



Эконометрика

**Кракашова Ольга
Анатольевна**

канд. экон. наук,
доцент кафедры СЭиОР РГЭУ (РИНХ)



Лекция № 2

Парная (простая) регрессия

Парная регрессия и корреляция

Парная (простая) регрессия представляет собой модель, где среднее значение зависимой (объясняемой) переменной рассматривается как функция одной независимой (объясняющей) переменной x , т.е. это модель вида:

$$\hat{y}_x = f(x).$$

В каждом отдельном случае величина y складывается из двух слагаемых:

$$y = \hat{y}_x + \varepsilon,$$

где y – фактическое значение результативного признака; \hat{y}_x – теоретическое значение результативного признака, найденное исходя из уравнения регрессии; ε – случайная величина, характеризующая отклонения реального значения результативного признака от теоретического, найденного по уравнению регрессии.

Случайная величина ε называется также возмущением. Она включает влияние не учтенных в модели факторов, случайных ошибок и особенностей измерения. Ее присутствие в модели порождено тремя источниками: спецификацией модели, выборочным характером исходных данных, особенностями измерения переменных.

Виды ошибок при построении регрессии и методы их устранения


| Вид ошибки | Метод устранения |
|---|---|
| Ошибки спецификации: неправильный выбор той или иной математической функции для y и недоучет в уравнении регрессии какого-либо существующего фактора, т.е. использование парной регрессии вместо множественной. | Изменение формы модели (вид математической формулы). |
| Ошибки выборки, которые имеют место в силу неоднородности данных в исходной статистической совокупности. | Увеличение объема исходных данных; исключение из совокупности единицы с аномальными значениями исследуемых признаков. |
| Ошибки измерения | Изменение методики измерения (когда это возможно). |

Предполагая, что ошибки измерения сведены к минимуму, основное внимание в эконометрических исследованиях уделяется ошибкам спецификации модели.


Методы выбора вида математической функции:

- 1) графический;
- 2) аналитический, т.е. исходя из теории изучаемой взаимосвязи;
- 3) экспериментальный.


Основные типы кривых, используемые при количественной оценке связей между двумя переменными




$$\hat{y}_x = a + b \cdot x$$




$$\hat{y}_x = a + b \cdot x + c \cdot x^2$$




$$\hat{y}_x = a \cdot x^b$$



$$\hat{y}_x = a \cdot b^x$$



$$\hat{y}_x = a + b/x$$



$$\hat{y}_x = a + b \cdot x + c \cdot x^2 + d \cdot x^3$$

Если уравнение регрессии проходит через все точки корреляционного поля, что возможно только при функциональной связи, когда все точки лежат на линии регрессии $\hat{y}_x = f(x)$, то фактические значения результативного признака совпадают с теоретическими $y = \hat{y}_x$, т.е. они полностью обусловлены влиянием фактора x . В этом случае остаточная дисперсия $\sigma_{\text{ост}}^2 = 0$.

В практических исследованиях, как правило, имеет место некоторое рассеяние точек относительно линии регрессии. Оно обусловлено влиянием прочих, не учитываемых в уравнении регрессии, факторов. Иными словами, имеют место отклонения фактических данных от теоретических $(y - \hat{y}_x)$. Величина этих отклонений и лежит в основе расчета остаточной дисперсии:

$$\sigma_{\text{ост}}^2 = \frac{1}{n} \sum (y - \hat{y}_x)^2.$$

Чем меньше величина остаточной дисперсии, тем меньше влияние не учитываемых в уравнении регрессии факторов и тем лучше уравнение регрессии подходит к исходным данным.

Считается, что число наблюдений должно в 7-8 раз превышать число рассчитываемых параметров при переменной x . Это означает, что искать линейную регрессию, имея менее 7 наблюдений, вообще не имеет смысла. Если вид функции усложняется, то требуется увеличение объема наблюдений, ибо каждый параметр при x должен рассчитываться хотя бы по 7 наблюдениям. Значит, если мы выбираем параболу второй степени $\hat{y}_x = a + b \cdot x + c \cdot x^2$, то требуется объем информации уже не менее 14 наблюдений.

Линейная модель парной регрессии и корреляции

Линейная регрессия сводится к нахождению уравнения вида


$$\hat{y}_x = a + b \cdot x \text{ или } y = a + b \cdot x + \varepsilon. \quad (1.1)$$

Уравнение вида $\hat{y}_x = a + b \cdot x$ позволяет по заданным значениям фактора x находить теоретические значения результативного признака, подставляя в него фактические значения фактора x .

Построение линейной регрессии сводится к оценке ее параметров – a и b . Классический подход к оцениванию параметров линейной регрессии основан на методе наименьших квадратов (МНК). МНК позволяет получить такие оценки параметров a и b , при которых сумма квадратов отклонений фактических значений результативного признака y от теоретических \hat{y}_x минимальна:

$$\sum_{i=1}^n (y_i - \hat{y}_x)^2 = \sum_{i=1}^n \varepsilon_i^2 \rightarrow \min. \quad (1.2)$$

Линия регрессии с минимальной дисперсией остатков



Обозначим $\sum_i \varepsilon_i^2$ через $S(a, b)$, тогда: $S(a, b) = \sum (y - a - b \cdot x)^2$.

$$\begin{cases} \frac{\partial S}{\partial a} = -2 \sum (y - a - b \cdot x) = 0; \\ \frac{\partial S}{\partial b} = -2 \sum x(y - a - b \cdot x) = 0. \end{cases} \quad (1.3)$$

После несложных преобразований, получим следующую систему линейных уравнений для оценки параметров a и b :

$$\begin{cases} a \cdot n + b \cdot \sum x = \sum y; \\ a \cdot \sum x + b \cdot \sum x^2 = \sum x \cdot y. \end{cases} \quad (1.4)$$

Решая систему уравнений (1.4), найдем искомые оценки параметров a и b . Можно воспользоваться следующими готовыми формулами, которые следуют непосредственно из решения системы (1.4):

$$a = \bar{y} - b \cdot \bar{x}, \quad b = \frac{\text{COV}(x, y)}{\sigma_x^2}, \quad (1.5)$$

где $\text{COV}(x, y) = \overline{y \cdot x} - \bar{y} \cdot \bar{x}$ – ковариация признаков x и y ,

$\sigma_x^2 = \overline{x^2} - \bar{x}^2$ – дисперсия признака x и

$$\bar{x} = \frac{1}{n} \sum x, \quad \bar{y} = \frac{1}{n} \sum y, \quad \overline{y \cdot x} = \frac{1}{n} \sum y \cdot x, \quad \overline{x^2} = \frac{1}{n} \sum x^2.$$

Ковариация – числовая характеристика совместного распределения двух случайных величин, равная математическому ожиданию произведения отклонений этих случайных величин от их математических ожиданий.

Дисперсия – характеристика случайной величины, определяемая как математическое ожидание квадрата отклонения случайной величины от ее математического ожидания.

Математическое ожидание – сумма произведений значений случайной величины на соответствующие вероятности.

Параметр b называется **коэффициентом регрессии**. Его величина показывает среднее изменение результата с изменением фактора на одну единицу.

Показатель тесноты связи при использовании линейной регрессии - линейный коэффициент корреляции:

$$r_{xy} = b \cdot \frac{\sigma_x}{\sigma_y} = \frac{\text{COV}(x, y)}{\sigma_x \cdot \sigma_y} \quad (1.6)$$

Линейный коэффициент корреляции находится в пределах: $-1 \leq r_{xy} \leq 1$. Чем ближе абсолютное значение r_{xy} к единице, тем сильнее линейная связь между факторами (при $r_{xy} = \pm 1$ имеем строгую функциональную зависимость). Но следует иметь в виду, что близость абсолютной величины линейного коэффициента корреляции к нулю еще не означает отсутствия связи между признаками. При другой (нелинейной) спецификации модели связь между признаками может оказаться достаточно тесной.

Коэффициент детерминации

Коэффициент детерминации характеризует долю дисперсии результативного признака y , объясняемую регрессией, в общей дисперсии результативного признака:

$$r_{xy}^2 = \frac{\sigma_{\text{факт}}^2}{\sigma_y^2} = 1 - \frac{\sigma_{\text{ост}}^2}{\sigma_y^2}, \quad (1.7)$$

где $\sigma_y^2 = \frac{1}{n} \sum (y - \bar{y})^2$, $\sigma_{\text{факт}}^2 = \frac{1}{n} \sum (\hat{y}_x - \bar{y})^2$, $\sigma_{\text{ост}}^2 = \frac{1}{n} \sum (y - \hat{y}_x)^2$.

Соответственно величина $1 - r_{xy}^2$ характеризует долю дисперсии y , вызванную влиянием остальных, не учтенных в модели, факторов.

Проверить значимость уравнения регрессии – значит установить, соответствует ли математическая модель, выражающая зависимость между переменными, экспериментальным данным и достаточно ли включенных в уравнение объясняющих переменных (одной или нескольких) для описания зависимой переменной.

Средняя ошибка аппроксимации:

$$\bar{A} = \frac{1}{n} \sum \left| \frac{y - \hat{y}_x}{y} \right| \cdot 100\%. \quad (1.8)$$

Средняя ошибка аппроксимации не должна превышать 8–10%.

Оценка значимости уравнения регрессии в целом производится на основе *F*-критерия Фишера, которому предшествует дисперсионный анализ.

Согласно основной идее дисперсионного анализа, общая сумма квадратов отклонений переменной y от среднего значения \bar{y} раскладывается на две части – «объясненную» и «необъясненную»:

$$\sum (y - \bar{y})^2 = \sum (\hat{y}_x - \bar{y})^2 + \sum (y - \hat{y}_x)^2,$$

где $\sum (y - \bar{y})^2$ – общая сумма квадратов отклонений; $\sum (\hat{y}_x - \bar{y})^2$ – сумма квадратов отклонений, объясненная регрессией (или факторная сумма квадратов отклонений); $\sum (y - \hat{y}_x)^2$ – остаточная сумма квадратов отклонений, характеризующая влияние неучтенных в модели факторов.

Схема дисперсионного анализа имеет вид

(n – число наблюдений, m – число факторов)

| Компоненты дисперсии | Сумма квадратов | Число степеней свободы | Дисперсия на одну степень свободы |
|----------------------|--------------------------------|------------------------|---|
| Общая | $\sum (y - \bar{y})^2$ | $n - 1$ | $S_{\text{общ}}^2 = \frac{\sum (y - \bar{y})^2}{n - 1}$ |
| Факторная | $\sum (\hat{y}_x - \bar{y})^2$ | m | $S_{\text{факт}}^2 = \frac{\sum (\hat{y}_x - \bar{y})^2}{m}$ |
| Остаточная | $\sum (y - \hat{y}_x)^2$ | $n - m - 1$ | $S_{\text{ост}}^2 = \frac{\sum (y - \hat{y}_x)^2}{n - m - 1}$ |

Определение дисперсии на одну степень свободы приводит дисперсии к сравнимому виду. Сопоставляя факторную и остаточную дисперсии в расчете на одну степень свободы, получим величину:

$$F = \frac{S_{\text{факт}}^2}{S_{\text{ост}}^2} \quad (1.9)$$

Фактическое значение F -критерия Фишера (1.9) сравнивается с табличным значением $F_{\text{табл}}(\alpha; k_1; k_2)$ при уровне значимости α и степенях свободы $k_1 = m$ и $k_2 = n - m - 1$. При этом, если фактическое значение F -критерия больше табличного, то признается статистическая значимость уравнения в целом.

Для парной линейной регрессии $m = 1$, поэтому

$$F = \frac{S_{\text{факт}}^2}{S_{\text{ост}}^2} = \frac{\sum (\hat{y}_x - \bar{y})^2}{\sum (y - \hat{y}_x)^2} \cdot (n - 2). \quad (1.10)$$

Величина F -критерия связана с коэффициентом детерминации r_{xy}^2 , и ее можно рассчитать по следующей формуле:

$$F = \frac{r_{xy}^2}{1 - r_{xy}^2} \cdot (n - 2). \quad (1.11)$$

В парной линейной регрессии оценивается значимость не только уравнения в целом, но и отдельных его параметров. С этой целью по каждому из параметров определяется его стандартная ошибка: m_b и m_a .

Стандартная ошибка коэффициента регрессии определяется по формуле:

$$m_b = \sqrt{\frac{S_{\text{ост}}^2}{\sum (x - \bar{x})^2}} = \frac{S_{\text{ост}}}{\sigma_x \cdot \sqrt{n}}, \quad (1.12)$$

где $S_{\text{ост}}^2 = \frac{\sum (y - \hat{y}_x)^2}{n - 2}$ – остаточная дисперсия на одну степень свободы.

Величина стандартной ошибки совместно с t -распределением Стьюдента при $n - 2$ степенях свободы применяется для проверки существенности коэффициента регрессии и для расчета его доверительного интервала.

Для оценки существенности коэффициента регрессии его величина сравнивается с его стандартной ошибкой, т.е. определяется фактическое значение t -критерия Стьюдента:

$$t_b = \frac{b}{m_b}$$

которое затем сравнивается с табличным значением при определенном уровне значимости α и числе степеней свободы ($n - 2$). Доверительный интервал для коэффициента регрессии определяется как $\bar{b} \pm t_{\text{табл}} \cdot m_b$, знак коэффициента регрессии указывает на рост результативного признака y при увеличении признака-фактора x ($b > 0$), уменьшение результативного признака при увеличении признака-фактора ($b < 0$) или его независимость от независимой переменной ($b = 0$), то границы доверительного интервала для коэффициента регрессии не должны содержать противоречивых результатов, например, $-1,5 \leq b \leq 0,8$. Такого рода запись указывает, что истинное значение коэффициента регрессии одновременно содержит положительные и отрицательные величины и даже ноль, чего не может быть.

Стандартная ошибка параметра a определяется по формуле:

$$m_a = \sqrt{S_{\text{ост}}^2 \cdot \frac{\sum x^2}{n \cdot \sum (x - \bar{x})^2}} = S_{\text{ост}} \cdot \frac{\sqrt{\sum x^2}}{\sigma_x \cdot n}. \quad (1.13)$$

Значимость линейного коэффициента корреляции проверяется на основе величины ошибки коэффициента корреляции m_r :

$$m_r = \sqrt{\frac{1-r^2}{n-2}}. \quad (1.14)$$

Фактическое значение t -критерия Стьюдента определяется как

$$t_r = \frac{r}{m_r}.$$

Существует связь между t -критерием Стьюдента и F -критерием Фишера:

$$|t_b| = |t_r| = \sqrt{F}. \quad (1.15)$$

он дополняется расчетом стандартной ошибки


$$m_{y_0} = \sqrt{S_{\text{ост}}^2 \left(1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum (x - \bar{x})^2} \right)} = \sqrt{S_{\text{ост}}^2 \left(1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{n \cdot \sigma_x^2} \right)}, \quad (1.16)$$

где $S_{\text{ост}}^2 = \frac{\sum (y - \hat{y}_x)^2}{n-2}$, и построением доверительного интервала прогнозного значения y_0^* :

$$\hat{y}_0 - m_{y_0} \cdot t_{\text{табл}} \leq y_0^* \leq \hat{y}_x + m_{y_x} \cdot t_{\text{табл}}$$

Пример

| | | | | | | | | |
|--|-----|-----|-----|-----|-----|------|------|------|
| Расходы на продукты питания, y , тыс. руб. | 0,9 | 1,2 | 1,8 | 2,2 | 2,6 | 2,9 | 3,3 | 3,8 |
| Доходы семьи, x , тыс. руб. | 1,2 | 3,1 | 5,3 | 7,4 | 9,6 | 11,8 | 14,5 | 18,7 |



Поле корреляции.

| | x | y | $x \cdot y$ | x^2 | y^2 | \hat{y}_x | $y - \hat{y}_x$ | $(y - \hat{y}_x)^2$ | $A, \%$ |
|------------------|----------|----------|-------------|----------|----------|-------------|-----------------|---------------------|-----------|
| 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| 1 | 1,2 | 0,9 | 1,08 | 1,44 | 0,81 | 1,038 | -0,138 | 0,0190 | 15,33 |
| 2 | 3,1 | 1,2 | 3,72 | 9,61 | 1,44 | 1,357 | -0,157 | 0,0246 | 13,08 |
| 3 | 5,3 | 1,8 | 9,54 | 28,09 | 3,24 | 1,726 | 0,074 | 0,0055 | 4,11 |
| 4 | 7,4 | 2,2 | 16,28 | 54,76 | 4,84 | 2,079 | 0,121 | 0,0146 | 5,50 |
| 5 | 9,6 | 2,6 | 24,96 | 92,16 | 6,76 | 2,449 | 0,151 | 0,0228 | 5,81 |
| 6 | 11,8 | 2,9 | 34,22 | 139,24 | 8,41 | 2,818 | 0,082 | 0,0067 | 2,83 |
| 7 | 14,5 | 3,3 | 47,85 | 210,25 | 10,89 | 3,272 | 0,028 | 0,0008 | 0,85 |
| 8 | 18,7 | 3,8 | 71,06 | 349,69 | 14,44 | 3,978 | -0,178 | 0,0317 | 4,68 |
| Итого | 71,6 | 18,7 | 208,71 | 885,24 | 50,83 | 18,717 | -0,017 | 0,1257 | 52,19 |
| Среднее значение | 8,95 | 2,34 | 26,09 | 110,66 | 6,35 | 2,34 | - | 0,0157 | 6,52 |
| σ | 5,53 | 0,935 | - | - | - | - | - | - | - |
| σ^2 | 30,56 | 0,874 | - | - | - | - | - | - | - |

$$b = \frac{\text{cov}(x, y)}{\sigma_x^2} = \frac{\overline{x \cdot y} - \bar{x} \cdot \bar{y}}{\overline{x^2} - \bar{x}^2} = \frac{26,09 - 8,95 \cdot 2,34}{30,56} = 0,168;$$

$$a = \bar{y} - b \cdot \bar{x} = 2,34 - 0,168 \cdot 8,95 = 0,836.$$

Получили уравнение: $\hat{y}_x = 0,836 + 0,168 \cdot x$. Т.е. с увеличением дохода семьи на 1000 руб. расходы на питание увеличиваются на 168 руб.

Как было указано выше, уравнение линейной регрессии всегда дополняется показателем тесноты связи – линейным коэффициентом корреляции r_{xy} :

$$r_{xy} = b \cdot \frac{\sigma_x}{\sigma_y} = 0,168 \cdot \frac{5,53}{0,935} = 0,994.$$

$$r_{xy}^2 = 0,987$$

уравнением регрессии объясняется 98,7% дисперсии резульативного признака, а на долю прочих факторов приходится лишь 1,3%.

Оценим качество уравнения регрессии в целом с помощью F -критерия Фишера. Сосчитаем фактическое значение F -критерия:

$$F = \frac{r_{xy}^2}{1-r_{xy}^2} \cdot (n-2) = \frac{0,987}{1-0,987} \cdot 6 = 455,54.$$

Табличное значение ($k_1=1$, $k_2=n-2=6$, $\alpha=0,05$): $F_{\text{табл}} = 5,99$. Так как $F_{\text{факт}} > F_{\text{табл}}$, то признается статистическая значимость уравнения в целом.

Для оценки статистической значимости коэффициентов регрессии и корреляции рассчитаем t -критерий Стьюдента и доверительные интервалы каждого из показателей. Рассчитаем случайные ошибки параметров линейной регрессии и коэффициента корреляции

$$\left(S_{\text{ост}}^2 = \frac{\sum (y - \hat{y}_x)^2}{n-2} = \frac{0,1257}{8-2} = 0,021 \right):$$

$$m_b = \frac{S_{\text{ост}}}{\sigma_x \cdot \sqrt{n}} = \frac{\sqrt{0,021}}{5,53 \cdot \sqrt{8}} = 0,0093,$$

$$m_a = S_{\text{ост}} \cdot \frac{\sqrt{\sum x^2}}{\sigma_x \cdot n} = \frac{\sqrt{0,021 \cdot 885,24}}{5,53 \cdot 8} = 0,0975,$$

$$m_r = \sqrt{\frac{1-r^2}{n-2}} = \sqrt{\frac{1-0,987}{6}} = 0,0465.$$

Фактические значения t -статистик: $t_b = \frac{0,168}{0,0093} = 18,065,$

$t_a = \frac{0,836}{0,0975} = 8,574,$ $t_r = \frac{0,994}{0,0465} = 21,376.$ Табличное значение t -

критерия Стьюдента при $\alpha=0,05$ и числе степеней свободы $\nu = n-2=6$ есть $t_{\text{табл}} = 2,447$. Так как $t_b > t_{\text{табл}}$, $t_a > t_{\text{табл}}$ и $t_r > t_{\text{табл}}$, то признаем статистическую значимость параметров регрессии и показателя тесноты связи. Рассчитаем доверительные интервалы для параметров регрессии a и b : $a \pm t \cdot m_a$ и $b \pm t \cdot m_b$. Получим, что $a^* \in [0,597; 1,075]$ и $b^* \in [0,145; 0,191]$.

Средняя ошибка аппроксимации (находим с помощью столбца 10 таблицы 1.3; $A_j = \left| \frac{y_j - \hat{y}_x}{y_j} \right| \cdot 100\%$) $\bar{A} = 6,52\%$ говорит о хорошем качестве уравнения регрессии, т.е. свидетельствует о хорошем подборе модели к исходным данным.

И, наконец, найдем прогнозное значение результативного фактора \hat{y}_0 при значении признака-фактора, составляющем 110% от среднего уровня $x_0 = 1,1 \cdot \bar{x} = 1,1 \cdot 8,95 = 9,845$, т.е. найдем расходы на питание, если доходы семьи составят 9,85 тыс. руб.

$$\hat{y}_0 = 0,836 + 0,168 \cdot 9,845 = 2,490 \text{ (тыс. руб.)}$$

Значит, если доходы семьи составят 9,845 тыс. руб., то расходы на питание будут 2,490 тыс. руб.

Найдем доверительный интервал прогноза. Ошибка прогноза


$$m_{\hat{y}_p} = S_{\text{ост}} \cdot \sqrt{1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{n \cdot \sigma_x^2}} = \sqrt{0,021 \cdot \left(1 + \frac{1}{8} + \frac{(9,845 - 8,95)^2}{8 \cdot 30,56}\right)} = 0,154$$

а доверительный интервал ($\hat{y}_0 - m_{\hat{y}_0} \cdot t_{\text{табл}} \leq y_0^* \leq \hat{y}_x + m_{\hat{y}_x} \cdot t_{\text{табл}}$):

$$2,113 < \hat{y}_0^* < 2,867.$$

Т.е. прогноз является статистически надежным.

Теперь на одном графике изобразим исходные данные и линию регрессии:



Нелинейные модели парной регрессии и корреляции

Различают два класса нелинейных регрессий:

1. Регрессии, нелинейные относительно включенных в анализ объясняющих переменных, но линейные по оцениваемым параметрам, например

– полиномы различных степеней – $\hat{y}_x = a + b \cdot x + c \cdot x^2$,

$\hat{y}_x = a + b \cdot x + c \cdot x^2 + d \cdot x^3$;

– равнобочная гиперболола – $\hat{y}_x = a + b/x$;

– полулогарифмическая функция – $\hat{y}_x = a + b \cdot \ln x$.

2. Регрессии, нелинейные по оцениваемым параметрам, например

– степенная – $\hat{y}_x = a \cdot x^b$;

– показательная – $\hat{y}_x = a \cdot b^x$;

– экспоненциальная – $\hat{y}_x = e^{a+b \cdot x}$.

Регрессии нелинейные по оцениваемым параметрам делятся на два типа:

- нелинейные модели внутренне линейные (приводятся к линейному виду с помощью соответствующих преобразований, например, логарифмированием);
- нелинейные модели внутренне нелинейные (к линейному виду не приводятся).

К внутренне линейным моделям относятся, например, степенная функция – $\hat{y}_x = a \cdot x^b$, показательная – $\hat{y}_x = a \cdot b^x$, экспоненциальная – $\hat{y}_x = e^{a+b \cdot x}$, логистическая – $\hat{y}_x = \frac{a}{1+b \cdot e^{-c \cdot x}}$, обратная – $\hat{y}_x = \frac{1}{a+b \cdot x}$.

К внутренне нелинейным моделям можно, например, отнести следующие модели: $\hat{y}_x = a + b \cdot x^c$, $\hat{y}_x = a \cdot \left(1 - \frac{1}{1 - x^b}\right)$.

Среди нелинейных моделей наиболее часто используется степенная функция $y = a \cdot x^b \cdot \varepsilon$, которая приводится к линейному виду логарифмированием:

$$\ln y = \ln(a \cdot x^b \cdot \varepsilon);$$

$$\ln y = \ln a + b \cdot \ln x + \ln \varepsilon;$$

$$Y = A + b \cdot X + E,$$

где $Y = \ln y$, $X = \ln x$, $A = \ln a$, $E = \ln \varepsilon$. Т.е. МНК мы применяем для преобразованных данных:

$$\begin{cases} A \cdot n + b \cdot \sum X = \sum Y, \\ A \cdot \sum X + b \cdot \sum X^2 = \sum X \cdot Y, \end{cases}$$

а затем потенцированием находим искомое уравнение.

Формулы для расчета средних коэффициентов эластичности для наиболее часто используемых типов уравнений регрессии

| Вид функции, y | Первая производная, y' | Средний коэффициент эластичности, $\bar{\varepsilon}$ |
|---|---|--|
| 1 | 2 | 3 |
| $y = a + b \cdot x + \varepsilon$ | b | $\frac{b \cdot \bar{x}}{a + b \cdot \bar{x}}$ |
| $y = a + b \cdot x + c \cdot x^2 + \varepsilon$ | $b + 2c \cdot x$ | $\frac{(b + 2c \cdot \bar{x}) \cdot \bar{x}}{a + b \cdot \bar{x} + c \cdot \bar{x}^2}$ |
| $y = a + \frac{b}{x} + \varepsilon$ | $-\frac{b}{x^2}$ | $-\frac{b}{a \cdot \bar{x} + b}$ |
| $y = a \cdot x^b \cdot \varepsilon$ | $a \cdot b \cdot x^{b-1}$ | b |
| $y = a \cdot b^x \cdot \varepsilon$ | $a \cdot \ln b \cdot b^x$ | $\bar{x} \cdot \ln b$ |
| $y = a + b \cdot \ln x + \varepsilon$ | $\frac{b}{x}$ | $\frac{b}{a + b \cdot \ln \bar{x}}$ |
| $y = \frac{a}{1 + b \cdot e^{-cx + \varepsilon}}$ | $\frac{a \cdot b \cdot c \cdot e^{-cx}}{(1 + b \cdot e^{-cx})^2}$ | $\frac{b \cdot c \cdot \bar{x}}{b + e^{c\bar{x}}}$ |
| $y = \frac{1}{a + b \cdot x + \varepsilon}$ | $-\frac{b}{(a + b \cdot x)^2}$ | $-\frac{b \cdot \bar{x}}{a + b \cdot \bar{x}}$ |

Уравнение нелинейной регрессии, так же, как и в случае линейной зависимости, дополняется показателем тесноты связи. В данном случае это индекс корреляции:

$$\rho_{xy} = \sqrt{1 - \frac{\sigma_{\text{ост}}^2}{\sigma_y^2}}, \quad (1.21)$$

где $\sigma_y^2 = \frac{1}{n} \sum (y - \bar{y})^2$ – общая дисперсия результативного признака y ,

$\sigma_{\text{ост}}^2 = \frac{1}{n} \sum (y - \hat{y}_x)^2$ – остаточная дисперсия.

Величина данного показателя находится в пределах: $0 \leq \rho_{xy} \leq 1$.

Квадрат индекса корреляции носит название индекса детерминации и характеризует долю дисперсии результативного признака y , объясняемую регрессией, в общей дисперсии результативного признака:

$$\rho_{xy}^2 = 1 - \frac{\sigma_{\text{ост}}^2}{\sigma_y^2} = \frac{\sigma_{\text{факт}}^2}{\sigma_y^2}, \quad (1.22)$$

т.е. имеет тот же смысл, что и в линейной регрессии;

$$\sigma_{\text{факт}}^2 = \frac{1}{n} \sum (\hat{y}_x - \bar{y})^2.$$

Индекс детерминации используется для проверки существенности в целом уравнения регрессии по F -критерию Фишера:

$$F = \frac{\rho_{xy}^2}{1 - \rho_{xy}^2} \cdot \frac{n - m - 1}{m}, \quad (1.23)$$

где ρ_{xy}^2 – индекс детерминации, n – число наблюдений, m – число параметров при переменной x . Фактическое значение F -критерия (1.23) сравнивается с табличным при уровне значимости α и числе степеней свободы $k_2 = n - m - 1$ (для остаточной суммы квадратов) и $k_1 = m$ (для факторной суммы квадратов).