

# Спецкурс "Регрессия"

Шкляев А.В.

15 января 2019 г.

## 1 Нормальная модель

### 1.1 Проверка гипотез в линейной модели

Будем записывать наше предположение  $\vec{Y} = X\vec{a} + \vec{\varepsilon}$ ,  $\vec{\varepsilon} \sim \mathcal{N}(0, \sigma^2 E)$  в терминах  $Y - \vec{\varepsilon} \in L$ , где

$$L = \{X\vec{a}, \vec{a} \in \mathbb{R}^n\}.$$

Будем проверять гипотезу  $H_0 : Y - \vec{\varepsilon} \in L_0$ , где  $L_0$  — линейное подпространство  $L$  с общей альтернативой  $H_1 : Y - \vec{\varepsilon} \in L \setminus L_0$ .

Воспользуемся обобщенным критерием правдоподобий, который предлагает для проверки  $H_0$  против  $H_1$  использовать статистику отношения правдоподобий

$$\frac{L(X_1, \dots, X_n; \tilde{\theta})}{L(X_1, \dots, X_n; \hat{\theta})} > c,$$

где  $\tilde{\theta}$  — ОМП при выполненной гипотезе, а  $\hat{\theta}$  — ОМП в общей модели  $H_0 \cup H_1$ .

Как мы уже обсуждали выше, правдоподобие в модели имеет вид

$$L(y_1, \dots, y_n; \vec{a}, \sigma^2) = \left( \frac{1}{\sqrt{2\pi}\sigma} \right)^n \exp \left( -\frac{1}{2\sigma^2} \|y - X\vec{a}\|^2 \right).$$

При этом ОМП для  $\sigma^2$  при  $H_0$  будет иметь вид

$$\hat{\sigma}^2 = \|y - X\vec{a}\|^2/n = \|y - \text{proj}_{L_0} y\|^2/n,$$

а правдоподобие приобретет вид

$$L(y_1, \dots, y_n; \vec{a}, \hat{\sigma}^2) = \left( \frac{\sqrt{n}}{\sqrt{2\pi} \|y - \text{proj}_{L_0} y\|} \right)^n \exp \left( -\frac{n}{2} \right).$$

Аналогичным образом при  $H_0 \cup H_1$  омп для  $\sigma^2$  и правдоподобие приобретут вид

$$\tilde{\sigma}^2 = \|y - \text{proj}_L y\|^2/n, \quad L(y_1, \dots, y_n; \vec{a}, \tilde{\sigma}^2) = \left( \frac{\sqrt{n}}{\sqrt{2\pi} \|y - \text{proj}_L y\|} \right)^n \exp \left( -\frac{n}{2} \right).$$

Тогда отношение правдоподобий имеет вид

$$\frac{L(y_1, \dots, y_n; \vec{a}, \tilde{\sigma}^2)}{L(y_1, \dots, y_n; \vec{a}, \hat{\sigma}^2)} = \left( \frac{\|y - \text{proj}_L y\|}{\|y - \text{proj}_{L_0} y\|} \right)^{n/2}.$$

Следовательно, критическое множество критерия обобщенного отношения правдоподобий имеет вид

$$\left\{ \vec{y} : \frac{\|\vec{y} - \text{proj}_{L_0} \vec{y}\|}{\|\vec{y} - \text{proj}_L \vec{y}\|} > c \right\} = \left\{ \vec{y} : \frac{\|\vec{y} - \text{proj}_{L_0} \vec{y}\|^2}{\|\vec{y} - \text{proj}_L \vec{y}\|^2} > c^2 \right\} = \left\{ \frac{\|\vec{y} - \text{proj}_{L_0} \vec{y}\|^2 - \|\vec{y} - \text{proj}_L \vec{y}\|^2}{\|\vec{y} - \text{proj}_L \vec{y}\|^2} > \tilde{c} \right\}$$

для некоторого  $\tilde{c}$ . В числителе стоит разность квадратов длин перпендикуляров из  $\vec{y}$ , опущенных на  $L_0$  и  $L$ , равная квадрату длины  $\text{proj}_L \vec{Y} - \text{proj}_{L_0} \vec{Y}$  по теореме Пифагора. Следовательно, мы должны найти  $\tilde{c}$  такое что

$$\mathbf{P}_{H_0} \left( \frac{\|\text{proj}_L \vec{Y} - \text{proj}_{L_0} \vec{Y}\|^2}{\|\vec{Y} - \text{proj}_L \vec{Y}\|^2} > \tilde{c} \right) = 1 - \alpha.$$

При верной гипотезе  $H_0$  величины  $\text{proj}_L \vec{Y} - \text{proj}_{L_0} \vec{Y}$  и  $\vec{Y} - \text{proj}_L \vec{Y}$  представляют собой проекции вектора  $\vec{Y} - X\vec{a} \sim \mathcal{N}(0, \sigma^2)$  на два ортогональных пространства  $L^\perp$  и  $L_1 \cap L_0^\perp$ . Следовательно,

$$\mathbf{P}_{H_0} \left( \frac{\|\text{proj}_L \vec{Y} - \text{proj}_{L_0} \vec{Y}\|^2 / (m - m_0)}{\|\vec{Y} - \text{proj}_L \vec{Y}\|^2 / (n - m)} > \hat{c} \right) = 1 - F_{f_{m-m_0, n-m}}(\hat{c}),$$

где  $\dim L = m$ ,  $\dim L_0 = m_0$ ,  $f_{k,l}$  — распределение Фишера-Снедекора с  $k$  и  $l$  степенями свободы.

Отсюда получаем критерий с критическим множеством

$$\frac{D_{0,1} / (m - m_0)}{D_1 / (n - m)} = \frac{(D_0 - D_1) / (m - m_0)}{D_1 / (n - m)} > f_{1-\alpha}, \quad D_{0,1} = \|\text{proj}_L \vec{y} - \text{proj}_{L_0} \vec{y}\|^2, \quad D_1 = \|\vec{y} - \text{proj}_L \vec{y}\|^2,$$

где  $f$  — квантиль распределения Фишера-Снедекора с  $m - m_0, n - m$  степенями свободы.

## 1.2 One-way ANOVA

Применим полученный критерий к задаче однофакторного дисперсионного анализа (ANalysis Of VAriance или ANOVA).

Пусть  $Z_{i,j} \sim \mathcal{N}(\mu_i, \sigma^2), j \leq n_i, i \leq k$  — независимые наблюдения из  $k$  различных групп,  $n_1 + \dots + n_k = n$ . Мы хотим проверить гипотезу о том, что группы однородны:  $H_0 : \mu_1 = \mu_2 = \dots = \mu_k$  с общей альтернативой.

Представим наши данные соответственно линейной модели:

$$\vec{Y} = X\vec{a} + \vec{\varepsilon},$$

где  $\vec{Y} = (Z_{1,1}, \dots, Z_{1,n_1}, \dots, Z_{k,1}, \dots, Z_{k,n_k})$ ,  $\vec{a} = (\mu_1, \dots, \mu_k)$ ,  $\varepsilon_i$  — н.о.р.  $\mathcal{N}(0, \sigma^2)$  и

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

При этом

$$\hat{a} = (X^t X)^{-1} X^t \vec{Y} = \begin{pmatrix} n_1 & 0 & \dots & 0 \\ 0 & n_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & n_k \end{pmatrix}^{-1} X^t \vec{Y} = \begin{pmatrix} \bar{Z}_{1,\cdot} \\ \bar{Z}_{2,\cdot} \\ \dots \\ \bar{Z}_{k,\cdot} \end{pmatrix}.$$

Гипотеза утверждает, что  $\vec{Y} = a\vec{e} + \vec{\varepsilon}$ , где  $\vec{e} = (1, \dots, 1)$ . При этом  $\tilde{a} = \bar{Y} = \bar{Z}_{\cdot, \cdot}$ . Таким образом,

$$RSS = \|\vec{Y} - \text{proj}_L \vec{Y}\|^2 = \sum_{i=1}^k \sum_{j=1}^{n_i} (Z_{i,j} - \bar{Z}_{i,\cdot})^2, SS_{Reg} = \|\text{proj}_{L_0} \vec{Y} - \text{proj}_L \vec{Y}\|^2 = \sum_{i=1}^k n_i (\bar{Z}_{i,\cdot} - \bar{Z}_{\cdot,\cdot})^2.$$

Критерий тем самым приобретает вид

$$F = \frac{SS_{Reg}/(k-1)}{RSS/(N-k)} > f_{1-\alpha},$$

где  $f_{1-\alpha}$  — квантиль распределения Фишера с  $k-1, N-k$  степенями свободы

### 1.3 Проверка адекватности линейной модели

Для частного случая проверки гипотезы  $H_0 : \vec{a} = 0, H_1 : \vec{a} \neq 0$ , где  $\vec{Y} = X\vec{a} + b\vec{e}$  мы получаем критерий

$$1 - \frac{D_{01}/(k-1)}{D_1/(N-k)} > f_{1-\alpha}.$$

Можно охарактеризовать статистику величиной

$$R^2 = 1 - \frac{D_1}{D_0} \in [0, 1].$$

Чем ближе эта величина к 1, тем ближе мы к отклонению гипотезы неадекватности модели  $H_0$ , то есть тем мы увереннее, что  $X$  помогают в оценивании  $\vec{Y}$ .

Величина  $R^2$  называется коэффициентом детерминации.

Отметим, что величина  $R^2$  увеличивается при добавлении в модель предикторов, поскольку длина проекции  $D_1$  убывает, а  $D_0$  не меняется.

### 1.4 Снижение количества предикторов

#### Forward selection.

Начнем с модели  $\vec{Y} = \vec{\varepsilon}$  и будем добавлять переменные.

Выбирая, какую переменную добавить в модель, мы будем смотреть на

$$F = \frac{(D_1 - D_0)/(k-1)}{D_1/(N-k)},$$

где  $D_0$  — RSS текущей модели,  $D_1$  — следующей. Максимальное значение эта величина принимает при максимальном

$$R^2 = 1 - \frac{D_1}{D_{00}},$$

где  $D_{00}$  рассчитывается по сравнению с моделью  $H_0 : \vec{Y} = \vec{\varepsilon}$ . Тем самым, мы получаем процедуру добавления переменных — на каждом шаге выбираем переменную с максимальным  $R^2$ . Остановиться можно либо когда  $R^2$  стал достаточно близок к 1 (больше данного порога), либо когда статистика  $F$  оказалась малой.

#### Backward selection.

В этом случае мы напротив начинаем со всех предикторов и избавляемся от них один за другим. При этом аналогичным образом можно выбирать тот предиктор, у которого наименьшая статистика  $R^2$  и избавляться от него. Критерием остановки можно считать либо момент, когда наименьший из  $R^2$  достаточно отдалится от 1 (на заданное расстояние), либо когда статистика  $F$  оказалось большой.