

# **Эконометрика**

## **Тема 5**

## ***Тема 5. Некоторые вопросы практического использования регрессионных моделей***

- 1) Мультиколлинеарность**
- 2) Отбор наиболее существенных объясняющих переменных в регрессионной модели**
- 3) Линейные регрессионные модели с переменной структурой. Фиктивные переменные**
- 4) Критерий Г. Чоу**
- 5) Нелинейные модели регрессии**
- 6) Частная корреляция**

# 1. Мультиколлинеарность

Под **мультиколлинеарностью** понимается высокая взаимная коррелированность объясняющих переменных.

## Формы мультиколлинеарности

### Функциональная

Матрица  $X'X$  особенная и  $|X'X| = 0$

нарушается предпосылка 6  
регрессионного анализа

**невозможность решения**  
соответствующей системы нормальных  
уравнений и получения оценок  
параметров регрессионной модели

### Стохастическая (встречается чаще)

Матрица  $X'X$  неособенная, но  $|X'X|$  очень мал

Вектор оценок  $b$  и его ковариационная  
матрица пропорциональны матрице  $(X'X)^{-1}$ , т.е.  
их элементы обратно пропорциональны  
определителю  $|X'X|$

**значительные** средние квадратические  
отклонения коэффициентов регрессии  $b_0,$   
 $b_1, \dots, b_p$  и **оценка их значимости по  $t$ -  
критерию не имеет смысла**

# 1. Мультиколлинеарность

## Эвристические подходы по выявлению мультиколлинеарности

**Анализ корреляционной матрицы** между объясняющими переменными  $X_1, X_2, \dots, X_p$  и выявление пар переменных, имеющих высокие коэффициенты корреляции (обычно больше 0,8). Если такие переменные существуют, то говорят о мультиколлинеарности между ними.

**Нахождение множественных коэффициентов детерминации** между одной из объясняющих переменных и некоторой группой из них. Наличие высокого множественного коэффициента детерминации (обычно больше 0,6) свидетельствует о мультиколлинеарности.

**Исследование матрицы  $X'X$ .** Если  $|X'X|$  либо ее минимальное собственное значение близки к нулю или есть значительное отклонение максимального собственного значения матрицы  $X'X$  от ее минимального собственного значения, то это говорит о наличии мультиколлинеарности.

# 1. Мультиколлинеарность

Методы устранения или уменьшения мультиколлинеарности:

- 1) Из **двух объясняющих переменных, имеющих высокий коэффициент корреляции (больше 0,8), одну переменную исключают из рассмотрения.**

Выбор исключаемой переменной:

- а) на основании экономических соображений;
- б) переменная с меньшим коэффициентом корреляции с зависимой переменной;
- в) переменная с большими коэффициентами корреляции с другими независимыми переменными

- 2) Переход **от несмещенных оценок, определенных по МНК, к смещенным оценкам, обладающим меньшим рассеянием** относительно оцениваемого параметра: использование **«ридж-регрессии»** со смещенными оценками, задаваемыми вектором:

$$\hat{\beta}_{\tau} = \left( X'X + \tau E_{p+1} \right)^{-1} X'Y$$

где  $\tau$  - некоторое положительное число («гребень» или «хребет»),  $E_{p+1}$  — единичная матрица (p+1)-го порядка

- 3) Переход **от исходных объясняющих переменных  $X_1, X_2, \dots, X_n$ , связанных между собой достаточно тесной корреляционной зависимостью, к новым переменным, представляющим линейные комбинации исходных.** При этом новые переменные должны быть **слабокоррелированными** либо вообще некоррелированными.

## 2. Отбор наиболее существенных объясняющих переменных в регрессионной модели

Еще одним из возможных методов устранения или уменьшения мультиколлинеарности является использование **пошаговых процедур отбора наиболее информативных переменных**:

1. **Процедура присоединения объясняющих переменных.** На 1-м шаге рассматривается лишь 1 объясняющая переменная, имеющая с зависимой переменной  $Y$  наибольший  $R^2$ . На 2-м шаге включается в регрессию новая объясняющая переменная, которая вместе с первоначально отобранной образует пару объясняющих переменных, имеющую с  $Y$  наиболее высокий (скорректированный)  $R^2$ . На 3-м шаге вводится в регрессию еще 1 объясняющая переменная, которая вместе с двумя первоначально отобранными образует тройку объясняющих переменных, имеющую с  $Y$  наибольший (скорректированный)  $R^2$  коэффициент детерминации, и т. д. Процедура введения новых переменных продолжается до тех пор, пока будет увеличиваться соответствующий (скорректированный)  $R^2$ .
2. **Процедура исключения факторов.** Сначала в модель включаются все факторы. Затем после построения уравнения регрессии из модели исключают фактор, коэффициент при котором незначим и имеет **наименьшее значение t-критерия**. После этого получают новое уравнение регрессии и снова проводят оценку значимости всех оставшихся коэффициентов регрессии. Процесс исключения факторов продолжается до тех пор, пока модель не станет удовлетворять определенным условиям и все коэффициенты регрессии не будут значимы.

### 3. Линейные регрессионные модели с переменной структурой. Фиктивные переменные

**Качественные признаки** могут существенно влиять на структуру линейных связей между переменными. В этом случае говорят об исследовании регрессионных моделей **с переменной структурой** или **построении регрессионных моделей по неоднородным данным**.

Для этого используются **фиктивные переменные** – обычно дихотомические (бинарные, булевы) переменные, которые принимают всего два значения: «0» или «1» (например, значение переменной  $Z_1$  по фактору «пол»:  $Z_1 = 0$  для работников-женщин и  $Z_1 = 1$  - для мужчин).

**Пример 1** модели множественной линейной регрессии с переменной структурой - зависимость размера заработной платы  $Y$  работников от количественных факторов  $X_1, X_2, \dots, X_n$  и от качественного фактора  $Z_1$  - «пол работника»:

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \alpha_1 z_{i1} + \varepsilon_i, \quad i=1, \dots, n,$$

$$\text{где } z_{i1} = \begin{cases} 1, & \text{если } i\text{-й работник мужского пола;} \\ 0 & \text{если } i\text{-й работник женского пола.} \end{cases}$$

### 3. Линейные регрессионные модели с переменной структурой. Фиктивные переменные

Если рассматриваемый качественный признак имеет **несколько (k) уровней (градаций)**, то в уравнение вводят **(k-1) бинарных переменных**.

**Пример 2** модели множественной линейной регрессии с переменной структурой - зависимость размера заработной платы  $Y$  работников от количественных факторов  $X_1, X_2, \dots, X_n$ , от качественного фактора  $Z_1$  - «пол работника» и качественных бинарных переменных  $Z_{21}$  и  $Z_{22}$ , учитывающих уровень образования работников ( $k=3$  – уровни образования работников: высшее, среднее, начальное):

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \alpha_1 z_{i1} + \alpha_{21} z_{i21} + \alpha_{22} z_{i22} + \varepsilon_i,$$

где  $z_{i21} = \begin{cases} 1, & \text{если } i\text{-й работник имеет высшее образование;} \\ 0 & \text{во всех остальных случаях;} \end{cases}$

$z_{i22} = \begin{cases} 1, & \text{если } i\text{-й работник имеет среднее образование;} \\ 0 & \text{во всех остальных случаях.} \end{cases}$

если  $i$ -й работник имеет **начальное образование**, это будет отражено в модели парой значений  $z_{i21} = 0, z_{i22} = 0$ .



### 3. Линейные регрессионные модели с переменной структурой. Фиктивные переменные

Пример 1 и Пример 2 рассмотренные выше отражали влияние качественного признака (фиктивных переменных) только на значения переменной  $Y$ , т. е. **на свободный член** уравнения регрессии. В более сложных моделях может быть отражена также зависимость фиктивных переменных **на сами параметры при переменных** регрессионной модели.

**Пример 3:** при наличии в модели объясняющих переменных количественной  $X_1$  и фиктивных  $Z_{11}, Z_{12}, Z_{21}, Z_{22}$ , из которых  $Z_{11}, Z_{12}$  влияют только на значение коэффициента при  $X_1$ , а  $Z_{21}, Z_{22}$  - только на величину свободного члена уравнения, такая регрессионная модель примет вид:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_{11}(z_{i11}x_{i1}) + \beta_{12}(z_{i12}x_{i1}) + \alpha_{21}z_{i21} + \alpha_{22}z_{i22} + \varepsilon_i, \quad i = 1, \dots, n.$$

*Модели такого типа используются, например, при исследовании зависимости объема потребления  $Y$  некоторого продукта от дохода потребителя  $X$ , когда одни качественные признаки (например, фактор сезонности) влияют лишь на количество потребляемого продукта (свободный член уравнения регрессии), а другие (например, уровень доходности домашнего хозяйства) - на параметр  $\beta_1$  при  $X$ , интерпретируемый как «склонность к потреблению».*

## 4. Критерий Г. Чоу

*при одних  
при  
условиях  
несколько измененных условиях.*

*однородны  
можно ли объединить две выборки в  
одну*

*тест (критерий) Г.  
Чоу*

## 4. Критерий Г. Чоу

По каждой выборке строятся две линейные регрессионные модели:

$$y_i = \beta'_0 + \sum_{j=1}^p \beta'_j x_{ij} + \varepsilon'_i, \quad i = 1, \dots, n_1;$$

$$y_i = \beta''_0 + \sum_{j=1}^p \beta''_j x_{ij} + \varepsilon''_i, \quad i = n_1 + 1, \dots, n_1 + n_2.$$



Проверяемая нулевая гипотеза имеет вид —  $H_0: \beta' = \beta''$ ;  $D(\varepsilon') = D(\varepsilon'') = \sigma^2$ , где  $\beta' = \beta''$  — векторы параметров двух моделей;  $\varepsilon', \varepsilon''$  — их случайные возмущения.



Если нулевая гипотеза  $H_0$  верна, то две регрессионные модели можно объединить в одну объема  $n = n_1 + n_2$ :

$$y_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ij} + \varepsilon_i, \quad i = 1, 2, \dots, n.$$



## 4. Критерий Г. Чоу



Согласно критерию Г. Чоу нулевая гипотеза  $H_0$  **отвергается** на уровне значимости  $\alpha$ , если статистика:

$$F = \frac{\left( \sum_{i=1}^n e_i^2 - \sum_{i=1}^{n_1} e_i^2 - \sum_{i=n_1+1}^n e_i^2 \right) (n - 2p - 2)}{\left( \sum_{i=1}^{n_1} e_i^2 + \sum_{i=n_1+1}^n e_i^2 \right) (p + 1)} > F_{\alpha; p+1; n-2p-2},$$

где  $\sum_{i=1}^n e_i^2$ ,  $\sum_{i=1}^{n_1} e_i^2$ ,  $\sum_{i=n_1+1}^n e_i^2$  — остаточные суммы квадратов соответственно для объединенной, первой и второй выборок;  $n = n_1 + n_2$ .

$p$  — количество факторов в каждой регрессии;

$F_{\alpha; p+1; n-2p-2}$  — критерий Фишера для соответствующего уровня значимости и количества степеней свободы.

## 5. Нелинейные модели регрессии

### Виды нелинейных моделей регрессии

Модели нелинейные **по переменным**

**Пример:**

$$y_i = \beta_0 + \beta_1 x_{i1}^2 + \beta_2 \sqrt{x_{i2}} + \varepsilon_i,$$

$$i = 1, \dots, n$$

Модели нелинейные **по параметрам**

**Пример:**

$$Y = AK^\alpha L^\beta \varepsilon$$

(производственная функция Кобба—Дугласа)

## 5. Нелинейные модели регрессии

### Методы оценки параметров нелинейных моделей

#### **Линеаризация модели:**

с помощью подходящих преобразований исходных переменных исследуемую зависимость представляют в виде **линейного соотношения** между преобразованными переменными.

#### **Нелинейная оптимизация на основе исходных переменных:**

применяется в случае, когда подобрать соответствующее линеаризующее преобразование не удастся.

## 5. Нелинейные модели регрессии

**Пример 1:** решение модели нелинейной **по переменным** с помощью **линеаризации**:

$$y_i = \beta_0 + \beta_1 x_{i1}^2 + \beta_2 \sqrt{x_{i2}} + \varepsilon_i, \quad i = 1, \dots, n$$



Вводим новые переменные:

$$Z_1 = X_1^2, \quad Z_2 = \sqrt{X_2}$$



Получаем  
линейную  
модель:

$$y_i = \beta_0 + \beta_1 z_{i1} + \beta_2 z_{i2} + \varepsilon_i, \quad i = 1, \dots, n,$$



Параметры линеаризованной модели находятся обычным ММК (необходимо определенное уточнение полученных оценок **для получения оценок по исходным переменным**)

## 5. Нелинейные модели регрессии

Пример 2: решение модели нелинейной **по параметрам** с помощью линеаризации:

$$Y = AK^\alpha L^\beta \varepsilon$$

- производственная функция  
Кобба-Дугласа

Логарифмирование обеих частей  
уравнения

Получаем  
линейную  
модель:

$$\ln y_i = \ln A + \alpha \ln K_i + \beta \ln L_i + \ln \varepsilon_i, \quad i = 1, \dots, n.$$

Параметры линеаризованной модели находятся обычным ММК (необходимо определенное уточнение полученных оценок **для получения оценок по исходным переменным**)




## 6. Частная корреляция

Если переменные коррелируют друг с другом, то на значении выборочного коэффициента корреляции частично сказывается влияние **других** переменных. В связи с этим часто возникает необходимость исследовать **частную корреляцию** между переменными при **исключении (элиминировании) влияния** одной или нескольких переменных.

**Выборочным частным коэффициентом корреляции между переменными  $X_i$  и  $X_j$  при фиксированных значениях остальных  $(p - 2)$  переменных** называется выражение:

$$r_{ij.1,2,\dots,p} = \frac{-q_{ij}}{\sqrt{q_{ii}q_{jj}}},$$

где  $q_{ii}$  и  $q_{jj}$  – алгебраические дополнения элементов  $r_{ii}$  и  $r_{jj}$  **матрицы выборочных коэффициентов корреляции**:   $r_{ij}$  – выборочные парные линейные коэффициенты корреляции

$$q_p = \begin{pmatrix} 1 & r_{12} & \dots & r_{1p} \\ r_{21} & 1 & \dots & r_{2p} \\ \dots & \dots & \dots & \dots \\ r_{p1} & r_{p2} & \dots & 1 \end{pmatrix}$$

## 6. Частная корреляция

Если  $p=3$  (*3 переменные*), то выборочный частный коэффициент корреляции:

$$r_{ij.k} = \frac{r_{ij} - r_{ik}r_{jk}}{\sqrt{(1 - r_{ik}^2)(1 - r_{jk}^2)}}$$

Диапазон значений выборочного частного коэффициента корреляции: **от +1 до -1**;

Статистическую значимость частного коэффициента корреляции  $r_{ij.12\dots p}$  оценивают *так же, как и обычного коэффициента корреляции  $r$*  – с использованием критерия Стьюдента, но при этом используют в качестве *числа наблюдений  $n'=n-p+2$*

## ***Вопросы изученные в Теме 5:***

- 1) Мультиколлинеарность**
- 2) Отбор наиболее существенных объясняющих переменных в регрессионной модели**
- 3) Линейные регрессионные модели с переменной структурой. Фиктивные переменные**
- 4) Критерий Г. Чоу**
- 5) Нелинейные модели регрессии**
- 6) Частная корреляция**