

ЛИНЕЙНАЯ ПАРНАЯ РЕГРЕССИЯ

Лекция №2

ПОСТАНОВКА ЗАДАЧИ

Пусть объясняющая переменная X и объясняемая переменная Y связаны соотношением:

$$Y = tX + b + \varepsilon,$$

Эта модель является регрессионной, если $M_x Y = tx + b$, т. е. если $M\varepsilon = 0$

где t и b - детерминированные величины, ε - случайное возмущение.

Получены наблюдения: $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$.

Требуется по наблюдениям найти в некотором смысле наилучшие оценки значений t и b . Тогда оценивание Y по известному x можно производить по формуле:

Далее дается два подхода к определению таких оценок и формулируются условия, при которых эти подходы дают одинаковый результат.

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ (МНК)

Обозначим:

Компоненты дисперсии	Сумма квадратов	Число степеней свободы	Средние квадраты
Регрессионная y_i	$Q_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	p	$s_R^2 = \frac{Q_R}{p}$
Остаточная	$Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	$n - (p + 1)$	$s^2 = \frac{Q_e}{n - (p + 1)}$
Общая	$Q = \sum_{i=1}^n (y_i - \bar{y})^2$	$n - 1$	

Q_e - остаточная сумма

поле корреляции

x_i

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Параметры регрессии определяются из условия минимума остаточной суммы:

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Необходимое условие экстремума:


Откуда получаем *нормальную систему уравнений*:

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Обозначим:

Тогда из (1) получим:

Решая систему (2), найдем:



(3)

- *выборочный коэффициент
регрессии*

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Заметим, что

s_x - выборочное среднее квадратичное отклонение x

- выборочная дисперсия X

- выборочная
ковариация X и Y


С учетом этих обозначений получим:

(4)

МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

Из (3): прямая

проходит через точку



МЕТОД НАИМЕНЬШИХ КВАДРАТОВ

При $M\varepsilon_i=0$, $i=1,\dots,n$, (отсутствии систематических ошибок)
уравнение $\hat{y} = b_0 + b_1x$ является уравнением регрессии, т. е.

Внимание! При получении МНК-оценок параметров b и m не использовалось никаких предположений о распределении X и Y .

КОЭФФИЦИЕНТ КОРРЕЛЯЦИИ

Представим последнее соотношение в эквивалентном виде:

где s_x , s_y - выборочные средние квадратичные отклонения x и y .

Здесь используются *нормированные и центрированные* значения x , y .

Нормирование позволяет избежать зависимости от их единиц измерения.

Центрирование позволяет работать с приращениями.

КОЭФФИЦИЕНТ КОРРЕЛЯЦИИ

Обозначив

**r - выборочный
коэффициент корреляции**

получим

Коэффициент корреляции показывает, насколько величин s_y в среднем изменится y , если x изменится на s_x .

Коэффициент корреляции характеризует тесноту связи X и Y .

КОЭФФИЦИЕНТ КОРРЕЛЯЦИИ

С учетом (4) получаем:




Эта формула обычно используется как определение выборочного коэффициента корреляции

Для расчетов по таблице наблюдений применяется формула:

Свойства коэффициента корреляции


- 1. $-1 \leq r \leq 1$. Чем ближе $|r|$ к 1, тем теснее связь.
- 2. При $r = \pm 1$ корреляционная связь - линейная (наблюдения располагаются на прямой)
- 3. При $r = 0$ связь отсутствует, линия регрессии параллельна оси ОХ.

Коэффициент корреляции характеризует тесноту связи




Коэффициент корреляции характеризует тесноту связи

у тесная связь, r близок к 1



у слабая связь, r близок к 0



Классическая нормальная линейная регрессионная МОДЕЛЬ

Предположим, что:

X - детерминированная величина;

$\varepsilon_1, \dots, \varepsilon_n$ - независимые нормальные одинаково распределенные случайные величины: $\varepsilon_i \sim N(0, \sigma^2)$.

В этих предположениях соотношение

$$Y = mX + b + \varepsilon$$

называется *классической нормальной линейной регрессионной моделью*

(Classical Normal Linear Regression model).

МЕТОД МАКСИМАЛЬНОГО ПРАВДОПОДОБИЯ

Для упрощения выкладок можно вместо функции (5) максимизировать ее логарифм (т. к. логарифм - монотонная функция):

Из (6) следует, что **при известной дисперсии σ^2** для нахождения оценок МП достаточно минимизировать Q_e , и, следовательно, **МП-оценка совпадает с НК-оценкой.**

Свойства оценок: несмещенность

Оценка $\hat{\theta}$ является **несмещенной** оценкой параметра θ , если:

Математическое ожидание оценки равно оцениваемому параметру.

МП-оценки могут иметь смещение!

Свойства оценок: состоятельность

Обозначим $\hat{\theta}_n$ -оценка параметра θ , полученная по n наблюдениям.

$\hat{\theta}_n$ называется **состоятельной оценкой**, если $\hat{\theta}_n \xrightarrow{P} \theta$ сходится по вероятности к θ :

*для состоятельной
несмещенной
оценки выполняется
закон больших чисел*

Свойства оценок: состоятельность

Другая формулировка закона больших чисел -
неравенство Чебышева:

Может использоваться для определения необходимого числа наблюдений, если задано допустимое отклонение оценки от оцениваемого параметра и допустимая вероятность отклонения.

Свойства оценок: эффективность

Эффективной называется оценка, обладающая минимальной дисперсией:

-любая другая оценка.

Для несмещенных оценок:

Несмещенность оценок параметров регрессии



формула (3)

Доказательство несмещенности параметра m :

Несмещенность оценок параметров регрессии

В силу детерминированности X , свойств математического ожидания и определения

Так как $My_i = mx_i + b$, то, после приведения подобных членов, получаем

что и требовалось доказать

Несмещенность оценок параметров регрессии

Доказательство несмещенности параметра b :

В силу свойств математического ожидания и детерминированности X , получаем:

Так как _____ и по определению _____ имеем:

Несмещенность оценок параметров регрессии

Так как $My_i = mx_i + b$, и в силу свойств математического ожидания получаем:

что и требовалось доказать

Теорема Гаусса-Маркова

В условиях классической нормальной регрессионной модели оценки (3) имеют наименьшую дисперсию в классе всех линейных несмещенных оценок.

(3) - самые эффективные оценки -

Best Linear Unbiased Estimates (BLUE)

ОЦЕНИВАНИЕ ДИСПЕРСИИ ВОЗМУЩЕНИЙ

Оценка
максимального правдоподобия

Несмещенная оценка

где


↙ Число неизвестных
параметров (m, b)

Оценки b, m, σ независимы

?для нормированных наблюдений

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Обозначим:



Q_e - остаточная сумма

поле корреляции

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Компоненты дисперсии	Сумма квадратов	Число степеней свободы	Средние квадраты
Регрессионная	$Q_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	p	$s_R^2 = \frac{Q_R}{p}$
Остаточная	$Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	$n-(p+1)$	$s^2 = \frac{Q_e}{n-(p+1)}$
Общая	$Q = \sum_{i=1}^n (y_i - \bar{y})^2$	$n-1$	

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

- Чем меньше остаточная сумма Q_e , тем выше качество модели.
- Чем больше регрессионная сумма Q_R , тем выше качество модели.
- Чем больше отношение Q_R/Q_e , тем выше качество модели.
- Для перехода к стандартному распределению следует рассматривать не суммы, а средние квадраты.

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Можно доказать, что

*В условиях теоремы Гаусса-
Маркова*

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

F показывает, в какой мере регрессия лучше оценивает значение зависимой переменной по сравнению с ее средним значением

При

(!)


гипотеза (предположение) о незначимости регрессии отклоняется с уровнем значимости α .

Неравенство (!) - правило (критерий) проверки гипотезы о незначимости линейной регрессии,

$f_{\alpha, k1, k2}$ — квантиль распределения Фишера, критическое (пороговое) значение F,

α - вероятность отклонения гипотезы при условии, что она верна - вероятность ошибки первого рода.

Квантили F-распределения Фишера-Снедекора



MS Excel 2010: $f_{\alpha, k1, k2} = \text{F.Обр.ПХ}(\alpha, k1, k2)$

α - вероятность «хвоста», которую также называют уровнем значимости или вероятностью ошибки 1 рода (вероятность отклонить гипотезу о незначимости при условии, что она верна).

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Коэффициент детерминации:

Коэффициент детерминации показывает, какая часть изменения зависимой переменной объясняется изменением объясняющей переменной.

$$0 \leq R^2 \leq 1$$

1. Чем ближе R^2 к единице, тем лучше регрессия аппроксимирует наблюдения.
2. Если $R^2=1$, то наблюдения лежат на линии регрессии.
3. Если $R^2=0$, то изменение зависимой переменной полностью обусловлено неучтенными в модели факторами, и линия регрессии параллельна оси ОХ.

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Можно доказать, что в случае парной регрессии:

$$R^2 = r^2$$

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

- $Q_R > Q_e$ – регрессионная модель значима;
- $Q_R < Q_e$ – регрессионная модель незначима;
- $Q_R = Q_e$ – граничный случай; $R^2 = 0.5$;
- $R^2 \geq 0.5$ ($r \geq 0.7$) – регрессионная модель значима.

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Критерий (!) проверки гипотезы о незначимости регрессии может использовать значение R^2 :

Статистика F Фишера (Фишера-Снедекора) и коэффициент детерминации R^2 связаны друг с другом

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Другой способ оценки значимости уравнения ПАРНОЙ регрессии -
проверка гипотезы $t=0$

если $t=0$, то y не зависит от x .

Можно ли по значению оценки t судить о справедливости этой гипотезы?

Если гипотеза верна, то

*большие значения оценки
маловероятны*

x_α - квантиль стандартного нормального
распределения, α - суммарная вероятность
двух «хвостов» (в эконометрике $\alpha=0.05$)

СКО оценки t не знаем, используем выборочное СКО:

ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

СКО оценки t не знаем, используем выборочное СКО:

-статистика Стьюдента с числом степеней свободы $n-2$, $t_{\alpha, n-2}$ – ее квантиль уровня α (суммарная вероятность двух «хвостов»)

Правило проверки гипотезы о незначимости уравнения регрессии: гипотеза отклоняется при

$$|T_{n-2}| > t_{\alpha, n-2}, (!!)$$


ОЦЕНКА ЗНАЧИМОСТИ УРАВНЕНИЯ РЕГРЕССИИ

Для парной регрессии правила(!) и (!!) эквиваленты и

$$F=T^2,$$

Для парной регрессии значимость уравнения регрессии эквивалентна значимости коэффициента регрессии

Квантили Т-распределения Стьюдента



Excel: $t_\alpha = \text{Стьюдент.Обр.2X}(\alpha, \text{число степеней свободы})$

*α - заданная вероятность ошибки 1 рода (уровень значимости),
суммарная вероятность двух хвостов*