

Глава 4. Регрессионный анализ для стационарных объясняющих переменных

Прежде, чем переходить к изложению материала этой главы, заметим, что в этой главе мы не будем различать в обозначениях случайные величины и их наблюдаемые значения – в обоих случаях будут использоваться строчные буквы.

4.1. Асимптотическая обоснованность стандартных процедур

В главе 1 мы уже отмечали, что рассмотренные там случаи, в которых можно использовать стандартные процедуры регрессионного анализа несмотря на то, что объясняющие переменные являются стохастическими (ситуации А, А', В, С), не охватывают наиболее интересных для нас моделей стационарных и нестационарных временных рядов. Это замечание относится и к широко используемым на практике моделям авторегрессии, в том числе и стационарным.

Рассмотрим модель авторегрессии $AR(p)$

$$y_t = \alpha + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t,$$

где ε_t – инновации, образующие процесс белого шума с $D(\varepsilon_t) = \sigma_\varepsilon^2$. Эту модель можно представить в виде линейной модели регрессии

$$y_t = x_t^T \theta + \varepsilon_t,$$

где

$$x_t = (1, y_{t-1}, y_{t-2}, \dots, y_{t-p})^T, \quad \theta = (\alpha, a_1, a_2, \dots, a_p)^T.$$

Но мы не можем использовать для нее результаты, полученные в ситуациях А и В. Хотя ε_s и x_t статистически независимы при $s \geq t$, они оказываются зависимыми уже при $s = t - 1$, поскольку ε_{t-1} участвует в формировании случайной величины y_{t-1} , входящей в состав x_t . Это нарушает условие, входящее в определения ситуаций А и В.

Мы не можем также использовать и результаты, полученные в ситуациях А' и С. Там требовалось, чтобы условное распределение вектора ε при фиксированной матрице X имело вид $N(0, \sigma^2 V)$ с положительно определенной (невырожденной) матрицей V (в ситуации А' это единичная матрица). Однако при фиксированных значениях $x_{t+1} = (1, y_t, y_{t-1}, \dots, y_{t-p+1})^T$ и x_t значение ε_t известно с полной определенностью.

Тем не менее, если $AR(p)$ модель стационарна, то положение вполне благополучно:

Ситуация D

- процесс y_t порождается моделью

$$y_t = \alpha + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t \quad (\varepsilon_t \text{ – инновации});$$

- все корни полинома $1 - a_1z - a_2z^2 - \dots - a_pz^p = 0$ лежат за пределами единичного круга;
- $\varepsilon_t \sim i.i.d., E(\varepsilon_t) = 0, D(\varepsilon_t) = \sigma^2 > 0, E(\varepsilon_t^4) = \mu_4 < \infty$.

При выполнении перечисленных условий, для оценки наименьших квадратов $\hat{\theta}_n$ вектора коэффициентов $\theta = (\alpha, a_1, a_2, \dots, a_p)$, полученной по n наблюдениям, выполняется соотношение

$$n^{1/2} (\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2 Q^{-1}),$$

где Q – положительно определенная матрица, элементы которой выражаются в явной форме через математическое ожидание и автокорреляции процесса y_t . Ковариационная матрица $\sigma^2 Q^{-1}$ асимптотического распределения может быть оценена состоятельно посредством $S_n^{-2}(X_n^T X_n/n)^{-1}$, и это означает, что асимптотически обоснованны статистические процедуры, трактующие распределение $\hat{\theta}_n$ как $N(\theta, S_n^{-2}(X_n^T X_n)^{-1})$. (Здесь X_n – матрица значений объясняющих переменных в n наблюдениях.)

Иными словами, и в рассматриваемой ситуации можно пользоваться стандартными методами регрессионного анализа, имея в виду их асимптотическую обоснованность.

Если перейти к процессам, стационарным относительно детерминированного тренда, то следует отметить возникающую здесь особенность, связанную со сходимостью распределения оценок наименьших квадратов к асимптотическому распределению. Мы поясним эту особенность на следующем примере.

Пусть ряд y_t порождается простой моделью временного тренда

$$y_t = \alpha + \beta t + \varepsilon_t,$$

где $\varepsilon_t \sim i.i.d., E(\varepsilon_t) = 0, D(\varepsilon_t) = \sigma^2 > 0, E(\varepsilon_t^4) = \mu_4 < \infty$. Если и здесь записать модель в стандартной форме

$$y_t = x_t^T \theta + \varepsilon_t, \quad x_t = (1, t)^T, \quad \theta = (\alpha, \beta),$$

то чтобы получить невырожденное асимптотическое распределение оценки наименьших квадратов $\hat{\theta}_n = (\hat{\alpha}_n, \hat{\beta}_n)$, приходится использовать различные нормирующие множители: $(\hat{\alpha}_n - \alpha_n)$ умножается на $T^{1/2}$, а $(\hat{\beta}_n - \beta_n)$ умножается на $T^{3/2}$. Однако это различие компенсируется тем, что аналогичным образом ведут себя и стандартные ошибки для $\hat{\alpha}_n$ и $\hat{\beta}_n$. Как результат, обычные t -статистики имеют асимптотическое $N(0, 1)$ распределение. Иными словами, можно использовать стандартную технику регрессионного анализа, имея в виду ее асимптотическую обоснованность.

Те же самые принципы можно использовать и для исследования процесса авторегрессии произвольного порядка, стационарного относительно детерминированного временного тренда.

Ситуация Е

- процесс y_t порождается моделью

$$y_t = \alpha + \beta t + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + \varepsilon_t \quad (\varepsilon_t - \text{инновации});$$

- все корни полинома $1 - a_1z - a_2 z^2 - \dots - a_p z^p = 0$ лежат за пределами единичного круга;
- $\varepsilon_t \sim i.i.d., E(\varepsilon_t) = 0, D(\varepsilon_t) = \sigma^2 > 0, E(\varepsilon_t^4) = \mu_4 < \infty$.

При выполнении этих предположений обычные t -статистики и статистики qF (где q – количество линейных ограничений на коэффициенты, а F – обычная F -статистика критерия для проверки выполнения этих ограничений) имеют асимптотические $N(0, 1)$ и $\chi^2(q)$ распределения. Можно использовать стандартную технику регрессионного анализа, имея в виду ее асимптотическую обоснованность.

Если не ограничиваться процессами авторегрессии, но оставаться в классе стационарных моделей, то и в этом случае все еще можно надеяться на возможность использования стандартной техники регрессионного анализа, опять имея в виду ее асимптотическую обоснованность.

Рассмотрим линейную модель

$$y = X\theta + \varepsilon, \quad X = X_n,$$

или, в эквивалентной форме,

$$y_t = x_t^T \theta + \varepsilon_t, \quad t = 1, 2, \dots, n,$$

где

$$x_t = (x_{t1}, x_{t2}, \dots, x_{tp})^T -$$

вектор значений p объясняющих переменных в t -м наблюдении, и пусть $\hat{\theta}_n$ – оценка наименьших квадратов вектора коэффициентов $\theta = (\theta_1, \theta_2, \dots, \theta_p)^T$, полученная по n наблюдениям. Известно (см., например, [Green (1997)]), что следующие три условия обеспечивают состоятельность и асимптотическую нормальность $\hat{\theta}_n$ при $n \rightarrow \infty$:

- $\text{plim} \left(\frac{1}{n} \sum_{t=1}^n x_t \varepsilon_t \right) = 0$

[в эквивалентной форме: $\text{plim} (n^{-1} X_n^T \varepsilon) = 0$];

- $\text{plim} \left(\frac{1}{n} \sum_{t=1}^n x_t x_t^T \right) = Q$

[в эквивалентной форме: $\text{plim} (n^{-1} X_n^T X) = Q$], где Q – положительно определенная матрица;

- $\left(\frac{1}{\sqrt{n}} \sum_{t=1}^n x_t \varepsilon_t \right) \rightarrow N(0, \sigma^2 Q)$

[в эквивалентной форме: $(n^{-1/2} X_n^T \varepsilon) \rightarrow N(0, \sigma^2 Q)$].

(Здесь plim – предел по вероятности; стрелка в последнем условии обозначает сходимость по распределению.) Если эти условия выполнены, то при $n \rightarrow \infty$, как и в ситуации D,

$$\sqrt{n} (\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2 Q^{-1}).$$

В работе [Mann, Wald (1943)] авторы показали следующее (**теорема Манна-Вальда**). Если

$$\bullet \quad \text{plim} \left(\frac{1}{n} \sum_{t=1}^n x_t x_t^T \right) = Q$$

[в эквивалентной форме: $\text{plim} (n^{-1} X_n^T X) = Q$], где Q – положительно определенная матрица,

- $\varepsilon_t \sim i.i.d.$, $E(\varepsilon_t) = 0$, $D(\varepsilon_t) = \sigma^2 > 0$, $E|\varepsilon_t|^m < \infty$ для всех $m = 1, 2, \dots$,
- $E(x_t \varepsilon_t) = 0$, $t = 1, 2, \dots, n$,

то тогда выполнены также первое и третье условия из предыдущей тройки условий, обеспечивающих состоятельность и асимптотическую нормальность $\hat{\theta}_n$ при $n \rightarrow \infty$.

Заметим, что условие $E(x_t \varepsilon_t) = 0$, $t = 1, 2, \dots, n$, в сочетании с $E(\varepsilon_t) = 0$, означает, что

$$\text{Cov}(x_{tk}, \varepsilon_t) = 0 \quad \text{для } k = 1, 2, \dots, p,$$

т.е. означает некоррелированность значений объясняющих переменных с ε_t в совпадающие моменты времени. Условие $E|\varepsilon_t|^m < \infty$ для всех $m = 1, 2, \dots$, выполняется, в частности, для нормального распределения ε_t .

Цитированные результаты можно объединить теперь вместе.

Ситуация F

Пусть в линейной модели

$$y_t = x_t^T \theta + \varepsilon_t, \quad t = 1, 2, \dots, n,$$

где

$$x_t = (x_{t1}, x_{t2}, \dots, x_{tK})^T -$$

вектор значений K объясняющих переменных в t -м наблюдении, $\hat{\theta}_n$ – оценка наименьших квадратов вектора коэффициентов $\theta = (\theta_1, \theta_2, \dots, \theta_K)$, полученная по n наблюдениям. Пусть для этой модели выполнены следующие условия:

$$\bullet \quad \text{plim}_{n \rightarrow \infty} \left(\frac{1}{n} \sum_{t=1}^n x_t x_t^T \right) = Q \quad \left(\text{т.е.} \quad \text{plim}_{n \rightarrow \infty} \frac{1}{n} X_n^T X_n = Q \right),$$

где Q – положительно определенная матрица,

- $\varepsilon_t \sim i.i.d.$, $E(\varepsilon_t) = 0$, $D(\varepsilon_t) = \sigma^2 > 0$, $E|\varepsilon_t|^m < \infty$ для всех $m = 1, 2, \dots$,
- $\text{Cov}(x_{tk}, \varepsilon_t) = 0$ для $k = 1, 2, \dots, K$.

Тогда при $n \rightarrow \infty$

$$\sqrt{n} (\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2 Q^{-1}).$$

Предположим теперь, что x_t – **стационарный векторный (K -мерный) ряд**, так что

$$E(x_t) = \mu = \text{const}, \quad \text{Cov}(x_t) = Q, \quad \text{Cov}(x_{tk}, x_{t+s,l}) = \gamma_{kl}(s)$$

при всех t, s для каждой пары $k, l = 1, 2, \dots, K$. (Здесь $\gamma_{kl}(s)$ – **кросс-корреляция** значений k -ой и l -ой компонент векторного ряда x_t , разнесенных на s единиц времени. Если рассматривать s как аргумент, а $\gamma_{kl}(s)$ как функцию от s , то $\gamma_{kl}(s)$ – **кросс-корреляционная функция** k -ой и l -ой компонент векторного ряда x_t .) Тогда первое из трех условий, перечисленных в ситуации F, обеспечивает возможность оценивания

неизвестной ковариационной матрицы $Cov(x_t) = Q$ простым усреднением доступных наблюдению матриц $x_t x_t^T$ по достаточно длинному интервалу $t = 1, 2, \dots, n$.

В рамки ситуации F помещается достаточно распространенный класс **ARX моделей** :

$$y_t = a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + z_t^T \beta + \varepsilon_t,$$

где

$$z_t = (z_{t1}, z_{t2}, \dots, z_{tM})^T, \beta = (\beta_1, \beta_2, \dots, \beta_M)^T.$$

Подобная модель вписывается в ситуацию F, если положить

$$x_t = (y_{t-1}, y_{t-2}, \dots, y_{t-p}, z_1, z_2, \dots, z_M)^T,$$

$$\theta = (a_1, a_2, \dots, a_p, \beta_1, \beta_2, \dots, \beta_M)^T.$$

Пусть для этой модели выполнены следующие условия:

- z_t – стационарный векторный (M -мерный) ряд;
- $\text{plim} \left(\frac{1}{n} \sum_{t=1}^n z_t z_t^T \right) = Q_Z,$

где Q_Z – положительно определенная матрица;

- $\varepsilon_t \sim i.i.d., E(\varepsilon_t) = 0, D(\varepsilon_t) = \sigma^2 > 0, E|\varepsilon_t|^m < \infty$ для всех $m = 1, 2, \dots$;
- $Cov(z_{tm}, \varepsilon_t) = 0$ для $m = 1, 2, \dots, M$;
- $Cov(y_{t-j}, \varepsilon_t) = 0$ для $j = 1, 2, \dots, p$;
- все корни уравнения $a(z) = 1 - a_1 z - a_2 z^2 - \dots - a_p z^p = 0$ лежат вне единичного круга.

Тогда (см. [Green (1993)]) выполнено и первое условие ситуации F, и при $n \rightarrow \infty$ $n^{1/2} (\hat{\theta}_n - \theta) \rightarrow N(0, \sigma^2 Q^{-1})$.

Последнее из перечисленных условий, касающееся корней уравнения $a(z) = 0$, обеспечивает **стабильность** модели ARX. Последнее означает, что по мере продвижения в будущее (т.е. с ростом t) устанавливается определенная **“долговременная” (long-run)** связь между переменными $y_t, z_{t1}, z_{t2}, \dots, z_{tM}$, по отношению к которой происходят достаточно быстрые осцилляции.

4.2. Динамические модели

Среди различных ARX моделей, в эконометрических исследованиях широкое применение нашли **динамические модели (модели с авторегрессионно распределенными запаздываниями – ADL)**

$$y_t = \alpha_0 + a_1 y_{t-1} + a_2 y_{t-2} + \dots + a_p y_{t-p} + (\beta_{10} x_{1,t} + \beta_{11} x_{1,t-1} + \dots + \beta_{1r} x_{1,t-r}) + \dots + (\beta_{s0} x_{s,t} + \beta_{s1} x_{s,t-1} + \dots + \beta_{sr} x_{s,t-r}) + \varepsilon_t.$$

Для такой модели используют обозначение **ADL(p,r; s)**, где p – глубина запаздываний по переменной y_t , r – глубина запаздываний по переменным $x_{1,t}, x_{2,t}, \dots, x_{s,t}$, не являющимся запаздываниями переменной y_t , s – количество таких переменных. При такой форме записи допускается, что некоторые из коэффициентов

β_{ij} равны нулю, так что глубина запаздываний может быть различной для различных переменных $x_{i,t}$.

Модель $ADL(p,r; s)$ можно представить в компактном виде

$$a(L) y_t = \mu + b_1(L) x_{1,t} + \dots + b_s(L) x_{s,t} + \varepsilon_t,$$

где

$$a(L) = 1 - a_1 L - a_2 L^2 - \dots - a_p L^p,$$

$$b_i(L) = \beta_{i0} + \beta_{i1} L + \dots + \beta_{ir} L^r, \quad i = 1, \dots, s.$$

Если выполнено условие стабильности, то y_t представляется в виде

$$y_t = \frac{1}{a(L)} \mu + \frac{1}{a(L)} b_1(L) x_{1,t} + \dots + \frac{1}{a(L)} b_s(L) x_{s,t} + \frac{1}{a(L)} \varepsilon_t,$$

или

$$y_t = \frac{1}{a(L)} \mu + c_1(L) x_{1,t} + \dots + c_s(L) x_{s,t} + \frac{1}{a(L)} \varepsilon_t,$$

где

$$c_i(L) = \frac{b_i(L)}{a(L)}.$$

Долговременную связь между переменными можно найти, полагая в выражении для y_t

$$L = 1, \quad \varepsilon_t \equiv 0.$$

При этом получаем

$$y_t = \frac{1}{a(1)} \mu + c_1(1) x_{1,t} + \dots + c_s(1) x_{s,t};$$

строго говоря, в последнем выражении указание на момент t следует исключить:

$$y = \frac{1}{a(1)} \mu + c_1(1) x_1 + \dots + c_s(1) x_s.$$

Коэффициенты $c_1(1)$, ..., $c_s(1)$ в последнем соотношении называются **долгосрочными мультипликаторами (long-run multipliers)**. Поясним это название на примере модели $ADL(1, 1; 1)$, которую запишем в виде

$$(1 - \alpha_1 L) y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t.$$

При $|\alpha_1| < 1$ получаем равносильное представление

$$y_t = \frac{1}{(1 - \alpha_1 L)} \mu + \frac{1}{(1 - \alpha_1 L)} (\beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t),$$

т.е.

$$y_t = (1 + \alpha_1 + \alpha_1^2 + \dots) \mu + (1 + \alpha_1 L + \alpha_1^2 L^2 + \dots) (\beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t),$$

из которого последовательно находим:

$$\partial y_t / \partial x_t = \beta_0,$$

$$\partial y_{t+1} / \partial x_t = \partial y_t / \partial x_{t-1} = \beta_1 + \alpha_1 \beta_0,$$

$$\partial y_{t+2} / \partial x_t = \partial y_t / \partial x_{t-2} = \alpha_1 \beta_1 + \alpha_1^2 \beta_0,$$

$$\partial y_{t+3} / \partial x_t = \partial y_t / \partial x_{t-3} = \alpha_1^2 \beta_1 + \alpha_1^3 \beta_0,$$

и т.д. Правые части дают значения **импульсных мультипликаторов**, показывающих влияние единовременного (импульсного) изменения значения x_t на текущее и последующие значения переменной y_t . Просуммировав полученные выражения, получаем:

$$\begin{aligned} \partial y_t / \partial x_t + \partial y_t / \partial x_{t-1} + \partial y_t / \partial x_{t-2} + \partial y_t / \partial x_{t-3} + \dots = \\ = \beta_0 (1 + \alpha_1 + \alpha_1^2 + \dots) + \beta_1 (1 + \alpha_1 + \alpha_1^2 + \dots) = \\ = (1 - \alpha_1 L)^{-1} (\beta_0 + \beta_1). \end{aligned}$$

Правая часть этого соотношения, как легко заметить, представляет собой долгосрчный мультипликатор рассматриваемой ADL(1, 1; 1). В соответствии с левой частью, этот мультипликатор показывает изменение значения y_t при изменении на единицу текущего и всех предыдущих значений переменной x_t .

Прежде, чем перейти к рассмотрению примера оценивания конкретной ADL модели, следует заметить следующее.

При выполнении условий, обеспечивающих возможность использования стандартной техники регрессионного анализа (имеется в виду ее асимптотическая обоснованность – см. разд. 4.1, ситуация F):

- Обычная t -статистика имеет асимптотическое $N(0,1)$ распределение.
- Если F – обычная F -статистика для проверки гипотезы о выполнении q линейных ограничений на коэффициенты модели, то статистика qF имеет асимптотическое χ^2 распределение с q степенями свободы.
- При умеренном количестве наблюдений параллельно с асимптотическими распределениями для t и qF можно для контроля использовать и точные (стандартные) распределения (распределение Стьюдента для t -статистики, распределение Фишера для F -статистики). Согласованность получаемых при этом результатов подкрепляет уверенность в правильности соответствующих статистических выводов.
- При наличии в правой части запаздывающих значений объясняемой переменной проверку гипотезы об отсутствии автокоррелированности у ряда ε_t следует производить, используя **критерий Бройша – Годфри**. Критерий Дарбина – Уотсона не годится для этой цели, поскольку в данном случае значения

статистики Дарбина – Уотсона d смещены в направлении значения $d = 2$, так что использование таблиц Дарбина – Уотсона приводит к неоправданно частому неопровержению указанной гипотезы (“презумпция некоррелированности ε_t ”).

Пример

Рассмотрим модель ADL(3, 2; 1)

$$(1 - 0.5L - 0.1L^2 - 0.05L^3)y_t = 0.7 + (0.2 + 0.1L + 0.05L^2)x_t + \varepsilon_t.$$


Для нахождения долговременной связи между переменными y и x полагаем $L = 1$ и $\varepsilon_t \equiv 0$:

$$(1 - 0.5 - 0.1 - 0.05)y = 0.7 + (0.2 + 0.1 + 0.05)x,$$


т.е. $0.35y = 0.7 + 0.35x$, или

$$y = 2 + x.$$

На приводимом ниже графике представлены смоделированная реализация ряда $x_t = 0.7x_{t-1} + \varepsilon_{xt}$, $\varepsilon_{xt} \sim i.i.d. N(0, 1)$, и соответствующая ей реализация ряда y_t , порождаемого указанной моделью ADL(3, 2; 1), где $\varepsilon_t \sim i.i.d. N(0, 1)$, причем ряд ε_t порождается независимо от ряда ε_{xt} . В качестве начальных значений при моделировании были взяты: $x_1 = 0, y_1 = y_2 = y_3 = 0$.



Имея в распоряжении только эти две реализации, мы не знаем, с какой моделью имеем дело. Начнем с оценивания статической модели $y_t = \mu + \beta x_t + \varepsilon_t$ методом наименьших квадратов; в результате получаем оцененную модель $y_t = 1.789 + 0.577x_t + e_t$, где e_t – ряд остатков. График ряда остатков имеет вид:



Здесь обнаруживается явная автокоррелированность ряда остатков, которая подтверждается построенной для него коррелограммой

ACF PAC
F C PAC Q-Stat Prob

			C	4		
*****	*****	.696	.696	9.981	.000	
			C	7		
*****	*	.536	.099	9.868	.000	
				9		
***		.364	0.081	3.801	.000	
				9		
**		.227	0.056	9.279	.000	
				1		
*		.130	0.015	01.10	.000	
				1		
		.057	0.020	01.46	.000	

и критерием Бройша – Годфри с запаздыванием на один шаг, который дает *P*-значение 0.0000. Это означает, что мы имеем дело не со статической, а с динамической моделью. Поэтому следует прежде всего рассмотреть характер поведения обоих рядов и произвести их идентификацию.

Для ряда x_t коррелограмма имеет вид

ACF	PACF	AC	PAC	Q-Stat	Prob
*****	*****	0.686	0.686	48.468	0.000
***	*	0.429	-0.079	67.594	0.000
*	*	0.193	-0.132	71.527	0.000
.	*	0.024	-0.066	71.591	0.000
*	.	-0.058	0.003	71.958	0.000
*	*	-0.140	-0.107	74.090	0.000

По этой коррелограмме ряд x_t идентифицируется как AR(1).

Для ряда y_t коррелограмма имеет вид

ACF	PACF	AC	PAC	Q-Stat	Prob
*****	*****	0.767	0.767	60.58	0.000
*****	*	0.629	0.100	101.75	0.000
*****	.	0.494	-0.042	127.37	0.000
****	.	0.399	0.019	144.32	0.000
***	.	0.318	-0.003	155.21	0.000
**	.	0.257	0.004	162.38	0.000
**					

так что и этот ряд идентифицируется как AR(1).

Такой предварительный анализ ограничивает рассмотрение моделью ADL с глубиной запаздываний, равной единице:

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t.$$

Оценивая такую модель ADL(1, 1; 1), получаем:

Dependent Variable: Y

Variable Coefficient Std. Error t-Statistic Prob.

C	0.558588	0.157276	3.55163	0.0006
Y(-1)	0.695204	0.066095	10.51828	0.0000
X	0.208971	0.126135	1.65673	0.1009
X(-1)	0.161690	0.132352	1.22166	0.2249

Анализ остатков не выявляет автокоррелированности (P -значение критерия Бройша–Годфри при AR(1) альтернативе равно 0.164), не выявляет значимых отклонений от нормальности распределения ε_t (P -значение критерия Jarque – Bera = 0.267), не обнаруживает гетероскедастичности (P -значение критерия Уайта = 0.159), так что можно, опираясь на приведенные выше факты, использовать асимптотическую теорию статистических выводов и на ее основе использовать результаты, получаемые при применении t - и F -критериев.

При проверке гипотезы $H_0: \beta_0 = \beta_1 = 0$ получаем при использовании F -распределения P -значение 0.0032; при использовании асимптотического распределения $\chi^2(2)$ получаем P -значение 0.0022. В обоих случаях эта гипотеза отвергается. Исключение из правой части модели запаздывающей переменной x_{t-1} , коэффициент при которой статистически незначим и имеет большее P -значение, чем коэффициент при x_t , дает:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.517868	0.154098	3.360648	0.0011
Y(-1)	0.719738	0.063131	11.40064	0.0000
X	0.310343	0.095241	3.258511	0.0015
R-squared	0.637523	Mean dependent var	1.844751	
Adjusted R-squared	0.629971	S.D. dependent var	1.709520	
S.E. of regression	1.039901	Akaike info criterion	2.945962	
Sum squared resid	103.8138	Schwarz criterion	3.024602	
Log likelihood	-142.8251	F-statistic	84.42207	
Durbin-Watson stat	2.256404	Prob(F-statistic)	0.000000	

Здесь все коэффициенты имеют высокую значимость, а остатки вполне удовлетворительны.

Если из предыдущей модели исключить не x_{t-1} , а x_t , то это приводит к оцененной модели

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.567821	0.158600	3.580215	0.0005
Y(-1)	0.692523	0.066673	10.38690	0.0000
X(-1)	0.305939	0.100582	3.041698	0.0030
R-squared	0.632818	Mean dependent var	1.844751	
Adjusted R-squared	0.625169	S.D. dependent var	1.709520	
S.E. of regression	1.046627	Akaike info criterion	2.958857	
Sum squared resid	105.1611	Schwarz criterion	3.037497	
Log likelihood	-143.4634	F-statistic	82.72550	
Durbin-Watson stat	2.221594	Prob(F-statistic)	0.000000	

По критерию Шварца чуть более предпочтительной выглядит модель с исключенной x_{t-1} , так что на ней можно и остановиться. Посмотрим, к какому долговременному соотношению приводит такая модель.

Итак, мы останавливаемся на оцененной модели

$$(1 - 0.720L)y_t = 0.518 + 0.310x_t + e_t.$$

Полагая $L = 1$ и $e_t \equiv 0$, получаем: $0.28y_t = 0.518 + 0.310x_t$, так что долговременное соотношение оценивается как

$$y = 1.839 + 1.107x.$$

Это соотношение, конечно, несколько отличается от теоретического. Посмотрим, однако, что дало бы оценивание динамической модели ADL(3, 2; 1). Оценивая такую модель, получаем:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.539617	0.174057	3.100239	0.0026
Y(-1)	0.590293	0.105583	5.590795	0.0000
Y(-2)	0.153936	0.120517	1.277303	0.2048
Y(-3)	-0.031297	0.099814	-0.313555	0.7546
X	0.205570	0.129483	1.587626	0.1159
X(-1)	0.191959	0.153608	1.249666	0.2147
X(-2)	-0.024779	0.138389	-0.179053	0.8583
R-squared	0.643818	Mean dependent var	1.882787	
Adjusted R-squared	0.620072	S.D. dependent var	1.706160	
S.E. of regression	1.051648	Akaike info criterion	3.008022	
Sum squared resid	99.53667	Schwarz criterion	3.193826	
Log likelihood	-138.8891	F-statistic	27.11327	
Durbin-Watson stat	1.999213	Prob(F-statistic)	0.000000	

Если найти долговременное соотношение между y и x на основе такого оцененного уравнения по той же схеме, что и прежде, то получаем:

$$y = 1.882 + 1.300x,$$

и это соотношение отнюдь не ближе к теоретическому, чем то, которое мы получили по редуцированному уравнению. Впрочем, и по критерию Шварца полная оцененная модель хуже редуцированной.

4.3. Векторная авторегрессия

Популярной моделью связи между временными рядами является **векторная авторегрессия (VAR – vector autoregression)**.

В своей простейшей форме такая модель связывает два ряда y_{1t} и y_{2t} следующим образом:

$$y_{1t} = \mu_1 + \pi_{11.1}y_{1,t-1} + \pi_{12.1}y_{2,t-1} + \varepsilon_{1t},$$

$$y_{2t} = \mu_2 + \pi_{21.1}y_{1,t-1} + \pi_{22.1}y_{2,t-1} + \varepsilon_{2t},$$

т.е., в отличие от простого процесса авторегрессии, значение y_{1t} связывается не только с запаздыванием $y_{1,t-1}$, но и с запаздыванием $y_{2,t-1}$ второй переменной y_{2t} . Случайные величины ε_{1t} и ε_{2t} являются **инновациями**:

- $Cov(\varepsilon_{jt}, \varepsilon_{ls}) = 0$ для $t \neq s$ при любых $j, l = 1, 2$;
- $Cov(\varepsilon_{jt}, y_{l,t-r}) = 0$ для $r \geq 1$ при любых $j, l = 1, 2$.

В то же время, для совпадающих моментов времени случайные величины ε_{1t} и ε_{2t} могут быть коррелированными.

Модель векторной авторегрессии для двух рядов допускает включение в правые части уравнений для y_{1t} и y_{2t} и большего количества запаздываний этих переменных. Наибольший порядок запаздываний, включаемых в правую часть, называется **порядком** векторной авторегрессии. Если этот порядок равен p , то для такой модели используют обозначение **VAR(p)**.

В общем случае рассматривается k временных рядов $y_{1t}, y_{2t}, \dots, y_{kt}$. Модель векторной авторегрессии порядка p предполагает, что связь между этими рядами имеет вид

$$\begin{aligned} y_{1t} = & \mu_1 + \pi_{11.1} y_{1,t-1} + \pi_{11.2} y_{1,t-2} + \dots + \pi_{11.p} y_{1,t-p} + \\ & + \pi_{12.1} y_{2,t-1} + \pi_{12.2} y_{2,t-2} + \dots + \pi_{12.p} y_{2,t-p} + \\ & + \dots + \\ & + \pi_{1k.1} y_{k,t-1} + \pi_{1k.2} y_{k,t-2} + \dots + \pi_{1k.p} y_{k,t-p} + \varepsilon_{1t}, \end{aligned}$$

$$\begin{aligned} y_{2t} = & \mu_2 + \pi_{21.1} y_{1,t-1} + \pi_{21.2} y_{1,t-2} + \dots + \pi_{21.p} y_{1,t-p} + \\ & + \pi_{22.1} y_{2,t-1} + \pi_{22.2} y_{2,t-2} + \dots + \pi_{22.p} y_{2,t-p} + \\ & + \dots + \\ & + \pi_{2k.1} y_{k,t-1} + \pi_{2k.2} y_{k,t-2} + \dots + \pi_{2k.p} y_{k,t-p} + \varepsilon_{2t}, \end{aligned}$$

...

$$\begin{aligned} y_{kt} = & \mu_k + \pi_{k1.1} y_{1,t-1} + \pi_{k1.2} y_{1,t-2} + \dots + \pi_{k1.p} y_{1,t-p} + \\ & + \pi_{k2.1} y_{2,t-1} + \pi_{k2.2} y_{2,t-2} + \dots + \pi_{k2.p} y_{2,t-p} + \\ & + \dots + \\ & + \pi_{kk.1} y_{k,t-1} + \pi_{kk.2} y_{k,t-2} + \dots + \pi_{kk.p} y_{k,t-p} + \varepsilon_{kt}, \end{aligned}$$

где $\pi_{ij,r}$ - коэффициент при $y_{j,t-r}$ в уравнении для y_{it} .

Здесь $\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{kt}$ - случайные величины, для которых

- $Cov(\varepsilon_{jt}, \varepsilon_{lt}) = 0$ для $t \neq s$ при любых $j, l = 1, \dots, k$;
- $Cov(\varepsilon_{jt}, y_{l,t-r}) = 0$ для $r \geq 1$ при любых $j, l = 1, \dots, k$;
- $Cov(\varepsilon_{jt}, \varepsilon_{lt})$ могут отличаться от нуля.

Случайные величины $\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{kt}$ образуют случайный вектор $\varepsilon_t = (\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{kt})^T$, компоненты которого некоррелированы по времени и не коррелированы с запаздывающими значениями переменных $y_{1t}, y_{2t}, \dots, y_{kt}$. Этот вектор называют **вектором инноваций (обновлений) относительно информационного множества**

$$Y_{t-1} = (y_{1,t-1}, y_{1,t-2}, \dots, y_{1,t-p}, \dots, y_{k,t-1}, y_{k,t-2}, \dots, y_{k,t-p}).$$

Пример


Рассмотрим следующую модель VAR(1) для двух рядов ($k = 2, p = 1$):

$$y_{1t} = 0.6 + 0.7 y_{1,t-1} + 0.2 y_{2,t-1} + \varepsilon_{1t},$$


$$y_{2t} = 0.4 + 0.2 y_{1,t-1} + 0.7 y_{2,t-1} + \varepsilon_{2t}.$$

Приводимый ниже график иллюстрирует поведение смоделированной пары y_{1t}, y_{2t} порождаемой этой моделью для $t = 2, 3, \dots, 100$. В качестве начальных значений

были взяты $y_{11} = y_{21} = 0$; ε_{1t} и ε_{2t} моделировались как независимые случайные величины, имеющие одинаковое нормальное распределение $N(0, 0.1^2)$.



Следующий график представляет поведение разности $(y_{1t} - y_{2t})$.



Мы видим, что с течением времени поведение рядов стабилизируется: они осциллируют вокруг установившихся уровней. Второй график показывает, что установившийся уровень для ряда y_{1t} превышает установившийся уровень для ряда y_{2t} приблизительно на 0.4 (среднее арифметическое разности $y_{1t} - y_{2t}$ равно 0.403). Такой характер поведения пары y_{1t}, y_{2t} указывает на стабильность данной модели VAR.

Предсказать стабильный характер поведения реализаций рядов, связанных VAR моделью, можно, анализируя коэффициенты модели. Для этого удобно записать VAR(p) модель для k рядов в более компактной форме

$$y_t = \mu + \Pi_1 y_{t-1} + \Pi_2 y_{t-2} + \dots + \Pi_p y_{t-p} + \varepsilon_t.$$

Здесь

$$y_t = (y_{1t}, y_{2t}, \dots, y_{kt})^T, \mu = (\mu_1, \mu_2, \dots, \mu_k)^T, \varepsilon_t = (\varepsilon_{1t}, \varepsilon_{2t}, \dots, \varepsilon_{kt})^T,$$

$\Pi_r = (\pi_{ij,r})$ – матрица размера $k \times k$ коэффициентов при $y_{1,t-r}, y_{2,t-r}, \dots, y_{k,t-r}$ в k уравнениях.

Последнее представление можно записать как

$$y_t - \Pi_1 y_{t-1} - \Pi_2 y_{t-2} - \dots - \Pi_p y_{t-p} = \mu + \varepsilon_t,$$

$$(I_k - \Pi_1 L - \Pi_2 L^2 - \dots - \Pi_p L^p) y_t = \mu + \varepsilon_t,$$

или

$$A(L) y_t = \mu + \varepsilon_t,$$

где

$$A(L) = I_k - \Pi_1 L - \Pi_2 L^2 - \dots - \Pi_p L^p.$$

Условие стабильности такой VAR модели состоит в следующем:

- Все k корней уравнения

$$\det(I_k - z \Pi_1 - z^2 \Pi_2 - \dots - z^p \Pi_p) = 0 \quad (\text{т.е. } \det A(z) = 0)$$

лежат за пределами единичного круга на комплексной плоскости (т.е. модули всех k корней больше единицы).

Если это условие выполняется, то при продвижении вперед по оси времени система постепенно “забывает” о том, при каких начальных значениях y_1, y_2, \dots, y_p она начала реализовываться. Стабильное состояние системы находится путем приравнивания $L = 1$ и $\varepsilon_t = 0$. При этом получаем

$$A(1) y_t = \mu,$$

так что стабильное состояние определяется как

$$y_t = A^{-1}(1) \mu.$$

Пример

Продолжим рассмотрение модели VAR(1) для двух рядов

$$y_{1t} = 0.6 + 0.7 y_{1,t-1} + 0.2 y_{2,t-1} + \varepsilon_{1t},$$

$$y_{2t} = 0.4 + 0.2 y_{1,t-1} + 0.7 y_{2,t-1} + \varepsilon_{2t}.$$

В компактной форме эта система имеет вид

$$y_t = \mu + \Pi_1 y_{t-1} + \varepsilon_t,$$

где

$$y_t = \begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix}, \quad \mu = \begin{pmatrix} 0.6 \\ 0.4 \end{pmatrix}, \quad \Pi_1 = \begin{pmatrix} 0.7 & 0.2 \\ 0.2 & 0.7 \end{pmatrix}, \quad \varepsilon_t = \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{pmatrix},$$

или

$$A(L) y_t = \mu + \varepsilon_t,$$

где

$$A(L) = I_2 - \Pi_1 L = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} - \begin{pmatrix} 0.7L & 0.2L \\ 0.2L & 0.7L \end{pmatrix} = \begin{pmatrix} 1-0.7L & -0.2L \\ -0.2L & 1-0.7L \end{pmatrix},$$

так что

$$A(1) = \begin{pmatrix} 0.3 & -0.2 \\ -0.2 & 0.3 \end{pmatrix}, \quad A^{-1}(1) = \begin{pmatrix} 6 & 4 \\ 4 & 6 \end{pmatrix}.$$

Уравнение $\det A(z) = 0$ принимает здесь вид

$$\det A(z) = \begin{vmatrix} 1-0.7z & -0.2z \\ -0.2z & 1-0.7z \end{vmatrix} = 0,$$

т.е. $(1 - 0.7z)^2 - (0.2z)^2 = 0$, или $(1 - 0.9z)(1 - 0.5z) = 0$. Оба корня $z = 1/0.9$ и $z = 1/0.5$ больше 1, т.е. условие стабильности выполняется.

Долгосрочное (стабильное) поведение системы находим по формуле

$$y_t = A^{-1}(1) \mu = \begin{pmatrix} 6 & 4 \\ 4 & 6 \end{pmatrix} \begin{pmatrix} 0.6 \\ 0.4 \end{pmatrix} = \begin{pmatrix} 5.2 \\ 4.8 \end{pmatrix}.$$

Таким образом, стабильное состояние системы определяется здесь как

$$y_{1t} = 5.2, \quad y_{2t} = 4.8,$$

так что стабильное состояние разности $y_{1t} - y_{2t}$ есть $y_1 - y_2 = 0.4$.

Соответственно, с течением времени, независимо от начальных условий, ряд y_{1t} начинает осциллировать вокруг уровня 5.2, а ряд y_{2t} начинает осциллировать вокруг уровня 4.8; разность $(y_{1t} - y_{2t})$ осциллирует вокруг уровня 0.4. Именно такое поведение смоделированных реализаций рассматриваемой VAR(1) мы и наблюдали ранее.

Векторные авторегрессии, определенные так, как было указано выше, называют также *замкнутыми VAR*, отличая тем самым эти модели от *открытых VAR*, в правые части которых наряду с запаздывающими значениями переменных, находящихся в левых частях уравнений (*эндогенные переменные*), входят и некоторые другие переменные и их запаздывания (*экзогенные переменные*). Проводя различие между эндогенными и экзогенными переменными, по-существу предполагают, что значения экзогенных переменных формируются вне рассматриваемой системы, а значения эндогенных переменных порождаются в рамках этой системы. Фактически, система в этом случае рассматривается как условная по отношению к экзогенным переменным. Заметим, что в замкнутой VAR экзогенные переменные отсутствуют.

Открытую VAR можно представить в виде

$$A(L)y_t = \mu + B(L)x_t + \varepsilon_t,$$

где

$$A(L) = I - \Pi_1 L - \Pi_2 L^2 - \dots - \Pi_p L^p$$

и $B(L)$ – матричные полиномы.

Если все решения уравнения $\det A(z) = 0$ лежат за пределами единичного круга на комплексной плоскости, что необходимо для обеспечения стабильности системы, то тогда справедливо также представление

$$y_t = A^{-1}(L)\mu + C(L)x_t + A^{-1}(L)\varepsilon_t,$$

где $C(L) = A^{-1}(L)B(L)$ – *передаточная функция (transfer function)*. Функция $C(L)$ – матричная функция; она устанавливает влияние единичных изменений в экзогенных переменных на эндогенные переменные.

Долговременную (долгосрочную, стабильную, long-run) связь между экзогенными и эндогенными переменными можно найти, полагая в последнем представлении $L = 1$ и $\varepsilon_t \equiv 0$. При этом получаем:

$$y_t = A^{-1}(1)\mu + C(1)x_t.$$

Матрица $C(1)$ называется *матрицей долгосрочных мультипликаторов*. Ее (i, j) -й элемент $c_{ij}(1)$ представляет влияние единичного изменения x_{jt} на y_{it} в долговременном плане (см. интерпретацию *долгосрочных мультипликаторов* в разд. 4.2).

Пример

На базе рассмотренной выше замкнутой модели VAR(1) для двух рядов построим открытую VAR

$$y_{1t} = 0.6 + 0.7 y_{1,t-1} + 0.2 y_{2,t-1} + 0.1 x_{1,t-1} + 0.2 x_{2,t} + \varepsilon_{1t},$$

$$y_{2t} = 0.4 + 0.2 y_{1,t-1} + 0.7 y_{2,t-1} + 0.2 x_{1,t} + 0.4 x_{2,t-1} + \varepsilon_{2t}.$$

Здесь μ и матричный полином $A(L)$ – те же, что и ранее, а

$$B(L) = B_0 + B_1L = \begin{pmatrix} 0 & 0.2 \\ 0.2 & 0 \end{pmatrix} + \begin{pmatrix} 0.1 & 0 \\ 0 & 0.4 \end{pmatrix}L = \begin{pmatrix} 0.1L & 0.2 \\ 0.2 & 0.4L \end{pmatrix},$$

так что

$$B(1) = B_0 + B_1 = \begin{pmatrix} 0.1 & 0.2 \\ 0.2 & 0.4 \end{pmatrix}.$$

Матрица долгосрочных мультипликаторов равна

$$C(1) = A^{-1}(1)B(1) = \begin{pmatrix} 6 & 4 \\ 4 & 6 \end{pmatrix} \begin{pmatrix} 0.1 & 0.2 \\ 0.2 & 0.4 \end{pmatrix} = \begin{pmatrix} 1.4 & 2.8 \\ 1.6 & 3.2 \end{pmatrix},$$

так что стабильное решение есть

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 5.2 \\ 4.8 \end{pmatrix} + \begin{pmatrix} 1.4 & 2.8 \\ 1.6 & 3.2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix},$$

т.е.

$$y_1 = 5.2 + 1.4x_1 + 2.8x_2,$$

$$y_2 = 4.8 + 1.6x_1 + 3.2x_2.$$


Ниже приведены графики смоделированных реализаций этой открытой системы в случае, когда $x_{1,t}$ и $x_{2,t}$ – независимые друг от друга AR(1) ряды,

$$x_{1,t} = 0.7x_{1,t-1} + v_{1t}, \quad x_{2,t} = 0.5x_{2,t-1} + v_{2t}; \quad v_{1t} \text{ и } v_{2t} \sim i.i.d. N(0, 1).$$

В качестве начальных значений при моделировании взяты

- $x_{11} = x_{21} = 0, y_{11} = y_{21} = 0$ (вариант 1)
- $x_{11} = x_{21} = 0, y_{11} = 5.2, y_{21} = 4.8$ (вариант 2).

В результате получаем:



В первом случае, из-за несоответствия начальных значений переменных стабильным соотношениям, системе требуется некоторое время, чтобы выйти на стабильный режим. Во втором случае начальные значения переменных согласованы с долговременными соотношениями между переменными.

Рассмотрим следующую замкнутую VAR(1) для двух переменных:

$$y_{1t} = 0.8y_{1,t-1} + 0.2y_{2,t-1} + \varepsilon_{1t},$$

$$y_{2t} = 0.2y_{1,t-1} + 0.8y_{2,t-1} + \varepsilon_{2t}.$$

Для этой системы

$$\begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} = \begin{pmatrix} 0.8L & 0.2L \\ 0.2L & 0.8L \end{pmatrix} \begin{pmatrix} y_{1t} \\ y_{2t} \end{pmatrix} + \begin{pmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{pmatrix},$$

так что

$$A(L) = \begin{pmatrix} 1-0.8L & -0.2L \\ -0.2L & 1-0.8L \end{pmatrix}.$$

При этом


$$A(1) = \begin{pmatrix} 0.2 & 0.2 \\ 0.2 & 0.2 \end{pmatrix},$$

определитель этой матрицы равен нулю, и матрица $A^{-1}(1)$ не определена.


Уравнение $\det A(z) = 0$ имеет здесь вид $(1 - 0.8z)^2 - (0.2z)^2 = 0$, т.е.

$$(1 - z)(1 - 0.6z) = 0.$$

Корни этого уравнения равны $(1/0.6)$ и 1 . Наличие корня, равного 1 , нарушает условие стабильности системы. Как ведут себя в этом случае реализации системы? Ниже приводится соответствующий график.



Здесь стабилизации системы не наблюдается. Можно предположить, что это происходит из-за неудачного выбора начальных значений $y_{11} = y_{21} = 0$. Перемоделируем реализации, полагая начальные значения приблизительно равными наблюдаемому “конечному” уровню: $y_{11} = y_{21} = 5$. Новые реализации



по-прежнему не стабилизируются, и это отражает фундаментальное отличие рассматриваемой нестабильной модели VAR от стабильной.

4.4. Некоторые частные случаи динамических моделей

Чтобы не загромождать изложение, мы ограничимся здесь рассмотрением моделей, входящих в качестве частных случаев в модель ADL(1,1;1)

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t.$$

Эти частные случаи, несмотря на свою простоту, дают схематические представления девяти широко используемых типов моделей.

Различные типы моделей соответствуют различным ограничениям на вектор коэффициентов $\theta = (a_1, \beta_0, \beta_1)$. При наличии двух ограничений мы говорим об *однопараметрической* модели, а при наличии одного ограничения – о *двухпараметрической модели*. Полная модель ADL(1,1;1) является *трехпараметрической*. Ниже мы рассматриваем 9 различных типов моделей.

(1) Статическая регрессия ($a_1 = \beta_1 = 0$): $y_t = \mu + \beta_0 x_t + \varepsilon_t$.

Здесь на значение y_t влияет только значение x_t в тот же момент времени; предшествующие значения y_{t-1} и x_{t-1} не влияют на y_t .

Такая модель обычно не характерна для данных, получаемых последовательно во времени, поскольку в таких ситуациях, как правило, случайные величины ε_t автокоррелированы.

(2) Процесс авторегрессии ($\beta_0 = \beta_1 = 0$): $y_t = \mu + a_1 y_{t-1} + \varepsilon_t$.

Здесь значение y_t зависит только от значения y_{t-1} ; значения переменной x_t в моменты t и $(t-1)$ не влияют на y_t .

Подобные ситуации затрудняют экономический анализ и проведение соответствующей экономической политики из-за того, что в этом случае нет “управляющей” переменной, значения которой можно было бы устанавливать самостоятельно с целью управления значениями переменной y_t .

(3) Модель опережающего показателя ($a_1 = \beta_0 = 0$):

$$y_t = \mu + \beta_1 x_{t-1} + \varepsilon_t.$$

Такие модели могут использоваться для прогнозирования, если изменения показателя y следуют с запаздыванием за изменениями показателя x с достаточной надежностью. Однако, при отсутствии серьезных теоретических оснований, коэффициент β_1 вовсе не обязан быть постоянным. В последнем случае это может приводить к некачественным прогнозам, особенно в периоды структурных изменений, когда хороший прогноз особенно необходим. Кроме того, не видно каких-то особых причин для исключения из правой части запаздывающих значений переменной y .

(4) Модель скорости роста ($a_1 = 1, \beta_1 = -\beta_0$)

$$\Delta y_t = \mu + \beta_0 \Delta x_t + \varepsilon_t,$$

($\Delta = 1 - L$, так что $\Delta y_t = y_t - y_{t-1}$, $\Delta x_t = x_t - x_{t-1}$), соответствует модели статической регрессии, но не для рядов в уровнях, а для рядов в разностях (для *продифференцированных* данных). Однако переход к рядам разностей оправдан только если исходные ряды имеют стохастический тренд и коинтегрированы. Об этом мы будем подробно говорить в последующих главах. А пока укажем только на то, что при неоправданном переходе к рядам разностей теряется информация о характере долговременной экономической связи между рядами в уровнях.

(5) Модель распределенных запаздываний ($a_1 = 0$)

$$y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$$

не содержит в правой части запаздываний переменной y . Она страдает теми же недостатками, что и статическая регрессия, но к ним еще может добавиться и проблема мультиколлинеарности переменных x_t и x_{t-1} .

(6) Модель частичной корректировки ($\beta_1 = 0$)

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \varepsilon_t$$

не содержит в правой части запаздывающих значений переменной x . К такой модели приводят, например, следующие соображения.

Пусть $y_t^* = \alpha + \beta x_t$ – целевой уровень переменной y , а фактически приращение $\Delta y_t = y_t - y_{t-1}$ описывается моделью

$$y_t - y_{t-1} = (1 - \lambda)(y_t^* - y_{t-1}) + \varepsilon_t, \quad 0 \leq \lambda \leq 1,$$

т.е.

$$y_t = (1 - \lambda)y_t^* + \lambda y_{t-1} + \varepsilon_t,$$

так что, с точностью до случайной ошибки ε_t , текущее значение y_t равно взвешенному среднему целевого y_t^* и предыдущего значения переменной y . (Например, y_t – уровень запасов, x_t – уровень продаж.) Тогда

$$y_t = y_{t-1} + (1 - \lambda)(\alpha + \beta x_t - y_{t-1}) + \varepsilon_t = (1 - \lambda)\alpha + \lambda y_{t-1} + (1 - \lambda)\beta x_t + \varepsilon_t,$$

или

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \varepsilon_t,$$

где

$$\mu = (1 - \lambda)\alpha, \quad a_1 = \lambda, \quad \beta_0 = (1 - \lambda)\beta.$$

Во многих случаях вывод подобных уравнений приводит к автокоррелированным ошибкам, а игнорирование x_{t-1} часто порождает оценку коэффициента a_1 , существенно отличающуюся от оценки a_1 в полной модели.

(7) Фальстарт, или приведенная форма ($\beta_0 = 0$):

$$y_t = \mu + a_1 y_{t-1} + \beta_1 x_{t-1} + \varepsilon_t.$$

К такой модели можно придти, например, если $x_t = \lambda x_{t-1} + u_t$. Тогда подстановка выражения для x_t в полное уравнение ADL(1,1;1) дает:

$$\begin{aligned} y_t &= \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t \\ &= \mu + a_1 y_{t-1} + (\beta_0 \lambda + \beta_1) x_{t-1} + (\varepsilon_t + \beta_0 u_t), \end{aligned}$$

или

$$y_t = \mu + a_1 y_{t-1} + \beta_1^* x_{t-1} + \varepsilon_t^*.$$

По одному последнему уравнению (*приведенная форма* исходного уравнения) невозможно восстановить значения β_0 и β_1 , не зная значения λ . Т.е. мы можем оценить коэффициенты приведенной формы, но не коэффициенты *структурной формы* (исходного представления ADL(1,1;1)).

(8) Авторегрессионные ошибки ($\beta_1 = -a_1 \beta_0$):

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t - a_1 \beta_0 x_{t-1} + \varepsilon_t.$$

Запишем это уравнение в виде

$$y_t - a_1 y_{t-1} = (1 - a_1)\alpha + \beta_0(x_t - a_1 x_{t-1}) + \varepsilon_t.$$

В последнем уравнении легко узнается известное *преобразование Кохрейна – Оркатта*, используемое для преодоления проблемы автокоррелированности ошибок в модели парной регрессии

$$y_t = \alpha + \beta_0 x_t + u_t, \quad u_t = a_1 u_{t-1} + \varepsilon_t, \quad |a_1| < 1.$$

(9) Модель коррекции ошибок ($|a_1| < 1, \beta_0 + \beta_1 = b(1 - a_1), b \neq 0$):

$$\Delta y_t = \mu + \beta_0 \Delta x_t - (1 - a_1)(y_{t-1} - a - b x_{t-1}) + \varepsilon_t,$$

или

$$\Delta y_t = \beta_0 \Delta x_t - (1 - a_1)(y_{t-1} - a - b x_{t-1}) + \varepsilon_t,$$

где $a = \mu / (1 - a_1)$, $b = (\beta_0 + \beta_1) / (1 - a_1)$.

Модели такого вида будут очень часто встречаться у нас при рассмотрении связей между нестационарными временными рядами. В этих случаях такая модель описывает механизм поддержания *долговременной связи*

$$y = a + b x$$

между переменными y_t и x_t в форме коррекций отклонений

$$y_{t-1} - a - b x_{t-1}$$

от долговременной связи в предыдущий момент времени.

Замечание

Исходную (полную) модель ADL(1,1;1)

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$$

всегда можно преобразовать к виду

$$y_t - y_{t-1} = \mu - (1 - a_1) y_{t-1} + \beta_0 (x_t - x_{t-1}) + (\beta_0 + \beta_1) x_{t-1} + \varepsilon_t.$$

Если выполнено условие $|a_1| < 1$ (условие стабильности модели), то

$$\Delta y_t = \mu + \beta_0 \Delta x_t - (1 - a_1)(y_{t-1} - ((\beta_0 + \beta_1)/(1 - a_1)) x_{t-1}) + \varepsilon_t,$$

и при $\beta_0 + \beta_1 \neq 0$ мы получаем модель коррекции ошибок.

Таким образом, модели с $|a_1| < 1$ и $\beta_0 + \beta_1 \neq 0$ могут быть представлены в равносильной форме в виде модели коррекции ошибок.

Обратим теперь внимание на следующее. На практике мы имеем дело только со статистическими данными и не можем знать точно, какая именно модель лежала в основе *процесса порождения данных (data generating process – DGP)*. Мы можем только, привлекая какие-то теоретические положения или результаты ранее проведенных исследований с другими множествами данных, выбрать некоторую *статистическую модель (statistical model – SM)*, которую, по нашему мнению, можно использовать для описания процесса порождения данных. Выбрав такую модель, мы производим ее оценивание и затем можем по оцененной модели проверять различные гипотезы о ее коэффициентах, строить доверительные интервалы для коэффициентов и прогнозировать значения объясняемых переменных для нового набора объясняющих переменных. Между тем, здесь решающее значение имеет соотношение между истинным процессом порождения данных и выбранной статистической моделью.

Если статистическая модель SM оказывается более полной по сравнению с DGP, то тогда оценивание SM приводит к менее эффективным оценкам. С другой стороны, если процесс порождения данных оказывается полнее, чем выбранная SM, то это приводит к более неприятным последствиям – смещению оценок. Вследствие этого, обычно рекомендуется следовать принципу “от общего к частному”, т.е. первоначально выбирать в качестве статистической модели достаточно полную модель, а затем, производя последовательное тестирование статистической модели, редуцировать исходную статистическую модель к более экономной форме.

Пример


Статистические данные ($n = 100$) порождены стабильной моделью ADL(1,1,1)

$$y_t = 0.5 y_{t-1} + 0.2 x_t + 0.3 x_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim i.i.d. N(0, 0.1^2),$$

$$x_t = 0.5 x_{t-1} + v_t, \quad v_t \sim i.i.d. N(0, 0.5^2),$$

причем ряды ε_t и v_t порождаются независимо друг от друга.

Смоделированные реализации имеют вид



Оценивание по этим реализациям полной модели $ADL(1,1;1)$ в качестве статистической модели дает следующие результаты:

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.014122	0.009556	1.477773	0.1428
Y(-1)	0.555208	0.034143	16.26107	0.0000
X	0.188567	0.018421	10.23666	0.0000
X(-1)	0.258377	0.020673	12.49808	0.0000
R-squared	0.913395	Mean dependent var	0.062869	
Adjusted R-squared	0.910660	S.D. dependent var	0.310554	
S.E. of regression	0.092824	Akaike info criterion	-1.876660	
Sum squared resid	0.818547	Schwarz criterion	-1.771806	

Исключая из правой части статистической модели константу, получаем:

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.565569	0.033621	16.82186	0.0000
X	0.190325	0.018495	10.29043	0.0000
X(-1)	0.256578	0.020764	12.35668	0.0000
R-squared	0.911404	Mean dependent var	0.062869	
Adjusted R-squared	0.909558	S.D. dependent var	0.310554	
S.E. of regression	0.093394	Akaike info criterion	-1.874134	
Sum squared resid	0.837363	Schwarz criterion	-1.795494	
Log likelihood	95.76965	Durbin-Watson stat	2.218619	

Редуцированная модель признается лучшей по критерию Шварца. Проверка ее на адекватность дает следующие результаты.

- Коррелограмма ряда остатков соответствует процессу белого шума.
- Критерий Бройша – Годфри указывает на отсутствие автокоррелированности у ряда ε_t (P-значение = 0.375 при AR(1) альтернативе и 0.165 при AR(2) альтернативе).
- Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.689).
- Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.285).

Иными словами, применение критериев адекватности к оцененной модели дает удовлетворительные результаты.

Посмотрим теперь, что дает оценивание по тем же данным выбираемых в качестве SM перечисленных ранее 8 редуцированных моделей.

SM₁ (статическая регрессия): $y_t = \mu + \beta_0 x_t + \varepsilon_t$.

Оцененная модель:

Dependent Variable: Y

Sample: 1 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
X	0.271208	0.053356	5.082965	0.0000
R-squared	0.174472	Mean dependent var	0.062241	
Adjusted R-squared	0.174472	S.D. dependent var	0.309046	
S.E. of regression	0.280794	Akaike info criterion	0.307561	
Sum squared resid	7.805700	Schwarz criterion	0.333613	
Log likelihood	-14.37805	Durbin-Watson stat	0.839862	

В правой части этой статистической модели нет запаздывающих значений объясняемой переменной. Поэтому здесь можно ориентироваться на значения статистики Дарбина – Уотсона. Низкое значение этой статистики указывает на автокоррелированность ряда ε_t , т.е. на неправильную спецификацию выбранной статистической модели.

SM₂ Процесс авторегрессии: $y_t = \mu + a_1 y_{t-1} + \varepsilon_t$.

Оцененная модель:

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.013941	0.020679	0.674149	0.5018
Y(-1)	0.764874	0.065621	11.65594	0.0000

Поскольку в этой статистической модели правая часть содержит запаздывающее значение объясняемой переменной, ориентироваться на статистику Дарбина – Уотсона не следует. Проверку на отсутствие автокоррелированности для ряда ε_t выполняем, используя критерий Бройша – Годфри. При AR(1) альтернативе Р-значение этого критерия равно 0.00003, так что гипотеза некоррелированности случайных величин ε_t отвергается. Следовательно, выбранная статистическая модель специфицирована неправильно.

SM₃ Модель опережающего показателя: $y_t = \mu + \beta_1 x_{t-1} + \varepsilon_t$.

Оцененная модель:

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.049508	0.019722	2.510238	0.0137
X(-1)	0.455497	0.037291	12.21457	0.0000

При AR(1) альтернативе Р-значение критерия Бройша – Годфри равно 0.0002, гипотеза некоррелированности случайных величин ε_t отвергается. Выбранная статистическая модель специфицирована неправильно.

SM₄ Модель скорости роста: $\Delta y_t = \mu + \beta_0 \Delta x_t + \varepsilon_t$

Оцененная модель

Dependent Variable: D(Y)

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.001126	0.021384	-0.052674	0.9581
D(X)	0.040538	0.033362	1.215078	0.2273
Log likelihood	13.74152	F-statistic	1.476415	
Durbin-Watson stat	1.574116	Prob(F-statistic)	0.227286	

При AR(1) альтернативе Р-значение критерия Бройша – Годфри равно 0.029, гипотеза некоррелированности случайных величин ε_t отвергается. Выбранная статистическая модель специфицирована неправильно.

SM₅ Модель распределенных запаздываний:

$$y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$$

Оцененная модель

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.046032	0.018096	2.543741	0.0126
X	0.156214	0.035435	4.408526	0.0000
X(-1)	0.414363	0.035435	11.69370	0.0000

При AR(1) альтернативе Р-значение критерия Бройша – Годфри равно 0.00000, гипотеза некоррелированности случайных величин ε_t отвергается. Выбранная статистическая модель специфицирована неправильно.

SM₆ Модель частичной корректировки:

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \varepsilon_t$$

Оцененная модель

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.007088	0.015431	0.459354	0.6470
Y(-1)	0.753212	0.048925	15.39514	0.0000
X	0.253493	0.028588	8.867013	0.0000

При AR(1) альтернативе Р-значение критерия Бройша – Годфри равно 0.012, гипотеза некоррелированности случайных величин ε_t отвергается. Выбранная статистическая модель специфицирована неправильно.

SM₇ Приведенная форма: $y_t = \mu + a_1 y_{t-1} + \beta_1 x_{t-1} + \varepsilon_t$.

Оцененная модель

Dependent Variable: Y

Sample(adjusted): 2 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.020438	0.013757	1.485648	0.1406
Y(-1)	0.517457	0.048968	10.56734	0.0000
X(-1)	0.318058	0.028613	11.11579	0.0000

S.E. of regression 0.133909 Akaike info criterion -1.153476

Sum squared resid 1.721440 Schwarz criterion -1.074836

Здесь Р-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.499, а при AR(2) альтернативе равно 0.538. Гипотеза некоррелированности случайных величин ε_t не отвергается, и можно перейти к проверке адекватности другими критериями. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (Р-значение = 0.937). Критерий Уайта не обнаруживает гетероскедастичности (Р-значение = 0.348).

Иными словами, применение критериев адекватности к оцененной модели дает удовлетворительные результаты. Поэтому возможно осуществить редукцию модели, основываясь на статистической незначимости константы в правой части уравнения. Исключение константы из правой части дает:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.532005	0.048276	11.02001	0.0000
X(-1)	0.316252	0.028765	10.99445	0.0000

S.E. of regression 0.134740 Akaike info criterion -1.150947

Sum squared resid 1.761018 Schwarz criterion -1.098520

Модель без константы предпочтительнее по критерию Шварца.

С точки зрения анализа остатков, последняя модель вполне может быть использована для описания процесса порождения данных. Однако если мы сравним результаты ее оценивания с полученными ранее результатами оценивания модели $y_t = a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$, то обнаружим, что в модели с включением x_t в правую часть значения критериев Акаике (- 1.874) и Шварца (- 1.795) гораздо предпочтительнее.

SM₈ Авторегрессионные ошибки:

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t - a_1 \beta_0 x_{t-1} + \varepsilon_t.$$

Использование нелинейного (итерационного) метода наименьших квадратов для оценивания параметров этого уравнения дает следующие результаты

Dependent Variable: Y

Sample(adjusted): 2 100

Convergence achieved after 19 iterations

Y=C(1)+C(2)*Y(-1)+C(3)*X-(C(2)*C(3))*X(-1)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.014489	0.020617	0.702743	0.4839
C(2)	0.749747	0.070184	10.68267	0.0000
C(3)	0.052577	0.036535	1.439066	0.1534

R-squared 0.592630 Mean dependent var 0.062869

Adjusted R-squared 0.584144 S.D. dependent var 0.310554

S.E. of regression	0.200267	Akaike info criterion	-0.348499
Sum squared resid	3.850250	Schwarz criterion	-0.269859
Log likelihood	20.25069	Durbin-Watson stat	1.447077

При AR(1) альтернативе Р-значение критерия Бройша – Годфри равно 0.0002, гипотеза некоррелированности случайных величин ε_t отвергается. Выбранная статистическая модель специфицирована неправильно.

Рассмотрим также оценивание SM в форме модели коррекции ошибок (хотя эта модель и не является редуцированной).

SM₉ Модель коррекции ошибок:

$$\Delta y_t = \mu + \beta_0 \Delta x_t - (1 - a_1)(y_{t-1} - b x_{t-1}) + \varepsilon_t .$$

Оцененная модель (нелинейный метод наименьших квадратов):

Dependent Variable: D(Y)

Sample(adjusted): 2 100

Convergence achieved after 4 iterations

$$D(Y) = C(1) + C(2)*D(X) + (C(3)-1)*(Y(-1)-C(4)*X(-1))$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.014122	0.009556	1.477773	0.1428
C(2)	0.188567	0.018421	10.23666	0.0000
C(3)	0.555208	0.034143	16.26107	0.0000
C(4)	1.004839	0.078119	12.86299	0.0000
R-squared	0.816395	Mean dependent var	-0.001100	
Adjusted R-squared	0.810597	S.D. dependent var	0.213288	
S.E. of regression	0.092824	Akaike info criterion	-1.876660	
Sum squared resid	0.818547	Schwarz criterion	-1.771806	
Log likelihood	96.89465	Durbin-Watson stat	2.248395	

Р-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.130, а при AR(2) альтернативе равно 0.318; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (Р-значение = 0.711). Критерий Уайта не обнаруживает гетероскедастичности (Р-значение = 0.380).

Иными словами, применение критериев адекватности к оцененной модели дает удовлетворительные результаты. Опираясь на них, редуцируем модель, исключая из правой части константу; при этом получаем:

Dependent Variable: D(Y)

Convergence achieved after 3 iterations

$$D(Y) = C(2)*D(X) + (C(3)-1)*(Y(-1)-C(4)*X(-1))$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(2)	0.190325	0.018495	10.29043	0.0000
C(3)	0.565569	0.033621	16.82186	0.0000
C(4)	1.028710	0.080225	12.82279	0.0000
R-squared	0.812174	Mean dependent var	-0.001100	
Adjusted R-squared	0.808261	S.D. dependent var	0.213288	
S.E. of regression	0.093394	Akaike info criterion	-1.874134	
Sum squared resid	0.837363	Schwarz criterion	-1.795494	

Log likelihood 95.76965 Durbin-Watson stat 2.218619

т.е.

$$\Delta y_t = 0.190 \Delta x_t - 0.434(y_{t-1} - 1.029 x_{t-1}) + e_t .$$

Модель без константы предпочтительнее по критерию Шварца.

Уединяя y_t в левой части уравнения, получаем:

$$y_t = 0.566 y_{t-1} + 0.190 x_t + 0.253 x_{t-1} + e_t .$$

Сравним это уравнение с реально использованным для моделирования

$$\text{DGP: } y_t = 0.5 y_{t-1} + 0.2 x_t + 0.3 x_{t-1} + \varepsilon_t$$

и с результатом оценивания соответствующей ему статистической модели:

$$y_t = 0.565 y_{t-1} + 0.190 x_t + 0.257 x_{t-1} + \varepsilon_t .$$

Найдем долговременное соотношение между переменными y_t и x_t , соответствующее теоретическому процессу порождения данных:

$$y_t = 0.5 y_t + 0.2 x_t + 0.3 x_t \rightarrow y = x .$$

В то же время, долговременное соотношение, получаемое по оцененной SM, соответствующей этому DGP:

$$y_t = 0.565 y_t + 0.190 x_t + 0.257 x_t \rightarrow y = 1.002 x .$$

Далее, долговременное соотношение, получаемое по оцененной SM₉ (в варианте без константы в правой части):

$$y_t = 0.566 y_t + 0.190 x_t + 0.253 x_t \rightarrow y = 1.021 x .$$

Наконец, если взять результаты оценивания модели SM₇ (приведенная форма) без включения константы, то для этого случая получаем:

$$y_t = 0.532 y_t + 0.316 x_t \rightarrow y = 0.675 x .$$

Эти результаты указывают на возможность серьезных последствий, проистекающих из неправильной спецификации SM, когда эта спецификация оказывается уже спецификации DGP. Заметим, что в рамках такой SM отнюдь не всегда удастся обнаружить статистическими методами “узость” выбранной спецификации. Мы смогли это сделать в рамках оцененных статистических моделей SM₁ – SM₆ и SM₈ , но не в модели SM₇ .

Рассмотрим теперь обратную ситуацию, когда, напротив, выбранная для оценивания статистическая модель SM оказывается полнее (“шире”) модели DGP, так что модель, соответствующая DGP, является частным случаем статистической модели, выбранной для оценивания.

В качестве DGP будем последовательно брать модели (1) – (8), а в качестве SM – полную модель ADL(1,1;1) без ограничений на коэффициенты:

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t .$$

Значения коэффициентов при переменных в моделях (1) – (8) будем брать такими же, как и в исходной модели ADL(1,1;1)

$$y_t = 0.5 y_{t-1} + 0.2 x_t + 0.3 x_{t-1} + \varepsilon_t .$$

При моделировании DGP во всех случаях берется $\varepsilon_t \sim i.i.d. N(0, 0.1^2)$.

DGP₁ : Статическая регрессия

$$y_t = 0.2 x_t + \varepsilon_t .$$

Оцененная статистическая модель

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004647	0.010300	-0.451175	0.6529
Y(-1)	0.102848	0.101833	1.009966	0.3151
X	0.186813	0.020222	9.238033	0.0000
X(-1)	0.000201	0.028272	0.007101	0.9943
R-squared	0.507795	Mean dependent var		0.001230
Adjusted R-squared	0.492252	S.D. dependent var		0.143412
S.E. of regression	0.102190	Akaike info criterion		-1.684398
Sum squared resid	0.992068	Schwarz criterion		-1.579545

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.760, а при AR(2) альтернативе равно 0.951, гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.733). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.770).

Иными словами, применение критериев адекватности к оцененной модели дает удовлетворительные результаты. Опираясь на них, можно перейти к проверке гипотез о значениях коэффициентов. При проверке гипотезы о занулении константы и коэффициентов при y_{t-1} и x_{t-1} получаем значение обычной F-статистики, равное $F = 0.738$, и $qF = 2.214$. Исходя из F-распределения для статистики F , получаем P-значение 0.532. Использование асимптотического распределения $\chi^2(3)$ для qF приводит к P-значению 0.529. При обоих вариантах гипотеза о занулении трех указанных коэффициентов не отвергается. Тем самым, можно перейти к оцениванию редуцированной модели $y_t = \mu + \beta_0 x_t + \varepsilon_t$, и это дает:

Dependent Variable: Y

Sample: 1 100

Variable	Coefficient	Std. Error	t-Statistic	Prob.
X	0.190067	0.019291	9.852604	0.0000
R-squared	0.494995	Mean dependent var		0.001935
Adjusted R-squared	0.494995	S.D. dependent var		0.142860
S.E. of regression	0.101522	Akaike info criterion		-1.727139
Sum squared resid	1.020359	Schwarz criterion		-1.701087

Редуцированная модель лучше полной и по критерию Акаике и по критерию Шварца. Остатки от оцененной редуцированной модели проходят тесты на нормальность, отсутствие автокоррелированности и гетероскедастичности.

DGP₂ : Процесс авторегрессии

$$y_t = 0.5y_{t-1} + \varepsilon_t.$$

Оцененная статистическая модель

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004519	0.010315	-0.438075	0.6623
Y(-1)	0.576756	0.084134	6.855173	0.0000
X	-0.013220	0.020253	-0.652774	0.5155
X(-1)	0.021476	0.020228	1.061719	0.2911
R-squared	0.338422	Mean dependent var		-0.007891

Adjusted R-squared	0.317530	S.D. dependent var	0.123820
S.E. of regression	0.102290	Akaike info criterion	-1.682441
Sum squared resid	0.994011	Schwarz criterion	-1.577588

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.600, а при AR(2) альтернативе равно 0.773, гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.654). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.956).

При проверке гипотезы о занулении константы и коэффициентов при x_t и x_{t-1} получаем значение обычной F-статистики, равное $F = 0.641$, и $qF = 1.283$. Исходя из F-распределения для статистики F , получаем P-значение 0.529. Использование асимптотического распределения $\chi^2(3)$ для qF приводит к P-значению 0.527. При обоих вариантах гипотеза о занулении трех указанных коэффициентов не отвергается. Тем самым, можно перейти к оцениванию редуцированной модели $y_t = a_1 y_{t-1} + \varepsilon_t$, и это дает:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.575922	0.082705	6.963585	0.0000
R-squared	0.328274	Mean dependent var	-0.007891	
Adjusted R-squared	0.328274	S.D. dependent var	0.123820	
S.E. of regression	0.101482	Akaike info criterion	-1.727825	
Sum squared resid	1.009258	Schwarz criterion	-1.701612	

Редуцированная модель предпочтительнее и по критерию Акаике и по критерию Шварца. Анализ остатков не выявляет значимых отклонений от сделанных предположений в отношении ряда ε_t .

DGP₃: Модель опережающего показателя

$$y_t = 0.3 x_{t-1} + \varepsilon_t.$$

Оцененная модель

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.005202	0.010305	-0.504767	0.6149
Y(-1)	0.052373	0.054196	0.966363	0.3363
X	-0.012475	0.020310	-0.614213	0.5405
X(-1)	0.315962	0.020645	15.30433	0.0000
R-squared	0.736662	Mean dependent var	0.004035	
Adjusted R-squared	0.728346	S.D. dependent var	0.196154	
S.E. of regression	0.102236	Akaike info criterion	-1.683501	
Sum squared resid	0.992959	Schwarz criterion	-1.578647	

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.614, а при AR(2) альтернативе равно 0.868, гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.740). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.804).

При проверке гипотезы о занулении константы и коэффициентов при x_t и y_{t-1} получаем значение обычной F-статистики, равное $F = 0.577$, и $qF = 1.730$. Исходя из F-распределения для статистики F , получаем P-значение 0.632. Использование

асимптотического распределения $\chi^2(3)$ для qF приводит к Р-значению 0.630. При обоих вариантах гипотеза о занулении трех указанных коэффициентов не отвергается. Тем самым, можно перейти к оцениванию редуцированной модели $y_t = \beta_1 x_{t-1} + \varepsilon_t$, и это дает:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
X(-1)	0.315777	0.019302	16.35987	0.0000
R-squared	0.731866	Mean dependent var		0.004035
Adjusted R-squared	0.731866	S.D. dependent var		0.196154
S.E. of regression	0.101572	Akaike info criterion		-1.726058
Sum squared resid	1.011044	Schwarz criterion		-1.699844

Редуцированная модель предпочтительнее и по критерию Акаике и по критерию Шварца. Анализ остатков не выявляет значимых отклонений от сделанных предположений в отношении ряда ε_t .

DGP₄: Модель скорости роста

$$\Delta y_t = \mu + \beta_0 \Delta x_t + \varepsilon_t.$$


Оцененная модель

Dependent Variable: Y

Included observations: 99 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.029026	0.017741	-1.636049	0.1051
Y(-1)	0.959750	0.024228	39.61303	0.0000
X	0.184064	0.019993	9.206520	0.0000
X(-1)	-0.173461	0.020340	-8.528162	0.0000
R-squared	0.944972	Mean dependent var		-0.599911
Adjusted R-squared	0.943234	S.D. dependent var		0.425076
S.E. of regression	0.101277	Akaike info criterion		-1.702356
Sum squared resid	0.974412	Schwarz criterion		-1.597502
Log likelihood	88.26661	F-statistic		543.7988
Durbin-Watson stat	1.745026	Prob(F-statistic)		0.000000

Отметим близкое к единице оцененное значение коэффициента при y_{t-1} , что может говорить о том, что в DGP “истинное” значение коэффициента равно $a_1 = 1$. Но тогда нарушается условие стабильности системы. И действительно, график ряда y_t , полученного в результате моделирования, имеет вид




явно указывающий на нестационарность ряда.


Вопрос о проверке гипотез типа $H_0: a_1 = 1$ требует специального рассмотрения, и мы будем рассматривать его в последующих главах. Сейчас же, исходя из наблюдаемого поведения ряда y_t и близости оцененного значения коэффициента к 1, займемся оценением модели

$$\Delta y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t.$$

Мы можем использовать для нее стандартную (асимптотическую) технику статистических выводов, поскольку реализация ряда x_t имеет вид



указывающий на стационарность этого ряда, и реализация ряда разностей Δy_t имеет вид



говорящий в пользу стационарности ряда Δy_t .

В результате оценивания получаем:

Dependent Variable: D(Y)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004915	0.010297	-0.477336	0.6342
X	0.185224	0.020163	9.186333	0.0000
X(-1)	-0.179782	0.020163	-8.916410	0.0000

Здесь мы, конечно, обращаем внимание на статистическую незначимость константы, а также на то, что оцененные коэффициенты при переменных x_t и x_{t-1} близки по абсолютной величине и противоположны по знаку. В связи с этим, мы в рамках статистической модели

$$\Delta y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$$

проверяем гипотезу $H_0: \mu = 0, \beta_0 = -\beta_1$. Используя F -распределение для F -статистики и распределение хи-квадрат $\chi^2(2)$ для статистики $qF = 2F$, получаем в обоих случаях P -значение 0.876. Гипотеза H_0 не отвергается, и можно перейти к

оцениванию модели с такими ограничениями, т.е. модели $\Delta y_t = \beta_0 \Delta x_t + \varepsilon_t$. Оцененная модель с ограничениями:

Dependent Variable: D(Y)

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(X)	0.182495	0.015882	11.49045	0.0000

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.328, а при AR(2) альтернативе равно 0.605; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (*P*-значение = 0.673). Критерий Уайта не обнаруживает гетероскедастичности (*P*-значение = 0.988). Таким образом, и в этом случае мы вышли в результате тестирования на статистическую модель, имеющую ту же спецификацию, что и DGP.

DGP₅ Модель распределенных запаздываний

$$y_t = \mu + 0.2 x_t + 0.3 x_{t-1} + \varepsilon_t.$$

Оцененная модель

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.003282	0.010206	-0.321584	0.7485
Y(-1)	0.000523	0.058294	0.008975	0.9929
X	0.181735	0.019977	9.097166	0.0000
X(-1)	0.289502	0.024922	11.61638	0.0000
R-squared	0.804020	Mean dependent var		0.010665
Adjusted R-squared	0.797831	S.D. dependent var		0.225113
S.E. of regression	0.101218	Akaike info criterion		-1.703515
Sum squared resid	0.973283	Schwarz criterion		-1.598661

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.972, а при AR(2) альтернативе равно 0.826; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (*P*-значение = 0.689). Критерий Уайта не обнаруживает гетероскедастичности (*P*-значение = 0.433).

Проверяем гипотезу $H_0: \mu = 0, a_1 = 0$. Используя *F*-распределение для *F*-статистики и распределение хи-квадрат $\chi^2(2)$ для статистики $qF = 2F$, получаем в обоих случаях *P*-значение 0.950. Гипотеза H_0 не отвергается, и можно перейти к оцениванию модели с $\mu = 0, a_1 = 0$, т.е. модели $y_t = \mu + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$. Оцененная модель с ограничениями:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
X	0.181461	0.019754	9.185972	0.0000
X(-1)	0.289367	0.019756	14.64736	0.0000

DGP₆ Модель частичной корректировки

$$y_t = \mu + 0.5 y_{t-1} + 0.2 x_t + \varepsilon_t.$$

Оцененная модель:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
----------	-------------	------------	-------------	-------

C	-0.005099	0.010263	-0.496869	0.6204
Y(-1)	0.592041	0.071296	8.304016	0.0000
X	0.188766	0.020280	9.308077	0.0000
X(-1)	0.000973	0.025019	0.038898	0.9691

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.904, а при AR(2) альтернативе равно 0.723; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.691). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.533).

Проверяем гипотезу $H_0: \mu = 0, \beta_1 = 0$. Используя F-распределение для F-статистики и распределение хи-квадрат $\chi^2(2)$ для статистики $qF = 2F$, получаем в обоих случаях P-значение 0.884. Гипотеза H_0 не отвергается, и можно перейти к оцениванию модели с $\mu = 0, \beta_1 = 0$, т.е. модели $y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \varepsilon_t$. Оцененная модель с ограничениями:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.592666	0.056702	10.45233	0.0000
X	0.188468	0.019202	9.814814	0.0000
R-squared	0.690477	Mean dependent var		0.004719
Adjusted R-squared	0.687286	S.D. dependent var		0.180476
S.E. of regression	0.100924	Akaike info criterion		-1.728911
Sum squared resid	0.988000	Schwarz criterion		-1.676484

DGP₇ Приведенная форма

$$y_t = 0.5 y_{t-1} + 0.3 x_{t-1} + \varepsilon_t.$$

Оцененная модель

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.005886	0.010271	-0.573100	0.5679
Y(-1)	0.559497	0.042762	13.08387	0.0000
X	-0.010318	0.020320	-0.507807	0.6128
X(-1)	0.316645	0.020229	15.65291	0.0000

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.701, а при AR(2) альтернативе равно 0.827; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.740). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.586).

Проверяем гипотезу $H_0: \mu = 0, \beta_0 = 0$. Используя F-распределение для F-статистики и распределение хи-квадрат $\chi^2(2)$ для статистики $qF = 2F$, получаем в обоих случаях P-значение 0.734. Гипотеза H_0 не отвергается, и можно перейти к оцениванию модели с $\mu = 0, \beta_0 = 0$, т.е. к оцениванию модели $y_t = a_1 y_{t-1} + \beta_1 x_{t-1} + \varepsilon_t$. Оцененная модель с ограничениями:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.561389	0.041849	13.41452	0.0000

X(-1)	0.313207	0.019269	16.25422	0.0000
-------	----------	----------	----------	--------

DGP₈ Авторегрессионные ошибки

$$y_t = 0.5y_{t-1} + 0.2x_t - 0.1x_{t-1} + \varepsilon_t.$$

Оцененная модель:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.004519	0.010315	-0.438075	0.6623
Y(-1)	0.576756	0.084134	6.855173	0.0000
X	0.186780	0.020253	9.222532	0.0000
X(-1)	-0.093875	0.025414	-3.693770	0.0004

P-значение критерия Бройша – Годфри при AR(1) альтернативе равно 0.600, а при AR(2) альтернативе равно 0.773; гипотеза некоррелированности случайных величин ε_t не отвергается. Критерий Jarque – Bera не обнаруживает значимых отклонений от нормальности (P-значение = 0.654). Критерий Уайта не обнаруживает гетероскедастичности (P-значение = 0.682).

Исключим из статистической модели статистически незначимую константу:

Dependent Variable: Y

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	0.578309	0.083705	6.908866	0.0000
X	0.186426	0.020151	9.251413	0.0000
X(-1)	-0.094531	0.025263	-3.741827	0.0003

Заметим, что произведение оцененных коэффициентов при y_{t-1} и x_t равно 0.108, т.е. близко по абсолютной величине и противоположно по знаку коэффициенту при x_{t-1} . В связи с этим наблюдением, проверим гипотезу $H_0: \beta_1 = -a_1\beta_0$. Здесь мы имеем дело с нелинейной гипотезой, и результаты проверки могут зависеть от формы записи этого ограничения на коэффициенты. Поэтому мы проверяем указанную гипотезу в трех формах:

$$H_0: \beta_1 = -a_1\beta_0 ; H_0: \beta_0 = -(\beta_1/a_1) ; H_0: a_1 = -(\beta_1/\beta_0).$$

Соответствующие этим формам P-значения $\chi^2(1)$ -критериев равны 0.515, 0.514 и 0.506, так что выводы в отношении гипотезы H_0 согласуются: эта гипотеза не отвергается. Последнее означает, что можно перейти к оцениванию модели с ограничением на коэффициенты в виде $\beta_1 = -a_1\beta_0$, т.е. к модели $y_t = a_1y_{t-1} + \beta_0x_t - a_1\beta_0x_{t-1} + \varepsilon_t$. В итоге получаем оцененную модель

Dependent Variable: Y

Convergence achieved after 3 iterations

$$Y = C(1)*Y(-1) + C(2)*X - (C(1)*C(2))*X(-1)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.575812	0.083369	6.906747	0.0000
C(2)	0.182370	0.019110	9.543254	0.0000

которую можно записать в виде

$$y_t = 0.576y_{t-1} + 0.182x_t - 0.105x_{t-1} + \varepsilon_t.$$

Таким образом, во всех рассмотренных случаях, когда DGP являлся частным случаем выбранной для оценивания статистической модели, последовательное применение метода редукции модели от общего к частному (с предварительной проверкой SM на адекватность) выводило нас на редуцированные модели, спецификация которых соответствовала спецификации DGP. В то же время, как мы видели перед этим, при движении “от частного к общему” возможны ситуации, когда остановка происходит на модели, существенно отличающейся от DGP, хотя и проходящей стандартные тесты на адекватность имеющимся статистическим данным.

Это еще раз подчеркивает предпочтительность использования при подборе моделей по статистическим данным метода “от общего к частному”, т.е. первоначальному выбору достаточно общей модели, проверки ее на адекватность имеющимся статистическим данным, и, в случае признания выбранной модели адекватной данным, последующей редукции этой модели с использованием стандартных критериев спецификации.

В связи с последними замечаниями, еще раз обратимся к модели линейной регрессии с автокоррелированными ошибками, образующими стационарный процесс авторегрессии первого порядка. В учебной литературе по эконометрике довольно часто делается упор на эту модель как средство преодоления проблемы автокоррелированности ошибок в рамках известных процедур Кохрейна – Оркатта или Прайса – Уинстена. Однако, как ясно из предыдущего изложения, такая модель (в нашей нумерации – модель 8) является всего лишь весьма частным случаем общей динамической модели ADL(1,1;1). В рамках этой общей модели

$$y_t = \mu + a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \varepsilon_t$$

модель, о которой идет речь, выделяется выполнением соотношения

$$\beta_1 = -a_1 \beta_0.$$

В то же время, при $\beta_0 \neq 0$ общую модель ADL(1,1;1) можно представить в виде

$$(1 - a_1 L)y_t = \beta_0 \left(1 + \frac{\beta_1}{\beta_0} L \right) x_t + \varepsilon_t,$$

или

$$a(L) y_t = b(L) x_t + \varepsilon_t,$$

где

$$a(L) = 1 - a_1 L, \quad b(L) = \beta_0 \left(1 + \frac{\beta_1}{\beta_0} L \right).$$

(Для простоты мы полагаем $\mu = 0$.)

Если $a_1 = -\frac{\beta_1}{\beta_0}$, то модель принимает вид

$$(1 - a_1 L)y_t = \beta_0 (1 - a_1 L) x_t + \varepsilon_t,$$

так что многочлены $a(L)$ и $b(L)$ имеют **общий множитель** $(1 - a_1 L)$. Разделив обе части уравнения на этот общий множитель, получаем

$$y_t = \beta_0 x_t + u_t,$$

где

$$u_t = \frac{\varepsilon_t}{1 - a_1 L},$$

так что $(1 - a_1 L) u_t = \varepsilon_t$ и $u_t = a_1 u_{t-1} + \varepsilon_t$.

В связи с наличием общего множителя, модель авторегрессионных ошибок относят к классу моделей, носящему название COMFAC (common factors). Рассматриваемая модель обязана принадлежностью к этому классу именно наличию ограничения $\beta_1 = -a_1\beta_0$. Класс COMFAC является весьма частным случаем моделей с авторегрессионно распределенными запаздываниями. Поэтому применение обычной процедуры проверки автокоррелированности ошибок в модели регрессии $y_t = \beta_0 x_t + u_t$ и коррекции обнаруженной автокоррелированности посредством авторегрессионного преобразования переменных, вообще говоря, некорректно. Правильный порядок действий должен состоять

- В установлении пригодности модели $a(L) y_t = b(L) x_t + \varepsilon_t$ с помощью различных критериев адекватности; гипотеза о том, что ряд ε_t является гауссовским белым шумом, не должна отвергаться – в противном случае следует говорить о непригодности уже этой общей модели.
- В проверке гипотезы о том, что многочлены $a(L)$ и $b(L)$ имеют общие корни.
- Наконец, в случае подтверждения обеих гипотез следует проверить гипотезу $H_0: a_1 = 0$ (она соответствует модели статической регрессии). Заметим, что отвержение этой гипотезы непосредственно в модели с автокоррелированными ошибками вовсе не доказывает наличия указанных общих множителей.

Однако здесь имеются некоторые сложности.

На первом шаге гипотеза H_0 : “ ε_t – белый шум” проверяется, в частности, против альтернативы $H_A: \varepsilon_t \sim \text{AR}(k)$ с $k \leq p$, т.е.

$$\varepsilon_t = \rho_1 \varepsilon_{t-1} + \dots + \rho_p \varepsilon_{t-p} + v_t,$$

где $v_t \sim i.i.d.$ и хотя бы одно $\rho_j \neq 0$. Модель, соответствующая альтернативе, имеет вид

$$y_t = a_1 y_{t-1} + \beta_0 x_t + \beta_1 x_{t-1} + \rho_1 \varepsilon_{t-1} + \dots + \rho_p \varepsilon_{t-p} + v_t,$$

и, фактически, речь идет о проверке гипотезы $H_0: \rho_1^2 = \dots = \rho_p^2 = 0$ против $H_A: \rho_1^2 + \dots + \rho_p^2 \neq 0$. Такую проверку можно осуществить, используя стандартный LM критерий Бройша – Годфри. В то же время не рекомендуется использовать для этой цели критерии, основанные на статистиках Бокса – Пирса и Лjung – Бокса из разд. 3.1 и предназначенные для анализа “сырых” рядов. (См., например, статью [Kwan, Sim (1996)].)

Проблемы возникают и с применением стандартного критерия Вальда для проверки гипотезы $H_1: \beta_1 = -a_1\beta_0$ против альтернативы $H_A: \beta_1 \neq -a_1\beta_0$. Дело в том, что эта гипотеза не является линейной, а в таких случаях результаты применения критерия Вальда зависят от того, в какой форме записано ограничение: $\beta_1 = -a_1\beta_0$, $a_1 = -\beta_1/\beta_0$ или $\beta_0 = -\beta_1/a_1$, что может приводить к противоречивым выводам.

Отметим также проблему, связанную с последовательным использованием нескольких критериев проверки гипотез. В рамках рассмотренной процедуры приходится, по крайней мере, сначала проверять гипотезу H_1 о наличии общих множителей, а затем, если она не отвергается, проверять гипотезу $H_2: a_1 = 0$ о некоррелированности ошибок в статической модели регрессии.

Пусть каждая из этих гипотез проверяется на уровне значимости α , скажем, $\alpha = 0.05$. Какова в такой ситуации вероятность ошибочного отвержения модели статической регрессии? Имеем:

$$\begin{aligned} P\{\text{ошибочно отвергается хотя бы одна из гипотез } H_1, H_2\} &\leq \\ &\leq P\{\text{ошибочно отвергается } H_1\} + P\{\text{ошибочно отвергается } H_2\} = \end{aligned}$$

$$= \alpha + \alpha = 2\alpha.$$

Следовательно, если положить $\alpha = 0.025$, то вероятность отвержения модели статической регрессии в рамках двухступенчатой процедуры не будет превышать 0.05. Заметим, что при этом мы еще не принимали в расчет ошибки, связанные с возможностью неправильной диагностики общей модели.