

2. Линейная модель МР

Модель множественной регрессии (МР)

$$\underline{1)} \quad M(Y|x_1, x_2, \dots, x_p) = f(x_1, x_2, \dots, x_p)$$

$$\underline{2)} \quad y = f(x_1, x_2, \dots, x_p) + \varepsilon$$

$$\underline{3)} \quad y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$$

$\beta_0 \Rightarrow x_0 = 1$ – фиктивная переменная

Матричная запись

$$Y = XB + E$$

$$Y = [y_1, y_2, \dots, y_n]'$$

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \boxtimes & x_{1p} \\ 1 & x_{21} & x_{22} & \boxtimes & x_{2p} \\ \boxtimes & \boxtimes & \boxtimes & \boxtimes & \boxtimes \\ 1 & x_{n1} & x_{n2} & \boxtimes & x_{np} \end{bmatrix}$$

$$B = [\beta_0, \beta_1, \beta_2, \dots, \beta_p]'$$

$$E = [\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n]'$$

Выборочная модель МР

$$1) \quad y = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p + e$$

$$2) \quad \hat{y} = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p$$

Матричная запись

$$Y = XB + E$$

$$\hat{Y} = XB$$

$$B = [b_0, b_1, b_2, \dots, b_p]'$$

$$E = [e_1, e_2, \dots, e_n]'$$

Число степеней свободы:

$$v = n - p - 1$$

Рекомендация:

$$n \geq 3(p + 1)$$

Целесообразно:

объем выборки должен быть в 6-7 раз
больше числа независимых переменных.

Классическая нормальная линейная модель МР при выполнении требований

1. Независимые переменные – величины неслучайные, возмущения - есть СВ.
2. МО возмущений равны 0.
3. Дисперсия возмущений постоянна (условие гомоскедастичности).

Классическая нормальная линейная модель МР при выполнении следующих требований

4. Отсутствие автокорреляции в возмущениях и их некоррелированность со всеми НП.
5. Возмущения распределены по нормальному закону.
6. Отсутствие мультиколлинеарности (между НП отсутствует сильная линейная связь).

**Для классической нормальной
линейной модели МР МНК-оценки
параметров модели имеют
наименьшую дисперсию в классе
линейных несмещенных оценок**

2. Оценка параметров линейной модели МР

Метод наименьших квадратов

Оценки параметров ЛММР согласно МНК будем искать из условия:

$$Q = \sum e_i^2 =$$
$$= \sum \left(y_i - b_0 - b_1 x_1 - b_2 x_2 - \dots - b_p x_p \right)^2 \rightarrow \min$$

Условиями минимума функции являются равенство нулю первых производных по коэффициентам УМР.

Матричный метод

$$\begin{aligned} 1) \quad \mathbf{B} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \\ &= \mathbf{A}^{-1} \mathbf{X}'\mathbf{Y} \end{aligned}$$

$$2) \quad \mathbf{A} = \mathbf{X}'\mathbf{X}$$

$$3) \quad \text{Rank}(\mathbf{X}) = p + 1 < n$$

Гомоскедастичность

1) $D(\varepsilon_i) = D(\varepsilon_j)$ для любых i и j

Гетероскедастичность

2) $D(\varepsilon_i) \neq D(\varepsilon_j)$ для любых i и j

Понятие автокорреляции

Определение. Автокорреляцией (serial correlation) порядка p в ошибках модели регрессии называется зависимость ошибок вида

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + \dots + \rho_p \varepsilon_{t-p} + u_t,$$

где u_t удовлетворяет условиям теоремы Гаусса – Маркова.

Обобщенный метод наименьших квадратов

Теорема. Если в схеме Гаусса-Маркова не выполняется предпосылка о гомоскедастичности и некорелированности случайных возмущений, то наилучшей линейной процедурой оценки параметров модели является:

$$\mathbf{b} = \left(\mathbf{X}^T \mathbf{P}^{-1} \mathbf{X} \right)^{-1} \mathbf{X}^T \mathbf{P}^{-1} \mathbf{Y}$$

\mathbf{P} - матрица ковариаций случайных возмущений
(положительно определенная матрица)

Взвешенный метод наименьших квадратов

Теорема. Если в схеме Гаусса-Маркова не выполняется предпосылка о гомоскедастичности случайных возмущений, то наилучшей линейной процедурой оценки параметров модели является:

$$\mathbf{b} = \left(\mathbf{X}^T \mathbf{P}^{-1} \mathbf{X} \right)^{-1} \mathbf{X}^T \mathbf{P}^{-1} \mathbf{Y}$$

\mathbf{P} - матрица ковариаций случайных возмущений :

$$\mathbf{P} = \begin{pmatrix} \sigma^2(e_1) & 0 & \dots & 0 \\ 0 & \sigma^2(e_2) & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \sigma^2(e_n) \end{pmatrix}$$

Взвешенный метод наименьших квадратов

Определение. Пусть заданы положительные числа $\{w_i\}_{i=1}^n$ (веса).
Оценки коэффициентов модели регрессии, полученные минимизацией *взвешенной суммы квадратов отклонений*

$$\sum_{i=1}^n w_i (y_i - \beta_0 - \beta_1 x_{i1} - \cdots - \beta_k x_{ik})^2 \longrightarrow \min,$$

называются *WLS-оценками* (WLS = Weighted Least Squares) или *оценками взвешенного метода наименьших квадратов*.

Мультиколлинеарность (МТК) – это явление высокой взаимной коррелированности НП.

Два вида МТК:

1) совершенная (строгая, полная)

2) несовершенная (частичная)

Полная МТК при наличии функциональных связей между НП.

Это нарушение требования к рангу матрицы:

1) $\text{rank } X < p + 1$

2) $\det X'X = 0$

$$B = (X'X)^{-1} X'Y$$

Последствия МТК:

- Оценки коэффициентов УМР ненадежны и неустойчивы (увеличиваются стандартные ошибки оценок и уменьшаются t -статистики МНК-оценок)
- МНК-оценки коэффициентов неустойчивы (чувствительны к изменениям данных и размерности выборки)
- Возможность получения неверного знака у коэффициентов регрессии

Последствия МТК:

- Оценки коэффициентов УМР становятся очень чувствительными к ошибкам спец.
- Осложнение процесса определения наиболее существенных факторов
- Затрудняет экономическую интерпретацию коэффициентов УМР (выделение характеристик влияния факторов на ЗП в чистом виде)

ОДНАКО:

- Оценки коэффициентов остаются несмещенными
- Оценки коэффициентов немультикол. факторов не ухудшаются

Причины возникновения МТК:

- НП характеризуют одну и ту же сторону экон. процесса
- Использование в модели НП, суммарное значение которых есть постоянная величина
- НП, являющиеся элементами друг друга
- НП могут иметь общий временный тренд, относительно которой они совершают малые колебания

Наблюдается фиктивная (ложная) линейная СВЯЗЬ.

Методы устранения мультиколлинеарности

Переход к смещенным методам оценивания

«Ридж – регрессия» («гребневая регрессия»)

$$\mathbf{B}_{\tau} = \left(\mathbf{X}'\mathbf{X} + \tau\mathbf{I}_{p+1} \right)^{-1} \mathbf{X}'\mathbf{Y}$$

$$\tau_0 \approx 0.1 - 0.4$$

Регрессия на главных компонентах

2. Метод главных компонент – переход к новым объясняющим переменным, линейным комбинациям старых:

1) Центрирование переменных $X_y = X - \bar{X}$, $Y_y = Y - \bar{Y}$;

2) Решение характеристического уравнения $|\Sigma - \lambda E| = 0$:

a) Нахождение собственных чисел $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p > 0$,

b) Нахождение для каждого собственного числа λ_j собственного вектора $l^{(j)}$;

3) Переход к новым переменным $Z = X_y L$, $X_y = ZL^{-1} = ZL^T$;

4) Построение линейной регрессии $Y_y = ZC$, вычисление оценок с помощью МНК

$$\hat{C} = (Z^T Z)^{-1} Z^T Y = \text{diag}\{1/\lambda_j\} Z^T Y;$$

5) Проверка гипотез $H_{0j}: c_j = 0$, $j = 1, \dots, p$, исключение несущественных переменных;

6) При необходимости переход к исходной модели $\hat{\theta}_j = \sum_{k \in K_{\text{сущ}}} \hat{c}_k l_k^{(j)}$, $\hat{\theta}_0 = \bar{y} - \sum_{j=1}^p \hat{\theta}_j \bar{x}^{(j)}$.

Тема №1. Линейные эконометрические модели

4. Оценивание параметров ЭМ с учетом ограничений

Ограничения

$$1) \quad b_i > 0$$

$$2) \quad \mathbf{RB} = \mathbf{r}$$

$$3) \quad b_2 = b_3 \quad b_2 + b_3 + 2b_4 = 2$$

$$\mathbf{r} = \begin{bmatrix} 0 \\ 2 \end{bmatrix} \quad \mathbf{R} = \begin{bmatrix} 0 & 1 & -1 & 0 & \boxtimes \\ 0 & 1 & 1 & 2 & \boxtimes \end{bmatrix}$$

Целевая функция

$$1) \min_{b_i} \left(\sum_{j=1}^n e_j^2 = (\mathbf{Y} - \mathbf{XB})' (\mathbf{Y} - \mathbf{XB}) \right)$$

при ограничениях

$$2) \quad b_{i \min} \leq b_i \leq b_{i \max}, \quad \mathbf{RB} = \mathbf{r}$$

$$3) \quad \hat{\mathbf{b}} = \mathbf{b} + (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T \times \\ \times \left[\mathbf{R} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{R}^T \right]^{-1} (\mathbf{r} - \mathbf{Rb})$$

Тема №1. Линейные эконометрические модели

5. Проверка качества линейных
моделей МР
(самостоятельная проработка)

Проверка статических гипотез

Виды статистических гипотез:

1) Нулевые (основные);

2) альтернативные (конкурирующие).

Нулевая гипотеза H_0 - проверяемая гипотеза

Альтернативная гипотеза H_1 - гипотеза, которая противоречит нулевой.

Проверка статических гипотез

Ошибка первого рода – отвергается нулевая гипотеза, когда она верна.

Обозначают α и наз. **уровнем значимости (размером критерия)**

Ошибка второго рода – принимается нулевая гипотеза, когда верна альтернативная гипотеза.

Обозначают β и вероятность $1 - \beta$ не совершить ошибку второго рода наз.

мощностью критерия

Проверки статистических гипотез

Случайная величина K , построенная по результатам наблюдений для проверки нулевой гипотезы, наз. **статистическим критерием.**

Основа схемы построения статистического критерия – разделение выборочного пространства на две области:

- 1) область отклонения нулевой гипотезы (критическая обл.)
- 2) область принятия нулевой гипотезы

Статистическая проверка гипотез

$$f(k/H_0)$$



Проверка статических гипотез

Статистический критерий

определяется заданием:

1) статистической гипотезы H_0 ;

2) уровня значимости α ;

3) статистики критерия;

4) критической области.

Критерий наз. наиболее мощным, если

из всех критериев с заданным уровнем

значимости он обладает наибольшей

мощностью

Два способа проверки гипотез:

1. Нахождением критических точек, соответствующих заданным уровням значимости α .

2. Нахождением уровня значимости P (значимой вероятности), соответствующего наблюдаемому значению статистического критерия.

Если значимость P меньше заданного стандартного уровня значимости α , то нулевая гипотеза отвергается в пользу альтернативной.

Общая схема проверки гипотез

1. Формулировка нулевой и альтернативной гипотез
2. Задается уровень значимости α
3. Определение объема выборки n .
4. Выбор статистического критерия для проверки нулевой гипотезы.
5. Определение критической области и области принятия гипотезы.
6. Вычисление наблюдаемого значения статистического критерия.
7. Принятие статистического решения.

Проверка гипотез при двусторонней КО тесно связано с интервальным оцениванием.

Два способа проверки гипотез:

1. Нахождением критических точек, соответствующих заданным уровням значимости α .

2. Нахождением уровня значимости P (значимой вероятности), соответствующего наблюдаемому значению статистического критерия.

Если значимость P меньше заданного стандартного уровня значимости α , то нулевая гипотеза отвергается в пользу альтернативной.

Качество подгонки данных моделью

$$\sum (y_i - \bar{y})^2 = \sum (y_i - \hat{y}_i)^2 + \sum (y_i - y_i)^2$$

Общая СумКО
(TSS)

$$df = n - 1$$

Факторная
СумКО (ESS)

$$df = p$$

Остаточная СумКО
(RSS)

$$df = n - p - 1$$

Коэффициент множественной детерминации

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \in [0,1]$$

Коэффициенты R^2 в разных моделях с
разным числом наблюдений (и переменных)
несравнимы

Скорректированный коэффициент множественной детерминации

$$1) \quad \bar{R}^2 = 1 - \frac{RSS / (n - p - 1)}{TSS / (n - 1)} \leq 1$$

2)

$$\bar{R}^2 = 1 - (1 - R^2) \frac{n - 1}{n - p - 1} = R^2 - \frac{p}{n - p - 1} (1 - R^2)$$

Скорректированные коэффициенты в разных моделях с разным числом наблюдений (и переменных) ограничено сравнимы

Множественный коэффициент корреляции

1) $R = \sqrt{R^2} \in [0,1]$

2) $R \geq \max \{r_{yx_i}, i = \overline{1, p}\}$

Проверка значимости коэффициентов

Проверка статических гипотез

Статистический критерий

определяется заданием:

1) статистической гипотезы H_0 ;


2) уровня значимости α ;

3) статистики критерия;

4) критической области.

Статистическая проверка гипотез

$$f(k/H_0)$$



Проверка статических гипотез

Ошибка первого рода – отвергается нулевая гипотеза, когда она верна.

Обозначают α и наз. **уровнем значимости (размером критерия)**

Ошибка второго рода – принимается нулевая гипотеза, когда верна альтернативная гипотеза.

Обозначают β и вероятность $1 - \beta$ не совершить ошибку второго рода наз.

мощностью критерия

Проверка значимости коэффициент b_0

1. Мы обычно не имеем наблюдений вблизи $X = 0$.
2. При отсутствии наблюдений на каком-либо участке оцененная зависимость не может быть в данном месте достоверной.

$$1) \quad H_0 : \beta_j = 0; \quad H_1 : \beta_j \neq 0$$

$$2) \quad t_{b_j} = \frac{b_j}{m_{b_j}}, \quad j = \overline{0, p}$$

$$3) \quad m_{b_j} = S_e \sqrt{z_{jj}}$$

$$S_e = \sqrt{\sum (y - \hat{y}_x)^2 / (n - p - 1)}$$

z_{jj} – диагональные элементы матрицы

$$\mathbf{Z} = [z_{ij}]_{i, j = \overline{0, p}} = (\mathbf{X}' \mathbf{X})^{-1}$$

Проверка значимости коэф. УМР

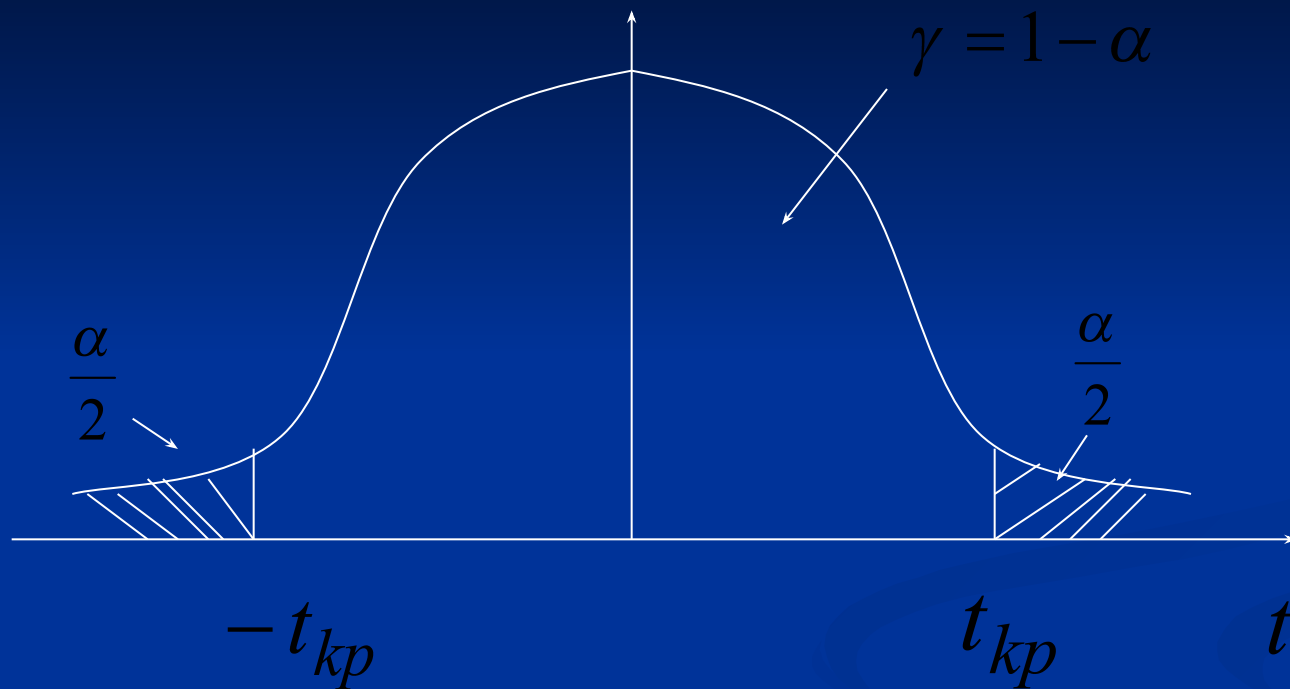
$$1) \left| t_{b_j} \right| > t_{\text{табл}}(\alpha; n - p - 1) \quad - \text{ параметр значим}$$

Общий случай

$$2) H_0 : b_j = \beta_j; \quad H_1 : b_j \neq \beta_j$$

$$3) t_{b_j} = \frac{b_j - \beta_j}{m_{b_j}}, \quad j = \overline{0, p}$$

Вычисление критической точки РС



Доверительный интервал

1)
$$b_j - \Delta_{b_j} < \beta_j < b_j + \Delta_{b_j}$$

2) **Предельная ошибка**

$$\Delta_{b_j} = t_{\text{табл}}(\alpha; n - p - 1) \cdot m_{b_j}$$

Односторонние проверка значимости коэф. УМР

1) $H_0 : b_j \leq \beta_j; \quad H_1 : b_j > \beta_j$

2) $t_{b_j} = \frac{b_j - \beta_j}{m_{b_j}}, j = \overline{0, p}$

3) $t_{b_j} > t_{\text{табл}}(2\alpha; n - p - 1)$ - прин. H_1



Односторонние гипотезы

- 1) $H_0 : b_j \leq \beta_j; \quad H_1 : b_j > \beta_j$ - правосторонняя
- 2) $H_0 : b_j \geq \beta_j; \quad H_1 : b_j < \beta_j$ - левосторонняя

Если имеется информация о знаках коэф.

- 3) **Знак «+»** $H_0 : b_j \leq 0; \quad H_1 : b_j > 0$
- Знак «-»** $H_0 : b_j \geq 0; \quad H_1 : b_j < 0$

Использование односторонних гипотез иногда позволяет «спасти» значимость коэффициентов регрессии при том же уровне значимости



Это требует обязательного экономического обоснования

Оценка значимости УМР

$$1) H_0 : D_{\text{факт.}} = D_{\text{ост.}} \quad H_1 : D_{\text{факт.}} > D_{\text{ост.}}$$

$$2) F = \frac{D_{\text{факт.}}}{D_{\text{ост.}}} \sim F(\nu_1 = p; \nu_2 = n - p - 1)$$

$$D_{\text{факт.}} = \frac{ESS}{p} \quad D_{\text{ост.}} = \frac{RSS}{n - p - 1}$$

$$3) F > F_{\text{табл}}(\alpha; p; n - p - 1) \Rightarrow (\text{модель значима})$$

Тестирование одного линейного ограничения

$$1) \beta_1 + \beta_2 + \dots + \beta_k = 1$$

Общий случай

$$2) r_1\beta_1 + r_2\beta_2 + \dots + r_k\beta_k = \mathbf{r}^T \boldsymbol{\beta}$$

$$H_0: \mathbf{r}^T \boldsymbol{\beta} = q \quad H_1: \mathbf{r}^T \boldsymbol{\beta} \neq q$$

$$4) t_{\text{набл}} = \frac{\mathbf{r}^T \mathbf{b} - q}{S_e \sqrt{\mathbf{r}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{r}}}$$

$$|t_{\text{набл}}| > t_{\text{табл}}(\alpha; n - k) \quad - \text{прин. } H_1$$

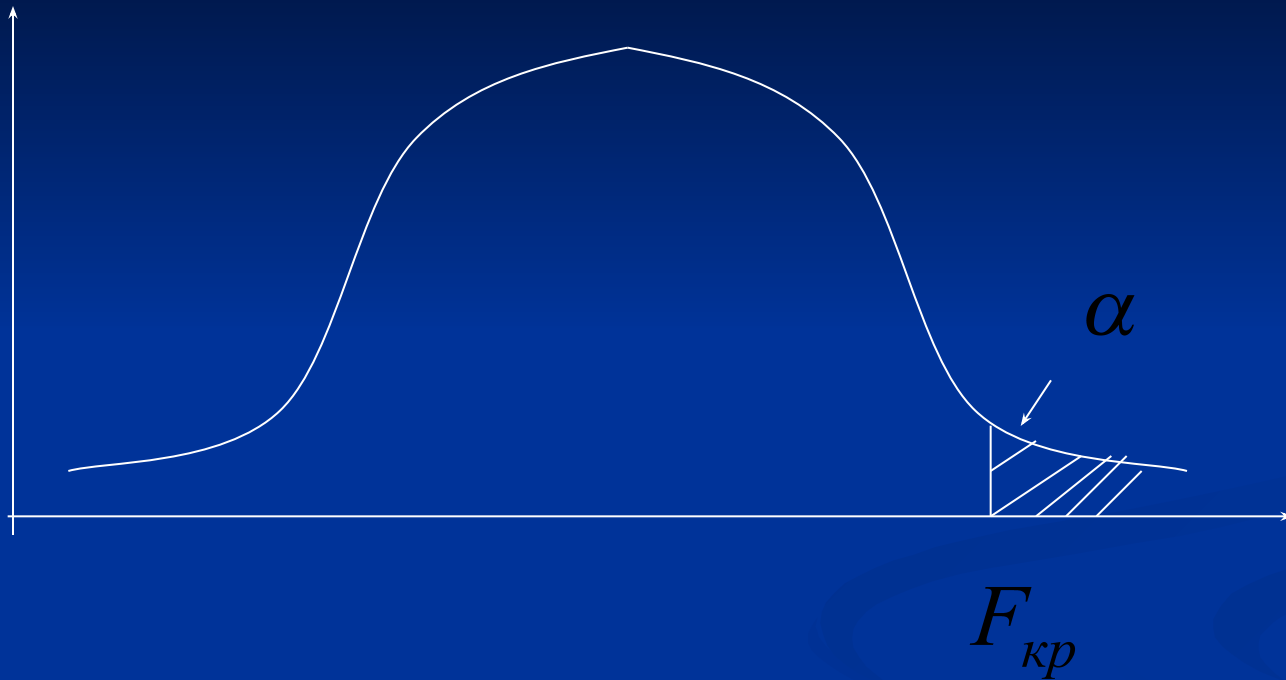
Анализ значимости коэффициента множественной детерминации

1) $H_0 : R^2 = 0$ $H_1 : R^2 > 0$

2)
$$F = \frac{R^2}{1 - R^2} \cdot \frac{n - p - 1}{p}$$

3) $F > F_{\text{табл}}(\alpha; p; n - p - 1)$ - модель значима

Вычисление критической точки РФ для правосторонней критической области



$$F_{кр} = F_{табл}(\alpha; p; n - p - 1)$$

Определение точности РМ

Меры точности РМ:

1. Средняя квадратическая ошибка остаточной компоненты на 1 степень свободы (стандартная ошибка регрессии RMSE)

$$RMSE = S_e = \sqrt{\sum (y - \hat{y}_x)^2 / (n - p - 1)}$$

Основная величина для измерения качества модели (чем она меньше, тем лучше)

Значения RMSE в однотипных моделях с разным числом наблюдений и (или) переменных сравнимы

Определение точности РМ

2. Средняя относительная ошибка аппроксимации

$$E_{\text{относ.}} = \frac{1}{n} \cdot \sum \left| \frac{e_i}{y_i} \right| \times 100$$

$$E_{\text{относ.}} < 5 - 7\% \quad \text{- хороший подбор РМ}$$

Типичные ошибки в использовании показателей качества ПР

- # Величина коэффициентов регрессии не указывает на силу связи или силу влияния на зависимую переменную
- # Значимость коэффициентов по t -тестам не позволяет сделать вывод о справедливости тех или иных теорий
- # t -статистики не указывают на относительную важность коэффициентов регрессии
- # t -статистики предназначены для использования исключительно для выборки и бесполезны для анализа всей совокупности
- # Нельзя сравнивать t -статистики, F -статистики, коэффициенты детерминации и др. у разных уравнений

Конец лекции