

# СИСТЕМЫ ОБРАБОТКИ

## МЕДИАДААННЫХ

### ЛИНЕЙНАЯ РЕГРЕССИЯ

**д.т.н., доцент Вашкевич М. И.**

**[vashkevich@bsuir.by](mailto:vashkevich@bsuir.by)**



Белорусский государственный университет  
информатики и радиоэлектроники  
Кафедра электронных вычислительных средств

# Пример

Как потребление газа зависит от внешней температуры? (Whiteside, 1960-e)

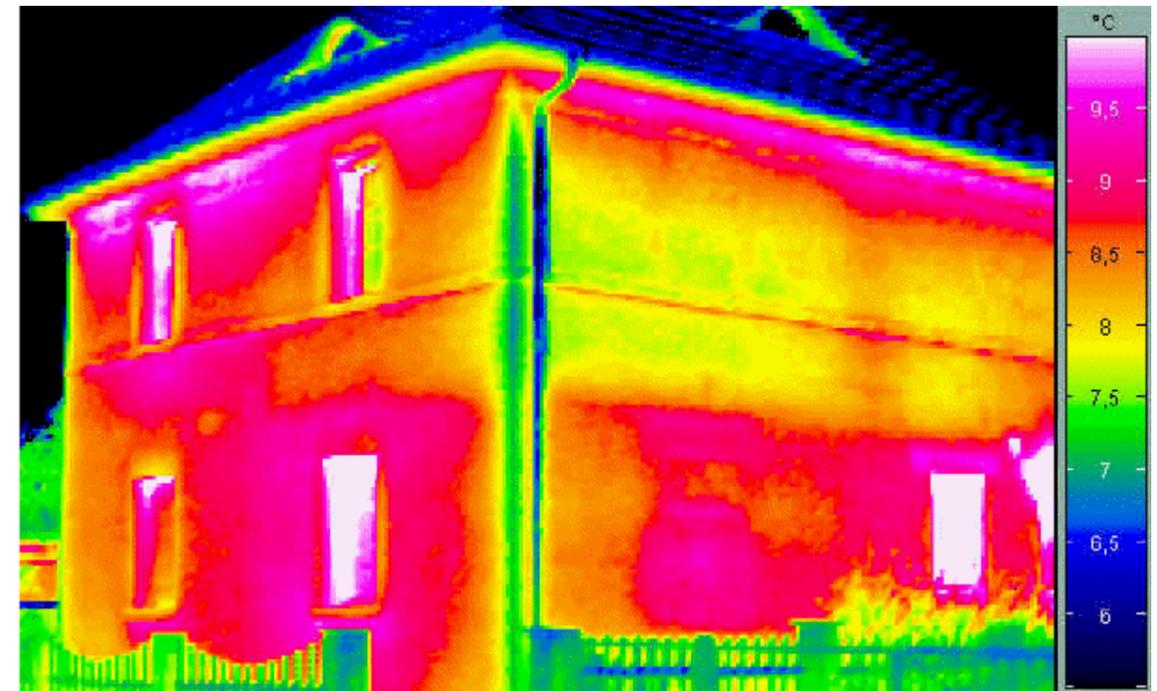
Еженедельно измерялась:

- средняя температура воздуха
- коэффициент теплоизоляции
- общий объем использованного газа

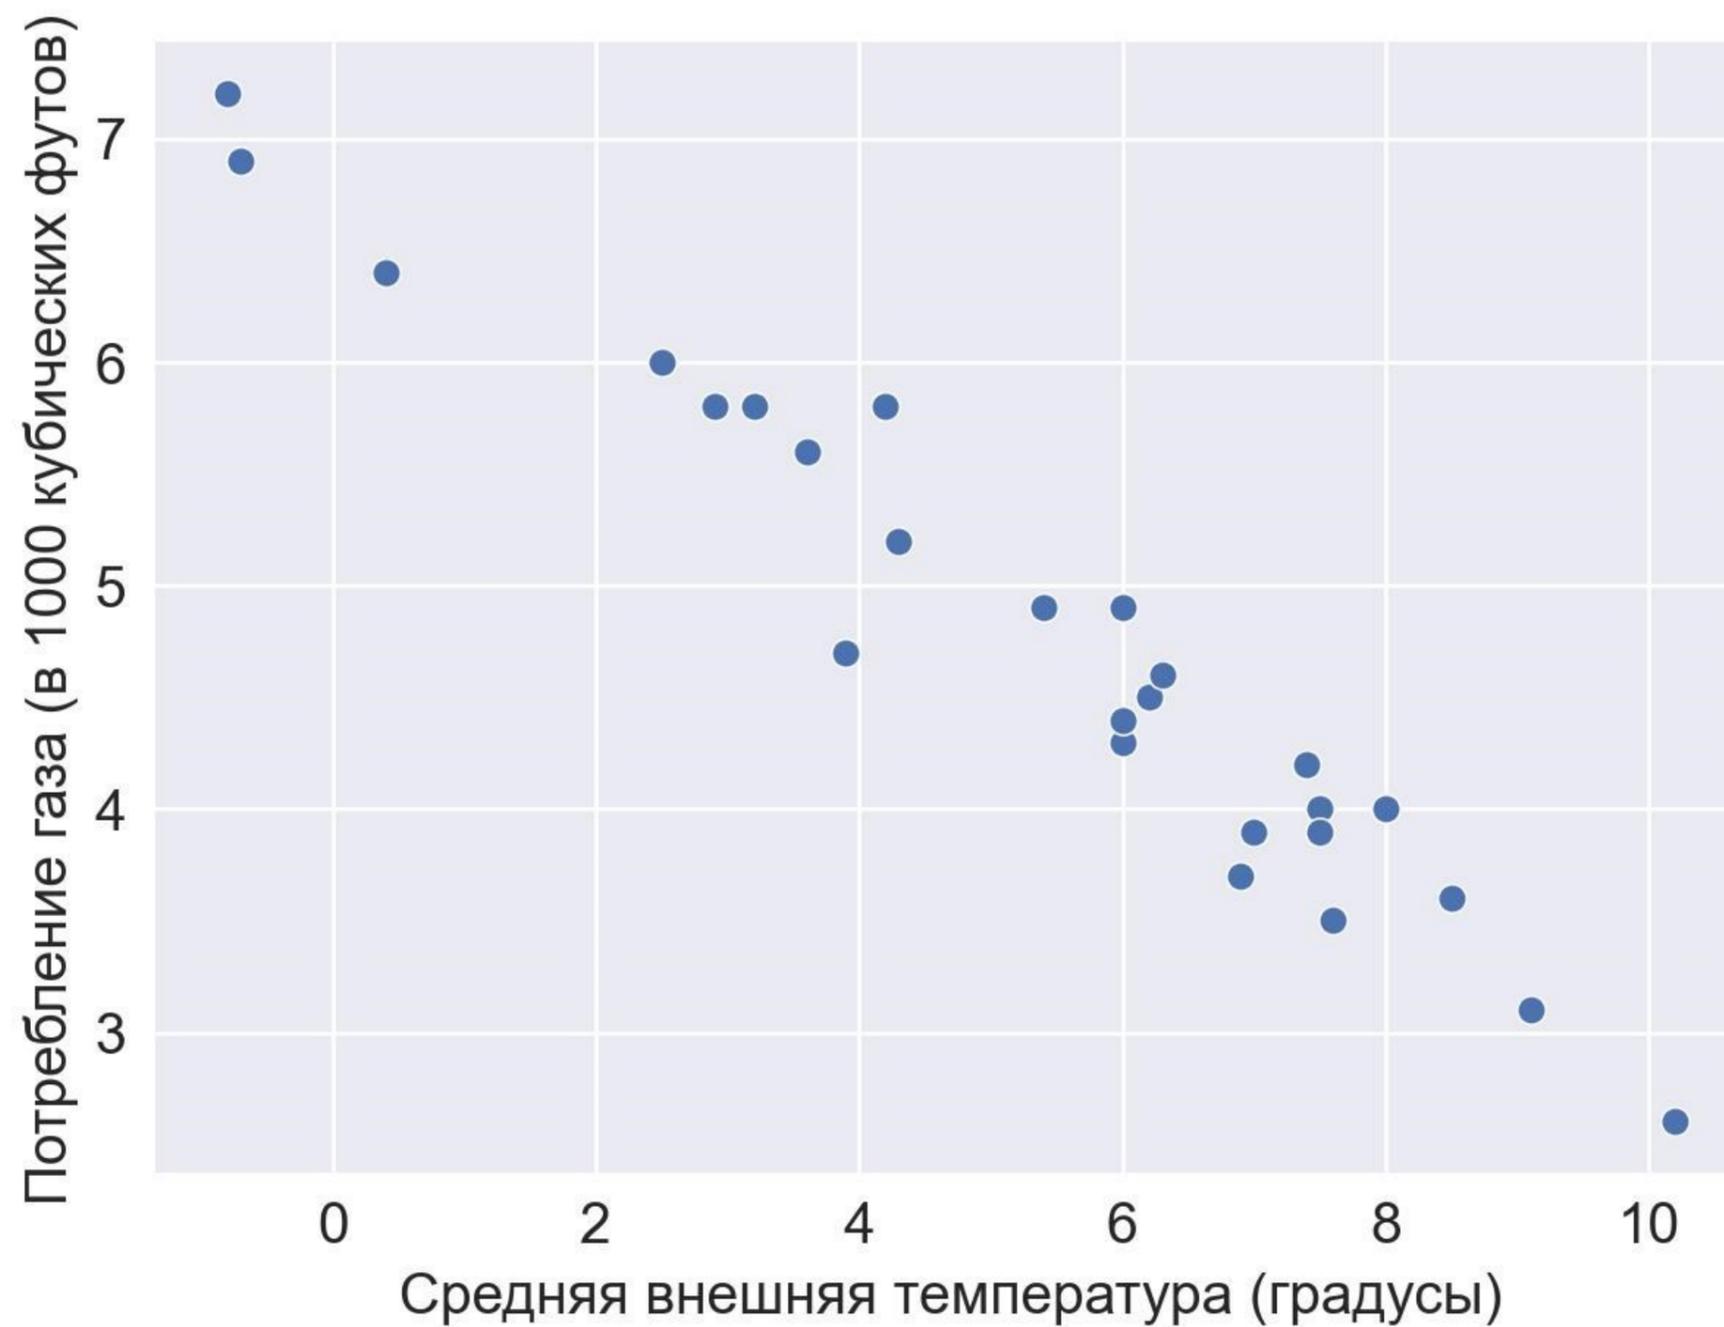
Набор данных 56 строк и 3 столбца:

Вопросы:

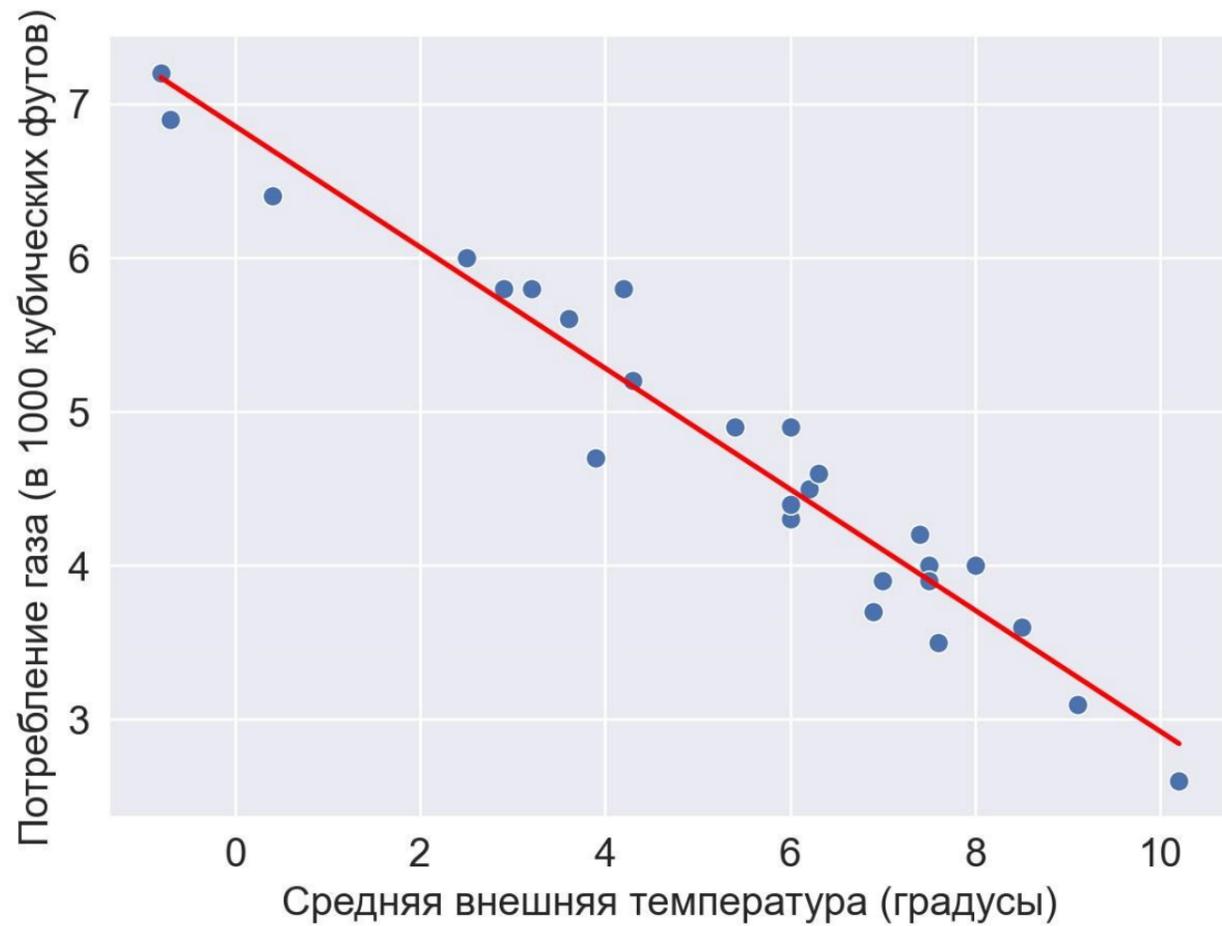
- Как потребление газа зависит от внешней температуры воздуха?
- Сколько газа необходимо при заданной температуре?



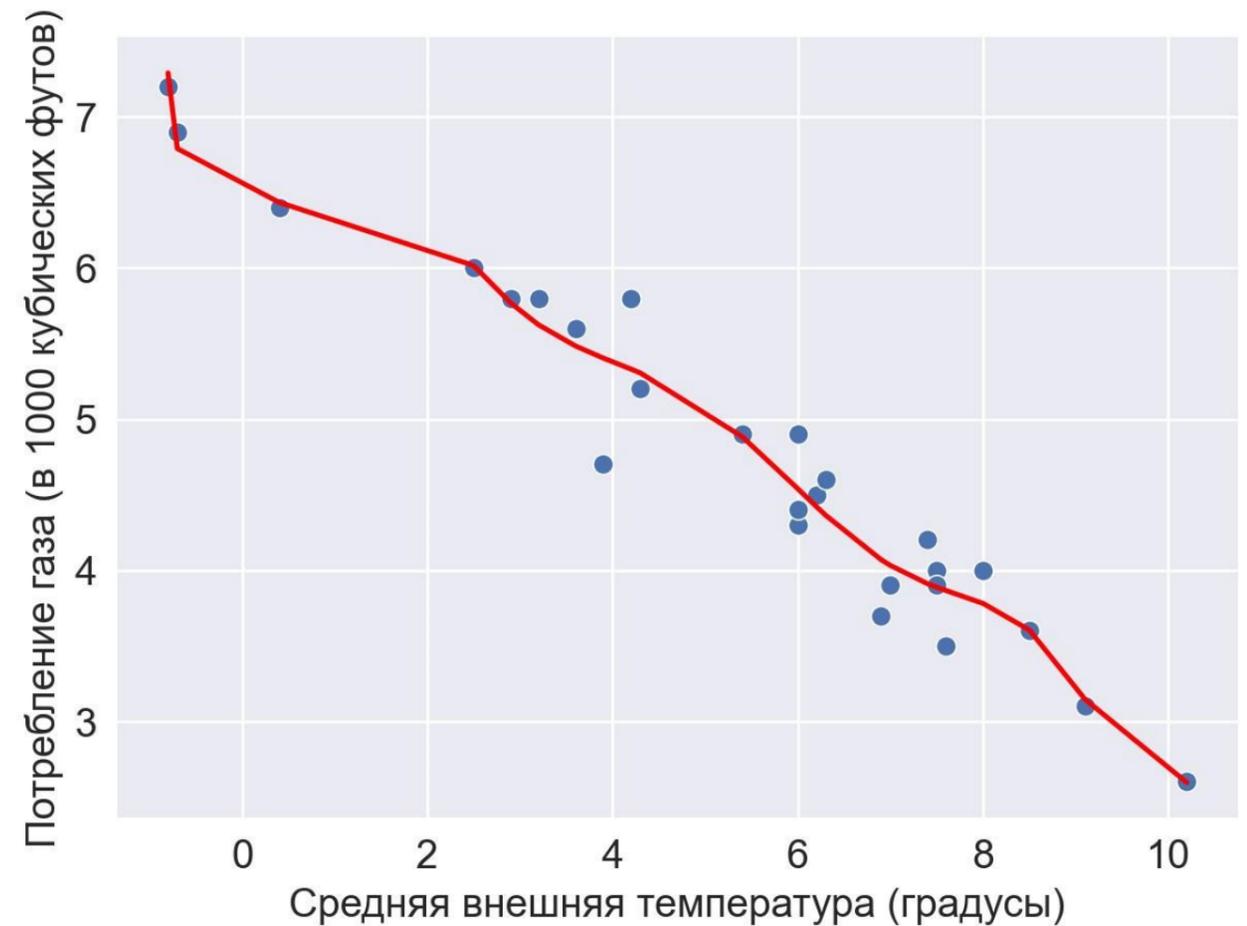
# Пример



# Пример



**Линейная модель**



**Более гибкая модель**

# Обозначения

- Обычно в нашем распоряжении есть выборка, содержащая  $n$  наблюдений.
- Каждое наблюдение состоит из  $p$  переменных (или параметров), на основании которых мы делаем предсказания.
- При помощи  $x_{ij}$  – обозначают  $i$ -е значение,  $j$ -й переменной, где  $i = 1, 2, \dots, n$ , а  $j = 1, 2, \dots, p$ .
- При помощи  $\mathbf{X}$  будем обозначать матрицу  $n \times p$ , чей  $(i, j)$ -й элемент это  $x_{ij}$ :

$$\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{pmatrix}$$

# Обозначения

- Строки матрицы  $\mathbf{X}$  будем записывать, как  $x_1, x_2, \dots, x_n$ . Здесь  $x_i$  – вектор длиной  $p$  переменных  $i$ -го наблюдения:

$$x_i = \begin{pmatrix} x_{i1} \\ x_{i2} \\ \vdots \\ x_{ip} \end{pmatrix}.$$

- Столбцы матрицы  $\mathbf{X}$  будем записывать, как  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_p$ . Здесь  $\mathbf{x}_j$  – вектор длиной  $n$   $j$ -го признака всех наблюдений:

$$\mathbf{x}_j = \begin{pmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{nj} \end{pmatrix}.$$

- Матрицу  $\mathbf{X}$  можно записать, как  $\mathbf{X} = (\mathbf{x}_1 \quad \mathbf{x}_2 \quad \dots \quad \mathbf{x}_p)$ .

# Формальная постановка задачи регрессии

Пусть

$X_1, X_2, X_p$  – случайные величины называемые **предикторами** (или **входами**, **независимыми переменными**).

Пусть  $\mathcal{X}_1, \mathcal{X}_2, \dots, \mathcal{X}_p$  – их область определения.

Будем использовать короткую форму записи

$$X := (X_1, X_2, \dots, X_p)$$

для вектора предикторов и

$$\mathcal{X} := \mathcal{X}_1 \times \mathcal{X}_2 \times \dots \times \mathcal{X}_p$$

для области определения

$Y$  – случайная величина, называемая **целевой переменной** (или **выход**, **отклик**)

Пусть  $\mathcal{Y}$  – область определения.

$\mathcal{D} \subset \mathcal{P}(\mathcal{X} \times \mathcal{Y})$  – множество примеров из неизвестного совместного распределения  $p(X, Y)$  входов и выходов, которое называется **данными**.

$\mathcal{D}$  обычно записывается списком

$$\mathcal{D} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

# Формальная постановка задачи регрессии

- Задача регрессии (и классификации) это **предсказать  $Y$  на основе  $X$ .**

- Другими словами, необходимо оценить функцию

$$f(x) := E\{Y|X = x\} = \int y \cdot p(y|x) dy$$

на основе данных.  $f(x)$  называется **функцией регрессии**.

- Если  $Y$  принимает численные значения, то задача называется **регрессией**.

- Если  $Y$  принимает номинальные значения, то задача называется **классификацией**.

# Формальная постановка задачи регрессии

- Мы предполагаем, что между  $Y$  и  $X$  существует связь, которую можно записать в общей форме:

$$Y = f(X) + \epsilon,$$

$f$  – фиксированная, но неизвестная функция от  $X_1, X_2, \dots, X_p$ ,  $\epsilon$  – ошибка, которая не зависит от  $X$ .

- Функция  $f$  выражает **систематическую** информацию о  $Y$ , содержащуюся в  $X$ .

## Зачем оценивать $f$ ?

### 1) Предсказание $Y$ :

$$\hat{Y} = \hat{f}(X)$$

$\hat{f}$  – оценка  $f$ ,  $\hat{Y}$  – предсказанное значение  $Y$ .

### 2) Статистический вывод.

Мы можем найти ответы на вопросы: какие предикторы связаны с откликом? Какова связь между откликом и каждым предиктором? и т.д.

# Предсказание

- Точность  $\hat{Y}$  в качестве предсказанного значения  $Y$  зависит от:  
1) **устранимой ошибки** и 2) **неустранимой ошибки**.
- Устраняемая ошибка связана с неидеальной оценкой  $f$ .
- Неустраняемая ошибка связана с наличием  $\epsilon$  (шума), который возникает из-за неучтенных факторов.

Пусть  $\hat{Y} = \hat{f}(X)$ , причем  $\hat{f}$  и  $X$  являются фиксированными, тогда:

$$\begin{aligned} E \left\{ (Y - \hat{Y})^2 \right\} &= E \left\{ \left( f(X) + \epsilon - \hat{f}(X) \right)^2 \right\} \\ &= \underbrace{\left( f(X) - \hat{f}(X) \right)^2}_{\text{устраняемая}} + \underbrace{\text{Var}\{\epsilon\}}_{\text{неустраняемая}}. \end{aligned}$$

# Модель простой линейной регрессии

- Самый простой предиктор  $X$  это одномерный вектор, т.е. ( $X = X_1$ )
- $f(x)$  – предполагается линейной:

$$f(x) = w_0 + w_1x$$

- модель линейной регрессии предполагает, что

$$y_i = w_0 + w_1x_i + \varepsilon_i, \quad E\{\varepsilon\} = 0, \quad Var\{\varepsilon\} = \sigma^2.$$

- 3 параметра линейной регрессии

$w_0$  – **пересечение** (свободный член)

$w_1$  – **угловой коэффициент** (коэффициент регрессии)

$\sigma^2$  – **дисперсия остатков**

# Модель простой линейной регрессии

## Оценки параметров

$$\hat{w}_0, \hat{w}_1, \hat{\sigma}^2$$

## Подогнанная линейная функция

$$\hat{f}(x) = \hat{w}_0 + \hat{w}_1 x$$

## Предсказанные / подогнанные значения

$$\hat{y}_i = \hat{f}(x_i)$$

## Остатки / отклонения

$$\varepsilon_i = y_i - \hat{y}_i = y_i - (\hat{w}_0 + \hat{w}_1 x_i)$$

## Сумма квадратов остатков

$$RSS = \sum_{i=1}^n \varepsilon_i^2$$

# Как оценить параметры?

Пример

Используя данные  $\mathcal{D} := \{(1,2), (2,3), (4,6)\}$ , предсказать значения для  $x = 3$ .

Построим линию через первую и вторую точку

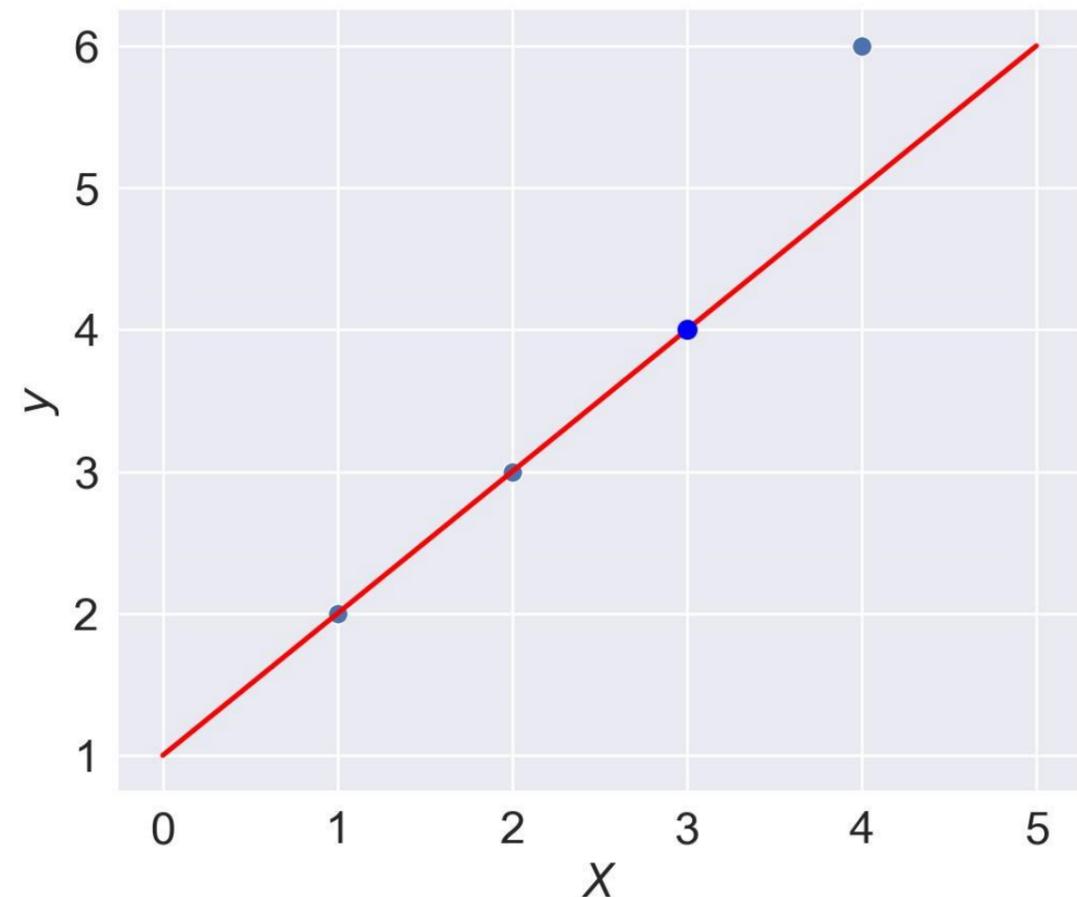
$$\hat{w}_1 = \frac{y_2 - y_1}{x_2 - x_1} = 1$$

$$\hat{w}_0 = y_1 - \hat{w}_1 x_1 = 1$$

RSS:

$i$	$y_i$	$\hat{y}_i$	$(y_i - \hat{y}_i)$
1	2	2	0
2	3	3	0
3	6	5	1
$\Sigma$			1

$$\hat{r}(3) = 4$$



# Как оценить параметры?

Пример

Используя данные  $\mathcal{D} := \{(1,2), (2,3), (4,6)\}$ , предсказать значения для  $x = 3$ .

Построим линию через первую и последнюю точку

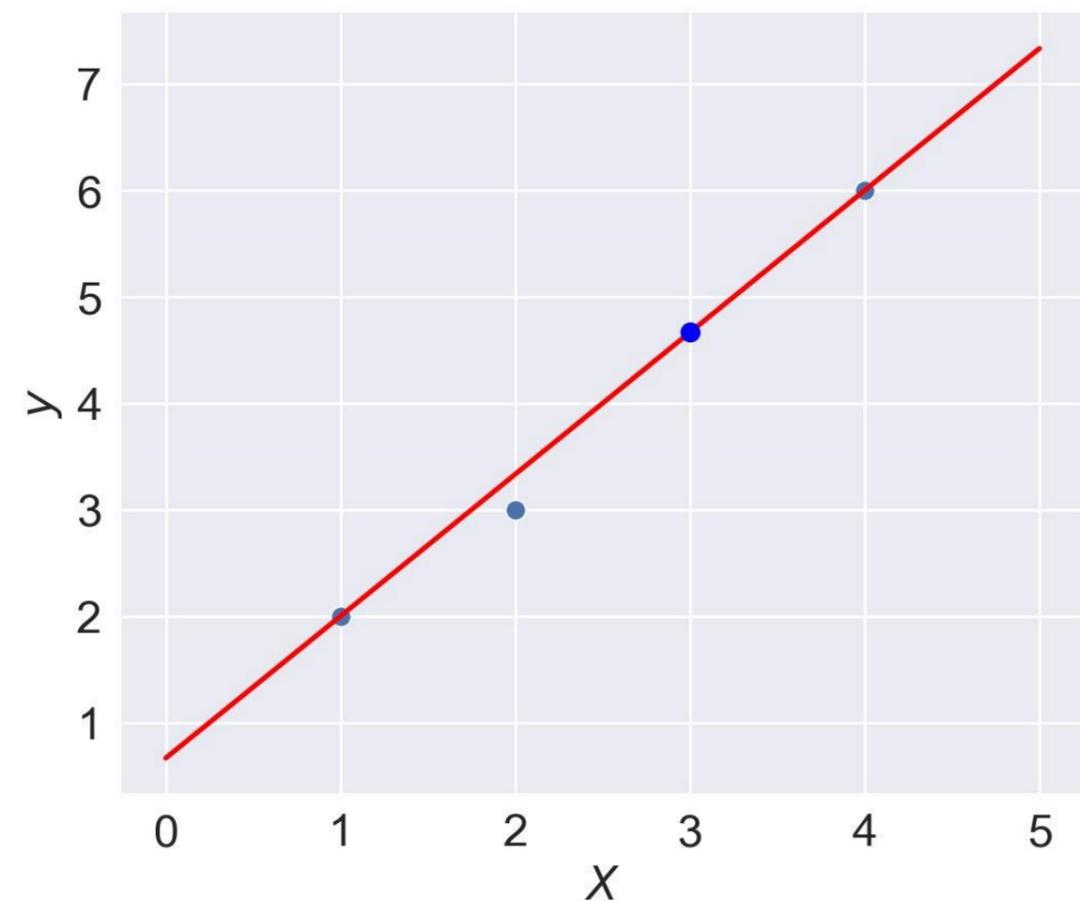
$$\hat{w}_1 = \frac{y_3 - y_1}{x_3 - x_1} = \frac{4}{3} = 1.333$$

$$\hat{w}_0 = y_1 - \hat{w}_1 x_1 = 2/3$$

RSS:

$i$	$y_i$	$\hat{y}_i$	$(y_i - \hat{y}_i)$
1	2	2	0
2	3	3.333	0.333
3	6	6	0
$\Sigma$			0.333

$$\hat{r}(3) = 4.667$$



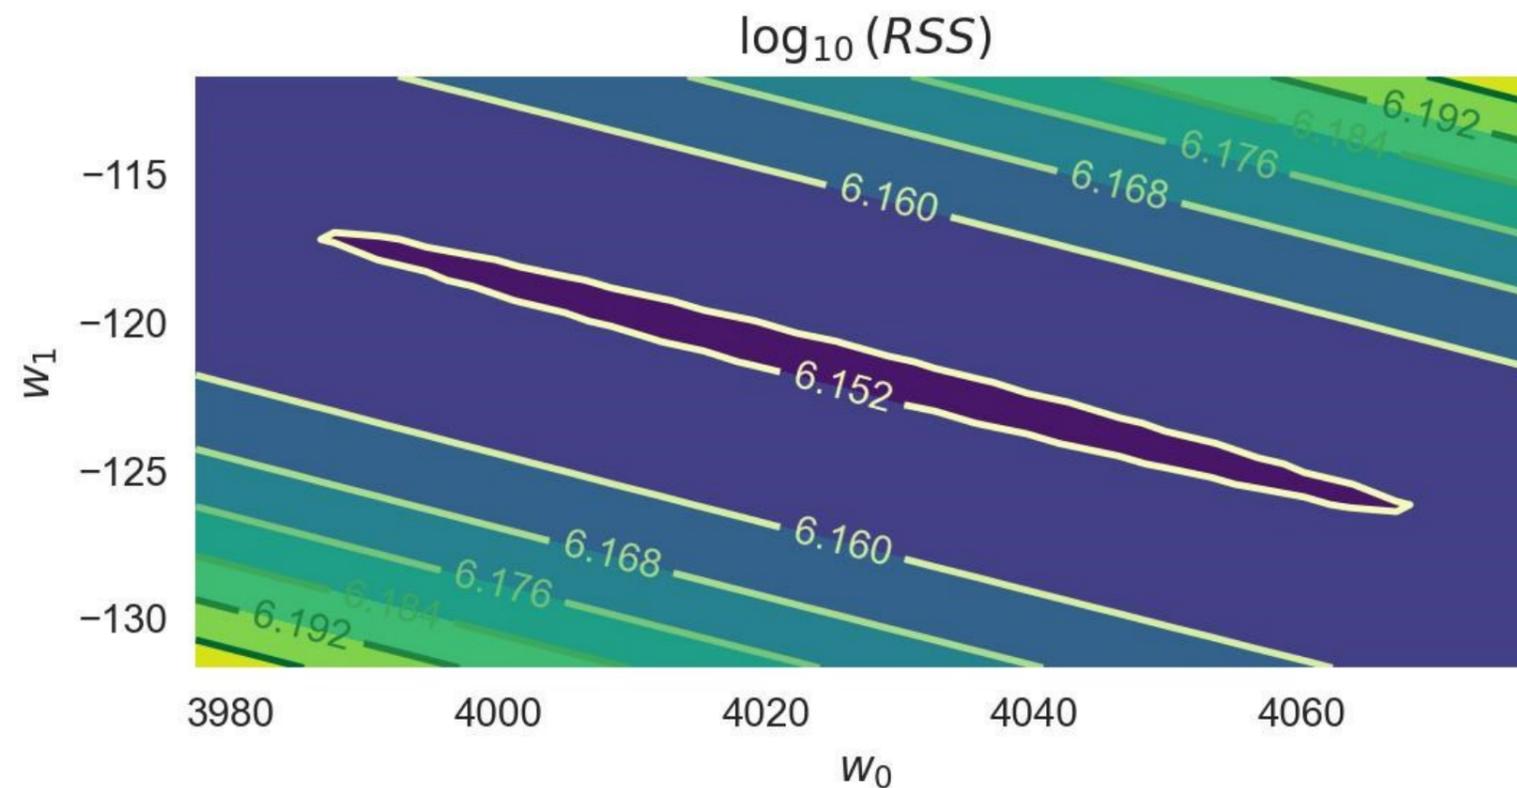
# Метод наименьших квадратов

Существует много различных способов оценки по данным параметров  $\hat{w}_0$ ,  $\hat{w}_1$  и  $\hat{\sigma}^2$ , которые отличаются свойствами, которыми в результате будет обладать решение.

Рассмотрим функцию

$$RSS = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i))^2.$$

для некоторого набора данных

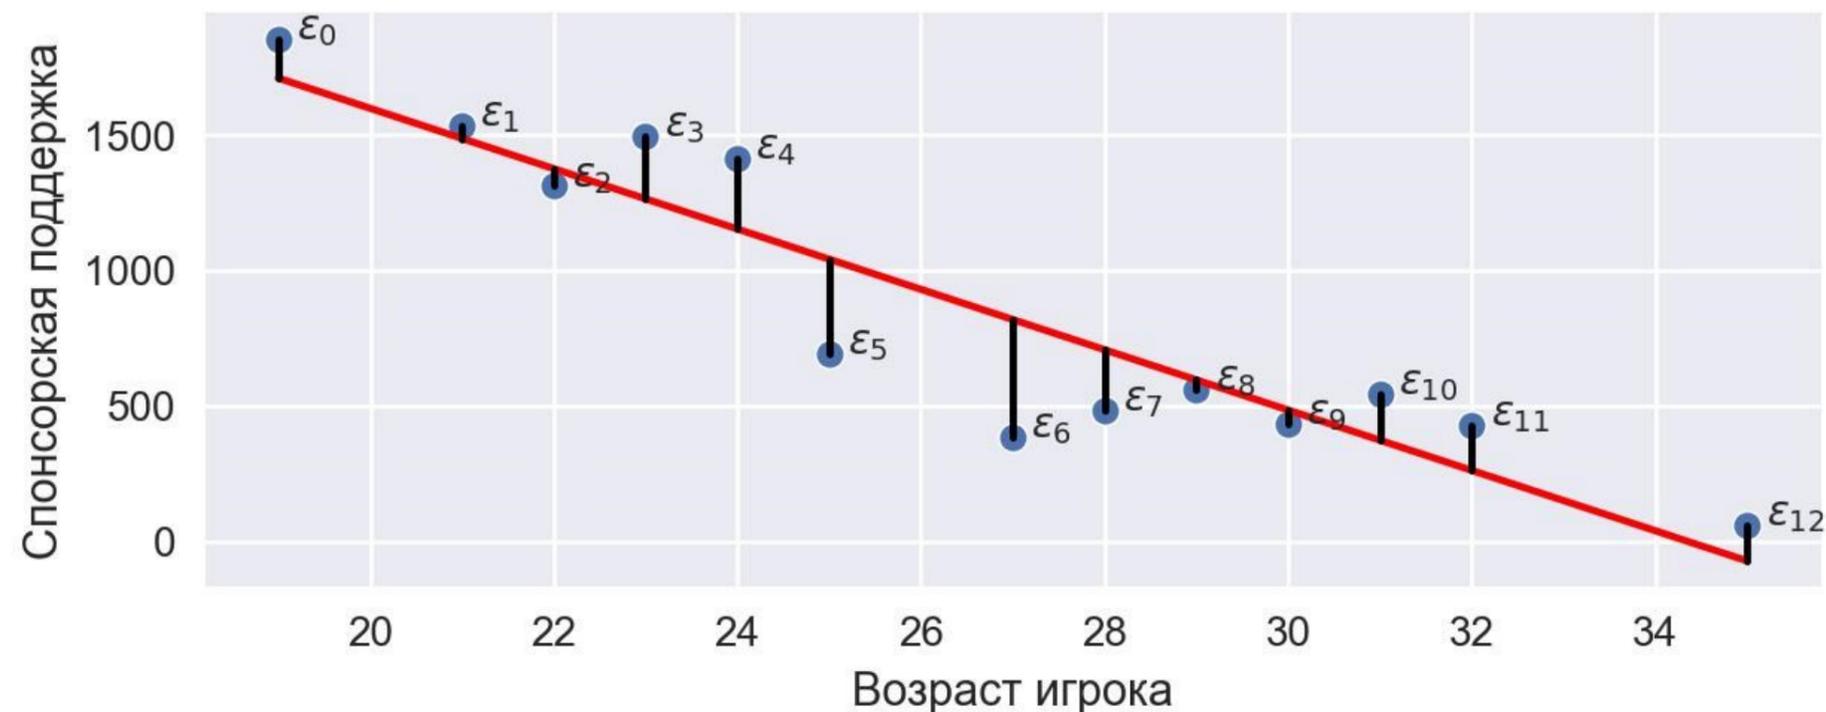


# Метод наименьших квадратов

Существует много различных способов оценки по данным параметров  $\hat{w}_0$ ,  $\hat{w}_1$  и  $\hat{\sigma}^2$ , которые отличаются свойствами, которыми в результате будет обладать решение.

**Оценка методом наименьших квадратов** (*LS – least square*) этих параметров осуществляется путем минимизации

$$RSS = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i))^2.$$



# Метод наименьших квадратов

Метод наименьших квадратов осуществляется путем минимизации

$$RSS = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i))^2.$$

Найдем производную по  $\hat{w}_0$ :

$$\frac{\partial RSS}{\partial \hat{w}_0} = \sum_{i=1}^n 2(y_i - \hat{w}_0 - \hat{w}_1 x_i)(-1) \triangleq 0$$

$$\Rightarrow \hat{w}_0 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{w}_1 x_i)$$

$$\hat{w}_0 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{w}_1 x_i) = \underbrace{\frac{1}{n} \sum_{i=1}^n y_i}_{\bar{y}} - \hat{w}_1 \underbrace{\frac{1}{n} \sum_{i=1}^n x_i}_{\bar{x}} = \bar{y} - \hat{w}_1 \bar{x}.$$

# Метод наименьших квадратов

Перепишем  $RSS$  учитывая выражение для  $\hat{w}_0$

$$\begin{aligned} RSS &= \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i))^2 = \sum_{i=1}^n (y_i - (\bar{y} - \hat{w}_1 \bar{x}) - \hat{w}_1 x_i)^2 \\ &= \sum_{i=1}^n (y_i - \bar{y} - \hat{w}_1 (x_i - \bar{x}))^2. \end{aligned}$$

Найдем производную по  $\hat{w}_1$ :

$$\frac{\partial RSS}{\partial \hat{w}_1} = \sum_{i=1}^n 2(y_i - \bar{y} - \hat{w}_1 (x_i - \bar{x}))(-1)(x_i - \bar{x}) \triangleq 0.$$

$$\Rightarrow \hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

# Метод наименьших квадратов

Оценка методом наименьших квадратов параметров  $\hat{w}_0$ ,  $\hat{w}_1$  и  $\hat{\sigma}^2$  осуществляется путем минимизации

$$RSS = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i))^2.$$

Решение можно записать в замкнутом виде:

$$\hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x}$$

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \varepsilon_i^2$$

# Метод наименьших квадратов (МНК) / Пример

Пример

Используя данные  $\mathcal{D} := \{(1,2), (2,3), (4,6)\}$ , предсказать значения для  $x = 3$ .

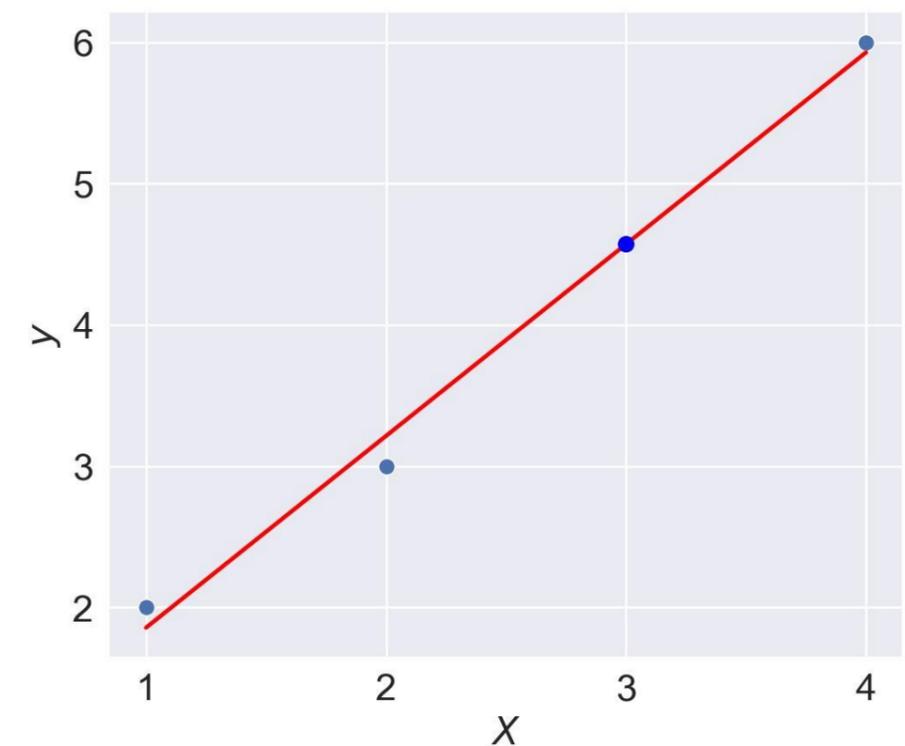
Построим линию регрессии методом МНК.

$$\bar{x} = 7/3, \bar{y} = 11/3.$$

$i$	$x_i - \bar{x}$	$y_i - \bar{y}$	$(x_i - \bar{x})^2$	$(x_i - \bar{x})(y_i - \bar{y})$
1	$-4/3$	$-5/3$	$16/9$	$20/9$
2	$-1/3$	$-2/3$	$1/9$	$2/9$
3	$5/3$	$7/3$	$25/9$	$35/9$
$\Sigma$			$42/9$	$57/9$

$$\hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{57}{42} \approx 1,36$$

$$\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x} = \frac{11}{3} - \frac{57}{42} \cdot \frac{7}{3} = 0,5$$



# Метод наименьших квадратов (МНК) / Пример

Пример

Используя данные  $\mathcal{D} := \{(1,2), (2,3), (4,6)\}$ , предсказать значения для  $x = 3$ .

Построим линию регрессии методом наименьших квадратов.

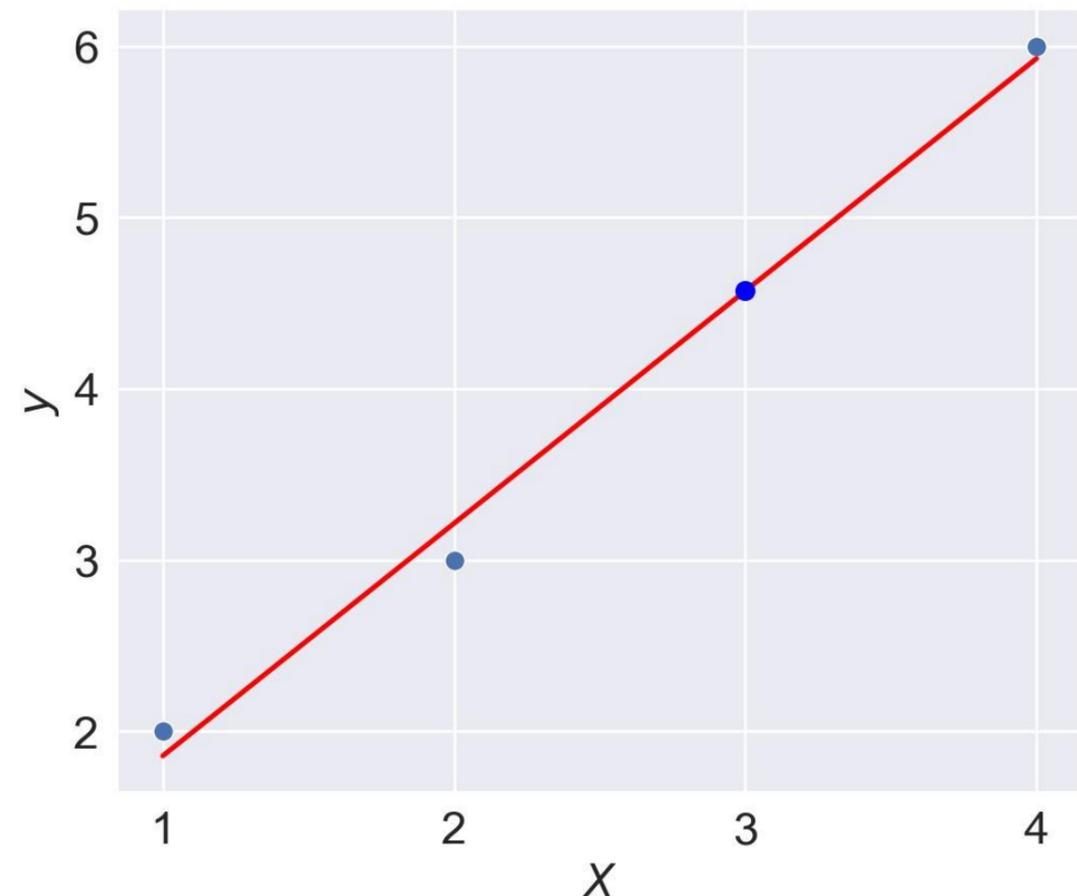
$$\hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{57}{42} \approx 1,36$$

$$\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x} = \frac{11}{3} - \frac{57}{42} \cdot \frac{7}{3} = 0,5$$

RSS:

$i$	$y_i$	$\hat{y}_i$	$(y_i - \hat{y}_i)^2$
1	2	1,86	0,020
2	3	3,21	0,050
3	6	5,93	0,005
$\Sigma$			0,071

$$\hat{r}(3) = 4,571$$



# Особенности уравнения линейной регрессии

Оценка по методу  
наименьших квадратов

Свободный член

$$\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x}$$

Коэффициент  
регрессии

$$\hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Коэффициент регрессии содержит умноженную на  $n$  ковариацию между  $X$  и  $Y$  и умноженную на  $n$  дисперсию  $X$  в знаменателе

$$\hat{w}_1 = \frac{n \cdot \text{Cov}(X, Y)}{n \cdot \text{Var}\{X\}} = \frac{\text{Cov}(X, Y)}{\text{Var}\{X\}}.$$

# Особенности уравнения линейной регрессии

Уравнение линейной регрессии (МНК):

$$\hat{y} = \underbrace{\bar{y} - \hat{w}_1 \bar{x}}_{\hat{w}_0} + \hat{w}_1 x = \bar{y} + \hat{w}_1 (x - \bar{x})$$

Решение проходит через точку  $(\bar{x}, \bar{y}) \Rightarrow$  можно выполнить центрирование:

$$\check{x}_i = x_i - \bar{x}$$

Оценка по методу  
наименьших квадратов  
(центрированные данные)

Свободный член

$$\hat{w}_0 = \bar{y}$$

Коэффициент  
регрессии

$$\hat{w}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(\check{x}_i)}{\sum_{i=1}^n (\check{x}_i)^2}$$

# Нормирование и нормализация данных

Нормирование означает

$$x'_i = \frac{x_i}{\sigma_x} \implies \bar{x}' = \frac{\bar{x}}{\sigma_x}$$

Оценка по методу  
наименьших квадратов  
(нормированные данные)

Свободный  
член

Коэффициент  
регрессии

$$\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x}' \quad \hat{w}_1 = \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}')$$

Нормализация = центрирование относительно 0 + нормирование

$$x'_i = \frac{x_i - \bar{x}}{\sigma_x}$$

Оценка по методу  
наименьших квадратов  
(нормализованные данные)

Свободный  
член

Коэффициент  
регрессии

$$\hat{w}_0 = \bar{y}$$

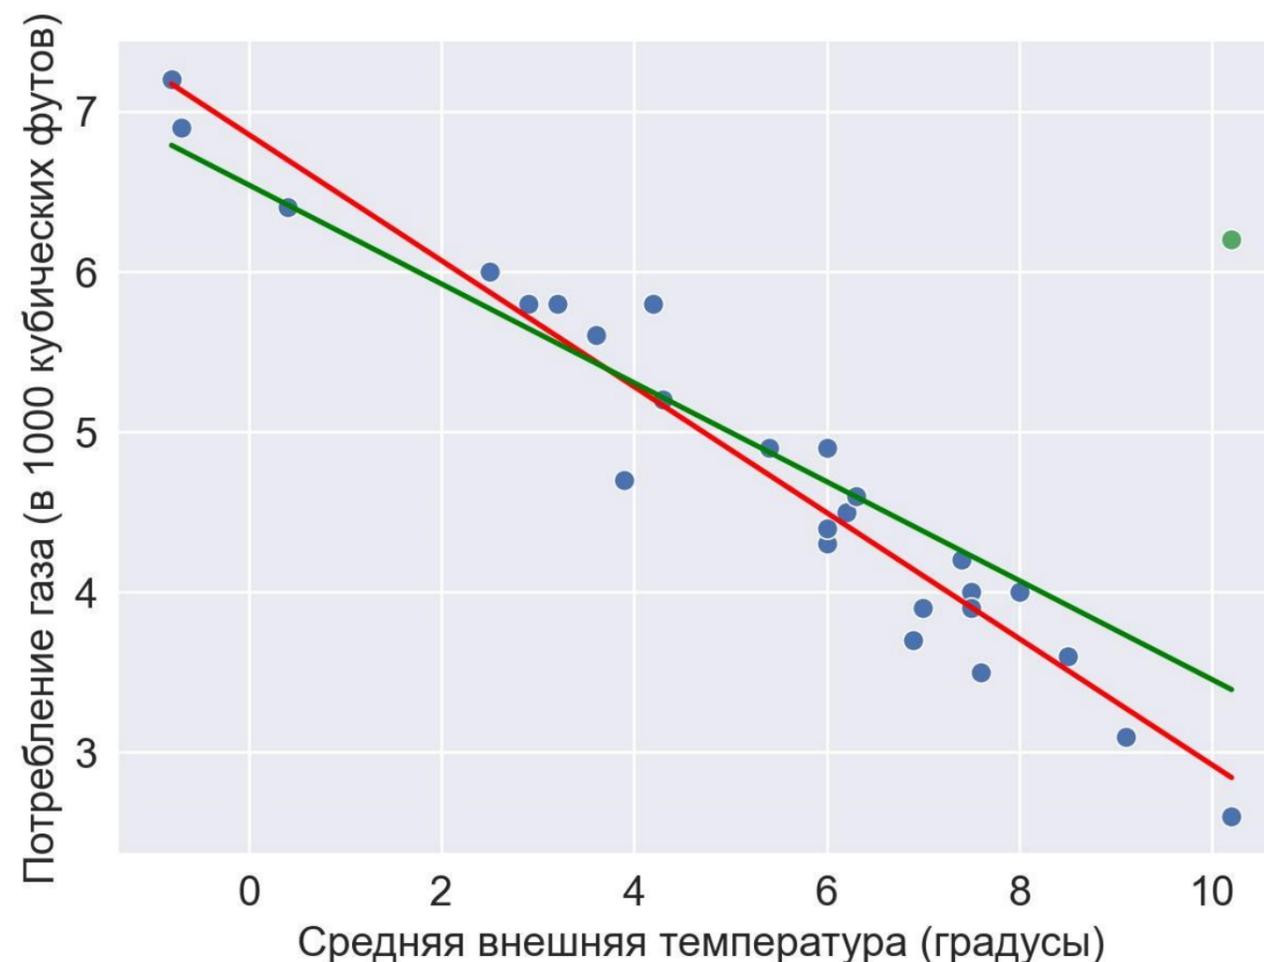
$$\hat{w}_1 = \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}')$$

# Линейная регрессия (МНК): анализ отклонений

$$\sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n (y_i - (\hat{w}_0 + \hat{w}_1 x_i)) = 0$$

Это следует из того, что  $\hat{w}_0 = \bar{y} - \hat{w}_1 \bar{x}$ . [Доказать].

Эта особенность делает линейную регрессию чувствительной к **выбросам**.



# Векторные обозначения

Обозначим через  $\mathbf{x}_i = [1 \ x_i]^T$ , а через  $\mathbf{w} = [w_0 \ w_1]^T$ , тогда уравнение линейной регрессии переписывается, как

$$y_i = \mathbf{x}_i^T \mathbf{w} + \epsilon_i$$

Такая запись особенно удобна, когда число предикторов больше одного.

# Множественная регрессия

Несколько предикторов  $X_1, X_2, \dots, X_p$

$$\begin{aligned} Y &= w_0 + w_1 X_1 + w_2 X_2 + \dots + w_p X_p + \varepsilon = \\ &= \mathbf{X}^T \mathbf{w} + \varepsilon \end{aligned}$$

с  $p + 1$  параметрами  $\mathbf{w} = [w_0, w_1, \dots, w_p]$ .

# Матричная запись (линейная форма)

Несколько предикторов  $X_1, X_2, \dots, X_p$

$$\begin{aligned} Y &= w_0 + \sum_{i=1}^p w_i X_i + \varepsilon \\ &= \mathbf{X}^T \mathbf{w} + \varepsilon \end{aligned}$$

где

$$\mathbf{w} = \begin{pmatrix} w_0 \\ w_1 \\ \vdots \\ w_p \end{pmatrix}, \quad \mathbf{X} := \begin{pmatrix} 1 \\ X_1 \\ \vdots \\ X_p \end{pmatrix}$$

свободный член ( $w_0$ ) рассматривается, как и все остальные параметры, но для искусственно заданной константной переменной  $X_0 = 1$ .

# Уравнение для всего набора данных

Для всего набора данных  $(x_1, y_1), \dots, (x_n, y_n)$ :

$$\underbrace{\begin{pmatrix} y_1 \\ \vdots \\ y_N \end{pmatrix}}_{\mathbf{y}} = \underbrace{\begin{pmatrix} 1 & x_{1,1} & \cdots & x_{1,p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n,1} & \cdots & x_{n,p} \end{pmatrix}}_{\mathbf{X}} \underbrace{\begin{pmatrix} w_0 \\ \vdots \\ w_d \end{pmatrix}}_{\mathbf{w}} + \underbrace{\begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}}_{\boldsymbol{\varepsilon}}.$$

т.е.

$$\mathbf{y} = \mathbf{X}\mathbf{w} + \boldsymbol{\varepsilon}$$

# Оценка по МНК

Оценка  $\hat{\mathbf{w}}$  по методу наименьших квадратов (МНК) минимизирует:

$$RSS(\hat{\mathbf{w}}) = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \|\mathbf{y} - \mathbf{X}\hat{\mathbf{w}}\|^2$$

МНК оценка вектора  $\hat{\mathbf{w}}$  вычисляется по формуле:

$$\hat{\mathbf{w}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

**Доказательство: ?**

# Оценка по МНК

Оценка  $\hat{\mathbf{w}}$  по методу наименьших квадратов (МНК) минимизирует:

$$RSS(\hat{\mathbf{w}}) = \|\mathbf{y} - \hat{\mathbf{y}}\|^2 = \|\mathbf{y} - \mathbf{X}\hat{\mathbf{w}}\|^2$$

МНК оценка вектора  $\hat{\mathbf{w}}$  вычисляется по формуле:

$$\hat{\mathbf{w}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

**Доказательство:**

$$RSS(\hat{\mathbf{w}}) = (\mathbf{y} - \mathbf{X}\hat{\mathbf{w}})^T (\mathbf{y} - \mathbf{X}\hat{\mathbf{w}})$$

*Это квадратичная функция с  $p + 1$  параметрами.*

$$\frac{\partial RSS}{\partial \hat{\mathbf{w}}} = -2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\hat{\mathbf{w}}), \quad \frac{\partial^2 RSS}{\partial \hat{\mathbf{w}} \partial \hat{\mathbf{w}}^T} = 2\mathbf{X}^T \mathbf{X}$$

$$-2\mathbf{X}^T (\mathbf{y} - \mathbf{X}\hat{\mathbf{w}}) = 0 \quad \Rightarrow \quad \hat{\mathbf{w}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}.$$

# Множественная регрессия

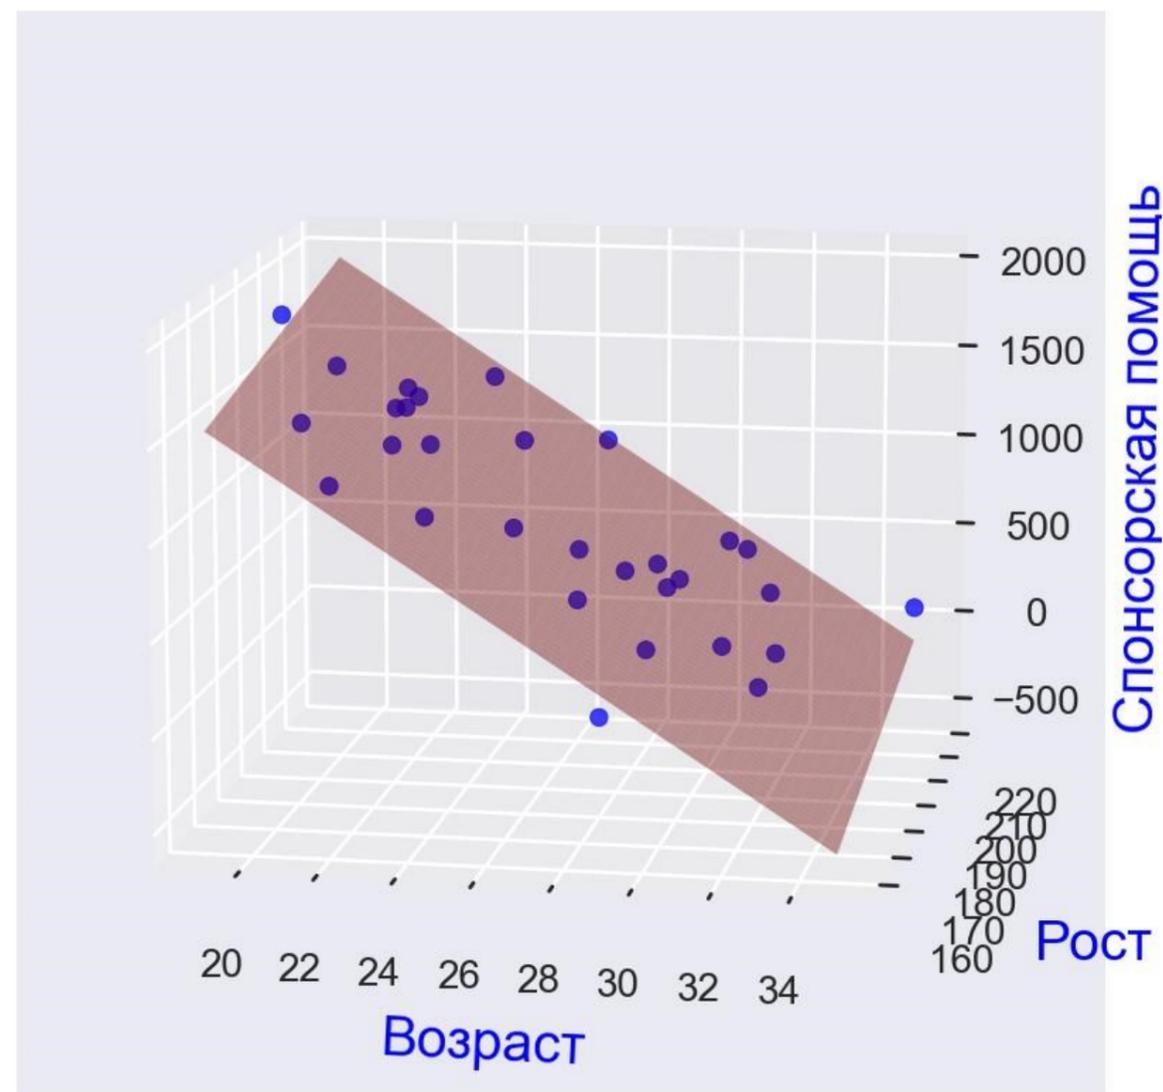
Предположим, у нас есть данные о игроках баскетбольной команды, которые включают в себя такие параметры, как рост, вес, возраст и средненедельный объем спонсорской поддержки.

#	Возраст ( $X_1$ ), лет	Рост ( $X_2$ ), см	Вес ( $X_3$ ), фунты	Спонсорская помощь ( $Y$ ), \$
1	29	192	218	561
2	35	218	251	60
3	22	197	221	1312
4	22	192	219	1359
5	29	198	223	362
6	21	166	188	1536
...	...	...	...	...

# Множественная регрессия: пример

Пример с использованием данных о игроках баскетбольной команды.

**Предикторы:** возраст, рост; **целевая переменная:** средненедельный объем спонсорской поддержки.



# Градиентный спуск

Обучение = минимизация функции потерь.

- Минимизация осуществляется методом градиентного спуска

$$\mathbf{w}_t = \mathbf{w}_{t-1} - \eta \frac{\partial RSS}{\partial \mathbf{w}},$$

где  $\mathbf{w}_t$  – значение весов на шаге  $t$ ,  $\frac{\partial RSS}{\partial \mathbf{w}}$  – градиент функции потерь по  $\mathbf{w}$ ,  $\eta$  – параметр скорости обучения.

- Выбор параметра  $\eta$  – значительно влияет на процесс обучения.

# ЛИНЕЙНАЯ РЕГРЕССИЯ, КАК ГЕНЕРАТИВНАЯ МОДЕЛЬ

# Распределение Гаусса

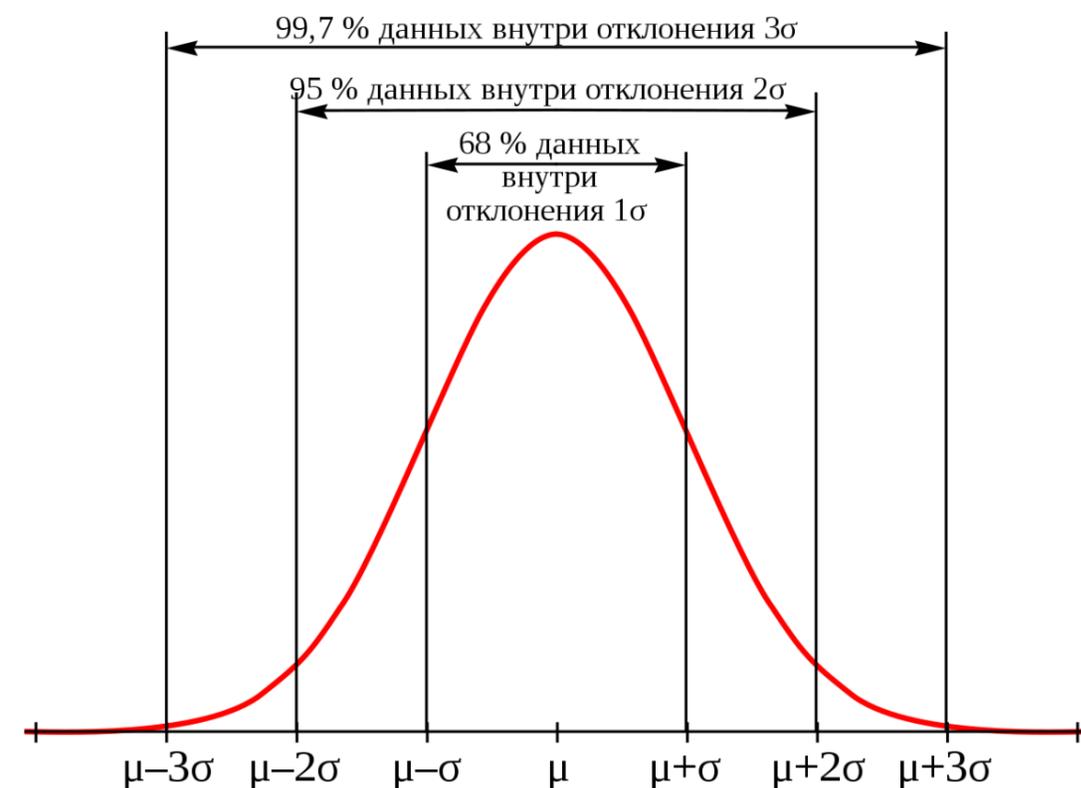
- Случайная величина  $x$  с нормальным распределением принимает значения в интервале  $(-\infty, \infty)$  и имеет функцию **плотности вероятности**

$$p(x | \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

где  $\mu$  – математическое ожидание,  $\sigma^2$  – дисперсия.

## Правило трех сигм

Вероятность того, что случайная погрешность отдельного анализа не превысит по абсолютному значению  $\sigma$  (или  $2\sigma$ ,  $3\sigma$ ), составляет 0,68 (или 0,95, 0,99).



# Стандартное нормальное распределение

- Гауссово распределение  $p(x)$  обозначают, как  $\mathcal{N}(x | \mu, \sigma^2)$  или  $X \sim \mathcal{N}(\mu, \sigma^2)$
- Все нормальные распределения могут быть сведены к одному нормальному распределению с параметрами  $\mu = 0, \sigma^2 = 1$ . Для этого нужно выполнить преобразование

$$u = \frac{x - \mu}{\sigma}.$$

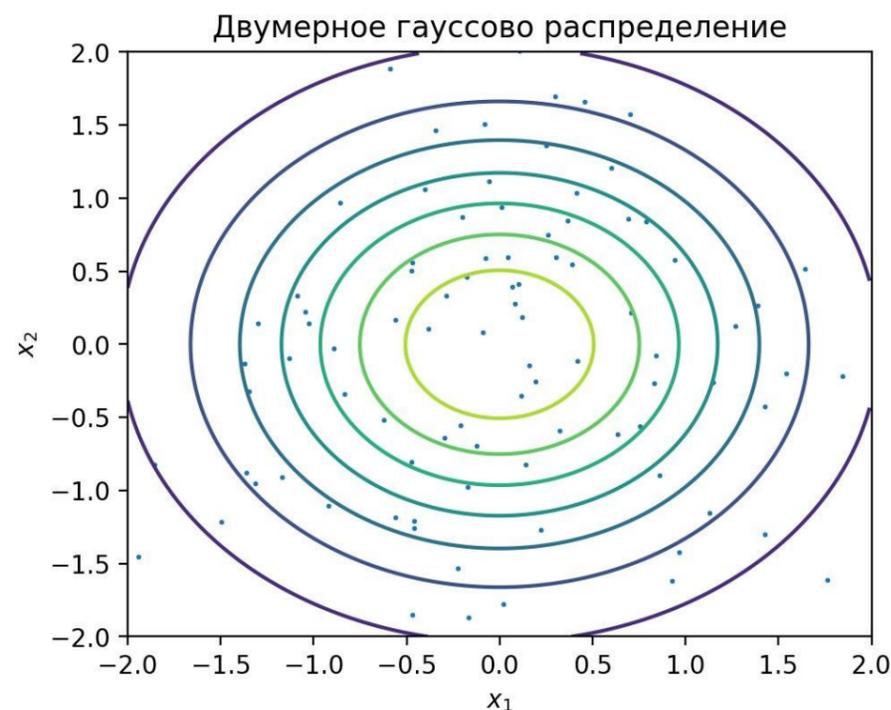
- Если с.в.  $X \sim \mathcal{N}(\mu, \sigma^2)$ , то  $U = \frac{X - \mu}{\sigma}$  имеет распределение  $U \sim \mathcal{N}(0, 1)$ .

# Многомерное гауссово распределение

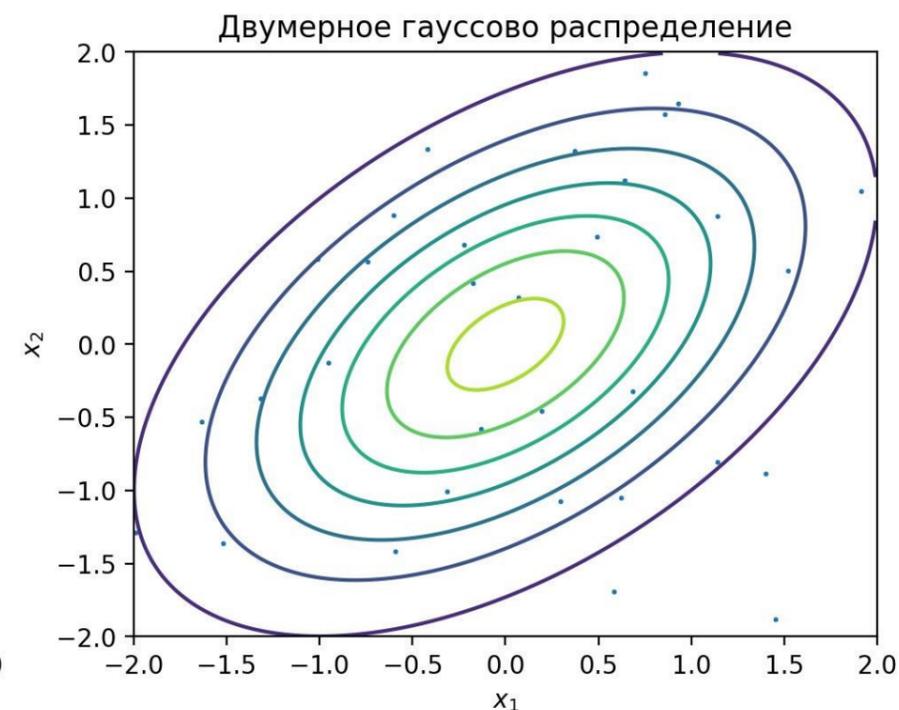
**Многомерное гауссово распределение** полностью определяется вектором средних  $\boldsymbol{\mu}$  и ковариационной матрицей  $\boldsymbol{\Sigma}$

$$p(\mathbf{x} \mid \boldsymbol{\mu}, \boldsymbol{\Sigma}) = (2\pi)^{-\frac{D}{2}} \cdot |\boldsymbol{\Sigma}|^{-\frac{1}{2}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

$p(\mathbf{x} \mid \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$  – короткая запись,  $D$  – размерность вектора  $\mathbf{x}$ .



$$\boldsymbol{\Sigma} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$



$$\boldsymbol{\Sigma} = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix}$$

# Генеративная модель

Модель линейной регрессии предполагает, что

$$y_i = \mathbf{x}_i^T \mathbf{w} + \varepsilon_i, \quad E\{\varepsilon\} = 0, \quad \text{Var}\{\varepsilon\} = \sigma^2.$$

Мы накладываем ограничения на отклонения  $\varepsilon$ , но не задаем закона их распределения.

Мы можем сделать предположение относительно распределения  $\varepsilon$ :

$$\varepsilon \sim \mathcal{N}(0, \sigma^2)$$

следовательно

$$Y \sim \mathcal{N}(\mathbf{X}^T \mathbf{w}, \sigma^2).$$

Мы можем сгенерировать выборку по этой модели.

# Метод максимального правдоподобия

Пусть  $p(X, Y | \mathbf{w})$  совместная плотность распределения  $X$  и  $Y$ , а  $\mathbf{w}$  – неизвестный параметр(ы) распределения.

Функция **правдоподобия**

$$L_{\mathcal{D}}(\mathbf{w}) := \prod_{i=1}^n p(x_i, y_i | \mathbf{w}).$$

Правдоподобие показывает вероятность появления набора данных  $\mathcal{D}$ .

# Метод максимального правдоподобия

Пусть  $p(X, Y | \mathbf{w})$  совместная плотность распределения  $X$  и  $Y$ , а  $\mathbf{w}$  – неизвестный параметр(ы) распределения.

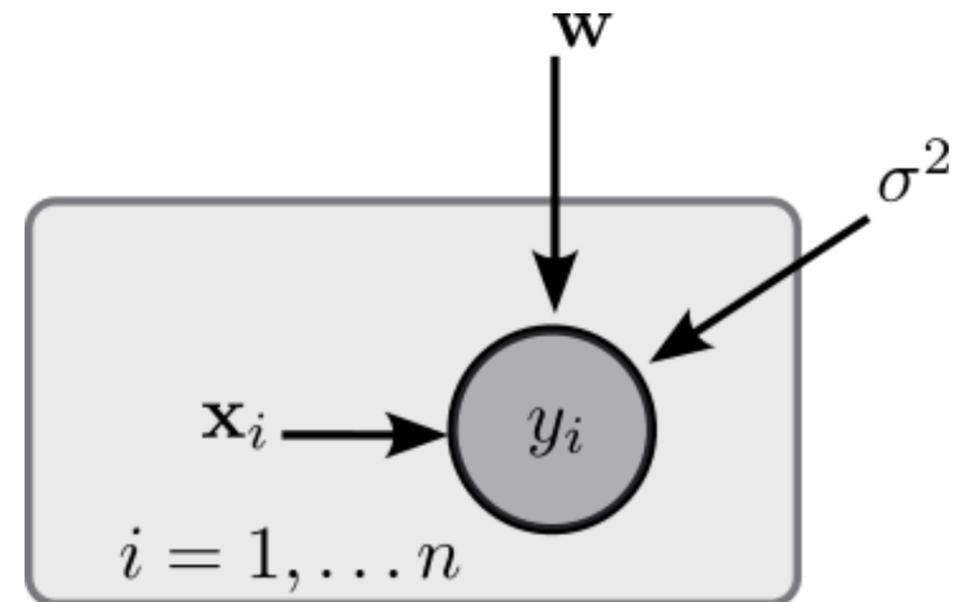
Функция **правдоподобия**

$$L_{\mathcal{D}}(\mathbf{w}) := \prod_{i=1}^n p(x_i, y_i | \mathbf{w}).$$

Правдоподобие показывает вероятность появления набора данных  $\mathcal{D}$ .

Сущность метода **максимального правдоподобия** состоит в том, чтобы найти такое значение параметра  $\mathbf{w}$ , которое будет максимизировать  $L_{\mathcal{D}}(\mathbf{w})$ . При максимизации подразумевается, что данные  $\mathcal{D}$  фиксированы, а изменяется только параметр  $\mathbf{w}$ :

$$\mathbf{w}_{ML} = \arg \max_{\mathbf{w}} L_{\mathcal{D}}(\mathbf{w})$$



# Применение метода максимального правдоподобия

- При оценивании неизвестных параметров распределения на практике часто используют метод максимального правдоподобия (*MLE – maximum likelihood estimation*).

# Применение метода максимального правдоподобия

- При оценивании неизвестных параметров на практике часто используют метод максимального правдоподобия (*MLE – maximum likelihood estimation*).
- Пусть есть случайные величины  $x_1, x_2, \dots, x_n$  каждая из которых распределены по закону  $p(x|\theta)$ . Предполагается, что функция  $p(x|\theta)$  известная с точностью до параметра  $\theta$ .

# Применение метода максимального правдоподобия

- При оценивании неизвестных параметров на практике часто используют метод максимального правдоподобия (*MLE – maximum likelihood estimation*).
- Пусть есть случайные величины  $x_1, x_2, \dots, x_n$  каждая из которых распределены по закону  $p(x|\theta)$ . Предполагается, что функция  $p(x|\theta)$  известная с точностью до параметра  $\theta$ .
- Функция

$$L(\theta) := \prod_{i=1}^n p(x_i|\theta).$$

представляет собой случайную величину и называется **функцией правдоподобия**.

# Применение метода максимального правдоподобия

- При оценивании неизвестных параметров на практике часто используют метод максимального правдоподобия (*MLE – maximum likelihood estimation*).
- Пусть есть случайные величины  $x_1, x_2, \dots, x_n$  каждая из которых распределены по закону  $p(x|\theta)$ . Предполагается, что функция  $p(x|\theta)$  известная с точностью до параметра  $\theta$ .
- Функция

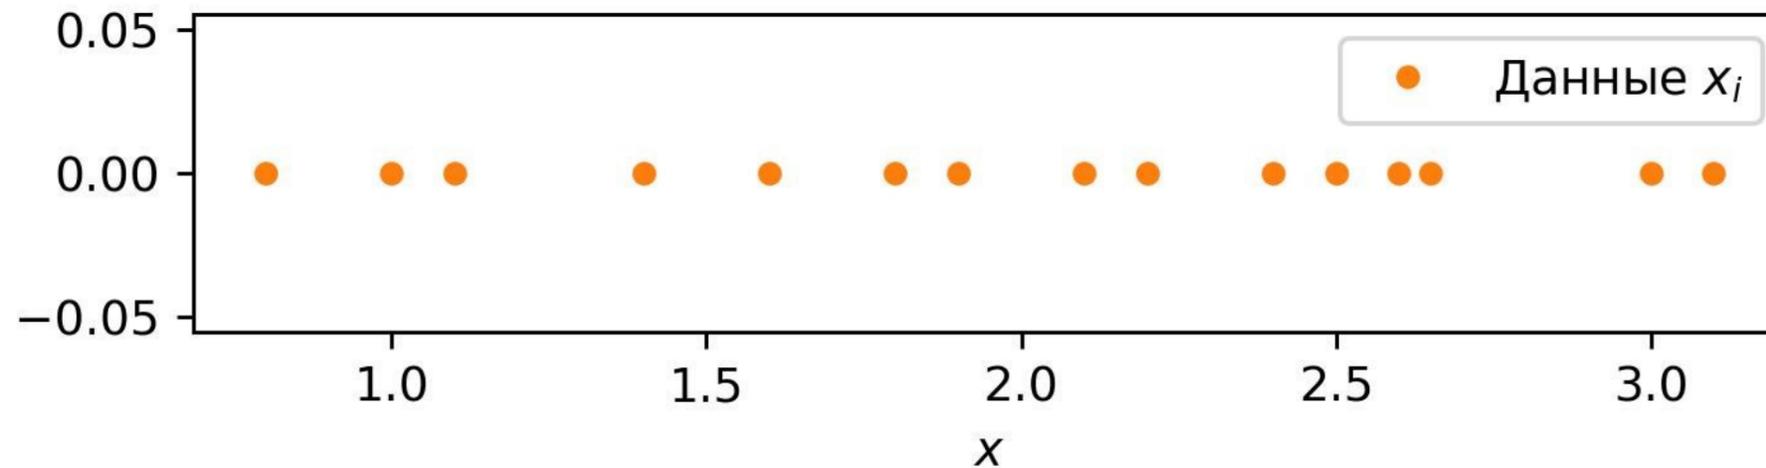
$$L(\theta) := \prod_{i=1}^n p(x_i|\theta).$$

представляет собой случайную величину и называется **функцией правдоподобия**.

- **Повторим:** метода **максимального правдоподобия** состоит в том, чтобы найти такое значение параметра  $\theta$ , которое будет максимизировать  $L(\theta)$ . При максимизации подразумевается, что реализации с.в.  $x_1, x_2, \dots, x_n$  фиксированы, а изменяется только параметр  $\theta$ .

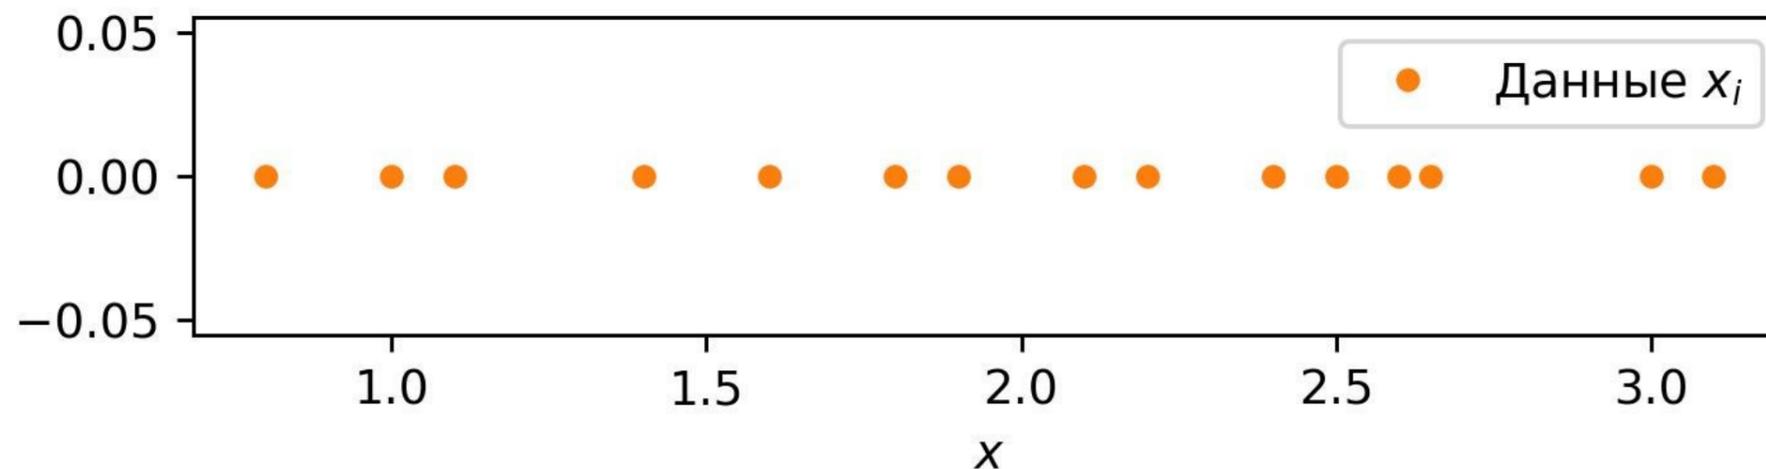
# Максимальное правдоподобие: пример

- Пусть даны реализации с.в.  $x_1, x_2, \dots, x_n$  имеющей нормальное распределение и известное  $\sigma$ .



# Максимальное правдоподобие: пример

- Пусть даны реализации с.в.  $x_1, x_2, \dots, x_n$  имеющей нормальное распределение и известное  $\sigma$ .



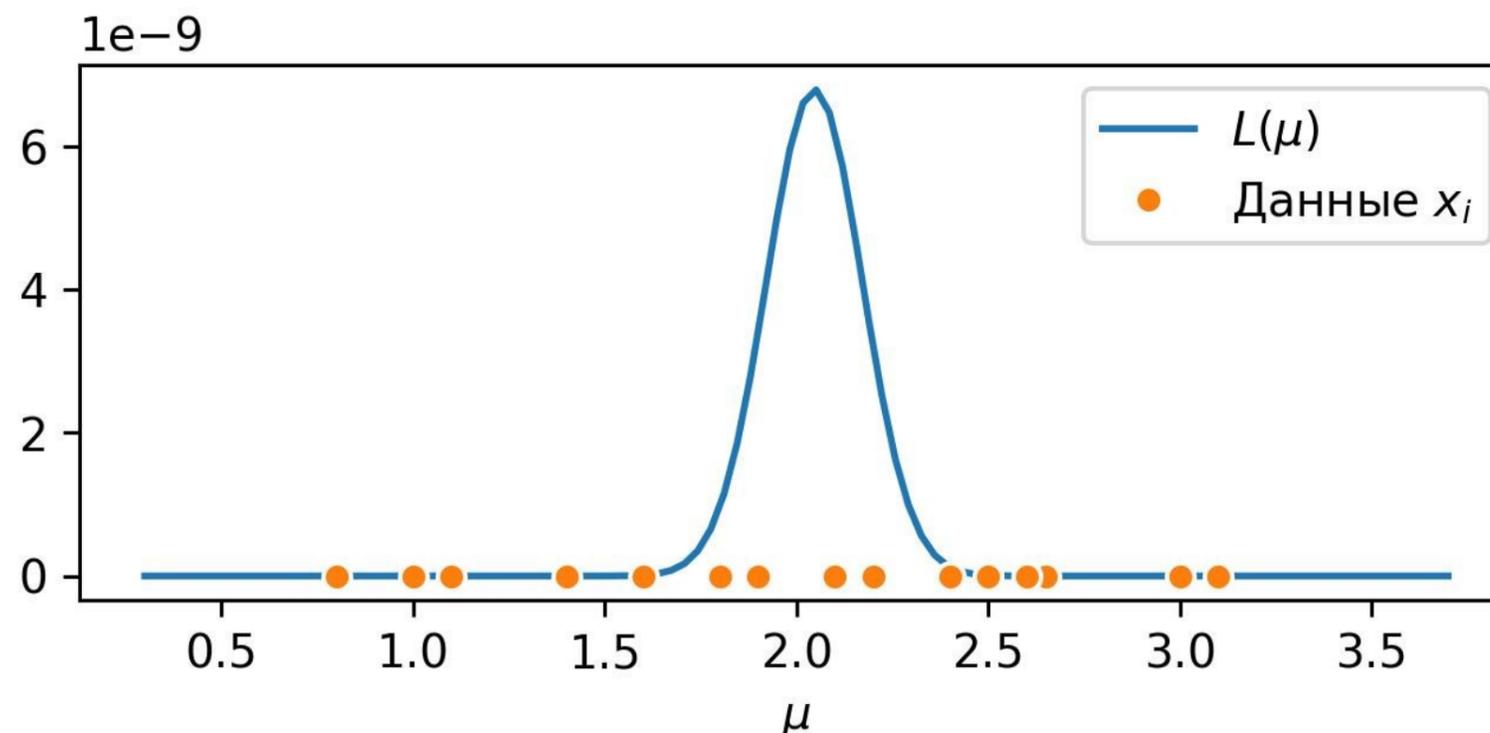
- Функция правдоподобия имеет вид (пусть  $\sigma = 0,8$ ):

$$L(\mu) = \prod_{i=1}^n p(x_i | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^n}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$

# Максимальное правдоподобие: пример

- Пусть даны реализации с.в.  $x_1, x_2, \dots, x_n$  имеющей нормальное распределение и известное  $\sigma$ .
- Функция правдоподобия имеет вид (пусть  $\sigma = 0,8$ ):

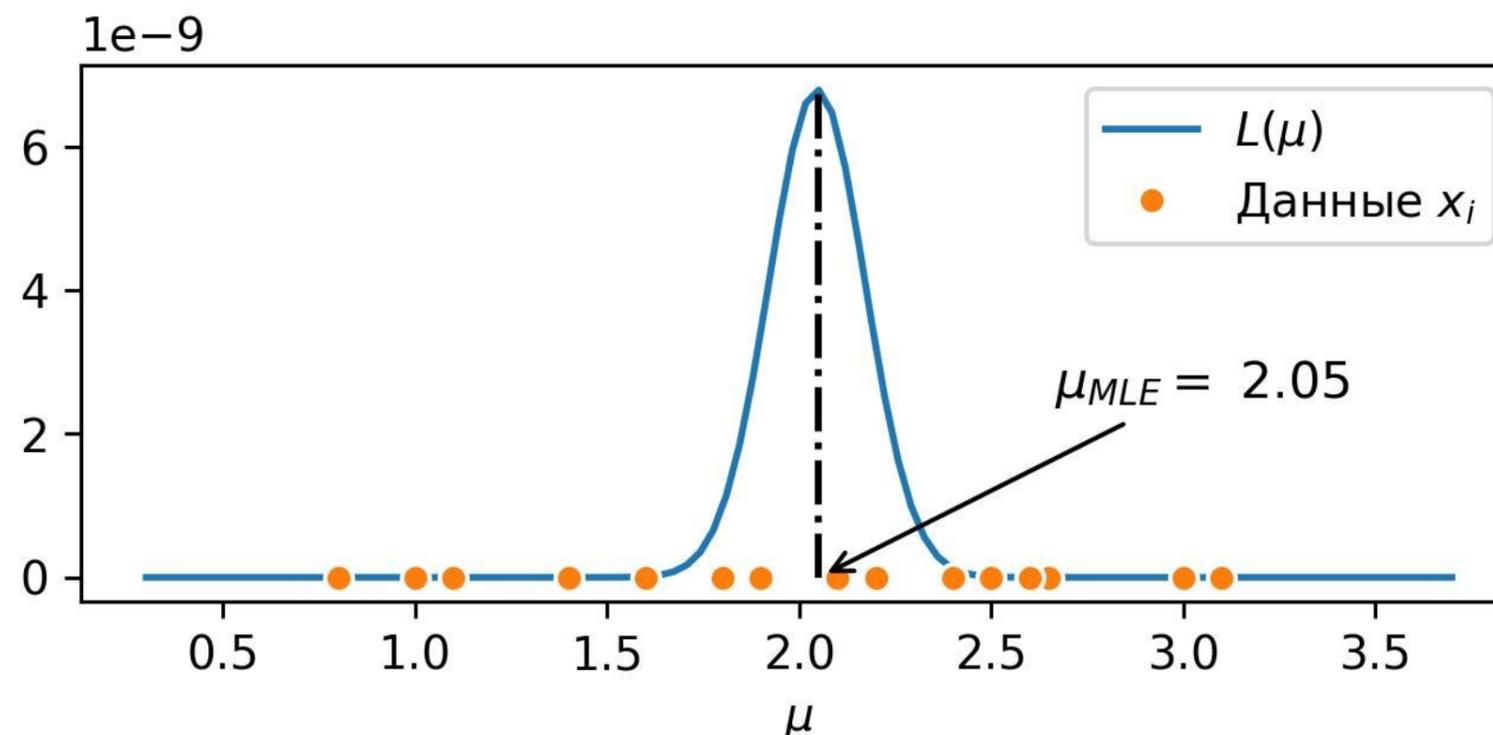
$$L(\mu) = \prod_{i=1}^n p(x_i | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$



# Максимальное правдоподобие: пример

- Пусть даны реализации с.в.  $x_1, x_2, \dots, x_n$  имеющей нормальное распределение и известное  $\sigma$ .
- Функция правдоподобия имеет вид (пусть  $\sigma = 0,8$ ):

$$L(\mu) = \prod_{i=1}^n p(x_i | \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^n}} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$



# Максимальное правдоподобие: пример

- Функция правдоподобия имеет вид:

$$L(\mu) = \prod_{i=1}^n p(x_i | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$

- На практике используют логарифм от функции правдоподобия:

$$\log L(\mu) = \log \prod_{i=1}^n p(x_i | \mu, \sigma) = \underbrace{\log \frac{1}{\sqrt{2\pi}\sigma^n}}_{\text{const}} - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$

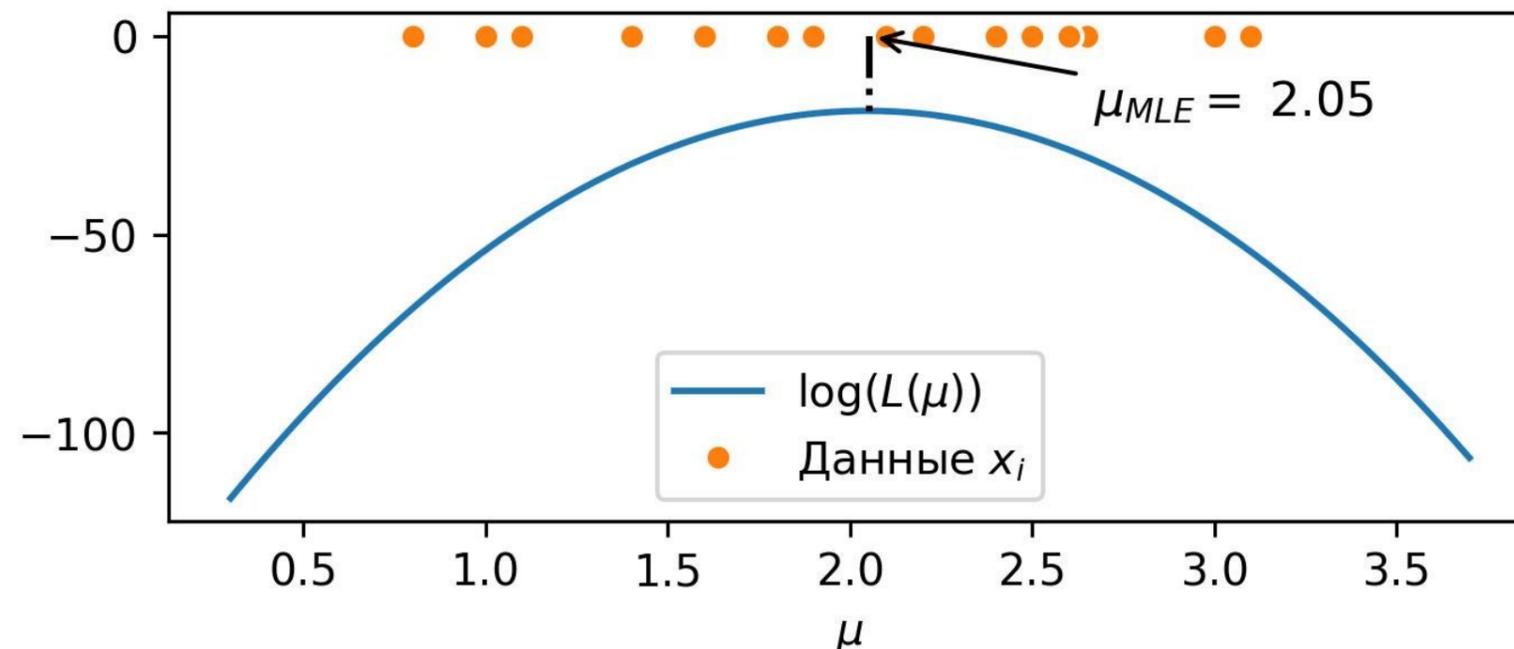
# Максимальное правдоподобие: пример

- Функция правдоподобия имеет вид:

$$L(\mu) = \prod_{i=1}^n p(x_i | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right).$$

- На практике используют логарифм от функции правдоподобия:

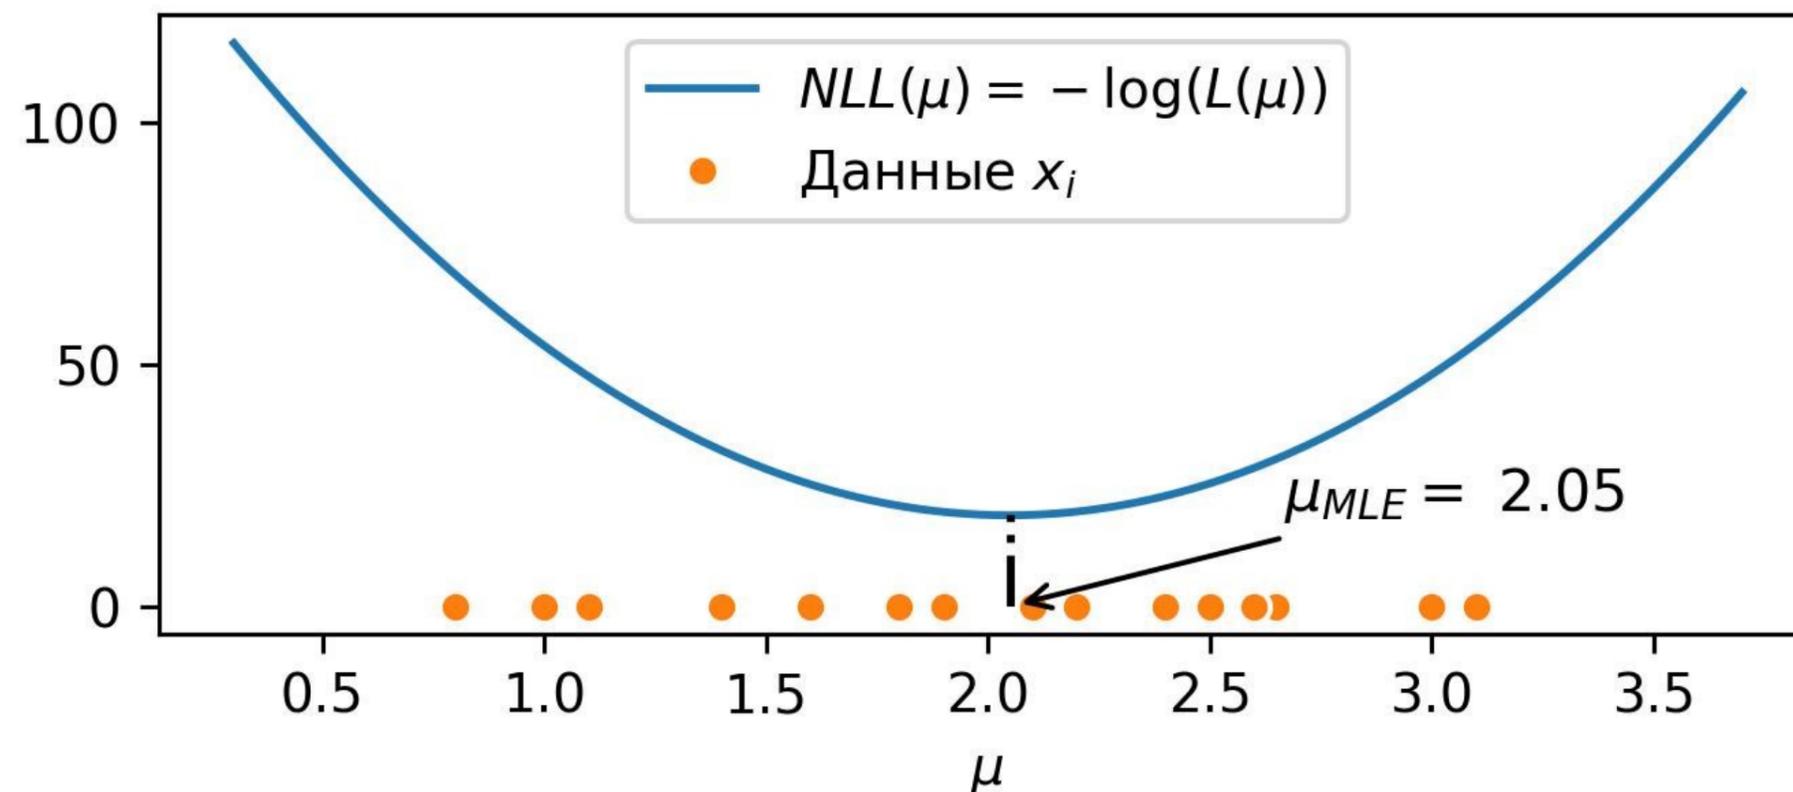
$$\log L(\mu) = \log \prod_{i=1}^n p(x_i | \mu, \sigma) = \underbrace{\log \frac{1}{\sqrt{2\pi}\sigma^n}}_{\text{const}} - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2.$$



# Максимальное правдоподобие: пример

- На практике также вместо поиска максимума функции правдоподобия ищут минимум отрицательного логарифмического правдоподобия:

$$NLL(\mu) = -\log L(\mu) = \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 + \text{const.}$$



# Метод максимального правдоподобия для линейной регрессии

Правдоподобие

$$L_{\mathcal{D}}(\hat{\mathbf{w}}) := \prod_{i=1}^n p(x_i, y_i) = \prod_{i=1}^n p(y_i|x_i)p(x_i) = \prod_{i=1}^n p(y_i|x_i) \prod_{i=1}^n p(x_i)$$

# Метод максимального правдоподобия для линейной регрессии

Правдоподобие

$$L_{\mathcal{D}}(\hat{\mathbf{w}}) := \prod_{i=1}^n p(x_i, y_i) = \prod_{i=1}^n p(y_i | x_i) p(x_i) = \prod_{i=1}^n p(y_i | x_i) \prod_{i=1}^n p(x_i)$$

Условное  
правдоподобие

$$\begin{aligned} L_{\mathcal{D}}^{\text{cond}}(\hat{\mathbf{w}}) &:= \prod_{i=1}^n p(y_i | x_i) = \prod_{i=1}^n \mathcal{N}(y_i | \mathbf{x}_i^T \mathbf{w}, \hat{\sigma}^2) = \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\hat{\sigma}}} e^{-\frac{(y_i - \hat{y}_i)^2}{2\hat{\sigma}^2}} = \frac{1}{(\sqrt{2\pi\hat{\sigma}})^n} e^{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \end{aligned}$$

# Метод максимального правдоподобия для линейной регрессии

Правдоподобие

$$L_{\mathcal{D}}(\hat{\mathbf{w}}) := \prod_{i=1}^n p(x_i, y_i) = \prod_{i=1}^n p(y_i | x_i) p(x_i) = \prod_{i=1}^n p(y_i | x_i) \prod_{i=1}^n p(x_i)$$

Условное  
правдоподобие

$$\begin{aligned} L_{\mathcal{D}}^{\text{cond}}(\hat{\mathbf{w}}) &:= \prod_{i=1}^n p(y_i | x_i) = \prod_{i=1}^n \mathcal{N}(y_i | \mathbf{x}_i^T \mathbf{w}, \hat{\sigma}^2) = \\ &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\hat{\sigma}}} e^{-\frac{(y_i - \hat{y}_i)^2}{2\hat{\sigma}^2}} = \frac{1}{(\sqrt{2\pi\hat{\sigma}})^n} e^{-\frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \end{aligned}$$

**Логарифм правдоподобия**

$$\log L_{\mathcal{D}}^{\text{cond}}(\hat{\mathbf{w}}) = -\frac{n}{2} \log(2\pi\hat{\sigma}^2) - \frac{1}{2\hat{\sigma}^2} \sum_{i=1}^n (y_i - \hat{y}_i)^2 = -\frac{1}{2\hat{\sigma}^2} \text{RSS} - \text{const.}$$

⇒ если мы предполагаем нормальность  $\varepsilon$ , то оценка по методу максимального правдоподобия совпадает с оценкой по методу наименьших квадратов.

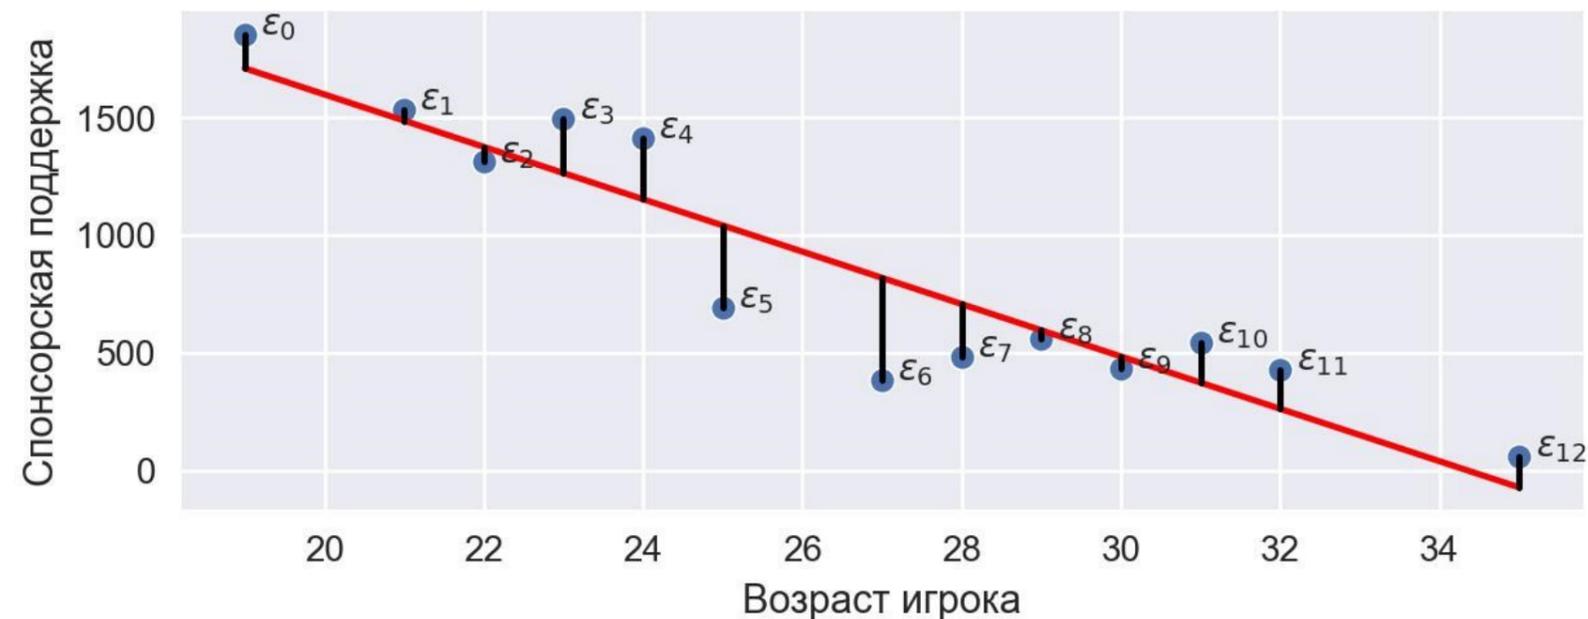
# ОЦЕНКА КАЧЕСТВА ЛИНЕЙНОЙ РЕГРЕССИИ

# Значение RSS

Значение  $RSS$  показывает, какая величина отклонения (дисперсии) остается после подгонки линейной модели, которая измеряется квадратами различий между прогнозируемыми и фактическими целевыми значениями.

$$RSS = \sum_{i=1}^n \varepsilon_i^2$$

Недостаток  $RSS$  – его зависимость от набора данных и величин измерения целевой переменной.

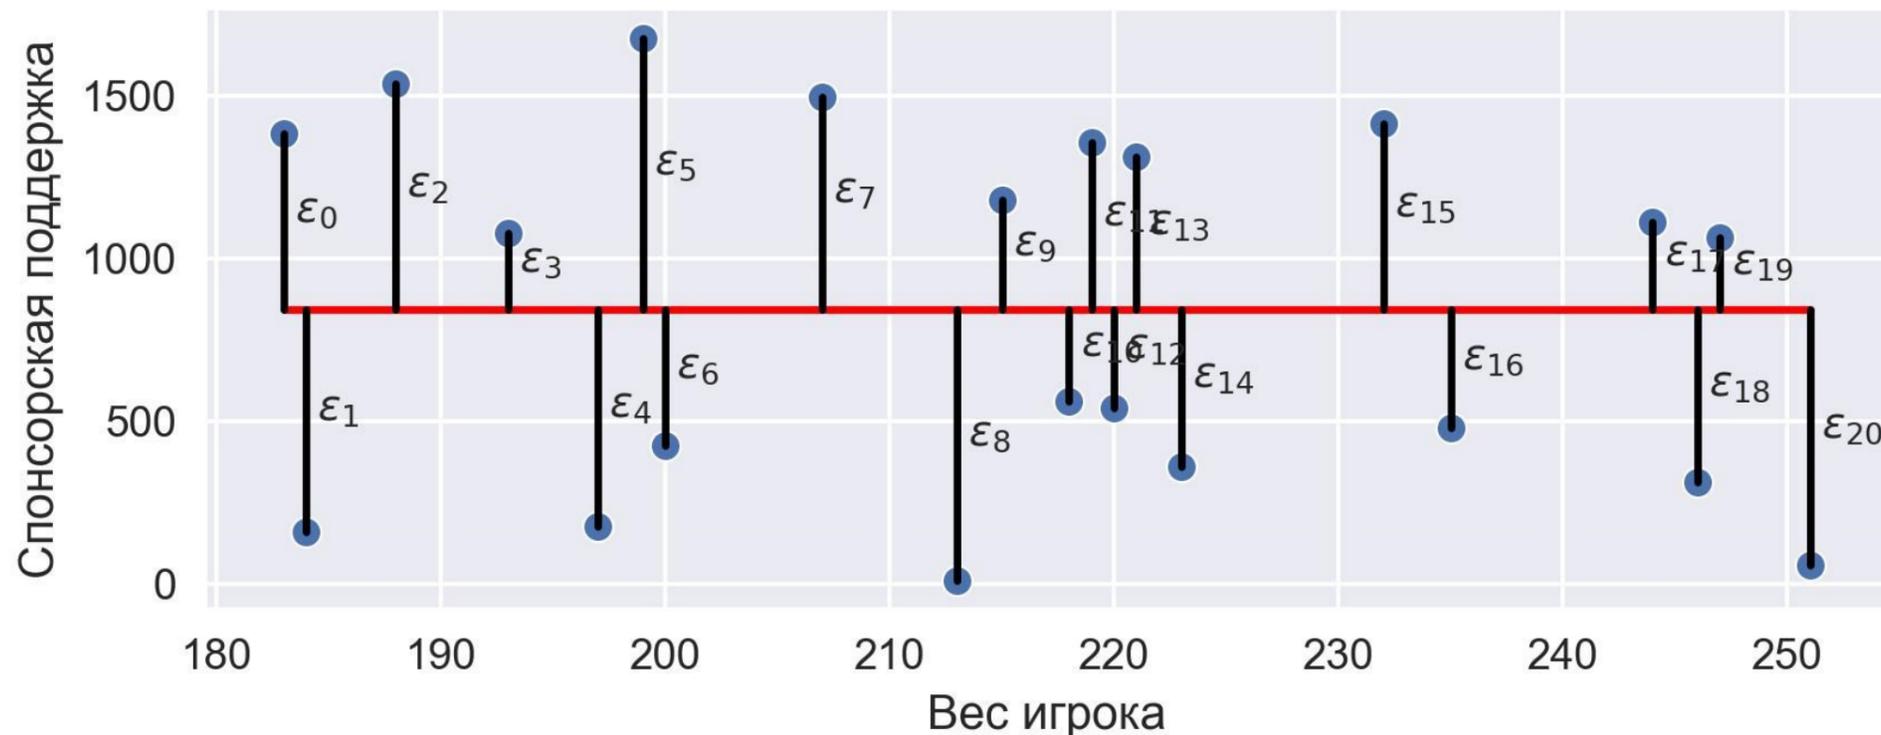


# Коэффициент детерминации $R^2$

В основе расчета коэффициента  $R^2$  лежит сравнение оцениваемой модели с «базовой» моделью. В качестве **базовой модели** используется модель, которая для любого  $x$  возвращает среднее значение целевой переменной  $y$ , которое рассчитано на всем наборе.

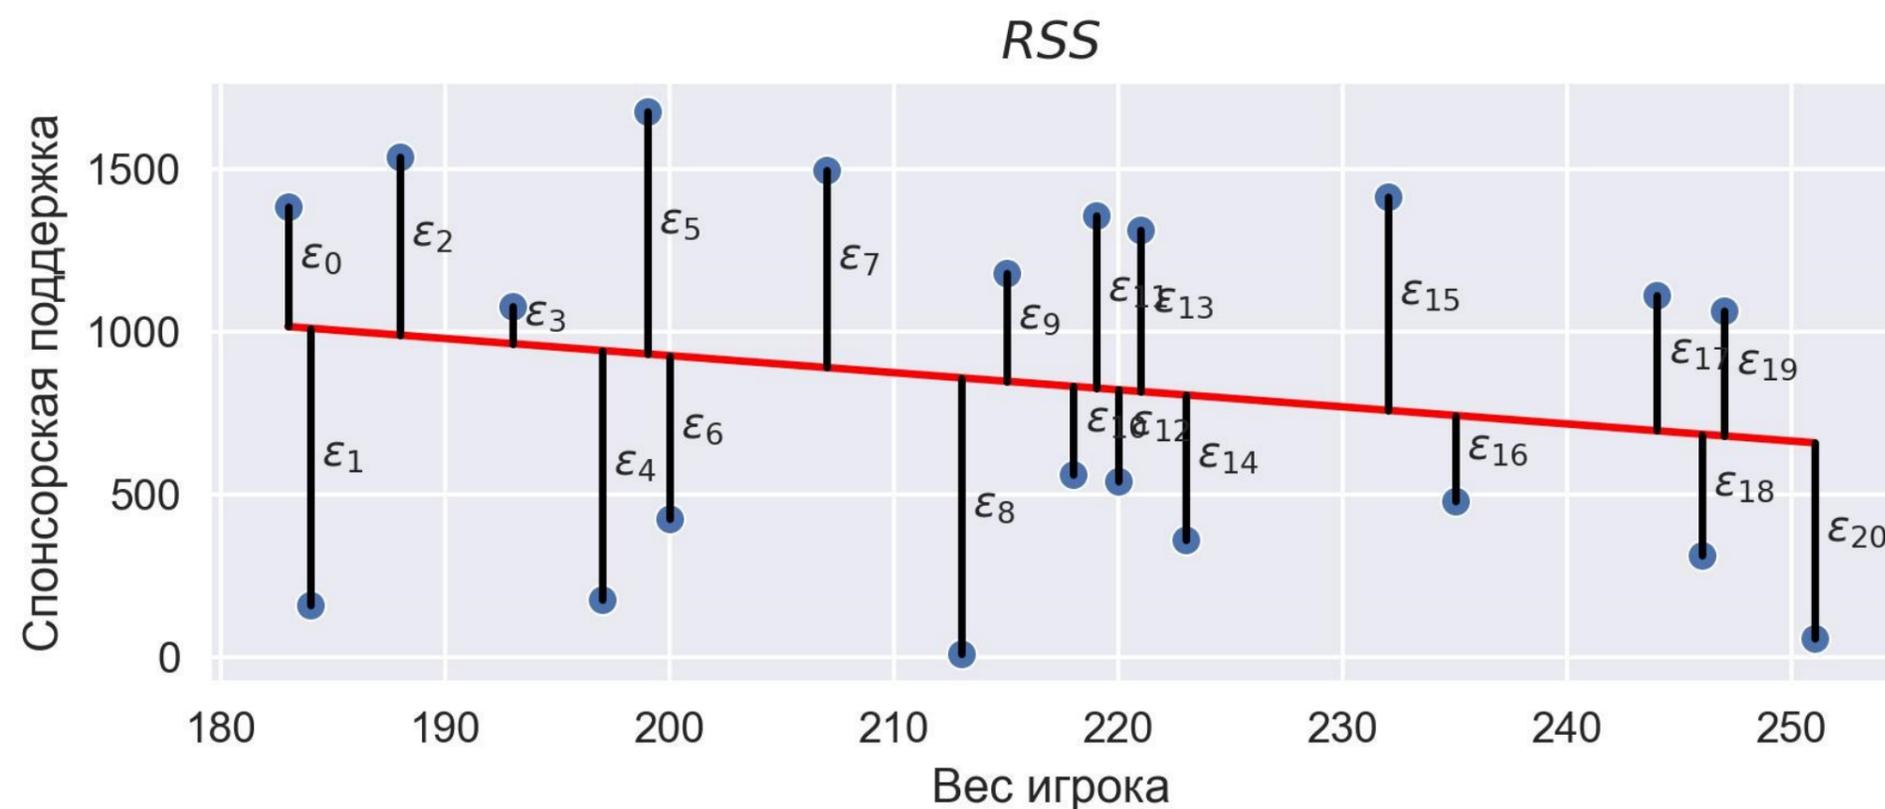
$$TSS = \sum_{i=1}^n \epsilon^2 = \sum_{i=1}^n (y_i - \bar{y})^2,$$

$TSS$



# Коэффициент детерминации $R^2$

$$R^2 = 1 - \frac{\text{сумма квадратов остатков}}{\text{общая сумма квадратов}} = 1 - \frac{RSS}{TSS}$$



$$R^2 = 1 - \frac{8\,778\,000}{9\,019\,000} = 0.026$$

Значение  $R^2$  находится в диапазоне  $[0, 1)$ . Значения, близкие к единице указывают на лучшую эффективность модели. Коэффициент детерминации  $R^2$  также интерпретируют, как величину изменения зависимой переменной  $y$ , которая объясняется независимыми (описательными) признаками  $x$ .

# Скорректированный коэффициент $R^2$ (adjusted $R^2$ )

$R^2$  всегда увеличивается (не уменьшается) с увеличением количества предикторов в модели, даже если они вообще не содержат никакой информации о целевой переменной.

# Скорректированный коэффициент $R^2$ (adjusted $R^2$ )

$R^2$  всегда увеличивается (не уменьшается) с увеличением количества предикторов в модели, даже если они вообще не содержат никакой информации о целевой переменной.

## Пример

Допустим, что мы хотим построить линейную регрессию, чтобы предсказать размер спонсорской поддержки ( $y$ ) по описательным признакам (Возраст, Рост, Вес). Рассчитаем несколько моделей каждый раз добавляя по одному новому признаку и посмотрим, как будет изменяться  $R^2$ . Результаты представлены в следующей таблице.

№	Предиктор	$R^2$
1	Возраст	0.8427
2	Рост	0.8629
3	Вес	0.8639

# Скорректированный коэффициент $R^2$ (adjusted $R^2$ )

**Скорректированный  $R^2$**  учитывает количество предикторов, используемых в модели:

$$R_{\text{adj}}^2 = 1 - \left( \frac{RSS}{TSS} \times \frac{n - 1}{n - p - 1} \right),$$

где  $n$  – число наблюдений,  $p$  – число предикторов.

## Пример (продолжение)

Если мы теперь посчитаем  $R_{\text{adj}}^2$  для данных о спонсорской поддержке, то получим следующие значения.

№	Предиктор	$R_{\text{adj}}^2$
1	Возраст	0.8427
2	Рост	0.8580
3	Вес	0.8539

Таблица 0.1 – Коэффициент  $R_{\text{adj}}^2$

# Значимость коэффициентов регрессии

Найденные коэффициенты регрессии  $\hat{w}_j$  являются случайными величинами.

- Для проверки значимости коэффициентов регрессии выдвигается гипотеза

$H_0$ : между  $X_j$  и  $Y$  нет взаимосвязи

Альтернативная гипотеза:

$H_1$ : между  $X_j$  и  $Y$  есть взаимосвязь.

- Математически это выражается, как

$$H_0: w_j = 0$$

ПРОТИВ

$$H_1: w_j \neq 0.$$

# Значимость коэффициентов регрессии

Принятие/отклонение гипотезы выполняется в три этапа:

1) Вычисляется **тестовая статистика**.

2) Вычисляется вероятность того, что значение с.в. с распределением тестовой статистики будет больше или равно значению тестовой статистики. Эта вероятность называется **p-значением**.

3) P-значение сравнивается с **предопределенным порогом значимости**, и если p-значение меньше порога, то нулевая гипотеза отклоняется. Стандартные статистические пороги равны 5 и 1%.

# Значимость коэффициентов регрессии

- Известно, что  $w_j$  распределено по нормальному закону.
- Дисперсия коэффициента  $w_j$  линейной регрессии рассчитывается как

$$SE(\hat{w}_j)^2 = \sigma_{\hat{w}_j}^2 = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2},$$

- $\sigma^2$  мы не знаем, поэтому выборочная дисперсия служит её оценкой:

$$\sigma^2 \rightarrow s^2 = \frac{\sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\mathbf{w}})^2}{n - 2}.$$

- Статистика (предполагается, что  $w_j = 0$ )

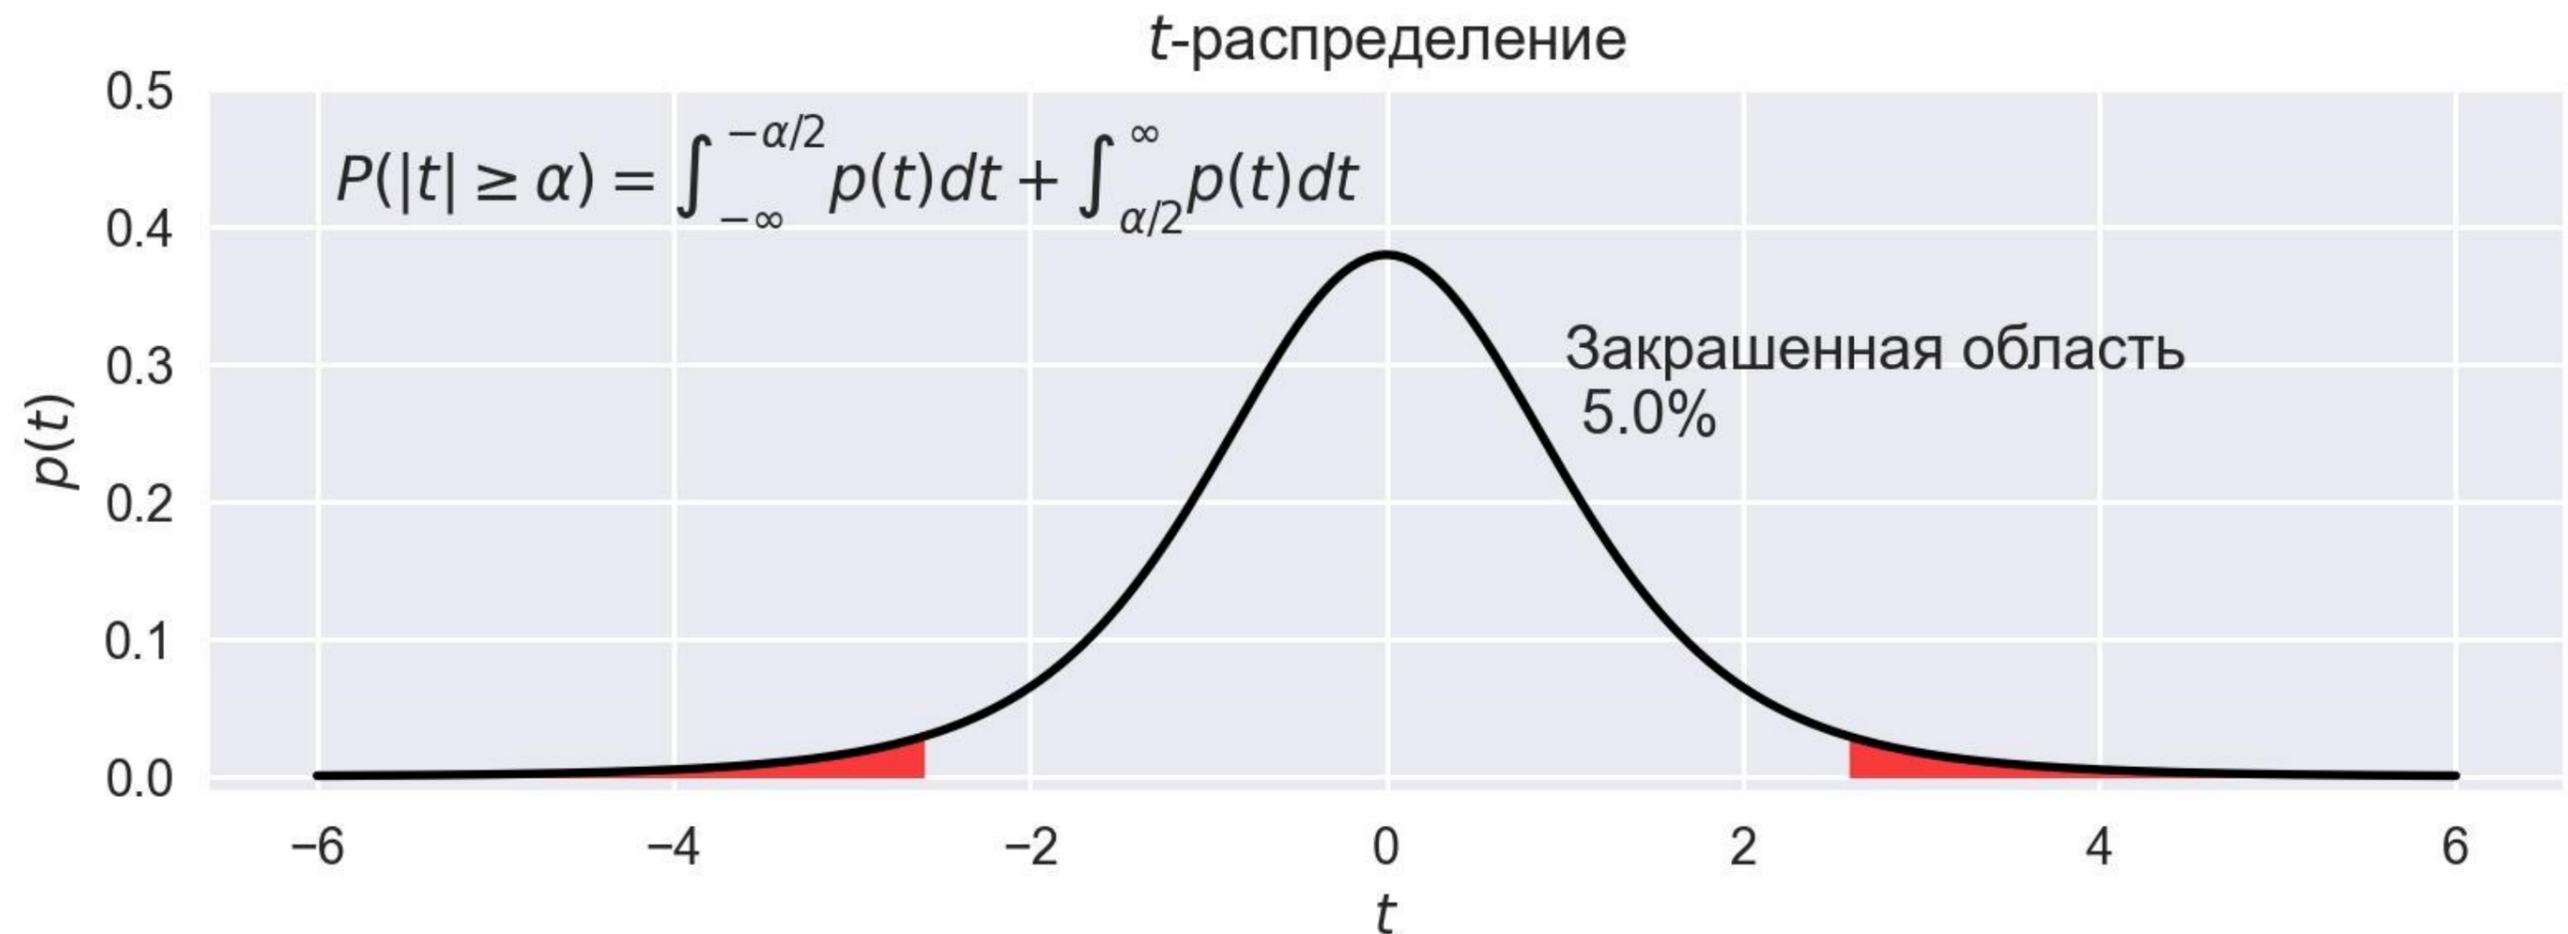
$$t = \frac{\hat{w}_j - 0}{SE(\hat{w}_j)},$$

подчинена  $t$ -распределению с  $n - p - 1$  степенями свободы.

# Значимость коэффициентов регрессии

$$t = \frac{\hat{w}_j - 0}{SE(\hat{w}_j)}$$

- Используя статистическое программное обеспечение, легко вычислить вероятность получения значения, равного или больше  $|t|$ . Эта вероятность называется ***p*-значением**.



# Значимость коэффициентов регрессии

Рассчитаем значимость коэффициентов регрессии для данных о баскетбольной команде.

№	Предиктор	Коэффициент $w_j$	Значение $t$	p-значение
1	Возраст	-128.76	-13.935	4.0515e-14
2	Рост	8.93	3.127	0.004
3	Вес	-2.08	-1.059	0.298

# Доверительный интервал

С доверительной вероятностью 95% интервал

$$[\hat{w}_j - 2 \times SE(\hat{w}_j), \hat{w}_j + 2 \times SE(\hat{w}_j)]$$

содержит реальное значение  $w_j$  (по сценарию, в котором мы получили повторяющиеся выборки, подобные имеющейся).

# Интерпретация коэффициентов регрессии

- Идеальный случай – предикторы не коррелируют друг с другом:
  - Каждый коэффициент может быть оценен и протестирован отдельно.
  - Возможны такие интерпретации, как *"изменение в  $X_j$  связанном с  $w_j$  вызывает изменение  $Y$ , в то время как все остальные переменные остаются неизменными"*.
- Наличие корреляции между предикторами создают проблемы:
  - Дисперсия всех коэффициентов имеет тенденцию к увеличению, иногда существенному
  - Интерпретации становятся опасными – когда меняется  $X_j$ , меняется все остальное.
- Следует избегать **заявлений о причинно-следственной связи** в отношении данных наблюдений.

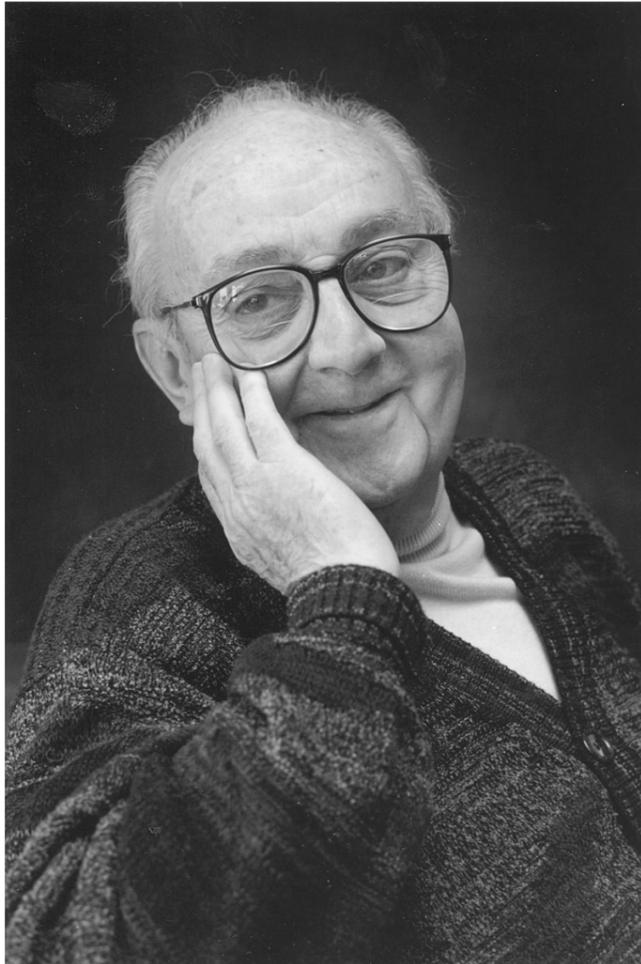
# Интерпретация коэффициентов регрессии

- Коэффициент регрессии  $w_j$  оценивает ожидаемое изменение  $Y$  при изменении  $X_j$  на одну единицу, **при этом все остальные предикторы остаются неизменными**. Но предикторы обычно меняются одновременно!

## Пример

Пусть  $Y$  - общая сумма мелочи в вашем кармане;  $X_1$  = количество монет;  $X_2$  = количество монет номиналом 1, 2, 5 и 10 копеек. Сам по себе коэффициент регрессии  $Y$  на  $X_2$  будет  $> 0$ . А каким будет коэффициент при  $X_1$ ?

# Вместо заключения



В 1976 году британский статистик Джордж Бокс написал фразу: **«Все модели неправильны, но некоторые из них полезны»**.

*Он имел в виду, что мы должны сосредотачиваться на пользе моделей в прикладных сценариях, а не бесконечно спорить о том, является ли модель точной («правильной»)*