
УНИВЕРСИАДА ПО ЭКОНОМЕТРИКЕ 2023
РЕШЕНИЯ ЗАДАЧ ВТОРОГО ТУРА

Задача 1. (25 баллов)
О градообразующих предприятиях

①

В терминах оцененной пробит-модели предсказанная вероятность создания территории опережающего развития (ТОРа) имеет вид¹

$$\hat{\mathbb{P}}(y = 1 | X) = \Phi(0.360 + 0.187X - 0.17X^2)$$

Поскольку функция $\Phi(x)$ очевидным образом монотонна, она достигает своего максимума при максимальном значении аргумента (2 балла), иными словами нас интересует решение задачи

$$0.360 + 0.187X - 0.17X^2 \rightarrow \max_X \implies X_{\max} = -\frac{0.187}{2 \times (-0.17)} = \frac{11}{20} = 0.55 \quad (2 \text{ балла})$$

②

В общем виде рассуждение выше можно представить так

$$\hat{\mathbb{P}}(y = 1 | X) = \Phi(\hat{\beta}_0 + \hat{\beta}_1 X + \hat{\beta}_2 X^2) \implies X_{\max} = -\frac{\hat{\beta}_1}{2\hat{\beta}_2}$$

Получается, равенство $-\frac{\hat{\beta}_1}{2\hat{\beta}_2} = 0.6$ эквивалентно равенству

$$1.2\hat{\beta}_2 + \hat{\beta}_1 = 0$$

¹ Далее $\Phi(x)$ означает функцию распределения для стандартного нормального распределения:

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-x^2/2} dx$$

Теперь можно воспользоваться стандартным t -тестом (тест на одно линейное ограничение), для которого

$$\begin{aligned} H_0 &: 1.2\beta_2 + \beta_1 = 0 \\ H_1 &: 1.2\beta_2 + \beta_1 \neq 0 \end{aligned} \quad (1 \text{ балл})$$

$$t_{\text{расч}} = \frac{1.2\hat{\beta}_2 + \hat{\beta}_1}{\widehat{\text{se}}(1.2\hat{\beta}_2 + \hat{\beta}_1)} = \frac{1.2\hat{\beta}_2 + \hat{\beta}_1}{\sqrt{1.44\hat{V}\hat{\beta}_2 + 2.4\widehat{\text{cov}}(\hat{\beta}_2, \hat{\beta}_1) + \hat{V}\hat{\beta}_1}} \quad (2 \text{ балла})$$

Соответственно, нулевая гипотеза будет отвергаться, если

$$|t_{\text{расч}}| > t_{\text{крит}}^\alpha(n - k) \quad (1 \text{ балл})$$

Выше $t_{\text{крит}}^\alpha(n - k)$ – соответствующее критическое значение t -распределения с уровнем значимости α и $n - k$ степенями свободы, где n – число наблюдений, а k – число коэффициентов в модели.

Вычислим расчетную статистику, пользуясь данной в задаче ковариационной матрицей оценок коэффициентов и результатом пункта ①:

$$t_{\text{расч}} = \frac{-1.2 \times 0.17 + 0.187}{\sqrt{1.44 \times 0.051 + 2.4 \times 0.024 + 0.075}} = -\frac{0.017}{\sqrt{0.206}} \approx -0.037 \quad (2 \text{ балла})$$

Поскольку $n - k = 200 - 3 = 197$ достаточно велико, можно использовать критические значения нормального распределения вместо t -распределения. Поскольку при этом $|t_{\text{расч}}| < 1.69$, то даже на 10% уровне значимости нельзя отвергнуть нулевую гипотезу о том, что $X_{\text{max}} = 0.6$ (1 балл).

③

Пусть угловой коэффициент при $X \leq 0.6$ составляет β_1^L , а при $X > 0.6$ – β_1^R . Тогда нетрудно убедиться в том, что нужная спецификация пробит-модели имеет вид²

$$\mathbb{P}(y = 1 | X) = \Phi(\beta_0 + \beta_1^L(X - 0.6)[X \leq 0.6] + \beta_1^R(X - 0.6)[X > 0.6]) \quad (1.3.1)$$

² Под выражением $[X > \vartheta]$ подразумевается дамми-переменная события $X > \vartheta$, то есть

$$[X > \vartheta] = \begin{cases} 1, & \text{если } X > \vartheta \\ 0, & \text{если } X \leq \vartheta \end{cases}$$

Как легко видеть, спецификация (1.3.1) выше эквивалентна следующей

$$\mathbb{P}(y = 1 | X) = \Phi(\gamma_0 + \gamma_1 X + \gamma_2(X - 0.6)[X > 0.6]) \quad (1.3.2)$$

При этом связь между β и γ такова

$$\gamma_0 = \beta_0 - 0.6 \beta_1^L \quad \gamma_1 = \beta_1^L \quad \gamma_2 = \beta_1^R - \beta_1^L$$

В этом пункте **1 балл** снимался за типичную ошибку, при которой участник забывал, что имеет дело с пробит-моделью (забывал применить $\Phi(\cdot)$ к выражению с дамми-переменными). Далее **1 балл** давался за введение переменной для сдвига и еще **1 балл** – для наклона. Наконец, оставшиеся **2 балла** ставились за то, что предложенная спецификация непрерывна по X .

④

Предложенная модель в явном виде предполагает излом в точке $X = 0.6$, поэтому для ответа участника достаточно написать, что эта точка окажется точкой максимума тогда и только тогда, когда верны неравенства (в терминах уравнений (1.3.1) и (1.3.2) соответственно)

$$\begin{cases} \beta_1^L > 0 \\ \beta_1^R < 0 \end{cases} \quad \text{или} \quad \begin{cases} \gamma_1 > 0 \\ \gamma_1 + \gamma_2 < 0 \end{cases} \quad (4 \text{ балла})$$

И соответствующие коэффициенты статистически значимы. Для полного балла не требовалось предъявить строгий тест такой гипотезы, однако интересующийся читатель может обратиться к статье [Wolak, 1989], в которой такой тест предложен.

Предложения по проверке равенства $X_{\max} = 0.6$ или $\beta_1^L \neq \beta_1^R$ не оценивались.

⑤

Обозначим $X_{\max} = \vartheta$. Поскольку ϑ неизвестна и не оценивается внутри модели (является так называемым *гиперпараметром*), то ее можно найти, например, так:

1. Рассмотреть некоторую решетку $\Theta = \{\vartheta_1, \vartheta_2, \dots, \vartheta_k\}$
2. Для каждого $\vartheta \in \Theta$ (то есть для каждого $m = 1, 2, \dots, k$) оценить модель, аналогичную модели из пункта ③
3. Из значений $\vartheta \in \Theta$ выбрать то, которое соответствует оптимальной модели

Оптимальность модели следует понимать в терминах некоторого заранее зафиксированного критерия качества. Например, в качестве такого критерия можно выбрать информационный критерий Шварца (и, соответственно, предпочтение отдается модели с его наименьшим значением). Альтернативой лобовому (или случайному) перебору по решетке Θ может быть, например, более продвинутая [байесовская оптимизация](#) или иные [методы подбора гиперпараметров](#).

Более подробно интересующийся читатель может ознакомиться с материалами о пороговых регрессиях [Брюса Хансена](#).

Идея перебора параметров по сетке оценивалась в [3 балла](#). При этом для получения оставшихся [2 баллов](#) требовалось обоснование

1. Того, что предложенный алгоритм выберет **единственный** порог³
2. Того, что такой выбор единственного ϑ рационален (иными словами, максимизирует какой-то критерий качества)

³ В этом смысле недостаточно выбирать такие ϑ , чтобы они проходили тест из пункта [④](#), потому что в таком случае «оптимальный» ϑ не будет единственным.

Задача 2. (20 баллов)

О пропавших оценках

Ⓐ

В результатах Маши нет противоречий, поскольку, вообще говоря, среднее арифметическое из коэффициентов парных регрессий, оцененных по отдельным подвыборкам, не совпадает с коэффициентом по всей выборке. Здесь можно сослаться на парадокс Симпсона, на наличие «фиксированных эффектов» стран. (2 балла)

Ⓑ

Сразу разумно оговориться о том, что в модели (5) очевидным образом присутствует чистая мультиколлинеарность, поэтому оценки, соответствующие буквам Т, Ф, Ц, Ч, Ш, Ы, Э и Ю, невозможно вычислить (3 балла).

Теперь обозначим сумму квадратов остатков и коэффициент детерминации j -ой модели как $ESS_{(j)}$ и $R^2_{(j)}$ соответственно. Тогда для $R^2_{(1)}$ имеет место формула⁴

$$R^2_{(1)} = 1 - \frac{ESS_{(1)}}{TSS_{(1)}} = 1 - \frac{200}{TSS_{(1)}} = 0.6 \iff TSS_{(1)} = 500$$

Поскольку во всех моделях (1)–(5) использована одна и та же зависимая переменная, то $TSS_{(j)}$ совпадают для всех j и равны 500. В таком случае, можно вычислить

$$R^2_{(2)} = 1 - \frac{ESS_2}{TSS_2} = 1 - \frac{220}{500} = 0.56 \implies \boxed{A = 0.56} \quad (1 \text{ балл})$$

Далее, как нетрудно заметить, $X + IMP = Sum$ и $X - IMP = Nx$, поэтому модели (1), (3) и (4) при оценивании с помощью МНК будут проектировать y на одно и то же линейное многообразие (в данном конкретном случае – линейную оболочку X и IMP). Это означает, что для этих моделей неминуемо совпадут ESS и коэффициенты детерминации, поэтому

$$\boxed{Ж = 200}$$

(1 балл)

$$\boxed{С = 200}$$

(1 балл)

$$\boxed{Е = 0.6}$$

(1 балл)

$$\boxed{П = 0.6}$$

(1 балл)

⁴ Формально в задаче явно не указано, присутствует ли в уравнении регрессия константа. Далее R^2 вычисляются, исходя из формул для регрессии с константой, то есть $R^2 = 1 - \frac{ESS}{TSS}$. На остальные выводы и значения неизвестных параметров спецификация никак не влияет.

Более того, из-за этого совпадут и предсказанные значения зависимой переменной, то есть три следующих вектора совпадают

$$\hat{y}_{(1)} = \hat{y}_{(3)} = \hat{y}_{(4)}$$

Теперь с учетом этого сравним оцененные уравнения моделей (1) и (3)

$$\underbrace{0.6 X + 0.8 IMP}_{\text{Модель (1)}} = \hat{y}_{(1)} = \hat{y}_{(3)} = \underbrace{B \times \text{Sum} + \Gamma \times Nx}_{\text{Модель (3)}} \\ \iff 0.6 X + 0.8 IMP = B (X + IMP) + \Gamma (X - IMP)$$

Отмечается, что равенство выше выполняется по координатам. Раскрывая скобки и группируя слагаемые в правой части последнего уравнения, получаем систему

$$\begin{cases} B + \Gamma = 0.6 \\ B - \Gamma = 0.8 \end{cases} \iff \boxed{\begin{matrix} B = 0.7 \\ \Gamma = -0.1 \end{matrix}} \quad (2 \text{ балла})$$

Аналогично можно сравнить модели (1) и (4), откуда получается

$$\underbrace{0.6 X + 0.8 IMP}_{\text{Модель (1)}} = \hat{y}_{(1)} = \hat{y}_{(4)} = \underbrace{I \times IMP + L \times \text{Sum}}_{\text{Модель (4)}} \\ \iff 0.6 X + 0.8 IMP = I \times IMP + B (X + IMP) \\ \begin{cases} L = 0.6 \\ I + L = 0.8 \end{cases} \iff \boxed{\begin{matrix} L = 0.6 \\ I = 0.2 \end{matrix}} \quad (2 \text{ балла})$$

Наконец, что касается стандартных ошибок, проще всего дело обстоит с Д и К. Как известно, вложенные модели, отличающиеся только одним регрессором, можно сравнить как с помощью F -теста, так и с помощью t -теста, причем соответствующие расчетные статистики связаны соотношением

$$F_{\text{расч}} = t_{\text{расч}}^2 \quad (2.Б)$$

Можно заметить, что модели (2) и (3) вложенные: модель (2) является частным случаем модели (3). Тогда гипотезу $H_0 : \Gamma = 0$ можно проверить двумя тестами, для

которых равенство (2.Б) будет иметь вид⁵

$$\frac{(R_{(3)}^2 - R_{(2)}^2) / 1}{(1 - R_{(3)}^2) / (43 - 2)} = \frac{0.04 \times 41}{0.4} = F_{\text{расч}} = t_{\text{расч}}^2 = \left(\frac{\Gamma}{D}\right)^2 = \frac{0.01}{D^2}$$

$$\implies \boxed{D = \sqrt{\frac{0.01}{4.1}} \approx 0.049} \quad (2 \text{ балла})$$

Аналогичным образом модели (4) и (2) вложенные, поэтому гипотезу $H_0 : \text{И} = 0$ можно вновь проверить с помощью двух тестов

$$\frac{(R_{(4)}^2 - R_{(2)}^2) / 1}{(1 - R_{(4)}^2) / (43 - 2)} = 4.1 = F_{\text{расч}} = t_{\text{расч}}^2 = \left(\frac{\text{И}}{K}\right)^2 = \frac{0.04}{K^2}$$

$$\implies \boxed{K = \sqrt{\frac{0.04}{4.1}} \approx 0.099} \quad (1 \text{ балл})$$

Несколько сложнее обстоит ситуация с В и М. На самом деле, их можно вычислить, что можно показать на примере В. Пусть ковариационная матрица оценок в модели (1) имеет вид⁶

$$\hat{V}\hat{\beta}_{(1)} = \begin{pmatrix} 0.04^2 & c \\ c & 0.04^2 \end{pmatrix}$$

Здесь c – неизвестная ковариация между оценками в первой модели. При вычислении Б и Г было показано, что

$$\begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \hat{\beta}_{(2)} = \hat{\beta}_{(1)} \iff \hat{\beta}_{(2)} = \frac{1}{2} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \hat{\beta}_{(1)}$$

Как известно, при линейном преобразовании ковариационная матрица меняется так же, как соответствующая квадратичная форма, поэтому⁷

$$\hat{V}\hat{\beta}_{(2)} = \frac{1}{4} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \underbrace{\begin{pmatrix} 0.04^2 & c \\ c & 0.04^2 \end{pmatrix}}_{=\hat{V}\hat{\beta}_{(1)}} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$$

⁵ Здесь подразумевается, что регрессии оцениваются без константы, поэтому модель (3) включает 2 коэффициента, а модель (2) – только один.

⁶ Здесь и далее $\hat{\beta}_{(j)}$ означает вектор оценок из модели (j).

⁷ А именно верно равенство $\mathbb{V}(A^T \xi) = A^T \mathbb{V}(\xi) A$.

С другой стороны, в матрице $\hat{V}\hat{\beta}_{(2)}$ есть один заведомо известный элемент – D^2 , вычисленный ранее. В таком случае, если выразить его из матричного уравнения выше, получится уравнение с одним неизвестным – ковариацией c . Если найти ее из него и вычислить $\hat{V}\hat{\beta}_{(2)}$, то получится найти и B . Аналогичным образом с помощью выражения $\hat{V}\hat{\beta}_{(4)}$ через $\hat{V}\hat{\beta}_{(1)}$ ищется M (3 балла).

Для получения полного балла на этом этапе участник мог просто очертить план вычисления B и M , показав, что их можно найти. Здесь давать численный ответ было необязательно⁸.

⁸ Если это интересно, то количественно $c = -\frac{84}{25\,625}$, откуда нетрудно получить искомые величины.

Задача 3. (30 баллов)

О нелинейной регрессии

Ⓘ

Из уравнения $y_i = \beta x_i + u_i$ можно получить, что $y_i - bx_i = (\beta - b)x_i + u_i$ (при верной нулевой гипотезе). Подставляя этот результат в статистику H , получаем

$$\begin{aligned} H &= \frac{1}{\sqrt{n}} \sum_{i=1}^n (y_i - bx_i) = \frac{1}{\sqrt{n}} \sum_{i=1}^n ((\beta - b)x_i + u_i) = (\beta - b) \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i = \\ &= -\sqrt{n}(b - \beta) \frac{1}{n} \sum_{i=1}^n x_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \quad (2 \text{ балла}) \end{aligned}$$

Ⓢ

Как известно, оценка коэффициента в парной линейной регрессии без константы $y_i = \beta x_i + u_i$ имеет вид (вновь при верной нулевой гипотезе)

$$b = \frac{\sum_{i=1}^n y_i x_i}{\sum_{i=1}^n x_i^2} = \frac{\sum_{i=1}^n (\beta x_i + u_i) x_i}{\sum_{i=1}^n x_i^2} = \beta + \frac{\sum_{i=1}^n u_i x_i}{\sum_{i=1}^n x_i^2} \iff b - \beta = \frac{\sum_{i=1}^n u_i x_i}{\sum_{i=1}^n x_i^2} \quad (1 \text{ балл})$$

Подставляя этот результат в предыдущее равенство и замечая в результате скалярное произведение соответствующих векторов, имеем

$$\begin{aligned} H &= -\sqrt{n} \begin{pmatrix} \frac{\sum_{i=1}^n u_i x_i}{\sum_{i=1}^n x_i^2} \\ 1 \end{pmatrix} \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n x_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \end{pmatrix} = -\frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i = \\ &= \begin{pmatrix} -\frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2} \\ 1 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \end{pmatrix} \quad (3 \text{ балла}) \end{aligned}$$

(III)

Закон повторного математического ожидания позволяет понять, что

$$\mathbb{E} u_i = \mathbb{E}_x \underbrace{\mathbb{E}(u_i | x_i)}_{=0} = 0 \quad \mathbb{E}(x_i u_i) = \mathbb{E}_x \mathbb{E}(x_i u_i | x_i) = \mathbb{E}_x x_i \underbrace{\mathbb{E}(u_i | x_i)}_{=0} = 0$$

Отсюда мгновенно получается, что⁹

$$\mathbb{V} u_i = \mathbb{E} u_i^2 \quad \mathbb{V}(x_i u_i) = \mathbb{E}(x_i^2 u_i^2) \quad \text{cov}(u_i, x_i u_i) = \mathbb{E}(x_i u_i^2)$$

Случайные величины u_i независимы, одинаково распределены и, как подразумевается, имеют конечную дисперсию. Аналогичное верно для величин $x_i u_i$. Таким образом, по классической ЦПТ суммы $\frac{1}{\sqrt{n}} \sum_{i=1}^n u_i$ и $\frac{1}{\sqrt{n}} \sum_{i=1}^n u_i x_i$ асимптотически нормальны, поэтому из полученного выше имеем¹⁰

$$\begin{pmatrix} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \end{pmatrix} \xrightarrow{d} \mathcal{N} \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \underbrace{\begin{pmatrix} \mathbb{E}(x_i^2 u_i^2) & \mathbb{E}(x_i u_i^2) \\ \mathbb{E}(x_i u_i^2) & \mathbb{E} u_i^2 \end{pmatrix}}_{\Sigma} \right)$$

Наконец, из соображений ЗБЧ и теоремы Манна–Вальда при $n \rightarrow \infty$ имеем

$$\frac{1}{n} \sum_{i=1}^n x_i \xrightarrow{p} \mathbb{E} x_i \quad \frac{1}{n} \sum_{i=1}^n x_i^2 \xrightarrow{p} \mathbb{E} x_i^2 \quad - \frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2} \xrightarrow{p} - \frac{\mathbb{E} x_i}{\mathbb{E} x_i^2}$$

По теореме Слуцкого для случайных векторов получаем, что при $n \rightarrow \infty$ верно¹¹

$$H = \underbrace{\begin{pmatrix} -\frac{1}{n} \sum_{i=1}^n x_i & 1 \\ \frac{1}{n} \sum_{i=1}^n x_i^2 & 1 \end{pmatrix}}_{\xrightarrow{p} \begin{pmatrix} -\frac{\mathbb{E} x_i}{\mathbb{E} x_i^2} & 1 \end{pmatrix}} \underbrace{\begin{pmatrix} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i \\ \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \end{pmatrix}}_{\xrightarrow{d} \mathcal{N}(\mathbf{0}, \Sigma)} \xrightarrow{d} \mathcal{N} \left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} -\frac{\mathbb{E} x_i}{\mathbb{E} x_i^2} & 1 \\ \mathbb{E}(x_i^2 u_i^2) & \mathbb{E}(x_i u_i^2) \\ \mathbb{E}(x_i u_i^2) & \mathbb{E} u_i^2 \end{pmatrix} \begin{pmatrix} -\frac{\mathbb{E} x_i}{\mathbb{E} x_i^2} \\ 1 \end{pmatrix} \right)$$

⁹ Здесь использованы те факты, что $\mathbb{V} \xi = \mathbb{E}(\xi^2) - (\mathbb{E} \xi)^2$ и $\text{cov}(\xi, \eta) = \mathbb{E}(\xi \eta) - \mathbb{E} \xi \mathbb{E} \eta$.

¹⁰ Здесь использовано, что $\mathbb{V} \left(\frac{1}{\sqrt{n}} \sum_{i=1}^n \xi_i \right) = \frac{1}{n} \sum_{i=1}^n \mathbb{V} \xi_i = \mathbb{V} \xi_i$ для независимых и одинаково распределенных ξ_i (также верен похожий факт для ковариации).

¹¹ Здесь использован тот факт, что при линейном преобразовании случайного вектора ковариационная матрица меняется как матрица соответствующей квадратичной формы: $\mathbb{V}(A^\top \xi) = A^\top \mathbb{V}(\xi) A$.

Таким образом, статистика H в самом деле асимптотически нормальна и имеет соответствующие предельные $\mathbb{E}H$ и $\mathbb{V}H$.

В этом пункте **1 балл** ставился за любое верное обоснование асимптотической нормальности (быть может, менее подробное, чем приведенное выше). Также **1 балл** ставился за верное асимптотическое математическое ожидание и **2 балла** – за дисперсию. При этом вычисление математического ожидания и дисперсии H на конечной выборке не требовалось.

(IV)

При верной альтернативной гипотезе $H_1 : \alpha \neq 1$ имеем следующее представление для оценки b

$$b = \frac{\sum_{i=1}^n y_i x_i}{\sum_{i=1}^n x_i^2} = \frac{\sum_{i=1}^n (\beta x_i^\alpha + u_i) x_i}{\sum_{i=1}^n x_i^2} = \beta \frac{\sum_{i=1}^n x_i^{\alpha+1}}{\sum_{i=1}^n x_i^2} + \frac{\sum_{i=1}^n x_i u_i}{\sum_{i=1}^n x_i^2} \quad (4 \text{ балла})$$

(V)

При верной альтернативной гипотезе $y_i = \beta x_i^\alpha + u_i$. С учетом этого, а также результата пункта (IV) статистика H принимает вид

$$\begin{aligned} H &= \frac{1}{\sqrt{n}} \sum_{i=1}^n (y_i - b x_i) = \frac{1}{\sqrt{n}} \sum_{i=1}^n (\beta x_i^\alpha + u_i - b x_i) = \frac{\beta}{\sqrt{n}} \sum_{i=1}^n x_i^\alpha - \frac{b}{\sqrt{n}} \sum_{i=1}^n x_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i = \\ &= \frac{\beta}{\sqrt{n}} \sum_{i=1}^n x_i^\alpha - \frac{1}{\sqrt{n}} \left(\beta \frac{\sum_{i=1}^n x_i^{\alpha+1}}{\sum_{i=1}^n x_i^2} + \frac{\sum_{i=1}^n x_i u_i}{\sum_{i=1}^n x_i^2} \right) \sum_{i=1}^n x_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i = \\ &= \beta \sqrt{n} \underbrace{\left[\frac{1}{n} \sum_{i=1}^n x_i^\alpha - \frac{\frac{1}{n} \sum_{i=1}^n x_i^{\alpha+1}}{\frac{1}{n} \sum_{i=1}^n x_i^2} \frac{1}{n} \sum_{i=1}^n x_i \right]}_{A_n} + \underbrace{\left[-\frac{\frac{1}{n} \sum_{i=1}^n x_i}{\frac{1}{n} \sum_{i=1}^n x_i^2} \frac{1}{\sqrt{n}} \sum_{i=1}^n x_i u_i + \frac{1}{\sqrt{n}} \sum_{i=1}^n u_i \right]}_{B_n = \text{Правая часть уравнения (5)}} \quad (4 \text{ балла}) \end{aligned}$$

(VI)

Из соображений ЗБЧ и теоремы Манна–Вальда при $n \rightarrow \infty$ имеем

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n x_i^\alpha &\xrightarrow{p} \mathbb{E} x_i^\alpha & \frac{1}{n} \sum_{i=1}^n x_i^{\alpha+1} &\xrightarrow{p} \mathbb{E} x_i^{\alpha+1} & \frac{1}{n} \sum_{i=1}^n x_i^2 &\xrightarrow{p} \mathbb{E} x_i^2 \\ \frac{1}{n} \sum_{i=1}^n x_i &\xrightarrow{p} \mathbb{E} x_i & \frac{\frac{1}{n} \sum_{i=1}^n x_i^{\alpha+1}}{\frac{1}{n} \sum_{i=1}^n x_i^2} &\xrightarrow{p} & \frac{\mathbb{E} x_i^{\alpha+1}}{\mathbb{E} x_i^2} \end{aligned}$$

Таким образом, предел A_n по вероятности имеет вид

$$A_n = \frac{1}{n} \sum_{i=1}^n x_i^\alpha - \frac{\frac{1}{n} \sum_{i=1}^n x_i^{\alpha+1}}{\frac{1}{n} \sum_{i=1}^n x_i^2} \xrightarrow{p} \mathbb{E} x_i^\alpha - \frac{\mathbb{E} x_i^{\alpha+1}}{\mathbb{E} x_i^2} \mathbb{E} x_i \quad (4 \text{ балла})$$

(VII)

Поскольку при $\alpha \neq 1$ предложено¹², что $A_n \not\rightarrow 0$ при $n \rightarrow \infty$, то

$$\text{plim}_{n \rightarrow \infty} \underbrace{\sqrt{n}}_{\rightarrow \infty} \underbrace{\beta A_n}_{\rightarrow \text{const} \neq 0} = \infty \quad (2 \text{ балла})$$

Теперь обратим внимание на второй предел

$$\text{plim}_{n \rightarrow \infty} H_n = \text{plim}_{n \rightarrow \infty} (\beta \sqrt{n} A_n + B_n) = \text{plim}_{n \rightarrow \infty} \sqrt{n} \left(\beta A_n + \frac{1}{\sqrt{n}} B_n \right)$$

Зафиксируем произвольное $\varepsilon > 0$ и рассмотрим¹³

$$P_\varepsilon = \lim_{n \rightarrow \infty} \mathbb{P} \left(\left| \frac{1}{\sqrt{n}} B_n - 0 \right| > \varepsilon \right) \leq \lim_{n \rightarrow \infty} \frac{\mathbb{V} B_n}{n \varepsilon^2} = 0$$

По определению сходимости по вероятности это в точности означает, что по аналогии с первым пределом

$$\text{plim}_{n \rightarrow \infty} \frac{1}{\sqrt{n}} B_n = 0 \implies \text{plim}_{n \rightarrow \infty} H = \infty \quad (2 \text{ балла})$$

¹² Кстати говоря, показать это можно, например, с помощью неравенства Гельдера или техники дифференцирования под знаком математического ожидания.

¹³ В этот момент используется неравенство Чебышева и тот факт, что $\mathbb{E} B_n = 0$. Также из сходимости B_n по распределению к нормальной случайной величине следует, что последовательность $\mathbb{V} B_n$ ограничена.

(VIII)

Рассмотрим следующий критерий отвержения гипотезы H_0 :

$$\frac{|H|}{\sqrt{\mathbb{V}H}} > z_{1-\alpha/2} \quad (4 \text{ балла})$$

Выше $z_{1-\alpha/2}$ – критическое значение стандартного нормального распределения, соответствующее уровню значимости α при двустороннем тесте. Как следует из предыдущих пунктов, статистика $\frac{|H|}{\sqrt{\mathbb{V}H}}$ имеет распределение $\mathcal{N}(0, 1)$, поэтому такой критерий корректен.

На практике в тесте выше $\mathbb{V}H$ можно заменить на ее состоятельную оценку или использовать бутстрап-распределение для H .

Задача 4. (25 баллов)

О репликации исследования

①

Да, использовать X_2 в качестве несмещенной (условно на $X_1 > c$) оценки для μ можно, поскольку из соображений независимости

$$X_2 \perp\!\!\!\perp X_1 \implies \mathbb{E}(X_2 \mid X_1 > c) = \mathbb{E}X_2 = \mu$$

Интуитивно это так, поскольку, хотя репликация и проводится только в случае публикации оригинальной работы (то есть когда $X_1 > c$), их результаты независимы. Поскольку репликация проводится «честно», то ее результатам можно доверять.

②

Нет, X_1 не годится в качестве несмещенной оценки μ при условии $X_1 > c$. Вычислим плотность распределения X_1 условно на событие $X_1 > c$

$$p_{X_1}(x_1 \mid X_1 > c) = \frac{\phi(x_1 - \mu) [x_1 > c]}{\mathbb{P}(X_1 > c)} = \frac{\phi(x_1 - \mu) [x_1 > c]}{1 - \Phi(c - \mu)}$$

В таком случае, нетрудно вычислить искомое математическое ожидание

$$\begin{aligned} \mathbb{E}(X_1 \mid X_1 > c) &= \int_{-\infty}^{+\infty} x_1 p_{X_1}(x_1 \mid x_1 > c) dx_1 = \frac{1}{1 - \Phi(c - \mu)} \int_{-\infty}^{+\infty} x_1 \phi(x_1 - \mu) [x_1 > c] dx_1 = \\ &= \frac{1}{1 - \Phi(c - \mu)} \int_{-\infty}^{+\infty} (\mu + (x_1 - \mu)) \phi(x_1 - \mu) [x_1 > c] dx_1 = \\ &= \mu \times \underbrace{\frac{1}{1 - \Phi(c - \mu)} \int_{-\infty}^{+\infty} \phi(x_1 - \mu) [x_1 > c] dx_1}_{=1} + \frac{1}{1 - \Phi(c - \mu)} \int_{-\infty}^{+\infty} (x_1 - \mu) \phi(x_1 - \mu) [x_1 > c] dx_1 = \\ &= \mu + \frac{1}{1 - \Phi(c - \mu)} \frac{1}{\sqrt{2\pi}} \int_c^{+\infty} (x_1 - \mu) e^{-\frac{(x_1 - \mu)^2}{2}} dx_1 = \mu + \underbrace{\frac{1}{1 - \Phi(c - \mu)} \frac{1}{\sqrt{2\pi}} e^{-\frac{(c - \mu)^2}{2}}}_{>0} > \mu \end{aligned}$$

Получается, X_1 не может служить несмещенной оценкой для μ .

③

Поскольку случайные величины X_1 и X_2 независимы, то их совместная плотность (условно на $X_1 > c$) факторизуется до вида

$$p(x_1, x_2 | X_1 > c) = p_{X_1}(x_1 | X_1 > c) \underbrace{p_{X_2}(x_2 | X_1 > c)}_{\phi(x_2 - \mu)} = \frac{\phi(x_1 - \mu)\phi(x_2 - \mu) [x_1 > c]}{1 - \Phi(c - \mu)}$$

④

В случае, если работа публикуется только при достаточно большом X_1 , математическое ожидание X_1 при публикации $\mathbb{E}(X_1 | X_1 > c)$ также оказывается завышено относительно μ . Таким образом, при условии публикации работы заведомо получается, что $\frac{X_1 + X_2}{2}$ – смесь несмещенной оценки X_2 и завышенной оценки X_1 , поэтому она сама является завышенной.

Формально в этом нетрудно убедиться, используя вычисленные в предыдущих пунктах математические ожидания

$$\mathbb{E}\left(\frac{X_1 + X_2}{2} \mid X_1 > c\right) = \frac{1}{2} \underbrace{\mathbb{E}(X_2 | X_1 > c)}_{=\mu} + \frac{1}{2} \underbrace{\mathbb{E}(X_1 | X_1 > c)}_{>\mu} > \frac{1}{2}\mu + \frac{1}{2}\mu = \mu$$