

# Спецкурс "Регрессия"

Шкляев А.В.

15 января 2019 г.

## 0.1 Гипотеза в параметрическом виде

Предположим, что в линейной модели  $\vec{Y} = X\vec{a} + \vec{\varepsilon}$  мы проверяем гипотезу  $H_0 : C\vec{a} = \vec{r}$ , где  $C$  — заданная матрица  $m \times k$  полного ранга,  $k \leq m$ ,  $\vec{r}$  — заданный вектор.

Распишем разность

$$\|\vec{Y} - X\vec{a}\|^2 = \|\vec{Y} - X\tilde{a}\|^2 + 2\langle \vec{Y} - X\tilde{a}, X(\tilde{a} - \vec{a}) \rangle + \|X(\tilde{a} - \vec{a})\|^2,$$

где  $\vec{a}$  — произвольный вектор, такой что  $C\vec{a} = \vec{r}$ , а  $C\tilde{a} = \vec{r}$  — искомый минимум. Тогда нам достаточно подобрать такое  $\tilde{a}$ , что  $\langle X^t(\vec{Y} - X\tilde{a}), \vec{b} \rangle = 0$  при всех  $\vec{b} : C\vec{b} = 0$ . При этом  $X^t\vec{Y} - X^tX\hat{a} = 0$ , где  $\hat{a}$  — оценка МНК для общей задачи, откуда вектор  $X^tX(\hat{a} - \tilde{a})$  должен быть ортогонален всем векторам  $\vec{b} : C\vec{b} = 0$ . Естественно потребовать

$$X^tX(\hat{a} - \tilde{a}) = C^t\vec{u}$$

при некотором  $\vec{u}$ . Тогда

$$(\hat{a} - \tilde{a}) = (X^tX)^{-1}C^t\vec{u}, \quad C(\hat{a} - \tilde{a}) = C(X^tX)^{-1}C^t\vec{u} = C\hat{a} - \vec{r}.$$

Отсюда

$$\vec{u} = C(X^tX)^{-1}C^t)^{-1}(C\hat{a} - \vec{r}), \quad \tilde{a} = \hat{a} - (X^tX)^{-1}C^t(C(X^tX)^{-1}C^t)^{-1}(C\hat{a} - \vec{r}) \quad (1)$$

При этом

$$\|\vec{Y} - X\tilde{a}\|^2 = \|\vec{Y} - X\hat{a}\|^2 + \|X(\hat{a} - \tilde{a})\|^2, \quad (2)$$

где

$$\|X(\hat{a} - \tilde{a})\|^2 = (\hat{a} - \tilde{a})^t X^tX(\hat{a} - \tilde{a}) = (C\hat{a} - \vec{r})^t (C(X^tX)^{-1}C^t)^{-1} (C\hat{a} - \vec{r}) \quad (3)$$

где в последнем равенстве мы воспользовались формулой (1).

Таким образом, оценка в рассматриваемой задаче принимает вид (1) (ее также иногда называют обобщенной оценкой наименьших квадратов), а остаточная сумма квадратов для этой оценки имеет вид (2).

## 0.2 Снижение размерности

Предположим, что мы рассматриваем гипотезу  $H_0 : \vec{a}_1 = \dots = \vec{a}_k = 0$  о том, что часть коэффициентов можно убрать. Тогда

$$C = \begin{pmatrix} 1 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 & 0 & \dots & 0 \\ & & \dots & & & & \\ 0 & 0 & \dots & 1 & 0 & \dots & 0 \end{pmatrix},$$

$\vec{r} = (0, \dots, 0)$ . Следовательно, для расстояния до пространства, заданного при гипотезе, можно записать выражение.

$$\|X(\hat{a} - \tilde{a})\|^2 = \hat{a}^t C^t (C^t (X^t X)^{-1} C^t)^{-1} C \hat{a}$$

Матрица  $C^t (X^t X)^{-1} C$  представляет собой квадратную матрицу  $k \times k$ , представляющей верхний левый угол матрицы  $(X^t X)^{-1}$ . Для ее обращения мы воспользуемся следующей леммой

**Лемма 1.** Пусть

$$D = \begin{pmatrix} G & B \\ B^t & F \end{pmatrix},$$

где  $G, F$  — симметричные матрицы  $k \times k$  и  $(m - k) \times (m - k)$ ,  $B$  — матрица  $k \times (m - k)$ . Тогда

$$D^{-1} = \begin{pmatrix} H^{-1} & C \\ C^t & K \end{pmatrix},$$

где  $H = G - BF^{-1}B^t$ ,  $K$  — некоторая симметрическая матрица  $(m - k) \times (m - k)$ ,  $C$  — некоторая матрица  $k \times (m - k)$ .

*Доказательство.* По существу вопрос только в том, почему верхний угол  $L$  матрицы  $D^{-1}$  имеет такой вид. Запишем условие  $DD^{-1} = E$ :

$$GL + BC^t = E_k, \quad GC + BK = 0, \quad B^t L + FC^t = 0, \quad B^t C + FK = E_{m-k}.$$

Отсюда  $C^t = -F^{-1}B^t L$ ,  $GL - BF^{-1}B^t L = HL = E_k$ , откуда  $L = H^{-1}$ , что и требовалось доказать.  $\square$

**Замечание 1.** Можно указать явный вид  $C = -H^{-1}BF^{-1}$ ,  $K = F^{-1}(E - B^t H^{-1}BF^{-1})$  и получить предыдущее утверждение простым перемножением матриц.

Таким образом,  $C^t (X^t X)^{-1} C = H^{-1}$ , откуда

$$H = (C^t (X^t X)^{-1} C)^{-1} = (G - BF^{-1}B^t)^{-1},$$

где  $G = X_1^t X_1$ ,  $B = X_1^t X_2$ ,  $F = X_2^t X_2$ , где  $X_1 = (X_{\cdot,1}, \dots, X_{\cdot,k})$ ,  $X_2 = (X_{\cdot,k+1}, \dots, X_{\cdot,m})$ . Следовательно,

$$\|X(\hat{a} - \tilde{a})\|^2 = \hat{a}_{1:k}^t (G - BF^{-1}B^t) \hat{a}_{1:k} = \hat{a}_{1:k}^t X_1^t (E - X_2 (X_2^t X_2)^{-1} X_2^t) X_1 \hat{a}_{1:k},$$

где  $\hat{a}_{1:k} = (\hat{a}_1, \dots, \hat{a}_k)$ . Таким образом,

$$D_{0,1} = \hat{a}_{1:k}^t X_1^t X_1 \hat{a}_{1:k} - \hat{a}_{1:k}^t X_1^t X_2 (X_2^t X_2)^{-1} X_2^t X_1 \hat{a}_{1:k}, \quad D_1 = \vec{Y}^t (E - X (X^t X)^{-1} X^t) \vec{Y}.$$

Таким образом, критерий приобретает вид

$$\frac{(\hat{a}_{1:k}^t X_1^t X_1 \hat{a}_{1:k} - \hat{a}_{1:k}^t X_1^t X_2 (X_2^t X_2)^{-1} X_2^t X_1 \hat{a}_{1:k}) / k}{\vec{Y}^t (E - X (X^t X)^{-1} X^t) \vec{Y} / (n - m)} > f_{1-\alpha},$$

где  $f$  — квантиль  $F_{k, n-m}$ .

В частности, удобный вид критерий приобретает в случае ортогональных блоков предикторов, когда  $X_1$  ортогонально  $X_2$ . В этом случае  $D_{0,1} = \hat{a}_{1:k}^t X_1^t X_1 \hat{a}_{1:k}$ .

Еще одним удобным случаем является случай  $k = 1$ , когда

$$D_{0,1} = \hat{a}_1^2 \left( \sum_{i=1}^n X_{1,i}^2 - X_1^t X_2 (X_2^t X_2)^{-1} X_2^t X_1 \right).$$

При  $k = m - 1$

$$D_{0,1} = \hat{a}_{1:m-1}^t X_1^t \left( E - \frac{1}{\sum_{l=1}^n x_{m,l}^2} (x_{m,i} x_{m,j}, i, j \leq n) \right) X_1 \hat{a}_{1:m-1}, \quad R^2 = \frac{D_{0,1}}{D_0} = \frac{D_{0,1}}{\sum_{i=1}^n (y_i - \bar{y})^2}.$$

### 0.3 Последовательный спуск

Можно представлять себе регрессию следующим образом

1. Берем  $Z_{\cdot,1} = X_{\cdot,1}$ .
2. При каждом  $j$  осуществляем регрессию  $X_{\cdot,j}$  на  $Z_{\cdot,1}, \dots, Z_{\cdot,j-1}$  и получаем коэффициенты

$$\hat{\gamma}_{i,j} = \frac{\langle X_{\cdot,j}, Z_{\cdot,i} \rangle}{\langle Z_{\cdot,i}, Z_{\cdot,i} \rangle}$$

и вектор остатков  $Z_{\cdot,j} = X_{\cdot,j} - \sum_{i=1}^{j-1} \hat{\gamma}_{i,j} Z_{\cdot,i}$ .

3. Осуществляем регрессию  $y$  на  $z_p$ , находя коэффициент  $\hat{\beta}_m = \langle z_m, y \rangle / \langle z_m, z_m \rangle$ .

При этом коэффициент  $\hat{\beta}_m$  совпадает с коэффициентом разложения  $Y$  по  $X_{\cdot,m}$ .