


Введение в линейную регрессию

- Регрессия – от лат. regressio:
обратное движение, возвращение
- 1886 г., Фрэнсис Гальтон



- 205 семей, 962 детей
- У более высоких родителей рождаются более высокие дети, а у более низких – низкие
- Дети высоких родителей оказываются менее высокими, а дети более низких – более высокими
- Регрессия к среднему (regression to the mean)
- Все значения лежат практически на одной линии (линии регрессии)







DIAGRAM BASED ON TABLE I .

(all female heights are multiplied by 1.08)





- $Y_i = a_0 + a_1 X_i + \varepsilon_i$ – реальные значения
- $\hat{Y}_i = a_0 + a_1 X_i$ – предполагаемая линия регрессии

- X_i – предиктор/фактор, Y_i – отклик
- a_0 – свободный член (intercept)
- a_1 – угловой коэффициент/коэффициент регрессии
- ε_i – случайная ошибка

Метод наименьших квадратов (1795)



- $\sum \varepsilon_i^2 \rightarrow \min$

- $$\begin{cases} \hat{a}_1 = \frac{\overline{XY} - \bar{X} \cdot \bar{Y}}{\overline{X^2} - \bar{X}^2} \\ \hat{a}_0 = \bar{Y} - \hat{a}_1 \bar{X} \end{cases}$$

- $\hat{Y}_i = \hat{a}_0 + \hat{a}_1 X_i$, тогда

$$\hat{Y}_i - \bar{Y} = \hat{a}_1 (X_i - \bar{X})$$

Условия Гаусса-Маркова


- $E\varepsilon_i = 0, D\varepsilon_i = \sigma^2$
- $corr(\varepsilon_i, \varepsilon_j) = 0, \forall i \neq j$
- $corr(X_i, \varepsilon_j) = 0, \forall i, j$




Если $\varepsilon_i \sim N_{0, \sigma^2}$, то оценка МНК совпадает с оценкой ММП

Пример нарушения условий Гаусса-Маркова

Разная дисперсия наблюдений



Автокорреляция наблюдений



Для нашей модели регрессии получили линию


$$\hat{Y}_i = 47.67 + 0.73X_i$$

Предсказания:



$$X_i = 150\text{см}, \hat{Y}_i = 157.17\text{см}$$

$$X_i = 190\text{см}, \hat{Y}_i = 186.37\text{см}$$

МОЁ ХОББИ: ЭКСТРАПОЛИРОВАТЬ




Случай, когда X и Y независимы




Коэффициент детерминации R^2

- $SST = \sum (Y_i - \bar{Y})^2$
- $SSE = \sum (Y_i - \hat{Y}_i)^2$
- $R^2 = 1 - \frac{SSE}{SST}$
- $R^2 \in [0; 1]$



US spending on science, space, and technology correlates with Suicides by hanging, strangulation and suffocation

Correlation: 99.79% (r=0.99789126)



Data sources: U.S. Office of Management and Budget and Centers for Disease Control & Prevention


tylervigen.com

В случае парной линейной регрессии коэффициент детерминации равен квадрату коэффициента корреляции

На графиках показаны не связанные друг с другом величины, имеющие при этом высокий коэффициент корреляции

Math doctorates awarded correlates with Uranium stored at US nuclear power plants



Correlation: 95.23% (r=0.952257)



Data sources: National Science Foundation and Dept. of Energy



tylervigen.com

При большом разбросе данных R^2 будет низким даже для очень хорошей модели



Выбросы влияют на R^2 и на оценки МНК

$$Y_i = 5 + 2X_i + N_{0,1}$$



Множественная линейная регрессия

- $Y_i = \sum a_j X_{ij} + \varepsilon_i$

Перепишем в виде

- $Y = Xa + \varepsilon,$

где Y, a, ε – вектор-столбцы, X – матрица.

Тогда

- $SSE = (Y - Xa)^T (Y - Xa)$

- $\hat{a}_{\text{МНК}} = (X^T X)^{-1} X^T Y$