

# Спецкурс "Регрессия"

Шкляев А.В.

15 января 2019 г.

## 1 Простая линейная регрессия для нормальной модели

### 1.1 Оценка для $y$

Напомню, что мы рассматриваем модель  $y_i = ax_i + b + \varepsilon_i$ , где  $\varepsilon_i$  н.о.р.  $\mathcal{N}(0, \sigma^2)$ . Мы получили оценки максимального правдоподобия

$$\hat{a} = \frac{\overline{xy} - \bar{y}\bar{x}}{\overline{x^2} - \bar{x}^2}, \quad \hat{b} = \bar{y} - \hat{a}\bar{x}, \quad \hat{\sigma}^2 = \overline{(y - \hat{a}x - \hat{b})^2}$$

и показали, что

$$(\hat{a}, \hat{b}) \sim \mathcal{N}\left((a, b), \frac{\sigma^2}{nS_x^2}\Sigma\right), \quad \Sigma = \begin{pmatrix} 1 & -\bar{x} \\ -\bar{x} & \overline{x^2} \end{pmatrix}.$$

Разберемся с распределением  $\hat{\sigma}^2$ . Для этого нам понадобится следующее утверждение:

**Лемма 1.** Пусть  $\vec{Z} = (Z_1, \dots, Z_n) \sim \mathcal{N}(0, \sigma^2 E)$ ,  $L$  — некоторое подпространство размерности  $m$  в  $\mathbb{R}^n$ ,  $L^\perp$  — его ортогональное дополнение. Пусть  $U = \text{proj}_L \vec{Z}$ ,  $V = \text{proj}_{L^\perp} \vec{Z}$ . Тогда  $U$ ,  $V$  независимы,  $\|U\|^2/\sigma^2 \sim \chi_m^2$ ,  $\|V\|^2/\sigma^2 \sim \chi_{n-m}^2$ .

*Доказательство.* Рассмотрим такую ортонормированную систему координат, что первые  $m$  базисных векторов образуют базис  $L$ , а остальные — базис  $L^\perp$ . Тогда в новых координатах вектор  $Z$  будем иметь вид  $W = CZ$ , где  $C$  — матрица перехода от исходного базиса к новому. Таким образом, вектор  $W$  также имеет распределение  $\mathcal{N}(0, \sigma^2 E)$ , поскольку  $C$  — ортогональная матрица.

Следовательно, векторы  $\tilde{U} = (W_1, \dots, W_m, 0, 0, \dots, 0)$  и  $\tilde{V} = (0, \dots, 0, W_{m+1}, \dots, W_n)$  независимы и квадраты их длин являются  $\chi_m^2$  и  $\chi_{n-m}^2$  случайными величинами. Однако, тогда  $U = C^{-1}\tilde{U}$ ,  $V = C^{-1}\tilde{V}$  независимы, а их квадраты длин в точности совпадают с квадратами длин  $U$  и  $V$ .  $\square$

Теперь заметим, что поскольку оценки  $\hat{a}$ ,  $\hat{b}$  минимизируют

$$\sum_{i=1}^n (y_i - ax_i - b)^2,$$

то  $(\hat{a}x_1 + \hat{b}, \dots, \hat{a}x_n + \hat{b})$  — это проекция  $(y_1, \dots, y_n)$  на двумерное подпространство  $L$ , порожденное векторами  $(1, 1, \dots, 1)$ ,  $(x_1, \dots, x_n)$ . При этом вектор  $Y_1, \dots, Y_n$  имеет распределение  $\mathcal{N}(a\vec{x} + b, \sigma^2 E)$ , а значит проекция  $\vec{Y}$  на  $L^\perp$  совпадает с проекцией  $\vec{Y} - a\vec{x} - b$  на  $L^\perp$ . В силу Леммы 1 квадрат длины этой проекции

$$RSS = \sum_{i=1}^n (y_i - \hat{a}x_i - \hat{b})^2$$

при делении на  $\sigma^2$  имеет  $\chi_{n-2}^2$  распределение.

Итак,

$$\frac{n\widehat{\sigma}^2}{\sigma^2} \sim \chi_{n-2}^2.$$

Более того, в силу леммы RSS не зависит от пары  $(\widehat{a}, \widehat{b})$ , являющейся координатами проекции  $\vec{Y}$  на  $L$ . Тем самым, мы можем утверждать, что

$$\sqrt{n}S_x \frac{\widehat{a} - a}{\widehat{\sigma}\sqrt{n/(n-2)}} \sim t_{n-2}, \quad \frac{\sqrt{n}S_x}{\sqrt{x^2}} \frac{\widehat{b} - b}{\widehat{\sigma}\sqrt{n/(n-2)}} \sim t_{n-2},$$

откуда имеем доверительные интервалы

$$a \in \left( \widehat{a} + t_{\alpha/2}\widehat{\sigma}\sqrt{\frac{S_x^2}{n-2}}, \widehat{a} + t_{1-\alpha/2}\widehat{\sigma}\sqrt{\frac{S_x^2}{n-2}} \right), \quad b \in \left( \widehat{b} + t_{\alpha/2}\widehat{\sigma}\sqrt{\frac{S_x^2}{(n-2)x^2}}, \widehat{b} + t_{1-\alpha/2}\widehat{\sigma}\sqrt{\frac{S_x^2}{(n-2)x^2}} \right).$$

## 1.2 Нормальная модель: прогноз

Осуществим на основе наших наблюдений прогноз  $\widehat{y}_*$  значения  $y_*$  в точке  $x_*$ , которой не было среди  $x_i$ . Естественным образом, зададим оценку соотношением  $\widehat{y}_* = \widehat{a}x_* + \widehat{b}$ . Тогда  $y_*$  имеет нормальное распределение с параметрами

$$m_* = ax_* + b, \quad \sigma_*^2 = x_*^2 \mathbf{D}\widehat{a} + \mathbf{D}\widehat{b} + 2x_* \text{cov}(\widehat{a}, \widehat{b}) = \frac{\sigma^2}{nS_x^2} \left( x_*^2 - 2x_*\bar{x} + \bar{x}^2 \right) = \frac{\sigma^2}{nS_x^2} \left( \frac{1}{n} \sum_{i=1}^n (x_i - x_*)^2 \right).$$

Соответственно, погрешность прогноза по сравнению с реальными данными будет иметь распределение

$$\mathcal{N} \left( 0, \sigma^2 \left( \frac{\sum_{i=1}^n (x_i - x_*)^2}{n^2 S_x^2} + 1 \right) \right).$$

При этом  $\widehat{y}_*$  есть функция от  $\widehat{a}$ ,  $\widehat{b}$  и  $x_i$ , а значит не зависит от RSS. Тем самым, можно заметить, что

$$\frac{\widehat{y}_* - y_*}{\sqrt{\frac{RSS}{(n-2)} \left( \frac{\sum_{i=1}^n (x_i - x_*)^2}{n^2 S_x^2} + 1 \right)}} \sim t_{n-2},$$

откуда мы можем построить доверительный интервал

$$y_* \in \left( \widehat{y}_* + t_{\alpha/2} \sqrt{\frac{RSS}{(n-2)} \left( \frac{\sum_{i=1}^n (x_i - x_*)^2}{n^2 S_x^2} + 1 \right)}, \widehat{y}_* + t_{1-\alpha/2} \sqrt{\frac{RSS}{(n-2)} \left( \frac{\sum_{i=1}^n (x_i - x_*)^2}{n^2 S_x^2} + 1 \right)} \right).$$

## 1.3 Множественная регрессия в нормальной модели

Обобщим задачу, рассмотренную в предыдущем разделе. Пусть

$$\begin{cases} Y_1 = a_1 X_{1,1} + \dots + a_m X_{1,m} + \varepsilon_1, \\ Y_2 = a_1 X_{2,1} + \dots + a_m X_{2,m} + \varepsilon_2, \\ \dots \\ Y_n = a_1 X_{n,1} + \dots + a_m X_{n,m} + \varepsilon_n, \end{cases}$$

где  $a_1, \dots, a_m$  — неизвестные коэффициенты,  $\varepsilon_j$  — случайные величины, являющиеся условно независимыми и одинаково распределенными  $\mathcal{N}(0, \sigma^2)$  при условии  $X_{1,1} = x_{1,1}, \dots, X_{n,m} = x_{n,m}$ . Как и прежде, эти условия позволяют нам рассматривать  $x_{i,j}$  как константы. Мы будем предполагать, что матрица  $X$  имеет линейно независимые столбцы.

Как и в предыдущем случае мы можем выписать функцию правдоподобия

$$L(y_1, \dots, y_n; a_1, \dots, a_m, \sigma^2) = \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n \exp \left( -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \langle \vec{a}, X_{i,\cdot} \rangle)^2 \right)$$

и максимизировать ее для поиска ОМП. Задача разбивается на две части:

1) Поиск наилучшего вектора  $\vec{a}$ .

Мы ищем вектор  $\vec{a}$  такой, что  $\|y - X\vec{a}\|$  минимально.

2) Поиск  $\sigma^2$  так, чтобы  $\ln L$  было максимально.

Мы ищем  $\sigma^2$  такое, что

$$\ln L = -\frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \langle \vec{a}, X_{i,\cdot} \rangle)^2 + n \ln \sigma.$$

Вторая задача достаточно стандартна, дифференцированием мы получаем ответ

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \langle \vec{a}, X_{i,\cdot} \rangle)^2$$

Остается найти оценку  $\vec{a}$ . Это задача поиска ближайшего к  $\vec{y}$  вектора в плоскости  $X_{\cdot,1}a_1 + \dots + X_{\cdot,m}a_m$ .

Здесь  $X_{\cdot,i}$  — базис в указанной плоскости, а  $a_i$  — коэффициенты разложения по этому базису.

Наилучшие  $(a_1, \dots, a_m)$  определяются тем, что разность  $\vec{y}$  и  $X\vec{a}$  есть перпендикуляр к плоскости:

$$(\vec{y} - X\vec{a}, X_{\cdot,i}) = 0$$

Иначе говоря,

$$X^t \vec{y} = (X^t X) \vec{a}.$$

Таким образом,  $\vec{a}$  определяется как

$$(X^t X)^{-1} X^t \vec{y}.$$

**Пример 1.** Простая линейная регрессия соответствует случаю множественной регрессии с матрицей  $X$  вида  $X_{i,1} = x_i$ ,  $X_{i,2} = 1$ . Соответственно,

$$X^t X = \begin{pmatrix} \sum_{i=1}^n x_i^2 & \sum_{i=1}^n x_i \\ \sum_{i=1}^n x_i & 1 \end{pmatrix}.$$

Обратная матрица будет иметь вид

$$(X^t X)^{-1} = \frac{1}{nS_x^2} \begin{pmatrix} n & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}.$$

Следовательно,

$$(X^t X)^{-1} X^t \vec{y} = \frac{1}{n^2 S_x^2} \begin{pmatrix} n & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix} \begin{pmatrix} x_1 y_1 + \dots + x_n y_n \\ y_1 + \dots + y_n \end{pmatrix} = \frac{1}{x^2 - \bar{x}^2} \begin{pmatrix} \overline{xy} - \bar{x} \bar{y} \\ \frac{x^2}{2} \bar{y} - \overline{xy} \bar{x} \end{pmatrix}.$$

Оценка совпадает с той, которая была получена в этой модели.

## 1.4 Распределение оценок

Распределение вектора  $\vec{a} = (X^t X)^{-1} X^t \vec{y}$  можно выписать, пользуясь простым утверждением

**Лемма 2.** Если  $Z \sim \mathcal{N}(\vec{\mu}, \Sigma)$ , а  $C$  — матрица, то  $CZ \sim \mathcal{N}(C\vec{\mu}, C\Sigma C^t)$ .

*Доказательство.* Мы будем пользоваться определением нормальности в терминах характеристических

функций:  $Z \sim \mathcal{N}(\vec{\mu}, \Sigma)$ , если

$$\psi_Z(\vec{s}) = \mathbf{E} \exp(i\langle Z, \vec{s} \rangle) = \exp\left(i\langle \vec{s}, \vec{\mu} \rangle - \frac{1}{2} \vec{s}^t \Sigma \vec{s}\right).$$

Тогда

$$\psi_{CZ}(\vec{s}) = \mathbf{E} \exp(i\langle CZ, \vec{s} \rangle) = \mathbf{E} \exp(i\langle Z, C^t \vec{s} \rangle) = \exp\left(i\langle C^t \vec{s}, \vec{\mu} \rangle - \frac{1}{2} \vec{s}^t C \Sigma C^t \vec{s}\right).$$

Глядя на формулу характеристической функции, мы видим что полученное распределение нормально с указанными параметрами.  $\square$

В силу Леммы 2 и соотношения

$$\vec{Y} \sim \mathcal{N}(X\vec{a}, \sigma^2 E),$$

имеем

$$\hat{a} = (X^t X)^{-1} X^t \vec{Y} \sim \mathcal{N}\left((X^t X)^{-1} X^t X \vec{a}, \sigma^2 (X^t X)^{-1} X^t ((X^t X)^{-1} X^t)^t\right) = \mathcal{N}\left(\vec{a}, \sigma^2 (X^t X)^{-1}\right).$$

Таким образом, оценки несмещенные и имеют нормальное распределение.

Как и в предыдущем случае, пользуясь Леммой 1, мы получаем, что

$$RSS = \|\vec{Y} - X\hat{a}\|^2$$

не зависит от  $\vec{a}$  и после деления на  $\sigma^2$  имеет  $\chi_{n-m}^2$  распределение.

Тем самым, мы можем построить несмещенную оценку  $RSS/(n-m)$  для  $\sigma^2$  (отличающуюся от ОМП), а также может построить доверительные интервалы для исследуемых параметров:

$$a_i \in \left( \hat{a}_i - \frac{t_{1-\alpha/2} \sqrt{n-m}}{\sqrt{(X^t X)^{-1}_{i,i}} \sqrt{RSS}}, \hat{a}_i + \frac{t_{1-\alpha/2} \sqrt{n-m}}{\sqrt{(X^t X)^{-1}_{i,i}} \sqrt{RSS}} \right),$$

$$\sigma^2 \in \left( \frac{RSS}{y_{1-\alpha/2}}, \frac{RSS}{y_{\alpha/2}} \right),$$

где  $t$  — квантиль распределения Стьюдента с  $n-m$  степенями свободы,  $y$  — квантиль распределения  $\chi_{n-m}^2$ .