

Парный регрессионный анализ



Модель парной линейной регрессии

- Коэффициент корреляции показывает, что две переменные связаны друг с другом, однако он не дает представления о том, каким образом они связаны.
- Рассмотрим более подробно те случаи, в которых мы предполагаем, что одна переменная зависит от другой.


- Начнем с простейшей модели - модели **парной линейной регрессии**:

$$y = a + \beta x + u.$$




- Величина y , рассматриваемая как **зависимая** переменная, состоит из двух составляющих:
- **неслучайной составляющей $\alpha + \beta x$** , где x выступает как объясняющая (независимая) переменная, а постоянные величины α и β - как параметры уравнения;
- **случайного члена u** .


- На рисунке показано, как комбинация этих двух составляющих определяет величину y .



- x_1, x_2, x_3, x_4 - это четыре гипотетических значения объясняющей переменной.
- Если бы соотношение между y и x было **линейным**, то значения y были бы представлены точками Q_1, Q_2, Q_3, Q_4 на прямой.



- Случайный член положителен в первом и четвертом наблюдениях и отрицателен в двух других.
- Если отметить на графике реальные значения y при соответствующих значениях x , то получим точки P_1, P_2, P_3, P_4
- Фактические значения a и β и, следовательно, положения точек Q неизвестны.



- Задача регрессионного анализа состоит в получении оценок α и β и, следовательно, в определении положения прямой по точкам P.
- Если бы случайный член отсутствовал, то точки P совпали бы с точками Q и точно показали бы положение прямой.
- В этом случае достаточно было бы просто построить эту прямую и определить значения α и β .

• Почему же существует случайный член?

Причины существования случайного члена

- **1. Невключение объясняющих переменных.**
- Соотношения между y и x является большим упрощением. В действительности существуют другие факторы, влияющие на y , которые не учтены в формуле $y = a + \beta x + u$.
- Влияние этих факторов приводит к тому, что наблюдаемые точки лежат вне прямой.

- Часто происходит так, что имеются переменные, которые мы хотели бы включить в регрессионное уравнение, но не можем этого сделать потому, что не знаем, как их измерить, например психологические факторы.
- Возможно, что существуют также другие факторы, которые можно измерить, но которые оказывают такое слабое влияние, что их не стоит учитывать.

- Кроме того, могут быть факторы, которые являются существенными, но которые мы из-за отсутствия опыта таковыми не считаем.
- Объединив все эти составляющие, мы получаем то, что обозначено как **u**.
- Если бы мы точно знали, какие переменные присутствуют здесь, и имели возможность точно их измерить, то могли бы включить их в уравнение и исключить соответствующий элемент из случайного члена.
- Проблема состоит в том, что мы никогда не можем быть уверены, что входит в данную совокупность, а что - нет.

- **2. Агрегирование переменных.**
- Во многих случаях рассматриваемая зависимость - это попытка объединить вместе некоторое число микроэкономических соотношений.
- Например, функция суммарного потребления - это попытка общего выражения совокупности решений отдельных индивидов о расходах.
- Так как отдельные соотношения, вероятно, имеют разные параметры, любая попытка определить соотношение между совокупными расходами и доходом является лишь **аппроксимацией**.
- Наблюдаемое расхождение при этом приписывается наличию случайного члена.

• **3. Неправильное описание структуры модели.**

- Структура модели может быть описана неправильно или не вполне правильно.
- Например, если зависимость относится к данным о временном ряде, то значение y может зависеть не от фактического значения x , а от значения, которое ожидалось в предыдущем периоде.
- Если ожидаемое и фактическое значения тесно связаны, то будет казаться, что между y и x существует зависимость, но это будет лишь аппроксимация, и расхождение вновь будет связано с наличием случайного члена.

- **4. Неправильная функциональная спецификация.**
- Функциональное соотношение между y и x математически может быть определено неправильно.
- Например, истинная зависимость может не являться линейной, а быть более сложной.
- Безусловно, надо постараться избежать возникновения этой проблемы, используя подходящую математическую формулу, но любая самая изощренная формула является лишь приближением, и существующее расхождение вносит вклад в остаточный член.


- **Ошибки измерения.**

- Если в измерении одной или более взаимосвязанных переменных имеются ошибки, то наблюдаемые значения не будут соответствовать точному соотношению, и существующее расхождение будет вносить вклад в остаточный член.

- **Остаточный член является суммарным проявлением всех этих факторов.**


Регрессия по методу наименьший квадратов.

- Допустим, имеется четыре наблюдения для x и y , и поставлена задача - определить значения a и β в уравнении **$y = a + \beta x + u$** .
- Можно отложить четыре точки **P** и построить прямую, в наибольшей степени соответствующую этим точкам



- Отрезок, отсекаемый прямой на оси y , представляет собой оценку \mathbf{a} и обозначен \mathbf{a} , а угловой коэффициент прямой представляет собой оценку $\mathbf{\beta}$ и обозначен \mathbf{b} .
- Невозможно рассчитать истинные значения \mathbf{a} и $\mathbf{\beta}$, можно получить только оценки, и они могут быть хорошими или плохими

•Способ достаточно точной оценки алгебраическим путем – Метод наименьших квадратов




- Первым шагом является определение остатка для каждого наблюдения.
- На рисунке при $x=x_1$ соответствующей ему точкой на линии регрессии будет R_1 со значением \hat{y}_1

вместо фактически наблюдаемого значения y_1 .

Величина \hat{y}_1 – расчетное значение

Разность между фактическим и расчетным

значениями $y_1 - \hat{y}_1$ это остаток e_1



- Соответственно, для других наблюдений остатки будут обозначены как e_1, e_2, e_3 и e_4 .

- Очевидно, что мы хотим построить линию регрессии таким образом, чтобы остатки были минимальными.
- Очевидно также, что линия, строго соответствующая одним наблюдениям, не будет соответствовать другим, и наоборот.
- Необходимо выбрать такой критерий подбора, который будет одновременно учитывать величину всех остатков.

- Одним из способов решения поставленной проблемы состоит в минимизации суммы квадратов остатков S — **метод наименьших квадратов МНК**.
- Для рисунка верно такое соотношение: $S = e_1^2 + e_2^2 + e_3^2 + e_4^2$.

- Величина **S** будет зависеть от выбора **a** и **b**, так как они определяют положение линии регрессии.
- Чем меньше **S**, тем строже соответствие. Если $S=0$, то получено абсолютно точное соответствие.
- В этом случае линия регрессии будет проходить через все точки, однако, вообще говоря, это невозможно из-за наличия случайного члена.

- Рассмотрим случай, когда имеется n наблюдений двух переменных x и y .
- Предположив, что y зависит от x , мы хотим подобрать уравнение

$$\hat{y} = a + bx$$



Вывод выражений для a и b

- Выразим квадрат i -го остатка через a и b и наблюдения значений x и y :

$$e_i^2 = (y_i - \hat{y}_i)^2 = (y_i - a - bx_i)^2 = y_i^2 + a^2 + a^2x_i^2 - 2ay_i + 2abx_i - 2x_iy_i$$

Суммируя по всем n наблюдениям, запишем S в виде:

$$S = \sum (y_i)^2 + na^2 + b^2 \sum (x_i)^2 - 2a \sum y_i + 2ab \sum x_i - 2b \sum x_i y_i$$

- Данное выражение для S является квадратичной формой по a и b , и ее коэффициенты определяются выборочными значениями x и y

- Мы можем влиять на величину **S**, только задавая **a** и **b**.
- Значения **x** и **y**, которые определяют положение точек на диаграмме рассеяния, уже не могут быть изменены после того, как мы взяли определенную выборку.
- Условия первого порядка для минимума, принимают вид:

$$\frac{d}{da} S = 2an - 2 \sum y_i + 2b \sum x_i = 0$$

$$\frac{d}{db} S = 2b \sum (x_i)^2 + 2a \sum x_i - 2 \sum x_i y_i = 0$$

Эти уравнения называют нормальными уравнениями для коэффициентов регрессии.

- Первое уравнение позволяет выразить **a**

$$2an - 2n\bar{y} + 2bn\bar{x} = 0$$

Следовательно

$$a = \bar{y} - b\bar{x}$$

- Подставив выраженное **a** во второе уравнение, затем поделив на **2n** и перегруппировав, получим:
 $b\text{Var}(x) = \text{Cov}(x, y)$, и таким образом получим уравнение:
 $b = \text{Cov}(x, y) / \text{Var}(x)$.



- Существуют и другие достаточно разумные решения, однако при выполнении определенных условий метод наименьших квадратов дает несмещенные и эффективные оценки α и β .

Качество оценки: коэффициент детерминации R^2

- Цель регрессивного анализа состоит в объяснении поведения зависимой переменной y .
- В любой данной выборке y оказывается сравнительно низким в одних наблюдениях и сравнительно высоким - в других.
- Разброс значений y в любой выборке можно суммарно описать с помощью выборочной дисперсии **$\text{Var}(y)$** .

- В парном регрессионном анализе мы пытаемся объяснить поведение y путем определения регрессионной зависимости y от соответственно выбранной независимой переменной x .
- После построения уравнения регрессии мы можем разбить значение y_i в каждом наблюдении на две составляющих -

$$y_i = \hat{y}_i + e_i$$

Величина \hat{y}_i – расчетное значение y в наблюдении i

- Это то значение, которое имел бы y при условии, что уравнение регрессии было бы правильным, и отсутствии случайного фактора.

Величина y спрогнозированная по значению x в данном наблюдении.

Тогда остаток e_i есть расхождение между фактическим и спрогнозированным значениями величины y .

Это та часть y , которую мы не можем объяснить с помощью уравнения регрессии.

$$\text{var}(y) = \text{var}(\hat{y}) + \text{var}(e) + 2 \text{cov}(\hat{y}, e)$$

$$2 \text{cov}(\hat{y}, e) = 0 \Rightarrow \text{var}(y) = \text{var}(\hat{y}) + \text{var}(e)$$

Значит мы можем разложить $\text{Var}(y)$ на две части

$\text{var}(\hat{y})$ – часть, которая "объясняется" уравнением регрессии,

и $\text{Var}(e)$ - "необъяснимую" часть.

$$R^2 = \frac{\text{var}(\hat{y})}{\text{var}(y)} = 1 - \frac{\text{var}(e)}{\text{var}(y)}$$

Это коэффициент детерминации

Максимальное значение коэффициента R^2 равно единице. Это происходит в том случае, когда линия регрессии точно соответствует всем наблюдениям

Тогда $\text{var}(y) = \text{var}(\hat{y})$

$$\text{Var}(e) = 0 \text{ и } R^2 = 1.$$

- Если в выборке отсутствует видимая связь между y и x , то коэффициент R^2 будет близок к нулю.
- При прочих равных условиях желательно, чтобы коэффициент R^2 был как можно больше.
- В частности, мы заинтересованы в таком выборе коэффициентов a и b , чтобы максимизировать R^2

- Принцип минимизации суммы квадратов остатков эквивалентен минимизации дисперсии остатков.
- Однако, если мы минимизируем **Var(e)**, то при этом в соответствии с **$R^2 = 1 - \text{Var}(e) / \text{Var}(y)$** автоматически максимизируется коэффициент **R²**.

Пример вычисления коэффициента R2

Уравнение регрессии $\hat{y} = 1,6667 + 1,5x$

Набл.	x	y	\hat{y}	e	$y - \hat{y}$	$\hat{y} - \bar{y}$	$(y - \hat{y})^2$	$(\hat{y} - \bar{y})^2$	e^2
1	1	3	3,1667	-0,1667	-1,6667	-1,5	2,7778	2,25	0,0278
2	3	5	4,6667	0,3333	0,3333	0,0	0,1111	0,00	0,1111
3	3	6	6,1667	-0,1667	1,3333	1,5	1,7778	2,25	0,0278
Сумма	6	14	14	0			4,6667	4,50	0,1667
Среднее	2	4,6667	4,6667	0			1,5556	1,50	0,0556

$$R^2 = 1,5000 / 1,5556 = 0,96$$

- Общая сумма квадратов **TSS** – сумма квадратов отклонений y от своего среднего значения
- Объясненная сумма квадратов (**ESS**) отклонений – сумма квадратов отклонений $a+bx$ от выборочного среднего.
- Необъясненная (остаточная) сумма квадратов отклонений (**RSS**) – сумма квадратов остатков всех наблюдений.

$$TSS = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$ESS = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$RSS = \sum_{i=1}^n e_i^2$$

Другая формула для коэффициента детерминации

$$R^2 = \frac{ESS}{TSS} \quad TSS = RSS + ESS$$



Связь между коэффициентом детерминации и коэффициентом корреляции

$$\begin{aligned} r_{y,\hat{y}} &= \frac{\text{cov}(y, \hat{y})}{\sqrt{\text{var}(y) \text{var}(\hat{y})}} = \frac{\text{cov}(\hat{y} + e, \hat{y})}{\sqrt{\text{var}(y) \text{var}(\hat{y})}} = \frac{\text{cov}(\hat{y}, \hat{y}) + \text{cov}(e, \hat{y})}{\sqrt{\text{var}(y) \text{var}(\hat{y})}} = \\ &= \frac{\text{var}(\hat{y})}{\sqrt{\text{var}(y) \text{var}(\hat{y})}} = \frac{\sqrt{\text{var}(\hat{y})}}{\sqrt{\text{var}(y)}} = \sqrt{R^2} \end{aligned}$$

т.к. $\text{cov}(e, \hat{y}) = 0$

То есть коэффициент детерминации равен квадрату выборочной корреляции между y и $\mathbf{a} + \mathbf{b}x$

- Чем ближе коэффициент детерминации к 1 , тем ближе выборка к **линии регрессии $y=a+bx$, а не к истинной прямой.**
- Это один из недостатков МНК.