

# КЛАССИЧЕСКИЙ РЕГРЕССИОННЫЙ АНАЛИЗ

## Оценки модели линейной регрессии

### Построение модели

#### Слайд 2

Пусть  $n$ -вектор  $\mathbf{Y}$ , связан с  $q$ -мерной *нестуточной векторной переменной*  $\mathbf{x} = [\mathbf{x}_1, \dots, \mathbf{x}_q]'$ . Значения  $Y_i, i = 1, \dots, n$ , полученные в эксперименте при заданных  $\mathbf{x}_i = [\mathbf{x}_{i1}, \dots, \mathbf{x}_{iq}]'$ , случайным образом изменяются около некоторого неизвестного истинного уровня  $\eta(\mathbf{x}_i)$ . Тогда можем записать

$$Y_i = \eta(\mathbf{x}_i) + \varepsilon_i, i = 1, \dots, n, \quad (1)$$

где  $\varepsilon_i$  – случайная ошибка, которая объясняет отклонение  $Y_i$  от величины  $\eta(\mathbf{x}_i)$ . При этом  $\varepsilon$  может быть случайной компонентой, присущей величине  $\eta(\mathbf{x})$ , и представлять случайную ошибку измерения значений  $\mathbf{Y}$  или влияние различных неучтенных факторов. Предположим, что  $\eta(\mathbf{x})$  можно описать линейной моделью первого порядка по  $\mathbf{x}_j$  с  $q$  переменными

$$\eta(\mathbf{x}, \boldsymbol{\beta}) = \beta_0 + \beta_1 \mathbf{x}_1 + \dots + \beta_q \mathbf{x}_q.$$

где  $\boldsymbol{\beta} = [\beta_0, \beta_1, \dots, \beta_q]'$  – вектор неизвестных параметров (коэффициентов), подлежащий оцениванию. Тогда получим

$$\mathbf{Y} = \beta_0 + \beta_1 \mathbf{x}_1 + \dots + \beta_q \mathbf{x}_q + \boldsymbol{\varepsilon} \quad (2)$$

Если в формуле (2)  $\mathbf{M}\boldsymbol{\varepsilon} = 0$ , то условное математическое ожидание случайного вектора  $\mathbf{Y}$  при заданных переменных  $\mathbf{x}_j, j = 1, \dots, q$  равно

$$\mathbf{M}[\mathbf{Y}/\mathbf{x}] = \beta_0 + \beta_1 \mathbf{x}_1 + \dots + \beta_q \mathbf{x}_q \quad (3)$$

Уравнение (3), в котором  $\mathbf{x}$  играет роль «независимой» переменной, называется *уравнением регрессии* или просто *регрессией*.

Термин «регрессия» впервые был введен Ф. Гальтоном<sup>1</sup> (1886) в теории наследственности для обозначения явления «возврата к среднему состоянию» (*regression to mediocrity*), состоящего в том, что дети тех родителей, рост которых превышает среднее значение на  $a$  единиц, имеют в среднем рост, превышающий среднее значение меньше чем на  $a$  единиц.

В дальнейшем переменные<sup>1</sup>  $\mathbf{Y}, \mathbf{x}_j, j = 1, \dots, q$  и  $\boldsymbol{\varepsilon}$  будем называть *откликом, регрессорами* и *остатком* (используются другие названия этих переменных: выход, зависимая или эндогенная переменная; факторы, предикторы, входные, экзогенные или независимые переменные; ошибка, помеха, невязка).

Когда используется уравнение (2) при анализе совокупности данных и оценивается вектор параметров  $\boldsymbol{\beta}$ , то предполагается, что элементы этой совокупности *однородны* в смысле подчинения одному и тому же причинному закону. Это означает, что параметры  $\beta_j$  приемлемы для каждого отдельно взятого наблюдения.

#### Слайд 3

**Пример 1.** Идентификация статических характеристик сложного объекта, выходы которого, измеряемые со случайными ошибками, является функциями многих входных переменных.

<sup>1</sup> Гальтон (Galton) Фрэнсис (16.02.1822 – 17.01.1911) – английский психолог и антрополог.

<sup>1</sup> Следуя большинству книг по регрессионному анализу, случайный вектор-отклик и матрицы будем обозначать полужирными прописными буквами; векторы-регрессоры и вектор-остаток строчными полужирными буквами.

Необходимо по наблюдениям входов и выходов определить эти функции. В общем случае совокупность переменных, определяющих текущее состояние сложного объекта, можно описать следующими группами входных и выходных переменных (рис. 1).

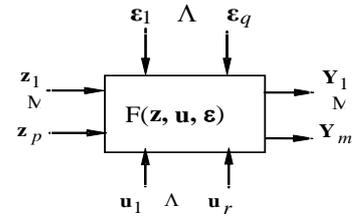


Рис. 1. Модель сложного объекта

1. *Контролируемые неуправляемые переменные*  $\mathbf{z} = (z_1, \dots, z_p)$ , значения этих переменных можно измерить, но нельзя произвольно изменить.
2. *Контролируемые управляющие переменные*  $\mathbf{u} = (u_1, \dots, u_r)$ , значения, которых в любой момент времени можно изменить в пределах допустимого диапазона.
3. *Неконтролируемые неуправляемые переменные*  $\boldsymbol{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_q)$ , которые характеризуют множество реально существующих факторов, влияющих на текущее состояние объекта, но недоступных контролю и управлению.
4. *Контролируемые управляемые переменные*  $\mathbf{Y} = (Y_1, \dots, Y_m)$ , которые характеризуют результат функционирования объекта.

Входные переменные  $\mathbf{z}, \mathbf{u}, \boldsymbol{\varepsilon}$  могут рассматриваться как причины, оказывающие влияние на каждую из выходных переменных  $\mathbf{Y}_i$ .

При общем рассмотрении нет необходимости разделять контролируемые переменные  $(\mathbf{z}, \mathbf{u})$  поэтому объединим их в одну группу и обозначим  $\mathbf{X}$ . Далее будем полагать, что  $x_j$  при  $j = 1, \dots, q$  – неслучайные контролируемые независимые переменные;  $\boldsymbol{\varepsilon}$  – случайная неконтролируемая переменная (остаток, помеха, ошибка). Так как каждая из выходных переменных  $\mathbf{Y}_i$  полностью определяется в вероятностном смысле группой входных переменных  $\mathbf{X}$  и остатком  $\boldsymbol{\varepsilon}$ , то достаточно рассмотреть схему с одной выходной переменной (откликом). Будем полагать, что случайная остаток  $\boldsymbol{\varepsilon}$  аддитивно приложен к выходной переменной  $\mathbf{Y}$ , т. е.  $\mathbf{Y} = \boldsymbol{\eta} + \boldsymbol{\varepsilon}$ . Тогда физическую модель, характеризующую зависимость  $\mathbf{Y}$  от  $\mathbf{X}$  можно выразить уравнением (1).

#### Слайд 4

Структурная схема объекта, соответствующая этой модели, приведена на рис. 2.

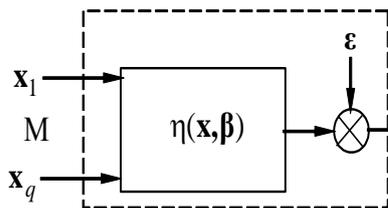


Рис. 2. Структурная схема объекта

Тогда

$$Y_i = \eta(0, \mathbf{K}, 0) + \sum_{j=1}^q \left( \frac{\partial \eta}{\partial x_j} \right)_0 x_{ij} + \frac{1}{2} \sum_j \sum_k \left( \frac{\partial^2 \eta}{\partial x_j \partial x_k} \right)_0 x_{ij} x_{ik} + \mathbf{K} + \varepsilon_i.$$

Обозначив постоянные

$$\beta_0 = (0, \mathbf{K}, 0), \quad \beta_j = (\partial \eta / \partial x_j)_0, \quad \beta_{jk} = (1/2)(\partial^2 \eta / \partial x_j \partial x_k)_0,$$

получим

$$Y_i = \beta_0 + \sum_{j=1}^q \beta_j x_{ij} + \sum_j \sum_k \beta_{jk} x_{ij} x_{ik} + \mathbf{K} + \varepsilon_i.$$

В общем случае функция  $\boldsymbol{\eta}(\mathbf{x}, \boldsymbol{\beta})$  нелинейна относительно вектора параметров  $\boldsymbol{\beta}$ . Простейшим и важнейшим для практики является случай линейной зависимости  $\boldsymbol{\eta}(\mathbf{x}, \boldsymbol{\beta})$  от  $\boldsymbol{\beta}$ . Линейную регрессионную модель можно получить, разложив  $\boldsymbol{\eta}(\mathbf{x}, \boldsymbol{\beta})$  в ряд Тейлора в точке  $\mathbf{x}_0 = 0$ .

Ограничимся рассмотрением в этом уравнении только первых двух членов, случайные ошибки и ошибки за счет неучтенных членов ряда отнесем к остатку  $\varepsilon$ . При этом будем полагать, что неучтенные члены *не коррелированы* с учтенными. Тогда уравнение можно переписать в виде модели линейной регрессии (2). ■

Модель вида (2) является весьма общей и очень широко используется. Частными случаями ее являются, например, полиномиальная модель  $q$ -го порядка одной переменной

$$Y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \dots + \beta_q x_i^q + \varepsilon_i,$$

Основное свойство модели вида (2) заключается в ее *линейности* по отношению к неизвестному вектору коэффициентов  $\beta$ . По сравнению с ней, например, модель

$$Y_i = \beta_0 + \beta_1 e^{-\beta_2 x_i} + \varepsilon_i$$

нелинейная по параметру  $\beta_2$ .

## Слайд 5

Рассмотрим оценки  $\hat{\beta}$  вектора коэффициентов  $\beta$  регрессионной модели (3). При этом будем различать два типа оценок. Первый – точечные оценки, получаемые на основании наблюдаемых данных регрессоров и отклика. Второй тип оценок связан с построением доверительных областей (интервалов) в пространстве оценок, которые с заданной вероятностью «накрывают» неизвестное истинное значение. Анализ уравнения (3) и оценку его коэффициентов будем проводить с использованием матричной алгебры. Применение матриц упрощает расчеты и придает им наглядность.

### Оценивание параметров. Свойства оценок

Рассмотрим схему, изображенную на рис. 2, где пунктиром выделена ненаблюдаемая часть. Пусть отклик  $Y$  связан с входами полиномом вида (2). Записывая эти  $n$  уравнений в матричной форме, получаем

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} x_{10} & x_{11} & \Lambda & x_{1q} \\ x_{20} & x_{21} & \Lambda & x_{2q} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n0} & x_{n1} & \Lambda & x_{nq} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_q \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

Или

$$Y = X\beta + \varepsilon, \tag{4}$$

где  $x_{10} = x_{20} = \dots = x_{n0} = 1$ . Матрица  $X$  типа «объект-признак» (см. п. 1.1) размера  $n \times (q + 1)$  называется *регрессионной матрицей*, столбцами которой являются регрессоры  $x_j, j = 1, \dots, q$ , а строками –  $n$  объектов или опытов;  $Y$  и  $\varepsilon$  –  $n$ -векторы отклика и остатков,  $\beta$  – подлежащий оцениванию  $(q + 1)$ -вектор неизвестных коэффициентов. В активных экспериментах элементы матрицы  $X$  выбираются равными только нулю и единице и в этом случае  $X$  называется *матрицей плана*.

Необходимо по наблюдениям  $(x_{i1}, \dots, x_{iq}, Y_i), i = 1, \dots, n$  найти наилучшую оценку  $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_q)'$  вектора коэффициентов  $\beta = (\beta_0, \beta_1, \dots, \beta_q)'$  уравнения регрессии  $\eta(x, \beta)$ . Одним из самых распространенных методов оценки вектора коэффициентов регрессии  $\beta$  является *метод наименьших квадратов* (МНК) (*least squares method*). Для обеспечения эффективности МНК-оценок должны соблюдаться следующие постулаты<sup>1</sup>:

<sup>1</sup> В реальной жизни все эти постулаты редко соблюдаются.

### Слайд 6

1. Число регрессоров  $q$  полинома (3) априори известно точно.
2. Все регрессоры измеряются без ошибок, а вычисления проводятся абсолютно точно.
3. Остаток  $\varepsilon$  является независимой нормально распределенной случайной величиной с нулевым средним  $\mathbf{M}[\varepsilon] = 0$  и неизвестной постоянной дисперсией  $\sigma_\varepsilon^2$  при всех  $i = 1, \dots, n$ .
4. Дисперсия отклика  $Y_i$  постоянна, или является известной функцией номера наблюдения  $i = 1, \dots, n$ .
5. Распределение  $Y_i$  одинаково при всех  $i = 1, \dots, n$ .
6. Число опытов  $n$  существенно больше числа регрессоров  $q$ .

### Слайд 7

Если постулаты (1 – 6) соблюдаются и  $\mathbf{X}'\mathbf{X}$  обратимая матрица, то согласно фундаментальной *теореме Гаусса-Маркова* наилучшей оценкой вектора коэффициентов  $\boldsymbol{\beta}$  является оценка  $\hat{\boldsymbol{\beta}}$ , доставляющая *минимум суммы квадратов остатков* (невязок, ошибок, помех):

$$Q(\hat{\boldsymbol{\beta}}) = \sum_{i=1}^n (Y_i - \sum_{k=0}^q x_{ik} \hat{\beta}_k)^2 \rightarrow \min.$$

Заметим, что этот остаток не может равняться нулю, так как число наблюдений  $n$  превосходит число неизвестных параметров  $q$ . Если  $Q(\hat{\boldsymbol{\beta}})$  имеет производные по  $\hat{\beta}_m$ , то необходимым условием минимума являются уравнения

$$\partial Q / \partial \hat{\beta}_m = -2 \sum_{i=1}^n (Y_i - \sum_{k=0}^q x_{ik} \hat{\beta}_k) x_{im} = 0,$$

или

$$\sum_{i=1}^n x_{im} \sum_{k=0}^q x_{ik} \hat{\beta}_k = \sum_{i=1}^n x_{im} Y_i, \quad m = 0, 1, \dots, q. \quad (5)$$

Система уравнений (5) называется *системой нормальных уравнений* (СНУ) МНК. Слово «нормальных» не связано с нормальным распределением вероятностей, а только подчеркивает, что уравнения, как правило, имеют такой «нормальный» вид.

### Слайд 8

Обозначим  $\boldsymbol{\theta} = \mathbf{X}\boldsymbol{\beta}$ ,  $\hat{\boldsymbol{\theta}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ . Будем минимизировать величину  $\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon} = \|\mathbf{Y} - \boldsymbol{\theta}\|^2$  по отношению к  $\boldsymbol{\theta} \in \Omega$ , где  $\Omega$  – подпространство оценок  $\hat{\boldsymbol{\theta}}$ . Если изменять значения вектора  $\boldsymbol{\theta}$  в пределах  $\Omega$ , то квадрат длины вектора  $\|\mathbf{Y} - \boldsymbol{\theta}\|^2$  достигнет минимума при значении  $\boldsymbol{\theta} = \hat{\boldsymbol{\theta}}$ , которое является проекцией вектора  $\mathbf{Y}$  на подпространство  $\Omega$ . Тогда справедливо  $(\mathbf{Y} - \hat{\boldsymbol{\theta}}) \perp \hat{\boldsymbol{\theta}}$  и, следовательно,  $(\mathbf{Y} - \hat{\boldsymbol{\theta}}) \perp \mathbf{X}$  (рис. 3). Отсюда для скалярного произведения  $(\mathbf{Y} - \hat{\boldsymbol{\theta}})$  и  $\mathbf{X}$  получаем

$$(\mathbf{Y} - \hat{\boldsymbol{\theta}}, \mathbf{X}) = 0$$

Или

$$\mathbf{X}'\hat{\boldsymbol{\theta}} = \mathbf{X}'\mathbf{Y}. \quad (6)$$

Если столбцы матрицы  $\mathbf{X}$  линейно независимы, то существует единственный вектор параметров  $\boldsymbol{\beta}$ , для которого  $\hat{\boldsymbol{\theta}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ . Тогда система (6) выразится в виде СНУ  $\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{Y}$ .

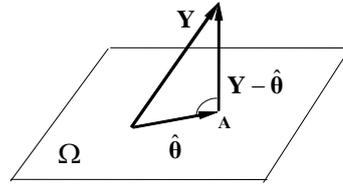


Рис. 3. Нахождение точки А, для которой норма  $\|\mathbf{Y} - \hat{\boldsymbol{\theta}}\|$  минимальна

### Слайд 9

Обозначим  $\mathbf{C} = \mathbf{X}'\mathbf{X}$ ,  $\boldsymbol{\Psi} = \mathbf{X}'\mathbf{Y}$ , тогда СНУ запишется в виде

$$\mathbf{C}\boldsymbol{\beta} = \boldsymbol{\Psi}. \quad (7)$$

Свойства матрицы  $\mathbf{C}$ :

- так как регрессоры  $\mathbf{x}_1, \dots, \mathbf{x}_q$  линейно независимы, то матрица  $\mathbf{C}$  невырождена;
- $\mathbf{C}$  положительно определена и ранг ее в точности равен  $q$ ;
- $\mathbf{C}$  – симметричная матрица,  $\mathbf{C} = \mathbf{C}'$ , т. е. является эрмитовой<sup>1</sup>.

Отсюда следует, что СНУ (6) имеет единственное решение

$$\hat{\boldsymbol{\beta}} = \mathbf{C}^{-1}\boldsymbol{\Psi} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}. \quad (8)$$

Оценка  $\hat{\boldsymbol{\beta}}$  называется *оценкой метода наименьших квадратов (МНК-оценкой)*. Так как в решении (8) матрица  $\mathbf{A} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$  неслучайная, то  $\hat{\boldsymbol{\beta}} = \mathbf{A}\mathbf{Y}$  является линейной комбинацией наблюдений  $\mathbf{Y}$ . В соответствии с теоремой Гаусса-Маркова МНК-оценка  $\hat{\boldsymbol{\beta}}$  имеет наименьшую дисперсию среди всех возможных несмещенных линейных оценок.

### Слайд 10

#### Свойства оценок

МНК-оценка  $\hat{\boldsymbol{\beta}}$  является случайной величиной. Найдем математическое ожидание оценки  $\hat{\boldsymbol{\beta}}$ . Используя решение (8) и, учитывая, что матрица  $\mathbf{X}$  является детерминированной, получаем

$$\begin{aligned} \mathbf{M}[\hat{\boldsymbol{\beta}}] &= \mathbf{M}[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}] = \mathbf{M}[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})] = \\ &= (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\boldsymbol{\beta} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{M}[\boldsymbol{\varepsilon}] = \boldsymbol{\beta}. \end{aligned}$$

Таким образом, математическое ожидание оценки вектора  $\hat{\boldsymbol{\beta}}$  равно истинному значению  $\boldsymbol{\beta}$ , т. е.  $\hat{\boldsymbol{\beta}}$  является *несмещенной оценкой*. Другими словами, если эксперимент снова и снова повторяется при неизменной матрице  $\mathbf{X}$ , среднее значение  $\hat{\boldsymbol{\beta}}$  будет равно  $\boldsymbol{\beta}$ .

#### Распределения

До сих пор единственное предположение относительно  $\boldsymbol{\varepsilon}$  состояло в том, что  $\mathbf{M}[\boldsymbol{\varepsilon}] = \mathbf{0}$ ,  $\mathbf{D}[\boldsymbol{\varepsilon}] = \sigma_{\varepsilon}^2\mathbf{I}_n$ . Если дополнительно предположить, что остаток  $\boldsymbol{\varepsilon}$  нормально распределен с параметрами  $0, \sigma_{\varepsilon}^2\mathbf{I}_n$ , или, при кратком обозначении,  $\boldsymbol{\varepsilon} : N_n(0, \sigma_{\varepsilon}^2\mathbf{I}_n)$ , то  $\mathbf{Y} : N_n(\mathbf{X}\boldsymbol{\beta}, \sigma_{\varepsilon}^2\mathbf{I}_n)$ . Отсюда получается целый ряд результатов, связанных с распределениями. Если  $\mathbf{Y} : N_n(\mathbf{X}\boldsymbol{\beta}, \sigma_{\varepsilon}^2\mathbf{I}_n)$ , то:

- $\hat{\boldsymbol{\beta}} \sim N_n(\boldsymbol{\beta}, \sigma_{\varepsilon}^2(\mathbf{X}'\mathbf{X})^{-1})$ ,
- $(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'\mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})/\sigma_{\varepsilon}^2 \sim \chi_{(q+1)}^2$ ,
- $\hat{\boldsymbol{\beta}}$  не зависит от  $S_{\varepsilon}^2$ ,
- $SSE/\sigma_{\varepsilon}^2 = (n - q - 1)S_{\varepsilon}^2/\sigma_{\varepsilon}^2 \sim \chi_{(n-q-1)}^2$ .

<sup>1</sup> Эрмит (Hermite) Шарль (24.12.1822 – 14.01.1901) – французский математик.

Предположение нормальности распределения остатков позволяет создать целостную систему статистической обработки, которая включает точечные, интервальные оценки и проверки статистических гипотез. Однако на практике распространенный миф нормальности распределения не всегда выполняется, а в случае малых выборок гипотезу нормальности распределения ошибок трудно проверить. Отклонение от нормальности может быть вызвано и засорением наблюдений чужеродными элементами. В этом случае для обнаружения и удаления этих элементов нужно применить методы, изложенные в предыдущей лекции.

Другой подход связан с применением вместо МНК *метода наименьших модулей* (МНМ). Близким к МНМ является *непараметрический регрессионный анализ*, например, *знаковый регрессионный анализ*, который позволяет получать хорошие оценки и при сильно засоренных выборках. И, наконец, для таких данных можно использовать *робастную регрессию* или решать задачу регрессии с помощью *нейронных сетей*.