

Эконометрика

ОБОБЩЕННЫЙ МЕТОД НАИМЕНЬШИХ
КВАДРАТОВ

ОБОБЩЕННЫЙ МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Пусть функция регрессии представлена функцией, линейным образом зависящей от параметров - нелинейной по объясняющим переменным, но линейной по параметрам или, нелинейной по параметрам, но внутренне линейной (в этом случае необходимо произвести преобразование переменных):

$$y = a_0 + a_1 \phi_1(x_1, x_2, \dots, x_m) + a_2 \phi_2(x_1, x_2, \dots, x_m) + \dots + a_n \phi_n(x_1, x_2, \dots, x_m).$$

Модель данных в этом случае будет

$$y_i = a_0 + a_1 \phi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + a_2 \phi_2(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \phi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \varepsilon_i.$$

Предпосылки обобщенного метода наименьших квадратов

1. $(x_{1i}, x_{2i}, \dots, x_{mi})$ – детерминированные (нестохастические) переменные ;
2. Каждое измерение случайной погрешности характеризуется нулевым средним, не зависящим от значений наблюдаемых переменных;
3. Теоретическая дисперсия случайной составляющей постоянна для всех наблюдений, а их величины независимы от значений наблюдаемых переменных (**гомоскедастичность**);
4. Отсутствует **автокорреляция ошибок**, то есть отсутствие систематической связи между значениями случайной составляющей в любых двух наблюдениях;
5. Случайные погрешности имеют нормальное распределение.

Принцип наименьших квадратов

Утверждает, что выбор параметров функции регрессии является оптимальным в случае, когда сумма квадратов отклонений эмпирических значений результирующей переменной от теоретических значений этой переменной, рассчитанной по функции регрессии, является минимальной.

В этом случае он записывается,

$$Q(a_0, a_1, \dots, a_n) = \sum_{i=1}^N \left(y_i - \hat{y}_i(a_0, a_1, \dots, a_n; x_{1i}, x_{2i}, \dots, x_{mi}) \right)^2 =$$
$$= \sum_{i=1}^N \left(y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})) \right)^2 \rightarrow \min.$$

В этом случае N -число наблюдений.

По принципу Лагранжа

$$Q(a_0, a_1, \dots, a_n) = \sum_{i=1}^N \left(y_i - \hat{y}_i(a_0, a_1, \dots, a_n; x_{1i}, x_{2i}, \dots, x_{mi}) \right)^2 =$$
$$= \sum_{i=1}^N \left(y_i - \left(a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) \right) \right)^2 \rightarrow \min.$$



$$\left\{ \begin{array}{l} \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_0} = 0 \\ \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_1} = 0 \\ \dots \\ \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_n} = 0 \end{array} \right.$$

Проведем преобразования

$$\left\{ \begin{array}{l} \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_0} = \sum_{i=1}^N \frac{\partial (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})))^2}{\partial a_0} \\ \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_1} = \sum_{i=1}^N \frac{\partial (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})))^2}{\partial a_1} \\ \dots \\ \frac{\partial Q(a_0, a_1, \dots, a_n)}{\partial a_n} = \sum_{i=1}^N \frac{\partial (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})))^2}{\partial a_n} \end{array} \right.$$

Проведем преобразования

$$\left\{ \begin{array}{l} 2 \sum_{i=1}^N (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}))) \cdot (-1) = 0 \\ 2 \sum_{i=1}^N (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}))) \cdot (-\varphi_1(x_{1i}, x_{2i}, \dots, x_{mi})) = 0 \\ \dots \dots \dots \\ 2 \sum_{i=1}^N (y_i - (a_0 + a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}))) \cdot (-\varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})) = 0 \end{array} \right.$$

Умножим каждое уравнение на $\frac{1}{2}$.

Разобьем суммы на слагаемые

$$\left\{ \begin{array}{l} - \sum_{i=1}^N y_i + \sum_{i=1}^N a_0 + \sum_{i=1}^N a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + \sum_{i=1}^N a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) = 0 \\ - \sum_{i=1}^N y_i \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \sum_{i=1}^N a_0 \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \sum_{i=1}^N a_1 \varphi_1^2(x_{1i}, x_{2i}, \dots, x_{mi}) + \\ \dots + \sum_{i=1}^N a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) = 0 \\ \dots \\ - \sum_{i=1}^N y_i \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \sum_{i=1}^N a_0 \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \\ \sum_{i=1}^N a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + \sum_{i=1}^N a_n \varphi_n^2(x_{1i}, x_{2i}, \dots, x_{mi}) = 0 \end{array} \right.$$

Перенесем независимые переменные в право

$$\left\{ \begin{aligned} \sum_{i=1}^N a_0 + \sum_{i=1}^N a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + \sum_{i=1}^N a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) &= \sum_{i=1}^N y_i \\ \sum_{i=1}^N a_0 \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \sum_{i=1}^N a_1 \varphi_1^2(x_{1i}, x_{2i}, \dots, x_{mi}) + \\ \dots + \sum_{i=1}^N a_n \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) &= \sum_{i=1}^N y_i \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) \\ \dots & \\ \sum_{i=1}^N a_0 \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \sum_{i=1}^N a_1 \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + \\ \dots + \sum_{i=1}^N a_n \varphi_n^2(x_{1i}, x_{2i}, \dots, x_{mi}) &= \sum_{i=1}^N y_i \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) \end{aligned} \right.$$

УЧИТЫВАЯ, ЧТО

$$\sum_{i=1}^N a_0 = a_0 \sum_{i=1}^N 1 = a_0 (1 + \dots + 1) = Na_0$$

$$Na_0 + a_1 \sum_{i=1}^N \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + \dots + a_n \sum_{i=1}^N \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) = \sum_{i=1}^N y_i$$

$$a_0 \sum_{i=1}^N \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) + a_1 \sum_{i=1}^N \varphi_1^2(x_{1i}, x_{2i}, \dots, x_{mi}) +$$

$$\dots + a_n \sum_{i=1}^N \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) = \sum_{i=1}^N y_i \cdot \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi})$$

$$a_0 \sum_{i=1}^N \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) + a_1 \sum_{i=1}^N \varphi_1(x_{1i}, x_{2i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi}) +$$

$$\dots + a_n \sum_{i=1}^N \varphi_n^2(x_{1i}, x_{2i}, \dots, x_{mi}) = \sum_{i=1}^N y_i \cdot \varphi_n(x_{1i}, x_{2i}, \dots, x_{mi})$$

Запишем систему линейных уравнений в матричной форме

$$\begin{pmatrix}
 N & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) \\
 \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1^2(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) \\
 \dots & \dots & \dots & \dots \\
 \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n^2(x_{1i}, \dots, x_{mi})
 \end{pmatrix} \cdot \begin{pmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{pmatrix} =$$

$$= \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N y_i \varphi_1(x_{1i}, \dots, x_{mi}) \\ \dots \\ \sum_{i=1}^N y_i \varphi_n(x_{1i}, \dots, x_{mi}) \end{pmatrix}$$

Решим систему методом Крамера

Для этого необходимо, чтобы

$$D = \begin{vmatrix} N & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) \\ \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1^2(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) \\ \dots & \dots & \dots & \dots \\ \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n^2(x_{1i}, \dots, x_{mi}) \end{vmatrix} \neq 0$$

Тогда

$$D_0 = \begin{vmatrix} \sum_{i=1}^N y_i & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) \\ \sum_{i=1}^N y_i \varphi_1(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1^2(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) \\ \dots & \dots & \dots & \dots \\ \sum_{i=1}^N y_i \varphi_n(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n^2(x_{1i}, \dots, x_{mi}) \end{vmatrix}$$

$$a_0 = \frac{D_0}{D}$$

$$D_1 = \begin{vmatrix} N & \sum_{i=1}^N y_i & \dots & \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) \\ \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N y_i \varphi_1(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) \\ \dots & \dots & \dots & \dots \\ \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N y_i \varphi_n(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N \varphi_n^2(x_{1i}, \dots, x_{mi}) \end{vmatrix}$$

$$a_1 = \frac{D_1}{D}$$

Последний определитель будет

$$D_n = \begin{vmatrix} N & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N y_i \\ \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1^2(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N y_i \varphi_1(x_{1i}, \dots, x_{mi}) \\ \dots & \dots & \dots & \dots \\ \sum_{i=1}^N \varphi_n(x_{1i}, \dots, x_{mi}) & \sum_{i=1}^N \varphi_1(x_{1i}, \dots, x_{mi}) \cdot \varphi_n(x_{1i}, \dots, x_{mi}) & \dots & \sum_{i=1}^N y_i \varphi_n(x_{1i}, \dots, x_{mi}) \end{vmatrix}$$

$$a_n = \frac{D_n}{D}$$

Определители раскрываются через миноры

$$\begin{vmatrix} d_{11} & d_{12} & \dots & d_{1n} \\ d_{21} & d_{22} & \dots & d_{2n} \\ \dots & \dots & \dots & \dots \\ d_{n1} & d_{n2} & \dots & d_{nn} \end{vmatrix} = d_{11} \cdot (-1)^{1+1} \cdot \begin{vmatrix} d_{22} & \dots & d_{2n} \\ \dots & \dots & \dots \\ d_{n2} & \dots & d_{nn} \end{vmatrix} + d_{12} \cdot (-1)^{1+2} \cdot \begin{vmatrix} d_{21} & d_{13} \dots & d_{2n} \\ \dots & \dots & \dots \\ d_{n1} & d_{n3} \dots & d_{nn} \end{vmatrix} +$$
$$+ d_{13} \cdot (-1)^{1+3} \cdot \begin{vmatrix} d_{21} & d_{22} & d_{24} \dots & d_{2n} \\ \dots & \dots & \dots & \dots \\ d_{n1} & d_{n2} & d_{n4} \dots & d_{nn} \end{vmatrix} + \dots + d_{1n} \cdot (-1)^{1+n} \cdot \begin{vmatrix} d_{21} & \dots & d_{2n-1} \\ \dots & \dots & \dots \\ d_{n1} & \dots & d_{nn-1} \end{vmatrix}$$

В Excel определители можно посчитать с помощью функции МОПРЕД(определитель).

Эконометрика

КОРРЕЛЯЦИЯ ДЛЯ НЕЛИНЕЙНОЙ РЕГРЕССИИ.
КОЭФФИЦИЕНТЫ ЭЛАСТИЧНОСТИ

Корреляция в случае нелинейной регрессии

Уравнение нелинейной регрессии дополняется показателями корреляции:

$$R^2 = \frac{\delta^2}{\sigma^2} = \left(1 - \frac{\varepsilon^2}{\sigma^2}\right) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$

где δ^2 – объясненная уравнением регрессии дисперсия результирующего признака, а ε^2 – остаточная (необъясненная уравнением регрессии) дисперсия результирующего признака, σ^2 – полная дисперсия результирующего признака. Величину R^2 называют показателем (индексом) корреляции. Она изменяется в границах от 0 до 1 и чем она ближе к 1, тем теснее связь рассматриваемых признаков, тем более надежно уравнение регрессии.

Коэффициенты эластичности

□ характеристика силы связи фактора с результатом, показывающая, на сколько процентов изменится значение результата при изменении каждого фактора на 1%. Коэффициент эластичности (в случае парной регрессии) рассчитывается как:

$$\varepsilon = \frac{dy}{dx} \cdot \frac{y}{x} = \frac{dy}{dx} \cdot \frac{x}{y}$$

Различают

Средние коэффициенты эластичности

$$\bar{\varepsilon}_x = \frac{dy}{dx} \cdot \frac{\bar{x}}{\bar{y}(x)}$$

и точечные коэффициенты эластичности

$$\varepsilon_{x_0} = \frac{dy}{dx} \cdot \frac{x_0}{y(x_0)}$$

Они показывают на сколько процентов изменится значение y при росте x на 1% относительно среднего уровня или уровня x_0 .

Введем коэффициенты эластичности для различных функций регрессии

1. Для линейной функции $y = \alpha + \beta x$

Коэффициент эластичности будет:

$$\mathcal{E}_{(x_0)} = \frac{\beta x_0}{\alpha + \beta x_0}, \quad \mathcal{E}_{\bar{x}} = \frac{\beta \bar{x}}{\alpha + \beta \bar{x}}$$

2. Для параболы $y = \alpha + \beta x + \gamma x^2$

Коэффициент эластичности будет:

$$\mathcal{E}_{(x_0)} = \frac{(\beta + 2\gamma x_0)x_0}{\alpha + \beta x_0 + \gamma x_0^2}, \quad \mathcal{E}_{\bar{x}} = \frac{(\beta + 2\gamma \bar{x})\bar{x}}{\alpha + \beta \bar{x} + \gamma \bar{x}^2}$$

Введем коэффициенты эластичности для различных функций регрессии

3. Для равносторонней гиперболы $y = \alpha + \frac{\beta}{x}$

Коэффициент эластичности будет:

$$\mathcal{E}_{(x_0)} = \frac{-\beta}{x_0^2} \cdot \frac{1}{\alpha + \frac{\beta}{x_0}} \cdot x_0 = \frac{-\beta x_0}{x_0^2 \cdot (\alpha x_0 + \beta)} =$$

$$\frac{-\beta}{\alpha x_0 + \beta}, \quad \mathcal{E}_x = \frac{-\beta}{\alpha x + \beta}$$

4. Для степенной функции $y = \alpha + x^\beta$

Коэффициент эластичности будет:

$$\mathcal{E}_{(x_0)} = \frac{\alpha \cdot \beta x_0^\beta}{\alpha \cdot x_0^\beta} = \beta, \quad \mathcal{E}_x = \beta$$

Введем коэффициенты эластичности для различных функций регрессии

5. Для показательной функции

$$y = \alpha \cdot \beta^x$$

Коэффициент эластичности будет:

$$\mathcal{E}_{(x_0)} = \frac{\alpha \ln \beta \cdot \beta^{x_0} \cdot x_0}{\alpha \beta^{x_0}} = x_0 \ln \beta, \quad \mathcal{E}_{\bar{x}} = \bar{x} \cdot \ln \beta$$

Частные коэффициенты

В случае многомерной функции регрессии можно рассчитать **частные коэффициенты эластичности** показывают на сколько процентов в среднем изменяется результат с увеличением конкретного фактора x_j на 1% от своего среднего уровня при фиксированном положении других факторов модели. Частный коэффициент эластичности рассчитываются по формуле

$$\varepsilon_j = \frac{\partial y}{\partial x_j} \cdot \frac{\overline{x_j}}{y(x_1, \dots, x_n)}, \quad j = 1, \dots, n$$

β -коэффициенты

Для характеристики степени связи между результирующей переменной и факторными признаками в случае многомерной регрессии используются еще и **стандартизованные частные коэффициенты регрессии** – β -коэффициенты. Они показывают, на какую часть своего среднего квадратического отклонения σ_{ij} изменится результат y с увеличением соответствующего фактора x_j на величину своего среднего квадратического отклонения σ_{xj} при неизменном влиянии прочих факторов модели.

Частные коэффициенты эластичности и β -коэффициенты можно использовать для ранжирования факторов по силе их влияния на результат. Чем они больше для соответствующего фактора, тем сильнее влияние этого фактора на результат.

Получение β -коэффициентов

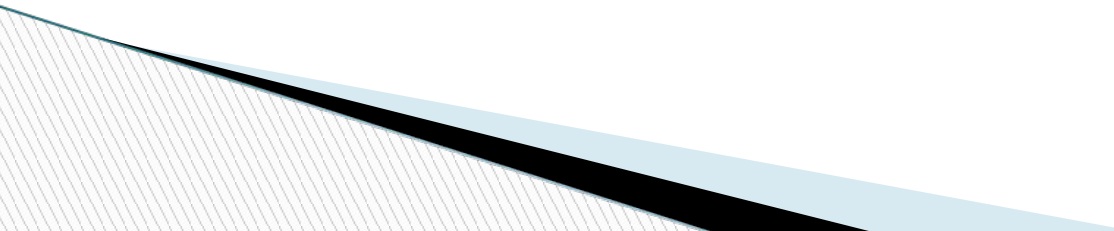
Расчет β -коэффициентов осуществляется с помощью нахождения коэффициентов регрессии стандартизованной системы линейных уравнений.

Вводится стандартизованная переменная:

$$t_{x_{ji}} = \frac{x_{ji} - \bar{x}_j}{\sigma_{x_j}}, \quad j = 1, \dots, m, \quad t_{y_i} = \frac{y_i - \bar{y}}{\sigma_y}$$

Таким образом, начало отсчета каждой стандартизованной переменной совмещается с ее средним значением, а в качестве единицы изменения принимается ее среднее квадратическое отклонение (σ). Если связь между переменными в естественном масштабе линейная, то изменение начала отсчета и единицы изменения этого свойства не нарушат.

Частные коэффициенты эластичности

- Эмпирические частные коэффициенты эластичности;
 - Частные коэффициенты эластичности или оценки частных коэффициентов эластичности.
- 

Эмпирические частные коэффициенты эластичности

Рассчитываются по каждому фактору модели, для j фактора он будет равен:

$$\mathcal{E}_{ji} = \frac{\Delta y_i}{\Delta x_{ji}} \cdot \frac{x_{ji}}{y_i},$$

где $\Delta y_i = y_i - y_{i-1}$, $\Delta x_{ji} = x_{ji} - x_{ji-1}$

Итоговый коэффициент эластичности равен

$$\bar{\mathcal{E}}_j = \frac{1}{m} \cdot \sum_{i=1}^m \mathcal{E}_{ji},$$

Оценки частных коэффициентов эластичности

Рассчитываются для каждого фактора модели. Для j фактора они равны

$$\hat{\varepsilon}_{ji} = \hat{a}_j \cdot \frac{\hat{x}_{ji}}{\hat{y}_i}$$

Итоговый коэффициент для каждого фактора равен:

$$\overline{\hat{\varepsilon}_{ji}} = \frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_{ji}$$

Частная корреляция

Показатели парной корреляции – r_{yx} характеризуют тесноту связи результата и фактора, не принимая во внимание возможного влияния на результат других факторов модели. Поэтому в множественном регрессионном анализе возникает проблема определения тесноты связи между двумя разными факторами.

$$r_{yx_i / x_1 \dots x_{i-1}, x_{i+1} \dots x_m} = \sqrt{1 - \frac{1 - R_{y(x_1 \dots x_m)}^2}{1 - R_{y(x_1 \dots x_{i-1}, x_{i+1} \dots x_m)}^2}}$$

где $R_{y(x_1 \dots x_m)}^2$ - коэффициент множественной детерминации у с комплексом факторов x_1, \dots, x_m ;

а $R_{y(x_1 \dots x_{i-1}, x_{i+1} \dots x_m)}^2$ - коэффициент множественной детерминации у с комплексом факторов $x_1 \dots x_{i-1}, x_{i+1} \dots x_m$

Частная корреляция

Частные коэффициенты корреляции используются для ранжирования факторов в модели по степени влияния на результат.

Они изменяются на промежутке от 0 до 1, и чем ближе они к 1, тем сильнее влияет этот фактор на результат, а чем ближе к 0, тем слабее.

Их также используют для **отсева факторов**.

Эконометрика

ПРОБЛЕМА МУЛЬТИКОЛЛИНЕАРНОСТИ.
ФИКТИВНЫЕ ПЕРЕМЕННЫЕ



Мультиколлинеарность

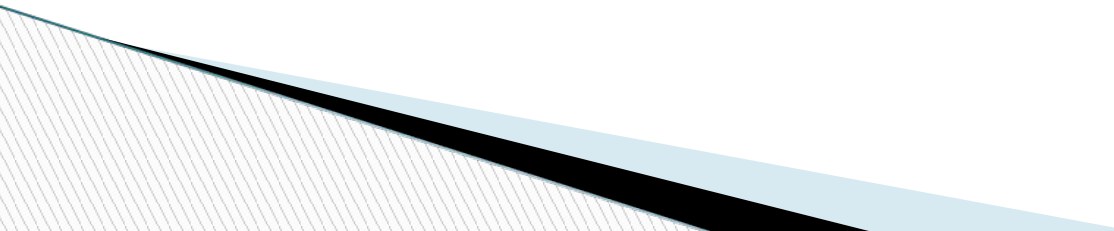
Мультиколлинеарность – это нестрогая линейная зависимость между факторными признаками (что противоречит предпосылкам применения МНК для поиска параметров функции регрессии).

Мультиколлинеарность может привести к следующим неприятным последствиям:

- Оценки параметров станут ненадежными (большие статистические ошибки, малая значимость), при этом сама модель может быть в целом значима (завышенное значение множественного коэффициента корреляции).
- Небольшое изменение исходных данных приведет к существенному изменению оценок параметров регрессии.
- Оценки параметров модели будут иметь неправильные с точки зрения теории знаки или чрезмерно большие значения (модель будет непригодна для прогнозирования).
- Делает невозможным определение изолированного влияния факторов на результат.

Снижение мультиколлинеарности

Мультиколлинеарность не всегда оказывает неблагоприятное влияние, если другие условия благоприятны:

- Число наблюдений значительно.
 - Выборочные дисперсии факторов велики, а дисперсия случайной составляющей мала.
 - При условии влияния этих благоприятных факторов, оценки параметров могут оказаться вполне приемлемы.
- 

Обнаружение мультиколлинеарности

На практике о наличии мультиколлинеарности судят:

По матрице парных коэффициентов корреляции
(корреляционной матрице):

$$\begin{pmatrix} 1 & r_{01} & \dots & r_{0j} & \dots & r_{0n} \\ r_{10} & 1 & \dots & r_{1j} & \dots & r_{1n} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ r_{j0} & r_{j1} & \dots & 1 & \dots & r_{jn} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ r_{n0} & r_{n1} & \dots & r_{nj} & \dots & 1 \end{pmatrix},$$

где r_{jk} – коэффициенты парной линейной корреляции между j -м и k -м факторами ($j, k=1, \dots, n$), а r_{0j} – коэффициент парной линейной корреляции между результатом и j -м фактором ($j=1, \dots, n$). На главной диагонали стоят единицы, так как там стоят коэффициенты, показывающие степень связи признаков самих с собой. Матрица является симметричной относительно главной диагонали ($r_{jk}=r_{kj}$).

На практике можно воспользоваться

Парными коэффициентами корреляции:

$$r_{x_j y} = \frac{\sum_{i=1}^N (x_{ji} - \bar{x}_j)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_{ji} - \bar{x}_j)^2} \cdot \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}},$$

$$r_{x_j x_k} = \frac{\sum_{i=1}^N (x_{ji} - \bar{x}_j)(x_{ki} - \bar{x}_k)}{\sqrt{\sum_{i=1}^N (x_{ji} - \bar{x}_j)^2} \cdot \sqrt{\sum_{i=1}^N (x_{ki} - \bar{x}_k)^2}},$$

Если имеет место мультиколлинеарность, то в модель следует включать не все факторы, а только те факторы, которые менее ответственны за нее (имеют меньшие по модулю значения коэффициентов корреляции), при условии, что качество модели **снижается несущественно**.

Обнаружение мультиколлинеарности

2. По величине коэффициентов множественной детерминации

$$R^2_{x_j(x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_n)} = \sum_{j=1}^m \beta_j \cdot r_{yx_i} =$$
$$= 1 - \frac{\sum_{i=1}^N \left(y_i - \hat{y}_{x_j(x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_n)} \right)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}$$

которые показывают зависимость фактора x_j других факторов. Чем он ближе этот коэффициент к 1, тем больше ответственность за мультиколлинеарность конкретного фактора. Сравнивая коэффициенты множественной детерминации для различных факторов, можно проранжировать их по степени ответственности за мультиколлинеарность.

Фиктивные переменные

В некоторых случаях в модель необходимо ввести некоторую качественную переменную, изменение которой может существенно влиять на результат.

В данном случае качественная переменная может быть введена в уравнение в форме фиктивной переменной. Для этого вводится система цифровых обозначений и в модель включается фактор, принимающий одно из значений в рамках заданной системы.

Например, разный уровень образования работников дает разный прирост уровня их заработной платы и может быть введен в модель наравне с возрастом и стажем.