

Stationaarisen VAR-mallin teoriaa

Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen

- Rajoittamattoman mallin tapauksessa residuaalien määritelmä on

$$\hat{\varepsilon}_t = y_t - \hat{v} - \hat{A}_1 y_{t-1} - \cdots - \hat{A}_p y_{t-p}, \quad t = 1, \dots, T.$$

- Jos malli on oikein spesifioitu, tulisi residuaalien muistuttaa ominaisuuksiltaan teoreettisia virheitä ε_t .
- Tämän tarkistamiseksi kannattaa ensiksi piirtää residuaalisarjojen kuvat ja tutkia
 - löytyykö poikkeavia residuaaleja tai residuaaliryhmiä,
 - varianssin vaihtelua tai muita selviä systemaattisia piirteitä.
 - Myös residuaalien normaalisuutta on hyvä tutkia, vaikka mallin asymptoottinen estimointi- ja testiteoria ei normaalisuutta vaadikaan (iid-oletus riittää).

Stationaarisen VAR-mallin teoriaa

Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen

- Residuaalien auto- ja ristikorreloituneisuutta voidaan tutkia laskemalla residuaalisarjoista auto- ja ristikorrelaatiofunktiot.
- Jos teoreettisille virheille pätee $\varepsilon_t \sim \text{iid}(0, \Omega)$, ovat residuaalien auto- ja ristikorrelaatioestimaattorit asymptoottisesti normaalisia odotusarvona nolla.
- Toisin kuin teoreettisten virheiden tapauksessa residuaaleista estimoidut auto- ja ristikorrelaatiot eivät ole asymptoottisesti riippumattomia eikä $N(0, 1/T)$ -jakauma-approksimaatio ole pätevä.
- Oikea asymptoottinen jakauma tunnetaan ja jotkut tietokoneohjelmat tulostavat niihin perustuvat asymptoottiset keskivirheet, joiden avulla residuaaleista estimoitujen auto- ja ristikorrelaatioiden suuruutta voidaan arvioida.

Stationaarisen VAR-mallin teoriaa

Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen

- Residuaalien mahdollisen auto- ja ristikorreloituneisuuden tutkimisessa voidaan käyttää apuna myös tilastollisia testejä.
- Ns. *pormanteau-testi* perustuu suoraan residuaalien auto- ja ristikorrelaatiofunktioihin.
- Eräs versio testisuureesta on

$$Q_K^* = T^2 \sum_{k=1}^K \frac{1}{T-k} \text{tr} (S_k' S_0^{-1} S_k S_0^{-1}), \quad S_k = \sum_{t=1}^{T-k} \hat{\varepsilon}_t \hat{\varepsilon}_{t+k}'.$$



Jos rajoittamattomassa VAR(p)-mallissa $\varepsilon_t \sim \text{iid}(0, \Omega)$, niin

$$Q_K^* \underset{as}{\sim} \chi_{n^2(K-p)}^2.$$

- Rajoitetussa mallissa, vapausasteluku = $n^2 K - \text{VAR-parametrien lukumäärä}$ eli $n^2 K - \dim(\delta)$.
- Asymptoottinen tulos edellyttää lisäksi, että K on "suuri".

Stationaarisen VAR-mallin teoriaa

Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen



Kuvio 1.1. Euron ja Yhdysvaltojen dollarin välisen kuukausittaisen vaihtokurssin (euro/U.S. dollari) muutos (vasemalla) ja euroalueen ja Yhdysvaltojen 10 vuoden valtioiden obligaatioiden kesikorkojen ero (oikealla) ajanjaksona 1999I - 2009XI.

Stationaarisen VAR-mallin teoriaa


Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen

Kuvion 1.1. aineistolle estimoitu VAR(2)-malli

$$\begin{bmatrix} dexch_t \\ rdif_t \end{bmatrix} = \begin{bmatrix} -0.002 \\ (0.002) \\ 0.004 \\ (0.014) \end{bmatrix} + \begin{bmatrix} 0.418 & 0.023 \\ (0.089) & (0.012) \\ -0.187 & 1.144 \\ (0.672) & (0.090) \end{bmatrix} \begin{bmatrix} dexch_{t-1} \\ rdif_{t-1} \end{bmatrix} \\ + \begin{bmatrix} -0.178 & -0.026 \\ (0.087) & (0.012) \\ 0.603 & -0.179 \\ (0.659) & (0.089) \end{bmatrix} \begin{bmatrix} dexch_{t-2} \\ rdif_{t-2} \end{bmatrix} + \begin{bmatrix} \hat{\varepsilon}_{1t} \\ \hat{\varepsilon}_{2t} \end{bmatrix}.$$

Stationaarisen VAR-mallin teoriaa

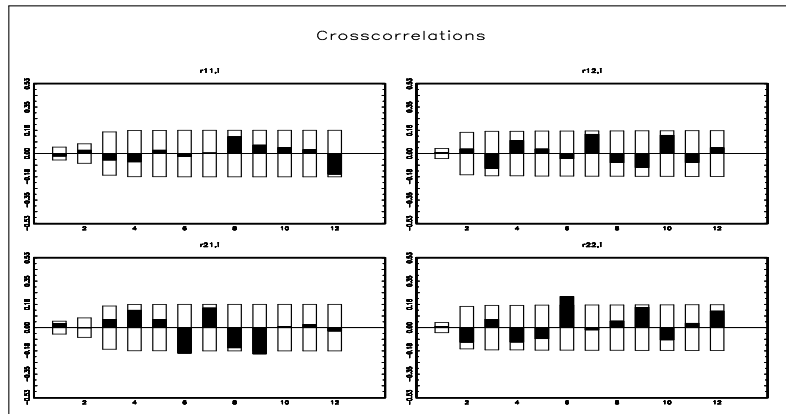
Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen



Kuvio 4.2. (i) Kuvion 1.1. aineistolle estimoidun VAR(2)–mallin residuaalit (vasemmalla $\hat{\varepsilon}_{1t}$ ja oikealla $\hat{\varepsilon}_{2t}$).

Stationaarisen VAR-mallin teoriaa

Mallinvalinta ja valitun mallin sopivuuden tutkiminen residuaaleja käyttäen



Kuvio 4.2. (ii) Kuvion 1.1. aineistolle estimoidun VAR(2)-mallin residuaaleista lasketut auto- ja ristikorrelaatiofunktiot.

Valkoiset pylväät osoittavat kriittiset rajat ($\pm 2 \times$ likimääräinen keskivirhe, kun $\varepsilon_t \sim \text{iid}(0, \Omega)$).

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus: Yleinen määritelmä

- Miten voitaisiin määritellä kausaalisuus reaaliarvoisesta muuttujasta x reaaliarvoiseen muuttujaan z ?
- Kausaalisuudelle on ilmeisesti välttämätöntä, ettei syytapahtuma tapahdu seurauksen jälkeen.
- Jos muuttuja x on muuttujan z syy, täytyisi muuttujasta x olla siten hyötyä ennustettaessa muuttujaa z .
- Tarkastellaan seuraavaksi kahta *reaaliarvoisia* stokastista prosessia x_t ja z_t ja z_t :n tulevien arvojen ennustamista ajankohtana t .
- Olkoon \mathcal{F}_t hypoteettinen muuttujajoukko (tai informaatiojoukko), joka x_t :n lisäksi sisältää kaikki relevantit muuttujat, jotka ajankohtana t voivat tulla kysymykseen z_t :n tulevia arvoja z_{t+h} , $h \geq 1$, ennustettaessa.

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus: Yleinen määritelmä

- Olkoot

- $z_t(h | \mathcal{F}_t) = E(z_{t+h} | \mathcal{F}_t)$ informaatiojoukkoon \mathcal{F}_t perustuva z_{t+h} :n (keskineliövirheen mielessä) optimaalinen ennuste
- $z_t(h | \mathcal{F}_t \setminus \mathcal{F}_t^x) = E(z_{t+h} | \mathcal{F}_t \setminus \mathcal{F}_t^x)$ z_{t+h} :n optimaalinen ennuste, kun joukosta \mathcal{F}_t on poistettu $\mathcal{F}_t^x = \{x_s, s \leq t\}$ ja
- $\Sigma_z(h | \mathcal{F}_t)$ ja $\Sigma_z(h | \mathcal{F}_t \setminus \mathcal{F}_t^x)$ vastaavat keskineliövirheet

- Prosessien x_t ja z_t välillä sanotaan olevan *Grangerin kausaalisuus* edellisestä jälkimmäiseen eli $x \rightarrow z$, jos

$$\Sigma_z(h | \mathcal{F}_t) < \Sigma_z(h | \mathcal{F}_t \setminus \mathcal{F}_t^x)$$

ainakin yhdellä t ja $h \in \{1, 2, \dots\}$.

- Toisin sanoen, prosessia z_t voidaan ennustaa tarkemmin käyttämällä prosessia x_t kuin ilman sitä.

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus: Yleinen määritelmä

- Olkoot nyt x_t ja z_t vektoriarvoisia prosesseja ja
 - $z_t(h | \mathcal{F}_t) = E(z_{t+h} | \mathcal{F}_t)$ informaatiojoukkoon \mathcal{F}_t perustuva z_{t+h} :n (keskineliövirheen mielessä) optimaalinen ennuste
 - $z_t(h | \mathcal{F}_t \setminus \mathcal{F}_t^x) = E(z_{t+h} | \mathcal{F}_t \setminus \mathcal{F}_t^x)$ z_{t+h} :n optimaalinen ennuste, kun joukosta \mathcal{F}_t on poistettu $\mathcal{F}_t^x = \{x_s, s \leq t\}$ ja
 - $\Sigma_z(h | \mathcal{F}_t)$ ja $\Sigma_z(h | \mathcal{F}_t \setminus \mathcal{F}_t^x)$ vastaavat keskineliövirhematriisit

- Pätee välttämättä (ja ilmeisesti)

$$\Sigma_z(h | \mathcal{F}_t \setminus \mathcal{F}_t^x) - \Sigma_z(h | \mathcal{F}_t) \geq 0.$$

- Ei kohtuullista vaatia, että tässä olisi $>$, joten *Grangerin kausaalisuuden* sanotaan pätevän suuntaan $x \rightarrow z$, jos

$$\Sigma_z(h | \mathcal{F}_t) \neq \Sigma_z(h | \mathcal{F}_t \setminus \mathcal{F}_t^x)$$

ainakin yhdellä t ja $h \in \{1, 2, \dots\}$.

- Samanaikaiseen kausaalisuuteen ei oteta kantaa.

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus VAR-mallissa

- Tarkastellaan stationaarista VAR(p)-mallia

$$y_t = A_1 y_{t-1} + \dots + A_p y_{t-p} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \Omega).$$

- Nyt informaatiojoukko on $\mathcal{F}_t = \{y_s, s \leq t\}$.
- Kun ositetaan $y_t = (z_t, x_t)$, niin yo mallista tulee

$$\begin{bmatrix} z_t \\ x_t \end{bmatrix} = \sum_{j=1}^p \begin{bmatrix} A_{11,j} & A_{12,j} \\ A_{21,j} & A_{22,j} \end{bmatrix} \begin{bmatrix} z_{t-j} \\ x_{t-j} \end{bmatrix} + \begin{bmatrix} \zeta_t \\ \xi_t \end{bmatrix}.$$

- Varsin ilmeistä, että Grangerin kausaalisuus suuntaan $x \rightarrow z$ liittyy siihen onko $A_{12,j} \neq 0$ jollain $1 \leq j \leq p$.
- Lause 4.1.** Jos $y_t = (z_t, x_t)$ on kuten edellä, niin Grangerin kausaalisuus suuntaan $x \rightarrow z$ ei päde jos ja vain jos $A_{12,j} = 0$ kaikilla $j = 1, \dots, p$.

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus VAR-mallissa

- Myös vakiollisessa VAR(p)-mallissa

$$\begin{bmatrix} z_t \\ x_t \end{bmatrix} = \begin{bmatrix} v_1 \\ v_2 \end{bmatrix} + \sum_{j=1}^p \begin{bmatrix} A_{11,j} & A_{12,j} \\ A_{21,j} & A_{22,j} \end{bmatrix} \begin{bmatrix} z_{t-j} \\ x_{t-j} \end{bmatrix} + \begin{bmatrix} \zeta_t \\ \xi_t \end{bmatrix}$$

Grangerin kausaalisuus suuntaan $x \rightarrow z$ ei päde jos ja vain jos $A_{12,j} = 0$ kaikilla $j = 1, \dots, p$.

- Grangerin kausaalisuutta VAR(p)-mallissa voidaan siis testata testaamalla lineaarista hypoteesia

$$H_0 : A_{12,1} = \dots = A_{12,p} = 0.$$

- Jos z_t on $n_1 \times 1$ vektori ja x_t on $n_2 \times 1$ vektori ($n_1 + n_2 = n$) on $A_{12,j}$ $n_1 \times n_2$ matriisi ja rajoitteiden lukumäärä on $n_1 n_2 p$.
- Waldin testiä tai uskottavuusosamäärätestiä voidaan siten käyttää yhdessä (asymptoottisen) $\chi^2_{n_1 n_2 p}$ -jakauman kanssa.

Kuvion 1.1. aineistolle estimoitu VAR(2)-malli

$$\begin{bmatrix} dexch_t \\ rdif_t \end{bmatrix} = \begin{bmatrix} -0.002 \\ (0.002) \\ 0.004 \\ (0.014) \end{bmatrix} + \begin{bmatrix} 0.418 & 0.023 \\ (0.089) & (0.012) \\ -0.187 & 1.144 \\ (0.672) & (0.090) \end{bmatrix} \begin{bmatrix} dexch_{t-1} \\ rdif_{t-1} \end{bmatrix} \\ + \begin{bmatrix} -0.178 & -0.026 \\ (0.087) & (0.012) \\ 0.603 & -0.179 \\ (0.659) & (0.089) \end{bmatrix} \begin{bmatrix} dexch_{t-2} \\ rdif_{t-2} \end{bmatrix} + \begin{bmatrix} \hat{\varepsilon}_{1t} \\ \hat{\varepsilon}_{2t} \end{bmatrix}.$$

- Uskottavuusosamäärätesti:

- $H_0 : dexch_t \not\Rightarrow rdif_t$; likimääräinen P-arvo 0.65.
- $H_0 : rdif_t \not\Rightarrow dexch_t$; likimääräinen P-arvo 0.06.

Stationaarisen VAR-mallin teoriaa

Grangerin kausaalisuus VAR-mallissa

- Kuvion 1.1. aineistolle estimoitu VAR(2)-malli, kun oletetaan $dexch_t \leftrightarrow rdif_t$:

$$\begin{bmatrix} dexch_t \\ rdif_t \end{bmatrix} = \begin{bmatrix} -0.002 \\ (0.002) \\ 0.003 \\ (0.014) \end{bmatrix} + \begin{bmatrix} 0.411 & 0.023 \\ (0.084) & (0.012) \\ 0 & 1.147 \\ & (0.086) \end{bmatrix} \begin{bmatrix} dexch_{t-1} \\ rdif_{t-1} \end{bmatrix} + \begin{bmatrix} -0.158 & -0.026 \\ (0.082) & (0.012) \\ 0 & -0.185 \\ & (0.086) \end{bmatrix} \begin{bmatrix} dexch_{t-2} \\ rdif_{t-2} \end{bmatrix} + \begin{bmatrix} \tilde{\varepsilon}_{1t} \\ \tilde{\varepsilon}_{2t} \end{bmatrix}.$$

- Verrattuna rajoittamattoman mallin estimointiin on estimointitarkkuus (odotetusti) parantunut ja rajoittamattomat estimaatit muuttuneet vain vähän.