

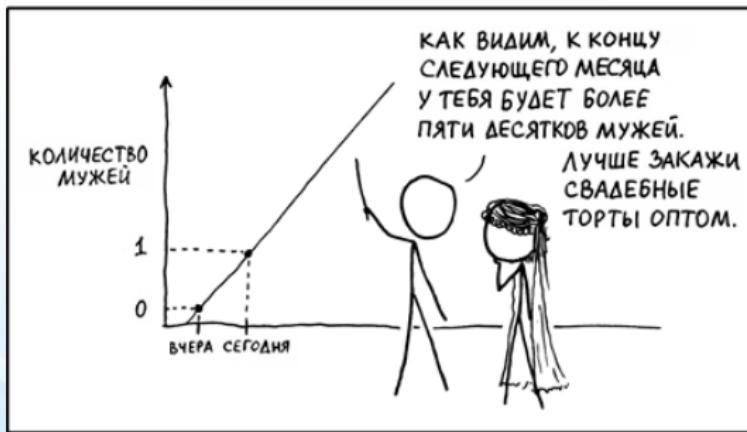
Статистика ФИВТ ПМИ

Прикладной поток

Лекция 12

7. Линейная регрессия

МОЁ ХОББИ: ЭКСТРАПОЛИРОВАТЬ



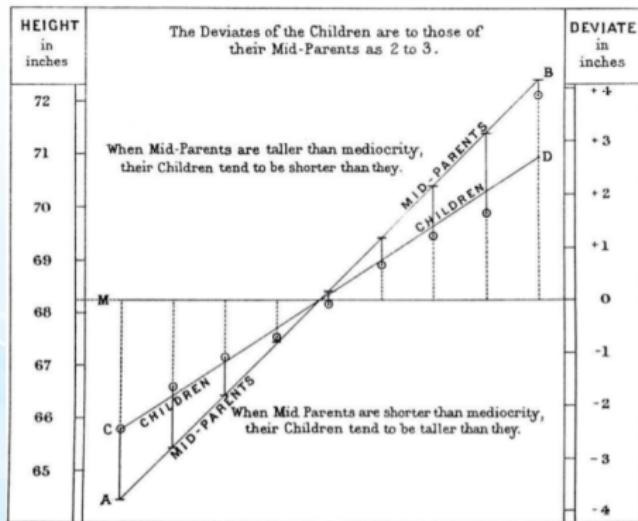
Первое упоминание регрессии

Впервые регрессия упоминается в работе Гальтона

"Регрессия к середине в наследственности роста", 1885 г.

x — рост родителей, y — рост детей

Установлена зависимость $y - \bar{y} \approx \frac{2}{3}(x - \bar{x})$, т.е. регрессия к середине.



7. Линейная регрессия

7.1. Постановка задачи линейной регрессии

Пример

Пусть x — рост песика, а y — его вес.

Что мы знаем?

- ▶ чем крупнее песик, тем больший вес он имеет;
- ▶ песики одинакового роста могут иметь разный вес.

Выводы:

- ▶ для фиксированного роста песика x его вес $y = f(x)$ является случайной величиной;
- ▶ в среднем вес $f(x)$ возрастает при увеличении роста песика x .

Пример

Простая зависимость:

$$y = \theta_0 + \theta_1 x + \varepsilon,$$

x — рост песика,

y — вес песика,

θ_0, θ_1 — неизвестные параметры,

ε — случайная составляющая с нулевым средним.

Зависимость **линейна по параметрам**, линейна по аргументу.

Пример

Более сложная зависимость:

$$y = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_2^2 + \varepsilon,$$

x_1 — рост песика,

x_2 — обхват туловища песика,

y — вес песика,

$\theta_0, \theta_1, \theta_2, \theta_3$ — неизвестные параметры,

ε — случайная составляющая с нулевым средним.

Зависимость **линейна по параметрам**, квадратична по аргументам.

Модель линейной регрессии

Рассматриваем функциональную зависимость вида

$$y = y(x) = \theta_1 x_1 + \dots + \theta_d x_d$$

x_1, \dots, x_d — признаки ,

$\theta = (\theta_1, \dots, \theta_d)^T$ — вектор параметров.

Для оценки θ производится n испытаний вида

$$Y_i = \theta_1 x_{i1} + \dots + \theta_d x_{id} + \varepsilon_i, \quad i = 1, \dots, n,$$

$x_i = (x_{i1}, \dots, x_{id})$ — признаковые описания объекта i

(обычно неслучайные),

ε_i — случайная ошибка измерений.

Модель линейной регрессии

Введем обозначения

$$Y = \begin{pmatrix} Y_1 \\ \dots \\ Y_n \end{pmatrix}, \quad X = \begin{pmatrix} x_{11} & \dots & x_{1d} \\ \dots & & \dots \\ x_{n1} & \dots & x_{nd} \end{pmatrix}, \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \dots \\ \varepsilon_n \end{pmatrix}.$$

Матричная форма записи проведенных испытаний

$$Y = X\theta + \varepsilon.$$

$X \in \mathbb{R}^{n \times d}$ — регрессоры (или матрица плана эксперимента),

$Y \in \mathbb{R}^n$ — отклик.

Матричный вид зависимости: $y(x) = x^T \theta$.

Замечание

Зависимость $y = y(x)$ должна быть **линейна по параметрам**, но не обязана быть линейной по признакам.

Пусть z_1, \dots, z_k — набор "независимых" переменных.

Можно рассматривать модель

$$y(x) = \theta_1 x_1(z_1, \dots, z_k) + \dots + \theta_d x_d(z_1, \dots, z_k),$$

где $x_j(z_1, \dots, z_k)$ — некоторые функции (м.б. нелинейные).

Примеры:

- ▶ $x(z_1, \dots, z_k) = 1;$
- ▶ $x(z_1, \dots, z_k) = z_1;$
- ▶ $x(z_1, \dots, z_k) = \ln z_1;$
- ▶ $x(z_1, \dots, z_k) = z_1^2 z_2.$

Пример: Потребление мороженого

Предполагается линейная зависимость потребления мороженого в литрах на человека от среднесуточной температуры воздуха: $ic = \theta_0 + \theta_1 t$.

Проведена серия наблюдений

$$IC_i = \theta_0 + \theta_1 t_i + \varepsilon_i,$$

t_i — среднесуточная температура воздуха,

IC_i — потребление мороженого в литрах на чел.,

$\varepsilon_i \sim \mathcal{N}(0, \sigma^2)$ — случайное отклонение.



Пример: Потребление мороженого

Наблюдения: $IC_i = \theta_0 + \theta_1 t_i + \varepsilon_i$.

В данном примере $x_1(t) = 1, x_2(t) = t$,

$$X = \begin{pmatrix} 1 & t_1 \\ \dots & \dots \\ 1 & t_n \end{pmatrix}, \quad Y = \begin{pmatrix} IC_1 \\ \dots \\ IC_n \end{pmatrix}, \quad \theta = \begin{pmatrix} \theta_0 \\ \theta_1 \end{pmatrix}.$$

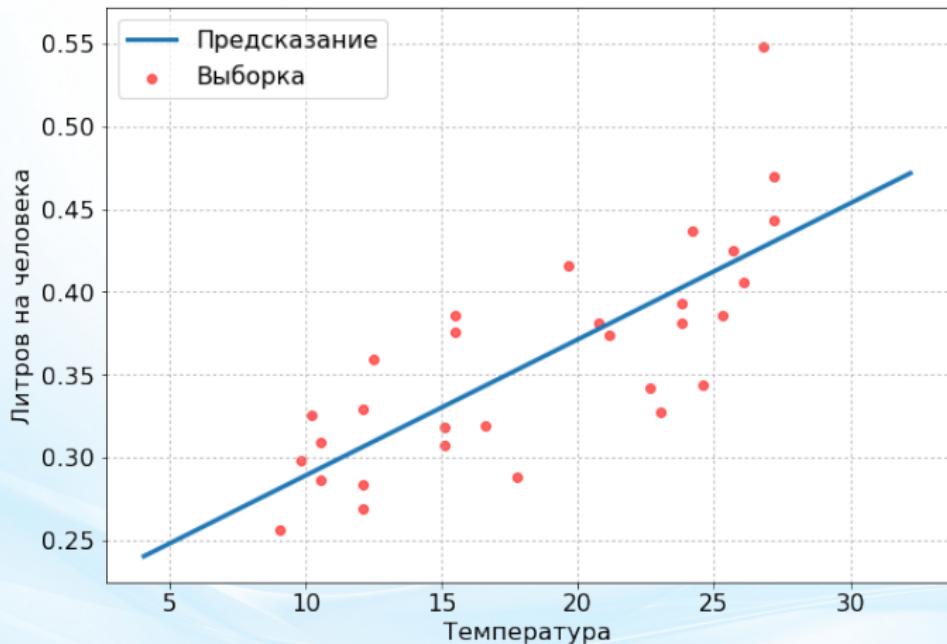
Пусть $w = I\{\text{выходной день}\}$, зависимость $ic = \theta_0 + \theta_1 t + \theta_2 t^2 w$.

Наблюдения: $IC_i = \theta_0 + \theta_1 t_i + \theta_2 t_i^2 w_i + \varepsilon_i$.

В данном примере $x_1(t, w) = 1, x_2(t, w) = t, x_3(t, w) = t^2 w$,

$$X = \begin{pmatrix} 1 & t_1 & t_1^2 w_1 \\ \dots & \dots & \dots \\ 1 & t_n & t_n^2 w_n \end{pmatrix}, \quad Y = \begin{pmatrix} IC_1 \\ \dots \\ IC_n \end{pmatrix}, \quad \theta = \begin{pmatrix} \theta_0 \\ \theta_1 \\ \theta_2 \end{pmatrix}.$$

Пример 3: Потребление мороженого



Категориальные переменные

x — id должности сотрудника (натуральное число),

y — его зарплата.

Предположим, что должности занумерованы следующим образом:

- ▶ $x = 1$ — простой рабочий;
- ▶ $x = 2$ — сисадмин, присваивающий id;
- ▶ $x = 3$ — директор.

Сисадмин предложит рассмотреть модель $y = \theta_0 + \theta_1 x :))$

Если $x \in \{1, \dots, k\}$, то рассматриваются **dummy-переменные**:

$x_j = I\{x = j\}, \quad j = 1, \dots, k - 1,$

модель $y = \theta_0 + \theta_1 x_1 + \dots + \theta_{k-1} x_{k-1}.$

7. Линейная регрессия

7.2. Метод наименьших квадратов

Материал на доске



Реализация в sklearn

```
m = sklearn.linear_model.LinearRegression(fit_intercept=True)
```

Обучение модели:

```
m.fit(X, Y)
```

Вектор коэффициентов:

```
m.coef_
```

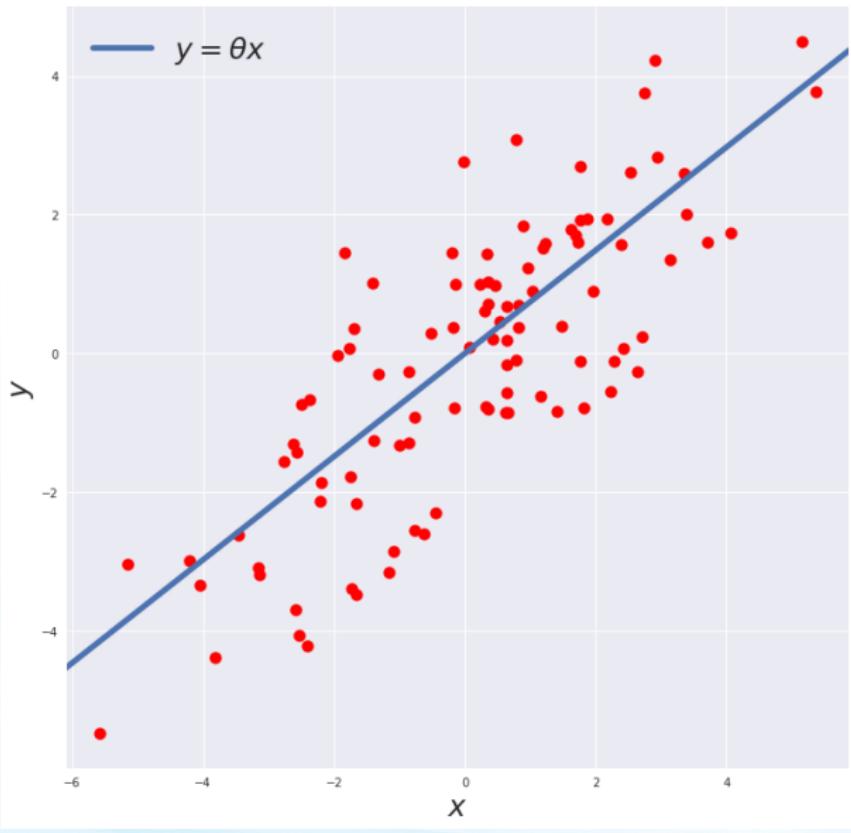
Свободный коэффициент:

```
m.intercept_
```

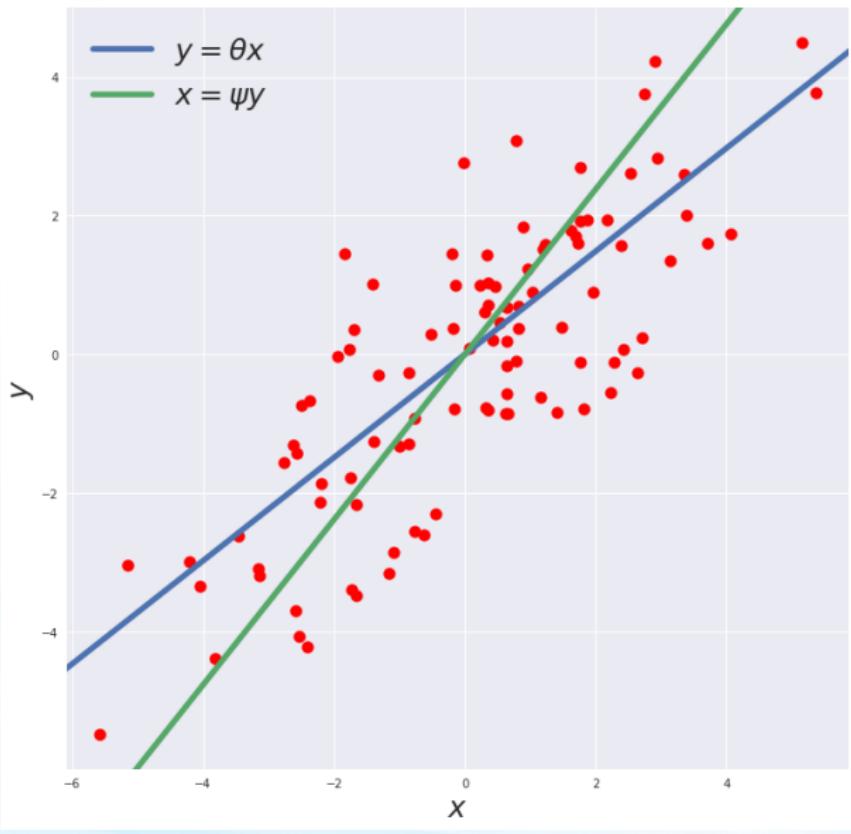
Предсказания:

```
m.predict(X)
```

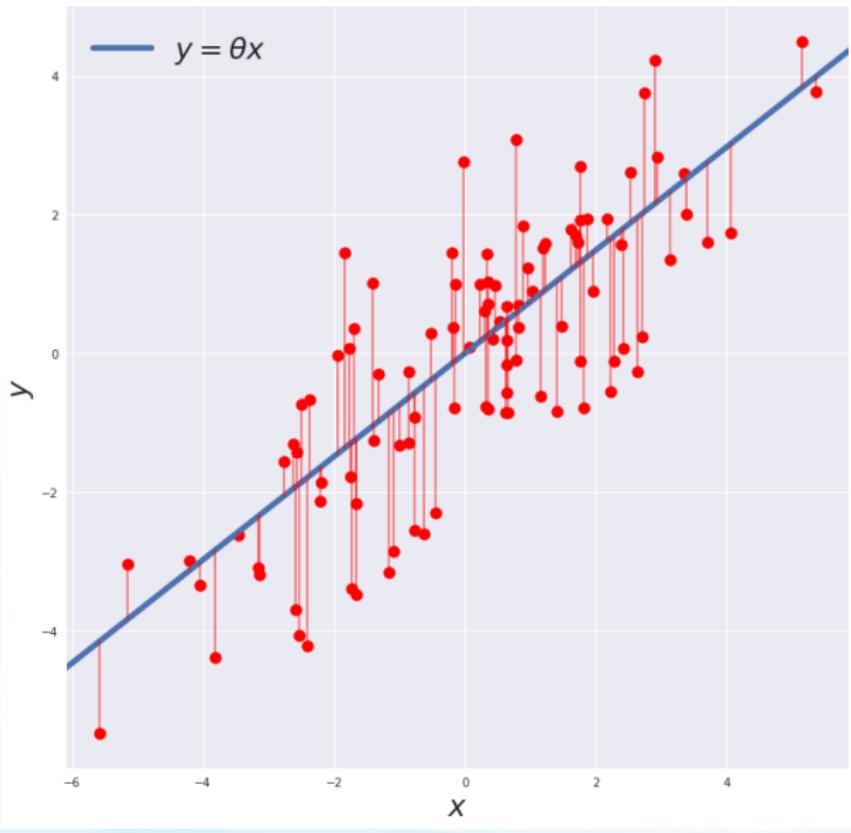
Инверсия



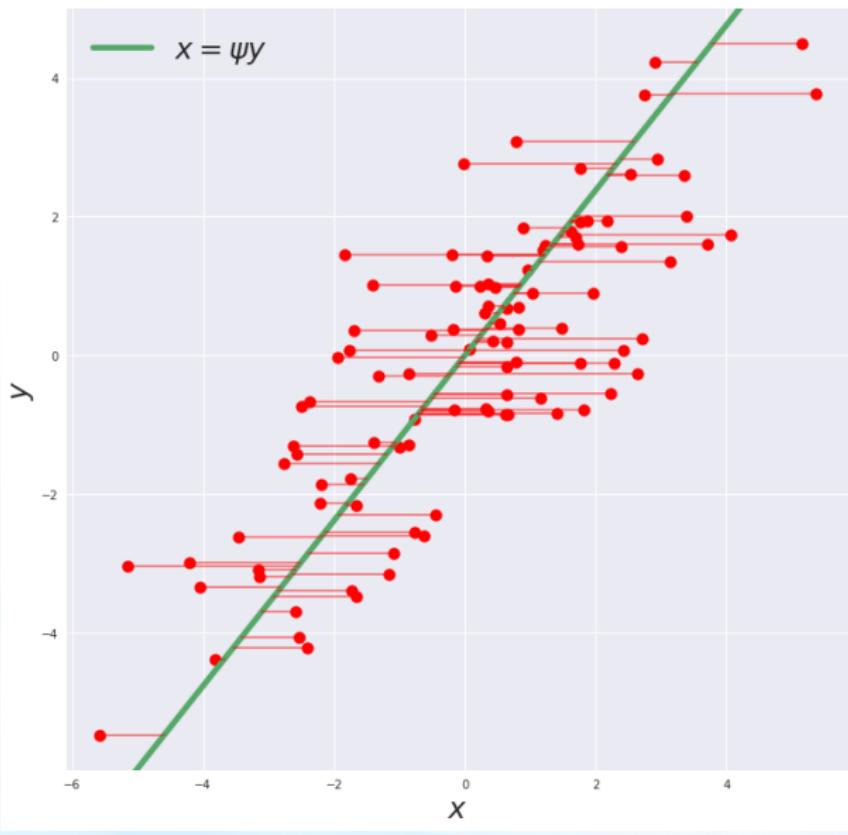
Инверсия



Инверсия



Инверсия





BCE !