

**Понятие корреляционного,
регрессионного и кластерного
анализа данных**

Группы методов

Две группы методов: методы корреляционного анализа и методы регрессионного анализа

Корреляционный анализ

Существует ли связь между явлениями?

Насколько сильная связь между явлениями?

Регрессионный анализ


Каков характер связи между явлениями?

Построение регрессионной модели явлений.

Диаграмма рассеяния

Пример 1. Построить диаграмму рассеяния для результатов наблюдения за возрастом и артериальным давлением группы людей, приведенных в таблице.

№	Возраст, лет (x)	Давление, мм.рт.ст. (y)
1	43	128
2	48	120
3	56	135
4	61	143
5	67	141
6	70	152



Свойства коэффициента корреляции

Основные свойства коэффициента корреляции:

Сильная
обратная
связь

Нет
линейной
связи




Сильная
прямая
связь



-1

0

+1



**Парная регрессия. Метод
наименьших квадратов.**

Построение уравнения регрессии

Задача построения уравнения регрессии для одного факторного и одного результативного признака формулируется следующим образом:

Пусть имеется набор значений двух переменных: результативного признака y_i и факторного признака x_i . Между этими переменными существует объективная связь вида: $y_i = f(x_i) + \varepsilon_i$.

Необходимо по данным наблюдения $y_i, x_i, i = \overline{1, n}$ подобрать функцию $\hat{y} = F(x)$, наилучшим образом описывающую существующую связь.

Чаще всего используются следующие зависимости :

* линейная $f(t) = a_0 + a_1 t$


* параболическая $f(t) = a_0 + a_1 t + a_2 t^2$;

* экспоненциальная $f(t) = \exp(a_0 + a_1 t)$.

Оценка параметров осуществляется методом наименьших квадратов:

$$\sum_{t=1}^n (y_t - f(t))^2 \rightarrow \min$$

Графическая интерпретация



$$y_i = a + bx_i + e_i \quad i = 1, 2, \dots, n$$

Метод наименьших квадратов

$$S = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \rightarrow \min$$

Применение МНК для расчёта параметров регрессии рассмотрим на примере

$$\hat{y} = a + bx$$

$$S = \sum_{i=1}^n (y_i - a - bx_i)^2 \rightarrow \min$$

Вычисление коэффициентов

$$a = \frac{\sum_{i=1}^n y_i - b \sum_{i=1}^n x_i}{n} = \bar{y} - b\bar{x}$$

$$b = \frac{\frac{\sum x \sum y}{n} - \sum xy}{\frac{(\sum x)^2}{n} - \sum x^2} \quad \text{или} \quad b = r_{xy} \frac{\sigma_y}{\sigma_x}$$

Матричное представление

$$y_i = a + b x_i + e_i, i = 1, 2, \dots, m$$

$$Y = X \beta + U$$

$$Y = \begin{pmatrix} y_1 \\ \dots \\ y_m \end{pmatrix}$$

$$U = \begin{pmatrix} u_1 \\ \dots \\ u_m \end{pmatrix}$$

$$\beta = \begin{pmatrix} a \\ b \end{pmatrix}$$

$$X = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \dots & \dots \\ 1 & x_m \end{pmatrix}$$

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

Алгоритм кластерного анализа: K-means

Одной из широко используемых методик кластеризации является *разделительная кластеризация*, в соответствии с которой для выборки данных, содержащей n записей, задаётся число кластеров k , которое должно быть сформировано. Затем алгоритм разбивает все объекты выборки на k групп ($k < n$), которые и представляют собой кластеры.

К наиболее простым и эффективным алгоритмам кластеризации относится k-means (k-средних). Он состоит из четырёх шагов:

1. Задаётся число кластеров k , которое должно быть сформировано из объектов исходной выборки.
2. Случайным образом выбирается k записей, которые будут служить начальными центрами кластеров.
3. Для каждой записи исходной выборки определяется ближайший к ней центр кластера.
4. Производится вычисление *центроидов* - центров тяжести кластеров. Это делается путём определения среднего для значений **каждого** признака всех записей в кластере.

Шаги 3 и 4 повторяются до тех пор, пока не будет выполнено условие в соответствии с некоторым критерием сходимости (чаще всего используется сумма квадратов ошибок между центроидом кластера и всеми вошедшими в него записями).

Остановка алгоритма производится, когда на каждой итерации в каждом кластере остаётся один и тот же набор записей.

Пример

Заданы координаты пяти точек на плоскости:

$(1, 5)$, $(7, 4)$, $(5, 2)$, $(7, 5)$, $(4, 7)$.

Задано число кластеров: 2.

Проведите кластеризацию методом K-means. Выполните две итерации.