

Лекція 3

Класична лінійна багатофакторна модель.



Кафедра інформаційних технологій
доцент Бесклінська О.П.

Зміст:

- 1. Методи побудови багатофакторної регресійної моделі**
- 2. Етапи дослідження загальної лінійної моделі множинної регресії**
- 3. Приклад параметризації та дослідження багатофакторної регресійної моделі**



1. Методи побудови багатофакторної регресійної моделі

1

Метод усіх можливих регресій

2

Метод виключень

3

Покроковий регресійний метод

2. Етапи дослідження загальної лінійної моделі множинної регресії

Розглядається багатofакторна лінійна регресійна
модель

$$y = a_0 + a_1x_1 + a_2x_2 + \dots + a_mx_m$$

Для дослідження моделі слід виконати такі кроки.

1 За даними спостережень оцінити параметри a_1, a_2, \dots, a_m

2 Для перевірки адекватності отриманої моделі обчислити:

а) залишки моделі — розбіжності між спостереженими та розрахунковими значеннями залежної змінної $u_i = y_i - \hat{y}_i, i = 1, 2, \dots, n$

б) відносну похибку залишків та її середнє значення

в) залишкову дисперсію

г) коефіцієнт детермінації

**д) вибірковий коефіцієнт множинної
кореляції**

3

Перевірити статистичну значущість отриманих результатів:

а) перевірити адекватність моделі загалом:
за допомогою F -критерію Фішера перевірити гіпотезу

$$a_1 = a_2 = \dots = a_m = 0$$

проти альтернативної

H_A : існує хоча б один коефіцієнт $a_j \neq 0$

б) перевірити значущість коефіцієнта множинної кореляції, тобто розглянути гіпотезу

$$H_0 : R = 0$$

**в) перевірити істотність коефіцієнтів регресії:
за допомогою **t-критерію Стьюдента****

перевірити гіпотезу

$$H_0 : a_j = 0 \text{ для всіх } j = 1, 2, \dots, m$$

проти відповідних альтернативних гіпотез

$$H_A : a_j \neq 0 \text{ для всіх } j = 1, 2, \dots, m;$$

4 Обчислити та інтерпретувати коефіцієнти еластичності

5 Визначити довірчі інтервали регресії при рівні значущості α .

6 Побудувати довірчі інтервали для параметрів регресії.


7. Обчислити прогностні значення y_p

за значеннями $x_{1p}, x_{2p}, \dots, x_{mp}$,

що перебувають за межами
базового періоду,

і знайти межі довірчих інтервалів
індивідуальних прогнорованих значень
і межі довірчих інтервалів
середнього прогнозу.

3. Приклад параметризації та дослідження багатофакторної регресійної моделі



Припустимо, що між економічним показником y і факторами x_1, x_2, x_3 існує лінійний зв'язок.

$$\begin{array}{cccccc} \sphericalangle & & \sphericalangle & & \sphericalangle & & \sphericalangle & & \sphericalangle & & \sphericalangle \\ y = a_0 + a_1 x_1 + a_2 x_2 + a_3 x_3 \end{array}$$

a_0, a_1, a_2, a_3
параметри моделі, які потрібно оцінити

Вихідні дані в умовних одиницях

Номер спост.	$x_1(i)$	$x_2(i)$	$x_3(i)$	$y(i)$
1	17,37	5,28	1,42	15,7
2	18,24	6,47	1,58	17,34
3	22,47	6,98	1,98	21,57
4	18,47	7,05	2,04	33,5
5	16,82	7,94	2,38	32,30
.....
14	35,67	18,47	8,58	62,22
15	47,87	19,64	9,47	77,58

1

Знайдемо МНК-оцінки параметрів моделі.

	$x_1(i)$	$x_2(i)$	$x_3(i)$
$Y :=$	15.7	17.34	21.57
	33.5	32.3	37.9
	40.78	48.02	43.3
	49.57	52.14	55.17
	59.18	62.22	77.58
$X :=$	1 17.37	5.28	1.42
	1 18.24	6.47	1.58
	1 22.47	6.98	1.98
	1 18.47	7.05	2.04
	1 16.82	7.94	2.38
	1 17.6	8.12	3.48
	1 17.12	8.69	3.07
	1 19.81	9.31	3.84
	1 18.67	10.45	4.28
	1 20.83	10.47	4.67
	1 22.84	13.48	5.98
	1 28.85	15.78	6.51
	1 29.61	17.65	7.82
	1 35.67	18.47	8.58
	1 47.87	19.64	9.47

**Обчислимо оцінки регресійних
коефіцієнтів за формулою**

$$\hat{a} = (X^T X)^{-1} X^T Y$$

де X^T — транспонована матриця X

Виконавши обчислення, одержимо параметри моделі:

Regression Summary for Dependent Variable: y (Данные)						
R= ,95622179 R ² = ,9136011 Adjusted R ² = ,89100378						
F(3,11)=39,148 p<,00000 Std. Error of estimate: 5,7357						
	Beta	Std. Err. of Beta	B	Std. Err. of B	t(11)	p-level
N=15						
Intercept			26,10789	8,107584	3,10528	0,010009
x1	-0,126364	0,188375	-0,25180	0,175368	-0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,186744	-1,09688	0,296124
x3	1,797200	0,666441	11,85602	4,396525	2,69668	0,020780

$$\mathbf{a} = \begin{pmatrix} 26.108 \\ -0.252 \\ -2.728 \\ 11.856 \end{pmatrix}$$

a_0

a_1

a_2

a_3

Функція регресії з урахуванням знайдених оцінок параметрів моделі набуває вигляду

$$y = 26,108 - 0,252x_1 - 2,728x_2 + 11,856x_3$$

2

Для перевірки адекватності отриманої моделі
обчислимо:

а) Залишки $u_i = y_i - \hat{y}_i$

б) Відносну похибку розрахункових значень
регресії:

$$\delta_i = \frac{u_i}{y_i} \cdot 100\%$$

середнє значення відносної похибки


$$\bar{\delta} = \frac{\sum_{i=1}^n \delta_i}{n}$$



$$\bar{\delta} = -0,52783$$

в) Обчислимо середньоквадратичну помилку дисперсії збурень

$$\hat{S}_u = \hat{\sigma}_u = \sqrt{\frac{\sum_{i=1}^n u_i^2}{n - m - 1}}$$



$$\hat{S}_u = 5,7357$$

Regression Summary for Dependent Variable: y (Данные)						
R= ,96622179 R²= ,91436011 Adjusted R²= ,89100378						
F(3,11)=39,148 p<,0000 Std.Error of estimate: 5,7357						
N=15	Beta	Std.Err. of Beta	B	Std.Err. of B	t(11)	p-level
Intercept			26,10789	8,407584	3,10528	0,010009
x1	-0,126364	0,188376	-0,25180	0,375368	-0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,486744	-1,09688	0,296124
x3	1,797200	0,666449	11,85602	4,396525	2,69668	0,020780

г) Перевіримо тісноту загального зв'язку (впливу) незалежних змінних на залежну змінну. Для цього треба обчислити коефіцієнт **детермінації** за формулою

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

Regression Summary for Dependent Variable: y (Данные)						
R= ,9562279 R ² = ,91436011 Adjusted R ² = ,89100378						
F(3,11)=39,146 p< ,00000 Std. Error of estimate: 5,7357						
N=15	Beta	Std.Err. of Beta	B	Std.Err. of B	t(11)	p-level
Intercept			26,10789	8,407584	3,10528	0,010009
x1	-0,126364	0,188376	-0,25180	0,375368	-0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,486744	-1,09688	0,296124
x3	1,797200	0,666449	11,85602	4,396525	2,69668	0,020780

У нас

$$R^2 = 0,91436$$

Висновок: чим ближчий він до одиниці, тим більше варіація залежної змінної **y** визначається варіацією незалежної змінної **x** (є тісний зв'язок між залежною та незалежними змінними).²⁰

д) Перевіримо на значущість вибіркового коефіцієнта кореляції.

Для цього обчислимо $R = \sqrt{R^2}$ - коефіцієнт кореляції (характеризує тісноту лінійного зв'язку всіх незалежних факторів x_i із залежною змінною y).

У нас

$$R = \sqrt{R^2} = \sqrt{0,91436} = 0,956222$$

3

Перевіримо статистичну значущість отриманих результатів.


а) Обчислимо F -статистику за формулою

$$F_{\text{експ}} = \frac{R^2}{1 - R^2} \cdot \frac{n - m - 1}{m}$$

Знайти табличне значення: $F(m, n - m - 1, \alpha)$
і порівняти його з обчисленою F – статистикою: якщо

$$F_{\text{експ}} > F(m, n - m - 1, \alpha)$$

то гіпотеза **відхиляється**, інакше приймається.



Маємо $F_{експ} = 39,14827$,

табличне значення: $F(3; 11; 0,05) = 3,59$

Порівняємо його з обчисленою **F -статистикою.**

Оскільки $F_{експ} > F(3; 11; 0,05)$

нульова гіпотеза відхиляється, тобто коефіцієнти регресії є значущими.

Regression Summary for Dependent Variable: y (Данные)						
R= ,95622179 R ² = ,91436011 Adjusted R ² = ,89100378						
F(3,11)=39,148 p<,00000 Std.Error of estimate: 5,7357						
	Beta	Std.Err. of Beta	B	Std.Err. of B	t(11)	p-level
N=15						
Intercept			26,10789	8,407584	3,10528	0,010009
x1	-0,126364	0,188376	-0,25180	0,375368	-0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,486744	-1,09688	0,296124
x3	1,797200	0,666449	11,85602	4,396525	2,69668	0,020780

б) Обчислимо t -статистику за формулою

$$t = \frac{R\sqrt{n-m-1}}{\sqrt{1-R^2}}$$

Якщо $|t| > t_{\text{табл}}(\alpha/2, n-m-1)$

де $t_{\text{табл}}(\alpha/2, n-m-1)$

відповідне табличне значення t -розподілу з $(n-m-1)$ ступенями свободи, то можна зробити висновок про **значущість коефіцієнта кореляції між залежною і незалежними змінними моделі.**



У нас

Маємо $t = 37,03215$.

Відповідне табличне значення

$$t_{табл}(0,025; 11) = 2,593097$$


Оскільки $|t| > t_{табл}(0,025; 11)$

можна зробити висновок про **достовірність коефіцієнта кореляції**, який характеризує тісноту зв'язку між залежною та незалежними змінними моделі.

Для вибраного рівня значущості α і відповідного ступеня вільності $k=n-m-1$ записати межі надійності для множинного коефіцієнта кореляції R :

$(R-\Delta R; R+\Delta R)$, де

$$\Delta R = t_{\alpha/2, k} \cdot \frac{1-R}{\sqrt{n}}$$



Маємо

$$\Delta R = 2,593 \cdot \frac{1 - 0,956222}{\sqrt{15}} = 0,029311$$

отже

$$(R - \Delta R ; R + \Delta R) = (0,926911 ; 0,985533)$$

в) Перевіримо значущість окремих коефіцієнтів регресії.

Визначимо *t*-статистику за формулою

$$t_j = \frac{a_j}{\sqrt{\sigma_u^2 c_{jj}}} = \frac{a_j}{S_{a_j}}$$

де c_{jj} - діагональний елемент матриці $(X^T X)^{-1}$,

S_{a_j} - стандартизована помилка оцінки параметра моделі.

Значення t_j -критерію порівнюється з табличними при $k = n - m - 1$ ступенях свободи і рівні значущості α :

якщо $|t_j| > t_{\alpha/2, k}$, то відповідна оцінка параметра регресійної моделі є значуща; інакше приймаємо гіпотезу про рівність

a_j нулю

Regression Summary for Dependent Variable: y (Данные)						
R= ,95622179 R ² = ,91436011 Adjusted R ² = ,89100378						
F(3,11)=39,148 p<,00000 Std. Error of estimate: 5,7357						
N=15	Beta	Std. Err. of Beta	B	Std. Err. of B	t(11)	p-level
Intercept			26,10789	8,407584	3,10528	0,010009
x1	-0,126364	0,188376	-0,25180	0,375368	-0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,486744	-1,09688	0,296124
x3	1,797200	0,666449	11,85602	4,396525	2,69669	0,020780



$$t_0 = 3,105278; \quad t_1 = -0,67081;$$

$$t_2 = -1,09688; \quad t_3 = 2,696681$$

табличне значення

$$t_{табл}(0,025,11) = 2,593097$$

Оскільки $|t_0| > t_{\alpha/2,k}; \quad |t_1| < t_{\alpha/2,k}; \quad |t_2| < t_{\alpha/2,k}; \quad |t_3| > t_{\alpha/2,k}$

відповідно оцінки \hat{a}_0, \hat{a}_3 **є значущими**

а оцінки \hat{a}_1, \hat{a}_2 **не є значущими**

4 Обчислимо коефіцієнти еластичності за формулою

$$\alpha_i = \frac{\partial \hat{y}}{\partial x_i} \cdot \frac{\bar{x}_i}{\bar{y}}$$

коефіцієнт еластичності є показником впливу зміни питомої ваги x_i на y у припущенні, що вплив інших факторів відсутній: показує, що регресанд y зміниться на $\alpha\%$, якщо фактор x зміниться на 1%

$$y = 26,108 - 0,252x_1 - 2,728x_2 + 11,856x_3$$

$$\frac{\partial \hat{y}}{\partial x_1} = -0,252$$

$$\bar{x}_1 = 23,416$$

$$\bar{y} = 43,08$$

$$\alpha_1 = \frac{\partial \hat{y}}{\partial x_1} \cdot \frac{\bar{x}_1}{\bar{y}} = -0,252 \cdot \frac{23,416}{43,08} \approx -0,137$$



У нас

$$\alpha_1 = -0,137; \alpha_2 = -0,699; \alpha_3 = 1,24$$

У нашому випадку він показує, що *прибуток підприємства зменшиться на 0,14 %*, якщо *інвестиції зростуть на 1%*, *прибуток підприємства зменшиться на 0,7 %*, якщо *витрати на рекламу зростуть на 1 %*, *прибуток підприємства збільшиться на 1,24 %*, якщо *заробітна плата зросте на 1 %*.

Загальна еластичність Y від усіх факторів x_i дорівнює:

$$\alpha = \sum_{i=1}^m \alpha_i$$

Цей показник свідчить, що на α % зміниться y , якщо одночасно збільшити на 1% всі фактори x_i)

У нас

$$\alpha = 0,394033.$$

5 Обчислимо довірчі інтервали для математичного сподівання \hat{y} і для кожного спостереження


$$X_i^T = (1, x_{1(i)}, x_{2(i)}, x_{3(i)})$$

$$(\hat{y}_i - \Delta\hat{y}_i; \hat{y}_i + \Delta\hat{y}_i),$$

де

$$\Delta\hat{y}_i = t_{\alpha/2, k} \cdot \hat{S}_u \cdot \sqrt{X_i^T (X^T X)^{-1} X_i}$$

де \hat{S}_u — незміщена оцінка дисперсії
залишків:



$$\hat{S}_u = 5,7357$$

**Виконавши необхідні розрахунки, отримаємо
довірчі зони регресії:**

(23,430; 24,904)

(22,594; 22,604)

(24,730; 25,041)

.....

(62,887; 63,558)

(68,229; 68,712)

(71,961; 73,556)

6

Побудуємо довірчі інтервали для параметрів регресії.

$$(a_j - t_{\alpha/2, k} \sqrt{\sigma_u^2 c_{jj}} ; a_j + t_{\alpha/2, k} \sqrt{\sigma_u^2 c_{jj}})$$

Довірчий інтервал при рівні надійності $(1-\alpha)$ є інтервал з випадково залежними межами і накриває істинне значення коефіцієнта регресії a_j з *рівнем довіри* $(1-\alpha)$.

c_{jj} діагональний елемент матриці $(X^T X)^{-1}$

У нас

Regression Summary for Dependent Variable: y (Данніе)						
R= ,95622179 R ² = ,91436011 Adjusted R ² = ,89100378						
F(3,11)=39,148 p<,00000 Std.Error of estimate: 5,7357						
N=15	Beta	Std.Err. of Beta	B	Std.Err. of B	t(11)	p-level
Intercept			26,10789	8,407584	3,10528	0,010009
x1	-0,126364	0,188376	-0,25180	0,375368	0,67081	0,516179
x2	-0,744814	0,679027	-2,72767	2,486744	-1,09688	0,296124
x3	1,797200	0,666449	11,85602	4,396525	2,69668	0,020780

Стандартні похибки

$$\sqrt{\sigma_u^2 c_{jj}}$$

$$t_{табл}(0,025;11) = 2,20$$

$$a_0 \in (7,85; 44,47)$$

$$a_1 \in (-1,095; 0,539)$$

$$a_2 \in (-8,126; 2,801)$$

$$a_3 \in (2,195; 21,44)$$

За допомогою пакету Excel. Виконати команду Сервіс/Аналіз даних

ВЫВОД ИТОГОВ								
<i>Регрессионная статистика</i>								
Множественный R	0,956221789							
R-квадрат	0,914360109							
Нормированный R-кв	0,891003776							
Стандартная ошибка	5,735708227							
Наблюдения	15							
<i>Дисперсионный анализ</i>								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Значимость F</i>			
Регрессия	3	3863,740536	1287,913512	39,14827207	3,6639E-06			
Остаток	11	361,8818375	32,89834886					
Итого	14	4225,622373						
<i>Коэффициенты</i>								
<i>У-пересечение</i>	<i>Стандарт ошибка</i>	<i>t-статистика</i>	<i>P-Значение</i>	<i>Нижние 95%</i>	<i>Верхние 95%</i>	<i>Нижние 95,0%</i>	<i>Верхние 95,0%</i>	
У-пересечение	26,10788542	8,407584346	3,105277847	0,010009436	7,602907684	44,61286316	7,602907684	44,61286316
Переменная X 1	-0,251800474	0,375367538	-0,670810467	0,516178968	-1,077979273	0,574378325	-1,077979273	0,574378325
Переменная X 2	-2,727670903	2,486743611	-1,096884653	0,296123749	-8,200959455	2,745617649	-8,200959455	2,745617649
Переменная X 3	11,85602384	4,396524578	2,696680897	0,020779618	2,179333598	21,53271409	2,179333598	21,53271409

7

Обчислимо прогностні значення і знайдемо межі довірчих інтервалів індивідуальних прогностних значень і межі довірчих інтервалів для математичного сподівання (точковий та інтервальний прогнози).

а) для обчислення прогнозних

значень $y_{pi} = Y_{pr}$

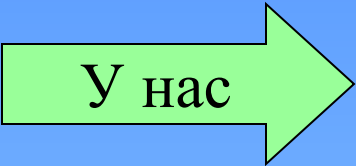
у рівняння

$$\hat{y} = \hat{a}_0 + \hat{a}_1 x_1 + \hat{a}_2 x_2 + \hat{a}_3 x_3$$

тобто

$$\hat{y} = 26,108 - 0,252x_1 - 2,728x_2 + 11,856x_3$$

підставимо задані значення x_{pi}



У нас

Підставимо

$$x_{1np} = 48,82, \quad x_{2np} = 20,04, \quad x_{3np} = 10,25$$

одержимо

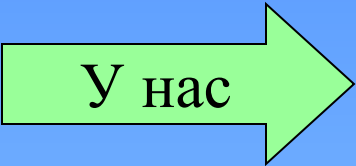
$$y_{np} = 80,68$$

б) знайдемо межі довірчих інтервалів індивідуальних прогнозованих значень за формулою:

$$\hat{Y}_{np} - \Delta \hat{Y}_{np} \leq Y_{np} \leq \hat{Y}_{np} + \Delta \hat{Y}_{np},$$

де

$$\Delta \hat{Y}_{np} = t_{\alpha/2} \hat{\sigma}_u \sqrt{1 + X_{np}^T (X^T X)^{-1} X_{np}}$$



У нас

$$\hat{Y}_{np} = 80,68$$

$$\sigma_u = 5,7357$$

$$X_{np} = (48,82; 20,04; 10,25)$$

тоді

$$Y_{np} \in (58,72; 102,64)$$

інтервальний прогноз індивідуального значення

в) знайдемо межі довірчих інтервалів для математичного сподівання значення y_{pi} за формулою:

$$\hat{Y}_{np} - \Delta_1 \leq M(Y_{np}) \leq \hat{Y}_{np} + \Delta_1,$$

де

$$\Delta_1 = t_{\alpha/2} \hat{\sigma}_u \sqrt{X_{np}^T (X^T X)^{-1} X_{np}}$$



$$\hat{Y}_{np} = 80,68$$

$$\sigma_u = 5,7357$$


тоді

$$M(Y_{np}) \in (64,52; 96,83)$$

довірчий інтервал для *математичного сподівання*.

Завдання для самостійної роботи

**Лугінін О.Є. Економетрія.
Стор.123-132.
Приклад 6.3 розібрати розв'
язок.**



Експрес контроль

Знайти значення критерію Фішера
для парної регресії, якщо $n=10+k$,
 $R^2=0,9t$,

де k - номер по списку,

t - номер групи (1,2,3,4,5,6,7)