

# Lineaarinen prosessi

## Ei-kausaalinen lineaarinen prosessi

- MA(1)- tai MA(q)-prosessi on erikoistapaus yleisestä (ei-kausaalisesta) lineaarisesta prosessista

$$y_t = \sum_{j=-\infty}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid} (0, \sigma^2) \quad (2.3)$$

$$\sum_{j=-\infty}^{\infty} \psi_j^2 < \infty \quad (2.4)$$

- Ehto (2.4) takaa, että yhtälön (2.3) oikea puoli on hyvin määritelty osasummien jonon  $\sum_{j=-n}^n \psi_j \varepsilon_{t-j}$  kvadraattisena raja-arvona ( $n \rightarrow \infty$ ).
- Vahva stationaarisuus seuraa oletuksesta  $\varepsilon_t \sim \text{iid} (0, \sigma^2)$  ja ominaisuudesta VS4
- Heikko stationaarisuus laskemalla  $E(y_t)$ ,  $\text{Var}(y_t)$  ja  $\text{Cov}(y_t, y_{t+h})$

# Lineaarinen prosessi

## Kausaalinen lineaarinen prosessi

- Erikoistapauksena saadaan kausaalinen lineaarinen prosessi:

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid} (0, \sigma^2), \quad \sum_{j=0}^{\infty} \psi_j^2 < \infty$$

- Kuten ei-kausaaliossa tapauksessakin, havaittavan  $y_t$ :n ajatellaan syntyvän (mahdollisesti) äärettömän monen riippumattoman ja ei-havaittavan satunnaissokin painottuna summana.
- Erona ei-kausaaliseen tapaukseen on, että tulevat sokit  $\varepsilon_{t+j}$  ( $j > 0$ ) eivät vaikuta prosessin nykyiseen arvoon.
- Molemmissa tapauksissa kaukana nykyisyydestä olevien sokkien vaikutus on mitättömän pieni (koska  $\psi_j \rightarrow 0$ , kun  $|j| \rightarrow \infty$ ).
- Useat käytännössä paljon käytetyt prosessit voidaan esittää (kausaaliossa) lineaarisina prosesseina.

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Oletetaan, että kausaalisessa lineaarisessa prosessissa

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

pätee  $\psi_j = \phi^j$ , jossa  $|\phi| < 1$ .

- Vaadittu ehto  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  täyttyy, sillä

$$\sum_{j=0}^{\infty} \psi_j^2 = \sum_{j=0}^{\infty} \phi^{2j} = 1/(1 - \phi^2).$$

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Oletetaan, että kausaalisessa lineaarisessa prosessissa

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

pätee  $\psi_j = \phi^j$ , jossa  $|\phi| < 1$ .

- Vaadittu ehto  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  täyttyy, sillä

$$\sum_{j=0}^{\infty} \psi_j^2 = \sum_{j=0}^{\infty} \phi^{2j} = 1/(1 - \phi^2).$$

- Prosessi  $y_t$  voidaan määritellä myös käyttäen yhtälöä

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2), \quad |\phi| < 1. \quad (2.6)$$

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Oletetaan, että kausaalisessa lineaarisessa prosessissa

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

pätee  $\psi_j = \phi^j$ , jossa  $|\phi| < 1$ .

- Vaadittu ehto  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  täyttyy, sillä

$$\sum_{j=0}^{\infty} \psi_j^2 = \sum_{j=0}^{\infty} \phi^{2j} = 1/(1 - \phi^2).$$

- Prosessi  $y_t$  voidaan määritellä myös käyttäen yhtälöä

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2), \quad |\phi| < 1. \quad (2.6)$$

- Näin määriteltyä prosessia kutsutaan *ensimmäisen asteen autoregressiiviseksi prosessiksi* eli AR(1) prosessiksi.

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Oletetaan, että kausaalisessa lineaarisessa prosessissa

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2),$$

pätee  $\psi_j = \phi^j$ , jossa  $|\phi| < 1$ .

- Vaadittu ehto  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$  täyttyy, sillä

$$\sum_{j=0}^{\infty} \psi_j^2 = \sum_{j=0}^{\infty} \phi^{2j} = 1/(1 - \phi^2).$$

- Prosessi  $y_t$  voidaan määritellä myös käyttäen yhtälöä

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2), \quad |\phi| < 1. \quad (2.6)$$

- Näin määriteltyä prosessia kutsutaan *ensimmäisen asteen autoregressiiviseksi prosessiksi* eli AR(1) prosessiksi.
- Ilmeinen yleistys AR(p)-prosessi

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- AR(1)-prosessin tavallisesti käytetty määrittely

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2), \quad |\phi| < 1. \quad (2.6)$$

osoittaa, että prosessin nykyinen arvo riippuu lineaarisesti edellisen periodin arvosta ja ei-havaittavasta satunnaissokista tai virhetermistä aivan kuten lineaarisessa mallissa.

- Tässä ehdon  $|\phi| < 1$  tarpeellisuus nähdään johtamalla yhtälöstä (2.6) peräkkäisillä sijoituksilla yhtälö

$$y_t = \phi^k y_{t-k} + \sum_{j=0}^{k-1} \phi^j \varepsilon_{t-j}.$$

- Kun  $|\phi| < 1$ , johtaa tämä stationaariseen ratkaisuun

$$y_t = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j}.$$

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- AR(1)-prosessin lineaarisesta esityksestä

$$y_t = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j}, \quad \varepsilon_t \sim \text{iid} (0, \sigma^2), \quad |\phi| < 1,$$

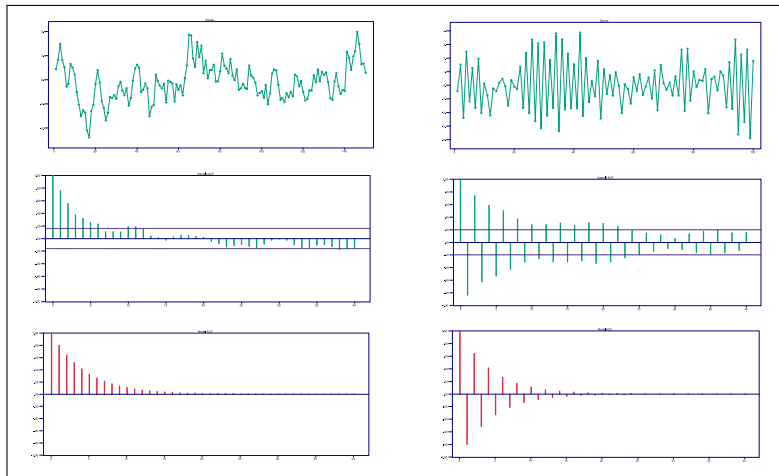
saadaan laskemalla

- $E(y_t) = 0,$
  - $\text{Var}(y_t) = \sigma^2 / (1 - \phi^2)$
  - $\text{Cov}(y_t, y_{t+h}) = \sigma^2 \phi^h / (1 - \phi^2).$
- Autokorrelaatiofunktio on näin ollen

$$\rho_h = \begin{cases} 1, & h = 0 \\ \phi^h, & h > 0. \end{cases}$$

- Toisin kuin MA(1)-prosessilla on autokorrelaatiofunktio nolasta poikkeava kaikilla viipymillä (ellei  $\phi = 0$ ).
- Ehto  $\gamma_h \rightarrow 0$ , kun  $h \rightarrow \infty$ , kuitenkin täyttyy.





**Kuvio 2.3.** Kaksi AR(1)-prosessista  $y_t = \phi y_{t-1} + \varepsilon_t$ ,  $\varepsilon_t \sim \text{nid}(0, 1)$ , simuloitua aikasarjaa ( $T = 150$ ), niiden otosautokorrelaatiofunktiot (keskellä) ja teoreettiset autokorrelaatiofunktiot (alinna) viipymillä  $h = 0, \dots, 40$ . Vasemmalla  $\phi = 0.8$  ja oikealla  $\phi = -0.8$ .

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Ehto  $|\phi| < 1$  takaa, että (stokastisella) differenssiyhtälöllä

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2)$$

on stationaarinen ratkaisu  $y_t = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j}$ .

- Tämä ehto ei kuitenkaan ole välttämätön stationaarisen ratkaisun olemassaololle.
- Ehdon  $|\phi| > 1$  voimassaollessa saadaan myös stationaarinen ratkaisu

$$y_t = - \sum_{j=1}^{\infty} \phi^{-j} \varepsilon_{t+j},$$

joka aikaisemmasta (kausaalisesta) ratkaisusta poiketen on ei-kausaalinen.

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- AR(1)-prosessilla

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

on stationaarinen ratkaisu, kun  $|\phi| < 1$  tai  $|\phi| > 1$  eli kun  $|\phi| \neq 1$ .

- Kun  $|\phi| = 1$ , ei stationaarista ratkaisua ole.
- Kun määrittely-yhtälössä aikaindeksi rajoitetaan positiiviseksi, voidaan kuitenkin määritellä AR(1)-prosessi

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

kaikilla  $\phi \in \mathbb{R}$ .

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- Tarkastellaan "yleistä" AR(1)-prosessia

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

- Peräkkäisillä sijoituksilla nähdään, että kaikilla  $\phi \in \mathbb{R}$

$$y_t = \phi^t y_0 + \sum_{j=0}^{t-1} \phi^j \varepsilon_{t-j}, \quad t = 1, 2, \dots$$

- Kun  $y_0 \perp\!\!\!\perp \{\varepsilon_t, t \geq 1\}$ , saadaan tästä laskelmalla

$$E(y_t) = \phi^t E(y_0) \quad \text{ja} \quad \text{Var}(y_t) = \phi^{2t} \text{Var}(y_0) + \sigma^2 \sum_{j=0}^{t-1} \phi^{2j},$$

mikä osoittaa epästationaarisuuden tapauksessa  $|\phi| = 1$ .

# Lineaarinen prosessi

## Toinen yksinkertainen erikoistapaus

- "Yleisen" AR(1)-prosessin (epästationaarista) erikoistapausta


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

sanotaan *satunnaiskuluksi*.

- Satunnaiskululle saadaan myös esitys

$$y_t = y_0 + \sum_{j=0}^{t-1} \varepsilon_{t-j}.$$

- Nähdään, että satunnaiskulun differenssit  $y_t - y_{t-1} = \varepsilon_t$  ovat stationaarisia ja sama pätee yleisesti, kun edellä  $\varepsilon_t$  on stationaarinen.
- Satunnaiskululla ja sen yleistyksillä on keskeinen asema epästationaaristen aikasarjojen analysoinnissa.



**Kuvio 2.4.** Satunnaiskulusta simuloitu 150:n havainnon realisaatio (vasemmalla) ja sen differenssi (oikealla), kun  $\varepsilon_t \sim \text{nid}(0, 1)$ .

# Lineaarinen prosessi

## Viivästysoperaattorin $B$ käyttö

- Määritellään mille tahansa prosessille (tai lukujonolle)  $x_t$  operaatio

$$Bx_t = x_{t-1}.$$

- Yleistetään tämä induktiivisesti  $B^2x_t = B(Bx_t) = Bx_{t-1} = x_{t-2}$  ja

$$B^k x_t = B(B^{k-1}x_t) = x_{t-k}, \quad B^0 x_t = x_t.$$

- Tapauksessa  $k < 0$  prosessia edistetään eli  $B^{-1}x_t = x_{t+1}$ ,  $B^{-2}x_t = x_{t+2}$  jne.
- Viivästysoperaattoria käyttäen voidaan määrittellä polynomeja ja sarjoja kuten

$$\theta(B) = 1 + \theta B \quad \text{ja} \quad \psi(B) = \sum_{j=-\infty}^{\infty} \psi_j B^j$$

ja operoida niillä aivan kuten  $B$ :n ollessa reaali- tai kompleksiluku.

- Lineaarinen prosessi voidaan määritellä yhtälöllä

$$y_t = \psi(B) \varepsilon_t, \quad \psi(B) = \sum_{j=-\infty}^{\infty} \psi_j B^j, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2).$$

- Operaattori  $\psi(B)$  ajatellaan usein *lineaariseksi suotimeksi*, joka suorittaa muunnoksen  $\{\varepsilon_t\} \rightarrow \{y_t\}$ .
- Erityisesti kausaalisessa tapauksessa  $\psi_j = 0, j < 0$ , sanotaan valkoista kohinaa  $\varepsilon_t$  tähän liittyen usein prosessin  $y_t$  *innovaatioksi*.
- Tärkeä erikoistapaus:  $\psi(B) = \sum_{j=0}^{\infty} \psi_j B^j = \theta(B) / \phi(B)$ , jossa  $\phi(B)$  ja  $\theta(B)$  ovat (äärellisasteisia) polynomeja ja

$$y_t = \frac{\theta(B)}{\phi(B)} \varepsilon_t.$$



- Esimerkiksi, kun  $\theta(B) = 1 + \theta B$  ja  $\phi(B) = 1 - \phi B$ ,  $|\phi| < 1$ ,

$$y_t = \frac{1 + \theta B}{1 - \phi B} \varepsilon_t.$$

- Kertomalla tässä puolittain  $(1 - \phi B)$ :llä saadaan

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

- eli

$$y_t = \phi y_{t-1} + \varepsilon_t + \theta \varepsilon_{t-1}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2). \quad (2.7)$$

- Näin määriteltyä prosessia sanotaan *ensimmäisen asteen autoregressiiviseksi-liukuvan keskiarvon prosessiksi* eli ARMA(1,1)-prosessiksi.
- Ilmeinen yleistys ARMA(p,q)-prosessi

- Kun  $|\phi| < 1$ , saadaan yhtälöstä

$$y_t = \phi y_{t-1} + \varepsilon_t + \theta \varepsilon_{t-1}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2). \quad (2.7)$$

kuten AR(1)-tapauksessa peräkkäisiä sijoituksia käyttäen, että  $y_t$ :llä on kausaalinen lineaarinen esitys

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j}.$$

- Formaalisti:

$$(1 - \phi B)y_t = (1 + \theta B)\varepsilon_t \quad | \quad (1 - \phi B)^{-1}.$$

- $\implies$

$$y_t = \frac{1 + \theta B}{1 - \phi B} \varepsilon_t = \psi(B) \varepsilon_t, \quad \psi(B) = \sum_{j=0}^{\infty} \psi_j B^j = \frac{1 + \theta B}{1 - \phi B}.$$

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

- $y_t$ :n määrittely-yhtälöstä seuraa

$$y_t + y_{t-2} = A [\cos(\lambda t) + \cos(\lambda(t-2))] + B [\sin(\lambda t) + \sin(\lambda(t-2))]$$

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

- $y_t$ :n määrittely-yhtälöstä seuraa

$$y_t + y_{t-2} = A [\cos(\lambda t) + \cos(\lambda(t-2))] + B [\sin(\lambda t) + \sin(\lambda(t-2))]$$

- jossa oikea puoli  $= 2 \cos(\lambda) y_{t-1}$  (sinin ja kosini summakaavat!).

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

- $y_t$ :n määrittely-yhtälöstä seuraa

$$y_t + y_{t-2} = A [\cos(\lambda t) + \cos(\lambda(t-2))] + B [\sin(\lambda t) + \sin(\lambda(t-2))]$$

- jossa oikea puoli =  $2 \cos(\lambda) y_{t-1}$  (sinin ja kosini summakaavat!).

- Pätee siis

$$y_t = 2 \cos(\lambda) y_{t-1} - y_{t-2}, \quad t = 0, \pm 1, \pm 2, \dots$$

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

- $y_t$ :n määrittely-yhtälöstä seuraa

$$y_t + y_{t-2} = A [\cos(\lambda t) + \cos(\lambda(t-2))] + B [\sin(\lambda t) + \sin(\lambda(t-2))]$$

- jossa oikea puoli  $= 2 \cos(\lambda) y_{t-1}$  (sinin ja kosini summakaavat!).

- Pätee siis

$$y_t = 2 \cos(\lambda) y_{t-1} - y_{t-2}, \quad t = 0, \pm 1, \pm 2, \dots$$

- Ts., kun  $y_{t-1}$  ja  $y_{t-2}$  (ja  $\lambda$ :n arvo) tunnetaan, voidaan  $y_t$ :n arvo ennustaa ilman minkäänlaista ennustevirhettä.

# Woldin hajotelma

## Esimerkki

- Tarkastellaan heikosti stationaarista prosessia (Esimerkki 2.1(ii))

$$y_t = A \cos(\lambda t) + B \sin(\lambda t), \quad t = 0, \pm 1, \pm 2, \dots, \quad \lambda \in [0, \pi) \quad (\text{vakio}),$$

$$E(A) = E(B) = 0, \quad \text{Var}(A) = \text{Var}(B) = \sigma^2 \quad \text{ja} \quad \text{Cov}(A, B) = 0.$$

- $y_t$ :n määrittely-yhtälöstä seuraa

$$y_t + y_{t-2} = A [\cos(\lambda t) + \cos(\lambda(t-2))] + B [\sin(\lambda t) + \sin(\lambda(t-2))]$$

- jossa oikea puoli  $= 2 \cos(\lambda) y_{t-1}$  (sinin ja kosini summakaavat!).

- Pätee siis

$$y_t = 2 \cos(\lambda) y_{t-1} - y_{t-2}, \quad t = 0, \pm 1, \pm 2, \dots$$

- Ts., kun  $y_{t-1}$  ja  $y_{t-2}$  (ja  $\lambda$ :n arvo) tunnetaan, voidaan  $y_t$ :n arvo ennustaa ilman minkäänlaista ennustevirhettä.
- Tällaista prosessia sanotaan *deterministiseksi*.



- Edellä tarkastellun deterministisen prosessin

$$y_t = 2 \cos(\lambda) y_{t-1} - y_{t-2}, \quad t = 0, \pm 1, \pm 2, \dots$$

yleistys:

- Tarkastellaan  $y_t$ :n ennustetta, joka on mikä tahansa prosessin aikaisempien arvojen  $y_{t-1}, y_{t-2}, \dots$  *lineaarinen* funktio.
- Ts., ennuste on muuttujien  $y_{t-1}, \dots, y_{t-n}$  lineaarikombinaatio tai tällaisten kvadraattinen raja-arvo, kun  $n \rightarrow \infty$ .
- Prosessia  $y_t$  sanotaan *deterministiseksi*, jos  $y_t$ :n arvo voidaan ennustaa (arvojen  $y_{t-1}, y_{t-2}, \dots$  lineaarisen funktion avulla) ilman minkäänlaista ennustevirhettä kaikilla  $t$ .
- Jos prosessi ei ole deterministinen, sitä sanotaan *ei-deterministiseksi*.

- Jokaisella *heikosti stationaarisella* ei-deterministisellä prosessilla  $y_t$  ( $t = 0, \pm 1, \pm 2, \dots$ ) on esitys

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j} + v_t,$$

- (i)  $\psi_0 = 1$ ,  $\sum_{j=0}^{\infty} \psi_j^2 < \infty$
- (ii)  $\varepsilon_t \sim \text{wn}(0, \sigma^2)$  on satunnaismuuttujien  $y_t, y_{t-1}, \dots$  lineaarikombinaatioiden kvadraattinen raja-arvo
- (iii)  $v_t$  on deterministinen ja voidaan ennustaa lineaarisesti satunnaismuuttujien  $y_{t-1}, y_{t-2}, \dots$  avulla ilman virhettä
- (iv)  $\text{Cov}(\varepsilon_t, v_s) = 0$  kaikilla  $t$  ja  $s$ .

- Woldin hajotelma osoittaa, että jokainen heikosti stationaarinen ei-deterministinen prosessi voidaan esittää deterministisen prosessin ja kausaalisen  $MA(\infty)$ -prosessin summana

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j} + v_t, \quad \varepsilon_t \text{ heikkoa, mutta ei vahvaa, valkoista kohinaa.}$$

- Kun havaitaan vain yksi realisaatio, voidaan deterministinen osa  $v_t$  tulkita ei-satunnaiseksi ja sisällyttää  $y_t$ :n odotusarvoon.
- Jatkossa oletetaan yleensä, ettei deterministisiä termejä ole, jolloin

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j} = \psi(B) \varepsilon_t$$

ja  $\psi(B) = \theta(B) / \phi(B)$  on rationaalinen, kun  $y_t \sim \text{ARMA}$ .

- ARMA-prosessien voidaan odottaa pystyvän kuvaamaan hyvin heikosti stationaarisia prosesseja. On kuitenkin syytä huomata, että ...

- **Huom.:** Woldin hajotelma

$$y_t = \sum_{j=0}^{\infty} \psi_j \varepsilon_{t-j} + v_t, \quad \varepsilon_t \sim \text{wn}(0, \sigma^2), \quad v_t \text{ deterministinen}$$

koskee vain *heikosti stationaarisia prosesseja* ja *lineaarista ennustamista*.

- On olemassa vahvasti stationaarisia prosesseja, joilla lineaarinen ennustaminen ei ole (keskineliövirheen mielessä) optimaalista.
- Tällaisilla prosesseilla Woldin hajotelmassa esiintyvä lineaarinen ennustevirhe  $\varepsilon_t$  ei ole riippumaton (eli iid( $0, \sigma^2$ )), vaikka se onkin autokorreloimaton (eli wn( $0, \sigma^2$ )).
- Optimaalisen ennusteen ennustevirhe on riippumaton, joten lineaarinen ennustaminen perustuu malliin, joka ei ota kaikkia prosessin satunnaispiirteitä huomioon.

# Otoskeskiarvon ja otosautokorrelaatiofunktion ominaisuuksia (oletetaan heikko ja vahva stationaarisuus)

- Otoskeskiarvolle  $\bar{y} = T^{-1} (y_1 + \dots + y_T)$  pätee  $E(\bar{y}) = \mu$  eli se on odotusarvon  $\mu = E(y_t)$  *harhaton estimaattori*.

# Otoskeskiarvon ja otosautokorrelaatiofunktion ominaisuuksia (oletetaan heikko ja vahva stationaarisuus)

- Otoskeskiarvolle  $\bar{y} = T^{-1} (y_1 + \dots + y_T)$  pätee  $E(\bar{y}) = \mu$  eli se on odotusarvon  $\mu = E(y_t)$  *harhaton estimaattori*.
- Lasketaan seuraavaksi

$$\text{Var}(\bar{y}) = \frac{1}{T} \sum_{h=-T}^T \left(1 - \frac{|h|}{T}\right) \gamma_h.$$

# Otoskeskiarvon ja otosautokorrelaatiofunktion ominaisuuksia (oletetaan heikko ja vahva stationaarisuus)

- Otoskeskiarvolle  $\bar{y} = T^{-1} (y_1 + \dots + y_T)$  pätee  $E(\bar{y}) = \mu$  eli se on odotusarvon  $\mu = E(y_t)$  *harhaton estimaattori*.
- Lasketaan seuraavaksi

$$\text{Var}(\bar{y}) = \frac{1}{T} \sum_{h=-T}^T \left(1 - \frac{|h|}{T}\right) \gamma_h.$$

- Kun oletetaan  $\sum_{h=-\infty}^{\infty} |\gamma_h| < \infty$ , saadaan tulos

$$\text{Var}(\bar{y}) = E(\bar{y} - \mu)^2 \leq \frac{1}{T} \sum_{h=-T}^T |\gamma_h| \rightarrow 0, \quad \text{kun } T \rightarrow \infty.$$

# Otoskeskiarvon ja otosautokorrelaatiofunktion ominaisuuksia (oletetaan heikko ja vahva stationaarisuus)

- Otoskeskiarvolle  $\bar{y} = T^{-1} (y_1 + \dots + y_T)$  pätee  $E(\bar{y}) = \mu$  eli se on odotusarvon  $\mu = E(y_t)$  *harhaton estimaattori*.
- Lasketaan seuraavaksi

$$\text{Var}(\bar{y}) = \frac{1}{T} \sum_{h=-T}^T \left(1 - \frac{|h|}{T}\right) \gamma_h.$$

- Kun oletetaan  $\sum_{h=-\infty}^{\infty} |\gamma_h| < \infty$ , saadaan tulos

$$\text{Var}(\bar{y}) = E(\bar{y} - \mu)^2 \leq \frac{1}{T} \sum_{h=-T}^T |\gamma_h| \rightarrow 0, \quad \text{kun } T \rightarrow \infty.$$

- Siis, otoskeskiarvo on (Markovin epäyhtälön perusteella) odotusarvon *tarkentuva estimaattori*.



$T^2 \text{Var}(\bar{y}) = \sum_{t=1}^T \sum_{s=1}^T \text{Cov}(y_t, y_s)$  on  $T \times T$  matriisin

$$\text{Cov}(y_1, \dots, y_T) = \begin{bmatrix} \gamma_0 & \gamma_1 & \cdots & \gamma_{t-s} & \cdots & \gamma_{T-1} \\ \gamma_{-1} & \gamma_0 & \ddots & & \ddots & \vdots \\ \vdots & \ddots & \ddots & \ddots & & \gamma_{t-s} \\ \gamma_{s-t} & & \ddots & \ddots & \ddots & \vdots \\ \vdots & \ddots & & \ddots & \ddots & \gamma_1 \\ \gamma_{T-1} & \cdots & \gamma_{s-t} & \cdots & \gamma_{-1} & \gamma_0 \end{bmatrix},$$

kaikkien alkioden summa eli yhtä kuin

$$\begin{aligned} & T\gamma_0 + (T-1)\gamma_1 + \cdots + \gamma_{T-1} \\ & \quad + (T-1)\gamma_{-1} + \cdots + \gamma_{-(T-1)} \\ = & \sum_{h=-T}^T (T-|h|)\gamma_h \end{aligned}$$