

# Ehdollisen varianssin mallintaminen

## GARCH( $r,s$ )-malli

- GARCH(1,1)-mallin ilmeinen yleistys on GARCH( $r,s$ )-malli,

$$y_t = h_t^{1/2} \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, 1)$$

$$h_t = \omega + \beta_1 h_{t-1} + \cdots + \beta_r h_{t-r} + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2$$

- Ehdon  $h_t > 0$  takaamiseksi oletetaan usein ehdot

$$\omega > 0, \quad \alpha_i \geq 0, \quad i = 1, \dots, s, \quad \beta_i \geq 0, \quad i = 1, \dots, r,$$

jotka eivät kuitenkaan ole välttämättömiä, ellei  $r = s = 1$ .

- Lisäksi, ainakin yksi parametreista  $\alpha_1, \dots, \alpha_s$  nollasta poikkeava, jottei differenssiyhtälöstä tulisi ei-satunnainen.

$$\begin{aligned}h_t &= \omega + \beta_1 h_{t-1} + \cdots + \beta_r h_{t-r} + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2 \\ &= \omega + \beta(B) h_t + \alpha(B) y_{t-1}^2,\end{aligned}$$

jossa  $\beta(B) = \beta_1 B + \cdots + \beta_r B^r$  ja  $\alpha(B) = \alpha_1 B + \cdots + \alpha_s B^s$ .

- Siis,

$$(1 - \beta(B)) h_t = \omega + \alpha(B) y_{t-1}^2.$$

- Parametrien estimointi vaatii identifioituv. ehdon (vrt. ARMA-malli):  
Polynomeilla  $\alpha(z)$  ja  $1 - \beta(z)$  ei ole yhteisiä juuria ja joko  $\alpha_s$  tai  $\beta_r$  on nolasta poikkeava.

- Yhtälö  $h_t = \omega + \beta_1 h_{t-1} + \dots + \beta_r h_{t-r} + \alpha_1 y_{t-1}^2 + \dots + \alpha_s y_{t-s}^2 \Rightarrow$

$$y_t^2 = \omega + \sum_{j=1}^m (\alpha_j + \beta_j) y_{t-j}^2 + \xi_t - \sum_{j=1}^r \beta_j \xi_{t-j}, \quad (*)$$

jossa  $m = \max\{r, s\}$ ,  $\alpha_j = 0$ , jos  $j > s$ , ja  $\beta_j = 0$ , jos  $j > r$ .

Lisäksi,  $\xi_t = y_t^2 - h_t = h_t (\varepsilon_t^2 - 1)$ .

- (\*) voidaan esittää vaihtoehtoisesti

$$(1 - \beta(B) - \alpha(B)) y_t^2 = \omega + (1 - \beta(B)) \xi_t.$$

Stationaarisuus ja  $E(y_t^2) < \infty$ , jos  $1 - \beta(z) - \alpha(z) \neq 0$ ,  $|z| \leq 1$

eli kuten *ARMA( $p,q$ )-mallin vastaava tulos, josta tätä ei kuitenkaan voida päätellä.*

- GARCH(1,1)-mallin vahvan stationaarisuuden välttämätön ja riittävä ehto  $E [\log (\beta_1 + \alpha_1 \varepsilon_t^2)] < 0$  voidaan yleistää (monimutkaisesti) myös GARCH(r,s)-mallille.
- Kun polynomin  $1 - \beta(z)$  juuret sijaitsevat yksikköympyrän kehän ulkopuolella voidaan GARCH(r,s)-mallille johtaa ARCH( $\infty$ )-esitys:

$$(1 - \beta(B)) h_t = \omega + \alpha(B) y_{t-1}^2 \Rightarrow h_t = \frac{\omega}{1 - \beta(B)} + \frac{\alpha(B)}{1 - \beta(B)} y_t^2$$

- Kun  $E(y_t^4) < \infty$ , voidaan johtaa  $y_t^2$ :n autokorrelaatiofunktio ARMA(m,r)-esityksestä

$$y_t^2 = \omega + \sum_{j=1}^m (\alpha_j + \beta_j) y_{t-j}^2 + \zeta_t - \sum_{j=1}^r \beta_j \zeta_{t-j}, \quad \zeta_t \sim \text{wn}(0, \cdot).$$

- Ns. kynnyksmallissa muuttujan  $y_{t-1}$  etumerkin vaikuttavan ehdolliseen varianssiin:

$$h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2 + \pi \mathbf{1}(y_{t-1} > 0) y_{t-1}^2,$$

jossa  $\mathbf{1}(y_{t-1} > 0)$  saa arvon 1, kun  $y_{t-1} > 0$ , ja 0, kun  $y_{t-1} \leq 0$ .

- Lisäksi,  $\omega > 0$ ,  $\alpha \geq 0$ ,  $\beta \geq 0$  ja  $\alpha + \pi \geq 0$ , jotta  $h_t > 0$ .
- Stationaarisuus ja  $E(y_t^2) < \infty$  riippuvat virhetermin  $\varepsilon_t$  jakaumasta.
  - Symmetrisen jakauman tapauksessa vaaditaan  $\alpha + \beta + \pi/2 < 1$ .
- Osaketuottosarjoissa tyypillisesti  $\pi \leq 0$ , koska negatiivisten " uutisten" vaikutus on suurempi kuin positiivisten.

- Ns. EGARCH-mallissa ( $E \leftrightarrow$  'exponent') mallinnetaan  $\log h_t$ :tä:

$$\log h_t = \omega + \beta \log h_{t-1} + \alpha \varepsilon_{t-1} + \pi (|\varepsilon_{t-1}| - E(|\varepsilon_{t-1}|)).$$

Parametreille ei tarvitse asettaa ehtoja, jotta  $h_t > 0$  toteutuisi.

- Tässä mallissa voidaan prosessin  $\log h_{t-1}$  ja siten  $h_t$ :n ja  $y_t$ :n stationaarisuus päätellä kuten AR(1)-prosessin tapauksessa.
- Ehto  $|\beta| < 1$  takaa stationaarisuuden, koska

$$g(\varepsilon_{t-1}) = \alpha \varepsilon_{t-1} + \pi (|\varepsilon_{t-1}| - E(|\varepsilon_{t-1}|)) \sim \text{iid}(0, \cdot).$$

- Koska  $g(\varepsilon_{t-1})$  voidaan kirjoittaa

$$(\alpha + \pi)\varepsilon_{t-1}\mathbf{1}(\varepsilon_{t-1} > 0) + (\alpha - \pi)\varepsilon_{t-1}\mathbf{1}(\varepsilon_{t-1} \leq 0) - \pi E(|\varepsilon_{t-1}|)$$

on negatiivisten uutisten vaikutus  $\alpha - \pi$  ja positiivisten  $\alpha + \pi$ .

- Oletuksesta

$$y_t = h_t^{1/2} \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, 1)$$

seuraa

$$E_{t-1}(y_t) = 0,$$

joten prosessin  $y_t$  ennustaminen ei ole kiinnostava kysymys.

- Tarkastellaan sen sijaan ehdollisen varianssin  $h_t$  ennustamista GARCH(1,1)-tapauksessa olettaen vahva stationaarisuus.
- Ehdollisen varianssin määritelmä vaatii lisäksi ehdon  $E(y_{t+1}^2) < \infty$  ja ennusteen keskineliövirheen äärellisyys ehdon  $E(h_{t+1}^2) < \infty$  ja siten ehdon  $E(y_{t+1}^4) < \infty$ .

# Ehdollisen varianssin mallintaminen

## Ehdollisen varianssin ennustaminen

- Kun  $k \geq 2$ , niin  $h_{t+k}$ :n keskineliövirheen mielessä optimaalinen ennuste on

$$E_t(h_{t+k}) = \omega \sum_{j=0}^{k-2} (\alpha + \beta)^j + (\alpha + \beta)^{k-1} h_{t+1}, \quad k = 2, 3, \dots,$$

jossa  $h_{t+1}$  on funktio ennusteajankohtana tunnetuista muuttujista  $\{y_t, y_{t-1}, \dots\}$ .

- Käytännössä  $\omega$ ,  $\alpha$  ja  $\beta$  täytyy korvata estimaateilla.
- Nyt ennustettava suurekin ei-havaittava, mutta voidaan laskea yhtälön  $h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2$  avulla kaikilla  $t \geq 1$ , kunhan alkuarvot  $h_0$  ja  $y_0$  tunnetaan.
- $y_0$  voidaan olettaa tunnetuksi, mutta  $h_0$ :aa ei.  $h_0$  korvataan usein havaitusta aikasarjasta lasketulla otosvarianssilla.
- Stationarisessa tapauksessa alkuarvojen vaikutus häviää  $t$ :n kasvaessa.



# Ehdollisen varianssin mallintaminen

## Ehdollisen varianssin ennustaminen

- Yleisen  $GARCH(r,s)$ -mallin ennustaminen sujuu periaatteessa samalla tavalla kuin  $GARCH(1,1)$ -mallin, joskin kaavoista tulee monimutkaisempia.
- Ennusteiden luottamusvälien muodostaminen on myös monimutkaista mm. siksi, että ehdollisen varianssin jakauma on vahvasti normaalista poikkeava.

- Oletetaan, että

$$y_t = h_t^{1/2} \varepsilon_t, \quad \varepsilon_t \sim \text{nid}(0, 1),$$

jossa  $h_t = h(y_{t-1}, y_{t-2}, \dots)$  ja  $\varepsilon_t \perp\!\!\!\perp (y_{t-1}, y_{t-2}, \dots)$ .

Oletetaan lisäksi, että  $y_t$  on stationaarinen.

- Oletuksista seuraa

$$y_t | \{y_{t-j}, j \geq 1\} \sim y_t | h_t \sim N(0, h_t).$$

- Havaittu aikasarja  $y_{-l}, \dots, y_0, y_1, \dots, y_T$ , jossa ensimmäiset  $l$  havaintoa käytetään ehdollisten varianssien  $h_1, \dots, h_T$  arvojen laskemiseen.

- Esim. GARCH(1,1)-mallissa  $h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2 \Rightarrow l = 0$ .

- Merkitään

$$\mathbf{Y}_t = (\mathbf{Y}_0, y_1, \dots, y_t), \quad t = 1, \dots, T,$$

jossa  $\mathbf{Y}_0 = (y_{-l}, \dots, y_0, h_{-k}, \dots, h_0)$  sisältää myös ehdollisten varianssien  $h_1, \dots, h_T$  arvojen laskemisessa tarvittavat aikaisemmat ehdollisen varianssin arvot.

- Esim. GARCH(1,1)-mallissa

$$h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2 \Rightarrow \mathbf{Y}_0 = (h_0, y_0).$$

- Käyttäen ehdollisen tiheysfunktion kaavaa saadaan

$$\begin{aligned} f_{\mathbf{Y}_T} &= f_{y_T | \mathbf{Y}_{T-1}} \cdot f_{\mathbf{Y}_{T-1}} = f_{y_T | \mathbf{Y}_{T-1}} \cdot f_{y_{T-1} | \mathbf{Y}_{T-2}} \cdot f_{\mathbf{Y}_{T-2}} = \dots \\ &= \prod_{t=1}^T f_{y_t | \mathbf{Y}_{t-1}} \cdot f_{\mathbf{Y}_0}. \end{aligned}$$

# Ehdollisen varianssin mallintaminen

## GARCH-mallien parametrien estimointi

- Havaintojen yhteistiheysfunktio on siis

$$f_{\mathbf{Y}_T} = \prod_{t=1}^T f_{y_t | \mathbf{Y}_{t-1}} \cdot f_{\mathbf{Y}_0}.$$

- Alkuarvossa  $\mathbf{Y}_0 = (y_{-l}, \dots, y_0, h_{-k}, \dots, h_0)$  olevia ehdollisia variansseja ei käytännössä havaita eikä alkuarvon jakaumaakaan tunneta.
- Näin ollen,  $f_{\mathbf{Y}_0}$  jätetään pois uskottavuusfunktioista, joka perustetaan ehdolliseen tiheysfunktioon

$$\prod_{t=1}^T f_{y_t | \mathbf{Y}_{t-1}} = f_{\mathbf{Y}_T} / f_{\mathbf{Y}_0}$$

eli  $\mathbf{Y}_0$  tulkitaan ei-satunnaiseksi.

- Stationaarisuuden voimassa ollessa alkuarvo-oletuksen vaikutus on suurissa otoksissa mitätön.

# Ehdollisen varianssin mallintaminen

## GARCH-mallien parametrien estimointi

- Koska  $y_t | \{y_{t-j}, j \geq 1\} \sim N(0, h_t)$  ja  $\mathbf{Y}_{t-1} = (\mathbf{Y}_0, y_1, \dots, y_{t-1})$ , saadaan (ehd. jakauma riippuu  $\{y_{t-j}, j \geq 1\}$ :sta vain  $h_t$ :n kautta)

$$f_{y_t | \mathbf{Y}_{t-1}} = (2\pi)^{-1/2} h_t^{-1/2} \exp \left\{ -\frac{y_t^2}{2h_t} \right\}.$$

- Havaintojen ehdolliseksi yhteistiheysfunktioiksi saadaan siten

$$\prod_{t=1}^T f_{y_t | \mathbf{Y}_{t-1}} = (2\pi)^{-T/2} \cdot \prod_{t=1}^T h_t^{-1/2} \cdot \exp \left\{ -\frac{1}{2} \sum_{t=1}^T \frac{y_t^2}{h_t} \right\}$$

ja ehdolliseksi (tai approksimatiiviseksi) log-uskottavuusfunktioiksi

$$\tilde{l}(\delta) = -\frac{1}{2} \sum_{t=1}^T \log h_t(\delta) - \frac{1}{2} \sum_{t=1}^T \frac{y_t^2}{h_t(\delta)},$$

jossa esim. GARCH(1,1)-mallin tapauksessa  $\delta = (\omega, \alpha, \beta)$ .

- Log-uskottavuusfunktio

$$\tilde{l}(\delta) = -\frac{1}{2} \sum_{t=1}^T \log h_t(\delta) - \frac{1}{2} \sum_{t=1}^T \frac{y_t^2}{h_t(\delta)},$$

- Uskottavuusfunktion maksimointi vaatii samanlaisia numeerisia menetelmiä kuin ARMA(p,q)-mallissa.
- Ehdollisen varianssin arvojen  $h_1(\delta), \dots, h_T(\delta)$  laskeminen annetulla  $\delta$ :n arvolla vaatii alkuarvojen  $h_{-k}(\delta), \dots, h_0(\delta)$  valinnan (esim. aineistosta laskettu otosvarianssi).
- Jotkut algoritmit vaativat  $\tilde{l}(\delta)$ :n tai yhtäpitävästi  $h_t(\delta)$ :n ensimmäiset ja toiset derivaatat, jotka voidaan laskea aina numeerisesti. Monien mallien (esim. GARCH(r,s)) tapauksessa myös analyyttiset derivaatat voidaan laskea.

- Jos normaalisuusoletus eli

$$y_t = h_t^{1/2} \varepsilon_t, \quad \varepsilon_t \sim \text{nid}(0, 1),$$

pätee, pätevät SU-estimaattorin  $\hat{\delta}$  tavanomaiset asymptoottiset tulokset eli

$$\hat{\delta}_{as} \underset{as}{\sim} N\left(\delta, \mathbf{V}(\delta)^{-1}\right), \quad (*)$$

jossa  $\mathbf{V}(\delta) = E[-\partial^2 \tilde{l}(\delta) / \partial \delta \partial \delta']$ .

- $\mathbf{V}(\delta)$  on on (aproksimatiivisesta) log-uskottavuusfunktiosta muodostettu  $\delta$ :n Fisherin informaatiomatriisi ja  $-\partial^2 \tilde{l}(\delta) / \partial \delta \partial \delta'$  on vastaavasti havaittu informaatiomatriisi.
- (\*) pätee myös, kun havainnoista vähennetään otoskeskiarvo.

- Käytännössä erityisesti osake- ja valuuttakurssituotoilla residuaalien  $\hat{\varepsilon}_t = y_t / \hat{h}_t^{1/2}$  ( $\hat{h}_t^{1/2} = h_t^{1/2}(\hat{\delta})$ ) jakauman on usein havaittu olevan normaalijakaumaa huipukkaampi ja paksuhäntäisempi.
- Toisin kuin ARMA(p,q)-mallin tapauksessa normaalijakaumaan perustuva tulos

$$\hat{\delta} \underset{as}{\sim} N\left(\delta, \mathbf{V}(\delta)^{-1}\right), \quad \mathbf{V}(\delta) = E\left[-\partial^2 \tilde{l}(\delta) / \partial \delta \partial \delta'\right],$$

*ei päde, jos virhetermi  $\varepsilon_t$  on ei-normaalinen.*

- Tavanomaiseen uskottavuusteoriaan perustuvat keskivirheet, testit ja luottamusvälit ovat siten asymptoottisestikin pätemättömiä.



# Ehdollisen varianssin mallintaminen

## GARCH-mallien parametrien estimointi

- Jos normaalisuusoletus  $\varepsilon_t \sim N(0, 1)$  havaitaan virheelliseksi, voidaan ongelma yrittää ratkaista kahdella tavalla:
  - (i) Pitäytymällä (virheellisessä) normaalijakaumassa ja johtamalla estimaattorille  $\hat{\delta}$  oikea asymptoottinen jakauma
  - (ii) Käyttämällä (oikeaa) ei-normaalista jakaumaa.
- Vaikka edellisen tapauksen mukainen ratkaisu onkin mahdollinen, on syytä huomata, että ei-normaalissa tapauksessa estimaattori  $\hat{\delta}$  ei ole tehokas, vaikka se voidaankin todeta tarkentuvaksi ja asymptoottisesti normaaliseksi.