

# Множественный регрессионный анализ

**Множественная регрессия** – это уравнение связи с несколькими независимыми переменными:

$$y = f(x_1, x_2, \dots, x_p) + \varepsilon$$



часть значения  $y$ ,  
которая объяснена  
уравнением регрессии  
с несколькими  
факторами



необъясненная  
часть значения  $y$   
(или возмущение)

# Построение уравнения регрессии

## 1. Постановка задачи

По имеющимся данным  $n$  наблюдений за совместным изменением параметров  $y$ ,  $x_j$  и  $((y_i, x_j, i); j=1, 2, \dots, p; i=1, 2, \dots, n)$  необходимо определить аналитическую зависимость  $\hat{y} = f(x_1, x_2, \dots, x_p)$ , наилучшим образом описывающую данные наблюдений.

### Данные наблюдений

	$y$	$X_1$	$X_2$	...	$X_p$
1	$y_1$	$x_{11}$	$x_{21}$	...	$x_{p1}$
2	$y_2$	$x_{12}$	$x_{22}$	...	$x_{p2}$
...	...	...	...	...	...
$n$	$y_n$	$x_{1n}$	$x_{2n}$	...	$x_{pn}$

**Критерий качества  
выбранной зависимости:**

$$S = \sum (y_i - \hat{y}_i)^2 \rightarrow \min$$

## 2. Спецификация модели

### 2.1. Отбор факторов, подлежащих включению в модель

#### Требования к отбираемым факторам

Факторы не должны  
быть взаимно  
коррелированы

Факторы должны  
быть количественно  
измеримы

#### Пример:

$y$  – себестоимость единицы  
продукции

$x$  – заработная плата  
работника

$z$  – производительность  
труда

$$y = 22600 - 5x - 10z + \varepsilon$$

$$r_{xz} = 0,95$$

- ✓ целесообразность включения каждого нового фактора оценивается с помощью коэффициента детерминации;
- ✓ при возникновении необходимости добавить в уравнение качественный фактор вводится «фиктивная» переменная

## Парная коллинеарность и мультиколлинеарность

Две переменные считаются **явно коллинеарными**, т.е. находятся между собой в линейной зависимости, если **коэффициент интеркорреляции** (корреляции между двумя объясняющими переменными)  $\geq 0,7$ .

Если факторы явно коллинеарны, то они дублируют друг друга и один из них рекомендуется исключить из уравнения.

**Мультиколлинеарность** – линейная зависимость между более чем двумя переменными, т.е. совокупное воздействие факторов друг на друга.

## ***Включение в модель мультиколлинеарных факторов нежелательно***

***по следующим причинам:***

- затрудняется интерпретация параметров множественной регрессии; параметры линейной регрессии теряют экономический смысл;
- оценки параметров не надежны, имеют большие стандартные ошибки и меняются с изменением количества наблюдений (не только по величине, но и по знаку), что делает модель непригодной для анализа и прогнозирования.

## Оценка мультиколлинеарности

Для оценки мультиколлинеарности используется **определитель матрицы парных коэффициентов интеркорреляции:**

**(!) Если факторы не коррелируют между собой**, то матрица коэффициентов интеркорреляции является единичной, поскольку в этом случае все недиагональные элементы равны 0.

Например, для уравнения с тремя переменными

$$y = a + b_1x_1 + b_2x_2 + b_3x_3 + \varepsilon$$

$$\text{Det}(R) = |R| = \begin{vmatrix} r_{x_1x_1} & r_{x_2x_1} & r_{x_3x_1} \\ r_{x_1x_2} & r_{x_2x_2} & r_{x_3x_2} \\ r_{x_1x_3} & r_{x_2x_3} & r_{x_3x_3} \end{vmatrix} = \begin{vmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{vmatrix} = 1$$

**(!) Если между факторами существует полная линейная зависимость** и все коэффициенты корреляции равны 1, то определитель такой матрицы равен 0.

$$\text{Det}(R) = |R| = \begin{vmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{vmatrix} = 0$$

**Чем ближе к 0** определитель матрицы коэффициентов интеркорреляции, тем сильнее мультиколлинеарность и ненадежнее результаты множественной регрессии.

**Чем ближе к 1** определитель матрицы коэффициентов интеркорреляции, тем меньше мультиколлинеарность факторов.

## Способы преодоления мультиколлинеарности факторов:

- исключение из модели одного или нескольких факторов;
- переход к совмещенным уравнениям регрессии, т.е. к уравнениям, которые отражают не только влияние факторов, но и их взаимодействие. *Например,*  
если  $y = f(x_1, x_2, x_3)$ , то можно построить следующее совмещенное уравнение:  
$$y = a + b_1x_1 + b_2x_2 + b_3x_3 + b_{12}x_1x_2 + b_{13}x_1x_3 + b_{23}x_2x_3 + \varepsilon$$
- переход к уравнениям приведенной формы (в уравнение регрессии подставляется рассматриваемый фактор, выраженный из другого уравнения).

## 2. Спецификация модели

### 2.2. Выбор формы уравнения регрессии

- **Линейная регрессия**

$$y = a + b_1x_1 + b_2x_2 + \dots + b_px_p + \varepsilon$$

- **Линеаризуемые регрессии**

- **Степенная регрессия**

$$y = ax_1^{b_1} x_2^{b_2} \dots x_p^{b_p} \varepsilon$$

- **Экспоненциальная регрессия**

$$y = e^{a+b_1x_1+b_2x_2+\dots+b_px_p+\varepsilon}$$

- **Гиперболическая регрессия**

$$y = \frac{1}{a + b_1x_1 + b_2x_2 + \dots + b_px_p + \varepsilon}$$

Например, зависимость спроса на товар ( $Q_d$ ) от цены ( $P$ ) и дохода ( $I$ ) характеризуется следующим уравнением:

$$Q_d = 2,5 - 0,12P + 0,23 I.$$

Коэффициенты данного уравнения говорят о том, что при увеличении цены на единицу, спрос уменьшится в среднем на 0,12 единиц, а при увеличении дохода на единицу, спрос возрастет в среднем 0,23 единицы.

Например, зависимость выпуска продукции  $Y$  от затрат капитала  $K$  и труда  $L$ :

$$Y = 0.89K^{0.23}L^{0.81}$$

говорит о том, что увеличение затрат капитала  $K$  на 1% при неизменных затратах труда вызывает увеличение выпуска продукции  $Y$  на 0,23%.

Увеличение затрат труда  $L$  на 1% при неизменных затратах капитала  $K$  вызывает увеличение выпуска продукции  $Y$  на 0,81%.



## Решение системы уравнений с помощью метода определителей:

$$a = \frac{\Delta a}{\Delta}, \quad b_1 = \frac{\Delta b_1}{\Delta}, \quad \dots, \quad b_p = \frac{\Delta b_p}{\Delta}$$

где  $\Delta$  – определитель системы:

$$\Delta = \begin{vmatrix} n & \sum x_1 & \sum x_2 & \dots & \sum x_p \\ \sum x_1 & \sum x_1^2 & \sum x_2 x_1 & \dots & \sum x_p x_1 \\ \sum x_2 & \sum x_1 x_2 & \sum x_2^2 & \dots & \sum x_p x_2 \\ \dots & \dots & \dots & \dots & \dots \\ \sum x_p & \sum x_1 x_p & \sum x_2 x_p & \dots & \sum x_p^2 \end{vmatrix}$$

$\Delta a$ ,  $\Delta b_1$ ,  $\Delta b_p$  – частные определители ( $\Delta_j$ ), которые получаются из основного определителя путем замены  $j$ -го столбца на столбец свободных членов

$$\begin{pmatrix} \sum y \\ \sum yx_1 \\ \dots \\ \sum yx_p \end{pmatrix}$$

### 3. Оценка параметров модели

#### 3.2. Метод оценки параметров через стандартизованные коэффициенты $\beta$

**Уравнение регрессии в стандартизованном (нормированном) масштабе:**

$$t_y = \beta_1 t_{x_1} + \beta_2 t_{x_2} + \dots + \beta_p t_{x_p}$$

где  $t_y = \frac{y - \bar{y}}{\sigma_y}$ ,  $t_{x_i} = \frac{x_i - \bar{x}_i}{\sigma_{x_i}}$  - стандартизованные переменные

$\beta$  - стандартизованные коэффициенты регрессии.

$\beta$ -коэффициенты показывают, на сколько сигм (средних квадратических отклонений) изменится в среднем результат за счет изменения соответствующего фактора  $x_i$  на одну сигму при неизменном среднем уровне других факторов.

## Взаимосвязь $b_i$ и $\beta$

Связь коэффициентов «чистой» регрессии  $b_i$  с коэффициентами  $\beta_i$  описывается соотношением:

$$b_i = \beta_i \frac{\sigma_y}{\sigma_{x_i}} \quad \text{или} \quad \beta_i = b_i \frac{\sigma_{x_i}}{\sigma_y} \quad (i = 1, 2, \dots, p)$$

Коэффициенты  $\beta$  определяются при помощи МНК из следующей системы уравнений методом определителей:

$$\begin{cases} r_{yx_1} = \beta_1 + \beta_2 r_{x_2 x_1} + \beta_3 r_{x_3 x_1} + \dots + \beta_p r_{x_p x_1}, \\ r_{yx_2} = \beta_1 r_{x_2 x_1} + \beta_2 + \beta_3 r_{x_3 x_2} + \dots + \beta_p r_{x_p x_2}, \\ r_{yx_p} = \beta_1 r_{x_p x_1} + \beta_2 r_{x_p x_2} + \beta_3 r_{x_p x_3} + \dots + \beta_p \end{cases}$$

**Параметр  $a$  определяется как:**

$$a = \bar{y} - b_1 \bar{x}_1 - b_2 \bar{x}_2 - \dots - b_p \bar{x}_p$$

## 4. Проверка качества уравнения регрессии

Но: уравнение статистически не значимо

$$\begin{array}{rcc} y_i & = & \hat{y}_i + \varepsilon_i \\ D(y) & = & D(\hat{y}) + D(\varepsilon) \\ \downarrow & & \downarrow \\ \frac{1}{n} \sum (y - \bar{y})^2 & = & \frac{1}{n} \sum (\hat{y} - \bar{y})^2 + \frac{1}{n} \sum (y - \hat{y})^2 \end{array}$$

**полная (общая) сумма квадратов отклонений** = **сумма квадратов отклонений, объясненная регрессией** + **(остаточная) сумма квадратов отклонений, не объясненная регрессией**

## **F-критерий Фишера:**

$$F = \frac{\frac{D(\hat{y})}{k}}{\frac{D(\varepsilon)}{n - m - 1}} \quad \text{или} \quad \frac{R^2}{1 - R^2} \times \frac{n - m - 1}{m}$$

где  $m$  – число независимых переменных в уравнении

регрессии;

$n$  – число единиц совокупности.

Если **Fфакт** > **Fтабл**, то  $H_0$  о случайной природе связи отклоняется и признается статистическая значимость и надежность уравнения.

Если **Fфакт** < **Fтабл**, то  $H_0$  не отклоняется и признается статистическая незначимость уравнения регрессии.

## Частный F-критерий:

$$F_{\text{част}x_i} = \frac{R^2_{yx_1 \dots x_i \dots x_p} - R^2_{yx_1 \dots x_{i-1} x_{i+1} \dots x_p}}{1 - R^2_{yx_1 \dots x_i \dots x_p}} \cdot \frac{n - m - 1}{1}$$

- оценивает статистическую значимость присутствия каждого из факторов в уравнении.