

Лекція 13.

Кореляція. Коефіцієнт кореляції

1. Кореляційний зв'язок.
2. Коефіцієнт кореляції.
3. Лінія регресії.

1. Кореляційний зв'язок.

Кореляція (від лат. *correlation* – відповідність) – статистична залежність між величинами, яка не має, взагалі кажучи, строго функціонального характеру. Кореляційна залежність виникає тоді, коли одна з величин залежить не тільки від заданої другої, а й від деяких випадкових факторів; або, коли серед умов, від яких залежать обидві величини, є загальні для них обох.

Озн. 1: Кореляційний зв'язок – це не точна залежність однієї величини від іншої. Числовим значенням однієї змінної ставиться у відповідність середнє декількох значень інших. Наприклад, між кількістю внесених на поле добрив і врожайністю пшениці існує незаперечна залежність. Але це не означає, що конкретній кількості добрив відповідає визначена величина урожаю. На урожай впливає багато інших факторів: склад і структура ґрунту, різні методи посіву і таке інше.

Кореляційний зв'язок виявляється у середньому для усієї сукупності спостережень. По відношенню ж до окремих спостережень цей зв'язок є дуже неповним і неточним. Відомо, наприклад, що існує кореляція між вагою тварини і її висотою. Це означає, що більш високі тварини звичайно важчі за низьких. Та в деяких випадках низька тварина може виявитися важчою за високу.

Кореляційний зв'язок може мати різну степінь – від повної незалежності до функціональної залежності. Крім того, характер зв'язку між різними величинами може бути різний. Тому виникає необхідність визначити форму, напрям і степінь кореляційних зв'язків.

За формою кореляція може бути *прямолінійною* і *криволінійною*, за напрямком – *прямою* і *оберненою*.

При додатній кореляції залежність між величинами буде прямою: при збільшенні однієї величини, збільшується й інша. При від'ємній кореляції залежність обернена: збільшення однієї величини пов'язано зі зменшенням другої. Степінь кореляції вимірюється різними показниками зв'язку. Такими показниками є коефіцієнт кореляції, кореляційне відношення та ін.

2. Коефіцієнт кореляції.

Озн 2: Кореляційним моментом називають математичне сподівання я добутків відхилень випадкових величин X та Y від їх середніх:

$$\mu = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{n} \quad (1)$$

Числове значення μ не може бути мірою тісноти зв'язку, бо залежить від одиниць вимірювання величини X та Y . Тому вводиться поняття коефіцієнта кореляції.

Озн 3: Коефіцієнтом парної кореляції називають відношення кореляційного моменту до добутку середніх квадратичних відхилень:

$$r = \frac{\mu}{\sigma_x \sigma_y} = \frac{\sum_{i=1}^n (X_i - \bar{X}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2 \cdot \sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (2)$$

де X_i, Y_i – числові значення величин, між якими встановлюється кореляційний зв'язок, \bar{X}, \bar{Y} – їх середні арифметичні значення величин.

Для незалежних величин $r=0$, для функціональних залежностей $r=\pm 1$. Якщо зростання X призводить до зростання Y , то r – додатне, якщо до зменшення – то r – від'ємне. Щоб нехтувати знаком r , вводять поняття коефіцієнта детермінації $R = r^2$, який завжди додатний.

Кореляція вважається сильною, якщо $r < 0,75$.

Приклад 1. Дві випадково розподілені величини X і Y . Знайти коефіцієнт кореляції:

X	40	40	39	40	41	38	42	40	42	38
Y	35	37	35	36	35	36	37	36	38	35

Розв'язання: Обчислимо середні значення \bar{X} і \bar{Y} :

$$\bar{X} = \frac{40 + 40 + 39 + 40 + 41 + 38 + 42 + 40 + 42 + 38}{10} = 40;$$

$$\bar{Y} = \frac{35 + 37 + 35 + 36 + 35 + 36 + 37 + 36 + 38 + 35}{10} = 36.$$

Для обчислення r необхідно, крім \bar{X} і \bar{Y} , визначити наступні величини: $(X_i - \bar{X})$, $(Y_i - \bar{Y})$, $(X_i - \bar{X}) \cdot (Y_i - \bar{Y})$, $(X_i - \bar{X})^2$, $(Y_i - \bar{Y})^2$. Тому результати обчислень зведемо в таблицю:

X	Y	$(X_i - \bar{X})$	$(Y_i - \bar{Y})$	$(X_i - \bar{X}) \cdot (Y_i - \bar{Y})$	$(X_i - \bar{X})^2$	$(Y_i - \bar{Y})^2$
40	35	0	-1	0	0	1
40	37	0	1	0	0	1
39	35	-1	-1	1	1	1
40	36	0	0	0	0	0
41	35	1	-1	1	1	1
38	36	-2	0	2	4	1
42	37	2	1	0	0	0
40	36	0	0	0	4	0
42	38	2	2	4	4	4
38	35	-2	-1	2	4	1
$\bar{X}=40$	$\bar{Y}=36$	$\sum=0$	$\sum=0$	$\sum=8$	$\sum=18$	$\sum=10$

З таблиці легко отримати:

$$\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = 8 \sum_{i=1}^n (X_i - \bar{X})^2 = 18; \sum_{i=1}^n (Y_i - \bar{Y}) = 10.$$

$$\text{Тоді } r = \frac{8}{\sqrt{18 \cdot 10}} \approx 0,596.$$

3. Лінія регресії.

Прямолінійний кореляційний зв'язок характеризується рівномірною зміною середнього значення величини Y під впливом відповідної зміни величини X .

Озн. 4: Рівняння парної регресії має вигляд: $Y - \bar{Y} = r_{xy} \cdot \frac{\sigma_y}{\sigma_x} \cdot (X - \bar{X})$ (3)


Приклад 2. На основі попереднього прикладу побудувати лінію регресії та позначити експериментальні точки.

Розв'язання: Запишемо рівняння регресії: $Y - \bar{Y} = r_{xy} \cdot \frac{\sigma_y}{\sigma_x} \cdot (X - \bar{X})$.

З попередніх обчислень: $\bar{X} = 40$, $\bar{Y} = 36$, $\sigma_x = 18$, $\sigma_y = 10$, $r = 0,596 \approx 0,6$, тоді:

$$Y - 36 = 0,6 \cdot \frac{10}{18} \cdot (X - 40) \Rightarrow Y = 0,3X + 22,7.$$

Побудуємо отриману функціональну залежність:



Д.з.: «Т. й.» Шевченко Р.Л., Ревецька У.С. Розділ X. § 1–3.