




Математическая статистика



Линейная регрессия



МОЁ ХОББИ: ЭКСТРАПОЛИРОВАТЬ





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.



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

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

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



Модель линейной регрессии

Введем обозначения

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

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



Модель линейной регрессии

Введем обозначения

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

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



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 $y = \theta_0 + \theta_1 x$:))



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**:

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

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



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**:

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

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



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:

▶ $\hat{\theta}$ — несмещенная оценка θ .



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:
 - ▶ $\hat{\theta}$ — несмещенная оценка θ .
2. $E\varepsilon = 0$ и $D\varepsilon = \sigma^2 I_n$ — несмещенность и гомоскедастичность:



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:

▶ $\hat{\theta}$ — несмещенная оценка θ .

2. $E\varepsilon = 0$ и $D\varepsilon = \sigma^2 I_n$ — несмещенность и гомоскедастичность:

▶ $D\hat{\theta} = \sigma^2 (X^T X)^{-1}$;

▶ $\hat{\theta}$ — оптимальная оценка θ среди линейных по y ;

▶ $\hat{\sigma}^2 = RSS(\hat{\theta}) / (n - d)$ — несмещенная оценка σ^2 .



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $\text{rank } X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:
 - ▶ $\hat{\theta}$ — несмещенная оценка θ .
2. $E\varepsilon = 0$ и $D\varepsilon = \sigma^2 I_n$ — несмещенность и гомоскедастичность:
 - ▶ $D\hat{\theta} = \sigma^2 (X^T X)^{-1}$;
 - ▶ $\hat{\theta}$ — оптимальная оценка θ среди линейных по y ;
 - ▶ $\hat{\sigma}^2 = RSS(\hat{\theta}) / (n - d)$ — несмещенная оценка σ^2 .
3. $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$ — гауссовская линейная модель:



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $rank X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:
 - ▶ $\hat{\theta}$ — несмещенная оценка θ .
2. $E\varepsilon = 0$ и $D\varepsilon = \sigma^2 I_n$ — несмещенность и гомоскедастичность:
 - ▶ $D\hat{\theta} = \sigma^2 (X^T X)^{-1}$;
 - ▶ $\hat{\theta}$ — оптимальная оценка θ среди линейных по y ;
 - ▶ $\hat{\sigma}^2 = RSS(\hat{\theta}) / (n - d)$ — несмещенная оценка σ^2 .
3. $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$ — гауссовская линейная модель:
 - ▶ МНК совпадает с ОМП для θ ;
 - ▶ $\hat{\theta}$ — оптимальная оценка θ ;
 - ▶ $RSS(\hat{\theta}) / \sigma^2 \sim \chi_{n-d}^2$.



Метод наименьших квадратов

Задача: $RSS(\theta) = \|Y - X\theta\|_2^2 \rightarrow \min_{\theta \in \mathbb{R}^d}$.

Решение: $\hat{\theta} = (X^T X)^{-1} X^T Y$ если $rank X = d$.

Предположения и следствия:

1. $E\varepsilon = 0$ — несмещенность:
 - ▶ $\hat{\theta}$ — несмещенная оценка θ .
2. $E\varepsilon = 0$ и $D\varepsilon = \sigma^2 I_n$ — несмещенность и гомоскедастичность:
 - ▶ $D\hat{\theta} = \sigma^2 (X^T X)^{-1}$;
 - ▶ $\hat{\theta}$ — оптимальная оценка θ среди линейных по y ;
 - ▶ $\hat{\sigma}^2 = RSS(\hat{\theta}) / (n - d)$ — несмещенная оценка σ^2 .
3. $\varepsilon \sim \mathcal{N}(0, \sigma^2 I_n)$ — гауссовская линейная модель:
 - ▶ МНК совпадает с ОМП для θ ;
 - ▶ $\hat{\theta}$ — оптимальная оценка θ ;
 - ▶ $RSS(\hat{\theta}) / \sigma^2 \sim \chi_{n-d}^2$.



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





Качество модели

$$R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2} \text{ — коэффициент детерминации.}$$

$R^2 \approx 1$ — хорошо, $R^2 \approx 0$ — плохо.



Качество модели

$$R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2} \text{ — коэффициент детерминации.}$$

$R^2 \approx 1$ — хорошо, $R^2 \approx 0$ — плохо.

Проблема: чем больше признаков, тем больше значение R^2 .



Качество модели

$$R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2} \text{ — коэффициент детерминации.}$$

$R^2 \approx 1$ — хорошо, $R^2 \approx 0$ — плохо.

Проблема: чем больше признаков, тем больше значение R^2 .

Для отбора признаков можно использовать подправленный R^2 :

$$R_{adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - d}.$$



Качество модели

$$R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2} \text{ — коэффициент детерминации.}$$

$R^2 \approx 1$ — хорошо, $R^2 \approx 0$ — плохо.

Проблема: чем больше признаков, тем больше значение R^2 .

Для отбора признаков можно использовать подправленный R^2 :

$$R_{adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - d}.$$

Информационные критерии: (чем меньше, тем лучше)

$$AIC = \frac{2d}{n} + \ln \frac{RSS(\hat{\theta})}{n} \text{ — Акаике, } BIC = \frac{d \ln n}{n} + \ln \frac{RSS(\hat{\theta})}{n} \text{ — Шварца.}$$



Качество модели

$$R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2} \text{ — коэффициент детерминации.}$$

$R^2 \approx 1$ — хорошо, $R^2 \approx 0$ — плохо.

Проблема: чем больше признаков, тем больше значение R^2 .

Для отбора признаков можно использовать подправленный R^2 :

$$R_{adj}^2 = 1 - (1 - R^2) \frac{n - 1}{n - d}.$$

Информационные критерии: (чем меньше, тем лучше)

$$AIC = \frac{2d}{n} + \ln \frac{RSS(\hat{\theta})}{n} \text{ — Акаике, } BIC = \frac{d \ln n}{n} + \ln \frac{RSS(\hat{\theta})}{n} \text{ — Шварца.}$$



Качество модели

Качество модели обычно считают на тестовом множестве наблюдений, которые не участвовали в обучении.

$X_{test} \in \mathbb{R}^{k \times d}$, $Y_{test} \in \mathbb{R}^k$ — тестовое множество



Качество модели

Качество модели обычно считают на тестовом множестве наблюдений, которые не участвовали в обучении.

$X_{test} \in \mathbb{R}^{k \times d}$, $Y_{test} \in \mathbb{R}^k$ — тестовое множество

$$MSE = \frac{1}{k} \sum_{i=1}^k (Y_i^{test} - \hat{y}(X_i^{test}))^2$$



Качество модели

Качество модели обычно считают на тестовом множестве наблюдений, которые не участвовали в обучении.

$X_{test} \in \mathbb{R}^{k \times d}$, $Y_{test} \in \mathbb{R}^k$ — тестовое множество

$$MSE = \frac{1}{k} \sum_{i=1}^k (Y_i^{test} - \hat{y}(X_i^{test}))^2$$

$$MAE = \frac{1}{k} \sum_{i=1}^k |Y_i^{test} - \hat{y}(X_i^{test})|$$



Качество модели

Качество модели обычно считают на тестовом множестве наблюдений, которые не участвовали в обучении.

$X_{test} \in \mathbb{R}^{k \times d}$, $Y_{test} \in \mathbb{R}^k$ — тестовое множество

$$MSE = \frac{1}{k} \sum_{i=1}^k (Y_i^{test} - \hat{y}(X_i^{test}))^2$$

$$MAE = \frac{1}{k} \sum_{i=1}^k |Y_i^{test} - \hat{y}(X_i^{test})|$$

$$MAPE = \frac{100\%}{k} \sum_{i=1}^k \left| \frac{Y_i^{test} - \hat{y}(X_i^{test})}{Y_i^{test}} \right|$$

Реализация метрик: `sklearn.metrics`



Качество модели

Качество модели обычно считают на тестовом множестве наблюдений, которые не участвовали в обучении.

$X_{test} \in \mathbb{R}^{k \times d}$, $Y_{test} \in \mathbb{R}^k$ — тестовое множество

$$MSE = \frac{1}{k} \sum_{i=1}^k (Y_i^{test} - \hat{y}(X_i^{test}))^2$$

$$MAE = \frac{1}{k} \sum_{i=1}^k |Y_i^{test} - \hat{y}(X_i^{test})|$$

$$MAPE = \frac{100\%}{k} \sum_{i=1}^k \left| \frac{Y_i^{test} - \hat{y}(X_i^{test})}{Y_i^{test}} \right|$$

Реализация метрик: `sklearn.metrics`



Гауссовская линейная модель



Величина	Доверительный интервал
----------	------------------------

σ	$\left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$
----------	---

Дов. интервал для размера шума в отклике



Величина	Доверительный интервал
----------	------------------------

σ	$\left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$
----------	---

Дов. интервал для размера шума в отклике

θ_j	$\left(\hat{\theta}_j \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}} \right)$
------------	---

Дов. интервал для коэффициента перед j -м признаком



Величина **Доверительный интервал**

$$\sigma \quad \left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \quad \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$$

Дов. интервал для размера шума в отклике

$$\theta_j \quad \left(\hat{\theta}_j \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}} \right)$$

Дов. интервал для коэффициента перед j -м признаком

$$x_0^T \theta \quad \left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \right)$$

Дов. интервал для **среднего** отклика на объекте x_0



Величина **Доверительный интервал**

$$\sigma \quad \left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \quad \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$$

Дов. интервал для размера шума в отклике

$$\theta_j \quad \left(\hat{\theta}_j \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{(X^T X)_{jj}^{-1}} \right)$$

Дов. интервал для коэффициента перед j -м признаком

$$x_0^T \theta \quad \left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \right)$$

Дов. интервал для **среднего** отклика на объекте x_0

$$x_0^T \theta + \varepsilon \quad \left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{\mathbf{1} + x_0^T (X^T X)^{-1} x_0} \right)$$

Предск. интервал для **наблюдаемого** отклика на объекте x_0



Величина	Доверительный интервал
----------	------------------------

σ	$\left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$
----------	---

Дов. интервал для размера шума в отклике

θ_j	$\left(\hat{\theta}_j \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}} \right)$
------------	---

Дов. интервал для коэффициента перед j -м признаком

$x_0^T \theta$	$\left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \right)$
----------------	--

Дов. интервал для **среднего** отклика на объекте x_0

$x_0^T \theta + \varepsilon$	$\left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{\mathbf{1} + x_0^T (X^T X)^{-1} x_0} \right)$
------------------------------	---

Предск. интервал для **наблюдаемого** отклика на объекте x_0

Примечание: если $P_{a,b}$ — некоторое распределение с параметрами a и b , то $P_{a,b,\alpha}$ — его α квантиль



Величина **Доверительный интервал**

$$\sigma \quad \left(\sqrt{RSS(\hat{\theta}) / \chi_{n-d, 1-\alpha/2}^2}, \quad \sqrt{RSS(\hat{\theta}) / \chi_{n-d, \alpha/2}^2} \right)$$

Дов. интервал для размера шума в отклике

$$\theta_j \quad \left(\hat{\theta}_j \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{(X^T X)_{jj}^{-1}} \right)$$

Дов. интервал для коэффициента перед j -м признаком

$$x_0^T \theta \quad \left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{x_0^T (X^T X)^{-1} x_0} \right)$$

Дов. интервал для **среднего** отклика на объекте x_0

$$x_0^T \theta + \varepsilon \quad \left(x_0^T \hat{\theta} \pm T_{n-d, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{1 + x_0^T (X^T X)^{-1} x_0} \right)$$

Предск. интервал для **наблюдаемого** отклика на объекте x_0

Примечание: если $P_{a,b}$ — некоторое распределение с параметрами a и b , то $P_{a,b,\alpha}$ — его α квантиль



Типы гипотез

1. Значим ли признак j ?

$$H_0: \theta_j = 0$$



Типы гипотез

1. Значим ли признак j ?

$$H_0: \theta_j = 0$$

2. Значима ли регрессия вообще?

$$H_0: \theta_2 = \dots = \theta_d = 0 \text{ если } x_1 = 1$$



Типы гипотез

1. Значим ли признак j ?

$$H_0: \theta_j = 0$$

2. Значима ли регрессия вообще?

$$H_0: \theta_2 = \dots = \theta_d = 0 \text{ если } x_1 = 1$$



1. Значим ли признак j ?

Гипотеза о незначимости коэффициента θ_j

$H_0: \theta_j = 0$ vs. $H_1: \theta_j \{<, \neq, >\} 0$



1. Значим ли признак j ?

Гипотеза о незначимости коэффициента θ_j

$H_0: \theta_j = 0$ vs. $H_1: \theta_j \{<, \neq, >\} 0$

Критерий Стьюдента

$$T_j^0(X, Y) = \frac{\hat{\theta}_j}{\hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}}} \stackrel{H_0}{\sim} T_{n-d}$$

$T_j^0(X, Y)$ — Т-статистика критерия



1. Значим ли признак j ?

Гипотеза о незначимости коэффициента θ_j

$H_0: \theta_j = 0$ vs. $H_1: \theta_j \{<, \neq, >\} 0$

Критерий Стьюдента

$$T_j^0(X, Y) = \frac{\hat{\theta}_j}{\hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}}} \stackrel{H_0}{\sim} T_{n-d}$$

$T_j^0(X, Y)$ — Т-статистика критерия

Для $H_1: \theta_j \neq 0$ критерий $\{|T_j^0(X, y)| > T_{n-d, 1-\alpha/2}\}$,

где $T_{n-d, 1-\alpha/2}$ — $(1 - \alpha/2)$ квантиль распределения T_{n-d}



1. Значим ли признак j ?

Гипотеза о незначимости коэффициента θ_j

$H_0: \theta_j = 0$ vs. $H_1: \theta_j \{<, \neq, >\} 0$

Критерий Стьюдента

$$T_j^0(X, Y) = \frac{\hat{\theta}_j}{\hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}}} \stackrel{H_0}{\sim} T_{n-d}$$

$T_j^0(X, Y)$ — Т-статистика критерия

Для $H_1: \theta_j \neq 0$ критерий $\{|T_j^0(X, y)| > T_{n-d, 1-\alpha/2}\}$,

где $T_{n-d, 1-\alpha/2}$ — $(1 - \alpha/2)$ квантиль распределения T_{n-d}

Если H_0 не отвергается, то можно считать, что θ_j отклоняется от нуля статистически незначимо. Возможно, признак j стоит убрать.



1. Значим ли признак j ?

Гипотеза о незначимости коэффициента θ_j

$H_0: \theta_j = 0$ vs. $H_1: \theta_j \{<, \neq, >\} 0$

Критерий Стьюдента

$$T_j^0(X, Y) = \frac{\hat{\theta}_j}{\hat{\sigma} \sqrt{(X^T X)^{-1}_{jj}}} \stackrel{H_0}{\sim} T_{n-d}$$

$T_j^0(X, Y)$ — Т-статистика критерия

Для $H_1: \theta_j \neq 0$ критерий $\{|T_j^0(X, y)| > T_{n-d, 1-\alpha/2}\}$,

где $T_{n-d, 1-\alpha/2}$ — $(1 - \alpha/2)$ квантиль распределения T_{n-d}

Если H_0 не отвергается, то можно считать, что θ_j отклоняется от нуля статистически незначимо. Возможно, признак j стоит убрать.



2. Значима ли регрессия вообще?

Гипотеза о незначимости регрессии

$$H_0: \theta_1 = \theta_2 = \dots = \theta_d = 0 \text{ vs. } H_1: \exists \theta_j \neq 0$$



2. Значима ли регрессия вообще?

Гипотеза о незначимости регрессии

$$H_0: \theta_1 = \theta_2 = \dots = \theta_d = 0 \text{ vs. } H_1: \exists \theta_j \neq 0$$

Критерий Фишера

$$F(X, Y) = \frac{R^2/(d-1)}{(1-R^2)/(n-d)} \stackrel{H_0}{\sim} F_{d-1, n-d},$$

где $R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2}$ — коэффициент детерминации.

$F(X, Y)$ — F-статистика критерия



2. Значима ли регрессия вообще?

Гипотеза о незначимости регрессии

$$H_0: \theta_1 = \theta_2 = \dots = \theta_d = 0 \text{ vs. } H_1: \exists \theta_j \neq 0$$

Критерий Фишера

$$F(X, Y) = \frac{R^2/(d-1)}{(1-R^2)/(n-d)} \stackrel{H_0}{\sim} F_{d-1, n-d},$$

где $R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2}$ — коэффициент детерминации.

$F(X, Y)$ — F-статистика критерия

Для $H_1: \exists \theta_j \neq 0$ критерий $\{F_j^0(X, y) > F_{d-1, n-d, 1-\alpha}\}$,

где $F_{d-1, n-d, 1-\alpha}$ — $(1-\alpha)$ квантиль распределения $F_{d-1, n-d}$



2. Значима ли регрессия вообще?

Гипотеза о незначимости регрессии

$$H_0: \theta_1 = \theta_2 = \dots = \theta_d = 0 \text{ vs. } H_1: \exists \theta_j \neq 0$$

Критерий Фишера

$$F(X, Y) = \frac{R^2/(d-1)}{(1-R^2)/(n-d)} \stackrel{H_0}{\sim} F_{d-1, n-d},$$

где $R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2}$ — коэффициент детерминации.

$F(X, Y)$ — F-статистика критерия

Для $H_1: \exists \theta_j \neq 0$ критерий $\{F_j^0(X, y) > F_{d-1, n-d, 1-\alpha}\}$,

где $F_{d-1, n-d, 1-\alpha}$ — $(1-\alpha)$ квантиль распределения $F_{d-1, n-d}$

Если H_0 не отвергается, то можно считать, что регрессия статистически незначимо отличается от приближения константой.



2. Значима ли регрессия вообще?

Гипотеза о незначимости регрессии

$$H_0: \theta_1 = \theta_2 = \dots = \theta_d = 0 \text{ vs. } H_1: \exists \theta_j \neq 0$$

Критерий Фишера

$$F(X, Y) = \frac{R^2/(d-1)}{(1-R^2)/(n-d)} \stackrel{H_0}{\sim} F_{d-1, n-d},$$

где $R^2 = 1 - \frac{RSS(\hat{\theta})}{\|Y - \bar{Y}\|_2^2}$ — коэффициент детерминации.

$F(X, Y)$ — F-статистика критерия

Для $H_1: \exists \theta_j \neq 0$ критерий $\{F_j^0(X, y) > F_{d-1, n-d, 1-\alpha}\}$,

где $F_{d-1, n-d, 1-\alpha}$ — $(1-\alpha)$ квантиль распределения $F_{d-1, n-d}$

Если H_0 не отвергается, то можно считать, что регрессия статистически незначимо отличается от приближения константой.



Таблица в statsmodels

```
# Load data
In [4]: dat = sm.datasets.get_rdataset("Guerry", "HistData").data

# Fit regression model (using the natural log of one of the regressors)
In [5]: results = smf.ols('Lottery ~ Literacy + np.log(Pop1831)', data=dat).fit()

# Inspect the results
In [6]: print(results.summary())
```

OLS Regression Results

```
=====
Dep. Variable:          Lottery      R-squared:                0.348
Model:                  OLS         Adj. R-squared:           0.333
Method:                 Least Squares   F-statistic:              22.20
Date:                   Mon, 14 May 2018   Prob (F-statistic):      1.90e-08
Time:                   21:48:09         Log-Likelihood:          -379.82
No. Observations:      86              AIC:                     765.6
Df Residuals:          83              BIC:                     773.0
Df Model:               2
Covariance Type:       nonrobust
=====
```

	coef	std err	t	P> t	[0.025	0.975]
Intercept	246.4341	35.233	6.995	0.000	176.358	316.510
Literacy	-0.4889	0.128	-3.832	0.000	-0.743	-0.235
np.log(Pop1831)	-31.3114	5.977	-5.239	0.000	-43.199	-19.424



ВСЁ!