

STATIONAARISET AIKASARJAT, 10 OP. 13.9.–14.12.2012. Kirjallisuus: James Hamiltonin Time Series Analysis, luvut 1–5 ja Terence Millsin The Econometric Modelling of Financial Time Series, luku 2. Luennoi: yliopistonlehtori Pekka Pere.

Harjoitusten 11 vastaukset (30.11.)

1.

a) Tehtävä on hyvin samantapainen kuin HT 10.1. Otosautokorrelaatioiden ($\hat{\rho}_j$) keskivirheet voidaan laskea Millsin sivun 29 kaavalla eli Hamiltonin kaavalla [4.8.8] (ilmeisin merkinnöin):

$$SE(\hat{\rho}_j) = \sqrt{V(\hat{\rho}_j)} \approx \sqrt{T^{-1}(1 + 2\rho_1^2 + 2\rho_2^2 \cdots + 2\rho_q^2)}, \quad j = q + 1, q + 2, \dots \quad (1)$$

Kaava olettaa, että tutkittava aikasarja noudattaa MA(q)-prosessia eli että $\rho_j = 0$. Keskivirhe voidaan laskea myös olettaen, että kaikki autokorrelaatiot ovat nolliä, jolloin keskivirhe olisi kaikille $\hat{\rho}_j$:ille

$$SE(\hat{\rho}_j) \approx \sqrt{T^{-1}} = T^{-1/2}, \quad j = 1, 2, \dots \quad (2)$$

Otosautokorrelaatiot ovat suurilla havaintomäärillä normaalijakautuneita, joten 95 %:n luottamusväli $\hat{\rho}_j$:lle on

$$\pm 1,96 \times \sqrt{T^{-1}(1 + 2\rho_1^2 + 2\rho_2^2 \cdots + 2\rho_q^2)} \approx \pm 2 \times \sqrt{T^{-1}(1 + 2\rho_1^2 + 2\rho_2^2 \cdots + 2\rho_q^2)}.$$

Kaavan mukaan 95 %:n luottamusvälit ovat

$$\begin{aligned} \rho_1: & \pm 2 \times \sqrt{T^{-1}} = \pm 2/\sqrt{T}, & \text{jos prosessi on MA(0)} \\ \rho_2: & \pm 2 \times \sqrt{T^{-1}(1 + 2\rho_1^2)}, & \text{jos prosessi on MA(1)} \\ \vdots & \vdots & \vdots \\ \rho_k: & \pm 2 \times \sqrt{T^{-1}(1 + 2\rho_1^2 + 2\rho_2^2 \cdots + 2\rho_{k-1}^2)}, & \text{jos prosessi on MA}(k-1) \end{aligned} \quad (3)$$

(yllä on approksimoitu standardinormaalijakauman 97,5:ttä persentiiliä (1,96) 2:sella).

Kaavan $SE(\hat{\rho}_j) \approx T^{-1/2}$ mukaan 95 %:n luottamusvälit ovat kaikille autokorrelaatioille

$$\rho_j: \pm 2/\sqrt{T}, \quad \text{jos prosessi on MA(0)}. \quad (4)$$

Otososittaisautokorrelaatioiden ($\hat{\alpha}_m^{(m)}$) keskivirheet ovat suurilla havaintomäärillä (Hamiltonin merkinnöillä s:lla 111)

$$SE(\hat{\alpha}_m^{(m)}) = \sqrt{V(\hat{\alpha}_m^{(m)})} \approx \sqrt{T^{-1}} = T^{-1/2}, \quad m = p + 1, p + 2, \dots, \quad (5)$$

kun tutkittava aikasarja on generoitunut AR(p)-prosessista. Näin ollen osittaisautokorrelaatioiden 95 %:n luottamusvälit ovat

$$\alpha_m^{(m)}: \pm 2/\sqrt{T}, \quad m = p + 1, p + 2, \dots \quad (6)$$

Tehtävän tilanteessa havaintoja on 83. Otosautokorrelaatioiden keskivirheet ja vastaavat luottamusvälit ovat kaavojen (2) ja (4) mukaan

$$SE(\hat{\rho}_j) \approx 83^{-1/2} \approx 0,11, \quad j = 1, 2, \dots \quad (2)$$

ja

$$\rho_j: \pm 2/\sqrt{83} \approx \pm 0,22. \quad (4)$$

Kaavoista (1) ja (3) keskivirheiksi ja luottamusväleiksi saataisiin seuraavat:

```
* sr1=sqrt(1/83)
* sr2=sqrt((1+2*0.71^2)/83)
* sr3=sqrt((1+2*0.71^2+2*0.53^2)/83)
* sr4=sqrt((1+2*0.71^2+2*0.53^2+2*0.40^2)/83)
*
*   otosauto-      keski-      luottamus-
*   korrelaatiot  virheet   valit
* 1.  0.71         sr1=0.11   +- 2*0.11 = +- 0.22
* 2.  0.53         sr2=0.16   +- 2*0.16 = +- 0.32
* 3.  0.40         sr3=0.16   +- 2*0.16 = +- 0.32
* 4.  0.30         sr4=0.17   +- 2*0.17 = +- 0.34
```

Otososittaisautokorrelaatioiden keskivirheet ja luottamusvälit ovat kaavojen (5) ja (6) mukaan

$$SE(\hat{\alpha}_m^{(m)}) \approx 83^{-1/2} \approx 0,11, \quad m = p + 1, p + 2, \dots$$

ja

$$\alpha_m^{(m)}: \pm 2/\sqrt{83} \approx \pm 0,22. \quad m = p + 1, p + 2, \dots$$

b) AR(1). Muutosaikasarjan otosautokorrelaatiofunktio ei katkea, mikä viittaa AR- tai ARMA-prosessiin. Otososittaisautokorrelaatiofunktio katkeaa yhden viipeen jälkeen, mikä viittaa siihen, että prosessissa ei ole MA-osaa ja eritoten, että prosessi olisi AR(1). Funktioiden "katkeamiset" edellä peurustuvat autokorrelaatioiden tarkasteluun a)-kohdassa, jonka mukaan ensimmäiset otosautokorrelaatiot eivät kuulu 95 %:n luottamusvälille ja osittaisautokorrelaation kohdalla vain ensimmäinen otososittaisautokorrelaatio ei kuulu luottamusvälille.

c) AIC-kriteeri on

$$AIC(p, q) = \log \hat{\sigma}^2 + 2(p + q)/T$$

(Mills, s. 34). Kriteeri lasketaan kullekin sovitulle mallille. AIC-kriteerin mukaan paras malli on se, joka minimoi AIC:n. Intuitio on, että kriteerissä "rangaistaan" lisäparametreista, jotka "aina" pienentävät mallin jäännösvarianssia $\hat{\sigma}^2$. Jäännösvarianssin tulee pienentyä enemmän kuin "rankaisutermin" $2(p + q)/T$ kasvaa. Kokeen aineiston kohdalla AIC suosittelee AR(1)-mallia.

Todetaan lisäksi, että sopivalta vaikuttavan AR(1)-mallin regressiotulostus on tällainen (Survon eikä PcGiven tulostus; niiden estimointitulokset eroavat hieman ilmeisesti koska PcGiven optimointifunktio on eri; havainnot):

$$y_t = \begin{matrix} 0,004 \\ (1,082) \end{matrix} + \begin{matrix} 0,712y_{t-1} \\ (9,104) \end{matrix} + \hat{\varepsilon}_t,$$

$$T = 83, R^2 = 0,51, \sigma^2 = 0,0009$$

Estimaattien alla on niiden t -arvot ja muut merkinnät ovat ilmeiset. Todetaanpa vielä, että mallin mukaan

$$E(y_t) = \frac{0,004}{1 - 0,712} \approx 1,014.$$

Asuntojen hinnat nousevat siis mallin mukaan keskimäärin 1,4 % neljännesvuodessa.

Aivan lopuksi tutkitaan AR(1)-mallin residuaalien mahdollista autokorreloituneisuutta Box–Ljung-testisuurella:

Viive	Box–Ljung-testisuure
1	(0,167)
2	0,231
3	0,242
4	2,185
5	2,187
6	4,159
7	4,183
8	5,648
9	5,881
10	7,254
11	14,669
12	17,213

Testisuure noudattaa asymptoottisesti approksimatiivisesti $\chi^2(k-p-q)$ -jakaumaa (ei eksaktisti edes asymptoottisesti, jos $p + q > 0$!). (Ensimmäinen luku on su-luissa, koska sitä "pitäisi" verrata " $\chi^2(0)$ -jakaumaan".) Lisäksi k :n pitäisi olla suuri. Testisuure lienee siis järkevintä laskea kahteentoista autokorrelaatioon perustuen. Koska 17,213 on noin $\chi^2(12 - 1)$ - eli $\chi^2(11)$ -jakauman 90. persentiili, niin nollahypoteesi jäännösten autokorrelaottomuudesta jää voimaan tavallisella 5 prosentin riskitasolla.

2. Perustellaan ensiksi vihjeessä annetut yhtäsuuruudet:

$$\begin{aligned}\sum_{t=1}^T (y_t - \bar{y}) &= \sum_{t=1}^T y_t - T\bar{y} \\ &= T\bar{y} - T\bar{y} \\ &= 0\end{aligned}$$

ja

$$\begin{aligned}\sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2 &= \sum_{t=1}^T y_{t-1}^2 - 2\bar{y}_{-1} \sum_{t=1}^T y_{t-1} + T\bar{y}_{-1}^2 \\ &= \sum_{t=1}^T y_{t-1}^2 - 2T\bar{y}_{-1}^2 + T\bar{y}_{-1}^2 \\ &= \sum_{t=1}^T y_{t-1}^2 - T\bar{y}_{-1}^2.\end{aligned}$$

Derivoidaan uskottavuusfunktio [5.2.27] ($t = 1, \dots, T; y_1 \rightarrow y_0$) c :n suhteen, asetetaan derivaatta nolaksi ja ratkaistaan $\hat{c}(\phi)$:

$$\begin{aligned}\frac{\partial l(c, \phi)}{\partial c} &\stackrel{5.2.27}{=} \frac{\partial}{\partial c} \left[-\frac{T}{2} \log 2\pi - \frac{T}{2} \log \sigma^2 - \sum_{t=1}^T \frac{(y_t - c - \phi y_{t-1})^2}{2\sigma^2} \right] \\ &= -\sigma^{-2} \sum_{t=1}^T (y_t - c - \phi y_{t-1})(-1) = 0 \quad \Leftrightarrow\end{aligned}$$

$$\begin{aligned}\sum_{t=1}^T (y_t - c - \phi y_{t-1}) &= 0 \quad \Leftrightarrow \\ \hat{c}(\phi) &= T^{-1} \sum_{t=1}^T y_t - \phi T^{-1} \sum_{t=1}^T y_{t-1} \\ &= \bar{y} - \phi \bar{y}_{-1}.\end{aligned}$$

Derivoidaan uskottavuusfunktio [5.2.27] ($t = 1, \dots, T; y_1 \rightarrow y_0$) ϕ :n suhteen, asetetaan derivaatta nolaksi ja ratkaistaan $\hat{\phi}(c)$:

$$\begin{aligned}\frac{\partial l(c, \phi)}{\partial \phi} &\stackrel{\text{ylt\u00e4}}{=} -\sigma^{-2} \sum_{t=1}^T (y_t - c - \phi y_{t-1})(-y_{t-1}) = 0 \Leftrightarrow \\ \sum_{t=1}^T (y_t - c - \phi y_{t-1})y_{t-1} &= 0 \quad \Leftrightarrow \\ \hat{\phi}(c) &= \frac{\sum_{t=1}^T (y_t - c)y_{t-1}}{\sum_{t=1}^T y_{t-1}^2}.\end{aligned}$$

Sijoittamalla $\hat{\phi}(c)$ $\hat{c}(\phi)$:n kaavaan saadaan

$$\hat{c} = \hat{c}(\hat{\phi}) = \bar{y} - \hat{\phi} \bar{y}_{-1}.$$

Vastaavasti sijoittamalla $\hat{c}(\phi)$ $\hat{\phi}(c)$:n kaavaan saadaan:

$$\begin{aligned}\hat{\phi} = \hat{\phi}(\hat{c}) &= \frac{\sum_{t=1}^T [y_t - (\bar{y} - \hat{\phi} \bar{y}_{-1})] y_{t-1}}{\sum_{t=1}^T y_{t-1}^2} \\ &= \frac{\sum_{t=1}^T (y_t - \bar{y}) y_{t-1} - T \hat{\phi} \bar{y}_{-1}}{\sum_{t=1}^T y_{t-1}^2} \Leftrightarrow\end{aligned}$$

$$\left[1 - \frac{T \bar{y}_{-1}}{\sum_{t=1}^T y_{t-1}^2} \right] \hat{\phi} = \frac{\sum_{t=1}^T y_{t-1}^2 - T \bar{y}_{-1}}{\sum_{t=1}^T y_{t-1}^2} \hat{\phi} = \frac{\sum_{t=1}^T (y_t - \bar{y}) y_{t-1}}{\sum_{t=1}^T y_{t-1}^2} \Leftrightarrow$$

$$\begin{aligned}\hat{\phi} &= \frac{\sum_{t=1}^T (y_t - \bar{y}) y_{t-1}}{\sum_{t=1}^T y_{t-1}^2 - T \bar{y}_{-1}^2} \\ &\stackrel{\text{vihje}}{=} \frac{\sum_{t=1}^T (y_t - \bar{y})(y_{t-1} - \bar{y}_{-1})}{\sum_{t=1}^T y_{t-1}^2 - T \bar{y}_{-1}^2} \\ &\stackrel{\text{vihje}}{=} \frac{\sum_{t=1}^T (y_t - \bar{y})(y_{t-1} - \bar{y}_{-1})}{\sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2}.\end{aligned}$$

Otoskorrelaatiokerroin (r) y_t :n ja y_{t-1} :n välillä on

$$r = \frac{\sum_{t=1}^T (y_t - \bar{y})(y_{t-1} - \bar{y}_{-1})}{\sqrt{\sum_{t=1}^T (y_t - \bar{y})^2} \sqrt{\sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2}}.$$

Osoittaja on täsmälleen sama kuin $\hat{\phi}$:n osoittaja. Elleivät y_0 tai y_T ole kovin poikkeuksellisia tai T erityisen pieni pätee $\sum_{t=1}^T (y_t - \bar{y})^2 \approx \sum_{t=1}^T (y_{t-1} - \bar{y}_{-1})^2$. Näin ollen r :n nimittäjä on noin $\hat{\phi}$:n nimittäjä. Täten $\hat{\phi} \approx r$.

3.

a) Merkitään $\beta' = [c \quad \phi]$ ja $\hat{\beta} = [\hat{c}_{pns} \quad \hat{\phi}_{pns}]'$. Estimoitava malli on

$$\mathbf{y} = \mathbf{X}\beta + \mathbf{u},$$

jossa $\mathbf{y} = [y_1, \dots, y_T]'$, \mathbf{X} on $T \times 2$ -matriisi, jonka ensimmäinen sarake koostuu ykkösistä ja toisen sarakkeen elementit ovat y_0, \dots, y_{T-1} ja $\mathbf{u} = [\varepsilon_1 \dots \varepsilon_T]'$. PNS-estimaattori on $\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$. Näin ollen

$$E(\hat{\beta}) = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}] = E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'(\mathbf{X}\beta + \mathbf{u})] = \beta + E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}].$$

Odotusarvo-operaattoria ei voida viedä viimeisen termin sisälle, koska sekä \mathbf{X} -matriisin että \mathbf{u} -vektorin termit ovat satunnaismuuttujia, jotka eivät ole toisistaan riippumattomia. \mathbf{X}' -matriisin toinen rivi (y_0, \dots, y_{T-1}) ja \mathbf{u} -vektori ($\varepsilon_1, \dots, \varepsilon_T$) korreloivat, koska $y_t = \sum_{i=1}^t \phi^{t-i} \varepsilon_i + \phi^t y_0$ (HT 8.3 a). Selvästikin ylipäänsä $E[(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{u}] \neq 0$, joten $E(\hat{\beta}) \neq \beta$.

b) $E(\hat{\phi}_{pns}) \approx \phi - (2\phi)/T$, kun mallissa ei ole vakiota:

ϕ	$T = 25$	$T = 100$
-0,9	-0,83	-0,88
-0,33	-0,30	-0,32
0	0	0
0,33	0,30	0,32
0,9	0,83	0,88

Kommentointia: $\hat{\phi}_{pns}$ on harhaton, kun $\phi = 0$. Kun ϕ on lähellä -1 :tä tai 1 :tä, on $\hat{\phi}_{pns}$ harhainen kohti nollaa. Harha on itseisarvoltaan sama riippumatta ϕ :n etumerkistä. Harha pienenee, kun havaintojen lukumäärä kasvaa.

$E(\hat{\phi}_{pns}) \approx \phi - (1 + 3\phi)/T$, kun mallissa on vakio:

ϕ	$T = 25$	$T = 100$
-0,9	-0,83	-0,88
-0,33	-0,33	-0,33
0	-0,04	-0,01
0,33	0,25	0,31
0,9	0,75	0,86

Kommentointia: $\hat{\phi}_{pns}$ on harhaton, kun $\phi = -1/3$. Kun ϕ on lähellä -1 :tä tai 1 :tä, on $\hat{\phi}_{pns}$ harhainen kohti nollaa. Harha (sen itseisarvo) on suurempi, kun $\phi > 0$ ja se on erityisen suurta, kun ϕ on lähellä yhtä. Harha on lähellä

-1 :tä samansuuruista kuin mallissa ilman vakiota. Positiivisilla ϕ :n arvoilla harha on paljon suurempaa kuin mallissa ilman vakiota. Harha pienenee, kun havaintojen lukumäärä kasvaa.

Huomautus 1: Approksimaatioiden tarkkuus heikkenee lähestyttäessä ϕ :n arvoja -1 tai 1 . Approksimaatioiden tarkkuus paranee, kun havaintojen lukumäärä kasvaa.

Huomautus 2: Marriotin ja Popen tuloksen perusteella voidaan konstruoida approksimatiivisesti harhaton estimaattori ϕ :lle. Simulointikokeiden mukaan sen varianssi on suurempi kuin PNS-estimaattorin. Harhakorjatun estimaatin keskineliövirhe on pienempi tai suurempi kuin PNS-estimaattorin riippuen ϕ :n arvosta. Harhakorjattua estimaattoria ei ole käytetty paljon ekonometrisessä kirjallisuudessa. Harhan pienentämistä käsittelevä tutkimus on edelleen aktiivista.

Huomautus 3: Shaman ja Stine (1988)¹ ovat johtaneet vastaavia kaavoja PNS-estimaattorin harhalle, kun prosessi on $AR(p)$.

¹The Bias of Autoregressive Coefficient Estimators, Journal of the American Statistical Association, 83, 842-848.