

ПРИМЕНЕНИЕ ЗНАКОВЫХ КРИТЕРИЕВ К АНАЛИЗУ ЛИНЕЙНЫХ МОДЕЛЕЙ НАБЛЮДЕНИЙ

Д.Г. Белкин

*Пермский государственный национальный
исследовательский университет, г. Пермь*

Линейные модели наблюдений получили широкое применение в разнообразных статистических приложениях. Традиционно, самым распространенным методом их анализа является метод наименьших квадратов. Этот метод позволяет получить глубокие статистические результаты в предположении, что случайные ошибки наблюдений распределены по нормальному закону. В противном случае, выводы, полученные средствами гауссовской статистики, рискуют оказаться ошибочными. Поэтому в последние десятилетия получили развитие непараметрические методы анализа линейных моделей.

К числу таких методов относится знаковый метод анализа линейных моделей [1], в основе которого лежит предположение о том, что независимые случайные ошибки наблюдений с равными вероятностями принимают положительные и отрицательные значения. При этом они даже не обязаны быть одинаково распределёнными. Так как в этом методе используются не сами наблюдения, а их знаки (или знаки остатков), естественно называть этот метод знаковым.

Важнейшим свойством знаковых процедур является независимость знаковых тестовых статистик от распределения исходных данных. Другие их привлекательные свойства – асимптотическая нормальность при минимальных ограничениях на распределение данных и устойчивость к выбросам в данных.

Общие подходы к построению знаковых процедур, ориентированных на проверку гипотез, изложены в [1]. Однако, их реализация требует значительных усилий и предполагает дополнительно глубокие знания в области линейной алгебры. Между тем применительно к анализу линейных регрессионных моделей при выполненных классических предположениях Гаусса-Маркова, включающих нормальное распределение случайных ошибок, построена простая теория [2], позволяющая проверять различные линейные гипотезы. В частности, хорошо известны t - и F - критерии для проверки гипотез о значимости отдельных коэффициентов линейной модели, о значимости модели в целом и о наличии структурных изменений в линейной модели. В данной

работе приводятся результаты, существенно упрощающие реализацию знаковых критериев для решения этих трех задач.

Рассмотрим общую линейную модель наблюдений

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + \varepsilon_i, \quad i = \overline{1, n} \quad (1)$$

где $\{x_{ij}\}$ – заданные числовые значения, y_i – значения переменной y в i -м наблюдении, β_0, \dots, β_k – неизвестные коэффициенты модели, ε_i – случайная ошибка i -го наблюдения. При этом ошибки $\{\varepsilon_i, i = 1, \dots, n\}$ являются независимыми случайными величинами, имеющими одно и то же распределение с медианой, равной нулю.

Как показано в [1], при выполнении ряда условий регулярности, накладываемых на модель (1), проверку любой линейной гипотезы о векторе параметров $\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_k)^\top$ с помощью знаковой процедуры можно осуществить с помощью неравенств

$$\left| \mathbf{B}^\top S(\hat{\mathbf{Y}}) \right|^2 < q_{1-\varepsilon} \quad (2)$$

или

$$S^\top(\hat{\mathbf{Y}}) \mathbf{B} (\mathbf{B}^\top \mathbf{B})^{-1} \mathbf{B}^\top S(\hat{\mathbf{Y}}) < \hat{q}_{1-\varepsilon}. \quad (3)$$

где \mathbf{B} – некоторая матрица, вид которой определяется проверяемой гипотезой; $q_{1-\varepsilon}$ и $\hat{q}_{1-\varepsilon}$ – квантили распределения уровня $1 - \varepsilon$ случайных величин $|\mathbf{B}^\top \boldsymbol{\zeta}|^2$ и $S^\top(\boldsymbol{\zeta}) \mathbf{B} (\mathbf{B}^\top \mathbf{B})^{-1} \mathbf{B}^\top S(\boldsymbol{\zeta})$ соответственно; $S(\hat{\mathbf{Y}})$ – вектор знаков оценки $\hat{\mathbf{Y}}$ вектора результатов наблюдений $\mathbf{Y} = (y_1, \dots, y_n)^\top$, вычисляемой в условиях справедливости проверяемой гипотезы. Вектор $\boldsymbol{\zeta} = (\zeta_1, \dots, \zeta_n)^\top$ имеет независимые компоненты с распределением: $P(\zeta_i = -1) = P(\zeta_i = 1) = 0.5, \quad i = 1, \dots, n$.

Основные результаты данной работы приведены ниже в теоремах 1 – 3. В них дано явное описание матриц \mathbf{B} , позволяющих построить знаковые критерии (2) – (3) для проверки гипотез о значимости отдельных

коэффициентов линейной модели, о значимости модели в целом, а также о наличии структурных изменений в модели (1).

Перед тем как сформулировать теоремы, введем следующие обозначения.

\mathbf{X}_i – i -й столбец исходной матрицы наблюдений

$\mathbf{X} = \left\| x_{i,j} \right\|, \{i = \overline{1, n}, j = \overline{1, k}\}$. $\mathbf{V}_{(i)}$ – вектор, получаемый из вектора \mathbf{V}

удалением i -го элемента, $\mathbf{W}_{(i)}$ – матрица, получаемая из матрицы \mathbf{W}

удалением i -го столбца. $\overline{\mathbf{X}_i \mathbf{X}_j} = \frac{1}{n} \sum_{k=1}^n x_{i,k} x_{j,k}$, $\overline{\mathbf{X}_i} = \frac{1}{n} \sum_{k=1}^n x_{i,k}$.

Теорема 1. В условиях регулярности проверку гипотезы о незначимости коэффициента $H_0 : \beta_i = 0, i \in \{1, 2, \dots, k\}$ в модели (1) можно осуществить с помощью матрицы \mathbf{B} , имеющей следующий вид:

$$\mathbf{B} = -\left(\mathbf{X}_1 - \overline{\mathbf{X}_1} \cdot \mathbf{1}_n \quad \mathbf{X}_2 - \overline{\mathbf{X}_2} \cdot \mathbf{1}_n \quad \dots \quad \mathbf{X}_k - \overline{\mathbf{X}_k} \cdot \mathbf{1}_n\right)_{(i)}^T \mathbf{X}_l^{-1} \boldsymbol{\Psi} + \left(\mathbf{X}_i - \overline{\mathbf{X}_i} \cdot \mathbf{1}_n\right),$$

где

$$\boldsymbol{\Psi} = \begin{pmatrix} \overline{\mathbf{X}_k} \\ \overline{\mathbf{X}_1 \mathbf{X}_k} \\ \dots \\ \overline{\mathbf{X}_k \mathbf{X}_k} \end{pmatrix}_{(i)}, \quad \mathbf{X}_l = \begin{pmatrix} 1 & \overline{\mathbf{X}_1} & \dots & \overline{\mathbf{X}_k} \\ \overline{\mathbf{X}_1} & \overline{\mathbf{X}_1 \mathbf{X}_1} & \dots & \overline{\mathbf{X}_1 \mathbf{X}_k} \\ \dots & \dots & \dots & \dots \\ \overline{\mathbf{X}_{k-1}} & \overline{\mathbf{X}_1 \mathbf{X}_{k-1}} & \dots & \overline{\mathbf{X}_k \mathbf{X}_{k-1}} \end{pmatrix}_{(i)}$$

используя критерии (2) или (3).

Теорема 2. Если $\text{rank}(\mathbf{X}) = k + 1$, то проверку гипотезы о незначимости модели (1) можно осуществить с помощью матрицы \mathbf{B} , имеющей следующий вид:

$$\mathbf{B} = \left(\mathbf{X}_1 - \overline{\mathbf{X}_1} \cdot \mathbf{1}_n \quad \dots \quad \mathbf{X}_k - \overline{\mathbf{X}_k} \cdot \mathbf{1}_n\right).$$

Также, используя знаковый критерий вида (2) или (3), можно проверить гипотезу об отсутствии структурных изменений в модели (1)

$H_0 : \beta_{0,1} = \beta_{0,2}, \beta_{1,1} = \beta_{1,2}, \dots, \beta_{k,1} = \beta_{k,2}$ по результатам двух серий наблюдений:

$$y_i = \beta_{01} + \beta_{11}x_{i1} + \dots + \beta_{k1}x_{ik} + \varepsilon_i, \quad i = \overline{1, n_1},$$

$$y_i = \beta_{02} + \beta_{12}x_{i1} + \dots + \beta_{k2}x_{ik} + \varepsilon_i, \quad i = \overline{n_1 + 1, n_1 + n_2}, \quad n_1 + n_2 = n. \quad (4)$$

Введем дополнительно обозначения:

$$\boldsymbol{\beta} = \begin{pmatrix} \boldsymbol{\beta}_I \\ \boldsymbol{\beta}_{II} \end{pmatrix}, \quad \boldsymbol{\beta}_I = (\beta_{01}, \dots, \beta_{k1})^T, \quad \boldsymbol{\beta}_{II} = (\beta_{02}, \dots, \beta_{k2})^T,$$

$$\mathbf{X} = (\mathbf{X}_I \quad \mathbf{X}_{II}), \quad \mathbf{X}_I = \begin{pmatrix} \mathbf{X}_I \\ \mathbf{O}_{n_2 \times (k+1)} \end{pmatrix}, \quad \mathbf{X}_{II} = \begin{pmatrix} \mathbf{O}_{n_1 \times (k+1)} \\ \mathbf{X}_{II} \end{pmatrix},$$

$$\mathbf{X}_I = \begin{pmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ \dots & \dots & \dots & \dots \\ 1 & x_{n_1,1} & \dots & x_{n_1,k} \end{pmatrix},$$

$$\mathbf{X}_{II} = \begin{pmatrix} 1 & x_{n_1+1,1} & \dots & x_{n_1+1,k} \\ 1 & x_{n_1+2,1} & \dots & x_{n_1+2,k} \\ \dots & \dots & \dots & \dots \\ 1 & x_{n,1} & \dots & x_{n,k} \end{pmatrix}.$$

Здесь $\mathbf{O}_{n_i \times (k+1)}$ – нулевая матрица размерности $n_i \times (k+1)$.

Тогда справедлива

Теорема 3. В условиях регулярности проверку гипотезы об отсутствии структурных изменений $H_0: \beta_{01} = \beta_{02}, \dots, \beta_{k1} = \beta_{k2}$ в модели (4) можно осуществить с помощью матрицы \mathbf{B} , имеющей следующий вид:

$$\mathbf{B} = \begin{pmatrix} -\mathbf{X}_I (\mathbf{X}_I^T \mathbf{X}_I)^{-1} \mathbf{X}_I^T \mathbf{X}_{II} \\ \mathbf{X}_{II} \end{pmatrix}$$

используя статистики из (2) или (3).

С использованием приведенных выше теоретических результатов была проведена серия экспериментов над парной линейной моделью наблюдений. Изменяемыми параметрами являлись значения коэффициентов β и тип распределения случайной ошибки ϵ . Целью экспериментов являлось сравнение мощности знаковых критериев с мощностью t - и F -критериев.

Оказалось, что при наличии в выборке выбросов применение знаковых критериев более предпочтительно. Также знаковый критерий показал лучшие результаты и при анализе выборок без выбросов при распределении случайных ошибок по закону Коши.

Список литературы

1. *Болдин М.В., Симонова Г.И., Тюрин Ю.Н.* Знаковый статистический анализ линейных моделей. М.: Наука. Физматлит, 1997. 288 с.
2. *Себер Дж.* Линейный регрессионный анализ: Пер. с англ. М.: Мир, 1980. 456 с.
3. *Шевцов Г.С.* Линейная алгебра: теория и прикладные аспекты: Учеб. Пособие. М.: Финансы и статистика, 2003. 576 с.