

Многомерные модели временных рядов

Лекция 14



БАЛАКОВСКИЙ ИНЖЕНЕРНО-ТЕХНОЛОГИЧЕСКИЙ ИНСТИТУТ
ФИЛИАЛ НАЦИОНАЛЬНОГО ИССЛЕДОВАТЕЛЬСКОГО ЯДЕРНОГО УНИВЕРСИТЕТА «МИФИ»



План лекции

Модели стационарных временных рядов:

- Модель распределенных лагов;
- Авторегрессионная модель распределенных лагов;
- Автокорреляция.

Многомерные модели временных рядов

Ранее мы рассматривали модели для единственного временного ряда.

Теперь мы будем анализировать модели, включающие несколько рядов.

Мотивация:

- Такой подход может улучшить качество прогнозов;
- Такой подход позволяет отвечать на вопросы о динамических причинно-следственных связях.

Примеры вопросов о динамических причинно-следственных связях

- Как увеличение налога на сигареты скажется на их потреблении в этом году, через год, через пять лет?
- Банк России увеличил ставку рефинансирования. Как это скажется на инфляции через месяц? Через 2 месяца? Через 6 месяцев?
- Как увеличение расходов на рекламу сегодня повлияет на объем продаж в следующем квартале?

Динамические модели со стационарными переменными

В рамках этой лекции мы предполагаем, что выполняется предпосылка о стационарности всех используемых временных рядов.

Модель распределенных лагов

The Distributed-Lag Model

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Предпосылки:

1. Регрессоры экзогенны $E(u_t | x_{t-1}, \dots, x_{t-q}) = 0$
2. Нет совершенной мультиколлинеарности
3. Временные ряды x_t и y_t стационарны
4. Временные ряды x_t и y_t имеют конечные восьмые моменты распределения (техническая предпосылка)

Модель распределенных лагов

The Distributed-Lag Model

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Оценивание:

При выполнении предпосылок 1- 4 МНК дает состоятельные оценки коэффициентов модели.

Модель распределенных лагов

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Интерпретация:

1. δ_0 - мгновенный эффект: мгновенное влияние x_t на y_t
2. δ_j - динамический мультипликатор j -го периода, $j \geq 1$.
3. $\delta_0 + \delta_1 + \dots + \delta_j$ - накопленный динамический мультипликатор j -го периода.
4. $\delta_0 + \delta_1 + \dots + \delta_q$ - долгосрочный динамический мультипликатор (эффект).

Связь расходов на рекламу (x_t) и объема продаж (y_t) фирмы

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \delta_2 x_{t-2} + u_t$$

$$\hat{y}_t = 9,1 + 0,3x_t + 0,9x_{t-1} + 0,6x_{t-2}$$

$\hat{\delta}_0$ - мгновенный эффект: увеличение расходов на рекламу на единицу увеличивает объем продаж в том же периоде на 0,3 единицы.

$\hat{\delta}_0 + \hat{\delta}_1 = 1,2$ - накопленный динамический мультипликатор 1-го периода: увеличение расходов на рекламу на единицу увеличивает объем продаж в сумме в текущем и следующем периодах на 1,2 единицы.

Связь расходов на рекламу (x_t) и объема продаж (y_t) фирмы

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \delta_2 x_{t-2} + u_t$$

$$\hat{y}_t = 9,1 + 0,3x_t + 0,9x_{t-1} + 0,6x_{t-2}$$

$\hat{\delta}_0 + \hat{\delta}_1 + \hat{\delta}_2 = 1,8$ - долгосрочный динамический мультипликатор: увеличение расходов на рекламу на единицу увеличивает объем продаж в сумме по итогам текущего и всех последующих периодов на 1,8 единицы.

Заморозки во Флориде и цены на апельсины

Во Флориде производится значительная часть апельсинов, потребляемых в США.

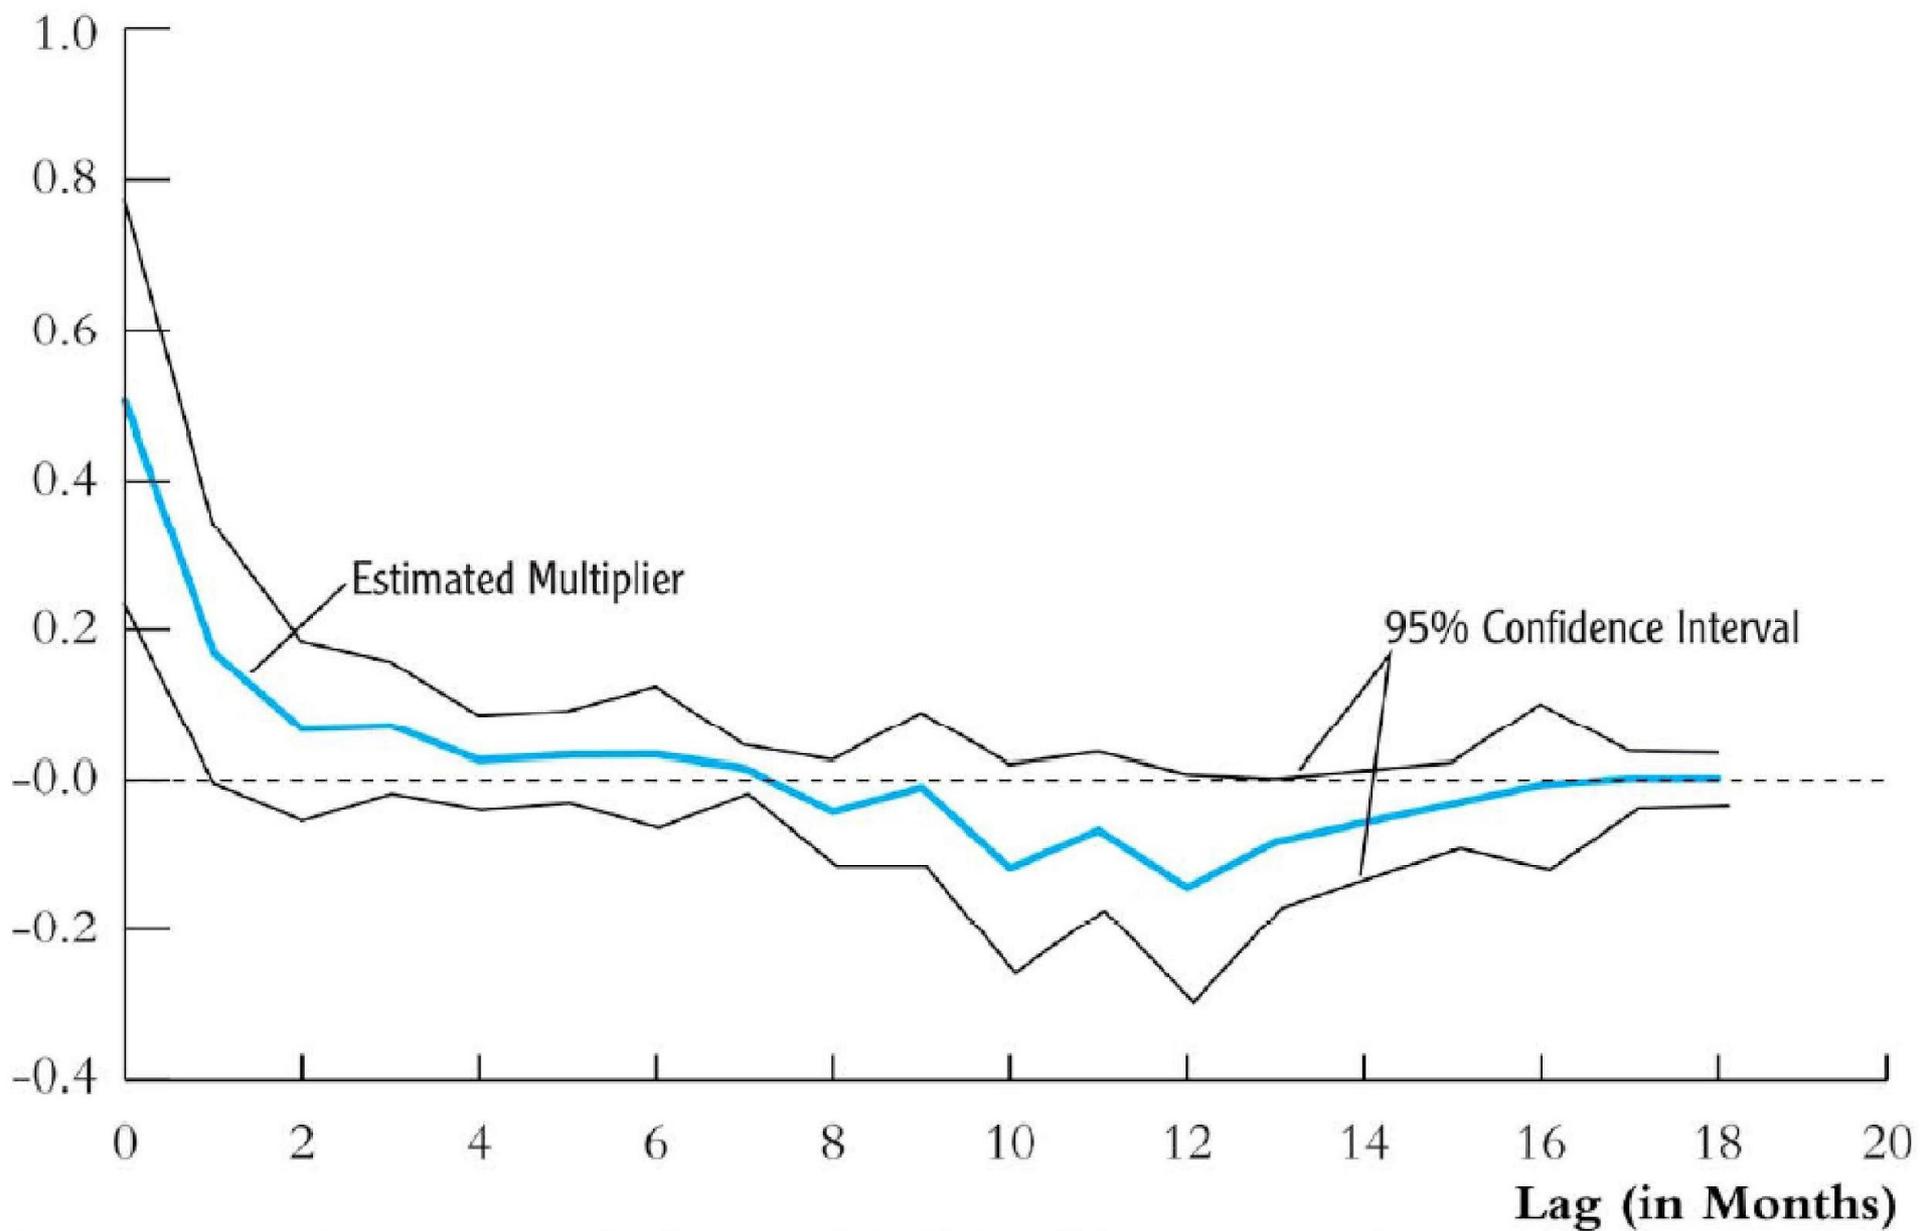
Заморозки во Флориде влияют на урожайность апельсинов, на их предложение и, следовательно, на их равновесную цену.

y_t - равновесная цена апельсинов в месяце t

x_t - количество дней заморозков во Флориде в месяце t

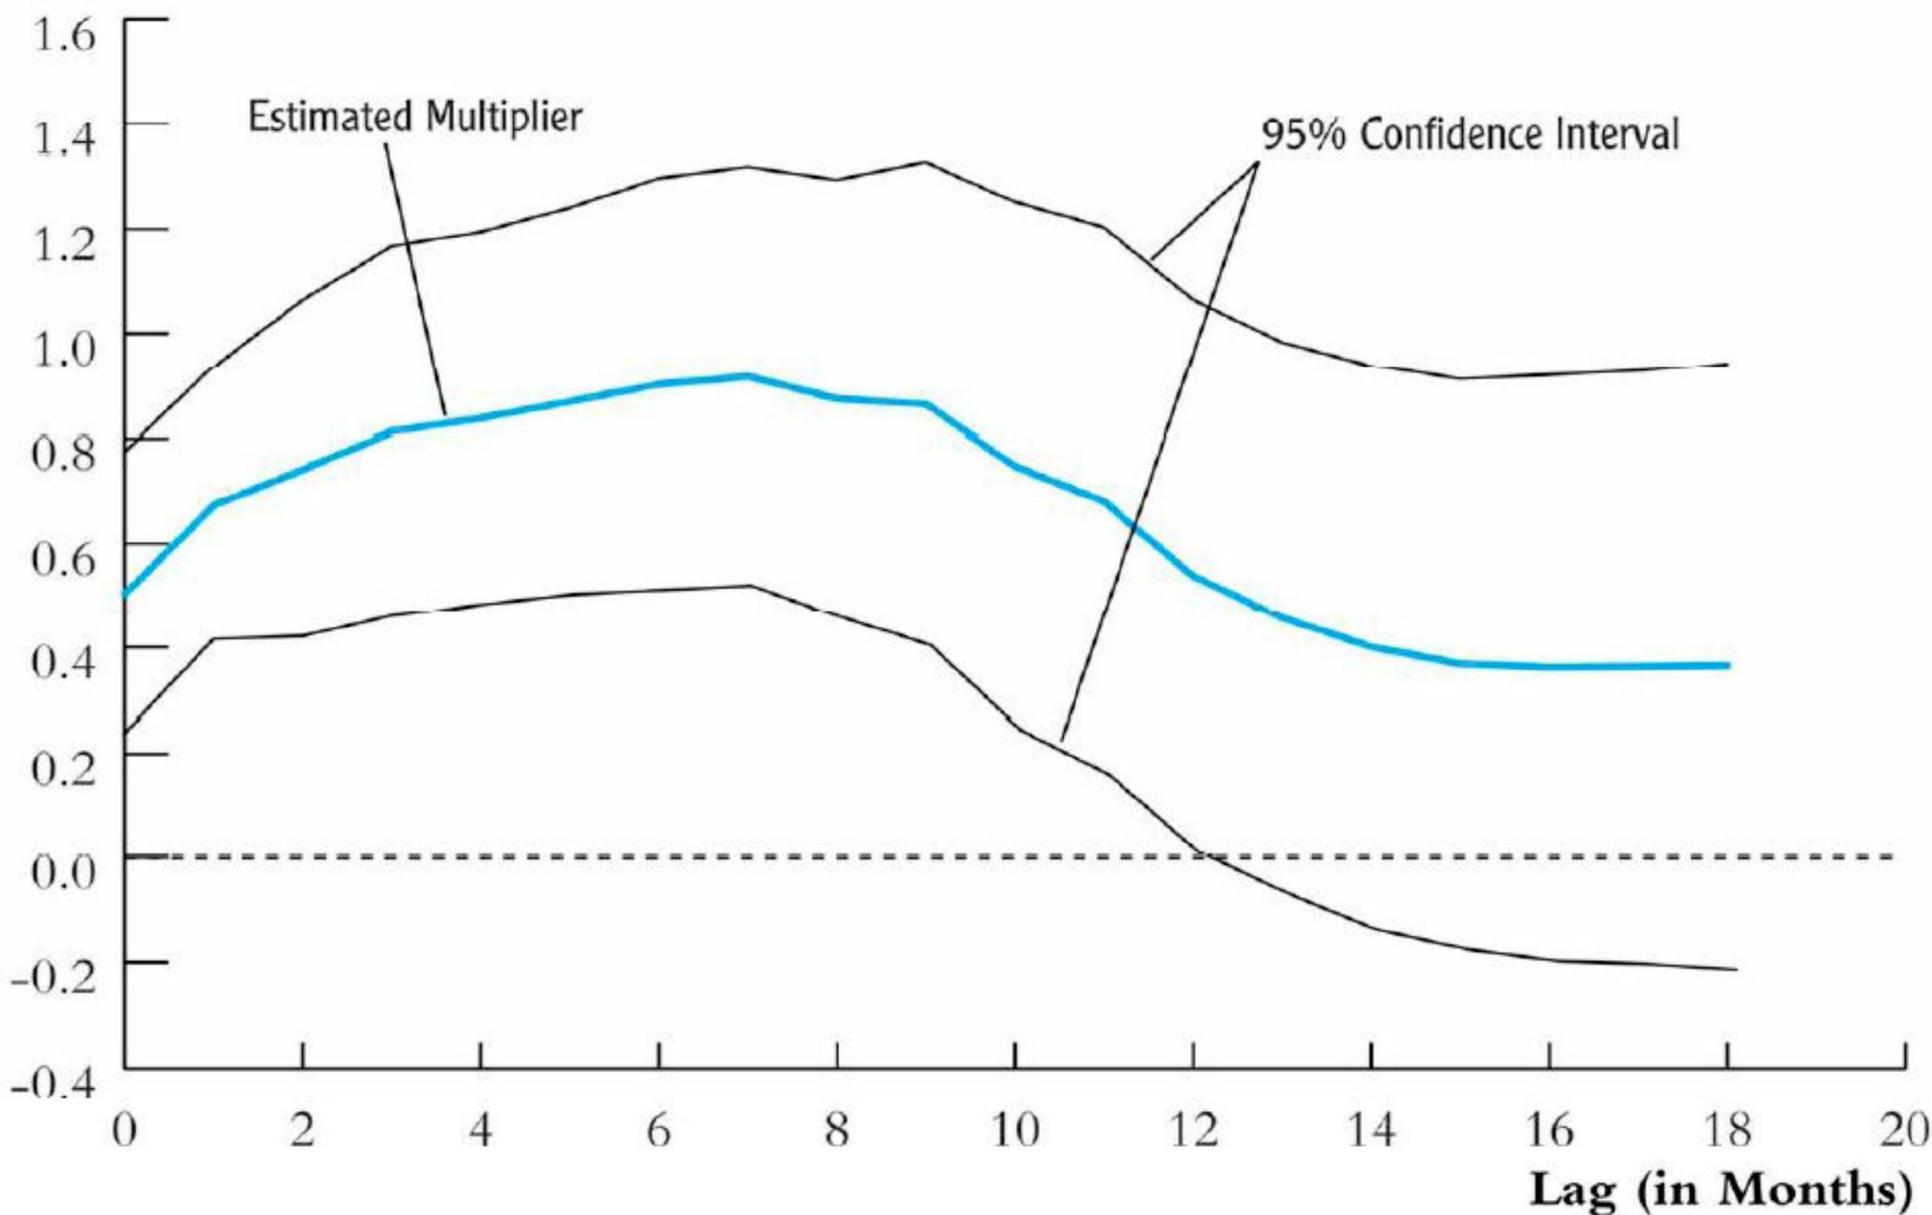
Источник данных: *Stock, Watson*

Multiplier



(a) Estimated Dynamic Multipliers and 95% Confidence Interval

Multiplier



(b) Estimated Cumulative Dynamic Multipliers and 95% Confidence Interval

Авторегрессионная модель распределенных лагов

Естественное обобщение предыдущей
модели – **ADL(p,q)**

The Autoregressive Distributed-Lag Model

$$y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \\ + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Эмпирическая кривая Филлипса

(с адаптивными ожиданиями)

Пример модели ADL(4,4) на основе данных о безработице и инфляции в США (1962 – 2004)

$$\overline{\Delta Inf}_t = 1,30 - 0,42\Delta Inf_{t-1} - 0,37\Delta Inf_{t-2} + 0,06\Delta Inf_{t-3} - 0,04\Delta Inf_{t-4}$$

(0,44) (0,08) (0,09) (0,08) (0,08)

$$-2,64Unem_{t-1} + 3,04Unem_{t-2} - 0,38Unem_{t-3} + 0,25Unem_{t-4}$$

(0,46) (0,86) (0,89) (0,45)

Авторегрессионная модель распределенных лагов

ADL(p,q)

$$y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \\ + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

- В качестве предпосылок по-прежнему требуется стационарность рядов x , y и экзогенность регрессоров

Авторегрессионная модель распределенных лагов

ADL(p,q)

$$y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \\ + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

- Аналогично можно рассматривать случай большего числа объясняющих $x_t^{(1)}, x_t^{(2)}$ переменных

... Но мы для краткости ограничимся одной.

Авторегрессионная модель распределенных лагов

ADL(p,q)

$$y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \\ + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

- Порядок лагов снова можно определять, используя критерии Акаике и Шварца.

Динамические мультипликаторы в ADL модели

$$y_t = \beta_0 + \beta_1 y_{t-1} + \delta_0 x_t + \delta_1 x_{t-1} + u_t$$

Мгновенный эффект δ_0

Накопленные динамические

мультипликаторы: $\delta_0 + (\beta_1 \delta_0 + \delta_1)$

- Для одного периода $\delta_0 + (\beta_1 \delta_0 + \delta_1) + \beta_1 (\beta_1 \delta_0 + \delta_1)$
- Для двух периодов

Долгосрочный линейный мультипликатор $(\delta_0 + \delta_1) / (1 - \beta_1)$

Тест Грейнджера на причинно-следственную связь

Granger Causality Test

$$y_t = \beta_0 + \beta_1 y_{t-1} + \dots + \beta_q y_{t-q} + \\ + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Гипотеза « x не влияет на y »: $H_0(\delta_1 = \dots = \delta_q = 0)$

$$x_t = \alpha_0 + \alpha_1 y_{t-1} + \dots + \alpha_q y_{t-q} + \\ + \theta_1 x_{t-1} + \dots + \theta_q x_{t-q} + u_t$$

Гипотеза « y не влияет на x »: $H_0(\alpha_1 = \dots = \alpha_q = 0)$

Тест Грейнджера на причинно-следственную связь

- Если гипотеза « x не влияет на y » **отклоняется** и гипотеза « y не влияет на x » **принимается**, то говорят, что переменная x является причиной по Грейнджеру для переменной y .
- Исторически сложившееся название теста не очень удачное: тест **не может гарантировать** наличия причинно-следственной связи.
- Тест может указывать на потенциальную **возможность** ее наличия и на то, что одна переменная полезна при прогнозировании другой.

Значимость коэффициентов и доверительные интервалы

$$y_t = \beta_0 + \delta_0 x_t + \delta_1 x_{t-1} + \dots + \delta_q x_{t-q} + u_t$$

Если u_t - белый шум, то можно использовать обычный подход к тестированию, который мы обсуждали для пространственных выборок.

Но на практике u_t обычно коррелированы друг с другом, то есть описываются процессом авторегрессии:

$$u_t = \rho_1 u_{t-1} + \dots + \rho_k u_{t-k} + \varepsilon_t$$

⇒ Автокорреляция случайных ошибок.

Автокорреляция

План рассказа об автокорреляции:

1. Что такое автокорреляция?
2. Чем она плоха?
3. Что можно сделать в случае автокорреляции?
4. Как понять, есть ли эта проблема в модели или нет?

Автокорреляция

$$u_t = \rho_1 u_{t-1} + \dots + \rho_k u_{t-k} + \varepsilon_t$$

- Автокорреляция случайных ошибок – такое же типичное явление для временных рядов, как гетероскедастичность для пространственных выборок.
- Ее последствия во многом аналогичны последствиям гетероскедастичности.

Последствия автокорреляции

1. МНК-оценки коэффициентов остаются несмещенными, но...
2. МНК-оценки коэффициентов становятся неэффективными.
3. Стандартные ошибки коэффициентов смещены и несостоятельны \Rightarrow
t-статистики вычисляются некорректно

Что делать в условиях автокорреляции?

1. Робастные стандартные ошибки
2. Обобщенный МНК

Робастные стандартные ошибки

Как было сказано выше, оценки коэффициентов не смещены (хоть и неэффективны).

Смещены и несостоятельны стандартные ошибки.

Один из подходов к решению проблемы – вычисление состоятельных (в условиях автокорреляции) стандартных ошибок

– **HAC (heteroskedasticity and autocorrelation-consistent) standard errors**

Робастные стандартные ошибки

$$y_t = \beta_1 + \beta_2 x_t + u_t$$

Робастная к автокорреляции и гетероскедастичности стандартная ошибка коэффициента при переменной (HAC standard error):

$$\widetilde{se}(\widehat{\beta}_2) = \sqrt{\widehat{\sigma}_{\beta_2}^2 \cdot \widehat{f}_T}$$

$\widehat{\sigma}_{\beta_2}^2$ - робастная к гетероскедастичности оценка дисперсии

(в форме Вайта) см. лекцию по

гетероскедас:
$$\widehat{f}_T = 1 + 2 \sum_{j=1}^{m-1} \left(\frac{m-j}{m} \widetilde{\rho}_j \right)$$

Робастные стандартные ошибки

$$\hat{f}_T = 1 + 2 \sum_{j=1}^{m-1} \left(\frac{m-j}{m} \tilde{\rho}_j \right)$$

$$\tilde{\rho}_j = \frac{\sum_{t=j+1}^T \hat{v}_t \cdot \hat{v}_{t-1}}{\sum_{t=1}^T \hat{v}_t^2}$$

$$\hat{v}_t = (x_t - \bar{x})e_t$$

Детали –
[Stock, Watson] Ch. 15

m – truncation parameter, определяется размером

выборки: $\frac{1}{m} = 0,75T^{-\frac{1}{3}}$

(с округлением до целого)

Обобщенный МНК

Проиллюстрируем применение обобщенного МНК на примере автокорреляции первого порядка

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t = \beta + \delta x_t + u_t$$

$$y_{t-1} = \beta + \delta x_{t-1} + u_{t-1}$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t = \beta + \delta x_t + u_t$$

$$\rho y_{t-1} = \rho\beta + \rho\delta x_{t-1} + \rho u_{t-1}$$

Домножим второе уравнение на ρ

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t = \beta + \delta x_t + u_t$$

$$y_{t-1} = \beta + \delta x_{t-1} + u_{t-1}$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t = \beta + \delta x_t + u_t$$

$$\rho y_{t-1} = \rho\beta + \rho\delta x_{t-1} + \rho u_{t-1}$$

Домножим второе уравнение на ρ

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t = \beta + \delta x_t + u_t$$

$$\rho y_{t-1} = \rho\beta + \rho\delta x_{t-1} + \rho u_{t-1}$$

Вычтем из первого уравнения второе

$$y_t - \rho y_{t-1} = (1 - \rho)\beta + \delta(x_t - \rho x_{t-1}) + \\ +(u_t - \rho u_{t-1})$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t - \rho y_{t-1} = (1 - \rho)\beta + \delta(x_t - \rho x_{t-1}) + \\ + (u_t - \rho u_{t-1})$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t - \rho y_{t-1} = (1 - \rho)\beta + \delta(x_t - \rho x_{t-1}) + \varepsilon_t$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t - \rho y_{t-1} = (1 - \rho)\beta + \delta(x_t - \rho x_{t-1}) + \varepsilon_t$$

Сделаем замену переменных:

$$y_t^* = y_t - \rho y_{t-1}$$

$$x_t^* = x_t - \rho x_{t-1}$$

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 1. Значение ρ известно

$$y_t^* = (1 - \rho)\beta + \delta x_t^* + \varepsilon_t$$

В новой модели нет автокорреляции

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 2. Значение ρ неизвестно

Обобщенный МНК

$$y_t = \beta + \delta x_t + u_t$$

$$u_t = \rho u_{t-1} + \varepsilon_t$$

Случай 2. Значение ρ неизвестно

1. Оцениваем исходную регрессию обычным МНК. Получаем ряд остатков.
2. Оцениваем регрессию для остатков:

$$\hat{e}_t = \hat{\rho} e_{t-1} \quad \Rightarrow \quad \hat{\rho} = \frac{\sum_{t=2}^T e_t \cdot e_{t-1}}{\sum_{t=2}^T e_{t-1}^2}$$

3. Далее действуем в соответствии со случаем 1, и $\hat{\rho}$ пользуясь .

Обобщенный МНК

Два важных замечания:

Замечание 1. Описанный выше алгоритм можно последовательно применить несколько раз: заново оценить остатки, заново $\hat{\rho}$ оценить, заново сделать замену переменных и так далее.

Итерации повторяются до тех пор, пока не достигается сходимость (оценки коэффициентов при переменных и оценка перестают изменяться).

Такая процедура называется процедурой Кохрейна-Оркатта.

Обобщенный МНК

Два важных замечания:

Замечание 2. Вернемся к уравнению

$$y_t - \rho y_{t-1} = (1 - \rho)\beta + \delta(x_t - \rho x_{t-1}) + \varepsilon_t$$

Перепишем его следующим образом:

$$y_t = (1 - \rho)\beta + \rho y_{t-1} + \delta x_t + (-\rho\delta)x_{t-1} + \varepsilon_t$$

$$y_t = \beta_0 + \beta_1 y_{t-1} + \delta_0 x_t + \delta_1 x_{t-1} + \varepsilon_t$$

Мы получили модель ADL. Вместо описанной выше процедуры можно оценивать непосредственно ее. И в ней также нет проблемы автокорреляции остатков. \Rightarrow Еще один способ устранить автокорреляцию – использовать ADL модели.

Тестирование автокорреляции

Как выяснить, есть ли в модели автокорреляция?

1. Анализ графиков остатков.
2. Коррелограмма остатков и тест Льюинга-Бокса для ряда остатков.
 - Если в модели нет автокорреляции, то остатки должны вести себя как белый шум.
3. Тест Дарбина-Уотсона.

Тест Дарбина-Уотсона

$$u_t = \rho u_{t-1} + \varepsilon_t \quad H_0: \rho = 0$$

Расчетное значение тестовой статистики:

$$DW = \frac{\sum_{t=2}^T (e_t - e_{t-1})^2}{\sum_{t=1}^T e_t^2}$$

$$DW \approx 2(1 - \hat{\rho}) \quad \hat{\rho} \approx 1 - \frac{1}{2}DW$$

Два критических значения: $d_L < d_U$

Тест Дарбина-Уотсона

$$DW \approx 2(1 - \hat{\rho}) \qquad \hat{\rho} \approx 1 - \frac{1}{2}DW$$

$$DW < d_L \implies \rho > 0$$

$$d_U < DW < 4 - d_U \implies \rho = 0$$

$$DW > 4 - d_L \implies \rho < 0$$

В остальных случаях нельзя сделать вывод.

Тест Дарбина-Уотсона

Ограничения теста:

1. Применим только если в модели есть константа.
2. Нельзя применять, если в правой части уравнения есть лагированное значение зависимой переменной (y_{t-1}).
3. Корректен только в случае, если в модели автокорреляция не выше первого порядка.