

УДК 517.8, 681.5

ИДЕНТИФИКАЦИЯ ЛИНЕЙНЫХ РЕГРЕССИОННЫХ МОДЕЛЕЙ ПРИ НАЛИЧИИ ПОГРЕШНОСТЕЙ ВО ВХОДНЫХ И ВЫХОДНЫХ ДАННЫХ*

Т. А. Макарова¹, А. Н. Тырсин²

¹Государственное образовательное учреждение высшего профессионального образования
«Челябинский государственный университет»,
454021, г. Челябинск, ул. Бр. Кашириных, 129
E-mail: toma.makarova@gmail.com

²Научно-инженерный центр «Надёжность и ресурс больших систем и машин»
Уральского отделения РАН,
620049, г. Екатеринбург, ул. Студенческая, 54а

Рассмотрена задача построения линейных регрессионных моделей при наличии погрешностей во входных и выходных данных. Предложен статистический тест для обнаружения наличия погрешностей измерений входных данных, который не требует предварительной состоятельной оценки коэффициентов в предположении наличия ошибок. Приведены примеры исследования работоспособности теста с помощью статистического моделирования методом Монте-Карло.

Ключевые слова: регрессионные модели, погрешности во входных данных, статистическое моделирование методом Монте-Карло.

Введение. При моделировании в физико-технических приложениях, биологии, медицине, экономике часто используются регрессионные зависимости. Пусть случайные величины y, x_1, \dots, x_k связаны линейным соотношением

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon, \quad (1)$$

где случайная величина ε представляет собой ошибку, которая может быть обусловлена как неточностью измерения фактора y , так и неточностью спецификации самой модели; $\beta_i, i = 0, \dots, k$, — некоторые постоянные коэффициенты. Предположим, что вместо точных значений $x_j, j = 1, \dots, k$, известны значения $u_j, j = 1, \dots, k$:

$$u_j = x_j + \xi_j, \quad (2)$$

где ξ_j — ошибка измерения x_j , случайная величина с нулевым математическим ожиданием.

Определение коэффициентов модели (1), (2) на основе измерений $y_i, u_{1i}, \dots, u_{ki}, i = 1, \dots, n$, представляет собой известную задачу регрессионного анализа данных с погрешностями во входных и выходных данных [1, 2]. Оценивание параметров модели (1), (2) при наличии погрешностей только в выходных данных осуществляется известными методами (метод наименьших квадратов (МНК), взвешенный метод наименьших квадратов (ВМНК), метод наименьших модулей). Наличие случайных погрешностей ξ_j приводит к смещённым и несостоятельным оценкам коэффициентов [1, 2], следовательно, к ложным выводам и неправильным решениям.

*Работа выполнена при поддержке Российского фонда фундаментальных исследований (грант № 10-01-96013-р-Урал-а).

Известные методы состоятельной оценки коэффициентов модели (1), (2) достаточно сложны [1, 3–7], в большинстве случаев они используют некоторую априорную информацию или предположения об исходных данных, требуют серьёзных вычислительных затрат или проведения дополнительных исследований и вычислений. Применение метода максимального правдоподобия не позволяет решать поставленную задачу, потому что оценки имеют сложную нелинейную структуру, и это затрудняет сравнение смещений таких оценок при наличии погрешностей входных данных. Актуальной проблемой является проверка необходимости использования таких процедур, другими словами, проверка наличия ошибок измерения регрессоров в статистических данных согласно модели (1), (2).

Следует отметить, что применение специальных методов для задач, в которых отсутствуют ошибки независимых переменных, как правило, приводит к менее эффективным оценкам по сравнению со стандартными подходами [4, с. 80].

В ряде случаев наличие или отсутствие погрешностей ξ_j заранее неизвестно. С учётом различия методов оценивания параметров модели при наличии или отсутствии погрешностей входных данных требуется идентификация модели.

Для проверки наличия ошибок измерения регрессоров в модели (1), (2) можно использовать тест Хаусмана [4, 8]. Он основан на сравнении некоторой стандартной оценки, являющейся несмещённой и состоятельной только при отсутствии ошибок, и некоторой оценки, являющейся несмещённой и состоятельной при наличии ошибок и их отсутствии. В этом случае расхождение между оценками будет свидетельствовать о наличии ошибки в независимых переменных. Известно несколько вариантов тестов, основанных на применении метода инструментальных переменных [4, 9]. Однако описанный подход требует решения задачи (1), (2), что может быть достаточно затруднительным и чего хотелось бы избежать с помощью подобного теста.

Целью предлагаемой работы является создание статистического теста для проверки наличия ошибок измерения регрессоров в модели (1), (2), который не требовал бы предварительной состоятельной оценки коэффициентов в предположении наличия ошибок.

Постановка задачи. Рассмотрим линейную регрессионную модель

$$y_i = \beta_0 + \beta x_i + \varepsilon_i; \quad u_i = x_i + \xi_i, \quad i = 1, \dots, n, \quad (3)$$

где коэффициенты β_0, β — постоянные величины, причём $\beta \neq 0$. Будем считать, что для модели (3) выполнены следующие предположения:

$$x_i, \varepsilon_i, \xi_i, \quad i = 1, \dots, n, \text{ — независимые реализации случайных величин } x, \varepsilon, \xi, \quad (4)$$

$$E[\xi] = E[\varepsilon] = 0; \quad D[\xi] = \sigma_\xi^2; \quad D[\varepsilon] = \sigma_\varepsilon^2; \quad D[x] = \sigma_x^2, \quad (5)$$

$$\text{cov}(\xi_i, \varepsilon_i) = \text{cov}(y_i, \varepsilon_i) = \text{cov}(y_i, \xi_i) = \text{cov}(x_i, \xi_i) = \text{cov}(x_i, \varepsilon_i) = 0 \quad \text{для всех } i; \quad (6)$$

для случайных величин x и ξ существуют моменты

$$\mu_4(x) = E[(x - Ex)^4]; \quad \mu_4(\xi) = E[(\xi - E\xi)^4]. \quad (7)$$

Требуется по набору наблюдений $\{y_i, u_i\}$, $i = 1, \dots, n$, при справедливости (3)–(7) сделать вывод о наличии или отсутствии погрешности измерения независимой переменной, другими словами, проверить гипотезу $H_0: \{\sigma_\xi^2 = 0\}$ против альтернативной гипотезы $H_1: \{\sigma_\xi^2 > 0\}$.

Построение теста. Регрессионную модель (3) можно представить в виде

$$y_i = \beta_0 + \beta u_i + \nu_i, \quad \nu_i = \varepsilon_i - \beta \xi_i, \quad i = 1, \dots, n. \quad (8)$$

Пусть b_1 и b_2 — соответственно МНК- и ВМНК-оценки коэффициента β в модели (8):

$$b_1 = \sum_{i=1}^n u'_i y'_i \left[\sum_{j=1}^n (u'_j)^2 \right]^{-1} = \beta + \sum_{i=1}^n u'_i \nu_i \left[\sum_{j=1}^n (u'_j)^2 \right]^{-1}, \quad (9)$$

$$b_2 = \sum_{i=1}^n (u'_i)^2 y'_i \left[\sum_{j=1}^n (u'_j)^4 \right]^{-1} = \beta + \sum_{i=1}^n (u'_i)^2 \nu_i \left[\sum_{j=1}^n (u'_j)^4 \right]^{-1}, \quad (10)$$

где $y'_i = y_i - (1/n) \sum_{i=1}^n y_i$; $u'_i = u_i - (1/n) \sum_{i=1}^n u_i$. При справедливости гипотезы H_0 оценки b_1 и b_2 являются несмещёнными. Действительно, в этом случае $\nu_i = \varepsilon_i$, $i = 1, \dots, n$, и согласно (6) математические ожидания вторых слагаемых в выражениях (9) и (10) равны нулю. При справедливости гипотезы H_1 оценки b_1 и b_2 являются смещёнными [3, 5]:

$$E[b_1] = \beta \frac{\sigma_x^2}{\sigma_x^2 + \sigma_\xi^2} = \beta \left(1 - \frac{\sigma_\xi^2}{\sigma_u^2} \right); \quad E[b_2] = \beta \frac{\mu_4(u) - 3\sigma_x^2 \sigma_\xi^2 - \gamma_\xi \sigma_\xi^4}{\mu_4(u)}, \quad (11)$$

где γ_ξ — коэффициент эксцесса случайной величины ξ , $\gamma_\xi = \mu_4(\xi)/\sigma_\xi^4$.

Пусть $A = \sigma_\xi^2/\sigma_u^2$ — доля дисперсии ошибки ξ в общей дисперсии наблюдаемой переменной u , $0 \leq A \leq 1$, при справедливости гипотезы H_0 $A = 0$. Из (11) имеем

$$E[b_1] = \beta(1 - A); \quad E[b_2] = \beta \left[1 - \left(\frac{3}{\gamma_u} A + \frac{\gamma_\xi - 3}{\gamma_u} A^2 \right) \right]. \quad (12)$$

Если $A = 0$, то $E[b_1] = E[b_2]$, обратное верно не во всех случаях. Рассмотрим лемму.

Лемма. Пусть $E[b_1] = E[b_2]$ и справедливо одно из условий: 1) $\xi \sim N(0, \sigma_\xi^2)$, $\gamma_u \neq 3$; 2) $\gamma_\xi \neq 3$, $\gamma_u > \gamma_\xi$. Тогда $A = 0$.

Доказательство. Из (12) и условия $E[b_1] = E[b_2]$ получим уравнение следующего вида:

$$\frac{3 - \gamma_u}{\gamma_u} A + \frac{\gamma_\xi - 3}{\gamma_u} A^2 = 0. \quad (13)$$

Если $\xi \sim N(0, \sigma_\xi^2)$, то $\gamma_\xi = 3$, и при условии $\gamma_u \neq 3$ уравнение (13) имеет единственное решение $A = 0$. Предположим, что $\gamma_\xi \neq 3$, уравнение (13) имеет два решения: $A = 0$, $A = (\gamma_u - 3)/(\gamma_\xi - 3)$, но $A \neq (\gamma_u - 3)/(\gamma_\xi - 3)$, поскольку по условию $(\gamma_u - 3)/(\gamma_\xi - 3) > 1$, а $A \leq 1$.

Теорема. При справедливости гипотезы H_0 в условиях модели (3)–(7) статистика

$$h = \frac{(b_2 - b_1)^2}{\sigma_\nu^2} \left[E \left\{ \sum_{i=1}^n u_i'^6 / \left(\sum_{i=1}^n u_i'^4 \right)^2 - 1 / \sum_{i=1}^n u_i'^2 \right\} \right]^{-1} \quad (14)$$

асимптотически имеет распределение $\chi^2(1)$, σ_ν^2 — дисперсия ошибки ν в уравнении (8).

Доказательство. Предположим, что гипотеза H_0 верна. В данном случае $E[b_1] = E[b_2] = \beta$, причём оценки b_1 и b_2 являются асимптотически нормальными [4, с. 67], тогда

$$h = \frac{(b_2 - b_1)^2}{D[b_2 - b_1]} \stackrel{ac}{\approx} \chi^2(1), \quad (15)$$

где $D[b_2 - b_1]$ — дисперсия разности оценок.

Дисперсию разности оценок b_2 и b_1 запишем в виде [4]

$$\begin{aligned} D[b_2 - b_1] &= D[b_2] + D[b_1] - 2\text{cov}(b_2, b_1) = \\ &= \sigma_\nu^2 E \left\{ \sum_{i=1}^n u_i'^6 / \left(\sum_{i=1}^n u_i'^4 \right)^2 + 1 / \sum_{i=1}^n u_i'^2 \right\} - 2\text{cov}(b_2, b_1). \end{aligned} \quad (16)$$

Из (9) и (10), учитывая $\text{cov}(\nu_i, \nu_j) = \text{cov}(\varepsilon_i, \varepsilon_j) = 0$ при $i \neq j$, имеем

$$\begin{aligned} \text{cov}(b_2, b_1) &= E[(b_2 - \beta)(b_1 - \beta)] = \\ &= E \left[\left(1 / \sum_{i=1}^n u_i'^2 \right) \left(\sum_{i=1}^n u_i'^4 y_i' / \sum_{i=1}^n u_i'^4 \right) \right] = \sigma_\nu^2 E \left[1 / \sum_{i=1}^n u_i'^2 \right]. \end{aligned} \quad (17)$$

Подставив (17) в (16), получим

$$D[b_2 - b_1] = D[b_2] - D[b_1] = \sigma_\nu^2 E \left\{ \sum_{i=1}^n u_i'^6 / \left(\sum_{i=1}^n u_i'^4 \right)^2 - 1 / \sum_{i=1}^n u_i'^2 \right\}. \quad (18)$$

Из (15) и (18) следует справедливость (14).

Пусть выполнены условия леммы, сформулируем статистический критерий δ для проверки гипотезы H_0 против альтернативы H_1 для заданного уровня значимости α :

$$\delta(Y, U) = \begin{cases} H_0, & h(Y, U) < \chi_\alpha^2, \\ H_1, & h(Y, U) \geq \chi_\alpha^2, \end{cases}$$

где $Y = (y_1, \dots, y_n)$, $U = (u_1, \dots, u_n)$ — исходные данные; $h(Y, U)$ — статистика, рассчитанная согласно формуле (14); χ_α^2 — α -квантиль распределения $\chi^2(1)$.

Моделирование. Исследование работоспособности предложенного метода было проведено с помощью моделирования методом Монте-Карло нескольких задач с различными законами распределения независимой переменной x . Пусть $\varepsilon \sim N(0, 0,3)$, $\xi \sim N(0, \sigma_\xi^2)$, теоретические коэффициенты регрессии $\beta_0 = 0,5$, $\beta_1 = 1,0$. Уровень значимости зададим $\alpha = 0,05$.

Рассмотрено несколько вариантов распределения независимой переменной x : экспоненциальное (Exp), логнормальное (LogNorm), Лапласа (Laplas).

В таблице представлены оценки мощности теста для различных законов распределения случайной величины x и различных отношений дисперсий ошибки ξ и наблюдаемой переменной u (отношение $A = \sigma_\xi^2 / \sigma_u^2$). Оценки получены методом Монте-Карло для выборок размера 500 и 1000, количество испытаний 2000.

Согласно (12) величина A соответствует смещению МНК-оценки. По результатам моделирования мощность теста растёт с увеличением смещения МНК-оценок и размера выборки, что свидетельствует в пользу состоятельности критерия.

Размер выборки	Отношение дисперсий A	Распределение			Размер выборки	Отношение дисперсий A	Распределение		
		Exp	LogNorm	Laplas			Exp	LogNorm	Laplas
500	0	0,04	0,05	0,05	1000	0	0,05	0,05	0,05
	0,05	0,16	0,60	0,22		0,05	0,26	0,78	0,35
	0,10	0,44	0,96	0,51		0,10	0,71	1	0,76
	0,20	0,85	1	0,85		0,20	0,98	1	0,98
	0,30	0,96	1	0,94		0,30	1	1	1
	0,40	0,98	1	0,94		0,40	1	1	1
	0,50	0,98	1	0,91		0,50	1	1	1

Множественная линейная регрессия с ошибками в переменных. Рассмотрим линейную модель множественной регрессии

$$y_i = \beta_0 + \beta_1 x_i^1 + \dots + \beta_k x_i^k + \varepsilon_i; \quad u_i^j = x_i^j + \xi_i^j, \quad j = 1, \dots, k, \quad i = 1, \dots, n, \quad (19)$$

где $\beta_0, \beta_1, \dots, \beta_k$ — постоянные коэффициенты, причём $\beta_j \neq 0, j = 1, \dots, k$. Для модели (19) будем считать, что выполнены следующие предположения:

$$x_i^j, \varepsilon_i, \xi_i^j, \quad i = 1, \dots, n, \quad - \text{независимые реализации}$$

$$\text{случайных величин } x^j, \varepsilon, \xi^j, \quad j = 1, \dots, k, \quad (20)$$

$$E[\xi^j] = E[\varepsilon] = 0; \quad D[\xi^j] = \sigma_{\xi^j}^2; \quad D[\varepsilon] = \sigma_{\varepsilon}^2; \quad D[x^j] = \sigma_{x^j}^2, \quad (21)$$

$$\text{cov}(\xi_i^j, \varepsilon_i) = \text{cov}(y_i, \varepsilon_i) = \text{cov}(y_i, \xi_i^j) = \text{cov}(x_i^j, \xi_i^j) = \text{cov}(x_i^j, \varepsilon_i) = 0 \quad \text{для всех } i, j; \quad (22)$$

для случайных величин x^j и ξ^j существуют моменты

$$\mu_4(x^j) = E[(x^j - Ex^j)^4]; \quad \mu_4(\xi^j) = E[(\xi^j - E\xi^j)^4]. \quad (23)$$

Также будем рассматривать наблюдаемую случайную величину $u^j = x^j + \xi^j, \sigma_{u^j}^2 = \sigma_{x^j}^2 + \sigma_{\xi^j}^2$.

Требуется по набору наблюдений $\{y_i, u_i^1, \dots, u_i^k\}, i = 1, \dots, n$, при справедливости (19)–(23) сделать вывод о наличии или отсутствии погрешностей измерения независимой переменной $x^l, 1 \leq l \leq k$, проверить гипотезу $H_0: \{\sigma_{\xi^l}^2 = 0\}$ против альтернативной гипотезы $H_1: \{\sigma_{\xi^l}^2 > 0\}$.

Представим регрессию в матричном виде:

$$\mathbf{y} = \mathbf{U}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\beta} = (\beta_1, \dots, \beta_k)^T, \quad \mathbf{y} = (y'_1, \dots, y'_n)^T, \quad \boldsymbol{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_n)^T,$$

где \mathbf{U} — $(n \times k)$ -матрица:

$$\mathbf{U} = \{u_i^j, i = 1, \dots, n, j = 1, \dots, k\}, \quad u_i^j = u_i^j - (1/n) \sum_{m=1}^n u_m^j, \quad j = 1, \dots, k.$$

Пусть $\mathbf{b}_1 = (b_1^1, \dots, b_k^1)$ и $\mathbf{b}_2 = (b_1^2, \dots, b_k^2)$ — векторы оценок коэффициентов

$$\mathbf{b}_1^T = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T \mathbf{y}, \quad \mathbf{b}_1^T = (\mathbf{U}^T \mathbf{W} \mathbf{U})^{-1} \mathbf{U}^T \mathbf{W} \mathbf{y},$$

где $\mathbf{W} = \{w_{ij}, i = 1, \dots, k, j = 1, \dots, n\}$ — $(k \times n)$ -матрица; $w_{ij} = 0$ при $i \neq j$, $w_{ii} = u_i^l$. Аналогично случаю парной регрессии покажем, что

$$E[b_l^1] = \beta_l \frac{\sigma_{x^l}^2}{\sigma_{u^l}^2}, \quad E[b_l^2] = \beta_l \frac{\mu_4(u^l) - 3\sigma_{x^l}^2 \sigma_{\xi^l}^2 - \gamma_{\xi^l} \sigma_{\xi^l}^4}{\mu_4(u^l)}.$$

Пусть $\mathbf{V}_1 = V[\mathbf{b}_1]$ и $\mathbf{V}_2 = V[\mathbf{b}_2]$ — ковариационные матрицы оценок \mathbf{b}_1 и \mathbf{b}_2 соответственно, тогда нетрудно показать, что $V[\mathbf{b}_2 - \mathbf{b}_1] = \mathbf{V}_2 - \mathbf{V}_1$. Действительно

$$\begin{aligned} V[\mathbf{b}_2 - \mathbf{b}_1] &= \mathbf{V}_2 + \mathbf{V}_1 - 2\text{cov}(\mathbf{b}_2, \mathbf{b}_1) = \\ &= \mathbf{V}_2 + \mathbf{V}_1 - 2E[(\mathbf{U}^T \mathbf{W} \mathbf{U})^{-1} \mathbf{U}^T \mathbf{W} \boldsymbol{\varepsilon} \boldsymbol{\varepsilon}^T \mathbf{U} (\mathbf{U}^T \mathbf{U})^{-1}] = \\ &= \sigma_\varepsilon^2 E[(\mathbf{U}^T \mathbf{U})^{-1}] + \mathbf{V}_2 - 2\sigma_\varepsilon^2 E[(\mathbf{U}^T \mathbf{U})^{-1}] = \mathbf{V}_2 - \mathbf{V}_1. \end{aligned}$$

Таким образом, для дисперсии l -й компоненты справедливо $D[b_l^2 - b_l^1] = (\mathbf{V}_2)_{ll} - (\mathbf{V}_1)_{ll}$.

Если для случайных величин ξ^l и u^l справедливы условия утверждения леммы, то совпадение оценок b_l^1 и b_l^2 означает отсутствие ошибки измерения независимой переменной x^l в модели (19)–(23). При справедливости H_0 статистика

$$h = \frac{(b_l^2 - b_l^1)^2}{(V_2)_{ll} - (V_1)_{ll}} \stackrel{ac}{\approx} \chi^2(1).$$

Пример. Исследование зависимости потребления от уровня дохода. Согласно известной модели потребления Кейнса доход Y есть основной фактор, который определяет потребление C , и связь между данными величинами линейная. Фридман, сформулировав гипотезу постоянного дохода [10], предложил рассматривать текущий доход как сумму двух компонент: постоянного дохода Y^{cst} и временного дохода Y^{rnd} . Постоянный доход является той частью дохода, которая согласно ожиданиям сохранится в будущем. Иными словами, постоянный доход есть средний доход, а временный — случайное отклонение от этого среднего значения. Фридман считал, что потребление должно в основном зависеть именно от постоянного дохода.

На основе квартальных данных о динамике дохода и потребления в США в период с 1947 по 2011 год (www.economagis.com) рассмотрим регрессионную модель следующего вида:

$$C_i = \beta_0 + \beta Y_i^{cst}, \quad Y_i = Y_i^{cst} + Y_i^{rnd}, \quad i = 1, \dots, n, \quad n = 256.$$

Проведём тест на наличие случайной составляющей Y^{rnd} . По формулам (9), (10) и (14) были рассчитаны значения оценок b_1 , b_2 и значение статистики h : $b_1 = 8,36 \cdot 10^{-3}$, $b_2 = 7,8 \cdot 10^{-3}$, $h = 64,45$. Для уровня значимости $\alpha = 0,05$ квантиль $\chi^2(1) = 3,84$. Таким образом, гипотезу об отсутствии погрешности Y^{rnd} следует отклонить. Полученный результат свидетельствует в пользу гипотезы Фридмана. Также следует отметить, что оценка склонности к потреблению (коэффициента β), полученная стандартными методами, будет заниженной относительно истинного значения.

Заключение. Для решения задачи идентификации модели (1), (2) предложен статистический тест, позволяющий для достаточно общих условий выявлять наличие погрешностей измерений входных данных. Результаты статистического моделирования методом Монте-Карло подтверждают состоятельность такого теста для различных альтернатив. Теоретическое рассмотрение данного вопроса является направлением дальнейших исследований.

СПИСОК ЛИТЕРАТУРЫ

1. **Кендалл М. Дж., Стюарт А.** Статистические выводы и связи. М.: Наука, 1973. 900 с.
2. **Себер Дж.** Линейный регрессионный анализ. М.: Мир, 1980. 456 с.
3. **Демиденко Е. З.** Линейная и нелинейная регрессия. М.: Финансы и статистика, 1981. 302 с.
4. **Green W. H.** Econometric Analysis. New Jersey, 2003. 1026 p.
5. **Тимашев С. А., Тырсин А. Н.** Оценивание линейных структурных соотношений между случайными величинами // Заводская лаборатория. 2010. **76**, № 3. С. 68–71.
6. **Тимашев С. А., Тырсин А. Н.** Построение линейной регрессионной модели на основе энтропийного подхода // Заводская лаборатория. 2009. **75**, № 3. С. 66–69.
7. **Erickson T., Whited T. M.** Two-step GMM estimation of the errors-in-variables model using high-order moments // Econometric Theory. 2002. **18**, N 3. P. 776–799.
8. **Hausman J.** Specification tests in econometrics // Econometrica. 1978. **46**, N 6. P. 1251–1271.
9. **Ebbes P., Wedel M., Bockenholt U., Steerneman T.** Solving and testing for regressor-error in dependence when no instrumental variables are available: with new evidence for the effect of education on income // Quantitative Marketing and Economics. 2005. **3**, N 4. P. 365–392.
10. **Friedman M. A.** A Theory of Consumption Function. Princeton: Princeton University Press, 1957. 260 p.

Поступила в редакцию 9 августа 2011 г.
