

# Лекция 9. Множественная линейная регрессия

Буре В.М., Грауэр Л.В.

ШАД

Санкт-Петербург, 2013

# Содержание

- 1 Спецификация модели
- 2 Метод наименьших квадратов
- 3 Свойство оценок метода наименьших квадратов
- 4 Построение доверительных интервалов и проверка статистических гипотез
- 5 Нелинейные регрессионные модели, сводящиеся к линейным при помощи замены переменных

## Спецификация модели

Рассмотрим следующая модель наблюдений, связывающую значения некоторого наблюдаемого показателя  $y$  и объясняющих переменных  $x = (x_1, \dots, x_m)^T$  :

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i, \quad i = 1, \dots, n, \quad (1)$$

где  $\beta^T = (\beta_0, \dots, \beta_k)$  - неизвестные параметры,  $x_{ij}$  - значения объясняющих факторов,  $\varepsilon_i$  — ненаблюдаемая случайная компонента,  $j$  — номер переменной,  $i$  — номер наблюдения.

Будем предполагать, что имеется  $n$  наблюдений показателя  $y_i$ , точно известны значения объясняющих переменных  $x_i = (x_{i1}, \dots, x_{ik})$  в каждом из наблюдений, причем в модель наблюдений (1) входит значение ненаблюдаемой случайной компоненты  $\varepsilon_i$ . Ненаблюдаемая компонента может представлять собой ошибку измерений или заменять совокупное действие других переменных, значения которых не учитываются в модели наблюдений (1).

Сформулируем основные предположения регрессионного анализа, которые относятся к случайным компонентам  $\varepsilon_i$ ,  $i = 1, \dots, n$ .

Первая группа

- Случайные величины  $\varepsilon_i$ ,  $i = 1, \dots, n$  образуют так называемый слабый белый шум, т. е. последовательность центрированных ( $E\varepsilon_i = 0$ ,  $i = 1, \dots, n$ ) и некоррелированных ( $E(\varepsilon_l\varepsilon_u) = 0$  при  $l \neq u$ ) случайных величин с одинаковыми дисперсиями  $\sigma^2$  ( $E\varepsilon_i^2 = \sigma_i^2$ ,  $i = 1, \dots, n$ ).

Вторая группа

- Совместное распределение случайных величин  $\varepsilon_i$ ,  $i = 1, \dots, n$  является нормальным распределением с нулевым вектором математических ожиданий и ковариационной матрицей  $\sigma^2 E_n$ , т. е. случайный вектор  $\varepsilon^T = (\varepsilon_1, \dots, \varepsilon_n) \sim N(0, \sigma^2 E_n)$ , где  $E_n$  — единичная матрица порядка  $n \times n$ .

Модель наблюдений (1) можно записать в матричном виде:

$$Y = X\beta + \varepsilon, \quad (2)$$

где  $Y = (y_1, \dots, y_n)^T$ ,  $\beta = (\beta_0, \beta_1, \dots, \beta_k)^T$ ,  $\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)^T$ ,

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix}$$

— матрица порядка  $n \times (k + 1)$ .

## Метод наименьших квадратов

В модели наблюдений (1), (2) неизвестными являются параметры

$$\sigma, \beta_0, \beta_1, \dots, \beta_k.$$

Рассмотрим в качестве процедуры оценивания неизвестных параметров метод наименьших квадратов.

Введем обозначение:  $X_r = (x_{1r}, x_{2r}, \dots, x_{nr})^T$ ,  $r = 1, \dots, k$  — столбец матрицы  $X$ , тогда

$$X = (X_0, X_1, \dots, X_k),$$

где  $X_0 = (1, 1, \dots, 1)^T$ .

В качестве минимизируемого критерия рассмотрим

$$(Y - X\beta)^T(Y - X\beta) = \sum_{i=1}^n (y_i - \beta_0 - \beta_1 x_{i1} - \dots - \beta_k x_{ik})^2. \quad (3)$$

Оценки, получаемые из условия минимума (3), называют оценками метода наименьших квадратов.

Для минимизации выражения (3) по неизвестным параметрам  $\beta$  воспользуемся геометрическими представлениями. Рассмотрим в  $n$ -мерном пространстве  $\mathbb{R}^n$  линейное подпространство  $L(X_0, X_1, \dots, X_k)$ , в котором вектора  $X_0, X_1, \dots, X_k$  являются базисом. При этом, конечно, в дальнейшем будем предполагать, что они линейно независимы. Пусть  $\hat{Y}$  представляют собой ортогональную проекцию вектора  $Y$  на подпространство  $L(X_0, X_1, \dots, X_k)$ . Очевидно, что для любого другого вектора  $\tilde{Y} \in L(X_0, \dots, X_k)$  будет выполняться

$$(Y - \hat{Y})^T (Y - \hat{Y}) \leq (Y - \tilde{Y})^T (Y - \tilde{Y}),$$

неравенство следует из условия ортогональности вектора  $Y - \hat{Y}$  подпространству  $L(X_0, \dots, X_k)$ .

Действительно, для любого вектора  $\tilde{Y} \in L(X_0, \dots, X_k)$  выполняется  $(\tilde{Y} - \hat{Y}) \perp (Y - \hat{Y})$ , так как  $(\tilde{Y} - \hat{Y}) \in L(X_0, \dots, X_k)$  и  $(Y - \hat{Y}) \perp L(X_0, \dots, X_k)$ . Но тогда

$$\begin{aligned} (Y - \tilde{Y})^T (Y - \tilde{Y}) &= (Y - \hat{Y} - (\tilde{Y} - \hat{Y}))^T (Y - \hat{Y} - (\tilde{Y} - \hat{Y})) = \\ &= (Y - \hat{Y})^T (Y - \hat{Y}) + (\tilde{Y} - \hat{Y})^T (\tilde{Y} - \hat{Y}) \end{aligned}$$

Откуда следует

$$(Y - \tilde{Y})^T(Y - \tilde{Y}) \geq (Y - \hat{Y})^T(Y - \hat{Y}),$$

причем, равенство возможно только, если  $\tilde{Y} = \hat{Y}$ .

Для того, чтобы вектор  $Y - \hat{Y}$  был ортогонален подпространству  $L(X_0, X_1, \dots, X_k)$  необходимо и достаточно, чтобы

$$(Y - \hat{Y}) \perp X_i, \quad i = 0, 1, \dots, k$$

или, чтобы

$$(Y - \hat{Y})^T X = 0 \tag{4}$$

Так как вектор  $\hat{Y} \in L(X_0, X_1, \dots, X_k)$ , то существует набор коэффициентов, обозначим их через  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ , что

$$\hat{Y} = \sum_{r=0}^k \hat{\beta}_r X_r = X \hat{\beta},$$

где  $\hat{\beta} = (\hat{\beta}_0, \dots, \hat{\beta}_k)^T$ .



Тогда равенство (4) равносильно равенству

$$X^T Y - X^T X \hat{\beta} = 0$$

или равенству

$$(X^T X) \hat{\beta} = X^T Y. \quad (5)$$

Так как, по нашему предположению, столбцы матрицы  $X$  линейно независимы, то отсюда следует, что  $n \geq k$  и определитель  $|X^T X| \neq 0$ . Следовательно, оценки метода наименьших квадратов  $\hat{\beta}$  неизвестных параметров  $\beta$  имеют вид:

$$\hat{\beta} = (X^T X)^{-1} X^T Y. \quad (6)$$

Для удобства дальнейших преобразований введем ряд новых матриц и изучим их свойства. Из формулы (6) следует, что ортогональная проекция произвольного вектора  $Y$  на  $L(X_0, \dots, X_k)$  имеет вид  $\hat{Y} = X\hat{\beta} = X(X^T X)^{-1}X^T Y$ , но тогда матрица

$$P = X(X^T X)^{-1}X^T$$

представляет собой матрицу ортогонального проектирования на пространство  $L(X_0, \dots, X_k)$ . Рассмотрим подпространство  $L^\perp$  ортогональное подпространству  $L(X_0, \dots, X_k)$ . Любой вектор  $Y$  из  $\mathbb{R}^n$  однозначно представим в виде:

$$Y = \hat{Y} + (Y - \hat{Y}),$$

где  $\hat{Y} \in L(X_0, \dots, X_k)$ ,  $Y - \hat{Y} \in L^\perp$ . Из предыдущего ясно, что

$$Y - \hat{Y} = Y - X(X^T X)^{-1}X^T Y = (E_n - X(X^T X)^{-1}X^T)Y.$$

Следовательно, матрица

$$P^\perp = E_n - P$$

является матрицей ортогонального проектирования на подпространство  $L^\perp$ .

Действительно, для любого вектора  $Y \in \mathbb{R}^n$  получаем

$$P^\perp Y = Y - PY = Y - \hat{Y},$$

но вектор  $Y - \hat{Y} \perp L(X_0, \dots, X_k)$ , следовательно, вектор  $Y - \hat{Y} \in L^\perp$ .  
Нетрудно проверить справедливость следующих свойств:

- ①  $P^T = P, (P^\perp)^T = P^\perp$ .
- ②  $P^2 = P, (P^\perp)^2 = P^\perp$ .
- ③  $PP^\perp = P^\perp P = 0$ .
- ④  $P + P^\perp = E_n$ .
- ⑤  $PX_j = X_j, j = 0, 1, \dots, k, P^\perp X_j = 0, j = 0, 1, \dots, k$ .

Введем вектор

$$\hat{\varepsilon} = Y - \hat{Y} = P^\perp Y, \quad (7)$$

который будем называть **вектором остатков**.

Следует иметь в виду, что после нахождения коэффициентов  $\hat{\beta}$  можно рассмотреть следующую функцию, которую собственно и называют линейной регрессией:

$$\hat{y}(x) = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \dots + \hat{\beta}_k x_k. \quad (8)$$

Построенная линейная регрессия представляет собой эмпирическую зависимость между изучаемым показателем  $y$  и объясняющими переменными  $x = (x_1, \dots, x_k)^T$ , поэтому естественно называть остатками разности

$$y_i - \hat{y}(x_i) = \hat{\varepsilon}_i, \quad i = 1, \dots, n, \quad (9)$$

которые не объясняются построенной эмпирической моделью (8). Вектор, составленный из разностей  $\hat{\varepsilon}_i$ , и представляет собой вектор  $\hat{\varepsilon} = (\hat{\varepsilon}_1, \dots, \hat{\varepsilon}_n)$ .

Нетрудно заметить, что

$$\hat{\varepsilon} = P^\perp Y = P^\perp (X\beta + \varepsilon) = P^\perp \varepsilon. \quad (10)$$

Величины  $\hat{\varepsilon}_i$ ,  $i = 1, \dots, n$ , можно, следовательно, рассматривать, как оценки ненаблюдаемых величин  $\varepsilon_i$ ,  $i = 1, \dots, n$ .

## Свойство оценок метода наименьших квадратов

Как нетрудно заметить, оценки метода наименьших квадратов обладают свойством несмещенности:

$$E\hat{\beta} = (X^T X)^{-1} X^T EY = (X^T X)^{-1} X^T X\beta = \beta.$$

Вычислим ковариационную матрицу оценок метода наименьших квадратов, считая, что выполнена первая группа предположений регрессионного анализа:

$$\begin{aligned} D\hat{\beta} &= E\{(\hat{\beta} - \beta)(\hat{\beta} - \beta)^T\} = E\{(X^T X)^{-1} X^T \varepsilon \varepsilon^T X (X^T X)^{-1}\} = \\ &= (X^T X)^{-1} X^T \sigma^2 E_n X (X^T X)^{-1} = \sigma^2 (X^T X)^{-1}. \end{aligned}$$

Оценки метода наименьших квадратов при условии выполнения предположений из первой группы являются наилучшими линейными несмещенными оценками. Линейность понимается в том смысле, что оценки имеют вид  $\hat{\beta} = AY$ , где  $A = (X^T X)^{-1} X^T$  — матрица коэффициентов, т.е. речь идет о линейности по наблюдениям.

Следуя общему определению эффективности оценок, заметим, что оценки  $\hat{\beta}$  являются наилучшими линейными несмещенными оценками в том смысле, что для любых других оценок  $\tilde{\beta}$  вида  $\tilde{\beta} = CY$ , обладающих свойством несмещенности, оказывается, что разность дисперсионных матриц оценок  $D\tilde{\beta} - D\hat{\beta}$  представляет собой неотрицательно определенную матрицу, т.е. для любого вектора  $\gamma \in \mathbb{R}^{k+1}$  выполняется

$$\gamma^T (D\tilde{\beta} - D\hat{\beta})\gamma \geq 0.$$

Отсюда, в частности, сразу следует, что дисперсии оценок  $\tilde{\beta}_i$  не меньше, чем дисперсии оценок  $\hat{\beta}_i$ , т.е.

$$D\tilde{\beta}_i \geq D\hat{\beta}_i, \quad i = 0, 1, 2, \dots, k.$$

## Теорема 1 (Теорема Гаусса-Маркова)

Пусть выполнены все условия из первой группы предположений регрессионного анализа, тогда оценки метода наименьших квадратов  $\hat{\beta}$  являются наилучшими линейными несмещенными оценками.

### Доказательство

Пусть  $\tilde{\beta} = CY$  — произвольные линейные несмещенные оценки вектора  $\beta$ . Из условия несмещенности следует

$$E\tilde{\beta} = CX\beta = \beta.$$

Так как это равенство должно выполняться для любого вектора  $\beta$ , то условие несмещенности равносильно матричному равенству

$$CX = E_{k+1}.$$

Введем в рассмотрение матрицу  $D$ , определяемую равенством

$$D = C - (X^T X)^{-1} X^T.$$



Как легко видеть,  $DX = 0$ . Очевидно, что

$$D\tilde{\beta} = E\{(\tilde{\beta} - \beta)(\tilde{\beta} - \beta)^T\} = E\{C\varepsilon\varepsilon^T C^T\} = \sigma^2 CC^T.$$

Заметим, что

$$CC^T = (D + (X^T X)^{-1} X^T)(D + (X^T X)^{-1} X^T)^T = DD^T + (X^T X)^{-1}.$$

Но тогда для произвольного вектора  $\gamma \in \mathbb{R}^{k+1}$ :

$$\gamma^T (D\tilde{\beta} - D\beta)\gamma = \sigma^2 \gamma^T DD^T \gamma = \sigma^2 (\gamma^T D)(\gamma^T D)^T \geq 0.$$

Оценим дисперсию одиночного наблюдения  $\sigma^2$ . Для этого вначале найдем ковариационную матрицу  $D\hat{\varepsilon}$ . Как следует из формулы (6)

$$D\hat{\varepsilon} = E\{P^\perp \varepsilon \varepsilon^T P^\perp\} = \sigma^2 P^\perp.$$

Рассмотрим сумму квадратов остатков:

$$\sum_{i=1}^n \hat{\varepsilon}_i^2 = \hat{\varepsilon}^T \hat{\varepsilon} = \text{tr}\{\hat{\varepsilon} \hat{\varepsilon}^T\}.$$

Вычислим математическое ожидание:

$$E\hat{\varepsilon}^T \hat{\varepsilon} = E\text{tr}\{\hat{\varepsilon} \hat{\varepsilon}^T\} = \text{tr}E\{\hat{\varepsilon} \hat{\varepsilon}^T\} = \text{tr}\{E(P^\perp \varepsilon \varepsilon^T P^\perp)\} = \sigma^2 \text{tr}P^\perp.$$

Заметим, что

$$\begin{aligned} \text{tr}P^\perp &= \text{tr}\{E_n - X(X^T X)^{-1}X^T\} = n - \text{tr}\{X(X^T X)^{-1}X^T\} = \\ &= n - \text{tr}\{(X^T X)(X^T X)^{-1}\} = n - k - 1. \end{aligned}$$

При выводе формулы мы воспользовались свойством  $\text{tr}(AB) = \text{tr}(BA)$ , если оба произведения имеют смысл.

В результате проведенных выкладок получаем, что статистика

$$S^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n - k - 1} = \frac{1}{n - k - 1} \hat{\varepsilon}^T \hat{\varepsilon}$$

является несмещенной оценкой дисперсии  $\sigma^2$ .

Рассмотрим матрицу  $E\{(\hat{\beta} - \beta)\hat{\varepsilon}^T\}$ , элементы которой представляют собой ковариации случайных величин  $\hat{\beta}_j$  и  $\hat{\varepsilon}_i$ ,  $j = 0, 1, \dots, k$ ,  $i = 1, 2, \dots, n$ .

Из свойств матрицы  $P^\perp$  следует

$$E\{(\hat{\beta} - \beta)\hat{\varepsilon}^T\} = (X^T X)^{-1} X^T E\{\varepsilon \varepsilon^T\} P^\perp = \sigma^2 (X^T X)^{-1} X^T P^\perp = 0.$$

Найденная несмещенная оценка  $S^2$  одиночной дисперсии  $\sigma^2$  позволяет построить несмещенные оценки всех ковариаций вектора оценок  $\hat{\beta}$ .

Действительно, как было получено ранее,  $D\hat{\beta} = \sigma^2(X^T X)^{-1}$ , но теперь, заменяя  $\sigma^2$  на  $S^2$ , получаем несмещенные оценки всех ковариаций и дисперсий вектора  $\hat{\beta}$ , другими словами, элементы матрицы  $\hat{\sigma}^2(X^T X)^{-1}$  являются несмещенными оценками дисперсий и ковариаций оценок  $\hat{\beta}_j, j = 0, \dots, k$ .

### Лемма 1

*Пусть выполнены все условия из первой и второй групп предположений регрессионного анализа, тогда статистика  $(n - k - 1)S^2/\sigma^2$  подчиняется распределению  $\chi^2$  с  $n - k - 1$  степенями свободы.*

*Доказательство*

Ранее было установлено, что  $\hat{\varepsilon} = P^\perp \varepsilon$ , где  $P^\perp$  — матрица ортогонального проектирования на подпространстве  $L^\perp$ . Очевидно, что размерность подпространства  $L(X_0, \dots, X_k)$  равна  $k + 1$ . Но тогда размерность подпространства  $L^\perp$  равна  $n - k - 1$ . Выберем в подпространстве  $L^\perp$  ортонормированный базис  $l_1, \dots, l_{n-k-1}$ . Пусть  $l = (l_1, \dots, l_{n-k-1})$ . Тогда вектор  $\hat{\varepsilon}$  единственным образом представим в базисе  $l$ :

$$\hat{\varepsilon} = \sum_{r=1}^{n-k-1} \eta_r l_r = l \eta,$$

где  $\eta^T = (\eta_1, \dots, \eta_{n-k-1})$ .

Очевидно, что

$$\eta = l^T \hat{\varepsilon}.$$

В силу второй группы предположений вектор  $\hat{\varepsilon}$  подчиняется многомерному нормальному распределению, но тогда  $\eta$  также подчиняется многомерному нормальному распределению в виду линейности преобразования.

Нетрудно увидеть, что  $E\eta = I^T E\hat{\varepsilon} = 0$ ,

$$D\eta = I^T D\hat{\varepsilon}I = \sigma^2 I^T P^\perp I = \sigma^2 I^T I = \sigma^2 E_{n-k-1},$$

так как  $P^\perp$  матрица ортогонального проектирования на  $L^\perp$ , но все  $l_i \in L^\perp$ ,  $i = 1, \dots, n - k - 1$ . Кроме того,

$$\hat{\varepsilon}^T \hat{\varepsilon} = \eta^T I^T I \eta = \eta^T \eta.$$

Следовательно, статистики  $\hat{\varepsilon}^T \hat{\varepsilon} / \sigma^2$  и  $\eta^T \eta / \sigma^2$  распределены одинаково, но из определения распределения  $\chi^2$  получаем, что статистика  $\eta^T \eta / \sigma^2$  подчиняется распределению  $\chi^2$  с  $n - k - 1$  степенями свободы.

## Лемма 2

Пусть выполнены предположения первой и второй групп, тогда справедливы утверждения:

- ① Вектор оценок  $\hat{\beta}$  подчиняется многомерному нормальному распределению,  $\hat{\beta} \sim N(\beta, \sigma^2(X^T X)^{-1})$ .
- ② Статистика  $(n - k - 1)S^2/\sigma^2$  подчиняется распределению  $\chi^2$  с  $(n - k - 1)$  степенями свободы и взаимно независима с вектором оценок  $\hat{\beta}$ .

## Доказательство

Первое утверждение сразу следует из линейности явного выражения  $\hat{\beta}$  и второй группы предположений:

$$\hat{\beta} = (X^T X)^{-1} X^T Y,$$

линейное преобразование не меняет тип нормального распределения.

Вектор математических ожиданий и дисперсионная матрица были вычислены ранее. Второе утверждение следует из леммы 1 и того факта, что  $E\{(\hat{\beta} - \beta)\hat{\varepsilon}^T\} = 0$ .

Действительно, как нетрудно заметить

$$\begin{pmatrix} \hat{\beta} \\ \hat{\varepsilon} \end{pmatrix} = \begin{pmatrix} (X^T X)^{-1} X^T \\ P^\perp \end{pmatrix} Y.$$

Следовательно, вектор  $(\hat{\beta}^T, \hat{\varepsilon}^T)$  подчиняется многомерному нормальному распределению, но тогда вектора  $\hat{\beta}$  и  $\hat{\varepsilon}$  взаимно независимы.



## Построение доверительных интервалов и проверка статистических гипотез

При выполнении всех условий из первой и второй групп предположений регрессионного анализа справедлива лемма 2 предыдущего параграфа, из которой сразу следует, что статистика

$$\frac{\widehat{\beta}_j - \beta_j}{S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}}} \sim T_{n-k-1}, \quad j = 0, \dots, k, \quad (11)$$

где  $[(X^T X)^{-1}]_{(j+1)(j+1)}$  — элемент стоящий на главной диагонали в строке  $j + 1$  и столбце  $j + 1$  матрицы  $(X^T X)^{-1}$ , распределение  $T_{n-k-1}$  — распределение Стьюдента с  $n - k - 1$  степенями свободы.

Доказательство следует из определения распределения Стьюдента и леммы 2.

Из формулы (11) следует формула для доверительного интервала с уровнем доверия  $1 - \alpha$  для любого параметра  $\beta_j, j = 0, 1, \dots, k$ .

Доверительный интервал имеет вид:

$$P \left\{ \hat{\beta}_j - t_{1-\frac{\alpha}{2}, n-k-1} S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}} < \beta_j < \right. \\ \left. < \hat{\beta}_j + t_{1-\frac{\alpha}{2}, n-k-1} S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}} \right\} = 1 - \alpha,$$

где  $t_{1-\frac{\alpha}{2}, n-k-1}$  — квантиль уровня  $1 - \frac{\alpha}{2}$  распределения Стьюдента  $T_{n-k-1}$ .

Важное значение имеет проверка гипотез статистической значимости найденных оценок  $\hat{\beta}_j$ ,  $j = 0, 1, \dots, n$ .

Если доверительный интервал для параметра  $\beta_j$  с уровнем доверия  $1 - \alpha$  содержит нуль, т. е. если концы доверительного интервала имеют разный знак, то нельзя отклонить гипотезу  $H_0: \beta_j = 0$ , следовательно, в этом случае найденная оценка  $\hat{\beta}_j$  не может быть признана статистически значимой на уровне значимости  $\alpha$ .

Отсюда следует правило проверки статистической значимости оценки  $\hat{\beta}_j$  или, что тоже самое, правило проверки гипотезы  $H_0: \beta_j = 0$ .

Выберем уровень значимости  $\alpha$  и вычислим статистику

$$t_{\beta_j} = \frac{\hat{\beta}_j}{S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}}.$$

Если  $|t_{\beta_j}| > t_{1-\frac{\alpha}{2}, n-k-1}$ , то гипотеза  $H_0$  отклоняется, и оценка  $\hat{\beta}_j$  признается статистически значимой на уровне значимости  $\alpha$ .

Если  $|t_{\beta_j}| \leq t_{1-\frac{\alpha}{2}, n-k-1}$ , то гипотеза  $H_0$  не отклоняется, и оценка  $\hat{\beta}_j$  признается статистически незначимой на уровне значимости  $\alpha$ .

Нетрудно аналогичным образом проверить более общую гипотезу вида  $H_0: \beta_j = \beta_j^{(0)}$ . Рассуждая таким же образом, получаем правило проверки гипотезы  $H_0$  на уровне значимости  $\alpha$ :

- Если  $\frac{|\hat{\beta}_j - \beta_j^{(0)}|}{S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}} > t_{1-\frac{\alpha}{2}, n-k-1}$ , то гипотеза  $H_0: \beta_j = \beta_j^{(0)}$  отклоняется на уровне значимости  $\alpha$ .
- Если  $\frac{|\hat{\beta}_j - \beta_j^{(0)}|}{S \sqrt{[(X^T X)^{-1}]_{(j+1)(j+1)}} \leq t_{1-\frac{\alpha}{2}, n-k-1}$ , то гипотеза  $H_0: \beta_j = \beta_j^{(0)}$  принимается на уровне значимости  $\alpha$ .

В линейном регрессионном анализе коэффициентом детерминации  $R^2$  называется квадрат коэффициента корреляции между наблюдаемыми значениями показателя  $Y^T = (y_1, \dots, y_n)$  и значениями эмпирической функции  $\hat{Y}^T = (\hat{y}_1, \dots, \hat{y}_n)$ .

Так как  $X_0^T = (1, \dots, 1)$  и  $\hat{Y} = PY$ , причем,  $P$  — матрица ортогонального проектирования на подпространство  $L(X_0, \dots, X_n)$ , то  $PX_0 = X_0$  или  $X_0^T = X_0^T P$ .

Но тогда

$$X_0^T \hat{Y} = X_0^T P Y = X_0^T Y$$

или

$$\sum_{j=1}^n \hat{y}_j = \sum_{i=1}^n y_i,$$

следовательно,

$$\bar{\hat{y}} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i = \frac{1}{n} \sum_{i=1}^n y_i = \bar{y}.$$

По определению

$$R^2 = \frac{\left(\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{y})\right)^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{y})^2} = \frac{((Y - \bar{y}X_0)^T (\hat{Y} - \bar{y}X_0))^2}{(Y - \bar{y}X_0)^T (Y - \bar{y}X_0) (\hat{Y} - \bar{y}X_0)^T (\hat{Y} - \bar{y}X_0)}$$

Заметим, что

$$\begin{aligned} (Y - \bar{y}X_0)^T (\hat{Y} - \bar{y}X_0) &= ((Y - \hat{Y}) + (\hat{Y} - \bar{y}X_0))^T (\hat{Y} - \bar{y}X_0) = \\ &= (\hat{Y} - \bar{y}X_0)^T (\hat{Y} - \bar{y}X_0), \end{aligned}$$

так как вектор  $Y - \hat{Y} \in L^\perp$ , а  $\hat{Y} - \bar{y}X_0 \in L(X_0, \dots, X_k)$  и, следовательно, вектора  $Y - \hat{Y}$  и  $\hat{Y} - \bar{y}X_0$  ортогональны, т.е.

$$(Y - \hat{Y})^T (\hat{Y} - \bar{y}X_0) = 0.$$

Но тогда

$$R^2 = \frac{(\hat{Y} - \bar{y}X_0)^T(\hat{Y} - \bar{y}X_0)}{(Y - \bar{y}X_0)^T(Y - \bar{y}X_0)} = 1 - \frac{\hat{\varepsilon}^T \hat{\varepsilon}}{(Y - \bar{y}X_0)^T(Y - \bar{y}X_0)}. \quad (12)$$

Для доказательства последнего равенства заметим, что

$$\begin{aligned} (\hat{Y} - \bar{y}X_0)^T(\hat{Y} - \bar{y}X_0) &= \\ &= ((\hat{Y} - Y) + (Y - \bar{y}X_0))^T((\hat{Y} - Y) + (Y - \bar{y}X_0)) = \\ &= (-\hat{\varepsilon} + (Y - \bar{y}X_0))^T(-\hat{\varepsilon} + (Y - \bar{y}X_0)) = \\ &= -\hat{\varepsilon}^T \hat{\varepsilon} + (Y - \bar{y}X_0)^T(Y - \bar{y}X_0), \end{aligned}$$

в виду того, что

$$\hat{\varepsilon}^T(Y - \bar{y}X_0) = \hat{\varepsilon}^T Y - \bar{y} \hat{\varepsilon}^T X_0 = \hat{\varepsilon}^T(Y - \hat{Y}) + \hat{\varepsilon}^T \hat{Y} - \bar{y} \hat{\varepsilon}^T X_0 = \hat{\varepsilon}^T \hat{\varepsilon},$$

так как  $\hat{\varepsilon} \in L^\perp$ ,  $\hat{Y} \in L(X_0, \dots, X_k)$ ,  $X_0 \in L(X_0, \dots, X_k)$ .

Равенство (12) удобно в вычислительном отношении, кроме того, из него видно, что, если построенная линейная регрессия идеально точно соответствует наблюдениям, то  $Y = \hat{Y}$  и, следовательно,  $\hat{\varepsilon} = 0$ , но тогда  $R^2 = 1$ .

Наоборот, если  $\hat{\beta}_1 = \dots = \hat{\beta}_k = 0$ , т.е. линейная регрессия не зависит от  $x_1, \dots, x_k$ , то  $R^2 = 0$ . Из определения коэффициента детерминации  $R^2$  сразу следует, что  $0 \leq R^2 \leq 1$ .

Наиболее важным применением коэффициента  $R^2$  является его использование при проверке гипотезы статистической значимости линейной регрессионной модели в целом, т.е. при проверке гипотезы  $H_0: \beta_1 = \dots = \beta_k = 0$ . Если указанную гипотезу  $H_0$  нельзя отвергнуть на уровне значимости  $\alpha$ , то это означает, что на уровне значимости  $\alpha$  построенная линейная регрессия статистически незначима. Малые значения  $R^2$  свидетельствуют против статистической значимости построенной линейной регрессии.

## Лемма 3

Пусть выполнены обе группы основных предположений линейного регрессионного анализа, тогда в предположении справедливости гипотезы  $H_0: \beta_1 = \dots = \beta_k = 0$  статистика

$$F = \frac{R^2}{1 - R^2} \frac{n - k - 1}{k} \sim \mathcal{F}_{k, n-k-1}$$

подчиняется распределению Фишера со степенями свободы  $k$  и  $n - k - 1$ .

*Доказательство*

Очевидно, что

$$\frac{R^2}{1 - R^2} = \frac{(\hat{Y} - \bar{y}X_0)^T (\hat{Y} - \bar{y}X_0)}{\hat{\varepsilon}^T \hat{\varepsilon}}.$$

При доказательстве леммы 2 было показано, что вектора  $\hat{\beta}$  и  $\hat{\varepsilon}$  взаимно независимы, так как  $\hat{Y} = X\hat{\beta}$ , и  $\bar{y} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i$ , то числитель и знаменатель дроби взаимно независимы.



Кроме того, уже было ранее показано, что статистика

$$\frac{(n - k - 1)S^2}{\sigma^2} = \frac{1}{\sigma^2} \hat{\varepsilon}^T \hat{\varepsilon} \sim \chi_{n-k-1}^2$$

подчиняется распределению  $\chi^2$  с  $n - k - 1$  степенями свободы.

Найдем распределение числителя в предположении справедливости гипотезы  $H_0: \beta_1 = \dots = \beta_k = 0$ . Заметим, что

$$\hat{Y} = PY = X\beta + P\varepsilon = \beta_0 X_0 + P\varepsilon,$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i = \beta_0 + \frac{1}{n} X_0^T P\varepsilon = \beta_0 + \frac{1}{n} X_0^T \varepsilon$$

Тогда

$$\hat{Y} - \bar{y}X_0 = P\varepsilon - \frac{1}{n} X_0^T \varepsilon X_0 = P\varepsilon - \bar{\varepsilon} P X_0 = P(\varepsilon - \bar{\varepsilon} X_0),$$

где  $\bar{\varepsilon} = \frac{1}{n} \sum_{i=1}^n \varepsilon_i$ ,  $X_0 = P X_0$ .

Как видим

$$\eta = \hat{Y} - \bar{y}X_0 = P(E_n - \frac{1}{n}T_n)\varepsilon, \quad (13)$$

где  $T_n = X_0X_0^T$  — квадратная матрица порядка  $n \times n$ , все элементы которой являются единицами. Нетрудно заметить, что  $\eta \in L(X_0, \dots, X_k)$ , кроме того, вектор  $\eta$  ортогонален вектору  $X_0$ , следовательно,  $\eta \in L(\tilde{X}_1, \dots, \tilde{X}_k)$ , где базисные вектора определяются следующими равенствами

$$\tilde{X}_r = X_r - \bar{x}_r X_0, \quad \bar{x}_r = \sum_{i=1}^n x_{ir}/n.$$

Нетрудно убедиться, что все вектора  $\tilde{X}_r$  ортогональны вектору  $X_0$ , следовательно, вектор  $X_0$  ортогонален подпространству  $L(\tilde{X}_1, \dots, \tilde{X}_k)$ . Кроме того, из (13) следует, что вектор  $\eta$  подчиняется многомерному нормальному распределению,  $E\eta = 0$ .

Нетрудно проверить, что матрица  $P_1 = P(E_n - T_n/n)$  — матрица ортогонального проектирования на подпространство  $L(\tilde{X}_1, \dots, \tilde{X}_k)$ .

Вектор  $\eta = P_1\varepsilon$ , следовательно,  $D\eta = \sigma^2 P_1$ .

Все свойства, которые были сформулированы для матрицы  $P$ , выполняются и для матрицы  $P_1$ . Выберем в подпространстве  $L(\tilde{X}_1, \dots, \tilde{X}_k)$  ортонормированный базис  $d = (d_1, \dots, d_k)$ , тогда

$$\eta = \sum_{r=1}^k \xi_r d_r = d\xi, \quad \xi = d^T \eta,$$

$$\xi = (\xi_1, \dots, \xi_k)^T \sim N(0, \sigma^2 E_k),$$

так как

$$D\xi = E\{(d^T \eta)(\eta^T d)\} = \sigma^2 d^T P_1 P_1 d = \sigma^2 d^T d = \sigma^2 E_k.$$

Кроме того,

$$\eta^T \eta = \xi^T d^T d \xi = \xi^T \xi.$$

Следовательно, распределения левой и правой частей совпадают. Но тогда из определения распределения  $\chi^2$  получаем, что статистика

$$\frac{1}{\sigma^2}(\hat{Y} - \bar{y}X_0)^T(\hat{Y} - \bar{y}X_0) \sim \chi_k^2$$

подчиняется распределению  $\chi^2$  с  $k$  степенями свободы.

Построенная линейная регрессия статистически значима на уровне  $\alpha$  тогда и только тогда, когда гипотеза  $H_0: \beta_1 = \dots = \beta_k = 0$  отклоняется на уровне значимости  $\alpha$ . Поэтому правило проверки статистической значимости линейной регрессии в целом сформулируем следующим образом:

- Если  $F = \frac{R^2}{1-R^2} \frac{n-k-1}{k} > F_{1-\alpha; k, n-k-1}$ , то гипотеза  $H_0: \beta_1 = \dots = \beta_k = 0$  отклоняется на уровне значимости  $\alpha$  и, следовательно, построенная линейная регрессия является статистически значимой.
- Если  $F \leq F_{1-\alpha; k, n-k-1}$ , то гипотеза  $H_0$  принимается, и, следовательно, построенная линейная регрессия является статистически незначимой, здесь  $F_{1-\alpha; k, n-k-1}$  — квантиль уровня  $1 - \alpha$  распределения Фишера с  $k$  и  $n - k - 1$  степенями свободы.

## Нелинейные регрессионные модели, сводящиеся к линейным при помощи замены переменных

Регрессионная модель от  $k$  факторов и  $l$  параметров может быть записана в виде  $y = f(x_1, \dots, x_k, \beta_1, \dots, \beta_l)$ . Среди них есть нелинейные как по факторам, так и по параметрам. Существуют нелинейные модели, которые путем преобразований могут быть приведены к линейным. Преобразования применяются как к отклику, так и к факторам.

- *Обратное преобразование:*  $Y = \beta_0 + \beta_1(1/X) + \varepsilon$ .  
Замена  $Z = 1/X$ .
- *Логарифмическое преобразование:*  $Y = \beta_0 + \beta_1 \ln X + \varepsilon$ .  
Замена  $Z = \ln X$ .
- *Преобразование типа квадратного корня:*  $Y = \beta_0 + \beta_1 \sqrt{X} + \varepsilon$ .  
Замена  $Z = \sqrt{X}$ .

- *Мультипликативная модель:*  $Y = \alpha X^\beta \varepsilon$ .  
 $\alpha, \beta$  — неизвестные параметры,  $\varepsilon$  — мультипликативная случайная ошибка, которая имеет непрерывное распределение с математическим ожиданием, равным 1, и конечной дисперсией.

$$\ln Y = \ln \alpha + \beta \ln X + \ln \varepsilon.$$

Следует помнить, что оценки границ доверительных интравлов будут обоснованными, только если логарифм ошибок имеет нормально распределение:  $\ln \varepsilon \in N(0, \sigma^2)$ . Замена  $Z = \sqrt{X}$ .

- *Экспоненциальная модель:*  $Y = \alpha e^{\beta_1 X} \varepsilon$ .

$$\ln Y = \ln \alpha + \beta_1 X + \ln \varepsilon.$$

- *Обратная модель:*  $Y = \frac{1}{\beta_0 + \beta_1 X + \varepsilon}$ .

$$1/Y = \beta_0 + \beta_1 X + \varepsilon.$$

- Обратная экспоненциальная модель:  $Y = \frac{1}{1 + \alpha e^{\beta_1 X + \varepsilon}}$ .

$$\ln(1/Y - 1) = \ln \alpha + \beta_1 X + \varepsilon.$$

При использовании преобразований, особенно отклика, следует проверять предпосылки регрессионного анализа: независимость ошибок, нормальность их распределений.