

- **Luennoija:** Pentti Saikkonen
- **Tyyppi ja laajuus:** Aineopinnot ja vaativammin suoritettuna syventävät opinnot, 8-10 op
- **Luentoajat:** I ja II periodi, ti 12-14, B120 ja to 12-14, B121
- **Suoritustapa:** Kahdella kurssikokeella tai erilliskokeella yleistentissä; aineopinnot 8 op. Laajennus syventäviin opintoihin 2 op:n harjoitustyöllä.
- **Laskuharjoitukset:** Henri Karttunen
 - I ja II periodi: to 10-12, C122
 - Lisäpisteitä harjoitustehtävien ratkaisemisesta saa 1, 2, ..., 7, jos ratkaistujen tehtävien määrä on vastaavasti 20, 30, ..., 80 prosenttia.

• Esitietovaatimukset

- Tilastollinen päättely II
- Lineaariset mallit I
- Edellisten vaatimat esitiedot

• Sisältö

- Aikasarja-analyysin peruskäsitteet
- ARMA-mallin ominaisuudet ja sillä ennustaminen
- ARMA-mallin rakentaminen; mallin valinta, parametrien estimointi ja testaus
- Finanssiaikasarjojen mallintamisessa käytettävät ARCH- GARCH- ja AR-GARCH-mallit


• Kirjallisuus ja muu kurssimateriaali

- Luentomoniste. Oheislukemistona voi käyttää soveltuvia osia teoksista:
- P.J. Brockwell & R.A. Davis: Introduction to Time Series and Forecasting. Springer, 1996, 2002 (2nd ed.).
- J. Hamilton: Time Series Analysis, Princeton University Press, 1994.
- P.H. Franses & D. van Dijk: Nonlinear Time Series Models in Empirical Finance, Cambridge University Press, 2000 (finanssiaikasarjoista).
- H. Lütkepohl & M. Krätzig (toim.): Applied Time Series Econometrics, Cambridge University Press, 2004. (JMulti-ohjelmistoon liittyvä kirja)

• Muuta


- Opiskeltavia malleja voi soveltaa esimerkiksi R:llä (koodit saatavissa kurssisivulta) tai ilmaiseksi saatavissa olevalla JMulti-ohjelmistolla (<http://www.jmulti.de/>).

- Aikasarja on havaintoaineisto, jossa havainnot on saatu peräkkäisinä ajankohtina: y_t , $t = 1, \dots, T$, jossa t on ajankohta ja T havaintojen lukumäärä.
- Esimerkiksi vuosiaineistossa $t = 1970, \dots, 2005$ tai kuukausiaineistossa $t = 1970I, 1970II, \dots, 2005XII$.
- Tällä kurssilla oletetaan, että peräkkäiset ajankohdat ovat ajallisesti yhtä kaukana toisistaan tai niitä voidaan käsitellä sellaisina.
- Jos y_t on skalaari, puhutaan *yksiulotteisesta tai reaaliarvoisesta aikasarjasta*. Jos y_t on vektori, puhutaan *moniulotteisesta tai vektoriarvoisesta aikasarjasta*.
- Aikasarja-aineistoja analysoidaan useilla sovellusalueilla kuten taloustieteissä ja muissa yhteiskuntatieteissä, luonnontieteissä, insinööritieteissä ja lääketieteessä.




Kuvio 1.1. Australian tavaroiden ja palvelusten neljännesvuositainen tuonti ajanjaksolta 1959III - 1990IV (miljoonaa Australian dollaria).

- Ominaista nouseva *trendi*.




Kuvio 1.2. USA:ssa auto-onnettomuuksissa kuukausittain kuolleiden lukumäärä ajanjaksolta 1973I - 1978XII.

- Ei selvää nousevaa tai laskevaa trendiä.
- Sen sijaan selvä *kausivaihtelu*. Vuotuinen maksimi aina heinäkuussa ja minimi helmikuussa.



Kuvio 1.3. Australialaisen punaviinin kuukausittaisen myynnin volyyymi (tuhansina litroina) ajanjaksolta 1980I - 1991X.

- Sekä nouseva trendi että selvää kausivaihtelua.
- Vuotuinen huippu yleensä heinäkuussa, myynti alhaisimmillaan tammikussa. Myynnin vaihtelu kasvaa myynnin määrän kasvaessa (tai ajan kuluessa).



Kuvio 1.4. Vuotuisten auringonpilkkujen lukumäärä vuosilta 1770 - 1870.

- Ei trendiä eikä kausivaihtelua.
- *Syklistä* vaihtelua, jossa syklin luonne vaihtelee eri aikoina: Peräkkäisten huippujen välinen etäisyys ei ole vakio.
- Peräkkäisten havaintojen välillä positiivinen korrelaatio: Suuret havaintoarvot esiintyvät yleensä peräkkäin ja samoin pienet.

- **Aikasarja-analyysin tavoitteena** on usein rakentaa *tilastollinen malli*, jolla kuvataan havaittua aikasarjaa (aikasarjoja) ja sen (niiden) vaihtelua sekä peräkkäisten havaintojen välistä, yleensä ilmeistä, riippuvuutta.
- **Kun malli on valittu, voidaan**
 - estimoida sen parametrit
 - tarkistaa estimoidun mallin ja havaintojen yhteensopivuus
 - testata parametreja koskevia hypoteeseja
 - käyttää mallia ajateltuun tarkoitukseen.

- **Mallia voidaan käyttää esimerkiksi**

- antamaan havaintoaineistosta *tiivistetty kuvaus*, joka auttaa ymmärtämään aineiston taustalla olevaa ilmiötä
- *ennustamaan* aikasarjan (aikasarjojen) tulevia arvoja - moniulotteisessa tapauksessa kysymyksessä on yhden aikasarjan ennustaminen muiden (selittävien) aikasarjojen avulla
- tutkimaan moniulotteisessa tapauksessa aikasarjojen välisten ajallisten *riippuvuuksia* - esim. punaviinin myynnin ja valkoviinin myynnin välistä riippuvuutta

- Ensiksi on aina syytä piirtää tarkasteltava aikasarja.
- Tällöin saadaan käsitys aikasarjan pääpiirteistä kuten trendistä ja/tai kausivaihtelusta ja/tai ilmeisistä äkillisistä muutoksista tai poikkeavista havainnoista, joita ei seuraavassa oleteta olevan.
- Monissa aikasarjamalleissa trendiä ja/tai säännöllistä kausivaihtelua ei oleteta olevan.
- Jos niitä on ja tällaisia malleja halutaan soveltaa, käytetään muunnettua aikasarjaa, jossa valitulla muunnoksella eliminoidaan nämä aikasarjan piirteet.
- Alkuperäisen aikasarjan kannalta katsoen trendi ja/tai kausivaihtelu mallinnetaan tällöin muunnoksella, joka voi vaatia parametrien estimointia.

- Lineaarisen trendin tapauksessa voidaan havaittuun aikasarjaan sovittaa pienimmän neliösumman (PNS) menetelmällä trendisuora ja siirtyä tarkastelemaan residuaalisarjaa.
- Havaittu aikasarja y_t korvataan tällöin aikasarjalla

$$\hat{x}_t = y_t - \hat{\alpha} - \hat{\beta}t, \quad t = 1, \dots, T,$$

jossa estimaatit $\hat{\alpha}$ ja $\hat{\beta}$ on laskettu PNS-menetelmällä. Lineaarisen funktion asemesta voidaan yleisempiä polynomeja.

- Kausivaihtelun mallintamiseen voidaan käyttää trigonometrisia ajan funktioita tai ns. *kausi-indikaattoreita*, jolloin esim. neljännesvuosiaineistossa käytetään residuaaliaikasarjaa

$$\hat{x}_t = y_t - \hat{\beta}_1 d_{1t} - \dots - \hat{\beta}_4 d_{4t}, \quad t = 1, \dots, T,$$

jossa i . kausi-indikaattori d_{it} saa arvon yksi, kun kysymyksessä on neljänneksen i havainto ja nolla muulloin ($i = 1, \dots, 4$).

- Muutokset eli differenssit:


$$y_t - y_{t-s}, \quad s \geq 1.$$

Tapaus $s = 1$ tavallisin; kausivaihtelun yhteydessä voi myös olla $s =$ kausivaihtelujakson pituus (esim. $s = 4$ tai $s = 12$).

- Usein differenssointiin yhdistetään logaritointi (olettaen $y_t > 0 \forall t$).
- Logaritointia suositetaan erityisesti, kun aikasarjassa on eksponentiaalinen trendi tai kun aikasarjan vaihtelu kasvaa tason kasvaessa.
- Logaritmisten differenssit voidaan tulkita suhteellisten muutosten indikaattoreiksi, sillä

$$\log y_t - \log y_{t-1} \approx (y_t - y_{t-1}) / y_{t-1},$$

kun muutos on pieni.



Kuvio 1.5. Australian tavaroiden ja palvelusten tuonti.

- Alkup. sarja (vas. ylh.), saman logaritmi, jossa trendi lähes lineaarinen (oik. ylh.) ja näiden differenssit (alh.), jossa vasemmalla vaihtelu kasvaa sarjan tason kasvaessa.

- Kurssilla tarkastellaan malleja, jotka olettavat, että havaitussa aikasarjassa ei ole trendiä tai että trendi on eliminoitu muunnoksella ja käytetään muunnettua sarjaa.
- Kurssilla ei tarkastella moniulotteisia aikasarjamalleja eikä malleja, joissa trendin mallinnus olisi varsinaisen mielenkiinnon kohteena.

- **Lähtökohta:** Tarkoituksena on rakentaa tilastollinen malli havaitulle yksiulotteiselle aikasarjalle y_1, \dots, y_T , jossa ei ole trendiä.
- Hyvin yleisellä tasolla havaittu aikasarja tulkitaan tällöin satunnaisvektorin $y = (y_1, \dots, y_T)$ havaituksi arvoksi eli *realisaatioksi*.
- **Huom.:** Samaa merkintää käytetään satunnaisille suureille ja niiden havaituille arvoille. Ero ymmärrettävä asiayhteydestä.

Stationaariset prosessit

Peruskäsitteitä

- Mallinnuksessa spesifioidaan havaitun aikasarjan "tuottaneen" satunnaisvektorin $y = (y_1, \dots, y_T)$ todennäköisyysjakauma.
- Havainnot eivät riippumattomia \Rightarrow komponenttien y_t ($t = 1, \dots, T$) reunajakaumien spesifiointi ei riitä.
- Konkreettisissa tilanteissa y :n yhteisjakauman spesifiointi tapahtuu yleensä spesifioimalla peräkkäisten havaintojen riippuvuutta kuvaava malliyhtälö, johon liitetään "sopiva" jakaumaoletus.

Stationaariset prosessit

Stokastisen prosessin käsite

- Matemaattisissa tarkasteluissa ja myös aikasarjamalleja määriteltäessä on kätevää tarkastella havaittua aikasarja vastaavan satunnaisvektorin $y = (y_1, \dots, y_T)$ "laajennusta".
- Diskreettiaikainen *stokastinen prosessi* (usein vain prosessi) on joukko satunnaismuuttujia

$$\{y_t; t = 0, \pm 1, \pm 2, \dots\}$$

tai toisinaan

$$\{y_t; t = 0, 1, 2, \dots\} \quad \text{tai} \quad \{y_t; t = 1, 2, \dots\}.$$

- Koska aikaindeksin arvojoukko on yleensä tiedossa, voidaan merkitä lyhyesti y_t tai $\{y_t\}$, jos halutaan korostaa eroa prosessin yksittäiseen komponenttiin.

Stationaariset prosessit

Stokastisen prosessin käsite

- Käytännön kannalta on merkityksellistä, että prosessista $\{y_t; t = 0, \pm 1, \pm 2, \dots\}$ on käytettävissä vain yksi havaittu realisaatio eli yksi havainto (y_1, \dots, y_T) .
- Lisäksi, prosessista $\{y_t; t = 0, \pm 1, \pm 2, \dots\}$ saatu havainto havaitaan vain osittain eli ajankohtina $t = 1, \dots, T$.
- Edellä sanotusta seuraa, ettei tarkasteltavan prosessin ominaisuuksia voida selvittää käytettävissä olevan havaintoaineiston y_1, \dots, y_T avulla ilman prosessia $\{y_t; t = 0, \pm 1, \pm 2, \dots\}$ koskevia rajoittavia oletuksia.

Stationaariset prosessit

Stokastisen prosessin 1. ja 2. momentit

- Tarkastellaan prosessin y_t *odotusarvofunktiota*

$$\mu_t = E(y_t), \quad t = 0, \pm 1, \pm 2, \dots$$

ja *kovarianssifunktiota*

$$\gamma_{s,t} = \text{Cov}(y_s, y_t) = E[(y_s - \mu_s)(y_t - \mu_t)], \quad t = 0, \pm 1, \pm 2, \dots$$

- Näiden funktioiden estimointi yhden realisaation avulla mahdotonta, ellei niiden riippuvuutta ajasta rajoiteta jotenkin.
- Oletaan, ettei tällaista ajallista riippuvuutta (tietyssä mielessä) ole.

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- Prosessi y_t on *heikosti stationaarinen tai kovarianssistationaarinen*, jos

$$E(y_t) = \mu \quad \text{kaikilla } t = 0, \pm 1, \pm 2, \dots$$

ja

$$\text{Cov}(y_t, y_{t+h}) = \gamma_{t,t+h} = \gamma_{0,h} \quad \text{kaikilla } h, t = 0, \pm 1, \pm 2, \dots$$

- Ts., pätee *aikainvarianttius*: Odotusarvofunktio μ_t on ajassa vakio ja kovarianssifunktio $\gamma_{s,t}$ ei riipu ajankohdista s ja t , vaan pelkästään niiden välisestä etäisyydestä $t - s$. Merkitään lyhyesti $\gamma_{0,h} = \gamma_h$. Erityisesti,

$$\gamma_0 = \text{Var}(y_t).$$

- γ_h :ta kutsutaan y_t :n *autokovarianssikertoimeksi* viipymällä h ja h :n funktiona y_t *autokovarianssifunktioksi*. μ :tä nimitetään *odotusarvoksi*.

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- Autokovarianssifunktiolla on ominaisuudet

$$\gamma_0 \geq 0, \quad |\gamma_h| \leq \gamma_0 \quad \text{ja} \quad \gamma_h = \gamma_{-h}.$$

Tapaus $\gamma_0 = 0$ mielenkiinnoton \Rightarrow oletetaan $\gamma_0 > 0$.

- Käytännössä käytetään yleensä *autokorrelaatiofunktiota*

$$\rho_h = \text{Cor}(y_t, y_{t+h}) = \gamma_h / \gamma_0.$$

- *Autokorrelaatiokertoimilla* ρ_h on ilmeiset ominaisuudet

$$\rho_0 = 1, \quad |\rho_h| \leq 1 \quad \text{ja} \quad \rho_h = \rho_{-h}.$$

- Sekä autokovarianssifunktiota että autokorrelaatiofunktiota riittää siis tarkastella vain viipymilla $h \geq 0$ (jälkimmäistä viipymillä $h > 0$).

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- Heikon stationaarisuuden takaama aikainvarianttius \Rightarrow
 $E(y_t) = \mu$ ja $\text{Cor}(y_t, y_{t+h}) = \gamma_h$ ilmeisesti mahdollista estimoida.
- Ongelmana vielä, että autokorrelaatiofunktiossa on yleisesti ottaen ääretön määrä estimoitavia suureita, joita kaikkia ei voida käytännössä estimoida.
- Yleensä voidaan kuitenkin olettaa, että

$$\gamma_h \rightarrow 0, \quad \text{kun } h \rightarrow \infty.$$

- Tällöin satunnaismuuttujat y_t ja y_{t+h} ovat lähes korreloimattomia, kun h on "suuri" eli kun y_t ja y_{t+h} ovat ajallisesti "kaukana" toisistaan.
- Käytännössä riittää siten estimoida autokorrelaatiofunktio ρ_h , kun $h = 1, \dots, H$ ja H on niin suuri, että $\rho_h \approx 0$, kun $h > H$.

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- Oletetaan, että y_t on *heikosti stationaarinen*.

$$\text{Tällöin } E(y_1) = \dots = E(y_T) = \mu$$

ja luonteva odotusarvon estimaattori on otoskeskiarvo

$$\bar{y} = \frac{1}{T} \sum_{t=1}^T y_t.$$


- Tällöin on myös $\text{Cov}(y_1, y_{1+h}) = \dots = \text{Cov}(y_{T-h}, y_T) = \gamma_h$ ($h \geq 0$) ja $E(y_t) = E(y_{t+h})$,

joten luonteva autokovarianssikertoimen γ_h estimaattori on

$$c_h = \frac{1}{T-h} \sum_{t=1}^{T-h} (y_t - \bar{y})(y_{t+h} - \bar{y}), \quad 0 \leq h < T,$$


ja luonteva autokorrelaatiofunktion estimaattori on siten

$$r_h = c_h/c_0, \quad 0 \leq h < T.$$




Kuvio 1.4. Vuotuisten auringonpilkkujen lukumäärä vuosilta 1770 - 1870.

- Ei trendiä eikä kausivaihtelua.
- *Syklistä* vaihtelua, jossa syklin luonne vaihtelee eri aikoina: Peräkkäisten huippujen välinen etäisyys ei ole vakio.
- Peräkkäisten havaintojen välillä positiivinen korrelaatio: Suuret havaintoarvot esiintyvät yleensä peräkkäin ja samoin pienet.



Kuvio 1.2. USA:ssa auto-onnettomuuksissa kuukausittain kuolleiden lukumäärä ajanjaksolta 1973I - 1978XII.

- Ei selvää nousevaa tai laskevaa trendiä.
- Sen sijaan selvä *kausivaihtelu*. Vuotuinen maksimi aina heinäkuussa ja minimi helmikuussa.



Kuvio 2.1. Auringonpilkkusarjan otosautokorrelaatiofunktio (vasemmalla) ja onnettomuussarjan otosautokorrelaatiofunktio (oikealla) viipymillä $h = 0, \dots, 40$.

- Yksittäinen estimaattori r_h kuuluu likimain 95%:n todennäköisyydellä kuvioihin piirrettyjen rajojen väliin, jos $\rho_h = 0$ kaikilla $h > 0$

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- **Esimerkki 2.1.**(i) Prosessi ε_t on (*heikko*) *valkoinen kohina*, jos

$$E(\varepsilon_t) = \mu, \quad \text{Var}(\varepsilon_t) = \sigma^2 < \infty \quad \text{ja} \quad \text{Cov}(\varepsilon_s, \varepsilon_t) = 0, \quad \text{kun } s \neq t.$$

- $E(\varepsilon_t)$ on t :stä riippumaton vakio ja

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+h}) = \begin{cases} \sigma^2, & \text{kun } h = 0 \\ 0, & \text{kun } h \neq 0, \end{cases}$$

joten heikko stationaarisuus on määritelmän nojalla ilmeinen.

- Yksinkertaisuudestaan huolimatta keskeinen prosessi, sillä sen avulla voidaan määritellä monimutkaisempia prosesseja.

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- **Esimerkki 2.1.**(ii) Määritellään prosessi

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

jossa satunnaismuuttujat A ja B toteuttavat

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

- Tällöin

$$E(y_t) = 0 \text{ ja } \text{Cov}(y_t, y_{t+h}) = \sigma^2 \cos(\lambda h) \text{ riippuu vain } h\text{:sta,}$$

joten y_t on heikosti stationaarinen (perustelu jätetään tehtäväksi).

- Realisaatiot $\cos(\lambda t)$:n ja $\sin(\lambda t)$:n lineaarikombinaatioita.
- Huomaa, että ehto $\gamma_h \rightarrow 0$, kun $h \rightarrow \infty$ ei päde.

Stationaariset prosessit

Stokastisen prosessin heikko stationaarisuus

- Heikko stationaarisuus on sikäli havainnollinen käsite, että sen realistisuutta voidaan arvioida katsomalla havaitun aikasarjan kuvaa.
- Jos havainnot vaihtelevat vakiovarianssilla kiinteän tason ympärillä, voidaan heikkoa stationaarisuutta pitää kohtuullisena oletuksena.
- Heikko stationaarisuus ei kuitenkaan riitä aikasarjamallien tilastolliseen analysointiin, sillä se ei yksistään mahdollista uskottavuusfunktion muodostamista eikä estimaattorien ja testisuureiden jakaumien tutkimista.
- Tästä syystä määritellään heikkoa stationaarisuutta vahvempi stationaarisuuden muoto.

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- Prosessin $\{y_t; t = 0, \pm 1, \pm 2, \dots\}$ sanotaan olevan *vahvasti stationaarinen*, jos satunnaismuuttujilla

$$y_{t_1}, \dots, y_{t_m} \quad \text{ja} \quad y_{t_1+h}, \dots, y_{t_m+h}$$

on sama m -ulotteinen yhteisjakauma kaikilla kokonaisluvuilla t_1, \dots, t_m, h ja m ($m > 0$).

- Ts., prosessin prosessin y_t koko todennäköisyysstruktuuri (ei vain ensimmäiset ja toiset momentit) on aikainvariantti.

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- Jos y_t on vahvasti stationaarinen, niin

$$(y_{t_1}, \dots, y_{t_m}) \sim (y_{t_1+h}, \dots, y_{t_m+h}) \text{ kaikilla } t_1, \dots, t_m, h \text{ ja } m (m > 0).$$

- Pätee siis,

VS1 Satunnaismuuttujat y_t ovat samoin jakautuneita $\forall t$.

VS2 Satunnaisvektorit (y_t, y_{t+h}) ja (y_s, y_{s+h}) ovat samoin jakautuneita kaikilla t ja s ja jokaisella (kiinteällä) h .

VS3 y_t on heikosti stationaarinen, jos $E(y_t^2) < \infty$.

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- Prosessi y_t (ei välttämättä missään mielessä stationaarinen) on *normaalinen*, jos satunnaismuuttujien y_{t_1}, \dots, y_{t_m} m -ulotteinen todennäköisyysjakauma on normaalinen kaikilla kokonaisluvuilla t_1, \dots, t_m ja m ($m > 0$).
- Koska ensimmäiset ja toiset momentit määräävät normaalijakauman täysin, seuraa heikosta stationaarisuudesta ja prosessin normaalisuudesta vahva stationaarisuus.
- Yleisesti heikosta stationaarisuudesta ei seuraa vahva stationaarisuus (heikko stationaarisuus ei esim. rajoita toista kertalukua korkeampia momenteja).
- Vahvasta stationaarisuudesta ei seuraa heikko stationaarisuus, jos $E(y_t^2) = \infty$ (vrt. esim. Cauchyn jakauma).

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- Vahva stationaarisuus (toisin kuin heikko) säilyy funktiomuunnoksissa:

VS4 Jos z_t on vahvasti stationaarinen prosessi, niin samoin on prosessi

$$y_t = g(z_{t+m}, \dots, z_{t-n}), \quad m, n \geq 0,$$

millä tahansa "siistillä" (eli esim. jatkuvalla tai yleisemmin ns. mitallisella) funktiolla g . Lisäksi m :n tai n :n tai molempien paikalla voi olla ∞ .

- Kun m ja n ovat äärellisiä seuraa ominaisuus VS4 jokseenkin suoraan vahvan stationaarisuuden määritelmästä.
- Ellei stationaarisuuden luonnetta täsmennetä, tulkitaan stationaarisuus jatkossa vahvaksi stationaarisuudeksi (ei yleisesti käytössä oleva tulkinta).

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- **Esimerkki 2.2.**(i) Olkoon ε_t jono riippumattomia ja samoin jakautuneita satunnaismuuttujia kertymäfunktiona $F(\cdot)$.
- Tämä prosessi on vahvasti stationaarinen ja sitä kutsutaan *vahvaksi valkoiseksi kohinaksi*.
- Jos $E(\varepsilon_t^2) < \infty$, on ε_t myös heikko valkoinen kohina eli pätee
$$E(\varepsilon_t) = \mu, \quad \text{Var}(\varepsilon_t) = \sigma^2 < \infty \quad \text{ja} \quad \text{Cov}(\varepsilon_s, \varepsilon_t) = 0, \quad \text{kun } s \neq t.$$
- Kun $E(\varepsilon_t^2) < \infty$, käytetään tästä prosessista lyhennystä
$$\varepsilon_t \sim \text{iid}(\mu, \sigma^2),$$
jossa $\mu = E(\varepsilon_t)$ ja $\sigma^2 = \text{Var}(\varepsilon_t)$ (jatkossa yleensä $\mu = 0$).
- Jos edellisessä oletetaan lisäksi $\varepsilon_t \sim N(\mu, \sigma^2)$, merkitään
$$\varepsilon_t \sim \text{nid}(\mu, \sigma^2).$$

Stationaariset prosessit

Stokastisen prosessin vahva stationaarisuus

- **Esimerkki 2.2.**(ii) Määritellään prosessi

$$y_t = \varepsilon_t \sqrt{\omega + \alpha \varepsilon_{t-1}^2}, \quad \omega > 0, \quad \alpha \geq 0 \quad \text{ja} \quad \varepsilon_t \sim \text{iid} (0, \sigma^2).$$

- Laskemalla nähdään, että y_t on heikko valkoinen kohina.
- Koska $y_{t-1} = \varepsilon_{t-1} \sqrt{\omega + \alpha \varepsilon_{t-2}^2}$, on selvää, ettei y_t ole tapausta $\alpha = 0$ lukuun ottamatta vahva valkoinen kohina.
- Heikosta valkoisesta kohinasta, jolle siis pätee

$$E(\varepsilon_t) = \mu, \quad \text{Var}(\varepsilon_t) = \sigma^2 < \infty \quad \text{ja} \quad \text{Cov}(\varepsilon_s, \varepsilon_t) = 0, \quad \text{kun} \quad s \neq t,$$

käytetään merkintää $\varepsilon_t \sim \text{wn}(\mu, \sigma^2)$ ($\text{wn} \leftrightarrow$ 'white noise').

Lineaarinen prosessi

Yksinkertainen erikoistapaus

- Valkoisen kohinan avulla määritellä monimutkaisempia prosesseja.
- Yksinkertainen esimerkki on *ensimmäisen asteen liukuvan keskiarvon prosessi* eli MA(1)-prosessi (MA \leftrightarrow 'moving average')

$$y_t = \varepsilon_t + \theta\varepsilon_{t-1}, \quad \varepsilon_t \sim \text{iid} (0, \sigma^2), \quad (2.2)$$

- Prosessin saamien arvojen oletetaan syntyvän kahden riippumattoman ja ei-havaittavan satunnaissokin painotettuna summana.
- MA(1)-prosessi on vahvasti stationaarinen (ks. Esimerkki 2.2(i) ja ominaisuus VS4) ja myös heikko stationaarisuus pätee.
- Ilmeinen yleistys on MA(q)-prosessi

Lineaarinen prosessi

Yksinkertainen erikoistapaus

- Laskemalla nähdään, että MA(1)-prosessin

$$y_t = \varepsilon_t + \theta\varepsilon_{t-1}, \quad \varepsilon_t \sim \text{iid}(0, \sigma^2), \quad (2.2)$$

1. ja 2. momentit ovat (myös oletuksella $\varepsilon_t \sim \text{wn}(0, \sigma^2)$)

$$E(y_t) = 0, \quad \text{Var}(y_t) = \sigma^2(1 + \theta^2)$$


ja

$$\text{Cov}(y_t, y_{t+h}) = \begin{cases} \theta\sigma^2, & h = 1 \\ 0, & h > 1 \text{ (tai } h < -1). \end{cases}$$

- Autokorrelaatiofunktio on siten

$$\rho_h = \begin{cases} 1, & h = 0 \\ \theta / (1 + \theta^2), & h = 1 \\ 0, & h > 0. \end{cases}$$

- MA(1)-prosessille on siis ominaista, että autokorrelaatiofunktiossa on katkos viipymällä yksi.



Kuvio 2.2. Kaksi MA(1)-prosessista $y_t = \varepsilon_t + \theta\varepsilon_{t-1}$, $\varepsilon_t \sim \text{nid}(0, 1)$, simuloitua aikasarjaa ($T = 150$), niiden otosautokorrelaatiofunktiot (keskellä) ja teoreettiset autokorrelaatiofunktiot (alinna) viipymillä $h = 0, \dots, 40$. Vasemmalla $\theta = 0.8$ ja oikealla $\theta = -0.8$.