

Darstellung eines VAR(p)-Prozesses als VAR(1)-Prozess

Definiere

$$\mathbf{x}_t = \begin{pmatrix} \mathbf{Y}_t \\ \mathbf{Y}_{t-1} \\ \vdots \\ \mathbf{Y}_{t-p+1} \end{pmatrix}$$

Darstellung eines VAR(p)-Prozesses als VAR(1)-Prozess

Dann gilt:

$$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \begin{pmatrix} \mathbf{u}_t \\ 0 \\ 0 \end{pmatrix},$$

$$\mathbf{F} = \begin{pmatrix} \Phi_1 & \dots & \Phi_{p-1} & \Phi_p \\ I_p & \mathbf{0}_p & \dots & \mathbf{0}_p \\ \mathbf{0}_p & I_p & \dots & \mathbf{0}_p \\ \mathbf{0}_p & \dots & I_p & \mathbf{0}_p \end{pmatrix},$$

Beispiele

VAR(2)-Prozess

$$\mathbf{F} = \begin{pmatrix} \Phi_1 & \Phi_2 \\ I_2 & \mathbf{0}_2 \end{pmatrix},$$

VAR(3)-Prozess

$$\mathbf{F} = \begin{pmatrix} \Phi_1 & \Phi_2 & \Phi_3 \\ I_3 & \mathbf{0}_3 & \mathbf{0}_3 \\ \mathbf{0}_3 & I_3 & \mathbf{0}_3 \end{pmatrix}.$$

Stationaritätsbedingung

\mathbf{F} ist eine pm Matrix

Alle Eigenwerte der Matrix \mathbf{F} sind betragsmäßig kleiner als 1.

Dann gilt:

- Sind die Fehler normalverteilt, so ist der VAR(1)- Prozess streng stationär
- Sind die Fehler nicht normalverteilt, aber gilt $E(\mathbf{u}_t) = \mathbf{0}$ und $\text{Var}(\mathbf{u}_t) = \Sigma$, so ist der VAR(1)- Prozess schwach stationär

Bestimmen des Erwartungswertes

Erwartungswert $\mu = E(\mathbf{Y}_t)$ eines stationären Prozesses, erfüllt folgendes Gleichungssystem:

$$E(\mathbf{Y}_t) = \Phi_1 E(\mathbf{Y}_{t-1}) + \dots + \Phi_p E(\mathbf{Y}_{t-p}) + \mathbf{c} + E(\boldsymbol{u}_t).$$

Daher gilt:

$$\mu = \Phi_1 \mu + \dots + \Phi_p \mu + \mathbf{c},$$

$$\mu - \Phi_1 \mu - \dots - \Phi_p \mu = \mathbf{c},$$

$$(\mathbf{I} - \Phi_1 - \dots - \Phi_p) \mu = \mathbf{c},$$

$$\mu = (\mathbf{I} - \Phi_1 - \dots - \Phi_p)^{-1} \mathbf{c}.$$

Bestimmen des Erwartungswertes

Bei einem stationären VAR(p)-Modell hat die Matrix

$$\mathbf{A} = \mathbf{I} - \Phi_1 - \dots - \Phi_p$$

vollen Rang und ist daher invertierbar. In diesem Fall sind alle Eigenwerte von \mathbf{A} von 0 verschieden.

2.5 Schätzung in EViews

Darstellung eines VAR(1)-Modells als Gleichungssystem:

$$Y_{1t} = \Phi_{11}Y_{1,t-1} + \Phi_{12}Y_{2,t-1} + \cdots + \Phi_{1m}Y_{m,t-1} + c_1 + u_{1t},$$

$$Y_{2t} = \Phi_{21}Y_{1,t-1} + \Phi_{22}Y_{2,t-1} + \cdots + \Phi_{2m}Y_{m,t-1} + c_2 + u_{2t},$$

:

$$Y_{mt} = \Phi_{m1}Y_{1,t-1} + \Phi_{m2}Y_{2,t-1} + \cdots + \Phi_{mm}Y_{m,t-1} + c_m + u_{mt}.$$

Schätzung in EViews

- Das sind m Regressionsmodelle mit identischen Prädiktoren.
- $\Phi_{11}, \Phi_{12}, \dots, \Phi_{1m}$ (1. Zeile von Φ) und c_1 kommen nur im ersten Regressionsmodell vor.
- $\Phi_{j1}, \Phi_{j2}, \dots, \Phi_{jm}$ (j .te Zeile von Φ) und c_j kommen nur im j .ten Regressionsmodell vor.
- Getrennte OLS-Schätzung aus den einzelnen Zeilen zulässig, da die Prädiktoren identisch sind.

Schätzung eines VAR(p)-Modells in EViews

- Darstellung eines VAR(p)-Modells als Gleichungssystem möglich.
- Das sind m Regressionsmodelle mit identischen Prädiktoren.
- Jeweils die j .te Zeile von $\Phi_1, \Phi_2, \dots, \Phi_p$ sowie c_j kommen nur im j .ten Regressionsmodell vor.
- Getrennte OLS-Schätzung aus den einzelnen Zeilen zulässig, da die Prädiktoren identisch sind.

EViews Exercise - Case Study Industrial Production

Industrial production - quarterly data for various European countries from 1970:1 to 2001:4; consider France (ip-fra), Germany (ip-deu), and Spain (ip-esp) - estimate various trivariate VAR(p)-models for relative growth rate (r-fra , r-deu, r-esp)

- Estimate VAR(1) model
- Estimate VAR(p) model with increasing p
- Discuss where to find the coefficients
- Discuss stationarity of estimated model

Auswerten der OLS-Residuen

Für jedes der m Regressionsmodelle gibt es OLS-Residuen, z.B. VAR(1)-Modell:

$$\hat{u}_{jt} = Y_{jt} - \hat{\Phi}_{j1}Y_{1,t-1} - \hat{\Phi}_{j2}Y_{2,t-1} - \cdots - \hat{\Phi}_{jm}Y_{m,t-1} - \hat{c}_j, \quad t = 2, 3$$

Diese OLS-Residuen sind nützlich zur:

- Schätzung von Σ durch empirische Kovarianzmatrix der Residuen:

$$\hat{\Sigma}_{jk} = \frac{1}{N} \sum_{t=2}^N \hat{u}_{jt} \hat{u}_{kt}.$$

- Residuendiagnose

EViews Exercise - Case Study Industrial Production

Industrial production - quarterly data for various European countries from 1970:1 to 2001:4; consider France (ip-fra), Germany (ip-deu), and Spain (ip-esp) - estimate various trivariate VAR(p)-models for relative growth rate (r-fra, r-deu, r-esp)

- Discuss residual diagnostics (in particular remaining auto- and crosscorrelation)
- Discuss choosing the model order using AIC and SC

Impuls response function

A stationary VAR(1)-process \mathbf{Y}_t has a representation as a weighted sum of past “shocks” $\mathbf{u}_t, \mathbf{u}_{t-1}, \mathbf{u}_{t-2}, \dots$:

$$\mathbf{Y}_{t-2} - \boldsymbol{\mu} = \Phi(\mathbf{Y}_{t-3} - \boldsymbol{\mu}) + \mathbf{u}_{t-2},$$

$$\mathbf{Y}_{t-1} - \boldsymbol{\mu} = \Phi(\mathbf{Y}_{t-2} - \boldsymbol{\mu}) + \mathbf{u}_{t-1},$$

$$\mathbf{Y}_t - \boldsymbol{\mu} = \mathbf{u}_t + \Phi(\mathbf{Y}_{t-1} - \boldsymbol{\mu}) = \mathbf{u}_t + \Phi\mathbf{u}_{t-1} + \Phi^2(\mathbf{Y}_{t-2} - \boldsymbol{\mu}) =$$

$$\mathbf{u}_t + \Phi\mathbf{u}_{t-1} + \Phi^2\mathbf{u}_{t-2} + \Phi^3(\mathbf{Y}_{t-3} - \boldsymbol{\mu}) = \dots$$

Therefore:

$$\mathbf{Y}_t - \boldsymbol{\mu} = \mathbf{u}_t + \Phi\mathbf{u}_{t-1} + \Phi^2\mathbf{u}_{t-2} + \dots + \Phi^s\mathbf{u}_{t-s} + \dots$$

Impuls response function

- Due to stationarity: $\Phi^s \rightarrow 0$ (all eigenvalues smaller than 1), hence the influence of “old” shocks decreases
- Extension to VAR(p)-Models:

$$\mathbf{Y}_t - \boldsymbol{\mu} = \mathbf{u}_t + \boldsymbol{\Psi}^{[1]} \mathbf{u}_{t-1} + \boldsymbol{\Psi}^{[2]} \mathbf{u}_{t-2} + \dots + \boldsymbol{\Psi}^{[s]} \mathbf{u}_{t-s} + \dots,$$

where $\boldsymbol{\Psi}^{[s]}$ is a $m \times m$ matrix depending on Φ_1, \dots, Φ_p (e.g. $\boldsymbol{\Psi}^{[s]} = \Phi^s$ for a VAR(1) model).

- $\boldsymbol{\Psi}^{[s]}$ describes how a shock at time t influences future deviations of \mathbf{Y}_{t+s} from $\boldsymbol{\mu}$ (this response to a shock is independent of t)

Impulse response function

Interpretation of the coefficients of $\Psi^{[s]}$:

- The element $\Psi_{ij}^{[s]}$ measures how a shock in the j th time series Y_{jt} of order 1 effects deviations of the i th time series $Y_{i,t+s}$ from the long run mean after s periods.
- Impulse response function: plotting $\Psi_{ij}^{[s]}$ for a fixed combination of (i, j) over s - Reaction of time series i to a shock in time series j
- There are, in total, m^2 impulse response functions

Granger Kausalität

Bivariate VAR(2)-Modell in Gleichungsschreibweise:

$$\begin{aligned} Y_{1t} &= \Phi_{1,11}Y_{1,t-1} + \Phi_{2,11}Y_{1,t-2} \\ &\quad + \Phi_{1,12}Y_{2,t-1} + \Phi_{2,12}Y_{2,t-2} + c_1 + u_{1t}, \\ Y_{2t} &= \Phi_{1,21}Y_{1,t-1} + \Phi_{2,21}Y_{1,t-2} \\ &\quad + \Phi_{1,22}Y_{2,t-1} + \Phi_{2,22}Y_{2,t-2} + c_2 + u_{2t}. \end{aligned}$$

Wenn $Y_{1,t-1}$ und $Y_{1,t-2}$ zur Vorhersage von Y_{2t} hilfreich ist ($\Phi_{1,21} \neq 0$, $\Phi_{2,21} \neq 0$), dann heisst Y_{2t} durch Y_{1t} im Sinne von Granger verursacht.

Granger Kausalität

Allgemein sagt man, daß Y_{jt} nicht durch Y_{kt} im Sinne von Granger verursacht wird, wenn die Koeffizienten von $Y_{k,t-1}$ und $Y_{k,t-p}$ in der j .ten Zeile des VAR(p)-Modells 0 sind:

$$\Phi_{j,1k} = \dots = \Phi_{j,pk} = 0$$

Nach der OLS-Schätzung eines VAR(p)-Modells, kann diese Nullhypothese für jedes $k \neq j$ mittels eines statistischen Tests geprüft werden.

EViews Exercise - Case Study Industrial Production

Industrial production - quarterly data for various European countries from 1970:1 to 2001:4; consider France (ip-fra), Germany (ip-deu), and Spain (ip-esp)

- Estimate a trivariate VAR(p)-model for relative growth rate ($r\text{-}fra$, $r\text{-}deu$, $r\text{-}esp$)
- Discuss Granger Causality Test for various model orders

EViews Exercise - Case Study Austrian Stock Exchange

Stock exchange data - weekly data from January 7, 1986 to September 22, 1992; consider Leykam ($\log(p\text{-lkm})$), Wienerberger ($\log(p\text{-wie})$), Veitascher ($\log(p\text{-vei})$)

- Estimate a trivariate VAR(p)-model for relative growth rate ($r\text{-lkm}$, $r\text{-wie}$, $r\text{-vei}$)
- Discuss Granger Causality Test for various model orders

Vorhersage mit VAR(1)-Prozessen

Wegen

$$\mathbf{Y}_{t+1} - \boldsymbol{\mu} = \Phi(\mathbf{Y}_t - \boldsymbol{\mu}) + \mathbf{u}_{t+1}, \quad \mathbf{u}_{t+1} \sim \text{Normal}(\mathbf{0}, \boldsymbol{\Sigma})$$

gilt:

$$E(\mathbf{Y}_{t+1} | \mathbf{Y}_t) = \boldsymbol{\mu} + \Phi(\mathbf{Y}_t - \boldsymbol{\mu}).$$

Zwei Informationsquellen zur Vorhersage:

- langfristiges Niveau (stationärer Erwartungswert $\boldsymbol{\mu}$)
- aktuelle Abweichungen der beobachteten Werte \mathbf{Y}_t vom langfristigen Niveau $\boldsymbol{\mu}$

Vorhersage mit VAR(1)-Prozessen

Der Informationswert der aktuellen Abweichungen der beobachteten Werte \mathbf{Y}_t vom langfristigen Niveau μ nimmt mit steigendem Vorhersagehorizont ab:

$$E(\mathbf{Y}_{t+l} | \mathbf{Y}_t) = \mu + \Phi^l (\mathbf{Y}_t - \mu).$$

Wegen der Stationarität geht Φ^l gegen 0, und die Vorhersage nähert sich μ .

EViews Exercise - Case Study Industrial Production

Industrial production - quarterly data for various European countries from 1970:1 to 2001:4; consider France (ip-fra), Germany (ip-deu), and Spain (ip-esp) - estimate various trivariate VAR(p)-models for relative growth rate defined by $d\log(ip\text{-}fra)$, $d\log(ip\text{-}deu)$, $d\log(ip\text{-}esp)$

- Discuss forecasting to the relative change rate
- Discuss forecasting of the original time series