3. Оценка статистической значимости коэффициентов регрессии и коэффициента корреляции с помощью F и t-тестов

(первая часть РГР)

Пример 2. В таблице приведена динамика экономических показателей России: валовой внутренний продукт РФ (в процентах к предыдущему году) – показатель y (ВВП) и капитальные вложения в основные фонды РФ (в процентах к предыдущему году) – фактор x (КВОФ). Требуется оценить влияние фактора x на результативный признак y.

Год	ВВП (y,%)	КВОФ (x,%)
1991	95	85
1992	85,5	60
1993	91,3	88
1994	87,3	76
1995	95,8	90
1996	94	82
1997	100,4	95
1998	95,1	88
1999	104,6	105,3
2000	109,9	117,4
2001	105	108,7
2002	104,3	109,9

Имеем уравнение ПЛР:

$$Y = 55{,}9 + 0{,}45X$$

- где: 0,45 – коэффициент регрессии означает, что при увеличении признака X на 1% изменение результирующего признака У в среднем составит рост на 0,45%, т.к. имеет место **сильная прямая линейная связь** между темпом роста валового внутреннего продукта РФ (ВВП) - Y и темпом роста капитальных вложений в основные фонды РФ (КВОФ) – X.

3. Оценим качество УПЛР и значимость его коэффициентов

3.1. Для оценки качества линейной регрессии рассчитаем **коэффициент детерминации**

-алгебраически:

$$R^2 = r^2 = (0,97)^2 = 0,94$$

-статистически

$$R^2 = 0,93$$

Вывод:

Коэффициент детерминации показывает, что 93 % различий в объеме ВВП по годам объясняется вариацией капиталовложений - X , а оставшиеся 7 % объясняются другими неучтенными факторами.

3.2. Охарактеризуем статистическую надежность результатов регрессионного анализа с помощью F-критерия (F-mecm) на уровне значимости 0,05:

- Вычислим алгебраически:

$$F_{факт} = \frac{R^2}{1 - R^2}(n-2) =$$

- Определим статистически :

$$F_{факт} =$$

- Сравним $F_{факт}$ с $F_{табл}(\alpha; k_1; k_2) = 4{,}96$

где $k_1=1$; $k_2=12-1-1=10$,

- Вывод: **$F_{факт} > F_{табл}$, т.е. отвергается H_0 о** статистической незначимости уравнения регрессии и показателя тесноты связи коэффициента - **в**
- Имеется существенная связь между признаками уравнения с

3.3. Оценим значимость коэффициентов регрессии и корреляции с помощью t-критерия Стьюдента при уровне значимости 0,05 (с расчетом доверительных интервалов каждого из показателей). Также выдвигается гипотеза H_0 о случайной природе показателей, т.е. о незначимом их отличии от нуля.

- Оценка значимости параметров (коэффициентов) регрессии и коэффициента корреляции с помощью t-критерия Стьюдента проводится путем сопоставления их значений с величиной случайной ошибки ***m***:

$$t_b = \frac{b}{m_b}; \quad t_a = \frac{a}{m_a}; \quad t_r = \frac{r}{m_r}.$$

- Случайные ошибки – m - параметров линейной регрессии и коэффициента корреляции определяются по формулам:

$$m_b = \sqrt{\frac{\sum (y - \hat{y}_x)^2 / (n-2)}{\sum (x - \bar{x})^2}} = \sqrt{\frac{S^2_{\text{ост}}}{\sum (x - \bar{x})^2}} = \frac{S_{\text{ост}}}{\sigma_x \sqrt{n}};$$

$$m_a = \sqrt{\frac{\sum (y - \hat{y}_x)^2}{(n-2)} \cdot \frac{\sum x^2}{n \sum (x - \bar{x})^2}} = \sqrt{S^2_{\text{ост}} \frac{\sum x^2}{n^2 \sigma_x^2}} = S_{\text{ост}} \frac{\sqrt{\sum x^2}}{n \sigma_x};$$

$$m_{r_{xy}} = \sqrt{\frac{1 - r^2_{xy}}{n-2}}.$$

Сравнивая фактическое и критическое (табличное) значения t-статистики, принимаем или отвергаем гипотезу H_o:

- Если $t_{табл} < t_{факт}$, то H_0 отклоняется, т.е. *a, b* и r_{xy} не случайно отличаются от нуля и сформировались под влиянием систематически действующего фактора *x.*
- Если $t_{табл} > t_{факт}$, то гипотеза H_0 не отклоняется и признается случайная природа формирования *a, b* или r_{xy}.

Принимаем уровень значимости 0,05, степень свободы 10.
Тогда для данного примера (слайд 2):

- $t_{табл}$ = 2,2281(для всех параметров!)

Расчет (с продолжением таблицы данных) фактических статистик дает:

$t_{факт\ a}$ =

$t_{факт\ b}$ =

$t_{факт\ r}$ =

3.4 Далее рассчитываем доверительный интервал для каждого параметра УПЛР

$$\gamma_a = a \pm \Delta_a; \qquad \gamma_{a_{\min}} = a - \Delta_a; \qquad \gamma_{a_{\max}} = a + \Delta_a;$$

$$\gamma_b = b \pm \Delta_b; \qquad \gamma_{b_{\min}} = b - \Delta_b; \qquad \gamma_{b_{\max}} = b + \Delta_b.$$

определяем предельную ошибку для каждого параметра:

$$\Delta_a = t_{\text{табл}} m_a, \qquad \Delta_b = t_{\text{табл}} m_b.$$

4. Определение прогнозного значения У с помощью УПЛР и проверка ошибки

В итоге определяется прогнозное значение Ур путем подстановки в уравнение регрессии Ур =а + вХ соответствующего (прогнозного) значения Хр.

Средняя стандартная ошибка прогноза рассчитывается по формуле:

$$m_{\hat{y}_p} = \sigma_{\text{ост}} \cdot \sqrt{1 + \frac{1}{n} + \frac{(x_p - \overline{x})^2}{\sum (x - \overline{x})^2}},$$

$$\text{где } \sigma_{\text{ост}} = \sqrt{\frac{\Sigma(y - \hat{y})^2}{n - m - 1}};$$

- Вычислим алгебраически:

$$F_{факт} = \frac{R^2}{1 - R^2}(n-2) =$$

- Определим статистически :

$$F_{факт} =$$

- Сравним $F_{факт}$ с $F_{табл}(\alpha;\ k_1;\ k_2) = 4{,}96$

где $k_1 = 1$; $k_2 = 12 - 1 - 1 = 10$,

- Вывод: $F_{факт} > F_{табл}$, т.е. отвергается H_0 о статистической незначимости уравнения регрессии и показателя тесноты связи коэффициента - в
- Имеется существенная связь между признаками уравнения с уровнем значимости α

№	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
коэ фф	1,3	1,5	1,6	1,7	1,9	2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7	2,8	2,9	3,0	3,1	3,2	3,3	3,4	3,5	3,6	3,7	3,8

Строится доверительный интервал прогноза:

$$\gamma_{\hat{y}_p} = \hat{y}_p \pm \Delta_{\hat{y}_p}; \quad \gamma_{\hat{y}_{p\,\min}} = \hat{y}_p - \Delta_{\hat{y}_p}; \quad \gamma_{\hat{y}_{p\,\max}} = \hat{y}_p + \Delta_{\hat{y}_p},$$

где $\Delta_{\hat{y}_p} = t_{\text{табл}} \cdot m_{\hat{y}_p}$.

Выполненные правильно расчеты, оформленные выводы по прогнозу для приведенного примера (для каждого студента свой прогноз) засчитываются в 1-ю часть РГР.