

Лекція 23. Статистичне вивчення кореляційного зв'язку випадкових величин.

1. Кореляційний момент, вибірковий коефіцієнт кореляції
2. Емпіричні моменти
3. Коефіцієнт асиметрії A_s^* . Екцес

1. Кореляційний момент, вибірковий коефіцієнт кореляції

Під час дослідження двовимірного статистичного розподілу вибірки постає потреба з'ясувати наявність зв'язку між ознаками X і Y , який у статистиці називають кореляційним. Для цього обчислюється емпіричний кореляційний момент K_{xy}^* за формулою

$$K_{xy}^* = \frac{\sum_{i=1}^k \sum_{j=1}^m y_i x_j n_{ij}}{n} - \bar{x} \cdot \bar{y} \quad (23.1)$$

Якщо $K_{xy}^* = 0$, то кореляційного зв'язку між ознаками X і Y немає. Якщо ж $K_{xy}^* \neq 0$, то цей зв'язок існує.

Отже, кореляційний момент дає лише відповідь на запитання: є зв'язок між ознаками X і Y , чи його немає.

Для вимірювання тісноти кореляційного зв'язку обчислюється вибірковий коефіцієнт кореляції r_B за формулою

$$r_B = \frac{K_{xy}^*}{\sigma_x \sigma_y} \quad (23.2)$$

Як і в теорії ймовірностей, $|r_B| \leq 1$, $-1 \leq r_B \leq 1$.

Приклад. За заданим двовимірним статистичним розподілом вибірки ознак X і Y

$Y = y_i$	$X = x_j$				n_{y_i}
	10	20	30	40	
2	—	2	4	4	10
4	10	8	6	6	30
6	5	10	5	—	20
8	15	—	15	10	40
n_{x_j}	30	20	30	20	

потрібно: обчислити K_{xy}^* , r_B .

Розв'язання. Щоб обчислити K_{xy}^* , r_B визначимо \bar{x} , σ_x , \bar{y} , σ_y . Оскільки $n = \sum \sum n_{ij} = 100$, то

$$\bar{x} = \frac{\sum x_j n_{x_j}}{n} = \frac{10 \cdot 30 + 20 \cdot 20 + 30 \cdot 30 + 40 \cdot 20}{100} =$$

$$= \frac{300 + 400 + 900 + 800}{100} = \frac{2400}{100} = 24.$$

$$\bar{x} = 24.$$

$$\frac{\sum x_j^2 n_{x_j}}{n} = \frac{(10)^2 \cdot 30 + (20)^2 \cdot 20 + (30)^2 \cdot 30 + (40)^2 \cdot 20}{100} =$$

$$= \frac{3000 + 8000 + 27000 + 32000}{100} = \frac{70000}{100} = 700.$$

$$D_x = \frac{\sum x_j^2 n_{x_j}}{n} - (\bar{x})^2 = 700 - (24)^2 = 700 - 576 = 124.$$

$$\sigma_x = \sqrt{D_x} = \sqrt{124} \approx 11,14.$$

Отже, $\sigma_x = 11,14$.

$$\bar{y} = \frac{\sum y_i n_{y_i}}{n} = \frac{2 \cdot 10 + 4 \cdot 30 + 6 \cdot 20 + 8 \cdot 40}{100} =$$

$$= \frac{20 + 120 + 120 + 320}{100} = 5,8.$$

Отже, $\bar{y} = 5,8$.

$$\frac{\sum y_i^2 n_{y_i}}{n} = \frac{(2)^2 \cdot 10 + (4)^2 \cdot 30 + (6)^2 \cdot 20 + (8)^2 \cdot 40}{100} =$$

$$= \frac{40 + 480 + 720 + 2560}{100} = \frac{3800}{100} = 38.$$

$$D_y = \frac{\sum y_i^2 n_{y_i}}{n} - (\bar{y})^2 = 38 - (5,8)^2 = 38 - 33,64 = 4,36,$$

$$\sigma_y = \sqrt{D_y} = \sqrt{4,36} \approx 2,1.$$

Для визначення K_{xy}^* обчислюють

$$\sum \sum y_i x_j n_{ij} = 2 \cdot 10 \cdot 0 + 2 \cdot 20 \cdot 2 + 2 \cdot 30 \cdot 4 + 2 \cdot 40 \cdot 4 + 4 \cdot 10 \cdot 10 + 4 \cdot 20 \cdot 8 +$$

$$+ 4 \cdot 30 \cdot 6 + 4 \cdot 40 \cdot 6 + 6 \cdot 10 \cdot 5 + 6 \cdot 20 \cdot 10 + 6 \cdot 30 \cdot 5 + 6 \cdot 40 \cdot 0 + 8 \cdot 10 \cdot 15 +$$

$$+ 8 \cdot 20 \cdot 0 + 8 \cdot 30 \cdot 15 + 8 \cdot 40 \cdot 10 = 0 + 80 + 240 + 320 + 400 + 640 + 720 +$$

$$+ 960 + 300 + 1200 + 900 + 0 + 1200 + 0 + 3600 + 3200 = 13760.$$

Тоді

$$K_{xy}^* = \frac{\sum \sum y_i x_j n_{ij}}{n} - \bar{x} \cdot \bar{y} = \frac{13760}{100} - 24 \cdot 5,8 = 137,6 - 139,2 = -1,6.$$

Отже, $K_{xy}^* = -1,6$, а це свідчить про те, що між ознаками X і Y існуватиме від'ємний кореляційний зв'язок.

Для вимірювання тісноти цього зв'язку обчислимо вибіркового коефіцієнт кореляції.

$$r_B = \frac{K_{xy}^*}{\sigma_x \sigma_y} = \frac{-1,6}{11,14 \cdot 2,1} = \frac{-1,6}{23,394} \approx -0,068.$$

Отже, $r_B = -0,068$, тобто тіснота кореляційного зв'язку між ознаками X та Y є слабкою.

2. Емпіричні моменти

Початкові емпіричні моменти. Середнє зважене значення варіант у степені k ($k = 1, 2, 3, \dots$) називають *початковим емпіричним моментом k -го порядку* v_k^* , який обчислюється за формулою

$$v_k^* = \frac{\sum x_k n_i}{n} \quad (23.3)$$

При $k = 1$ дістанемо початковий момент першого порядку:

$$v_1^* = \frac{\sum x_i n_i}{n} = \bar{x}_B \quad (23.4)$$

При $k = 2$ обчислимо початковий момент другого порядку:

$$v_2^* = \frac{\sum x_i^2 n_i}{n} \quad (23.5)$$

Отже, дисперсію вибірки можна подати через початкові моменти першого та другого порядків, а саме:

$$D_B = v_2^* - (v_1^*)^2 \quad (23.6)$$

Центральний емпіричний момент k -го порядку. Середнє зважене відхилення варіант у степені k ($k = 1, 2, 3, \dots$) називають *центральним емпіричним моментом k -го порядку*

$$\mu_k^* = \frac{\sum (x_i - \bar{x}_B)^k n_i}{n} \quad (23.7)$$

При $k = 1$ дістанемо:

$$\mu_1^* = \frac{\sum (x_i - \bar{x}_B) n_i}{n} = \frac{\sum x_i n_i}{n} - \bar{x}_B \cdot \frac{\sum n_i}{n} = \bar{x}_B - \bar{x}_B = 0.$$

При $k = 2$ маємо:

$$\mu_2^* = \frac{\sum (x_i - \bar{x}_B)^2 n_i}{n} = D_B.$$

На практиці найчастіше застосовуються центральні емпіричні моменти третього та четвертого порядків, що обчислюються за формулами:

$$\mu_3^* = v_3^* - 3v_2^* \cdot v_1^* + 2(v_1^*)^2, \quad (23.8)$$

$$\mu_4^* = v_4^* - 4v_3^* \cdot v_1^* + 6v_2^* (v_1^*)^2 - 3(v_1^*)^4. \quad (23.9)$$

3. Коефіцієнт асиметрії A_s^* . Ексцес.

Центральний емпіричний момент третього порядку застосовується для обчислення коефіцієнта асиметрії:

$$A_s^* = \frac{\mu_3^*}{\sigma_B^3} \quad (23.10)$$

Якщо варіанти статистичного розподілу вибірки симетрично розміщені відносно \bar{x}_B , то в цьому разі $A_s = 0$, оскільки $\mu_3^* = 0$.

При $A_s < 0$ варіанти статистичного розподілу $x_i < \bar{x}_B$ переважають варіанти $x_i > \bar{x}_B$. Таку асиметрію називають *від'ємною*. При $A_s > 0$ варіанти $x_j > \bar{x}_B$ переважають варіанти $x_i < \bar{x}_B$, і таку асиметрію називають *додатною*.

Ексцес. Центральний емпіричний момент четвертого порядку застосовується для обчислення ексцесу:

$$E_s^* = \frac{\mu_4^*}{\sigma_B^4} - 3. \quad (23.11)$$

E_s^* , як правило, використовується при дослідженні неперервних ознак генеральних сукупностей, оскільки він оцінює крутизну закону розподілу неперервної випадкової величини порівняно з нормальним. Для нормального закону розподілу, як відомо, $E_s^* = 0$.