

Ehdollisen varianssin mallintaminen

Mallin yleinen rakenne

- Kun y_t on osaketuotto ajankohtana t , kiinnostaa tietää millä todennäköisyydellä seuraavan periodin $t + 1$ tuotto y_{t+1} alittaa valitun riskituoton rajan c .
- Tässä on järkevää laskea periodin $t + 1$ tuoton ehdollinen todennäköisyys ehdolla tuoton ajankohtaan t asti ulottuva historia $\{y_t, y_{t-1}, \dots\}$.

Ehdollisen varianssin mallintaminen

Mallin yleinen rakenne

- Kun y_t on osaketuotto ajankohtana t , kiinnostaa tietää millä todennäköisyydellä seuraavan periodin $t + 1$ tuotto y_{t+1} alittaa valitun riskituoton rajan c .
- Tässä on järkevää laskea periodin $t + 1$ tuoton ehdollinen todennäköisyys ehdolla tuoton ajankohtaan t asti ulottuva historia $\{y_t, y_{t-1}, \dots\}$.
- Jos merkitään $P_t(\cdot) = P_t(\cdot | y_s, s \leq t)$, saadaan ($y_{t+1} = h_{t+1}^{1/2} \varepsilon_{t+1}$)

$$P_t(y_{t+1} < c) = F_\varepsilon(c/h_{t+1}^{1/2}),$$

jossa $F_\varepsilon(\cdot)$ on virhetermin ε_t kertymäfunktio.

Ehdollisen varianssin mallintaminen

Mallin yleinen rakenne

- Kun y_t on osaketuotto ajankohtana t , kiinnostaa tietää millä todennäköisyydellä seuraavan periodin $t + 1$ tuotto y_{t+1} alittaa valitun riskituoton rajan c .
- Tässä on järkevää laskea periodin $t + 1$ tuoton ehdollinen todennäköisyys ehdolla tuoton ajankohtaan t asti ulottuva historia $\{y_t, y_{t-1}, \dots\}$.
- Jos merkitään $P_t(\cdot) = P_t(\cdot | y_s, s \leq t)$, saadaan ($y_{t+1} = h_{t+1}^{1/2} \varepsilon_{t+1}$)

$$P_t(y_{t+1} < c) = F_\varepsilon(c/h_{t+1}^{1/2}),$$

jossa $F_\varepsilon(\cdot)$ on virhetermin ε_t kertymäfunktio.

- Jos $F_\varepsilon(\cdot)$ ja h_{t+1} tunnetaan, voidaan oikealla oleva todennäköisyys laskea. Käytännössä molemmat joudutaan selvittämään aineistoa apuna käyttäen.

Ehdollisen varianssin mallintaminen

Mallin yleinen rakenne

- Usein kysytään toisin päin kuin edellä.
- Mikä on annettua (pientä) todennäköisyyttä π vastaava riskiarvo c (engl. 'value at risk'), jolle pätee $P_t(y_{t+1} < c) = \pi$?
- Vastaus saadaan hakemalla c , joka tunnetulle h_{t+1} :n arvolla toteuttaa

$$P_t(y_{t+1} < c) = F_\varepsilon(c/h_{t+1}^{1/2}) = \pi.$$

Ehdollisen varianssin mallintaminen

Mallin yleinen rakenne

- Jotta yhtälöstä

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

saataisiin käyttökelpoinen malli, täytyy ehdollisen varianssin h_t riippuvuus prosessin y_t menneisyydestä y_{t-j} , $j \geq 1$, spesifioida.

- Seuraavassa tarkastellaan *ns. autoregressivisiä ehdollisen heteroskedastisuuden malleja*, joita voidaan pitää ehdollisen varianssin standardimalleina ja siinä mielessä ARMA-mallien vastineina ehdollista varianssia mallinnettaessa.

- Määrittely:

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

$$h_t = \omega + \alpha y_{t-1}^2, \quad \omega > 0 \text{ ja } \alpha \geq 0,$$

jossa $\omega > 0$ ja $\alpha \geq 0$, jotta $h_t > 0$ ja siten myös $\text{Var}(y_t) > 0$.

- Näiden yhtälöiden tai vain jälkimmäisen määrittelemää mallia kutsutaan *ensimmäisen asteen autoregressiiviseksi ehdollisen heteroskedastisuuden malliksi* eli ARCH(1)-malliksi ('autoregressive conditional heteroskedasticity').
- Jos $\alpha < 1$, on y_t sekä vahvasti että heikosti stationaarinen eli $E(y_t^2) < \infty$.
- Tällöin myös h_t on vahvasti, muttei välttämättä heikosti, stationaarinen. $E(h_t) < \infty$ kuitenkin pätee.

Ehdollisen varianssin mallintaminen

ARCH(1)-malli

- Malli

$$h_t = \omega + \alpha y_{t-1}^2, \quad \omega > 0 \text{ ja } \alpha \geq 0,$$

- Kun heikko stationaarisuus oletetaan, niin

$$\sigma_y^2 \equiv \text{Var}(y_t) = E(y_t^2) = E(h_t)$$

ja siten

$$E(y_t^2) = \omega + \alpha E(y_{t-1}^2) \Leftrightarrow \sigma_y^2 = \omega / (1 - \alpha)$$

Siis, $\alpha < 1$ on välttämätön (ja riittävä) ehto heikolle stationaarisuudelle.

- Stationaarisuuskysymykset hankalampia kuin ARMA-malleilla, koska y_t on epälineaarinen prosessi:

$$y_t = (\omega + \alpha y_{t-1}^2)^{1/2} \varepsilon_t$$

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

$$(ii) \quad h_t = \omega + \alpha y_{t-1}^2, \quad \omega > 0 \text{ ja } 0 < \alpha < 1 \text{ oletetaan.}$$

- Jos $|y_{t-1}|$ on suuri, on ehdollinen varianssi h_t suuri (ks. (ii))
 - ⇒ todennäköisyys havaita suuri $|y_t|$ tulee "kohtuullisen" suureksi (ks. (i))
 - ⇒ seuraavan periodin ehdollinen varianssi h_{t+1} tulee myös suureksi.
- Siis, itseistartovaltaan suurilla havainnoilla on taipumus seurata toisiaan ja samoin pienillä eli volatilitetissä havaitaan "klusteroitumista" (vrt. DAX-indeksi).

- $y_t = h_t^{1/2} \varepsilon_t$, $\varepsilon_t \sim \text{iid}(0, 1)$ ja $h_t = \omega + \alpha y_{t-1}^2$, $0 \leq \alpha < 1 \Rightarrow$
$$y_t^2 = \omega + \alpha y_{t-1}^2 + \zeta_t,$$

jossa $\zeta_t = y_t^2 - h_t = h_t (\varepsilon_t^2 - 1)$ toteuttaa oletuksella $E(y_t^4) < \infty$

$$E(\zeta_t) = 0 \quad \text{ja} \quad \text{Cov}(\zeta_t, \zeta_{t-k}) = 0, \quad k > 0.$$

- Siis, prosessia y_t^2 voidaan tarkastella AR(1)-prosessina, jonka virheet ovat heikkoa valkoista kohinaa, mutta eivät vahvaa valkoista kohinaa:

$$\zeta_t = (\omega + \alpha y_{t-1}^2) (\varepsilon_t^2 - 1) \quad \text{ja} \quad y_{t-1}^2 = \omega + \alpha y_{t-2}^2 + \zeta_{t-1}.$$

- $y_t = h_t^{1/2} \varepsilon_t$, $\varepsilon_t \sim \text{iid}(0, 1)$ ja $h_t = \omega + \alpha y_{t-1}^2$, $0 \leq \alpha < 1 \Rightarrow$

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

- Kun $E(y_t^4) < \infty$, $\zeta_t = (\omega + \alpha y_{t-1}^2)(\varepsilon_t^2 - 1)$ toteuttaa

$$E(\zeta_t) = 0 \text{ ja } \text{Cov}(\zeta_t, \zeta_{t-k}) = 0, \quad k > 0$$

- Kuten AR(1)-prosessin tapauksessa voidaan (*) :stä siten johtaa

$$\text{Cor}(y_t^2, y_{t-k}^2) = \alpha^k, \quad k = 0, 1, \dots$$

(lin. prosessin autokovarianssifunktion johto pätee myös, kun virhetermi on vain autokorreloimaton)

- Siis, oletuksella $E(y_t^4) < \infty$ ARCH(1)-mallissa

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

$$h_t = \omega + \alpha y_{t-1}^2, \quad \omega > 0 \text{ ja } \alpha \geq 0,$$

pätee

$$\text{Cor}(y_t^2, y_{t-k}^2) = \alpha^k, \quad k = 0, 1, \dots$$

Koska $\alpha > 0$, on itseisarvoltaan suurilla (vast. pienillä) havainnoilla taipumusta seurata toisiaan eli volatilitetilla on taipumusta klusteroitua.

- **Huom.:** Oletus $E(y_t^4) < \infty$ vaatii enemmän kuin $\alpha < 1$. Täsmällinen ehto riippuu virhetermin ε_t jakaumasta. Jos $\varepsilon_t \sim N(0, 1)$, vaaditaan $\alpha^2 < 1/3$ eli $\alpha < \sqrt{1/3} \approx 0.577$, jolloin y_t^2 :n autokorreloituneisuus on varsin heikkoa.

- Vaikka ξ_t onkin heikkoa valkoista kohinaa ja $E(\xi_t^2) < \infty$ pätsisi, ei yhtälöä

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

voida tulkita tavanomaiseksi AR(1)-malliksi.

- Tämän syynä on prosessin ξ_t riippuvuus y_{t-1} :stä:

$$\xi_t = y_t^2 - h_t = h_t (\varepsilon_t^2 - 1) = (\omega + \alpha y_{t-1}^2) (\varepsilon_t^2 - 1).$$

Tämä tarkoittaa erityisesti, *että sen enempää heikkoa kuin vahvaakaan stationaarisuutta ei voida päätellä soveltaen AR(1) prosessille jaksossa 2.2.3 käytettyjä menettelyjä yhtälöön (*), vaan stationaarisuus on perusteltava toisin.*

- Oletetaan, että satunnaismuuttujalle X pätee

$$E(X^4) < \infty \text{ ja } E(X) = 0.$$

- Tällöin X :n jakauman huipukkuus on määritelmän mukaan

$$\kappa_X = E(X^4) / (E(X^2))^2$$

Määritelmä ei riipu X :n varianssista, joka voidaan skaalata ykköseksi.

- $N(0, 1)$ -jakauman huipukkuus on 3, joka usein vähennetään edellä esitetystä huipukkuuden määritelmästä.

- Oletetaan $E(y_t^4) < \infty$. Rakenneyhtälö $y_t = h_t^{1/2} \varepsilon_t$, $\varepsilon_t \sim \text{iid}(0, 1)$, ja riippumattomuus $h_t \perp\!\!\!\perp \varepsilon_t \Rightarrow$

$$E(y_t^4) = E(h_t^2) E(\varepsilon_t^4) \geq (E(h_t))^2 E(\varepsilon_t^4) = (E(y_t^2))^2 E(\varepsilon_t^4).$$

- Siis,


$$\kappa_y \equiv \frac{E(y_t^4)}{(E(y_t^2))^2} \geq \frac{E(\varepsilon_t^4)}{(E(\varepsilon_t^2))^2} \equiv \kappa_\varepsilon.$$

eli y_t :n jakauman huipukkuus ylittää ε_t :n jakauman huipukkuuden.

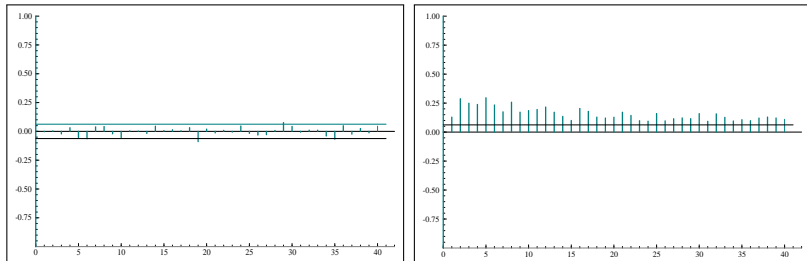
- Tapauksessa $\varepsilon_t \sim N(0, 1)$ pätee $\kappa_y = 3(1 - \alpha^2) / (1 - 3\alpha^2)$ joten $\kappa_y > 3 = N(0, 1)$ -jakauman huipukkuus.

- Epäyhtälön $\kappa_y \geq \kappa_\varepsilon$ perustelussa käytettiin vain y_t :n stationaarisuutta, oletusta $E(y_t^4) < \infty$ ja rakenneyhtälöä $y_t = h_t^{1/2} \varepsilon_t$, $\varepsilon_t \sim \text{iid}(0, 1)$.
- Näin ollen tämä epäyhtälö on ominainen kaikille rakenneyhtälöön perustuvilla malleilla.
- Kuvion 5.1 DAX-indeksistä saadaan κ_y :n estimaatiksi $4.79 > 3$.
- Tällainen normaalijakaumaa suurempaa huipukkuus on volatiliteetin klusteroitumisen lisäksi toinen tyypillinen piirre osake- ja valuuttakurssituotoilla. Nämä piirteet on nähty niin tyypillisiksi, että niiden yhteydessä käytetään englannin kielessä nimitystä 'stylized fact'.

Ehdollisen varianssin mallintaminen



Kuvio 5.1(i). Frankfurtin pörssin DAX-indeksin päivätuotot ajalta 1.1.1999 - 31.1.2003. Tuotot on laskettu kaavalla $y_t = 100 (\log P_t - \log P_{t-1})$, jossa P_t on indeksin arvo päivänä t .



Kuvio 5.1(ii). Frankfurtin pörssin DAX-indeksin päivätuotoista ajalta 1.1.1999 - 31.1.2003 laskettu otosautokorrelaatiofunktio (vas.) ja neljien otosautokorrelaatiofunktio (oik.) viipymillä $h = 1, \dots, 40$.

- DAX-indeksistä ensimmäisen autokorrelaation $\text{Cor}(y_t^2, y_{t-1}^2)$ estimaatti on vain 0.13.
- Koska ARCH(1)-mallissa $\text{Cor}(y_t^2, y_{t-1}^2) = \alpha$, täytyisi α :n olla pieni, jotta ARCH(1) olisi sopiva malli.
- Koska lisäksi, $\text{Cor}(y_t^2, y_{t-k}^2) = \alpha^k$, täytyisi neliöityjen havaitojen autokorrelaatioiden vaimentua nopeasti nollaa kohti.
- Näin ei selvästikään käy, mikä viittaa yleisemmän mallin tarpeellisuuteen.

- ARCH(1)-mallin ilmeinen yleistys on ARCH(s)-malli,

$$\begin{aligned}y_t &= h_t^{1/2} \varepsilon_t, \quad \varepsilon_t \sim \text{iid}(0, 1), \\h_t &= \omega + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2.\end{aligned}$$

Jotta vaatimus $h_t > 0$ ja siten $\text{Var}(y_t) > 0$ toteutuisi, oletetaan $\omega > 0$ ja $\alpha_i \geq 0$, $i = 1, \dots, s$.

- h_t :n yhtälöstä saadaan

$$y_t^2 = \omega + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2 + \zeta_t,$$

jossa jälleen $\zeta_t = y_t^2 - h_t = h_t (\varepsilon_t^2 - 1)$ ja, kuten ARCH(1)-tapauksessa, pätee $E(\zeta_t) = 0$ (kun $E(y_t^2) < \infty$) ja ζ_t :n autokorreloimattomuus (kun $E(y_t^4) < \infty$).

- Olettaen heikko stationaarisuus seuraa yhtälöstä

$$y_t^2 = \omega + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2 + \xi_t$$

$$E(y_t^2) = \omega + \alpha_1 E(y_{t-1}^2) + \cdots + \alpha_s E(y_{t-s}^2) + E(\xi_t)$$

ja edelleen, koska $E(\xi_t) = 0$ ja $E(y_t^2) = \sigma_y^2 \quad \forall t$,

$$\sigma_y^2 = \omega + \alpha_1 \sigma_y^2 + \cdots + \alpha_s \sigma_y^2.$$

- Siis,

$$\sigma_y^2 = \omega / (1 - \alpha_1 - \cdots - \alpha_s),$$

joten välttämätön ehto heikolle stationaarisuudelle on $\alpha_1 + \cdots + \alpha_s < 1$, joka on myös riittävä sekä heikolle että vahvalle stationaarisuudelle.

- Koska $\alpha_i \geq 0$, $i = 1, \dots, s$, voidaan osoittaa tulos

$$\alpha_1 + \dots + \alpha_s < 1 \Leftrightarrow 1 - \alpha_1 z - \dots - \alpha_s z^s \neq 0, \quad |z| \leq 1.$$

- Kuten tapauksessa $s = 1$, *ARCH(s)-prosessin stationaarisuutta ei kuitenkaan voida päätellä soveltamalla AR(s)-prosessin stationaarisuusehtoa muodollisesti samanlaiseen prosessiin*

$$y_t^2 = \omega + \alpha_1 y_{t-1}^2 + \dots + \alpha_s y_{t-s}^2 + \xi_t,$$

jossa ξ_t on heikkoa valkoista kohinaa.

- Jos oletetaan stationaarisuus ja $E(y_t^4) < \infty$, voidaan tätä yhtälöä ja ξ_t :n autokorreloimattomuutta käyttäen johtaa neliöidyn prosessin y_t^2 autokovarianssi- ja autokorrelaatiofunktio samaan tapaan kuin AR(p)-prosessin tapauksessa (ks. jakso 3.1).

- Yhtälön

$$y_t^2 = \omega + \alpha_1 y_{t-1}^2 + \cdots + \alpha_s y_{t-s}^2 + \zeta_t, \quad \zeta_t \sim \text{wn}(0, \cdot)$$

perusteella on selvää, että ARCH-tyyppinen ehdollinen heteroskedastisuus ilmenee aikasarjan neliöiden autokorreloituneisuutena.

- Neliöityjen havaintojen otosautokorrelaatioita ja McLeodin ja Lin testisuuretta voidaan siten käyttää testattaessa nollahypoteesia $y_t \sim \text{iid}(0, \sigma^2)$ ARCH-tyyppistä ehd. heteroskedastisuutta vastaan.
- Voidaan osoittaa, että tämä testi on asympotoottisesti yhtäpitävä Raon pistemäärätestin kanssa, kun rakenneyhtälössä

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

oletetaan normaalisuus ja vaihtoehtona on ARCH(s)-malli, jossa s on McLeodin ja Lin testisuureessa käytettyjen otosautokorrelaatioiden lukumäärä.

Ehdollisen varianssin mallintaminen

GARCH(1,1)-malli

- On havaittu, että sovellettaessa ARCH(s)-mallia vaaditaan usein suuri s:n arvo ja siten suuri määrä estimoitavia parametreja.
- Onnistuneeksi vähäparametriseksi vaihtoehdoksi on osoittautunut ns. GARCH(1,1)-malli (G \leftrightarrow 'generalized')

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

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

jossa vaatimuksen $h_t > 0$ vuoksi oletetaan $\omega > 0$, $\alpha \geq 0$ ja $\beta \geq 0$.

- Tapaus $\alpha = 0$ vain, jos samalla $\beta = 0$, koska muuten h_t :n differenssiyhtälöstä tulee ei-satunnainen.

- Yhtälö $h_t = \omega + \beta h_{t-1} + \alpha y_{t-1}^2$ & peräkkäiset sijoitukset \Rightarrow

$$h_t = \omega \sum_{j=0}^k \beta^j + \alpha \sum_{j=0}^k \beta^j y_{t-1-j}^2 + \beta^{k+1} h_{t-k-1}.$$

- Tämä viittaa siihen, että tapauksessa $\beta < 1$ saadaan

$$h_t = \omega \sum_{j=0}^{\infty} \beta^j + \alpha \sum_{j=0}^{\infty} \beta^j y_{t-1-j}^2$$

eli GARCH(1,1)-malli voidaan tulkita (tietyn tyypiseksi) ARCH(∞)-malliksi.

- Ehto $\beta < 1$ ei kuitenkaan riitä takaamaan y_t :n stationaarisuutta eikä äärellistä varianssia.
- Riittävä ehto vahvalle ja heikolle stationaarisuudelle on $\alpha + \beta < 1$.