

Simultaneous Equation (Instantaneous Equation) :

* اقتصاد علمی سیستمی است و پویا / لاگران متغیرها هم بازخورد دارند و هم از متغیرهای دیگر بازخورد می گیرند.

با در نظر گرفتن اینکه اقتصاد پویا است تک معادله ای مانند X نمی تواند رفتار آنرا توضیح دهد. در اینجا X را توضیح می دهد. ولی این Y نیز X را توضیح دهد بیان نشده است در رگرسیون K متغیره.

$$C = \alpha + \beta Y_t$$

نکته ۱: با تک معادلات نمی توان رفتار اقتصادی را توضیح داد.

$$Y = C + E + I$$

* وقتی این معادله نادیده گرفته شود Miss Information داریم.

$$I = \alpha_r B_r + \beta_2 Y$$

در اقتصادسنجی اغلبی می بینیم X داده شده و غیر تصادفی است اگر به صورت سیستمی در نظر گرفته شود

مشاهده می شود که X نیز تصادفی است.

می خواهیم لایبراتورری تهیه کنیم که بتوان چسب اللوها یا اللوها پیچیده تر را از لحاظ تخمین ضرایب به طور همزمان

و بررسی کرد که آیا کدام بخشی این کار را انجام می دهد یا نه. به این نتیجه می رسیدیم که کدام این تخمین مشکلاتی دارد و

بخشی تخمین نمی زند در این صورت چه روش هایی باید استفاده کرد؟

اگر یک طبقه نوری منطقی از سیستم اقتصادی داشته باشیم می توان متغیرها را به ۳ گروه رو به تقلیل کرد :

۱- متغیرهای درون را $\leftarrow$ endogenous Variable

۲- متغیرهای بیرون را $\leftarrow$ exogenous Variable

۳- متغیرهای از قبل تعیین شده (وقفه ای) $\leftarrow$ lag Variable


نکته: تمامی تئوری‌های اقتصادی در مقابل بلزدرست نوشته می‌شوند. steady state

$$Y_{1t} = \alpha_1 Y_{2t} + \alpha_2 X_1 + \alpha_3 X_2 + \varepsilon_1 \rightarrow E(Y_1, \varepsilon_1) \neq 0$$

سیستم معادلات همزمان:

$$Y_{2t} = \alpha_4 Y_{1t} + \alpha_5 X_1 + \alpha_6 X_2 + \varepsilon_2 \rightarrow E(Y_1, \varepsilon_2) \neq 0$$

Y_1 و X_2 ← متغیرهای «دوت‌زا»
 X_1 و X_2 ← متغیرهای بیرون‌زا.



X_{1t-1} و X_{2t-1} ← متغیرهای رفتاری (از قبل تعیین شده).

ε_1 و ε_2 ← متغیر تصادفی خطا.

$$Y_1 = \alpha_1 Y_2 + \dots + U_1 \Rightarrow \text{cov}(Y_2, U_1) \neq 0$$

نکته:

در اقتصاد بیشتر متغیرها «دوت‌زای» باشند و قرار محدودی از آنها بیرون‌زا است. متغیرهای از قبل تعیین شده چند متغیرهای بیرون‌زا.

→ Statistical Model :

فرض می‌کنیم متغیرهای از قبل تعیین شده وجود ندارد. درواقع چیز متغیرهای بیرون‌زا در نظریه بگیریم.

$$Y_1 \gamma_{11} + Y_2 \gamma_{21} + Y_3 \gamma_{31} + \dots + Y_m \gamma_{m1} + X_1 B_{11} + X_2 B_{21} + \dots + X_K B_{K1} + \varepsilon_1 = 0$$

$$Y_1 \gamma_{12} + Y_2 \gamma_{22} + Y_3 \gamma_{32} + \dots + Y_m \gamma_{m2} + X_1 B_{12} + X_2 B_{22} + \dots + X_K B_{K2} + \varepsilon_2 = 0$$

$$Y_1 \gamma_{1m} + Y_2 \gamma_{2m} + Y_3 \gamma_{3m} + \dots + Y_m \gamma_{mm} + X_1 B_{1m} + X_2 B_{2m} + \dots + X_K B_{Km} + \varepsilon_m = 0$$

Y_m تا Y_1 متغیرهای «دوت‌زا» هستند و X_1 تا X_K متغیرهای بیرون‌زا هستند.

* m تا معادله ساختار اقتصاد را بیانات می‌کنند که به این معادلات ساختاری گفته می‌شود.

→ Structural Model.

$$(y_1, \dots, y_m)_{1 \times m} \begin{bmatrix} x_{11} & \dots & x_{1m} \\ \vdots & & \vdots \\ x_{m1} & \dots & x_{mm} \end{bmatrix}_{m \times m} + (x_1, \dots, x_k)_{1 \times k} \begin{bmatrix} B_{11} & \dots & B_{1m} \\ \vdots & & \vdots \\ B_{k1} & \dots & B_{km} \end{bmatrix}_{k \times m} + [\varepsilon_1, \dots, \varepsilon_m]_{1 \times m} =$$

$$\Rightarrow Y' + XB + E = 0 \quad \Rightarrow \text{structural Equations.}$$

نکته: به علاوه B پارامترهای ساختاری کوئند و به E جات خطای ساختاری کوئند.

y_i به عنوان متغیر درون زامانی دارد که در داده با لا نوشته شده است. در صورتی که دوره زمانی احاطه شود.

$$Y = [y_1, \dots, y_m] = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \vdots & \vdots & & \vdots \\ y_{T1} & y_{T2} & \dots & y_{Tm} \end{bmatrix}_{T \times m}$$

به صورت زیر است.

$$X = [x_1, \dots, x_k] = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & & x_{2k} \\ \vdots & \vdots & & \vdots \\ x_{T1} & x_{T2} & & x_{Tk} \end{bmatrix}_{T \times k}$$

$$E = [\varepsilon_1, \dots, \varepsilon_m] = \begin{bmatrix} \varepsilon_{11} & \varepsilon_{12} & \dots & \varepsilon_{1m} \\ \varepsilon_{21} & \varepsilon_{22} & & \varepsilon_{2m} \\ \vdots & \vdots & & \vdots \\ \varepsilon_{T1} & \varepsilon_{T2} & & \varepsilon_{Tm} \end{bmatrix}_{T \times m}$$

* می‌خواهیم ماتریس واریانس-کواریانس خطاها را درست آوریم.

$$E(\varepsilon'\varepsilon) = \begin{pmatrix} \varepsilon'_1 \\ \vdots \\ \varepsilon'_m \end{pmatrix} \cdot (\varepsilon_1, \dots, \varepsilon_m) \quad , \quad \varepsilon\varepsilon' = \begin{pmatrix} \varepsilon_{11} \\ \vdots \\ \varepsilon_{T1} \end{pmatrix} \cdot (\varepsilon'_{11} \dots \varepsilon'_{T1}) = \begin{bmatrix} \varepsilon_{11} & 0 \\ & \varepsilon_{11} \\ 0 & \ddots & \varepsilon_{11} \end{bmatrix} = \varepsilon_{11} I$$

$$E(\varepsilon'\varepsilon) = \begin{bmatrix} E(\varepsilon'_1\varepsilon_1) & E(\varepsilon'_1\varepsilon_2) & \dots & E(\varepsilon'_1\varepsilon_m) \\ E(\varepsilon'_2\varepsilon_1) & E(\varepsilon'_2\varepsilon_2) & \dots & E(\varepsilon'_2\varepsilon_m) \\ \vdots & \vdots & \ddots & \vdots \\ E(\varepsilon'_m\varepsilon_1) & E(\varepsilon'_m\varepsilon_2) & \dots & E(\varepsilon'_m\varepsilon_m) \end{bmatrix} = \begin{bmatrix} \varepsilon_{11}I & \varepsilon_{12}I & \dots & \varepsilon_{1m}I \\ \varepsilon_{21}I & \varepsilon_{22}I & \dots & \varepsilon_{2m}I \\ \vdots & \vdots & \ddots & \vdots \\ \varepsilon_{m1}I & \varepsilon_{m2}I & \dots & \varepsilon_{mm}I \end{bmatrix}$$

$$\Rightarrow E(\varepsilon'\varepsilon) = \sum_{m \times m} \otimes I_{T \times T}$$

$$\Sigma = \begin{bmatrix} \varepsilon_{11} & \varepsilon_{12} & \dots & \varepsilon_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ \varepsilon_{m1} & \varepsilon_{m2} & \dots & \varepsilon_{mm} \end{bmatrix}_{m \times m}$$

* ماتریس واریانس-کواریانس خطاهای ساختاری

هدف درست آمدن پارامترهای ساختاری است که لزایت طریق ساختار را درست می‌آوریم.

$$Y\Pi + XB + \varepsilon = 0 \Rightarrow Y + XB\Pi^{-1} + \varepsilon\Pi^{-1} = 0 \Rightarrow Y = X\Pi + U$$

$$\Rightarrow \begin{cases} U = -\varepsilon\Pi^{-1} \\ \Pi = -B\Pi^{-1} \end{cases}$$

→ Reduced Form equations

← Π ترکیبی از ضرایب ساختاری است و U ترکیبی از خطاهای ساختاری

Π حتماً باید دارای معکوس باشد زیرا که ضرایب ساختاری به صورت ترکیب خطای از معادلات دیگر درست می‌آید.

اگر با متغیرهای Reduced Form کار کنیم می توانیم ساختار را درست آیدیم و تحلیل کنیم چون پارامترها تکلیف شده نیست.

$$E(VV') = E(\Pi' \Pi' E' E \Pi) = \Pi' (\sum \otimes I) \Pi = \sum_R \text{ reduced form}$$

$$(y_1, \dots, y_m) = (x_1, \dots, x_k) \begin{pmatrix} \pi_{11} & \dots & \pi_{1m} \\ \vdots & & \vdots \\ \pi_{k1} & \dots & \pi_{km} \end{pmatrix} + (\varepsilon_1, \dots, \varepsilon_m)$$

نکته: تمامی متغیرهای درون زای مدل تابعی از تمامی متغیرهای بیرون زای مدل هستند.

نکته: Reduced Form چیست و برای چه کاری استفاده شده است؟ چرا مدل ساختاری را تبدیل

به Reduced Form کردیم؟ اساسی درک ما از اقتصاد را نشان می دهد.

* برای نوشتن متن این قضیه عنوان شناسایی را بازی کنیم → Identification

نکته: در single equation ماتریس واریدنی - کواریانس $E(VV')$ بود، در واقع ماتریس واریدنی - کواریانس

بین مشاهدات است در سیستم معادلات ماتریس واریدنی - کواریانس هم بین مشاهدات و هم بین معادلات است.

Identification: هم در اقتصاد سنتی هستند و هم نوین اساس درک از اقتصاد را مشخص می کند. کمک می کند تا سیستم معادلات را در اقتصاد تخمین بزنیم.

در واقع در فرم ماتریسی $Y\Pi + XB + E = 0$ به دنبال تخمین ضرایب ساختاری (Π, B) هستیم که به کمک

identification این کار را انجام می دهیم. در واقع reduced form به این شتابی، تخمین کمک می کند و با تخمین

این ضرایب می توان ساختار اقتصاد را شناسایی کرد. RF به تخمین پارامترهای ساختاری کمک می کند.

نکته: هم ضرایب و هم ماتریس واریدنی - کواریانس Reduced Form ترکیب خطی از مدل ساختاری می باشد.

بحثی که در اینجا مطرح می شود این است که اثر تخمین های $Reduced Form$ را داشته باشیم یا کمک آنها بتواند تخمین از ضرایب ساختاری درست آید.

* برای این منظور باید تخمین از $reduced form$ داشته باشیم زیرا پارامترهای آن، پارامترهای جامعه اند و درست تر نیستند.

بحثی که مطرح می شود این است که با چه روشی $reduced form$ را تخمین ببریم که $\hat{\pi}$ را داشته باشیم و از آن برای استخراج پارامترهای ساختاری استفاده کنیم.

برای استخراج پارامترهای ساختاری به $Reduced parameters$ نیاز داریم.

* m معادله موجود در $Reduced Form$ فقط تابعی از متغیرهای توضیحی باشد و تمامی معادلات ظاهر شده اند. متغیر وابسته y_1 تا y_m باشد و متغیرهای توضیحی x_1 تا x_k هستند. (متغیرهای بیون را). آنها نیز متعلق به

$Reduced Form$ هستند.

نکته: برای تخمین معادلات سیستمی از $SURE$ استفاده می کنیم، چون y ها دوبه دو در این سیستم $correlated$ اند.

نکته: اگر در تمامی معادلات متغیرهای سمت راست یکی باشد $SURE$ دقیقاً همان خواص OLS دارد.

$$y_1 = x_1 \pi_{11} + \dots + x_k \pi_{1k} + \epsilon_1$$

$$\Rightarrow \hat{\pi} = (x'x)^{-1} x'y$$

$$y_m = x_1 \pi_{1m} + \dots + x_k \pi_{km} + \epsilon_m$$

چون پارامترهای $Reduced form$ را داریم می توان ماتریس واریدانه کوواریانس را محاسبه کرد.

نکته: بررسی کنیم آیا استفاده از $Reduced form$ به تخمین و شناسایی پارامترهای ساختاری کمک می کند؟

در مدل ساختاری بررسی می کنیم چه پارامترهایی برای تخمین داریم ←

$$Y\Gamma + XB + E = 0$$

$$\Gamma_{m \times m}, \beta_{K \times m}, \sum_{m \times m} \rightarrow S = m^2 + Km + \frac{m(m+1)}{2} - m$$

structural Model :

$$\begin{aligned} Y_1 \delta_{11} + Y_2 \delta_{21} + \dots + Y_m \delta_{m1} + \dots + \varepsilon_1 &= 0 \rightarrow Y_1 = \dots \\ Y_1 \delta_{12} + Y_2 \delta_{22} + \dots + Y_m \delta_{m2} + \dots + \varepsilon_2 &= 0 \rightarrow Y_2 = \dots \\ \vdots &\vdots \\ Y_1 \delta_{1m} + Y_2 \delta_{2m} + \dots + Y_m \delta_{mm} + \dots + \varepsilon_m &= 0 \rightarrow Y_m = \dots \end{aligned}$$

$$\begin{pmatrix} \delta_{11} = -1 & \delta_{12} & \dots & \delta_{1m} \\ \delta_{21} & \delta_{22} = -1 & & \delta_{2m} \\ \vdots & \vdots & & \vdots \\ \delta_{m1} & \delta_{m2} & \dots & \delta_{mm} = -1 \end{pmatrix}_{m \times m}$$

* در مرحله اول، Y_1 را تابعی از بقیه عوامل می کنیم. در مرحله دوم Y_2 را تابعی از بقیه عوامل می کنیم تا مرحله m . به این عمل normalization یا کونیز در هر یک از معادلات پارامترها Normalize می کنیم.

در Reduced Form چه پارامترهایی را تخمین می زنیم ؟ $R = Km + \frac{m(m+1)}{2}$ $Y = X\pi + U \rightarrow$

$$\Rightarrow S - R = m(m-1) \rightarrow \text{تفاوت پارامترهای ساختاری و پارامترهای R.F.}$$

نکته: با Reduced Form نمی توان تمام پارامترهای مدل ساختاری را برست آورد و ساختار را شناسایی نکرد.

نکته: برای شناسایی مدل آماری $\leftarrow$ statistical Model $\rightarrow$ تنها با استفاده از پارامترهای حاصل از تخمین Reduced Form

نمی توان عمل کرد بلکه باید از تئوری (اعتقادی) استفاده کرد و بعد از آن پارامترها را که R.F. تخمین نمی زند را با استفاده از تئوری اقتصاد تعیین کرد.

نکته: $m(m-1)$ پارامتر را که R.F. تخمین نمی زند را با استفاده از تئوری اقتصاد برست می آوریم.

نکته: از دو راه می توان اطلاعات اضافی برست آورد: ۱- تئوری اقتصادی

۲- خود پارامترهای مدل تقلیل یافته.

مثال: اقتصادی را در نظر بگیرید که از متغیرهای زیر تشکیل شده است.
 $C_t, Y_t, I_t, r_t, C_{t-1}$
که در این مدل C_t, Y_t, I_t متغیرهای دین را هستند و r_t و C_{t-1} متغیرهای بیرون را می باشند.

$$Y = f(C_t, r_t, I_t, C_{t-1})$$

$$C = f(Y_t, I_t, r_t, C_{t-1})$$

$$I_t = f(Y_t, C_t, r_t, C_{t-1})$$

$$\Rightarrow C_t = B_1 I_t + B_2 Y_t + B_3 r_t + B_4 C_{t-1}$$

$$I_t = B'_1 Y_t + B'_2 C_t + B'_3 r_t + B'_4 C_{t-1}$$

C تابعی از ثروت و درآمد است (طبق تئوری اقتصادی) و بقیه عوامل مزبور دارند. $B_1 = 0$ و $B_3 = 0$

I تابعی از نرخ بهره است، طبق تئوری که اصل شتاب را در نظر می گیرد. $B'_1 = 0$ و $B'_2 = 0$ و $B'_4 = 0$

جایگاه Identification و ارتباط میان Statistical Model و Economic Model چیست؟

ارتباط مدل ساده ریاضی و تئوری اقتصادی است که یک مدل اقتصادی را حاصل می کند. تمامی مدل های اقتصادی که می خواهیم یک مدل آماری است که بر اساس تئوری ها از یک معادلات همزمان بر اساس Identification برست می آید.

تفاوت بین Statistical Model با یک تئوری اقتصادی این است وجود محدودیت های منفی که از تئوری دارد می شوند و آنرا تبدیل به Economic Model یا Theoretical Model می کند.

* می‌خواهیم شرطی را بدست آوریم که بتوان یک مدل را identified کرد و تشخیص داد چه موقع سیستم identified می‌شود.

یا over identified یا under identified یا un identified است.

برای این منظور اول معادله این سیستم معادلات را در نظر می‌گیریم، بدون اینکه لیت را از دست بدهیم این روند را تا m معادله می‌توان ادامه داد.

$$Y\Pi + XB + E = 0$$

* identification به صورت معادله به معادله صورت می‌گیرد.

← پارامترهای معادله اول

$$(Y_1 \dots Y_m) \begin{pmatrix} \delta_{11} \\ \delta_{21} \\ \vdots \\ \delta_{m1} \end{pmatrix} + (X_1 \dots X_K) \begin{pmatrix} B_{11} \\ B_{21} \\ \vdots \\ B_{K1} \end{pmatrix} + (\epsilon_1 \dots \epsilon_m) = 0$$

$$\Pi = -B\Pi^{-1} \Rightarrow \Pi\Pi = -B \Rightarrow \Pi \begin{bmatrix} \delta_{11} \\ \delta_{21} \\ \vdots \\ \delta_{m1} \end{bmatrix} = - \begin{bmatrix} B_{11} \\ B_{21} \\ \vdots \\ B_{K1} \end{bmatrix}$$

محدودیت‌های معضرا اعمال می‌کنیم. با فرض اینکه تا m_1 پارامتر و ضمیمه معضراست و تا K_1 پارامتر و ضمیمه معضراست.

$$\Rightarrow \Pi \begin{bmatrix} \delta_{11} \\ \delta_{21} \\ \vdots \\ \delta_{m1} \\ \hline 0 \\ \vdots \\ 0 \end{bmatrix} = - \begin{bmatrix} B_{11} \\ B_{21} \\ \vdots \\ B_{K1} \\ \hline 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\Rightarrow \begin{matrix} m_1 & m-m_1 \\ K_1 & m-K_1 \end{matrix} \begin{bmatrix} \pi_1 & \pi_3 \\ \pi_2 & \pi_4 \end{bmatrix} \cdot \begin{matrix} m \times 1 \\ K \times m \end{matrix} \begin{bmatrix} \delta_{11} \\ \delta_{21} \\ \vdots \\ \delta_{m1} \\ \hline 0 \\ \vdots \\ 0 \end{bmatrix} = - \begin{matrix} K \times 1 \end{matrix} \begin{bmatrix} B_{11} \\ B_{21} \\ \vdots \\ B_{K1} \\ \hline 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\Rightarrow \pi_1 \begin{bmatrix} \delta_{11} \\ \vdots \\ \delta_{m1} \end{bmatrix} = - \begin{bmatrix} B_{11} \\ B_{21} \\ \vdots \\ B_{K1} \end{bmatrix}, \quad \pi_2 \begin{bmatrix} \delta_{11} \\ \delta_{21} \\ \vdots \\ \delta_{m1} \end{bmatrix} = 0$$

$$\Rightarrow \begin{cases} \pi_1 \lambda_1 = -\beta_1 \\ \pi_2 \lambda_1 = 0 \end{cases} \rightarrow \begin{aligned} &\text{با جایگزینی } \lambda_1, \beta_1 \text{ برست می آید.} \\ &\text{برست می آید } \lambda_1 \Rightarrow \text{سیستم همگن نیست} \end{aligned}$$

* $\hat{\pi}$ رانز Reduced Form برست می آید.

نکته: اگر سیستم $\pi_2 \lambda_1 = 0$ همگن باشد، دارای جواب صفر است که در نتیجه این جواب به درستی می خورد.

اما در اصل این معادله همگن نیست. $\pi_2 \lambda_1 = 0$ به این دلیل همگن نیست که در هنگام normalization، λ_1 given است و سیستم قابل حل است و لاها برست می آید و β ها نیز برست می آید.

* سیستم معادلات اول را نسبت به سیستم معادلات دومی وابسته به π_2 می باشد. باید شروطی اعمال کنیم که بتوان شروطی برست آورد که در مورد شناسایی بتوان قضاوت کرد.

← $k - k_1$ معادله داریم و m_1 پارامتر داریم که می دانیم که از پارامترها جدا می شود. است. $(m_1 - 1) \cdot \pi_2 (k - k_1) \cdot m_1$

شروط این سیستم معادلات جواب داشته باشد این است که: $\rho(\pi_2) = m_1 - 1$
Conditional Rank

شرط لازم داشتن جواب برای سیستم معادلات، باید تعداد پارامترها کوچکتر یا مساوی تعداد معادلات باشد. $k - k_1 \geq m_1 - 1$

در سیستم معادلات همزمان، باید تک تک معادلات را بررسی کرد حتی اگر یکی از معادلات را نتوان Identified کرد. سیستم همزمان قابل شناسایی نیست باید Identified یا over identified باشد.

نکته: در اقتصاد عموماً زمانی سیستم قابل شناسایی است که over identified باشد.

اگر شرط $m_1 - 1 \geq K - K_1$ برقرار نباشد (شرط لازم) نمی توان سیستم را حل کرد under identified است.

← شرط کافی

← شرط لازم

$$p(\pi_2) = m_1 - 1, \quad K - K_1 > m_1 - 1 \Rightarrow \text{over identified}$$

$$p(\pi_2) = m_1 - 1, \quad K - K_1 = m_1 - 1 \Rightarrow \text{just identified}$$

$$p(\pi_2) = m_1 - 1, \quad K - K_1 < m_1 - 1 \Rightarrow \text{under identified}$$

$$p(\pi_2) \neq m_1 - 1, \quad K - K_1 \geq m_1 - 1 \Rightarrow \text{un identified}$$

رویکرد شناسایی

دنباله رویکرد دیگری هستیم که بتوان به راحتی مساله را آزمون کرد، می خواهیم شرط رتبه ای استخراج کنیم که بر اساس آن

این کار را انجام دهیم.

$$\Gamma = \begin{bmatrix} \gamma_{11} & \dots & \gamma_{1m} \\ \gamma_{21} & & \gamma_{2m} \\ \vdots & & \vdots \\ \gamma_{m1} & & \gamma_{mm} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_{11} & \dots & \beta_{1K} \\ \beta_{21} & & \beta_{2K} \\ \vdots & & \vdots \\ \beta_{K1} & & \beta_{KK} \end{bmatrix}$$

ابتدا ضرایب ساختاری در نظریه گیریم.

میراث رسیدن به این شرط شناسایی سیستم ماتریسی مانند زیر در نظریه گیریم.

$$A = \left(\frac{\Gamma}{B} \right)$$

ماتریسی مانند A در نظریه گیریم که از ادغام ماتریس (B و Γ) درست می آید.

چون محدوده های داده ها هستند انتظار می رود رتبه باشد. حتما باید بر اساس m منوال رتبه مستوی باشد و بتوان ترکیب خطی از هم نوشت. A باید حتما منوال رتبه مستوی باشد. اگر نباشد Γ معکوس پذیر نیست.

$$A = \begin{bmatrix} \gamma_{11} & \dots & \gamma_{1m} \\ \vdots & & \vdots \\ \gamma_{m1} & \dots & \gamma_{mm} \\ \hline \beta_{11} & \dots & \beta_{1n} \\ \vdots & & \vdots \\ \beta_{k1} & \dots & \beta_{kn} \end{bmatrix} = (a_1, \dots, a_m) \quad (m+k) \times m$$

برای استخراج شرط m ترسی مانند m را تشکیل می دهیم. m ما ترسی با ستون های $m+k$ و ردیف های اختیاری به تعداد

محدودیت هایی نمی تواند اختیار کند ما سه مقدار در فضا های 4.7

نشره لازم و کافی $\rightarrow P(A) = m_{-1}$

در رویکرد اول مشروط لازم به تعقل و کاها مسئله داشت اما در این رویکرد همه چیز به ما تشریح محدودیت مسئله دارد.

m_1 : بر اساس معادله اول محدودیت‌های λ ، محدودیت‌های μ در سیستم بر اساس k اعمال شده است و توان m_2 را برای معادله مشخصه می‌زنیم.

نکته: در حالتی که از شر $P(\pi_2)$ استفاده می کردیم ابتدا از مدل ساختاری $R.f$ را برست می آوردیم و سپس $P(\pi_2)$ را برست می آوردیم، اما در این حالت نیازی به $R.f$ نیست بلکه با استفاده از ماتریس محدودیت $\mathcal{F}$ حل می شود.

دشتر لار $P(t) \geq m-1$ order condition

در ویژگی اول m_1 تعادل متصیرهای «رون زای ساده اول است» در ویژگی دوم m تعادل متصیرهای «رون زای لایه ششم است».

Priori information $\phi \cdot a_1 = 0$
 ϕ_{1+k}

Posterior information : $\pi = -\beta \Pi^{-1} \Rightarrow \pi \Pi + \beta = 0 \Rightarrow \underbrace{\begin{bmatrix} \pi & | & I \end{bmatrix}}_W \underbrace{\begin{bmatrix} \Pi \\ \beta \end{bmatrix}}_A = 0 \Rightarrow WA = 0$
 $\Rightarrow \begin{pmatrix} \phi \\ w \end{pmatrix} \cdot a_1 = 0 \Rightarrow p\left(\begin{pmatrix} \phi \\ w \end{pmatrix}\right) = m+k-1 \checkmark \Rightarrow p(\phi A) = p(\pi_b) = m_1-1$

آلر $p(\beta) = m-1$ و $p(\beta A) = m-1$ سیستم just. identified است.

آلر $p(\beta) > m-1$ و $p(\beta A) = m-1$ سیستم over. identified است.

آلر $p(\beta) < m-1$ و شرط رتبه هم نخواهد داشت، سیستم under. identified است.

آلر $p(\beta) > m-1$ و $p(\beta A) \neq m-1$ سیستم un identified است.

مثال

$$\begin{cases} y_1 \delta_{11} + y_2 \delta_{21} + y_3 \delta_{31} + y_4 \delta_{41} + x_1 B_{11} + \dots + x_4 B_{41} + \varepsilon_1 = 0 \\ y_1 \delta_{12} + y_2 \delta_{22} + \dots + x_1 B_{12} + x_2 B_{22} + \dots + \varepsilon_2 = 0 \\ y_1 \delta_{13} + y_2 \delta_{23} + y_3 \delta_{33} + y_4 \delta_{43} + x_1 B_{13} + \dots + x_4 B_{43} + \varepsilon_3 = 0 \\ y_4 \delta_{44} + x_1 B_{14} + x_2 B_{24} + x_3 B_{34} + x_4 B_{44} + \varepsilon_4 = 0 \end{cases}$$

$$A = \begin{bmatrix} \delta_{11} & \delta_{12} & \delta_{13} & 0 \\ \delta_{21} & \delta_{22} & \delta_{23} & 0 \\ 0 & 0 & \delta_{33} & 0 \\ \delta_{41} & 0 & \delta_{43} & \delta_{44} \\ B_{11} & B_{12} & B_{13} & B_{14} \\ 0 & B_{22} & B_{23} & B_{24} \\ 0 & 0 & 0 & B_{34} \\ B_{41} & 0 & B_{43} & B_{44} \end{bmatrix}_{8 \times 4}$$

نکته: لا حتماً باید به تعداد معادلات باشد و تریه ترکیب خطی از هم می باشند ولی در مورد B ها چنین محدودیتی

وجود ندارد.

هر محدودیتی یک ردیف به خودش اختصاص می دهد که ممکن است این محدودیت های مغفیر اساسی تئوری

اعمال شده باشد که در ماتریس ρ وارد می کنیم.

معادله اول: $\rho = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}_{3 \times 8}$

$\rho(\rho) = 3 = m-1 \rightarrow$ شرط لازم برقرار

$\rho A = \begin{bmatrix} 0 & 0 & \gamma_{33} & 0 \\ 0 & \beta_{22} & 0 & \beta_{24} \\ 0 & 0 & 0 & \beta_{34} \end{bmatrix}_{3 \times 4}$

$\rightarrow \rho(\rho A) = 3 = m-1 = 3$ شرط رتبه هم برقرار

این سیستم یک سیستم just identified است.

معادله 2: $\rho = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}_{4 \times 8}$

$\rho(\rho) = 4 > m-1 = 3$ over identified

$\rho A = \begin{bmatrix} 0 & 0 & \gamma_{33} & 0 \\ \gamma_{41} & 0 & \gamma_{34} & \gamma_{44} \\ 0 & 0 & 0 & \beta_{34} \\ \beta_{41} & 0 & \beta_{43} & \beta_{44} \end{bmatrix}_{4 \times 4}$

$\rightarrow \rho(\rho A) = 3 = m-1 = 3$

معادله 3: $\rho = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}_{2 \times 8}$

$\rightarrow \rho(\rho) = 2 < m-1 = 3$

این سیستم under identified است.

پارامترها: $\rho = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix}_{3 \times 8} \rightarrow p(\rho) = 3 = m-1$

$\rho A = \begin{bmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & 0 \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & 0 \\ 0 & 0 & \gamma_{33} & 0 \end{bmatrix} \rightarrow p(\rho A) = 3 = m-1$

* این سیستم just-identified است.

$\pi \Pi = -B$

$\Rightarrow \begin{bmatrix} \hat{\pi}_{11} & \hat{\pi}_{12} & \hat{\pi}_{13} & \hat{\pi}_{14} \\ \hat{\pi}_{21} & \hat{\pi}_{22} & \hat{\pi}_{23} & \hat{\pi}_{24} \\ \hat{\pi}_{31} & \hat{\pi}_{32} & \hat{\pi}_{33} & \hat{\pi}_{34} \\ \hat{\pi}_{41} & \hat{\pi}_{42} & \hat{\pi}_{43} & \hat{\pi}_{44} \end{bmatrix} \cdot \begin{bmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & 0 \\ \gamma_{21} & \gamma_{22} & \gamma_{23} & 0 \\ 0 & 0 & \gamma_{33} & 0 \\ \gamma_{41} & 0 & \gamma_{43} & \gamma_{44} \end{bmatrix} = -B$

پارامترهای B ، γ را از معادله $\hat{\pi}$ ضرایب R.F. هستند. از این معادله تخمین زده می شوند.

$\hat{\pi} = (X'X)^{-1}X'Y$

تمام سطوحی ماتریس π را در ستون اول ماتریس Π ضرایب می کنیم داریم:

معادلات:
$$\left\{ \begin{array}{l} \hat{\pi}_{11}\gamma_{11} + \hat{\pi}_{12}\gamma_{21} + \hat{\pi}_{14}\gamma_{41} = -B_{11} \\ \hat{\pi}_{21}\gamma_{11} + \hat{\pi}_{22}\gamma_{21} + \hat{\pi}_{24}\gamma_{41} = 0 \\ \hat{\pi}_{31}\gamma_{11} + \hat{\pi}_{32}\gamma_{21} + \hat{\pi}_{34}\gamma_{41} = 0 \\ \hat{\pi}_{41}\gamma_{11} + \hat{\pi}_{42}\gamma_{21} + \hat{\pi}_{44}\gamma_{41} = -B_{41} \end{array} \right\} \Rightarrow \begin{array}{l} \hat{\pi}_{22}\gamma_{21} + \hat{\pi}_{24}\gamma_{41} = -\hat{\pi}_{21} \\ \hat{\pi}_{32}\gamma_{21} + \hat{\pi}_{34}\gamma_{41} = -\hat{\pi}_{31} \end{array}$$

از اینجا γ_{21} ، γ_{41} برآورد می آید.

با جایگزینی γ_{21} و γ_{41} در معادله های 1 و 4 - B_{11} ، B_{41} برآورد می آید.

نسیستم عطفی : Recursive System

VAR (Vector Auto regressive) بحث سیستم عطفی بسیار نفیس / نیز در سبب در مورد identification دارد.

$$y'' + xB + E = 0 \rightarrow \text{Structural Model}$$

$$y = x\pi + u \rightarrow \text{Reduced Form}$$

در سیستم معادلات همزمان متغیرهای درون را با هم Correlate بودند.

نوعی از معادلات همزمان را می توان به صورت سیستم عطفی نوشت. (معادلات عطفی).

$$y_1 x_{11} + x_1 B_1 + \dots + x_k B_{k1} + E_1 = 0 \rightarrow \text{اولی فقط تابعی از متغیرهای بیرون را}$$

$$y_1 x_{12} + y_2 x_{22} + x_1 B_{12} + \dots + x_k B_{k2} + E_2 = 0 \rightarrow \text{دومی فقط تابعی از } y_1 \text{ و متغیرهای بیرون را}$$

$$y_1 x_{13} + y_2 x_{23} + y_3 x_{33} + x_1 B_{13} + \dots + x_k B_{k3} + E_3 = 0 \rightarrow \text{سومی فقط تابعی از } y_1, y_2 \text{ و متغیرهای بیرون را}$$

$$y_1 x_{1m} + \dots + y_m x_{mm} + x_1 B_{1m} + \dots + x_k B_{km} + E_m = 0$$

همیشه در سیستم های که ماتریس ضرایب یا ماتریس متغیر یا بالا متغیر است سیستم عطفی است.

$$\Gamma = \begin{bmatrix} \gamma_{11} & \gamma_{12} & \gamma_{13} & \dots & \gamma_{1m} \\ 0 & \gamma_{22} & \gamma_{23} & \dots & \gamma_{2m} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \gamma_{mm} \end{bmatrix}$$

$$E(e'e) = \Sigma \otimes I$$

$\rightarrow$


$$\Sigma_{m \times m} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22} & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{m1} & \dots & \dots & \sigma_{mm} \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} E_{11} & & & 0 \\ & E_{22} & & \\ & & \ddots & \\ 0 & & & E_{mm} \end{bmatrix}$$

نکته: وقتی سیستم عطفی می‌تردد ماتریس Σ به دلیل یک ماتریس قطری می‌تردد.

✓ چون در این سیستم همبستگی وجود دارد.

Example →



یک سیستم عطفی در قالب ۳ متغیر درون زانو

ماتریس واریانس-کواریانس

$$R = \frac{m(m+1)}{2} + mk$$

نکته: تعداد پارامترهای مدل ساختاری و معرّم نهایی:

$$\Rightarrow R = S$$

$$S = m + \frac{m(m+1)}{2} + mk - m$$

$\downarrow$ واریانس خودرسانی
 $\downarrow$ Π
 $\downarrow$ B (تعداد پارامترهای B می‌تواند از ۰ باشد)
 $\downarrow$ m

نکته مهم: سیستم معادلات عطفی همواره just-identified است. (دقیقاً قابل شناسایی است.)

$Y\pi + XB + E = 0 \rightarrow$ structural Model : Estimation

تخمین معادلات همزمان :

$Y = X\pi + v \rightarrow$ Reduced Form

برای تخمین سیستم معادلات همزمان ابتدا فرض ساختاری سیستم تغییراتی ایجاد می‌کنیم، برای آنکه به راحتی بتوان تخمین زد، بدین منظور ما ترمیم X را افزایش می‌کنیم.

$$Y_{Tym} = (y_1 \mid y_1 \mid y_2) \begin{matrix} T_{Y1} \\ T_{X(m-1)} \\ T_{X(m-m_1)} \end{matrix} T_{X(m)}$$

$y_1 \rightarrow$ متغیر وابسته

$y_1 \rightarrow$ متغیرهای درون زاین (که در معادله هستند)

$y_2 \rightarrow$ متغیرهای درون زاین (که در معادله نیستند)

Example $\rightarrow y_1 = \lambda_{21} y_2 + \lambda_{41} y_4 + x_1 B_{11} + x_4 B_{41} + \varepsilon$

$y_1 \leftarrow$ نرمال این شده معادله اول.

$y_1 \leftarrow$ تحت عنوان ما ترمیم، قرار متغیرهای درون را در معادله اول به جز y_1 را نشان می‌دهد $\leftarrow$ «مثال با λ_2, λ_4 ».

$y_2 \leftarrow$ قرار متغیرهای درون زاین در سیستم معادلات متغیرهای «درون زاین معادله اول» $\leftarrow (y_3)$

$$X = (x_1 \mid x_2) \begin{matrix} T_{XK} \\ T_{XK_1} \\ T_{X(K-K_1)} \end{matrix}$$

X را هم به صورت «رو به افزایش می‌کنیم :

$x_1 \leftarrow$ قرار متغیرهایی که در معادله اول هستند، $(x_1 \text{ و } x_4 \text{ در مثال با } \lambda_4)$.

$x_2 \leftarrow$ قرار متغیرهای بیرون زاین که در معادله اول نیستند، $(x_2 \text{ و } x_3 \text{ در مثال با } \lambda_4)$.

$$y_1 = y_1 x_1 + x_1 B_1 + e_1$$

معادله اول به سیستم معادلات همزمان $\leftarrow$

$$\Rightarrow (y_1 \mid y_1 \mid y_2) \begin{pmatrix} -1 \\ x_1 \\ 0 \end{pmatrix} + (x_1 \mid x_2) \begin{pmatrix} B_1 \\ 0 \end{pmatrix} + e_1 = 0$$

$$\Rightarrow -y_1 + y_1 x_1 + x_1 B_1 + e_1 = 0 \Rightarrow y_1 = y_1 x_1 + x_1 B_1 + e_1$$

$$y_1 = [y_1 \ x_1] \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} + e_1 \Rightarrow y_1 = z_1 \delta_1 + e_1$$

$$\Rightarrow \hat{\delta}_1 = (z_1' z_1)^{-1} z_1' y_1$$

(OLS)

* اولین معادله ای که می‌توان از این روش تمامی

معادلات معین معادلات همزمان را به روش کلاسه تخمین زد در پارامترهای ساختاری را با روش کلاسه برست آمد. البته اگر معین قابل شناسایی باشد.

بحث این است که تخمین‌های برست آمده از کلاسه تا چه حد قابل استفاده و قابل اعتماد است؟ برین منظور به بررسی

خواص تخمین کلاسه می‌پردازیم.

$$\hat{\delta}_{OLS} = \begin{pmatrix} y_1' y_1 & y_1' x_1 \\ x_1' y_1 & x_1' x_1 \end{pmatrix}^{-1} \begin{pmatrix} y_1' \\ x_1' \end{pmatrix} y_1$$

۱- بررسی نااریب بودن کلاسه (طبق نمونه‌های کوچک)

$$\Rightarrow \hat{\delta}_{OLS} = (z_1' z_1)^{-1} z_1' y_1 = (z_1' z_1)^{-1} z_1' (z_1 \delta_1 + e_1) \Rightarrow \hat{\delta}_{OLS} = \delta_1 + (z_1' z_1)^{-1} z_1' e_1$$

$$E(\hat{\delta}_{OLS}) = \delta_1 + E\left\{(z_1' z_1)^{-1} z_1' e_1\right\} = \delta_1 + E\left\{(z_1' z_1)^{-1} \begin{bmatrix} y_1' e_1 \\ x_1' e_1 \end{bmatrix}\right\}$$

* چون y_1 متغیر تصادفی است در نتیجه Expectation از آن نمی‌گردد، از طرفی چون e_1 با y_1 comolate است محیداً Expectation از آن نمی‌گردد. پس نااریب نیست.

نکته ← هر Estimator وقتی متغیر تصادفی (مستقل) درون را باشد، الزاماً متغیر با جمله اخلال

comolate باشد. حتماً این Estimator اریب است. اگر متغیر تصادفی با جمله اخلال قطعاً وابسته نباشد

می‌تواند نااریب باشد.

$$Y = XB + U$$

$$\hat{\beta} = (X'X)^{-1}X'Y = (X'X)^{-1}X'(XB+U) = B + (X'X)^{-1}X'U$$

$$\rightarrow E(\hat{\beta}) = B \quad \text{if } X \text{ given}$$

$$\rightarrow E(\hat{\beta}) = B \quad \text{if } X \text{ stochastic \& uncorrelated}$$

$$\rightarrow E(X'U) \neq 0 \quad \text{if } X \text{ stochastic \& correlated}$$

نکته: اکثر تخمین زنده‌ها زمانی که متغیر توضیح دهنده تصادفی است و نسبت آن و جمله خطا وابستگی وجود دارد، اریب است.

* وقتی در مورد اریب یا نالریب بودن و یا کارایی صحبت می‌کنیم، نمونه‌های کوچک مدنظر می‌باشند.

استفاده از نمونه‌های کوچک برای دید تخمین زنده نمی‌تواند روش مناسبی برای ارزیابی خواص تخمین زنده باشد. مثلاً آنکه بتوانیم خواص نمونه‌های بزرگ تخمین زنده‌ها را بررسی می‌کنیم.

از این به بعد دنبال مفهوم سازگاری consistency هستیم چون همواره تمامی تخمین زنده‌ها اریب هستند.


بررسی سازگاری مربوط به نمونه‌های بزرگ است.

دو رویکرد برای همگرایی داریم: 1- همگرایی در احتمال $\leftarrow \text{Converge in Probability}$

2- همگرایی در توزیع $\leftarrow \text{Converge in distribution}$

همگرایی در احتمال :

فرض می کنیم که یک توزیع داریم و شروع به افزایش مشاهدات می کنیم در این حالت واریانس تخمین زتنه به سمت صفر میل می کند



که سبب می شود توزیع در نقطای مثل θ پهنای شود.

در این شرایط انتظار داریم، اریب از بین رود و به سمت صفر میل کند.

در واقع وقتی $T \rightarrow \infty \iff \text{Var}(\hat{\theta}) \rightarrow 0$ یعنی نوسان کم می شود و سازگار است. به تعریف نلاقین

$$T \rightarrow \infty$$

از consistency است.

نلاق سازگاری یعنی وقتی $T \rightarrow \infty$ هم داریا نوا و هم اریب به صفر میل می کند. $\leftarrow$ Converge in mean square

مفهوم سازگاری: اگر $\hat{\theta}$ یک تخمین زتنه θ باشد، زمانی $\hat{\theta}$ یک برآورد سازگار از θ است که همگرایی برابری

$$\lim_{T \rightarrow \infty} |\hat{\theta} - \theta|^2 \rightarrow 0$$

$$T \rightarrow \infty$$

مجموع خطاها رخ داده باشد $\leftarrow$

$$\lim_{T \rightarrow \infty} [(\hat{\theta} - E(\hat{\theta})) + (E(\hat{\theta}) - \theta)]^2 = \lim_{T \rightarrow \infty} (\hat{\theta} - E(\hat{\theta}))^2 + \lim_{T \rightarrow \infty} (E(\hat{\theta}) - \theta)^2$$

$$= \lim_{T \rightarrow \infty} \text{Var}(\hat{\theta}) + (\text{bias} \cdot \hat{\theta})^2 = \lim_{T \rightarrow \infty} \text{MSE} \rightarrow 0$$

* همگرایی در احتمال یعنی هم اریب و هم واریانس از بین می رود. همگرایی در احتمال مفهومی دقیق سازگاری را بیان می کند.

$$\lim_{T \rightarrow \infty} \text{MSE} \iff p \lim \hat{\theta} = \theta$$

نلاق همگرایی در MSE مفهوم سازگاری است.

در دنیای واقعی به خواص نمونه‌ها کوچک دسترسی داریم و در نتیجه باید از خواص نمونه‌های بزرگ استفاده کنیم و محبتی از آریب نمی‌کنیم بلکه در مورد سازگاری آن بحث می‌کنیم و بررسی می‌کنیم خواص نمونه‌های بزرگ را دارد یا نه. اگر خواص نمونه‌های بزرگ را داشته باشد، تخمین زنده قدرتمندی است که در موارد مختلف مفارقات است.

در این جایی توان در مورد توزیع و استنباط آماری حامل از آن صحبت کرد چون در نقطه θ توزیع تباهیده شده است، توزیع داریم. لذا باید درباره مفهوم همگرایی در توزیع استفاده کرد.

قضیه حد مرکزی: اگر جملاتی را در نظر بگیریم که پارامتر آن θ است و $\hat{\theta}$ تخمین زنده‌ای از θ باشد، این قضیه بیان می‌کند که توزیع تخمین زنده $\hat{\theta}$ زمانی که مقدار مشاهدات به سمت بی نهایت میل می‌کند برابر توزیع نرمال می‌شود.

* نکته: زمانی که همگرایی را احتمال صورت می‌گیرد سعی می‌کنیم قبل از نویاشی توزیع نهاده کنیم که پارامترها چقدر است که برای استنباط از آن‌ها استفاده کرد و عملاً به صورت زیر نمایش داده می‌شود.

$$N(\theta, \sigma^2) \xrightarrow{D} \sqrt{n}(\hat{\theta} - \theta) \rightarrow \text{سرعت تغییر همگرایی}$$

↓
به توزیع

$$\text{plim}(\hat{\theta} - \theta) \xrightarrow{P} 0 \quad \text{Lim MSE}(\hat{\theta}) \rightarrow 0 \quad \leftarrow \text{همگرایی احتمال}$$

↓
به صورت حد و توزیع به سمت نرمال می‌رود

* نکته: بررسی کردیم که گاهی تخمین زنده‌ای آریب است و هر تخمین زنده دیگری هم در سیستم معادلات همزمان به کار می‌رود. اما به همین دلیل دنبال خواص نمونه‌های بزرگ هستیم.

* آیا گاهی خواص نمونه‌های بزرگ را دارد؟ اگر کلا consistent باشد از آن در تخمین معادلات همزمان می‌توان استفاده کرد و اگر نه از تخمین زنده‌های دیگر استفاده می‌کنیم که خواص سازگاری را به ما بدهد و بررسی می‌کنیم که اگر I منفی و یا I باشد لزوماً روش استفاده کنیم و چه تخمین زنده‌ای را به کار ببریم.

* می‌خواهیم شرط سازگاری را برای δ_1 بررسی کنیم و $\text{plim}(\hat{\delta}_1) = \delta_1$ ؟ یا نه δ_1 برآورد نری سازگار است؟

هر وقت با سیستم معادلات همزمان مواجه هستیم که نالریب نیست به همین جهت سراغ سازگاری می‌رویم.

$$\hat{\delta}_{ols} = \delta_1 + (Z'Z)^{-1} Z'e_1 \Rightarrow \hat{\delta}_{ols} = \delta_1 + \left(\frac{Z'Z}{T} \right)^{-1} \cdot \frac{Z'e_1}{T}$$

$$\text{plim}(\hat{\delta}_1) = \delta_1 + \text{plim} \left(\frac{Z'Z}{T} \right)^{-1} \cdot \text{plim} \left(\frac{Z'e_1}{T} \right)$$

$$y = XB + u$$

باید بررسی کنیم $\text{plim}(Z'Z)$ در طول زمان چگونه است؟

$$\hat{B} = B + \frac{(X'X)^{-1}}{(T)^{-1}} \cdot \frac{X'u}{T} \Rightarrow \text{plim} \hat{B} = B + \text{plim} \left(\frac{X'X}{T} \right)^{-1} \cdot \text{plim} \left(\frac{X'u}{T} \right)$$

$$\text{Subst} \Rightarrow \frac{X'X}{T} = \frac{1}{T} \begin{bmatrix} T & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} = \begin{bmatrix} 1 & \frac{\sum x_i}{T} \\ \frac{\sum x_i}{T} & \frac{\sum x_i^2}{T} \end{bmatrix}$$

$$\lim_{T \rightarrow \infty} \frac{X'X}{T} = \lim_{T \rightarrow \infty} \begin{bmatrix} 1 & \frac{\sum x_i}{T} \\ \frac{\sum x_i}{T} & \frac{\sum x_i^2}{T} \end{bmatrix} \rightarrow Q$$

* چون هم سرعت زیاد می‌شود و هم مخرج و با توجه به سرعت همگرایی به یک عدد میل می‌کند به بررسی Q می‌کنیم.

$$\text{Example} \rightarrow y_t = \alpha + \beta t + u_t \rightarrow \lim \begin{bmatrix} 1 & \frac{\sum t_i}{T} \\ \frac{\sum t_i}{T} & \frac{\sum t_i^2}{T} \end{bmatrix} = \lim \begin{bmatrix} 1 & \frac{T+1}{2} \\ \frac{T+1}{2} & \frac{(T+1)(T+1)}{6} \end{bmatrix}$$

$$= \lim \begin{bmatrix} 1 & \infty \\ \infty & \infty \end{bmatrix}$$

به خاطر non-stationary بودن است در واقع سرعت همگرایی در این حالت متفاوت است.

با حالتی است که متغیرها stationary هستند، سرعت همگرایی $\frac{3\sqrt{T}}{2}$ است.

* چون X ها با v ها $correlated$ نباشند پس $p\lim(\frac{X'v}{T}) = 0$ است. $\Rightarrow p\lim(\hat{\theta}) = \beta + Q^{-1} p\lim(\frac{X'v}{T})$

$$E(v) = 0$$

مازکاری در شرایط K متغیر برای θ به قرار شد و نالیب نیز هست

قضیه: اگر $\hat{\theta}$ برآورد نری از θ باشد و نالیب باشد، مجانباً نیز نالیب است.

$$E(\hat{\theta}) = \theta \rightarrow \lim E(\hat{\theta}) = \theta$$

اگر $\hat{\theta}$ نالیب باشد در نمونه‌های کوچک می‌تواند در طول زمان با افزایش نمونه‌ها به یک برآورد نالیب تبدیل شود و نالیب از میان رود.

$$1. p\lim(\hat{\theta} \cdot \hat{\lambda}) = p\lim(\hat{\theta}) \cdot p\lim(\hat{\lambda})$$

قضایای مربوط به $p\lim$ (همگرایی در احتمال)

$$2. p\lim\left(\frac{\hat{\theta}}{\hat{\lambda}}\right) = \frac{p\lim \hat{\theta}}{p\lim \hat{\lambda}}$$

$$3. p\lim(\hat{\theta} \pm \hat{\lambda}) = p\lim(\hat{\lambda}) \pm p\lim(\hat{\theta})$$

4. اگر $\hat{\theta}$ یک برآورد نری از θ باشد و $\hat{\lambda}$ نالیب باشد، $p\lim(\hat{\theta}) = \theta$ یک برآورد نری از θ باشد و $\hat{\lambda}$ نالیب باشد، $p\lim(\hat{\theta}) = \theta$

$$p\lim(g(\hat{\theta})) = g(\theta) \quad \text{قضیه اسلاشکی}$$

به عبارت دیگر مازکاری منتقل می‌شود.

$$p\lim(\hat{\delta}_1) = \delta_1 + p\lim\left(\frac{z'z}{T}\right)^{-1} \cdot p\lim\left(\frac{z'e}{T}\right) = \delta_1 + Q^{-1} \cdot p\lim\left(\frac{z'e}{T}\right)$$

$$p\lim\left(\frac{z'e}{T}\right) = p\lim \frac{1}{T} \begin{bmatrix} x' \\ x' \end{bmatrix} e = p\lim \begin{bmatrix} \frac{y'e}{T} \\ \frac{x'e}{T} \end{bmatrix} = \begin{bmatrix} p\lim \frac{y'e}{T} \\ p\lim \frac{x'e}{T} \end{bmatrix} = \begin{bmatrix} \psi \\ 0 \end{bmatrix}$$

$$\Rightarrow \rho \lim (\hat{\delta}_{ols}) = \delta_i + Q^{-1} \begin{pmatrix} 1 \\ 0 \end{pmatrix}$$

* نکته: گاهی حتی برای نمونه‌های بزرگ در سیستم معادلات همزمان نیز همبستگی و برآورد ناسمبایی برای سیستم

معادلات همزمان نمی باشد.

* چه تخمین زنده‌های دیگری هستند که می‌تواند برآورد‌های سازگاری را بدهد؟ خواص آنها هم از لحاظ مایختاری و هم از لحاظ

کارایی چقدر می‌تواند باشد؟ اولین برآوردگر که بررسی می‌کنیم حداقل مربعات غیر مستقیم ← کلا است

* حداقل مربعات غیر مستقیم (کلا):

← یکی از محدودیت‌های اساسی تخمین زنده کلا این است که سیستم معادلات همزمان باید just-identified باشد تا بتوان

از این برآوردگر استفاده کرد.

برای بررسی این تخمین زنده و چگونگی کارکرد آن به صورت زیر عمل می‌کنیم.

$$y_i = \gamma_1 x_{i1} + x_{i1} \beta_1 + e_i = \gamma \delta_i + e_i$$

معادله اول سیستم معادلات همزمان را در نظر می‌گیریم ←

$$y = x\pi + u \rightarrow \text{Reduced Form.}$$

$$y = (y_1 : y_1 : y_2) \quad x = (x_1 : x_2)$$

مشابه معادله مایختاری R.F را نیز امتحان می‌کنیم.

$$u = (u_1 : u_1 : u_2) \quad \pi = \begin{pmatrix} \hat{\pi}_1^o & \hat{\pi}_1^{\infty} & \hat{\pi}_3 \\ \hat{\pi}_2^o & \hat{\pi}_2^{\infty} & \hat{\pi}_4 \end{pmatrix}$$

$$(y_1 \quad y_1 \quad y_2)' = (x_1 \quad x_2)' \begin{pmatrix} \hat{\pi}_1^0 & \hat{\pi}_1^\infty & \hat{\pi}_3 \\ \hat{\pi}_2^0 & \hat{\pi}_2^\infty & \hat{\pi}_4 \end{pmatrix} + (u_1 \quad u_1 \quad u_2)'$$

$$y_1 = x_1 \hat{\pi}_1^0 + x_2 \hat{\pi}_2^0 + u_1$$

$$y_1 = x_1 \hat{\pi}_1^\infty + x_2 \hat{\pi}_2^\infty + u_1$$

$$y_2 = x_1 \hat{\pi}_3 + x_2 \hat{\pi}_4 + u_2$$

$$\pi \pi' = -B \Rightarrow \begin{pmatrix} \hat{\pi}_1^0 & \hat{\pi}_1^\infty & \hat{\pi}_3 \\ \hat{\pi}_2^0 & \hat{\pi}_2^\infty & \hat{\pi}_4 \end{pmatrix} \begin{pmatrix} -1 \\ x_1 \\ 0 \end{pmatrix} = - \begin{pmatrix} \beta_1 \\ 0 \end{pmatrix}$$

$$\Rightarrow \begin{cases} -\hat{\pi}_1^0 + \hat{\pi}_1^\infty x_1 = -\beta_1 \Rightarrow \boxed{\hat{\beta}_1 = -\hat{\pi}_1^\infty (\hat{\pi}_2^\infty^{-1} \hat{\pi}_2^0) + \hat{\pi}_1^0} \\ -\hat{\pi}_2^0 + \hat{\pi}_2^\infty x_1 = 0 \Rightarrow \boxed{\hat{x}_1 = \hat{\pi}_2^\infty^{-1} \hat{\pi}_2^0} \end{cases}$$

غیر مستقیم به خاطر این است که از R, f به پارامترهای ساختاری رسمیم. اگر سیستم I باشد جواب منحصر به فرد داریم.

در غیر این صورت جواب منحصر به فرد ندارد.

آیا تخمین زسته II سازگار است؟ به تخمین زسته سازگار است در مقابل ماه اما ضرورت دارد.

1) باید I باشد. سیستم دقیقاً متقابل شناسایی باشد.

2) اگر R, f را تخمین زد، بهر از حل چهار ریشه در پارامترهای ساختاری. در حالت نبرد سخت می شود.

π از معادله $y = x\pi + v$ یا روش کاه تخمین خود رجوع π معادله $y = x\pi + v$ است که هم فارغ است و هم سازگار. چون v دارد.

complete نیست. $\lim(\hat{\pi}) = \pi$ و بر اساس رابطه $\pi \pi' = -B$ سازگاری به B هم متعلق می شود و هم چنین به π طبق قضیه شناختی.

نکته - برای برآورد $\hat{\pi}$ که از OLS استفاده شده چون در R.F. OLS هم نالایب است و هم سازگار در نتیجه

$$y = x\pi + u$$

سازگاری منتقل می شود.

$\rightarrow \hat{\pi}_{OLS} = (X'X)^{-1}X'y$ $\rightarrow$ $\hat{\pi}_{OLS}$ مقصود از آن که با u هم وابستگی ندارد که می توان هم از OLS و هم از SUR استفاده کرد.

Two stage least square $\rightarrow$ 2SLS $\leftarrow$

* نکته برای just-identified به کار برده می شود و اگر سیستم over-identified باشد به دلیل تعداد پارامترها تخمین امکان پذیر شود. بنابراین به دنبال روشی هستیم که زمانی که سیستم over-identified است بتوان برآورد انجام دهد. که برای این منظور از تخمین زنده 2SLS استفاده می کنیم که یک OLS و مرحله ای است که هم برای I و هم $O.I$ استفاده می شود و هم سازگار است که مشکل ما را حل می کند.

$$y = x\pi + u$$

برای این منظور ابتدا R.F. را در نظر می گیریم و افراز می کنیم.

$$(y_1 | x_1 | y_2) = (x_1 | x_2) \begin{pmatrix} \hat{\pi}_1^o & \hat{\pi}_1^u & \hat{\pi}_3 \\ \hat{\pi}_2^o & \hat{\pi}_2^u & \hat{\pi}_4 \end{pmatrix} + (\hat{u}_1 | \hat{u}_1 | \hat{u}_2)$$

$$\hat{y}_1 = x_1 \hat{\pi}_1^o + x_2 \hat{\pi}_2^o$$

$$\hat{\pi} = (X'X)^{-1}X'y$$

اگر به روش OLS تخمین بزنیم داریم $\leftarrow$ R.F. غیر

$$\hat{y}_1 = x_1 \hat{\pi}_1^u + x_2 \hat{\pi}_2^u$$

$$\Rightarrow y_1 = \hat{y}_1 + \hat{u}_1$$

* این مرحله اول least square است که از R.F. برآورد می آید.

$$\hat{y}_2 = x_1 \hat{\pi}_3 + x_2 \hat{\pi}_4$$

$$y_1 = x_1 y_1 + x_1 B_1 + e_1$$

مجدداً بدون از دست دادن کلیت قضیه، مرحله اول را می نویسیم.

گام اول در این مرحله این است که y_1 را که از مرحله اول برآورد آمد را در این رابطه جایگزین کنیم.

$$y_i = \hat{y}_i x_i + x_i B_i + e_i + \underbrace{\hat{u}_i x_i}_{\varepsilon_i} \Rightarrow y_i = \hat{y}_i x_i + x_i B_i + \varepsilon_i \Rightarrow y_i = \hat{z}_i \delta_i + \varepsilon_i$$

$$y_i = [\hat{y}_i \ x_i] \begin{bmatrix} \delta_i \\ B_i \end{bmatrix} + \varepsilon_i \Rightarrow \hat{\delta}_{i2SL} = (\hat{z}_i' \hat{z}_i)^{-1} \hat{z}_i' y_i$$

* این سیستم هم برای δ_i و هم B_i جواب دارد.

نکته: زمانی که سیستم δ_i جوابی که از کلاس 2SL برستای بگیرد دقیقاً همان جواب‌هایی است که از کلاس 1SL برستای بگیرد.

$\hat{y}_i$ را تخمین از y_i در حال که x_i را می‌بینیم و دوباره به روش کلاس تخمین می‌زنیم.
✓ برای اطمینان اینکه این سیستم δ_i باشد، جواب کلاس 2SL با کلاس 1SL برابر می‌شود.

$$y_i = x_i \delta_i + x_i B_i + e_i \Rightarrow y_i = \hat{y}_i x_i + x_i B_i + \varepsilon_i \Rightarrow y_i = (x_i \hat{\pi}_1^{\circ} + x_i \hat{\pi}_2^{\circ}) x_i + x_i B_i + \varepsilon_i$$

$$\Rightarrow y_i = x_i (\hat{\pi}_1^{\circ} + B_i) + x_i \hat{\pi}_2^{\circ} x_i + \varepsilon_i \Rightarrow y_i = (x_i \ x_i) \begin{pmatrix} \hat{\pi}_1^{\circ} + B_i \\ \hat{\pi}_2^{\circ} x_i \end{pmatrix} + \varepsilon_i$$

$$\Rightarrow \begin{pmatrix} \hat{\pi}_1^{\circ} x_i + B_i x_i \\ \hat{\pi}_2^{\circ} x_i \end{pmatrix} = (x_i' x_i)^{-1} x_i' y_i = \begin{pmatrix} \hat{\pi}_1^{\circ} \\ \hat{\pi}_2^{\circ} \end{pmatrix} \Rightarrow \hat{\delta}_i = (\hat{\pi}_2^{\circ})^{-1} \hat{\pi}_2^{\circ}$$

$$y_i = x_i \hat{\pi}_1^{\circ} + x_i \hat{\pi}_2^{\circ} + v_i \Rightarrow y_i = (x_i \ x_i) \begin{pmatrix} \hat{\pi}_1^{\circ} \\ \hat{\pi}_2^{\circ} \end{pmatrix} + v_i$$

$$\Rightarrow \begin{pmatrix} \hat{\pi}_1^{\circ} \\ \hat{\pi}_2^{\circ} \end{pmatrix} = (x_i' x_i)^{-1} x_i' y_i$$

$$\hat{\delta}_{i2SL} = (\hat{z}_i' \hat{z}_i)^{-1} \hat{z}_i' y_i = \begin{pmatrix} \hat{y}_i' \hat{y}_i & \hat{y}_i' x_i \\ x_i' \hat{y}_i & x_i' x_i \end{pmatrix}^{-1} \begin{pmatrix} \hat{y}_i' \\ x_i' \end{pmatrix} y_i$$

$(m_1 + k) \times (m_1 + k)$

← ثابت کنید 2SL برای δ_i هم مناسب است.

$$y_i = \gamma_i x_i + \alpha_i \beta_i + e_i$$

بررسی سازگاری 2SLS برای معادلات همزمان :

$$y_i = \hat{\gamma}_i x_i + \alpha_i \beta_i + \varepsilon_i$$

$$\Rightarrow \hat{\delta}_{12SL} = (\hat{Z}' \hat{Z})^{-1} \hat{Z}' y_i \Rightarrow \hat{\delta}_{12SL} = (\hat{Z}' \hat{Z})^{-1} \hat{Z}' (\gamma_i x_i + \alpha_i \beta_i + e_i)$$

$$\Rightarrow \hat{\delta}_{2SL} = (\hat{Z}' \hat{Z})^{-1} \hat{Z}' (\hat{Z} \delta_i + e_i) = \delta_i + (\hat{Z}' \hat{Z})^{-1} \hat{Z}' e_i$$

نکته: $\hat{Z}' \hat{Z} = \hat{Z}' \hat{Z}$

$$p\lim \hat{\delta}_{2SL} = \delta_i + p\lim \left(\frac{\hat{Z}' \hat{Z}}{T} \right)^{-1} \cdot \frac{\hat{Z}' e_i}{T} \Rightarrow p\lim \hat{\delta}_{2SL} = \delta_i + Q^{-1} p\lim \left(\frac{\hat{Z}' e_i}{T} \right)$$

$$\Rightarrow p\lim \hat{\delta}_{2SL} = \delta_i + Q^{-1} p\lim \left(\frac{1}{T} \begin{bmatrix} y_i' \\ x_i' \end{bmatrix} e_i \right) = \delta_i + Q^{-1} p\lim \left(\frac{1}{T} \begin{bmatrix} y_i' e_i \\ x_i' e_i \end{bmatrix} \right)$$

$$\Rightarrow p\lim \hat{\delta}_{2SL} = \delta_i + Q^{-1} p\lim \left(\frac{1}{T} \begin{bmatrix} (\hat{\pi}_1'' x_i' + \hat{\pi}_2'' x_i') e_i \\ x_i' e_i \end{bmatrix} \right) \Rightarrow p\lim \hat{\delta}_i = \delta_i$$

$$y = x\pi + u$$

* 2SLS یک برآورد سازگار در سیستم معادلات همزمان است.

$$\hat{y}_i = x_i \hat{\pi}_1'' + x_2 \hat{\pi}_2'' \rightarrow \text{first stage}$$

$$y_i = \hat{y}_i x_i + \alpha_i \beta_i + \varepsilon_i$$

چون $\hat{y}_i$ تابعی خطی از متغیرهای بهین زانست، ارتباط میان y_i ، x_i و $\hat{y}_i$ که از طریق

برآوردن $\hat{y}_i$ در مرحله اول انجام شده است و باعث می شود که در مرحله دوم که برآورد سازگار شود.

مرحله دوم که برآورد سازگار بوجود می آید از طریق *comolate*، $\hat{y}_i$ به x_i و x_2 و عمود بر y به خطا یعنی مستقل بودن

آن. بنابراین در مرحله دوم *comolation* که از طریق $\hat{y}_i$ وجود داشت از طریق $\hat{y}_i$ رفع شده و امکان برآورد

سازگار را می دهد. بنابراین 2SLS سازگار است.

* $\hat{y}$ تخمین زندهای از y است، اگر $\hat{y}$ دقیقاً شود ($R^2 = 1$) که برآمد سرسازداری نیست، ($\hat{y}_1 = y_1$)

حراق استفاده از داده تخمین سازداری نهاده.

رویه استفاده از داده 285 :

11 متغیرهای بیوت را از متغیرهای «دوت را تقلیل می کنیم. تمامی متغیرهای «دوت را را تابعی از متغیرهای بیوت را گرفته و آنرا

را به روش داده تخمین می زنیم. تخمین هم نهایی R^2 برابر برآمد معادلات متغیرهای «دوت را را مورد به روش قرار می دهیم.

12 در این مرحله $\hat{y}$ های بیوت آمده از مرحله اول را به ترتیب در متغیرهای تو ضیحی معادلات ساختاری جایگزین می کنیم.

و داده را روی تک تک معادلات تخمین می زنیم تا پارامترهای ساختاری تخمین خورده این روش سیستم نیست و

معادلات سازگار است چون از معادلات بین سیستم استفاده می کنند.

Instrumental Variable (IV) :

$$y = x\beta + u \quad \text{if } x \text{ is stochastic and } E(x'u) \neq 0$$

$$\hat{\beta}_{OLS} = \beta + (X'X)^{-1}X'u \rightarrow E(\hat{\beta}_{OLS}) = \beta + E(X'u)^{-1}X'u \neq \beta$$

$$plim \hat{\beta}_{OLS} = \beta + plim \left(\frac{X'X}{T} \right)^{-1} \cdot plim \left(\frac{X'u}{T} \right) \Rightarrow plim \hat{\beta}_{OLS} = \beta + Q^{-1}(\delta) \Rightarrow plim(\hat{\beta}_{OLS}) \neq \beta$$

* در IV Estimator ← این است که چه متغیری باشد که بالاترین correlation را با x داشته باشد ولی

uncorrelated با u .

فرض می‌کنیم متغیر مورد نظر w باشد اثر $\leftarrow$
 $y = x\beta + u$

$$w'y = w'x\beta + w'u$$

در نتیجه می‌توانیم داشته باشیم $\leftarrow$

ابعاد w نیز مانند x است یعنی w نیز $n \times k$ است.

$$w'y = w'x\beta \Rightarrow \beta = (w'x)^{-1} \cdot w'y$$

اثر $w'u$ را در نظر نگیریم داریم $\leftarrow$

$$\Rightarrow \hat{\beta}_{IV} = (w'x)^{-1} w'y$$

چرا می‌توانیم متغیر ابزاری؟

* چون w ابزاری است، باعث می‌شود تخمین زنده سازگار شود و دارای این خواص است که:

1) w با u correlate نباشد.

2) با لا کوریت correlate را با x داشته باشد.

متغیرهای بیرون را منطقاً متغیر ابزاری می‌شوند.

با بررسی معادلات همزمان می‌پردازیم $\leftarrow$ اولین معادله سیستم معادلات همزمان $\leftarrow$
 $y_1 = \gamma_1 \delta_1 + \gamma_2 \delta_2 + e_1$

مشکل اینجا correlate بودن e_1 و γ_1 است که $cov(\gamma_1, e_1) \neq 0$ است یا $E(\gamma_1 e_1) \neq 0$.

$$y_1 = [\gamma_1 \quad \gamma_2] \begin{bmatrix} \delta_1 \\ \delta_2 \end{bmatrix} + e_1 \Rightarrow y_1 = z_1 \delta_1 + e_1 \rightarrow cov(z_1, e_1) \neq 0 \quad z_1 \text{ } n \times (k_1 + \gamma_1 - 1)$$

z_1 حداقل از ناحیه γ_1 با e_1 correlate است، ابزار مناسب در این رابطه چیست؟

$$w_1' y_1 = w_1' z_1 \delta_1 + w_1' e_1$$

16) if $E(w_1' e_1) = 0 \Rightarrow \hat{\delta}_{IV} = (w_1' z_1)^{-1} w_1' y_1$

$$w_1 = \hat{z}_1 \Rightarrow \hat{\delta}_{IV} = (\hat{z}_1' \hat{z}_1)^{-1} \hat{z}_1' y_1$$

2SLS

$\hat{y}_1 = x_1 \hat{\pi}_1^{2SLS} + x_2 \hat{\pi}_2^{2SLS}$ $\hat{y}_1$ یک ابزار است که بر اساس تمامی متغیرهای بدون زای سیستم تعریف می‌شود.

نکته $\leftarrow$ $\hat{y}_1$ یک ابزار است که بر اساس تمامی متغیرهای بدون زای سیستم تعریف می‌شود.

نکته $\leftarrow$ IV یک تخمین از شده General است که تمامی تخمین از شده‌ها II، 2SLS و ... را در بر می‌گیرد.

$$w_1 = [\hat{y}_1 \ x_1] \Rightarrow \hat{\delta}_{IV} = (w_1' z_1)^{-1} w_1' y_1 \Rightarrow \hat{\delta}_{IV} = (\hat{z}_1' \hat{z}_1)^{-1} \hat{z}_1' y_1$$

$$\hat{\delta}_{2SLS} = (\hat{z}_1' \hat{z}_1)^{-1} \hat{z}_1' y_1$$

از طرفی هم می‌دانیم که $\leftarrow$

$$y_1 = \hat{y}_1 + \hat{u}_1 \Rightarrow y_1' y_1 = \hat{y}_1' \hat{y}_1 + \hat{y}_1' \hat{u}_1 \Rightarrow \hat{y}_1' \hat{y}_1 = \hat{y}_1' (y_1 - \hat{u}_1) = \hat{y}_1' y_1 - \hat{y}_1' \hat{u}_1$$

$$\Rightarrow \hat{y}_1' \hat{y}_1 = \hat{y}_1' y_1$$

$$\Rightarrow \hat{z}_1' \hat{z}_1 = \hat{z}_1' z_1$$

$$\Rightarrow \hat{\delta}_{IV} = \hat{\delta}_{2SLS}$$

رویکرد IV در سیستم معادلات همزمان :

وقتی سیستم معادلات همزمان داریم و متغیرهای درون زای و بیرون زای آن را می‌دانیم، اگر گفته شود در این سیستم

ابزارها چیست، گفته می‌شود ابزار در این سیستم معادلات همزمان متغیرهای بیرون زای باشند. با توجه به معادله

اول $y = \dots$ تابعی از تمامی متغیرهای بیرون زای سیستم شود.

* در 2 مرحله اول $\hat{y}_1$ تابعی از تمامی متغیرهای بیرون زای سیستم شد (y_1, y_2) که ابزارهای y_1 و y_2 می باشند $\hat{y}_1$ را می دهیم و آن یک ابزار برای y_1 است.

ابزار از تمامی متغیرهای بیرون زای سیستم می شود، قیمت را برسد آورده و جایگزینی می کنیم.

اگر با سیستم معادلات مواجه نباشیم و یک معادله ما به مصرف داشته باشیم:

$$C_t = \alpha + \beta_1 y_t + \beta_2 C_{t-1} + u_t$$

در این معادله y_t به نوعی درون زاست ($y = C + I + \dots$) و از طرفی correlate بودن با u_t می تواند باعث شود

که داده تخمین زنده از داده نباشد. در اینجا بهتر است که از یک ابزار (IV) استفاده کنیم. برای y_t خارج

از این معادله ابزاری تعریف کنیم. در واقع متغیرهای را در نظری بگیریم که درون زای بودن y_t را از بین ببرد.

چیزی که در تئوری سیستم اعتقاد ممل است باشد $\leftarrow$

$$y_t = F(C_{t-1}, y_{t-1}, I_{t-1}, \dots)$$

$\leftarrow$ از طریق داده تخمین از y_t را برسد آورده و در معادله می گذاریم $\hat{y}_t$ و u_t را از این طریق

از بین می ببریم. این یک IV برای یک single equation است.

نکته $\leftarrow$ single می بینیم اما Simultaneous تخمین می زنیم.

* Three stage Least square $\rightarrow 3SLS$

$$y_i = \gamma_1 x_i + x_i \beta_1 + e_i$$

$$y_i = [\gamma_1 \ x_i] \begin{bmatrix} \gamma_1 \\ \beta_1 \end{bmatrix} + e_i \Rightarrow y_i = z_i \delta_i + e_i$$

اگر سیستم دقیقاً قابل شناسایی بود، تک تک معادلات را به روش 2SLS تخمین می زدیم و $\hat{\gamma}$ را درست می آوردیم.
اگر معادلات را جدا جدا تخمین ببریم، مشکلات سازگاری حل می شد ولی به صورت سیستمی تخمین نخواهیم.
به عبارت دیگر به آوردن Full information Estimator نیست.

چطوری توانیم یک روش سیستمی Full information Estimator داشته باشیم؟

* SUR یک روش سیستمی است، چون ارتباط میان جهات خط را در نظر می گرفت.

* IV, 2SLS, تخمین زنده های Full information نیستن چون ارتباط میان خطها را در نظر نمی گیرن.
ولی تخمین زنده های سازگار هستند ولی هنوز مشکل اطلاعات را دارند.

* SUR اطلاعات بین معادلات را در نظر می گرفت و اطلاعات به efficiency میری کرد. زمانی که correlation خطها

را در نظر بگیریم efficient می شود، چون روش، روش سیستمی است.

اگر در 2SLS سازگاری مطرح است، باید efficiency را وارد کنیم، efficiency از طریق وارد کردن

ارتباط خطها وارد می شود.

* 3SLS روشی Full information است. (روش همبسته است).

* 3SLS نه تنها سازگار است بلکه efficiency نیز می باشد و از تمام اطلاعات میان خطاها استفاده می کند.

* ILS, 2SLS و IV از روش های همزمان هستند اما همبسته نیستند. چون اطلاعات بین معادلات را در نظر نمی گیرند.

* اگر به 2SLS روش سوم به SURE اضافه کنیم تبدیل به 3SLS می شود. اما دقیقتر اگر به جای δ از γ استفاده کنیم روش از limited information به full information ریا از غیر همبسته به همبسته تبدیل می شود.

فرم های دیگر از 2SLS :

$$y_1 = \gamma_1 \delta_1 + x_1 \beta_1 + e_1$$

$$y_1 = z_1 \delta_1 + e_1 \rightarrow \hat{\delta}_{1,2SLS} = (z_1' z_1)^{-1} z_1' y_1$$

$$(y_1 | y_1 | y_2) = (x_1 | x_2) \begin{pmatrix} \hat{\pi}_1^{\infty} & \hat{\pi}_1^{\infty} & \hat{\pi}_3 \\ \hat{\pi}_2^{\infty} & \hat{\pi}_2^{\infty} & \hat{\pi}_4 \end{pmatrix} + (u_1 | u_1 | u_2)$$

$$y_1 = x_1 \hat{\pi}_1^{\infty} + x_2 \hat{\pi}_2^{\infty} + \hat{u}_1 \Rightarrow y_1 = \hat{y}_1 + \hat{u}_1$$

$$\Rightarrow \begin{pmatrix} \hat{\pi}_1^{\infty} \\ \hat{\pi}_2^{\infty} \end{pmatrix} = (x'x)^{-1} x'y_1$$

$$\hat{y}_1 = x_1 \hat{\pi}_1^{\infty} + x_2 \hat{\pi}_2^{\infty} = x \begin{pmatrix} \hat{\pi}_1^{\infty} \\ \hat{\pi}_2^{\infty} \end{pmatrix}$$

$$\Rightarrow \hat{y}_1 = x (x'x)^{-1} x'y_1 \quad (1)$$

$$X = (x_1 : x_2) = X (X'X)^{-1} X'X = X (X'X)^{-1} X' (x_1 : x_2) \begin{cases} \rightarrow x_1 = X (X'X)^{-1} X' x_1 \\ \rightarrow x_2 = X (X'X)^{-1} X' x_2 \end{cases}$$

$$\Rightarrow x_1 = X (X'X)^{-1} X' x_1 \quad (2)$$

$$(1) \text{ و } (2) \Rightarrow (\hat{y}_1 : x_1) = X (X'X)^{-1} X' (y_1 : x_1) \Rightarrow \hat{z}_1 = X (X'X)^{-1} X' z_1 \quad (3)$$

$$\Rightarrow \hat{\delta}_{12SL} = [Z' X (X'X)^{-1} X' (X'X)^{-1} X' Z]^{-1} (Z' X (X'X)^{-1} X') y_1$$

$$\Rightarrow \hat{\delta}_{12SL} = [Z' X (X'X)^{-1} X' Z]^{-1} (Z' X (X'X)^{-1} X') y_1$$

حال یک روش IV و GLS را باهم به کار می بریم تا به 2SL برسیم.

ابتدا فرض می کنیم تمامی متغیرهای بیرون زای X ابزار باشند.

تمامی متغیرهای «دوت ز» را تابعی از تمامی متغیرهای بیرون زای سیستم می لند. $\checkmark$ Fit را می گیرند و جابجایی می لند. (ایر 2SL)

مرحله اول در این روش استفاده از IV می باشد و مرحله بعد استفاده از GLS است.

$\checkmark$ ابتدا تمامی متغیرهای بیرون زای سیستم را به عنوان ابزار در نظر می گیریم.

$$y_1 = x_1 \beta_1 + \epsilon_1$$

$$y_1 = z_1 \delta_1 + \epsilon_1 \rightarrow X' y_1 = X' z_1 \delta_1 + X' \epsilon_1$$

$$\text{Cov}(X' \epsilon_1) = X' E(\epsilon_1 \epsilon_1') X = \sigma^2 X' X$$

$$y^* = z^* \delta^* + e^*$$

$$e^*.e^{*'} = \Sigma \otimes I \quad \text{برای } X^* = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix} = I \otimes X \leftarrow \text{که اینجاست}$$

$$\hat{\delta}_{2SLS}^* = (Z^{*'} X^* (X^{*'} X^*)^{-1} X^{*'} Z^*)^{-1} Z^{*'} X^* (X^{*'} X^*)^{-1} X^{*'} y^*$$

$$\hat{\delta}_{2SLS}^* = \left[Z^{*'} (I \otimes X) \left((I \otimes X)' (I \otimes X) \right)^{-1} (I \otimes X)' Z^* \right]^{-1} Z^{*'} (I \otimes X) \left[(I \otimes X)' (I \otimes X) \right]^{-1} (I \otimes X)' y^*$$

$$\hat{\delta}_{2SLS}^* = \left[Z^{*'} \left(\underline{I \otimes X (X'X)^{-1} X'} \right) Z^* \right]^{-1} Z^{*'} \left(\underline{I \otimes X (X'X)^{-1} X'} \right) y^*$$

همه m معادلات را در چارچوب یک سیستم نوشتیم. I می توانست ماتریس واریانس-کوواریانس باشد و سیستمی کنیم

و چرا. چرا تخمین می زنیم باز هم اطلاعات بین معادلات را «نظر گرفته نشده است» و با توجه به اینکه ما زیاده داریم

اما هنوز نسبت به روش سیستمی efficiency کمتری دارد.

در 3SLS $\rightarrow$ اگر X^* را با معادلات ابزار در نظر بگیریم و یک FLS بزنیم ماتریس واریانس-کوواریانس به دست می آید

و شامل اطلاعات بین معادلات است و از روش سیستمی ما زیاده هست.

یک ابزار مانند X در نظر می گیریم ←

$$\Rightarrow y^* = z^* \delta^* + e^*$$

$$X^* y^* = X^* z^* \delta^* + X^* e^*$$

$$\text{cov}(X^* e^*) = X^* E(e^* e^{*'}) X^* = X^* (Z \otimes I) X^*$$

✓ چون ماتریس واریانس-کواریانس جلات خطا ظاهر شده است در نتیجه 2SLS نیست.

✓ ارتباط GLS با کار گیریم :

$$\delta^* = \left[Z^* X^* (X^* (Z \otimes I) X^*)^{-1} X^* Z^* \right]^{-1} \left[Z^* X^* (X^* (Z \otimes I) X^*)^{-1} X^* y^* \right]$$

$$\Rightarrow \delta^* = \left[Z^* (I \otimes X) (I \otimes X)' (Z \otimes I) (I \otimes X) \right]^{-1} (I \otimes X)' Z^* \left[Z^* (I \otimes X) (I \otimes X)' (Z \otimes I) (I \otimes X) \right]^{-1} (I \otimes X)' y^*$$

$$\Rightarrow \delta_{2SLS}^* = \left[Z^* (\hat{Z}^{-1} \otimes X(X'X)^{-1}X') Z^* \right]^{-1} \left[Z^* (\hat{Z}^{-1} \otimes X(X'X)^{-1}X') \right] y^* \quad **$$

* و * ← مشاهده می شود که در رابطه (**) خطاهای جیت معادلاتی در قالب ماتریس واریانس-کواریانس ظاهر شده است.

در رابطه (**) که ما به 2SLS زده شده اند اطلاعات بین معادلاتی خطاها در نظر گرفته نشده است و I ظاهر می شود.

اما چون خطاها correlate هستند وقتی از ابزار استفاده می کنیم (مانند X) و GLS یا SUR می زنیم اطلاعات بین

معادلاتی به جای I به صورت $\hat{\Sigma}^{-1}$ نشان داده می شود.

در SUR برای تک تک معادلات OLS می‌زدیم، پس آن‌ها را استخراج می‌کردیم، correlation خطاها را می‌نرمالیزیم یا ماتریس Σ می‌سازیم.

در 3SLS مرحله اول و دوم به 2SLS برمی‌گردیم. که در 2SLS از R^2 ، χ^2 را تخمین زده و در معادله‌ها اختاری

می‌گذاریم و سپس خطاهای معادله را به روش 2SLS تخمین خورده را محاسبه کرده $(e = y_i - z\hat{\beta}_i)$ خطاهای بین معادلاتی

را کواریانس گرفته مثل SUR، در معادله گذاشته که stage سوم را می‌دهد. که ماژار نیز هست.

نکته 3SLS $\leftarrow$ یک 2SLS و SUR است که خطاهای آن از 2SLS درست می‌آید که تلفیق این دو 3SLS را می‌دهد

و چون اطلاعات بین معادلاتی ظاهر شده است به این روش Full Information گفته می‌شود.

نکته 3SLS کاراتر از 2SLS یا برابر آن است اگر در Σ اطلاعاتی وجود داشته باشد 3SLS کاراتر و در صورتی که فاقد

اطلاعات باشد، کارایی آن برابر 2SLS است.

$$|\Sigma_{3SLS}| - |\Sigma_{2SLS}| < 0 \rightarrow \text{Negative Semi definite Matrix.}$$

$$|\Sigma_{2SLS}| - |\Sigma_{3SLS}| \geq 0 \rightarrow \text{Positive Semi definite Matrix.}$$

نکته $\leftarrow$ تخمین‌هایی که Full information هستند کاراتر از تخمین‌های Limited information می‌باشند.

تخمین‌هایی که Full می‌باشند روش‌های همبسته‌ای از چگونگی تمام اطلاعات بین معادلاتی استفاده می‌کنند.

$$y = x\beta + u \quad \rightarrow \quad E(x'u) \neq 0$$

$$y_i = z_i\beta + e_i \quad \rightarrow \quad E(z_i'e_i) \neq 0$$

Instrument variable in ols → x'

$$E(x'u) = 0 \quad \checkmark$$

$$x'e = 0 \rightarrow x'(y - x\hat{\beta}) = 0 \Rightarrow x'y = x'x\hat{\beta}$$

$$\Rightarrow \hat{\beta}_{ols} = (x'x)^{-1}x'y$$

$$\begin{cases} \frac{1}{n} \sum x_1 e = 0 \\ \vdots \\ \frac{1}{n} \sum x_k e = 0 \end{cases} \Rightarrow \text{لشتار} \checkmark$$

x اگر $E(x'u) \neq 0$ باشد IV مناسب چیست؟

$$E(z'u) = 0 \rightarrow z'e = 0 \rightarrow z'(y - x\hat{\beta}) = 0 \Rightarrow z'y = z'x\hat{\beta} \Rightarrow \hat{\beta}_{IV} = (z'x)^{-1}z'y \leftarrow$$

نشان دهید که سیستم 2SLS هم برای just و هم برای over id مناسب است.

$$\min_{\hat{\beta}} (z'(y - x\hat{\beta}))' W (z'(y - x\hat{\beta})) = Q(\beta)$$

$$\frac{\partial Q(\beta)}{\partial \beta} = 0 \rightarrow 2x'z'Wz'x\hat{\beta} - 2x'z'Wz'y = 0$$

$$\Rightarrow \hat{\beta} = (x'z'Wz'x)^{-1}x'z'Wz'y$$

$$W = (z'z)^{-1} \rightarrow \hat{\beta} = [x'z(z'z)^{-1}z'x]^{-1}x'z(z'z)^{-1}z'y$$

→ Five ←

مطالبی که تا اینجا مطرح شد تحت عنوان اقتصادسنجی سنتی بود که از سال ۱۹۸۰ تحول در آلو سازی اقتصادسنجی توسط Sims مطرح شد.

دو مشکل اساسی که در اقتصادسنجی وجود داشته است :

۱- به طور معمول در کتاب‌های متنی اقتصادسنجی $y_t = \alpha + \beta y_t + v_t$ در مورد اینکه y_t دارای unit root باشد یا نه صحبت نکردیم. در اقتصادسنجی متنی فرض بر این بود که برخی متغیرها مانده هستند و آلوها را برای اساسی تخمین می‌زدیم. در صورتی که در اقتصاد آلوها غیرمانده (non stationary) هستند و دارای رفتار I(1) هستند.

کاری که Engle - Breuinger در سال ۱۹۸۷ انجام دادند تحول بزرگی در اقتصادسنجی بوجود آورد که بین آلوهای که

مانده و غیرمانده هستند در اقتصادسنجی تفاوت قائل شویم.

۲- یک مجموعه ایرادی که از سال ۱۹۸۰ به بعد مطرح شد و عمدتاً روی پیکره سیستم معادلات همزمان مطرح شد، اولین آلوها که برای آلو سازی معادلات همزمان انجام می‌شد در موسسات معروف به *State* توسط تیم برن و کلارین انجام شد. آلوهای با تعداد معادلات زیاد حتی تا ۱۰۰۰۰ معادله اما علیرغم جامع بودن این آلوها بیش‌بیش‌های مخفی داشتند.

از این به بعد دنبال آلوهای هستیم که هم به خوبی ساختار را تحلیل کند و هم پیش‌بینی خوبی ارائه دهد.

در سال ۱۹۸۰، Sims مقاله‌ای به نام *Macro Economics & reality* در *Econometrica* منتشر کرد

که ایرادی که به اقتصادسنجی سنتی مطرح بود را عنوان کرد :

۱- بحث over identified بودن این آلوها است :

Sims بیان می‌کند آلوها کاملاً تئوری محور هستند یعنی در واقع تئوری به داده‌ها تمایل می‌شود و با توجه به داده‌ها آلو مناسب انتخاب نمی‌شود، به طور معمول باید با توجه به داده‌ها تئوری انتخاب شود و دست‌آورد «

* بر اساس آزمون تئوری انتخاب می شود نه اینکه یک الگوی آن تمایل شود، در عادات همزمان قیود زیاد بود
که می خواهیم آنهارا کم کنیم.

هدف درایت مسافت ← آیا داده ها تئوری های اقتصادی را می پذیرند؟

۲- در سبب بحث Dynamic Specification بودن این الگوهاست. (تشریح پویا)

هدف پیدا کردن رفته های مناسب برای داده ها است.

partial adjustment adaptive از جهت روش های است که رفته را وارد مدل می کند و از الگوهای استیلا تبدیل به الگوهای پویا می کند و از

چهار چوب تئوری می آید و در تمامی این رویکردها یک رفته ظاهر می شود.

$$\frac{M_t}{P_t} = A Y_t^{B_1} \cdot e^{B_2 i} + U_t \rightarrow \text{الگوی غیر خطی}$$

$$\log \frac{M_t^d}{P_t} = \log A + B_1 \log Y_t + B_2 i + U_t \rightarrow \text{Demand for money} \leftarrow \text{یک الگوی استیلا}$$

$$* M^d = M^s$$

در بازار می توان M^d را برسد آمد چون تقاضای پول بی نهایت است.

M^s (حجم نقدینگی) توسط مقامات پولی تعیین می شود.

$$* \rightarrow \log \frac{M_t^s}{P_t} = \log A + B_1 \log Y_t + B_2 i + U_t$$

→ تمامی تئوری ها در steady state نوشته می شوند به همین

علت استیلا هستند.

حال می خواهیم این تقاضا برای پول را به صورت پویا بنویسیم از یک سری هزینه استفاده می کنیم.

در بازار یک حجم مطلوب واتی پول وجود دارد یا تقاضا وجود دارد.

جمع تقاضا شده مطلوب پول

$$\log \frac{M_t}{P_t} - \log \frac{M_{t-1}}{P_{t-1}} = \lambda \left(\log \frac{M_t^d}{P_t} - \log \frac{M_{t-1}}{P_{t-1}} \right)$$

ضریب adjustment $0 < \lambda < 1$

B_1 و B_2 لنگش های بلند مدت هستند و وقتی آلگوی پویای شو کوتاه مدت می شود.

$$\Rightarrow \frac{1}{\lambda} \left[\log \frac{M_t}{P_t} - \log \frac{M_{t-1}}{P_{t-1}} \right] + \log \frac{M_{t-1}}{P_{t-1}} = \log \frac{M_t^d}{P_t}$$

$$\Rightarrow \frac{1}{\lambda} \log \frac{M_t}{P_t} = -\left(1 - \frac{1}{\lambda}\right) \log \frac{M_{t-1}}{P_{t-1}} + \log A + B_1 \log Y_t + B_2 i_t + u_t$$

$$\Rightarrow \log \frac{M_t}{P_t} = \underbrace{\lambda_1}_{\lambda_1} \log \frac{M_{t-1}}{P_{t-1}} + \underbrace{\lambda_0}_{\lambda_0} + \underbrace{\lambda_2}_{\lambda_2} \log Y_t + \underbrace{\lambda_3}_{\lambda_3} i_t + \epsilon_t$$

λ_2 و λ_3 لنگش های کوتاه مدت هستند.

* با تخمین لنگش های کوتاه مدت، لنگش های بلند مدت حاصل می شوند.

* Sims برای توالی القای لنگش های بلند مدت و پیش بینی Dynamic Specification هستند. ممکن است رتبه های لازم را نداشته باشند و دچار خطای Error Box & Jenkins می شود که به خوبی پیش بینی کند و رتبه های لازم را درست آید. Exogeneity Assumption $\rightarrow$ Causality. نظریه شریک Sims در جهت پیشانی بود که آلگوی ساختاری به نسبت آلگوی همبستگی $\leftarrow$ معمول بیرون زایی در اقتصاد سنتی.

به عنوان مثال در آلگوی زیر هزینه های دولتی را به صورت strictly exogeneous در نظریه درفینیم یعنی از شوک های

و اما تأثیری پذیرد که فرض بسیار قوی است و با واقعیت اقتصاد سازگار نیست.

و خودش می تواند تحت تأثیر متغیرهای دیگر قرار گیرد را به سطحی از بیرون زایی را داشته باشد.

Hendry - Engle - Richard (1983) $\rightarrow$ Super Exogeneity
 $\rightarrow$ Strong "
 $\rightarrow$ weakly "

Sims به جای اینکه از مفهوم strictly استفاده کند از مفهومی Granger causality استفاده می‌کند.

۴- چهارمین موردی که مطرح شد انتقاد لوکاس بود.

انتقاد لوکاس در چارچوب نئوکلاسیک مطرح می‌شود.

سیاست‌های پولی و مالی از آنجایی که مردم rational هستند در برابر این سیاست‌ها تغییر رفتار نشان می‌دهند در نتیجه تغییر در ساختار رخ می‌دهد بی‌اثر هستند. یعنی پاراسترها که فرض برای این بود ثابت اند در مقابل سیاست‌ها تغییر نمی‌کنند.

انتظارات به جای عقب‌نزدی جلوتر می‌باشد ← مردم جلوتر از دولت حرکت می‌کنند ساختار حرکت تغییر دارد.

Vector Auto Regressive $\rightarrow$ VAR

در مدل VAR همه متغیرها درون را هستند. $\leftarrow$ چه وقتها و چه غیر وقتها. متغیرهای آفوندا بیرون را بیرون را مشخص کنند.

مثال $\leftarrow$ هر سه درون را هستند همه این متغیرها را در قالب Vector مثل Y_t نشان می دهیم

$$Y_t = \begin{bmatrix} GDP_t \\ P_t \\ M_t \end{bmatrix}$$

که مربوط به مشاهده تمام است.

الگوی VAR (1) را به صورت زیر نشان می دهیم $\leftarrow$

$$Y_t = \mu + A Y_{t-1} + U_t \quad \text{VAR(1)}$$

$$\begin{bmatrix} GDP_t \\ P_t \\ M_t \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \mu_3 \end{bmatrix} + \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} GDP_{t-1} \\ P_{t-1} \\ M_{t-1} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \\ u_{3t} \end{bmatrix}$$

$$GDP_t = \mu_1 + a_{11} GDP_{t-1} + a_{12} P_{t-1} + a_{13} M_{t-1} + u_{1t}$$

$$P_t = \mu_2 + a_{21} GDP_{t-1} + a_{22} P_{t-1} + a_{23} M_{t-1} + u_{2t}$$

$$M_t = \mu_3 + a_{31} GDP_{t-1} + a_{32} P_{t-1} + a_{33} M_{t-1} + u_{3t}$$

* هر متغیر تابعی از متغیرهای خود در متغیر دیگر است.

* از متغیر VAR $\leftarrow$ متغیرها stationary هستند.

$$Y_t = r + AY_{t-1} + U_t \quad \text{VAR}(1)$$

در سیستم VAR، ثبات آن:

$$Y_1 = r + AY_0 + U_1$$

ابتدا به صورت Recursive حل می‌کنیم

$$Y_2 = r + A(Y_1 + U_1) + U_2 = r + Ar + A^2Y_0 + AU_1 + U_2$$

$$Y_t = (I + A + \dots + A^{t-1})r + A^tY_0 + \sum_{i=0}^{t-1} A^i U_{t-i}$$

الان $t-j-1$ شروع کنیم در حالت General Solution داریم

$$Y_t = (I + A + A^2 + \dots + A^{t-1})r + A^tY_0 + \sum_{i=0}^{t-1} A^i U_{t-i}$$

$$Y_t = (I - A)^{-1}r + \sum_{i=0}^{\infty} A^i U_{t-i}$$

Vector Moving Average

در حد گیری خواهیم داشت

VMA(∞)

ریشه‌های ماتریس A شرط ثبات را برای ما در می‌آورد $0 < |k| < 1$

عضیه α در سیستم VAR(P) تمامی مقادیر و تیر کویچ تیر از یک باشند سیستم stable است و این دلالت برای

دارد که سیستم Stationary (تمامی متغیرها $I(0)$ هستند) ولی علی قفیه به قرار نیست

Stable بودن نه تنها قوی‌تر از Stationary بودن است زیرا weakly stationary معنی است هر سیستم stable

حتی Stationary هم نیست اما علی این مطلب مافوق نیست در صورتی strictly stationary در نظر باشد با مفهوم

Stable یکی است

نکته: ممکن است تمامی سریهای y_t stationery باشند اما اثر تصحیح وقفه را درست انجام ندهیم در این صورت
 ممکن است سیستم stable نباشد.

$$y_t = \mu + \lambda y_t + v_t$$

اثر سیستم VAR(1) را به صورت lag operator بنویسیم

$$(I - \lambda)y_t = \mu + v_t \Rightarrow |I - \lambda z| = 0 \Rightarrow z_i = \frac{1}{\lambda_i}$$

در این صورت ریشههای z باید بزرگتر از 1 باشند تا نشان دهیم سیستم پایدار است.

$$y_t = v + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + v_t \quad \text{VAR}(p)$$

$$Y_t = \begin{bmatrix} y_t \\ y_{t-1} \\ \vdots \\ y_{t-p+1} \end{bmatrix}_{Kp \times 1} \quad V = \begin{bmatrix} v \\ 0 \\ \vdots \\ 0 \end{bmatrix}_{Kp \times 1} \quad A = \begin{bmatrix} A_1 & \dots & A_p \\ I_K & 0 & \dots & 0 \\ & \ddots & \ddots & \vdots \\ & & I_K & 0 \end{bmatrix}_{Kp \times Kp} \quad Y_{t-1} = \begin{bmatrix} y_{t-1} \\ y_{t-2} \\ \vdots \\ y_{t-p} \end{bmatrix}_{Kp \times 1}$$

$$\Rightarrow Y_t = V + AY_{t-1} + v_t$$

تبدیل سری از VAR(p) به صورت VAR(1) است

$$\Rightarrow Y_t = \mu + \sum_{i=0}^{\infty} A^i v_{t-i} \quad \rightarrow \quad \mu = (I - A)^{-1} V \quad \rightarrow \quad \text{VMA}(\infty)$$

ماتریس J را تعریف می کنیم تا حاصل ضرب آن در عبارت $\sum_{i=0}^{\infty} A^i v_{t-i}$ فقط $\text{VAR}(p)$ را به ما بدهد.

$$JY_t = \begin{bmatrix} I_K & 0 & \dots & 0 \end{bmatrix} \begin{bmatrix} y_t \\ y_{t-1} \\ \vdots \\ y_{t-p+1} \end{bmatrix} \Rightarrow JY_t = y_t$$

$$JY_t = J\mu + J \sum_{i=0}^{\infty} A^i v_{t-i}$$

$$Y_t = \mu + \sum_{i=0}^{\infty} A^i \sum_{j=0}^i v_{t-j}$$

$$\Rightarrow Y_t = \mu + \sum_{i=0}^{\infty} \underbrace{(JA^i J')}_{\psi_i} v_{t-i} \Rightarrow Y_t = \mu + \sum_{i=0}^{\infty} \psi_i v_{t-i}$$

world-Decomposition Theorem

هر فرآیند چون VAR را می توان از ترکیب ۲ فرآیند جدا نوشت اولین فرآیند که در دنیا مطرح است

یک فرآیند قطعی است و دیگری فرآیند تصادفی است.

$$Y_t = \mu + \sum_{i=0}^{\infty} \psi_i v_{t-i}$$

↓
بخش قطعی بخش تصادفی

یک فرآیند نامتناهی MA است که به هر شکلی آن می تواند فرآیندی باشد

VAR(P) متناهی بهر دو وضعیت با هم توپا → نامعلوم order → نامتناهی

$$Y_t = \phi(L) v_t \rightarrow VMA(q) \text{ محدود}$$

$$\Rightarrow \phi^{-1}(L) Y_t = v_t \Rightarrow A(L) Y_t = v_t \rightarrow VAR(\infty)$$

There is a unique inverse ← $\phi(L)$ باید absolutely adaptive باشد

Lag operator

اگر summable نباشد ← $L > 1$ می شوند و محوس پذیر نیست

Data generation Process :

در عملیات همزمان بر اساس تئوری جلوی زقیم بعد داده‌ها را می‌گذاشتیم.

اما در نگاه Sims با توجه به داده‌ها به تئوری‌ها می‌رسیم پس داده‌ها را در مدل گذاشتیم و به تئوری می‌رسیم.

* اگر پارامترهای A را داشته باشیم می‌توانیم پیش‌بینی کنیم.

$$\rightarrow Y_t = \tau + A Y_{t-1} + U_t \quad \text{VAR (1)}$$

ایده کلی Forecast :

هدف ما در پیش‌بینی این است که MSE را Min کنیم. بحثی که در اینجا مطرح می‌شود این است که پیش‌بینی بر چه اساسی صورت می‌گیرد. اینجا باید linear projection را در نظر بگیریم. نکته این است که این گونه نباشد، اگر یک اطلاعاتی مانند Y_t داشته باشیم و بخواهیم پیش‌بینی Y_{t+h} را در افق زمانی پیش‌بینی کنیم، زمانی می‌توانیم بگوییم که این پیش‌بینی خوب است که نسبت به سایر پیش‌بینی‌ها، Min MSE کمتر داشته باشد.

$$E(Y_{t+h} | Y_t) \rightarrow \text{Min } MSE_{Y_t}(h | Y_t)$$

* یک پیش‌بینی کمتر داریم تا Y_t در نظریه می‌گیریم به نحوی که $MSE_{Y_t}(h | Y_t) = E(Y_{t+h} - \bar{Y}_t(h)) (Y_{t+h} - \bar{Y}_t(h))'$ و می‌خواهیم بررسی کنیم که $MSE_{Y_t}(h | Y_t) < MSE_{Y_t}(h | Y_t)$ ؟

$$\begin{aligned} MSE_{Y_t}(h | Y_t) &= E \left[(Y_{t+h} - E(Y_{t+h} | Y_t)) + (E(Y_{t+h} | Y_t) - \bar{Y}_t(h)) \right] \cdot \left[(Y_{t+h} - E(Y_{t+h} | Y_t)) + (E(Y_{t+h} | Y_t) - \bar{Y}_t(h)) \right]' \\ &= MSE_{Y_t}(h | Y_t) + E \left[(E(Y_{t+h} | Y_t) - \bar{Y}_t(h)) (E(Y_{t+h} | Y_t) - \bar{Y}_t(h))' \right] + 0 \end{aligned}$$

$$(I) \rightarrow E(Y_{t+h} - E(Y_{t+h} | Y_t)) (E(Y_{t+h} | Y_t) - \bar{Y}_t(h))' = 0$$

$$(II) \rightarrow MSE_{Y_t}(h | Y_t) = E(Y_{t+h} - E(Y_{t+h} | Y_t)) (Y_{t+h} - E(Y_{t+h} | Y_t))'$$

$$\Rightarrow MSE_{Y_t}(h | Y_t) = MSE_{Y_t}(h | Y_t) + E \left[(E(Y_{t+h} | Y_t) - \bar{Y}_t(h)) (E(Y_{t+h} | Y_t) - \bar{Y}_t(h))' \right]$$

$$\Rightarrow MSE_{Y_t}(h | Y_t) \geq MSE_{Y_t}(h | Y_t)$$

VAR یک مدل بهرار Linear projection (ترکیب خطی از گذشته خودش است).

$$Y_{t+h} = (I + A + A^2 + \dots + A^{h-1})Y_t + A^h Y_t + \sum_{i=0}^{h-1} A^i U_{t+h-i}$$

$$E(Y_{t+h}) = (I + A + A^2 + \dots + A^{h-1}) + A^h Y_t$$

$$\rightarrow E[Y_{t+h} - E(Y_{t+h})][Y_{t+h} - E(Y_{t+h})]' = \left(\sum_{i=0}^{h-1} A^i U_{t+h-i} \right)^2 = \text{MSE}$$

که مجموع خطاهای در طول زمان

Granger - causality

به عدد تری منطقی پیش بینی min MSE بحث می کند.

اولین بار توسط Granger در سال 1969 ارائه شده است. و اساس آن برای مناسب است که آیا متغیرهای وجود

دارند که به پیش بینی متغیرهای دیگر کمک کند. اگر در مجموعه X_t چند متغیر وجود داشته باشد می تواند به پیش بینی متغیر مورد نظر کمک کند و می توان گفت بین دو متغیر causality وجود دارد.

* متغیر علت هیچ وقت بعد از معلول اتفاق نمی افتد. علت باید متغیر دیالو تا معلول اتفاق بیفتد.

اگر دو متغیر X_t و Z_t را در نظر بگیریم و اگر بخواهیم $X_t(h|Y)$ را برست بگیریم زمانی می توانیم بگیریم X_t باعث توضیح پیش بینی Z_t می شود که ؟

* X_t مربوط به S ها که کوچکتر از t را از X_t خارج کنیم

$$\text{MSE}_{Z_t}(h|Y) < \text{MSE}_{Z_t}(h|Y \setminus X_S | S \leq t)$$

X_t Granger - cause Z_t

or X_t is Granger - cause for Z_t

* در آلتوی VAR، وقفه‌های Y_t آن را Cause می‌کنند به این معنی که در Instantaneous-causality, Granger-cause را در نظر نمی‌گیریم.

Instantaneous causality به معنی Cause آنی است. ابتدا خودش در پیش بینی Y_{t+1} تا اثری ندارد (همزمان)

* مثال: قیمت نفت اثراتی می‌یابد می‌خواهیم ببینیم این اثرات قیمت Y_t را اضافه می‌کنیم یا نه؟

تئوری و واقعیت نشان می‌دهد که P_t^o از مکانیزم‌های مختلف با یکدیگر چند وقته تولید را تحت تأثیر قرار می‌دهد. اما تغییر قیمت نفت در آن واحد قیمت ارز را تحت تأثیر قرار می‌دهد که تقریبی و سطح پول را تحت تأثیر قرار می‌دهد.

آن را Instantaneous را به Granger اضافه کنیم؟

$$MSE_{Y_t}(1|Y_t) > MSE_{Y_t}(1|Y_t \cup \{Y_{t+1}\})$$

بر اساس مجموعه اطلاعاتی که بحث کردیم، به سراغ VAR می‌رویم Granger causality را در VAR پیاده می‌کنیم، که از این به بعد یاد از روش‌هایی که می‌توانیم در مورد ساختار صحبت کنیم در VAR Granger causality است و در چهارچوب VAR چه طوری می‌توانیم بفهمیم، Causal، حساس یا نه؟

مرحله بعدی به امیلات C, C می‌پردازیم و سعی می‌کنیم I, C را وارد کنیم. و با روش‌های شبیه سازی آمقادی در چهارچوب آلتوی VAR به شبیه سازی آمقادی می‌پردازیم. در واقع به اثرات و تاثیرهای cause و تاثیر بر روی متغیر دیگر و در قالب I, C و C, C می‌پردازیم که نوعی شبیه سازی است. تئوری به یک متغیر می‌دهیم و اثرات خود را در طول زمان

$$Y_t = \mu + AY_{t-1} + U_t \quad \text{VAR}(1)$$

روی متغیرهای دیگر بررسی می‌کنیم. اثر آنی و وقفه‌ای در طول زمان چقدر است.

$$Y_t = \mu + \sum_{i=0}^{\infty} A^i U_{t-i} \quad \text{VMA}(\infty)$$

$$y_t = \mu + \sum_{i=0}^{\infty} \theta_i v_{t-i} \quad \text{MA}$$

$$y_t = \begin{bmatrix} z_t \\ x_t \end{bmatrix}$$

y را به دو مجموعه بزرگتر افراز می کنیم

$$\Rightarrow \begin{bmatrix} z_t \\ x_t \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} + \begin{bmatrix} \theta_{11}(L) & \theta_{12}(L) \\ \theta_{21}(L) & \theta_{22}(L) \end{bmatrix} \begin{bmatrix} v_{zt} \\ v_{xt} \end{bmatrix} \quad \begin{aligned} \theta(L) &= I + \theta L + \theta^2 L^2 + \dots \\ \theta(L) &= \sum \theta^i L^i \end{aligned}$$

$$\Rightarrow z_t = \mu_1 + \theta_{11}(L) v_{zt} + \theta_{12}(L) v_{xt}$$

$$x_t = \mu_2 + \theta_{21}(L) v_{zt} + \theta_{22}(L) v_{xt}$$

ما خواهیم بررسی کنیم که آیا x_t Granger-caused می کند z_t ؟

$$z_t = \mu_1 + \sum_{i=0}^{\infty} \theta_{11,i} v_{zt-i} + \sum_{i=0}^{\infty} \theta_{12,i} v_{xt-i}$$

هم z هم x است

$$\rightarrow z_t(1|y_t) = \mu_1 + \sum_{i=0}^{\infty} \theta_{11,i} v_{zt-i} + \sum_{i=0}^{\infty} \theta_{12,i} v_{xt-i}$$

$$\Rightarrow \text{MSE}_Z(h|y_s/s \leq t) < \text{MSE}_Z(h|z_s/s \leq t) \Rightarrow x_t \text{ Granger-caused } z_t \text{ است.}$$

z_t هم تحت تاثیر خودش و هم خود z های مربوطه به x_t قرار می گیرد.

اگر x_t non-Granger-caused باشد، در این صورت باید تمامی θ_{12} روی تمام آنها صفر باشد.

اثر کردن x روی z معنی ندارد. (و دقیقاً با Concept بالا هم خوانی دارد)

و در واقع یک قضیه است.

قضیه:

* اگر y_t از یک فرآیند با ثبات VAR تبعیت کند، اگر y_t را به مجموعه متغیران زیر کنیم $y_t = \begin{bmatrix} z_t \\ x_t \end{bmatrix}$

و فرآیند canonical MA را برای z به صورت معادله (1) نوشته شود، non-Granger-causal بودن x_t برای

z_t زمانی برقرار است که تمام $\theta_{12,i}$ ها برابر صفر باشند، $\theta_{12,i} = 0$ و $i=0, 1, \dots$

$$MSE_z(h | y_s | s \leq t) = MSE_z(h | z_s | s \leq t) \Leftrightarrow \theta_{12,i} = 0 \text{ و } i=0, 1, \dots$$

* اگر causality برقرار نباشد $\rightarrow$

$$\begin{bmatrix} \theta_{11}(L) & 0 \\ \theta_{21}(L) & \theta_{22}(L) \end{bmatrix} \rightarrow \begin{bmatrix} \theta_{11}^{-1}(L) & 0 \\ \theta_{22}^{-1}(L) \cdot \theta_{21}(L) \cdot \theta_{11}^{-1}(L) & \theta_{22}^{-1}(L) \end{bmatrix}$$

VAR(2):

$$\begin{bmatrix} z_t \\ x_t \end{bmatrix} = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} + \begin{bmatrix} A_{1,11} & A_{1,12} \\ A_{1,21} & A_{1,22} \end{bmatrix} \begin{bmatrix} z_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} A_{2,11} & A_{2,12} \\ A_{2,21} & A_{2,22} \end{bmatrix} \begin{bmatrix} z_{t-2} \\ x_{t-2} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \end{bmatrix}$$

non-Granger-causal $\rightarrow A_{1,12} = A_{2,12} = 0$

VAR(p): $A_{i,12} = 0 \quad i=0, 1, \dots, p$

نکته!

در non-Granger-causal z_t فقط ثابتی از رتبه های خودش است و رابطه ای میان z_t و x_t وجود ندارد.

* می توان با f-test راجع به Granger-causal در VAR بررسی کرد.

VAR را یک بار بدون مقید تخمین زده و یکبار رتبه های x_t را برآورد و تخمین می زنیم، تفاوت آماره F ظاهر می شود.

و در باره معنی داری تفاوت در MSE بحث می کنند.

؟

$$\begin{matrix} Z_t \\ X_t \end{matrix} \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ y_{3,t} \end{bmatrix} = \Gamma + \begin{bmatrix} .5 & 0 & 0 \\ .1 & .1 & .3 \\ 0 & .2 & .3 \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \\ y_{3,t-1} \end{bmatrix} + \begin{bmatrix} u_{1,t} \\ u_{2,t} \\ u_{3,t} \end{bmatrix}$$

→ X_t is non Granger-causal for Z_t

→ Z_t is Granger-causal for X_t

* اثر هر دو متغیر Granger هم با هم می‌توانیم Feed back داریم.

یا توجه به دامنیت ابعاد VAR، و به کاربرد Granger-causality و اینکه چای زمانی causality وجود دارد به سبب سازی سیاستی می‌پردازیم. Impulse-Response را استخراج کرده سپس به نقد آن می‌پردازیم. روشی که Sims درباره Policy Simulation در ابزار VAR مطرح کرد را نشان می‌دهیم (اثر یک متغیر (شوک) روی متغیرهای دیگر).

: Impulse-Responses.

ایده اصلی Impulse-Response برای منطبق است که اثر در یک آلگوی VAR، K متغیر دامنیت با هم می‌روند. اثر به یکی از این متغیرها شوکی وارد شود، اثر این متغیر شوک (کنانه) روی خود متغیر و سایر متغیرهای آلگوی VAR در طول زمان چه جوری خوش را نشان می‌دهد.

* الگوی VAR را در نظر می‌گیریم که $K=3$ و عرض از مبدأ نداریم.

$$\begin{bmatrix} y_{1t} \\ y_{2t} \\ y_{3t} \end{bmatrix} = \begin{bmatrix} .5 & 0 & 0 \\ .1 & .1 & .3 \\ 0 & .2 & .3 \end{bmatrix} \begin{bmatrix} y_{1,t-1} \\ y_{2,t-1} \\ y_{3,t-1} \end{bmatrix} + \begin{bmatrix} u_{1t} \\ u_{2t} \\ u_{3t} \end{bmatrix}$$

ماتریس واریانس-کوواریانس $\rightarrow$

$$\Sigma_u = \begin{bmatrix} 2.25 & 0 & 0 \\ 0 & 1 & .5 \\ 0 & .5 & .74 \end{bmatrix}$$

+ در زمان t رخ می‌شود به u_{1t} وارد می‌شود و بقیه شوند صفر است. ($u_{1t}=1$) خواهیم افزایش شوند را در طی زمان

S.1/

$$\begin{bmatrix} y_{1t} \\ y_{2t} \\ y_{3t} \end{bmatrix} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix}$$

$$u = \begin{bmatrix} u_{1t}=1 \\ u_{2t}=0 \\ u_{3t}=0 \end{bmatrix}$$




بررسی کنیم.

در S.S مقدار وقفه‌ها برابر صفر است.

S.2/

$$\begin{bmatrix} y_{1,t+1} \\ y_{2,t+1} \\ y_{3,t+1} \end{bmatrix} = \begin{bmatrix} .5 & 0 & 0 \\ .1 & .1 & .3 \\ 0 & .2 & .3 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} .5 \\ .1 \\ 0 \end{bmatrix}$$

$$\begin{bmatrix} y_{1,t+2} \\ y_{2,t+2} \\ y_{3,t+2} \end{bmatrix} = \begin{bmatrix} .5 & 0 & 0 \\ .1 & .1 & .3 \\ 0 & .2 & .3 \end{bmatrix} \begin{bmatrix} .5 \\ .1 \\ 0 \end{bmatrix} = \begin{bmatrix} .25 \\ .06 \\ .02 \end{bmatrix}$$



مشکلات روشی داریم که بر اینم

۱۱ با توجه به ماتریس واریانس و کواریانس و Correlation میان U ها، نمیتوان مثلاً U_3 را منفی کرد و U_2 را یک کرد و

در واقع شوند خالص نیست، به دلیل وجود Correlation میان U_2 و U_3 .

اگر ماتریس قطری باشد، Correlation نداریم و میتوان یکی را یک و مابقی را منفی کرد.

۱۲ VAR همواره R.F است، خطی آن R.F است و در واقع شوند به R.F وارد می شود و تحلیل از لحاظ اقتصادی ارزشی

$$\pi' + \lambda B + E = 0$$

ندارد. چون شوند R.F تلفیقی از چند پارامتر ساختاری است.

$$-E\pi' = U \Rightarrow \pi' E' E \pi' = U' U$$

* U ترکیبی از پارامترهای ساختاری است.

$$R.F \Rightarrow y_t = -\pi' B y_{t-1} - \pi' E_t \Rightarrow y_t = A y_{t-1} + U_t \quad \text{VAR(1)}$$

$$\pi' + \lambda B + E = 0 \Rightarrow \pi' y_t + B \lambda_t + E_t = 0$$

فرض می کنیم در الگو متغیر درون را وجود ندارد، اما متغیرهای از قبل تعیین شده وجود دارد.

$$\Rightarrow \pi' y_t + B y_{t-1} + E_t = 0 \Rightarrow y_t = -\pi' B y_{t-1} - \pi' E_t \Rightarrow y_t = A y_{t-1} + U_t \quad \text{VAR(1)}$$

* فرض می کنیم در معادلات همزمان، دو متغیر و یا در set متغیر داریم.

$$\begin{bmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & \gamma_{22} \end{bmatrix} \begin{bmatrix} z_t \\ x_t \end{bmatrix} + \begin{bmatrix} \beta_{11} & \beta_{12} \\ \beta_{21} & \beta_{22} \end{bmatrix} \begin{bmatrix} z_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix} = 0$$

$$* \text{اولین معادله} \rightarrow \gamma_{11} z_t + \gamma_{12} x_t + \beta_{11} z_{t-1} + \beta_{12} x_{t-1} + \varepsilon_{1t} = 0$$

در معادله اول z_t تابعی از قبلی و در

$$\rightarrow \text{نمی توانیم} \begin{bmatrix} -1 & \gamma_{12} \\ \gamma_{21} & -1 \end{bmatrix} \begin{bmatrix} z_t \\ x_t \end{bmatrix} = - \begin{bmatrix} \beta_{11} & \beta_{12} \\ \beta_{21} & \beta_{22} \end{bmatrix} \begin{bmatrix} z_{t-1} \\ x_{t-1} \end{bmatrix} - \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix}$$

معادله دوم x_t تابعی از قبلی می شود

نکته در R.F $\leftarrow$ Instantaneous causality نیست و فقط Greinger-caused است.

Sims : معنی می کند correlation آنی را با هم ببیند.

شکوک را به R.F ندهد و روشها را به ساختار دهد.

3. $I \rightarrow$ causality را وارد کند نه تنها وقفهها اثر دارند بلکه هم آنی اثر کند. او اینها را در چارچوب Impulse-Response

در آلتوی VAR وارد می کند.

در بکس Sims تحت عنوان orthogonal-impulse

$$Y_t = AY_{t-1} + U_t$$

$$\Gamma Y_t = -BY_{t-1} - E_t$$

$$\Rightarrow Y_t = -\Gamma^{-1}BY_{t-1} - \Gamma^{-1}E_t \Rightarrow Y_t = AY_{t-1} + U_t$$

$$E(UU') = \Sigma_U = PP'$$

بالا مثلثی $\rightarrow$ چاله پایینی مثلثی

* VAR را حل کرده ماتریس واریدارها را برست آمده و Choleski- Decomposition را انجام می دهیم که برای این

این روشها هر ماتریس مربع را می توان به یک ماتریس بالا مثلثی و یک ماتریس مثلثی قوی تبدیل کرد.

$$\text{Ex) } \begin{bmatrix} 1 & 3 \\ 3 & 2 \end{bmatrix} = \begin{bmatrix} a_{11} & 0 \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} a_{11} & a_{12} \\ 0 & a_{22} \end{bmatrix} = \begin{bmatrix} a_{11}^2 & a_{11}a_{12} \\ a_{11}a_{21} & a_{12}a_{21} + a_{22}^2 \end{bmatrix} \rightarrow \begin{bmatrix} 1 & 3 \\ 3 & 2 \end{bmatrix} \begin{matrix} a_{11}=1 \\ a_{12}=3 \\ a_{22}= \end{matrix}$$

ماتریس ماتریس D را Diagonal مرتب می گیریم که روی قطر آن حقیقی مسطری قطر ماتریس P باشد و P را در D ضرب

می کنیم که روی قطر آن 1 می شود و پایینی مثلثی است. لزوماً اجزاء آن با اجزاء P برابر نیست.

$$\Rightarrow \Gamma^{-1} = PD^{-1} \Rightarrow P = \Gamma^{-1}D$$

* می خواهیم شوند را به ساختار بدهیم تا معنی تئوریک داشته باشد.

$$v_t = -\pi^{-1} \epsilon_t \Rightarrow \epsilon_t = -\pi v_t \rightarrow R.F$$

↳ structural shock

$$\epsilon_t \epsilon_t' = \pi v_t v_t' \pi' \rightarrow E(\epsilon_t \epsilon_t') = \pi E(v_t v_t') \pi'$$

$$\Rightarrow \Sigma_\epsilon = \pi \Sigma_v \pi' = \pi \rho \rho' \pi' = \pi \pi' \Omega \Omega' \pi'$$

ماتریس قطری $\Rightarrow \Sigma_\epsilon = \Lambda$ ماتریس واریانس-کواریانس مختل

نکته ۱: چون ϵ ها با هم correlation هستند یک شود به ϵ وارد می شود، یک شود خالص نیست و بر روی سایر ϵ ها هم تاثير می گذارد. با این روش ماتریس واریانس-کواریانس را قطری نبرديم که شود خالص است با شيم و شود به دي از ϵ ها به ديگر ϵ ها تاثير نمی گذارد.

در سیستم معادلات همزمان هدف تخمین ضرایب ساختاری (B و π) بود.

نکته اول: زمانی که ماتریس P را تجربه و ماتریس واریانس-کواریانس را درست آيم D را به عنوان معادله می تواند روی قطرها یک کنو برستای آيم. عملاً به نوعی ماتریس π را تخمین زده ايم و از ماتریس واریانس-کواریانس شناسایی می کنیم شناسایی از دور روش استفاده از پاراسترها و یا ماتریس واریانس-کواریانس انجام می شود. تخمین از π' معادلات همزمان است که پاراسترها را به صورت عطفی تخمین می زند.

نکته دوم: π_1 و π_2 لا شود آنی است که اگر بخواهیم شناسایی کنیم (بطور عطفی) یک ماتریس پابین مثلثی می شود $\pi = \begin{bmatrix} \pi_{11} & 0 \\ \pi_{21} & \pi_{22} \end{bmatrix}$ نوعی شناسایی به Sims بررسی می کند عطفی است که همواره just identified است، ایرادی که به Sims وارد نشد این بود که معادلات over-identified نیستند. شود ساختاری است و سیستم معادلات همزمان عطفی است.

یکی از مشکلات Simulation ساده این بود که چون تواریها غیر مفر بودند، اثر شود خالص نبود و باعث می‌شد بررسی اثر شودها بررسی می‌توانیم تحلیل قائل شویم. ایراد دوم این بود که شود را به R.F می‌داد که معنوی اقتصادی ندارد و در حالی که ما با ساختار کاری کنیم و اثر شود باید برگزیده از ساختار باشد. ایراد سوم اینکه شودهای لحظه‌ای را نمی‌دید و Grenger Causality را بررسی می‌کرد، I. causality را بررسی نمی‌کرد

$$y_1 x_{11} + x_1 B_{11} + x_2 B_{21} + \dots + x_k B_{k1} + E_1 = 0$$

$$y_1 x_{12} + y_2 x_{22} + x_1 B_{12} + \dots + x_k B_{k2} + E_2 = 0$$

سیستم معادلات می‌گیریم

$$\Gamma = \begin{bmatrix} -1 & \gamma_{12} & \dots \\ 0 & -1 & \dots \\ \vdots & \vdots & \ddots \\ 0 & 0 & \dots & -1 \end{bmatrix}$$

$$\Rightarrow P = \Gamma^{-1} D \Rightarrow \boxed{\Gamma^{-1} = P D^{-1}}$$

$$\boxed{E = -\Gamma^{-1} v_t}$$

$$E(vv') = \Sigma_v \Rightarrow \boxed{E(E_t E_t') = \Lambda}$$

چون ماتریس واریانس-کواریانس R.F. correlation دارد اما Λ ندارد.

به جای اینکه بگوییم سیستم همزمان است، معادلات می‌گیریم. تا Γ تبدیل به یک ماتریس بالا یا پایین مثلثی تبدیل شود. (یا وارد کردن محدودیت‌های مفر) و به جای اینکه از Q برای تخمین استفاده کنیم از ماتریس P استفاده کرده و Γ را برست

$$\Gamma^{-1} = P D^{-1}$$

برای اساس می‌توان هم شود را به صورت Instantaneous در نظر بگیریم و هم شودهای ساختاری درست می‌گیریم.

$$\begin{bmatrix} -1 & \gamma_{12} \\ \gamma_{21} & -1 \end{bmatrix} \begin{bmatrix} z_t \\ x_t \end{bmatrix} + \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} \begin{bmatrix} z_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix} = 0$$

توضیح بیشتر

* برای تبدیل این سیستم معادلات همزمان به سیستم معادلات باید $\gamma_{12} = 0$ می‌گذاریم. که تبدیل به z_t می‌شود و سپس به روش OLS، γ_{21} را تخمین می‌زنیم.
 که از لحاظ نظری صحیح است

$$\Rightarrow \underbrace{\begin{bmatrix} z_t \\ y_t \end{bmatrix}}_{Y_t} = - \underbrace{\begin{bmatrix} -1 & 0 \\ \gamma_{21} & -1 \end{bmatrix}}_A \underbrace{\begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}}_{Y_{t-1}} \underbrace{\begin{bmatrix} z_{t-1} \\ y_{t-1} \end{bmatrix}}_{Y_{t-1}} - \underbrace{\begin{bmatrix} -1 & 0 \\ \gamma_{21} & -1 \end{bmatrix}}_{U_t} \underbrace{\begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix}}_{U_t}$$

$\Rightarrow Y_t = A Y_{t-1} + U_t$ structural که تبدیل به VAR شده است و identification بر اساس پارامترهای رگرسیون معادلات ساختاری صورت گرفته است.

* فرض کنید $\gamma_{12} \neq 0$ و VAR داریم که در مورد $j=1$ و $i=0$ آن صحبتی نداریم. وی خواهیم R.F را به تحلیل ساختار بر نرسانیم.

$$U_t = - \begin{bmatrix} -1 & \gamma_{12} \\ \gamma_{21} & -1 \end{bmatrix}^{-1} \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix}$$

* می توان به جای اینکه شناسایی را روی پارامترها انجام داد، می توان از ماتریس واریا فنس - کواریانس استفاده کرد که ترکیبی از پارامترهای ساختاری و شقوق های ساختاری است.

* و چون این ماتریس Σ است کافی است که محدودیت را اعمال کرد و شناسایی را انجام دهیم.

اگر فرض کنیم $j=1$ است باید متد سیستم عطفی «نظم گرفته می شود» کافی است حالا γ_{21} را تخصیص زد که به نوعی تخصیص پارامترهای ساختاری از طریق ماتریس واریا فنس - کواریانس است.

و وقتی از Ch.D استفاده کردیم مثل اینکه تبدیل به دو ماتریس بالا و پایین مثلثی تبدیل کردیم و شناسایی کردیم.

و $j=1$ و سیستم عطفی می شود.

داشتن pp' مثل داشتن π' است، با این تفاوت که هر π' ضرب شده تا نرمالایز کرد.

داشتن D مثل این است که رابطه عطفی میان ε و γ وارد کردیم و با داشتن این ماتریس مثل این است که سیستم

$$U_{1t} = \varepsilon_{1t}$$

معادلات همزمان را به صورت عطفی انجام دادیم. از شقوق R.F به شقوق ساختاری رسیدیم.

$$U_{2t} = \gamma_{21} \varepsilon_{1t} + \varepsilon_{2t}$$

از رابطه میان ε_{1t} و ε_{2t}

نکته ۱ از غرض آنکه تحلیل داده‌ها شروع کرده و به جای وارد کردن شوک به $R \cdot f$ با حفظ تفرق معادلات همزمان شوک به خطای معادله ساختاری وارد می‌شود. چون با خطاهای دیگر correlation ندارد و شوک خالص است.

و بر اساس رابطه بالا به معادله‌های دیگر وارد می‌شود و همزمانی با ارتباط شوک‌های ساختاری وارد می‌شود. ارتباط z_4 و z_4

ϵ_4 و ϵ_4 ارتباط دارند.

وقتی به ϵ_4 شوک می‌دهیم روی خود شوک z_4 ظاهر می‌شود (در آن واحد) ولی در معادله دوم با ضرب z_4 به طورانی

در معادله دوم اثر می‌گذارد و در معادله نهم با وقفه و پویایی سیستم شروع به کاری کند.

نکته ۲ اگر شوک به ϵ_4 داده شود به طور همزمان بر روی z_4 تا اثر نمی‌گذارد و این یکی از ایرادات اولیه است که اولاً به عقبه بونی

بر می‌گردد که اثر این رویداد 0.1 بود مشکل حل می‌شود که بعدها کامل می‌شود تحت عنوان Structural VAR مطرح می‌شود.

همزمان سه کار انجام دادیم: ۱) شوک‌ها را Diagonal کردیم.

۲) orthogonal Impulse ← شوک‌ها را عمود کردیم.

۳) همزمان شوک‌ها را به ساختاری دهیم.

$$y_t = \mu + \sum_{i=0}^{\infty} \theta_i v_{t-i}$$

نمایش Granger، VMA ←

$$\Rightarrow y_t = \mu + \sum_{i=0}^{\infty} \theta_i \cdot P D^{-1} \epsilon_{t-i} \Rightarrow y_t = \mu + \sum_{i=0}^{\infty} \theta_i P D^{-1} \epsilon_{t-i}$$

$$E(\epsilon_t \epsilon_t') = D D'$$

D به انحراف معیار است. چون $D D'$ ماتریس واریانس-کواریانس است.

$$\begin{bmatrix} \epsilon_1 / \sigma_{\epsilon_1} & \\ & \epsilon_2 / \sigma_{\epsilon_2} \end{bmatrix}$$

بخاطر ماتریس D شوک به اندازه یک واحد انحراف معیار وارد می‌شود.

$$\Rightarrow \begin{bmatrix} v_{1t} \\ v_{2t} \\ v_{3t} \end{bmatrix} = - \begin{bmatrix} 1 & 0 & 0 \\ \gamma^{21} & 1 & 0 \\ \gamma^{31} & \gamma^{32} & 1 \end{bmatrix} \begin{bmatrix} \epsilon_{1t} \\ \epsilon_{2t} \\ \epsilon_{3t} \end{bmatrix} \rightarrow \begin{cases} v_{1t} = \epsilon_{1t} \\ v_{2t} = \gamma^{21} \epsilon_{1t} + \epsilon_{2t} \\ v_{3t} = \gamma^{31} \epsilon_{1t} + \gamma^{32} \epsilon_{2t} + \epsilon_{3t} \end{cases}$$

* شوک به y_t می‌دهیم، از کانال Δ^2 به y_t و از کانال Δ^3 به y_{t+1} می‌رسد. (در حالت Δ^2).

از مرحله قبلی رفته به صورت پویا شروع به کاری کرد. Loop recursive اثر خود را نشان می‌دهد و هم Instantaneous و هم Granger - Causality بررسی می‌شود.

نکته - اثر شوک به y_t وارد شوک در اولی چون عطفی است بی تاخیر است و در دومی و سومی تاخیر دارد (در آن واحد) و در y_{t+1} نیز وارد اولی می‌شود.

ایراد سیستم عطفی Choleski Decomposition با رویکرد Sims چون $Ch.D$ استفاده می‌کنیم و امر نیست و به جای متغیرهای VAR حساس است و به این که کدام متغیر اول باشد حساس است و اثر ترتیب و چیزهای تغییر پیدا کند $Ch.D$ تغییر پیدا می‌کند و اهمیت شوک نیز جای می‌شود.

برای از بین بردن این ایراد Δ رویکرد وارد می‌شود.

۱۱ اثر متغیر داشته باشیم ۹ تا impulse-response داریم، تمام ۹ حالت را مدنظر گرفته و بررسی کنیم چقدر تفاوت دارند و کدام با تئوری سازگارتر است.

بر اساس تئوری Demand Side، اثر متغیرهای اسمی و money supply بر روی متغیرهای حقیقی GDP کوتاه مدت است.

نکته - اثر شوک پولی به کار ببریم در مرحله اول حجم GDP را افزایش می‌دهد اما با افزایش حجم پول در مراحل بعدی باعث می‌شود price بالا رود و تورمی که ایجاد می‌شود می‌تواند افزایش GDP را خنثی کند.

۱۲ چیزهای متغیرهای VAR بر اساس تئوری است و بر اساس ذهنیتی که از تئوری می‌آید می‌تواند حس زد که متغیرهای بیرون را کدام است.

یک متغیر اقتصاد ساده را در نظر می‌گیریم که متغیر m_2 ، P ، GDP دارد، به m شوک می‌دهیم و تکرار می‌کنیم که سرعت گردش پول ثابت است $\rightarrow$ لا زیادی می‌شود در مرحله بعدی P بالا می‌رود و رابطه دوباره برقرار می‌گردد.

$$\rightarrow P \Delta y_t = r m_t$$

اثر روی Δ کوتاه مدت روی P بلند مدت است.

«واقع در ذهنیت از لحاظ تئوری برای این سیستم m_2 بیرون زاست و می‌خواهیم اثر شوک m_2 را روی سایر متغیرها ببینیم

لپس چیرمان به صورت $\begin{bmatrix} m_2 \\ GDP \\ P \end{bmatrix}$ است.

داده‌ها نشان می‌دهند که از P و GDP به m_2 Causality وجود ندارد ولی از m_2 به GDP و P causality وجود دارد. حالت‌های خاص را می‌توان بررسی کرد. با چیرمان تخمین VAR «رون زایی تغییر نمی‌کند».

نکته ← اثر Supply shock مثل تکنولوژی بلندمرت است و اثر Demand shock کوتاه مدت است.
R.B.C می‌تواند هیچ شونی در اقتصاد نداشته باشد بجز تکنولوژی.

www.economy.ir

در آلوی VAR، تجزیه و تحلیل آن‌ها را رویداد دارد :

Impulse-response

Variance-Decomposition

نکته سه مساحتی که از آنجا می‌آید و یا $O.I$ باشد چه از طریق ماتریس واریانس و چه از طریق تجزیه مساحت متراپ نتیجه مساحتی برای فرقی می‌باشد

اتراپ آلوی VAR را در نظر می‌گیریم :

$$Y_t = \mu + A Y_{t-1} + u_t \Rightarrow Y_t = \mu + \sum_{i=0}^{\infty} \theta_i u_{t-i} \quad VAR(\infty)$$

$$\Rightarrow Y_{t+h} = \mu + \sum_{i=0}^{\infty} \theta_i u_{t+h-i}$$

$$(Y_{t+h} - Y_t(h)) = \sum_{i=0}^{\infty} \theta_i u_{t+h-i}$$

توان از این عبارت MSE را می‌دهد

* تجزیه واریانس اساساً بر روی خطای پیش‌بینی استوار است

* این روش که مکمل روش Impulse Response است، بحث می‌کند اثر شوک ساختاری به یک از متغیرها انجا می‌کند چنانچه که طرح می‌شود این است که چه سهمی از این شوک مربوط به سایر متغیرها می‌شود و چه سهمی مربوط به خود متغیر می‌شود

* اثر متغیری تغییرات دارد بررسی می‌کنیم سهم تغییرات بر روی خود متغیر و سایر متغیرها چگونه است

* وقتی یک سری را Decompose می‌کنیم در واقع واریانس سری می‌خواهیم ببینیم از 1 تا 1 چه بخشی از تغییرات واریانس مربوط

به خودش و چه بخشی مربوط به سایر متغیرها است (این تجزیه واریانس)

اینجا u داریم که مربوط به R.F است باید تبدیل به شوک ساختاری کرد

$$(Y_{t+h} - Y_t(h)) = \sum_{i=0}^{\infty} \theta_i \underbrace{PD'}_{\phi} \underbrace{\varepsilon_{t+h-i}}_w = \sum_{i=0}^{\infty} \phi_i w_{t+h-i} \quad \neq w = D' \varepsilon_{t+h-i}$$

$$E(\varepsilon_t \varepsilon_t') = DD'$$

$$E(D' \varepsilon \varepsilon' D) = D' E(\varepsilon \varepsilon') D = D' D D' D = I$$

ماتریس واریانس کواریانس w می‌شود

۷. رابطه در متغیر z_t و x_t اختیار کردیم. می خواهیم اثر خودها بر روی z_t را با $\hat{P}$ دوره بررسی کنیم

$$\begin{bmatrix} z_t \\ x_t \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} + \begin{bmatrix} \phi_{11}(L) & \phi_{12}(L) \\ \phi_{21}(L) & \phi_{22}(L) \end{bmatrix} \begin{bmatrix} v_{1t} \\ v_{2t} \end{bmatrix}$$

$$z_t = \mu_1 + \phi_{11}(L) v_{1t} + \phi_{12}(L) v_{2t}$$

$$z_t = \mu_1 + \phi_{11}(L) w_{1t} + \phi_{12}(L) w_{2t}$$

$$(z_{t+h} - z_t(h)) = \phi_{11}(L) w_{1t+h} + \phi_{12}(L) w_{2t+h}$$

$$\Rightarrow z_{t+h} - z_t(h) = \sum_{i=0}^{\infty} \phi_{11,i} w_{1t+h-i} + \sum_{i=0}^{\infty} \phi_{12,i} w_{2t+h-i}$$

$$= \sum_{i=0}^{\infty} (\phi_{11,i} w_{1t+h-i} + \phi_{12,i} w_{2t+h-i})$$

حال اگر k تا متغیر داشته باشیم w $j = 1, \dots, k$

$$y_{j,t+h} - y_{j,t}(h) = \sum_{i=0}^{h-1} (\phi_{j1,i} w_{1t+h-i} + \dots + \phi_{jk,i} w_{kt+h-i})$$

$$\Rightarrow y_{j,t+h} - y_{j,t}(h) = \sum_{k=1}^K (\phi_{jk,0} w_{kt+h} + \dots + \phi_{jk,h-1} w_{k,t+1})$$

توضیح نحوه جایابی sum ها ←

$$\sum_{i=0}^{h-1} (\phi_{j1,i} w_{1t+h-i} + \dots + \phi_{jk,i} w_{kt+h-i}) = \phi_{j1,0} w_{1t+h} + \phi_{j1,1} w_{1t+h-1} + \dots + \phi_{j1,h-1} w_{1,t+1}$$

$$+ \phi_{j2,0} w_{2t+h} + \phi_{j2,1} w_{2t+h-1} + \dots + \phi_{j2,h-1} w_{2,t+1} + \dots$$

$$= \sum_{k=1}^K (\phi_{jk,0} w_{kt+h} + \dots + \phi_{jk,h-1} w_{k,t+1})$$

$MSE = E [y_{j,t+h} - y_{j,t}(h)]^2 = \sum_{k=1}^K (\phi_{j,k,h}^2)$

$\delta_{j,k,h} = \frac{\phi_{j,k,h}^2}{\sum_{k=1}^K \phi_{j,k,h}^2}$

* سهم هر متغیر از تغییرات عبارت است از:

* جمع تمامی این سهم‌ها یک است.

* می‌توان تمامی این سهم‌ها را در طول زمان استخراج کرد.

✓ سوال صفحه 57 کتاب / Lutkepohl : مطالعه شود

یک الگوی کلان ساده داریم به

1) $y_t = C + I + G + X - M$

5) $I = f_4(y_t, r_t)$

2) $C_t = f_1(y_t)$

6) $\frac{M_t}{P_t} = f_5(r_t, y_t)$

3) $X = f_2(\frac{eP^*}{P_t})$

7) $M^s = M^d$

4) $M = f_3(y_t, \frac{eP^*}{P_t})$

اگر بخواهیم از سیستم معادلات استفاده کنیم، ۷ معادله داریم.

اگر به جای تخمین معادلات، یک الگوی VAR بنویسیم، سیستم را بر اساس قیمت می‌نویسیم و قیمت مقادیر وارد الگو می‌شود.

الگوی بزرگ پیش بینی درستی می‌دهد. الگوی VAR به دنبال پیش‌بینی درست است و هم چنین تعیین ساختار.

برای تبدیل کردن به VAR در steady state می‌نویسیم به ترانسجاری $X-M=0$

$\Rightarrow y_t = f_6(\frac{eP^*}{P_t})$

$\Rightarrow X_t = f_7(\frac{eP^*}{P_t}, r_t)$ و $\frac{M^s}{P_t} = f_8(y_t, X_t)$

$y_t = \{y_t, \frac{eP^*}{P_t}, r_t, \frac{M^s}{P_t}\}$

می‌توان G_t را به صورت $G = f(G_{t-1}, \dots)$ وارد کرد.

بدون اینکه هیچ تئوری را وارد کنیم، می توان به یک VAR رسید که بر اساس قیمت ها و متغیرهای $real$ است.

سوال سه: اگر قرار است در VAR هر متغیر را وارد کنیم، تئوری $Miss specification$ چای شود؟

اگر بدون تئوری باشد $Miss specification$ چای شود؟

اگر $Base$ ذهنی یک چهارموب تئوری اقتصاد باشد نه بریت معنی نه تئوری را تحصیل کردیم در چهارموب این

الگو هر متغیری بود را وارد VAR کردیم و تئوری تحصیل نکردیم. می دانیم بر اساس این سیستم هیچ متغیری نسبت

که در سیستم مهم باشد و مادر الگو وارد نکرده باشیم و هیچ توزیعی بین معادلات تحصیل نشده است و باید متغیر رفتار تمام متغیرهای الگو را در نظر گرفت. این VAR تحلیل دقیقتری نسبت به سیستم معادلات بود.

* در VAR به جای اینکه $sector$ را الگو کنیم، بازار به بازار الگوی کنیم. تحلیل ها بر اساس بازار است.

* تمامی شوک های معادلات ۱، ۲، ۳، ۴، ۵ در قالب شوک بازار کالا وارد می شود و به جای وارد شدن می شود، می شود وارد می شود.

شناسایی شوک های بازار پول و کالا است که کمک به شناسایی رفتار کلی می کند، مشکل زمانی است که VAR به خوبی

و شوک بازار پول و کالا را تفکیک نکند و در چهار مشکل شناسایی می کنیم.

$$\log L(A', \Sigma) = -\frac{TK}{2} \log 2\pi + \frac{T}{2} \log |\Sigma|^{-1} - \frac{1}{2} \sum_{t=1}^T \text{tr} (y_t - \hat{A}' x_t) \Sigma^{-1} (y_t - \hat{A}' x_t)'$$

$$\frac{\partial \log L(A', \Sigma)}{\partial \Sigma^{-1}} = \frac{T}{2} \Sigma - \frac{1}{2} \sum_{t=1}^T \hat{u}_t \hat{u}_t' = 0 \Rightarrow \hat{\Sigma} = \frac{\sum_{t=1}^T \hat{u}_t \hat{u}_t'}{T}$$

* آزمون R.F. به این جنبه زینوها رسیدیم.

حال آزمون ما نیز به لایحه ریسیو و LR Test : آزمون محدودیتها میماند

over-Ident, راستای کنیم.

$$\log L(A', \hat{\Sigma}) = -\frac{TK}{2} \log 2\pi + \frac{T}{2} \log |\hat{\Sigma}|^{-1} - \frac{T}{2} \text{tr} \frac{I_K}{\hat{\Sigma}}$$

$$\log L_U(\hat{A}', \hat{\Sigma}) = -\frac{TK}{2} \log 2\pi + \frac{T}{2} \log |\hat{\Sigma}|^{-1} - \frac{TK}{2} \rightarrow \text{unrestricted}$$

$$\log L_R(\hat{A}', \hat{\Sigma}) = -\frac{TK}{2} \log 2\pi + \frac{T}{2} \log |\hat{\Sigma}_R|^{-1} - \frac{TK}{2} \rightarrow \text{restricted}$$

$$2(\log L_R - \log L_U) = T(\log |\hat{\Sigma}_R|^{-1} - \log |\hat{\Sigma}_U|^{-1})$$

$$-2(\log L_R - \log L_U) = T(\log |\hat{\Sigma}_R^{\oplus}| - \log |\hat{\Sigma}_U^{\oplus}|) \quad \chi^2(q)$$

* دارای توزیع χ^2 با q درجه آزادی است. برای خواندن معانی است.

$$\lim_{T \rightarrow \infty} q_f \rightarrow q^2(q) \checkmark$$

به توزیع f مجانباً به توزیع q^2 میل می کند. توزیع f برای نمونه های کوچک است.
 به توزیع f مجانباً به Z میل می کند.

تعیین آمینه و فاصله در VAR به روش آماره LR Test:

$$Y_{1t} = v_1 + \alpha_{11} Y_{1t-1} + \alpha_{12} Y_{2t-1} + \alpha_{13} Y_{1t-2} + \alpha_{14} Y_{2t-2} + v_{1t}$$

VAR(2)

$$Y_{2t} = v_2 + \alpha_{21} Y_{1t-1} + \alpha_{22} Y_{2t-1} + \alpha_{23} Y_{1t-2} + \alpha_{24} Y_{2t-2} + v_{2t}$$

* تست آمینه VAR(1) بهتر است یا VAR(2) ؟

Restricted
Unrestricted > Test

Restricted * متفاوت است یا Unrestricted > VAR

$H_0: \text{VAR}(1)$

$H_1: \text{VAR}(2)$

VAR(2) ← unrestricted
 VAR(1) ← Restricted

(*) به روش کلاسه تعیین بهینه همان کلاسه است.

(*) در دینای واقعی تعیین و فاصله به روش آماره LR Test.

$$\Sigma = PP'$$

$$PD' = P^{-1} \rightarrow P = P^{-1} D$$

$$\rightarrow \Sigma = P^{-1} D D' P^{-1} = P^{-1} \Lambda P^{-1}$$

$$\Sigma^{-1} = (P^{-1} \Lambda P^{-1})^{-1} = P \Lambda^{-1} P'$$

$$\log L(\Lambda, P^{-1}) = -\frac{TK}{2} \log 2\pi - \frac{T}{2} \log |P^{-1} \Lambda P^{-1}| - \frac{1}{2} \sum_{t=1}^T \underbrace{(\underbrace{y_t - \hat{A}' x_t}_{\hat{u}'}')}_{\text{posterior Information}} \underbrace{(P^{-1} \Lambda P^{-1})}_{\text{prior Information}} (\underbrace{y_t - \hat{A}' x_t}_{\hat{u}})$$

34) Structural VAR :

لها اقتصاد سنجی ۲ : 91.9.27 :

Blanchard - Quent :

identification /
یک رویداد

ما می خواهیم اثرات بلند مدت را بر این مدل impose کنیم . $VAR(p)$ $y_t = A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + u_t$

$$\Rightarrow y_t = (A_1 + A_2 L + \dots + A_p L^{p-1}) y_{t-1} + u_t \Rightarrow y_t = A(L) y_{t-1} + u_t \Rightarrow (I - A(L)) y_t = u_t$$

$$\Rightarrow y_t = \longrightarrow u(L) C(L)^{-1} \Rightarrow \boxed{y_t = C^{-1}(L) \cdot u(L)} \Rightarrow y_t = C^{-1}(L) G(L) \varepsilon_t$$

اثرات بلند مدت :

(یعنی اثرات یک شوک در کوتاه مدت صفر است)

$C^{-1}(L) G \leftarrow$ را باید بدست آورد . $C^{-1}(L)$ را از تعین VAR بدست می آوریم و چنانکه می دانستیم G را بدست می آوریم .

$$C^{-1}(L) \hat{\Sigma} C^{-1}(L) = W$$

$$W = C^{-1}(L) G \cdot G' \cdot C^{-1}(L)$$

$$* G \leq p^{-1}$$

اثر بلند مدت $\rightarrow$

$$W = \begin{bmatrix} w_{11} & 0 \\ w_{21} & w_{22} \end{bmatrix} \begin{bmatrix} w_{11} & w_{21} \\ 0 & w_{22} \end{bmatrix}$$

۲۳/۴۲

۸/۴/۱۵

من و هم
لری و زری و ماه

$$\begin{bmatrix} 1 - \sum a_{12,i} & -\sum a_{11,i} \\ -\sum a_{21,i} & 1 - \sum a_{22,i} \end{bmatrix} \begin{bmatrix} g_{11} & g_{12} \\ g_{21} & g_{22} \end{bmatrix} \begin{bmatrix} \varepsilon_{1t} \\ \varepsilon_{2t} \end{bmatrix}$$

$$g_{12}(1 - \sum a_{22,i}) - g_{21} \sum a_{11,i} = 0$$

$$\rightarrow C(L) \cdot C^{-1}(L) \cdot G = G$$

$$\Delta y_{t-2} = y_{t-2} - y_{t-3} \Rightarrow \Delta y_{t-2} = y_{t-1} - \Delta y_{t-1} - y_{t-3}$$

$$\Rightarrow y_{t-3} = y_{t-1} - \Delta y_{t-1} - \Delta y_{t-2}$$

$$\Rightarrow \Delta y_t = (A_1 + A_2 + A_3 - I) y_{t-1} - (A_2 + A_3) \Delta y_{t-1} - A_3 \Delta y_{t-2} + v_t$$

$$\Rightarrow \Delta y_t = \pi y_{t-1} + \pi_1 \Delta y_{t-1} + \pi_2 \Delta y_{t-2} + v_t$$

له بردار y_{t-1} π Δy_{t-1} Δy_{t-2} v_t

$$\pi = A_1 + A_2 + A_3 - I$$

→ Vector Error Correlation Model

له با difference گرفتن، وقفه را یک دوره کم کرد.

تمام تحلیلها بر روی ماتریس π $p \times p$ صورت می گیرد.

حالت اول:

در تست ADF اگر $\phi = 0$ باشد، متغیرها non-stationary بودند و اینجاست چون π ماتریس است باید از رتبه

استفاده کنیم. اگر رتبه π برابر صفر باشد، یعنی تمام مقادیر ویژه آن برابر یک است، یعنی در واقع تمام مقادیر ویژه ماتریس

A_1, A_2, A_3, I یک است. و تمام ترکیب های خطی $I(1)$ هستند. $(p(\pi) = 0)$.

اگر ترکیب خطی دو متغیر $I(1)$ هستند، $I(2)$ باشد $cointegration$ وجود دارد.

در واقع مقادیر ویژه همان ϕ هست که اگر $\lambda = 0 = 1$ باشد نامتناهی شود.

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

$$\begin{bmatrix} y_t \\ y_{t-1} \end{bmatrix} = \begin{bmatrix} \phi & 0 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ y_{t-2} \end{bmatrix} + \begin{bmatrix} \varepsilon_t \\ 0 \end{bmatrix} \Rightarrow \begin{matrix} \lambda = \phi \\ \lambda = 0 \end{matrix}$$

نکته: اگر $p(\pi) = 0$ هیچ ترکیب خطی میان متغیرها وجود ندارد که $I(2)$ برود در واقع تبدیل به VAR Sims می شود و می توان از difference استفاده کرد و با این کار اطلاعاتی در بلندمدت وجود ندارد که از دست ببریم.

حالت دوم

اگر $p(\pi) = \text{Full Rank}$ باشد، یعنی تمام متغیرها Stationary هستند و تمامی $k \times 1$ است و وقتی هم نامنا هستند در واقع

رابطه بلندمدتی نداریم. زمانی رابطه بلندمدت داریم که متغیرها نامنا باشند و ترکیب خطی آنها $I(0)$ باشد، به

صورت معمولی دارد VAR می گویند، تمامی ترکیبهای خطی متغیرها $I(0)$ هستند.

حالت سوم: حالتی است که در آن رتبه ماتریس π نه Full Rank است و نه صفر. یعنی در واقع $0 < p(\pi) < p$

می باشد. در این حالت یعنی متغیرها با هم cointegrate هستند و برخی نیستند و در واقع Full Rank نیستند و

Reduce Rank است و $p(\pi) = r$ و $0 < r < p$.

Reduce rank یعنی ترکیب خطی بعضی از متغیرها cointegrate هستند و برخی نیستند.

در واقع اساس فکری Johansen بر روی این شکل می گیرد که ترکیب خطی برخی متغیرها $I(1)$ و برخی $I(0)$

است.

در این روش می توانا بررسی کرد ۸ (۱) چقدر است.

۱۲ ضرایب بلندمدت و کوتاه مدت را جدا کرد. (تخمین ضرایب بلندمدت و کوتاه مدت).

۱۳ چند بردار هم نمیشود داریم ← cointegrated vector.

Reduced Rank Regression (RRR)

به بررسی حالت دوم می پردازیم:

اینه اصلی اینست که ابتدا π را به خط بندی کنیم و به عبارتی به صورت زیر تعریف می کنیم:

$$Z_t = \Delta y_t$$

$$Z_{t+1} = \Delta y_{t+1}$$

$$\Psi Z_t = \sum_{i=1}^{k-1} \pi_i \Delta y_{t+i}$$

$$\Rightarrow \Delta y_t = \pi y_{t-1} + \sum_{i=1}^{p-1} \pi_i \Delta y_{t+i} + v_t$$

$$\Rightarrow Z_t = \pi Z_t + \Psi Z_t + v_t \Rightarrow \boxed{Z_t = \alpha B' Z_t + \Psi Z_t + v_t}$$

* Canonical correlation سه قوت ترست همبستگی میان دو اکت را گویند. همبستگی میان دو مجموعه به سزات مقادیر ویژه هستند دار.

$$\pi = \alpha B' \quad \text{px rpx}$$

اگر یک ماتریس درتصیف Reduced Rank باشد. RRR میگوید که π را می توان به دو ماتریس انزال کرد.

که ماتریس α و B یکتا نیستند.

و مشاهده می کنیم که B ضرایب بلند مدت و α ضرایب تقریل کوتاه مدت است.

برای بررسی correlation میان Z_t و Z_{t+1} باید Z_{t+1} را از این دو جزئی کنیم.

$$Z_{t+1} = \alpha B' Z_t + \Psi Z_t \quad (1)$$

ماتریسی مانند M_{12} و ... داریم. رانقرت می کنیم.

$$M_{12} = T^{-1} \sum Z_{t+1} Z_t'$$

می توان از رابطه دیگر Ψ را برصفت کرده با توجه به داشت M_{12} .

طریقی رابطه را در Z_t ضرب می کنیم، sum می گیریم و در T^{-1} ضرب می کنیم به رابطه زیر می رسمیم.

$$\Rightarrow M_{02} = \alpha B' M_{12} + \Psi M_{22} \Rightarrow \boxed{\Psi = M_{02} M_{22}^{-1} - \alpha B' M_{12} M_{22}^{-1}}$$

هدف خالص کردن Z_t و Z_{2t} از Z_{1t} است تا cointegration آنها را به طور دقیق‌تر پیدا کنیم.

پس با داشتن مقدار ψ می‌توان به سمان R را بدست آوردیم که در تیر داخل آن Z_{2t} نوشته باشیم.

بسیار نزدیک به خالص کردن Z_{2t} از Z_{1t} $\Rightarrow$

$$\begin{cases} R_{1t} = Z_{1t} - M_{21} M_{22}^{-1} Z_{2t} \\ R_{2t} = Z_{2t} - M_{12} M_{22}^{-1} Z_{2t} \end{cases}$$

$$\Rightarrow R_{1t} = \alpha' B' R_{2t} + \varepsilon_t \quad R.R.R$$

* دو سمت دارد ضریب اول مربوط به Z_{1t} و ضریب دومی مربوط به Z_{2t} است.

$$\Rightarrow (Z_{1t} - M_{21} M_{22}^{-1} Z_{2t}) = \alpha' (Z_{2t} - M_{12} M_{22}^{-1} Z_{2t}) + \varepsilon_t \quad * \quad R.R.R$$

* رابطه 1 یک سیستم غیر خطی بر روی تغییرهاست و می‌توان آنها را بدست آورد چون رابطه غیر خطی است.

ابتدا با فرض given بودن α ، B را بدست آورده و سپس با بدست آوردن α ، B را بدست می‌آوریم. معمولاً این دو تکرار

یک روش 4 مرحله‌ای است.

$$\log L(\alpha, B', \lambda, \psi) = -\frac{T}{2} \log |\lambda| - \frac{1}{2} \sum_{t=1}^T (Z_{1t} - \alpha' B' Z_{2t} - \psi Z_{2t})' \lambda^{-1} (Z_{1t} - \alpha' B' Z_{2t} - \psi Z_{2t})$$

$$T^{-1} \sum Z_{1t} Z_{1t}' = M_{11}$$

$$T^{-1} \sum Z_{1t} Z_{2t}' = M_{12} \Rightarrow * \log L = -\frac{T}{2} \log |\lambda| - \frac{1}{2} \left\{ \text{tr} \sum Z_{1t} \lambda^{-1} \psi Z_{2t}' + \text{tr} \sum Z_{2t} B \alpha' \lambda^{-1} \psi Z_{2t}' \right.$$

$$T^{-1} \sum Z_{2t} Z_{2t}' = M_{22}$$

$$\left. - \text{tr} \sum Z_{2t} \psi' \lambda^{-1} Z_{1t}' + \text{tr} \sum Z_{2t} \psi' \lambda^{-1} \alpha' B' Z_{2t}' + \text{tr} \sum Z_{2t} \psi' \lambda^{-1} \psi Z_{2t}' \right\}$$

$$\Rightarrow -\frac{1}{2} \left\{ \text{tr} \psi M_{12} \lambda^{-1} + \text{tr} \psi M_{12} B \alpha' \lambda^{-1} - \text{tr} \psi' \lambda^{-1} M_{22} + \text{tr} \psi' \lambda^{-1} \alpha' B' M_{22} + \text{tr} \psi' \lambda^{-1} \psi M_{22} \right\}$$

$$\frac{\partial \text{Log} L}{\partial \psi} = 0 \Rightarrow -\bar{\lambda}' M_{02} + \bar{\lambda}' \alpha B' M_{12} - \bar{\lambda}' M_{02} + \bar{\lambda}' \alpha B' M_{12} + 2 \bar{\lambda}' \psi M_{22} = 0$$

$$\Rightarrow -M_{02} + \alpha B' M_{12} + \psi M_{22} = 0 \Rightarrow \hat{\psi} = M_{02} M_{22}^{-1} - \alpha B' M_{12} M_{22}^{-1}$$

$$\text{Log} L(\alpha, B, \lambda) = -T/2 \log |M| - 1/2 \sum_{t=1}^T (R_{0t} - \alpha B' R_{1t})' \bar{\lambda}^{-1} (R_{0t} - \alpha B' R_{1t})$$

$$T^{-1} \sum R_{0t} R_{1t}' = S_{01}$$

$$* -\frac{1}{2} \left\{ \text{tr} \alpha B' S_{01} \bar{\lambda}^{-1} - \text{tr} \alpha \bar{\lambda}^{-1} S_{10} B + \text{tr} \alpha' \bar{\lambda}^{-1} \alpha B' S_{11} B \right\}$$

$$\frac{\partial \text{Log} L}{\partial \alpha} = 0 \Rightarrow -\bar{\lambda}^{-1} S_{01} B - \bar{\lambda}^{-1} S_{10} B + 2 \bar{\lambda}^{-1} \alpha B' S_{11} B = 0$$

$$\Rightarrow S_{01} B = \alpha B' S_{11} B \Rightarrow \hat{\alpha} = (S_{01} B) (B' S_{11} B)^{-1}$$

$$2) \frac{\partial \text{Log} |A|}{\partial A} = A^{-1}$$

$$1) \frac{\partial \text{tr}(AB)}{\partial A} = B' \quad \text{utili!}$$

$$3) \frac{\partial \text{Log} |A'|}{\partial A} = A$$

$$4) \frac{\partial \text{tr} A^{-1} B}{\partial A} = -B'$$

$$\text{Log } L = T/2 \log |\hat{\Sigma}| - 1/2 \sum^T \text{tr } \hat{\Sigma}^{-1} (R_{it} - \alpha B' R_{it})' (R_{it} - \alpha B' R_{it})$$

$$\frac{\partial \text{Log } L}{\partial \alpha} = T/2 \cdot 1 - 1/2 \sum^T (R_{it} - \alpha B' R_{it})' (R_{it} - \alpha B' R_{it})$$

$$\Rightarrow \hat{\Sigma} = T^{-1} \sum^T (R_{it} - \alpha B' R_{it})' (R_{it} - \alpha B' R_{it})$$

$$\Rightarrow \hat{\Sigma} = S_{00} - S_{01} B' - \alpha B' S_{10} + \alpha B' S_{11} B \alpha'$$

$$\hat{\Sigma} = S_{00} - S_{01} B (B' S_{11} B)^{-1} B' S_{10}$$

باجا بکزاری و در رابطه بالا به عبارت زیر می رسیدیم

$$\Rightarrow \hat{\Sigma} = S_{00} - S_{01} B (B' S_{11} B)^{-1} B' S_{10}$$

$$|\hat{\Sigma}| = \begin{vmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{vmatrix} = |\Sigma_{11}| \left| \Sigma_{22} - \Sigma_{21}^{-1} \Sigma_{12} \right| = |\Sigma_{22}| \left| \Sigma_{11} - \Sigma_{12}^{-1} \Sigma_{21} \right|$$

$$\Rightarrow \begin{vmatrix} S_{00} & S_{01} B \\ B' S_{10} & B' S_{11} B \end{vmatrix} = |S_{00}| \left| B' S_{11} B - S_{01} B (S_{00})^{-1} B' S_{10} \right| = |B' S_{11} B| \left| S_{00} - S_{01} B (B' S_{11} B)^{-1} B' S_{10} \right|$$

$$\Rightarrow \left| S_{00} - S_{01} B (B' S_{11} B)^{-1} B' S_{10} \right| = \frac{|S_{00}| \left| B' S_{11} B - S_{01} B (S_{00})^{-1} B' S_{10} \right|}{|B' S_{11} B|}$$

هدف Max کردن Liklihood است و یک Duality است مثل اینکه ماتریس واریا فنس - کواریانس

را Min کنیم

$T\hat{\Sigma} = \text{tr} \sum (R_t - \alpha B'R_t)(R_t - \alpha B'R_t)'$ $\log L$ مترادفیم و چون

$\Rightarrow \log L = -T/2 \log |\Sigma| - T/2 \text{tr} I \Rightarrow \log L = -T/2 \log |\Sigma| - \frac{TP}{2}$

* Min کردن از معادل Max کردن Liklihood است

* B باید چنان باشد که ماتریس مترادف از آن، معین گردد.

* مرحله اول هدف بدست آوردن α و از بود و مرحله دوم بدست آوردن Σ به نحوی است که L را Max و Σ را Min کند. B ثابتی است که co-integrate vector را می دهد.

Lemma 1

اگر دو ماتریس متقارن $N_{p \times p}$ و $M_{p \times p}$ را در نظر بگیریم که اولی معین مثبت و دومی معین مثبت باشد
حل معادله $|N-M|=0$ در واقع مقادیر ویژه ای را می دهد که بر اساس آن مقادیر ویژه می توانیم به صورت زیر بایست؟
 $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_p \rightarrow$ λ ها بر اساس مقادیر مرتب شده اند.

خواهیم که بتوان استخراچ کرد به صورت زیر است

1) $\lambda_i N V_i = M V_i \rightarrow$ بردار ویژه مربوط به λ_i

2) $V_i' N V_i = I$, $V_i' M V_i = D$ و λ_i یک ماتریس قطری است که در آن مقادیر ویژه قرار دارند.

Lemma 2: یا متریک ماتریس های M و N به صورت قبل، نسبت زیربر اساس بزرگترین مقادیر ویژه λ_1 و بردار ویژه

$$\frac{X'MX}{X'NX}$$

λ_1 که از حل $|h; N-M|=0$ حاصل می شود، Max می شود.

X یک بردار PXI است.

λ_1 که بر اساس λ_1 ، Max درست آمد در واقع همان λ است.

اولین λ ، h_1 و دومی h_2 ... این روش می تواند ادامه داشته باشد تا جا تنگ ارتباط وجود داشته باشد.

X ← بردار ویژه بر اساس بزرگترین λ است که نیتا نیست.

* می خواهیم $\sum \lambda$ را min کنیم که برابر است با $\frac{\sum (R_{it} - \alpha B' R_{it})(R_{it} - \alpha B' R_{it})}{T}$ و می خواهیم

correlation residual را درست اگر λ به رابطه یا نسبت $\frac{X'MX}{X'NX}$ می رسمیم.

$|A - \lambda I| = 0$ سه مقدار رفتار مقادیر ویژه A را نشان می دهد، λI اطلاعاتی ندارد.

λ و correlation در set است. قوی ترین correlation بر اساس بزرگترین λ که $|N-M|=0$

Lemma 3: $\max \left| \frac{B'MB}{B'NB} \right|$ زمانی حاصل می شود که رابطه $\frac{r}{\pi} h_1$ Max گردد که جرات B حاصل

$B = (v_1, \dots, v_r)$ بردارهای ویژه است ←

در واقع r مقدار λ های بزرگ و معنی دار است که λ ها از حل $|h; N-M|=0$ حاصل می شود است ← $h_1 > h_2 > \dots > h_p$

B یک ماتریس Reduced Rank است که ابعاد آن $P \times r$ است و نیتا نیست.

$$N = S_{11} \quad r \quad M = S_{11} - S_{10}(S_{00})^{-1}S_{01}$$

$$\Rightarrow |PS_{11} - (S_{11} - S_{10}(S_{00})^{-1}S_{01})|$$

47/ * در تمامی مواردی خواستیم Max کنیم ولی اینجا می خواهیم Min کنیم. در این حالت $p=1-h$ است و باید Min کنیم.

$$\Rightarrow |(1-h)s_{11} - (s_{11} - s_{10}(s_{10}^T s_{11})^T)| = |hs_{11} - s_{10}(s_{10}^T s_{11})^T| = 0$$

ما را برداریم / که با توجه به h ها ، ما را برداریم و بر اساسی رابط $\prod_{i=1}^r f_{i,r}$ سوال سازی

انجام می شود

Maximum Likelihood Ratio Test و (LR)

واریانس ناهمبستگی شرطی (AR) : Auto regressive Conditional Heteroscedasticity (ARCH)

این کار را اولین بار Engle در سال 1982 ارائه کرد. ارائه نظری این رویکرد بازار مالی را تحت تأثیر قرار داد.
و تبدیل به ابزار قدرتمندی برای اندازه گیری ریسک و پیش بینی ریسک شده است.

در بازارهای مثل بازار نفت، تنوع تقاضا و عرضه تعیین کننده قیمت است. بلکه بورس بازهای هستند که می توانند در قیمت تأثیر بگذارند.
و بحث اصلی این است که چه عواملی باعث تغییر قیمت می شود. در واقع می توان دریافت که در صورتی که اثر بلندمدت مربوط به عرضه و تقاضا و اثر کوتاه مدت مربوط به بورس بازار می شود.
در بورس زمان بسیار مهم است، تغییرات آن برای تحلیل بازار بسیار مهم است و حجم معاملات روزانه است که می توان قیمت را در کوتاه مدت تحت تأثیر قرار داد. اما در مورد عرضه و تقاضا بلندمدت مطرح است و متغیرهای مطرح می شوند.


آیا قیمت تقلبی وجود دارد؟ و به چه صورت تعیین می شود؟
تبادل یک مفهوم تقلبی است و مازاد فضای تقلبی داریم و زمانه بازار تقلبی است مازاد فضای تقلبی داریم. کمین.
تبادل آماری به جای تقلب قطعی مطرح می شود. cointegrate بودن و I(0) بودن به معنای تقلب است و در یک بازه تبادل مطرح می شود و نه در یک نقطه. در واقع منظور از تقلب در فضای تقلبی است که stationary.

عمر می کمین قیمت stock market را به صورت روزانه داریم و می خواهیم پیش بینی کنیم. با روش های مختلفی می توان این کار را انجام داد. تقریباً ARIMA.

می تونیم مهم قیمت بکنیم واریانس مهم است و ریسک مطرح می شود. دنبال روشی هستیم که نوسانات را بررسی کند.
منظور از fluctuation به تغییرات می تونیم است.
منظور از Validity به تغییرات واریانس است.

ARCH می‌خواهیم آلتو بررس کنیم که بتواند ریسک را بررسی و پیش‌بینی کند.

متغیری مثل قیمت، تورم و... را در نظر می‌گیریم



$$Y_t = \alpha + \beta Y_t + U_t$$

در Time Series راریابی داده‌ها را ثابت در نظر می‌گیریم.

$$E(U_t^2) = \sigma^2$$

راریابی غیر متغیری

Engle مطرح می‌کند که اگرچه راریابی غیر متغیری ثابت است اما مستقیماً مستویاً خوشه‌ها خوشه‌ها راریابی از یک دوره به دوره دیگر

به صورت conditional تغییر پیدا می‌کند.

در واقع راریابی دوره قبل conditional می‌شود برای دوره بعد.

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + U_t \quad U_t \sim i.i.d. N(0, \sigma^2)$$

شرط ثابت این است که ریشه‌ها باید داخل دایره واحد قرار گیرند (ریشه‌ها 2 خارج از دایره واحد باشند).

$$|1 - \phi_1 z - \phi_2 z^2 - \dots - \phi_p z^p| = 0$$

که U_t^2 خوشه‌ها می‌تواند یک فرآیند AR باشد.

$$U_t^2 = \alpha_0 + \alpha_1 U_{t-1}^2 + \dots + \alpha_m U_{t-m}^2 + \varepsilon_t \quad \varepsilon_t \sim i.i.d. (0, \sigma^2)$$

$$E(U_t^2 | U_{t-1}^2, \dots, U_{t-m}^2) = \alpha_0 + \alpha_1 U_{t-1}^2 + \alpha_2 U_{t-2}^2 + \dots + \alpha_m U_{t-m}^2$$

$$\Rightarrow U_t^2 = \alpha_0 + \alpha_1 U_{t-1}^2 + \alpha_2 U_{t-2}^2 + \dots + \alpha_m U_{t-m}^2 + \varepsilon_t, \quad \varepsilon_t \sim i.i.d. (0, \sigma^2) \quad \text{ARCH}$$

می‌دانیم ϵ_t مثبت است چون تمام ϵ_t ها دارای توان ۲ هستند.

$$1 - \alpha_1 z - \alpha_2 z^2 - \dots - \alpha_m z^m = 0$$

با بررسی محدودیت‌هایی اعمال کنیم که حتماً مثبت است. باید تمامی ضرایب مثبت باشد.

$$1) \sum \alpha_i > 0$$

$$2) -\sum \alpha_i = \epsilon_t$$

۱) ϵ_t نباید از ϵ_t کوچکتر باشد

$$3) \alpha_1 + \alpha_2 + \dots + \alpha_m < 1 \rightarrow$$

stability شرط

$$u_t = \sqrt{h_t} \epsilon_t$$

$$\epsilon_t \sim N(0,1)$$

تبدیل دیگری از ARCH که عمومی‌تر است

$$h_t = E(\epsilon_t^2 | \epsilon_{t-1}^2, \epsilon_{t-2}^2, \dots, \epsilon_{t-m}^2) = \omega + \alpha_1 \epsilon_{t-1}^2 + \dots + \alpha_m \epsilon_{t-m}^2$$

ARCH(m)

$$\Rightarrow \epsilon_t^2 = h_t \epsilon_t^2 \rightarrow E(\epsilon_t^2) = h_t E(\epsilon_t^2) = h_t$$

h_t ← ریسک بازاری است.

در این سیستم از α_1 تا α_m را با برآورد نبریم و هیچ اطلاعاتی از h_t نداریم. برای برآورد h_t باید ϕ_1 تا ϕ_p را تخمین نبریم و پس از آن برآورد h_t را برآورد می‌کنیم. اما در مورد واریانس دیگری اطلاعاتی نداریم و برآورد h_t را با استفاده از MLE برآورد می‌کنیم. h_t تابعی از ϵ_t ها به توان ۲ می‌باشد.

$$\log L = -\frac{T}{2} \log 2\pi - \frac{T}{2} \log h_t - \frac{1}{2h_t} (\epsilon_t - c - \phi_1 \epsilon_{t-1} - \dots - \phi_p \epsilon_{t-p})^2$$

با برآورد h_t واریانس h_t نسبت به پارامترهای ϕ_1 تا ϕ_p نبریم.

h_t خودش تابعی از α و ϕ و یک فرآیند غیرخطی است.

$$h_t = \omega + \alpha_1 (\epsilon_{t-1} - c - \phi_1 \epsilon_{t-2} - \dots - \phi_p \epsilon_{t-p})^2 + \dots + \alpha_m (\epsilon_{t-m} - c - \phi_1 \epsilon_{t-m-1} - \dots - \phi_p \epsilon_{t-m-p})^2$$

ابتداءً حل جبری از ϕ_1 تا ϕ_p که از h_t برآورد می‌کنیم. در نتیجه α_1 تا α_m را برآورد می‌کنیم. در L تخمین

از α_1 تا α_m نیاز داریم تا با h_t داشته باشیم h_t را برآورد می‌کنیم. در h_t نشان می‌دهد که به Max

نزدیک شده است یا نه و این خنثی را ادامه می یابد تا به Max likelihood برسد.

$$\theta_i^{t+1} = \theta_i^t + \left(\frac{\partial \log L_i}{\partial \theta_i} \right) \left(\frac{\partial^2 \log L_i}{\partial \theta_i \partial \theta_i'} \right)^{-1}$$

$$\Rightarrow \theta = (\theta_i, \alpha)$$

به طور معمول تا جایی ادامه می دهیم تا به

$$|\theta_i^{t+1} - \theta_i^t| < \delta$$

www.economya.ir

Generalized Autoregressive conditional heteroscedasticity:

$$h_t = \sum + \pi(L) u_t^2$$

$$\pi(L) = \sum \pi_i L^i, \quad \pi(L) = \frac{\alpha(L)}{1 - \delta(L)} \rightarrow \text{بج طور کے ساتھ اس کا انا}$$

$$\alpha(L) = \alpha_1 L + \alpha_2 L^2 + \dots + \alpha_m L^m$$

$$\delta(L) = \delta_1 L + \delta_2 L^2 + \dots + \delta_q L^q$$

$$* u_t^2 = h_t + \varepsilon_t$$

جوں تصدیق سے اس کا انا
میں m درجہ کی گریڈ

$$* h_t = \sum + \frac{\alpha(L)}{1 - \delta(L)} u_t^2 \Rightarrow (1 - \delta(L)) h_t = \sum (1 - \delta(L)) + \alpha(L) u_t^2$$

$$\Rightarrow h_t = K + \delta(L) h_t + \alpha(L) u_t^2$$

$$\Rightarrow h_t = K + \alpha_1 u_{t-1}^2 + \dots + \alpha_m u_{t-m}^2 + \delta_1 h_{t-1} + \delta_2 h_{t-2} + \dots + \delta_q h_{t-q} *$$

$$\Rightarrow h_t + u_t^2 = K + \alpha_1 u_{t-1}^2 + \dots + \alpha_m u_{t-m}^2 + \delta_1 h_{t-1} + \dots + \delta_q h_{t-q} + u_t^2$$

$$\Rightarrow h_t + u_t^2 = K + \alpha_1 u_{t-1}^2 + \dots + \alpha_m u_{t-m}^2 + \delta_1 u_{t-1}^2 + \dots + \delta_q u_{t-q}^2 - [\delta_1 u_{t-1}^2 + \dots + \delta_q u_{t-q}^2] + \delta_1 h_{t-1} + \dots + \delta_q h_{t-q} + u_t^2$$

$$\Rightarrow h_t + u_t^2 = K + (\alpha_1 + \delta_1) u_{t-1}^2 + \dots + (\alpha_r + \delta_r) u_{t-r}^2 + [\delta_1 u_{t-1}^2 + \dots + \delta_q u_{t-q}^2] + \delta_1 h_{t-1} + \dots + \delta_q h_{t-q} + u_t^2$$

$$\rightarrow r = \max\{m, q\}$$

$$\Rightarrow h_t + u_t^2 = K + (\alpha_1 + \delta_1) u_{t-1}^2 + \dots + (\alpha_r + \delta_r) u_{t-r}^2 + \delta_1 (h_{t-1} - u_{t-1}^2) + \dots + \delta_q (h_{t-q} - u_{t-q}^2) + (u_t^2 - h_t)$$

E GARCH :

به عنوان اطلاعات به صورت نامتوازن است

یعنی اثری که به خبر خوب دارد برابر نیست با اثری که به خبر بد دارد.

اثر asy را می بیند $\rightarrow$

$$\log h_t = \omega + \sum_{j=1}^{\infty} \alpha_j \left\{ |u_{t-j} - E(u_{t-j})| + \delta u_{t-j} \right\} + \varepsilon u_{t-j}$$

به اثر asy -metric قراریم $\Rightarrow v_t > 0$ و $\delta < 0$ اثر

اثر خبر خوب و بد متفاوت خواهد بود $\Rightarrow \delta < 0$ اثر

اثر تسهیلگری اثر $\Rightarrow \delta < 0$ اثر

اثر راکاهشی اثر $\Rightarrow \delta > 0$ اثر

Multi Variate - Arch - mean - Asy

اثر شتابهای مثبت و منفی را با هم ترکیب می کند $\rightarrow$ ARCH
و اثر منوالی و کسالت به معنی $Symmetry$ است.