

- ARMA(p,q)-prosessi määritellään yhtälöllä

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2)$$

jossa $1 - \phi_1 z - \dots - \phi_p z^p \neq 0, \quad |z| \leq 1$ (stationaarisuusehto) ja
 $1 + \theta_1 z - \dots + \theta_q z^q \neq 0, \quad |z| \leq 1$ (käännettävyysehto)

- Oletetaan, että havaittu aikasarja y_1, \dots, y_T voidaan (mm. kuvion perusteella) tulkita stationaarisen prosessin tuottamaksi ja sen mallintaminen jollain ARMA(p,q)-prosessilla tuntuu kohtuulliselta.
- Stationaarisuusoletus saattaa vaatia aikasarjan muuntamista.
- Tavallisimmat esimerkit muunnoksista ovat differensointi (mahdollisesti logaritointiin yhdistettynä) ja deterministisen trendin eliminointi PNS-menetelmällä.

- Sopivan ARMA(p,q)-prosessin tai, kuten mallintamisen yhteydessä tavallisesti sanotaan, ARMA(p,q)-mallin löytäminen on perinteisesti ajateltu koostuvan seuraavista toisiinsa liittyvistä vaiheista:
 - 1) Mallin asteiden p ja q valinta
 - 2) Parametrien alustava estimointi
 - 3) Parametrien tehokas estimointi
 - 4) Estimoidun mallin riittävyden tutkiminen eli mallin diagnostiikka
- Jos estimoitu malli havaitaan vaiheessa 4 puutteelliseksi, on valittava uusi malli (uudet asteet), estimoitava valitun mallin parametrit ja tutkittava estimoidun mallin riittävyttä.
- Tyypillinen puutteellisuus mallissa on virheiden ε_t autokorreloituneisuus, jolloin asteista p ja q (ainakin) toinen on valittu liian pieneksi.

- Kannattaisiko ARMA(p,q)-mallin asteet valita varmuuden vuoksi niin suuriksi, että virhetermin autokorreloituneisuutta ei ole mitään syytä epäillä?
- Tähän liittyvä ongelma on identifioituvuus eli voidaan päätyä malliin

$$\delta(B)\phi(B)y_t = \delta(B)\theta(B)\varepsilon_t, \quad \delta(B) = 1 + \delta_1 B + \dots + \delta_r B^r,$$

jota ei voida erottaa mallista

$$\phi(B)y_t = \theta(B)\varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2).$$

- Tällöin ensin mainitun mallin parametreja ei voida identifioida, joten estimointi on epävakaa, mikä heijastuu epätarkkuutena ennustamisessa.
- Kannattaa suosia ns. *säästäväisyysperiaatetta* eli pyrkiä valitsemaan mahdollisimman yksinkertainen, mutta kuitenkin riittävä malli.

ARMA-mallien rakentaminen

Autokorrelaatio- ja osittaisautokorrelaatiofunktion käyttäminen mallin valinnassa

- Aikasarjan kuvan piirtämisen jälkeen on hyvä tutustua aineistoon tutkimalla sarjan autokorrelaatio-ominaisuuksia estimoidun autokorrelaatio- ja osittaisautokorrelaatiofunktion avulla.
- Tämä saattaa antaa joissakin tapauksissa vihjeitä sopivista mallin asteista. Erityisesti, jos havaitaan katkoksia.
- Katkos autokorrelaatiofunktiossa (osittaisautokorrelaatiofunktiossa) viittaa MA-prosessiin (AR-prosessiin). Jos katkoksia ei ole, voidaan epäillä ARMA-prosessia.
- Usein selvää johtopäätöstä on vaikea tehdä, mutta joitakin mallivaihtoehtoja voidaan ehkä sulkea pois.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

Havaittu aikasarja y_1, \dots, y_T . Mallina on nyt

$$y_t - \mu = \phi_1 (y_{t-1} - \mu) + \dots + \phi_p (y_{t-p} - \mu) + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2).$$

Jakso 3.1: Parametrien $\boldsymbol{\phi} = (\phi_1, \dots, \phi_p)$ ja σ^2 Yule-Walker -estimaatit

$$\tilde{\boldsymbol{\phi}}_{\text{YW}} = \begin{bmatrix} c_0 & c_1 & \dots & c_{p-1} \\ c_1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & c_1 \\ c_{p-1} & \dots & c_1 & c_0 \end{bmatrix}^{-1} \begin{bmatrix} c_1 \\ \vdots \\ \vdots \\ c_p \end{bmatrix} = \mathbf{C}_p^{-1} \mathbf{c}_p,$$

$$\tilde{\sigma}_{\text{YW}}^2 = c_0 - \tilde{\boldsymbol{\phi}}_{\text{YW},1} c_1 - \dots - \tilde{\boldsymbol{\phi}}_{\text{YW},p} c_p,$$

jossa $c_h = (T - h)^{-1} \sum_{t=1}^{T-h} (y_t - \bar{y})(y_{t+h} - \bar{y})$ on otosautokovarianssi.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

- Voidaan osoittaa, että

$$\tilde{\boldsymbol{\phi}}_{\text{YW}} \underset{as}{\sim} \text{N}(\boldsymbol{\phi}, T^{-1}\sigma^2\boldsymbol{\Gamma}_p^{-1}),$$

jossa $\boldsymbol{\Gamma}_p = [\gamma_{i-j}]_{i,j=1,\dots,p}$ ja $\tilde{\sigma}_{\text{YW}}^2 \mathbf{C}_p^{-1} \xrightarrow{p} \sigma^2 \boldsymbol{\Gamma}_p^{-1}$.

- Lisäksi, jos $\varepsilon_t \sim \text{nid}(0, \sigma^2)$, niin yo asymptoottinen jakauma on sama kuin SU-estimaattorin asymptoottinen jakauma, joten Yule-Walker estimaattori $\tilde{\boldsymbol{\phi}}_{\text{YW}}$ on asymptoottisesti tehokas.
- Yo asymptoottista jakaumatulosta käyttäen voidaan muodostaa Waldin testejä ja luottamusvälejä tavanomaiseen tapaan.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

- Kun $E(y_t) = \mu \neq 0$ sallitaan, voidaan AR(p)-malli esittää myös käyttäen parametointia

$$y_t = \nu + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

jossa $\nu = \mu - \phi_1 \mu - \cdots - \phi_p \mu$.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

- Kun $E(y_t) = \mu \neq 0$ sallitaan, voidaan AR(p)-malli esittää myös käyttäen parametointia

$$y_t = \nu + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

jossa $\nu = \mu - \phi_1 \mu - \cdots - \phi_p \mu$.

- Tuntuu luontevalta käyttää parametrien $\boldsymbol{\phi}$ ja ν estimointiin PNS-menetelmää eli minimoidaan neliösummafunktio

$$S(\nu, \boldsymbol{\phi}) = \sum_{t=p+1}^T \left(y_t - \nu - \phi_1 y_{t-1} - \cdots - \phi_p y_{t-p} \right)^2.$$

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

- Kun $E(y_t) = \mu \neq 0$ sallitaan, voidaan AR(p)-malli esittää myös käyttäen parametointia

$$y_t = \nu + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

jossa $\nu = \mu - \phi_1 \mu - \dots - \phi_p \mu$.

- Tuntuu luontevalta käyttää parametrien $\boldsymbol{\phi}$ ja ν estimointiin PNS-menetelmää eli minimoidaan neliösummafunktio

$$S(\nu, \boldsymbol{\phi}) = \sum_{t=p+1}^T \left(y_t - \nu - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} \right)^2.$$

- Jos $\tilde{\nu}_{PNS}$ ja $\tilde{\boldsymbol{\phi}}_{PNS}$ ovat näin saatuja PNS-estimaattoreita, voidaan σ^2 estimaattoriksi valita $S(\tilde{\nu}_{PNS}, \tilde{\boldsymbol{\phi}}_{PNS}) / (T - p)$ tai $S(\tilde{\nu}_{PNS}, \tilde{\boldsymbol{\phi}}_{PNS}) / (T - 2p - 1)$.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: AR(p)

- Voidaan osoittaa, että PNS-estimaattorilla $\tilde{\phi}_{PNS}$ on sama asymptoottinen jakauma kuin Yule-Walker estimaattorilla, joten se on asymptoottisesti yhtäpitävä normaalijakaumaan perustuvan SU-estimaattorin kanssa ja siten asymptoottisesti tehokas.
- Lisäksi, kaikki tavanomaiset lineaarisen mallin testeihin ja luottamusväleihin liittyvät tulokset ja menetelmät pätevät *likimääräisesti, mutta eivät äärellisillä $T:n$ arvoilla tarkasti*.
- PNS-estimaattori poikkeaa SU-estimaattorista vain siinä, että havainnot y_1, \dots, y_p tulkitaan ei-satunnaisiksi vakioiksi eli ehdollistetaan niiden suhteen.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: ARMA(p,q)

- Oletetaan stationaarisuus ja käännettavyys sekä $E(y_t) = 0$.

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q},$$
$$\varepsilon_t \sim \text{iid}(0, \sigma^2).$$

- Jos viivästetyt innovaatiot $\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ tunnettaisiin, voitaisiin menetellä kuten AR(p)-mallin tapauksessa ja estimoida parametrit ϕ_1, \dots, ϕ_p ja $\theta_1, \dots, \theta_q$ yksinkertaisesti PNS-menetelmällä.
- Hannanin ja Rissasen menetelmän ideana on korvata viivästetyt innovaatiot empiirisillä vastineilla, jotka perustetaan y_t :n AR(∞)-esityksen AR(m)-approksimaatioon (m "suuri"). Tämä vaatii mallin käännettävyyden.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: ARMA(p,q)

- Olkoon

$$\tilde{\varepsilon}_t = y_t + \tilde{\pi}_1 y_{t-1} + \cdots + \tilde{\pi}_m y_{t-m}, \quad t = m+1, \dots, T,$$

y_t :n AR(m)-approksimaatioon perustuvat PNS- tai Yule-Walker-residuaalit.

- Asetetaan $n = \max\{m+p+1, m+q+1\}$ ja muodostetaan "apumalli" ($t = n, \dots, T$)

$$y_t = \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \theta_1 \tilde{\varepsilon}_{t-1} + \cdots + \theta_q \tilde{\varepsilon}_{t-q} + a_t,$$

josta parametrit $\boldsymbol{\phi} = (\phi_1, \dots, \phi_p)$ ja $\boldsymbol{\theta} = (\theta_1, \dots, \theta_q)$ estimoidaan PNS-llä eli minimoimalla neliösummafunktio

$$\tilde{S}(\boldsymbol{\phi}, \boldsymbol{\theta}) = \sum_{t=n}^T \left(y_t - \phi_1 y_{t-1} - \cdots - \phi_p y_{t-p} - \theta_1 \tilde{\varepsilon}_{t-1} - \cdots - \theta_q \tilde{\varepsilon}_{t-q} \right)^2$$

ARMA-mallien rakentaminen

Parametrien alustava estimointi: ARMA(p,q)

Parametrille $\beta = (\phi, \theta)$, saadaan siten estimaattori

$$\tilde{\beta}_{HR} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y},$$

jossa $\mathbf{y} = [y_n \cdots y_T]'$ ja

$$\mathbf{X} = \begin{bmatrix} y_{n-1} & \cdots & y_{n-p} & \tilde{\varepsilon}_{n-1} & \cdots & \tilde{\varepsilon}_{n-q} \\ \vdots & & \vdots & \vdots & & \vdots \\ y_T & \cdots & y_{T-p} & \tilde{\varepsilon}_{T-1} & \cdots & \tilde{\varepsilon}_{T-q} \end{bmatrix}.$$

Innovaatiovarianssi σ^2 estimoidaan suurella $\tilde{S}(\tilde{\beta}_{HR}) / (T - n)$.

ARMA-mallien rakentaminen

Parametrien alustava estimointi: ARMA(p,q)

- Estimaattorin $\tilde{\beta}_{HR}$ toimivuus vaatii, että viipymä m valitaan "tarpeeksi suureksi", jotta AR(m)-approksimaatio tai $e_t \approx \varepsilon_t$ toimii "kohtuullisen hyvin".
- Toisaalta m ei saa olla "liian suuri" suhteessa havaintojen lukumäärään T , koska muutoin AR(m)-approksimaatiossa estimoidaan liian paljon parametreja suhteessa havaintojen lukumäärään ja $\tilde{\beta}_{HR}$ perustuu liian pieneen havaintomäärään.
- Käytännössä m :n arvo voidaan valita tutkimalla estimoitua osittaisautokorrelaatiofunktioita (vrt. jakso 3.1) tai ns. mallinvalintakriteerejä (tai molempia).
- **HUOM.:** *Estimaattori $\tilde{\beta}_{HR}$ ei ole (asymptoottisesti) tehokas eivätkä tavanomaiset lineaarisen mallin F- ja t-testit ole (edes asymptoottisesti) päteviä.* Sitä on tarkoitus käyttää (korkeintaan) edellä mainittujen mallinvalintakriteerien kanssa sekä tuottamaan alkuarvoja numeerisia menetelmiä vaativassa SU-estimoinnissa.

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä

- Tavoitteena on valita (stationaarisen ja käännettävän) ARMA(p, q)-mallin

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q},$$
$$\varepsilon_t \sim \text{iid}(0, \sigma^2).$$

asteet p ja q , kun "riittävän suuret" maksimiasteet p^* ja q^* on kiinnitetty.

- Lineaarisen mallin teorian perusteella voitaisiin ajatella menettelyä, jossa Hannanin ja Rissasen "apumallin" ($t = n, \dots, T$)

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 \tilde{\varepsilon}_{t-1} + \dots + \theta_q \tilde{\varepsilon}_{t-q} + a_t$$

virhetermin a_t estimoitua varianssia $\tilde{\sigma}_{p,q}^2$ ($0 \leq p \leq p^*$, $0 \leq q \leq q^*$) minimoitaisiin p :n ja q :n suhteen.

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä

- Jos "apumallissa" ($t = n, \dots, T$)

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 \tilde{\varepsilon}_{t-1} + \dots + \theta_q \tilde{\varepsilon}_{t-q} + a_t$$

p ja/tai q kasvaa, niin (PNS:ään perustuva) residuaalineliosumma ja siten myös $\tilde{\sigma}_{p,q}^2$ pienenee. (Olettaen, että $n \geq \max(p^*, q^*)$ pidetään samana kaikilla kokeiltavilla p :n ja q :n arvoilla.)

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä

- Jos "apumallissa" ($t = n, \dots, T$)

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 \tilde{\varepsilon}_{t-1} + \dots + \theta_q \tilde{\varepsilon}_{t-q} + a_t$$

p ja/tai q kasvaa, niin (PNS:ään perustuva) residuaalineliosumma ja siten myös $\tilde{\sigma}_{p,q}^2$ pienenee. (Olettaen, että $n \geq \max(p^*, q^*)$ pidetään samana kaikilla kokeiltavilla p :n ja q :n arvoilla.)

- Siis, $\tilde{\sigma}_{p,q}^2$:n minimointi p :n ja q :n suhteen ($0 \leq p \leq p^*$, $0 \leq q \leq q^*$) johtaa väistämättä laajimpaan mahdolliseen malliin.

- Jos "apumallissa" ($t = n, \dots, T$)

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 \tilde{\epsilon}_{t-1} + \dots + \theta_q \tilde{\epsilon}_{t-q} + a_t$$

p ja/tai q kasvaa, niin (PNS:ään perustuva) residuaalineliosumma ja siten myös $\tilde{\sigma}_{p,q}^2$ pienenee. (Olettaen, että $n \geq \max(p^*, q^*)$ pidetään samana kaikilla kokeiltavilla p :n ja q :n arvoilla.)

- Siis, $\tilde{\sigma}_{p,q}^2$:n minimointi p :n ja q :n suhteen ($0 \leq p \leq p^*$, $0 \leq q \leq q^*$) johtaa väistämättä laajimpaan mahdolliseen malliin.
- Ratkaisu: Valitaan asteet minimoimalla funktio

$$C_{HR}(p, q) = \log \tilde{\sigma}_{p,q}^2 + (p + q) g(T) / T, \quad 0 \leq p \leq p^*, 0 \leq q \leq q^*,$$

jossa ns. sakkofunktio $g(\cdot)$ on positiivinen ja $g(T) / T \rightarrow 0$, kun $T \rightarrow \infty$.


ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä

- Sakkofunktion idea on rankaista tarpeettoman laajan mallin käyttämisestä. Jos asteen p tai q kasvattaminen ei pienennä estimaattorin $\tilde{\sigma}_{p,q}^2$ arvoa tarpeeksi, ei laajempaa mallia valita.
- Tunnettuja sakkofunktioita ovat
 - AIC: $g(T) = 2$ (Akaike, 1974)
 - HQ: $g(T) = 2 \log(\log T)$ (Hannan ja Quinn, 1979)
 - BIC: $g(T) = \log T$ (Schwarz, 1978, Rissanen, 1978).
- Näistä ensimmäinen sakottaa vähiten (suosii laajempia malleja) ja viimeinen eniten (suosii suppeampia malleja). Kriteerifunktiosta HQ on myös versioita, joissa vakion 2 paikalla on joku muu vakio.
- Käytännössä ei ole suositeltavaa minimoida kriteerifunktiota $C_{HR}(p, q)$ mekaanisesti, vaan käyttää vain yhtenä mallin valinnan apuvälineenä.

ARMA-mallien rakentaminen


Hannanin ja Rissasen mallinvalintamenetelmä



Kuvio 1.4. Vuotuisten auringonpilkkujen lukumäärä vuosilta 1770 - 1870.

ARMA-mallien rakentaminen


Hannanin ja Rissasen mallinvalintamenetelmä



Kuvio 2.1. Kuvion 1.4 auringonpilkkusarjan otosautokorrelaatiofunktio (vas.) ja Kuvion 1.2 onnettomuussarjan otosautokorrelaatiofunktio (oik.) viipymillä $h = 0, \dots, 40$.

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä



Kuvio 3.2. Kuvion 1.4 auringonpilkkusarjan otosittaisautokorrelaatiofunktio (vas.) ja Kuvion 1.2 onnettomuussarjan otosittaisautokorrelaatiofunktio (oik.) viipymillä $h = 0, \dots, 40$.


ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä

- Estimoidun osittaisautokorrelaatiofunktion perusteella AR(2)-malli vaikuttaa sopivalta auringonpilkkusarjalle.
- Hannanin ja Rissasen menetelmä valinnoilla $m = 10$ ja $p^* = q^* = 4$ johtaa kaikilla kolmella sakkofunktiolla (AIC, HQ, BIC) kuitenkin laajempaan ARMA(2,1)-malliin.

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä




Kuvio 4.1. USAn neljännesvuosittainen inflaatio sarja ajanjaksolta 1970I - 2006IV ($T = 148$). Alkuperäisen kausipuhdistetun kuluttajien hintaindeksin logaritmiset differenssit kerrottuna neljällä sadalla.

Sarjan alkupuoli näyttää hieman erilaiselta kuin loppupuoli, mutta stationaarisuus tuntuu kuitenkin melko kohtuulliselta oletukselta.

ARMA-mallien rakentaminen

Hannanin ja Rissasen mallinvalintamenetelmä



Kuvio 4.2. Kuvion 4.1 inflaationsarjan otosautokorrelaatiofunktio (vas.) ja otososittaisautokorrelaatiofunktio (oik.) viipymilla $h = 0, \dots, 40$.

- Estimoitu autokorrelaatiofunktio vaimenee viipymän pituuden kasvaessa. Estimoidussa osittaisautokorrelaatiofunktiossa on varsin selvä katkos viipymällä 3. Siten AR(3)-malli voisi olla sopiva.
- Hannanin ja Rissasen menetelmä valinnoilla $m = 10$ ja $p^* = q^* = 4$ johtaa myös AR(3)-malliin kaikilla kolmella sakkofunktiolla (samoin, kuin valinnoilla $m = 10$ ja $p^* = q^* = 5, \dots, 9$).