

REGRESSIOANALYYSIN JATKOKURSSI, 5–10 OP (aine- ja syventävät opinnot).
15.9.–16.12.2011. Kirjallisuus: Russell Davidson ja James MacKinnon: *Econometric Theory and Methods*. Luennoi: yliopistonlehtori Pekka Pere.

Harjoitukset 6 (pe 21.10.)

1. Seuraavat kaksi puheluiden kysyntään liittyvää mallia on estimoitu PNS:llä Telecom Canadan neljännesvuosiaineistosta 1975–1985. (Mallit eivät ole realistisia; ne on laadittu havainnollistamaan tehtävän ideaa.) Ensimmäinen estimoitu malli on

$$\log(P_t) = -40.51 - 0.58 \log(H_t/KHI_t) + 1.64D_t \log(H_t/KHI_t) + \mathbf{x}_t' \hat{\gamma}_{1t} + \hat{\varepsilon}_{1t}. \quad (1)$$

Yllä ”log” on luonnollinen logaritmi, P on puheluiden määrä, H on puheluiden hinta, KHI on Kanadan kuluttajahintaindeksi, jonka arvo on normeerattu sadaksi vuonna 1981⁵, D on dummy-muuttuja, joka saa arvon nolla vuoteen 1983 asti ja sen jälkeen arvon yksi, $\hat{\varepsilon}_{1t}$ on residuaali ja alaindeksi t viittaa ajankohtaan. Malliin kuuluu muita tehtävän kannalta epäoleellisia muuttujia ja parametreja, joita on merkitty $\mathbf{x}_t' \hat{\gamma}_{1t}$:llä. Mallin mukaan puheluiden määrä on riippunut negatiivisesti puheluiden reaalisesta hinnasta (hinnasta suhteessa kuluttajahintaindeksiin) mutta vuoden 1983 jälkeen riippuvuutta osoittava kerroin muuttuu.

Jos KHI jaetaan sadalla — KHI :n tulkinnan kannalta täysin merkityksetön muutos — lasketaan uusi H/KHI^* -muuttuja ja estimoidaan malli (1) (”vapaila” parametreilla) uudestaan, niin saadaan

$$\log(P_t) = -40.32 - 0.50 \log(H_t/KHI_t^*) - 0.02D_t \log(H_t/KHI_t^*) + \mathbf{x}_t' \hat{\gamma}_{1t}^* + \hat{\varepsilon}_{1t}^* \quad (1^*)$$

ilmeisin merkinnöin. Mallien (1) ja (1*) kertoimet (ja residuaalit) poikkeavat!

a) Selitä, miksi estimaatit ovat eri suuria yhtälöissä (1) ja (1*). (Vihje: Sijoita ensimmäiseen yhtälöön KHI :n paikalle $KHI^* = KHI/100$, muokkaa yhtälö yhtäpitäväksi mallin (1) kanssa ja pohdi, miten laatimasi yhtälö eroaa mallista (1*).)

b) Perustele, miksi β_i -kertoimien estimaatit eivät muuttuisi edellä kuvatuksen normeerauksen jälkeen, jos alunperin estimoitu malli olisi ollut

$$\log(P_t) = \alpha_1 + \alpha_2 D_t + \beta_1 \log(H_t/KHI_t) + \beta_2 D_t \log(H_t/KHI_t) + x_t' \gamma_{2t} + \varepsilon_{2t}. \quad (2)$$

(Vihje: Sijoita $a \times KHI$ yhtälöön (2). Edellä a on mielivaltainen kerroin.)

⁵Kuluttajahintaindeksi mittaa kuluttajan kannalta tärkeiden tavaroiden ja palvelusten hintaa — pähkinäkuoressa yleistä hintatasoa. Kun yksittäisen tuotteen hinta eri ajankohtina jaetaan kuluttajahintaindeksiin vastaavalla lukemalla, saadaan selville, miten tuotteen reaalin hinta on kehittynyt.

2. Testaan F -testillä HT 3.2:n malleissa (1), (2) ja (3) kertoimien nolluutta (pois lukien vakiovektorinkertoimen). Poikkeavatko näistä malleista lasketut F -testisuureet nollassa nollahypoteeseille $H_0: \beta_2 = \dots \beta_k = 0$ ja $H_0^*: \beta_2^* = \dots \beta_k^* = 0$? Perustele.

3. Regressiomalli on

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u} = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2 + \mathbf{u}_1,$$

jossa $\mathbf{u} \sim \text{IID}(\mathbf{0}, \sigma^2 \mathbf{I})$, $\boldsymbol{\beta} = [\boldsymbol{\beta}'_1 \quad \boldsymbol{\beta}'_2]'$, $\boldsymbol{\beta}_1$ ja $\boldsymbol{\beta}_2$ ovat $k_1 \times 1$ ja $k_2 \times 1$ -vektoreita, \mathbf{X}_1 ja \mathbf{X}_2 ovat $n \times k_1$ ja $n \times k_2$ -matriiseja ($k_1, k_2 \geq 1$) ja \mathbf{X} on täysiasteinen $n \times k$ -matriisi ($k_1 + k_2 = k$). Merkitään $r = k_2$. Testataan F -testillä nollahypoteesia $H_0: \boldsymbol{\beta}_2 = \mathbf{0}$ (r lineaarisesti riippumatonta rajoitusta).

Luennolla todistettiin, että nollahypoteesin pätiessä F -testisuure voidaan esittää muodossa

$$F_{\beta_2} = \frac{\boldsymbol{\varepsilon}' \mathbf{M}_1 \mathbf{X}_2 (\mathbf{X}_2' \mathbf{M}_1 \mathbf{X}_2)^{-1} \mathbf{X}_2' \mathbf{M}_1 \boldsymbol{\varepsilon} / r}{\boldsymbol{\varepsilon}' \mathbf{M}_X \boldsymbol{\varepsilon} / (n - k)} \quad (3)$$

(kaava (4.34) ja että se noudattaa asympotoottisesti $\chi^2(r)/r$ -jakaumaa, jos selittäjät ovat eksogeenisiä. Yllä $\boldsymbol{\varepsilon} = \sigma^{-1} \mathbf{u}$, joten $\boldsymbol{\varepsilon} \sim \text{IID}(\mathbf{0}, \mathbf{I})$. Todista, että sama asympotoottinen jakauma pätee, jos selittäjät ovat ennaltamääräytyneitä. Voit olettaa ilman eri todistusta, että F_{β_2} :n nimittäjä konvergoi stokastisesti 1:seen (perustele intuitiivisesti). (Vihje 1: Normeeraa F_{β_2} :n termit kuten kirjan kaavassa (4.58). Vihje 2: Todistus aivan samaan tapaan kuin vastaavalle tulokselle t -testisuurelle kirjan sivuilla 152–154.)

4. Tutkitaan regressiomallia

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}_1 \quad (4)$$

ilmeisin merkinnöin. Sitokoon k -vektorin $\boldsymbol{\beta}$ parametreja r lineaarisesti toisistaan riippumatonta rajoitusta $\mathbf{R}\boldsymbol{\beta} = \mathbf{r}$. Tässä \mathbf{R} on astetta r oleva $r \times k$ -matriisi ($r \leq k$; r on myös vektorin \mathbf{r} pituus eli rajoitusten lukumäärä).¹ Tehtävä liittyy kirjan sivuihin 138 ja 141.

a) Perustele, että selittäjät (matriisin \mathbf{X} sarakkeet) ja niitä vastaavat parametrit (vektorissa $\boldsymbol{\beta}$) voidaan järjestää aina niin, että lineaariset rajoitukset voidaan kirjoittaa muodossa

$$\mathbf{R}_1 \boldsymbol{\beta}_1 + \mathbf{R}_2 \boldsymbol{\beta}_2 = \mathbf{r}, \quad (5)$$

jossa \mathbf{R}_1 on täysiasteinen $r \times r$ -matriisi ja \mathbf{R}_2 on $r \times (k - r)$ -matriisi ($\boldsymbol{\beta}' = [\boldsymbol{\beta}'_1 \quad \boldsymbol{\beta}'_2]$).

¹Merkinnät \mathbf{r} ja r voivat sekoittua, jos $r = 1$. Selkeämpää olisi merkitä rajoitusten lukumääräksi k_1 . Tässä noudatetaan kuitenkin kirjan merkintää rajoitusten lukumäärälle ($= r$; s:t 141 ja 173).

b) Perustele, että yhtälö

$$\mathbf{y}^* = \mathbf{Z}_2\boldsymbol{\beta}_2 + \mathbf{u}_0 \quad (6)$$

on yhtäpitävä yhtälön (4) kanssa, kun rajoitukset (5) pätevät. Yllä $\mathbf{y}^* = \mathbf{y} - \mathbf{X}_1\mathbf{R}_1^{-1}\mathbf{r}$ ja $\mathbf{Z}_2 = \mathbf{X}_2 - \mathbf{X}_1\mathbf{R}_1^{-1}\mathbf{R}_2$. ($\mathbf{X} = [\mathbf{X}_1 \ \mathbf{X}_2]$). (Vihje: Ratkaise $\boldsymbol{\beta}_1$ yhtälöstä (5).)

c) Lisätään regressioon (6) selittäjiksi \mathbf{X}_1 :

$$\mathbf{y}^* = \mathbf{Z}_1\boldsymbol{\gamma}_1 + \mathbf{Z}_2\boldsymbol{\gamma}_2 + \mathbf{u}_1, \quad (7)$$

jossa $\mathbf{Z}_1 = \mathbf{X}_1$ ja $\boldsymbol{\gamma}_2 = \boldsymbol{\beta}_2$. Perustele, että $S(\mathbf{Z}_1, \mathbf{Z}_2) = S(\mathbf{X}_1, \mathbf{Z}_2) = S(\mathbf{X})$.

d) Esimerkkinä olkoon regressio

$$\mathbf{y} = \beta_1\mathbf{x}_1 + \beta_2\mathbf{x}_2 + \mathbf{u}_1$$

rajoituksella $\beta_1 + \beta_2 = 1$ (\mathbf{x}_1 ja \mathbf{x}_2 ovat n -vektoreita). Selitä miten se ja regressiot

$$\mathbf{y} - \mathbf{x}_1 = \beta_2(\mathbf{x}_2 - \mathbf{x}_1) + \mathbf{u}_0$$

ja

$$\mathbf{y}^* = \gamma_1\mathbf{z}_1 + \gamma_2\mathbf{z}_2 + \mathbf{u}_1$$

liittyvät regressioihin edellä. Yllä $\mathbf{y}^* = \mathbf{y} - \mathbf{x}_1$, $\mathbf{z}_1 = \mathbf{x}_1$ ja $\mathbf{z}_2 = \mathbf{x}_2 - \mathbf{x}_1$.

e) Selitä, miten oheiset kuviot liittyvät edellisiin kohtiin.

f) Perustele edellisten kohtien avulla (vrt. kirjan s:t 138, 141 ja 173), että regressioiden (4) ja (7) residuaalivektorit ovat samoja ja että nollahypoteesin $\mathbf{R}\boldsymbol{\beta} = \mathbf{r}$ pätevyyttä mallille (4) voidaan tutkia testaamalla rajoitusta $\boldsymbol{\gamma}_1 = \mathbf{0}$ F -testisuureella regressiomallissa (7). Edellä $\boldsymbol{\gamma}_1$ on r -vektori.