

## Универсиада «Ломоносов» по эконометрике 2026

### Отборочный этап, сумма 30 баллов

#### Решение и критерии

#### Задание

Заполните **ПРОПУСКИ** и напишите обоснование для каждого из них. На месте пропуска может стоять одно или несколько слов или фраза.

Каждый пропуск по 1 баллу, обоснование по 2 балла.

Сергей Т. – начинающий эконометрист и опытный HR. Сергей оценивает методом наименьших квадратов (МНК) сперва парную регрессию с константой  $y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$ , где  $y_i$  – заработная плата  $i$ -го сотрудника компании, а  $x_i$  – опыт работы  $i$ -го сотрудника компании.

Затем он оценивает парную регрессию с константой  $x_i = \alpha_1 + \alpha_2 y_i + u_i$ , где  $\varepsilon_i$  и  $u_i$  – случайные шоки.

Между МНК-оценками, полученными Сергеем, будет выполняться соотношение  $\hat{\alpha}_2 = \frac{1}{\hat{\beta}_2}$ , если **ПРОПУСК 1**.

#### РЕШЕНИЕ

Способ от составителя:

Можно вспомнить свойство, что эр-квадрат в парной регрессии равен квадрату коэффициента корреляции, и он одинаков в двух регрессиях:  $y$  от  $x$  и  $x$  от  $y$ . Отсюда можно получить связь между МНК-оценками коэффициентов  $\beta_2$  и  $\alpha_2$ .

$$\hat{\alpha}_2 = \frac{\widehat{\text{cov}}(x,y)}{\widehat{\text{var}}(y)}, \hat{\beta}_2 = \frac{\widehat{\text{cov}}(x,y)}{\widehat{\text{var}}(x)}$$

$$R^2 = (\widehat{\text{corr}}(x,y))^2 = \left( \frac{\widehat{\text{cov}}(x,y)}{\sqrt{\widehat{\text{var}}(x) * \widehat{\text{var}}(y)}} \right)^2 = \frac{\widehat{\text{cov}}(x,y)}{\widehat{\text{var}}(x)} * \frac{\widehat{\text{cov}}(x,y)}{\widehat{\text{var}}(y)} = \hat{\beta}_2 * \hat{\alpha}_2$$

Откуда:  $\hat{\alpha}_2 = \frac{R^2}{\hat{\beta}_2}$ .

Ответ: ... если  $R^2 = 1$  (или корреляция равно +1 или -1)

Зачёт по смыслу: если все точки с координатами  $(x,y)$  лежат на одной прямой линии и т.д.

Альтернативно:

$\hat{\alpha}_2 = \frac{1}{\hat{\beta}_2}$  выполняется, если линия регрессии проходит через ноль ( $\beta_1 = 0$  и  $\alpha_1 = 0$ ) или что

$$(\sum_{i=1}^n x_i y_i)^2 = \sum_{i=1}^n y_i^2 * \sum_{i=1}^n x_i^2$$

С подробностями:

$$y_i = \beta_2 x_i + \varepsilon_i, \text{ откуда } \hat{\beta}_2 = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$$

$$x_i = \alpha_2 y_i + u_i, \text{ откуда } \hat{\alpha}_2 = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n y_i^2}$$

$$\hat{\alpha}_2 = \frac{1}{\hat{\beta}_2}$$

$$\frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n y_i^2} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$$

$$(\sum_{i=1}^n x_i y_i)^2 = \sum_{i=1}^n y_i^2 * \sum_{i=1}^n x_i^2$$

Затем Сергей решает вместо уравнения  $y_i = \beta_1 + \beta_2 x_i + \varepsilon_i$  оценить регрессию по центрированным данным, т. е. в отклонениях заработной платы от средней по компании и отклонениях опыта работы от среднего по компании.

В результате МНК-оценка коэффициента  $\beta_1$  ПРОПУСК 2, МНК-оценка коэффициента  $\beta_2$  ПРОПУСК 3, коэффициент детерминации ПРОПУСК 4, стандартная ошибка МНК-оценки коэффициента  $\beta_2$  ПРОПУСК 5.

### РЕШЕНИЕ

Это задние по смыслу, как изменятся оценки коэффициентов и прочие величины, если из игрека вычесть константу и из икса вычесть константу.

До центрирования:

$$\hat{\beta}_2 = \frac{\text{cov}(x,y)}{\text{var}(x)}, \hat{\beta}_1 = \bar{y} - \hat{\beta}_2 * \bar{x}, R^2, s. e. (\hat{\beta}_2) = \sqrt{\frac{ESS/(n-2)}{\sum_{i=1}^n (x_i - \bar{x})^2}}$$

После центрирования:

$\hat{\beta}_{2\text{центр}} = \frac{\text{cov}(x-\bar{x}, y-\bar{y})}{\text{var}(x-\bar{x})} = \frac{\text{cov}(x,y)}{\text{var}(x)} = \hat{\beta}_2$ . От вычитания константы ни дисперсия, ни ковариация не изменяются. То есть МНК-оценка коэффициента наклона не изменяется.

После центрирования средние становятся нулями. Поэтому  $\hat{\beta}_{1\text{центр}} = 0$ .

От вычитания константы ни дисперсия, ни ковариация не изменяются, поэтому коэффициент детерминации не изменяется:

$$R^{2\text{центр}} = (\text{cov}(x - \bar{x}, y - \bar{y}))^2 = (\text{cov}(x, y))^2 = R^2$$

Сумма квадратов остатков (ESS) по той же причине не изменяется. Квадраты отклонения иксов от среднего значения тоже не изменяются, поэтому  $s. e. (\hat{\beta}_{2\text{центр}})$  без изменений.

Ксения ищет работу аналитиком и спрашивает у Сергея, как обойти ИИ-алгоритм, который используют HR-ры, чтобы её резюме прошло отбор на живое собеседование. Ксения имела опыт работы в Жёлтом банке и умеет строить модели машинного обучения. Сергей планирует исследовать, как вероятность приглашения на живое собеседование зависит от указания в резюме опыта работы с моделями машинного обучения. Для этого он оценивает логит-модель:

$$P(z_i=1) = \Lambda(\alpha + \beta w_i + \varepsilon_i)$$

где:

$z_i$  принимает только значения 1, если кандидата  $i$  пригласили, и 0, если нет;  $w_i$  принимает только значения 1, если у кандидата  $i$  есть опыт работы с моделями машинного обучения, и 0, если нет;

$\Lambda(\dots)$  – логистическая функция;  $\alpha$  и  $\beta$  – коэффициенты модели;  $\varepsilon_i$  – случайный шок.

Сергей собрал выборку. Сведения о количестве кандидатов с соответствующим сочетанием характеристик представлены в таблице:

|           | $z_i = 0$ | $z_i = 1$ |
|-----------|-----------|-----------|
| $w_i = 1$ | $m_1$     | $m_2$     |
| $w_i = 0$ | $m_3$     | $m_4$     |

Сергей сможет получить оценки логит-модели бинарного выбора по этим данным, если ПРОПУСК 6.

РЕШЕНИЕ:

... ЕСЛИ все 4 числа  $m_1, m_2, m_3, m_4$  не нулевые.

Пояснение:

Если формально обосновано отсутствие экстремума (ссылкой на монотонность или неразрешимость FOC) — 2 балла за объяснение

Если объяснение не полностью и не строгое, то 1 балл.

|           |           |           |
|-----------|-----------|-----------|
|           | $z_i = 0$ | $z_i = 1$ |
| $w_i = 1$ | $m_1$     | $m_2$     |
| $w_i = 0$ | $m_3$     | $m_4$     |

Ищем оценки методом максимального правдоподобия:

$$L = \prod_{y=1} (\Lambda(\alpha + \beta w_i)) * \prod_{y=0} (1 - \Lambda(\alpha + \beta w_i)) =$$

$$(\Lambda(\alpha))^{m_2} * (\Lambda(\alpha + \beta))^{m_4} * (1 - \Lambda(\alpha))^{m_1} * (1 - \Lambda(\alpha + \beta))^{m_3} \rightarrow \max_{\alpha, \beta}$$

Логарифмируем, чтобы перейти к суммам вместо произведений:

$$\ln L = m_2 \ln \Lambda(\alpha) + m_4 \ln \Lambda(\alpha + \beta) + m_1 (1 - \ln \Lambda(\alpha)) + m_3 \ln (1 - \Lambda(\alpha + \beta)) \rightarrow \max_{\alpha, \beta}$$

обозначим  $\gamma = \alpha + \beta$ . Тогда:

$$\ln L = m_2 \ln \Lambda(\alpha) + m_4 \ln \Lambda(\gamma) + m_1 (1 - \ln \Lambda(\alpha)) + m_3 \ln (1 - \Lambda(\gamma)) \rightarrow \max_{\alpha, \gamma}$$

Обозначим  $f$  – производную от  $\Lambda$ .

Тогда условия первого порядка (FOC):

$$\frac{\partial \ln L}{\partial \alpha} = m_2 \frac{f(\alpha)}{\Lambda(\alpha)} - m_1 \frac{f(\alpha)}{1 - \Lambda(\alpha)} = 0$$

$$\frac{\partial \ln L}{\partial \gamma} = m_4 \frac{f(\gamma)}{\Lambda(\gamma)} - m_3 \frac{f(\gamma)}{1 - \Lambda(\gamma)} = 0$$

Приведём к общему знаменателю, сократим первое на  $f(\alpha)$ , второе на  $f(\gamma)$ . Имеем:

$$m_2(1 - \Lambda(\alpha)) - m_1 \Lambda(\alpha) = 0, \text{ откуда } \Lambda(\alpha) = \frac{m_2}{m_2 + m_1}.$$

Тогда если  $m_2 = 0$ , то  $\Lambda(\alpha) = \frac{1}{1 + e^\alpha} = 0$ , что не может выполняться.

Если  $m_1 = 0$ , то  $\Lambda(\alpha) = \frac{1}{1 + e^\alpha} = 1$ , то есть  $e^\alpha = 0$ , что не может выполняться.

Аналогично со вторым выражением из FOC.

Выкладки могут отличаться, но смысл такой же.

Приятель Ксении по имени Никита обеспокоен растущими ценами. Он оценил регрессию:

$$\hat{Q}_i = 5000 + 0.08Y_i - 150PF_i + 90PNF_i$$

где  $Q_i$  – затраты на продукты питания в регионе  $i$ ,  $Y_i$  – располагаемый доход в регионе  $i$ ,  $PF_i$  – индекс цен на продукты питания в регионе  $i$ ,  $PNF_i$  – индекс цен на непродовольственные товары в регионе  $i$ .

Расчётные t-статистики для оценок коэффициентов равны соответственно: 4.17; 1.6; -1.25 и 0.82.

Коэффициент детерминации равен 0.88, число регионов в выборке Никиты равно 30.

Подобные результаты возможны из-за **ПРОПУСК 7**. Преодолеть эту проблему **ПРОПУСК 8**.

Исходя из изначально полученных результатов, 95%-ный доверительный интервал для коэффициента при располагаемом доходе **ПРОПУСК 9**.

### РЕШЕНИЕ

Подобные результаты возможны из-за МУЛЬТИКОЛЛИНЕАРНОСТИ. Пояснение: признаками мультиколлинеарности являются незначимые коэффициенты и одновременно высокий эр-квадрат.

Преодолеть эту проблему МОЖНО, НАПРИМЕР, УДАЛИВ ОДИН ИЗ ИНДЕКСОВ ЦЕН ИЛИ ПЕРЕЙДЯ К РЕАЛЬНЫМ ПОКАЗАТЕЛЯМ ВМЕСТО НОМИНАЛЬНЫХ. Ещё одна проблема – это оценки по малому числу точек (30).

Исходя из изначально полученных результатов, 95%-ный доверительный интервал для коэффициента при располагаемом доходе СОСТАВЛЯЕТ (-0.0228; 0.1828). Расчёт: стандартная ошибка для оценки коэффициента при располагаемом доходе =  $0.08/1.6 = 0.05$ . Значение из таблицы Стьюдента для 26 степеней свободы 2.056. Тогда доверительный интервал:  $0.08 - 2.056 * 0.05$ ;  $0.08 + 2.06 * 0.05$ .

Никита переходит к изучению потребления на макроуровне. Он столкнулся с системой уравнений, которые описывают закрытую экономику:

$$Y_i = \beta_1 + \beta_2 C_i + \beta_3 I_i + \beta_4 G_i + \varepsilon_i$$

$$C_i = \alpha_1 + \alpha_2 Y_i + u_i,$$

где  $Y_i$  – ВВП,  $C_i$  – потребление,  $I_i$  – инвестиции,  $G_i$  – госрасходы. Случайные шоки  $\varepsilon_i$  и  $u_i$ , некоррелированные. Опытная макроэкономистка Лиза говорит Никите, что при оценке второго уравнения по МНК оценка коэффициента  $\alpha_2$  будет смещена в сторону **ПРОПУСК 10**.

Стандартная ситуация эндогенности:

$$Y_i = \beta_1 + \beta_2 C_i + \beta_3 I_i + \beta_4 G_i + \varepsilon_i = \beta_1 + \beta_2 (\alpha_1 + \alpha_2 Y_i + u_i) + \beta_3 I_i + \beta_4 G_i + \varepsilon_i$$

$$Y_i = \frac{(\beta_1 + \beta_2 \alpha_1) + \beta_3 I_i + \beta_4 G_i + \beta_2 u_i + \varepsilon_i}{1 - \beta_2 \alpha_2}$$

$$\text{cov}(Y_i; u_i) = \frac{\beta_2 \text{var}(u_i)}{1 - \beta_2 \alpha_2}$$

$$E(\hat{\alpha}_2) = E \frac{\text{cov}(C, Y)}{\text{var}(Y)} = \frac{\text{cov}(\alpha_1 + \alpha_2 Y_i + u_i, Y)}{\text{var}(Y)} = \alpha_2 + \frac{\text{cov}(u_i, Y)}{\text{var}(Y)} = \alpha_2 + \frac{\beta_2 \text{var}(u_i)}{(1 - \beta_2 \alpha_2) \text{var}(Y)}$$

Дисперсии  $> 0$ ,  $\beta_2 > 0$ , и  $0 < \alpha_2 < 1$  (это предельная склонность к потреблению). Соответственно, если  $\beta_2 * \alpha_2 < 1$ , то смещение вверх (завышение).

*Штраф: если путаница с крышками - минус 0,5*

Вероятностный предел + 1 балл

Правильное указание всех знаков + 0,5 баллов

Правильное утверждение про положительную корреляцию  $Y$  и  $u$  (можно словами, можно с помощью формулы) + 0,5 баллов

Правильный ответ сам по себе +1 балл (здесь мы засчитываем "зависит от величины коэффициентов" и "положительное смещение/завышена").