

**МАШИННОЕ ОБУЧЕНИЕ
И АНАЛИЗ ДАННЫХ**
(Machine Learning and Data Mining)

Н. Ю. Золотых

<http://www.uic.unn.ru/~zny/ml>

Лекция 5

Метод наименьших квадратов

Agenda

- Регрессионная функция
 - Метод наименьших квадратов
 - Метод максимального правдоподобия
- Линейная регрессия
- Оценка коэффициентов по выборке
- Переобучение
- Сокращение числа параметров и «усадка» коэффициентов
 - Выбор подмножества параметров
 - Гребневая регрессия
 - Лассо
 - Метод главных компонент
 - Частичные наименьшие квадраты

5.1. Регрессия


Гаусс (1794–1795), Лежандр (1805–1806) — метод наименьших квадратов
(Исследование траектории астероида Церера)

Фрэнсис Гальтона (1822–1911)

«Регрессия к середине в наследовании роста» (1885 г.)

«Где это возможно, считайте». Ф.Гальтон


Зависимость роста ребенка от роста родителей в исследовании Ф. Гальтона




928 наблюдений $ch = 0.65par + 24 = 68.2 + 0.65 \times (par - 68.2)$

x = средняя оценка по мат. анализу и алгебре в 1-м семестре

y = средняя оценка по мат. анализу, алгебре и программированию во 2-м семестре



79 студентов




$$\text{sem2} = 0.93 + 0.77 \times \text{sem1} \approx 3.86 + 0.77 \times (\text{sem1} - 3.82)$$

3.82 — средняя оценка по всем студентам в 1-м семестре

3.86 — средняя оценка по всем студентам во 2-м семестре

Зависимость между массой тела и массой мозга животного (Найдите выбросы (outlayers).)



$$\lg \text{brain} = \beta_0 + \beta_1 \lg \text{body}$$

$$\beta_0 = 0.94, \beta_1 = 0.75, \text{brain} = 8.6 \times (\text{body})^{3/4}$$

Обучающая выборка

$$(x^{(1)}, y^{(1)}), (x^{(2)}, y^{(2)}), \dots, (x^{(N)}, y^{(N)})$$
$$x^{(i)} \in \mathcal{X}, \quad y^{(i)} \in \mathcal{Y} = \mathbf{R} \quad (i = 1, 2, \dots, N)$$
$$f^*(x^{(i)}) \approx y^{(i)} \quad (i = 1, 2, \dots, N)$$

Будем искать функцию $f^*(x)$ в виде (*линейная регрессионная модель*):


$$f(x) = f(x, \beta) = \beta_0 + \sum_{j=1}^d \beta_j x_j$$


Метод наименьших квадратов — один из методов нахождения неизвестных параметров $\beta_0, \beta_1, \dots, \beta_d$.

Ищем набор параметров $\hat{\beta}$, доставляющих минимум сумме квадратов невязок, или *остаточной сумме квадратов (residual sum of squares)*


$$\text{RSS}(\beta) = \sum_{i=1}^N \left(y^{(i)} - f(x^{(i)}, \beta) \right)^2.$$

Заметим, что $\frac{1}{N} \text{RSS}(\beta)$ есть эмпирический риск для квадратичной функции потерь.





$$y = \beta_0 + \sum_{j=1}^{N-1} \beta_j x^j$$



Функция $f^*(x)$ может быть функцией более общего вида:

$$f(x) = f(x, \beta) = \sum_{j=1}^q \beta_j h_j(x),$$

где β_j — неизвестные параметры, а $h_j(x)$ — заданные функции

Заметим, что параметры β_j входят *линейным* образом.

Но неизвестные параметры могут входить и *нелинейным* образом:

Например,

$$y = \beta_1 e^{\lambda_1 x} + \beta_2 e^{\lambda_2 x}.$$

β_1, β_2 — линейно, λ_1, λ_2 — нелинейно.

Если λ_1, λ_2 известны, то получаем линейную задачу (наименьших квадратов)

Если λ_1, λ_2 не известны — нелинейную задачу (наименьших квадратов)

Задача аппроксимации сплайнами тоже сводится к линейной задаче наименьших квадратов.

Почему метод наименьших *квадратов*?

Выведем (при некоторых дополнительных предположениях) метод наименьших квадратов из *принципа максимального правдоподобия*.

Y — с. в. с плотностью вероятности $p(y, \theta)$, где θ — вектор параметров.

N копий непрерывной случайной величины Y : $Y^{(1)}, Y^{(2)}, \dots, Y^{(N)}$

(N независимых одинаково распределенных с.в. — испытания Бернулли)

N реализаций этих величин: $y^{(1)}, y^{(2)}, \dots, y^{(N)}$

Плотность вероятности N -мерной с.в. $(Y^{(1)}, Y^{(2)}, \dots, Y^{(N)})$:

$$L(\theta) = p(y^{(1)}, y^{(2)}, \dots, y^{(N)}, \theta) = p(y^{(1)}, \theta) \cdot p(y^{(2)}, \theta) \cdot \dots \cdot p(y^{(i)}, \theta)$$

$L(\theta)$ — *функция правдоподобия*

Логарифмическая функция правдоподобия:

$$\ell(\theta) = \ln L(\theta) = \sum_{i=1}^N \ln p(y^{(i)}, \theta).$$

Принцип максимального правдоподобия предполагает, что наиболее разумные значения неизвестных параметров θ доставляют максимум функции $L(\theta)$ (и $\ell(\theta)$).

(Если Y — дискретная, то вместо $p(y^{(i)}, \theta)$ нужно рассмотреть $\Pr \{Y = y^{(i)}\}$)

Модель с аддитивной случайной ошибкой:

$$y = f^*(x) + E,$$

где E — случайная величина (ошибка), не зависящая от x , и $E E = 0$.

$f^*(x) = E(Y | X = x)$ — регрессионная функция.

Дополнительно предположим, что $E \sim N(0, \sigma^2) \Leftrightarrow$

$$p(y | x, \beta) = \frac{1}{\sqrt{2\pi}\sigma} \cdot e^{-\frac{1}{2} \frac{(y - f(x, \beta))^2}{\sigma^2}}$$

Тогда

$$\ell(\beta) = \sum_{i=1}^N \ln p(y^{(i)} | x, \beta) = -\frac{N}{2} \ln 2\pi - N \ln \sigma - \frac{1}{2\sigma^2} \sum_{i=1}^N (y^{(i)} - f(x^{(i)}, \beta))^2$$

В ней только последний член содержит вектор параметров β .

С точностью до множителя этот член равен $RSS(\beta)$

Итак, при сделанных предположениях метод наименьших квадратов эквивалентен принципу максимального правдоподобия

Как найти минимум функции $\text{RSS}(\beta)$?

Пусть

$$\mathbf{X} = \begin{pmatrix} 1 & x_1^{(1)} & x_2^{(1)} & \dots & x_d^{(1)} \\ 1 & x_1^{(2)} & x_2^{(2)} & \dots & x_d^{(2)} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_1^{(N)} & x_2^{(N)} & \dots & x_d^{(N)} \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(N)} \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_d \end{pmatrix}$$

Тогда

$$\text{RSS}(\beta) = \|\mathbf{y} - \mathbf{X}\beta\|^2 = (\mathbf{y} - \mathbf{X}\beta)^\top (\mathbf{y} - \mathbf{X}\beta) \rightarrow \min$$

Можно рассмотреть систему уравнений (относительно β)

$$\mathbf{X}\beta = \mathbf{y}$$

$\hat{\beta}$ называется *псевдорешением* этой системы (оно минимизирует норму невязки).

$\text{RSS}(\beta)$ — квадратичная функция от $d + 1$ неизвестных (параметров) $\beta_0, \beta_1, \dots, \beta_d$.

Дифференцируя, находим:

$$\frac{\partial \text{RSS}}{\partial \beta} = -2\mathbf{X}^\top (\mathbf{y} - \mathbf{X}\beta), \quad \frac{\partial^2 \text{RSS}}{\partial \beta \partial \beta^\top} = 2\mathbf{X}^\top \mathbf{X}.$$

Обозначим $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_d$ столбцы матрицы \mathbf{X} .

Если $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_d$ линейно независимы, то матрица $\mathbf{X}^\top \mathbf{X}$ невырождена и положительно определена, поэтому минимум функции $\text{RSS}(\beta)$ достигается, когда первая производная по β обращается в ноль:

$$\mathbf{X}^\top (\mathbf{y} - \mathbf{X}\beta) = 0 \quad \Leftrightarrow \quad \mathbf{X}^\top \mathbf{X}\beta = \mathbf{X}^\top \mathbf{y}.$$

Это *нормальная система уравнений*, или *система нормальных уравнений*.

Единственным решением является вектор

$$\hat{\beta} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$$

Итак, *псевдорешением* системы $\mathbf{X}\beta = \mathbf{y}$ является *решение* системы $\mathbf{X}^\top \mathbf{X}\beta = \mathbf{X}^\top \mathbf{y}$.

Матрица $\mathbf{X}^+ = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$ называется *псевдообратной* (Мура–Пенроуза) к \mathbf{X} .


Входным значениям x_1, x_2, \dots, x_N будет соответствовать вектор выходных переменных

$$\hat{\mathbf{y}} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_d)^\top = \mathbf{X}\hat{\beta} = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}.$$

Пусть $\mathbf{H} = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$, тогда получаем $\hat{\mathbf{y}} = \mathbf{H}\mathbf{y}$

$\hat{\mathbf{y}}$ есть ортогональная проекция \mathbf{y} на п/п-во, натянутое на $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_d$

\mathbf{H} называется *матрицей проектирования*



Если столбцы матрицы \mathbf{X} линейно зависимы, то $\hat{\beta}$, на котором достигается минимум функции $\text{RSS}(\beta)$, не единственен, однако, по-прежнему, \hat{y} является ортогональной проекцией вектора y на линейную оболочку векторов $\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_d$.

5.2. Проверка значимости и доверительные интервалы для коэффициентов (регрессионный анализ)

y , E , $\hat{\beta}$ случайны; \mathbf{X} , β детерминированы; $\mathbf{E} E = 0$, $\text{Cov } E = \sigma^2 \mathbf{I}$.

$$y = \mathbf{X}\beta + E, \quad \hat{\beta} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top y = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top (\mathbf{X}\beta + E).$$

$$\hat{\beta} - \beta = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top (\mathbf{X}\beta + E) - \beta = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top E$$

Несмещенность:

$$\mathbf{E} (\hat{\beta} - \beta) = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{E} E = 0 \quad \Rightarrow \quad \mathbf{E} \hat{\beta} = \beta.$$

Матрица ковариации:

$$\begin{aligned} \text{Cov } \hat{\beta} &= \mathbf{E} ((\hat{\beta} - \beta)(\hat{\beta} - \beta)^\top) = \mathbf{E} \left(((\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top E) ((\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top E)^\top \right) \\ &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \cdot \mathbf{E} (E E^\top) \cdot \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \cdot \sigma^2 \mathbf{I} \cdot \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} = \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \end{aligned}$$

Несмещенной оценкой для σ^2 является *остаточная дисперсия* $\hat{\sigma}^2 = \text{RSS} / (N - d - 1)$:

$$\mathbf{E} \hat{\sigma}^2 = \mathbf{E} (\text{RSS} / (N - d - 1)) = \mathbf{E} (y^\top (\mathbf{I} - \mathbf{H}) y / (N - d - 1)) = \sigma^2.$$

Дополнительные предположения:

Пусть ошибки $E^{(i)}$ распределены по нормальному закону:

$$E \sim N(0, \sigma \mathbf{I}).$$

В этом случае из некоррелированности случайных величин $E^{(i)}$ следует их независимость.

Теперь можно показать (*faciat, qui potest*), что

$$\hat{\beta} \sim N(\beta, (\mathbf{X}^\top \mathbf{X})^{-1} \sigma^2) \quad \text{и} \quad (N - d - 1) \hat{\sigma}^2 \sim \sigma^2 \chi_{N-d-1}^2.$$

Эти свойства будем использовать для построения статистических тестов и доверительных интервалов для β_j .

Проверка значимости модели.

Гипотеза $H_0: \beta_1 = \dots = \beta_d = 0$

Альтернативная гипотеза H_1 : найдется j , для которого $\beta_j \neq 0$

Если гипотеза H_0 верна, то решением задачи наименьших квадратов будет

$$\beta_0 = \bar{y} = \frac{1}{N} \sum_{i=1}^N y^{(i)}.$$

В этом случае остаточная сумма квадратов (называемая в данном случае *полной суммой квадратов относительно среднего*) равна

$$\text{TSS} = \sum_{i=1}^N (y^{(i)} - \beta_0)^2 = \sum_{i=1}^N (y^{(i)} - \bar{y})^2$$

Если принимается гипотеза H_1 , то говорят, что модель *статистически значима*.

Можно показать, что

$$\sum_{i=1}^d (y^{(i)} - \bar{y})^2 = \sum_{i=1}^d (y^{(i)} - \hat{y}^{(i)})^2 + \sum_{i=1}^d (\hat{y} - \bar{y})^2$$

TSS RSS ESS


TSS = $\sum_{i=1}^N (y^{(i)} - \bar{y})^2$ — полная сумма квадратов (total sum of squares)

ESS = $\sum_{i=1}^N (\hat{y}^{(i)} - \bar{y})^2$ — сумма квадратов, обусловленная регрессией (explained s. of sq.)

Если гипотеза H_0 верна, то

$$\hat{F} = \frac{\text{ESS}}{d\sigma^2} \bigg/ \frac{\text{RSS}}{(n-d-1)\sigma^2} \sim F(d, n-d-1)$$

Если модель значима, то ESS большая и критическая область справа:



Коэффициент детерминации (взгляд с другой стороны)

Коэффициент детерминации, или коэффициент регрессии Пирсона

$$R^2 = 1 - \frac{\text{RSS}}{\text{TSS}} = \frac{\text{ESS}}{\text{TSS}}. \quad (\star)$$

— доля объясняемого регрессией разброса относительно среднего.

$$0 \leq R^2 \leq 1.$$

Если R^2 близок к 1, то RSS намного больше TSS.

Очевидно, что $R = \sqrt{R^2}$ по модулю равно выборочной корреляции между $y^{(i)}$ и $\hat{y}^{(i)}$.

Если $d = 1$, то R равен выборочной корреляции между $x^{(i)}$ и $y^{(i)}$.

Если гипотеза H_0 верна, то

$$\hat{F} = \frac{R^2/d}{(1 - R^2)/(N - d - 1)} \sim F(d, n - d - 1).$$

Недостаток R^2 : при добавлении в модель новых признаков R^2 не изменяется. (Если d велико и близко к N , то может быть, что $\text{RSS} \approx 0$ и $R^2 \approx 1$.) В этом случае используется скорректированный («подправленный») коэффициент

$$R_a^2 = R^2 - \frac{1 - R^2}{N - d - 1}.$$

Упражнение 5.1 Доказать, что $TSS = RSS + ESS$. Это можно доказать непосредственное, а можно предварительно доказать, что $y - \hat{y} \perp \hat{y} - \bar{y}$, где \bar{y} — вектор, составленный из \bar{y} , и воспользоваться этим.

Упражнение 5.2 Разности

$$e^{(i)} = y^{(i)} - \hat{y}^{(i)} = y^{(i)} - \sum_{j=1}^d \hat{\beta}_j x_j^{(i)}$$

называются *остатками*. Доказать, что

$$\sum_{i=1}^N e^{(i)} = 0.$$

Упражнение 5.3 Доказать, что

$$\bar{y} = \beta_0 + \sum_{j=1}^d \hat{\beta}_j \bar{x}_j.$$

Упражнение 5.4 Доказать, что

$$\sum_{i=1}^N y^{(i)} = \sum_{i=1}^N \hat{y}^{(i)}.$$

Проверка значимости одного коэффициента.

Гипотеза $H_0: \beta_j = 0$ (j фиксировано):

использование переменной x_j не улучшает предсказание по сравнению с предсказанием, полученным на основе только остальных $d - 1$ переменных.

Для проверки этой гипотезы (против гипотезы $\beta_j \neq 0$) рассмотрим *стандартный коэффициент* (*z-score*)

$$t_j = \frac{\hat{\beta}_j}{\text{se } \beta_j}, \quad (*)$$

где

$$\text{se } \beta_j = \hat{\sigma} \sqrt{v_j}$$

— *стандартная ошибка* коэффициента β_j , а v_j — j -й диаг. элемент матрицы $(\mathbf{X}^\top \mathbf{X})^{-1}$.

В предположении $\beta_j = 0$ коэффициент t_j имеет t -распределение Стьюдента t_{N-d-1} .

Если $|t_j|$ «велико», то гипотезу H_0 следует отбросить.

Если гипотеза H_0 отбрасывается, то говорят, что коэффициент $\hat{\beta}_j$ *статистически значим*.

Можно проверить гипотезу $\beta_j = \beta'_j$ (относительно односторонней или двусторонней альтернативы), где β'_j — некоторое заданное значение.

Статистика критерия имеет в этом случае вид

$$t'_j = \frac{\hat{\beta}_j - \beta'_j}{\text{se } \beta_j}.$$

Коэффициент t'_j имеет распределение t_{N-d-1} .

Проверка гипотезы зависит от вида альтернативной гипотезы и происходит обычным образом.

Проверка значимости группы коэффициентов. Гипотеза о равенстве нулю группы коэффициентов (против гипотезы, что по крайней мере один из коэффициентов не равен нулю): переменные этой группы не улучшают предсказание по отношению к предсказанию, полученному без этих переменных.

Будем использовать статистику

$$F = \frac{(RSS_2 - RSS_1)/(d_1 - d_2)}{RSS_1 / (N - d_1 - 1)},$$

где RSS_1 — остаточная сумма квадратов «бóльшей» модели с $d_1 + 1$ параметрами, а RSS_2 — остаточная сумма квадратов «вложенной» модели с $d_2 + 1$ параметрами,

(«вложенная» модель получается из «бóльшей» обнулением $d_1 - d_2$ параметров).

В предположении, что E имеет нормальное распределение, статистика F имеет $F(d_1 - d_2, N - d_1 - 1)$ распределение Фишера.

Если отбрасывается один коэффициент, то F равен квадрату стандартного коэффициента t_j из (*).

Доверительные интервалы. Для β_j доверительным интервалом является

$$(\hat{\beta}_j - z^{(1-\alpha)}\hat{\sigma}\sqrt{v_j}, \hat{\beta}_j + z^{(1-\alpha)}\hat{\sigma}\sqrt{v_j}),$$

где $z^{(1-\alpha)}$ есть $(1 - \alpha)$ -процентиль для нормального распределения:

$$z^{(1-0.1)} = 1.645,$$

$$z^{(1-0.05)} = 1.96,$$

$$z^{(1-0.01)} = 2.58, \quad \text{и т. д.}$$

(v_j — j -й диаг. элемент в $(\mathbf{X}^\top \mathbf{X})^{-1}$, $\text{se } \hat{\beta}_j = \hat{\sigma}\sqrt{v_j}$ — стандартная ошибка для $\hat{\beta}_j$).


Таким образом, интервал $\hat{\beta} \pm 2 \cdot \text{se } \hat{\beta}$ соответствует мере доверия около 95%.

5.2.1. Пример


Зависимость длина тормозного пути (dist) от начальной скорости автомобиля (speed) [*Ezekiel M. Methods of Correlation Analysis. Wiley. 1930*], $N = 50$.

В качестве модели рассмотрим

$$\text{dist} = \beta_0 + \beta_1 \times \text{speed}.$$



Найдены значения $\hat{\beta}_0 = -17.579$, $\hat{\beta}_1 = 3.932$.



Синий график: регрессия в виде $\text{dist} = \beta_0 + \beta_1 \times \text{speed}$.

Красный график: регрессия в виде $\text{dist} = \beta_0 + \beta_1 \times \text{speed} + \beta_2 \times \text{speed}^2$.

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-17.5791	6.7584	-2.601	0.0123 *
speed	3.9324	0.4155	9.464	1.49e-12 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 15.38 on 48 degrees of freedom

Multiple R-squared: 0.6511, Adjusted R-squared: 0.6438

F-statistic: 89.57 on 1 and 48 DF, \pvalue: 1.49e-12

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	2.47014	14.81716	0.167	0.868
speed	0.91329	2.03422	0.449	0.656
I(speed^2)	0.09996	0.06597	1.515	0.136

Residual standard error: 15.18 on 47 degrees of freedom

Multiple R-squared: 0.6673, Adjusted R-squared: 0.6532

F-statistic: 47.14 on 2 and 47 DF, \pvalue: 5.852e-12

Для $\text{dist} = \beta_0 + \beta_1 \times \text{speed}$

Коэффициент детерминации и подправленный коэффициент детерминации:

$$r^2 = 0.6511, \quad r_a^2 = 0.6438.$$

Таким образом, регрессия объясняет около 65% изменчивости данных.

Стандартные ошибки и стандартные коэффициенты:

$$\text{se } \beta_0 = 6.7584, \quad \text{se } \beta_1 = 0.4155, \quad t_0 = -2.601, \quad t_1 = 9.464.$$

Задача имеет $N - d - 1 = 48$ степеней свободы.

Сравнивая значения t_0 и t_1 с квантилями t -распределения Стьюдента с 48 степенями свободы, получаем, что для гипотезы $\beta_0 = 0$ значение p -value меньше 0.0123, а для гипотезы $\beta_1 = 0$ оно равно 1.49×10^{-12} .

Если считать, что уровень надежности равен, например, $\alpha = 0.01$, то гипотезу $\beta_0 = 0$ принимаем, гипотезу $\beta_1 = 0$ отвергаем.

Остаточная стандартная ошибка равна $\hat{\sigma} = 15.38$.

Значение F -статистики $F = 89.57$ сравниваем с квантилями F -распределения $F_{1,48}$.

Получаем p -value, равное 1.490×10^{-12} — для указанного уровня надежности модель статистически значима.

Для $\text{dist} = \beta_0 + \beta_1 \times \text{speed} + \beta_2 \times \text{speed}^2$:

Найдены значения $\hat{\beta}_0 = 2.47014$, $\hat{\beta}_1 = 0.91329$, $\hat{\beta}_2 = 0.09996$.

Имеем

$$r^2 = 0.6673, \quad r_a^2 = 0.6532,$$

$$\text{se } \beta_0 = 14.81716, \quad \text{se } \beta_1 = 2.03422, \quad \text{se } \beta_2 = 0.06597,$$

$$t_0 = 0.167, \quad t_1 = 0.449, \quad t_2 = 1.515.$$

Задача имеет $N - d - 1 = 47$ степеней свободы.

Значение p-value для гипотезы $\beta_0 = 0$ меньше 0.868.

Для гипотезы $\beta_1 = 0$ оно равно 0.656,

а для гипотезы $\beta_2 = 0$ равно 0.136.

Таким образом, при уровне надежности $\alpha = 0.01$ гипотезу $\beta_2 = 0$ принимаем.

Коэффициент β_2 не является статистически значимым.

Остаточная стандартная ошибка равна $\hat{\sigma} = 15.18$.

Значение F -статистики $F = 47.14$ нужно сравнить с квантилями F -распределения Фишера $F_{2,47}$.

Это сравнение приводит к p-value, равному 5.852×10^{-12} .

Таким образом, для указанного уровня надежности модель статистически значима.

Сравниваем обе модели (1-я квадратичная; 2-я линейная)

$$F = \frac{(RSS_2 - RSS_1)/(d_1 - d_2)}{RSS_1/(N - d_1 - 1)} = \frac{(11353.52 - 10824.72)/(2 - 1)}{10824.72/(50 - 2 - 1)} = 2.296027$$

Заметим, что $\sqrt{F} = 1.515265$ совпадает с t-статистикой для β_2

Вычисляем p-value = 0.13640241 — β_2 незначим.

5.2.2. Пример. Boston

Все данные:

$$N = 506, d = 13 \text{ RSS} = 11078.78 \text{ RSS} / N = 21.90$$

Residuals:

Min	1Q	Median	3Q	Max
-15.595	-2.730	-0.518	1.777	26.199

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	3.646e+01	5.103e+00	7.144	3.28e-12	***
CRIM	-1.080e-01	3.286e-02	-3.287	0.001087	**
ZN	4.642e-02	1.373e-02	3.382	0.000778	***
INDUS	2.056e-02	6.150e-02	0.334	0.738288	
CHAS	2.687e+00	8.616e-01	3.118	0.001925	**
NOX	-1.777e+01	3.820e+00	-4.651	4.25e-06	***
RM	3.810e+00	4.179e-01	9.116	< 2e-16	***
AGE	6.922e-04	1.321e-02	0.052	0.958229	
DIS	-1.476e+00	1.995e-01	-7.398	6.01e-13	***
RAD	3.060e-01	6.635e-02	4.613	5.07e-06	***
TAX	-1.233e-02	3.760e-03	-3.280	0.001112	**

```
PTRAT      -9.527e-01  1.308e-01  -7.283  1.31e-12 ***
B           9.312e-03  2.686e-03   3.467  0.000573 ***
LSTAT      -5.248e-01  5.072e-02 -10.347  < 2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.745 on 492 degrees of freedom
Multiple R-squared: 0.7406, Adjusted R-squared: 0.7338
F-statistic: 108.1 on 13 and 492 DF, \pvalue: < 2.2e-16

Выделим обучающую ($N = 405$) и тестовую ($N_{\text{test}} = 101$) выборки

на обучающей $\text{RSS} = 8655.383$, $\text{RSS} / N = 21.37132$

на тестовой $\text{RSS}_{\text{test}} = 2522.615$, $R \approx \text{RSS}_{\text{test}} / N_{\text{test}} = 24.97638$, $\text{se } R = 0.4997638$.

$$(\text{se } R)^2 = \frac{1}{N_{\text{test}}} \text{Var}(Y - \hat{Y}) = \frac{1}{N_{\text{test}}} \left(\frac{1}{N_{\text{test}} - 1} \sum_{i=1}^{N_{\text{test}}} (y^{(i)} - \hat{y}^{(i)})^2 \right)$$

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	32.353120	5.775840	5.601	4.01e-08	***
CRIM	-0.116261	0.034297	-3.390	0.00077	***
ZN	0.049895	0.015084	3.308	0.00103	**
INDUS	0.032491	0.073167	0.444	0.65724	
CHAS	2.054215	1.059339	1.939	0.05320	.
NOX	-17.501306	4.194206	-4.173	3.71e-05	***
RM	4.261255	0.500527	8.514	3.67e-16	***
AGE	-0.003699	0.015249	-0.243	0.80845	
DIS	-1.389752	0.216254	-6.426	3.80e-10	***
RAD	0.310786	0.072337	4.296	2.19e-05	***
TAX	-0.013453	0.004167	-3.229	0.00135	**
PTRATIO	-0.913321	0.148451	-6.152	1.89e-09	***
B	0.008908	0.002929	3.042	0.00251	**
LSTAT	-0.475633	0.061656	-7.714	1.02e-13	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.705 on 391 degrees of freedom
Multiple R-squared: 0.7432, Adjusted R-squared: 0.7346
F-statistic: 87.03 on 13 and 391 DF, \pvalue: < 2.2e-16

Возьмем только значимые (***) переменные: CRIM + NOX + RM + DIS + RAD + PTRATIO + LSTAT

На обучающей выборке $RSS = 9437.129$, $RSS / N = 23.30155$

На тестовой выборке $RSS = 2798.908$, $RSS / N = 27.71196$ $se = 0.5264215$

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	35.55914	5.71594	6.221	1.25e-09	***
CRIM	-0.11438	0.03527	-3.243	0.00128	**
NOX	-20.55633	3.86533	-5.318	1.75e-07	***
RM	4.59477	0.48776	9.420	< 2e-16	***
DIS	-1.06844	0.17807	-6.000	4.44e-09	***
RAD	0.11284	0.04673	2.415	0.01619	*
PTRATIO	-1.13134	0.14049	-8.053	9.54e-15	***
LSTAT	-0.51548	0.05926	-8.699	< 2e-16	***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 4.876 on 397 degrees of freedom

Multiple R-squared: 0.72, Adjusted R-squared: 0.715

F-statistic: 145.8 on 7 and 397 DF, \pvalue: < 2.2e-16

$$F = \frac{(\text{RSS}_2 - \text{RSS}_1)/(d_1 - d_2)}{\text{RSS}_1 / (N - d_1 - 1)} = \frac{(9437.129 - 8655.383)/(13 - 7)}{8655.383/(405 - 13 - 1)} = 5.885792$$

Распределение $F(d_1 - d_2, N - d_1 - 1) = F(6, 391)$.

Находим p-value: $6.783518e - 06$, т. е. гипотеза о незначимости 6 переменных не принимается (для разумного уровня значимости α)

5.2.3. Анализ остатков

Ранее мы сделали предположение, что остатки должны быть независимы (некоррелированы) и иметь нормальное распределение.

Многие рассмотренные выше тесты достаточно устойчивы по отношению к отклонениям от таких предположений. Однако перед тем, как исследовать статистическую значимость модели и строить доверительные интервалы, рекомендуется провести анализ остатков.

«Визуальные» способы:

- Гистограмма остатков — должна быть близка к нормальному распределению;
- график остатков — без зависимостей и нелинейностей;
- *QQ-график* (график «квантиль–квантиль»)







График остатков в задаче восстановления зависимости длины тормозного пути от начальной скорости.





Гистограмма остатков в задаче восстановления зависимости вида $\text{dist} = \beta_0 + \beta_1 \times \text{speed}$ длины тормозного пути от начальной скорости.



QQ-график в задаче восстановления зависимости длины тормозного пути от начальной скорости.

Теоретическая проверка нормальности остатков:

- общие критерии согласия: χ^2 , критерий Колмогорова–Смирнова и т. п.
- специализированные, например, *критерий Шапиро–Уилка*

Нуль-гипотеза в критерии Шапиро–Уилка заключается в том, что статистически наблюдаемая случайная величина имеет нормальное распределение.

В задаче с определением длины тормозного пути автомобиля статистика Шапиро–Уилка оказалась равной $W = 0.9451$.

Соответствующее p-value равно 0.02153. При уровне значимости $\alpha = 0.01$ гипотезу о нормальности распределения остатков принимаем.

Критерий Уайта

Проверка на гомоскедастичность (постоянство дисперсии) остатков.

Гипотеза $H_0: \sigma_1 = \sigma_2 = \dots = \sigma_N$

Гипотеза $H_1: H_0$ не выполнено

К исходной модели применяется метод наименьших квадратов и находятся остатки e_1, e_2, \dots, e_N .

Затем строится модель, описывающая квадраты этих остатков через исходные переменные, их квадраты и попарные произведения:

$$e^2 = \gamma_0 + \sum_{j=1}^d \gamma_j x_j + \sum_{j \leq j'} \gamma_{jj'} x_j x_{j'}.$$

При гипотезе H_0 величина nr^2 асимптотически имеет распределение $\chi^2(d' - 1)$, где


$d' = 1 + d + \frac{d(d+1)}{2}$ — число переменных новой модели,


r^2 — коэффициент детерминации новой модели.


Анализ остатков для линейной модели $\text{dist} = \beta_0 + \beta_1 \times \text{speed}$:

```
bptest(dist ~ speed, data=cars) # BP = 3.2149, df = 1, \pvalue = 0.07297  
White = 3.2157, df = 2, \pvalue = 0.2003
```

Boston








Критерий Шапиро-Уилка $W = 0.8739$, $p\text{-value} < 2.2e-16$ Отвергаем

Тест на гомоскедастичность

Тест Бройша–Пагана = 51.0623, df = 13, p-value= 1.958e-06


Критерий Уайта: White-test = 285.8917, df = 103, p-value < 2.2e-16




В оригинальной статье [Harrison and Rubinfeld, 1978] рассматривается модель


$$\ln \text{MEDV} = \beta_0 + \beta_1 \text{CRIM} + \beta_2 \text{ZN} + \beta_3 \text{INDUS} + \beta_4 \text{CHAS} + \beta_5 \text{NOX}^2 + \beta_6 \text{RM}^2 + \beta_7 \text{AGE} + \beta_8 \ln \text{DIS} + \\ + \beta_9 \ln \text{RAD} + \beta_{10} \text{TAX} + \beta_{11} \text{PTRAT} + \beta_{12} \text{B} + \beta_{13} \ln \text{LSTAT} + E.$$

$$\text{RSS} / N_{\text{train}} = 16.05832, \quad \text{RSS} / N_{\text{test}} = 14.77086$$



Но также не проходит тест на нормальность. Shapiro-Wilk normality test $W = 0.9439$, $p\text{-value} = 2.989e-11$






Тест на гомоскедастичность

Тест Бройша–Пагана = 76.1122, df = 13, p-value= 5.905e-11

Критерий Уайта =



Для выявления корреляции между остатками (точнее: сериальной корреляции) часто используется критерий Дарбина–Уотсона. Статистика Дарбина–Уотсона вычисляется по формуле

$$D = \frac{\sum_{i=1}^{N-1} (e^{(i+1)} - e^{(i)})^2}{\sum_{i=1}^N e^{(i)2}}.$$

Упражнение 5.5 Доказать, что $0 \leq D \leq 4$.

Если $D < D_L(\alpha)$ или $D > 4 - D_L(\alpha)$, то с достоверностью α принимается гипотеза о наличии отрицательной или соответственно положительной корреляции остатков.

Если $D_L(\alpha) < D < D_U(\alpha)$ или $4 - D_U(\alpha) < D < 4 - D_L(\alpha)$, то критерий не позволяет принять решение о наличии или отсутствии корреляции остатков.

Если $D_U(\alpha) < D < 4 - D_U(\alpha)$, то гипотеза о наличии корреляции остатков отклоняется.

Таблицы критических значений $D_L(\alpha)$ и $D_U(\alpha)$ для различных α , N , d приведены, например, в [Дрейпер, Смит Т. 1, С. 211].

5.3. Подготовка данных

В линейной регрессионной модели в качестве признаков x_j могут выступать:

- исходные количественные признаки
- функции от исходных количественных признаков, например, x_1^2 , $\ln x_2$
- функции от нескольких исходных признаков, например, $x_3 = x_1 \cdot x_2$
- бинарные признаки
- бинаризованные категориальные признаки

$$y = f(x) \equiv \sum_{j=1}^s \beta_j h_j(x)$$

Например,

$$y = f(x) \equiv \beta_1 e^{\lambda_1 x} + \beta_2 e^{\lambda_2 x}.$$

Если λ_1 , λ_2 известны, то получаем линейную регрессию

Если λ_1 , λ_2 не известны, то получаем нелинейную регрессию

5.3.1. Бинаризация категориальных признаков

(one hot encoding)

Категориальный признак **House**, принимающий значения

Block, Brick, Monolithic, Panel, Wooden,

заменяем на 5 бинарных признаков:

x_{Block} , x_{Brick} , $x_{\text{Monolithic}}$, x_{Panel} , x_{Wooden}

$$\text{House} = \text{Block} \Leftrightarrow x_{\text{Block}} = 1, x_{\text{Brick}} = 0, x_{\text{Monolithic}} = 0, x_{\text{Panel}} = 0, x_{\text{Wooden}} = 0$$

$$\text{House} = \text{Brick} \Leftrightarrow x_{\text{Block}} = 0, x_{\text{Brick}} = 1, x_{\text{Monolithic}} = 0, x_{\text{Panel}} = 0, x_{\text{Wooden}} = 0$$

и т. д.

Нужны только 4 бинарных признака!

Price	цена квартиры (тыс. руб.)
Date	№ дня, в который квартира выставлена на продажу
Lat	географическая широта объекта недвижимости
Lng	географическая долгота объекта недвижимости
Housing	тип недвижимости (0 — вторичное жилье, 1 — новостройка)
Floors	количество этажей в доме
House	тип дома
Rooms	количество комнат
Floor	№ этажа
Area	площадь квартиры (м ²)

$$y = \beta_0 + \sum_{j=1}^{12} \beta_j x_j$$

$$\beta_0 = -1.398 \times 10^5, \quad \beta_1 = \beta_{\text{Date}} = 3.634 \times 10^{-1}, \quad \beta_2 = \beta_{\text{Lat}} = 7.540 \times 10^2, \quad \dots$$

$$\widehat{R}_{\text{train}} = \frac{1}{N_{\text{train}}} \text{RSS}_{\text{train}} = 495194.6, \quad \widehat{R}_{\text{test}} = \frac{1}{N_{\text{test}}} \text{RSS}_{\text{test}} = 547395.1$$

5.3.2. Центрирование и нормализация данных

Центрирование:

- Центрирование $x^{(i)}$:
каждое $x_j^{(i)}$ заменяем на $x_j^{(i)} - \bar{x}_j$ ($i = 1, 2, \dots, N$; $j = 1, 2, \dots, d$), где

$$\bar{x}_j = \frac{1}{N} \sum_{i=1}^N x_j^{(i)}$$

Приведение к единичному стандартному отклонению:

- Приведение к нулевому среднему и единичному стандартному отклонению:
каждое $x_j^{(i)}$ заменяем на $\frac{x_j^{(i)} - \bar{x}_j}{s_j}$ ($i = 1, 2, \dots, N$; $j = 1, 2, \dots, d$), где

$$\bar{x}_j = \frac{1}{N} \sum_{i=1}^N x_j^{(i)}, \quad s_j = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_j^{(i)} - \bar{x}_j)^2}$$

Приведение к отрезку $[0, 1]$:

- каждое $x_j^{(i)}$ заменяем на

$$\frac{x_j^{(i)} - \min_i \bar{\mathbf{x}}_j}{\max_i \bar{\mathbf{x}}_j - \min_i \bar{\mathbf{x}}_j} \quad (i = 1, 2, \dots, N; j = 1, 2, \dots, d),$$

где

$$\min_i \bar{\mathbf{x}}_j = \min \left\{ x_j^{(1)}, x_j^{(2)}, \dots, x_j^{(N)} \right\}, \quad \max_i \bar{\mathbf{x}}_j = \max \left\{ x_j^{(1)}, x_j^{(2)}, \dots, x_j^{(N)} \right\}$$

- Центрирование y :
каждое $y^{(i)}$ заменяем на $y^{(i)} - \bar{y}$ ($i = 1, 2, \dots, N$)

$$\bar{y} = \frac{1}{N} \sum_{i=1}^N y^{(i)}$$

Если центрирование y проведено, то далее используем МНК без β_0 :

$$y = f(x) \equiv \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_d x_d,$$

а потом кладем $\beta_0 = \bar{y}$