

Тема 6.

Прогнозирование на основе
использования
эконометрических моделей

Что мы знаем:

1. Спецификация эконометрической модели
2. Сбор исходной информации
3. Вычислительный этап:
Оценка параметров модели (теорема Гаусса-Маркова)
4. Анализ полученных результатов:
 - 4.1. Тестирование качества спецификации модели
(коэффициент R^2 , F-тест, проверка $H_0: a_i=0$)
 - 4.2 Исследование модели на мультиколлинеарность

ПОНЯТИЕ МУЛЬТИКОЛЛИНЕАРНОСТИ

Одно из условий возможности применения МНК – это матрица X должна иметь полный ранг.

Это означает, что все столбцы матрицы коэффициентов системы уравнений наблюдений должны быть линейно-независимыми

Данное условие математически можно записать так:

$$\mathit{rank}(X) = \mathit{rank}(X^T X) = k \quad (3.1)$$

где: k – число столбцов матрицы X (Количество регрессоров в модели +1)

Если среди столбцов матрицы X имеются линейно-зависимые, то $\mathit{rank}(X) < k$

Тогда по свойству определителей

$$\mathit{det}(X^T X) = 0 \quad (3.2)$$

Понятие мультиколлинеарности

Условие (3.2) приводит к тому, что матрица $(X^T X)^{-1}$ не существует, то есть является вырожденной.

Следовательно, нет возможности воспользоваться процедурами, сформулированными в теореме Гаусса-Маркова для оценки параметров модели и их ковариационной матрицы.

Наличие линейных (иногда функциональных) связей между факторами X_1, X_2, \dots, X_k , включенными во множественную эконометрическую модель называется мультиколлинеарностью.

Существует полная и частичная мультиколлинеарности.

Полная мультиколлинеарность

Если, регрессоры в модели связаны строгой функциональной зависимостью, то говорят о наличии **полной (совершенной) мультиколлинеарности**

Полная мультиколлинеарность не позволяет однозначно оценить параметры исходной модели и разделить вклады регрессоров в эндогенную переменную по результатам наблюдений

Рассмотрим пример

Пусть спецификация модели имеет вид:

$$Y = a_0 + a_1 x_1 + a_2 x_2 + e \quad (3.3)$$

Предположим, что регрессоры x_1 и x_2 связаны между собой строгой линейной зависимостью:

$$x_2 = \alpha_0 + \alpha_1 x_1 \quad (3.4)$$

Полная мультиколлинеарность

Подставив (3.4) в (3.3), получим уравнение парной регрессии

$$Y = a_0 + a_1 x_1 + a_2 (\alpha_0 + \alpha_1 x_1) + e$$

Раскрыв скобки и приведя преобразования, получим модель в виде:

$$Y = (a_0 + a_2 \alpha_0) + (a_1 + a_2 \alpha_1) x_1 + e \quad (3.5)$$

Уравнение (3.5) можно записать в виде:

$$Y = b_0 + b_1 x_1 + e$$

где :

$$\begin{cases} b_0 = a_0 + a_2 \alpha_0 \\ b_1 = a_1 + a_2 \alpha_1 \end{cases}$$

(3.6)

По оценкам параметров b_0 и b_1 невозможно однозначно оценить параметры модели (3.3), так как в системе (3.6) неизвестных больше, чем исходных данных. Такая система, в общем случае, имеет бесчисленное множество решений.

Частичная мультиколлинеарность

Так как в реальности мы имеем дело с данными, имеющими стохастический характер, то случай полной мультиколлинеарности на практике встречается крайне редко.

На практике мы имеем дело с частичной мультиколлинеарностью.

Частичная (несовершенная, стохастическая) мультиколлинеарность характерна для случаев, когда часть экзогенных факторов (X_1, X_2, \dots, X_k) находится в корреляционной связи или образует различные линейные

$$x_i = \overset{\text{комбинации вида}}{b_1x_1 + b_2x_2 + \dots + b_kx_k}$$

Для определения степени коррелированности строят матрицу взаимных корреляций регрессоров $R = \{r_{ij}\}$, $i, j = 1, 2, \dots, k$

Частичная мультиколлинеарность

Если между регрессорами имеется корреляционная связь, соответствующий коэффициент корреляции будет близок к единице $r_{ij} \approx 1$

Матрица $(X^T X)^{-1}$ будет иметь полный ранг, но близка к вырожденной, т.е. $\det(X^T X)^{-1} \approx 0$

В этом случае, формально можно получить оценки параметров модели, их точностные показатели, но все они **будут неустойчивыми.**

Подобная ситуация возникает, если при спецификации модели в качестве факторных признаков одновременно используются такие показатели, как затраты на единицу продукции, себестоимость товара, его цена.

Частичная мультиколлинеарность

Последствия частичной мультиколлинеарности:

- Увеличение дисперсий оценок параметров. Это расширяет интервальные оценки и снижает их точность;
- Уменьшение значений t -статистик для параметров, что приводит к неправильному выводу о их статистической значимости;
- Неустойчивость оценок МНК-параметров и их дисперсий;
- Возможность получения неверного (с точки зрения теории) знака у оценки параметра.

Частичная мультиколлинеарность

Поясним это на примере

Пусть спецификация модели имеет вид:

$$Y = a_1 x_1 + a_2 x_2 + e$$

Для такой модели значения дисперсий параметров и их ковариация может быть выражена через значение выборочного коэффициента корреляции следующим образом:

$$\sigma_{a_1}^2 = \frac{\sigma^2}{\sum_{t=1}^{t=n} x_{t1}^2 (1 - r_{12}^2)}, \quad \sigma_{a_2}^2 = \frac{\sigma^2}{\sum_{t=1}^{t=n} x_{t2}^2 (1 - r_{12}^2)}$$

$$COV(a_1, a_2) = \frac{-\sigma^2 r_{12}}{(1 - r_{12}^2) \sqrt{\sum_{t=1}^{t=n} x_{t1}^2} \sqrt{\sum_{t=1}^{t=n} x_{t2}^2}}$$

где

$$r_{12} = \frac{\sqrt{\sum_{t=1}^{t=n} x_{t1} x_{t2}}}{\sqrt{\sum_{t=1}^{t=n} x_{t1}^2} \sqrt{\sum_{t=1}^{t=n} x_{t2}^2}}$$

Частичная мультиколлинеарность

Точные количественные критерии для обнаружения частичной мультиколлинеарности отсутствуют.

В качестве признаков ее наличия используют следующие:

- Модуль парного коэффициента корреляции между регрессорами X_i и X_j больше 0,75
- Близость к нулю определителя матрицы $(X^T X)^{-1}$
- Большое количество статистически незначимых параметров в модели

ПРИЗНАКИ МУЛЬТИКОЛЛИНЕАРНОСТИ

К общим признакам наличия мультиколлинеарности в регрессионной модели следует отнести:

1. Небольшое изменение исходных данных (например, добавление новых наблюдений) приводит к существенному изменению оценок параметров модели;
2. Оценки имеют большие стандартные ошибки и малую значимость в то время как модель в целом является значимой (наблюдается высокое значение коэффициента детерминации и соответствующей F-статистики);
3. Оценки параметров имеют неоправданно большие значения или неверные знаки

СПОСОБЫ ОПРЕДЕЛЕНИЯ НАЛИЧИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

1. Величина определителя матрицы $X^T X$. Собственные числа λ_i находятся следующим образом:

$$|X^T X| = \sum_{i=1}^k \lambda_i, \quad \begin{vmatrix} b_{11} - \lambda & b_{12} & \dots & b_{1n} \\ b_{21} & b_{22} - \lambda & \dots & b_{2n} \\ \dots & \dots & \dots & \dots \\ b_{n1} & \dots & \dots & b_{nn} - \lambda \end{vmatrix} = 0.$$

Чем ближе определитель этой матрицы к нулю, тем большая степень мультиколлинеарности между включенными в модель факторами.

СПОСОБЫ ОПРЕДЕЛЕНИЯ НАЛИЧИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

2. Минимальное собственное число матрицы $X^T * X$

$$\lambda_{\min} (X^T * X) = \min_i (\lambda_i) = \lambda_1$$

Чем меньше λ_1 , тем сильнее мультиколлинеарность.

3. Мера обусловленности матрицы $X^T * X$ по Нейману-Голдштейну:

$$\frac{\lambda_{\max} (X^T * X)}{\lambda_{\min} (X^T * X)}; \quad \lambda_{\max} = \max_i (\lambda_i) = \lambda_k$$

Чем ближе $\frac{\lambda_k}{\lambda_1}$ к бесконечности, тем сильнее мультиколлинеарность. Существует некоторая шкала для данного отношения, позволяющая дать качественную оценку степени мультиколлинеарности по величине меры Неймана-Голдштейна: если это отношение больше 30, то мультиколлинеарность средней степени, если больше 100 – мультиколлинеарность большая.

СПОСОБЫ ОПРЕДЕЛЕНИЯ НАЛИЧИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

4 *Максимальная сопряженность.* Для построения этой меры рассчитывается регрессия переменной i на остальные независимые переменные с номерами $1, 2, \dots, i-1, i+1, \dots, k$, определяется коэффициент детерминации R_i^2 в регрессии X_i на $X_1, X_2, \dots, X_{i-1}, X_{i+1}, \dots, X_k$. В качестве меры сопряженности используется величину $\max_i |R_i|$. Если значение $\max_i |R_i|$ близкое к 1, то совокупность независимых переменных подвержена сильному влиянию эффекта мультиколлинearности.

СПОСОБЫ ОПРЕДЕЛЕНИЯ НАЛИЧИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

5. Метод Феррара-Глобера, который основан на применении трех видов статистических критериев:

- 1) всего массива независимых переменных (χ^2 критерий);
- 2) каждой независимой переменной со всеми другими (F-критерий);
- 3) каждой пары независимых переменных (t-критерий).

Сравнив эти критерии с их критическими значениями, можно сделать вывод о наличии или отсутствии мультиколлинеарности между независимыми переменными.

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Коэффициент корреляции, очищенный от влияния других факторов, называется **частным коэффициентом корреляции**

Частный коэффициент корреляции определяет степень зависимости между двумя переменными без учета влияния на них других факторов

Рассмотрим пример. Пусть спецификация модели имеет вид:

$$Y = a_0 + a_1 x_1 + a_2 x_2 + e \quad (3.6)$$

Задача. Определить корреляцию между Y и X_1 , исключив влияние переменной X_2

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Алгоритм решения заключается в следующем:

1. Строится регрессия Y на X_2

$$\tilde{Y} = \tilde{\alpha}_0 + \tilde{\alpha}_2 x_2$$

2. Строится регрессия X_1 на X_2

$$x_1 = \tilde{\beta}_0 + \tilde{\beta}_2 x_2$$

3. Для удаления влияния X_2 вычисляются остатки:

$$\varepsilon_Y = Y - \tilde{Y}, \quad \varepsilon_{x_1} = x_1 - \tilde{x}_1$$

4. Значение частного коэффициента корреляции между переменными Y и X_1 вычисляется по формуле:

$$r(Y, x_1 | x_2) = r(\varepsilon_Y, \varepsilon_{x_1})$$

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Частные коэффициенты корреляции могут быть вычислены по значениям парных коэффициентов

$$r(Y, x_1 | x_2) = \frac{r(Y, x_1) - r(Y, x_2)r(x_1, x_2)}{\sqrt{1 - r^2(x_1, x_2)}\sqrt{1 - r^2(Y, x_2)}} \quad (3.7)$$

В общем случае связь между частными и обычными коэффициентами корреляции осуществляется следующим образом:

$$r_{ij}^* = \frac{-c_{ij}}{\sqrt{c_{ii}}\sqrt{c_{jj}}} \quad i = 1, 2, \dots, k, \quad j = 1, 2, \dots, k$$

где :

(3.8)

$$C = R^{-1}, \quad R = \begin{pmatrix} 1 & r_{12} & \dots & r_{1k} \\ r_{21} & 1 & \dots & r_{2k} \\ \dots & \dots & \dots & \dots \\ r_{k1} & r_{k2} & \dots & 1 \end{pmatrix}, \quad r_{ij} = \text{COR}(x_i, x_j)$$

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Пример 1. Вычислить частный коэффициент корреляции $r(Y, X_1 | X_2)$ между переменными модели (3.6)

Пусть матрица R имеет вид:

$$R = \begin{pmatrix} 1 & r_{01} & r_{02} \\ r_{10} & 1 & r_{12} \\ r_{20} & r_{21} & 1 \end{pmatrix},$$

где :

$$r_{01} = \text{COR}(Y, x_1), \quad r_{02} = \text{COR}(Y, x_2), \quad r_{10} = \text{COR}(x_1, Y),$$

$$r_{20} = \text{COR}(x_2, Y), \quad r_{12} = \text{COR}(x_1, x_2), \quad r_{21} = \text{COR}(x_2, x_1),$$

$$r_{00} = r_{11} = r_{22} = 1$$

Тогда частный коэффициент корреляции $r(Y, X_1 | X_2)$ вычисляется с помощью (3.7)

$$r_{01|2} = \frac{r_{10} - r_{20}r_{12}}{\sqrt{1 - r_{21}r_{12}}\sqrt{1 - r_{02}^2}}$$

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Пример 2. В таблице приведены данные об объеме импорта Y (млрд. дол), ВВП X_1 (млрд.дол) и индексе цен X_2 в США за период 1964-1979 гг

Вычислить элементы матрицы взаимных корреляций модели:

$$Y = a_0 + a_1 x_1 + a_2 x_2 + e$$

| Годы | Y | X_1 | X_2 |
|------|-------|--------|-------|
| 1964 | 28,4 | 635,7 | 92,9 |
| 1965 | 32,0 | 688,1 | 94,5 |
| 1966 | 37,7 | 753,0 | 97,2 |
| 1967 | 40,6 | 796,3 | 100,0 |
| 1968 | 47,7 | 868,5 | 104,2 |
| 1969 | 52,9 | 935,5 | 109,8 |
| 1970 | 58,5 | 982,4 | 116,3 |
| 1971 | 64,0 | 1063,4 | 121,3 |
| 1972 | 75,9 | 1171,1 | 125,4 |
| 1973 | 94,4 | 1306,6 | 133,1 |
| 1974 | 131,9 | 1412,9 | 137,7 |
| 1975 | 126,9 | 1528,8 | 161,2 |
| 1976 | 155,4 | 1702,2 | 170,5 |
| 1977 | 185,8 | 1899,5 | 181,5 |
| 1978 | 217,5 | 2127,6 | 195,4 |
| 1979 | 260,9 | 2368,5 | 217,4 |

Решение.

1. Вычисляем матрицу взаимных корреляций

| | Y | X_1 | X_2 |
|-------|--------|--------|--------|
| Y | 1,0000 | | |
| X_1 | 0,9932 | 1,0000 | |
| X_2 | 0,9885 | 0,9957 | 1,0000 |

2. Вычисляется обратная матрица

| | | |
|---------|----------|----------|
| 73,764 | -76,936 | 3,689 |
| -76,625 | 196,433 | -119,845 |
| 3,379 | -119,537 | 116,683 |

ЧАСТНЫЕ КОЭФФИЦИЕНТЫ КОРРЕЛЯЦИИ

Пример 2. (Продолжение)

3. Вычисляются оценки частных коэффициентов корреляции с помощью (3.8)

Обратная матрица R^{-1}

| | | |
|---------|----------|----------|
| 73,764 | -76,936 | 3,689 |
| -76,625 | 196,433 | -119,845 |
| 3,379 | -119,537 | 116,683 |

Выражение (3.8)

$$r_{ij}^* = \frac{-c_{ij}}{\sqrt{c_{ii}}\sqrt{c_{jj}}} \quad i = 1, 2, \dots, k, \quad j = 1, 2, \dots, k$$

Тогда:

$$r(Y, x_1 | x_2) = \frac{76.936}{\sqrt{73.764}\sqrt{196.433}} = 0,639$$

$$r(Y, x_2 | x_1) = \frac{-3.689}{\sqrt{73.764}\sqrt{116.683}} = -0,0398$$

$$r(x_1, x_2 | Y) = \frac{119.845}{\sqrt{196.433}\sqrt{116.683}} = 0,792$$

Проверка гипотезы H_0 :
 $r(x_1, x_2 | Y) = 0$

$$t = \frac{|r(x_1, x_2 | Y)|\sqrt{n-k-1}}{\sqrt{1-r(x_1, x_2 | Y)^2}} = \frac{0.792\sqrt{16-2-1}}{\sqrt{1-0.792^2}} = 7.661 > t_{кр}$$

МЕТОДЫ УСТРАНЕНИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

Существуют следующие группы методов устранения мультиколлинеарности в уравнениях регрессии:

- Методы исключения переменных модели;
- Методы, которые используют внешнюю информацию;
- Методы, предполагающие переход к смещенным оценкам параметров модели;
- Методы преобразования данных;
- Метод главных компонент

МЕТОДЫ УСТРАНЕНИЯ МУЛЬТИКОЛЛИНЕАРНОСТИ

Основным методом устранения мультиколлинеарности заключается в исключении переменных

Существует несколько способов решения этой задачи

1. Метод дополнительных регрессий

Алгоритм метода заключается в следующем:

1. Строятся уравнения регрессии, которые связывают каждый из регрессоров со всеми оставшимися
2. Вычисляются коэффициенты детерминации R^2 для каждого уравнения регрессии
3. Проверяется статистическая гипотеза $H_0: R^2=0$ с помощью F теста

Вывод: если гипотеза $H_0: R^2=0$ не отклоняется, значит данный регрессор не приводит к мультиколлинеарности

Методы устранения мультиколлинеарности

Пример. Рассмотрим предыдущую задачу и определим, приводит ли регрессор X_1 к мультиколлинеарности

Исходные данные

| Годы | Y | X_1 | X_2 |
|------|-------|--------|-------|
| 1964 | 28,4 | 635,7 | 92,9 |
| 1965 | 32,0 | 688,1 | 94,5 |
| 1966 | 37,7 | 753,0 | 97,2 |
| 1967 | 40,6 | 796,3 | 100,0 |
| 1968 | 47,7 | 868,5 | 104,2 |
| 1969 | 52,9 | 935,5 | 109,8 |
| 1970 | 58,5 | 982,4 | 116,3 |
| 1971 | 64,0 | 1063,4 | 121,3 |
| 1972 | 75,9 | 1171,1 | 125,4 |
| 1973 | 94,4 | 1306,6 | 133,1 |
| 1974 | 131,9 | 1412,9 | 137,7 |
| 1975 | 126,9 | 1528,8 | 161,2 |
| 1976 | 155,4 | 1702,2 | 170,5 |
| 1977 | 185,8 | 1899,5 | 181,5 |
| 1978 | 217,5 | 2127,6 | 195,4 |
| 1979 | 260,9 | 2368,5 | 217,4 |

Результаты расчета

| | | |
|-------|---------|---------|
| a_i | 13,59 | -568,32 |
| s_i | 0,34 | 47,35 |
| R^2 | 0,99 | 51,07 |
| Fтест | 1616,97 | 14,00 |
| | 4217961 | 36519,9 |

Значение Fтест = 1616.97 > Fкрит
Следовательно, гипотеза о равенстве нулю коэффициента детерминации отклоняется
Вывод: регрессор X_1 вызовет в модели мультиколлинеарность

Методы устранения мультиколлинеарности

2. Метод последовательного присоединения (пошаговая регрессия)

В отличие от рассмотренного, метод последовательного присоединения регрессоров позволяет выявить набор регрессоров, который не только не приводит к мультиколлинеарности, но и обеспечивает наилучшее качество спецификации модели

Алгоритм метода следующий:

1. Строится регрессионная модель с учетом всех предполагаемых регрессоров. По признакам делается вывод о возможном присутствии мультиколлинеарности
2. Рассчитывается матрица корреляций и выбирается регрессор, имеющий наибольшую корреляцию с эндогенной переменной
3. К выбранному регрессору последовательно в модель добавляется каждый из оставшихся регрессоров и вычисляются скорректированные коэффициенты детерминации для каждой из моделей. К модели присоединяется тот регрессор, который обеспечивает наибольшее значение скорректированного R^2

Методы устранения мультиколлинеарности

4. К паре выбранных регрессоров последовательно присоединяется третий из числа оставшихся. Строятся модели, вычисляется скорректированный R^2 , добавляется тот регрессор, который обеспечивает наибольшее значение скорректированного R^2 .

Процесс присоединения регрессоров прекращается, когда значение скорректированного R^2 становится меньше достигнутого на предыдущем шаге.

Замечание. Каким бы образом не осуществлялся отбор факторов, уменьшение их числа приводит к улучшению обусловленности матрицы $(X^T X)^{-1}$, а, следовательно, к повышению качества оценок параметров модели.

Методы устранения мультиколлинеарности

Пример 2.

Исследуется зависимость урожайности зерновых культур Y от следующих факторов производства:

X_1 – число тракторов на 100га

X_2 – число зерноуборочных комбайнов на 100га

X_3 – Число орудий поверхностной обработки почвы на 100 га

X_4 - количество удобрений, расходуемых на гектар (т/га)

X_5 – количество химических средств защиты растений (т/га)

Методы устранения мультиколлинеарности

Исходные данные

| Номер района | Y | X ₁ | X ₂ | X ₃ | X ₄ | X ₅ |
|--------------|-------|----------------|----------------|----------------|----------------|----------------|
| 1 | 9,70 | 1,59 | 0,26 | 2,05 | 0,32 | 0,14 |
| 2 | 8,40 | 0,34 | 0,28 | 0,46 | 0,59 | 0,66 |
| 3 | 9,00 | 2,53 | 0,31 | 2,46 | 0,30 | 0,31 |
| 4 | 9,90 | 4,63 | 0,40 | 6,44 | 0,43 | 0,59 |
| 5 | 9,60 | 2,16 | 0,26 | 2,16 | 0,39 | 0,16 |
| 6 | 8,60 | 2,16 | 0,30 | 2,69 | 0,32 | 0,17 |
| 7 | 12,50 | 0,68 | 0,29 | 0,73 | 0,42 | 0,23 |
| 8 | 7,60 | 0,35 | 0,26 | 0,42 | 0,21 | 0,08 |
| 9 | 8,90 | 0,52 | 0,24 | 0,49 | 0,20 | 0,08 |
| 10 | 13,50 | 3,42 | 0,31 | 3,02 | 1,37 | 0,73 |
| 11 | 9,70 | 1,78 | 0,30 | 3,19 | 0,73 | 0,17 |
| 12 | 10,70 | 2,40 | 0,32 | 3,30 | 0,25 | 0,14 |
| 13 | 12,20 | 9,36 | 0,40 | 11,51 | 0,39 | 0,38 |
| 14 | 9,70 | 1,72 | 0,28 | 2,26 | 0,82 | 0,17 |
| 15 | 7,00 | 0,59 | 0,29 | 0,60 | 0,13 | 0,35 |
| 16 | 7,20 | 0,28 | 0,26 | 0,30 | 0,09 | 0,15 |
| 17 | 8,20 | 1,64 | 0,29 | 1,44 | 0,20 | 0,08 |
| 18 | 8,40 | 0,09 | 0,22 | 0,05 | 0,43 | 0,2 |
| 19 | 13,10 | 0,08 | 0,25 | 0,03 | 0,73 | 0,2 |
| 20 | 8,70 | 1,36 | 0,26 | 0,17 | 0,99 | 0,42 |

Методы устранения мультиколлинеарности

Шаг 2. Построение матрицы корреляций

| | Y | X1 | X2 | X3 | X4 | X5 |
|----|------|------|------|------|------|----|
| Y | 1 | | | | | |
| X1 | 0,42 | 1 | | | | |
| X2 | 0,34 | 0,85 | 1 | | | |
| X3 | 0,4 | 0,98 | 0,88 | 1 | | |
| X4 | 0,56 | 0,11 | 0,03 | 0,03 | 1 | |
| X5 | 0,29 | 0,34 | 0,46 | 0,28 | 0,57 | 1 |

Наибольшую корреляцию эндогенная переменная Y имеет с X_4

Вывод: в модель необходимо включить регрессор X_4 и к нему присоединять остальные

Шаг 3. Рассматриваем следующие спецификации моделей:

1. $Y = a_0 + a_4 x_4 + a_1 x_1 + e_1$

2. $Y = a_0 + a_4 x_4 + a_2 x_2 + e_2$

3. $Y = a_0 + a_4 x_4 + a_3 x_3 + e_3$

4. $Y = a_0 + a_4 x_4 + a_5 x_5 + e_4$

| | X_4, X_1 | X_4, X_2 | X_4, X_3 | X_4, X_5 |
|-------|------------|------------|------------|------------|
| R^2 | 0,4113 | 0,3814 | 0,4232 | 0,272 |

Наибольший R^2 в модели 3

Вывод: Продолжаем присоединение к модели 3

Методы устранения мультиколлинеарности

Шаг 4. Рассматриваем следующие спецификации моделей:

1. $Y = a_0 + a_4 x_4 + a_3 x_3 + a_1 x_1 + e_1$

2. $Y = a_0 + a_4 x_4 + a_3 x_3 + a_2 x_2 + e_2$

3. $Y = a_0 + a_4 x_4 + a_3 x_3 + a_5 x_5 + e_3$

| | X_4, X_1, X_3 | X_4, X_3, X_2 | X_4, X_3, X_5 |
|-------|-----------------|-----------------|-----------------|
| R^2 | 0,3911 | 0,392 | 0,4169 |

Наибольший коэффициент детерминации соответствует модели 3.

Однако его значение меньше, чем было достигнуто ранее: $R^2=0,4232$

Выводы:

1. Не имеет смысл рассматривать спецификацию 3.
2. Для построения следует принять спецификацию модели в виде:

$$Y = a_0 + a_4 x_4 + a_3 x_3 + e$$

ПРОБЛЕМА

МУЛЬТИКОЛЛИНЕАРНОСТИ

Выводы:

1. Последствием мультиколлинеарности является потеря устойчивости вычисления оценок параметров модели
2. Наличие мультиколлинеарности приводит к завышенным значениям СКО оценок
3. Отсутствуют строгие критерии тестирования наличия мультиколлинеарности
4. Подозрением наличия мультиколлинеарности служит большое количество незначимых факторов в модели
5. Для устранения мультиколлинеарности необходимо удалить из спецификации модели факторы, ее вызывающие
6. Для получения спецификации модели, не имеющей мультиколлинеарности можно воспользоваться методом присоединения регрессоров или методом исключения регрессоров