn + \frac{n(n+1)}{2} - W(Y_{[m]}, X_{[n]})$$

Статистика Манна-Уитни может быть вычислена следующим образом:

$$U(X_{[n]}, Y_{[m]}) = \min\{U_Y(X_{[n]}, Y_{[m]}), U_X(X_{[n]}, Y_{[m]})\}$$

При $m, n > 8$ можно применить аппроксимацию

$$U^*(X_{[n]}, Y_{[m]}) = \frac{U(X_{[n]}, Y_{[m]}) - mn/2}{\sqrt{mn(m+n+1)/12}}$$

статистика подчиняется стандартному нормальному закону.