



# **Линейные регрессионные модели с переменной структурой**

# Проблема неоднородных (в регрессионном смысле) данных

Статистические данные называются **однородными** (в регрессионном смысле), если все они зарегистрированы при одних и тех же условиях, то есть при одних и тех же значениях качественных переменных.


Статистические данные называются **неоднородными** (в регрессионном смысле), если они зарегистрированы при различных условиях (значениях качественных переменных).

# Примеры неоднородных данных

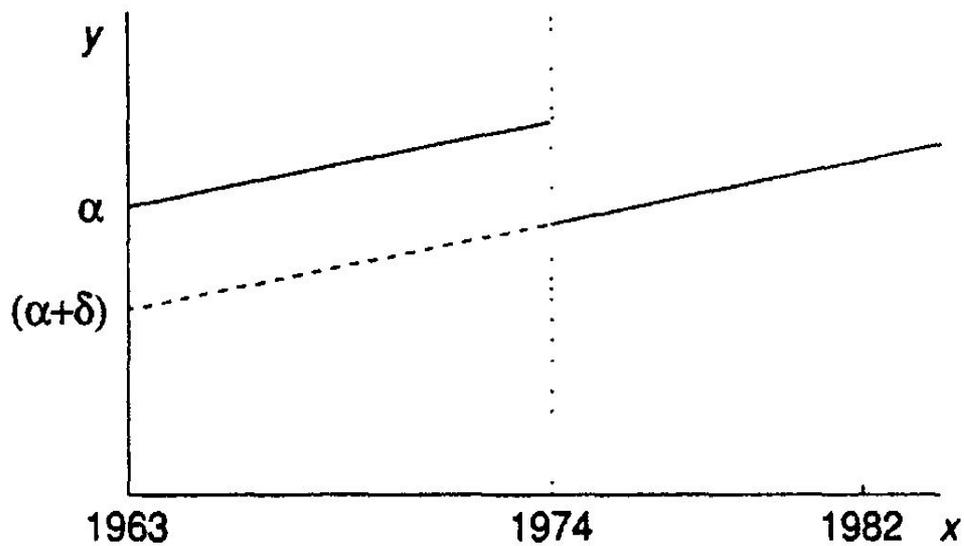
А



Б



Зависимость заработной платы работников ( $y$ ) от производительности труда ( $x$ ) с учетом пола работника



Пример статистических данных со сдвигом во времени

## Качественный признак

Значения ненаблюдаемы,  
незарегистрированы при сборе  
статистических данных

Применение методов кластерного  
анализа (в т.ч. методы расщепления  
смесей вероятностных распределений)  
для разбиения исходных  
статистических данных на  
подвыборки объемом  $n'$ ,  $n''$ , ...

1. Если объемы подвыборок  $n'$ ,  $n''$ , ... значительно выше, чем  $k+1$ , то для каждой подвыборки оценивается своя функция регрессии

2. Объемы подвыборок  $n'$ ,  $n''$ , ... ниже, чем  $k+1$ ,  
необходимость введения фиктивных переменных, «манекенов»

Значения наблюдаемы при  
сборе статистических данных

Разбиение выборки на регрессионно  
однородные подвыборки объемом  
 $n'$ ,  $n''$ , ...

# Фиктивные переменные

Фиктивные переменные —  
бинарные переменные  
(принимают значения 0 или 1)

Используются для  
моделирования качественных  
признаков

# Правило введения фиктивных переменных

При этом если качественная переменная имеет  $p$  градаций, то для отражения ее влияния на структуру искомой регрессионной связи необходимо ввести  $(p-1)$  фиктивных переменных. Иначе для любого объекта наблюдения выполнялось бы тождество:  $z_{i1} + z_{i2} + \dots + z_{ip} = 1$ , что означало бы линейную зависимость объясняющих переменных, и как следствие, невозможность получения МНК-оценок.

$$d_j^{(l)} = \begin{cases} 1, & \text{если } i\text{-й объект обладает } l\text{-м качественным свойством;} \\ 0, & \text{в противном случае} \end{cases},$$

$$j = 1, 2, \dots, p-1$$

# Фиктивные переменные:

## пример1

Существует ли дискриминация на рынке труда?

$$Y_i = \beta_1 + \beta_2 * X_i + \beta_3 * D_i + \varepsilon_i$$

$Y$  — зарплата, долларов в час

$X$  — стаж работы, лет

$$D_i = \begin{cases} 0, & \text{если } i_{\text{ый}} \text{ респондент мужчина} \\ 1, & \text{если } i_{\text{ая}} \text{ респондентка женщина} \end{cases}$$

# Фиктивные переменные:

## пример1

Существует ли дискриминация на рынке труда?

$$Y_i = \beta_1 + \beta_2 * X_i + \beta_3 * D_i + \varepsilon_i$$

$Y$  — зарплата, долларов в час

$X$  — стаж работы, лет

$$D_i = \begin{cases} 0, & \text{если } i_{\text{ый}} \text{ респондент мужчина} \\ 1, & \text{если } i_{\text{ая}} \text{ респондентка женщина} \end{cases}$$

# Фиктивные переменные:

## пример1

Существует ли дискриминация на рынке труда?

$$Y_i = \beta_1 + \beta_2 * X_i + \beta_3 * D_i + \varepsilon_i$$

$Y$  — зарплата, долларов в час

$X$  — стаж работы, лет

$$D_i = \begin{cases} 0, & \text{если } i_{\text{ый}} \text{ респондент мужчина} \\ 1, & \text{если } i_{\text{ая}} \text{ респондентка женщина} \end{cases}$$

# Фиктивные переменные: пример 2

Исследовать зависимость  
веса новорожденного ( $y$ ) от  
среднего числа сигарет ( $x$ ),  
выкуриваемых матерью в день, с  
учетом уже имеющихся у матерей  
детей  $z$

	1 $Y$	2 $X$	3 $Z$
1	3,52	10	1
2	3,46	19	2
3	3,2	16	0
4	3,32	28	1
5	3,54	4	3
6	3,31	14	2
7	3,36	21	0
8	3,65	10	1
9	3,15	22	0
10	3,44	12	1
11	3,1	31	3
12	3,22	29	0
13	3,71	8	2
14	3,76	6	1
15	3,92	8	1

# Фиктивные переменные:

**Пример 2**  
1. Построение регрессионной модели для отдельных подвыборок матерей по количеству уже имеющихся детей, приводит к невозможности проведения регрессионного анализа, поскольку некоторые группы (3 и 4) содержат небольшое количество наблюдений

Количество детей у матери (z)	0	1	2	3
Количество матерей	4	6	3	2

2. Для учета наличия структурных сдвигов, введем фиктивные переменные

$$d_i = \begin{cases} 1 - & \text{если кол-во имеющихся у матери детей } i \\ 0 - & \text{в противном случае} \end{cases}$$

# Таблица

<b>Y</b>	<b>X</b>	<b>Z</b>	<b>d1</b>	<b>d2</b>	<b>d3</b>
<b>3,52</b>	<b>10</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>
<b>3,46</b>	<b>19</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>0</b>
<b>3,2</b>	<b>16</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>3,32</b>	<b>28</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>
<b>3,54</b>	<b>4</b>	<b>3</b>	<b>0</b>	<b>0</b>	<b>1</b>
<b>3,31</b>	<b>14</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>0</b>
<b>3,36</b>	<b>21</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>3,65</b>	<b>10</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>
<b>3,15</b>	<b>22</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>3,44</b>	<b>12</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>
<b>3,1</b>	<b>31</b>	<b>3</b>	<b>0</b>	<b>0</b>	<b>1</b>
<b>3,22</b>	<b>29</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>3,71</b>	<b>8</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>0</b>
<b>3,76</b>	<b>6</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>
<b>3,92</b>	<b>8</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>

# Фиктивные переменные: пример 2

Regression Summary for Dependent Variable: Y (Spreadsheet1)						
R= ,86521807 R <sup>2</sup> = ,74860231 Adjusted R <sup>2</sup> = ,68003930						
F(2,12)=10,918 p<,00126 Std.Error of estimate: ,13604						
N=15	Beta	Std.Err. of Beta	B	Std.Err. of B	t(11)	p-level
Intercept			3,612701	0,110439	32,71222	0,000000
X	-0,622960	0,169405	-0,017124	0,004657	-3,67735	0,003643
d1	0,422031	0,183996	0,200157	0,087264	2,29370	0,042500

$$\hat{y} = 3,61 - 0,017x + 0,200d_1$$

(0,110)
(0,005)
(0,087)

- Вывод:**
1. при рождении вес второго ребенка у курящих женщин будет в среднем на 0,2 кг выше, чем вес детей у остальных женщин, выкуривающих в день то же количество сигарет;
  2. с ростом количества выкуриваемых сигарет вес новорожденного будет уменьшаться на 0,017 кг.

# Критерий ЧОУ

$$H_0: \bar{\beta}^{(1)} = \bar{\beta}^{(2)}; \sigma_\varepsilon^2(1) = \sigma_\varepsilon^2(2)$$

$$H_1: \bar{\beta}^{(1)} \neq \bar{\beta}^{(2)}; \sigma_\varepsilon^2(1) \neq \sigma_\varepsilon^2(2)$$

Для проверки гипотезы используется статистика Чоу, которая в условиях справедливости нулевой гипотезы распределена по закону Фишера-Снедекора ( $\nu_1 = n_2, \nu_2 = n_1 - k - 1$ ):

$$\gamma_{n,n_1} = \frac{(e^T e - e^{(1)T} e^{(1)})/n_2}{e^{(1)T} e^{(1)} / (n_1 - k - 1)},$$

где  $e$  - вектор регрессионных остатков, оцененных по всей выборке;

$e^{(1)}$  - вектор регрессионных остатков, оцененных по первой подвыборке.

Если  $n_2$  достаточно велико, то наряду с данным подходом используется другой критерий, связанный с критерием Чоу:

$$\gamma_{n_1, n_2} = \frac{(e^T e - e^{(1)T} e^{(1)} - e^{(2)T} e^{(2)}) / (k + 1)}{(e^{(1)T} e^{(1)} + e^{(2)T} e^{(2)}) / (n_1 + n_2 - 2k - 2)},$$