

- Yhtälöstä $h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2$ saadaan

$$y_t^2 = \omega + (\alpha + \beta)y_{t-1}^2 + \xi_t - \beta\xi_{t-1}, \quad (*)$$

jossa $\xi_t = y_t^2 - h_t = h_t (\varepsilon_t^2 - 1)$ ja jälleen $\xi_t \sim \text{wn}(0, \cdot)$.

- Ts., prosessilla y_t^2 on ARMA(1,1)-prosessin mukainen esitys ja GARCH(1,1)-mallin stationaarisuusehto $\alpha + \beta < 1$ ($\alpha, \beta \geq 0$) vastaa sitä mitä ARMA-mallien teorian perusteella voi odottaa.
- *Kuten aikaisemminkiaan, ehtoa $\alpha + \beta < 1$ ei voida perustella soveltamalla aikaisempia ARMA(1,1)-mallin tuloksista yhtälöön (*).*
- Samalla tavalla kuin ARCH(1)-mallissa nähdään, että välttämätön heikolle stationaarisuudelle on $\alpha + \beta < 1$ ja että tällöin $\sigma_y^2 = \omega / (1 - \alpha - \beta)$.

$$y_t^2 = \omega + (\alpha + \beta)y_{t-1}^2 + \zeta_t - \beta\zeta_{t-1}, \quad \zeta_t \sim \text{wn}(0, \cdot). \quad (*)$$

- Jos oletetaan stationaarisuus ja $E(y_t^4) < \infty$, voidaan johtaa y_t^2 :n autokorrelaatiofunktio, joka vaimenee nollaan viipymän kasvaessa eksponentiaalisesti.
- Vaimenemisen on sitä hitaampaa mitä lähempänä ykköstä $\alpha + \beta$ on.
- Ehto $\alpha + \beta < 1$ on riittävä vahvalle stationaarisuudella ja välttämätön ja riittävä heikolle stationaarisuudelle.
- Ehto $E[\log(\beta + \alpha\varepsilon_t^2)] < 0$ on välttämätön ja riittävä vahvalle stationaarisuudelle.
- Tästä seuraa $\beta < 1$ ja ehdosta $\alpha + \beta < 1$ poiketan se riippuu virhetermin ε_t jakaumasta.

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 α_s tai β_r on nolasta poikkeava.

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

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

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

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

- (*) voidaan esittää vaihtoehtoisesti

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

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(∞)-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 ε_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 ω , α ja β 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 $h_t = h_t(y_{t-1}, y_{t-2}, \dots)$ 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.

- Koska $y_t | \{y_{t-j}, j \geq 1\} \sim N(0, h_t)$ ja $\mathbf{Y}_{t-1} = (\mathbf{Y}_0, y_1, \dots, y_t)$, 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 δ :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

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

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

- $\mathbf{V}(\delta)$ on on (aproksimatiivisesta) log-uskottavuusfunktiosta muodostettu δ :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 ε_t on ei-normaalinen.

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

- 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.