

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 4 vastaukset (5.10.)

1.

a) Odotusarvo ei riipu ajankohdasta:

$$\begin{aligned} E(y_t) &= E(y_1) \\ &= \mu. \end{aligned}$$

Varianssi ei riipu ajankohdasta:

$$\begin{aligned} \gamma_0 &= \text{var}(y_t) \\ &= \text{var}(y_1) \\ &= E(y_1^2) - [E(y_1)]^2 \\ &= E[(\mu + \varepsilon_1)^2] - \mu^2 \\ &= \mu^2 + 2\mu E(\varepsilon_1) + E(\varepsilon_1^2) - \mu^2 \\ &= \sigma^2. \end{aligned}$$

Autokovarianssit eivät riipu ajankohdasta:

$$\begin{aligned} \gamma_j &= \text{cov}(y_t, y_{t-j}) \\ &= E\{[y_t - E(y_t)][y_{t-j} - E(y_{t-j})]\} \\ &\stackrel{E(y_i)=\mu}{=} E[(y_t - \mu)(y_{t-j} - \mu)] \\ &\stackrel{y_t=y_1}{=} E[(y_1 - \mu)(y_1 - \mu)] \\ &= E(y_1^2) - \mu E(y_1) - \mu E(y_1 - \mu) \\ &= E[(\mu + \varepsilon_1)^2] - \mu^2 - 0 \\ &= \mu^2 + 2\mu E(\varepsilon_1) + E(\varepsilon_1^2) - \mu^2 \\ &= \sigma^2. \end{aligned}$$

Prosessi  $\{y_t\}_{t=1}^{\infty}$  on heikosti stationaarinen, koska sen 1. ja 2. momentit eivät riipu ajankohdasta ( $t$ ).

Huom. Tutkija tarvitsisi monia reaalisatioita prosessista, jotta hän pääsisi jyvälle sen luonteesta!

b) Autokorrelaatiot  $\rho_j$  ovat

$$\begin{aligned} \rho_j &= \frac{\gamma_j}{\gamma_0} \\ &\stackrel{\text{a)}}{=} \frac{\sigma^2}{\sigma^2} \\ &= 1, \quad j = 0, 1, 2, \dots \end{aligned}$$

Autokorrelaatio on 1 eli vakio kaikille viipeille. Riippuvuus menneistä havainnoista on mahdollisimman suurta. Autokorrelaatiot eivät kuoleennu edes suurilla viipeen  $j$  arvoilla.

Kohdan a) mukaan prosessi on heikosti stationaarinen. Näin ollen heikosti stationaarisen prosessin autokorrelaatiofunktio ei välttämättä kuoleennu suurilla viipeen  $j$  arvoilla!

Huom. Tyypillisissä — kirjassa esillä olleissa tilanteissa — heikosti stationaarisen prosessin autokorrelaatiot konvergoivat nollaan suurilla  $j$ :n arvoilla.

2.

a) ”Standarditilanteessa”, jolloin prosessin innovaatiot  $\varepsilon_t \sim \text{IID}(0, \sigma^2)$ , on MA( $q$ )-prosessi ( $q < \infty$ ) aina heikosti stationaarinen (kirjan s. 51). (Jos innovaatioilla ei ole momentteja — esim. innovaatiot noudattavat Cauchy-jakaumaa — niin MA( $q$ )-prosessi ei ole heikosti stationaarinen.

b) MA( $\infty$ )-prosessi ei ole aina heikosti stationaarinen. Esimerkiksi jos ” $\theta_j = \psi_j$ -kertoimet” eivät ole neliöllisesti summautuvia, niin prosessilla ei ole äärellistä varianssia eikä se ole heikosti stationaarinen (s. 52).

c) & d) Vastaesimerkki. Noudattakoon  $y_t$  MA( $q$ )-prosessia

$$y_t = \varepsilon_t + \theta_q \varepsilon_{t-q},$$

jossa  $q > 1$ ,  $\theta_q \neq 0$  ja  $\varepsilon_t \sim \text{IID}(0, \sigma^2)$  (” $\theta_1 = \dots = \theta_{q-1} = 0$ ”). On helppo osoittaa, että

$$\begin{aligned} E(y_t) &= 0, \\ E(y_t^2) &= (1 + \theta_q) \sigma_\varepsilon^2 > 0, \\ E(y_t y_{t-1}) &= 0 \end{aligned}$$

ja

$$\begin{aligned} \gamma_q \stackrel{E(y_t)=0}{=} E(y_t y_{t-q}) &= E(\varepsilon_t + \theta_q \varepsilon_{t-q})(\varepsilon_{t-q} + \theta_q \varepsilon_{t-2q}) \\ &= E(\theta_q \varepsilon_{t-q}^2) \\ &= \theta_q \sigma^2 \\ &\neq 0. \end{aligned}$$

Prosessi ei ole siis autokorreloimaton kaikilla viipeillä eikä ole valkoista kohinaa. (Erään suomalaisen aikasarja-analyysin kurssin luentomonisteesta määriteltiin valkoinen kohina tehtävän mukaisesti. Varmaan painovirhe.)

3.

$$\begin{aligned} \sum_{i=0}^{\infty} |\psi_i| < \infty & \Rightarrow \\ \sum_{i=j}^{\infty} |\psi_i| < \infty \quad (j \geq 1) & \Rightarrow \\ \sum_{i=0}^{\infty} \psi_i \psi_{i+j} & < \\ \sum_{i=0}^{\infty} |\psi_i \psi_{i+j}| & = \sum_{i=0}^{\infty} |\psi_i| |\psi_{i+j}| \\ & < \sum_{i=0}^{\infty} |\psi_i| \sum_{i=j}^{\infty} |\psi_{i+j}| \\ & < \infty. \end{aligned}$$

Ytimekkäin vastaus olisi, että kaavan [3.3.19] mukaan (todistus kirjan s:lla 70) autokovarianssien itseisarvojen summa on äärellinen, jos  $\psi_j$ -kertoimet ovat absoluuttisesti summautuvia, joten varmasti yksittäiset autokorrelaatiotkin ovat. Argumentin taustalla on kuitenkin tämän harjoitustehtävän tapainen todistus.

4.

a)

$$\mathbf{E}(y_t) = \mathbf{E}(\beta t + \varepsilon_t) = \mathbf{E}(\beta t) + \mathbf{E}(\varepsilon_t) = \mathbf{E}(\beta t) + 0 = \beta t.$$

Odotusarvo muuttuu ajassa ( $\beta \neq 0$ ). Prosessi  $y_t = \beta t + \varepsilon_t$  ei siis ole heikosti stationaarinen (ellei  $\beta = 0$ ).

b)

$$\mu = \mathbf{E}(y_t - \beta t) = 0,$$

$$\gamma_0 = \mathbf{var}(y_t - \beta t) = \mathbf{E}[(y_t - \beta t)^2] = \mathbf{E}(\varepsilon_t^2) = \sigma^2$$

ja

$$\gamma_j = \mathbf{cov}[y_t - \beta t, y_{t-j} - \beta(t-j)] = \mathbf{cov}(\varepsilon_t, \varepsilon_{t-j}) = \mathbf{E}(\varepsilon_t \varepsilon_{t-j}) = 0,$$

kun  $j \neq 0$ . Prosessi  $y_t - \beta t = \varepsilon_t$  on siis heikosti stationaarinen.

c)

$$\mathbf{E}(y_t) = \beta \sin(t).$$

Odotusarvo muuttuu ajankohdasta toiseen ( $\beta \neq 0$ ). Prosessi ei ole heikosti stationaarinen.

d)

$$\mu = \mathbf{E}(y_t^{(i)}) = \sin(t) \mathbf{E}(\beta^{(i)}) = \sin(t) * 0 = 0.$$

$$\begin{aligned} \mathbf{var}(y_t^{(i)}) &= \mathbf{E}[(y_t^{(i)} - \mu)^2] = \mathbf{E}\{[\beta^{(i)} \sin(t) + \varepsilon_t - 0]^2\} \\ &= \mathbf{E}[\beta^{(i)} \sin(t)]^2 + \mathbf{E}(\varepsilon_t^2) + 2\mathbf{E}\{[\beta^{(i)} \sin(t)]\varepsilon_t\} \\ &\stackrel{\perp}{=} [\sin^2(t) \mathbf{E}[\beta^{(i)}]^2] + \sigma^2 + 0 \\ &= \sigma_\beta^2 \sin^2(t) + \sigma^2. \end{aligned}$$

Prosessin odotusarvo on vakio, mutta sen varianssi ei ole. Prosessi ei siis ole heikosti stationaarinen.

e)

$$\begin{aligned} \mu &= \mathbf{E}(y_t^{(i)}) = [\sin(t)] \mathbf{E}(\beta_1^{(i)}) + [\cos(t)] \mathbf{E}(\beta_2^{(i)}) + \mathbf{E}(\varepsilon_t) \\ &= 0 * \sin(t) + 0 * \cos(t) + 0 \\ &= 0. \end{aligned}$$

$$\begin{aligned}
\gamma_0 &= \mathbf{E}(y_t^{(i)} - \mu)^2 \\
&= \mathbf{E}[\beta_1^{(i)} \sin(t) + \beta_2^{(i)} \cos(t) + \varepsilon_t - 0]^2 \\
&= \mathbf{E}[\beta_1^{(i)} \sin(t) + \beta_2^{(i)} \cos(t)]^2 + 2\mathbf{E}\{[\beta_1^{(i)} \sin(t) + \beta_2^{(i)} \cos(t)]\varepsilon_t\} + \mathbf{E}(\varepsilon_t^2) \\
&= \mathbf{E}[\beta_1^{(i)2}] \sin^2(t) + 2\mathbf{E}(\beta_1^{(i)} \beta_2^{(i)}) \sin(t) \cos(t) + \mathbf{E}[\beta_2^{(i)2}] \cos^2(t) + 0 + \sigma^2 \\
&\stackrel{\perp}{=} \sigma_\beta^2 \sin^2(t) + 2 * 0 * \sin(t) \cos(t) + \sigma_\beta^2 \cos^2(t) + \sigma^2 \\
&= \sigma_\beta^2 [\sin^2(t) + \cos^2(t)] + \sigma^2 \\
&= \sigma_\beta^2 + \sigma^2.
\end{aligned}$$

$$\begin{aligned}
\gamma_j &= \mathbf{E}[(y_t^{(i)} - \mu)(y_{t-j}^{(i)} - \mu)] \\
&= \mathbf{E}\{[\beta_1^{(i)} \sin(t) + \beta_2^{(i)} \cos(t) + \varepsilon_t - 0][\beta_1^{(i)} \sin(t-j) + \beta_2^{(i)} \cos(t-j) + \varepsilon_{t-j} - 0]\} \\
&= \mathbf{E}\{[\beta_1^{(i)} \sin(t)][\beta_1^{(i)} \sin(t-j) + \beta_2^{(i)} \cos(t-j) + \varepsilon_{t-j}]\} \\
&\quad + \mathbf{E}\{[\beta_2^{(i)} \cos(t)][\beta_1^{(i)} \sin(t-j) + \beta_2^{(i)} \cos(t-j) + \varepsilon_{t-j}]\} \\
&\quad + \mathbf{E}\{\varepsilon_t[\beta_1^{(i)} \sin(t-j) + \beta_2^{(i)} \cos(t-j) + \varepsilon_{t-j}]\} \\
&= [\sin(t)]\{[\sin(t-j)]\mathbf{E}[\beta_1^{(i)2}] + [\cos(t-j)]\mathbf{E}(\beta_1^{(i)} \beta_2^{(i)}) + \mathbf{E}(\beta_1^{(i)} \varepsilon_{t-j})\} \\
&\quad + [\cos(t)]\{[\sin(t-j)]\mathbf{E}(\beta_1^{(i)} \beta_2^{(i)}) + [\cos(t-j)]\mathbf{E}[\beta_2^{(i)2}] + \mathbf{E}(\beta_2^{(i)} \varepsilon_{t-j})\} \\
&\quad + [\sin(t-j)]\{\mathbf{E}(\varepsilon_t \beta_1^{(i)}) + [\cos(t-j)]\mathbf{E}(\varepsilon_t \beta_2^{(i)}) + \mathbf{E}(\varepsilon_t \varepsilon_{t-j})\} \\
&\stackrel{\perp}{=} [\sin(t)][\sin(t-j)]\sigma_\beta^2 + 0 + 0 \\
&\quad + 0 + [\cos(t)][\cos(t-j)]\sigma_\beta^2 + 0 \\
&\quad + 0 + 0 + 0 \\
&= \sigma_\beta^2 \{[\cos(t)][\cos(t-j)] + [\sin(t)][\sin(t-j)]\} \\
&\quad \left\langle \begin{array}{l} \cos(x) \cos(y) + \sin(x) \sin(y) = \cos(x-y); \\ \text{valitaan yllä } x = t \text{ ja } y = t-j \end{array} \right\rangle \\
&\quad = \sigma_\beta^2 \{\cos[(t - (t-j))]\} \\
&\quad = \sigma_\beta^2 [\cos(j)].
\end{aligned}$$

Prosessin odotusarvo ( $\mathbf{E}(y_t^{(i)}) = 0$ ), varianssi ( $\text{var}(y_t) = \mathbf{E}[(y_t^{(i)})^2] - [\mathbf{E}(y_t^{(i)})]^2 = \sigma_\beta^2 - 0^2 = \sigma_\beta^2$ ) ja autokovarianssit ( $\gamma_j = \sigma_\beta^2 \cos(j)$ ) ovat vakioita. Prosessi on siis heikosti stationaarinen.  $\beta_1^{(i)}$ - ja  $\beta_2^{(i)}$ -parametrien odotusarvoa ja varianssia ei voi selvittää yhden aikasarjan avulla.

Huom. Prosessi on heikosti stationaarinen, vaikka asetettaisiin  $\varepsilon_t \equiv 0$ . Tällöin yksittäistä aikasarjaa voitaisiin ennustaa äärettömän tarkasti mielivaltaisen kaukaiseen tulevaisuuteen!

5.

a) Ehtojen merkitys:

- $|\phi| < 1$  eli prosessi on stationaarinen,
- $|\theta| < 1$  eli prosessi on kääntyvä ja
- $\phi \neq -\theta$  eli viivepolynomit eivät supistu pois (niillä ei ole yhteisiä juuria) eli malli on parsimoninen.

b) Vihjeen mukaisesti kerrotaan kaava (3)  $y_{t-j}$ :llä ja hyödynnetään stationaarisuusoletusta — odotusarvoja laskettaessa:

$$(1 - \phi L)y_t = (1 + \theta L)\varepsilon_t,$$

joten

$$\begin{aligned} \mathbf{E}(y_t y_{t-j} - \phi y_{t-1} y_{t-j}) &= \mathbf{E}(\varepsilon_t y_{t-j} + \theta \varepsilon_{t-1} y_{t-j}) && \Leftrightarrow \\ \gamma_j &\stackrel{\mathbf{E}(y_t)=0}{=} \phi \gamma_{j-1} + \mathbf{E}(y_{t-j} \varepsilon_t) + \theta \mathbf{E}(y_{t-j} \varepsilon_{t-1}). && (*) \end{aligned}$$

Kaksi viimeistä odotusarvoa ovat selvästikin nollija, kun  $j > 1$ . Ehdon pätiessä jakamalla alempi yhtälö (vielä tuntemattomalla)  $\gamma_0$ :lla saadaan toinen väitteistä:

$$\frac{\gamma_j}{\gamma_0} = \phi \frac{\gamma_{j-1}}{\gamma_0} \Leftrightarrow \rho_j = \phi \rho_{j-1}, \quad j > 1.$$

Kun  $j = 1$ , pätee

$$\begin{aligned} \gamma_1 &\stackrel{(*)}{=} \phi \gamma_0 + \mathbf{E}(y_{t-1} \varepsilon_t) + \theta \mathbf{E}(y_{t-1} \varepsilon_{t-1}) \\ &\stackrel{(3)}{=} \phi \gamma_0 + 0 + \theta \mathbf{E}[(\phi y_{t-2} + \varepsilon_{t-1} + \theta \varepsilon_{t-2}) \varepsilon_{t-1}] && (**) \\ &= \phi \gamma_0 + \theta(0 + \sigma^2 + 0) \\ &= \phi \gamma_0 + \theta \sigma^2. \end{aligned}$$

Kun  $j = 0$ , pätee

$$\begin{aligned} \gamma_0 &= \phi \gamma_{-1} + \mathbf{E}(y_t \varepsilon_t) + \theta \mathbf{E}(y_t \varepsilon_{t-1}) \\ &\stackrel{(3) \& \text{stat.}}{=} \phi \gamma_1 + \mathbf{E}[(\phi y_{t-1} + \varepsilon_t + \theta \varepsilon_{t-1}) \varepsilon_t] + \theta \mathbf{E}[(\phi y_{t-1} + \varepsilon_t + \theta \varepsilon_{t-1}) \varepsilon_{t-1}] \\ &= \phi \gamma_1 + (0 + \sigma^2 + 0) + (\theta \phi \sigma^2 + 0 + \theta^2 \sigma^2) \\ &= \phi \gamma_1 + (1 + \theta \phi + \theta^2) \sigma^2. && (***) \end{aligned}$$

Sijoitetaan yltä  $\gamma_1$  yo. kaavaan  $\gamma_0$ :lle:

$$\begin{aligned} \gamma_0 &= \phi(\phi \gamma_0 + \theta \sigma^2) + (1 + \theta \phi + \theta^2) \sigma^2 \Leftrightarrow \\ \gamma_0 &= \frac{\phi \theta + 1 + \theta \phi + \theta^2}{1 - \phi^2} \sigma^2 \\ &= \frac{1 + 2\phi \theta + \theta^2}{1 - \phi^2} \sigma^2. \end{aligned}$$

Sijoitetaan tämä  $\gamma_1$ :n kaavaan:

$$\begin{aligned}
\gamma_1 &= \phi \frac{1 + 2\phi\theta + \theta^2}{1 - \phi^2} \sigma^2 + \theta \sigma^2 \\
&= \frac{\phi + 2\phi^2\theta + \phi\theta^2 + \theta - \phi^2\theta}{1 - \phi^2} \sigma^2 \\
&= \frac{(1 + \phi\theta)(\phi + \theta)}{1 - \phi^2} \sigma^2. \\
\rho_1 = \frac{\gamma_1}{\gamma_0} &= \frac{\frac{(1 + \phi\theta)(\phi + \theta)}{1 - \phi^2} \sigma^2}{\frac{1 + 2\phi\theta + \theta^2}{1 - \phi^2} \sigma^2} = \frac{(1 + \phi\theta)(\phi + \theta)}{1 + 2\phi\theta + \theta^2}.
\end{aligned}$$

Kaksi ylimääräistä huomiota:

1. Viimeinen tulos voitaisiin johtaa myös ratkaisematta eksplisiittisesti  $\gamma_0$ :aa tai  $\gamma_1$ :tä: Kaavoista (\*\*) ja (\*\*\*) saadaan, että

$$\begin{aligned}
\frac{\gamma_0 - \phi\gamma_1}{\gamma_1 - \phi\gamma_0} &= \frac{(1 + \theta\phi + \theta^2)\sigma^2}{\theta\sigma^2} \\
&= \frac{(1 + \theta\phi + \theta^2)}{\theta} && \Leftrightarrow \\
\theta(\gamma_0 - \phi\gamma_1) &= (\gamma_1 - \phi\gamma_0)(1 + \theta\phi + \theta^2) && \Leftrightarrow \\
[\phi\theta + (1 + \theta\phi + \theta^2)]\gamma_1 &= [\theta + \phi(1 + \theta\phi + \theta^2)]\gamma_0 && \Leftrightarrow \\
\rho_1 = \frac{\gamma_1}{\gamma_0} &= \frac{\theta + \phi(1 + \theta\phi + \theta^2)}{1 + 2\theta\phi + \theta^2} \\
&= \frac{(1 + \phi\theta)(\phi + \theta)}{1 + 2\theta\phi + \theta^2}.
\end{aligned}$$

2. Vaihtoehtoisesti — ja tarkistuksena — voidaan johtaa prosessin varianssi käyttämättä hyväksi stationaarisuusoletusta. Prosessin odotusarvo on

selvästikin nolla, joten prosessin varianssi on sen neliön odotusarvo:

$$\begin{aligned}
& E(y_t^2) \\
&= E[(1 - \phi L)^{-1}(1 + \theta L)\varepsilon_t]^2 \\
&\stackrel{|\phi| < 1}{=} E[(1 + \phi L + \phi^2 L^2 + \dots)(\varepsilon_t + \theta\varepsilon_{t-1})]^2 \\
&= E[(\varepsilon_t + \phi\varepsilon_{t-1} + \phi^2\varepsilon_{t-2} + \dots) + \theta(\varepsilon_{t-1} + \phi\varepsilon_{t-2} + \phi^2\varepsilon_{t-3} + \dots)] \\
&\quad \times [(\varepsilon_t + \phi\varepsilon_{t-1} + \phi^2\varepsilon_{t-2} + \dots) + \theta(\varepsilon_{t-1} + \phi\varepsilon_{t-2} + \phi^2\varepsilon_{t-3} + \dots)] \\
&\stackrel{i.i.d.}{=} E[(\varepsilon_t^2 + \phi^2\varepsilon_{t-1}^2 + \phi^4\varepsilon_{t-2}^2 + \dots) + \theta^2(\varepsilon_{t-1}^2 + \phi\varepsilon_{t-2}^2 + \phi^2\varepsilon_{t-3}^2 + \dots) \\
&\quad + 2\theta\phi(\varepsilon_{t-1}^2 + \phi^2\varepsilon_{t-2}^2 + \phi^4\varepsilon_{t-3}^2 + \dots)] \\
&= \left[ \frac{1}{1 - \phi^2} + \frac{\theta^2}{1 - \phi^2} + \frac{\theta\phi}{1 - \phi^2} \right] \sigma^2 \\
&= \left[ \frac{1 + 2\theta\phi + \theta^2}{1 - \phi^2} \right] \sigma^2. \quad \%
\end{aligned}$$

ARMA( $p, q$ )-prosessin autokorrelaatiot noudattavat viipeestä  $q$  eteenpäin prosessin AR-osan mukaista differenssiyhtälöä (Hamilton s. 60). Tehtävän tilanteessa AR-osa on AR(1)-prosessin mukainen, joten viipeen 1 jälkeiset autokorrelaatiot noudattavat prosessin mukaista 1. asteen differenssiyhtälöä ( $\rho_j = \phi\rho_{j-1}$ ,  $j > 1$ ).

c) Kun  $\phi \approx 1$  ja  $\phi < 1$  on 1. autokorrelaatio

$$\rho_1|_{\phi \approx 1} \approx \frac{(1 + \phi\theta)(\phi + \theta)}{1 + 2\phi\theta + \theta^2} \Big|_{\phi \approx 1} \approx \frac{(1 + \theta)(1 + \theta)}{1 + 2\theta + \theta^2} = 1.$$

Seuraavat autokorrelaatiot noudattavat b)-kohdan mukaan differenssiyhtälöä

$$\rho_j = \phi\rho_{j-1}.$$

Kun  $\phi$  on lähellä yhtä, ovat myös  $\rho_2, \rho_3, \dots$  lähellä yhtä. Viipeen  $j$  kasvaessa autokorrelaatioiden täytyy kuitenkin kuoleentua lopulta eli mennä nol- laan, koska  $|\phi| < 1$ .

Huom! Lasku/väite

$$\lim_{\phi \rightarrow 1} \rho_1 = \lim_{\phi \rightarrow 1} \frac{(1 + \phi\theta)(\phi + \theta)}{1 + 2\phi\theta + \theta^2}$$

ei olisi järkevä, koska b)-kohdassa johdettu kaava  $\rho_1$ :lle oletti, että prosessi on stationaarinen ( $|\phi| < 1$ ).

d) Hyvin erilaiset autokorrelaatiofunktiot ovat mahdollisia, kun prosessi on ARMA(1,1). Ks. kuva 3.11 kirjassa Box ja Jenkins (1976): *Time Series Analysis: Forecasting and Control*.

Huomaa, että kohdan *iii*) autokorrelaatiofunktio saa vain negatiivisia arvoja, vaikka AR-kerroin on positiivinen. (1. autokorrelaatio on negatiivinen MA- kertoimen takia, ja seuraavat autokorrelaatiot noudattavat AR-osan määräämää differenssiyhtälöä.)